



Instituto Superior de Contabilidade e Administração

Politécnico de Coimbra



Avaliação do desempenho dos *Exchange-Traded Funds* de inteligência artificial

Bárbara Ferreira

ISCAC | 2024



**Instituto Superior
de Contabilidade
e Administração**

Politécnico de Coimbra

Bárbara Ferreira

Avaliação do desempenho dos *Exchange-Traded Funds* de inteligência artificial

Coimbra, maio de 2024



**Instituto Superior
de Contabilidade
e Administração**

Politécnico de Coimbra

Bárbara Ferreira

Avaliação do desempenho dos *Exchange-Traded Funds* de inteligência artificial

Dissertação submetida ao Instituto Superior de Contabilidade e Administração de Coimbra para cumprimento dos requisitos necessários à obtenção do grau de **Mestre em Análise Financeira**, realizada sob a orientação da Professora Doutora Maria Elisabete Duarte Neves e a coorientação da Professora Doutora Maria do Castelo Baptista Gouveia.

Coimbra, maio de 2024

TERMO DE RESPONSABILIDADE

Declaro ser a autora desta dissertação, que constitui um trabalho original e inédito, que nunca foi submetido a outra Instituição de ensino superior para obtenção de um grau acadêmico ou outra habilitação. Atesto ainda que todas as citações estão devidamente identificadas e que tenho consciência de que o plágio constitui uma grave falta de ética, que poderá resultar na anulação da presente dissertação.

AGRADECIMENTOS

Agradeço sinceramente a todas as pessoas que colaboraram e apoiaram a realização desta dissertação.

Primeiramente, expresso a minha profunda gratidão à minha orientadora Professora Doutora Maria Elisabete Duarte Neves, pela orientação valiosa, partilha de conhecimento, encorajamento ao longo de todo o processo e sobretudo a sua disponibilidade e ajuda incondicional.

Gostaria também de agradecer à minha coorientadora Professora Doutora Maria do Castelo Baptista Gouveia, pela sua cooperação importante na implementação do modelo matemático, a sua disponibilidade e ajuda foram deveras importantes na realização deste trabalho.

À minha família e amigos agradeço todo apoio, compreensão, motivação que demonstraram ao longo deste percurso.

RESUMO

Esta dissertação tem como objetivo avaliar o desempenho dos *Exchange-Traded Funds* (ETFs) de inteligência artificial (IA). A fim de atingir o objetivo proposto, foi analisada uma amostra de 22 ETFs de IA cotados em bolsa de valores, no período de 1 ano (2022), 3 anos (2020 a 2022) e 5 anos (2018 a 2022), recorrendo à metodologia *Value-Based DEA* (*Data Envelopment Analysis*) desenvolvida por Gouveia et al. (2008).

O método *Value-Based DEA* é uma abordagem que combina técnicas da DEA com princípios da Análise de Decisão Multicritério (*Multiple Criteria Decision Analysis* - MCDA). Neste método, os *inputs* (recursos) e *outputs* (produtos) de cada unidade de decisão (*Decision Making Unit* – DMU) são convertidos em funções de valor, que representam as preferências do tomador de decisão em relação aos diferentes critérios. O objetivo é encontrar uma alocação de pesos que minimize a diferença de valor em relação à melhor DMU, permitindo uma avaliação mais precisa da eficiência relativa. Esta metodologia considera as preferências individuais e as prioridades do decisor, oferecendo informações úteis para a avaliação do desempenho e subsequente tomada de decisão.

Os resultados obtidos indicam que os ETFs de IA representam um produto financeiro promissor com potencial para capturar os avanços tecnológicos e inovadores. Numa perspectiva de curto prazo, as medidas de risco têm maior relevância para os fundos eficientes, isto é, os investidores adotam uma posição retraída no mercado. No médio/longo prazo, observa-se um aumento significativo nos ETFs eficientes, e as métricas de rentabilidade ajustadas ao risco revelam-se cruciais. Neste período, o investidor encontra a segurança na rentabilidade associada à inovação e ao ciclo de produtos, reconhecendo que eventualmente num período mais longo a instabilidade destes produtos poderá ressurgir acompanhada de volatilidade e risco. A longo prazo, o número de fundos eficientes volta a aumentar, o que sugere que o investidor tende a privilegiar os que replicam o mercado, mas atendendo de igual modo à sua sensibilidade às flutuações do mesmo.

Esta dissertação é original e procura colmatar o gap da literatura existente sobre a eficiência deste tipo de fundos, já que se trata de um assunto do momento e ainda pouco explorado.

Palavras-chave: ETF, inteligência artificial, desempenho, eficiência, *Value-Based DEA*

ABSTRACT

This dissertation aims at evaluating the performance of artificial intelligence (AI) *Exchange-Traded Funds* (ETFs). Over a 1-year (2022), 3-years (2023 to 2022) and 5-years (2018 to 2022) period, a sample of 22 artificial intelligence ETFs, listed on the stock Exchange, was analyzed using the *Value-Based DEA (Data Envelopment Analysis)* methodology developed by Gouveia et al (2008).

The *Value-Based DEA* method is an approach that combines DEA techniques with the principles of *Multiple Criteria Decision Analysis* (MCDA). Following this method, the *inputs* (resources) and *outputs* (products) of each *Decision Making Unit* (DMU) are converted into value functions, which represent the preferences of the decision maker in relation to the different criteria. The aim is to find an allocation of weights that minimizes the difference in value in relation to the best DMU, resulting in a more accurate assessment of relative efficiency. This approach takes into account the individual preferences and priorities of the decision-maker, providing valuable *insights* into performance analysis and decision-making.

The results obtained indicate that artificial intelligence ETFs represent a promising financial product, which helps to facilitate technological and innovative advance. From a short-term perspective, risk measures are more relevant for efficient funds, i.e., investors adopt a withdrawn position on the market. In the medium to long term, there is a significant increase in efficient ETFs, for which risk-adjusted return metrics are crucial. During a period, the investor finds security in the returns associated with innovation and the product cycle, recognizing that eventually, in a longer period, the instability of these products will return, based on volatility and risk. In the long term, the number of efficient funds increases again. This suggests that the investor tends to favor those funds that replicate the market, while their sensitivity to market fluctuations, also needs to be taken into account.

This dissertation seeks add to limited research on the subject, particularly in the artificial intelligence sector, such as the implementation of the *Value-Based DEA* methodology in evaluating the efficiency of ETFs. As far as we know, the evaluation of the performance of artificial intelligence *Exchange-Traded Funds* is new in this research area.

Keywords: ETF, artificial intelligence, performance, efficiency, Value-Based DEA

ÍNDICE GERAL

1. INTRODUÇÃO.....	1
2. REVISÃO DA LITERATURA.....	5
2.1. Enquadramento teórico.....	5
2.2. Desempenho dos ETFs.....	10
2.2.1. ETFs de inteligência artificial.....	13
3. METODOLOGIA E DADOS.....	18
3.1. DEA.....	18
3.1.1. DEA num contexto financeiro.....	20
3.2. <i>Value-Based</i> DEA.....	24
3.3. Dados.....	27
3.3.1. Descrição dos dados.....	27
3.3.2. Seleção de <i>inputs</i> e <i>outputs</i>	29
4. ANÁLISE E DISCUSSÃO DE RESULTADOS.....	32
4.1. Resultados para 1 ano (2022).....	33
4.2. Resultados para 3 anos (2020-2022).....	34
4.3. Resultados para 5 anos (2018-2022).....	36
4.4. Discussão de resultados.....	38
5. CONCLUSÕES.....	41
REFERÊNCIAS BIBLIOGRÁFICAS.....	43
WEBGRAFIA.....	49
APÊNDICES.....	50

ÍNDICE DE FIGURAS

Figura 1: Número de ETFs e total de ativos. Fonte: Statistica (2023)	3
Figura 2: Total de ativos líquidos e número de ETFs. Fonte: Investment Company Institute (2023).....	9
Figura 3: ETFs geograficamente. Fonte: VettaFi (2024)	9
Figura 4: Fluxos mensais de ETFs de IA e Robótica. Fonte: Bloomberg Intelligence (2023)	15

ÍNDICE DE TABELAS

Tabela 2: Estudos com base em DEA	20
Tabela 3: Dados relativos aos ETFs	27
Tabela 4: Inputs e Outputs.....	31
Tabela 5: Scores de eficiência dos ETFs	32
Tabela 6: Scores e Pesos atribuídos aos fatores dos ETFs eficientes para 1 ano	33
Tabela 7: Scores e Pesos atribuídos aos fatores dos ETFs eficientes para 3 anos.....	34
Tabela 8: Scores e Pesos atribuídos aos fatores dos ETFs eficientes para 5 anos.....	36

ÍNDICE DE APÊNDICES

Apêndice A.1. - Valores convertidos em valores de escala para 1 ano	51
Apêndice A. 2. - Valores convertidos em valores de escala para 3 anos.....	52
Apêndice A. 3. - Valores convertidos em valores de escala para 5 anos.....	53
Apêndice B.1. - Pesos atribuídos aos fatores para 1 ano	54
Apêndice B.2. - Pesos atribuídos aos fatores para 3 anos.....	55
Apêndice B.3. - Pesos atribuídos aos fatores para 5 anos.....	56
Apêndice C.1. - Pares e slacks para 1 ano	56
Apêndice C.2. - Pares e slacks para 3 anos.....	57
Apêndice C.3. - Pares e slacks para 5 anos.....	57

Lista de abreviaturas, acrónimos e siglas

AUM – *Assets Under Management*

BP-SBM – *Base point-slack-based measure*

CCR – Charnes Cooper & Rhodes

CMVM – Comissão do Mercado de Valores Mobiliários

DEA – *Data Envelopment Analysis*

DMU – *Decision Making Unit*

ESG – *Environmental, Social and Governance*

ETF – *Exchange-Traded Funds*

EUA- Estados Unidos da América

FII – Fundos de investimento imobiliário

FIM – Fundos de investimento mobiliário

IA – Inteligência Artificial

I&D – Investigação e desenvolvimento

MAVT – *Multi-Attribute Value Theory*

MCDA – *Multiple Criteria Decision Analysis*

MCDM – *Multiple Criteria Decision Making*

PNL – Processamento de linguagem natural

RAM – *Range Adjusted Measure*

RDM – *Range directional model*

S&P 500 – Standard & Poor's 500

SEC – *Securities and Exchange Commission*

TSE-35 – *Toronto Stock Exchange 35*

VRS – *Variable Returns to Scale*

WRDDM – Weighted Russell Diretional Distance Model

Glossário

Benchmark – refere-se a um ponto de referência ou padrão utilizado para comparar, avaliar ou medir o desempenho, eficiência ou qualidade de algo em relação a um padrão conhecido.

Bear market – é um termo usado para descrever um mercado financeiro caracterizado por uma tendência de queda prolongada nos preços dos ativos. Neste período, os investidores estão pessimistas em relação às perspectivas futuras do mercado e tendem a vender os seus ativos o que provoca uma redução contínua nos preços dos mesmos.

Downside risk – corresponde à perda potencial que pode surgir como medida de risco contra um retorno mínimo aceitável, isolando a parte negativa da volatilidade.

Expense ratio – representa a taxa anual dos ativos totais de um fundo de investimento que é utilizada para cobrir os custos operacionais e administrativos do fundo.

Fintech – este termo é uma abreviação de “tecnologia financeira” (do inglês “financial technology”) e diz respeito a empresas que utilizam a tecnologia para oferecer produtos e serviços financeiros de forma inovadora, eficiente e acessível.

Loads – é a taxa ou comissão de vendas cobrada a um investidor no momento da compra ou do resgate das ações de um fundo.

Market Timing – corresponde a uma estratégia de investimento que envolve a previsão dos movimentos futuros do mercado financeiro, a fim de fechar posições de investimento com o intuito de obter lucros ou evitar perdas.

Maximum drawdown – este termo refere-se à maior queda em valor de um investimento ou portfolio, medida a partir de um pico até ao ponto mais alto, antes de atingir um novo pico.

Performance – é uma medida crítica utilizada para avaliar o desempenho ou resultado alcançado por uma empresa, investimento ou portfolio durante um determinado período de tempo.

Price-to-book ratio – compara o valor de mercado de uma empresa com o seu valor contabilístico.

Score – representa uma medida quantitativa ou qualitativa que avalia o desempenho, resultado ou classificação de algo num determinado contexto.

Software – define o conjunto de componentes lógicos de um computador que controlam a operação de um sistema e permitem a execução de diversas tarefas específicas, desde o processamento de dados até à comunicação e entretenimento.

Spread – refere-se à diferença entre os preços de compra e de venda de um ativo financeiro. Assim, quanto maior é o *spread*, maior a diferença entre os preços de compra e de venda, logo, maior o custo de transação para o investidor.

Stakeholder – é qualquer pessoa, grupo ou entidade que é afetada, direta ou indiretamente, pelas atividades de uma organização, projeto ou iniciativa e, portanto, tem um interesse no seu sucesso ou fracasso.

Swaps – é um produto financeiro, contratualizado no mercado entre duas partes que concordam trocar fluxos de pagamentos futuros com base em determinadas condições acordadas. Estas condições geralmente incluem a troca de pagamentos em diferentes moedas, taxas de juro, índices ou valores nominais.

Ticker – corresponde ao sistema de letras utilizado a fim de identificar um produto financeiro negociado em bolsa de valores, designado como símbolo de negociação.

Trailing Total Return – é o retorno total de um investimento, incluindo ganhos de capital, dividendos ou juros reinvestidos ao longo de um período contínuo até ao presente.

Turnover ratio – este rácio representa uma medida de eficiência da atividade de negociação de um fundo e representa a rotatividade com que um gestor de fundo consegue vender todas as suas ações num determinado ano.

1. INTRODUÇÃO

A ascensão da inteligência artificial (IA) tem transformado significativamente diversos setores, e o mercado de capitais não é exceção, sendo um dos principais temas de debate e interesse na atualidade (Haenlein & Kaplan, 2019).

Haenlein & Kaplan (2019) identificam as raízes da IA na década de 1940, mais concretamente em 1942, quando o escritor americano de ficção científica Isaac Asimov publicou o seu conto “*Runaround*”, que narrava a criação de um robot. Através do mesmo inspirou gerações de cientistas no domínio da robótica, da IA e da ciência de computação. Também nesta altura, o matemático inglês Alan Turing desenvolveu uma máquina de decifrar códigos chamada “*The Bombe*” para o governo britânico, com o objetivo de decifrar o código enigma utilizado pelo exército alemão na Segunda Guerra Mundial, tarefa esta que era impossível para qualquer ser humano. Os autores descrevem que a palavra “inteligência artificial” foi oficialmente cunhada cerca de seis anos mais tarde, quando em 1956 Marvin Minsky e John McCarthy organizaram o *Dartmouth Summer Research Project on Artificial Intelligence* (DSRPAI). Este evento tinha como objetivo reunir investigadores de vários domínios no sentido de obterem uma nova área de investigação destinada a construir máquinas capazes de simular a inteligência humana. Entre os participantes contavam-se o cientista informático Nathaniel Rochester, que mais tarde concebeu o IBM 701, o primeiro computador científico comercial, e o matemático Claude Shannon, que fundou a teoria da informação.

Atualmente, a IA está a revolucionar muitas indústrias ao realizar tarefas que normalmente requerem a inteligência humana para serem executadas, contribuindo para fluxos de trabalho científico e de engenharia complexos, simulando, complementando ou aumentando a inteligência humana de forma eficiente e precisa (Muthukrishnan et al., 2020). Esta tecnologia tem como objetivo programar a inteligência nas máquinas aprendendo com as experiências e adaptando-se às mudanças no ambiente para simular a tomada de decisões e os processos de raciocínio humano (Muthukrishnan et al., 2020). Muitas empresas investiram na investigação e no desenvolvimento de tecnologias inovadoras a fim de tornar os seus processos operacionais mais eficientes e assim aumentar a competitividade. Entre muitas das novas tecnologias de alta, a IA é a que tem atraído maior atenção (Ali Mohamad et al., 2023). Para além disso, as empresas que implementaram tecnologias de IA tornaram os seus procedimentos empresariais mais

eficientes e menos onerosos, e estes benefícios são úteis para melhorar o desempenho das empresas, tanto a nível organizacional como de processos (Wamba-Taguimdje et al., 2020).

Relativamente ao mercado de capitais, nos últimos anos houve uma forte tendência pelo investimento em *Exchange-Traded Funds* (ETFs), estes fundos aumentaram em termos de dimensão, diversidade, âmbito, complexidade e importância no mercado (Ivanov, 2016). Na figura 1, podemos constatar que o volume de ETFs está a aumentar a nível mundial, em 2010 existiam 2.503 ETFs (1.313 biliões de dólares de ativos), e em 2022 contavam-se 8.724 (9.552 biliões de dólares de ativos), o que revela uma taxa de crescimento rápida que atesta o estatuto dos ETFs como um dos investimentos mais populares e importantes da atualidade.

Estudos anteriores demonstraram que a natureza destes investimentos incentiva os investidores a mudar o seu comportamento, alterando o preço das ações, a volatilidade e a liquidez dos componentes dos ETFs. Por exemplo, Narend & Thenmozhi (2016) sugeriram que os ETFs são utilizados para ganhar exposição nas várias classes de ativos, estes fundos são preferidos essencialmente pelos seus baixos rácios de despesas, transparência, negociação intradiária e eficiência fiscal (M. E. Neves et al., 2019). Zhang (2015) demonstrou que a emissão de ETFs sobre o ouro atraiu investidores desinformados, diminuindo a liquidez e os preços das ações de empresas relacionadas com o ouro. Pelo contrário, Hegde & McDermott (2004) e Richie & Madura (2007) concluíram que a emissão de ETFs aumenta a liquidez e a valorização das ações presentes na constituição da sua carteira.




Figura 1: Número de ETFs e total de ativos. Fonte: Statista (2023)

Perante este cenário, os ETFs de IA emergem como veículos promissores para capitalizar as inovações tecnológicas (Yousaf et al., 2024). Estes fundos reúnem uma carteira diversificada de ativos relacionados à IA, proporcionando aos investidores uma entrada estratégica no universo dinâmico deste setor. Este fenômeno não apenas reflete a rápida evolução tecnológica, mas também evidencia uma nova abordagem para a construção de carteiras de investimento. Contudo, a eficácia e a consistência do desempenho dos ETFs de IA tornam-se elementos cruciais a serem avaliados.

Assim, este estudo propõe-se a analisar de forma aprofundada a eficiência dos ETFs de IA, a fim de compreender a sustentabilidade dos seus níveis de desempenho ao longo do tempo. A avaliação crítica destes ETFs é essencial não apenas para investidores que procuram oportunidades de investimento atrativas, mas também para profissionais do mercado financeiro e acadêmicos interessados em compreender o impacto da IA na gestão de ativos. Para além disso, a sociedade civil poderá ter a percepção da maneira como a tecnologia e mais especificamente a IA está presente no mercado de capitais. Assim, ao explorar as características de desempenho e eficiência dos ETFs de IA, esta dissertação visa contribuir para a compreensão mais abrangente do papel destes instrumentos financeiros inovadores no mercado de capitais, oferecendo contributos valiosos sobre o seu potencial, os riscos e o papel da IA na definição do futuro financeiro.

Relativamente à estrutura da dissertação, esta será organizada da seguinte forma: no capítulo 1 é efetuada a revisão da literatura contextualizando o tema em análise. De seguida no capítulo 2 a metodologia de investigação é detalhada, mais especificamente a amostra, as variáveis, o método *Value-Based* DEA e o modelo estabelecido. No capítulo 3 são discutidos os resultados obtidos. Por último, apresenta-se a conclusão, algumas limitações encontradas na realização deste estudo, bem como sugestões para linhas de investigações futuras e contribuições específicas para cada *stakeholder*.

2. REVISÃO DA LITERATURA

Neste capítulo é apresentada a revisão da literatura do tema em análise, nomeadamente sobre a evolução dos níveis de desempenho dos ETFs.

2.1. Enquadramento teórico

Atendendo à definição proposta pela Comissão do Mercado de Valores Mobiliários (CMVM)¹, os ETFs são fundos de investimento abertos admitidos a negociação numa bolsa de valores e têm como principal objetivo um desempenho relacionado com o comportamento de um determinado indicador de referência. Ao contrário dos fundos de investimento convencionais, os ETFs permitem aos investidores negociarem os seus ativos na bolsa de valores a um preço de mercado.

De acordo com a *Securities and Exchange Commission (SEC)*² (Comissão dos Valores Mobiliários dos Estados Unidos), os ETFs são um tipo de investimento negociado em bolsa de valores que deve ser registado na SEC ao abrigo da Lei de 1940 como uma sociedade de investimento aberta (geralmente conhecida como “fundos”) ou como um fundo de investimento unitário. Os pequenos investidores apenas podem comprar e vender ações de ETFs em transações de mercado. Isto é, ao contrário dos fundos mútuos, os ETFs não vendem ações individuais diretamente a investidores de retalho, nem resgatam as suas ações individuais diretamente desses investidores (Bhojraj et al., 2020). Em vez disso, os promotores de ETFs definem relações contratuais com uma ou mais instituições financeiras conhecidas como “Participantes Autorizados”. Estes Participantes Autorizados são normalmente grandes corretoras, e apenas estes estão autorizados a comprar e resgatar ações diretamente do ETF, e só podem fazer em grandes agregações ou blocos (por exemplo 50.000 ações do ETF), designadas por “Unidades de Criação”.

Ben-David et al. (2017) argumentam que existem dois tipos principais de ETFs que se distinguem pela forma como replicam o índice subjacente, intitulados como *physical* ETFs e *synthetic* ETFs. A característica fundamental dos *physical* ETFs é que estes

¹<https://investidor.cmvm.pt/PInvestidor/Content?Input=E4600A824482C80A76A6AA40A03761FF9601796E8E877C3598DF92C245BA884E> acedido em 23 de novembro de 2023

² <https://www.investor.gov/introduction-investing/investing-basics/investment-products/mutual-funds-and-exchange-traded-2> acedido a 8 de dezembro de 2023

pretendem seguir de perto o retorno do seu índice de referência, mantendo nas suas carteiras a totalidade ou uma amostra representativa do mesmo, com ponderações que permitam a sua imitação. Em contrapartida, os *synthetic* ETFs reproduzem um índice ao celebrar contratos de derivados, tais como *swaps* de retorno total sobre o índice de referência. Estes têm uma popularidade maior na Europa em comparação aos Estados Unidos (Ben-David et al., 2017b). Relativamente ao risco subjacente a estes investimentos, os *physical* ETFs efetuam empréstimos de títulos. Assim, há uma exposição ao risco de incumprimento do tomador do título, ao contrário dos *synthetic* ETFs que se expõem ao risco de incumprimento da contraparte do contrato de derivados.

De acordo com os estudos elaborados por Charupat & Miu (2013) e Deville (2008), a origem dos ETFs provém do *Toronto Stock Exchange Index Participations*, introduzido no mercado em 1990 é concebido para acompanhar o índice de ações TSE-35. Em 1993, a *American Stock Exchange* introduziu a negociação dos *Standard & Poor's Depositary Receipts* (SPDR), popularmente conhecido como “*Spider*”, cujo objetivo principal era acompanhar o índice S&P 500. Dado o seu sucesso no mercado de valores mobiliários, a procura por veículos de negociação de cabazes de baixo custo sofreu um enorme crescimento e assim surgiram outros ETFs. Contudo, foi através do lançamento do *Nasdaq-100 Index Tracking Stock*, em 1999, que os ETFs se assumiram como um investimento atrativo no mercado.

Segundo Charupat & Miu (2013), Lettau & Madhavan (2018) e Narend & Thenmozhi (2016), a popularidade dos ETFs deve-se às suas diversas vantagens que os distinguem de outros produtos financeiros que seguem índices de referência, como os fundos de investimento convencionais e os fundos fechados (Dumitrescu et al., 2023). Os principais benefícios são a possibilidade da negociação intradiária, a eficiência fiscal, os baixos rácios de despesas e a transparência de custos. Apesar de todas estas vantagens, estes produtos financeiros podem ter comissões de gestão elevadas se tiverem pouca liquidez (Charupat & Miu, 2013).

Relativamente ao notório crescimento dos ETFs, este tem se revelado a tendência mais perturbadora no setor da gestão de ativos nos último 20 anos. De acordo com um estudo realizado pela PWC (2023), houve 1.4 triliões de dólares de saídas líquidas de fundos mútuos no mundo. Contudo os ETFs contrariaram a tendência, atraindo 779 milhões de dólares em entradas líquidas. Em dezembro 2022, os ETFs *assets under management*

(AUM) atingiram 9.2 bilhões de dólares. Os gestores de ETFs que participaram no inquérito deste estudo, preveem que os ETFs AUM a nível mundial aumentem para pelo menos 15 bilhões de dólares até 2027.

Segundo o autor Jackson (2023) da *Morningstar*³, este crescimento pode ser explicado pelo desenvolvimento da legislação, de produtos e tendências de mercado que colocaram em evidência as vantagens únicas dos ETFs. Nos últimos anos, estes investimentos afirmaram-se no mercado de capitais, e em cada ano civil desde 2018 embolsaram aproximadamente 25 bilhões de dólares, ou seja, uma taxa de crescimento orgânica de 30%. No final de outubro de 2023, estes ETFs ostentavam 444 bilhões de dólares em ativos, quase o triplo do valor comparado com outubro de 2020. Com a crescente procura deste produto financeiro, os investidores abdicaram dos fundos mútuos geridos ativamente, sofrendo assim saídas em 2022 de 1 trilhão de dólares. Ao contrário dos ETFs geridos ativamente que sofreram um aumento de lançamentos, de janeiro a outubro de 2022, de 789 novos ETFs. Para além disso, um desenvolvimento importante levou à proliferação de ETFs ativos, a SEC em 2019 aprovou a Regra 6c-11, esta legislação permitiu aos fornecedores de fundos de criar e resgatar ações de ETFs com cabazes personalizados. Este evento foi crucial, dado que deu flexibilidade aos gestores de ativos para aproveitarem a eficiência fiscal dos ETFs. Assim, a conversão de fundos mútuos em ETFs tornou-se uma prática comum para alguns gestores de ativos, dos 1.286 ETFs ativos listados em outubro de 2023, 65 eram fundos mútuos que foram convertidos.

Atendendo ao relatório apresentado pelo Investment Company Institute (2023), o mercado de ETFs nos Estados Unidos, no final de 2022, tinha cerca de 2.844 fundos e 6.5 bilhões de dólares em ativos líquidos totais, representando dessa forma 72% dos 8.9 bilhões de dólares em ativos líquidos de ETFs em todo o mundo. A maior parte dos investidores acede aos ETFs através do mercado secundário, contudo há investidores institucionais que podem aceder também no mercado primário (através de criações e resgates de ações de ETFs). Estes investidores que negociam ETFs no mercado secundário, são geralmente motivados pela arbitragem, ou seja, utilizam este investimento para ganhar ou reduzir a exposição a classes de ativos ou estratégias de

³ <https://www.morningstar.com/etfs/constellation-factors-powering-active-etfs-meteoric-rise> acedido em 8 de dezembro de 2023

investimento específicas, diversificar as suas carteiras ou cobrir riscos de investimento. Por conseguinte, não é surpreendente que o volume de transações no mercado secundário de ETFs seja elevado.

Durante períodos de turbulência, o volume de negociação no mercado secundário de ETFs sofre um enorme aumento devido ao facto dos investidores recorrerem aos ETFs para transferir e cobrir riscos de forma rápida e eficiente (da Costa Neto et al., 2019). Por exemplo em 2022, houve uma grande preocupação com o aumento da volatilidade nos mercados acionistas e obrigacionistas devido à posição da Reserva Federal relativamente à política monetária para combater o aumento da inflação. Assim, o volume de negociação dos ETFs atingiu um pico de 39% das negociações do mercado de ações.

Nos últimos anos, a procura de ETFs cresceu, visto que os investidores institucionais descobriram que os ETFs são um veículo conveniente para participar em movimentos amplos no mercado de ações, ou para se protegerem contra. Em 2022, a emissão líquida de ações de ETFs (incluindo dividendos reinvestidos) representou 609 biliões de dólares, mesmo com perdas acentuadas nos mercados de ações e títulos. A emissão líquida de ETFs de ações americanas foi de 317 biliões de dólares, abaixo dos 519 biliões de dólares em 2021, e a emissão líquida de ETFs de ações globais caiu de 211 biliões de dólares para 100 biliões de dólares. Esta diminuição refletiu o fraco desempenho dos preços das ações mundialmente e foi provavelmente reprimida por uma valorização do dólar americano, o que diminui a atratividade dos investimentos internacionais para os investidores americanos.




Figura 2: Total de ativos líquidos e número de ETFs. Fonte: *Investment Company Institute* (2023)

A nível mundial, os ETFs estão presentes em todos os continentes, sendo que há neste momento 13.629 ETFs (Figura 3).




Figura 3: ETFs geograficamente. Fonte: VettaFi (2024)

Tendo em conta o crescimento e a importância predominante que os ETFs estão a ter no mercado de capitais, o estudo que sugerimos pretende explorar as vantagens destes recorrendo à avaliação da sua eficiência. Os diversos ETFs do setor de IA que serão estudados baseiam-se em *physical* ETFs e *synthetic* ETFs. Assim, a amostra terá ETFs que serão compostos por ações com participações idênticas às que serão apresentadas pelo índice de referência e ETFs baseados em *commodities* que implementam essencialmente contratos de futuros e *swaps*. Estes dois tipos de ETFs conjugados

permitem ao potencial investidor aceder a diversas estratégias de investimento no sentido de potenciar o seu valor.

2.2. Desempenho dos ETFs

Após um enquadramento teórico relativamente à importância recente dos ETFs, faz-se nesta subsecção referência a alguns estudos elaborados a fim de explicar o desempenho destes fundos de investimento no mercado de capitais ao longo do tempo.

Blitz et al. (2012) ao analisarem o desempenho dos fundos mútuos de índices e dos ETFs cotados na Europa e que acompanham os principais índices dos mercados bolsistas dos EUA, Europa, Japão e mercados emergentes, concluíram que estes fundos têm um desempenho inferior ao dos seus índices de referência em 50 a 150 pontos base por ano. Esta diferença é explicada pelos elevados impostos retidos na fonte sobre os dividendos que impactam os fundos em -48 pontos base, bem como as elevadas despesas dos fundos que prejudicam o desempenho dos mesmos em -56 pontos base.

Mais tarde, Neves et al. (2019) analisaram os efeitos reais da diversificação, risco e desempenho dos ETFs de diversos países durante o período da crise global de 2004 a 2015. O estudo revelou que os benefícios da diversificação através deste veículo de investimento são bastante limitados, nomeadamente em períodos de crise, existindo contágio entre fundos que são índices.

Blitz & Vidojevic (2021) ao efetuarem um estudo à *performance* dos ETFs de ações dos EUA, concluíram que o desempenho dos ETFs, ao contrário do esperado, não é impressionante, uma vez que não é muito diferente do desempenho dos fundos mútuos convencionais geridos ativamente. Além disso, constataram que os ETFs obtiveram um desempenho pior do que o do mercado, assim o fascínio destes investimentos encontra-se com pouco apoio empírico nos dados, logo têm de demonstrar que podem gerar um melhor desempenho do que os dos fundos convencionais geridos ativamente.

Da mesma forma, Tripathi & Sethi (2022) investigaram sobre a eficiência dos ETFs domiciliados na Índia e analisaram o desempenho do seu acompanhamento. Através dos resultados obtidos verificaram que estes ativos têm uma exposição significativamente mais baixa em relação aos seus índices de referência. Além disso, existem ligações a longo prazo com os índices de referência para a maioria dos ETFs, contudo, os desvios de preços em relação aos índices são bastante persistentes. Os *spreads* de compra e venda,

os desvios de preços, o valor líquido dos ativos, a idade do fundo e a sua dimensão são os principais fatores de influência do acompanhamento do desempenho.

Favreau et al. (2020) corroboram a ideia de que os ETFs não conseguem acompanhar os seus índices de referência. O estudo conclui que estes fundos apresentam uma rentabilidade ajustada ao risco inferior. A análise dos autores revela que grande parte deste desempenho é explicado pela falta de experiência prévia dos gestores dos ETFs.

Zawadzki (2020) avaliou o desempenho dos ETFs utilizando várias abordagens de cálculo do *Tracking Error*, com base numa amostra de 18 ETFs diferentes emitidos pela *iShares*. Os resultados indicaram que os ETFs não conseguem imitar de forma eficiente os seus índices de referência e afirmaram que o critério geográfico determina o nível de erro de seguimento. Para além disso, demonstraram que os mercados emergentes têm uma avaliação incorreta dos ETFs, provocada pela liquidez reduzida, diferentes horários de negociação e pela diferença cambial.

Bahadar et al. (2020) efetuaram um estudo que avalia o desempenho dos ETFs internacionais através da análise das rentibilidades, volatilidades, capacidade de acompanhamento e a eficiência dos preços. A amostra é composta por 56 ETFs internacionais listados nos EUA, oferecendo exposição aos mercados da Ásia-Pacífico e da Europa. Assim, foi demonstrado que os horários de negociação assíncronos entre os mercados dos ETFs e dos seus índices de referência não só dificultam a aplicação de uma estratégia de reprodução integral, como também tornam ineficaz o processo de criação e/ou resgate e, consequentemente, prejudicam o desempenho dos ETFs internacionais.

Também os autores Valadkhani & Moradi-Motlagh (2023) avaliaram o desempenho de 110 ETFs americanos ao aplicar um modelo de distância direcional de fronteira atribuindo pesos diferentes a três medidas de rentabilidade líquida e de risco nos últimos 3, 5 e 10 anos. Esta investigação revela que alguns ETFs, independentemente das ponderações atribuídas à rentabilidade e ao risco, são totalmente eficientes. Além disso, as conclusões do estudo demonstram que os ETFs com maior desempenho se situam predominantemente nos setores da tecnologia e dos dispositivos médicos, beneficiando de ganhos relativamente mais elevados e de perdas mais baixas.

A investigação elaborada por Baklaci et al. (2023) sugeriu que os ETFs Environmental, Social and Governance (ESG) dos mercados globais e emergentes não conseguem proporcionar retornos suficientes para justificar os seus níveis de risco. Além disso, na

maioria dos casos, estes fundos têm um desempenho inferior ao dos ETFs convencionais. Estes resultados implicam que as competências de seleção de títulos dos gestores dos ETFs ESG são inferiores às dos gestores dos ETFs convencionais. Em contrapartida, os resultados apresentados dos ETFs ESG dos Estados Unidos sugerem que a capacidade de *market timing* dos gestores destes fundos são melhores que dos gestores de ETFs convencionais.

O estudo efetuado por Miu et al. (2021) investiga o desempenho do acompanhamento e a eficiência de preços de cinco grupos de ETFs alavancados de ações negociadas no Japão. Os ETFs alavancados caracterizam-se pelo facto de utilizarem apenas contratos de futuros para obterem a exposição desejada ao índice de referência. Os resultados empíricos obtidos permitiram concluir que os fundos com rácios de alavancagem positivos tendem a ter um desempenho superior ao dos seus índices de referência, um padrão oposto ao dos fundos de acompanhamento de índices de ações cotadas nos EUA. Ademais, prova-se que o desempenho superior se concentra nas datas importantes referentes aos dividendos das ações constituintes do índice subjacente. Os autores argumentam que este facto pode ser devido à forte dependência de contratos de futuros.

De acordo com a *Securities and Exchange Commission*⁴, o investimento em ETFs tem diversos riscos e benefícios. Em primeiro lugar, o prémio ou desconto em relação ao valor líquido dos ativos (*Premium or Discount to NAV*), devido à forma como os ETFs são negociados, pode-se pagar mais ou menos pelas ações do ETF do que o valor dos ativos subjacentes do fundo. Isto deve-se ao facto de as ações do ETF serem negociadas ao longo do dia nas bolsas de valores nacionais e a preços de mercado que podem ser ou não iguais ao valor líquido das ações. De seguida, as taxas são baixas, ou seja, os ETFs tendem a ser menos dispendiosos do que os fundos mútuos, dado que os custos de transação são mais baixos e há uma necessidade reduzida de serviços de funcionamento. Por outro lado, os ETFs podem ser eficientes do ponto de vista fiscal, dado que muitos ETFs compram e vendem títulos da carteira em trocas em espécie (e não em dinheiro). Isto significa que os ETFs têm, normalmente, menos distribuições de mais-valias, consequentemente, os investidores podem pagar menos impostos. Ademais, os ETFs têm dois preços de

⁴ <https://www.investor.gov/introduction-investing/general-resources/news-alerts/alerts-bulletins/investor-bulletins-24> acedido em 8 de dezembro de 2023

mercado, o preço de compra e o preço de venda, logo existe um *spread bid-ask*. Assim, os ETFs mais líquidos e com maior volume de transações apresentam *spreads* mais baixos. Contudo, este *spread* pode ser considerado como um custo oculto para os investidores, uma vez que os *spreads* reduzem os retornos potenciais. Finalmente, uma vez que os ETFs não vendem/resgatam ações individuais diretamente a investidores de retalho, os gestores de ETFs não têm as mesmas preocupações com resgates constantes, logo aumenta a flexibilidade dos gestores para investirem em mais quantidade.

Os estudos mencionados demonstraram que existe alguma preocupação em analisar este tipo de investimentos e desmistificar o seu desempenho, bem como a sua propensão em superar ou pelo menos imitar os seus índices de referência. Assim, a nossa pretensão é analisar se os ETFs revelam ser eficientes e determinar os seus fatores de influência. Desta forma pretende-se ajudar o investidor na sua tomada de decisão relativamente a uma carteira de ETFs na temática de IA.

2.2.1. ETFs de inteligência artificial

De acordo com o Parlamento Europeu⁵, a IA é a capacidade de uma máquina para reproduzir competências idênticas às humanas como é o caso do raciocínio, aprendizagem, planeamento e criatividade, através de heurísticas codificadas por *software*. A IA permite que os sistemas técnicos percebam o ambiente que os rodeia e resolvam problemas, agindo no sentido de alcançar um objetivo específico.

Em 2022, os lançamentos do ChatGPT da OpenAI e do Bard da Google provocaram um enorme interesse pela IA, tornando o tema popular no âmbito financeiro e da sociedade em geral. O fascínio pelo ChatGPT tornou-o sinónimo de IA na mentalidade da maioria dos consumidores, contudo, representa apenas uma pequena parte das formas como a tecnologia de IA está a ser implementada atualmente.

No mercado de capitais, a IA está apenas a dar os primeiros passos, sendo que deve ser aplicada com base em conceitos rigorosos assentes em fundamentos económicos sólidos. Embora seja difícil quantificar o seu impacto, a IA é por muitos considerada uma

⁵ <https://www.europarl.europa.eu/news/pt/headlines/society/20200827STO85804/o-que-e-a-inteligencia-artificial-e-como-funciona> acedido em 28 de novembro de 2023

inovação tecnológica com potencial para mudar a sociedade, à semelhança da introdução da internet (Haenlein & Kaplan, 2019).

A inteligência artificial pode ser implementada de duas formas distintas no mercado de capitais. A primeira passa pelo investimento em empresas que de certa forma utilizam a IA, a robótica ou a tecnologia sofisticada nos seus processos, bem como, a produção de soluções de IA. A segunda, é quando os investimentos são efetuados com auxílio da IA, ou seja, a utilização de abordagens computacionais para automatizar o processo de investimento financeiro que inclui a eliminação da irracionalidade momentânea e decisões tomadas com base em emoções, a capacidade de reconhecer e explorar padrões que são ignorados pelos humanos, e o consumo imediato de informação em tempo real (Ferreira et al., 2021).

A IA, as moedas digitais, os pagamentos móveis e o comércio eletrónico são o resultado de inovações financeiras bem-sucedidas e do rápido desenvolvimento da tecnologia financeira, intitulada *Fintech*. Os *Exchange-Traded Funds* permitem a diversificação no âmbito da revolução *fintech* e tornam-se um veículo de investimento de eleição para os investidores que procuram uma exposição rápida e de baixo custo a índices alargados do mercado de ações. Estes fundos estão a apoiar iniciativas que impulsionam as fronteiras tecnológicas e o desenvolvimento das economias. A IA é uma tecnologia de grande transformação que influencia todos os setores e revela-se um fator crucial na transformação digital.

De acordo com Lizette Chapman (2023) da revista Bloomberg⁶, a IA está a ser introduzida em toda a indústria de ETFs nos Estados Unidos, no valor de quase 7 bilhões de dólares, quer como tecnologia de gestão de fundos, quer como uma nova fronteira para o investimento. Jillian DelSignore, diretora administrativa e chefe do crescimento estratégico e soluções da *FLX Networks* afirmou a 7 de dezembro de 2023: “A indústria de ETFs é o setor da gestão de ativos onde a inovação vai prosperar e é onde a inovação está a ter lugar”. Esta afirmação incentiva os investidores e demonstra a importância dos ETFs na evolução da tecnologia no mercado de capitais. Embora ainda seja um setor

⁶ <https://www.bloomberg.com/news/articles/2023-12-07/andreessen-horowitz-leads-financing-for-ai-startup-air-space-intelligence> acedido em 28 de novembro de 2023

relativamente pequeno, a IA substituiu as criptomoedas como o tópico do momento para os milhares de emissores, fornecedores de índices e consultores que participaram na conferência *Inside ETFs*. Ainda assim, os participantes desta conferência afirmaram que é necessário esclarecer melhor o que significa efetivamente investir em IA. Para alguns, é utilizar a tecnologia, enquanto para outros, é investir em empresas relacionadas à IA.




Figura 4: Fluxos mensais de ETFs de IA e Robótica. Fonte: *Bloomberg Intelligence* (2023)

Mo'ath Almahasneh (2023)⁷, constatou que os investidores rapidamente se consciencializaram do potencial de crescimentos das empresas relacionadas com a IA. Em maio 2023, a Nvidia tornou-se rapidamente o exemplo de investimento em IA quando superou os lucros e reviu as previsões em alta, devido ao seu foco em unidades de processamento gráfico utilizadas para a IA generativa e grandes modelos de linguagem. Consequentemente, o preço da Nvidia subiu 27% entre 22 e 26 de maio de 2023, fazendo com que a sua capitalização bolsista ultrapassasse o ilustre limiar de 1 bilhão de dólares. Durante o mesmo período, houve um investimento de aproximadamente 232 milhões de dólares em ETFs que visam especificamente empresas que ajudam a construir ou beneficiam de IA. Assim, este fator pode marcar o início de um novo tema promissor no investimento em ETFs, que tem apenas 3.28 bilhões de dólares em ativos para ETFs domiciliados nos Estados Unidos com foco em IA.

⁷ <https://www.morningstar.com/etfs/are-ai-etfs-worth-hype> acedido em 29 de novembro de 2023

Para além disso, investir num veículo que visa aproveitar um único tema pode muitas vezes resultar numa aposta estreita, os ETFs temáticos concentram-se geralmente num ou dois setores do mercado e detêm um pequeno número de empresas, porém, a IA é um setor vasto, pelo que as probabilidades de perder empresas que podem beneficiar da IA são maiores do que noutros temas. Contudo, a seleção de fundos que estejam bem posicionados para aproveitar o tema da IA pode ser um desafio, dado que os temas podem ser difíceis de articular em termos reais, e as empresas líderes podem não oferecer uma exposição pura a um tema. Porém, os investidores podem questionar, se os ETFs de IA os expõem adequadamente aos desenvolvimentos atuais e futuros e às implicações mais amplas da corrida ao ouro da IA. As carteiras concentradas aumentam a probabilidade de perder empresas preparadas para beneficiar dos desenvolvimentos da IA. Assim, tentar posicionar ativamente a carteira para capturar empresas que colhem os benefícios da IA pode ser trabalhoso e demorado, no entanto, possuir uma fatia maior do mercado pode aumentar as probabilidades de os investidores obterem uma exposição antecipada a ações e temas vencedores.

De acordo com Dom Lawson (2023)⁸, os fundos centrados na IA representaram mais de metade dos fluxos de entrada de ETFs temáticos europeus no ano de 2023, de acordo com dados da *Morningstar*. Este tema atraiu entradas líquidas de 510 milhões de euros no primeiro semestre de 2023, depois de ter registado saídas de 60 milhões de euros em 2022. Os fluxos de entrada representam 53% dos 960 milhões de euros registados por todos os ETFs temáticos na Europa. Kenneth Lamont, gestor sénior e analista de investigação de estratégias passivas da *Morningstar*, afirmou que a IA foi, sem dúvida, o principal tema que animou os mercados acionistas mundiais no ano de 2023. Os nove fundos temáticos com melhor desempenho no primeiro semestre centraram-se no tema das mudanças tecnológicas, de acordo com um relatório da *WisdomTree*.

Numa entrevista da *VettaFi*⁹, o autor Karrie Gordon (2023) relatou que Jay Jacobs da *BlackRock* e Pedro Palandrani da *Global X* juntaram-se ao chefe de pesquisa da *VettaFi*,

⁸ <https://www.ft.com/content/08e159e5-d545-4bc0-ac84-9ede1567d529> acedido em 29 de dezembro de 2023

⁹ <https://www.etftrends.com/artificial-intelligence-channel/ai-incredibly-powerful-theme-next-decade/> acedido em 29 de dezembro de 2023

Todd Rosenbluth, para discutir sobre o investimento em IA e as empresas a serem observadas nos próximos anos no recente simpósio de IA organizado pela *VettaFi*. Jay Jacobs, acredita que a IA será uma das tecnologias mais transformadoras desde a introdução da internet. A adoção da IA está a acontecer a um ritmo muito acelerado, nomeadamente o ChatGPT registou mais de 100 mil milhões de novos utilizadores em junho e julho de 2023. Para consultores em dúvida sobre o investimento direcionado em IA, Jacobs explicou que o portfólio de ações do consultor médio já contém uma exposição de cerca de 20% à IA. Contudo, apesar de muitos investidores reconhecerem que a IA é um tema importante, é difícil de selecionar ações, especialmente porque se trata de uma indústria relativamente recente. O que pode significar que as ações não são todas bem reconhecidas e podem ser difíceis de pesquisar; poucos intervenientes significativos sem líderes de mercado claros; e demasiados novos participantes e/ou saídas rápidas para acompanhar. Dada esta dificuldade, torna-se mais fácil investir num ETF de IA que analisa as ações que o incorpora e garante um investimento em IA.

Segundo Isabelle Lee na revista *Bloomberg*¹⁰, em termos de perspetivas futuras, os ETFs que acompanham empresas ligadas à IA podem ver os seus ativos triplicar para 35 mil milhões de dólares até 2030, segundo um relatório da *Bloomberg Intelligence*. O número deste tipo de ETFs pode também ascender a mais de 150 a nível mundial, contra os atuais 56. Ademais, a China prevê que pode ser o maior destino dos fundos graças ao esforço robusto de IA do país, apesar de ter apenas três ETFs centrados na robótica com cerca de 67 milhões de dólares em ativos. Por outro lado, constataram que os ETFs que rastreiam empresas de IA superaram os fundos movidos a IA. O *AI Powered Equity ETF* (AIEQ) de 105 milhões de dólares subiu cerca de 2% em 2023, este ativo utiliza um modelo quantitativo executado na plataforma *Watson da IBM Corporate* para examinar milhares de empresas americanas. Isso empalidece em comparação com uma subida de cerca de 8% do S&P 500. Os analistas da *Boomberg Intelligence* afirmam que uma razão potencial pode ser a diferença na ponderação das empresas, a Nvidia, por exemplo, registou um retorno de 160% até à data, enquanto a Microsoft Corp. e a Alphabet Inc registaram ganhos superiores a 30%.

¹⁰<https://www.bloomberg.com/news/articles/2023-05-25/assets-in-ai-etfs-to-triple-by-2030-with-china-in-the-lead?leadSource=uverify%20wall> acedido em 29 de dezembro de 2023

3. METODOLOGIA E DADOS

No primeiro subcapítulo é introduzido o método DEA, inicialmente de forma geral para permitir um melhor entendimento da metodologia e de seguida num contexto financeiro. No segundo subcapítulo é detalhado o método *Value-Based* DEA, implementado para avaliar a eficiência das unidades de decisão (DMUs), com informação imprecisa, com o propósito de identificar quais as DMUs eficientes, atendendo às preferências de um hipotético decisor/investidor. Por fim, são descritos os dados, o processo de seleção dos mesmos, e ainda a explicação das variáveis.

3.1. DEA

A metodologia DEA (Análise Envoltória de dados, em inglês: *Data Envelopment Analysis*) é uma abordagem fundamentada na lógica da programação linear, utilizada em pesquisas operacionais e económicas para avaliar a eficiência relativa de unidades de decisão (Boussofiane et al., 1991). A aplicação desta técnica resulta na conversão de múltiplos *inputs* (recursos) e *outputs* (resultados) numa única medida de eficiência, determinada pela razão da soma ponderada dos *outputs* pela soma ponderada dos *inputs* (Huang et al., 2015).

Os princípios desta metodologia foram baseados nos estudos de Farrell (1957) sobre técnicas de avaliação de produtividade, em que reconhecia a importância de desenvolver indicadores de eficiência global, em oposição à mera produtividade de fatores, e assim, enfatizou a necessidade de avaliar a eficiência resultante da combinação de vários *inputs*. E assim surgiu o primeiro modelo que considerou os rendimentos constantes à escala (CRS - *Constant Returns to Scale*), desenvolvido por Charnes et al. (1978). Esta iniciativa foi impulsionada pela avaliação de programas educacionais destinados a estudantes desfavorecidos em escolas públicas nos Estados Unidos. A característica fundamental deste modelo (geralmente designado na literatura científica por modelo CCR ou *Engineering Ratio*) é, para cada DMU existe um “consumo” de múltiplos *inputs* e a “produção” de múltiplos *outputs*, sendo estes reduzidos a um único valor de *input* virtual e a um único valor de *output* virtual, atribuindo assim um peso a cada *input* e *output*. Assim, a razão entre o *output* virtual e o *input* virtual fornece uma medida de eficiência, que é a função de um conjunto de multiplicadores que constituem as variáveis de um modelo de programação linear fracionária.

Posteriormente, e de forma a tratar os rendimentos variáveis à escala (VRS - *Variable Returns to Scale*), houve uma extensão do modelo CCR, proposta por Banker et al. (1984), designada como modelo BCC, onde foi introduzida uma restrição para assegurar que cada DMU em análise será comparada com uma combinação convexa das demais DMUs.

Da mesma forma, foi elaborada uma extensão ao modelo BCC que é o modelo DEA aditivo, proposto por Charnes et al. (1985), que para além de considerar que os rendimentos possam ser variáveis à escala, não requer uma escolha entre modelo orientado a *inputs* e modelo orientado a *outputs*.

A principal diferença entre o modelo DEA aditivo e os modelos orientados (CCR e BCC), reside no facto que estes últimos utilizam um mecanismo de projeção em duas etapas. Nos modelos orientados, inicialmente, todos os fatores são ajustados proporcionalmente até atingirem a superfície envolvente e de seguida são calculadas as folgas que indicam a posição projetada na fronteira eficiente. Pelo contrário, o modelo DEA aditivo utiliza apenas a segunda etapa. Assim, o valor obtido na primeira etapa dos modelos orientados oferece uma medida de ineficiência variando de 0 a 1, para as DMUs ineficientes, dependendo da orientação adotada e o modelo DEA aditivo é desprovido de tal medida.

O objetivo fundamental desta metodologia, através dos diversos modelos, é comparar os *inputs* e *outputs* de todas as DMUs determinando uma fronteira eficiente (ou superfície envolvente) de desempenho máximo (Ali et al., 1995), comparando a eficiência das DMUs face a essa fronteira. Assim, para os modelos orientados é possível constatar que a DMU em avaliação será eficiente se, comparativamente às demais, tiver maior produção para as quantidades fixas de recursos (orientação a *outputs*) e/ou utilizar menos recursos para gerar uma quantidade fixa de produtos (orientação a *inputs*). Deste modo, permitem a identificação de unidades de referência (*benchmarks*) cujos níveis de eficiência servem como referência para as restantes unidades envolvidas pela fronteira de eficiência. A fase crucial deste processo reside na seleção dos fatores de *input* e *output* que melhor representam a avaliação das unidades de decisão. Estes fatores devem abranger todos os recursos utilizados e produtos gerados, considerando o ambiente específico em que cada unidade opera de acordo com a perspetiva de avaliação.

3.1.1. DEA num contexto financeiro

Na literatura financeira, esta abordagem tem-se destacado uma vez que proporciona ao investidor algumas informações adicionais sobre os principais fatores determinantes de eficiência ou ineficiência, utilizando variáveis previamente selecionadas numa análise de *benchmarking*, com a qual o gestor pode avaliar as alterações necessárias para que as DMUs se tornem eficientes em termos competitivos.

Ao ser aplicada a fundos de investimento, a DEA apresenta múltiplos benefícios em relação às técnicas paramétricas tradicionais dado que a análise de regressão se aproxima da eficiência dos fundos em avaliação relativamente ao desempenho médio. Esta metodologia é adequada para avaliar a *performance* relativa dos fundos, possibilitando a comparação da eficiência de um fundo com os de melhor desempenho. Como ferramenta de avaliação do desempenho, a DEA fornece informação que inclui uma pontuação de eficiência para cada fundo, dando a conhecer os de melhor desempenho (Tsolas & Charles, 2015).

Para além disso, esta ferramenta matemática não necessita de qualquer modelo teórico de referência, uma vez que a eficiência de cada fundo (DMU) é medida em relação a um conjunto de fundos dentro da mesma categoria. Ademais, permite considerar os custos de transação, visto que é um modelo flexível e pode considerar em simultâneo os custos de transação (*inputs*) e retornos (*outputs*) (Murthi et al., 1997).

Na Tabela 1 apresentam-se alguns estudos que utilizaram a metodologia DEA no âmbito das finanças, especialmente na avaliação do desempenho de instrumentos financeiros.

Tabela 1: Estudos com base em DEA

Autores	Ano	Objetivo	Modelo DEA	Inputs	Outputs
Murthi et al.	1997	Avaliar a eficiência dos fundos mútuos	CCR	Desvio padrão, <i>Expense ratio</i> , <i>Turnover</i> e <i>Loads</i>	<i>Return</i>
Basso & Funari	2003	Avaliar o desempenho dos fundos éticos	CCR	Desvio padrão, <i>β-coefficient</i>	<i>Expected Return</i>
Prasanna	2012	Avaliar o desempenho de ETFs temáticos	CCR	Desvio padrão, <i>maximum drawdown</i> e <i>downside risk</i>	Lucro e retorno
Tsolas & Charles	2015	Avaliar o desempenho de ETFs verdes	RAM e RAM-BCC	<i>Price of Cashflow</i>	<i>Sharpe ratio</i> e Alfa Jensen

				<i>Price-to-Book ratio</i>	
Huang et al.	2015	Comparar o desempenho do ETF Taiwan Excel50 e outros 3 fundos mútuos de referência	DEA-MODM	Beta e <i>downside risk</i>	<i>Return rate e Sharpe ratio</i>
Choi & Min	2017	Avaliar a eficiência de um índice, 8 ETF's e 200 ações	RDM	<i>Standard Deviation</i> e Beta	Return
Tsolas	2019	Analisar o desempenho dos ETFs de serviços públicos	GRA-DEA	<i>Portofolio price/cash flow, portfolio price/book e total expense ratio</i>	<i>Sharpe ration e Jensen's alpha</i>
Tsolas	2022	Classificar os ETFs mais eficientes de forma a encontrar os que têm melhor utilidade	RAM	Beta, <i>Tracking error, Expense ratio</i> e total do ativo	Retorno médio anual
Henriques et al.	2022	Analisar a <i>performance</i> de ETFs do setor da energia e selecionar as possíveis carteiras eficientes	WRDDM, RDM+	β -coefficient e standard deviation	<i>Jensen's Alpha, Sharpe Index, mean annual return e trailing total return</i>
Proença et al.	2023	Analisar a eficiência dos fundos dos setores tecnológicos, da saúde e do consumo cíclico com base nos rankings da U.S. News & World Report	Value-based DEA	Beta, <i>Standard Deviation, R-squared e Variance</i>	<i>Sharpe Ratio e Alpha</i>
Henriques et al.	2023	Avaliar o desempenho dos ETFs europeus e americanos	BP-SBM	<i>Downside risk e expense ratio</i>	<i>Monthly return e upside deviation</i>
Valadkhani & Moradi-Motlagh	2023	Analisar a eficiência de 110 ETFs americanos e os seus fatores de influência	WRDDM	<i>Average standard deviation</i>	<i>Average net return</i>

Através desta tabela, podemos observar que a metodologia DEA é implementada para analisar a eficiência de vários ETFs. No entanto, apesar das vantagens da utilização desta metodologia estarem bem fundamentadas na literatura, não existem estudos científicos sobre a análise do desempenho de ETFs de IA, tratando-se de um *gap* que se pretende superar através desta investigação.

Murthi et al. (1997) foram os primeiros a implementar a metodologia DEA para investigar a eficiência de portfólios de fundos mútuos e estabeleceram uma comparação dos resultados com o Alfa de Jensen e o índice de Sharpe. A amostra é constituída por 731

fundos mútuos do terceiro trimestre de 1993, da *Morningstar*. Através deste estudo, os autores demonstraram que a eficiência dos fundos mútuos não está correlacionada com os custos de transação e que fundos de maior dimensão são mais eficientes em algumas categorias.

Prasanna (2012) investigou as características e o padrão de crescimento de 82 ETFs lançados e transacionados na bolsa de valores indiana e assim avaliou o desempenho utilizando a metodologia DEA. Os resultados demonstraram que, em média, os ETFs registraram um crescimento anual de 37% de 2006 a 2011, tendo ainda concluído que estes ETFs superaram sistematicamente o índice de mercado e geraram rendibilidades excedentárias em 3% por ano em relação ao CNX NIFTY, que é o índice de referência do mercado acionista indiano. Os ETFs de ouro proporcionaram rendimentos excedentários de 13% em relação a esse mesmo índice. Verificou ainda através do método implementado, que os fundos eficientes têm rácios de Sharpe mais elevados.

A investigação elaborada por Tsolas & Charles (2015) avalia o desempenho de uma amostra de ETFs verdes com base no pressuposto de que existem ações de valor no mercado de ações verdes e de que os potenciais investidores preferem ETFs que dão ênfase a ações com valor. Os autores utilizaram dois tipos de métricas da metodologia DEA, o primeiro baseia-se em modelos de DEA com folgas, nomeadamente o modelo RAM-BCC e o segundo baseia-se num conjunto comum de pesos da RAM. Os resultados obtidos revelam que apenas quatro ou cinco dos dezasseis fundos da amostra, dependendo do modelo utilizado, podem ter valor para os investidores.

Choi & Min (2017) avaliaram 8 ETFs e o seu índice de referência, o KOSPI 200, com base no rácio de Sharpe e no rácio de Treynor. Os resultados permitiram demonstrar empiricamente que os ETFs são os instrumentos de investimento mais eficientes no que concerne à nova medida de desempenho concebida com base na metodologia DEA, assim, as carteiras bem diversificadas melhoram a eficiência ajustando as variáveis.

Tsolas (2019) propõe uma abordagem eficaz que integra a análise *grey relational analysis* (GRA) e a DEA, a fim de selecionar os melhores ETFs de serviços públicos de 2008 a 2010. Os resultados demonstraram que os principais ETFs identificados pela abordagem GRA-DEA também são os mais eficientes no modelo DEA. Assim, a abordagem GRA-DEA proposta pelos autores é superior à DEA convencional no que diz respeito à

classificação do fundo, logo parece um método eficaz como ferramenta na escolha dos ETFs eficientes.

Henriques et al. (2022) propõem uma abordagem em duas etapas para construir modelos de carteiras. Inicialmente é necessário aplicar a metodologia DEA para identificar os ativos que atingem um melhor desempenho financeiro e de seguida há uma construção de modelos de carteiras multiobjectivo intervalares para obter uma composição ótima e eficiente. Os resultados obtidos, considerando ETFs no setor energético americano, demonstram que os ETFs relacionados com a energia nuclear são os mais frequentemente vistos como eficientes. Para além disso, as carteiras eficientes não contêm ETFs relacionados com o setor das energias renováveis.

Recentemente, Proença et al. (2023) analisaram a eficiência dos fundos dos setores tecnológico, da saúde e do consumo cíclico com base nos rankings da *U.S. News & World Report* no período de 2016 a 2020. Os resultados obtidos demonstraram que os fundos mais eficientes são do setor da tecnologia e da saúde. Os fundos de saúde são vistos como de baixo risco e dificilmente consideram os fatores de rendibilidade em todos os períodos analisados, o que é muitas vezes considerado como *benchmark* para fundos ineficientes. Por outro lado, no setor tecnológico, o Beta e o Alfa são geralmente os indicadores com maior peso na eficiência dos fundos, mostrando que estes fundos superam o mercado em termos de rendibilidade e que são menos arriscados que o *benchmark*.

Valadkhani & Moradi-Motlagh (2023), avaliaram o desempenho de 110 ETFs americanos adotando um modelo distância direcional de fronteira, atribuindo pesos diferentes a três medidas de rendibilidade líquida e de risco nos últimos três, cinco e dez anos. Os resultados demonstram que os ETFs com melhor desempenho se situam predominantemente nos setores da tecnologia, dos dispositivos médicos e dos semicondutores, beneficiando de ganhos relativamente mais elevados e de perdas mais baixas.

No presente estudo será utilizada a metodologia *Value-Based* DEA a fim de avaliar a eficiência dos ETFs de IA, considerando *inputs* e *outputs* transformados em escalas de valor por via de funções de valor não lineares.

3.2. Value-Based DEA

O método *Value-Based DEA*, desenvolvido por Gouveia et al. (2008) é uma variante do modelo DEA aditivo com projeções orientadas (Ali et al., 1995), que incorpora as preferências do decisor utilizando o conceito da MCDA com informação imprecisa (Dias & Clímaco, 2000).

Esta metodologia foi inicialmente proposta para superar algumas limitações do modelo DEA aditivo, tais como, o problema de escalas ao projetar as DMUs ineficientes na fronteira eficiente, visto que depende da escala utilizada para medir cada *input* ou *output*. Outra das limitações ultrapassada é a de lidar com desempenhos negativos em alguns fatores (*input* ou *output*). Além disso, no modelo DEA aditivo o resultado da otimização da função objetivo é uma medida bastante pessimista, uma vez que é a distância L_1 que está a ser maximizada, e esta medida de eficiência carece de uma interpretação intuitiva.

No *Value-Based DEA*, os autores consideram que as DMUs assumem o papel de alternativas de um modelo de avaliação multicritério, sendo cada uma avaliada por vários critérios, ou seja, cada fator (*input* ou *output*) é transformado em funções de valor parcial, cada uma delas definida no intervalo $[0,1]$, geralmente refletindo as preferências do decisor. O pior desempenho em cada fator possui o valor 0, e o melhor o valor de 1, resultando na maximização de todos os fatores. Subsequentemente, as funções de valor aditivas são aplicadas para agregar as funções de valor parcial associadas a cada fator, com base no *Multiple Attribute Value Theory* (MAVT) (Keeney & Raiffa, 1976). Assim, supera-se o problema de escalas, uma vez que todas as medidas de *input* e *output* são traduzidas em valores. Para além disso, os pesos usados na agregação das funções de valor parciais assumem um significado específico, como os coeficientes das funções de valor que definem a direção da projeção. Os coeficientes de ponderação são valores escolhidos por cada DMU, a fim de se tornar a melhor DMU (se possível) ou então no sentido de minimizar a diferença de valor para a melhor DMU, ao invés de ser fixado previamente como no modelo de Ali et al. (1995).

No desenvolvimento desta metodologia foi utilizado a regra “*min-max regret*” que é fundamentada no conceito de perda de valor ao escolher uma alternativa face a outra, ou seja, pretende-se determinar para cada alternativa o potencial “arrependimento” associado à sua escolha, observando quão melhor poderia ser outra qualquer alternativa. Para um

dado vetor de coeficientes de ponderação, a perda de valor de escolher a alternativa a_k em vez de outra alternativa $a_j \neq a_k$ é dada por (1):

$$R_{max}(a_k, a_j) = \max_{j \neq k} V(a_j) - V(a_k) \quad (1)$$

A perda de valor máxima associada a uma determinada alternativa a_k , $R_{max}(a_k)$, é dada pela perda máxima de oportunidade associada à escolha dessa alternativa (2):

$$R_{max}(a_k) = \max_w \left\{ \left(\max_{j \neq k} V(a_j) \right) - V(a_k) \right\} \quad (2)$$

A decisão ótima *min-max regret* permite minimizar a perda no pior caso relativamente a possíveis realizações do vetor de coeficientes w , i.e., alternativas com $R_{max}(a_k)$, mínimo são preferidas. Assim, a medida de eficiência atribuída a cada DMU revela um significado intuitivo: corresponde a uma medida "*min-max regret*" (minimizar o máximo arrependimento).

Considerando que o conjunto de n DMUs a avaliar é: $\{DMU_j: j = 1, \dots, n\}$. Cada DMU_j é analisada de acordo com m fatores (critérios) a serem minimizados (*inputs*) e p fatores (critérios) a serem maximizados (*outputs*). Assim, a DMU_j é representada por um vetor m -dimensional de *inputs* x_{ij} ($i = 1, \dots, m$) e um vetor p -dimensional de *outputs* y_{rj} ($r = 1, \dots, p$). Posteriormente, os fatores são convertidos em funções de valor parciais $\{v_c(DMU_j), c = 1, \dots, q, \text{ with } q = m + p, j = 1, \dots, n\}$ e agregados numa função de valor global, atendendo ao modelo aditivo MAVT, $V(DMU_j) = \sum_{c=1}^q w_c v_c(DMU_j)$, onde $w_c \geq 0$, $\forall c = 1, \dots, q$ e $\sum_{c=1}^q w_c = 1$ (por convenção). Os coeficientes de escala $w_1, \dots, w_q$ são os pesos das funções de valor e refletem as compensações (*trade-offs*) de valor do decisor. Cada DMU é livre de escolher os seus pesos de forma a minimizar a distância até a melhor DMU, dentro do conceito da regra de "*min-max regret*".

Após todos os fatores terem sido convertidos numa escala de valor, o método *Value-Based DEA* divide-se em duas fases:

Fase 1: Calcular a medida de eficiência, d_k^* , para cada DMU_k , $k = 1, \dots, n$, e o vetor de ponderação correspondente w_k^* resolvendo o problema linear (3).

Fase 2: Se $d_k^* \geq 0$, então resolve o problema do "aditivo ponderado" (4), usando o vetor de ponderação ótimo resultante da Fase 1, w_k^* , e determina o correspondente ponto projetado da DMU_k em análise.

Os autores Gouveia et al. (2013) incluíram o conceito de super-eficiência (Andersen & Petersen, 1993) na formulação (3) para acomodar a discriminação de DMUs eficientes:

$$\begin{aligned} \min_{d_k, w} d_k, \\ s. t. \sum_{c=1}^q w_c v_c(DMU_j) - \sum_{c=1}^q w_c v_c(DMU_k) \leq d_k, j = 1, \dots, n; j \neq k \\ \sum_{c=1}^q w_c = 1 \\ w_c \geq 0, \forall c = 1, \dots, q \end{aligned} \quad (3)$$

O valor ótimo d_k^* é a distância definida pela diferença de valor para a melhor de todas as DMUs (observe que a melhor DMU também dependerá de w), excluindo-se do conjunto de referência. Se d_k^* for negativa, então a DMU_k em análise é eficiente, sendo possível classificar essas unidades eficientes levando em consideração que quanto mais negativo for o valor d_k^* , mais eficiente será a DMU.

Se a DMU tiver uma pontuação não negativa, d_k^* , então a DMU_k é ineficiente e um alvo pode ser calculado através da resolução do problema linear (4):

$$\begin{aligned} \min_{\lambda, s} z_k = - \sum_{c=1}^q w_c^* s_c \\ s. t. \sum_{j=1, j \neq k}^n \lambda_j v_c(DMU_j) - s_c = v_c(DMU_k) \\ \sum_{j=1, j \neq k}^n \lambda_j = 1 \\ \lambda_j, s_c \geq 0, j = 1, \dots, k-1, k+1, \dots, n; c = 1, \dots, q \end{aligned} \quad (4)$$

As variáveis $\lambda_1, \dots, \lambda_n$ definem uma combinação convexa das n DMUs. As DMUs eficientes que definem a combinação convexa com $\lambda_j > 0$ são designadas de "pares" da DMU_k em análise. Esta combinação convexa corresponde a um ponto na fronteira

eficiente, melhor do que a DMU_k com uma diferença de valor de s_c (folga) em cada critério c . O valor das folgas em cada fator define a distância L_1 que os ineficientes têm de percorrer para alcançarem a fronteira de eficiência e igualarem o seu *benchmark* ou atingirem o seu alvo (combinação linear de fundos eficientes).

3.3. Dados

3.3.1. Descrição dos dados

De forma a atingir o objetivo desta investigação, iremos efetuar uma avaliação do desempenho dos ETFs de IA, através de uma amostra composta por 22 ETFs, retirada do site etfdb.com¹¹. Inicialmente, a amostra era composta por 53 ETFs de IA, contudo, dada a falta de dados para o período em estudo, esta amostra foi restringida. O período da amostra situa-se nos períodos de 1 ano (2022), 3 anos (2020 a 2022) e 5 anos (2018 a 2022). Relativamente às variáveis a utilizar, estas são: beta, desvio padrão, alfa de Jensen, *Tracking Error* e *Sharpe ratio*. Os valores das mesmas foram extraídos através do site *financial times* e *Datastream*.

Os ETFs de IA são fundos que satisfazem pelo menos um dos três critérios seguintes: investem especificamente em empresas envolvidas no desenvolvimento de novos produtos ou serviços e em melhorias tecnológicas na investigação científica relacionada com a IA; ou têm pelo menos 25% da exposição da carteira a empresas que gastam grandes quantias em despesas de investigação e desenvolvimento (I&D) de IA; ou utilizam metodologias de IA para seleccionar títulos individuais para inclusão no fundo.

Na Tabela 2 são apresentados os dados relativos aos ETFs envolvidos no estudo, assim como o seu respetivo *ticker*, categoria, data de criação, tipo e domicílio.

Tabela 2: Dados relativos aos ETFs

ID	<i>Ticker</i>	Nome	Categoria	Data de criação	Tipo	Domicílio
1	IYW	iShares U.S. Technology ETF	<i>Equity</i>	15/05/2000	Science and Technology funds	USA

¹¹ <https://etfdb.com/screener/> acedido a 4 de Outubro de 2023

2	FTEC	Fidelity MSCI Information Technology Index ETF	Equity	21/10/2013	Science and Technology funds	USA
3	FDN	First Trust Dow Jones Internet Index Fund	Equity	19/06/2006	Science and Technology funds	USA
4	IXN	iShares Global Tech ETF	Equity	12/11/2001	Science and Technology funds	USA
5	IGM	iShares Expanded Tech Sector ETF	Equity	13/03/2001	Science and Technology funds	USA
6	XT	iShares Exponential Technologies ETF	Equity	19/03/2015	Science and Technology funds	USA
7	BOTZ	Global X Robotics & Artificial Intelligence ETF	Equity	12/09/2016	Science and Technology funds	USA
8	ARKQ	ARK Autonomous Technology & Robotics ETF	Equity	30/09/2014	Industrials	USA
9	DRIV	Global X Autonomous & Electric Vehicles ETF	Equity	13/03/2018	Science and Technology funds	USA
10	AIQ	Global X Artificial Intelligence & Technology ETF	Equity	11/05/2018	Science and Technology funds	USA
11	PNQI	Invesco NASDAQ Internet ETF	Equity	12/06/2008	Science and Technology funds	USA
12	IRBO	iShares Robotics and Artificial Intelligence Multisector ETF	Equity	26/06/2018	Science and Technology funds	USA
13	ROBT	First Trust Nasdaq Artificial Intelligence & Robotics ETF	Equity	21/02/2018	Science and Technology funds	USA
14	AIVL	WisdomTree U.S. AI Enhanced Value Fund	Equity	16/06/2006	Multi-cap Value	USA
15	QTU M	Defiance Quantum ETF	Equity	14/09/2018	Science and Technology funds	USA
16	IETC	iShares U.S. Tech Independence Focused ETF	Equity	21/03/2018	Science and Technology funds	USA
17	AIEQ	AI Powered Equity ETF	Equity	18/10/2017	Multi-cap Value	USA
18	DTEC	ALPS Disruptive Technologies ETF	Equity	28/12/2017	Science and Technology funds	USA
19	LOUP	Innovator Deepwater Frontier Tech ETF	Equity	25/07/2018	Science and Technology funds	USA
20	UBOT	Direxion Daily Robotics, Artificial Intelligence & Automation Index Bull 2X Shares	Equity	19/03/2018	Equity Leverage	USA
21	IEDI	iShares U.S. Consumer Focused ETF	Equity	21/03/2018	Costumer Services	USA
22	KOIN	Capital Link Global Fintech Leaders ETF	Equity	30/01/2018	Science and Technology funds	USA

Fonte: Datastream (2023)

3.3.2. Seleção de *inputs* e *outputs*

A seleção dos fatores (*inputs* e *outputs*) a utilizar na metodologia *Value-Based* DEA foi realizada de acordo com a literatura existente (Tabela 1). Assim, os *inputs* são: o Beta, o *Tracking error* e o Desvio Padrão; e os *outputs* são: o Alfa de Jensen e o *Sharpe ratio*.

No que diz respeito ao Beta, cujo cálculo é efetuado segundo a fórmula (5), também utilizado por Basso & Funari (2014), Choi & Min (2017), Huang et al., (2015) e Proença et al. (2023) como *input*, é uma medida de risco que indica de que forma é que o desempenho de um portfólio está relacionado ao desempenho de um índice de referência.

$$Beta = \frac{Covariância\ entre\ os\ retornos\ do\ ativo\ e\ os\ retornos\ do\ mercado}{Variância\ dos\ retornos\ do\ mercado} \quad (5)$$

Esta variável é utilizada para avaliar o risco sistemático de um investimento, ou seja, a percentagem de risco que não pode ser eliminada através da diversificação. Além disso, permite avaliar de que forma é que um portfólio reage em relação ao mercado e assim ajustar o risco consoante os objetivos pretendidos. Um Beta igual a 1 indica que o portfólio tenderá a mover-se paralelamente ao mercado. Um Beta superior a 1 indica que o portfólio é mais volátil do que o mercado, o que significa que se irá mover mais do que o mercado. Pelo contrário, quando o Beta é menor que 1, indica que o portfólio é menos volátil, ou seja, tem menos risco, uma vez que é menos sensível às flutuações do mercado.

A variável *Tracking Error* (erro de rastreamento), obtida pela fórmula (6), usada por Tsolas (2022) como *input*, é uma métrica que avalia o desempenho de um fundo de investimento ou carteira em relação ao seu índice de referência (*benchmark*). Permite medir a volatilidade da diferença entre o retorno do fundo e o retorno do *benchmark* ao longo de um período de tempo.

$$Tracking\ error = \sqrt{\frac{\sum (Retorno\ do\ fundo - Retorno\ do\ Benchmark)^2}{(n - 1)}} \quad (6)$$

Esta medida analisa o quão bem um fundo está a rastrear o seu índice de referência. Assim, quanto menor o *Tracking Error*, mais próximo estará o desempenho do fundo em relação ao desempenho do *benchmark*, o que indica que o fundo está a cumprir o seu objetivo. Por outro lado, um *Tracking Error* elevado significa que o fundo está a afastar-se do desempenho do índice de referência.

O Desvio Padrão, calculado através da fórmula (7), foi usado por Basso & Funari (2014), Choi & Min (2017), Henriques et al. (2022b), Murthi et al. (1997), Prasanna (2012), Proença et al. (2023) e Valadkhani & Moradi-Motlagh (2023) como *input*.

$$\text{Desvio padrão} = \sqrt{\frac{\sum (\text{Retorno individual} - \text{Média dos retornos})^2}{(n - 1)}} \quad (7)$$

Esta medida estatística quantifica a volatilidade ou o risco do portfólio. Esta variável indica em que medida é que os retornos do portfólio tendem a desviar-se da média histórica dos retornos. Quanto maior o desvio padrão, maior a volatilidade do portfólio, o que implica um maior risco.

Em relação ao Alfa de Jensen, devolvido como resultado da fórmula (8), e utilizado no modelo de Henriques et al. (2022b), Proença et al. (2023), Tsolas (2019) e Tsolas & Charles (2015) como *output*, determina o retorno anormal de um portfólio em relação ao retorno teórico esperado, tendo em conta o risco sistemático (risco não diversificável) associado ao mercado como um todo.

$$\text{Alfa de Jensen} = [R(i) - R(f) + \beta(R(m) - R(f))] \quad (8)$$

O Alfa de Jensen tenta explicar se um investimento teve um desempenho melhor ou pior do que o seu valor Beta sugerido. Se Alfa de Jensen for positivo, indica que o investimento teve um desempenho superior ao esperado. Pelo contrário, um Alfa de Jensen negativo indica que o investimento teve um desempenho inferior ao esperado. Um Alfa de Jensen igual a zero indica que o investimento obteve um desempenho igual ao esperado.

Relativamente ao índice de Sharpe, obtido por via da fórmula (9) e escolhido por Henriques et al. (2022b), Huang et al. (2015), Proença et al. (2023), Tsolas (2019) e Tsolas & Charles (2015) como *output*, é uma medida matemática que devolve o prémio de risco de um portfólio por unidade de risco total (Desvio Padrão).

$$\text{Sharpe Ratio} = \frac{\text{Retorno do investimento} - \text{Taxa livre de risco}}{\text{Desvio padrão do investimento}} \quad (9)$$

Quanto maior o índice de Sharpe, melhor é considerado o desempenho ajustado ao risco do investimento. Isso ocorre porque um índice de Sharpe mais alto indica que o investimento gerou retornos mais altos em relação ao risco assumido. Por outro lado, um índice de Sharpe mais baixo indica que o investimento teve um desempenho pior em relação ao risco.

A Tabela 3 resume o modelo, assim como os fatores (*inputs* e *outputs*) selecionados para a avaliação do desempenho dos ETFs.

Tabela 3: *Inputs e Outputs*

Fatores a minimizar (<i>inputs</i>)	Fatores a maximizar (<i>outputs</i>)
Beta	Alfa de Jensen
Desvio Padrão	Sharpe Ratio
Tracking Error	

O método *Value-Based* DEA converte os desempenhos originais dos fatores em escalas de valor, utilizando funções de valor parciais. Considerando que o valor p_{cj} indica o desempenho de uma DMU j no fator c , os desempenhos dos *inputs* e *outputs* são convertidos em valores por via de uma transformação linear, uma vez que não existe um decisor real que as possa definir. Os desempenhos de cada DMU são calculados através da fórmula (10):

$$v_c(DMU_j) = \begin{cases} \frac{p_{cj} - M_c^L}{M_c^U - M_c^L}, & \text{se o factor } c \text{ for um output} \\ \frac{M_c^U - p_{cj}}{M_c^U - M_c^L}, & \text{se o factor } c \text{ for um input} \end{cases}, j = 1, \dots, n; c = 1, \dots, q \quad (10)$$

Em que são considerados os valores $M_c^L < \min\{p_{cj}, j = 1, \dots, n\}$ e $M_c^U > \max\{p_{cj}, j = 1, \dots, n\}$, para cada $c=1, \dots, q$.

Os apêndices A.1, A.2 e A.3 exibem os dados relativos aos fatores em avaliação para cada ETF, na escada de desempenho original e na escala de valor.

Em relação às estatísticas descritivas, a média dos *inputs* é superior em todos os períodos. No que diz respeito aos valores máximos dos fatores, estes decrescem da amostra de 1 ano para a de 3 anos e posteriormente da amostra de 3 anos para a de 5 anos voltam a crescer.

4. ANÁLISE E DISCUSSÃO DE RESULTADOS

Neste capítulo será apresentada a análise dos resultados obtidos através da metodologia *Value-Based* DEA, para os três períodos de 1, 3 e 5 anos. Desta análise resulta a classificação dos ETFs no que se refere à eficiência, bem como a identificação dos fatores que a determinam. Podem ainda ser identificados os *gaps* de ineficiência e eventuais propostas de melhoria para cada ETF ineficiente, atendendo aos *benchmarks* por eles escolhidos.

Tabela 4: Scores de eficiência dos ETFs

ETFs de IA	Modelo		
	d* 1 ano	d* 3 anos	d* 5 anos
1	-0,091	0,011	-0,052
2	0,029	0,010	0,001
3	0,033	-0,008	0,001
4	0,043	0,021	-0,003
5	0,030	0,029	0,010
6	0,084	0,009	-0,001
7	0,009	0,025	-0,003
8	0,102	-0,003	-0,012
9	0,118	0,003	0,005
10	0,041	0,022	0,005
11	0,071	-0,048	0,004
12	0,085	0,015	0,011
13	0,043	0,019	0,007
14	-0,111	-0,132	-0,065
15	0,047	-0,066	-0,001
16	-0,084	0,012	-0,008
17	0,031	0,005	0,013
18	0,050	-0,010	0,005
19	0,085	0,036	0,014
20	0,055	-0,379	-0,406
21	0,081	0,044	0,010
22	-0,068	-0,124	-0,022
Nº de ETFs eficientes	4	8	10

Na Tabela 4 estão as pontuações obtidas por cada ETF nos três períodos. É de notar que, na classificação dos ETFs, quanto menor for o valor de d^* , melhor será o seu desempenho, logo d^* negativos estão associados a DMUs (ETFs) eficientes. Se d^* for igual a 0, a DMU em análise é fracamente eficiente e se d^* tiver um valor positivo então a DMU é ineficiente (Gouveia et al., 2013).

4.1. Resultados para 1 ano (2022)

Tabela 5: Scores e Pesos atribuídos aos fatores dos ETFs eficientes para 1 ano

ETFs eficientes	d^*	1 ano				
		W_{Beta}	W_{DP}	W_{TE}	W_{Alfa}	W_{SR}
1	-0,091	0,042	0,000	0,000	0,958	0,000
14	-0,111	0,000	0,429	0,571	0,000	0,000
16	-0,084	0,900	0,000	0,000	0,000	0,100
22	-0,068	0,000	0,968	0,000	0,000	0,032
Média		0,942	1,397	0,571	0,958	0,132

Na Tabela 5, verifica-se que, considerando um ano, existem apenas 4 ETFs eficientes num total de 22 ETFs. Dois destes quatro ETFs atribuem um maior peso ao Desvio Padrão, assim o gestor está consciente de que a composição de uma carteira com baixo risco vai ao encontro de um determinado perfil de investidor. De salientar que o ETF 22 atribui um peso quase total ao Desvio Padrão o que significa que será de incluir num perfil de investidor avesso ao risco. O fator Alfa, uma medida de desempenho ajustada ao risco, é o que mais contribui para a eficiência do ETF 1. A variável Beta, que determina a sensibilidade de uma carteira face ao seu *benchmark*, é escolhida pelo ETF 16 como o fator de maior importância. Desta forma, o ETF 16 atribui cerca de 90% do seu peso a Beta, o que sugere que o investidor deste fundo arrisca menos do que o mercado. O ETF 14 dá maior ênfase ao fator *Tracking Error*, que permite avaliar em que medida o fundo está a ter melhor desempenho do que o seu *benchmark*. Por último, o fator *Sharpe Ratio* é o menos valorizado pelos ETFs, logo não colabora na eficiência de uma forma mais preponderante.

Globalmente, os ETFs eficientes no curto prazo atribuem muito mais peso aos níveis de risco do que de rendibilidade. Provavelmente por serem ainda mais recentes e estarem sob o escrutínio dos investidores, atentos a notícias e eventos externos acerca de novos produtos lançados a todo o momento o que pode provocar movimentos bruscos dos preços das ações no curto prazo. São fundos cuja natureza é volátil e incerta muito dependente

das empresas e setores que maioritariamente se compõem. Há, no entanto, a possibilidade de crescimento significativo, dada a dinâmica deste setor.

Para reforçar esta leitura, mostra-se a significativa influência das novas tecnologias na composição destes fundos. O ETF 1 é composto por 96,05% de tecnologia, o seu setor é ciências e tecnologia e a sua gestão é passiva. O ETF 16 tem 78,93% de tecnologia, o seu setor é ciências e tecnologia e é gerido de forma ativa. O ETF 22 é composto por 42,80% de tecnologia, o seu setor é ciências e tecnologia e a sua gestão é efetuada de forma ativa. Apenas o ETF 14 tem fraca composição de tecnologia, com apenas 6,07% e não está considerado num setor específico, visto que é muito diversificado sendo a sua gestão igualmente passiva.

Relativamente aos fundos ineficientes, estes demonstram pelo valor médio das *slacks*, que necessitam de reduzir os *inputs* Beta e Desvio Padrão com maior expressão para conseguirem atingir o estatuto de eficientes. No Apêndice C.1 podemos constatar que o fator que carece de menor ajuste é o *output* Alfa de Jensen, isto significa que os ETFs têm valores desta variável muito equiparados aos dos seus pares. Consequentemente, os ETFs escolhidos mais vezes como referências foram o 14 e o 16, ambos escolhidos 14 vezes. Estes ETFs não atribuem o seu peso de forma similar dado que o 14 concede importância aos *inputs* Desvio Padrão e *Tracking Error*, pelo contrário, o ETF 16 distribuiu a sua ponderação pelo *input* Beta e *output* Sharpe Ratio. Contudo, estes fundos apresentam características que os seus pares ambicionam alcançar, reforçando que, no curto prazo, a característica dos ETFs de IA mais valorizada é o risco (Trabelsi Karoui et al., 2024).

4.2. Resultados para 3 anos (2020-2022)

Tabela 6: Scores e Pesos atribuídos aos fatores dos ETFs eficientes para 3 anos

ETFs eficientes	d*	3 anos				
		W_{Beta}	W_{DP}	W_{TE}	W_{Alfa}	W_{SR}
3	-0,008	0,323	0,000	0,459	0,000	0,218
8	-0,003	0,279	0,000	0,466	0,018	0,237
11	-0,048	0,000	0,373	0,627	0,000	0,000
14	-0,132	0,816	0,000	0,000	0,000	0,184
15	-0,066	0,000	0,000	0,000	0,000	1,000
18	-0,010	0,000	0,309	0,496	0,000	0,195
20	-0,379	0,000	0,000	1,000	0,000	0,000
22	-0,124	0,000	0,149	0,404	0,448	0,000
Média		1,418	0,830	3,452	0,465	1,834

Considerando os dados para 3 anos, período que incorpora a crise da pandemia COVID-19, o número de ETFs eficientes duplicou, tendo-se mantido como eficientes dois dos que haviam sido eficientes para um ano (o ETF 14 e o 22). A composição de todos os ETFs é altamente tecnológica, exceto o 14, como verificado para 1 ano, e o ETF 20 cuja composição é maioritariamente industrial. Verifica-se que seis dos oito fundos eficientes atribuem pesos ao *Tracking Error*, sendo que cinco atribuem o seu maior peso a esta variável que analisa o desempenho do fundo em relação ao desempenho do seu *benchmark*. Num período pandémico com desafios únicos no setor tecnológico, os gestores de fundos podem priorizar a gestão do *Tracking Error* para mitigar alguns riscos específicos do setor e proteger os investidores contra potenciais perdas ao mesmo tempo que ajustam as suas estratégias de investimento para absorverem as oportunidades emergentes e responder às novas tendências de consumo. Assim, replicar o *benchmark* poderá ser a forma mais segura de gestão (Buetow & Henderson, 2012). Note-se que o fundo 20 atribui 100% do seu peso a este *input*, o que significa que, para ser eficiente o gestor entende que tem de replicar o seu *benchmark* (no caso, industrial, dada a sua composição) pois sente que também o potencial investidor se sentirá mais confiante dessa forma.

Relativamente aos dois fundos que já tinham sido eficientes no curto prazo, notam-se diferenças significativas nos fatores de influência. Especificamente, o ETF 22, tecnológico, quase que deixa de atribuir peso ao desvio padrão (no curto prazo atribuía um peso de cerca de 97%) para passar a atribuir de forma equilibrada ao *Tracking Error* e a Alfa de Jensen, um *input* e um *output*. Tanto o gestor como o potencial investidor, não recomendam que seja o risco o fator mais relevante no médio e longo prazo, mesmo em período de pandemia. A tecnologia é entendida como algo forte e sustentável no mercado (C. Neves et al., 2024). Este resultado sugere que se os fundos superam o curto prazo, a concorrência e as rápidas mudanças tecnológicas, têm potencial de crescimento privilegiando a rendibilidade. O mesmo não acontece com o ETF 14 que atribui agora mais de 80% de peso ao Beta, o que pode ser justificado pela sua composição muito mais diversificada e com pouco peso na tecnologia, tornando-o mais volátil face ao mercado, nesta altura de grandes flutuações nas economias. O gestor segue aquilo que é a tendência do investidor em períodos *bear market*, mais defensivos e conservadores, procurando proteger o seu capital e evitar perdas significativas.

De salientar ainda o peso de 100% atribuído pelo ETF 15 ao *Sharpe Ratio*, uma medida de rentabilidade utilizada para comparar o desempenho dos gestores de investimento através do ajustamento do risco. No médio e longo prazo, os ETFs de alta tecnologia, como é o caso do ETF 15, que apresentam um *Sharpe Ratio* mais alto, são geralmente percebidos como melhores opções, uma vez que oferecem retornos mais consistentes para o nível de risco que apresentam.

Os resultados são consistentes e mostram claramente que, ao fim de algum tempo no mercado, os ETFs tecnológicos representam muito potencial de rendimento, e que isso pode ser uma característica mais atendida pelo investidor do que propriamente o risco.

No que concerne à escolha do *benchmark*, os ETFs mais frequentemente escolhidos pelos fundos ineficientes foram o ETF 14 e o ETF 22, como podemos constatar no Apêndice C.2.

Atendendo às sugestões de melhoria derivadas da metodologia e destacadas pelos valores das *slacks*, observa-se que os fundos ineficientes precisam predominantemente de reduzir a variável Beta e aumentar o Alfa de Jensen, corroborando os resultados, já que no médio e longo prazo, é fundamental levar em consideração tanto o retorno quanto o risco e não apenas o risco como acontecia no curto prazo. Contudo, é de notar que estes ajustes são menores em comparação ao primeiro ano, sendo assim, há uma melhoria na distância até à fronteira de eficiência à medida que o tempo se prolonga.

4.3. Resultados para 5 anos (2018-2022)

Tabela 7: Scores e Pesos atribuídos aos fatores dos ETFs eficientes para 5 anos

ETFs eficientes	d*	5 anos				
		W_{Beta}	W_{DP}	W_{TE}	W_{Alfa}	W_{SR}
1	-0,052	0,000	0,000	0,000	0,000	1,000
4	-0,003	0,000	0,148	0,493	0,000	0,359
6	-0,001	0,000	0,012	0,500	0,380	0,108
7	-0,003	0,000	0,000	0,529	0,471	0,000
8	-0,012	0,000	0,000	0,467	0,533	0,000
14	-0,065	0,753	0,000	0,247	0,000	0,000
15	-0,001	0,000	0,062	0,417	0,520	0,000
16	-0,008	0,908	0,000	0,000	0,000	0,092
20	-0,406	0,000	0,000	1,000	0,000	0,000
22	-0,022	0,000	0,754	0,101	0,146	0,000
Média		1,661	0,976	3,755	2,049	1,559

Numa perspectiva mais enquadrada a longo prazo, existem 10 ETFs eficientes, mais 2 ETFs eficientes quando comparado com os dados relativos a 3 anos.

Neste período, verifica-se uma maior dispersão nos pesos atribuídos a cada fator, mas globalmente denota-se que são o *Tracking Error* e o Alfa de Jensen os mais ponderados. O gestor procura alguma estabilidade na gestão eficaz do fundo em replicar os retornos do *benchmark* ao mesmo tempo que procura superar algumas das expectativas de mercado. Destaca-se que quatro ETFs atribuem maior ênfase ao *Tracking Error*, sendo que o ETF mais eficiente, o ETF 20, atribui 100% do peso a este fator, tal como já acontecia no médio e longo prazo. Este resultado sugere que o gestor destes fundos dá ênfase à volatilidade da diferença entre o retorno proporcionado pelo ETF em relação ao retorno do índice de referência. Assim, permite avaliar o quão bem o ETF está a seguir o seu *benchmark*. O ETF 22 mudou a sua escolha em relação ao período de 3 anos e deu maior importância ao Desvio Padrão, tal como acontecia no curto prazo, o que pode estar associado a uma elevada magnitude das flutuações nos retornos do fundo. Os resultados sugerem alguma moderação relativamente ao binómio rendibilidade-risco à medida que o prazo aumenta. O mesmo se nota quando o ETF 15 deixa de atribuir 100% de peso ao *Sharpe Ratio* para, de forma moderada, atribuir 52% à medida de rendibilidade ajustada ao risco, Alfa de Jensen, e cerca de 42% ao *Tracking Error*.

No que concerne a escolha dos *benchmarks* pelos fundos ineficientes, é de notar que o ETF mais vezes escolhido como referência é o ETF 22. Pelo contrário, os ETFs 1, 4 e 20 foram apenas referenciados uma única vez pelos seus pares. A fim dos ETFs ineficientes melhorarem o seu *score* de eficiência, é necessário que estes diminuam o Beta e aumentem o *Sharpe Ratio*. Contudo, a ausência de valores nulos nos valores das *slacks* pressupõe que todos os ETFs ineficientes requerem um ajustamento em todos os seus fatores em comparação aos seus pares. À medida que o tempo passa, volta de alguma forma a desconfiança dos investidores que começam de novo a ponderar o risco que incorrem com este tipo de fundos, muito dependentes de novas tecnologias e altamente mutáveis. Dá a sensação de que apenas no médio prazo, a expectativa de ganhos anormais é mais evidente.

Os resultados sugerem que o investidor procura, com o passar do tempo, uma alocação mais equilibrada entre diferentes setores e classes de ativos, reduzindo assim a exposição aos riscos específicos do setor de tecnologia. Ao longo do tempo o investidor pode temer a possibilidade de bolhas especulativas, levando-os a ser mais cautelosos nas suas opções

de investimento e procurando ou replicação de *benchmark* ou evidentes superações das expectativas de mercado.

4.4. Discussão de resultados

Da leitura dos resultados é possível observar que os únicos ETFs que mantêm o seu estatuto de eficiência e demonstram ser constantes no curto e no longo prazo são o ETF 14 e o ETF 22. Para além disso, o ETF 22 foi o fundo mais vezes escolhido no médio e longo prazo como fundo de referência e o ETF 14 foi o mais escolhido no período de avaliação de 1 ano. Assim, analisámos individualmente cada um destes ETFs para perceber a sua gestão de eficiência e as suas características.

O ETF 14, o *WisdomTree U.S. AI Enhanced Value Fund* (AIVL) foi criado em 2006, composto essencialmente (97,38%) por ações de setores diversos dos quais a tecnologia (6,07%), a sua gestão é ativa e os seus *benchmarks* são o *Russell 1000 value TR*, o *US 3-Month Treasury Bill TR USD* e o *Lipper Global Equity US*. O seu objetivo principal é investir principalmente em títulos de capital com base nos resultados da seleção de um modelo de IA quantitativa desenvolvido pela *Voya Investment Management*.

O AIVL investe em ações de valor dos EUA utilizando um modelo de IA quantitativo e exclusivo que analisa vários dados, incluindo os fundamentos da empresa e o sentimento do mercado. O gestor compra e vende ações mensalmente com base nas recomendações do modelo de IA.

Por outro lado, o ETF 22, o *Capital Link Global Fintech Leaders ETF* (KOIN), foi criado em 2018, o seu setor é *Science and Technology funds* com 42,80% no setor da tecnologia, a sua gestão é ativa e os seus índices de referência são o *ATFI Global NextGen Fintech Index*, o *Russell 3000 TR*, o *US 3-Month Treasury Bill TR USD* e o *Lipper Global Equity Sector Information Tech*. O seu principal objetivo é seguir o índice ATFI, que analisa as empresas quanto à sua adoção da tecnologia, e ainda selecionar ações a nível mundial líderes em *fintech*.

O KOIN inicia a construção da sua carteira através da seleção de empresas de mercados desenvolvidos e emergentes utilizando um algoritmo de PNL. De seguida, as ações são agrupadas em duas categorias distintas: Fornecedores de Ativos Digitais (empresas que utilizam a tecnologia para aumentar as ciências operacionais, otimizar os processos de liquidação, melhorar a experiência do cliente, aumentar a segurança/ integridade dos

dados e criar ativos digitais) ou Fornecedores de Soluções (empresas que ajudam na adoção e implementação das mais recentes tecnologias e aplicações).

Desta forma, constatamos que ambos os ETFs utilizam a IA, contudo de forma diferente, um investe em ações de IA, o outro opta por incorporar na sua gestão um modelo de IA para auxiliar a escolha dos melhores ativos que incorporam o fundo. O ETF 22 foi criado em 2018 e tornou-se imediatamente eficiente, sendo visto como referência por outros ETFs.

Por outro lado, constatámos que os ETFs 8, 15 e 20 demonstram ser mais eficientes no médio e longo prazo. Para além disso, o ETF 20 demonstrou ser o mais eficiente nos períodos de 3 e 5 anos.

Em relação ao ETF 8, o *ARK Autonomous Technology & Robotics ETF*, identifica empresas que beneficiam de novas tecnologias e de automatização, mais especificamente negócios transformadores em automação, energia e IA. Tem como *benchmarks* o *S&P 500 TR*, o *NASDAQ Industrials CR*, o *US 3-Month Treasury Bill TR USD* e o *Lipper Global Equity Sector Industrials*, para além disso, tem uma gestão ativa, foi criado em 2014 e o seu setor é industrial.

Relativamente ao ETF 15, intitulado *Defiance Quantum ETF*, este procura empresas envolvidas no desenvolvimento da computação quântica e da tecnologia de aprendizagem automática. Foi criado em 2018, gerido ativamente, o seu setor é o *Science and Technology Funds*, e pretende rastrear o *BlueStar Machine Learning and Quantum Computing Index*.

O ETF 20, o *Direxion Daily Robotics, Artificial Intelligence & Automation Index Bull 2X Shares*, oferece uma exposição alavancada a empresas que desenvolvem e produzem produtos e serviços automatizados de IA utilizando como referência o *Indxx Global Robotics & Artificial Intelligence Thematic Index*. Este investimento é gerido de forma ativa e foi criado em 2018 e o seu setor é o *Equity Leverage*.

Todos estes ETFs são especializados num único tema que é a IA e potenciam o seu desempenho e eficiência através da escolha pormenorizada de empresas especializadas no setor da tecnologia. Globalmente, percebe-se que se trata de investimentos muito recentes e que o estudo aqui levado a cabo ajuda a entender o seu comportamento.

É possível inferir que o mercado de tecnologia, nomeadamente a IA, pode ser caracterizado por ciclos de otimismo e pessimismo. No curto prazo, a um ano, eventos específicos, como resultados trimestrais de empresas de tecnologia, anúncios de produtos ou

mudanças regulatórias, podem influenciar a confiança dos investidores. No longo prazo, esses ciclos podem-se manifestar como períodos de euforia, seguidos por correções ou recessões no setor. Por este motivo se denota que os fundos que são eficientes no curto e no longo prazo repetem a intensidade dos pesos nas medidas associadas ao risco, desvio Padrão e Beta.

5. CONCLUSÕES

A IA desempenha um papel cada vez mais relevante na sociedade, moldando diversas facetas das nossas vidas e impulsionando avanços significativos em diversos fatores. Esta evolução tecnológica tem desempenhado um papel significativo no mercado de capitais, transformando a maneira como as instituições financeiras operam, os investidores tomam decisões e os mercados funcionam. Desta forma, os *Exchange-Traded Funds* de IA possibilitam aos investidores uma forma acessível e diversificada de participar no crescimento e na inovação do setor da tecnologia, e assim, surgiu uma procura crescente no investimento destes produtos financeiros.

Por conseguinte, a presente dissertação teve como objetivo o estudo da avaliação do desempenho dos *Exchange-Traded Funds* de inteligência artificial. Para os 22 ETFs da amostra foi utilizada a metodologia *Value-Based DEA*, proposta por Gouveia et al., (2008), que permitiu a análise dos ETFs classificados como eficientes e a compreensão dos fatores determinantes da sua eficiência.

Os ETFs de IA demonstram, em grande medida, a capacidade de capturar os avanços tecnológicos e o potencial de crescimento associado à inteligência artificial. As suas carteiras, muitas vezes compostas por empresas inovadoras, oferecem aos investidores uma exposição única a um setor em constante evolução. Os resultados refletem isso mesmo, quando se considera o curto prazo são as medidas de risco que têm maior atribuição de pesos nos fundos considerados eficientes. São normalmente empresas que estão na vanguarda da inovação tecnológica e por esse motivo os investidores podem recluir questões regulatórias e grande volatilidade associada às constantes mudanças para que continuem a obter vantagens competitivas em ambientes cada vez mais agressivos.

Quando se passa do curto para o médio/longo prazo, a 3 anos, o número de ETFs eficientes aumenta significativamente, sendo neste período onde se denota que são as medidas de rentabilidade ajustadas ao risco as de maior relevância, aumentando as expectativas de crescimento com influência positiva nos níveis de desempenho. O investidor encontra neste período a segurança por rentabilidade associada à inovação e ciclo de produtos, reconhecendo que eventualmente num período mais longo, a instabilidade destes produtos voltará alicerçada em volatilidade e risco.

Finalmente, no longo prazo, em que o número de fundos eficientes aumenta ligeiramente relativamente ao médio prazo, os resultados sugerem que os investidores tendem a

privilegiar os fundos que replicam o mercado, mas atendendo de igual modo à sua sensibilidade e às flutuações do mercado. Parece ser uma abordagem mais equilibrada onde a volatilidade pode ser suavizada ao longo do tempo, mas que também pode resultar em ganhos menos acentuados.

Num futuro próximo, para que seja efetuada a melhoria e reforço do investimento em IA, devem ser efetuadas intervenções regulamentares nas políticas de investimento, com o intuito de padronizar o conceito de IA, a fim de o desagregar do setor da tecnologia.

Esta investigação pode interessar a vários *stakeholders*: em primeiro lugar, aos gestores de ativos porque podem compreender os fatores chave de eficiência deste tipo de fundos e a forma como devem alocar os seus recursos na melhoria do desempenho, através da confiança e transparência no investimento, permitindo o aumento do interesse e participação dos investidores nos fundos de IA; aos investidores que ficam mais aptos a avaliar de forma mais eficaz as opções de investimento disponíveis e a tomar decisões mais informadas; aos académicos, que podem encontrar nesta investigação uma nova linha de pensamento, com avanço do conhecimento no campo dos investimentos em IA.

Na elaboração desta dissertação, foram encontradas algumas limitações, nomeadamente porque nem todos os ETFs dispunham de informação completa para os períodos em análise e para todas as variáveis em estudo, dada a sua recente criação. Além disso, a literatura existente que explora o tema de IA é escassa, fundamentalmente implementando a metodologia DEA para a avaliação do desempenho de ETFs, tornando assim a comparação de resultados algo complexo.

Relativamente a sugestões para futuras investigações, seria interessante introduzir fatores de ordem comportamental, estudando fatores psicológicos e emocionais que influenciam as decisões financeiras utilizando mídias sociais, notícias e sentimentos do mercado, para informar as decisões de investimento. Entender como os investidores respondem aos ETFs e como a IA pode afetar esses comportamentos ao longo do tempo.

REFERÊNCIAS BIBLIOGRÁFICAS

- Ali, A. I., Lerme, C. S., & Seiford, L. M. (1995). Components of efficiency evaluation in data envelopment analysis. *European Journal of Operational Research*, 80, 462–473.
- Ali Mohamad, T., Bastone, A., Bernhard, F., & Schiavone, F. (2023). How artificial intelligence impacts the competitive position of healthcare organizations. *Journal of Organizational Change Management*, 36(8), 49–70. <https://doi.org/10.1108/JOCM-03-2023-0057>
- Andersen, P., & Petersen, N. C. (1993). A Procedure for Ranking Efficient Units in Data Envelopment Analysis. *Management Science*, 39(10), 1261–1264. <https://doi.org/10.1287/mnsc.39.10.1261>
- Bahadar, S., Gan, C., & Nguyen, C. (2020). Performance Dynamics of International Exchange-Traded Funds. *Journal of Risk and Financial Management*, 13(8). <https://doi.org/10.3390/jrfm13080169>
- Baklaci, H. F., Cheng, W. I. W., & Zhang, J. (2023). Performance Attributes of Environmental, Social, and Governance Exchange-Traded Funds. *Asia-Pacific Financial Markets*. <https://doi.org/10.1007/s10690-023-09416-9>
- Banker, R. D., Charnes, A., & Cooper, W. W. (1984). Some models for estimating technical and scale inefficiencies in data envelopment analysis. *Management Science*, 30.
- Basso, A., & Funari, S. (2014). Constant and variable returns to scale DEA models for socially responsible investment funds. *European Journal of Operational Research*, 235(3), 775–783. <https://doi.org/10.1016/j.ejor.2013.11.024>
- Ben-David, I., Franzoni, F. A., & Moussawi, R. (2017a). Exchange Traded Funds (ETFs). *Annual Review of Financial Economics*, 9. <http://www.ssrn.com/abstract=2865734><http://www.ssrn.com>
- Ben-David, I., Franzoni, F. A., & Moussawi, R. (2017b). Exchange Traded Funds (ETFs). *Annual Review of Financial Economics*, 9. <http://www.ssrn.com/abstract=2865734><http://www.ssrn.com>

- Bhojraj, S., Mohanram, P., & Zhang, S. (2020). ETFs and information transfer across firms. *Journal of Accounting and Economics*, 70(2–3).
<https://doi.org/10.1016/j.jacceco.2020.101336>
- Blitz, D., Huij, J., & Swinkels, L. (2012). The Performance of European Index Funds and Exchange-Traded Funds. *European Financial Management*, 18(4), 649–662.
<https://doi.org/10.1111/j.1468-036X.2010.00550.x>
- Blitz, D., & Vidojevic, M. (2021). The Performance of Exchange-Traded Funds. *Journal of Alternative Investments*, 23(3), 81–99.
- Boussofiane, A., Dyson, R. G., & Thanassoulis, E. (1991). Applied data envelopment analysis. *European Journal of Operational Research*, 52, 1–15.
- Buetow, G. W., & Henderson, B. J. (2012). An Empirical Analysis of Exchange-Traded Funds. *Journal of Portfolio Management*, 38, 112–127.
<https://doi.org/10.3905/jpm.2012.38.4.112>
- Charnes, A., Cooper, W., & Rhodes, E. (1978). Measuring the efficiency of decision making units. *Company European Journal of Operational Research*, 2, 429–444.
- Charnes, A., Cooper, W. W., Seiford, L., & Stutz, J. (1985). Foundations of data envelopment analysis for Pareto-Koopmans efficient empirical production functions. *Journal of Econometrics*, 30, 91–107.
- Charupat, N., & Miu, P. (2013). Recent developments in exchange-traded fund literature: Pricing efficiency, tracking ability, and effects on underlying securities. In *Managerial Finance* (Vol. 39, Issue 5, pp. 427–443). Emerald Group Publishing Ltd.
<https://doi.org/10.1108/03074351311313816>
- Choi, H. S., & Min, D. (2017). Efficiency of well-diversified portfolios: Evidence from data envelopment analysis. *Omega (United Kingdom)*, 73, 104–113.
<https://doi.org/10.1016/j.omega.2016.12.008>
- da Costa Neto, A. F., Klotzle, M. C., & Figueiredo Pinto, A. C. (2019). Investor behavior in ETF markets: a comparative study between the US and emerging markets. *International Journal of Emerging Markets*, 14(5), 944–966.
<https://doi.org/10.1108/IJOEM-04-2018-0195>
- Deville, L. (2008). HANDBOOK OF FINANCIAL ENGINEERING. *Springer, Boston, MA*, 18, 67–98.

- Dias, L. C., & Clímaco, J. N. (2000). Shortest path problems with partial information: Models and algorithms for detecting dominance. *European Journal of Operational Research*, 121, 16–31. www.elsevier.com/locate/orms
- Dumitrescu, A., Järvinen, J., & Zakriya, M. (2023). Hidden Gem or Fool's Gold: Can passive ESG ETFs outperform the benchmarks? *International Review of Financial Analysis*, 86. <https://doi.org/10.1016/j.irfa.2023.102540>
- Farrell, M. J. (1957). The Measurement of Productive Efficiency. *Source: Journal of the Royal Statistical Society. Series A (General)*, 120(3), 253–290.
- Favreau, C., Kane, H., & Shelton, A. (2020). Charles Favreau The (Under) Performance of Hedge Fund ETFs. *The Journal of Alternative Investments*, 22(4), 120–143.
- Ferreira, F. G. D. C., Gandomi, A. H., & Cardoso, R. T. N. (2021). Artificial Intelligence Applied to Stock Market Trading: A Review. *IEEE Access*, 9, 30898–30917. <https://doi.org/10.1109/ACCESS.2021.3058133>
- Gouveia, M. C., Dias, L. C., & Antunes, C. H. (2008). Additive DEA based on MCDA with imprecise information. *Journal of the Operational Research Society*, 59(1), 54–63. <https://doi.org/10.1057/palgrave.jors.2602317>
- Gouveia, M. C., Dias, L. C., & Antunes, C. H. (2013). Super-efficiency and stability intervals in additive DEA. *Journal of the Operational Research Society*, 64(1), 86–96. <https://doi.org/10.1057/jors.2012.19>
- Haenlein, M., & Kaplan, A. (2019). A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California Management Review*, 61(4), 5–14. <https://doi.org/10.1177/0008125619864925>
- Hegde, S. P., & McDermott, J. B. (2004). The market liquidity of DIAMONDS, Q's, and their underlying stocks. *Journal of Banking and Finance*, 28(5), 1043–1067. [https://doi.org/10.1016/S0378-4266\(03\)00043-8](https://doi.org/10.1016/S0378-4266(03)00043-8)
- Henriques, C. O., Neves, M. E., Castelão, L., & Nguyen, D. K. (2022a). Assessing the performance of exchange traded funds in the energy sector: a hybrid DEA multiobjective linear programming approach. *Annals of Operations Research*, 313(1), 341–366. <https://doi.org/10.1007/s10479-021-04323-6>
- Henriques, C. O., Neves, M. E., Castelão, L., & Nguyen, D. K. (2022b). Assessing the performance of exchange traded funds in the energy sector: a hybrid DEA

- multiobjective linear programming approach. *Annals of Operations Research*, 313(1), 341–366. <https://doi.org/10.1007/s10479-021-04323-6>
- Henriques, C. O., Neves, M. E., Conceição, J. A., & Vieira, E. S. (2023). Performance of US and European Exchange Traded Funds: A Base Point-Slack-Based Measure Approach. *Journal of Risk and Financial Management*, 16(2). <https://doi.org/10.3390/jrfm16020130>
- Huang, C. Y., Chiou, C. C., Wu, T. H., & Yang, S. C. (2015). An integrated DEA-MODM methodology for portfolio optimization. *Operational Research*, 15(1), 115–136. <https://doi.org/10.1007/s12351-014-0164-7>
- Investment Company Institute. (2023). *Investment Company Fact Book*. www.ici.org/etf.
- Ivanov, S. I. (2016). Analysis of the factors impacting ETFs net fund flow changes. *Studies in Economics and Finance*, 33(2), 244–261. <https://doi.org/10.1108/SEF-06-2014-0114>
- Keeney, R. L., & Raiffa, H. (1976). *Decisions with Multiple Objectives: Preferences and Value Trade-off*. Wiley: New York.
- Lettau, M., & Madhavan, A. (2018). Exchange-Traded funds 101 for economists. *Journal of Economic Perspectives*, 32(1), 135–153. <https://doi.org/10.1257/jep.32.1.135>
- Miu, P., Yueh, M. L., & Han, J. (2021). Performance of Japanese leveraged ETFs. *Pacific Basin Finance Journal*, 65. <https://doi.org/10.1016/j.pacfin.2020.101490>
- Murthi, B. P. S., Choi, Y. K., & Desai, P. (1997). Efficiency of mutual funds and portfolio performance measurement: A non-parametric approach. *European Journal of Operational Research*, 98, 408–418.
- Muthukrishnan, N., Maleki, F., Ovens, K., Reinhold, C., Forghani, B., & Forghani, R. (2020). Brief History of Artificial Intelligence. *Neuroimaging Clinics of North America*, 30(4), 393–399. <https://doi.org/10.1016/j.nic.2020.07.004>
- Narend, S., & Thenmozhi, M. (2016). What drives fund flows to index ETFs and mutual funds? A panel analysis of funds in India. *DECISION*, 43(1), 17–30. <https://doi.org/10.1007/s40622-016-0124-6>

- Neves, C., Oliveira, T., & Sarker, S. (2024). Citizens' participation in local energy communities: the role of technology as a stimulus. *European Journal of Information Systems*. <https://doi.org/10.1080/0960085X.2024.2302426>
- Neves, M. E., Fernandes, C. M., & Martins, P. C. (2019). Are ETFs good vehicles for diversification? New evidence for critical investment periods. *Borsa Istanbul Review*, 19(2), 149–157. <https://doi.org/10.1016/j.bir.2019.01.002>
- Prasanna, K. (2012). Performance of Exchange-Traded Funds in India. *International Journal of Business and Management*, 7(23). <https://doi.org/10.5539/ijbm.v7n23p122>
- Proença, C. A. N., Neves, M. E. D., do Castelo Baptista Gouveia, M., & da Silva Madaleno, M. T. (2023). Technological, healthcare and consumer funds efficiency: influence of COVID-19. *Operational Research*, 23(2). <https://doi.org/10.1007/s12351-023-00749-x>
- PWC. (2023). *ETFs 2027: a world of new possibilities*.
- Richie, N., & Madura, J. (2007). Impact of the QQQ on liquidity and risk of the underlying stocks. *Quarterly Review of Economics and Finance*, 47(3), 411–421. <https://doi.org/10.1016/j.qref.2006.04.002>
- Trabelsi Karoui, A., Sayari, S., Dammak, W., & Jeribi, A. (2024). Unveiling Outperformance: A Portfolio Analysis of Top AI-Related Stocks against IT Indices and Robotics ETFs. *Risks*, 12(3), 52. <https://doi.org/10.3390/risks12030052>
- Tripathi, V., & Sethi, A. (2022). An Evaluation of the Tracking Performance of Exchange Traded Funds (ETFs): The Case of Indian Index ETFs. *Vision*, 26(3), 339–350. <https://doi.org/10.1177/0972262921996485>
- Tsolas, I. E. (2019). Utility exchange traded fund performance evaluation. A comparative approach using grey relational analysis and data envelopment analysis modelling. *International Journal of Financial Studies*, 7(4). <https://doi.org/10.3390/ijfs7040067>
- Tsolas, I. E. (2022). Performance Evaluation of Utility Exchange-Traded Funds: A Super-Efficiency Approach. *Journal of Risk and Financial Management*, 15(7). <https://doi.org/10.3390/jrfm15070318>

- Tsolas, I. E., & Charles, V. (2015). Green exchange-traded fund performance appraisal using slacks-based DEA models. *Operational Research*, 15(1), 51–77. <https://doi.org/10.1007/s12351-015-0169-x>
- Valadkhani, A., & Moradi-Motlagh, A. (2023). An empirical analysis of exchange-traded funds in the US. *Economic Analysis and Policy*, 78, 995–1009. <https://doi.org/10.1016/j.eap.2023.05.002>
- Wamba-Taguimdje, S. L., Fosso Wamba, S., Kala Kamdjoug, J. R., & Tchatchouang Wanko, C. E. (2020). Influence of artificial intelligence (AI) on firm performance: the business value of AI-based transformation projects. *Business Process Management Journal*, 26(7), 1893–1924. <https://doi.org/10.1108/BPMJ-10-2019-0411>
- Yousaf, I., Youssef, M., & Goodell, J. W. (2024). Tail connectedness between artificial intelligence tokens, artificial intelligence ETFs, and traditional asset classes. *Journal of International Financial Markets, Institutions and Money*, 91. <https://doi.org/10.1016/j.intfin.2023.101929>
- Zawadzki, K. (2020). The performance of ETFs on developed and emerging markets with consideration of regional diversity. *Quantitative Finance and Economics*, 4(3), 515–525. <https://doi.org/10.3934/QFE.2020024>
- Zhang, Y. (2015). The securitization of gold and its potential impact on gold stocks. *Journal of Banking and Finance*, 58, 309–326. <https://doi.org/10.1016/j.jbankfin.2015.03.016>

WEBGRAFIA

<https://bpstat.bportugal.pt/conteudos/sabia-que/116> consultado a 23 de novembro de 2023.

<https://investidor.cmvm.pt/PInvestidor/Content?Input=E4600A824482C80A76A6AA40A03761FF9601796E8E877C3598DF92C245BA884E> acedido em 23 de novembro de 2023.

<https://www.morningstar.com/etfs/constellation-factors-powering-active-etfs-meteoric-rise> acedido em 8 de dezembro de 2023.

<https://www.investor.gov/introduction-investing/general-resources/news-alerts/alerts-bulletins/investor-bulletins-24> acedido em 8 de dezembro de 2023.

<https://www.europarl.europa.eu/news/pt/headlines/society/20200827STO85804/o-que-e-a-inteligencia-artificial-e-como-funciona> acedido em 28 de novembro de 2023.

<https://www.bloomberg.com/news/articles/2023-12-07/andreessen-horowitz-leads-financing-for-ai-startup-air-space-intelligence> acedido em 28 de novembro de 2023.

<https://www.morningstar.com/etfs/are-ai-etfs-worth-hype> acedido em 29 de novembro de 2023.

<https://www.ft.com/content/08e159e5-d545-4bc0-ac84-9ede1567d529> acedido em 29 de dezembro de 2023.

<https://www.etftrends.com/artificial-intelligence-channel/ai-incredibly-powerful-theme-next-decade/> acedido em 29 de dezembro de 2023.

<https://www.bloomberg.com/news/articles/2023-05-25/assets-in-ai-etfs-to-triple-by-2030-with-china-in-the-lead?leadSource=verify%20wall> acedido em 29 de dezembro de 2023.

<https://etfdb.com/screener/> acedido a 4 de Outubro de 2023.

APÊNDICES

Apêndice A.1. - Valores convertidos em valores de escala para 1 ano

1 ano	Fatores com dados originais			Fatores em escala de valor		
	Beta	Desvio Padrão	Tracking Error	Beta	Desvio Padrão	Tracking Error
ETFs IA inputs						
1	1,01	22,52	42,67%	0,904	0,819	0,241
2	1,04	21,13	32,98%	0,888	0,855	0,387
3	0,99	23,5	22,14%	0,916	0,793	0,551
4	1,15	22,81	34,27%	0,826	0,811	0,368
5	1,04	22,23	37,45%	0,888	0,827	0,320
6	1,24	21,9	9,68%	0,775	0,835	0,738
7	1,18	24,76	28,12%	0,809	0,760	0,461
8	1,2	30,11	13,54%	0,798	0,620	0,680
9	1,67	31,65	10,40%	0,534	0,580	0,728
10	1,18	24,16	38,55%	0,809	0,776	0,304
11	1,32	26,55	30,48%	0,730	0,713	0,425
12	1,29	25,62	24,32%	0,747	0,738	0,518
13	1,16	23,62	10,24%	0,820	0,790	0,730
14	1,01	18,06	-7,68%	0,904	0,936	1,000
15	1,13	24,26	30,11%	0,837	0,773	0,431
16	0,84	18,97	33,64%	1,000	0,912	0,378
17	1,23	26,37	-5,64%	0,781	0,718	0,969
18	1,05	18,71	4,40%	0,882	0,919	0,818
19	1,42	29,57	27,31%	0,674	0,634	0,473
20	2,62	53,79	58,70%	0,000	0,000	0,000
21	1,16	18,7	18,26%	0,820	0,919	0,609
22	0,9	15,61	9,52%	0,966	1,000	0,741
Média	1,220	24,755	0,229	0,787	0,760	0,540
Mínimo	0,840	15,610	-0,077	0,000	0,000	0,000
Máximo	2,620	53,790	0,587	1,000	1,000	1,000

1 ano	Fatores com dados originais		Fatores em escala de valor	
	Alfa de Jensen	Sharpe Ratio	Alfa de Jensen	Sharpe Ratio
ETFs IA outputs				
1	18,86	1,52	1,000	1,000
2	12,77	1,35	0,832	0,881
3	6,21	0,9	0,651	0,566
4	12,44	1,31	0,823	0,853
5	14,96	1,38	0,892	0,902
6	-5,4	0,61	0,330	0,364
7	11,45	1,19	0,795	0,769
8	-3,8	0,48	0,374	0,273
9	-8,96	0,52	0,232	0,301
10	14,66	1,35	0,884	0,881
11	8,23	1,06	0,707	0,678
12	3,62	0,9	0,579	0,566
13	-1,31	0,69	0,443	0,420
14	-8,38	0,43	0,278	0,238
15	9,81	1,11	0,750	0,713
16	15,27	1,48	0,901	0,972
17	-17,36	0,09	0,000	0,000
18	-7,46	0,45	0,273	0,252
19	5,35	0,91	0,627	0,573
20	16,86	1,09	0,945	0,699
21	-8,07	0,51	0,256	0,294
22	-2,39	0,72	0,413	0,441

Média	3,971	0,911	0,589	0,574
Mínimo	-17,360	0,090	0,000	0,000
Máximo	18,860	1,520	1,000	1,000

Apêndice A. 2. - Valores convertidos em valores de escala para 3 anos

3 anos	Fatores com dados originais			Fatores em escala de valor		
	Beta	Desvio Padrão	Tracking Error	Beta	Desvio Padrão	Tracking Error
ETFs IA inputs						
1	1,19	23,69	-1,44%	0,806	0,833	0,015
2	1,2	23,1	-2,78%	0,800	0,849	0,051
3	1,13	24,75	-19,95%	0,842	0,805	0,522
4	1,25	23,71	-3,04%	0,770	0,833	0,058
5	1,22	23,8	-5,85%	0,788	0,830	0,135
6	1,13	20,66	-11,86%	0,842	0,914	0,286
7	1,34	27,5	-18,34%	0,715	0,731	0,478
8	1,34	30,74	-18,92%	0,715	0,645	0,494
9	1,53	29,86	-3,88%	0,600	0,668	0,081
10	1,15	22,9	-9,15%	0,830	0,854	0,226
11	1,22	26,14	-23,57%	0,788	0,768	0,621
12	1,18	25,08	-15,64%	0,812	0,796	0,404
13	1,27	25,04	-14,22%	0,758	0,797	0,365
14	0,87	17,46	-3,45%	1,000	1,000	0,070
15	1,25	24,76	-0,91%	0,770	0,805	0,000
16	1,12	22,12	-4,73%	0,848	0,875	0,105
17	1,12	24,56	-14,85%	0,848	0,810	0,382
18	1,16	21,79	-18,02%	0,824	0,884	0,469
19	1,47	31,98	-14,46%	0,636	0,611	0,371
20	2,52	54,82	-37,39%	0,000	0,000	1,000
21	1,03	19,12	-1,43%	0,903	0,956	0,014
22	0,99	18,06	-12,17%	0,927	0,984	0,309
Média	1,258	25,529	-0,116	0,765	0,784	0,293
Mínimo	0,870	17,460	-0,374	0,000	0,000	0,000
Máximo	2,520	54,820	-0,009	1,000	1,000	1,000

3 anos	Fatores com dados originais		Fatores em escala de valor	
	Alfa de Jensen	Sharpe Ratio	Alfa de Jensen	Sharpe Ratio
ETFs IA outputs				
1	5,03	0,52	0,951	0,934
2	3,75	0,48	0,915	0,890
3	-11,36	-0,18	0,491	0,165
4	3,04	0,45	0,895	0,857
5	0,81	0,34	0,832	0,736
6	-3,69	0,15	0,706	0,527
7	-10,05	-0,07	0,528	0,286
8	-7,75	0,01	0,592	0,374
9	4,96	0,48	0,949	0,890
10	-1,45	0,24	0,769	0,626
11	-16	-0,22	0,360	0,000
12	-7,06	0	0,611	0,363
13	-5,25	0,1	0,662	0,473
14	-0,37	0,44	0,799	0,846
15	6,78	0,58	1,000	1,000
16	2,03	0,4	0,867	0,802

17	-9,49	0,04	0,543	0,407
18	-9,23	-0,1	0,551	0,253
19	-5,03	0,12	0,668	0,495
20	-28,84	-0,1	0,000	0,253
21	-3,19	0,16	0,720	0,538
22	4,58	0,08	0,938	0,451
Média	-3,990	0,173	0,698	0,553
Mínimo	-28,840	-0,330	0,000	0,000
Máximo	6,780	0,580	1,000	1,000

Apêndice A. 3. - Valores convertidos em valores de escala para 5 anos

5 anos	Fatores com dados originais			Fatores em escala de valor		
	Beta	Desvio Padrão	Tracking Error	Beta	Desvio Padrão	Tracking Error
ETFs IA inputs						
1	1,16	23,75	5,79%	0,906	0,909	0,000
2	1,17	23,35	4,78%	0,901	0,917	0,034
3	1,15	25,13	-9,44%	0,910	0,882	0,512
4	1,16	23,11	3,89%	0,906	0,922	0,064
5	1,19	23,83	1,81%	0,892	0,908	0,134
6	1,08	20,69	-5,55%	0,943	0,971	0,381
7	1,29	27,3	-10,02%	0,844	0,838	0,531
8	1,38	31,03	-3,57%	0,802	0,763	0,315
9	1,47	29,27	-1,40%	0,759	0,798	0,242
10	1,17	23,66	-0,13%	0,901	0,911	0,199
11	1,22	26,58	-9,28%	0,877	0,852	0,507
12	1,23	25,77	-6,89%	0,873	0,869	0,426
13	1,28	25,59	-7,58%	0,849	0,872	0,449
14	0,96	19,88	-11,89%	1,000	0,987	0,594
15	1,22	24,6	3,08%	0,877	0,892	0,091
16	1,11	22,55	3,01%	0,929	0,934	0,093
17	1,14	24,41	-11,74%	0,915	0,896	0,589
18	1,18	23,16	-8,37%	0,896	0,921	0,476
19	1,45	31,18	-5,47%	0,769	0,760	0,378
20	3,08	68,92	-23,96%	0,000	0,000	1,000
21	1,06	20,42	-3,30%	0,953	0,976	0,306
22	1,01	19,25	-6,20%	0,976	1,000	0,403
Média	1,280	26,520	-0,047	0,849	0,854	0,351
Mínimo	0,960	19,250	-0,240	0,000	0,000	0,000
Máximo	3,080	68,920	0,058	1,000	1,000	1,000

5 anos	Fatores com dados originais		Fatores em escala de valor	
	Alfa de Jensen	Sharpe Ratio	Alfa de Jensen	Sharpe Ratio
ETFs IA outputs				
1	10,01	0,72	1,000	1,000
2	9,09	0,69	0,969	0,948
3	-3,3	0,15	0,549	0,017
4	8,33	0,67	0,943	0,914
5	6,28	0,57	0,874	0,741
6	0,66	0,35	0,683	0,362
7	-3,72	0,15	0,535	0,017
8	3,08	0,37	0,765	0,397
9	4,3	0,45	0,807	0,534
10	5	0,51	0,830	0,638
11	-3,23	0,16	0,551	0,034
12	1,16	0,24	0,622	0,172
13	-1,61	0,24	0,606	0,172
14	-6,13	0,15	0,453	0,017
15	7,96	0,62	0,931	0,828
16	7,64	0,64	0,920	0,862
17	-6,79	0,16	0,431	0,034
18	-2,42	0,2	0,579	0,103
19	0,24	0,29	0,669	0,259
20	-19,51	0,14	0,000	0,000
21	1,42	0,38	0,709	0,414
22	0,16	0,32	0,666	0,310
Média	0,741	0,371	0,686	0,399
Mínimo	-19,510	0,140	0,000	0,000
Máximo	10,010	0,720	1,000	1,000

Apêndice B.1. - Pesos atribuídos aos fatores para 1 ano

ETFs	1 ano				
	W_{Beta}	W_{DP}	W_{TE}	W_{Alfa}	W_{SR}
1	0,042	0,000	0,000	0,958	0,000
2	0,000	0,000	0,512	0,488	0,000
3	0,000	0,000	0,512	0,488	0,000
4	0,000	0,000	0,512	0,488	0,000
5	0,000	0,000	0,419	0,581	0,000
6	0,000	0,000	0,541	0,000	0,459
7	0,000	0,000	0,512	0,488	0,000
8	0,000	0,000	0,512	0,488	0,000
9	0,000	0,000	0,541	0,000	0,459
10	0,000	0,000	0,419	0,581	0,000
11	0,000	0,000	0,512	0,488	0,000
12	0,000	0,000	0,512	0,488	0,000
13	0,000	0,000	0,512	0,488	0,000
14	0,000	0,429	0,571	0,000	0,000
15	0,000	0,000	0,512	0,488	0,000
16	0,900	0,000	0,000	0,000	0,100
17	0,000	0,000	1,000	0,000	0,000
18	0,000	0,802	0,198	0,000	0,000
19	0,000	0,000	0,512	0,488	0,000
20	0,000	0,000	0,000	1,000	0,000
21	0,000	1,000	0,000	0,000	0,000
22	0,000	0,968	0,000	0,000	0,032
Média	0,942	3,199	8,812	7,997	1,049

1 ano					
ETFs eficientes	W_{Beta}	W_{DP}	W_{TE}	W_{Alfa}	W_{SR}
1	0,042	0,000	0,000	0,958	0,000
14	0,000	0,429	0,571	0,000	0,000
16	0,900	0,000	0,000	0,000	0,100
22	0,000	0,968	0,000	0,000	0,032
Média	0,942	1,397	0,571	0,958	0,132

Apêndice B.2. - Pesos atribuídos aos fatores para 3 anos

3 anos					
ETFs	W_{Beta}	W_{DP}	W_{TE}	W_{Alfa}	W_{SR}
1	0,458	0,000	0,000	0,464	0,079
2	0,000	0,167	0,446	0,091	0,295
3	0,323	0,000	0,459	0,000	0,218
4	0,000	0,167	0,446	0,091	0,295
5	0,000	0,167	0,446	0,091	0,295
6	0,000	0,270	0,462	0,000	0,268
7	0,192	0,106	0,473	0,000	0,229
8	0,279	0,000	0,466	0,018	0,237
9	0,000	0,000	0,471	0,298	0,231
10	0,155	0,000	0,446	0,116	0,282
11	0,000	0,373	0,627	0,000	0,000
12	0,252	0,034	0,467	0,009	0,238
13	0,000	0,270	0,462	0,000	0,268
14	0,816	0,000	0,000	0,000	0,184
15	0,000	0,000	0,000	0,000	1,000
16	0,000	0,167	0,446	0,091	0,295
17	0,294	0,000	0,465	0,000	0,241
18	0,000	0,309	0,496	0,000	0,195
19	0,155	0,000	0,446	0,116	0,282
20	0,000	0,000	1,000	0,000	0,000
21	0,000	1,000	0,000	0,000	0,000
22	0,000	0,149	0,404	0,448	0,000
Média	2,923	3,179	8,930	1,833	5,135

3 anos					
ETFs eficientes	W_{Beta}	W_{DP}	W_{TE}	W_{Alfa}	W_{SR}
3	0,323	0,000	0,459	0,000	0,218
8	0,279	0,000	0,466	0,018	0,237
11	0,000	0,373	0,627	0,000	0,000
14	0,816	0,000	0,000	0,000	0,184
15	0,000	0,000	0,000	0,000	1,000
18	0,000	0,309	0,496	0,000	0,195
20	0,000	0,000	1,000	0,000	0,000
22	0,000	0,149	0,404	0,448	0,000
Média	1,418	0,830	3,452	0,465	1,834

Apêndice B.3. - Pesos atribuídos aos fatores para 5 anos

5 anos					
ETFs	W_{Beta}	W_{DP}	W_{TE}	W_{Alfa}	W_{SR}
1	0,000	0,000	0,000	0,000	1,000
2	0,000	0,009	0,488	0,410	0,093
3	0,036	0,000	0,506	0,458	0,000
4	0,000	0,148	0,493	0,000	0,359
5	0,000	0,029	0,473	0,424	0,074
6	0,000	0,012	0,500	0,380	0,108
7	0,000	0,000	0,529	0,471	0,000
8	0,000	0,000	0,467	0,533	0,000
9	0,000	0,000	0,500	0,392	0,108
10	0,000	0,029	0,473	0,424	0,074
11	0,036	0,000	0,506	0,458	0,000
12	0,016	0,000	0,506	0,478	0,000
13	0,000	0,004	0,521	0,451	0,024
14	0,753	0,000	0,247	0,000	0,000
15	0,000	0,062	0,417	0,520	0,000
16	0,908	0,000	0,000	0,000	0,092
17	0,123	0,000	0,497	0,167	0,213
18	0,000	0,035	0,510	0,455	0,000
19	0,000	0,000	0,522	0,457	0,020
20	0,000	0,000	1,000	0,000	0,000
21	0,000	0,794	0,000	0,206	0,000
22	0,000	0,754	0,101	0,146	0,000
Média	1,872	1,875	9,258	6,829	2,166

5 anos					
ETFs eficientes	W_{Beta}	W_{DP}	W_{TE}	W_{Alfa}	W_{SR}
1	0,000	0,000	0,000	0,000	1,000
4	0,000	0,148	0,493	0,000	0,359
6	0,000	0,012	0,500	0,380	0,108
7	0,000	0,000	0,529	0,471	0,000
8	0,000	0,000	0,467	0,533	0,000
14	0,753	0,000	0,247	0,000	0,000
15	0,000	0,062	0,417	0,520	0,000
16	0,908	0,000	0,000	0,000	0,092
20	0,000	0,000	1,000	0,000	0,000
22	0,000	0,754	0,101	0,146	0,000
Média	1,661	0,976	3,755	2,049	1,559

Apêndice C.1. - Pares e slacks para 1 ano

1 ano						
ETFs Ineficientes	Pares	S_{Beta}	S_{DV}	S_{TE}	S_{Alfa}	S_{SR}
2	Fd(14); Fd(16)	0,102	0,060	0,057	0,000	0,013
3	Fd(14); Fd(16)	0,047	0,128	0,065	0,000	0,125
4	Fd(14); Fd(16)	0,163	0,104	0,084	0,000	0,031
5	Fd(1); Fd(16)	0,071	0,046	0,000	0,051	0,082
6	Fd(14); Fd(16)	0,145	0,097	0,155	0,030	0,000
7	Fd(14); Fd(16)	0,175	0,156	0,018	0,000	0,084
8	Fd(14); Fd(16)	0,125	0,311	0,200	0,000	0,107
9	Fd(14); Fd(16)	0,378	0,354	0,219	0,072	0,000

10	Fd(1); Fd(16)	0,139	0,086	0,000	0,070	0,106
11	Fd(14); Fd(16)	0,241	0,206	0,138	0,000	0,076
12	Fd(14); Fd(16)	0,206	0,186	0,167	0,000	0,044
13	Fd(14); Fd(16)	0,113	0,139	0,084	0,000	0,037
15	Fd(14); Fd(16)	0,141	0,145	0,091	0,000	0,089
17	Fd(14)	0,123	0,218	0,031	0,248	0,238
18	Fd(14); Fd(22)	0,031	0,027	0,143	0,000	0,017
19	Fd(14); Fd(16)	0,286	0,288	0,166	0,000	0,091
20	Fd(1)	0,904	0,819	0,241	0,055	0,301
21	Fd(22)	0,146	0,081	0,132	0,157	0,147

Apêndice C.2. - Pares e slacks para 3 anos

3 anos						
ETFs Ineficientes	Pares	S_{Beta}	S_{DV}	S_{TE}	S_{Alfa}	S_{SR}
1	Fd(14); Fd(15); Fd(22)	0,025	0,026	0,018	0,000	0,000
2	Fd(14); Fd(15); Fd(20); Fd(22)	0,025	0,000	0,000	0,000	0,034
4	Fd(14); Fd(15); Fd(20)	0,040	0,000	0,006	0,000	0,063
5	Fd(14); Fd(15); Fd(20); Fd(22)	0,022	0,000	0,000	0,000	0,098
6	Fd(14); Fd(20); Fd(22)	0,063	0,034	0,000	0,165	0,000
7	Fd(3); Fd(20); Fd(22)	0,000	0,021	0,000	0,169	0,100
9	Fd(15); Fd(20); Fd(22)	0,169	0,138	0,000	0,008	0,000
10	Fd(14); Fd(20); Fd(22)	0,094	0,098	0,000	0,067	0,000
12	Fd(8); Fd(14); Fd(22)	0,000	0,001	0,000	0,131	0,057
13	Fd(14); Fd(20); Fd(22)	0,002	0,000	0,041	0,074	0,000
16	Fd(14); Fd(15); Fd(20); Fd(22)	0,000	0,000	0,000	0,031	0,031
17	Fd(3); Fd(8); Fd(14)	0,017	0,023	0,000	0,059	0,000
19	Fd(15); Fd(20); Fd(22)	0,131	0,202	0,000	0,138	0,000
21	Fd(14)	0,097	0,044	0,056	0,079	0,308

Apêndice C.3. - Pares e slacks para 5 anos

5 anos						
ETFs Ineficientes	Pares	S_{Beta}	S_{DV}	S_{TE}	S_{Alfa}	S_{SR}
2	Fd(1); Fd(16)	0,013	0,001	0,000	0,002	0,002
3	Fd(7); Fd(14); Fd(22)	0,000	0,028	0,000	0,002	0,074
5	Fd(15); Fd(16); Fd(22)	0,000	0,000	0,000	0,020	0,016
9	Fd(4); Fd(8)	0,071	0,007	0,006	0,005	0,000
10	Fd(8); Fd(15); Fd(16); Fd(22)	0,010	0,000	0,011	0,000	0,000
11	Fd(7); Fd(14); Fd(22)	0,000	0,025	0,000	0,008	0,043
12	Fd(7); Fd(8); Fd(22)	0,000	0,000	0,022	0,000	0,011
13	Fd(7); Fd(8); Fd(22)	0,026	0,000	0,005	0,009	0,000
17	Fd(14); Fd(16); Fd(20)	0,071	0,077	0,000	0,026	0,000
18	Fd(14); Fd(22)	0,090	0,074	0,005	0,000	0,087
19	Fd(7); Fd(8)	0,045	0,025	0,000	0,029	0,027
21	Fd(16); Fd(22)	0,014	0,012	0,029	0,005	0,000