



Seis etapas para o sucesso com machine learning

O caminho para aproveitar ao máximo
o potencial do machine learning



INTRODUÇÃO

O avanço rumo ao machine learning

Quando implantados com a estratégia correta, a inteligência artificial (IA) e o machine learning (ML) podem ampliar a agilidade, otimizar processos e aumentar a receita por meio do desenvolvimento de novos produtos, do aprimoramento de produtos existentes e da viabilização de decisões melhores e mais rápidas.

Não há dúvida de que a IA e o ML podem ajudar as empresas a obter melhores resultados. Até 2025, espera-se que os gastos mundiais com IA cheguem a USD 204 bilhões.¹ Também está claro que as empresas que adotam essa tecnologia continuam confiantes na capacidade da IA em agregar valor e gerar vantagem competitiva.

Embora o ML exista há décadas, sua acessibilidade como ferramenta para transformação de negócios é relativamente nova. Além disso, a inexistência de um caminho único e comprovado para obter sucesso com ML está levando algumas empresas a continuarem em compasso de espera, sem saber como dar o próximo (ou mesmo o primeiro) passo nessa jornada.

Chegou a hora de as organizações superarem as preocupações com o ML, deixarem de simplesmente tentar alcançar a concorrência e avançarem com confiança rumo a essa tecnologia. Este e-book define o caminho comprovado, desde a primeira etapa até a medição dos resultados, com insights das práticas recomendadas do ML da Amazon e nossa experiência ajudando milhares de clientes a concretizar as próprias iniciativas.

75%

das empresas começarão a operacionalizar a IA até o final de 2024², e 66% delas consideram essa tecnologia fundamental para o sucesso³.



¹ "Investment in Artificial Intelligence Solutions Will Accelerate as Businesses Seek Insights, Efficiency, and Innovation, According to a New IDC Spending Guide", IDC, 2021

² "Gartner Identifies Top 10 Data and Analytics Technology Trends for 2020", Gartner, 2020

³ "Becoming an AI-fueled Organization", Deloitte, 2021



POR QUE ADOPTAR O ML

O que se entende por inteligência artificial e machine learning?

Você já deve ter lido várias descrições de IA e ML, por isso vamos revisar o significado de cada termo. IA é uma forma de descrever qualquer sistema capaz de replicar tarefas que antes exigiam inteligência humana.

A maioria dos casos de uso de IA busca um resultado probabilístico: fazer previsões, classificar ou tomar decisões com um alto nível de certeza e de forma semelhante ao discernimento humano.

Hoje, quase todos os sistemas de IA são criados utilizando o ML, que usa grandes volumes de dados para criar e validar a lógica das decisões. Isso é conhecido como modelo. O sistema de IA alimenta esse modelo com dados de entrada, e o modelo gera previsões ou classificações semelhantes às aquelas feitas por humanos. Basicamente, o ML é a tecnologia subjacente dos sistemas inteligentes.

Por que adotar o machine learning?

Antes de nos aprofundarmos nas etapas da jornada para o ML, vamos explorar por que as empresas devem embarcar nela. Afinal de contas, mesmo com as orientações deste e-book, a concretização das etapas definidas aqui exigirá investimento e dedicação contínuos. A empresa precisará recordar constantemente o objetivo que busca, permanecendo focada nos benefícios exatos que o negócio poderá obter ao aproveitar ao máximo a tecnologia de ML.

As empresas já estão percebendo o impacto de:

1

Otimizar os negócios com novos ganhos de eficiência

O ML pode ser usado para aumentar a eficiência por meio de modelos sofisticados de planejamento e previsão de demanda. Embora isso seja uma realidade em praticamente todos os setores, a manufatura oferece algumas evidências específicas. Durante a pandemia da COVID-19, a **Foxconn**, o maior fabricante mundial de produtos eletrônicos e provedor de soluções de tecnologia, enfrentou uma volatilidade sem precedentes em demanda de consumidores, suprimentos e capacidade. A empresa colaborou com o **Laboratório de Soluções do Amazon Machine Learning** para desenvolver um modelo de previsão de demanda usando o **Amazon Forecast** de modo que a fábrica do México aumentasse a precisão das previsões de pedidos líquidos em 8%. De acordo com um relatório de 2022 da McKinsey, as empresas nos setores de telecomunicações, energia elétrica, gás natural e saúde observaram que os motores de previsão de IA podem automatizar até 50% das tarefas de gestão da força de trabalho, resultando em reduções de custo de 10 a 15%.⁴

2

Tomar decisões mais inteligentes e mais rápidas

Apoiada por fontes de dados e de análises cada vez mais inteligentes graças ao ML, uma empresa e sua força de trabalho podem tomar decisões mais bem-informadas e mais rápidas, acelerando a resposta a oportunidades e obtendo melhores resultados. A equipe de ML da **Zendesk** é responsável por aprimorar as equipes de experiência de clientes para servi-los melhor. Ao combinar o poder dos dados e das pessoas para automatizar o trabalho manual, a Zendesk fornece produtos inteligentes que tornam seus clientes mais produtivos.⁵

3

Aumentar o envolvimento do cliente oferecendo experiências personalizadas

A **Warner Bros. Discovery, Inc.** tem uma variedade de conteúdos que atendem um público amplo e diversificado.⁶ A empresa queria ajudar os clientes a encontrar conteúdo selecionado de acordo com interesses específicos e buscou a Amazon Web Services (AWS) e o **Amazon Personalize** para permitir sugestões personalizadas de conteúdo para sua plataforma de streaming, discovery+.⁷ Em vez de oferecer conteúdo genérico ao público, a Warner Bros. Discovery, Inc. agora usa recomendações feitas pelo ML do Amazon Personalize para personalizar a experiência do usuário e melhorar a jornada do cliente de modo geral.

4

Incluir novas capacidades em produtos existentes

O ML pode aprimorar produtos existentes, aumentando o engajamento dos clientes e atraindo novos usuários por meio de experiências mais envolventes. Por exemplo, a **Livongo** dispõe de uma plataforma e um aplicativo móvel que funcionam com dispositivos inteligentes, como monitores de glicose sanguínea conectados para ajudar as pessoas a gerenciar problemas de saúde. A empresa usa ML para converter dados de leituras de glicemia, atividade física e registros de refeições, além de dados do smartphone e outros dados importantes, em “dicas de saúde” oportunas e práticas. Essas mensagens personalizadas sobre dieta, exercícios, medicamentos e muito mais, enviadas em tempo real aos membros nos dispositivos conectados, ajudam o usuário a evitar complicações que poderiam resultar até mesmo em internações, além de gerar economia para o sistema e o usuário.⁸

5

Inventar produtos inéditos

Em sua missão de possibilitar que a tecnologia de saúde atenda melhor as pessoas, a **Cambia** usou a AWS, inclusive a tecnologia de ML, para desenvolver o Journi, uma solução de saúde digital completa guiada por inteligência orientada por dados e conhecimentos humanos. O Journi ajuda os conveniados e as respectivas famílias a aproveitar ao máximo os benefícios do plano de saúde.⁹

6

Obter uma vantagem competitiva

O ML já não é uma opção de nicho, mas uma necessidade para se manter relevante e competitivo, independentemente da área e do domínio da empresa. A **OnPoint**, subsidiária da Koch Engineered Solutions, colaborou recentemente com a AWS para desenvolver uma plataforma inteligente de otimização de processos (IPOP). A plataforma desenvolvida para as soluções da OnPoint utiliza uma infraestrutura digital de borda e de nuvem para fornecer recursos avançados de ML e computação industrial para o ecossistema conectado da OnPoint. Isso permite que os operadores industriais e seus parceiros preferenciais integrem e ajam com base no melhor conhecimento disponível, em qualquer lugar, a qualquer momento e em larga escala.¹⁰

Agora que definimos o *porquê* do machine learning, vamos explorar o *como*. As próximas seções demonstrarão as etapas da jornada para o ML usando as práticas recomendadas pela AWS e por clientes para exemplificar as mudanças necessárias para implementar, implantar e dimensionar soluções de ML.

⁶ “Warner Bros. Discovery, Inc. Is Enhancing the Customer Experience with Amazon Personalize”, Amazon Web Services, 2021, vídeo do YouTube

⁷ “Discovery Enhances Customer Experience Using Amazon Personalize”, estudo de caso da AWS, 2021

⁸ “Data Empowers Patients and Providers”, artigo do jornal Wall Street encomendado pela AWS, 2020

⁹ “Cambia Health Solutions Builds Integrated, Human-Centered Healthcare Solution on AWS”, estudo de caso da AWS, 2021

¹⁰ Robinson, M., et al., “Acoustic Anomaly Detection Using Amazon Lookout for Equipment”, blog de machine learning da AWS, 2021

A jornada rumo ao machine learning

Nem sempre a jornada rumo ao ML é um caminho reto. A viabilização do sucesso com ML requer não apenas uma excelente tecnologia, mas também a garantia de que a organização esteja alinhada aos objetivos certos. A identificação e a concretização desses objetivos exigirão mudanças amplas em processos, administração e cultura. As próximas seções vão explorar como as organizações podem superar desafios comuns, que frequentemente impedem avanços, e como dar os passos certos para implementar o ML de maneira eficiente e sustentável.

ETAPA 1

Promover uma cultura de machine learning

Para liberar todo o potencial comercial do ML, é necessário fazer mudanças culturais na organização, nos objetivos e na visão das equipes.

Para que o ML se prolifere dentro da organização, as equipes comerciais e técnicas precisarão trabalhar em conjunto e compartilhar as mesmas prioridades. Para alcançar esse objetivo, as iniciativas relacionadas a ML precisam contar com o apoio dos níveis mais elevados, com metas definidas pelos líderes executivos e investimentos em tecnologias e processos que viabilizem o sucesso. Isso inclui, entre outros, um compromisso em criar uma IA mais responsável desde o início, trabalhando para identificar e mitigar vieses, melhorar a explanabilidade e ajudar a manter os dados em segurança e sigilo. Ao adotar uma abordagem centralizada em pessoas, as empresas podem trabalhar para orientar sua força de trabalho em direção a uma IA responsável e criar equipes mais diversas para combinar mais pontos de vista e aumentar a equidade.

É importante que a administração tenha uma visão ampla enquanto promove iniciativas de ML. Os executivos precisam ser firmes em seus objetivos, mas flexíveis na forma como eles serão alcançados. Com certeza haverá erros. Todavia, ao manter o foco na visão de longo prazo e combater o desânimo, as organizações podem aprender com cada erro e aplicar esses aprendizados na promoção da cultura de ML em toda a empresa.

Talvez a maior mudança cultural pela qual as organizações precisam passar seja utilizar a oportunidade inerente aos erros. O ML é um processo iterativo que exige experimentação constante para ser bem-sucedido. Frequentemente, esses experimentos falharão. Somente aprendendo com os erros, e recusando-se a interromper o desenvolvimento para determinar “o que deu errado”, as organizações poderão alcançar consistentemente o sucesso extraordinário que as aguarda.

O exemplo da Amazon

A Amazon tem usado ML há mais de 20 anos. Após cerca de 10 anos de experiência com essa tecnologia, nossa equipe de liderança pediu que todos os líderes da organização – independentemente do tipo de equipe, como pesquisa, centros de distribuição ou RH – respondessem como planejavam usar ML em seus negócios.

Na maioria dos casos, “não pretendemos usar” não era uma resposta aceitável. Isso obrigou líderes, especialistas em assuntos específicos e especialistas técnicos a colaborar com as iniciativas de ML e não deixar que nada interrompesse o progresso, mesmo quando os benefícios perceptíveis da tecnologia ainda estivessem bem distantes no futuro.

Além de contratar cientistas de dados externos, a Amazon criou a Machine Learning University (MLU), que formou muitos de seus desenvolvedores para usar o ML de modo mais eficaz. A empresa criou ferramentas como o **Amazon SageMaker**, que simplifica o processo de criação de modelos e diminui a barreira de entrada, a fim de permitir um dimensionamento mais eficaz de tecnologias e iniciativas de ML. Além disso, a Amazon desenvolveu um conjunto de **serviços de IA** predefinidos que fornecem uma inteligência pronta para abordar casos de uso comercial comuns para clientes, sem que eles precisem criar os próprios modelos.

Hoje, não há um único departamento na Amazon que não tenha tido contato com o ML. A tecnologia de personalização da Amazon, que fornece recomendações exclusivas para clientes com base em preferências e hábitos, melhorou significativamente desde a criação do primeiro modelo há 20 anos, tendo sido aplicada a outras áreas do negócio.

Vejamos alguns exemplos de como a Amazon está aproveitando o ML. A empresa usa ML em todo o processo de distribuição e aproveita um sistema de previsões que pode antecipar a demanda de quase todos os produtos em seu enorme inventário. Esses modelos de previsão permitem que a Amazon atenda melhor às expectativas dos clientes em termos de conveniência, custo e velocidade de entrega.

“Fazemos previsões para milhões de produtos todos os dias em todos os nossos sites da Amazon ao redor do mundo”, afirmou Jenny Freshwater, diretora de previsões da Amazon. “Sem o machine learning, não poderíamos fazer essas previsões.”

Os exemplos são muitos. A Amazon criou a Alexa, que fornece aos clientes uma forma inédita de interagir com a tecnologia. A empresa desenvolveu uma tecnologia inovadora de voo autônomo com os drones do Amazon Prime Air. E ela usa robótica nos centros de distribuição para envios mais rápidos.

Isso exigiu muitos investimentos em tecnologia, pesquisa e talentos. No entanto, esses investimentos teriam sido desperdiçados sem a mudança cultural que fez a empresa persistir após muitas falhas e desafios inesperados. Todas as organizações precisam fomentar esse mesmo tipo de cultura de experimentação e inovação tolerante a erros antes que a jornada rumo ao ML possa realmente começar.

A Amazon usa ML para minimizar desperdícios de embalagem, reduzindo o peso da embalagem para remessa em **33%** e eliminando **915 mil toneladas** de materiais de embalagem em todo o mundo.¹¹

ETAPA 2

Reinventar a estratégia de dados

O sucesso do ML depende muito da qualidade dos dados. Sem uma estratégia de dados apropriada, o progresso será muito lento e prejudicará a eficácia do modelo final.

Pior ainda, se o modelo receber informações de dados de má qualidade, os resultados gerados podem ser enganosos ou até mesmo completamente errados.

“[Os modelos de machine learning são] extremamente sensíveis à qualidade dos dados”, disse Freshwater. “Então, aprendemos – em muitos casos, da pior maneira possível – que o tempo investido inicialmente na obtenção de dados de alta qualidade gerava lucros na produção dos nossos modelos finais.”

A estratégia de dados certa para ML deve ter como objetivo romper os silos, permitindo que as equipes de TI acessem e coletem de maneira fácil, rápida e segura os dados de que precisam.

Embora as estratégias modernas de dados adotem as mais diversas formas, os data lakes estão se tornando um componente cada vez mais popular dos modelos mais eficientes.

Os data lakes oferecem mais agilidade e flexibilidade do que sistemas tradicionais de gerenciamento de dados, permitindo que empresas gerenciem diferentes tipos de dados com base em uma grande variedade de fontes e armazenem tais dados, estruturados ou não, em um repositório centralizado.

Depois de armazenar os dados, é possível analisá-los com vários tipos de técnicas e serviços de ML de maneira mais rápida e eficiente do que as abordagens isoladas tradicionais. A arquitetura de data lakes também permite que diversos grupos na organização se beneficiem da análise de um conjunto de dados consistente, que engloba toda a empresa.

Se precisar de ajuda para desenvolver uma estratégia de dados mais holística que inclua data lakes, acesse [AWS for Data](#).

O exemplo da Georgia-Pacific

Centenas de bobinas e lenços de papel são produzidos diariamente nas unidades fabris da **Georgia-Pacific** na América do Norte. Ocorrências frequentes de rasgos ou rompimentos das lâminas de papel provocam interrupções e um tempo de inatividade na máquina e na linha de conversão que pode custar à empresa milhões de dólares anualmente por linha.

A Georgia-Pacific começou migrando 50 TB de dados de produção estruturados e não estruturados de uma infraestrutura de banco de dados herdada para um data lake na nuvem. A aplicação de bancos de dados e ferramentas de análise da AWS a todos esses dados permitiu que a Georgia-Pacific otimizasse os principais processos de manufatura para prever falhas em equipamentos com antecedência de 60 a 90 dias. Ao reduzir os rasgos das lâminas de papel e as interrupções não planejadas, a empresa aumentou os lucros em milhões de dólares em uma única linha de produção.

“Usamos as tecnologias de análise de dados da AWS para prever [...] com exatidão a velocidade máxima de operação das linhas de conversão para evitar rasgos. Com a redução dos rasgos das lâminas de papel, aumentamos os lucros de uma linha de produção em milhões de dólares.”

Steve Bakalar, VP de TI e transformação digital da Georgia-Pacific

[Leia a história completa ›](#)

ETAPA 3

Abordar o problema comercial certo

Um erro que as organizações cometem com frequência em suas jornadas de ML é contratar cientistas de dados que trabalham em silos para criar modelos de ML como provas de conceitos em vez de resolver os problemas reais do negócio. Sem um problema específico do negócio a ser resolvido, os executivos da área de TI terão uma dificuldade cada vez maior para demonstrar o valor dos projetos de ML para seus pares executivos. Isso pode atrasar ou até mesmo interromper o progresso das iniciativas de ML.

Aqui estão algumas perguntas importantes que as organizações devem fazer antes de embarcar na jornada rumo ao ML:

1. O projeto é suficientemente importante para receber atenção e adesão?
2. Ele resolve um problema real do negócio?
3. Existem lugares onde a organização já tem muitos dados inexplorados?
4. O projeto precisa de ML?
5. O projeto pode ser concretizado por uma única empresa?
6. É possível operacionalizá-lo em algum momento?

“A primeira etapa é identificar um problema que disponha de dados em abundância mas que você ainda não foi capaz de resolver empregando métodos tradicionais”, disse Freshwater.

O **Explorador de Casos de Uso de IA** é um site de navegação e busca centralizado em resultados de negócio que permite aos usuários encontrar os casos de uso certos de IA, descobrir histórias de sucesso relevantes de clientes e mobilizar as equipes para a implantação.

Em uma jornada de sucesso rumo ao ML, as empresas criam equipes de ML para abordar problemas específicos do negócio. Para isso, é necessário incluir tanto especialistas técnicos quanto especialistas em assuntos específicos nessas equipes. Embora os especialistas técnicos assumam o fardo da criação de modelos, eles precisam do conhecimento de campo dos especialistas em assuntos específicos para definir desafios exatos para o negócio e identificar os dados mais importantes para encontrar uma solução.

Essa abordagem também é fundamental para fazer mudanças na gestão. Quando especialistas em assuntos específicos e especialistas técnicos colaboram para criar modelos de ML, os funcionários se sentirão mais confiantes para tomar decisões baseadas na lógica do algoritmo.

Juntas, essas equipes também devem trabalhar em maneiras para medir o sucesso. “Tenha métricas nítidas e claras antes de embarcar na jornada rumo ao machine learning”, disse Freshwater. “Muitas vezes, os modelos são utilizados para algo que já existe e você quer assegurar que eles realmente ficaram melhores e que é possível medir essas melhorias.”

Para saber mais sobre como medir o sucesso das iniciativas de ML, consulte a **Etapa 6** deste e-book.

Algumas organizações já têm talentos na própria empresa para identificar os problemas que poderiam ser resolvidos de um jeito melhor com ML e para implementar os projetos-piloto adequados. As organizações podem aproveitar o **Laboratório de Soluções do Amazon Machine Learning** para que os clientes trabalhem em retrospecto, partindo dos desafios do negócio e avançando gradativamente pelo processo de criação de projetos de ML para superar esses desafios.

O exemplo da NFL

A NFL trabalhou durante décadas para oferecer insights mais completos sobre jogadores e times, com o objetivo de atender à necessidade de mais segurança para os jogadores e satisfazer o apetite insaciável dos fãs por dados e estatísticas.

Para isso, a NFL trabalhou com a AWS para criar o programa NFL Next Gen Stats (NGS), baseado em ML. Como a ciência de dados e o futebol americano são áreas muito diferentes, a NFL sabiamente incluiu tanto especialistas técnicos quanto especialistas em assuntos específicos para a criação do NGS, garantindo que os dois grupos pudessem trabalhar juntos para identificar os dados certos e desenvolver estatísticas.

O NGS usa tags RFID para rastrear o movimento dos jogadores e fornecer dados de localização, velocidade e aceleração em tempo real de cada jogador durante cada jogo em cada centímetro do campo. Ao simular situações diferentes em um ambiente de jogo, a NFL busca promover um melhor entendimento sobre como tratar e recuperar lesões no curto prazo e, por fim, prever lesões e intervir para evitá-las no futuro.

O NGS também usa modelos de ML para calcular mais de 20 estatísticas avançadas diferentes que empolgam os fãs. Um exemplo é a métrica de expectativa de jardas corridas, criada para mostrar quantas jardas um jogador que carrega a bola deveria correr em um trajeto específico de acordo com a localização relativa, a velocidade e a direção dos bloqueadores e defensores.

Insights como a expectativa de jardas corridas não existiriam sem a parceria entre especialistas técnicos (capazes de criar e treinar os modelos para processar os dados necessários) e especialistas em assuntos específicos (que sabem quais dados precisam medir para criar as estatísticas mais empolgantes).

Essa parceria também ajuda a promover a aceitação do NGS, já que aumenta a probabilidade de os locutores citarem estatísticas avançadas que especialistas em futebol americano (e, em alguns casos, os próprios locutores) ajudaram a criar.

[Leia a história completa ›](#)



ETAPA 4

Desenvolver as habilidades das equipes

Enquanto cria uma estratégia de dados, a organização precisa se concentrar em munir as equipes com as habilidades certas.

As organizações estão cada vez mais cientes do déficit de habilidades de ML, ou seja, a crescente lacuna entre as tecnologias e a capacidade dos especialistas internos de TI de aproveitá-las. O relatório de 2021 da O'Reilly, que entrevistou mais de 3.500 líderes empresariais, revelou que a falta de pessoal qualificado e a dificuldade de contratação foram os principais desafios em IA, e 19% dos entrevistados consideraram isso um obstáculo "significativo".¹² Para preencher essa lacuna na área de ML, será preciso combinar treinamento e recrutamento. A verdade é que não há uma quantidade suficiente de cientistas de dados para liderar a transformação de ML que está por vir. Isso faz com que as organizações que desejam aproveitar o ML invistam no desenvolvimento de talentos e nas ferramentas de software certas para o sucesso.

Embora não exista uma solução única para o déficit de habilidades em ML, há métodos comprovados capazes de maximizar as habilidades da equipe, reduzindo a necessidade de grandes investimentos em compra ou recorrer a talentos especializados previamente treinados.

Esses métodos incluem:

Definir o déficit de habilidades: antes de superar o déficit de habilidades, a organização deve identificar as diferenças específicas entre o que ela precisa ou deseja que seus funcionários façam e o que os funcionários atualmente são capazes de fazer.

Entender como as habilidades são mapeadas: como as iniciativas de ML são esforços interdisciplinares, a organização deve mapear as habilidades necessárias entre cientistas de dados, engenheiros de dados, analistas de negócios, desenvolvedores de aplicações, estatísticos e especialistas em outras áreas da empresa.

Personalizar treinamentos para necessidades específicas: se uma organização já tem currículos de treinamento que podem ser úteis, ela deve trabalhar para personalizar esses materiais com o objetivo de atender às necessidades de ML específicas da empresa. Os líderes também devem explorar serviços de IA previamente treinados que forneçam inteligência pronta para as aplicações e fluxos de trabalho da empresa.

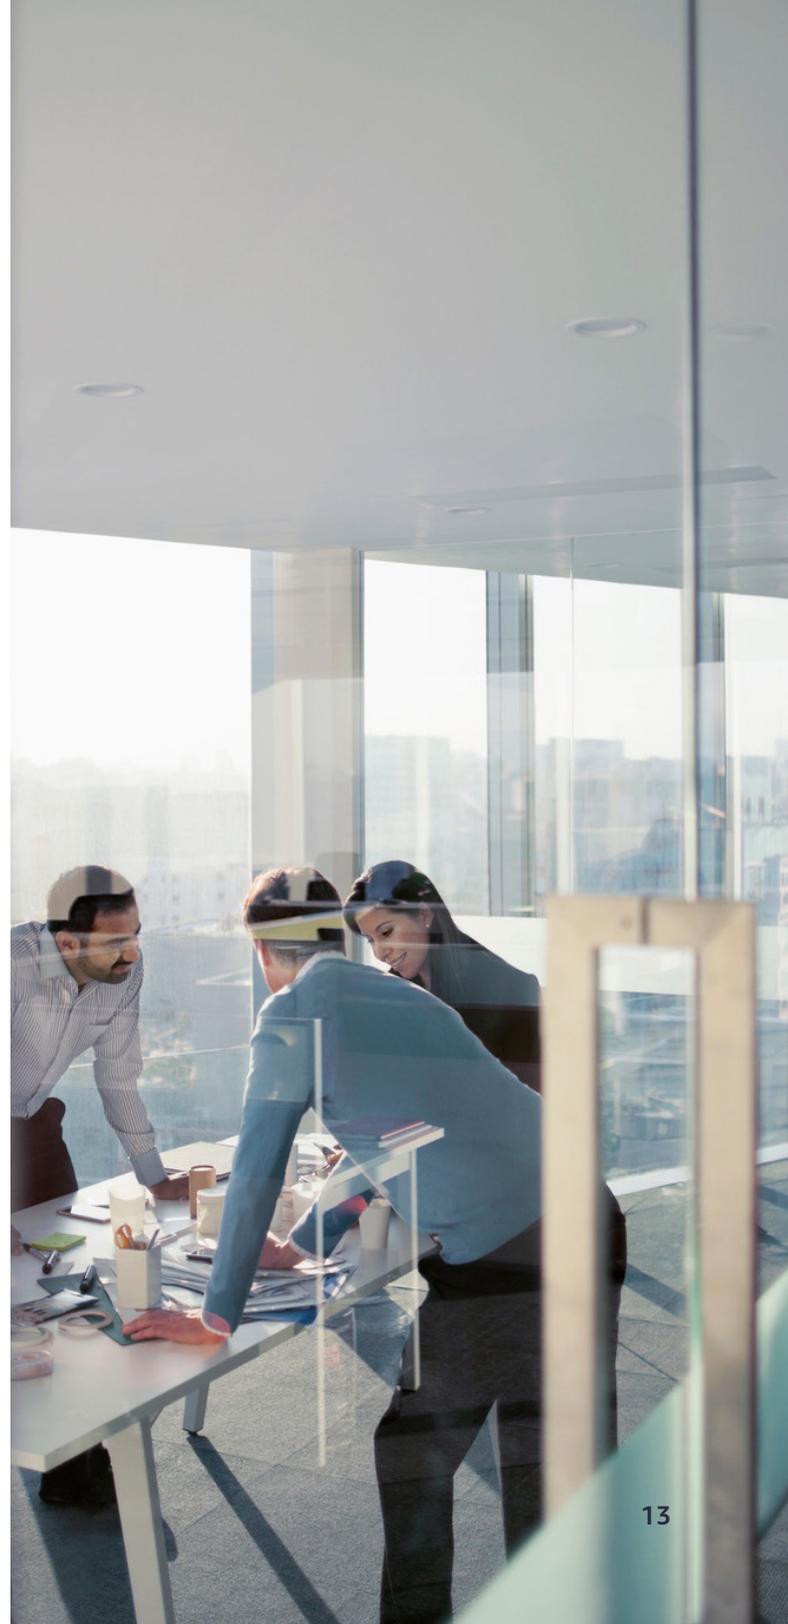
Avaliar opções sem código: muitos casos de uso de ML estão ao alcance das equipes de análise de negócios existentes mediante ferramentas de inteligência de negócios que fazem previsões sem precisar criar códigos ou ter experiência com ML. Elas são ideais para casos de uso como previsão e predição de rotatividade.

Além do treinamento, as organizações precisam alinhar as equipes para resolver com êxito problemas relacionados a ML. Isso pode ser feito destas formas:

- **Promover uma cultura de equipes capacitadas:** as equipes de projetos de ML precisam ser interfuncionais, ter autoridade para alcançar objetivos individuais e ter liberdade de trocar conhecimentos organicamente com outras equipes para reagir a novas demandas e oportunidades. Para possibilitar esse tipo de trabalho em equipe, a administração vai precisar receber novas estruturas – e esquecer os modelos organizacionais estritamente hierárquicos e departamentais do passado.
- **Começar com uma equipe-piloto:** a empresa deve definir uma equipe-piloto de engenheiros e profissionais de TI e ML, além de líderes do negócio e encarregá-la de um projeto de ML. “Eu recomendaria colocar algumas pessoas muito inteligentes para tentar descobrir quais métricas você quer otimizar ou prever [...] simplesmente para começar aos poucos”, afirmou Freshwater.
- **Viabilizar uma transformação orgânica:** após a conclusão do projeto-piloto, a empresa poderá dividir a equipe, adicionar pessoas para criar outras equipes e colocá-las à frente de novos projetos. Esse processo continua, permitindo que o conhecimento se espalhe organicamente das equipes com mais tempo de casa para os novos recrutados e que seja transmitido entre as equipes.

Ao seguir essa orientação, muitas organizações estão descobrindo que as pessoas que atualmente trabalham para elas são, na verdade, os funcionários de que precisavam para eliminar os déficits de habilidades em ML. Embora o recrutamento ainda seja necessário em alguns casos, investimentos em ferramentas certas e mudanças de processos e de gestão podem colaborar muito para desenvolver as habilidades pessoais necessárias para o sucesso do ML.

Também é importante garantir que os líderes empresariais sejam treinados para entender o ML e o que constitui um bom caso de uso, além de saber articular a linguagem técnica do ML. Há muitos cursos disponíveis para líderes empresariais, como o **Machine Learning Essentials for Business and Technical Decision Makers** (Fundamentos de machine learning para tomadores de decisões empresariais e técnicas). Além disso, analistas de negócios que apoiam áreas financeiras, de marketing, operações e vendas podem começar a usar a tecnologia de forma simples: carregando dados na nuvem e usando o **Amazon SageMaker Canvas** para gerar previsões. O SageMaker Canvas é um serviço visual sem código para gerar previsões de ML em poucos cliques.



O exemplo da Morningstar

A empresa de pesquisa de investimentos **Morningstar** usa ML para automatizar os processos de coleta de dados e ampliar o número de fundos cobertos. Para isso, ela usa previsões de um modelo de ML treinado para emular o processo de avaliação de fundos dos analistas da empresa.

Para treinar seus funcionários e acelerar a aplicação de ML, a Morningstar usa o **AWS DeepRacer**, uma ferramenta que facilita o treinamento prático em ML, com o uso de um carro de corrida totalmente autônomo em escala 1:18 guiado por aprendizado por reforço, um simulador de corridas em 3D e uma liga mundial de corridas. Mais de 445 funcionários da Morningstar de diferentes cargos e oito países, incluindo 35% dos cargos de tecnologia da empresa, já participaram da DeepRacer League.¹³

Em 2021, a Morningstar teve dezenas de projetos de ML em desenvolvimento. Entre eles, um programa de aprendizado por reforço que busca padrões em registros regulatórios e um algoritmo que identifica e corrige links inválidos para sites de instituições financeiras.

¹³ "In the News: Morningstar Launches Global AWS DeepRacer Corporate Competition to Accelerate Application of Machine Learning", AWS para diversos setores, 2021

“Nosso desafio DeepRacer aproveita o entusiasmo de nossos funcionários por machine learning e inteligência artificial. Ele fornece um treinamento prático em toda a empresa e acelera a aplicação prática do machine learning da Morningstar em todos os nossos produtos, serviços e processos de investimento. A resposta de nossas equipes foi muito além do que eu esperava, e foi uma forma divertida de unir nossas equipes globais tanto na área de tecnologia quanto em outras funções.”

James Rhodes, CTO da Morningstar

Leia a história completa >

ETAPA 5

Ir além dos projetos-piloto

Após o sucesso dos primeiros projetos-piloto, é necessário dar o próximo passo da jornada: aumentar a escala do ML de maneira sustentável por toda a empresa. Isso é um desafio tanto técnico quanto cultural.

Para alcançar escalabilidade, as organizações precisam facilitar o uso de ML por seus desenvolvedores. Criar modelos de ML em larga escala pode ser um trabalho intenso e complexo, que pode reduzir a velocidade das inovações.

Muitas organizações estão resolvendo a questão da escalabilidade com o **Amazon SageMaker**, uma solução abrangente que engloba todo o fluxo de trabalho de ML para preparar os dados e criar, treinar e implantar modelos de ML. Ao usar o Amazon SageMaker, a organização pode colocar seus modelos em produção mais rapidamente e com um custo mais baixo, permitindo uma expansão sustentável das iniciativas de ML que vão além dos projetos-piloto.

Outras organizações estão aumentando a escala por meio dos **serviços de IA da AWS**, um conjunto de serviços pré-treinados e gerenciados que podem ser usados como componentes básicos para abordar casos de uso comuns, incluindo personalizar recomendações, modernizar as centrais de atendimento, melhorar o nível de segurança e aumentar o engajamento com o cliente.

As empresas podem abordar a mudança cultural necessária para aumentar a escala do ML de diversas maneiras. Algumas empresas podem obter sucesso criando um centro de excelência para reunir a comunidade e continuar impulsionando novas iniciativas. Como alternativa, a exemplo da Amazon, as organizações podem transformar o ML em parte integrante dos processos anuais de planejamento, reunindo continuamente especialistas técnicos e de domínios específicos para pensar em conjunto e determinar os próximos passos.

O exemplo da Intuit

Usando o Amazon SageMaker, a Intuit reduziu o tempo de implantação do ML em 90%, de seis meses para uma semana. Ao centralizar as iniciativas de ML, a Intuit incentiva a inovação e implanta técnicas de IA e ML com velocidade e escala, alcançando um valor empresarial que vai além de seus produtos e serviços.

“A AWS fornece uma plataforma comum para que o pessoal da Intuit compartilhe e colabore com dados em um ambiente seguro”, disse Ashok Srivastava, vice-presidente sênior e diretor de dados da Intuit. “Por exemplo, o Amazon SageMaker nos oferece a plataforma e a infraestrutura de que precisamos para aplicar nossas tecnologias sofisticadas de IA e machine learning.”

“No futuro, estamos ansiosos para aproveitar tudo que o (Amazon) SageMaker oferece [...] para mudarmos fundamentalmente a experiência de produto para nossos usuários.”

Nhung Ho, VP de IA da Intuit

Assista ao vídeo ›



ETAPA 6

Medir os resultados

Quando medimos os resultados das iniciativas de ML, o ponto de vista tradicional do “ROI do projeto” (no qual um projeto tem início e fim, orçamento e retorno definidos) é redutivo e pode ser prejudicial para o sucesso da iniciativa. Se o projeto não gerar um retorno positivo em um prazo específico, a empresa poderá perder o interesse e deixar de aproveitar oportunidades essenciais no futuro.

Em vez disso, tanto os executivos quanto a área de TI precisam medir os esforços de ML com base no que o sucesso significa para a empresa e em relação aos processos que estão sendo otimizados. Além disso, eles precisam considerar os esforços em ML como investimentos de longo prazo, reconhecendo que um “retorno” verdadeiro talvez só seja possível depois de muitos anos e inúmeras iterações.

Ao planejar iniciativas de ML, é melhor visualizar o processo sob o prisma de agilidade, vantagem competitiva ou tolerância a riscos, em vez de pensar no retorno esperado. A organização terá mais sucesso se desconsiderar a pergunta “Qual será o retorno do meu investimento em X meses?” e favorecer algo como “Se não investirmos nisso agora, vamos ficar para trás da concorrência em X anos quando a tecnologia estiver mais madura?”

Embora as métricas tradicionais de ROI talvez não sejam a melhor abordagem, ainda é possível medir o impacto das iniciativas de ML na empresa. Basta considerá-las de maneira diferente.

É possível medir os resultados de ML por meio de algo semelhante a uma “árvore de valor”, na qual o tronco principal representa o “retorno” tradicional e os galhos que saem dele reconhecem o valor dos outros resultados do negócio.

Os ramos da árvore de valor dependerão da organização, do setor e da iniciativa, e podem representar o tempo economizado com processos automatizados, a identificação de novos leads, mercados e oportunidades, as melhorias no serviço ao cliente ou os aumentos em vendas adicionais.

Medir o sucesso do ML por meio de um modelo mais holístico e de longo prazo manterá as organizações focadas nos melhores resultados para o futuro do negócio.

O exemplo da Lotte Mart

Comparado à abordagem de recomendação anterior usada pela Lotte Mart, o Amazon Personalize eliminou a necessidade de uma análise manual, tediosa e complexa de dados e reduziu o tempo de desenvolvimento pela metade. Isso economizou tempo porque a Lotte Mart tinha que fornecer apenas conjuntos de dados de interações, usuários e itens predefinidos. A equipe de engenharia conseguiu gerar resultados de teste na metade do tempo em comparação com a abordagem anterior. Com o Amazon Personalize, a Lotte Mart pôde recomendar, de forma econômica, novos produtos difíceis de promover e impulsionar a demanda por meio de métodos tradicionais.

“Para que pudéssemos nos concentrar no cliente, aumentar nosso alcance e a adoção pelos usuários, recorreremos ao Amazon Personalize, que permitiu a mais de 600 mil usuários de nosso aplicativo móvel M Coupon economizarem durante a experiência de compra na loja. Ao usar o Amazon Personalize, notamos um aumento de 5x na resposta aos produtos recomendados comparado à nossa solução anterior de análise de big data, resultando no aumento da receita mensal. Em especial, o Amazon Personalize aumentou o número de produtos que o cliente adquiriu pela primeira vez em até 40%. O novo serviço de recomendações oferecido pela AWS é o primeiro de um lançamento muito mais amplo de tecnologia de IA em nossa organização.”

Jaehyun Shin, líder da equipe de big data da Lotte Mart

[Leia o blog ›](#)



Dar o próximo passo com a AWS

Independentemente da etapa em que a empresa se encontra na jornada rumo ao ML, você pode dar o próximo passo com as soluções da AWS criadas na plataforma de nuvem mais abrangente e otimizada para ML com computação, segurança e análise de alto desempenho. Com o conjunto mais amplo e especializado do mundo de serviços de IA e ML, mais de 100 mil clientes executam suas workloads de IA e ML na AWS.

Para ajudar você a identificar as soluções e casos de uso mais relevantes de IA e ML, criamos o **Explorador de Casos de Uso de IA**, uma ferramenta fácil de usar que traz sugestões dos melhores casos de uso com base em seu setor, sua função e a prioridade de negócio, incluindo:

Central de atendimento inteligente: melhore a experiência da central de atendimento para personalizar e simplificar as interações com os clientes, melhorar a produtividade do atendente e aumentar a eficiência dos processos de negócios ao integrar ML à sua central de atendimento.

Chatbots e assistentes virtuais: ative a comunicação multicanal 24 horas com seus clientes por meio de chatbots, assistentes de voz e quiosques de informação interativos.

Personalização: melhore a conversão e o envolvimento dos clientes criando experiências personalizadas, desenvolvidas sob medida para os comportamentos e as preferências individuais dos clientes entre os canais.

Processamento inteligente de documentos: extraia texto e dados instantaneamente de praticamente qualquer documento, como solicitações de empréstimos e formulários médicos, sem esforço manual.

Pesquisa inteligente: para aumentar a produtividade e a satisfação do cliente, conceda informações úteis e precisas com maior rapidez de fontes diferentes de toda a organização usando perguntas em linguagem natural.

Verificação de identidade: reduza o tempo de integração, dê maior comodidade ao usuário e diminua a ocorrência de fraudes ao mesmo tempo que reduz custos usando a verificação de identidade do usuário por ML.

Moderação de conteúdo: crie ambientes on-line seguros, proteja sua marca e minimize custos de moderação com o uso de ML para moderar volumes amplos e complexos de conteúdo gerados pelo usuário.

Inteligência de mídia: maximize o valor do conteúdo de mídia com a inclusão de ML em fluxos de trabalho de mídia, como pesquisa e descoberta, tradução de conteúdo, conformidade, monetização e muito mais.

Previsão: preveja a demanda com precisão e simplifique as decisões de demanda por fornecimento para combinar dados históricos de séries temporais com outras variáveis, como recursos dos produtos, preços e datas festivas.

Modernização do desenvolvimento de ML: para acelerar a inovação ao mesmo tempo que reduz custos, modernize o ciclo de desenvolvimento de ML por meio de uma infraestrutura escalável, ferramentas integradas, práticas íntegras para o uso responsável de ML, escolhas acessíveis de ferramentas para desenvolvedores de todos os níveis de habilidade, além de uma gestão eficiente de recursos.

Amazon SageMaker: crie produtos e serviços com o Amazon SageMaker. Ele permite que seus analistas de negócios, cientistas de dados e engenheiros de ML preparem os dados e criem, treinem e implantem facilmente modelos de ML, simplificando a escalabilidade em todo o negócio. O SageMaker elimina a complexidade que interfere na implementação bem-sucedida de ML em todos os casos de uso e setores, desde a execução de modelos para detecção de fraudes em tempo real, até a análise virtual dos impactos biológicos de possíveis medicamentos ou a identificação do melhor piloto de Fórmula 1.

Os números do machine learning com a AWS

Mais de 100 mil clientes usam a AWS em suas workloads de IA e ML

Mais de 20 anos de experiência acumulada na Amazon

Aprimoramento de até 10x na produtividade dos cientistas de dados

Centenas de algoritmos e modelos no Amazon SageMaker JumpStart

Frameworks de ML: os clientes da AWS podem escolher entre TensorFlow, PyTorch, Apache MXNet e outros frameworks populares para experimentar e personalizar algoritmos de ML. Você pode usar seu framework preferido de forma gerenciada no Amazon SageMaker ou as **AMIs de deep learning da AWS (DLAMI)** (Amazon Machine Images) e **contêineres de deep learning da AWS (contêineres de DL da AWS)**, totalmente configurados de acordo com as versões mais recentes dos frameworks e ferramentas de aprendizado profundo mais populares. O Amazon Elastic Compute Cloud (Amazon EC2) oferece uma ampla seleção de tipos de instância otimizados para casos de uso de ML para clientes que treinam modelos ou executam inferências em modelos treinados. Essas instâncias variam de **GPUs** para o treinamento de aprendizado profundo de computação intensa até o **AWS Inferentia** para inferência de baixo custo.

Suporte de implementação: o **Laboratório de Soluções do Amazon Machine Learning** reúne sua equipe com especialistas em ML com a finalidade de ajudar a identificar e desenvolver soluções de ML para abordar as oportunidades de ML de sua organização que oferecem o maior ROI.

Também oferecemos treinamento para aumentar o nível de conhecimento especializado sobre ML em sua equipe, bem como treinamento de desenvolvedores, treinamento de líderes empresariais e um evento prático por meio do **AWS Machine Learning Embark Program**.

Saiba mais sobre como você pode levar o **uso responsável de IA e ML** da teoria à prática com serviços, recursos e treinamento com propósito específico.

Ferramentas de aprendizado: você pode aprimorar suas habilidades de ML com ferramentas de aprendizado detalhado, incluindo:

- **[AWS DeepRacer](#)**
- **[Treinamento e Certificação em Machine Learning](#)**
- **[Laboratório de Soluções do Amazon Machine Learning](#)**
- **[Amazon SageMaker Studio Lab](#)**

Resolver os maiores desafios de machine learning

A maior parte das organizações fizeram investimentos consideráveis em ML e têm progredido em suas jornadas rumo ao ML. Porém, muitas estão enfrentando contratempos ao longo do caminho, preocupadas se os custos e as complexidades vão aumentar muito enquanto avançam.

Ao longo deste e-book, exploramos as etapas para avançar rumo ao ML e alcançar todo o potencial dessa tecnologia. Para relembrar, vamos rever os maiores desafios que identificamos no caminho, juntamente de uma breve recomendação de como sua empresa pode enfrentá-los.

Para saber mais sobre como superar obstáculos e acelerar sua jornada rumo ao ML, visite o [centro de recursos de ML da AWS](#).

[Comece agora mesmo >](#)

Desafio	Solução
Desânimo causado por falhas	Desenvolver uma cultura que tolera erros
Dados isolados e não processados	Criar uma estratégia moderna de dados que inclua data lakes
Encontrar os problemas comerciais certos	Criar equipes mistas que incluam tanto especialistas técnicos quanto especialistas em assuntos específicos
O déficit de habilidades em ML	Adotar novos modelos organizacionais, processos, ferramentas sem código e filosofias de gerenciamento de equipe
Ir além dos projetos-piloto de maneira sustentável	Aproveitar ferramentas abrangentes, como o Amazon SageMaker, para simplificar o desenvolvimento de ML
Medir os resultados	Deixar as métricas tradicionais de ROI de lado e priorizar agilidade, vantagem competitiva e tolerância a riscos; usar o modelo da árvore de valores