

## DEEP LEARNING APLICADO À NEGOCIAÇÃO DE AÇÕES POR ALGORITMOS: UMA REVISÃO DESCRITIVA DA LITERATURA

**Camilo Ilzo Shimabukuro**

Centro Paula Souza

camilo.shimabukuro@gmail.com

**Prof. Dr. Napoleão Verardi Galegale**

Centro Paula Souza

nvg@galegale.com.br

**Prof. Dr. Marcelo Tsuguio Okano**

Centro Paula Souza

marcelo.okano@cps.sp.gov.br

**Profa. Dra. Celi Langhi**

Centro Paula Souza

celi@infolearning.com.br

### Resumo

Revisões da literatura relativamente recentes apresentam o Deep Learning como campo do Aprendizado de Máquina pouco explorado na área de negociação e predição de ativos por algoritmos (AT). Identifica-se uma oportunidade para a investigação das frentes de pesquisa e formulações epistemológicas emergentes sobre o tema.

Este estudo tem por objetivo prospectar a produção científica sobre Deep Learning aplicado a sistemas de AT, identificando o estado da arte da pesquisa por meio de análise bibliométrica, revisão descritiva da literatura e análise das abordagens. Busca-se contribuir para aprimoramento do mercado de capitais quanto à liquidez, eficiência e capacidade preditiva de preços de ações, que possam se traduzir em redução de incertezas e menores custos de transação aos investidores.

**Palavras-chave:** Deep Learning, Algorithmic Trading, Revisão da Literatura, Preços de ações.

## Abstracts

Relatively recent literature reviews present Deep Learning as a field of Machine Learning that is little explored in the area of algorithmic trading and asset price prediction (AT). An opportunity is identified for the investigation of the research fronts and emerging epistemological formulations on the subject. This research aims to prospect the scientific literature on Deep Learning applied to AT systems, identifying the state of the art through bibliometric analysis, descriptive literature review and analysis of approaches. The aim is to contribute to capital market enhancement in terms of liquidity, efficiency and predictive capacity of stock prices, which may translate into reduced uncertainty and lower transaction costs for investors.

**Keywords:** Deep Learning, Algorithmic Trading, Literature Review, Stock price.

## Introdução

Ao comprar ou vender ações de uma empresa em bolsas de valores, um investidor busca aumentar o retorno financeiro de sua carteira de ativos. Em conjunto com os demais investidores, estabelecem o valor de mercado da empresa ao participarem da livre formação de preços durante uma sessão de negociação no mercado secundário. O capital obtido dos acionistas somado à emissão de dívida compõem a estrutura de capital de uma empresa, que poderá realizar investimentos de longo prazo, tornar-se mais competitiva e aumentar seus lucros, que por sua vez retornam aos investidores

na forma de dividendos ou da valorização das ações (ROSS; WESTERFIELD e JAFFE, 2011; DAMODARAN, 2012).

A negociação de ações, que anteriormente acontecia em pregões a viva voz, foi gradativamente sendo transferida para meios eletrônicos ao longo da década de 1990, em especial nos Estados Unidos, com o surgimento da NASDAQ (*National Association of Securities Dealers Automated Quotations*) e dos sistemas de execução eletrônica de ordens em bolsas de valores e futuros tradicionais, como NYSE (*New York Stock Exchange*) e CME (*Chicago Mercantile Exchange*) (JOHNSON, 2010).

A crescente interconexão entre participantes do mercado de capitais, a utilização de infraestrutura tecnológica a custos decrescentes e a adoção de padrões de comunicação eletrônica, como o FIX Protocol (*Financial Information eXchange Protocol*) na segunda metade da década de 1990, estimularam o surgimento de estratégias automatizadas baseadas em algoritmos, o *Algorithmic Trading* (AT). Ao fim da década de 2000, o AT já respondia por sessenta por cento do volume negociado no mercado de ações americano (HENDERSHOTT; JONES; MENKVELD, 2011; NUTI *et al.*, 2011; FIX TRADING COMMUNITY, 2018).

A ampliação do acesso eletrônico aos mercados acionários, a equiparação da capacidade tecnológica em grande parte da indústria financeira e a expectativa por maiores resultados das estratégias de AT atraíram o foco dos gestores quantitativos para o uso do Aprendizado de Máquina (ML), ainda que inicialmente com resultados limitados (JOHNSON, 2010; IEEE SPECTRUM, 2017).

Na segunda metade da década de 2000, as abordagens de ML baseadas em *Deep Learning* (DL) ganharam evidência com os resultados obtidos em áreas como o reconhecimento de imagens e o processamento natural da linguagem, trazendo perspectivas para aplicação em outros segmentos (GOODEFELLOW; BENGIO; COURVILLE, 2016; SCHMIDHUBER, 2014; RUSSELL; NORVIG, 2016).

Entretanto, revisões da literatura relativamente recentes, no período de 2009 a 2015, ainda apresentavam o DL como campo muito pouco explorado na área de finanças e AT, como a seleção de ativos para composição de carteiras de investimentos e a predição em séries temporais de preços de ações (HU *et al.*, 2015; CAVALCANTE *et al.*, 2016). Identifica-se, portanto, uma oportunidade para a investigação das

formulações epistemológicas recentes sobre abordagens de DL aplicadas em sistemas de AT.

Por estas razões, propõe-se responder à questão: qual o estado da arte das abordagens e frentes de pesquisas de DL aplicados em sistemas de AT, no período de 2016 a 2019?

Esta pesquisa tem por objetivo prospectar a produção científica sobre DL aplicado a sistemas de AT, identificando o estado da arte das principais abordagens e frentes de pesquisa. Busca-se por meio deste trabalho contribuir para aprimoramento do mercado de capitais quanto à liquidez das bolsas de valores, à eficiência das operações e à capacidade preditiva de preços, que se traduzam em redução de incertezas e menores custos de transação aos investidores.

## **1. Fundamentação teórica**

### **1.1 Negociação de Ações por Algoritmos**

O AT pode ser definido como um sistema baseado em algoritmos de computadores que automatiza a execução de ordens de compra ou venda de ativos em mercados eletrônicos como bolsas de valores, de futuros e câmbio (CHAN, 2009; JOHNSON, 2010).

Desde o seu surgimento, tem sido objeto de questionamento quanto aos seus riscos e benefícios. Pesquisas indicam que o AT reduz os custos de negociação, aumenta o grau de informação das cotações, melhora a conexão entre mercados, reduz a discrepância de preços entre mercados, aumenta a liquidez para investidores, reduz a volatilidade de preços, tornando a formação de preços mais eficiente. Todavia, tais benefícios nem sempre se confirmam quando ocorrem condições inesperadas e severas. Embora os resultados sugiram que a qualidade do mercado em geral tenha melhorado, acredita-se que a fragilidade episódica dos mercados seja uma questão ainda não resolvida e espera-se que futuras pesquisas possam esclarecê-la (HENDERSHOTT; JONES e MENKVELD, 2011; HASBROUCK e SAAR, 2013; CHABOUD *et al.*, 2014; BROGAARD; HENDERSHOTT e RIORDAN, 2017)

O aumento da participação do AT no mercado de ações, entretanto, apresenta implicações para órgãos reguladores, que devem promover a competição entre os agentes e assegurar a igualdade de condições aos investidores. Tais implicações se tornaram ainda mais críticas após a ocorrência do *Flash Crash*, em 6 de maio de 2010, quando o índice industrial Dow Jones despencou abruptamente mais de 900 pontos em cinco minutos (EASLEY; PRADO e O'HARA, 2011; HENDERSHOTT e RIORDAN, 2013).

## 1.2 Aprendizado de Máquina aplicado à Negociação por Algoritmos

A computação financeira (*computational finance*), uma divisão da ciência da computação, pode ser definida como o estudo de dados e algoritmos utilizados em finanças, aplicada em estratégias quantitativas como: previsão de tendências de preços de ações, identificação de padrões no comportamento de ativos e administração de carteiras de investimentos, bem como na avaliação de riscos financeiros, análise comportamental dos investidores e detecção de anomalias (GADRE-PATWARDHAN; KATDARE; JOSHI, 2016).

Estratégias quantitativas dependem de uma eficiente coleta e análise de informações, bem como do desenvolvimento de processos dinâmicos que otimizem critérios de desempenho prescritos na presença da incerteza (GUO *et al.*, 2017).

A incerteza é um dos maiores desafios enfrentados na pesquisa e gestão em finanças. Ao introduzir um inevitável fator de risco, não apenas torna complexa a tomada de decisões, mas cria também oportunidades a investidores, demandando uma eficiente e efetiva análise de riscos (GADRE-PATWARDHAN; KATDARE e JOSHI, 2016).

O estudo de abordagens de ML aplicadas ao AT acrescenta um grau de complexidade ainda maior a esta área do conhecimento, que pressupõe o domínio de finanças, cálculo, estatística, e tecnologia da informação. No aspecto das finanças, requer conhecimentos sobre a microestrutura do mercado. Nas áreas ligadas ao cálculo e à estatística, demanda conhecimentos sobre álgebra linear, otimização convexa, matemática discreta, processamento de sinais e ciência de dados. Na área da computação, além da teoria da informação e programação orientada a objetos, requer domínio de processamento paralelo, computação de alto desempenho (HPC) e das linguagens R ou Python, associadas a bibliotecas de software especializadas como:

pandas, scikit-learn, keras e tensorflow (EASLEY; PRADO e O'HARA, 2011; HILPISCH, 2018; PRADO, 2018).

Os dados utilizados por um sistema de AT podem ser classificados em: dados fundamentais, dados de mercado (MD), dados analíticos e dados alternativos. Dados fundamentais são balanços, demonstrativos, distribuição de proventos e demais informações contábeis, de divulgação obrigatória e em conformidade com procedimentos estabelecidos por órgãos reguladores. O MD inclui toda atividade de negociação de ações que ocorre numa bolsa de valores, como as séries de preços intradiários e históricos. Os dados analíticos são dados secundários resultantes de um processo de análise especializada sobre dados fundamentais e de mercado, como múltiplos e indicadores de fluxo de caixa, ou resultantes de um cálculo efetuado por software, como indicadores da análise técnica. Os dados alternativos são extraídos de notícias, redes sociais, informações comerciais e governamentais, como níveis de vendas, estoques, dados econômicos, taxas de juros, entre outros. O Quadro 1 mostra os quatro tipos de dados financeiros (PRADO, 2018).

Quadro 1 – Quatro tipos de dados financeiros

<b>Dados Fundamentais</b>	<b>Dados de Mercado</b>	<b>Dados Analíticos</b>	<b>Dados Alternativos</b>
<b>Balanços</b>	Preços diários	Recomendações	Notícias financeiras
<b>Demonstrativos</b>	Preços históricos	Risco de Crédito	Redes Sociais, Internet
<b>Proventos</b>	Livros de Ofertas	Previsão de Lucros	Governo, Comércio,
<b>Fluxo de Caixa</b>	Volatilidade histórica	Múltiplos	Indústria, Agronegócio
<b>Variáveis Macro</b>		Análise Técnica	Análise de Sentimento

Fonte: Prado (2018)

As séries temporais financeiras apresentam característica de não estacionariedade. Uma série de tempo é não estacionária quando seus valores se distanciam continuamente do seu valor inicial. Os preços das ações são tipicamente não estacionários, exibindo um passeio randômico geométrico, tendendo a se distanciar do

seu valor inicial. Entretanto, pode-se obter uma série estacionária com arbitragens estatísticas (*Long-Short*) ao se combinar duas ações do mesmo setor ou similares, sendo uma comprada e outra vendida. O diferencial de preços apresenta características estacionárias, como a reversão à média. Neste caso as séries de tempo de cada ação são ditas cointegradas, pois uma combinação linear delas é integrada de ordem zero (CHAN, 2008).

Aspecto importante no estudo das séries de preços em finanças, o ruído é resultante da atuação de uma grande quantidade de participantes do mercado, comprando e vendendo em diferentes momentos e para variados propósitos. Podem resultar também de choques de preços, de eventos inesperados, como notícias ou fatos econômicos, cujos impactos podem persistir no futuro por intervalos de tempo variados. O ruído apresenta muitas das características das sequências randômicas. Quase metade dos movimentos de preços muda de direção no dia seguinte, cerca de 25% mantêm a direção por dois dias seguidos, e 12,5% por três dias, e assim por diante. Por outro lado, as variações de preço também apresentam característica randômica, 50% são relativamente pequenas, 25% apresentam o dobro de tamanho, 12,5% são quatro vezes maiores, e pouquíssimas são extremamente grandes (KAUFMAN, 2013)

Ainda que os preços de ações apresentem em média um comportamento próximo ao passeio aleatório, sob determinadas condições e horizontes de tempo podem apresentar algum grau de reversão à média ou comportamento de tendência. Os regimes são comportamentos observáveis em mercados financeiros, em que se busca identificar o momento de mudança de padrões, ou o ponto de inflexão (CHAN, 2008; LÄNGKVIST, 2014).

Para Kearns e Nevmyvaka (2013), a utilização de dados históricos para inferência preditiva em finanças quantitativas tem sido amplamente utilizada, tendo como exemplos mais frequentes o Modelo de Precificação de Ativos Financeiros (CAPM) e a Hipótese do Mercado Eficiente (EMH). Todavia, a dificuldade do ML para lidar com o AT surge da microestrutura do mercado, da granularidade dos dados, com execuções parciais, cancelamentos de ordens, liquidez oculta, em que não se tem ao menos uma intuição de como a distribuição de liquidez dos livros de ordens limitadas (LOB) se relaciona com movimentos futuros dos preços. Assim, propõem a seleção de

características (*feature selection*) ou engenharia de características (*feature engineering*) como caminhos para aplicação de ML ao AT, em especial à negociação de alta frequência (HFT).

Ainda que a engenharia de características permita uma previsão da direção de movimento dos preços a partir de certos estados do LOB, em que operações lucrativas superem as não lucrativas, que algoritmos de ML capturem essa previsibilidade (*alpha*) a custos suficientemente baixos, e que, conforme estudos de caso realizados, se reconheça que o ML forneça um framework poderoso, escalável e fundamentado para análise de dados e previsão, não se tem, entretanto, um caminho fácil para a rentabilidade (KEARNS; NEVMYVAKA, 2013).

Prado (2018) chama a atenção para os cuidados com o sobreajuste (*overfitting*), em que um modelo estatístico se ajusta bem aos dados históricos ou de treinamento, mas perde capacidade de previsão efetiva sobre dados novos. Recomenda cautela também quanto aos resultados testes de desempenho de modelos obtidos com base em dados históricos (*backtesting*), pois a pesquisa na área das finanças lida com conjuntos de dados pouco extensos e uma baixa razão sinal/ruído; e a aplicação dos modelos no ambiente real de negociação, além de implicar em riscos e custos de maior grandeza, podem apresentar comportamento diferente do exibido no *backtesting*.

### **1.3 Deep Learning aplicado à Negociação por Algoritmos**

Avanços recentes em DL têm se mostrado promissores na extração de informações sobre dados não classificados, por meio do aprendizado não-supervisionado, prescindindo do intensivo trabalho da engenharia de características, e sendo aplicados com sucesso em campos como o reconhecimento da fala, reconhecimento de imagens e processamento da linguagem natural. Entretanto, a previsão de séries temporais de preços de ações apresenta alta complexidade até mesmo para analistas e investidores profissionais. Além disso, a identificação de padrões que possam eventualmente existir estão sujeitos a mudanças no comportamento dos investidores, que aprendem ao longo do tempo e competem pela extração de resultados (BENGIO; COURVILLE; PASCAL, 2012; LECUN; BENGIO; HINTON, 2015; TAKEUCHI; LEE, 2013).

O aprendizado não-supervisionado também apresenta a vantagem de poder sobrepor camadas de representação de características para criar redes neurais profundas

(DNN) com maior capacidade de modelar estruturas complexas de dados. Porém, para obter resultados satisfatórios e uma maior eficiência de aprendizado, as redes neurais requerem a redução da dimensionalidade, uma cuidadosa seleção das variáveis de entrada e dos parâmetros de rede, como a taxa de aprendizado, o número de camadas ocultas e o número de nós em cada camada (LÄNGKVIST; KARLSSON; LOUTFI, 2014; CHONG; HAN; PARK, 2017).

Não obstante, observa-se uma tendência na comunidade de pesquisa em ML e reconhecimento de padrões para a aplicação da topologia não-linear do DL à predição em séries temporais financeiras. Dentre as abordagens de DL observadas nos estudos recentes pode-se citar: Redes Neurais Convolucionais (CNN), Redes Neurais Recorrentes (RNN), *Long Short-Term Memory* (LSTM), um caso particular de RNN, *Deep Belief Networks* (DBN) e *Stacked Autoencoders* (BAO; YUE; RAO, 2017).

## 2. Métodos

Esta pesquisa é de natureza qualitativa, de objetivo exploratório, de tipologia teórico-conceitual. A pesquisa qualitativa busca o entendimento, a descrição, a tradução do fenômeno ou conceito pesquisado, fundamentada na teoria e complementada por variáveis, constructos e hipóteses (VAN MAANEN, 1979; BRYMAN, 2011; CAUCHICK-MIGUEL; FLEURY, 2012; CRESWELL, 2014).

Frequentemente associada à pesquisa qualitativa, a pesquisa de objetivo exploratório é conduzida para se obter um melhor entendimento do problema ou determinar sua natureza. Pretende-se explorar a questão de pesquisa, podendo ser conduzida por meio de uma busca na literatura, não fornecendo necessariamente uma evidência conclusiva (SAUNDERS; LEWIS; THORNHILL, 2012).

Na tipologia teórico-conceitual sobre dados secundários (FILIPPINI, 1997), os conceitos são discutidos a partir de levantamentos horizontais, como análises bibliométricas e revisões da literatura, e de levantamentos verticais, como a análise de modelagens conceituais, tendo como base a percepção e experiência do autor (BERTO; NAKANO, 2000).

O levantamento horizontal na literatura possibilita identificar as teorias existentes relativas ao fenômeno pesquisado, buscando as mais promissoras no intuito de transformar o conhecimento existente e, possivelmente, gerar conhecimento novo (CAUCHICK-MIGUEL; FLEURY, 2012). O propósito da análise bibliométrica é medir os resultados da pesquisa por meio de dados e indicadores da literatura científica. (OKUBO, 1997).

A revisão descritiva da literatura tem por objetivo avaliar se os estudos suportam ou revelam padrões ou tendências com relação a proposições, teorias, metodologias ou descobertas existentes. Para cumpri-lo e garantir a generalidade dos resultados, coleta e analisa dados como a frequência de assuntos, autores, anos de publicação, métodos de pesquisa, técnicas de coleta de dados, direcionamentos e robustez de resultados na literatura existente, buscando apresentar o estado da arte em um domínio da pesquisa (PARÉ *et al.*, 2015).

O levantamento vertical busca analisar os modelos no estado da arte identificados no levantamento horizontal e compreender seus conceitos, para então propor questionamentos fundamentados, ou até novos modelos dentro de determinados cortes epistemológicos (CAUCHICK-MIGUEL; FLEURY, 2012).

Neste trabalho, a pesquisa teórico-conceitual sobre dados secundários compreende um levantamento horizontal baseado em análise bibliométrica e uma revisão descritiva da literatura sobre abordagens de DL aplicadas ao AT. O levantamento vertical é realizado mediante análise das abordagens apresentadas pelos artigos selecionados na revisão da literatura.

Foram consultadas as bases bibliográficas: Scopus Elsevier, Web of Science, ACM Digital Libray e IEEE Xplore, apropriadas ao propósito da pesquisa em engenharia e ciência da computação (KITCHENHAM; CHARTERS, 2007; KITCHENHAM *et al.*, 2010).

### **3. RESULTADOS E DISCUSSÃO**

#### **3.1 Análise Bibliométrica**

As bases bibliográficas foram pesquisadas para prospectar a produção científica sobre abordagens de DL aplicadas ao AT, conforme critérios de busca mostrados no Quadro 2:

Quadro 2 – Critérios de busca sobre abordagens de DL aplicadas ao AT

<b>Atributo</b>	<b>Critério</b>
Expressão de Busca	( <i>“Deep Learning”</i> ) AND ( <i>“Algorithmic Trading”</i> OR <i>“High Frequency Trading”</i> OR <i>“Systematic Trading”</i> OR <i>“Quantitative Trading”</i> OR <i>“Automated Trading”</i> OR <i>“Stock Market”</i> OR <i>“Stock Trading”</i> OR <i>“Stock Price”</i> OR <i>“Trading Systems”</i> )
Período	2000 a 2019
Idioma	Inglês
Tipo de Publicação	Artigos primários e secundários de periódicos e conferências
Exclusão Domínios Pesquisa	de Artes e Humanidades, Psicologia, Medicina, Agricultura e Biociências, de Química e Geociências.

Fonte: Autores

O número de documentos retornados pelas bases é apresentado na

Tabela 1.

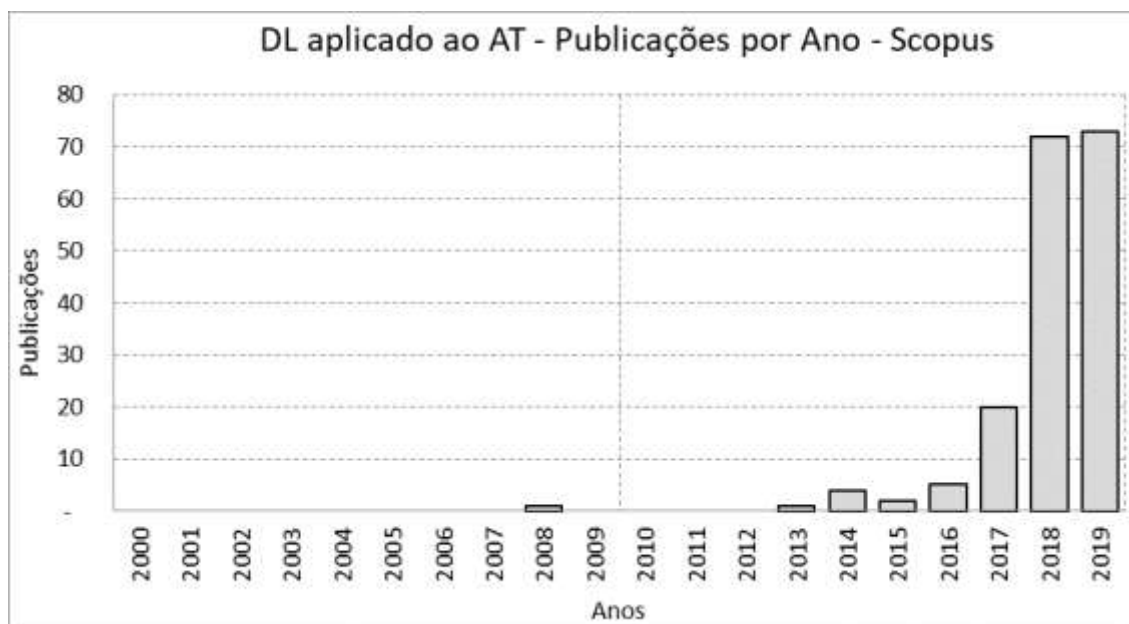
Tabela 1 – Publicações sobre abordagens de DL aplicadas ao AT

Base	Campo	Publicações
Scopus	Títulos, Resumos e Palavras-chave	178
Web of Science	Tópicos	103
ACM Digital Library	Títulos, Resumos e Palavras-chave	20
IEEE Xplore	All-Metadata	107

Fonte: Scopus (2019), Web of Science (2019), ACM Digital Library (2019), IEEE Xplore (2019)

O crescimento de publicações utilizando abordagens de DL aplicadas ao AT com dados da base Scopus é apresentado na Figura 1, e com dados da Web of Science na Figura 2. Observa-se o surgimento de publicações a partir de meados da década de 2010, em 2017 o crescimento se acentua, tornando-se mais significativo a partir de 2018. Os dados de 2019, ainda que parciais, limitados até setembro, revelam um discreto crescimento ou ao menos a manutenção do volume da produção científica.

Figura 1 – Publicações sobre abordagens de DL aplicadas ao AT (Scopus)



Fonte: Scopus (2019)

Figura 2 – Publicações sobre abordagens de DL aplicadas ao AT (Web of Science)



Fonte: Scopus (2019)

Na Tabela 2 são apresentados os percentuais de crescimento das publicações até 2018, nas bases Scopus e Web of Science, nos períodos de 2 anos e 1 ano.

Tabela 2 – Crescimento das publicações sobre abordagens de DL aplicadas ao AT

Períodos	2 anos	1 ano
Bases	2016 a 2018	2017 a 2018
Scopus	1.340 %	260 %
Web of Science	600 %	163 %

Fonte: Scopus (2019) e Web of Science (2019)

A Tabela 3 lista os dez países que mais publicaram abordagens de DL aplicadas ao AT. Cabe destaque para a China ocupando o primeiro lugar na lista, seguida de Estados Unidos e Índia.

Tabela 3 – Dez Países que mais publicaram abordagens de DL aplicadas ao AT


<b>Países</b>	<b>Publicações</b>
<b>China</b>	46
<b>Estados Unidos</b>	20
<b>Índia</b>	19
<b>Japão</b>	13
<b>Coréia do Sul</b>	13
<b>Taiwan</b>	11
<b>Reino Unido</b>	9
<b>Austrália</b>	8
<b>Hong Kong</b>	5
<b>Itália</b>	4

Fonte: Scopus (2019)

O gráfico da

Figura 3 apresenta a participação percentual dos dez países com maior produção científica sobre o tema, conforme a base Scopus.

Figura 3 – Países que mais publicaram abordagens de DL aplicadas ao AT



Fonte: Scopus (2019)

A Tabela 4 apresenta os vinte artigos mais citados dentre os 178 artigos resultantes da busca sobre a base Scopus.

Tabela 4 – Artigos sobre abordagens de DL aplicados ao AT mais citados

Título	Autores	Fonte	Ano	CC	FWCI
<b>Deep learning for event-driven stock prediction</b>	Ding X., et al.	IJCAI Artificial Intelligence	2015	132	22,23
<b>Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies</b>	Chong E., Han C., Park F.C.	Expert Systems with Applications	2017	80	16,77
<b>A deep learning framework for financial time series using stacked autoencoders and long-short term memory</b>	Bao W., Yue J., Rao Y.	PLoS ONE	2017	74	14,62
<b>Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models</b>	Kim H.Y., Won C.H.	Expert Systems with Applications	2018	28	11,12
<b>Big Data: Deep Learning for</b>	Sohangir S.,	Journal of Big	2018	27	9,61

<b>financial sentiment analysis</b>	et al.	Data				
<b>Decision support from financial disclosures with deep neural networks and transfer learning</b>	Kraus M., Feuerriegel S.	Decision Support Systems	2017	25	5,47	
<b>Forecasting stock prices from the limit order book using convolutional neural networks</b>	Tsantekidis A., et al.	IEEE Business Informatics	2017	21	16,26	
<b>Artificial neural networks architectures for stock price prediction: Comparisons and applications</b>	Di Persio L., Honchar O.	Journl Circuits, Systems and Signal Processing	2016	19	2,27	
<b>Listening to chaotic whispers: A deep learning framework for news-oriented Stock trend prediction</b>	Hu Z., et al.	WSDM - ACM Web Search Data Mining	2018	18	26,08	
<b>An innovative neural network approach for stock market prediction</b>	Pang X., et al.	Journal of Supercomputing	2018	18	13,61	
<b>Predicting stock market trends by recurrent deep neural networks</b>	Yoshihara A., et al.	Computer Science	2014	18	1,42	
<b>Stock price prediction using LSTM, RNN and CNN-sliding window model</b>	Selvin S., et al.	Computing, Communications and Informatics	2017	17	8,96	
<b>Deep learning for stock market prediction from financial news articles</b>	Vargas M.R., Lima B.S.L.P., Evsukoff A.G.	IEEE Comput Intelligenc Virtual E M S A	2017	17	10,72	
<b>Stock prediction using deep learning</b>	Singh R., Srivastava S.	Multimedia Tools and Applications	2017	16	3,14	
<b>Financial time-series data analysis using deep convolutional neural networks</b>	Chen J.-F., et al.	Cloud Computing and Big Data	2017	16	6,91	
<b>A stock decision support system based on DBNs</b>	Zhu C., Yin J., Li Q.	Computational IS	2014	14	1,02	
<b>Deep neural networks for bot detection</b>	Kudugunta S., Ferrara E.	Information Sciences	2018	13	4,86	
<b>Query-less: Predicting task repetition for nextgen proactive search and recommendation engines</b>	Song Y., Guo Q.	International WWW	2016	12	2,97	
<b>Forecasting stock market crisis events using deep and statistical machine learning techniques</b>	Chatzis S.P., et al.	Expert Systems with Applications	2018	10	4,00	
<b>Intraday prediction of Borsa Istanbul using convolutional neural networks and feature correlations</b>	Gunduz H., Yaslan Y., Cataltepe Z.	Knowledge-Based Systems	2017	10	1,49	

Fonte: Scopus (2019)

Os autores mais citados dentre os 178 artigos são apresentados na Tabela 5, contendo também o número de publicações, a contagem de citações, a razão do número de citações por número de publicações e o índice-h.

Tabela 5 – Autores sobre abordagens de DL aplicados ao AT mais citados

<b>Autor</b>	<b>Instituição Afiliação</b>	<b>País</b>	<b>Publicações</b>	<b>Citações</b>	<b>C/P</b>	<b>Índice-h</b>
<b>Khoshgoftaar, T.</b>	Florida Atlantic U.	EUA	610	11.114	18,2	53
<b>Gabbouj, M.</b>	Tampere U. Techn.	Finlândia	599	7.373	12,3	37
<b>Liu, T-Y.</b>	Microsoft Resrch Asia	China	187	5.986	32,0	35
<b>Liu, T.</b>	Harbin Inst Technology	China	246	3.831	15,6	27
<b>Tefas, A.</b>	Aristotle Thessaloniki U.	Grécia	314	3.500	11,1	29
<b>Park, F. C.</b>	Seoul National University	Coréia do Sul	158	3.479	22,0	29
<b>Chang, V.</b>	Teesside University	Reino Unido	250	2.811	11,2	28
<b>Ferrara, E.</b>	U. Southern California	EUA	100	2.778	27,8	29
<b>Yin, J.</b>	Dongguan Technology U.	China	262	2.145	8,2	23
<b>Zhang, Y.</b>	Hunan University	China	89	1.792	20,1	21
<b>Soman, K. P.</b>	Amrita Sch.Engineering	Índia	447	1.766	4,0	16
<b>Wang, D.</b>	Florida Atlantic U.	EUA	61	1.759	28,8	20
<b>Iosifidis, A.</b>	Aarhus Universitet	Dinamarca	123	1.210	9,8	18
<b>Bian, J.</b>	Microsoft Research Asia	China	42	1.116	26,6	15
<b>Song, Y.</b>	Google LLC	EUA	28	1.044	37,3	17
<b>Liu, X.</b>	Peking University	China	100	1.022	10,2	18
<b>Chatzis, S.P.</b>	Cyprus U. Technology	Chipre	88	921	10,5	15
<b>Feuerriegel, S.</b>	ETH Zürich	Suíça	60	520	8,7	14

Fonte: Scopus (2019)

### 3.2 Revisão Descritiva da Literatura

Para o estudo das frentes de pesquisa das abordagens de DL aplicadas ao AT, foram considerados os títulos, palavras-chave e resumos dos 50 artigos mais citados resultantes da busca da análise bibliométrica sobre as quatro bases. O critério de ordenação de artigos considerou a soma de citações nestas bases. A seleção dos documentos foi realizada mediante leitura dos resumos, obedecendo aos critérios apresentados no Quadro 3.

Quadro 3 – Critérios de seleção sobre abordagens de DL aplicadas ao AT

<b>Tipo de Critério</b>	<b>Critério</b>
Inclusão	Conteúdo se concentra em abordagens de DL aplicadas ao AT Conteúdo apresenta aspectos relevantes sobre abordagens de DL aplicadas ao AT
Exclusão	Conteúdo fora da área de interesse ou marginalmente relacionado ao tema de busca Documento não disponível para consulta online Documento duplicado

Fonte: Autores

Os artigos resultantes foram analisados quanto aos dados de entrada, objetivos de saída, abordagens e desempenho.

#### Dados de Entrada

Os dados de entrada mais frequentemente utilizados são os dados de mercado, compostos pelas informações dos livros de ordens e pelas informações de negócios realizados, como ativo, preço, quantidade e natureza (compra ou venda) e horários de execução (*timestamps*). São séries temporais não lineares e não estacionárias, cuja predição encontra-se entre as aplicações de DL (GUO, 2017; PRADO, 2018).

As notícias, em especial as de impacto econômico, podem ser objeto dos métodos de DL aplicados à interpretação de textos e à análise de sentimento (VARGAS; LIMA; EVSUKOFF, 2017; HU *et al.*, 2018; SOHANGIR; WANG; POMERANETS; KHOSHGOFTAAR, 2018).

Produzidos por softwares especializados, os indicadores da Análise Técnica resultam de transformações dos dados de mercado em características e padrões secundários, como médias móveis, formação de figuras, retas de suporte e resistência, entre outros (MURPHY, 1999; KHARE; DAREKAR; GUPTA; ATTAR, 2017).

A frequência de ocorrência das fontes de dados de entrada e a classificação por tipo são apresentadas na Tabela 6, em que um artigo pode apresentar mais de uma fonte de dados.

Tabela 6 – Fontes de dados das abordagens

<b>Fontes de Dados</b>	<b>Tipo de Dado</b>	<b>Número de Artigos</b>
<b>Preços de Mercado</b>	Dados de Mercado	45
<b>Notícias</b>	Dados Alternativos	10
<b>Indicadores de Análise Técnica</b>	Dados Analíticos	5
<b>Balancos e Demonstrativos</b>	Dados Fundamentais	4
<b>Redes Sociais</b>	Dados Alternativos	1
<b>Volatilidade</b>	Dados de Mercado	1

Fonte: Resultado da Pesquisa

## Objetivos de Saída

O desempenho de uma estratégia de AT é avaliado por meio da variável de saída, ou objetivo de saída (*target output*), comparado ao desempenho das abordagens de referência (*baseline methods*) que podem ser as tradicionais (sem técnicas de aprendizado) ou as de ML. A Tabela 7 mostra os objetivos de saída das abordagens analisadas e sua frequência de ocorrência:

Tabela 7 – Objetivos de saída das abordagens

<b>Objetivo de Saída (Target Output)</b>	<b>Número de Artigos</b>
<b>Preço do Ativo</b>	31
<b>Direção da Tendência</b>	10
<b>Indicação de Compra ou Venda</b>	4
<b>Detecção de Crise</b>	1
<b>Detecção Falência</b>	1
<b>Escolha de Ativo</b>	1
<b>Volatilidade</b>	1
<b>Polaridade do Sentimento</b>	1

Fonte: Resultado da Pesquisa

O objetivo de saída mais frequentemente utilizado é o Preço do Ativo, em que a abordagem busca prever um preço alvo, ou um intervalo de preços, a ser atingido dentro de um determinado prazo (CHONG; HAN; PARK, 2017). A direção da tendência busca apenas indicar se os preços apresentarão comportamento de alta ou baixa, sem especificar valores ou faixas de valores. As indicações de compra ou venda, buscam prever os momentos para assumir posições compradas ou vendidas em razão da ocorrência de configurações características da análise técnica como pontos de inflexão (MURPHY, 1999; VIDYAMURTHY, 2004).

As abordagens que visam à identificação de crises buscam nos dados de mercado, divulgações corporativas e notícias uma indicação de risco sistemático. A predição de falência busca nos dados informações sobre riscos e chances de falência de uma empresa, enquadrando-se na predição de riscos não sistemáticos. A seleção algorítmica de ativos auxilia o gestor de carteiras (*portfolio manager*) a compor o conjunto de ativos que maximiza seu desempenho de acordo com o enquadramento legal e as características do risco que seu fundo de investimento ou carteira pode assumir (ELTON; GRUBER, 1995; ROSS; WESTERFIELD; JAFFE, 2011).

As indicações de volatilidade são utilizadas por estratégias baseadas na precificação da volatilidade implícita de opções. Tais estratégias assumem posições compradas e

vendidas em opções sobre ações, índices e outros ativos financeiros (HULL, 2018; NATENBERG, 1994; TALEB, 1997). Podem também ser utilizadas por ferramentas da análise técnica como as bandas de Bollinger (MURPHY, 1999).

## Abordagens

A Tabela 8 mostra as abordagens encontradas nos artigos e suas frequências de ocorrência. Um artigo pode eventualmente utilizar mais de uma abordagem. As abordagens de DL mais frequentes são a LSTM e a CNN.

Tabela 8 – Frequência de Abordagens de DL em artigos de AT

Abordagens	Abreviação	Número de Artigos
<i>Long Short-Term Memory</i>	LSTM	21
Redes Neurais Convolucionais	CNN	20
Redes Neurais Profundas	DNN	10
<i>Gated Recurrent Unit</i>	GRU	3
Redes Neurais Recorrentes	RNN	3
<i>Stacked Autoencoders</i>	SAE	2
Máquina de Boltzmann Restrita	RBM	2
<i>Deep Belief Networks</i>	DBN	1
Redes Neurais Convolucionais Recorrentes	RCNN	1

Fonte: Resultado da Pesquisa

A

Tabela 9 mostra a ocorrência de abordagens de DL por objetivo de saída. Esta forma de visualização permite identificar as abordagens mais utilizadas para cada objetivo de saída.

Tabela 9 – Abordagens de DL por objetivo de saída

Objetivo de Saída	Abordagem de DL	LST M	CNN	DNN	GRU	RNN	SAE	RB M	DBN	RCNN
Preço		15	11	6	2	3	2			
Direção		4	6	2	1			1		1
Ponto de Compra/Venda		1	1	1					1	
Seleção de Ativos			1							
Detecção de Falência			1							
Detecção de Crise				1						
Polaridade do Sentimento								1		
Volatilidade		1								
<b>Total das Abordagens</b>		<b>21</b>	<b>20</b>	<b>10</b>	<b>3</b>	<b>3</b>	<b>2</b>	<b>2</b>	<b>1</b>	<b>1</b>

Fonte: Resultado da Pesquisa

Dos 50 artigos selecionados na revisão da literatura, 47 apresentam avaliação positiva do desempenho do DL comparativamente às abordagens de ML ou tradicionais (não-ML), seja quanto à precisão ou à eficiência. Três artigos avaliaram o DL negativamente, ou com desempenho inferior às demais, conforme Tabela 10.

Tabela 10 – Avaliação geral de desempenho do DL

Avaliação	Frequência
Positiva	47
Negativa	3

Fonte: Resultado da Pesquisa

Dentre as abordagens mais frequentes de DL, o LSTM e o CNN apresentam 19 avaliações de desempenho favoráveis, com duas desfavoráveis para LSTM e uma para CNN. A avaliação de desempenho das abordagens é apresentada na Tabela 11.

As estratégias orientadas à previsão de preços indicam utilização mais frequentemente da LSTM, seguida da CNN, com uma frequência menor para a DNN no sentido estrito, isto é, excluindo LSTM e CNN. As estratégias direcionais se concentram também na CNN e LSTM.

Tabela 11 – Avaliação de desempenho das abordagens

Abordagens	Abreviação	Positiva	Negativa
<i>Long Short-Term Memory</i>	LSTM	19	2
Redes Neurais Convolucionais	CNN	19	1
Redes Neurais Profundas	DNN	9	1
<i>Gated Recurrent Unit</i>	GRU	3	
Redes Neurais Recorrentes	RNN	3	
<i>Stacked Autoencoders</i>	SAE	2	
Máquina de Boltzmann Restrita	RBM	2	
<i>Deep Belief Networks</i>	DBN	1	
Redes Neurais Convolucionais Recorrentes	RCNN	1	

Fonte: Resultado da Pesquisa

### 3.3 Análise das abordagens

A preferência pela LSTM entre os artigos selecionados encontra fundamentação na sua capacidade de extração de características a partir de sequências ordenadas e capturar relações não lineares dos sinais temporais dos preços das ações (KRAUS; FEUERRIEGEL, 2017).

Embora as RNNs sejam adequadas a modelagem de séries temporais, o aprendizado é dificultado pelo problema do *vanishing gradient*, com variações nos pesos cada vez menores, impedindo, assim, a rede neural de continuar o aprendizado. A LSTM, um caso particular de RNN, torna a análise de séries dependentes do tempo mais eficiente, por sua capacidade de guardar informações passadas, e evita o *vanishing gradient* utilizando células de memória, que utilizam portas para controlar as interações

com as células vizinhas e seu próprio estado (BAO; YUE; RAO, 2017; SELVIN et al., 2017).

As CNNs são abordagens se caracterizam pela especialização de redes neurais que atuam sobre dados armazenados em matrizes de grandes dimensões (GOODFELLOW; BENGIO; COURVILLE, 2016). Têm sido utilizadas na predição em finanças porque preservam as características de tendências sem perder as informações da microestrutura dos mercados, aproveitando a totalidade dos dados e eventos dos LOBs, extraindo de forma mais precisa os padrões recorrentes em cada intervalo de tempo (TSANTEKIDIS et al., 2017).

O Quadro 4 apresenta uma síntese das abordagens mais frequentes, LSTM e CNN, seus conceitos, aplicações gerais, aplicações específicas a sistemas de AT, tipos de estratégias, frequência de ocorrência da abordagem, objetivos de saída e avaliações de desempenho.

Quadro 4 – Abordagens de Deep Learning aplicadas ao AT

Abordagens de DL	Memória de Curto Prazo Extensa (LSTM)	Redes Neurais Convolucionais (CNN)
Conceitos Gerais	Baseadas em Redes Neurais Recorrentes em conjunto com algoritmos de aprendizado baseados em gradiente (HOCHREITER; SCHMIDHUBER, 1997).	Baseadas em Redes Neurais Multi-camadas, treinadas em algoritmo especial de retro-propagação (LECUN; BENGIO, 1995).
Aplicações Gerais	Classificação, processamento e predição sobre séries temporais não-lineares, guarda informações passadas. Evita o <i>vanishing gradient</i> (WIERSTRA; SCHMIDHUBER; GOMEZ, 2005; BAO; YUE; RAO, 2017; SELVIN et al., 2017).	Reconhecimento de padrões visuais a partir de pixels de imagens com mínimo processamento (LECUN; BENGIO, 1995).
Aplicações em AT	Aplicável a dados sequenciais, como séries temporais. Por exemplo: séries de preços, volatilidades, médias móveis (KRAUS; FEUERRIEGEL, 2017).	Aplicável a dados não-estacionários, não lineares, característicos da microestrutura do mercado, como os livros de ordens limitadas de ações durante um pregão eletrônico (TSANTEKIDIS et al., 2017).

Tipos de Estratégias	de	Previsão de preços de ativos, direção de tendências, recomendações de compra e venda.	Previsão de preços de ativos, direção de tendências, recomendações de compra e venda, escolha de ativos, previsão de falência
Ocorrência entre artigos selecionados		21 artigos	20 artigos
Objetivos de Saída	de	Preço, Direção, Ponto de Compra ou Venda, Volatilidade.	Preço, Direção, Ponto de Compra ou Venda, Seleção de Ativos, Indicador de Falência.
Desempenho		19 avaliações positivas e 2 negativas	19 avaliações positivas e 1 negativa

Fonte: Resultado da Pesquisa

#### 4. Considerações finais

A análise bibliométrica revelou que a produção científica sobre o tema se desenvolveu a partir de 2016 e 2017, apresentando volume significativo em 2018 e 2019, segundo a base Scopus, com mais de 70 artigos por ano, indicando interesse recente e consistente por parte da comunidade acadêmica. A China lidera em número de publicações, seguida de Estados Unidos e Índia, com participações de 26%, 11% e 11% respectivamente. Desta análise também foram extraídos os artigos mais citados e os fatores de impacto dos periódicos. A lista dos autores mais citados mostrou que determinados pesquisadores recebem muitas citações sobre um pequeno volume de artigos. Esta relação sugere um indicador de produtividade diferenciado da contagem de citações e do índice-h.

A revisão descritiva da literatura evidenciou que os dados de entrada de preferência dos pesquisadores são os dados de mercado, seguidos das notícias. Os objetivos de saída de escolha são os preços dos ativos, seguidos da direção da tendência e da indicação de compra ou venda, com frequência bem menor. As abordagens mais utilizadas nos artigos selecionadas são a LSTM e a CNN. Mais de 90% dos artigos apresentam avaliação positiva comparadas às abordagens tradicionais ou de ML.

A preferência pela LSTM se fundamenta na sua capacidade de extração de características das relações não lineares dos sinais temporais dos preços das ações,

da seletividade na retenção das informações passadas relevantes e descarte das não relevantes, e da possibilidade de eliminar o *vanishing gradient*. A preferência pelas CNNs se explica pela atuação sobre dados armazenados em matrizes de grandes dimensões, que preservam as características de tendências sem perder as informações da microestrutura dos mercados.

Esta pesquisa buscou apresentar o estado da arte dos estudos sobre DL aplicados ao AT, identificando os artigos mais relevantes extraídos de quatro bases apropriadas à prospecção sobre o tema, por critérios de contagem de citações e aderência à questão de pesquisa. Como possíveis desdobramentos deste trabalho, sugerem-se estudos comparativos sobre outros ativos negociados nos mercados locais, bem como a implementação de protótipos de software com as abordagens analisadas, em especial CNN, LSTM e GRU.

## Referências

ACM Digital Library (2019). Acesso em 30 set. 2019. Disponível em <  
<https://dlnext.acm.org/>>

BAO, W.; YUE, J.; RAO, Y. A deep learning framework for financial time series using stacked autoencoders and long-short term memory. **PLoS ONE**, 2017.

BENGIO, Y.; COURVILLE, A.; PASCAL, V. Representation learning: a review and new perspectives. **ArXiv e-prints**, 2012.

BERTO, R.M.V.S.; NAKANO, D.N. A produção científica nos anais do Encontro Nacional de Engenharia de Produção: um levantamento de métodos e tipos de pesquisa. **ABEPRO Produção**, v. 9, n. 2, p. 65-76, 2000.

BROGAARD, J.; HENDERSHOTT, T.; RIORDAN, R. High-Frequency Trading and the 2008 short-sale ban. **Journal of Financial Economics**. v. 124, 2017.

BRYMAN, A.; BELL, E. **Business Research Methods**. 3 ed. Oxford University Press, 2011.

CAUCHICK-MIGUEL, P. A.; FLEURY, A. **Metodologia De Pesquisa em Engenharia de Produção**. 2ª.ed. Capítulo 2 – Planejamento do Projeto de Pesquisa e Definição do Modelo Teórico. Elsevier, 2012.

CAVALCANTE, C. C. et al. Computational Intelligence and Financial Markets: A Survey and Future Directions. **Expert Systems with Applications**. v 55, 2016.

CHABOUD, A. P.; CHIQUUOINE, B.; HJALMARSSON, E.; VEGA, C. Rise of the Machines: Algorithmic Trading in the Foreign Exchange Market. **The Journal of Finance**. v. 69, n. 5, 2014.

CHAN, E. P. **Quantitative trading: how to build your own algorithmic trading business**. Wiley, 2009.

CHONG, E.; HAN, H.; PARK, F. C. Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. **Expert Systems with Applications**, v. 83, pp. 187-205, 2017.

CRESWELL, J. W. Research Design. **Qualitative, Quantitative, and Mixed Methods Approaches**. SAGE Publications, 2014.

DAMODARAN, A. **Investment Valuation. Tools and Techniques for Determining the Value of Any Asset**. 3rd ed. New Jersey: John Wiley & Sons, 2012.

EASLEY, D.; PRADO, M. M. L.; O'HARA, M. The Microstructure of the 'Flash Crash'. Flow toxicity, Liquidity Crashes and the Probability of Informed Trading. **The Journal of Portfolio Management**, v. 37, n. 2, p. 118-128, 2011.

ELTON, E.; GRUBER, M. **Modern Portfolio Theory and Investment Analysis**. 5 ed. New York: Wiley, 1995.

FILIPPINI, R. Operations management research: some reflections on evolution, models and empirical studies in OM. **International Journal of Operations and Production Management**, v. 17, n.7, p. 655-70, 1997.

FIX TRADING. FIX Protocol. Disponível em: <[www.fixtrading.org](http://www.fixtrading.org)>. Acesso em 07 jun. 2018.

GADRE-PATWARDHAN, S.; KATDARE V. V.; JOSHI M. R. A Review of Artificially Intelligent Applications in the Financial Domain. Cap. 1 in DUNIS, C. L.; MIDDLETON, P. W.; KARATHANASOPOULOS, A.; THEOFILATOS, K. **Artificial Intelligence in Financial Markets**. Palgrave MacMillan, 2016.

GOODEFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press, 2016.

GUO, X.; LAI, T. L.; SHEK, H.; WONG, S. P. **Quantitative trading - Algorithms, Analytics, Data, Models, Optimization**. CRC Press. Taylor & Francis Group, 2017.

HARVARD UNIVERSITY - IACS (INSTITUTE for APPLIED COMPUTATIONAL SCIENCE). Symposium Data, Dollars, and Algorithms: The Computational Economy. Publ. 19-jan-2017. Disponível em: <[iacs.seas.harvard.edu/event/annual-iacs-symposium-data-dollars-and-algorithms-computational-economy?delta=0](http://iacs.seas.harvard.edu/event/annual-iacs-symposium-data-dollars-and-algorithms-computational-economy?delta=0)> Acesso em 19-set-2018.

HASBROUCK, J.; SAAR, G. Low-latency trading. **Journal of Financial Markets**. v. 16, 2013.

HENDERSHOTT, T.; JONES, C. M.; MENKVELD, A. J. Does Algorithmic Trading Improve Liquidity? The **Journal of Finance**. v. 66 n. 1, 2011.

HENDERSHOTT, T.; RIORDAN, R. Algorithmic Trading and the Market for Liquidity. **Journal of financial and quantitative analysis**. v. 48, n. 4, p. 1001–1024, 2013.

HILPISCH, Y. **Algorithmic Trading in Less Than 100 Lines of Python Code**. 2018. Disponível em <[www.Oreilly.Com/Learning/Algorithmic-Trading-In-Less-Than-100-Lines-Of-Python-Code](http://www.Oreilly.Com/Learning/Algorithmic-Trading-In-Less-Than-100-Lines-Of-Python-Code)> Acesso em 19 Set. 2018.

HOCHREITER, S.; SCHMIDHUBER, J. Long Short-Term Memory. **Neural Computation**, 1997.

HU, Z.; LIU, W.; BIAN, J.; LIU, X.; LIU, T-Y. Listening to Chaotic Whispers: A Deep Learning Framework for News-oriented Stock Trend Prediction. **ACM Web Search and Data Mining**, feb, 2018 .

HULL, J. **Options, Futures, and Other Derivatives**. 10th ed. Pearson, 2018.

IEEE Spectrum. Hedge Funds Look to Machine Learning, Crowdsourcing for Competitive Advantage. 2017. Disponível em: <<https://spectrum.ieee.org/tech-talk/computing/software/fintech-trends-hedge-funds-look-to-machine-learning-crowdsourcing-for-competitive-advantage>> Acesso em 18 abr. 2019.

IEEE Xplore. Acesso em 30 set. 2019. Disponível em <<https://ieeexplore.ieee.org>> (2019).

JOHNSON, B. **Algorithmic Trading & DMA – An introduction to direct access trading strategies**. London: 4MyelomaPress, 2010.

KAUFMAN, P. J. **Trading Systems and Methods**. 5 ed. Wiley, 2013.

KEARNS, M.; NEVMYVAKA, Y. Machine Learning for Market Microstructure and High-Frequency Trading. In: EASLEY, D.; PRADO, M. M. L.; O'HARA, M. (Orgs.) **High-Frequency Trading: New Reality for Traders, Markets and Regulators**. Risk Books, 2013.

KHARE, K.; DAREKAR, O.; GUPTA, P.; ATTAR, V. Z. Short Term Stock Price Prediction using Deep Learning. **2nd IEEE International Conference on Recent Trends in Electronics, Information and Communication Technology, Proceedings - RTEICT 2017**, pp. 482-486, 2017.

KITCHENHAM, B. A.; CHARTERS, S. Guidelines for performing systematic literature reviews in software engineering. version 2.3. **EBSE Technical Report – Keele University – University of Durham**, 2007.

KITCHENHAM, B. A. *et al.*; Systematic literature reviews in software engineering – A tertiary study. **Information and Software Technology**, v. 52, pp. 792-805, 2010.

KRAUS, M.; FEUERRIEGEL, S. Decision support from financial disclosures with deep neural networks and transfer learning. **Decision Support Systems**, v. 104, pp. 38-48, 2017.

LÄNGKVIST, M.; KARLSSON, L.; LOUTFI, A. A review of unsupervised feature learning and deep learning for time-series modeling. **Pattern Recognition Letters**. v. 42, pp. 11-24. 2014.

LECUN, Y.; BENGIO, Y. Convolutional Networks for Images, Speech, and Time-Series. **The handbook of brain theory and neural networks**. MIT Press, 1995.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep Learning. **Nature**. Vol. 521, pp.436-444, 2015.

MIT TECHNOLOGY REVIEW. As Goldman Embraces Automation, Even the Masters of the Universe Are Threatened. Nanette Byrnes. 7 fev. 2017. Disponível em [www.technologyreview.com/s/603431/as-goldman-embraces-automation-even-the-masters-of-the-universe-are-threatened/](http://www.technologyreview.com/s/603431/as-goldman-embraces-automation-even-the-masters-of-the-universe-are-threatened/)>. Acesso em 7 jun. 2018.

MURPHY, J. **Technical Analysis of the Financial Markets**. New York: Penguin Putnam, 1999.

NATENBERG, S. **Option Volatility & Pricing. Advanced Trading Strategies and Techniques**. McGraw-Hill, 1994.

NUTI, G.; MIRGHAEMI, M.; TRELEAVEN, P.; YINGSAEREE, C. Algorithmic trading. **Computer-IEEE Computer Society**, v. 44, n. 11, p. 61-69, 2011.

OKUBO, Y. **Bibliometric Indicators and Analysis of Research Systems: Methods and Examples**. Paris: OECD Publishing, 1997.

PARÉ, G.; TRUDEL, M-C.; JAANA, M.; KTSIOU, S. Synthesizing information systems knowledge: A typology of literature reviews. **Information and Management**. v. 52, n. 2, p 183-199, 2005.

PRADO, M. L. **Advances in Financial Machine Learning**. John Wiley & Sons, 2018.

ROSS, S. A.; WESTERFIELD, R. W.; JAFFE, J. F. **Administração Financeira – Corporate Finance**. São Paulo: ATLAS, 2011.

RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence - A Modern Approach**. 3rd. ed. Pearson, 2016

SAUNDERS, M.; LEWIS, P; THORNHILL, A. **Research Methods for Business Students**. 6th edition, Pearson Education Limited. 2012

SCHMIDHUBER, J. Deep learning in neural networks. **Neural Networks**. Vol. 61, p.85-117, 2014.

SCOPUS – ELSEVIER Disponível em <[www.scopus.com](http://www.scopus.com)>. Acesso em 30 Set. 2019.

SELVIN, S. et al. Stock price prediction using LSTM, RNN and CNN-sliding window model. **Computing, Communications and Informatics**, 2017.

SOHANGIR, S.; WANG, D.; POMERANETS, A.; KHOSHGOFTAAR, T. M. Big Data: Deep Learning for financial sentiment analysis. **Journal of Big Data**, 2018.

TAKEUCHI, L.; LEE, Y-Y. Applying Deep Learning to Enhance Momentum Trading Strategies in Stocks. **Stanford.edu**, 2013.

TALEB, N. **Dynamic Hedging. Managing Vanilla and Exotic Options**. New York: John Wiley & Sons, 1997.

TSANTEKIDIS, A. et al. Forecasting stock prices from the limit order book using convolutional neural networks. **2017 IEEE 19th Business Informatics**, 2017.

VAN MAANEN, J. Reclaiming Qualitative Methods for Organizational Research. **Administrative Science Quartely**, v. 24, p. 520-526, dez. 1979.

VARGAS. M. R.; LIMA, B. S. L. P.; EVSUKOFF, A. G. Deep learning for stock market prediction from financial news articles. **2017 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications, CIVEMSA 2017**, p. 60-65, 2017.

VIDYAMURTHY, G. **Pairs Trading. Quantitative Methods and Analysis**. New Jersey: Wiley, 2004.

WIERSTRA, D.; SCHMIDHUBER, J.; GOMEZ, F. J. Evolino: Hybrid Neuroevolution/Optimal Linear Search for Sequence Learning. **Proceedings of the 19th International Joint Conference on Artificial Intelligence (IJCAI)**, Edinburgh: pp. 853–858, 2005.

WEB OF SCIENCE – CLARIVATE ANALYTICS Disponível em <[www.webofknowledge.com](http://www.webofknowledge.com)>. Acesso em 30 Set. 2019.

