

Machine Learning, uma peça-chave na transformação dos modelos de negócio



Design e diagramação

Departamento de Marketing e Comunicação
Management Solutions - Espanha

Fotografias

Arquivo fotográfico da Management Solutions
iStock

© Management Solutions 2018

Todos os direitos reservados. Proibida a reprodução, distribuição, comunicação ao público, no todo ou em parte, gratuita ou paga, por qualquer meio ou processo, sem o prévio consentimento por escrito da Management Solutions.

O material contido nesta publicação é apenas para fins informativos. A Management Solutions não é responsável por qualquer uso que terceiros possam fazer desta informação. Este material não pode ser utilizado, exceto se autorizado pela Management Solutions.

Índice



Introdução

4



Sumário executivo

8



A revolução digital e a transformação dos modelos de negócio


12



Conceito e tendências em aprendizagem automática

18

3



Exercício quantitativo

30



Bibliografia

38



Glossário

40

Introdução

I believe that at the end of the century the use of words and general educated opinion will have altered so much that one will be able to speak of machines thinking without expecting to be contradicted

Alan Turing¹



A revolução digital está provocando mudanças profundas nos hábitos de consumo dos clientes, devido, entre outros fatores, a um maior acesso aos dados e a um crescente desenvolvimento de novas tecnologias. Isso tudo nos convida a repensar profundamente os atuais modelos de negócio.

Uma alavanca fundamental para a transformação dos modelos de negócio é a ciência de dados (ou *Data Science*), que está baseada no uso combinado de técnicas de aprendizagem automática, inteligência artificial, matemática, estatística, bases de dados e otimização², conceito que já foi amplamente abordado em uma publicação anterior da Management Solutions³.

Existem diversos fatores, com origem principalmente na tecnologia, que impulsionam o uso destas técnicas de *Data Science* em um conjunto amplo de setores. Estes fatores podem ser agrupados em quatro eixos: (1) o aumento sem precedentes do volume e da tipologia de dados disponíveis; (2) a conectividade e o acesso aos dados; (3) a melhoria dos algoritmos utilizados; e (4) o aumento da capacidade computacional dos sistemas.

Em relação ao volume de dados, existem diversos estudos que reúnem diferentes métricas que permitem evidenciar a magnitude desse crescimento. Para citar alguns dos mais relevantes:

- ▶ De acordo com relatórios recentes, 90% dos dados criados em toda a história da humanidade foram criados no último ano e estima-se um crescimento de 40% anuais para a próxima década⁴. Atualmente, devido ao avanço das comunicações conhecidas como *Machine to Machine* (M2M), e ao desenvolvimento da chamada Internet das Coisas (IoT), o volume de dados disponíveis é ainda maior.
- ▶ Estudos publicados por grandes empresas de telecomunicações⁵ mostram que o número de dispositivos conectados à internet será três vezes maior que a população mundial em 2021 e que o número de conexões IoT chegará a 13,7 bilhões nesse mesmo ano, sendo que em 2016 esse número foi de 5,8 bilhões.
- ▶ Como consequência disso, em 2020 o total de dados existentes chegará aos 44 trilhões de gigabytes⁶.

- ▶ Entre eles, um grande conjunto de dados é gerado diretamente no ambiente digital, como buscas no Google (40.000 buscas por segundo), mensagens no Facebook (31 milhões de mensagens por minuto) ou aumento de dados em vídeos e fotos (300 horas de vídeos carregados no YouTube a cada hora).
- ▶ Estima-se que, em 2020, 100% dos dispositivos móveis irão incluir tecnologia biométrica⁷. Da mesma forma, para este ano, estima-se que pelo menos um terço dos dados passará pela nuvem⁸.

Em segundo lugar, as melhorias na conectividade implicam um salto qualitativo que permite o desenvolvimento de novos serviços e modelos de negócio ligados à geração de dados em tempo real, bem como a sua análise, para adaptar o serviço e o preço em função do uso: a geração e a coleta de dados é realizada de forma automática através da sensorização e da digitalização dos terminais no ponto de venda, o que cria um fluxo contínuo de informações. Uma grande parte desta conectividade é realizada entre máquinas: uma vez que uma ação é realizada, os dados gerados por diferentes elementos digitais envolvidos são conectados com servidores, com o objetivo de armazenar e analisar as informações. Este tipo de conexões M2M, cresceu até chegar a 1,1 bilhões de conexões em 2017⁹.

Em terceiro lugar, a melhoria dos algoritmos permitiu tanto otimizar o tratamento de grandes volumes de dados (através de técnicas de escalada, *resampling*, etc.) quanto obter métodos mais eficientes e robustos e tratar *missings*, variáveis não numéricas e atípicos. Apesar de a maior parte dos algoritmos ter sido desenvolvida antes do ano 2000, agora é que as empresas estão investindo mais na implementação destes algoritmos, obtendo melhores resultados que os alcançados por humanos. Por exemplo:

¹Turing, A.M. (1950). Matemático considerado o pai da ciência da computação. Decifrou a máquina Enigma durante a 2ª Guerra Mundial. Foi o precursor da informática moderna e da inteligência artificial.

²Dahr, V. (2013). Professor da Stern School of Business e Diretor no Center for Digital Economy Research, Nova Iorque.

³Management Solutions (2015).

⁴Ministério de Indústria, Energia e Turismo. Governo da Espanha (2018).

⁵Cisco (2017).

⁶Forbes (2015).

⁷Acuity Market Intelligence (2016).

⁸Forbes (2015).

⁹Statista (2017).

- ▶ Atualmente, os algoritmos de DeepMind AlphaZero e AlphaGo têm um nível de jogo superior a qualquer humano nos jogos de xadrez e go.
- ▶ Um algoritmo baseado em inteligência artificial é capaz de detectar um câncer de mama 30 vezes mais rapidamente do que um médico e com um grau de confiabilidade de 99%¹⁰.
- ▶ Nos Estados Unidos, os *roboadvisors*¹¹ possuem 25,83 milhões de usuários, o que representa um grau de penetração de 1,8% em 2018. Espera-se que este índice chegue a 8,3% em 2022¹².

Por último, o aumento da capacidade de computação, que nas últimas décadas cresceu enormemente apoiada na melhoria dos processadores, agora conta com outros fatores como principais impulsionadores: entre outros, a grande evolução das linguagens de programação (tanto generalistas como dedicadas a processamento de dados, visualização, algoritmos etc.), o *cloud computing* e, especialmente, a criação de novas arquiteturas de computação dirigidas especificamente a tarefas de aprendizagem automática, análise de dados e aplicações de engenharia (conhecidas como GPUs¹³).

Em resumo, nas últimas duas décadas, a disponibilidade de dados digitais aumentou quase mil vezes, ao mesmo tempo em que se registrou uma eficiência dez vezes maior nos algoritmos, e a velocidade de computação aumentou cem vezes o seu desempenho¹⁴. Isso tudo levou a um interesse renovado nestas técnicas como uma fórmula para obtenção de informações com valor agregado no novo ambiente de negócios.

Aprendizagem automática: mais de meio século de história

As técnicas de aprendizagem automática (ou *Machine Learning*) estão experimentando um auge sem precedentes em diferentes âmbitos, tanto no mundo acadêmico como no empresarial, e são uma importante alavanca de transformação. Ainda que estas técnicas já fossem conhecidas nos dois âmbitos, diversos fatores estão fazendo com o que seu uso seja mais intensivo, quando antes era minoritário, e se estenda a outros campos, quando antes praticamente não eram utilizadas, tanto pelos altos custos de implementação quanto pelos escassos benefícios inicialmente esperados por sua aplicação.

As técnicas de aprendizagem automática podem ser definidas como um conjunto de métodos capazes de detectar automaticamente padrões nos dados¹⁵. Com esta definição, o

¹⁰Forbes (2016).

¹¹Algoritmos automáticos que proporcionam assessoria e gestão online com uma mínima intervenção humana.

¹²Statista (2018).

¹³Graphics processing unit.

¹⁴Brynjolfsson, E. y McAfee, A. (2017). Brynjolfsson, professor no MIT Sloan School of Management. Diretor do MIT Initiative on the Digital Economy, Diretor do MIT Center of Digital Business. É conhecido por sua contribuição ao mundo de Produtividade de IT. McAfee, codiretor do MIT Initiative on the *Digital Economy* e Diretor associado do *Center for Digital Business*.

¹⁵Murphy, K. (2012). Pós-doutorado no MIT, professor em Ciências da computação na Universidade de British Columbia (Canadá), esse livro recebeu o prêmio *DeGroot* em 2013. Atualmente é pesquisador no Google (Califórnia) sobre Inteligência Artificial, *Machine Learning*, computer vision, e entendimento de linguagem natural.





conceito de aprendizagem automática existe pelo menos desde os anos 50, período em que foram descobertos e redefinidos diversos métodos estatísticos, e foram aplicados à aprendizagem automática através de algoritmos simples, circunscritos quase que exclusivamente ao âmbito acadêmico.

Este conceito de aprendizagem automática inclui, desde então, o uso de padrões detectados para realizar previsões ou para tomar outros tipos de decisões em ambientes de incerteza¹⁶.

Comparada às técnicas estatísticas clássicas, a introdução de técnicas de *Machine Learning* permite melhorar o processo de estimativa de modelos, não só em relação ao aumento de poder de previsão através de novas metodologias e técnicas de seleção de variáveis, mas também na melhoria da eficiência dos processos através da automatização.

Neste contexto, o presente estudo pretende dar uma visão sobre a revolução digital e seu impacto na transformação dos negócios, com um foco especial nas técnicas de aprendizagem automática. Para isso, o documento está estruturado em três seções, que atendem a três objetivos:

- ▶ Ilustrar o desenvolvimento da revolução digital e seu impacto em diferentes frentes.
- ▶ Introduzir a disciplina de aprendizagem automática, descrever diferentes abordagens e expor as tendências atuais nesta área.
- ▶ Expor um caso de estudo para ilustrar a aplicação de técnicas de *Machine Learning* no caso específico do setor financeiro.

¹⁶Ibid.

Sumário executivo



A revolução digital e a transformação dos modelos de negócio

1. A mudança de paradigma introduzida pela digitalização nos convida a repensar os atuais modelos de negócio.
2. O celular e a internet como porta de acesso a serviços on-line, as redes sociais como fonte de dados, a inteligência artificial e as arquiteturas *big data*, as infraestruturas para a computação distribuída e o uso de aplicativos na nuvem, o desenvolvimento das tecnologias de computação por blocos (*blockchain*), a aplicação de criptografia e biometria, a denominada internet das coisas, os robôs e assistentes virtuais, a impressão 3D e a realidade virtual e etc., são ferramentas úteis ao alcance das empresas que por um lado mudam o próprio ambiente e que, por outro, impulsionam uma reelaboração dos modelos de negócio neste novo ambiente.
3. Na era digital, os dados se convertem em uma clara fonte de valor. Seu volume aumenta exponencialmente pela digitalização dos processos e as crescentes interações com clientes, funcionários e fornecedores através de canais digitais.
4. Também adquirem um maior protagonismo: a experiência do cliente, a personalização da oferta, ou o conceito de acesso ao serviço em contraposição à propriedade; e se dá, ao mesmo tempo, a entrada de novos competidores cuja proposta de valor está baseada fundamentalmente em elementos tecnológicos.
5. A realidade é que a introdução da dimensão digital muda tudo na empresa, impactando em sua definição da estratégia, na governança, na organização e na cultura de trabalho, em seus processos comerciais e operacionais, no acesso, no armazenamento, no processamento e na modelagem de dados, na gestão e no controle de riscos (onde aparecem novos riscos, como os de segurança cibernética ou os relativos à proteção de dados pessoais, ou na ética da inteligência artificial); bem como na própria regulação, que se torna mais global.

Conceito e tendências na aprendizagem automática

6. Um dos elementos estruturadores desta transformação digital é a aprendizagem automática, ou *Machine Learning*: a aplicação de técnicas e algoritmos capazes de aprender a partir de diferentes e novas fontes de informação, construindo algoritmos que melhorem de forma autônoma com a experiência. Isso permite a utilização de métodos capazes de detectar automaticamente padrões nos dados e usá-los para prever dados futuros em um ambiente de incerteza.
7. Os componentes principais da aprendizagem automática podem ser classificados em quatro grupos:
 - As fontes de informação, que podem trazer dados tanto estruturados como não estruturados, que são a base dos demais componentes.
 - As técnicas e os algoritmos para o tratamento de informações não estruturadas (texto, voz, vídeo etc.) e para a obtenção de padrões a partir dos dados.
 - A capacidade de autoaprendizagem, que permite que o algoritmo se adapte às mudanças nos dados.
 - O uso de sistemas e *software* como veículo para a visualização da informação e a programação.
8. O desenvolvimento destes componentes representa uma evolução em relação ao enfoque tradicional da modelagem. Isso implica, entre outros elementos, o uso de um maior número de tipologias de fontes de informação, a capacidade de detecção de padrões ocultos nos dados a partir de métodos indutivos, a manutenção do poder de previsão durante mais tempo, bem como a necessidade de uma maior capacidade de armazenamento e processamento dos dados. Deste modo, a seleção da técnica de aprendizagem automática mais apropriada entre as múltiplas existentes dependerá, em grande parte, dos elementos citados.
9. Por um lado, algumas técnicas podem ser utilizadas para a transformação de informações não estruturadas (textos, sons, imagens etc.) em dados que possam ser analisados e processados por um computador. Entre estas técnicas é importante destacar o uso de estatísticas ou a classificação de palavras em categorias para a compreensão do texto escrito, o uso de redes neurais para o reconhecimento de voz ou de imagens, a aplicação de cadeias de Markov para a

construção de textos em linguagem natural, ou a aplicação de algoritmos não supervisionados de classificação para a organização de imagens.

10. Por outro lado, as técnicas de modelagem utilizadas com informações estruturadas podem ser classificadas como aprendizagem supervisionada ou não supervisionada, em função das informações utilizadas para a aprendizagem. Na aprendizagem supervisionada há uma variável-objetivo observada nos dados, enquanto que na aprendizagem não supervisionada, o objetivo é encontrar padrões ou relações entre eles.
11. No processo de modelagem, costuma-se realizar uma primeira fase de organização e preparação do conjunto de dados inicial, com o objetivo de facilitar e otimizar seu uso posterior. Para isso, são realizadas tarefas de análise descritiva e preparação dos dados (incluindo técnicas específicas de regularização, como por exemplo a aplicação de redes elásticas).
12. Entre as técnicas utilizadas na aprendizagem supervisionada podem ser destacadas as redes neurais (incluindo sua extensão ao *deep learning*), as máquinas de vetor suporte, os classificadores bayesianos ou as árvores de regressão e classificação.
13. Estas técnicas podem ser combinadas com algoritmos que permitem melhorar a capacidade preditiva, chamados métodos *ensemble*, que consistem na combinação de modelos para geração de um modelo mais preditivo ou mais estável.
14. Dentro da aprendizagem não supervisionada vale destacar as técnicas de *clustering* ou as técnicas de *Data Analysis*, como a de redução da dimensionalidade.
15. A aplicação destas técnicas faz com que os métodos de validação de resultados devam ser mais sofisticados, como o *bootstrapping* ou o *cross-validation*, que permitem analisar o modelo em mais de uma amostra de validação. Além disso, a natureza dinâmica destas técnicas dificulta a rastreabilidade dos modelos.
16. Há um grande número de casos de implementação de técnicas de aprendizagem automática em diferentes setores. Como exemplos, destacam-se as aplicações nos setores de educação (como tutores inteligentes), nas finanças (para o *trading* automático, *roboadvisors*, detecção da fraude, mensuração do risco, ou na elaboração de modelos *prospect* com fins comerciais), na saúde (o diagnóstico por imagem, a gestão de consultas de tratamento e sugestões, compilação de informações médicas ou a cirurgia robótica), ou, de modo transversal, na melhoria da eficiência das organizações (através, por exemplo, da melhoria da função de TI).
17. Entre as principais tendências na implementação de técnicas de *Machine Learning*, pode-se destacar o uso de fontes de informação que compilam dados em tempo real, a

maior importância dada para obter um poder preditivo elevado em relação à interpretabilidade dos modelos, incorporar a capacidade de que o algoritmo seja modificado de forma autônoma em função das mudanças que vão ocorrendo na população-objetivo, ou o investimento em arquiteturas e infraestruturas tecnológicas que garantem a escalabilidade na capacidade de armazenamento de dados e uma maior velocidade de processamento, combinadas com soluções baseadas em *Cloud* e no uso de infraestruturas de *edge computing*, onde são oferecidas funções já previamente instaladas preparadas para seu uso direto (*Functions as a Service*).

18. Tudo isso pressupõe uma série de desafios e dificuldades. O uso de novas fontes de informação acarreta a necessidade de realizar um investimento econômico para identificar novas fontes de dados relevantes, incorporar técnicas de *data quality*, garantir a proteção das informações ou estabelecer controles e sistemas de segurança cibernética.
19. A aplicação de novas técnicas e algoritmos acarreta também a necessidade de reforçar a função de gestão do risco de modelo, realizar uma escolha prévia do algoritmo mais adequado entre uma ampla variedade de possibilidades ou verificar se os resultados automáticos não implicam na aparição de tratamentos discriminatórios. Incorporar a característica da autoaprendizagem nos modelos pode dificultar a sua validação e exige considerar novos elementos, como o controle dos graus de liberdade na automatização, uma maior frequência na avaliação do poder discriminante ou outras técnicas de contraste. Finalmente, tudo isso acarreta a necessidade de realizar investimentos em recursos e infraestruturas de TI.
20. Além disso, a introdução da aprendizagem automática nas organizações pressupõe a necessidade de contar com recursos humanos com um alto grau de preparação e especialização, capazes de compreender e trabalhar com linguagens de programação, algoritmos, matemática, estatística e arquiteturas tecnológicas complexas.

Exercício quantitativo: uso de técnicas de Machine Learning na construção de um modelo de scoring

21. Os objetivos do exercício proposto foram: (i) analisar e ilustrar o impacto do uso de técnicas de *Machine Learning* no desenvolvimento de modelos e (ii) avaliar a variação do processo de estimativa e os resultados obtidos mediante o uso de Técnicas de *Machine Learning*.
22. Para isso, um modelo de *scoring* foi treinado, utilizando diferentes algoritmos de *Machine Learning*, e os resultados foram comparados com os obtidos com técnicas tradicionais.
23. O estudo foi realizado utilizando um conjunto de mais de 500 mil empréstimos, que compreendem mais de 10 anos

de história, com uma taxa de inadimplência de 6%. A amostra inclui informações relativas à operação e ao cliente, bem como outras informações que podem ser úteis na modelagem, como comissões, número de transações realizadas etc.

24. Em uma primeira fase de *knowledge discovery* foi realizado um tratamento de *missings* (mediante técnicas de alocação através, entre outros, do uso de algoritmos de *clustering* ou de modelos de regressão), uma análise e tratamento de atípicos e um processo de simplificação e agrupamento de variáveis (utilizando novamente algoritmos de *clustering*). Isto permitiu reduzir o número de variáveis, com o objetivo de melhorar a eficiência dos processos posteriores e preparar as informações existentes para adequar os requisitos específicos dos diferentes modelos e possíveis limitações dos algoritmos.
25. Em uma segunda fase foram avaliados diferentes modelos: uso tradicional (logístico) que serve como comparação e cinco técnicas de *Machine Learning*: um modelo com técnicas de regularização (rede elástica), dois métodos ensemble (um *random forest* e um *adaboost*) e duas máquinas de vetor suporte (utilizando, respectivamente, uma função linear e uma radial). Posteriormente, realizou-se o cálculo de duas medidas da capacidade discriminante sobre uma amostra de validação: a taxa de acerto do modelo (baseada em uma estimativa do ponto de corte) e a área sob a curva ROC.
26. Após a comparação com estas estatísticas observa-se que três das técnicas analisadas permitem melhorar o poder preditivo do modelo, tanto na taxa de acerto¹⁷ como no poder discriminante: o *random forest*, a aplicação da rede elástica e o *adaboost*.
27. Particularmente, o *random forest* é o que apresenta o melhor resultado comparado às demais metodologias: em termos de taxa de acerto melhora de 74,7% do modelo tradicional para 80,3%, o que representa um aumento percentual de 7,5% sobre o obtido através de técnicas tradicionais; em termos de poder discriminante, consegue-

se melhorar a área sob a curva ROC de 81,5% no modelo tradicional até 88,2%, o que representa um aumento percentual de 8,2%. O segundo melhor método é a aplicação da rede elástica, com a qual os valores de taxa de acerto e a área sob a curva ROC chegam a 79% e 86,4% respectivamente. Isto representa um aumento percentual de 6% em ambos os indicadores.

28. Este aumento do poder preditivo implica que, com um mesmo volume de negócio, a taxa de inadimplência se reduziria em 48%, no caso do *random forest* (utilizando um ponto de corte ideal com o modelo clássico, chegaria a uma taxa de inadimplência de 2,1%, que se reduz a 1,1% com o *random forest* se o volume de operações aprovadas for mantido), e 30% no caso da rede elástica (em que a taxa de inadimplência se reduz a 1,4%). Da mesma forma, bem como a taxa de inadimplência, o volume de negócio aumentaria 16% no caso do *random forest* e 13% no caso da rede elástica.
29. No entanto, estas melhorias foram alcançadas através de um aumento da complexidade em relação ao modelo tradicional, tendo utilizado um total de 80 variáveis entre as 50 árvores que compõem o bosque, no caso do *random forest*, e um total de 45 variáveis após a aplicação da rede elástica, em comparação com 11 variáveis no modelo tradicional.
30. Portanto, como foi observado no estudo realizado, as técnicas de *Machine Learning* permitem melhorar o poder discriminante dos modelos, o que implica em melhorias no negócio, mas à custa de uma maior complexidade tanto de um ponto de vista estatístico quanto pelo volume de informação utilizada, o que gera uma maior dificuldade na hora de analisar a interpretação dos resultados e a necessidade de reforço dos procedimentos de validação (entre outros, utilizando modelos replicáveis que façam challenge em relação aos modelos de *Machine Learning* e explicando as diferenças nas saídas de ambos os modelos).

¹⁷Porcentagem de operações corretamente classificadas pelo modelo, definido um ponto de corte.



A revolução digital e a transformação dos modelos de negócio

Technology doesn't provide value to a business. Instead, technology's value comes from doing business differently because technology makes it possible

George Westerman¹⁸



Há alguns anos vêm aparecendo inúmeras iniciativas para a transformação, tanto dos processos quanto dos sistemas utilizados pelas empresas, o que impacta definitivamente na maneira de trabalhar. Estas iniciativas surgem tanto no âmbito da empresa privada quanto no setor público e se fundamentam na combinação de infraestruturas físicas com elementos novos, provenientes do desenvolvimento da tecnologia digital e da biotecnologia.

Este conjunto de mudanças não é simplesmente uma continuação e uma sofisticação dos sistemas de produção atuais, mas implica em um novo paradigma, a chamada quarta revolução industrial. Este paradigma se baseia em mudanças radicais na produção, ligados à velocidade de implementação sem precedentes históricos, e no alcance dessa transformação, que afeta um conjunto elevado de elementos da cadeia de valor¹⁹.

Dentro desta revolução industrial, o conceito de transformação digital aglutina as iniciativas relacionadas diretamente com as tecnologias digitais. Segundo alguns autores²⁰, a transformação digital pode ser definida como:

“The use of new digital technologies (social media, mobile, analytics or embedded devices) to enable major business improvements (such as enhancing customer experience, streamlining operations or creating new business models)”

Estas tecnologias digitais impactam diretamente os processos, em questões relativas à velocidade, à segurança ou à transparência, o que permite o desenvolvimento de novos serviços que antes não existiam, por falta de mercado ou de rentabilidade, já que as tecnologias digitais, em geral, apresentam poucas barreiras de entrada e com custos marginais que tendem a zero.

Além disso, também afeta os intermediários de serviços ao corrigir, pelo menos parcialmente, algumas imperfeições de mercado como as informações assimétricas, os custos de transação ou as assimetrias no fechamento de oferta e demanda, através do uso de plataformas B2B ou P2P²¹ com uma mínima intervenção de terceiros.

Além disso, a gestão de dados passou a ser um ativo fundamental para a empresa, sendo ao mesmo tempo matéria-prima e gerador de negócio. A digitalização dos processos e a interação com clientes, funcionários e fornecedores através de canais digitais traz uma grande quantidade de informação que pode ser aproveitada para novas oportunidades. A modo ilustrativo, segundo a Comissão Europeia, o valor da economia dos dados na União poderia chegar em 2020 a até 4% do PIB (mais do dobro em relação à situação atual).

Por último, também representa uma mudança de paradigma no mercado de trabalho, já que requer a execução de tarefas mais qualificadas, o que implica na necessidade de realização de um maior investimento tanto no sistema educativo como nos planos de treinamento contínuo das empresas.

No entanto, como será comentado mais adiante, a transformação digital não se refere às novas aplicações e usos da tecnologia, mas sim a como estas tecnologias modificam o ambiente em que as empresas operam e como elas devem se adaptar a este novo ambiente (Figura 1), utilizando precisamente estas tecnologias nos processos e sistemas, mas também mudando sua organização e estratégia.

Figura 1. Elementos da transformação digital



¹⁸Westerman, G. (2017). Pesquisador no MIT *Initiative on the Digital Economy* e Co-autor do best seller *“Leading Digital: Turning Technology Into Business Transformation”*

¹⁹Schwab, K. (2016). Economista e empresário alemão, conhecido principalmente por ser o fundador do Fórum Mundial de Economia.

²⁰Fitzgerald et al. (2013). Editor e colaborador em temas relacionados à transformação digital no MIT *Sloan Management Review*.

²¹B2B: *Business to Business*. P2P: *Peer to Peer*.

Tecnologias da transformação digital

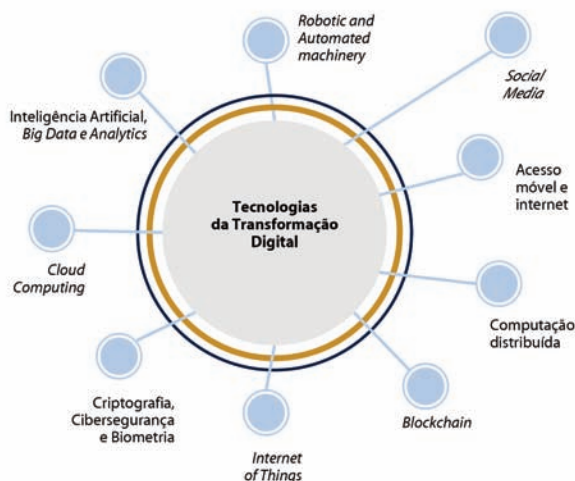
A transformação no âmbito empresarial, que abrange diversos âmbitos e propostas, fundamenta-se em uma série de desenvolvimentos tecnológicos que, mesmo obedecendo a diferentes origens e naturezas, possuem elementos em comum: sua forte alavancagem no investimento, a geração e o uso de grandes volumes de dados e o objetivo de melhorar a experiência do cliente e a eficiência operacional. Entre as principais tecnologias que impulsionam a transformação, encontram-se as seguintes (Figura 2):

- ▶ **Acesso móvel e internet:** devido à generalização das telecomunicações e ao acesso a uma ampla diversidade de serviços *on-line*, interfaces de programação de aplicativos (APIs) estão sendo desenvolvidas pelas empresas, o que lhes permite ter novos canais de interlocução com os clientes e contar com um amplo conjunto de dados. Isto leva à aparição de novas formas relevantes de informação, como a geolocalização. Além disso, o acesso móvel permitiu a universalização do acesso à informação e à comunicação, independentemente da localização física. Por exemplo, as comunicações de banda larga móvel aumentaram cinco vezes nas economias desenvolvidas nos últimos 10 anos²².
- ▶ **Social Media:** as redes sociais são uma fonte de dados que proporciona uma melhor compreensão do comportamento dos clientes e uma maior produtividade através da melhoria da comunicação interna. As tendências relacionadas com a *Social Media* são um *marketing* muito mais segmentado e direcionado, além de novas formas de comunicação em tempo real.
- ▶ **Inteligência artificial, Big Data e Analytics:** ferramentas de detecção de padrões e modelos de previsão de comportamento baseadas no uso de enormes bases de dados (que contêm informações tanto estruturadas como não estruturadas²³-logs de conexão à internet, mensagens em redes sociais etc.-) e na aplicação de técnicas de modelagem e algoritmos avançados. Tudo isso permite obter um melhor conhecimento do cliente, o que melhora a

segmentação, a personalização do produto e do preço e permite um *marketing* mais eficiente.

- ▶ **Computação distribuída²⁴:** os recursos tecnológicos (armazenamento, processamento, fontes de dados e supercomputadores) podem ser encontrados distribuídos geograficamente, mas sua interconexão pode ser aproveitada pelos usuários em qualquer parte do mundo.
- ▶ **Cloud computing:** o uso de aplicativos na nuvem também permite o acesso à informação em qualquer lugar, facilita operações comerciais e permite maior rapidez, segurança e custos mais baixos. Isto leva a um novo modelo de negócio em que esses recursos são oferecidos como *utilities* e cobrados como um serviço.
- ▶ **Distributed Ledger Technology (Blockchain):** estrutura de dados que implementa um sistema de registro distribuído (*ledger*), ou seja, um registro criptográfico de todas as operações realizadas e previamente validadas por uma rede de nós independentes através de um algoritmo de consenso. Isso permite o registro de qualquer ativo digitalizável, como criptomoedas, instrumentos financeiros ou "*smart contracts*" (contratos programáveis que implementam regras de negócio e cujo código fica registrado e pode ser executado de forma distribuída pelos diferentes nós da rede). Tudo isso traz rapidez nas operações, segurança e privacidade, através de regras criptográficas que permitem o registro inviolável das operações, transparência (já que todas as operações são armazenadas no registro e podem ser auditadas por qualquer membro da rede), eliminação de um ponto único de decisão e diminuição de custos (elimina-se a intermediação para validar e registrar as operações).
- ▶ **Criptografia, cibersegurança e biometria:** novas ferramentas criptográficas e iniciativas que buscam a melhoria dos processos de segurança e criptografia da informação, bem como a criação de sistemas de segurança mais robustos baseados em sensores e biometria.
- ▶ **Internet of Things:** em contraposição aos sistemas de comunicação clássicos, o conceito de internet das coisas se refere à interconexão através de redes abertas de dispositivos com capacidade computacional que enviam e recebem dados sem intervenção humana, o que permite a compilação massiva e direta de dados, bem como a operação remota em tempo real dos dispositivos conectados à internet. Esta tecnologia, por um lado, melhora a experiência do cliente, mas ao mesmo tempo permite o uso destes dados em alguns processos comerciais, como é o caso do *pricing* ou a busca da eficiência.

Figura 2. Tecnologias da transformação digital.



²²International Telecommunication Union (2017).

²³Pode ser entendida como informação estruturada aquela que está processada e preparada para ser utilizada diretamente através de linguagens estatísticas e de programação. A informação não estruturada é aquela que não cumpre estas características, como as informações em linguagem natural (texto, áudio), imagens, vídeo etc.

²⁴International Telecommunication Union (2009).

- ▶ **Robotics and automated machinery:** As ferramentas RPA²⁵ e os assistentes virtuais baseados na interpretação da linguagem natural permitem automatizar tarefas repetitivas de baixo valor agregado, tradicionalmente realizadas de forma manual, de modo que esta capacidade disponível possa se orientar a tarefas de maior valor agregado. As indústrias dirigidas ao usuário final estão adaptando rapidamente esta nova tecnologia com o objetivo de melhorar a qualidade dos produtos e reduzir os custos de manufatura.
- ▶ **Impressão 3D:** dirigida à fabricação deslocalizada e descentralizada de objetos a partir da recepção remota e digitalizada do *design* industrial, com aplicação em diversos setores e uso direto por parte dos consumidores (nos setores aeronáutico, automotor, eletrônico, médico etc.).
- ▶ **A realidade aumentada e a realidade virtual:** apresentam múltiplas aplicações, como na indústria dos vídeo-games, ou de conteúdos multimidiáticos, treinamento de funcionários de indústrias muito especializadas, o suporte em consertos e manutenção na indústria energética, o apoio em vendas de moradias, buscadores de moradia, escritórios bancários, caixas eletrônicos etc.

O novo ambiente da transformação digital

O novo ambiente digital está modificando significativamente as condições nas quais os mercados alcançam seu equilíbrio, tanto através da modificação nas empresas ofertantes como das expectativas e do comportamento dos consumidores, bem como das diferentes condições nas quais as operações são realizadas (compra e venda de produtos, serviços etc.).

Como será comentado nesta seção, a transformação digital está ocorrendo em um ambiente onde existem diferentes impulsionadores. Por um lado, as novas capacidades tecnológicas são a sua origem, mas o elemento fundamental que possibilita a transformação são as mudanças nos clientes ou nos mercados provocados pela tecnologia, o que possibilita, fomenta e requer sua implementação nas empresas para poder se adaptar a este novo paradigma.

Estas mudanças são ampliadas como consequência da desaparecimento das barreiras de entrada existentes nos setores (Figura 3).

Isso porque este aumento da oferta de bens e serviços está motivado por diversos fatores. Um dos principais é a entrada de novos competidores cuja proposta de valor está baseada fundamentalmente em um elemento tecnológico, o que tem

uma influência determinante no modelo de negócio e nos elementos associados (elevada capacidade de crescimento, baixo custo e custo marginal decrescente, fortemente alavancado na tecnologia móvel, na análise de dados, nas tecnologias *cloud* e na cibersegurança).

Além da entrada de novos competidores, estes em alguns casos substituem o produto ou o serviço oferecido por um totalmente digital ou híbrido, o que resulta em menores custos e preços, e em uma fácil e rápida substituição do serviço tradicional. Este é o caso de novos modelos de serviço baseados no uso de algoritmos que interpretam dados de redes sociais e outras fontes pouco convencionais para fornecer informações relevantes para seus clientes em tempo real, substituindo dessa forma as fontes tradicionais de informação.

Por último, os fornecedores podem influir também na adaptação de processos específicos ao gerar plataformas de comunicação e enfoques de negócio digitais que facilitam a migração dos processos de abastecimento de produtos ou serviços a seus clientes.

Tudo isso implica que os agentes clássicos nos mercados, em resposta, também estejam adaptando seus modelos de negócio, apesar da presença de diversos inibidores da transformação digital, como a resistência à mudança, a cultura ou a falta de formação das pessoas.

Os fatores tecnológicos anteriormente comentados também atuam indiretamente como um motor de mudança na forma de entender a prestação de serviços por parte dos clientes.

As mudanças na forma de consumir são sintetizadas pelo World Economic Forum (WEF) em três elementos²⁶:

1. Maior protagonismo da experiência do cliente: a experiência de compra ganha mais valor, de forma que qualquer pessoa, empresa ou instituição opta por um produto ou serviço não apenas com base na sua qualidade e no seu preço, mas também pela experiência que este proporciona (por exemplo em prazos de entrega ou qualidade do serviço pós-venda).

15

Figura 3. Porcentagem de entrevistados que consideram muito provável que um setor seja afetado por tendências digitais.



Fonte: Harvard Business Review (2017).

²⁵Robotic Process Automation.

²⁶Digital Consumption (2016).

2. Hiperpersonalização da oferta: os clientes possuem maiores expectativas sobre a adaptação do produto ao seu gosto pessoal. A tecnologia digital permite cumprir com estas expectativas sem aumentar drasticamente os custos.

3. Acesso, mais que propriedade: o conceito de acesso substituindo o de propriedade está sendo generalizado. Os clientes preferem o acesso sob demanda, otimizando dessa maneira o consumo.

O sucesso de iniciativas como a da Amazon exemplificam essas questões, em que a experiência do cliente no processo de compra é enriquecida com uma seleção personalizada de produtos relacionados, e a oferta de valor ao cliente inclui o produto e certa personalização nos prazos e mecanismos de entrega, ou o das plataformas de conteúdos Netflix ou Spotify, em que o cliente acessa os conteúdos sem possuir a propriedade, por um custo menor.

Paralelamente, as próprias normas internacionais estão se adaptando ao novo ambiente, tornando-se mais globais e incisivas, especialmente nos aspectos relativos à proteção de dados pessoais.

Por último, o próprio mercado de trabalho se vê impactado, com uma crescente demanda de perfis tecnológicos e quantitativos (STEP), e também a gestão dos recursos humanos, gerando uma maior flexibilidade e a fragmentação do trabalho, bem como mudanças na mensuração do desempenho, nas estratégias de contratação ou nas necessidades de formação.

Efeitos nas organizações e nos âmbitos de atuação

Muitas organizações estão incorporando novas tecnologias em seus processos (com maior ou menor grau de integração), mas nem sempre com o mesmo objetivo. Algumas empresas pretendem se beneficiar das novas tecnologias com o objetivo de ser mais eficientes, reduzir custos, outras como um meio de chegar a novos mercados, mas apenas algumas as aproveitam para gerar novos modelos de negócio.

Segundo uma pesquisa da Comissão Europeia²⁷, as empresas tendem a utilizar estas tecnologias, tais como serviços móveis, tecnologia cloud, social media, etc. (Figura 4), para melhorar funções de negócio específicas, mais do que como uma ferramenta inovadora para transformar os modelos de negócio.

A transformação digital nas empresas, entendida como uma mudança disruptiva, tem implicações não apenas nos processos e sistemas, adaptando-os às novas ferramentas e aos enfoques de trabalho, mas em sua governança, em sua organização e na própria definição estratégica.

É importante, portanto, posicionar-se em cada um dos principais âmbitos de atuação afetados pela transformação digital (Figura 5).

Estratégia e mobilização. Uma aproximação estratégica ao objetivo digital implica um questionamento dos atuais modelos de negócio e suporte. Não há uma receita universal que sirva para qualquer empresa, mas a transformação digital não é uma opção, e sim uma necessidade cujos tempos e alcance dependerão do contexto de cada empresa.

Existem diversas fórmulas para realizar esta transformação, tanto em relação à posição de uma entidade diante das novas tecnologias (*early adopter*, seguidor, desafiador etc.) como em relação à participação de terceiros (*joint ventures*, colaboração com *start-ups*, universidades, centros de pesquisa, fundos de capital de risco, outras empresas ou, até mesmo, através de plataformas baseadas em ambientes abertos).

Um primeiro passo muito importante é documentar bem a situação de partida de cada empresa e de seu setor para, em seguida, tentar deduzir as oportunidades e as ameaças que a digitalização apresenta.

Outra questão fundamental é a liderança da transformação, que deve ser feita pelo primeiro executivo da empresa. Também não se deve esquecer o impacto dessa transformação nas pessoas e na própria cultura de trabalho da empresa.

Considerando que os custos e riscos são elevados, bem como os prazos incertos, é importante sintetizar e priorizar os objetivos da transformação, assim como contar com indicadores específicos (como o impacto econômico, a melhoria da experiência do cliente ou a vinculação dos funcionários) que ajudem a mensurar o grau de cumprimento de tais objetivos.

Organização, cultura e governança. A forma de trabalhar e organizar o trabalho também está mudando. As estruturas organizacionais ficam mais horizontais, com equipes multidisciplinares, organizadas em projetos, adotando princípios e desenvolvendo organizações *Agile*. Além disso, as tecnologias modificam a interação, a comunicação e a tomada de decisões.

Também surgem novas funções, como as relacionadas com a visão estratégica da tecnologia, governança dos dados e dos modelos, a proteção de dados pessoais ou a segurança informática (cibersegurança).

Figura 4. Porcentagem da adoção das principais tecnologias.



Fonte: EC (2017)

²⁷EC (2017).

Processos comerciais. As empresas estão revisando seus modelos de produção e distribuição, repensando o uso de seus canais digitais e tradicionais. Neste contexto, destaca-se a alavanca de mobilidade. O canal móvel se transforma em um elemento centralizador da relação com o cliente.

Por outro lado, procura-se uma maior personalização da proposta de valor (interpretando as informações disponíveis através de sua modelagem), procurando assim melhorar a experiência do cliente.

Processos operacionais. O objetivo fundamental da transformação dos processos operacionais (*end-to-end*) é a melhoria da eficiência e da qualidade do serviço aos clientes, bem como o fortalecimento do controle das operações.

Para alcançar esses objetivos, proliferam iniciativas como a criação de *back offices* sem papel, a digitalização dos *contact centers*, a sensorização dos processos de produção, a robotização dos centros de processamento etc.

Dados e modelagem. A maior capacidade de armazenamento e de tratamento de dados, facilita uma exploração mais eficaz das informações disponíveis, mas também surgem novos desafios, como o uso de informações não estruturadas, a gestão de grandes volumes de dados ou a análise de informações em tempo real.

Também são incorporadas técnicas de modelagem e de aprendizagem automática (como redes neurais, redes profundas, máquinas de vetor suporte, classificadores bayesianos, árvores de classificação e regressão etc.), que contribuem para a melhoria dos processos de decisão.

Proteção de dados. No contexto atual, os dados se converteram em um ativo estratégico. Por isso, as suas confidencialidade e segurança são elementos fundamentais para o negócio, especialmente no que diz respeito aos dados de caráter pessoal.

Como consequência, é necessário realizar uma gestão proativa da permissão dos usuários, que permita, ao mesmo tempo, cumprir com a regulamentação e explorar adequadamente o

potencial dos dados disponíveis. Isso significa contar com políticas de gestão de consentimento e finalidade, bem como de tratamento transfronteiriço, identificar e manter repositórios de dados de caráter pessoal, vincular ações comerciais aos usos permitidos etc., o que implica uma oportunidade para repensar a estrutura e a governança dos dados de uma empresa.

Cibersegurança. Nos últimos anos, o risco cibernético aumentou devido a diversos fatores, como a existência de um maior e mais complexo ambiente tecnológico nas empresas, a integração de empresas de diferentes setores ou a própria profissionalização dos ataques. Os danos por ataques cibernéticos já chegaram aos 3 trilhões de dólares por ano e estima-se que em 2021 chegarão a 6 trilhões anuais²⁹. Isso ganha grande importância em um contexto de transformação digital, em que um possível incidente pode ter impacto na continuidade de negócio da empresa.

A cibersegurança dentro da estratégia de digitalização passa pela realização de iniciativas que evitem riscos durante e após os processos de transformação. Entre as principais iniciativas, pode-se destacar a implementação de instâncias de cibersegurança, a revisão da estrutura organizacional associada à cibersegurança, à identificação e à revisão dos sistemas e serviços críticos, à mensuração do risco ou à geração de respostas eficazes em caso de incidentes.


Novas tecnologias. O investimento em novas tecnologias é um elemento decisivo em todo o processo de transformação digital. Para isso, é necessário possuir conhecimentos suficientes em tecnologia da informação e das comunicações.

Isso porque a evolução das plataformas tecnológicas a ambientes de nuvem, a definição de arquiteturas de *software* que incorporam soluções abertas, a utilização de tecnologias disruptivas (*big data*, *AI*, *block-chain*, *IoT*, *biometria*, *robotics*, etc.) se converteram em questões centrais da estratégia empresarial.

²⁸Círculo de Empresários (2018).


²⁹Cybersecurity Ventures (2017).

Figura 5. Âmbitos de atuação da transformação digital²⁸.



Conceito e tendências na aprendizagem automática

All models are wrong, but some models are useful
George Box³⁰



Como já exposto, a quantidade de dados disponíveis e a variedade de fontes apresentam um crescimento exponencial, que ultrapassa a capacidade de análise do ser humano. O uso de novas fontes de informação, bem como a aplicação de técnicas e algoritmos capazes de aprender a partir de informações novas³¹, permite obter uma série de benefícios, entre os quais vale destacar:

- ▶ O aumento das tipologias de dados (tanto estruturados quanto desestruturados) e fontes de informação que podem se incorporar aos processos de modelagem.
- ▶ O uso eficiente de grandes quantidades de dados nos processos de tomada de decisões.
- ▶ A detecção de padrões sofisticados ou não evidentes, não baseados em hipóteses realizadas a priori.
- ▶ A maior automatização dos processos de modelagem e autoaprendizagem, que facilita o incremento do poder preditivo dos modelos. Uma vez desenhados e implementados, seus requerimentos de calibração e manutenção são inferiores aos tradicionais, reduzindo assim os tempos de modelagem e custos.

Conceito e componentes da aprendizagem automática

A definição clássica de aprendizagem automática se baseia nos primeiros estudos para o desenvolvimento de técnicas de aprendizagem :

"Campo de estudo que dá aos computadores a capacidade de aprender sem serem explicitamente programados".³²

Assim, o campo de estudos da aprendizagem automática se dedica a construir algoritmos que melhorem de forma autônoma com a experiência³³. Do ponto de vista da ciência da computação, a experiência se materializa nas informações produzidas através de processos de armazenamento de dados. Portanto, os modelos e os algoritmos que constituem o corpo desta disciplina se fundamentam na extração de informações a partir de diferentes fontes de dados. Tudo isso leva à definição formal de aprendizagem automática³⁴:

"A computer program is said to learn from experience E with respect to some task T and some performance measure P, if its performance on T, as measured by P, improves with experience E".

De um modo menos formal, pode-se definir³⁵ o campo de aprendizagem automática como um conjunto de métodos capazes de detectar automaticamente padrões nos dados e usá-los para fazer previsões sobre dados futuros, ou para tomar certas decisões em um ambiente de incerteza. Portanto, as técnicas de aprendizagem automática partem de um conjunto de

³⁰Box, G. y Draper, N. (1987). Box, estatístico britânico que trabalhou nas áreas de controle e qualidade, análise de séries temporais, desenho de experimentos, e na inferência bayesiana, é considerado como uma das mentes mais brilhantes da estatística do século XX. Draper, professor emérito no departamento de estatística da universidade de Wisconsin, Madison.

³¹Shalev-Shwartz, S. e Ben-David, S. (2014). Shalev-Shwartz, professor na Faculdade de Ciências da Computação e Engenharia da Universidade de Jerusalém, Israel. Ben-David, professor na Escola de Ciências da Computação na Universidade de Waterloo, Canadá.

³²Parafraseado de Samuel, A. (1959). A citação textual é: "Programming computers to learn from experience should eventually eliminate the need for much of this detailed programming effort". Samuel, Master em Engenharia Elétrica pelo MIT, unificou os laboratórios Bell, trabalhou no primeiro computador comercial de IBM e foi professor na Universidade de Stanford.

³³Mitchell, T. (1997). Doutorado na Stanford, professor da cátedra E. Fredkin no departamento de Machine Learning da escola de Ciência da Computação na Universidade de Carnegie Mellon.

³⁴Mitchell, T. (1997).

³⁵Murphy, K. (2012). Pós-doutorado no MIT, professor em Ciências da computação na Universidade de British Columbia (Canadá), esse livro recebeu o prêmio DeGroot em 2013. Atualmente é pesquisador no Google (Califórnia) sobre Inteligência Artificial, Machine Learning, computer vision, e entendimento de linguagem natural.



dados observados³⁶, sobre os quais serão obtidas regras de classificação ou padrões de comportamento, que serão aplicados sobre dados diferentes àqueles utilizados para a análise³⁷.

A partir dessa definição, podem ser englobados os diferentes componentes da aprendizagem automática:

- ▶ As **fontes de informação**, que refletem a experiência E da qual se aprende.
 - Dados estruturados: bases de dados relacionais, sistemas de arquivos, etc.
 - Dados não estruturados: transacionais, Marlin, CRM, voz, imagens, etc.
- ▶ As **técnicas e os algoritmos**, que se relacionam com as tarefas T a serem realizadas.
 - Técnicas para o tratamento da informação não estruturada: *tf-idf*, *parsing*, mapas auto-organizativos, etc.
 - Modelos supervisionados e não supervisionados: modelos de classificação, modelos estocásticos, simulação, otimização, obstina, etc.
- ▶ A **capacidade de autoaprendizagem**, que melhora as métricas de desempenho P.
 - Retreinamento automático a partir de nova informação.
 - Combinação de modelos e reponderação/ calibração.
- ▶ O uso de **sistemas e software** para a visualização da informação e a programação³⁸:
 - Visualização: QlikView, Tableau, SAS Visual Analytics, Pentaho, TIBCO Spotfire, Power BI.
 - Programação: R, Python, Scala, Ruby, SAS, Java, SQL, Matlab, C, Google, AWS, Azure.

O desenvolvimento destes componentes implica uma evolução em relação ao enfoque tradicional da modelagem. Essa evolução apresenta uma série de diferenças em relação ao enfoque tradicional³⁹ (Figura 6).

Técnicas de aprendizagem automática

Figura 6. Diferenças da aprendizagem automática em relação ao enfoque tradicional.

	Modelagem tradicional	Machine Learning
1 Fontes de Informação	<ul style="list-style-type: none"> ▶ Dados estruturados ▶ Número reduzido de fontes de dados ▶ Limitadas pelo projeto inicial, estrutura e processos internos de obtenção da informação ▶ Atualizações não contínuas e planejadas dos dados 	<ul style="list-style-type: none"> ▶ Dados estruturados e desestruturados e + granulares ▶ Múltiplas fontes de dados ▶ Extensas, de fácil acesso e em crescimento contínuo: redes sociais, bancos de dados públicos ou <i>pools</i> de dados privados, <i>Internet of Things</i>, etc. ▶ Atualização contínua e em tempo real dos dados
2 Técnicas e algoritmos	<ul style="list-style-type: none"> ▶ Fundamento estatístico e matemático ▶ Limitação dos padrões e relações identificadas devido à assunção de hipóteses prévias ▶ Uso de métodos dedutivos 	<ul style="list-style-type: none"> ▶ Fundamento estatístico e matemático + ciência da computação (especialmente inteligência artificial) ▶ Identificação de padrões ocultos nos dados sem assumir hipóteses prévias ▶ Uso de métodos indutivos
3 Aprendizagem	<ul style="list-style-type: none"> ▶ Treinamento manual e planejado ▶ Hipóteses pré-definidas ou o conhecimento prévio das relações entre variáveis ▶ Redução do poder preditivo ao longo do tempo devido a uma ancoragem a uma janela temporal ▶ Rastreabilidade disponível 	<ul style="list-style-type: none"> ▶ Treinamento automático e autoaprendizagem ▶ Busca de padrões e relações sem restrições ▶ Manutenção do poder preditivo ao longo do tempo devido à adaptação da janela temporária ▶ Rastreabilidade: não garantida
4 Sistemas e software	<ul style="list-style-type: none"> ▶ Menor requerimento computacional ▶ Ferramentas tradicionais, às vezes usadas <i>stand-alone</i> ▶ Uso único de repositórios de informação estruturada ▶ Dados desestruturados vistos como arquivo sem valor 	<ul style="list-style-type: none"> ▶ Maior requerimento computacional e velocidade de processamento e capacidade de gestão de dados ▶ Combinação de ferramentas ▶ Armazenamento e uso de <i>Data Lakes</i> que combina dados estruturados e desestruturados

Machine Learning em função da informação e o paradigma de aprendizagem

Existem diversas técnicas de aprendizagem automática, dependendo da tipologia de informação utilizada (informação estruturada ou desestruturada) e do paradigma de aprendizagem utilizado (Figura 7). A seleção da técnica dependerá, entre outras coisas, do objetivo do modelo que se quer construir, bem como da tipologia de informação disponível.

Existem algumas técnicas específicas que podem ser utilizadas para a transformação de informações não estruturadas (textos, sons, imagens etc.) em dados que possam ser analisados e processados por um computador. Como exemplo, pode-se destacar o processamento da linguagem natural ou a identificação de imagens (Figura 8). Alguns exemplos são o uso de estatísticas para a avaliação da relevância das palavras em textos escritos, a classificação de palavras em categorias para a compreensão do texto escrito, o uso de redes neurais para o reconhecimento de voz ou de imagens, a aplicação de cadeias de Markov para a construção de textos em linguagem natural ou a aplicação de algoritmos não supervisionados de classificação para a organização de imagens.

Por outro lado, as técnicas de modelagem utilizadas com informações estruturadas podem ser classificadas em

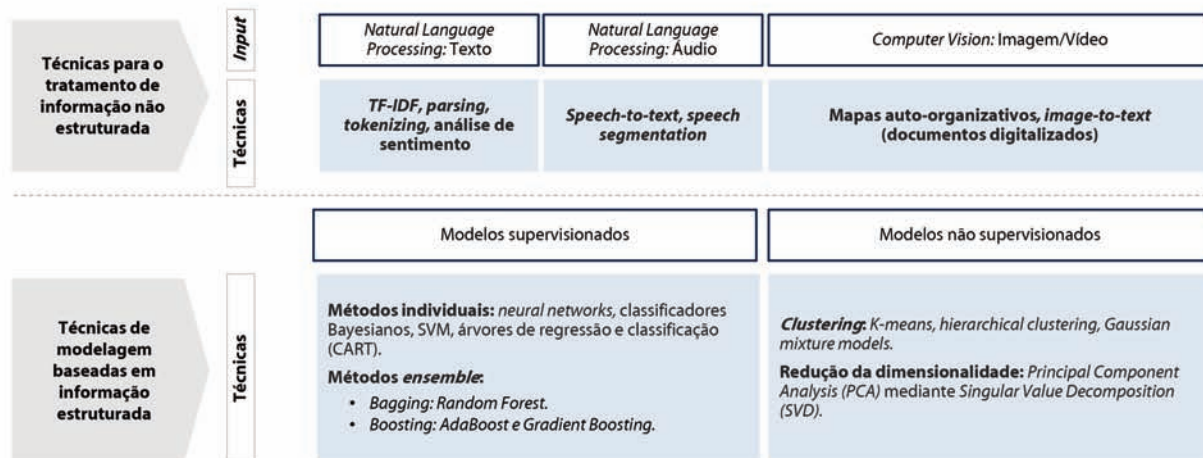
³⁶Este conjunto de dados costuma ser denominado "amostra de treinamento".

³⁷No entanto, no próprio processo de construção e validação do modelo são utilizados dados que, mesmo que sejam observados, não são incluídos na amostra de treinamento e simulam os que seriam os dados de aplicação. Estes dados costumam conformar as denominadas "amostra de teste" e "amostra de validação".

³⁸O uso massivo de dados implica também a implementação de ferramentas de *big data* e a aplicação de técnicas de eficiência computacional, ainda que estes elementos não tenham sido incluídos no conceito de *Machine Learning* nesta publicação.

³⁹Domingos, P. (2012). Professor na Universidade de Washington. Pesquisador de *Machine Learning* e conhecido por seu trabalho em Redes Lógicas de Markov.

Figura 7. Tipologias e técnicas de aprendizagem automática.



função das informações utilizadas para a aprendizagem^{40,41}:

Aprendizagem supervisionada: as informações para construir o algoritmo contêm informações sobre a característica estudada, que não está presente nos dados futuros. Portanto, as informações que se quer prever, ou a partir das quais se quer classificar uma população, estão disponíveis nos dados utilizados para construir o modelo. Mais formalmente, o objetivo da aprendizagem supervisionada é treinar a aplicação de um conjunto de variáveis (denominadas explicativas, características ou fatores) “x” em uma variável output “y”, a partir de um conjunto de dados (denominado amostra de treinamento) de pares $\Delta = \{(x_i, y_i), i \in 1, \dots, N\}$, onde “N” é o tamanho da amostra.

Quando a variável output “y” é contínua, fala-se em um problema de regressão, mas quando é nominal ou discreta, fala-se em um problema de classificação⁴².

Aprendizagem não supervisionada: como conceito oposto ao

caso anterior, não está disponível, na amostra de construção, a informação de uma variável que se quer prever. Portanto, neste caso não está disponível a variável output, de forma que o conjunto de dados é da forma $\Delta = \{x_i, i \in 1, \dots, N\}$, onde “N” é o tamanho da amostra⁴³. O objetivo deste tipo de problemas é encontrar padrões ou relações nos dados. Por isso, também é conhecido como *knowledge discovery* (processo de identificar padrões nos dados que sejam válidos, novos, potencialmente úteis e compreensíveis⁴⁴).

⁴⁰Shalev-Shwartz, S. e Ben-David, S. (2014).

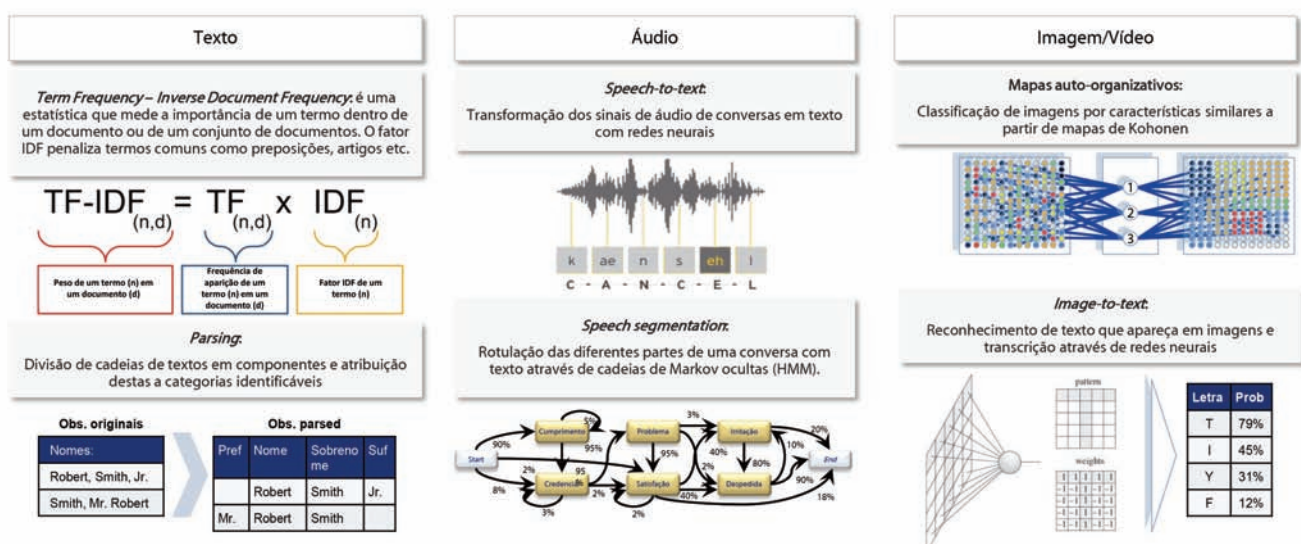
⁴¹Murphy, K. (2012).

⁴²Por exemplo, no caso dos modelos de classificação em função da qualidade de crédito, a variável-objetivo é dicotômica (*default/não default*), ou discreta (nível de *rating*), em cujo caso se fala em um problema de classificação.

⁴³Pretendem-se encontrar diferentes grupos nos dados sem ter uma amostra onde estes grupos tenham sido previamente observado.

⁴⁴Cios, K.J. e outros (2007). Doutor em Ciência da computação pela Universidade de Ciência e Tecnologia da Cracóvia, trabalhou na agência internacional de energia atômica. É professor e chefe do departamento de ciências da computação da Universidade da Virginia Commonwealth. Seus trabalhos de pesquisa são focados em machine learning, data mining e informática biomédica.

Figura 8. Métodos para Natural Language Processing e Computer Vision.



Técnicas de Machine Learning

No processo de modelação modelagem costuma-se realizar uma primeira fase de *knowledge discovery*. Dentro deste processo são realizadas, entre outras, as seguintes tarefas (Figura 9):

- ▶ **Entendimento dos dados:** preparação inicial e análise descritiva dos dados, análise da qualidade da informação etc.
- ▶ **Preparação dos dados:** limpeza ou tratamento dos dados (incluindo o tratamento de *missings*, *outliers*, registos equivocados ou inconsistentes), análise multivariada, combinação ou criação de novas variáveis a partir das existentes, redução do número de variáveis (através da eliminação de variáveis redundantes, projeção sobre subespaços de dimensão inferior), etc.
- ▶ **Seleção da técnica apropriada e aplicação de processos de regularização,** onde se transforma a dados e se prepara para a modelagem. Por exemplo, entre estes métodos podem ser considerados os seguintes:
 - Homogeneização da amplitude das variáveis, por exemplo subtraindo a média e dividindo pelo desvio padrão (normalizar), dividindo pela amplitude da variável (escalar), etc.
 - Identificação das variáveis mais relevantes para o modelo que se quer construir. No lugar dos métodos prévios de seleção de variáveis, como o *stepwise*⁴⁵, podem ser aplicadas técnicas como o uso de redes elásticas (*elastic nets*): a função que se utiliza para a estimativa dos parâmetros do modelo (denominada função-objetivo ou função de custo, cujo valor se pretende minimizar) se modifica acrescentando um termo adicional para detectar quais variáveis não trazem informações quando se compara o modelo em amostras de construção e de teste, o que permite, portanto, a seleção automática de

variáveis: se L é a função de custo que se utiliza para obter os estimadores do modelo, $\beta^t = (\beta_1, \dots, \beta_n)$ os estimadores, e $\lambda_1 \in \mathbb{R}$, $\lambda_2 \in \mathbb{R}^+$, então, a função pode ser transformada com a seguinte expressão⁴⁶:

$$L' = L + \lambda_2 \|\beta\|_2^2 + \lambda_1 \|\beta\|_1$$

No caso particular em que $\lambda_2=0$, obtém-se o método denominado LASSO, e quando $\lambda_1=0$ obtém-se o método denominado *ridge regression*⁴⁷.

Dentro das técnicas de *Machine Learning* de aprendizagem supervisionada, vale mencionar os chamados métodos individuais (Figura 9), assim denominados porque podem ser utilizados de forma isolada. Entre eles se destacam as redes neurais, as máquinas de vetor suporte, os classificadores bayesianos, ou as árvores de classificação e regressão:

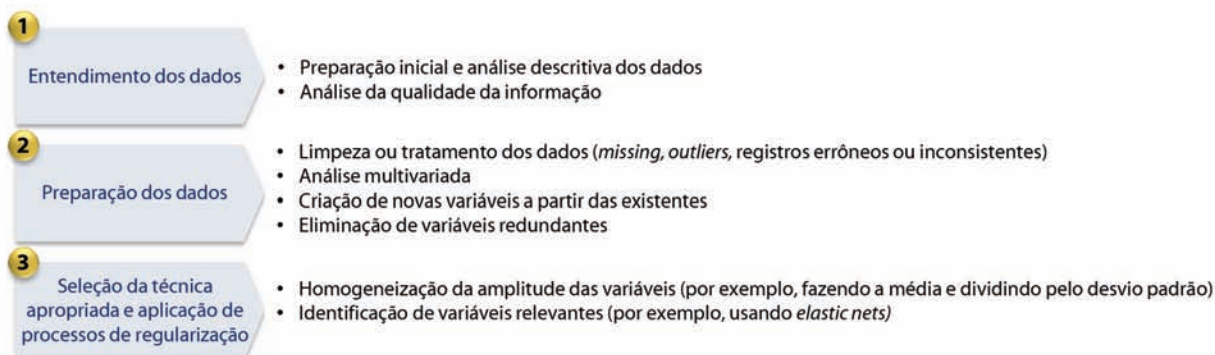
- ▶ **As redes neurais** são modelos matemáticos multivariados não lineares que utilizam procedimentos iterativos, com o objetivo de minimizar determinada função de erro e, dessa forma, classificar as observações. As redes neurais são compostas de neurónios conectados entre si através de nós e camadas. Tais conexões simulam os dendritos e axónios nos sistemas nervosos biológicos, através dos quais a informação é transmitida. São utilizados tanto em problemas supervisionados como não supervisionados, com a vantagem de que podem separar regiões de forma não linear. Sua maior desvantagem é seu carácter de "caixa preta", ou seja, a dificuldade na interpretação dos resultados e a limitação na hora de incorporar o sentido de negócio sobre a complexa estrutura de pesos.

⁴⁵É um método repetitivo de construção de modelos baseado na seleção automática de variáveis.

⁴⁶Em que \mathbb{R} representa o conjunto de números reais, \mathbb{R}^+ o conjunto de números reais positivos $\|\beta\|_2^2 = \sum_j \beta_j^2$ v. $\|\beta\|_1 = \sum_j |\beta_j|$

⁴⁷Para uma discussão detalhada de cada método, vantagens e inconvenientes, ver Murphy, K. (2012).

Figura 9. Tarefas no processo de modelagem.



Como uma extensão das redes neurais, destacam-se as redes profundas, que consistem no uso das redes neurais com múltiplas camadas. Estes modelos, englobados no que se denomina aprendizagem profunda ou *deep learning*⁴⁸, podem ter milhões de parâmetros, em função da complexidade do problema que se queira abordar. No entanto, devido à dificuldade de estimativa, existem múltiplas aproximações no uso desta tipologia de métodos⁴⁹ (por exemplo, o uso de algoritmos de otimização para ajustar os parâmetros nas redes profundas em função dos erros de seus *outputs*; o uso de algoritmos *greedy* para o treinamento de redes específicas, como as redes dirigidas; o uso de *auto-encoders* para a redução da dimensionalidade etc.). Graças ao desenvolvimento tecnológico, esses métodos puderam ser incorporados, por exemplo, em processos de reconhecimento e criação automática de textos ou em *computer vision*.

- ▶ **As máquinas de vetor suporte** (*support vector machine* ou SVM) são modelos de classificação que tentam resolver as dificuldades que podem significar amostras de dados complexas, em que as relações não têm por que ser lineares. Ou seja, pretende-se classificar as observações em vários grupos ou categorias, mas estas não são separáveis por meio de um hiperplano no espaço dimensional definido pelos dados. Para isso, o conjunto de dados é colocado em um espaço de dimensão superior através de uma função⁵⁰ que permita separar os dados no novo espaço através de um hiperplano nesse espaço. Então, busca-se um hiperplano equidistante aos pontos mais próximos de cada categoria (ou seja, o objetivo é encontrar o hiperplano que separa as categorias, e mais distante das suas observações de forma simultânea).

⁴⁸Os algoritmos utilizados em *deep learning* podem ser do tipo aprendizagem supervisionada ou não supervisionada.

⁴⁹Murphy, K. (2012).

⁵⁰Esta função é denominada kernel.

Diferenças entre inteligência artificial, Machine Learning e deep learning

Inteligência Artificial (IA), *Machine Learning* e *Deep Learning* são conceitos que estão relacionados, mas habitualmente há dificuldades para diferenciá-los. Com o objetivo de ilustrar suas diferenças, propõe-se as seguintes definições:

- A inteligência artificial é o conceito mais amplo, cujo objetivo é que as máquinas sejam capazes de realizar tarefas da mesma forma que um ser humano faria. Na maioria dos casos, isso se desenvolve a partir da execução de regras previamente programadas. Na Conferência de Inteligência Artificial de Dartmouth (1956) foi definida como “todos os aspectos da aprendizagem ou qualquer outra característica da inteligência que pode, em princípio, ser precisamente descrita de forma tal que uma máquina possa realizá-la”. Desde princípios do século XX já tivemos alguns exemplos disso em pioneiros como Alan Turing, que decifrou a máquina Enigma, na primeira aparição do que hoje chamaríamos de redes neurais.
- Por outro lado, a aprendizagem automática (ML) pode ser considerada como uma vertente da IA e é definida⁵¹ como “o conjunto de métodos capazes de detectar padrões automaticamente em um conjunto de dados e usá-los para fazer previsões sobre dados futuros, ou para tomar outro tipo de decisões em um ambiente de incerteza”.
- Por último, a *Deep Learning* ou aprendizagem profunda é um ramo do Machine Learning que, definido em seu aspecto mais básico pode ser explicada como um sistema de probabilidades que permite que modelos computacionais, que estão compostos por múltiplas camadas de processamento, aprendam sobre dados com múltiplos níveis de abstração⁵².



⁵¹Murphy, K. (2012).

⁵²Bengio, Y. e outros (2015). Bengio, cientista da computação no Canadá. Conhecido principalmente por seu trabalho nas redes neuronais e em *Deep Learning*.

- ▶ Os **classificadores bayesianos** são modelos baseados no teorema de probabilidade condicionada de Bayes, que utilizam as informações conhecidas das variáveis explicativas, ou seja, os denominados priors, para classificar as observações. Dito de outra forma, um classificador bayesiano assume que a presença ou a ausência de certas categorias permite atribuir certa probabilidade à ausência ou à presença de outra característica, ou definir uma variável-objetivo em função da relação existente em uma amostra entre estas características e a variável-objetivo definida. É uma técnica simples, mas consistente, para classificar observações em um conjunto de categorias. O classificador bayesiano toma formas específicas de acordo com a distribuição assumida, que seguem as variáveis explicativas (normal, multinomial etc.).
- ▶ Por fim, as **árvores de classificação** (quando a variável-objetivo é categórica) e **de regressão** (quando a variável-objetivo é contínua) são técnicas de análise que permitem prever a atribuição de amostras a grupos pré-definidos em função de uma série de variáveis previsíveis. As árvores de decisão são modelos simples e facilmente interpretáveis, o que faz com que sejam muito valorizadas pelos analistas. No entanto, seu poder preditivo pode ser mais limitado do que o de outros modelos, porque realizam uma divisão ortogonal⁵³ do espaço, o que converte a amostra em silos e limita a capacidade preditiva dado que este tipo de algoritmo tende ao supertreinamento.

Todos estes métodos individuais podem ser combinados com técnicas e algoritmos que permitem melhorar a capacidade preditiva, através de métodos ensemble (Figura 10). Estes métodos consistem na combinação de modelos individuais para gerar um modelo mais preditivo ou mais estável, que aproveita o conhecimento do coletivo. Por exemplo, os modelos podem ser combinados através do uso dos resultados de modelos independentes (como no caso da técnica de *bagging*) ou buscando corrigir em cada iteração o erro cometido (como no caso do *boosting*).

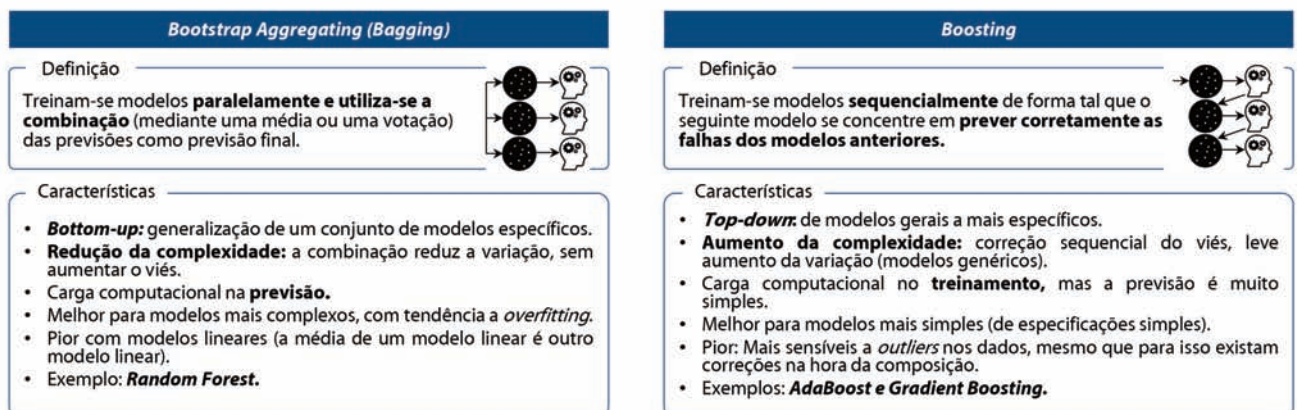
Finalmente, entre os modelos não supervisionados, vale destacar as técnicas de *clustering* ou as técnicas de *Data Analysis*, como a de redução da dimensionalidade:

- O *clustering* é um modelo não supervisionado utilizado para identificar grupos (*clusters*) ou padrões de observação similares em um conjunto de dados. Uma das técnicas mais utilizadas é o método de *k-means*, que consiste em definir um ponto central de referência de cada *cluster* (denominado centroide) e atribuir a cada indivíduo o *cluster* do centroide mais próximo em função das distâncias existentes entre os atributos de entrada. O algoritmo parte da fixação de *k* centroides aleatoriamente e, mediante um processo iterativo, atribui cada ponto ao cluster com o centroide mais próximo, atualizando o valor dos centroides. Este processo termina quando se alcança um determinado critério de convergência.
- Os métodos de redução da dimensionalidade pretendem reduzir o número de dimensões do espaço de análise, determinado pelo conjunto de variáveis explicativas. Uma das técnicas é a análise de componentes principais (principal component analysis ou PCA), que converte um conjunto de variáveis correlacionadas em outro (com menor quantidade de variáveis) sem correlação, chamadas componentes principais. A principal desvantagem de aplicar PCA sobre o conjunto de dados é que estes perdem a sua interpretabilidade.

De qualquer forma, a aplicação destas técnicas significa que os métodos de validação de resultados devem ser mais sofisticados. Como em muitos casos a aprendizagem é contínua e utiliza mais de uma subamostra na construção,

⁵³Ou seja, uma partição de um espaço *n*-dimensional em regiões através de hiperplanos perpendiculares a cada um dos eixos que definem as variáveis explicativas.

Figura 10. Exemplos de métodos ensemble.





deve-se implementar técnicas que sejam adequadas para estes novos processos, como o *bootstrapping*⁵⁴ ou o *k-fold-cross-validation*⁵⁵, que permitem avaliar o modelo em mais de uma amostra de validação. Também é importante prestar atenção a outros aspectos da validação, como a existência de possíveis vieses na frequência de atualização dos dados, relações espúrias ou sem uma relação causal. Por último, a natureza dinâmica destas técnicas dificulta a rastreabilidade. Isto ganha especial relevância em ambientes regulados ou com supervisão, que exigem um *framework* de validação e de rastreabilidade específico.

Usos e tendências na aprendizagem automática


O uso da aprendizagem automática nas indústrias

A incorporação da aprendizagem automática no desenvolvimento dos negócios nas diferentes indústrias é desigual (Figura 11), tanto em função do setor quanto de diversos fatores relacionados ao tamanho, estilo de diretoria e, em geral, em função do ambiente em que a empresa opera.

As técnicas de aprendizagem automática estão sendo implementadas com diferentes graus de velocidade e profundidade em diferentes setores. Por exemplo, destacam-se

⁵⁴Geração de muitas amostras de validação a partir da seleção aleatória com substituição.
⁵⁵Divide-se a amostra k em grupos. Na primeira repetição, k-1 são utilizados para a construção e o restante para a validação. Este processo é repetido, escolhendo como grupo de validação cada um dos k grupos construídos.

Figura 11. Presença do desenvolvimento de Machine Learning nos diferentes setores em 2016.





algumas aplicações nas indústrias da educação, finanças, saúde ou, transversalmente, na melhoria da eficiência das organizações^{56,57}:

- ▶ No âmbito educativo⁵⁸ a inteligência artificial poderá fornecer sistemas que funcionem como "companheiros de aprendizagem" durante toda a vida do aluno e acessíveis através de múltiplos canais.
- ▶ Em finanças, os algoritmos de *Machine Learning* estão dirigidos a funções como o trading automático, a criação de *roboadvisors* para a gestão automática de carteiras, a detecção da fraude ou a medição do risco. Um dos âmbitos de maior crescimento é o conhecido como *RegTech*⁵⁹, em que se usam técnicas de *Machine Learning* para cumprir com a regulamentação e a supervisão. A previsão é de que o mercado de *RegTech* chegue a 6,5 bilhões de dólares em 2020⁶⁰. Além disso, estas técnicas podem ser utilizadas para a análise de carteiras onde não existe tanta informação estruturada armazenada nas

bases de dados das instituições financeiras, como por exemplo os modelos de *prospect* de não-clientes. Neste caso, os modelos de *prospect* pretendem classificar potenciais clientes em função de sua probabilidade de inadimplência, o que é aplicável em processos comerciais como o lançamento de campanhas ou a emissão de novos produtos. Estes modelos também costumam ser interessantes nos segmentos de clientes nos quais não existem muitas informações, como no caso de autônomos e microempresas, ou em segmentos de particulares ou autônomos que não utilizam o sistema bancário. Para isso, é possível utilizar informações sobre contas anuais (incluindo informações

⁵⁶Kaggle (2017).


⁵⁷Forbes (2017).

⁵⁸Pearson (2016).

⁵⁹*Regtech* surge da combinação dos termos "*regulatory technology*" e consiste em um grupo de companhias que utilizam a tecnologia para ajudar as empresas a cumprir com as normas de maneira eficiente e com baixos custos.

⁶⁰Frost & Sullivan (2017).





sobre atividades, como rotação de inventários ou de fornecedores, índices de alavancagem, de liquidez, solvência ou rentabilidade), que são complementadas com informações de produtos e serviços, ou mesmo com informações externas não estruturadas.

- ▶ No caso do setor da saúde, os esforços estão focados em melhorar o diagnóstico por imagem, a gestão de consultas de tratamento e sugestões, bem como a compilação de informações médicas para estudos ou para cirurgia robótica. Estima-se que o mercado da inteligência artificial no campo da saúde pode chegar aos 6,6 bilhões de dólares em 2021 e economizar potencialmente 150 bilhões de dólares em 2026 no setor da saúde nos EUA⁶¹.
- ▶ Em setores como a indústria ou a logística, são propostas soluções para a melhoria da manutenção das máquinas (através do uso de modelos e sensorização para a manutenção preditiva) ou maior eficiência na

distribuição (por exemplo, mediante a otimização da correlação entre necessidades de transporte com múltiplas empresas)⁶².

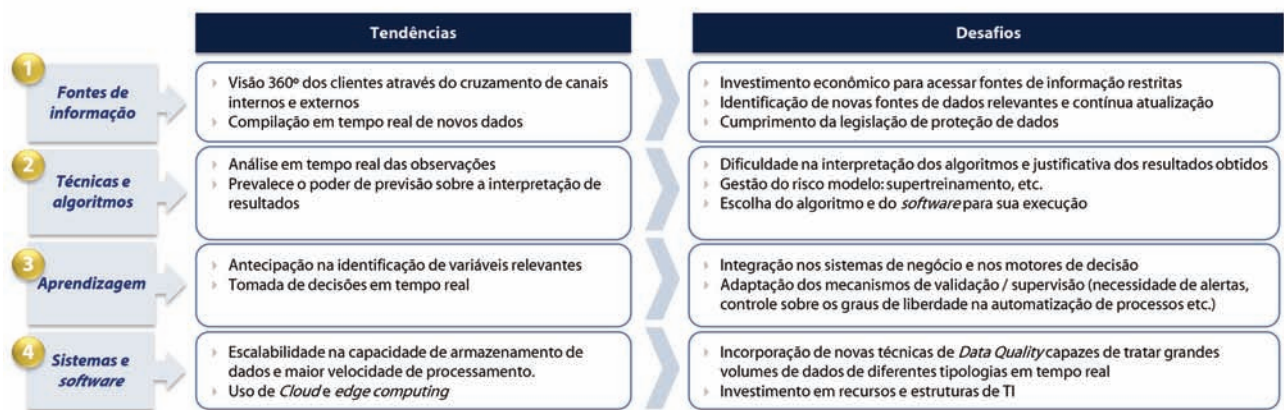
- ▶ Em relação à melhoria da eficiência das organizações, a função de tecnologia e operações pode ser mais proativa em empresas nas quais os sistemas tecnológicos geram dados massivos (*logs*, relatórios de status, arquivos de erros etc.). A partir destas informações, os algoritmos de *Machine Learning* podem detectar a causa de alguns problemas ou as falhas dos sistemas podem ser atenuadas significativamente utilizando análises preditivas. Além disso, podem ser incorporadas experiências tecnológicas personalizadas: a disponibilidade de um assistente virtual por funcionário ajudará as empresas a maximizar a produtividade no local de trabalho. Este assistente será capaz de conectar

⁶¹Techemergence (2017).

⁶²Círculo de Empresários (2018).



Figura 12. Tendências e desafios sobre os componentes da aprendizagem automática.



informações de uso de aplicativos do usuário com outras bases de dados armazenadas e detectará padrões que antecipem as seguintes ações e acessos a bases de dados de documentos por parte do funcionário.

Como exemplo ilustrativo de como está sendo realizada a incorporação destas técnicas em uma indústria clássica pode-se destacar o caso de Rolls-Royce, que chegou a um acordo com a Google para utilizar os motores de *Machine Learning* do Google em *Cloud*, com o objetivo de melhorar a eficiência e a segurança na navegação no curto prazo e com o objetivo de alcançar o controle remoto sem tripulação. Este caso reúne todos os elementos típicos da aprendizagem automática: coleta de informação não estruturada baseada em sensores, tratamento da informação mediante novas técnicas, objetivo de automatização completa etc.

Tendências sobre os componentes da aprendizagem automática

O uso de diferentes técnicas e a proliferação de diversos enfoques e ferramentas modificam o processo de modelagem em todos os seus vetores: os dados utilizados, novas técnicas, metodologias de estimativa e as arquiteturas e os sistemas de suporte (Figura 12). No entanto, este novo enfoque significa um conjunto de desafios do ponto de vista técnico, metodológico e de negócio⁶³:

1. Em função das fontes de informação: Procura-se obter uma visão de 360° dos clientes através do cruzamento de canais internos e externos, utilizando dados compilados em tempo real. Isso leva a uma série de objetivos a serem enfrentados, como o investimento econômico para acessar fontes de informação restritas, a identificação de novas fontes de dados relevantes e sua contínua atualização, bem como a incorporação de técnicas de *Data Quality* capazes de tratar grandes volumes de dados de diferentes tipologias em tempo real. Da mesma forma,

um dos grandes desafios é a aplicação dos regulamentos em matéria de proteção de dados, como a GDPR na Europa, que implica uma análise profunda das fontes de informação que podem ser utilizadas nos modelos de aprendizagem automática, seu tratamento e seu armazenamento, bem como o estabelecimento de controles e sistemas de cibersegurança.

2. Em função das técnicas e os algoritmos: Por mais que aumente a dificuldade na interpretação dos algoritmos e na justificativa dos resultados obtidos, em certos âmbitos ainda prevalece o poder da previsão sobre sua interpretação. Tudo isso faz com que seja mais relevante implementar uma correta gestão do risco de modelo durante o ciclo de vida completo (desenvolvimento, avaliação, implementação, uso, manutenção e descontinuação). A natureza e as possíveis fontes de risco do modelo, como carências nos dados, a incerteza na estimativa ou os erros nos modelos e o uso inadequado do modelo⁶⁴ estão igualmente presentes no uso de técnicas de aprendizagem automática. Entre os desafios na resolução de problemas mediante o uso de técnicas de *Machine Learning* também se encontram a própria escolha do algoritmo mais adequado entre uma ampla gama de possibilidades (já que este pode depender tanto do objetivo do modelo que se quer construir quanto das informações disponíveis), a aparição de possíveis problemas de *overfitting*⁶⁵ e de *data dredging*⁶⁶, ou a

⁶³Jordan, M. I., Mitchell, T. M. (2015) e Kaggle (2017). Jordan, doutor em Ciência cognitiva pela Universidade da Califórnia, além de professor do MIT e atualmente professor no departamento de Engenharia Elétrica e Ciências da computação e do departamento de Estatística na universidade da Califórnia.

⁶⁴Management Solutions (2014).

⁶⁵*Overfitting*: o modelo está demasiadamente ajustado à amostra de treinamento, de forma que não obtém resultados satisfatórios sobre amostras diferentes desta (por exemplo, a amostra de validação).

⁶⁶O *data dredging* é produzido quando se encontram relações que não estão respaldadas por hipóteses ou causas que realmente expliquem tais relações.

necessidade de estabelecer mecanismos para que a aplicação dos resultados automáticos não implique na aparição de tratamentos discriminatórios (este risco é tratado através do que se conhece como ética algorítmica).

3. Em função da autoaprendizagem: Incorporar a característica de autoaprendizagem nos modelos implica na capacidade de que o algoritmo se modifique de forma autônoma em função das mudanças que vão ocorrendo na população-objetivo. Isso pode originar modificações nos parâmetros ou nas variáveis relevantes para construir o algoritmo, bem como a necessidade de tomar decisões de modelagem em tempo real. No entanto, estes ajustes aos modelos em tempo real dificultam a sua validação, que deve evoluir a partir do enfoque tradicional e incorporar novos elementos, como o controle de graus de liberdade na automatização, uma maior frequência na avaliação do poder discriminante ou outras técnicas de comparação (por exemplo, através de modelos alternativos mais simples que, mesmo que percam capacidade de ajuste, permitam fazer challenge aos resultados). No caso específico de modelos que necessitam a aprovação de um supervisor como, por exemplo, os modelos regulatórios no setor financeiro, um desafio acrescentado a esta validação é a dificuldade de obter a aprovação por parte do supervisor.

4. Em função dos sistemas e do software utilizado: Investe-se em arquiteturas e infraestruturas tecnológicas que garantam a escalabilidade na capacidade de armazenamento de dados e uma maior velocidade de processamento. Também estão sendo desenvolvidas soluções baseadas em *Cloud*, como plataformas alternativas às implementações *in-house* utilizadas tradicionalmente pelas empresas e incorporadas infraestruturas de *edge computing*, onde são oferecidas funções já previamente instaladas (FaaS⁶⁷) preparadas para uso direto, o que simplifica a experiência do desenvolvedor, já que reduz o esforço de programação e gestão do código. Tudo isso implica na necessidade de realizar investimentos em recursos e estruturas de TI.

Além disso, tudo isso pressupõe a necessidade de contar com recursos humanos com um alto grau de preparação e especialização, capazes de compreender e trabalhar com linguagens de programação, algoritmos, matemática, estatística e arquiteturas tecnológicas complexas.

⁶⁷ *Functions as a Service*, um modelo sem servidores.

Fontes de informação e restrições regulatórias

A rápida evolução tecnológica e a globalização criaram novos desafios no âmbito da proteção dos dados pessoais. Neste sentido, aumentou significativamente a magnitude da coleta e do intercâmbio de dados pessoais e, atualmente, a tecnologia permite o tratamento dos dados pessoais em uma escala sem precedentes.

Estes avanços e o uso de fontes de informação que incorporam dados de caráter pessoal requerem um *framework* sólido e coerente para a proteção de dados, devido à importância de gerar uma confiança que permita o desenvolvimento da economia digital. Assim, surge a necessidade de que as pessoas físicas tenham o controle de seus próprios dados pessoais e de reforçar a segurança jurídica e prática para as pessoas físicas, os operadores econômicos e as autoridades públicas⁶⁸. Como consequência, os reguladores desenvolveram normas para garantir a proteção desses dados. Como exemplo paradigmático, pode-se analisar o caso da União Europeia, onde a *General Data Protection Regulation* (GDPR), que entrou em vigor em maio de 2018, estabeleceu uma série de requisitos gerais de tratamento e proteção das informações, homogeneizando o seu tratamento em todos os países membros (Figura 13).

⁶⁸Parlamento Europeu (2016).

Figura 13. Principais requisitos da GDPR.



Exercício quantitativo

Your job in a world of intelligent machines is to keep making sure they do what you want, both at the input (setting the goals) and at the output (checking that you got what you asked for)

Pedro Domingos⁶⁹



As técnicas de *Machine Learning* introduzem diversas novidades nas técnicas estatísticas e econométricas clássicas, alavancadas no uso de maior quantidade de informação e maior complexidade dos algoritmos.

Introduz um conjunto de novos elementos no âmbito da modelagem que, se por um lado permite realizar análises mais sólidas, por outro requer a resolução de questões como o aumento das variáveis disponíveis (o que aumenta a complexidade no tratamento dos dados, bem como na seleção de informações relevantes), a correta identificação de relações espúrias ou o não cumprimento das hipóteses dos modelos tradicionais (por exemplo: falta de cointegrabilidade em séries temporais ou presença de multicolinearidade e autocorrelação).

Como resultado disso, pode-se modificar o enfoque de modelagem, introduzindo diferentes ferramentas para aproveitar os algoritmos de *Machine Learning*, mas evitando cometer erros ligados a estas novas ferramentas.

Nesta seção, foi desenvolvido um modelo de scoring comportamental para classificar empréstimos bancários. Para isso foram utilizadas algumas destas novas técnicas com a finalidade de poder comparar os resultados, bem como avaliar os objetivos que implicam o seu uso no processo de modelagem, as oportunidades que surgem e os riscos existentes.

Objetivo

O objetivo do exercício é analisar e ilustrar o impacto do uso de técnicas de *Machine Learning* no desenvolvimento de modelos. Especificamente, pretende-se avaliar a variação do processo de estimativa e os resultados obtidos, partindo de diferentes abordagens de modelagem, mediante o uso de técnicas de *Machine Learning*.

Para isso, um modelo de *scoring* foi treinado, utilizando diferentes abordagens de *Machine Learning*, e os resultados foram comparados com as técnicas tradicionais. Partiu-se de uma amostra de empréstimos e foram desenvolvidas duas fases de modelagem (tratamentos de dados em tarefas de preparação, limpeza e seleção de variáveis e aplicação de

diversos enfoques para avaliar o modelo). A seguir, a amostra utilizada será descrita e as diferentes fases do estudo detalhadas, bem como os resultados e as principais conclusões obtidas.

Datos utilizados

O estudo foi realizado utilizando um conjunto de mais de 500 mil empréstimos, que compreendem mais de 10 anos de história, com uma taxa de inadimplência de 6%. A amostra inclui variáveis relativas à operação (montante, prazo da operação, taxa de juros, finalidade do financiamento, etc.) ao cliente (informações econômicas como receita anual, mensal, patrimônio, variáveis de endividamento, pontuação de *scorings* externos etc., informações sobre inadimplências, como quebras de registros públicos, contas com atrasos etc., ou variáveis de antiguidade como cliente e antiguidade em outros produtos), bem como relativas a outros tipos de informações que possam ser úteis na modelagem, como comissões, número de transações realizadas, etc. Neste exercício, todas estas variáveis foram mantidas na amostra inicial, com o propósito de realizar *knowledge discovery*.

31

Desenvolvimento do estudo

O estudo foi desenvolvido em duas fases, detalhadas a seguir:

1. Fase 1: Knowledge Discovery. Inicialmente foi desenvolvida uma fase de *knowledge discovery*, em que foram realizados diferentes tratamentos de *missings*, *outliers* e agrupamento de variáveis.

2. Fase 2: Aplicação de técnicas de Machine Learning. Na segunda fase, foi iniciado o desenvolvimento de diferentes modelos, utilizando técnicas de modelagem sobre as amostras de construção geradas.

⁶⁹Domingos, P (2015). Professor na Universidade de Washington. Pesquisador de Machine Learning e conhecido por seu trabalho em Redes Lógicas de Markov.

Fase 1: Knowledge Discovery

A primeira fase do desenvolvimento do exercício consiste em aplicar algumas técnicas de *knowledge discovery*. Alguns dos tratamentos aplicados, descritos a seguir, podem ser mais adequados do que outros, dependendo do tipo de algoritmo final utilizado para a modelagem. Desta forma, a primeira fase permite obter um conjunto de amostras de construção que podem ser utilizadas como dados para treinar diferentes algoritmos.

Nesta primeira fase, observou-se que 40% das variáveis apresentam mais de 10% de observações missing. Para utilizar as informações disponíveis, foram realizados diferentes tratamentos sobre estas variáveis⁷⁰:

- Foi estabelecido o valor médio (ou a moda, no caso de variáveis qualitativas) às observações *missing*.
- Um *clustering analysis* foi realizado, e atribui-se a média a cada valor *missing* (ou a moda, no caso de variáveis qualitativas) do *cluster*. A determinação do número ideal de *clusters* que gera a melhor classificação foi realizada através de métodos quantitativos⁷¹.
- Foi realizada uma regressão sobre outras variáveis para estimar um valor para as observações *missing* de uma variável em função do restante das informações.
- Para o caso específico do *Random Forest*, foi estabelecido um valor máximo (ex. 9999) com o objetivo de identificar o *missing* como um valor adicional para que a árvore crie, de forma automática, um galho específico para esta informação.

Por outro lado, foi realizado um tratamento de *outliers*, que simplesmente consistiu em aplicar um *floor* no percentual 1, e um *cap* no percentual 99 nas variáveis com presença de valores atípicos.

Por fim, foi realizado um processo de simplificação de variáveis. Para isso, um algoritmo de *clustering* foi novamente aplicado, para substituir as variáveis que permitem identificar uma boa

classificação em grupos pelo *cluster* atribuído (Figura 14). Também foram eliminadas as variáveis que, após uma primeira análise exploratória, não contêm informações relevantes (devido à má qualidade das informações, variáveis informadas a um valor constante, etc).

Após todos estes tratamentos, foram obtidas diferentes amostras de construção, que serão utilizadas para a estimativa dos algoritmos⁷².

Conjuntamente, estas técnicas permitem reduzir o número de variáveis com o objetivo de melhorar a eficiência dos processos posteriores, preparar as informações existentes para que se adequem aos requisitos específicos dos diferentes modelos e possíveis limitações dos algoritmos, bem como antecipar e validar hipóteses para avaliar os resultados das diferentes técnicas de modelagem utilizadas.

Fase 2: Aplicação de técnicas de Machine Learning

Na segunda fase, partindo das diferentes amostras já tratadas, foram aplicadas diferentes técnicas e iniciou-se o cálculo das diferentes métricas da capacidade discriminante do modelo sobre uma amostra de validação. As técnicas que foram desenvolvidas são as seguintes:


- Em primeiro lugar, para poder realizar uma comparação com um método tradicional de modelagem, foi construído um modelo logístico.
- Foi aplicada uma rede elástica como técnica de regularização, para observar o impacto desta técnica sobre a modelagem tradicional.

⁷⁰Tratamentos adicionais ao clássico, que consiste em trocar um *missing* por um zero e criar uma variável *dummy* para reconhecer onde foram atribuídos os *missing*.

⁷¹Existem diversos métodos quantitativos para realizar esta seleção, como o *elbow method* ou o algoritmo *partition around medoids* (PAM). Em termos gerais, pretende-se analisar o número de *clusters* a partir do qual o lucro marginal de informações na classificação se faz residual ao ampliar o número de *clusters*. Neste caso, foi aplicado o algoritmo PAM.

⁷²Ainda que possam ter diferentes amostras de construção para um único algoritmo e, portanto, diferentes resultados, neste estudo mostram-se somente os resultados ideais.

Figura 14. Exemplos de clustering para K=2, K=4 e K=8 em função de duas variáveis. As variáveis X e Y serão substituídas pela variável definida pelo cluster.



- c. Foi desenvolvido um *random forest* como um dos métodos ensemble.
- d. Também foi estimado um *adaboost*, para dispor de um segundo método *ensemble*.
- e. Foi estimado um modelo através de uma SVM utilizando uma função linear.
- f. Por último, foi estimado um segundo modelo de SVM com uma função radial.

Após aplicar estas técnicas, foram obtidos os seguintes modelos:

a. Modelo logístico (modelo tradicional base para a comparação). Foi realizada uma pré-seleção de variáveis mediante técnicas bivariadas e multivariadas, levando em consideração o significado individual de cada variável, o poder discriminante do modelo global e diferentes métodos e critérios de informação. Como resultado, obteve-se um modelo que conta com 11 variáveis, em que as que apresentam maior importância são do tipo comportamental (por exemplo, número de contas que nunca entraram em *default*, se existem dívidas pendentes ou o número de contas que esteve mais de 120 dias em situação irregular). A importância de cada variável foi mensurada como a contribuição marginal dessa variável à bondade de ajuste do modelo. Portanto, pode-se analisar qual é o padrão de incorporação de cada variável em função de sua importância (Figura 15).

b. Modelo com técnicas de regularização. Após aplicar a rede elástica, foi desenvolvido um modelo com um total de 45 variáveis, entre as quais se destacam as variáveis comportamentais (por exemplo, contas em situação irregular, dívidas pendentes nos últimos 12 meses, informações positivas em registros públicos etc.). Foram incluídas variáveis relativas à operação e ao cliente, sendo que a importância das primeiras é muito mais significativa (Figura 16).

c. Random Forest. Foi obtido um algoritmo com 50 árvores, sendo que a máxima profundidade do galhos é três e o número de variáveis incluídas aleatoriamente como candidatas em cada nó é igual a sete. No total, estão sendo utilizadas 80 variáveis para conformar o conjunto de árvores. As variáveis de maior relevância no algoritmo são as de tipo comportamental (por exemplo, existência de dívidas pendentes, outras contas com inadimplência, números de contas ativas etc.) e algumas outras variáveis que caracterizam o cliente ou a operação (por exemplo, o nível de endividamento). Observa-se que em termos de importância, as primeiras variáveis obtêm um peso elevado, enquanto que o resto das variáveis mantêm uma importância relativa reduzida (Figura 17).

Figura 15. Importância das variáveis no algoritmo tradicional.

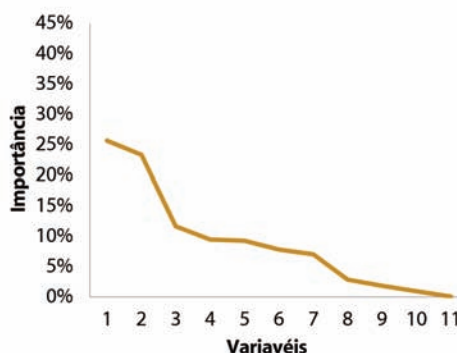


Figura 16. : Importância das variáveis após aplicar redes elásticas.

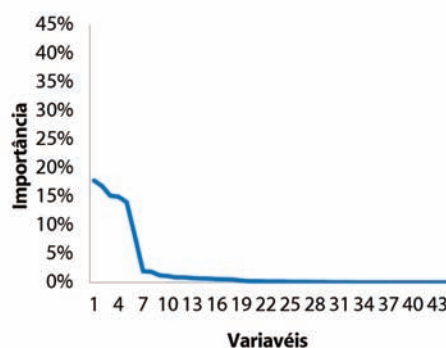
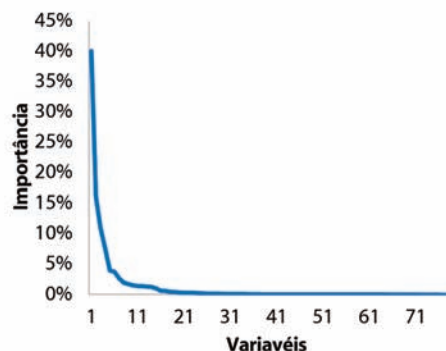


Figura 17. Importância das variáveis no algoritmo de Random Forest.



d. Adaboost: foi selecionado um algoritmo com 20 iterações, cujo parâmetro de redução foi fixado automaticamente em um. Como resultado, foram obtidas 68 variáveis significativas entre as quais se destacam novamente as de tipo comportamental (por exemplo, a média do saldo *revolving* no conjunto de contas, o número de contas de cartões de crédito sem inadimplências, o principal devolvido pelo cliente etc.), bem como outras variáveis relativas ao cliente. Neste caso, observa-se uma queda reduzida, porém paulatina, na importância das variáveis (Figura 18).

e. SVM com função linear. Foram obtidos diferentes modelos em função das variáveis utilizadas e foi selecionado o melhor modelo, utilizando técnicas de validação cruzada. No modelo escolhido foram obtidas 68 variáveis relevantes, das quais as que apresentam maior importância são as comportamentais (por exemplo, as dívidas pendentes nos últimos 12 meses ou a porcentagem de contas que nunca estiveram em situação irregular, Figura 19).

f. SVM com função radial. Bem como no caso linear, foi feita uma seleção entre diferentes modelos. Este modelo também possui 68 variáveis, onde as que apresentam maior importância também são as comportamentais. Ainda que ambos os modelos de SVM sejam muito similares, a importância das variáveis em cada um deles difere significativamente (Figura 20).

Figura 18. Importância das variáveis no algoritmo Adaboost.

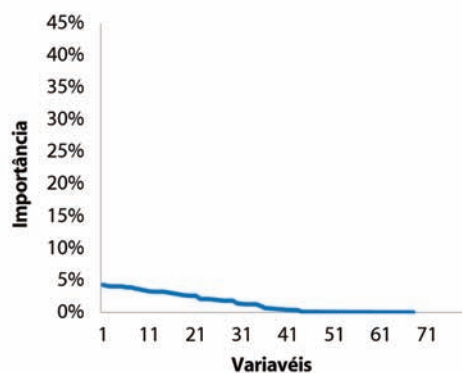


Figura 19. Importância das variáveis no algoritmo SVM com função linear.

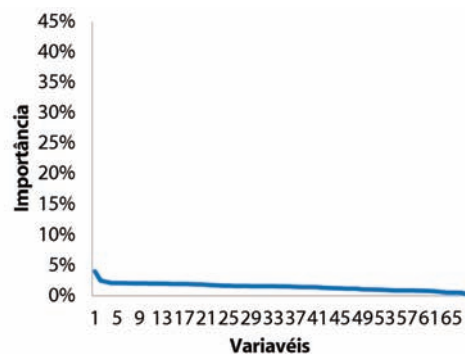



Figura 20. Importância das variáveis no algoritmo SVM com função radial



Detalhes das técnicas utilizadas no estudo⁷³


Rede Elástica. Como já foi descrito na seção anterior, a aplicação da rede elástica é realizada mediante a incorporação do termo $\lambda_2 \|\beta\|_2^2 + \lambda_1 \|\beta\|_1$ à função-objetivo que se pretende otimizar quando os parâmetros são estimados $\beta^t = (\beta_1, \dots, \beta_n)$.

Para isso, foi realizada a transformação $\alpha = \frac{\lambda_2}{\lambda_1 + \lambda_2}$ e, portanto, o termo foi estimado

$$(1 - \alpha) \cdot \|\beta\|_2^2 + \alpha \cdot \|\beta\|_1$$

Então, passa-se a construir o desvio da função de verossimilhança parcial (*partial likelihood deviance*, o PLD⁷⁴) como função desse parâmetro α , e busca-se o mínimo dessa função. Neste caso, o valor mínimo é encontrado em $\alpha=0,8$ (Figura 21). Com esse valor de α estreia-se a função-objetivo, de onde são obtidas variáveis cujo estimador associado é próximo a zero e, portanto, não são considerados na construção do modelo.

Figura 21. Função de otimização para o método de redes elásticas. Mostra-se o valor de α que minimiza o desvio da função de verossimilhança parcial (PLD).



Random Forest. Esta técnica se baseia nas técnicas de combinação de modelos independentes (*bagging*), de forma que um número elevado de árvores é gerado e calcula-se a média dos seus resultados. Para realizar cada árvore é atribuída aleatoriamente uma seleção aleatória da amostra com substituição e divisão das variáveis, com o objetivo de reduzir o sobre-treinamento e controlar a multicolinearidade (Figura 22). Para prever uma nova observação, recorre-se à árvore em função do valor de seus previsores até chegar a um dos nós terminais. No

caso de árvores de classificação, costuma-se empregar a moda da variável-resposta como valor de previsão, ou seja, a categoria mais frequente do nó. Além disso, a proporção de árvores que tomam uma mesma resposta é interpretada como a sua probabilidade, o que dá informações sobre a confiança da previsão.

Adaboost. Na aplicação desta técnica são estimados diferentes estimadores fracos sobre a amostra que, posteriormente, são adicionados mediante técnicas de *boosting*, utilizando diferentes ponderações, o que em um contexto repetitivo permite que o algoritmo aprenda dos erros cometidos nas repetições anteriores. O processo é o seguinte:

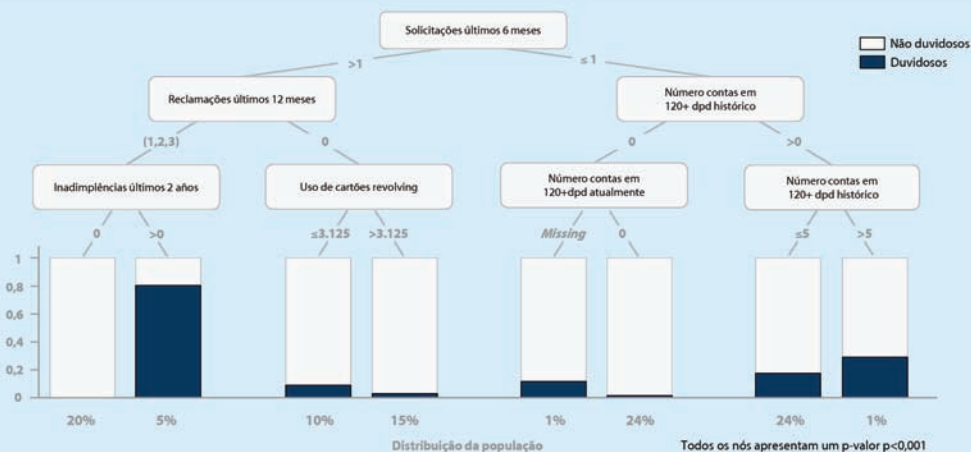
- Com a amostra de treinamento se constrói um submodelo atribuindo pesos equivalentes a todas as observações.
- Àquelas observações incorretamente classificadas, aumenta-se o peso relativo, e àquelas observações corretamente classificadas se diminui, e se constrói um novo submodelo, levando em consideração os novos pesos. Isto é realizado até chegar a um nível baixo de erro.
- São combinados sequencialmente todos os submodelos, obtendo um modelo final complexo baseado nos submodelos intermediários simples.

Aplicação de máquinas de vetor suporte (SVM). A aplicação das SVM foi realizada utilizando dois modelos, um linear e outro radial. A diferença está em como é definida a função *kernel*, que permite separar os grupos. A SVM linear utiliza como função $K(x_i, x_j) = x_i^t x_j$ (o produto escalar). A SVM radial utiliza como função $K(x_i, x_j) = \exp(-\gamma \cdot \|x_i - x_j\|_2^2)$, onde $\gamma > 0$. Nos modelos desenvolvidos, foram utilizados valores de $\gamma=0,014$ para o modelo linear, e $\gamma=1$ para o modelo radial.

⁷³A descrição de cada uma destas técnicas pode ser encontrada no capítulo anterior, de forma que incorporamos alguns detalhes técnicos associados ao seu uso específico.

⁷⁴O desvio da função de verossimilhança parcial (PLD) é um indicador que permite comparar o poder preditivo de um modelo sob análise com o de um modelo de referência (que pode ser um modelo constante). É calculado através da diferença das log-funções de verossimilhança parcial entre o modelo sob análise e o modelo de referência.

Figura 22. Exemplo de segmentos de uma árvore para o modelo Random Forest.



Resultados e conclusões

Para comparar os resultados obtidos neste estudo após a aplicação das diferentes técnicas, foi utilizada como medida de poder discriminante uma matriz de confusão, bem como a área sob a curva ROC (AUC):


- ▶ A matriz de confusão permite medir as taxas de acerto do modelo. Para isso, foi estabelecido o ponto de corte no valor que minimiza o erro de previsão.
- ▶ Em relação ao indicador AUC, quanto maior for o valor do indicador, maior é o poder de discriminação. A experiência prática⁷⁵ mostra que este indicador costuma tomar valores entre 75% e 90%. Estes indicadores estão estimados sobre uma amostra de validação⁷⁶.

Também foram comparados os impactos da mudança do poder preditivo no negócio. Para isso, foi escolhido o modelo tradicional como base de comparação (com o ponto de corte estabelecido a partir da otimização dos erros tipo I e tipo II). Sobre esse modelo, estimou-se a taxa de inadimplência resultante com cada um dos modelos analisados, mantendo o mesmo nível de taxa de aceitação que o modelo tradicional (ou seja, a igualdade do volume de negócio), bem como a taxa de aceitação de cada um dos modelos, se a taxa de inadimplência se mantém é a mesma que no modelo tradicional.

Os resultados obtidos são os seguintes⁷⁷ (Figuras 23, 24 e 25):

- ▶ Após a comparação com estas estatísticas (Figura 24), observa-se um melhor desempenho nos modelos *ensemble* em relação às outras metodologias. Particularmente, o *random forest* é o método que apresenta os melhores resultados: em termos de taxa de acerto aumenta de 74,7% do modelo tradicional para 80,3%, o que supõe um aumento percentual de 7,5% sobre o obtido através de técnicas tradicionais; em termos de poder discriminante, consegue-se melhorar a área sob a curva ROC de 81,5% no modelo tradicional até 88,2%, o que representa um aumento percentual de 8,2%. No entanto, esta melhoria foi obtida aumentando a complexidade da estimativa, já que foram utilizadas muitas variáveis entre as 50 árvores estimadas.

Figura 24. Taxa de acerto na matriz de confusão (soma da diagonal) para as diferentes abordagens.



- ▶ O segundo melhor método é a aplicação da rede elástica, com a qual os valores de taxa de acerto e a área sob a curva ROC chegam a 79% e 86,4%, respectivamente. Isto representa um aumento percentual de 6% em ambos os indicadores. Como se observa, em amostras com muitas variáveis, a aplicação de técnicas de regularização implicam em um aumento significativo em relação a métodos tradicionais de seleção de variáveis (*stepwise*).
- ▶ Da mesma forma, neste caso em particular, observou-se que a dificuldade acrescentada pelo uso de SVM (tanto lineal como radial) não significa um aumento no poder preditivo do modelo. Isto se deve a que o modelo logístico tradicional já apresenta um poder discriminante elevado (82%), o que costuma ocorrer quando as variáveis permitem separar linearmente as duas classes e, portanto, a aplicação de SVM não incorpora informações sobre a separabilidade das categorias (de fato, neste caso perde-se poder preditivo e taxa de acerto).

⁷⁵BCBS (2005).

⁷⁶De acordo com as práticas em modelagem, a população total foi separada em amostras diferentes de construção e validação, de forma que cada modelo treinado com a amostra de construção foi utilizado para pontuar novamente a amostra de validação, e os resultados sobre a validação foram estimados sobre essa amostra.

⁷⁷Estes resultados foram obtidos sobre amostras de validação específicas, porém em um ambiente de *Machine Learning* é adequado avaliar em diferentes subamostras a adequação dos resultados (através de técnicas de *bootstrapping* ou *cross-validation*).

Figura 23. Resultados para as diferentes abordagens.

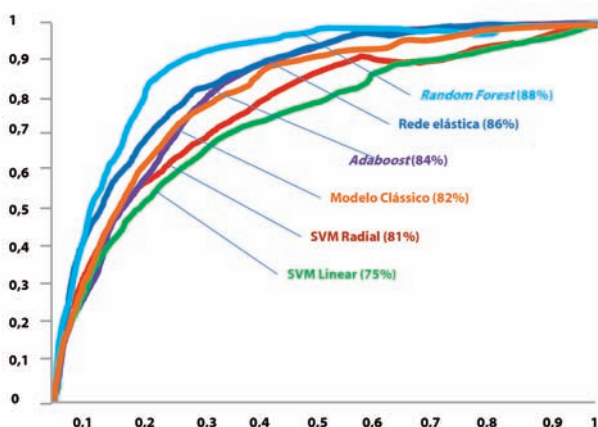
	Modelo tradicional		Rede elástica		Random Forest		Adaboost		SVM Linear		SVM Radial	
Matriz de confusão	70,3%	1,5%	74,4%	1,2%	75,6%	1,2%	72,4%	1,4%	65,2%	1,8%	67,6%	1,6%
	23,9%	4,4%	19,8%	4,6%	18,5%	4,7%	21,8%	4,5%	29,0%	4,0%	26,5%	4,2%
AUC	81,5%		86,4%		88,2%		83,7%		74,6%		81,1%	
Taxa de inadimplência (igualdade de negócio)	2,1%		1,4%		1,1%		1,7%		2,7%		2,4%	
Taxa de aceitação (igualdade de inadimplência)	71,8%		81,4%		83,2%		76,8%		41,8%		61,4%	

- ▶ Por fim, do ponto de vista do possível impacto no negócio do aumento do poder preditivo dos modelos, conclui-se que, com um mesmo volume de negócio, a taxa de inadimplência se reduziria em 48%, no caso do *random forest* (utilizando um ponto de corte ideal com o modelo clássico, chegaria a uma taxa de inadimplência de 2,1%, que se reduz a 1,1% com o *random forest* se o volume de operações aprovadas for mantido) e 30% no caso da rede elástica (em que a taxa de inadimplência se reduz a 1,4%). Da mesma forma, bem como a taxa de inadimplência (2,1%), o volume de negócio aumentaria 16% no caso do *random forest* e 13% no caso da rede elástica.

Para poder se beneficiar das vantagens associadas a estas técnicas é fundamental, portanto, possuir um *framework* e uma função de gestão do risco de modelo de acordo aos máximos padrões de qualidade (já tratados na publicação anterior⁷⁸ da Management Solutions "Model Risk Management: Aspectos quantitativos e qualitativos da gestão do risco de modelo") que inclua, entre outros aspectos, a execução, por parte da função de Validação interna de um *challenge* efetivo, das hipóteses utilizadas e os resultados alcançados por estes modelos através, entre outras técnicas, da sua réplica e, nas entidades mais avançadas, do desenvolvimento de modelos "*challenger*" com técnicas tradicionais.

⁷⁸Management Solutions (2014)

Figura 25. Curvas ROC obtidas para cada uma das técnicas.



A matriz de confusão a partir do ponto de corte que minimiza os erros


Uma das técnicas para medir o poder discriminante do modelo é a matriz de confusão. Esta matriz compara a previsão do modelo com o resultado real. No caso do modelo de *scoring*, permite comparar os *defaults* previstos pelo modelo com os que ocorreram realmente (Figura 26). Para isso, são calculadas as taxas de acerto (*defaults* corretamente previstos pelo modelo e operações classificadas como não *defaults* que, ao final, não entraram em inadimplência) e os erros do modelo (os conhecidos como erro tipo I e erro tipo II⁷⁹).

Figura 26. Matriz de confusão.

		Realidade	
		Não Default	Default
Previsão	Não Default	Acerto	Erro tipo I
	Default	Erro tipo II	Acerto

Considerando que os modelos outorgam uma pontuação (que é uma ordenação das operações em função da qualidade de crédito), para poder determinar se o modelo prevê um *default* é necessário estabelecer um ponto de corte. Uma das metodologias aceitas na indústria é estabelecer o ponto de corte que minimiza simultaneamente os dois erros (Figura 27).

Figura 27. Ponto de corte que minimiza simultaneamente o erro tipo I e o erro tipo II.



⁷⁹Porcentagem de *defaults* erroneamente classificados pelo modelo e porcentagem de falsos *defaults* erroneamente previstos pelo modelo, respectivamente.

Bibliografia



Acuity Market Intelligence (2016). "The Global Biometrics and Mobility Report: The Convergence of Commerce and Privacy". Market Analysis and Forecasts 2016 to 2022.

BCBS (2005). "Studies on the Validation of Internal Rating Systems". Bank for International Settlements.

Bengio, Y. e outros (2015). Bengio, Y. LeCun, Y. Hinton, G.: "Deep Learning"(2015) Nature.

Box, G. e Draper, N. (1987). "Empirical Model-Building and Response Surfaces". Wiley.

Breiman, L. (2001). "Statistical Modeling: The two cultures", Vol 16 (3), Statistical Science, 2001. p. 199-231.

Brynjolfsson, E. e McAfee, A. (2017). "The business of artificial intelligence". Harvard Business Review.

Cios, K.J. e outros (2007). Cios, K.J., Pedrycz, W., Swiniarski, R.W., Kurgan, L.: "Data Mining: A Knowledge Discovery Approach". Springer 2007.

Círculo de Empresários (2018). "Alcance e implicaciones de la transformación digital: principales ámbitos de actuación".

Cisco (2017). "The Zettabyte Era: Trends and Analysis". White paper. Junho de 2017.

Cybersecurity Ventures (2017). Cyber economy research.

Dahr, V. (2013). "Data Science and prediction". Association for Computer Machinery.

Digital Consumption (2016). World Economic Forum White Paper Digital Transformation of Industries.

Domingos, P. (2012). "A few useful things to know about *Machine Learning*", Vol 55 (10), Communications of the ACM, 2012. p. 78-87.

Domingos, P (2015). "The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World". 2015.

EC (2017). Digital Transformation Scoreboard 2017. European Commission.

Fitzgerald et al. (2013). "Embracing Digital Technology: A New Strategic Imperative", Sloan Management Review

Forbes (2015). "Big Data: 20 Mind-Boggling Facts Everyone Must Read".

Forbes (2016). "Artificial Intelligence Is Helping Doctors Find Breast Cancer Risk 30 Times Faster".

Forbes (2017). Janakiram MSV: "3 Key *Machine Learning* Trends To Watch Out For In 2018". Forbes, dezembro de 2017.

Friedman, J. H. (1997). "Data mining and statistics: what's the connection?" Apresentado no 29th Symposium on the Interface: Computing Science and Statistics, Maio 14-17, 1997, Houston, TX, p. 3-9.

Frost & Sullivan (2017). "Global Forecast of RegTech in Financial Services to 2020".

International Telecommunication Union (2009). "Distributed Computing: Utilities, Grids & Clouds". ITU-T Technology Watch Report 9.

International Telecommunication Union (2017). ITU World Telecommunication/ICT indicators database 2015.

Jordan, M. I., Mitchell, T. M. (2015). "*Machine Learning: Trends, perspectives, and prospects*", Vol 349 (6245), Science, 2015. p. 255-260.

LEGOs (2018). Still "The Apple of Toys"? Harvard Business School

Management Solutions (2014). "Model Risk Management: Aspectos cuantitativos y cualitativos de la gestión del riesgo de modelo".

Management Solutions (2015). "*Data Science y la transformación del sector financiero*".

McKinney (2018). "Python for Data Analysis". O'Reilly Media.

Ministério de Indústria, Energia e Turismo. Governo da Espanha (2018). "Nuevas tendencias y desafíos en el mundo de los datos". Março de 2018.

Mitchell, T. (1997). *Machine Learning*. McGraw Hill.

Murphy, K. (2012). "*Machine Learning: A probabilistic perspective*". The MIT Press.

Parlamento Europeu (2016). Regulamento (UE) 2016/679 do Parlamento Europeu e do Conselho de 27 de abril de 2016.

Pearson (2016). Lukin, R. et alter: "Intelligence Unleashed: An argument for AI in Education". Pearson.

Samuel, A. (1959). "Some studies in *Machine Learning* using the game of checkers". IBM Journal. July 1959.

Schwab, K. (2016). "The Fourth Industrial Revolution". World Economic Forum.

Shalev-Shwartz, S. e Ben-David, S. (2014). "Understanding *Machine Learning: From Theory to Algorithms*". Cambridge University Press.

Statista (2017). "Number of Machine-to-Machine (M2M) connections worldwide from 2014 to 2021". 2018.

Statista (2018). "Digital Market Outlook". 2018.

Techemergence (2017). "How America's 5 Top Hospitals are Using *Machine Learning* Today".

The Economist (2017). Axel Springer's digital transformation.

Turing, A.M. (1950). "Computer Machinery and Intelligence". Mind 49: p. 433-460.

Westerman, G. (2017). "Your Company Doesn't Need a Digital Strategy". MITSloan Management Review.

Glossário



Análise de componentes principais (PCA): método de redução de dimensionalidade através do qual se busca um subespaço dimensional inferior para projetar os dados para minimizar os erros de projeção, convertendo um conjunto de variáveis correlacionadas em outro (com menor quantidade de variáveis) sem correlação, chamadas componentes principais.

Auto-encoder: algoritmo de aprendizagem não supervisionado baseado em redes neurais que aplicam propagação retroativa, estabelecendo os valores do *target* para que sejam iguais aos do *input*.

Big Data: qualquer quantidade volumosa de dados estruturados, semiestruturados ou não estruturados que têm o potencial de ser extraída para obtenção de informação. Por

extensão, se refere também ao conjunto de infraestruturas e arquiteturas tecnológicas que armazenam estes dados.

Blockchain: estrutura de dados que implementa um registro criptográfico de todas as operações realizadas e previamente validadas por uma rede de nós independentes através de um algoritmo de consenso.

Bootstrapping: Processo de geração de muitas amostras a partir da seleção aleatória com substituição.

Business to Business (B2B): transações comerciais entre empresas, isto é, as estabelecidas entre um fabricante e o distribuidor de um produto, ou entre o distribuidor e um varejista.

Cadeia de Markov: processo estocástico discreto em que a probabilidade de que um evento ocorra depende unicamente do evento anterior.

Cibersegurança: conjunto de ferramentas, políticas, métodos, ações, seguros e tecnologias que podem ser utilizadas para proteger os diferentes ativos tecnológicos e os dados de uma organização armazenados em algum tipo de suporte físico ou lógico no ciberentorno, assim como as comunicações entre estes ativos.

Computer Vision: subcampo da inteligência artificial, cujo propósito é programar um computador para que entenda uma cena ou as características de uma imagem.

Curva ROC (Receiver Operating Characteristic): curva empregada para analisar o poder preditivo de um modelo de saída binária. Representa a relação entre o erro de tipo 1 (classificar incorretamente eventos adversos) e o erro tipo 2 (classificar incorretamente eventos favoráveis).

Data dredging: uso de técnicas de *data mining* com o objetivo de encontrar padrões estatisticamente significativos que não estão respaldados por hipóteses *a priori* sobre a causalidade da relação.

Função de custo: função que, a partir de um valor dos estimadores de um modelo, fornece uma medida do erro que se comete ao utilizar o modelo. O processo de treinamento de um modelo costuma consistir em obter os estimadores que minimizam a função de custo.

Function as a Service (FaaS): categoria de serviços de programação na nuvem proporcionado por uma plataforma que permite aos usuários desenvolver, usar e administrar funcionalidades de uma aplicação sem a complexidade de construir e manter a infraestrutura tipicamente associada a esta aplicação.

Graphics Process Unit (GPU): coprocessador dedicado ao processamento de gráficos ou operações de ponto flutuante para diminuir a carga de trabalho do processador central (CPU).

Greedy: algoritmo em que cada elemento a considerar é avaliado uma única vez, sendo descartado ou selecionado, de tal forma que se é selecionado forma parte da solução, e se é descartado, não forma parte da solução e nem voltará a ser considerado para a mesma.

Internet das coisas (IoT): interconexão dos objetos de uso cotidiano através da Internet.

k-fold cross validation: processo de validação de amostras cruzadas que consiste em dividir a amostra em k grupos, e de forma iterativa utilizar cada um dos grupos para a validação e o resto para a construção, alterando o grupo de validação em cada iteração.

Knowledge discovery: processo de identificar padrões nos dados que sejam válidos, novos, potencialmente úteis, e entendíveis.

Machine to Machine (M2M): conectividade entre máquinas onde, uma vez que uma ação é realizada, os dados gerados pelos distintos elementos digitais envolvidos se conectam com servidores com o objetivo de armazenar e analisar a informação.

Overfitting (supertreinamento): característica de um modelo que se dá quando este se ajustou demasiadamente à amostra de treinamento, de forma que não consegue resultados satisfatórios sobre amostras diferentes a esta (por exemplo sobre a amostra de validação).

Partial likelihood deviance (PLD): diferença das log-funções de verossimilhança parcial entre o modelo sob análise e um modelo de comparação (geralmente um modelo que não depende de nenhuma variável).

Partição ortogonal: partição de uma amostra de dados em um espaço n-dimensional perpendicular a cada um dos eixos que definem as variáveis explicativas.

Peer to Peer (P2P): rede de computadores que permitem o intercâmbio direto de informação em qualquer formato, entre os computadores interconectados.

RegTech: combinação dos termos "*regulatory technology*", que faz alusão a uma empresa que utiliza a tecnologia para ajudar as empresas a cumprir com a regulação de maneira eficiente e com um custo reduzido.

Regularização: técnica matemática que proporciona estabilidade numérica a um problema mal condicionado através da adição de um funcional penalizador em sua formulação (como, por exemplo, o caso das redes elásticas).

Resampling: conjunto de métodos que permite reconstruir uma amostra de dados. Utilizado principalmente para criar subconjuntos de treinamento e validação sobre a amostra original.

Roboadvisor: sistema automático de gestão financeira baseado em algoritmos, utilizado para o desenho, composição e monitoramento de carteiras de investimento de forma automatizada.

Robotics Process Automation (RPA): desenvolvimento de software que replica as ações de um ser humano, interagindo com a *interface* de usuário de um sistema de informática.

Smart contract: contrato programável que implementa regras de negócio, cujo código fica registrado e pode ser executado de forma distribuída pelos diferentes nós da rede.

Stepwise: método iterativo de construção de modelos baseado na seleção automática de variáveis.



Nosso objetivo é superar as expectativas dos nossos clientes sendo parceiros de confiança

A Management Solutions é uma empresa internacional de serviços de consultoria com foco em assessoria de negócios, riscos, organização e processos, tanto sobre seus componentes funcionais como na implementação de tecnologias relacionadas.

Com uma equipe multidisciplinar (funcionais, matemáticos, técnicos, etc.) de 2.000 profissionais, a Management Solutions desenvolve suas atividades em 24 escritórios (11 na Europa, 12 nas Américas e um na Ásia).

Para atender às necessidades de seus clientes, a Management Solutions estruturou suas práticas por setores (Instituições Financeiras, Energia e Telecomunicações) e por linha de negócio (FCRC, RBC, NT), reunindo uma ampla gama de competências de Estratégia, Gestão Comercial e Marketing, Gerenciamento e Controle de Riscos, Informação Gerencial e Financeira, Transformação: Organização e Processos, e Novas Tecnologias.

A área de P&D presta serviço aos profissionais da Management Solutions e a seus clientes em aspectos quantitativos necessários para realizar os projetos com rigor e excelência, através da aplicação das melhores práticas e da prospecção contínua das últimas tendências em data science, machine learning, modelagem e big data.

Javier Calvo

Sócio

javier.calvo.martin@msgermany.com.de

Manuel A. Guzmán

Gerente de P&D

manuel.guzman@msspain.com

Daniel Ramos

Metodologista de P&D

daniel.ramos.garcia@msspain.com



Management Solutions, serviços profissionais de consultoria

A Management Solutions é uma firma internacional de serviços de consultoria focada na assessoria de negócio, riscos, finanças, organização e processos

Para mais informações acesse: **www.managementsolutions.com**

Nos siga em: 

© **Management Solutions. 2018**

Todos os direitos reservados.

www.managementsolutions.com

Madrid Barcelona Bilbao London Frankfurt Paris Warszawa Zürich Milano Roma Lisboa Beijing New York Boston Atlanta
Birmingham San Juan de Puerto Rico Ciudad de México Medellín Bogotá São Paulo Lima Santiago de Chile Buenos Aires