ÁREA TEMÁTICA: FINANÇAS

CATEGORIA: ENANGRAD PLENO

DESEMPENHO DE CARTEIRAS COM EXPOSIÇÃO À INTELIGÊNCIA ARTIFICIAL APÓS 2022 SOB A PERSPECTIVA DO ÍNDICE DE SHARPE

Resumo

Este estudo avalia se a inclusão de empresas com alta exposição prévia à inteligência artificial (IA) melhorou a relação entre risco e retorno das carteiras após 2022. Utiliza-se um painel mensal de empresas listadas entre 2000 e 2025, combinando informações financeiras do LSEG com registros de inovação tecnológica do Google Patents, harmonizados com bases da OECD. A exposição tecnológica é mensurada pelo estoque de patentes e fixada em setembro de 2022, evitando viés retrospectivo. Foram construídas carteiras de empresas com alta exposição à IA, de comparação, de infraestrutura tecnológica e de mercado, com ponderação igualitária e por valor de mercado. Os resultados sugerem que, após 2022, o mercado passou a atribuir maior valor às capacidades tecnológicas acumuladas pelas empresas. Contudo, a melhora das carteiras decorreu principalmente dos retornos superiores das empresas expostas à IA, e não apenas da redução do risco proporcionada pela diversificação.

Palavras-chave: inteligência artificial; patentes; capital intangível; diversificação de carteiras; desempenho ajustado ao risco.

Abstract

This study examines whether the inclusion of companies with substantial prior involvement in artificial intelligence (AI) improved portfolio risk–return performance after 2022. The analysis draws on a monthly panel of listed corporations from 2000 to 2025, combining financial information from LSEG with patent records obtained through Google Patents and harmonized according to OECD classifications. AI intensity is measured through accumulated patent stocks and fixed as of September 2022, preventing subsequent market performance from affecting company classification. Investment strategies are formed for highly AI-intensive businesses, a comparison group, technology infrastructure providers, and the broader market, under both equal- and value-weighted approaches. The findings indicate that investors placed greater value on previously accumulated innovative capabilities following 2022. The observed gains were driven primarily by stronger returns among AI-intensive companies rather than solely by lower risk resulting from diversification.

Keywords: artificial intelligence; patents; intangible capital; portfolio diversification; risk-adjusted performance.

1 Introdução

A inteligência artificial (IA) virou peça-chave na chamada Quarta Revolução Industrial e já está mudando o jeito como funcionam os mercados financeiros e como os investidores montam suas carteiras (El Khoury et al., 2023). Segundo a UNCTAD (2025), o mercado global de IA deve crescer de US$ 189 bilhões em 2023 para US$ 4,8 trilhões em 2033. Na gestão de ativos, 55% das gestoras já usam IA no processo de investimento, 27% desenvolvem projetos-piloto e 18% não possuem integração, embora 91% pretendam expandir seu uso nos próximos 12 meses (UNCTAD, 2025; Mercer, 2026). Assim, a IA transforma tanto as oportunidades dos investidores quanto os processos de pesquisa, alocação, negociação e gestão de riscos. Nesse cenário, o acúmulo histórico de patentes, P&D e conhecimento técnico gerou capacidades cujo valor econômico nem sempre é precificado de imediato pelo mercado de ações (Kogan et al., 2017; Babina et al., 2024).

Apesar dos avanços da área, ainda não há uma compreensão consolidada de como as capacidades tecnológicas e o capital intangível das empresas afetam os preços dos ativos e podem ser incorporados à formação de carteiras (Kogan & Papanikolaou, 2019). Ainda há pouca evidência sobre sua contribuição para o desempenho agregado dos portfólios (Hirshleifer et al., 2013; Kogan et al., 2017; Babina et al., 2024). Essa lacuna tornou-se particularmente relevante após 2022, quando os controles norte-americanos sobre semicondutores avançados e o lançamento do ChatGPT ampliaram a importância econômica da infraestrutura computacional e das capacidades preexistentes de IA (Bureau of Industry and Security, 2022; OpenAI, 2022). Segundo Markowitz (1952), não basta olhar só para o retorno de cada empresa. É preciso ver também como esses retornos afetam o risco do conjunto e a eficiência das carteiras.

Na fronteira recente da literatura, os avanços concentram-se na mensuração do capital intangível das empresas inovadoras e no uso de métodos mais sofisticados para a construção de portfólios (Ayyagari et al., 2024; Jensen et al., 2026). Sheng et al. (2026), por exemplo, verificam que *hedge funds* que adotaram IA generativa após o lançamento do ChatGPT obtiveram retornos anormais anualizados entre 2% e 4% superiores aos dos não adotantes. Esses resultados reforçam que as capacidades tecnológicas podem afetar tanto a valorização dos ativos quanto as decisões de alocação. Contudo, sua contribuição deve ser avaliada considerando conjuntamente retorno, risco, covariância e desempenho ajustado ao risco (Markowitz, 1952; Sharpe, 1966), sobretudo quando a exposição tecnológica é mensurada antes de uma mudança de regime.

Nesse contexto, o objetivo deste estudo é avaliar se a inclusão de empresas com elevada exposição prévia a patentes de IA melhorou a relação entre risco e retorno de carteiras diversificadas após a transição tecnológica de 2022. Para isso, utiliza-se uma base empresa-mês de 2000 a 2025, com a exposição tecnológica fixada em setembro de 2022, evitando que o desempenho posterior das ações influencie a classificação das empresas. O estudo contribui ao relacionar o capital intangível de IA à gestão de portfólios, examinando se essa exposição representa apenas uma fonte de valorização concentrada ou também uma característica relevante para a diversificação e o desempenho ajustado ao risco.

Este estudo está organizado da seguinte forma: a Seção 2 apresenta a fundamentação teórica sobre inovação, capital intangível e diversificação; a Seção 3 descreve os dados e a metodologia de construção das carteiras; a Seção 4 apresenta e discute os resultados; e a Seção 5 reúne as conclusões e implicações do estudo.

2 Fundamentação Teórica

Esta seção relaciona o capital intangível em IA ao valor de mercado das empresas (2.1) e baseia a avaliação de risco-retorno na Teoria Moderna do Portfólio e no Índice de Sharpe (2.2).

2.1 Capital Intangível, Patentes e Inteligência Artificial

O capital intangível reúne recursos como patentes, software, conhecimento organizacional e capacidades de pesquisa, que podem sustentar inovação, produtividade e vantagens competitivas das empresas no mercado. No caso da IA, seu valor pode depender também de infraestrutura computacional, capital humano e ativos complementares.

Babina et al. (2024) mostram que investimentos empresariais em IA estão associados ao crescimento das vendas, do emprego, da inovação de produtos e da avaliação de mercado. As patentes permitem mensurar parte desse conhecimento acumulado: Kogan et al. (2017) demonstram que informações patentárias ajudam a identificar o valor econômico das inovações, enquanto Hirshleifer et al. (2013) relacionam a eficiência inovadora aos retornos futuros das ações.

Depois de 2022, a difusão da IA generativa e o aumento da demanda por infraestrutura computacional ampliaram as oportunidades para empresas que já acumulavam conhecimento nessa área. Esse posicionamento anterior poderia facilitar o desenvolvimento de novos produtos, o crescimento das vendas e a geração de caixa, levando o mercado a rever suas expectativas sobre essas companhias. Assim, o estoque de patentes de IA é utilizado como medida da capacidade tecnológica acumulada antes dessa mudança no mercado (Kogan & Papanikolaou, 2019; Babina et al., 2024).

2.2 Teoria Moderna do Portfólio e Índice de Sharpe

A Teoria Moderna do Portfólio, desenvolvida por Markowitz (1952), estabelece que o risco de um ativo deve ser avaliado de acordo com sua contribuição para a variância e a covariância da carteira. A diversificação ocorre quando ativos com correlação inferior à unidade são combinados, permitindo reduzir o risco agregado ou elevar o retorno esperado para determinado nível de volatilidade.

Neste estudo, o desempenho das carteiras não depende apenas do retorno das empresas mais expostas à IA. Também importa a forma como essas ações se comportam em relação aos demais ativos. Uma carteira pode apresentar retorno maior e, ainda assim, não oferecer um resultado melhor caso esse ganho seja acompanhado por um aumento elevado do risco.

Para fazer essa comparação, utiliza-se o Índice de Sharpe, que relaciona o excesso de retorno da carteira à sua volatilidade (Sharpe, 1966). Quanto maior o índice, maior o retorno obtido por unidade de risco. Os critérios de formação das carteiras e as demais medidas utilizadas na avaliação de seu desempenho são apresentadas na metodologia.

3 Metodologia

Este capítulo descreve a construção do painel de dados e estoques de patentes (3.1), a estratégia de formação das carteiras (3.2) e as métricas estatísticas aplicadas para mensurar o desempenho (3.3 e 3.4).

3.1 Base de dados e construção do painel

A análise utiliza um painel mensal não balanceado de janeiro de 2000 a dezembro de 2025, composto por 35.727 observações empresa-mês de 174 companhias listadas, cada uma incluída apenas durante sua janela efetiva de negociação. A amostra não pretende representar todo o mercado acionário, mas reunir empresas líquidas e intensivas em inovação para as quais foi possível integrar informações financeiras e patentárias.

A seleção partiu das companhias de semicondutores e equipamentos classificadas no grupo histórico 4530 do GICS (*Global Industry Classification Standard*) e de quatro grupos de comparação: hardware tecnológico, software e plataformas, farmacêuticas e de biotecnologia e energia solar e limpa. Foram mantidas companhias com valor de mercado do *free float* superior a US$ 100 milhões em pelo menos um mês e volume médio diário negociado acima de US$ 500 mil. No grupo de hardware, foram excluídas aquelas cuja receita de semicondutores superasse 15% da receita por segmentos. Para software e plataformas, exigiu-se gasto em P&D superior a 10% da receita em pelo menos cinco anos; para farmacêuticas e biotecnológicas, o limite foi de 15%, além da seleção das maiores companhias por valor médio de mercado.

O grupo de energia solar e limpa foi mantido como comparação externa. Sendo considerada apenas uma listagem principal por companhia, foram removidas duplicidades pelo RIC (*Reuters Instrument Code*) e pelo ISIN (*International Securities Identification Number*) e preservadas empresas adquiridas ou retiradas da bolsa durante sua janela de negociação. A amostra final reúne 57 empresas de semicondutores, 27 de hardware, 30 de software e plataformas, 50 farmacêuticas e de biotecnologia e 10 de energia solar e limpa.

As informações financeiras foram extraídas do LSEG Workspace por meio de sua API e incluem retornos totais com dividendos reinvestidos, valor de mercado, volume negociado e outras características empresariais. Alterações de denominação, subsidiárias, aquisições e listagens múltiplas foram incorporadas à identificação histórica das companhias. As patentes relacionadas à IA foram obtidas no Google Patents Public Data por meio do Google BigQuery, com os nomes dos depositantes harmonizados a partir da OECD Harmonised Applicants Names e as classes tecnológicas validadas com a base COR&DIP.

Antes da construção do estoque, a base foi filtrada para manter apenas as publicações relacionadas à IA, de acordo com as classes tecnológicas validadas com a COR&DIP/IPC. As demais patentes foram excluídas e não entraram no cálculo da exposição das empresas. Os critérios de grupo foram aplicados separadamente para definir quais companhias fariam parte da amostra.

O arquivo utilizado na construção do estoque tecnológico contém 1.047.966 publicações relacionadas à IA, tratadas como registros agregados associados às empresas, e não como famílias de patentes distintas. A camada complementar COR&DIP/IPC reúne 335.848 patentes únicas e aproximadamente 1,16 milhão de registros patente-classe. Python foi utilizado na construção, integração e análise do painel e das carteiras, enquanto R foi empregado nas validações complementares.

O estoque mensal de patentes foi reconstruído pelo método de inventário perpétuo:

$$K_{i,t} = (1 - \delta_m)K_{i,t-1} + P_{i,t}, \qquad (1)$$

em que $K_{i,t}$ representa o estoque de patentes da empresa i no mês t, $P_{i,t}$ corresponde ao número de publicações atribuídas à empresa naquele mês e δ_m é a taxa mensal de depreciação:

$$\delta_m = 1 - (1 - 0{,}15)^{1/12}. \qquad (2)$$

A depreciação anual de 15% permite que conhecimentos mais antigos permaneçam no estoque com peso gradualmente menor, enquanto o uso das datas de publicação identifica o momento em que a informação tecnológica se torna pública. Essa abordagem é consistente com estudos que utilizam patentes para mensurar o valor econômico da inovação e sua relação com o desempenho das empresas (Kogan et al., 2017). A exposição principal é definida por $\log(1 + K_{i,t})$e fixada em 30 de setembro de 2022, evitando que retornos posteriores influenciem retrospectivamente a composição das carteiras. Entre as 161 empresas elegíveis nessa data, o percentil 75 da distribuição foi igual a 7,091, dando origem à seguinte classificação:

$$HighAI_i = \mathbb{1}\left[\log(1 + K_{i,\text{set.2022}}) \geq q_{0,75}\right]. \qquad (3)$$

As 41 empresas situadas no quartil superior formam a carteira de Alta IA, enquanto as 120 restantes constituem a carteira de Comparação. A carteira de Infraestrutura de IA reúne 32 empresas de Alta IA pertencentes aos segmentos de semicondutores, hardware ou software e plataformas.

A comparação considera três intervalos:

- período anterior: janeiro de 2000 a setembro de 2022;
- transição: outubro e novembro de 2022;
- período posterior: dezembro de 2022 a dezembro de 2025.

Os dois meses de transição são excluídos da comparação principal. O período anterior contém 273 meses, enquanto a janela posterior contém 37 meses.

3.2 Construção das carteiras

Então, foram construídas carteiras de Mercado, Alta IA, Comparação, Infraestrutura de IA e uma estratégia Combinada 50/50. A carteira de Mercado é formada pelo fator de excesso de retorno de mercado acrescido da taxa mensal livre de risco, ambos obtidos na Kenneth French Data Library e no painel financeiro. A biblioteca disponibiliza séries mensais dos fatores de mercado e dos modelos Fama–French.

Na ponderação igualitária, o retorno da carteira g no mês t é:

$$R_{g,t}^{EW} = \frac{1}{N_{g,t}} \sum_{i \in g_t} R_{i,t}\,, \qquad (4)$$

em que $N_{g,t}$ representa o número de empresas ativas na carteira.

Na ponderação pelo valor de mercado:

$$R_{g,t}^{VW} = \sum_{i \in g_t} w_{i,t}\, R_{i,t}, w_{i,t} = \frac{MV_{i,t}}{\sum_{j \in g_t} M\, V_{j,t}}, \qquad (5)$$

em que $MV_{i,t}$ corresponde ao valor de mercado da organização.

A especificação principal combina Mercado e Alta IA em proporções iguais:

$$R_t^{50/50} = 0{,}5R_t^{Mercado} + 0{,}5R_t^{HighAI}. \qquad (6)$$

Como teste de robustez, foram estimadas carteiras que maximizam o Índice de Sharpe:

$$\max_w \frac{w'\mu - r_f}{\sqrt{w'\Sigma w}}, \qquad (7)$$

sujeitas a:

$$1'w = 1{,}0 \leq w_j \leq c, c \in \{0{,}50; 0{,}60; 0{,}70\}. \qquad (8)$$

Os pesos foram estimados exclusivamente com os 60 meses anteriores a setembro de 2022 e aplicados, sem reestimação, de dezembro de 2022 a dezembro de 2025. Esse procedimento reduz o risco de selecionar retrospectivamente os pesos que apresentaram melhor desempenho. A avaliação fora da amostra é importante porque os pesos da carteira são definidos com dados anteriores a setembro de 2022 e mantidos fixos no período seguinte. Dessa forma, os retornos observados após 2022 não são usados para escolher a combinação que apresentou o melhor resultado, evitando superestimar o Índice de Sharpe da carteira (Jensen et al., 2026).

3.3 Mensuração do desempenho

Para comparar o desempenho das carteiras, foram calculados o retorno anualizado, a volatilidade, os índices de Sharpe e Sortino, a riqueza acumulada e o maximum drawdown. Também foram analisadas as correlações entre as carteiras e a evolução do Índice de Sharpe ao longo do tempo.

O retorno anualizado é calculado geometricamente:

$$R_{anual} = \left[\prod_{t=1}^{T}(1 + R_t)\right]^{12/T} - 1, \qquad (9)$$

e a volatilidade anualizada é:

$$\sigma_{anual} = s(R_t)\sqrt{12}. \qquad (10)$$

O Índice de Sharpe corresponde ao excesso médio de retorno por unidade de volatilidade:

$$SR = \frac{R_t - \bar{r}_{f,t}}{s(R_t - r_{f,t})}\sqrt{12}. \qquad (11)$$

A formulação segue Sharpe (1966), que propõe a comparação do retorno de uma estratégia relativamente à sua variabilidade. O Índice de Sortino utiliza somente os desvios negativos:

$$Sortino = \frac{R_t - \bar{r}_{f,t}}{\sqrt{T^{-1} \sum_{t=1}^{T} \min(R_t - r_{f,t}, 0)^2}} \sqrt{12}. \qquad (12)$$

A riqueza acumulada é dada por:

$$W_t = \prod_{\tau=1}^{t} (1 + R_\tau), \qquad (13)$$

enquanto o *maximum drawdown* corresponde à maior redução em relação ao pico anterior:

$$MDD = \min_t \left[\frac{W_t}{\max_{s \le t} W_s} - 1 \right]. \qquad (14)$$

Também foram calculadas as correlações entre as carteiras, o Sharpe móvel de 12 meses e as combinações de risco e retorno associadas à fronteira eficiente.

A incerteza das diferenças entre os índices de Sharpe foi avaliada por *bootstrap* em blocos, com 10.000 reamostragens e blocos de três e seis meses. Os retornos das carteiras comparadas foram reamostrados conjuntamente, preservando sua associação contemporânea e parte da dependência temporal. Foram calculados intervalos de confiança de 90% e 95% e valores de p. O emprego de blocos é apropriado para séries temporalmente dependentes, enquanto a inferência por *bootstrap* é recomendada para a comparação robusta entre índices de Sharpe (Künsch, 1989; Ledoit & Wolf, 2008).

4 Resultados

A seção apresenta a composição das carteiras (4.1) e evidencia que a exposição prévia à IA melhorou significativamente os retornos e o desempenho ajustado ao risco das carteiras após 2022 (4.2 a 4.4).

4.1 Composição e concentração das carteiras

Na carteira de Alta Exposição à IA, 42% das empresas pertencem ao setor de semicondutores, 32% a software e plataformas, 15% a hardware e 12% ao setor farmacêutico. A presença de quatro segmentos mostra que a classificação por patentes não formou uma carteira restrita a um único setor. Já a carteira de Infraestrutura de IA reúne apenas empresas de semicondutores, software e plataformas e hardware, que representam, respectivamente, 47%, 36% e 17% de sua composição.

Apesar de reunirem 41 e 32 empresas, respectivamente, as duas carteiras apresentam maior concentração quando os pesos são definidos pelo valor de mercado. Nesse tipo de ponderação, as companhias de maior capitalização recebem pesos mais elevados, enquanto as empresas menores têm participação reduzida. Assim, o desempenho da carteira passa a depender mais de um grupo limitado de grandes empresas, o que está de acordo com Babina et al. (2024), que identificam maior concentração dos investimentos em IA e de seus efeitos sobre crescimento e valorização entre companhias maiores.

4.2 Desempenho após 2022

A Figura 1 compara retorno anualizado, volatilidade, Índice de Sharpe e *maximum drawdown* nos períodos anterior e posterior a 2022. A principal mudança ocorre nas carteiras ponderadas por valor de mercado, para as quais a exposição à IA passou a apresentar desempenho substancialmente superior após a transição.

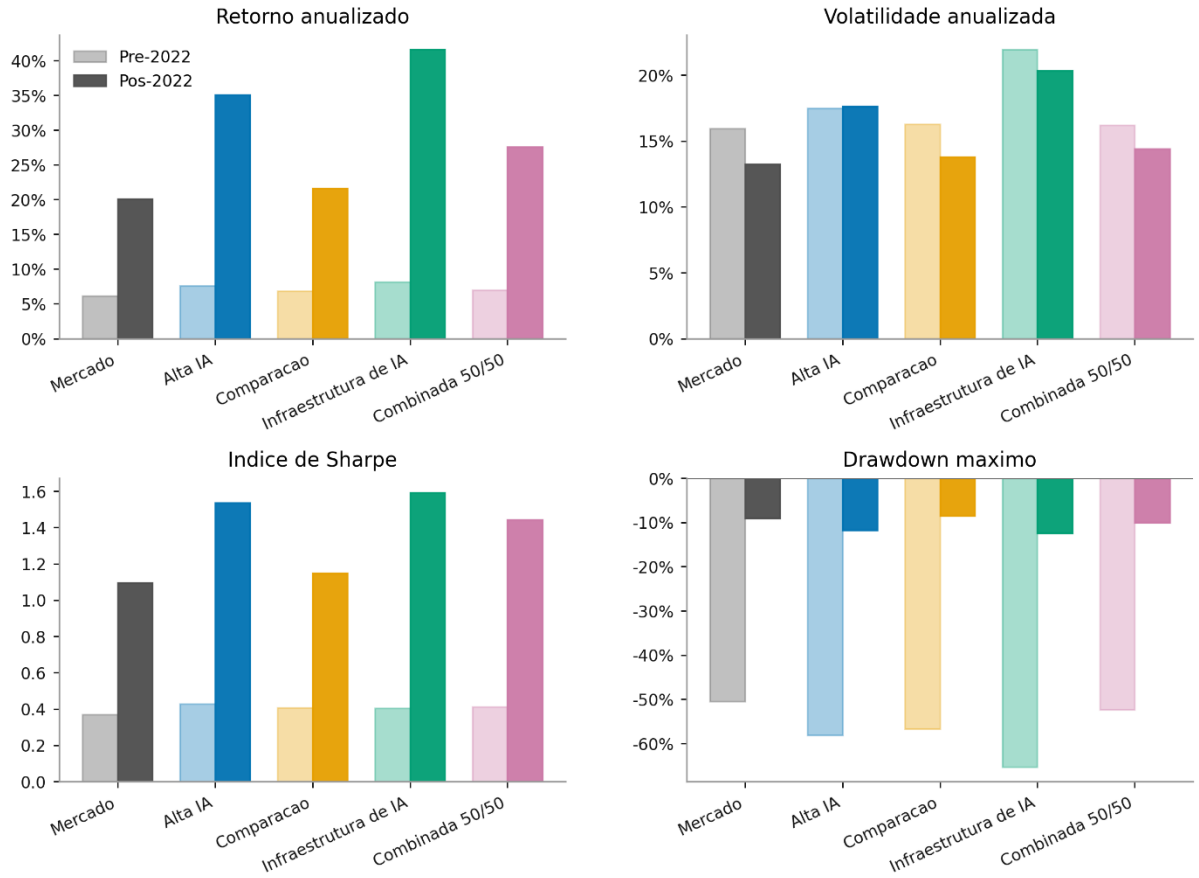

Figura 1 — Retorno, volatilidade, Índice de Sharpe e *maximum drawdown* antes e depois de 2022

Fonte: Elaborado pelos autores.

A Tabela 1 apresenta o desempenho das carteiras no período posterior a 2022. Na ponderação igualitária, a carteira de Alta Exposição à IA teve retorno anualizado de 22,6% e Índice de Sharpe de 1,169. A carteira Combinada 50/50, composta por partes iguais de Mercado e Alta Exposição à IA, alcançou Sharpe de 1,223, volatilidade de 12,7% e a menor perda máxima do grupo, de 8,7%. Na ponderação por valor de mercado, a diferença foi maior. A carteira de Alta IA registrou retorno de 35,1% e Sharpe de 1,536, enquanto a de Infraestrutura de IA chegou a 41,6% de retorno e Sharpe de 1,592. A carteira Combinada 50/50 também ficou acima do Mercado, com retorno de 27,6% e Sharpe de 1,443, frente a 1,094 da carteira de Mercado.

Tabela 1 — Desempenho das carteiras no período posterior a 2022

Ponderação	Carteira	Retorno anualizado	Volatilidade	Sharpe	Sortino	*Maximum drawdown*
Igualitária	Mercado	20,1%	13,2%	1,094	1,939	−9,1%
Igualitária	Alta IA	22,6%	14,3%	1,169	2,349	−12,1%
Igualitária	Comparação	20,1%	14,3%	1,019	1,810	−9,4%
Igualitária	Infraestrutura de IA	29,4%	17,6%	1,289	3,595	−11,9%
Igualitária	Combinada 50/50	21,5%	12,7%	1,223	2,204	−8,7%
Valor de mercado	Mercado	20,1%	13,2%	1,094	1,939	−9,1%
Valor de mercado	Alta IA	35,1%	17,6%	1,536	3,158	−11,7%
Valor de mercado	Comparação	21,6%	13,8%	1,149	1,940	−8,5%
Valor de mercado	Infraestrutura de IA	41,6%	20,3%	1,592	3,170	−12,4%
Valor de mercado	Combinada 50/50	27,6%	14,4%	1,443	2,471	−10,1%

Fonte: Elaborado pelos autores.

Antes de 2022, os Sharpes de Alta Exposição à IA e Comparação eram próximos (0,428 e 0,406); após a transição, a diferença aumentou para 0,387, afastando a hipótese de prêmio permanente. A otimização elevou o Sharpe para 1,503. A Figura 2 mostra que, com a riqueza normalizada em dezembro de 2022, as carteiras de Alta Exposição e Infraestrutura de IA passaram a crescer mais rapidamente, sobretudo na ponderação por valor de mercado, enquanto Mercado e Comparação mantiveram trajetórias inferiores.

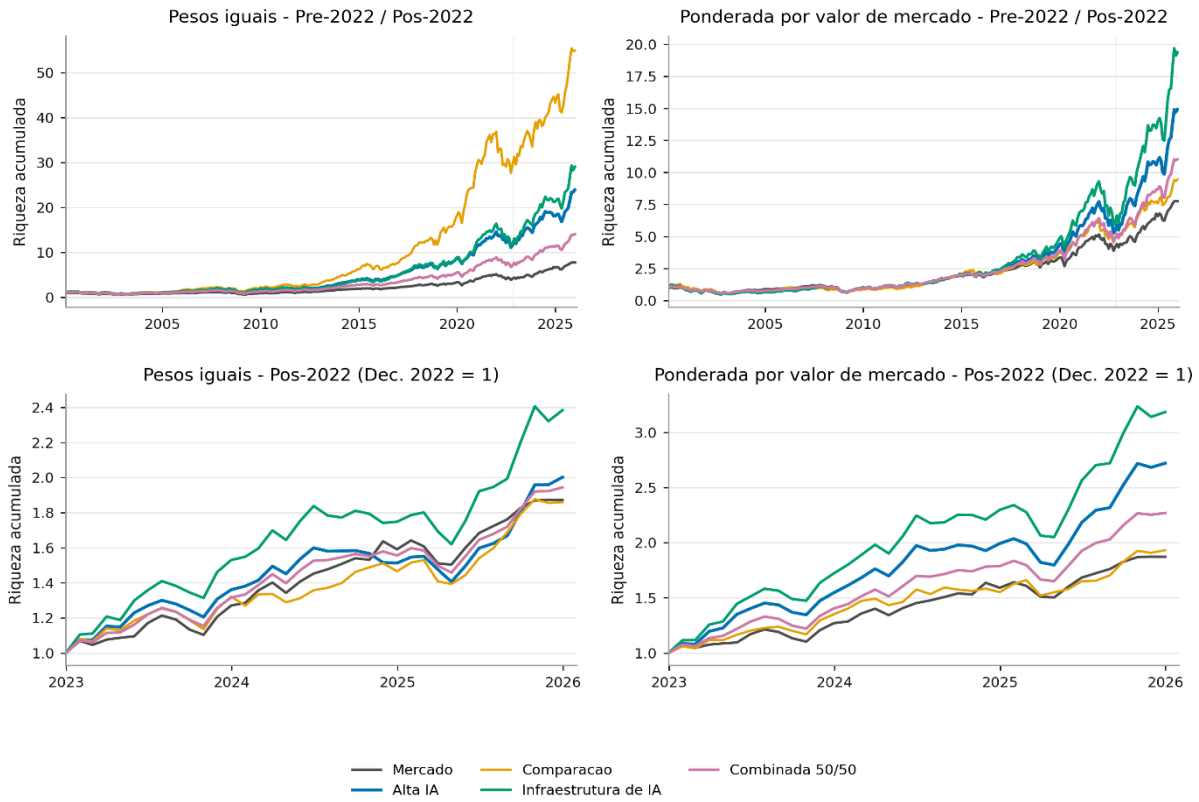

Figura 2 — Riqueza acumulada das carteiras antes e depois de 2022

Fonte: Elaborado pelos autores.

4.3 Correlações e benefícios da diversificação

A Figura 3 apresenta as correlações entre as carteiras nos períodos anterior e posterior a 2022. Na ponderação por valor de mercado, a correlação entre a carteira de Alta Exposição à IA e o Mercado caiu de 0,88 para 0,74, enquanto sua correlação com a carteira de Comparação diminuiu de 0,86 para 0,81. A correlação entre a estratégia Combinada 50/50 e o Mercado também recuou de 0,97 para 0,91, indicando maior diferenciação da exposição tecnológica após 2022.

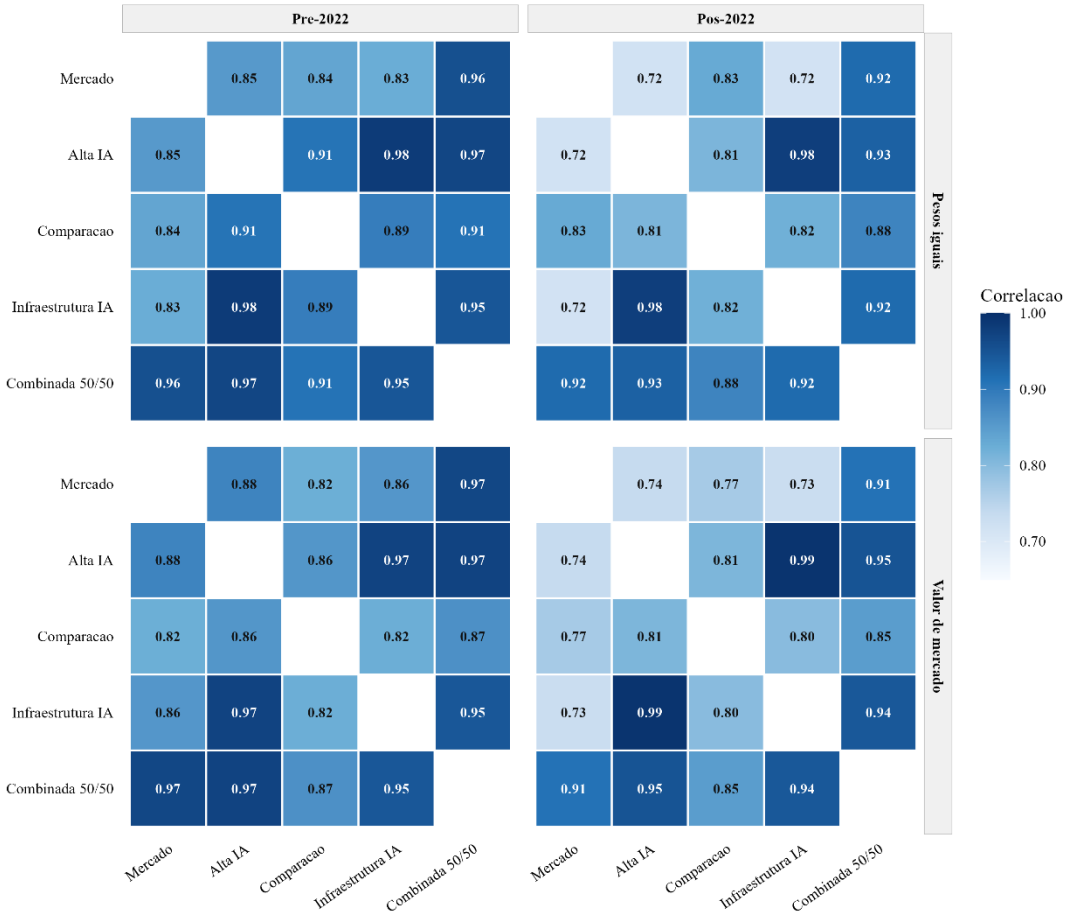

Figura 3 — Correlações entre as carteiras antes e depois de 2022

Fonte: Elaborado pelos autores.

Essa redução ajuda a explicar por que a estratégia Combinada 50/50 alcançou Sharpe de 1,443, acima dos 1,094 do Mercado, mantendo volatilidade inferior à da carteira de Alta Exposição à IA. O resultado é coerente com Markowitz (1952), segundo o qual os benefícios de uma carteira dependem não apenas dos retornos individuais, mas também das covariâncias entre seus componentes. Entretanto, a correlação entre Alta IA e Infraestrutura de IA aumentou de 0,97 para 0,99, mostrando que a combinação dessas duas carteiras oferece pouca diversificação adicional.

A otimização reforça essa interpretação: na ponderação por valor de mercado, o Sharpe aumentou de 1,443 para 1,503 quando o limite máximo de Alta IA passou de 50% para 70%, e os pesos atingiram todos os limites permitidos. Assim, os ganhos decorrem principalmente do desempenho superior das empresas com maior exposição tecnológica, e não exclusivamente da redução do risco por diversificação. Esse resultado é consistente com Kogan e Papanikolaou (2019), que relacionam inovação e capital intangível à precificação dos ativos e às mudanças nos fluxos de caixa esperados e nas taxas de desconto.

4.4 Inferência por *bootstrap*

Como o período posterior a 2022 contém apenas 37 observações mensais, as diferenças entre os índices de Sharpe foram avaliadas por *bootstrap* em blocos, com reamostragens e blocos de três e seis meses. O procedimento preserva parte da dependência temporal dos retornos e permite avaliar se as diferenças observadas são

consistentes, em vez de decorrerem de variações ocasionais da amostra (Künsch, 1989; Ledoit & Wolf, 2008).

Tabela 2 — Diferenças dos índices de Sharpe por *bootstrap*

Ponderação	Comparação	Diferença	Bloco	IC de 90%	IC de 95%	p	Reamostragens
Igualitária	Alta IA − Comparação	0,150	3	[−0,614; 0,773]	[−0,796; 0,889]	0,734	10.000
Igualitária	Alta IA − Comparação	0,150	6	[−0,750; 0,751]	[−0,960; 0,874]	0,846	10.000
Valor de mercado	Alta IA − Comparação	0,387	3	[−0,022; 0,806]	[−0,119; 0,912]	0,108	10.000
Valor de mercado	Alta IA − Comparação	0,387	6	[0,049; 0,834]	[−0,031; 0,946]	0,061	10.000
Valor de mercado	Combinada 50/50 − Mercado	0,349	3	[0,032; 0,675]	[−0,038; 0,753]	0,056	10.000
Valor de mercado	Combinada 50/50 − Mercado	0,349	6	[0,007; 0,669]	[−0,069; 0,748]	0,092	10.000
Valor de mercado	Infraestrutura de IA − Mercado	0,498	3	[−0,020; 0,980]	[−0,132; 1,097]	0,124	10.000
Valor de mercado	Infraestrutura de IA − Mercado	0,498	6	[−0,104; 1,009]	[−0,230; 1,138]	0,178	10.000

Fonte: Elaborado pelos autores.

A Tabela 2 mostra que, na ponderação igualitária, a diferença de Sharpe entre as carteiras de Alta Exposição à IA e de Comparação foi de 0,150, sem significância estatística. Na ponderação por valor de mercado, a diferença aumentou para 0,387 e alcançou significância de 10% com blocos de seis meses ($p = 0{,}061$), embora o intervalo de 95% ainda inclua zero. A estratégia Combinada 50/50 também apresentou melhora em relação ao Mercado, com diferença de 0,349 e intervalos de 90% positivos, enquanto os resultados da carteira de Infraestrutura de IA permaneceram estatisticamente imprecisos.

Em conjunto, os resultados oferecem apoio econômico, mas apenas evidência estatística moderada, à hipótese de que a exposição prévia à IA melhorou o desempenho ajustado ao risco após 2022. Os ganhos foram mais fortes entre empresas de maior valor de mercado e decorreram principalmente de retornos superiores, não apenas da redução das correlações. Essa interpretação é compatível com a concentração do capital intangível em grandes empresas e com estudos recentes sobre o uso da IA na gestão de ativos e na construção de fronteiras eficientes implementáveis (Ayyagari et al., 2024; Jensen et al., 2026; Sheng et al., 2026).

5 Discussão

A diferença entre os períodos indica que o estoque de patentes de IA não esteve associado a um prêmio permanente. Antes de 2022, o desempenho das empresas mais expostas era semelhante ou inferior ao do grupo de comparação; posteriormente, porém, a vantagem aumentou, sobretudo quando ponderada pelo valor de mercado. Esse padrão sugere uma valorização condicionada ao ambiente tecnológico, e não uma característica invariável das empresas.

Uma possível explicação está na mudança no mercado de IA ocorrida após 2022. O avanço da IA generativa e a demanda por infraestrutura computacional podem ter favorecido empresas que já reuniam conhecimento, patentes e outros recursos nessa área. Esse posicionamento anterior teria melhorado as expectativas de vendas, de crescimento e de geração de caixa, contribuindo para a valorização das ações. Essa interpretação é compatível com a relação entre inovação, capital intangível e preços dos ativos discutida por Kogan e Papanikolaou (2019), bem como com os efeitos empresariais da adoção de IA identificados por Babina et al. (2024). Ainda assim, os resultados mostram uma associação entre exposição anterior e desempenho posterior, sem permitir afirmar que as patentes, isoladamente, causaram a valorização observada. Mudanças regulatórias e incertezas políticas também podem afetar os retornos esperados e as taxas de desconto (Pástor & Veronesi, 2012, 2013).

Sob a perspectiva das carteiras, os resultados não representam apenas um benefício tradicional de diversificação. A estratégia combinada apresentou Sharpe superior ao do mercado e menor volatilidade do que a carteira mais exposta, mas as otimizações atingiram os limites máximos permitidos e a correlação entre a exposição tecnológica e a infraestrutura chegou a 0,99. Portanto, a melhora decorreu principalmente dos retornos superiores das empresas mais intensivas em IA, embora a redução de algumas correlações também tenha contribuído para o desempenho conjunto.

Essa interpretação tem relevância prática porque investidores demonstram interesse crescente em IA, mas ainda alocam pouco em infraestrutura de IA (J.P. Morgan, 2026). Os resultados sugerem que as patentes podem complementar os indicadores financeiros na identificação de capacidades tecnológicas. A evidência estatística permanece moderada e sensível à ponderação, ao corte classificatório e às restrições de concentração, o que recomenda cautela na transformação dos achados em estratégias de investimento (Abate et al., 2022).

6 Considerações Finais

Este estudo avaliou o uso do estoque de patentes de IA na formação de carteiras, considerando as capacidades acumuladas pelas empresas antes da mudança tecnológica de 2022. Como a exposição foi fixada em setembro daquele ano, a classificação das empresas não foi influenciada pela valorização observada no período posterior.

Os resultados mostram que as empresas com maior exposição prévia à IA apresentaram melhor desempenho ajustado ao risco depois de 2022, principalmente na ponderação por valor de mercado. A combinação dessas empresas com a carteira de Mercado também apresentou resultado superior ao Mercado isoladamente, embora a melhora tenha vindo mais dos retornos das empresas expostas do que da redução do risco pela diversificação.

A principal contribuição do estudo está no uso de informações patentárias para identificar capacidades tecnológicas construídas antes de sua maior valorização pelo mercado. O estoque de patentes de IA não substitui os indicadores financeiros usados na análise de investimentos, mas acrescenta uma informação que normalmente não aparece nas medidas de retorno, risco ou valor de mercado. Seu uso pode ajudar a diferenciar empresas que já possuíam conhecimento acumulado daquelas que passaram a se posicionar somente após a expansão recente da IA.

As conclusões dependem do corte utilizado para definir a Alta IA, da forma de ponderação das carteiras e do período posterior analisado. Estudos futuros podem ampliar essa janela, testar outros percentis de exposição e atribuir pesos diferentes às patentes conforme suas citações ou relevância tecnológica. Também seria possível atualizar a classificação ao longo do tempo e aplicar o mesmo procedimento a outras amostras e mercados, sem alterar a lógica central adotada neste trabalho.

7 Referências Bibliográficas

Abate, G., Bonafini, T., & Ferrari, P. (2022). Portfolio constraints: An empirical analysis. *International Journal of Financial Studies, 10*(1), Article 9. https://doi.org/10.3390/ijfs10010009

Ayyagari, M., Demirgüç-Kunt, A., & Maksimovic, V. (2024). The rise of star firms: Intangible capital and competition. *The Review of Financial Studies, 37*(3), 882–949. https://doi.org/10.1093/rfs/hhad065

Babina, T., Fedyk, A., He, A. X., & Hodson, J. (2024). Artificial intelligence, firm growth, and product innovation. *Journal of Financial Economics, 151*, Article 103745. https://doi.org/10.1016/j.jfineco.2023.103745

Bureau of Industry and Security. (2022, October 7). *Commerce implements new export controls on advanced computing and semiconductor manufacturing items to the People's Republic of China (PRC).* U.S. Department of Commerce. https://www.bis.gov/press-release/commerce-implements-new-export-controls-advanced-computing-semiconductor-manufacturing-items-peoples

El Khoury, R., Alshater, M. M., & Li, Y. (2023). Multidimensional connectedness among the fourth industrial revolution assets. *Borsa Istanbul Review, 23*(4), 953–979. https://doi.org/10.1016/j.bir.2023.04.002

Google. (2026). *Google Patents Public Data on BigQuery* [Data set]. GitHub. https://github.com/google/patents-public-data

Hirshleifer, D., Hsu, P.-H., & Li, D. (2013). Innovative efficiency and stock returns. *Journal of Financial Economics, 107*(3), 632–654. https://doi.org/10.1016/j.jfineco.2012.09.011

Jensen, T. I., Kelly, B., Malamud, S., & Pedersen, L. H. (2026). Machine learning and the implementable efficient frontier. *The Review of Financial Studies*, Article hhag022. https://doi.org/10.1093/rfs/hhag022

J.P. Morgan Private Bank. (2026). *2026 global family office report: A worldwide view into family office strategy*. https://privatebank.jpmorgan.com/nam/en/insights/reports/2026-family-office-report

Kogan, L., & Papanikolaou, D. (2019). Technological innovation, intangible capital, and asset prices. *Annual Review of Financial Economics, 11*, 221–242. https://doi.org/10.1146/annurev-financial-110118-123049

Kogan, L., Papanikolaou, D., Seru, A., & Stoffman, N. (2017). Technological innovation, resource allocation, and growth. *The Quarterly Journal of Economics, 132*(2), 665–712. https://doi.org/10.1093/qje/qjw040

Künsch, H. R. (1989). The jackknife and the bootstrap for general stationary observations. *The Annals of Statistics, 17*(3), 1217–1241. https://doi.org/10.1214/aos/1176347265

Ledoit, O., & Wolf, M. (2008). Robust performance hypothesis testing with the Sharpe ratio. *Journal of Empirical Finance, 15*(5), 850–859. https://doi.org/10.1016/j.jempfin.2008.03.002

London Stock Exchange Group. (2026). *LSEG Workspace*. https://www.lseg.com/en/data-analytics/products/workspace

Markowitz, H. (1952). Portfolio selection. *The Journal of Finance, 7*(1), 77–91. https://doi.org/10.1111/j.1540-6261.1952.tb01525.x

Mercer. (2026). Moving beyond the AI pitch: Asset managers' use of AI [Report]. https://www.mercer.com/insights/investments/market-outlook-and-trends/asset-managers-use-of-ai/

OpenAI. (2022, November 30). *Introducing ChatGPT*. https://openai.com/index/chatgpt/

OECD. (2026). *Harmonised applicants' names (HAN) database* [Data set]. https://www.oecd.org/sti/inno/intellectual-property-statistics-and-analysis.htm

OECD. (2025). *Competition in artificial intelligence infrastructure* (OECD Roundtables on Competition Policy Papers No. 330). https://doi.org/10.1787/623d1874-en

Pástor, Ľ., & Veronesi, P. (2012). Uncertainty about government policy and stock prices. *The Journal of Finance, 67*(4), 1219–1264. https://doi.org/10.1111/j.1540-6261.2012.01746.x

Pástor, Ľ., & Veronesi, P. (2013). Political uncertainty and risk premia. *Journal of Financial Economics, 110*(3), 520–545. https://doi.org/10.1016/j.jfineco.2013.08.007

Sharpe, W. F. (1966). Mutual fund performance. *The Journal of Business, 39*(1), 119–138. https://doi.org/10.1086/294846

Sheng, J., Sun, Z., Yang, B., & Zhang, A. L. (2026). Generative AI and asset management. *The Review of Financial Studies*, Article hhag050. https://doi.org/10.1093/rfs/hhag050

United Nations Conference on Trade and Development (UNCTAD). (2025). *Technology and innovation report 2025: Inclusive artificial intelligence for development*. United Nations. https://unctad.org/publication/technology-and-innovation-report-2025