



UNIVERSIDADE FEDERAL DO CEARÁ
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO, ATUÁRIA E CONTABILIDADE
CURSO DE FINANÇAS

STEFFANY DE OLIVEIRA FAÇANHA

PROSPECÇÃO DO USO DE MACHINE LEARNING NAS CORRETORAS
BRASILEIRAS

FORTALEZA

2019

STEFFANY DE OLIVEIRA FAÇANHA

PROSPECÇÃO DO USO DE MACHINE LEARNING NAS CORRETORAS
BRASILEIRAS

Monografia apresentada ao Curso de Finanças da Universidade Federal do Ceará, como requisito parcial à obtenção do título de bacharel em Finanças. Área de concentração: Tecnologia aplicada a finanças

Orientador: Prof. Dr. Francisco Gildemir Ferreira da Silva

FORTALEZA

2019

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

F123p Façanha, Steffany de Oliveira.

Prospecção do uso de machine learning nas corretoras brasileiras / Steffany de Oliveira Façanha. – 2019.
52 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Faculdade de Economia, Administração, Atuária e Contabilidade, Curso de Finanças, Fortaleza, 2019. Orientação: Prof. Dr. Francisco Gildemir Ferreira da Silva .

1. Machine learning . 2. Corretoras brasileiras . 3. Prospecção . I. Título.

CDD 332

STEFFANY DE OLIVEIRA FAÇANHA

PROSPECÇÃO DO SOBRE O USO DE MACHINE LEARNING NAS CORRETORAS
BRASILEIRAS

Monografia apresentada ao Curso de Finanças da Universidade Federal do Ceará, como requisito parcial à obtenção do título de bacharel em Finanças. Área de concentração: Tecnologia aplicada a finanças

Aprovada em: ___/___/_____.

BANCA EXAMINADORA

Prof. Dr. Francisco Gildemir Ferreira da Silva (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Rafael Barros Barbosa (Examinador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Vitor Monteiro Borges (Convidado)
Universidade Federal do Ceará (UFC)

À minha mãe, Isabel, por me apoiar sempre. E aos amigos e professores que me acompanharam nessa jornada.

AGRADECIMENTOS

À CAPES, pelo apoio financeiro com a manutenção da bolsa de auxílio.

Ao Prof. Dr. Francisco Gildemir Ferreira da Silva, pela excelente orientação.

Aos professores participantes da banca examinadora Prof. Dr. Rafael Barros e Prof. Dr. Vitor Borges pelo tempo, pelas valiosas colaborações e sugestões.

“Machines take me by surprise with great frequency.” (Alan Turing).

RESUMO

A tecnologia de *machine learning* (ML) está sendo cada vez mais utilizada pelo setor financeiro dos EUA, Europa e Ásia. Neste contexto, o presente trabalho buscou prospectar dados referentes ao uso dessa tecnologia pelas corretoras de valores mobiliários do Brasil. Investigaram-se duas hipóteses: o uso dessa tecnologia ou não pelas corretoras e, se sim, em que são aplicadas. Adotou-se uma metodologia descritiva analítica. Foi disponibilizado um formulário *online* em duas partes para 72 corretoras do país, com questões que definem seu perfil e mostram os usos atribuídos ao *machine learning*. Os resultados limitaram-se à baixa adesão das corretoras ao questionário que só obteve quatro respostas, representando 5% da população. O estudo mostra que as técnicas de *machine learning* são utilizadas pelas corretoras investigadas, porém a um nível abaixo de seu potencial. A sua finalidade inclui analisar dados financeiros e prever tendências do mercado. O uso de ML ainda foi apontado como relevante para aumento da receita e da produtividade das operações das empresas que participaram da pesquisa. Sendo assim, nota-se que as técnicas de *machine learning* são pouco exploradas para operações financeiras no Brasil. Contudo, há restrições quanto a estas afirmações, por causa do tamanho limitado da amostra. Sendo assim, faz-se necessária a ampliação de estudos sobre o assunto para orientar as instituições financeiras do país na adoção dessa tecnologia, uma vez que auxiliaria no entendimento acerca das vantagens e desvantagens de utilizá-la.

Palavras-chave: *Machine learning*. Corretoras brasileiras. Prospeção.

ABSTRACT

Machine learning technology is increasingly used in the US, Europe and Asia financial sector. In this context, the present study sought to prospect data regarding the use of this technology by Brazilian securities brokers. Two hypotheses were investigated: the use of this technology or not by brokerages and, if so, in which they are applied. An analytical descriptive methodology was adopted. A two-part online form was made available to 72 brokerages in the country, with questions that define their profile and show the uses attributed to machine learning. The results were limited to the brokers' low adherence to the questionnaire that only obtained four answers, representing 5% of the population. The study shows that machine learning is used by the brokerage firms investigated, but at a level below its potential. Its purpose includes analyzing financial data and predicting market trends. The use of ML was also pointed as relevant to increase revenue and productivity of operations of companies that participated in the research. Thus, it is noted that the machine learning techniques are little explored for financial operations in Brazil. However, there are restrictions on these findings because of the limited sample size. Thus, it is necessary to expand studies on the subject to guide the country's financial institutions in the adoption of this technology, as it would help in understanding the advantages and disadvantages of using it.

Keywords: Machine learning. Brazilian brokerages. Prospection.

LISTA DE FIGURAS

Figura 1 - Interesse pelo termo <i>machine learning</i> no mundo.....	199
Figura 2 - Países interessados no termo <i>machine learning</i>	19
Figura 3 - Interesse pelo termo <i>machine learning</i> no Brasil	20
Figura 4 - Regiões do Brasil interessadas no termo <i>machine learning</i>	20
Figura 5 - Nível de uso das tecnologias digitais nas principais atividades	311
Figura 6 - Uso da análise de dados (analytics)	322
Figura 7 - Concordância com afirmações sobre atividades operacionais.....	333

LISTA DE GRÁFICOS

Gráfico 1 - Limitações da amostra da pesquisa	37
Gráfico 2 - Anos de experiência das corretoras no mercado de valores.....	38
Gráfico 3 - Localização das corretoras participantes da pesquisa	38
Gráfico 4 - Localização da maioria dos clientes das corretoras pesquisadas	39
Gráfico 5 - Ativos administrados pelas corretoras pesquisadas	39
Gráfico 6 - Respostas sobre utilização de IA nas corretoras pesquisadas	40
Gráfico 7 - Como as corretoras utilizam a inteligência artificial	40
Gráfico 8 - Corretoras pesquisadas que utilizam ML.....	41
Gráfico 9 - Utilização de ML pelas corretoras pesquisadas	41
Gráfico 10 - Corretoras pesquisadas que afirmam que ML contribui para potencializar suas operações	42
Gráfico 11 - Operações potencializadas pelo uso de ML	42
Gráfico 12 - Nível de aprimoramento das operações das corretoras pesquisadas.....	43
Gráfico 13 - Corretoras pesquisadas que possuem uma cultura de análise de dados.....	43
Gráfico 14 - Aumento da velocidade da análise de dados financeiro usando ML	44
Gráfico 15 - Aumento de receita da empresa que usa ML	44
Gráfico 16 - Motivos de as corretoras pesquisadas não utilizarem ML	45
Gráfico 17 - Esforços para adoção de ML pelas corretoras pesquisadas	45

LISTA DE QUADROS

Quadro 1 - As tecnologias de inteligência artificial e seus conceitos.....	24
Quadro 2 - Tipos de aprendizados e exemplos de uso.....	26
Quadro 3 - Áreas específicas de utilização de machine learning e instituições usuárias	30
Quadro 4 - Exemplos do uso de machine learning em instituições financeiras no Brasil..	356

LISTA DE ABREVIATURAS E SIGLAS

FEAAC	Faculdade de Economia, Administração, Atuárias e Contabilidade
FEBRABAN	Federação Brasileira de Bancos
FSB	Financial Stability Board
IA	Inteligência Artificial
IBM	International Business Machines
ML	Machine Learning
UFC	Universidade Federal do Ceará

LISTA DE SÍMBOLOS

\$	Dólar
%	Porcentagem
£	Libra
¥	Iene
€	Euro
§	Seção
©	Copyright
®	Marca Registrada

SUMÁRIO

1	INTRODUÇÃO	157
1.1	Objetivo	18
<i>1.1.1</i>	<i>Objetivo Geral</i>	18
<i>1.1.2</i>	<i>Objetivos específicos</i>	18
1.2	Justificativa	18
1.3	Delimitação	20
1.4	Estrutura do trabalho	211
2	REVISÃO DA LITERATURA	22
2.1	Inteligência Artificial, <i>Big Data</i> e <i>Machine Learning</i>	22
2.2	Conceitos e processos de aprendizagem de <i>machine learning</i>	24
2.3	<i>Machine learning</i> no mercado financeiro mundial	277
2.4	<i>Machine learning</i> no mercado financeiro brasileiro	311
3	METODOLOGIA DA PESQUISA	366
3.1	Enquadramento metodológico	366
3.2	Hipóteses investigadas	366
<i>3.2.1</i>	<i>Primeira hipótese investigada</i>	366
<i>3.2.2</i>	<i>Segunda hipótese investigada</i>	366
3.3	Teste das hipóteses investigadas	377
3.4	Descrição da amostra	377
4	RESULTADOS	468
4.1	Primeira hipótese investigada	42
4.2	Segunda hipótese investigada	42
5	CONSIDERAÇÕES FINAIS	477
5.1	Conclusões	477
5.2	Recomendações	48
	REFERÊNCIAS	499

APÊNDICE A – QUESTIONÁRIO DE PESQUISA	51
--	-----------

1 INTRODUÇÃO

A Inteligência Artificial (IA) vem tomando cada vez mais espaço na vida das pessoas do século XXI e vem alterando significativamente os modelos operacionais das instituições financeiras. (Febraban, 2019). Com um conjunto de tecnologias relacionadas que incluem *machine learning* (ML) e *deep learning* (DL), IA tem o potencial de causar uma ruptura e redefinir a indústria de serviços financeiros tradicionais. (Buchanan, 2019).

O *machine learning* é uma subcategoria de IA, e trata-se de processos em que a máquina é capaz de aprender sem precisar de programação explícita. Possui diferentes tipos de aprendizado (supervisionado, não supervisionado, por reforço e *deep learning*) que são utilizados para os mais variados fins no setor de serviços financeiros. Buchanan (2019), apresenta as principais áreas de uso de *machine learning* nas instituições financeiras dos EUA, Europa e Ásia como detecção de fraudes, *chatbots* e negociação algorítmica.

No que diz respeito ao Brasil, Capgemini (2017), mostra que as instituições financeiras compreendem a importância da inserção das tecnologias nas suas operações. As tecnologias de IA são utilizadas, principalmente, para fins de comunicação com os clientes. De acordo com o estudo, a análise de dados (*analytics*) é utilizada, principalmente, para entender melhor as necessidades dos clientes. A pesquisa mostra ainda que os bancos no Brasil já estão explorando a transformação digital, e na comparação com outros setores estão bem mais avançados em relação a esse processo, pois enxergam a transformação digital como importante fator de posicionamento competitivo.

Sendo este trabalho uma revisão bibliográfica de caráter prospectivo e descritivo sobre o uso de *machine learning* pelas corretoras de valores brasileiras. Este objetiva prospectar dados sobre o uso da tecnologia de *machine learning* pelas corretoras de valores brasileiras. Onde serão analisadas, por meio de um questionário em duas partes, quatro corretoras do país a fim de esclarecer se essa tecnologia vem sendo utilizada ou não e, se sim, com qual finalidade.

Motivado pelo crescente uso das tecnologias de IA na área financeira desenvolveu-se este trabalho que ampliará os estudos sobre tecnologias disruptivas no setor financeiro brasileiro.

1.1 Objetivo

O principal objetivo deste trabalho é prospectar dados sobre a utilização da tecnologia de *machine learning* pelas corretoras de valores brasileiras.

1.1.1 Objetivo Geral

Mostrar como vem sendo aplicado os modelos de *machine learning* em corretoras de valores brasileiras.

1.1.2 Objetivos específicos


- a) Propor questionário para análise das corretoras de valores nacionais;
- b) Identificar a área de aplicação das técnicas de *machine learning* pelas instituições em suas operações.

1.2 Justificativa

As técnicas de *machine learning* vêm sendo adotadas no setor financeiro de diversos países da América, Europa e Ásia para detecção de fraude, previsões de tendências do mercado, entre outras funções (Buchanan, 2019).

Dessa forma, a adoção destas técnicas geraram um maior interesse sobre os seus conceitos e aplicações. Através do Google Trends, uma ferramenta do Google que mostra as tendências de buscas em todo o mundo, podemos observar que a trajetória do interesse em *machine learning*, especificamente, em operações do setor financeiro vem crescendo nos últimos cinco anos no Brasil e no mundo como pode ser observado nas Figuras 1 e 3.

Figura 1 - Interesse pelo termo *machine learning* no mundo



Fonte: Google Trends, 2019.

O período apresentado na Figura 1 começa em 2004 e segue até 2019. É possível observar picos de interesse por *machine learning* aplicado ao setor financeiro entre 2004 e 2008, no entanto, é a partir de 2014 que a trajetória se torna crescente. Entre os países interessados no assunto estão a Índia, China, Estados Unidos, Canadá, Austrália, Rússia, Finlândia, entre outros (FIGURA 2).


Figura 2 - Países interessados no termo *machine learning*



Fonte: Google Trends, 2019.

No que diz respeito ao Brasil, é possível observar um crescimento no interesse pelo assunto também a partir do segundo semestre de 2014 (FIGURA 3).

Figura 3 - Interesse pelo termo *machine learning* no Brasil



Fonte: Google Trends, 2019.

E as regiões do país interessadas por ML são a sul e a sudeste, e há interesse de alguns estados das outras regiões como Amazonas, Ceará, Bahia, Distrito Federal, entre outros (FIGURA 4).

Figura 4 - Regiões do Brasil interessadas no termo *machine learning*



Fonte: Google Trends, 2019.

Sendo assim, este trabalho segue o interesse mundial pela aplicação de ML no setor financeiro ao investigar a adesão ou não das corretoras de valores do Brasil da tecnologia em seus processos.

Com isso, é possível fazer um pareamento entre as tecnologias usadas no mundo frente às usadas no Brasil. Dessa forma, ao apurar o uso ou não do *machine learning* pelas corretoras brasileiras serão ampliados os estudos sobre tecnologias disruptivas no setor financeiro que, imagina-se, ainda são incipientes no país.

1.3 Delimitação

O presente trabalho é uma revisão bibliográfica de caráter prospectivo e descritivo sobre o uso de machine learning pelas corretoras de valores brasileiras. Onde serão analisadas quatro corretoras do país a fim de esclarecer se essa tecnologia vem sendo utilizada ou não e, se sim, com qual finalidade.

1.4 Estrutura do trabalho

O trabalho está dividido em cinco partes. A primeira introduz o tema e a importância do mesmo. Assim como seus objetivos geral e específico, e a razão da escolha do tema. A segunda faz a revisão de literatura sobre os conceitos de *machine learning*, suas origens, suas formas de aprendizagem e uso no setor financeiro de diferentes países. A terceira parte mostra a metodologia da pesquisa, a descrição da amostra, suas limitações e as duas hipóteses a serem testadas. O quarto bloco apresenta os resultados obtidos de quatro respostas ao formulário *online* disponibilizado a 72 corretoras brasileiras e as duas hipóteses investigadas. Por fim, têm-se as conclusões, seguidas de recomendações para futuros trabalhos sobre o tema.

2 REVISÃO DA LITERATURA

Nesta revisão, o primeiro tópico apresenta os conceitos de Inteligência Artificial e *Big Data* e sobre como se relacionam com *machine learning*. O segundo expõe os conceitos do termo *machine learning* e seus processos de aprendizado como esses métodos diferem uns dos outros. O terceiro discorre sobre as aplicações do *machine learning* no setor financeiro de diversos países. E por fim, explora-se o uso de *machine learning* no setor financeiro do Brasil.

2.1 Inteligência Artificial, *Big Data* e *Machine Learning*

O aumento recente da influência das tecnologias de Inteligência Artificial (IA) na vida das pessoas associado ao aumento na quantidade e disponibilidade de dados resultaram no ressurgimento do interesse pelas suas aplicações. Como já ocorre no diagnóstico de doenças, tradução de línguas, direção de carros e no setor financeiro (FSB, 2017).

Um de seus precursores foi Alan Turing que em seu artigo “*Computing Machinery and Intelligence*” de 1950, mostrou a possibilidade de criar máquinas capazes de imitar o comportamento humano e aprender como uma criança. Os estudos na área foram levados adiante por outros estudiosos como John McCarthy, considerado o pai da IA, Marvin L. Minsky, Nathaniel Rochester e Claude E. Shannon com suas pesquisas em inteligência artificial na Universidade de Stanford e Dartmouth em 1955. Em seus estudos propunham comprovar que uma máquina possuía a capacidade de simular as características do cérebro humano. Para isso, buscavam desenvolver os aspectos de aprendizado de máquina fazendo com que resolvessem problemas antes reservados apenas para a capacidade humana, além de aprimorar-se sozinhas a partir da experiência (McCarthy, Minsky, Rochester e Shannon, 1955).

Sendo assim, JP. Morgan (2017), afirma que a inteligência artificial é um esquema mais amplo para habilitar máquinas com inteligência cognitiva semelhante à humana. E as primeiras tentativas de alcançar a IA envolveram a codificação de um grande número de regras e informações na memória do computador.

A inteligência artificial é usada em diversas formas e pode ser encontrada em um largo número de setores como linhas de montagens robóticas e brinquedos de alta tecnologia. Além de sistemas de reconhecimento de voz e pesquisas médicas. Sua aplicação mais comum é na busca de padrões em dados que é a razão por ser normalmente aplicada em buscas *online* e recomendação de sites. (Hussain; Manhas, 2016, tradução nossa).

O *machine learning* é uma subcategoria de IA que permite que um sistema aprenda

a partir de dados, e não através de programação explícita. Como explicam os autores Hurwitz e Kirsch (2018, tradução nossa), “*IA pode ser entendida como a maneira mais ampla de descrever sistemas que podem ‘pensar’, enquanto que o aprendizado de máquina concentra-se na capacidade de aprender e adaptar um modelo baseado em dados em vez de programação explícita*”.

Em *machine learning*, a máquina recebe uma entrada (conjuntos de variáveis e dados) e uma saída que é consequência de variáveis de entrada. A partir disso, a máquina aprende uma regra que vincula a entrada e a saída. Em última análise, o sucesso desta tarefa de aprendizagem é testado fora da amostra, ou seja, sua capacidade de obter conhecimento útil da relação entre variáveis e prever resultados em situações ainda não vistas (JP Morgan, 2017).

O armazenamento e análise desses conjuntos de dados é denominado “*Big Data*” e utiliza técnicas de inteligência artificial para encontrar padrões em dados de fontes diversas (FSB, 2017). Como mostram Hurwitz e Kirsch (2018, tradução nossa), “*Big data é qualquer tipo de fonte de dados que tem pelo menos uma das quatro características compartilhadas, chamadas de quatro Vs: volume, velocidade, variedade e veracidade*”.

- a) Volumes de dados extremamente grandes;
- b) Capacidade de mover esses dados em alta velocidade;
- c) Variedade de dados com fontes em constante expansão;
- d) Veracidade para que as fontes de dados realmente representem a verdade.

Hurwitz e Kirsch (2018) afirmaram que nos últimos 30 anos, o papel da análise nos processos operacionais das organizações mudou de forma significativa. As empresas vêm experimentando uma progressão nos níveis de maturidade analítica que vão desde a análise descritiva à análise preditiva até o aprendizado de máquina. Empresas como Facebook e Google, baseiam-se em métodos de inteligência artificial como entendimento de textos e reconhecimento facial, além de utilizarem suas técnicas para processar grandes volumes de dados acumuladas por toda parte (Cozman, 2018). Isto ocorre pela imensa produção de informações dos últimos anos que criaram conjuntos de dados grandes e complexos (estruturados, desestruturados e semiestruturados).

De acordo com Hurwitz e Kirsch (2018), o *Big Data* é apropriado para treinar modelos de *machine learning*, pois este requer o conjunto certo de dados que podem ser aplicados a um processo de aprendizado. Para que uma organização use técnicas de *machine learning* não é necessário grande volume de dados. No entanto, o *Big Data* contribui com a precisão dessas técnicas e amplia o rigor das análises feitas pelas organizações levando a resultados apurados.

A precisão de um modelo de aprendizado de máquina pode aumentar substancialmente se for treinada em *Big Data*. Sem dados suficientes, você está tentando tomar decisões sobre pequenos subconjuntos de dados que podem levar à interpretação incorreta de uma tendência ou à falta de um padrão que está apenas começando a surgir. (Hurwitz, Kirsch, 2018, tradução nossa).

Dessa forma, pode-se observar que o grande volume de dados gerados e armazenados diariamente, ou seja, o *Big Data*, relaciona-se tanto à inteligência artificial utilizando suas técnicas para tratar desses dados, como com *machine learning* alimentando as máquinas de aprendizado para gerar resultados mais precisos.

O Quadro 1 apresenta um resumo das tecnologias apresentadas neste tópico.

Quadro 1 - As tecnologias de inteligência artificial e seus conceitos

Tecnologia	Conceito
Inteligência artificial	São sistemas que possuem a capacidade de simular as características do cérebro humano
Machine learning	São sistemas que aprendem a partir de dados ao invés de usar uma programação explícita
Big Data	É o grande volume de dados gerados diariamente que tem pelo menos uma das quatro características compartilhadas, chamadas de quatro Vs: volume, velocidade, variedade e veracidade

Fonte: Autoral, 2019.

2.2 Conceitos e processos de aprendizagem de *machine learning*

O *Machine Learning* (ML), ou aprendizado de máquina, remonta a década de 1950, quando Arthur Lee Samuels, pesquisador da IBM (*International Business Machines*), desenvolveu um dos primeiros programas de aprendizado de máquina, um programa de auto aprendizado para jogar damas, e cunhou o termo “*machine learning*”. Desde então, segundo afirmam Berset e Allen (2018), o *machine learning* está se tornando rápida e fundamentalmente parte da vida cotidiana e vai desde a descoberta de novos sistemas solares no espaço até a identificação de células cancerígenas a partir de imagens.

Para Hurwitz e Kirsch (2018, tradução nossa), “*machine learning é uma forma de inteligência artificial que permite que um sistema aprenda a partir de dados ao invés de usar uma programação explícita*”. Por usar uma variedade de algoritmos que aprendem de forma interativa com dados para melhorá-los, descrevê-los e prever resultados, é possível produzir modelos mais precisos baseados nesses dados. Isto significa que o ML é um exercício orientado por dados, ou seja, é permitido aos computadores encontrar padrões e relacionamento em dados sem serem orientados por regras ou hipóteses e a partir disso são capazes de fazer previsões. (Berset e Allen, 2018).

Com efeito, Hurwitz e Kirsch (2018) afirmam que o aprendizado de máquina tornou-se um dos tópicos mais importantes nas organizações que buscam maneiras inovadoras de impulsionar recursos de dados para ajudar os negócios a obter um novo nível de conhecimento. Com os modelos adequados de *machine learning*, as organizações têm a capacidade de prever continuamente as mudanças nos negócios podendo se preparar para o que vier em seguida. À medida que os dados são adicionados continuamente, os modelos de aprendizado de máquina garantem que a solução seja atualizada de forma ininterrupta.

O *machine learning* possui quatro tipos de processos de aprendizado são eles: o aprendizado supervisionado, não supervisionado, de reforço e *deep learning*.

a) Aprendizado de máquina supervisionado é o caso em que um algoritmo de *machine learning* calibra seus parâmetros usando dados alimentados por um analista, a partir disso o algoritmo ajusta o modelo e o melhora à medida que mais dados são coletados. O termo “aprendizado supervisionado” surge a partir da observação de que o analista guia, ou seja, supervisiona o algoritmo na calibração de parâmetros, fornecendo um conjunto de variáveis de entrada e saída claramente rotuladas ou variáveis previstas. Um exemplo de utilização desse tipo de aprendizado seria tentar prever o quanto o mercado irá se mover se houver um aumento repentino na inflação (JP Morgan, 2017).

b) Aprendizado de máquina não supervisionado é definido como um sistema que aprende sem precisar de assistência humana e dados “rotulados” para ensiná-lo, ou seja, o algoritmo procura encontrar estrutura nos dados, geralmente agrupando observações (Buchanan, 2019). Em finanças esse método de aprendizado pode ser usado na identificação de regimes históricos como regime de alta ou baixa volatilidade, regime de inflação crescente, entre outros, importante para alocação entre diferentes ativos e prêmios de risco. Outro uso dado a este método é o de entender o comportamento do consumidor e do comerciante. Um exemplo é o crédito bancário descoberto para que os banqueiros entendam melhor o que está acontecendo com esses indivíduos e quais podem ser as causas da situação (JP Morgan, 2017).

c) Aprendizado por reforço é o caso em que a conexão entre ações e recompensas é desconhecida e deve ser inferida a partir das interações do agente com o ambiente. Um conjunto de dados não rotulados é enviado a um algoritmo e, em seguida, o algoritmo escolhe uma ação para cada ponto de dados. Um humano pode então fornecer feedback (a parte supervisionada) que subsequentemente ajuda o algoritmo a aprender (Buchanan, 2019).

d) *Deep Learning* (DL) ou Aprendizado Profundo é usado no pré-processamento de conjuntos de *Big Data* não estruturados e analisa dados em várias camadas de aprendizado. Pode começar a fazê-lo aprender sobre conceitos mais simples e combiná-los para aprender sobre conceitos mais complexos e noções abstratas. *Deep learning* é uma forma de ML que usa algoritmos que funcionam em camadas inspiradas na estrutura do cérebro humano. Sua estrutura é chamada de redes neurais artificiais, e pode ser usada no aprendizado supervisionado, não supervisionado e por reforço (FSB, 2017). No setor financeiro, o modelo pode primeiro identificar algumas características simples que afetam negativamente o mercado, como uma quebra de momentum, um aumento na volatilidade, um declínio na liquidez, entre outros. (JP Morgan, 2017). O Quadro 2 a seguir mostra os tipos de aprendizados e exemplos de sua utilização no mercado financeiro.

Quadro 2 - Tipos de aprendizados e exemplos de uso

Tipos de aprendizado	Exemplos de uso
Supervisionado	Previsão da reação do mercado diante de um choque inflacionário
Não supervisionado	Identificação de padrões no comportamento do consumidor e do comerciante/ Identificação de regimes históricos (volatilidade, inflação, entre outros)
<i>Deep learning</i>	Identifica fatores que podem afetar negativamente o mercado

Fonte: Autoral, 2019.

Sendo assim, como observado por Hurwitz e Kirsch (2018), os diferentes tipos de processos de *machine learning* mostram-se como técnicas necessárias para melhorar a precisão de modelos preditivos os quais dependendo da natureza do problema a ser tratado há diferentes abordagens baseadas no tipo e volume de dados.

2.3 *Machine learning* no mercado financeiro mundial

Buchanan (2019) explica que nos últimos anos, uma variedade de desenvolvimentos tecnológicos contribuiu para que o setor financeiro pudesse explorar uma volumosa infraestrutura de dados não estruturados sobre mercados e consumidores. Esses dados são provenientes de várias fontes, incluindo aplicativos para consumidores, interações com clientes, metadados e outras fontes externas. Segundo a autora, o setor de serviços financeiros é um dos que mais gasta com serviços de IA e as razões para o aumento da adoção de *machine learning* pelo setor financeiro é a oportunidade de redução de custos, maior produtividade e melhor gerenciamento de riscos.

De acordo com FSB (2017), as instituições financeiras e fornecedores estão usando métodos de IA e ML para avaliar a qualidade do crédito, preços de mercado, contratos de seguros e para automatizar as interações dos clientes. As técnicas de ML estão otimizando capital escasso, assim como analisando impactos no mercado da negociação de grandes posições. Além disso, fundos de *hedge*, corretoras e outras empresas utilizam esta tecnologia para encontrar sinais de retornos maiores (e não correlacionados) e para otimizar as execuções das negociações.

O *Financial Stability Board* (2017), indica que *machine learning* vem sendo aplicado no setor financeiro como detector de sentimentos, em que as empresas de análise de dados de mídias sociais fornecem indicadores de sentimentos aos *players* de serviços financeiros como bancos, fundos de *hedge*, entre outros. Outro exemplo apresentado pelo mesmo estudo, vem do setor de seguros que utiliza *machine learning* para analisar dados complexos, e a partir disso reduzir seus custos e aumentar a lucratividade.

Os estudos de Buchanan (2019) e de FSB (2017) apontam três áreas específicas na indústria de serviços financeiros que atualmente estão sendo revolucionadas pela inteligência artificial, são elas: a detecção e conformidade de fraude; *chatbots* bancários, serviços de consultoria em robótica e negociação algorítmica.

a) Detecção de fraude e conformidade

À medida que o comércio eletrônico se tornou mais difundido, a fraude *online* também aumentou. Como efeito, segundo Buchanan (2019), os bancos americanos gastam mais de US\$ 70 bilhões a cada ano no combate à conformidade de fraude no setor financeiro.

Usando as técnicas de ML, os sistemas de detecção de fraude podem responder ativamente a novas ameaças de segurança potenciais ou reais. Usando ML, os sistemas dos

bancos podem detectar atividades ou comportamentos incomuns e sinalizá-los para investigação. A detecção de fraude de cartão de crédito é uma das aplicações mais bem sucedidas do ML, uma vez que o *machine learning* é usado para identificar padrões complexos e, assim destacar transações suspeitas potencialmente graves, levando a uma investigação detalhada (FSB, 2017).

Muitas empresas de serviços financeiros estão explorando alternativas de prevenção contra fraudes baseadas em *machine learning* como a *Mastercard* que lançou a tecnologia *Decision Intelligence (DI)* que diferente do modelo tradicional de prevenção não fica limitada a um conjunto predefinido de regras, ao invés disso, analisa padrões de compras históricas e o comportamento de gastos dos clientes para comparar e pontuar cada nova transação. O *NatWest* do Reino Unido também adotou uma solução de ML para detectar e evitar fraudes de redirecionamento que ocorre quando uma empresa é levada a pagar dinheiro na conta de um fraudador, ao invés de seu fornecedor pretendido (Buchanan, 2019).

b) Bancos *chatbots* e serviços de consultoria robótica

De acordo com Buchanan (2019), *chatbots* e *robo-advisors* baseados em *Natural Language Processing (NPL)*, habilidade dos computadores de compreender escrita e fala humanas, e algoritmos ML fornecem uma experiência personalizada, de conversação natural a usuários em diferentes domínios. Segundo a autora (tradução nossa), “Um *robo-advisor* é uma plataforma digital baseada em algoritmos que oferece consultoria financeira automatizada ou serviços de gerenciamento de investimentos.” O termo “conselheiro-robô” é relativamente comum no panorama financeiro, onde os consultores robóticos são algoritmos que calibram um portfólio financeiro para as metas e tolerância à riscos do usuário.

FSB (2017), aponta que os *chatbots* estão cada vez mais ajudando os clientes das instituições financeiras a tomar decisões, enquanto essas podem se beneficiar obtendo informações sobre seus clientes com base nessas interações clientes-*chatbots*. As instituições e reguladores financeiros asiáticos desenvolveram *chatbots* sofisticados, atualmente em uso, que ultrapassaram o desenvolvimento tardio em outros continentes, causados pela desatualizada armazenagem de dados dos clientes. O setor de seguros também explora o uso de *chatbots* para fornecer consultoria em tempo real.

Buchanan (2019) afirma que os *Chatbots* e interfaces de conversação são uma área em rápida expansão de investimento de risco e orçamento de atendimento ao cliente. Esta tecnologia está sendo utilizada pelos bancos para melhorar suas interfaces de autoatendimento como é o caso do *Bank of America* que lançou o *chatbot Erica* e está disponível por meio de bate-papo por voz ou texto por meio do aplicativo do banco e auxilia no gerenciamento de

finanças pessoais. O *JP Morgan* investiu no *COiN*, que analisa documentos e extrai dados em muito menos tempo que um humano.

Como dito por Martins (2019), presença desses robôs tem crescido exponencialmente nos últimos anos, em meados de 2017, os robo-advisors já administravam aproximadamente 200 bilhões de dólares ao redor do mundo e estimativas apontam que esse montante deve chegar a 2,2 trilhões até 2020.

Atualmente, o Reino Unido e a Alemanha dominam o crescimento no setor de consultoria de robótica na Europa. No entanto, os EUA ainda são considerados um importante centro do setor de consultoria de robótica, existem entre 98 e 126 serviços de *roboadvisory* na Europa, em comparação com cerca de 200 nos EUA. Robo-conselheiros têm o potencial de reduzir custos e aumentar a qualidade e a transparência do aconselhamento financeiro para os consumidores. (Rohner, Uhl, 2017, tradução nossa *apud* Buchanan, 2019).

(Rohner, Uhl, 2017 *apud* Buchanan, 2019) descrevem serviços de consultoria robótica em contextos de acesso e reequilíbrio de estratégias de investimento passivas e baseadas em regras, também implementação eficiente de uma alocação diversificada de ativos e vieses comportamentais. Eles consideram que, comparados aos conselhos tradicionais de investimento, os consultores robóticos podem economizar custos de até 4,4% ao ano para as instituições que os utilizam.

c) Negociação algorítmica

O comércio algorítmico também chamado de "Sistemas de negociação automatizada" tornou-se uma força dominante nos mercados financeiros globais. Trata-se da calibragem de regras comerciais a um programa que será usado em negociações e podendo ser definido como uma abordagem ao ML que aprende a estrutura dos dados e depois faz previsões para tomar decisões comerciais rápidas. Os seus benefícios incluem a capacidade de as negociações serem executadas com os melhores preços possíveis, maior precisão e menor probabilidade de erros, além de verificar automaticamente e simultaneamente múltiplas condições de mercado e reduzir erros causados por emoções humanas. Os alvos da negociação algorítmica são os fundos de *hedge*, casas comerciais proprietárias, agências comerciais proprietárias de bancos, corporações e os criadores de mercado da próxima geração (Buchanan, 2019).

No que diz respeito ao benefício relacionado a maior precisão e menor probabilidade de erros, Buchanan (2019) mostra que os algoritmos *Mosaic Smart Data* da Agência Espacial Européia estão sendo implantados agora para mitigar os negócios de “dedos gordos” em que o profissional acidentalmente pressiona a chave errada. Esses algoritmos podem ser implantados para analisar milhões de pontos de dados de negociações financeiras e,

recentemente, foram casos de alto perfil na *Samsung* e no *Deutsche Bank*. Os algoritmos também estão sendo adotados para detectar fraudes no setor de serviços financeiros.

A *Sentient Technologies*, com sede nos EUA, é uma empresa de IA que opera um fundo de *hedge* e desenvolveu um algoritmo que processa milhões de pontos de dados para encontrar padrões de negociação e tendências de previsão. Com base em trilhões de cenários comerciais simulados, os algoritmos da *Sentient* usam esses cenários para identificar e combinar padrões comerciais bem-sucedidos e criar novas estratégias reduzindo 1.800 dias de negociação para apenas alguns minutos. O *Sentient* chama suas estratégias comerciais de sucesso de “genes”, que são então testadas em negociações ao vivo. Aqui os genes evoluem autonomamente à medida que ganham experiência. O algoritmo da companhia norte americana *Kensho* processa milhões de pontos de dados de mercado para descobrir correlações e oportunidades de investimento (Buchanan, 2019).

O Quadro 3 a seguir mostra as três áreas específicas de serviços financeiros que utilizam *machine learning* no setor financeiro em diferentes instituições e países.

Quadro 3 - Áreas específicas de utilização de machine learning e instituições usuárias

Áreas	Instituições
Detecção de fraude e conformidade	<i>Mastercard, NatWest</i>
Bancos <i>chatbots</i> e serviços de consultoria robótica	<i>Bank of America</i>
Negociação algorítmica	<i>Sentient Technologies, Deutsche Bank</i>

Fonte: Autoral, 2019.


De acordo com o relatório da *Financial Stability Board* (2017), embora os dados sobre a adoção de inteligência artificial e *machine learning* em vários mercados sejam bastante limitados, essas tecnologias estão sendo ativamente empregadas em alguns segmentos do sistema financeiro. Além disso, FSB (2017) afirma que a utilização dessas tecnologias contribui para um sistema financeiro mais eficiente por suas características de processamento de grandes volumes de informações e diferentes tipos de processos de aprendizado.

2.4 *Machine learning* no mercado financeiro brasileiro

Em 2016, uma pesquisa realizada pela empresa britânica *Coleman Parkes Research* sobre maturidade digital no Brasil mostrou que as tecnologias digitais estão sendo amplamente utilizadas pelas instituições financeiras brasileiras focando, principalmente, no fornecimento de serviços de autoatendimento e na consistência do atendimento para os clientes em todos os canais. Esse estudo analisou especificamente a indústria de finanças, que está diante de mudanças significativas com a eclosão do fenômeno das *Fintechs*, dos conceitos de banco digital e de novas tecnologias como *Blockchain* (Capgemini, 2017).

Capgemini (2017) mostra que das 60 instituições que participaram da pesquisa, 62% afirmaram já usarem tecnologias digitais, em maior ou menor intensidade, para oferecer serviços de autoatendimento e uma experiência consistente aos clientes nos diferentes canais. Apenas 39% estão implementando tais tecnologias com o intuito de personalizar as experiências de vendas (FIGURA 5). A partir dos resultados da pesquisa é possível verificar que o foco das instituições financeiras é explorar as tecnologias digitais para melhorar a experiência dos clientes.

Figura 5 - Nível de uso das tecnologias digitais nas principais atividades




Fonte: Capgemini, 2017.

Com a grande quantidade de dados disponíveis em diversos canais, seria possível inferir que os próximos passos das instituições financeiras seria utilizar os métodos de análise sofisticados como o *machine learning* para gerar *insights* a partir dos dados coletados. Entretanto, Capgemini (2017) mostra que o uso da análise de dados (*analytics*) no setor financeiro é estrito, apenas 17% das empresas adotam tecnologias de *analytics* de forma significativa para qualificar as vendas potenciais, embora 23% já as utilizem parcialmente.

Apenas 13% das empresas estão utilizando amplamente a análise de dados para otimizar a formação de preços e 12% para criar ações de marketing personalizadas (FIGURA 6). A partir disso, constata-se a pouca exploração das organizações das tecnologias de análise de dados para gerar *insights* que contribuam com o crescimento dos negócios.


Figura 6 - Uso da análise de dados (analytics)



Fonte: Capgemini, 2017.

A maioria das organizações financeiras (63%) participantes do estudo concordam com a afirmação de que uma companhia toma melhores decisões operacionais com base na análise de dados (*analytics*), apesar de ainda não ser tão ampla a adoção dessa tecnologia (FIGURA 7). A pesquisa também revelou que 57% das organizações afirmam estar promovendo as mudanças necessárias e investimentos necessários para a transformação digital (Capgemini, 2017).

Figura 7 - Concordância com afirmações sobre atividades operacionais



Fonte: Capgemini, 2017.

De acordo com Capgemini (2017), a *analytics* está sendo utilizada, principalmente, para entender melhor as necessidades dos clientes, no entanto, também é necessário o uso analítico de dados e algoritmos, pois há significativa disponibilidade de dados e ainda pouco uso deles pelo setor financeiro brasileiro. O estudo mostra ainda que os bancos já estão explorando a transformação digital e na comparação com outros setores estão bem mais avançados em relação a esse processo, pois enxergam a transformação digital como importante fator de posicionamento competitivo e de facilitação da experiência de comunicação com o cliente.

Como demonstra um estudo realizado pela Federação Brasileira de Bancos (FEBRABAN), em 2018, com vinte bancos brasileiros ou que atuam no país, a análise de dados (*analytics*) e inteligência artificial figuram no topo dos investimentos realizados pelos bancos no Brasil. Das instituições pesquisadas, 80% destacaram que essa ferramenta recebeu recursos em 2018, em seguida vêm a inteligência artificial e computação cognitiva (73%), aplicadas, principalmente, para melhorar o relacionamento entre banco e consumidor. Esses investimentos nas ferramentas de comunicação e relacionamento com os clientes se refletiram no aumento expressivo das interações realizadas entre os bancos e os usuários por meio dos canais digitais. (Fosse; Biagini, 2019).

As interações via chats operados por profissionais de atendimento cresceram 364% em 2018, chegando a 138,3 milhões. Ainda mais impressionante foi a expansão de 2.585% nos atendimentos via chatbots – no qual a interação é automatizada por robôs que usam linguagem natural e se aperfeiçoam quanto mais são utilizados: em 2017 foram realizadas 3 milhões de interações via chatbots, enquanto em 2018 foram efetuadas 80,6 milhões. (Fosse; Biagini, 2019).

Fosse e Biagini (2019) apontam que esse tem sido um dos recursos nos quais os bancos mais têm aplicado as ferramentas de inteligência artificial e computação cognitiva para proporcionar ao usuário uma melhor experiência com as soluções e produtos bancários no país.

De acordo com a FEBRABAN (2019), os bancos brasileiros já oferecem serviços baseados em IA como *chatbots* para interagir com clientes e funcionários tirando dúvidas, realizando transações pelas redes sociais, reconhecimento de assinaturas em cheques, reconhecimento de fachada na abertura de conta de pessoa jurídica, abertura de contas digitais, oferta de serviços personalizados e segurança e combate a fraudes. Bancos como Bradesco, Banco do Brasil, Santander, Banco Original e Bannrisul são algumas das instituições que usam a tecnologia IBM *Watson* (plataforma de inteligência artificial da IBM) para atender os usuários em diferentes canais de atendimento ou em áreas de apoio interno (*backoffice*).

O banco Bradesco começou a utilizar a BIA (Inteligência Artificial do Bradesco) em 2016, com o objetivo de responder dúvidas de funcionários. Em 2017, passou a atender aos clientes reduzindo o tempo de espera de uma resposta, de minutos para segundos. Agora, o banco trabalha no desenvolvimento de seu próprio sistema de inteligência artificial para ser utilizado em paralelo ao da IBM. São 168 milhões de interações já feitas com inteligência artificial nos canais de atendimento do Bradesco desde a sua implementação em 2016. O banco Santander faz uso da tecnologia, no processo de *onboarding* (abertura de contas) digital, financiamentos e modelos de riscos de crédito. A utilização de IA reduz os custos de *backoffice*, pois as automações robóticas de processos estão levando a ganhos de quase 80% nos tempos de alguns fluxos. Dos cerca de 25,5 milhões de clientes do Santander, 12,7 milhões usam canais digitais, com serviços apoiados por IA, como os de segurança e antifraude. A assistente virtual do banco, *Sara*, atende internamente os 48 mil funcionários do banco. O Banco do Brasil realiza transações bancárias via *Whatsapp* e *Messenger*, do *Facebook*, por meio de um assistente virtual, com a inteligência artificial do *Watson* da IBM, e a troca de informação nas interações com clientes são criptografadas. (FEBRABAN, 2019).

Por sua vez, Martins (2019), foca na utilização de *robo-advisors*, que são prestadores de serviços de consultoria e administração de investimentos por meio de tecnologias baseadas em algoritmos por corretoras de valores brasileiras. Para ilustrar como essa tecnologia vem sendo utilizada no país, o autor elencou três corretoras que prestam serviços financeiros de investimentos com auxílio de sistemas automatizados de assessoria de valores mobiliários.

Martins (2019), mostra que os *robo-advisors* são utilizados na interação com o investidor e na determinação de seu perfil comportamental e de risco, a partir de questões envolvendo idade, renda e experiência com investimentos. Além do objetivo, do valor mensal

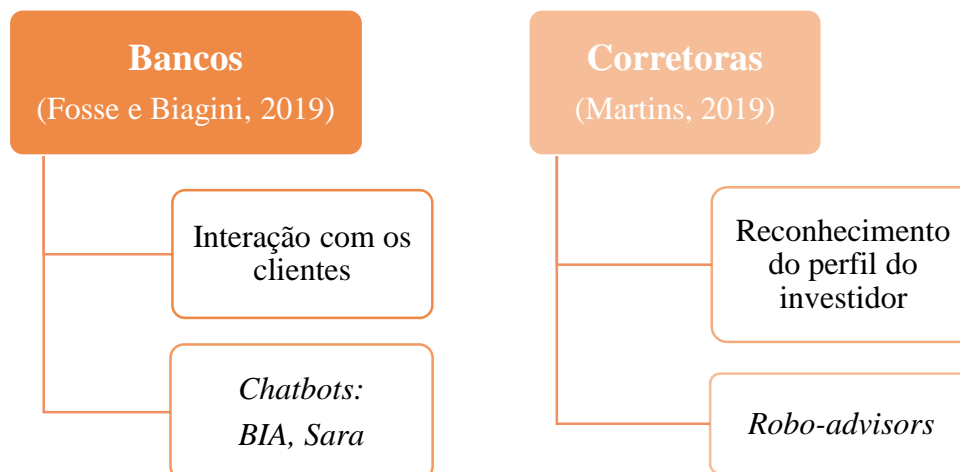
disponível para investir e do prazo do investimento, a partir das quais a plataforma indica a composição de carteira ideal para o investidor. Na prática, a automatização é utilizada para traçar o perfil do investidor, de modo a compor a carteira entre renda fixa e variável de maneira compatível. Entretanto, os ativos a serem adquiridos pelo investidor são administrados pela corretora que não se apoia em algoritmos para execução de ordens e elaboração de estratégias. Portanto, o serviço de *robo-advisor* é preponderantemente encontrado nesse caso na etapa de reconhecimento do perfil do investidor.

Outro uso verificado para os algoritmos são a comparação, seleção e monitoramento dos ativos que irão compor a carteira de investimentos do cliente. Nessa etapa, Martins (2019), aponta que o serviço prestado é híbrido, ou seja, conjuga-se a capacidade analítica dos robôs com a experiência profissional dos analistas. O robô atua no processamento de cálculos para alocar os ativos, monitorar e calcular o retorno do portfólio de seus clientes dia a dia. Nesse sentido, a corretora atua com um sistema de automatização para traçar o perfil dos clientes e, na gestão dos ativos, combinando a atuação de algoritmos com a humana.

Portanto, verifica-se um padrão de utilização de *robo-advisors* no Brasil: atuam na prestação de serviços de consultoria e administração de investimentos por meio de tecnologias baseadas em algoritmos em plataformas digitais. Nota-se uma tendência do uso de sistemas automatizados para definição do perfil de risco dos investidores e de uma abordagem híbrida na gestão propriamente dita da carteira de valores mobiliários. (Martins, 2019).

O Quadro 4 resume os exemplos de usos de *machine learning* na instituições financeiras no Brasil que foram abordados nesta seção.

Quadro 4 - Exemplos do uso de *machine learning* em instituições financeiras no Brasil



Fonte: Autoral, 2019.

3 METODOLOGIA DA PESQUISA

Este trabalho tem como objetivo investigar as hipóteses sobre o uso de *machine learning* pelas corretoras de valores brasileiras. A realização do levantamento de dados ocorreu por meio da aplicação de um formulário online às instituições financeiras do país.

Sendo assim, os tópicos a seguir apresentam: o enquadramento metodológico da pesquisa e as hipóteses investigadas sobre a adoção de *machine learning*. Ademais, é feita a descrição da amostra, suas limitações e dos resultados obtidos.

3.1 Enquadramento metodológico

Adotou-se a análise descritiva analítica de estudos estrangeiros sobre o uso de *machine learning* no setor financeiro, a fim de comparar com os resultados obtidos a partir de pesquisa realizada em campo com as corretoras brasileiras através de um questionário *online*.

3.2 Hipóteses investigadas

A pesquisa busca prospectar dados acerca do uso de *machine learning* pelas corretoras brasileiras. Nesse sentido, são testadas duas hipóteses: a primeira trata da adoção ou não de *machine learning* pelas corretoras e a segunda investiga como as empresas que o adotam utilizam essa tecnologia.

3.2.1 Primeira hipótese investigada

A pesquisa objetiva investigar a adoção dos processos de *machine learning* pelas corretoras de valores brasileiras, assumindo a hipótese de que as corretoras nacionais utilizam menos do que as corretoras americanas ou europeias os modelos de *machine learning*.

3.2.2 Segunda hipótese investigada

Outro ponto investigado na pesquisa são os usos atribuídos ao *machine learning* nas empresas que adotam esta tecnologia em suas operações.


3.3 Teste das hipóteses investigadas

Foi proposto um questionário *online* com 18 questões dividido em duas partes: a primeira busca traçar o perfil das corretoras com questões sobre experiência de mercado, regiões em que operam, ativos administrados, entre outras. Enquanto a segunda investiga a utilização da tecnologia de *machine learning* no dia a dia da empresa, com perguntas sobre a cultura de análise de dados da empresa, as operações em que é aplicada, os retornos obtidos com o uso de ML, entre outras.

3.4 Descrição da amostra

O Brasil possui cerca de 80 corretoras de valores registradas pela Comissão de Valores Mobiliários (CVM). Contudo, os resultados da pesquisa estão restritos por uma amostra de, aproximadamente, 5% da população, pois participaram da pesquisa apenas quatro empresas, onde era desejada uma amostra de, no mínimo, 10% (GRÁFICO 1). Isso ocorreu apesar das tentativas de contato com a Comissão de Valores Mobiliários (CVM) e a B3 para que estas reforçassem o pedido às empresas de participação na pesquisa. Porém, também não houve respostas das mesmas. Dessa forma, as conclusões do estudo podem ser prejudicadas pelo baixo número de respostas ao formulário que impede uma prospecção mais abrangente e acurada sobre o tema.

Gráfico 1 - Limitações da amostra da pesquisa



Fonte: Autoral, 2019.


4 RESULTADOS

A seguir serão apresentados os resultados obtidos com a amostra das corretoras de valores brasileiras sobre o uso de *machine learning* em suas operações.

Adotou-se como método para prospecção de dados a aplicação de um questionário em duas partes: a primeira com seis questões, identifica o perfil da corretora, e a segunda parte com doze questões, foca na utilização de *machine learning* e dos retornos alcançados com a sua utilização. O questionário foi enviado a 72 corretoras, as quais apenas 4 responderam ao mesmo. Os resultados obtidos com essa amostra foram os seguintes:

Com base em uma escala de 1 a 50 anos, o estudo relatou que 50% das empresas possuem de 21 a 30 anos de experiência no mercado, enquanto 25% possuem de 31 a 40 anos e 25% de 41 a 50 anos de experiência no mercado (GRÁFICO 2).


Gráfico 2 - Anos de experiência das corretoras no mercado de valores



Fonte: Autoral, 2019.

Todas as corretoras que participaram da pesquisa possuem suas matrizes (GRÁFICO 3), assim como a grande maioria dos seus clientes, localizadas na região sudeste do Brasil (GRÁFICO 4).

Gráfico 3 - Localização das corretoras participantes da pesquisa



Fonte: Autoral, 2019.

Gráfico 4 - Localização da maioria dos clientes das corretoras pesquisadas



Fonte: Autoral, 2019.

No que diz respeito aos ativos financeiros: 75% das corretoras são especializadas na venda e administração de ações, enquanto os 25% restantes trabalham com ações, títulos públicos, fundos de investimento, títulos privados, derivativos e opções (GRÁFICO 5).


Gráfico 5 - Ativos administrados pelas corretoras pesquisadas



Fonte: Autorial, 2019.

Quanto à utilização de inteligência artificial (IA), evidenciou-se que 50% das corretoras utilizam-na em suas atividades (GRÁFICO 6).


Gráfico 6 - Respostas sobre utilização de IA nas corretoras pesquisadas



Fonte: Autorial, 2019.

E destacaram, ainda, que utilizam IA para as operações (25%) e os outros 25% delas para análise de mercado, considerando apenas duas respostas (GRÁFICO 7).

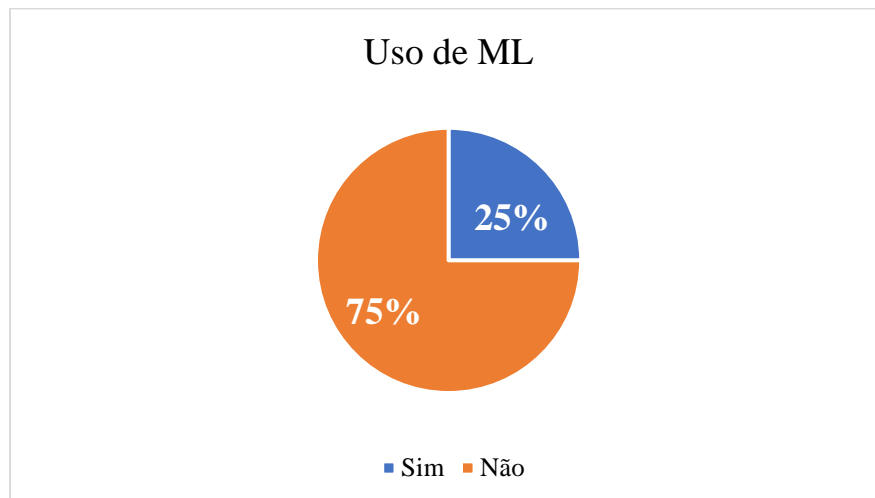
Gráfico 7 - Como as corretoras utilizam a inteligência artificial



Fonte: Autoral, 2019.

Referente ao uso de *machine learning*, 75% das corretoras não o empregam em suas operações (GRÁFICO 8).

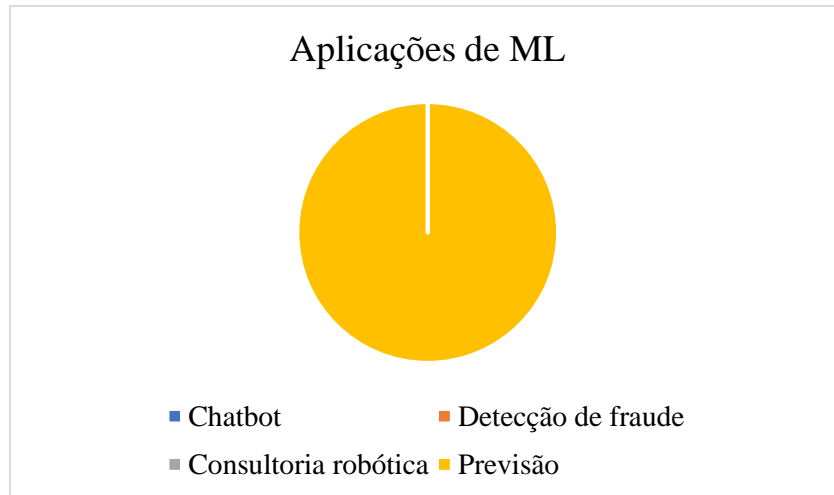
Gráfico 8 - Corretoras pesquisadas que utilizam ML



Fonte: Autoral, 2019.

Quanto às empresas que utilizam ML (25%), todas o fazem para previsões de tendências dos mercados em que operam (GRÁFICO 9).


Gráfico 9 - Utilização de ML pelas corretoras pesquisadas



Fonte: Autoral, 2019.

Metade das corretoras discordam da afirmação de que o uso de *machine learning* contribui para potencializar as operações da empresa (GRÁFICO 10).


Gráfico 10 - Corretoras pesquisadas que afirmam que ML contribui para potencializar suas operações



Fonte: Autoral, 2019.

Enquanto isso, a metade que concorda, aponta que o aumento de receita, a redução de risco nas operações (50%) e o aumento da produtividade (50%) foram potencializados pelo uso de ML (GRÁFICO 11).


Gráfico 11 - Operações potencializadas pelo uso de ML



Fonte: Autorial, 2019.

Metade das corretoras estudadas consideram o aprimoramento das suas operações elevado ao utilizarem *machine learning* (GRÁFICO 12), enquanto a outra metade considera o nível desse aprimoramento mediano (considerando duas respostas).

Gráfico 12 - Nível de aprimoramento das operações das corretoras pesquisadas



Fonte: Autorial, 2019.

As corretoras que afirmam possuírem uma cultura de análise de dados (25%), utilizam ML para esse fim (GRÁFICO 13).


Gráfico 13 - Corretoras pesquisadas que possuem uma cultura de análise de dados



Fonte: Autoral, 2019.

Apenas uma empresa declarou utilizar *machine learning* em suas operações. E a partir de uma escala que vai de 0 a 100%, a corretora afirmou que o uso de ML aumentou a velocidade da análise de dados financeiros de 0 a 10% (GRÁFICO 14).


Gráfico 14 - Aumento da velocidade da análise de dados financeiro usando ML



Fonte: Autoral, 2019.

E o uso dessa tecnologia, ainda, aumentou de 11% a 20% o retorno de receita da empresa, considerando um escala similar (GRÁFICO 15).

Gráfico 15 - Aumento de receita da empresa que usa ML



Fonte: Autoral, 2019.

Das empresas que não utilizam ML, todas afirmam que a adoção da tecnologia ainda está sob análise (GRÁFICO 16).


Gráfico 16 - Motivos de as corretoras pesquisadas não utilizarem ML



Fonte: Autoral, 2019.

Porém, 100% afirmam ter a intenção de utilizá-la. As corretoras apontam que estão realizando estudos de retorno da utilização dessa tecnologia (66,7%) ou contratando pessoal especializado (33,3%) como um esforço para a utilização de ML (GRÁFICO 17).

Gráfico 17 - Esforços para adoção de ML pelas corretoras pesquisadas



Fonte: Autorial, 2019.

4.1 Primeira hipótese investigada

Como pode ser observado na descrição dos resultados, das quatro corretoras participantes do estudo, apenas uma empresa declarou utilizar *machine learning* em suas operações. A empresa em questão afirma que o uso da tecnologia potencializou suas operações ao contribuir para o aumento da receita da empresa, redução dos riscos nas operações e aumento da produtividade. A corretora declarou ainda que o nível de aprimoramento gerado pelo uso de ML vai de mediano à elevado.

4.2 Segunda hipótese investigada

Os resultados referentes aos usos praticados pela corretora que declara utilizar *machine learning* em suas operações mostram que este é utilizado principalmente na previsão de tendências do mercado financeiro. A corretora que a utiliza afirma um aumento da velocidade da análise de dados financeiros entre 0% e 10%. Além disso há um aumento da receita da empresa entre 11% e 20%. Por fim, a empresa indica um esforço, com a contratação de pessoal especializado, a fim de expandir a utilização da tecnologia.

5 CONSIDERAÇÕES FINAIS

Este tópico apresenta as conclusões baseadas nos resultados obtidos com a pesquisa e recomendações para futuros trabalhos sobre o tema.

5.1 Conclusões

Machine learning é uma subcategoria de IA que permite que um sistema aprenda a partir de dados, e não através de programação explícita. (Hurwitz; Kirsch 2018). Com efeito, os autores também afirmam que o aprendizado de máquina tornou-se um dos tópicos mais importantes nas organizações que buscam inovação para impulsionar seus negócios a um novo nível de conhecimento. Dessa forma, Buchanan (2019) diz que as razões para o aumento da adoção de *machine learning* pelo setor financeiro é a oportunidade de redução de custos, maior produtividade e melhor gerenciamento de riscos.

De acordo com o relatório da *Financial Stability Board* (2017), embora os dados sobre a adoção de inteligência artificial e *machine learning* em vários mercados sejam bastante limitados, essas tecnologias estão sendo ativamente empregadas em alguns segmentos do sistema financeiro. Buchanan (2019) aponta três áreas específicas na indústria de serviços financeiros global que atualmente estão sendo revolucionadas pela IA, são elas: a detecção e conformidade de fraude; *chatbots* bancários e serviços de consultoria em robótica e negociação algorítmica.

No Brasil, de acordo com Capgemini (2017), a *analytics* está sendo utilizada, principalmente, para entender melhor as necessidades dos clientes. No entanto, ainda há necessidade do uso analítico de dados e algoritmos, pois há significativa disponibilidade de dados e pouco uso deles pelo setor financeiro brasileiro. O estudo mostra ainda que os bancos já estão explorando a transformação digital e na comparação com outros setores estão bem mais avançados em relação a esse processo, pois enxergam a transformação digital como importante fator de posicionamento competitivo.

Sendo assim, motivado pelo aumento da utilização da tecnologia de *machine learning* no setor financeiro global, buscou-se prospectar dados sobre o uso ML pelas corretoras de valores brasileiras. O objetivo foi investigar se a tecnologia é utilizada ou não pelas corretoras e, se sim, qual a finalidade deste uso. Para isso, revisou-se a literatura sobre o tema que apresentaram seus conceitos, tipos de aprendizagem e como ML se relaciona com

inteligência artificial e *Big Data*. Foi visto também os seus tipos de aprendizagem e usos feitos por diversas instituições financeiras em diferentes países.

Dessa forma, investigou-se as hipóteses de utilização de *machine learning* pelas corretoras brasileiras e as áreas de aplicação nas empresas que a utiliza. Para a prospecção de dados foi disponibilizado um formulário *online* para 72 corretoras de valores do país que identificou o perfil das empresas e os usos atribuídos ao ML. Foram obtidas quatro respostas, com as quais foi possível chegar a conclusões prévias. Nota-se que a tecnologia vem sendo aplicada pelas empresas. Quanto à finalidade de seu uso, ML é aplicado para previsão de tendências de mercado e foi apontado como relevante para aumento da receita e produtividade das operações da empresa. Contudo, há restrições quanto a estas conclusões, por causa do tamanho limitado da amostra.

O estudo aponta que as técnicas de *machine learning* são pouco exploradas para operações financeiras no Brasil. No entanto, com base na literatura acerca de sua utilização em outros países, e uma vez que há um grande volume de dados ainda inexplorado pelas instituições financeiras do país (Capgemini, 2017), a tecnologia tem grande potencial de utilização.

Sendo assim, faz-se necessária a ampliação de estudos sobre o assunto para orientar as instituições financeiras do país na adoção dessa tecnologia, uma vez que auxiliaria no entendimento acerca das vantagens e desvantagens de utilizá-la.

5.2 Recomendações

Recomenda-se a investigação das técnicas de *machine learning* mais utilizadas no Brasil e no mundo, e se podem tornar modelos mais ou menos eficientes para operações financeiras tendo em vista os potenciais de uso dessa tecnologia.

Faz-se necessário destacar que o questionário utilizado foi elaborado para este estudo específico e deve ser melhorado por trabalhos futuros sobre o tema. Como pode ser visto nas perguntas 3 e 4 do questionário (APÊNDICE A), que podem induzir as respostas das empresas pesquisadas por já considerar que há benefícios na aplicação de *machine learning* nas operações da empresa.

REFERÊNCIAS

- ALLEN, Alex; BERSET, Jerome. **Introduction to Machine Learning Part 1**. Limited. London, United Kingdom: EFG Asset Management (UK), 2018. Disponível em: <https://www.newcapitalfunds.com/ResearchInsights/LatestInsightsDetail/tabid/529/Article/254/introduction-to-machine-learning-part-1.aspx>. Acesso em: 13 jun. 2019.
- BUCHANAN, Bonnie G. **Artificial intelligence in Finance**. Abril 2019. Washington, Estados Unidos. Zenodo. Disponível em: <http://doi.org/10.5281/zenodo.2612537>. Acesso em: 13 jun. 2019.
- CAPGEMINI. **Pesquisa sobre Maturidade Digital no Brasil para o setor de Serviços Financeiro**. Reino Unido. 2017. Disponível em: <https://www.capgemini.com/br-pt/resources/maturidade-digital-no-brasil/#>>. Acesso em: 13 jun. 2019.
- COZMAN, Fabio G. **Inteligência Artificial: uma utopia, uma distopia**. Teccogs: Revista Digital de Tecnologias Cognitivas, TIDD | PUC-SP, São Paulo, n. 17, p. 32-43, jan-jun. 2018.
- FEBRABAN. **Bancos miram parcerias e expansão para a inteligência artificial**. FEBRABAN. Setembro de 2019. Disponível em: <https://portal.febraban.org.br/noticia/3356/pt-br/>>. Acesso em: 15 out. 2019.
- FINANCIAL STABILITY BOARD. **Artificial intelligence and machine learning in financial services: Market developments and financial stability implications**. FSB, 2017. Disponível em: <https://www.fsb.org/2017/11/artificial-intelligence-and-machine-learning-in-financial-service/>>. Acesso: 13 jun. 2019.
- FOSSE, Gustavo; BIAGINI, Sergio. **Pesquisa FEBRABAN de Tecnologia Bancária 2019**. São Paulo. 2019. Federação Brasileira de Bancos. Deloitte. Disponível em: <https://portal.febraban.org.br/pagina/3106/48/pt-br/pesquisa>>. Acesso em: 15 nov. 2019.
- HURWITZ, Judith; KIRSCH, Daniel. **Machine Learning For Dummies®**, IBM Limited Edition Published by John Wiley & Sons, Inc. 2018. *E-book*. Disponível em: <https://www.ibm.com/analytics/machine-learning>. Acesso em: 13 jun. 2019.
- HUSSAIN, Mubashir; MANHAS, Jatinder. **Artificial Intelligence for Big Data: Potential and Relevance**. International Academy of Engineering and Medical Research, 2016 Volume-1, ISSUE-1. Published Online October-November 2016 in IAEM.
- KOLANOVIC, Marko; KRISHNAMACHARI, Rajesh T. **Big Data and AI Strategies: Machine Learning and Alternative Data Approach to Investing Quantitative and Derivatives Strategy**. Maio 2017. JP Morgan Chase & Co.
- MARTINS, Ciro Silva. **Robo-advisors e os deveres fiduciários dos assessores de valores mobiliários no Brasil**. Rio de Janeiro. 2019.
- McCARTHY, John; MINSKY, Marvin L.; ROCHESTER, Nathaniel; SHANNON, Claude E. **A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence**. August 31, 1955. AI Magazine Volume 27 Number 4 (2006). Disponível em:

<<https://jmc.stanford.edu/articles/dartmouth.html>>. Acesso em: 13 jun. 2019.

TURING, A. M. **Computing Machinery and Intelligence**. 1950. *Mind* 49: 433-460.

WORLD ECONOMIC FORUM. **The New Physics of Financial Services: Understanding how artificial intelligence is transforming the financial ecosystem**. WEF: Agosto, 2018. Disponível em: <https://www.weforum.org/report/the-new-physics-of-financial-services-how-artificial-intelligence-is-transforming-the-financial-ecosystem>. Acesso em: 15 nov. 2019.

APÊNDICE A – QUESTIONÁRIO DE PESQUISA**PARTE I**

1. Sua empresa possui quantos anos de experiência no mercado financeiro?

1 – 5 6 – 10 11 - 20 21 – 30 31 - 40 41 - 50

2. Em que região do Brasil localiza-se a matriz da sua empresa?

Centro-Oeste Nordeste Norte Sudeste Sul

3. Em que região a maioria dos seus clientes concentra-se?

Centro-Oeste Nordeste Norte Sudeste Sul

4. Sua empresa é especializada na venda e administração de que tipos de ativos financeiros?

Títulos públicos Ações Fundos de investimento Títulos privados

5. Sua empresa utiliza inteligência artificial nas suas atividades?

Sim Não

6. Se sim, como a IA é utilizada?

Análise de mercado Comunicação com cliente Segurança do cliente Outro

PARTE II

1. Sua empresa utiliza machine learning?

Sim Não

2. Se sim, qual a finalidade do uso de machine learning?

Chatbot Detecção de fraude Consultoria robótica Previsão Outro

3. O uso de machine learning contribui para a potencialização das operações da empresa?

Sim Não

4. Se sim, de que forma são potencializadas?

Redução de custos Aumento da produtividade Aprimoramento do gerenciamento de riscos Outro

5. Qual o nível desse aprimoramento?

Baixo Mediano Elevado

6. Sua empresa possui uma cultura de análise de dados?

Sim Não

7. Se sim, a tecnologia de machine learning é utilizada nessa análise?

Sim Não

8. O uso de machine learning aumenta em quanto a velocidade da análise de dados?

0 – 10% 11% – 20% 21% - 30% 31% - 40% 41% - 50%

51% - 60% 61% - 70% 71% - 80% 81% - 90% 91% - 100%

9. A utilização dessa tecnologia aumenta em quanto o retorno da empresa?

0 – 10% 11% – 20% 21% - 30% 31% - 40% 41% - 50%

51% - 60% 61% - 70% 71% - 80% 81% - 90% 91% - 100%

10. Há a intenção de utilização dessa tecnologia?

Sim Não

11. Se não utiliza machine learning, qual o motivo?

Desconhecimento Ainda sob análise Outro

12. Se sim, que esforço está sendo feito por sua empresa para adoção dessa tecnologia?

Estudo de retorno Contratação de pessoal especializado Outro
