

**UNIVERSIDADE DE BRASÍLIA
DEPARTAMENTO DE ECONOMIA**

Discente: Otávio Kahlil B. Waquim



**Fatores de risco estilizados: uma análise para o mercado de
debêntures de infraestrutura no Brasil**

Professor: Daniel Oliveira Cajueiro

Brasília
2024

Sumário

1. Resumo	3
2. Abstract.....	3
3. Introdução	4
4. Revisão de literatura.....	6
5. Metodologia:.....	8
6. Resultados:	20
7. Conclusão:.....	29
8. Anexos.....	32
8.1 MQO por Setor	32
8.2 MQO por Lei 12.431	36
8.3 RMSE por setor por ano:	37
8.4 RMSE por Lei 12.431 por ano:.....	39
9. REFERÊNCIAS BIBLIOGRÁFICAS.....	40

1. Resumo

A monografia explora o uso de modelos de fatores para previsão de retornos no mercado de crédito privado brasileiro, com foco em debêntures de infraestrutura. Utilizando dados de 212 de 2013 até 2024 de empresas de setores estratégicos como energia elétrica e transporte, o estudo aplica regressões lineares múltiplas para avaliar variáveis como duration, volatilidade e Value at Risk (VaR), além de fatores SMB, HML, RMW e CMA do modelo de Fama e French. A análise inclui validação cruzada e simulações de Monte Carlo para testar a robustez dos modelos. Resultados indicam que debêntures incentivadas são mais sensíveis a fatores de risco, enquanto debêntures não incentivadas apresentam menor volatilidade. A baixa capacidade explicativa dos modelos reflete desafios específicos da aplicação de estratégias de *factor investing* em renda fixa, como fragmentação do mercado e altos custos de transação.

2. Abstract

The monograph explores the use of factor models to predict returns in the Brazilian private credit market, focusing on debentures of infrastructure. Using data from 211 companies from 2013 to 2024 in strategic sectors such as energy and transportation, the study applies multiple linear regressions to evaluate variables such as duration, volatility, and Value at Risk (VaR), as well as SMB, HML, RMW, and CMA factors from the Fama and French model. The analysis includes cross-validation and Monte Carlo simulations to test the robustness of the models. Results indicate that incentivized debentures are more sensitive to risk factors, while non-incentivized debentures exhibit lower volatility. The low explanatory capacity of the models highlights specific challenges in applying factor investing strategies to fixed income, such as market fragmentation and high transaction costs.

3. Introdução

A infraestrutura é uma das áreas mais relevantes para o crescimento econômico, especialmente em países em desenvolvimento como o Brasil, onde há um déficit histórico de investimentos no setor. Dados levantados pelo IPEA (Instituto de Pesquisa Econômica Aplicada), em 2024, indicam que, como percentual do PIB, os investimentos brasileiros em infraestrutura permanecem abaixo da mediana da América Latina, evidenciando a necessidade de políticas públicas e instrumentos financeiros que possam mitigar esse hiato. Com vistas em incentivar um mercado privado de financiamento de longo prazo, o governo brasileiro promulgou a Lei nº 12.431, de 27 de junho de 2011, cujo objetivo é desempenhar o papel de alternativa para empréstimos de longo prazo realizados para projetos de infraestrutura (ANBIMA, 2011). Paralelamente, o mercado de crédito corporativo brasileiro oferece uma oportunidade particular para explorar metodologias que buscam explicar a rentabilidade de debêntures de infraestrutura a partir de fatores de risco e estilo, como *Factor Investing* e *Smart Beta*. Essas abordagens, amplamente utilizadas em mercados desenvolvidos, podem fornecer análises valiosas sobre a precificação de ativos no Brasil, especialmente na avaliação do impacto de variáveis como duration, volatilidade e VAR, bem como fatores clássicos como SMB, HML, RMW e CMA. Queremos avaliar se é possível explicar e prever a rentabilidade de debêntures de infraestrutura brasileiras, incentivadas e não incentivadas, considerando fatores de risco e estilo, bem como as particularidades setoriais. A análise terá como pilares comparações internas ao modelo, avaliando as diferenças entre debêntures incentivadas e não incentivadas, e comparações setoriais, destacando cinco setores prioritários. Não obstante, será explorada a aplicabilidade do modelo de *Factor Investing* no contexto brasileiro, tradicionalmente associado a mercados desenvolvidos, como os EUA e a Europa Ocidental.

O presente trabalho concentra-se em explicar e prever a rentabilidade de debêntures de infraestrutura brasileiras, abrangendo tanto papéis incentivados quanto não incentivados, com foco em cinco setores estratégicos da economia: transporte, energia elétrica, petróleo e gás, saneamento básico e distribuição de gás natural. Os dados utilizados foram extraídos da base Econômica, cobrindo o período de 2013 a 2024, conforme o maior volume de emissões identificado nesse intervalo. Essa abordagem temporal possibilita uma análise robusta de fatores de risco em diferentes cenários econômicos, considerando a relevância crescente do investimento em infraestrutura no Brasil. Adicionalmente, o trabalho utiliza regressões lineares múltiplas por Mínimos Quadrados Ordinários (OLS) para avaliar a significância estatística dos fatores de risco e estilo selecionados, permitindo verificar sua relevância na explicação da rentabilidade dos ativos analisados. Para assegurar a solidez das análises preditivas e avaliar a capacidade explicativa do modelo, metodologias foram integradas ao estudo. A técnica de validação cruzada (*cross-validation*), conforme descrita por Arlot e Celisse (2009), foi aplicada para testar a generalização do modelo em diferentes subconjuntos de dados e minimizar o risco de *overfitting*. Simultaneamente, Simulações de Monte Carlo foram utilizadas para projetar cenários de retorno com base em distribuições probabilísticas, permitindo explorar a variabilidade esperada e avaliar cenários extremos. Essas ferramentas complementam a análise estatística, garantindo a validade dos resultados e oferecendo uma base para verificar a aplicabilidade do modelo no mercado brasileiro.

A importância deste trabalho reside na relevância econômica do setor de infraestrutura e no potencial de inovação ao aplicar métodos consolidados, como regressão OLS, *cross-validation* e Simulação de Monte Carlo, para uma amostra específica e de alta representatividade. O objetivo geral é avaliar a significância e a capacidade preditiva dos fatores de risco e de estilo na explicação da rentabilidade de debêntures de infraestrutura. Os objetivos específicos incluem: (i) identificar fatores relevantes para a rentabilidade das debêntures; (ii) comparar as características de ativos

incentivados e não incentivados no que tange a fatores de estilo; (iii) realizar análises quantitativas setoriais detalhadas e validar os modelos.

O alicerce teórico está fundamentado em estudos clássicos e contemporâneos. Fama e French (1992, 1993) introduziram fatores de estilo, como SMB, HML, RMW e CMA, que foram adaptados para o mercado de renda fixa por Bektić et al. (2014), destacando sua relevância na explicação de retornos. Em paralelo, Song e Xie (2016) demonstraram a importância de variáveis específicas, como duration, volatilidade e VAR, para o mercado de crédito. Esses fatores foram integrados para construir um modelo abrangente, considerando tanto as características dos ativos quanto os riscos específicos do mercado brasileiro. Métodos, como *cross-validation*, descritos por Arlot e Celisse (2009), foram utilizados para validar a capacidade de generalização do modelo, enquanto a Simulação de Monte Carlo foi aplicada para prever cenários de retorno e variabilidade esperada, reforçando a análise preditiva. Além disso, a significância estatística dos fatores foi avaliada por meio de regressões lineares múltiplas utilizando OLS, garantindo uma abordagem robusta e replicável.

Nas seções seguintes, o presente estudo investiga a aplicabilidade dos fatores de Fama e French (1993), bem como variáveis estilizadas como duration, volatilidade e *Value at Risk*, no mercado de debêntures brasileiras. A Revisão de Literatura apresenta os principais conceitos teóricos e estudos relacionados à precificação baseada em fatores. Na Metodologia, são descritos os procedimentos econométricos adotados, incluindo regressões lineares múltiplas e validação cruzada. A seção de Resultados aborda a análise empírica, interpretando os coeficientes estimados e sua significância, além da análise da relação entre retornos preditos e simulados. Por fim, a Conclusão sintetiza os achados principais, discute as limitações da pesquisa e propõe direções futuras para o aprimoramento dos estudos sobre crédito privado no Brasil.

4. Revisão de literatura

A introdução de modelos de fatores de risco em finanças foi fulcral para o avanço das teorias de investimentos. Em 1952, o economista Harry Markowitz publicou seu artigo "*Portfolio Selection*", que inicializou a teoria de finanças modernas (Markowitz, 1952). Markowitz apresentou uma abordagem para a construção de portfólios, que não apenas maximiza o retorno esperado, mas considera o risco medido pelo desvio padrão dos retornos. Sua proposta de diversificação estabeleceu o conceito de "fronteira eficiente", representando combinações ótimas de ativos para investidores racionais.

O modelo de Markowitz retificou a teoria ao demonstrar que portfólios bem diversificados podem diminuir o risco total, um princípio que foi chamado de "modelo canônico", por representar o equilíbrio teórico entre risco e retorno. Segundo a hipótese de eficiência de mercado, todos os investidores são racionais e as informações disponíveis no mercado são refletidas de forma rápida e precisa nos preços dos ativos, evitando oportunidades de arbitragem. Os preços rapidamente se ajustam a novas informações devido à arbitragem. Essa visão, de um mercado eficiente em que os preços são ajustados rapidamente, teve grande influência na formulação das finanças modernas (Fama, 1970).

Com a evolução dos mercados e o aumento dos dados históricos, começaram a surgir "*puzzles*" ou paradoxos empíricos que desafiavam a lógica teórica do "modelo canônico" dos anos 1950. Shiller (1981) demonstrou a significância da volatilidade ao observar que os preços das ações flutuam mais do que seria justificado pelos fundamentos econômicos, como dividendos e lucros futuros. Esse desvio entre a teoria e a prática colocou em dúvida a eficiência do mercado, mas também apontou a influência de fatores comportamentais e especulativos. A ideia de que os preços de ativos poderiam ser voláteis levou a uma reconsideração dos modelos que se baseavam na racionalidade e eficiência do mercado, sugerindo que fatores de estilo também influenciam as decisões de investidores e, conseqüentemente, os preços dos ativos. Outro *puzzle* relevante foi destacado por De Bondt e Thaler (1985), os quais questionaram o "modelo canônico", levantando a possibilidade de superar o mercado. Eles discutiram o fenômeno em que os preços frequentemente reagem excessivamente a novas informações, ocasionando anomalias de mercado.

Para estimar a esperança do retorno de um ativo, diversos modelos foram desenvolvidos. O "*Capital Asset Pricing Model*" (CAPM), de Sharpe (1964), é considerado pioneiro nessa teoria. A ideia central de que o retorno esperado depende de um beta para explicar o risco sistemático de um ativo foi expandida por Ross (1976) no "*Arbitrage Pricing Theory*" (APT), que considera outros fatores de risco, como variáveis macroeconômicas. O modelo de risco multifatorial com base em fatores de estilo, de Fama e French (1992), motivará o estudo a ser realizado nesta monografia. A evolução dos modelos de fatores de risco culminou com o modelo de fatores de Fama e French (1993), que ampliou o CAPM ao incorporar o tamanho das empresas e o valor como fatores adicionais, além do risco de mercado.

Behavioral Finance é uma área de estudo que examina como fatores de estilo influenciam as decisões financeiras dos indivíduos e, conseqüentemente, os mercados, levando a anomalias. Esses erros podem surgir de vieses cognitivos, o que acarreta desvios dos modelos teóricos anteriores (Kahneman e Tversky, 1979). Os novos fatores de risco introduzidos no modelo de Fama e French estão alinhados com descobertas do *Behavioral Finance*.

O *Factor Investing*, aplicado à renda fixa, é uma extensão da análise de fatores amplamente utilizada em renda variável, mas apresenta desafios devido às diferenças estruturais entre os dois mercados. Spielman et al. (2015) exploram como fatores tradicionais, como tamanho e valor, podem ser adaptados para o mercado de *bonds* corporativos, particularmente em mercados de

high yield e grau de investimento nos EUA e na Europa. Os autores usaram o modelo de Fama e French (1993, 2015) como base, testando fatores como lucratividade e investimento para determinar sua relevância na precificação de *bonds* corporativos. A aplicação de tais fatores na renda fixa busca capturar premissas de risco sistemático, destacando-se como um potencial incremento na busca por retornos ajustados ao risco.

Soe e Xie (2020) confirmam o aumento do interesse por estratégias de *Factor Investing* na renda fixa, impulsionado pelo cenário de baixas taxas de juros após a crise de 2008. Segundo o estudo, fatores como valor e baixa volatilidade pode ser utilizados de forma sistemática em índices de renda fixa, com a criação de um portfólio teórico de múltiplos fatores, o qual busca retornos superiores em relação aos índices tradicionais de *bonds* corporativos de grau de investimento dos EUA.

A construção de estratégias de Factor Investing para *bonds* corporativos requer adaptações específicas. Enquanto fatores de tamanho e valor são diretamente aplicáveis, outros, como momentum, enfrentam limitações devido à menor liquidez e transparência dos mercados de *bonds* em comparação com ações (Carhart, 1997). Estudos como o de Houweling e Zundert (2014) mostram que fatores de tamanho, volatilidade, valor e momentum produzem prêmios significativos no mercado de *bonds* corporativos dos EUA, sendo a combinação desses fatores vantajosa frente a portfólios de fator único.

Armeanu, Bălu e Obreja (2008) destacam a relevância da duration e da volatilidade no gerenciamento de risco de renda fixa. Eles utilizam a metodologia de gap de duration para medir a sensibilidade de portfólios a flutuações nas taxas de juros, sugerindo que a duration pode ser entendida como um fator essencial para estratégias de investimento baseadas em fatores.


Os estudos que investigam a precificação de ativos a partir de fatores de risco expandem significativamente a aplicação de modelos econômicos e financeiros, fornecendo uma base sólida para estratégias baseadas em dados. Elton et al. (2001) consolidaram a relevância da teoria moderna de portfólios, explicando como a diversificação pode ser melhorada ao incorporar diferentes fatores de risco sistemáticos. A pesquisa também aborda a importância de entender os custos de transação e a liquidez como elementos fundamentais que impactam a performance dos portfólios ajustados ao risco. Adicionalmente, Banz (1981) identificou uma relação inversa entre o tamanho das empresas e os retornos médios das ações, apontando que empresas menores tendem a apresentar maiores retornos ajustados ao risco, fenômeno que fundamenta o fator SMB em modelos multifatoriais.

A evolução dessas análises para o mercado de renda fixa é amplamente documentada. Houweling e Zundert (2014) aplicaram a lógica de fatores ao mercado de *bonds* corporativos, destacando que estratégias baseadas em fatores como volatilidade e valor produzem resultados superiores a benchmarks tradicionais. Por outro lado, a análise de Harvey (2023) sugere que a integração de dados quantitativos com avanços tecnológicos permite aprimorar estratégias de investimento, reforçando a importância de abordagens sistemáticas. Arlot e Celisse (2009) contribuíram com métodos para validação de modelos preditivos, detalhando como a cross-validation pode ser usada para reduzir o risco de overfitting e melhorar a generalização dos resultados em amostras independentes. Esses estudos, aliados a novas metodologias de backtesting, expandem a aplicabilidade dos modelos de fatores, indicando a necessidade de incluir variáveis como custos de transação e spreads de crédito para uma análise mais robusta.


5. Metodologia:

A metodologia adotada neste estudo busca oferecer uma análise replicável dos fatores de risco no mercado de crédito privado brasileiro, com foco nas debêntures incentivadas e não incentivadas, utilizando uma base de dados composta por 212 empresas de setores estratégicos, totalizando 600 papéis. Dentre essas debêntures, 363 são incentivadas pela Lei nº 12.431/2011, enquanto 237 não possuem incentivo fiscal. A Lei nº 12.431, criada para fomentar o financiamento de longo prazo em projetos de infraestrutura, é particularmente relevante neste contexto, uma vez que suas condições impactam diretamente os retornos observados nos ativos analisados.


Os dados foram extraídos da plataforma Economática, contemplando informações detalhadas sobre duration, volatilidade e Value at Risk (VaR) a um nível de confiança de 95%, bem como o valor de mercado das empresas emissoras, utilizado para ponderar os fatores de risco. A análise inicial concentrou-se em descrever a evolução desses fatores ao longo do tempo, aplicando uma média móvel de 50 períodos para suavizar as flutuações e destacar tendências consistentes. As Figuras 1, 2 e 3 apresentam, respectivamente, a evolução da duration média ponderada, da volatilidade média ponderada e do VaR médio ponderado.



Fonte: Economática Figura 1: Evolução da Duration Média Ponderada (média móvel)




Fonte: Economática Figura 2: Evolução da Volatilidade Média Ponderada (média móvel)




Fonte: Economática Figura 3: Evolução do VAR Médio Ponderado (média móvel)


Na sequência, realizou-se uma segmentação dos dados com base na Lei nº 12.431, permitindo comparar as debêntures incentivadas e não incentivadas em termos de retorno acumulado, duration, volatilidade e VaR, como ilustrado nas Figuras 4, 5, 6 e 7. Essa análise buscou identificar como os fatores de risco se comportam em cada grupo, considerando a maior exposição dos papéis incentivados a projetos de infraestrutura. Para contextualizar o impacto setorial, a Figura 8 apresenta a distribuição das empresas por setor econômico, destacando que o setor de energia elétrica possui a maior representatividade, uma vez que é amplamente beneficiado pela legislação mencionada.




Fonte: Economática Figura 4: Retorno Acumulado por Lei 12.431



Fonte: Economática Figura 5: Duration Média Ponderada por Lei 12.431



Fonte: Economática Figura 6: Volatilidade Média Ponderada por Lei 12.431




Fonte: Economática Figura 7: VAR Médio Ponderado por Lei 12.431

As assíntotas que ocorreram durante o período da pandemia, tanto para os papéis incentivados quanto para os não incentivados, ocorrem no período em que se observou maior risco sistemático


Os principais setores de atuação dessa lei e das emissões relacionadas à infraestrutura serão apresentados em sequência na Figura 8:

Fonte: Economática Figura 8: Distribuição de Empresas por Setor Econômico




Para avaliar o impacto setorial nos fatores de risco, analisou-se a rentabilidade acumulada (Figura 9), duration média ponderada (Figura 10), volatilidade média ponderada (Figura 11) e VaR médio ponderado (Figura 12), complementados por um painel detalhado dos dados por setor na Figura 13. Em paralelo, a correlação entre os setores foi explorada por meio de uma matriz, apresentada na Figura 14, que revela uma forte relação entre setores dependentes de políticas


públicas, como energia elétrica e saneamento, e programas governamentais como o Plano Decenal de Energia Elétrica e o Novo Programa de Aceleração Econômica.




Fonte: Economática Figura 9: Rentabilidade Acumulada por Setor Econômico




Fonte: Economática Figura 10: Duration Média Ponderada por Setor Econômico



Fonte: Economática Figura 11: Volatilidade Média Ponderada por Setor Econômico

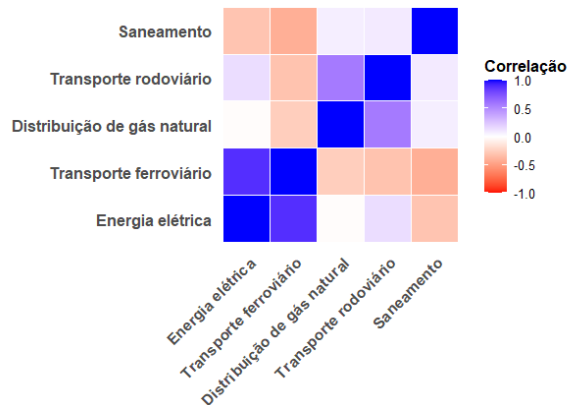


Fonte: Economática Figura 12: VAR Médio Ponderado por Setor Econômico



Fonte: Economática Figura 13: Painel de VAR Médio Ponderado por Setor Econômico

Destaca-se na análise, a correlação entre os principais setores considerados para os diferentes papéis, conforme exibido na matriz abaixo (Figura 14). Observa-se que há uma correlação forte entre os setores que dependem de políticas governamentais, como é o caso do Plano Decenal de Energia Elétrica, do Marco Legal do Saneamento e do Novo Programa de Aceleração Econômica.



Fonte: Economática Figura 14: Matriz de Correlações por Setor Econômico

A amostra é composta por 3 empresas de distribuição de gás natural, 132 de Energia elétrica, 27 empresas de Saneamento, 3 de Transporte aquático, 1 de Transporte aéreo, 1 de Transporte de gás natural por tubos, 7 de Transporte ferroviário, 2 de Transporte fluvial, 32 de Transporte rodoviário e 1 de Transporte turístico.

Para aprofundar a análise, os dados foram segmentados em decis de volatilidade, duration e VaR, ponderados pelo valor de mercado, conforme apresentado nas Tabelas 1, 2 e 3 e nos boxplots correspondentes (Figuras 15, 16 e 17). Essa abordagem permitiu identificar características específicas dos papéis em relação aos fatores de risco, baseando-se nos estudos de Merton (1974), que destacam a importância da duration e da volatilidade para compreender os prêmios de crédito. A duration, em particular, é fundamental para medir a sensibilidade dos títulos às variações nas taxas de juros, enquanto a volatilidade atua como um controle de risco,

identificando títulos com spreads de crédito amplos, mas sem excesso de risco.

```
[1] "Decis para volatilidade Ponderada"  
> print(decis_volatilidade)  
Decis valor  
1 1 0.3501990  
2 2 0.8002196  
3 3 1.9411572  
4 4 3.2402253  
5 5 3.9925530  
6 6 4.7946219  
7 7 5.4707108  
8 8 6.1530416  
9 9 7.3385936  
10 10 10.8953751
```

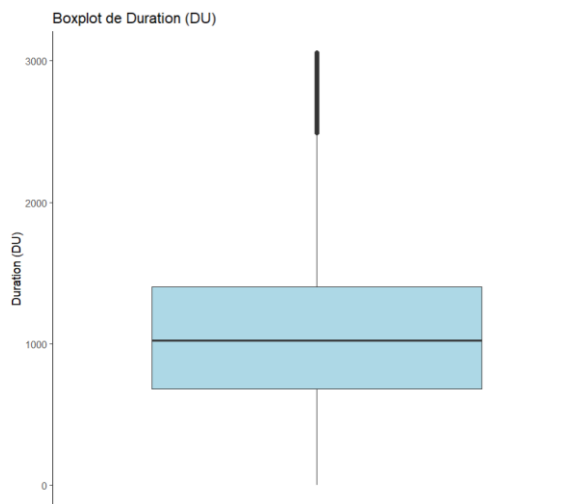
Fonte: Economática Tabela 1: Volatilidade Média Ponderada por Decis

```
[1] "Decis para Duration Ponderada"  
> print(decis_duration)  
Decis valor  
1 1 269.8985  
2 2 461.9379  
3 3 594.5395  
4 4 736.4564  
5 5 878.9468  
6 6 995.4425  
7 7 1126.6540  
8 8 1281.6181  
9 9 1499.0012  
10 10 2023.5386
```

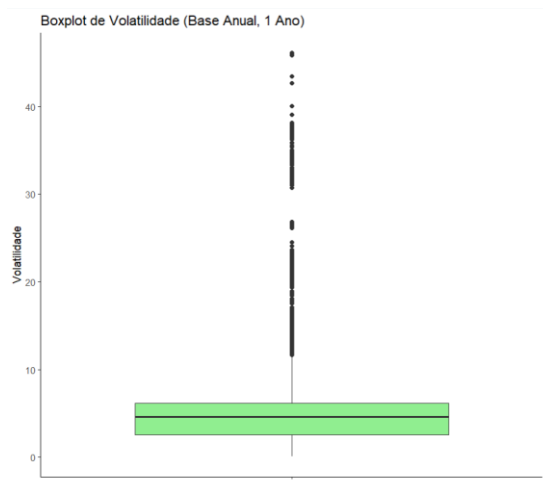
Fonte: Economática Tabela 2: Duration Média Ponderada por Decis

```
[1] "Decis para VAR Ponderado"  
> print(decis_var)  
Decis valor  
1 1 0.0361958  
2 2 0.0826560  
3 3 0.2002507  
4 4 0.3349806  
5 5 0.4129724  
6 6 0.4953866  
7 7 0.5656482  
8 8 0.6359418  
9 9 0.7576941  
10 10 1.1210121
```

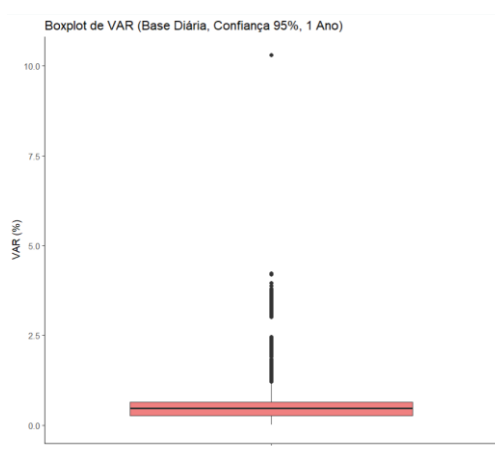
Fonte: Economática Tabela 3: VAR Médio Ponderado por Decis



Fonte: Economática Figura 15: Box Plot de Duration Média Ponderada por Valor de Mercado



Fonte: Economática Figura 16: Box Plot de Volatilidade Média Ponderada por Valor de Mercado



Fonte: Economática Figura 17: Box Plot de VAR Médio Ponderado por Valor de Mercado


Ao considerar a relevância da volatilidade, da *duration* e do VAR, no contexto das estratégias de investimento, a literatura sugere que a *duration* e a volatilidade das empresas são cruciais para entender os prêmios de crédito, conforme explicado por Merton (1974). Através da análise de decis, observa-se que a volatilidade das empresas é bastante variada.

A volatilidade, definida como o desvio padrão das mudanças diárias no rendimento dos títulos ao longo de um período de doze meses, permite identificar os títulos que, apesar de terem *spreads* de crédito elevados, não justificam essa volatilidade histórica. Isso é particularmente importante em mercados de renda fixa, onde a volatilidade pode atuar como um mecanismo de controle de risco, selecionando títulos com *spreads* de crédito amplos, mas que não estão excessivamente carregados de risco.

Além disso, a *duration*, é um fator clássico que influencia os retornos dos títulos de renda fixa. Os estudos mostram que, ao longo de um horizonte de investimento prolongado, títulos de longo prazo tendem a obter retornos mais elevados em comparação com títulos de curto prazo, refletindo o prêmio de risco de taxa de juros.

A utilização conjunta dos fatores de volatilidade, *duration* e VAR, como discutido no artigo de Song e Xie (2016) pode ajudar a construir um portfólio de títulos corporativos de alto grau de investimento que combina a oportunidade de estreitamento de *spreads* de crédito com

uma abordagem de controle de volatilidade, resultando em retornos ajustados ao *benchmark*, que serão escolhidos a partir das carteiras IDA da Anbima, CDI Acumulado e IPCA Acumulado. A Figura 18 apresenta a evolução da rentabilidade desses índices de mercado:




Fonte: Economática Figura 18: Rentabilidade Acumulada para Diferentes Benchmarks

Não obstante, os fatores Size (tamanho), Value (valor), Profitability (lucratividade) e Investment (investimento), variáveis orientadas pelos estudos de Spielman et al. (2015) e Soe e Xie (2020), destacam sua relevância na avaliação do desempenho de ativos de renda fixa e renda variável. Os gráficos a seguir apresentam a evolução desses fatores de risco ao longo do tempo, evidenciando um comportamento consistente com as estatísticas descritivas da amostra.

O fator tamanho ou SMB (Figura 19) representa a diferença de retorno entre empresas pequenas e grandes, capturando o efeito de tamanho nos retornos. Foi calculado usando o valor de mercado da empresa, medido em milhares. Essa escolha se justifica pela relação observada entre o tamanho das empresas e seu desempenho no mercado. Em geral, empresas pequenas (*Small*) tendem a ter retornos maiores do que empresas grandes (*Big*). A *dummy* SMB_Small captura esse efeito categorizando as empresas em pequenas ou não (1 para pequenas, 0 para as demais). (Banz, 1981; Fama e French, 1993, 2015). As empresas foram divididas em *Small*, *Neutral* e *Big* com base nos percentis 33%, 66% e 100%.

$$SMB = \frac{1}{3}(SMALL + SMALL_{NEUTRAL} + SMALL_{BIG}) - \frac{1}{3}(BIG_{SMALL} + BIG_{NEUTRAL} + BIG)$$



Fonte: Economática Figura 19: Evolução de SMB

O fator valor ou HML (Figura 20) foi calculado como a razão entre o patrimônio líquido e o valor de mercado da empresa. Essa métrica é análoga à relação *book-to-market* usada por Fama e French (1992) e ajustada conforme Asness e Frazzini (2013). O fator HML_High captura o prêmio de risco associado a empresas de alto valor contábil/valor de mercado (Book-to-Market, B/M), ou seja, debêntures de valor, em relação às de crescimento (baixo B/M). As empresas são classificadas como *Low* e *High* com base nos percentis 50%.


$$HML = \frac{1}{2}(LOW + LOW_{HIGH}) - \frac{1}{2}(HIGH + HIGH_{LOW})$$



Fonte: Economática Figura 20: Evolução de HML

A lucratividade ou RMW (Figura 21) foi medida como a razão entre o retorno anual sobre o patrimônio líquido (ROE), ajustado por mil. A escolha desse parâmetro, mais uma vez, baseia-se no trabalho de Fama e French (1993), quando demonstra que empresas com alta lucratividade (*Robust 50%*) tendem a oferecer retornos maiores do que comparado às empresas *Weak(50%)*, devido à sua capacidade de gerar fluxos de caixa saudáveis.

$$RMW = \frac{1}{2}(WEAK + WEAK_{ROBUST}) - \frac{1}{2}(ROBUST + ROBUST_{WEAK})$$



Fonte: Economática Figura 21: Evolução de RMW

O fator investimento ou CMA (Figura 22) foi calculado como a variação nos ativos totais da empresa em relação ao ano anterior, ajustado por mil. A variável eleita, calculada como a diferença de retorno entre empresas conservadoras e agressivas, segue a definição de Fama e French (1993), quando mostram que empresas com maiores níveis de investimento (*Agressiva x Conservate 50%*) tendem a ter maiores retornos futuros, pois investem apenas em projetos com

altos retornos esperados. Os fatores foram ponderados pelo valor de mercado das empresas, conforme a metodologia sugerida por Elton et al. (2001).

$$CMA = \frac{1}{2}(CONSERVATE + CONSERVATE_{AGRESSIVE}) - \frac{1}{2}(AGRESSIVE + AGRESSIVE_{CONSERVATE})$$

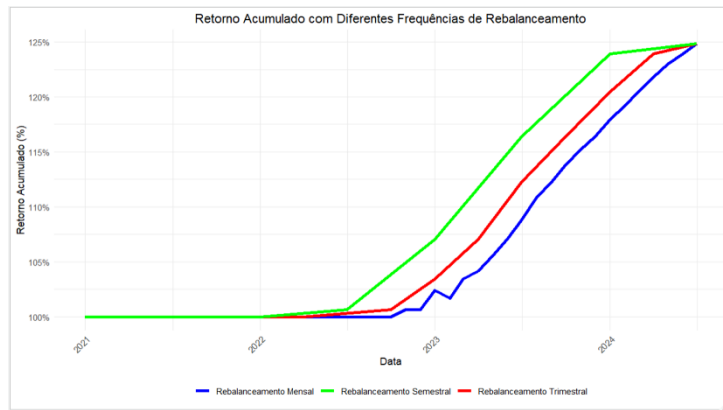


Fonte: Economática Figura 22: Evolução de CMA

De acordo com o artigo de Song e Xie, *Factor Investing* é uma estratégia estabelecida, particularmente em renda variável, mas ainda emergente em renda fixa. Os autores identificam que grande parte do risco em renda fixa pode ser explicado por fatores sistemáticos. A Figura 23 é construída a partir de um portfólio baseado nos fatores *duration*, volatilidade e *Value at Risk* (95% de significância); rebalanceados mensalmente, trimestralmente e semestralmente:

O processo de rebalanceamento foi conduzido com o objetivo de alinhar periodicamente o portfólio às proporções ideais dos fatores de risco selecionados, conforme os critérios estabelecidos neste estudo. A seleção dos fatores foi realizada com base no segundo decil, priorizando combinações de baixa **Duration** e baixo **VAR**, visando identificar carteiras com uma relação risco-retorno mais eficiente. Para cada frequência de rebalanceamento — mensal, trimestral e semestral —, os pesos dos ativos no portfólio foram ajustados de acordo com as variações nos fatores ao longo do período. O rebalanceamento envolveu uma atualização das ponderações dos ativos com base nos retornos observados e na exposição aos fatores, minimizando discrepâncias em relação às proporções originalmente definidas. Esse processo foi implementado para capturar o impacto da frequência de ajustes no desempenho do portfólio, considerando os custos de transação associados.

A análise dos resultados foi fundamental para verificar como diferentes frequências de rebalanceamento influenciam o retorno acumulado e ajustado ao risco. Estudos prévios, como o de Song e Xie (2016), indicam que frequências mais baixas de rebalanceamento tendem a gerar retornos ajustados ao risco superiores, devido à redução na rotatividade dos ativos e nos custos de transação. Este estudo avaliou se essa dinâmica se mantém no mercado brasileiro de crédito corporativo, especialmente para debêntures vinculadas a projetos de infraestrutura. Comparar os retornos acumulados sob diferentes frequências permite validar a hipótese de que um menor número de ajustes reduz os custos e otimiza o desempenho do portfólio, oferecendo insights relevantes para estratégias de investimento baseadas em fatores no contexto local.



Fonte: Economática Figura 23: Retorno Acumulado por Frequência de Rebalanceamento

Para selecionar os fatores, o ponto de corte adotado foi o segundo decil. Sugere-se que a combinação de fatores baixa duration e baixo risco pode resultar em retornos ajustados a uma melhor relação risco-retorno. Na amostra, as frequências de rebalanceamento mensal, trimestral e semestral evidenciaram uma variação no retorno acumulado, o que ocorre no estudo de Song e Xie para o mercado americano. O resultado obtido assemelha-se ao observado no artigo, demonstrando que uma menor frequência de rebalanceamento, tende a resultar em retornos ajustado ao risco mais elevados. Segundo a conclusão do *paper*, uma menor frequência de rebalanceamento vem a reduzir a rotatividade do portfólio e, conseqüentemente, os custos de transação. Isso ocorre porque há menos operações de compra e venda, o que diminui o impacto dos custos de transação no retorno líquido. Essa redução de custos resulta em um retorno líquido superior, como foi observado no exemplo em que o portfólio, de dois fatores reequilibrados trimestralmente, apresentou um retorno excedente maior em comparação com o portfólio reequilibrado mensalmente. Comparar os retornos acumulados sob diferentes frequências permite validar a hipótese de que um menor número de ajustes reduz os custos e otimiza o desempenho do portfólio.

À medida que o investimento baseado em fatores e a diversificação de fatores de risco ganharam força no mercado de ações após a crise financeira, o interesse foi ampliado para os prêmios de risco nos mercados de renda fixa também. A análise preditiva realizada consiste em uma regressão linear múltipla com OLS que podem ser descritas pelas seguintes equações, com seus respectivos resultados na seção seguinte:

$$(1) R = \alpha_0 + \beta_1 Duration + \beta_2 VAR + \beta_3 Volatilidade + \varepsilon$$

$$(2) R = \alpha_0 + \beta_1 SMB + \beta_2 HML + \beta_3 RMW + \beta_4 CMA + \varepsilon$$

$$(3) R = \alpha_0 + \beta_1 Duration + \beta_2 VAR + \beta_3 Volatilidade + \beta_4 SMB + \beta_5 HML + \beta_6 RMW + \beta_7 CMA + \varepsilon$$

Para avaliar a precisão e a robustez dos modelos de regressão, foi utilizado o Erro Quadrático Médio (RMSE), que mede a diferença entre os valores previstos e os valores observados. O RMSE foi calculado para cada modelo ajustado, permitindo identificar a eficácia em diferentes períodos e categorias, como setores econômicos e debêntures incentivadas ou não incentivadas. Valores menores de RMSE indicam maior precisão do modelo, enquanto valores mais elevados sugerem discrepâncias significativas entre os retornos previstos e os observados.

Esse processo foi seguido por análises de validação cruzada (*cross-validation*), que dividem a amostra em subconjuntos independentes para ajuste e teste do modelo (dois terços dos dados para testes e um terço para treino). Essa abordagem reduz o risco de *overfitting*, avaliando a capacidade de generalização dos modelos em dados não utilizados no ajuste inicial.

Além disso, foi realizada uma Simulação de Monte Carlo para analisar a distribuição dos retornos preditos com base nos fatores de risco identificados. Foram geradas 50.000 simulações de retornos utilizando distribuições normais para cada variável independente do modelo, permitindo observar cenários possíveis e mensurar a variabilidade esperada dos retornos. Os resultados da simulação foram comparados com os retornos reais para identificar discrepâncias e validar a adequação do modelo às condições observadas no mercado. Essa técnica também possibilitou a análise de cenários extremos, avaliando a robustez do modelo em condições adversas e fornecendo insights para decisões estratégicas relacionadas a investimentos baseados em fatores.

6. Resultados:

Variáveis	Coeficientes	std.error	t statistic	p.value	Significância
(Intercept)	0,047852252	0,001456493	32,85442858	3,0826E-236	***
`Duration (DU)`	-1,29597E-05	1,85875E-06	6,972277956	3,12602E-12	***
`VAR % base diária confiança: 95% 1 anos Em moeda orig`	2,51001492	0,067554055	37,15565154	2,2929E-301	***
`Volatilidade base anual 1 anos Em moeda orig_1`	-	-	-	4,9522E-308	***
R-squared	0,005869607				
Observations	254.996				

Fonte: Económica Tabela 4: Resultado de MQO (Duration, VAR e Volatilidade)

Variáveis	Coeficientes	std.error	t statistic	p.value	Significância
(Intercept)	0,184172601	0,013155165	14,00002193	1,5997E-44	***
SMB_Small	-0,005087415	0,002105539	-2,416205202	0,015683702	*
HML_High	-0,023278629	0,012836685	-1,813445533	0,069763944	
RMW_Robust	-0,069369257	0,01010442	-6,865239131	6,64841E-12	***
CMA_Aggressive	-0,05009542	0,010582587	-4,733759224	2,20481E-06	***
Observations	369.237				

Fonte: Económica Tabela 5: Resultado de MQO (Fatores de Fama e French)

Variáveis	Coefficientes	std.error	t statistic	p.value	Significância
(Intercept)	0,200165594	0,013390625	14,94818894	1,68141E-50	***
`Duration (DU)`	-1,32805E-05	1,86145E-06	7,134497251	9,73982E-13	***
`VAR % base diária confiança: 95% 1 anos Em moeda orig`	2,5113314	0,067533326	37,18655005	7,3102E-302	***
`Volatilidade base anual 1 anos Em moeda orig_1`	-	0,006845738	37,59803849	0	***
SMB_Small	0,003470944	0,002149077	1,615085796	0,106293354	
Observations	0	0,01027753	-7,84084425	4,49242E-15	***
CMA_Aggressive R-squared	0,049799907	0,010647881	4,676978215	2,91282E-06	***
Observations	254.996				

Fonte: Econômicã Tabela 6: Resultado de MQO (Fatores de Fama e French, Duration, VAR e Volatilidade)

Na primeira regressão (Tabela 4), são utilizadas apenas as variáveis Duration, VAR e Volatilidade para prever o retorno dos ativos. Os resultados indicaram que todas essas variáveis são estatisticamente significativas. A variável Duration apresentou um coeficiente negativo, ; O coeficiente de VAR foi positivo, indicando que um maior risco, conforme medido pelo VAR, está associado a um retorno superior, o que reflete o prêmio exigido pelo mercado para ativos mais arriscados. Já a Volatilidade teve um coeficiente negativo, sugerindo que ativos voláteis são penalizados em termos de retorno, possivelmente devido à assimetria de informação. O valor do R² ajustado desta regressão foi de 0.0059, o que indica uma baixa capacidade explicativa dessas variáveis isoladas para os retornos observados. Apesar disso, o teste F (501.8, com p-valor < 2.2e-16) sugere que o modelo é estatisticamente significativo, indicando que Duration, VAR e Volatilidade contribuem para explicar uma parcela, ainda que pequena, da variabilidade dos retornos.

Na segunda regressão (Tabela 5), são incluídos apenas os fatores de Fama e French: SMB (tamanho), HML (valor), RMW (lucratividade) e CMA (investimento). Esses fatores são ordenados com SMB no percentil 33; HML, RMW e CMA no percentil 50. Os resultados mostram que os fatores RMW e CMA são estatisticamente significativos e têm coeficientes negativos, indicando que empresas mais lucrativas e mais conservadoras em termos de investimento tendem a apresentar retornos menores. O fator de tamanho (SMB) também apresentou significância estatística, no entanto, o fator HML, que representa o efeito de valor, não foi estatisticamente significativo. O R² ajustado para este modelo foi ainda menor, 0.0004, o que reforça a ideia de que esses fatores não capturam bem a variabilidade dos retornos no mercado de crédito isoladamente.

Na terceira regressão (Tabela 6), são combinadas as variáveis específicas do mercado de crédito (Duration, VAR e Volatilidade) com os fatores de Fama e French. Esse modelo completo indicou que Duration, VAR e Volatilidade mantiveram-se significativos e com sinais consistentes com a primeira regressão. Entre os fatores de Fama e French, RMW e CMA continuaram significativos e com coeficientes negativos, sugerindo que empresas lucrativas e conservadoras em termos de investimento apresentam retornos menores. O ajuste do modelo, no entanto, permaneceu baixo, com um R² Ajustado de apenas 0.0065, indicando que, embora algumas variáveis sejam significativas, elas explicam uma pequena parcela da variabilidade dos retornos. O teste F para esse modelo (239.6, com p-valor < 2.2e-16) sugere que o conjunto de variáveis e fatores utilizados contribui para a explicação do retorno, mas a magnitude explicativa é limitada. Isso sugere que, para o mercado de crédito, esses fatores tradicionais e as variáveis específicas de crédito podem não capturar toda a complexidade dos retornos dos ativos analisados.

A baixa consistência do R² nos modelos pode ser explicada pelos desafios inerentes de aplicar a metodologia de fatores, comumente utilizada em ações, no mercado de renda fixa. De acordo com a publicação da BlackRock, "*Factors in Fixed Income? It's (not so) Academic*" (2023), há várias limitações que tornam o uso de fatores menos eficaz e mais complexo no mercado de crédito. Entre os principais desafios estão a falta de dados consistentes e abrangentes, os altos custos de transação, a fragmentação dos ativos e a disponibilidade limitada de títulos, o que dificulta a construção de portfólios com retornos consistentes baseados em fatores.

Esses problemas de dados e a falta de consenso sobre os fatores específicos para a renda fixa limitam o poder explicativo dos modelos, resultando em um R² baixo. Conforme observado no texto, "diferentemente do mercado acionário, onde há uma estrutura de dados sólida e acessível para pesquisa de fatores, o mercado de crédito carece de uma fonte pública robusta de dados históricos confiáveis, o que dificulta a replicação e validação de pesquisas". (BlackRock, 2023).

O cálculo do RMSE (*Root Mean Squared Error*) ou Erro Quadrático Médio foi realizado para avaliar a precisão do modelo de regressão. Para cada ano, foi ajustado um modelo linear com as variáveis independentes Duration, VAR, Volatilidade e os fatores de Fama-French (SMB, HML, RMW e CMA) e calculado o RMSE para a amostra de teste. Os resultados estão evidenciados abaixo na Tabela 7:


	Ano	RMSE
1	2013	0.371
2	2014	0.461
3	2015	0.508
4	2016	0.426
5	2017	0.543
6	2018	0.580
7	2019	0.408
8	2020	0.540
9	2021	0.316
10	2022	0.278
11	2023	0.290
12	2024	0.267

Fonte: Economática Tabela 7: Erro Quadrático Médio por ano

Na tabela, observa-se o RMSE calculado para cada ano, com assíntotas variando entre 0.267 em 2024 a 0.580 em 2018. Em anos como 2024 e 2022, os valores mais baixos de RMSE sugerem que o modelo conseguiu capturar bem a relação entre os fatores e o retorno dos ativos nesses períodos. Já em 2018, o RMSE mais alto pode indicar um maior desvio entre os valores previstos e os valores reais, sugerindo dificuldades do modelo em capturar as flutuações dos retornos nesse ano.

O RMSE na amostra de teste é de 0.334, refletindo a capacidade geral do modelo em prever os retornos dos ativos fora da amostra de treino.

Para a construção da Figura 24 que se trata da dispersão entre os retornos observados e os retornos preditos na amostra de teste, foi utilizada a metodologia de *cross-validation*, conforme descrito por Arlot e Celisse (2010), no artigo, "*A survey of cross-validation procedures for model selection*". O objetivo desta metodologia é separar os dados em amostras de treino e teste para avaliar a capacidade do modelo de forma robusta. No caso deste estudo, foi definido dois terços da amostra como dados de treino e o restante como dados de teste, permitindo uma análise do modelo em dados independentes.



Fonte: Economática Figura 24: Validação Cruzada – Retornos Observados e Preditos

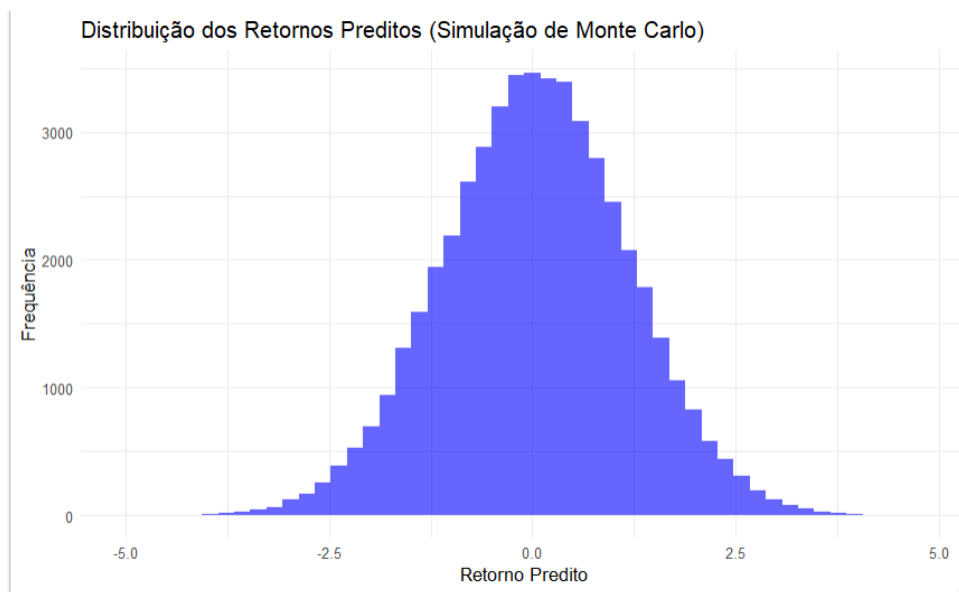
A técnica de *cross-validation* é útil para evitar o problema de *overfitting*, no qual o modelo se ajusta excessivamente aos dados de treino e perde a capacidade de generalização para novos dados. Segundo Arlot e Celisse (2010), o uso de uma amostra de teste ajuda a estimar o risco de generalização do modelo, verificando como ele se comporta em dados não utilizados no ajuste inicial.

A técnica de *cross-validation* auxilia na escolha de um modelo mais robusto ao fornecer uma medida de erro que considera a variação dos dados. No caso desse gráfico, a dispersão dos pontos em torno da linha de identidade evidencia a necessidade de ajustes adicionais no modelo para melhorar a capacidade explicativa, especialmente para valores de retorno distantes da média.

Ainda, como *Backtesting*, foi realizada uma Simulação de Monte Carlo para explicar o retorno com base em fatores de risco, conforme exposto na Tabela 8 (Estatísticas Descritivas) e Figura 25.

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
-4.95871	-0.72381	0.04674	0.04336	0.81039	4.75879

Fonte: Economática Tabela 8: Estatísticas Descritivas da Simulação de Monte Carlo

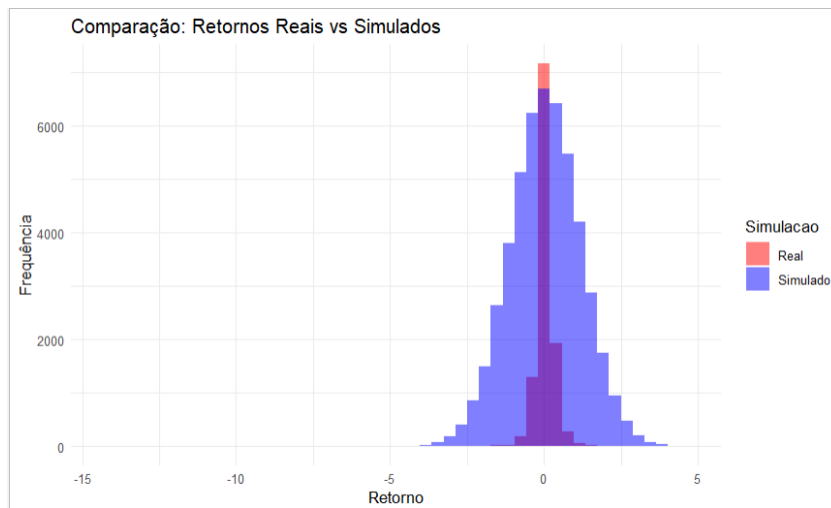


Fonte: Economática Figura 25: Retornos preditos com Simulação de Monte Carlo

Para o *Backtesting*, foram geradas 50.000 simulações de retornos preditos, construídas a partir das distribuições normais de cada variável independente, o que proporciona uma visão robusta de possíveis resultados futuros.

O gráfico de distribuição dos retornos preditos na simulação de Monte Carlo mostra uma forma aproximadamente simétrica, o que sugere uma distribuição normal. A maioria dos retornos simulados se concentra em torno de zero, com uma média próxima a 0,04336, confirmando que o modelo espera um retorno relativamente baixo em média. Esse comportamento é consistente com o que foi previsto pelo modelo linear.

A Figura 26, que compara os retornos reais e simulados, revela que a concentração dos retornos simulados em torno da média é maior. Isso propõe que se pode estar subestimando a variabilidade dos retornos reais, uma vez que mostram uma maior dispersão em torno de zero. Essa diferença pode ser atribuída a fatores exógenos não capturados pelo modelo, como choques de mercado ou eventos econômicos imprevisíveis. O sumário estatístico dos retornos preditos mostra que a mediana está ligeiramente acima de zero (0,04674). O resultado reforça a utilidade do modelo para avaliar retornos esperados e fornecer insights para a tomada de decisão, mas também aponta para a necessidade de ajustes adicionais, caso o objetivo seja capturar com precisão a volatilidade e os extremos observados nos retornos reais.



Fonte: Econom tica Figura 26: Compara o de retornos reais e simulados com Simula o de Monte Carlo


A an lise de regress o, presente no anexo 8.1 deste estudo foi mais eficiente para setores que apresentam maior volatilidade e est o sujeitos a flutua es de mercado. Por exemplo, no setor de Transporte Rodovi rio, a vari vel volatilidade foi significativa com uma estat stica t de -3.64 e p-valor de 0.00027, sugerindo que a oscila o nos retornos est  relacionada com a volatilidade do mercado. Esse setor, sujeito a varia es de demanda e custos, especialmente com oscila o no pre o de combust veis, evidencia o impacto das vari veis de mercado analisadas.

A an lise das deb ntures de acordo com a Lei 12.431 de 2011 contida no Anexo 8.2 revelou diferen as no comportamento dos retornos e na relev ncia dos fatores de estilo. O modelo   mais eficaz em explicar os retornos das deb ntures incentivadas, onde fatores de risco, como duration, volatilidade e VAR, exercem uma influ ncia mais forte e estatisticamente significativa. A diferen a entre os valores de R^2 sugere que as deb ntures incentivadas, associadas a projetos de infraestrutura e setores estrat gicos, possuem retornos mais sens veis. Para as deb ntures incentivadas, o fator VAR apresentou um coeficiente beta positivo de 2,72 com uma estat stica t de 33,97, indicando uma rela o significativa. Esses resultados indicam que as deb ntures incentivadas est o mais expostas a flutua es de mercado. As deb ntures n o incentivadas apresentaram coeficientes de menor magnitude e signific ncia estat stica reduzida. O coeficiente beta para VAR foi de 1,06 com uma estat stica t de 2,97. Esses resultados refletem a menor exposi o das deb ntures n o incentivadas a fatores de estilo, enquanto as deb ntures incentivadas se mostram mais sens veis a varia es de mercado, o que ratifica a complexidade dos projetos financiados por essas deb ntures

A an lise dos erros quadr ticos m dios (RMSE) por setor ao longo dos anos (Anexo 8.3) fornece informa es importantes sobre a baixa precis o do modelo em cada contexto de mercado. Observa-se que setores como Energia el trica e Transporte rodovi rio mantiveram valores de RMSE baixos na maioria dos anos. Al m disso, o Transporte rodovi rio mostra uma tend ncia de melhora na precis o preditiva nos per odos mais recentes, sugerindo que o modelo conseguiu capturar melhor as vari veis relevantes para este setor ao longo do tempo. Em contrapartida, setores como Transporte aqu tico e Transporte a reo refletem maiores erros preditivos.

A an lise dos valores de RMSE entre as deb ntures incentivadas e n o incentivadas de acordo com a Lei 12.431 (Anexo 8.4) revela diferen as na precis o do modelo de previs o de retornos. As deb ntures n o incentivadas apresentaram valores de RMSE mais baixos em compara o com as incentivadas na maioria dos anos analisados, especialmente nos  ltimos per odos. Esse padr o sugere que as caracter sticas das deb ntures n o incentivadas podem ser mais previs veis dentro do modelo atual, talvez por possuirem menos volatilidade ou varia es

estruturais em comparação às incentivadas, que podem estar mais expostas a mudanças de mercado e políticas. Em 2018, por exemplo, o RMSE das debêntures incentivadas foi de 0,617, comparado a 0,367 para as não incentivadas, indicando um desvio expressivo.




Fonte: Economática Figura 27: Validação Cruzada – Retornos Observados e Preditos por Setor

A análise dos gráficos de *cross validation* de retornos observados e preditos para diferentes setores (Figura 27) revela variabilidades consideráveis na precisão dos modelos de previsão entre os setores. Nos setores em que se observa uma dispersão relativamente alta ao longo da linha de tendência ideal, sugere que o modelo apresenta dificuldade em prever com precisão os retornos reais.


No setor de Energia Elétrica, os pontos de retorno observados e preditos estão mais próximos da linha de tendência ideal, indicando uma melhor performance do modelo. No entanto, ainda é possível notar algumas dispersões, o que pode indicar que embora o modelo capture a maior parte da variabilidade dos retornos, ele ainda enfrenta dificuldades com alguns pontos extremos ou com mudanças inesperadas de retorno.

Para o setor de Saneamento, observa-se que a dispersão é mais concentrada em torno da linha de tendência, mas ainda com alguma variabilidade. A performance moderada do modelo neste setor pode ser devida à relativa estabilidade das operações de saneamento.




Fonte: Economática Figura 28: Validação Cruzada – Retornos Observados e Preditos de acordo com a Lei 12.431

Os resultados da validação cruzada para debêntures incentivadas e não incentivadas, segundo a Lei 12.431, conforme demonstrado na Figura 28, mostram que as debêntures não incentivadas, possuem retornos observados centralizados, e os pontos de dispersão estão concentrados, indicando uma menor variação dos retornos em relação ao modelo preditivo. Em contraste, para as debêntures incentivadas, há uma maior variabilidade nos retornos observados, com pontos de dispersão que se estendem em uma faixa maior.



Fonte: Economática Figura 29: Retornos reais e simulados com Simulação de Monte Carlo por Lei 12.431



Fonte: Economática Figura 30: Retornos reais e simulados com Simulação de Monte Carlo por Setor Econômico

Analisando os painéis de Monte Carlo, nas Figuras 29 e 30, observa-se que o modelo não consegue capturar completamente o comportamento dessas debêntures. Entretanto, esse desvio sugere que há variáveis específicas nesses setores, possivelmente relacionadas a fatores econômicos ou de mercado, que não foram totalmente incorporadas no modelo. A análise também evidencia que as debêntures não incentivadas estão sujeitas à menor volatilidade. Essa diferença indica a necessidade de ajustar os modelos para capturar os efeitos de políticas governamentais e incentivos fiscais, que impactam diretamente a performance dos ativos incentivados.

7. Conclusão:

A análise realizada demonstrou resultados significativos em diversos aspectos relacionados aos fatores de risco e suas implicações no mercado brasileiro de debêntures. Primeiramente, os fatores SMB, HML, RMW e CMA mostraram relevância estatística na explicação de retornos, alinhando-se às evidências de estudos, como os de Fama e French (1993) e Soe e Xie (2020). Em particular, o fator RMW, relacionado à lucratividade, destacou-se com coeficientes estatisticamente significativos, indicando que empresas mais robustas apresentam retornos menores no contexto analisado.

Além disso, a inclusão de variáveis específicas como duration, volatilidade e VAR revelaram-se fundamental para capturar características únicas do mercado de renda fixa no Brasil. A análise indicou que essas variáveis possuem impacto significativo nos retornos, como evidenciado pelo coeficiente positivo do VAR e negativo da volatilidade, sugerindo que maior risco tende a ser premiado, enquanto ativos voláteis são penalizados.

Quando analisados os fatores de estilo de Fama e French os resultados indicaram que RMW e CMA são estatisticamente significativos, ambos com coeficientes negativos, o que sugere que empresas mais lucrativas e conservadoras em investimentos tendem a apresentar retornos inferiores. No entanto, os fatores SMB e HML não demonstraram significância robusta em todos os modelos, refletindo a complexidade do mercado de crédito em comparação ao mercado de ações, onde esses fatores são amplamente aplicáveis.

Ao combinar variáveis específicas do mercado de crédito com os fatores de Fama e French, o modelo apresentou melhor capacidade explicativa, com um aumento no valor do R^2 ajustado, embora este ainda se mantenha baixo (0,0065). Isso reflete as limitações de aplicar metodologias tradicionais de *Factor Investing* no mercado de renda fixa, como já discutido na literatura de referência.

A análise por setores revelou que a relevância e significância dos fatores variam conforme a natureza econômica de cada setor. Setores como Energia Elétrica e Transporte Rodoviário apresentaram melhores ajustes, com coeficientes significativos para variáveis de risco, enquanto setores como Transporte Aquático e Transporte Aéreo demonstraram maior dificuldade em capturar os retornos com os fatores utilizados, refletindo características específicas e desafios do modelo.

Na comparação entre debêntures incentivadas e não incentivadas, os resultados mostraram que os fatores de risco têm maior influência nas debêntures incentivadas, como evidenciado pelos coeficientes significativos de VAR e Volatilidade, e valores mais elevados de R^2 ajustado. Isso reflete a maior exposição dessas debêntures a flutuações de mercado e às características dos projetos de infraestrutura associados. Em contrapartida, as debêntures não incentivadas apresentaram menor variabilidade de retornos e valores de RMSE mais baixos, indicando maior previsibilidade no modelo.

A aplicação de validação cruzada e Simulação de Monte Carlo trouxe considerações importantes sobre a capacidade preditiva do modelo. A validação cruzada demonstrou que o modelo possui limitações em capturar com precisão os retornos em determinados períodos e setores, evidenciado pela dispersão dos retornos observados em torno da linha de tendência ideal. Já a Simulação de Monte Carlo indicou que o modelo é capaz de projetar cenários futuros com retornos concentrados em torno de uma média consistente, mas subestima a variabilidade real, especialmente para retornos extremos.

A análise de RMSE por setor e por Lei 12.431 reforçou as diferenças entre os grupos analisados. Setores como Energia Elétrica e Transporte Rodoviário apresentaram menor erro preditivo, enquanto setores como Transporte Aquático e Transporte Aéreo mostraram maiores desafios. Para as debêntures incentivadas, os valores de RMSE foram superiores em comparação às não incentivadas, destacando a maior complexidade e sensibilidade dessas debêntures às variações do mercado e políticas governamentais.

Os resultados também destacaram diferenças importantes entre debêntures incentivadas e não incentivadas. As incentivadas, vinculadas a projetos de infraestrutura, apresentaram maior sensibilidade aos fatores analisados, com retornos mais associados a flutuações de mercado, enquanto as não incentivadas demonstraram maior estabilidade e previsibilidade. Apesar disso, os baixos valores de R^2 indicam que os modelos capturam apenas parcialmente a variabilidade dos retornos, reforçando a complexidade do mercado de crédito privado.

No caso dos setores econômicos, observou-se variações significativas nos coeficientes e níveis de significância dos fatores Duration, VAR, Volatilidade, e dos fatores de estilo SMB (tamanho), HML (valor), RMW (lucratividade) e CMA (investimento). Em setores como energia elétrica, Duration apresentou um coeficiente negativo e significativo, refletindo a sensibilidade desses ativos a mudanças nas taxas de juros. O fator VAR foi consistentemente significativo e positivo em vários setores, como transporte rodoviário e energia elétrica, indicando que um maior risco percebido é associado a retornos mais elevados. A volatilidade, por outro lado, apresentou coeficientes negativos e significativos em diversos setores, como transporte rodoviário, sinalizando que maior instabilidade tende a ser penalizada nos retornos.

Nos setores mais sensíveis, como energia elétrica e saneamento, a inclusão dos fatores de estilo (SMB, HML, RMW e CMA) forneceu proposições adicionais. O fator RMW, relacionado à lucratividade, destacou-se em alguns setores, com coeficientes negativos e significativos, sugerindo que empresas mais robustas em termos de lucratividade tendem a apresentar retornos menores, possivelmente devido ao menor risco associado. Em setores como transporte ferroviário, a CMA (investimento) mostrou impacto marginal, destacando diferenças nas estratégias de crescimento e impacto no retorno.

Ao analisar as debêntures incentivadas e não incentivadas pela Lei 12.431, os resultados apontam para uma maior sensibilidade dos ativos incentivados aos fatores de risco Duration, VAR e Volatilidade, com coeficientes significativos. Duration apresentou coeficiente negativo e significativo para as debêntures incentivadas, enquanto o VAR exibiu impacto positivo relevante, reafirmando que ativos mais arriscados oferecem maior prêmio de risco. A volatilidade continuou a penalizar os retornos, indicando a importância de considerar estabilidade em decisões de investimento.

Para debêntures não incentivadas, os resultados mostram menores coeficientes e níveis de significância para os fatores analisados, o que pode indicar uma maior previsibilidade e estabilidade nesses ativos. O menor R^2 encontrado tanto para incentivadas quanto não incentivadas reflete a complexidade de capturar a variabilidade dos retornos apenas com os fatores analisados, indicando a necessidade de incluir variáveis adicionais, como custos de transação e liquidez, em análises futuras.

Embora os resultados sejam relevantes, há limitações que merecem atenção em trabalhos futuros. A ausência de variáveis relacionadas aos custos de transação e à liquidez pode restringir a capacidade explicativa dos modelos, especialmente em mercados fragmentados como o de renda fixa. A inclusão desses fatores em análises futuras poderia melhorar significativamente a compreensão dos retornos ajustados ao risco, fornecendo uma visão mais completa e prática.

Assim, estudos subsequentes que incorporem esses elementos poderão contribuir para o desenvolvimento de estratégias mais robustas e alinhadas às particularidades do mercado brasileiro.

8. Anexos

8.1 MQO por Setor

Setor NAICS	Variável	Coefficiente	std.error	statistic	p.value	Significancia
Distribuição de gás natural	(Intercept)	0,016635192	0,127513643	0,130458137	0,896209661	
Distribuição de gás natural	`Duration (DU)`	-1,21532E-05	1,90563E-05	-0,637751028	0,523667416	
Distribuição de gás natural	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	4,088830933	4,022805567	1,016412766	0,309486174	
Distribuição de gás natural	`Volatilidade base anual 1 anos Em moeda orig_1`	-	0,411169912	-1,014026691	0,310623198	
Distribuição de gás natural	SMB_Small	0,075650137	0,035455277	2,133677795	0,032921769	*
Distribuição de gás natural	HML_High	-	0,061567728	-0,755038834	0,450264227	
Distribuição de gás natural	RMW_Robust	0,127679565	0,122917802	1,038739412	0,298980388	
Distribuição de gás natural	CMA_Aggressive	-	0,077253228	-0,899972581	0,36818182	
Distribuição de gás natural	R-squared	0,002565186				
Distribuição de gás natural	Number of Variables	7				
Distribuição de gás natural	Sample Size (n)	4621				
Energia elétrica	(Intercept)	0,216625351	0,017937649	12,07657455	1,45162E-33	***
Energia elétrica	`Duration (DU)`	-6,977E-06	2,37567E-06	-2,936851639	0,00331609	**
Energia elétrica	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	3,195030259	0,082715894	38,62655782	0	***
Energia elétrica	`Volatilidade base anual 1 anos Em moeda orig_1`	-	0,00840711	-39,08618657	0	***
Energia elétrica	SMB_Small	0,000959798	0,002339275	0,410297168	0,681588508	
Energia elétrica	HML_High	-	0,01486592	-2,152076978	0,031392754	*
Energia elétrica	RMW_Robust	0,077446222	0,013580418	-5,702786282	1,18067E-08	***
Energia elétrica	CMA_Aggressive	-	0,015137464	-4,276810377	1,89698E-05	***

Energia elétrica	R-squared	0,010368414				
Energia elétrica	Number of Variables	7				
Energia elétrica	Sample Size (n)	163240				
Saneamento	(Intercept)	0,108053752	0,059258493	1,823430654	0,068247192	
		-6,58498E-				
Saneamento	`Duration (DU)`	06	4,44317E-06	-1,482046065	0,138337544	
Saneamento	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	0,607349417	0,645069325	0,941525807	0,346442331	
Saneamento	`Volatilidade base anual 1 anos Em moeda orig_1`	-0,0636119	0,066338624	-0,958896875	0,337617692	
		-				
Saneamento	SMB_Small	0,002413894	0,002915696	-0,827896352	0,407735161	
Saneamento	HML_High	0,064014721	0,060214141	1,063117731	0,287736309	
		-				
Saneamento	RMW_Robust	0,079805394	0,020201975	-3,950375894	7,819E-05	***
Saneamento	CMA_Aggressive	-0,03915448	0,021412847	-1,828550869	0,067475899	
Saneamento	R-squared	0,001411721				
Saneamento	Number of Variables	7				
Saneamento	Sample Size (n)	33158				
Transporte aquático	(Intercept)	-0,03104133	0,237308261	-0,130805941	0,895945329	
Transporte aquático	`Duration (DU)`	6,83798E-05	6,20367E-05	1,102247913	0,270520302	
Transporte aquático	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	0,694638576	1,17324829	0,592064426	0,553891413	
Transporte aquático	`Volatilidade base anual 1 anos Em moeda orig_1`	-	-	-	-	
Transporte aquático		0,076277326	0,131065493	-0,581978708	0,560663321	
		-				
Transporte aquático	SMB_Small	0,012232098	0,030360507	-0,402895065	0,687079451	
		-				
Transporte aquático	HML_High	0,001629354	0,121877363	-0,013368797	0,989335234	
Transporte aquático	RMW_Robust	0,047468876	0,262908786	0,180552642	0,856741683	
Transporte aquático	CMA_Aggressive					
Transporte aquático	R-squared	0,005061335				
Transporte aquático	Number of Variables	6				
Transporte aquático	Sample Size (n)	1601				
Transporte aéreo	(Intercept)	0,239170115	0,065410793	3,656431968	0,000256951	***
Transporte aéreo	`Duration (DU)`	1,66111E-06	1,94548E-05	0,085383241	0,931958281	
Transporte aéreo	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	0,714171825	0,313031904	2,281466574	0,022540001	*
Transporte aéreo	`Volatilidade base anual 1 anos Em moeda orig_1`	-	-	-	-	
Transporte aéreo		0,082304359	0,029760257	-2,765579553	0,005691712	**
Transporte aéreo	SMB_Small					
Transporte aéreo	HML_High					
		-				
Transporte aéreo	RMW_Robust	0,073937765	0,071999769	-1,026916694	0,304482424	
		-				
Transporte aéreo	CMA_Aggressive	0,065480824	0,041847682	-1,564741947	0,117672387	
Transporte aéreo	R-squared	0,006433968				
Transporte aéreo	Number of Variables	5				
Transporte aéreo	Sample Size (n)	10933				
Transporte de gás natural por tubos	(Intercept)	0,141475471	0,217042942	-0,651831707	0,515108541	
Transporte de gás natural por tubos	`Duration (DU)`	0,000167311	0,000153414	1,090591224	0,276502809	

Transporte de gás natural por tubos	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	1044,716434	215,8539983	4,839921623	2,27561E-06	***
Transporte de gás natural por tubos	`Volatilidade base anual 1 anos Em moeda orig_1`	-108,005036	22,31110536	-4,840864416	2,26576E-06	***
Transporte de gás natural por tubos	SMB_Small					
Transporte de gás natural por tubos	HML_High					
Transporte de gás natural por tubos						
Transporte de gás natural por tubos	RMW_Robust	0,066181781	0,139173396	-0,475534713	0,63482113	
Transporte de gás natural por tubos	CMA_Aggressive	0,101613183	0,197631452	0,514154919	0,607597861	
Transporte de gás natural por tubos	R-squared	0,089031956				
Transporte de gás natural por tubos	Number of Variables		5			
Transporte de gás natural por tubos	Sample Size (n)		256			
Transporte ferroviário	(Intercept)	0,229995212	0,038518743	5,970994799	2,43579E-09	***
Transporte ferroviário	`Duration (DU)`	-3,12333E-05	1,00572E-05	-3,105569063	0,001904277	**
Transporte ferroviário	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	2,005225072	1,427705108	1,404509279	0,160197332	
Transporte ferroviário	`Volatilidade base anual 1 anos Em moeda orig_1`	0,202037923	0,146974633	-1,374644858	0,169271406	
Transporte ferroviário						
Transporte ferroviário	SMB_Small	0,001081915	0,012031039	-0,08992697	0,928346993	
Transporte ferroviário	HML_High	0,061426274	0,090035716	0,682243416	0,49510035	
Transporte ferroviário						
Transporte ferroviário	RMW_Robust	0,219402224	0,100670683	-2,17940533	0,029324093	*
Transporte ferroviário						
Transporte ferroviário	CMA_Aggressive	0,020773411	0,070493647	-0,294684873	0,768240544	
Transporte ferroviário	R-squared	0,003888223				
Transporte ferroviário	Number of Variables		7			
Transporte ferroviário	Sample Size (n)		10333			
Transporte fluvial	(Intercept)	0,312737873	0,211507285	1,478615139	0,139777772	
Transporte fluvial						
Transporte fluvial	`Duration (DU)`	0,000110477	0,000209635	-0,526998033	0,598393375	
Transporte fluvial	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	14,28345743	38,5994264	0,370043256	0,71148328	
Transporte fluvial	`Volatilidade base anual 1 anos Em moeda orig_1`	1,440827476	3,980455402	-0,361975536	0,717500138	
Transporte fluvial	SMB_Small					
Transporte fluvial	HML_High	0,52745749	0,251164551	2,100047505	0,036149367	*
Transporte fluvial						
Transporte fluvial	RMW_Robust	0,716815366	0,237195736	-3,022041528	0,00261981	**
Transporte fluvial						
Transporte fluvial	CMA_Aggressive	0,125156057	0,237341854	-0,527324006	0,598167169	
Transporte fluvial	R-squared	0,031275337				
Transporte fluvial	Number of Variables		6			
Transporte fluvial	Sample Size (n)		596			
Transporte rodoviário	(Intercept)	0,152596836	0,042959879	3,552077903	0,000382805	***
Transporte rodoviário		-9,22951E-06				
Transporte rodoviário	`Duration (DU)`	06	6,64025E-06	-1,389933967	0,164559559	

Transporte rodoviário	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	0,975649109	0,272491656	3,580473338	0,00034353	***
Transporte rodoviário	`Volatilidade base anual 1 anos Em moeda orig_1`	0,099885686	0,027446559	-3,639279065	0,000273875	***
Transporte rodoviário	SMB_Small	0,009317245	0,010073243	0,924949918	0,354999627	
Transporte rodoviário	HML_High	0,021357797	0,050728164	0,421024447	0,673740339	
Transporte rodoviário	RMW_Robust	0,066989693	0,038934657	-1,720567191	0,085340019	
Transporte rodoviário	CMA_Aggressive	0,057431283	0,032125569	-1,787712577	0,073832791	
Transporte rodoviário	R-squared	0,001472601				
Transporte rodoviário	Number of Variables	7				
Transporte rodoviário	Sample Size (n)	29116				
Transporte turístico	(Intercept)	0,077281371	0,126192224	0,612409927	0,540505768	
Transporte turístico	`Duration (DU)`	0,000145282	6,79772E-05	2,137217075	0,032996491	*
Transporte turístico	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	17,66070616	19,929203	-0,886172225	0,375890736	
Transporte turístico	`Volatilidade base anual 1 anos Em moeda orig_1`	1,801876536	2,042318924	0,882269911	0,377995106	
Transporte turístico	SMB_Small					
Transporte turístico	HML_High	-0,00595237	0,086736307	-0,068626047	0,945310856	
Transporte turístico	RMW_Robust					
Transporte turístico	CMA_Aggressive	0,001930502	0,149570085	0,012907006	0,989706408	
Transporte turístico	R-squared	0,008477583				
Transporte turístico	Number of Variables	5				
Transporte turístico	Sample Size (n)	588				
Transporte urbano	(Intercept)	0,071367583	0,152561056	0,467796862	0,640115505	
Transporte urbano	`Duration (DU)`	0,000135688	0,00016585	-0,818138233	0,413633208	
Transporte urbano	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	135,190816	51,97790641	2,600928459	0,009547804	**
Transporte urbano	`Volatilidade base anual 1 anos Em moeda orig_1`	13,95875648	5,386414306	-2,591474715	0,009810823	**
Transporte urbano	SMB_Small					
Transporte urbano	HML_High					
Transporte urbano	RMW_Robust	0,021647584	0,147723636	65411	0,883548041	
Transporte urbano	CMA_Aggressive					
Transporte urbano	R-squared	0,019243792				
Transporte urbano	Number of Variables	4				
Transporte urbano	Sample Size (n)	554				

8.2 MQO por Lei 12.431

Lei	Variável	Coefficiente	std.error	statistic	p.value	Significancia
12.431	(Intercept)	0,083922625	0,011780213	7,124033076	1,05786E-12	***
Não	`Duration (DU)`	1,06265E-06	2,36222E-06	0,449851726	0,652818704	
Não	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	1,067804846	0,358996351	2,974416991	0,002936426	**
Não	`Volatilidade base anual 1 anos Em moeda orig_1`	-	-	-	-	
Não	SMB_Small	-0,001511159	0,001452466	1,040705739	0,298015613	
Não	HML_High	0,004229746	0,011386828	0,371459558	0,710296359	
Não	RMW_Robust	0,012762198	0,009578509	-1,33237833	0,182740092	
Não	CMA_Aggressive	0,014322321	0,008844122	1,619416948	0,105361937	
Não	R-squared	0,000614857				
Não	Number of Variables	7				
Não	Sample Size (n)	72430				
Sim	(Intercept)	0,248272053	0,017745671	13,99057004	1,8766E-44	***
Sim	`Duration (DU)`	-1,57745E-05	2,31531E-06	6,813132482	9,57903E-12	***
Sim	`VAR % base diária confiança: 95% 1 anos Em moeda orig`	2,723233065	0,080154354	33,97486134	3,2338E-252	***
Sim	`Volatilidade base anual 1 anos Em moeda orig_1`	0,276755771	0,008069048	34,29844199	5,481E-257	***
Sim	SMB_Small	0,000649399	0,002854129	0,227529557	0,820012243	
Sim	HML_High	0,031803468	0,016885092	-1,88352352	0,059631044	
Sim	RMW_Robust	0,098467074	0,014703277	6,696947552	2,13431E-11	***
Sim	CMA_Aggressive	0,085445722	0,015029143	5,685335572	1,30754E-08	***
Sim	R-squared	0,007547105				
Sim	Number of Variables	7				
Sim	Sample Size (n)	182566				

8.3 RMSE por setor por ano:

Ano	Setor	RMSE
2013	Energia elétrica	0,393785235
2013	Transporte rodoviário	0,298362948
2014	Energia elétrica	0,454436618
2014	Transporte rodoviário	0,465268868
2015	Energia elétrica	0,515398726
2015	Transporte aéreo	0,503119458
2015	Transporte rodoviário	0,49764462
2016	Energia elétrica	0,447958345
2016	Transporte aéreo	0,381156197
2016	Transporte ferroviário	0,533358701
2016	Transporte rodoviário	0,431946316
2017	Energia elétrica	0,4116499
2017	Transporte aéreo	0,390656073
2017	Transporte ferroviário	0,411314145
2017	Transporte rodoviário	0,859273781
2018	Distribuição de gás natural	0,297320439
2018	Energia elétrica	0,351362664
2018	Transporte aéreo	0,355810716
2018	Transporte ferroviário	0,332671695
2018	Transporte rodoviário	1,11007029
2019	Distribuição de gás natural	0,325564436
2019	Energia elétrica	0,269787237
2019	Transporte aéreo	0,347253625
2019	Transporte ferroviário	0,212356938
2019	Transporte rodoviário	0,795615859
2020	Distribuição de gás natural	0,562147216
2020	Energia elétrica	0,55485355
2020	Saneamento	0,370845502
2020	Transporte aquático	0,032361378
2020	Transporte aéreo	0,560938857
2020	Transporte ferroviário	0,402327375
2020	Transporte rodoviário	0,494106701
2021	Distribuição de gás natural	0,257714774
2021	Energia elétrica	0,331006886

2021	Saneamento	0,25959104
2021	Transporte aquático	0,020087053
2021	Transporte aéreo	0,316521476
2021	Transporte ferroviário	0,371722164
2021	Transporte rodoviário	0,235690862
2022	Distribuição de gás natural	0,277285585
2022	Energia elétrica	0,289129885
2022	Saneamento	0,232523944
2022	Transporte aquático	0,01099466
2022	Transporte aéreo	0,23541329
2022	Transporte ferroviário	0,364155761
2022	Transporte rodoviário	0,23891993
2022	Transporte turístico	0,043836588
2023	Distribuição de gás natural	0,253111907
2023	Energia elétrica	0,315632771
2023	Saneamento	0,200451663
2023	Transporte aquático	0,580673414
2023	Transporte aéreo	0,185489065
2023	Transporte de gás natural por tubos	0,008449905
2023	Transporte ferroviário	0,276672734
2023	Transporte fluvial	0,293263129
2023	Transporte rodoviário	0,230642337
2023	Transporte turístico	0,278129505
2023	Transporte urbano	0,244027849
2024	Distribuição de gás natural	0,239963172
2024	Energia elétrica	0,268378022
2024	Saneamento	0,194898493
2024	Transporte aquático	0,268762114
2024	Transporte aéreo	0,965078462
2024	Transporte de gás natural por tubos	0,137592119
2024	Transporte ferroviário	0,238690364
2024	Transporte fluvial	0,274963231
2024	Transporte rodoviário	0,217583005
2024	Transporte turístico	0,097111424
2024	Transporte urbano	0,141757668

8.4 RMSE por Lei 12.431 por ano:

Lei 12.431	Ano	RMSE
Não	2013	0,382281
Sim	2013	0,258994
Não	2014	0,454187
Sim	2014	0,47236
Não	2015	0,50464
Sim	2015	0,508858
Não	2016	0,439801
Sim	2016	0,420192
Não	2017	0,416255
Sim	2017	0,574919
Não	2018	0,367139
Sim	2018	0,617968
Não	2019	0,185331
Sim	2019	0,435243
Não	2020	0,381528
Sim	2020	0,56731
Não	2021	0,164226
Sim	2021	0,350147
Não	2022	0,105285
Sim	2022	0,318253
Não	2023	0,089989
Sim	2023	0,344674
Não	2024	0,077446
Sim	2024	0,324115

9. REFERÊNCIAS BIBLIOGRÁFICAS

1. ARLOT, S.; CELISSE, A. A survey of cross-validation procedures for model selection. **Statistics Surveys**, v. 4, p. 40–79, 2009.
2. ARMEANU, Dan; BĂLU, Florentina-Olivia; OBREJA, Carmen. Interest rate risk management using duration gap methodology. **Managerial Finance**, v. 34, n. 9, p. 620-632, mar. 2008.
3. BANZ, Rolf W. The relationship between return and market value of common stocks. **Journal of Financial Economics**, v. 9, n. 1, p. 3-18, Mar. 1981.
4. BEKTIĆ, Demir et al. Extending Fama–French Factors to Corporate Bond Markets. **Managerial Finance**, v. 34, n. 9, p. 620-632, jul. 2017.
5. BLACKROCK. Factors in Fixed Income? It's (not so) Academic. BlackRock, 2023. Disponível em: <https://www.blackrock.com>. Acesso em: [15/05/2024].
6. DE BONDT, Werner; THALER, Richard. Does the stock market overreact? **The Journal of Finance**, v. 40, n. 3, p. 793-805, Jul. 1985.
7. ELTON, Edwin J.; GRUBER, Martin J.; BROWN, Stephen J.; GOETZMANN, William N. **Modern Portfolio Theory and Investment Analysis**. 6. ed. John Wiley & Sons, 2001.
8. FAMA, Eugene F.; FRENCH, Kenneth R. Common risk factors in the returns on stocks and bonds. **Journal of Financial Economics**, v. 33, n. 1, p. 3-56, fev. 1993.
9. HARVEY, Campbell R. We are All Quants. The New Era of Systematic Investing. Outubro de 2023. Disponível em: <https://www.researchaffiliates.com>. Acesso em: [15/05/2024].
10. HOUWELING, Patrick; VAN ZUNDT, Jeroen. Factor investing in the corporate bond market. **Financial Analysts Journal**, v. 70, n. 4, p. 63-80, 2014.
11. JACOBY, Gady; GOTTESMAN, Aron A.; FOWLER, David J. Asset Pricing and the Bid-Ask Spread. Asper School of Business, University of Manitoba; Molson School of Business, **Concordia University**; **Schulich School of Business, York University**. Disponível em: <https://link.aip.org/link>. Acesso em: [14/05/2024].
12. MARKOWITZ, Harry. Portfolio Selection. **The Journal of Finance**, v. 7, n. 1, p. 77-91, mar. 1952.
13. ROSS, Stephen A. The Arbitrage Pricing Theory (APT). **Journal of Economic Theory**, v. 13, n. 3, p. 341-360, Dez. 1976.
14. SHARPE, William F. Capital asset prices: A theory of market equilibrium under conditions of risk. **Journal of Finance**, v. 19, n. 3, p. 425-442, set. 1964.

15. SHILLER, Robert J. Do Stock Prices Move Too Much to Be Justified by Subsequent Changes in Dividends? **American Economic Review**, v. 71, n. 3, p. 421-436, Jun. 1981.
16. SOE, Aye M.; XIE, Hong. Factor-Based Investing in Fixed Income: A Case Study of the U.S. Investment-Grade Corporate Bond Market. Jan. 2016.