



# Aplicação da IA: como o uso de automated machine learning tem revolucionado o setor de seguros



## Introdução: novas oportunidades, novas necessidades

Nos dias de hoje, inteligência artificial (IA) e machine learning apresentam oportunidades e necessidades para as seguradoras.

Não há qualquer função em qualquer setor em que você não esteja concorrendo com seguradoras e intermediários que utilizam análises avançadas para otimizar sua rentabilidade. Seja nas funções de marketing, subscrição ou sinistros, ou se ramo em que você atua é pessoas, comercial ou de bens e responsabilidade civil, a utilização de IA e machine learning pode fazer com que praticamente todas as funções na sua organização sejam desempenhadas com mais facilidade e eficiência.

IA e machine learning têm transformado *data analytics*, possibilitando que empresas de todo porte criem modelos preditivos, cinco a quinze vezes mais rápido, a um custo muito menor. Ao utilizar IA e machine learning, as empresas conseguem superar limitações anteriores impostas por dados, sistemas e equipes para incorporar mais insights e informações corporativas em previsões cada vez mais precisas.

Nessa visão geral do setor, vamos abordar alguns dos principais desafios enfrentados pelo setor de seguros nos dias de hoje e como a IA, especificamente o automated machine learning, podem causar um impacto significativo.

Como as seguradoras podem aplicar a IA hoje:

- **Marketing:** identificar as melhores oportunidades de conversão e aperfeiçoar a qualidade e distribuição de riscos.
- **Subscrição:** possibilitar diferenciação mais granular entre os riscos e, assim, otimizar a seleção de riscos, classificação e atribuições dentro da empresa.
- **Precificação:** possibilitar previsão mais precisa de probabilidade de perda e modelos de precificação mais específicos por cobertura, segmento de mercado, ramo ou região geográfica.
- **Controle de perda:** distinguir, de forma mais precisa, as causas do sinistro no que diz respeito ao seu impacto na taxa de sinistralidade, proporcionando, assim, uma abordagem mais estratégica para esforços de mitigação de riscos.
- **Sinistros:** implementar uma "triagem" eficiente de sinistros, identificando sinistros que devem ser liquidados automaticamente, avaliados manualmente ou que indicam potencial fraude.



## Automated Machine Learning: democratizando o seu modelo

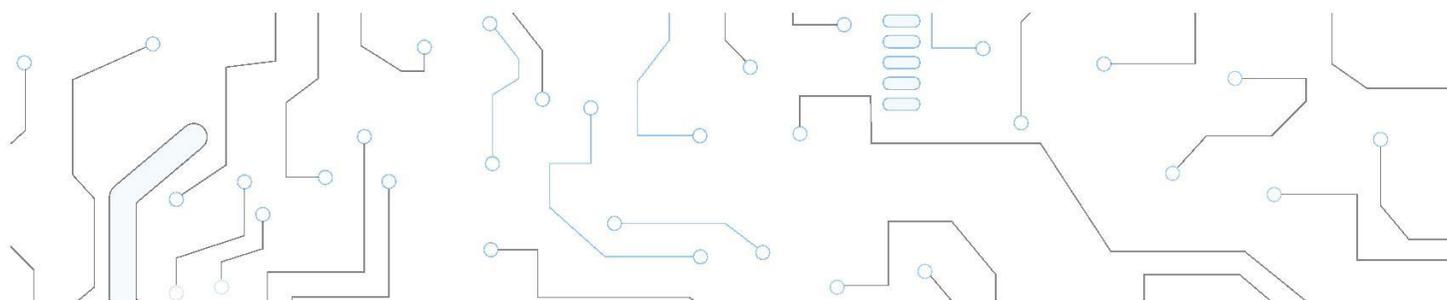
Até o momento, a concorrência para desenvolver análises de seguros tem sido, antes de mais nada, uma concorrência para contratar e reter cientistas de dados -- profissionais altamente qualificados e especializados, com grande demanda e pouca oferta, que tendem a permanecer por pouco tempo com seus empregadores.

Devido às demandas que enfrentam, os cientistas de dados do setor de seguros geralmente se encontram sobrecarregados e conseguem abordar somente 5-15% dos problemas de modelagem de uma empresa, muitas vezes atuando em silos, separados das operações e decisões dos negócios. Atualmente, estamos em um momento em que a capacidade de aumentar as equipes de cientistas de dados encontra-se seriamente limitada pela oferta e poucos anos de qualificação necessária para desenvolver novos cientistas de dados. As empresas que praticam análise preditiva manual atingiram o pico de impacto da análise preditiva.

Automated machine learning é um divisor de águas para as seguradoras, pois capacita equipes das empresas--atuários, analistas de precificação, gerentes de produto etc. -- para ajudar na criação de modelos analíticos, complementando e potencializando o valor dos cientistas de dados.

Os próprios cientistas de dados podem utilizar automated machine learning para otimizar sua produtividade. Em vez de passar horas codificando alguns modelos manualmente, eles conseguem criar, de forma automática, uma série de modelos ao mesmo tempo, utilizando algoritmos e técnicas de engenharia que não tinham acesso antes.

Os modelos operam sem a necessidade de serem reescritos várias vezes, ao contrário dos métodos analíticos tradicionais, que precisam de uma a três revisões de modelo antes de serem implantados.





A relação seguradora-corretor se deteriora com o tempo, já que, normalmente, são poucos gerentes de vendas para manter as operações de agentes e corretores funcionando nos períodos de pico. Como resultado, o volume e a qualidade de novos negócios diminuem, junto com a retenção de clientes já existentes e a eficiência da colaboração.

O automated machine learning cria uma estrutura completamente nova para gerenciar essa função fundamental

Em vez de esperar anos para conhecer a qualidade dos negócios do seu corretor, o automated machine learning consegue projetar a experiência de sinistros a partir do que já se conhece, fazendo com que você tenha ciência, quase que imediatamente, da qualidade das suas contas.

Ao analisar rapidamente a experiência por conta em um histórico de negócios, o automated machine learning identifica seus corretores mais produtivos, possibilitando que você determine quais relacionamentos devem ser preservados, aprimorados ou extinguidos.

## Tendências transformadoras

IA e machine learning superam significativamente as abordagens tradicionais das funções no setor de seguros e, hoje, são acessíveis àqueles que não são cientistas de dados, de forma prática e econômica. Essa evolução é crucial, considerando os desafios transformadores enfrentados atualmente pelas seguradoras.

Para se manterem competitivas, as empresas não podem mais depender de dados coletados periodicamente a partir de operações ou fontes públicas. Empresas líderes do setor têm utilizado dados operacionais e comportamentais em tempo real sobre os riscos apresentados através de, entre outros meios:

- **sensores IoT, utilizados para monitorar água, calor e outros perigos potenciais em propriedades particulares e comerciais;**
- **Telemática, utilizada para monitorar comportamento do motorista e manutenção do veículo em automóveis comerciais e veículos de passeio;**
- **Bioinformática e tecnologia *wearable*, utilizadas para monitorar bem-estar e segurança individual para seguro saúde e indenização trabalhista.**

Ao mesmo tempo, os compradores de produtos de seguros têm elevado suas expectativas em relação ao que esperam de um serviço online. Suas experiências cotidianas com serviços como a Amazon, por exemplo, têm os condicionado a esperar que as empresas antecipem seus interesses e recomendem os melhores produtos e serviços entre as muitas opções disponíveis.

Outro desafio que as seguradoras enfrentam é a rotatividade de pessoal, particularmente a iminente aposentadoria de centenas de milhares de profissionais de seguro que o setor tem se esforçado para substituir. Quando profissionais experientes são substituídos, as empresas geralmente descobrem que profissionais recém-treinados da equipe são recrutados pela concorrência.

Contratação competitiva afeta significativamente o desenvolvimento do conhecimento institucional dentro das empresas. A IA ajuda a resolver essa questão ao monitorar, registrar e aprender a partir das interações com o cliente e experiência da conta. Portanto, mesmo com as idas e vindas dos profissionais da equipe, o registro de melhores práticas fundamentadas em decisões sólidas e baseadas em dados permanece intacto.

Com o aumento desses desafios, as seguradoras não enfrentam apenas a concorrência de outras seguradoras. Enfrentam, também, centenas de *insurtechs* que buscam reinventar a forma como o seguro é fornecido.

As *insurtechs* não possuem histórico de perdas e experiência com subscrição, como seguradoras já estabelecidas, mas podem explorar novos tipos de dados e disponibilizar experiências flexíveis, intuitivas, que aprendem a partir do seu engajamento com os compradores.



## Onde as seguradoras têm obtido valor agregado a partir da IA e machine learning

Como comentado anteriormente, não há qualquer função no setor de seguros que não seja impactada pela utilização da inteligência artificial e machine learning. Além de automatizar e fundamentar os processos tradicionais, a IA e o machine learning disponibilizam novos recursos que capacitam as seguradoras na otimização de cada função da cadeia de valores do seguro.

### Marketing e distribuição

Para fins de marketing, IA e machine learning ajudam a garantir que o seu marketing seja direcionado aos prospects mais adequados, de forma eficaz, sem desperdiçar tempo e dinheiro. IA desenvolve modelos de seleção de risco de subscrição para qualificar previamente prospects de marketing, para garantir que sejam riscos atrativos para sua empresa e consistentes com o negócio que você pretende abordar. O mercado costuma utilizar IA para prever a propensão de um cliente em potencial adquirir um produto e sua rentabilidade em vários níveis de preço. A partir dessa decisão, a IA e o machine learning conseguem prever a permanência de contas individuais em diversos panoramas de preço, possibilitando aos usuários estimar o valor da vida útil das contas.

Saber como atingir seus prospects é geralmente tão importante quanto saber quem são seus prospects. Os clientes geralmente utilizam IA para determinar quais canais de comunicação e campanhas são mais adequados para cada cliente. Muitos clientes têm economizado milhões de dólares otimizando o momento e a forma como realizam publicidade on line.

No geral, os resultados são aperfeiçoados. A segmentação dinâmica de clientes identifica quais prospects merecem uma prioridade maior em suas iniciativas de marketing e um meio mais eficaz de atingi-los. Isso se estende à diferenciação dinâmica e específica entre riscos individuais em vários segmentos. IA e machine learning complementam suas aplicações em marketing com suporte à subscrição ideal e precificação aprimorada e dinâmica de apólices.



## Subscrição, elaboração mais rápida de tarifas e precificação dinâmica

IA ajuda a apoiar excelência em todas as atividades de subscrição, desde a solicitação do corretor até seleção de riscos, precificação e gestão de renovações. Para riscos comerciais ou online mais complexos, esse recurso otimiza a diretriz de risco do subscritor no momento em que uma solicitação for enviada e evita situações em que os corretores elaborem cotação e termos, de forma prematura, sem que todos os riscos tenham sido totalmente compreendidos.

A triagem de subscrição é uma das soluções de retorno mais ágeis para personal lines e small commercial lines. Novas solicitações são analisadas e selecionadas conforme as categorias de aprovação automática, revisão rápida, revisão, revisão especial e recusa automática. As recomendações para aprovação automática e recusa automática aumentam visivelmente os tempos de resposta de subscrição e otimizam diretamente os resultados operacionais, evitando riscos inaceitáveis que aumentariam sua taxa de sinistralidade, aprovando clientes mais seguros que ajudariam a diminuir sua taxa de sinistralidade. Modelos complementares estão disponíveis para atribuições baseadas em resultados para subscritores específicos, identificados pelos modelos como mais bem preparados para gerenciar determinadas solicitações.

O limite mais recente na transferência de risco individualizado é a “configuração preditiva de produto”, o uso de IA e machine learning para prever quais coberturas, limites e franquias provavelmente atendem às necessidades de um prospect. Isso possibilita um processo de aquisição simplificado, eficiente e completo que acelera a conversão da conta.

Tudo o que é capturado pela IA e machine learning em relação à seleção e análise de risco é preservado, aprimorado e utilizado para tornar os profissionais de subscrição, principalmente os mais novos, mais bem informados, capacitados e valiosos.

Graças ao aprendizado contínuo proporcionado pela IA e machine learning, as seguradoras estão constantemente cientes de quaisquer alterações nos custos e na concorrência e, portanto, prontas para elaborar e registrar novas tarifas de forma muito mais rápida do que no passado.

Precificação dinâmica é uma prática consolidada, utilizada por muitas seguradoras para alavancar fontes de dados de terceiros e outros, para otimizar a segmentação dos riscos. Com mais dados disponíveis, as seguradoras conseguem aprimorar sua compreensão dos níveis de riscos comparativos e valores para cada cliente. Sucesso significa conquistar novos clientes e evitar riscos não rentáveis (além de deixar os riscos ruins para os concorrentes).



O desafio que as seguradoras enfrentam é o esforço para revisar, de forma rápida, os dados internos e externos disponíveis, em tempo hábil, para determinar quais novas fontes de dados otimizam os modelos de precificação. É um processo demorado, por isso as equipes de precificação recorrem ao julgamento (em vez de análise estatística), renunciando novas fontes de dados ou testes rápidos que não avaliam inteiramente o poder preditivo de informações adicionais. O automated machine learning avalia dados de forma rápida, cria modelos com agilidade e automatiza os recursos da engenharia, fazendo com que as seguradoras se sintam seguras de que estão extraindo o máximo de valor das novas fontes de dados.

A velocidade do machine learning, quando aplicado aos modelos de precificação, revoluciona o desenvolvimento de novos produtos, principalmente para linhas competitivas e instáveis, onde a capacidade de resposta às mudanças de mercado e novas probabilidades de perda são extremamente importantes. As seguradoras conseguem reduzir o tempo de criação de modelos de precificação baseados em perdas em 60-90%. Isso inclui a exportação de tabelas de tarifação para os reguladores, otimizando, de forma automática, a documentação elaborada e explorando estratégias de precificação alternativa, como por exemplo a criação de modelos para percorrer novos subsegmentos por setor, região ou cobertura. Mais importante ainda, além de se tornarem adaptáveis ao mercado, as seguradoras criam modelos precisos que otimizam precificação e rentabilidade.

A classificação por níveis de risco é uma prática do século 20. O século 21 pertence àqueles capazes de realizar avaliação de risco individualizado, precificação dinâmica e desenvolvimento rápido de novos produtos para aproveitar as oportunidades de mercado.

## Sinistros e engajamento

Sinistros representam o momento da verdade para as seguradoras. Se demorar muito para responder, corre-se o risco de lidar com a ira do cliente, mal julgamento de conduta pelo mercado ou queixas de má-fé. Se responder muito rápido, sem informações apropriadas, corre-se o risco de pagar a mais, excesso de reserva ou ser vítima de fraude.

IA é utilizada para fundamentar e, se necessário, automatizar a triagem dos sinistros. Esses recursos podem direcionar automaticamente sinistros *no touch* para processamento automático e designar sinistros *low touch* e *high touch* para reguladores individuais identificados pela análise como mais capacitados para gerenciar tais sinistros. Isso é semelhante à atribuição otimizada de subscritores descrita anteriormente.



Ao longo do processo de sinistro, a IA e o machine learning podem, automaticamente, distinguir os sinistros de acordo com seu tamanho e complexidade, chances de disputa judicial, probabilidade de fraude e potencial para sub-rogação. O modelo eficaz e preciso de desenvolvimento de sinistros resulta em uma maior precisão e menos surpresas na projeção de reserva.

Reservas podem ser mais precisas designando reguladores a avisos de sinistro similares e já liquidados, onde é possível coletar melhores práticas, bem como práticas a serem evitadas em uma análise de "sinistros como este". Modelos de machine learning analisam as reservas e projetam quais reservas têm a probabilidade de serem alteradas – talvez excedendo um certo limite (\$50) – ou identificando quais sinistros podem irromper em perdas graves ou aumentar até se tornarem inúmeras alterações de reservas.

As organizações de sinistros podem implementar métodos de melhoria contínua utilizando modelos de machine learning para identificar avisos de sinistro mais adequados para análise mensal de aviso, e aprender a partir das melhores (e não tão melhores) práticas apontadas como causas para inadequação de reservas. Esses aprendizados podem ser implantados para melhorar a atribuição de sinistros, prever alterações de reservas e oportunidades para treinamento dos reguladores.

Por fim, a IA e o machine learning fortalecem o engajamento com o cliente ao medir e prever os fatores que levam os clientes a renovar suas apólices ou deixá-las expirar, além dos fatores que tornam os clientes bons prospects para venda cruzada e venda casada de produtos novos ou otimizados, agregando, assim, ao seu valor do tempo de vida.

A leitura ótica de texto, seja online ou dos arquivos da empresa, captura os comentários dos clientes e possibilita aos usuários detectar, medir e prever o sentimento e a lealdade do cliente. Isso torna possível a gestão sistemática da *net promoter score* (NPS) da empresa, uma métrica de crescimento rápido em relação à aceitação e qualidade da empresa.



## Aprimorar o conhecimento das perdas

Conhecer os passivos de sinistro de uma seguradora é fundamental para o cálculo da reserva de sinistros. Os atuários criaram técnicas confiáveis para prever com precisão as obrigações de sinistros finais de uma seguradora, com métodos de previsão de triângulos e *chain-ladder*. Embora bem testadas ao longo do tempo, essas abordagens normalmente funcionam de cima para baixo em todos os sinistros, reconhecendo despesas adicionais incorridas, estimando reservas insuficientes (IBNER) e prevendo sinistros que ocorreram, porém ainda não foram avisados pelo cliente (IBNYR). Abordagens de cima para baixo preenchem os requisitos de relatórios financeiros, porém são um desafio para melhorar a precisão das reservas da cobertura primária do sinistro. Simplificando, é complicado alocar com precisão alterações individuais nas reservas da carteira existente de sinistros.

Com o *automated machine learning*, as empresas descobriram que podem desenvolver sinistros individuais, com muita precisão, até seu valor final. Da mesma forma, sinistros incorridos, mas não avisados, podem ser previstos e agregados às perdas desenvolvidas individualmente para produzir triângulos de perda extremamente precisos. Informações otimizadas podem ser combinadas com relatórios tradicionais como um complemento e ajudar a explicar quaisquer decisões para alterar as reservas.

Os métodos tradicionais *chain-ladder* são seriamente desafiados quando têm que explicar movimentações nas reservas (como comparativos trimestrais, por exemplo) e levam semanas para pesquisar. Por outro lado, modelos de perda individual podem identificar imediatamente quais sinistros levam a alterações nas reservas. Análise complementar explica, de forma rápida, as tendências de perda com base no sinistro, apólice e características do cliente comuns aos aumentos nas reservas. As respostas, agora, chegam em poucos dias em vez de semanas.

A precisão aprimorada de perdas permite uma infinidade de aplicações na seguradora. Modelos de precificação com base em perdas desenvolvidas individualmente são mais precisos e as áreas de sinistros podem revisar o desenvolvimento da perda e decidir como tratar mudanças previstas para cada sinistro. Reservas mais precisas liberam capital desnecessário e melhoram o índice combinado da empresa.



## O surgimento do automated machine learning

O automated machine learning (criado pela DataRobot) soluciona muitos dos desafios descritos acima e torna outros mais gerenciáveis.

### Automated Machine Learning

1. Busca o modelo mais adequado para o seu contexto específico, por meio da concorrência a partir de uma ampla biblioteca de modelos comuns — eliminando centenas ou até milhares de horas necessárias para encontrar o modelo mais adequado para o seu contexto.
2. Classifica os modelos com melhor desempenho para que você avalie e selecione os mais adequados para o seu contexto específico.
3. Oferece transparência no uso de dados de cada modelo, informando não apenas quais dados são mais importantes como também quando usá-los.
4. Explica previsões individuais até as variáveis de dados específicas e seus valores.
5. Fornece diagnóstico para entendimento da precisão do modelo utilizando uma variedade de métricas de desempenho.
6. Disponibiliza ferramentas para conhecer e tomar decisões *tradeoff* (por exemplo, entre velocidade e precisão, valor preditivo positivo versus negativo, quando e onde modelos adicionais podem ser justificáveis em termos de custos).
7. Cria, de forma automática, a maior parte da documentação necessária para validação de modelo e gestão de riscos do modelo, reduzindo o custo de oportunidade do tempo gasto em atividades de menor valor (atividades essas que os cientistas de dados, praticamente em toda parte do mundo, não gostam de investir seu tempo).
8. Reduz o custo, dificuldade e risco para implantar modelos em seu ambiente de produção, fornecendo opções de implantação minimamente invasivas, como geração de código, implantação de API e implantação de Hadoop.
9. Facilita o monitoramento do desempenho do modelo e detecção de desvios ou degradação do desempenho ao longo do tempo, alertando os responsáveis pelo modelo sobre a necessidade de retreiná-lo ou criação de modelos desafiadores.
10. Torna o retreino de modelos sobre novos dados e a reimplantação de modelos na produção algo simples, rápido e de baixo risco.



## Clareza e consistência

Muitos observadores, particularmente reguladores e consumidores ativistas, além dos executivos de empresas, estão apreensivos com o fato da IA gerar resultados imprecisos, "caixa-preta", que eles não conseguem entender ou explicar.

Nesse sentido, o DataRobot, por si só, comprova que todas as etapas nos seus processos de modelagem são visíveis e capazes de serem reproduzidas, identificando e expondo claramente fatores que apresentam valor preditivo. Em relação ao cliente, "esclarecimento sobre previsões" possibilita aos subscritores expor claramente aos corretores e clientes o motivo pelo qual uma cotação ou conta específica recebeu determinado preço, pontuação ou recomendação. Isso também reforça que os resultados do modelo podem ser explicados para executivos e reguladores.

Além disso, qualquer pessoa que já trabalhou com análise preditiva sabe que a precisão dos modelos "oscila" com novas experiências de sinistro e subscrição. Modelos criados a partir da IA e machine learning apresentam recursos integrados para informar aos usuários com que frequência e até que ponto os resultados atuais divergem das previsões demonstradas e quais fatores de variáveis podem estar causando a divergência.

## Principais casos de uso das seguradoras em relação à IA e machine learning

### Precisão da precificação dinâmica

Usando o DataRobot para precificação, uma grande seguradora de automóveis no Reino Unido substituiu um modelo *gradient boosting* por seu modelo linear generalizado (MLG) em uma de suas linhas de negócios. Como resultado, a seguradora reduziu sua taxa de sinistralidade, melhorou seu índice combinado, aumentou seus índices de retenção e reduziu seus custos de aquisição; ao todo, agregou um valor de £7 milhões. A capacidade do DataRobot de executar algoritmos lineares e não lineares simultaneamente ajuda na precificação precisa e específica ao risco, o que reduz vulnerabilidade à aceitação adversa.



### Redução de churn

As seguradoras perdem dinheiro quando bons clientes não renovam, pois as apólices vencidas precisam ser substituídas por novos negócios mais onerosos. Com o uso do DataRobot, uma grande seguradora europeia incorporou o risco de "churn" no seu preço de renovação, resultando em redução nos cancelamentos e não renovações, melhora na taxa de sinistralidade e 24% de redução nos custos variáveis. Ao todo, a empresa estima o montante a €12,5 milhões por ano.

### Mitigação de risco de disputa judicial

Uma grande seguradora de P&C dos Estados Unidos usou o DataRobot para criar um modelo para prever a probabilidade de um pedido de indenização trabalhista resultar em disputa judicial. As solicitações com pontuação alta para a probabilidade de disputa judicial são encaminhadas para equipe sênior de sinistros para que sejam feitas ofertas antecipadas e atrativas. A empresa estima que evitou 10% de disputas judiciais que teria enfrentado sem o modelo, resultando em uma redução de 25% no custo de pedidos que apresentavam risco e um montante estimado para a empresa de mais de \$5 milhões por ano.

### Detecção de fraude

O machine learning atual é muito mais eficaz do que regras estáticas para detectar métodos de fraude cada vez mais evoluídos. Num determinado caso, uma grande seguradora de P&C europeia implementou processamentos em lote noturnos de sinistros de veículos em um modelo criado a partir do DataRobot. As solicitações com pontuação alta para fraude foram designadas para uma equipe especializada de investigação de fraudes de sinistros. A empresa estima que aumentou a precisão da sua detecção de fraude em 30%, rendendo um valor maior que \$10 milhões.

### Recuperações com sub-rogação

Oportunidades de sub-rogação são como encontrar dinheiro, mas apenas se você conseguir identificá-las e agir rapidamente. Uma seguradora de automóveis da Europa continental trabalhou com o DataRobot para identificar sinistros com alta probabilidade de recuperação de sub-rogação. Os gerenciadores de sinistros recebem, agora, listas automatizadas de sinistros com metas de sub-rogação. A empresa dobrou seu índice de sub-rogação e espera recuperações anuais adicionais de €4-8 milhões por ano.



## Conclusão

A era do automated machine learning chegou. As seguradoras que adotarem o machine learning e o aproveitarem, considerando como introduzir esse aprendizado em cada parte da sua organização, dominarão sua concorrência. As seguradoras que hesitarem, atrasarem ou evitarem conhecer essa tecnologia vão perder terreno e, no final das contas, podem não resistir.

DataRobot é o criador e líder na categoria de automated machine learning. Como pioneiro, DataRobot desenvolveu a solução completa mais eficaz. Deixe nossa equipe de especialistas no setor de seguros mostrar como você pode atingir suas metas e vencer sua concorrência com o automated machine learning. Aproveite nossa experiência de trabalho com as seguradoras em todo o mundo na utilização do machine learning praticamente em todas as funções e linhas de negócios.

Para mais informações sobre o DataRobot ou para agendar uma demonstração, acesse [www.datarobot.com/insurance](http://www.datarobot.com/insurance)



## DataRobot

DataRobot ajuda as empresas a adotar inteligência artificial (IA). Criado pela DataRobot, o automated machine learning capacita as organizações na criação de modelos preditivos que revelam valores em dados, tornando o machine learning acessível aos analistas de negócios e possibilitando aos cientistas de dados atuarem com mais agilidade. Com DataRobot, as organizações se tornam orientadas por IA e capacitadas para automatizar processos, otimizar resultados e extrair insights mais aprofundados.

Inscreva-se para uma demonstração gratuita sobre como o DataRobot pode ajudar sua organização em [datarobot.com](https://datarobot.com)