

**UNIVERSIDADE DE SÃO PAULO**  
**FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE**  
**DEPARTAMENTO DE ECONOMIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA**

**ESSAYS ON MUTUAL FUNDS**

**ENSAIOS SOBRE FUNDOS DE INVESTIMENTOS**

**Elias Cavalcante Filho**

**Orientador: Prof. Dr. Rodrigo De Losso da Silveira Bueno**

**SÃO PAULO**

**2020**

Prof. Dr Vahan Agopyan  
Reitor da Universidade de São Paulo

Prof. Dr. Fabio Frezatti  
Diretor da Faculdade de Economia, Administração e Contabilidade

Prof. Dr José Carlos de Souza Santos  
Chefe do Departamento de Economia

Prof. Dr. Ariaster Baumgratz Chimeli  
Coordenador do Programa de Pós-Graduação em Economia

**ELIAS CAVALCANTE FILHO**

**ESSAYS ON MUTUAL FUNDS**

**ENSAIOS SOBRE FUNDOS DE INVESTIMENTOS**

Tese apresentada ao Programa de Pós-Graduação em Economia do Departamento de Economia da Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo como requisito parcial para a obtenção do título de Doutor em Ciências.

Área de Concentração: Teoria Econômica

**Orientador: Prof. Dr. Rodrigo De Losso da  
Silveira Bueno**

**Versão Original**

**SÃO PAULO**

**2019**



## **Catálogo na Publicação**

Ficha Catalográfica com dados inseridos pelo autor

Cavalcante Filho, Elias.

Ensaio sobre fundos de investimento / Elias Cavalcante Filho. – São Paulo, 2020.  
103 p.

Tese (Doutorado) – Universidade de São Paulo, 2020.  
Bibliografia.

1. Finanças. 2. Fundos de investimento. 3. Modelos fatoriais. 4. desempenho. 5.  
ETF. I. Universidade de São Paulo. Faculdade de Economia, Administração e  
Contabilidade. II. Título.



## **AGRADECIMENTOS**

Agradeço

ao meu orientador Rodrigo De Losso pela orientação e cada ensinamento ao longo deste trabalho.

aos professores Alan De Genaro, Bruno Giovannetti e Fernando Chague pelos comentários nas versões preliminares desta tese.

ao professor José Carlos pelas diversas sugestões e contribuições ao longo desses anos.

aos meus pais, Elias e Miriam, pela sabedoria partilhada e aos meus irmãos, Laura e Alfredo, por todo apoio.

aos meus companheiros de jornada Bruno Paliolol, Alexander Chow, Gabriel Oliveira, Denise Li, Bruno Cordeiro, Eduardo Astorino, André Roncaglia e Joelson Sampaio por toda experiência compartilhada.

à minha esposa Fabiana Pansonato por todos momentos de paciência e companheirismo.

O presente trabalho foi realizado com apoio da Fundação Instituto de Pesquisas Econômicas (Fipe) e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).



## RESUMO

A tese explora dados de fundos de investimento em ações e traz evidências sobre os mecanismos de avaliação dos seus investidores, desempenho dos seus gestores, e características sobre a distribuição dos seus retornos. No capítulo 1 se investigam os determinantes dos fluxos de recursos para fundos de investimentos brasileiros. Constata-se que investidores são mais atentos ao risco de mercado (beta) ao avaliar fundos, e atribuem à habilidade do gestor (alfa) os retornos atrelados aos demais fatores de risco como tamanho, valor, *momentum*, iliquidez e risco de indústrias. Adicionalmente, usando medidas de variação da sofisticação de investidores, confirma-se a hipótese de que investidores mais sofisticados tendem a avaliar fundos com base em critérios mais complexos. No capítulo 2 analisa-se a relação entre fatores climáticos e o desempenho dos fundos. Conclui-se que, apesar dos gestores dos fundos, a princípio, trabalharem em locais climatizados e com iluminação artificial adequada, existe relação entre fatores climáticos externos e os desempenhos dos fundos. Essa relação se mostra côncava para temperatura, o que implica em região de temperatura ótima em termos de produtividade. Além disso, observam-se efeitos distintos a depender das condições climáticas médias da região e data analisadas, por exemplo, aumentos de temperatura em locais de clima frio têm efeitos nulos, ao passo que em regiões de clima quente aumentos de 1°C têm efeitos negativos de 0,03% sobre os retornos dos fundos. Por fim, no capítulo 3, é examinada a distribuição de retornos dos fundos quando utilizados ETFs como *benchmarks*. Conclui-se que conjuntos de 3 a 5 ETFs são ideais para replicar o desempenho de fundos de gestão ativa, porém por meio da seleção aleatória de ETFs não é possível explicar a variabilidade de desempenho dos fundos. Assim sendo, são propostos algoritmos para seleção de ETF, com os quais estima-se que 95% dos fundos de gestão ativa não geram valor aos seus investidores.



## ABSTRACT

The thesis explores equity mutual funds data and provides evidence on the valuation mechanisms of their investors, the performance of their managers and characteristics about the distribution of their returns. In Chapter 1 we investigate the determinants of flows to Brazilian mutual funds. We observe that investors attend most to market risk (beta) when evaluating funds, but they treat returns linked to other risk factors such as size, value, momentum, illiquidity and risk of industries as the ability of the manager (alpha). Additionally, using proxies for variation in investor sophistication, we confirm the hypothesis that more sophisticated investors tend to evaluate funds based on more complex criteria. In Chapter 2 we analyze the relation between weather and the fund's performance. We conclude that, although funds' managers work in a climate-controlled environment and with artificial lighting, there is a relation between external weather and the funds' performance. This relation is concave for temperature, which implies an optimal temperature region in terms of productivity. Moreover, different effects are observed depending on the average climatic conditions of the region and time; for instance, an increase in temperature level in cold climate places has no effect, while in a hot climate region, an increase of 1°C has the negative effect of 0.03% on the fund's returns. Finally, in Chapter 3 we use Exchange Traded Funds (ETFs) instead of risk factors as benchmarks to examine active mutual fund performance distribution. We conclude that sets of 3 to 5 ETFs replicate most levels of active fund performance. Finally, we propose specific ETF selection algorithms, whereby we estimate that 95% of active management funds fail to generate value for their investors.



# ÍNDICE

<b>1. QUAIS OS FATORES DE RISCO RELEVANTES AOS INVESTIDORES? EVIDÊNCIAS NO MERCADO DE FUNDOS BRASILEIRO .....</b>	<b>15</b>
1.1. RESUMO.....	15
1.2. INTRODUÇÃO .....	15
1.3. MÉTODOS E DADOS.....	17
1.3.1. Fonte de dados .....	17
1.3.2. Captação Líquida de Recursos .....	18
1.3.3. Métricas de Retorno .....	18
1.3.4. Competição entre modelos.....	21
1.3.5. Decomposição de Retornos.....	24
1.4. ANÁLISE DESCRITIVA .....	25
1.5. RESULTADOS .....	29
1.5.1. Quais fatores importam aos investidores?.....	29
1.5.2. Decomposição de Retornos.....	30
1.5.2.1. Decomposição do alfa.....	34
1.6. COMPARAÇÃO COM RESULTADOS DA LITERATURA .....	38
1.7. CONCLUSÃO.....	39
<b>2. EVIDÊNCIAS DO IMPACTO DE FATORES CLIMÁTICOS SOBRE O DESEMPENHO DE FUNDOS DE INVESTIMENTO .....</b>	<b>41</b>
2.1. RESUMO.....	41
2.2. INTRODUÇÃO .....	41
2.3. LITERATURA .....	43
2.4. MÉTODOS E DADOS.....	45
2.4.1. Fonte de dados .....	45
2.4.2. Métricas de Retorno .....	45
2.4.3. Métricas de Climáticas .....	46
2.5. ANÁLISE DESCRITIVA .....	47
2.5.1. Fundos de Investimentos analisados .....	48
2.5.2. Informações climáticas analisadas .....	51
2.6. RESULTADOS .....	53
2.6.1. Relação entre desempenho e variações climáticas .....	53
2.6.2. Efeitos considerando diferentes parâmetros médios de longo prazo .....	56
2.6.3. Métricas de desempenho alternativas .....	60
2.6.4. Avaliação com dados dos Estados Unidos .....	62
2.7. CONCLUSÃO.....	65
<b>3. UNSKILLED FUND MANAGERS: REPLICATING ACTIVE FUND PERFORMANCE WITH FEW ETFS..67</b>	<b>67</b>
3.1. ABSTRACT .....	67
3.2. INTRODUCTION .....	67
3.3. METHODOLOGY .....	69
3.3.1. FDR Approach to Estimate Skilled Proportion Funds.....	70
3.3.1.1. Calculation Procedure for $\pi_0$ .....	72
3.3.1.2. Simulated Example .....	72
3.3.2. Random ETF Selection .....	74
3.3.3. Proposed ETF Algorithm Selection (PS) .....	75
3.3.4. Lasso Selection regarding Risk Factors .....	77
3.3.5. Forward Selection regarding Risk Factors .....	78
3.4. DATA.....	78
3.5. RESULTS .....	81
3.5.1. Benchmark potential of ETFs .....	81
3.5.2. ETF Selection.....	86
3.5.2.1. ETF selection based on fund performance .....	86
3.5.2.1.1. Cross-validation.....	88
3.5.2.2. ETF selection based on risk factors.....	91
3.5.2.3. Growth impact on the number of ETFs .....	94
3.6. CONCLUSION.....	95
APPENDIX.....	97
A1. Procedure to compute alpha p-value for each fund $\pi_i$ .....	97
A2. Procedure to compute optimal lambda from the data $\lambda^*$ .....	97
A3. Procedure to compute optimal gamma from the data $\gamma^*$ .....	98
A4. Standard Deviation Estimators .....	98
<b>REFERÊNCIAS .....</b>	<b>99</b>



# **1. Quais os fatores de risco relevantes aos investidores? Evidências no mercado de fundos brasileiro**

## **1.1. Resumo**

Neste artigo investiga-se o que determina o fluxo de recursos para fundos de investimentos brasileiros. Constata-se que investidores são mais atentos ao risco de mercado (beta) ao avaliar fundos, enquanto tendem a atribuir o retorno de fatores como tamanho, valor, momentum, iliquidez e risco de indústrias ao alfa. Usando medidas de variação da sofisticação de investidores, constata-se também que investidores mais sofisticados tendem a avaliar fundos com base em critérios mais complexos. O resultado é aderente ao observado para os EUA. Adicionalmente, é observado que investidores menos sofisticados demonstram ser mais sensíveis a todas métricas de retorno passado porém, ao decompor os alfas dos fundos em componente persistente e componente aleatório, evidencia-se que essa sensibilidade está concentrada no componente aleatório dos alfas.

## **1.2. Introdução**

Neste artigo identifica-se que o CAPM é o modelo que melhor representa o processo de avaliação do desempenho dos fundos de ações brasileiros. Além disso, constata-se que investidores experientes fazem uso de modelos mais complexos e têm melhor capacidade na distinção entre risco e habilidade sobre os retornos passados dos fundos.

Quando um investidor opta por um fundo de gestão ativa em detrimento de um fundo de gestão passiva, espera-se que o investidor privilegie a alocação em fundos com gestores com maior habilidade e capazes de gerar retornos acima dos obtidos por meio de gestão passiva. Nesse sentido, os investidores recompensam os gestores mais habilidosos com novos aportes e penalizam os gestores sem habilidade com resgates. Como fonte de informações, investidores têm acesso aos retornos passados dos fundos e ao histórico dos fatores de risco. Nesse contexto, o alfa de um fundo, definido como a parcela do retorno não atrelada aos fatores de risco, é a medida capaz de identificar os gestores habilidosos capazes de obter retornos superiores aos obtidos apenas pela exposição aos fatores de risco (Barber, Huang, & Odean, 2016; Berk & van Binsbergen, 2017; Berk & Van Binsbergen, 2016).

Sendo assim, o investidor só eleva o volume de investimentos em um fundo em detrimento de outro quando esse apresenta maior alfa. Portanto, ao relacionar a captação líquida de recursos

contra os componentes do retorno do fundo, espera-se que a captação seja sensível ao alfa, porém não aos retornos do fundo atrelados aos fatores de risco.

As conclusões do artigo são obtidas pela análise da relação entre as informações de captação líquida e desempenho passado dos fundos. O alto (baixo) desempenho de um fundo é interpretado como sinalização da habilidade do gestor e supõe-se que investidores buscam alocar seus recursos em fundos com gestores habilidosos. Os dados utilizados se referem às informações mensais dos fundos brasileiros de ações com gestão ativa no período entre janeiro de 2001 e abril de 2019.

O artigo segue a metodologia semelhante a proposta por Barber et al. (2016), em que se exploram casos de divergência entre a classificação dos fundos por diferentes métodos de se calcular o alfa de um fundo. Essas situações são avaliadas de modo que, se o fluxo de entrada (saída) de recursos é mais intenso, conclui-se que a métrica que classifica o fundo como bom (ruim) é a mais relevante na tomada de decisão. Isso ocorre, por exemplo, supondo uma situação em que determinado fundo é classificado dentre os melhores de acordo com o alfa do CAPM. Todavia, de acordo com o alfa do modelo de três fatores (Fama & French, 1992, 1993), o fundo é classificado dentre os piores. Nessa situação, caso se observe entrada de recursos do fundo, avalia-se que o alfa do CAPM é a métrica mais condizente com o comportamento dos investidores. O oposto vale se for observada saída de recursos.

Adicionalmente, decompõe-se o retorno dos fundos em termos dos fatores de risco que compõem tal retorno. Retornos atrelados aos fatores de risco são definidos pela multiplicação realização do fator de risco e a sensibilidade (exposição) do fundo a esse fator. Entendem-se esses componentes como as parcelas do retorno explicadas pelas realizações dos fatores de risco e o retorno não explicado como decorrente da habilidade do gestor, isto é, o alfa do fundo. Por fim, analisa-se como esses componentes se relacionam aos fluxos de investimento dos fundos e como medidas de variação da sofisticação do investidor no tempo (*investor sentiment*) e entre fundos (restrição investidores qualificados e investimento mínimo) afetam os resultados.

Posteriormente, é realizada uma decomposição adicional dos alfas dos fundos em componente persistente e aleatório. Dessa forma, o componente persistente é a parcela do alfa explicada pela realização futura do alfa. Já o componente aleatório corresponde à parcela restante. Essa decomposição permite tratar possíveis imperfeições dos alfas, tais como potencial falha na distinção completa entre o retorno atrelado à habilidade do gestor e o retorno decorrente de risco ou efeitos aleatórios.

Constata-se que os investidores são mais atentos ao risco de mercado (beta) e avaliam como alfa do fundo os retornos relacionados aos fatores de risco como tamanho, valor, *momentum*, iliquidez e exposição a setores da indústria. Além disso, evidencia-se que investidores mais sofisticados utilizam métricas de desempenho mais elaboradas para fazer distinção entre risco e habilidade dos gestores. Por fim, constata-se que investidores menos sofisticados são mais sensíveis a todas métricas de retorno, sejam elas relacionadas ao alfa ou aos componentes de risco do fundo, no entanto, ao se decompor os alfas em componente persistente e componente aleatório, observa-se que a maior sensibilidade dos investidores menos sofisticados ao alfa provém da forte sensibilidade ao seu componente aleatório.

O presente artigo contribui com trabalhos desenvolvidos por Agarwal, Green, & Ren (2018); Barber et al. (2016); Berk & van Binsbergen (2017); Berk & Van Binsbergen (2016); e Blocher & Molyboga (2017), os quais documentam os mesmos padrões, para o mercado de fundos dos Estados Unidos. Adicionalmente, o artigo documenta que a maior sensibilidade dos investidores menos sofisticados aos alfas provém da relação dos seus fluxos de investimento com variações aleatórias do alfa. Contudo, os fluxos de investimento de investidores menos sofisticados não se mostram mais sensíveis a variações persistentes dos alfas dos fundos.

Adicionalmente, apesar das evidências documentadas por Barber et al. (2016); Berk & van Binsbergen (2017); e Berk & Van Binsbergen (2016) serem referência na literatura subjacente, como os trabalhos de Franzoni & Schmalz (2017), Harvey & Liu (2019), e Polkovnichenko, Wei, & Zhao (2019), até nosso conhecimento, o presente artigo é primeiro a documentar o comportamento para mercado fora dos Estados Unidos. Nesse sentido, o estudo fortalece a evidência e contribui para a literatura dedicada à análise de finanças com dados brasileiros na medida em que demonstra equivalência dos resultados aos observados na economia norte americana, a qual é considerada com referência ao estudo de finanças.

### **1.3. Métodos e Dados**

#### **1.3.1. Fonte de dados**

Os dados do artigo são organizados na frequência mensal e abrangem o período entre janeiro de 2001 e abril de 2019. Todos os valores monetários são deflacionados pelo IPCA para maio de 2018.

As séries de retornos, resgate e captação dos fundos foram coletadas na Economatica<sup>®</sup> e no Portal de Dados da CVM. O histórico de cotação do Ibovespa e as informações cadastrais dos

fundos também foram coletados na Economatica<sup>®</sup>. As séries de retorno dos fatores de risco brasileiros e retornos dos setores industriais foram obtidas no site do Núcleo de Pesquisas em Economia Financeira da Universidade de São Paulo – Nefin ([www.nefin.com.br](http://www.nefin.com.br)).

Os fundos são analisados a partir do momento que seu patrimônio líquido supera R\$5 milhões. Da mesma forma, só se mantêm um fundo na análise enquanto seu PL é superior a R\$100 mil. Adicionalmente, como são realizadas regressões em janelas móveis de 30 meses, são eliminados os fundos cujo histórico não acumula pelo menos 30 meses.

Por fim, parcela relevante da base não tem informação referente ao tipo de condomínio do fundo, se fechado ou aberto. Dessa forma, com intuito de manter na base apenas fundos de condomínio aberto, foram eliminados fundos cuja captação líquida é igual a zero em mais de 50% das observações.

### 1.3.2. Captação Líquida de Recursos

A captação líquida, variável dependente do artigo, se refere à variação percentual da carteira do fundo decorrente de entrada ou saída de recursos. Sendo assim, seu valor para o fundo  $p$  no mês  $t$  é resultado da seguinte equação:

$$Cap_{pt} = \left( \frac{VLC_{p,t}}{VLC_{p,t-1}} - (1 + R_{p,t}) \right) \times 100 \quad (1)$$

em que,  $VLC_{p,t}$  é o valor da carteira do fundo  $p$  no mês  $t$ , e  $R_{p,t}$  o retorno do fundo  $p$  no mês  $t$ . Esse procedimento de cálculo segue o padrão aplicado na literatura (Barber et al., 2016; Berk & Van Binsbergen, 2016; Goldstein, Jiang, & Ng, 2017; Jiang & Yuksel, 2017).

### 1.3.3. Métricas de Retorno

É de se esperar que os investidores de fundos de gestão ativa busquem por fundos capazes de proporcionar retornos acima de tudo aquilo que possa ser atrelado à sua exposição aos fatores de risco conhecidos (por exemplo, risco de mercado, tamanho etc.), ou seja, procurem por fundos capazes de gerar alfas. Se o investidor estivesse apenas interessado em se expor a tais riscos, seria suficiente que ele alocasse seus recursos em fundos de gestão passiva (Berk & van Binsbergen, 2017).

Apesar da busca por alfa pelos investidores ser algo esperado, não é claro como o alfa é estimado. Por um lado, os investidores podem, simplesmente, avaliar os fundos com base em seus retornos passados brutos. Por outro lado, eles podem classificar os fundos com base em

um modelo multifatorial de retornos conforme comumente praticado na literatura de precificação de ativos.

Diante desse contexto, e seguindo o proposto em Barber et al. (2016), são estimadas seis métricas de retorno controladas por risco (alfas): o retorno acima do retorno de mercado (MAR – *Market Adjusted Return*); Capital Asset Pricing Model (CAPM); o modelo de três fatores de Fama & French (1993) (M3F) em que são adicionados os fatores de tamanho (SMB) e valor (HML); o modelo de quatro fatores de Carhart (1997) com o acréscimo do fator de *momentum* (WML); o modelo cinco fatores (M5F) com a inclusão do fator de liquidez (IML) de Acharya & Pedersen (2005); e, por fim, o modelo com oito fatores (M8F) que inclui também mais três fatores de indústria calculados para mercado brasileiro com dados de indústrias do Nefin, com aplicação da metodologia descrita em Pástor & Stambaugh (2002b, 2002a).

Frequentemente esses modelos geram classificações semelhantes de fundos mútuos. No entanto, são explorados os casos em que os rankings dos fundos, determinados por tais medidas, diferem entre si e, com base nessa divergência, se identificam os modelos mais adequados para entender as escolhas dos investidores.

Primeiramente, são estimados os modelos com janelas de 30 meses. Por exemplo, no caso do M8F, é estimada a seguinte relação:

$$R_{p,\tau}^e = \alpha_{p,t} + \beta_{p,t}(R_{m,\tau} - R_{f,\tau}) + s_{p,t}SMB_{\tau} + h_{p,t}HML_{\tau} + w_{p,t}WML_{\tau} + l_{p,t}IML_{\tau} + \sum_{k=1}^3 i_{p,t}^k IND_{\tau}^k + \epsilon_{p,\tau} \quad (2)$$

em que,  $\tau \in [t-1, t-30]$ ,  $R_{p,\tau}^e$  é o excesso de retorno do fundo  $p$ ,  $R_{m,\tau}$  o retorno de mercado,  $R_{f,\tau}$  é o retorno livre de risco, e  $SMB_{\tau}$ ,  $HML_{\tau}$ ,  $WML_{\tau}$ ,  $IML_{\tau}$ , e  $IND_{\tau}^k$  são, respectivamente, os fatores de risco tamanho, valor, momento, liquidez e o  $k$ -ésimo fator de indústria.

A partir de (2) são estimados  $\hat{\beta}_{p,t}$ ,  $\hat{s}_{p,t}$ ,  $\hat{h}_{p,t}$ ,  $\hat{w}_{p,t}$ ,  $\hat{l}_{p,t}$  e  $\hat{i}_{p,t}$ , com os quais é calculado o retorno ajustado por risco (alfa) no mês  $t$ :

$$\hat{\alpha}_{p,t} = R_{p,t}^e - \left[ \hat{\beta}_{p,t}(R_{m,t} - R_{f,t}) + \hat{s}_{p,t}SMB_t + \hat{h}_{p,t}HML_t + \hat{w}_{p,t}WML_t + \hat{l}_{p,t}IML_t + \sum_{k=1}^3 \hat{i}_{p,t} IND_t^k \right] \quad (3)$$

O procedimento é repetido para todos os meses e para todos os fundos. Com isso, obtém-se uma série histórica ( $\hat{\alpha}_{p,t}$ ) para cada fundo da amostra. O procedimento é o mesmo para os demais modelos analisados. Por exemplo, para o CAPM são calculados os alfas regredindo os retornos dos fundos apenas contra o excesso de retorno de mercado. O alfa derivado do MAR se refere à diferença entre o retorno do fundo e o retorno de mercado.

Os alfas são analisados como métricas de habilidade dos gestores. Alfas elevados sinalizam maior habilidade dos gestores esperando-se, portanto, que o fluxo de captação líquida seja positivamente relacionado com os alfas.

No entanto, para a avaliação do comportamento dos investidores, é preciso também definir o horizonte de análise e a importância relativa de cada horizonte de tempo. Uma opção é considerar que todos os alfas possuem a mesma relevância na tomada de decisão dos investidores e, portanto, tomar a média dos alfas passados. Outra opção é considerar que os alfas mais recentes têm peso relativo superior.

Novamente, seguindo o proposto por Barber et al. (2016), calcula-se a média exponencial dos últimos alfas observados para o fundo na seguinte relação:

$$Cap_{p,t} = a + \sum_{s=1}^{13} b_s MAR_{p,t-s} + \mu_t + cX_{p,t} + e_{p,t} \quad (4)$$

em que,  $Cap_{p,t}$  representa o volume percentual de recursos captado pelo fundo  $p$  no mês  $t$ ,  $MAR_{p,t-s}$  representa o retorno ajustado ao mercado do fundo  $p$  no mês  $t-s$ , tal que  $s \in (1,2,\dots,13)$ ,  $\mu_t$  é o efeito fixo de tempo, e  $X_{p,t}$  é a matriz de variáveis de controle utilizada, a saber: log da idade do fundo em  $t-1$ , desvio padrão do excesso de retorno do fundo nos últimos 12 meses, log do PL do fundo no mês  $t-1$ , defasagens da captação líquida dos últimos 14 meses (são testados horizontes de um a 24 meses e o número de defasagens utilizado é definido de modo a minimizar o critério de informação Akaike).


Como resultado da regressão, são obtidos os coeficientes  $b_s$ , os quais são representados pela linha tracejada da Figura 1. Esses coeficientes indicam a relação dos retornos passados com captação corrente de recursos. Como se pode observar, existe um comportamento de queda da relevância dos retornos passados em relação a captação corrente.

Com intuito de captar esse decaimento na relação entre retornos passados e a captação líquida de recursos, é estimada a relação entre captação de recursos com uma média exponencial dos retornos dos últimos 13 meses. A média é estimada com taxa de decaimento  $\lambda$ , sendo assim temos:

$$Cap_{p,t} = a + b \sum_{s=1}^T e^{-\lambda(s-1)} MAR_{p,t-s} + \mu_t + cX_{p,t} + e_{p,t} \quad (5)$$

A relação de decaimento exponencial é também ilustrada na Figura 1. Nesse caso apenas um parâmetro é estimado, mas a relação da captação líquida com retornos passados pode ser analisada pela multiplicação entre o parâmetro  $b$  estimado e os pesos  $e^{-\lambda(s-1)}$  definidos por  $\lambda$  e  $s$ .

**Figura 1: Relação Cap. Líquida e Retorno Passado**



*Nota: A figura ilustra a relação entre captação líquida de recursos com retornos ajustados ao mercado defasados em até  $T=13$  meses ( $MAR_{p,t}$ ). A linha tracejada ilustra os  $b_s$  estimados pelo modelo irrestrito (4). A linha contínua representa a relação de decaimento exponencial ( $b \times e^{-\lambda(s-1)}$ ) estimada pelo modelo restrito (5).*

Com o procedimento, é definido o número de defasagens analisado (13) e estimado o parâmetro de decaimento exponencial  $\lambda$ . Esses dois parâmetros são fixados e com eles é estimado, para cada fundo  $p$  e mês  $t$ , as métricas de retornos controlado por risco analisadas ao longo do artigo com base nos diferentes modelos:

$$ALPHA_{p,t} = \frac{\sum_{s=1}^{13} e^{-\hat{\lambda}(s-1)} \hat{\alpha}_{p,t-s}}{\sum_{s=1}^{13} e^{-\hat{\lambda}(s-1)}} \quad (6)$$

Portanto, a métrica do retorno controlado por risco de cada modelo consiste em uma média exponencial dos  $\alpha_{p,t-s}$  de cada fundo em relação as últimas  $s = 13$  defasagens.

### 1.3.4. Competição entre modelos

O objetivo do artigo é verificar quais tipos de risco são levados em consideração pelos investidores quando eles avaliam o desempenho dos fundos. A abordagem obtém suas conclusões examinando as decisões de alocação de capital dos investidores nas opções de fundos de investimentos e como essas decisões se relacionam com o desempenho passado dos

fundos. O alto desempenho de um fundo sinaliza a maior habilidade do gestor e deve atrair recursos, enquanto o baixo desempenho indica baixa habilidade e deve gerar resgates no fundo.

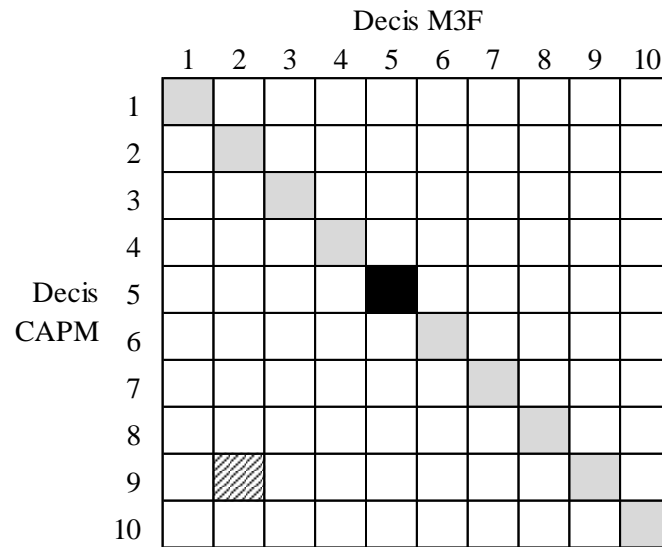
Assim sendo, espera-se observar uma relação positiva entre o desempenho passado e os fluxos de captação líquida subsequentes dos investidores. Ao mesmo tempo, é de se esperar que a relação seja mais forte para o modelo de risco específico mais empregado pelos investidores. Por exemplo, se os investidores estão preocupados apenas com o risco de mercado, os fluxos de fundos devem reagir mais fortemente aos alfas do CAPM do que aos alfas de modelos mais elaborados. Alternativamente, se os investidores também considerarem componentes de riscos mais complexos, espera-se que os fluxos de fundos reajam mais intensamente aos alfas dos modelos nos quais esses componentes são considerados.

Para tanto, segue-se, novamente, a metodologia proposta por Barber et al. (2016). Essa propõe uma competição entre os modelos em que, para cada mês da amostra e sob a perceptiva de cada modelo, se dividem as métricas de retorno ajustado a risco em decis de tal modo que os piores fundos de determinado mês são classificados no 1º decil e os melhores fundos no 10º decil.

Com base nessa classificação, os modelos são comparados dois a dois com base nas dummies  $D_{ijpt}$  que representam a relação entre as classificações de dois modelos. Tomando como exemplo a comparação entre o CAPM e M3F, a dummy  $D_{ijpt}$  assume valor 1 quando no mês  $t$  o fundo  $p$  é classificado no decil  $i$  de acordo com o CAPM e no decil  $j$  pelo M3F. Com isso, é possível estimar a seguinte relação:

$$Cap_{pt} = a + \sum_i \sum_j b_{ij} D_{ijpt} + cX_{pt} + \mu_t + e_{pt}. \quad (7)$$

Os parâmetros de interesse de (7) são os valores de  $b_{ij}$ , os quais podem ser organizados conforme ilustra a Figura 2. Na figura, os coeficientes na diagonal se referem aos casos em que os modelos analisados geram a mesma classificação. Os coeficientes fora da diagonal são os casos em que ocorre divergência entre a classificação dos modelos. Os valores no triângulo inferior (superior) da matriz se referem aos casos em que o CAPM classifica os fundos em um decil melhor (pior) que o M3F.

**Figura 2: Competição de Modelos**

Nota: A figura ilustra a comparação de decis do CAPM vs M3F. Nas linhas temos os decis segundo o CAPM e nas colunas os decis pelo M3F. Valores no triângulo inferior (superior) são caos em que fundos são considerados com melhor (pior) classificação pelo CAPM do que a classificação obtida pelo M3F. Por exemplo, a célula *rachurada* indica o caso em que o CAPM classificou fundos no 9º decil enquanto o M3F classificou esses fundos no 2º decil, portanto, a classificação do CAPM é relativamente melhor que a do M3F.

Com isso, é possível analisar a diferença entre os coeficientes do triângulo inferior com os coeficientes do triângulo superior. Os casos em que a soma dos coeficientes do triângulo inferior é superior à soma dos coeficientes do superior, significam que, quando o CAPM gera melhor classificação de retorno em relação ao M3F, ocorre maior captação de recursos do que nos casos em que ocorre o oposto. Isto é, os investidores tendem a seguir com maior intensidade os retornos ajustados a risco estimados pelo CAPM do que pelo M3F.

Para avaliar a diferença na sensibilidade da captação de recursos as métricas de retorno entre CAPM e M3F, a regressão (7) é estimada e é realizado o seguinte teste de hipótese:

$$\sum_{i>j} (b_{ijpt}) - \sum_{i<j} (b_{ijpt}) = 0 \quad (8)$$

ou seja, é testado se a soma dos  $b_{ij}$  no triângulo inferior da Figura 2 é superior à soma do triângulo superior. Se a hipótese não é rejeitada, não é possível afirmar que existe diferença na reação dos investidores às diferenças nos resultados dos modelos. Porém, caso a hipótese seja rejeitada, existe evidência que os investidores reagem de maneira diferente a cada modelo, sendo que, caso a diferença seja positiva (negativa) a reação ao CAPM é maior (menor) que a reação ao M3F. O mesmo procedimento é realizado para todas combinações, dois a dois entre os modelos.

### 1.3.5. Decomposição de Retornos

O fato de um modelo ser o mais aderente aos fluxos de investimento observados, não implica que os investidores sejam totalmente insensíveis aos retornos relacionados aos fatores inclusos nesse modelo. Assim sendo, Barber et al. (2016) propõem um teste para estimar a sensibilidade dos fluxos de investimentos dos fundos a cada um dos componentes que integram seu retorno. O procedimento consiste em, primeiramente, decompor os retornos dos fundos em alfa e retornos atrelados aos fatores de risco aos quais os fundos são expostos e, em seguida, regredir os fluxos de investimento contra esses componentes do retorno.

Para decompor os retornos dos fundos, esses são definidos da seguinte maneira:

$$R_{p,t}^e = \hat{\alpha}_{p,t} + \left[ \hat{\beta}_{p,t}(R_{m,t} - R_{f,t}) + \hat{s}_{p,t}SMB_t + \hat{h}_{p,t}HML_t + \hat{w}_{p,t}WML_t + \hat{l}_{p,t}IML_t + \sum_{k=1}^3 \hat{\gamma}_{p,t}^k IND_t^k \right] \quad (9)$$

Em seguida, para cada mês  $t$ , se calcula a média exponencial dos últimos 13 meses de cada componente. Por exemplo, para calcular o componente de retorno associado ao risco de mercado do fundo, tem-se:

$$RMERCADO_{p,t} = \frac{\sum_{s=1}^{13} e^{-\hat{\lambda}(s-1)} \hat{\beta}_{p,t-s} (R_{m,t-s} - R_{f,t-s})}{\sum_{s=1}^{13} e^{-\hat{\lambda}(s-1)}} \quad (10)$$

O mesmo procedimento é aplicado para todos os componentes, os quais são denominados ao longo do trabalho de RMERCADO, RTAMANHO, RVALOR, RMOMENTO, RLIQUIDEZ, RIND1, RIND2, e RIND3.

Com essa decomposição dos retornos, é determinado se os investidores respondem de maneira distinta à cada componente pela análise da seguinte regressão:

$$\begin{aligned} Cap_{p,t} = & b_0 + b_1 ALPHA_{p,t} + b_2 RMERCADO_{p,t} + b_3 RTAMANHO_{p,t} \\ & + b_4 RVALOR_{p,t} + b_5 RMOMENTO_{p,t} + b_5 RLIQUIDEZ_{p,t} \\ & + \sum_{k=1}^3 b_{5+k} RINDk_t + \mu_t + cX_{p,t} + \varepsilon_{p,t} \end{aligned} \quad (11)$$

Os parâmetros de interesse, aqui, são os coeficientes  $b_j$ , tal que  $j \in \{1, \dots, 9\}$ . Se o valor do coeficiente é positivo e significativo, conclui-se que os investidores são sensíveis aos retornos decorrentes do fator em questão. Por exemplo, se os investidores consideram integralmente o risco de mercado,  $b_1 = 0$  e os retornos decorrentes desse fator não implicam em alterações no fluxo de investimentos para o fundo. Por outro lado, se o coeficiente é positivo, indica-se que

os investidores interpretam o retorno observado como sinal de maior habilidade do gestor e, portanto, alteram o fluxo de investimentos dos fundos frente a retornos decorrentes da exposição a esse fator.

#### 1.4. Análise descritiva

Esta seção tem como intuito apresentar a base de dados utilizada, bem como explicar os filtros aplicados e seus impactos sobre a amostra. A base de dados completa contém fundos de ações de gestão ativa e passiva. Define-se como fundos de gestão passiva os fundos com atuação atrelada a um índice de mercado e que declaram não cobrar taxa de desempenho. Os demais fundos são definidos como de gestão ativa.

A Tabela 1 apresenta a distribuição de fundos por tipo de gestão e por classes de atuação, de acordo com a Classificação Anbima. Para cada grupo é informado a quantidade de fundos analisados, o número de observações e o patrimônio líquido médio em milhões de reais.

**Tabela 1: Distribuição de Fundos por Classes**

Classificação Anbima	Qtde Fundos	Qtde Obs.	PL Médio (R\$ Milhões)
<b>Fundos de Gestão Ativa</b>			
Ações Dividendos	90	7.800	181,90
Ações IBOVESPA Ativo	367	15.061	53,09
Ações IBOVESPA Ativo com Alavancagem	111	3.019	42,36
Ações IBOVESPA Indexado*	2	58	188,12
Ações IBrX Ativo	75	3.587	117,87
Ações IBrX Ativo com Alavancagem	5	185	187,53
Ações IBrX Indexado*	2	105	91,43
Ações Indexados*	5	332	70,73
Ações Índice Ativo	340	33.235	123,60
Ações Livre	1764	102.221	128,64
Ações Livre com Alavancagem	65	1.366	47,49
Ações Small Caps	53	5.201	114,24
Ações Sustentabilidade/Governança	30	3.622	113,14
Ações Valor/Crescimento	159	12.751	111,61
Fechados de Ações	3	128	58,66
<b>Total Gestão Ativa</b>	<b>3.071</b>	<b>188.671</b>	<b>108,69</b>
<b>Fundos de Gestão Passiva</b>			
Ações IBOVESPA Indexado	60	3.002	50,48
Ações IBrX Indexado	14	761	47,54
Ações Indexados	71	8.222	126,97
Fundos de índices – ETF	40	2.023	425,66
<b>Total Gestão Passiva</b>	<b>185</b>	<b>14.008</b>	<b>162,66</b>

*Nota: A tabela apresenta a distribuição de fundos por tipo de gestão e por classes de atuação. Em relação ao tipo de gestão os fundos são organizados em fundo de gestão Ativa e Passiva. A classe de atuação segue o padrão definido pela Anbima. A tabela informa para cada classe de atuação a quantidade de fundos, o número de observações conforme número de fundos e os meses em que eles são analisados, e o valor médio do patrimônio líquido em R\$ milhões. \*Fundos classificados como ativos pois cobram taxa de desempenho.*

Como se pode observar, a base é composta por 3.071 fundos de gestão ativa e 185 de gestão passiva. Os fundos são distribuídos ao longo do tempo e totalizam 188.671 observações de

fundos ativos e 14.008 observações de fundos passivos. O grupo de gestão ativa é composto por 15 categorias com relevante concentração em “Ações Livre” e “Ações Índice Ativo”. Ademais, alguns fundos, uma vez que cobram taxa de desempenho de seus investidores, são classificados como fundos de gestão ativa apesar de atuarem atrelados a um índice de mercado.

Também é relevante para o artigo a classificação dos fundos em termos de condomínio: se fechado ou aberto. Investidores de fundos de condomínio fechado só podem realizar resgates em uma frequência predeterminada. Diante disso, é de se esperar que o fluxo de investimento desses fundos não seja sensível ao seu desempenho passado, pelo menos em análises com horizontes de curto e médio prazo, como é caso em tela. Dessa forma, o interesse se restringe a fundos de condomínio aberto.

A distribuição dos fundos em termos de tipo de condomínio é apresentada na Tabela 2. Como se pode observar, o volume de fundos classificados como abertos é muito superior ao volume de fundos classificados como fechados. Contudo, também é relevante o volume de fundos sem classificação do tipo de condomínio.

Ao invés de limitar o filtro apenas aos fundos classificados como condomínio fechado da base, opta-se por aplicar filtro com base na frequência em que se observa captação ou resgate diferentes de zero. Desta forma, foram selecionados apenas fundos para os quais se observa captação líquida não nula em mais de 50% dos meses observados (valor esse próximo à frequência mínima observada entre os fundos declarados como de condomínio aberto).

**Tabela 2: Distribuição de Fundos por Tipo de Condomínio**

	<b>Ativo</b>	<b>Passivo</b>	<b>Total</b>
<b>Número Fundos</b>	3.071	185	3.256
<i>Cond. Aberto</i>	2.016	82	2.098
<i>Cond. Fechado</i>	31	-	31
<i>Cond. Sem classificação</i>	1.024	103	1.127
<b>Número de meses (jan/2000 - abr/19)</b>	<b>220</b>	<b>220</b>	<b>220</b>
<b>Total observações</b>	188.671	651	202.679

*Nota: A tabela apresenta a distribuição dos fundos em termos de tipo de condomínio. A primeira coluna informa a classificação do fundo em termos de condomínio: Aberto, Fechado ou sem classificação. As três últimas colunas apresentam o volume de dados observados para fundos Ativos e Passivos e soma dos dois grupos.*

Foram mantidos os fundos de investimento em cotas, uma vez que não se observam argumentos que sustentem captação de recursos desses fundos não seja sensível aos seus retornos passados.

A Tabela 3 apresenta a análise descritiva da base de dados utilizada. No Painel A são apresentadas informações para a base completa. O Painel B se refere à subamostra obtida com

aplicação dos filtros necessários para análise da captação líquida dos fundos. Os filtros em questão consistem na seleção de: (i) fundos ativos; (ii) com no mínimo 30 observações no tempo (número de meses necessário para realizar as regressões de janelas móveis da seção 1.5); (iii) e captação líquida diferente de zero em mais que 50% das observações.

**Tabela 3: Análise descritiva**

Variável	Média	Desv. Pad	Mín	p05	Mediana	p95	Máx
<b>Painel A: Base Completa</b>							
<b>Fundos Ativos (N = 3.071; Obs = 188.671)</b>							
Cap Líq (%)	0,34	9,35	-35,76	-9,71	0,00	12,62	51,74
Idade (meses)	103,86	58,00	1,00	23,00	94,00	220,00	220,00
PL (R\$ Milhões)	119,81	265,91	0,10	3,31	39,90	499,02	5.390,11
Retorno (%)	0,02	5,67	-16,37	-9,58	-0,01	9,53	15,31
Retorno acumulado (%)	7,43	61,49	-99,63	-63,19	-2,88	116,74	538,05
Freq. Movimentação (%)	64,49	36,12	0,00	3,83	79,22	100,00	100,00
Taxa de adm. (%)	0,104	0,094	0,00	0,00	0,088	0,249	0,799
Taxa de desemp. (%)	0,48	0,79	0,00	0,00	0,26	1,46	11,12
<b>Fundos Passivos (N = 185; Obs = 14.008)</b>							
Cap Líq (%)	-0,02	9,87	-35,76	-11,79	-0,12	13,75	51,74
Idade (meses)	129,88	64,90	7,00	28,00	137,00	220,00	220,00
PL (R\$ Milhões)	149,40	433,29	0,17	3,17	45,32	509,92	6.664,69
Retorno (%)	0,04	6,48	-16,37	-11,29	-0,13	10,22	15,31
Retorno acumulado (%)	-14,53	31,88	-94,49	-58,40	-15,73	35,88	139,78
Freq. Movimentação (%)	79,46	30,52	1,85	10,19	98,89	100,00	100,00
Taxa de adm. (%)	0,08	0,10	0,00	0,00	0,02	0,29	0,55
Taxa de desemp. (%)	0,00	0,00	0,00	0,00	0,00	0,00	0,00
<b>Painel B: Base Análise Cap. Líquida</b>							
<b>Fundos Ativos (N = 1.193; Obs = 112.388)</b>							
Cap Líq (%)	0,48	9,68	-35,76	-10,28	-0,12	14,92	51,74
Idade (meses)	121,80	55,83	30,00	43,00	113,00	220,00	220,00
PL (R\$ Milhões)	144,00	304,68	0,10	3,32	46,25	594,63	5.390,11
Retorno (%)	0,12	5,61	-16,37	-9,37	0,07	9,51	15,31
Retorno acumulado (%)	14,65	69,21	-94,80	-62,74	1,66	137,00	538,05
Freq. Movimentação (%)	89,31	13,90	50,00	57,41	96,59	100,00	100,00
Taxa de adm. (%)	0,12	0,10	0,00	0,00	0,12	0,29	0,73
Taxa de desemp. (%)	0,31	0,43	0,00	0,00	0,18	0,93	4,70

*Nota: A tabela apresenta uma análise descritiva das variáveis. O painel A se refere à base completa e o painel B à subamostra utilizada nas análises captação de recursos e obtida após filtrar apenas fundos ativos, com pelo menos 30 observações e captação líquida diferente de zero em pelo menos 50% dos meses analisados. São analisadas as seguintes variáveis: captação percentual líquida dos fundos (Cap Líq), idade dos fundos em meses (Idade), patrimônio líquido ao longo do histórico dos fundos (PL), excesso de retorno mensal (Retorno), excesso de retorno acumulado (Retorno acumulado), percentual de meses em que o fundo apresentou captação líquida diferente de zero (Freq. Movimentação), taxa de administração (Taxa de adm.) e de desempenho (Taxa de desemp.). As estatísticas apresentadas consistem em: Média, desvio padrão (Dev. Pad), mínimo (Mín), percentil 5 (p05), mediana, percentil 95 (p95) e máximo (Máx).*

Com base na Tabela 3, é possível notar que os filtros aplicados para definição da amostra utilizada neste artigo, descritas no Painel B da tabela, não geram grandes distorções nas estatísticas das variáveis em termos de média, desvio padrão e percentis analisados. Ademais, é necessário destacar que, com os filtros aplicados, aproximadamente 40% das observações de fundos ativos é eliminada da análise. Essa queda ocorre em grande parte devido à exigência de 30 meses de observação. Esse filtro traz à análise certo viés de sobrevivência, porém é relevante para a aplicação de metodologia proposta. Em estudos com dados dos Estados Unidos, como Berk & Van Binsbergen (2016), é aplicado filtro de 60 meses. Na mesma tabela pode-se notar

a presença de fundos com patrimônio líquido destoantes, elevados, o que inclusive distorce a média da variável em relação a sua mediana. No entanto, o fato não exige ajustes adicionais e as conclusões se mantêm se excluídas essas observações.

**Tabela 4: Análise descritiva alfas dos fundos e componentes do retorno**

Variável	Média	Desv. Pad	Mín	p05	Mediana	p95	Máx
<b>Painel A: Análise entre fundos (1.193 fundos)</b>							
coef. alfa ( $\hat{\alpha}$ )	0,085	0,479	-3,046	-0,716	0,104	0,772	2,337
coef. de mercado ( $\hat{\beta}$ )	0,703	0,242	-0,475	0,246	0,751	0,964	1,881
coef. de tamanho ( $\hat{\delta}$ )	0,110	0,258	-1,200	-0,262	0,095	0,539	1,350
coef. de valor ( $\hat{h}$ )	-0,032	0,188	-0,895	-0,314	-0,037	0,294	0,970
coef. de momento ( $\hat{w}$ )	0,061	0,142	-1,117	-0,195	0,065	0,279	0,524
coef. de liquidez ( $\hat{l}$ )	0,097	0,242	-0,889	-0,273	0,086	0,486	1,411
coef. de indústria 1 ( $\hat{i}^1$ )	-0,010	0,098	-0,500	-0,139	-0,013	0,145	0,532
coef. de indústria 2 ( $\hat{i}^2$ )	0,090	0,393	-2,534	-0,165	-0,017	0,801	3,668
coef. de indústria 3 ( $\hat{i}^3$ )	-0,025	0,133	-0,663	-0,241	-0,016	0,137	1,118
<b>Painel B: Análise no tempo (220 meses)</b>							
$ALFA_{M8F}$	0,114	1,162	-2,768	-1,657	0,091	1,727	6,961
RMERCADO	0,058	5,270	-21,064	-8,350	-0,097	8,415	12,096
RTAMANHO	0,080	1,335	-4,778	-1,952	0,030	2,031	6,035
RVALOR	0,116	0,896	-3,762	-1,033	0,013	1,485	3,956
RMOMENTO	0,005	0,761	-3,843	-1,361	0,024	1,065	3,175
RLIQUIDEZ	-0,080	0,797	-3,253	-1,438	0,010	1,082	3,222
RIND1	-0,024	0,346	-2,023	-0,598	-0,007	0,522	1,633
RIND2	-0,063	1,821	-10,444	-3,074	0,008	2,467	6,429
RIND3	0,075	0,687	-2,403	-0,602	0,000	1,066	5,004

*Nota: A tabela apresenta no Painel A distribuição entre os fundos para os coeficientes de risco dos fundos estimados pelo modelo de 8 fatores estimado pela equação (11). No Painel B é apresentada análise descritiva dos componentes de retorno dos fundos decompostos pelos oito fatores conforme a equação (2). As estatísticas apresentadas consistem em: Média, desvio padrão (Dev. Pad), mínimo (Mín), percentil 5 (p05), mediana, percentil 95 (p95) e máximo (Máx).*

Akbas, Armstrong, Sorescu, & Subrahmanyam (2015); Brown, Goetzmann, Hiraki, Shirishi, & Watanabe (2003); e Chiu & Kini (2013) discutem o uso da captação líquida de recursos para fundos de investimento como medida para "*investor sentiment*". Nesse sentido, e seguindo Barber et al. (2016), utiliza-se a variação dessa variável no tempo como indicador de *High Sentiment* no mercado. Considera-se como período de *High Sentiment* quando a captação agregada supera o valor do seu 75º percentil histórico. A mesma intuição é aplicada para a variação percentual no número de cotas no mercado de fundos. Essas duas métricas de *High Sentiment* são necessárias na seção 1.5.2 em que é feita decomposição dos retornos em alfa e risco.

A Tabela 4 apresenta análises para as medidas de risco estimadas para os fundos conforme o modelo de oito fatores estimado pela equação (11), bem como a análise descritiva dos componentes de risco dos retornos dos fundos conforme a equação (2). Pela análise do Painel A da tabela é possível notar relevante variabilidade nos resultados das estimações entre os fundos, o que reflete a variabilidade na exposição a risco dos fundos. Ademais, o Painel B da

tabela indica que a diferença na exposição a risco dos fundos implica em relevante variabilidade nos retornos dos fundos uma vez que, como se pode observar, é distinta a distribuição observada para cada componente de retorno dos fundos.

Por fim, a Tabela 5 apresenta a análise de correlação para os componentes de retorno dos fundos, bem como a análise de correlação nas medidas de desempenho expressas pelos alfas estimados nos diferentes modelos analisados. Como é de se esperar, a correlação entre os componentes dos retornos dos fundos é baixa, uma vez que esses são decompostos pela relação ortogonal estimada pela equação (2). Por outro lado, em relação aos alfas estimados pelos diferentes modelos, é possível notar que as medidas são altamente correlacionadas. Essa alta correlação evidencia a relevância do método, aqui proposto, de competição, entre modelos, uma vez que o método não é restrito a relações lineares e é mais adequado a lidar com problemas decorrentes da forte relação linear entre as medidas.

**Tabela 5: Análise de correlação dos componentes de retorno e alfas**

<b>Painel A: Correlação entre componentes dos retornos dos fundos</b>								
	$ALFA_{M8F}$	RMERCADO	RTAMANHO	RMOMENTO	RLIQUIDEZ	RIND1	RIND2	RIND3
$ALFA_{M8F}$	1,000							
RMERCADO	-0,048	1,000						
RTAMANHO	-0,046	0,103	1,000					
RVALOR	-0,089	-0,101	0,036	1,000				
RMOMENTO	-0,066	-0,097	-0,164	0,077	1,000			
RLIQUIDEZ	-0,045	0,032	-0,510	-0,170	-0,029	1,000		
RIND1	-0,101	-0,060	-0,051	-0,036	-0,006	0,022	1,000	
RIND2	-0,097	-0,033	-0,329	-0,322	-0,131	0,096	-0,081	1,000
RIND3	-0,102	0,059	0,037	-0,028	-0,135	-0,004	-0,020	-0,189

<b>Painel B: Correlação entre alfas</b>						
	$ALFA_{MAR}$	$ALFA_{CAPM}$	$ALFA_{M3F}$	$ALFA_{M4F}$	$ALFA_{M5F}$	$ALFA_{M8F}$
$ALFA_{MAR}$	1,000					
$ALFA_{CAPM}$	0,738	1,000				
$ALFA_{M3F}$	0,674	0,916	1,000			
$ALFA_{M4F}$	0,652	0,865	0,944	1,000		
$ALFA_{M5F}$	0,637	0,837	0,913	0,970	1,000	
$ALFA_{M8F}$	0,578	0,750	0,820	0,867	0,893	1,000

Nota: A tabela apresenta no Painel A análise de correlação entre componentes dos retornos dos fundos e no Painel B análise de correlação entre as diferentes métricas de alfas analisadas.

## 1.5. Resultados

### 1.5.1. Quais fatores importam aos investidores?

Existem diversas opções para se ajustar os retornos dos fundos pelo risco a que esses são expostos, desde métodos simples como comparar o retorno do fundo com o retorno de mercado, até modelos mais complexos como o CAPM ou modelos com diversos fatores. Diante desse conjunto de alternativas, não é claro dizer qual método melhor representa o processo decisório

dos investidores. Nesta seção identifica-se qual o modelo mais condizente com as decisões de investimento realizadas pelos investidores.

Na Tabela 6 são resumidos os resultados obtidos com o procedimento exposto na seção 1.3.4, em que se propõe uma comparação, dois a dois, dos modelos com base na organização mensal do desempenho passado dos fundos em decis.

**Tabela 6: Competição entre modelos**

	<b>MAR</b>	<b>CAPM</b>	<b>M3F</b>	<b>M4F</b>	<b>M5F</b>	<b>M8F</b>
<b>MAR</b>		-8,532	7,377	13,008	16,754	20,363
p-valor		(0,019)	(0,006)	(0,000)	(0,000)	(0,000)
<b>CAPM</b>	8,532		22,379	25,029	28,048	26,344
p-valor	(0,019)		(0,000)	(0,000)	(0,000)	(0,000)
<b>M3F</b>	-7,377	-22,379		11,799	16,153	18,811
p-valor	(0,006)	(0,000)		(0,132)	(0,019)	(0,000)
<b>M4F</b>	-13,008	-25,029	-11,799		30,938	18,173
p-valor	(0,000)	(0,000)	(0,132)		(0,005)	(0,000)
<b>M5F</b>	-16,754	-28,048	-16,153	-30,938		14,922
p-valor	(0,000)	(0,000)	(0,019)	(0,005)		(0,000)
<b>M8F</b>	-20,363	-26,344	-18,811	-18,173	-14,922	
p-valor	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	

*Nota: A tabela resume os resultados da competição de modelos dois a dois. Os resultados se referem ao teste de hipótese da equação (8). Ao analisar a tabela pelas as linhas são apresentados os resultados entre o modelo da linha contra o modelo da coluna. Os casos que o resultado é positivo, indicam a que métrica de desempenho da linha supera o modelo da coluna em termos de capacidade de explicação da captação líquida de recursos. Os valores estão em percentual, tal que 1 significa que quando o modelo da linha classifica um fundo em decil melhor que o modelo da coluna, a captação líquida do fundo tende a ser positiva em 1% da sua carteira.*

Como se pode observar, o desempenho medido pelo CAPM indica maior potencial para explicar a captação de recursos dos fundos. O modelo CAPM não perde para nenhuma das métricas analisadas, nem mesmo para medidas mais simples como o MAR ou mais completas como os modelos com mais fatores. Também é possível identificar certo padrão de perda de poder explicativo à medida que o modelo incorpora mais fatores de risco. Apesar disso, ao se comparar os resultados entre M3F e M4F, não se observa diferença significativa entre esses modelos.

### 1.5.2. Decomposição de Retornos

Nesta seção é analisada a relação entre a captação de recursos dos fundos e os retornos passados dos fundos decompostos em alfa e retornos atrelados a fatores de risco. Conforme descrito na seção 1.3.5, os retornos são decompostos em alfa do modelo com oito fatores (M8F) com medida de desempenho e nos diferentes retornos atrelados aos demais fatores de risco. Com isso, é analisada a regressão em que a variável dependente é o fluxo de investimento dos fundos e a variável independente são os componentes dos retornos dos fundos.

É de se esperar que um investidor não aumente o volume de recursos em um fundo, em detrimento de outro, quando a diferença nos retornos entre eles é atrelada à diferença na exposição de cada um aos fatores de risco. Nessa situação, o investidor só elevaria o volume de investimentos em um fundo, em detrimento de outro, quando esse apresentasse alfa maior. Do mesmo modo, um fundo com alto desempenho decorrente apenas da sua alta exposição ao fator de risco *momentum*, por exemplo, não deveria obter maior captação de recursos em relação aos demais fundos. Nesse sentido, ao regredir a captação líquida de recursos contra os componentes do retorno do fundo, espera-se que a captação seja sensível ao alfa porém, não tenha relação com os retornos do fundo atrelados aos fatores de risco aos quais o fundo é exposto.

Aliado a isso, e tendo em vista as evidências que o CAPM é o modelo que melhor representa a atuação dos investidores, é esperado que a relação entre captação de recursos e retorno passado, explicado pelo risco de mercado do fundo (RMERCADO), tenha menor relevância que os componentes do retorno relacionados aos demais fatores de risco.

Além disso, uma vez que investidores mais qualificados tendem a ter melhores condições de diferenciar retornos atrelados a habilidade dos gestores daqueles atrelados a componentes de risco, com base em interações com *proxies* para nível de qualificação dos investidores, espera-se que a sensibilidade dos fluxos de investimentos aos retornos atrelados aos componentes de risco seja menor para os investidores mais qualificados.

Esse é exatamente o comportamento observado na Tabela 7. A tabela apresenta resultados das regressões entre captação líquida de recursos e os componentes do retorno organizado em quatro perspectivas. Na primeira delas, apresentada na coluna (1), são exibidos os coeficientes da relação entre captação líquida e componentes do retorno sem nenhuma interação com *proxies* de qualificação do investidor. Por outro lado, nas perspectivas exibidas nas colunas seguintes são apresentados resultados da mesma relação, porém considerando algumas interações, de modo a captar o efeito da variação na qualificação dos investidores no tempo e entre os fundos. As colunas identificadas como “Dif.” sempre se referem a diferença na relação estimada para os investidores menos qualificados em relação aos mais qualificados.

Sendo assim, as colunas (2) e (3) organizam os resultados diferenciando o comportamento em períodos de *low* e *high sentiment*. A coluna (2) define períodos de *high sentiment* com base na captação líquida agregada observada. A coluna (3) faz a mesma análise, porém com base na variação no número agregado de cotas. Espera-se dos períodos com *high sentiment* um maior volume de investidores menos qualificados.

Por sua vez, as colunas (4) e (5) analisam o efeito da variação na qualificação dos investidores observada entre os fundos. Na coluna (4) se analisa a diferença das relações entre fundos com e sem restrições para investidores qualificados. A coluna (5) analisa, por sua vez, a diferença na relação entre fundos com exigência mínima de investimento de R\$ 100 mil e fundos com menor exigência.

Os resultados da regressão sem interações confirmam o comportamento esperado. Ao mesmo tempo que a captação de recursos tem forte reação ao alfa, a relação com o componente RMERCADO é a mais baixa. Também é possível observar que a variável dependente é sensível a todos os demais componentes do retorno, o que indica que os investidores tendem a distribuir seus recursos em fundos com maior desempenho passado, mesmo que esse desempenho seja atrelado à exposição do fundo a componentes de riscos conhecidos na literatura e não à habilidade do gestor.

As regressões com interações com nível de qualificação dos investidores indicam que a medida que são analisados comportamentos de investidores potencialmente mais qualificados, a sensibilidade da captação de recursos a retornos passados atrelado a risco tende a se reduzir. Por exemplo, é possível notar diferença positiva na relação do fluxo de investimentos com RMERCADO entre períodos de *low* e *high sentiment*. Isso indica que nos períodos de *high sentiment* a captação de recursos tende a reagir com maior intensidade aos retornos passados atrelados ao risco de mercado. O mesmo padrão se repete para a maioria dos fatores de risco.

Em apenas um caso a diferença estimada é negativa, porém o valor não é estatisticamente diferente de zero.

Tabela 7: Decomposição retornos e relação com sofisticação do investidor

	Sem interações	Períodos de Períodos de High e Low Sentiment (Captação)			Períodos de Períodos de High e Low Sentiment (Cotas)			Fundos com e sem restrição			Aplicação Inicial Mínima		
	(1)	(2)		(3)	(4)		(5)						
		Low	High	Dif.	Low	High	Dif.	Qualificados	Geral	Dif.	≥100 mil	<100 mil	Dif.
$ALFA_{M8F}$	0,688 (0,041)*	0,483 (0,040)*	1,008 (0,096)*	<b>0,526</b> <b>(0,104)*</b>	0,623 (0,047)*	0,722 (0,094)*	<b>0,099</b> <b>(0,108)</b>	0,519 (0,043)*	0,845 (0,063)*	<b>0,326</b> <b>(0,071)*</b>	0,207 (0,161)	0,701 (0,041)*	<b>0,495</b> <b>(0,163)*</b>
RMERCADO	0,246 (0,040)*	0,090 (0,037)*	0,592 (0,095)*	<b>0,502</b> <b>(0,103)*</b>	0,189 (0,047)*	0,472 (0,074)*	<b>0,282</b> <b>(0,088)*</b>	0,121 (0,040)*	0,329 (0,048)*	<b>0,208</b> <b>(0,042)*</b>	-0,029 (0,108)	0,254 (0,040)*	<b>0,282</b> <b>(0,099)*</b>
RTAMANHO	0,784 (0,068)*	0,633 (0,060)*	1,120 (0,179)*	<b>0,487</b> <b>(0,190)*</b>	0,785 (0,081)*	0,688 (0,158)*	<b>-0,097</b> <b>(0,179)</b>	0,636 (0,078)*	0,915 (0,090)*	<b>0,280</b> <b>(0,104)*</b>	0,530 (0,288)	0,784 (0,069)*	<b>0,254</b> <b>(0,291)</b>
RVALOR	0,454 (0,103)*	0,263 (0,111)*	1,014 (0,239)*	<b>0,752</b> <b>(0,262)*</b>	0,306 (0,118)*	0,915 (0,200)*	<b>0,610</b> <b>(0,232)*</b>	0,133 (0,119)	0,720 (0,145)*	<b>0,587</b> <b>(0,167)*</b>	-0,437 (0,392)	0,488 (0,107)*	<b>0,925</b> <b>(0,416)*</b>
RMOMENTO	0,648 (0,077)*	0,408 (0,074)*	1,348 (0,215)*	<b>0,939</b> <b>(0,229)*</b>	0,548 (0,087)*	1,348 (0,222)*	<b>0,800</b> <b>(0,239)*</b>	0,355 (0,091)*	0,867 (0,113)*	<b>0,512</b> <b>(0,140)*</b>	0,575 (0,356)	0,645 (0,080)*	<b>0,070</b> <b>(0,374)</b>
RLIQUIDEZ	1,047 (0,094)*	0,884 (0,092)*	1,068 (0,260)*	<b>0,184</b> <b>(0,279)</b>	1,042 (0,105)*	0,818 (0,216)*	<b>-0,224</b> <b>(0,241)</b>	0,824 (0,105)*	1,213 (0,120)*	<b>0,388</b> <b>(0,134)*</b>	1,020 (0,402)*	1,046 (0,095)*	<b>0,026</b> <b>(0,398)</b>
RIND1	0,612 (0,132)*	0,282 (0,133)*	1,660 (0,296)*	<b>1,378</b> <b>(0,324)*</b>	0,445 (0,164)*	0,905 (0,201)*	<b>0,461</b> <b>(0,259)</b>	-0,049 (0,164)	1,188 (0,201)*	<b>1,237</b> <b>(0,262)*</b>	-0,267 (0,479)	0,636 (0,133)*	<b>0,904</b> <b>(0,469)</b>
RIND2	0,859 (0,096)*	0,662 (0,096)*	1,394 (0,181)*	<b>0,732</b> <b>(0,204)*</b>	0,470 (0,173)*	0,698 (0,257)*	<b>0,228</b> <b>(0,310)</b>	0,619 (0,106)*	1,043 (0,123)*	<b>0,424</b> <b>(0,127)*</b>	0,619 (0,422)	0,867 (0,097)*	<b>0,248</b> <b>(0,422)</b>
RIND3	0,857 (0,127)*	0,648 (0,116)*	1,166 (0,358)*	<b>0,517</b> <b>(0,378)</b>	0,852 (0,175)*	0,984 (0,273)*	<b>0,132</b> <b>(0,322)</b>	0,524 (0,154)*	1,161 (0,166)*	<b>0,637</b> <b>(0,194)*</b>	0,342 (0,515)	0,875 (0,128)*	<b>0,534</b> <b>(0,512)</b>
Controles	Sim		Sim			Sim			Sim			Sim	
Efeito fixo de tempo	Sim		Sim			Sim			Sim			Sim	
Observações	92,793		92,793			87,129			92,793			92,793	
R <sup>2</sup> -Ajust.	0,120		0,127			0,127			0,122			0,120	

\*p&lt;0,05

Nota: A tabela apresenta os resultados das regressões entre captação líquida de recursos e os componentes do retorno. Na coluna (1), são exibidos os coeficientes da relação entre captação líquida e componentes do retorno sem nenhuma interação. A coluna (2) define períodos de high sentiment com base na captação líquida agregada observada. A coluna (3) faz a mesma análise, porém com base na variação no número agregado de cotas. Na coluna (4) se analisa a diferença das relações entre fundos com e sem restrições para investidores qualificados. A coluna (5) analisa a diferença na relação entre fundos com exigência mínima de investimento de R\$ 100 mil e fundos com menor exigência. As colunas identificadas como "Dif" se referem a diferença na relação estimada para os investidores menos qualificados em relação aos mais qualificados.

Encontra-se o mesmo comportamento ao se analisar a diferença entre fundos restritos a investidores qualificados e fundos sem restrições. Fundos com restrições tendem a ter um comportamento condizente com o esperado para investidores que diferenciam compensação a risco e habilidade do gestor. O mesmo ocorre com a análise da exigência mínima para investimentos. Nos fundos em que há tal tipo de restrição, a relação entre a captação líquida e os retornos atrelados a fatores de risco é sempre menor em relação ao comportamento dos fundos sem restrições.

Por outro lado, não fica claro o fato da relação entre alfa e fluxo de investimentos ser também maior para investidores menos qualificados. Ao se analisar as diferenças dessas relações para os diferentes níveis de qualificação, exceto o resultado da coluna (3), em que é analisado o efeito do *investor sentiment* calculado com base na variação de cotas, para todo os demais a diferença é positiva e significativa. Apesar desse comportamento estar em linha com o documentado por Barber et al. (2016), não é esperado que investidores menos qualificados tenham sensibilidade maior ao alfa do que a sensibilidade observada para os investidores qualificados.

Essa inversão na relação esperada pode decorrer de ruído nas proxies de qualificação dos investidores ou do fato da medida de desempenho calculada não distinguir completamente no retorno a parcela atrelada a habilidade do gestor da parcela decorrente de risco ou efeitos aleatórios. Com base na segunda suposição, é desenvolvida a próxima seção.

#### **1.5.2.1. Decomposição do alfa**

A partir dos resultados da seção anterior, conclui-se que investidores menos qualificados demonstram maior sensibilidade não apenas aos retornos atrelados a exposição a fatores de risco, mas também ao aumento do alfa do fundo. No entanto, o comportamento esperado é que investidores menos qualificados tenham sensibilidade igual ou menor ao alfa em relação ao observado para os investidores mais qualificados. Diante disso, nesta seção é feita análise mais aprofundada dessa questão.

A análise é desenvolvida com base na suposição que o alfa estimado, utilizado como métrica de desempenho, não distingue completamente do retorno, a parcela atrelada à habilidade do gestor de um termo aleatório. Nesse sentido, o alfa é decomposto em um componente persistente e um termo aleatório. O termo persistente é definido como a parcela do alfa relacionada com o alfa futuro. Entende-se que o termo persistente, apesar não ser observado pelo investidor, é uma melhor medida para a habilidade do gestor e, portanto, investidores

qualificados devem ser mais sensíveis a essa medida do que os investidores não qualificados. O termo aleatório, por sua vez, é definido como a parcela restante.

A decomposição do alfa é obtida pela regressão entre o alfa contemporâneo ( $ALFA_{M8F,p,t}$ ) com alfa do mês seguinte ( $\alpha_{i,t+1}$ ), conforme representado na equação (12). Note que, enquanto o alfa contemporâneo é estimado como a média ponderada dos alfas observados no últimos 13 meses, conforme descrito na seção 1.3.3, o alfa do mês seguinte se refere a observação de um único mês.

$$ALFA_{M8F,p,t} = \theta_p \alpha_{p,t+1} + u_{p,t} \quad (12)$$

Com base na relação estimada em (12) é feita uma decomposição do alfa contemporâneo em alfa persistente e alfa aleatório, conforme representado a seguir:

$$ALFA_{Persistente,p,t} = \theta_p \alpha_{p,t+1} \quad (13)$$

$$ALFA_{Aleatório,p,t} = u_{p,t} \quad (14)$$

Um resumo dos resultados das regressões realizadas para decomposição dos alfas dos fundos é apresentado na Tabela 8, em que são informados os percentis dos valores estimados para relação entre alfa contemporâneo e alfa futuro ( $\hat{\theta}$ ), bem como as estatísticas t dessas estimativas e a distribuição de  $R^2$  das regressões. Como se pode observar, as relações estimadas são todas positivas ou nulas, sendo 99% das estimativas positivas e significantes. Também pode-se notar que para grande maioria dos fundos a regressão capta mais de 35% da variância da variável dependente.

**Tabela 8: Resumo Decomposição Alfas**

	0%	1%	5%	10%	50%	90%	95%	99%	100%
$\hat{\theta}$	0,0468	0,1682	0,1913	0,2021	0,2538	0,3297	0,3630	0,4677	0,8306
t-valor	0,2981	3,1447	3,9092	4,5680	6,9228	10,6821	11,7704	12,2603	13,4452
$R^2$	0,0816	0,3522	0,3895	0,4037	0,4217	0,4798	0,5124	0,6380	0,7947

*Nota: A tabela apresenta um resumo dos resultados obtidos com as regressões realizadas para cada fundo entre seu alfa contemporâneo ( $ALFA_{M8F,p,t}$ ) com alfa do mês seguinte ( $\alpha_{i,t+1}$ ). A tabela exibe os valores de alguns percentis para os valores estimados para relação entre alfa contemporâneo a alfa futuro ( $\hat{\theta}$ ), bem como as estatísticas t dessas estimativas e a distribuição de  $R^2$  das regressões.*

Finalmente, com base na decomposição do alfa em componente persistente e aleatório, repete-se a análise da relação entre fluxo de investimentos dos fundos e seus componentes de retorno. Os resultados são apresentados na Tabela 9. A tabela apresenta os resultados das

regressões entre captação líquida de recursos e os componentes do retorno organizado nas mesmas quatro perspectivas analisadas anteriormente, portanto, uma coluna para os resultados sem interações e outras quatro colunas para os resultados obtidos com interações entre as *proxies* de qualificação dos investidores de modo a distinguir o comportamento entre investidores menos qualificados e mais qualificados. As colunas identificadas como “Dif.” sempre se referem à diferença na relação estimada para os investidores menos qualificados em relação aos mais qualificados. A diferença está na inclusão dos componentes persistente e aleatório do alfa, expressos nas duas primeiras linhas de resultado da tabela.

Pela análise da tabela pode-se observar que as relações estimadas para os fatores de risco permanecem as mesmas, ou seja: (i) os fluxos de investimentos apresentam menor sensibilidade em relação aos retornos decorrentes da exposição ao risco de mercado mensurados pela variável RMERCADO; (ii) a sensibilidade aos fatores de risco se eleva a medida em que investidores menos qualificados são analisados. Por outro lado, em relação a sensibilidade ao alfa, pode-se notar que investidores menos qualificados deixam de apresentar maior sensibilidade ao componente persistente do alfa. A diferença significativa entre a sensibilidade entre investidores qualificados e não qualificados permanece apenas para o componente aleatório.

Tabela 9: Decomposição alfas e relação com sofisticação do investido

	Sem interações	Períodos de Períodos de High e Low Sentiment (Captação)			Períodos de Períodos de High e Low Sentiment (Cotas)			Fundos com e sem restrição			Aplicação Inicial Mínima		
	(1)	(2)		(3)	(4)		(5)						
		Low	High	Dif.	Low	High	Dif.	Qualificados	Geral	Dif.	≥100 mil	<100 mil	Dif.
<i>ALFA</i> <sub>persistente</sub>	0,515 (0,061)*	0,357 (0,058)*	0,623 (0,143)*	<b>0,267</b> <b>(0,154)</b>	0,491 (0,068)*	0,316 (0,133)*	<b>-0,175</b> <b>(0,149)</b>	0,420 (0,063)*	0,603 (0,091)*	<b>0,183</b> <b>(0,101)</b>	0,326 (0,243)	0,520 (0,062)*	<b>0,193</b> <b>(0,243)</b>
<i>ALFA</i> <sub>Aleatório</sub>	0,824 (0,052)*	0,586 (0,050)*	1,291 (0,130)*	<b>0,705</b> <b>(0,139)*</b>	0,732 (0,057)*	1,019 (0,121)*	<b>0,287</b> <b>(0,138)*</b>	0,600 (0,057)*	1,034 (0,075)*	<b>0,434</b> <b>(0,085)*</b>	0,117 (0,212)	0,845 (0,052)*	<b>0,729</b> <b>(0,212)*</b>
RMERCADO	0,249 (0,040)*	0,091 (0,037)*	0,601 (0,093)*	<b>0,510</b> <b>(0,101)*</b>	0,191 (0,047)*	0,486 (0,073)*	<b>0,295</b> <b>(0,087)*</b>	0,123 (0,040)*	0,333 (0,047)*	<b>0,210</b> <b>(0,041)*</b>	-0,031 (0,108)	0,257 (0,040)*	<b>0,288</b> <b>(0,099)*</b>
RTAMANHO	0,776 (0,069)*	0,631 (0,060)*	1,068 (0,185)*	<b>0,437</b> <b>(0,196)*</b>	0,783 (0,081)*	0,664 (0,169)*	<b>-0,119</b> <b>(0,188)</b>	0,631 (0,079)*	0,907 (0,089)*	<b>0,276</b> <b>(0,103)*</b>	0,526 (0,291)	0,776 (0,070)*	<b>0,250</b> <b>(0,294)</b>
RVALOR	0,465 (0,101)*	0,274 (0,109)*	1,005 (0,238)*	<b>0,731</b> <b>(0,260)*</b>	0,321 (0,116)*	0,873 (0,189)*	<b>0,552</b> <b>(0,221)*</b>	0,137 (0,119)	0,741 (0,141)*	<b>0,604</b> <b>(0,165)*</b>	-0,436 (0,390)	0,501 (0,104)*	<b>0,937</b> <b>(0,415)*</b>
RMOMENTO	0,647 (0,077)*	0,408 (0,074)*	1,351 (0,216)*	<b>0,943</b> <b>(0,229)*</b>	0,551 (0,087)*	1,293 (0,241)*	<b>0,742</b> <b>(0,256)*</b>	0,356 (0,091)*	0,864 (0,111)*	<b>0,508</b> <b>(0,136)*</b>	0,569 (0,356)	0,643 (0,080)*	<b>0,074</b> <b>(0,376)</b>
RLIQUIDEZ	1,032 (0,093)*	0,877 (0,091)*	0,999 (0,263)*	<b>0,122</b> <b>(0,281)</b>	1,037 (0,103)*	0,733 (0,220)*	<b>-0,304</b> <b>(0,244)</b>	0,818 (0,106)*	1,189 (0,117)*	<b>0,371</b> <b>(0,134)*</b>	1,037 (0,402)*	1,031 (0,093)*	<b>-0,005</b> <b>(0,398)</b>
RIP1	0,595 (0,134)*	0,267 (0,135)*	1,673 (0,307)*	<b>1,407</b> <b>(0,335)*</b>	0,430 (0,168)*	0,882 (0,205)*	<b>0,452</b> <b>(0,265)</b>	-0,060 (0,165)	1,167 (0,200)*	<b>1,226</b> <b>(0,258)*</b>	-0,276 (0,480)	0,617 (0,135)*	<b>0,893</b> <b>(0,471)</b>
RIP2	0,853 (0,098)*	0,662 (0,097)*	1,352 (0,192)*	<b>0,690</b> <b>(0,214)*</b>	0,479 (0,176)*	0,610 (0,276)*	<b>0,131</b> <b>(0,327)</b>	0,616 (0,107)*	1,037 (0,124)*	<b>0,421</b> <b>(0,126)*</b>	0,657 (0,425)	0,862 (0,098)*	<b>0,204</b> <b>(0,427)</b>
RIP3	0,850 (0,128)*	0,641 (0,117)*	1,178 (0,344)*	<b>0,537</b> <b>(0,364)</b>	0,842 (0,177)*	0,900 (0,291)*	<b>0,059</b> <b>(0,340)</b>	0,524 (0,154)*	1,144 (0,166)*	<b>0,621</b> <b>(0,194)*</b>	0,355 (0,519)	0,868 (0,129)*	<b>0,513</b> <b>(0,519)</b>
Controles	Sim	Sim			Sim			Sim			Sim		
Efeito fixo de tempo	Sim	Sim			Sim			Sim			Sim		
Observações	92,793	87,129			92,793			92,793			92,793		
R <sup>2</sup> -A <sub>ajus.</sub>	0,120	0,127			0,128			0,122			0,121		

\*p&lt;0,05

Nota: A tabela apresenta os resultados das regressões entre captação líquida de recursos e os componentes do retorno e dos alfas persistente e aleatório. Na coluna (1), são exibidos os coeficientes da relação entre captação líquida e componentes do retorno sem nenhuma interação. A coluna (2) define períodos de high sentiment com base na captação líquida agregada observada. A coluna (3) faz mesma análise porém com base na variação no número agregado de cotas. Na coluna (4) se analisa a diferença das relações entre fundos com e sem restrições para investidores qualificados. A coluna (5) analisa a diferença na relação entre fundos com exigência mínima de investimento de R\$ 100 mil e fundos com menor exigência. As colunas identificadas como "Dif." se referem a diferença na relação estimada para os investidores menos qualificados em relação aos mais qualificados.

## 1.6. Comparação com resultados da literatura

A base de dados brasileira utilizada para o presente artigo apresenta características que a divergem dos dados utilizadas para documentar as evidências no mercado norte-americano (Agarwal et al., 2018; Barber et al., 2016; Berk & van Binsbergen, 2017; Berk & Van Binsbergen, 2016). Diante disso, a seguir são discutidos algumas das divergências, bem como são analisados os ajustes realizados e os potenciais impactos sobre os resultados.

Primeiramente, cabe destacar o tamanho da base em termos de horizonte de tempo. Os resultados de norte-americanos são obtidos com dados referentes a horizontes entre 16 e 34 anos. Assim sendo, neste quesito o presente artigo não destoa de maneira relevante, uma vez que os resultados do presente estudo se referem a horizonte de 17 anos.

Ademais, menor horizonte de dados disponível exige que as regressões de janelas móveis sejam realizadas com apenas 30 meses. Nos estudos com dados dos Estados Unidos, convencionalmente utilizam-se janelas de 60 meses. O impacto desse ajuste, por um lado reduz o potencial de viés de sobrevivência em relação aos trabalhos internacionais. Por outro lado, prejudica a significância e precisão dos alfas estimados, o que, por sua vez, tem potencial de prejudicar a robustez das evidências encontradas. Conjuntamente, esses ajustes trazem robustez às evidências, uma vez que têm menor viés de sobrevivência e apresentam significância estatística, apesar da presença relativa de maior ruído nas variáveis estimadas.

Outra divergência é o número de fundos disponíveis. O presente artigo avalia um conjunto de 1.193 fundos, enquanto os estudos internacionais baseiam suas conclusões em amostras com aproximadamente 5 mil fundos. Novamente, a divergência tem potencial de prejudicar as evidências apresentadas e dificultar as significâncias estatísticas. No entanto, diante da robustez dos resultados observados, espera-se que esses tornem ainda mais relevantes à medida que se avaliem bases de dados com mais fundos. Nesse sentido, e de se esperar que a tendência recente de aumento no número de fundos no Brasil beneficie estudos futuros com dados de fundos brasileiros.

Dadas as devidas considerações sobre a base de dados, é possível destacar os resultados muito semelhantes aos documentados para os Estados Unidos. Essencialmente,

replica-se o padrão de relevância dos modelos, sendo o modelo CAPM o mais relevante, seguido pelos demais em ordem de sofisticação, do mais simples ao mais sofisticado.

Do mesmo modo, evidencia-se, também, que a sensibilidade de captação dos fundos diverge de acordo com as medidas de sofisticação dos investidores. Assim, como documentado para o mercado dos Estados Unidos, confirma-se a hipótese que investidores mais sofisticados recorrem a medidas mais sofisticadas de avaliação.

### **1.7. Conclusão**

São amplamente reconhecidas na literatura de finanças as evidências sobre comportamentos observados nos retornos dos ativos de acordo com determinadas características, tais como tamanho da empresa, relação valor contábil e valor de mercado, liquidez, desempenho passado dos ativos, dentre outros. Inclusive, diante disso, diversos fundos passivos elaboram seus perfis de investimentos baseados nessas evidências.

Ainda assim, investidores tendem a recompensar gestores que replicam o comportamento de tais fatores. Por exemplo, para cada 1% de retorno atribuído a um dos fatores analisados no artigo (tamanho, valor, iliquidez e risco de indústria) a captação do fundo tende a se elevar entre 0,6% e 1%. Ao considerar o feito dos investidores menos sofisticados os efeitos são ainda maiores e atingem até 1,7%.

O artigo evidencia que os investidores são capazes de distinguir o efeito do risco de mercado sobre os rendimentos dos fundos, porém atribuem à habilidade do gestor os retornos decorrentes da exposição a outros fatores de risco. Por outro lado, constata-se que investidores mais sofisticados fazem melhor distinção entre risco e habilidade na análise do desempenho passado dos fundos.

O CAPM demonstra ser o melhor modelo para explicar o comportamento dos investidores de fundos, superando modelos com múltiplos fatores e a comparação direta com o retorno de mercado. Os resultados reforçam as evidências documentadas para o mercado dos Estados Unidos e as amplia para um mercado emergente.

Adicionalmente, observa-se que investidores menos sofisticados demonstram ser mais sensíveis, não apenas aos retornos atrelados a risco, mas também ao alfa do fundo. Para cada alfa de 1%, a captação de recursos dos fundos tende a se elevar em 0,7%, porém a captação é 0,5% superior para investidores menos sofisticados em relação aos investidores sofisticados.

No entanto, ao se decompor os alfas dos fundos em componente persistente e componente aleatório, evidencia-se que a essa maior sensibilidade está concentrada no componente aleatório dos alfas. Enquanto o termo persistente do alfa não gera diferenças significantes na captação de recursos entre os diferentes níveis de sofisticação. Para cada retorno aleatório de 1%, a captação de recursos de investidores menos sofisticados tende a ser superior em até 0,7% em relação aos investidores sofisticados.

## **2. Evidências do impacto de fatores climáticos sobre o desempenho de fundos de investimento**

### **2.1. Resumo**

Analisa-se, aqui, a relação entre fatores climáticos e o desempenho de fundos de investimento em ações. Conclui-se que, apesar de gestores de fundo, a princípio, trabalharem em locais climatizados e com iluminação artificial adequada, os desempenhos dos fundos demonstram relação com fatores climáticos. Tal conclusão está em linha com o documentado pela literatura de produtividade. Os dados apontam relação côncava entre desempenho e variação da temperatura, o que implica em temperatura ótima em termos de produtividade. Além disso, observam-se efeitos distintos a depender das condições climáticas médias da região e data analisadas, por exemplo, aumentos de temperatura em locais de clima frio têm efeitos nulos, ao passo que em regiões de clima quente aumentos de 1°C têm efeitos negativos de 0,03% sobre retorno dos fundos. As conclusões são baseadas em amostra de retornos diários de fundos brasileiros e norte-americanos utilizando retornos ajustados por risco como métricas de desempenho. O conjunto de variáveis climáticas consideradas contemplam temperatura, precipitação e nebulosidade.

### **2.2. Introdução**

Este artigo analisa o vínculo entre as condições externas climáticas e o desempenho de fundos de ações de gestão ativa. Conclui-se que condições de temperatura, nebulosidade e precipitação têm impacto sobre o desempenho dos fundos, apesar do fato de os gestores desses fundos trabalharem, a princípio, em locais fechados e isolados dos eventos climáticos externos, isto é, em ambientes climatizados.

As conclusões são baseadas em amostra de retornos diários de 776 fundos brasileiros de gestão ativa distribuídos em 13 cidades no período entre janeiro de 2002 e dezembro de 2016. Como métrica de desempenho são avaliados os retornos ajustados por risco dos fundos de acordo com modelo de quatro fatores de Carhart (1997), bem como métricas alternativas. O conjunto de variáveis climáticas analisadas contemplam temperatura, precipitação e nebulosidade nas cidades dos respectivos fundos.

Os resultados são robustos quando comparados com uma base de fundos norte-americana, que contempla retornos diários de 8.638 fundos observados entre janeiro de 2003 e dezembro de 2019, distribuídos por 268 cidades.

O trabalho contribui com a literatura que analisa a relação entre fatores climáticos e retornos financeiros. Essa literatura tem início com Saunders (1993), que documenta associação inversamente proporcional entre nebulosidade e retornos, utilizando dados da cidade de Nova York no período entre 1927 a 1989. Posteriormente, Hirshleifer e Shumway (2003) complementam a análise, com dados de 26 bolsas de valores no mundo entre 1982 e 1997, e mostram que a luz do sol está correlacionada com os retornos diários das ações. Na mesma linha, Cao e Wei (2005) examinam mercados de ações em todo o mundo e encontram uma correlação significativa e negativa entre temperatura e retorno.

O canal para a existência de tais efeitos é debatido na literatura de finanças comportamentais. Diversos trabalhos se dedicaram a avaliar a relação entre eventos climáticos com o comportamento dos ativos financeiros (Dichev & Janes, 2003; Dowling & Lucey, 2005, 2008; Pizzutilo & Roncone, 2017; Symeonidis, Daskalakis, & Markellos, 2010; Yuan, Zheng, & Zhu, 2006), normalmente utilizando tais eventos como proxies para variação de humor dos indivíduos.

O trabalho complementa a literatura dedicada ao estudo da relação entre produtividade dos indivíduos e clima (Baylis, 2015; Cheema & Patrick, 2012; Duxbury, Gärling, Gamble, & Klass, 2020; Fang, Wyon, Clausen, & Fanger, 2004; Hancock & Vasmatzidis, 2003; Heyes & Saberian, 2019; Seppanen, Fisk, & Lei, 2006). Neste trabalho a hipótese é que as variações climáticas de curto prazo afetam o comportamento dos indivíduos que, por sua vez, têm impacto sobre suas decisões e, conseqüentemente, sobre como os ativos financeiros dos fundos são negociados. Apesar da ampla literatura dedicada ao estudo da relação entre eventos climáticos e decisões dos investidores, este trabalho é o primeiro a analisar a relação entre clima e os desempenhos de fundos de investimento.

As conclusões obtidas são consistentes com diversas evidências documentadas pela literatura, dentre elas a relação côncava entre produtividade e temperatura, implicando uma região de máxima produtividade em função da temperatura; relação negativa da produtividade em relação ao volume de precipitação e nebulosidade. Por fim, também de forma inédita, são considerados os efeitos não lineares entre desempenho dos fundos e as variáveis climáticas, em que se prevê que aumentos de temperatura,

precipitação e nebulosidade têm efeitos distintos a depender dos valores médios históricos observados na data e região analisada. Por exemplo, aumentos de temperatura em locais historicamente quentes têm efeitos negativos, enquanto o efeito é nulo em regiões historicamente frias.

### **2.3. Literatura**

Diversos artigos examinam como fatores externos relacionados a clima afetam as capacidades cognitivas dos indivíduos com impactos sobre sua produtividade, tomada de decisões e tolerância a risco. Em sua maioria, os estudos avaliam tais componentes em ambientes de laboratório fechados e controlados, em que se variam fatores como a temperatura, e se avaliam os impactos sobre uma medida de desempenho específica. Outro subconjunto analisa o efeito desses fatores em ambientes diversos em que o clima não é necessariamente controlado. Além disso, apesar da qualidade e abundância de dados financeiros, são poucos os estudos que abordam a relação entre fatores climáticos e impactos sobre decisões financeiras como tomadas de decisão e produtividade na gestão de ativos.

Seppanen *et al.* (2006), por meio de uma análise de um conjunto de artigos, avaliam a relação entre temperatura do ambiente e desempenho. O trabalho evidencia a existência de uma relação côncava entre temperatura e produtividade, em que a produtividade aumenta à medida em que se eleva a temperatura dentro do intervalo entre 21 e 22°C, porém cai quando esta ultrapassa 24°C. Assim sendo, estima-se que a produtividade atinge seu máximo em torno de 22°C e cai aproximadamente 9% desse máximo quando atinge 30°C. No mesmo sentido, Hancock e Vasmatazidis (2003) documentam que o estresse térmico no calor tem uma influência maior do que o estresse frio no desempenho de tarefas cognitivas. Em relação ao efeito sobre tomada de decisão, Cheema e Patrick (2012) apresentam evidência de que indivíduos em temperaturas mais altas são menos propensos a participar de apostas, a escolher produtos inovadores e mais propensos a se orientarem pelo pensamento intuitivo e baseado no hábito, em detrimento do pensamento baseado em lógica.

A literatura traz também evidências para a relação entre clima e humor, o que por sua vez tem relação com literatura que estuda a causalidade entre humor e a tomada de decisões. Baylis (2015) vincula a temperatura a medidas do estado hedônico (humor) usando a atividade geolocalizada do Twitter. Suas métricas de sentimento baseadas em

fraseologia, uso de *emoticons* e palavras se tornam cada vez mais negativas quando as temperaturas externas excedem os 21°C.

Em relação aos efeitos do clima em ambientes fechados e supostamente isolados, pode-se destacar Heyes e Saberian (2019), que analisam o impacto da temperatura externa em decisões judiciais nos Estados Unidos e evidenciam que aumento na temperatura do dia do caso reduz as decisões favoráveis ao requerente. Os resultados encontrados se mostram consistentes com as ligações estabelecidas da temperatura ao humor e ao apetite por risco.

De maneira semelhante, vários trabalhos de finanças vinculam variações diárias no clima – tipicamente cobertura de nuvens e luz do sol, mas também temperatura e umidade – a movimentos de preços de ações. Saunders (1993), o primeiro a vincular o comportamento do investimento às condições climáticas, com base em evidências para a cidade de Nova York no período de 1927 a 1989, mostra que nebulosidade está associada a retornos mais baixos. Hirshleifer e Shumway (2003) examinam a relação entre nebulosidade e o retorno das ações e, com base de dados contemplando 26 bolsas de valores no mundo entre 1982 e 1997, documentando que a luz do sol está altamente correlacionada com os retornos diários das ações. Cao e Wei (2005) examinam mercados de ações em todo o mundo e encontram uma correlação significativa e negativa entre temperatura e retorno. A correlação negativa observada é robusta para testes alternativos e mantém sua significância estatística após o controle de várias anomalias conhecidas.

Adicionalmente, com avanço da literatura de finanças comportamentais, emergiu um campo dedicado ao estudo do impacto de diversas variáveis, inclusive condições do clima, sobre o comportamento dos investidores e, conseqüentemente, sobre o mercado acionário como um todo. Duxbury *et al.* (2020) fazem ampla revisão sobre a literatura dedicada ao estudo da relação entre emoções e efeitos sobre o mercado financeiro. Nessa revisão abordam estudos de efeitos de *proxies* de humor no desempenho do mercado, estudos de campo que medem as emoções dos investidores e estudos de laboratório sobre influências emocionais na tomada de decisões dos investidores. Embora apontem fortes evidências de que as emoções influenciam os investidores nos mercados financeiros, concluem que há uma falta de precisão quanto a sua natureza.

## 2.4. Métodos e Dados

### 2.4.1. Fonte de dados

Os dados são organizados na frequência diária e abrangem o período entre janeiro de 2002 e dezembro de 2016. O período analisado é determinado pelo histórico de dados disponível para RAIS<sup>1</sup>, base na qual são coletados os endereços dos fundos analisados. Todos os valores monetários são deflacionados pelo IPCA para maio de 2018.

As séries de retornos e captação líquida, as informações cadastrais dos fundos e o histórico de cotação do Ibovespa são coletadas na Economatica®. As séries de retorno dos fatores de risco brasileiros são obtidas no site do Núcleo de Pesquisas em Economia Financeira da Universidade de São Paulo – Nefin ([www.nefin.com.br](http://www.nefin.com.br)). As informações de endereço dos fundos são obtidas junto a base da RAIS por meio do CNPJ dos fundos analisados.

Os fundos são analisados a partir do momento que seu patrimônio líquido supera R\$ 5 milhões e só são mantidos durante período em que seu patrimônio líquido é superior a R\$ 100 mil. Adicionalmente, como é necessária estimação de regressões para cálculo das métricas de desempenho, são eliminados fundos cujo histórico é inferior a 30 meses.

As informações de clima foram coletadas junto com o *International Research Institute for Climate and Society* (IRI) da Universidade de Columbia<sup>2</sup>. Os dados são diários e abrangem período entre 1986 e 2019. As informações são georreferenciadas em um grid de 2 por 2 graus<sup>3,4</sup> de latitude-longitude; assim sendo, atribui-se para cada fundo a informação disponível para a localização mais próxima geograficamente.

### 2.4.2. Métricas de Retorno

Diante da proposta de avaliar o impacto no desempenho do fundo em função de componentes externos que possam afetar as decisões dos gestores, recorre-se à métrica tradicional na literatura para avaliação do desempenho dos fundos, estimação e avaliação do retorno ajustado por risco. Para tanto, são estimadas, para cada fundo, séries de retornos ajustados por risco, alfas, por quatro métricas: o retorno acima do retorno de

---

<sup>1</sup> Base de Relação Anual de Informações Sociais do Ministério da Economia.

<sup>2</sup> IRI - Columbia University - <https://iri.columbia.edu/resources/data-library>.

<sup>3</sup> A distância de um grau é de aproximadamente 111 km.

<sup>4</sup> Os conclusões para o Brasil permanecem as mesmas se utilizada base de Xavier, King, & Scanlon (2016) com dados de temperatura e precipitação organizadas em grid de 1 por 1 grau. Essa base alternativa não é utilizada no trabalho por não conter dados para os Estados Unidos e de nebulosidade.

mercado (MAR – *Market Adjusted Return*); Capital Asset Pricing Model (CAPM); o modelo de três fatores de Fama e French (1992, 1993) (M3F) em que são adicionados os fatores de tamanho (SMB) e valor (HML); o modelo de quatro fatores (M4F) de Carhart (1997) com o acréscimo do fator de *momentum* (WML).

Os resultados principais são apresentados com base no observado para o M4F e as demais métricas são apresentadas nas análises de robustez. Opta-se pelo modelo de quatro fatores por ser o mais abrangente e alinhado com práticas da literatura para análise de desempenho de fundos (Barras, Scaillet, & Wermers, 2010; Fama & French, 2010).

Mais especificamente o histórico de retorno ajustado por risco de cada fundo,  $R_{p,t}^*$ , é estimado pela seguinte relação:

$$R_{p,t}^* = R_{p,t}^e - E(R_{p,t}^e) \quad (12)$$

em que

$R_{p,t}^e$  é o excesso de retorno do fundo  $p$  observado no dia  $t$ ;  $E(R_{p,t}^e)$  é o retorno esperado para o fundo  $p$  no dia  $t$  que, por sua vez, no caso do M4F é estimado pela relação:

$$E(R_{p,t}^e) = \alpha_p + \beta_p(R_{m,t} - R_{f,t}) + s_p \text{SMB}_t + h_p \text{HML}_t + w_p \text{WML}_t \quad (13)$$

tal que  $R_{m,t}$  é o retorno de mercado no dia  $t$ ;  $R_{f,t}$  é o retorno livre de risco observado no dia  $t$ ; e  $\text{SMB}_t$ ,  $\text{HML}_t$  e  $\text{WML}_t$  são, respectivamente, os fatores de risco tamanho, valor e momento.

### 2.4.3. Métricas de Climáticas

O forte comportamento sazonal é um componente característico para variáveis climáticas. Por exemplo, os meses de inverno no sudeste do Brasil são comumente acompanhados de clima mais nublados e frios. Do mesmo modo, a literatura documenta diversas outras características que potencialmente afetam os retornos, das quais muitas têm também potencial sazonal (Keim, 1983). Diante disso, para garantir que os resultados não são direcionados por essas características, é realizado um ajuste nas variáveis climáticas com metodologia equivalente à proposta por Hirshleifer e Shumway (2003).

O ajuste consiste em, primeiramente, avaliar a variável pelo desvio do seu valor médio diário de longo prazo. Por exemplo, para a informação de temperatura observada nos dias

de 02 de janeiro, calcula-se, a média da temperatura de todos os anos para essa data. Em seguida, subtrai-se da temperatura observada para cada 02 de janeiro esse valor médio calculado. Na literatura denomina-se de “clima” o padrão climático da região e data analisada, calculado pela média de longo prazo (Dell, Jones, & Olken, 2012, 2014).

Assim sendo, obtém-se as seguintes variáveis:

$$\Delta temp_{p,t} = temp_{p,t} - tempLP_{p,t} \quad (14)$$

$$\Delta prec_{p,t} = prec_{p,t} - precLP_{p,t} \quad (15)$$

$$\Delta neb_{p,t} = neb_{p,t} - nebLP_{p,t} \quad (16)$$

em que  $temp_{c,t}$ ,  $prec_{c,t}$ , e  $neb_{c,t}$  referem-se, respectivamente, a temperatura, precipitação e nebulosidade (percentual de céu encoberto) na cidade do fundo  $p$  no dia  $t$ ; e  $tempLP_{c,t}$ ,  $precLP_{c,t}$ , e  $nebLP_{c,t}$  representam, respectivamente, a média histórica, ou clima, das variáveis temperatura, precipitação e nebulosidade para cidade do fundo  $p$  dia  $t$ .

Com isso, as variáveis em questão são analisadas com desvios do seu clima para cidade e data em questão. A base completa de informações climáticas abrange período entre 1986 e 2019, porém se utiliza o período completo apenas para cálculo das médias de longo prazo. Com isso, as demais variáveis climáticas são calculadas com base no período entre 2002 e 2016. Em termos de unidade de medida, a temperatura é expressa em graus Celsius (°C), precipitação em milímetros por dia (mm/dia), nebulosidade/céu encoberto em percentual (%).

As informações de clima são organizadas por tempo e cidade. No entanto, como as variáveis dependentes deste trabalho se referem aos fundos, opta-se por indexar as variáveis climáticas também por  $p$  para representar adequadamente a relação funcional avaliada entre as variáveis.

## 2.5. Análise descritiva

Esta seção detalha a base de dados utilizada, explica os filtros aplicados e seus impactos sobre a amostra. Primeiramente, são apresentadas as informações sobre os fundos selecionados. Em seguida, são exibidas análises descritivas com as informações climáticas coletadas.

### 2.5.1. Fundos de Investimentos analisados

A base de dados analisada contempla fundos de investimento de gestão ativa observados no período entre janeiro de 2002 e dezembro de 2016. São excluídos fundos de cotas de fundos de investimento; e fundos de gestão passiva, os quais são definidos como fundos com atuação atrelada a um índice de mercado e que não cobram taxa de desempenho.

A Tabela 10 apresenta a distribuição de fundos por classes de atuação, de acordo com a Classificação Anbima. Para cada grupo é informado a quantidade de fundos analisados, o número de observações e patrimônio líquido médio em milhões de reais (R\$ milhões).

Como se pode observar, a base é composta por 776 fundos de gestão, os quais são distribuídos ao longo tempo e totalizam 1.144.832 observações diárias. Ademais, os fundos são distribuídos em 13 categorias as quais apresentam patrimônio líquido médio entre R\$ 66,6 milhões e R\$ 195,6 milhões. Os fundos da base possuem patrimônio líquido médio de R\$ 130,2 milhões.

**Tabela 10: Distribuição de Fundos por Classes**

<b>Classificação Anbima</b>	<b>Qtde. Fundos</b>	<b>Qtde. Observações</b>	<b>PL Médio (R\$ Milhões)</b>
Ações Dividendos	43	60.108	195,6
Ações IBOVESPA Ativo	104	121.064	66,6
Ações IBOVESPA Ativo com Alavancagem	19	12.398	44,3
Ações IbrX Ativo	36	38.683	172,4
Ações IbrX Ativo com Alavancagem	3	1.828	60,6
Ações IbrX Indexado	1	1.178	117,0
Ações Indexados	5	4.951	64,9
Ações Índice Ativo	147	262.523	129,0
Ações Livre	387	504.821	143,5
Ações Livre com Alavancagem	7	6.018	24,4
Ações Small Caps	25	43.618	101,9
Ações Sustentabilidade/Governança	16	32.695	169,4
Ações Valor/Crescimento	37	54.947	91,0
<b>Total</b>	<b>776</b>	<b>1.144.832</b>	<b>130,2</b>

*Nota: A tabela informa a distribuição dos fundos de acordo com classificação Anbima. A primeira se refere a classificação Anbima em questão e as demais colunas informam, respectivamente, a quantidade de fundos, o número de observações e o valor médio do patrimônio líquido observado em moeda de maio de 2018.*

A Tabela 11 apresenta a distribuição dos fundos ao longo dos anos analisados. Para cada ano da base a tabela informa a quantidade de fundos analisados, o número de observações e patrimônio líquido médio em R\$ milhões.

Pela análise da tabela é possível notar que o período apresenta tendência de elevação no número de observações, com 117 fundos e 27.111 observações para o ano de 2002 e 449 fundos e 104.823 observações no ano de 2016. No entanto, apesar dessa tendência, para todos os anos da base a amostra de dados é representativa. Em termos de valor médio de patrimônio líquido dos fundos, também há elevação nos anos iniciais da base. Porém, o valor é razoavelmente estável nos anos posteriores a 2009.

**Tabela 11: Distribuição de Fundos no tempo**

<b>Ano</b>	<b>Qtde. Fundos</b>	<b>Qtde. Observações</b>	<b>PL Médio (R\$ Milhões)</b>
2002	117	27.111	57,6
2003	123	28.804	58,5
2004	147	33.659	77,7
2005	146	31.362	86,0
2006	151	32.817	146,9
2007	216	45.081	224,7
2008	300	64.375	177,3
2009	356	77.636	134,4
2010	416	95.832	150,2
2011	460	106.010	143,8
2012	534	115.961	138,4
2013	571	127.201	143,1
2014	565	133.839	127,8
2015	521	120.321	103,5
2016	449	104.823	97,9
<b>Total</b>	<b>776</b>	<b>1.144.832</b>	<b>130,2</b>

*Nota: A tabela informa a distribuição dos fundos de acordo com anos da base. A primeira coluna informa o ano de referência e as demais colunas informam, respectivamente, a quantidade de fundos, o número de observações e o valor médio do patrimônio líquido observado em moeda de maio de 2018.*

Em termos de número de observações, a base acumula total de 1.144.832 observações, também com tendência positiva ao longo dos anos. Para o ano de 2002, a base possui um

total de 27.111 observações, mas atinge máximo de 133.839 observações o para ano de 2014 e encerra com 104.823 observações em 2016.

A Tabela 12 apresenta a distribuição dos fundos ao longo dos anos e cidades analisadas. Os fundos da base são distribuídos por 13 cidades, com relevante concentração nas cidades de São Paulo e Rio de Janeiro, porém apresenta também participação de cidades mais distantes dos principais centros financeiros do país, por exemplo Porto Alegre, Fortaleza e Brasília.

**Tabela 12: Número de fundos por cidade e ano**

Cidade	Anos (2002 – 2016)														
	02	03	04	05	06	07	08	09	10	11	12	13	14	15	16
São Paulo	85	80	97	82	82	128	183	209	231	269	306	321	338	329	282
Osasco	8	15	20	22	24	25	38	52	77	74	92	99	95	96	81
Rio de Janeiro	13	15	18	18	17	26	40	19	24	45	58	64	61	61	57
Poá	-	-	-	12	18	25	26	43	49	50	54	54	34	-	1
Porto Alegre	4	5	5	5	5	5	6	25	24	7	10	15	16	16	14
Barueri	-	-	-	-	-	-	-	-	-	8	7	10	11	10	8
Belo Horizonte	2	2	2	2	2	2	2	2	2	2	3	3	2	2	1
Curitiba	1	1	1	1	1	2	2	3	-	3	2	3	3	2	2
Fortaleza	1	1	1	1	1	2	2	2	2	2	2	2	3	3	1
Brasília	-	1	1	1	-	-	-	-	5	-	-	-	2	2	2
Salvador	2	2	2	2	1	1	1	1	2	-	-	-	-	-	-
Cachoeiras de Macacu	-	1	-	-	-	-	-	-	-	-	-	-	-	-	-
Cerqueira César	1	-	-	-	-	-	-	-	-	-	-	-	-	-	-
<b>Total</b>	<b>117</b>	<b>123</b>	<b>147</b>	<b>146</b>	<b>151</b>	<b>216</b>	<b>300</b>	<b>356</b>	<b>416</b>	<b>460</b>	<b>534</b>	<b>571</b>	<b>565</b>	<b>521</b>	<b>449</b>

*Nota: A tabela informa a distribuição dos fundos de acordo com ano e cidade em que o fundo é localizado. A primeira se refere a cidade em questão e as demais colunas informam a quantidade de fundos para cada cidade conforme ano analisado entre 2002 e 2016.*

A Tabela 13 exibe distribuição para as medidas de risco estimadas para os fundos conforme modelos de quatro fatores estimados em linha com equações (12) e (13). A tabela indica que a diferença na exposição a risco dos fundos implica relevante variabilidade nos retornos dos fundos uma vez que, como se pode observar, é distinta a distribuição observada para cada componente de retorno dos fundos. A diferença na exposição de risco observada para os fundos sinaliza heterogeneidade no estilo de

investimento entre os fundos, o que é pertinente ao objetivo do artigo em captar desvio do desempenho a fatores exógenos externos.

**Tabela 13: Análise descritiva dos alfas dos fundos e componentes do retorno**

Variável	Média	Desv. Pad	Mín	p05	Mediana	p95	Máx
coef. alfa ( $\hat{\alpha}$ )	0,004	0,032	-0,417	-0,030	0,006	0,035	0,065
coef. de mercado ( $\hat{\beta}$ )	0,577	0,166	-0,159	0,296	0,609	0,776	1,070
coef. de tamanho ( $\hat{\delta}$ )	-0,048	0,092	-0,350	-0,177	-0,053	0,101	0,564
coef. de valor ( $\hat{h}$ )	0,077	0,122	-0,312	-0,136	0,074	0,300	0,746
coef. de momento ( $\hat{w}$ )	0,092	0,079	-0,551	-0,033	0,096	0,7	0,394

*Nota: A tabela apresenta análise descritiva dos componentes de retorno dos fundos decompostos pelos quatro fatores conforme a equação (13). As estatísticas apresentadas consistem em: Média, desvio padrão (Dev. Pad), mínimo (Mín), percentil 5 (p05), mediana, percentil 95 (p95) e máximo (Máx).*

### 2.5.2. Informações climáticas analisadas

Conforme apresentado na seção 2.4.3, a base completa de informações climáticas abrange o período entre 1986 e 2019, porém utiliza-se o período completo apenas para cálculo do clima. As demais variáveis são calculadas com base no período de 2002 a 2016.

A Tabela 14 e a Tabela 15 apresentam uma análise descritiva das variáveis utilizadas. A Tabela 14 informa, para cada cidade da amostra brasileira, informações de média, desvio padrão, máximo, mínimo e outros percentis da distribuição das variáveis de temperatura, precipitação e nebulosidade. A Tabela 15 se dedica a comparar a distribuição das variáveis climáticas de acordo com a transformação analisadas: em nível, média de longo prazo e desvio em relação a média de longo prazo.

Como se pode observar pela análise da Tabela 14, a medida de temperatura varia entre mínima de 3,5°C observada para Porto Alegre e máxima de 31,6°C em Brasília. Em termos médios a cidade com menor média é Porto Alegre e a mais quente Fortaleza. Porém, mesmo nas regiões de São Paulo e Rio de Janeiro, que são mais representativas da base, se pode observar que a variável oscila entre 10,4° e 28,6°C, portanto também com amplitude relevante.

As demais variáveis apresentam variabilidade com intensidade semelhante. Em termos da precipitação, seu valor é mais elevado na cidade de Curitiba e tem sua mínima em Salvador. Para nebulosidade, quase todas as cidades apresentem mínima de zero e máxima próxima a 80%.

**Tabela 14: Análise descritiva informações climáticas por cidade**

Cidade	Média	Desv. Pad.	Mín	p05	Mediana	p95	Máx
<b>Painel A: Temperatura (°C)</b>							
São Paulo	20,4	2,8	10,4	15,5	20,6	24,2	28,6
Rio de Janeiro	22,9	2,0	16,7	19,2	22,9	26,0	27,2
Poá	20,2	2,7	10,4	15,2	20,5	24,1	28,5
Porto Alegre	18,4	4,1	3,5	10,6	18,9	24,1	27,1
Osasco	20,4	2,8	10,4	15,5	20,6	24,2	28,6
Barueri	20,5	2,8	10,4	15,6	20,7	24,4	28,6
Curitiba	19,1	3,4	4,7	12,6	19,6	23,7	25,9
Brasília	22,7	2,3	15,2	19,6	22,5	27,9	31,6
Cerqueira César	21,1	2,6	11,7	16,0	21,5	24,7	28,0
Belo Horizonte	20,5	2,2	12,5	16,7	20,7	24,1	29,1
Fortaleza	26,7	1,8	23,2	24,2	26,5	29,6	30,7
Salvador	23,6	1,9	18,6	20,6	23,7	26,5	29,0
Cachoeiras de Macacu	23,0	2,3	17,6	18,7	23,1	26,1	27,2
<b>Painel B: Precipitação (mm/dia)</b>							
São Paulo	4,7	5,6	0,0	0,0	2,3	15,5	45,3
Rio de Janeiro	2,3	4,0	0,0	0,0	0,3	10,5	55,6
Poá	4,8	5,6	0,0	0,0	2,6	15,8	45,3
Porto Alegre	4,8	6,8	0,0	0,0	1,5	17,9	85,1
Osasco	4,7	5,7	0,0	0,0	2,4	15,6	45,3
Barueri	4,8	5,8	0,0	0,0	2,4	15,7	45,3
Curitiba	5,1	6,1	0,0	0,0	2,9	15,8	55,8
Brasília	4,4	5,2	0,0	0,0	2,3	13,7	28,4
Cerqueira César	4,3	5,1	0,0	0,0	2,0	13,8	21,1
Belo Horizonte	4,5	6,0	0,0	0,0	1,4	15,4	63,1
Fortaleza	3,4	4,7	0,0	0,0	0,9	13,5	30,6
Salvador	1,9	3,3	0,0	0,0	0,5	8,4	39,7
Cachoeiras de Macacu	2,7	4,4	0,0	0,0	0,6	11,6	26,8
<b>Painel C: Percentual de céu encoberto (%)</b>							
São Paulo	30,9	17,8	0,0	5,0	30,0	63,0	87,0
Rio de Janeiro	32,3	16,9	1,0	8,0	31,0	62,0	82,0
Poá	31,1	18,2	0,0	4,0	30,0	63,0	87,0
Porto Alegre	23,7	18,9	0,0	0,0	21,0	60,0	89,0
Osasco	31,0	17,9	0,0	4,0	30,0	63,0	87,0
Barueri	30,8	17,4	0,0	5,0	29,0	62,0	87,0
Curitiba	28,7	18,7	0,0	1,0	28,0	60,0	88,0
Brasília	34,6	18,3	0,0	5,0	37,0	63,0	84,0
Cerqueira César	29,4	17,3	0,0	6,0	27,0	59,6	76,0
Belo Horizonte	29,1	18,2	0,0	3,0	27,0	62,0	85,0
Fortaleza	37,3	15,2	2,0	14,0	37,0	63,0	78,0
Salvador	21,3	16,2	0,0	2,0	17,0	54,0	78,0
Cachoeiras de Macacu	32,8	16,5	4,0	9,0	31,0	60,6	82,0

*Nota: A tabela apresenta análise descritiva para as informações climáticas coletadas, conforme cidade analisada. São apresentadas informações para temperatura, precipitação e percentual de céu encoberto, respectivamente no Painel A, Painel B e Painel C. As estatísticas apresentadas consistem em: Média, desvio padrão (Dev. Pad), mínimo (Mín), percentil 5 (p05), mediana, percentil 95 (p95) e máximo (Máx).*

**Tabela 15: Análise descritiva variáveis climáticas**

Variável	Média	Desv. Pad.	Mín	p05	Mediana	p95	Máx
<b>Painel A: Variável climáticas em nível</b>							
temp (°C)	20,89	2,90	7,15	15,15	21,65	24,75	28,45
prec (mm/dia)	5,64	5,58	0,00	0,00	4,58	15,27	29,20
neb (%)	33,87	17,71	0,00	6,00	35,00	64,00	83,00
<b>Painel B: Variável climáticas médias de longo prazo – clima</b>							
tempLP (°C)	21,06	2,15	12,91	17,48	21,58	24,66	28,49
precLP (mm/dia)	5,86	3,84	0,18	0,76	5,44	10,80	13,18
nebLP (%)	34,77	9,80	9,67	19,17	35,62	49,10	49,10
<b>Painel C: Desvio das variáveis climáticas em relação às médias de longo prazo (clima)</b>							
$\Delta$ temp (°C)	-0,17	1,97	-7,40	-3,43	0,02	2,42	5,42
$\Delta$ prec (mm/dia)	-0,21	4,37	-10,34	-5,61	-0,74	6,67	24,39
$\Delta$ neb (%)	-0,91	16,08	-28,62	-21,29	-4,10	27,95	54,52

*Nota: A tabela apresenta análise descritiva para as informações climáticas utilizadas. No painel A são informadas estatísticas para as variáveis climáticas em nível. No Painel B são apresentadas as médias de longo prazo para as variáveis climáticas, as quais são calculadas com base em histórico completo ente 1986 e 2019. No Painel C são organizadas análises descritivas dos desvios das variáveis em relação a respectiva média de longo prazo. As estatísticas apresentadas consistem em: Média, desvio padrão (Dev. Pad), mínimo (Mín), percentil 5 (p05), mediana, percentil 95 (p95) e máximo (Máx).*

Com base na análise da Tabela 15, é possível observar os efeitos decorrentes das transformações realizadas sobre as variáveis climáticas, como descrito na seção 2.4.3. Enquanto as variáveis em nível e médias de longo prazo (clima) apresentam valores próximos aos observados para as médias por cidade, desvios em relação a média de longo prazo, naturalmente, tem todos médias próximas de zero. O valor médio não é igual a zero, pois as médias de longo prazo são calculadas com horizonte superior ao analisada neste estudo e para o qual existem dados disponíveis para fundos de investimento.

## 2.6. Resultados

### 2.6.1. Relação entre desempenho e variações climáticas

Em linha com especificação proposta por Hirshleifer e Shumway (2003), em sua análise de efeitos do clima sobre retorno de ações, começa-se com a avaliação da seguinte especificação:

$$R_{p,t}^* = \gamma_1 \Delta \text{temp}_{p,t} + \gamma_2 \Delta \text{temp}_{p,t}^2 + \gamma_3 \Delta \text{prec}_{p,t} + \gamma_4 \Delta \text{neb}_{p,t} + EF_p + EF_t \quad (17)$$

em que, conforme exposto em detalhes na seção 2.4,  $R_{p,t}^*$  se refere ao retorno ajustado por risco pelo modelo de quatro fatores de Carhart (1997) do fundo  $p$  no instante  $t$ ;  $\Delta\text{temp}_{c,t}$ ,  $\Delta\text{prec}_{c,t}$ , e  $\Delta\text{nebul}_{c,t}$  representam, respectivamente, o desvio em relação a média de longo prazo das variáveis temperatura, precipitação e nebulosidade no instante  $p$  na cidade do fundo  $p$ ; e  $EF_p$  e  $EF_t$  representam os efeitos fixo de fundo e tempo.

Em termos de unidade de medida, o retorno é expresso em percentual, temperatura em °C, precipitação em milímetros por dia, e nebulosidade em percentual. O desvio padrão dos coeficientes é estimado com cluster de cidade.

Cabe destacar que, para a variável de temperatura, é incluso termo quadrático. Essa inclusão decorre das evidências que temperatura possui efeito não linear sobre desempenho dos indivíduos. Mais especificamente, uma relação côncava entre as variáveis, portanto, com ponto de máximo (Seppanen *et al.*, 2006). Desse modo, é incluso o termo quadrático, de modo que, se este apresentar valor negativo e significativo, existe evidência que a relação também é côncava para a amostra analisada. Para as demais variáveis é incluso apenas o termo linear em linha com prática da literatura.

O resultado da regressão é apresentado na Tabela 16 e ilustrado na Figura 3. A tabela informa o resultado obtido para diversas especificações alternativas nas colunas de (1) a (5), e na coluna (6), a especificação completa. Para cada variável é apresentada seu efeito estimado, em seguida, entre colchetes, o coeficiente estimado quando os desvios em torno da média de longo prazo são expressos em desvios padrão; por fim, entre parênteses, a estatística  $t$  calculada. A figura ilustra os efeitos individuais de cada variável, mantendo as demais variáveis em seu valor médio.

Os coeficientes estimados representam o impacto esperado, em termos de retorno ajustado por risco, do desvio das variáveis climáticas em relação a sua média de longo prazo. Assim sendo, tem-se que, exceto pela variável nebulosidade, as variáveis demonstram efeito significativo sobre o desempenho dos fundos.

As estimações feitas para a variável precipitação indicam sempre um efeito negativo sobre o desempenho. Por exemplo, na especificação completa apresentada na coluna (6), estima-se uma queda, estatisticamente significativa, de 0,0024% no retorno do fundo para um aumento de 1 mm no volume de precipitação, ou, em termos de desvio padrão, queda de 0,0104% para aumento de um desvio padrão no volume de precipitação. Como referência de magnitude, pode-se comparar efeitos de retornos decrescentes de

escala estimados pela literatura. Como exemplo, para os Estados Unidos estima-se que, em média, o aumento de U\$ 1 milhão no tamanho um fundo, implica em queda de  $0.000479\% \times 10^{-3}$  nos retornos ajustados por risco desses fundos (Zhu, 2018).

Por sua vez, a variável de nebulosidade demonstra efeito significativo para as especificações em que essa não é regredida junto a variável de precipitação. Porém, uma vez que precipitação é adicionada à regressão, aquela perde sua significância. O fato possivelmente se dá devido a correlação elevada (0,62) entre as variáveis.

Por fim, para temperatura, observa-se evidência significativa da relação côncava entre as variáveis por meio da estimação negativa e significativa do termo quadrático ( $\Delta\text{temp}^2$ ) em  $-0,00247$ . Pode-se validar mais adequadamente o efeito côncavo estimado para temperatura pela relação ilustrada na Figura 3. Como se pode observar, mantida as demais variáveis constantes em seus valores médios, a variação de temperatura demonstra um efeito côncavo e significativo com ponto de ótimo próximo a zero, portanto ponto de máximo desempenho quando a temperatura observada é próxima da temperatura média de longo prazo para cidade e data em questão.

**Tabela 16: Efeito clima sobre desempenho dos fundos**

Variável	(1)	(2)	(3)	(4)	(5)	(6)
<b><math>\Delta\text{temp}</math></b>	-0,004*** [-0,0079] (-4,95)			-0,0038*** [-0,0077] (-4,54)	-0,0043*** [-0,0087] (-4,71)	-0,0038*** [-0,0077] (-4,28)
<b><math>\Delta\text{temp}^2</math></b>	-0,002*** [-0,0090] (-5,59)			-0,0025*** [-0,0096] (-5,54)	-0,0024*** [-0,0095] (-5,30)	-0,0025** [-0,0096] (-5,33)
<b><math>\Delta\text{prec}</math></b>		-0,0022*** [-0,0095] (-4,74)		-0,0025*** [-0,0107] (-4,63)		-0,0024*** [-0,0104] (-5,76)
<b><math>\Delta\text{cld}</math></b>			-0,0003* [-0,0044] (-1,72)		-0,0004** [-0,0067] (-2,21)	-0,0000 [-0,0004] (-0,14)
<b>R<sup>2</sup> ajustado</b>	0,02	0,02	0,02	0,02	0,02	0,02
<b>Efeito fixo de fundo</b>	Sim	Sim	Sim	Sim	Sim	Sim
<b>Efeito fixo de tempo</b>	Sim	Sim	Sim	Sim	Sim	Sim
<b>Cluster cidade</b>	Sim	Sim	Sim	Sim	Sim	Sim
<b>Observações</b>	1.144.832	1.144.832	1.144.832	1.144.832	1.144.832	1.144.832


\* $p < 0,10$ ; \*\* $p < 0,05$ ; \*\*\* $p < 0,01$ .

Nota: A tabela informa o resultado da regressão do efeito linear entre as variável de clima e o desempenho ajustado por risco do fundo. São apresentados os valores dos coeficientes estimados para cada variável, em seguida, entre colchetes, os coeficientes estimados quando os desvios em relação as médias de longo prazo são expressos em desvios padrão; e, entre parênteses, os valores das estatísticas t calculadas. Em termos de unidade de medida, a variável dependente ( $R_{p,t}^*$ ) é expressa em percentual, temperatura em °C, precipitação em mm/dia, e nebulosidade.

As relações das demais variáveis também podem ser avaliadas pela Figura 3. Para precipitação ilustra-se o efeito negativo sobre o retorno dos fundos à medida que se eleva

o volume de precipitação. Por fim, para a variável de nebulosidade, constata-se nenhuma alteração do retorno dos fundos a depender do valor da variável.

**Figura 3: Efeito clima sobre desempenho dos fundos**



As análises desta seção trazem evidências do efeito de variações climáticas sobre o desempenho dos fundos. Precipitação demonstra ter efeitos negativos e temperatura indica uma relação côncava com ponto de máximo quando a temperatura é próxima a sua média de longo prazo. As evidências estão em linha com a literatura em situações similares em que se analisa como tais fatores afetam as capacidades cognitivas dos indivíduos. O resultado também está em linha com outras evidências que demonstram os efeitos de condições climáticas externas sobre os indivíduos, mesmo quando esses estão de certa forma isolados em um ambiente fechado (Baylis, 2015; Cheema & Patrick, 2012; Duxbury *et al.*, 2020; Fang *et al.*, 2004; Hancock & Vasmatzidis, 2003; Heyes & Saberian, 2019; Seppanen *et al.*, 2006).

### 2.6.2. Efeitos considerando diferentes parâmetros médios de longo prazo

As evidências apresentadas na seção anterior indicam a relação entre o desempenho dos fundos e fatores climáticos externos. No entanto, os testes realizados não quantificam a sensibilidade do efeito a depender das condições médias de clima da região e época do ano. Contudo, a literatura aponta que as variações de temperatura, precipitação ou nebulosidade têm efeitos distintos a depender do clima padrão do local analisado. Por exemplo, espera-se que aumentos da temperatura tenham efeito distinto em um ambiente frio em relação ao efeito esperado para um ambiente com temperaturas elevadas. Mesmo na especificação do efeito côncavo para temperatura, não é possível identificar diferenças nos efeitos a depender das condições médias do local analisado.

Diante desse fato, são estimados os efeitos a depender das condições médias de longo prazo observadas. Para tanto, avalia-se uma especificação semelhante à anterior, porém com acréscimo de termos de interação entre as variáveis de desvio da média de longo prazo e as próprias médias de longo prazo. Com isso, obtém-se a seguinte especificação:

$$R_{p,t}^* = \gamma_1 \Delta \text{temp}_{p,t} + \gamma_2 \Delta \text{temp}_{p,t}^2 + \gamma_3 \Delta \text{prec}_{p,t} + \gamma_4 \Delta \text{neb}_{p,t} + \text{EF}_p + \text{EF}_t + \gamma_5 \Delta \text{temp}_{p,t} \times \text{tempLP}_p + \gamma_6 \Delta \text{prec}_{p,t} \times \text{precLP}_p + \gamma_7 \Delta \text{neb}_{p,t} \times \text{nebLP}_p \quad (18)$$

em que, conforme exposto em detalhes na seção 2.4 e aplicado na seção anterior,  $R_{p,t}^*$  se refere ao retorno ajustado por risco pelo modelo de quatro fatores de Carhart (1997) do fundo  $p$  no instante  $t$ ;  $\Delta \text{temp}_{c,t}$ ,  $\Delta \text{prec}_{c,t}$ , e  $\Delta \text{neb}_{c,t}$  representam, respectivamente, o desvio em relação ao clima de longo prazo das variáveis temperatura, precipitação e nebulosidade no instante  $p$  na cidade do fundo  $p$ ;  $\text{EF}_p$  e  $\text{EF}_t$  representam os efeitos fixos de fundo e tempo; e  $\text{tempLP}_{p,t}$ ,  $\text{precLP}_{p,t}$ , e  $\text{nebLP}_{p,t}$  se referem aos climas de longo prazo para temperatura, precipitação e nebulosidade da cidade do fundo  $p$  no instante  $t$ .

O propósito do uso dessa especificação está em permitir a estimação do efeito marginal decorrente do desvio das variáveis em relação a sua média de longo prazo, isto é, com essa especificação é possível medir o impacto decorrente dos desvios condicionados a diferentes níveis médio de longo prazo. Mais especificamente, deste modo é possível estimar as seguintes relações:

$$\frac{\partial R_{p,t}^*}{\partial \Delta \text{temp}} = \gamma_1 + 2 \times \gamma_2 \Delta \text{temp}_{p,t} + \gamma_5 \text{tempLP}_p \quad (19)$$

$$\frac{\partial R_{p,t}^*}{\partial \Delta \text{prec}} = \gamma_3 + \gamma_6 \text{precLP}_p \quad (20)$$

$$\frac{\partial R_{p,t}^*}{\partial \Delta \text{neb}} = \gamma_4 + \gamma_7 \text{nebLP}_p \quad (21)$$


A especificação em questão segue o proposto por Mendelsohn (2017) para avaliar efeitos climáticos em dados em painel, com a vantagem de evitar a imposição de hipóteses

muito fortes no tocante à relação entre a variável dependente e as variáveis climáticas, uma prática comum nessa literatura.

Os resultados obtidos pelas estimações desses efeitos marginais para temperatura são ilustrados na Figura 4. Para facilitar a comparação entre os efeitos das diferentes variáveis climáticas, os efeitos são estimados para variações em um desvio padrão, portanto, no caso de temperatura,  $\Delta temp = 2^\circ\text{C}$  aproximadamente. Na parte superior da Figura 4 são apresentados os efeitos sobre o desempenho do fundo decorrente de variações da temperatura em relação a sua média de longo prazo. Na parte inferior é apresentado um histograma que ilustra a distribuição da variável em questão.

Como se pode observar, para temperaturas baixas, os aumentos da temperatura têm efeitos nulos sobre o desempenho do fundo. Por outro lado, quando se analisam cenários mais quentes, acima de  $18^\circ\text{C}$ , aumentos de temperatura têm impactos negativos sobre o desempenho do fundo. Nos casos mais extremos, quando temperatura supera os  $25^\circ\text{C}$ , aumentos de temperatura em um desvio padrão ( $2^\circ\text{C}$ ) tendem a gerar quedas de desempenho de aproximadamente 0,0592%.

**Figura 4: Impacto Marginal de  $\Delta temp = 1$  desvio padrão ( $2^\circ\text{C}$ ) – Brasil**




Na Figura 5 e Figura 6 são apresentadas análises equivalentes, porém para as variáveis de precipitação e nebulosidade, respectivamente.

Para precipitação conclui-se que, em locais e datas com clima pouco chuvoso, o aumento do volume de chuvas implica em quedas no desempenho dos fundos. Porém, quando o volume de precipitação já é elevado para o local e data analisada, não há evidências de impacto sobre o desempenho do fundo.


Por fim, em termos de nebulosidade, para regiões e datas tradicionalmente com baixos percentuais de céu encoberto, portanto, menos nebulosas, o aumento no volume de nuvens no céu implica em aumento no desempenho dos fundos. Por sua vez, regiões e datas com baixos níveis de luminosidade, portanto, mais nebulosos, têm queda na produtividade quando há aumento no volume de nuvens.

Os resultados fortalecem as evidências de que há impacto de fatores climáticos externos sobre o desempenho dos fundos, mesmo sabendo que seus gestores normalmente são de certa forma protegidos das variações climáticas externas durante seus horários de trabalho, uma vez que normalmente realizam suas atividades em ambientes climatizados e com iluminação artificial adequada. Ademais, os efeitos demonstram variar a depender dos níveis médios de temperatura, precipitação e nebulosidade observados nos locais e datas analisadas.

**Figura 5: Impacto Marginal de  $\Delta prec = 1$  desvio padrão (4,4 mm) – Brasil**



**Figura 6: Impacto Marginal de  $\Delta neb = 1$  desvio padrão (16,1%) – Brasil**



### 2.6.3. Métricas de desempenho alternativas

Nesta seção são apresentados os resultados obtidos se avaliadas as métricas alternativas de desempenhos. Para tanto, avalia-se o resultado se considerados como métricas de desempenho o retorno acima do retorno de mercado (*Market Adjusted Return – MAR*) ou retornos ajustados por risco de acordo com modelos fatoriais CAPM, modelo de três fatores (M3F), ou modelo de quatro fatores.

Os resultados obtidos são resumidos na Tabela 17, em que são apresentados, de acordo com cada métrica de risco avaliada, os coeficientes estimados para a especificação completa, conforme equação (18).

Como se pode observar, ao analisar os valores estimados e compará-los com os estimados para a métrica M4F, nota-se os resultados são equivalentes entre as demais métricas de desempenho, exceto pela métrica de MAR. Entende-se que a falta de robustez observada ao se avaliar os resultado obtidos para a métrica MAR se deve à natureza do indicador. A métrica em questão é a menos criteriosa dentre as avaliadas por ser o simples resultado da diferença entre retorno do fundo e retorno de mercado, é um ajuste homogêneo entre fundos e não leva em conta o perfil de risco de cada fundo avaliado. Entende-se também que essa deve ser a explicação para que diversos coeficientes estimados para essa métrica não apresentem significância estatística.

**Tabela 17: Análise de robustez do efeito clima sobre desempenho dos fundos**

Variável	MAR (1)	CAPM (2)	M3F (3)	M4F (4)
$\Delta temp$	0,0156 [0,0309] (0,62)	0,0640*** [0,1265] (5,58)	0,0638*** [0,1261] (5,99)	0,0601*** [0,1188] (5,45)
$\Delta temp^2$	0,0000 [0,0001] (0,05)	-0,0020*** [-0,0073] (-4,18)	-0,0019*** [-0,0074] (-4,25)	-0,0021*** [-0,0081] (-4,66)
$\Delta prec$	0,0031*** [0,0134] (8,26)	-0,0040*** [-0,0118] (-4,27)	-0,0040*** [-0,018] (-3,99)	-0,0044*** [-0,196] (-4,86)
$\Delta cld$	-0,0039*** [-0,0623] (-4,83)	0,0023*** [0,0377] (5,83)	0,0020*** [0,0330] (5,46)	0,0023*** [0,0376] (6,31)
$\Delta temp \times tempLP$	-0,0013 [-0,0025] (-1,04)	-0,0035*** [-0,0070] (-6,00)	-0,0035*** [-0,0070] (-6,48)	-0,0033*** [-0,0064] (-5,87)
$\Delta prec \times precLP$	-0,0005*** [-0,0020] (-5,07)	0,0005*** [0,0023] (3,52)	0,0004** [0,0023] (2,98)	0,0004*** [0,0019] (3,40)
$\Delta cld \times cldLP$	0,0001** [0,0012] (2,91)	-0,0001*** [-0,0015] (-4,71)	-0,0001*** [-0,0013] (-4,58)	-0,0001*** [-0,0014] (-4,81)
<b>R<sup>2</sup> ajustado</b>	0,02	0,02	0,02	0,02
<b>Efeito fixo de fundo</b>	Sim	Sim	Sim	Sim
<b>Efeito fixo de tempo</b>	Sim	Sim	Sim	Sim
<b>Cluster cidade</b>	Sim	Sim	Sim	Sim
<b>Observações</b>	1.144.832	1.144.832	1.144.832	1.144.832

*Nota: A tabela informa o resultado da regressão do efeito entre as variável de clima e o desempenho ajustado por risco do fundo de acordo com métricas decorrentes de Market adjusted return, isto é, retorno acima do retorno de mercado (MAR); modelo CAPM; modelo de três fatores (M3F); e modelo de quatro fatores (M4F). São apresentados os valores dos coeficientes estimados para cada variável, em seguida, entre colchetes, os coeficientes estimados quando os desvios em relação as médias de longo prazo são expressos em desvios padrão; e, entre parênteses, os valores das estatísticas t calculadas.*

#### **2.6.4. Avaliação com dados dos Estados Unidos**

Conforme exposto na seção 2.5, a base de fundos brasileira apresenta fundos localizados em 13 cidades, no entanto, com a maioria deles localizado nas regiões próximas a São Paulo e ao Rio de Janeiro. Apesar desse fato, a base apresenta relevante variabilidade nas variáveis de clima decorrentes do horizonte de tempo avaliado.

Contudo, é adequado avaliar os efeitos testados em um conjunto de dados com maior variabilidade climática do que a observada na base brasileira. Diante disso, são apresentados a seguir os resultados obtidos se aplicados os mesmos testes sobre conjunto de dados norte-americanos.

A base em questão contempla retornos diários de 8.638 fundos de ações de gestão ativa observados entre janeiro de 2003 e dezembro de 2019, distribuídos por 268 cidades e com total de 19.878.963 observações. Assim como a base brasileira, a base dos Estados Unidos também apresenta concentração de dados em algumas cidades, porém bem menos acentuado que o caso brasileiro. Na base, Nova York e Chicago são as cidades com maior número de observações com 20,5% e 17,7%, respectivamente. No entanto, a terceira cidade é Boston, a qual já possui concentração muito menor, de 3,7%.

A variabilidade dos dados climáticos por sua vez pode ser observada nos resultados apresentados a seguir. A Figura 7, Figura 8, e Figura 9 apresentam os resultados obtidos com dados norte-americanos.

Como se pode observar, o sentido da relação observada entre temperatura e desempenho é semelhante ao observado com os dados brasileiros. A Figura 7 ilustra que, para temperaturas muito baixas, aumentos de temperatura têm efeito positivo sobre o desempenho, porém o efeito é negativo quando a temperatura é elevada para local e data analisados. Por sua vez a relação se inverte em comparação ao estimado para o Brasil quando avaliados os componentes de precipitação e nebulosidade.

De todo modo, mesmo que com sinais opostos aos estimados com dados brasileiros em relação a precipitação de nebulosidade, os resultados demonstram robustez nas evidências de efeitos significantes de variações climáticas sobre desempenho de fundos.

A inversão de sinais para os efeitos de precipitação e nebulosidade entre Brasil e Estados Unidos pode estar ligado diferenças das variabilidades climáticas entre os dois

países. No entanto, as análises apresentadas nesse trabalho não são capazes de justificar essa diferença e, portanto, devem ser objeto de análise para pesquisas futuras.


**Tabela 18: Efeito clima sobre desempenho dos fundos dos Estados Unidos**

Variável	(1)	(2)	(3)	(4)	(5)	(6)
$\Delta temp$	0,0002* [0,0008] (1.74)			0,0002 [0,0006] (1.50)	0,0001 [0,0004] (1.29)	0,0001 [0,0004] (1.08)
$\Delta temp^2$	-0,0000 [-0,0002] (-1.19)			-0,0000 [-0,0002] (-1.39)	-0,0000 [0,0002] (-1.27)	-0,0000 [0,0002] (-1.42)
$\Delta prec$		0,0007*** [0,0035] (3.00)		0,00070*** [0,0033] (3.06)		0,0006*** [0,0028] (3.96)
$\Delta cld$			-0,0002*** [-0,0042] (-4.41)		-0,0003*** [0,0044] (-4.56)	-0,0003*** [0,0049] (-4.69)
$\Delta temp \times tempLP$	-0,0000** [-0,0001] (-1.85)			-0,0000* [0,0001] (-1.69)	-0,0000** [0,0001] (-1.87)	-0,0000* [0,0001] (-1.68)
$\Delta prec \times precLP$		-0,0002*** [0,0008] (-2.85)		-0,0002*** [0,0007] (-2.85)		-0,0002*** [0,0002] (-3.66)
$\Delta cld \times cldLP$			0,00001*** [0,0002] (5.92)		0,0000*** [0,0002] (6.02)	0,0000*** [0,0002] (6.19)
<b>R<sup>2</sup> ajustado</b>	0,00	0,00	0,00	0,00	0,00	0,00
<b>Efeito fixo de fundo</b>	Sim	Sim	Sim	Sim	Sim	Sim
<b>Efeito fixo de tempo</b>	Sim	Sim	Sim	Sim	Sim	Sim
<b>Cluster cidade</b>	Sim	Sim	Sim	Sim	Sim	Sim
<b>Observações</b>	19.878.963	19.878.963	19.878.963	19.878.963	19.878.963	19.878.963


\* $p < 0,10$ ; \*\* $p < 0,05$ ; \*\*\* $p < 0,01$ .

Nota: A tabela informa o resultado da regressão do efeito entre as variável de clima e o desempenho ajustado por risco do fundo para amostra de dados dos Estados Unidos. São apresentados os valores dos coeficientes estimados para cada variável, em seguida, entre colchetes, os coeficientes estimados quando os desvios em relação as médias de longo prazo são expressos em desvios padrão; e, entre parênteses, os valores das estatísticas t calculadas.


**Figura 7: Impacto Marginal de  $\Delta temp = 1$  desvio padrão (3,8°C) – EUA**



**Figura 8: Impacto Marginal de  $\Delta prec = 1$  desvio padrão (4,9 mm)– EUA**



**Figura 9: Impacto Marginal de  $\Delta\text{neb} = 1$  desvio padrão (16,3%) – EUA**



## 2.7. Conclusão

Apesar da ampla literatura dedicada ao estudo da relação entre fatores climáticos e produtividade, inclusive na área de finanças, pelo nosso conhecimento, nenhum outro trabalho se debruça sobre a relação entre eventos climáticos e o desempenho de fundos de investimento, o que torna a presente pesquisa a primeira a abordar o assunto.

Dentre as vantagens da análise está a riqueza dos dados. Por um lado, variáveis climáticas são ótimos mecanismos para avaliação da capacidade de processamento de informações dos mercados financeiros, uma vez que são genuinamente exógenas e observáveis (Roll, 1992). Por outro lado, a diversidade dos dados financeiros, os quais permitem avaliações em diversos momentos no tempo, frequências e localidades.

Nesse contexto o presente trabalho aponta evidências que fatores climáticos têm efeitos estatisticamente significantes sobre o desempenho dos fundos de investimento ativo em ações. O trabalho traz evidências que tais efeitos são distintos a depender do clima padrão da região e data analisados. Por exemplo, com base nos dados brasileiros tem-se que, quando avaliados em climas com temperatura entre 16°C e 18°C, aumentos de 1°C não tem efeitos sobre o desempenho, no entanto, à medida que se avaliam climas mais quentes, o aumento na temperatura tem efeitos cada vez mais negativos. Para os Estados Unidos o comportamento é semelhante, porém é possível explorar a maior amplitude dos dados climáticos. Para esse conjunto de dados evidencia-se que aumentos na temperatura quando o clima tem média inferior a 0°C traz impacto positivo sobre o

desempenho porém, à medida que são avaliados climas mais quentes, o impacto passa a ser negativo.

Os resultados complementam estudos anteriores dedicados a avaliação do desempenho de indivíduos em diferentes condições climáticas com resultados que fortalecem a hipótese de efeito significativo. Não é escopo do trabalho determinar os canais pelos quais ocorre essa relação, porém a literatura tem explorado efeitos climáticos como proxies de humor no desempenho do mercado e como essa tem efeitos sobre as decisões dos investidores.

### **3. Unskilled fund managers: replicating active fund performance with few ETFs**

#### **3.1. Abstract**

This paper use Exchange Traded Funds (ETFs) instead of risk factors as benchmarks to examine active mutual fund performance distribution. While transaction costs are included in the ETF returns, that is not true regarding risk factors, making it more challenging to characterize extraordinary performances via alphas. Assessments are based on the proportion of skilled funds, defined as positive-alpha funds. Such a proportion is calculated taking into account potential false discoveries and employing the method devised by Barras et al. (2010). After evaluating several ETF combinations, we conclude that sets of 3 to 5 ETFs replicate most levels of active fund performance. Finally, we propose specific ETF selection algorithms, whereby we estimate that 95% of active management funds fail to generate value for their investors. Alphas calculated with ETFs are higher than those using risk factors, and the difference is similar to the transaction costs required for investing in risk factor portfolios (Frazzini et al., 2012).

#### **3.2. Introduction**

In this paper, we use Exchange Traded Funds (ETFs) instead of risk factors as benchmarks to examine active mutual fund performance distribution. While transaction costs are included in the ETF returns, that is not true regarding risk factors, making it more challenging to characterize extraordinary performances via alphas. We base our assessment on the False Discovery Rate (FDR) method developed by Barras *et al.* (2010), employing a sample of active U.S. asset mutual funds from 2005 to 2019.

In regards to alphas, our results are distinct from those obtained using risk factors, and the difference is nearly the same as the transaction costs required for investing in risk factor portfolios (Frazzini *et al.*, 2012). On the other hand, akin to the results obtained by approaches that use risk factors (Barras *et al.*, 2010), we estimate that approximately 95% of the industry fails to generate value for its investors. Moreover, we point to the fact that a random selection of ETFs is unsuited to outperform active funds; however, this can be achieved by applying specific guided methods to select a set of ETFs.

Using passive funds as benchmarks for active funds is not new. Malkiel (1995) argues that active managers should use passive funds as opportunity cost. Sharpe (1992)

seminal paper explain fund returns by twelve different asset class index. The author shows evidence that a constrained regression produces nearly the same results as a regular regression, which leads to the conclusion that individual investors are able to replicate certain funds' performance with a limited-leverage asset class index portfolio.

Although ETFs have shown massive growth in terms of capital allocation, only a small number of studies<sup>5</sup> have taken them into account. Using the Bloomberg database, we are able to find over 2,000 ETFs negotiated in the U.S. stock exchanges, which covers a significant variety of asset classes, geographic locations and investment strategies. By looking at ETFs focused only in the U.S. equity domestic markets, our dataset displays 875 funds, accounting for an overall sum of 2.1 trillion dollars of assets under management – AUM – as of December, 2019. The Lettau & Madhavan's (2018) survey suggests that this substantial growth might stem from the fact that ETFs are liquid instruments that include transaction costs, in addition to being able to replicate a wide range of investment strategies, including benchmarks.

In order to estimate the proportion of skilled active funds, we choose to focus on individual investors' net-of-fee performance and cost. We single out calculated alpha from net-of-fee excess returns, customarily used<sup>6</sup> to measure individual investors' economic returns. Therefore, in our terminology, a skilled fund is defined as any fund capable of delivering idiosyncratic returns after it is controlled by certain risks (a set of risk factors or, in our case, selected ETF excess returns).

From an econometric perspective, assessing the proportion of skilled active funds is something far from trivial since we have to deal with lucky and unlucky funds (false positives / Type I error). However, a wide range of papers has already addressed that issue. Fama & French (2010) propose a bootstrap procedure to calculate zero-alpha fund distribution and come to a conclusion on how skill funds are distributed after comparing them to empirical distribution<sup>7</sup>. Pástor & Stambaugh (2002), on the other hand, apply Bayesian techniques, setting priors for unskilled, zero-alpha and skilled fund distributions<sup>8</sup>. Chen *et al.* (2017) assume a parametric mixture model of distribution for

---

<sup>5</sup> See Alexander & Barbosa (2008) and Poterba & Shoven (2002) as examples of ETF-related economic studies.

<sup>6</sup> See Carhart (1997); Fama & French (2010); Malkiel (1995), Carhart (1997), Barras *et al.* (2010); Crane & Crotty (2018).

<sup>7</sup> See also Kosowski *et al.* (2006) and Ferson & Chen (2015).

<sup>8</sup> See also Baks *et al.* (2001) and Avramov & Wermers (2006).

alpha funds. We follow the False Discovery Rate (FDR) approach devised by Barras *et al.* (2010). The methodology controls luck funds by calculating their actual proportion within the overall sample. Additionally, it poses the benefits of not requiring prior assumptions about alpha fund distributions and has been widely applied in fund industry research<sup>9</sup>.

We propose specific algorithms that enable investors to choose a parsimonious set of ETFs suited to evaluate actively managed funds. We start with a random ETF selection. Repeating it several times, we measure the average outperforming capacity of a random ETFs group within mutual funds. Second, we propose an algorithm that chooses ETFs based on their ability to outperform mutual funds and to explain fund return variability. At last, applying lasso and forward selection, we select ETFs by looking into the risk factor space.

This paper aims, above all, to help introduce a chapter on ETFs to the discussion of active versus passive fund performance evaluation. Our findings support the current lack of skills existing in the active mutual fund industry.

### 3.3. Methodology

To evaluate whether actively managed funds generate value for their investors by outperforming passive investments, we follow standard procedures set forth in academic literature, as well as benchmarked funds against the investment opportunity set that passive investors have to deal with, in this case, the ETF net return.

Following the traditional viewpoint conveyed in the literature (Ardia & Boudt, 2018; Barras *et al.*, 2010; Fama & French, 2010), we define performance as fund managers' ability to generate higher alphas. Therefore, we begin our analysis with the following linear risk factor model:

$$r_{i,t} = \alpha_i + \boldsymbol{\beta}_i \mathbf{ETF}_t + \varepsilon_{i,t} \quad (22)$$

where  $r_{i,t}$  is the  $i$  mutual fund excess return for period  $t$ ,  $\mathbf{ETF}_t$  is a  $(P \times 1)$  vector of  $P$  selected ETF fund excess returns,  $i \in (1, \dots, N)$ , and  $t \in (1, \dots, T)$ . It is essential to point

---

<sup>9</sup> See Patton & Ramadorai (2013) and Criton & Scaillet (2014) for other empirical studies that apply the FDR estimator in the mutual fund industry.

out that both mutual and ETF fund returns are net-of-fees and expenses measuring individual investors' direct returns.

Based on the model (22), we assume that the actively managed mutual fund population is comprised of three distinct performance categories: unskilled funds ( $\alpha < 0$ ), zero-alpha funds ( $\alpha = 0$ ), and skilled funds ( $\alpha > 0$ ). Therefore, if mutual fund  $i$  is a skilled fund ( $\alpha_i > 0$ ), it yields an idiosyncratic positive excess return and outperforms those selected benchmarks.

For any given ETF selection, our main interest is to evaluate the true proportion of skilled mutual funds within our sample. By estimating (22) for  $i = (1, \dots, N)$ , as is already widely known in the literature, the direct inference of the proportion of skilled funds collecting p-values from  $H_i^0: \alpha_i = 0$  against  $H_i^1: \alpha_i \neq 0$  turns into an issue since it fails to control false positives (Type I error)<sup>10</sup>. These false positives became known as lucky and unlucky funds. To address this problem, we apply the FDR (False discovery rate) approach devised by Storey (2002), initially used in the mutual industry fund by Barras *et al.* (2010).

As Andrikogiannopoulou & Papakonstantinou (2019) stress, in order to achieve a meaningful FDR estimator of skilled proportion funds, we need to make sure that individual tests estimated with the model (22) do not yield low power. Therefore, we must choose a sparse set of ETFs to calculate (22) by OLS, including an adequate time series length. As we describe in the following subsections, we employ four different types of ETF selections to achieve a sparse set of predictors.

To compare results attained from our different ETF selections, we set the risk factor model below as our benchmark:

$$r_{i,t} = \alpha_i + \boldsymbol{\beta}_i \mathbf{f}_t + \varepsilon_{i,t} \quad (23)$$

where  $\mathbf{f}_t$  is a  $(P_f \times 1)$  risk factor vector.

### 3.3.1. FDR Approach to Estimate Skilled Proportion Funds

The FDR methodology is used to control false-positive results, estimating their proportion from the overall sample. It sets the proportion of false-positive results

---

<sup>10</sup> See Barras *et al.* (2010); Chen *et al.* (2017); Fama & French (2010); Kosowski, Timmermann, Wermers, & White (2006); and Pástor & Stambaugh (2002).

classified as skilled (unskilled) funds to  $F_\gamma^+$  ( $F_\gamma^-$ )<sup>11</sup>. By defining  $\pi_0$  as the proportion of zero-alpha funds for a given  $\gamma$  level of significance, the expected value of  $F_\gamma^+$  can be written as:

$$E(F_\gamma^+) = \pi_0 \frac{\gamma}{2} \quad (24)$$

After p-values from  $H_i^0: \alpha_i = 0$  against  $H_i^1: \alpha_i \neq 0$  for the model (22)<sup>12</sup> are computed, we proceed to measure the proportion of funds that yield a significant positive-alpha as follows:

$$\hat{S}_\gamma^+ = \frac{\sum_{i \in I_{\hat{\alpha}^+}} \mathbb{I}(\hat{p}_i > \frac{\gamma}{2})}{N} \quad (25)$$

where  $\mathbb{I}(\hat{p}_i > \frac{\gamma}{2})$  is an indicator function equal to 1 if  $\hat{p}_i > \frac{\gamma}{2}$  and zero otherwise; and  $I_{\hat{\alpha}^+} = \{i: \hat{\alpha}_i > 0\}$ . Therefore, the expected proportion of skilled funds in the population, corrected by the proportion of false-positive, can be estimated as:

$$E(\pi_+) = E(S_\gamma^+) - E(F_\gamma^+) \quad (26)$$

Hence, with an estimator of the proportion of zero-alpha funds ( $\hat{\pi}_0$ ), and a  $\gamma^*$  optimal significance level, we can calculate  $E(\pi_+)$  as follows:

$$\hat{\pi}_+ = \hat{S}_{\gamma^*}^+ - \hat{\pi}_0 \frac{\gamma^*}{2} \quad (27)$$

Since the sum of the proportion of unskilled, zero-alpha and skilled funds must be 1, we can calculate  $E(\pi_-)$  with:

$$\hat{\pi}_- = 1 - \hat{\pi}_0 - \hat{\pi}_+ \quad (28)$$

It is worth noting that the entire process from (24) to (28) can be adjusted by estimating  $\hat{\pi}_-$  by (27), and  $\hat{\pi}_+$  by (28). Therefore, one needs simply to reverse the variable subscriptions +/- . In fact, this decision depends on the number of the elements of sets  $I_{\hat{\alpha}^+}$

<sup>11</sup>  $F_\gamma^+$  ( $F_\gamma^-$ ) are known in the mutual fund industry literature as lucky (unlucky) funds.

<sup>12</sup> See appendix A.1. for a complete description of the p-value estimation procedure.

and  $I_{\hat{\alpha}^-}$ <sup>13</sup>. If  $I_{\hat{\alpha}^-}$  has more elements than  $I_{\hat{\alpha}^+}$ , we calculate  $\hat{\pi}_-$  using (27), and  $\hat{\pi}_+$  using (28), otherwise, we follow the exact same process given by models (24) to (28). In both cases, the optimal significance level ( $\gamma^*$ ) is determined by the bootstrap procedure detailed in appendix A.3. The  $\pi_0$  estimation procedure is described in the following section.

### 3.3.1.1. Calculation Procedure for $\pi_0$

By definition, and pursuant to null hypothesis  $H_i^0: \alpha_i = 0$ , the multiple test for  $H_i^0: \alpha_i = 0$  against  $H_i^1: \alpha_i \neq 0$  generates a series of p-values ( $\{p_i\}_{i=1}^I$ ) that results in a uniform distribution across the  $[0,1]$  interval<sup>14</sup>. In other words, if the null hypothesis is true, we can, therefore, state that:

$$H_{0,i}: \alpha_i = 0 \implies p_i \sim U(0,1) \quad (29)$$

In our second assumption, we presume that p-values larger than a threshold  $\lambda^*$  can only originate from zero-alpha funds. Hence, considering the p-value empirical distribution, the area given by  $\frac{\sum_{i=1}^I I(\hat{p}_i > \lambda^*)}{N}$  becomes the proportion of the uniform distribution of p-values from zero-alpha funds in the  $[\lambda^*, 1]$  interval<sup>15</sup>. In assuming that the area is equal to the  $[0,1]$  range, we can determine the proportion of the entire uniform distribution relating to the full p-value mass, thereby computing the  $\pi_0$  estimator as:

$$\hat{\pi}_0(\lambda^*) = \frac{\sum_{i=1}^I I(\hat{p}_i > \lambda^*)}{N \times (1 - \lambda^*)} \quad (30)$$

where the optimal threshold level ( $\lambda^*$ ) is determined by the bootstrap procedure described in appendix A.2.

### 3.3.1.2. Simulated Example

In this section we illustrate the calculation of  $\boldsymbol{\pi} = (\pi_-, \pi_0, \pi_+)$  using the FDR approach for a simulated dataset. We were able to generate 1,000 alpha ETFs from  $\alpha \sim N(-0.025, 0.01)$  (unskilled funds), 8,000 alphas from  $\alpha \sim N(0, 0.01)$  (zero-alpha

<sup>13</sup>  $I_{\hat{\alpha}^-} = \{i: \hat{\alpha}_i < 0\}$ .

<sup>14</sup> Hung, O'Neill, Bauer, & Kohne (1997), and Murdoch, Tsai, & Adcock (2008) submit a feature on the condition of the null hypothesis and p-value distribution.

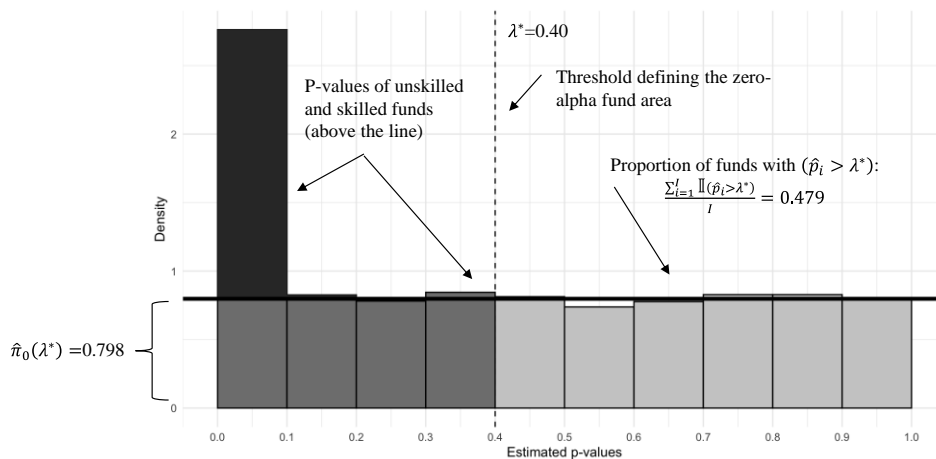
<sup>15</sup>  $I$  is an indicator function that is equal to 1 if  $\hat{p}_i > \lambda^*$  or, otherwise, to zero.

funds), and 1,000 alphas from  $\alpha \sim N(0.025, 0.01)$  (skilled funds). By construction, it is a known fact that the true parameters are  $\boldsymbol{\pi} = (0.10, 0.80, 0.10)$ .

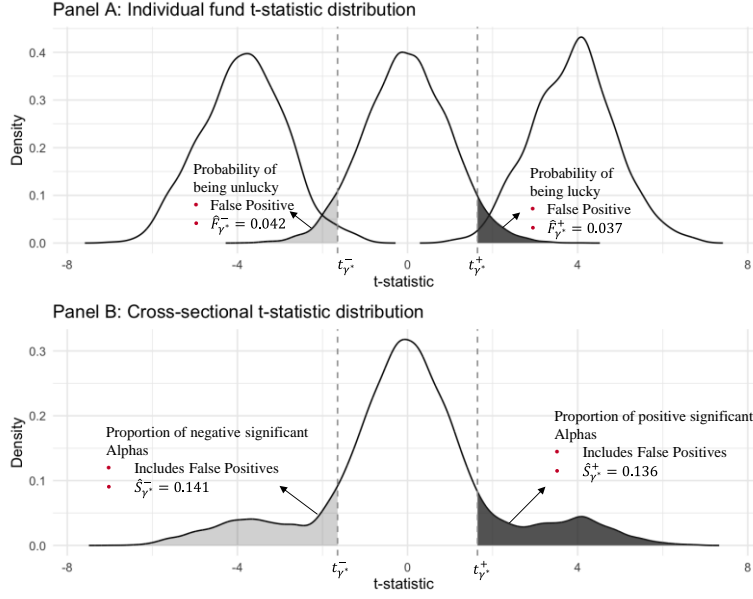
For each generated alpha, we test  $H_i^0: \alpha_i = 0$  against  $H_i^1: \alpha_i \neq 0$ , after which point we compute the estimated p-values ( $\hat{p}_i$ ), as described in the previous section. Figure 1 plots the histogram of  $\hat{p}_i$ , and we realize that the optimal  $\lambda^*$  for this synthetic data is 0.40. The light grey area is the proportion of funds by which  $\hat{p}_i > \lambda^*$ , and by assumption, we infer that it comes only from zero-alpha funds. Looking at equation (30), we can see that the dark grey area in Figure 1 depicts the deduction of the uniform distribution of zero-alpha funds for the  $[0, \lambda^*)$  interval, and since the light grey area is by assumption the uniform distribution area for  $[\lambda^*, 1]$ ,  $\hat{\pi}_0(\lambda^*)$  is the result of the sum of the light and dark grey areas. The black area in Figure 1 refers to proposition funds that are either unskilled or skilled.

Panel B of Figure 2 displays t-statistics-related empirical distribution. As one can see, if we fail to correct the proportion of positive significant alphas ( $\hat{S}_{\gamma^*}^+$ ) with the false positive ( $F_{\gamma^*}^+$  area in Panel A from Figure 2), we would attain a 13.6% proportion of skilled funds instead of a 9.62% proportion for our final calculation of  $\hat{\pi}_+$ . Table 1 summarizes our procedural results for the simulated dataset, and we can consider  $\hat{\boldsymbol{\pi}} = (0.106, 0.789, 0.962)$  to be close to the original parameters of  $\boldsymbol{\pi} = (0.10, 0.80, 0.10)$ .

**Figure 1: Estimated p-values from BY  $H_i^0: \alpha_i = 0$  for the simulated dataset**



*Note: The figure represents the p-value histogram of 10,000 simulated funds. We managed to generate 1,000 alphas from  $\alpha \sim N(-0.025, 0.01)$  (unskilled funds), 8,000 alphas from  $\alpha \sim N(0, 0.01)$  (zero-alpha funds), and 1,000 alphas from  $\alpha \sim N(0.025, 0.01)$  (skilled funds). Original parameters are  $\boldsymbol{\pi} = (0.10, 0.80, 0.10)$ .*

**Figure 2: T-statistics distribution from  $H_1^0: \alpha_t = 0$  for the simulated dataset**

Note: Panel A displays t-statistic distribution in funds across three skill groups (zero-alpha, unskilled, and skilled funds). True non-zero alphas are set to  $-2.5\%$ , and  $+2.5\%$  for unskilled and skilled funds. Panel B depicts the cross-sectional t-statistic distribution. It is a combination of the three distributions in Panel A, where the weight on each distribution depends on the proportion of zero-alpha, unskilled, and skilled funds, whose population values are  $\pi_- = 0.10, \pi_0 = 0.80, \pi_+ = 0.10$ .

**Table 1: FDR approach results for skilled proportion funds in the simulated dataset**

Value	$\pi_-$	$\pi_0$	$\pi_+$
<b>Simulated Example</b>			
Proportion	9.62%	79.77%	10.61%
Number	962	7,977	1,061
Std.	0.0036	0.0083	0.0073

Note: The table reports proportions of zero-alpha, skilled, and unskilled ( $\pi_0, \pi_+, \pi_-$ ) funds based on the risk factor model used for the simulated example set.  $\gamma^* = 0.40$  and  $\lambda^* = 0.10$  values are obtained with the selection algorithms proposed by (Barras et al., 2010).

### 3.3.2. Random ETF Selection

Here, we use a random ETF selection as our first methodology to define the set for the  $ETF_t$  vector for the model (22). Random selection is the most straightforward technique applied to establish sets of ETFs. Furthermore, it provides an average measure of the outperforming capacity of a random group of selected ETFs within mutual funds, but the procedure must be repeated several times. Since  $ETF_t$  is a  $(P \times 1)$  vector, we define a dimension threshold of  $P^* = 10$  so as  $P = 1, \dots, P^*$ . By establishing a low level for  $P^*$ , we are manually able to set a low dimension for  $ETF_t$ .

For each  $P$  dimension, this procedure starts by randomly selecting a  $b$  subsample ( $ETF_{(P),(b),t}$ ) from the original ETF dataset. With this subsample data, we fit the following model to  $i = 1, \dots, N$  mutual funds:

$$r_{i,t} = \alpha_i + \beta_i ETF_{(P),(b),t} + \varepsilon_{i,t} \quad (31)$$

After estimating the model (31), we can compute:  $R_{(P),(b),i}^2$ ,  $\hat{\alpha}_{(p),(b),i}$  both for  $i = 1, \dots, I$ , and  $\hat{\pi}_{(P),(b)}$ .

We repeat this procedure  $B = 500$  times so as  $b = 1, \dots, B$  in order to measure the following statistics:

$$R_{(P)}^2 = \frac{1}{BN} \sum_{b=1}^B \sum_{i=1}^N R_{(P),(b),i}^2 \quad (32)$$

$$\hat{\alpha}_{(P)} = \frac{1}{BI} \sum_{b=1}^B \sum_{i=1}^N \hat{\alpha}_{(p),(b),i} \quad (33)$$

$$\hat{\pi}_{(P)} = \frac{1}{B} \sum_{b=1}^B \hat{\pi}_{(P),(b)} \quad (34)$$

Hence, for a selected  $P$  of the  $ETF_t$  vector dimension, we calculate the average adjusted- $R^2$  (32), the average calculated alpha (33), and the average fund category proportion (34) across all subsamples and all mutual funds.

### 3.3.3. Proposed ETF Algorithm Selection (PS)

In this section we describe a proposed algorithm selection that chooses ETFs based on their ability to outperform mutual funds (high  $\hat{\pi}_+$ ), as well as their ability to explain fund return variability (high average adjusted- $R^2$ )<sup>16</sup>.

We define  $E$  as the overall number of ETFs available in our original dataset so that  $ETF_t = (ETF_{(1),t}, \dots, ETF_{(E),t})$ . We kick off the first step of our algorithm by calculating:

---

<sup>16</sup> The highest possible adjusted- $R^2$  is required to address the issues as pointed out by Andrikogiannopoulou & Papakonstantinou (2019).

$$r_{i,t} = \alpha_i + \beta_i ETF_{(e),t} + \varepsilon_{i,t} \quad (35)$$

where  $e = (1, \dots, E)$ .

For each  $ETF_{(e),t}$ , we compute the average adjusted- $R^2$  ( $R_{(e)}^2$ )<sup>17</sup> and the estimated skilled fund proportion ( $\hat{\pi}_{(e),+}$ ). Additionally, we select a set of ETFs featuring an  $R_{(e)}^2$  higher than a  $R^{2(*)}$  threshold<sup>18</sup> so that:

$$ETF_{1,t}^{R^2} = \{e: R_{(e)}^2 \geq R^{2(*)}\} \quad (36)$$

Next, based on the  $ETF_{1,t}^{R^2}$  set, we choose the ETF yielding the lowest  $\hat{\pi}_{(e),+}$  so that:

$$ETF_{(e_1),t} = \left\{ e: e = \underset{e \in ETF_{1,t}^{R^2}}{\operatorname{argmin}} \hat{\pi}_{(e),+} \right\} \quad (37)$$

where  $ETF_{(e_1),t}$  is the ETF selected in the first step.

In the second step, we measure:

$$r_{i,t} = \alpha_i + \beta_{i,e_1} ETF_{(e_1),t} + \beta_i ETF_{(e),t} + \varepsilon_{i,t} \quad (38)$$

where  $e = (1, \dots, E) \setminus \{e_1\}$ .

We then select a pair of ETF sets that produce a higher adjusted  $R^2$  than that of the previous sole  $ETF_{(e_1),t}$  so that:

$$ETF_{2,t}^{R^2} = \{e: R_{(e)}^2 \geq R_{(e_1)}^2\} \quad (39)$$

Next, we pick the second ETF using:

$$ETF_{(e_2),t} = \left\{ e: e = \underset{e \in ETF_{2,t}^{R^2}}{\operatorname{argmin}} \hat{\pi}_{(e),+} \wedge \hat{\pi}_{(e),+} < \hat{\pi}_{(e_1),+} \right\} \quad (40)$$

Model (37) enables us to conclude that, in order to be selected, the second ETF must also enhance its outperformance across mutual funds by attaining a lower estimated

---

<sup>17</sup>  $R_{(e)}^2 = \frac{\sum_{i=1}^I R_{(e),i}^2}{N}$  where,  $R_{(e),i}^2$  is the adjusted  $R^2$  from the fitted model  $r_{i,t} = \alpha_i + \beta_i ETF_{(e),t} + \varepsilon_{i,t}$ .

<sup>18</sup> We set  $R^{2(*)} = 0.85$  for our empirical research.

skilled fund proportion.

We proceed with the algorithm until  $\mathbf{ETF}_{s,t}^{R^2} = \emptyset$ , or  $\mathbf{ETF}_{(e_s),t} = \emptyset$ , where  $s$  is the number of steps. Therefore, the final selection can be expressed as  $\mathbf{ETF}_{A,t} = \bigcup_{s=1}^S \{\mathbf{ETF}_{(e_s),t}\}$ .

### 3.3.4. Lasso Selection regarding Risk Factors

Given the well-known fact that risk factors outperform industry mutual funds<sup>19</sup>, one can attain a more sophisticated ETF selection by looking into the risk factor space. Based on the Fama & French (2010) and Barras *et al.* (2010), we focus on the four-risk factor model proposed by Carhart (1997), setting our risk factor to  $\mathbf{f}_t = (f_{Mkt,t}, f_{SMB,t}, f_{HML,t}, f_{WML,t})$ . As highlighted in the Fama (1998), desirable properties from a multifactor risk model like (23) are neither an idiosyncratic risk ( $\alpha_i = 0$ ) nor a satisfactory explanatory power (significant betas and high adjusted- $R^2$ ). Consequently, for each  $f$  risk factor<sup>20</sup>, we look for ETFs that might spam the risk factor space, applying the following model:

$$f_{f,t} = \boldsymbol{\beta}_f \mathbf{ETF}_t + \varepsilon_{f,t} \quad (41)$$

Since original ETF datasets pose a great number of predictors, as well as the fact that we are interested in selecting a sparse number of predictors, we apply the Lasso estimator<sup>21</sup> to (20) with the loss function, as follows:

$$L(\boldsymbol{\beta}_f) = \frac{1}{2} \sum_{t=1}^T (f_{f,t} - \boldsymbol{\beta}_f \mathbf{ETF}_t)^2 + \lambda_f \|\boldsymbol{\beta}_f\|_1 \quad (42)$$

$$\widehat{\boldsymbol{\beta}}_{Lasso,f} = \operatorname{argmin}_{\boldsymbol{\beta}_f} L(\boldsymbol{\beta}_f) \quad (43)$$

ETFs selected with risk factor  $f$  are defined as  $\mathbf{ETF}_{Lasso,f,t} = \{\mathbf{ETF}_t: \widehat{\boldsymbol{\beta}}_{Lasso,f} \neq \mathbf{0}\}$ . Hence, the final set of ETFs selected by the Lasso procedure can be attained calculating:  $\mathbf{ETF}_{Lasso,t} = \bigcup_{f \in F} \{\mathbf{ETF}_{Lasso,f,t}\}$ .

<sup>19</sup> See Fama & French (2010) and Barras *et al.* (2010).

<sup>20</sup>  $f = (Mkt, SMB, HML, WML)$ .

<sup>21</sup> See Hastie, Tibshirani, & Friedman (2009) for an extensive description of Lasso estimator properties.

### 3.3.5. Forward Selection regarding Risk Factors

We also apply the forward fund selection algorithm as an alternative method to select ETFs in model (41). We define a grid of  $k = 1, \dots, K^{22}$  with  $K$  being the threshold for the  $\mathbf{ETF}_t$  vector dimension in equation (35). Therefore, the sparsity level in the forward fund selection algorithm is directly controlled by the value of  $K$ .

For each risk factor  $f$  we start the procedure by setting  $k = 1$ , and adjusting all possible models to (35). It is worth noting that since  $k = 1$ , in this first step the number of regressions is exactly the same as the number of elements in the original ETF dataset. We choose the ETF that yields the highest adjusted  $R^2$ . Then, we move on to the second step by setting  $k = 2$ , and adjusting all possible models to (35) with the ETF selected in the previous step defined as the first predictor, whereas all other remaining ETFs from the original dataset remain potential candidates for the second predictor. Again, we select the ETF set yielding the highest adjusted- $R^2$  and repeat those same steps until  $k = K$ , at which point we pick the final  $K$  ETF ( $\{\mathbf{ETF}_{F,f,t}\}$ ). As in the Lasso procedure, the final selection is a combination of every selection we make for each risk factor ( $\mathbf{ETF}_{F,t} = \bigcup_{f \in F} \{\mathbf{ETF}_{F,f,t}\}$ ).

### 3.4. Data

Fund data is collected from the CRSP Survivor-Bias-Free U.S. Mutual Fund Database<sup>23</sup> from January 1980 to December 2019 on a monthly basis. We pick only U.S. domestic equity market funds. To avoid incubation bias, we remove all funds' observations before said funds' AUM reaches 5.0 million 2000 dollars<sup>24</sup>. Once the funds are included in the dataset, we keep analyzing them until its AUM drops below 1.0 thousand 2000 dollars. Next, we remove funds that have less than 30 months of observable data. After all adjustments are made, our dataset displays an unbalanced panel with 13,922 funds from January 2005 to December 2019. Risk factor and risk-free rate historical returns were obtained from the French Library<sup>25</sup>.

Figure 3 depicts the number of analyzed funds in our final dataset universe per month. The figure clearly shows a positive trend in the number of funds over the years.

<sup>22</sup> We select two ETF sets with this methodology, one with  $K = 1$ , and other with  $K = 2$ .


<sup>23</sup> See CRSP (2012) for a complete description of this dataset.

<sup>24</sup> Following Berk & van Binsbergen (2015); Fama & French (2010); Harvey & Liu (2019); and Franzoni & Schmalz (2017).

<sup>25</sup> [https://mba.tuck.dartmouth.edu/pages/faculty/ken.french/data\\_library.html](https://mba.tuck.dartmouth.edu/pages/faculty/ken.french/data_library.html).

Consequently, most funds are observed in recent years and mainly within our time-sample from January 2005 to December 2019.


**Figure 3: Monthly number of funds from January 1980 to December 2019**



*Note: The figure shows the historical evolution of the 13,922 mutual funds selected from 1980 to 2019. Numbers were gathered from the CRSP U.S. domestic mutual fund database with the AUM ranging from 5.0 million to 1.0 thousand 2000 dollars, including over 30 months of observable data.*

Figure 4 displays the evolution in number of ETFs from 1994 to 2019. We can observe that there are more than 800 ETFs available in this period. Moreover, even though ETFs are a considerable market nowadays, they are also a recent financial innovation. Hence, there is a trade-off between the time series length and the number of ETFs available. Under this context, we begin our time-sample in January 2005, which leads to a balanced panel of 100 ETFs issued up to this date.

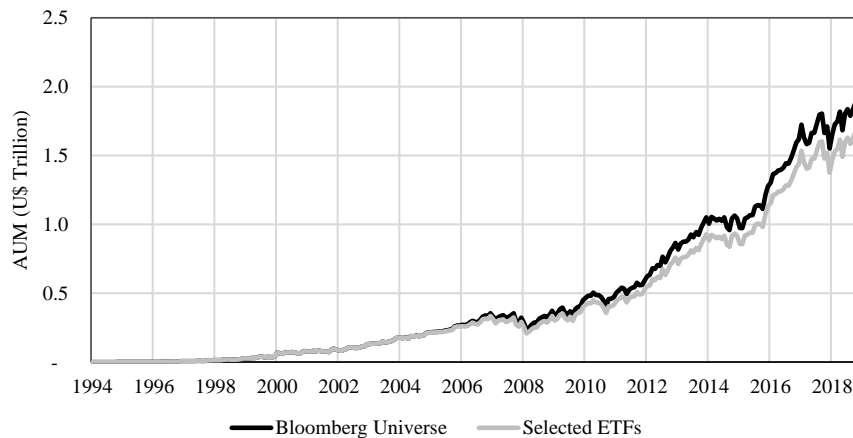
**Figure 4: Number of ETF funds in the Bloomberg dataset**



*Note: The figure displays the number of ETFs available in the Bloomberg database.*

In Figure 5 we compare the AUM of the Bloomberg ETF population to our selected sample. The selected ETFs represent more than 85% of the overall AUM database, amounting to over 2.0 trillion dollars of AUM. Here, we must point out that our ETF sample encompasses a significant share of the ETF market, as well as the fact that liquidity is not an issue for individual investors.

**Figure 5: ETF AUM from January 1994 to December 2019**



*Note: The figure displays the evolution of AUM (US\$ trillions) for the Bloomberg ETF sample and the selected ETF.*

Table 2 brings statistics for our final dataset universe, ranging from January 2005 to December 2019. Panel A and Panel B consolidate domestic equity mutual funds, as well as the selected ETF sample, respectively, and further detail average excess returns, Sharpe ratios, AUM (US\$ Bi), time series lengths, and the number of funds/ETFs. Panel C, in turn, submits average risk factor returns and Sharpe ratios.

**Table 2: Final dataset statistics**

<b>Panel A: Mutual Funds</b>							
<b>Description</b>	<b>Mean</b>	<b>Std.</b>	<b>Min</b>	<b>p05</b>	<b>Median</b>	<b>p95</b>	<b>Max</b>
Av. Excess Return (% p.m.)	0.51%	1.30%	-3.90%	-0.39%	0.56%	1.13%	139.84%
S.R. ( <i>ex-post</i> )	0.13	0.12	-1.34	-0.08	0.13	0.30	0.69
Av. AUM (US Bi)	0.37	1.54	0.00	0.01	0.06	1.35	47.37
Time Series Length	126	80	30	34	105	292	180
# Total Number of Funds	13,922						
<b>Panel B: Selected ETFs</b>							
<b>Description</b>	<b>Mean</b>	<b>Std.</b>	<b>Min</b>	<b>p05</b>	<b>Median</b>	<b>p95</b>	<b>Max</b>
Av. Excess Return (% p.m.)	0.56%	0.19%	0.13%	0.26%	0.55%	0.94%	0.98%
S.R. ( <i>ex-post</i> )	0.12	0.04	0.03	0.04	0.13	0.18	0.19
Av. AUM (US Bi)	6.80	15.77	0.10	0.23	2.51	20.72	137.89
# Total Number of Funds	100						
<b>Panel C: Risk Factors</b>							
<b>Description</b>	<b>Av. Excess Return (% p.m.)</b>			<b>S.R. (<i>ex-post</i>)</b>			
Mkt	0.72%			0.17			
SMB	0.02%			0.01			
HML	-0.12%			-0.05			
WML	0.10%			0.02			

*Note: The table displays Statistics for the final dataset. Panel A refers to the mutual fund sample, Panel B to the selected ETF, and Panel C to risk factors. The table includes average excess returns, Sharpe ratios, time series length, as well as the number of funds and ETFs.*

As we can see, both mutual funds and ETFs, as well as excess returns and Sharpe ratio averages are positive, although lower than numbers reported for the market risk factor (Panel C). As Cochrane (2009) points out, the fact that the market risk factor yields higher Sharpe ratios than average fund Sharpe ratios may suggest that said risk factors may be able to span most funds' excess returns, whereas only a small number of funds would be able to generate alpha. In fact, this result is confirmed by Barras *et al.* (2010) for the period ranging from 1975 to 2006. In Panel B of Table 2, we notice that average ETF Sharpe numbers are closer to average fund Sharpe ratios, thereby implying that funds, on most cases, are not alpha when benchmarked by ETFs. On average, each fund is examined monthly over a 10-year-term, resulting in an appropriate time-series length.

### 3.5. Results

#### 3.5.1. Benchmark potential of ETFs

In this section we show the potential ETFs have to explain fund return distributions. We start by applying the risk factor model to evaluate results, used herein as our performance guideline. To do so, we look at the proportion of skills across three subsamples: the first one encompasses the entire period ranging from 1980 to 2019; the second brings observations from 1980 to 2004, a timeframe similar to the one examined in the Barras *et al.* (2010) paper; finally, the third and main period used herein covers the years from 2005 to 2019.

Proportions of unskilled, zero-alpha and skilled funds are shown in Table 3, in accordance with the sub-sample that was analyzed.

**Table 3: Proportions of zero-alpha, unskilled, and skilled funds**

Value	$\pi_-$	$\pi_0$	$\pi_+$
<b>Panel A: Period 01/1980 to 12/2019</b>			
Proportion	37.86%	60.95%	1.19%
Number	5,271	8,485	163
Std.	0.0052	0.0109	0.0083
<b>Panel B: Period 01/1980 to 12/2004</b>			
Proportion	26.29%	73.17%	0.54%
Number	1,494	4,158	30
Std.	0.0077	0.0138	0.0099
<b>Panel C: Period 01/2005 to 12/2019</b>			
Proportion	41.27%	57.56%	1.17%
Number	4,829	6,732	137
Std.	0.0056	0.0116	0.0088

*Note: The table displays proportions of zero-alpha, skilled, and unskilled ( $\pi_0, \pi_+, \pi_-$ ) funds based on the risk factor model for three different time samples. Panel A shows estimated proportions for the entire fund population (13,922 funds) from 1980 to 2019. Panel B submits estimated proportions from the entire sample from 1980 to 2004 (5,682 funds). Panel C exhibits estimated proportions in the sample from 2005 to 2019 (11,700 funds).  $\gamma^*$  and  $\lambda^*$  values are obtained using the selection algorithms devised by (Barras et al., 2010).*

The table replicates specific patterns documented by academic literature, these being: predominance of unskilled and zero-alpha funds, whose joint proportions exceed 98% in all subsamples; and an increase in the volume of unskilled funds over time with the proportion rising from 26.29% in the 1980/2004 period to 41.27% in the 2005/2019 period. Barras *et al.* (2010) also report both results.


Nevertheless, these conclusions are reached by comparing fund returns with traditional risk factors, these being theoretical portfolios that pose several caveats in regards to their practical elaboration (Frazzini *et al.*, 2012; Novy-Marx & Velikov, 2016).

Under this context, we consider the sensitivity of these results whenever funds are exposed to ETF portfolios instead of traditional risk factors. Using the method detailed in section 3.3.2, we proceed to randomly pick ETF combinations and assess combinations with 1 to 10 ETFs. First, we define the number of ETFs that we will use as benchmarks, after which point we choose 500 random combinations, whose average alpha and average adjusted-R<sup>2</sup> distributions are evaluated.

The results are summarized in Figure 6. The upper panel represents the average alpha according to the number of ETFs used across the 500 random combinations tested, as well as their 95% confidence interval. The lower panel, in turn, shows the adjusted-R<sup>2</sup>, according to the number of ETFs considered. Each point in the figure illustrates an

average number of 500 random combinations, whose individual values are calculated from a distribution of 11,700 funds, as detailed in section 3.3.2. The red dotted lines refer to average alpha risk factors of -0.13% and the average adjusted-R<sup>2</sup> of 87.7%.

**Figure 6: Random ETF Selection Potential vs Risk Factors**




*Note: The figure shows the average alpha ( $\alpha$ ) and the adjusted-R<sup>2</sup> estimated using the risk factor model based on Random ETF selection, conditional to the number of ETFs selected. The red dotted line represents risk factor estimates, whereas the solid black line denotes estimates based on Random ETF selection: avg. alpha of -0.13% and avg. adjusted-R<sup>2</sup> of 87.7%.*

Figure 6 enables us to note that the average alpha stabilizes when we take into consideration combinations of around 4 ETFs. Furthermore, the value stabilizes at levels of 0.02%, showing that it is approximately 0.15% higher than the average alpha calculated with risk factors. This substantial difference is close to the estimated transaction cost of 0.18% used to devise risk factors, according to Frazzini *et al.* (2012).

Regards to the adjusted-R<sup>2</sup>, the results are also noteworthy since whenever we evaluate combinations of 4 or more ETFs, this measure is also close to the one we obtain with risk factors. When we examine combinations with 8 ETFs, the adjusted-R<sup>2</sup> reaches average numbers akin to those obtained with risk factors (87.7%), whereas from 4 ETFs onwards the average already exceeds 85%.

Thereafter, we proceed to analyze Figure 7, where we show average proportions of unskilled, zero-alpha and skilled funds, according to the number of ETFs evaluated in random combinations. The solid black line refers to average proportions among random combinations concerning different numbers of ETFs that we analyzed. The gray area delimits intervals from the 2.5th to the 97.5th percentiles of random combinations used. The red dotted line denotes proportions estimated with risk factors, as seen in Panel C of Table 3: 41.27%, 57.56%, and 1.17% for unskilled, zero-alpha and skilled funds, respectively.

**Figure 7: Expected skill proportion based on Random ETF Selection**



*Note: The figure shows average proportions of unskilled, zero-alpha, and skilled funds, according to the number of ETFs tested in the random selection. The solid black line refers to average values of each proportion among random combinations tested pursuant to the number of ETFs analyzed. The gray area delimits intervals from the 2.5th to the 97.5th percentiles. The red dotted line indicates skill proportions estimated using risk factors.*

Starting with the proportion of unskilled funds, the figure backs our results previously shown in Figure 6. The proportion of unskilled funds does not correspond to the number obtained with risk factors when we use ETFs. Benchmarking fund returns with ETF combinations entail unskilled fund proportions with stable averages of around 10%, regardless of the number of ETFs used. When we consider risk factors, however, this proportion reaches 41.27%. This behavior can also be explained by the absence of transaction costs in risk factor returns. Without transaction costs, risk factor averages are potentially higher, thus, the use of such variables as benchmarks signal potentially lower alphas, in addition to a higher unskilled proportion. Such a pattern is consistent with the conclusion found in Figure 6, in which we point out that the average alpha is higher when we use ETFs as a reference as opposed to when we use risk factors.

In contrast, although proportions of unskilled funds are stable, proportions of zero-alpha and skilled funds seem to be sensitive to the number of ETFs analyzed, behaving in a total opposite way. As we look at more and more ETF combinations, proportions of calculated zero-alphas go up, while proportions of estimated skilled funds go down. In truth, we expect the opposite to happen, since all three proportions add up to 100%, and the unskilled fund proportion remains stable. Nevertheless, when we examine intervals from the 2.5th to the 97.5th percentiles, we note that ETF combinations yielding results akin to those obtained with risk factors exist since the gray area intersects with the red dotted line which represents the risk factors. Additionally, in regards to average proportions, it becomes clear that the best results, in order to explain fund performance, are obtained using combinations that range from 3 to 5 ETFs due to the fact that zero-alpha proportions reach their peak in this interval, whereas proportions of skilled funds sink to their lowest point.

Another pattern, shown in Figure 7, refers to the positive trend concerning proportions of skilled funds, which may help to tell us that, as we proceed to test combinations with increasing numbers of ETFs, the proportion of skilled funds will also rise. At first, the pattern may seem unusual, however, one must keep in mind that ETFs are selected randomly, consequently, insofar as we start to consider combinations with greater numbers of ETFs, the number of possibilities expands rapidly, thereby making it difficult to evaluate the same combinations again only with the increase of specific ETFs<sup>26</sup>.

Our assessment in this section enables us to conclude that ETFs demonstrate a capacity to generate results that come close to those obtained when we compare fund returns to risk factors, although they show inconsistencies concerning the proportion of estimated unskilled funds, which, again, are potentially explained by differences in transaction costs. On the other hand, when we choose to single out proportions of skilled funds for evaluation, we observe that combinations around 4 ETFs are best suited to generate close results to the ones attained using risk factors.

In summary, we conclude that: (i) ETFs can be used as benchmarks to assess fund performance; (ii) we should only compare skilled fund proportions since transaction costs

---

<sup>26</sup> For instance, when combinations of 4 out of 100 ETF options are drawn, the total number of options is 3,921,225 ( $= 100! / ([4! (100-4)!])$ ). However, when we look at combinations of 6 ETFs, the number of options is 186,087,894,300 ( $= 100! / ([6! (100-6)!])$ ).

suggest differences between proportions of unskilled funds obtained with risk factors and ETFs; (iii) finally, the optimal ETF combination should not stray far from the range of 3 to 5 ETFs.

### **3.5.2. ETF Selection**

Given the results of section 3.5.1, the following are the dedicated methodologies we employ to identify optimal ETF combinations. Unlike the previous section, this one does not intend to evaluate random ETF combinations, but rather combinations chosen through specific procedures.

These procedures are divided into two approaches. The first one is detailed in section 3.5.2.1 and selects a set of ETFs aimed at replicating the best possible results concerning proportions of skilled, adjusted-R<sup>2</sup> and alpha funds. The second approach, in turn, is described in subsection 3.5.2.2 and uses a procedure to identify a set of ETFs that replicates risk factor dimensions. Both approaches have the same purpose: to select the best benchmarking set for the fund sample. However, the first one addresses this through fund return dimensions, whereas the second takes on an approach based on the perspective of risk factors.

#### **3.5.2.1. ETF selection based on fund performance**

In this section we disclose the results obtained selecting ETFs after we examined fund return dimensions. The approach aims to identify ETF combinations capable of explaining fund return variability (high adjusted-R<sup>2</sup>); to generate a low proportion of skilled funds (low  $\pi_+$ ), and to recommend low average values for risk-adjusted excess returns (low  $\alpha$ ).

As described in section 3.3.3, the procedure used consists of selecting ETFs sequentially so that an ETF is picked in each iteration, thereby generating the lowest possible proportion of skilled funds with an average adjusted-R<sup>2</sup> greater than 85%, as well as higher than the adjusted-R<sup>2</sup> obtained with the last selected ETF. Therefore, the first ETF is selected in order to minimize both the proportion and the skilled funds, though conditioned to an average adjusted-R<sup>2</sup> equal to or greater than 85%. We then continue to add further ETFs, always minimizing the proportion of skilled funds, and only considering options that generate an average adjusted-R<sup>2</sup> greater than or equal to the one obtained in the previous iteration. The procedure concludes when we establish that additional ETFs are not capable of reducing the estimated proportion of skilled funds.

A minimum adjusted- $R^2$  average is required to help avoid regressions that show weak adherence to data, as well as to reduce potential calculations of p-values with volatile distribution for both skilled and unskilled funds. As Andrikogiannopoulou & Papakonstantinou (2019) point out, excessively volatile calculated p-values can lead to significantly high values, even for non-zero-alpha funds. In this case, we see an overestimation of the proportion of zero-alphas, which, in turn, leads to an underestimation of proportions of non-zero alpha funds.

After applying the aforementioned procedure, we proceed to select five ETFs: VV.U; IJT; SLYV; XLY; and XLV. Results concerning performance metrics distribution used in this proposed selection (combining the four benchmarking ETFs), in addition to the estimated proportions of unskilled, zero-alpha and skilled funds, are found in Table 4. With the aim of helping to compare outcomes obtained, and taking into account risk factors and randomly selected ETFs, we also include them in the table. Panel A shows performance distribution metrics, whereas Panel B displays skill proportions.

The results exceed those attained simply by randomly selecting ETFs, considering every metric analyzed. Moreover, they are close to values obtained with risk factors, except for the average alpha, which in spite of being negative, is still approximately 0.11% higher than the estimated risk factors.

Finally, as one can see, the estimated proportion of skilled funds accounts for only 5.73%. Therefore, based on the selected ETF combination, we estimate that 94.27% of both population and funds fail to demonstrate adequate management skills required to generate positive risk-adjusted returns. The result underscores evidence that has already been shown in a wide host of papers, nevertheless, when considering all transaction costs, it is still attained herein. Similar results can be achieved by analyzing funds' gross returns, i.e., before expenses. However, as studies have also shown, there are far too many distortions in the available expense ratio data (Berk & van Binsbergen, 2015, 2017).

Still, it is worth pointing out that despite some impressive results, they might be impacted by overfitting fund data samples that we analyzed. This stems from the fact that several variables are evaluated to choose the best set of ETFs. Consequently, we also examine out-of-sample results in the following section.

**Table 4: ETF selection results based on fund performance distribution**

<b>Panel A: Performance measures</b>							
<b>Benchmark</b>	<b>Mean</b>	<b>Std.</b>	<b>Min</b>	<b>p05</b>	<b>Median</b>	<b>p95</b>	<b>Max</b>
	$\alpha$						
<i>Risk factors</i>	-0.12%	0.92%	-0.93%	-0.46%	-0.13%	0.13%	0.42%
<i>Random selection</i>	0.03%	1.84%	-0.82%	-0.32%	0.03%	0.26%	0.48%
<i>Proposed Selection (PS)</i>	-0.01%	0.67%	-0.87%	-0.35%	0.00%	0.24%	0.56%
	$adjusted - R^2$						
<i>Risk factors</i>	87.72%	16.58%	3.20%	51.94%	92.91%	97.78%	99.08%
<i>Random selection</i>	86.43%	15.65%	4.14%	55.13%	91.29%	95.75%	97.24%
<i>Proposed Selection (PS)</i>	86.15%	16.97%	-1.13%	51.16%	91.41%	97.16%	98.63%
<b>Panel B: Skill distribution</b>							
	$\pi_-$		$\pi_0$			$\pi_+$	
<i>Risk factors</i>	41.28%		57.54%			1.18%	
<i>Random selection</i>	9.67%		71.31%			19.02%	
<i>Proposed Selection (PS)</i>	5.63%		88.64%			5.73%	

*Note: Panel A of the table displays the distribution of alpha and adjusted-R<sup>2</sup> in the funds that we analyzed, in accordance with the evaluated benchmark: Risk factors, Random Selection or Proposed Selection (PS). In regards to random selection, average estimated parameters for each fund are shown, taking into account models with 1 to 15 ETFs. Panel B reports proportions of unskilled, zero-alpha, and skilled funds.*

### 3.5.2.1.1. Cross-validation

This section employs the same ETF selection procedure as the one described in section 3.5.1, however, here we proceed to compare both the in-sample and out-of-sample performance. To achieve this, fund populations were randomly divided into two groups: the training-set and the testing-set. The training-set sample, which covers 70% of the fund sample, is used to select ETFs. The testing-set sample, in turn, contains the remaining 30% funds, and its sole purpose is to ensure an overfitting-free performance. To better assess the method performance, we execute repeated cross-validation, wherein we carry out the described procedure 100 times, in addition to evaluating distributions of average alpha, average adjusted-R<sup>2</sup> and the estimated  $\pi_+$ .

The results are in Table 5, where we disclose parameter distributions for all 100 cross-validation samples. Furthermore, as a reference parameter, we report the results we obtained with the proposed algorithm selection (PS) for every sample shown in the previous section. It is essential to point out that full sample results are estimated only once, thus, there is only one value for the average  $\alpha$ , the average adjusted-R<sup>2</sup>, and  $\pi_+$ .

**Table 5: Cross-validation for ETF selection based on fund performance**


Sample	Full sample	Training	Testing
<b>Average <math>\alpha</math></b>			
Mean	-0.01%	0.02%	0.02%
Std.	-	0.03%	0.04%
Min	-	-0.04%	-0.04%
p05	-	-0.02%	-0.03%
Median	-	0.02%	0.01%
p95	-	0.07%	0.11%
Max	-	0.09%	0.15%
<b>Average adjusted-R<sup>2</sup></b>			
Mean	87.72%	86.07%	86.03%
Std.	-	0.25%	0.41%
Min	-	85.45%	85.08%
p05	-	85.59%	85.30%
Median	-	86.08%	86.04%
p95	-	86.47%	86.76%
Max	-	86.71%	87.09%
<b><math>\pi_+</math></b>			
Mean	5.73%	6.07%	7.38%
Std.	-	1.00%	2.02%
Min	-	4.34%	3.44%
p05	-	4.65%	4.65%
Median	-	5.95%	7.47%
p95	-	7.58%	10.92%
Max	-	8.52%	12.39%

*Note: Panel A of the table displays the distribution of the average alpha and the average adjusted-R<sup>2</sup> throughout the cross-validation samples for the proposed algorithm selection (PS), in accordance with the evaluated sample. We only disclose the mean for the Full sample since the only number available is the estimated result from Table 4 section 3.5.2.1. For Training-sets and Testing-sets, numbers shown relate to average  $\alpha$  and average adjusted-R<sup>2</sup> parameters estimated throughout all 100 cross-validation samples.*

As we can see, results obtained with training-sets and testing-sets are close, as well as results reported for the entire fund sample disclosed in the previous section. The alphas' training and testing distributions are very similar to each other, and both present estimated averages around 0.02% close to the full sample result of -0.01%. Besides that, the training and testing samples have adjusted-R<sup>2</sup> averages around 86%, which is close to the 88% full sample estimated value. The standard deviations for the alphas and adjusted-R<sup>2</sup> are low for the training and testing samples. Proportions of skilled funds have higher variabilities, with average values slightly above those calculated in the full sample. The training sample has an estimated proportion of 6.07%, while the testing sample records 7.38%. Nevertheless, both numbers are close to the full sample result of 5.73%.

Figure 8 allows us to compare the distribution of estimated metrics for both training-sets and testing-sets across all simulations performed. Again, it is possible to verify that distribution percentages are close, signaling that the procedure has a low overfitting risk, which helps to underscore the results we have already disclosed.


**Figure 8: Measure distributions among training-sets and testing-sets**



*Note: The figure displays alpha distributions ( $\alpha$ ), the proportion of skilled funds ( $\pi_+$ ), and the adjusted- $R^2$  obtained with the cross-validation procedure. Histograms in dark gray and solid lines denote the distribution of estimated parameters in the training sample, while histograms in light gray and the dotted line represent distributions in the testing sample.*

It is also worth evaluating the sensitivity of the results in regards to the number of ETFs selected. When we look at the entire fund sample, we select five ETFs reinforcing the quantity indicated in the random ETF selection analysis described in section 3.5.1. Likewise, Figure 9, which illustrates how the selected ETFs are distributed, shows that nearly 86% of cases are performed with a number of ETFs ranging from 3 to 5. Again, close to the pattern observed with the entire data sample.

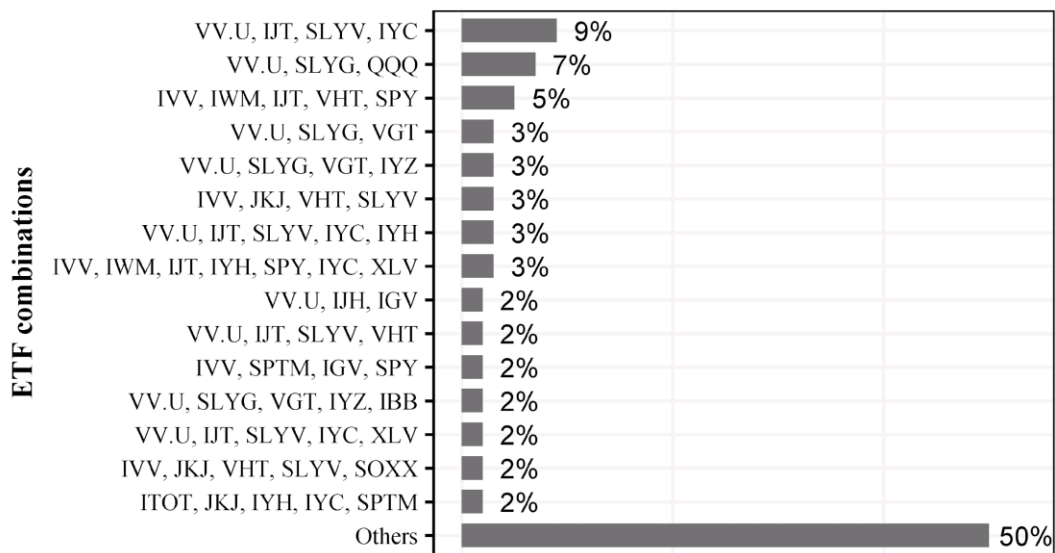
**Figure 9: Cross-validation distribution for the number of selected ETFs**



*Note: The figure displays the distribution of the number of ETFs selected with the cross-validation procedure. The vertical axis refers to the number of ETFs selected, while the horizontal axis represents their frequency.*

Finally, Figure 10 shows how the selected ETF combinations are distributed. Combinations are arranged from lowest to highest in terms of frequency. Furthermore, combinations picked only once are grouped in the “Other” category.

**Figure 10: ETF combination frequency in cross-validation**



*Note: The table shows the frequency by which each ETF combination was selected using the cross-validation procedure. The vertical axis depicts ETF combinations, whereas the horizontal axis illustrates the frequency in which they occur. Combinations that occur only once are grouped in the "Other" category.*

As we can see, the set of selected ETFs does not exhibit a pattern. In other words, the procedure does not seem to suggest that any optimal ETF combination exists, although there are several possibilities. This becomes clear when we take into account the fact that most combinations are selected once, at most, and that the most common combination takes place in approximately only 9% of the cases.

### 3.5.2.2. ETF selection based on risk factors

In this section, we employ specific procedures intending to select a set of ETFs capable of mimicking risk factor returns. In doing so, our goal is to attempt to find a set of ETFs that can replicate results when fund returns are exposed to risk factors.

The first tested procedure is based on the Lasso methodology and considers the set of ETFs as potential explanatory variables for risk factors. Thus, we apply a Lasso methodology for each risk factor to pinpoint sets of ETFs capable of explaining risk factor variability. The methodology’s hyperparameters are set following the five-fold cross-validation method. ETFs selected for each risk factor are found in Table 6. The lower row

of the table reports the adjusted-R<sup>2</sup> obtained after regressing risk factors by the selected ETFs.

**Table 6: Selected ETFs by Lasso**

ETF	Description	Selected			
		Mkt	SMB	HML	WML
XLF	Blend Funds	x		x	x
IYM	Blend Materials	x			
IYG	Blend Funds			x	
IWO	Small-Cap Growth	x	x		
XNTK	Growth Technology	x			
SOXX	Blend Technology	x			
<b>adjusted -R<sup>2</sup></b>		95.5%	74.5%	53.4%	33.9%

*Note: The table lists ETFs selected using the Lasso method. Each row refers to a selected ETF. The first column represents the name of the ETF. The second row brings a brief description of the asset investment guideline. The other columns show which risk factor is linked to each ETF. Finally, the last row reports the adjusted-R<sup>2</sup> attained from the regression between the selected ETFs and each risk factor.*

As we can see, the procedure selects five ETFs to explain the Mkt risk factor variability, however, two of them were also selected through HML, WML and SMB. The HML factor requires two ETFs to be chosen. Finally, SMB and WML call for the selection of one additional ETF, each. In all, there are six ETFs selected, whereas in regards to the adjusted-R<sup>2</sup>, they range from 95.5% to 33.9%.

The second selection procedure is based on the forward selection methodology. More specifically, said procedure consists of selecting a set of ETFs for each risk factor to obtain the highest possible adjusted-R<sup>2</sup>. This approach picks one ETF for each risk factor in each iteration. Unless the same ETF is selected to explain different risk factors, the procedure selects a set with four ETFs in each new iteration.

Only results obtained with, at most, 2 ETFs for each risk factor were evaluated. Selected ETFs are shown in Table 7, where Forward 1 and Forward 2 submit, respectively, results obtained when one to two ETFs are selected for each risk factor.

Results show that ETFs selected for each risk factor do not intersect, thus, we picked an overall number of four ETFs in the first iteration (Forward 1), plus an additional four in the second iteration (Forward 2). The adjusted-R<sup>2</sup> ranges from 99.6% to 33.2% when we use one ETF, and from 99.6% to 45.5% when we select two ETFs.

Final results obtained using the procedure described are found in Table 8, in addition to results attained with risk factors and random ETF selection. The table is split into two panels. Panel A shows the distribution of alpha and adjusted-R<sup>2</sup> for each set of

benchmarks. Panel B, in turn, reports proportions of unskilled, zero-alpha, and skilled funds.

**Table 7: Selected ETFs by Forward Selection**

ETF	Benchmark	Selected			
		Mkt	SMB	HML	WML
<b>Panel A: Forward 1</b>					
XLF	Blend Funds				x
IWM	Small-Cap Blend		x		
SPTM	Broad Market Blend	x			
PEY	Large-Cap Blend			x	
<b>adjusted -R<sup>2</sup></b>		<b>99.6%</b>	<b>94.5%</b>	<b>57.4%</b>	<b>33.2%</b>
<b>Panel B: Forward 2</b>					
XLF	Blend Funds				x
IWM	Small-Cap Blend		x		
SPTM	Broad Market Blend	x			
PEY	Large-Cap Blend			x	
SPTM	Broad Market Blend	x			
FVL	Broad Market Blend				x
JKE	Large-Cap Growth			x	
PEY	Large-Cap Blend			x	
SPTM	Broad Market Blend	x			
<b>adjusted -R<sup>2</sup></b>		<b>99.6%</b>	<b>94.7%</b>	<b>80.6%</b>	<b>45.5%</b>

*Note: The table lists ETFs selected with the Forward Selection method. Each row refers to a selected ETF. The first column represents the name of the ETF. The second row brings a brief description of the asset investment guideline. The other columns report which risk factor is linked to each ETF. The last row shows the adjusted-R<sup>2</sup> from the regression attained between the selected ETFs and each risk factor. Panel A displays the selected ETFs with one method iteration, while Panel B depicts ETFs selected using two iterations.*

When we begin looking at Lasso selection results, it is noticeable that this procedure entails the worst results, these being even lower than those we achieved with the random ETF selection. Applying it generates an average alpha of 0.13%, an average adjusted-R<sup>2</sup> of 84.98%, and a proportion of skilled funds corresponding to 39.37%. On the other hand, both Forward 1 and 2 selection methods deliver better results than those attained using the random ETF selection. In regards to the calculated average alpha for these funds, it is worth pointing out that the average of both approaches comes close to zero (0.02% and 0.01%). We also see satisfactory results for the adjusted-R<sup>2</sup>, which are even closer to the outcome we obtained with the risk factors. Finally, when it comes to the estimated proportion of skilled funds, said ratio varies close to 11%.

The procedures applied suggest that it is increasingly possible to select ETFs that are able to explain returns posted by actively managed investment funds. However, although these results exceed those obtained with random ETF selection, the estimated proportion of skilled funds remains substantially higher than the proportion estimated using risk factors. It is also worth noting that said procedures are not impacted by potential

data snooping since we select ETFs here by analyzing risk factor dimensions, instead of directly from the funds.

**Table 8: Selection results based on risk factors**

<b>Panel A: Performance measures</b>							
<b>Benchmark</b>	<b>Mean</b>	<b>Std.</b>	<b>Min</b>	<b>p05</b>	<b>Median</b>	<b>p95</b>	<b>Max</b>
$\alpha$							
<i>Risk factors</i>	-0.12%	0.92%	-0.93%	-0.46%	-0.13%	0.13%	0.42%
<i>Random selection</i>	0.03%	1.84%	-0.82%	-0.32%	0.03%	0.26%	0.48%
<i>Lasso</i>	0.13%	0.90%	-0.81%	-0.29%	0.14%	0.44%	0.71%
<i>Forward 1</i>	0.02%	1.35%	-0.83%	-0.35%	0.02%	0.29%	0.58%
<i>Forward 2</i>	0.01%	1.93%	-0.88%	-0.36%	0.01%	0.27%	0.57%
$R^2$							
<i>Risk factors</i>	87.72%	16.58%	3.20%	51.94%	92.91%	97.78%	99.08%
<i>Random selection</i>	86.43%	15.65%	4.14%	55.13%	91.29%	95.75%	97.24%
<i>Lasso</i>	84.98%	16.02%	0.31%	52.88%	89.94%	95.63%	97.70%
<i>Forward 1</i>	87.38%	16.61%	1.37%	53.46%	92.56%	97.53%	98.80%
<i>Forward 2</i>	88.79%	16.16%	2.37%	56.35%	93.88%	98.00%	99.08%
<b>Panel B: Skill distribution</b>							
	$\pi_-$		$\pi_0$		$\pi_+$		
<i>Risk factors</i>	41.28%		57.54%		1.18%		
<i>Random selection</i>	9.67%		71.31%		19.02%		
<i>Lasso</i>	4.59%		56.04%		39.37%		
<i>Forward 1</i>	4.36%		84.39%		11.25%		
<i>Forward 2</i>	8.48%		79.89%		11.63%		

*Note: Panel A of the table displays the distribution of alpha and adjusted-R<sup>2</sup> in the funds we analyzed, in accordance with the evaluated benchmark. In regards to random selection, we report the average parameter estimated for each fund, considering models with 1 to 15 ETFs. Panel B, in turn, shows proportions of unskilled, zero-alpha, and skilled funds.*

### 3.5.2.3. Growth impact on the number of ETFs

As illustrated in section 3.4, recent years have seen a substantial increase in the volume of ETFs available for investors. Previous sections of this paper examined data from 2005 with 100 ETFs. Nevertheless, when we analyze the database starting from 2009, we can evaluate 299 ETFs in all. That being said, this section describes our results after analyzing this period that features a greater number of ETFs.

More specifically, we examine all prior results in this section, i.e., risk factors, random selection, selection based on fund returns, and selection based on risk factor returns. Nevertheless, we do so by looking at the 2009 to 2019 period, which includes a pool of 299 ETFs.

The results obtained are shown in Table 9. Panel A displays parameters of the calculated alpha distribution for each benchmark set, whereas Panel B illustrates the adjusted-R<sup>2</sup> distribution. Finally, Panel C brings each fund's skill ratios, also in accordance with the analyzed benchmark set.

**Table 9: Results obtained with larger ETF samples**

<b>Panel A: Performance measures</b>							
<b>Benchmark</b>	<b>Mean</b>	<b>Std.</b>	<b>Min</b>	<b>p05</b>	<b>Median</b>	<b>p95</b>	<b>Max</b>
$\alpha$							
<i>Risk factors</i>	-0.15%	0.21%	-0.97%	-0.48%	-0.13%	0.12%	0.38%
<i>Random selection</i>	0.03%	0.20%	-0.73%	-0.29%	0.04%	0.29%	0.52%
<i>Lasso</i>	-0.07%	0.23%	-0.95%	-0.42%	-0.07%	0.25%	0.61%
<i>Forward 1</i>	0.01%	0.21%	-0.89%	-0.32%	0.02%	0.29%	0.55%
<i>Forward 2</i>	0.02%	0.22%	-0.79%	-0.29%	0.04%	0.32%	0.61%
<i>PS</i>	-0.01%	0.20%	-0.79%	-0.32%	0.00%	0.27%	0.58%
$R^2$							
<i>Risk factors</i>	87.48%	17.00%	3.23%	49.16%	93.03%	97.89%	99.12%
<i>Random selection</i>	82.61%	16.11%	2.39%	47.99%	87.69%	93.10%	94.95%
<i>Lasso</i>	86.98%	16.57%	1.77%	52.73%	92.27%	97.68%	98.74%
<i>Forward 1</i>	86.44%	16.95%	1.86%	50.16%	91.80%	97.33%	98.67%
<i>Forward 2</i>	87.18%	16.57%	2.11%	51.47%	92.52%	97.16%	98.24%
<i>PS</i>	85.57%	17.40%	-0.36%	47.52%	91.14%	97.00%	98.47%
<b>Panel B: Skill distribution</b>							
	$\pi_-$		$\pi_0$		$\pi_+$		
<i>Risk factors</i>	44.94%		52.25%		2.81%		
<i>Random selection</i>	13.19%		65.43%		21.38%		
<i>Lasso</i>	19.51%		78.48%		2.01%		
<i>Forward 1</i>	4.27%		86.04%		9.69%		
<i>Forward 2</i>	5.79%		79.51%		14.70%		
<i>PS</i>	1.19%		98.79%		0.02%		

*Note: The table refers to results obtained from observations made in 2009 and 2019, including a sample of 299 ETFs. Panel A of the table reports the distribution of alpha and adjusted-R<sup>2</sup> in the funds we analyzed, in accordance with the evaluated benchmark. In regards to random selection, the table shows the average parameter estimated for each fund, considering models with 1 to 15 ETFs. Panel B displays proportions of unskilled, zero-alpha, and skilled funds.*

As we can see, results attained with the new ETF set time-sample are not different from those observed earlier. According to risk factors assessed, we estimate an average alpha of -0.15%. Furthermore, we conclude that 97% of the mutual fund industry fails to generate value. When randomly selecting ETFs, we reach an average alpha of 0.03% and an unskilled fund proportion of 79%. To conclude, we can say that the PS method delivers reliable results again with an average alpha of -0.01%, while signaling that 99.98% of funds fail to generate value for their investors.

### 3.6. Conclusion

The number of ETFs has grown massively over the past years. In this paper, we examine this fact to better understand skill distribution relating to active fund performance. We have shown how several combinations within the ETF population are suited to be used as benchmarks to evaluate active management funds. Results obtained in regards to the estimated proportion of skilled managers are similar to those estimated with traditional risk factors. Nevertheless, ETFs are a better fit for the task since, unlike risk factors, they are legitimate financial instruments that are actually traded in the market.

Therefore, their observed performance takes into account transactional costs involved in their operation.

After analyzing random selections of ETF combinations, we are able to verify that: *(i)* ETFs can be used as benchmarks to assess fund performance; *(ii)* we should only compare skilled fund proportions since transaction costs suggest differences between proportions of unskilled funds obtained with risk factors and ETFs; *(iii)* finally, we find that the optimal ETF combination should not stray far from the range of 3 to 5 ETFs.

Nonetheless, we also find that several ETF combinations lead to substantial differences in regards to observed behaviors in the active fund population. Thus, this proves the need for a guided method to select ETFs featuring the appropriate traits required to evaluate funds.

Under this context, we proceeded to test a set of selection algorithms, establishing that it is possible to find suitable combinations. We have also examined cross-validation-based algorithm performances, which led us to the finding that, based on an assessed set of approximately 5 ETFs, 95% of the active mutual fund industry does not have neither the necessary skills nor the ability to generate value for their investors.

## Appendix

### A1. Procedure to compute alpha p-value for each fund ( $\hat{p}_i$ )

For each estimation attained by model (22) ( $i = (1, \dots, N)$ ), we compute the t-statistics for test  $H_i^0: \alpha_i = 0$  against  $H_i^1: \alpha_i \neq 0$  by  $\hat{t}_i = \frac{\hat{\alpha}_i}{\hat{\sigma}_{\alpha_i}}$ , where  $\hat{\sigma}_{\alpha_i}$  is a HAC estimator (Newey & West, 1987). As Kosowski *et al.* (2006) point out, t-statistic distribution in mutual funds is usually not normal, thus, we employ a bootstrap procedure to compute the p-value for the test. Following the guidelines set by Barras *et al.* (2010), we generate  $B$  bootstrap samples<sup>27</sup> for each fund return ( $\{r_{i,t}^b\}_{b=1}^B$ ) and compute a series of t-statistics ( $\{\hat{t}_i^b\}_{b=1}^B$ ). The estimated p-value for each fund can be expressed as:

$$\hat{p}_i = 2 \min \left( \frac{1}{B} \sum_{q=1}^B \mathbb{I}(\hat{t}_i^q > \hat{t}_i), \frac{1}{B} \sum_{q=1}^B \mathbb{I}(\hat{t}_i^q < \hat{t}_i) \right) \quad (44)$$

where  $\mathbb{I}$  is an indicator function that is equal to 1 if  $\hat{t}_i^b > \hat{t}_i$  or, otherwise, to zero.

### A2. Procedure to compute optimal lambda from the data ( $\lambda^*$ )

Using Barras *et al.* (2010) as our standard again, we set a grid for  $\lambda$  so that  $\lambda = (\lambda_1, \dots, \lambda_K)^{28}$ . For each value of  $\lambda_k$  so that  $\lambda_k \in \lambda$ , we calculate  $\hat{\pi}_0(\lambda_k) = \frac{1}{N} \frac{\sum_{i=1}^I \mathbb{I}(\hat{p}_i > \lambda_k)}{(1-\lambda_k)}$ , where  $\mathbb{I}$  is an indicator that is equal to 1 if  $\hat{p}_i > \lambda_k$  or, otherwise, to zero. Next, we generate  $B$  p-value bootstrap samples for each fund  $i$  ( $\{\hat{p}_i^b\}_{b=1}^B$ ) and compute  $\{\hat{\pi}_0^b(\lambda_k)\}_{b=1}^B$  for each  $\lambda_k$ <sup>29</sup>. The mean square error of  $\hat{\pi}_0(\lambda_k)$  is as follows:

$$\widehat{MSE}(\lambda_k) = \frac{1}{B} \sum_{b=1}^B \left( \hat{\pi}_0^b(\lambda_k) - \min_{\lambda \in \lambda} \hat{\pi}_0(\lambda) \right)^2 \quad (45)$$

The optimal lambda ( $\lambda^*$ ) is defined as:

$$\lambda^* = \operatorname{argmin}_{\lambda \in \lambda} \widehat{MSE}(\lambda) \quad (46)$$

<sup>27</sup> We set  $B = 1,000$ , in accordance with the Barras *et al.* (2010) procedure.

<sup>28</sup> We follow the Barras *et al.* (2010) specifications and set  $\lambda = (0.30, 0.32, \dots, 0.70)$  and  $B = 1,000$ .

<sup>29</sup>  $\hat{\pi}_0^b(\lambda_k) = \frac{1}{I} \frac{\sum_{i=1}^I \mathbb{I}(\hat{p}_i^b > \lambda_k)}{(1-\lambda_k)}$ , where  $\mathbb{I}$  is a indicate that is equal to 1 if  $\hat{p}_i^b > \lambda_k$  or, otherwise, to zero.

### A3. Procedure to compute optimal gamma from the data ( $\boldsymbol{\gamma}^*$ )

Akin to the procedure we used to set  $\lambda^*$ , we start by defining a grid  $\boldsymbol{\gamma} = (\gamma_1, \dots, \gamma_K)^{30}$ . First, we compute  $\hat{\pi}_+(\gamma_k) = \hat{S}_{\gamma_k}^+ - \hat{\pi}_0(\lambda^*) \frac{\gamma_k}{2}$  for each value of  $\gamma_k$  ( $\lambda_k \in \lambda$ ). Second, we generate  $B$  p-value bootstrap samples for each fund  $i$  ( $\{\hat{p}_i^b\}_{b=1}^B$ ) and calculate  $\{\hat{\pi}_+(\boldsymbol{\gamma})\}_{b=1}^B$ <sup>31</sup> for each  $\gamma_k$ . The mean square error of  $\hat{\pi}_+(\gamma_k)$  is:

$$\widehat{MSE}(\gamma_k) = \frac{1}{B} \sum_{b=1}^B \left( \hat{\pi}_+^b(\gamma_k) - \max_{\boldsymbol{\gamma} \in \boldsymbol{\gamma}} \hat{\pi}_+(\boldsymbol{\gamma}) \right)^2 \quad (47)$$

The optimal gamma ( $\gamma_*$ ) is defined as:

$$\gamma_* = \operatorname{argmin}_{\boldsymbol{\gamma} \in \boldsymbol{\gamma}} \widehat{MSE}(\boldsymbol{\gamma}) \quad (48)$$

### A4. Standard Deviation Estimators

In accordance with Barras *et al.* (2010), we assume that  $\hat{\pi}$  estimators are stochastic processes indexed by  $\boldsymbol{\gamma}$  and  $\lambda$  that converge to a Normal distribution if  $N \rightarrow \infty$ . Hence,  $\hat{\sigma}_{\hat{\pi}_0}$  can be estimated as<sup>32</sup>:

$$\hat{\sigma}_{\hat{\pi}_0} = \left( \frac{(\sum_{i=1}^I \mathbb{I}(\hat{p}_i > \lambda^*)) * (N - \sum_{i=1}^I \mathbb{I}(\hat{p}_i > \lambda^*))}{N^3 (1 - \lambda^*)^2} \right)^{\frac{1}{2}} \quad (49)$$

If we estimate  $\hat{\pi}_+$  by (6) and  $\hat{\pi}_-$  by (7),  $\hat{\sigma}_{\hat{\pi}_+}$  and  $\hat{\sigma}_{\hat{\pi}_-}$  are given by:

$$\hat{\sigma}_{\hat{\pi}_+} = \left( \frac{(\hat{S}_{\gamma^*}^+ (1 - \hat{S}_{\gamma^*}^+))}{N} + \frac{(\gamma^* \hat{\sigma}_{\hat{\pi}_0})^2}{4} + \frac{(\gamma^* \hat{S}_{\gamma^*}^+)}{(1 - \lambda^*)} + \frac{(\sum_{i=1}^I \mathbb{I}(\hat{p}_i > \lambda^*))}{N^2} \right)^{\frac{1}{2}} \quad (50)$$

$$\hat{\sigma}_{\hat{\pi}_-} = \left( \hat{\sigma}_{\hat{\pi}_0}^2 + \hat{\sigma}_{\hat{\pi}_+}^2 - \frac{2\hat{S}_{\gamma^*}^+ (\sum_{i=1}^I \mathbb{I}(\hat{p}_i > \lambda^*))}{(1 - \lambda^*) N^2} - \gamma^* \hat{\sigma}_{\hat{\pi}_0}^2 \right)^{\frac{1}{2}} \quad (51)$$

If we use (27) to calculate  $\hat{\pi}_-$  and (28) to estimate  $\hat{\pi}_+$  in order to obtain  $\hat{\sigma}_{\hat{\pi}_+}$  and  $\hat{\sigma}_{\hat{\pi}_-}$  expressions, we merely change subscriptions  $+$  to  $-$ , and  $-$  to  $+$ , for equations (50) and (51).

<sup>30</sup> Again, we set  $\boldsymbol{\gamma} = (0.05, 0.10, \dots, 0.50)$  and  $B = 1,000$  conforming Barras *et al.* (2010).

<sup>31</sup>  $\hat{\pi}_+(\boldsymbol{\gamma}) = \frac{\sum_{i=1}^I \mathbb{I}(\hat{p}_i^b > \boldsymbol{\gamma})}{I} - \hat{\pi}_0(\lambda^*) \frac{\boldsymbol{\gamma}}{2}$ , where  $\mathbb{I}$  is a indicator that is equal to 1 if  $\hat{p}_i^b > \boldsymbol{\gamma}$  or, otherwise, to zero.

<sup>32</sup> See Proposition 3.2 from Genovese & Wasserman (2004).

## REFERÊNCIAS

- Acharya, V. V., & Pedersen, L. H. (2005). Asset pricing with liquidity risk. *Journal of financial Economics*, 77(2), 375–410.
- Agarwal, V., Green, T. C., & Ren, H. (2018). Alpha or beta in the eye of the beholder: What drives hedge fund flows? *Journal of Financial Economics*, 127(3), 417–434.
- Akbas, F., Armstrong, W. J., Sorescu, S., & Subrahmanyam, A. (2015). Smart money, dumb money, and capital market anomalies. *Journal of Financial Economics*, 118(2), 355–382.
- Alexander, C., & Barbosa, A. (2008). Hedging index exchange traded funds. *Journal of Banking & Finance*, 32(2), 326–337.
- Andrikogiannopoulou, A., & Papakonstantinou, F. (2019). Reassessing false discoveries in mutual fund performance: Skill, luck, or lack of power? *The Journal of Finance*, 74(5), 2667–2688.
- Ardia, D., & Boudt, K. (2018). The peer performance of hedge funds. *Cahier de recherche/Working Paper*, 13, 29.
- Barber, B. M., Huang, X., & Odean, T. (2016). Which factors matter to investors? Evidence from mutual fund flows. *The Review of Financial Studies*, 29(10), 2600–2642.
- Barras, L., Scaillet, O., & Wermers, R. (2010). False discoveries in mutual fund performance: Measuring luck in estimated alphas. *The journal of finance*, 65(1), 179–216.
- Baylis, P. (2015). Temperature and temperament: Evidence from a billion tweets. *Energy Institute at HAAS working paper*, 12(1), 1–21.
- Berk, J. B., & van Binsbergen, J. H. (2015). Measuring skill in the mutual fund industry. *Journal of Financial Economics*, 118(1), 1–20.
- Berk, J. B., & Van Binsbergen, J. H. (2016). Assessing asset pricing models using revealed preference. *Journal of Financial Economics*, 119(1), 1–23.
- Berk, J. B., & van Binsbergen, J. H. (2017). Mutual Funds in Equilibrium. *Annual Review of Financial Economics*, 9(1), 147–167. <https://doi.org/10.1146/annurev-financial-110716-032454>

- Blocher, J., & Molyboga, M. (2017). The revealed preference of sophisticated investors. *European Financial Management*, 23(5), 839–872.
- Brown, S. J., Goetzmann, W. N., Hiraki, T., Shirishi, N., & Watanabe, M. (2003). Investor sentiment in Japanese and US daily mutual fund flows.
- Cao, M., & Wei, J. (2005). Stock market returns: A note on temperature anomaly. *Journal of Banking & Finance*, 29(6), 1559–1573.
- Carhart, M. M. (1997). On Persistence in Mutual Fund Performance. *Journal of Finance*, 57–82.
- Cheema, A., & Patrick, V. M. (2012). Influence of warm versus cool temperatures on consumer choice: A resource depletion account. *Journal of Marketing Research*, 49(6), 984–995.
- Chen, Y., Cliff, M., & Zhao, H. (2017). Hedge funds: The good, the bad, and the lucky. *Journal of Financial and Quantitative Analysis*, 52(3), 1081–1109.
- Chiu, H.-H. H., & Kini, O. (2013). Equity issuances, equity mutual fund flows, and noise trader sentiment. *Review of Finance*, 18(2), 749–802.
- Cochrane, J. H. (2009). *Asset pricing: Revised edition*. Princeton university press.
- Crane, A. D., & Crotty, K. (2018). Passive versus active fund performance: do index funds have skill? *Journal of Financial and Quantitative Analysis*, 53(1), 33–64.
- Criton, G., & Scaillet, O. (2014). Hedge fund managers: Luck and dynamic assessment. *Bankers, Markets & Investors*, (129), 28–38.
- CRSP. (2012). *Survivor-bias-free US mutual fund guide*.
- Dell, M., Jones, B. F., & Olken, B. A. (2012). Temperature shocks and economic growth: Evidence from the last half century. *American Economic Journal: Macroeconomics*, 4(3), 66–95.
- Dell, M., Jones, B. F., & Olken, B. A. (2014). What do we learn from the weather? The new climate-economy literature. *Journal of Economic Literature*, 52(3), 740–798.
- Dichev, I. D., & Janes, T. D. (2003). Lunar cycle effects in stock returns. *The Journal of Private Equity*, 6(4), 8–29.
- Dowling, M., & Lucey, B. M. (2005). Weather, biorhythms, beliefs and stock returns—some preliminary Irish evidence. *International Review of Financial Analysis*, 14(3),

337–355.

- Dowling, M., & Lucey, B. M. (2008). Mood and UK equity pricing. *Applied Financial Economics Letters*, 4(4), 233–240.
- Duxbury, D., Gärling, T., Gamble, A., & Klass, V. (2020). How emotions influence behavior in financial markets: a conceptual analysis and emotion-based account of buy-sell preferences. *The European Journal of Finance*, 1–22.
- Fama, E. F. (1998). Determining the number of priced state variables in the ICAPM. *Journal of Financial and Quantitative Analysis*, 33(2), 217–231.
- Fama, E. F., & French, K. R. (1992). The Cross-Section of Expected Stock Returns. *Journal of Finance*, 47(2), 427–465.
- Fama, E. F., & French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of financial economics*, 33(1), 3–56
- Fama, E. F., & French, K. R. (2010). Luck versus skill in the cross-section of mutual fund returns. *The journal of finance*, 65(5), 1915–1947.
- Fang, L., Wyon, D. P., Clausen, G., & Fanger, P. O. (2004). Impact of indoor air temperature and humidity in an office on perceived air quality, SBS symptoms and performance. *Indoor air*, 14, 74–81.
- Franzoni, F., & Schmalz, M. C. (2017). Fund flows and market states. *Review of Financial Studies*, 30(8), 2621–2673.
- Frazzini, A., Israel, R., & Moskowitz, T. J. (2012). Trading costs of asset pricing anomalies. Fama-Miller working paper, (14), 5–14.
- Genovese, C., & Wasserman, L. (2004). A stochastic process approach to false discovery control. *The Annals of Statistics*, 32(3), 1035–1061.
- Goldstein, I., Jiang, H., & Ng, D. T. (2017). Investor flows and fragility in corporate bond funds. *Journal of Financial Economics*, 126(3), 592–613.
- Hancock, P. A., & Vasmatazidis, I. (2003). Effects of heat stress on cognitive performance: the current state of knowledge. *International Journal of Hyperthermia*, 19(3), 355–372.
- Harvey, C. R., & Liu, Y. (2019). Cross-sectional alpha dispersion and performance evaluation. *Journal of Financial Economics*, 134(2), 273–296.

- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media.
- Heyes, A., & Saberian, S. (2019). Temperature and decisions: evidence from 207,000 court cases. *American Economic Journal: Applied Economics*, 11(2), 238–265.
- Hirshleifer, D., & Shumway, T. (2003). Good day sunshine: Stock returns and the weather. *The Journal of Finance*, 58(3), 1009–1032.
- Hung, H. M. J., O’Neill, R. T., Bauer, P., & Kohne, K. (1997). The behavior of the p-value when the alternative hypothesis is true. *Biometrics*, 11–22.
- Jiang, G. J., & Yuksel, H. Z. (2017). What drives the Smart-Money effect? Evidence from investors money flow to mutual fund classes. *Journal of Empirical Finance*, 40, 39–58.
- Keim, D. B. (1983). Size-related anomalies and stock return seasonality: Further empirical evidence. *Journal of financial economics*, 12(1), 13–32.
- Kosowski, R., Timmermann, A., Wermers, R., & White, H. (2006). Can mutual fund “stars” really pick stocks? New evidence from a bootstrap analysis. *The Journal of finance*, 61(6), 2551–2595.
- Lettau, M., & Madhavan, A. (2018). Exchange-traded funds 101 for economists. *Journal of Economic Perspectives*, 32(1), 135–154.
- Malkiel, B. G. (1995). Returns from investing in equity mutual funds 1971 to 1991. *The Journal of finance*, 50(2), 549–572.
- Mendelsohn, R. (2017). Measuring weather impacts using panel data. In *ASSA Annual Meeting 2017*.
- Murdoch, D. J., Tsai, Y.-L. L., & Adcock, J. (2008). P-values are random variables. *The American Statistician*, 62(3), 242–245.
- Newey, W. K., & West, K. D. (1987). Hypothesis testing with efficient method of moments estimation. *International Economic Review*, 777–787.
- Novy-Marx, R., & Velikov, M. (2016). A taxonomy of anomalies and their trading costs. *The Review of Financial Studies*, 29(1), 104–147.
- Pástor, L., & Stambaugh, R. F. (2002a). Investing in equity mutual funds. *Journal of Financial Economics*, 63(3), 351–380.

- Pástor, L., & Stambaugh, R. F. (2002b). Mutual fund performance and seemingly unrelated assets. *Journal of Financial Economics*, 63(3), 315–349.
- Patton, A. J., & Ramadorai, T. (2013). On the high-frequency dynamics of hedge fund risk exposures. *The Journal of Finance*, 68(2), 597–635.
- Pizzutilo, F., & Roncone, V. (2017). Red sky at night or in the morning, to the equity market neither a delight nor a warning: the weather effect re-examined using intraday stock data. *The European Journal of Finance*, 23(14), 1280–1310.
- Polkovnichenko, V., Wei, K. D., & Zhao, F. (2019). Cautious Risk Takers: Investor Preferences and Demand for Active Management. *The Journal of Finance*, 74(2), 1025–1075.
- Poterba, J. M., & Shoven, J. B. (2002). Exchange-traded funds: A new investment option for taxable investors. *American Economic Review*, 92(2), 422–427.
- Roll, R. (1992). Weather in: Newman P., Milgate M., Eatwell J.[ed.] *The new Palgrave dictionary of money and finance*. Macmillan Press, London.
- Saunders, E. M. (1993). Stock prices and Wall Street weather. *The American Economic Review*, 83(5), 1337–1345.
- Seppanen, O., Fisk, W. J., & Lei, Q. H. (2006). Room temperature and productivity in office work.
- Sharpe, William F. "Asset allocation: Management style and performance measurement." *Journal of portfolio Management* 18.2 (1992): 7-19
- Symeonidis, L., Daskalakis, G., & Markellos, R. N. (2010). Does the weather affect stock market volatility? *Finance Research Letters*, 7(4), 214–223.
- Xavier, A. C., King, C. W., & Scanlon, B. R. (2016). Daily gridded meteorological variables in Brazil (1980-2013). *International Journal of Climatology*, 36(6), 2644–2659.
- Yuan, K., Zheng, L., & Zhu, Q. (2006). Are investors moonstruck? Lunar phases and stock returns. *Journal of Empirical Finance*, 13(1), 1–23.
- Zhu, M. (2018). Informative fund size , managerial skill , and investor rationality. *Journal of Financial Economics*, 130(1), 114–134.