

Seleção de ativos e otimização de portfólios de investimentos com métodos de inteligência artificial: uma revisão sistemática e bibliométrica da literatura

NATAN FELIPE SILVA

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MINAS GERAIS (IFMG)

BRUNO CÉSAR DE MELO MOREIRA

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MINAS GERAIS (IFMG)

LÉLIS PEDRO DE ANDRADE

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MINAS GERAIS (IFMG)

WASHINGTON SANTOS SILVA

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MINAS GERAIS (IFMG)

MAÍSA KELY DE MELO

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MINAS GERAIS (IFMG)

SELEÇÃO DE ATIVOS E OTIMIZAÇÃO DE PORTFÓLIOS DE INVESTIMENTOS COM MÉTODOS DE INTELIGÊNCIA ARTIFICIAL: UMA REVISÃO SISTEMÁTICA E BIBLIOMÉTRICA DA LITERATURA

Introdução

Na década de 50, Markowitz (1952) propôs a teoria moderna de portfólio que, por meio da diversificação de ativos e da análise de risco, retorno e correlação, buscou minimizar o risco do portfólio a partir de um determinado retorno desejado. No entanto, a partir do modelo tradicional de Markowitz, foram desenvolvidas outras abordagens de seleção de portfólios que levam em conta métodos da inteligência artificial.

Problema de Pesquisa e objetivo

Devido a aplicação de diferentes métodos advindos da inteligência artificial na área de seleção e otimização de portfólio de investimento, esta pesquisa emerge com o seguinte objetivo: realizar uma análise sistemática da literatura relacionada aos métodos de inteligência artificial aplicados na seleção de ativos e na otimização de portfólio de investimentos. A pesquisa considerou o período de 1989 a 2022 e a busca principal retornou um total de 402 artigos na *Web of Science* e 455 artigos na base *Scopus*, tendo contemplado todo o período de busca disponível em ambas as bases.

Fundamentação teórica

Os modelos provenientes da inteligência artificial como *Machine Learning* (aprendizado de máquina) e *Deep Learning* (aprendizado profundo), têm recebido destaque na área de seleção de ativos e otimização de portfólios de investimento para aumentar a eficiência do desempenho do portfólio (CHEN, 2021; MA; HAN; WANG, 2021), o que tem contribuído com a literatura a partir de Markowitz (1952). Dentre os estudos que fazem uso desses métodos advindos da inteligência artificial, cita-se o algoritmo *random forest* (floresta aleatória), que foi utilizado na otimização de portfólio e pré-seleções de ações (BALLINGS et al., 2015), bem como a regressão de vetor suporte (MATÍAS; REBOREDO, 2012).

Discussão

Inicialmente, foi realizado o levantamento do número de publicações ao longo dos anos, o que indica um crescimento considerado expressivo da área, especialmente a partir de 2009. Também foi feito o levantamento dos periódicos mais relevantes na área, considerando os índices H, G e M, além do número de citações e publicações. Por fim, foi feita uma análise de palavras-chaves e tendências da área, a partir da qual, especificamente, notou-se uma crescente aplicação de métodos utilizando de *deep learning* e *deep reinforcement learning*.

Conclusões

O estudo traz as seguintes conclusões: i) o campo de estudo está em pleno crescimento nos últimos anos; ii) o número de pesquisas utilizando métodos advindos da inteligência artificial como *machine learning* e *deep learning* tem aumentado consideravelmente, tanto para seleção de ativos quanto

para otimização de portfólios; iii) O modelo média –variância de Markowitz (1952) ainda é muito utilizado, porém, há um grande número de pesquisas que combina o modelo tradicional com outros métodos advindos da inteligência artificial, seja para pré-seleção de ativos ou para a otimização dos portfólios.

Contribuições/Impacto

Este estudo buscou contribuir para a área de seleção e otimização de portfólio de investimentos por meio de uma revisão bibliométrica nas bases *Web of Science* e *Scopus*. Foi possível demonstrar o crescimento da aplicação dos métodos provenientes da inteligência artificial nesse campo temático, com destaque aos modelos de *machine learning* e *deep learning*. As contribuições deste estudo destacam a importância de explorar as capacidades da inteligência artificial para melhorar os processos de seleção de ativos e otimização de portfólios de investimento em relação a métodos tradicionais.

Referencias bibliográficas

MA, Y.; HAN, R.; WANG, W. Portfolio optimization with return prediction using deep learning and machine learning. **Expert Systems with Applications**, v. 165, 2021. MARKOWITZ, H. Portfolio selection. **The Journal of Finance**, v. 7, n. 1, p. 77–91, 1952. MATÍAS, J. M.; REBOREDO, J. C. Forecasting performance of nonlinear models for intraday stock returns. **Journal of Forecasting**, v. 31, n. 2, p. 172–188, 2012. CHEN, W. et al. Mean–variance portfolio optimization using machine learning-based stock price prediction. **Applied Soft Computing**, v. 100, p. 106943, mar. 2021.

Palavras-chave: revisão bibliométrica e sistemática, seleção e otimização de portfólio, inteligência artificial.

1 INTRODUÇÃO

Na década de 50, Markowitz (1952) propôs a teoria moderna de portfólio que, por meio da diversificação de ativos e da análise de risco, retorno e correlação, buscou minimizar o risco do portfólio a partir de um determinado retorno desejado. O método proposto por Markowitz (1952) ficou conhecido como modelo de média-variância. Desde então, diversos estudos têm aplicado o modelo de média-variância na composição de carteiras de investimentos (KALAYCI; ERTENLICE; AKBAY, 2019). No entanto, estudos (Golmakani & Fazel, 2011; Mehlawat, 2016) têm utilizado novos métodos na busca de otimizar o portfólio, sendo que alguns (UTZ et al., 2014) combinam o modelo de média-variância (MARKOWITZ, 1952) com outros métodos quantitativos, oriundos da estatística (LEE, 2019; LI; YI, 2019), pesquisa operacional como modelo de análise multicritérios (SILVA et al., 2023) , séries temporais e computação científica (SIKARIA; SEN; UPADHYE, 2021) , cujo intuito é o de obter desempenhos considerados melhores na relação risco e retorno.

Outros métodos que ganharam espaço ao longo dos últimos anos são os modelos provenientes da inteligência artificial: *Machine Learning* (aprendizado de máquina) e *Deep Learning* (aprendizado profundo), que podem ser combinados com o modelo média –variância para melhorar o desempenho do portfólio (CHEN, 2021; MA; HAN; WANG, 2021). Dentre os estudos que fazem uso desses métodos advindos da inteligência artificial, pode-se citar o algoritmo *random forest* (floresta aleatória), que foi utilizado na otimização de portfólio e pré-seleções de ações (BALLINGS et al., 2015), bem como a regressão de vetor suporte, que foi aplicada ao mercado de ações (MATÍAS; REBOREDO, 2012). Os algoritmos de aprendizado de conjunto incluem principalmente *Adaptive Boosting* (AdaBoost) (ZHANG; LI; PAN, 2016), *Gradient Boosted Decision Tree* (GBDT) (ZHOU et al., 2019) e *eXtreme Gradient Boosting* (XGBoost) (NOBRE; NEVES, 2019).

Diante desse contexto, este trabalho visa responder a seguinte pergunta de pesquisa: Quais são os principais métodos de inteligência artificial aplicados na área de seleção e otimização de portfólio de investimentos? Assim, o objetivo do presente capítulo é realizar uma análise sistemática da literatura na área de seleção e otimização de portfólio de investimentos utilizando métodos de inteligência artificial. Também, espera-se identificar os principais estudos sobre o tema bem como as lacunas e tendências de pesquisas na literatura relacionada

2.2.1 Metodologia

A pesquisa caracteriza-se como uma análise bibliométrica, que foi realizada utilizando os artigos extraídos da base *Scopus* e *Web of Science*, sendo também classificada como descritiva e dotada de abordagem quantitativa (COSTA et al., 2017). Para realizar a análise bibliométrica, foram seguidas as etapas listadas na Figura 1.

Figura 1- Etapas da montagem da pesquisa e análise bibliométrica.



Fonte: Elaborado pelos autores - adaptado a partir de (COSTA et al., 2017).

Observam-se na Figura 1 as etapas que foram seguidas no decorrer da pesquisa. A primeira etapa de delimitar o objetivo e o campo da pesquisa ocorreu na introdução do trabalho. As bases de dados que serão utilizadas para realizar o estudo serão a base *Scopus* e *Web of Science*. A metodologia aplicada nas etapas subsequentes será descrita nos próximos tópicos.

2.2.1.1 Procedimentos Metodológicos

Para a definição e identificação dos termos de busca e palavras-chaves, considerando a temática das técnicas de inteligência artificial ligadas à otimização de portfólio de investimentos, foram utilizadas expressões booleanas com o intuito de trazer à tona o maior número de trabalhos que contemplam a temática. A chave de pesquisa utilizada foi:

(PORTFOLIO AND (OPTIMIZATION OR SELECTION) AND ("ARTIFICIAL INTELLIGENCE " OR " MACHINE LEARNING" OR "DEEP LEARNING") AND (INVESTMENT OR FINANCE))

2.2.1.2 Coleta e estruturação de dados

Na terceira etapa da Figura 1, coleta e estruturação de dados, para análise bibliométrica foi utilizado o pacote *Bibliometrix* do *software R*, programa utilizado na literatura conforme estudos (KHAN, 2022; PALTRINIERI et al., 2019; PATTNAIK et al., 2020) pela praticidade de quantificar e processar os dados. Para realizar as análises utilizando o *Bibliometrix*, seguiu-se o estudo de (ARIA; CUCCURULLO, 2017), que apresenta uma série de possibilidades de análises bibliométricas com o pacote e suas respectivas funções.

2.2.1.3 Análise contextual da produção científica relacionada a amostra

A quarta etapa da Figura 1 consiste em realizar uma análise contextual da produção científica selecionada pela amostra cujo objetivo é conhecer as publicações selecionadas pela busca. Para tanto, primeiramente foi realizada uma análise do número de publicações ao longo dos anos. Além disso, também foram analisadas as citações dos artigos selecionados, a fim de identificar as publicações mais relevantes da amostra. Também foi realizada uma análise sobre os periódicos mais relevantes do tema e os países que têm produzido as pesquisas mais impactantes ao longo do tema.

2.2.1.4 Análise das redes das citações realizadas pela amostra

A quinta etapa da análise bibliométrica, na Figura 1, consiste em analisar e discutir as redes de citações realizadas pela amostra. Essa etapa tem por objetivo identificar os *clusters* de pesquisas e as relações de citações.


3 Resultados e discussões

3.1 Análise contextual da amostra e da produção científica

A pesquisa foi realizada em outubro de 2022 e a busca principal retornou um total de 402 artigos na *Web of Science* e 455 artigos na base *Scopus*, que foram publicados no período de 1989 a 2022. A pesquisa contemplou todo o período de busca disponível em ambas as bases. As duas bases de dados tiveram os dados consolidadas em um único arquivo, sendo removidos os artigos duplicados, restando assim um total de 702 artigos, ou seja, um grupo de 155 artigos estavam presente nas duas bases.

Com o objetivo de conhecer o recorte temporal das publicações recolhidas, elaborou-se um gráfico a partir de um critério de busca previamente estabelecido, que pode ser observado na Figura 2, mostrando o número de artigos publicados ao longo do tempo.

Figura 2: Análise das publicações ordenadas por quantidade anual de publicações



Fonte: Elaborada pelos autores com os dados da pesquisa.

Observa-se na Figura 2 um crescimento no número de publicações principalmente a partir de 2009. O primeiro artigo da amostra foi publicado em 1989, intitulado “Intelligent Stock Portfolio Management System”, publicado na revista “Expert Systems”, tendo 14 citações na base *Scopus*. O estudo de Lee; Kim; Chu, (1989) propõe um modelo de seleção e otimização de carteira utilizando algoritmos inteligentes.

Dentre os artigos selecionados com base nos critérios de busca previamente estabelecidos, alguns se destacaram de acordo com o número de citações. Portanto, a Tabela 1 apresenta os estudos com mais citações conforme a busca realizada tanto na base *scopus* como *web of science*.

Tabela 1- Cinco artigos mais citados

Título	Autor	Citações <i>Web of Science</i>	Citações Scopus
Computational Intelligence and Financial Markets: A Survey and Future Directions	(CAVALCANTE et al., 2016)	289	355
Portfolio selection using neural networks	(FERNÁNDEZ; GÓMEZ, 2007)	186	229

A first application of independent component analysis to extracting structure from stock returns	(BACK; WEIGEND, 1997)	170	206
Particle Swarm Optimization (PSO) for the constrained portfolio optimization problem	(ZHU et al., 2011)	146	199
A hybrid stock selection model using genetic algorithms and support vector regression	(HUANG, 2012)	133	175

Fonte: Elaborada pelos autores com os dados da pesquisa.

Com 289 citações na *Web of Science* e 355 citações na base scopus, Cavalcante et al., (2016) apresentam uma revisão sistemática dos métodos de inteligência computacional aplicados à área de finanças, tanto na previsão de retornos de preços de ações como na seleção e otimização de portfólios de investimentos. O segundo artigo apresentado na Tabela 1, com 186 citações *Web of Science* e 229 citações na base scopus, desenvolveu um modelo heurístico que faz uso de redes neurais artificiais para selecionar e otimizar portfólios de investimentos (FERNÁNDEZ; GÓMEZ, 2007). Com 170 citações na *Web of Science* e 206 citações na base scopus, o estudo de Back; Weigend (1997) é o terceiro estudo com maior número de citações, sendo que a pesquisa dos autores utiliza uma técnica de processamento de linguagem de sinais conhecida como análise de componentes independentes, sendo aplicada em séries financeiras multivariadas como a carteira de investimento. O artigo de Zhu et al. (2011), que tem 146 citações na *Web of Science* e 199 citações na base scopus, apresenta a aplicação do modelo de otimização de enxame por partículas para otimizar um portfólio de investimentos e compara os resultados com outros métodos. O estudo de Huang (2012), com 133 citações na *Web of Science* e 175 citações na base scopus, utilizou um modelo híbrido que combina dois métodos de inteligência artificial para seleção de ativos: regressão vetor suporte e algoritmo genético.

A pesquisa também analisou os periódicos com maior relevância no tema, sendo considerados o índice H que representa a produtiva e a influência do periódico, o índice g que leva em consideração a distribuição das citações e o índice m que representa a mediana em ordem decrescente das citações recebidas no periódico. Além dessas métricas também foram considerados o TC (total de citações e NP (número de publicações)). A Tabela 2 apresenta os periódicos com maior impacto, levando em consideração esses parâmetros.

Tabela 2- Dez periódicos mais ranqueados conforme o número de citações

Periódicos	Índice h	Índice g	Índice m	TC	NP
EXPERT SYSTEMS WITH APPLICATIONS	19	40	1,12	1669	42
EUROPEAN JOURNAL OF OPERATIONAL RESEARCH	7	11	0,27	657	11
QUANTITATIVE FINANCE	6	11	0,75	148	11
KNOWLEDGE-BASED SYSTEMS	6	10	0,67	660	10
ADVANCES IN INTELLIGENT SYSTEMS AND COMPUTING	2	5	0,25	29	7
COMMUNICATIONS IN COMPUTER AND INFORMATION SCIENCE	1	2	0,08	6	7
INFORMATION SCIENCES	6	7	0,38	254	7
JOURNAL OF FINANCIAL DATA SCIENCE	4	5	1,00	25	7
APPLIED SOFT COMPUTING JOURNAL	5	6	0,45	243	6
INTERNATIONAL JOURNAL OF MACHINE LEARNING AND CYBERNETICS	3	4	0,30	18	6

Fonte: Elaborada pelos autores com os dados da pesquisa.

Observou-se na Tabela 2 que o periódico com maior relevância, com base nos artigos levantados por meio da revisão bibliométrica, foi o "*Expert Systems with Applications*". Este periódico destaca-se por seu foco na aplicação de novos métodos em diversas áreas do conhecimento, incluindo a área de finanças. Dentre os estudos que foram publicados neste periódico foram encontrados um total de 21 pesquisas por meio desta revisão bibliométrica (AMIN; HAJJAMI, 2021; BALLINGS et al., 2015; CAVALCANTE et al., 2016; CHEN; ZHONG; CHEN, 2020; CORBERÁN-VALLET et al., 2023; DE MELO; CARDOSO; JESUS, 2022; DENG; LIN; LO, 2012; DU, 2022; GOLMAKANI; FAZEL, 2011; JALOTA et al., 2023; KALAYCI; ERTENLICE; AKBAY, 2019; LEE; KIM; CHU, 1989; MA; HAN; WANG, 2021; NOBRE; NEVES, 2019; ORIMOLOYE et al., 2020; PAIVA et al., 2019; RASHIDPOOR TOOCHAEI; MOEINI, 2023; WANG et al., 2020; ZHOU et al., 2023; ZHU et al., 2011).

3.2 Análise das palavras-chaves e tendências de pesquisas

A Figura 3 apresenta neste tópico as *Keywords* (palavras-chaves) que apareceram com mais frequências na amostra do presente estudo, a partir da base *Scopus* e *Web of Science*. Em destaque, podemos notar os termos “investimentos”, “mercado de finanças”, “*machine learning*” e “*neural networks*”, dentre outras obtidas, conforme apresentado na Figura 9.

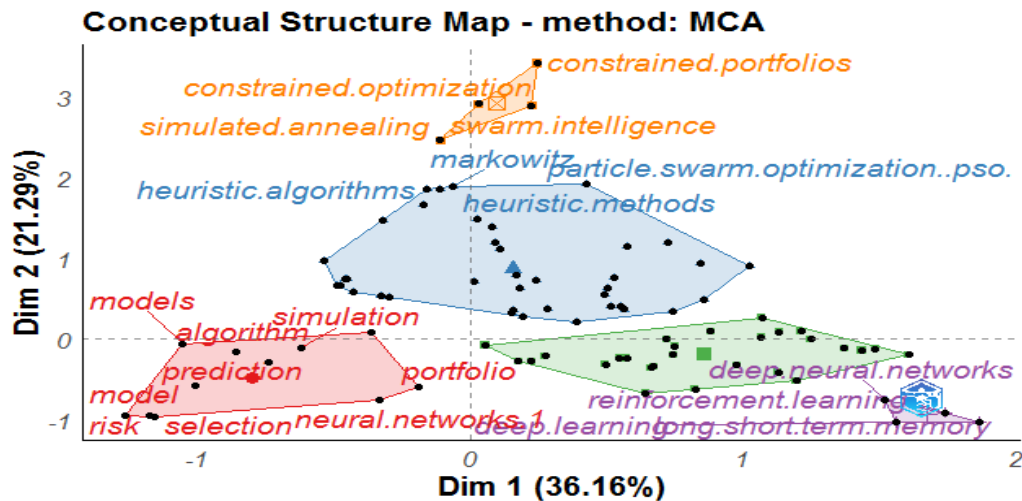
Figura 3: Nuvem de palavras-chaves



Fonte: Elaborado pelos autores com os dados da pesquisa.

Na Figura 3, observa-se a ocorrência principal de palavras-chaves como “*machine learning*” e “*investment*”. Um ponto a se destacar é que esses termos estão ligados à chave de busca que foi determinada na seção de procedimentos metodológicos. Outras palavras-chaves que apareceram com frequência e merecem destaque são: “*neural networks*” ou rede neural, que está ligada a uma subárea da inteligência artificial. Outra palavra que merece destaque é “*Computer simulation*”, que diz respeito à simulação computacional na área de otimização.

Figura 4: Nuvem de palavras-chaves



Fonte: Elaborado pelos autores com os dados da pesquisa.

A Figura 4 apresenta um dendrograma que utiliza técnicas de agrupamento para tentar identificar grupos de artigos que expressam objetivos em comum. Nesse caso, pode-se relatar quatro grupos. O grupo em vermelho trata de estudos sobre seleção de ativos por meio de técnicas de previsão de retorno usando *machine learning* e redes neurais, a exemplo dos estudos (MA; HAN; WANG, 2021; PRASAD; BAKHSHI, 2022). O grupo em azul ressalta estudos que utilizaram na otimização métodos heurísticos e algoritmos bio-inspirados como exame de partículas e algoritmo genético, a exemplo do estudo de (GOLMAKANI; FAZEL, 2011b) e o estudo de (FRAUSTO SOLIS et al., 2022), que utilizam algoritmo genético tanto para seleção de investimentos como para otimização do modelo. Outra dimensão em laranja trata de diferentes métodos de otimização que buscam encontrar as melhores soluções ótimas, a exemplo dos estudos que utilizam o algoritmo *simulated annealing* (KIRKPATRICK; GELATT; VECCHI, 1983; LUO; ZHU; TANG, 2014; WANG; HE; JI, 2016), e portfólio que fazem uso de restrições de cardinalidades (DENG et al., 2022; SHAHID et al., 2022).

Por fim, a última dimensão trata de modelos que utilizam *deep learning* e *deep reinforcing learning*, dentre os quais se pode destacar estudos que utilizaram redes neurais para fazer a pré-seleção de ativos para uma posterior otimização (MICHÁŃKÓW; SAKOWSKI; ŚLEPACZUK, 2022; PADHI et al., 2022). Uma outra tendência relatada nos estudos que utilizaram métodos de inteligência artificial, seja de *machine learning* ou *deep learning*, é que quando a pré-seleção de ações é realizada por tais métodos antes da otimização, o portfólio apresenta um desempenho largamente superior se comparado com outros portfólios (CHEN et al., 2021; MA; HAN; WANG, 2021).

4. Considerações Finais

O objetivo deste trabalho foi realizar uma análise bibliométrica na área de seleção e otimização de portfólio de investimentos com ênfase nos modelos de inteligência artificial, com a finalidade de identificar os principais estudos sobre o tema, bem como as lacunas e tendências de pesquisas. Para isso, foram coletados dados da base *Scopus* e *Web of Science*, contemplando todo o período de dados disponível, sendo os dados tratados pelo pacote Bibliometrix da linguagem de programação R.

Inicialmente, foi realizado o levantamento do número de publicações ao longo dos anos, o que indica um crescimento considerado expressivo da área. Também foi feito o levantamento dos periódicos mais relevantes na área, considerando os índices H, G e M, além do número de citações e publicações. Por fim, foi feita uma análise de palavras-chaves e tendências da área, a partir da qual, especificamente, notou-se uma crescente aplicação de métodos utilizando de *deep learning* e *deep reinforcement learning*. Podemos observar a vasta possibilidade de se utilizar diferentes métodos, tanto para realizar a pré-seleção de ativos quanto para otimizar portfólios de investimentos, principalmente devido à aplicação de modelos advindos da inteligência artificial. Estes podem tanto ser utilizados individualmente quanto combinados com o tradicional modelo média-variância proposto por Markowitz (1952).

A revisão bibliométrica realizada neste estudo traz as seguintes conclusões: i) o campo de estudo está em pleno crescimento nos últimos anos, conforme visto na Figura 2; ii) o número de pesquisas utilizando métodos advindos da inteligência artificial como *machine learning* e *deep learning* tem aumentado consideravelmente, conforme visto na Figura 4; iii) O modelo média – variância de Markowitz (1952) ainda é muito utilizado, porém, há um grande número de pesquisas que combina o modelo tradicional com outros métodos (BALLINGS et al., 2015; CHEN et al., 2021; MA; HAN; WANG, 2021; MATÍAS; REBOREDO, 2012); iv) alguns estudos constataram que a aplicação de métodos de inteligência artificial para realizar a seleção de ações antes de realizar a otimização do portfólio aumentou significativamente o desempenho do portfólio (MA; HAN; WANG, 2021; TA; LIU; TADESSE, 2020; ZHOU et al., 2019).

Como contribuições com o avanço da literatura este estudo buscou contribuir para a área de seleção e otimização de portfólio de investimento por meio de uma revisão bibliométrica nas bases *Web of Science* e *Scopus*. Por meio desta revisão, foi possível demonstrar o crescimento constante dos métodos provenientes da inteligência artificial para a aplicação nesse campo específico. A análise bibliométrica revelou uma tendência crescente no uso de técnicas de inteligência artificial, tais como modelos de *machine learning* e *deep learning*, no contexto da seleção e otimização de

portfólio de investimento. Esta tendência surge a partir dos pressupostos que estes métodos podem oferecer resultados mais eficientes para investidores em relação ao modelo tradicional (CHEN et al., 2021; MA; HAN; WANG, 2021).

Para futuras pesquisas, sugere-se: i) realizar um estudo das técnicas de inteligência artificial focadas na pré-seleção de ativos; ii) realizar uma análise dos métodos aplicados à temática e relacionar com os resultados encontrados nas pesquisas; e iii) realizar trabalhos separados pelas áreas da inteligência artificial, por exemplo, “*machine learning* e seleção e otimização de portfólios”.

REFERÊNCIAS

AMIN, G. R.; HAJJAMI, M. Improving DEA cross-efficiency optimization in portfolio selection. **Expert Systems with Applications**, v. 168, 2021.

ARIA, M.; CUCCURULLO, C. bibliometrix : An R-tool for comprehensive science mapping analysis. **Journal of Informetrics**, v. 11, n. 4, p. 959–975, nov. 2017.

BACK, A. D.; WEIGEND, A. S. A First Application of Independent Component Analysis to Extracting Structure from Stock Returns. **International Journal of Neural Systems**, v. 08, n. 04, p. 473–484, 21 ago. 1997.

BALLINGS, M. et al. Evaluating multiple classifiers for stock price direction prediction. **Expert Systems with Applications**, v. 42, n. 20, p. 7046–7056, 2015.

BARROSO, B. C.; CARDOSO, R. T. N.; MELO, M. K. Performance analysis of the integration between Portfolio Optimization and Technical Analysis strategies in the Brazilian stock market. **Expert Systems with Applications**, v. 186, 2021.

CAVALCANTE, R. C. et al. Computational Intelligence and Financial Markets: A Survey and Future Directions. **Expert Systems with Applications**, v. 55, p. 194–211, ago. 2016.

CHEN, B.; ZHONG, J.; CHEN, Y. A hybrid approach for portfolio selection with higher-order moments: Empirical evidence from Shanghai Stock Exchange. **Expert Systems with Applications**, v. 145, p. 113104, maio 2020.

CHEN, W. et al. Mean–variance portfolio optimization using machine learning-based stock price prediction. **Applied Soft Computing**, v. 100, p. 106943, mar. 2021.

CHEN, Y. BP Neural Network Based on Simulated Annealing Algorithm Optimization for Financial Crisis Dynamic Early Warning Model. **Computational Intelligence and Neuroscience**, v. 2021, 2021.

CORBERÁN-VALLET, A. et al. A new approach to portfolio selection based on forecasting. **Expert Systems with Applications**, v. 215, 2023.

- COSTA, D. F. et al. Bibliometric analysis on the association between behavioral finance and decision making with cognitive biases such as overconfidence, anchoring effect and confirmation bias. **Scientometrics**, v. 111, n. 3, p. 1775–1799, 2017.
- DE MELO, M. K.; CARDOSO, R. T. N.; JESUS, T. A. Multiobjective Model Predictive Control for portfolio optimization with cardinality constraint. **Expert Systems with Applications**, v. 205, 2022.
- DENG, G.-F.; LIN, W.-T.; LO, C.-C. Markowitz-based portfolio selection with cardinality constraints using improved particle swarm optimization. **Expert Systems with Applications**, v. 39, n. 4, p. 4558–4566, mar. 2012.
- DENG, X. et al. Non-dominated sorting genetic algorithm-II for possibilistic mean-semiabsolute deviation-Yager entropy portfolio model with complex real-world constraints. **Mathematics and Computers in Simulation**, v. 202, p. 59–78, dez. 2022.
- DU, J. Mean–variance portfolio optimization with deep learning based-forecasts for cointegrated stocks. **Expert Systems with Applications**, v. 201, p. 117005, set. 2022.
- FERNÁNDEZ, A.; GÓMEZ, S. Portfolio selection using neural networks. **Computers & Operations Research**, v. 34, n. 4, p. 1177–1191, abr. 2007.
- FRAUSTO SOLIS, J. et al. SAIPO-TAIPO and Genetic Algorithms for Investment Portfolios. **Axioms**, v. 11, n. 2, 2022.
- GOLMAKANI, H. R.; FAZEL, M. Constrained portfolio selection using particle swarm optimization. **Expert Systems with Applications**, v. 38, n. 7, p. 8327–8335, 2011a.
- GOLMAKANI, H. R.; FAZEL, M. Constrained Portfolio Selection using Particle Swarm Optimization. **Expert Systems with Applications**, v. 38, n. 7, p. 8327–8335, jul. 2011b.
- HUANG, C.-F. A hybrid stock selection model using genetic algorithms and support vector regression. **Applied Soft Computing**, v. 12, n. 2, p. 807–818, fev. 2012.
- JALOTA, H. et al. A novel approach to incorporate investor’s preference in fuzzy multi-objective portfolio selection problem using credibility measure. **Expert Systems with Applications**, v. 212, 2023a.
- JALOTA, H. et al. A novel approach to incorporate investor’s preference in fuzzy multi-objective portfolio selection problem using credibility measure. **Expert Systems with Applications**, v. 212, 2023b.
- KALAYCI, C. B.; ERTENLICE, O.; AKBAY, M. A. A comprehensive review of deterministic models and applications for mean-variance portfolio optimization. **Expert Systems with Applications**, v. 125, p. 345–368, 2019.
- KHAN, M. A. ESG disclosure and Firm performance: A bibliometric and meta analysis. **Research in International Business and Finance**, v. 61, p. 101668, out. 2022.

KIRKPATRICK, S.; GELATT, C. D.; VECCHI, M. P. Optimization by Simulated Annealing. **Science**, v. 220, n. 4598, p. 671–680, 13 maio 1983.

LEE, C. Financing method for real estate and infrastructure development using Markowitz's portfolio selection model and the Monte Carlo simulation. **Engineering, Construction and Architectural Management**, v. 26, n. 9, p. 2008–2022, 2019.

LEE, J. K.; KIM, H. S.; CHU, S. C. Intelligent Stock Portfolio Management System. **Expert Systems**, v. 6, n. 2, p. 74–87, abr. 1989.

LI, H.-Q.; YI, Z.-H. Portfolio selection with coherent Investor's expectations under uncertainty. **Expert Systems with Applications**, v. 133, p. 49–58, 2019.

LUO, Y.; ZHU, B.; TANG, Y. Simulated annealing algorithm for optimal capital growth. **Physica A: Statistical Mechanics and its Applications**, v. 408, p. 10–18, 2014.

MA, Y.; HAN, R.; WANG, W. Portfolio optimization with return prediction using deep learning and machine learning. **Expert Systems with Applications**, v. 165, 2021.

MARKOWITZ, H. Portfolio selection. **The Journal of Finance**, v. 7, n. 1, p. 77–91, 1952.

MATÍAS, J. M.; REBOREDO, J. C. Forecasting performance of nonlinear models for intraday stock returns. **Journal of Forecasting**, v. 31, n. 2, p. 172–188, 2012.

MEHLAWAT, M. K. Credibilistic mean-entropy models for multi-period portfolio selection with multi-choice aspiration levels. **Information Sciences**, v. 345, p. 9–26, 2016.

MICHAŃKÓW, J.; SAKOWSKI, P.; ŚLEPACZUK, R. LSTM in Algorithmic Investment Strategies on BTC and S&P500 Index. **Sensors**, v. 22, n. 3, 2022.

NOBRE, J.; NEVES, R. F. Combining Principal Component Analysis, Discrete Wavelet Transform and XGBoost to trade in the financial markets. **Expert Systems with Applications**, v. 125, p. 181–194, jul. 2019.

ORIMOLOYE, L. O. et al. Comparing the effectiveness of deep feedforward neural networks and shallow architectures for predicting stock price indices. **Expert Systems with Applications**, v. 139, p. 112828, jan. 2020.

PADHI, D. K. et al. An Intelligent Fusion Model with Portfolio Selection and Machine Learning for Stock Market Prediction. **Computational Intelligence and Neuroscience**, v. 2022, 2022.

PAIVA, F. D. et al. Decision-making for financial trading: A fusion approach of machine learning and portfolio selection. **Expert Systems with Applications**, v. 115, p. 635–655, 2019.

PALTRINIERI, A. et al. A bibliometric review of sukuk literature. **International Review of Economics & Finance**, abr. 2019.

PATTNAIK, D. et al. Trade credit research before and after the global financial crisis of 2008 – A bibliometric overview. **Research in International Business and Finance**, v. 54, p. 101287, dez. 2020.

PRASAD, A.; BAKHSHI, P. Forecasting the Direction of Daily Changes in the India VIX Index Using Machine Learning. **Journal of Risk and Financial Management**, v. 15, n. 12, 2022.

RASHIDPOOR TOOCHAEI, M.; MOEINI, F. Evaluating the performance of ensemble classifiers in stock returns prediction using effective features. **Expert Systems with Applications**, v. 213, 2023.

SHAHID, M. et al. Solving constrained portfolio optimization model using stochastic fractal search approach. **International Journal of Intelligent Computing and Cybernetics**, 2022.

SIKARIA, S.; SEN, R.; UPADHYE, N. S. Bayesian Filtering for Multi-period Mean–Variance Portfolio Selection. **Journal of Statistical Theory and Practice**, v. 15, n. 2, 2021.

SILVA, N. F. et al. An integrated CRITIC and Grey Relational Analysis approach for investment portfolio selection. **Decision Analytics Journal**, p. 100285, jul. 2023.

TA, V.-D.; LIU, C.-M.; TADESSE, D. A. Portfolio optimization-based stock prediction using long-short term memory network in quantitative trading. **Applied Sciences (Switzerland)**, v. 10, n. 2, 2020.

UTZ, S. et al. Tri-criterion inverse portfolio optimization with application to socially responsible mutual funds. **European Journal of Operational Research**, v. 234, n. 2, p. 491–498, 2014.

WANG, W. et al. Portfolio formation with preselection using deep learning from long-term financial data. **Expert Systems with Applications**, v. 143, p. 113042, abr. 2020.

WANG, X.; HE, L.; JI, H. **Modified generalized simulated annealing algorithm used in data driven portfolio management**. Proceedings of 2016 IEEE Information Technology, Networking, Electronic and Automation Control Conference, ITNEC 2016. **Anais...2016**.

ZHANG, X.; LI, A.; PAN, R. Stock trend prediction based on a new status box method and AdaBoost probabilistic support vector machine. **Applied Soft Computing**, v. 49, p. 385–398, dez. 2016.

ZHOU, F. et al. Cascading logistic regression onto gradient boosted decision trees for forecasting and trading stock indices. **Applied Soft Computing**, v. 84, p. 105747, nov. 2019.

ZHOU, Z. et al. Multi-source data driven cryptocurrency price movement prediction and portfolio optimization. **Expert Systems with Applications**, v. 219, 2023.

ZHU, H. et al. Particle Swarm Optimization (PSO) for the constrained portfolio optimization problem. **Expert Systems with Applications**, v. 38, n. 8, p. 10161–10169, ago. 2011.