

NICK POLSON
JAMES SCOTT



NUMERI
INTELLIGENTI

*La matematica
che fa funzionare l'intelligenza artificiale
di Google, Facebook, Apple & Co.*

**UTET**



Titolo originale: *AIQ: How People and Machines Are Smarter Together*
Traduzione dall'inglese: Giuseppe Bozzi

Copyright © 2018 by Nick Polson and James Scott. This edition arranged with DeFiore and Company Literary Management, Inc. through Andrew Nurnberg Associates International Limited.

Per l'edizione italiana: © 2019 DeA Planeta Libri S.r.l.
Redazione: Via Inverigo, 2 – 20151 Milano

Progetto grafico: X^XY studio
www.deaplanetalibri.it

Prima edizione e-book: marzo 2019
ISBN 978-88-511-6952-7

Tutti i diritti riservati

www.utetlibri.it
www.deagostini.it



[@DeAPlanetaLibri](https://www.facebook.com/DeAPlanetaLibri)



[@DeAPlanetaLibri](https://twitter.com/DeAPlanetaLibri)



[@DeAPlanetaLibri](https://www.instagram.com/DeAPlanetaLibri)



[@Utetlibri](https://www.facebook.com/Utetlibri)



[@UtetLibri](https://twitter.com/UtetLibri)



[@UtetLibri](https://www.instagram.com/UtetLibri)

Nessuna parte di questo volume può essere riprodotta, memorizzata o trasmessa in alcuna forma o con alcun mezzo elettronico, meccanico, in fotocopia, in disco o in altro modo, compresi cinema, radio, televisione, senza autorizzazione scritta dell'Editore.

Le riproduzioni effettuate per finalità di carattere professionale, economico o commerciale o comunque per uso diverso da quello personale possono essere effettuate a seguito di specifica autorizzazione rilasciata da CLEARedi, Corso di Porta Romana n. 108, Milano 20122, e-mail info@clearedi.org e sito web www.clearedi.org

Edizione elettronica realizzata da Gag srl

Nick Polson e James Scott

NUMERI INTELLIGENTI

La matematica che fa funzionare
l'intelligenza artificiale
di Google, Facebook, Apple & Co.

Traduzione di Giuseppe Bozzi



SOMMARIO

Introduzione

[Che cosa significa davvero "IA"?](#)

[Come siamo arrivati fin qui?](#)

[Ansie da IA](#)

[Brevi considerazioni sulla matematica](#)

Il rifugiato

[Abraham Wald, eroe della seconda guerra mondiale](#)

[I primi anni di Wald](#)

[Wald in America](#)

[Wald e gli aerei mancanti](#)

[Dati mancanti: quello che non conosci può trarti in inganno](#)

[Bombardieri mancanti, valutazioni mancanti](#)

[Le caratteristiche nascoste dicono tutto](#)

[Il lascito eterogeneo dei motori di suggerimenti](#)

[Post scriptum](#)

La fabbricante di candellieri

[Input/output: come le macchine riconoscono gli schemi](#)

[Una scoperta stellare](#)

[Adattare le regole di predizione ai dati](#)

[Oltre le linee rette](#)

[Post scriptum](#)

Il reverendo e il sottomarino

[La rivoluzione robotica](#)

[In che modo trovare un sottomarino è simile a sapere dove ti trovi lungo una strada?](#)

[La regola di Bayes, dal reverendo al robot](#)

[Come la regola di Bayes può renderci più intelligenti](#)

[Post scriptum](#)

Amazing Grace

[La storia di due rivoluzioni](#)

[Da Grace ad Alexa: la rivoluzione del linguaggio naturale](#)

[1980-2010: lo sviluppo dell'elaborazione statistica del linguaggio naturale](#)

[Come le parole diventano numeri](#)

[La comunicazione tra esseri umani e macchine](#)

[Post scriptum](#)

[Il genio della Zecca reale](#)

[La seconda carriera professionale di Isaac Newton](#)

[La prova della pisside](#)

[Rilevazione di anomalie nell'era dell'IA](#)

[Moneyball per l'era digitale](#)

[Post scriptum](#)

[La dama con la lanterna](#)

[L'angelo della Crimea](#)

[L'eredità di Nightingale per l'analisi dei dati](#)

[Danni evitabili nell'era dell'IA](#)

[IA alla riscossa?](#)

[Che cosa succederà?](#)

[Post scriptum](#)

[Il Clipper degli Yankees](#)

[Joe DiMaggio e la fretta di concludere](#)

[Modelli antiquati](#)

[Distorsioni in ingresso e in uscita](#)

[Post scriptum](#)

[Ringraziamenti](#)

[Note](#)

[Indice analitico](#)

A Diana e Anne.
NP

Ai miei nonni, a Margaret Aiken,
e alla ghinea d'oro.
JS

INTRODUZIONE

Insegniamo scienza dei dati a centinaia di studenti ogni anno. Sono tutti affascinati dall'Intelligenza artificiale (IA) e fanno *ottime* domande. Come impara un'automobile a guidare da sola? Come riesce Alexa a capire quello che dico? Come fa Spotify a suggerirmi playlist così belle? Come riesce Facebook a riconoscere i miei amici nelle foto che carico? Gli studenti capiscono che l'IA non è una specie di droide appartenente a un futuro fantascientifico: è qui e ora, e sta cambiando il mondo uno smartphone alla volta. Vogliono capirla, e vogliono partecipare al cambiamento.

Ma i nostri studenti non sono gli unici a essere entusiasti. Condividono l'esaltazione con le aziende più grandi al mondo, da Amazon, Facebook e Google in America, a Baidu, Tencent e Alibaba in Cina. Probabilmente saprai che queste aziende stanno conducendo una costosa "corsa agli armamenti", ovvero ai talenti dell'IA, ritenuti essenziali per il loro futuro. Per anni le abbiamo viste corteggiare giovani dottori di ricerca con salari da oltre i 300 000 dollari e caffè decisamente migliore di quello che abbiamo all'università. Ora vediamo molte più aziende buttarsi nella mischia per assumere nel campo dell'IA, aziende che siedono su montagne di dati, per esempio nel settore assicurativo o petrolifero, con offerte salariali enormi e lussuose macchine per il caffè espresso.

Eppure, nonostante la corsa alle armi sia reale, pensiamo che esista una tendenza più marcata in atto nel settore dell'IA, una tendenza alla diffusione e alla divulgazione, piuttosto che alla concentrazione. Certo, ogni grande azienda hi-tech sta cercando di accaparrarsi talenti matematici e informatici. Ma, allo stesso tempo, la tecnologia e le idee alla base dell'IA si stanno diffondendo a velocità straordinaria: verso aziende più piccole, verso altri settori dell'economia, verso appassionati, programmatori, scienziati e ricercatori di tutto il mondo. Questo processo di democratizzazione attira, più di qualsiasi altra cosa, i nostri studenti: essi si trovano di fronte un'enorme massa di problemi in attesa di buone soluzioni da parte dell'IA.

Chi avrebbe pensato, per esempio, che un gruppo di laureandi potesse appassionarsi alla matematica dei cetrioli? Be', è successo. È stato quando hanno sentito la storia di Makoto Koike, un ingegnere automobilistico giapponese i cui genitori coltivano cetrioli. In Giappone i cetrioli si presentano in un'incredibile varietà di forme, dimensioni, colori e grado di spinosità. Sulla base di queste caratteristiche visive, essi devono essere separati in nove diverse classi, ognuna con un proprio prezzo di mercato. La madre di Koike passava *otto ore al giorno* a classificare manualmente i cetrioli. A un certo punto, Koike si accorse che poteva usare un software open source di IA prodotto da Google, chiamato TensorFlow, per fare lo stesso lavoro: doveva solo implementare un algoritmo di *deep learning* (apprendimento profondo) che riuscisse a classificare i cetrioli a partire da una fotografia. Koike non aveva mai usato TensorFlow o l'IA in precedenza ma, con tutte le risorse liberamente disponibili in rete, riuscì facilmente a imparare. Quando mise su YouTube un video della sua macchina classificatrice automatica basata sull'IA, Koike divenne una celebrità mondiale del deep learning e dei cetrioli. La sua non era solo la storia strappalacrime di un figlio che salva la madre da lunghe ore di lavoro ingrato. Era anche di ispirazione per studenti e programmatori di tutto il mondo: se l'IA può risolvere i problemi di un coltivatore di cetrioli, può risolvere qualsiasi problema.

Quel messaggio si sta diffondendo rapidamente. I medici ora usano l'IA per diagnosticare e trattare i tumori. Le compagnie elettriche usano l'IA per produrre energia in modo più efficiente. Gli investitori la utilizzano per gestire i rischi di investimento. Le compagnie petrolifere la usano per aumentare la sicurezza nella trivellazione in acque profonde. Le forze dell'ordine la utilizzano per dare la caccia ai terroristi. Gli scienziati la usano per fare nuove scoperte in astronomia, fisica e neuroscienze. Aziende, ricercatori e semplici appassionati usano l'IA in migliaia di modi diversi: per rilevare perdite di gas, estrarre ferro, predire epidemie, salvare le api dall'estinzione o quantificare la disparità di genere nei film di Hollywood. Ed è solo l'inizio.

Pensiamo che la *vera* storia dell'IA sia la storia di questa diffusione: da un pugno di concetti matematici fondamentali, che risalgono a decenni o persino secoli fa, agli odierni supercomputer e alle macchine che parlano, pensano o classificano cetrioli, fino ad arrivare alle nuove e pervasive meraviglie digitali di domani. L'obiettivo del nostro libro è raccontarti questa storia. In parte è la

storia di una tecnologia, ma è principalmente una storia di idee, e di persone dietro le idee, persone di epoche antiche, che si buttavano a capofitto e risolvevano i loro problemi di matematica e di analisi dei dati, e che *non avevano la più pallida idea* del ruolo che le soluzioni da loro escogitate avrebbero giocato nel plasmare il mondo in cui viviamo oggi. Alla fine della storia, capirai cos'è l'IA, da dove viene, come funziona e perché è importante per la tua vita.

Che cosa significa davvero “IA”?

Quando senti il termine “IA”, non pensare a un droide. Pensa a un *algoritmo*.

Un algoritmo è un insieme di istruzioni dettagliate talmente esplicite che persino un computer, che prende tutto alla lettera, è in grado di comprenderle. (Probabilmente conosci la barzelletta del robot che resta intrappolato nella doccia in eterno, perché l'algoritmo sulla bottiglia dello shampoo dice: «Insaponare. Risciacquare. Ripetere».) Preso da solo, un algoritmo non è più intelligente di un trapano elettrico; esegue molto bene una cosa per volta, come, per esempio, ordinare una lista di numeri o cercare foto di animali carini sul web. Ma se metti insieme in modo ingegnoso parecchi algoritmi, puoi produrre IA: un'illusione di comportamento intelligente all'interno di un campo specifico. Per esempio, considera un assistente digitale come Google Home, a cui potresti porre una domanda del tipo «Dove posso trovare i migliori tacos di Austin a colazione?». Questa domanda innesca una reazione a catena di algoritmi:

Un algoritmo converte l'onda sonora non elaborata in un segnale digitale.

Un altro algoritmo traduce il segnale in una stringa di fonemi, o di suoni percettivamente distinti: «ko-la-tsjo-ne-ta-kos».

L'algoritmo successivo raggruppa i fonemi in parole: «colazione tacos».

Le parole sono inviate a un motore di ricerca – anch'esso composto da un'enorme sequenza di algoritmi – che elabora la domanda e invia una risposta.

Un ulteriore algoritmo trasforma la risposta in una frase di senso compiuto.

Un ultimo algoritmo pronuncia la frase in modo non robotico: «I migliori tacos di Austin a colazione sono da Julio's in Duval Street. Vuoi le indicazioni per arrivarci?».

Questa è l'IA. Quasi tutti i sistemi di IA – un'auto a guida autonoma, un classificatore di cetrioli, un software che tiene sotto controllo la tua carta di credito per evitare frodi – seguono lo stesso modello a “catena di algoritmi”. La catena riceve in ingresso dati da un campo specifico, effettua una serie di calcoli e formula una predizione o prende una decisione.

Gli algoritmi utilizzati in IA hanno due caratteristiche distintive. Per prima cosa, essi hanno tipicamente a che fare con probabilità piuttosto che con fatti certi. Un algoritmo di IA, per esempio, non dirà mai con certezza che una determinata transazione della carta di credito è fraudolenta. Dirà invece che la probabilità che sia fraudolenta è del 92% o qualsiasi altra stima considerando i dati a disposizione. Poi c'è il problema di stabilire come questi algoritmi “sappiano” quali istruzioni seguire. Negli algoritmi tradizionali, come quelli che controllano i siti web o i programmi di videoscrittura, le istruzioni sono stabilite in anticipo da un programmatore. Nell'IA, invece, l'algoritmo stesso “impara” le istruzioni tramite “dati di allenamento”. Nessuno dice a un algoritmo di IA come classificare le transazioni della carta di credito. L'algoritmo, invece, analizza molti esempi da ognuna delle due categorie (fraudolenta o non fraudolenta) e trova uno schema per distinguere l'una dall'altra. Nell'IA il ruolo del programmatore non è dire all'algoritmo che cosa fare. È dire all'algoritmo come *imparare* che cosa è necessario fare, usando i dati a disposizione e le regole della probabilità.

Come siamo arrivati fin qui?

I moderni sistemi di IA, come un'auto a guida autonoma o un assistente digitale, sono comparsi abbastanza di recente. Ma ti sorprenderà sapere che la maggior parte dei concetti alla base dell'IA sono in realtà *vecchi* – in molti casi, vecchi di centinaia di anni – e che i nostri antenati li hanno utilizzati per generazioni nella risoluzione di problemi. Per esempio, prendiamo le auto a guida autonoma. Google ha presentato la sua prima automobile di questo tipo nel 2009. Ma nel capitolo 3 scoprirai che uno dei concetti fondamentali alla base di queste automobili è stato scoperto intorno al 1750 da un pastore presbiteriano e che lo stesso concetto è stato utilizzato più di cinquant'anni fa da un team di matematici per risolvere uno degli enigmi più famosi della guerra fredda.

Oppure considera il processo di classificazione delle immagini, come per esempio il software che riconosce i tuoi amici nelle foto su Facebook. Gli algoritmi per l'analisi delle immagini sono migliorati radicalmente negli ultimi cinque anni. Ma nel capitolo 2 leggerai che le idee chiave risalgono al 1805 e che queste stesse idee sono state utilizzate un secolo fa, da un'astronoma quasi sconosciuta di nome Henrietta Leavitt, per rispondere a una delle domande più profonde mai poste dall'uomo: quanto è grande l'universo?

O ancora prendi il riconoscimento vocale, uno dei maggiori trionfi dell'IA degli ultimi anni. Gli assistenti digitali come Alexa e Google Home si esprimono incredibilmente bene, e potranno solo migliorare. Ma la prima persona che rese un computer in grado di comprendere il linguaggio fu un contrammiraglio della marina militare statunitense quasi settant'anni fa. (*Vedi capitolo 4.*)

Sono solo tre esempi di un aspetto sorprendente: in qualsiasi ambito dell'IA troverai idee che sono in circolazione da parecchio tempo. Dunque, dal punto di vista storico, la domanda non è «Perché l'IA si sta sviluppando ora?», ma «Perché non si è sviluppata molto tempo fa?». Per spiegare il mistero, dobbiamo esaminare tre forze tecnologiche che hanno permesso di traghettare questi venerandi concetti verso una nuova era.

Il primo facilitatore dell'IA è la crescita esponenziale della velocità dei computer in corso da vari decenni, solitamente nota come legge di Moore. È difficile descrivere in modo intuitivo quanto i computer siano diventati veloci. Il luogo comune più diffuso è che gli astronauti delle missioni Apollo sono atterrati sulla Luna con meno potenza computazionale rispetto a quella di una calcolatrice tascabile. Ma questo paragone non regge più perché... cos'è una calcolatrice tascabile? Proviamo invece con un'analogia automobilistica. Nel 1951 uno dei computer più veloci era l'UNIVAC, che effettuava 2000 operazioni al secondo, mentre una delle automobili più veloci era l'Alfa Romeo 6C, che viaggiava a 180 chilometri orari. Sia le automobili che i computer sono migliorati dal 1951, ma se le automobili avessero seguito la stessa crescita esponenziale dei computer, una odierna Alfa Romeo viaggerebbe a otto milioni di volte la velocità della luce.

Il secondo facilitatore è la *nuova* legge di Moore: la crescita esplosiva della quantità di dati disponibili, a causa della progressiva digitalizzazione delle informazioni. La Library of Congress occupa 10 terabyte di memoria ma, nel solo 2013, le quattro più grandi aziende di tecnologia – Google, Apple,

Facebook e Amazon – hanno raccolto dati per un ammontare 120 000 volte maggiore. Ed è una vita fa, in termini di anni internet. Il ritmo di raccolta dati accelera più di un razzo Apollo; nel 2017, più di 300 ore di video sono state caricate su YouTube ogni minuto, e più di 100 milioni di immagini sono state caricate su Instagram ogni giorno. Più dati vuol dire algoritmi più intelligenti.

Il terzo facilitatore è il *cloud computing* (nuvola informatica). Questa tendenza è quasi invisibile ai consumatori, ma ha avuto un enorme effetto democratizzante sull'IA. Per illustrarla, tracciamo un'analogia tra i dati e il petrolio. Immagina se tutte le compagnie petrolifere all'inizio del XX secolo avessero posseduto del petrolio, ma avessero dovuto costruire le infrastrutture per estrarlo, trasportarlo e raffinarlo per conto proprio. Qualsiasi compagnia con una buona idea per far fruttare il suo petrolio avrebbe dovuto affrontare costi enormi solo per poter iniziare: in queste condizioni, la maggior parte del petrolio sarebbe rimasta per sempre nel sottosuolo. La stessa logica si applica ai dati, il petrolio del XXI secolo. La maggior parte degli appassionati o delle piccole aziende avrebbe affrontato costi proibitivi se avesse dovuto comprare tutte le attrezzature e le conoscenze necessarie a costruire una IA partendo dai propri dati. Ma le risorse di cloud computing fornite da aziende come Microsoft Azure, IBM e Amazon Web Services hanno trasformato costi fissi in costi variabili, modificando radicalmente il bilancio economico per lo stoccaggio e l'analisi dei dati su larga scala. Oggi, chiunque voglia far uso del suo "petrolio" può farlo spendendo poco, noleggiando da terzi l'infrastruttura necessaria.

Mettendo insieme questi quattro fattori – processori più veloci, enormi insiemi di dati, cloud computing e soprattutto *buone idee* – si ottiene un'esplosione in stile supernova della domanda di IA e della capacità dell'IA di risolvere problemi reali.

Ansie da IA

Ti abbiamo già detto quanto i nostri studenti siano entusiasti dell'IA, e come le maggiori aziende al mondo si stiano affrettando a adottarla. Ma mentiremmo se dicessimo che *tutti* sono ottimisti nei confronti delle nuove tecnologie. In realtà, molti sono preoccupati per il lavoro, per la privacy, per la concentrazione di ricchezza o per i russi e per i loro finti profili Twitter automatici che generano fake news. Alcuni – e tra di essi il più famoso è Elon

Musk, l'imprenditore che sta dietro Tesla e SpaceX – dipingono uno scenario ancora più inquietante, in cui i robot acquistano coscienza di sé, decidono di non voler più obbedire a noi umani e iniziano a governarci con pugno di silicio.

Iniziamo dalle preoccupazioni di Musk. La sua visione ha avuto molto risalto, probabilmente perché la gente presta particolare attenzione quando un membro del club dei miliardari sovversivi parla di intelligenza artificiale. Musk ha detto che, sviluppando la tecnologia per l'IA, l'umanità sta «evocando un demone» e che le macchine intelligenti sono «la più grande minaccia alla nostra esistenza come specie».

Dopo che avrai letto il nostro libro, potrai decidere autonomamente se queste preoccupazioni sono fondate o meno. Tuttavia ti avvisiamo fin d'ora che è molto facile cadere nella trappola che gli scienziati cognitivi chiamano “euristica della disponibilità”: una scorciatoia mentale che porta le persone a stimare la plausibilità di un'affermazione basandosi sugli esempi più immediati che vengono in mente. Nel caso dell'IA, tali esempi provengono per lo più dalla fantascienza, e sono in gran parte negativi, da Terminator, a Borg, a HAL 9000. Pensiamo che questi esempi tratti dalla fantascienza facciano fortemente presa e inducano le persone a considerare la narrazione della “malvagia IA” con meno scetticismo di quanto dovrebbero. Dopotutto, il fatto che possiamo immaginare quelle cose e realizzare film su di esse non vuol dire che siamo in grado di costruirle. Nessuno al giorno d'oggi ha idea di come creare un robot con un'intelligenza *generale*, alla stregua di un umano o di Terminator. Forse i tuoi lontani discendenti riusciranno a farlo; forse saranno persino in grado di programmare la loro creazione in modo da terrorizzare i lontani discendenti di Elon Musk. Ma saranno loro scelte e loro preoccupazioni, perché nessuna opzione a oggi sul tavolo fa presagire, neanche lontanamente, tale possibilità. Ora, e nel futuro prossimo, le macchine “intelligenti” sono intelligenti solo all'interno del loro dominio specifico:

- Alexa può leggerti una ricetta per gli spaghetti alla bolognese, ma non può affettare le cipolle e sicuramente non può minacciarti con un coltello da cucina.
- Un'automobile a guida autonoma può condurti al campo di calcio, ma non può arbitrare la partita, né tantomeno decidere di legarti al palo e prenderti a pallonate nelle parti basse.

Inoltre, considera il rapporto costi-benefici di occuparsi della possibilità di essere soggiogati da robot coscienti. Preoccuparsi di questa possibilità *ora* sarebbe come se la de Havilland Aircraft Company, dopo aver realizzato il primo aereo di linea nel 1952, si fosse preoccupata delle implicazioni dei viaggi a velocità di curvatura verso lontane galassie. Forse un giorno dovremo farlo, ma al momento ci sono cose molto più importanti di cui occuparsi, per esempio, proseguendo l'analogia con l'aereo di linea, stabilire regole intelligenti per tutti gli aerei in volo *oggi*.

Il tema delle regole ci porta verso una nuova categoria di preoccupazioni riguardo all'IA, molto più plausibili e immediate. L'IA creerà un mondo senza lavoro? Le macchine prenderanno decisioni importanti sulla tua vita senza doverne rendere conto? Il futuro apparterrà alle persone che possederanno i robot più intelligenti?

Queste domande sono di vitale importanza e vengono affrontate continuamente, nelle conferenze di tecnologia, sulle pagine dei maggiori quotidiani mondiali e nei pranzi tra colleghi. Ti avvertiamo subito che non troverai le risposte a queste domande nel nostro libro, perché non le conosciamo. Come i nostri studenti, siamo fondamentalmente ottimisti riguardo al futuro dell'IA e speriamo che lo sarai anche tu una volta terminato il libro. Ma non siamo specialisti di economia del lavoro, esperti di politica o veggenti. Ci occupiamo di scienza dei dati ma siamo anche accademici e, come tali, tendiamo a restare nel nostro campo, in cui siamo sicuri delle nostre competenze. Possiamo parlarti dell'IA, ma non possiamo dirti con certezza cosa ci riserva il futuro.

Quello che *possiamo* dirti, tuttavia, è che ci siamo imbattuti in una serie di narrazioni utilizzate per inquadrare l'argomento e le troviamo tutte incomplete. Tali narrazioni evidenziano la ricchezza e il potere delle grandi aziende di tecnologia, ma ignorano l'incredibile democratizzazione e diffusione dell'IA che è già in atto. Sottolineano il pericolo che le macchine prendano decisioni importanti usando dati parziali, ma tralasciano di riconoscere la parzialità o la vera e propria malizia nei processi decisionali *umani* con cui conviviamo da sempre. Soprattutto, mettono l'accento su ciò che le macchine possono sottrarre, ma perdono di vista quello che noi otteniamo in cambio: opportunità di lavoro diverse e migliori, nuove comodità, libertà da lavori ingrati, luoghi di lavoro più sicuri, assistenza sanitaria di qualità più elevata, minori barriere linguistiche, nuovi strumenti

per studiare e per prendere decisioni che ci aiuteranno a essere persone migliori e più intelligenti.

Prendiamo, per esempio, il lavoro. In America, le richieste di disoccupazione hanno toccato i minimi storici tra il 2010 e il 2017, nel momento in cui l'IA e l'automazione hanno guadagnato terreno come forze economiche. L'automazione robotica è progredita a un ritmo ancora più implacabile in Cina, eppure i salari sono andati alle stelle per anni. Questo non significa che l'IA non abbia messo in pericolo il lavoro delle *singole persone*. Lo fa e continuerà a farlo, proprio come il telaio meccanico ha messo in pericolo il lavoro dei tessitori, e come le automobili hanno messo in pericolo il mercato delle fruste da cocchiere. Le nuove tecnologie cambiano sempre l'insieme dei lavori richiesti dall'economia, spingendo i salari in alto in qualche settore e in basso in altri settori. L'IA non fa eccezione e per questo noi sosteniamo con forza progetti di welfare sociale e di formazione professionale che diano un valido aiuto a coloro che hanno perso il lavoro a causa della tecnologia. La risposta potrebbe essere anche un reddito di base universale, come pensano molti dirigenti della Silicon Valley; non sappiamo dirlo con certezza. Ma l'argomento secondo cui l'IA creerà un futuro senza lavoro è, al momento, totalmente privo di prove concrete.

Poi c'è il problema del monopolio sul mercato. Amazon, Google, Facebook e Apple sono aziende enormi con un potere immenso. È *essenziale* vigilare su questo potere, affinché non sia usato per ostacolare la concorrenza o erodere le regole democratiche. Ma non devi dimenticare che queste aziende hanno successo perché hanno creato prodotti e servizi che piacciono. E continueranno ad avere successo solo se continueranno a innovare, compito non facile per le grandi organizzazioni. Inoltre, leggiamo molte predizioni che affermano che le grandi aziende tecnologiche di oggi resteranno in posizione di dominio per sempre: di solito, tali predizioni non spiegano neppure il passato, figurarsi il futuro. Ricordi quando Dell e Microsoft dominavano il mercato dei computer? O quando Nokia e Motorola avevano il monopolio dei cellulari ed era difficile immaginare le cose diversamente? Ricordi quando ogni avvocato possedeva un BlackBerry, ogni band musicale era su Myspace e ogni server era prodotto da Sun Microsystems? Ti ricordi di AOL, Blockbuster, Yahoo!, Kodak, o del Walkman Sony? Le aziende vanno e vengono, ma il tempo passa in fretta e i gadget diventano sempre più *cool*.

Noi condividiamo un punto di vista concreto sull'IA: è qui oggi e ce ne sarà sempre di più in futuro, che ci piaccia o no. Queste tecnologie porteranno

immensi benefici, ma allo stesso tempo evidenzieranno, inevitabilmente, i punti deboli della nostra civiltà. Di conseguenza, ci saranno pericoli da evitare per la privacy, per l'uguaglianza, per le istituzioni esistenti o per qualcosa che nessuno ha neppure ancora immaginato. Dobbiamo affrontare questi pericoli con politiche intelligenti e, se speriamo di mettere a punto politiche intelligenti, in un mondo di opinioni a raffica e di ragionamenti da 140 caratteri, è essenziale che la nostra società riesca a discutere di questi temi in maniera equilibrata, in modo da evidenziare sia la loro importanza che la loro complessità. Il nostro libro non si concentrerà su questa discussione, ma ti mostrerà ciò che devi capire se vuoi prendere parte attiva al dibattito.

Brevi considerazioni sulla matematica

Prima di iniziare, dobbiamo darti un ultimo avvertimento: troverai un po' di matematica in questo libro. Anche se la matematica non fa per te, non preoccuparti. Quella dell'IA è *sorprendentemente* semplice, e ti assicuriamo che è alla tua portata. Ti promettiamo anche che ne varrà la pena: se capisci un po' della matematica che c'è dietro, l'IA ti sembrerà molto meno misteriosa.

Avremmo potuto scrivere un libro sull'IA totalmente privo di matematica, in ossequio alla comune convinzione, che sentiamo ripetere da tutta la vita, che puoi scegliere la matematica o gli amici ma non entrambi. Il nostro editore ci ha inizialmente *supplicato* di scegliere questo approccio, bisbigliando qualcosa del tipo «si perdono tremila lettori per ogni simbolo matematico», o forse era «cinquemila lettori per ogni lettera greca». Comunque sia, abbiamo risposto «non se ne *παρλα*», poiché la nostra esperienza ci insegna che possiamo fidarci molto di te. Considerando l'esperienza di entrambi, abbiamo insegnato scienza dei dati e probabilità per quarant'anni, anche in parecchi master in Business administration (MBA) e a laureandi che arrivavano con questo orribile virus preinstallato che fa loro *odiare la matematica*. Eppure abbiamo visto gli occhi di quegli stessi studenti accendersi quando scoprono come funzionano tutte quelle applicazioni dell'IA di cui hanno sentito parlare, da Alexa al riconoscimento delle immagini, quando scoprono che, in fondo, si tratta semplicemente di probabilità caricate con potenti steroidi di dati. Capiscono che le equazioni dopotutto non sono così difficili. E, alla fine, si sentono persino *arricchiti*

dalla matematica: realizzano che, nelle giuste circostanze, pensare un po' più come una macchina – ovvero, prendere decisioni usando i dati e le regole della probabilità – può aiutarti a diventare più intelligente.

Seguici quindi per i prossimi sette capitoli, in cui ti presenteremo sette personaggi storici affascinanti, ognuno con una importante lezione da insegnarti sul perché macchine intelligenti hanno bisogno di persone intelligenti, e viceversa. Ne uscirai con un QIA (Quoziente intellettuale artificiale) più alto e una nuova consapevolezza di quanto possano essere brillanti gli esseri umani quando mettono insieme le loro menti e la loro tecnologia.

IL RIFUGIATO

Sulla personalizzazione: di come un emigrato ungherese usò la probabilità condizionata per proteggere gli aerei dal fuoco nemico nella seconda guerra mondiale, e di come le odierne aziende usino la stessa matematica per dare suggerimenti personalizzati per film, musica, notizie e perfino farmaci contro il cancro.

Netflix è arrivato così lontano, e così velocemente, che a stento ricordiamo che nacque come un'azienda di «*machine learning* (apprendimento automatico) via posta». Non più tardi del 2010, la sua attività principale consisteva nello spedire DVD all'interno di buste rosse che promettevano: «Nessuna penale per ritardo nella restituzione!». Ogni busta tornava indietro qualche giorno dopo, insieme alla valutazione del film da parte del cliente, su una scala da 1 a 5. Con l'accumularsi di quei dati, gli algoritmi di Netflix iniziarono a individuare schemi e col tempo i clienti ottennero suggerimenti migliori sui film. (Questo tipo di IA è solitamente chiamato "sistema di raccomandazione"; a noi piace anche l'espressione "motore di suggerimenti".)

Netflix 1.0 era talmente concentrata sul miglioramento del suo sistema di raccomandazioni che nel 2007, per la gioia incontenibile degli appassionati di matematica di tutto il mondo, organizzò una competizione pubblica di machine learning con un premio di un milione di dollari. L'azienda mise una parte dei suoi dati su un server pubblico e sfidò chiunque a migliorare il proprio sistema, chiamato Cinematch, di almeno il 10%: si trattava, dunque, di predire la valutazione di un film da parte di un utente con un'accuratezza migliore del 10% rispetto a quella raggiunta da Netflix. Il primo team a raggiungere la soglia del 10% avrebbe incassato il premio.

Nei mesi successivi, si registrarono migliaia di tentativi. Alcuni arrivarono incredibilmente vicino alla magica soglia del 10%, ma nessuno la oltrepassò. Tuttavia, nel 2009, dopo aver perfezionato il loro algoritmo per due anni, un

team chiamato BellKor's Pragmatic Chaos finalmente fornì il codice da un milione di dollari, in grado di battere il motore di Netflix del 10,06%. E fecero bene a non fermarsi a guardare un altro episodio di *The Big Bang Theory* prima di inviare la loro proposta. BellKor tagliò il traguardo della corsa biennale solo 19 minuti e 54 secondi prima di un secondo team, The Ensemble, che sottopose un algoritmo che forniva lo stesso miglioramento del 10,06%, ma in ritardo di un nulla.

A posteriori, il Netflix Prize era una testimonianza perfetta di quanto l'azienda facesse affidamento su un compito chiave del machine learning: predire, tramite un algoritmo, quanto un utente avrebbe gradito un film. Poi, nel marzo del 2011, tre parole cambiarono per sempre il futuro di Netflix: *House of Cards*.

House of Cards è stata la prima serie targata Netflix, il primo tentativo di produrre TV anziché distribuirla semplicemente. Il team di produzione di *House of Cards* era già andato da tutti i maggiori network televisivi, e ognuno di essi era interessato. Ma erano tutti diffidenti, e volevano prima vedere un episodio pilota. In fin dei conti, si trattava di una storia di bugie, tradimenti e assassini. Puoi quasi immaginarti i grandi network che si domandano: «Come possiamo essere sicuri che la gente voglia vedere qualcosa di così sinistro?». Be', Netflix lo era. Secondo i produttori, Netflix fu l'unico network ad avere il coraggio di dire: «Crediamo in voi. Abbiamo interrogato i nostri dati e ci dicono che il nostro pubblico guarderà questa serie. Non abbiamo bisogno di un episodio pilota. Quanti episodi volete fare?». ¹

Abbiamo interrogato i nostri dati e non abbiamo bisogno di un episodio pilota. Pensa alle implicazioni economiche di questa affermazione per l'industria televisiva. L'anno prima che *House of Cards* debuttasse, i maggiori network televisivi commissionarono 113 episodi pilota, per un costo totale di quasi 400 milioni di dollari. Di questi, solo trentacinque furono trasmessi, e solo tredici – una serie su nove – giunsero a una seconda stagione. In tutta evidenza, i network non avevano alcuna idea di cosa avrebbe avuto successo.

Dunque, nel marzo del 2011, che cosa sapeva Netflix che gli altri network non sapevano? Che cosa rendeva il team di Netflix così sicuro della propria valutazione da passare dal *consigliare* programmi TV su misura al *produrre* programmi TV su misura?

Una risposta immediata è che Netflix possedeva informazioni sui suoi utenti. Ma per quanto i dati fossero importanti, questa spiegazione era troppo

semplice. Anche i network avevano parecchi dati, sotto forma di indici d'ascolto Nielsen, gruppi di discussione, migliaia e migliaia di sondaggi e grandi budget per raccogliere ancora più dati, se lo avessero ritenuto importante.

Gli analisti dei dati di Netflix, tuttavia, avevano due cose che i network non avevano, almeno altrettanto importanti dei dati stessi: (1) una profonda conoscenza della probabilità, necessaria per porre le domande giuste interrogando i loro dati, e (2) il coraggio di ricostruire il loro business basandosi sulle risposte ottenute. Il risultato fu una trasformazione straordinaria per Netflix: da un network di distribuzione guidato dal machine learning a un nuovo tipo di casa di produzione, in cui analisti di dati e artisti si uniscono per fare della grande televisione. Come disse Ted Sarandos, direttore dei contenuti di Netflix, in un'intervista su "GQ": "L'obiettivo è diventare la HBO prima che la HBO diventi noi".²

Oggi poche organizzazioni usano l'IA per la personalizzazione meglio di Netflix, e il suo approccio pionieristico ora domina l'economia online. Le tracce che lasci lungo il tuo sentiero digitale producono consigli per musica su Spotify, video su YouTube, prodotti su Amazon, notizie sul "New York Times", amici su Facebook, pubblicità su Google e lavori su LinkedIn. Persino i medici possono usare lo stesso metodo per generare terapie oncologiche personalizzate, basate sul corredo genico individuale.

Un tempo, l'algoritmo più importante della tua vita digitale era il motore di ricerca, che per la maggior parte di noi significava Google. Ma gli algoritmi chiave del futuro riguardano i suggerimenti, non le ricerche. Una ricerca è limitata e circoscritta: devi sapere cosa cercare e sei limitato dalla tua stessa conoscenza ed esperienza. I suggerimenti, invece, possono essere ampi e senza limiti: attingono alla conoscenza accumulata e all'esperienza di miliardi di altre persone. I motori di suggerimenti sono come "software sosia" che un giorno potrebbero conoscere le tue preferenze meglio di te, almeno a livello conscio. Quanto tempo ci vorrà ancora, per esempio, prima che tu possa dire ad Alexa: «Mi sento in vena di avventure: prenotami una vacanza di una settimana», aspettandoti un risultato fantastico?

Naturalmente c'è un bel po' di matematica sofisticata dietro questi motori di suggerimenti. Ma, se hai la fobia della matematica, ci sono ottime notizie. In realtà c'è un unico concetto chiave da capire, ed è questo: per una macchina in grado di apprendere in modo automatico, "personalizzazione" significa "probabilità condizionata".

In matematica, una probabilità condizionata è la probabilità che qualcosa accada, sapendo che qualcos'altro è accaduto in precedenza. Un ottimo esempio sono le previsioni del tempo. Se guardi fuori dalla finestra al mattino e vedi nuvole all'orizzonte, penserai che probabilmente pioverà e che ti conviene portare un ombrello al lavoro. Nell'IA, esprimiamo questa valutazione in termini di probabilità condizionata. Per esempio, «la probabilità condizionata che ci sia pioggia questo pomeriggio, dato che ci sono nuvole al mattino, è del 60%». Gli analisti dei dati lo scrivono in modo più compatto: $P(\text{pioggia nel pomeriggio} \mid \text{nuvole al mattino}) = 60\%$. P sta per “probabilità” e la barra verticale significa “dato che” o “a condizione che”. A sinistra della barra c'è l'evento a cui siamo interessati. A destra della barra c'è l'informazione di cui disponiamo, anche detto “evento condizionante”: ciò che crediamo o poniamo essere vero.

La probabilità condizionata è il modo in cui i sistemi di IA esprimono valutazioni che riflettono le informazioni parziali a loro disposizione.

Hai appena dato a *Sherlock* una valutazione alta. Qual è la probabilità condizionata che ti piacerà *The Imitation Game* o *La talpa*?

Ieri hai ascoltato Pharrell Williams su Spotify. Qual è la probabilità condizionata che vorrai ascoltare Bruno Mars oggi?

Hai appena comprato cibo per cani biologico. Qual è la probabilità condizionata che comprerai anche un collare per cani munito di GPS?

Segui Cristiano Ronaldo (@cristiano) su Instagram. Qual è la probabilità condizionata che reagirai positivamente al suggerimento di seguire Lionel Messi (@leomessi) o Gareth Bale (@garethbale11)?

La personalizzazione si basa sulle probabilità condizionate da stimare attraverso enormi insiemi di dati in cui l'evento condizionante *sei tu*. In questo capitolo, imparerai un po' della magia che c'è dietro tutto questo.

Abraham Wald, eroe della seconda guerra mondiale

L'idea di fondo alla base della personalizzazione è molto più vecchia di Netflix, più vecchia anche della televisione. In effetti, se vuoi capire la rivoluzione dell'ultimo decennio avvenuta nel modo in cui le persone interagiscono con la cultura di massa, il posto migliore per iniziare non è la Silicon Valley o il salotto di un trentenne di Brooklyn o Shoreditch che

abbandona la TV via cavo. È, invece, nei cieli dell'Europa occupata del 1944, dove la padronanza della probabilità condizionata da parte di un uomo salvò la vita a un numero enorme di piloti di bombardieri nella più grande campagna aerea della storia: il bombardamento del Terzo Reich.

Durante la seconda guerra mondiale, i numeri della guerra aerea nei cieli europei erano impressionanti. Ogni mattina, enormi squadriglie di Lancaster inglesi e B-17 americani decollavano dalle basi britanniche e raggiungevano i loro bersagli al di là della Manica. Nel 1944 le forze aeree alleate sganciarono più di dieci milioni di chili di bombe *ogni settimana*. Ma, all'intensificarsi della campagna aerea, crescevano anche le perdite. In una singola missione nell'agosto del 1943, gli Alleati impiegarono 376 aeroplani provenienti da sedici diverse basi aeree per bombardamenti congiunti su fabbriche nei pressi di Schweinfurt e Regensburg in Germania. Sessanta aerei non fecero ritorno, una perdita giornaliera del 16%. La 381a flotta, proveniente dalla Royal Air Force di Ridgewell, perse nove dei suoi venti bombardieri quel giorno.³

I piloti della seconda guerra mondiale erano dolorosamente consapevoli del fatto che ogni missione era un lancio di dadi. Ma di fronte a queste probabilità sconfortanti, avevano almeno tre difese:

1. I loro mitraglieri di coda e di torretta per respingere gli attacchi.
2. Le loro pattuglie di scorta: gli Spitfire e i Mustang P-51 mandati a difendere i bombardieri impegnati nell'attacco alla Luftwaffe.
3. Uno statistico ungherese-americano di nome Abraham Wald.

Abraham Wald non ha mai abbattuto un Messerschmitt e non ha nemmeno mai visto l'interno di un aereo da combattimento. Ciononostante, ha dato un contributo enorme allo sforzo militare alleato usando un'arma ugualmente potente: la probabilità condizionata. Nello specifico, Wald costruì un "suggeritore" in grado di dare "consigli di sopravvivenza personalizzati" a differenti tipi di aeroplani. Nei suoi punti essenziali era simile a un moderno sistema di suggerimenti per programmi televisivi basato sull'IA. E se capisci come Wald lo ha costruito, capirai anche molto di Netflix, Hulu, Spotify, Instagram, Amazon, YouTube e di ogni altra azienda tecnologica che ti abbia consigliato qualcosa di utile.

I primi anni di Wald

Abraham Wald nacque nel 1902 da una grande famiglia ebrea ortodossa a Kolozsvár, in Ungheria, che dopo la seconda guerra mondiale passò alla Romania e cambiò nome in Cluj. Suo padre, che lavorava in una panetteria in città, creò un'atmosfera di cultura e curiosità intellettuale in casa per i suoi sei bambini. Il giovane Wald e i suoi fratelli crescevano suonando il violino, risolvendo problemi di matematica e ascoltando storie raccolti intorno al nonno, un famoso e amato rabbino. Wald frequentò l'università locale, laureandosi nel 1926. Proseguì gli studi all'Università di Vienna, dove studiò matematica con un accademico famoso di nome Karl Menger.⁴

Nel 1931, terminato il suo dottorato, Wald mostrava un talento raro. Menger, che ne fu relatore, definì la tesi di dottorato del suo allievo «un capolavoro di matematica pura», descrivendola come «profonda, bella e di fondamentale importanza». Ma nessuna università in Austria avrebbe assunto un ebreo, a prescindere dal talento e da quanto fosse sponsorizzato dal suo famoso relatore. Così Wald cercò altre opportunità. Disse a Menger che sarebbe stato felice di fare qualsiasi lavoro che gli permettesse di arrivare a fine mese: tutto ciò che voleva fare era continuare a dimostrare teoremi e frequentare seminari di matematica.

All'inizio Wald lavorò come insegnante privato di matematica per un facoltoso banchiere austriaco, Karl Schlesinger, a cui restò sempre riconoscente. Poi nel 1933 fu assunto come ricercatore all'Austrian Institute for Business Cycle Research, dove un altro accademico famoso fu impressionato da lui: l'economista Oskar Morgenstern, il coinventore della teoria dei giochi. Wald lavorò fianco a fianco con Morgenstern per cinque anni, analizzando le variazioni stagionali dei dati economici. Fu in quell'istituto che Wald si imbatté nella statistica, la specialità che avrebbe determinato la sua vita professionale.

Ma nuvole nere si addensavano sull'Austria. Come disse Menger «la cultura viennese somigliava a un'aiuola di fiori delicati, lasciata senza luce e senza terreno dal suo proprietario, mentre un vicino spietato aspettava solo un'occasione per distruggere l'intero giardino». La primavera del 1938 portò il disastro: l'Anschluss (l'annessione dell'Austria alla Germania nazista). L'11 marzo, il capo di stato austriaco eletto, Kurt Schuschnigg, fu deposto da Hitler e sostituito da un fantoccio nazista. Nel giro di poche ore, 100 000 truppe della Wehrmacht attraversarono il confine senza incontrare opposizione. Il 15 marzo sfilarono trionfalmente per le vie di Vienna. Come

segno di cattivo presagio, Karl Schlesinger, il benefattore di Wald negli anni difficili 1931-1932, si suicidò proprio in quel giorno.

Fortunatamente per Wald, il suo lavoro sulla statistica economica aveva ricevuto attenzioni all'estero. L'estate precedente, nel 1937, era stato invitato in America da un istituto di ricerca economica a Colorado Springs. Sebbene fosse lusingato dal riconoscimento, Wald aveva esitato a lasciare Vienna. Ma l'Anschluss gli fece cambiare idea, dopo aver visto gli ebrei austriaci cadere vittima di una terribile serie di omicidi, rapine e tradimenti. I loro negozi venivano saccheggiati, le loro case devastate, la loro partecipazione alla vita pubblica cancellata dalle leggi di Norimberga, incluso il ruolo che Wald ricopriva all'Institute for Business Cycle Research. Wald disse addio con tristezza a Vienna, la sua seconda casa, ma vedeva chiaramente i venti di follia soffiare ogni giorno più forti.

Dunque, nell'estate del 1938, correndo un gran rischio, attraversò clandestinamente il confine con la Romania e partì per l'America, schivando le guardie di confine che andavano a caccia di ebrei che volevano lasciare il paese. La decisione di partire gli salvò con ogni probabilità la vita. In Europa restarono i genitori di Wald, i nonni e i suoi cinque fratelli e sorelle: tutti tranne uno, suo fratello Hermann, furono assassinati nell'Olocausto. In quel periodo Wald viveva in America. Era al sicuro e lavorava molto, era sposato e aveva due bambini, e trovava conforto nelle gioie della sua nuova vita. Ma restò per sempre profondamente segnato dal destino della sua famiglia e non suonò mai più il violino.

Wald in America

Wald, tuttavia, si diede molto da fare affinché Hitler ascoltasse ugualmente la sua musica.

Il trentacinquenne Wald arrivò in America nell'estate del 1938. Sebbene gli mancasse Vienna, la sua nuova casa gli piacque subito. Colorado Springs gli ricordava le colline della sua gioventù, ai piedi dei Carpazi, e i suoi nuovi colleghi lo accolsero con calore e affetto. Ma non restò in Colorado a lungo. Oskar Morgenstern, anch'egli fuggito in America e ora a Princeton, parlava a tutti i suoi colleghi della East Coast di questo suo collega Wald, che descriveva come «un uomo gentile» con «doti eccezionali e grande spessore matematico». La reputazione di Wald continuò a crescere, e presto destò

l'attenzione di un eminente professore di statistica di New York, Harold Hotelling. Nell'autunno del 1938 Wald accettò un'offerta per unirsi al gruppo di Hotelling alla Columbia University. Iniziò con un contratto di ricerca, ma si fece notare così rapidamente, sia come insegnante sia come ricercatore, che gli venne subito offerta una posizione permanente nel corpo insegnante.

Alla fine del 1941 Wald era a New York da tre anni, e la posta in gioco al di là dell'oceano era ovvia a tutti tranne che a chi non voleva vedere. Per due anni la Gran Bretagna aveva combattuto i nazisti da sola «per salvare non solo l'Europa, ma l'umanità», come diceva Churchill. E in quei due lunghi anni l'America era rimasta a guardare. Ci volle il bombardamento di Pearl Harbor per scuotere il popolo americano dal suo torpore, ma finalmente il risveglio avvenne. Giovani uomini corsero ad arruolarsi. Le donne entrarono nelle fabbriche e si unirono alle unità infermieristiche. Gli scienziati, specialmente i tanti emigrati che erano fuggiti dal terrore nazista, si precipitarono nei loro laboratori e alle loro lavagne: Albert Einstein, John von Neumann, Edward Teller, Stanisław Ulam e centinaia di altri brillanti rifugiati che durante la guerra diedero alla scienza americana un impulso decisivo.

Anche Wald era ansioso di rispondere alla chiamata. L'opportunità arrivò subito, quando il suo collega W. Allen Wallis lo invitò a unirsi al Gruppo di ricerca statistica della Columbia University. Il GRS era stato fondato nel 1942 da quattro statistici che si incontravano periodicamente in una stanzetta del Rockefeller Center, nel centro di Manhattan, per fornire consulenza statistica all'esercito. Da accademici, inizialmente non erano abituati a lavorare sotto pressione. A volte questo generava episodi che rivelavano una consapevolezza ridicolmente scarsa delle esigenze in tempo di guerra: agli inizi del GRS, un matematico si lamentò con tono risentito del fatto che una segretaria lo costringesse a risparmiare carta scrivendo le sue equazioni su entrambe le facciate del foglio.

Ma le cose cambiarono in fretta. Nel 1944, il GRS era diventato un team di sedici statistici e trenta giovani donne provenienti dal Vassar College e dall'Hunter College che presero in carico il lavoro computazionale. Il gruppo divenne una fonte indispensabile di consigli tecnici per l'Ufficio ricerca e sviluppo dell'esercito, e la sua assistenza venne richiesta dai più alti livelli di comando, ottenendo notevoli risultati. Gli statistici della Columbia non svilupparono nulla di altrettanto spaventoso o famoso come i team al lavoro negli stessi anni a Los Alamos o Bletchley Park. Ma il loro compito era più ampio e l'effetto che ebbero sulla guerra fu molto profondo. Studiarono

propellenti per missili, siluri e spolette di prossimità, geometria dei combattimenti aerei, vulnerabilità dei mercantili e qualsiasi cosa coinvolgesse la matematica e contribuisse allo sforzo militare. Come in seguito ricordò Wallis, il direttore del gruppo:

Durante la battaglia delle Ardenne, nel dicembre del 1944, molti ufficiali di alto rango delle forze armate volavano a Washington lasciando la battaglia, trascorrevano la giornata discutendo del posizionamento ottimale delle spolette di prossimità per l'esplosione in aria dei proiettili di artiglieria lanciati contro le truppe terrestri, e tornavano in battaglia. [...] Questo genere di responsabilità, anche se spesso taciuto, era sempre nell'aria ed esercitava una pressione potente, pervasiva e persistente.⁵

Fortunatamente si trattava di un team composto da alcune delle migliori menti matematiche del paese, molte delle quali avrebbero continuato a primeggiare nel proprio campo di ricerca. Due membri diventarono rettori di università. Quattro membri furono nominati presidenti dell'American Statistical Association. Mina Rees divenne la prima presidente donna della American Association for the Advancement of Science. Milton Friedman e George Stigler ricevettero il premio Nobel per l'economia.

In questo gruppo stellare, Abraham Wald era come il cestista NBA LeBron James: l'uomo che poteva fare tutto. Solo i problemi più difficili arrivavano sulla sua scrivania, perché anche i suoi geniali colleghi riconoscevano che, come diceva il direttore del gruppo, «il tempo di Wald è troppo prezioso per essere sprecato».

Wald e gli aerei mancanti

Il contributo più famoso di Wald al lavoro del gruppo fu un articolo che inventò una nuova branca dell'analisi dei dati, nota come campionamento sequenziale. Le sue intuizioni matematiche mostrarono alle fabbriche come produrre meno carri armati e aerei difettosi, semplicemente implementando protocolli di ispezione più accurati. Quando l'articolo fu desecretato dall'esercito, rese Wald una celebrità accademica e cambiò il corso della statistica del XX secolo, poiché i ricercatori di tutto il mondo iniziarono ad applicare le idee di Wald in nuove aree, in particolar modo nei trial clinici, dove sono usate tuttora.

Ma ciò che ci interessa, ovvero la crescita esponenziale della personalizzazione in stile Netflix, è collegato a un diverso, e quasi universalmente incompreso, lavoro di Abraham Wald: il suo metodo per generare consigli di sopravvivenza personalizzati per aeroplani.

Ogni giorno le forze aeree alleate inviavano grandi squadriglie ad attaccare i bersagli nazisti e molti aerei tornavano danneggiati dal fuoco nemico. A un certo punto, qualcuno nell'aeronautica ebbe la buona idea di analizzare la distribuzione dei colpi sugli aerei di ritorno. L'idea era semplice: se riesci a trovare uno schema ricorrente nelle zone dell'aereo colpite, puoi suggerire dove rinforzare la carlinga con più armatura. Questi suggerimenti, inoltre, potevano essere personalizzati per ogni aereo, dato che i rischi che correva un agile caccia P-51 erano molto diversi da quelli di un bombardiere B-17.

La strategia un po' naïf sarebbe stata mettere più armatura ovunque ci fossero buchi di proiettili sugli aeroplani di rientro. Ma non era una buona idea, poiché l'aviazione non possedeva i dati degli aeroplani abbattuti. Per capire l'importanza di ciò, considera un esempio estremo. Supponi che un bombardiere possa essere abbattuto da un singolo colpo al motore, ma che sia invulnerabile ai colpi sulla fusoliera. Se fosse vero, gli analisti dei dati dell'aviazione vedrebbero tornare centinaia di bombardieri con innocui fori sulla fusoliera ma neppure un singolo aereo con buchi intorno al motore, poiché ogni aereo colpito in quel modo sarebbe caduto. In questo scenario, se aggiungessi semplicemente armatura in corrispondenza dei buchi sulla fusoliera, in realtà *penalizzeresti* i bombardieri, caricandoli di un peso che li “protegge” da un pericolo inesistente.

Questo esempio illustra un caso estremo di “distorsione di sopravvivenza”. Nonostante il mondo reale sia molto meno estremo – i proiettili diretti al motore non sono al 100% letali e i proiettili diretti alla fusoliera non sono al 100% innocui – la considerazione statistica rimane: lo schema di danneggiamento sugli aerei rientrati alla base doveva essere analizzato con attenzione.

Arrivati a questo punto, dobbiamo fermarci per evidenziare due fatti importanti. Primo, il web va pazzo per questa storia. Secondo, quasi tutti coloro che l'hanno raccontata – con la notevole eccezione di un articolo sconosciuto e altamente tecnico pubblicato nel “Journal of the American Statistical Association” nel 1984 – l'hanno fraintesa.⁶

Prova a cercare tu stesso su Google “Abraham Wald” e “seconda guerra mondiale” e guarda il risultato: una successione di articoli di blog su come un

paladino della statistica di nome Wald impedì a quei testoni dell'aviazione di compiere un'incredibile idiozia, sbattendo un mucchio di armatura inutile sulle fusoliere degli aerei. Abbiamo letto decine di storie del genere, e ti risparmiamo lo stesso compito desolante, creando il seguente racconto di fantasia.

Durante la seconda guerra mondiale, l'aviazione trovò un evidente schema ricorrente nei danneggiamenti agli aerei di ritorno dai bombardamenti in Germania, in cui la maggior parte dei fori di artiglieria erano sulla fusoliera. Gli uomini dell'aviazione giunsero all'ovvia conclusione: mettere più armatura sulla fusoliera. Tuttavia, per essere sicuri, diedero i loro dati ad Abraham Wald. I neuroni di Wald si misero all'opera. E, all'improvviso, un fulmine. «Aspettate!», esclama Wald. «È sbagliato. Non vediamo danni ai motori perché gli aerei colpiti al motore non tornano. Dovete aggiungere armatura al motore, non alla fusoliera.» Wald aveva scovato l'errore cruciale nel ragionamento dell'aviazione: la distorsione di sopravvivenza. Il suo suggerimento salvavita era esattamente l'opposto rispetto a quello dei cosiddetti esperti: *mettere l'armatura dove non ci sono buchi di proiettile.*

Capiamo perché questa versione della storia è così irresistibile: la controintuizione produce un'inversione a 360 gradi. Immagina di chiedere a una persona qualsiasi in strada: «Dove dovremmo mettere armatura aggiuntiva sugli aerei per aiutarli a sopravvivere al fuoco nemico?». Anche se non abbiamo fatto un sondaggio di questo tipo, sospettiamo che «il motore» sarebbe la risposta più gettonata. Ma un'interpretazione ingenua dei dati sembrava inizialmente suggerire il contrario: se gli aerei di ritorno erano danneggiati sulla fusoliera, allora, per l'amor del cielo, mettiamo un rinforzo lì. Solo un genio come Wald, prosegue il racconto, poteva vedere il nocciolo della questione, riportandoci alla nostra iniziale risposta intuitiva.

E invece, dalle informazioni storiche che abbiamo, questo resoconto ha molto poco fondamento. Ancora peggio, questa versione abbellita, in cui il succo della storia è la distorsione di sopravvivenza, tralascia ciò che è davvero importante del contributo di Abraham Wald allo sforzo militare alleato. La distorsione di sopravvivenza nell'analisi dei dati era ovviamente il problema, e tutti lo sapevano. Altrimenti non ci sarebbe stato bisogno di chiamare il GRS: l'aviazione non aveva bisogno di un gruppo di professori di matematica per contare i buchi di proiettile. La loro domanda era più specifica: come si poteva stimare la probabilità condizionata che un aereo sopravvivesse a un colpo nemico in un determinato punto, nonostante

mancassero molti dati rilevanti. I militari non sapevano rispondere a questa domanda. Erano intelligenti, ma non è un insulto dire che non erano intelligenti come Abraham Wald.

Il vero contributo di Wald fu molto più sottile e interessante dello spiattellare la distorsione di sopravvivenza in faccia alla caricatura idiota di un comandante dell'aviazione. Il suo colpo di genio non fu identificare il problema, ma inventare una soluzione: un «sistema di suggerimenti per la sopravvivenza», ovvero un metodo che fornisse al comando militare suggerimenti personalizzati su come migliorare le probabilità di sopravvivenza di *qualsiasi* modello di aereo, usando i dati di danneggiamento in battaglia. L'algoritmo di Wald era, per dirla con le parole del direttore del GRS, «un lavoro geniale di una delle figure di maggior rilievo nella storia della statistica americana». Anche se l'algoritmo di Wald non fu pubblicato prima degli anni ottanta, venne utilizzato durante la seconda guerra mondiale e anche per molti anni in seguito.⁷ Nel corso della guerra del Vietnam, l'aviazione usò l'algoritmo di Wald per gli Skyhawk A-4; anni più tardi, venne utilizzato per migliorare l'armatura sul B-52 Stratofortress, l'aereo militare più a lungo utilizzato nella storia degli Stati Uniti.

Dati mancanti:

quello che non conosci può trarti in inganno

Ora sei in grado di capire che il problema di Abraham Wald su come incrementare la sopravvivenza degli aerei è molto simile al problema di Netflix di generare consigli personalizzati sui film. Ma c'è un tranello, ed è anche molto grande.

Aeronautica militare statunitense nel 1943: «Vogliamo stimare la probabilità condizionata che un aereo cada, sapendo che è stato colpito in un determinato punto dal fuoco nemico, alla luce dei dati di danneggiamento provenienti da tutti gli altri aerei. Questo ci consentirà di personalizzare i suggerimenti per la sopravvivenza per ogni modello di aereo. Tuttavia mancano molti dati: gli aerei abbattuti non fanno ritorno».

Netflix settanta anni dopo: «Vogliamo stimare la probabilità condizionata che a un utente piaccia un film, dato il suo storico di visualizzazioni, alla luce delle valutazioni da parte di tutti gli altri utenti. Questo ci consentirà di

personalizzare i suggerimenti sui film per ogni utente. Tuttavia mancano molti dati: la maggior parte degli utenti non ha visto la maggior parte dei film».

Il tranello sta nel fatto che sia Abraham Wald sia Netflix dovevano stimare una probabilità condizionata, ma entrambi avevano il problema della mancanza di dati. E, a volte, ciò che non sappiamo può contenere molte informazioni.

Considera, per esempio, ciò che accadde quando uno degli autori di questo libro (Polson, l'inglese) fece visita per la prima volta all'altro (Scott, il texano), a Austin. Camminando verso la caffetteria, notammo un grande furgone bianco parcheggiato in strada su cui era scritto:

ARMADILLO

PET CARE (cura degli animali domestici)

Immagina lo stupore di Polson all'idea di un fiorente business locale dedicato ai bisogni di queste creature così poco inglesi. Come poteva un armadillo essere considerato un animale domestico? Era in grado di imparare il proprio nome? E a cosa serviva quel furgone così grande?

Ma a un tratto un fattorino spostò un carrello pieno di pacchi impilati di fianco al furgone, e la banale verità fu svelata:

ARMADILLO

CARPET CARE (cura dei tappeti)

A volte, i dati mancanti cambiano completamente le cose.

Era più o meno la stessa situazione in cui si trovava Abraham Wald con i dati sulla sopravvivenza degli aerei. Anche se i veri numeri sono andati perduti, possiamo utilizzare i rapporti pubblicati dall'aeronautica per ipotizzare cosa egli possa aver visto. Immaginiamo di seguire le orme di Wald mentre esamina i dati sul bombardamento di Schweinfurt e Regensburg nell'agosto del 1943, in cui gli alleati persero sessanta dei loro 376 aerei in un solo giorno. I crudi resoconti dal campo di battaglia dovevano somigliare a qualcosa del genere, dove un punto interrogativo significa "dato mancante":

Aereo	Posizione del danneggiamento	Esito della missione
1) <i>Agnese l'Arpia</i>	Fusoliera	Rientrato
2) <i>Bombardiere del Bronx</i>	?	Abbattuto
3) <i>Papà Pistolero</i>	Motore	Rientrato
...
375) <i>Angelo Nostalgico</i>	?	Abbattuto
376) <i>Calamity Jane</i>	Nessun danno	Rientrato

Da questi resoconti, Wald avrebbe potuto incrociare i dati sugli aerei in base alla posizione del danneggiamento e all'esito della missione.^{*a} Questo avrebbe prodotto la seguente tabella:

Posizione del danneggiamento	Rientrati (316 totali)	Abbattuti (60 totali)
Motore	29	?
Abitacolo	36	?
Fusoliera	105	?
Nessun danno	146	0

Dei 316 aerei rientrati alla base, 105 avevano danni alla fusoliera. Questo avrebbe permesso a Wald di stimare la probabilità condizionata che un aereo riportasse danni alla fusoliera, sapendo che era rientrato alla base:

$$P(\text{danno alla fusoliera} \mid \text{rientro alla base}) = 105/316 \approx 32\%.$$

Ma questa è la risposta giusta alla domanda sbagliata. Vogliamo in realtà sapere l'esatto contrario: la probabilità condizionata che un aereo faccia ritorno, sapendo che ha subito un danno alla fusoliera. Potrebbe venir fuori un numero molto diverso.

Questo ci conduce a una proprietà molto importante sulle probabilità condizionate: non sono simmetriche. Il fatto che Wald conoscesse $P(\text{danno alla fusoliera} \mid \text{rientro alla base})$ non implicava necessariamente che egli conoscesse $P(\text{rientro alla base} \mid \text{danno alla fusoliera})$. Per spiegare il motivo, consideriamo un semplice esempio:

- Tutti i giocatori NBA giocano a basket: questo significa che la probabilità $P(\text{gioca a basket} \mid \text{gioca in NBA})$ è quasi del 100%.
- Una frazione infinitesima di coloro che giocano a basket arriva in NBA: questo significa che $P(\text{gioca in NBA} \mid \text{gioca a basket})$ è quasi lo 0%.

Dunque $P(\text{gioca a basket} \mid \text{gioca in NBA})$ non è uguale a $P(\text{gioca in NBA} \mid \text{gioca a basket})$. Quando si ha a che fare con le probabilità, è molto importante essere chiari su quale evento si trovi a sinistra della barra verticale e quale evento si trovi a destra.

Wald lo sapeva. Sapeva che, per calcolare una probabilità come $P(\text{rientro alla base} \mid \text{danno alla fusoliera})$, doveva stimare quanti aerei erano stati danneggiati alla fusoliera *e non avevano fatto ritorno*. Il suo compito era inserire numeri al posto dei punti interrogativi nella tabella precedente, ovvero, sopperire ai dati mancanti ricostruendo la firma statistica degli aerei abbattuti. Gli analisti dei dati chiamano questo processo “imputazione”. Di solito, è molto meglio di “amputazione”, che significa semplicemente tagliare via i dati mancanti.

I tentativi di imputazione di Wald facevano tutti capo alle sue ipotesi di modellizzazione. Doveva ricreare lo scontro tipico di un B-17 con il nemico, usando solo la muta testimonianza dei fori di proiettile sugli aerei rientrati e un modello ipotetico di battaglia aerea. Per essere certo che la sua modellizzazione fosse realistica, Wald iniziò a lavorare come un analista forense. Considerò l’angolo di attacco probabile dei combattenti nemici. Parlò con gli ingegneri. Studiò le proprietà delle nuvole di schegge generate dalle granate shrapnel che, sparate dalla contraerea, esplodono a mezz’aria. Propose persino all’esercito di mitragliare un aereo con migliaia di finti proiettili in modo da poterne tabulare i colpi ricevuti.

Alla fine di questo processo, Wald aveva inventato un metodo per ricostruire l’intera tabella. Basandosi sul suo modello di battaglia aerea, le sue stime dovevano essere più o meno queste:

Posizione del danneggiamento	Rientrati (316 totali)	Abbattuti (60 totali)
Motore	29	31
Abitacolo	36	21
Fusoliera	105	8
Nessun danno	146	0

Da un insieme di dati come questo, è semplice stimare le probabilità condizionate di cui Wald aveva bisogno. Per esempio, dei 113 aerei con danni alla fusoliera, 105 aerei hanno fatto rientro e un numero stimato di otto aerei è stato abbattuto. Dunque la probabilità condizionata di tornare alla base, avendo subito un danno alla fusoliera, è:

$$P(\text{rientro alla base} \mid \text{danno alla fusoliera}) = \frac{105}{105+8} \approx 93\%$$

Secondo questa stima, un B-17 aveva ottime probabilità di sopravvivere a un colpo ricevuto sulla fusoliera.

D'altra parte, dei sessanta aerei danneggiati al motore, solo ventinove erano rientrati. Quindi:

$$P(\text{rientro alla base} \mid \text{danno al motore}) = \frac{29}{29+31} \approx 48\%$$

Era molto più probabile che un bombardiere colpito al motore venisse abbattuto.

Questi erano finalmente numeri che l'aviazione poteva utilizzare. Ma più che i numeri stessi per uno specifico aereo, poteva usare il metodo di Wald per personalizzare i suggerimenti di sopravvivenza per *qualsiasi* aereo. L'associazione della probabilità condizionata e di un'attenta modellizzazione dei dati mancanti si dimostrò essere una combinazione salvavita.

Bombardieri mancanti, valutazioni mancanti

Settanta anni dopo, gli stessi concetti avrebbero giocato un ruolo fondamentale nel modo in cui Netflix reinventò se stessa.

Tutto iniziò dal sistema di suggerimenti di Netflix 1.0, che ora spiegheremo a grandi linee. Immagina di avere l'ingrato compito di dover concepire tu stesso un tale sistema. In ingresso, il sistema accetta lo storico delle visualizzazioni dell'utente, mentre in uscita deve fornire una predizione sul fatto che allo stesso utente piacerà un determinato programma. Decidi di iniziare con un caso facile, ispirandoti a Wald: stabilire la probabilità che a un utente piaccia *Salvate il soldato Ryan*, sapendo che gli è piaciuta la serie HBO *Band of Brothers*. Sembra abbastanza facile: sono entrambi drammi di argomento storico, basati sullo sbarco in Normandia e sulle sue conseguenze.

Per questa particolare coppia di programmi, non hai dubbi: consigli la visione. Ricorda, tuttavia, che vuoi essere capace di farlo in modo automatico. Non sarebbe certamente economico assumere un enorme team di annotatori di preferenze per etichettare tutte le possibili coppie di film simili e fornire suggerimenti. Però hai a disposizione l'intero database di Netflix con le informazioni su quali film piacciono a quali utenti. Il tuo obiettivo è sfruttare questa enorme massa di dati per automatizzare il sistema di suggerimenti.

L'idea chiave è descrivere il problema in termini di probabilità condizionata. Supponi che, per una certa coppia di film, A e B, la probabilità $P(\text{utente a cui piace il film A} \mid \text{stesso utente a cui piace il film B})$ sia alta, diciamo l'80%. Vieni a sapere, dal suo storico di visualizzazioni, che a Linda è piaciuto il film B ma non ha ancora visto il film A. Non sarebbe una buona idea consigliarle il film A? Basandoti sul fatto che le è piaciuto il film B, c'è una probabilità dell'80% che le piacerà anche A.

Ma come facciamo a ottenere $P(\text{utente a cui piace } \textit{Salvate il soldato Ryan} \mid \text{utente a cui piace } \textit{Band of Brothers})$? Qui entra in gioco il tuo database. Per farla semplice, supponiamo che ci siano 100 persone nel database, e che tutte abbiano visto entrambi i film. I loro storici di visualizzazione compongono un'enorme "matrice di valutazione", in cui le righe corrispondono agli utenti e le colonne ai film:

Utente	Piace <i>Salvate il soldato Ryan</i> ?	Piace <i>Band of Brothers</i> ?
1. Aaron	Sì	Sì
2. Alice	Sì	Sì
...
99. Wendy	No	No
100. Zack	Sì	No

Ora puoi incrociare i dati della tabella contando quanti utenti avevano una determinata combinazione di preferenze per questi due film:

	Piace <i>Band of Brothers</i>	Non piace <i>Band of Brothers</i>
Piace <i>Salvate il soldato Ryan</i>	56 utenti	6 utenti
Non piace <i>Salvate il soldato Ryan</i>	14 utenti	24 utenti

Da questa tabella possiamo facilmente ricavare la probabilità condizionata che serve al tuo sistema di suggerimenti:

- A 70 utenti piace *Band of Brothers* (56 + 14).
- Tra questi 70 utenti, a 56 piace anche *Salvate il soldato Ryan*, mentre a 14 no.

Questo ti permette di calcolare la probabilità condizionata che a qualcuno piaccia *Salvate il soldato Ryan*, sapendo che gli è piaciuto *Band of Brothers*:

$$P(\text{piace } \textit{Salvate il soldato Ryan} \mid \text{piace } \textit{Band of Brothers}) = \frac{56}{56+14} = 80\%$$

La cosa essenziale che permette a questo metodo di lavoro di funzionare così bene è il suo automatismo. I computer non sono (ancora) molto efficienti nell'effettuare una scansione dei film per contenuto tematico. Ma sono abilissimi nel contare, ovvero nell'incrociare i dati di enormi database pieni di informazioni sulle visualizzazioni e sulle valutazioni dei singoli utenti per stimare le probabilità condizionate.

Il problema che Netflix si trova davanti è molto più complesso di questo semplice esempio, per almeno tre motivi. Il primo motivo sono le dimensioni. Netflix non ha 100 utenti, ne ha 100 milioni, e non ha dati di valutazione su due programmi ma su più di 10 000. Di conseguenza, la matrice di valutazione contiene più di 1000 miliardi di possibili elementi.

Il secondo motivo è la mancanza di dati. Gran parte degli utenti non ha visto gran parte dei film, e quindi moltissimi di quei miliardi di elementi sono ignoti. In più, come nel caso dei bombardieri durante la seconda guerra mondiale, quello che manca contiene molte informazioni. Se non hai visto *Fight Club*, può essere o perché non ti ci sei ancora imbattuto o perché i film sul nichilismo non fanno per te.

L'ultimo motivo è l'esplosione combinatoria. O, per restare in tema *Fight Club* e filosofia: ogni utente Netflix è un magnifico e unico fiocco di neve. In

un database con soli due film, milioni di utenti condivideranno le stesse valutazioni, dal momento che solo quattro di esse sono possibili: entrambi graditi, entrambi sgraditi, gradito uno e sgradito l'altro. Non è così per un database di 10 000 film. Pensa al tuo storico di visualizzazioni. Sarà diverso da qualsiasi altro storico esistente e da qualsiasi altro storico futuro, perché ci sono tantissimi modi in cui due storici possono differire. Anche in un database con soli 300 film, il numero di possibili combinazioni di valutazione (2^{300}) sarebbe più grande del numero di atomi nell'universo (circa 2^{272}). Smetteresti di contare molto prima di arrivare a $2^{10\,000}$: le differenti esperienze di gradimento sono, a tutti gli effetti pratici, infinite.

Questo fa sorgere una domanda importante: come può Netflix dare un suggerimento sulla base del tuo storico di visualizzazioni, usando storici di altre persone, dal momento che il tuo storico è unico e irripetibile?

La soluzione a tutti e tre i problemi è un'attenta modellizzazione. Proprio come Wald risolse il problema della mancanza di dati costruendo un modello di incontro ravvicinato tra un B-17 e il nemico, Netflix ha risolto il problema costruendo un modello di "incontro ravvicinato" tra un utente e un film. E, mentre l'attuale modello di Netflix è protetto da copyright, il modello da un milione di dollari costruito dal team BellKor's Pragmatic Chaos e vincitore del Netflix Prize, è gratis e a disposizione di chiunque sul web.⁸ Ecco come funziona a grandi linee. (Ricorda che Netflix fornisce valutazioni su una scala da 1 a 5, e da qui compie una predizione sul possibile gradimento stabilendo un minimo fissato, per esempio quattro stelle.)

L'equazione fondamentale è

$$\text{valutazione prevista} = \text{media totale} + \text{correzione per il film} + \text{correzione per l'utente} + \text{interazione utente-film}$$

I primi tre termini al membro destro dell'equazione sono facili da spiegare:

- La media totale delle valutazioni, calcolata su tutti i film, è 3,7 stelle.
- Ogni film ha una correzione. *Schindler's List* e *Shakespeare in Love* hanno correzioni positive perché sono molto popolari, mentre *L'asilo dei papà* e *Dredd – La legge sono io* hanno correzioni negative perché non lo sono.
- Ogni utente ha una correzione perché alcuni sono più o meno critici della media. Magari Vladimir è un cinico e valuta sempre negativamente ogni film (correzione negativa), mentre Donald pensa che tutti i film siano fantastici e li valuta tutti positivamente (correzione positiva).

Questi tre termini forniscono una valutazione di base per la coppia utente/film. Per esempio, supponi di consigliare *La spia che mi amava* (correzione film = 0,4) a Vlad il taccagno (correzione utente = -0,2). La valutazione di base di Vlad dovrebbe essere $3,7 + 0,4 - 0,2 = 3,9$.

Ma questa è solo una prima approssimazione in quanto ignora ancora l'interazione utente-film, dove entra pesantemente in gioco la scienza dei dati. Per stimare questa interazione, il team vincente ha costruito un modello detto "a caratteristica latente". (Per latente si intende qualcosa che non viene misurato direttamente.) L'idea è che le valutazioni di film simili da parte di un utente mostrano alcune regolarità, in quanto sono associate a caratteristiche latenti di quell'utente. Ogni caratteristica latente può essere stimata da valutazioni precedenti e usata per fare predizioni su dati ancora non disponibili. Questa stessa idea spunta dappertutto, con nomi diversi.

- I partecipanti ai sondaggi danno risposte simili a domande sul loro lavoro e sulla formazione. Entrambi sono collegati a una caratteristica latente, lo "status socioeconomico", che può essere utilizzata per predire le risposte a domande sul reddito. I sociologi la chiamano "analisi fattoriale".
- I senatori votano in modo simile sulle tasse e sulle politiche di assistenza sanitaria. Entrambe sono collegate a una caratteristica latente, "l'ideologia", che può essere utilizzata per predire il voto di un senatore sugli stanziamenti per la difesa. I sociologi la chiamano "modello puntiforme ideale".
- Coloro che vengono sottoposti a un test SAT (Scholastic Aptitude Test) forniscono risposte simili a domande sulla geometria e sull'algebra. Entrambe sono collegate a una caratteristica latente, "l'abilità matematica", che può essere usata per predire una risposta a una domanda sulla trigonometria. I creatori del test la chiamano "teoria della risposta in argomento".
- Gli utenti Netflix valutano allo stesso modo *30 Rock* e *Arrested Development*. Entrambi sono collegati a una caratteristica latente – chiamiamola "affinità per commedie originali" – che può essere usata per predire la valutazione di *Parks and Recreation*. In scienza dei dati si chiama "selezione collaborativa basata sugli utenti".

Naturalmente non c'è un'unica caratteristica latente che descrive gli utenti Netflix, ma decine o addirittura centinaia: "misterioso omicidio inglese", "poliziesco con protagonista coraggioso", "programmi di cucina", "commedie da hipster" e così via. Queste caratteristiche formano gli assi coordinati di un gigantesco spazio multidimensionale in cui ogni utente occupa una posizione unica, corrispondente al suo univoco insieme di preferenze. Ti piace *Poirot* ma non sopporti la violenza di *Narcos*? Forse sei a +2,5 sull'asse del

“misterioso omicidio inglese” e a $-2,1$ sull’asse del poliziesco d’azione. Adori *I Tenenbaum* ma ti viene sonno con *The Great British Bake Off*? Forse sei a $3,1$ sull’asse delle commedie hipster e a $-1,9$ sugli spettacoli di cucina.

La parte più interessante dell’intero processo è che le caratteristiche latenti che definiscono questi assi non sono decise a priori: sono scoperte in modo naturale dall’IA, usando le correlazioni che emergono da milioni di valutazioni degli utenti. I dati – non un critico o un selezionatore umano – determinano le trasmissioni simili.

Le caratteristiche nascoste dicono tutto

Possiamo finalmente concludere il nostro racconto sulla personalizzazione nell’IA. È la storia di come le caratteristiche latenti dell’utente, scoperte grazie alla probabilità condizionata a partire da insiemi enormi di dati, sono state il motore nascosto della trasformazione strategica di Netflix da distributore a produttore. È anche la storia di come queste caratteristiche latenti siano l’elisir magico dell’economia digitale, una speciale ricetta di dati, algoritmi e intuizioni umane che rappresenta lo strumento più perfetto mai concepito per il marketing personalizzato. Quelli di Netflix lo hanno capito, e hanno deciso di usare quello strumento per fare televisione da soli, e non ci hanno mai ripensato.

Pensa a cosa rende diverso Netflix come produttore di contenuti. A differenza dei maggiori network televisivi, a Netflix non interessa quanti anni hai, di che etnia fai parte o dove vivi. Non è importante il tuo lavoro, la tua formazione, il tuo reddito o il tuo genere. E certamente non gli interessa quello che pensano i pubblicitari, anche perché non ne hanno. L’unica cosa che interessa a Netflix è cosa ti piace in TV e la conoscono straordinariamente bene, grazie all’esame delle tue caratteristiche latenti.

Quelle caratteristiche consentono a Netflix di suddividere gli utenti in base a centinaia di criteri diversi. Ti piacciono i drammi o le commedie? Sei amante dello sport? Ti piacciono gli spettacoli di cucina? Ti piacciono i musical? Ti piacciono i film con cast eterogenei? Guardi ogni secondo di un film d’azione o mandi avanti quando ci sono scene di violenza? Guardi cartoni animati? Le regolarità nel tuo storico di visualizzazione, insieme a quelle di tutti gli altri utenti, danno una risposta matematicamente precisa a ognuna di queste domande e a centinaia di altre ancora. La tua esatta

combinazione di caratteristiche latenti – il tuo angolino nel gigantesco spazio euclideo multidimensionale – ti rende un “unicum” demografico.

Ecco come Netflix ha inventato il suo nuovo modello di business, che consiste nel commissionare trame magnifiche ad artisti di fama mondiale, alcune mirate a un piccolo e selezionato pubblico, altre a un altro tipo di pubblico. Un eccellente esempio è *The Crown*, un’opera drammatica sfarzosa e stratificata sugli anni giovanili di Elisabetta II. Fino al 2017, *The Crown* era la più costosa serie televisiva di sempre: 130 milioni di dollari per dieci episodi. Il budget includeva 7000 abiti d’epoca, tra cui il più famoso era un vestito da matrimonio reale da 35 000 dollari. Può sembrare che Netflix spenda in nuovi programmi TV come un marinaio ubriaco. Ma ricorda le statistiche incredibili del singolo anno di un network televisivo: 400 milioni di dollari per produrre 113 episodi pilota, dei quali solo tredici sono arrivati alla seconda stagione. Quando lo standard industriale è buttare centinaia di milioni di dollari in programmi destinati all’irrelevanza, anche un abito da matrimonio che costa 300 abbonamenti annuali a Netflix inizia a sembrare un buon affare. Dunque, più che un marinaio ubriaco, la metafora adatta è un indovino con la sfera di cristallo, una palla probabilistica, basata sui dati, in grado di dire a quelli di Netflix esattamente il tipo di programma per cui i loro utenti pagherebbero 130 milioni di dollari. Una volta intuito questo, si affidano agli artisti per il resto.

I numeri iniziano a mostrare che questa strategia paga. Netflix non rilascia statistiche di visione, ma abbiamo un indicatore: i premi. Nel 2015, Netflix era al sesto posto tra i network televisivi per quanto riguarda le candidature agli Emmy Awards. Nel 2017 era al secondo posto; le sue novantuno candidature erano seconde solo al bottino di centodieci della HBO, e giustamente HBO è molto preoccupata di ciò che potrebbe succedere quando il popolarissimo *Game of Thrones* giungerà al termine. Pare solo questione di tempo, prima che i servizi di streaming come Netflix arrivino a dominare la scena agli Awards.

In ogni caso, l’approccio di Netflix alla personalizzazione domina già l’economia digitale. Se il futuro della vita digitale riguarda i suggerimenti piuttosto che la ricerca, come noi crediamo, allora il futuro dipenderà inevitabilmente dalla probabilità condizionata.

Il lascito eterogeneo dei motori di suggerimenti

I motori di suggerimenti rappresentano un'importante area di ricerca nell'IA da oltre un decennio, sia nell'industria che nell'università. Anche se il loro lascito si sta ancora dispiegando, è utile fare una riflessione sul punto in cui ci troviamo. Il bilancio è contrastante.

Il lato oscuro del marketing personalizzato

Prima le brutte notizie: queste tecnologie non sono state usate *unicamente* per dare suggerimenti su cose divertenti, come i programmi TV e la musica. Esiste anche un lato oscuro, sfruttato in contesti cinici e divisivi. Non esiste esempio migliore dell'uso di Facebook da parte dell'intelligence russa nei mesi precedenti l'elezione presidenziale del 2016 negli Stati Uniti.

Facebook è popolare tra i pubblicitari per lo stesso motivo per cui Netflix è popolare tra gli spettatori televisivi: padroneggia l'arte del marketing personalizzato basandosi sulle tue tracce digitali. Anni fa, quando le aziende volevano raggiungere un determinato settore demografico – studenti universitari, per esempio, o genitori con figli in età scolastica – pagavano per mettere annunci pubblicitari in posti dove il loro pubblico di riferimento *avrebbe potuto* prestare attenzione. I venditori prendevano queste decisioni di acquisto usando dati aggregati su quale tipologia di persone guardasse un determinato programma o leggesse una determinata rivista. Ma non erano in grado di rivolgersi a singoli individui. Come dice un vecchio adagio: metà dei soldi investiti in pubblicità è sprecata, ma non sappiamo quale metà.

Ma se un annuncio pubblicitario era in passato un'arma spuntata, oggi è un raggio laser. I venditori possono ora costruire una pubblicità online per ogni possibile segmento di pubblico, definito a un livello impressionante di dettaglio demografico e psicografico. Se ti presentassi all'ufficio vendite di Facebook con l'obiettivo di raggiungere “giovani professionisti”, per esempio, probabilmente ti riderebbero dietro. Ti chiederebbero di specificare *esattamente* chi vuoi raggiungere. Vuoi avvocati o bancari? Democratici o repubblicani? Sportivi o appassionati di opera lirica? Bianchi o neri, uomini o donne, del Nord o del Sud, bistecca o insalata e, se insalata, iceberg o cavolo riccio? E l'elenco potrebbe continuare. Una volta che hai stabilito il tuo pubblico, gli algoritmi di Facebook possono selezionare *esattamente* gli utenti a cui proporre un annuncio pubblicitario o un post sponsorizzato, nell'esatto istante in cui è più probabile che siano ricettivi nei confronti del messaggio. Tutto questo fa venire le vertigini ai venditori ed è il motivo per cui Facebook

vale, nel momento in cui scriviamo, 500 miliardi di dollari: più del PIL della Svezia.

Questo tipo di marketing personalizzato va avanti già da un po' e, a giudicare dal loro comportamento, gran parte degli utenti Facebook sono stati ben felici di accettare l'accordo "dati in cambio di gossip", implicito nell'uso continuativo della piattaforma. Ma per molti il campanello d'allarme suonò all'alba delle elezioni presidenziali 2016, quando divenne chiaro il modo intelligente in cui la Russia manipolò il sistema di annunci pubblicitari di Facebook per seminare dissenso tra gli elettori americani. I servizi russi, per esempio, si concentrarono su un gruppo di utenti che esprimeva solidarietà agli agenti di polizia durante le proteste del movimento Black Lives Matter. A questi utenti venne destinata una pubblicità contenente una bara avvolta in una bandiera durante il funerale di un poliziotto, insieme a una didascalia: «Un altro raccapricciante attacco alla polizia da parte di un attivista del movimento BLM. I nostri cuori sono con quegli undici eroi». In seguito presero di mira un gruppo di utenti cristiani conservatori con una diversa pubblicità: una foto di Hillary Clinton che stringe la mano a una donna con il velo, insieme a una didascalia scritta in caratteri arabeggianti: «Sostieni Hillary. I musulmani d'America». I russi idearono pubblicità differenti per newyorkesi e texani, per i sostenitori della comunità LGBTQ e per quelli della NRA, per veterani e attivisti dei diritti civili, tutti presi di mira con spietata efficienza algoritmica.⁹

Non conosciamo nessuno, di qualsiasi partito o professione, che non sia spaventato all'idea di una potenza estera ostile che utilizzi i social media come arma per manipolare le elezioni americane. Ed è chiaro che la tecnologia che c'è dietro ai motori di suggerimenti è almeno uno degli ingredienti di questo cocktail tossico che mescola denaro russo e identità politica. Superati questi punti comuni, su cui c'è accordo pressoché universale, il problema diventa tuttavia molto più complesso. Per esempio:

1. Queste attività hanno davvero influenzato l'esito delle elezioni presidenziali? Probabilmente non lo sapremo mai, poiché non possiamo ripercorrere all'indietro i processi decisionali dei 138,8 milioni di persone che hanno votato, o delle decine di milioni che sono rimaste a casa.
2. Sarebbe diverso se un attivista statunitense – per esempio, i fratelli Koch a destra o il Blue Dog PAC a sinistra – avesse fatto qualcosa di simile? Se pensi che sarebbe ugualmente preoccupante, e che Facebook o qualcun altro dovrebbe porre un freno a tutto ciò, saresti rassicurato dal fatto che i tuoi avversari politici potessero decidere dove mettere i limiti?

3. Queste tecniche dell'era digitale sono qualitativamente più efficaci nell'influencare le persone rispetto alle tecniche usate in altre epoche, per esempio da Leni Riefenstahl alla radio di propaganda? È una domanda semplice: se alle persone viene indirizzata pubblicità digitale iperspecifica, basata su quello che i dati dicono di loro, e se i dati sono molto accurati, quante di loro cambieranno idea o si comporteranno diversamente? Se la risposta è «la pubblicità non cambia le opinioni, ma semplicemente rende più probabile il fatto che le persone votino secondo posizioni che già sostengono» – ipotizzando, di nuovo, un inserzionista americano – questo è un bene o un male per la democrazia?
4. Che cosa dovremmo fare ora, in pratica? Gli algoritmi hanno certamente giocato un ruolo nella *débâcle* Russia/Facebook, ma lo stesso è accaduto con la nostra preesistente cultura politica e con le nostre leggi sulla pubblicità, in particolar modo la pubblicità politica a pagamento. Qual è il giusto mix di azioni giuridiche e politiche per evitare che eventi del genere si ripetano? Andando oltre, dovremmo prendere tutto ciò come un campanello d'allarme nei confronti del marketing digitale personalizzato *tout court*, e non solo in politica?

Non conosciamo le risposte a queste domande, ma crediamo che un dibattito informato sul tema sia possibile. Ecco dunque due aspetti da considerare come spunti di conversazione.

Primo, non c'è esempio più nitido dell'abuso che i russi hanno fatto di Facebook per affermare che la società non può aspettarsi un futuro luminoso affidandosi unicamente all'intelligenza delle macchine senza supervisione umana. I motori di suggerimenti non spariranno, e non c'è alternativa al creare un quadro legale e culturale in cui possano essere usati responsabilmente. Siamo ottimisti nel credere che, nel caso fosse necessario, le persone *possono* essere abbastanza intelligenti da prevenire i peggiori abusi della tecnologia senza distruggere le macchine.

Secondo, non c'è argomentazione migliore di questa per convincersi che ogni cittadino del XXI secolo debba capire alcuni concetti di base dell'intelligenza artificiale e della scienza dei dati. Se l'educazione, come diceva Thomas Jefferson, è la pietra angolare della democrazia, allora, pensando alla tecnologia digitale, le nostre mura democratiche stanno cedendo. Gli americani hanno discusso dei limiti della libertà di parola nel campo del commercio sin dall'alba della nazione. Ma oggi siamo *ben oltre* un dibattito sulla pubblicità dei cereali nei cartoni animati della domenica mattina, molto lontani dal mero esempio di una discutibile pratica commerciale resa obsoleta dalle nostre nuove tecnologie. Ci sono *talmente*

tante incognite che ci aspettano lungo il percorso. Come minimo, tribunali e assemblee legislative dovrebbero sopperire ai loro punti deboli e smetterla di considerare “gergo da iniziati” i dettagli che non capiscono. E i cittadini dovrebbero partecipare a queste discussioni con una conoscenza di base, piuttosto che con il timore, dei dettagli tecnici. In termini semplici, le persone intelligenti che hanno a cuore il mondo *devono* sapere di più sull’IA. È una delle ragioni per cui abbiamo scritto questo libro.

Il lato positivo per la scienza

E ora qualche buona notizia sui motori di suggerimenti. I concetti matematici e algoritmici sviluppati nell’ultimo decennio di lavoro sulla personalizzazione iniziano a diffondersi in altre aree della scienza e della tecnologia. E portano molte novità positive.

Prendi per esempio i social network rivolti alle persone affette da malattie: Crohnology per pazienti con disturbi gastrointestinali, Tiatros per soldati con disturbo da stress post-traumatico o PatientsLikeMe per quasi qualsiasi disturbo. Questi network si basano su algoritmi di personalizzazione, proprio come Facebook. I pazienti li considerano una risorsa importante per consigli sui trattamenti e sui cambiamenti dello stile di vita, mentre i ricercatori li vedono come una preziosa riserva di dati sanitari che può essere utilizzata per migliorare ulteriormente quei consigli.

Oppure considera i sempre più numerosi strumenti statistici a disposizione dei neuroscienziati, che ora possono monitorare sistematicamente l’attività di centinaia di neuroni in un colpo solo mentre cercano di capire il modo in cui il cervello elabora le informazioni. I progressi nell’hardware li metteranno presto nelle condizioni di monitorare migliaia di neuroni per volta. Al crescere dei dati a disposizione, i neuroscienziati si stanno sempre più spostando verso modelli a caratteristiche latenti in stile Netflix, per trovare gruppi di neuroni che si attivano insieme in risposta a qualche stimolo: l’equivalente neurofisiologico dell’apprezzare lo stesso programma televisivo. Questo lavoro potrebbe portare a nuove scoperte e a trattamenti innovativi per alcune delle malattie più comuni, dall’autismo all’Alzheimer.

Probabilmente le novità più eccitanti sono nel campo della ricerca sul cancro, in particolare nella “terapia personalizzata”. Sebbene il cancro sia classificato in base alla parte del corpo che colpisce, è fondamentalmente una malattia che riguarda il genoma. In più, i genomi tumorali possono presentarsi

sotto molteplici forme. Anche pazienti con lo stesso tipo di cancro possono avere tumori con differenti sottotipi genetici, e i ricercatori hanno scoperto che tali sottotipi rispondono spesso in modo diverso ai farmaci. È oggi comune analizzare gli specifici geni e proteine di un campione tumorale di un paziente per scegliere il farmaco appropriato.

Nel corso degli anni, i ricercatori impegnati nella lotta ai tumori hanno costruito enormi database di informazioni genetiche su differenti tipologie tumorali, e hanno lavorato insieme ad analisti dei dati per scandagliare quei database alla ricerca di schemi che potessero essere sfruttati in terapie personalizzate. Per esempio, circa il 60% dei tumori del colon-retto presentano una versione non mutata del gene KRAS. Un particolare farmaco antitumorale, il cetuximab, è efficace contro questi tumori ma inefficace nei confronti del 40% che presenta il gene KRAS mutato.

Questo è un modello semplice, che coinvolge solo un gene. Altri modelli, invece, sono molto complessi. Coinvolgono decine o centinaia di geni, collegati a uno dei molti e complicati “indizi molecolari” che qualcosa sta andando storto nella cellula tumorale. Per gestire tale complessità, i ricercatori ricorrono sempre più spesso a modelli a caratteristiche latenti, sulla falsariga di quelli sviluppati nella Silicon Valley nell’ultimo decennio per alimentare motori di suggerimenti su larga scala. Questi modelli sono utilizzati per analizzare i dati provenienti dai genomi e spiegare perché alcuni pazienti rispondono ai farmaci e altri no. Proprio come Netflix usa le caratteristiche degli storici di visualizzazione per proporre agli utenti i programmi televisivi, i ricercatori sperano di usare le caratteristiche dei “profili genomici” per delineare terapie e magari anche inventarne di nuove, espressamente disegnate per ciascuno, in stile *House of Cards*.

L’idea sta prendendo piede. Per esempio, nel 2015, gli scienziati del National Cancer Institute hanno annunciato la scoperta di due diversi sottotipi di neoplasia dei linfociti B, distinti in base a caratteristiche genetiche latenti. I ricercatori ipotizzarono che i due sottotipi, ABC e GCB, potessero rispondere diversamente a un determinato farmaco, l’ibrutinib. Dunque effettuarono un trial clinico con ottanta pazienti affetti da linfoma, prelevarono campioni tumorali per determinare se fossero del tipo ABC o GCB, diedero a tutti l’ibrutinib, e seguirono la loro evoluzione nei mesi e anni successivi. I risultati furono strabilianti: l’ibrutinib era sette volte più efficace nei pazienti con il sottotipo ABC.¹⁰

Dato il lungo orizzonte temporale e i miliardi di dollari richiesti per sviluppare e testare un nuovo farmaco tumorale, la strategia di profilazione del genoma è ancora lontana dalla piena maturità. Ma come mostra il trial sull'ibrutinib, la probabilità condizionata inizia a dare i suoi frutti nella ricerca sul cancro, e i laboratori di tutto il mondo sono al lavoro sulle ultime generazioni di terapie personalizzate.

Post scriptum

Speriamo che questo capitolo ti abbia aiutato a capire un po' meglio il concetto essenziale su cui si basano aziende come Netflix, Spotify e Facebook: per una macchina, "personalizzazione" vuol dire "probabilità condizionata". Speriamo anche che tu abbia compreso che i moderni sistemi di IA rappresentano solo un passo lungo il tortuoso cammino seguito dall'ingegno umano, un cammino che certamente porterà nuove meraviglie, ma che è anche pieno di nuove sfide.

Per chiudere il capitolo, ti lasciamo con un aneddoto personale sui motori di suggerimenti. Nell'estate del 2014, uno degli autori (Scott) vistò Ypres, una città nel Belgio occidentale la cui posizione strategica le fece rivestire un ruolo di primo piano nella prima guerra mondiale. I tedeschi e le armate alleate combatterono nei pressi di Ypres nell'ottobre del 1914. Entrambe le fazioni scavarono trincee e ne derivò una situazione di stallo che durò per anni:

Gli uomini marciavano addormentati. Molti, persi gli stivali,
procedevano claudicanti, calzati di sangue. Tutti finirono azzoppati; tutti orbi;
Ubrachi di stanchezza; sordi persino al sibilo
di stanche granate che cadevano lontane indietro.
Wilfred Owen¹¹

Alla fine della terza battaglia di Ypres, nel 1917, quasi mezzo milione di soldati erano morti, e la città era un cumulo di rovine.

Un secolo più tardi, passeggiare per la città ricostruita è un evento solenne e, durante la sua visita nel 2014, Scott trovò che il senso di solennità fosse rafforzato da una rete di altoparlanti che diffondeva musica classica nel centro della città. Era un tocco di raffinatezza, e la scelta musicale era di gusto tradizionalmente classico... fino all'attacco di una modernissima e inattesa

linea di basso. Non fu facile all'inizio riconoscere la canzone, ma le parole non lasciarono dubbi. Chiunque fosse a scegliere la musica a Ypres, aveva messo su *SexyBack*, la hit di Justin Timberlake del 2006.

Forse era voluto. Ypres aveva riportato un po' di vita tra i suoi vicoli medievali, ricostruiti mattone dopo mattone alla fine della guerra. Eppure, dopo tutta quella musica classica, sembrava una scelta stravagante. E così, quando entrò nell'ufficio turistico alla ricerca di una mappa dei monumenti commemorativi del campo di battaglia, Scott chiese alla signorina fiamminga dietro la scrivania se fosse lei a selezionare la musica da diffondere negli altoparlanti.

«Oh, no» disse. «In realtà usiamo Spotify.»

Anche i migliori motori di suggerimenti ogni tanto falliscono.

[*a](#) Per i maghi dei fogli di calcolo, questo equivale a fare una tabella pivot.

LA FABBRICANTE DI CANDELIERI

Che cosa collega le dimensioni dell'universo alla salvezza delle api? Il modo in cui i computer imparano a riconoscere schemi nei dati e usano quegli schemi per fare predizioni incredibilmente intelligenti.

Nel 2017 la polizia di Pechino capì di avere un problema. Un pericoloso gruppo di criminali era all'opera in città.

Fortunatamente, un'analisi attenta dei misfatti rivelò uno specifico piano d'azione. L'obiettivo principale era il parco del Tempio del Cielo, un luogo di grande importanza spirituale per il popolo cinese, in cui si trova uno dei capolavori architettonici della dinastia Ming. I criminali arrivavano di buon mattino, si mescolavano agli anziani del posto che facevano esercizio fisico o cantavano canzoni, e aspettavano pazientemente che le casse dei loro bersagli fossero riempite. A metà mattina entravano in azione, infilandosi con nonchalance in un bagno pubblico nelle vicinanze e restandovi per un paio di minuti, in modo da non destare sospetti. A quel punto colpivano con rapidità e freddezza: afferravano e mettevano in uno zaino tutti i rotoli di carta igienica che riuscivano a trovare, e uscivano dalla toilette come se nulla fosse successo. Il rischio maggiore era in quei primi passi alla luce del sole. Ma una volta mischiatisi tra la folla, era fatta.

Questi ladri erano diventati eccezionalmente abili e audaci. Rubavano grandi quantità di carta igienica e la polizia di Pechino iniziò a dar loro la caccia.

Il primo passo fu installare distributori automatici di carta igienica in ogni bagno pubblico nei pressi del Tempio del Cielo, in modo che ogni utente ricevesse esattamente sessanta centimetri di carta, equivalenti a sei strappi. Ma ben presto i ladri, non potendo più rubare rotoli interi, iniziarono a rubare carta igienica sei strappi alla volta. Facevano semplicemente il giro del parco, prelevando da ogni toilette lungo il percorso, fino a tornare al punto di partenza. A quel punto ricominciavano il giro, e andavano avanti con la loro

passaggiata clepto-scatologica finché tutta la carta igienica non era nelle loro mani. L'intera operazione prendeva molto più tempo rispetto ai giorni felici dei rotoli liberi, ma il risultato era ugualmente disastroso per il budget cittadino in carta igienica.

Con tutta evidenza, questi ladri non si sarebbero lasciati intimorire da un distributore a sei strappi. Le autorità considerarono, per breve tempo, anche l'ipotesi di ricorrere a buttafuori posti di guardia accanto alle toilette. Ma nel 2017 decisero di affidarsi all'intelligenza artificiale: installarono videocamere e software di riconoscimento facciale, basati su un algoritmo di deep learning, su ogni bagno pubblico del parco.

Oggi, se vuoi usare un bagno nei pressi del Tempio del Cielo, devi: (1) togliere cappello, occhiali, maschere di Guy Fawkes ecc.; (2) guardare nell'obiettivo che, per decenza, è posto all'esterno. Se il software riconosce che il tuo volto è già comparso in una toilette delle vicinanze negli ultimi nove minuti, allora niente da fare: non avrai i tuoi sei strappi.

Dotare i bagni pubblici di intelligenza artificiale può sembrare una soluzione estrema, o forse solo particolarmente inquietante, al problema del furto di carta igienica. Molti hanno sollevato dubbi in merito alla violazione della privacy e, come prevedibile, sono sorti diversi problemi logistici: lunghe code, videocamere rotte, scambi di identità. Il nostro obiettivo nel riportare questo esempio non è certamente quello di sostenere l'approccio della polizia di Pechino, ma evidenziare un semplice fatto: il riconoscimento di schemi basato sull'IA è al giorno d'oggi ovunque, persino nei bagni. Dunque se vuoi capire la realtà contemporanea, sarà utile comprendere come funzionano questi sistemi e perché dipendono così fortemente dai dati.

Input/output:

come le macchine riconoscono gli schemi

Le persone sono bravissime a riconoscere schemi. Fin dalla più tenera età, per esempio, impariamo ad associare volti a nomi, e molta parte della formazione successiva si basa sull'applicazione di giusti schemi:



- Per parlare bisogna abbinare un suono al relativo significato.
- Per leggere bisogna abbinare una stringa di simboli alla parola giusta.
- Per saper stare in società bisogna abbinare il giusto comportamento a ogni contesto sociale.


- Per essere un bravo medico bisogna abbinare i sintomi alla giusta diagnosi e alle giuste cure.
- Per essere un analista di dati bisogna abbinare un set di dati al modo giusto di analizzarli.

In qualsiasi campo del sapere, essere intelligenti significa riconoscere molti schemi: sapere come abbinare un *input* con l'*output* appropriato.

Non siamo i soli a riconoscere schemi. Per esempio, uno degli autori (Scott) ha un adorabile gattino che odia i viaggi in auto. Il gatto ha imparato che quando i suoi padroni iniziano a prepararsi, gli toccherà passare un po' di tempo in macchina. Ora, ogni volta che qualcuno prende un borsone dall'armadio, Markov va immediatamente a nascondersi sotto il letto.

Anche i computer sono oggi in grado di riconoscere schemi, come i gatti e le persone. Ricorderai la storia di Makoto Koike, che costruì un classificatore di cetrioli basato sul riconoscimento di caratteristiche grazie all'IA. In quel caso l'input era un'immagine, l'output era la decisione di classificare il cetriolo in una delle nove differenti classi, e lo schema era la relazione tra l'aspetto del cetriolo e la sua classe di appartenenza. In IA si chiama "classificazione di immagini" e la troviamo ovunque: nei bagni pubblici di Pechino, per identificare i tuoi amici nelle foto su Facebook, per rilevare collisioni tra particelle subatomiche in immagini provenienti dagli esperimenti di fisica delle alte energie al CERN, l'enorme laboratorio nei pressi di Ginevra. Ma l'input non deve necessariamente essere un'immagine. I computer non hanno preferenze rispetto all'input che puoi fornire, dal momento che per un computer si tratta in ogni caso di numeri. L'input potrebbe essere un'onda sonora (per interpretare una richiesta a un assistente digitale), una sequenza genica (per stimare la predisposizione a una certa malattia) o una frase in inglese (per tradurla in spagnolo). Come indicato nella seguente tabella, qualsiasi cosa tu possa rappresentare come un insieme di numeri può essere trasmesso come input a un sistema di riconoscimento di schemi. Come discuteremo in seguito, tuttavia, in certi casi è banale rappresentare un input tramite una sequenza di numeri, mentre in altri casi lo è meno.

Input	Output
	<p>Geolocalizzazione: «Roma, Italia»</p>
	<p>Frase trasformata in testo: «Aus-tin ko-la-tsjo-ne-ta-kos»</p>

Input	Output
	<p>Classificazione di immagini: «Hot dog»/«Non hot dog»</p>
<p>20 °C, 70% umidità, prevalentemente soleggiato</p>	<p>Predizione numerica: «Il consumo di elettricità a Londra sarà 25 500 megawatt/h»</p>
<p>«Buenos dias!»</p>	<p>Traduzione: «Buongiorno!»</p>
<p>«Essere, o non essere...»</p>	<p>Attribuzione di autore: «Shakespeare»</p>

In questo capitolo apprenderai i due concetti chiave alla base di questi sistemi di riconoscimento di schemi:

1. Nell'IA uno "schema" è una regola di predizione che mappa un input in un output atteso.

2. “Imparare uno schema” significa applicare una buona regola di predizione a un insieme di dati.

C'è un po' di matematica a questo punto, ma non preoccuparti: le idee ti risulteranno abbastanza semplici ed eleganti e passeremo il resto del capitolo ad aiutarti ad assimilarle.

Vediamo un primo esempio di ciò che intendiamo. Avrai certamente letto questa regola da qualche parte su internet o l'avrai sentita da un guru del fitness: per stimare la tua massima frequenza cardiaca, sottrai la tua età da 220. Questa regola può essere espressa tramite un'equazione ($MFC = 220 - \text{età}$) che fornisce la descrizione matematica di uno schema riscontrato nei dati: la massima frequenza cardiaca (output) tende ad abbassarsi con l'età (input). Ti fornisce anche un modo per fare una predizione. Per esempio, se hai trentacinque anni predirai la tua frequenza cardiaca massima inserendo “età = 35” nell'equazione, ottenendo $MFC = 220 - 35$, ovvero 185 battiti al minuto.

Una regola di predizione in IA è esattamente questo: un'equazione che descrive uno schema ricorrente nella relazione tra input e output. Una volta utilizzato un insieme di dati per trovare una buona regola di predizione, puoi applicarla a ogni nuovo input per trovare l'output corrispondente, allo stesso modo in cui inserisci la tua età nell'equazione “ $MFC = 220 - \text{età}$ ” e ottieni la predizione per la tua massima frequenza cardiaca.

È il momento di un po' di linguaggio tecnico. In IA le regole di predizione sono spesso chiamate “modelli”, per esempio un “modello di riconoscimento facciale” che accetta un'immagine in input e restituisce l'identità di una persona in output, o un “modello traduttore” che prende una frase in inglese e la restituisce in spagnolo. Utilizzare dati al fine di trovare una buona regola di predizione è detto “allenare il modello”. Ci piace la parola “allenamento” perché evoca i benefici progressivi per la salute derivanti da ogni sessione in palestra o, nel caso dell'IA, i progressivi miglioramenti derivanti da ogni nuovo dato a disposizione. Se non riusciamo noi ad andare in palestra, per lo meno ci vanno i nostri modelli.

Ma questo solleva molte domande. Che cosa significa “allenare un modello su un set di dati”? Che cosa rende un modello migliore di un altro? Come lo spiegheresti a un computer? Ovvero, come insegneresti a un algoritmo a trovare il giusto schema in un insieme di dati? Dopotutto i computer non “pensano” solo in termini numerici? Come funziona tutto questo quando l'input è qualcosa di complesso, come un'immagine, un'onda sonora o un

singolo numero, come l'età di una persona? E forse, ancora più importante per coloro che sono alla ricerca di una comprensione più profonda dell'IA: da dove viene questa idea di allenare i modelli con i dati? E come è arrivata a ricoprire un ruolo così fondamentale, sebbene invisibile, nelle nostre vite, essendo praticamente alla base di tutto: dai social media alla terapia oncologica, dalla coltivazione dei cetrioli alle traduzioni in spagnolo, dai bagni pubblici alle reti elettriche?

Una scoperta stellare

Per rispondere a queste domande, inizieremo con un articolato esempio di come una regola di predizione può rappresentare uno schema. Tale schema è del tutto identico a quelli che spuntano fuori dappertutto nell'IA, ed è molto più interessante della corrispondenza età-frequenza cardiaca. In effetti, lo schema in questione ha portato a uno dei più grandi trionfi intellettuali di tutti i tempi, aiutando gli scienziati a rispondere a una domanda millenaria: quanto è grande l'universo?

Qualsiasi persona curiosa può oggi aprire un browser e trovare migliaia di splendide immagini provenienti dal telescopio spaziale Hubble: galassie in collisione, resti di stelle esplose, lontani quasar con energia pari a milioni di Soli. Gli astronomi di un secolo fa riconoscerebbero a malapena queste meraviglie. Per loro l'universo era un posto molto più piccolo. Nel 1924 l'opinione scientifica dominante era che la nostra galassia, la Via Lattea, fosse l'unica galassia nell'universo e oltre i suoi confini vi fosse solo il vuoto. La sconcertante verità fu scoperta solo nei primi decenni del XX secolo: viviamo in un gigantesco universo composto da migliaia di miliardi di galassie.

Ci concentreremo su tre caratteristiche essenziali nella storia di questa grande scoperta:

1. una ignota macchiolina di luce nel cielo notturno, visibile perfino in antichità;
2. un principio matematico, noto da secoli, sul riconoscimento di schemi che oggi è alla base dei nostri più sofisticati sistemi di IA;
3. un'astronoma poco nota dei primi del Novecento, di nome Henrietta Leavitt, che, usando quel principio matematico, ci ha spiegato come misurare le dimensioni dell'universo.

Quando vedrai questi tre protagonisti unire le loro forze, avrai una comprensione molto più profonda di come le macchine rilevano gli schemi nel mondo intorno a loro e di come usano quegli schemi per fare predizioni incredibilmente accurate, che si tratti della classificazione dei cetrioli, del riconoscimento dei tuoi amici nelle foto o di dover incastrare ladri di carta igienica a Pechino.

Una «macchia sfocata» nell'emisfero nord

Più di mille anni fa, osservatori attenti si accorsero di alcuni piccoli puntini luminosi nel cielo: non erano propriamente delle stelle ed erano più simili a nuvole luminose dai contorni sfocati. La più grande di esse, visibile a occhio nudo in una notte buia, era una macchiolina brillante sulla cintura di Andromeda, una costellazione dell'emisfero nord. Nel X secolo d.C., l'astronomo persiano 'Abd al-Rahman al-Ṣūfi riferì di una «macchia sfocata».¹ al-Ṣūfi non riusciva a capire cosa fosse, e nessun altro ci riusciva. Con l'invenzione del telescopio nel XVII secolo, il mistero della Grande Nebulosa di Andromeda si infittì ulteriormente e gli astronomi scoprirono altre piccole macchie simili e molte di esse, proprio come quella di Andromeda, avevano una caratteristica forma a spirale.

A inizio Ottocento gli astronomi le chiamavano “nebulose a spirale”, dalla parola *nebula* che in latino indica la nebbia. Queste nebulose imploravano una spiegazione. Erano stelle neonate? Erano nubi di gas luminoso all'estrema periferia della Via Lattea? O erano ognuna, come alcuni suggerivano, una galassia lontana del tutto simile alla nostra?²



Figura 2.1 Un'immagine moderna della galassia di Andromeda dal Galaxy Evolution Explore della nasa. Courtesy NASA/JPL-Caltech.

Quest'ultima interpretazione – ovvero che le nebulose a spirali fossero “universi isola”, l'espressione usata a quel tempo per una galassia – era stata in voga per buona parte del XVIII e XIX secolo. Il sostenitore più celebre era stato il filosofo tedesco Immanuel Kant. Ma all'alba del XX secolo la teoria degli universi isola era caduta in disgrazia. Non c'erano prove dirette a sostegno, e dunque la maggioranza degli astronomi concordava con l'ipotesi di un'unica galassia esistente nell'universo. Pensavano che le spirali si trovassero ai confini della Via Lattea e fossero nubi in cui si formavano nuove stelle. L'idea che potessero essere galassie indipendenti era ritenuta «megalomane» e «fuorviante», descritta in un testo di astronomia dell'epoca come così ridicola che «non ha neppure bisogno di essere discussa».³

Ma con il miglioramento dei telescopi e con l'acquisizione di nuove prove, alcuni astronomi iniziarono a pensare di aver scartato troppo presto la vecchia teoria di galassie indipendenti. Un punto a loro favore era il ritmo con cui gli astronomi scoprivano supernove: “nuove stelle” che comparivano all'improvviso nel cielo notturno e gradualmente sparivano nel giro di settimane o mesi. Le supernove erano note da centinaia di anni, ma i potenti

nuovi telescopi dell'inizio del Novecento misero gli astronomi di fronte a un fatto curioso. La Grande Nebulosa di Andromeda sembrava avere un numero sorprendente di supernove al suo interno, maggiore, in realtà, rispetto a quello del resto della galassia. Se Andromeda era solo una nuvola di polvere sul bordo esterno della Via Lattea, com'era possibile? Perché un piccolo angolo di galassia dovrebbe dovuto essere così pieno di supernove?

E poi c'era il problema della velocità a cui Andromeda si muoveva. Nel 1913 l'astronomo Vesto Slipher l'aveva accuratamente misurata usando uno spettrometro, una "pistola laser" cosmica che sfrutta l'effetto Doppler, lo stesso principio che causa l'aumento della frequenza del suono di un'ambulanza quando si avvicina e la sua diminuzione quando si allontana. I risultati di Slipher erano così sorprendenti che lui stesso ne era scettico: Andromeda si muoveva rispetto alla Terra a 300 chilometri *al secondo*, circa venti volte più veloce di qualsiasi altro oggetto nella Via Lattea. Ancora più scioccante era il fatto che la gran parte delle altre nebulose a spirale si muoveva anche più velocemente e alcune arrivavano fino a 1000 chilometri al secondo. Per molti astronomi, i risultati di Slipher mettevano fine alla questione una volta per tutte: le spirali si muovevano troppo velocemente per essere all'interno della nostra galassia.⁴

Gli scettici della teoria delle galassie indipendenti, tuttavia, avevano pronta una controreplica. Se la Nebulosa di Andromeda era una galassia a parte, potevano essere tratte due conseguenze impossibili. Per prima cosa, Andromeda doveva essere lontana milioni di anni luce, altrimenti sarebbe dovuta essere molto più luminosa. E se questo fosse stato vero, allora ogni supernova all'interno di Andromeda avrebbe dovuto liberare l'energia di milioni di Soli, altrimenti non l'avremmo mai vista da così lontano. Col senno di poi, ora sappiamo che entrambe le "impossibilità" sono vere. Ma, agli occhi di molti astronomi dell'inizio del Novecento, bastavano a rendere un'assurdità la teoria delle galassie indipendenti.

Che cosa dovevano pensare dunque gli astronomi di tutte quelle nebulose? Erano grandi o piccole? Erano nuvole di polvere all'interno della nostra galassia o galassie a parte? Nessuno aveva una prova decisiva, e questo lasciava tutti nella confusione più totale, perché queste domande generavano un altro grande interrogativo: quanto è grande davvero l'universo? Copernico ci aveva umiliato dimostrando che la Terra non è al centro della creazione. Galileo ci aveva umiliato una seconda volta dimostrando che la Via Lattea era un enorme ammasso di stelle simili alla nostra. Dovevamo aspettarci una

terza umiliazione che ci rivelasse che la nostra galassia non era l'unica? Era il Grande Interrogativo dell'astronomia e imperversò per i primi due decenni del XIX secolo. E l'unico motivo per cui non si risolveva era che nessuno riusciva a rispondere a una semplice domanda: quanto dista la Grande Nebulosa di Andromeda?

Come si misurano le stelle?

Immagina di guidare di notte lungo una buia stradina di campagna. Raggiungi la cima di una collina e un puntino luminoso brilla in lontananza. Quanto dista? È la fioca lampada del porticato di una casa a qualche centinaio di metri di distanza? Sono i fari di un'altra auto a un paio di chilometri di distanza? O forse è qualcosa di più lontano ma molto più brillante, come il bagliore di una piccola città venti chilometri più a valle?

Stai esaminando il problema fondamentale dell'astronomia. I tuoi occhi possono dire solo quanto un oggetto *sembra* brillante, ma non quanto lo è realmente in origine. Venere, per esempio, sembra l'oggetto più luminoso nel cielo notturno dopo la Luna, ma è solo perché è molto vicino. La stella Alpha Centauri, invece, sembra 100 volte più fioca di Venere, ma solo perché dista 40 000 miliardi di chilometri. Da vicino è più luminosa del nostro Sole.

Un telescopio ha lo stesso problema. Può misurare la luminosità *apparente* di una stella, ovvero quanto sembra brillante a noi qui sulla Terra, ma non la sua luminosità *reale*, ovvero quanta luce emette davvero. È la domanda che gli astronomi si pongono riguardo a ogni puntino di luce nel cielo: è fioco e vicino, o brillante e lontano?

Potresti domandarti: se questo è vero, come sappiamo che Alpha Centauri è a 40 000 miliardi di chilometri? La risposta è che gli astronomi sfruttano un metodo detto di "parallasse". Puoi intuire di cosa si tratta tramite il piccolo esperimento seguente: alza il dito indice, o magari un altro dito in caso tu ci stia maledicendo per tutta questa matematica, e mettilo a qualche centimetro dal naso. Guardalo tenendo chiuso prima l'occhio destro, poi l'occhio sinistro. Ripeti l'esperimento più volte. Dovresti notare che il dito sembra muoversi da un occhio all'altro: questo movimento apparente è detto parallasse.

Ecco ora lo schema da sfruttare: più lontano è il dito dal naso, meno sembrerà muoversi spostandoti da un occhio all'altro. Puoi descrivere lo schema in termini matematici, tramite un'equazione che lega il moto apparente del tuo dito, ovvero la parallasse, alla sua distanza dal tuo naso.

L'equazione dice che se la parallasse diminuisce, allora la distanza aumenta: $\text{distanza} = 1/\text{parallasse}$. Si può derivare per mezzo di calcoli trigonometrici, ma ti risparmierei i dettagli, perché il punto essenziale è che siamo di nuovo di fronte a un caso di “output = funzione di un input”, come la regola di predizione che collega la tua massima frequenza cardiaca alla tua età.

Gli astronomi misurano la distanza di stelle vicine per mezzo dello stesso metodo occhio destro/occhio sinistro. In particolare, usano due immagini al telescopio della stessa stella prese a distanza di sei mesi. Questo permette alla Terra di compiere metà orbita intorno al Sole, massimizzando la separazione tra gli “occhi” destro e sinistro degli astronomi. Confrontando queste due immagini, si misura la parallasse della stella, che viene poi inserita nell'equazione precedente per stimare la distanza della stella.

Il difetto maggiore del metodo parallasse/distanza è che, come righello cosmico, non ci permette di arrivare molto lontano. Se un oggetto è lontano più di 300 anni luce, la sua parallasse sarà troppo piccola per poter essere misurata accuratamente e 300 anni luce è una distanza piccolissima per gli standard di una galassia. Perfino all'inizio del Novecento, nel pieno delle accese discussioni sulle nebulose a spirale, tutti concordavano sul fatto che la Via Lattea si estendesse per almeno decine di migliaia di anni luce o anche di più. Dunque entrambe le fazioni riconoscevano che, a prescindere da chi avesse ragione, Andromeda era troppo distante per poter essere misurata usando la parallasse. Gli astronomi erano alla disperata ricerca di un modo migliore per misurare le distanze, ma non riuscivano a trovarlo.

Finché un'astronoma quasi sconosciuta, Henrietta Leavitt, fece una scoperta sensazionale. Leavitt trovò un nuovo metodo che consentì agli astronomi di misurare distanze fino a milioni di anni luce, più lontano di quanto avessero mai sognato. Non usò la trigonometria, con cui era stata scoperta la parallasse. Al contrario, usò i dati, applicando lo stesso principio che Google, Apple e Facebook oggi usano nei loro sistemi per riconoscere schemi ricorrenti.

La grande scoperta di Leavitt

Henrietta Leavitt diventò un'astronoma quasi per caso. Nata nel 1868 a Lancaster, Massachusetts, e cresciuta in una famiglia numerosa, iniziò a studiare discipline umanistiche al Radcliffe College nel 1888. Durante l'ultimo anno di studi decise di frequentare un corso di astronomia.

Fortunatamente per la scienza, le piacque talmente tanto che, dopo aver completato gli studi, decise di iniziare un dottorato e lavorare come volontaria all'Harvard College Observatory. Le sue straordinarie capacità attirarono subito l'attenzione del direttore dell'osservatorio, Edward C. Pickering, che le chiese di unirsi agli Harvard Computers, un gruppo di talenti matematici – tutte donne – dedito all'analisi dei dati provenienti dai telescopi. Molto prima che la parola “computer” denotasse un dispositivo, indicava una persona che faceva calcoli.⁵

Il compito principale di Leavitt era stimare e catalogare la luminosità delle stelle per l'enorme progetto di “scansione” della volta celeste intrapreso a Harvard: questo le richiedeva di confrontare le dimensioni di minuscoli puntini luminosi all'interno di migliaia di immagini d'archivio provenienti dai telescopi di tutto il mondo. Era un lavoro ripetitivo e faticoso: l'umanità non ha sempre avuto a disposizione algoritmi in grado di riconoscere schemi in modo automatico.

Ma c'era qualcosa che rendeva sopportabile questo compito ingrato: la ricerca di stelle pulsanti (*pulsar*). La luminosità di una pulsar varia nel tempo in maniera straordinariamente regolare: oscilla tra fioca e luminosa in continuazione, come un pendolo. (Vedi figura 2.2) Ora sappiamo che queste stelle pulsanti sono migliaia di volte più grandi del nostro Sole e che la loro luminosità varia perché le loro atmosfere stellari si espandono e si contraggono in continuazione, come i nostri polmoni durante l'atto respiratorio. Al tempo di Leavitt, però, si sapeva ben poco di queste strane stelle. Gli astronomi ne erano affascinati, e Leavitt aveva il preciso compito di tenere d'occhio tutte quelle che riusciva a scovare.

Per fare ciò, raccoglieva immagini di una singola stella scattate lungo un arco di molte notti. Le esaminava attentamente con una lente d'ingrandimento e un piccolo righello per cercare la prova rivelatrice di una pulsar: la periodica variazione in dimensioni del piccolo puntino luminoso. Lo fece immagine per immagine, stella per stella, per anni e anni, e finì col trovare 1777 pulsar ignote in precedenza.




Figura 2.2 Oscillazione della luminosità di una pulsar. Questa particolare stella completa un periodo, da luminosa a fioca a luminosa, ogni 5,4 giorni. Leavitt scoprì che il periodo di una pulsar è legato alla sua luminosità: le pulsar più luminose oscillano più lentamente di quelle fioche, in modo matematicamente predicibile.

Nel 1912 Leavitt rivolse la sua attenzione su un gruppo di venticinque pulsar all'interno della Piccola Nube di Magellano.^{*a} Poiché queste stelle facevano parte dello stesso gruppo, Leavitt ritenne ragionevole ipotizzare che si trovassero tutte alla stessa distanza dalla Terra. Dunque, se una stella *sembrava* più luminosa, voleva dire che *era* più luminosa alla sorgente. Annotò due tipi di dati per ogni stella. Il primo era il periodo di pulsazione, ovvero quanto tempo occorre alla stella per compiere un ciclo completo da luminosa a fioca a luminosa. Ogni stella aveva un periodo specifico, compreso tra 1,25 giorni e 127 giorni. Il secondo dato era la luminosità della stella, ovvero quanta luce emetteva in totale.

Leavitt mise su un grafico questi dati. Nella figura 2.3 abbiamo riprodotto quel grafico usando i suoi dati originali. Ogni punto rappresenta una delle venticinque pulsar. La coordinata orizzontale (X) rappresenta il periodo di pulsazione, mentre la coordinata verticale (Y) rappresenta la luminosità. Grafici come questo sono perfetti per rivelare regolarità nei dati e Leavitt vi trovò una correlazione straordinaria tra luminosità e periodo. I punti si trovavano quasi perfettamente lungo una linea retta. Le stelle più fioche avevano periodi misurabili in giorni, mentre le stelle più luminose avevano periodi misurabili in mesi. Era una regolarità così straordinaria da poter essere

descritta tramite un'equazione: una linea retta passante proprio in mezzo ai dati.

Si tratta di una delle rette più importanti nella storia della scienza. Per capire il perché, immagina di nuovo di trovarti su quella strada di campagna buia e di vedere una luce in lontananza ma di non sapere quanto sia lontana. Ora immagina che qualcuno ti dia un indizio, dicendoti quanto è luminosa la sorgente. Da questo indizio, puoi ricavare la distanza della luce: se ti dicono che si tratta di una singola lampadina da 60 watt, allora deve trovarsi nelle vicinanze, ma se ti dicono che è il bagliore di un'intera città, allora deve essere molto lontana. Il principio di base è: se puoi misurare la luminosità *apparente* di un oggetto e se qualcuno ti dice la sua *vera* luminosità – ovvero quanta luce emette in totale – allora puoi, usando le leggi della fisica, ricavare la distanza a cui si trova quell'oggetto. Questo processo all'indietro è matematicamente noioso ma concettualmente semplice. L'indizio indispensabile per rivelare la distanza è *la conoscenza della vera luminosità di un oggetto*.

La scoperta di Leavitt fornì agli astronomi proprio questo indizio. Essi potevano puntare i loro telescopi verso una pulsar e misurare sia la sua luminosità apparente sia il suo periodo. Poi potevano prendere il periodo, inserirlo nell'equazione della Leavitt e leggere la predizione corrispondente per la luminosità *reale*.^{*b} Questo forniva immediatamente la distanza della stella e dunque la distanza di *qualsiasi* altra stella nelle vicinanze. In gergo astronomico, Leavitt aveva scoperto che le pulsar sono “candele standard”: oggetti di luminosità nota, la cui distanza poteva essere misurata in modo affidabile. Nel gergo dell'IA, aveva scoperto una regola di predizione. La sua equazione era di nuovo, molto semplicemente, “output = funzione dell'input”.




Figura 2.3 Dati di Henrietta Leavitt del 1912 su venticinque pulsar. Questa relazione matematica – una linea retta che collega il periodo di oscillazione alla luminosità – permise agli astronomi di misurare distanze cosmiche su scale inimmaginabili in precedenza.

Leavitt pubblicò i suoi risultati nel 1912, in un lavoro di sole tre pagine. I colleghi riconobbero immediatamente che la sua scoperta forniva il tipo di “metro cosmico” che attendevano con impazienza, e lo misero all’opera appena gli strumenti lo permisero.

Il primo risultato importante venne da un astronomo di nome Harlow Shapley. Egli misurò il periodo di diverse pulsar all’interno della Via Lattea, applicò la legge di Leavitt per ricavare la loro luminosità reale, e utilizzò il risultato per calcolare la loro distanza. Queste stelle risultarono essere sorprendentemente lontane. I risultati di Shapley implicavano che la nostra galassia dovesse estendersi per almeno 100 000 anni luce – molto più di quanto chiunque potesse immaginare – e, rievocando le parole di Copernico, che il nostro Sole non fosse affatto vicino al centro della galassia.⁶

Ma il pezzo da novanta arrivò da un altro astronomo, destinato a diventare uno degli scienziati più famosi di tutti i tempi: Edwin Hubble.

Nel 1919, Hubble iniziò a lavorare al Mount Wilson Observatory a Pasadena, in California, giusto in tempo per l’inaugurazione del nuovo telescopio Hooker da 100 pollici. Con la regola di predizione di Leavitt bene in mente, iniziò a cercare pulsar nelle nebulose a spirale e, poiché aveva a

disposizione il più grande telescopio al mondo, aveva ottime probabilità di trovarle. Ogni pulsar sarebbe stata una candela standard da utilizzare per calcolare la distanza della spirale che la ospita.

Ci vollero anni, ma alla fine la ricerca attenta e paziente di Hubble diede i suoi frutti. Nell'ottobre del 1923 Hubble finalmente sperimentò il suo momento «Eureka!»: trovò una pulsar all'interno di Andromeda, quella «macchiolina sfocata» che aveva attirato l'attenzione di 'Abd al-Rahman al-Sfi più di mille anni prima e che confondeva gli astronomi. Misurò la luminosità apparente della stella e misurò il suo periodo in 31,4 giorni. Inserì questi valori nella regola di Leavitt per ottenere la luminosità reale e quindi usò i valori di entrambe le luminosità per calcolare la distanza di Andromeda.

Il risultato fu sconcertante. La Grande Nebulosa di Andromeda distava più di un milione di anni luce dalla Terra, ben al di fuori della Via Lattea. Andromeda era dunque *enorme*, in quanto è possibile vederla dalla Terra nonostante la grande distanza. Questo lasciava una sola possibilità: Andromeda doveva essere una galassia a parte. In un colpo solo, Hubble aveva risposto alla millenaria domanda sul nostro posto nel cosmo.

Hubble continuò a sfruttare le pulsar per scoprire molte più galassie o, per usare le sue parole, «interi mondi, ognuno di essi un universo a parte, sparsi per tutta la volta celeste... come i proverbiali granelli di sabbia su una spiaggia».⁷ Ma fu la prima pulsar che egli scoprì all'interno di Andromeda – oggi nota con il nome di Hubble Variable 1 o V1 – a passare alla storia. Molti anni dopo, nel 1990, quando lo space shuttle Discovery mise in orbita terrestre bassa il telescopio spaziale Hubble, portò con sé un oggetto dall'alto valore sentimentale: una copia della foto originale di V1 – fatta da Hubble nel 1923⁸ – che rese famoso il telescopio e cambiò per sempre il corso dell'astronomia. Ma era anche una foto il cui significato poteva essere apprezzato da Hubble solo grazie a Henrietta Leavitt, perché fu lei a mostrare a Hubble, e a tutti, come misurare le dimensioni dell'universo.

Adattare le regole di predizione ai dati

Torneremo a parlare di Henrietta Leavitt alla fine del capitolo. Per il momento teniamo a mente la sua grande scoperta e riprendiamo i due concetti chiave sul riconoscimento di schemi che abbiamo menzionato all'inizio del capitolo.

1. Nell'IA, uno "schema" è una regola di predizione che collega direttamente un input a un output.
2. "Apprendere uno schema" vuol dire ricavare una buona regola di predizione da un insieme di dati.

Speriamo che le pulsar di Henrietta Leavitt ti abbiano convinto di quanto sia preziosa una buona regola di predizione. Ma probabilmente ora ti starai facendo delle domande. Per esempio, cosa rende una regola migliore di un'altra? E com'è possibile che un oggetto dall'immaginazione così limitata, come un computer, sia in grado di trovare la giusta regola di predizione?

Nell'IA il criterio per valutare una regola di predizione è semplice: quanto è grande l'errore commesso in media da quella regola? Nessuna regola può essere perfetta e collegare in modo infallibile ogni input con l'output corretto: tutte le regole commettono errori. Più piccolo sarà l'errore medio, migliore sarà la regola.

Per capire meglio, torniamo sulla regola di predizione di Henrietta Leavitt per le pulsar. Nella parte sinistra della figura 2.4 sono riportati i dati di Leavitt insieme alla sua equazione originale: la linea retta che collega la luminosità di una pulsar al suo periodo. La scala di luminosità è quella in uso presso gli astronomi, chiamata "magnitudo". Per ragioni storiche, gli astronomi assegnano punteggi in modo simile al golf: numeri piccoli indicano stelle più brillanti.

Concentriamoci sulla stella evidenziata con una freccia, che ha un periodo di un paio di giorni. Possiamo misurare l'errore commesso dalla regola di Leavitt calcolando la distanza verticale tra il punto e la retta: questa distanza è detta "residuo" o "errore di ricostruzione". Per la stella in questione, la regola predice una magnitudo stellare di 16,1, mentre in realtà è di 15,6: un errore di ricostruzione di 0,5 unità.

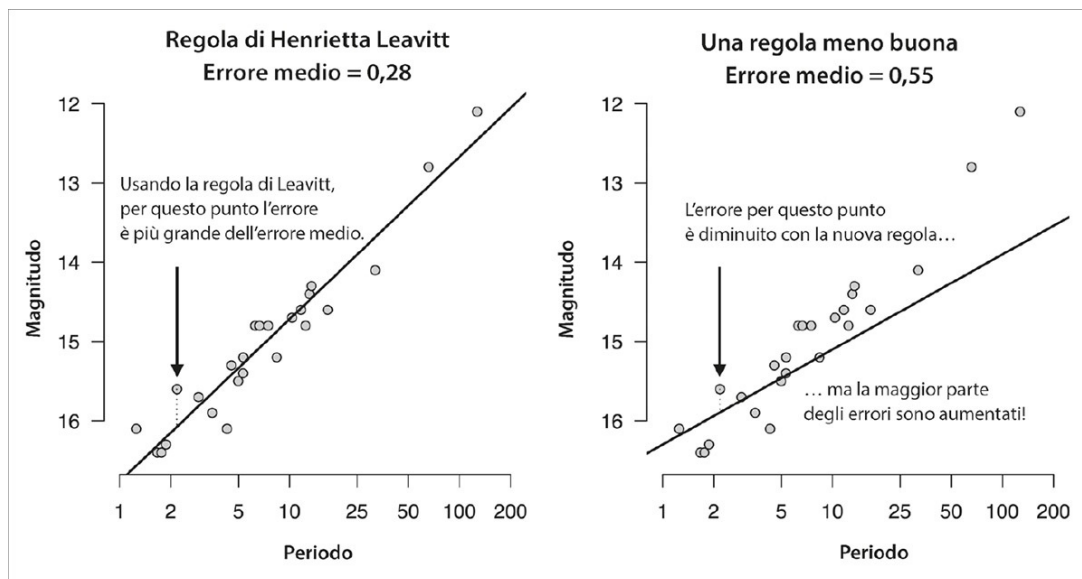


Figura 2.4 Confronto tra l'equazione originale di Leavitt (sinistra) e un'equazione modificata che non descrive i dati altrettanto bene.

Consideriamo ora una regola leggermente diversa, come quella riportata nel lato destro della figura 2.4. In questo caso abbiamo inclinato la retta di Leavitt, rendendola meno ripida. Per la stella in questione, l'errore è effettivamente diminuito. Ma, per la maggior parte delle altre stelle, l'errore è aumentato. La regola di Leavitt è dunque migliore della nostra: in media, è più accurata quasi per un fattore due.

In effetti, la regola di predizione di Leavitt è la migliore: tra tutte le linee rette, è quella con il più piccolo errore di ricostruzione medio. Puoi modificare la retta come vuoi: alcuni errori diminuiranno, ma le tue modifiche, come la nostra nella parte destra della figura, faranno aumentare l'errore medio. Possiamo dirlo con certezza perché Leavitt applicò un procedimento matematico chiamato “principio dei minimi quadrati” per adattare la sua regola ai dati. Introdotto dal matematico francese Adrien-Marie Legendre nel 1805, questo principio fornisce una formula esplicita per trovare la retta “ottimale” che descrive un insieme di dati, ovvero la retta che restituisce il minore errore di ricostruzione medio possibile.^{*c} Gli scienziati usano estensivamente questa formula sin da allora.⁹ In più, lo stesso principio chiave che Legendre formulò più di due secoli fa è in uso ancora oggi per costruire alcuni dei più sofisticati sistemi di intelligenza artificiale. Le regole di predizione in IA sono solo versioni più ricercate della regola di Leavitt: si tratta di equazioni che collegano output a input, e sono scelte in modo da

minimizzare l'errore medio di ricostruzione all'interno di un insieme di dati, proprio come suggerito da Legendre più di duecento anni fa.^{*d}

Prima di discutere l'idea in dettaglio, faremo tre esempi veloci che riguardano il tuo cellulare. Per prima cosa, prendiamo il software di riconoscimento di immagini, quello che identifica i tuoi amici nelle foto che carichi su Facebook. Il riconoscimento di immagini non è altro che una regola di predizione: l'input è l'immagine del volto di una persona e l'output è l'identità di quella persona. Il collegamento tra input e output è un'equazione complicata che descrive uno schema complicato ricavato dai dati utilizzati come allenamento: quali caratteristiche facciali tendono a corrispondere a quali nomi nelle foto precedentemente caricate.

Come secondo esempio, consideriamo Google Translate. Anche questa non è altro che una regola di predizione: collega frasi in ingresso in una determinata lingua (per esempio, l'inglese) a frasi in uscita in un'altra lingua (per esempio, lo spagnolo). Il modello sottostante è, di nuovo, un'equazione complicata che descrive uno schema complicato: quali frasi in inglese tendono a essere associate a quali frasi in spagnolo all'interno di un enorme database di frasi messe l'una accanto all'altra in entrambe le lingue.

Infine, consideriamo una nuova app per smartphone sviluppata dalla dottoressa Elna Berglund Scherwitzl, un fisico svedese che ha contribuito alla scoperta del bosone di Higgs e che ora sta perseguendo una seconda carriera da imprenditrice, avendo inventato una nuova tecnologia di contraccezione basata sull'IA. Berglund Scherwitzl ha a lungo cercato un'alternativa alla contraccezione ormonale, senza mai riuscire a trovare un metodo che la soddisfacesse. Nel problema intravide un'opportunità da sfruttare. Lei e il marito, Raoul Scherwitzl, lasciarono il loro lavoro come fisici e usarono le competenze acquisite in scienza dei dati per sviluppare una nuova versione di una vecchia idea: il "metodo del ritmo naturale", che sfrutta lo storico dei periodi mestruali precedenti per predire l'ovulazione.

Il problema con il metodo tradizionale è che, per usarlo con successo, bisogna essere eccezionalmente meticolosi nel registrare i dati. La versione di Berglund Scherwitzl si basa su qualcosa di più affidabile: la temperatura corporea, il cui ciclo mensile è fortemente correlato alla fertilità. Per usare il metodo, devi inserire due informazioni in un'app chiamata Natural Cycles: la tua temperatura corporea giornaliera e la data delle ultime mestruazioni. Col passare del tempo e con l'accumularsi dei dati di allenamento, la app stabilisce una regola di predizione appositamente concepita per il tuo ciclo.

L'input è la tua temperatura corporea, mentre l'output è una predizione sulla tua fertilità in quel giorno, sotto forma di un piccolo semaforo sullo smartphone. (Verde vuol dire via libera.) Le app che aiutano a monitorare il ciclo mestruale sono molto popolari, ma questa è la prima ad aver ottenuto la certificazione di metodo contraccettivo efficace da parte dell'Unione Europea. Nei trial clinici, la app si è dimostrata efficace più o meno quanto la pillola contraccettiva nell'evitare gravidanze indesiderate in condizioni d'uso normali.*e A metà del 2017, più di 300 000 utenti usano l'intelligenza artificiale per le loro scelte in ambito riproduttivo.

Oltre le linee rette

A questo punto, dovrete porti un'altra domanda. Abbiamo spiegato che, nell'IA, riconoscere uno schema vuol dire adattare una retta su un insieme di dati. E abbiamo anche spiegato che questa idea risale al 1805. Che cosa ha permesso dunque la rivoluzione in atto in questi anni? Perché tutti questi sistemi di riconoscimento di schemi, dall'identificazione facciale, alla traduzione automatica, al controllo delle nascite basato sull'IA, sono comparsi solo recentemente?

Ecco il perché: gli schemi da rintracciare in enormi database di immagini, testi e video sono terribilmente più complessi di qualsiasi schema visualizzabile all'interno di un grafico a dispersione, come quello di Henrietta Leavitt sulle pulsar. E schemi complicati devono essere descritti per mezzo di equazioni complicate, molto più complicate dell'equazione di una linea retta. E tali equazioni sono molto esigenti: come illustreremo, c'è bisogno di una grande potenza di calcolo e di una grande massa di dati per stimarle in modo affidabile. Solo in tempi recenti la nostra tecnologia ha reso tutto ciò possibile ed economico.

Il grande passo avanti per l'IA è stato determinato dall'uso di *reti neurali* per stimare le regole di predizione a partire dai dati. L'espressione "rete neurale" suona orribilmente cervellotica, ma non è altro che una geniale trovata di marketing. In realtà, una rete neurale è semplicemente un'equazione molto complessa in grado di descrivere schemi molto complessi all'interno di insiemi di dati, in altre parole un insieme di collegamenti intricati tra input e output. Usiamo le reti neurali non perché simulano il funzionamento del cervello umano, ma perché funzionano incredibilmente

bene nel predire schemi in ambiti totalmente diversi, dal linguaggio alle immagini ai video.

Diamo uno sguardo più da vicino ai quattro fattori che hanno determinato l'esplosione dell'IA.

Fattore 1: modelli enormi

In passato costruivamo regole di predizione per descrivere semplici schemi usando modelli di dimensioni ridotte, in pratica estraendo informazioni con gli equivalenti di picconi e vanghe. Oggi descriviamo schemi complicatissimi usando modelli enormi, più simili a quei camion giganti con ruote delle dimensioni di una piccola casa. È lo stesso concetto, ma sono cambiati i mezzi a disposizione.

Per capire cosa intendiamo con modelli “enormi”, bisogna introdurre il concetto di *parametro*. Un parametro è un numero nella tua equazione che sei libero di scegliere in modo tale da descrivere al meglio i tuoi dati. Modelli piccoli hanno pochi parametri liberi, mentre modelli enormi hanno moltissimi parametri. Torniamo, per esempio, a questa equazione che hai già incontrato: massima frequenza cardiaca = $220 - \text{età}$. Questo è un modello piccolo, perché l'equazione ha solo un parametro: il valore di partenza 220, a cui devi sottrarre la tua età. Avremmo potuto scegliere 210 o 230 o qualsiasi altro numero, ma la scelta di 220 descrive meglio i dati.

C'è però un modello leggermente più grande che funziona ancora meglio: massima frequenza cardiaca = $208 - 0,7 \times \text{età}$. Ovvero, moltiplica la tua età per 0,7 e sottrai il risultato a 208 per predire la tua massima frequenza cardiaca. La regola precedente aveva solo un parametro, mentre questa nuova regola ne ha due: il valore iniziale 208 e il “moltiplicatore per l'età” 0,7, entrambi regolabili in modo da descrivere meglio i dati. Puoi vedere entrambi i modelli nella figura 2.5, che mostra un grafico di dispersione contenente la misura della frequenza cardiaca di 151 adulti. Il grafico mostra la predizione “ $220 - \text{età}$ ” in grigio e la nuova regola “ $208 - 0,7 \times \text{età}$ ” in nero. Gli scienziati preferiscono la retta nera: avendo due parametri liberi piuttosto che uno, offre più libertà di adattare nel migliore modo possibile l'equazione ai dati.^{*f} Alcuni utilizzano ancora la vecchia regola “sottrai la tua età a 220” perché è più semplice, un parametro al posto di due. Ma la semplicità ha un prezzo da pagare: la predizione sulla massima frequenza cardiaca non sarà accurata come quella del modello a due parametri, almeno in media.




Figura 2.5 Due equazioni per predire la massima frequenza cardiaca a partire dall'età. La retta nera ha un solo parametro; la retta grigia ha due parametri e descrive meglio i dati.

Vediamo ora come è fatta una predizione a *tre* parametri. Supponi di essere un analista dati dell'agenzia immobiliare online Zillow e che tu debba trovare un'equazione per stabilire il prezzo di una casa. Potresti iniziare prendendo in considerazione due caratteristiche essenziali di una casa, come la metratura e il numero di bagni, moltiplicando ciascuna per un fattore. Per esempio,

$$\text{prezzo} = 10\,000 + 125 \times (\text{metri quadrati}) + 26\,000 \times (\text{numero di bagni})$$

Detto altrimenti, per predire il prezzo di una casa devi compiere tre passaggi:

1. Moltiplica la metratura della casa per 125 (parametro 1).
2. Moltiplica il numero di bagni per 26 000 (parametro 2).
3. Aggiungi 10 000 (parametro 3) alla somma di 1 e 2. Questo fornisce il prezzo totale.

Ma perché fermarsi a soli due moltiplicatori? Le case hanno molte altre caratteristiche che ne influenzano il prezzo, per esempio la grandezza del giardino, le condizioni del tetto, il numero di caminetti. Usando il principio

dei minimi quadrati che Legendre introdusse nel 1805, gli analisti possono facilmente costruire un'equazione che incorpora tutte queste caratteristiche, e anche altre centinaia. Questo è, in soldoni, il metodo di Zillow per stabilire il prezzo di una casa. Ogni caratteristica ha il suo fattore moltiplicativo e le caratteristiche più importanti hanno fattori più grandi, poiché i dati mostrano che esse hanno un impatto maggiore sul prezzo finale. Ovviamente, se provi a tradurre questa regola in parole – «somma questo», «moltiplica quello», come abbiamo fatto per la regola a due caratteristiche – somiglierà da vicino a un infernale modulo dell'agenzia dell'entrate. Ma un computer digerisce qualsiasi calcolo senza batter ciglio, anche nel caso di modelli con centinaia di parametri.

Nell'IA, tuttavia, sogniamo in grande e concepiamo modelli con un numero di parametri *molto* più grande di qualche centinaio. Prendi, per esempio, un modello per classificare le immagini. Per una macchina, un'immagine sono semplici pixel e i pixel sono semplici numeri: intensità di colore da 0% a 100%. Un'immagine non compressa da un megapixel, per esempio, contiene tre milioni di numeri: un'intensità di rosso, verde e blu per ognuno dei pixel (un milione in totale): ecco dunque un esempio con tre milioni di caratteristiche. E ci vogliono parecchi parametri per fare buon uso di tre milioni di caratteristiche, specialmente se vuoi combinare quelle caratteristiche in modi interessanti, anziché moltiplicarli per un singolo fattore, come abbiamo fatto nel modello immaginario riguardante Zillow.*g

Qui entrano in gioco le reti neurali. Nel 2014, per esempio, gli ingegneri di Google hanno pubblicato un lavoro su un modello di rete neurale, soprannominato "Inception", come il film con Leonardo DiCaprio, in grado di riconoscere e catalogare automaticamente un'immagine. Ed era incredibilmente efficace. I vecchi modelli di riconoscimento di immagini erano in grado di dire se un'immagine conteneva un cane oppure no; Inception poteva dire se il cane era un Siberian Husky o un Alaskan Malamute. Il modello conteneva 388.736 parametri, e per tirare fuori una predizione erano necessarie 1,5 miliardi di operazioni aritmetiche – 1,5 miliardi di «somma questo» e «moltiplica quello» – per ogni singola immagine in input. È un modulo dell'agenzia delle entrate decisamente lungo. È bene, dunque, che una scheda grafica Nvidia riesca a effettuare 1,5 miliardi di operazioni in meno di 0,0001 secondi.

Fattore 2: insieme enormi di dati

Ma c'è una controindicazione: se hai un modello enorme, hai bisogno di un enorme insieme di dati.

Un modello come Inception di Google, con 388 736 parametri, fa venire il mal di testa a scienziati e ingegneri della vecchia guardia, che guardano tali mostri con disprezzo. Il grande matematico John von Neumann, per esempio, un giorno liquidò un modello complicato dicendo: «Con quattro parametri posso descrivere un elefante, e con cinque posso fargli muovere la proboscide». Von Neumann voleva dire che un modello con molti parametri va incontro al rischio di essere “eccessivamente adattato”, ovvero di memorizzare il rumore casuale presente nei dati di allenamento senza riconoscere lo schema sottostante. Un modello del genere è in grado di descrivere perfettamente il passato ma può fallire nel predire il futuro.

Se vuoi capire il concetto di adattamento eccessivo, dai un'occhiata a quei sapientoni pagati dalle TV per tirare fuori assurde perle di “saggezza” sulle elezioni presidenziali, per esempio: «Nessun democratico in carica senza esperienze di guerra ha mai sconfitto qualcuno il cui nome valesse più del suo a Scarabeo». Questa regola in effetti *ha funzionato* per 208 anni di storia americana, fino a quando Bill Clinton non ha sconfitto Bob Dole nel 1996.^{[*h](#)} Ma non ha mai avuto alcun potere predittivo. Si tratta di un esempio classico di adattamento eccessivo: setacciare retrospettivamente migliaia di dettagli sulle elezioni passate e scegliere con cura *quel* dettaglio isolato che si è realmente verificato.

Ma quindi, nell'adattare una regola di predizione ai dati, come si può evitare questo effetto indesiderato? Ci sono solo due modi. Per prima cosa, rifiutando le spiegazioni troppo involute. Il tuo modello non potrà conservare memoria di fatti complicati e non generalizzabili del passato se gli imponi di ignorare *tutti* i fatti eccetto i più semplici. Questa soluzione funziona bene per le scienze dure. In effetti, è quello che proponeva von Neumann quando suggeriva di «descrivere un elefante»: a lui interessava trovare teorie semplici in grado di spiegare le leggi fisiche universali per la materia e l'energia piuttosto che fenomeni terrestri contingenti come gli elefanti e le loro proboscidi oscillanti. Ma l'approccio “ignora le teorie complicate” non funziona assolutamente con l'IA. Gli schemi che vogliamo trovare all'interno dei dati – per esempio, quale combinazione di pixel può essere etichettata “Husky” e quale può essere etichettata “Malamute” – sono *davvero* terrestri, singoli e complicati. Piccoli modelli con due, tre o persino duemila o

tremila parametri non sono assolutamente in grado di descrivere questi schemi in modo accurato.^{*i}

Questo ci costringe a ricorrere alla seconda strategia: raccogliere un numero enorme di dati. Molti dati vuol dire molta esperienza e con molta esperienza puoi escludere le spiegazioni complicate *errate*, lasciando spazio alle spiegazioni complicate *giuste*. Questa soluzione non funziona per le elezioni presidenziali: ce ne sono state solo cinquantasei e dunque non c'è modo di stabilire, a partire dai soli dati, se una complicata spiegazione a posteriori del risultato di un'elezione abbia valore predittivo per il futuro. Ma funziona molto bene per modelli che estraggono schemi da immagini, testi e video, di cui disponiamo in abbondanza.

John von Neumann sarebbe certamente sorpreso dal risultato. Pensava di poter descrivere un elefante con soli quattro parametri, ma in realtà ce ne vogliono 388 736 o almeno questo è il numero di parametri di cui hai bisogno per *identificare* un elefante tra le foto del tuo safari africano. Non si tratta di magia, ma semplicemente di insiemi enormi, con milioni o miliardi di dati. Questo ci permette di usare modelli complicati per descrivere schemi complicati, senza il rischio di adattamento eccessivo. Per essere onesti nei confronti di von Neumann, egli sicuramente non avrebbe mai potuto immaginare un mondo dove le persone caricano 100 milioni di immagini al giorno su Instagram, molte delle quali con utili tag del tipo #safari o #elefante.

Fattore 3: provare e riprovare, un milione di volte al secondo

All'inizio del Novecento, Henrietta Leavitt ricavò la sua regola di predizione usando carta e penna, applicando la formula di Legendre del 1805 per ricavare le rette ottimali. Fino all'inizio di questo secolo, gran parte degli scienziati faceva ancora uso della stessa formula, con leggere variazioni. L'unica differenza era che potevano prendersela comoda, facendo fare i calcoli a un computer.

Ma non esiste una formula matematica per le regole di predizione odierne. In realtà c'è solo un modo per mettere a punto un modello enorme come Inception, ed è procedere per tentativi, errore dopo errore. Inizi provando una regola di predizione, per esempio identificando come elefanti ciondolanti nella savana tutte quelle figure grigie su sfondo verde. Questa regola iniziale sarà quasi sicuramente sbagliata. Con l'arrivo di nuovi dati, provi a

perfezionare la tua regola. Per ogni nuovo dato, ti poni due domande: quanto sbaglia il mio modello attuale su questo dato e come posso modificare il modello in modo che il mio errore sia più piccolo? I moderni computer possono farsi queste due domande e risponderci migliaia o anche milioni di volte al secondo. Sottoponendo il tuo enorme insieme di dati a questo incessante assalto computazionale, non ti ci vorrà molto a migliorare in modo drastico la tua regola di predizione, per esempio apprendendo che *alcune* figure grigie su sfondo verde sono elefanti, mentre altre sono rinoceronti.

Oggi questa strategia di definizione di modelli per tentativi viene utilizzata ovunque. È ciò che permette a grandi aziende, per esempio, di predire cosa potresti voler comprare online, anche prima che tu stesso lo sappia. Prendi Alibaba, il gigante cinese dell'e-commerce con entrate per ventiquattro miliardi di dollari nel 2017. Come Amazon, Alibaba promette di consegnarti gli acquisti velocemente, così velocemente che non potrebbe mai farlo spedendo tutto dalla sede centrale. Ma gli analisti dei dati di Cainiao, il supporto logistico di Alibaba, sono maestri dell'IA e predicono esattamente cosa vorranno gli utenti nei prossimi giorni e nelle prossime settimane, in modo che l'azienda possa spedire il giusto prodotto nel giusto centro di distribuzione prima ancora che qualcuno clicchi su "Compra". In più, devono farlo per ogni prodotto che Alibaba vende e per ogni mercato servito, che sia questa periferia di Shanghai o quel quartiere di Canton. E fanno tutto questo procedendo per tentativi: usando enormi insiemi di dati per allenare modelli enormi che diventano sempre più efficaci a ogni nuovo acquisto.

Nel business dell'IA, questo processo di miglioramento di un modello per tentativi successivi è noto con diversi nomi, come "apprendimento online" e "discesa stocastica del gradiente". Stiamo omettendo un bel po' di dettagli essenziali per rendere efficiente la strategia, ma sono solo minuzie, quel genere di cose che si impara durante un dottorato in IA. Se hai capito la strategia del "prova e riprova", hai già fatto il 90% della strada.

Fattore 4: deep learning

Oltre al livello di dettaglio dei nostri modelli, alla dimensione dei nostri insiemi di dati e alla velocità dei nostri computer, c'è una quarta caratteristica grazie alla quale la nostra capacità di fornire regole di predizione è migliorata moltissimo: abbiamo imparato come estrarre informazioni utili da input

enormemente più complicati. Se hai mai sentito l'espressione deep learning e ti sei chiesto cosa significasse, stiamo per spiegarlo.

Abbiamo detto all'inizio del capitolo che, per un computer, il tipo di dati in ingresso non è rilevante. Ma è vero solo in parte. Henry Ford è famoso per aver detto che i clienti della Ford Motor Company potevano acquistare una macchina di qualsiasi colore, a patto che quel colore fosse il nero. Per i computer è lo stesso: puoi fornire loro qualsiasi input, a patto che sia un numero. La parte più difficile in quasi tutte le applicazioni dell'IA non è allenare il modello ma rispondere alla domanda: come metto in forma di numeri l'input per il mio modello? Gli analisti la chiamano "ingegneria delle caratteristiche", ovvero estrarre caratteristiche numeriche da un input che non è un numero, come un'immagine o una stringa di parole in inglese.

Nell'ultimo decennio, gli esperti di IA hanno fatto passi da gigante nell'ingegneria delle caratteristiche, usando uno specifico tipo di regola di predizione chiamata *deep neural network*. Hai imparato in precedenza che una rete neurale è solo un'equazione complicata con molti parametri. Una deep neural network è una variazione sul tema, in cui l'equazione è strutturata in modo tale da estrarre più informazione possibile da un input specifico.

Prendi le immagini. In questo caso, le deep neural network risolvono una sfida concettuale dell'ingegneria delle caratteristiche: molte diverse disposizioni dei pixel di un'immagine possono rappresentare lo stesso oggetto. Rotazioni, traslazioni, cambi di colore, tutte queste cose possono cambiare drasticamente i pixel di un'immagine senza però cambiarne il contenuto. Il simbolo di un cuore rosso, per esempio, mantiene lo stesso significato sia che tu lo metta a sinistra o a destra di un'immagine, oppure che tu lo ruoti di qualche grado. Mantiene lo stesso significato anche se lo cambi di colore, come nella famosa canzone country di Joe Diffie del 1990, in cui un giovane contadino di nome Billy Bob si arrampica sul serbatoio cittadino per dipingere un cuore alto tre metri con un messaggio per la sua amata, Charlene, usando l'unico colore a sua disposizione: il verde dei trattori John Deere.¹⁰ Charlene è in grado di capire che un cuore è un cuore, che sia colorato di rosso o di un altro colore più agricolo. Ma un computer che è stato programmato per interpretare alla lettera i pixel può facilmente entrare in confusione. Ecco perché abbiamo bisogno dell'ingegneria delle caratteristiche: per convertire pixel grezzi in caratteristiche utili e generalizzabili di un'immagine.

Le deep neural network risolvono il problema in modo molto efficace. Per illustrarlo, tornerò sull'esempio di Henrietta Leavitt, della sua ricerca di pulsar e della successiva scoperta che le pulsar possono essere usate per misurare la distanza di remote regioni dell'universo. Rinfreschiamoci la memoria sul lavoro di Leavitt. La scienziata doveva tenere traccia di una singola stella all'interno di diverse fotografie. Doveva misurare la luminosità della stella in ogni fotografia per controllare se aumentasse o diminuisse alla maniera di una pulsar. Se lo faceva, doveva calcolare il periodo, ovvero quanto tempo impiegava per completare una pulsazione.

Nel fare tutto ciò, Leavitt ricorreva ad almeno cinque concetti visivi, ognuno a un livello maggiore di astrazione rispetto al precedente.

Livello 1: le parti luminose della foto rappresentano luce proveniente dal cielo.

Livello 2: una stella è un puntino luminoso circondato dal buio.

Livello 3: la luminosità di una stella è data dalla dimensione e dall'intensità del puntino.

Livello 4: una pulsar è una stella la cui luminosità varia in modo regolare su un insieme di foto.

Livello 5: il periodo di una pulsar è l'intervallo di tempo che essa impiega per passare da luminosa a fioca a luminosa.

Questo è un esempio di ingegneria delle caratteristiche. Se segui la gerarchia da 1 a 5, spunta fuori un numero: il periodo di una pulsar, che in seguito utilizzerai come input nella tua regola di predizione. (Ricorda che la regola di Leavitt per le pulsar aveva il periodo come input e la luminosità reale come output.)

Possiamo dire che Leavitt usava una deep neural network a cinque livelli: applicava una serie di concetti visivi, disposti in una gerarchia a cinque livelli, per estrarre una caratteristica utile da un'immagine. E questo è esattamente ciò che fa una deep neural network.^{*1} Ogni nuovo livello gerarchico attinge dai concetti dei livelli precedenti, proprio come, in questo caso, il concetto di pulsar del livello 4 è definito in termini di un concetto (stella) del livello 2 e di uno (luminosità) del livello 3. Al livello massimo della gerarchia si trova una caratteristica – il periodo – che può essere usata come input per la regola di predizione.

Leavitt sapeva come applicare questa gerarchia di concetti visivi grazie alla sua formazione di astronoma. Ma nel corso dell'ultimo decennio, gli esperti di

IA hanno scoperto di poter insegnare ai computer come estrarre tali gerarchie concettuali direttamente dalle immagini di partenza e questo approccio è di solito molto più efficace rispetto a programmare gli stessi computer in un dominio ben specifico, che si tratti di astronomia o di cetrioli.

Questo intero approccio è chiamato deep learning e fino a poco tempo fa suscitava solo la curiosità degli accademici. Ora non è più così: in alcuni compiti, nell'identificazione di immagini, le deep neural network sbaragliano gli umani. Gli esperti di IA usano un insieme di dati chiamato ImageNet Visual Recognition Challenge per testare i loro modelli. ImageNet è un database online con milioni di foto di un migliaio di categorie diverse, come “barca a vela” e “Alaskan Malamute”, e l'obiettivo è allenare un modello a identificare automaticamente le immagini. Gli umani compiono un errore medio pari a circa il 5% in questo compito, mentre nel 2011 per i migliori modelli di IA l'errore era del 25%. Tuttavia, nel 2014 Inception di Google ha portato il record mondiale per l'errore medio di una macchina a 6,7%. Inception era una rete neurale a ventidue livelli, ognuno di essi corrispondente a una maggiore astrazione: da concetti come “cerchio” e “confine” al livello più basso, fino a concetti come “barca a vela” o “Malamute” al livello più alto, tutti appresi in modo naturale dai dati. E, nel 2016, modelli successivi hanno raggiunto livelli di errore inferiori al 3%: *meglio di un essere umano medio*.

I potenziali benefici...

Il deep learning rappresenta una vera e propria rivoluzione nella competenza visiva delle macchine, e i concetti chiave e le tecnologie si stanno diffondendo ovunque. I limiti erano un tempo la disponibilità di dati, la velocità dei computer e la dimensione dei modelli. Oggi sembra esserci un solo limite ed è l'immaginazione delle persone:

- Un apicoltore svedese, Björn Lagerman, sta cercando di salvare le api da miele per mezzo di un modello di deep learning allenato con 40 000 immagini di colonie di api, in grado di avvertire gli apicoltori della presenza dell'acaro Varroa, il peggior nemico delle api occidentali.¹¹
- Mark Johnson e la sua startup, Descartes Labs, hanno allenato deep neural network su quattro petabyte di immagini da satellite, insieme a resoconti sui raccolti stilati dal Dipartimento dell'agricoltura statunitense (USDA), per predire la produzione di grano. Queste predizioni sono cruciali per gli innumerevoli intermediari della filiera agricola, dai proprietari dei silos di

grano ai produttori di etanolo. Dal 2014, Descartes ha regolarmente predetto in modo corretto i successivi report dell'USDA.¹²

- I produttori di elettricità stanno allenando modelli che utilizzano dati meteorologici per predire la richiesta di elettricità a livello di rete. In Inghilterra, queste informazioni vengono combinate con dati satellitari per predire la potenza prodotta da fonti rinnovabili, come il solare e l'eolico. La National Grid stima che questo tipo di modelli deep learning potrebbe ridurre del 10% la bolletta dell'elettricità inglese, semplicemente bilanciando in modo più efficace domanda e offerta.¹³

E poi c'è lo studio pubblicato recentemente dal Geena Davis Institute on Gender in Media. I ricercatori di questo istituto hanno iniziato a prendere dati nel 2007 sul modo in cui gli uomini e le donne sono descritti nei film. Inizialmente facevano l'analisi dati a mano, guardando migliaia di ore di film e cercando schemi ripetitivi scena dopo scena. Ma poco tempo fa hanno unito le forze con Google al fine di automatizzare questo compito, usando le deep neural network per classificare le immagini. Hanno usato una versione aggiornata del modello Inception per analizzare i 100 film hollywoodiani con incasso più alto nel corso degli anni. Il modello classificava automaticamente il genere di ogni persona in scena e dell'attore che aveva la parola in quel momento.

I risultati sono stati sorprendenti. C'è una sola tipologia di film in cui le donne sono in scena per più tempo rispetto agli uomini: l'horror, dove di solito sono vittime. In qualsiasi altra tipologia di film, le donne sono sottorappresentate. In media, sono in scena per il 36% del tempo e parlano per il 35% del tempo e, nei film nominati agli Oscar, parlano solo per il 27% del tempo. Questi risultati illustrano come l'IA può aiutare a discutere in modo informato a proposito di stereotipi di genere e di pregiudizi inconsci.¹⁴

... e le minacce alla privacy

Dopo aver evidenziato i molti potenziali benefici dei nuovi algoritmi di riconoscimento di schemi, è altrettanto importante riconoscere le preoccupazioni riguardo alla privacy che essi sollevano. La stessa tecnologia di deep learning usata per identificare i pregiudizi di genere nei film hollywoodiani può essere utilizzata dalla polizia, per esempio, per monitorare le riprese delle telecamere a circuito chiuso nei luoghi pubblici. Con abbastanza videocamere e abbastanza dati di allenamento, non ci sono motivi

tecnologici che impediscano di programmare un sistema di IA in modo da seguire una singola persona passo dopo passo all'interno di una grande città. Va detto che la polizia cerca da sempre di tenere sotto controllo i sospetti criminali, aprendo la loro corrispondenza con il vapore, mettendo i loro telefoni sotto sorveglianza o monitorando i tabulati dei telefoni cellulari. Ciò che è cambiato, nell'era dell'IA, è che ora c'è la possibilità teorica di sorvegliare *chiunque*, qualcosa di logisticamente impossibile da fare con la sola intelligenza umana, anche mettendo da parte le questioni legali. E il potenziale abuso che da ciò deriva non si ferma al caso della polizia. Un'azienda privata con accesso a tutte quelle riprese video potrebbe usarle per costruire un database eccezionalmente dettagliato delle cose che guardiamo e del tempo che passiamo a guardarle, oppure un funzionario governativo potrebbe usarle per cercare retrospettivamente particolari imbarazzanti da usare per ricattare o intimidire qualcuno, come un giornalista o un avversario politico, per esempio.

Se approfondirai ancora le tematiche dell'IA, incontrerai due narrazioni sovrapposte del problema della sorveglianza. La versione meno estrema è più o meno questa. La tecnologia di riconoscimento facciale è immensamente potente e ha bisogno di norme stilate con attenzione, allo stesso modo in cui elaboriamo regole per altre tecnologie dal potenziale nocivo. Siamo totalmente d'accordo con questo punto di vista. C'è un'enorme discrepanza tra la nostra tecnologia basata sull'IA e le nostre leggi, e la società doveva farsi carico del problema già ieri, non può rinviarlo a domani. Abbiamo bisogno di norme intelligenti, scritte da persone che capiscono quello che stanno tentando di regolamentare, tenendo in considerazione sia i benefici che i potenziali pericoli.

La narrazione più estrema sostiene che, in modo connaturato e inevitabile, c'è qualcosa di autocratico nelle capacità di sorveglianza della moderna IA. Ammettiamo di non essere esperti di sociologia della tecnologia, ma dobbiamo ancora vedere prove credibili di questa affermazione. La Gestapo certamente non aveva bisogno di IA per perfezionare la propria arte dello spionaggio e, se è per questo, neppure l'FBI negli anni cinquanta, quando prendeva di mira le organizzazioni per i diritti civili. In più, da un punto di vista globale, non c'è un'evidente correlazione tra l'investimento di un paese in tecnologia digitale e il suo rispetto per i diritti umani. In Scandinavia, per esempio, ci sono sia le leggi sulla privacy più rigide del mondo sia l'economia digitale più sviluppata. (Se pensate di pagare in contanti un caffè a

Stoccolma, in bocca al lupo.) Questo complica qualsiasi sforzo per ricavare un collegamento semplicistico tra la tecnologia dell'IA e la tirannia.

Perciò, politici e uomini di legge, al lavoro. Le paure per la privacy sono ben fondate, ma siamo ottimisti sul fatto che si possano eliminare.

Post scriptum

Chiuderemo il capitolo con un'ultima storiella sugli stereotipi, particolarmente rilevante in un mondo in cui solo il 17% dei laureati in informatica nelle università americane è donna e tale percentuale è in costante diminuzione da decenni.

Ricorderai che Edwin Hubble sfruttò la regola di predizione di Henrietta Leavitt per le pulsar – le candele standard dell'universo – per mostrare con certezza che la Via Lattea non è l'unica galassia esistente. Nel fare ciò, egli rispose a un quesito su cui gli astronomi discutevano da secoli. Quando annunciò la scoperta al mondo, Hubble diventò istantaneamente una celebrità. Scienziati e giornalisti facevano a gara per ottenere la sua attenzione. Vinse medaglie e premi, incontrò star del cinema e capi di stato, fu chiamato al telefono da Einstein in persona e ora un enorme telescopio orbitante intorno alla Terra porta il suo nome.

Nessuno di questi onori fu tributato a Henrietta Leavitt. Morì di cancro nel 1921, quattro anni prima che Hubble annunciasse la sua scoperta. Gli astronomi professionisti, tutti uomini, sicuramente sapevano della sua fondamentale equazione e del fatto che essa mostrasse loro come usare le pulsar per misurare le dimensioni dell'universo. Ma le diedero molto meno credito di quello che avrebbe meritato. Per molti di loro, Leavitt era “solo” un computer: una donna a cui era proibito mettere piede in un osservatorio e che aveva bisogno di un uomo che la sponsorizzasse per poter pubblicare il suo lavoro su una rivista rispettabile. E al grande pubblico era semplicemente sconosciuta, più o meno come lo è ora. Possiamo ragionevolmente predire che il centesimo anniversario della scoperta di Hubble, nel 2025, sarà sulle prime pagine di tutti i maggiori quotidiani mondiali. Mentre il centesimo anniversario della scoperta di Henrietta Leavitt, nel 2012, non è apparso nemmeno nei titoli delle maggiori riviste di astronomia.

Le dobbiamo molto più di questo. Perché se le pulsar sono le candele dell'universo, allora Henrietta Leavitt è stata colei che ne ha forgiato il

candeliere, regalandoci un'equazione che possiamo tenere alta nel cielo per fare luce nell'oscurità.

***a** Si scoprì in seguito che si trattava di una classe speciale di pulsar chiamata “variabili Cefeidi”.

***b** Stiamo semplificando un po' le cose. La retta di Leavitt permetteva di ricavare la vera luminosità di una pulsar *relativa* alla vera luminosità di qualsiasi altra pulsar. L'affermazione tecnicamente corretta, dunque, è: se conosci la luminosità reale di una pulsar – ne basta una sola – allora dalla regola di Leavitt puoi immediatamente ricavare la luminosità reale di qualsiasi altra pulsar nell'universo. In gergo astronomico, la retta di Leavitt doveva essere “calibrata”, stimando in qualche altro modo la luminosità reale di una singola pulsar. Ci vollero diversi anni per capire come fare e questo ritardò l'adozione della regola di Leavitt per stimare le distanze delle stelle. Ma lasceremo ad altri questa parte della storia; *vedi*, per esempio, M. Bartusiak, *The Day We Found the Universe*, Vintage Books, New York 2010, capitolo 8.

***c** Nota tecnica: se hai seguito un corso di analisi matematica, ricorderai di aver imparato come si minimizza una funzione. Legendre fece esattamente questo per trovare la regola di predizione che minimizza l'errore medio. In effetti, la soluzione di Legendre minimizza l'*errore quadratico medio* (da cui l'espressione “minimi quadrati”). Questo punto è importante dal punto di vista tecnico, ma non è essenziale per capire l'idea di fondo.

***d** Questa è una leggera semplificazione. Dobbiamo anche preoccuparci del cosiddetto *overfitting*: ne parleremo tra qualche pagina.

***e** La pillola è molto più efficace in condizioni di uso “perfette”, ovvero seguendo le indicazioni del produttore, con una percentuale di fallimento dello 0,3% in un anno.

***f** La regola “ $MFC = 208 - 0,7 \times \text{età}$ ” è il fit dei minimi quadrati per i dati ottenuto grazie alla formula di Legendre del 1805.

***g** Nel gergo dell'IA questo modello è detto “non lineare”, a differenza di quello immaginato per Zillow che contiene un singolo fattore moltiplicativo per ogni caratteristica.

***h** Questo esempio è tratto dalla fantastica serie di fumetti xkcd, disponibile all'indirizzo <https://xkcd.com/1122/>.

***i** Nota tecnica: gli sviluppatori di modelli in ia in realtà provano a rendere i loro modelli più semplici usando una tecnica matematica chiamata “regolarizzazione”. Questo aiuta anche a evitare la sovradeterminazione, ed è davvero importante per ottenere buone regole di predizione. Ti incoraggiamo ad approfondire il tema della sovradeterminazione, se sei interessato all'argomento.

***l** Questo per quanto riguarda le immagini. Ma esistono deep neural network per qualsiasi tipo di input, dai video ai testi, e sono tutte strutturate in modo diverso.

IL REVERENDO E IL SOTTOMARINO

Domanda: cosa hanno in comune una bicicletta, la neve, un canguro e un sottomarino? Risposta: sono tutti importanti per costruire un'automobile a guida autonoma.

Considera le biciclette. Le biciclette sono un problema. I sensori delle automobili a guida autonoma funzionano bene nell'identificare oggetti come pedoni e scoiattoli, che si muovono molto più lentamente delle auto e che appaiono quasi uguali da ogni visuale. Le altre automobili sono banali: sono enormi pezzi di metallo riflettente che brillano come alberi di Natale agli occhi di un radar. Ma le biciclette? Le biciclette possono andare lentamente o velocemente, possono essere piccole o grandi, in metallo o in fibra di carbonio e, a seconda del punto di vista, possono essere larghe come una macchina o sottili come un libro. Se non fai caso alla bici, come puoi distinguere un ciclista da un pedone con una postura strana? Per non parlare di tutti quegli scarti improvvisi, così imprevedibili e fulminei. Ce n'è abbastanza per fare venire un bel mal di testa a un computer.

Anche la neve è un problema e non per la trazione, i robot sono abbastanza intelligenti da indossare gomme da neve e conoscono i propri limiti. Ma la neve copre la segnaletica delle corsie, nasconde i segnali di stop, interferisce con i fasci laser che le macchine usano per misurare la distanza degli oggetti nelle vicinanze. Per una macchina robotizzata, la neve è una privazione sensoriale.

Per quanto riguarda i canguri, esistono altri animali dal comportamento poco predicibile, ma almeno restano sul terreno. Un canguro salta dieci metri alla volta. E, nel saltare su e giù, appare più grande e più piccolo, più grande e più piccolo nel campo visivo di una videocamera, come un coniglio gigante in un caleidoscopio. Questo confonde davvero le idee a un robot. Con tutti questi rapidi cambiamenti di dimensione, come puoi stabilire la sua distanza? Bisognerebbe quasi avere un laser espressamente dedicato ai canguri, anzi, a

molti di essi perché i canguri si spostano in... be' ci sarà un motivo se gli zoologi le chiamano "orde".

E poi c'è il sottomarino. Promettiamo di arrivarci tra un minuto.

Ma prima ti invitiamo a riflettere su una cosa. Non è sorprendente il fatto che stiamo parlando di *orde di canguri* come uno dei principali ostacoli per la tecnologia e non del pericolo, per esempio, di andare fuori strada o di entrare nel salotto del vicino? Fatti una semplice domanda. Se dovessi mettere su un taxi una persona cara, la affideresti alla guida di un sedicenne qualsiasi con una patente o a una delle automobili Waymo? (Waymo è l'azienda produttrice di automobili a guida autonoma, nata dentro Google.) Se ritieni di doverci pensare su, ti invitiamo a considerare qualche dato.¹

Il 56% degli adolescenti americani parla al telefono mentre guida.

Nel 2015, 2715 adolescenti americani sono morti e 221 313 sono finiti in ospedale a causa di incidenti stradali.

Nella metà di tutti gli incidenti riguardanti adolescenti è coinvolto un solo veicolo.

Al contrario, le automobili Waymo non si distraggono mai. Non bevono. Non si stancano e non mandano messaggi ai loro amici quando dovrebbero invece prestare attenzione alla strada. Dal 2009 hanno percorso più di 3,5 milioni di chilometri sulle strade e hanno causato un solo incidente: una strisciata contro la fiancata di un bus in California alla velocità di tre chilometri orari. A conti fatti, la percentuale di incidenti per chilometro, calcolata su nove anni, è quaranta volte più piccola rispetto a quella dei guidatori tra i sedici e i diciannove anni, e dieci volte più piccola rispetto a quella dei guidatori tra i cinquanta e i cinquantanove anni. E si tratta di *prototipi*.

Questi numeri predicono un chiaro indirizzo per le regole del futuro: permettere a un sedicenne di guidare un'automobile sembrerà una follia da irresponsabili. Quando i nostri discendenti sapranno che un tempo era normale, reagiranno allo stesso modo in cui reagiamo oggi quando ci dicono che i nostri nonni erano soliti tornare a casa mettendosi al volante dopo aver bevuto quattro martini e senza cinture di sicurezza. Ma per quanto riguarda le bici, la neve e i canguri? Questi sono problemi dell'ingegneria. Saranno risolti nell'immediato futuro, forse anche prima che tu legga questo libro, e quasi sicuramente per mezzo della solita soluzione: dati migliori. Nell'IA, i dati sono come l'acqua: è il solvente universale.

In realtà, se parli con gli scienziati al lavoro sulle automobili a guida autonoma, ti imbattevi presto nella scioccante domanda: è già nato l'ultimo californiano che avrà bisogno di una patente di guida?

La rivoluzione robotica

I robot sono arrivati molto lontano in poco tempo.

Negli anni cinquanta, lo stato dell'arte era Teseo, un topo autonomo a grandezza naturale costruito da Claude Shannon ai Bell Labs e alimentato da un banco di relè telefonici. L'originale Teseo, l'eroe greco, entrò nel labirinto per uccidere il Minotauro. Il topo Teseo aveva ambizioni più modeste: entrò in un labirinto da tavolo composto da venticinque quadrati per trovare un pezzo di formaggio. All'inizio procedette per tentativi e riuscì a trovare il pezzo di formaggio. Dopo il trionfo iniziale, riuscì a trovare il percorso per uscire da qualsiasi punto del labirinto, senza mai compiere errori.²

Negli anni sessanta e settanta, arrivò lo Stanford Cart: un veicolo grande quanto un carretto con quattro piccole ruote di bicicletta, un motore elettrico e una singola videocamera. Il Cart fu inizialmente concepito come prototipo usato dagli ingegneri per capire come controllare un veicolo lunare dalla Terra in modo remoto. Ma si trasformò presto in una piattaforma di ricerca sulla navigazione autonoma per un'intera generazione di studenti di robotica allo Stanford Artificial Intelligence Lab. Nel 1979, dopo anni di perfezionamenti, il Cart riusciva a farsi strada in una stanza piena di sedie in cinque ore, senza intervento umano, un traguardo importante per l'epoca.³

E oggi? Le auto a guida autonoma sono solo l'inizio. Non dimenticare i taxi volanti autonomi, come quelli che il governo di Dubai sta testando dal settembre 2017. O la miniera di ferro autonoma a Rio Tinto, nell'entroterra australiano. O il terminal automatico del porto di Tsingtao, in Cina: sei enormi ormeggi che si estendono per due chilometri di costa, da cui transitano 5,2 milioni di container ogni anno, centinaia di camion robot e di gru automatiche, e nessuno al volante.⁴

Una delle domande più frequenti che arrivano dagli studenti dei nostri corsi di scienza dei dati è «Come funzionano i robot?». Ci piacerebbe poter rispondere in modo completo a questa domanda, ma purtroppo non possiamo farlo. Innanzitutto, ci sarebbero così tanti dettagli che servirebbe un libro molto più lungo, con moltissime equazioni. E poi molti di questi dettagli sono

riservati. Per esempio, potresti aver sentito che Waymo ha fatto causa a Uber per 1,86 miliardi di dollari per il supposto furto di alcuni di questi dettagli, una causa il cui esito, nel momento in cui scriviamo, è ancora sconosciuto.⁵

Dettagli a parte, cerchiamo di afferrare i concetti di base. Ecco un'analogia. Puoi certamente imparare i principi in base ai quali un aereo resta in aria, anche se non sai costruire un Boeing 787. Analogamente, puoi capire come un'automobile a guida autonoma riesce a muoversi nel suo ambiente, anche se non sei in grado di costruirne una. Questo è esattamente il livello di comprensione che raggiungerai alla fine del capitolo, partendo da quello che hai già imparato sulla probabilità condizionata.

Per arrivarci, inizieremo con una domanda semplice, quasi infantile, ma fondamentale per ogni robot autonomo, sia che cammini o che guidi o che voli, sia che scavi per trovare il ferro o che ci porti al supermercato, sia che abbia le dimensioni di un topo o quelle di una nave portacontainer. Questa domanda, in effetti, è talmente importante che necessita di una risposta decine o anche centinaia di volte al secondo.

La domanda è: dove mi trovo?

Nell'IA, è definito problema SLAM, da *simultaneous localization and mapping* (localizzazione e mappatura simultanee). Il termine "simultanee" è essenziale in questo caso. Che tu sia una persona o un robot, sapere dove ti trovi significa fare due cose allo stesso tempo: (1) costruire una mappa mentale di un ambiente ignoto, e (2) dedurre la tua posizione all'interno di quell'ambiente. È il famoso problema dell'uovo e della gallina. Le tue nozioni sull'ambiente circostante dipendono dalla tua posizione, ma la nozione di posizione dipende dall'ambiente circostante. Non è possibile conoscere l'una in modo indipendente dall'altra e dunque sembra logicamente impossibile dedurle allo stesso tempo. Immagina, per esempio, di voler arrivare a Times Square senza mai essere stato in precedenza a New York. Ti diciamo che si trova a una fermata di metro a nord della Penn Station e poi, quando ci chiedi dove si trova la Penn Station, ti rispondiamo che è a una fermata di metro a sud di Times Square. A questo punto devi andare a cercare entrambi i posti senza mappa. Questo è il problema SLAM.

Anche se non sembra, l'informazione che ricevi dai tuoi sensi riguardo alla tua posizione nel mondo è circolare quasi come le nostre informazioni su Times Square. Il miracolo cognitivo è che tu sei perfettamente in grado di risolvere il problema SLAM, senza alcuno sforzo a livello conscio, ogni volta che entri in un ambiente sconosciuto. I neuroscienziati non capiscono fino in

fondo come sia possibile, ma sanno che sono coinvolti circuiti cerebrali molto specializzati e filogeneticamente antichi, in particolar modo all'interno dell'ippocampo. E, come molte capacità perfezionate dall'evoluzione, risulta molto difficile da ripercorrere al contrario. In IA, questo è spesso chiamato “paradosso di Moravec”: le cose facili per un bimbo di cinque anni sono difficili per un computer, e viceversa.^{*a}

L'attuale rivoluzione nel campo dei robot autonomi è stata resa possibile solo perché tutta la ricerca dedicata ai sistemi SLAM ha finalmente dato i suoi frutti. I robot sono passati dall'evitare sedie all'evitare altri guidatori; dalle cinque ore necessarie per attraversare una stanza ai cinque gigabyte di dati provenienti ogni secondo dai sensori; da un topo autonomo in grado di muoversi attraverso un labirinto di venticinque quadratini a un'automobile a guida autonoma che può percorrere milioni di chilometri sulle strade. Quella dello SLAM è una delle storie di maggior successo dell'IA. In questo capitolo esamineremo due aspetti legati allo SLAM: uno ovvio, l'altro più inatteso.

1. Come fa una macchina a guida autonoma a capire dove si trova?
2. Come puoi diventare più intelligente pensando come una macchina a guida autonoma?

Per rispondere a entrambe le domande è necessaria la *regola di Bayes*. Si tratta della regola che consente alle macchine a guida autonoma di sapere dove si trovano sulla strada, ma serve anche a molto di più. La regola di Bayes è un risultato matematico profondo usato quotidianamente quasi in ogni ambito scientifico e industriale. Inoltre, è un principio incredibilmente utile per vivere la vita di tutti i giorni in modo più intelligente, per esempio investendo i propri risparmi in maniera prudente o prendendo decisioni informate sui trattamenti medici. La regola di Bayes è il miglior esempio del perché allenare te stesso a pensare un po' più come una macchina può aiutarti a essere una persona più saggia e più in forma.

In che modo trovare un sottomarino è simile a sapere dove ti trovi lungo una strada?

Possiamo ora, finalmente, tornare alla nostra vecchia promessa. Ti abbiamo detto che comprendere un sottomarino è importante per fare in modo che un'auto si guidi da sola. Ora vedremo perché.

La connessione in questo caso è la regola di Bayes, che ti spiegheremo raccontandoti la storia di un sottomarino. Non uno di quelli a guida autonoma, ma un ordinario sottomarino a propulsione nucleare chiamato *USS Scorpion*. Lo *Scorpion* è famoso perché un giorno, nel 1968, scomparve in un tratto di mare aperto ampio migliaia di chilometri. Questo mandò la marina militare in fibrillazione: non è una buona cosa che un sottomarino nucleare scompaia. Nonostante le scarse possibilità di successo, gli ufficiali della marina si buttarono a capofitto nella ricerca. Setacciarono l'oceano per mesi, ma non riuscivano a scovare lo *Scorpion*. Scoraggiati e disperati, stavano per sospendere le ricerche.

Ma un uomo era troppo testardo per arrendersi. Il suo nome era John Craven, ed era testardo perché era convinto di avere la probabilità dalla sua parte e la cosa stupefacente è che aveva ragione. John Craven e il suo gruppo di ricerca usarono la regola di Bayes per rispondere alla domanda: «Dove si trova lo *Scorpion* in mezzo a questo oceano vuoto?». Quando saprai come hanno fatto, capirai che un'auto a guida autonoma usa la stessa matematica per rispondere a una domanda molto simile: «Qual è la mia posizione su questa grande strada?».

La ricerca dello Scorpion

Nel febbraio del 1968 lo *USS Scorpion* prese il largo da Norfolk, Virginia, sotto la guida del comandante Francis A. Slattery. Lo *Scorpion* era un sottomarino d'attacco ad alta velocità, di classe Skipjack, il più veloce della flotta americana. Come altri sottomarini della sua classe, giocava un ruolo importante nella strategia militare statunitense: si era all'apice della guerra fredda, e sia i russi sia gli americani utilizzavano ampie flotte di sottomarini per localizzare, tracciare e, nel caso estremo, distruggere i sottomarini lanciamissili del nemico.

Lo *Scorpion* si mise in rotta verso est con questa missione, diretto verso il Mediterraneo, dove per tre mesi partecipò a esercitazioni con la 6^a flotta navale. Poi, a metà maggio, lo *Scorpion* fu mandato indietro verso ovest, oltrepassò Gibilterra ed entrò nell'Atlantico. Lì gli venne ordinato di tenere d'occhio le navi sovietiche al largo delle Azzorre – un remoto arcipelago nel mezzo dell'Atlantico del Nord, a circa 1300 chilometri dalle coste portoghesi – e poi di proseguire a ovest, verso casa. Il sottomarino sarebbe dovuto rientrare a Norfolk alle 13.00 di lunedì 27 maggio 1968.

I familiari dei novantanove membri dell'equipaggio dello *Scorpion* si erano raccolti sul molo quel giorno per accogliere i loro cari. Ma alle 13.00 il sottomarino non era ancora emerso. I minuti divennero ore; il giorno fece spazio alla notte. E le famiglie aspettavano. Ma ancora nessuna traccia dello *Scorpion*.

Con crescente preoccupazione, la marina diede inizio a una ricerca. Alle 22.00 erano coinvolte diciotto navi nell'operazione; al mattino successivo, trentasette navi e sedici aerei da pattugliamento.⁶ L'ultimo contatto con lo *Scorpion* era stato al largo delle Azzorre, sei giorni prima. Poteva trovarsi ovunque all'interno della striscia larga 4300 chilometri tra le Azzorre e la costa est degli Stati Uniti. Col passare delle ore, le probabilità di trovare il sottomarino e di inviare una missione di soccorso diminuivano rapidamente. In una conferenza stampa molto tesa, il 28 maggio, il presidente Lyndon Johnson espresse il sentimento dell'intera nazione: «Siamo profondamente angosciati. [...] Non abbiamo nulla di incoraggiante da riferire».⁷

Dopo otto giorni, la marina fu costretta ad ammettere l'evidenza: i novantanove uomini dell'equipaggio furono dichiarati dispersi, presumibilmente deceduti. La marina aveva ora l'ingrato compito di localizzare il punto dove giaceva lo *Scorpion*, un minuscolo ago nell'enorme pagliaio di grandezza pari a tre quarti dell'oceano Atlantico. Sebbene le speranze di salvare la vita dell'equipaggio fossero svanite, la posta in gioco nel ritrovare il sottomarino era altissima, e non solo a beneficio delle famiglie dei dispersi: lo *Scorpion* trasportava due missili con testate nucleari, capaci di affondare una portaerei con un solo colpo. Queste pericolose testate ora si trovavano da qualche parte sul fondo del mare.

John Craven, guru della ricerca bayesiana

Per guidare la ricerca, il Pentagono si rivolse a John Craven, scienziato dell'Ufficio progetti speciali della marina, e massimo esperto nel trovare oggetti smarriti in acque profonde.

Fortunatamente, Craven aveva già fatto questo tipo di ricerche. Due anni prima, nel 1966, un bombardiere B-52 si era scontrato in volo con un aereo per il rifornimento al di sopra della costa spagnola, vicino al villaggio di Palomares. Entrambi gli aerei erano precipitati e le quattro bombe all'idrogeno del B-52, ognuna cinquanta volte più potente della bomba di Hiroshima, erano sparse nel raggio di diverse miglia. Per fortuna, nessuna

delle testate era esplosa, e tre erano state ritrovate subito. Ma mancava la quarta, e si temeva che fosse caduta in mare.

Craven e il suo team dovettero considerare moltissime variabili sconosciute della collisione. La bomba era rimasta sull'aereo o era fuoriuscita? Se i paracadute si erano attivati, era possibile che la bomba fosse stata trasportata dai venti in mare aperto? E, in questo caso, in quale direzione e quanto lontano? Per orientarsi in questa fitta boscaglia di variabili sconosciute, Craven fece ricorso alla sua strategia preferita: la *ricerca bayesiana*. Questo metodo era stato sviluppato durante la seconda guerra mondiale per aiutare gli Alleati a localizzare gli U-Boot tedeschi. Ma le sue origini risalgono a molto tempo prima: al principio matematico chiamato regola di Bayes, proposto per la prima volta a metà del XVIII secolo.⁸

La ricerca bayesiana è composta di quattro passaggi essenziali. Per prima cosa, devi creare una mappa delle *probabilità a priori* sulla tua griglia di ricerca. Queste probabilità sono dette “a priori” in quanto rappresentano le tue convinzioni prima di raccogliere qualsiasi dato. Esse combinano due tipi di informazioni:

- Le opinioni preesistenti di vari esperti. Nel caso della bomba H scomparsa, alcuni di questi esperti conoscevano bene le dinamiche degli scontri in volo, altri le bombe nucleari, altri ancora le correnti oceaniche e così via.
- Le potenzialità degli strumenti di ricerca. Per esempio, supponi che lo scenario più plausibile sia che la bomba si trovi sul fondale di una profonda fossa oceanica. Nonostante questa eventualità sia possibile, non inizierai a cercare da lì: il fondale è talmente buio e remoto che, anche se la bomba si trovasse davvero lì, probabilmente non riusciresti a trovarla. Per usare una metafora familiare, il metodo bayesiano ti fa iniziare la ricerca del tuo mazzo di chiavi perse usando una precisa combinazione matematica di due fattori: dove pensi di averlo perduto e dove l'illuminazione pubblica è più intensa.

Puoi vedere un esempio di mappa di probabilità a priori nella parte alta della figura 3.1.

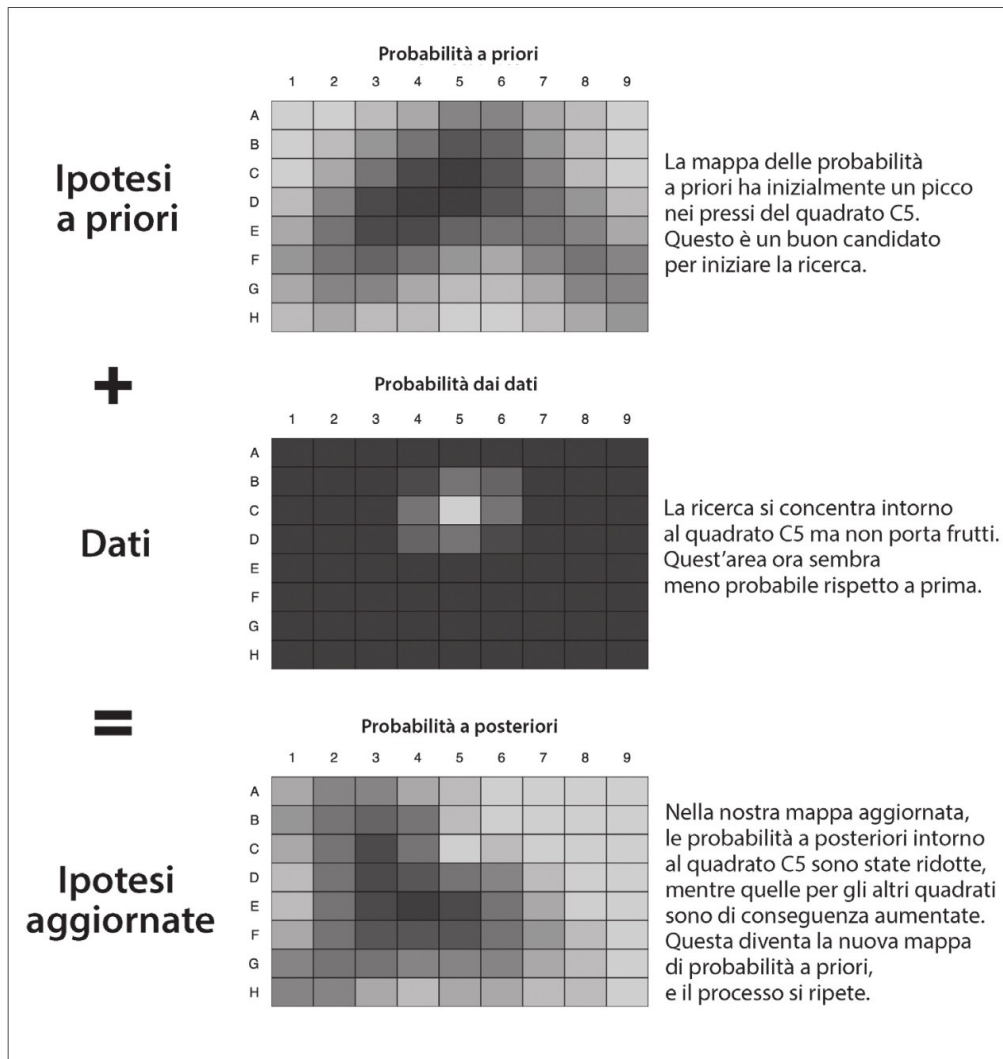


Figura 3.1 Nella ricerca bayesiana, le ipotesi a priori sono combinate con i dati ricavati dai sensori per produrre un insieme di ipotesi aggiornate.

Il secondo passaggio è compiere una ricerca intorno al punto di maggiore probabilità, ovvero il quadrato C5 in figura 3.1. Se trovi ciò che stai cercando, allora hai finito. Altrimenti, passa al terzo step: rivedi le tue ipotesi. Supponi di aver cercato intorno a C5 ma di non aver trovato nulla. A questo punto riduci il valore della probabilità intorno a C5 e, di conseguenza, aumenti i valori delle probabilità in altre regioni. Le tue probabilità a priori sono ora diventate, grazie ai nuovi dati, probabilità a posteriori. Puoi visualizzare questo concetto sovrapponendo due mappe una sopra l'altra:

- La mappa originale delle probabilità a priori (parte alta della figura).
- La mappa delle probabilità risultanti dai dati (parte centrale della figura). Queste probabilità sono basse nelle regioni dove hai effettuato la ricerca e non hai trovato nulla, ma restano alte nelle regioni che non hai esplorato, poiché

non puoi escluderle.

Questa è l'essenza della regola di Bayes: probabilità a priori + fatti = probabilità a posteriori.

Il quarto passaggio è ricominciare la ricerca. Ripeti gli step 2 e 3, sempre cercando nelle regioni ad alta probabilità. Se torni a mani vuote, rivedi di nuovo le tue previsioni. Le probabilità a posteriori di oggi diventano le probabilità a priori di domani, fino a quando la ricerca darà esito positivo.

La frustrazione di Craven

Sfortunatamente, Craven e il suo team non ebbero modo di applicare questi principi bayesiani alla ricerca della bomba H persa nel 1966 a largo di Palomares. Con una classica mossa militare, il Pentagono aveva chiesto a Craven di fare qualcosa della massima importanza, e allo stesso tempo aveva affidato a qualcun altro il compito di rendergli la vita il più difficile possibile. L'ufficiale al comando, il viceammiraglio William "Bull Dog" Guest, aveva una visione decisamente diversa del modo in cui la ricerca andava condotta. Non aveva la pazienza necessaria per affidarsi alla probabilità, alla regola di Bayes, e a quel ventenne dottore di ricerca in matematica vestito in stile Oxford e in velluto a coste. I suoi ordini iniziali per Craven erano dimostrare che la bomba era caduta sulla terraferma anziché in mare, in modo che il compito ingrato passasse a qualcun altro. Di conseguenza, la ricerca della bomba H di Palomares erano in realtà due ricerche. C'era la ricerca bayesiana "ombra" di Craven, con le sue regole di calcolo e le mappe di probabilità, e con numeri costantemente aggiornati trasmessi per mezzo di telescriventi da un elaboratore in Pennsylvania su cui i matematici eseguivano calcoli in remoto. Ma gli avanzamenti ottenuti per mezzo di questi calcoli erano ignorati in favore del "piano di quadrati" dell'ammiraglio Guest, che dirigeva la vera ricerca.

Alla fine la bomba H di Palomares fu trovata, grazie a un pescatore locale che l'aveva vista cadere in acqua attaccata a un paracadute e che guidò la marina sul posto. Sebbene la ricerca avesse avuto successo, l'approccio bayesiano era stato un fallimento per la semplice ragione che non ebbe mai una reale possibilità di entrare in gioco. Nonostante questo, l'incidente di Palomares diede a John Craven alcune preziose lezioni, sia sul condurre dal

punto di vista pratico una ricerca bayesiana, sia su come ottenere supporto dagli ufficiali militari.⁹

Due anni dopo, quando fu chiamato per la ricerca dello *Scorpion*, Craven era pronto.

La ricerca dello Scorpion continua

Quando lo *Scorpion* scomparve nel maggio del 1968, Craven e il suo team di esperti di ricerca bayesiana si riunirono subito. A prima vista, il compito sembrava molto più scoraggiante rispetto alla bomba di Palomares. In quel caso, sapevano di poter limitare la loro ricerca a un'area relativamente piccola nelle basse acque della Spagna meridionale. Ora invece bisognava trovare un sottomarino a più di tre chilometri di profondità, da qualche parte tra la Virginia e le Azzorre, senza il più piccolo indizio.

Ma ebbero un colpo di fortuna. Fin dall'inizio degli anni sessanta, l'esercito statunitense aveva investito diciassette miliardi di dollari per installare un'enorme rete segreta di microfoni sottomarini nel Nord Atlantico, in modo da poter seguire i movimenti della marina sovietica. Tecnici altamente specializzati monitoravano continuamente questi microfoni in postazioni segrete. Dopo aver ficcato il naso qua e là, Craven scoprì che una di queste postazioni segrete sulle isole Canarie aveva registrato, in un giorno di fine maggio, una serie molto insolita di diciotto suoni sottomarini. In seguito apprese anche che altre due postazioni – entrambe distanti migliaia di chilometri, al largo della costa di Terranova – avevano registrato quegli stessi suoni più o meno contemporaneamente. Il team di Craven confrontò queste tre registrazioni e, grazie alla triangolazione, dedusse che i suoni dovevano provenire da un punto molto profondo dell'oceano Atlantico, a circa 600 chilometri a sud-ovest delle Azzorre. Questo punto si trovava sulla rotta dello *Scorpion* verso casa. I suoni stessi erano molto indicativi: un'esplosione subacquea attutita, poi novantuno secondi di silenzio, e poi altri suoni in rapida successione che, secondo Craven, indicavano l'implosione di vari compartimenti di un sottomarino che sprofonda oltre la quota di schiacciamento.¹⁰

Questa informazione restrinse parecchio l'area di ricerca. Ma il team aveva ancora più di 200 chilometri quadrati di oceano da esplorare, tutti al di sotto dei 300 metri di profondità e dunque inaccessibili anche ai sottomarini più avanzati.

A questo punto, la ricerca bayesiana fece il suo ingresso solenne. Craven e il suo team intervistarono marinai esperti che fornirono nove possibili scenari – un incendio a bordo, un missile esploso nel suo alloggio, un attacco russo segreto e così via – su come il sottomarino potesse essere affondato. Stimarono la probabilità a priori di ogni scenario e utilizzarono simulazioni al computer per capire la successione dei probabili movimenti del sottomarino. Fecero persino esplodere cariche di profondità in punti precisi per calibrare i dati acustici originali presi dalle postazioni di ascolto delle isole Canarie e di Terranova.

Alla fine combinarono tutte queste informazioni stimando una probabilità di efficacia per la ricerca in ogni singola cella della griglia. Questa mappa cristallizzava migliaia e migliaia di ore di interviste, calcoli, esperimenti e ragionamenti accurati. Qualcosa di molto simile alla figura 3.2.

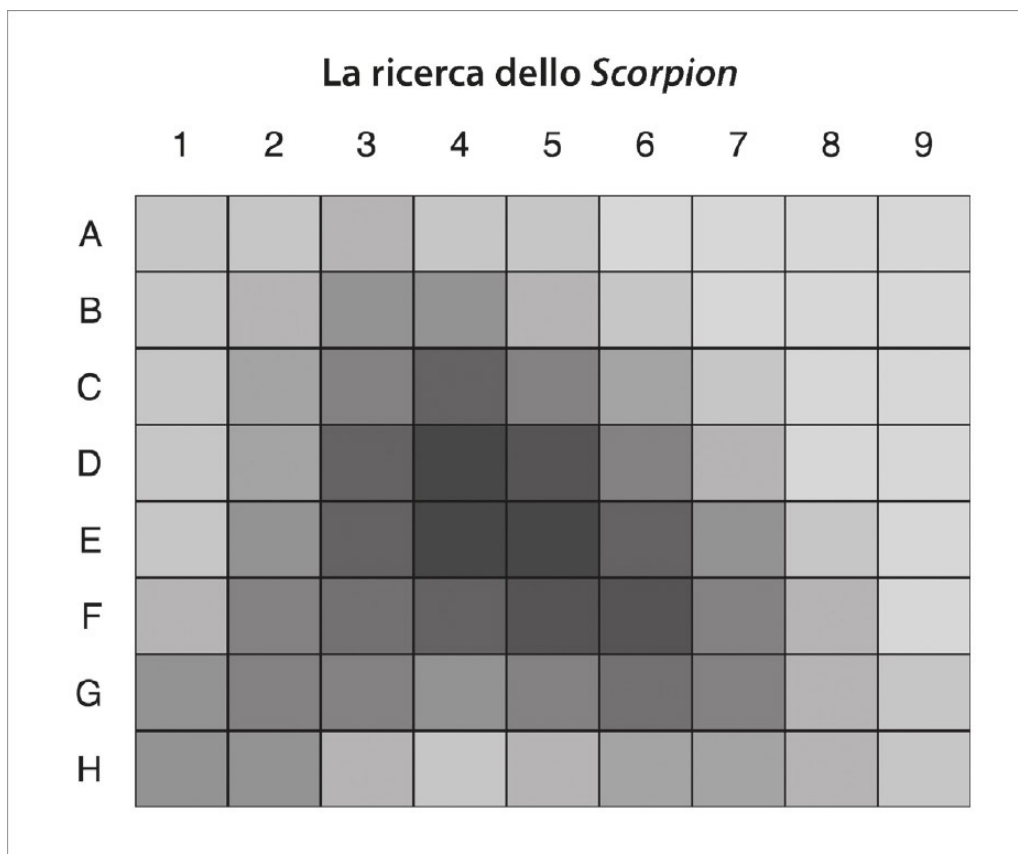


Figura 3.2 Una ricostruzione della mappa delle probabilità a priori utilizzata nella ricerca dello *Scorpion*.

Come previsto, Craven incontrò difficoltà logistiche e burocratiche quando cercò di attirare l'attenzione del Pentagono sulle sue mappe di probabilità.

Passò un'intera estate. A questo punto, la ricerca dello *Scorpion* andava avanti da oltre tre mesi, inutilmente.

Alla fine la sua ostinazione ebbe la meglio, e i militari ordinarono che la mappa di Craven venisse utilizzata per guidare le ricerche. Dunque, a partire da ottobre, quando i comandanti a bordo della USS *Mizar* ebbero in mano la mappa, l'operazione diventò davvero bayesiana. Giorno dopo giorno, il team setacciò la regione con probabilità più alta, aggiustò i numeri e aggiornò la mappa per il giorno dopo. E giorno dopo giorno, quei numeri si concentrarono sul rettangolo F6.

Il 28 ottobre, finalmente, Bayes diede i suoi frutti.

La *Mizar* era alla sua quinta spedizione e al settantaquattresimo tentativo di ricerca sul fondale oceanico. Tutto a un tratto, il magnetometro della nave schizzò, indicando un'anomalia sul fondale. Subito vennero inviate telecamere, ed era lì. Parzialmente sepolto sotto la sabbia, a sessanta chilometri dalla terraferma e a tre chilometri sotto il livello del mare, lo *Scorpion* venne finalmente trovato.¹¹



Figura 3.3 Una foto della prua dello USS *Scorpion*, scattata nel 1968 dall'equipaggio del batiscafo *Trieste II*.

Oggi nessuno sa cosa sia successo allo *Scorpion* o, se qualcuno lo sa, non lo dice. La versione ufficiale della marina parla di un'esplosione accidentale di un missile o del malfunzionamento di una unità di smaltimento rifiuti come cause più probabili. Sono state avanzate molte altre spiegazioni nel corso degli anni e, come con qualsiasi altro evento misterioso, abbondano le teorie complottiste.¹²

Ma almeno una risposta definitiva l'abbiamo ottenuta: la ricerca bayesiana ha funzionato brillantemente. I resti del sottomarino si trovavano a soli 100 metri dal rettangolo E5, la regione iniziale con più alta probabilità sulla mappa di Craven. Il team di ricerca era passato su quel punto in una precedente missione, ma aveva mancato la rilevazione a causa di un sonar rotto.¹³

Rifletti ancora un momento. Pensa quanto sia difficile trovare qualcosa che hai perso su una spiaggia lunga una trentina di metri o anche nel tuo salotto. Eppure, quando un sottomarino solitario è scomparso da qualche parte in una regione di oceano larga 4000 chilometri, una ricerca bayesiana è stata in grado di localizzarlo con la precisione di 100 metri, appena tre volte la lunghezza del sottomarino stesso. Si è trattato di un trionfo per il team di Craven e per la regola di Bayes, la formula proposta 250 anni fa e utilizzata come principio guida per la ricerca.

La regola di Bayes, dal reverendo al robot

La lezione che dobbiamo tenere a mente dalla storia dello *Scorpion* è: tutte le probabilità sono in realtà probabilità *condizionate*. In altre parole, tutte le probabilità si basano su ciò che già sappiamo. Quando le informazioni a nostra disposizione cambiano, devono cambiare anche le probabilità e la regola di Bayes ci dice come farlo.

La regola di Bayes fu scoperta da uno sconosciuto sacerdote di nome Thomas Bayes. Nato nel 1701 da una famiglia presbiteriana londinese, Bayes mostrò un talento precoce per la matematica, ma a quel tempo coloro che professavano religioni diverse dal protestantesimo erano esclusi dalle università in Inghilterra. Rifiutato da Oxford e Cambridge, rinunciò alla matematica e si iscrisse all'Università di Edimburgo per studiare teologia. Questa dovette sembrare una vera e propria ingiustizia a Bayes, così come a molti altri della sua epoca. Ma questa discriminazione aveva un interessante

effetto collaterale. Proprio a causa dell'intolleranza religiosa, l'Inghilterra ospitava un numero sorprendente di società matematiche amatoriali formate da talenti di religione presbiteriana esclusi, come Bayes, dalle università inglesi, e che dunque avevano creato comunità intellettuali per conto proprio. Dopo i quarant'anni Bayes divenne membro di una di queste società, in una cittadina termale nel Kent chiamata Tunbridge Wells, dove aveva preso servizio come pastore presbiteriano e dove, intorno al 1750, concepì la regola che oggi porta il suo nome.

Sorprendentemente, la sua scoperta non ebbe molta risonanza nei primi tempi. Bayes non la pubblicò nemmeno prima della morte; morì nel 1761 e il suo manoscritto fu letto postumo alla Royal Society nel 1763 dal suo amico Richard Price. Ci fu un breve periodo di tempo, verso l'inizio del XVIII secolo, in cui le idee bayesiane fiorirono, principalmente grazie al grande matematico francese Pierre-Simon de Laplace. Ma alla morte di Laplace nel 1827, la regola di Bayes finì nel dimenticatoio e fu abbandonata per più di un secolo.

Aggiornamento bayesiano e automobili a guida autonoma

Oggi, invece, la regola di Bayes è tornata in forma smagliante e fa bella mostra di sé al volante di ogni automobile a guida autonoma.

La regola di Bayes è un'equazione che ci indica come aggiornare le nostre convinzioni alla luce di nuove informazioni, trasformando probabilità *a priori* in probabilità *a posteriori*. Offre la soluzione perfetta al problema della robotica descritto in precedenza: SLAM o *simultaneous localization and mapping* (localizzazione e mappatura simultanee). Lo SLAM è un problema intrinsecamente bayesiano. All'arrivo di nuovi dati dai sensori, una macchina automatica deve aggiornare la sua "mappa mentale" dell'ambiente circostante – i segnalatori di corsia, gli incroci, i semafori, i segnali di stop e tutti gli altri veicoli sulla strada – e allo stesso tempo deve ricavare la sua posizione *all'interno* di quell'ambiente. In sostanza, una macchina a guida autonoma "immagina" se stessa come una palla di probabilità che viaggia lungo una strada bayesiana.

Prima di descriverne il funzionamento, facciamoci un'altra domanda: perché non usare la tecnologia GPS, come quella che c'è sul tuo smartphone? Il problema è che, anche in condizioni ideali, i sistemi GPS di uso civile hanno un'accuratezza di soli cinque metri e funzionano molto peggio nelle

gallerie o in prossimità di edifici alti, dove possono sbagliare anche di trenta o quaranta metri. Usare esclusivamente il GPS nel traffico cittadino equivale a effettuare un'operazione di chirurgia vascolare con guantoni da forno e benda sugli occhi.

Dunque, per integrare le informazioni provenienti dal GPS, una macchina a guida autonoma deve affidarsi a un bel po' di altri sensori. Alcuni di questi sono semplici videocamere, mentre altri sono equivalenti alle tecnologie per la sicurezza già presenti su gran parte delle macchine odierne, per esempio i radar nascosti nei paraurti: quelli che suonano quando ti avvicini troppo a qualcosa.

Il sensore migliore, e il più utile, di una macchina automatica è il LIDAR, una crasi di *light* e *radar* che sta per *light detection and ranging* (rilevazione di luce e misurazione di distanza). Immagina di essere bendato e di dover attraversare una stanza sconosciuta con il solo aiuto di un bastone. Probabilmente procederesti per tentativi: usando il bastone, daresti dei colpetti a destra e sinistra, misurando approssimativamente la distanza delle cose intorno a te. Se lo fai un numero sufficiente di volte, in tutte le direzioni, sarai in grado di costruire una buona mappa mentale dell'ambiente circostante.

Un LIDAR funziona allo stesso modo: emette un raggio laser e misura la distanza rilevando quanto tempo passa prima che la luce torni indietro. Un tipico insieme di LIDAR conta fino a sessantaquattro singoli laser, ognuno dei quali invia centinaia di migliaia di impulsi al secondo. Ogni raggio laser fornisce informazioni dettagliate su una direzione molto specifica. Dunque, per permettere alla macchina di vedere in ogni direzione, il LIDAR è montato sul tetto, all'interno di un meccanismo che ruota circa 300 volte al minuto, proprio come una versione più veloce del fascio rotante sugli schermi radar di *Top Gun*. I laser puntano circa cinque volte al secondo lungo ogni singola direzione, dando al veicolo aggiornamenti sulla posizione *discreti* anziché *continui*. In altre parole, l'automobile vede il mondo illuminato non dalla luce del sole continua, ma da una lampada stroboscopica: da brevi impulsi di dati, provenienti dal LIDAR e da altri sensori, che danno all'automobile ogni volta una nuova immagine dei dintorni, come in figura 3.4.



Figura 3.4 Un'immagine LIDAR di un'autostrada, su licenza della Oregon State University.

Ogni volta che l'auto riceve un nuovo pacchetto di dati, utilizza la regola di Bayes per aggiornare le sue "convinzioni" sulla propria posizione. Possiamo visualizzare questo processo di aggiornamento usando una mappa dove la strada è suddivisa in piccole celle, ognuna con la sua probabilità. Supponi di essere uscito dall'autostrada sulla tua macchina a guida autonoma e che tu abbia trascorso sessanta secondi viaggiando a circa quarantacinque chilometri orari. Basandosi sui dati fino a questo punto, la macchina si è fatta un insieme di "convinzioni" sulla sua posizione, come mostrato sulla mappa di probabilità nel pannello in alto a sinistra della figura 3.5. Consideriamo ora la macchina un quinto di secondo più tardi, dopo una spazzata del LIDAR, a 60,2 secondi dall'inizio del tuo viaggio. Come sono cambiate quelle convinzioni?

Il ragionamento della macchina è fatto di tre passaggi. Il primo è quello che gli esperti di navigazione chiamano "modalità stimata" o, come piace a noi chiamarlo, "introspezione ed estrapolazione". *Introspezione* significa raccogliere informazioni sullo "stato interno" come velocità, angolo di sterzata, accelerazione; *estrapolazione* vuol dire usare questa informazione, insieme alle leggi della fisica, per prevedere il possibile movimento della macchina nella prossima frazione di secondo. Il risultato è una mappa di probabilità a priori per la posizione della macchina dopo 60,2 secondi

dall'inizio del viaggio, mostrata nel pannello in alto a destra della figura 3.5. Queste probabilità sono “a priori” perché non includono i dati aggiornati dei sensori: siamo nell'istante immediatamente precedente al prossimo impulso stroboscopico.

Avrai notato due cose: la palla di probabilità si è spostata lungo la strada e si è un po' allargata per coprire un'area più vasta. Questo allargamento rappresenta l'incertezza aggiuntiva introdotta dall'estrapolazione. Per esempio, se viaggi a quarantacinque chilometri orari, ti aspetti di percorrere circa 2,5 metri in 0,2 secondi. Ma potresti in realtà percorrerne un po' di più o un po' di meno a causa, per esempio, di una sterzata imprevista, di una frenata o di un'accelerazione.

Il secondo passaggio è la raccolta dati dai sensori esterni, come le videocamere e il LIDAR. I dati forniscono un controllo sulla posizione della macchina, aiutando a correggere gli errori introdotti dell'estrapolazione. Questa informazione è mostrata nel pannello in basso a sinistra della figura 3.5. Puoi pensare a questa mappa come a un insieme di probabilità “basato sui soli sensori”, ovvero cosa penserebbe la macchina a proposito della sua posizione basandosi sui soli sensori esterni e in assenza di qualsiasi informazione a priori?

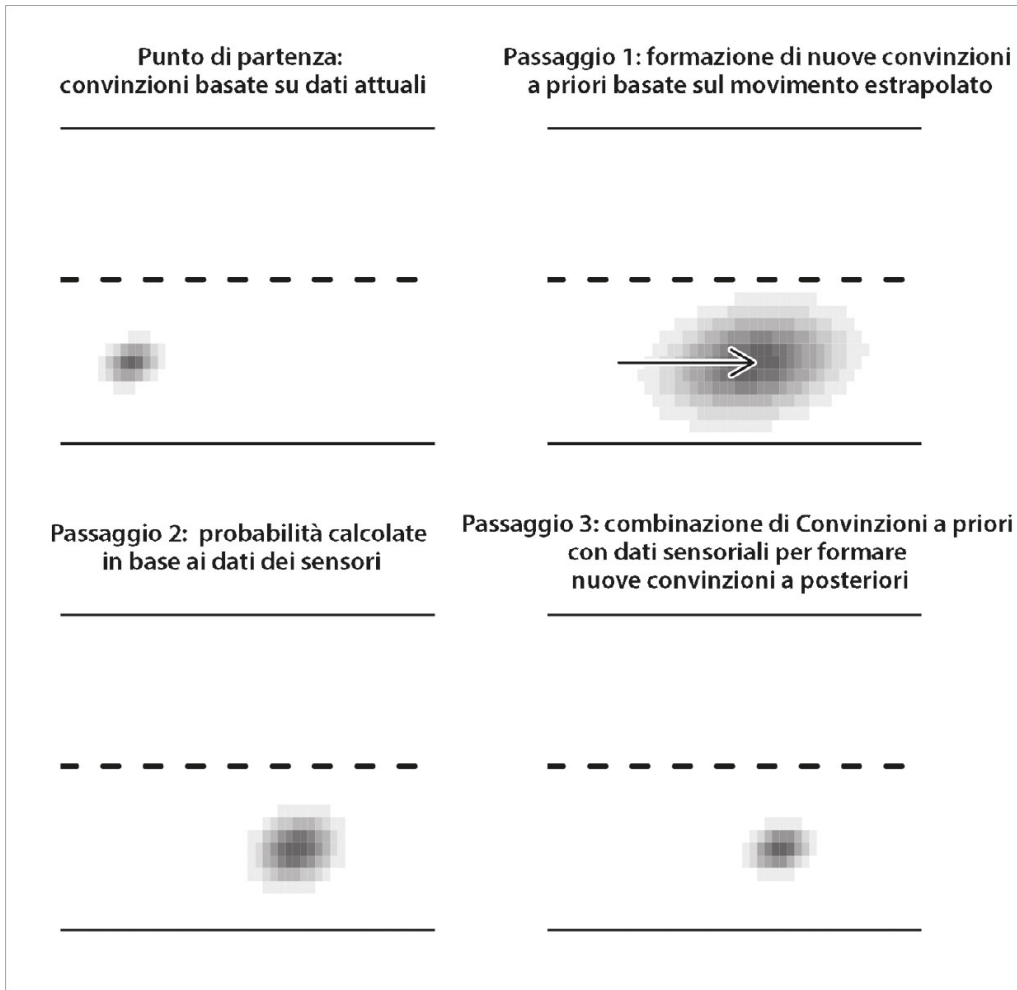


Figura 3.5 Come una macchina a guida autonoma utilizza la regola di Bayes per aggiornare le sue “convinzioni” sulla propria posizione.

Tuttavia la macchina *possiede* informazioni a priori, e dunque il terzo e ultimo passaggio è la sintesi. Usando la regola di Bayes, le probabilità a priori basate sull’extrapolazione (passaggio 1) sono combinate con i dati dei sensori (passaggio 2). Nel pannello in basso a destra puoi vedere questa nuova mappa di probabilità a posteriori, che fornisce la risposta aggiornata alla domanda fondamentale: «Dove mi trovo?». È cruciale notare che la palla di probabilità a posteriori è meno allargata sia di quella basata sulle probabilità a priori sia di quella basata sui soli dati sensoriali. Due sorgenti di informazione implicano di solito minore incertezza di quella che otterresti da una sola delle due.

Abbiamo trascurato molti dettagli. Ecco il più grande: nell’esempio precedente abbiamo ipotizzato che la strada fosse un sistema di riferimento fissato e che l’unica variabile sconosciuta fosse la posizione dell’automobile all’interno di quel sistema. Si tratta della L in *SLAM* e sta per

“localizzazione”. Ma non bisogna dimenticare la M di “mappatura”. In realtà, la strada stessa è sconosciuta e tutte le sue caratteristiche sono soggette allo stesso trattamento bayesiano. I bordi della strada, la segnaletica delle corsie, i pedoni, le altre macchine, persino i canguri sono tutti rappresentati da palle di probabilità le cui posizioni vengono costantemente aggiornate a ogni input di dati dai sensori.

Come la regola di Bayes
può renderci più intelligenti

Agli occhi della regola di Bayes, trovare un sottomarino disperso e trovare la tua posizione lungo una strada sono problemi molto simili. Ma la regola di Bayes è molto più di questo. In realtà, se pensiamo alle sue applicazioni nella vita di tutti i giorni, è una delle equazioni più utili mai scoperte: una dose matematica perfetta di antidogmatismo che ci dice quando essere diffidenti e quando essere di mente aperta. Pensa a tutte le nuove informazioni che ricevi ogni giorno. La regola di Bayes risponde a una domanda molto importante: quando è bene che quelle informazioni ti facciano cambiare idea, e di quanto?

Probabilmente, nel corso della tua vita, non prenderai mai carta e penna per affrontare la matematica della regola di Bayes, e va benissimo così. Il punto è che, anche se non lo fai, imparare a guardare il mondo allo stesso modo di un'automobile bayesiana – in termini di dati e convinzioni a priori – può aiutarci a diventare più saggi. Ecco due esempi chiave.

Regola di Bayes in diagnostica medica

Inizieremo da un esempio con numeri molto chiari, in cui anche esperti di elevata formazione ottengono risultati sbagliati perché non applicano bene la regola di Bayes.

Immagina di essere un dottore e che una donna di quarant'anni di nome Alice entri nel tuo studio per una mammografia di controllo. Sfortunatamente, l'esito della mammografia è positivo e dunque la donna potrebbe avere un tumore al seno. Ma sai bene, grazie ai tuoi studi, che nessun test è perfetto e che il test di Alice potrebbe essere un falso positivo. Che cosa le dovresti dire riguardo alla probabilità di avere un tumore, dato l'esito positivo della mammografia? Ecco alcuni fatti per aiutarti nella decisione.

- L'incidenza del tumore al seno nella fascia di età in cui si trova Alice è dell'1%. Ovvero, su 1000 donne di quarant'anni sottoposte a mammografie di routine, circa dieci hanno un tumore al seno.
- Il test ha un tasso di identificazione dell'80%: se lo effettuiamo su dieci donne con il tumore, ne rileverà otto, in media.
- Il test ha un tasso di falsi positivi del 10%: se lo effettuiamo su cento donne senza tumore al seno, lo attribuirà erroneamente a dieci di esse, in media.

Alla luce di questi numeri, qual è la probabilità a posteriori $P(\text{tumore} \mid \text{mammografia positiva})$?

La risposta, secondo la regola di Bayes, è abbastanza piccola: solo il 7,4%. Questo numero potrebbe sorprenderti, ma non saresti il solo: un numero incredibilmente grande di medici stima una probabilità molto più alta. In uno studio famoso, cento medici hanno ricevuto le stesse informazioni che ti abbiamo appena dato, e novantacinque di essi ha stimato che $P(\text{tumore} \mid \text{mammografia positiva})$ fosse tra il 70% e l'80%.¹⁴ Non è solo sbagliato: è sbagliato di un fattore dieci.

Questo esempio pone due domande. La prima è: perché la probabilità a posteriori $P(\text{tumore} \mid \text{mammografia positiva})$ è solo del 7,4%, nonostante la mammografia sia accurata per l'80%? La seconda è: come possono così tanti medici sbagliare in modo così evidente?

La risposta alla prima domanda è questa: la maggior parte delle donne con una mammografia positiva è sana perché la grandissima maggioranza delle donne che effettua una mammografia è sana. In termini semplici, *il tumore ha una bassa probabilità a priori*. Possiamo visualizzarlo con un *diagramma a cascata*, che è in pratica una versione “per la vita di tutti i giorni” della mappa di probabilità che una macchina a guida autonoma utilizza per orientarsi. Nella figura 3.6, esaminiamo una ipotetica coorte di 1000 donne, tutte quarantenni, sottoposte a mammografia di controllo. Il ramo di sinistra mostra dieci donne (1% di 1000) che hanno davvero il tumore al seno. Poiché il test è accurato per l'80%, ci aspettiamo che due di questi dieci casi non siano riconosciuti e otto siano individuati. Il ramo destro mostra 990 pazienti senza tumore. Poiché il test ha un tasso di falsi positivi del 10%, ci aspettiamo che circa 890 casi siano correttamente individuati e 100 siano erroneamente diagnosticati, arrotondando un po'.¹⁵

Dunque alla base della cascata avremo 1000 casi, suddivisi come segue.

- 108 mammografie positive. Otto di queste sono veri positivi, ovvero tumori

correttamente diagnosticati. I restanti 100 sono falsi positivi, ovvero donne sane erroneamente diagnosticate dal test.

- 892 mammografie negative. Due di queste sono falsi negativi, ovvero tumori non diagnosticati. I restanti 890 sono veri negativi, ovvero donne correttamente identificate come sane.

Ognuno di questi 1000 casi è equiprobabile, per cui usiamo lo stesso colore per tutti i quadratini. Il fatto che il tumore sia poco probabile non è indicato dalla colorazione, ma dai numeri: solo dieci di questi 1000 quadrati corrispondono a casi reali di tumore.

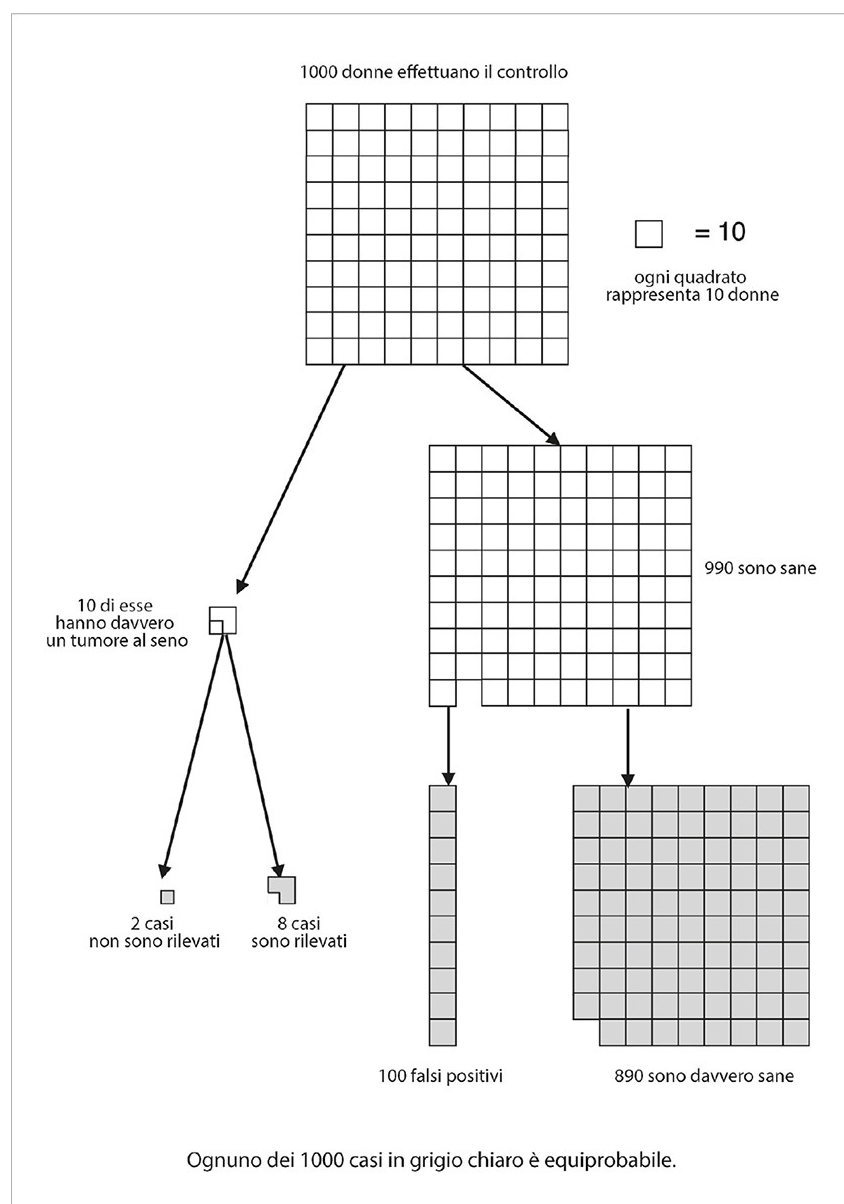


Figura 3.6 Un diagramma a cascata che segue un'ipotetica coorte di 1000 donne di quarant'anni sottoposte a mammografie di controllo.

Usiamo ora questo diagramma per analizzare il caso della tua ipotetica paziente, Alice. Quando entra nello studio medico, sai che Alice sarà una delle 1000 donne alla base del diagramma a cascata, ma non sai esattamente quale. Quando ricevi la mammografia con esito positivo, sai che Alice fa parte delle 108 donne che hanno ottenuto lo stesso risultato. Dunque torniamo al diagramma e coloriamo quei 108 casi con un grigio più scuro, scartando gli altri 892 casi colorandoli di bianco, come in figura 3.7.

Otto di queste 108 mammografie positive sono casi reali di tumore, mentre 100 sono falsi positivi. Dunque la probabilità a posteriori che Alice abbia un tumore, $P(\text{tumore} \mid \text{mammografia positiva})$, è circa $8/108$, ovvero circa il 7,4%.

E questa è la regola di Bayes. La probabilità a priori del tumore era 1%. Dopo aver visto i dati, la probabilità a posteriori del tumore diventa 7,4%, molto più alta della probabilità a priori, ma ancora molto lontana dal 70-80% stimato dalla gran parte dei medici. (Se vuoi vedere l'equazione che porta a tutto questo, vai alla fine del capitolo.)

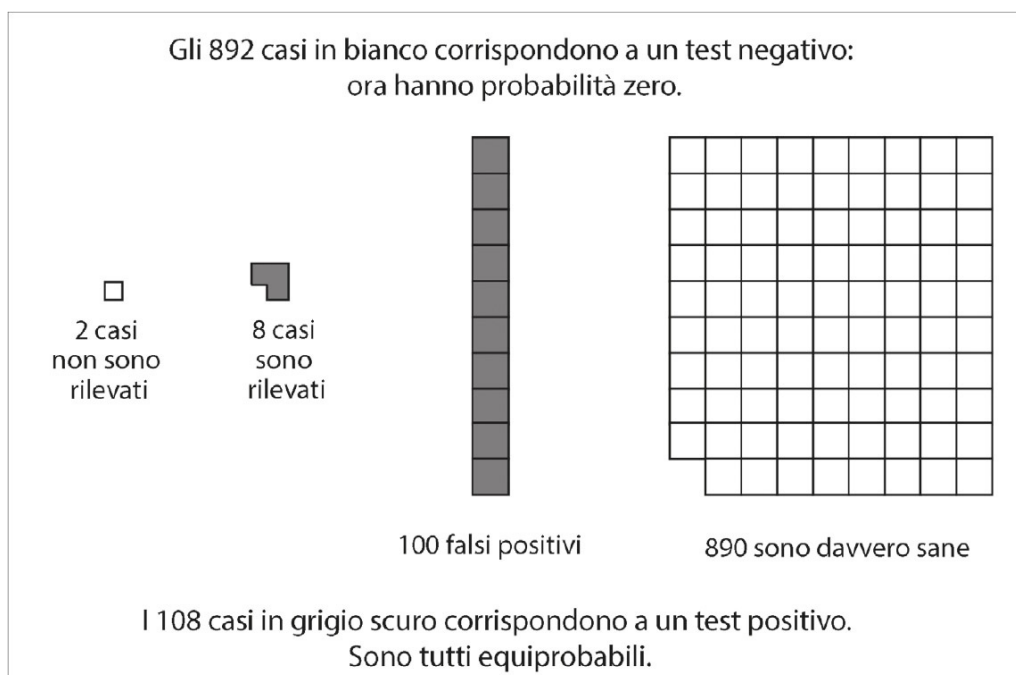


Figura 3.7

Torniamo ora alla seconda domanda che ci siamo posti in precedenza. Perché, quando è stato chiesto loro di stimare la probabilità a posteriori $P(\text{tumore} \mid \text{mammografia positiva})$, moltissimi medici hanno fornito un numero dieci volte maggiore di quello vero? In poche parole, i medici stavano ignorando la

probabilità a priori, una fallacia chiamata “omissione della probabilità primaria”. Le stime del 70-80% da parte dei medici non tenevano conto del basso tasso di incidenza del tumore nella popolazione (1%), che implica che la maggior parte dei test positivi deve essere un falso positivo. I medici si concentravano, invece, su un solo numero: il fatto che il test fosse “accurato all’80%”, ovvero che rileva l’80% dei casi reali di tumore. Facevano troppo affidamento sui dati e non abbastanza affidamento sulla probabilità a priori.

Possiamo trarre tre morali da questa storia. Primo, mai chiedere al tuo medico: «Quanto è accurato questo test?». Nel migliore dei casi, otterrai la risposta giusta alla domanda sbagliata. Chiedi invece: «Qual è la probabilità a posteriori che io sia malato?». (Ma preparati a uno sguardo torvo perché il tuo medico potrebbe non sapere di cosa stai parlando.)

Secondo, anche se la regola di Bayes è espressa normalmente in forma di equazione, raramente avrai bisogno di questa equazione per calcolare una probabilità a posteriori. Puoi fare semplicemente un diagramma a cascata come quello nella pagina precedente, seguendo un’ipotetica coorte di individui attraverso il processo di raccolta dati. Potrai gustare la tua omelette bayesiana senza dover rompere l’uovo matematico.

Infine, non dimenticare mai la probabilità primaria, nota anche come probabilità a priori, quando interpreti i tuoi dati. La regola di Bayes dice che la corretta probabilità a posteriori si trova sempre combinando i dati e la probabilità a priori, proprio come fa una macchina a guida autonoma lungo una strada.

La regola di Bayes e gli investimenti

Quando vieni a conoscenza del problema del trascurare le probabilità primarie, inizi a vederlo ovunque. Come mostra il nostro prossimo esempio, si tratta di una fallacia particolarmente importante da tenere in considerazione nel momento in cui si prende una delle più importanti decisioni in ambito finanziario: come investire i propri soldi per garantirsi una buona pensione.

In generale, ci sono due strategie popolari di investimento per creare un portafoglio pensionistico: indicizzazione e azzardo. “Azzardo” significa che cerchi di indovinare il cavallo vincente, affidando i tuoi soldi a un gestore di fondi che tenta di ottenere risultati superiori a quelli di mercato. “Indicizzazione” significa che rinunci a tentare di *sconfiggere* il mercato, ma lo *compri* sotto forma di un ampio indice di azioni, come S&P 500.

I fautori della strategia d'azzardo affermano che è assolutamente possibile battere il mercato nel lungo termine. La loro argomentazione migliore a supporto di questa affermazione è lunga solo due parole: Warren Buffett. Buffett, noto anche come l'“oracolo di Omaha”, spicca nella storia degli investimenti. Le sue performance sono incredibili: dal 1964 al 2014, un risparmiatore che avesse investito nella società finanziaria di Buffett, Berkshire Hathaway, avrebbe trasformato 10 000 dollari in 182 milioni di dollari. La costanza temporale dell'efficacia di Buffett è altrettanto notevole: le sue scelte di azioni hanno ottenuto risultati migliori dello S&P 500 su quasi tutti i periodi quinquennali a partire dalla metà degli anni sessanta. E anche se Buffett è la più famosa storia di successo di Wall Street, ce ne sono state altre, un pugno di veri maghi del mercato, da Joel Greenblatt a Peter Lynch, i cui risultati sono troppo impressionanti per essere attribuibili unicamente alla fortuna. Gli investitori che hanno riconosciuto e si sono fidati di questi straordinari gestori di fondi sono stati riccamente ricompensati.

Ma, al di là di questi rari geni, esiste una dura realtà numerica: la maggior parte dei gestori di fondi non assomiglia neanche un po' a Warren Buffett. Le loro performance sono state particolarmente deludenti nei dieci anni tra il 2007 e il 2016, periodo caratterizzato da una crisi storica e da un conseguente rialzo impetuoso dei mercati. Erano le condizioni ideali per gestori intelligenti eppure, secondo Standard & Poor's, l'86% dei fondi azionari si comportò peggio dei propri indici di riferimento in quel periodo. In Europa, andò ancora peggio: il 98,9% dei fondi nazionali, il 97% dei fondi dei mercati emergenti e il 97,8% dei fondi globali fu al di sotto dei livelli, al netto dei costi. I gestori di fondi olandesi fecero l'en plein: il 100% di essi non riuscì ad andare meglio dei propri indici di riferimento.¹⁶

La morale è che esistono geni dell'investimento, ma sono difficili da trovare. Come dovrebbe tutto ciò condizionare la tua strategia di investimento? È meglio riparare su un fondo indicizzato? O è meglio scommettere alto, nella speranza di trovare uno di quei rari geni in grado di battere il mercato?

Se decidi di scommettere, allora dovresti essere onesto con te stesso riguardo al tuo obiettivo: devi condurre una tua personale ricerca bayesiana mirata a scovare il nuovo Warren Buffett. Le possibili “località di ricerca” sono tutti i diversi gestori di capitale e i tuoi “dati di ricerca” sono le informazioni storiche sui risultati ottenuti dai singoli gestori. Quali sono le

possibilità che la tua ricerca riesca a trovare una delle rare eccezioni nel mare di gestori che non è in grado di battere il mercato?

Purtroppo la regola di Bayes fornisce una risposta molto chiara: le possibilità sono infime.

Per capire il perché, useremo una metafora che fa uso della probabilità per agevolare l'approccio: gran parte dei gestori si comportano come una moneta lanciata in aria. In alcuni anni esce testa, e battono il mercato. In altri anni esce croce, e il mercato vince. (Ovviamente, indipendentemente dal fatto che esca testa o croce, vogliono comunque essere pagati.) Un raro investitore come Warren Buffett è, metaforicamente parlando, come una moneta con due teste: batte il mercato anno dopo anno, senza eccezioni.

Con questa metafora, se dovessimo confrontare la performance su dieci anni di Warren Buffett con quella di cinque gestori normali, vedremmo qualcosa di simile alla seguente tabella.

	Anno 1	Anno 2	Anno 3	Anno 4	Anno 5	Anno 6	Anno 7	Anno 8	Anno 9	Anno 10	T totali
Jane Doe	T	T	T	C	T	C	C	T	C	C	5
John Bull	C	C	T	T	T	T	C	C	C	T	5
Jean Dupont	T	T	C	T	T	T	T	C	C	T	7
Jan Jansen	C	C	T	T	T	C	C	C	T	C	4
Max Mustermann	C	C	T	T	C	C	C	C	C	T	3
Warren Buffett	T	T	T	T	T	T	T	T	T	T	10

Per i nostri cinque investitori medi, la performance è praticamente casuale. Ma la performance di Buffett è guidata dalla sua superiore abilità nello scegliere le azioni, quella particolare moneta con due teste che tiene da parte in una cassaforte di Omaha, in Nebraska. Come puoi vedere dalla tabella, la sua eccellente performance spicca nettamente sul resto degli investitori.

Ma c'è un problema: a Wall Street devi emergere da una folla molto più numerosa. Non ci sono solo cinque gestori mediocri che lanciano monete e riscuotono costi di gestione. Ce ne sono migliaia e migliaia, e ci sono buone

possibilità che almeno qualcuno di essi infili una lunga serie di vittorie, solo in base al caso.

Qui entra in gioco la regola di Bayes. Immagina un vaso contenente 1024 monete. Un tuo amico mette nel vaso una moneta con due teste, mescola per bene e ti chiede di estrarre una singola moneta. Vuoi sapere se sei riuscito a estrarre la moneta con due teste, ma le regole ti impediscono di guardare semplicemente su entrambi i lati: non potresti farlo nel mondo reale, poiché ogni gestore di fondi possiede qualche geniale idea di marketing per apparire simile a una moneta con due teste. Dunque sei obbligato a condurre un test *statistico* lanciando la moneta dieci volte.

Supponi ora che l'esito dei dieci lanci sia stato sempre testa. Sulla base di questo dato, hai in mano la moneta con due teste o una qualsiasi delle altre 1024 monete normali? Per rispondere con la regola di Bayes, consideriamo i seguenti dati:

- Ci sono 1025 monete nel vaso: 1024 sono normali, una ha testa su entrambi i lati.
- La moneta con due teste mostra sicuramente testa dieci volte di fila.
- Qualsiasi altra moneta ha una probabilità di $1/1024$ di mostrare testa per dieci volte di fila. (Questo valore è stato calcolato moltiplicando $1/2$ per se stesso 10 volte.) Dunque, tra le 1024 monete normali nel vaso, ce ne aspettiamo una che mostri testa dieci volte di fila.

Possiamo organizzare queste informazioni in una tabella:

	Almeno una croce	Dieci teste di fila
Monete normali	1023 (veri negativi)	1 (falso positivo)
Moneta con due teste	0 (falsi negativi)	1 (vero positivo)

Questa matrice ci dice che, tra le 1025 monete nel vaso, ci aspettiamo che due di esse mostrino testa dieci volte di fila. Solo una di esse è in realtà la moneta a due teste. C'è solo una probabilità del 50% che tu la abbia in mano, anche dopo dieci lanci.

Confrontiamo ora questo scenario con il linguaggio da imbonitore che potresti sentire da un gestore con uno storico al di sopra della media:

Guardate alle mie performance passate. Gestisco il mio fondo da dieci anni e ho battuto il mercato ogni singolo anno. Se fossi semplicemente uno di quei gestori medi di fondi scadenti, sarebbe molto improbabile: meno di una possibilità su mille.

La matematica di questo scenario è esattamente la stessa di quella del vaso pieno di monete. Metaforicamente, il gestore sta affermando di essere una moneta con due teste, basandosi sulle dieci teste uscite di fila (ha battuto il mercato ogni anno per dieci anni). Ma dal tuo punto di vista le cose non sono così chiare. Dovresti riconoscere che il messaggio di marketing sta confondendo due probabilità diverse: $P(\text{risultati positivi per dieci anni} \mid \text{buon gestore})$ e $P(\text{buon gestore} \mid \text{risultati positivi per dieci anni})$. Ma ricorda la lezione che abbiamo imparato dalla storia di Abraham Wald: le probabilità condizionate non sono simmetriche.

Ma quindi il gestore è bravo o fortunato? Facciamo il calcolo bayesiano con le due diverse ipotesi a priori. Iniziamo supponendo che l'1% dei gestori sia davvero bravo e che il restante 99% tiri semplicemente monete in aria. Sotto queste ipotesi, immaginiamo di seguire una coorte di 10 000 gestori per dieci anni.

- Tutti i 100 gestori eccellenti (1% di 10 000) batteranno il mercato ogni anno.
- Un gestore mediocre ha una possibilità su 1000 di battere il mercato dieci volte di fila.^{*b} Poiché ci sono 9900 gestori mediocri, ci aspettiamo che dieci di essi battano il mercato per dieci anni, semplicemente per caso.

Dunque ci sono 110 gestori che battono il mercato: 100 sono bravi e dieci sono fortunati. Di conseguenza, la probabilità a posteriori $P(\text{batte il mercato} \mid \text{dieci anni di vittorie})$ è $100/110$, ovvero circa il 91%.

Cosa accadrebbe se tu credessi che il talento fosse molto più raro, per esempio $P(\text{bravo gestore}) = 1/10\,000$? Sotto questa ipotesi, la probabilità a posteriori diventa molto più bassa:

- Ora c'è solo un gestore eccellente che batte il mercato ogni anno.
- Tra i 9999 gestori mediocri, ce ne aspettiamo ancora dieci che battano il mercato ogni anno, semplicemente per caso.

Dunque abbiamo $P(\text{batte il mercato} \mid \text{dieci anni di vittorie}) = 1/11$, ovvero circa il 9%.¹⁷

La regola di Bayes suggerisce che la giusta reazione a uno storico di successo per un investitore dipende fortemente dalla probabilità a priori che assegni al fatto che i gestori eccellenti siano comuni o rari. Ma tutte le evidenze disponibili mostrano che i veri talenti sono molto rari. Ricorda tutte quelle pessime statistiche su quanti pochi fondi riescono a comportarsi meglio dei propri indici di riferimento in un *singolo* anno, figurarsi per dieci anni di fila.

Tutto ciò ha una conseguenza molto importante per il risparmiatore. Potrebbero esserci molti gestori bravi in giro, ma la regola di Bayes implica che, senza uno storico di successi *molto* lungo, tali geni non possono essere distinti da un gruppo più grande di mediocri con molta fortuna. Anche il genio di Warren Buffett divenne evidente solo dopo decenni. Dunque, quando si tratta di cercare un gestore di successo, la lezione della regola di Bayes è: non provarci nemmeno. È persino più difficile di trovare un sottomarino disperso in 4000 chilometri di mare aperto. È certamente meglio investire in un indice azionario e obbligazionario ampio, piuttosto che cercare di individuare il cavallo vincente.

In ogni caso, la speranza è l'ultima a morire. Ma se il tuo ottimismo non fosse stato scalfito dalla dura realtà della regola di Bayes, ti lasciamo con questa riflessione. Se spera di trovare il nuovo Warren Buffett, puoi orientarti solo attraverso slogan di marketing; all'inizio della carriera, i dati sulle performance sono quasi del tutto inutili. Quindi sii cauto o finirai per scegliere il gestore dalla faccia di bronzo piuttosto che quello dalle uova d'oro.

Post scriptum

Abbiamo introdotto la regola di Bayes come principio guida per trovare un sottomarino disperso, ma oggi la ricerca bayesiana è un piccolo settore industriale, con intere aziende che fanno consulenza su operazioni di ricerca e soccorso.¹⁸ Per esempio, ricorderai la tragedia del volo Air France 447, che cadde nell'oceano Atlantico sulla rotta per Rio de Janeiro, nel giugno del 2009. Alla fine del 2011 la ricerca del relitto andava avanti già da due anni. A quel punto venne chiamata un'azienda specializzata in ricerca bayesiana che disegnò una mappa di probabilità e l'aereo venne trovato nel giro di una settimana di ricerche sottomarine.¹⁹

Inoltre l'idea principale della regola di Bayes – aggiornare la conoscenza a priori alla luce di nuove prove – si applica ovunque, non solo al volante di una macchina a guida autonoma. I biologi la usano per capire il ruolo dei nostri geni nello sviluppo tumorale. Gli astronomi la usano per trovare pianeti che orbitano intorno ad altre stelle ai confini della nostra galassia. È stata usata per rilevare i casi di doping alle Olimpiadi, per filtrare la posta indesiderata nella tua casella email e per aiutare i tetraplegici a controllare bracci robotici con il pensiero, proprio come Luke Skywalker.²⁰ E, come hai visto, è essenziale per orientarsi nel territorio insidioso della salute e della finanza.

Dunque la regola di Bayes è molto più di un principio-guida per trovare qualcosa che abbiamo perso. Certo, ha aiutato la ricerca dello *Scorpion* e aiuta le macchine a guida autonoma a trovare la propria posizione sulla strada. Ma può anche aiutarti a trovare saggezza nel mare di informazioni che ricevi ogni giorno.

RIQUADRO: LA REGOLA DI BAYES IN FORMA DI EQUAZIONE

Nella vita di tutti i giorni, non hai bisogno di conoscere l'equazione della regola di Bayes per essere in grado di applicare la logica sottostante. Le mappe e i diagrammi a cascata, come quelli presenti in questo capitolo, possono portarti molto lontano con pochissima matematica. Ma se sogni una carriera nella scienza dei dati o se semplicemente vuoi saperne di più, è bene dare un'occhiata a quell'equazione. Ecco quindi come viene insegnata la regola di Bayes nei corsi universitari di IA o di statistica.

Useremo la lettera H per rappresentare un'ipotesi che può essere vera o falsa, e la lettera D per rappresentare i dati rilevanti. La regola di Bayes ci dice come utilizzare i dati per trasformare la probabilità a priori dell'ipotesi, $P(H)$, nella probabilità a posteriori, $P(H | D)$:

$$P(H | D) = \frac{P(H) \cdot P(D | H)}{P(D)}$$

Nel nostro esempio dell'esame medico, H è l'ipotesi che una paziente abbia il tumore al seno e D è l'informazione che la sua mammografia ha dato esito positivo. Sappiamo che l'1% delle pazienti ha il tumore al seno: $P(H) = 0,01$. Sappiamo anche che il test è accurato all'80% nel rilevare il tumore al seno, se presente: $P(D | H) = 0,8$. L'ultima cosa di cui abbiamo bisogno è $P(D)$, la probabilità totale di avere un test positivo. Dal nostro diagramma a cascata, sappiamo che su 1000 test circa 108 di essi avrà un esito positivo: 8 veri positivi e 100 falsi positivi. Dunque $P(D) = 108/1000 = 0,108$.

È tutto ciò di cui abbiamo bisogno. Inseriamo questi tre numeri nella regola di Bayes per calcolare la probabilità a posteriori di un tumore, data la positività del test:

$$P(H | D) = \frac{0,01 \cdot 0,8}{0,108} = 0,074$$

È la stessa probabilità (7,4%) che abbiamo ottenuto dal diagramma a cascata.

***a** Dal nome di Hans Moravec, un pioniere nel campo della robotica.

***b** Abbiamo arrotondato le cifre.

AMAZING GRACE

Da Babele ai bit: di come le macchine hanno imparato a parlare la nostra lingua.

Da molto tempo gli umani tentano di far comprendere la loro lingua alle macchine, ma le macchine continuano a commettere errori stupidi. Ti sarà certamente capitato di dover combattere contro il correttore automatico del tuo telefono. E magari sei stato all'estero, e hai visto come i servizi di traduzione via internet possano confondere parecchio le idee, allo zoo («Non dare da mangiare agli animali: dare tutto il cibo all'inserviente») o nelle lavanderie automatiche («Abbassa i tuoi pantaloni qui»). Una battuta ricorrente tra gli esperti di IA è che se Stanley Kubrick avesse girato *2001: Odissea nello spazio* oggi, la conversazione tra Dave e il malefico supercomputer HAL 9000 suonerebbe così:

Dave

Apri la porta di servizio della navetta, HAL. (Open the pod bay doors, HAL.)

HAL

Ho fatto una ricerca sul web e ho trovato diversi risultati per iPod, Dave. Vuoi vederli?

Ma le macchine fanno anche errori più sottili. Al supercomputer Watson di IBM è stato chiesto, in preparazione a una sfida a *Jeopardy!*^{*a} con un concorrente umano, di trovare due parole in rima per indicare «un termine usato nella boxe per indicare un colpo sotto la cintura». La risposta corretta in rima era *low blow* (colpo basso), ma Watson rispose *wang bang*,^{*b} un termine che non compariva nel suo database e che doveva aver concepito di sua iniziativa.

Ok, scatenati pure con le offese. Ma ti chiediamo di tenere a mente un paio di fatti. Primo, anche gli umani fanno errori nel parlare. Proferiscono barbarie come *for all intensive purposes*^{*c} o *at his beckon call*. Intendono male i testi delle canzoni, come nel caso di Billy Joel («We didn't start the fire, it was always burning, said the worst attorney»)^{*d} o di Madonna («Like a virgin, touched for the thirty-first time»). Fanno anche errori di traduzione. Per esempio, nel 2009, il segretario di stato Hillary Clinton consegnò in pompa magna un dono al ministro degli esteri russo: un grande pulsante rosso su cui doveva essere scritta la parola “Reset” in inglese e in russo, in modo da sottolineare la politica di resettaggio delle relazioni con la Russia portata avanti dall'amministrazione Obama. Tuttavia pare che tale politica non abbia funzionato molto bene e nemmeno il dono, dato che il termine russo riportato non era “reset” ma “sovraccarico”.

La seconda cosa da considerare è che le macchine stanno migliorando molto velocemente con il linguaggio. (Devi ammettere che *wang bang* è un esempio creativo di cronaca pugilistica.) Gli esperti di IA usano l'espressione *natural language processing* (analisi del linguaggio naturale), o NLP, per descrivere come i computer si relazionano al linguaggio. Nel corso degli ultimi anni, c'è stata una crescita incredibile dei sistemi NLP:

- Assistenti digitali come Echo della Amazon e Google Home sono *molto* meglio dei maldestri programmi di riconoscimento vocale di qualche anno fa. Possono segnare appuntamenti, fare la lista della spesa, scegliere una canzone o addebitarti qualcosa sulla carta di credito, tutto comandato vocalmente con un livello di accuratezza nella trascrizione che sarebbe sembrato fantascienza fino a poco tempo fa.
- La versione di Google Translate del 2016 ha rappresentato un enorme progresso rispetto ai precedenti sforzi nel campo della traduzione automatica. Il software ora produce traduzioni di tutto rispetto in oltre 100 lingue, molte delle quali direttamente dalla fotocamera del tuo smartphone, come per esempio il menu di un ristorante o un cartello in una stazione ferroviaria. Skype fa qualcosa di simile nel corso di una videochat, in tempo reale.
- I chatbot – software concepiti per simulare una conversazione umana – si stanno diffondendo rapidamente nel mondo digitale. Sono particolarmente popolari su Messenger, dove puoi chiedere a un bot di prenotare un viaggio tramite Kayak o dare il tormento a un venditore per controllare lo stato di una consegna in ritardo. I chatbot sono ancora più popolari in Cina, dove gran parte delle startup creano un loro bot ufficiale su WeChat – che ha un bacino di 930 milioni di utenti – ancora prima di creare una pagina web.

Le macchine stanno anche imparando a scrivere. L'Associated Press ha iniziato a usare un algoritmo che riesce a scrivere un resoconto più che accettabile di una partita di baseball a partire dal punteggio: al momento, viene usato per i match universitari in cui non vi sono reporter presenti. Il sistema ha anche imparato a inserire luoghi comuni del linguaggio sportivo e riceve i dati alla fine di ogni incontro. Gli analisti della Salesforce hanno recentemente sviluppato un programma simile che riesce a riassumere in modo accurato lunghi articoli per aiutare i dipendenti di un'azienda ad assimilare notizie più velocemente. E, da bravi accademici passati attraverso le forche caudine della *peer review*, non ci siamo affatto meravigliati quando abbiamo saputo che un algoritmo creato da ricercatori dell'Università di Trieste scrive *peer reviews* false ma abbastanza realistiche da trarre in inganno gli editori delle riviste scientifiche.¹

E poi c'è il progetto dello sviluppatore Andy Herd, che ha allenato una rete neurale con alcuni copioni della popolare serie televisiva degli anni novanta *Friends* per provare a scrivere nuovi episodi. I risultati sono indiscutibilmente *nonsense*, ma esattamente allo stesso modo in cui lo era *Friends*. Monica è aggressiva in modo bizzarro, Chandler si lamenta un sacco e ci sono anche dei cammei di star del cinema degli anni novanta:

Van Damme

Andrò al cesso.

Monica

Ma ti prego, continua pure a parlare!

Phoebe

Wow, amica, come sei aggressiva...

Chandler

E quindi a Phoebe piacciono i miei slip.

Monica

Chicken Bob!

Chandler

(Vestito da muffin) (Corre verso le ragazze piangendo)

Posso avere dei regali?²

Immagina cosa otterresti con più di 236 episodi, parecchi per una *sit-com*, ma ancora molto pochi per allenare una rete neurale standard.

Quindi, se vuoi capire come sarà un futuro con sistemi di IA in grado di comprendere il linguaggio, la domanda interessante non è perché a volte compiono errori sciocchi, ma come abbiano fatto a imparare ad ascoltare, a parlare e anche a scrivere in modo così efficace.

La storia di due rivoluzioni

In realtà abbiamo a che fare con due rivoluzioni: la rivoluzione del linguaggio di programmazione, che ebbe il suo culmine negli anni cinquanta, e la rivoluzione del linguaggio naturale, che stiamo vivendo in questi anni. Esse differiscono per molte cose importanti, ma un concetto comune le unisce: per far sì che una macchina capisca delle parole è necessario fornirglielie in un linguaggio che essa riesca a elaborare. Ovvero, bisogna convertire le parole in numeri.

Per decenni, l'unico approccio efficace è stato quello di tipo *top-down*, basato su regole predefinite. Pensa a queste regole come a un contratto che stabilisca come due soggetti, la “macchina” e l’“umano”, possano utilizzare il linguaggio per interagire. Pensa al contratto legale più dettagliato che tu riesca a concepire, scritto da legali con parcelle elevatissime. E moltiplica per cento questo livello di dettaglio.

- C'è un set di regole per gli umani, chiamato linguaggio di programmazione. (Esempi famosi sono Python, Java e Perl.) Un linguaggio di programmazione contiene simboli matematici come + e =, insieme a un vocabolario limitato, solitamente scritto in font a larghezza fissa per intimidire le persone: IF, THEN, WHILE ecc. Il linguaggio possiede anche una grammatica: regole per combinare le parole in “frasi legali” che dicono alla macchina di fare qualcosa in particolare.
- Poi c'è un set di regole per la macchina, codificato all'interno di un cosiddetto “compilatore”.³ Queste regole agiscono dietro le quinte e sono invisibili al programmatore umano. Forniscono alla macchina le singole istruzioni per tradurre ogni possibile frase dal linguaggio di programmazione al “linguaggio macchina” interno fatto di bit e vettori.

Questo contratto è interpretato nella maniera più letterale possibile. Se scrivi una determinata frase nella grammatica del linguaggio di programmazione, la

macchina deve fare *esattamente* ciò che le dici. E se fai anche solo un piccolissimo errore, sbagliando a scrivere una parola o dimenticando un punto e virgola, la macchina ti mostra il dito medio (nel nostro linguaggio, 00100).

Fino a non molto tempo fa, una conversazione tra computer e umani poteva svolgersi solo in questi termini. Come apprenderai in questo capitolo, era già un enorme passo avanti rispetto ai primi tempi, in cui le persone erano obbligate a parlare con i computer usando il loro linguaggio “nativo” fatto di 0 e 1. Ma non era comunque abbastanza per poter sfruttare appieno la potenza del linguaggio umano nel trasmettere messaggi. Naturalmente possiamo chiedere ai computer di fare cose banali come puntare, cliccare, scorrere ecc. Ma sono compiti molto *rudimentali*. Immagina se dovessi comunicare con altre persone solo indicando oggetti o usando menu a tendina che escono dalle tue palpebre. Il linguaggio umano è molto più efficace e dagli anni cinquanta in poi, se volevi usare il linguaggio per dare ordini *sul serio* a un computer, la tua unica risorsa erano i linguaggi di programmazione.

Ora non è più così. All’incirca dal 2010, le migliori menti nel campo dell’IA hanno elaborato un secondo set di termini contrattuali, un New Deal dell’interazione linguistica uomo-macchina. Questo New Deal è di tipo *bottom-up* anziché *top-down*. Tanto per cominciare, buttiamo via il librone delle regole grammaticali predefinite e iniziamo a parlare alle macchine usando il nostro linguaggio naturale: inglese, cinese, coreano, qualsiasi esso sia. Le macchine devono capire cosa vogliamo dire e risponderci nella nostra lingua, senza avvocati in giro che suggeriscano loro di ignorare le nostre richieste se ci dimentichiamo un punto e virgola.

Per portare a termine questo New Deal, abbiamo dato alle macchine tre cose, il cui significato sarà spiegato nel corso del capitolo.

1. Giocattoli: GPU veloci e parecchia memoria.
2. Software sofisticati, sotto forma di reti neurali basate su “vettori parola”, un’idea molto intelligente al confine tra matematica e linguaggio che ci consente di tradurre parole in numeri e fornire regole di predizione.
3. Ma soprattutto, la miniera d’oro di dati che sono diventati disponibili negli ultimi due decenni, da quando cioè i prodotti del linguaggio umano sono espressi prevalentemente in forma digitale.

L’ultima è senz’altro la più importante. La comunicazione tra persone si basa su innumerevoli convenzioni di linguaggio, la maggior parte delle quali è data per scontata come, per esempio, la differenza tra le frasi «togli i pantaloni in

vetrina» e «*togliti i pantaloni in vetrina*», una sola delle quali può essere usata senza imbarazzo durante l’allestimento di un negozio di abbigliamento. Una convenzione di questo tipo è difficile da codificare in regole, perché ne esistono troppe. Che tu ci creda o no, il modo migliore per farle apprendere alle macchine è fornire loro un hard disk enorme pieno di esempi di conversazioni, e lasciare che se la cavino da sole per mezzo di un modello statistico.

Questo approccio al linguaggio, unicamente basato sui dati, può sembrare ingenuo, e fino a poco tempo fa non avevamo abbastanza dati a disposizione o computer abbastanza veloci per renderlo efficace. Oggi, tuttavia, funziona incredibilmente bene. In una conferenza del 2017, per esempio, Google ha audacemente proclamato che le macchine hanno raggiunto la parità con gli esseri umani nel campo del riconoscimento vocale, con un tasso di errore per singola parola nel dettato pari al 4,9%, decisamente meglio del 20-30% del 2013. Questo enorme salto nella performance linguistica è uno dei motivi per cui le macchine sembrano oggi così intelligenti. Si può ben dire, in effetti, che il riconoscimento vocale a livello di un essere umano è la più grande conquista dell’IA nell’ultimo decennio. Qual è stata la svolta, e come siamo arrivati fin qui? Che cosa sono i “vettori parola” e perché sono così utili? Perché i dati sono così importanti e perché non possiamo semplicemente dire a una macchina di seguire delle regole grammaticali prestabilite, come facciamo con i ragazzi a scuola, oppure chiederle di capire il linguaggio Python?

Per rispondere a queste domande, ti racconteremo la storia di Grace Hopper. Era soprannominata “Amazing Grace”, e non solo per il fatto di essere l’unica persona nominata in questo libro ad aver preso parte al David Letterman Show.^{*e} Hopper ottenne il dottorato in matematica a Yale nel 1934, prestò servizio nella marina statunitense durante la seconda guerra mondiale e continuò a servire il suo paese in uniforme per più di quarantadue anni. Fu la prima persona nella storia a far comprendere la lingua inglese a un computer. E quindi il grande racconto sulle macchine in grado di parlare, ascoltare e scrivere – Watson, Alexa, i chatbot, Google Translate e tutte le altre meraviglie linguistiche del mondo digitale – parte da Amazing Grace.

Grace Hopper, regina del software

Grace Hopper nacque a New York nel 1906. Da ragazza imparò in fretta che, per la sua famiglia, due cose rivestivano particolare valore: essere autosufficienti e servire la patria. Si trovava in vacanza insieme ai suoi

genitori nel New Hampshire, e stava facendo un giro in canoa da sola, quando all'improvviso un colpo di vento rovesciò la canoa e la scaraventò in acqua. Ma sua madre, che dalla riva la vedeva agitarsi nel lago, sembrava stranamente indifferente. Prese semplicemente un megafono e urlò «Ricordati del tuo bisnonno, l'ammiraglio!». Grace tornò prontamente a riva, trainando la canoa.⁴

Il bisnonno in questione era il contrammiraglio Alexander Wilson Russell, che da giovane si batté contro i pirati e in seguito prestò servizio nella marina unionista. Ma la genealogia militare di Grace si estendeva anche oltre. Per tutta la vita ascoltò le storie di Samuel Lemuel Fowler, un antenato che aveva marciato con il moschetto in spalla fino a Concord, Massachusetts, nel 1775 per combattere per il suo paese. Grace avrebbe fatto lo stesso 168 anni dopo, ma dalla parte degli inglesi anziché contro di loro.⁵

Nell'autunno del 1924, Grace Hopper fece rotta verso il Vassar College, determinata a prepararsi per il mondo del lavoro. In quell'anno il Vassar College introduceva tre nuovi corsi: "Maternità", "Marito e moglie" e "La famiglia come unità economica". Hopper decise di non seguirli, ma scelse "Elettromagnetismo", "Probabilità e statistica" e "Teoria delle variabili complesse". Decisamente incoraggiata da sua madre, si era sempre interessata alla matematica piuttosto che seguire i percorsi tradizionali per le donne dell'epoca. Il talento diede i suoi frutti al Vassar, dove si laureò con lode nel 1928 in matematica e fisica, e continuò a esprimersi a Yale, dove iniziò un dottorato in matematica.

Nel 1931, a tesi non ancora ultimata, Hopper tornò al Vassar come docente di matematica, e la sua passione e la sua curiosità per la materia furono contagiose. Diventò un'insegnante molto popolare; le iscrizioni al suo corso passarono da dieci a settantacinque, con tanto di lista d'attesa. Insegnava in modo non tradizionale, concentrandosi sulle applicazioni pratiche anziché sul formalismo. Insegnava la matematica dei dislocamenti, per esempio, portando l'intera classe in bagno e chiedendo a qualcuno di entrare nella vasca da bagno.⁶ Terminò la tesi a distanza, discutendola nel 1934, e continuò a insegnare al Vassar per il decennio successivo.

Hopper in guerra: Harvard Mark I

Lo scoppio della seconda guerra mondiale cambiò la vita di Grace per sempre. Nel 1942, con il ricordo vivido di Pearl Harbor e del suo bisnonno

bene in mente, provò ad arruolarsi tra le riserve della marina militare, uno dei pochi ruoli aperti alle donne. A trentacinque anni, tuttavia, era considerata troppo vecchia, e pesando quarantotto chili per 1,70 metri di altezza, le mancavano sette chili per soddisfare i requisiti minimi. Fu respinta. Ma la determinazione nel servire la patria era risolutamente insita nella sua famiglia. Dunque provò di nuovo, allegando documenti per richiedere l'esenzione dai requisiti minimi di peso. Stavolta fu accettata, e nel dicembre del 1943 entrò tra le riserve della marina.⁷ Il corso d'ingresso durò poco, come diceva Grace, «trenta giorni per imparare a prendere ordini, trenta giorni per imparare a dare ordini, e sei un ufficiale».⁸ Completò il corso come prima allieva tra i suoi 800 colleghi e fu nominata sottotenente di vascello nel giugno del 1944.

Per via delle sue capacità matematiche, Hopper pensava che sarebbe stata destinata all'unità di crittografia per decifrare i codici radio delle potenze dell'Asse. Ma c'era qualcosa di ancora più adatto a una persona con le sue abilità. Fu destinata a Cambridge, Massachusetts, e divenne la terza persona in grado di far funzionare Harvard Mark I, il primo computer digitale programmabile del paese. Anni dopo, quando Hopper era già famosa, e un intervistatore le chiese come decise di dedicarsi alla programmazione, rispose semplicemente «La marina mi ordinò di dedicarmi al primo computer degli Stati Uniti, e io ho obbedito».⁹

Il Mark I era stato concepito da un uomo chiamato Howard Aiken, costruito da IBM e donato a Harvard – dove Aiken era professore e comandante navale – per poter essere sfruttato a fini militari. Era un bestione lungo come un rimorchio e pesante più di due rinoceronti: cinque tonnellate, quindici metri di lunghezza, 2,5 metri di altezza e un metro di profondità. Aveva al suo interno 853 chilometri di cavi, 765 000 interruttori elettromeccanici e un elegante rivestimento modernista disegnato da Norman Bel Geddes. Il Mark I differiva dai computer precedenti perché era davvero polivalente. Poteva essere utilizzato per equazioni differenziali, algebra lineare, analisi armonica e statistica; poteva essere programmato per simulare un razzo, un sottomarino, un'onda radar o qualsiasi cosa ti venga in mente. Il suo inventore Aiken lo chiamava «macchina aritmetica generale» ma i giornali preferivano i termini «cervello robot» o «supercervello algebrico».¹⁰ Quando i pezzi grossi dell'esercito vennero a fargli visita, Aiken vantò il fatto che Mark I riuscisse a sommare tre numeri al secondo e a fare divisioni a più

cifre in 14,7 secondi.¹¹ È interessante confrontare questi numeri con quelli relativi a un iPhone X del 2017:

	Dimensioni (centimetri)	Peso (grammi)	Addizioni al secondo
Harvard Mark I (1944)	1550 × 250 × 90	4 284 140	3
Apple iPhone x (2017)	14 × 7 × 1	138	350 000 000 000

Considerando le operazioni al secondo per unità di volume, un iPhone X è quattro milioni di miliardi (4×10^{15}) di volte migliore. Ma il Mark I era in ogni caso molto più veloce di un essere umano nel masticare numeri. E inoltre sarebbero stati necessari altri settantatré anni perché il nuovo iPhone vedesse la luce.

Quando Hopper arrivò a Harvard, il suo ufficiale in comando le diede una settimana per imparare a programmare Mark I. Come vedrai tra poche pagine, si trattava di un lavoro lento e frustrante, e non c'erano né un manuale di istruzioni, né un chatbot di supporto tecnico, né tempo da perdere. Era l'estate del 1944. I soldati alleati stavano per attaccare le spiagge della Normandia e il team del Mark I doveva calcolare le tavole balistiche che consentivano ai soldati di utilizzare efficacemente la loro nuova artiglieria a lunga gittata. E non era l'unico compito importante del team. C'era il "problema K", nell'agosto del 1944: un insieme di calcoli immensamente complesso e altamente riservato richiesto da un laboratorio di Los Alamos, nel New Mexico. Il Mark I era prenotato per settimane quando arrivò questa richiesta. Ma la marina ordinò di riservare al matematico di Los Alamos – John von Neumann, che lavorava su un certo progetto Manhattan – qualsiasi ammontare di tempo-macchina egli richiedesse.

Come si parlava con un computer nel 1944?

Dopo la guerra, Hopper avrebbe potuto tranquillamente tornare al Vassar College e continuare la sua vita da professore ordinario. Ma i computer le piacevano più della carriera accademica, e dunque restò nella riserva della marina per iniziare la sua nuova vita da esperta di computer, uno dei pochissimi al mondo a quel tempo. In quel ruolo, Hopper fu in grado di

compiere un passo storico per il settore, nato dalla frustrazione accumulata nel programmare Mark I: divenne la prima persona al mondo a parlare in inglese a una macchina.

Hopper lavorò presso l'Harvard Computation Lab per quattro anni dopo la fine della guerra. Nel 1949 accettò un lavoro alla Eckert-Mauchly Computer Corporation, che aveva realizzato un computer chiamato UNIVAC. Fu una scelta decisiva, sia per Grace sia per il futuro della programmazione. Prima dell'UNIVAC, i computer erano visti come ottime macchine per fare conti in matematica e scienze, ma non molto di più. Gli esperti stimavano che ci sarebbe stata una domanda pari a venti computer in tutto il paese, la maggior parte dei quali presso laboratori di ricerca. Ma il lavoro di Hopper sull'UNIVAC cambiò tutto. Dimostrò che i computer erano utili anche per risolvere problematiche aziendali che riguardavano i *database*, una complicazione che non si era mai presentata nei problemi di matematica pura che Mark I aveva affrontato durante la guerra. Con l'aiuto di Hopper, le aziende iniziarono a vedere del potenziale in queste nuove macchine. La US Steel finì col comprare un UNIVAC per gestire i suoi pagamenti. MetLife ne acquistò uno per calcolare i premi delle assicurazioni. DuPont, General Electric, l'Ufficio del censimento, Westinghouse comprarono un UNIVAC per dargli in pasto i loro dati, rendendolo così il primo computer di successo a livello commerciale.¹²

Per illustrare la grande scoperta di Hopper dobbiamo tornare a una domanda risalente al 1944: in che modo Hopper dava istruzioni a Harvard Mark I? Come diceva ai 765 000 interruttori elettromeccanici di muoversi all'unisono per generare una tabella balistica?

Sicuramente non poteva usare l'inglese. Hopper lo descrive in questo modo: «Scomponi semplicemente tutti i tuoi calcoli matematici in una serie di passaggi elementari, composti da addizioni, moltiplicazioni e divisioni [...] e li metti in sequenza».¹³ Sembra semplice, da come lo racconta, ma non lo era. La parte difficile era tradurre queste istruzioni nel “linguaggio macchina” nativo di Mark I, l'unico linguaggio che esso fosse in grado di comprendere.

Per capire cos'è un linguaggio macchina, immagina un programma per computer che si occupi di preparare un tè. In un linguaggio di programmazione moderno “di alto livello” come Python, il programma suonerebbe così: (1) metti due cucchiaini di tè in una teiera; (2) metti a bollire mezzo litro d'acqua; (3) versa l'acqua bollente sul tè e aspetta quattro minuti. Ma in linguaggio macchina devi spezzare queste istruzioni in passaggi molto

più piccoli e specifici. Invece di dire «metti a bollire acqua», devi prima descrivere come raggiungere il lavandino: muovi il piede sinistro, muovi il piede destro, muovi il piede sinistro, e così via. Poi devi descrivere come riempire il bollitore: solleva la mano sinistra, afferra il rubinetto, gira il pomello in senso antiorario, e così via. A quel punto devi descrivere come riscaldare l'acqua, preparare il tè, versare il tè, con tutti i fastidiosi dettagli biomeccanici. In più devi scrivere tutto usando codici numerici al posto dell'inglese, dando in pasto al computer una lunga sequenza di schede perforate. Questi codici dicevano a Mark I il modo esatto in cui manipolare i bit (“numeri binari”, 0 o 1) all'interno dei suoi circuiti. In quanto programmatore, dovevi conoscere quali codici eseguivano quale compito. Nel nostro esempio del tè, il codice 7204 potrebbe significare «muovi il piede sinistro», il codice 6107 «afferra il rubinetto con la mano sinistra» ecc.

Dunque: 7204, 6107, ... questo è un tipico linguaggio macchina. Siamo molto lontani da «Essere, o non essere» – ma anche da «Alexa, metti un po' di musica anni ottanta». Come dice Douglas Hofstadter: «Guardare un programma scritto in linguaggio macchina è vagamente comparabile a guardare una molecola di DNA atomo per atomo».¹⁴ Ma un computer “pensa” in questo modo, anche oggi. E, all'alba dell'era digitale, non c'era semplicemente altro modo per dirgli cosa fare. Un programmatore di quell'epoca era in pratica un idraulico binario, che incanalava bit attraverso i circuiti di un computer con l'aiuto di un libretto di istruzioni che mostrava come tradurre problemi matematici in linguaggio macchina. Cercavi le cose nel libretto, foravi la carta nel modo appropriato, inserivi la carta nel computer e incrociavi le dita.

Parlare in questo modo a un computer era un procedimento noioso e soggetto a errori. Ancora peggio, agli inizi alcuni computer non usavano nemmeno numeri in base decimale (base 10). Usavano invece numeri ottali (in base 8), che comportano stranezze matematiche del tipo $7 + 1 = 10$ o $5 \times 5 = 31$.^{*f} Questo rendeva matti i programmatori, e Grace Hopper non faceva eccezione. Una volta, dopo aver passato settimane a programmare in base otto un computer chiamato BINAC, Hopper notò che non le tornavano i conti con il proprio libretto degli assegni. Rifece i calcoli più volte, ma non riusciva a trovare l'errore. Ma alla fine capì. I suoi conti non tornavano con quelli della banca perché, senza rendersene conto, aveva tenuto nota delle sue spese in base 8 anziché in base 10.¹⁵

Hopper inventa il compilatore

La disavventura del libretto degli assegni rivelò a Hopper la vera natura del problema con i computer: non parlano la nostra stessa lingua. Ma lei intravide una possibilità di miglioramento. Tutto ebbe inizio con l'idea di annotare gli schemi ricorrenti, qualcosa che in seguito divenne noto con il nome di "subroutine".

Forse conosci la storiella dei prigionieri che hanno sentito le stesse barzellette talmente tante volte che hanno assegnato un numero a ciascuna per rendersi la vita più facile. Quindi uno di loro urla «31!» e gli altri scoppiano a ridere. Un altro urla «17!» e giù altre risate. Un terzo urla «104!» ma stavolta tutti restano in silenzio, perché bisogna anche saperle raccontare.

Nella programmazione, una subroutine è come una barzelletta numerata: un pezzo di codice utile in generale per risolvere un problema che si presenta molto spesso, come per esempio risolvere un'equazione quadratica o ordinare una sequenza numerica. Ogni volta che Hopper scriveva una subroutine per Mark I, la annotava a mano su un quaderno, in modo da non dover inventare la ruota ogni volta. In poco tempo, mise in piedi una grande collezione di subroutine scritte in linguaggio macchina. Quando ne voleva usare una, la prendeva dal suo quaderno e la trascriveva su carta. Ma questo richiedeva tempo e un singolo errore di trascrizione avrebbe compromesso l'intero programma. Hopper realizzò che Mark I era più bravo di qualsiasi essere umano nel copiare, ed ebbe un'idea. Perché non raggruppare le subroutine in un archivio – ordinandole secondo codici numerici, come quelli utilizzati dai prigionieri per le barzellette – e dire al computer di copiare e compilare quelle che gli servono per un determinato compito? In altre parole, perché non programmare un computer in modo da programmarsi da solo?

Questa idea di un "compilatore" è probabilmente la più importante innovazione nella storia della programmazione. Per tornare all'esempio del tè, i programmatori non dovevano più scrivere istruzioni del tipo «solleva la mano sinistra, afferra il rubinetto, gira la manopola» ogni volta che volevano riempire il bollitore. Bastava dare al computer il giusto codice numerico che descrivesse il processo di riempire il bollitore, mettere l'acqua a bollire ecc. La macchina stessa si sarebbe occupata di mettere insieme tutte le subroutine per costruire il programma che prepara il tè. Codici che richiedevano una settimana di lavoro potevano essere scritti in cinque minuti in questo modo. In

più, ogni subroutine era controllata in anticipo e dunque il suo funzionamento era assicurato. Non c'era modo di raccontare male la barzelletta.

Quando Hopper spiegò l'idea ai suoi superiori, pensarono che fosse matta. I computer capivano solo la matematica, dicevano. Non sarebbero riusciti a scriversi programmi da soli: solo un essere umano poteva farlo. Più o meno in questo periodo Grace scelse la sua citazione preferita, che utilizzò più volte negli anni: «La frase più pericolosa di tutte è “Abbiamo sempre fatto così”». Naturalmente i superiori di Hopper si sbagliavano, e lei riuscì a dimostrarlo.¹⁶

Hopper non si fermò qui. Le sue intuizioni sui compilatori la convinsero di una verità fondamentale: che il futuro dei computer dipendeva da quanto facilmente saremmo riusciti a parlarci. Questo richiedeva molto più della semplice sostituzione del manuale dell'idraulico con codici matematici. La notazione matematica andava bene per uno scienziato o per un ricercatore della marina, ma la gran parte degli acquirenti di computer, come Hopper notava, «non avrebbe riconosciuto un coseno se lo avesse incontrato in strada».¹⁷ Gli uomini d'affari non avevano bisogno di un linguaggio per dire a un computer come calcolare la traiettoria di un missile. Avevano bisogno di un linguaggio per lavorare con i database: conti, prezzi, vendite, buste paga, ore di lavoro e così via. C'era solo un linguaggio comune a tutti i tipi di dati nelle differenti aree dell'economia: l'inglese. Per Hopper la conclusione era ovvia: bisognava programmare i computer in modo da lavorare con input in lingua inglese.

Ancora una volta, i suoi superiori pensarono che fosse folle anche solo provarci, e nel 1953 le negarono i finanziamenti. È ovvio che non possiamo far sì che un computer comprenda l'inglese, le risposero. L'idea è totalmente assurda. Dobbiamo programmare i computer usando simboli e numeri: abbiamo sempre fatto così.¹⁸

Non era la prima volta che Hopper si scontrava con il maschilismo nel campo della programmazione, e non sarebbe stata l'ultima. Ma quando il vento l'aveva scaraventata fuori dalla canoa, Grace era riuscita a tornare a nuoto sulla riva. Continuò a lavorare alla sua idea per conto proprio, e nel gennaio del 1955 aveva ultimato un prototipo funzionante. Parlando in una stanza piena di pezzi grossi dell'azienda, dimostrò che il suo «compilatore analizzatore di dati» poteva far sì che UNIVAC capisse un programma scritto in inglese le cui prime righe somigliavano alle seguenti.¹⁹

Leggi il file di inventario A; assegna un prezzo al file B.

Confronta il prodotto #A con il prodotto #B.

Se il prezzo è maggiore, vai all'operazione 10.

Se è uguale, vai all'operazione 5.

E così via. Hopper aveva programmato il computer in modo che traducesse in maniera automatica queste frasi, permettendo all'utente di concentrarsi su quello che conosceva (il flusso di dati) piuttosto che su quello che ignorava (i dettagli matematici).

A questo punto Hopper fece un passo falso. Per enfatizzare il fatto che il computer stava semplicemente applicando delle regole per associare frasi a sequenze di bit, mostrò che le stesse frasi in francese davano luogo a uno stesso programma: «Lisez paquet A; si fin de données, allez en operation 14». Questo rese furiosi i suoi superiori. Come descrisse Grace: «Fu una catastrofe! Era assolutamente ovvio che uno stimabile computer americano, costruito a Philadelphia, Pennsylvania, non potesse in alcun modo comprendere il francese». ²⁰ Con un pugno di frasi dal sospetto suono non-americano, aveva portato indietro il suo progetto di quattro mesi.

Alla fine Hopper ebbe la meglio, e riuscì a far finanziare dall'azienda lo sviluppo del suo compilatore per analisi dei dati, chiamato FLOW-MATIC. Uno studio pilota mostrava che FLOW-MATIC permetteva agli utenti di compiere le stesse azioni per cui in precedenza dovevano usare “simboli e numeri”, ma in un quarto del tempo. Con i loro clienti entusiasti del nuovo approccio di Hopper, i superiori non poterono far altro che cedere. Dovettero ringraziare l'estrema determinazione di Hopper.

In quel momento ebbe inizio la rivoluzione dei linguaggi di programmazione. Dalla metà degli anni cinquanta in poi, quasi tutti coloro che parlavano con un computer lo facevano sfruttando il metodo introdotto da Grace Hopper. Il linguaggio macchina continuò ad avere la sua importanza, ma solo per una ristretta cerchia di esperti. Tutti gli altri usarono linguaggi di programmazione ad alto livello, i cui insiemi di istruzioni erano molto più simili a «riempi il bollitore» piuttosto che a «afferra il rubinetto, gira il rubinetto». Con l'invenzione di questo modello, Hopper diede un enorme impulso a quella che crediamo sia la tendenza più importante in atto nella storia dell'umanità a partire dal 1945: la diffusione della tecnologia digitale in ogni aspetto della vita.

Da Grace ad Alexa: la rivoluzione del linguaggio naturale

Questa storia ci ha portato agli inizi degli anni sessanta. Come siamo arrivati al punto in cui puoi farti consegnare a domicilio qualsiasi bene di consumo, proveniente da qualsiasi parte del mondo, semplicemente parlando a voce alta con un computer?

Per impostare il discorso, riassumiamo il modello top-down basato su regole per l'interazione linguistica uomo-macchina elaborato da Grace Hopper negli anni cinquanta.

- Le persone dicono alle macchine cosa fare usando un linguaggio di programmazione, con regole grammaticali molto strette e un vocabolario minimo di parole inglesi.
- Le macchine interpretano i comandi nel loro proprio linguaggio usando enormi raccolte di regole di traduzione preinserite.
- Sia le regole di programmazione per gli umani sia le regole di traduzione per le macchine devono essere definite da zero, una per una, da programmatori umani.

Tra gli anni cinquanta e gli anni settanta, gli esperti hanno tentato di far comprendere il linguaggio naturale alle macchine usando lo stesso approccio top-down: (1) porre dei vincoli agli utenti umani, restringendo la grammatica e il vocabolario a disposizione; e (2) imbottire le macchine di regole di traduzione, quindi sintassi, pronuncia, scelta dei termini... in pratica tutte le regole che hai imparato senza sforzi da bambino e tutta la grammatica che la maestra ti ha insegnato alle elementari.

Questo metodo ha funzionato alla grande per i linguaggi di programmazione. Ma non ha mai funzionato bene per i linguaggi naturali.

Un ottimo esempio di cattivo funzionamento è il riconoscimento vocale da parte dei computer. I primi sistemi di riconoscimento vocale erano sostanzialmente dei giocattoli. All'Esposizione universale del 1962, per esempio, l'IBM presentò una macchina in grado di riconoscere alcune parole in inglese – sedici, per la precisione – e solo se pronunciate molto chiaramente. Negli anni settanta ci fu un certo entusiasmo generato da un programma di nome Harpy, creato dai ricercatori della Carnegie Mellon University. Harpy riconosceva esattamente 1011 parole, più o meno come un bimbo piccolo. Era costruito secondo i principi di Hopper: grammatica e

vocabolario ristretti per gli umani e un insieme terribilmente complesso di regole per le macchine, al fine di tradurre parole in testi. Il team di Harpy, composto da cinque programmatori, impiegò due lunghi anni per codificare tutte quelle regole: regole di acustica, fonetica, struttura della frase, limiti delle parole e così via. In condizioni di laboratorio assolutamente ideali, il sistema raggiungeva un'accuratezza del 70% nella trascrizione delle parole. Questo generò parecchio entusiasmo tra i ricercatori in IA. Harpy sembrava suggerire che, con regole migliori e computer più veloci, performance di livello quasi umano potevano essere facilmente raggiungibili.²¹

Eppure questi miglioramenti non arrivarono. In test successivi, effettuati in condizioni di vita reale, l'accuratezza di Harpy precipitò al 37%. Dopo cinque anni, il governo statunitense tagliò i finanziamenti al progetto. E oggi i sistemi per il riconoscimento del linguaggio naturale basati unicamente su regole sono rarissimi. Essi non sono mai stati in grado di superare tre problemi fondamentali: il proliferare di regole, l'affidabilità e l'ambiguità.

Problema 1: il proliferare di regole

Per prima cosa, è molto difficile scrivere tutte le regole per un linguaggio naturale. Ce ne sono decisamente troppe, molte più di quelle di qualsiasi linguaggio di programmazione. Anche se non te ne rendi conto, puoi davvero imparare molto del linguaggio Python in un singolo giorno. Ma non andrai molto avanti con il coreano nello stesso lasso di tempo.

Parte del problema è dovuta al fatto che le regole hanno eccezioni o, come diceva il famoso linguista Edward Sapir: «Ogni grammatica ha le sue falle». In inglese, per esempio:

- Gli aggettivi vengono prima dei nomi, ma non dirlo al legittimo erede.^{*g}
- La *i* precede la *e*, tranne quando segue una *c*, eccetto nel caso di scienziati lungimiranti,^{*h} che bevono frullati di proteine e caffeina.
- Due affermazioni non fanno una negazione? Certo, come no.

E così via. Le eccezioni creano problemi, poiché le macchine sono perse se togliamo loro la tirannica consistenza delle regole. L'unico modo per aggirare il problema è scrivere una regola per ogni eccezione.

Appare già un compito improbo, ma il problema delle “troppe regole” va molto oltre. In molti casi, semplicemente non sappiamo quali sono le regole

di un linguaggio naturale. Consideriamo quello che i linguisti chiamano problema della “segmentazione del parlato”. Prova a leggere questa frase ad alta voce: «Le previsioni del tempo danno pioggia domani». Percepirai una serie di parole staccate: “previsioni”, “pioggia”, “domani” ecc. Ma questa serie discreta è solo un’illusione cognitiva: solo i robot della fantascienza... parlano... facendo... pause. Quello che in realtà percepisci è un flusso continuo di termini, senza pause acustiche ovvie tra le parole. Capire dove finisce una parola e dove inizia la successiva è davvero un grosso problema. I linguisti hanno scoperto moltissime regole uditive nascoste su cui ci basiamo e hanno nomi bizzarri come “fonotattica” e “variazione allofonica”. Ma i linguisti sanno anche di non aver trovato *tutte* le regole, perché quelle che *hanno* trovato non riescono a spiegare completamente quanto siamo esperti nella segmentazione del parlato.

Il problema è banale: se non riusciamo nemmeno a identificare tutte le regole, sicuramente non saremo in grado di insegnarle a un computer.

Problema 2: l’affidabilità

Il secondo problema con le regole top-down è che, di solito, non funzionano sempre nel mondo reale. In altri termini, non sono affidabili.

Considera, per esempio, il problema di distinguere il parlato dal rumore di fondo. Il tuo cervello è *incredibilmente efficace* nel fare questo; riesci tranquillamente a capire un tuo amico in un pub rumoroso, nonostante il frastuono. I neuroscienziati non capiscono fino in fondo come sia possibile, e questo è il motivo per cui il rumore di fondo è la lamentela ricorrente delle persone che indossano apparecchi acustici.

Un’altra sorgente di modifiche irrilevanti è quello che crudelmente chiami “errore”. Immagina che cosa succederebbe se oggi decidessi di non rispettare una singola regola grammaticale in ogni frase scritta o pronunciata. Potresti causare qualche sguardo stranito, ma la gente ti capirebbe lo stesso. Anche se usassi pezzi di frasi. Anche se come il venerabile Yoda tu ti esprimessi. Anche se sbagliassi tutti i maschili e femminili, incurante delle reprimende della tua maestra delle elementari riguardo al tuo abuso di participi. La comprensione del linguaggio parlato è molto solida rispetto a questo tipo di variazioni, ma tale affidabilità è difficile da replicare usando regole top-down.

Un altro grande problema è la pronuncia. Chiedi a qualcuno di Derry, nel New Hampshire, di dire *caramel*. Poi chiedilo a qualcuno di Derry,

nell'Irlanda del Nord. Le risposte saranno totalmente diverse; le vocali non saranno le stesse, e persino il numero di sillabe sarà diverso. Potresti pensare: ok, introduciamo due regole per *caramel*. Ma abbiamo considerato solo irlandesi e americani. Esistono anche i texani, i londinesi, i californiani e... bene, capisci da solo dove sta il problema. Immagina di programmare un computer con un insieme di regole che associano in maniera efficace tutte queste diverse pronunce – “care-a-mell”, “crrr-mul” e ogni sfumatura di caramello possibile – alla stessa parola. Congratulazioni, hai appena risolto il problema del riconoscimento vocale per *caramel*. Ti restano solo altre 171 475 parole dell'*Oxford English Dictionary*. Poi puoi iniziare con il dialetto, e forse anche con il mandarino.

Problema 3: ambiguità

Infine, è difficile inventare regole che funzionino nel gestire le ambiguità, e il linguaggio è pieno di ambiguità. Gli esempi più ovvi coinvolgono le omofonie: *weather/whether, rain/reign, I scream/ice cream*, e così via.

E poi ci sono quelle che i linguisti chiamano “ambiguità sintattiche” o frasi che possono essere lette in molti modi. I titoli dei giornali sono spesso colpevoli in questo senso, eppure riusciamo a capirli.

- *Defendant gets nine months in violin case* (“L'imputato è condannato a nove mesi per il caso del violino”) non è una forma insolita di reclusione (*violin case* può essere inteso anche come “custodia del violino”).
- *Include your children when baking cookies* (“Coinvolgi i bambini quando prepari i biscotti”) non è un consiglio per la tua ricetta (si potrebbe anche tradurre “Aggiungi i tuoi bambini quando prepari i biscotti”).
- *British left waffles on Falkland* (“La sinistra inglese parla a vanvera sulle Falkland”) si riferisce a un Partito laburista indeciso, non a una colazione abbandonata (*Left*, “La sinistra”, può essere anche il verbo “lasciare”, e *waffles*, “parla a vanvera”, può essere inteso come il dolce per la colazione).

Il problema di fondo in questo caso è che, per quanto riguarda il linguaggio, siamo motori deduttivi incredibilmente efficaci, programmati da milioni di anni di evoluzione a farsi beffe delle ambiguità. Magari non ti accorgi nemmeno delle lttre mncnti nei messaggi di testo. Ti muovi tra le analogie come una lama calda nel burro. Sai che “avere bisogno di una pausa” ha un significato diverso nell'attività sportiva o in una discussione con il/la partner. Utilizzi informazioni dal contesto per interpretare quello che il tuo

interlocutore intende dire, anche se esiste un'altra frase che suona esattamente allo stesso modo.

- *The president's new direction has split his party* (Il nuovo corso del presidente ha diviso il partito)
- *The president's nude erection has split his party* (La nuda erezione del presidente ha diviso il partito)

Questo tipo di ambiguità sono proibite in ogni linguaggio concepito per un computer, proprio perché causano problemi a coloro che fissano le regole. Eppure tu riesci a gestirle senza fatica. Come?

1980-2010: lo sviluppo dell'elaborazione statistica del linguaggio naturale

I filosofi distinguono due tipi di conoscenza: il “sapere come” e il “sapere cosa”. Il “sapere come” indica la conoscenza intuitiva, pratica. Per esempio, tu sai *come* camminare e *come* andare in bicicletta senza sforzo a livello conscio. Il “sapere cosa”, d'altro canto, indica la conoscenza da manuale, basata sui fatti. Per esempio, dalla lettura di una pagina Wikipedia a caso che inizia per *N*, potresti venire a sapere che Nike è il nome di una marca di scarpe o che Napoleone invase la Russia nel 1812 ma la trovò decisamente fredda.

Le persone considerano il linguaggio parlato l'esempio perfetto di “sapere come”. Il miracolo cognitivo è la sua apparente semplicità: siamo in grado di parlare in maniera comprensibile e riuscire a decodificare le ambigue onde sonore provenienti dalle bocche altrui, senza neanche pensarci. A questo scopo, sfruttiamo processi deduttivi che fanno uso di ogni tipo di informazione aggiuntiva: l'esperienza, la comprensione implicita di quello che gli altri probabilmente pensano, e molti sottili indizi uditivi.

Come abbiamo visto, gli esperti di elaborazione del linguaggio naturale hanno provato per molto tempo a “educare” i computer fornendo molte regole esplicite. Tali regole avrebbero dovuto simulare le conoscenze che i bambini acquisiscono in modo naturale durante l'apprendimento del linguaggio. Eppure, anche nel migliore dei casi, questi approcci portavano a esiti orribili: non riuscivano a riprodurre le abilità linguistiche di un bambino di cinque anni, per non parlare di quelle di un adulto.

Dopo tre decenni di tentativi, sembrava chiara la necessità di un nuovo approccio all'elaborazione del linguaggio naturale. Doveva essere un approccio di tipo flessibile, e non rigido. Probabilistico, e non deterministico. Bottom-up, basato su dati reali, piuttosto che top-down, basato su un'infinità di regole. Ma, soprattutto, doveva essere in grado di lavorare con il vero linguaggio di tutti i giorni, piuttosto che con quello immaginato dagli esperti di grammatica.

Nel 1980, i ricercatori provarono qualcosa di diverso. Si arresero, buttarono via le loro regole, e dissero: usiamo i dati e basta. Inventarono nuovi algoritmi che lavoravano su premesse differenti: la conoscenza linguistica umana poteva essere troppo difficile da decodificare, ma sicuramente possedeva una chiara impronta statistica, rintracciabile nel modo in cui parliamo e scriviamo. Per esempio, se *weather report* (previsioni del tempo) è più sensato di *whether report* (*whether* significa "se"), allora ci saranno molti più esempi del primo caso che del secondo all'interno di un vasto insieme di frasi prese da conversazioni reali. E in effetti è quello che si osserva. Abbiamo usato un programma online chiamato Google Ngram Viewer,^{*i} che permette di ricavare la popolarità di qualsiasi parola o breve testo all'interno di tutti i libri pubblicati in inglese. Abbiamo scoperto che, tra il 1950 e il 2000, la combinazione *weather report* compare all'incirca 150 volte ogni due miliardi di coppie di parole (0,0000155797%) e risulta 250 volte più frequente di *whether report* (0,0000000652%), usato prevalentemente per scherzo o come esempio di ambiguità fonetica.

Dal 1980 in poi, i ricercatori del settore iniziarono ad attribuire sempre più valore a questa informazione puramente statistica. In precedenza, costruivano regole a tavolino in grado di *descrivere* come ottenere un certo costrutto linguistico. Ora invece iniziavano ad allenare modelli statistici a *predire* il modo in cui una persona avrebbe potuto ottenere lo stesso risultato. L'attenzione si spostò dalla comprensione all'imitazione, dal "sapere come" al "sapere cosa".

Questi nuovi modelli richiedevano moltissimi dati. Bisognava fornire alla macchina il maggior numero di esempi possibili di linguaggio umano, e programmarla secondo le regole della probabilità per trovare regolarità all'interno di quegli esempi. Il linguaggio diventò un problema di predizione basato su coppie input/output, simile ai problemi risolti da Henrietta Leavitt o dal contadino giapponese per classificare i suoi cetrioli:

- Per il riconoscimento vocale, si associa una registrazione vocale (input = «ahstinkolatsjonetakoz») con la corretta trascrizione (output = «Austin colazione tacos»).
- Per tradurre l'inglese in russo, si associa una parola inglese (*reset*) alla corrispondente traduzione russa (*perezagruzka*).
- Per indicare uno stato d'animo, si associa una frase («Che bella mattinata trascorsa in coda alle Poste») a un simbolo (☺).

E così via. In ogni caso, la macchina deve usare i dati per imparare una regola di predizione che associa un input al corretto output.

Negli anni ottanta, furono messi in commercio i primi software di riconoscimento vocale basati su questo principio. Erano in grado di riconoscere poche migliaia di parole, ma solo se parlavi... come... un... robot. Negli anni novanta e duemila videro la luce modelli sempre migliori che ti consentivano di parlare più normalmente. Ma lo stretto collo di bottiglia era sempre la scarsa disponibilità di dati. Ricorderai il problema della “sovradeterminazione” che abbiamo descritto nel capitolo 2, in base al quale un modello complicato può memorizzare semplicemente del rumore di fondo in un piccolo insieme di dati, anziché riconoscere le regolarità sottostanti. Anche in questo caso c'era un problema simile: i ricercatori non avevano abbastanza dati per costruire modelli sufficientemente complicati da descrivere il linguaggio umano senza incorrere nella sovradeterminazione. Di conseguenza, negli anni duemila il riconoscimento vocale entrò di nuovo in una fase di stallo, dopo aver raggiunto un'accuratezza del 75-80%. Per circa un decennio, il progresso fu decisamente lento e non solo nel riconoscimento vocale ma anche in altri settori dell'elaborazione del linguaggio naturale, sempre a causa della mancanza di dati: dalla traduzione automatica all'analisi delle emozioni.

Post 2010: la rivoluzione del linguaggio naturale

Tutto cambiò intorno al 2010, dapprima lentamente, poi a un ritmo accelerato. Ciò che causò il cambiamento fu l'enorme afflusso di dati.

Jorge Luis Borges ha scritto un racconto, intitolato *La biblioteca di Babele*, su una biblioteca i cui libri contengono tutte le possibili opere di prosa, ovvero tutti i possibili ordinamenti di lettere dell'alfabeto e segni di interpunzione. La maggior parte dei libri della libreria è composta di totali nonsense, come fossero scritti da scimmie che pigiano a caso i tasti di una

macchina per scrivere. Ma da qualche parte, in qualche libro, si possono trovare tutte le possibili frasi, tutte le storie d'amore, tutte le avventure, ogni capolavoro già scritto o ancora da scrivere.

La nostra biblioteca di Babele nel mondo reale è internet e, anche se non siamo ancora ai livelli del racconto di Borges, ci siamo vicini. Pensa all'immensa collezione di frasi inglesi scritte e parlate che si trovano sui server delle più grandi aziende tecnologiche. Pensa a una biblioteca contenente qualsiasi libro, rivista, quotidiano, canzone, film e spettacolo già composti. Ora pensa *molto* più in grande. Pensa a ogni pagina web. Ogni email. Ogni ricerca su Google o recensione di un prodotto, ogni messaggio di testo inviato, ogni conversazione su Slack o su Skype, ogni post su Facebook o su Twitter, ogni commento su YouTube o su Instagram. Questa collezione di frasi farebbe sembrare la Library of Congress degli Stati Uniti un bibliobus di terz'ordine. Finalmente, nel 2010 le menti migliori dell'IA sono riuscite a creare gli strumenti per sfruttare pienamente tutti questi dati.

Alcuni dati erano già a disposizione delle grandi aziende, che in ogni caso fecero di tutto per raccoglierne ancora di più. Un esempio in questo senso è Google 411, che fece la sua comparsa nel 2007. Forse ricorderai il tempo in cui potevi chiamare il 411 per cercare il numero di telefono di un negozio, al costo di un dollaro a chiamata. Google 411 ti offriva lo stesso servizio gratis, digitando 1-800-GOOG-411. Era un servizio molto utile, prima dell'avvento degli smartphone e per Google era anche un ottimo modo per costruire un enorme database di ricerche vocali e allenare i suoi modelli statistici per il riconoscimento vocale. Il servizio fu interrotto nel 2010, probabilmente perché Google aveva ottenuto tutti i dati che gli servivano.

Naturalmente, dal 2007 è partito un enorme lavoro di programmazione, in stile Grace Hopper, per convertire tutti i dati in regole di predizione. E dunque, a più di dieci anni di distanza, qual è il risultato? Facciamo un semplice esperimento. Apriamo il programma di gestione email sul cellulare e proviamo a dettare la seguente frase: «The weather report calls for rain, whether or not the reigning queen has an umbrella».*¹ Se sei di madrelingua inglese e il tuo telefono è basato su iOS o Android, otterrai quasi sicuramente la frase corretta, senza confusione tra *weather* e *whether* o tra *rain* e *reigning*.

Questo è un piccolo esempio di quello che puoi fare con i dati. Il software sa che *whether* e *reign* sono statisticamente più probabili in alcuni contesti, mentre *weather* e *rain* lo sono in altri. Ma questo non avviene perché il tuo telefono conosce il *significato* di questi termini: si tratta semplicemente di un

insieme enorme di probabilità^{*m} specifiche a seconda del contesto fornite per quasi ogni parola o frase in inglese rintracciabile su internet. Quando il dato acustico è soggetto ad ambiguità, il tuo telefono risolve il problema ricorrendo alla probabilità. Anche se in alcuni casi persistono dei problemi, almeno nel 2018, il software è in continuo miglioramento.

Anche altri sistemi di elaborazione del linguaggio naturale si sono evoluti in modo molto rapido per lo stesso motivo. Per molti anni abbiamo assistito a un fiorire di meme dedicati agli errori di Google Translate, e ne puoi ancora trovare a centinaia sul web. Per esempio, nel 2011 qualche smanettone si è accorto che la traduzione della frase «Justin Bieber raggiungerà mai la pubertà?» dall'inglese al vietnamita era «Justin Bieber non raggiungerà mai la pubertà».²² Questo genere di errori sintattici era tipico dei vecchi algoritmi di traduzione automatica. Azzecavano le parole, ma spesso facevano pasticci con l'ordine dei termini nella lingua di destinazione, producendo qualcosa di errato o privo di senso.

Con l'aumento dei dati di allenamento, e con il miglioramento dei modelli statistici del linguaggio, questi errori sintattici grossolani sono diventati molto meno frequenti.²³ In più, tutti questi dati hanno reso molto meno importanti le regole di traduzione esplicite. Per esempio, nessuno ha detto esplicitamente a Google Translate che l'inglese utilizza l'ordine soggetto-verbo-complemento oggetto, come per esempio in «i programmatori amano il caffè», mentre il giapponese utilizza l'ordine soggetto-complemento oggetto-verbo, come in «i programmatori il caffè amano». L'algoritmo ha semplicemente appreso la sintassi dalla statistica, da milioni di frasi in inglese e in giapponese nei dati di allenamento.

Oggi la stragrande maggioranza dei sistemi di elaborazione del linguaggio naturale rappresenta l'esempio perfetto del secondo tipo di conoscenza, nella classificazione dei filosofi: “sapere cosa”, piuttosto che “sapere come”.²⁴ Per il software sono semplicemente dei fatti, ma tali fatti sono quasi sempre sufficienti perché i dati sono tantissimi e gli algoritmi sono molto sofisticati.

Come le parole diventano numeri

Dedichiamoci ora agli algoritmi. Supponi di avere un gigantesco database di frasi, una biblioteca di Babele con più di 100 linguaggi naturali, dall'inglese

al cinese al farsi. Come puoi costruire un sistema di IA per un compito connesso al linguaggio e come lo metti all'opera?

Come puoi immaginare, non possiamo entrare nei dettagli perché sono troppo complicati. Tali dettagli sono il motivo per cui Google ha 70 000 dipendenti, un piccolo esercito di dottori di ricerca e più computer di quanti tu ne abbia mai visti in tutta la tua vita. Possiamo tuttavia darti una spiegazione sommaria di un concetto estremamente importante: il “vettore parola”. Per la precisione, ti illustreremo il famoso modello *word2vec* di Google, che fornisce una descrizione numerica (“vettore”) per ogni parola inglese. Se capisci *word2vec*, allora capirai una delle idee principali dell'IA nell'ultimo decennio. Anche i sistemi che non utilizzano direttamente questo algoritmo fanno uso dello stesso approccio di base.

Word2vec risponde a una semplice domanda: come trasformiamo le parole in numeri, in modo che parole con significato simile siano descritte con numeri simili? Può sembrare un compito bizzarro o persino impossibile. In che modo può il significato di parole come “tostapane” o “coraggio”, o di una frase come “Toronto Maple Leafs”, essere descritto tramite numeri? Eppure non è difficile come sembra: i bambini lo fanno costantemente.

La matematica di “20 domande”

C'è una scena di *Canto di Natale* che si svolge nel salotto di Fred, nipote di Ebenezer Scrooge. Fred ha invitato per la cena di Natale il suo ricco e spilorcio zio, che per tutta risposta ha replicato «ogni idiota che va in giro con il “lieto Natale!” sulle labbra, dovrebbe venire bollito nel suo stesso pudding, e sepolto con un rametto di agrifoglio sul cuore». Ma, nel frattempo, Scrooge riceve la visita di tre fantasmi che lo fanno riflettere sui propri errori da taccagno, e il secondo di questi, il fantasma del Natale presente, porta Scrooge in casa di Fred il giorno di Natale. I due osservano di nascosto Fred e la sua famiglia impegnati in un gioco chiamato “Sì o no”. Fred deve pensare qualcosa e tutti gli altri nella stanza devono indovinare di cosa si tratta facendo domande a cui egli può rispondere solo sì o no.

Il vivace fuoco di fila delle domande gli strappò che aveva pensato a un animale, un animale vivente, un animale piuttosto sgradevole e selvatico, un animale che qualche volta grugniva e ruggiva e qualche volta parlava, un animale che viveva a Londra, camminava nelle strade; non era mostrato in

pubblico come curiosità, e non era portato in giro alla catena, non viveva in un serraglio.

Cosa poteva essere? I bambini ridevano quasi istericamente. Cercavano di indovinare: Fred non stava pensando a un orso, a un cavallo, a una tigre o a un asino. Finalmente la cognata di Fred trovò la risposta giusta: «Ho indovinato. So cosa è, Fred. So cosa è... Tuo zio S-c-r-o-o-g-e!». E aveva indovinato.

I bimbi americani chiamano questo gioco “20 domande” e, anche se non sembra, la matematica entra pesantemente in gioco. In effetti, “20 domande” mostra come tradurre le parole in numeri, proprio quello che fanno i sistemi di IA. Prendiamo la parola “Scrooge” dal gioco in atto nel salotto di Fred. La sua rappresentazione numerica è questa:

	Animale	Piacevole	Ringhia o grugnisce	Parla	Vive a Londra	È un orso
Scrooge	1	0	1	1	1	0

Questo è un “vettore parola”.^{*n} Per la precisione, è un vettore “binario” o vettore 0/1: 1 significa sì, 0 significa no. Parole o frasi diverse, come “il piccolo Tim” o “l’orso Paddington” sono risposte diverse per la stessa domanda, e dunque avranno vettori parola diversi. Se mettiamo questi vettori in una matrice, in cui ogni riga è una parola e ogni colonna è una domanda, otteniamo qualcosa del genere:

	Animale	Piacevole	Ringhia o grugnisce	Parla	Vive a Londra	È un orso
Scrooge	1	0	1	1	1	0
Rafael Nadal	1	1	1	1	0	0
Piccolo Tim	1	1	0	1	1	0
Orso Paddington	1	1	0	1	1	1
Albero di Natale di Trafalgar Square	0	1	0	0	1	0

In che modo l’IA gioca a “20 domande”?

È abbastanza semplice convertire parole in numeri, usando il gioco “20 domande”. Modifichiamo ora le regole in tre modi, sia per avvicinarci al gioco in cui è impegnata un’IA, sia per far sì che i vettori parola contengano il maggior numero di informazioni.

Primo cambiamento: non si vince o si perde unicamente, ma si assegnano punteggi in base alla “prossimità semantica”, ovvero quanto vicino si riesce ad arrivare al vero significato del termine. Non entreremo nei dettagli di cosa significa esattamente “vicino”. Nell’IA c’è una precisa definizione matematica, ma è sufficiente che tu immagini di affidarti alla persona più equa che conosci in qualità di giudice. Per esempio, supponi che la risposta sia “orso”:

- Se la tua risposta definitiva è orso, ottieni cento punti.
- Se la tua risposta è cane o ghiottone, potresti ottenere novanta punti. Ci sei andato vicino, dal punto di vista filogenetico.
- Se la tua risposta è zanzara, potresti ottenere cinquanta punti. Quantomeno hai fatto il nome di un animale.
Se la tua risposta è sciroppo per la tosse, potresti ottenere due punti. Sei molto lontano, ma il tossire può ricordare molto alla lontana il verso di un orso.

Questo modo di assegnare punteggi somiglia molto a quello che avviene all’interno di gran parte dei sistemi di elaborazione del linguaggio. Per esempio, tradurre la frase di JFK «Ich bin ein berliner» con «Io sono tedesco» è un errore, ma è molto meglio che tradurre «Sono un krapfen».^{*o}

Il secondo cambiamento prevede di rispondere con un numero tra 0 (assolutamente no) e 1 (assolutamente sì), anziché con un sì o un no. Per esempio, prendiamo la domanda «È un orso?»:

- Nel caso di un vero orso, risponderesti con 1.
- Per un orsetto parlante come Paddington, potresti rispondere con 0,9. È pur sempre un orso, anche se non l’ideale platonico di orso.
- Nel caso di Scrooge, potresti rispondere con 0,65. Non è un orso, ma ha marcate tendenze da orso. (In *Canto di Natale*, la famiglia di Fred obiettò persino che «la risposta alla domanda: “È un orso?” avrebbe dovuto essere “sì”, dato che la risposta negativa era stata sufficiente a cancellare Scrooge dalla mente».)
- Nel caso di Rafael Nadal, potresti rispondere 0,2. Sembra una persona decisamente squisita in TV, ma è vivo e grugnisce parecchio.

Con questi cambiamenti, abbiamo vettori parola composti da numeri continui da 0 a 1 per ogni domanda, piuttosto che 0 o 1: livelli di grigio al posto di bianco o nero.

E ora il cambiamento più grande: devi porre *le stesse domande in ogni partita*. Questo spegnerebbe certamente tutto l'entusiasmo nei giochi da salotto, dal momento che riduce ogni partita di "20 domande" a una specie di censimento, in cui compili ogni volta lo stesso noioso formulario. Ma, nonostante questo, puoi mettere da parte le tue preoccupazioni. Immagina di inventare domande così ampie e articolate da essere in grado di distinguere ogni possibile parola, da "Scrooge" a "cacciavite", da "barbecue" a "basketball", da "eritrocita" a "epistemologia".

Non è facile, vero? Eppure i modelli di linguaggio naturale in IA funzionano davvero in questo modo. Con una sola eccezione: abbiamo bisogno di molto più di venti domande, dal momento che non possiamo adattare le domande successive alle risposte ottenute. Dunque in IA si gioca a "300 domande".

Non ci interesseremo allo specifico tipo di domande da porre, ma parleremo piuttosto del meccanismo di gioco. Il tuo primo pensiero potrebbe essere quello di formare una commissione: metti delle persone in gamba in una stanza e di' loro che non possono andarsene se non dopo aver elaborato le 300 domande in grado di codificare tutte le possibili parole o frasi in inglese. Sarebbe un interessante esperimento sociologico in stile *Tonto + tonto*.^{*p} Ma se ti illudi che funzioni, hai molta più fiducia nelle commissioni di quanta ne abbiamo noi. Quantomeno ci vorrebbe tantissimo tempo, e noi vorremmo poter dire al nostro smartphone di ordinare una pizza ora, non quando una qualche commissione avrà raggiunto un accordo.

Ci rimane solo una possibilità: lasciar scegliere le domande a un algoritmo.

Che tipo di domande potrebbe mai porre un algoritmo? Certamente non domande sul significato delle parole, perché le macchine non capiscono questo concetto. Però capiscono le *statistiche di posizionamento relativo delle parole*, ovvero quali parole tendono a comparire vicine a quali altre parole in frasi reali scritte da esseri umani. Queste statistiche sono un sostituto incredibilmente efficace del significato. Ecco una domanda di esempio: «Prendi tutte le frasi con "patate fritte", "ketchup", "focaccia". Questa parola compare spesso in queste frasi?». Questo è il genere di domande che una rete neurale potrebbe far pronunciare a Ross in un nuovo episodio di *Friends*. E,

dettaglio fondamentale, è una domanda che una macchina può porre e a cui può rispondere, perché non richiede *comprensione*, ma solo *conteggio*.

Ovviamente, questa domanda è troppo specifica se ne abbiamo solo 300 a disposizione. Ma la premessa di base – fare domande sulle statistiche di posizionamento relativo delle parole – è sensata. Anche se stiamo tralasciando parecchi dettagli, questo è a grandi linee il funzionamento di word2vec. Procedendo per errori e tentativi, le macchine selezionano 300 set di parole di prova (analoghe a “focaccia” e “ketchup” nell’esempio precedente).²⁵ Poi giocano molte partite di “300 domande”, apprendendo un vettore parola per ogni parola o frase in inglese, basandosi sulla statistica di posizionamento relativo rispetto alla parola di prova.

I vettori parola risultanti possono essere disposti in modo da formare una matrice, una parola per riga, proprio come abbiamo fatto con “Scrooge” e “il piccolo Tim” qualche pagina fa. È una matrice enorme, con 300 colonne e milioni di righe. Nella tabella a pagina seguente riportiamo un sottoinsieme di quattro colonne e quaranta righe, per darti un’idea delle domande che l’algoritmo impara a porre.

Per esempio, nella prima colonna vediamo parole come “router”, “pixel” e “firewall”, che danno risposte alla prima domanda molto vicine a 1. È evidente che l’algoritmo ha imparato a fare domande del tipo «Questa parola compare spesso in frasi con termini relativi ai computer?». *q (Ricorda che, secondo le nostre regole, 1 significa “certamente sì” e 0 “certamente no”.) Allo stesso modo, nella terza colonna vediamo parole come “arrosto”, “affumicato”, “manzo” e “grigliato”, tutte con risposte vicine a 1. L’algoritmo deve aver imparato a porre domande riguardo alla cucina. E ha anche imparato a porre domande sulle università e sulla legge e, in altre colonne non mostrate qui, domande su animali, politica, sport, salute e centinaia di altri argomenti.

Mettere all’opera i vettori parola

Questo approccio fornisce una rappresentazione sorprendentemente accurata delle varie sfumature di un linguaggio. I ricercatori di IA hanno anche messo a punto un numero di magia per mostrare l’efficacia dei loro vettori parola, cercando di completare analogie per addizione e sottrazione. Per esempio, prendiamo l’analogia «l’uomo sta al re come la donna sta a ____?». Come

possiamo tradurre questa analogia in termini matematici, in modo da descriverla con l'aritmetica dei vettori parola?

	Domanda 1: "computer"	Domanda 2: "università"	Domanda 3: "cucina"	Domanda 4: "legge"
nvidia	1	0,045	0,156	0,083
server	0,999	0,944	0,214	0,184
nome utente	0,999	0,468	0,842	0,963
ethernet	0,999	0,587	0,617	0,072
interfaccia	0,999	0,355	0,831	0,032
router	0,998	0,697	0,986	0,911
monitor	0,998	0,693	0,111	0,174
porta	0,997	0,646	0,583	0,184
pixel	0,997	0,253	0,017	0,21
firewall	0,995	0,729	0,957	0,636
laureando	0,089	0,999	0,107	0,627
facoltà	0,365	0,999	0,114	0,944
borsa di studio	0,063	0,999	0,291	0,398
candidato	0,153	0,999	0,22	0,77
college	0,206	0,997	0,132	0,514
associazione	0,216	0,997	0,035	0,688
commissione	0,32	0,996	0,912	0,824
dipartimento	0,42	0,994	0,502	0,77
residenziale	0,145	0,993	0,569	0,801
pubblicazioni	0,173	0,993	0,524	0,938
arrosto	0,778	0	1	0,767
affumicato	0,596	0,012	1	0,799
birre	0,815	0,043	1	0,613
barbecue	0,182	0,077	1	0,039
mais	0,827	0,044	1	0,122
manzo	0,471	0,015	0,999	0,699
peperoncino	0,403	0,002	0,999	0,425
peperoni	0,398	0	0,999	0,572
grigliato	0,531	0,001	0,999	0,46
sapore	0,281	0,026	0,997	0,248
cauzione	0,221	0,63	0,923	1
custodia	0,509	0,536	0,943	1
arresto	0,149	0,444	0,839	1
accuse	0,002	0,157	0,57	1
pena	0,44	0,105	0,413	0,999
possesso	0,123	0,304	0,73	0,999
illegale	0,045	0,406	0,478	0,999
reclusione	0,015	0,121	0,928	0,999
causa civile	0,175	0,147	0,735	0,999
sceriffo	0,275	0,305	0,882	0,999

Ecco come. Prendi il vettore per la parola "re" e sottrai il vettore per la parola "uomo". (Possiamo sommare e sottrarre vettori in modo analogo ai numeri, perché i vettori sono numeri.) Intuitivamente, sottraendo "uomo" da "re", abbiamo eliminato il genere maschile dalla parola, ottenendo un nuovo

vettore che rappresenta un concetto di regalità senza attributi di genere. Ora *sommiamo* il vettore per la parola “donna” a questo nuovo vettore, reintroducendo quindi una componente di genere, stavolta femminile. In altre parole, *prendi la parola “re” e rendila femminile*: in termini aritmetici, “re – uomo + donna”. La risposta di word2vec è precisa: facendo i calcoli, si ottiene la parola “regina”.

Altri tipi di analogie funzionano allo stesso modo, usando la somma e la differenza di vettori.

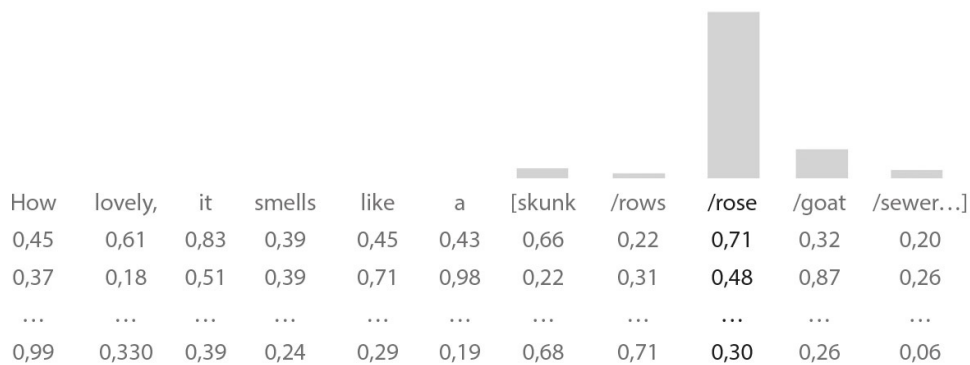
- Capitali del mondo: Londra – Inghilterra + Italia. Risposta di word2vec: “Roma”.
- Coniugazione: catturato – cattura + andare. Risposta di word2vec: “andato”.
- Quale squadra di hockey gioca in quale città: Canadiens – Montréal + Toronto. Risposta di word2vec: “Maple Leafs”.

In pratica, word2vec ha imparato a eseguire il test SAT verbale usando unicamente le competenze necessarie al test SAT matematico. Il modello sottostante non sa assolutamente nulla su monarchia, genere, geografia, grammatica, hockey o su qualsiasi altro argomento. Conosce solo le statistiche d’uso delle parole, ottenute dai dati di allenamento, e le regole della probabilità.²⁶


Tutto questo potrebbe essere semplicemente un trucco da illusionisti o un piacevole passatempo per fanatici della programmazione, ma è bene sottolineare un punto importante: una volta trasformate le parole in vettori, possiamo fare della matematica. E ciò è essenziale per lo sviluppo dei sistemi di IA per il linguaggio. I computer non comprendono le parole, ma comprendono la matematica.

Prendi un software di riconoscimento vocale, come quello che sta dietro ad Alexa o Google Voice. I vettori di parole sono di enorme aiuto in questo caso, poiché esprimono il significato di una frase in termini matematici gestibili da un computer. Tra le altre cose, questa procedura è essenziale nel caso delle omofonie, come *rows* (righe) e *rose* (rosa). Anche se le due parole hanno una pronuncia simile, sono identificate da vettori parola totalmente diversi – risposte diverse nel gioco delle “20 domande” – e uno di questi vettori si adatterà meglio agli altri vettori parola in una determinata frase. Bisogna ammettere che la definizione di “migliore adattamento” è complicata, e non scenderemo nei dettagli. Tutto si riduce a un sofisticato calcolo di aritmetica


dei vettori, che fornisce probabilità in grado di risolvere l'ambiguità acustica, come in questo caso:^{*I}



O questo:^{*S}



O questo:^{*t}



I vettori parola forniscono una chiarissima descrizione matematica di qualcosa che all'orecchio umano suona molto semplice: a volte una parola sta bene in una frase, altre volte meno. E con qualche importante modifica, gli stessi concetti matematici sono alla base di traduttori automatici, chatbot, sistemi di ricerca vocale... persino delle reti neurali che scrivono articoli sul baseball.

La comunicazione tra esseri umani e macchine

Speriamo che ti siano chiari i concetti chiave che hanno permesso alle macchine di arrivare a un punto di svolta nella loro capacità di gestire il linguaggio. Il miglioramento è stato in parte guidato dallo sviluppo di computer più veloci e di algoritmi più intelligenti, come le reti neurali e word2vec. Ma la cosa fondamentale è la disponibilità di dati, i nostri dati. Le macchine in grado di parlare non aprono un varco verso un nuovo tipo di intelligenza linguistica: sono semplicemente lo specchio della nostra.

Che cosa ci riserva il futuro? È impossibile da sapere, ovviamente, ma riusciamo a intravedere alcune direzioni.

Per prima cosa, i modelli linguistici diventeranno personalizzati: le macchine intorno a te si adatteranno al tuo modo di parlare, così come si adattano alle tue preferenze cinematografiche. Di conseguenza, ti conosceranno molto meglio. Considera, per esempio, l'evoluzione dell'iPhone. Per usare l'iPhone 6, devi fargli riconoscere la tua impronta digitale. Per usare l'iPhone X, devi fargli riconoscere il tuo volto. Non è difficile immaginare un iPhone del futuro a cui dovrai leggere una storia della buonanotte, in modo che impari a riconoscere la tua voce.

In secondo luogo, politiche sagge e legislazioni ponderate saranno molto importanti per ottenere tutti i benefici da questi nuovi strumenti, senza permettere che vengano usati in maniera dannosa. Un algoritmo che può scrivere una puntata di *Friends* può sembrare carino, anche se poco utile. Lo stesso algoritmo potrebbe essere molto più pericoloso se qualcuno lo usasse per diffondere falsità su internet in periodo elettorale. Anche se siamo in definitiva ottimisti, non siamo esperti di politiche e non conosciamo la soluzione a questo genere di problemi. Sappiamo, tuttavia, che tali problemi devono necessariamente essere discussi. Nello sviluppo storico di ogni tecnologia, dal fuoco alla manipolazione genica, arriva un momento in cui

l'approccio “agisci velocemente e spacca tutto” smette di essere un'opzione moralmente accettabile per una persona adulta. Nel caso dei computer e del linguaggio, quel momento è arrivato.

Riconoscere le potenziali minacce non vuol dire dimenticare i vantaggi. Se credi che *già oggi* abbiamo algoritmi intelligenti e insiemi di dati enormi, non hai ancora visto nulla. Pensa alle centinaia di milioni di persone che dettano le email ai loro telefoni, usando Google Translate, o che parlano a un bot su Facebook o WeChat. Ognuna di queste interazioni porta a modelli più precisi e prestazioni migliori, poiché le macchine sono sempre sulle tracce dei dati che disseminiamo durante le nostre attività digitali. Quando miglioreranno – e ci sono *ampi* margini di miglioramento – ci aspettiamo che queste macchine diventino strumenti di routine in qualsiasi professione e in qualsiasi aspetto della nostra vita.

Chiamaci inguaribili ottimisti, se vuoi, ma noi crediamo che tutto questo sia magnifico. Non auguriamo a nessuno di fare un lavoro duro e ingrato, e, per lo meno nei paesi industrializzati, gran parte di questi lavori è di tipo informatico e ci rendono sedentari e deboli. Perché i medici devono passare ore a inserire dati nei computer ogni giorno? Perché una persona non vedente deve essere costretta a usare una tastiera Braille? Perché un avvocato deve dedicare centinaia di ore di lavoro alla lettura di milioni di pagine di documenti? Perché gli impiegati devono passare anni delle loro vite a scrivere email? Perché la UE deve spendere centinaia di milioni di euro all'anno per tradurre tutto nelle ventitré lingue ufficiali? Perché devi fare affidamento sui tuoi pollici per dire a un telefono cosa deve fare? Hai visto quei computer che vengono utilizzati ai banchi del check-in in aeroporto?

Non vogliamo che altri esseri umani risucchino lo sporco dal pavimento o filtrino lo spam dalle caselle di posta: per quello ci sono gli aspirapolvere e gli algoritmi. Perché per la scrittura dovrebbe essere diverso?

Post scriptum

Grace Hopper è stata la prima persona a parlare con un computer in inglese, ma di certo non si è fermata lì.

Dopo il suo lavoro pionieristico sull'UNIVAC, Hopper intraprese una lunga carriera nel settore privato e nei riservisti della marina prima di andare in pensione a sessant'anni nel 1966. Nel 1967, tuttavia, fu improvvisamente

richiamata in servizio dalla marina, dove lavorò per altri diciannove anni, molto più in là dell'età di pensionamento obbligatorio, su speciale richiesta del Congresso. Aiutò il Dipartimento della difesa ad aggiornare la propria infrastruttura informatica e diventò una delle prime donne nella storia della marina a ricevere i gradi. In occasione della sua promozione a commodoro nel 1983, mentre stringeva la mano al presidente Ronald Reagan disse «Sono più vecchia di lei». Andò finalmente in pensione sul serio nel 1986, a 79 anni.

Hopper è morta nel 1992, ma il suo lascito è presente e duraturo. Nel corso degli anni, il suo nome è stato dato a una nave della marina, a un supercomputer Cray e al Grace Hopper College della Yale University. Le è stato dedicato un Google Doodle nel novembre del 2013 e le è stata conferita una Medal of Freedom presidenziale nel novembre del 2016. Non c'è dubbio che il suo bisnonno ammiraglio sarebbe stato fiero di lei. Grazie ai suoi sforzi per avvicinare esseri umani e macchine attraverso il linguaggio, Grace Hopper ha svolto un ruolo fondamentale nel dare forma al mondo moderno.

***a** Quiz televisivo statunitense in cui bisogna rispondere a domande di cultura generale. [n.d.t.]

***b** Sinonimo, decisamente volgare, di masturbazione maschile. [n.d.t.]

***c** La frase corretta sarebbe *for all intents and purposes* (a tutti i fini pratici), ma al suo posto viene spesso usata *for all intensive purposes*, foneticamente simile ma concettualmente errata. L'esempio successivo riporta un caso simile: la frase corretta *at his beck and call* (subito a sua disposizione) viene storpiata in *at his beckon call*. [n.d.t.]

***d** Le strofe originali delle due canzoni recitano «Since the world's been turning » al posto di «said the worst attorney», e «touched for the very first time» al posto di «touched for the thirty-first time». [n.d.t.]

***e** Puoi trovare facilmente l'intervista con Letterman su YouTube.

***f** I numeri decimali 8 e 25 si esprimono in base 8 come 10 e 31, rispettivamente.

***g** In inglese, *heir apparent* è il legittimo erede, mentre *apparent heir* significherebbe “erede presunto”. [n.d.t.]

***h** In inglese, *prescient* fa eccezione alla regola appena enunciata.

***i** <https://books.google.com/ngrams>. Un “n-gramma” è un termine della linguistica che indica una frase contenenti n oggetti, come parole o simboli. Per esempio, *weather report* è un 2-gramma, poiché contiene due parole.

***l** “Le previsioni del tempo riportano pioggia, che la sovrana regnante abbia o meno un ombrello.” In inglese, l'ambiguità fonetica riguarda le parole *weather/ whether* e *rain/reigning* che si pronunciano in modo molto simile. [n.d.t.]

***m** In questo caso, “contesto” vuol dire “le altre parole all’interno della frase”.

***n** In matematica, un vettore è un insieme di numeri associati allo stesso oggetto.

***o** In tedesco, *Berliner* può riferirsi a un abitante di Berlino o a un krapfen (*Berliner Pfannkuchen*). [n.d.t.]

***p** Commedia del 1996 diretta da Jason Bloom, in cui un gruppo di 5 scienziati sono imprigionati in un sistema ecologico chiuso, dalle sembianze di centro commerciale. [n.d.t.]

***q** Ovviamente l’algoritmo *non sa* che la domanda “riguarda i computer”. Sa solamente che la domanda riguarda la statistica di posizionamento relativo con altre parole che noi umani associamo ai computer.

***r** La frase nel grafico significa: «Che bello, profuma come un [mascalzone/file/rosa/capra/fogna/...]». [n.d.t.]

***s** «Il terzo giorno lui [file/resuscitò/telefonò/...] dai morti.» [n.d.t.]

***t** «Egli piantò 100 [orecchie/file/rosa/...] di mais.» [n.d.t.]

IL GENIO DELLA ZECCA REALE

Il monitoraggio in tempo reale, dallo sport alla politica alle frodi finanziarie: che cosa può insegnarci il peggiore errore matematico di Isaac Newton a proposito della ricerca di anomalie in vasti insiemi di dati.

Se sei un appassionato di NFL e vivi al di fuori della striscia di terraferma che va dal Connecticut al Maine, probabilmente vedi i New England Patriots – la squadra di football americano più forte degli ultimi quindici anni – con un misto di sospetto e antipatia. Innanzitutto, ci sono tutte quelle vittorie, che di sicuro irritano i fan delle altre trentuno squadre della NFL. E poi c'è Bill Belichick, l'arcigno allenatore dei Patriots, a cui la felpa e lo sguardo severo conferiscono un'inquietante somiglianza con l'imperatore malvagio di *Star Wars*. Ma, anche se non sei un fan del football, potresti essere un fan del rispetto delle regole, nel qual caso, i Patriots ti staranno sicuramente antipatici a causa delle conclamate truffe di cui si sono resi protagonisti, dagli episodi di spionaggio nei confronti degli altri team e delle loro tecniche fino alla (presunta) pratica di sgonfiare i palloni ovali per trarre vantaggio durante le giornate fredde.

Ma potrebbero i Patriots imbrogliare persino al *lancio della moneta prima del match*? Che tu ci creda o no, molte persone lo credono possibile: su una base di venticinque partite consecutive, nel corso delle stagioni 2014 e 2015, i Patriots vinsero diciannove lanci, che corrispondono a una percentuale di vincita altamente sospetta del 76%. Un opinionista televisivo, venuto a sapere di quest'ultimo "scandalo", commentò: «Questo prova semplicemente che Dio o il diavolo tifano per i Patriots, e di sicuro non può essere Dio». ¹

Prima di tirare in ballo la religione o la Forza per giustificare questa anomalia, consideriamo la spiegazione più innocua: fortuna sfacciata. Ogni volta che lanci una moneta, hai il 50% di probabilità di vittoria. Ma bisogna tenere in conto anche una certa variabilità. Se lanci ripetutamente la moneta, puoi facilmente incappare in serie fortunate, dove vinci un po' più spesso

unicamente per caso. È plausibile il fatto che i Patriots siano incappati in una serie fortunata su quelle venticinque partite?

Il ragionamento in questo caso è complicato da un'osservazione: è dal 2007 in poi (anno in cui scoppiò il loro primo scandalo) che una serie sospetta di vittorie dei Patriots sui lanci di moneta suscita subito l'attenzione della gente. Dunque non possiamo prendere solo questa particolare serie di venticinque partite e interrogarci sulla sua stranezza. La domanda giusta è: quanto è probabile che i Patriots vincano diciannove volte su *qualsiasi* serie di venticinque lanci consecutivi nel corso delle ultime undici stagioni?

Per rispondere a questa domanda, abbiamo usato un computer per simulare i lanci di moneta: per la precisione, più di diciassette milioni di lanci. Abbiamo scritto un programma che simula un lancio equo in tutte le 176 partite dei Patriots dalla stagione 2007 fino alla stagione 2017.^{*a} Abbiamo ripetuto questa simulazione 100 000 volte, controllando ogni volta se i Patriots avessero ottenuto una serie di venticinque partite con almeno diciannove vittorie al lancio della moneta. Puoi vedere nove di queste 100 000 simulazioni in figura 5.1. Nella maggior parte dei casi, i Patriots hanno vinto dodici o tredici volte, e questo è ciò che ci aspettavamo. Ma si osserva una grande variabilità. A volte i Patriots incappano in serie fortunate – come nelle simulazioni 3, 6, 9 – in cui vincono almeno diciannove volte. Nella simulazione 3 vincono addirittura ventidue volte.

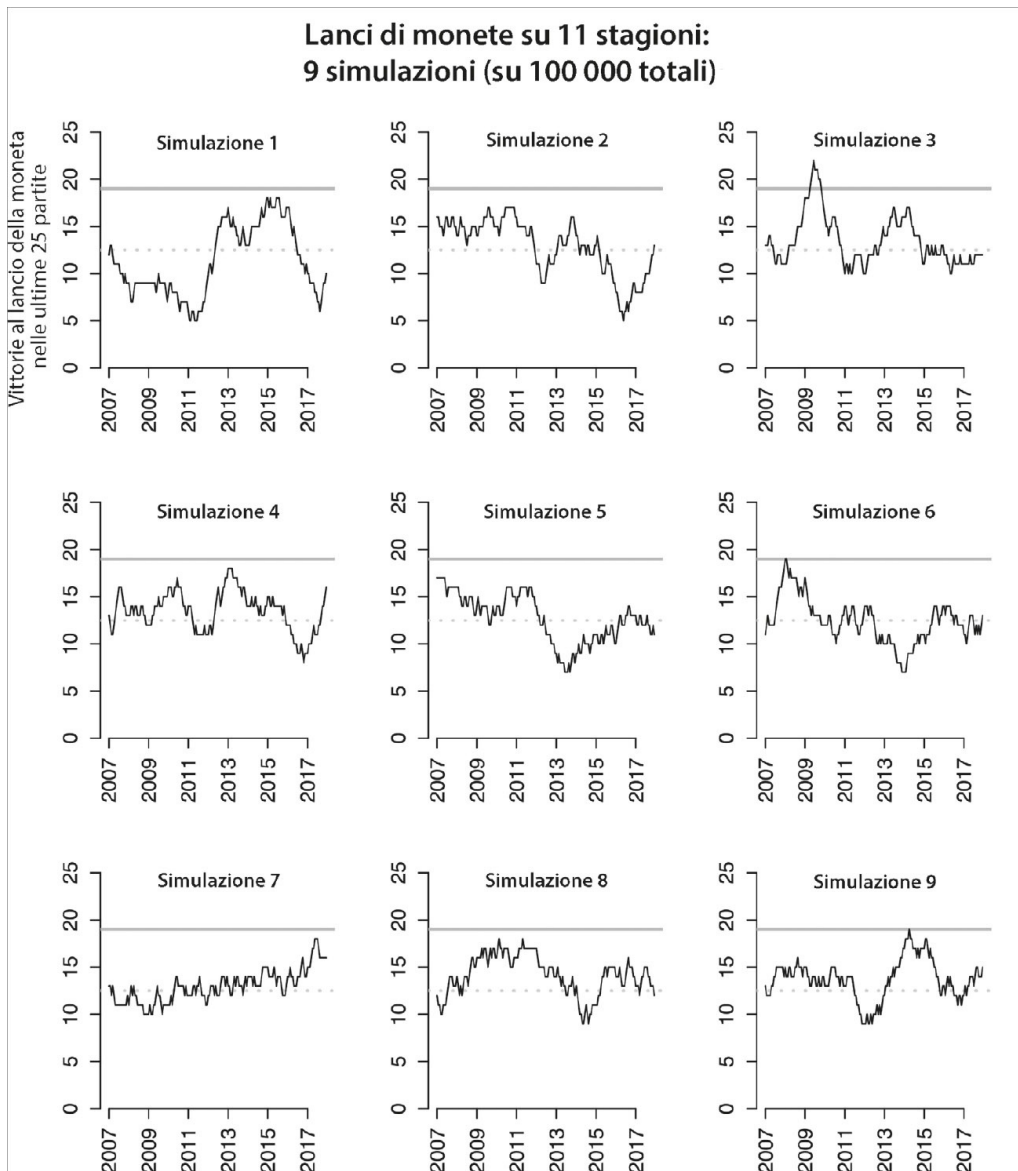


Figura 5.1 Ogni grafico mostra una serie di venticinque lanci di monete nel corso di undici stagioni simulate al computer, tra il 2007 e il 2017. L'asse verticale indica il numero di vittorie in ogni striscia continua di venticinque lanci. La retta grigia orizzontale indica diciannove vittorie, mentre la linea tratteggiata è la media attesa di 12,5 vittorie.

In tutto, i Patriots hanno raggiunto la soglia delle diciannove vittorie nel 23% delle nostre 100 000 simulazioni: non è un numero sufficientemente piccolo per escludere la fortuna come spiegazione.^{*b} Dunque, lasciando da parte le videocamere spia o i palloni sgonfiati, non c'è prova che i Patriots imbrogliassero al lancio della moneta. In un caso, nel corso di venticinque partite tra il 2014 e il 2015, sono stati semplicemente fortunati.

L'importanza della variabilità

La statistica del lancio della moneta per i New England Patriots illustra un principio fondamentale. Per decidere se qualcosa è anomalo, devi conoscere: (1) cosa aspettarti in media e (2) i limiti normali di variabilità intorno alla media. Se non capisci il concetto di variabilità – per esempio, come la percentuale di vittorie al lancio della moneta su venticinque partite dei Patriots vari rispetto alla media del 50% – allora non sarai mai in grado di distinguere una vera anomalia da una innocente fluttuazione casuale.

Questo ci porta dritti all'argomento principale, ovvero il monitoraggio in tempo reale per la rilevazione di anomalie.^{*c} Nell'IA, si traduce nel passare al setaccio un flusso di dati e identificare quelli che non corrispondono a uno schema tipico. Questo può salvare soldi e vite, e può portare a nuove intuizioni riguardo ai tuoi dati:

- Le banche usano software che cercano anomalie nelle tue spese per decidere se la tua carta di credito è stata rubata.
- Le grandi aziende vanno alla ricerca di traffico anomalo all'interno delle loro reti per identificare violazioni di sicurezza informatica.
- Gli analisti di dati nelle smart city cercano concentrazioni anomale di attività criminosa in una certa area per migliorare le strategie di prevenzione.
- Gli investigatori cercano anomalie nelle richieste di indennizzo per rilevare frodi a carico del servizio sanitario nazionale.
- Le squadre sportive controllano i dati dei sensori indossati dai loro giocatori per rilevare anomalie che possano suggerire un rischio di infortunio.

In tutte queste applicazioni dell'IA, e in migliaia di altre ancora, la rilevazione di anomalie si basa in egual misura su ciò che i dati descrivono in media e su quale sia la variabilità intorno a tale media.

Il più antico sistema di rilevazione di anomalie: una lezione su cosa non fare

Per illustrare l'importanza di questo principio per l'IA, inizieremo con l'esempio di qualcuno che l'aveva capito molto male, e non si tratta di una persona qualsiasi, ma una delle menti più geniali di tutti i tempi. Ti stiamo per trasportare nell'Inghilterra del 1696, in cui uno dei sistemi di rilevazione di anomalie utilizzato più a lungo nella storia era già in funzione. Questo sistema, chiamato “prova della pisside”, era stato concepito per prevenire frodi a carico della Zecca reale, in cui veniva stampata la moneta inglese. È

affascinante proprio perché fu un fallimento: non fu in grado di rilevare molte anomalie, nel corso di centinaia di anni, e giocò un ruolo importante, anche se non riconosciuto, in una crisi economica che causò sofferenze e rivolte.

E nel 1696 la persona che se ne occupava era Isaac Newton.

Sì, *quell'*Isaac Newton, l'inventore del calcolo infinitesimale, l'uomo che spiegò la gravitazione e che fu immortalato nel famoso distico di Alexander Pope: «La Natura e le sue leggi giacevano nell'oscurità;/Dio disse "Sia Newton!" e tutto fu luce». Nel 1696, Newton aveva 56 anni ed era una celebrità scientifica con una cattedra a vita a Cambridge. Non aveva obblighi di insegnamento e poteva lavorare su qualsiasi argomento volesse, fisica, alchimia, giochi di prestigio, qualsiasi cosa. Eppure nel 1696 lasciò la vita da accademico, si trasferì a Londra e accettò una sfida lanciategli dai suoi potenti amici nel governo: diventare il direttore della Zecca reale.

Nel complesso, Newton si comportò in maniera egregia nel suo nuovo lavoro, eccezion fatta per un punto cruciale, in cui commise un errore madornale, male interpretando un principio statistico di base in bell'evidenza davanti a lui per cinque lunghi anni. Oggi quel principio è al cuore di ogni sistema di monitoraggio in tempo reale basato sull'IA: nella Silicon Valley, nelle smart cities, negli uffici di ogni squadra sportiva e nell'ufficio per la prevenzione delle frodi di ogni banca. Dunque, se vuoi capire tutto ciò, è necessario esaminare tre aspetti della storia di Newton alla Zecca reale.

1. La crisi dell'economia inglese nel tardo XVII secolo, in cui la Zecca giocò un ruolo sottile ma fondamentale.
2. La grande coniazione del 1696, un passo drammatico nella politica monetaria inglese concepito per tamponare la crisi, e che Newton dovette salvare dal disastro.
3. L'importanza della variabilità statistica nella rilevazione delle anomalie: il soggetto del peggiore errore matematico compiuto da Newton.

La seconda carriera professionale di Isaac Newton

Newton arrivò alla Zecca reale nel 1696, nel bel mezzo di una crisi monetaria che minacciava di paralizzare l'economia inglese. Per comprendere appieno l'esperienza di Newton alla Zecca, bisogna risalire alle origini di questa crisi.

Il problema era il seguente: nel 1696, la moneta inglese scarseggiava già da almeno trent'anni. A quel tempo, l'Inghilterra utilizzava lo standard in

argento: il peso e il contenuto in argento determinavano il valore delle monete. A causa della guerra dei nove anni, tuttavia, la domanda di argento nel continente era andata alle stelle, al punto che le monete inglesi valevano più come metallo in Europa continentale che come moneta corrente in Inghilterra. Di conseguenza, gli inglesi si comportavano esattamente come ti aspetti. Portavano le monete in Francia o in Olanda, le liquefacevano, permutavano l'argento grezzo con oro e vendevano l'oro, arricchendosi abbastanza rapidamente. Con il fuoriuscire di tutto quell'argento, l'Inghilterra restò letteralmente a corto di moneta.²

C'era anche una seconda causa che spiegava la scarsità di argento e che amplificava l'effetto della prima: la limatura delle monete, un flagello per la massa monetaria durante tutto il Seicento. Bastava trovare una sporgenza di argento lungo il bordo e asportarla limando con cura. Non si otteneva molto da una singola moneta ma, lavorandone molte, si riusciva a mettere da parte un bel po' di argento. Tale pratica era punita con l'impiccagione già durante il regno di Elisabetta I, ma questo non sembrava scoraggiare i truffatori. Nel corso di un'indagine parlamentare, nel 1690, tre orafi raccolsero ciascuno 100 sterline in monete circolanti; il peso totale doveva essere pari a 1200 once troy, ma in realtà era di sole 624 once troy. La pratica della limatura era dunque evidente sulle grandi quantità ma, a meno di cogliere qualcuno in flagrante, era un crimine praticamente impossibile da provare.³

Ai limatori piace la variabilità

La limatura era agevolata dal fatto che, prima del 1662, tutte le monete inglesi erano realizzate a mano, ovvero, da un fabbro che martellava una forma di argento fuso su un'incudine fino a darle la forma di un disco. Il punto essenziale riguardo alla manifattura delle monete è la *variabilità*, sia in forma sia in peso, che risultò essenziale per il successo della pratica della limatura. La variabilità in forma assicurava che le monete avessero sempre delle piccole sporgenze da poter asportare. La variabilità in peso assicurava che ci fosse sempre una moneta leggermente più pesante da poter limare e successivamente utilizzare con nonchalance, come se fosse solo un po' più leggera delle altre.

Nel 1662, il parlamento finalmente si occupò del problema, e diede alla Zecca i fondi per produrre monete meccanicamente. L'obiettivo era semplice:

mettere fuori gioco i truffatori eliminando la variabilità in forma e in peso delle monete.

È utile descrivere in dettaglio la nuova coniazione meccanica, per dare un'idea dell'attività che Newton avrebbe in seguito ereditato. Si iniziava con dell'argento fuso che ribolliva all'interno di enormi calderoni a 1000 gradi centigradi. L'argento veniva poi versato in stampi per formare lingotti che, una volta raffreddati, erano trasformati in sfoglia da un matterello gigante azionato da quattro cavalli. Una seconda macchina, simile a uno stampo per biscotti, intagliava dischi dai fogli d'argento. I dischi erano dati in pasto a una pressa a vite, che confezionava le monete. Una quarta macchina, molto pericolosa, incideva un'effigie su entrambi i lati della moneta. Un uomo introduceva le monete in una piccola cavità all'interno dell'impianto, mentre altri quattro uomini ruotavano un disco di 180 gradi per mezzo di funi, azionando un'enorme pressa che stampava una profonda e indelebile effigie del re sulla moneta. Un ulteriore mezzo giro della ruota riportava la pressa in alto e, in questo lasso di tempo, il primo uomo doveva rimuovere la moneta pronta dalla cavità e inserirne un'altra. I quattro uomini che giravano la ruota erano esausti dopo appena quindici minuti di lavoro e l'uomo che inseriva e toglieva le monete era costantemente in ansia per le sue dita.⁴

Infine c'era la macchina rifinitrice, che incideva due segni speciali sul bordo: una serie di solchi lungo la circonferenza, chiamata "zigrinatura", che puoi ancora trovare sulle monete odierne, per esempio i venticinque cent americani e le due sterline inglesi; e l'iscrizione latina *Decus et Tutamen*, una frase dell'*Eneide* di Virgilio che significa "ornamento e garanzia". Proprio come suggerisce il latino, era una protezione contro la limatura: sarebbe stato difficile asportare del metallo senza che la modifica si notasse.*^d

Potresti pensare che l'introduzione della coniazione meccanica abbia risolto il problema della moneta in Inghilterra, eliminando la variabilità all'interno della massa monetaria. In realtà, dopo il 1662, il problema si aggravò. Il motivo è che le vecchie monete realizzate a mano continuavano a circolare e i mercanti le accettavano al loro valore nominale. Alla fine del Seicento, l'Inghilterra aveva a tutti gli effetti due monete in circolazione. C'erano le monete precedenti al 1662, talmente degradate da non poter essere fuse per ottenerne un guadagno. E poi c'erano le monete fatte a macchina, che non potevano essere limate. A questo punto, furono queste ultime a essere fuse e smerciate in Europa, lasciando in circolazione solo quelle fatte a mano.⁵

Gli economisti chiamano questo fenomeno, in base al quale la “moneta cattiva” mette fuori circolazione la “moneta buona”, legge di Gresham. Ma questo è solo un termine da libro di testo, inventato da economisti per dare ad alcune ovvietà il nome di altri economisti. Questa “legge” fu in effetti citata diciassette secoli prima di Gresham da Aristofane, nella sua opera *Le rane*: «Le massicce monete, orgoglio degli ateniesi, non vengono mai usate, mentre le brutte monete di rame passano di mano in mano». Non è altro che senso comune. Se vai a fare spesa e puoi scegliere se pagare con le lussuose monete ateniesi o con le brutte monete di rame, terrai quelle belle per te. Il negoziante ragionerà allo stesso modo quando ti darà il resto. E dunque solo le monete brutte circoleranno.

Questo è esattamente ciò che è successo con le monete inglesi. Dunque, quando Newton arrivò alla Zecca nel 1696, il commercio inglese era quasi al collasso. Cominciò a diffondersi del sarcasmo triste: anche se sotto re Giacomo le tasse erano più alte, perlomeno c’era della moneta con cui pagarle. Molta gente non aveva praticamente moneta, e quelli che invece la avevano, la tenevano per sé piuttosto che spenderla, pensando a buon diritto che in futuro sarebbe aumentata di valore. Di conseguenza, come scrisse lo storico Charles Macaulay, «il commercio e l’industria erano paralizzati, il malessere era sentito giorno dopo giorno, ora dopo ora, ovunque e in qualsiasi strato sociale». Un testimone di quel tempo spiegò a un amico che «il commercio si basa solo sulla fiducia. I nostri inquilini non riescono a pagare l’affitto. I nostri mercanti di grano non riescono a guadagnare per quello che hanno prodotto e non commerceranno più, ed è tutto fermo».⁶ Come riassunse Macaulay, «tutta la miseria inflitta alla nazione in un quarto di secolo da cattivi re, ministri, parlamenti e giudici» impallidiva di fronte alla «miseria causata in un solo anno da brutte corone e brutti scellini».⁷

La prova della pisside

Finora abbiamo imparato tre cose importanti sulle condizioni della moneta inglese nel 1696.

1. Tutte quelle monete forgiate a mano anteriori al 1662 costituivano un enorme problema. Costringevano le persone a discutere quotidianamente del loro reale valore, e la loro svalutazione mise le monete forgiate a macchina fuori circolazione e, in definitiva, fuori dall’Inghilterra.

2. Le monete realizzate a mano si svalutavano per via della limatura.
3. La chiave del successo della limatura era la variabilità: le differenze in forma e peso delle monete erano sfruttate dai criminali che limavano senza pietà le monete leggermente più pesanti, rendendole leggermente più leggere.

Dunque una domanda cruciale per capire la crisi dell'economia inglese è: perché si permise una tale variabilità?

Una certa percentuale di variabilità era inevitabile, specialmente per monete realizzate a mano. La legge inglese lo aveva persino riconosciuto ufficialmente, ponendo un limite legale alla variabilità accettata e mettendo in atto procedure di controllo per sincerarsi che tale limite fosse rispettato. Ma il sistema fallì e per spiegare come sia successo, introduciamo la prova della pisside.

La prova della pisside^{*e} è un metodo per rilevare anomalie utilizzato fin dal 1150. Sebbene i dettagli siano cambiati nel corso del tempo, l'obiettivo è sempre stato più o meno lo stesso: controllare se la Zecca barasse, fosse incapace, o entrambe le cose. Gli addetti della Zecca, per esempio, potevano barare coniando monete sistematicamente più leggere e intascando l'argento restante. O, semplicemente, potevano essere molto scarsi nel controllo qualità, facendo monete più pesanti e monete più leggere. Se questo succedeva, le monete accidentalmente più pesanti potevano essere fuse da qualche mercante dalla vista acuta per ricavarne un profitto.

La prova della pisside era concepita per prevenire tali furbizie. Ogni sessanta libbre di argento battute dalla Zecca, veniva messa da parte una singola moneta. Dopo aver accumulato diverse migliaia di monete, in genere nel giro di qualche anno, un comitato di fabbri esperti verificava la presenza di anomalie, per assicurarsi che gli standard di legge per il peso e la purezza del metallo fossero rispettati.⁸

Ma ricorda la lezione imparata dall'esempio dei New England Patriots: quando si controllano anomalie, bisogna tenere conto della variabilità. Anche in assenza di trucchi, non ci si poteva aspettare che le monete pesassero in modo *esattamente* uguale, a causa delle inevitabili imperfezioni del processo di lavorazione presso la Zecca. La legge inglese riconosceva questa variabilità almeno dal 1345, specificando limiti accettabili per il peso di una moneta. Tali limiti erano chiamati "rimedio", e corrispondevano a un $\pm 1\%$ rispetto al peso nominale.^{*f} Se la moneta era al di fuori di questi limiti, la Zecca doveva "porre rimedio" nei confronti della Corona e questa poteva essere una seria

minaccia, poiché il contratto della Zecca del 1280 affidava la vita dei responsabili e dei loro familiari “alla pietà del sovrano”.⁹

Perché la prova della pisside era così inefficace?

Dalla prospettiva della scienza dei dati, la prova della pisside sembra fantastica. Implica una procedura di campionamento ben definita, senza distorsioni evidenti, e un problema che qualsiasi professore di statistica del ventesimo secolo potrebbe assegnare come compito a casa: gli ufficiali della Zecca calcolavano il peso medio di un campione di monete, e volevano verificare se quella media fosse sufficientemente vicina alla media di riferimento.

Ma cosa vuol dire “sufficientemente vicina”? È qui che la prova iniziò ad avere problemi. Gli ufficiali ipotizzarono che la risposta fosse ovvia: se la legge diceva che una singola moneta doveva al più differire per l’1% dal valore di riferimento, allora anche il peso medio doveva differire per l’1%. Questa risposta “ovvia”, tuttavia, era totalmente sbagliata. Portava a valori *decisamente* troppo ampi e dunque involontariamente favorevoli ai limatori di monete.

Per comprendere l’errore, immagina di avere un campione di 2500 scellini davanti a te. Supponi che ogni scellino debba pesare 100 grammi – il “valore atteso” – con una tolleranza di ± 1 grammo. Il tuo compito è stabilire se queste monete rientrano nell’intervallo di ± 1 grammo dal valore atteso. L’approccio ovvio è pesare tutte le 2500 monete individualmente. Ma ti rendi conto di quanto possa essere noioso? È pur sempre il Seicento, e hai parecchi altri modi per passare il tempo, come suonare il liuto o assistere a esecuzioni capitali. Dunque decidi di risparmiarti tutto quel lavoro e calcoli il peso *medio* delle monete: le pesi tutte insieme sulla bilancia e poi dividi il risultato per 2500. Questo è un esempio abbastanza vicino al compito svolto dalla Zecca. Se la media è vicina ai 100 grammi, allora anche ogni moneta deve essere abbastanza vicina a quel peso. Se la media è lontana da 100 grammi, allora almeno qualche moneta deve essere lontana da quel valore.

Questa procedura – molto simile a quella messa in atto durante la prova della pisside – sarà sicuramente in grado di rilevare le anomalie più evidenti. Supponi, per esempio, che il peso medio riscontrato sia solo 50 grammi, anziché 100. Questa è una pistola fumante: dovresti suggerire agli ufficiali della Zecca di procurarsi un buon avvocato per tutto l’argento che hanno

rubato, perlomeno se hanno a cuore le loro vite e quelle dei loro familiari. Ma se i numeri non fossero così eclatanti e per esempio, se la media fosse 99,5 grammi? A prima vista, potrebbe sembrare un caso di truffa, proprio come il record dei Patriots di diciannove vittorie su venticinque al lancio della moneta. Ma ricorda, certe “anomalie” sono semplicemente dovute al caso. Come possiamo decidere se 99,5 grammi è un risultato sospetto?

Ecco dunque la domanda fondamentale: se i limiti accettabili per una *singola* moneta sono ± 1 grammo dal valore di riferimento, quali sono i limiti per il peso medio di *molte* monete? C'è una regola d'oro, in questo caso. Supponi che i limiti siano molto stretti e che le monete superino la prova solo se il peso medio cade in un intervallo di $\pm 0,0001$ grammi dal valore di riferimento di 100 grammi. In questo caso, il tuo sistema per rilevare anomalie entrerebbe sempre in funzione: vedrebbe anomalie ovunque, come quegli antifurto per le automobili degli anni ottanta che si attivavano toccando la carrozzeria con una piuma. D'altro canto, supponi di allargare molto i limiti, per esempio ± 10 grammi, all'incirca il peso di uno spicchio di limone. In questo caso, il tuo sistema resterebbe sempre inattivo e si farebbe sfuggire delle vere anomalie. La domanda da un milione di scellini è: se $\pm 0,0001$ è troppo poco e ± 10 è troppo, qual è il valore giusto?

LA REGOLA DELLA RADICE QUADRATA, OVVERO L'EQUAZIONE DI DE MOIVRE

C'è un'equazione molto importante in statistica, chiamata regola della radice quadrata, che dice *esattamente* quanto avrebbero dovuto essere ampi i limiti per riconoscere un'anomalia nella prova della piaside. Questa equazione fu scoperta nel 1718 da Abraham de Moivre, un matematico svizzero. Noi crediamo che si tratti di uno dei più sottovalutati trionfi della mente umana. La maggior parte delle persone ha sentito parlare dell'equazione di Einstein: $E = mc^2$. L'equazione di de Moivre è altrettanto profonda e rappresenta una verità altrettanto universale per fare predizioni scientifiche accurate. Eppure pochissime persone al di fuori della statistica e dell'IA la conoscono. È una vergogna, data la sua centralità nell'era delle macchine intelligenti.

L'equazione di de Moivre stabilisce una relazione inversa tra la variabilità di un campione e la radice quadrata dell'ampiezza del

campione. Si scrive così:

$$\text{Variabilità di una media} = \frac{\text{Variabilità di una singola misura}}{\sqrt{\text{Ampiezza del campione}}} = \frac{\sigma}{\sqrt{N}}$$

Gli scienziati di solito usano la lettera greca σ (sigma) per indicare la variabilità di una singola misura e la lettera N per indicare l'ampiezza del campione. Ecco perché abbiamo scritto l'equazione sia in parole sia in simboli, in modo più compatto, come σ/\sqrt{N} . Gli scienziati si riferiscono alla "variabilità della media" usando un termine leggermente più tecnico: "errore standard della media".

Proviamo a fare un esempio numerico. Supponi di pesare 2500 scellini ($N = 2500$). La legge consente una variazione di ± 1 grammo dal peso medio di 100 grammi per ciascuno scellino. Dunque, se il controllo qualità della Zecca sa il fatto suo, $\sigma = 1$. La regola della radice quadrata dice che se questo è vero, il peso medio di 2500 monete deve essere compreso in un intervallo di ampiezza $1/\sqrt{2500} = 0,02$ dal valore medio di 100 grammi. Dunque i limiti devono essere $100 \pm 0,02$. Qualsiasi valore al di fuori di questi limiti suggerisce una delle due possibili anomalie: o una "distorsione", ovvero il peso medio delle monete non è davvero 100, oppure una "sovradispersione", ovvero la variabilità di una singola misura è in realtà maggiore di 1.

Come abbiamo detto, coloro che effettuavano la prova della pisside credevano che, se i limiti accettabili per una singola moneta erano ± 1 grammo, allora i limiti per il peso medio di molte monete dovevano essere ugualmente ± 1 grammo. Ma, secondo la statistica moderna, i limiti dipendono in realtà da quante monete ci sono nel campione: più grande è il campione, più stretti saranno i limiti. Questa è una conseguenza di un'equazione molto importante chiamata "regola della radice quadrata", anche nota come "equazione di de Moivre". La regola dice che la variabilità di una media campione diminuisce all'aumentare della radice quadrata dell'ampiezza del campione. La matematica è un po' complicata, ma il concetto è semplice. In un campione piccolo, una singola moneta troppo leggera può abbassare molto la media. Ma in un campione grande, una moneta leggera può essere facilmente controbilanciata da una più pesante, e dunque la media dovrebbe essere più

vicina a quella di riferimento. Dunque, se fai la media su migliaia di misurazioni e il risultato non è molto vicino a quello atteso, c'è qualcosa di sospetto.^{*g} Si tratta della stessa matematica che i casinò utilizzano quando devono decidere se mandare degli energumeni a far visita ai ragazzi del MIT seduti al tavolo del blackjack.

Per mostrarti l'importanza della regola della radice quadrata nel problema delle anomalie, vediamola all'opera nel confronto di due intervalli diversi.

Ampiezza del campione	Limiti usati nella prova della pisside	Limiti corretti basati sulla statistica moderna
1	$100 \pm 1,00$	$100 \pm 1,00$
100	$100 \pm 1,00$	$100 \pm 0,10$
2500	$100 \pm 1,00$	$100 \pm 0,02$
10000	$100 \pm 1,00$	$100 \pm 0,01$

La prova della pisside usava intervalli *troppo ampi*. Questo errore non permetteva di rilevare due differenti tipi di anomalie, entrambe nocive per l'economia inglese.

La prima – che probabilmente non si verificò, ma che desta l'interesse di quasi ogni analista dati che si imbatte nella prova della pisside – è che i dipendenti della Zecca avrebbero potuto essi stessi limare dell'argento dalle monete. Per vedere come questo sia possibile, supponi che la Zecca sia in grado di battere moneta con variabilità entro i limiti di legge ($\pm 1\%$ in peso), ma che i dipendenti cerchino in modo disonesto di ottenere un valore pari a 99,5 grammi per scellino, anziché 100. (Questo tipo di anomalia è chiamato “errore sistematico” di 0,5 grammi.) Supponi anche che la prova della pisside cerchi di rilevare anomalie pesando un campione di 2500 monete. Giocando con la matematica della regola della radice quadrata, trovi che il peso medio di queste 2500 monete sarà compreso tra 99,48 e 99,52 grammi, molto al di fuori del corretto intervallo statistico $100 \pm 0,02$. Eppure la prova della pisside non avrebbe fatto scattare nessun allarme, perché la commissione avrebbe accettato qualsiasi valor medio compreso tra 99 e 101 grammi. Dipendenti particolarmente audaci avrebbero potuto, in teoria, mettere da parte lo 0,5% di tutto l'argento d'Inghilterra senza essere scoperti. Ma solo qualcuno che conosceva la regola della radice quadrata avrebbe potuto ingannare la prova

della pisside in questo modo, e non ci sono prove che suggeriscano che una simile epica frode sia mai avvenuta.

Tuttavia, *ci sono prove* che un secondo, e più sottile, tipo di anomalia si sia verificato: ovvero, che la Zecca fosse onesta ma negligente, e coniasse monete di peso altamente differente, dando ai truffatori il vantaggio di poter sfruttare una variabilità extra. Supponi, per esempio, che la Zecca mirasse effettivamente a un peso medio di 100 grammi, ma che il controllo qualità fosse talmente poco accurato che la variabilità del peso delle monete fosse dieci volte maggiore dei limiti di legge: 100 ± 10 grammi, anziché 100 ± 1 . Questo tipo di anomalia è chiamata “sovradisersione”. Non è necessariamente un indizio di frode, ma semplicemente di trascuratezza. Eppure la prova della pisside non sarebbe stata in grado di rilevarla. Se le monete cadono individualmente all’interno dell’intervallo 100 ± 10 , la regola della radice quadrata implica che il peso *medio* di 2500 monete di questo tipo è quasi certamente compreso tra 99,8 e 100,2. Di nuovo, questi valori sono in gran parte esterni all’intervallo corretto di $100 \pm 0,02$ e sarebbero stati rilevati da un moderno controllo di qualità. Ma la Prova avrebbe accettato qualsiasi valore tra 99 e 101.

Questo tipo di sovradisersione, una vera e propria manna per i truffatori, andò avanti per decenni, se non per secoli. Basiamo la nostra affermazione su due fatti. Per prima cosa, Isaac Newton evidenziò esplicitamente i bassi standard manifatturieri al suo arrivo alla Zecca. Si concentrò in particolare sulla variabilità delle monete: «Quando sono arrivato alla Zecca, e già da molti anni» egli scrisse, «le monete erano coniate in maniera disuguale, alcune due o tre grani più pesanti, altre più leggere».¹⁰ Newton scrisse anche che le monete pesanti «erano chiamate “ghinee di ritorno” poiché venivano identificate e riportate alla Zecca per essere coniate nuovamente» a vantaggio di qualcuno. Egli stimò che la frazione di ghinee di ritorno era di *una su quattro*, una pistola fumante che indicava un eccesso di variabilità. Non era una novità per la Zecca. Alla prova della pisside del 1534, per esempio, la commissione aveva specificamente evidenziato che «le monete erano molto diverse, e dunque era vantaggioso collezionare i pezzi più pesanti».¹¹

La seconda evidenza è che, al tempo di Newton, si erano già verificati due casi in cui le monete non avevano superato la prova della pisside.¹² Due insuccessi possono sembrare pochi, ma se le singole monete fossero rientrate nello standard di legge di variabilità ($\pm 1\%$), alla luce degli intervalli esageratamente ampi della Prova, persino *un singolo insuccesso* sarebbe stato

molto più improbabile della vincita della lotteria. La spiegazione più semplice per questo alto tasso di insuccesso, considerati i commenti di Newton sullo scadente controllo di qualità, è che il peso delle monete variava molto di più dei limiti di legge.

Newton alla Zecca

Venne fuori che i lavoratori della Zecca erano davvero scarsi nel controllo della variabilità. Lasciarono che i fabbri lavorassero in modo approssimativo per decenni, producendo monete molto più variabili in peso rispetto allo standard di legge dell' $\pm 1\%$. Eppure la prova della pisside *non li chiamò mai a rispondere dei loro atti*, fornendo dunque ai truffatori un alleato prezioso: le leggi della probabilità.

La matematica che c'è dietro questo tremendo errore, tuttavia, non era qualcosa di cui gli ufficiali della Zecca avrebbero potuto rendersi conto nel corso dei secoli, con l'unica eccezione di Isaac Newton.

Dovresti aver compassione del povero Newton all'arrivo alla Zecca. Il suo nuovo lavoro non era quella meraviglia che gli era stata prospettata. Gli avevano detto che avrebbe ricevuto 600 sterline all'anno, ma si trattava di una consapevole esagerazione da parte del ministro del tesoro, poiché il salario reale era solo di 400 sterline. Gli avevano detto che i suoi nuovi colleghi erano professionisti dalle menti raffinate, ma in realtà era una massa di incompetenti; il vicedirettore di Norwich finì in prigione con le sue proprietà confiscate, mentre il vicecontrollore fu presto congedato e riassegnato come ambasciatore di sua maestà presso i Pirati del Madagascar.¹³ Infine, dissero a Newton che il nuovo lavoro non sarebbe stato molto impegnativo, e questa era la bugia più grande. Giunse alla Zecca durante la grande coniazione del 1696: la soluzione drastica e definitiva del parlamento per il problema della limatura delle monete, in cui milioni di monete prodotte manualmente vennero richiamate, fuse e nuovamente forgiate a macchina.

Newton arrivò nel pieno della grande coniazione, a detta di tutti destinata al fallimento per via della pessima gestione. Ma Newton, e di questo gli va dato merito, non prese sottogamba il suo nuovo incarico e passò subito all'azione. Si assegnò compiti aggiuntivi quando i colleghi lo abbandonavano. Apprese ogni dettaglio del sistema contabile. Suggerì miglioramenti basati sulle sue conoscenze di metallurgia, affinate durante i molti anni di ricerche nel campo

dell'alchimia. Tali conoscenze non lo aiutarono a trasformare il piombo in oro, ma certamente furono utili per trasformare lingotti d'argento in monete.¹⁴

E poi c'era la questione della frequenza produttiva all'interno della grande coniazione. Ricordi l'infernale procedura meccanizzata, con la macchina per pasta sfoglia mangiatrice di dita di operai, alta due piani? I lavoratori pensavano che 3 o 4 monete al minuto fossero un ritmo accettabile, ma era evidentemente troppo poco per portare a termine la grande coniazione in tempo per evitare il disastro. Così Newton portò avanti personalmente uno studio dettagliato di tempi e movimenti degli operai sulla linea, e le modifiche da lui apportate li spinse a un ritmo di cinquanta monete al minuto. Tale ritmo fu mantenuto dalle quattro del mattino fino a mezzanotte, sette giorni su sette, per quasi due anni.¹⁵

Nel 1701, la grande coniazione era terminata, e non c'erano più monete realizzate a mano in Inghilterra.¹⁶ Newton era stato promosso al ruolo molto più prestigioso di direttore della Zecca, e indisse una prova della pisside. La commissione si riunì, le monete passarono il test e mangiarono tutti a spese del direttore. Newton si lamentò aspramente del conto della cena: due sterline per ogni membro della commissione, circa 200 sterline a testa in valuta odierna.¹⁷

La prova della pisside di Newton è notevole proprio perché finì con un nulla di fatto. Si trattava di Isaac Newton, il miglior controllore della qualità nella storia della Zecca reale. Aveva trascorso cinque anni a esaminare ogni dettaglio del processo di coniazione. Aveva sottolineato che le monete presentavano una variabilità troppo elevata rispetto ai limiti di legge. Aveva riconosciuto che l'eccessiva variabilità costituiva un problema per la Zecca da troppo tempo, e ridurla era diventata la sua ossessione. Infine, era il più grande matematico al mondo, ed era al centro di un pubblico processo, con gravi conseguenze, in cui la variabilità delle monete era *esattamente* la materia del contendere.

Era la persona giusta nel posto giusto al momento giusto per fare una scoperta fondamentale in campo statistico. Ma non successe. Newton mostrò di non accorgersi neppure che ci fosse un problema in cerca di soluzione e la prova della pisside continuò a commettere lo stesso errore per altri cento anni. Perché Newton non scoprì la regola della radice quadrata? È un mistero. È difficile immaginare che a Newton sia sfuggita una domanda così semplice: se le monete erano singolarmente molto più variabili rispetto ai limiti di

legge, come egli aveva esplicitamente riconosciuto, perché dunque avevano superato così tante Prove della Pisside per centinaia di anni?

È davvero un mistero, se si considera anche la grande passione di Newton per i problemi matematici, che non si spense neppure durante gli anni frenetici della grande coniazione. In un pomeriggio del 1696, per esempio, tornato a casa dalla Zecca alle 4 di pomeriggio, si mise a lavorare a un problema noto per la sua estrema difficoltà, chiamato “curva brachistocrona”, che era stato posto dal rivale matematico di Newton più irritabile, Johann Bernoulli.^{*h} Newton era molto stanco dalla giornata di lavoro alla Zecca ma, come scrisse nel suo diario, era ancora più stanco di «essere preso in giro e deriso [...] su argomenti di matematica». Dunque quel giorno saltò la cena e rifiutò di fare pause fino alle quattro del mattino successivo, quando completò la soluzione del problema e mostrò a Bernoulli chi era il migliore. Questo genere di comportamento era tipico di Newton, anche durante gli anni del suo cosiddetto pensionamento.¹⁸

Non fu dunque per mancanza di opportunità, di talento, di tenacia o di motivazione per il problema proprio davanti ai suoi occhi, che Newton non riuscì a vedere il suo errore. Questi sono gli ingredienti essenziali di ogni scoperta in campo scientifico. Il caso di Isaac Newton alla Zecca reale li conteneva tutti, ma non ci fu alcuna scoperta. Il lato ironico della faccenda è che, al confronto con il problema della curva brachistocrona, la matematica alla base della regola della radice quadrata sarebbe stata un gioco da ragazzi per Newton, se solo si fosse posta la domanda giusta. Ma non lo fece, e nessun altro lo fece per moltissimo tempo. La probabilità e la statistica non sarebbero nate come discipline per quasi un altro secolo e toccò a due grandi matematici di un’altra epoca – Gauss e Laplace – sviluppare il formalismo della regola della radice quadrata.

Rilevazione di anomalie nell’era dell’IA

Il periodo trascorso da Newton alla Zecca reale è un affascinante e, sorprendentemente, poco noto episodio storico, ma ha anche risvolti molto importanti per l’intelligenza artificiale. Mediare su molte misure è il concetto più importante nella storia della scienza dei dati. Un enorme numero di applicazioni dell’IA dipende da esso, dalla prevenzione delle frodi al

controllo intelligente, e il funzionamento di base è simile a quello della prova della pisside.

- Raccolta dati: vengono effettuate molte misure di un certo processo.
- Media: viene calcolata la media delle misure per fornire una “fotografia numerica” del processo.^{*i}
- Processo decisionale: la media è “abbastanza vicina” a ciò che ti aspetti o è al di fuori dei limiti di variabilità normale?

Ci sono tre grandi differenze rispetto all’epoca di Newton. La scelta di segnalare un’anomalia, di solito, è effettuata da una macchina piuttosto che da una persona. Tale decisione avviene nel giro di pochi millisecondi anziché di qualche anno. Infine, a differenza di coloro che gestivano la prova della pisside, le macchine non sbagliano i conti.

Questi sistemi di IA sono oramai ovunque. Le scuderie di Formula 1 controllano i dati provenienti da centinaia di sensori posti all’interno delle auto, alla ricerca di anomalie: temperatura del motore, usura degli pneumatici, aerodinamica, qualsiasi cosa possa avere ripercussioni sulle strategie di gara. Le aziende che emettono carte di credito passano al setaccio ogni transazione per rilevare possibili frodi. I poliziotti delle grandi città portano con sé sensori programmati per rilevare anomalie che potrebbero segnalare la presenza di bombe lasciate da terroristi. Facebook e Google, magazzini e drogherie, compagnie aeree e piattaforme petrolifere, senatori e operatori di borsa... effettuano misurazioni, le mediano e usano algoritmi per cercare anomalie all’interno di enormi insiemi di dati.

Sebbene la velocità e la dimensione di tali sistemi siano cambiate molto in tre secoli, il principio di base resta lo stesso: per rilevare un’anomalia devi capire la variabilità statistica.

Città intelligenti: grande N, grande D

Basta chiedere a chi lavora al Mayor’s Office of Data Analytics (MODA) di New York. Il MODA fu creato nel 2013 dall’allora sindaco Michael Bloomberg per analizzare l’immenso tesoro di dati municipali raccolti dall’amministrazione cittadina: qualsiasi cosa, dalle chiamate al 911, alle ispezioni degli edifici, ai resoconti botanici sui 5,2 milioni di alberi della città.

La ricchezza e l’ampiezza delle differenti fonti di dati del MODA rivela un fatto importante sull’intersezione tra insiemi di dati enormi e intelligenza

artificiale. Tali insiemi non contengono solo una “grande N ” (il numero di dati totali), ma anche una “grande D ” (il numero di dettagli registrati per ciascun dato). Per esempio, nel caso in cui il dato si riferisca agli appartamenti di New York, i dettagli possono essere la dimensione, la posizione e i servizi; nel caso di pazienti ospedalieri, i dettagli possono riguardare un insieme di indicatori di salute. “Grande N ” significa molti dati: molti appartamenti, molti pazienti e così via. “Grande D ” significa molti dettagli.

Possiamo pensare a un insieme di dati “grande N , grande D ” come a una collezione di molti sottoinsiemi che collettivamente presentano un’ampiezza vertiginosa (grande N) e una combinazione di dettagli altamente specifica (grande D). Di conseguenza, l’intelligenza artificiale viene raramente usata per cercare una singola anomalia in dati di questo tipo; si tratta piuttosto di cercare migliaia di possibili anomalie in milioni di posti diversi. Più grande e dettagliato è l’insieme di dati, più saranno i posti in cui cercare e più specifica sarà l’anomalia che sarai capace di rilevare.

Per esempio, New York ha solo 200 ispettori di edifici a disposizione per gestire più di 20 000 reclami all’anno riguardanti modifiche illegali agli appartamenti, come quelle in cui un proprietario trasforma uno spazio commerciale in uno residenziale o suddivide un appartamento già piccolo in minuscole unità.¹⁹ Questi ispettori devono utilizzare in modo intelligente le loro risorse, e dunque si sono rivolti al MODA affinché li aiutasse a trovare le caratteristiche che rendono più probabile un successo, ovvero un’ispezione che sveli una modifica illecita.

Per capire come funziona, immagina che il tasso di successo degli ispettori sia storicamente del 10% su tutti gli appartamenti. Ora considera i seguenti sottoinsiemi di appartamenti che, basandosi sulle ispezioni precedenti, sembrano dare probabilità più elevate di successo.

- Sottoinsieme A: immobile al quinto piano senza ascensore, a sud della Quattordicesima Strada, costruito prima del 1940, con negozio a piano terra. Percentuale di successo: 2 su 10 (20%).
- Sottoinsieme B: appartamento di due camere da letto, nuova costruzione, Queens. Percentuale di successo: 17 su 100 (17%).
- Sottoinsieme C: fabbrica di abbigliamento in disuso con più di cinque richieste di permesso per apertura ristorante nel raggio di cinque isolati. Percentuale di successo: 2 su 5 (40%).

Tutti questi sottoinsiemi hanno percentuali di successo maggiori del 10%, ma solo una costituisce un'anomalia, ovvero una percentuale difficile da spiegare in base alla sola casualità. Qual è? Prima di arrivare alla risposta, sottolineiamo l'idea chiave: esaminare ciascuno di questi sottoinsiemi equivale a fare una prova della pisside in miniatura. L'obiettivo è scovare un'anomalia, ovvero una differenza dalla percentuale globale di successo del 10%, che sia troppo grande da poter essere generata in modo casuale. (Suggerimento: fai attenzione all'ampiezza dei campioni.)

Potresti pensare che l'anomalia riguarda il sottoinsieme C, che presenta il valore più elevato di successo: 40%. Ma, in base alla regola della radice quadrata, la risposta giusta è in realtà il sottoinsieme B, quello con il valore *più basso*: 17%. Il motivo è che il sottoinsieme B è quello di ampiezza maggiore (100), e questo ci rende sicuri che l'elevato tasso di successo sia reale. I tassi in A e in C, invece, potrebbero essere alti a causa della variabilità del campionamento, ovvero potrebbe dipendere da quali specifici appartamenti sono stati già ispezionati. Questo ci riporta alla lezione imparata dall'esempio dei Patriots: la variabilità è molto importante per rilevare anomalie e campioni piccoli possono essere soggetti a grandi variazioni.*¹

Ovviamente, nel mondo reale gli insiemi possibili di appartamenti sono molto più di tre. Ecco perché facciamo ricorso all'IA, che riesce a scovare anomalie tra migliaia o milioni di possibili combinazioni di caratteristiche degli edifici, incluse quelle che un umano non riterrebbe importanti. Realizzare algoritmi in grado di fare ciò in maniera accurata ed efficiente continua a essere un importante argomento di ricerca. (Ti risparmieremo i dettagli matematici cruenti.)

Quando al MODA iniziarono ad applicare questi algoritmi per correlare i resoconti delle ispezioni con l'enorme collezione di dati provenienti da altre fonti municipali, ottennero risultati strabilianti. Gli ispettori moltiplicarono la loro percentuale di successo per *cinque*, e scoprirono due fattori altamente correlati a modifiche illegali degli appartamenti: picchi improvvisi nelle spese per servizi e aumento di segnalazioni per problemi legati ai servizi sanitari. Un altro team di ispettori utilizzò la stessa tecnica per identificare negozi che vendevano tabacco e alcol illegalmente, e anche in questo caso i tassi di successo aumentarono: dal 30% all'82%. E un terzo team riuscì a incidere sull'abuso di oppiacei, usando dati provenienti da richieste di rimborso al servizio sanitario nazionale per identificare un piccolo nucleo di farmacie –

circa l'1% del totale – che gestiva da solo il 60% delle prescrizioni cittadine di Oxycodone.²⁰

E ci siamo limitati agli ispettori. Immagina le possibilità di miglioramento per altre agenzie municipali se solo iniziassero a raccogliere e controllare nuovi tipi di dati, dalla polizia alla manutenzione delle strade, dal verde pubblico ai pompieri. Immagina, per esempio, quante vite potrebbero essere salvate se riuscissimo a identificare non solo dove e quando, ma anche *perché* si verificano incidenti tra automobili e pedoni. Ora inizi a capire perché le amministrazioni comunali di tutto il mondo celebrano la potenza dell'IA.

Annusare raggi gamma e perdite di gas

Una delle persone da celebrare potrebbe essere Alex Reinhart, un dottorando in statistica della Carnegie Mellon University che lavora a un nuovo sistema di rilevazione di anomalie, potenzialmente in grado di aiutare la polizia a disinnescare una delle più odiose minacce terroristiche: le bombe sporche.

Una bomba sporca è un'arma crudele e mortale che fa uso di esplosivo convenzionale per disperdere materiale radioattivo in aria. L'esplosione iniziale distrugge una piccola area, ma ne avvelena una molto più ampia, grande anche decine di isolati. La probabile buona notizia per la polizia è che ogni isotopo radioattivo emette raggi gamma di energia nota, collegata alla struttura atomica dell'isotopo. I raggi gamma anomali emessi da una bomba sporca potrebbero dunque, in linea di principio, essere rilevati da un "annusatore" prima che la bomba esploda.

Ma ci sono tre trappole, tre sorgenti di variabilità che rendono difficile segnalare un'anomalia. Per prima cosa, non puoi far scattare un allarme ogni volta che rilevi radiazione, perché una certa radiazione di fondo è ovunque. Molti materiali da costruzione, come mattoni e pietre, contengono piccolissimi quantitativi di uranio e torio radioattivi. Le banane e il concime da giardino presentano tracce di potassio radioattivo. Per non parlare dei raggi gamma, che arrivano dallo spazio in continuazione. I ricercatori usano il termine "NORM" come acronimo per Naturally Occurring Radioactive Materials (materiali naturalmente radioattivi), per riferirsi alle sorgenti benigne di raggi gamma. Sono innocue, ma implicano il non poter segnalare un'anomalia ogni volta che si rileva una radiazione.

Inoltre, questa radiazione di fondo varia da luogo a luogo, in particolar modo nelle grandi città. Se attraversi la strada o svolti l'angolo, durante la tua

caccia giornaliera alle bombe – una triste necessità per i poliziotti delle grandi città – passerai accanto a edifici di materiali diversi, ognuno con un profilo NORM leggermente diverso dagli altri.

Infine, la radiazione presenta rumore statistico, per motivi che hanno a che fare con la meccanica quantistica. Un isotopo radioattivo emette un numero casuale di raggi gamma di energie casuali in un definito intervallo di tempo. Quindi non potrai mai essere certo del fatto che un tale raggio gamma provenga dalla radiazione di fondo o da un'anomalia.

Il risultato è che la ricerca di anomalie da radiazione è un problema particolarmente spinoso. Devi confrontare la radiazione osservata, che è variabile, con la normale radiazione di fondo, anch'essa variabile nel tempo e nello spazio. Per fare ciò, hai bisogno di una mappa dettagliata della radiazione di fondo dell'intera città, insieme a un buon algoritmo che rilevi le anomalie in dati soggetti a rumore.

Al momento, la soluzione migliore fa ricorso all'intelligenza umana: in pratica, si assume qualcuno con un dottorato in fisica nucleare per esaminare i dati in tempo reale. Ma difficilmente questa può essere una soluzione adatta al tipo di operazioni antiterrorismo in atto a Londra, New York o Parigi, dove ci sarebbe bisogno di un piccolo esercito di persone con elevate competenze.

Reinhart e i suoi collaboratori, invece, propongono di utilizzare l'intelligenza artificiale. Immagino un poliziotto equipaggiato con un piccolo "annusatore" di raggi gamma collegato a uno smartphone con GPS integrato. Ogni due secondi, lo smartphone invia la lettura dell'annusatore e le coordinate GPS a un server centrale. Il server interroga un database geospaziale della radiazione di fondo cittadina, costruito nel corso di diversi mesi usando sensori mobili economici. La lettura attuale viene confrontata con il rumore di fondo tipico del luogo in cui si trova il poliziotto, usando la regola della radice quadrata per determinare i limiti oltre i quali segnalare un'anomalia. Se i limiti sono oltrepassati, il sistema segnala al poliziotto di indagare.

Le applicazioni di questa tecnologia geospaziale annusatrice non si limitano alla rilevazione di ordigni. Uno dei supervisori di Reinhart, il dottor Alex Athey, fa notare che ogni grande città possiede una gigantesca rete di tubature per il gas naturale, potenzialmente soggetta a pericolose perdite. Per esempio, New York ha più di 9000 chilometri di tubature sotterranee, e nel solo 2012 sono state scoperte 9906 perdite.²¹ Nel marzo del 2014, una di

queste perdite ha causato un'esplosione a East Harlem in cui hanno perso la vita otto persone.

Anche se una città potrebbe installare una nuova rete di tubature intelligenti in grado di far scattare un allarme in caso di perdite, questa soluzione sarebbe troppo invasiva e molto costosa. La soluzione proposta da Athey è molto più economica. Immagina di posizionare dei sensori per il metano sui veicoli pubblici, come i camion per l'immondizia, gli autobus urbani o le ambulanze. Col passare del tempo, questi veicoli attraverserebbero gran parte della città, costruendo una mappa di base dei livelli "normali" di metano. Se da qualche parte un tubo perdesse, quegli stessi sensori registrerebbero l'anomalia molto più velocemente della società fornitrice di gas e in modo molto più economico rispetto a modificare migliaia di chilometri di tubature poste diversi metri sottoterra.

La lotta alle frodi oggi

Ispettori e poliziotti non sono i soli a dare la caccia ai furfanti scovando le anomalie in enormi insiemi di dati. Anche le maggiori banche mondiali si stanno affidando sempre di più all'intelligenza artificiale per difendersi dalla maledizione della moderna economia digitale: le frodi.

La frode potrebbe essere il secondo mestiere più vecchio del mondo. Gli antichi greci credevano in Apate, dea dell'inganno e uno degli spiriti malvagi contenuti nel vaso di Pandora. Gli egizi impiegavano un'intera classe sociale, gli scribi, per controllare le transazioni riguardanti le riserve di grano del faraone. E qualcuno deve aver fatto qualcosa di terribile 3000 anni fa per suscitare l'ira di re Salomone, che nel capitolo 11 del Libro dei Proverbi dice: «La bilancia falsa è in abominio al Signore, ma del peso esatto egli si compiace».

Fino a poco tempo fa, la lotta alle frodi era combattuta usando l'intelligenza umana. Nel 1685, le monete d'argento erano ispezionate e pesate. Nel 1885, il valore delle cambiali dipendeva dalla reputazione. Nel 1985, gli assegni erano accettati solo se i dati personali combaciavano con quelli riportati sui documenti di identità. Oggi, invece, viviamo in un mondo di chip e PIN, e il controllo personale non è più possibile. Le banche americane, per esempio, nel 2015 hanno gestito 178 000 *miliardi* di dollari in transazioni senza uso di contanti. Quel numero include 70 miliardi di pagamenti con bancomat, 34 miliardi di pagamenti con carta di credito e 24

miliardi di bonifici.²² Purtroppo, sono incluse anche transazione fraudolente per miliardi di dollari, in gran parte a danno di commercianti al dettaglio, che poi scaricano il costo su tutti noi. Per ogni dollaro speso in drogheria, 1,3 centesimi vanno ai truffatori digitali: i limatori di monete del mondo odierno.

Fortunatamente, gli scienziati stanno lavorando a sistemi di IA in grado di rispondere all'attacco. Il punto chiave, come in tutti i casi di rilevazione di anomalie, è la misura della variabilità. Pensa alle tue abitudini di spesa, che variano in maniera predicibile da giorno a giorno e da settimana a settimana. Tale variabilità è la base statistica che permette alle frodi di essere rilevate.

Per anni, ogni maggiore istituto di credito ha analizzato le transazioni dei bancomat e delle carte di credito in tempo reale alla ricerca di frodi, e questo è il motivo per cui la tua carta a volte viene rifiutata. Ma gran parte di questi metodi obsoleti è basata su semplici regole prefissate, come l'ammontare e il luogo della transazione. Ciò trascura una fetta importante della variabilità da persona a persona. Nel caso di un insegnante, tre pagamenti con carta di credito in tre diverse nazioni nel corso di una settimana scolastica potrebbero essere un chiaro indizio di frode. Per un agente di commercio sempre in viaggio, lo stesso schema potrebbe invece essere normale e la differenza tra questi due clienti dovrebbe emergere chiaramente dal loro storico di transazioni.

Potresti pensare che le aziende che rilasciano carte di credito abbiano scandagliato le tue transazioni per anni in modo da rilevare tali differenze. In effetti lo hanno fatto, ma in modo limitato, e principalmente a ignobile scopo di marketing. Sfortunatamente, si è rivelato molto difficile sfruttare tutti quei dati di pagamento per sviluppare un sistema di pagamento in tempo reale che accetti o rifiuti la tua carta nel giro di un decimo di secondo.

Il motivo è semplice: la colossale sfida ingegneristica che deriva dallo studio di insiemi di dati su scala così ampia. Le aziende che emettono carte di credito generano petabyte di dati, e un petabyte corrisponde a circa 220 000 DVD. Fino a poco tempo fa, nessun sistema di IA era sufficientemente veloce da sfruttare tutti quei dati per rilevare frodi in tempo reale. Avevano tutti dei punti deboli, la performance dell'algoritmo di rilevazione, la velocità della rete o l'incredibilmente lento processo di lettura di tutti quei trilioni di 1 e 0 da un supporto fisico.

Di conseguenza, le banche dovevano ricorrere a un compromesso. Se volevano analizzare 100 miliardi di transazioni nel giro di millisecondi, erano limitate dalle semplici regole di rilevazione delle anomalie basate su "piccoli

D”, ovvero sul luogo, la data o l’ammontare della transazione. Se volevano invece sfruttare lo straordinario livello di dettaglio incluso nei singoli storici di transazione di ogni utente, erano costrette ad attendere mesi, non millisecondi, per rilevare anomalie. Potevano scegliere tra grandi *N* o grandi *D*, ma non potevano avere entrambi.

PayPal è solo una delle aziende che gestiscono sistemi di pagamento ad aver risolto finalmente il problema, con l’aiuto di moderni algoritmi e moderne infrastrutture informatiche. Il suo sistema di rilevazione di frodi usa il deep learning per confrontare ogni transazione con lo storico precedente e con il comportamento di altri utenti simili a te. Sulla base di questo confronto, che usa migliaia di possibili parametri, il sistema produce una probabilità di transazione fraudolenta che può essere utilizzata per accettare o rifiutare il pagamento, tutto in una frazione di secondo.

Con questo nuovo sistema, PayPal dispone ora di una stima molto migliore dei limiti normali di variabilità nei suoi dati, fino al livello dell’utente individuale. Il suo investimento in IA ha dato i suoi frutti: il tasso di frodi è sceso allo 0,32% delle entrate nel 2016, meno di un quarto della media del settore.²³ Altri aziende come Alipay in Cina o Stripe negli Stati Uniti hanno investito in tecnologie simili. E i sistemi continuano a migliorare, perché a ogni transazione imparano qualcosa in più sulle frodi.

Re Salomone e Isaac Newton ne sarebbero orgogliosi.

Moneyball per l’era digitale

Se sei un appassionato di sport, avrai probabilmente sentito parlare di *moneyball*, il termine coniato dallo scrittore Michael Lewis per indicare un determinato approccio, basato sui dati, nel costruire e allenare una squadra sportiva. Alla fine degli anni novanta, la squadra di baseball di Oakland si rese conto che i talent scout non erano molto efficaci nel determinare quali caratteristiche possedeva un buon giocatore. Molto di ciò che veniva attribuito all’abilità era in realtà dovuto alla fortuna e viceversa: confondevano sistematicamente segnale e rumore. Basandosi sui consigli dei loro talent scout, molte squadre di baseball pagavano milioni di dollari per giocatori che tuttavia non risultavano decisivi per vincere le gare o che non riuscivano a replicare le performance passate. Nel frattempo, molti altri giocatori passavano inosservati, nonostante fossero determinanti per le loro squadre

grazie a qualità importanti e utilizzabili anche altrove, ma non semplici da individuare. Questa inefficienza creò l'opportunità affinché un team riuscisse a trovare un modo migliore di agire.

Le innovazioni di Oakland erano di tre tipi. Usavano i dati per determinare quali caratteristiche e quali abitudini di gioco di un atleta erano davvero in grado di far vincere una partita. Poi usavano queste informazioni per cercare anomalie nel mercato, caratteristiche e abitudini vincenti che erano sistematicamente sottovalutate dagli altri team. Infine ingaggiavano i giocatori con quelle specifiche caratteristiche e li allenavano in modo da sviluppare quelle specifiche abitudini di gioco. Una volta fatto questo, Oakland fu in grado di competere con – e battere – squadre come i Red Sox e gli Yankees, che potevano permettersi di spendere tre volte tanto.

A distanza di venticinque anni, queste innovazioni hanno cambiato quasi tutti gli sport del mondo. Oggi, tuttavia, c'è una differenza importante. Nel 1990, il moneyball poteva essere gestito con un foglio di calcolo e un bravo tirocinante. Oggi hai bisogno di un supercomputer collegato a un server cloud e di un team di analisti specializzati, tutto a causa degli enormi insiemi di dati che le squadre professionistiche hanno iniziato a raccogliere dopo essersi rese conto del vantaggio che questo poteva dar loro.

Formula 1

Il simbolo di questa rivoluzione è la Formula 1, la competizione automobilistica più famosa al mondo. Durante le gare di Formula 1, i dati scorrono più veloci dello champagne nei palchi vip. Ogni aspetto della performance di una monoposto è esaminato in tempo reale e in grande dettaglio. Un'automobile di Formula 1 genera diversi gigabyte di dati per giro di pista, più o meno l'equivalente di trenta ore di canzoni o 6000 ebook. Questi dati sono comunicati via wireless alla scuderia, che fa uso di algoritmi sofisticati per rilevare anomalie che potrebbero influenzare la strategia di gara: potenza del motore, temperatura dei freni, consumo di carburante, rivestimento degli pneumatici, accelerazioni laterali, pressione sull'alettone posteriore e altre centinaia di variabili. Le scuderie non devono più aspettare che un pezzo di macchina ceda all'improvviso, rovinando la gara. Ora possono predire l'evento prima che accada.

In realtà, lo sfruttamento dei dati non si limita alla gara. Anche nella Formula 1 c'è una costosa corsa ad accaparrarsi specialisti di tecnologia e, per

limitare il fenomeno, le regole impongono un numero massimo di persone al lavoro per ogni scuderia durante la gara. Senza questo limite, le scuderie maggiori relegherebbero le minori nel dimenticatoio: dopotutto, si tratta di uno sport dove si spendono 100 milioni di dollari all'anno in motori e si utilizzano tre persone *per ogni pneumatico* durante i pit stop. I team più ricchi hanno ritenuto, tuttavia, di aver bisogno di ulteriore potenza di calcolo, e dunque si sono rivolti a ingegneri fuori dalle piste. Red Bull Racing, per esempio, ha recentemente stretto un accordo con AT&T per costruire una rete globale di trasmissione dati da ogni circuito di Formula 1 nel mondo al quartier generale del team a Milton Keynes, in Inghilterra. Lì, un secondo team di analisti controlla in tempo reale la monoposto della Red Bull. *Quasi* in tempo reale, in realtà: il fattore limitante per la performance del sistema è la velocità della luce, che può fare il giro del mondo solo 7,5 volte in un secondo. Questo tipo di investimento dovrebbe darti un'idea di cosa voglia dire per gli ingegneri "rilevazione delle anomalie *in tempo reale*".

Le scuderie di Formula 1 sono diventate talmente esperte nel controllo in tempo reale che alcune hanno iniziato a vendere i loro prodotti ad altre aziende. Il team McLaren, per esempio, ha recentemente creato un'azienda per il suo gruppo di analisi dei dati, chiamata McLaren Applied Technologies, che ha immediatamente siglato un accordo con la società di consulenza KPMG. Tra le altre cose, ora aiuta clienti nell'industria petrolifera a controllare i dati di sensori posti su trivelle, alla ricerca di anomalie che potrebbero indicare problemi.

Oltre la pista

Queste innovazioni si sono diffuse in altri sport. Nel 2016, per esempio, i Brooklyn Nets hanno firmato un contratto di sponsorizzazione con una compagnia chiamata Infor, quasi sconosciuta a coloro al di fuori dell'ambiente del software aziendale. Infor produce software per analisi dei dati – anche per la Scuderia Ferrari di Formula 1 – e, sebbene abbia pagato milioni di dollari per mostrare il proprio logo sulla divisa dei Nets, ha portato a casa dal tavolo delle trattative molto più del solo libretto degli assegni usato.

Brett Yormark, il CEO dei Nets, ha spiegato di aver venduto lo spazio sulla divisa a un partner strategico «fondamentale per incrementare la performance dentro e fuori dal campo». Il contratto firmato con Infor rappresenta la nuova

era moneyball della NBA, in cui alcune delle stelle della lega porteranno il logo di un'azienda di analisi dei dati sulle divise.²⁴

Nella NBA, gran parte di questa rivoluzione è dovuta a nuove sorgenti di dati, come sensori di movimento su ogni giocatore e videocamere che coprono ogni angolo del campo di gioco. Ma è anche dovuta a un cambiamento diffuso nella filosofia della costruzione di una squadra, e da un forte investimento in capacità di analisi. I Sacramento Kings, per esempio, hanno di recente assunto Luke Bornn, in precedenza ricercatore in statistica a Harvard, per scandagliare i dati video e di tracciamento dei giocatori. Come ha detto Bornn in un'intervista a NBC Sports:

Molto di ciò che avviene oggi in campo non viene descritto dal tabellone del risultato. Diversi giocatori apportano grandi contributi in maniera non evidente. Non con un assist, né con un rimbalzo, né con una stoppata.²⁵

Si tratta di altro, qualcosa che in precedenza non veniva notato dagli allenatori, ma era “nascosto in bella vista” all'interno dei dati, in attesa di essere scoperto. Bornn è persuaso che usare l'intelligenza artificiale per scandagliare dati alla ricerca di anomalie aiuterà i Kings a trovare giocatori sottovalutati e allenarli in maniera innovativa. Insieme a un gruppo di colleghi, per esempio, ha recentemente pubblicato un lavoro su misurazioni avanzate di abilità difensive nel basket. Usando dati raccolti da videocamere montate sulle travi delle arene NBA, sono stati in grado di rispondere a due semplici domande che non erano mai state prese in considerazione nelle statistiche del basket in precedenza: chi marcava chi, in ogni azione di gioco, e come si comportavano i singoli difensori di fronte ai singoli attaccanti?

Bornn e colleghi hanno scoperto che la *scelta* se tirare o meno (dove e quando un giocatore tira a canestro) e l'*efficienza* del tiro (se il tiro va a canestro) sono due componenti distinte dell'abilità difensiva nel basket. Queste componenti hanno anche un'evidente dipendenza dallo spazio, ovvero da dove il difensore si trova sul campo di gioco. Nei pressi del canestro, per esempio, il centro Dwight Howard è al di sopra della media nel ridurre la frequenza di tiro, ma è al di sotto della media nel ridurre l'efficacia di tiro ed è al di sotto della media in entrambi i casi quando è lontano dal canestro. Questa scoperta ha permesso a Bornn e colleghi di predire il risultato di specifici scontri in difesa. Per esempio, il loro modello ha previsto che LeBron James avrebbe segnato meno punti contro Kawhi Leonard quando

giocava per i San Antonio Spurs, rispetto a qualsiasi altro difensore della NBA.²⁶ Non dipende solo dal fatto che Leonard è in assoluto un difensore di talento: è che il suo peculiare mix di abilità difensive risulta favorito di fronte alla tipologia di abilità offensive di James.

Anche le abitudini giornaliere dei giocatori NBA vengono setacciate alla ricerca di anomalie, e questa declinazione “comportamentale” del moneyball è davvero inedita. Il playmaker Jeremy Lin crede che la collaborazione del suo team con Infor abbia dato i suoi frutti, aiutandolo a prendersi cura del proprio corpo come una scuderia di Formula 1 si prende cura delle sue monoposto. In particolare, riconosce all’analisi dei dati avanzata di aver migliorato il suo sonno e averlo aiutato a riprendersi più velocemente da una fastidiosa tendinite.²⁷ Anche in altre federazioni sportive, le squadre hanno iniziato a utilizzare l’IA, per lo stesso motivo per cui hanno accettato di mettere pubblicità sulle divise: un bel po’ di soldi in vista. Per esempio, il Leicester, nella Premier League inglese di calcio, ha fatto davvero buon uso dei dati di tracciamento della posizione dei giocatori durante la stagione trionfale 2015-2016. La squadra accedeva ai dati grazie a un sistema chiamato Prozone 3, che combina videocamere e sensori indossabili. Come tutte le squadre della Premier League, ha utilizzato quei dati per adattare le tattiche di gara a ogni avversario. Ma il Leicester ha anche setacciato i dati per trovare qualcos’altro: anomalie nei movimenti e nel carico di lavoro di un giocatore che suggerissero un rischio elevato di infortunio. Questi sforzi hanno dato alla squadra il tasso più basso di infortuni e la formazione di partenza più uniforme di tutta la Premier League.

Post scriptum

Ti lasciamo con un dettaglio sulla prova della pisside. Sebbene le monete inglesi non siano più fatte in argento, la prova si svolge ancora oggi. Ogni anno, il secondo martedì di febbraio, una commissione di orafi si riunisce a Londra per pesare un campione di monete e valutare la loro qualità. Fortunatamente, hanno imparato dagli errori del passato: i limiti per segnalare un’anomalia vengono calcolati in modo statisticamente corretto fin dalla metà dell’Ottocento.

Ma c’è un’altra differenza: per gli ultimi settantacinque anni circa, la commissione ha anche valutato lo spessore e il diametro delle monete. Queste

misurazioni non erano importanti al tempo di Newton. E, curiosamente, non lo sono nemmeno oggi, in quanto vennero introdotte per rispondere alle esigenze di un effimero intervallo di tempo nella storia inglese, in cui i londinesi erano soliti usare monete per fare telefonate da cabine rosse agli angoli delle strade.

***a** Abbiamo anche simulato le ventiquattro partite precedenti alla prima partita del 2007, in modo che la media su venticinque partite fosse ben definita all'inizio della serie da 176 partite in questione. Questo implica che la percentuale di vittoria calcolata su venticinque partite a partire dal 2007 fa riferimento, in realtà, anche a match che risalgono a metà del 2005.

***b** Se hai seguito un corso di statistica, riconoscerai in questo numero il *value p* ($p = 0,23$) dell'ipotesi nulla (nessun imbroglio).

***c** Due sinonimi di anomalia in cui potresti esserti imbattuto sono “segnali nel rumore di fondo” o “violazione dell'ipotesi nulla”.

***d** Questa iscrizione, *Decus et Tutamen*, restò sulle monete inglesi fino al 2017, quando fu tristemente rimossa dall'ultima versione della moneta da una sterlina.

***e** La Prova deve il suo nome a un locale dell'abbazia di Westminster, la camera della pisside. Pisside è un antico nome greco che indica il recipiente contenente le ostie per la comunione. Le monete in attesa della prova venivano conservate in una scatola, e la scatola veniva posta nella camera, da cui la prova della pisside.

***f** Stiamo arrotondando per semplificare i numeri. Il rimedio era in realtà pari a 48 grani per libbra d'argento, ovvero circa 7 grammi per chilo, lo 0,7% del peso. Vedi Stigler, *Statistics on the Table*, capitolo 23.

***g** Se hai voglia di vedere la matematica alla base della regola della radice quadrata, leggi il riquadro. Tuttavia, non è indispensabile per capire il messaggio principale di questo capitolo.

***h** Bernoulli pensava che la teoria della gravitazione di Newton fosse priva di senso, ed era amico di Leibniz, che aveva avuto in precedenza una disputa con Newton sul calcolo infinitesimale.

***i** Molti di questi sistemi non si basano su una comune media, ma su altri tipi di “fotografia numerica” dei dati. Un semplice esempio è la mediana, mentre esempi più complicati sono chiamati “analisi delle componenti principali” o “test di Kolmogorov-Smirnov”. Sono dettagli poco importanti: resta la necessità di comprendere la variabilità statistica, sia usando la media sia altri tipi più elaborati di fotografie numeriche.

***l** Anche questi altri sottoinsiemi potrebbero presentare anomalie, ma abbiamo bisogno di più dati per esserne certi. In pratica, si tratta di fare un compromesso tra esplorare insiemi con pochi dati e andare sul sicuro con insiemi che presentano anomalie evidenti.

LA DAMA CON LA LANTERNA

Cosa può insegnarci la guerra di Crimea sulla probabile futura rivoluzione nella salute pubblica indotta dall'IA e sulla cultura e le istituzioni che permettono all'innovazione di mettere radici.

Se segui gli ultimi aggiornamenti sulla salute pubblica, ti imatterai in due narrazioni molto diverse.

Per prima cosa, le brutte notizie: i sistemi sanitari dei paesi ricchi vacillano sotto il peso di popolazioni anziane e malate. L'obesità e le malattie cardiache sono in aumento e i costi stanno andando fuori controllo. Nel 2016, due terzi di tutti gli ospedali del Regno Unito erano in perdita e il sistema sanitario francese era in rosso di 3,4 miliardi di euro. Gli americani, nel frattempo, spendevano molto più di tutti gli altri in salute pubblica, in percentuale del PIL, ma non erano per questo più in salute. I dottori passano le loro giornate a combattere con le compagnie di assicurazione, sudando dietro cause legali e inserendo dati sanitari in un sistema elettronico; rispetto al resto della popolazione, i medici hanno il 40% di probabilità in più di fare abuso di alcool e droghe, e il doppio delle probabilità di suicidarsi.¹

Ci hanno anche raccontato, probabilmente come antidoto per queste storie deprimenti, che l'intelligenza artificiale rivoluzionerà la salute pubblica. Gli evangelisti dell'IA descrivono un mondo futuristico in cui il tuo chirurgo sarà supportato da un robot telecomandato, proprio come l'automobile di Google; i tuoi parametri vitali saranno controllati da un algoritmo alla ricerca di anomalie, proprio come la tua carta di credito; e le terapie saranno personalizzate, proprio come il tuo account Netflix. È un mondo in cui il tuo Fitbit può dirti se stai entrando in travaglio; in cui puoi scattare la foto di una ferita e ricevere una diagnosi istantanea sul tuo telefono; e in cui il tuo smartwatch sa quali tasti toccare per spingerti a mangiare più verdura o a fare le scale.

In questo mondo, i medici non trascorrono più un terzo del loro tempo a inserire dati manualmente: dicono tutto a una specie di Amazon Echo pompato di steroidi, che aggiorna immediatamente i tuoi dati sanitari che vengono successivamente analizzati usando sofisticate regole di predizione, allenate su database enormi, che aiutano i medici a rilevare problemi nascosti. È un mondo in cui la collaborazione tra intelligenza umana e intelligenza artificiale è perfetta: sensori economici indossabili, associati a tecnologie di controllo e diagnosi basate sull'IA, permettono un avanzamento significativo nell'assistenza alle categorie scarsamente servite, prima nei paesi ricchi, poi nei paesi in via di sviluppo. Le nascite diventeranno più sicure, le malattie saranno diagnosticate con più anticipo e l'enorme potenziale umano verrà finalmente a galla.

Speriamo che tu sia d'accordo sul fatto che questo mondo sembra davvero fantastico, a patto di riuscire a risolvere le tue preoccupazioni sulla privacy, cosa che proveremo a fare in questo capitolo. Quindi la nostra domanda è: perché non siamo già arrivati a questo punto? Tutte le tecnologie che abbiamo elencato esistono già a un certo livello di ricerca e sviluppo, ed è abbastanza evidente ciò che manca per consentire la loro adozione su larga scala: dati migliori, maggiore collaborazione tra professionisti sanitari e analisti di dati, leggi migliori che possano favorire l'innovazione salvaguardando i pazienti e la loro privacy. Ma, come leggerai in questo capitolo, il solo fatto che *sia possibile fare* qualcosa di buono con i dati, non implica che *sarà fatto*.

Fino a questo momento abbiamo riportato esempi di straordinario progresso tecnologico in IA. Ora esamineremo l'interazione tra tecnologia e *cultura*: i valori, gli incentivi e le abitudini che regolano il comportamento delle persone. Per mettere in atto il tipo di rivoluzione sanitaria che ricerchiamo, abbiamo certamente bisogno di risorse, dati e persone. Ma abbiamo principalmente bisogno di un'adesione di tipo culturale – da parte di medici, infermieri, ospedali, corporazioni, legislatori e pazienti – per mettere insieme le risorse, i dati e le persone. Google, Facebook, Amazon, PayPal, Baidu, Alibaba, Formula 1, l'Ufficio analisi dei dati del sindaco di New York, la produzione di cetrioli di Makoto Koike in Giappone hanno tutti preso questo impegno nei rispettivi campi, ottenendo risultati straordinari. E questo rende assai triste il fatto che la sanità sia ancora indietro da questo punto di vista, nonostante l'IA possa aiutare molte più persone in questo campo che in qualsiasi altro. Siamo forse ancora lontani da una realtà in cui le più avanzate tecnologie di IA saranno di aiuto per un grande numero di pazienti, ma i

motivi hanno più a che fare con cultura, incentivi e burocrazia che con la scienza e la potenza computazionale. E non è solo un problema statunitense. I sistemi sanitari in America, Europa e Asia differiscono per molti aspetti, ma hanno molte cose in comune in termini di ciò che l'IA potrebbe fare e non sta facendo. Il cancro e le patologie renali non hanno nazionalità, ma la parola burocrazia esiste in ogni lingua.

In un momento storico come questo, è di aiuto individuare l'esempio di qualcuno che si è imbattuto in un problema simile e lo ha risolto, qualcuno che aveva la conoscenza, il prestigio e la determinazione di contrapporsi alle strutture di potere che gestivano i sistemi sanitari e dire a nome di tutti. Basta, perché fate così? Non vi rendete conto che potremmo fare molto meglio?

Fortunatamente, conosciamo una persona del genere: Florence Nightingale.

Forse saprai, ma dipende dalla tua età, che Nightingale è stata l'infermiera più famosa di tutti i tempi – la “dama con la lanterna” – e divenne il simbolo vivente della compassione prendendosi cura dei soldati britannici durante la guerra di Crimea. Sappiamo che, oltre a occuparsi dei soldati, Nightingale era anche un'esperta analista di dati e riuscì a convincere gli ospedali che potevano migliorare i trattamenti usando la *statistica*. In effetti, nessun altro analista di dati può dire di aver salvato altrettante vite di Florence Nightingale. Nel 1859, come riconoscimento per i suoi risultati, fu la prima donna a essere inclusa nella Royal Statistical Society.

Il percorso seguito da Nightingale per sfruttare la potenza dei dati sanitari offre tre diverse lezioni. Per prima cosa, illustra il tipo di coinvolgimento istituzionale necessario affinché una rivoluzione basata sui dati si verifichi in un determinato campo. Se sei davvero interessato a capire come l'IA potrebbe cambiare il tuo campo professionale, non c'è lezione migliore.

Poi ti mostra cosa devi aspettarti in quanto paziente che aspira alle cure migliori. Nei suoi sforzi per migliorare l'analisi dei dati in ambito sanitario a metà dell'Ottocento, Nightingale fronteggiò strenue resistenze che cercavano di conservare lo status quo e di respingere cambiamenti utili ai pazienti. Al giorno d'oggi assistiamo a una battaglia sorprendentemente simile ma, se allora assunse i contorni di una tragedia, oggi appare una farsa.

Infine, la storia di Nightingale è di ispirazione. Gli odierni sistemi sanitari potrebbero beneficiare di persone con la tenacia, l'intelligenza e il coraggio morale che Florence Nightingale mostrò 160 anni fa. Forse una di quelle persone sei tu.

L'angelo della Crimea

Florence Nightingale era nata nel 1820 tra agi e privilegi. Ogni anno la sua famiglia affittava una suite d'hotel per la stagione londinese, prima di ritirarsi in una delle proprietà di campagna. Quando andavano in vacanza in Europa, viaggiavano in una carrozza da dodici posti e si regalavano intrattenimenti sfarzosi: un'opera ogni settimana, balli infiniti, banchetti offerti dal granduca di Toscana.²

Ma Florence si sentiva in una gabbia dorata. Aveva due grandi passioni, ma non riusciva a soddisfarle nei divertimenti della vita di salotto.

Il primo amore fu la matematica. Già da bambina, Florence si buttava a capofitto nel libro di matematica e risolveva problemi di ere passate: «Se nel mondo ci sono 600 milioni di pagani, quanti missionari ci vogliono per avere un missionario ogni 20 000 pagani?». ³ Inventava giochi di parole matematici: «Ho preso “respiro” e ho composto quaranta parole» scrisse all'età di sette anni.⁴ Da adolescente, imparò la geometria leggendo Euclide e i logaritmi da suo cugino Henry, e supplicò i genitori di permetterle di far visita allo zio Octavius, che aveva una fantastica biblioteca matematica.⁵

Ancora più della matematica, Florence amava la professione di infermiera. Da bambina curava cani feriti, scrisse un epitaffio per uno scricciolo e soffrì per il brutto raffreddore di una mucca; da adolescente faceva visita ai malati e ai poveri del villaggio locale quasi ogni giorno. Quando Florence di sera spariva, sua madre sapeva di dover andare a bussare alle porte del villaggio, dove la trovava «seduta al capezzale di qualche malato, dicendo di non riuscire a sedersi a una tavola imbandita per la cena delle sette». ⁶ Quando vi si sedeva, non mancava di porre domande imbarazzanti agli ospiti, non importa quanto altolocati, che distoglievano volentieri lo sguardo dalle sofferenze degli altri.

Si indirizzò fin da subito a una carriera da infermiera professionale, scrivendo nel suo diario: «La mia mente è tormentata dal pensiero delle sofferenze umane [...] tutto ciò che i poeti celebrano del mondo mi sembra falso. Tutte le persone che vedo sono divorate dalla povertà o dalle malattie». Si svegliava alle tre del mattino per leggere tutto ciò che riusciva a recuperare sulle politiche sociali: statistiche di censimento, note parlamentari, un *Resoconto sulle condizioni sanitarie delle classi lavoratrici della Gran Bretagna*.

I suoi genitori, purtroppo, trovavano le sue ambizioni frustranti e bizzarre, totalmente inadatte a una signora del suo rango, e si opposero al suo desiderio di iscriversi a un programma di formazione per infermiere. Florence rispose respingendo il loro concetto di donna «tirata su a pane e zucchero», che vive come una «allodola cinguettante al sole» e che «non si degna di mettere piede nell'affollata conigliera, dove gli abitanti scavano e si rintanano nella polvere».⁷ Si sentiva in colpa per essere così infelice, quando lei stessa poteva godere dei privilegi mentre molti altri conducevano misere esistenze di sofferenza. Giunta al suo trentesimo compleanno, con la famiglia che ancora ostacolava i suoi desideri, iniziò ad avere pensieri depressivi e di suicidio.

Alla fine la forza di volontà di Florence – che la sorella Parthenope definiva «la cosa più inscalfibile e più risoluta in cui mi sia imbattuta» – trionfò. All'età di trentun anni ottenne finalmente il permesso dei genitori per formarsi come infermiera a Kaiserswerth, un famoso ospedale benefico in Germania. Fu un punto di svolta. Il suo apprendistato a Kaiserswerth comportava lunghe ore a contatto con malati e disperati. Fasciava ferite, trattava il tifo, curava gli amputati e sedeva al capezzale dei moribondi. L'esperienza la fece sentire una donna completamente nuova. Stava finalmente rispondendo alla chiamata che sentiva da tutta la vita e, come un amico le scrisse, «la vacua vita quotidiana ti sembrerà più insopportabile che mai dopo che hai sperimentato la tua vera scelta».⁸

In effetti, quando Nightingale fece ritorno in Inghilterra, né la sua famiglia né le convezioni sociali della sua classe di appartenenza la trattennero dal realizzare i suoi sogni. Cominciò a lavorare all'ospedale femminile di Harley Street a Londra, guadagnandosi rapidamente una reputazione per talento e compassione, e nel 1854 le fu offerto il lavoro dei suoi sogni: sovrintendente delle infermiere al King's College Hospital. Ma la storia aveva altri piani per lei: in ottobre, al divampare della guerra di Crimea tra Gran Bretagna e Russia, Florence Nightingale fu chiamata a servire il suo paese.

«Aria viziata e danni evitabili»

La scintilla per la guerra di Crimea scoccò nel 1853, quando la Russia invase i Balcani minacciando la Turchia, alleato dei britannici. In risposta, la Gran Bretagna dichiarò guerra alla Russia nel marzo del 1854, mandando truppe nella penisola di Crimea per assediare Sebastopoli, il porto principale della flotta russa nel Mar Nero. A Londra la gente, in pieno fremito nazionalista,

pensava che la guerra sarebbe finita in un lampo. Le speranze di facile vittoria vennero subito smentite quando apparve chiaro che l'esercito britannico, a distanza di due generazioni dall'ultima grande guerra – nel 1815 contro Napoleone –, era totalmente impreparato ad affrontare la Russia.⁹

Questo era ancora più evidente nel decrepito sistema sanitario delle forze armate, in cui le regole base su igiene e approvvigionamenti dipendevano dal buon cuore degli ufficiali in comando. Il risultato della scarsa programmazione fu una catastrofe logistica e umanitaria. Un soldato ferito in Crimea veniva spedito su una nave sudicia a 500 chilometri di distanza, al Barrack Hospital di Scutari, dalla parte opposta del Bosforo rispetto a Costantinopoli. All'arrivo, aspettava fino a tre giorni prima di essere portato a terra, caricato su una lettiga o legato a un mulo. A questo punto affrontava la ripida scalata alla collina dove si trovava un lurido ospedale. Qui lo accoglieva una carneficina, sotto forma di commilitoni distesi su materassi sottili in mezzo a topi, sangue, tanfo e sporco. Colera e dissenteria imperversavano: le fognature erano intasate, i bagni scaricavano escrementi in cortile e una conduttura dell'acqua era ostruita dalla carcassa di un cavallo.¹⁰ L'ospedale era costantemente a corto di attrezzature mediche, biancheria pulita, cibo sano e cloroformio e molte amputazioni venivano eseguite senza disinfettante.¹¹ I medici erano pochi e quelli che c'erano correvano avanti e indietro da un'emergenza all'altra, schivando uomini e cadaveri.

Nell'autunno del 1854, venne effettuata un'ispezione approfondita sulle condizioni dell'ospedale di Scutari. Un articolo del 30 settembre sul "Times" rendeva conto dell'indignazione collettiva:

Non solo vengono lasciati morire agonizzanti, ignorati e abbandonati, cercando disperatamente di afferrare il chirurgo durante i suoi giri sulla fetida nave, ma ora apprendiamo che, quando entrano [in ospedale], dove credevano che tutto fosse pronto per alleviare le loro sofferenze e facilitare il loro recupero, non trovano nemmeno il minimo indispensabile per un ambulatorio di guardia.¹²

Sidney Herbert, ministro della guerra e amico di famiglia dei Nightingale, era enormemente sotto pressione. Aveva osservato la rapida ascesa di Florence nel campo dell'infermieristica e le fece una proposta. Le interessava essere a capo di un gruppo di infermiere, pagate dal governo, a Scutari per assistere i medici e alleviare le sofferenze degli uomini?

Florence accettò immediatamente e si preparò al peggio. Ma niente poteva prepararla alle condizioni che trovò all'arrivo: sei chilometri di corridoi pieni di uomini con ferite spaventose, che dormivano a quaranta centimetri l'uno dall'altro, circondati da «aria viziata e danni evitabili». La catena dei rifornimenti, per di più, era interrotta. Nightingale non riusciva a trovare garze per fare bendaggi o camicie pulite per sostituire quelle intrise di sangue. Era pieno di «cancrene, pidocchi, insetti e pulci» mentre mancavano «spazzoloni, stoviglie, carrelli, scarpe [...] coltelli e forchette, forbici (per tagliare i capelli degli uomini, che hanno letteralmente vita propria), bacinelle, asciugamani, borotalco». Imparò presto che le richieste di rifornimenti dovevano passare attraverso otto diversi uffici governativi a Londra e quando venivano finalmente processate, arrivavano rifornimenti sbagliati, oppure quelli giusti venivano mandati nel posto sbagliato. Persino a Scutari, Nightingale si scontrò con l'ozio e la passività del fornitore sovrintendente. I materiali erano talmente scadenti che chiese al "Times" di affidarle le donazioni che il giornale aveva raccolto per i soldati, in modo da fare a meno del fornitore e comprare direttamente il necessario al Gran Bazar di Costantinopoli.¹³ Da quel momento, divenne a tutti gli effetti il fornitore-ombra dell'ospedale e il canale principale per lo smistamento dell'enorme varietà di doni che semplici cittadini mandavano a Scutari: cibo, denaro, lenzuola, ciabatte, un mobile per l'asciugatura... persino confettura di lamponi e biscotti allo zenzero da una certa Mrs Gollop del Buckinghamshire.¹⁴

Sebbene Nightingale fosse un'infermiera di talento, le sue abilità di amministratore erano ancora più grandi. Iniziò con misure modeste, imponendo nuovi standard igienici, ma si trovò presto a dover riorganizzare praticamente ogni aspetto non clinico dell'ospedale. Florence descrisse il suo ruolo come «cuoca, governante, spazzina [...] lavandaia, pubblico concessionario, commerciante».¹⁵ L'impegno la ridusse all'osso. Lavorava venti ore al giorno e mangiava in piedi. Era annientata «dalla quantità di cose da scrivere, dalle discussioni... dal dover gestire gli egoismi e la cattiveria». Si sentiva «come Prometeo», incatenata alla «roccia dell'ignoranza e dell'incompetenza».¹⁶

Eppure stava facendo la differenza. A soli due mesi dal suo arrivo, il capellano ospedaliero notò un sorprendente «sollevio e miglioramento». C'erano cucine in ogni reparto e vasche da bagno in ogni angolo. Ogni uomo

aveva un letto, un materasso pulito e un cambio di camicia due volte a settimana.¹⁷ E la mortalità diminuiva: dopo aver raggiunto un terribile 52% degli ingressi nell'inverno del 1855, precipitò al 20% a marzo, continuando a diminuire nel corso dell'inverno seguente, fino a raggiungere la stessa percentuale tra i civili di una grande città.¹⁸

Difficilmente Florence avrebbe potuto rivendicare tutto il merito, e infatti non lo fece.¹⁹ Ma, per più di un anno, le attività cliniche a Scutari somigliavano a una nave in balia delle onde e, con le parole di un colonnello dell'esercito che vide la situazione con i suoi occhi, «Miss Nightingale [era] l'unica àncora». I suoi colleghi ricordano la sua energia, il suo esempio, il suo snellire la burocrazia a colpi di machete. Ricordano i momenti più bui dell'inverno, quando arrivavano feriti a centinaia e «gli ufficiali perdevano la testa, invocando il nome di Flo» per qualsiasi cosa.²⁰ E ricordano il caos che regnava nel corso delle sue brevi assenze, come quel giorno del 1854, quando prese qualche giorno di riposo dal suo compito non ufficiale di fornitore generale e gli uomini del corridoio C si ubriacarono attaccandosi alle bottiglie perché nessuno aveva dato loro tazze per bere vino.²¹

L'eredità di Nightingale per l'analisi dei dati

In Gran Bretagna, un giornalista del "Times" riportò un'immagine di Florence Nightingale che sarebbe diventata eterna: «Quando tutti gli ufficiali medici sono andati via per la notte e il buio è calato su quei chilometri di malati sfiniti, la vediamo con una piccola lanterna in mano, impegnata nelle sue ronde solitarie».²² Col tempo, la sua fama diventò sempre maggiore. Poesie e canzoni vennero scritte in suo onore. I diari intimi dei soldati riportavano sogni a occhi aperti in cui si lanciavano in suo aiuto di fronte al pericolo. Navi, cavalli da corsa e bambine di ogni classe sociale venivano chiamate come lei.²³

Ma per Nightingale tale fama era solo «finta popolarità, basata sull'ignoranza».²⁴ Credeva che il suo lavoro in Inghilterra, una volta finita la guerra, avrebbe davvero fatto la differenza e gli storici moderni sono ampiamente d'accordo con lei. Quel periodo ci ha lasciato tre eredità importanti, tutte scaturite dall'esperienza e dalla fama guadagnate dalla Nightingale durante la guerra di Crimea.

La dama con la lanterna

Nightingale è il simbolo vivente della riforma del ruolo dell'infermiere: questa è la sua prima eredità. Prima di lei, il simbolo dell'infermiera di epoca vittoriana era stata Mrs Sarah Gamp, la feroce caricatura di badante descritta nel *Martin Chuzzlewit* di Dickens. Rozza, inesperta e costantemente ubriaca, Mrs Gamp emanava «una fragranza caratteristica [...] come se un fatina di passaggio avesse tossito subito dopo essere uscita da una cantina». Il suo sguardo tipico, secondo Dickens, era «un mix di dolcezza e malizia [...] un po' spirituale, un po' alcolico e totalmente professionale».

Mrs Gamp era uno stereotipo, ma diventò un'icona perché mise d'accordo i contemporanei di Dickens, per i quali divenne il simbolo dello stato pietoso della professione di infermiere. Come scrisse un famoso medico di nome Edward Henry Sieveking nel 1852: «Evitiamo che i termini infermiera e bevitrice di gin diventino sinonimi; combattiamo le Mrs Gamps con tutte le nostre forze; e sostituiamole con assistenti pulite, intelligenti e forbite».²⁵

Con i successi conseguiti da Nightingale, l'immagine pubblica dell'infermiera si è trasformata in quella che è più o meno la versione moderna che tutti conosciamo. Ciò poteva verificarsi solo dopo un periodo di riforma decennale nell'educazione e nella certificazione della professione di infermiere, e Nightingale non fu la prima promotrice di tali riforme. Trasse ispirazione da molte pioniere del passato, in particolar modo dalle infermiere che gestivano Kaiserswerth, dove studiò nei primi anni cinquanta dell'Ottocento. In ogni caso, per l'opinione pubblica britannica Nightingale divenne *il* simbolo della moderna infermiera vittoriana. Si spese più di chiunque altro per rendere la professione di infermiere una scelta rispettabile per una donna della borghesia, contribuendo a creare un circolo virtuoso in cui infermiere migliori rendevano migliore la professione, che a sua volta attirava infermiere ancora più brave.

La statistica appassionata

La seconda eredità di Nightingale è l'analisi delle statistiche mediche della guerra di Crimea. Florence tornò in Inghilterra piena di legittima indignazione per lo scandalo di Scutari. Nel suo diario, scrisse: «Mi ergo sull'altare degli uomini uccisi: finché vivrò, combatterò per la loro causa».²⁶ E in effetti era una battaglia contro coloro che, nell'esercito e nelle istituzioni mediche,

ostacolavano il cambiamento, come l'ufficiale medico John Hall, per esempio, che liquidò Nightingale definendola «sottana arrogante».²⁷ Ma Florence usò tutte le armi a sua disposizione: la sua intelligenza, la sua rete di amicizie, la sua penna corrosiva... e soprattutto la matematica e la statistica, che considerava le frecce più temibili della sua faretra.

Il primo biografo di Nightingale, E.T. Cook, le diede il soprannome di «statistica appassionata», che per ovvi motivi non rimase impresso nell'immaginario collettivo come «la dama con la lanterna», ma descriveva molto meglio il modo in cui cambiò il mondo. Nightingale era particolarmente abile nello sfruttare la rappresentazione grafica dei dati per attirare l'attenzione della nazione sulle condizioni vergognose degli ospedali militari. Come disse una delle sue colleghe, la rappresentazione dei dati da parte di Nightingale poteva «far arrivare agli occhi delle persone quello che non riuscivamo a far arrivare alle menti attraverso le loro orecchie *a prova di parole*». Inventò addirittura un nuovo tipo di diagramma statistico: il diagramma polare, una sorta di diagramma a torta, che mostrava le variazioni della mortalità nel tempo usando una serie di spicchi colorati. Il diagramma a torta della guerra di Crimea, contenente l'aumento e la diminuzione della mortalità per malattia, è mostrato nella figura 6.1.




Figura 6.1 Diagramma polare di Nightingale del 1858. Nel cerchio sulla destra, i 12 spicchi esterni rappresentano le morti mensili durante la guerra di Crimea causate da «malattie osmotiche evitabili o mitigabili» dall'aprile 1854 al marzo 1855. La linea tratteggiata conduce al cerchio sulla sinistra, che mostra i dati per

l'anno successivo: da aprile 1855 a marzo 1856. In ogni cerchio, i due set di spicchi interni rappresentano le morti in battaglia (in nero) e quelle dovute ad altre cause (grigio chiaro).

Le analisi rivelarono che nei primi sette mesi della campagna di Crimea la mortalità da malattie tra i soldati inglesi raggiungeva il 60%. Era maggiore di quella registrata tra i londinesi durante la peste del 1665 e persino più alta della probabilità di decesso per un individuo che avesse contratto il colera nel 1850.²⁸ Sì, era decisamente più sicuro ammalarsi di colera in patria che sfidare la sorte in Crimea e questo *prima* di incrociare un singolo proiettile nemico. Nightingale lo chiamava «il più raffinato esperimento della storia moderna: stabilire quante persone potessero morire unicamente a causa del cibo avariato e dell'aria malsana», un esperimento che condannò a morte 16 000 uomini.²⁹

Nightingale analizzò anche le statistiche in tempo di pace e scoprì che, a causa delle precarie condizioni igieniche, il tasso di mortalità nell'esercito in patria era il doppio di quello della popolazione civile. Definì questo fatto «criminale» e in sostanza non differente dal «riunire 1100 uomini a Salisbury Plain e fucilarli».³⁰ Questo costrinse l'esercito a ristrutturare le caserme e ridisegnare gli ospedali, causando un'immediata diminuzione della mortalità collegata alle malattie.³¹ Le sue raccomandazioni presero piede anche nella società civile. Anche a causa dell'instancabile attivismo di Nightingale, gli ospedali con lunghe corsie e stanze affollate furono percepiti come incubatoi di infezione. Il suo modello preferito di struttura divenne presto la norma: un ospedale composto di padiglioni, con molta luce e molta circolazione d'aria e con reparti separati per tenere sotto controllo la diffusione di malattie. Queste «strutture Nightingale» restarono in voga a lungo nel corso del ventesimo secolo.³²

La madre della medicina basata sui dati

La terza eredità di Nightingale è forse la meno conosciuta di tutte: il suo ruolo nel creare un nuovo standard professionale nella raccolta e nell'analisi dei dati medici.

Spesso si dice che i generali combattono sempre la loro ultima guerra. Ma un ufficiale medico che avesse voluto imparare qualcosa dall'enorme varietà di casistica medica offerta dalla guerra di Crimea, non avrebbe potuto farlo. I

dati non venivano raccolti, poche storie cliniche venivano conservate e non veniva effettuata quasi nessuna autopsia. In molti casi, i malati erano caricati su un lato della nave in Crimea e venivano buttati in mare morti dall'altro lato, una volta arrivati a Scutari. Nightingale si disperava per la sorte degli uomini, ma trovava anche «sconsolante ed estremamente deludente» che un tale «tesoro scientifico» andasse perduto a causa di una cattiva gestione.³³

Al suo ritorno in Inghilterra, dopo la guerra, scoprì che queste inadempienze si verificavano anche negli ospedali civili. Il paese non aveva un sistema di raccolta dati, neanche per i dati medici più basilari, come le guarigioni, la durata dei ricoveri o la mortalità per differenti malattie. Anche se ci fosse stato un tale sistema, non ci sarebbe stato modo di fare confronti tra diversi ospedali, poiché facevano uso di sistemi di classificazione differenti per le malattie.³⁴

Nightingale considerava questa mancanza di attenzione ai dati un pericolo per la salute pubblica. Osservava come la nuova disciplina della statistica modificava altri campi, come l'astronomia e le scienze della Terra. Notava anche che gli statistici del continente – in particolar modo uno dei suoi idoli, l'illustre belga Adolphe Quetelet – usavano i nuovi strumenti per rispondere a domande delle scienze sociali riguardo alla criminalità e ai cambiamenti demografici. Nightingale vide il potenziale *incredibile* dell'applicazione delle stesse tecniche statistiche alla salute pubblica: «Ci permetterebbe di risparmiare vite e sofferenze, e di migliorare i trattamenti e la gestione dei malati».³⁵ Ma ciò richiedeva dati sensibilmente migliori dal sistema sanitario. A questo fine, elaborò uno standard per i formulari medici, ottenne l'appoggio di molti statistici di fama mondiale e spinse i grandi ospedali di Londra a iniziare a usarli. Fece anche pressioni sul governo per iniziare a raccogliere dati sulle malattie e sulla qualità degli alloggi durante i censimenti, argomentando che «la connessione tra la salute e gli alloggi della popolazione è una delle più importanti che esista».³⁶ Considerandolo globalmente, il lavoro di Nightingale ha anticipato i successivi 160 anni di medicina basata sui dati. Le sue idee hanno delineato un modello chiaro per il sistema internazionale di classificazione delle malattie oggi in uso, che è la base solida per tutta l'epidemiologia moderna e la scienza dei dati medici.³⁷

Danni evitabili nell'era dell'IA

Le tre eredità di Nightingale mostrano chiare analogie con il mondo odierno e pongono alcuni interrogativi sottili. Lei parlava di «aria malsana e danni evitabili» che uccidevano i soldati della campagna di Crimea e, anche se l'aria negli ospedali odierni è meno malsana, i danni evitabili sono ancora parecchi.

Una questione cruciale è come comporre e addestrare un moderno team di professionisti sanitari. Dopo Nightingale, nessun ospedale poté fare a meno di infermieri. Quando sarà la volta degli analisti e degli esperti di intelligenza artificiale, che a oggi contano molto poco nella salute pubblica?

Un secondo problema è come progettare un ospedale per l'epoca moderna. Nightingale aiutò a stabilire nuovi standard igienici e gli ospedali furono di conseguenza ristrutturati da cima a fondo. Quando avverrà una nuova trasformazione degli ospedali, in modo da integrare le novità introdotte dall'intelligenza artificiale? Quando l'igiene dei dati verrà presa altrettanto seriamente dell'igiene dei pazienti?

E, infine, il problema più importante di tutti: come saranno raccolti, condivisi, analizzati e utilizzati i dati sanitari? Abbiamo fatto molti progressi in questo campo negli ultimi 160 anni, anche grazie agli sforzi di Nightingale. Come vedrai, tuttavia, abbiamo migliorato solo alcuni aspetti e potremmo fare molto di più. Alla luce di quello che sta avvenendo *al di fuori* dell'ambito sanitario, questo inizia a diventare un problema etico. Viviamo in un'epoca in cui le macchine di Formula 1 sono controllate in tempo reale da algoritmi e team di ingegneri, le tue preferenze cinematografiche sono analizzate da sistemi di IA del valore di miliardi di dollari e la tua propensione a cliccare su una pubblicità di cibo per cani è analizzata da supercomputer usando milioni di variabili e miliardi di dati. Eppure, per quantificare la probabilità di un'insufficienza renale, facciamo per lo più affidamento su numeri che Florence Nightingale avrebbe potuto annotare con carta e penna. E in altri ambiti non siamo progrediti affatto: un articolo del 2017 nel "Journal of Royal Statistical Society" si riferisce al protocollo di Nightingale del 1860 per la raccolta dati in ospedale come «concettualmente più completa» di molti sistemi odierni.³⁸ E questo dovrebbe farci domandare: quando entrerà finalmente la scienza medica nel ventunesimo secolo?

Perché abbiamo bisogno di IA negli ospedali

Vogliamo essere chiari sul fatto che *non* è colpa dei singoli medici e infermieri. È colpa dell'intero sistema sanitario, che è stato per troppo tempo

la Mrs Gamp dell'analisi dei dati: arroccato sui precetti della statistica, annesso nella burocrazia e ignaro dei progressi dell'IA.

Per evidenziare il problema, ti racconteremo la storia di un uomo della East Coast degli Stati Uniti – lo chiameremo Joe –, morto a sessantadue anni per una malattia renale cronica. La storia di Joe spiega bene come l'approccio contemporaneo alla scienza dei dati medici sia nocivo per il paziente e perché una combinazione di intelligenza artificiale e di maggiore attenzione ai dati possa evitare molte sofferenze.

A quarantacinque anni, Joe soffriva già di diabete di tipo 2 e di scompenso cardiaco. Forse il suo lavoro era troppo stressante o forse era colpa della sua dieta e dello scarso esercizio fisico. Qualunque fosse la loro combinazione, alla fine i vari fattori ebbero la meglio. A poche settimane dal suo quarantasettesimo compleanno, Joe sentì un improvviso intorpidimento al braccio destro. Barcollò e cadde a terra. Fu portato al pronto soccorso, dove gli diagnosticarono un ictus ischemico: un coagulo aveva bloccato l'afflusso di sangue al cervello.

Fortunatamente Joe sopravvisse. Sebbene la pressione alta e il diabete fossero fattori di rischio per future malattie renali, per il momento i suoi reni lavoravano bene. La misura standard del funzionamento renale è il GFR o Glomerular Filtration Rate (velocità di filtrazione glomerulare). Il GFR di Joe era 99, ben lontano dalla soglia di pericolo: un GFR di 60 o inferiore indica una leggera o media perdita di funzionalità renale, mentre un GFR di 30 o inferiore indica una grave insufficienza.³⁹

Nell'anno seguente, Joe si recò nove volte in ospedale per diversi motivi, nessuno dei quali direttamente collegato ai suoi reni. In due di queste occasioni venne misurata la sua funzionalità renale: il suo GFR era 96 nel primo caso e 95 il mese successivo. La diminuzione era appena più accentuata rispetto all'1-2% annuale stimato per una persona sana. Ma ogni singola misura era ben al di sopra della soglia di 60 che normalmente preoccupa i medici.

A circa un anno dall'ictus, Joe iniziò a presentarsi regolarmente presso un ambulatorio: otto visite in quattordici mesi. Dopo ogni visita, il medico prescriveva una serie di analisi di routine e lo staff clinico inseriva diligentemente i dati sulla funzionalità renale di Joe in un database elettronico, lo stesso usato dai medici in ospedale. I suoi valori del GFR oscillavano tra 60 e 75: sempre al di sopra della soglia di 60, ma abbastanza al di sotto del valore 99 dell'anno precedente, e senz'altro in discesa.

All'età di quarantanove anni, Joe entrò di nuovo in ospedale, e il GFR precipitò a 54. Nei mesi successivi si recò per dieci volte al pronto soccorso e una dozzina di volte in ambulatorio. A questo punto era molto malato. Un mese prima del suo cinquantesimo compleanno, il GFR era pari a 40, all'interno della zona di rischio. Eppure non ricevette alcun trattamento che gli impedisse il declino verso l'insufficienza renale. Possiamo solo fare ipotesi sul perché, ma una possibile ragione è che a volte i risultati del test arrivano dopo un po' di tempo e a quel punto il paziente potrebbe essere già tornato a casa, non più sotto la supervisione del medico che aveva prescritto il test.

Nei tre anni successivi, Joe ebbe altre venti interazioni con i medici. In molte occasioni, la funzionalità renale precipitò a valori spaventosi: sotto i 30 a cinquantun anni e sotto i 20 a cinquantadue, quando Joe venne finalmente mandato da un nefrologo, più di un anno dopo che il suo GFR era sceso sotto il livello che tipicamente indica la necessità di ricorrere a uno specialista.

Ma l'insufficienza renale a questo punto era inevitabile. Tre mesi dopo il suo appuntamento con il nefrologo, i reni di Joe cedettero. Fu trasportato d'urgenza al pronto soccorso, per la sua venticinquesima visita dall'ictus. Il suo GFR era pari a 12; la sua funzionalità renale era scesa del 12% l'anno negli ultimi cinque anni, a partire dal valore 99 misurato dopo l'ictus. I medici del pronto soccorso lo misero in dialisi d'urgenza, una delle procedure più traumatiche e costose che esistano.

Nel corso del decennio successivo, Joe diventò ciò che le compagnie assicurative chiamano un "superutilizzatore", termine manageriale per un individuo gravemente malato: uno di quel 5% di pazienti che incidono per il 50% di tutta la spesa sanitaria negli Stati Uniti. Nel caso di Joe, voleva dire diabete di tipo 2, malattia renale di grado 5, angina, malattie vascolari e malattie infiammatorie del tessuto connettivo, oltre a una serie di attacchi cardiaci. I reni di Joe vennero testati 124 volte in questo lasso di tempo, si recò ventisei volte in ospedale e nove volte dal nefrologo. Il suo GFR oscillò un po', ma non tornò mai sopra 20.

Morì a una settimana dal suo sessantatreesimo compleanno, circa dieci anni dopo aver iniziato la dialisi.

Di cosa morì Joe? In un certo senso, la risposta è chiara: i suoi reni hanno ceduto. Ma affinché ciò si verificasse, ha ceduto anche qualcos'altro, in maniera così eclatante da fare fatica a crederci. Poiché se prendiamo tutti i

valori del GFR di Joe dopo l'ictus e li mettiamo su un grafico in funzione del tempo, la tendenza è decisamente palese (Vedi figura 6.2).⁴⁰

In quei tre anni di rapido declino tra i quarantasette e i cinquanta, nessuno nel personale medico ha esaminato il grafico in funzione del tempo del GFR di Joe. Il problema è stato, semplicemente, che nessuno ha collegato i puntini. Farlo avrebbe fornito una semplice e ovvia previsione: la funzionalità renale di quest'uomo sta scendendo così rapidamente che, continuando a questo ritmo, l'esito sarà doloroso e costoso.

Joe è certamente morto perché gli sono venuti a mancare i reni, ma in definitiva è morto per la mancanza di un grafico a dispersione.




Figura 6.2

Pensieri di soglia

Com'è potuto accadere tutto questo? Lo abbiamo chiesto alla dottoressa Katherine Heller, docente di statistica e machine learning alla Duke University, che ha analizzato i dati e ci ha segnalato per prima il caso di Joe. «Col senno di poi», dice Heller, «quella rapida diminuzione tra i quarantasette e i cinquant'anni rappresenta senz'altro un segnale non colto. Tutto ciò che bisognava fare era tracciare una linea retta attraverso i dati, in modo da vedere chiaramente dove si stava andando.»

E dunque perché nessun umano e nessuna macchina hanno pensato di tracciare quella retta? *Questa* è la domanda cruciale della sanità moderna. Per capire la risposta, dobbiamo riconsiderare due domande che Florence Nightingale si pose 160 anni fa, quando cercava di capire in che modo potesse usare all'interno degli ospedali i nuovi strumenti matematici disponibili nel 1850:

1. In che modo il sistema sanitario utilizza i dati oggi?
2. Alla luce delle nuove tecnologie di analisi dei dati, che cosa *si potrebbe* invece fare?

Oggi, l'utilizzo più diffuso dei dati nei sistemi sanitari è la compilazione di checklist. Tali liste codificano gli «standard di cura» raccomandati da organismi nazionali, come l'American Medical Association o il General Medical Council britannico. Questi standard, a loro volta, sono stabiliti in base ai dati pubblicati in articoli scientifici: quali sono i sintomi da tenere d'occhio, quali trattamenti funzionano meglio, quali protocolli diagnostici sono in grado di aiutare maggiormente le persone. Per esempio, ricorderai che l'American Cancer Society fece scalpore nel 2015, quando aggiornò le sue linee guida sulle mammografie. In base alle nuove raccomandazioni, le donne con rischio medio di tumore al seno dovrebbero effettuare uno screening annuale a partire dai quarantacinque anni, anziché dai quaranta. Il cambiamento fu suggerito solo dopo che un team di diciannove esperti concluse una gigantesca analisi di tutti i dati disponibili, e stabilì che le nuove linee guida erano in grado di prevenire undici falsi positivi ogni 500 donne sottoposte a screening, senza impatto apprezzabile sul numero di morti per tumore.⁴¹

Le checklist mediche sono molto utili, e il modo in cui vengono stilate e aggiornate rappresenta un trionfo dei dati sull'aneddotica, qualcosa di cui Florence Nightingale, se fosse ancora viva, andrebbe orgogliosa. Le checklist salvano vite aiutando i medici a considerare indizi sottili nel prendere decisioni complesse. Traendo ispirazione dalla sua esperienza di chirurgo, il medico scrittore Atul Gawande ha persino scritto *The Checklist Manifesto*, che illustra come le checklist possano aiutare *ovunque* sia necessario prendere decisioni complicate, non solo in medicina. E ha ragione.

Ma le checklist possono fallire, specialmente quando si basano su ciò che Katherine Heller chiama «il pensiero di frontiera». Per capirlo, torniamo alla

tendenza che appare così ovvia dal grafico di dispersione della funzionalità renale di Joe mostrato in precedenza. Heller crede che tutti i medici che si sono imbattuti in quella serie di puntini abbiano ragionato in termini di soglia binaria: un tipico pensiero da checklist. Il GFR è maggiore di 30? Ok, passa oltre. I livelli di potassio nel sangue sono al di sotto di 5,5 millimoli per litro? Ok, passa oltre. I livelli di albumina nell'urina sono nella norma? Gli altri indicatori del funzionamento renale sono nella norma? Ho seguito il protocollo? Ok, ok, ok.

Tutti questi ok dicono qualcosa della funzionalità renale di Joe nel corso di una singola visita e sono molto importanti per una buona diagnosi. Ma non dicono nulla sul lungo periodo. E quindi, anche se Joe stava precipitando da anni verso quella terribile soglia di GFR pari a 30, non l'aveva ancora oltrepassata e a nessuno venne in mente di lanciare l'allarme prima che fosse troppo tardi. In termini di intelligenza artificiale, le checklist sono solo regole di predizione: procedure che prendono i dati dei pazienti in input e forniscono una diagnosi clinica in output. In quanto regole di predizione, tuttavia, sono concepite per aiutare i medici a capire e ad agire su ciò che sta avvenendo *ora*, non su ciò che potrebbe avvenire in futuro. In realtà, è una caratteristica insita nelle checklist: fanno in modo che la mente del medico si concentri sui dettagli del presente. Ma in un mondo in cui i problemi più grandi e più costosi per il sistema sanitario vengono da malattie croniche che vanno avanti per anni, questa caratteristica comincia a somigliare a un difetto.

Potresti chiederti: perché non correggiamo il difetto semplicemente stilando una checklist più lunga, aggiungendo una voce che incoraggi i medici a guardare i dati sul lungo periodo? Avevamo la stessa idea. Dunque abbiamo chiesto a Heller se sarebbe mai stato possibile, per i sanitari che seguivano Joe, prendere i valori del GFR e metterli su uno schermo in funzione del tempo, alla ricerca di una regolarità. «Forse potresti interrogare il database in questo modo, se sapessi come farlo» rispose dopo averci pensato su per qualche istante. «Ma senz'altro non sarebbe un modo ovvio e naturale di usare il sistema da parte di un medico.» Per individuare una regolarità, continuava, «bisognava ispezionare manualmente i dati, una lettura per volta». Per ironia della sorte, questo sarebbe stato probabilmente più facile al tempo dei grafici cartacei.

In più, fece notare Heller, non si tratta di un solo set di rilevazioni da controllare, ma di centinaia o persino migliaia: analisi del sangue, test delle urine, elettrocardiogramma, frequenza cardiaca, pressione arteriosa, sintomi

clinici, fattori sociali e, molto presto, informazioni sull'espressione genica e sul profilo epigenetico del paziente. Sono *moltissimi* dati. È difficile per un essere umano comprenderli tutti, anche come visione d'insieme: figuriamoci visualizzare la loro evoluzione nel tempo.

Infine c'è il problema di come una tale ipotetica «ricerca di regolarità» all'interno della checklist possa essere inserita nel flusso di lavoro di un medico. Quando entri nel pronto soccorso, la principale preoccupazione del medico è: quanto è grave il tuo stato in questo momento? Dobbiamo darti una terapia e mandarti a casa, o sei sufficientemente malato da dover essere ricoverato? I medici sono sottoposti a stress enormi e rischi altissimi nel prendere tali decisioni e anche al di fuori del pronto soccorso, in una normale clinica, devono prendere le decisioni *velocemente*, perché ci sono dozzine di altre persone in sala d'attesa che hanno bisogno d'aiuto. Quanto è ragionevole attendersi che quei medici smettano di fare ciò che stanno facendo, avviino un software statistico ed esplorino un'enorme collezione di dati sanitari per trovare quel paio di regolarità che potrebbero essere rilevanti nel prevenire qualcosa nei mesi o negli anni a venire?

Il dottor Mark Sendak, dell'Institute for Health Innovation della Duke University, spiega che, sebbene i medici facciano questo genere di cose in serie TV come *Dr. House*, in ospedale di norma non lo fanno. «I medici dicono sempre che vogliono i dati» afferma Sendak. Ma continua:

Il problema è che non c'è un flusso di lavoro che permetta loro di accedere ai dati o di utilizzarli. Per il modo in cui i dati sono strutturati, questo richiederebbe tempo e abilità. Devi scrivere una richiesta, scaricare i dati su un foglio di calcolo e poi lavorare con quei dati. Ma i medici sono già sufficientemente sotto stress. La durata media delle visite è quindici minuti. Quando, esattamente, dovrebbero mettersi a giocare con i dati e capire cosa devono fare per i loro pazienti?

Questo ci porta a un problema ancora più rilevante: l'intero sistema di analisi dei dati sanitari è strutturato *solamente* per rispondere a domande al livello della popolazione. Per esempio, quante vite potremmo salvare se usassimo la soglia A invece della soglia B per riconoscere malattie renali? Devono esistere centinaia di studi sull'argomento. Ma l'analisi dei dati sanitari è quasi impotente riguardo alle domande statistiche di base al livello del singolo individuo. Come stanno cambiando i livelli di GFR di Joe nel corso del tempo? Dove si dirigeranno da qui in avanti? Che cosa ci dice questo sulle

condizioni di salute di Joe nel corso del prossimo mese o del prossimo anno? Queste domande sarebbero state semplici per un essere umano o per un algoritmo che avesse fatto uso della storia clinica di Joe, eppure a tutti quei dati non fu mai data l'occasione di parlare. Non c'era una routine da mettere in pratica per setacciare i dati di Joe alla ricerca di una malattia cronica: nessun team di analisti, nessun algoritmo, nessun medico con formazione interdisciplinare in statistica.

Con qualche eccezione qui e là, lo stesso può dirsi per la gran parte degli ospedali e degli ambulatori. Parlando di questo argomento con amici e colleghi, abbiamo notato che molti hanno l'impressione che ci sia qualche «medico robot» alle spalle di un moderno ospedale, qualche collezione di algoritmi intelligenti che analizzano i dati dei pazienti e aiutano i medici a dare consigli e terapie personalizzati. Forse tale impressione deriva dal fatto che vedono i loro medici inserire così tante informazioni o dal fatto che vedono l'IA trasformare molte altre attività. Qualunque sia il motivo, restano di solito stupefatti quando diciamo loro la verità: quando si arriva al livello del singolo paziente, non solo non c'è alcun medico robot, ma non c'è letteralmente *nessuno al volante*.

Quando abbiamo parlato con Heller, la sua frustrazione riguardo a questo punto era evidente. «Non è sufficiente raccogliere dati», osservava ironicamente. «Devi anche farci qualcosa.» In questo caso cita involontariamente Nightingale, che scrisse a proposito del St Thomas' Hospital di Londra: «Sembra conservare le statistiche più per il gusto di visitare pazienti irrequieti, che è senz'altro un obiettivo, ma non di tipo scientifico».⁴²

La storia di Joe, alla fine, è molto più della storia di un uomo con una malattia renale. È la storia di un grande solco tra ciò che i dati *potrebbero* fare per noi e ciò che il nostro sistema sanitario *permette* loro di fare.

IA alla riscossa?

Se ti sembra che i professionisti sanitari stiano annegando nei dati e abbiano bisogno di un salvagente – e che una combinazione di intelligenza umana e artificiale possa migliorare il sistema sanitario in modo radicale – sappi che non sei il solo a pensarla così. Aziende e ricercatori stanno lavorando duramente a una nuova generazione di tecnologie basate sull'IA, che restano dietro le

quinte, in attesa di aiutare medici e infermieri a rendere il loro lavoro più efficace.

Il team della dottoressa Katherine Heller alla Duke University, per esempio, ha collaborato con personale medico per sviluppare un sistema di IA in grado di rilevare i sintomi di una possibile malattia renale cronica.⁴³ Il fulcro del sistema è una regola di predizione, proprio come quelle incontrate nel capitolo 2: esamina lo storico dei valori GFR di un paziente, lo combina con altri parametri vitali e analisi di laboratorio, e fornisce una predizione per la funzionalità renale futura del paziente. Tale predizione è mostrata su un'app che i medici possono consultare durante il trattamento dei pazienti. Con questo tipo di IA, i medici *possono davvero* portare a termine la parte di lungo periodo della loro checklist, senza annaspire tra i dati.

Simili sistemi di allarme sono stati messi a punto da altri gruppi di ricerca per altre malattie: arresto cardiaco, depressione, sofferenza fetale durante il parto e infezioni ospedaliere, solo per citarne alcune. Altri avanzamenti notevoli dell'IA potrebbero presto rivoluzionare qualsiasi area della medicina, dalla radiologia alla cura dei tumori alla dermatologia. Daremo un'occhiata alla frontiera della ricerca in questo campo, prima di tornare al tema dei cambiamenti culturali necessari per adottare su larga scala l'IA nella sanità.

Dispositivi medici intelligenti

L'elettrobisturi, che usa onde ad alta frequenza per scaldare i tessuti fino a vaporizzarli, è un grande passo avanti rispetto ai bisturi di un tempo. Permette tagli molto più precisi e poiché cauterizza i tessuti circostanti quasi immediatamente, riduce al minimo anche il sanguinamento. Ma neanche il bisturi più sofisticato è in grado di suggerire al medico *dove* tagliare. Quando i chirurghi rimuovono un tumore, per esempio, è quasi impossibile che riescano a vedere a occhio nudo dove finisce esattamente il tessuto tumorale e dove inizia quello sano.

Un nuovo, e straordinario, bisturi basato sull'IA, sviluppato dal dottor Zoltán Takáts e dal suo team all'Imperial College di Londra, potrebbe presto risolvere il problema. Quando il tessuto viene vaporizzato dal bisturi elettrico, genera fumo che viene di solito aspirato da un collettore. Takáts ha avuto un'idea brillante: il fumo dovrebbe contenere metaboliti del tessuto vaporizzato, che possono essere sfruttati per capire se il tessuto è di tipo tumorale. Quindi ha costruito un bisturi elettrico in cui il fumo è convogliato

verso uno spettrometro di massa, che ne effettua il profilo chimico. Il profilo diventa l'input di una regola di predizione che classifica il fumo come proveniente da cellule tumorali o da cellule sane. E per di più, l'intero processo – vaporizzazione, estrazione, profilazione, classificazione – avviene in meno di tre secondi. Di conseguenza, questo nuovo tipo di bisturi *può* dire al chirurgo dove smettere di incidere. In una sperimentazione con pazienti reali, il software IA del bisturi ha correttamente identificato il tessuto novantuno volte su novantuno, come verificato dall'esame istologico postoperatorio.⁴⁴

Alcuni dispositivi medici intelligenti possono andare anche oltre la semplice misura e trattare direttamente il paziente in modo automatico. Prendi, per esempio, il pancreas artificiale a circuito chiuso, un sistema di IA che riproduce le funzionalità ormonali di un pancreas reale, fornendo automaticamente ai diabetici la corretta quantità di insulina in risposta alle variazioni del glucosio nel sangue. Un pancreas artificiale comporta tre passaggi: misura, dosaggio ed erogazione. Per il primo passaggio si usa un misuratore continuo del livello di glucosio, MCG, che fornisce ventiquattro ore al giorno, sette giorni su sette, la misura del livello di glucosio nel sangue. Il passaggio successivo è l'algoritmo che calcola il dosaggio: una regola di predizione che legge i dati del livello di glucosio in tempo reale dall'MCG e fornisce il dosaggio ottimale di insulina. L'ultimo passaggio è una pompa che somministra l'insulina al bisogno.

Le aziende di dispositivi medici come Medtronic, Insulet e Tandem stanno facendo rapidi progressi in questo campo e, come segno di buona volontà, le autorità di regolamentazione per ora tengono il passo. Nel settembre del 2016, per esempio, dopo un periodo di prova eccezionalmente rapido di tre mesi, la Food and Drug Administration degli Stati Uniti ha approvato l'ultimo modello della Medtronic: il primo pancreas artificiale in grado di porre rimedio a livelli di glucosio nel sangue sia alti sia bassi.⁴⁵

IA nella diagnostica per immagini

La diagnostica per immagini fornisce un esempio ancora più diretto del fatto che l'IA è in grado di fare la differenza. Molte tipologie comuni di analisi, dalle radiografie del torace all'esame di cellule tumorali al microscopio, hanno alla base un problema di riconoscimento di schemi: gli input sono le caratteristiche estratte dall'immagine e l'output è la diagnosi. Come abbiamo

visto nel capitolo 2, i computer sono bravissimi a imparare come predire output a partire da input, specialmente nel caso di immagini e, con più dati a disposizione e nuovi algoritmi di riconoscimento, migliorano in continuazione.

Per alcune diagnosi basate su immagini, non sarà nemmeno più necessario recarsi dal dottore. Prendi, per esempio, la diagnosi di una lesione cutanea. Il rischio è alto: il melanoma causa più di 10 000 morti l'anno solo negli Stati Uniti. La percentuale di sopravvivenza a cinque anni è più del 99% in caso di diagnosi precoce, ma si riduce al 14% se la diagnosi è tardiva. Per diversi motivi – tempo, denaro, avversione per i medici in generale – le persone spesso esitano ad andare dal dermatologo, e quando ci vanno è ormai troppo tardi.

Ma una ricerca del 2017 pubblicata su “Nature” da un team interdisciplinare di scienziati guidato da Sebastian Thrun della Stanford University, ha individuato un sistema di IA che potrebbe presto fornire un fondamentale supporto diagnostico per le lesioni cutanee, gratis, a chiunque abbia uno smartphone. Il team di Stanford era esperto di algoritmi per il riconoscimento di immagini, in quanto aveva precedentemente lavorato sulle macchine a guida autonoma, e ha avuto un'idea semplice. Invece di allenare gli algoritmi a distinguere segnali di stop da cervi che attraversano la strada, come fanno le macchine a guida autonoma, perché non provare a distinguere un tipo di lesione cancerosa da un'altra, basandosi su una semplice fotografia?

Non si tratta del primo caso di analisi dermatologica con l'aiuto di un computer, ma il team di Stanford ha fatto tre scelte cruciali che distinguono il suo approccio da quello di moltissimi altri, che non hanno avuto lo stesso successo. La prima scelta è la scala di grandezza. I tentativi precedenti usavano piccoli insiemi di dati, con meno di un migliaio di immagini contenenti lesioni cutanee. I ricercatori di Stanford hanno costruito diciannove database contenenti 129 450 immagini, ognuna classificata secondo una tassonomia di 2032 differenti tipi di lesioni. Più dati significa molta più esperienza, e dunque un miglior riconoscimento, analogo a quello di un dermatologo con molti anni di esperienza che ha visto quasi tutte le possibili lesioni cutanee.

La seconda scelta è l'approccio computazionale, che fa uso di una deep neural network che abbiamo incontrato nel capitolo 2. Questa tipologia di reti è in grado di estrarre caratteristiche visive anche minime e può combinarle in

concetti visivi di alto livello – come cerchi, contorni, strisce, trama o sfumature di aspetto – che possono essere utilizzati per distinguere 2000 diversi tipi di lesioni cutanee. E riesce persino a farlo senza che un programmatore dica in precedenza cosa analizzare.

L'ultima scelta del team di Stanford è l'uso di immagini prese da fotocamere comuni, piuttosto che le immagini mediche altamente specifiche che possono essere ottenute per mezzo di biopsie o grazie a dispositivi che solo un dermatologo può avere. Queste immagini presentano grandi disparità in termini di luminosità, equilibrio dei colori, zoom e angolazione: minime variazioni che possono ingannare un algoritmo meno accurato, facendogli vedere differenze che in realtà non esistono. Ma ciò che queste immagini perdono in qualità viene guadagnato in quantità: sarebbe estremamente difficile raccogliere più di 129 000 immagini ad alta risoluzione da un ambulatorio di dermatologia.

Il risultato di tutto questo lavoro è un sistema di IA che, da una comune foto, riesce a dedurre due informazioni fondamentali su una lesione cutanea. Può distinguere tra i due tipi più comuni di tumore della cute e può anche distinguere un neo benigno dalla più letale variante tumorale: il melanoma maligno. Riesce a farlo con accuratezza paragonabile a quella di un comitato di ventuno specialisti dermatologi. In alcune misurazioni, l'algoritmo di Stanford si comporta addirittura meglio.^{*a}

Tecniche simili di analisi verranno presto utilizzate in altre branche della medicina, quando nuove specialità come la radiologia computazionale e la patologia computazionale raggiungeranno la maturità. Un laboratorio di ricerca presso l'ETH di Zurigo, per esempio, ha sviluppato un algoritmo di IA per classificare la gravità di un'inflammazione dell'intestino a partire da una risonanza magnetica addominale.⁴⁶ Un altro laboratorio presso il Memorial Sloan Kettering Center ha inventato un sistema di classificazione del carcinoma delle cellule renali a partire da vetrini al microscopio.⁴⁷ E il Moorfields Eye Hospital di Londra ha recentemente collaborato con Google DeepMind per analizzare più di un milione di immagini da esami oculari. Il risultato è stata una rete neurale in grado di rilevare automaticamente malattie oculari, come la retinopatia diabetica e la degenerazione maculare.⁴⁸

Le aziende produttrici di hardware hanno risposto a questa esplosione della domanda di immagini mediche supportate dall'IA. Il produttore di microprocessori Nvidia, per esempio, è noto per le schede grafiche di alto

livello (GPU) utilizzate per i videogiochi e dai registi. Ma i suoi prodotti sono molto ambiti anche dai ricercatori in intelligenza artificiale che lavorano sulle immagini e sui video. Di conseguenza, Nvidia ha recentemente iniziato a produrre supercomputer basati sulle GPU, forniti di software esplicitamente concepito per l'analisi di immagini mediche. Il Massachusetts General Hospital è stato uno dei primi clienti, e Nvidia ora intende formare 100 000 nuovi sviluppatori di software in grado di usare il sistema per la diagnostica basata sull'IA.⁴⁹

Medicina a distanza

L'espressione "medicina a distanza" suscita immagini di persone che vivono in luoghi remoti con accesso limitato alle cure sanitarie, come una navicella spaziale o una piattaforma petrolifera nel Mare del Nord.⁵⁰ Per molte persone, tuttavia, le cure restano distanti non solo per motivi geografici. Pensa alle centinaia di milioni di persone che vivono nei paesi in via di sviluppo o alle decine di milioni di americani in difficoltà per via della crisi delle compagnie assicurative pubbliche e private. Oppure pensa a una normale persona di mezza età, con un lavoro e impegni familiari, a cui semplicemente non piace andare dal medico.

La medicina a distanza basata sull'IA promette un significativo miglioramento in termini di cure sanitarie per tutte queste persone. Immagina una versione dell'algoritmo di Stanford per la rilevazione dei tumori cutanei concepita per un vasto spettro di problemi diagnostici. Pensa a un semplice stetoscopio collegato al tuo smartphone, in modo che una rete neurale possa controllare il tuo battito cardiaco. O pensa di guardare semplicemente dentro la fotocamera così che un algoritmo possa fare una scansione dei tuoi occhi per cercare sintomi di una malattia della vista. Ora pensa di mettere insieme tutti questi algoritmi e di costruire una specie di dottor Alexa: un assistente digitale allenato in modo da avere una vasta conoscenza medica, programmato per farti domande sui sintomi e per rispondere in modo appropriato. (Il team Watson di IBM ha già sviluppato qualcosa di simile per la formazione degli studenti di medicina.)⁵¹

Una nuova generazione di sensori indossabili potrebbe ulteriormente incrementare l'efficacia della medicina a distanza basata sull'IA. Se pensi che il tuo Fitbit sia all'avanguardia, aspetta di vedere il primo tatuaggio biometrico su un tuo collega di lavoro: un piccolo cerotto, con lo stesso

spessore e la stessa elasticità della pelle umana, che invia informazioni mediche allo smartphone. Questa «elettronica epidermica» è analoga a un sistema di controllo per le monoposto della Formula 1. È possibile misurare la pressione arteriosa, la tensione muscolare, il livello di idratazione, la frequenza respiratoria, e persino l'attività elettrica del tuo cuore o del tuo cervello e, in caso di anomalie, l'allarme scatta immediatamente. Un tale sistema potrebbe essere utilizzato dai medici per controllare le condizioni di un paziente appena dimesso dall'ospedale o da persone comuni che vogliono tenere sotto controllo la propria salute giorno dopo giorno.

Queste tecnologie non rimpiazzeranno le sofisticate diagnosi di laboratorio e certamente non sostituiranno le cure di uno specialista in carne e ossa. Ma, per un certo numero di patologie, potrebbero essere in grado di suggerire semplici rimedi e consigliare di recarsi da un medico se e quando dovesse rendersi necessario, il tutto a un costo molto basso. Questo screening di primo livello, la diagnosi basata sull'IA, potrebbe estendere enormemente la platea di beneficiari di assistenza sanitaria e potrebbe aiutare i medici a trattare delle patologie prima che degenerino in qualcosa di potenzialmente letale e costoso, una sintesi perfetta di intelligenza umana e artificiale. Le implicazioni per la medicina nei paesi in via di sviluppo potrebbero essere enormi, grazie a una tecnologia più economica e più a portata di mano.

Che cosa succederà?

Speriamo tu sia d'accordo sul fatto che tutto questo è davvero eccitante. Tuttavia, a parte il fatto che alcune di queste tecnologie sono ancora in stadio preliminare, ci sono molte barriere culturali da affrontare prima di vederle all'opera.

Incentivi

Per capire di quali barriere si tratta, torniamo all'esempio del sistema di allarme precoce per le malattie renali basato sull'IA. Gli ospedali lo adotterebbero? Secondo il dottor Mark Sendak, la domanda che ogni ospedale si farebbe è: «Cosa comporta per il mio bilancio riuscire a predire meglio le malattie renali?». Non bisogna essere molto cinici per osservare, come fa

Sendak, che «i grandi sistemi di assistenza sanitaria fanno soldi sulle patologie croniche».

Il problema degli incentivi non è esclusivo degli Stati Uniti. Tutti i paesi, anche quelli in cui i governi finanziano il sistema sanitario, devono assicurarsi che ogni attore del sistema sia motivato e fornito di una visione a lungo termine. Sendak sottolinea questo punto: «Il miglioramento della scienza dei dati in campo sanitario non può prescindere dal creare incentivi: tutti devono essere interessati a quello che succede ai pazienti, una volta dimessi dall'ospedale». In questo modo, i medici faranno pressioni sui loro dirigenti per ottenere gli strumenti necessari per prendere decisioni nel solo interesse del paziente. Oggi questo non avviene: se sei spinto a preoccuparti solo dei pazienti di fronte a te, dice Sendak, «non ti preoccuperai di come i dati vengono registrati, e non ti preoccuperai di analizzare dati passati per rilevare schemi ricorrenti o tendenze in atto».

Il sistema legislativo fornisce un altro insieme di incentivi, o per meglio dire disincentivi. Immagina di essere nei panni della dottoressa Katherine Heller e pensa quanto sarebbe saggio commercializzare, o persino regalare, un'app basata sull'IA in grado di prevedere l'evoluzione di una malattia renale. Quest'app potrebbe aiutare molte persone, ma potrebbe anche creare problemi legali per gli sviluppatori. Non è chiaro se gli sviluppatori, gli analisti dei dati o i medici che usano l'app – o tutti e tre – rischierebbero una causa multimilionaria al primo, inevitabile, caso di malattia non diagnosticata, a prescindere da quante vite siano state salvate e dalle avvertenze sul corretto uso medico. Questo perché avvocati e politici non sono ancora riusciti a rispondere a una domanda fondamentale: chi è, in definitiva, responsabile del parere medico fornito da un algoritmo? Come possiamo rispondere a questa domanda in modo da favorire l'innovazione e proteggere i pazienti allo stesso tempo?

Condivisione dei dati

Questo ci porta a un'altra grande domanda: gli scienziati potranno avere accesso ai dati di cui hanno bisogno per migliorare i sistemi di IA esistenti e costruirne di nuovi? Se lavori per un singolo ospedale, puoi avere accesso ai dati di migliaia di pazienti. Ma non sarebbe meglio avere a disposizione i dati di milioni di pazienti da molti ospedali diversi? Dopotutto, il motivo per cui Google e Facebook hanno IA così sviluppate è lo strabiliante numero di dati a

loro disposizione. Ci sono sicuramente milioni di storie cliniche di malattie renali sparse nei database medici mondiali. In linea di principio, potrebbero essere condivise e team di analisti potrebbero analizzarli usando sofisticati strumenti basati sull'IA, in modo da preservare la privacy dei pazienti. Fare questo in tutti i campi della medicina creerebbe centinaia di migliaia di posti di lavoro e avrebbe un immenso valore sociale ed economico.

Ma ci sono poche speranze che ciò accada nel breve termine. Per prima cosa, le aziende sanitarie americane non hanno un sistema standard di raccolta dati e questo rende a tutti gli effetti impossibile metterli insieme e raggiungere la dimensione necessaria affinché le tecnologie di IA funzionino al meglio. Anche in paesi in cui il sistema sanitario è nazionale, come il Regno Unito, la non comunicabilità tra database – per esempio, tra quelli utilizzati negli ospedali e quelli degli ambulatori – resta un problema cruciale.

Poi, anche se ci fosse uno standard comune per i dati, gran parte degli ospedali è riluttante a collaborare con gli analisti, anche in presenza di condizioni che garantirebbero la privacy dei pazienti. In effetti, troviamo il loro atteggiamento quasi paranoico e altri ricercatori ci hanno confermato questo giudizio. Gli ospedali americani tendono a considerare i loro dati – i *tuo*i dati – come un segreto aziendale da tenere stretto. Nessuno ti dirà davvero perché, ma sospettiamo che sia per un motivo abbastanza vile: gli ospedali non vogliono che i loro bizantini meccanismi di rimborso vengano scoperti dalla concorrenza e dunque la loro soluzione è semplicemente chiudere a chiave gli hard disk. Qualunque sia la ragione, tutti questi dati sanitari sono usati per generare fatture molto dettagliate, ma quasi mai per evitare alle persone di ricorrere a cure mediche.

Riteniamo tutto ciò incredibile, e non siamo i soli. Immagina se gli ospedali gestissero la donazione degli organi nello stesso modo. Cosa succederebbe se potessero appropriarsi dei tuoi reni dopo la morte, proprio come fanno con i dati provenienti dalle tue analisi? Non dovrebbe esistere un foglio da firmare per esautorarli e donare i tuoi dati per salvare la vita di altre persone? Come sostiene Sendak, «l'imperativo morale è che queste sono persone che pagano perché ci prendiamo cura di loro. Raccogliamo i loro dati, veniamo pagati e non li utilizziamo in alcun modo. Se siamo gli unici a possedere queste informazioni, e per di più ci paghi affinché ne abbiamo cura, perché non li usiamo?».

E infine arriviamo al problema riguardante i dati stessi, tipicamente pieni di errori e omissioni – in altre parole, esattamente ciò che ti aspetti da un gruppo

di medici forzati a inserire dati manualmente, il più velocemente possibile tra un appuntamento e l'altro, dopo avere detto loro chiaramente che gran parte di quei dati non servirà mai a fare qualcosa di utile. Di conseguenza, quando qualche sparuto team di ricercatori fa richiesta e ottiene il permesso di utilizzare un piccolo insieme di dati per costruire un dispositivo basato sull'IA, deve prima ripulire e trattare in qualche modo i dati. Ciò richiede abilità, pazienza e collaborazione con i medici e, fino a questo momento, tali collaborazioni sono di tipo estemporaneo. Immagina un team di ricercatori che passa sei mesi a ripulire un set di decine di milioni di dati, tutti riguardanti un singolo problema – per esempio, come predire l'evoluzione di una malattia renale – e poi pubblica due lavori accademici. Non c'è una modalità chiara affinché altri gruppi possano trarre beneficio da quei dati; né esiste un sistema per facilitare simili interazioni su larga scala. Immagina se dovessi scrivere il tuo personale software di posizionamento GPS ogni volta che vuoi fare una corsa con Uber o Lyft. Probabilmente prenderesti un taxi.

E gli stessi ospedali, con qualche eccezione, non sembrano affrettarsi a reclutare team di analisti dei dati interni. Il risultato è un enorme spreco di competenze. I migliori analisti della nostra generazione avrebbero potuto essere al lavoro già da anni sui problemi sanitari. A molti piacerebbe, e donerebbero gratuitamente i frutti del loro lavoro. Invece, si riducono a escogitare modi sempre migliori per farti cliccare su un annuncio pubblicitario perché è lì che ci sono dati da utilizzare.

Privacy

Un altro problema è la privacy dei tuoi dati sanitari. Non possiamo trattare in modo completo questo grande tema, ma possiamo sottolineare un fatto importante: stiamo parlando di dati che gli ospedali possiedono già e che vengono utilizzati per inviarti fatture. Costruire un sistema di IA implica assumere qualcuno che analizzi tali dati preesistenti, sul posto o ottenendo accesso da remoto ai server, dopo aver rimosso tutte le informazioni che consentono di identificare il paziente.

Questo fatto rassicura molti, ma sicuramente non elimina tutti i *possibili* problemi di privacy o sicurezza. Per esempio, potresti aver paura che qualche analista malevolo *riesca* a identificare i pazienti basandosi su dati precedenti o anche su dati che non dovrebbero contenere informazioni personali. In effetti, di tutti i problemi elencati fin qui, questo è l'unico che può essere

risolto da una nuova tecnologia: per la precisione, da qualcosa chiamato «privacy differenziale». Gli statistici e i ricercatori di machine learning hanno *molto* a cuore la privacy e hanno inventato molti trucchi di analisi dei dati – tecniche matematiche con nomi del tipo «sottocampionamento», «funzione crittografica di hash» e «iniezione di rumore» – che mettono totalmente al riparo i dati personali. Con questi nuovi algoritmi di privacy differenziale, un team di analisti in ospedale potrebbe conservare dati sanitari in un modo che consenta di elaborare regole di predizione accurate senza consentire a malintenzionati di carpire dettagli dei pazienti coperti da privacy. Gli algoritmi esistono già, ma gran parte degli ospedali è lontanissima dall'adottarli. Puoi persino trovarli sui telefoni con sistema operativo iOS o Android, in cui, per esempio, vengono usati per analizzare quali correzioni automatiche decidi di scartare mentre scrivi i messaggi di testo. E tutto questo mantenendo i messaggi stessi crittografati e sicuri.

E poi c'è il problema del furto di dati. È una piaga che affligge già gli ospedali: se ricordi i grandi attacchi di pirateria informatica del 2017 (per esempio, WannaCry), ricorderai anche che le strutture sanitarie furono tra le più colpite. Probabilmente tali ospedali non utilizzavano l'IA per elaborare i loro dati, ma quel tipo di attività avrebbe generato rischi di gran lunga minori rispetto a quello già presente. Certo, gli ospedali dovrebbero riparare le falle informatiche, forse, come molti esperti suggeriscono, passando a un tipo di sistema basato su un'infrastruttura distribuita gestita da un'azienda che si occupa di sicurezza a livello professionale. Ma questo non c'entra nulla con il fatto che i dati, già presenti nei server degli ospedali, dovrebbero essere usati fin da subito per migliorare le cure.

Post scriptum

Come ora puoi capire, quando si tratta di adottare l'IA su larga scala nel sistema sanitario, le barriere tecnologiche sono davvero poche, ma ci sono enormi barriere culturali, legali e dovute a scarsi incentivi. Alcune di queste barriere sono tipiche degli Stati Uniti, ma molte altre sono presenti in tutti i paesi ricchi.

La conclusione è che la prossima rivoluzione nella scienza dei dati applicata all'ambito sanitario non richiederà solo una, ma migliaia di Florence Nightingale. Ci vorranno ricercatori come Katherine Heller, Zoltán Takáts,

Sebastian Thrun e Mark Sendak, persone che lavorino su progetti fantastici, che convincano i colleghi in ambito sanitario che l'IA funziona davvero e che continuino a fornire prove convincenti. Ci vorranno medici, infermieri, sviluppatori di software, avvocati, gestori di database, esperti di privacy, investitori, assicuratori, amministratori di ospedali, politici e pazienti al lavoro insieme per far funzionare le cose.

Possa la forza di volontà di Florence – quella «cosa più inscalfibile e più risoluta» – essere con loro.

[*a](#) Un'avvertenza: sia i medici che l'algoritmo esprimevano giudizi sulla base delle sole immagini, e questo è poco realistico. Ci si attendono risultati migliori in entrambi i casi, avendo a disposizione più informazioni cliniche sul paziente.

IL CLIPPER DEGLI YANKEES

Baseball, big data e l'importanza delle ipotesi.

Un certo numero di evangelisti dell'IA crede che le macchine intelligenti renderanno presto superflui gli esseri umani nelle attività di ricerca. Di qui a poco, dicono, non avremo più bisogno di teorie o ipotesi per capire il mondo. Avremo solo bisogno dei giusti algoritmi di deep learning, allenati sui giusti insiemi di dati, e accumuleremo talmente tanta conoscenza che ci uscirà dal naso.

Questo tipo di predizioni è in voga già da un po' di anni. Nel 2008, per esempio, il direttore di "Wired" scrisse: «La scienza può progredire anche senza modelli coerenti, teorie unificate o una qualsiasi spiegazione meccanicistica [...] Possiamo immettere numeri nei più potenti cluster di computer che il mondo abbia mai visto e lasciare che gli algoritmi statistici trovino regolarità dove la scienza non riesce».¹

Comprendiamo l'entusiasmo. L'IA è un mezzo potente e nessuno sa veramente se le macchine saranno un giorno abbastanza intelligenti da concepire nuovi farmaci, spiegare il funzionamento della mente o inventare una teoria quantistica della gravità, unicamente a partire dai dati.

Ma oggi? Non ci siamo affatto vicini. Per capire il perché, consideriamo una domanda semplice e molto specifica: i farmaci contro l'osteoporosi provocano il tumore dell'esofago? Questo è precisamente il tipo di domanda a cui le persone che lavorano sull'IA in medicina vorrebbero rispondere in modo automatico, usando algoritmi intelligenti allenati su enormi database di informazioni sanitarie. In effetti, è la domanda *perfetta* a cui rispondere, in quanto persone molto intelligenti e preparate rispondono in modo discorde. Per esempio, la dottoressa Jane Green, epidemiologa dei tumori presso l'Università di Oxford, ha raccolto prove del fatto che i farmaci contro l'osteoporosi *causano* il cancro. Il dottor Chris Cardwell, un ricercatore in

salute pubblica presso la Queen's University di Belfast, risponde che non è vero. Non sarebbe fantastico se l'IA aiutasse a dirimere la disputa?

Iniziamo con un po' di informazioni. Molte persone affette da osteoporosi prendono farmaci chiamati «bisfosfonati». Tali farmaci possono rallentare o prevenire le lesioni ossee, ma comportano un rischio di disturbi del tratto digestivo, causando nausea e diarrea. Alcuni medici temono che i bisfosfonati possano aumentare il rischio di sviluppare tumore dell'esofago, dello stomaco o del colon-retto.

Cosa dicono gli studi? Iniziamo con quelli che propendono per il no. Il dottor Chris Cardwell e i suoi collaboratori a Belfast hanno esaminato un enorme database di dati medici anonimi, contenente informazioni su quattro milioni di pazienti nel Regno Unito. Lo studio è semplice. Per prima cosa, hanno selezionato un gruppo di pazienti che avevano fatto uso di bisfosfonati. Poi hanno usato un sofisticato algoritmo per trovare pazienti di «controllo», simili a quelli del primo gruppo ma che non avevano fatto uso di bisfosfonati. Infine, hanno seguito nel tempo, all'interno del database, entrambi i gruppi. Non hanno rilevato differenze: gli utilizzatori di bisfosfonati presentavano percentuali di tumore esofageo simili a quelle dei pazienti che non li avevano assunti. I risultati dello studio sono stati pubblicati su "JAMA" (Journal of the American Medical Association), una delle riviste mediche più prestigiose al mondo, nell'agosto del 2010.²

Esaminiamo ora le ragioni del sì. Anche la dottoressa Jane Green e il suo team di ricerca a Oxford hanno esaminato un enorme database di pazienti del Regno Unito, e anche il loro studio è semplice, sebbene leggermente diverso. Hanno esaminato per primi i "casi", ovvero i pazienti che hanno sviluppato il tumore dell'esofago. Poi hanno usato un sofisticato algoritmo per trovare i pazienti di controllo che, pur essendo simili ai casi, non avevano sviluppato il tumore. Infine hanno confrontato casi e controlli, trovando che gli utilizzatori di bisfosfonati avevano una probabilità doppia di ammalarsi. Hanno pubblicato i risultati su "BMJ", un'altra rivista medica di livello mondiale, nel settembre del 2010, solo un mese dopo la pubblicazione del lavoro di Cardwell su "JAMA".³

Riassumendo: uno studio dice *nessun* aumento del rischio e l'altro dice rischio *raddoppiato*.^{*a} Uno dei due deve essere sbagliato.

Non è infrequente che due diverse pubblicazioni, basandosi su due diversi insiemi di dati, diano risposte differenti alla stessa domanda, specialmente se si tratta di qualcosa di estremamente complicato come la salute umana. La

scienza funziona spesso così. In un primo tempo, alcune prove puntano in una direzione, altre puntano in un'altra direzione. Solo col tempo, le evidenze favoriranno in maniera convincente una singola direzione.

Ma anche tenendo conto di ciò, c'è qualcosa di sorprendente negli studi di Cardwell e Green, pubblicati a un mese di distanza su sponde opposte dell'Atlantico e con conclusioni opposte sul fatto che il bisfosfonato aumenti il rischio di tumore. In realtà abbiamo ommesso una parte importante della storia. Senza rendersene conto, entrambi i team hanno analizzato *lo stesso database*, liberamente a disposizione di qualsiasi ricercatore medico. I team hanno ottenuto risposte diverse, nonostante avessero gli stessi casi di tumore, gli stessi utilizzatori di bisfosfonato, gli stessi pazienti di controllo... gli stessi identici dati.

Ma non tutto era davvero identico. I due studi hanno ottenuto risultati diversi perché sono partiti da *ipotesi* diverse. Per esempio, Caldwell e il suo team hanno selezionato i pazienti di controllo sulla base dell'esposizione al bisfosfonato (un modello a «coorte retrospettiva»), mentre Green e il suo team hanno selezionato i controlli sulla base della diagnosi di tumore (un modello «caso-controllo»). È la differenza più significativa nelle ipotesi alla base dei due studi, ma non è certamente l'unica e non esiste macchina sul pianeta che sia in grado di dire quale set di ipotesi sia quello giusto. Questo perché non è stato ancora inventato un algoritmo in grado di proporre, testare e giustificare le proprie ipotesi. Gli algoritmi fanno semplicemente ciò che viene loro ordinato di fare.

Ora capisci perché siamo così scettici al riguardo, rispetto agli evangelisti dell'IA. Se una macchina non è in grado di dirti quale studio sul bisfosfonato è corretto dopo avere esaminato i rispettivi esiti, come potrebbe riuscire a fornire le sue proprie risposte, senza l'aiuto dell'uomo?

La lezione è semplice. Possiamo avere l'impressione di dipendere in tutto e per tutto dalle macchine, al giorno d'oggi. In realtà, però, le macchine dipendono da noi in misura molto maggiore.

Uno studio sulle ipotesi

In che modo l'IA fa affidamento sulle ipotesi fatte dagli esseri umani? Di che tipo di ipotesi parliamo? Perché sono così importanti e che cosa succede di male quando non vengono rispettate? Queste sono le domande a cui risponderemo in questo capitolo.

Noi crediamo che l'esistenza dell'IA non renda affatto meno importanti le ipotesi. Le rende *più* importanti, poiché le conseguenze di una singola ipotesi sbagliata possono essere amplificate enormemente, come nel caso di una macchina che prende in continuazione la stessa decisione sbagliata. Detta in altro modo: l'IA permette al frutto di un albero avvelenato di diventare enorme. Di solito, quando ciò succede, è perché non si è lavorato bene il terreno.

Ci sono tre modi principali in cui ciò può verificarsi:

1. Fretta di concludere.
2. Modelli antiquati.
3. Presenza di distorsioni in input e in output.

Per illustrare questi tre temi, chiederemo l'aiuto di un'icona americana del secolo scorso: Joe DiMaggio.

Nato nel 1914 da una famiglia di immigrati italiani in California, "Joltin' Joe" DiMaggio diventò uno dei più grandi giocatori di baseball della storia, e la sua fama andò ben oltre i confini dello sport. La gente lo considerava un eroe popolare e scrittori e artisti – da Hemingway a Madonna, da Rodgers e Hammerstein fino a Simon e Garfunkel – gli rendevano omaggio nelle loro opere più famose. Uno speaker dello Yankee Stadium lo soprannominò «il Clipper degli Yankees», dal nome degli aerei della Pan American Airways: entrambi erano veloci ed eleganti.

Da perfetti nerd della probabilità, ricordiamo DiMaggio principalmente per l'estate del 1941, quando riuscì a conquistare almeno una base in cinquantasei partite consecutive. Questa serie record è tuttora la più lunga di tutti i tempi e svetta sul secondo posto, a quota quarantacinque incontri consecutivi, di «Wee» Willie Keeler nel 1897. Molti appassionati di baseball considerano il record di DiMaggio imbattibile; Stephen Jay Gould, il famoso biologo e appassionato di baseball, una volta lo definì «la cosa più straordinaria mai accaduta negli sport americani». Come dice Gould, DiMaggio non solo sconfisse cinquantasei diversi lanciatori della Major League, ma «sconfisse l'avversario più in gamba di tutti: la dea bendata».⁴

Quanto era improbabile il record di Joe DiMaggio di cinquantasei partite consecutive con almeno una battuta valida? La risposta interessa certamente gli appassionati che amano confrontare le performance atletiche tra sport

diversi ed epoche diverse, come per esempio il record di DiMaggio rispetto ai 1281 goal di Pelé o alle ventitré medaglie d'oro olimpiche di Michael Phelps.

In realtà a noi interessa per un altro motivo. La serie di cinquantasei partite di DiMaggio può insegnarci qualcosa sull'importanza delle ipotesi, in particolare sul rischio di utilizzare ipotesi poco accurate per fare estrapolazioni troppo audaci da un insieme di dati. Questa lezione è fondamentale per l'IA, poiché prassi corrette nel trattamento dei dati sono essenziali per costruire macchine in grado di apprendere e di prendere decisioni autonome. Il record di DiMaggio ci offre uno spunto per parlare dei possibili errori umani in questo processo.

Joe DiMaggio e la fretta di concludere

Atto primo: la serie

Per calcolare la probabilità delle cinquantasei partite consecutive di DiMaggio con almeno una battuta valida, inizieremo con una metafora. Pensa a una partita di baseball come al lancio di una moneta: testa vuol dire che DiMaggio effettua una battuta valida, croce vuol dire che non ci riesce. Questa metafora rende possibile un'analisi matematica dell'evento. Inizieremo con un caso semplice: qual è la probabilità che esca testa per due volte consecutive? Per una moneta comune, tutti sarebbero d'accordo nel dare la risposta $1/2 \times 1/2 = 1/4$, poiché la probabilità di ottenere testa a ogni lancio è $1/2$, e il secondo lancio non è influenzato dal primo. Il caso di DiMaggio è solo leggermente diverso da quello della moneta: in questo caso, la probabilità di ottenere testa è circa l'80%, perché egli riuscì a effettuare battute valide nell'80% delle partite, delle stagioni precedenti 1940-1942.^{*b} Dunque, la probabilità di una serie vincente di due match è $0,8 \times 0,8 = 0,64$.

Questa logica è facile da estendere a serie più lunghe, usando la cosiddetta "regola di composizione". Supponi che un certo evento si verifichi con probabilità P in ogni partita. Allora la probabilità che si verifichi ogni volta per N incontri è uguale a P^N , ovvero P moltiplicato N volte per se stesso. Dunque, per calcolare la probabilità della serie record di cinquantasei incontri, moltiplichiamo 0,8 per se stesso 56 volte. Il risultato è un numero molto piccolo:

$$P(\text{serie record di 56 partite per DiMaggio}) = \\ 0,8 \times 0,8 \times \dots 0,8 = 1 \text{ su } 250\,000.$$

Una reazione naturale è dire: «Wow, Joe DiMaggio è stato fortunato!». Questo è sicuramente vero. Se guardi ai singoli incontri della serie, certamente troverai qualche botta di fortuna e qualche battuta valida per un soffio.

Ma noi restiamo stupefatti per il talento di DiMaggio, non per la sua fortuna. Per capire il perché, facciamo lo stesso calcolo usando le statistiche di un altro giocatore: Pete Rose, che fece la sua serie vincente nel 1978. A quel punto della sua carriera, Rose aveva una percentuale di partite con battute valide del 76%, solo il 4% più bassa di quella di DiMaggio. Eppure, la regola di composizione amplifica enormemente questa piccola differenza, dando una probabilità pari a:

$$P(\text{serie record di 56 partite per Rose}) = \\ 0,76 \times 0,76 \times \dots 0,76 = 1 \text{ su } 5 \text{ milioni.}$$

È un numero venti volte più piccolo di quello di DiMaggio. E anche Rose era un giocatore straordinario. Che cosa succede se consideriamo un giocatore di medio livello della Major League e la sua media di battuta pari a .250 e una percentuale di battute valide per incontro pari al 68%?

$$P(\text{serie record di 56 partite}) = 0,68 \times 0,68 \times \dots 0,68 = \\ 1 \text{ su } 2 \text{ miliardi.}$$

Un evento praticamente impossibile.

Quindi, è certamente vero che DiMaggio ha avuto dei colpi di fortuna nel corso della sua serie. Ma doveva sicuramente essere molto bravo, in modo che la probabilità a suo favore fosse pari a 1 su 250 000.

Intermezzo: modelli contro realtà

Possiamo trarre due lezioni sulla scienza dei dati e sull'IA dalla nostra analisi della serie vincente di DiMaggio.

La prima lezione è che, in base alla regola di composizione, la probabilità cambia molto rapidamente, come l'interesse composto su una carta di credito. Nel lungo termine, le piccole differenze diventano enormi. Pensa a come una piccola differenza in probabilità tra DiMaggio (80%) e Rose (76%) generi una

differenza pari a un fattore 20 su cinquantasei partite. In effetti, questa è una buona metafora per spiegare il modo in cui le macchine spesso hanno la meglio sugli esseri umani nel gioco degli scacchi, nel gioco del Go o nel suggerire film: sfruttano tanti piccoli vantaggi che, accumulandosi, danno loro alla fine un grande vantaggio.

La seconda lezione riguarda l'importanza delle ipotesi di partenza. Come vedrai tra poco, se impari solo la prima lezione e non la seconda, potrebbero esserci dei problemi.

Gran parte dei calcoli in scienza dei dati fa uso di ipotesi di qualche tipo. Nel caso della serie record di DiMaggio ce n'erano due: il fatto che la probabilità di battuta valida fosse la stessa per ogni partita (80%) e l'*indipendenza* delle partite, ovvero il fatto che una battuta valida in una partita non influenzi in alcun modo la partita successiva. È come dire che, se lanci due volte una moneta, il primo lancio non ha effetti sul secondo. Senza queste ipotesi, la metafora della moneta non funzionerebbe, e nemmeno i nostri calcoli.

Ma queste ipotesi sono certamente vere? Non sempre! Prendi l'ipotesi di probabilità costante. DiMaggio giocava alcune partite in casa, nel gigantesco Yankee Stadium; altre le giocava in trasferta, in campi più piccoli. A volte si trovava a battere delle palle veloci, altre volte delle palle curve. In alcuni match, aveva di fronte lanciatori da hall of fame; in altri, rimpiazzati appena richiamati dai campionati inferiori. Non solo la probabilità non era la stessa per ogni match: era diversa per ogni singola palla di un incontro.

E per quanto riguarda l'indipendenza? Su questa ipotesi si può discutere, ma probabilmente è anch'essa falsa. Uno studio recente, presentato alla MIT Sloan Sports Analytics Conference nel 2016, ha esaminato un enorme numero di dati storici del baseball e ha rilevato un chiaro effetto di «mano calda» tra i battitori.⁵ In altre parole, i giocatori che battono una palla hanno maggiore probabilità di battere anche la successiva. Questo contraddice la nostra ipotesi sull'indipendenza.

Dunque, se le nostre ipotesi sono sbagliate, potresti domandarti, perché ci preoccupiamo di fare dei calcoli? È un'ottima domanda con una risposta complicata.

Ogni scienziato o ingegnere ti dirà che i modelli fanno funzionare il mondo. La Boeing usa i tunnel del vento per costruire aeroplani. I biologi usano i moscerini della frutta per comprendere la genetica umana. La Toyota usa manichini, durante i crash test, per stimare i danni sul corpo umano in

collisioni frontali. Tutte queste situazioni fanno uso di ipotesi su quali caratteristiche del modello devono essere esatte e quali approssimate. In molte situazioni, non faremmo quasi alcun progresso senza l'uso di ipotesi. Come disse un capoprogetto della spedizione Viking su Marte, il suo lavoro non era progettare una sonda che atterrasse su Marte: era progettare una sonda che atterrasse sul modello di Marte creato dai geologi della NASA.⁶

Anche in scienza dei dati si fa uso di modelli, proprio come quelli che ci hanno aiutato a esaminare la serie vincente di Joe DiMaggio. I nostri modelli sono basati sulla probabilità e vengono utilizzati per estrarre informazioni dai dati e per costruire sistemi di IA, come molti di quelli che hai incontrato in questo libro.

Gli analisti hanno un motto: tutti i modelli sono sbagliati, ma alcuni di essi sono utili.⁷ In altre parole, nessun modello può descrivere la realtà perfettamente, ma a volte la discrepanza è rilevante, altre volte no. Il corollario è che stabilire l'utilità di un modello richiede la conoscenza sia del modello sia di come viene usato. Un manichino per abbigliamento è un modello perfettamente adeguato se vuoi solo esporre un abito in vetrina, ma è totalmente inadeguato per insegnare l'anatomia vascolare agli studenti di medicina.

Torniamo dunque sulla nostra affermazione precedente, ovvero che Joe DiMaggio aveva una possibilità su 250 000 di effettuare battute valide in cinquantasei match di fila. Questa *non* è un'affermazione sul DiMaggio reale, ma sul modello di DiMaggio. Questo modello utilizza ipotesi, come la probabilità costante e l'indipendenza, che barattano intenzionalmente la realtà con la semplicità.

Non sarebbe molto difficile correggere i problemi del modello. Potremmo calcolare probabilità distinte per le partite in casa e in trasferta, o potremmo modificare i numeri a seconda del lanciatore che DiMaggio si trovava davanti.⁸ Le macchine gestiscono facilmente questo tipo di compiti. Ovviamente, per porti il problema devi prima capire quali sono i limiti del modello e, se ti interessa solo una buona approssimazione per una discussione da bar con un tuo amico, questi passaggi aggiuntivi potrebbero non essere necessari. Non devi accertarti che il modello sia quello giusto, ma solo che sia sufficientemente adatto ai tuoi scopi e che, sebbene sia possibile migliorare il modello, questo non aggiungerebbe informazioni rilevanti per la tua discussione informale sulle serie vincenti nel baseball.

Il punto cruciale è che la costruzione di modelli è un mestiere per esseri

umani. Una macchina può fare predizioni basate sulle ipotesi con cui è stata programmata, ma solo gli esseri umani possono controllare tali ipotesi. Una macchina può applicare un modello ai dati, ma solo un essere umano può usare quel modello per fare le domande giuste. Una macchina può scandagliare milioni di dati al secondo, ma solo un essere umano può decidere quali dati sono necessari. La scienza dei dati ha bisogno della collaborazione tra macchine ed esseri umani, perché la discrepanza tra modello e realtà non è sempre di poca importanza, come nel caso del baseball.

Per chiarire questo punto, passiamo alla seconda parte del racconto su Joe DiMaggio: vedrai un famoso quotidiano spingersi troppo oltre con il modello di serie vincente di DiMaggio, finendo per spaventare senza motivo milioni di persone. Questa storia è molto importante per capire il ruolo delle ipotesi in IA.

Atto secondo: quanto è efficace il tuo metodo?

Gli egizi del delta del Nilo utilizzavano un miscuglio di miele e carbonato di sodio. In Mesopotamia si preferivano foglie di acacia e stoffa. Gli antichi persiani usavano sterco di elefante e cavolo. Gli europei nel Rinascimento ricorrevano a radici di giglio e intestino di bachi da seta.

Nelle società moderne, la vita è più facile. Gran parte delle persone usano i profilattici o la pillola, o scelgono volontariamente la via della sterilizzazione indolore.

Il controllo delle nascite è vecchio almeno quanto la civiltà umana; la grande differenza, rispetto all'antichità, è che i nostri metodi funzionano davvero bene. Dagli anni sessanta, quando i metodi efficaci di contraccezione iniziarono a diffondersi, il tasso di natalità dei paesi industrializzati è andato in picchiata. Al giorno d'oggi, l'uso di metodi contraccettivi è quasi universale tra gli adulti sessualmente attivi nei paesi ricchi.⁹

Sappiamo che, per molte persone, la scelta di quando usare la contraccezione, e quale metodo in particolare, non può ridursi a una singola variabile.¹⁰ Ma una domanda importante a cui rispondere è: qual è la probabilità di incorrere in una gravidanza usando un certo metodo? Con questa domanda in mente, nel 2014, il "New York Times" pubblicò un articolo dal titolo *Quanto è probabile che il tuo metodo di contraccezione ti tradisca?*¹¹ Gli autori dell'articolo partirono da una semplice premessa: più fai uso di un metodo contraccettivo, più alta sarà la probabilità che fallisca.

Per fornire qualche numero a supporto, esaminarono i dati sull'efficacia in un anno di quindici metodi contraccettivi. Usarono tali dati – insieme ai loro calcoli, che descriveremo tra poco – per creare un grafico interattivo che si prefiggeva di evidenziare il tasso di fallimento a lungo termine, su un periodo di dieci anni, di ogni metodo.

Abbiamo usato gli stessi dati per replicare i calcoli del “New York Times”,¹² usando la stessa metodologia impiegata dagli autori dell'articolo, per un sottoinsieme di nove metodi. I nostri risultati, riportati nella figura 7.1, sono in accordo con i loro. Ogni grafico mostra un diverso metodo contraccettivo. L'asse verticale riporta la stima del “New York Times” per la probabilità di restare incinta almeno una volta, facendo uso di quel particolare metodo per lungo tempo.

Se i numeri ti sorprendono, sappi che non sei il solo: l'articolo impressionò molte persone. Per esempio, diceva che la percentuale di fallimento per un uso tipico della pillola era del 9%,^{*c} ma che la percentuale su dieci anni saliva a un allarmante 61%. I numeri per il preservativo erano ancora peggiori: la percentuale di fallimento a dieci anni era dell'86%. Per molte persone, questi numeri erano incredibilmente alti e implicavano un rischio decisamente maggiore di gravidanza indesiderata rispetto a quello a cui si erano preparati. L'articolo, probabilmente proprio per questo motivo, divenne subito virale sui social media e, anche se non provocò una corsa a prendere i voti di castità, generò parecchia ansia tra i lettori abituali del “New York Times”, molti dei quali presumevano che il proprio metodo contraccettivo fosse decisamente più efficace. Persino i ginecologi, che dovrebbero conoscere il proprio ambito di ricerca come qualunque altro scienziato, si precipitarono a condividere il link all'articolo e a lanciare l'allarme.^{*d}

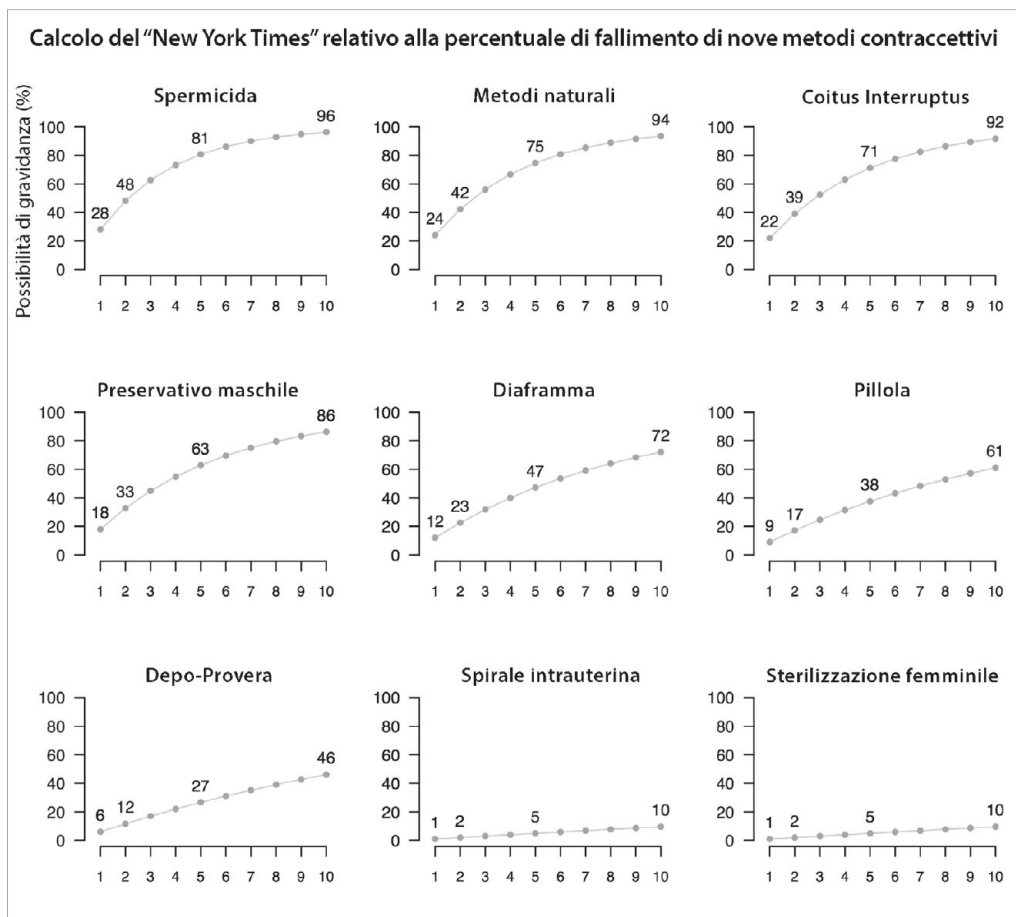


Figura 7.1

Una storia basata su ipotesi scadenti

Ma c'era un grave problema nell'articolo del "New York Times": le sue percentuali di fallimento a lungo termine non avevano alcuna base solida. Erano certamente *troppo* alte.

Nessuno al mondo conosce davvero le percentuali di fallimento su dieci anni di questi metodi contraccettivi.¹³ Per motivi di ordine pratico, lo studio non è stato ancora fatto. Nonostante la mancanza di prove, tuttavia, ci sono buoni motivi per pensare che il "New York Times", a causa di ipotesi scadenti, abbia largamente sovrastimato la possibilità di gravidanze facendo uso di metodi contraccettivi sul lungo termine.

Ecco come il giornale ha calcolato le supposte percentuali di fallimento. Per prima cosa hanno preso, da ricerche pubblicate, il tasso annuale di fallimento in seguito a un «uso tipico» (per esempio, il 9% nel caso della pillola). Questi numeri derivano da trial clinici o sondaggi a livello nazionale, e forniscono la migliore stima disponibile. Fin qui, tutto ok.

Poi gli autori hanno usato la regola di composizione per calcolare la probabilità di una «serie vincente» per diversi anni di seguito. In effetti, i giornalisti hanno trattato l'assenza di gravidanze indesiderate in seguito all'uso prolungato di contraccettivi in modo esattamente analogo alla serie vincente di Joe DiMaggio, usando le stesse ipotesi: indipendenza e probabilità costante negli anni.

Vediamo un esempio. Tra gli utenti tipici della pillola, la probabilità di evitare una gravidanza in un anno era del 91%. Basandosi su questo numero, il "New York Times" ha impiegato la regola di composizione per calcolare la seguente probabilità:

$$\begin{aligned}P(\text{nessuna gravidanza in 1 anno}) &= 0,91 \\P(\text{nessuna gravidanza in 2 anni}) &= (0,91)^2 \approx 0,82 \\P(\text{nessuna gravidanza in 3 anni}) &= (0,91)^3 \approx 0,75.\end{aligned}$$

E così via. Su dieci anni, la probabilità di una lunga «serie vincente» inizia a essere abbastanza piccola: circa il 39%. Questo implica un 61% di probabilità di avere almeno una gravidanza indesiderata su un periodo di dieci anni di utilizzo della pillola.

Un'analogia

Questo calcolo, tuttavia, contiene un errore gigantesco. Per vedere di cosa si tratta, consideriamo un'analogia. Supponi di condurre uno studio reclutando 100 persone e dando una moneta a ciascuna di esse. Le monete sono state modificate in modo che novanta abbiano testa su entrambi i lati e dieci croce su entrambi i lati. Ora chiediamo ai partecipanti di lanciare le monete: ottenere croce equivale a restare incinta. La domanda è: quanti dei nostri 100 partecipanti allo studio otterrà un risultato di «niente gravidanza» per dieci anni consecutivi, ovvero otterrà testa per dieci volte consecutive?

Chiaramente la risposta è il 90%: novanta partecipanti su cento hanno monete con due teste, e dunque non otterranno mai croce. Ma vediamo come possiamo ottenere la risposta sbagliata usando la regola di composizione. Supponi di procedere come segue:

1. Prendi i dati del primo anno di studio, in cui novanta persone ottengono testa e dieci ottengono croce.
2. Calcola la probabilità media di evitare croce nel primo anno, che sarà del 90%.

3. Usa la regola di composizione per calcolare la probabilità di una serie vincente di dieci anni, basandoti sulla stima a un anno: 0,910, ovvero circa il 35%.
4. Deduci che solo trentacinque dei cento partecipanti eviteranno una gravidanza indesiderata per dieci anni di fila.

Questo è più o meno quello che ha fatto il “New York Times”, nella sua analisi sui fallimenti dei metodi contraccettivi, ed è completamente sbagliato. È corretto dire che la probabilità media di ottenere testa sia 0,9? Certamente sì. Ma questo implica che la probabilità media di ottenere testa per dieci volte di fila sia 0,910, ovvero il 35%? Assolutamente no. Dieci persone nel nostro studio otterranno sempre croce e le altre novanta persone otterranno sempre testa. La probabilità media, calcolata sulla popolazione, di una serie vincente di dieci partite – o di qualunque numero di partite – è in realtà pari al 90%, non al 35%. Non possiamo usare la regola di composizione, nemmeno come approssimazione: semplicemente *non funziona* per le medie sulla popolazione.

Ecco un'altra analogia, molto vicina alla domanda sull'efficacia contraccettiva: qual è la probabilità di evitare un incidente d'auto nei prossimi dieci anni? Ogni anno, due milioni di automobilisti negli Stati Uniti provocano un incidente, ovvero circa l'1% del totale dei conducenti americani. Dunque la probabilità «tipica» di non causare incidenti negli Stati Uniti in un anno è pari a circa il 99%. Per calcolare la probabilità su dieci anni, potresti essere tentato di usare la regola di composizione, moltiplicando 0,99 per se stesso dieci volte:

$$P(\text{nessun incidente in 10 anni}) = 0,99 \times 0,99 \times \dots 0,99 = 0,904.$$

Ma è sbagliato. Per capire perché, torniamo alla fine del primo anno della serie. A questo punto, la popolazione americana si divide in due gruppi: due milioni di persone che hanno causato un incidente stradale, e 198 milioni di persone che non lo hanno causato. Ora fatti due semplici domande. Cosa succederà ai premi assicurativi delle automobili di ciascun gruppo, e perché?

La risposta è evidente. Il gruppo 1, con i due milioni di persone che hanno causato un incidente, subirà un aumento dei premi assicurativi. Il gruppo 2, con i 198 milioni di persone che non hanno provocato incidenti, vedrà le tariffe restare invariate o diminuire. Perché? Le compagnie assicurative non lo fanno per punire o premiare le persone. Lo fanno per valutare in modo appropriato il rischio di un *futuro* incidente, e gli incidenti futuri non sono

eventi totalmente indipendenti. Incidenti passati predicono incidenti futuri; per alcune persone è più probabile che esca testa, per altre è più probabile che esca croce.

Cosa succederà dunque durante il secondo anno? Quasi certamente, *più* dell'1% delle persone nel gruppo 1 provocherà un incidente. I conducenti in questo gruppo sono statisticamente meno prudenti, almeno in media. Parimenti, *meno* dell'1% delle persone nel gruppo 2 provocherà un incidente. I conducenti in questo gruppo sono statisticamente più prudenti, di nuovo, almeno in media. Nella scienza dei dati, la chiamiamo «variabile latente»: qualcosa che ha un effetto importante sull'esito di un test, sebbene non sia misurato direttamente.

Il problema della variabile latente illustra cosa c'era di sbagliato nel nostro calcolo precedente, in cui abbiamo preso la probabilità del 99% di non avere incidenti e abbiamo applicato la regola di composizione su dieci anni. La domanda è: la probabilità di quale gruppo stiamo utilizzando? E la risposta è: quella di nessun gruppo! La probabilità annuale dell'1% è una proprietà della popolazione o, al massimo, la proprietà di un immaginario *Homo medius*, con un rischio di incidenti pari all'1%, 2,1 figli, metà diploma universitario, un testicolo e una ovaia. Ma una persona *reale* ha un rischio che è o maggiore o minore dell'1% medio. Se hai fatto un incidente nel primo anno, il tuo rischio appare maggiore; se non lo hai fatto, appare minore. Il calcolo basato sulla regola di composizione è sbagliato *letteralmente per tutti*.

Ritorno alla pillola

Torniamo alla percentuale di fallimento su dieci anni della pillola contraccettiva. Utilizzando la probabilità di successo a 1 anno pari al 91%, insieme alla regola di composizione, il “New York Time” ha ottenuto una probabilità del 39% per una «serie vincente» di dieci anni senza gravidanze indesiderate. Ma, come abbiamo visto, non puoi semplicemente applicare la regola di composizione a una probabilità media sulla popolazione, perché non terresti conto delle variabili latenti. E c'è una variabile latente molto importante in questo caso: alcune persone non usano il metodo contraccettivo come dovrebbero, e dunque è più alta la probabilità che «esca croce», e di gravidanze.

In effetti, non esiste un *utente tipico* in uno studio sulla contraccezione, ma solo un *gruppo tipico*.¹⁴ La ricerca sulla contraccezione non è simile a una

partita di baseball per voyeur, in cui gli scienziati scrutano le camere da letto alla ricerca del giocatore medio di Major League, una media battuta di .250. Si tratta di aspettare e contare: si segue un gruppo tipico di persone che usano un metodo – alcune di loro in modo irregolare, altre in modo scrupoloso – e si conta quante restano incinte.

In qualsiasi situazione di questo tipo, se usi la regola di composizione per capire cosa succederà al gruppo basandoti sulla media in un anno, otterrai la risposta sbagliata. Per proseguire con le nostre precedenti analogie:

- Nel primo lancio di monete del nostro ipotetico studio, il 10% delle persone otterrà croce. Questo numero include sia le monete con due teste sia quelle con due croci. Dunque, se non ottieni croce, abbiamo imparato qualcosa sulla tua moneta: ha due teste. La tua probabilità di ottenere croce al prossimo lancio è 0%.
- In un singolo anno, circa l'1% degli americani provoca un incidente automobilistico. Questo numero include sia i guidatori più prudenti sia quelli meno prudenti. Dunque, se non provochi incidenti in un anno, abbiamo imparato qualcosa sul tuo stile di guida: la tua probabilità di causare incidenti il prossimo anno è minore dell'1%.
- Nel primo anno di utilizzo della pillola contraccettiva, circa il 9% delle donne restano incinte. Questo numero include sia coloro che la usano in modo irregolare, sia coloro che la usano in modo scrupoloso. Dunque, se non resti incinta nel primo anno, abbiamo imparato qualcosa sul tuo modo di usare la pillola: la tua probabilità di restare incinta l'anno prossimo è minore del 9%. Forse è l'8%, forse è il 2%, nessuno lo sa, perché nessuno ha fatto questo studio. Ma sappiamo che le utenti più irregolari, che hanno contribuito in larga parte alla percentuale di fallimento del 9% nel primo anno, sono ora fuori dal campione.

La figura 7.2 illustra il concetto. Confronta le percentuali di fallimento cumulative su dieci anni tra le utenti della pillola contraccettiva, sotto due ipotesi di partenza. La curva con i puntini fa uso dell'ipotesi del "New York Times": le donne che restano nello studio negli anni successivi continuano ad avere un'irrealistica probabilità, pari al 9% annuale, di restare incinte. Questo predice una percentuale di fallimento cumulativa su dieci anni pari al 61%, nell'ipotesi che le gravidanze indesiderate nel decimo anno siano altrettanto frequenti che nel primo anno.

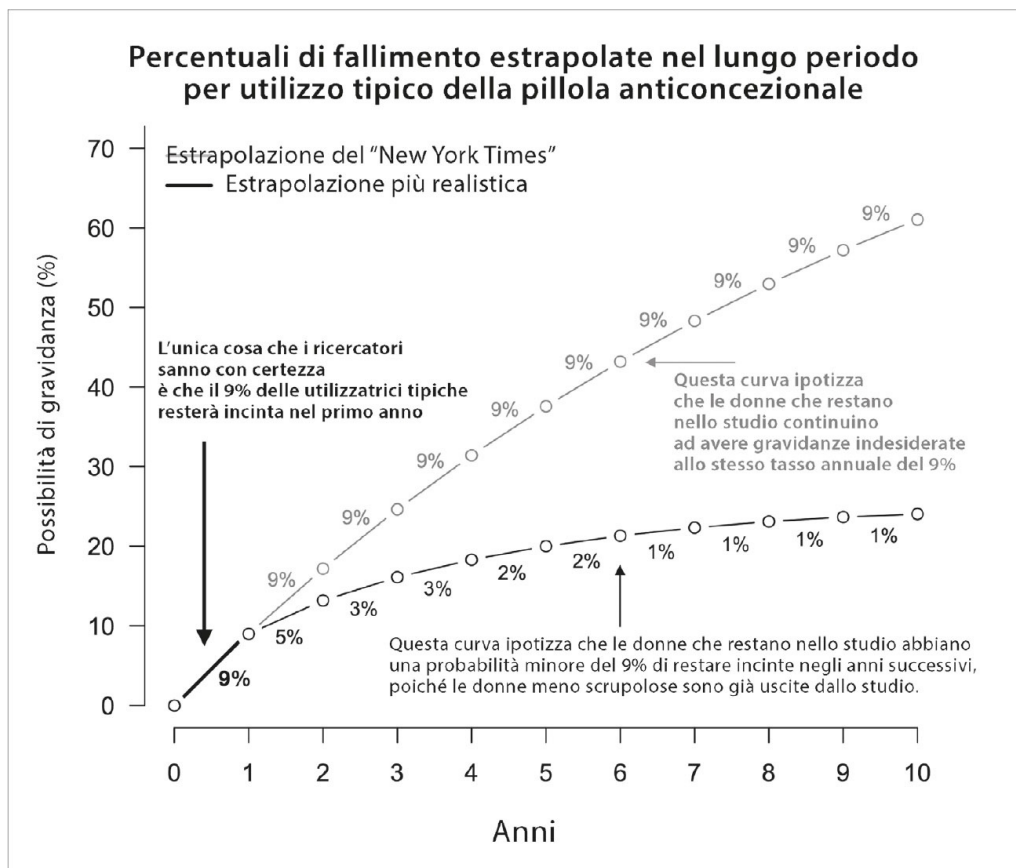


Figura 7.2

La curva continua ipotizza, invece, che negli anni successivi le donne che restano nello studio abbiano una probabilità *minore* del 9% di restare incinte, poiché le utenti meno scrupolose sono già uscite dallo studio. Questo effetto diventa più forte al passare del tempo, e solo le utenti più scrupolose restano fino alla fine dello studio. La curva predice una percentuale di gravidanze indesiderate pari al 25% su dieci anni, e gran parte di esse si verifica nei primi anni della finestra temporale, da parte di utenti meno scrupolose.

Dobbiamo sottolineare che l'unica cosa certa deducibile dai dati è che il 9% della coorte di utilizzatrici «tipiche» di pillola anticoncezionale resta incinta durante il primo anno. Dal secondo anno in poi, entrambe le curve sono estrapolazioni, basate unicamente su ipotesi di lavoro.

Anche se tutti i modelli sono sbagliati, alcuni sono più sbagliati di altri.

Epilogo: «Una mania inutile e dannosa»

Consideriamo l'articolo sulle percentuali di fallimento dei metodi contraccettivi come un esempio di ciò che il guru dell'analisi dei dati Edward

Tufte chiama «fallacia da fretta-di-concludere». Il nome viene da un aforisma di Flaubert: «La fretta di portare a termine qualcosa è una delle manie più inutili e dannose che affliggono l'umanità».¹⁵

Tufte si riferisce alla tendenza umana di vedere regolarità nella casualità, ma la fretta di concludere non si limita certamente a questo. A volte un insieme di dati è intrinsecamente inadatto a rispondere a un quesito. Quando questo succede, dovresti cercare un altro insieme di dati che *può* effettivamente essere di aiuto. Per esempio, i dati sulla percentuale di fallimento della pillola durante il primo anno non possono dirti nulla sulla percentuale di fallimento in dieci anni: per sapere cosa succede dopo dieci anni, devi aspettare dieci anni. Ma se hai fretta di sapere la risposta *ora*, la tentazione di estorcere una confessione dai dati a tua disposizione, usando ipotesi inadeguate, purtroppo è grande. E questa confessione potrebbe fare parecchi danni. Un conto è fare ipotesi azzardate per analizzare la serie vincente di Joe DiMaggio: non si rischia molto. Altra cosa è l'utilizzo delle stesse ipotesi per analizzare l'efficacia contraccettiva, nel qual caso quelle ipotesi sono *molto* errate e le fake news possono arrecare danno a milioni di persone.

Può essersi trattato di un errore dovuto a scarsità di dati, ma la lezione per il mondo dell'IA è chiara. Immagina che quelle stesse ipotesi non siano utilizzate solo per scrivere un articolo di giornale, ma che vengano fornite a un sistema di IA che prenda decisioni autonome senza il supporto di un essere umano. È esattamente ciò che sta alla base dei seguenti aneddoti.

- Nell'aprile del 2011, su Amazon erano disponibili diciassette copie di *The Making of a Fly*, un classico della biologia dello sviluppo. La più economica delle quindici copie usate costava 35,54 dollari, mentre la più economica delle copie nuove costava più di ventitré milioni di dollari. Due algoritmi, gestiti da due diversi rivenditori, erano finiti in un meccanismo di asta inversa, in seguito a ipotesi poco accurate sul comportamento degli altri rivenditori.¹⁶
- Un negozio online di abbigliamento chiamato Solid Gold Bomb ha creato un algoritmo che genera automaticamente nuovi modelli per magliette da stampare su richiesta, basandosi sull'uso di frasi random presenti in espressioni popolari, come «Keep Calm and Carry On». Per mancanza di supervisione, l'azienda finì per pubblicizzare magliette con terribili frasi misogine, incluse alcune riguardanti abusi sessuali. Fu un'esperienza traumatica per molti che si imbarcarono nei modelli online, e l'azienda cessò l'attività per via delle ripercussioni.¹⁷
- Il 6 maggio del 2010, il mercato azionario statunitense subì un *flash crash*, perdendo mille miliardi di dollari nel giro di pochi minuti per colpa di

algoritmi difettosi. Secondo il Dipartimento della giustizia statunitense, un operatore disonesto con base a Londra aveva effettuato finte transazioni per un valore di 200 milioni di dollari, modificate 19 000 volte su un periodo di tempo molto breve prima di essere definitivamente annullate. Ciò indusse un clima generale di sfiducia nei confronti di alcune azioni. In risposta, tutti gli altri algoritmi di investimento – le cui ipotesi di base non includevano la possibilità di tali inganni – andarono in tilt, emettendo milioni di *veri* ordini di vendita. Prima che qualcuno si rendesse conto di cosa stava succedendo, l'indice Dow Jones aveva perso il 9% del suo valore in meno di mezz'ora.¹⁸ (Fortunatamente, ci fu un rimbalzo quasi immediato.)

Questi algoritmi non erano consapevoli delle conseguenze delle loro decisioni e neanche del contesto d'affari che rese necessaria la loro costruzione. Stavano semplicemente facendo ciò che era stato chiesto loro di fare, da persone con ipotesi di lavoro errate.

Eppure, anche riconoscendo il rischio derivante da ipotesi sbagliate, è importante contenere lo scetticismo, in modo da non rinchiuderci in un angolo per paura di fare *qualsiasi tipo di ipotesi*. Non tutte le ipotesi sono errate, e anche quelle errate non portano sempre problemi. L'intelligenza artificiale tenta di spingere più in là possibile la frontiera della scienza dei dati, e a volte questo significa basarsi su ipotesi e approssimazioni per fare estrapolazioni al di fuori del dominio dei dati di partenza. Per esempio:

- Gli epidemiologi usano l'IA per setacciare database enormi di informazioni mediche e rispondere a quesiti importanti per la salute pubblica.
- Gli psicologi studiano i post su Instagram per rilevare cambiamenti nell'umore delle persone e riconoscere depressione e ansia allo stadio iniziale.
- Gli osservatori del mercato usano le chat sui social media come indicatore principale dell'attività economica.
- Zillow fa uso di dati pubblici e di resoconti generati dagli utenti per predire il valore di mercato di quasi ogni casa negli Stati Uniti.

Queste idee, e migliaia di altre, funzionano. Ma devono tutte fare i conti con un problema: gran parte dei dati nell'era di internet è raccolta secondo canoni decisamente poco scientifici, e per gli scopi di qualche altro soggetto, ed è dunque solo marginalmente utile per qualsiasi altro scopo. Per aggirare il problema – o, forse ancora più importante, sapere quando non puoi farlo – farai bene a riconsiderare le tue ipotesi di partenza.

È in corso un grande processo di democratizzazione dell'IA. Gli sforzi in atto per raccogliere e organizzare i dati, in modo che potenti algoritmi

possano fare il loro lavoro in modo efficiente e senza errori eclatanti, creeranno enormi database dall'alto valore economico e sociale. Molto presto quasi ogni azienda, grande o piccola, farà affidamento su questo tipo di dati per le proprie attività. In questa nuova era, è essenziale tenere a bada la fretta di concludere, ricordando che ogni ipotesi non verificata è un tappabuchi, un'approssimazione da usare, nel bene o nel male, solo finché non saranno disponibili nuovi dati.

Modelli antiquati

Abbiamo visto come ipotesi poco accurate all'interno del modello possano generare tremendi errori. Ma i modelli non sempre nascono male. A volte peggiorano a causa della troppa ruggine accumulata.

Un'applicazione sfortunata e molto nota dell'IA illustra perfettamente questo fenomeno. Il sistema in questione fu messo online nel 2008 nella speranza di rispondere a un importante problema di salute pubblica, che metteva a rischio denaro e vite umane. Nel tempo, tuttavia, le sue predizioni si allontanarono sempre di più dalla realtà. Nel 2012 il modello si comportava *davvero male*. Eppure, nonostante la sua performance si fosse deteriorata, il modello continuava a ricevere grande attenzione, dopotutto faceva uso di *big data*, un termine talmente seducente, sebbene protetto da un campo di forze di noiosità matematiche, da evitare esami più approfonditi.

Il sistema si chiamava Google Flu Trends. Questa è la storia del suo insuccesso, e del perché fu messo offline nel 2015.

Usare grandi insiemi di dati per predire epidemie di influenza

L'influenza uccide centinaia di migliaia di persone al mondo ogni anno, ed è causa di sofferenze per decine di milioni. E stiamo parlando solo dell'influenza di stagione. Gli esperti di malattie infettive perdonano il sonno dietro alle pandemie influenzali, come l'influenza di Hong Kong del 1968, o la Spagnola del 1918 che uccise cinquanta milioni di persone, tre volte più della prima guerra mondiale.

Per diffondere i suoi sforzi sulla prevenzione e sulle cure, lo US Center for Disease Control and Prevention (CDC) ha per lungo tempo utilizzato ILINet, che sta per Influenza-Like Illness Surveillance Network (rete di monitoraggio

di malattie di tipo influenzale). ILINet è una rete nazionale composta da più di 2700 operatori sanitari che inviano dati e campioni di laboratorio direttamente al CDC ogni volta che visitano un paziente con sintomi influenzali. Il CDC usa queste informazioni per produrre un indicatore settimanale di attività influenzale per ogni stato.

Sfortunatamente c'è un grosso problema con ILINet: impiega una settimana, o anche più, per esaminare i campioni di laboratorio e analizzare i dati grezzi. Dunque, nonostante il sistema sanitario del paese dipenda da ILINet per prendere decisioni importanti sulla prevenzione dell'influenza, sui test e sulla distribuzione dei farmaci – e sebbene sia tuttora il migliore strumento a disposizione – le predizioni arrivano in ritardo di due settimane. Ed è abbastanza perché un'epidemia contagi un numero enorme di individui.

Gli analisti di Google, tuttavia, credevano di poter risolvere il problema usando un approccio intelligente basato sull'IA. La loro idea era semplice e ingegnosa: la frequenza di alcune ricerche online doveva essere strettamente collegata all'attività influenzale. Per esempio, la figura 7.3 mostra quanto spesso gli americani chiedevano a Google «quanto dura l'influenza?» tra il 2008 e il 2012.

Le ricerche di questo tipo avevano un picco ogni inverno, proprio all'inizio della stagione influenzale. Google riesce ad analizzare questo tipo di ricerche molto più velocemente di quanto il CDC possa fare con i campioni di laboratorio provenienti da 2700 ambulatori. Dovrebbe quindi essere possibile tracciare l'attività influenzale con un ritardo molto minore, usando un sistema di IA che raggruppi le ricerche e produca previsioni.




Figura 7.3

Ma la mappatura tra le ricerche su Google e l'attività influenzale è imperfetta e soggetta a rumore. Non tutti usano gli stessi termini di ricerca, e non tutte le ricerche sul tema implicano che qualcuno abbia l'influenza. Non si può quindi costruire un sistema di tracciamento un bel po' naïf, conteggiando un caso di influenza per ogni ricerca Google contenente la parola «influenza». Bisogna agire in modo più intelligente, costruendo una regola di predizione basata su dati storici.

Gli analisti di Google hanno fatto esattamente questo. L'input per il loro modello erano le frequenze dei cinquanta milioni di termini possibili. L'output era una predizione per i numeri pubblicati da ILINet ogni settimana, lo standard di riferimento per quantificare l'attività influenzale negli Stati Uniti. Il team di Google descrisse il metodo in un articolo su "Nature",¹⁹ e iniziò a pubblicare le previsioni del proprio modello su un sito web a ciò dedicato, "Flu Trends", che fu accolto in pompa magna dalla comunità medica.

Sfortunatamente, Flu Trends partì col piede sbagliato. Nel 2009 mancò totalmente una gigantesca epidemia fuori stagione causata dal virus H1N1 (l'influenza suina). Di conseguenza, gli ingegneri Google fecero qualche modifica all'algoritmo e per i due anni successivi, dall'autunno del 2009 all'estate del 2011, Flu Trends si comportò bene: riuscì a riprodurre i risultati del CDC con accuratezza e senza il ritardo di due settimane.²⁰

A partire dall'autunno del 2011, tuttavia, le cose iniziarono a peggiorare. Nella stagione 2011-2012, il modello sovrastimò l'attività influenzale del 50%, suscitando l'allarme dei professionisti sanitari che facevano affidamento su di esso. Poi peggiorò ulteriormente: nella stagione 2012-2013, le previsioni di Flu Trends sovrastimarono il picco del 150%.²¹ In tutto, dall'agosto del 2011 al settembre del 2013, le stime di Google furono eccessive in 100 settimane su 108.²² Se i sanitari avessero fatto affidamento su quelle stime, avrebbero stanziato ingenti risorse per curare migliaia di casi influenzali che semplicemente non esistevano.

Come invecchiano i modelli

Google Flu Trends è un ottimo esempio di un principio generale: in IA, i modelli non si mantengono nuovi di zecca nel tempo.

In effetti, tendiamo a pensare che i modelli invecchino come padelle di ferro. Se ti prendi cura di una padella di ferro, può addirittura migliorare nel tempo: si forma una patina protettiva e il cibo non si attacca facilmente. Lo stesso vale per i modelli in IA. Se fai manutenzione e lo «aggiorni» periodicamente con nuovi dati – mediante la strategia di definizione per tentativi, di cui abbiamo parlato nel capitolo 2 – il modello fornisce previsioni migliori col tempo. Ma se lo trascuri, se lasci accumulare una crosta di ipotesi vecchie e annerite, quella patina può trasformarsi in ruggine. Trascuralo ancora un po', e il modello marcirà.

Flu Trends aveva accumulato troppa ruggine: era quasi marcio. Per capire il perché, abbiamo parlato con la dottoressa Rosalind Eggo, ricercatrice di malattie infettive alla London School of Hygiene & Tropical Medicine. Eggo elogiò subito il fatto che Google avesse messo una tale risorsa di dati al servizio del bene comune, ma disse anche che il fatto di aver mancato la pandemia H1N1 del 2009 avrebbe dovuto far scattare un allarme. «Sebbene Google non rilasciasse molti dettagli sull'algoritmo» spiega Eggo, «alcuni ipotizzano che i termini di ricerca scelti non fossero legati all'influenza, ma piuttosto all'*inverno* in generale, come le ricerche per il basket delle scuole superiori. Di conseguenza, tracciavano semplicemente una certa stagionalità dei termini di ricerca, piuttosto che qualcosa di specifico sull'influenza.» Eggo cita un articolo del 2014 pubblicato su *Science* dal dottor David Lazer e da suoi colleghi, che esamina la performance di Flu Trends nel tempo e conclude che l'algoritmo originale era «un po' rilevatore di influenza, un po'

rilevatore d'inverno».²³ Questo avrebbe dovuto destare sospetti sui dettagli dell'implementazione dell'algoritmo.

Un altro grosso problema è che Google spingeva i suoi utenti a violare le ipotesi di base di Flu Trends. Google effettua costantemente piccole e grandi modifiche sui suoi algoritmi di ricerca e le persone modificano di conseguenza le loro ricerche. Un esempio è offerto dall'autocompletamento, ovvero il sistema che ti suggerisce termini di ricerca mentre scrivi. Fa risparmiare tempo agli utenti, ma cambia anche i loro comportamenti. Eggo fa notare che, quando le persone poggiano le dita fredde e umide sulla tastiera per ricevere consigli sui sintomi dell'influenza, «l'autocompletamento influisce su quello che finiscono per trovare». Per esempio, qualcuno che voleva cercare «influenza come evitarla» finirà per cercare «influenza come curarla», perché «trattamento» era la prima parola suggerita dall'autocompletamento. Ma Flu Trends si basava sull'ipotesi di una relazione fissa tra termini di ricerca e attività influenzale. Se quell'ipotesi viene a mancare – se qualcosa *di diverso dall'influenza* modifica i termini della ricerca – anche il modello di previsione viene a mancare. È probabilmente ciò che è successo nel 2009: tutte queste migliaia di piccole modifiche agli algoritmi, secondo Eggo, «non erano tracciate da Google Flu Trends, e il loro effetto sulla qualità del fit non è stato preso in considerazione».

Ci sono due aspetti spiacevoli in questa storia. Per prima cosa, in linea di principio non dovrebbe essere difficile, per un'azienda con i mezzi di cui dispone Google, impegnarsi per prevenire la ruggine e permettere ai propri modelli di adattarsi ai nuovi comportamenti di ricerca degli utenti. I modelli dinamici, in grado di rilevare un cambiamento nella relazione strutturale tra input e output, sono una componente standard della cassetta degli attrezzi in scienza dei dati. Il perché gli analisti di Google non agirono in questo modo resta per noi un mistero e, per quanto ne sappiamo, nessuno ha mai fornito una spiegazione pubblica.

Un altro aspetto spiacevole è che molti ricercatori sono stati scoraggiati dal perseguire un'intuizione di tale portata. Abbiamo chiesto a Eggo se gli specialisti di salute pubblica abbiano imparato la lezione da Flu Trends, e lei ha risposto:

Credo che abbiano imparato fin troppo. Sono terrorizzati da questo fallimento. Se Google avesse semplicemente permesso al proprio modello di

adattarsi all'algoritmo di ricerca, probabilmente avrebbe funzionato. E avrebbe potuto fornire informazioni molto più dettagliate, a livello cittadino, rispetto a quelle che i comuni sistemi di sorveglianza potranno mai sperare di fornire. È un sistema enormemente promettente, ma credo Google ne abbia abbastanza della cattiva pubblicità. E per quanto riguarda i ricercatori, una volta scottati dal fuoco non vi si avvicinano più.

A volte, si tratta solo di difendersi dalla ruggine. Speriamo che Google decida di riprovarci.

Distorsioni in ingresso e in uscita

Un altro grande problema in IA emerge quando si allenano i modelli con dati contenenti un "pregiudizio" intrinseco. Ecco un'analogia per capire meglio. Nelle elezioni presidenziali del 2016, tutti gli aggregatori di sondaggi predicevano la vittoria di Hillary Clinton. Ma i loro modelli, non importa quanto sofisticati, erano fortemente limitati dalla qualità dei dati in ingresso. Il problema era una piccola ma persistente tendenza a sottostimare il sostegno a Donald Trump.

Molti algoritmi in IA presentano un problema simile: distorsioni in ingresso e in uscita. C'è un esempio classico riguardante una rete neurale costruita dall'esercito americano per rilevare carri armati seminascondi al margine di una foresta.²⁴ Gli scienziati militari allenavano i loro modelli usando un insieme di dati fotografici, alcuni contenenti carri armati, altri no. La rete neurale si comportava in modo estremamente accurato, perfino quando un certo numero di dati originali veniva rimosso e utilizzato esclusivamente per testare l'efficacia del modello. (Questa procedura di validazione dei risultati, che fa uso di dati «al di fuori del campione», è standard in IA.)

Ma, quando l'esercito provò a usare il modello per rilevare carri armati veri, non funzionò; il lancio di una moneta sarebbe stato altrettanto efficace. Gli esperti erano perplessi. Cosa poteva giustificare il drastico calo di efficacia? A un certo punto, qualcuno capì che i dati di allenamento contenevano una distorsione intrinseca. Tutte le foto contenenti carri armati erano state scattate in giornate serene. Tutte le foto senza carri armati erano state scattate in giornate nuvolose. Il modello aveva in realtà imparato a

distinguere una foresta con o senza ombre proiettate dagli alberi, qualcosa di totalmente inadatto a rilevare carri armati.

Molte applicazioni imprudenti o non corrette dell'IA falliscono per un motivo simile: distorsioni nascoste nei dati di allenamento. Più dati hai, peggiore può essere il problema. Insieme di dati più grandi non eliminano necessariamente le distorsioni: a volte, enfatizzano quelle già presenti in partenza.

Considera, per esempio, il modo in cui l'intelligenza artificiale è stata usata nel sistema giudiziario. I magistrati che emettono le sentenze cercano sempre di stabilire il danno che un condannato può arrecare alla società. Tradizionalmente, lo hanno sempre fatto in maniera poco scientifica, basandosi sulla propria conoscenza, sull'intuito e sull'esperienza per formulare giudizi sulla personalità e sul dossier dell'imputato. Oggi, tuttavia, tali giudizi iniziano a basarsi sui dati e alcuni giudici si affidano ad algoritmi di machine learning, allenati su dati storici del sistema giudiziario, che stabiliscono la probabilità di recidiva.

Un popolare algoritmo predittivo per le recidive si chiama COMPAS, Correctional Offender Management Profiling for Alternative Sanctions (Profilazione per la gestione correttiva dei trasgressori tramite sanzioni alternative). COMPAS, così come tutti i sistemi di questo tipo, non può «conoscere» l'etnia o il genere dell'accusato: queste informazioni non gli vengono date come input. Ma ciò non basta a prevenire distorsioni: la premessa di base del machine learning è che è possibile apprendere indirettamente le caratteristiche non osservate. Dunque, per testare la neutralità dell'algoritmo, i giornalisti di ProPublica hanno controllato le predizioni per recidiva su 10 000 persone arrestate nella contea di Broward, in Florida, e giudicate da magistrati che hanno fatto uso di COMPAS.²⁵ Hanno selezionato chi è stato poi nuovamente arrestato entro due anni dalla prima condanna e hanno trovato un'evidente disparità etnica. Tra le persone che *non hanno commesso* ulteriori crimini, le persone di colore avevano un tasso di falsi positivi decisamente più elevato: venivano classificate con rischio di recidiva maggiore rispetto alle persone di pelle chiara. Al contrario, tra le persone che *hanno commesso* altri crimini, le persone di pelle chiara avevano un tasso più alto di falsi negativi: venivano erroneamente classificate a basso rischio, e con maggiore frequenza rispetto alle persone di colore.

Com'è stato possibile, se l'algoritmo sottostante era davvero «etnicamente neutro»? Una spiegazione plausibile per tale discrepanza sono *i dati stessi*.

Ricorda che gli algoritmi di IA sono costruiti in modo da trovare e ricercare le regolarità degli insiemi di dati su cui si sono allenati. Se queste regolarità sono intrinsecamente discriminatorie, allora l'algoritmo imparerà a discriminare. Supponi di accettare le ipotesi, avanzate da alcuni accademici, che la polizia arresti in prevalenza persone di colore per un determinato crimine; che i procuratori si dedichino prevalentemente ai casi riguardanti persone di colore; che le giurie siano maggiormente propense a condannare persone di colore; e che le persone di pelle chiara riescano ad avere gli avvocati migliori. Se qualcuna di queste ipotesi è vera, allora è ovvio che i dati riflettano una percentuale di recidiva maggiore tra le persone di colore, per motivi che non hanno nulla a che fare con la propensione soggettiva al crimine. Se il colore della pelle è collegato a una maggiore probabilità di essere arrestati, processati e condannati per un determinato crimine, allora *qualsiasi* algoritmo di predizione di recidive che faccia bene il suo lavoro andrà alla ricerca di indicatori collegati al colore della pelle. E data la lunga e triste storia di discriminazione negli Stati Uniti, tali indicatori sono abbondanti: l'algoritmo potrebbe, per esempio, chiedersi se l'accusato ha qualche familiare in prigione.

Sfortunatamente, non possiamo essere sicuri che questa tipologia di razzismo da indicatori sia responsabile delle distorsioni presenti nelle predizioni di COMPAS per la contea di Broward, in Florida. L'algoritmo è segreto.²⁶ L'azienda che vende il software non svela il suo funzionamento a giudici e accusati, e dunque se l'algoritmo ti classifica ad alto rischio, e se il giudice ti condanna a un periodo più lungo di detenzione, *non puoi neanche chiedere il perché*. Ciò è moralmente ripugnante. Non accettiamo che gli algoritmi per stilare le classifiche delle squadre di football universitarie siano segreti: perché dovremmo accettarlo quando è in gioco la libertà delle persone?

Molte persone, quando vengono a sapere che un algoritmo segreto emette sentenze detentive con evidenti distorsioni basate sul colore della pelle, giungono a una semplice conclusione: l'intelligenza artificiale non dovrebbe giocare alcun ruolo nel sistema giudiziario.

Nonostante siamo altrettanto scioccati e arrabbiati, pensiamo che la conclusione sia errata. Certo, dobbiamo combattere tutte le distorsioni, e per farlo abbiamo bisogno di attenzione costante da parte degli esperti: persone che conoscono l'IA e anche la legge, e che abbiano il potere di agire se intravedono una minaccia per la giustizia. Ma, anche se riconosciamo le

trappole insite nell'uso dell'IA per aiutare i processi decisionali, e anche se accogliamo le richieste di trasparenza e correttezza nel definire i valori alla base di questa nuova era, non dimentichiamo che in tutto questo c'è un potenziale *enorme*. Dopotutto sono le *persone*, piuttosto che gli algoritmi, a essere responsabili del casino nella contea di Broward:

- Coloro che, all'interno del sistema giudiziario, hanno utilizzato un algoritmo per definire sentenze allo stesso modo in cui si usa un forno a microonde, semplicemente inserendo numeri e andando a farsi un giro.
- I legislatori e i tribunali superiori che hanno permesso che tali decisioni venissero prese per mezzo di algoritmi proprietari, il cui funzionamento non può essere interpretato, discusso o esaminato.
- Soprattutto la polizia, i procuratori, i giudici e le giurie che hanno collettivamente agito in modo da codificare una *distorsione basata sul colore della pelle* negli insiemi di dati su cui gli algoritmi si sono allenati.

È di questo ultimo gruppo – di cui facciamo tutti parte – che dobbiamo preoccuparci maggiormente. Se ascolti la storia di COMPAS e giungi alla conclusione che l'IA dovrebbe essere tenuta lontana dalle decisioni importanti, ti facciamo una semplice domanda: ti piace lo stato attuale delle cose? Le decisioni importanti in ambito giudiziario sono *sempre* state prese usando algoritmi pieni di distorsioni, allenati su dati falsati. Solo che questi algoritmi si trovano nella mente delle persone. Non puoi sottoporre le distorsioni di questi “algoritmi cognitivi” a un test numerico, come fai con le regole di predizione in IA. Ma basta semplicemente guardare la lista di criminali nel braccio della morte di Huntsville, in Texas, o esaminare le percentuali di detenuti in rapporto alla popolazione americana in base al colore della pelle – 0,45% per i bianchi, 2,31% per i neri – per vedere il danno che queste distorsioni hanno provocato.²⁷

E non si tratta solo del sistema giudiziario. Ti piacerebbe, per esempio, mettere il tuo futuro nelle mani di queste persone?

- Il manager delle risorse umane che preferisce chiamare per un colloquio lavorativo i candidati con un nome “tradizionalmente da bianchi” piuttosto che con un nome “tradizionalmente da neri”.
- Il capo che assegna valutazioni migliori a impiegati più attraenti.
- Il responsabile delle ammissioni al college che considera gli asiatici più preparati dei bianchi.
- Il direttore finanziario che paga a una donna l'80% del corrispondente salario maschile.

- I membri, fondamentalmente corretti e benintenzionati, di un comitato di selezione che devono esaminare un grande numero di curriculum per un singolo posto di lavoro, e che sono eccessivamente influenzati da un sapiente uso delle font e dall'uso dei verbi all'attivo.

Gli algoritmi decisionali distorti e costruiti male non sono meno pericolosi solo per il fatto di essere eseguiti da piccole cellule grigie anziché da piccoli transistor di silicio. Non vivremo in un mondo migliore se le persone danneggiate da pregiudizi provenienti da esseri umani potessero ottenere una seconda possibilità dall'IA, un algoritmo il cui funzionamento e le cui distorsioni siano alla portata di tutti, e possano quindi essere corretti?

Post scriptum

Immagina di poter tornare agli anni novanta, quando hai scaricato il primo browser web, o agli anni duemila, quando hai comprato il primo smartphone e aperto gli account su Facebook e Twitter. Alla luce di quello che hai imparato da allora, che consiglio daresti a te stesso sulle informazioni da condividere, sulle foto da pubblicare e sugli interessi da coltivare? E se potessi parlare a proprietari di aziende e personalità di governo, cosa vorresti dir loro? Quali storie racconteresti a proposito di come le nuove tecnologie ti hanno cambiato la vita in meglio? Quali patologie chiederesti loro di prevenire?

L'intelligenza artificiale giocherà presto un ruolo in decisioni ben più importanti rispetto ai film da vedere su Netflix, alla musica da ascoltare su Spotify o alle news da suggerire su Facebook. Consiglieranno le terapie per i pazienti, i lavori o i college per cui fare domanda, i prestiti a cui si può avere accesso e anche le condanne che si riceveranno in corrispondenza di un determinato crimine. Nel pensare a questi temi complessi, non possiamo fare affidamento su una macchina del tempo. Siamo soli e *dobbiamo fare in modo che le cose funzionino*. C'è molto da guadagnare ma anche molto da perdere, e l'equilibrio tra costi e benefici sarà influenzato significativamente dal fatto che le persone con potere decisionale capiscano o meno come funziona l'IA. Se agiamo in modo approssimativo – o, peggio ancora, lasciamo che le aziende tecnologiche vadano imperterrite per la loro strada mentre noi perdiamo tempo dietro ai nostri incubi fantascientifici – uccideremo la credibilità dei sistemi di IA prima ancora di dar loro la possibilità di maturare, e priveremo l'umanità di un potenziale enorme.

Ma immagina un mondo in cui gestiamo i nostri sforzi in modo intelligente, un mondo in cui mettiamo al lavoro gli esperti, escogitiamo le giuste protezioni legali e siamo eternamente vigili sulle distorsioni e le ipotesi dei nostri algoritmi. In quel mondo, i nostri protocolli decisionali potrebbero diventare *radicalmente* migliori di quelli odierni crivellati di distorsioni, che danno una spintarella alle persone più carine o dai modi spigliati o con il papà più ricco o la pelle chiara. La nostra visione collettiva e la nostra tecnologia hanno raggiunto un punto in cui possiamo insegnare alle macchine a guidarsi da sole, predire una malattia renale e fare conversazione. Possiamo certamente insegnare loro a comportarsi bene. Anzi, potrebbero insegnarlo loro a noi.

Tutti sono concordi nel ritenere che alcuni aspetti sono troppo importanti per essere esaminati da un algoritmo che agisce da solo e non deve rispondere a nessuno. Alcuni di noi fanno anche un passo ulteriore e sostengono la stessa tesi riguardo alle persone. Quando ci sono decisioni importanti da prendere, possiamo e dovremmo combinare l'intelligenza artificiale con i valori e le intuizioni umane. Basta che le macchine e gli esseri umani lavorino insieme.

***a** Una precisazione importante: il doppio di un numero piccolo è comunque un numero piccolo. L'incidenza del tumore esofageo tra i sessanta e i settantanove anni è di un caso su mille in cinque anni. Green *et al.* stimano che questo numero aumenti fino a due su mille nel caso di uso di bisfosfonati.

***b** Stiamo analizzando i dati di tre stagioni per avere un campione più grande ed evitare di selezionare solo la statistica favorevole dei match della stagione dei record, che gonfierebbe artificialmente la sua reale probabilità per singola partita.

***c** Con «uso tipico» non si intende «uso corretto». Se usi la pillola esattamente come prescritto, la percentuale di fallimento è molto più bassa, meno dell'1% su un anno.

***d** Per esempio, @hricciot: «Scioccante, anche per un ginecologo come me! #LARCisBest». LARC sta per *long-acting reversible contraception* (contraccettivo reversibile di lungo termine), per esempio, una spirale intrauterina.

RINGRAZIAMENTI

Vogliamo ringraziare le due persone che si sono prese maggiore cura di questo libro fin dalle fasi iniziali: Lisa Gallagher della DeFiore & Company e Tim Bartlett della St Martin's Press. Questo è per entrambi il primo lavoro non rivolto ad accademici, e non avevamo alcuna idea di cosa volesse dire scrivere e pubblicare un libro «vero». Siamo molto grati a Lisa per aver intravisto del potenziale nei nostri primi appunti scarabocchiati, che ora ci sembrano incredibilmente goffi. Siamo ugualmente grati a Tim, sia per aver scommesso su due scienziati sufficientemente temerari da buttarsi nella scrittura, sia per i suoi efficaci consigli lungo il percorso. Siamo anche debitori nei confronti di Doug Young della Transworld per i suoi utili suggerimenti editoriali.

Ringraziamo anche le molte persone di DeFiore, St Martin's Press e Macmillan che sono state di grande aiuto, inclusi Robert Allen, Alan Bradshaw, Jeff Capshew, Laura Clark, Jennifer Enderlin, Tracey Guest, Leah Johanson, Linda Kaplan, Alice Pfeifer, Gabrielle Piraino, Jason Prince, Sally Richardson, Brisa Robinson, Mary Beth Roche, Robert Van Kolken, Laura Wilson e George Witte. Ringraziamo in modo particolare India Cooper, le cui magnifiche competenze editoriali hanno messo in particolare evidenza le differenze tra uno scrittore professionista e due scrittori amatoriali come noi. Grazie anche a Larry Finlay, Bill Scott-Kerr e il resto del team della Transworld per il loro aiuto.

Grazie a Ellen Zippi per il prezioso lavoro di ricerca. Siamo anche grati a molti nostri colleghi per aver condiviso racconti ed esperienze, in particolare Steven Levitt per averci presentato a Lisa Gallagher, e David Madigan per aver attirato la nostra attenzione sui due studi sul bisfosfonato descritti nel capitolo 7. Grazie a Rosalind Eggo, Katherine Heller e Mark Sendak per il loro tempo e per aver acconsentito a essere intervistati. Grazie agli infaticabili membri delle nostre famiglie per aver letto le versioni iniziali e averci dato numerosi feedback: Catherine Aiken, Patricia e Josh Lowry, Anne e George Scott e Brian Woods.

Ringraziamenti personali

Sono grato al mio coautore, James Scott. Ringrazio in particolare la mia famiglia per l'amore e il supporto: mia moglie Anne Gron e i nostri bambini Emma, Michael e Sarah.

Nick Polson

Grazie a Nick Polson. Sono debitore nei confronti di Nick di molta parte della mia carriera, e non è possibile qui elencare tutto; questo libro è solo l'ultimo di una lunga serie di progetti e idee che ha voluto generosamente condividere con me. Nei decenni a venire, quando mi volterò indietro sono certo che considererò Nick la persona più influente nella mia vita professionale e il migliore amico che io abbia nel campo. Voglio anche ringraziare i tre insegnanti più importanti che abbia mai avuto: Bill Jeffreys, Jim Berger e John Trimble. Senza Bill e Jim, non sarei mai diventato uno statistico. Senza la gentilezza e la generosità di John, non avrei mai saputo come «intensificare/affinare/illuminare» la mia prosa. Ringrazio anche i miei genitori, che mi hanno dato così tanto, non ultimo il loro esempio. Infine, ringrazio mia moglie, Abigail Aiken, praticamente per tutto. Ti amo, e non sarei riuscito a scrivere questo libro senza il tuo supporto.

James Scott

Note

IL RIFUGIATO

- 1.** Citazione di Kevin Spacey durante la James MacTaggart Memorial Lecture all'Edinburgh Fringe Festival, nel 2013. Video disponibile su YouTube all'indirizzo [\[https://www.youtube.com/watch?v=oheDqofa5NM\]](https://www.youtube.com/watch?v=oheDqofa5NM).
- 2.** N. Hass, *And the Award for the Next HBO Goes to...*, in "GQ", 29 gennaio 2013, disponibile all'indirizzo <https://www.gq.com/story/netflix-founder-reed-hastings-house-of-cards-arrested-development>.
- 3.** Numeri presi da US Census Bureau, *Statistical Abstract of the United States*, USGPO, Washington (DC) 1944, 1947, 1950; e da Army Air Forces, *Statistical Digest (World War II)*, disponibile all'indirizzo <https://archive.org/details/ArmyAirForcesStatisticalDigestWorldWarII>.
- 4.** Il materiale sulla vita di Abraham Wald deriva dalle seguenti fonti: W. Allen Wallis, *The Statistical Research Group, 1942-1945*, in "Journal of the American Statistical Association", 75(1980), n. 370, pp. 320-330; M. Mangel, F.J. Samaniego, *Abraham Wald's Work on Aircraft Survivability*, in "Journal of the American Statistical Association", 79(1984), n. 386, pp. 259-267, e nella stessa rivista si veda anche *Rejoinder* degli stessi autori (pp. 270-271) e *Comment* di J.O. Berger (pp. 267-269); J. Wolfowitz, *Abraham Wald, 1902-1950*, in "Annals of Mathematical Statistics", 23(1952), n. 1, pp. 1-13; O. Morgenstern, *Abraham Wald, 1902-1950*, in "Econometrica", 19(1951), n. 4, pp. 361-367; K. Menger, *The Formative Years of Abraham Wald and His Work in Geometry*, in "Annals of Mathematical Statistics", 23(1952), n. 1, pp. 14-20; L. Weiss, "Wald, Abraham", in N.L. Johnson, S. Kotz (a cura di), *Leading Personalities in Statistical Sciences: From the Seventeenth Century to the Present*, John Wiley & Sons, New York 1997, pp. 164-167; MacTutor History of Mathematics Archive, *Abraham Wald*, disponibile all'indirizzo <http://www-history.mcs.st-andrews.ac.uk/Biographies/Wald.html>.
- 5.** W. Allen Wallis, *op. cit.*
- 6.** La nostra presentazione del metodo di Wald fa uso di notazione e termini moderni, ed è dunque intenzionalmente anacronistica. Wald non affrontò il problema esattamente in questi termini. Abbiamo anche tralasciato molti dettagli tecnici. Invitiamo il lettore interessato a consultare: M. Mangel, F.J. Samaniego, *Abraham Wald's Work on Aircraft Survivability*, cit.; Id., *Rejoinder*, cit.; e J.O. Berger, *Comment*, cit.
- 7.** W. Allen Wallis, *The Statistical Research Group, 1942-1945*, cit.; M. Mangel, F.J. Samaniego, *Rejoinder*, cit.
- 8.** Disponibile all'indirizzo https://www.netflixprize.com/community/topic_1537.html.
- 9.** D. Keating, K. Schaul, L. Shapiro, *The Facebook Ads Russians Targeted at Different Groups*, in "Washington Post", 1° novembre 2017, disponibile all'indirizzo <https://www.washingtonpost.com/graphics/2017/business/russian-ads-facebook-targeting/>.
- 10.** National Cancer Institute, *Study Shows Promise of Precision Medicine for Most Common Type of Lymphoma*, 20 luglio 2015, disponibile all'indirizzo <https://www.cancer.gov/news->

[events/press-releases/2015/ibrutinib-lymphoma-subtype.](#)

11. Wilfred Owen, *Dulce et decorum est*, da *Poesie di guerra*, traduzione e cura di Sergio Rufini, Einaudi 1985.

LA FABBRICANTE DI CANDELIERI

1. I. Hafez, *Abd al-Rahman al-Sufi and His Book of the Fixed Stars: A Journey of Rediscovery*, tesi di dottorato, James Cook University, 2010.

2. M. Bartusiak, *The Day We Found the Universe*, Vintage Books, New York 2010, p. 52.

3. Citazione di Agnes Clerke, *The System of the Stars* (1890), in *ivi*, p. 53.

4. K.C. Freeman, “*Slipher and the Nature of the Nebulae*”, in M. Way, D. Hunter (a cura di), *Origins of the Expanding Universe: 1912-1932*, Astronomical Society of the Pacific, San Francisco 2013 (Astronomical Society of the Pacific Conference Series, n. 471), pp. 63-70, disponibile all’indirizzo <http://arxiv.org/abs/1301.7509>.

5. Le nostre due fonti principali su Henrietta Leavitt sono: N. Byers, G. Williams, *Out of the Shadows: Contributions of Twentieth-Century Women to Physics*, Cambridge University Press, Cambridge 2006; e M. Bartusiak, *op. cit.*

6. In realtà Shapley stimò che la Via Lattea si estendesse per 300 000 anni luce. Stime successive riportano un valore di 100 000 anni luce.

7. Citato in M. Bartusiak, *op. cit.*, p. 218.

8. C. Moskowitz, *Star That Changed the Universe Shines in Hubble Photo*, in “Space.com”, 23 maggio 2011, disponibile all’indirizzo <https://www.space.com/11761-historic-star-variable-hubble-telescope-photo-aas218.html>.

9. C’è una disputa a proposito del metodo dei minimi quadrati. Gauss, il grande matematico tedesco, dovrebbe averlo scoperto per primo, ma Legendre lo ha pubblicato per primo. I lettori interessati alla questione dovrebbero consultare S.M. Stigler, *Gauss and the Invention of Least Squares*, in “Annals of Statistics”, 9(1981), n. 3, pp. 465-474.

10. *John Deere Green*, scritto da Dennis Linde, eseguito da Joe Diffie.

11. J. Mannes, *This Beekeeper Is Rescuing Honeybees with Deep Learning and an iPhone*, in “TechCrunch”, 2 maggio 2017, disponibile all’indirizzo <https://techcrunch.com/2017/05/02/beekeepers/>.

12. A. Brokaw, *This Startup Uses Machine Learning and Satellite Imagery to Predict Crop Yields*, in “The Verge”, 4 agosto 2016, disponibile all’indirizzo <https://www.theverge.com/2016/8/4/12369494/cartes-artificial-intelligence-crop-predictions-usda>.

13. S. Shead, *Google’s DeepMind Wants to Cut 10% Off the Entire UK’s Energy Bill*, in “Business Insider”, 13 marzo 2017, disponibile all’indirizzo <http://www.businessinsider.com/google-deepmind-wants-to-cut-ten-percent-off-entire-uk-energy-bill-using-artificial-intelligence-2017-3>.

14. *The Women Missing from the Silver Screen and the Technology Used to Find Them*, in “Google.com”, disponibile all’indirizzo <https://www.google.com/intl/en/about/main/gender-equality-films/>.

IL REVERENDO E IL SOTTOMARINO

1. Statistiche prese dall'Insurance Institute for Highway Safety, disponibili all'indirizzo http://www.iihs.org/auto/teens/Teen_Driving_Statistics.asp.
2. Claude E. Shannon: *A Goliath Amongst Giants*, disponibile all'indirizzo <https://www.bell-labs.com/claude-shannon/>.
3. L. Earnest, *Stanford Cart*, dicembre 2012, disponibile all'indirizzo <https://web.stanford.edu/~learnest/cart.htm>.
4. T. Ong, *Dubai Starts Testing Crewless Two-Person "Flying Taxis"*, in "The Verge", 26 settembre 2017, disponibile all'indirizzo <https://www.theverge.com/2017/9/26/16365614/dubai-testing-uncrewed-two-person-flying-taxis-voicopter>; T. Simonite, *Mining 24 Hours a Day with Robots*, in "MIT Technology Review", dicembre 2016, disponibile all'indirizzo <https://www.technologyreview.com/s/603170/mining-24-hours-a-day-with-robots/>; *Asia's First Automated Container Terminal, at Port of Qingdao, China*, live report di New China TV, 11 maggio 2017, disponibile all'indirizzo <https://www.youtube.com/watch?v=bn2GPNJmR7A>.
5. P. Henderson, *US Judge Deals Setback to Waymo Damage Claim in Uber Lawsuit*, in "Reuters", 3 novembre 2017, disponibile all'indirizzo <https://www.reuters.com/article/us-alphabet-uber-lawsuit/u-s-judge-deals-setback-to-waymo-damage-claim-in-uber-lawsuit-idUSKBN1D32J0>.
6. W. Beecher, *Vast Search Fails to Find Submarine*, in "New York Times", 29 maggio 1968.
7. "The President's News Conference of May 28, 1968", in *Public Papers of the Presidents of the United States: Lyndon B. Johnson, 1968-1969*, USGPO, Washington (DC) 1970, p. 656.
8. Questo e altri dettagli sull'incidente di Palomares sono tratti da S.B. McGrayne, *The Theory That Would Not Die*, Yale University Press, New Haven 2011, pp. 182-194.
9. Ivi, pp. 192-194.
10. *Nova. Submarines, Secrets, and Spies*, documentario PBS trasmesso il 19 gennaio 1999, disponibile all'indirizzo <https://www.youtube.com/watch?v=RvJTAMQQQUY>.
11. S.B. McGrayne, *op. cit.*, p. 202.
12. *Nova. Submarines, Secrets, and Spies*, cit.
13. S.B. McGrayne, *op. cit.*, p. 202.
14. D.M. Eddy, "Probabilistic Reasoning in Clinical Medicine: Problems and Opportunities", in D. Kahneman, P. Slovic, A. Tversky (a cura di), *Judgment Under Uncertainty: Heuristics and Biases*, Cambridge University Press, Cambridge 1982, pp. 249-267.
15. In realtà si tratta di novantanove falsi positivi, ma arrotondiamo a 100 per mantenere semplici i numeri. Se correggi il nostro piccolo errore di arrotondamento, la vera probabilità a posteriori $P(\text{tumore} \mid \text{test positivo})$ è 7,5%, non 7,4%.
16. M. Marriage, *86% of Active Equity Funds Underperform*, in "Financial Times", 20 marzo 2016, disponibile all'indirizzo <https://www.ft.com/content/e555d83a-ed28-11e5-888e-2eadd5fbc4a4>.
17. Vedi riquadro a p. 135.
18. L.D. Stone, *The Theory of Optimal Search*, Academic Press, New York 1975.
19. L.D. Stone et al., *Search for the Wreckage of Air France Flight AF 447*, in "Statistical Science", 29(2014), n. 1, pp. 69-80.
20. *Breakthrough: Robotic Limbs Moved by the Mind, 60 Minutes*, servizio trasmesso da CBS News il 30 dicembre 2012, disponibile all'indirizzo <https://www.cbsnews.com/news/breakthrough-robotic-limbs-moved-by-the-mind-30-12-2012/>.

AMAZING GRACE

- 1.** A. Bartoli *et al.*, “Your Paper Has Been Accepted, Rejected, or Whatever: Automatic Generation of Scientific Paper Reviews”, in F. Buccafurri *et al.* (a cura di), *Availability, Reliability, and Security in Information Systems*, Springer, Heidelberg 2016, pp. 19-28.
- 2.** A. Pandy, 18 gennaio 2016, disponibile all’indirizzo <https://twitter.com/Pandy/status/689209034143084547>.
- 3.** Un dettaglio tecnico: per i nostri scopi, non c’è necessità di distinguere tra “compilatore” (per un linguaggio come C++ o Java) e “interprete” (per un linguaggio come Python). Usiamo il termine “compilatore” per riferirci a entrambi i casi.
- 4.** K. Broome Williams, *Grace Hopper: Admiral of the Cyber Sea*, Naval Institute Press, Annapolis 2004, p. 1.
- 5.** Ivi, p. 2.
- 6.** Ivi, p. 11.
- 7.** Ivi, pp. 18-20.
- 8.** Ivi, p. 22.
- 9.** Ivi, p. 26.
- 10.** Ivi, p. 29.
- 11.** Ivi, pp. 27-28.
- 12.** Ivi, p. 82.
- 13.** K.W. Beyer, *Grace Hopper and the Invention of the Information Age*, The MIT Press, Cambridge (Massachusetts) 2009, p. 53.
- 14.** D. Hofstadter, *Gödel, Escher, Bach: An Eternal Golden Braid*, Vintage Books, New York 1980, p. 290.
- 15.** K. Broome Williams, *op. cit.*, p. 70.
- 16.** Ivi, p. 80.
- 17.** Ivi, p. 85.
- 18.** Ivi, p. 86.
- 19.** *Ibid.*
- 20.** Si veda ivi, p. 87. Riferimento originale: R.L. Wexelblat (a cura di), *History of Programming Languages I*, ACM, New York 1978, p. 17.
- 21.** B.T. Lowerre, *The HARP Speech Recognition System*, tesi di dottorato, Department of Computer Science, Carnegie Mellon University, 1976.
- 22.** *10 Inexplicable Google Translate Fails*, disponibile all’indirizzo <https://www.searchenginepeople.com/blog/10-google-translate-fails.html>.
- 23.** Per dettagli sul metodo e calcoli accurati, si veda Y. Wu *et al.*, *Google’s Neural Machine Translation System: Bridging the Gap Between Human and Machine Translation*, 8 ottobre 2016, disponibile all’indirizzo <https://arxiv.org/abs/1609.08144>.
- 24.** P. Norvig, *On Chomsky and the Two Cultures of Statistical Learning*, disponibile all’indirizzo <http://norvig.com/chomsky.html>.
- 25.** Se vuoi davvero leggere i dettagli, queste “parole di prova” sono in realtà chiamate “vettori contesto”. Si veda T. Mikolov *et al.*, *Distributed Representations of Words and Phrases and Their Compositionality*, in “Advances in Neural Information Processing Systems”, 27(2013),

disponibile all'indirizzo <https://papers.nips.cc/paper/5021-distributed-representations-of-words-and-phrases-and-their-compositionality>.

26. T. Mikolov, W. Yih, G. Zweig, "Linguistic Regularities in Continuous Space Word Representations", in *Proceedings of NAACL-HLT, 2013*, Association for Computational Linguistics, Stroudsburg (Pennsylvania), pp. 746-751.

IL GENIO DELLA ZECCA REALE

1. Ricordiamo distintamente di aver sentito questo commento durante uno spettacolo televisivo all'inizio del caso, ma non siamo stati in grado di trovare una trascrizione online dello show. Chiediamo scusa al sagace anonimo commentatore.

2. S. Quinn, *Gold, Silver and the Glorious Revolution: Arbitrage Between Bills of Exchange and Bullion*, in "The Economic History Review", 49(1996), n. 3, pp. 479-490.

3. T. Levenson, *Newton and the Counterfeiter*, Mariner Books, Boston 2010, pp. 626-663.

4. J. Craig, *Newton at the Mint*, Cambridge University Press, Cambridge 1946, pp. 6-7.

5. L. Ming-Hsun, *The Great Recoinage of 1696 to 1699*, Weidenfeld & Nicolson, London 1963, p. 47.

6. T. Levenson, *op. cit.*, pp. 137-138.

7. T. Babington Macaulay, *The History of England from the Accession of James II*, Harper & Brothers, New York 1856, vol. I, p. 187.

8. Dettagli del procedimento utilizzato durante la prova della pisside si trovano in: S.M. Stigler, *Statistics on the Table*, Harvard University Press, Cambridge (Massachusetts) 1999, pp. 386-389.

9. Ivi, pp. 389-390.

10. J. Craig, *The Mint: A History of the London Mint from AD 287 to 1948*, Cambridge University Press, Cambridge 2011, p. 212.

11. Ivi, p.104.

12. S.M. Stigler, *Statistics on the Table*, cit., p. 391.

13. J. Craig, *Newton at the Mint*, cit., pp. 12-14.

14. T. Levenson, *op. cit.*, pp. 139-141.

15. Ivi, pp. 141-144.

16. La grande coniazione è considerata una politica monetaria fallimentare dagli storici dell'economia. Il punto che vogliamo sottolineare è che si trattò di una rilevante impresa industriale, senza entrare nel merito degli effetti sull'economia.

17. J. Craig, *Newton at the Mint*, cit., pp. 48-49.

18. Ivi, p. 23.

19. D.A. Schweidel, *Profiting from the Data Economy: Understanding the Roles of Consumers, Innovators and Regulators in a Data-Driven World*, Pearson FT Press, Upper Saddle River (New Jersey) 2014, p. 81.

20. Ivi, p. 82; Accenture White Paper, *City of New York: Using Data Analytics to Achieve Greater Efficiency and Cost Savings*, 2013, disponibile all'indirizzo https://www.accenture.com/t20150624T211456Z_w_us-en/acnmedia/Accenture/Conversion-Assets/DotCom/Documents/Global/PDF/Technology_7/Accenture-Data-Analytics-Helps-New-York-City-Boost-Efficiency-Spend-Wisely.pdf.

21. P. McGeehan, R. Buettner, D.W. Chen, *Beneath Cities, a Decaying Tangle of Gas Pipes*, in "New York Times", 23 marzo 2014.

- 22.** Federal Reserve Payments Study, 2016, disponibile all'indirizzo <https://www.federalreserve.gov/paymentsystems/2016-payment-study.htm>.
- 23.** M. Morisy, *How PayPal Boosts Security with Artificial Intelligence*, in "MIT Technology Review", 25 gennaio 2016, disponibile all'indirizzo <https://www.technologyreview.com/s/545631/how-paypal-boosts-security-with-artificial-intelligence/>.
- 24.** *Brooklyn Nets' Jeremy Lin on New Partnership*, intervista televisiva su *Squawk Box*, CNBC, 8 febbraio 2017, disponibile all'indirizzo <http://video.cnb.com/gallery/?video=3000591640>.
- 25.** J. Ham, *Kings Add New Stat Guru Luke Bornn to Front Office*, NBC Sports, 20 aprile 2017, disponibile all'indirizzo <http://www.csnbayarea.com/kings/kings-add-new-stat-guru-luke-bornn-front-office>.
- 26.** A. Franks *et al.*, *Counterpoints: Advanced Defensive Metrics for NBA Basketball*, contributo presentato alla 9a conferenza annuale "MIT Sloan Sports Analytics", 2015, disponibile all'indirizzo http://www.lukebornn.com/papers/franks_ssac_2015.pdf.
- 27.** *Brooklyn Nets' Jeremy Lin on New Partnership*, cit.

LA DAMA CON LA LANTERNA

- 1.** G. Glaser, *Unfortunately, Doctors Are Pretty Good at Suicide*, in "Journal of Medicine", 15 agosto 2015, disponibile all'indirizzo <https://www.ncnp.org/journal-of-medicine/1601-unfortunately-doctors-are-pretty-good-at-suicide.html>.
- 2.** M. Bostridge, *Florence Nightingale: The Making of an Icon*, Farrar, Straus & Giroux, New York 2008, pp. 56-60.
- 3.** Ivi, p. 35.
- 4.** Ivi, pp. 31-35.
- 5.** Ivi, pp. 68-70.
- 6.** Ivi, pp. 47-50.
- 7.** Ivi, p. 105.
- 8.** Ivi, p. 157.
- 9.** Introduzione a L. McDonald (a cura di), *The Collected Works of Florence Nightingale*, Wilfrid Laurier University Press, Waterloo (Ontario) 2010, vol. XIV, *The Crimean War*, p. 9.
- 10.** M. Bostridge, *op. cit.*, p. 248.
- 11.** Ivi, pp. 219-220.
- 12.** Ivi, p. 203.
- 13.** Ivi, pp. 220, 225-229.
- 14.** Ivi, p. 229.
- 15.** *Ibid.*
- 16.** Lettera del 7 agosto 1855, in L. McDonald (a cura di), *The Collected Works of Florence Nightingale*, cit., vol. XIV, *The Crimean War*, p. 204.
- 17.** M. Bostridge, *op. cit.*, p. 237.
- 18.** L. McDonald, *Florence Nightingale and Her Crimean War Statistics: Lessons for Hospital Safety, Public Administration and Nursing*, trascrizione di una presentazione al Gresham College, 30 ottobre 2014, disponibile all'indirizzo <https://www.gresham.ac.uk/lectures-and-events/florence-nightingale-and-her-crimean-war-statistics-lessons-for-hospital-safety->

- 19.** M. Bostridge, *op. cit.*, p. 248.
- 20.** Ivi, p. 226.
- 21.** Ivi, p. 229.
- 22.** “*The Times*”, 8 febbraio 1855, citato in E.T. Cook, *The Life of Florence Nightingale*, 2 voll., Macmillan, London 1913, vol. I, pp. 236-237, disponibile all’indirizzo <https://archive.org/details/lifeofflorenceni01cookuoft>.
- 23.** M. Bostridge, *op. cit.*, pp. 260-262.
- 24.** Ivi, p. 321.
- 25.** E.H. Sieveking, *Training Institutions for Nurses*, in “*Englishwoman’s Magazine*”, 7(1852), p. 294, da A. Summers, *The Mysterious Demise of Sarah Gamp: The Domiciliary Nurse and Her Detractors*, in “*Victorian Studies*”, 32(1989), n. 3, p. 365.
- 26.** E.W. Kopf, *Florence Nightingale as Statistician*, in “*Journal of the American Statistical Association*”, 15(1916), n. 116, p. 390.
- 27.** Lettera di John Hall al dottor Andrew Smith, 6 aprile 1856. La lettera fu venduta all’asta nel 2007; una trascrizione è disponibile all’indirizzo <https://www.bonhams.com/auctions/15231/lot/26/>.
- 28.** F. Nightingale, “Notes on the Health of the British Army,” in L. McDonald (a cura di), *The Collected Works of Florence Nightingale, cit.*, vol. XIV, *The Crimean War*, p. 864.
- 29.** E.W. Kopf, *op. cit.*, p. 390.
- 30.** *Ibid.*
- 31.** M. Bostridge, *op. cit.*, p. 345.
- 32.** Ivi, pp. 335-339.
- 33.** F. Nightingale, “Notes on the Health of the British Army”, *cit.*, pp. 854-855.
- 34.** E.W. Kopf, *op. cit.*, p. 394.
- 35.** F. Nightingale, “Notes on Hospitals”, in L. McDonald (a cura di), *The Collected Works of Florence Nightingale, cit.*, vol. XVI, *Florence Nightingale and Hospital Reform*, p. 215.
- 36.** E.W. Kopf, *op. cit.*, p. 397.
- 37.** J. Keith, *Florence Nightingale: Statistician and Consultant Epidemiologist*, in “*International Nursing Review*”, 35(1988), n. 5, pp. 147-150.
- 38.** J. Beyersmann, C. Schrade, *Florence Nightingale, William Farr and Competing Risks*, in “*Journal of the Royal Statistical Society*”, Series A (Statistics in Society), 180(2017), n. 1, pp. 285-293.
- 39.** Molte analisi della funzionalità renale di Joe riguardavano i livelli di creatina serica, piuttosto che il GFR. Tutte le misure sono state convertite in GFR per facilità di visualizzazione. J. Futoma *et al.*, “Scalable Joint Modeling of Longitudinal and Point Process Data for Disease Trajectory Prediction and Improving Management of Chronic Kidney Disease”, in A. Ihler, D. Janzig (a cura di), *Proceedings of the 32nd Conference on Uncertainty in Artificial Intelligence*, AUA Press, Corvallis (Oregon) 2016, pp. 222-231.
- 40.** Nessun dato riservato è stato sfruttato per realizzare questo grafico. I dati sono stati simulati in modo da somigliare a quelli del paziente reale. Per un grafico basato su dati reali, si veda J. Futoma *et al.*, *op. cit.*, p. 223.
- 41.** K.C. Oeffinger *et al.*, *Breast Cancer Screening for Women at Average Risk: 2015 Guideline Update from the American Cancer Society*, in “*Journal of the American Medical Association*”, 314(2015), n. 15, pp. 1599-1614.

- 42.** Lettera a William Farr, 14 settembre 1859, in L. McDonald (a cura di), *The Collected Works of Florence Nightingale*, cit., vol. V, *Florence Nightingale on Society and Politics, Philosophy, Science, Education and Literature*, p. 76.
- 43.** J. Futoma et al., op. cit.
- 44.** J. Balog et al., *Intraoperative Tissue Identification Using Rapid Evaporative Ionization Mass Spectrometry*, in “Science Translational Medicine”, 5(2013), n. 194, pp. 194ra93; “Intelligent Knife” Tells Surgeon If Tissue Is Cancerous, Imperial College London press release, 17 luglio 2013, disponibile all’indirizzo http://www3.imperial.ac.uk/newsandeventspggrp/imperialcollege/newssummary/news_17-7-2013-17-17-32.
- 45.** *MiniMed 670G System Launches in the United States*, Medtronic Meaningful Information blog, 7 giugno 2017, disponibile all’indirizzo <https://www.medtronicdiabetes.com/blog/fda-approves-minimed-670g-system-worlds-first-hybrid-closed-loop-system/>.
- 46.** P.J. Schüffler et al., “Semi-automatic Crohn’s Disease Severity Estimation on MR Imaging”, in H. Yoshida, J. Näppi, S. Saini (a cura di), *Abdominal Imaging: Computational and Clinical Applications*, Springer-Cham, Heidelberg-New York 2014, pp. 128-139.
- 47.** T.J. Fuchs, J.M. Buhmann, *Computational Pathology: Challenges and Promises for Tissue Analysis*, in “Computerized Medical Imaging and Graphics”, 2011, vol. XXXV, nn. 7-8, pp. 515-530.
- 48.** V. Gulshan et al., *Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs*, in “Journal of the American Medical Association”, 316(2016), n. 22, pp. 2402-2410. La collaborazione con il Moorfields Eye Hospital è descritta in un comunicato stampa disponibile all’indirizzo <http://www.moorfields.nhs.uk/news/moorfields-announces-research-partnership>.
- 49.** J. Mc Hugh, *Man, Machine and Medicine: Mass General Researchers Using AI*, in “Nvidia blog”, 7 dicembre 2016, disponibile all’indirizzo <https://blogs.nvidia.com/blog/2016/12/07/mass-general-researchers-ai/>. Si veda anche L. Bell, *Nvidia to Train 100,000 Developers in “Deep Learning” AI to Bolster Healthcare Research*, in “Forbes.com”, 11 maggio 2017, disponibile all’indirizzo <https://www.forbes.com/sites/leebelltech/2017/05/11/nvidia-to-train-100000-developers-in-deep-learning-ai-to-bolster-health-care-research/>.
- 50.** Si veda, per esempio, T. Simonite, *The Recipe for the Perfect Robot Surgeon*, in “MIT Technology Review”, 14 ottobre 2016, disponibile all’indirizzo <https://www.technologyreview.com/s/602595/the-recipe-for-the-perfect-robot-surgeon/>.
- 51.** D. Szondy, *IBM’s Watson Adapted to Teach Medical Students and Aid Diagnosis*, in “New Atlas”, 21 ottobre 2013, disponibile all’indirizzo <http://newatlas.com/ibm-supercomputer/watsonpath/29415/>.

IL CLIPPER DEGLI YANKEES

- 1.** C. Anderson, *The End of Theory: The Data Deluge Makes the Scientific Method Obsolete*, in “Wired”, 23 giugno 2008, disponibile all’indirizzo <https://www.wired.com/2008/06/pb-theory/>.
- 2.** C.R. Cardwell et al., *Exposure to Oral Bisphosphonates and Risk of Esophageal Cancer*, in “JAMA”, 304(2010), n. 6, pp. 657-663.
- 3.** J. Green et al., *Oral Bisphosphonates and Risk of Cancer of Oesophagus, Stomach, and Colorectum: Case-Control Analysis Within a UK Primary Care Cohort*, in “British Medical Journal”, 341(2010), n. 7772, p. 545.

4. S.J. Gould, *The Streak of Streaks*, in “New York Review of Books”, 18 agosto 1988, disponibile all’indirizzo <http://www.nybooks.com/articles/1988/08/18/the-streak-of-streaks/>.
5. B. Green, J. Zweibel, *The Hot-Hand Fallacy: Cognitive Mistakes or Equilibrium Adjustments? Evidence from Major League Baseball*, contributo presentato alla conferenza “MIT Sloan Sports Analytics”, marzo 2016, disponibile all’indirizzo <http://www.sloansportsconference.com/wp-content/uploads/2016/02/1422-Baseball.pdf>.
6. Grazie a Peter Norvig di Google per questa storia. Gliel’abbiamo sentita raccontare nel corso di una visita all’Università del Texas a Austin nel 2011; è anche narrata in *On Chomsky and the Two Cultures of Statistical Learning*, disponibile all’indirizzo <http://norvig.com/chomsky.html>.
7. Di solito attribuito allo statistico George Box.
8. Si veda, per esempio, E. Beltrami, J. Mendelsohn, *More Thoughts on DiMaggio’s 56-Game Hitting Streak*, in “Baseball Research Journal”, 39(2010), n. 1, disponibile all’indirizzo <https://sabr.org/research/more-thoughts-dimaggio-s-56-game-hitting-streak>.
9. K. Daniels, W.D. Mosher, J. Jones, *Contraceptive Methods Women Have Ever Used: United States, 1982-2010*, in “National Health Statistics Reports”, n. 62, 14 febbraio 2013, disponibile all’indirizzo <http://www.cdc.gov/nchs/data/nhsr/nhsr062.pdf>.
10. Si veda, per esempio, *Contraceptive Use in the United States*, Guttmacher Institute Fact Sheet, settembre 2016, disponibile all’indirizzo <https://www.guttmacher.org/fact-sheet/contraceptive-use-united-states>.
11. G. Aisch, B. Marsh, *How Likely Is It That Birth Control Could Let You Down?*, in “New York Times. Sunday Review section”, 13 settembre 2014.
12. J. Trussell, *Contraceptive Failure in the United States*, in “Contraception”, 83(2011), n. 5, pp. 397-404.
13. L’unica eccezione è la sterilizzazione femminile, per cui esistono dati a lungo termine.
14. Questo standard è stato ampiamente adottato in letteratura da quando fu proposto da Trussell e Kost negli anni ottanta in: *Contraceptive Failure in the United States: A Critical Review of the Literature*, in “Studies in Family Planning”, 18(1987), n. 5, pp. 237-283.
15. G. Flaubert, *Correspondance*, Louis Conard, Paris 1929, p. 111 [trad. it. *Corrispondenza*, Carabba, Lanciano 2014]. La citazione originale in francese è: «La rage de vouloir conclure est une des manies les plus funestes et les plus stériles qui appartiennent à l’humanité».
16. J. Klein, *When Big Data Goes Bad*, in “Fortune”, 5 novembre 2013, disponibile all’indirizzo <http://fortune.com/2013/11/05/when-big-data-goes-bad/>.
17. C. Talbi, “Keep Calm and Rape” T-Shirt Maker Shuttters After Harsh Backlash, in “Huffington Post”, 25 giugno 2013, disponibile all’indirizzo https://www.huffingtonpost.com/2013/06/25/keep-calm-and-rape-shirt_n_3492411.html.
18. S. Brush, T. Schoenberg, S. Ring, *How a Mystery Trader with an Algorithm May Have Caused the Flash Crash*, in “Bloomberg News”, 21 aprile 2015, disponibile all’indirizzo <https://www.bloomberg.com/news/articles/2015-04-22/mystery-trader-armed-with-algorithms-rewrites-flash-crash-story>.
19. J. Ginsberg *et al.*, *Detecting Influenza Epidemics Using Search Engine Query Data*, in “Nature”, 457 (19 febbraio 2009), pp. 1012-1014.
20. D. Lazer *et al.*, *The Parable of Google Flu: Traps in Big Data Analysis*, in “Science”, 343 (14 marzo 2014), pp. 1203-1205.
21. D.R. Olson *et al.*, *Reassessing Google Flu Trends Data for Detection of Seasonal and Pandemic Influenza: A Comparative Epidemiological Study at Three Geographic Scales*, in

“PLOS Computational Biology”, 9(2013), n. 10, disponibile all’indirizzo <https://doi.org/10.1371/journal.pcbi.1003256>.

22. D. Lazer *et al.*, *op. cit.*

23. Ivi.

24. Anche se questa storia probabilmente era già nota in precedenza, l’abbiamo letta per la prima volta in H.L. Dreyfus, S.E. Dreyfus, *What Artificial Experts Can and Cannot Do*, in “AI & Society”, 6(1992), n. 1, pp. 18-26.

25. J. Angwin, J. Larson, *Bias in Criminal Risk Scores Is Mathematically Inevitable, Researchers Say*, in “ProPublica”, 30 dicembre 2016, disponibile all’indirizzo <https://www.propublica.org/article/bias-in-criminal-risk-scores-is-mathematically-inevitable-researchers-say>.

26. J. Angwin *et al.*, *Machine Bias*, in “ProPublica”, 23 maggio 2016, disponibile all’indirizzo <https://www.propublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing>.

27. L. Sakala, *Breaking Down Mass Incarceration in the 2010 Census*, Prison Policy Initiative Report, 28 maggio 2014, disponibile all’indirizzo <https://www.prisonpolicy.org/reports/rates.html>.

Indice analitico

‘Abd al-Rahman al-Şūfi
Aiken, Howard
Alexa (assistente digitale Amazon)
Alfa Romeo 6C
 algoritmi
 accumulo di dati e
 algoritmi per predire recidive
 analisi del linguaggio naturale e
 catene di
 deep learning
 giornalismo e
 in IA
 ipotesi e distorsioni in
 personalizzazione e
 politica e
 riconoscimento di schemi e
 rilevazione di anomalie e
 salute e
 suggerimenti contro ricerche
Alibaba
Alipay
Amazon
 Alexa
 Echo
 posizione dominante nel mercato
 salvataggio dei dati
 servizi Web
 sistema di raccomandazioni
 velocità di consegna

American Association for the Advancement of Science

American Statistical Association

“Journal of the American Statistical Association”

Andromeda, *vedi* Grande Nebulosa di Andromeda

Apple

iPhone

posizione dominante sul mercato

salvataggio dei dati

sistema di riconoscimento di schemi

assistenti digitali

Alexa (Amazon)

algoritmi e

Google Home

medicina e

riconoscimento vocale e

astronomia

Alpha Centauri

dati per la regola di predizione di Leavitt

equazione originale di Leavitt

Grande Nebulosa di Andromeda

misura delle stelle

nebulosa

oscillazione di una pulsar

parallasse

pulsar

regola di Bayes e

statistica e

Via Lattea

Athey, Alex

attivisti dei diritti civili e organizzazioni

automazione *vedi anche* robotica

Automobili, *vedi* incidenti automobilistici; gara di Formula1; automobili a guida

autonoma

automobili a guida autonoma

introspezione ed estrapolazione

LIDAR

problema SLAM

regola di Bayes e

Waymo

Baidu

Bel Geddes, Norman

Belichick, Bill
BellKor's Pragmatic Chaos
Bell Labs
Berglund Scherwitzl, Elina
Bernoulli, Johann
big data, *vedi* scienza dei dati; insiemi di dati
bisfosfonati e
 del colon-retto
 dell'esofago
 del seno
 diagnostica per immagini
 della pelle
 chirurgia
 linfoma
 terapia personalizzata
Black Lives Matter
Bornn, Luke
bosone di Higgs
Brooklyn Nets
Buffett, Warren

calcolo distribuito
 come facilitatore per l'IA
Cardwell, Chris
Carnegie Mellon University
carte di credito
 assistenti digitali e
 frodi e
Center for Disease Control and Prevention (CDC)
cetrioli
chatbot
Churchill, Winston
Cina
 automazione robotica
 aziende tecnologiche
 chatbot
 ladri di carta igienica
Cinematch (sistema di raccomandazione di Netflix)
città intelligenti
classificazione di immagini
Clinton, Bill
Clinton, Hillary

Columbia University, Gruppo di ricerca statistica (GRS)
compagnie elettriche
COMPAS
computer
 BINAC
 compilatori
 subroutine
 UNIVAC
 vedi anche Hopper, Grace
 velocità dei
contraccezione e controllo delle nascite
 ipotesi della
 metodo naturale
 Natural Cycles (app)
 storia della
controllo delle nascite, *vedi* contraccezione e controllo delle nascite
Cook, E.T.
Craven, John
curva brachistocrona

database
 analisi del linguaggio naturale
 città intelligenti
 compilatori e
 Netflix
 salute
dati, mancanti
dati, ritmo di raccolta
deep learning
 api e
 privacy e
 produzione di grano e
 rappresentazione di genere nei film e
 regole di predizione e
 richiesta di elettricità e
Descartes Labs
diagramma a cascata
Dickens, Charles
 Canto di Natale
 Martin Chuzzlewit
DiMaggio, Joe
dispositivi medici intelligenti

distorsione di sopravvivenza

Dole, Bob

2001: Odissea nello spazio

Duke University

e-commerce

Echo, Amazon

Eggo, Rosalind

Einstein, Albert

equazione di de Moivre (regola della radice quadrata)

estrazione di dati (estrazione delle informazioni)

euristica della disponibilità

Facebook

baratto “dati in cambio di gossip”

classificazione e riconoscimento immagini

elezioni presidenziali del 2016 e

insiemi di dati

marketing personalizzato

personalizzazione

predominio sul mercato

pubblicitari

rilevazione di anomalie

salvataggio dei dati

sistema di riconoscimento di schemi

Facebook Messenger

fake news

fallacia della fretta di concludere

fantascienza

ansia da IA e

robot

filosofia

Fitbit

Ford, Henry

Fowler, Samuel Lemuel

Friedman, Milton

Friends (serie televisiva)

gara di Formula 1

Geena Davis Institute on Gender in Media

gender

pregiudizi nei film

stereotipi,
Giappone
Google
 automobili a guida autonoma
 classificazione di immagini
 Inception (modello di rete neurale)
 insiemi di dati
 modello word2vec
 motore di ricerca
 personalizzazione
 posizione dominante sul mercato
 riconoscimento vocale
 rilevazione di anomalie
 salvataggio dei dati
 sistema di riconoscimento di schemi
 TensorFlow
Google 411
Google DeepMind
Google Doodle
Google Flu Trends
Google Home
Google Ngram Viewer
Google Translate
Google Voice
Gould, Stephen Jay
grande coniazione (1696)
Grande Nebulosa di Andromeda *vedi anche* astronomia
Green, Jane
Greenblatt, Joel
Gruppo di ricerca statistica (GRS)
guerra di Crimea
guerra fredda
Guest, William “Bull Dog”

Hall, John
Harvard Computers (gruppo di talenti matematici)
Harvard Mark I
HBO
Heller, Katherine
Herbert, Sidney
Herd, Andy
Hofstadter, Douglas

Hopper, Grace,
 “Amazing Grace”
 FLOW-MATIC (compilatore per la analisi dei dati)
 Google Doodle in onore di
 Howard Mark I e
 innovazione nei compilatori 147-154
 morte di
 primi anni e formazione
 seconda guerra mondiale e
 top-down, approccio basato sulle regole di
 ultimi anni
 UNIVAC e

Hotelling, Harold
House of Cards (serie televisiva Netflix)
Howard, Dwight
Hubble, Edwin
Hubble, telescopio spaziale
Hunter College

IBM
 Harvard Mark I
 riconoscimento vocale
 supercomputer Watson

ILINet
ImageNet Visual Recognition Challenge
Imperial College di Londra
imputazione
incidenti automobilistici
influenza
Infor
insiemi di dati
 anomalie in
 condivisione
 distorsioni in ingresso e in uscita
 enormi
 ImageNet Visual Recognition Challenge
 ipotesi e
 privacy
 riconoscimento di schemi e

Instagram
 hashtag
 psicologia e

salvataggio dati
Insulet
intelligenza artificiale
algoritmi e
ansia nei confronti della
automobili a guida autonoma
classificazione di immagini
contraccezione e
democratizzazione e
diffusione e divulgazione della
distorsioni in ingresso e in uscita
fallacia della fretta di concludere
gioco delle “20 domande” e
invecchiamento di un modello
ipotesi e
modello contro realtà
paradosso di Moravec
problema SLAM (*simultaneous localisation and map-ping*)
regole
riconoscimento di immagini
riconoscimento vocale
salari
sistema giudiziario e
talento e forza lavoro
tecnologie indotte dalla
vedi anche rilevazione di anomalie; regola di Bayes; salute e medicina; analisi
del linguaggio naturale; riconoscimento di schemi; personalizzazione; regole di
predizione
investimenti
regola di Bayes e investimenti
strategia d’azzardo
strategia di indicizzazione
ipotesi

James, LeBron
Jefferson, Thomas
Johnson, Lyndon
Johnson, Mark

Kaiserswerth (ospedale tedesco)
Kant, Immanuel
Koike, Makoto

Kubrick, Stanley

La biblioteca di Babele (Jorge Luis Borges)

ladri di carta igienica

Lagerman, Björn

lancio di monete

New England Patriots e

regola di Bayes e

Laplace, Pierre-Simon de

Lazer, David

Leavitt, Henrietta

dati della regola di predizione di

equazione originale di-79

morte di

primi anni e formazione

regola di predizione scoperta da

stereotipi di genere

Legendre, Adrien-Marie

legge di Gresham

legge di Moore

Le rane (Aristofane)

Leonard, Kawhi

Lewis, Michael

LIDAR

immagine di un'autostrada

vedi anche automobili a guida autonoma

limatura di monete

Lin, Jeremy

London School of Hygiene & Tropical Medicine

Lynch, Peter

Macaulay, Charles

machine learning *vedi anche* intelligenza artificiale (IA); regola di Bayes; reti neurali

Netflix e

malattia renale

mammografie

massima frequenza cardiaca

equazioni per la

matematica

“abilità matematica”

Florence Nightingale e

gioco delle “20 domande” e

informatica e
l'errore più grave di Newton
motori di suggerimenti e
principio dei minimi quadrati
probabilità condizionata
regola della radice quadrata (equazione di de Moivre)
riconoscimento di schemi e
vedi anche regola di Bayer; reti neurali; regole di predizione
vettori parola e

materiali radioattivi naturali (NORM)
medicina, *vedi* salute e medicina
Medtronic
Menger, Karl
Microsoft
Microsoft Azure
missione Schweinfurt-Regensburg (seconda guerra mondiale)
MODA
modellizzazione
 allenare i modelli
 analisi del linguaggio naturale e
 caratteristica latente
 dati mancanti e
 imputazioni e
 Inception
 invecchiamento dei modelli
 ipotesi e
 modelli basati su regole (top-down)
 modelli di deep learning
 modelli massivi
 realtà e
 regole di predizione come

Moneyball
Morgenstern, Oskar
motori di suggerimenti
 come “software sosia”
 marketing personalizzato e
 svantaggi dei
 vantaggi dei
 vedi anche sistemi di raccomandazioni

Musk, Elon

Netflix

Crown, The (serie televisiva)
House of Cards (serie televisiva)
motori di suggerimenti
Netflix Prize (premio per motori di suggerimenti)
personalizzazione
scienziati dei dati
storia di
New England Patriots
Newton, Isaac
Nightingale Florence
diagramma polare (1858)
eredità sulla medicina basata sui dati di
eredità sulla riforma dell'infer "la dama con la lanterna"
mieristica di
eredità sulla statistica medica di
guerra di Crimea e
primi anni e formazione
Nvidia

Obama, Barack
omissione della probabilità primaria

paradosso Moravec
parallasse
parassiti Varroa
PayPal
personalizzazione
 modello a caratteristiche latenti e
 Netflix e
 probabilità condizionata e
 raccomandazioni Ward per la sopravvivenza degli aerei e
 vedi anche motori di suggerimenti
Pickering, Edward C.
politica
predominio sul mercato
Price, Richard
prima guerra mondiale
principio dei minimi quadrati
privacy
probabilità condizionata
 asimmetria della
 meteo e

personalizzazione e
salute e
vedi anche regola di Bayes

problema SLAM

processo decisionale
rilevazione di anomalie e
umano
votazione

progetto Manhattan

ProPublica

prova della pisside

Quetelet, Adolphe

Reagan, Ronald

Rees, Mina

regola della radice quadrata (equazione di de Moivre)

regola di Bayes
automobili a guida autonoma e
diagnosi cliniche e
in forma di equazione
investimenti e
lancio della moneta e
mammografie e
ricerca dello USS *Scorpion* e
ricerca del volo Air France 447 e
scoperta della
utilità della

regole di predizione
allenare un modello
analisi del linguaggio naturale e
come modelli
contraccezione e
deep learning e
Google Translate e
Grande Nebulosa di Andromeda e
insiemi di dati enormi e
modelli massivi e
problema della sovradeterminazione
reti neurali e
riconoscimento di immagini e
strategia di tentativi ed errori

- valutazione delle
- Reinhart, Alex
- reti neurali
 - deep learning e
 - modello Inception
 - nuovi episodi di *Friends* e
 - regole di predizione e
- ricerca bayesiana
 - ipotesi a priori aggiornate
 - probabilità a posteriori
 - probabilità a priori
 - probabilità a priori e ricerca dello USS *Scorpion*
 - punti fondamentali della
- riconoscimento di immagini
 - regole di predizione e
- riconoscimento di schemi
 - apprendere uno schema
 - classificazione di cetrioli
 - input e output
 - ladri di carta igienica e
 - massima frequenza cardiaca e
 - regole di predizione e
 - vedi anche* regole di predizione
- riconoscimento vocale
 - Harpy
 - vedi anche* linguaggio naturale
- rilevazione di anomalie
 - città intelligenti e
 - distorsione (tipo di anomalia)
 - Formula 1 e
 - frodi e
 - importanza della variabilità
 - limatura di monete e
 - media
 - Moneyball
 - NBA e
 - prova della pisside (metodo anti-frode della Zecca reale)
 - record dei Patriots nel lancio della moneta e
 - record simulato di lancio della moneta
 - regola della radice quadrata (equazione di de Moivre)
 - rispetto della legge e
 - sovradispersione (tipo di anomalia)

robotica

- in Cina
- problema SLAM
- regola di Bayes e
- ricerca dello USS *Scorpion* e
- rivoluzione della
- Stanford Cart
- Teseo
- vedi anche* automobili robot

Rose, Pete

Russell, Alexander Wilson

S&P 500

Salesforce

salute e medicina

- condivisione dei dati
- Crohnology
- diagramma “a torta” di Nightingale (1858)
- eredità di Florence Nightingale in scienza dei dati
- funzionalità renale nel tempo
- IA e
- ibrutinib (farmaco tumorale)
- imaging medicale
- incentivi
- influenza
- innovazione e
- malattia renale
- medicina a distanza
- ospedali
- Patien tsLikeMe
- percentuali di fallimento nella contraccezione
- politiche sanitaria
- privacy e sicurezza
- profilazione genica
- reti sociali incentrate sui pazienti
- ricerche su Google per “quanto dura”
- screening mammografico
- strumentazioni mediche intelligenti
- tendenze future
- terapia personalizzata
- Tiatros
- vedi anche* tumore; Nightingale, Florence

velocità di filtrazione glomerulare (GFR)
Sapir, Edward
Sarandos, Ted
SAT
Scherwitzl, Raoul
Schlesinger, Karl
Schuschnigg, Kurt
scienza dei dati
 democrazia e
 eredità di Florence Nightingale
 impegno istituzionale e
 imputazione
 ingegneria delle caratteristiche
 ipotesi e
 personalizzazione e
 regole di predizione e
 riconoscimento di schemi e
 rilevazione di anomalie e
 salute e
 selezione collaborativa basata sugli utenti
 variabile latente
seconda guerra mondiale
battaglia delle Ardenne
consigli di sopravvivenza di Wald per aerei
Grace Hopper e
Gruppo di ricerca statistica (GRS)
missione Schweinfurt-Regensburg (seconda guerra mondiale)
ricerca bayesiana e
Sendak, Mark
Shannon, Claude
Shapley, Harlow
Sieveking, Edward Henry
Silicon Valley
sistemi di allarme precoce
sistemi di analisi del linguaggio naturale (NLP)
 ambiguità e
 approccio bottom-up
 approccio top-down
 assistenti digitali
 chatbot
 crescita degli NLP statistici
 Google Translate

“New Deal” per l’interazione linguistica uomo-macchina
regole di predizione e
regole e
riconoscimento vocale
rivoluzione dei linguaggi di programmazione
rivoluzione del linguaggio naturale
“sapere come” contro “sapere cosa”
solidità e
statistica di posizionamento delle parole
tendenze future
vettori parola
sistemi di raccomandazioni
eredità dei
Netflix
salute e
su larga scala
vedi anche motori di suggerimenti
sistema giudiziario
Skype
Slattery, Francis A., *vedi anche* USS Scorpion
Slipher, Vesto
smartphone
app
tecnologia GPS
smartwatch
social media, *vedi anche* Facebook
sottomarini, *vedi* USS Scorpion
SpaceX
Spotify
personalizzazione
probabilità condizionata
Standard & Poor’s
Stanford University
statistica
Stigler, George
Stripe (sistema di pagamento)
superutilizzatore

Takáts, Zoltán
Tandem
tecnologia GPS
Teller, Edward

Tencent
Terra
Tesla
test di Kolmogorov-Smirnov
The Checklist Manifesto (Atul Gawande)
Thrun, Sebastian
Tiatros
Trump, Donald
Tufte, Edward
tumore

Uber
Ufficio ricerca e sviluppo
Ulam, Stanisław
 UNIVAC
USS *Scorpion*
 convinzioni a priori e ricerca dello
 sezione di prua

Vassar College
vettori parola
 modello word2vec (Google)
von Neumann, John

Wald, Abraham
 campionamento sequenziale
 consigli di sopravvivenza per aerei
 membro del Gruppo di ricerca
 statistica (Columbia)
 negli Stati Uniti
 primi anni e formazione

Wallis, W. Allen
WannaCry
Watson (supercomputer IBM)
Waymo (azienda di automobili a guida autonoma)
WeChat

Yormark, Brett
YouTube

Zecca reale
 grande coniazione

limatura di monete
Newton, Isaac e
prova della pisside
Zillow

Ultimi volumi pubblicati

STEFANO BARTEZZAGHI, *Il falò delle novità. La creatività al tempo dei cellulari intelligenti*

AA.VV., *Dono, dunque siamo. Otto buone ragioni per credere in una società più solidale*

MICHELA MARZANO, *L'amore è tutto: è tutto ciò che so dell'amore* (10^a ediz.)

ANDREA VENTURA, MIMMO FRANZINELLI, *Una mattina mi son svegliato. Cinque storie dell'8 settembre 1943*

JIM HOLT, *Perché il mondo esiste? Una detective-story filosofica* (2^a ediz.)

BARBARA FRALE, *L'inganno del Gran Rifiuto. La vera storia di Celestino V, papa dimissionario* (3^a ediz.)

JACQUES DE SAINT VICTOR, *Patti scellerati. Una storia politica delle mafie in Europa*

ADAM ZAMOYSKI, *Marcia fatale. 1812 Napoleone in Russia* (3^a ediz.)

MARCO MAGNANI, *Sette anni di vacche sobrie. Come sarà l'Italia del 2020? Sfide e opportunità di crescita per sopravvivere alla crisi* (2^a ediz.)

SERGIO SCHIAVONE, ANTONIO NICASO, *Cacciatori di tracce. Storie e tecniche di investigazione sulla scena del crimine*

FELIX MARTIN, *Denaro. La storia vera: quello che il capitalismo non ha capito*

AA.VV., *L'oltre e l'altro. Sette variazioni sul viaggio* (2^a ediz.)

ELIDO FAZI, *Mefistofele. Come uscire dalla crisi economica con le ricette del diavolo*

LIA CELI, ANDREA SANTANGELO, *Mai stati meglio. Guarire da ogni malanno con la Storia*

JOSEF JOFFE, *Perché l'America non fallirà. Politica, economia e mezzo secolo di false profezie*

EVA CANTARELLA, *Ippopotami e sirene. I viaggi di Omero e di Erodoto* (4^a ediz.)

ANDREA CAMILLERI, *Segnali di fumo*

HANS ULRICH OBRIST, *Fare una mostra* (2^a ediz.)

ROBERTO COTRONEO, *Il sogno di scrivere. Perché lo abbiamo tutti. Perché è giusto realizzarlo* (2^a ediz.)

JESSE BERING, *Perv. Viaggio nelle nostre perversioni*

LAURA BOSIO, BRUNO NACCI, *Da un'altra Italia. 63 lettere, diari, testimonianze sul "carattere" degli italiani*

SLAVOJ ŽIŽEK, *Evento*

LAURA GRANDI, STEFANO TETTAMANTI, *Il cibo non era niente di speciale. Incontri, e scontri, di 239 scrittori con cibi, bevande e alberghi d'Europa*

RODERICK BAILEY, *Target: Italy. I servizi segreti contro Mussolini, 1940-1943*

MARCO SCARDIGLI, *Viaggio nella terra dei morti. La vita dei soldati nelle trincee della Grande Guerra* (2^a ediz.)

JOE BASTIANICH (con Sara Porro), *Giuseppino. Da New York all'Italia: storia del mio ritorno a casa* (2^a ediz.)

MARCO AIME, *Tra i castagni dell'Appennino. Conversazioni con Francesco Guccini*

ANDREA CARANDINI, *La Roma di Augusto in 100 monumenti* (2^a ediz.)

PIERO BIANUCCI, *Vedere, guardare. Dal microscopio alle stelle, viaggio attraverso la luce* (2^a ediz.)

MICHELA MARZANO (con Giovanna Casadio), *Non seguire il mondo come va. Rabbia, coraggio, speranza e altre emozioni politiche*

AA.VV., *L'arte della condivisione. Per un'ecologia dei beni comuni*

LELLA RAVASI BELLOCCHIO, *I sogni delle donne*

SUSAN NEIMAN, *Perché diventare grandi?*

GIGI DI FIORE, *La Nazione napoletana. Controstorie borboniche e identità suddista* (2^a ediz.)

MADDALENA SANTERONI, DONATELLA MILIANI, *La cuoca di d'Annunzio. I biglietti del Vate a "Suor Intingola". Cibi, menù, desideri e inappetenze al Vittoriale* (2^a ediz.)

MARCO AIME, *Senza sponda. Perché l'Italia non è più una terra d'accoglienza*

ROBERTO COTRONEO, *Lo sguardo rovesciato. Come la fotografia sta cambiando le nostre vite* (2^a ediz.)

CRISTINA GIUDICI, *Mare monstrum, mare nostrum. Migranti, scafisti, trafficanti. Cronache dalla lotta all'immigrazione clandestina*

LIA CELI, ANDREA SANTANGELO, *Caterina la Magnifica. Vita straordinaria di una geniale innovatrice* (3^a ediz.)

VITTORIO SABADIN, *Elisabetta, l'ultima regina* (3^a ediz.)

VIOLETTA BELLOCCHIO (a cura di), *Quello che hai amato. Undici donne. Undici storie vere*

ANDREA VENTURA, *Giulia. Una ragazza del Novecento*

BARBARA GRAZIOSI, *Gli dèi dell'Olimpo. Storia di una sopravvivenza*

MICHELA MARZANO, *Papà, mamma e gender* (5^a ediz.)

TIM PARKS, *Di che cosa parliamo quando parliamo di libri*

GIUSEPPE SCARAFFIA, *Gli ultimi giorni di Mata Hari*

LORENZO DEL BOCA, ANGELO MOIA, *Sulla via Francigena. Storia e geografia di un cammino millenario*

MARCO SCARDIGLI, ANDREA SANTANGELO, *Le armi del diavolo. Anatomia di una battaglia: Pavia, 24 febbraio 1525*

UMBERTO VERONESI, *Tre sere alla settimana. 300 film, 12 anni di passione cinematografica*

ARRIGO PETACCO, *Come eravamo negli anni di guerra. La vita quotidiana degli italiani tra il 1940 e il 1945 (2^a ediz.)*

MARCO ANSALDO, *Le molte feritoie della notte. I volti nascosti di Fabrizio De André*

PAOLO CIRINO POMICINO, *La Repubblica delle Giovani Marmotte. L'Italia e il mondo visti da un democristiano di lungo corso*

ENZO SORESI (con Pierangelo Garzia), *Mitocondrio mon amour. Strategie di un medico per vivere meglio e più a lungo*

ANDREW ROBERTS, *Napoleone il Grande*

GIANFRANCO PASQUINO, *La Costituzione in trenta lezioni*

FRANCO CARDINI, *Il califfato e l'Europa. Dalle crociate all'ISIS: mille anni di paci e guerre, scambi, alleanze e massacri (2^a ediz.)*

FRANCESCA PACI, *Un amore ad Auschwitz. Edek e Mala: una storia vera*

AA.VV., *Le case dell'uomo. Abitare il mondo*

FRANCES LARSON, *Teste mozze. Storie di decapitazioni, reliquie, trofei, souvenir e crani illustri*

MARCO MAGNANI, *Terra e buoi dei paesi tuoi. Scuola, ricerca, ambiente, cultura e capitale umano: quando l'impresa investe nel territorio*

BARBARA FRALE, *La guerra di Francesco. Gioventù di un santo ribelle*

ARMANDO MASSARENTI, *20 lezioni d'amore di filosofi e poeti dall'antichità ai giorni nostri*

GIACOMO PELLIZZARI, *Il carattere del ciclista*

VITTORIO SABADIN, *Carlo il principe dimenticato*

MARTA VERNA, *Nessuno esca piangendo (2^a ediz.)*

RICCARDO CHIABERGE, *1918. La grande epidemia. Quindici storie della febbre spagnola*

STEFANO BARTEZZAGHI, *La ludoteca di Babele. Dal dado ai social network: a che gioco stiamo giocando?*

GIOVANNI ARDUINO, LOREDANA LIPPERINI, *Schiavi di un dio minore. Sfruttati, illusi, arrabbiati: storie dal mondo del lavoro oggi*

LORENZO DEL BOCA, *Venezia tradita. All'origine della "questione veneta"*

LIA CELI, ANDREA SANTANGELO, *Casanova per giovani italiani*

ARRIGO PETACCO, *La nostra guerra 1940-1945. L'Italia al fronte tra bugie e verità*

CINZIA SASSO, *Moglie*, prefazione di Natalia Aspesi (3^a ediz.)

ANDREA CARANDINI (con Mattia Ippoliti), *Giove custode di Roma. Il dio che difende la città*

LARS MYTTING, *Norwegian Wood. Il metodo scandinavo per tagliare, accatastare e scaldarsi con la legna* (5^a ediz.)

GIOVANNI CAPRARA, *Rosso Marte. La grande avventura dell'uomo nello spazio*

GIULIANO VOLPE, *Un patrimonio italiano. Beni culturali, paesaggio e cittadini*

ELBERT HUBBARD, *Un messaggio per García* (con una nota di Luciano Canfora e un ritratto di Giuseppe Scaraffia)

FRANCO CARDINI, *I giorni del sacro. I riti e le feste del calendario dall'antichità a oggi*

AA. VV., *Da qui in poi. La cura delle parole in 21 racconti*

SEBASTIAN SMEE, *Artisti rivali. Amicizie, tradimenti e rivoluzioni nell'arte moderna*

GUIDO DAVICO BONINO (a cura di), «*Ti scrivo che ti amo*» 299 lettere d'amore italiane

CATHERINE MERRIDALE, *Cremlino. Dalle origini all'ascesa di Putin: il cuore politico della Russia*

ARTHUR CONAN DOYLE, *Avventura nell'Artico. Sei mesi a bordo della baleniera Hope*

MARCO ROMANO, *Le belle città. Cinquanta ritratti di città come opere d'arte*

SARA PORRO, *Prenotazione obbligatoria. Partenze, vagabondaggi e quello che ho mangiato*

TADEUSZ PANKIEWICZ, *Il farmacista del ghetto di Cracovia* (2^a ediz.)

AA.VV., *L'umanità in gioco*

LUCA LO SAPIO, *Bioetica cattolica e bioetica laica nell'era di papa Francesco. Che cosa è cambiato?* (con un saggio di Giovanni Fornero)

SIMONE REGAZZONI, *Ti amo. Filosofia come dichiarazione d'amore*

GIANFRANCO PASQUINO, *L'Europa in trenta lezioni*

ANDREA SANTANGELO, *Eccentrici in guerra. Storie e personaggi stravaganti della seconda guerra mondiale*

CATHERINE MERRIDALE, *Lenin sul treno*

FLAVIO CAROLI, *Storia di artisti e di bastardi*

GIOVANNI ZICCARDI, *Il libro digitale dei morti. Memoria, lutto, eternità e oblio nell'era dei social network*

GIACOMO PELLIZZARI, *Storia e geografia del Giro d'Italia*

TIFFANY WATT SMITH, *Atlante delle emozioni umane. 156 emozioni che hai provato, che non sai di aver provato, che non proverai mai* (6^a ediz.)

MARCO SCARDIGLI, *Il viaggiatore di battaglie. Sulle tracce delle piccole e grandi guerre combattute in Italia*

SALVATORE SETTIS, *Cieli d'Europa. Cultura, creatività, uguaglianza*

ARRIGO PETACCO, *La guerra dei mille anni. Dieci secoli di conflitto fra Oriente e*

Occidente

- MASSIMO BOCCHIOLA, MARCO SARTORI, *La battaglia di Canne. Il trionfo di Annibale*
- GIGI DI FIORE, *Briganti! Contro storia della guerra contadina nel Sud dei Gattopardi* (3^a ediz.)
- VICTOR DAVIS HANSON, *L'arte occidentale della guerra. Descrizione di una battaglia nella Grecia classica*
- VITTORIO SABADIN, *Diana. Vita e destino*
- HANS ULRICH OBRIST, *Vite degli artisti, vite degli architetti*
- GIAN PIERO ALLOISIO, *Il mio amico Giorgio Gaber. Tributo affettuoso a un uomo non superficiale*
- GREG MITCHELL, *Tunnel. 1962: fuga sotto il muro di Berlino*
- ERIC LAX, *Woody Allen dall'inizio alla fine. Un anno sul set con un grande regista*
- ERRICO BUONANNO, LUCA MASTRANTONIO, *Notti magiche. Atlante sentimentale degli anni novanta*
- ANDREA CARANDINI, *Antinomia ben temperata. Scavi nell'io e nel noi. 142 riflessioni su emozioni e ragione*
- MARIANO SIGMAN, *La vita segreta della mente. Come funziona il nostro cervello quando pensa, sente, decide* (2^a ediz.)
- RACHELE FERRARIO, *Les Italiens. Sette artisti alla conquista di Parigi*
- IAN THOMSON, *Primo Levi. Una vita*
- ŁUKASZ KAMIENSKI, *Shooting Up. Storia dell'uso militare delle droghe*
- LARS MYTTING, ADAM DOUGHTY, *Norwegian Wood Activity Book*
- GIANNALBERTO BENDAZZI, *Animazione. Una storia globale* (2 voll.)
- VIRGINIA WOOLF, *Ritratto della scrittrice da giovane. Lettere 1896-1912* (con un saggio di Nadia Fusini)
- FOLCO QUILICI, *Tutt'attorno la Sicilia. Un'avventura di mare*
- MIEP GIES (con ALISON LESLIE GOLD), *Si chiamava Anne Frank*
- CLAUDIO GIUNTA, *Come non scrivere. Consigli ed esempi da seguire, trappole e scemenze da evitare quando si scrive in italiano* (7^a ediz.)
- AA. VV., *La cultura ci rende umani. Movimenti, diversità e scambi*
- MARCO MONETA, *Un veneziano alla corte moghul. Vita e avventure di Nicolò Manucci nell'India del Seicento*
- FULVIO ROMANIN, *L'IVA funesta. Come aprire una partita IVA e sopravvivere per raccontarlo*
- GABRIELE NISSIM, *Il bene possibile. Essere giusti nel proprio tempo* (2^a ediz.)
- BELLA BATHURST, *Rumore. Perdere e recuperare l'udito*
- CHRISTOPHER TYERMAN, *Come organizzare una crociata*
- AGNESE CODIGNOLA, *Lsd. Da Albert Hofmann a Steve Jobs, da Timothy Leary a Robin Carhart-Harris: storia di una sostanza stupefacente* (2^a ediz.)
- CHIARA ALESSI, *Le caffettiere dei miei bisnonni. La fine delle icone nel design italiano*

GIANNI OLIVA, *La grande storia della Resistenza. 1943-1948*

DANIELE ZOVI, *Alberi sapienti, antiche foreste. Come guardare, ascoltare e avere cura del bosco* (4^a ediz.)

ARRIGO PETACCO, *Faccetta nera. L'illusione coloniale italiana*

CHIARA GARBARINO, *La felicità non sta mai ferma. Storia di Leo, il mio bambino ribelle*

ADRIANO FAVOLE, *Vie di fuga. Otto passi per uscire dalla propria cultura*

EDUARDO MENDOZA, *Che cosa succede in Catalogna. Un grande scrittore contro il pregiudizio, l'indifferenza e l'incomprensione*

GIACOMO PELLIZZARI, *Gli Italiani al Tour de France*

CORRADO DEL BÒ, FILIPPO SANTONI DE SIO, *La partita perfetta. Filosofia del calcio*

GIORGIO CAPONETTI, *Il grande Gualino. Vita e avventure di un uomo del Novecento* (4^a ediz.)

MARKUS TORGEBY, *Running Wild. Trovare se stessi correndo nella foresta artica*

ROBERTO COTRONEO, *L'invenzione di Caravaggio*

VINCINO, *Mi chiamavano Togliatti. Autobiografia disegnata a dispense*

KARIN BOJS, *I miei primi 54 000 anni. Storia della mia famiglia e del nostro DNA*

PIERLUIGI PANZA, *L'ultimo Leonardo. Storia, intrighi e misteri del quadro più costoso del mondo*

ARRIGO PETACCO, *L'uomo della provvidenza. La costruzione del mito di Mussolini dal trionfo alla catastrofe*

FIONA SAMPSON, *La ragazza che scrisse Frankenstein. Vita di Mary Shelley*

MARTIN ANGIONI, *Le 98 ragioni per cui vado in bicicletta*

GIGI DI FIORE, *L'ultimo re di Napoli. L'esilio di Francesco II di Borbone nell'Italia dei Savoia* (2^a ediz.)

RICCARDO RAO, *Il tempo dei lupi. Storia e luoghi di un animale favoloso* (2^a ediz.)

GUIDO COSSARD, *Cieli perduti. Archeoastronomia: le stelle dei popoli antichi*

LELE SACCHI, *Club Confidential. Cultura, dancefloor e rivoluzioni: un dj racconta la notte*

MIKA RISSANEN, JUHA TAHVANAINEN, *Storia dell'Europa in 24 pinte. Dieci secoli di birra*

VICTORIA EUGENIA HENAO, *Ho sposato Pablo Escobar. La mia vita con il re dei Narcos*

KASSIA ST CLAIR, *Atlante sentimentale dei colori. Da amaranto a zafferano, 75 storie straordinarie* (2^a ediz.)

ERRICO BUONANNO, *Falso Natale. Bufale, storie e leggende della festa più importante dell'anno*

STEVE BRUSATTE, *Ascesa e caduta dei dinosauri. La vera storia di un mondo perduto* (2^a ediz.)

FABIO TONACCI, GIULIANO FOSCHINI, *Jihadisti Italiani. Le storie, le intercettazioni, i documenti segreti dell'ISIS in Italia*
PASQUALE CHESSA, *Il romanzo di Benito. La vera storia dei falsi Mussolini*
ANDREA DE BENEDETTI, CARLO PESTELLI, *La lingua feliz. Curiosità, bizzarrie e segreti: tutto quello che avreste voluto sapere sulla lingua spagnola*
VITTORIO DAN SEGRE, *Storia di un ebreo fortunato*
AA. VV., *Rompere le regole. Creatività e cambiamento*
NELLO TROCCHIA, *Casamonica. Viaggio nel mondo parallelo del clan che ha conquistato Roma*
ANDREA CARANDINI, EMANUELE PAPI, *Adriano. Roma e Atene*
DHARSHINI DAVID, *Il mondo in un dollaro. Il viaggio di una banconota dal Texas alla Cina, dalla Nigeria all'Iraq, per capire l'economia globale*
DAVID ALLEGRANTI, *Come si diventa leghisti. Viaggio in un paese che si credeva rosso e si è svegliato verde*
FRANCIS FUKUYAMA, *Identità. La ricerca della dignità e i nuovi populismi*

UTETEXTRA

1. LUCREZIO, *La natura dell'amore. Con un racconto di Marcel Schwob*
2. CARLO COLLODI, *Pipì o lo scimmiottino color di rosa*
3. SHAFTESBURY, *Lettera sull'entusiasmo*
4. *Il cavo e il vuoto. 50 storie taoiste (3ª ediz.)*
5. GIACOMO LEOPARDI, *Questa città che non finisce mai. Lettere da Roma, 1822-32. Con un saggio di Emanuele Trevi (2ª ediz.)*
6. OVIDIO, *I rimedi dell'amore. Con le massime consolanti sull'amore di Charles Baudelaire*
7. *Il saggio e l'elefante. 30 rinascite del Buddha*
8. CHARLES SANDERS PEIRCE, *Come rendere chiare le nostre idee*
9. JOSEPH CONRAD, *Karain. Con un Ritratto di Bertrand Russell*
10. IGNAZIO DI LOYOLA, *Autobiografia*
11. ANTOINE DE SAINT-EXUPÉRY, *La pasta umana. Taccuini 1935-1940*
12. SHA'RANI, *Vite di santi musulmani*
13. *Il momento propizio. 99 storie confuciane*
14. *La società dell'orso. La spiritualità degli indiani del Nord America*
15. FRANCESCO BACONE, *Miniere di sale. Aneddoti sugli antichi e sui moderni*

CLASSICI

- IMMANUEL KANT, *Critica della ragion pura*, a cura di Pietro Chiodi (3^a ediz.)
- BARUCH SPINOZA, *Etica e Trattato teologico-politico*, a cura di Remo Cantoni e Franco Fergnani (2^a ediz.)
- JOHN MAYNARD KEYNES, *Teoria generale dell'occupazione, dell'interesse e della moneta*, a cura di Terenzio Cozzi (2^a ediz.)
- ADAM SMITH, *La ricchezza delle nazioni*, a cura di Anna e Tullio Bagiotti
- PLUTARCO, *Vite parallele I*, a cura di Antonio Traglia
- PLUTARCO, *Vite parallele II*, a cura di Domenico Magnino
- OVIDIO, *Metamorfosi*, a cura di Nino Scivoletto (2^a ediz.)
- LUCREZIO, *De rerum natura*, a cura di Armando Fellin (2^a ediz.)
- Apocrifi dell'Antico Testamento*, a cura di Paolo Sacchi, 2 voll.
- Avesta*, a cura di Arnaldo Alberti
- MOSÈ MAIMONIDE, *La guida dei perplessi*, a cura di Mauro Zonta
- KARL MARX, *Il capitale*, a cura di Aurelio Macchioro e Bruno Maffi, 3 voll. (2^a ediz.)
- GIUSEPPE FLAVIO, *Antichità giudaiche*, a cura di Luigi Moraldi, 2 voll. (2^a ediz.)
- AMMIANO MARCELLINO, *Le Storie*, a cura di Antonio Selem
- GIORDANO BRUNO, *Opere italiane*, a cura di Nuccio Ordine, 2 voll.
- ALEXIS DE TOCQUEVILLE, *La democrazia in America*, a cura di Nicola Matteucci
- Il Corano*, a cura di Gabriele Mandel, Introduzione di Khaled Fouad Allam
- ISIDORO DI SIVIGLIA, *Etimologie o origini*, a cura di Angelo Valastro Canale, 2 voll.
- ERODOTO, *Le Storie*, a cura di Aristide Colonna e Fiorenza Bevilacqua, 2 voll.
- OMERO, *Odissea*, a cura di Franco Ferrari
- IMMANUEL KANT, *Critica della ragion pratica e altri scritti morali*, a cura di Pietro Chiodi
- GEORG WILHELM FRIEDRICH HEGEL, *La filosofia dello spirito*, a cura di Alberto Bosi
- SEVERINO BOEZIO, *La consolazione della filosofia*, a cura di Claudio Moreschini

GUIDO GOZZANO, *Opere*, a cura di Giusi Baldissoni

MARZIALE, *Epigrammi*, a cura di Giuseppe Norcio

TUCIDIDE, *Le Storie*, a cura di Guido Donini, 2 voll.

ARISTOTELE, *La metafisica*, a cura di Carlo Augusto Viano

MONTESQUIEU, *Lo spirito delle leggi*, a cura di Sergio Cotta, 2 voll.

ABELARDO ED ELOISA, *Epistolario*, a cura di Ileana Pagani

ORAZIO, *Opere*, a cura di Tito Colamarino e Domenico Bo

AVICENNA, *Libro della guarigione. Le cose divine*, a cura di Amos Bertolacci

LUDOVICO ARIOSTO, *Orlando furioso e cinque canti*, a cura di Remo Ceserani e Sergio Zatti, 2 voll.

ARISTOTELE, *Retorica e poetica*, a cura di Marcello Zanatta

ELIODORO, *Le Etiopiche*, a cura di Aristide Colonna

MICHELANGELO, *Rime e lettere*, a cura di Paola Mastrocola

ARISTOTELE, *Politica e Costituzione di Atene*, a cura di Carlo Augusto Viano

AVERROÈ, *L'incoerenza dell'incoerenza dei filosofi*, a cura di Massimo Campanini

CICERONE, *Epistole ad Attico*, a cura di Carlo Di Spigno, 2 voll.

AA.VV., *Viaggiatori del Seicento*, a cura di Marziano Guglielminetti

LUCANO, *La guerra civile*, a cura di Renato Badalì

SENOFONTE, *Anabasi*, a cura di Fiorenza Bevilacqua

FEDRO E AVIANO, *Favole*, a cura di Giannina Solimano

Talmùd. Il trattato delle benedizioni, a cura di Sofia Cavalletti

BACONE, *Scritti filosofici*, a cura di Paolo Rossi

CICERONE, *Opere filosofiche*, a cura di Nino Marinone

TOMMASO D'AQUINO, *Compendio di teologia e altri scritti*, a cura di Agostino Selva e Tito S. Centi

PLUTARCO, *Vite parallele III*, a cura di M.L. Amerio e D.P. Orsi

PLUTARCO, *Vite parallele IV*, a cura di Domenico Magnino

AULO GELLIO, *Le notti attiche*, a cura di Giorgio Bernardi-Perini, 2 voll.

Testi dello Sciamanesimo Siberiano e centro-asiatico, a cura di Ugo Marazzi

GEORGES SOREL, *Scritti politici*, a cura di Roberto Vivarelli

ALEXIS DE TOCQUEVILLE, *La rivoluzione democratica in Francia. Scritti politici*

NICCOLÒ MACHIAVELLI, *Il principe*, a cura di Rinaldo Rinaldi, Introduzione di Tim Parks

BLAISE PASCAL, *Pensieri*, a cura di Bruno Nacci

Indice

Colophon	3
Frontespizio	4
Sommario	5
Introduzione	8
Che cosa significa davvero “IA”?	10
Come siamo arrivati fin qui?	11
Ansie da IA	13
Brevi considerazioni sulla matematica	17
Il rifugiato	19
Abraham Wald, eroe della seconda guerra mondiale	22
I primi anni di Wald	23
Wald in America	25
Wald e gli aerei mancanti	27
Dati mancanti: quello che non conosci può trarti in inganno	30
Bombardieri mancanti, valutazioni mancanti	34
Le caratteristiche nascoste dicono tutto	39
Il lascito eterogeneo dei motori di suggerimenti	40
Post scriptum	46
La fabbricante di candeliere	48
Input/output: come le macchine riconoscono gli schemi	49
Una scoperta stellare	53
Adattare le regole di predizione ai dati	63
Oltre le linee rette	67
Post scriptum	79
Il reverendo e il sottomarino	81
La rivoluzione robotica	83
In che modo trovare un sottomarino è simile a sapere dove ti trovi lungo una strada?	85
La regola di Bayes, dal reverendo al robot	94
Come la regola di Bayes può renderci più intelligenti	100
Post scriptum	109
Amazing Grace	117

Amazing Grace	112
La storia di due rivoluzioni	115
Da Grace ad Alexa: la rivoluzione del linguaggio naturale	126
1980-2010: lo sviluppo dell'elaborazione statistica del linguaggio naturale	130
Come le parole diventano numeri	134
La comunicazione tra esseri umani e macchine	143
Post scriptum	144
Il genio della Zecca reale	147
La seconda carriera professionale di Isaac Newton	151
La prova della pisside	154
Rilevazione di anomalie nell'era dell'IA	163
Moneyball per l'era digitale	171
Post scriptum	175
La dama con la lanterna	177
L'angelo della Crimea	180
L'eredità di Nightingale per l'analisi dei dati	184
Danni evitabili nell'era dell'IA	188
IA alla riscossa?	196
Che cosa succederà?	202
Post scriptum	206
Il Clipper degli Yankees	208
Joe DiMaggio e la fretta di concludere	212
Modelli antiquati	226
Distorsioni in ingresso e in uscita	231
Post scriptum	235
Ringraziamenti	237
Note	239
Indice analitico	249