



Universidade de Brasília (UnB)
Faculdade de Economia, Administração e Contabilidade e Gestão de Políticas Públicas
(FACE)
Departamento de Ciências Contábeis e Atuariais (CCA)
Bacharelado em Ciências Contábeis

GEOVANNA COSTA SANTOS FERNANDES

Uma Análise Bibliométrica da Pesquisa da Inteligência Artificial no Mercado Financeiro

Brasília, DF
2023

GEOVANNA COSTA SANTOS FERNANDES

Uma Análise Bibliométrica da Pesquisa da Inteligência Artificial no Mercado Financeiro

Trabalho de Conclusão de Curso (Monografia ou Artigo) apresentado ao Departamento de Ciências Contábeis e Atuariais da Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas da Universidade de Brasília como requisito parcial de obtenção do grau de Bacharel em Ciências Contábeis.

Prof^a. Responsável:
Danielle Montenegro Salamone Nunes

Linha de pesquisa:
Impactos da Contabilidade na Sociedade

Área:
Ensino e Pesquisa em Contabilidade

Brasília, DF
2023

Ci

Costa Santos Fernandes, Geovanna

Uma Análise Bibliométrica da Pesquisa da Inteligência Artificial no Mercado Financeiro/ Geovanna Costa Santos Fernandes; orientador Danielle Montenegro Salamone Nunes. - Brasília, 2023.

58 p.

Monografia (Graduação - Ciências Contábeis) --
Universidade de Brasília, 2023.

1. Inteligência Artificial. 2. Mercado Financeiro. 3. Finanças. 4. Bibliometria. I. Montenegro Salamone Nunes, Danielle, orient. II. Título.

Professora Doutora Márcia Abrahão Moura
Reitora da Universidade de Brasília

Professor Doutor Enrique Huelva Unternbäumen
Vice-Reitor da Universidade de Brasília

Professor Doutor Diêgo Madureira de Oliveira
Decano de Ensino de Graduação

Professor Doutor José Márcio Carvalho
Diretor da Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas
Públicas

Professor Doutor Sérgio Ricardo Miranda Nazaré
Chefe do Departamento de Ciências Contábeis e Atuarias

Professor Doutor Alex Laquis Resende
Coordenador de Graduação do curso de Ciências Contábeis - Diurno

Professor Doutor Wagner Rodrigues dos Santos
Coordenador de Graduação do curso de Ciências Contábeis - Noturno

GEOVANNA COSTA SANTOS FERNANDES

UMA ANÁLISE BIBLIOMÉTRICA DA PESQUISA DA INTELIGÊNCIA ARTIFICIAL
NO MERCADO FINANCEIRO

Trabalho de Conclusão de Curso (Monografia ou Artigo) apresentado ao Departamento de Ciências Contábeis e Atuariais da Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas da Universidade de Brasília como requisito parcial de obtenção do grau de Bacharel em Ciências Contábeis.

Prof^a. Danielle Montenegro Salamone Nunes
Orientadora
Departamento de Ciências Contábeis e Atuariais
Universidade Brasília (UnB)

Prof. Claudio Moreira Santana
Examinador
Departamento de Ciências Contábeis e Atuariais
Universidade de Brasília (UnB) ou outra instituição

BRASÍLIA, DF
2023

Dedico este trabalho aos meus pais,
Conceição de Maria Santos e José Arnô
Fernandes, com gratidão.

AGRADECIMENTOS

Deixo os meus sinceros agradecimentos à minha mãe, Conceição de Maria, ao meu pai, José Arnô, à minha tia Rosana Tereza, à minha tia Tereza, ao meu padrinho Antônio Carlos e ao meu primo Bruno Santos; pelo apoio e incentivo em todos os anos da minha graduação e por sempre estarem presentes quando eu mais precisei, fornecendo suporte emocional nos momentos de desafio. Além disso, agradeço por não serem apenas minha família, mas por também serem uma fonte constante de amor, compreensão e carinho. Fazer parte da família de vocês é uma bênção.

Aos amigos que fiz durante o período que estive na universidade, esses anos foram especiais, e boa parte disso se deve à amizade que construímos. Vocês foram mais do que colegas de classe, foram parte essencial da minha experiência. Quero dedicar uma menção especial à Giovana Mendes. Reencontrá-la da época do colégio foi uma alegre surpresa, e desde então, compartilhamos diversos momentos, tanto os difíceis quanto os prazerosos, ao longo dessa trajetória acadêmica. Espero levar essa amizade que construímos para o resto da minha vida.

A todos os meus professores da graduação do departamento de Ciências Contábeis e Atuariais (CCA) pela dedicação, conhecimento e orientação que proporcionaram ao longo do meu percurso acadêmico. Cada um de vocês desempenhou um papel fundamental na minha formação. Em particular, quero estender minha gratidão à professora Danielle Montenegro. Sua orientação, conselhos e ensinamentos foram verdadeiramente essenciais para o desenvolvimento da minha pesquisa.

Por fim, expresso minha profunda gratidão à Universidade de Brasília (UnB) pela valiosa oportunidade de realizar minha graduação nesta renomada instituição. Sou grata pela qualidade do ensino e pelos recursos disponibilizados, que contribuíram significativamente para o meu desenvolvimento acadêmico.

RESUMO

A inteligência artificial tem transformado o mercado financeiro, proporcionando aplicações inovadoras e implicando diversas mudanças. Neste contexto, o trabalho visa apresentar os resultados de um estudo cujo propósito foi identificar o perfil das publicações acadêmicas relacionadas à inteligência artificial no mercado financeiro, no período de 2016 a 2022. Para alcançar seus objetivos, foi adotada uma abordagem quantitativa, com foco em uma pesquisa documental que utiliza análise bibliométrica. O estudo analisou um total de 48 artigos, revelando uma tendência de crescimento na produção científica, com 38 artigos (79,17%) publicados nos últimos cinco anos. Dentre as publicações, o artigo *A deep learning framework for financial time series using stacked autoencoders and long-short term memory*, de Wei Bao, Jun Yue e Yulei Rao, destacou-se como o mais citado entre as publicações analisadas. O periódico *Expert Systems with Applications* possuiu o maior número de autorias. Em termos de afiliações, a China emergiu como o país com a maior participação no número de autorias, e as instituições mais produtivas foram a Central South University of Forestry & Technology e a Zhejiang University, ambas localizadas na China. O presente trabalho pode ser utilizado em pesquisas futuras sobre o tema inteligência artificial no mercado financeiro, pois proporciona uma visão abrangente da produção acadêmica recente, identificando o impacto, a produtividade, os autores, as instituições, as áreas de pesquisa, as tendências e as inter-relações entre as publicações científicas.

Palavras-chave: Inteligência Artificial; Mercado Financeiro; Bibliometria; Finanças.

ABSTRACT

Artificial intelligence has transformed the financial market, providing innovative applications and implying various changes. In this context, the study aims to present the research results whose purpose was to identify the profile of academic publications related to artificial intelligence in the financial market, from 2016 to 2022. To achieve its objectives, a quantitative approach was adopted, focusing on documentary research that employs bibliometric analysis. The study analyzed a total of 48 articles, revealing a trend of growth in scientific production, with 38 articles (79.17%) published in the last five years. Among the publications, the article A deep learning framework for financial time series using stacked autoencoders and long-short term memory, by Wei Bao, Jun Yue and Yulei Rao, stood out as the most cited among the analyzed publications. The journal Expert Systems with Applications had the highest number of authorships. Regarding affiliations, China emerged as the country with the highest participation in the number of authorships, and the most productive institutions were the Central South University of Forestry & Technology and Zhejiang University, both located in China. This study can be used in future research on artificial intelligence in the financial market, as it provides a comprehensive overview of recent academic production. It identifies the impact, productivity, authors, institutions, research areas, trends, and interrelations among scientific publications.

Keywords: Artificial Intelligence; Financial Market; Bibliometrics; Finance.

LISTA DE FIGURAS

Figura 1 - Distribuição de artigos por ano	32
Figura 2 - Áreas de pesquisa mais abordadas	33
Figura 3 - Distribuição do número de autores nas publicações analisadas ao longo do tempo	36
Figura 4 - Distribuição geográfica de autorias	37
Figura 5 - Afiliações acadêmicas por autores.....	38
Figura 6 - Afiliações acadêmicas por autoria	39
Figura 7 - Representação log da frequência versus rank, segundo a Lei de Zipf	43
Figura 8 - Rede de ocorrência das palavras-chave	45

LISTA DE TABELAS

Tabela 1 - Publicações mais citadas	34
Tabela 2 - Número de autores por publicação	35
Tabela 3 - Sexo dos autores	36
Tabela 4 - Análise da participação dos autores, segundo a Lei de Lotka.....	40
Tabela 5 - Impacto dos autores.....	40
Tabela 6 - Delimitação dos periódicos em zonas, segundo a Lei de Bradford.....	41
Tabela 7 - Periódicos que compõem o núcleo, segundo a Lei de Bradford	41
Tabela 8 - Frequências das palavras-chave, segundo a Lei de Zipf	42
Tabela 9 - Distribuição das palavras-chave	44

LISTA DE ABREVIATURAS E SIGLAS

IA	Inteligência artificial
DMA	<i>Direct Market Access</i>
HFT	<i>High Frequency Trading</i>

SUMÁRIO

1 INTRODUÇÃO	15
2 REFERENCIAL TEÓRICO	16
2.1 Mercado financeiro.....	16
2.2 Inteligência Artificial (IA).....	18
2.3 Aprendizado de máquina	20
2.4 Deep learning.....	21
2.5 Big Data.....	23
2.6 Direct Market Access (DMA)	24
2.7 Algorithmic trading (Algo Trading)	25
2.8 High Frequency Trading (HFT)	27
2.9 Impacto da inteligência artificial no mercado financeiro	28
3 METODOLOGIA	29
3.1 Tipo de pesquisa	30
3.2 Coleta de dados.....	30
3.3 Categorização e formas de análise.....	31
4 ANÁLISE E DISCUSSÃO DOS RESULTADOS	32
4.1 A evolução das pesquisas ao longo do tempo	32
4.2 Principais áreas de pesquisa	32
4.3 Citações	33
4.4 Autores por publicação	35
4.5 Sexo dos autores	36
4.6 País de origem das autorias	36
4.7 Afiliações acadêmicas dos autores e das autorias	37
4.8 Lei de Lotka.....	39

4.9 Lei de Bradford.....	40
4.10 Lei de Zipf	42
4.11 Rede de ocorrência das palavras-chave	44
5 CONSIDERAÇÕES FINAIS.....	46
REFERÊNCIAS	48
APÊNDICE - LISTA DE TRABALHOS OBSERVADOS.....	54

1 INTRODUÇÃO

Nos últimos anos, o mercado financeiro tem passado por uma significativa transformação impulsionada pela inteligência artificial (IA). A IA é uma área da ciência da computação que visa desenvolver sistemas capazes de simular a inteligência humana e tomar decisões autônomas com base em dados e algoritmos. No contexto financeiro, essa tecnologia tem se mostrado revolucionária, proporcionando maior eficiência, precisão e velocidade nas operações, além de possibilitar a criação de estratégias sofisticadas de investimento (Leippold; Wang; Zhou, 2022).

Uma das principais aplicações da IA no mercado financeiro é a análise de dados. Com a quantidade massiva de informações disponíveis, a capacidade humana de processá-las se torna limitada. Por meio da IA é possível realizar análises complexas em grandes volumes de dados em tempo real, identificando padrões, tendências e anomalias. Isso permite que investidores e instituições financeiras tomem decisões embasadas em informações mais precisas, aumentando suas chances de obter retornos favoráveis e reduzindo o risco de perdas (Nabipour et al., 2020).

Além disso, a IA tem impulsionado o surgimento de novos produtos e serviços financeiros. Os chamados "robôs de investimento" ou "consultores-robôs" utilizam algoritmos de IA para realizar a gestão de carteiras de investimentos de forma automatizada e personalizada. Esses robôs são capazes de analisar o perfil do investidor, seus objetivos e tolerância ao risco, bem como sugerir estratégias de alocação de recursos mais adequadas. Essa abordagem tem ganhado popularidade, especialmente entre investidores individuais, por oferecer custos mais baixos e acessibilidade (Leippold; Wang; Zhou, 2022).

Ademais, a IA pode ser aplicada na detecção de padrões suspeitos em transações financeiras, identificando atividades fraudulentas com maior precisão e agilidade. Os algoritmos de aprendizado de máquina podem ser treinados para reconhecer comportamentos anômalos e indicar possíveis ameaças cibernéticas, fortalecendo a segurança dos sistemas e protegendo os ativos dos clientes (Lin, 2019).

Entretanto, é importante ressaltar que a transformação do mercado financeiro com a IA também traz desafios e questões éticas. O uso indiscriminado de algoritmos pode levar a vieses e discriminação, uma vez que as decisões são baseadas em dados históricos que podem refletir desigualdades sociais. Ainda, a dependência excessiva da IA pode aumentar a vulnerabilidade do sistema financeiro a ataques cibernéticos e falhas tecnológicas, requerendo um cuidadoso gerenciamento de riscos (Nabipour et al., 2020).

Assim, a transformação do mercado financeiro com a inteligência artificial representa uma mudança profunda na forma como as operações são conduzidas. A IA oferece maior eficiência, precisão e personalização nos processos de análise de dados, gestão de investimentos e segurança financeira. No entanto, é fundamental um equilíbrio entre o uso responsável da tecnologia e a consideração dos impactos éticos e de segurança. À medida que a IA continua a evoluir, espera-se que suas aplicações no mercado financeiro sejam cada vez mais relevantes e influentes (Lin, 2019).

Pretende-se investigar, a partir da literatura sobre o tema, como a inteligência artificial tem sido utilizada no contexto financeiro, identificar as principais áreas em que tem sido aplicada e compreender as consequências dessa transformação. Dentro deste contexto, o objetivo deste trabalho é fazer uma análise bibliométrica da literatura acadêmica que trata as aplicações e implicações da inteligência artificial na transformação do mercado financeiro no período de 2016 a 2022. Para sustentar esse objetivo, o trabalho foi estruturado em capítulos que abrangem o referencial teórico, os procedimentos metodológicos aplicados, a análise e a discussão dos resultados e, por último, as considerações finais.

2 REFERENCIAL TEÓRICO

2.1 Mercado financeiro

O mercado financeiro é um componente vital da economia global, desempenhando um papel crucial na alocação eficiente de recursos e na facilitação do fluxo de capital entre os agentes econômicos. Esse mercado abrange um conjunto de instituições, instrumentos e participantes que possibilitam a negociação de ativos financeiros, como ações, títulos, moedas e derivativos. Vale ressaltar que o mercado financeiro, não se limita somente a um local físico, podendo englobar ambientes físicos ou virtuais onde vales ou títulos financeiros são emitidos e negociados (Pinheiro, 2019).

Uma das principais funções do mercado financeiro é proporcionar liquidez aos ativos. Isso significa que os investidores podem comprar e vender ativos de forma rápida e eficiente, convertendo seus investimentos em dinheiro quando necessário. A liquidez é fundamental para garantir que os mercados funcionem de maneira suave e que os participantes tenham a capacidade de tomar decisões de investimento com flexibilidade (Fortuna, 2016).

Além da liquidez, o mercado financeiro também desempenha um papel importante na formação de preços. A interação entre oferta e demanda de ativos em mercados financeiros

estabelece os preços desses ativos. A descoberta de preços eficiente é crucial para garantir que os recursos sejam alocados de maneira adequada, refletindo as expectativas dos participantes sobre os fundamentos econômicos e financeiros (Filho; Ishikawa, 2003).

Os participantes do mercado financeiro podem ser divididos em dois grupos principais: os agentes superavitários e os agentes deficitários. Os agentes superavitários, como poupadores e investidores institucionais, fornecem fundos ao mercado, enquanto os agentes deficitários, como empresas e governos, buscam captar recursos para financiar seus projetos e operações. Essa interação entre os dois grupos é facilitada pelos intermediários financeiros, como bancos, corretoras e seguradoras (Silva, 2018).

Existem diferentes tipos de mercado financeiro, cada um com características específicas. A intermediação financeira se desenvolve de maneira segmentada, sendo organizada em quatro subdivisões específicas (Neto, 2021):

- Mercado de capitais;
- Mercado monetário;
- Mercado de crédito; e
- Mercado cambial.

O mercado de capitais é um dos segmentos mais importantes e envolve a emissão e negociação de valores mobiliários, como ações e títulos. As empresas utilizam o mercado de capitais para captar recursos para investimentos em expansão, enquanto os investidores buscam retornos através da compra desses ativos (Filho; Ishikawa, 2003).

Dentro do mercado de capitais, distinguem-se o mercado primário e o mercado secundário. O mercado primário é onde ocorre a emissão inicial de títulos, permitindo que as empresas levantem capital diretamente dos investidores. Já o mercado secundário é onde os títulos emitidos anteriormente são negociados entre investidores, sem a participação direta da empresa emissora. A Bolsa de Valores é um exemplo proeminente do mercado secundário (Filho; Ishikawa, 2003).

Outro importante segmento do mercado financeiro é o mercado monetário, que lida com a negociação de instrumentos financeiros de curto prazo, como certificados de depósito, títulos do governo de curto prazo e papel comercial. O mercado monetário desempenha um papel fundamental na gestão da liquidez no sistema financeiro, permitindo que as instituições ajustem suas posições de caixa de maneira eficiente (Silva, 2018).

O mercado de crédito atende às necessidades de liquidez a curto e médio prazo de diversos agentes econômicos. Isso é realizado por meio da concessão de empréstimos tanto a indivíduos quanto a entidades corporativas, utilizando intermediários financeiros bancários, especificamente bancos comerciais e múltiplos. A amplitude desse mercado se estende além dos canais bancários tradicionais, uma vez que instituições financeiras não bancárias também proporcionam opções de financiamento a médio prazo para consumidores que buscam adquirir bens de consumo (Selan, 2015).

Além disso, há o mercado cambial, onde ocorre a negociação de moedas estrangeiras. Esse mercado facilita o comércio internacional e a gestão de riscos cambiais para empresas que operam em diferentes jurisdições. As taxas de câmbio são determinadas pela oferta e demanda por moedas estrangeiras, refletindo as condições econômicas e políticas globais (Filho; Ishikawa, 2003).

Os derivativos também desempenham um papel significativo no mercado financeiro, oferecendo instrumentos financeiros cujo valor deriva do desempenho de um ativo subjacente. Contratos de futuros, opções e swaps são exemplos comuns de derivativos. Esses instrumentos fornecem aos investidores e empresas ferramentas para gerenciar riscos, especular sobre movimentos de preços e ajustar suas exposições a diferentes classes de ativos (Silva, 2018).

Portanto, o mercado financeiro é um componente complexo e interconectado da economia global. Sua função vai além da simples negociação de ativos, desempenhando papéis cruciais na alocação eficiente de recursos, na formação de preços e na facilitação do fluxo de capital. Os diferentes tipos de mercado, como o de capitais, monetário, cambial e derivativos, atendem a diversas necessidades dos participantes, promovendo um ambiente dinâmico e robusto para a atividade econômica.

2.2 Inteligência Artificial (IA)

Inteligência artificial (IA) é um ramo da ciência da computação que busca criar sistemas capazes de simular o raciocínio humano, ou seja, de resolver problemas, aprender, adaptar-se e tomar decisões de forma inteligente. A IA surgiu na década de 1950, com o objetivo de reproduzir as capacidades cognitivas dos seres humanos em máquinas (Marcus; Davis, 2019). Desde então, a IA vem evoluindo e se aplicando a diversas áreas do conhecimento, como medicina, educação, indústria, entretenimento, entre outros. No entanto, a IA também enfrenta limitações e desafios, como questões éticas, sociais e técnicas (Dignum, 2020).

A IA é um campo multidisciplinar que busca desenvolver sistemas capazes de realizar tarefas que, normalmente, demandam inteligência humana. Este conceito remonta a antigas especulações filosóficas, mas foi formalmente estabelecido por John McCarthy em 1956, durante a Conferência de Dartmouth. McCarthy, um dos pioneiros da IA, delineou o objetivo de criar máquinas que pudessem imitar funções cognitivas humanas, impulsionando assim a pesquisa e desenvolvimento nesse campo (Marcus; Davis, 2019).

Ao longo das décadas, a inteligência artificial evoluiu significativamente e se expandiu para diversas aplicações. Um marco importante foi alcançado com o desenvolvimento de redes neurais artificiais nos anos 1980. Nesse contexto, Russell e Norvig (2014), em *Inteligência Artificial: Uma Abordagem Moderna*, destacam os avanços dessas técnicas, que possibilitaram a resolução de problemas complexos, como reconhecimento de padrões e tomada de decisões (Dignum, 2020).

A IA pode ser dividida em quatro categorias: sistemas que pensam como humanos, sistemas que agem como humanos, sistemas que pensam racionalmente e sistemas que agem racionalmente (Rich; Knight, 1991). Cada uma dessas categorias envolve diferentes abordagens e técnicas para modelar e implementar a inteligência artificial. Algumas dessas técnicas são: lógica, redes neurais artificiais, algoritmos genéticos, aprendizado de máquina, processamento de linguagem natural, visão computacional, entre outros.

No entanto, a IA também apresenta riscos e dilemas para a sociedade. Por exemplo, como garantir que os sistemas de IA sejam éticos, transparentes e responsáveis? Como evitar que ela seja usada para fins maliciosos ou prejudiciais? Como preservar os direitos e a dignidade dos seres humanos frente à IA? Essas são algumas das questões que precisam ser debatidas e regulamentadas pelos pesquisadores, legisladores e cidadãos (Marcus; Davis, 2019).

Brooks (2002) destaca que a inteligência artificial ainda enfrenta desafios significativos para alcançar a compreensão intuitiva e a adaptação flexível que caracterizam a inteligência humana. Além disso, são debatidas questões éticas, como vieses algorítmicos e privacidade. Um aspecto crítico a ser considerado é o desenvolvimento de sistemas de IA que sejam transparentes e compreensíveis. Conforme aponta Dignum (2020), é fundamental criar sistemas que possam explicar suas decisões, contribuindo para tornar a inteligência artificial mais confiável e compreensível para os usuários e para a sociedade em geral.

Portanto, a inteligência artificial representa uma área dinâmica e desafiadora, com amplas possibilidades de aplicação, mas também acompanhada por considerações éticas e limitações técnicas. A necessidade de um desenvolvimento responsável, transparente e alinhado

com os valores humanos torna-se cada vez mais evidente, conforme destacado por diversos autores que contribuem para a compreensão e evolução contínua desse campo.

2.3 Aprendizado de máquina

O termo "aprendizado de máquina" refere-se a qualquer processo pelo qual um sistema artificial aprende a partir de exemplos e os generaliza após a conclusão da fase de aprendizado (Lopes; Rebecchi; Bazotti, 2019). É um segmento da inteligência artificial que utiliza modelos estatísticos e dados para permitir que computadores aprendam e tomem decisões sem programação explícita. Priorizando o avanço no desenvolvimento de sistemas e algoritmos com capacidade de aprendizagem, focando em previsões através da identificação automática de padrões em conjuntos de dados.

O sistema pode analisar dados desconhecidos além de aprendê-los ou não. Algumas das inúmeras aplicações possíveis, são: procedimentos diagnósticos automatizados; detecção de fraude de cartão de crédito; análise do mercado de ações; classificação da sequência nucleotídica; reconhecimento de fala e texto; e sistemas autônomos (Domingos, 2012).

O aprendizado de máquina é um componente importante do crescente domínio da ciência dos dados. Através da utilização de métodos estatísticos, os algoritmos são treinados para fazer classificações ou previsões para descobrir informações importantes em projetos de extração de dados (Izbicki; Santos, 2020).

A descoberta de conhecimentos em bases de dados é um processo que envolve a extração de informações e conhecimentos úteis de grandes bases (Mpia et al., 2023). Esse processo inclui técnicas como a mineração de dados, que se centra na descoberta de padrões e relações dos dados. Esta, por sua vez, utiliza técnicas estatísticas, matemáticas, de inteligência artificial e de aprendizagem de máquina para analisar os dados e descobrir padrões (Hardianto et al., 2022). Como consequência, métodos de aprendizado de máquina são usados na mineração de dados, uma vez que envolvem a utilização de algoritmos para treinar modelos e fazer previsões ou classificações com base nos padrões identificados.

No aprendizado de máquina, o tipo e a potência da representação do conhecimento utilizada são críticos. Uma abordagem não simbólica são as redes neurais, que são "ensinadas" a operar de maneira calculável, mas não utilizam símbolos para expressar informações (na forma de exemplos ou regras induzidas). Nenhuma explicação é fornecida para os procedimentos de aprendizagem permitidos; este é um exemplo de representação implícita do conhecimento (Domingos, 2012).

O campo de aprendizado de máquina compreende várias categorias de tarefas utilizando algoritmos, podendo ser dividido em três classes principais: aprendizado supervisionado, não supervisionado e por reforço (Iguai; Seguí, 2017).

O aprendizado supervisionado envolve o mapeamento de dados rotulados, em que o conjunto de dados de entrada é acompanhado por rótulos de saída correspondentes ou valores-alvo. Nesse contexto, os algoritmos aprendem por meio de um conjunto de treinamento composto por exemplos rotulados, buscando generalizar para todo o espectro possível de entradas. Essa generalização é alcançada pela análise dos padrões e relacionamentos entre as características de entrada e seus rótulos correspondentes durante a fase de treinamento. Exemplos desse processo incluem técnicas como regressão logística, máquinas de vetor de suporte e árvores de decisão (Iguai; Seguí, 2017).

Na aplicação do aprendizado não-supervisionado, o algoritmo aprende a partir de dados não rotulados, explorando as informações conforme critérios estatísticos, geométricos ou de similaridade. Em contraste com o aprendizado supervisionado, não há rótulos de saída predefinidos ou valores-alvo fornecidos durante o treinamento. Em vez disso, o algoritmo busca identificar padrões ou estruturas ocultas nos dados independentemente. Isso pode envolver a agregação de instâncias similares ou a descoberta de dimensões ou representações subjacentes nos dados. Exemplos incluem agrupamento *k-means* e estimação de densidade de núcleo (Iguai; Seguí, 2017).

Por fim, o aprendizado por reforço utiliza definições de recompensa para orientar o seu processo de tomada de decisão. Tendo como objetivo a otimização de estratégias de resolução de problemas, maximizando as recompensas com base no *feedback* recebido, calculado através de recompensas e penalizações definidas (Chinnamgari, 2019).

2.4 *Deep learning*

O *deep learning*, ou aprendizado profundo, é um segmento da área de aprendizado de máquina, que se baseia em redes neurais artificiais para realizar tarefas complexas de forma automatizada. O *deep learning* utiliza redes neurais profundas para realizar tarefas complexas de aprendizado e reconhecimento de padrões. As redes neurais artificiais são compostas por camadas de neurônios interconectados, cada um processando informações e transmitindo-as para a próxima camada. A profundidade dessas redes permite a extração de representações hierárquicas complexas dos dados, capacitando-as a aprender padrões abstratos e realizar tarefas avançadas (Silva; Santos, 2022).

No contexto do mercado financeiro, o *deep learning* tem se destacado em várias frentes. Uma das aplicações mais proeminentes é a previsão de tendências de mercado e a análise de séries temporais financeiras. Modelos de *deep learning*, como redes neurais recorrentes (RNNs) e *long short-term memory networks* (LSTMs), mostraram-se eficazes na captura de padrões complexos em dados temporais, permitindo a previsão de movimentos de preços e a identificação de oportunidades de investimento (Shang; Wang, 2022).

A análise de sentimentos também é uma área onde o *deep learning* tem desempenhado um papel significativo no mercado financeiro. O processamento de linguagem natural (PLN) alimentado por modelos de *deep learning* pode analisar grandes volumes de notícias, *tweets* e outros dados textuais para avaliar o sentimento do mercado em relação a determinados ativos. Essa análise pode informar as decisões de investimento, ajudando os investidores a antecipar movimentos do mercado com base em eventos e notícias relevantes (Silva; Santos, 2022).

Outra aplicação importante é a gestão de riscos. Modelos de *deep learning* são utilizados para avaliar o risco associado a diferentes ativos e portfólios, considerando uma variedade de fatores, desde condições macroeconômicas até eventos geopolíticos. Essa capacidade de análise avançada contribui para uma tomada de decisão mais informada e para a mitigação de riscos no ambiente financeiro. A detecção de fraudes também é uma área onde o *deep learning* tem trazido benefícios significativos ao mercado financeiro. Algoritmos avançados são capazes de identificar padrões suspeitos em transações financeiras, indicando possíveis atividades fraudulentas. Essa capacidade é crucial para instituições financeiras que buscam proteger seus clientes e garantir a integridade do sistema financeiro como um todo (Silva; Santos, 2022).

Ao avaliar a capacidade de pagamento dos clientes, o *deep learning* considera diversos fatores, incluindo histórico financeiro e comportamento de consumo, permitindo a oferta de crédito personalizado e seguro. Além disso, na detecção de fraudes, a tecnologia é eficaz na identificação de padrões anormais em transações, prevenindo potenciais prejuízos. No contexto de investimentos, analisa dados históricos e atuais para criar modelos preditivos, auxiliando na tomada de decisão dos investidores. Por meio de *chatbots*, a tecnologia melhora a interação com os clientes, respondendo a dúvidas e realizando operações. Adicionalmente, na recomendação de produtos financeiros, o *deep learning* oferece sugestões personalizadas, aumentando a fidelização e rentabilidade dos clientes. Essas aplicações refletem o impacto significativo do aprendizado profundo no setor financeiro, proporcionando eficiência e personalização em diversas operações e serviços (Silva; Santos, 2022).

É importante ressaltar que, embora o *deep learning* ofereça muitas vantagens, ele não está isento de desafios. O treinamento de modelos requer conjuntos de dados volumosos e, em alguns casos, rotulação manual, o que pode ser trabalhoso e demandar recursos significativos. Além disso, a interpretabilidade dos modelos de *deep learning* pode ser um desafio, tornando essencial a validação cuidadosa dos resultados obtidos (Shang; Wang, 2022).

2.5 Big Data

O Big Data refere-se a recursos de informação cujas características em termos de volume, velocidade e variedade requerem o uso de tecnologias e métodos analíticos específicos para gerar valor, e que geralmente excedem as capacidades de uma única máquina e requerem processamento paralelo (Mendonça; Andrade; Neto, 2019).

A proliferação quantitativa de dados digitais fornece uma nova maneira de ver o mundo. A enorme quantidade de dados digitais acessíveis exige a adoção de novas ordens de grandeza em termos de captura, armazenamento, busca, compartilhamento, análise e visualização de dados (Rodrigues; Dias, 2017).

Os setores que utilizam grandes quantidades de dados reconheceram o benefício do Big Data e do aprendizado de máquina. Sendo que as ações mais comuns realizadas em conjuntos de dados utilizando a análise de Big Data incluem: a captura, o armazenamento, a análise, a atualização, a consulta e a visualização dos dados (Salkuti, 2020).

Big Data tem uma história breve e obscura como instrumento de tecnologia da informação e como um domínio crescente do ciberespaço. De acordo com os arquivos da biblioteca digital da *Association for Computing Machinery* (ACM), o termo "Big Data" surgiu pela primeira vez em outubro de 1997 em um ensaio acadêmico sobre as questões técnicas a serem abordadas para a exibição de "grandes conjuntos de dados" (Ottonicar; Atayde; Eulalia, 2019).

O desenvolvimento de sistemas de armazenamento, mineração e análise de informações digitais levou a um "*big bang*" de dados, que resultou no surgimento do Big Data. Suas origens, no entanto, remontam à intersecção da cibernética com as correntes de pensamento pós Segunda Guerra Mundial, segundo as quais o homem e o mundo podem ser representados como "conjuntos informacionais" cuja única distinção em relação às máquinas é seu grau de complexidade. Então, a existência consistiria em uma série de 0s e 1s, que são programáveis e previsíveis (Scaglione et al., 2021).

Poucos prospectivistas se arriscam a prever as evoluções que definem o Big Data e seus algoritmos, bem como as da ciência de dados, porque eles são amplamente ocultos (dentro das agências de inteligência dos principais estados) e tão rápidos e potencialmente significativos. A médio ou longo prazo, a maioria dos observadores os vê como desafios futuros significativos, tanto em termos de oportunidades comerciais quanto de convulsões sócio-políticas e militares, capazes de controlar, monitorar e/ou influenciar indivíduos e grupos (Rosa, 2018).

2.6 *Direct Market Access* (DMA)

Direct Market Access (DMA), ou Acesso Direto ao Mercado, é um sistema que permite aos investidores negociarem diretamente com as bolsas de valores, sem a necessidade de intermediários. Por meio do DMA, os investidores têm a capacidade de enviar ordens de compra e venda de forma eletrônica e em tempo real, obtendo maior transparência e agilidade nas operações (Nandanwar; Wanjari; Siraskar, 2022).

Ao eliminar a necessidade de intermediários humanos, o DMA permite uma negociação mais rápida e eficiente, melhores capacidades de tomada de decisões e uma menor assimetria de informação no mercado. Esta tecnologia revoluciona a forma como as transações financeiras são conduzidas, proporcionando poupanças de custos e uma maior eficiência operacional. Além disso, reduz o risco de erros humanos e permite que estratégias de negociação automatizadas e algorítmicas sejam implementadas com facilidade (Marwala; Hurwitz, 2017).

É importante ressaltar que o DMA não é uma inteligência artificial e sim uma tecnologia de acesso direto aos mercados financeiros. A IA pode ser aplicada no DMA a fim de melhorar a automação, a eficiência e a tomada de decisões nas operações de mercado. Essa integração visa aproveitar a velocidade do DMA e a capacidade de análise e adaptação da IA para obter melhores resultados no sistema financeiro.

Uma das principais vantagens do DMA é a redução dos custos de transação. Ao eliminar os intermediários, como corretoras e *dealers*, os investidores podem acessar os preços de mercado mais competitivos e obter melhores condições de execução das ordens. Isso pode resultar em economia significativa de custos, especialmente para investidores institucionais que realizam grandes volumes de negociação (Ozcariz, 2019).

Além disso, o DMA proporciona uma maior velocidade de execução das ordens. Ao negociar diretamente com as bolsas, as ordens são encaminhadas eletronicamente e executadas de forma mais rápida e eficiente. Isso é especialmente vantajoso em mercados de alta liquidez

e volatilidade, onde a velocidade de execução pode ser crucial para obter os melhores preços (Tuygunovich; Islamovna, 2022).

Outra vantagem do DMA é a transparência. Os investidores têm acesso direto às informações de mercado, incluindo os preços de compra e venda em tempo real, os volumes negociados e os melhores lances e ofertas disponíveis. Isso permite uma melhor análise e tomada de decisão, uma vez que os investidores podem avaliar o mercado de forma mais precisa e identificar oportunidades de negociação (Abouloula et al., 2021).

No entanto, é importante destacar que o DMA também apresenta riscos e desafios. Como os investidores têm um acesso direto ao mercado, eles são responsáveis por tomar suas próprias decisões de investimento e gerenciar seus riscos. Isso requer um conhecimento aprofundado do mercado e das estratégias de negociação, além da implementação de mecanismos de controle e gestão de riscos adequados (Ozcariz, 2019).

Outro desafio do DMA é a complexidade tecnológica. Os investidores precisam contar com sistemas de negociação sofisticados e de alta velocidade para enviar e executar as ordens de forma eficiente. Além disso, é necessário ter uma infraestrutura de tecnologia robusta e confiável para lidar com grandes volumes de dados e garantir a segurança das transações (Tuygunovich; Islamovna, 2022).

O DMA também está sujeito a riscos operacionais, como falhas de conectividade ou sistemas, que podem levar a atrasos ou interrupções nas ordens. Portanto, é essencial implementar medidas de contingência e redundância para minimizar esses riscos e garantir a continuidade das operações. Apesar dos desafios, o DMA tem se tornado cada vez mais popular entre os investidores institucionais e *traders* ativos. A busca por maior eficiência, redução de custos e acesso direto ao mercado impulsiona a adoção dessa abordagem. No entanto, é importante que os investidores compreendam os riscos envolvidos e tenham o conhecimento e as habilidades necessárias para utilizar o DMA de forma eficaz e responsável (Abouloula et al., 2021).

2.7 Algorithmic trading (Algo Trading)

O *Algo Trading*, ou negociação algorítmica, é um subcampo em finanças que está sendo cada vez mais empregado no mercado financeiro. Consiste na utilização de algoritmos e programas de computador para realizar operações de compra e venda de ativos de forma automatizada. Essa abordagem é baseada na análise de dados e no uso de estratégias pré-

definidas, permitindo que as operações sejam executadas de maneira rápida e eficiente (Pricope, 2021).

Uma das principais vantagens do *Algo Trading* é a eliminação do viés emocional nas decisões de investimento. Ao utilizar algoritmos, as decisões são baseadas exclusivamente em critérios objetivos, como indicadores técnicos, dados históricos e modelos matemáticos. Isso reduz a influência de fatores subjetivos e emocionais, o que pode levar a uma maior consistência e disciplina nas operações (Park; Lee, 2021).

Além disso, o *Algo Trading* possibilita o processamento e a análise de grandes volumes de dados em tempo real. Utilizando a IA, os modelos de negociação algorítmica têm a capacidade de se adaptar às condições de mercado em tempo real, permitindo-lhes reagir a dinâmicas em mudança e capitalizar as oportunidades emergentes. Com a ajuda de algoritmos avançados, é possível identificar padrões e tendências nos mercados financeiros que seriam difíceis de serem percebidos manualmente. Isso permite uma tomada de decisão mais precisa e rápida, o que pode resultar em melhores resultados financeiros (Théate; Ernest, 2021).

Outra vantagem do *Algo Trading* é a velocidade de execução das ordens. Enquanto um operador humano pode levar alguns segundos ou minutos para tomar uma decisão e enviar uma ordem de compra ou venda, os algoritmos podem executar essas operações em questão de milissegundos. Isso é especialmente importante em mercados de alta volatilidade, onde pequenos atrasos podem fazer a diferença entre um lucro e uma perda (Pricope, 2021). A utilização de IA na negociação algorítmica tem o potencial de reduzir o impacto dos erros humanos nas decisões de investimento, conduzindo a resultados mais consistentes e confiáveis.

No entanto, é importante destacar que o *Algo Trading* também apresenta desafios e riscos. A construção e o ajuste de algoritmos eficientes exigem conhecimentos avançados de programação e modelagem financeira. Além disso, é fundamental monitorar e atualizar constantemente os algoritmos para garantir que eles continuem sendo eficazes em um ambiente de mercado em constante mudança (Bao et al., 2022).

Outro desafio é a possibilidade de eventuais imprevistos afetarem negativamente as estratégias do *Algo Trading*. Por exemplo, um anúncio econômico inesperado pode levar a uma rápida mudança nas condições do mercado, fazendo com que os algoritmos executem operações indesejadas. Portanto, é essencial implementar mecanismos de gerenciamento de riscos e *circuit breakers* para minimizar os impactos desses eventos (Pricope, 2021).

Apesar dos desafios, o *AlgoTrading* tem se tornado cada vez mais popular no mercado financeiro. Grandes instituições financeiras, fundos de investimento e até mesmo investidores individuais estão adotando essa abordagem para melhorar seus resultados e aproveitar as

oportunidades oferecidas pela tecnologia. No entanto, é importante lembrar que o *Algo Trading* não substitui a análise fundamental e o conhecimento do mercado, sendo uma ferramenta complementar que pode auxiliar os investidores em suas estratégias (Théate; Ernest, 2021).

2.8 High Frequency Trading (HFT)

High Frequency Trading (HFT), ou Negociação de Alta Frequência, refere-se a uma estratégia de negociação que utiliza algoritmos avançados e sistemas computacionais de alta velocidade para realizar operações de compra e venda de ativos financeiros em velocidades extremamente rápidas. O HFT é caracterizado pela execução de um grande número de ordens em frações de segundo, buscando lucrar com pequenas variações nos preços dos ativos (Zaharudin; Yooung; Hsu, 2021).

Uma das principais vantagens do HFT é a capacidade de aproveitar as oportunidades de mercado em tempo real. Devido à sua velocidade de execução, os algoritmos de HFT podem identificar e agir sobre as mudanças de preço quase que instantaneamente, permitindo que as operações sejam realizadas em momentos de maior vantagem. Isso pode resultar em lucros significativos, especialmente quando combinado com grandes volumes de negociação (Ersan et al., 2020).

Além disso, o HFT contribui para a liquidez dos mercados financeiros. Ao realizar um grande número de operações em curtos períodos de tempo, os traders de HFT fornecem uma oferta constante de compra e venda de ativos, tornando mais fácil para outros investidores comprarem e venderem. Isso ajuda a reduzir os *spreads* e os custos de transação, beneficiando o mercado como um todo (Hossain, 2022).

Outra vantagem do HFT é a capacidade de realizar análises e processamentos complexos em grandes volumes de dados em tempo real. Os algoritmos de *High Frequency Trading* (HFT) possuem a capacidade de analisar de forma ágil os dados de mercado, incluindo feeds de cotações, notícias e indicadores técnicos. Essa análise rápida permite a identificação de padrões e oportunidades de negociação. Essa capacidade de processamento rápido e análise em tempo real é essencial em um mercado dinâmico e altamente competitivo (Ersan et al., 2020).

No entanto, o HFT também enfrenta desafios e críticas. Uma das preocupações é a possibilidade de ocorrerem eventos indesejados devido à velocidade extrema das negociações. Por exemplo, uma pequena falha em um algoritmo de HFT pode resultar em um grande número

de operações indesejadas ou em uma resposta excessiva a eventos de mercado, o que pode levar a instabilidades e aumentar o risco sistêmico do mercado (Zaharudin; Yooung; Hsu, 2021).

Outra crítica ao HFT é a preocupação com a equidade e a igualdade de acesso ao mercado. Devido à velocidade de execução das negociações de HFT, os *traders* que possuem infraestrutura de alta velocidade têm uma vantagem competitiva significativa em relação aos investidores que não possuem esses recursos. Isso levanta questões sobre a justiça e a transparência do mercado, especialmente quando se trata de investidores de varejo ou de menor porte (Hossain, 2022).

Além disso, o HFT está sujeito a regulamentações e supervisão rigorosas. Os órgãos reguladores têm buscado impor regras para garantir a estabilidade e a integridade dos mercados. Essas regulamentações incluem requisitos de transparência, limites de posição e controles de risco, visando mitigar os riscos associados ao HFT (Ersan et al., 2020).

Apesar das críticas e dos desafios, o HFT continua sendo uma estratégia amplamente utilizada por instituições financeiras e *traders* profissionais. Sua velocidade de execução, capacidade de análise em tempo real e contribuição para a liquidez do mercado são consideradas vantagens significativas (Zaharudin; Yooung; Hsu, 2021).

2.9 Impacto da inteligência artificial no mercado financeiro

A Inteligência Artificial (IA) está causando um impacto significativo no mercado financeiro, revolucionando a maneira como as operações financeiras são conduzidas. Esse sistema tem o potencial de melhorar a eficiência, a precisão e a velocidade das transações, bem como fornecer *insights* valiosos para os investidores (Lin, 2019).

A automação de processos é uma das principais contribuições da IA no mercado financeiro. Por meio de algoritmos sofisticados, automatiza tarefas rotineiras e repetitivas, como análise de dados, processamento de informações e execução de operações. Isso permite uma maior agilidade nas transações e liberação de recursos humanos para a dedicação a atividades mais estratégicas (Leippold; Wang; Zhou, 2022).

A tomada de decisão baseada em dados é outra área em que a IA tem um impacto significativo. Com a capacidade de analisar grandes volumes de dados em tempo real, identifica padrões e tendências ocultas nos mercados financeiros. Isso fornece aos investidores *insights* valiosos para a tomada de decisões informadas, reduzindo o impacto de vieses emocionais e aumentando a probabilidade de obter resultados positivos (Lin, 2019).

Além disso, tem sido amplamente utilizada na gestão de riscos no mercado financeiro. Com algoritmos avançados, identifica e avalia riscos potenciais, analisa cenários complexos e fornece recomendações para mitigar esses riscos. Isso ajuda os investidores a tomarem decisões mais seguras e a protegerem seus ativos (Nabipour et al., 2020).

A IA também tem contribuído para a criação de estratégias de negociação mais eficientes. Seus algoritmos podem analisar uma vasta gama de fatores para identificar oportunidades de negociação, como indicadores técnicos, dados históricos e notícias financeiras. Isso possibilita a execução de operações em velocidades muito mais rápidas do que o ser humano seria capaz de fazer, o que é especialmente vantajoso em mercados voláteis (Leippold; Wang; Zhou, 2022).

Outro impacto desse sistema no mercado financeiro é a personalização dos serviços financeiros, com a capacidade de analisar dados de clientes e entender seus perfis de investimento, oferecendo recomendações personalizadas e construção de carteiras de investimento de acordo com as necessidades e objetivos individuais. Isso melhora a experiência do cliente e aumenta a eficácia das estratégias de investimento (Lin, 2019).

É importante ressaltar que possui um papel importante na detecção de fraudes e atividades suspeitas nos mercados financeiros. Com o aumento da complexidade e sofisticação das fraudes, a IA pode analisar grandes volumes de dados em tempo real para identificar padrões suspeitos e comportamentos anômalos. Isso ajuda a proteger os investidores e manter a integridade do mercado (Nabipour et al., 2020).

No entanto, é importante destacar que o seu impacto no mercado financeiro também apresenta desafios. A interpretação e o uso correto dos dados são essenciais para evitar decisões equivocadas ou parciais. Além disso, a privacidade dos dados e a segurança das informações também são preocupações importantes que precisam ser endereçadas (Leippold; Wang; Zhou, 2022).

A IA está transformando o mercado financeiro de diversas maneiras. Desde a automação de processos e a tomada de decisão baseada em dados até a gestão de riscos e a personalização dos serviços financeiros. No entanto, é fundamental encontrar um equilíbrio entre o seu uso e a necessidade de supervisão humana para garantir a eficácia e a ética no mercado (Nabipour et al., 2020).

3 METODOLOGIA

3.1 Tipo de pesquisa

O presente trabalho classifica-se como um estudo exploratório, adotando uma abordagem quantitativa tanto em seus objetivos quanto em sua metodologia. Configura-se como uma pesquisa documental que emprega a análise bibliométrica para analisar as pesquisas acadêmicas selecionadas sobre o tema da inteligência artificial no mercado financeiro.

A bibliometria é uma análise estatística de dados quantitativos presentes em produções técnicas e científicas (Rodrigues; Vieira, 2016). Com ela é possível medir diversos aspectos das publicações científicas, incluindo o impacto e a influência de pesquisadores, instituições, periódicos e áreas de pesquisa (Guedes, 2012).

Lei de Lotka, Lei de Bradford e Lei de Zipf são as três leis fundamentais da bibliometria. A primeira destaca a produtividade dos autores, enquanto as duas últimas descrevem, respectivamente, a distribuição de periódicos dentro de um domínio específico e a frequência de palavras empregadas nas publicações (Araújo, 2006).

3.2 Coleta de dados

Os dados utilizados como base na pesquisa foram coletados através de buscas no Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), no Google Acadêmico e na *Web of Science* (WoS). Para a caracterização da amostra, utilizou-se as palavras-chave, de forma combinada: “Mercado Financeiro” ou “*Financial Market*”; “Finanças” ou “*Finance*”; “Aprendizado de Máquina” ou “*Machine Learning*”; e “Inteligência Artificial” ou “*Artificial Intelligence*”. Tendo como critério de busca o período de 2016 a 2022.

A primeira coleta, utilizando o Portal de Periódicos da CAPES, foi realizada entre os dias 22 a 30 de setembro de 2023. Utilizou-se as palavras-chave citadas anteriormente em conjunto com os filtros disponibilizados pela interface, sendo disponibilidade (periódicos revisados por pares); assunto (inteligência artificial, bolsa de valores, *capital markets*, *accounting*, *artificial intelligence*, desempenho financeiro, *artificial neural networks*, *finance*, *business & economics*, *machine learning* e *financial performace*); e data de criação (desde 2016 até 2022). Foram identificadas 7.628 publicações, excluindo as duplicadas e os estudos que não se relacionavam ao tema escolhido para a pesquisa, restando 53 artigos.

Em seguida, foi efetuada uma busca pelo site do Google Acadêmico, nos dias 2 a 10 de outubro, utilizando o mesmo conjunto de palavras-chave e período, selecionando apenas os artigos de revisão. Essa busca teve o intuito de procurar por artigos eventualmente não

disponíveis no Portal de Periódicos da CAPES, tendo sido selecionados 29 artigos distintos dos da pesquisa anterior.

Durante o período de 12 a 17 de outubro, realizou-se a leitura e análise dos 82 artigos resultantes das buscas, efetuando-se uma nova seleção daqueles considerados pertinentes para a análise bibliométrica. Como resultado desse processo, obteve-se um total de 63 publicações relevantes. Adicionalmente, foi consultado o site *Web of Science* (WoS) para verificar quais dos artigos selecionados faziam parte da base de dados, identificando-se, ao final, 48 artigos que compuseram a amostra do estudo.

3.3 Categorização e formas de análise

Após a coleta de dados e leitura das publicações, realizou-se a categorização e análise das informações com o auxílio do Microsoft Excel, para formação de tabelas e gráficos; das ferramentas disponibilizadas pela base de dados do *Web of Science* (WoS), do *Journal Citation Report* (JCR) e da Plataforma Sucupira; e do software *VOSviewer*, para a análise de redes.

Utilizando a base de dados do *Web of Science* (WoS), foi possível obter as informações dos artigos referentes as suas citações, ano de publicação, áreas de pesquisa, palavras-chave utilizadas pelos autores, instituição de vinculação, periódicos e país de origem. Com a Plataforma Sucupira foram extraídas as informações dos periódicos referentes às classificações na Qualis-CAPES Quadriênio 2017-2020. Adicionalmente, o *Journal Citation Report* (JCR) foi utilizado para encontrar o fator de impacto dos periódicos no ano de 2022.

Com o auxílio das informações obtidas na base de dados do *Web of Science* (WoS), foi utilizado o software *VOSviewer* para a criação de mapas de visualização de redes de ocorrência das palestras-chave. Por fim, o Microsoft Excel foi utilizado para criar gráficos e organizar os dados coletados em planilhas, separando informações referentes a autores, ano de publicação, periódico, classificação na Qualis-CAPES Quadriênio 2017-2020, fator de impacto, objetivo do estudo, palavras-chave, área de estudo e citações.

A partir dessas informações, realizou-se uma análise bibliométrica com o intuito de compreender, observar e identificar os principais assuntos e acompanhar a evolução da pesquisa sobre o tema. Essa abordagem foi realizada em conjunto com a aplicação dos conceitos da Lei de Lotka (Lei do Quadrado Inverso), da Lei de Bradford (Lei de Dispersão) e da Lei de Zipf (Lei do Mínimo Esforço).

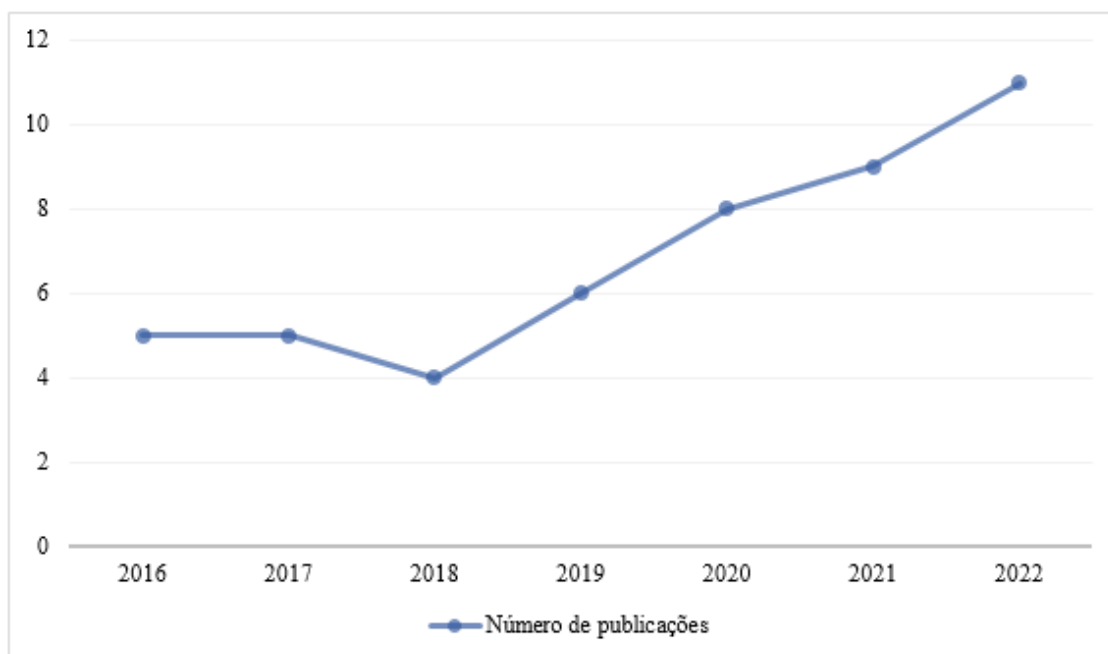
4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

4.1 A evolução das pesquisas ao longo do tempo

Foi observado um total de 48 estudos no período de 2016 a 2022. Nota-se uma estagnação na produção acadêmica nos anos de 2016 e 2017, com cada ano registrando 5 publicações. Em 2018, houve uma ligeira queda para 4 publicações. No entanto, a partir desse ano, notamos um crescimento expressivo na produção acadêmica, culminando em 2022 com o maior número de publicações, 11 no total, que representam 22,92% do total de publicações analisadas.

A Figura 1 evidencia o número de artigos publicados sobre o tema inteligência artificial no mercado financeiro. Ao analisá-la, é possível perceber o crescimento na produção de pesquisas a partir do ano de 2018. Durante o período de 2018 a 2022, foram publicados 38 artigos, constituindo 79,17% do total. Uma provável explicação para tal fenômeno seria o avanço das tecnologias de IA com a utilização do aprendizado de máquina e redes neurais, impulsionando novas pesquisas sobre o assunto no âmbito internacional e nacional.

Figura 1 - Distribuição de artigos por ano

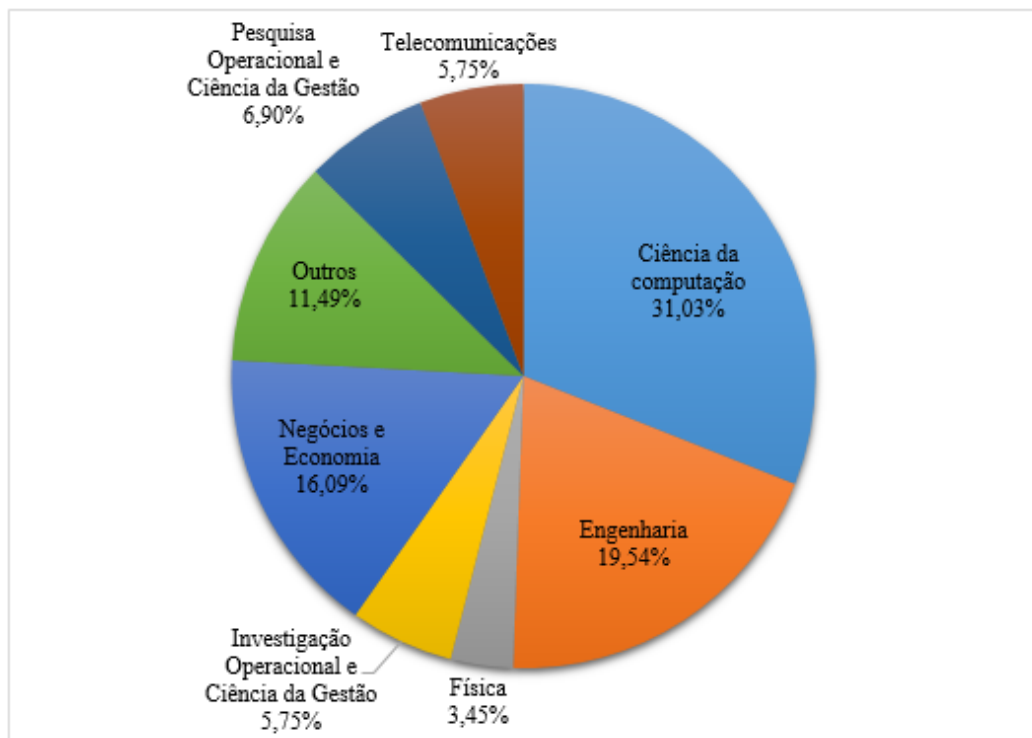


Fonte: Elaboração própria (2023)

4.2 Principais áreas de pesquisa

Observando a Figura 2¹ foi possível perceber que no período analisado a área de pesquisa que mais se destacou foi a Ciência da Computação com 31,03%, seguida pela área de Engenharia com 19,54%. Negócios e Economia foi a terceira área com mais publicações, com 16,09%. Assim, a crescente relevância de temas relacionados ao mercado financeiro e inteligência artificial evidencia uma abordagem interdisciplinar e contemporânea na produção de conhecimento acadêmico.

Figura 2 - Áreas de pesquisa mais abordadas



Fonte: Elaboração própria (2023)

4.3 Citações

Ao analisar as publicações selecionadas foi possível fazer um levantamento do número de citações. Verificou-se que 6 artigos (12,50%) não possuem nenhuma citação, enquanto 2 (4,17%) possuem uma única citação. Adicionalmente, 21 documentos (43,75%) possuem mais de 10 citações. Por fim, apenas, 7 artigos (18,58%) apresentam mais de 100 citações.

Dentre os 15 artigos mais citados, nota-se uma concentração nos anos de 2016 e 2019, ambos com 3 publicações. Destaca-se a publicação *A deep learning framework for financial*

¹ A categoria "Outros" inclui as áreas de pesquisa que apareceram apenas uma vez na amostra e foram agrupadas para simplificação.

time series using stacked autoencoders and long-short term memory, de Wei Bao, Jun Yue e Yulei Rao, publicado em 2017, com um total de 416 citações e uma média de citações por ano de 59,43.

No entanto, o artigo *Artificial intelligence and machine learning in finance: A bibliometric review*, de Shamima Ahmed *et al.*, publicado em 2022, registrou o menor número total de citações, com apenas 42, e uma média de 21 citações por ano. Embora sendo uma publicação recente, é possível que ainda não tenha tido tempo suficiente para acumular um grande número de citações, mas sugere que, com o passar do tempo, publicações mais recentes podem se destacar na pesquisa sobre o tema.

A Tabela 1 apresenta os 15 principais artigos, classificados pelo número de citações, com base nos dados do *Web of Science* (WoS).

Tabela 1 - Publicações mais citadas

Ano	Tema	Média de citações por ano	Citações totais
2017	<i>A deep learning framework for financial time series using stacked autoencoders and long-short term memory</i>	59,43	416
2016	<i>Computational Intelligence and Financial Markets: A Survey and Future Directions</i>	38,13	305
2019	<i>Literature review: Machine learning techniques applied to financial market prediction</i>	38,00	190
2019	<i>Machine Learning Methods for Systemic Risk Analysis in Financial Sectors</i>	32,80	164
2021	<i>Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis</i>	43,67	131
2018	<i>Forecasting stock market crisis events using deep and statistical machine learning techniques</i>	21,33	128
2017	<i>Stock market one-day ahead movement prediction using disparate data sources</i>	14,57	102
2020	<i>Stock market movement forecast: A Systematic review</i>	24,50	98
2016	<i>Bridging the divide in financial market forecasting: machine learners vs. financial economists</i>	11	88
2016	<i>Evaluating machine learning classification for financial trading: An empirical approach</i>	9,38	75
2020	<i>Industry 4.0 in finance: The impact of Artificial Intelligence (AI) on digital financial inclusion</i>	17,50	70
2021	<i>Digital servitization value co-creation framework for AI services: a research agenda for digital transformation in financial service ecosystems</i>	19,33	58
2019	<i>Global stock market investment strategies based on financial network indicators using machine learning techniques</i>	11,60	58

<i>Machine learning techniques and data for stock market</i>		
2022 <i>forecasting: A literature review</i>	24	48
<i>Artificial intelligence and machine learning in finance: A</i>		
2022 <i>bibliometric review</i>	21	42

Fonte: Elaboração própria (2023)

4.4 Autores por publicação

A Tabela 2 indica que a maioria dos artigos são publicados por três autores (27,08%), seguido pelos artigos publicados por apenas um autor (22,98%), e por dois e cinco autores (ambos com 16,67%). Observa-se que 77,08% das publicações analisadas foram em coautoria. A colaboração entre autores proporciona uma variedade de perspectivas e ideias, fomentando a produção de resultados de pesquisa mais inovadores e abrangentes.

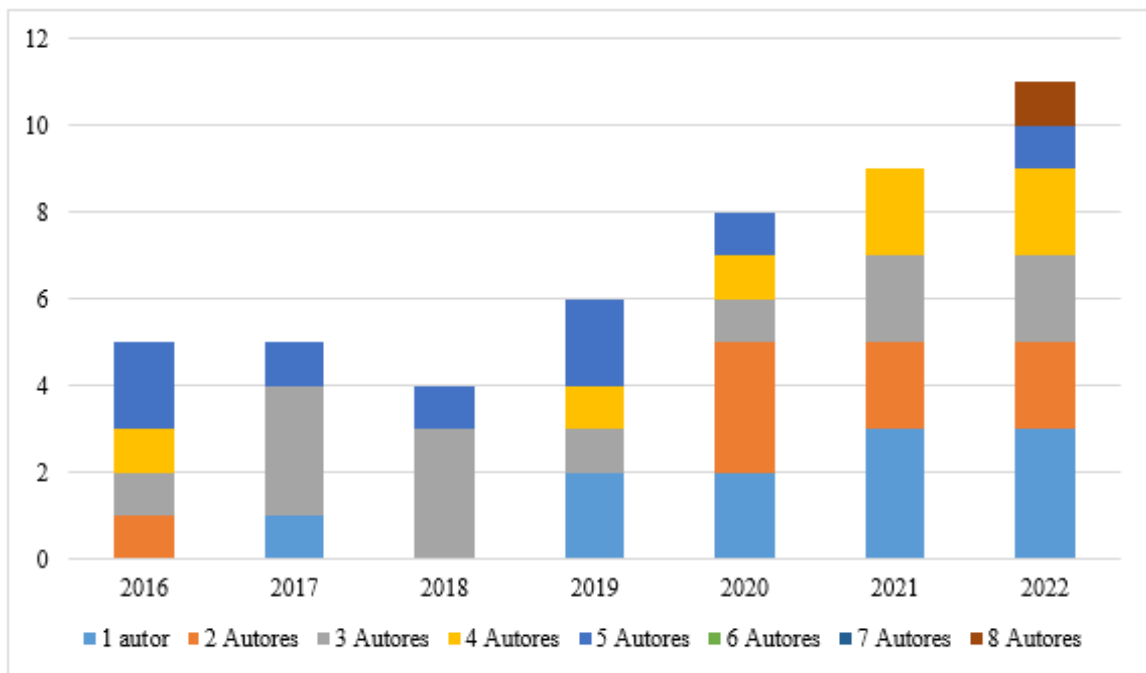
Tabela 2 - Número de autores por publicação

Quantidade de autores por artigo	Quantidade de artigos	Percentual (%)
1 autor	11	22,92%
2 autores	8	16,67%
3 autores	13	27,08%
4 autores	7	14,58%
5 autores	8	16,67%
8 autores	1	2,08%

Fonte: Elaboração própria (2023)

Também foi realizada uma análise da quantidade de autores envolvidos nas publicações em conjunto com a variação ao longo dos anos. Verificou-se que as pesquisas com três autores foram mais frequentes em 2017 e 2018. A partir de 2019, houve um aumento significativo de publicações com apenas um autor. Além disso, observou-se uma ampliação no número de publicações com quatro e cinco autores ao longo do tempo. A Figura 3 oferece uma visão aprofundada da dinâmica entre o número de autores e os anos de publicação.

Figura 3 - Distribuição do número de autores nas publicações analisadas ao longo do tempo



Fonte: Elaboração própria (2023)

4.5 Sexo dos autores

Na Tabela 3, apresenta-se os dados referentes ao sexo de todos os autores das publicações analisadas. Nota-se que há mais artigos com participação do sexo masculino, totalizando 117 pesquisadores (83,57%), enquanto do sexo feminino são 23 (16,43%). Esses dados revelam que a contribuição de pesquisadores do sexo masculino, para as pesquisas na área de inteligência artificial no mercado financeiro, é aproximadamente 5,09 vezes maior em comparação com a contribuição de pesquisadores do sexo feminino. Essa disparidade destaca uma diferença significativa na representação de sexo na autoria das publicações examinadas.

Tabela 3 - Sexo dos autores

Sexo dos autores	Quantidade	Percentual (%)
Masculino	117	83,57%
Feminino	23	16,43%

Fonte: Elaboração própria (2023)

4.6 País de origem das autorias


A distribuição geográfica dos autores revelou uma diversidade significativa de origens. A quantidade de autorias por país é: China (13 autorias); Inglaterra (6 autorias); Estados Unidos

da América (5 autorias); Brasil (4 autorias); Arábia Saudita e Austrália (3 autorias cada); Alemanha, Colômbia, França, Índia, Japão, Malásia, Polônia e Taiwan (2 autorias cada); e outros países (1 autoria cada). É possível visualizar essa delimitação na Figura 4.

Destacam-se como os principais contribuidores a China e a Inglaterra, juntas representam 29,23% das afiliações das autorias. Outros países que se destacam são os Estados Unidos da América e o Brasil, contribuindo com cerca de 13,85%.

Também foi possível examinar a colaboração entre países, e entre todas as nações a China destacou-se como a mais proeminente. Entre as relações mais significativas, destacam-se as com o Japão, a Inglaterra, a Malásia, a Arábia Saudita e a Espanha.

Figura 4 - Distribuição geográfica de autorias



Fonte: Elaboração própria (2023)

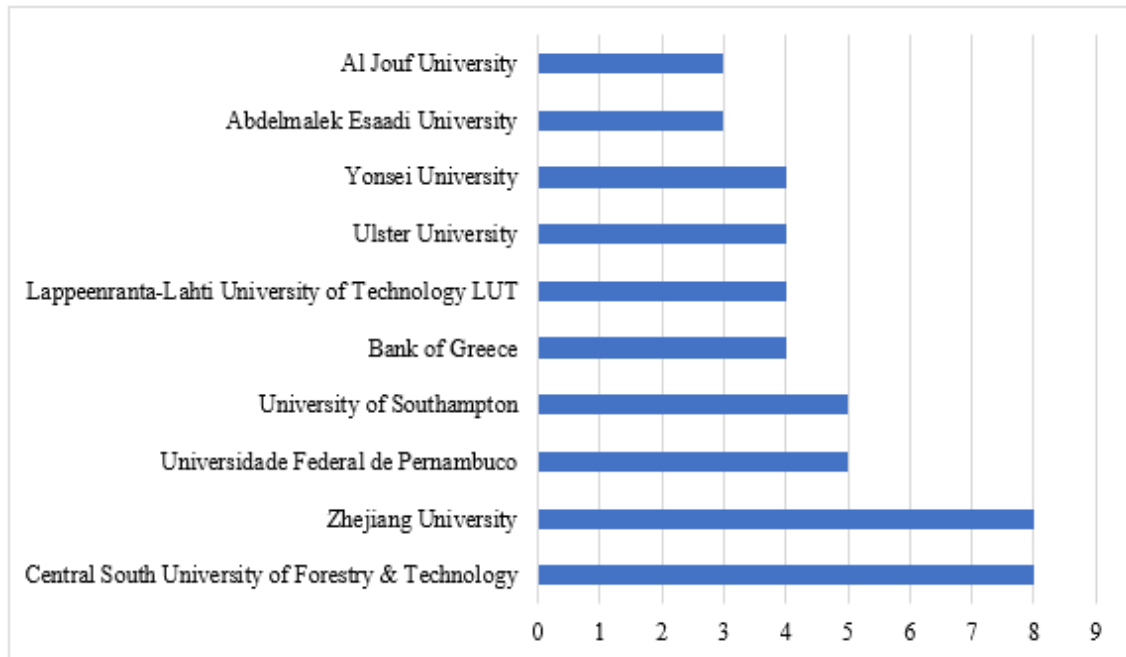
4.7 Afiliações acadêmicas dos autores e das autorias

Dos 140 acadêmicos dos 48 artigos analisados foi possível observar que eles possuem vinculação com 96 instituições diferentes, sendo 91 estrangeiras e 5 brasileiras. Destacou-se a participação de universidades e centros de pesquisa, representando 90,63% das afiliações analisadas. Ademais, foram identificadas colaborações relevantes com instituições do setor privado, compreendendo cerca de 4,17%, e órgãos governamentais, totalizando 5,21%.

As instituições com mais destaque baseadas no número de autores foram a Central South University of Forestry & Technology e a Zhejiang University, ambas com 8 autores (5,71%),

seguida pela Universidade de Pernambuco e pela University of Southampton, ambas com 5 autores (3,57%) e pelo Banco da Grécia com 4 autores (2,86%). A representação gráfica dessas distribuições está detalhada na Figura 5.


Figura 5 - Afiliações acadêmicas por autores



Fonte: Elaboração própria (2023)

Ao examinar a influência das afiliações acadêmicas, com foco nas autorias, observa-se que as instituições Central South University of Forestry & Technology, King Abdulaziz University, Peking University, Pontificia Universidad Javeriana, Shenzhen University, University System of Ohio e Zhejiang University são as principais produtoras de trabalhos acadêmicos no campo da inteligência artificial e mercado financeiro, cada uma com 2 autorias. As demais instituições possuem somente 1 autoria. Essa constatação baseia-se na análise de 48 artigos utilizados na pesquisa. A Figura 6 proporciona uma representação visual desses dados.

Figura 6 - Afiliações acadêmicas por autoria



Fonte: Elaboração própria (2023)

As instituições que se destacaram tanto por sua influência nas produções acadêmicas, quanto em relação aos autores quanto às autorias, foram a Central South University of Forestry & Technology e a Zhejiang University ambas com a significativa contribuição de oito autores e um total de duas autorias. Esses dados sugerem que as universidades emergem como instituições de destaque no tema de inteligência artificial no mercado financeiro. Suas proeminências não se limitam apenas à quantidade de autores envolvidos, mas também reflete na contribuição substantiva para o corpo acadêmico de conhecimento, evidenciada pelo número expressivo de autorias.

4.8 Lei de Lotka

A Lei de Lotka, ou Lei do Quadrado Inverso, descreve a frequência de publicação de autores em uma determinada área. O número de autores que contribuem com n trabalhos em um determinado campo científico é aproximadamente proporcional a $1/n^2$ daqueles que apresentam uma única contribuição (Lotka, 1926). Portanto, pode-se inferir que, à medida que a quantidade de artigos publicados aumenta, a presença de autores responsáveis por essas contribuições diminui.

Ao examinar os 48 artigos selecionados para a pesquisa, identificou-se a presença de 140 autores. No entanto, apenas 2 do total apresentaram mais de uma participação. Com o auxílio da Tabela 4, observou-se que o resultado revela discrepâncias em relação ao previsto pela Lei de Lotka, possivelmente influenciado pela limitada quantidade de estudos analisados.

Tabela 4 - Análise da participação dos autores, segundo a Lei de Lotka

Nº de artigos por autor	Nº de autores	Nº de autores esperados pela Lei de Lotka	Diferença entre a Lei de Lotka e o observado (%)	Multiplicador	Fórmula
1	138	138	0%		
2	2	34,50	-94,20%	25,00%	$(1/n^2)$
3	0	15,33	-100,00%	11,11%	$(1/n^2)$
4	0	8,63	-100,00%	6,25%	$(1/n^2)$
5	0	5,52	-100,00%	4,00%	$(1/n^2)$

Fonte: Elaboração própria (2023)

Os autores que mais se destacaram foram Chao-Chao Chen e Xiaolin Zheng, cada um contribuindo em dois dos 48 artigos analisados (8,33%). Ambos participaram da elaboração dos mesmos artigos, intitulados *FinBrain: when finance meets AI 2.0* e *FinBrain 2.0: when finance meets trustworthy AI*, datados de 2019 e 2022, respectivamente.

A Tabela 5 auxilia na análise da relevância dos autores que mais contribuíram nos artigos examinados pela pesquisa, empregando como métricas de impacto o índice H e o número de citações. Além disso, a tabela também apresenta o total de publicações já realizadas pelos autores e o ano de início de suas atividades acadêmicas.

Tabela 5 - Impacto dos autores

Autor	Nº total de publicações	Início da produção	Índice H	Total de citações
Xiaolin Zheng	4.715	2004	25	6.759
Chao-Chao Chen	40	2007	16	912

Fonte: Elaboração própria (2023)

4.9 Lei de Bradford

A Lei de Bradford, ou Lei da Dispersão, incide sobre um conjunto de periódicos para determinar o núcleo dos mais produtivos em uma determinada temática. A sua representação é

delineada por zonas que se distribuem em três, cada uma contendo cerca de um terço dos artigos, sendo proporcionalmente distribuída igual a $1:n:n^2$ (Bradford, 1934).

Essa delimitação identifica que um grupo de 4 periódicos (11,76%), os quais compõem a Zona 1, é responsável por aproximadamente 1/3 dos artigos utilizados na pesquisa. A zona 2, para conseguir um número aproximado de publicações precisou de 15 periódicos (42,86%), ou seja, 3,75 vezes o valor anterior. A última zona identificada é responsável por 16 periódicos (45,71%) e tem um número cerca de 4 vezes maior que a primeira.

Assim, conclui-se que dentre os 48 artigos utilizados na pesquisa e que foram publicados em 35 periódicos, a Zona 1 destaca-se como o grupo que concentra os periódicos mais influentes no tema pesquisado, o que pode fornecer uma base sólida para as decisões de pesquisadores que desejam publicar na área. A Tabela 6 apresenta como foi feita essa delimitação.

Tabela 6 - Delimitação dos periódicos em zonas, segundo a Lei de Bradford

Zonas	Periódicos	Nº de publicações	Classificação das zonas
Zona 1	4 periódicos	16	Núcleo
Zona 2	15 periódicos	16	Extensões
Zona 3	16 periódicos	16	Extensões

Fonte: Elaboração própria (2023)

De acordo com a Lei de Bradford, a Tabela 7 concentra-se no grupo de periódicos da Zona 1, que representa o núcleo, isto é, o grupo composto pelos periódicos mais produtivos no período de 2016 a 2022.

Tabela 7 - Periódicos que compõem o núcleo, segundo a Lei de Bradford

Periódicos	Nº de publicações	Porcentagem (%)	ISSN	Qualis	Fator de impacto
<i>Decision Support Systems</i>	2	4,44%	0167-9236	A1	7,5
<i>Expert Systems</i>	2	4,44%	0266-4720	A3	3,3
<i>Expert Systems with Applications</i>	9	20,00%	0957-4174	A1	8,5
<i>IEEE ACCESS</i>	3	6,67%	2169-3536	A3	3,9

Fonte: Elaboração própria (2023)

Dentre todos os periódicos que compõem o núcleo, segundo a Lei de Bradford, o qual mais se destaca é o *Expert Systems with Applications*, com 9 publicações (20,00%). Este possui uma classificação Qualis Capes A1, indicando que é considerado um periódico de alta qualidade acadêmica, e um fator de impacto de 8,5, destacando a sua relevância e influência.

4.10 Lei de Zipf

A Lei de Zipf, ou Lei do Mínimo Esforço, descreve a relação entre a frequência de palavras em um texto e sua ordem de série. Essa lei reflete que ao buscar simplificar a expressão linguística, as palavras não se dispersam, mas, inversamente, uma mesma palavra é empregada de maneira recorrente. A equação para esse relacionamento é: $r \times f = k$, onde r é a posição da palavra, f é a sua frequência e k é a constante (Zipf, 2016). Desse modo, com a lei de Zipf, é possível traçar um ranking de palavras que mais aparecerem em um determinado trecho ou texto.

Para a análise das palavras-chave utilizadas pelos autores, optou-se por preservá-las em uma única unidade, ao invés de separá-las em termos individuais, permitindo uma análise mais abrangente e contextualizada.

Ao analisar as palavras-chave utilizadas pelos autores, foi possível identificar um total de 241 termos. Através da multiplicação da ordem de série pela frequência de ocorrência, obtivemos a constante conforme estabelecida pela Lei de Zipf, ilustrada na Tabela 8.

Tabela 8 - Frequências das palavras-chave, segundo a Lei de Zipf

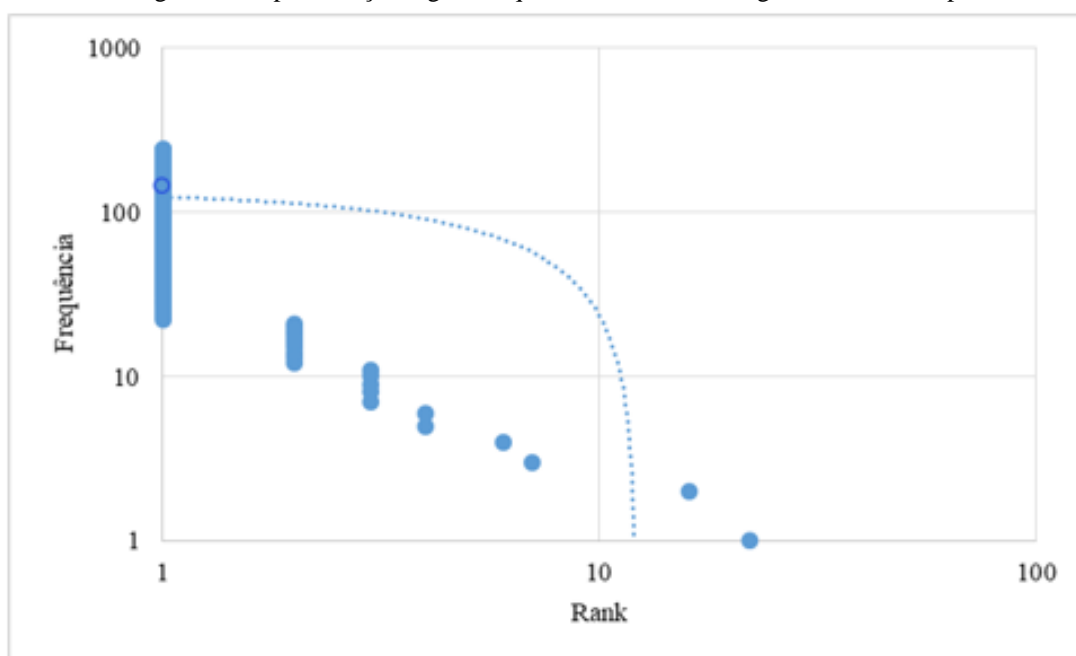
Rank (r)	Frequência (f)	Constante (r x f = k)
1	22	22
2	16	32
3	7	21
4	6	24
5	4	20
6	4	24
7	3	21
8	3	24
9	3	27
10	3	30

Fonte: Elaboração própria (2023)

Após análise dos dados fornecidos, constatou-se que a frequência das palavras-chave tende a diminuir à medida que seu rank aumenta, o que é consistente com a Lei de Zipf. No entanto, notou-se que o produto do rank e frequência apresentou variação, indicando que a constante não é uniforme para todas as palavras-chave.

A Lei de Zipf determina que a frequência das palavras é inversamente proporcional ao seu rank. Quando essa relação é plotada em um gráfico log-log, a expectativa é que se manifeste como uma linha reta. Entretanto, após análise da Figura 7, verificou-se que a linha não aderiu ao padrão antecipado. É possível concluir, portanto, que a Lei de Zipf não se aplica perfeitamente a esse conjunto de dados.

Figura 7 - Representação log da frequência versus rank, segundo a Lei de Zipf



Fonte: Elaboração própria (2023)

Com o propósito de realizar uma análise das palavras-chave empregadas pelos autores em zonas de distribuição, segundo a Lei de Zipf, visando delimitar sua importância no estudo, elas foram categorizadas em três grupos distintos: informação trivial, informação interessante e ruído (Quoniam et al., 2001).

A classificação de cada conjunto teve como critério a frequência da enésima posição em relação à primeira frequência. Dessa forma, os grupos foram divididos considerando o valor mais elevado dentro de cada um, e, em seguida, esse valor foi dividido por 10. A Tabela 9 auxilia na observação dos agrupamentos.

Tabela 9 - Distribuição das palavras-chave

Zona	Quantidade de palavras	Frequência	Frequência (%)
Trivial	11	74	30,71%
Interessante	10	20	8,30%
Ruído	147	147	61,00%

Fonte: Elaboração própria (2023)

A Zona 1, classificada como área de informação trivial, engloba as palavras-chave mais representativas da temática em estudo. Em contrapartida, a Zona 2, referida como área de informação relevante, inicialmente pode não parecer crucial, mas revela-se potencialmente inovadora em um segundo momento. Por último, a Zona 3, denominada como ruído, caracteriza-se por conter conceitos ainda não emergentes (Quoniam et al., 2001).

Algumas das palavras-chave que se destacam na zona trivial incluem: "*artificial intelligence*," "*machine learning*," "*finance*" e "*deep learning*." Na zona interessante, são identificadas 10 palavras, destacando-se termos como "*bibliometric analysis*", "*big data*" e "*financial industry*." Por fim, a zona de ruído, composta por 147 palavras, destaca termos como "*computational finance*", "*corporate governance*" e "*data stream mining*."

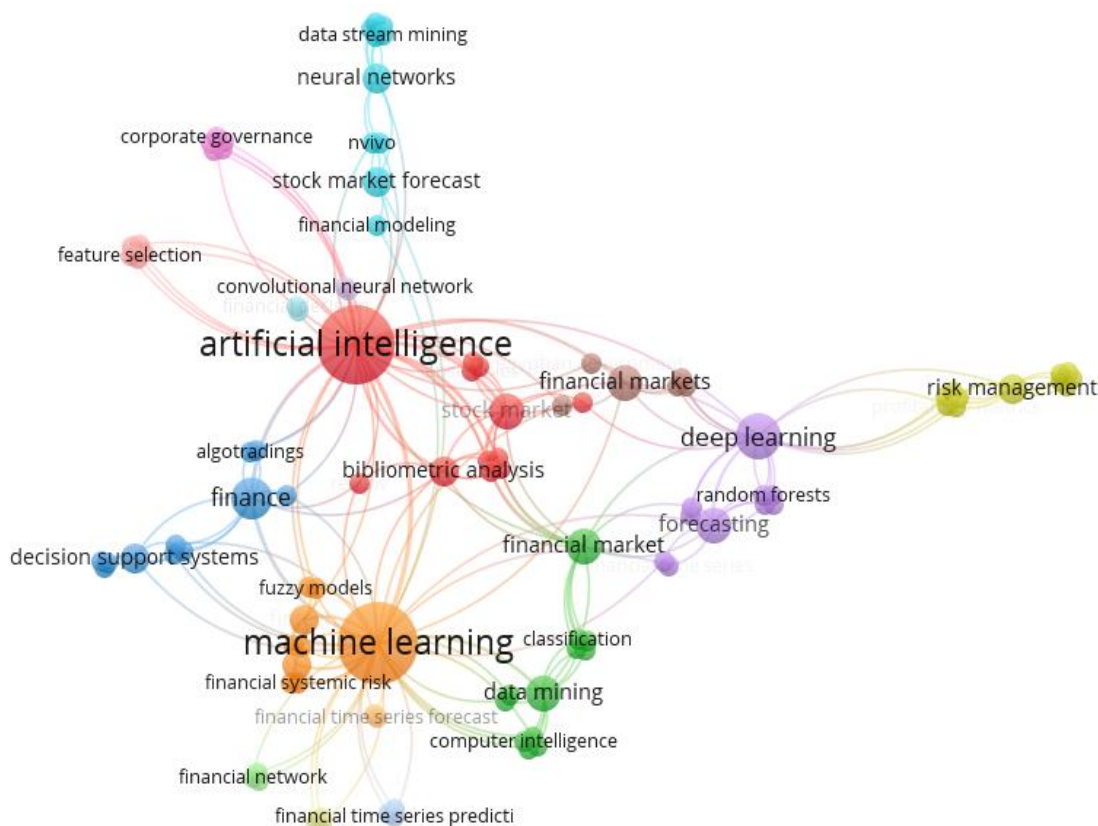
4.11 Rede de ocorrência das palavras-chave

Analisando os 48 artigos base da pesquisa de análise bibliométrica, foi possível identificar um total de 241 palavras-chave selecionadas pelos autores, com o requisito mínimo de 1 ocorrência. A média de ocorrência por publicação foi de aproximadamente 5,02.

As palavras-chave com maior número de incidência foram "*artificial intelligence*" (9,13%), "*machine learning*" (6,64%), "*finance*" (2,90%), "*deep learning*" (2,49%) e "*financial market*" (1,66%).

Com o auxílio da Figura 8, observa-se uma rede de ocorrência entre as palavras-chave mais utilizadas pelos autores. A rede constitui uma representação gráfica de dados, materializada por meio de círculos cujos tamanhos variam conforme a frequência de citações associadas a cada item, refletindo, dessa forma, a sua relevância relativa dentro do contexto da rede. Adicionalmente, a tonalidade de cada círculo é determinada pela afiliação categorial do item a um dos distintos *clusters* existentes. Vale ressaltar que a proximidade entre *clusters* vizinhos indica a força de sua relação (Van Eck; Waltman, 2023).

Figura 8 - Rede de ocorrência das palavras-chave



Fonte: VOSviewer

Ao observar a rede, verifica-se que as palavras-chave mais frequentes formam os principais *clusters*. O maior deles é representado pela cor vermelha e refere-se à palavra “*artificial intelligence*” com 22 ocorrências e uma força total de vínculo de 51. Essa medida indica a intensidade das conexões com as outras palavras-chave, determinando a influência conjunta dessas relações.

Em seguida, destacam-se os *clusters* laranja, azul, roxo e verde. O agrupamento laranja refere-se à “*machine learning*”, apresentando 16 ocorrências e uma força total de vínculo de 50. O azul refere-se a “*finance*”, com 7 ocorrências e uma força total de vínculo de 15. O roxo está relacionado a “*deep learning*”, contando com 6 ocorrências e uma força total de vínculo de 22. Por fim, o verde é associado a “*financial market*”, com 4 ocorrências e uma força total de vínculo de 16.

Clusters menores, compostos por palavras-chave menos frequentes, também se destacam pela intensidade evidenciada na rede, expressa pelo número de conexões estabelecidas com outros grupos. Assim, é possível ter uma compreensão abrangente das inter-

relações e agrupamentos de termos mais frequentes em pesquisas sobre inteligência artificial no mercado financeiro.

5 CONSIDERAÇÕES FINAIS

O presente trabalho apresentou uma análise abrangente do estado atual e das tendências nas pesquisas acadêmicas que exploram a aplicação da inteligência artificial no mercado financeiro. Ao longo do estudo, foi conduzida uma revisão bibliométrica da literatura, com a análise de artigos publicados no período de 2016 a 2022.

A análise bibliométrica verificou um total de 48 artigos, coletados da base de dados do Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), do Google Acadêmico e da *Web of Science* (WoS). Esses artigos foram identificados mediante a presença de termos combinados como “Mercado Financeiro” ou “*Financial Market*”; “Finanças” ou “*Finance*”; “Aprendizado de Máquina” ou “*Machine Learning*”; e “Inteligência Artificial” ou “*Artificial Intelligence*”.

Destaca-se uma nítida tendência de crescimento na produção científica sobre o tema, tendo início em 2018. Vale ressaltar que o ano de 2022 se destaca como o de maior expressividade, registrando um total de 11 artigos. Quanto à distribuição geográfica, a China emergiu como o país com o maior número de publicações, totalizando 13. Quanto às áreas de pesquisa, os artigos predominam na categoria “Ciência da Computação”.

A colaboração entre um e três autores destacou-se como predominante nas pesquisas acadêmicas sobre o tema inteligência artificial no mercado financeiro. Nesse contexto, a China sobressaiu-se como o país com o maior número de colaborações entre os autores. Em relação ao sexo dos autores, torna-se evidente uma maior participação de pesquisadores do sexo masculino, sendo cerca de 5,09 vezes superior à contribuição feminina, refletindo uma notável disparidade de sexo nesse domínio de estudo.

No que diz respeito às citações, observou-se uma concentração nos anos de 2016 e 2019 de publicações mais citadas. Destaca-se como artigo mais referenciado *A deep learning framework for financial time series using stacked autoencoders and long-short term memory*, de autoria de Wei Bao, Jun Yue e Yulei Rao, publicado em 2017, com um total de 416 citações e uma média de citações por ano de 59,43.

Dentre as instituições notáveis tanto pelo número de autores quanto pela quantidade de autorias, destacam-se a Central South University of Forestry & Technology, localizada na China, e a Zhejiang University, também na China, ambas com duas autorias e oito autores.

Este trabalho aplicou as três leis fundamentais da bibliometria: Lei de Lotka, Lei de Bradford e Lei de Zipf. Ao aplicar a Lei de Lotka, notou-se que os autores proeminentes nos artigos são Chao-Chao Chen e Xiaolin Zheng. Ambos contribuíram com dois trabalhos sobre o tema, sendo eles *FinBrain: when finance meets AI 2.0* e *FinBrain 2.0: when finance meets trustworthy AI*.

Relativamente à Lei de Bradford, constatou-se que os principais periódicos proeminentes nesta área são *Decision Support Systems*, *Expert Systems*, *Expert Systems with Applications* e *IEEE ACCESS*.

Por fim, pela Lei de Zipf, constatou-se que as palavras-chave mais frequentes nos artigos são "*artificial intelligence*", "*machine learning*", "*finance*" e "*deep learning*". Em relação às premissas estabelecidas pelas leis bibliométricas, observou-se que as Leis de Lotka e Zipf não foram confirmadas na amostra, ao contrário da Lei de Bradford.

A transformação no mercado financeiro, impulsionada pela adoção da inteligência artificial, representa uma mudança significativa na forma como as instituições financeiras operam. As diversas aplicações dessa tecnologia têm proporcionado notáveis benefícios, incluindo aprimoramento da eficiência, precisão e automatização de procedimentos. No entanto, é importante considerar os desafios e implicações associados ao seu uso, como a segurança cibernética e a ética. Espera-se que este trabalho contribua para o aprofundamento do conhecimento sobre as aplicações e implicações da inteligência artificial no mercado financeiro, incentivando discussões e pesquisas futuras nessa área em constante evolução.

Para futuras pesquisas, é recomendável ampliar a base de dados, a fim de incluir um maior número de trabalhos acadêmicos, permitindo resultados mais sólidos na aplicação das principais leis bibliométricas. Adicionalmente, é aconselhável investigar as redes de ocorrência entre instituições, autores, citações e países. Analisar os níveis acadêmicos dos autores e os métodos de pesquisa utilizados nos estudos sobre a área pode contribuir significativamente para o enriquecimento das análises.

REFERÊNCIAS²

ABOULOULA, Khalid *et al.* Artificial Intelligence–Based Methods of Financial Time Series for Trading Experts in a Relational D. *In: KRIT, Salah-Ddine et al. Internet of Everything and Big Data: major challenges in smart cities.* Boca Raton: CRC Press, p. 87-100, 2021.

AHMED, Shamima *et al.* Artificial intelligence and machine learning in finance: A bibliometric review. **Research in International Business and Finance**, [S.L], v. 61, p. 101646, 2022. DOI: <https://doi.org/10.1016/j.ribaf.2022.101646>. Acesso: 28 set. 2023.

ARAÚJO, Carlos Alberto. Bibliometria: evolução histórica e questões atuais. **Em Questão**, Porto Alegre, v. 12, n. 1, p. 11-32, 2006. Disponível em: <http://hdl.handle.net/20.500.11959/brapci/10124>. Acesso em: 23 nov. 2023.

BAO, Te *et al.* Algorithmic Trading in Experimental Markets with Human Traders: A Literature Survey. **Handbook of Experimental Finance**, [S.L], n. 23, p. 302-322, 2021. DOI: <https://dx.doi.org/10.2139/ssrn.3908065>. Acesso em: 09 set. 2023.

BAO, Wei; YUE, Jun; RAO, Yulei. A deep learning framework for financial time series using stacked autoencoders and long-short term memory. 2017. 24 f. Monografia (Especialização) - Curso de Ciência da Computação, Peking University, Pequim, 2017. DOI: <https://doi.org/10.1371/journal.pone.0180944>. Acesso em: 11 out. 2023.

BRADFORD, S. C. Sources of information on scientific subjects. **Engineering**, [S.L], v. 26, n. 137, p. 85-86, 1934.

BROOKS, R. A. **Flesh and Machines: How Robots Will Change Us.** Londres: Vintage, 2002.

BUSTOS, Oscar; POMARES-QUIMBAYA, Alexandra. Stock market movement forecast: A systematic review. **Expert Systems with Applications**, [S.L], v. 156, p. 113464, 2020. DOI: <https://doi.org/10.1016/j.eswa.2020.113464>. Acesso em: 25 set. 2023.

CAVALCANTE, Rodolfo C. *et al.* Computational Intelligence and Financial markets: A Survey and Future Directions. **Expert Systems with Applications**, [S.L], v. 55, p. 194-211, 2016. DOI: <https://doi.org/10.1016/j.eswa.2016.02.006>. Acesso em: 22 set. 2023.

CHATZIS, S. P. *et al.* Forecasting stock market crisis events using deep and statistical machine learning techniques. **Expert systems with applications**, [S.L], v. 112, p. 353-371, 2018. DOI: <https://doi.org/10.1016/j.eswa.2018.06.032>. Acesso em: 24 set. 2023.

CHINNAMGARI, Sunil Kumar. **R Machine Learning Projects: Implement supervised, unsupervised, and reinforcement learning techniques using R 3.5.** 1 ed. Birmingham: Packt Publishing Ltd, 2019.

DIGNUM, V. **Ética da Inteligência Artificial e Dados.** Rio de Janeiro: Alta Books, 2020.

² Este trabalho foi elaborado utilizando as normas da ABNT.

DOMINGOS, Pedro. A few useful things to know about Machine Learning. **Communications of the ACM**. Seattle, v. 55, n. 10, p. 78-87, 2012. DOI: <https://doi.org/10.1145/2347736.2347755>. Acesso em: 30 jul. 2023.

ERSAN, Oğuz *et al.* High-frequency Trading and its Impact on Market Liquidity: a review of literature. **Other Microeconomics: General Equilibrium & Disequilibrium Models of Financial Markets (Topic)**, [S.L], v. 5, n. 1, p. 1-18, 2020. Disponível em: <https://ssrn.com/abstract=3756596>. Acesso em: 16 set. 2023.

FILHO, Armando Mellagi; ISHIKAWA, Sergio. **Mercado financeiro e de capitais**. 3. ed. São Paulo: Atlas, 2003.

FORTUNA, Eduardo. **Mercado financeiro: produtos e serviços**. 21. ed. Rio de Janeiro: Qualitymark, 2016.

GERLEIN, Eduardo A. *et al.* Evaluating machine learning classification for financial trading: An empirical approach. **Expert Systems with Applications**, [S.L], v. 54, p. 193-207, 2016. DOI: <https://doi.org/10.1016/j.eswa.2016.01.018>. Acesso em: 22 set. 2023.

GOODELL, J. W. *et al.* Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis. **Journal of Behavioral and Experimental Finance**, [S.L], v. 32, p. 100577, 2021. DOI: <https://doi.org/10.1016/j.jbef.2021.100577>. Acesso em: 05 out. 2023.

GUEDES, Vania Lisboa da Silveira. A BIBLIOMETRIA E A GESTÃO DA INFORMAÇÃO E DO CONHECIMENTO CIENTÍFICO E TECNOLÓGICO: uma revisão da literatura. **Ponto de Acesso**, [S.L], v. 6, n. 2, p. 74-109, 2012. DOI: <https://doi.org/10.9771/1981-6766rpa.v6i2.5695>. Acesso em: 23 nov. 2023.

HARDIANTO, Roki *et al.* K-Means Clustering in Determining the Category of Stock Items In Angkasa Mart. **Knowbase: International Journal of Knowledge in Database**, [S.L], v. 2, n. 1, p. 30-45, 2022. DOI: <https://doi.org/10.30983/ijokid.v2i1.5411>. Acesso em: 29 set. 2023.

HENRIQUE, Bruno Miranda; SOBREIRO, Vinicius Amorim; KIMURA, Herbert. Literature review: Machine learning techniques applied to financial market prediction. **Expert Systems with Applications**, [S.L], v. 124, p. 226-251, 2019. DOI: <https://doi.org/10.1016/j.eswa.2019.01.012>. Acesso em: 25 set. 2023.

HOSSAIN, Shahadat. High-Frequency Trading (HFT) and Market Quality Research: an evaluation of the alternative HFT proxies. **Journal of Risk and Financial Management**, [S.L], v. 15, n. 2, p. 54, 2022. DOI: <https://doi.org/10.3390/jrfm15020054>. Acesso: 17 set. 2023.

HSU, Ming-Wei *et al.* Bridging the divide in financial market forecasting: machine learners vs. financial economists. **Expert systems with Applications**, [S.L], v. 61, p. 215-234, 2016. DOI: <https://doi.org/10.1016/j.eswa.2016.05.033>. Acesso em: 22 set. 2023.

IGUAL, Laura; SEGUÍ, Santi. **Introduction to data science: A Python approach to concepts, techniques and applications**. Suíça: Springer International Publishing, 2017.

IZBICKI, Rafael; SANTOS, Tiago Mendonça dos. **Aprendizado de máquina: uma abordagem estatística**. São Paulo: Atlas, 2020.

KOU, Gang *et al.* Machine learning methods for systemic risk analysis in financial sectors. **Technological and Economic Development of Economy**, [S.L], v. 25, n. 5, p. 716-742, 2019. DOI: <https://doi.org/10.3846/tede.2019.8740>. Acesso em: 25 set. 2023.

KUMBURE, Mahinda Mailagaha *et al.* Machine learning techniques and data for stock market forecasting: A literature review. **Expert Systems with Applications**, [S.L], v. 197, p. 116659, 2022. DOI: <https://doi.org/10.1016/j.eswa.2022.116659>. Acesso em: 28 set. 2023.

LEE, Tae Kyun *et al.* Global stock market investment strategies based on financial network indicators using machine learning techniques. **Expert Systems with Applications**, [S.L], v. 117, p. 228-242, 2019. DOI: <https://doi.org/10.1016/j.eswa.2018.09.005>. Acesso em: 25 set. 2023.

LEIPPOLD, Markus; WANG, Qian; ZHOU, Wenyu. Machine learning in the Chinese stock market. **Journal of Financial Economics**, [S.L], v. 145, n. 2, p. 64-82, 2022. DOI: <https://doi.org/10.1016/j.jfineco.2021.08.017>. Acesso em: 22 jul. 2023.

LIN, Tom C. W. Artificial Intelligence, Finance, and the Law. **Fordham Law Review**, [S.L], v. 88, p. 531, 2019. Disponível em: <https://ssrn.com/abstract=3480607>. Acesso em: 25 jul. 2023.

LOPES, Rafael Guasselli; REBECHI, Luiz Gabriel; BAZOTTI, João Pedro Lopes. USO DE CHATBOT COMO REFORÇO PARA A APRENDIZAGEM DE ESTUDANTES PORTADORES DE NECESSIDADES ESPECIAIS. *In: MoExp-Mostra De Ensino, Pesquisa E Extensão*, 9, 2019, Osório. **Anais [...]**. Osório: [S.I], 2019.

LOTKA, Alfred J. The frequency distribution of scientific productivity. **Journal of the Washington academy of sciences**, [S.L], v. 16, n. 12, p. 317-323, 1926.

MARCUS, G.; DAVIS, E. **Rebooting AI: Building Artificial Intelligence We Can Trust**. Londres: Vintage, 2019.

MARWALA, Tshilidzi; HURWITZ, Evan. **Artificial intelligence and economic theory: skynet in the market**. Suíça: Springer International Publishing, 2017.

MENDONÇA, C. M. C; ANDRADE, A. M. V.; NETO, M. V. S. Uso da IoT, Big Data e Inteligência Artificial nas capacidades dinâmicas. **Revista Pensamento Contemporâneo em Administração**, [S.L], v. 29, n. 4, p. 37-60, 2019. DOI: <https://doi.org/10.12712/rpca.v12i1.11350>. Acesso em: 02 set. 2023.

MHLANGA, David. Industry 4.0 in finance: the impact of artificial intelligence (AI) on digital financial inclusion. **International Journal of Financial Studies**, [S.L], v. 8, n. 3, p. 45, 2020. DOI: <https://doi.org/10.3390/ijfs8030045>. Acesso em: 10 out. 2023.

MPIA, Héritier Nsenge; MBURU, Lucy Waruguru; MWENDIA, Simon Nyaga. Applying Data Mining in Graduates' Employability: A Systematic Literature Review. **International Journal**

of **Engineering Pedagogy**, [S.L], v. 13, n. 2, p.86-108, 2023. DOI: <https://doi.org/10.3991/ijep.v13i2.33643>. Acesso em: 29 set. 2023.

NABIPOUR, Mojtaba *et al.* Predicting Stock Market Trends Using Machine Learning and Deep Learning Algorithms Via Continuous and Binary Data; a Comparative Analysis. **IEEE Access**, [S.L], v. 8, p. 150199-150212, 2020. DOI: <https://doi.org/10.1109/ACCESS.2020.3015966>. Acesso em: 23 jul. 2023.

NANDANWAR, Anurag; WANJARI, Prajwal; SIRASKAR, Warsha. Algorithmic Trading. **International Research Journal of Modernization in Engineering Technology and Science**, [S.L], v. 4, n. 5, p. 5243-5244, 2022.

NETO, Alexandre A. **Mercado Financeiro**. Rio de Janeiro: Atlas, 2021. *E-book*. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788597028171/>. Acesso em: 19 nov. 2023.

OTTONICAR, Selma Leticia Capinzaiki; ATAYDE, Gisele Rodrigues; EULALIA, Luis Antonio de Santa. O Big Data no desenvolvimento da indústria 4.0: novas perspectivas para o empreendedorismo acadêmico. *In*: MARTÍNEZ-ÁVILA, Daniel; SOUZA, Edna Alves de; GONZALEZ, Maria Eunice Quilici. **Informação, Conhecimento, Ação Autônoma e Big Data: Continuidade ou Revolução?**. São Paulo: UNESP, p. 185-202, 2019.

OZCARIZ, Ignacio. Quantum Supremacy: in financial markets (forex). **Ssrn Electronic Journal**, [S.L], p. 1-9, 2019. DOI: <http://dx.doi.org/10.2139/ssrn.3630301>. Acesso em: 07 set. 2023.

PARK, Deog-Yeong; LEE, Ki-Hoon. Practical Algorithmic Trading Using State Representation Learning and Imitative Reinforcement Learning. **IEEE Access**, [S.L], v. 9, p. 152310-152321, 2021. DOI: <http://dx.doi.org/10.1109/access.2021.3127209>. Acesso em: 09 set. 2023.

PAYNE, Elizabeth H. M.; DAHL, Andrew J.; PELTIER, James. Digital servitization value co-creation framework for AI services: a research agenda for digital transformation in financial service ecosystems. **Journal of Research in Interactive Marketing**, [S.L], v. 15, n. 2, p. 200-222, 2021. DOI: <https://doi.org/10.1108/JRIM-12-2020-0252>. Acesso em: 26 set. 2023.

PINHEIRO, Juliano Lima. **Mercado de Capitais**. São Paulo: Grupo GEN, 2019. *E-book*. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788597021752/>. Acesso em: 17 nov. 2023.

PRICOPE, Tidor-Vlad. Deep reinforcement learning in quantitative algorithmic trading: A review. **arXiv preprint arXiv:2106.00123**, 2021. DOI: <https://doi.org/10.48550/arXiv.2106.00123>. Acesso em: 09 set. 2023.

QUONIAM, Luc *et al.* Inteligência obtida pela aplicação de data mining em base de teses francesas sobre o Brasil. **Ciência da informação**, Brasília, v. 30, n. 2, p. 20-28, 2001. DOI: <https://doi.org/10.1590/S0100-19652001000200004>. Acesso em: 26 nov. 2023.

RICH, Elaine; KNIGHT, Kevin. **Artificial intelligence**. 2. ed. Nova York: McGraw-Hill, 1991.

RODRIGUES, A. A.; DIAS, G. A. Estudos sobre visualização de dados científicos no contexto da Data Science e do Big Data. **Pesquisa Brasileira em Ciência da Informação e Biblioteconomia**, [S.L], v. 12, n. 1, p. 1-2, 2017. DOI: 10.22478/ufpb.1981-0695.2017v12n1.34774. Acesso em: 03 set. 2023.

RODRIGUES, C.; VIERA, A. F. G. Estudos bibliométricos sobre a produção científica da temática Tecnologias de Informação e Comunicação em bibliotecas. **InCID: Revista de Ciência da Informação e Documentação**, [S.L], v. 7, n. 1, p. 167-180, 2016. DOI: <http://dx.doi.org/10.11606/issn.2178-2075.v7i1p167-180>. Acesso em: 23 nov. 2023.

ROSA, Caroline Silvério. **Estudo sobre as técnicas e métodos de análise de dados no contexto de Big Data**. 2018. TCC (Graduação) - Curso de Engenharia Eletrônica e de Telecomunicações, Universidade Federal de Uberlândia, Patos de Minas, 2018.

RUSSELL, Stuart; NORVIG, Peter. **Inteligência Artificial: Uma Abordagem Moderna**. São Paulo: Pearson, 2014.

SALKUTI, Surender Reddy. A survey of big data and machine learning. **International Journal of Electrical & Computer Engineering**, [S.L], v. 10, n. 1, p. 575-580, 2020. DOI: <http://doi.org/10.11591/ijece.v10i1.pp575-580>. Acesso em: 03 set. 2023.

SCAGLIONE, Thais *et al.* Estado da Arte sobre o uso de Big Data no Design: Perspectiva de Sistemas Produtos+ Serviços Sustentáveis. **DAT Journal**, [S.L], v. 6, n. 1, p. 229-244, 2021. DOI: <https://doi.org/10.29147/dat.v6i1.337>. Acesso em: 05 set. 2023.

SELAN, Beatriz. **Mercado financeiro**. [S.L.]: Estácio, 2015.

SHANG, Ziyu; WANG, Zhongyuan. Machine Learning in Finance: A Brief Review. **Atlantis Press**, 2022 International Conference on Artificial Intelligence, Internet and Digital Economy (ICAID 2022), [S.L], p. 258-264, 2022. DOI: https://doi.org/10.2991/978-94-6463-010-7_27. Acesso em: 24 nov. 2023.

SILVA, A.; SANTOS, B. **Deep Learning para Análise de Sentimentos**. São Paulo: Novatec, 2022.

SILVA, J. A. **Mercado financeiro: conceitos e aplicações**. 5. ed. São Paulo: Atlas, 2018.

THÉATE, Thibaut; ERNST, Damien. An application of Deep Reinforcement Learning to Algorithmic Trading. **Expert Systems with Applications**, [S.L], v. 173, p. 114632, 2021. DOI: <https://doi.org/10.1016/j.eswa.2021.114632>. Acesso em: 26 set. 2023.

TUYGUNOVICH, Alikulov Azamat; ISLAMOVNA, Gulbayeva Feruza. WHAT FACTORS INFLUENCE THE ACTIVITY OF RETAIL INVESTORS IN THE CAPITAL MARKET. **Gospodarka i Innowacje**, [S.L.], v. 29, p. 373-380, 2022.

VAN ECK, Ness Jan; WALTMAN, Ludo. VOSviewer Manual: Manual for VOSviewer version 1 .6.19. **CWTS Meaningful metrics**. Leiden, 2023.

WENG, Bin; AHMED, Mohamed A.; MEGAHED, Fadel M. Stock market one-day ahead movement prediction using disparate data sources. **Expert Systems with Applications**, [S.L],

v. 79, p. 153-163, 2017. DOI: <https://doi.org/10.1016/j.eswa.2017.02.041>. Acesso em: 11 out. 2023.

ZAHARUDIN, K. Z.; YOUNG, M. R.; HSU, WH. High-frequency trading: definition, implications, and controversies. **Journal of Economic Surveys**, [S.L], v. 36, n. 1, p. 75-107, 2021. DOI: <http://dx.doi.org/10.1111/joes.12434>. Acesso em: 14 set. 2023.

ZHENG, Xiao-lin *et al.* FinBrain: when finance meets AI 2.0. **Frontiers of Information Technology & Electronic Engineering**, [S.L], v. 20, n. 7, p. 914-924, 2019. DOI: <https://doi.org/10.1631/FITEE.1700822>. Acesso em: 12 out. 2023.

ZHOU, Jun *et al.* FinBrain 2.0: when finance meets trustworthy AI. **Frontiers of Information Technology & Electronic Engineering**, [S.L], v. 23, n. 12, p. 1747-1764, 2022. DOI: <https://doi.org/10.1631/FITEE.2200039>. Acesso em: 14 out. 2023.

ZIPF, George Kingsley. **Human behavior and the principle of least effort: An introduction to human ecology**. [S.L.]: Ravenio Books, 2016.

APÊNDICE - LISTA DE TRABALHOS OBSERVADOS

AHMED, Shamima *et al.* Artificial intelligence and machine learning in finance: A bibliometric review. **Research in International Business and Finance**, [S.L], v. 61, p. 101646, 2022. DOI: <https://doi.org/10.1016/j.ribaf.2022.101646>. Acesso: 28 set. 2023.

ALDHYANI, T. H. H.; ALZHRANI, A. Framework for predicting and modeling stock market prices based on deep learning algorithms. **Electronics**, [S.L], v. 11, n. 19, p. 3149, 2022. DOI: <https://doi.org/10.3390/electronics11193149>. Acesso em: 30 set. 2023.

BAO, Wei; YUE, Jun; RAO, Yulei. A deep learning framework for financial time series using stacked autoencoders and long-short term memory. 2017. 24 f. Monografia (Especialização) - Curso de Ciência da Computação, Peking University, Pequim, 2017. DOI: <https://doi.org/10.1371/journal.pone.0180944>. Acesso em: 11 out. 2023.

BERRADI, Zahra *et al.* A comprehensive review of artificial intelligence Techniques in Financial Market. **IEEE Access**, [S.L], p. 367-371, 2021. DOI: <https://doi.org/10.1109/CiSt49399.2021.9357175>. Acesso em: 02 out. 2023.

BREDT, Stephan. Artificial Intelligence (AI) in the financial sector—Potential and public strategies. **Frontiers in Artificial Intelligence**, [S.L], v. 2, p. 16, 2019. DOI: <https://doi.org/10.3389/frai.2019.00016>. Acesso em: 13 out. 2023.

BUSTOS, Oscar; POMARES-QUIMBAYA, Alexandra. Stock market movement forecast: A systematic review. **Expert Systems with Applications**, [S.L], v. 156, p. 113464, 2020. DOI: <https://doi.org/10.1016/j.eswa.2020.113464>. Acesso em: 25 set. 2023.

BUTLER, Tom. What's Next in the Digital Transformation of Financial Industry?. **IT Professional**, [S.L], v. 22, n. 1, p. 29-33, 2020. DOI: <https://doi.org/10.1109/MITP.2019.2963490>. Acesso em: 12 out. 2023.

CAVALCANTE, Rodolfo C. *et al.* Computational Intelligence and Financial markets: A Survey and Future Directions. **Expert Systems with Applications**, [S.L], v. 55, p. 194-211, 2016. DOI: <https://doi.org/10.1016/j.eswa.2016.02.006>. Acesso em: 22 set. 2023.

CHATZIS, S. P. *et al.* Forecasting stock market crisis events using deep and statistical machine learning techniques. **Expert systems with applications**, [S.L], v. 112, p. 353-371, 2018. DOI: <https://doi.org/10.1016/j.eswa.2018.06.032>. Acesso em: 24 set. 2023.

CHEN, Kun; YIN, Jian; PANG, Sulin. A design for a common-sense knowledge-enhanced decision-support system: Integration of high-frequency market data and real-time news. **Expert Systems**, [S.L], v. 34, n. 3, 2017. DOI: <https://doi.org/10.1111/exsy.12209>. Acesso em: 22 set. 2023.

CHOPRA, Ritika; SHARMA, Gagan Deep. Application of artificial intelligence in stock market forecasting: a critique, review, and research agenda. **Journal of risk and financial management**, [S.L], v. 14, n. 11, p. 526, 2021. DOI: <https://doi.org/10.3390/jrfm14110526>. Acesso em: 07 out. 2023.

FERREIRA, F. G. D. C.; GANDOMI, A. H.; CARDOSO, R. T. N. Artificial intelligence applied to stock market trading: a review. **IEEE Access**, [S.L], v. 9, p. 30898-30917, 2021. DOI: <https://doi.org/10.1109/ACCESS.2021.3058133>. Acesso em: 05 out. 2023.

GERLEIN, Eduardo A. *et al.* Evaluating machine learning classification for financial trading: An empirical approach. **Expert Systems with Applications**, [S.L], v. 54, p. 193-207, 2016. DOI: <https://doi.org/10.1016/j.eswa.2016.01.018>. Acesso em: 22 set. 2023.

GOODELL, J. W. *et al.* Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis. **Journal of Behavioral and Experimental Finance**, [S.L], v. 32, p. 100577, 2021. DOI: <https://doi.org/10.1016/j.jbef.2021.100577>. Acesso em: 05 out. 2023.

GROUT, Paul A. AI, ML, and competition dynamics in financial markets. **Oxford Review of Economic Policy**, [S.L], v. 37, n. 3, p. 618-635, 2021. DOI: <https://doi.org/10.1093/oxrep/grab014>. Acesso em: 13 out. 2023.

HENRIQUE, Bruno Miranda; SOBREIRO, Vinicius Amorim; KIMURA, Herbert. Literature review: Machine learning techniques applied to financial market prediction. **Expert Systems with Applications**, [S.L], v. 124, p. 226-251, 2019. DOI: <https://doi.org/10.1016/j.eswa.2019.01.012>. Acesso em: 25 set. 2023.

HERNES, Marcin; SOBIESKA-KARPIŃSKA, Jadwiga. Application of the consensus method in a multiagent financial decision support system. **Information Systems and e-Business Management**, [S.L], v. 14, p. 167-185, 2016. DOI: <https://doi.org/10.1007/s10257-015-0280-9>. Acesso em: 22 set. 2023.

HSU, Ming-Wei *et al.* Bridging the divide in financial market forecasting: machine learners vs. financial economists. **Expert systems with Applications**, [S.L], v. 61, p. 215-234, 2016. DOI: <https://doi.org/10.1016/j.eswa.2016.05.033>. Acesso em: 22 set. 2023.

JANKOVÁ, Zuzana. A Bibliometric Analysis of Artificial Intelligence Technique in Financial Market. **Scientific Papers of the University of Pardubice**, [S.L], v. 29, n. 3, 2021. DOI: <https://doi.org/10.46585/sp29031268>. Acesso em: 26 set. 2023.

JAWID, Raed Fadel. Study of using applications of artificial intelligence in performance of financial markets. **Journal of Cases on Information Technology (JCIT)**, [S.L], v. 24, n. 2, p. 1-18, 2022. DOI: <http://doi.org/10.4018/JCIT.20220401.oa4>. Acesso em: 09 out. 2023.

JIANG, Yali. Application and comparison of multiple machine learning models in finance. **Scientific Programming**, [S.L], v. 2022, 2022. DOI: <https://doi.org/10.1155/2022/9613554>. Acesso em: 09 out. 2023.

KAMRUZZAMAN, M. M.; ALRUWAILI, Omar; ALDAGHMANI, Dhiyaa. Measuring systemic and systematic risk in the financial markets using artificial intelligence. **Expert Systems**, [S.L], 2022. DOI: <https://doi.org/10.1111/exsy.12971>. Acesso em: 27 set. 2023.

KOU, Gang *et al.* Machine learning methods for systemic risk analysis in financial sectors. **Technological and Economic Development of Economy**, [S.L], v. 25, n. 5, p. 716-742, 2019. DOI: <https://doi.org/10.3846/tede.2019.8740>. Acesso em: 25 set. 2023.

KUMBURE, Mahinda Mailagaha *et al.* Machine learning techniques and data for stock market forecasting: A literature review. **Expert Systems with Applications**, [S.L], v. 197, p. 116659, 2022. DOI: <https://doi.org/10.1016/j.eswa.2022.116659>. Acesso em: 28 set. 2023.

LEE, Tae Kyun *et al.* Global stock market investment strategies based on financial network indicators using machine learning techniques. **Expert Systems with Applications**, [S.L], v. 117, p. 228-242, 2019. DOI: <https://doi.org/10.1016/j.eswa.2018.09.005>. Acesso em: 25 set. 2023.

LI, Audeliano Wolian; BASTOS, Guilherme Sousa. Stock market forecasting using deep learning and technical analysis: a systematic review. **IEEE access**, [S.L], v. 8, p. 185232-185242, 2020. DOI: <https://doi.org/10.1109/ACCESS.2020.3030226>. Acesso em: 25 set. 2023.

LI, Yuxin *et al.* Theory and application of artificial intelligence in financial industry. **Data Science in Finance and Economics**, [S.L], v. 1, n. 2, p. 96-116, 2021. DOI: <https://doi.org/10.1109/10.3934/DSFE.2021006>. Acesso em: 13 out. 2023.

LIGHTBOURNE, John. Algorithms & fiduciaries: existing and proposed regulatory approaches to artificially intelligent financial planners. **Duke Law Journal**, [S.L], v. 67, p. 651-679, 2017.

LIN, Chien-Cheng; CHEN, Chun-Sheng; CHEN, An-Pin. Using intelligent computing and data stream mining for behavioral finance associated with market profile and financial physics. **Applied Soft Computing**, [S.L], v. 68, p. 756-764, 2018. DOI: <https://doi.org/10.1016/j.asoc.2017.08.008>. Acesso em: 24 set. 2023.

LIN, Shih-Lin; HUANG, Hua-Wei. Improving deep learning for forecasting accuracy in financial data. **Discrete Dynamics in Nature and Society**, [S.L], v. 2020, p. 1-12, 2020. DOI: <https://doi.org/10.1155/2020/5803407>. Acesso em: 26 set. 2023.

MAHMOUDI, Nader; DOCHERTY, Paul; MOSCATO, Pablo. Deep neural networks understand investors better. **Decision Support Systems**, [S.L], v. 112, p. 23-34, 2018. DOI: <https://doi.org/10.1016/j.dss.2018.06.002>. Acesso em: 11 out. 2023.

MAKNICKIENE, Nijole; LAPINSKAITE, Indre; MAKNICKAS, Algirdas. Application of ensemble of recurrent neural networks for forecasting of stock market sentiments. **Equilibrium: Quarterly Journal of Economics and Economic Policy**, [S.L], v. 13, n. 1, p. 7-27, 2018. DOI: <https://doi.org/10.24136/eq.2018.001>. Acesso em: 24 set. 2023.

MCBRIDE, Russ; DASTAN, Alireza; MEHRABINIA, Poorya. How AI affects the future relationship between corporate governance and financial markets: A note on impact capitalism. **Managerial Finance**, [S.L], v. 48, n. 8, p. 1240-1249, 2022. DOI: <https://doi.org/10.1108/MF-12-2021-0586>. Acesso em: 14 out. 2023.

MHLANGA, David. Industry 4.0 in finance: the impact of artificial intelligence (AI) on digital financial inclusion. **International Journal of Financial Studies**, [S.L], v. 8, n. 3, p. 45, 2020. DOI: <https://doi.org/10.3390/ijfs8030045>. Acesso em: 10 out. 2023.

MILANA, Carlo; ASHTA, Arvind. Artificial intelligence techniques in finance and financial markets: a survey of the literature. **Strategic Change**, [S.L], v. 30, n. 3, p. 189-209, 2021. DOI: <https://doi.org/10.1002/jsc.2403>. Acesso em: 07 out. 2023.

MONKIEWICZ, Jan; MONKIEWICZ, Marek. Financial sector supervision in digital age: transformation in progress. **Foundations of Management**, [S.L], v. 14, n. 1, p. 25-36, 2022. DOI: <https://doi.org/10.2478/fman-2022-0002>. Acesso em: 29 set. 2023.

PAYNE, Elizabeth H. M.; DAHL, Andrew J.; PELTIER, James. Digital servitization value co-creation framework for AI services: a research agenda for digital transformation in financial service ecosystems. **Journal of Research in Interactive Marketing**, [S.L], v. 15, n. 2, p. 200-222, 2021. DOI: <https://doi.org/10.1108/JRIM-12-2020-0252>. Acesso em: 26 set. 2023.

REN, Jiaping. Research on financial investment decision based on artificial intelligence algorithm. **IEEE Sensors Journal**, [S.L], v. 21, n. 22, p. 25190-25197, 2021. DOI: <https://doi.org/10.1109/JSEN.2021.3104038>. Acesso em: 27 set. 2023.

ROSATI, Riccardo *et al.* Machine learning in capital markets: decision support system for outcome analysis. **IEEE Access**, [S.L], v. 8, p. 109080-109091, 2020. DOI: <http://dx.doi.org/10.1109/ACCESS.2020.3001455>. Acesso em: 25 set. 2023.

TANG, Yajiao *et al.* A survey on machine learning models for financial time series forecasting. **Neurocomputing**, [S.L], v. 512, p. 363-380, 2022. DOI: <https://doi.org/10.1016/j.neucom.2022.09.003>. Acesso em: 30 set. 2023.

WANG, Bai. A financial risk identification model based on artificial intelligence. **Wireless Networks**, [S.L], v. 28, n. 9, p. 112-121, 2022. DOI: <https://doi.org/10.1007/s11276-021-02856-z>. Acesso em: 27 set. 2023.

WEI, Xiaohui; CHEN, Wanling; LI, Xiao. Exploring the financial indicators to improve the pattern recognition of economic data based on machine learning. **Neural Computing and Applications**, [S.L], v. 33, p. 723-737, 2021. DOI: <https://doi.org/10.1007/s00521-020-05094-0>. Acesso em: 26 set. 2023.

WENG, Bin; AHMED, Mohamed A.; MEGAHED, Fadel M. Stock market one-day ahead movement prediction using disparate data sources. **Expert Systems with Applications**, [S.L], v. 79, p. 153-163, 2017. DOI: <https://doi.org/10.1016/j.eswa.2017.02.041>. Acesso em: 11 out. 2023.

XIE, Minzhen. Development of artificial intelligence and effects on financial system. **Journal of Physics: Conference Series**, [S.L], v. 1187, n. 3, 2019. DOI: <https://doi.org/10.1088/1742-6596/1187/3/032084>. Acesso em: 12 out. 2023.

YANG, G.; CHEN, Y.; HUANG, J. P. The highly intelligent virtual agents for modeling financial markets. **Physica A: Statistical Mechanics and its Applications**, [S.L], v. 443, p. 98-108, 2016. DOI: <https://doi.org/10.1016/j.physa.2015.09.071>. Acesso em: 22 set. 2023.

ZHAI, Jia *et al.* Computational intelligent hybrid model for detecting disruptive trading activity. **Decision Support Systems**, [S.L], v. 93, p. 26-41, 2017. DOI: <https://doi.org/10.1016/j.dss.2016.09.003>. Acesso em: 22 set. 2023.

ZHENG, Xiao-lin *et al.* FinBrain: when finance meets AI 2.0. **Frontiers of Information Technology & Electronic Engineering**, [S.L], v. 20, n. 7, p. 914-924, 2019. DOI: <https://doi.org/10.1631/FITEE.1700822>. Acesso em: 12 out. 2023.

ZHOU, Jun *et al.* FinBrain 2.0: when finance meets trustworthy AI. **Frontiers of Information Technology & Electronic Engineering**, [S.L], v. 23, n. 12, p. 1747-1764, 2022. DOI: <https://doi.org/10.1631/FITEE.2200039>. Acesso em: 14 out. 2023.