

EDIÇÃO PREMIUM
100 PÁGINAS

Agosto 2017 | www.sciam.com.br

SCIENTIFIC AMERICAN

BRASIL



ANO 15 | nº 175
R\$ 19,90 | 4,90 €

MAIS

A CIRURGIA QUE CURA DIABETES

Procedimento pode
amenizar e até extinguir
doença crônica

O SUMICO DOS VIKINGS


Estudos explicam
por que eles
abandonaram
a Groenlândia

BURACOS NEGROS EXPLICAM MATÉRIA ESCURA?

Gigantes cósmicos
podem ser resposta
para o enigma

AS TEIAS DA MEMÓRIA

Revolução na tecnologia revela o modo como nosso cérebro
conecta lembranças e modula nossa experiência do mundo



• APRENDIZAGEM
DE MÁQUINA


POR UMA IA MAIS HUMANA



A inteligência artificial vem passando por uma renovação desde que começou a incorporar nosso conhecimento sobre como as crianças aprendem

Alison Gopnik





Alison Gopnik é professora de psicologia e professora associada de filosofia da Universidade da Califórnia em Berkeley. Suas pesquisas focam como as crianças pequenas aprendem sobre o mundo que as cerca.



SE VOCÊ PASSA MUITO TEMPO COM CRIANÇAS É TENTADO A SE PERGUNTAR como esses jovens seres humanos aprendem tanto e tão depressa. Percorrendo um longo caminho de volta até Platão, os filósofos também têm se feito a mesma pergunta, mas sem achar respostas satisfatórias. Meu neto de cinco anos, Augie, sabe muito sobre plantas, animais e relógios, sem falar em dinossauros e naves espaciais. Ele também consegue entender o que as outras pessoas querem, como elas pensam e como se sentem. E ele utiliza esse conhecimento para classificar o que vê e ouve, e fazer novas previsões. Recentemente, ele afirmou, por exemplo, que as espécies recentemente descobertas de titanossauro em exibição no Museu Americano de História Natural da Cidade de Nova York são herbívoras, logo, isso significa que ele não é assim tão assustador.

Porém, tudo o que chega até Augie do ambiente que o rodeia é um feixe de fótons que impressionam sua retina e perturbações do ar que repercutem em seus tímpanos. De algum modo o computador neural atrás de seus olhos azuis consegue, a partir da informação limitada de seus órgãos sensoriais, fazer inferências sobre titanossauros comedores de plantas. Uma questão que permanece é se os computadores eletrônicos também podem fazer isso.

Nos últimos 15 anos, aproximadamente, cientistas da computação e psicólogos vêm tentando achar a resposta. As crianças absorvem uma grande quantidade de conhecimento com pouco *input* dos professores ou pais. Apesar dos enormes avanços da inteligência artificial (IA), até os computadores mais poderosos ainda não conseguem aprender tão bem como um garoto de cinco anos.

Entender como o cérebro de uma criança realmente funciona — e depois criar uma versão digital que funcione eficientemente — será um grande desafio para os cientistas da computação nas próximas décadas. Mas, enquanto isso, eles estão começando a desenvolver uma inteligência artificial que incorpore parte do que sabemos sobre como os seres humanos aprendem.

ESTE LADO PARA CIMA

Depois da primeira manifestação de entusiasmo nas décadas de 1950 e 1960, a busca pela IA esfriou durante décadas. Nos últimos cinco anos, no entanto, houve avanços surpreendentes, principalmente no campo da aprendizagem de máquina, e a IA tornou-se um dos desenvolvimentos mais proeminentes da tecnologia. Surgiram muitas previsões utópicas ou apolíticas sobre o

significado desses avanços. Elas foram adotadas, literalmente, para pressagiar imortalidade ou o fim do mundo, e muito se escreveu sobre as duas possibilidades. Acredito que os desenvolvimentos em IA levaram a esses sentimentos fortes por causa do medo entranhado que sentimos dos quase humanos. A ideia de que as pessoas possam criar uma ponte para encurtar a distância entre o humano e o artificial sempre foi perturbadora, desde o Golem medieval, passando pelo monstro de Frankenstein, até Ava, a sedutora robótica fatal do filme *Ex-Máquina: instinto artificial*.

Mas os computadores realmente aprendem tão bem quanto os seres humanos? Quanto da inflamada retórica revela uma mudança revolucionária, e quanto é apenas espalhafato midiático? Pode ser difícil acompanhar os detalhes de como os computadores aprendem a identificar, por exemplo, um gato, uma palavra pronunciada, ou um ideograma japonês. Mas, numa análise mais profunda, as ideias básicas por trás da aprendizagem de máquina não são tão enigmáticas quanto podem parecer a princípio.

Uma abordagem tenta resolver o problema começando com um feixe de fótons e vibrações do ar que Augie e todos nós recebemos e que atingem o computador como pixels de uma imagem digital e padrões sonoros de uma gravação de áudio. Depois ela procura extrair uma série de padrões dos dados digitais capazes de detectar e identificar objetos inteiros do mundo que nos rodeia. Essa chamada abordagem “de baixo para cima” se baseia nas ideias de filósofos como David Hume e John Stuart Mill e psicólogos como Ivan Pavlov e B.F. Skinner, entre outros.

Nos anos 1980, cientistas descobriram uma forma engenhosa

EM SÍNTESE

Como crianças pequenas sabem o que sabem? Essa questão preocupou filósofos e psicólogos por muito tempo — e agora preocupa os cientistas da computação.

Especialistas em inteligência artificial estão estudando os poderes do raciocínio mental de crianças em idade pré-escolar para desenvolver formas de ensinar máquinas sobre o mundo.

Duas estratégias rivais de aprendizagem de máquina — as duas competindo na tentativa de imitar o que as crianças fazem naturalmente — começaram a transformar a IA como uma disciplina.

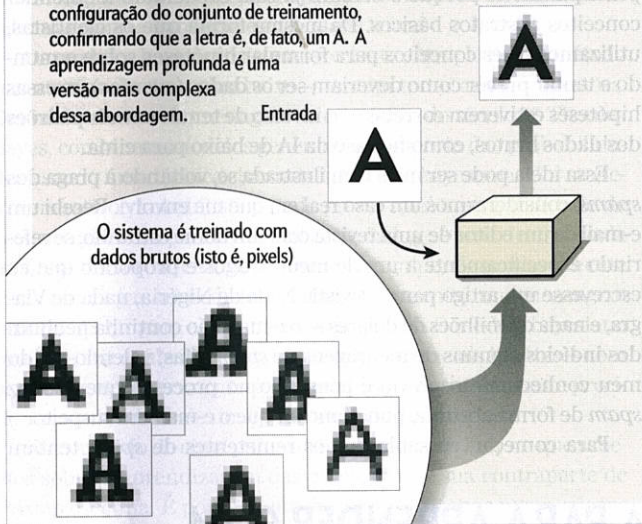
Dois caminhos para o ressurgimento da IA

Problemas que crianças na faixa dos cinco anos resolvem rapidamente podem confundir até os computadores mais poderosos. A IA realizou um movimento corajoso nos últimos anos ao ensinar computadores a aprender sobre o mundo de forma similar como as crianças aprendem. A máquina reconhece a letra “A” ou a partir de informação sensorial bruta — abordagem de baixo para cima —, ou a partir de pressupostos baseados em conhecimento preexistente — abordagem de cima para baixo.

De cima para baixo (aprendizagem profunda)

Exemplos da letra A ensinam um computador a distinguir padrões de pixels iluminados e escuros para várias versões da letra. Depois, quando a máquina recebe uma nova entrada, ela avalia se os pixels coincidem com a configuração do conjunto de treinamento, confirmando que a letra é, de fato, um A. A aprendizagem profunda é uma versão mais complexa dessa abordagem.

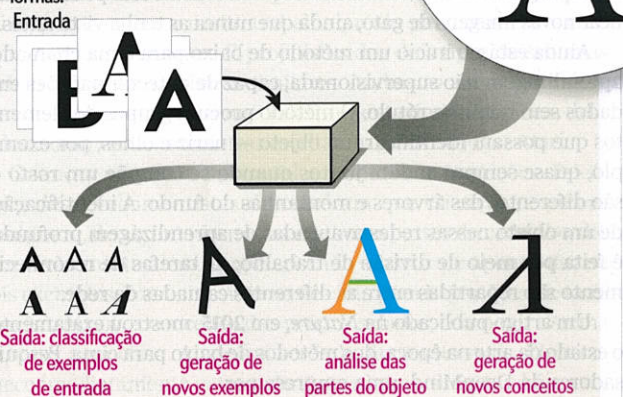
Saída: pixel por pixel, essa letra se parece com o conjunto de dados brutos de treinamento: portanto, ela é um A



De cima para baixo (métodos bayesianos)

Quando se usa métodos bayesianos, um único exemplo da letra A é suficiente para reconhecer exemplos similares. A máquina constrói um modelo de letra a partir de sua própria biblioteca interna de “partes”, montando uma figura formada por um ângulo agudo unido por um travessão, um A que pode então ser usado para identificar versões ligeiramente diferentes da letra ou modificá-la de várias formas.

O sistema é acionado com um exemplo de um novo conceito, suficiente para sustentar uma série de tarefas de saída



e irresistível de aplicar métodos de baixo para cima para permitir que os computadores caçassem padrões significativos nos dados. Sistemas chamados “conexionistas” ou “redes neurais” se inspiram na forma como os neurônios convertem padrões de luz em sua retina em representações do mundo que os rodeia. Uma rede neural faz algo similar. Ela utiliza elementos de processamento interconectados, semelhantes a células biológicas, para transformar pixels de uma camada da rede em representações cada vez mais abstratas — um nariz ou um rosto inteiro — à medida que os dados são processados em camadas sucessivamente mais altas.

As ideias sobre redes neurais passaram por uma recente revitalização por causa de novas técnicas chamadas aprendizagem profunda — tecnologia que agora está sendo comercializada pela Google, Facebook e outras gigantes da TI. O poder sempre crescente dos computadores — o crescimento exponencial da capacidade computacional previsto pela conhecida lei de Moore — também contribui para o novo sucesso desses sistemas. E isso ocorre também com o desenvolvimento de conjuntos de dados extremamente grandes. Com melhor capacidade de processamento e mais dados para digerir, os sistemas conexionistas podem aprender com muito mais eficiência que se imaginava.

Ao longo de anos, a comunidade de IA oscilou entre favorecer esses tipos de soluções de baixo para cima para a aprendizagem de máquina e abordagens alternativas “de cima para baixo”. As abordagens de cima para baixo alavancam o que um sistema já sabe

para ajudá-lo a aprender coisas novas. Platão e os filósofos racionalistas, como Descartes, acreditavam na aprendizagem de cima para baixo, que desempenhou um papel importante no início da IA. Na década de 2000 esses métodos também foram recriados na forma de modelagem probabilística ou bayesiana.

Como os cientistas, sistemas de cima para baixo também começam formulando hipóteses abstratas e amplas sobre o mundo e então pressupõem como deveriam ser os dados se essas hipóteses estiverem certas. Também como os cientistas, os sistemas então revisam suas hipóteses, conforme o resultado de suas previsões.

NIGÉRIA, VIAGRA E SPAM

Métodos de baixo para cima são, talvez, os mais rapidamente entendidos, por isso, vamos considerá-los primeiro. Imagine que você tenta fazer seu computador separar mensagens importantes misturadas a todos os e-mails de *spam* que chegam à sua caixa. É preciso observar que o *spam* geralmente tem certas características: longa lista de destinatários, endereço de remetente geralmente na Nigéria ou na Bulgária, referências a prêmios de US\$ 1 milhão, ou talvez uma propaganda do Viagra. Mas as mensagens legítimas podem parecer iguais. Você não quer perder o aviso de que ganhou uma promoção ou recebeu um prêmio acadêmico.

Se você comparar exemplos suficientes de *spam* com outros tipos de e-mails, notará que só o *spam* tende a ter elementos que se combinam de certas formas óbvias — por exemplo, Nigéria, jun-

FONTE: "NEURAL NETWORKS: CONCEPTS, EXAMINES THROUGH PROBABILISTIC PROGRAM INDUCTION" POR BRENDEN M. LAKE, RUSLAN SALAKHUTDINOV E JOSHUA B. TENENBAUM, EM SCIENCE, VOL. 350, 11 DE DEZEMBRO DE 2015 (exemplo bayesiano)

to com um pretensão prêmio de US\$ 1 milhão, sinaliza problemas. Na verdade, existem alguns outros padrões de nível mais alto, muito sutis, que diferenciam as mensagens de *spam* das legítimas — erros de ortografia e endereços de IP que não são nem um pouco óbvios, por exemplo. Se você pudesse detectá-los poderia filtrá-los do *spam* com grande precisão — sem receber não receber um aviso de que seu pedido de Viagra já foi expedido.

A aprendizagem de máquina de baixo para cima pode revelar pistas relevantes para resolver esse tipo de tarefa. Para isso, a rede neural precisa ser submetida ao seu próprio processo de aprendizagem. Ela analisa milhões de exemplos de gigantescas bases de dados, cada um rotulado como *spam* ou como e-mail autêntico. O programa então extrai um conjunto de elementos identificadores que separam o *spam* do resto.

De forma similar, a rede neural precisa inspecionar imagens da internet rotuladas como “gato”, “casa” e assim por diante. Ao extrair os elementos comuns de cada conjunto — o padrão que separa todos os gatos de todos os cachorros — a rede neural pode identificar novas imagens de gato, ainda que nunca as tenha visto antes.

Ainda está no início um método de baixo para cima chamado aprendizagem não supervisionada, capaz de detectar padrões em dados sem nenhum rótulo. O método procura grupos de elementos que possam identificar um objeto — nariz e olhos, por exemplo, quase sempre andam juntos quando se compõe um rosto e são diferentes das árvores e montanhas do fundo. A identificação de um objeto nessas redes avançadas de aprendizagem profunda é feita por meio de divisão de trabalho: as tarefas de reconhecimento são repartidas entre as diferentes camadas da rede.

Um artigo publicado na *Nature*, em 2015, mostrou exatamente o estado da arte na época, dos métodos de baixo para cima. Pesquisadores da DeepMind, uma empresa pertencente à Google, utilizaram uma combinação de duas diferentes técnicas de baixo para cima — aprendizagem profunda e aprendizado por reforço — para fazer um computador comandar os videogames Atari 2600. Inicialmente, o computador não sabe nada sobre o funcionamento de videogames. Então ele faz suposições aleatórias sobre os melhores movimentos e ao mesmo tempo recebe constante *feedback* de seu desempenho. A aprendizagem profunda ajudou o sistema a identificar os elementos na tela e o aprendizado por reforço recompensou-o pela alta pontuação. O computador atingiu um alto nível de proficiência em vários jogos. Em alguns casos, ele teve um desempenho melhor que experientes jogadores humanos. No entanto, ele também fracassou completamente em outros jogos tão simples como esses para os seres humanos.

A capacidade de aplicar IA para aprender a partir de grandes conjuntos de dados — milhões de imagens do Instagram, mensagens de e-mails ou gravações de voz — permite solucionar problemas que até então pareciam assustadores, como o reconhecimento de imagens e da linguagem. Mesmo assim, vale a pena lembrar que meu neto não tem a menor dificuldade em reconhecer um animal mesmo com dados e treinamento muito mais limitados. Problemas fáceis para uma criança de cinco anos ainda são muito complexos para os computadores e mais difíceis que jogar xadrez.

Computadores que aprendem a reconhecer uma cara peluda com bigodes geralmente precisam de milhões de exemplos para categorizar objetos que nós classificamos com poucos exemplos.

Depois de um treinamento intenso, o computador pode ser capaz de identificar a imagem de um gato que nunca tenha visto antes. Mas ele faz isso de formas completamente diferentes das generalizações feitas por seres humanos. Como o software do computador “pensa” de forma diferente, podem ocorrer erros. Algumas imagens de gatos poderão não estar rotuladas como gatos, ou ele pode incorretamente afirmar que uma imagem é um gato, embora seja apenas um borrão aleatório que não enganaria um humano.

SEMPRE PARA BAIXO

Outra abordagem da aprendizagem de máquina que transformou a IA nos últimos anos funciona no sentido oposto, de cima para baixo. Ela pressupõe que é possível extrair conhecimento abstrato de dados concretos, porque nós já sabemos muito, mas principalmente porque o cérebro já está capacitado a entender conceitos abstratos básicos. Da mesma forma que os cientistas, utilizamos esses conceitos para formular hipóteses sobre o mundo e tentar prever como deveriam ser os dados (eventos), se essas hipóteses estiverem corretas — o inverso de tentar extrair padrões dos dados brutos, como no caso da IA de baixo para cima.

Essa ideia pode ser mais bem ilustrada se, voltando à praga dos *spams*, considerarmos um caso real em que me envolvi. Recebi um e-mail de um editor de uma revista com um nome estranho, se referindo especificamente a um de meus artigos e propondo que eu escrevesse um artigo para a revista. Nada de Nigéria, nada de Viagra, e nada de milhões de dólares — o e-mail não continha nenhum dos indícios comuns de mensagens de *spam*. Mas, valendo-me do meu conhecimento prévio e pensando no processo que produz *spam* de forma abstrata, pude concluir que o e-mail era suspeito.

Para começar, eu sabia que os remetentes de *spam* tentam

APLICAR IA PARA APRENDER COM GRANDES CONJUNTOS DE DADOS PERMITE OBTER SOLUÇÕES PARA PROBLEMAS QUE ATÉ ENTÃO PARECIAM ASSUSTADORES.

obter dinheiro das pessoas apelando para a ganância humana — e quando se trata de publicar seus trabalhos, os acadêmicos podem ser tão gananciosos quanto as pessoas comuns são por ganhar um prêmio de US\$ 1 milhão ou conseguir melhor desempenho sexual. Eu também sabia que as revistas legítimas com “livre acesso” estavam começando a reduzir seus custos cobrando dos autores em vez de dos assinantes. Além disso, meu trabalho não tinha nada a ver com o título da revista. Juntando as peças, eu formulei uma hipótese plausível de que o e-mail estava tentando enganar os acadêmicos, induzindo-os a pagar para “publicar” seus artigos numa revista falsa. Cheguei a essa conclusão partindo de um único exemplo, e poderia testar ainda mais minha hipótese, checando a boafé do editor, apenas digitando várias perguntas num navegador.

Um cientista da computação poderia chamar meu processo de raciocínio de “modelo generativo”, que é capaz de representar conceitos abstratos, como ganância e falsidade. O mesmo modelo também pode descrever o processo usado para elaborar uma hipótese — o raciocínio que me levou à conclusão de que a mensagem poderia ser um e-mail fraudulento. O modelo me permite explicar como esse tipo de *spam* funciona, mas também per-

capaz antes. Geralmente, o computador não sabe reconhecer imagens, mas pode aprender a reconhecer padrões de evidência, em princípio, podem ser explicados por várias hipóteses diferentes. No meu caso, o e-mail realmente poderia ser legítimo, mas mesmo assim parecia improvável. Por isso, os modelos generativos precisam incorporar noções de probabilidades — um dos desenvolvimentos recentes mais importantes para esses métodos. Segunda, geralmente a origem dos conceitos básicos que formam os modelos generativos não é clara. Pensadores como Descartes e Chomsky sugeriram que nascemos com eles incorporados em nós, mas realmente chegamos a este mundo sabendo como a ganância e a falsidade levam a golpes?

Modelos generativos foram essenciais na primeira onda da IA nos anos 1950 e 1960. Mas eles também têm suas limitações. Primeira, padrões de evidência, em princípio, podem ser explicados por várias hipóteses diferentes. No meu caso, o e-mail realmente poderia ser legítimo, mas mesmo assim parecia improvável. Por isso, os modelos generativos precisam incorporar noções de probabilidades — um dos desenvolvimentos recentes mais importantes para esses métodos. Segunda, geralmente a origem dos conceitos básicos que formam os modelos generativos não é clara. Pensadores como Descartes e Chomsky sugeriram que nascemos com eles incorporados em nós, mas realmente chegamos a este mundo sabendo como a ganância e a falsidade levam a golpes?

Os modelos bayesianos — um excelente exemplo de um método recente tipo de cima para baixo — tentam tratar as duas questões. Denominados em homenagem ao estatístico do século 18 Thomas Bayes, combinam modelos generativos e a teoria das probabilidades usando uma técnica chamada inferência bayesiana. Um modelo generativo probabilístico pode prever qual a probabilidade de você perceber um padrão específico de dados, se uma determinada hipótese for verdadeira. Se o e-mail é um golpe, ele provavelmente apela para a ganância do leitor. Mas, obviamente, uma mensagem poderia apelar para a ganância sem ser *spam*. O modelo bayesiano combina seu conhecimento prévio sobre potenciais hipóteses com os dados que observa para poder calcular, de forma bastante precisa, a probabilidade de um e-mail ser legítimo ou *spam*.

Esse método de cima para baixo se encaixa melhor no que sabemos sobre a aprendizagem das crianças, que sua contraparte de baixo para cima. É por isso que nos últimos 15 anos meus colegas e eu usamos modelos bayesianos em nosso trabalho sobre desenvolvimento infantil. Nosso laboratório e outros usaram essas técnicas para entender como as crianças aprendem relações de causa e efeito, prever como e quando os jovens desenvolverão novas crenças sobre o mundo e quando eles mudarão as crenças já formadas.

Métodos bayesianos também são uma excelente forma de ensinar máquinas a aprender como pessoas. Em 2015, Joshua B. Tenenbaum, do Instituto de Tecnologia de Massachusetts, com quem eu às vezes colaboro, Branden M. Lake, da Universidade de Nova York, e seus colegas publicaram um estudo na *Science*. Eles projetaram um sistema de IA capaz de reconhecer letras manuscritas não familiares, uma atividade que é simples para as pessoas, mas extremamente complexa para os computadores.

Pense na sua capacidade de reconhecimento. Mesmo que nunca tivesse visto uma letra ou ideograma num pergaminho japonês, você saberia dizer se ela é igual ou diferente de outra em outro pergaminho. Provavelmente, você consegue desenhá-la ou até desenhar um ideograma falso, e também percebe que a letra é bem diferente de uma letra do alfabeto coreano ou russo. Foi isso que a equipe de Tenenbaum conseguiu que seu software fizesse. Com um método de baixo para cima, o programa poderia ser alimentado com milhares de exemplos e usaria os padrões encontrados para identificar novas letras. Em vez disso, o programa bayesiano mostrou à máquina um modelo geral de como desenhar uma letra. Por exemplo, um traço pode ir para a direita ou para a esquerda. E depois que o software termina uma letra, ele vai para a seguinte.

Ao ver uma dada letra, o programa podia inferir a sequência de

traços necessários para desenhá-la e produzir um conjunto similar de traços por si mesmo. Ele faz isso da mesma forma como eu inferi a série de passos que me conduziram ao e-mail de *spam* duvidoso. Em vez de avaliar a chance de o e-mail ter sido gerado por marketing fraudulento, o modelo de Tenenbaum prevê a chance de uma sequência específica de traços produzir a letra desejada. Esse programa de cima para baixo funcionava muito melhor que a aprendizagem profunda aplicada exatamente aos mesmos dados, e ele reproduzia fielmente o desempenho dos seres humanos.

UM CASAMENTO PERFEITO

Essas duas abordagens dominantes da aprendizagem de máquina — de baixo para cima e de cima para baixo — têm pontos fortes e fracos complementares. No método de baixo para cima, para começar, o computador não precisa entender nada sobre gatos, mas ele precisa de uma grande quantidade de informação.

O sistema bayesiano pode aprender com poucos exemplos e generalizar de forma mais ampla. Essa abordagem de cima para baixo, porém, requer muito trabalho prévio para articular o conjunto certo de hipóteses. E projetistas dos dois tipos de sistemas podem cair em armadilhas similares. Ambas as abordagens funcionam apenas em problemas relativamente limitados e bem definidos, como reconhecer letras escritas ou gatos ou jogar Atari.

Crianças não estão submetidas às mesmas restrições. Psicólogos desenvolvimentistas descobriram que crianças pequenas combinam, de alguma forma, as melhores partes de cada abordagem e vão muito além. Augie aprende a partir de apenas um ou dois exemplos, como um sistema de cima para baixo. Mas ele também extrai novos conceitos dos próprios dados, como um sistema de baixo para cima. Augie, na verdade, faz muito mais. Ele reconhece imediatamente gatos e distingue letras, mas também processa novas e criativas inferências surpreendentes que vão muito além de sua experiência ou conhecimento. Outro dia, explicou que se um adulto quisesse ser criança de novo ele deveria tentar não comer nenhuma verdura saudável, porque elas fazem as crianças crescerem e se tornarem adultas. Não temos praticamente nenhuma ideia de como esse tipo de raciocínio criativo é elaborado.

Poderíamos lembrar ainda dos misteriosos poderes da mente humana quando ouvimos afirmações de que IA é uma ameaça. A IA e a aprendizagem de máquina parecem assustadoras. E de algumas formas são. Os militares pesquisam formas de usar esses sistemas para controlar armas. A estupidez natural pode causar muito mais estragos que a IA, e nós, humanos, precisaremos ser muito mais inteligentes que fomos, no passado, para aproveitar bem as novas tecnologias. A lei de Moore é um elemento influente: mesmo que os avanços computacionais resultem do aumento quantitativo de dados e do poder dos computadores, e não de revoluções conceituais de nossa compreensão da mente, eles ainda poderão ter consequências práticas importantes. Com isso em mente, não deveríamos pensar que um novo Golem tecnológico esteja prestes a ser solto no mundo. ■

PARA CONHECER MAIS

The gardener and the carpenter: What the new science of child development tells us about the relationship between parents and children. Alison Gopnik, Farrar, Straus e Giroux, 2016.

Human-Level Concept Learning through Probabilistic Program Induction. Brenden Lake et al. em *Science*, vol. 350, págs. 1332-1338; 11 de dezembro de 2015.