

Como Devemos Definir Inteligência Artificial?



Em nossa primeira seção, nos familiarizaremos com o conceito de **Inteligência Artificial** que aqui chamaremos de **IA**, examinando sua definição e alguns exemplos.

Como você deve ter notado, a IA é atualmente um "tópico quente": a cobertura da mídia e a discussão pública sobre IA são quase impossíveis de evitar. No entanto, você também deve ter notado que a IA pode significar coisas diferentes para pessoas diferentes. Para alguns, IA está associada as formas de vida artificiais que podem ultrapassar a inteligência humana, e para outros, quase qualquer tecnologia de processamento de dados pode ser chamada IA.

Para definir o cenário, discutiremos o que é IA, como ela pode ser definida, e, quais outros campos ou tecnologias estão intimamente relacionados. Antes de fazermos isso, no entanto, vamos destacar três aplicações da IA que ilustram diferentes aspectos da IA. Voltaremos a cada um deles ao longo do curso, para aprofundarmos a nossa compreensão.

Aplicação 1. Carros autônomos



Os **carros autônomos** exigem uma combinação de várias técnicas de IA: busca e planejamento para encontrar a rota mais conveniente de A a B; visão computacional para identificar obstáculos; e tomada de decisão sob incerteza para lidar com o ambiente complexo e dinâmico. Cada um deles deve trabalhar com precisão quase perfeita para evitar acidentes.

As mesmas tecnologias também são usadas em outros sistemas autônomos, como robôs de entrega, drones e navios autônomos.

Implicações: a segurança no trânsito deve melhorar à medida que a confiabilidade dos sistemas ultrapassar o nível humano, bem como a eficiência das cadeias logísticas ao transportar mercadorias. Os humanos assumem um papel de supervisão, mantendo os olhos no que está acontecendo enquanto as máquinas cuidam da direção. Como o transporte é um elemento crucial em nossa vida cotidiana, é provável que também haja algumas implicações sobre as quais nós ainda nem pensamos.

Aplicação 2. Recomendação de Conteúdo




Muitas das informações que encontramos no decorrer de um dia típico são personalizadas. Exemplos incluem Facebook, Twitter, Instagram e outros conteúdos de mídias sociais; anúncios online; recomendações de música no Spotify; recomendações de filmes na Netflix, HBO e outros serviços de streaming. Muitos editores on-line, como sites de empresas de jornais e de radiodifusão, bem como mecanismos de pesquisa, como o Google, também personalizam o conteúdo que oferecem.

Embora a primeira página da versão impressa do New York Times ou do China Daily seja a mesma para todos os leitores, a primeira página da versão online é diferente para cada usuário. Os algoritmos que determinam o conteúdo que você vê são baseados em IA.

Implicações: Embora muitas empresas não queiram revelar os detalhes de seus algoritmos, o conhecimento dos princípios básicos ajuda a entender as possíveis implicações: envolvem as chamadas bolhas de filtro, câmaras de eco, fábricas de trolls, notícias falsas e novas formas de propaganda.


Aplicação 3. Processamento de imagem e vídeo



O **reconhecimento facial** já é uma commodity usada em muitos aplicativos, empresas e governos, como por exemplo: a organização de suas fotos de acordo com as pessoas, a marcação automática nas mídias sociais e o controle de passaportes. Técnicas semelhantes podem ser usadas para reconhecer outros carros e obstáculos em torno de um carro autônomo, ou para estimar populações de vida selvagem, apenas para citar alguns exemplos.

IA também pode ser usado para gerar ou alterar conteúdo visual. Os exemplos em uso atualmente incluem transferência de estilo, pelo qual você pode adaptar suas fotos pessoais para parecer que foram pintadas por Vincent Van Gogh, e personagens gerados por computador em filmes como Avatar, o Senhor dos Anéis e as populares animações da Pixar. Os personagens animados reproduzem gestos feitos por atores humanos reais.

A popularidade da IA na mídia está associada ao fato de que as pessoas começaram a usar o termo IA para definir coisas que nós costumávamos chamar por outros nomes. Você pode ver de tudo, desde estatísticas e análises de negócios, até regras codificadas manualmente, serem chamadas de IA. Por que isto acontece? Por que a percepção pública da IA é tão nebulosa? Vamos ver alguns motivos.



Razão 1: Sem definição oficial devidamente acordada

Mesmo os pesquisadores de IA não têm uma definição exata de IA. O campo está sendo constantemente redefinido quando alguns tópicos são classificados como não-IA, e novos tópicos emergem.

Há uma velha piada (nerd) de que IA é definida como “coisas legais que computadores não podem fazer”. A ironia é que, sob essa definição, a IA nunca pode fazer nenhum progresso: assim que

encontramos uma maneira de fazer algo legal com um computador, ele deixa de ser um problema de inteligência artificial. No entanto, há um elemento de verdade nesta definição. Cinquenta anos atrás, por exemplo, métodos automáticos de busca e planejamento eram considerados pertencentes ao domínio da IA. Hoje em dia, esses métodos são ensinados a todos os estudantes de ciência da computação. Da mesma forma, certos métodos para processar informações incertas estão se tornando tão bem compreendidos que provavelmente serão movidos da IA para a estatística ou para probabilidade muito em breve.



Razão 2: O legado da ficção científica

A confusão sobre o significado da IA é agravada pelas visões da IA presentes em várias obras literárias e cinematográficas de ficção científica. Histórias de ficção científica muitas vezes apresentam servos humanóides amigos que fornecem fatos excessivamente detalhados ou diálogos espirituosos, mas às vezes podem seguir os passos de Pinóquio e começarem a se perguntar se eles

podem se tornar humanos. Outra classe de seres humanóides na ficção científica defende motivos sinistros e se voltam contra seus senhores na veia de antigos contos de aprendizes de feiticeiros.

Frequentemente, a robustez de tais criaturas é apenas um verniz fino em cima de um agente muito humano, o que é compreensível, já que a maioria da ficção - até ficção científica - precisa ser identificada por leitores humanos que seriam alienados por uma inteligência muito diferente e estranha. A maior parte da ficção científica é, portanto, melhor lida como metáfora da atual condição humana, e os robôs poderiam ser vistos como substitutos de setores reprimidos da sociedade, ou talvez nossa busca pelo significado da vida.




Razão 3: o que parece fácil é realmente difícil...

Outra fonte de dificuldade para entender a IA é que é difícil saber quais tarefas são fáceis e quais são difíceis. Olhe ao redor e pegue um objeto em sua mão, então pense sobre o que você fez: você usou seus olhos para escanear seus arredores, descobriu onde estão alguns objetos adequados para pegar, escolheu um deles e planejou uma trajetória para sua mão. Chegou até ele, então, moveu sua mão contraindo vários músculos em sequência e conseguiu apertar o objeto com a quantidade certa de força para mantê-lo entre os dedos.

Pode ser difícil entender o quão complicado é tudo isso, mas às vezes fica visível quando algo dá errado: o objeto que você escolhe é muito mais pesado ou mais leve do que o esperado, ou alguém abre uma porta quando você está pegando a alça, e então você pode desequilibrar-se. Normalmente,

esse tipo de tarefa não requer esforço, mas esses sentimentos desmentem milhões de anos de evolução e vários anos de prática na infância.

Embora seja fácil para você agarrar objetos, para um robô essa é uma tarefa extremamente difícil e essa é uma das áreas de estudo e pesquisa ativos. Exemplos recentes incluem o projeto robótico do Google e um robô de colheita de couve-flor.



Razão 4: ... E o que parece difícil é fácil

Em contraste, as tarefas de jogar xadrez e resolver exercícios matemáticos podem parecer muito difíceis, exigindo anos de prática para dominar e envolver nossas “faculdades superiores” e concentrar o pensamento consciente. Não é de admirar que algumas pesquisas iniciais de IA tenham se concentrado nesse tipo de tarefa, e pode parecer que, na época, esse tipo de tarefa seja a essência da inteligência.

Desde então, o xadrez está muito bem adaptado aos computadores, que podem seguir regras bastante simples e calcular muitas sequências de movimentos alternativos a uma taxa de bilhões de cálculos por segundo. Os computadores derrotaram o atual campeão mundial humano no xadrez nos famosos combates Deep Blue vs Kasparov em 1997. Você poderia imaginar que o problema mais difícil acabou sendo pegar as peças e movê-las no tabuleiro sem derrubá-las! Estudaremos as técnicas usadas em jogos como xadrez ou jogo da velha no próximo capítulo.

Da mesma forma, enquanto o domínio profundo da matemática requer (o que parece) intuição e ingenuidade humana, muitos (mas não todos) exercícios de um curso típico de ensino médio ou universitário podem ser resolvidos aplicando-se uma calculadora e um conjunto simples de regras.

Então, qual seria uma definição mais útil?

Uma tentativa de definição mais útil do que a piada “o que os computadores não podem fazer ainda” seria listar propriedades que são características da IA, neste caso autonomia e adaptatividade.

Terminologia chave

Autonomia

A capacidade de executar tarefas em ambientes complexos sem orientação constante por um usuário.

Adaptabilidade

A capacidade de melhorar o desempenho aprendendo com a experiência.

As palavras podem ser enganosas

Ao definir e falar sobre IA, temos de ser cautelosos, pois muitas das palavras que usamos podem ser bastante enganosas. Exemplos comuns são: aprendizagem, compreensão e inteligência.

Você pode muito bem dizer, por exemplo, que um sistema é inteligente, talvez porque ele forneça instruções de navegações precisas ou detecta sinais de melanoma em fotografias de lesões de pele. Quando ouvimos algo assim, a palavra "inteligente" sugere facilmente que o sistema é capaz de realizar qualquer tarefa que uma pessoa inteligente possa realizar: ir ao supermercado e cozinhar o jantar, lavar e dobrar a roupa e assim por diante.

Da mesma forma, quando dizemos que um sistema de visão computacional entende imagens porque é capaz de segmentar uma imagem em objetos distintos como por exemplo: outros carros, pedestres, edifícios, estradas, etc., a palavra "entender" facilmente sugere que o sistema também entende que, mesmo que uma pessoa esteja usando uma camiseta com uma foto de uma estrada impressa, não haverá o problema em dirigir naquela estrada (e dirigir sobre a pessoa).

Em ambos os casos acima, estaríamos errados.

Nota

Cuidado com as "palavras-chave"

Marvin Minsk, um cientista cognitivo e um dos maiores pioneiros da IA, cunhou o termo palavra-chave para termos que carregam um monte de significados diferentes, mesmo que pretendamos usar apenas um deles. Usar esses termos aumenta o risco de interpretações erradas, como as interpretações realizadas acima.

É importante perceber que a inteligência não é uma dimensão única como a temperatura. Você pode comparar a temperatura de hoje com a de ontem, ou a temperatura em Salvador com a de Porto Alegre, e dizer qual é a mais alta e qual é a mais baixa. Nós até temos a tendência de pensar que é possível classificar as pessoas com relação à sua inteligência - isso é o que o quociente de inteligência (QI) deveria fazer. No entanto, no contexto da IA, é óbvio que diferentes sistemas de IA não podem ser comparados em um único eixo ou dimensão em termos de sua inteligência. Um algoritmo de jogo de xadrez é mais inteligente que um filtro de spam? Ou, um sistema de recomendação de música é mais inteligente do que um carro autônomo? Essas perguntas não fazem sentido. Isso ocorre porque a inteligência artificial é restrita (voltaremos ao significado de IA restrita no final deste capítulo): ser capaz de resolver um problema específico não nos diz nada sobre a capacidade de resolver outro problema diferente.

Por que não devemos utilizar o termo “Uma Inteligência Artificial”?



A classificação em IA vs não IA não é uma dicotomia “sim-não” absolutamente clara: enquanto alguns métodos são claramente pertencentes a IA e outros não são IA, existem também métodos que envolvem uma pitada de IA, como uma pitada de sal. Assim, às vezes seria mais apropriado falar sobre a "natureza", em vez de discutir se algo é IA ou não.

Nota

"IA" não é um substantivo contável

Ao discutir a IA, gostaríamos de desencorajar o uso da IA como um substantivo contável: uma IA, duas IAs e assim por diante. IA é uma disciplina científica, como matemática ou biologia. Isso significa que a IA é uma coleção de conceitos, problemas e métodos para resolvê-los.

Como a IA é uma disciplina, você não deveria dizer “uma IA”, assim como não dizemos “uma biologia”. Este ponto também deve ficar bem claro quando você tentar dizer algo como "precisamos de mais inteligências artificiais". Isso soa errado, não é?

Apesar de não concordarmos, o uso da IA como um substantivo contável é comum. Tomemos, por exemplo, a manchete “Os dados dos wearables ajudaram a ensinar uma IA a identificar sinais de diabetes”. É uma boa manchete, pois enfatiza a importância dos dados e deixa claro que o sistema

só detecta sinais de diabetes em vez de diagnosticar decisões de tratamento. E você definitivamente nunca deveria dizer algo como “a inteligência artificial do Google construiu uma IA que supera qualquer coisa feita por humanos”, a qual também é uma das manchetes de IA mais enganosas que já vimos (note que a manchete não é da equipe de Pesquisa do Google) .

O uso da IA como um substantivo contável não é um grande problema se o que está sendo dito faz sentido, mas se você quiser falar como um profissional, evite dizer "uma IA" e diga "um método de IA".

Campos Relacionados com a Inteligência Artificial

Além da IA, existem vários outros tópicos relacionados que devem ser conhecidos pelo menos pelo nome. Estes campos incluem: aprendizado de máquina, ciência de dados e aprendizado profundo.

Pode-se dizer que o aprendizado de máquina (Machine Learning) é um subcampo da IA, que em si é um subcampo da ciência da computação. (Tais categorias são frequentemente imprecisas e algumas partes do aprendizado de máquina podem ser igualmente pertencem à Estatística.) O aprendizado de máquina possibilita soluções de IA que são adaptativas. Uma definição concisa pode ser dada da seguinte forma:

Terminologia chave

Aprendizado de máquina (Machine Learning)

Sistemas que melhoram seu desempenho em uma determinada tarefa com mais e mais experiências ou dados.

O Aprendizado Profundo (Deep Learning)

É um subcampo do aprendizado de máquina, que em si é um subcampo da IA, que em si é um subcampo da ciência da computação. Encontraremos o conceito de aprendizado profundo (Deep Learning) com mais detalhes no Capítulo 5, mas, por enquanto, vamos notar que a “profundidade” da aprendizagem profunda refere-se à complexidade de um modelo matemático. E o aumento do poder computacional dos computadores modernos permitiu aos pesquisadores aumentar essa complexidade para atingir níveis que são não apenas quantitativamente, mas também qualitativamente diferentes de como eram antes. (Como você pode perceber, a ciência frequentemente envolve um número de subcampos progressivamente mais especiais, subcampos de subcampos e assim por diante. Isso permite que os pesquisadores ampliem um tópico em particular para que seja possível alcançar uma quantidade cada vez maior de conhecimentos acumulados

durante anos, e produzir novos conhecimentos sobre o tema ou, às vezes, até mesmo, corrigir o conhecimento anterior para ser mais preciso.)

A Ciência de Dados – Data Science


É um termo genérico recente (termo que abrange várias sub-disciplinas) que inclui aprendizado de máquina, matemática e estatística, certos aspectos da ciência da computação, incluindo algoritmos, armazenamento de dados e programação. A ciência de dados é também uma disciplina prática que requer compreensão do domínio no qual ela é aplicada, por exemplo, negócios ou ciência: seu propósito (o que significa "valor agregado"), suposições básicas e restrições. As soluções de ciência de dados geralmente envolvem pelo menos uma pitada de inteligência artificial (mas geralmente não tanto quanto se espera das manchetes).

Robótica significa construir e programar robôs para que eles possam operar em cenários complexos do mundo real. De certa forma, a robótica é o último desafio da IA, uma vez que, requer uma combinação de virtualidade em todas as áreas da IA. Por exemplo:

- **Visão computacional e reconhecimento de fala** para sentir o ambiente;
- **Processamento de linguagem natural**, recuperação de informações e raciocínio sob incerteza para o processamento de instruções e previsão de consequências de possíveis ações;
- **Modelagem cognitiva e computação afetiva** para interagir e trabalhar em conjunto com humanos;

Muitos dos problemas de IA relacionados à robótica são melhor abordados pelo aprendizado de máquina, o que torna o aprendizado de máquina uma ramificação central da IA para a robótica.

O que é um Robô?



Nota

O que é um robô?

Em suma, um robô é uma máquina que compreende sensores (que detectam o ambiente) e que atuam no ambiente após serem programados para executar seqüências de ações. As pessoas acostumadas a representações de robôs de ficção científica normalmente pensarão em máquinas humanóides andando com um andar desajeitado e falando em um tom metálico monótono. A maioria dos robôs reais atualmente em uso parece muito diferente, pois são projetados de acordo com o aplicativo. A maioria das aplicações não iria se beneficiar de o robô ter forma humana, assim como, não temos robôs humanóides para fazer nossa lavagem de louça, mas máquinas nas quais colocamos a louça para ser lavada por jatos de água.

Pode não ser óbvio à primeira vista, mas qualquer tipo de veículo que tenha pelo menos algum nível de autonomia e inclui sensores e atuadores também é considerado como robótica. Por outro lado, apenas as soluções baseadas em software, como o serviço de atendimento ao cliente chatbot, mesmo que às vezes sejam chamadas de 'robôs de software', não são consideradas como robótica (real).

A Filosofia da Inteligência Artificial

Teste de Turing

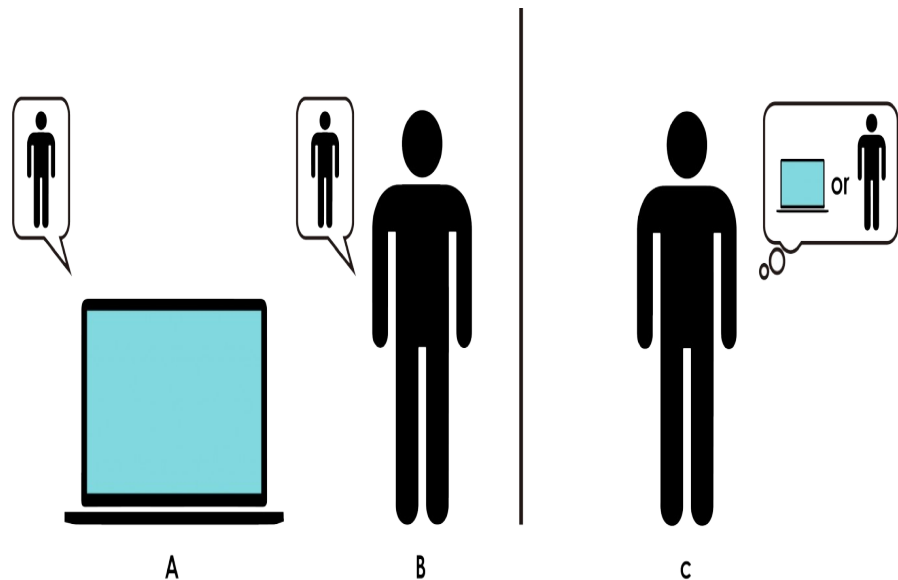
A Filosofia da Inteligência Artificial

A própria natureza do termo "inteligência artificial" levanta questões filosóficas se o comportamento inteligente implica ou requer a existência de uma mente, e em que medida a consciência é replicável como computação.

O Teste de Turing



Alan Turing



Turing Test

Alan Turing (1912-1954) foi um matemático e lógico inglês. Ele é legitimamente considerado o pai da ciência da computação. Turing era fascinado pela inteligência, pelo pensamento e pela possibilidade de simulá-los através de máquinas. A contribuição mais proeminente de Turing para a IA é o seu jogo de imitação, que mais tarde ficou conhecido como o teste de Turing.

No teste, um interrogador humano interage com dois jogadores, A e B, trocando mensagens escritas (em um bate-papo). Se o interrogador não puder determinar qual jogador, A ou B, é um computador e qual é um humano, o computador então passou no teste. O argumento é que, se um computador é indistinguível de um humano em uma conversa geral de linguagem natural, ele deve ter alcançado a inteligência no nível humano.

O que Turing quis dizer com o teste é muito semelhante ao aforismo citado no filme Forrest Gump: “a estupidez é tão estúpida quanto”. A versão de Turing seria "inteligente é tão inteligente quanto diz". Em outras palavras, uma entidade é inteligente se não puder ser distinguida de outra entidade inteligente pela observação de seu comportamento. Turing limitou-se a restringir o conjunto de comportamentos para que o interrogador não pudesse basear sua decisão nas aparências.

Um problema: ser humano significa que você é inteligente?

Uma das críticas ao teste de Turing como teste de inteligência é que ele pode realmente medir se o computador se comporta como um humano mais do que se é inteligente. O teste foi de fato "passado" por programas de computador que continuam mudando de assunto, causando muitos erros de ortografia e, às vezes, se recusando a responder.

Em 1950 Alan Turing publicou um artigo chamado “Computing Machine and Intelligence”. Neste artigo, Turing apresentou, pela primeira vez, o que hoje é conhecido por Teste de Turing, com o qual se pretendia descobrir se uma máquina podia ou não emular o pensamento humano. O Teste de Turing funciona da seguinte forma: um interrogador (humano) fará perguntas a duas entidades ocultas; uma delas é um humano e a outra é um computador. A comunicação entre o interrogador e as entidades é feita de modo indireto, pelo teclado, por exemplo. O interrogador tentará, através do “diálogo” realizado entre ele e as entidades, decidir qual dos dois é o humano. O computador será programado para se passar por humano e o humano responderá de forma a confirmar a sua condição. Se, no final do teste, o interrogador não conseguir distinguir quem é o humano, então conclui-se que o computador pode “pensar” segundo o Teste de Turing.

Em um de seus ensaios, Turing disse: “acredito que no fim do século o uso da palavra e a opinião geralmente educada terão se alterado tanto que alguém será capaz de falar de máquinas pensantes sem ser contraditado”. Porém já chegamos ao fim do século e entramos em outro e nenhuma máquina conseguiu passar, consistentemente, pelo Teste de Turing. Alguns computadores, devidamente programados, conseguiram passar por versões simplificadas do teste, contudo sempre esteve ausente o atributo mental do entendimento. Como Marvin Minsky, do MIT, disse: “o maior desafio é dar bom senso às máquinas, e bom senso é essencial para passar no Teste de Turing”. Russell e Norvig no clássico livro sobre Inteligência Artificial de 1995 (link na seção de bibliografias) observaram que programar um sistema de computador para passar no Teste de Turing é uma tarefa muito difícil. Tal sistema precisaria ter pelo menos as seguintes capacidades:

- Processamento de linguagem natural para se comunicar com o usuário;
- Representação de conhecimento para armazenar o que sabe ou aprende;
- Raciocínio automatizado para usar o conhecimento armazenado com a finalidade de responder perguntas ou tirar novas conclusões;

- Aprendizado de máquina para se adaptar a novas circunstâncias, detectar e extrapolar padrões, a fim de atualizar o seu conhecimento armazenado.

O Teste de Turing pode ser realizado de várias maneiras diferentes. Aqui o sucesso de uma máquina em induzir o concorrente a tratá-lo como humano seria tomado como prova de sua inteligência ou engenho.

A abordagem de Turing parece também enquadrar-se na tradição do “behaviorismo”, não apenas porque ele propôs um teste comportamental para a existência da mentalidade de máquina, mas também porque passar no Teste de Turing é suposto ser suficiente para justificar a existência da mentalidade. A máquina responder às perguntas de modo a induzir o competidor a adivinhar equivocadamente que a máquina é o humano, por exemplo, é visto como evidência suficientemente forte para justificar a conclusão de que a máquina possui mentalidade. Se ela passa pelo Teste de Turing, então ela possui uma mente, de acordo com esta concepção. Nesse sentido, a atribuição da mentalidade funciona como um modo abreviado de linguagem para a descrição do comportamento, onde atribuir essa propriedade não é cientificamente insignificante. Mas o Teste de Turing sempre sofreu críticas, uma vez que existem muitas maneiras de responder e interpretar as perguntas.

O Teste de Turing foi adaptado para o cinema em 2014, no filme *Ex Machina*.


A Filosofia da Inteligência Artificial

O Argumento da Sala Chinesa

A Filosofia da Inteligência Artificial

A própria natureza do termo "inteligência artificial" levanta questões filosóficas se o comportamento inteligente implica ou requer a existência de uma mente, e em que medida a consciência é replicável como computação.

O Argumento da Sala Chinesa



A ideia de que inteligência significa a mesma coisa que comportamento inteligente foi desafiada por alguns estudiosos. O contra-argumento mais conhecido é o experimento da Sala Chinesa, de John Searle. Searle descreve uma experiência em que uma pessoa que não conhece chinês está trancada em uma sala. Do lado de fora da sala existe uma pessoa que pode enviar notas escritas em chinês para dentro da sala através de um espaço para correspondência. A pessoa dentro da sala recebe um grande manual, onde ela pode encontrar instruções detalhadas para responder às anotações que ela recebe do lado de fora.

Searle argumentou que mesmo que a pessoa de fora da sala tenha a impressão de que ela esteja conversando com outra pessoa que fala chinês, a pessoa dentro da sala não entende chinês. Da mesma forma, seu argumento continua, mesmo que uma máquina se comporte de uma maneira inteligente, por exemplo, passando no teste de Turing, não podemos afirmar que ela seja inteligente ou que tenha uma "mente" semelhante a de um humano. A palavra "inteligente" também pode ser substituída pela palavra "consciente" e um argumento similar pode ser feito.

Um carro autônomo é inteligente?

O argumento da sala chinesa vai contra a noção de que a inteligência pode ser dividida em pequenas instruções mecânicas que podem ser automatizadas.

Um carro autônomo é um exemplo de um elemento de inteligência (dirigir um carro) que pode ser automatizado. O argumento da Sala Chinesa sugere que isso, no entanto, não seja realmente inteligente. Voltando à discussão acima o sistema de IA no carro não vê ou compreende seu ambiente, e não sabe dirigir com segurança, como um ser humano vê, compreende e sabe. De acordo com Searle, isso significa que o comportamento inteligente do sistema é fundamentalmente diferente de ser realmente inteligente.

Quanto a filosofia importa na prática?

A definição de inteligência, natural ou artificial, e consciência parecem ser extremamente evasivas e leva a um discurso aparentemente interminável. Em uma empresa intelectual, essa discussão pode ser bastante agradável. (Na falta de companhia adequada, livros como o “The Mind’s I” escrito por Hofstadter e Dennett podem oferecer estímulo).

No entanto, como John McCarthy apontou, “a filosofia da IA” provavelmente não terá mais efeito na prática da pesquisa da IA do que a filosofia da ciência geralmente tem na prática da ciência”. Assim, continuaremos investigando sistemas que são úteis na resolução de problemas práticos sem perguntar muito se eles são inteligentes ou apenas se comportam como se fossem.

Terminologia chave

IA Geral vs IA Restrita

Ao ler as notícias, você pode ver os termos IA "geral" e IA "restrita". Então, o que isso significa? IA restrita refere-se a IA que lida com apenas uma tarefa. E IA Geral, ou Inteligência Artificial Geral (IAG) refere-se a uma máquina que pode lidar com qualquer tarefa intelectual. Todos os métodos de inteligência artificial que usamos hoje se enquadram na inteligência artificial restrita. A IA Geral está associada ao campo da ficção científica. De fato, o ideal da IAG foi praticamente abandonado pelos pesquisadores da IA devido à falta de progresso em relação a ela em mais de 50 anos, apesar de todo o esforço. Em contraste, a inteligência artificial restrita ainda avança a passos curtos.

IA forte versus IA fraca

Uma dicotomia está relacionada ao conceito de IA "forte" e "fraca". Isso se resume à distinção filosófica acima entre o que é ser inteligente e como agir de forma inteligente, que foi difundida por Searle. **IA forte** seria uma "mente" genuinamente inteligente e autoconsciente. Enquanto a **IA fraca** é o que realmente temos, ou seja, sistemas que exibem comportamentos inteligentes, apesar de serem “meros” computadores.

O Que a IA Pode e (Ainda) Não Pode Fazer?

A Inteligência Artificial (IA) parece estar em todo lugar. Nós experimentamos a IA em casa e em nossos telefones. Mais rápido do que imaginamos, a IA estará em praticamente todos os produtos e serviços que compramos e usamos. Além disso, sua aplicação à solução de problemas de negócios está crescendo e, ao mesmo tempo, as preocupações com as implicações da IA estão aumentando, levando a discussões sobre o impacto da automação habilitada pela IA no local de trabalho, no lazer e na sociedade.

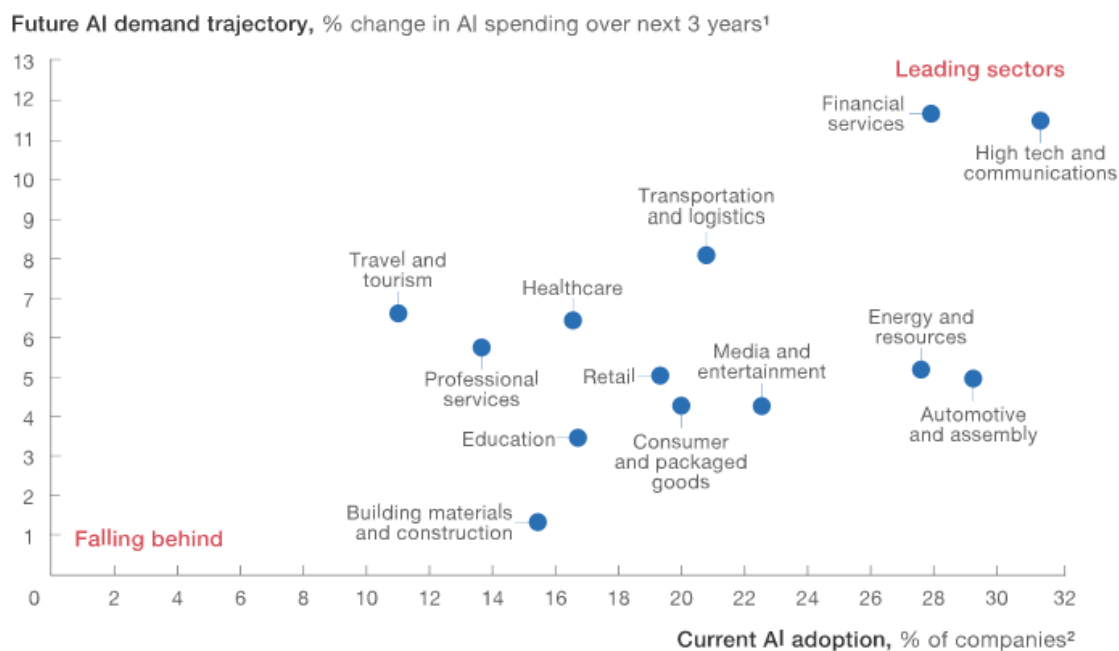
A consultoria McKinsey realizou um grande estudo para ajudar executivos e gestores a compreenderem O Que a IA Pode e (ainda) Não Pode Fazer Pelo Seu Negócio, estudo este que trazemos agora para você. Leia com atenção, fuja do hype e compreenda claramente o impacto atual e futuro da IA.

Relatório McKinsey

Uma realidade às vezes perdida entre os medos e os triunfos das manchetes, como Alexa, Siri e AlphaGo, é que as próprias tecnologias de IA – ou seja, aprendizado de máquina e seu subconjunto – aprendizado profundo (Deep Learning) – têm muitas limitações que ainda exigirão um esforço considerável para superar. Este é um artigo sobre essas limitações, cujo objetivo é ajudar os executivos a entender melhor o que pode estar atrapalhando seus esforços de IA. Ao longo do caminho, também destacaremos os avanços promissores que estão preparados para abordar algumas das limitações e criar uma nova onda de oportunidades.

Nossas perspectivas se baseiam em uma combinação de trabalho nas linhas de frente – pesquisando, analisando e avaliando centenas de casos de uso do mundo real – e em nossas colaborações com alguns líderes de pensamento, cientistas pioneiros e engenheiros que trabalham nas fronteiras da IA. Procuramos destilar essa experiência para ajudar os executivos que, em nossa experiência, estão expostos apenas a suas próprias iniciativas e não estão bem calibrados sobre onde está a fronteira ou o que os determinantes do ritmo já estão fazendo com a IA.

Simplificando, os desafios e as limitações da IA estão criando um problema de “alvo em movimento” para os líderes: é difícil alcançar uma vantagem significativa com uma tecnologia que esteja sempre avançando. Também é decepcionante quando os esforços da IA se deparam com barreiras do mundo real, o que pode diminuir o apetite por mais investimentos ou encorajar uma atitude de esperar para ver, enquanto outros avançam. Como indica a pesquisa recente do McKinsey Global Institute, há uma grande diferença entre os líderes e os retardatários na aplicação da IA nos mais variados setores.



¹Estimated average, weighted by company size; demand trajectory based on midpoint of range selected by survey respondent.

²Adopting 1 or more AI technologies at scale or in business core; weighted by company size.

Source: McKinsey Global Institute AI adoption and use survey; McKinsey Global Institute analysis

McKinsey&Company

Os executivos que desejam diminuir a distância devem ser capazes de abordar a IA de maneira informada. Em outras palavras, eles precisam entender não apenas onde a IA pode impulsionar a inovação, a percepção e a tomada de decisões, levar ao crescimento da receita e aumentar a eficiência, mas também onde a IA ainda não pode fornecer valor. Além disso, devem apreciar o relacionamento e as distinções entre restrições técnicas e organizacionais, como barreiras culturais, uma escassez de pessoal capaz de criar aplicativos prontos para uso e com inteligência artificial e o desafio da “última milha” de incorporar a IA em produtos e processos. Se você quiser se tornar um líder que entenda alguns dos desafios técnicos críticos que estão retardando o avanço da IA e esteja

preparado para explorar desenvolvimentos promissores que possam superar essas limitações e potencialmente dobrar a trajetória da IA – continue a ler.

Desafios, Limitações e Oportunidades

Um ponto de partida útil é entender os avanços recentes nas técnicas de aprendizagem profunda. Indiscutivelmente os desenvolvimentos mais empolgantes da IA, esses avanços estão gerando saltos na precisão da classificação e previsão, e estão sendo feitos sem a usual “engenharia de recursos” (Feature Engineering) associada ao aprendizado supervisionado tradicional. O aprendizado profundo usa redes neurais de grande escala que podem conter milhões de “neurônios” simulados estruturados em camadas. As redes mais comuns são chamadas Redes Neurais Convolucionais (CNNs) e Redes Neurais Recorrentes (RNNs). Essas redes neurais aprendem através do uso de dados de treinamento e algoritmos de backpropagation.

Embora muito progresso tenha sido feito, mais ainda precisa acontecer. Um passo crítico é adequar a abordagem da IA ao problema e à disponibilidade de dados. Como esses sistemas são “treinados” em vez de programados, os vários processos geralmente exigem grandes quantidades de dados rotulados para executar tarefas complexas com precisão. Obter grandes conjuntos de dados pode ser difícil. Em alguns domínios, eles podem simplesmente não estar disponíveis, mas, mesmo quando disponíveis, os esforços de rotulagem podem exigir enormes recursos humanos.

Além disso, pode ser difícil discernir como um modelo matemático treinado por aprendizado profundo chega a uma previsão, recomendação ou decisão específica. Uma caixa preta, mesmo aquela que faz o que deveria, pode ter utilidade limitada, especialmente quando as previsões ou decisões afetam a sociedade e mantêm ramificações que podem afetar o bem-estar individual. Nesses casos, os usuários às vezes precisam conhecer os “porquês” por trás do funcionamento, por exemplo, porque um algoritmo alcançou suas recomendações – desde descobertas factuais com repercussões legais até decisões de negócios, como empréstimos, que tenham repercussões regulatórias – e porquê – certos fatores (e não outros) eram tão críticos em um dado momento.

Vamos explorar cinco formas interconectadas em que essas limitações e as soluções que surgem para resolvê-las estão começando a acontecer.

Limitação 1: Rotulagem de Dados

A maioria dos modelos atuais de IA é treinada por meio de “aprendizado supervisionado”. Isso significa que os humanos devem rotular e categorizar os dados, o que pode ser uma tarefa considerável e propensa a erros. Por exemplo, as empresas que desenvolvem tecnologias de veículos autônomos estão contratando centenas de pessoas para anotar manualmente horas de vídeo

de protótipos de veículos para ajudar a treinar esses sistemas. Ao mesmo tempo, novas técnicas promissoras estão surgindo, como a supervisão in-stream (demonstrada por Eric Horvitz e seus colegas da Microsoft Research), na qual os dados podem ser rotulados no curso do uso natural. Abordagens não supervisionadas ou semi-supervisionadas reduzem a necessidade de grandes conjuntos de dados rotulados. Duas técnicas promissoras são o Aprendizado por Reforço e as Generative Adversarial Networks (GANs).

Vamos discutir primeiro o Aprendizado por Reforço. Esta técnica não supervisionada permite que os algoritmos aprendam tarefas simplesmente por tentativa e erro. A metodologia se refere a uma abordagem de “carrot and stick”: para cada tentativa de um algoritmo em realizar uma tarefa, ele recebe uma “recompensa” (como uma pontuação mais alta) se o comportamento for bem-sucedido ou uma “punição” se não for. Com a repetição, o desempenho melhora, em muitos casos, superando as capacidades humanas – desde que o ambiente de aprendizado seja representativo do mundo real.

Aprendizado por Reforço tem sido usado para treinar computadores para jogar – mais recentemente, em conjunto com técnicas de aprendizagem profunda (Deep Learning). Em maio de 2017, por exemplo, ajudou o sistema AlphaGo a derrotar o campeão mundial Ke Jie no jogo Go. Em outro exemplo, a Microsoft colocou em campo serviços de decisão que se baseiam no aprendizado por reforço e se adaptam às preferências do usuário. A aplicação potencial da aprendizagem de reforço atravessa muitas áreas de negócios. As possibilidades incluem uma carteira de negociação acionada por Inteligência Artificial que adquire ou perde pontos por ganhos ou perdas de valor, respectivamente; um mecanismo de recomendação de produtos que recebe pontos para cada venda orientada por recomendação; e software de roteamento de caminhões que recebe uma recompensa por entregas no prazo ou redução do consumo de combustível.

O aprendizado por reforço também pode ajudar a IA a transcender as limitações naturais e sociais da rotulagem humana, desenvolvendo soluções e estratégias previamente inimagináveis que até mesmo profissionais experientes poderiam nunca ter considerado. Recentemente, por exemplo, o sistema AlphaGo Zero, usando uma nova forma de aprendizado por reforço, derrotou seu predecessor AlphaGo depois de aprender a jogar Go do zero. Isso significava começar com um jogo completamente aleatório em vez de treinar em jogos de Go jogados por e com humanos.

Generative Adversarial Networks (GANs). Neste método de aprendizado semi-supervisionado, duas redes competem entre si para melhorar e aperfeiçoar sua compreensão de um conceito. Para reconhecer como as aves se parecem, por exemplo, uma rede tenta distinguir entre imagens genuínas e falsas de aves, e sua rede oposta tenta enganá-la produzindo imagens que se parecem muito com imagens de pássaros, mas não são. À medida que as duas redes se aproximam, a representação de cada modelo de um pássaro se torna mais precisa.

A capacidade das GANs de gerar exemplos cada vez mais confiáveis de dados pode reduzir significativamente a necessidade de conjuntos de dados rotulados por seres humanos. Treinar um

algoritmo para identificar diferentes tipos de tumores a partir de imagens médicas, por exemplo, normalmente exigiria milhões de imagens marcadas com humanos com o tipo ou estágio de um dado tumor. Usando um GAN treinado para gerar imagens cada vez mais realistas de diferentes tipos de tumores, os pesquisadores poderiam treinar um algoritmo de detecção de tumor que combina um conjunto de dados muito menor, com identificação humana, com a saída da GAN.

Embora a aplicação de GANs em diagnósticos precisos de doenças ainda esteja distante, os pesquisadores começaram a usar as GANs em contextos cada vez mais sofisticados. Estes incluem a compreensão e produção de obras de arte no estilo de um artista em particular e o uso de imagens de satélite, juntamente com uma compreensão das características geográficas, para criar mapas atualizados de áreas em rápido desenvolvimento.

Limitação 2: Obtendo Conjuntos de Dados Massivos Para Treinamento

Já foi demonstrado que técnicas simples de IA usando modelos lineares podem, em alguns casos, aproximar o poder de especialistas em medicina e outros campos. A onda atual de aprendizado de máquina, no entanto, requer conjuntos de dados de treinamento que não são apenas rotulados, mas também suficientemente grandes e abrangentes. Os métodos de aprendizagem profunda exigem milhares de registros de dados para que os modelos se tornem relativamente bons em tarefas de classificação e, em alguns casos, milhões para que eles desempenhem no nível de humanos.

A complicação é que conjuntos de dados massivos podem ser difíceis de obter ou criar para muitos casos de uso de negócios (pense: dados limitados de ensaios clínicos para prever os resultados do tratamento com mais precisão). E cada pequena variação em uma tarefa atribuída poderia exigir outro grande conjunto de dados para conduzir ainda mais treinamento. Por exemplo, ensinar um veículo autônomo a navegar em um local de mineração, onde o clima muda continuamente, exigirá um conjunto de dados que englobe as diferentes condições ambientais que o veículo possa encontrar.

O aprendizado de uma única vez é uma técnica que pode reduzir a necessidade de grandes conjuntos de dados, permitindo que um modelo de IA aprenda sobre um assunto quando recebe um pequeno número de demonstrações ou exemplos reais (até mesmo um, em alguns casos). Os recursos da IA se aproximarão dos recursos humanos, que podem reconhecer várias instâncias de uma categoria com relativa precisão depois de terem sido mostradas apenas uma única amostra – por exemplo, de uma caminhonete. Nesta metodologia ainda em desenvolvimento, os Cientistas de Dados primeiro pré-treinarão um modelo em um ambiente virtual simulado que apresentasse variantes de uma tarefa ou, no caso de reconhecimento de imagem, do aspecto de um objeto. Então, depois de mostrar apenas algumas variações do mundo real que o modelo de IA não viu no treinamento virtual, o modelo utilizaria seu conhecimento para alcançar a solução correta.

Esse tipo de aprendizado de uma única vez pode ajudar a alimentar um sistema para digitalizar textos por violações de direitos autorais ou para identificar um logotipo corporativo em um vídeo depois de mostrar apenas um exemplo rotulado. Hoje, esses aplicativos estão apenas em seus estágios iniciais, mas sua utilidade e eficiência podem expandir rapidamente o uso da Inteligência Artificial em vários setores.

Limitação 3: O Problema da Explicabilidade

A explicabilidade não é uma questão nova para os sistemas de IA, mas ela cresceu junto com o sucesso e a adoção do aprendizado profundo, o que deu origem tanto a aplicações mais diversas e avançadas quanto a mais opacidade. Modelos maiores e mais complexos tornam difícil explicar, em termos humanos, por que uma determinada decisão foi tomada (e ainda mais difícil quando foi alcançada em tempo real). Esse é um dos motivos pelos quais a adoção de algumas ferramentas de Inteligência Artificial permanece baixa nas áreas de aplicação, nas quais a capacidade de explicação é útil ou necessária. Além disso, à medida que a aplicação da IA se expande, os requisitos regulatórios também podem impulsionar a necessidade de modelos de IA mais explicáveis.

Dois abordagens nascentes que prometem aumentar a transparência do modelo são as técnicas explícitas local-interpretável-modelo-agnóstico (LIME) e técnicas de atenção. O LIME tenta identificar em quais partes dos dados de entrada um modelo treinado mais depende para fazer previsões no desenvolvimento de um modelo interpretável de proxy. Essa técnica considera certos segmentos de dados de cada vez e observa as mudanças resultantes na previsão para ajustar o modelo de proxy e desenvolver uma interpretação mais refinada (por exemplo, excluindo olhos em vez de, digamos, narizes para testar quais são mais importantes para reconhecimento facial). As técnicas de atenção visualizam as partes de dados de entrada que um modelo considera mais quando toma uma decisão em particular (como se concentrar em uma boca para determinar se uma imagem representa um ser humano).

LIME¹ is a sensitivity analysis that reveals which parts of an input matter most to the eventual output.

Turning off all but a few interpretable components of this image reveals the probability that the model will identify ...

- ... a tree frog 54%
- ... billiard balls 7%
- ... a balloon 5%

Attention shines a spotlight on where the model is looking when it makes a particular decision.

Words relevant to **food quality** ...

The fajita we tried was **tasteless** and **burned** and the **mole sauce** was **way too sweet**.

... or to **service**

They have one of the **fastest delivery times** in the **city**.

¹LIME = local-interpretable-model-agnostic explanations.
Source: Carlos Guestrin, Marco Tulio Ribeiro, and Sameer Singh, "Introduction to local interpretable model-agnostic explanations (LIME)," August 12, 2016, O'Reilly, oreilly.com; Minlie Huang, Yequan Wang, Li Zhao, and Xiaoyan Zhu, "Attention-based LSTM for aspect-level sentiment classification," Tsinghua University; Pixabay

O outra técnica que tem sido usada há algum tempo é a aplicação de modelos aditivos generalizados (GAMs). Ao usar modelos de recurso único, os GAMs limitam as interações entre os recursos, tornando cada um deles mais facilmente interpretável pelos usuários. Espera-se que o emprego dessas técnicas, entre outras, para desmistificar as decisões de IA, aumente a adoção da IA.

Limitação 4: Generalização da Aprendizagem

Ao contrário da maneira como os humanos aprendem, os modelos de IA têm dificuldade em levar suas experiências de um conjunto de circunstâncias para outro. Na verdade, o que quer que um modelo tenha alcançado para um dado caso de uso permanece aplicável somente àquele caso de uso. Como resultado, as empresas devem comprometer repetidamente recursos para treinar ainda outro modelo, mesmo quando os casos de uso são muito semelhantes.

Uma resposta promissora para esse desafio é a transferência de aprendizagem. Nessa abordagem, um modelo de IA é treinado para realizar uma determinada tarefa e, em seguida, aplica rapidamente esse aprendizado a uma atividade semelhante, porém distinta. Os pesquisadores da DeepMind também mostraram resultados promissores com transferência de aprendizagem em experimentos em que o treinamento feito em simulação é então transferido para braços robóticos reais.

À medida que a transferência de aprendizagem e outras abordagens generalizadas amadurecem, elas podem ajudar as organizações a criar novos aplicativos mais rapidamente e imbuir os aplicativos existentes com funcionalidades mais diversificadas. Ao criar um assistente pessoal virtual, por exemplo, a transferência de aprendizagem pode generalizar as preferências do usuário em uma área (como música) para outras pessoas (livros). A transferência de aprendizagem pode permitir que um produtor de óleo e gás, por exemplo, expanda seu uso de algoritmos de IA treinados para fornecer manutenção preditiva para poços a outros equipamentos, como tubulações e plataformas de perfuração. A transferência de aprendizagem tem o potencial de revolucionar a inteligência de negócios: considere uma ferramenta de análise de dados que compreenda como otimizar as receitas das companhias aéreas e, em seguida, adapte seu modelo às mudanças no clima ou na economia local.

Outra abordagem é o uso de algo que se aproxima de uma estrutura generalizada que pode ser aplicada em vários problemas. O AlphaZero da DeepMind, por exemplo, fez uso da mesma estrutura para três jogos diferentes: foi possível treinar um novo modelo com essa estrutura generalizada para aprender xadrez em um único dia, e então bateu um programa de xadrez campeão mundial.

Finalmente, considere as possibilidades em técnicas emergentes de meta-aprendizagem que tentam automatizar o design de modelos de aprendizado de máquina. A equipe do Google Brain, por exemplo, usa o AutoML para automatizar o design de redes neurais para classificar imagens em conjuntos de dados de grande escala. Essas técnicas agora funcionam tão bem quanto as projetadas por humanos. Esse é um desenvolvimento promissor, especialmente porque o talento continua a ser

escasso para muitas organizações. Também é possível que as abordagens de meta-aprendizagem ultrapassem as capacidades humanas e produzam resultados ainda melhores. Importante, no entanto, essas técnicas ainda estão em seus primeiros dias e muitas oportunidades surgirão.

Limitação 5: Viés em Dados e Algoritmos

Até agora, nos concentramos em limitações que podem ser superadas por meio de soluções técnicas já em andamento, algumas das quais descrevemos. O viés é um tipo diferente de desafio. As repercussões sociais potencialmente devastadoras podem surgir quando as predileções humanas (conscientes ou inconscientes) são utilizadas na escolha de quais dados apontam para o uso e quais devem ser desconsiderados. Além disso, quando o processo e a frequência da coleta de dados são desiguais entre grupos e comportamentos observados, é fácil que surjam problemas na forma como os algoritmos analisam esses dados, aprendem e fazem previsões. Consequências negativas podem incluir decisões de recrutamento mal informadas, dados científicos ou prognósticos médicos, modelos financeiros distorcidos e decisões de justiça criminal mal aplicados nas escalas legais. Em muitos casos, esses vieses passam despercebidos ou são desconsiderados sob o véu das “ciências de dados avançadas”, “dados e algoritmos proprietários” ou “análise objetiva”.

À medida que implantamos o aprendizado de máquina e os algoritmos de IA em novas áreas, provavelmente haverá mais instâncias em que essas questões de potencial viés sejam incorporadas em conjuntos de dados e algoritmos. Esses vieses tendem a permanecer incorporados porque reconhecê-los e tomar medidas para resolvê-los exige um profundo domínio das técnicas de ciência de dados, bem como uma meta-compreensão das forças sociais existentes, incluindo a coleta de dados. Ao todo, a desmembramento está provando estar entre os obstáculos mais intimidantes e, certamente, os mais preocupantes socialmente até hoje.

Existem agora vários esforços de pesquisa em andamento, bem como esforços para capturar as melhores práticas, que abordam essas questões em pesquisas acadêmicas, sem fins lucrativos e do setor privado. Não é cedo demais, porque o desafio provavelmente se tornará ainda mais crítico, e mais perguntas surgirão. Considere, por exemplo, o fato de que muitas dessas abordagens preditivas baseadas em aprendizado pressupõem implicitamente que o futuro será como o passado. O que devemos fazer em contextos socioculturais onde os esforços estão em andamento para estimular a mudança – e onde tomar decisões baseadas em comportamentos passados poderia inibir o progresso (ou, pior ainda, construir resistência à mudança)? Uma ampla variedade de líderes, incluindo líderes empresariais, pode em breve ser chamada para responder a essas perguntas.

Acertando o Alvo em Movimento

Soluções para as limitações que descrevemos, juntamente com a implementação comercial generalizada de muitos dos avanços descritos aqui, podem estar a anos de distância. Mas a gama de possibilidades de tirar o fôlego da adoção da IA sugere que a maior restrição para a IA pode ser a imaginação. Aqui estão algumas sugestões para os líderes que estão se esforçando para ficar à frente – ou pelo menos não ficarem muito atrás – da curva:

Faça o seu dever de casa e pesquise. Embora a maioria dos executivos não precise saber a diferença entre redes neurais convolucionais e recorrentes, você deve ter uma familiaridade geral com os recursos das ferramentas de hoje, um senso de onde os avanços de curto prazo provavelmente ocorrerão e uma perspectiva sobre o que está além do horizonte. Entre em contato com seus especialistas em ciência de dados e aprendizado de máquina, converse com alguns pioneiros da IA e participe de uma ou duas conferências de IA para ajudá-lo a obter os fatos reais; as agências de notícias podem ser úteis, mas também podem fazer parte da máquina do hype. Estudos de acompanhamento em curso por profissionais experientes, como o AI Index (um estudo do One-Year Studies on Artificial Intelligence, baseado em Stanford), são outra forma útil de manter-se informado.

Adote uma estratégia de dados sofisticada. Os algoritmos de IA precisam de assistência para desbloquear as informações valiosas que se escondem nos dados gerados por seus sistemas. Você pode ajudar desenvolvendo uma estratégia de dados abrangente que se concentra não apenas na tecnologia necessária para reunir dados de sistemas diferentes, mas também na disponibilidade e aquisição de dados, na rotulagem de dados e na governança de dados. Embora novas técnicas prometam reduzir a quantidade de dados necessários para o treinamento de algoritmos de Inteligência Artificial, o aprendizado supervisionado e sedento de dados continua a ser a técnica mais prevalente atualmente. E mesmo técnicas que visam minimizar a quantidade de dados necessários ainda precisam de alguns dados. Portanto, uma parte fundamental disso é conhecer completamente seus próprios pontos de dados e como aproveitá-los.

Pense lateralmente. As técnicas de aprendizado por transferência permanecem em sua infância, mas existem maneiras de alavancar uma solução de IA em mais de uma área. Se você resolver um problema como manutenção preditiva para grandes equipamentos de depósito, você também pode aplicar a mesma solução a produtos de consumo? Uma solução eficaz de próximo produto a comprar pode ser usada em mais de um canal de distribuição? Incentive as unidades de negócios a compartilhar conhecimento que possa revelar maneiras de usar suas melhores soluções de Inteligência Artificial e pensar em mais de uma área da empresa.

Seja um pioneiro. Manter-se atualizado com as tecnologias atuais de IA e os casos de uso não é suficiente para permanecer competitivo por um longo período. Envolve sua equipe de ciência de dados ou parceiro com especialistas externos para resolver um caso de uso de alto impacto com técnicas nascentes, como as discutidas neste artigo, que estão prestes a avançar. Além disso, mantenha-se informado sobre o que é possível e o que está disponível. Muitas ferramentas de aprendizado de máquina, conjuntos de dados e modelos treinados para aplicativos padrões (incluindo detecção de fala, visão e emoção) estão sendo amplamente disponibilizados. Às vezes eles vêm em código aberto e em outros casos por meio de interfaces de programação de aplicativos (APIs) criadas por pesquisadores e empresas pioneiras. Fique de olho em tais possibilidades para aumentar suas chances de apostar em uma vantagem pioneira ou adoção antecipada.

A promessa da IA é imensa, e as tecnologias, ferramentas e processos necessários para cumprir essa promessa não chegaram completamente. Se você acha que pode deixar a tecnologia se desenvolver e ser um seguidor rápido e bem-sucedido, pense novamente. É muito difícil acertar o alvo, principalmente quando o alvo está se movendo tão rapidamente e você não entende o que as ferramentas de Inteligência Artificial podem e não podem fazer agora. Com os pesquisadores e os pioneiros da IA prontos para resolver alguns dos problemas mais espinhosos de hoje, é hora de começar a entender o que está acontecendo na fronteira da Inteligência Artificial para posicionar sua organização para aprender, explorar e talvez até avançar em novas possibilidades.