



Universidade de Brasília - UnB

Faculdade de Administração, Economia e Contabilidade - FACE

Departamento de Ciências Contábeis e Atuariais - CCA

Curso de Ciências Contábeis

Coordenação de Pesquisa

Lucas Brandão Neves

**Uma avaliação da capacidade de previsão de modelos de aprendizagem
automática para índices de ações**

Brasília

2018

Professora Doutora Márcia Abrahão Moura

Reitora da Universidade de Brasília

Professor Mestre Enrique Huelva

Vice-Reitor da Universidade de Brasília

Professora Doutora Cláudia da Conceição Garcia

Decana de Ensino de Graduação

Professora Doutora Helena Eri Shimizu

Decano de Pesquisa e Pós-Graduação

Professor Doutor Eduardo Tadeu Vieira

Diretor da Faculdade de Economia, Administração e Contabilidade

Professor Doutor José Antônio de França

Chefe do Departamento de Ciências Contábeis e Atuariais

Professor Doutor César Augusto Tibúrcio Silva

Coordenador de Pós-Graduação do curso Ciências Contábeis

Professor Doutor Paulo Augusto Pettenuzzo de Britto

Coordenador de Graduação do Curso de Ciências Contábeis - Diurno

Professor Mestre Elivânio Geraldo de Andrade

Coordenador de Graduação do curso de Ciências Contábeis - Noturno

Lucas Brandão Neves

Uma avaliação da capacidade de previsão de modelos de aprendizagem automática para índices de ações

Trabalho de Conclusão de Curso apresentado ao Departamento de Ciências Contábeis e Atuariais da Faculdade de Economia, Administração e Contabilidade da Universidade de Brasília, como requisito à conclusão da disciplina Pesquisa em Ciências Contábeis e obtenção do grau de Bacharel em Ciências Contábeis.

Orientador: Prof. Ph.D. José Luiz Barros Fernandes.

Brasília
2018

NEVES, Lucas Brandão.

Uma avaliação da capacidade de previsão de modelos
de aprendizagem automática para índices de ações

34 páginas

Monografia - Faculdade de Economia, Administração e
Contabilidade da Universidade de Brasília. Departamento de
Ciências Contábeis e Atuariais.

Universidade de Brasília - UnB
Faculdade de Economia, Administração e Contabilidade - FACE
Departamento de Ciências Contábeis e Atuariais - CCA
Bacharelado em Ciências Contábeis

Lucas Brandão Neves

**Uma avaliação da capacidade de previsão de modelos de aprendizagem
automática para índices de ações**

Trabalho de Conclusão de Curso apresentado ao Departamento de Ciências Contábeis e Atuariais da Faculdade de Economia, Administração e Contabilidade da Universidade de Brasília como requisito para obtenção do título de Bacharel em Ciências Contábeis.

Orientador: Prof. Dr. José Luiz Barros Fernandes

BANCA EXAMINADORA:

Prof. Ph. D. José Luiz Barros Fernandes - Orientador

CCA/FACE/UNB

Prof. Dr. José Alves Dantas - Examinador

CCA/FACE/UNB

“Quando tomamos uma decisão, enxergamos apenas o que queremos, ignoramos possibilidades e minimizamos riscos que enfraquecem nossas esperanças. O pior é que muitas vezes somos confiantes mesmo quando estamos errados.”

-Daniel Kahneman

AGRADECIMENTOS

Gostaria de agradecer primeiramente a Deus pelo Dom da vida. Agradecer aos meus pais e minha irmã pela educação, zelo, carinho e principalmente pela paciência que tiveram comigo ao longo desta minha jornada. Sem eles, eu não teria chegado aonde cheguei. Também gostaria de agradecer a minha namorada, Sabrina, pela paciência, companheirismo e o amor a mim dedicado por todo este tempo. Ao meu cachorro, Ted, pelos momentos de alegria e de descontração ao longo deste trabalho. Um muito obrigado também a Ana Carolina Martins, pela amizade e principalmente pela ajuda ao longo do curso.

RESUMO

O objetivo deste trabalho foi analisar a capacidade das redes neurais artificiais na previsão de preços, retorno e risco dos principais índices de ações de países desenvolvidos e em desenvolvimento. Para isso, fizemos o uso dos algoritmos de aprendizagem de máquina: *Levenberg-Marquardt*, *Bayesian Regularization* e *Scaled Conjugate Gradient*, atrelados aos dados diários e semanais dos índices de ações do período entre 8 de janeiro de 2010 e 31 de dezembro de 2017. Os modelos apresentaram resultados satisfatórios na previsão de preço e risco histórico, notadamente: *Levenberg-Marquardt* e *Bayesian Regularization*. Por outro lado, retorno e risco implícito apresentaram características de passeio aleatório, tanto em países emergentes quanto desenvolvidos, reforçando a hipótese de eficiência do mercado. Efeitos nos retornos de padrões comportamentais não foram identificados pelos modelos.

Palavras-chaves: redes neurais artificiais, previsão, mercados emergentes, mercados desenvolvidos.

ABSTRACT

The objective of this work was to analyze the artificial neural networks' ability to predict the prices, return and risk of the main indices of developed and developing countries. For this, we made use of machine learning algorithms: Levenberg-Marquardt, Bayesian Regularization and Scaled Conjugate Gradient; linked to the daily and weekly data of stock indexes for the periods from January 8, 2010 to December 31, 2017. The models presented satisfactory results in the historical price and risk forecast, notably Levenberg-Marquardt and Bayesian Regularization. On the other hand, return and implicit risk presented Random Walk characteristics, both in emerging and developed countries, reinforcing the hypothesis of Market efficiency, Effects on behavioral pattern returns were not identified by models.

Keywords: Artificial Neural Networks. Prediction. Emerging Markets. Developed Markets.

SUMÁRIO

1 INTRODUÇÃO	10
2 REFERENCIAL TEÓRICO.....	11
2.1 Eficiência de mercado	11
2.2 Finanças comportamentais	13
2.3 Mercado financeiro em países desenvolvidos e emergentes	14
2.4 Aprendizagem automática (<i>machine learning</i>)	15
2.5 O mercado financeiro e a tecnologia da informação.....	17
3 METODOLOGIA.....	19
3.1 Dados.....	19
3.2 Algoritmos	21
3.2.1 <i>Levenberg-Marquardt</i> (LM).....	21
3.2.2 <i>Bayesian Regularization</i> (BR)	21
3.2.3 <i>Scaled Conjugate Gradient</i> (SCG).....	22
3.36 Estatísticas de análise	22
4 ANÁLISE DOS RESULTADOS	24
4.1 Índices mundial e de países emergentes.....	24
4.2 Média dos resultados dos países emergentes e dos países desenvolvidos	25
4.3 Resultado: dados semanais	27
5 CONCLUSÃO.....	29

1 INTRODUÇÃO

Devido ao avanço tecnológico, especialmente em meados dos anos 2000, o uso de computadores aliados a bases de dados cada vez mais complexas tem se tornado cada vez mais frequente. Basicamente, a nossa vida está rodeada pela tecnologia, por meio de computadores, celulares, televisão. Até mesmo na medicina o uso da tecnologia tem se mostrado cada vez mais presente.

No âmbito das finanças não poderia ser diferente. Hoje em dia, uma pessoa que mora no Brasil consegue investir diretamente de sua casa em uma empresa listada na bolsa de valores americana, devido ao avanço da tecnologia e da rapidez com que a informação é transmitida.

Machine learning ou aprendizagem automática consiste em algoritmos computacionais que buscam o reconhecimento de padrões em bases de dados cada vez mais densas e complexas, valendo-se do avanço na capacidade de processamento dos computadores. O uso da aprendizagem automática tem se tornado cada vez mais frequente em finanças, na tentativa de prever possíveis resultados de ações, de *Exchange Traded Funds* (ETF) e de índices.

A aprendizagem automática pode ser usada para examinar a mudança nos preços, utilizados para estratégias de negociação e também para avaliar o desempenho e as exposições de risco (RODRIGUES; RIVEIRO, 2006, p. 12). Liew e Mayster (2017) examinaram três algoritmos de aprendizagem automática populares para prever os retornos dos ETF e tiveram como conclusão que os algoritmos utilizados conseguem prever mudanças de preços no horizonte de dez a sessenta dias.

O presente trabalho visa a avaliar a capacidade de previsão de modelos de aprendizagem automática para risco e retorno de índices de ações, tanto de países desenvolvidos quanto de emergentes. Para isso, fez-se necessário o levantamento dos dados históricos dos principais índices de ações de países desenvolvidos e em desenvolvimento e o uso de três algoritmos de aprendizagem automática: *Levenberg-Marquardt*, *Bayesian Regularization* e *Scaled Conjugate Gradient*.

2 REFERENCIAL TEÓRICO

2.1 Eficiência de mercado

Em 1965, Fama desenvolveu a Hipótese dos Mercados Eficientes (HME). Essa hipótese requer, além da utilidade normal de maximização dos lucros dos agentes econômicos, que os agentes tenham expectativas racionais e sempre atualizem as suas expectativas imediatamente com a chegada de novas informações.

Fama classificou mercado eficiente como aquele em que o preço dos ativos negociados sempre reflete integralmente as suas informações disponíveis. Em outros termos, a eficiência de mercado está vinculada ao preço que determinado ativo tem devido às suas informações disponíveis e que impossibilita o investidor de obter ganho anormal, ou seja, um retorno superior ajustado ao seu risco.

Ainda em seu artigo, Fama (1970) propôs três formas de eficiência de mercado e, para cada uma, apresentou um tipo diferente de teste para identificar a sua eficiência.

A primeira, chamada de eficiência fraca, utiliza como informação os preços do passado. E, com ele, o investidor não consegue obter retornos anormais apenas com a análise dos preços passados, pois apenas com essa informação não há dados úteis ou relevantes para conseguir retornos excelentes.

A segunda forma, chamada de eficiência semiforte, abarca não apenas o comportamento passado do ativo, mas a forma como as informações públicas podem influenciá-lo. Assim como na eficiência fraca, o investidor também não consegue obter um ganho anormal apenas com as informações públicas, pois esta seria rapidamente incorporada ao preço do ativo, pois, uma vez pública, a informação está disponível para todos os investidores.

Por fim, a última eficiência, também chamada de eficiência forte, traz consigo não apenas a informação pública, mas a informação privilegiada ou privada, e, assim como as demais, o investidor não consegue obter um ganho anormal com esse tipo de informação, pois o mercado tende a ajustar o preço do ativo como defendido pelas finanças tradicionais.

Em complemento a Fama, Alcântara (1980) propôs três pressupostos básicos à teoria de mercado eficiente na qual se apoiam: o primeiro deles é que todo investidor possui as mesmas informações, relacionadas ao preço, ao risco e ao retorno dos ativos;

no segundo, presume-se que não existem custos transacionais; e, no terceiro, considera-se também que os impostos não influenciam os investimentos.

Já em pesquisas mais recentes, Forti, Peixoto e Santiago (2009) afirmam que a eficiência não ocorre de forma natural, ou seja, ela é a ação dos agentes que, ao buscar maiores ganhos com as negociações, acabam contribuindo para a eficiência do mercado.

Martineau (2018), em seu artigo *The evolution of market price efficiency around earnings news*, aplicou o teste de eficiência semiforte proposto por Fama (1970), para verificar a velocidade com que uma informação sobre o lucro é publicada e incorporada ao preço do ativo e se isso tornou o mercado mais eficiente. Como conclusão, Martineau (2018) afirmou que os mercados incorporaram todas as notícias de forma rápida e, por isso, o mercado tem se tornado mais eficiente.

Em finanças tradicionais, o propulsor de risco e retorno foi Markowitz, com a teoria da carteira, ou teoria do portfólio, com o artigo *Portfolio selection* (1952), no qual o risco de um ativo é calculado pelo seu desvio-padrão. Markowitz afirma que o risco de um ativo isolado é diferente se esse mesmo ativo é incluído em uma carteira.

A teoria de Markowitz mostrou que, à medida que o investidor diversifica a sua carteira, escolhendo ativos com correlação baixa ou negativa, ele consegue reduzir ou até eliminar – ao menos em teoria – o risco diversificável (risco não sistemático), consequentemente melhorando o seu retorno.

Tomando como base a teoria de carteiras do Markowitz, o *Capital Asset Pricing Model* (CAPM) proposto por Scholes, Jensen e Fischer (1972) propôs a taxa de retorno de um determinado ativo frente a uma carteira de mercado diversificada. O modelo considera a sensibilidade de determinado ativo ao risco não diversificável, conhecido como risco sistêmico. De acordo com o CAPM, o custo do capital corresponde à taxa de rentabilidade exigida como compensação pelo risco de mercado.

Em um mercado competitivo, o prêmio de risco varia proporcionalmente ao risco não diversificável. Na sua forma simples, o modelo prevê que o prêmio de risco esperado, dado pelo retorno esperado acima da taxa livre de risco, é proporcional ao risco não diversificável.

Uma medida aceita para o risco é a volatilidade, ou seja, a magnitude que o retorno de um ativo varia através de determinados períodos. O retorno é o ganho que um investidor espera por aceitar um determinado risco.

2.2 Finanças comportamentais

As chamadas finanças comportamentais surgiram por volta de 1980, a fim de quebrar os paradigmas das finanças tradicionais, por intermédio de estudos sobre o comportamento e a irracionalidade dos investidores, além de explicar as suas decisões financeiras. As finanças tradicionais muitas vezes não conseguiram explicar o motivo por que um determinado ativo valorizava ou perdia o seu valor, além de, em diversos casos, não compreender o motivo pelo qual os investidores investiam em determinada ação.

O artigo de referência, que trouxe luz à questão comportamental do indivíduo, foi o *Prospect theory: an analysis of decision under risk*, de Kahneman e Tversky (1979), com a sua teoria do prospecto. De acordo com a teoria, os indivíduos tomam as suas decisões em duas fases distintas. Na primeira, o problema é editado de acordo com os seus princípios heurísticos e as regras que regem as suas tomadas de decisões. Como consequência, na segunda fase, a partir da edição dos prospectos, o indivíduo atribui valores para cada decisão e escolhe, assim, a alternativa de maior valor para ele.

Olsen (1998) afirma que as finanças comportamentais não tentam definir o comportamento racional ou irracional, mas, sim, entender e predizer os processos de decisão psicológicos que implicam a sistemática dos mercados financeiros. De acordo com Ricciardi e Simon (2000), as finanças comportamentais visam a explicar e compreender os padrões de raciocínio dos investidores, incluídos os seus processos emocionais e o grau em que influenciam essas tomadas de decisões.

Conforme afirmado por Kimura, Basso e Krauter (2006, p. 44)

O comportamento humano é influenciado por diversos aspectos psicológicos que podem distorcer a identificação e a percepção dos fatos. Isso leva a uma decisão baseada em julgamentos individuais, nos quais a racionalidade imposta pela teoria da utilidade esperada pode não ser obedecida.

Assim, as finanças comportamentais vieram, portanto, para auxiliar e explicar as chamadas anomalias de mercado, como, por exemplo, o efeito de janeiro proposto por Wachtel (1942), as bolhas financeiras de Smith & Suchanek (1988), o otimismo e o pessimismo, a aversão à perda citado por Odean (1998), entre muitas outras anomalias encontradas por meio de estudos de mercado que acabam distorcendo a percepção dos fatos por parte dos investidores.

Em finanças comportamentais, a aversão ao risco é a relutância de um investidor em aceitar um negócio que apresenta um retorno incerto. É a hesitação de uma pessoa em concordar com uma situação com uma recompensa desconhecida, em vez de outra situação com uma recompensa mais previsível, mas, possivelmente, com um retorno esperado menor.

Hugonnier e Morellec (2007) demonstraram que a aversão ao risco fornece um incentivo para os investidores atrasarem o investimento e isso reduz, de forma significativa, o seu retorno. Eckel e Grossman (2011) fizeram um experimento laboratorial a respeito da aversão ao risco, comparando homens e mulheres, e chegaram à conclusão de que as mulheres são mais avessas ao risco do que os homens.

Aversão à perda e aversão ao risco não são a mesma coisa. Em situações de perda, frequentemente as pessoas aceitam o risco de perder principalmente quando existe a chance de não “concretizar” a perda. No que diz respeito aos ganhos, as pessoas são avessas ao risco, no entanto diante da possibilidade de perder são avessas à perda.

De acordo com Köbberling e Wakker (2005), o homem sente muito mais a dor da perda do que os benefícios gerados pelos ganhos realizados. Assim, para evitar que essas perdas ocorram, o ser humano é capaz de assumir riscos que a minimizam, por isso o chamado “aversão a perdas”. Com relação aos ganhos, o homem prefere a certeza, ou seja, é avesso aos ganhos.

2.3 Mercado financeiro em países desenvolvidos e emergentes

A expressão *países desenvolvidos* é utilizada para designar os países que possuem altos níveis de desenvolvimento social, cultural e, principalmente, econômico. Já a expressão *países emergentes* é usada para descrever países que possuem um padrão de vida variando entre baixo e médio e a sua economia está em desenvolvimento.

No âmbito do mercado financeiro, esses dois conceitos também se aplicam. Países desenvolvidos possuem um mercado financeiro mais desenvolvido, com um volume maior de operações e de empresas listadas na bolsa. Para países em desenvolvimento, os volumes de operações são inferiores, não possuem um mercado muito estruturado e não apresentam um grande volume de empresas listadas em sua bolsa.

De acordo com Yamani (2017), os países em desenvolvimento têm, em média, uma taxa de inflação maior, assim como as taxas de juros mais elevadas, uma renda *per*

capita menor e custos mais elevados de transação e de limites de arbitragem. Possuem também uma influência maior do governo na economia por meio de regulamentos e de taxas.

Ainda de acordo com Yamani (2017), que fez uma comparação das taxas de câmbio no período de crises entre os países desenvolvidos e em desenvolvimento, a hipótese de *random walk* e a hipótese de rentabilidade no período de crise, o estado de eficiência dos mercados desenvolvidos não se alteram, porém, para países em desenvolvimento, a crise tem um impacto grande na mudança na eficiência do mercado.

2.4 Aprendizagem automática (*machine learning*)

Machine learning – ou aprendizagem automática – é um subcampo da ciência da computação que evoluiu do estudo de reconhecimento de padrões e da teoria do aprendizado computacional em inteligência artificial. Através do aprendizado automático, pode-se obter uma análise preditiva, pois são empregados métodos para que a máquina analise os dados imputados para prever a probabilidade dos resultados.

Mitchell (1997), em seu livro, ilustra bem o poder que a aprendizagem automática poderia ter no dia a dia da população, indicando que a máquina pode determinar, por intermédio dos registros médicos, quais são os tratamentos mais eficazes para novas doenças ou, até mesmo, na manutenção de casas, otimizando os custos de energia com base nos padrões de uso.

Assim como nós, humanos, que aprendemos com base em experiências passadas, por meio da observação, da rotina e da memorização, as máquinas também podem potencialmente aprender dessa forma. No entanto, a aprendizagem humana é um tanto quanto mais eficaz, sofisticada e avançada enquanto a máquina tem a capacidade de memorizar, recordar e processar os dados muito mais rapidamente do que o ser humano.

Conforme apontado em seu livro, *Real World Machine Learning*, Brink, Richards e Fetherolf (2017, p. 6) afirmam que:

O aprendizado de máquina pode ser aplicado a uma ampla gama de problemas de negócios, de fraude detecção, para segmentação de clientes e recomendações de produtos, em tempo real monitorar a indústria, análise de sentimentos e diagnóstico médico. Pode assumir problemas que não pode ser gerenciado manualmente devido à enorme quantidade de dados que devem ser processados. Quando aplicado a grandes conjuntos de dados, ML às vezes pode encontrar

relacionamentos tão sutis que nenhuma quantidade de escrutínio manual os descobriria.

Dessa forma, o aprendizado automático veio para, de certa forma, simplificar e dar agilidade aos processos que poderiam levar muito tempo, por meio dessa ferramenta é possível obter informações muito mais rápidas e precisas, a fim de ajudar na tomada de decisão.

O *deep learning*, um subcampo de aprendizagem automática que utiliza o chamado de redes neurais, alcançou excelentes resultados no reconhecimento de imagem e de texto.

As Redes Neurais Artificiais (RNA) são modelos computacionais inspirados no sistema nervoso central e são capazes de reconhecer padrões e realizar o aprendizado automático. As RNA foram criadas no intuito de solucionar problemas de inteligência artificial, construindo um sistema que simule o cérebro humano, inclusive o seu comportamento. Esse sistema foi desenvolvido para tratar problemas de grande complexidade, uma vez que os humanos não os conseguiriam desenvolver ou que demorariam tempo demais para fazê-lo.

A RNA tem duas facetas, a arquitetura e o algoritmo de aprendizagem. O algoritmo de aprendizagem generaliza os dados e memoriza o conhecimento dentro dos parâmetros adaptáveis da rede, os pesos. Assim, o sistema baseado em RNA tem liberdade para definir o tipo de rede para resolver o problema e o algoritmo para treinar a rede e adaptar os pesos (RAUBER, 2005).

A vantagem do sistema de RNA e do avanço da tecnologia é a facilidade de processamento de dados, além da capacidade de armazenar e utilizar uma grande quantidade desses dados para tratar um problema. Aliado a isso, pode-se programar uma RNA a fim de trazer determinada resposta de dados por meio do aprendizado não supervisionado, sem que um agente externo forneça uma resposta.

De acordo com Chen, Daouk e Leung (2001), as redes neurais têm apresentado resultados promissores na previsão e na comercialização financeira, além da abordagem de previsão econométricas.

O aprendizado profundo é um ramo da aprendizagem automática que ensina os computadores a fazer o que é natural aos seres humanos: aprender com a experiência. Algoritmos de aprendizado de máquina usam métodos computacionais para "aprender" informações diretamente dos dados, sem depender de uma equação predeterminada

como modelo. O aprendizado profundo usa redes neurais profundas para aprender relações não lineares complexas a partir dos dados disponíveis, conforme afirma Sirignano (2006).

Ainda de acordo com Sirignano (2006), a aprendizagem profunda é especialmente adequada para o reconhecimento de imagens, o que é importante para resolver problemas como reconhecimento facial e de fala. Além disso, o aprendizado profundo pode ser utilizado para a detecção de movimento e para muitas tecnologias avançadas de assistência ao motorista, como direção autônoma, detecção de faixa, detecção de pedestres e estacionamento autônomo.

2.5 O mercado financeiro e a tecnologia da informação

A literatura de finanças, historicamente, se concentrou em modelos estocásticos e matemáticos. A aprendizagem automática pode ajudar os investidores a prever, com base nos dados passados, um possível resultado dos índices, elevando assim seus ganhos, prevendo as possíveis perdas e mitigando os riscos, como no modelo proposto por Kumar e Thenmozhi (2006, p. 13):

Com base na rede neural, o modelo de previsão do mercado de ações proposto nesta pesquisa não só reduzirá o risco de investimento, mas também ajudará os pequenos investidores a proteger os seus retornos de investimento contra a volatilidade do mercado. Através da pesquisa, desejamos fornecer um método eficiente e barato aos investidores para assegurar um bom retorno de investimento.

Mueller (1996) estudou a aplicação de uma RNA na capacidade de previsão de preços das ações de empresas brasileiras. E, já nessa época, uma RNA apresentava um maior sincronismo com o mercado, reagindo mais rapidamente às mudanças, se comparado, aos métodos convencionais.

Bennell e Sutcliffe (2003) fizeram uma comparação entre o modelo proposto por Black-Scholes (1973), e uma RNA para precificar índices europeus. Eles concluíram que a RNA é, de forma geral, superior ao modelo de Black-Scholes. Afirmam, ainda, que as RNA podem ter um papel importante a desempenhar na precificação de opções.

Até mesmo a aprendizagem automática pode minimizar os vieses comportamentais dos investidores, como proposto no estudo realizado por Peysakhovich e Naecker (2015), que trouxe à tona como os cientistas comportamentais

poderiam incorporar ferramentas advindas da aprendizagem automática para identificar aversão ao risco e ambiguidade.

Heaton, Polson e Witte (2016) afirmam que os seres humanos não possuem a capacidade de selecionar uma ação que provavelmente terá um bom desempenho. Porém, ferramentas, como o aprendizado de máquina, podem ser úteis em tais problemas, pois, se bem calibradas, essas máquinas podem calcular quaisquer dados disponíveis trazendo o melhor retorno.

Harvey, Rattray, Sinclair e Hermert (2017, p. 14) compararam a performance e a exposição ao risco de gerentes discricionários – habilidade de o humano interpretar uma informação – e sistemáticos – máquinas – para fundos *hedge* e obtiveram o seguinte resultado:

Descobrimos que, em termos de equidade e macro estratégias, os fundos sistemáticos e discricionários têm historicamente rendimentos ajustados ao risco médio semelhantes. [...] Nossos resultados mostram que uma aversão aos gerentes sistemáticos, conforme demonstrado por alguns investidores, e em consonância com um fenômeno mais geral de "aversão ao algoritmo", pode ser injustificada.

A pesquisa proposta por Messmer (2017) levanta a ideia de que, com o uso das redes neurais, é possível prever os retornos atraentes das ações dos Estados Unidos da América, ajustando os seus riscos e os seus retornos. Além disso, Messmer (2017) afirma que a reversão de curto prazo e o *momentum* de doze meses estão entre os principais propulsores das previsões de retorno.

Com a evolução tecnológica, computadores cada vez mais rápidos e um mundo cada vez mais conectado, o uso de aprendizagem automática tem o potencial de prever o aumento ou a queda de um índice e, conseqüentemente, o seu retorno e o risco atrelado a ele. No contexto das finanças comportamentais, redes neurais seriam capazes de rapidamente reconhecer os padrões dos vieses nas decisões dos investidores, seja para uma melhor descrição do fenômeno financeiro, seja para potencializar investimentos.

3 METODOLOGIA

O presente trabalho tem cunho descritivo e quantitativo, conforme Vergara (2009), pois visa a estudar a capacidade e comparar os modelos pré-definido de redes neurais artificiais, testando, com métodos quantitativos, a sua capacidade preditiva de curto prazo para os índices de ações.

3.1 Dados

Para o presente trabalho, foram necessários os levantamentos dos valores históricos dos principais índices de ações listados no Quadro 1. Selecionamos índices de ações relevantes tanto dos países desenvolvidos, quanto daqueles em desenvolvimento.

Para as séries históricas, foram utilizadas séries históricas diárias e semanais referentes ao período entre 8 de janeiro de 2010 e 31 de dezembro de 2017, extraídas do sítio eletrônico da empresa *Morgan Stanley Capital International* (MSCI), uma empresa americana provedora de ações, índices e ferramentas de análise de portfólio de ações.

Quadro 1: Índices

Classificação	País	Índice
Emergente	África do Sul	MXZA Index
Desenvolvido	Alemanha	MXDE Index
Desenvolvido	Austrália	MXAU Index
Emergente	Brasil	MXBR Index
Desenvolvido	Canada	MXCA Index
Emergente	China	MXCN Index
Desenvolvido	Estados Unidos	MXUS Index
Desenvolvido	França	MXFR Index
Emergente	Índia	MXIN Index
Desenvolvido	Japão	MXJP Index
Emergente	México	MXMX Index
Desenvolvido	Reino Unido	MXGB Index
Emergente	Rússia	MXRU Index
Desenvolvido	Zona Euro	MXEU Index
Desenvolvido	World	MXWO Index
Emergente	Mercado Emergente	MXEF Index

Fonte: elaboração própria.

Por meio dos dados dos preços, tanto diários quanto semanais, mensuramos o retorno por:

$$Retorno = \ln \left(\frac{Preço d_0}{Preço d_{-1}} \right) \times 100$$

E o risco, este último é mensurado por duas metodologias diferentes. A primeira delas, que busca uma *proxi* do risco implícito, é dada por:

$$Risco = \sqrt{Retorno^2}$$

E a segunda, com uma visão histórica da volatilidade, é dada pela fórmula abaixo, na qual o desvio padrão fora calculado através do retorno se considerado um intervalo de 18 dias.

$$Risco = Desvio Padrão$$

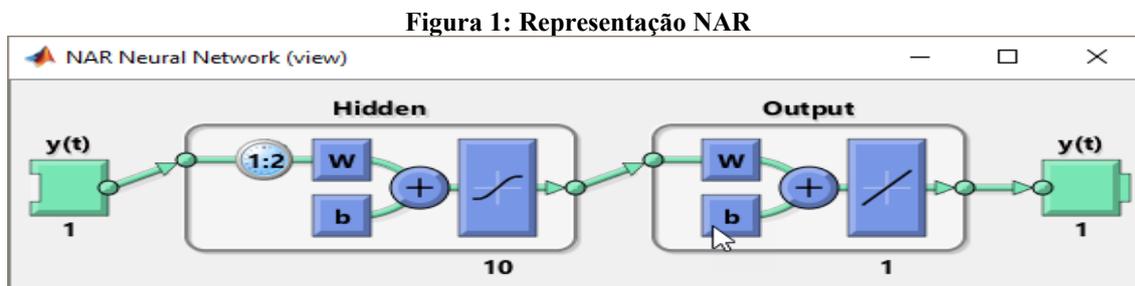
Para aplicação do estudo, os dados foram divididos em três partes, a primeira, que corresponde ao treinamento da máquina, utiliza 70% dos dados, enquanto os outros 30% foram separados da seguinte forma: 15% para validação e 15% para teste.

O conjunto de dados de validação serve para validar o modelo obtido durante o treinamento da rede, utilizando um conjunto de dados diferentes daqueles usados para treinamento e teste. A validação acompanha a evolução do aprendizado e o treinamento é interrompido, quando o erro de validação começa a crescer. Assim, se evita a especialização da rede para o conjunto de dados do treinamento.

Tendo essas variáveis definidas, pode-se implementar as redes neurais para previsão do preço dos principais índices de países desenvolvidos e emergentes. As redes foram implementadas através do software MATLAB® *neural network toolbox*™.

Para o presente trabalho, utilizamos mais precisamente o aplicativo *Time series app*, pois, por meio do modelo *Nonlinear Autoregressive* (NAR), no qual os valores futuros de uma série temporal $y(t)$ são previstos somente a partir de valores passados dessa série, da seguinte maneira:

$$y(t) = f(y(t-1), \dots, y(t-d))$$



Fonte: MATLAB®

3.2 Algoritmos

Dentro do NAR, existem três tipos de algoritmos e, para o presente trabalho, utilizamos todos os três a fim de compará-los e apresentar qual seria o melhor modelo em termos de poder preditivo para o mercado acionário.

3.2.1 *Levenberg-Marquardt (LM)*

Um algoritmo foi proposto por Levenberg, em 1944, para acelerar a convergência do modelo de Gauss-Newton. Em 1693, Marquardt propôs uma pequena mudança no algoritmo proposto por Levenberg, para que cada componente do gradiente fosse ponderada de acordo com a sua curvatura.

De acordo como Gavin (2017), o *Método Levenberg-Marquardt (LM)* é uma técnica utilizada para resolver problemas não lineares de mínimos quadrados. Esses problemas surgem para ajustar uma função parametrizada a um conjunto de dados, minimizando a soma dos quadrados dos erros entre os dados e a função.

Esse algoritmo tem sido amplamente usado e aceito como uma grande eficiência para solucionar o problema de minimização de quadrados para funções não lineares, além de ser considerado um bom algoritmo de otimização. Mesmo que as derivadas em relação aos parâmetros do modelo precisem ser computadas, o algoritmo geralmente converge rapidamente.

3.2.2 *Bayesian Regularization (BR)*

O *Bayesian Regularization (BR)* é uma função de treinamento de rede que atualiza os valores de peso e polarização de acordo com a otimização *Levenberg-Marquardt*. Ele minimiza uma combinação de erros e pesos quadrados e, em seguida, determina a combinação correta para produzir uma rede que generalize bem. Também modifica a combinação linear para que, ao final do treinamento, a rede resultante tenha boas qualidades de generalização. A regularização bayesiana ocorre dentro do algoritmo de *Levenberg-Marquardt*.

De acordo com Burden e Winkler (2008), a regularização bayesiana é um processo matemático que converte uma regressão não linear em um problema estatístico "bem posicionado" na forma de uma regressão linear. A vantagem do modelo é que os cálculos são robustos e o processo de validação, que é escalável como $O(N^2)$ em

métodos normais de regressão, como a propagação reversa, é desnecessário à sua validação.

Uma das principais vantagens das redes neurais de regularização bayesiana é que ela fornece uma estimativa para toda a distribuição dos parâmetros do modelo em vez de obter um conjunto único de pesos de rede, enquanto problemas de ajuste excessivo podem ser evitados e o desempenho de generalização pode ser melhorado. (KELEMEN; LIAN, 2003).

3.2.3 Scaled Conjugate Gradient (SCG)

Foi projetado por Moller, em 1990, para evitar a busca demorada de linha. O algoritmo é baseado em uma classe de técnicas de otimização bem conhecidas em análise numérica como os métodos de gradiente conjugado. O SCG usa informações de segunda ordem da rede neural, porém requer apenas o uso da memória $O(N)$, onde N é o número de pesos na rede. O desempenho do SCG é comparado ao desempenho do algoritmo padrão de retro propagação. A aceleração depende do critério de convergência, ou seja, quanto maior a demanda por redução no erro maior a aceleração.

3.3 Estatísticas de análise

Os resultados obtidos com os dados dos modelos foram mensurados por *Mean Squared Error* (MSE) e por R^2 (*Regression R²*).

O *Mean Squared Error* (MSE) mede a média dos quadrados dos erros ou dos desvios, ou seja, a diferença entre o estimador e o que é estimado. O MSE é uma função de risco, correspondente ao valor esperado da perda. A diferença ocorre devido à aleatoriedade ou porque o estimador não considera informações que poderiam produzir uma estimativa mais precisa.

A medida do erro quadrático médio requer um alvo de previsão ou uma estimativa, juntamente com um preditor ou um estimador, que é dito ser a função dos dados fornecidos. O MSE é definido como a média dos quadrados dos "erros".

O MSE é a variância do estimador. Como a variância, o MSE tem as mesmas unidades de medida do quadrado da quantidade estimada. Em uma analogia ao desvio padrão, obter a raiz quadrada do MSE produz o erro quadrático médio ou o desvio quadrático médio (RMSE ou RMSD), que tem as mesmas unidades que a quantidade

estimada; para um estimador enviesado, o RMSE é a raiz quadrada da variância, conhecida como o desvio padrão.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{X}_i - X_i)^2$$

Quando o valor de MSE é zero, significa que há precisão perfeita encontrada pelo estimador \hat{X} do parâmetro X . Essa condição é ideal e geralmente não é praticamente possível.

Um estimador enviesado com a menor variância entre todos os estimadores enviesados é considerado a melhor previsão, porque tende a minimizar a variância. É o melhor estimador enviesado e é conhecido como estimador enviesado de variância mínima (abreviado como MVUE).

Os valores de MSE podem ser usados para fazer comparações entre dois ou mais modelos estatísticos. Pode ser medido quão bem ilustrado é um dado ou um conjunto de dados. Em muitos métodos de regressão por etapas, o MSE é utilizado para a determinação do número de preditores a serem incluídos em um modelo a partir de um determinado conjunto de observações.

O R^2 varia geralmente entre 0 e 1, podendo este ser negativo, indicando em porcentagem o quanto o modelo consegue explicar os valores obtidos. Quanto maior o R^2 , mais explicativo é o modelo.

4 ANÁLISE DOS RESULTADOS

4.1 Índices mundial e de países emergentes

Além dos dados dos países desenvolvidos e daqueles em desenvolvimento, incluímos os índices *MXWO Index* e *MXEF Index*, que são os índices global e os daqueles países em desenvolvimento, respectivamente, a fim de compará-los com os dois tipos de países definidos na pesquisa. Para tanto, também consideramos os dados diários e os dados semanais.

O quadro a seguir apresenta o MSE e o R^2 para os três algoritmos utilizados aplicados para as séries diárias de preço e de retorno dos índices mundial e de emergentes.

Quadro 2: Resultados dos modelos para preço e retorno para índices mundial e emergentes

	Preço				Retorno			
	Índice mundial		Índice emergentes		Índice mundial		Índice emergentes	
	MSE	R^2	MSE	R^2	MSE	R^2	MSE	R^2
LM	136.17	0.99	89.12	0.99	0.61	0.16	0.96	0.22
BR	124.98	0.99	85.12	0.99	0.67	0.20	0.91	0.23
SCG	190.79	0.99	125.59	0.99	0.72	0.12	0.97	0.06

Fonte: elaboração própria

Considerando os dados diários para o preço em ambos os índices, o coeficiente R^2 apresentou valores relevantes acima de 99%, enquanto, segundo o MSE, para os ambos os casos, o algoritmo que obteve melhor resultado foi o BR.

Este resultado pode ser explicado pela linearidade do preço, que, apesar da volatilidade *intraday*, tende a ter um crescimento linear.

Quando se analisa os resultados obtidos para as séries de retorno, o poder preditivo dos modelos diminui razoavelmente, com R^2 de, no máximo, 23% para o modelo BR. Esta diferença para o R^2 do preço, pode ser explicada através da aleatoriedade que o retorno possui, uma vez que, analisámos este com o resultado do final do dia, ou seja, entre um e outro há uma diferença considerável. Já os valores de MSE indicam o LM como melhor modelo para o índice mundial, enquanto o BR superou os demais para o índice dos emergentes.

O quadro a seguir apresenta os resultados para as medidas de risco consideradas.

Quadro 3: Resultados dos modelos para risco 1 e risco 2 para índices mundial e de países emergentes

	Risco 1				Risco 2			
	Índice mundial		Índice emergentes		Índice mundial		Índice emergentes	
	MSE	R ²	MSE	R ²	MSE	R ²	MSE	R ²
LM	0.335	0.20	0.405	0.15	0.0029	0.99	0.0033	0.98
BR	0.390	0.33	0.390	0.19	0.0033	0.98	0.0029	0.99
SCG	0.345	0.24	0.520	0.33	0.0037	0.98	0.0082	0.97

Fonte: elaboração própria

Para a primeira medida de risco, os modelos utilizados conseguiram explicar, no máximo 33%, do fenômeno, seguindo a mesma linha de raciocínio do retorno apresentada anteriormente, uma vez que, a primeira medida de risco, utilizamos a raiz do retorno ao quadrado, visando alterar o sinal de negativo e afastando os valores de zero. Para o índice mundial, o R² indicou o BR como melhor modelo, enquanto o LM superou os demais pelo MSE. Para o índice dos países emergentes, o R² indicou o SCG como melhor modelo, enquanto o BR superou os demais pelo MSE.

Para a segunda medida de risco utilizada, o R² encontrado para ambos os índices ficou acima de 97%, enquanto o MSE apresentou resultados bem próximos a zero, indicando uma boa adequação dos modelos utilizados. Aqui segue-se a mesma linha do preço, o desvio padrão do retorno, considerando uma janela de 18 dias fez com que os valores ficassem próximos um do outro, ou seja, não houve uma aleatoriedade nos resultados obtidos.

Tanto para o índice mundial, quanto para o de países emergentes, o modelo que mais bem se aplica é o LM, indo de encontro com o melhor modelo, considerando as médias dos índices separadamente.

4.2 Média dos resultados dos países emergentes e dos países desenvolvidos

Quadro 4: Média dados diários para preço e retorno – emergentes e desenvolvidos

	Preço				Retorno			
	Média Emergentes		Média Desenvolvidos		Média Emergentes		Média Desenvolvidos	
	MSE	R ²	MSE	R ²	MSE	R ²	MSE	R ²
LM	1294.56	0.99	103.44	0.99	2.05	0.06	1.09	0.06
BR	1316.86	0.99	99.24	0.99	1.94	0.11	3.24	0.03
SCG	2037.00	0.99	143.14	0.99	2.07	0.05	1.21	0.04

Fonte: elaboração própria

O Quadro 4 apresenta os resultados médios para preço e retorno diário obtidos para os diversos índices considerados, agrupados por países emergentes e desenvolvidos.

Para preços, mais uma vez, o R^2 indica uma performance interessante dos três modelos e o MSE indica o LM como melhor modelo para os países emergentes, enquanto o BR foi melhor índice para os países desenvolvidos.

Novamente os valores encontrados, assim como os obtidos com os índices mundial e emergentes, se dão pela linearidade que os valores para preço possuem, desta forma o algoritmo consegue encontrar uma explicação quase perfeita para os valores de MSE.

Da mesma forma, o retorno, com a sua volatilidade *intraday* apresentou um resultado para R^2 de 11% sendo o modelo com melhor performance foi o BR para os países emergentes, que obteve R^2 de 11%. Os resultados para países emergentes e desenvolvidos foram próximos, à exceção do LM, indicando que o grau de eficiência desses mercados, quando tratamos de índices de ações, é bem próximo. O poder preditivo dos modelos para retorno foi baixo para todos os países.

O Quadro 5 apresenta os resultados médios dos países para as variáveis de risco consideradas.

Quadro 5: Média dados diários para risco 1 e risco 2 – emergentes e desenvolvidos

	Risco				Risco 2			
	Média Emergentes		Média Desenvolvidos		Média Emergentes		Média Desenvolvidos	
	MSE	R^2	MSE	R^2	MSE	R^2	MSE	R^2
LM	0.9350	0.18	0.5375	0.24	0.0085	0.98	0.0045	0.98
BR	0.9383	0.20	0.5369	0.26	0.0134	0.98	0.0046	0.98
SCG	0.9250	0.13	0.5475	0.19	0.0115	0.98	0.0060	0.98

Fonte: elaboração própria

Na medida do risco, considerada a primeira forma de mensuração – risco implícito –, para os países em desenvolvimento, o modelo que se aplica melhor à proposta do presente trabalho foi o BR, que apresentou um R^2 de 0,26 para a média dos países desenvolvidos.

Para a segunda medida do risco, os modelos apresentaram ótima performance com R^2 da ordem de 0,98. Tanto para países em desenvolvimento, quanto para os desenvolvidos, o modelo que explica melhor foi o LM.

Assim como nos resultados obtidos através dos índices mundial e emergentes, a primeira medida de risco apresentou resultados abaixo do que a segunda medida de risco, porém, um tanto quanto satisfatório se levarmos em consideração a volatilidade apresentada nesta medida.

Ao comparar os algoritmos utilizados no presente trabalho, percebe-se, de acordo com a Tabela 1, que aquele que tem a maior capacidade preditiva, ou seja, que obteve os melhores resultados e que, em comparação com os outros, foi o melhor, tanto para os índices global e emergentes, quanto para a média dos países desenvolvidos e em desenvolvimento, foi o BR.

Tabela 1: Resumo dados diários

	Preço	Retorno	Risco	Risco 2	Total
LM	8	4	6	6	24
BR	8	8	9	9	34
SCG	0	4	1	1	6
Total	16	16	16	16	64

Fonte: elaboração própria

No entanto, vale observar que, dentre todos os métodos disponíveis, apenas no preço e na segunda medida de risco, o modelo apresenta uma melhor explicação considerando o coeficiente R^2 , pois este apresentou uma correlação quase perfeita apenas nesses dois tipos de dados.

Vale ressaltar que ambos algoritmos são bem parecidos, o BR é apenas uma função de treinamento de rede que atualiza os valores e a polarização de acordo com a otimização obtida por LM.

4.3 Resultado: dados semanais

Da mesma forma que analisamos os dados diários, também utilizamos os mesmos parâmetros para os dados semanais, a fim de compará-los e saber se seria melhor aplicar o algoritmo em dados semanais ou em diários.

Assim, de acordo com a Tabela 2, que demonstra resumidamente a quantidade em que um modelo apresentou o melhor resultado, pode-se observar que, assim como com os dados diários, os melhores algoritmos a serem aplicados a que a pesquisa se propõe foram o LM e o BR.

Tabela 2: Resumo dados semanais

	Preço	Retorno	Risco	Risco 2	Total
LM	5	10	10	5	30
BR	8	2	5	10	25
SCG	3	4	1	1	9
Total	16	16	16	16	64

Fonte: elaboração própria

Porém, se compararmos a Tabela 2 com a Tabela 1, podemos observar que, para os dados diários, o modelo que apresentou um maior número de vezes como o melhor modelo foi o BR, em contrapartida, para os dados semanais, o melhor modelo foi o LM.

Assim como aconteceu nos dados diários, para os dados semanais, os modelos de aprendizagem de máquina utilizados apresentaram bom poder preditivo para preço e risco histórico (desvio-padrão), no entanto, para retorno e risco implícito, os resultados foram bem inferiores, porém, mesmo com os resultados obtidos apresentaram um poder preditivo aceitável. Não houve distinção destacável nos resultados obtidos para os países desenvolvidos e emergentes.

Quanto à escolha do algoritmo que mais bem se aplica, os resultados obtidos mostram que o LM e o BR são, sem dúvida, aqueles que apresentaram melhores resultados. No entanto, vale ressaltar que, para os dados diários, em relação ao preço, o melhor índice foi o BR, e, em contrapartida, para o risco, o melhor índice foi o LM. Em relação aos dados semanais, não há distinção considerável entre os dois modelos.

5 CONCLUSÃO

O presente trabalho buscou analisar a capacidade das redes neurais artificiais na previsão de preço, risco e retorno dos principais índices dos mercados emergentes e desenvolvidos. Para tanto, analisamos os dados diários e semanais no período compreendido entre 8 de janeiro de 2010 e 31 de dezembro de 2017 bem como utilizamos os seguintes algoritmos de aprendizagem de máquina: *Levenberg-Marquardt*, *Bayesian Regularization* e *Scaled Conjugate Gradient*.

Pelos dados obtidos pela pesquisa, os modelos apresentaram resultados satisfatórios na previsão de preço e risco histórico, notadamente: *Levenberg-Marquardt* e *Bayesian Regularization*.

Isso demonstra que as séries de preço e de desvio-padrão apresentam dependência de seus valores históricos e os modelos de aprendizagem de máquina ofereceram boa performance preditiva. Por outro lado, retorno e risco implícito apresentaram características de passeio aleatório, tanto em países emergentes quanto desenvolvidos, reforçando a hipótese de eficiência do mercado. Efeitos nos retornos de padrões comportamentais não foram identificados pelos modelos.

Para pesquisas futuras, seria interessante aplicar os modelos em ações individuais para verificar se a hipótese de mercado eficiente se mantém. Outros algoritmos de aprendizagem de máquina também poderiam ser empregados, assim como, verificar mais a fundo o motivo pela qual retorno e a primeira medida de risco apresentaram valores para R^2 com pouco poder preditivo.

REFERÊNCIAS

ALCÂNTARA, J. C. G. O modelo de avaliação de ativos (capital asset pricing model). **Revista de Administração de Empresas**, Rio de Janeiro, n. 20, v. 3, pp. 31-41, jul./set. 1980.

BENNELL, J.; SUTCLIFFE, C. Black-scholes versus artificial neural networks in pricing FTSE 100 options. **SSRN**, Southampton, School of Management, maio 2003. Disponível em: <<https://ssrn.com/abstract=544882>>.

BRINK, H.; RICHARDS, J. W.; FETHEROLF, M. **Real-world machine learning**. Nova Iorque: Manning Publications, 2017.

BURDEN, F.; WINKLER, D. Bayesian regularization of neural networks. *In*: LIVINGSTONE, D.J.; WALKER, J.M. (ed.) **Artificial neural networks: methods in Molecular Biology**. v. 458. [s.l.]: Humana Press, 2008.

CHEN, A.S.; DAOUK, H.; LEUNG, M. T. Application of neural networks to an emerging financial market: forecasting and trading the Taiwan stock index. **SSRN**, Michigan, jul. 2001. Disponível em: <<https://ssrn.com/abstract=237038>>.

ECKEL, C. C.; GROSSMAN, P. J. Men, women and risk aversion: experimental evidence. *In*: PLOTT, C. R.; SMITH, V. (ed.). **Handbook of experimental economics results**. v. 1. Nova Iorque: Elsevier, 2008. pp. 1061-1073. Disponível em: <<https://ssrn.com/abstract=1883693>>.

FAMA, E. F. Efficient capital markets: a review of theory and empirical work. **The Journal of Business**, v. 25, n. 2, Nova Iorque, pp. 383-417, maio 1969. Disponível em: <<http://www.jstor.org/stable/2325486>>.

FAMA, E. F. The behavior of the stock-market prices. **The Journal of Business**, v. 38, n. 1, pp. 34-105, jan. 1965. Disponível em: <<http://www.jstor.org/stable/2350752>>.

FORTI, C. A. B.; PEIXOTO, F. M.; SANTIAGO, W. P. Hipótese de eficiência de mercado: um estudo exploratório no mercado de capitais brasileiro. **Revista Gestão & Regionalidade**, v. 25, n. 75, pp. 45-56, set./dez. 2009.

GAVIN, H. P. The **Levenberg-Marquardt method for nonlinear least squares curve-fitting problems**. Durham: Duke University, 2017. Disponível em: <<http://people.duke.edu/~hpgavin/ce281/lm.pdf>>.

HARVEY, C. R. *et al.* Man vs. machine: comparing discretionary and systematic hedge fund performance. **Duke I&E Research Paper**, n. 2017-01, maio 2017. Disponível em: <<https://ssrn.com/abstract=2880641>>.

HEATON, J. B.; POLSON, N. G.; WITTE, J. H. Deep learning for finance: deep portfolios. **SSRN**, Chicago e Londres, set. 2016. Disponível em: <<https://ssrn.com/abstract=2838013>>.

HUGONNIER, J.; MORELLEC, E. Real options and risk aversion. **Swiss Finance Institute Research Paper**, set. 2007. Disponível em: <<https://ssrn.com/abstract=422600>>.

JENSEN, M. C.; BLACK, F.; SCHOLES, M. S. The capital asset pricing model: some empirical tests. *In*: JENSEN, M. C. **Studies in the theory of capital markets**. [s.l.]: Praeger Publishers Inc., 1972. Disponível em: <<https://ssrn.com/abstract=908569>>.

KAHNEMAN, D.; TVERSKY, A. Prospect theory: an analysis of decision under risk. **Econometria**, v. 47, n. 2, pp. 263-292, mar. 1979.

KELEMEN, A.; LIAN, Y. Bayesian regularized neural network for multiple gene expression pattern classification. **Proceedings of the International Joint Conference on Neural Networks**, n. 1, pp. 654- 659, 2003.

KIMURA, H.; BASSO, L. F. C.; KRAUTER, E. Paradoxos em finanças: teoria moderna versus finanças comportamentais. **Revista de Administração de Empresas**, Rio de Janeiro, pp. 41-58, jan./mar. 2006.

KÖBBERLING, V.; WAKKER, P. P. An index of loss aversion. **Journal of Economic Theory**, n. 122, pp. 119-131, 2005.

KUMAR, M.; THENMOZHI, M. Forecasting stock index movement: a comparison of support vector machines and random forest. **Indian Institute of Capital Markets 9th Capital Markets Conference Paper**, Madras, Índia, [s.d.]. Disponível em: <<https://ssrn.com/abstract=876544>>.

LIEW, J. K.; MAYSTER, B. Forecasting ETF with machine learning algorithms. **SSRN**, jan. 2017. Disponível em: <<https://ssrn.com/abstract=2899520>>.

MARKOWITZ, H. Portfolio selection. **The Journal of Finance**, v. 7, n 1, pp. 77-91, mar. 1952. Disponível em: <<http://www.jstor.org/stable/2975974>>.

MARTINEAU, C. **The evolution of market price efficiency around earnings news**. **SSRN**, fev. 2018. Disponível em: <<https://ssrn.com/abstract=3111607>>.

MATLAB. **Trainbr**. 2018. Disponível em: <<https://www.mathworks.com/help/nnet/ref/trainbr.html>>.

MESSMER, M. **Deep learning and the cross-section of expected returns** (versão preliminar). **SSRN**, 2017. Disponível em: <<https://ssrn.com/abstract=3081555>>.

MITCHELL, T. M. **Machine learning**. McGraw-Hill Science/Engineering/Math. 1 de março de 1997

MOLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. **Neutral Networks**, Computer Science Department, University of Aarhus, Dinamarca, nov. 1990. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0893608005800565>.

MULLER, A. **Uma aplicação de redes neurais artificiais na previsão do mercado acionário**. 1996. 118 f. Dissertação (Mestrado em Engenharia) - Departamento de Pós-

graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, 1996.

OLSEN, R. A. Implications of herding behavior for earnings estimation, risk assessment and stock returns. **Financial Analysts Journal**, v. 52, n. 4, pp. 37-41, jul./ago. 1996.

PEYSAKHOVICH, A.; NAECKER, J. Using methods from machine learning to evaluate behavioral models of choice under risk and ambiguity. **Journal of Economic Behavior and Organization**, **Forthcoming**, jan. 2015. Disponível em: <<https://ssrn.com/abstract=2548564>>.

RAUBER, T. W. Redes neurais artificiais. **FACEF Pesquisa, Desenvolvimento e Gestão**, Universidade Federal do Espírito Santo, v. 17, n. 3, pp. 259-272, set./out./nov./dez. 2014.

RICCIARDI, V.; SIMON, H. K. What is behavioral finance? **Business, Education & Technology Journal**, v. 2, n. 2, pp. 1-9, 2000. Disponível em: <<https://ssrn.com/abstract=256754>>.

RODRIGUES, P. N.; RIVERO, S. S. Using machine learning algorithms to find patterns in stock prices. **FEDEA Working Paper**, n. 2006-12, out. 2006. Disponível em: <<https://ssrn.com/abstract=893141>>.

SIRIGNANO, J. A. Deep learning for limit order book. **SSRN**, 2016. Disponível em: <<https://ssrn.com/abstract=2710331>>.

VERGARA, S. C. **Projetos e relatórios de pesquisa em administração**. 10. ed. São Paulo: Atlas, 2009.

YAMANI, E. Foreign exchange market efficiency: different tales from developed and developing markets during the recent financial crisis. **SSRN**, 2018. Disponível em: <<https://ssrn.com/abstract=2972163>>.