

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE CIÊNCIAS ECONÔMICAS
DEPARTAMENTO DE ECONOMIA E RELAÇÕES INTERNACIONAIS**

MARIANA STIGGER MOREIRA FORTES DA SILVA

**L2 BOOSTING: UMA ABORDAGEM EM MACHINE LEARNING PARA PREVISÃO
DE TAXAS DE INFLAÇÃO**

Porto Alegre

2024

MARIANA STIGGER MOREIRA FORTES DA SILVA

**L2 BOOSTING: UMA ABORDAGEM EM MACHINE LEARNING PARA PREVISÃO
DE TAXAS DE INFLAÇÃO**

Trabalho de conclusão submetido ao Curso de Graduação em Ciências Econômicas da Faculdade de Ciências Econômicas da UFRGS, como requisito parcial para obtenção do título Bacharel em Economia.

Orientador: Prof. Dr. Hudson da Silva Tor-
rent

Porto Alegre

2024

CIP - Catalogação na Publicação

Silva, Mariana Stigger Moreira Fortes da
L2 Boosting: uma abordagem em Machine Learning para
previsão de taxas de inflação / Mariana Stigger
Moreira Fortes da Silva. -- 2024.
50 f.
Orientador: Hudson da Silva Torrent.

Trabalho de conclusão de curso (Graduação) --
Universidade Federal do Rio Grande do Sul, Faculdade
de Ciências Econômicas, Curso de Ciências Econômicas,
Porto Alegre, BR-RS, 2024.

1. Boosting. 2. Econometria. 3. Previsão da
inflação. 4. Séries temporais macroeconômicas. I.
Torrent, Hudson da Silva, orient. II. Título.

MARIANA STIGGER MOREIRA FORTES DA SILVA

**L2 BOOSTING: UMA ABORDAGEM EM MACHINE LEARNING PARA PREVISÃO
DE TAXAS DE INFLAÇÃO**

Trabalho de conclusão submetido ao Curso de Graduação em Ciências Econômicas da Faculdade de Ciências Econômicas da UFRGS, como requisito parcial para obtenção do título Bacharel em Economia.

Aprovado em: Porto Alegre, 14 de agosto de 2024.

BANCA EXAMIDORA:

Prof. Dr. Hudson da Silva Torrent – Orientador
UFRGS

Prof. Dr. Jorge Paulo de Araújo
UFRGS

Prof. Dr. Sabino da Silva Pôrto Júnior
UFRGS

AGRADECIMENTOS

Com a conclusão deste trabalho de conclusão de curso, o alívio lentamente dá lugar à saudade dos corredores da Faculdade de Ciências Econômicas. É impossível não olhar para trás e valorizar cada momento vivido através de uma nova perspectiva. Acima de tudo, diversas pessoas tornaram essa jornada memorável e especial.

Minha gratidão vai, primeiramente, para meus pais, cujo sacrifício e encorajamento foram inabaláveis em meio às intercorrências de saúde e que sempre tiveram a sensibilidade de estimular minha curiosidade intelectual desde a infância.

Aos meus amigos, que foram parceiros de tantas aventuras acadêmicas e pessoais, agradeço profundamente. As memórias criadas no convívio fizeram essa trajetória valer a pena. A saber, agradeço a Gustavo Cassenott, com quem tive o prazer de compartilhar a passagem da adolescência à fase adulta. Agradeço também a Eliandro Junior pelas inúmeras caronas e pela companhia inseparável.

Um agradecimento especial ao meu orientador, Hudson da Silva Torrent, cujo conhecimento, serenidade e iluminação foram cruciais para o desenvolvimento deste projeto e para minha formação.

Por fim, minha gratidão se estende a todos aqueles que, direta ou indiretamente, contribuíram para a construção deste momento. Esse grupo inclui os professores Jorge Paulo de Araújo e Sabino da Silva Pôrto Júnior, que tive a honra de ter em minha banca de defesa, bem como todo o corpo docente e de funcionários da faculdade, além do CNPq, responsável pela bolsa de iniciação científica que deu origem a este trabalho.

“[...] I have insisted that econometrics must have relevance to concrete realities, otherwise it degenerates into something which is not worthy of the name econometrics, but ought rather to be called *playometrics*.” (FRISCH. *In*: ELTIS; SCOTT; WOLFE, 1970, p. 163).

RESUMO

No contexto de séries temporais contendo grande número de variáveis preditoras em potencial, a metodologia de *boosting* pode ser empregada para seleção das variáveis mais importantes. O presente trabalho buscou avaliar a performance de um modelo L2 *boosting* para a previsão das inflações alemã e britânica. Partindo de 18 variáveis independentes para a economia alemã e 19 para a economia britânica, os regressores em potencial englobaram 12 lags para cada variável e 12 termos autorregressivos para a própria variável dependente. Foram realizadas previsões fora da amostra para o período compreendido entre 2007-2017 para a Alemanha e 2004-2014 para o Reino Unido. A precisão do algoritmo de *boosting* foi avaliada contra três benchmarks: o passeio aleatório (RW), o modelo autorregressivo (AR) e o modelo autorregressivo de médias móveis (ARMA). Os resultados evidenciaram que o L2 *boosting* apresentou o menor RMSE para todos os horizontes de previsão no caso da Alemanha e para a maior parte dos horizontes na análise do Reino Unido, assim como as melhores estatísticas MAE e MAD, que são robustas para outliers. Contudo, somente no caso da Alemanha os modelos apresentaram diferença de capacidade preditiva estatisticamente significativa conforme o teste de Giacomini-White.

Palavras-chave: *Boosting*. Econometria. Previsão da inflação. Séries temporais macro-econômicas.

ABSTRACT

In the context of time series containing a large number of potential predictor variables, the boosting methodology can be employed for selecting the most important variables. The present study aimed to evaluate the performance of an L2 boosting model for forecasting German and British inflation. Starting with 18 independent variables for the German economy and 19 for the British economy, the potential regressors included 12 lags for each variable and 12 autoregressive terms for the dependent variable itself. Out-of-sample forecasts were made for the period from 2007 to 2017 for Germany and from 2004 to 2014 for the United Kingdom. The accuracy of the boosting algorithm was evaluated against three benchmarks: the random walk (RW), the autoregressive model (AR), and the autoregressive moving average model (ARMA). The results showed that L2 boosting had the lowest RMSE for all forecast horizons in the case of Germany and for most horizons in the UK analysis, as well as the best MAE and MAD statistics, which are robust to outliers. However, only in the case of Germany did the models show a statistically significant difference in predictive ability according to the Giacomini-White test.

Keywords: Boosting. Econometrics. Inflation forecasting. Macroeconomic time series.

LISTA DE FIGURAS

Figura 1 – Alemanha: AR, previsão fora da amostra (2007-2017)	28
Figura 2 – Alemanha: ARMA, previsão fora da amostra (2007-2017)	28
Figura 3 – Alemanha: L2, previsão fora da amostra (2007-2017).....	29
Figura 4 – Alemanha: CSFE, $h = 1:4$, <i>Boosting</i> vs. AR	31
Figura 5 – Alemanha: CSFE, $h = 5:8$, <i>Boosting</i> vs. AR	31
Figura 6 – Alemanha: CSFE, $h = 9:12$, <i>Boosting</i> vs. AR	32
Figura 7 – Reino Unido: AR, previsão fora da amostra (2004-2014)	36
Figura 8 – Reino Unido: ARMA, previsão fora da amostra (2004-2014)	36
Figura 9 – Reino Unido: L2, previsão fora da amostra (2004-2014)	37
Figura 10 – Reino Unido: CSFE, $h = 1:4$, <i>Boosting</i> vs. AR	38
Figura 11 – Reino Unido: CSFE, $h = 5:8$, <i>Boosting</i> vs. AR	39
Figura 12 – Reino Unido: CSFE, $h = 9:12$, <i>Boosting</i> vs. AR	39

LISTA DE TABELAS

Tabela 1 – Medidas de performance: Alemanha, 2007-2017	25
Tabela 2 – Precisão preditiva: Alemanha, 2007-2017	26
Tabela 3 – Alemanha: Razões de RMSE, MAE e MAD (2007-2017)	26
Tabela 4 – Teste de Giacomini-White: Alemanha, <i>Boosting</i> vs. AR	27
Tabela 5 – Medidas de performance: Reino Unido, 2004-2014	33
Tabela 6 – Precisão preditiva: Reino Unido, 2004-2014	34
Tabela 7 – Reino Unido: Razões de RMSE, MAE e MAD (2004-2014)	34
Tabela 8 – Teste de Giacomini-White: Reino Unido, <i>Boosting</i> vs. AR	35

SUMÁRIO

1	INTRODUÇÃO	11
2	REVISÃO DE LITERATURA	13
3	METODOLOGIA	20
3.1	ALGORITMO DE <i>BOOSTING</i>	20
3.2	BENCHMARKS	21
3.3	MEDIDAS DE PERFORMANCE	21
4	DADOS	23
5	RESULTADOS	24
5.1	ALEMANHA.....	24
5.2	REINO UNIDO	33
6	CONCLUSÃO	40
	REFERÊNCIAS	41
	BIBLIOGRAFIA CONSULTADA	44
	APÊNDICE A – ALEMANHA: VARIÁVEIS E TRANSFORMAÇÕES	47
	APÊNDICE B – REINO UNIDO: VARIÁVEIS E TRANSFORMAÇÕES	49

1 INTRODUÇÃO

Boas estimativas inflacionárias são úteis tanto a firmas quanto a formuladores de políticas econômicas, visto que muitos contratos são celebrados em termos nominais e que os elaboradores de políticas dependem de previsões certas para guiar a política monetária e ancorar as expectativas dos agentes. A longo prazo, erros de previsão sistemáticos podem minar a credibilidade dos bancos centrais, por exemplo, e, conseqüentemente, sua força de manobra.

Ben Bernanke, então presidente da Reserva Federal dos Estados Unidos, explicou em uma de suas famosas palestras sobre economia monetária que a inflação injeta ruído no sistema de preços, torna o planejamento financeiro de longo prazo mais complexo e interage de formas perversas com regras de taxaço e de contabilidade indexadas imperfeitamente (BERNANKE, 2007). No curto-para-médio prazo, a manutenção da estabilidade de preços ajuda a evitar o padrão das políticas monetárias *stop-go*; no longo prazo, promove crescimento, eficiência e estabilidade.

Nesse sentido, as expectativas dos agentes são de suma importância, pois as decisões econômicas contêm uma dimensão intertemporal tal que as escolhas contemporâneas dependem das percepções dos agentes acerca dos resultados econômicos futuros (COIBION; GORODNICHENKO; KAMDAR, 2018, p. 1447). Em outras palavras, as expectativas inflacionárias, ao influenciarem as decisões de consumo, investimento, preços e salários, acabam por afetar a inflação real observada.

Para a ancoragem das expectativas, traçar projeções é essencial. Como pontuado por Bernanke (2007), elas são a matéria prima através da qual os bancos centrais ao redor do globo definem como irão conduzir a política monetária. Aqui entra o papel dos modelos econométricos e do machine learning, que vêm sendo cada vez mais empregado na econometria por uma série de razões. Em primeiro lugar, sua capacidade de lidar com um grande volume de dados permite incluir uma infinidade de variáveis econômicas como elementos explicativos, proporcionando riqueza e complexidade aos modelos. Além disso, é capaz de identificar padrões e relações complexas nos dados que podem passar despercebidos pelos modelos econômicos tradicionais, permitindo a descoberta de informações valiosas e insights que podem melhorar as previsões.

Ng (2014) exemplifica como essas características podem ser empregadas pelo *boosting*. Embora o algoritmo tenha gerado falsos positivos por vezes, o método de

seleção das variáveis, que englobavam 1500 preditores em potencial, foi interessante: a grande surpresa foi a importância dada à variável que mensura o emprego em minas, em geral pouco lembrada na análise dos ciclos de negócios (NG, 2014, p. 18).

Alguns artigos que também empregaram algoritmos de *boosting*, dessa vez com melhores resultados, foram Robinzonov, Tutz e Hothorn (2012), Yoon (2021) e Lindenmeyer, Skorin e Torrent (2021). O projeto que se pretende desenvolver aqui segue na mesma linha, visando testar a precisão de um modelo *component-wise boosting* para a previsão das taxas de inflação da Alemanha de 2007-2017 e do Reino Unido de 2004-2014 frente a três benchmarks: o modelo autorregressivo (AR), o modelo autorregressivo de médias móveis (ARMA) e o passeio aleatório (RW). Para esse fim, foi utilizada a biblioteca “mboost” da linguagem de programação R, desenvolvida em Hothorn, Bühlmann, Kneib, Schmid e Hofner (2011). Todos os códigos elaborados podem ser encontrados em repositório do Github¹.

Os modelos foram comparados de acordo com as estatísticas RMSE (raiz do erro quadrático médio), MAE (erro médio absoluto) e MAD (desvio médio absoluto). Ademais, o teste de Giacomini-White foi utilizado para corroborar os resultados e foram elaborados gráficos para visualização dos *cumulative squared forecast errors* (CSFE) de Welch e Goyal (2008).

O trabalho está organizado da seguinte forma: o capítulo 2 apresenta a revisão da literatura; o capítulo 3 expõe a metodologia de aplicação do algoritmo e dos benchmarks, bem como a metodologia por trás das medidas de performance; o capítulo 4 descreve os dados e as transformações aplicadas a eles; o capítulo 5 exhibe os resultados do estudo; finalmente, o capítulo 6 conclui com uma discussão geral dos resultados obtidos.

¹ <https://github.com/stiggerfortes/tcc>

2 REVISÃO DE LITERATURA

Em matéria de projeções inflacionárias, um artigo clássico é o de Stock e Watson (1999), no qual os autores avaliaram a performance de diversos modelos, em especial dois baseados em curvas de Phillips modificadas: o primeiro, utilizando taxas defasadas de desemprego para prever mudanças futuras na taxa de inflação; o segundo, fazendo uso de um leque mais amplo de variáveis econômicas para traçar previsões, leque esse denominado pelos autores de índice de atividade (STOCK; WATSON, 1999).

Seguindo nessa via, os estudos levados a cabo na Economia passaram a englobar um número cada vez maior de variáveis explicativas. Tornou-se essencial, portanto, que os modelos econométricos avançassem o suficiente para permitir lidar com bases de dados de alta dimensionalidade, aquelas nas quais o número de regressores é grande, por vezes chegando a superar o número de observações na amostra.

Em tais condições, é comum utilizar modelos de fatores que capturam a influência de um conjunto de variáveis latentes, ditas fatores ou componentes principais, sobre as variáveis observáveis. A ideia central é que as variáveis observáveis podem ser modeladas como uma combinação linear dos fatores, em conjunto com um termo de erro que captura a variação específica de cada variável. Essa abordagem permite reduzir a dimensionalidade dos dados. No entanto, “o alto nível de agregação dos modelos de fatores, que têm estado entre os modelos mais populares para a previsão macroeconômica, não é adequado” (MEDEIROS; VASCONCELOS; VEIGA; ZILBERMAN, 2021, p. 99, tradução nossa). De fato, das três classes de modelos de machine learning empregadas pelos pesquisadores - *adaLASSO*, Ridge Regression e Random Forest -, nenhuma apontou os fatores como variáveis explicativas relevantes.

Outra forma de lidar com dados de alta dimensionalidade é utilizando *boosting*. Em machine learning, o método de *ensemble* consiste em combinar vários modelos chamados de “modelos fracos” (“*weak learners*”) ou “modelos base” (“*base learners*”) para criar um modelo mais robusto. Essencialmente,

Ensembles são um método de machine learning que combina as previsões de múltiplos modelos no esforço de atingir uma melhor performance preditiva. Existem muitos tipos diferentes de *ensembles*, embora todas as abordagens possuam duas propriedades-chave: elas requerem que os modelos contribuintes sejam diferentes para que produzam erros diferentes e suas previsões possam ser combinadas na tentativa

de aproveitar o que cada modelo faz bem. (BROWNLEE, 2021, p. 14, tradução nossa).

Existem três formas principais de combinar modelos: *bagging*, *stacking* e *boosting*. O Random Forest, já estabelecido no campo do machine learning e estudado por Medeiros, Vasconcelos, Veiga e Zilberman (2021), é um exemplo de *ensemble* que utiliza *bagging*. Por outro lado, a categoria do *boosting* lida com modelos base que buscam contrabalançar os erros dos modelos base de iterações anteriores; por isso, se diz que executa um aprendizado componente a componente (*component-wise boosting*) à medida em que itera.

Nesse sentido, o presente projeto visa preencher uma grave lacuna de pesquisa: embora os algoritmos preditivos de machine learning venham ganhando força na Economia, poucos estudos se concentraram especificamente na aplicação do L2 *boosting* para esse fim. De fato, em artigos recentes como o de Araujo e Gaglianone (2023) sobre os métodos mais novos de machine learning, o algoritmo sequer figura.

Para que se possa entender como o L2 *boosting* nasceu, antes é necessário compreender o surgimento da metodologia geral de *boosting*. O primeiro *boosting* a surgir foi o AdaBoost, introduzido em Schapire (1990), Freund (1995) e Freund e Schapire (1996) para produzir resultados binários fora do campo da Economia. Posteriormente, Breiman (1998) observou que a base matemática do AdaBoost poderia torná-lo aplicável não apenas a problemas de classificação, mas também a problemas de regressão. Friedman (2001) foi o primeiro a adaptar o método para uso em regressões com o auxílio de uma função de perda denominada L2, computada a partir da diferença elevada ao quadrado entre os dados reais da amostra e as previsões do modelo - daí o nome L2 *boosting*. Contudo, ainda não era possível utilizá-lo com bancos de dados de alta dimensionalidade.

Sabe-se que, quando o número de variáveis regressoras excede o número de observações na amostra, modelos estatísticos clássicos como mínimos quadrados ordinários (MQO) não podem ser aplicados. Afinal, nessas condições, tem-se uma matriz com mais colunas do que linhas, o que resulta em um sistema com mais incógnitas do que equações, que não admite solução única.

Assim sendo, Bühlmann e Yu (2003) adaptaram o L2 *boosting* concebido por

Friedman para efetuar uma pré-seleção das variáveis mais importantes. Resumidamente, isso significa que o algoritmo opera da seguinte maneira: na primeira iteração, calcula-se o resíduo como a diferença elevada ao quadrado entre os valores reais da variável dependente e sua média; em seguida, regride-se o resíduo como variável dependente sobre cada variável preditora em potencial, selecionando a que gerar a menor soma dos quadrados dos resíduos; por fim, cria-se uma nova previsão, que levará a um novo resíduo dado pela diferença elevada ao quadrado entre os valores reais da variável dependente e tal previsão; e assim sucessivamente. A cada iteração, o próximo modelo é treinado para prever os resíduos do modelo anterior. Dessa forma, o propósito do algoritmo é fazer com que cada modelo foque onde os anteriores tiveram mais dificuldade. Resumidamente, “o L2 *boosting* nada mais é senão mínimos quadrados ajustados repetitivamente aos resíduos” (BÜHLMANN; YU, 2003, p. 326, tradução nossa).

Mais tarde, Schmid e Hothorn (2008) lançaram mão do L2 *boosting* com modelos de *splines* penalizados como *base learners*. A função dos P-Splines ou *splines* penalizados é dividir as variáveis independentes em segmentos e ajustar, a cada segmento, uma função chamada *spline* natural, que é uma combinação linear de funções de base. Por sua vez, as funções de base são funções matemáticas pré-definidas, geralmente polinômios cúbicos. A penalização é introduzida para controlar o formato da curva: a ideia é penalizar as derivadas de ordem superior da curva para torná-la mais suave. O resultado, quando plotado em um gráfico, são curvas suaves que se ajustam aos dados observados. Essa tática transforma o L2 *boosting*, tradicionalmente trabalhado com *base learners* lineares, em um método com *base learners* não lineares. Novamente, destacou-se a aplicabilidade do *boosting* a bancos de dados de alta dimensionalidade:

[...] quando o número de covariáveis p em um banco de dados é grande (e quando selecionar um pequeno número de covariáveis relevantes é desejável), o *boosting* geralmente é superior a técnicas tradicionais de estimação para modelos de regressão (como regressão linear *stepwise*, que, por exemplo, não pode ser aplicada se p é maior do que o número de observações n). (SCHMID; HOTHORN, 2008, p. 298, tradução nossa).

Finalmente, o mecanismo de seleção de preditores foi aproveitado pela primeira

vez no contexto de séries temporais em Bai e Ng (2009):

Assim, em contraste com MQO, que toma um passo ambicioso em direção ao modelo final, o *boosting* faz vários pequenos ajustes, onde ‘ambicioso’ significa que, a cada passo, a função que leva à maior redução do erro é adicionada ao estimador. A capacidade do *boosting* de resistir ao sobreajuste dos dados está relacionada a essa abordagem em estágios para ajustar o modelo. (BAI; NG, 2009, p. 611, tradução nossa).

Dessa maneira, chegou-se ao L2 *boosting* atual: adaptado para grandes bancos de dados, para séries temporais e podendo ser usado com funções lineares e não lineares.

A seleção de regressores foi testada, também, em artigo mais recente de Lindemeyer, Skorin e Torrent (2021), no qual os pesquisadores buscaram testar a validade do L2 *boosting* como instrumento de previsão para o consumo de energia elétrica no período compreendido entre setembro de 2014 e outubro de 2017 no estado do Rio Grande do Sul.

O trabalho empregou 190 observações e 822 variáveis explicativas divididas entre quatro categorias: internacionais, nacionais, meteorológicas e regionais. O período de análise coincide com a crise política e econômica de 2015 que culminou no impeachment de Dilma Rousseff em 2016. Os dados foram compilados, dentre outras fontes, a partir do Federal Reserve Economic Data (FRED).

Usando 12 lags para as variáveis explicativas, concluiu-se que o L2 *boosting* foi capaz de selecionar variáveis associadas à crise de 2015 e de compreender melhor a mudança na trajetória da tendência do que o modelo SARIMA empregado como benchmark. Descobriram-se três conjuntos de preditores especialmente relevantes: I) os lags da própria variável dependente, que servem para modelar a sazonalidade da série; II) os lags do consumo de energia elétrica em todo o país, responsáveis por atualizar o modelo com as mudanças mais recentes no consumo; III) as taxas de desemprego, diretamente relacionadas com o período da crise.

Dessa forma, o L2 *boosting* se mostrou uma ferramenta útil para a seleção das variáveis explicativas mais relevantes e, portanto, eficaz no tratamento do banco de dados de alta dimensionalidade.

Essa conclusão vai ao encontro do trabalho de Luo e Spindler (2017). Nele, os pesquisadores buscaram estimar a influência da proteção de direitos de propriedade, medida pelas decisões sobre desapropriações do Tribunal Federal de Apelações, sobre o produto interno bruto americano. O parâmetro de interesse representava o efeito de uma decisão adicional a favor da propriedade individual, interpretada como direitos de propriedade individual mais fortes (LUO; SPINDLER, 2017, p. 272).

A análise foi dificultada pela possível presença de endogeneidade entre as decisões jurídicas e as variáveis econômicas, o que tornou necessária a implementação de variáveis instrumentais. A seleção de tais variáveis instrumentais foi deixada a cargo do L2 *boosting*. Conforme os autores reportam, o algoritmo de *boosting* foi capaz de produzir estimativas bastante similares às aquelas obtidas com um algoritmo Lasso tradicional, mas com menores erros-padrões, o que fez dele o modelo superior no teste.

Ainda, Ng (2014) buscou validar a performance de um algoritmo de *boosting* para previsão de períodos de recessão nos Estados Unidos de janeiro de 1961 a dezembro de 2011 utilizando 1500 preditores em potencial. Como a autora pontuou, antecipar períodos recessivos é particularmente desafiador porque apenas 15% das observações entre 1961 e 2012 correspondem a meses de recessão, o que dificulta a geração de previsões confiáveis. Ademais, os pesquisadores tendem a pré-selecionar alguns preditores para análise, tornando a omissão de variáveis relevantes uma possibilidade clara (NG, 2014, p. 3).

Descobriu-se que um grupo de variáveis foi sistematicamente importante para a previsão de períodos de recessão ao longo dos 50 anos cobertos, mas a importância relativa das variáveis mudou ao longo do tempo. Em outras palavras, a escolha das variáveis mais importantes foi fortemente influenciada pelo horizonte de previsão: o spread entre a taxa das Letras do Tesouro de 6 meses e a taxa básica de juros foi bastante importante para os horizontes $h = 3$ e $h = 6$, mas não para $h = 12$. Por outro lado, o índice NAPM, divulgado pela Associação de Executivos de Compras dos Estados Unidos, foi selecionado com frequência para $h = 12$, mas não para $h = 3$ ou $h = 6$. Como dito, a grande surpresa foi a importância dada pelo algoritmo à variável que mensura o emprego em minas, usualmente pouco utilizada na análise dos ciclos de negócios (NG, 2014, p. 18).

Como Ng explicou, o método esteve longe da perfeição, visto que gerou certas falhas e falsos positivos. Além disso, ainda que os modelos possam ter fornecido

estimativas precisas perto dos períodos de recessões, nem sempre lograram fornecê-las com antecipação suficiente. Tendo em vista que o *boosting* de Ng utilizou modelos logit que buscam prever a probabilidade de um evento - no caso, a probabilidade de uma recessão -, resta saber como se comporta o desempenho do *boosting* utilizando modelos lineares, como será investigado adiante.

Nesse campo, pode-se citar, ainda, Yoon (2021). Nele, o objetivo era prever o crescimento do PIB real japonês de 2001 a 2018 usando como benchmarks as estimativas do Fundo Monetário Internacional e do Banco do Japão. Os modelos de machine learning - um *boosting* tradicional e um Random Forest - foram comparados de acordo com as estatísticas para o erro absoluto percentual médio (MAPE) e para a raiz do erro quadrático médio (RMSE). Para o período de 2001-2018, ambos desbancaram os benchmarks, exceto pelo ano de 2009, marcado pela crise econômica mundial cujos efeitos sobre o PIB real japonês foram antecipados apenas pelo Fundo Monetário Internacional. Ademais, a partir da segunda metade das observações fora da amostra, o *boosting* produziu estimativas mais precisas, obtendo MAPE de 19.86% e RMSE de 0.35 contra MAPE de 67.23% e RMSE de 0.79 do Random Forest.

Outro artigo que corrobora a validade do *boosting* é “Forecasting with Many Predictors: is Boosting a Viable Alternative?” de Buchen e Wohlrabe (2011), escrito em resposta a “Forecasting with Many Predictors” de Stock e Watson (2006). No paper original, Stock e Watson prepararam um banco de dados com 130 regressores para fazer previsões acerca do índice de produção industrial dos Estados Unidos. A seguir, compararam diversas metodologias que iam de adaptações dos mínimos quadrados ordinários para lidar com o banco de dados de alta dimensionalidade até técnicas mais sofisticadas, como Análise de Componentes Principais (PCA), modelos de fatores dinâmicos e modelos bayesianos.

Inspirados por essa pesquisa, Buchen e Wohlrabe utilizaram o mesmo banco de dados e os mesmos critérios de avaliação de desempenho para testar a precisão do L2 *boosting* contra a de um benchmark AR. Buscaram determinar, ainda, o número de iterações do *boosting* de acordo com dois métodos: o tradicional Critério de Informação Akaike (AIC) e a validação cruzada. Descobriu-se que o algoritmo superava a performance do modelo AR em todos os horizontes de previsão exceto pelo primeiro. Além disso, se mantinha bastante competitivo frente a todos os modelos do artigo original de Stock e Watson e, para a projeção 12 horizontes à frente, saía vitorioso com folga

quando o número de iterações era determinado por validação cruzada.

Robinsonov, Tutz e Hothorn (2012) também discutiram a eficácia do L2 *boosting* para prever a produção industrial mensal da Alemanha de 1992 a 2006, dessa vez tanto com base learners lineares quanto com base learners de *splines* penalizados. As conclusões foram similares, corroborando o poder do método.

Em suma, o L2 *boosting* representa um promissor modelo que, dadas as suas aplicabilidade e performance, pode vir a conquistar popularidade na Econometria nos próximos anos. Como mencionado, as sementes do seu arcabouço teórico e matemático foram germinadas por Robert E. Schapire em seu artigo de 1990, “The Strength of Weak Learnability”. O título é propício, pois a força desse método reside precisamente na sua simplicidade: a cada iteração, a precisão do algoritmo cresce marginalmente à medida em que combina modelos fracos e força os modelos seguintes a focarem onde os anteriores apresentaram maior dificuldade. Dessa maneira, o *boosting* pode ser compreendido como o oposto dos modelos de redes neurais e do Random Forest, que visam enorme poder preditivo mas possuem fundamentos teóricos e matemáticos bastante abstratos, muitas vezes difíceis de compreender dado seu grau de complexidade. Ao contrário, o L2 *boosting*, como todos os algoritmos de *component-wise boosting*, visa equilibrar poder preditivo com facilidade no entendimento do seu funcionamento e, por isso, constitui uma ferramenta intuitiva.

3 METODOLOGIA

Esta seção descreve a abordagem metodológica aplicada na realização do estudo, detalhando os procedimentos e técnicas utilizados na análise dos dados. Divide-se em três subseções, cada uma dedicada a explicar aspectos específicos da metodologia empregada, garantindo a transparência e a reprodutibilidade do estudo: a primeira explica o funcionamento do algoritmo de *boosting*; a segunda, o procedimento de comparação com benchmarks; a terceira, as medidas de performance adotadas.

3.1 ALGORITMO DE *BOOSTING*

Como mencionado, Hothorn, Bühlmann, Kneib, Schmid e Hofner (2011) adaptou a metodologia de *boosting* para a linguagem de programação R através da biblioteca "mboost". Essa foi a biblioteca utilizada no presente trabalho.

O *boosting* pode ser executado com modelos lineares ou não lineares como *weak learners*. Embora a abordagem não linear tenha demonstrado resultados promissores, utilizou-se o método linear em última instância em função da sua simplicidade computacional e facilidade de comparação com os benchmarks.

Tem-se que $\hat{g}^{(m)}$ é o modelo base da iteração m e que $\sum_{m=1}^M \hat{g}^{(m)}$ é a soma dos modelos base de iterações $m = 1 : M$, onde o critério M foi escolhido via BIC com limite igual a 200. Essencialmente, o que o *boosting* faz é atualizar a previsão de acordo com o modelo base que produz a menor soma dos quadrados dos resíduos (SQR) a cada iteração m .

O algoritmo inicia com um valor ajustado temporário, $\hat{f}_t^{(0)} = \bar{y}$, que corresponde à média da variável dependente. Em seguida, o primeiro resíduo é calculado como a diferença elevada ao quadrado entre os valores observáveis da variável dependente e o valor ajustado temporário. Para cada iteração $m = 1 : M$, o algoritmo:

- Calcula os resíduos $u_t = y_t - \hat{f}_t^{(m-1)}$;
- Regride os resíduos u_t sobre cada variável em $z_{(k)}$;
- Calcula $SQR_{(k)} = \sum_{t=1}^T (u_t - z_{t,(k)} \hat{\beta}_{(k)})^2$;
- Seleciona como preditora a variável que produz a menor SQR ;
- Define $\hat{g}^{(m)} = \hat{\beta}_{(k^*)} z_{(k^*)}$;
- Atualiza $\hat{f}_t^{(m)} = \hat{f}_t^{(m-1)} + \hat{g}^{(m)}$.

3.2 BENCHMARKS

O primeiro benchmark utilizado foi o passeio aleatório (RW), no qual, para cada horizonte $h = 1 : 12$, as previsões são dadas por $\hat{\pi}_{t+h|t} = \pi_t$.

O segundo benchmark é o modelo autorregressivo (AR) de ordem p limitada a 12 e definida via BIC, cujas previsões são determinadas por $\hat{\pi}_{t+h|t} = \hat{\phi}_{0,h} + \hat{\phi}_{1,h}\pi_t + \dots + \hat{\phi}_{p,h}\pi_{t-p+1}$.

Finalmente, o terceiro benchmark é o modelo autorregressivo de médias móveis (ARMA) de ordens p e q limitadas a 12 e definidas via BIC, cujas previsões são geradas por $\hat{\pi}_{t+h|t} = \hat{\phi}_{0,h} + \hat{\phi}_{1,h}\pi_t + \dots + \hat{\phi}_{p,h}\pi_{t-p+1} + \hat{\theta}_{1,h}\epsilon_t + \dots + \hat{\theta}_{q,h}\epsilon_{t-q+1}$.

3.3 MEDIDAS DE PERFORMANCE

Os modelos foram comparados de acordo com três estatísticas: a raiz do erro quadrático médio (RMSE), o erro médio absoluto (MAE) e o desvio médio absoluto (MAD), definidas como

$$RMSE_{m,h} = \sqrt{\frac{1}{T - T_0 + 1} \sum_{t=T_0}^T \hat{\epsilon}_{t,m,h}^2},$$

$$MAE_{m,h} = \frac{1}{T - T_0 + 1} \sum_{t=T_0}^T |\hat{\epsilon}_{t,m,h}|,$$

$$MAD_{m,h} = \text{mediana}[|\hat{\epsilon}_{t,m,h} - \text{mediana}(\hat{\epsilon}_{t,m,h})|],$$

onde $\hat{\epsilon}_{t,m,h} = \pi_t - \hat{\pi}_{t,m,h}$, bem como $\hat{\pi}_{t,m,h}$ representa a previsão para a inflação no mês t feita pelo modelo m com informação disponível até $t - h$.

As duas primeiras medidas são tradicionalmente utilizadas na econometria. Fisher (1920) sugeriu que o RMSE é recomendável para a análise de erros normais (gaussianos), embora o MAE, ao minimizar o erro absoluto, muitas vezes produza melhores resultados porque os dados frequentemente englobam alguns outliers que fogem à distribuição normal. Por sua vez, o MAD, ainda que menos consolidado na literatura, por vezes tem sido apontado como mais confiável do que o MAE. Expor as medidas MAE e MAD, além do RMSE, visa tornar a análise mais robusta a outliers,

garantindo que seus resultados não se devem a alguns poucos erros maiores de previsão.

O RMSE penaliza mais os erros grandes do que os pequenos, devido ao termo ao quadrado na fórmula. Em contrapartida, o MAE mensura o erro médio em termos absolutos, sem considerar a direção do erro (positivo ou negativo). Um menor MAE indica que, em média, as previsões do modelo estão mais próximas dos valores reais, sem grandes desvios. Já o MAD é uma métrica que reflete a dispersão dos erros absolutos em relação à mediana: indica, através de menores valores, que os erros estão mais concentrados em torno da mediana, sugerindo uma maior consistência nas previsões.

Para corroborar os resultados das estatísticas descritivas, o teste de poder preditivo de Giacomini e White (2006) foi aplicado:

$$\Delta_k^{A,B} = L(\epsilon_k^A) - L(\epsilon_k^B),$$

onde $\epsilon_k^Z = p_k - \hat{p}_k$ é o erro de previsão do modelo Z para o horizonte temporal k e $L(\cdot)$ é a função de perda.

A hipótese nula do teste de Giacomini-White *two-sided* (bilateral) é a de igualdade preditiva entre dois modelos. Logo, a rejeição da hipótese nula implica que apresentam diferença de capacidade preditiva estatisticamente significativa.

Finalmente, foram elaborados gráficos para visualização dos erros de previsão quadráticos cumulativos ou *cumulative squared forecast errors* (CSFE) de Welch e Goyal (2008):

$$CSFE_{m,T} = \sum_{t=1}^T [(\hat{y}_{t+h|t,benchmark} - y_{t+h})^2 - (\hat{y}_{t+h|t,m} - y_{t+h})^2],$$

onde m diz respeito ao modelo concorrente testado m . Como explicado por Caldeira, Moura e Santos (2016, p. 86, tradução nossa), "no caso em que um modelo supera o benchmark, $CSFE_{m,T}$ será uma série crescente. Se o benchmark produz previsões mais exatas, então $CSFE_{m,T}$ será decrescente".

4 DADOS

Os dados foram obtidos do Federal Reserve Economic Data (FRED), repositório mantido pelo Federal Reserve Bank of St. Louis, e englobam o período de janeiro de 1993 a dezembro de 2017 para a Alemanha e de janeiro de 1990 a dezembro de 2014 para o Reino Unido. No caso de algumas variáveis, uma diferença foi tomada para garantir a estacionariedade, de forma que o banco de dados perde uma observação e tem início, efetivamente, em fevereiro dos respectivos anos. Embora o repositório contenha inúmeras outras séries temporais pertinentes ao tema, optou-se por utilizar apenas séries que contivessem valores não nulos em todo o período; isso explica, por exemplo, por que os agregados monetários M0, M1 e M3 foram usados nas previsões para o Reino Unido, mas não o agregado M2.

Assim, o banco de dados contém 18 variáveis independentes para a economia alemã e 19 para a economia britânica. No modelo L2 *boosting*, foram utilizados como regressores 12 lags de cada uma das variáveis, assim como 12 lags da própria variável dependente. Dessa forma, para a Alemanha, a análise contempla 228 regressores em potencial; para o Reino Unido, 240.

As variáveis de interesse para a Alemanha e o Reino Unido consistiam nos seus índices gerais de preço ao consumidor. As previsões foram computadas através de 132 janelas móveis que geravam dados para um período fora da amostra de janeiro de 2007 a dezembro de 2017 para a economia alemã e de janeiro de 2004 a dezembro de 2014 para a economia britânica. Conforme Medeiros, Vasconcelos, Veiga e Zilberman (2021, p. 101, tradução nossa), empregar um esquema de janelas móveis é útil para “atenuar os efeitos de potenciais quebras estruturais [nos dados] e outliers [...]”. Para cada uma dessas 132 observações, foram feitas projeções até 12 horizontes à frente.

Uma lista descritiva de todas as variáveis explicativas e das transformações aplicadas a elas para obtenção de estacionariedade consta nos apêndices deste trabalho. Em termos gerais, as variáveis selecionadas estavam relacionadas a preços, produção, níveis de incerteza política, taxas de juros e de câmbio, agregados monetários, desemprego, preços de ações e exportações e importações.

5 RESULTADOS

Esta seção apresenta os principais resultados obtidos no decorrer do estudo, organizados em duas subseções específicas: a análise dos dados referentes à Alemanha e a análise dos dados referentes ao Reino Unido.

5.1 ALEMANHA

Nesta subseção, serão apresentados os resultados para a análise do índice de preços da Alemanha para o período fora da amostra de janeiro de 2007 a dezembro de 2017. O presente trabalho foi inspirado por Medeiros, Vasconcelos, Veiga e Zilberman (2021), no qual os autores estudaram a performance de mais de 20 modelos de acordo com diversas métricas. Assim sendo, a tabela 1 segue o mesmo formato da apresentada em Medeiros, Vasconcelos, Veiga e Zilberman (2021): exibe as medidas de performance dos modelos para horizontes $h = 1 : 12$ com as estatísticas do passeio aleatório (RW) normalizadas para fins de comparação, ou seja, os valores dizem respeito às estatísticas de cada modelo divididas pelas estatísticas do passeio aleatório. As colunas (1), (2) e (3) reportam, respectivamente, os valores médios da raiz do erro quadrático médio (RMSE), do erro médio absoluto (MAE) e do desvio médio absoluto (MAD); as colunas (4), (5) e (6), respectivamente, os valores máximos de RMSE, MAE e MAD; e as colunas (7), (8) e (9), respectivamente, os valores mínimos de RMSE, MAE e MAD.

Os melhores resultados foram destacados em negrito. Conforme explicado na subseção 3.3, o RMSE é tradicional na análise de erros normais, ao passo em que o MAE e o MAD são menos sensíveis a outliers. De acordo com a tabela 1, percebe-se que o L2 *boosting* demonstrou superioridade unânime frente aos benchmarks para todas as medidas avaliadas, atingindo os menores valores para cada uma das estatísticas. A consistência de melhores desempenhos em todas essas métricas sugere que o algoritmo não foi apenas mais preciso do que os concorrentes, mas também foi balanceado em termos de tratar os diferentes tipos de erros. Assim, foi eficaz tanto em evitar grandes erros (indicado pelo RMSE) quanto em manter a precisão média (indicado pelo MAE) e a dispersão dos erros (indicado pelo MAD).

O modelo ARMA, em contrapartida, apresentou desempenho relativamente mais

fraco do que do *boosting* e do AR. De fato, apenas o ARMA registrou previsões piores do que as do passeio aleatório, como é possível ver pelas colunas (4), (5) e (6).

Tabela 1 – Medidas de performance: Alemanha, 2007-2017

Modelo	(1) média RMSE	(2) média MAE	(3) média MAD	(4) máx. RMSE	(5) máx. MAE	(6) máx. MAD	(7) mín. RMSE	(8) mín. MAE	(9) mín. MAD
RW	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
AR	0.60	0.60	0.60	0.92	0.93	0.92	0.51	0.50	0.46
ARMA	0.78	0.77	0.79	1.42	1.40	1.43	0.62	0.60	0.57
L2	0.54	0.54	0.55	0.88	0.91	0.91	0.46	0.45	0.42

Fonte: Elaboração própria.

Medeiros, Vasconcelos, Veiga e Zilberman (2021) também empregaram um algoritmo de *boosting* em seu artigo. Contudo, sua versão do *boosting*, que utilizava como potenciais regressores apenas fatores, não gerou grande diferença preditiva em relação ao AR. Comparando seus achados com os nossos, os resultados podem sugerir que utilizar diretamente as variáveis independentes - e não apenas fatores extraídos a partir delas - eleva substancialmente a qualidade das previsões. Uma desvantagem dessa abordagem é que não permite reduzir a dimensão do banco de dados. Em outras palavras, pode fazer com que o número de regressores supere o número de observações na amostra, gerando um sistema sem solução única. Entretanto, como discutido na seção 2, o método de *component-wise boosting* é capaz de contornar esse problema com facilidade. Logo, empregar todas as variáveis independentes à disposição como regressores pode acarretar ganhos de performance sem qualquer prejuízo ao funcionamento do algoritmo.

A tabela 2 sumariza o número de vezes em que cada modelo atingiu os valores mínimos de RMSE, MAE e MAD ao longo dos horizontes de previsão. Exceto por uma única vez na qual o modelo AR atingiu o menor MAD, o L2 *boosting* segue na liderança, obtendo os menores RMSE e MAE em todos os horizontes, bem como o menor MAD em 11 dos 12 horizontes. Tais descobertas estão apresentadas em mais detalhes na tabela seguinte.

**Tabela 2 – Precisão preditiva:
Alemanha, 2007-2017**

Modelo	# mín. RMSE	# mín. MAE	# mín. MAD
RW	0	0	0
AR	0	0	1
ARMA	0	0	0
L2	12	12	11

Fonte: Elaboração própria.

Através da tabela 3, é possível descobrir que o AR atingiu o menor MAD precisamente no 4º horizonte. De fato, a tabela 3 exibe as estatísticas RMSE, MAE e MAD de cada modelo em comparação com as estatísticas do passeio aleatório. Nesse sentido, valores menores do que 1 sinalizam que o modelo atingiu desempenho superior ao do passeio aleatório para dado horizonte de previsão. Somente o ARMA apresentou valores maiores do que 1 no 12º horizonte. Mais uma vez, os melhores resultados foram destacados em negrito. Nota-se o ganho de precisão do L2 *boosting* frente aos concorrentes, inclusive para as medidas MAE e MAD, que são menos sensíveis a outliers.

Tabela 3 – Alemanha: Razões de RMSE, MAE e MAD (2007-2017)

Painel (a): Razões do RMSE												
Horizontes de previsão												
Modelo	1	2	3	4	5	6	7	8	9	10	11	12
AR	0.55	0.64	0.58	0.57	0.58	0.51	0.59	0.55	0.58	0.57	0.52	0.92
ARMA	0.63	0.81	0.73	0.72	0.74	0.62	0.77	0.70	0.77	0.77	0.66	1.42
L2	0.46	0.54	0.53	0.52	0.52	0.47	0.54	0.50	0.53	0.53	0.49	0.88

Painel (b): Razões do MAE												
Horizontes de previsão												
Modelo	1	2	3	4	5	6	7	8	9	10	11	12
AR	0.58	0.67	0.58	0.57	0.55	0.50	0.58	0.54	0.58	0.57	0.56	0.93
ARMA	0.64	0.80	0.70	0.73	0.70	0.60	0.78	0.70	0.78	0.75	0.72	1.40
L2	0.47	0.56	0.52	0.51	0.49	0.45	0.52	0.48	0.53	0.53	0.52	0.91

Painel (c): Razões do MAD												
Horizontes de previsão												
Modelo	1	2	3	4	5	6	7	8	9	10	11	12
AR	0.71	0.65	0.51	0.50	0.47	0.46	0.49	0.57	0.64	0.63	0.64	0.92
ARMA	0.79	0.71	0.57	0.77	0.62	0.57	0.69	0.80	0.88	0.86	0.81	1.43
L2	0.55	0.62	0.43	0.51	0.42	0.43	0.43	0.53	0.58	0.57	0.60	0.91

Fonte: Elaboração própria.

Para confirmar os resultados, o teste de Giacomini-White foi empregado. A hipótese nula do teste *two-sided* (bilateral) é a de que não há diferença significativa de capacidade preditora entre os modelos. Em contrapartida, a hipótese alternativa é a de que existe discrepância de previsão estatisticamente significativa entre os modelos.


Optou-se por comparar o L2 *boosting* com o AR, o benchmark de melhor performance segundo as medidas RMSE, MAE e MAD. A tabela 4 indica os MAEs do *boosting* e do AR para cada horizonte de previsão, assim como sua respectiva significância de acordo com o valor-*p*. Nota-se que o *boosting* demonstra desempenho superior ao do AR a 0,1% de significância para os dois horizontes iniciais, bem como a pelo menos 5% de significância para os nove primeiros horizontes. Somente para os três últimos horizontes a dominância do *boosting* não se reflete em significância estatística.

**Tabela 4 – Teste de Giacomini-White:
Alemanha, *Boosting* vs. AR**


h	MAE L2	MAE AR	Significância
1	0.47	0.58	***
2	0.56	0.67	***
3	0.52	0.58	**
4	0.51	0.57	**
5	0.49	0.55	*
6	0.45	0.50	*
7	0.52	0.58	**
8	0.48	0.54	**
9	0.53	0.58	*
10	0.53	0.57	.
11	0.52	0.56	.
12	0.91	0.93	.

Fonte: Elaboração própria.

As figuras 1, 2 e 3 exibem, respectivamente, o comportamento dos modelos AR, ARMA e L2 *boosting* na produção de previsões para a inflação alemã. A linha preta denota os valores reais para o índice geral de preços aos consumidor no período de janeiro de 2007 a dezembro de 2017, enquanto que a linha verde expressa os valores previstos pelos algoritmos para o mesmo período. É possível notar que o ARMA apresentou maior dificuldade em acompanhar as flutuações do índice de preços frente aos seus concorrentes. Ademais, nos pontos em que as previsões do L2 e do AR se distanciam da linha preta, é nítido que o *boosting* comete erros visivelmente menores, razão pela qual apresentou RMSE, MAE e MAD mais baixos.

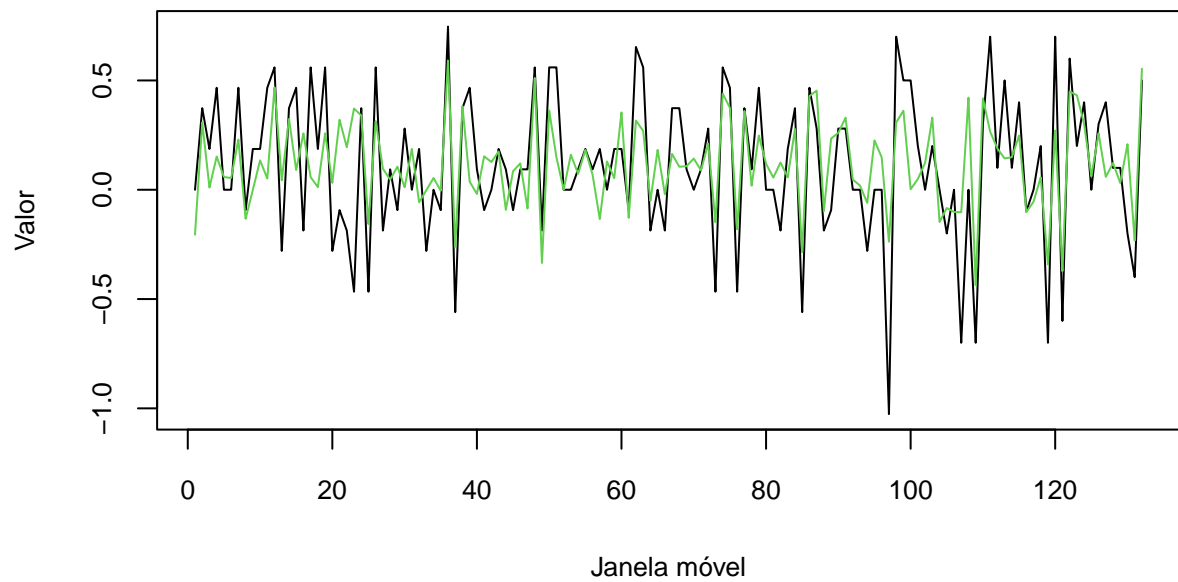
Figura 1 – Alemanha: AR, previsão fora da amostra (2007-2017)

Fonte: Elaboração própria.

Figura 2 – Alemanha: ARMA, previsão fora da amostra (2007-2017)

Fonte: Elaboração própria.

Figura 3 – Alemanha: L2, previsão fora da amostra (2007-2017)



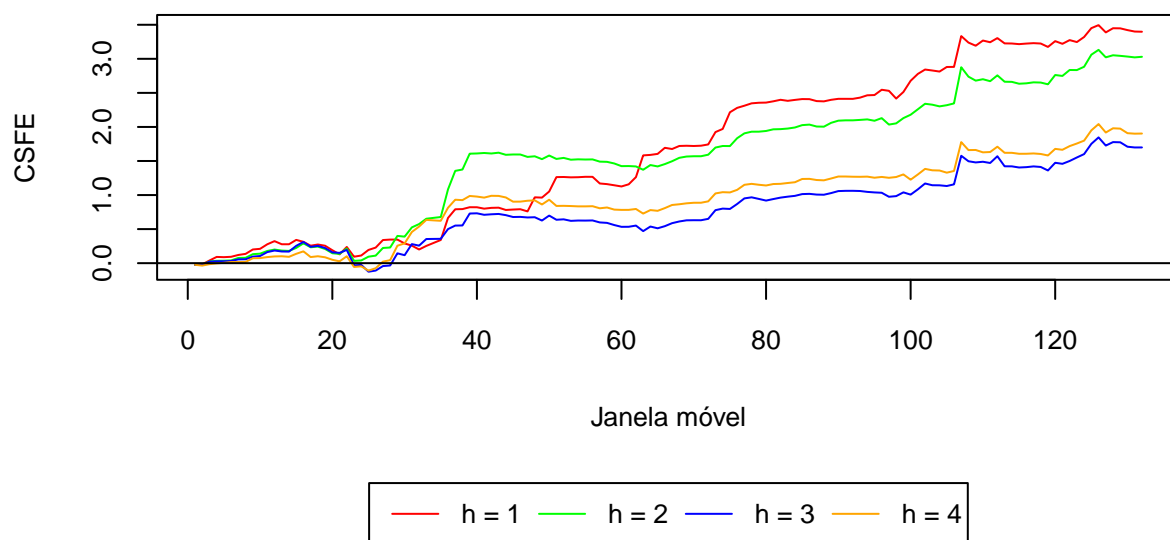
Fonte: Elaboração própria.

Por fim, as figuras 4, 5 e 6 dizem respeito aos erros de previsão quadráticos cumulativos ou *cumulative squared forecast errors* (CSFE) propostos em Welch e Goyal (2008). Valores maiores do que zero indicam melhor performance acumulada do modelo concorrente em comparação ao benchmark - nesse caso, o modelo AR, que apresentou os melhores RMSE, MAD e MAD. Ainda, quando o modelo concorrente supera o benchmark, o gráfico do CSFE é uma linha ascendente.

Através da análise dos gráficos, evidencia-se que o *boosting* produziu menores erros cumulativos do que o AR em geral, exceto para as observações fora da amostra iniciais dos quatro últimos horizontes de previsão. Para os quatro primeiros horizontes, sobretudo, seu ganho foi particularmente expressivo. Como se verá mais adiante, o *boosting* apresentou maior precisão para o estudo da Alemanha do que do Reino Unido.

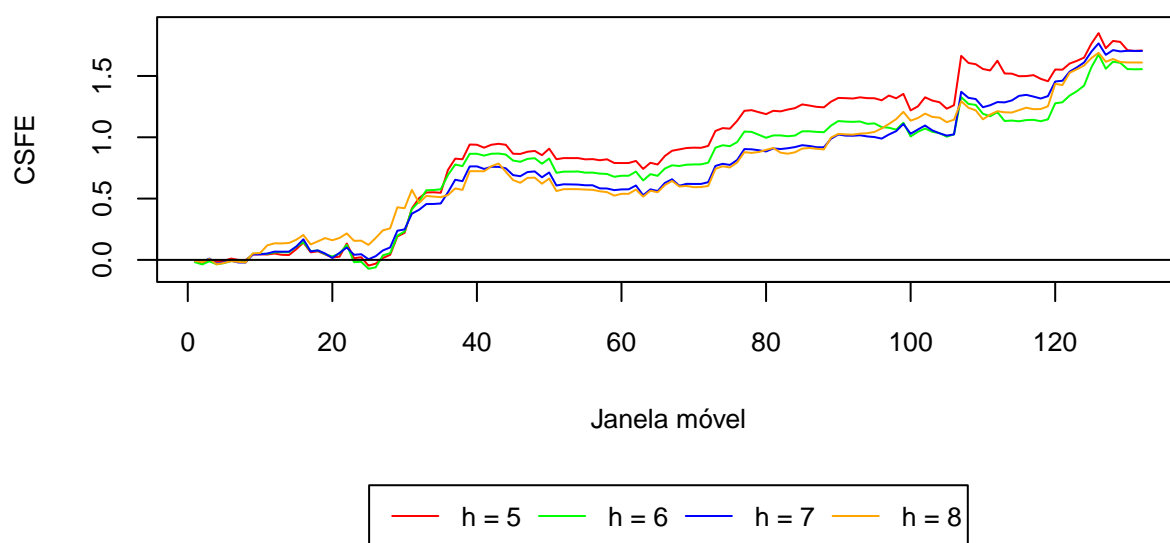
Esse resultado vai ao encontro de Robinzonov, Tutz e Hothorn (2012), outro trabalho que aplicou um *component-wise boosting* no estudo da economia alemã. Com o objetivo de prever a produção industrial para o período 1992-2006, os autores compararam o desempenho de diversos modelos com um benchmark AR - dentre eles, *boostings* linear e de *splines* penalizados. O *boosting* com modelos base lineares foi o único capaz de superar o benchmark para o horizonte imediatamente à frente. De fato, “ambos os métodos de *boosting* se provaram eficientes em previsão, especialmente o *boosting* linear nas previsões de curto e médio prazos, onde oferece o menor erro médio de predição” (ROBINZONOV; TUTZ; HOTHORN, 2012, p. 112, tradução nossa).

**Figura 4 – Alemanha: CSFE, h = 1:4,
Boosting vs. AR**




Fonte: Elaboração própria.

**Figura 5 – Alemanha: CSFE, h = 5:8,
Boosting vs. AR**



Fonte: Elaboração própria.

**Figura 6 – Alemanha: CSFE, h = 9:12,
Boosting vs. AR**



Fonte: Elaboração própria.

5.2 REINO UNIDO

Nesta subseção, serão apresentados os resultados para a análise do índice de preços do Reino Unido para o período fora da amostra de janeiro de 2004 a dezembro de 2014. Mais uma vez, a tabela 5 segue o mesmo esquema da apresentada em Medeiros, Vasconcelos, Veiga e Zilberman (2021): reporta as medidas de performance dos modelos para horizontes $h = 1 : 12$ com as estatísticas do passeio aleatório (RW) normalizadas para fins de comparação, isto é, os valores dizem respeito às estatísticas de cada modelo divididas pelas estatísticas do passeio aleatório. As colunas (1), (2) e (3) exibem, respectivamente, os valores médios de RMSE, MAE e MAD; as colunas (4), (5) e (6), respectivamente, os valores máximos de RMSE, MAE e MAD; e as colunas (7), (8) e (9), respectivamente, os valores mínimos de RMSE, MAE e MAD.

Os melhores resultados foram destacados em negrito. Novamente, o desempenho do ARMA foi fraco frente aos competidores, não tendo obtido a melhor métrica nem uma única vez. Em contrapartida, o modelo AR performou melhor do que no caso da Alemanha, apresentando o menor RMSE médio.

Tabela 5 – Medidas de performance: Reino Unido, 2004-2014

Modelo	(1) média RMSE	(2) média MAE	(3) média MAD	(4) máx. RMSE	(5) máx. MAE	(6) máx. MAD	(7) mín. RMSE	(8) mín. MAE	(9) mín. MAD
RW	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
AR	0.62	0.63	0.76	0.93	0.97	1.50	0.54	0.55	0.65
ARMA	0.77	0.80	0.88	1.19	1.24	1.72	0.67	0.69	0.76
L2	0.63	0.60	0.62	0.93	0.92	1.17	0.53	0.52	0.51

Fonte: Elaboração própria.

Contudo, como demonstrado pela tabela 6, o L2 *boosting* permanece vitorioso quando se leva em consideração as estatísticas MAE e MAD, que são robustas para outliers: dentre os 12 horizontes de previsão, obteve os menores MAE e MAD 11 vezes. Dessa forma, ambos L2 e AR apresentaram desempenho global semelhante quando consideramos o erro quadrático, indicado pelo RMSE. Todavia, o L2 *boosting* tendeu a ter erros absolutos menores, sendo menos sensível a outliers. Isso sugere que a maioria dos erros do L2 *boosting* são pequenos, mesmo que haja alguns poucos grandes erros que elevem o RMSE.

**Tabela 6 – Precisão preditiva:
Reino Unido, 2004-2014**

Modelo	# mín. RMSE	# mín. MAE	# mín. MAD
RW	0	0	1
AR	7	1	0
ARMA	0	0	0
L2	8	11	11

Fonte: Elaboração própria.

Com efeito, o AR e o *boosting* disputaram em termos de RMSE: como demonstrado na tabela 7, o algoritmo de machine learning domina apenas durante os quatro primeiros horizontes, a partir dos quais passa a rivalizar com o benchmark. Os melhores resultados foram destacados em negrito. Como a tabela exhibe as estatísticas RMSE, MAE e MAD de cada modelo em comparação com as estatísticas do passeio aleatório, valores menores do que 1 sinalizam que o modelo atingiu desempenho superior ao do passeio aleatório para dado horizonte de previsão. Como antes, somente o ARMA apresentou valores maiores do que 1 no 12º horizonte para as medidas RMSE e MAE; dessa vez, no entanto, nenhum modelo foi capaz de superar o passeio aleatório no último horizonte para o MAD.

Tabela 7 – Reino Unido: Razões de RMSE, MAE e MAD (2004-2014)

Painel (a): Razões do RMSE												
Horizontes de previsão												
Modelo	1	2	3	4	5	6	7	8	9	10	11	12
AR	0.58	0.63	0.57	0.60	0.57	0.72	0.56	0.60	0.54	0.59	0.55	0.93
ARMA	0.70	0.75	0.69	0.74	0.72	0.90	0.70	0.73	0.67	0.74	0.73	1.19
L2	0.53	0.60	0.55	0.59	0.60	0.88	0.56	0.56	0.55	0.60	0.55	0.93

Painel (b): Razões do MAE												
Horizontes de previsão												
Modelo	1	2	3	4	5	6	7	8	9	10	11	12
AR	0.59	0.61	0.58	0.63	0.57	0.73	0.58	0.61	0.55	0.60	0.58	0.97
ARMA	0.73	0.74	0.70	0.80	0.74	0.92	0.73	0.76	0.69	0.75	0.77	1.24
L2	0.52	0.58	0.54	0.61	0.56	0.76	0.54	0.54	0.52	0.56	0.54	0.92

Painel (c): Razões do MAD												
Horizontes de previsão												
Modelo	1	2	3	4	5	6	7	8	9	10	11	12
AR	0.71	0.70	0.69	0.68	0.65	0.67	0.67	0.71	0.72	0.71	0.74	1.50
ARMA	0.81	0.78	0.81	0.77	0.79	0.82	0.85	0.79	0.79	0.76	0.86	1.72
L2	0.62	0.61	0.63	0.57	0.55	0.56	0.59	0.56	0.55	0.51	0.56	1.17

Fonte: Elaboração própria.


Novamente, o teste de Giacomini-White *two-sided* (bilateral) foi aplicado, tendo a hipótese nula de que não existe diferença significativa de capacidade preditiva entre os modelos - nesse caso, o L2 *boosting* e o AR, o benchmark de melhor performance conforme as medidas RMSE, MAE e MAD. A tabela 8 indica os MAEs dos modelos para cada horizonte de previsão e sua respectiva significância de acordo com o valor-*p* de Giacomini-White. Dessa vez, contudo, apenas os horizontes 1 e 8 permitem rejeitar a hipótese nula a 5% de significância. Em outras palavras, para a maior parte dos horizontes, não é possível concluir que a diferença de performance entre os modelos é estatisticamente significativa.

**Tabela 8 – Teste de Giacomini-White:
Reino Unido, *Boosting* vs. AR**


h	MAE L2	MAE AR	Significância
1	0.52	0.59	*
2	0.58	0.61	
3	0.54	0.58	
4	0.61	0.63	
5	0.56	0.57	
6	0.76	0.73	
7	0.54	0.58	
8	0.54	0.61	*
9	0.52	0.55	
10	0.56	0.60	
11	0.54	0.58	
12	0.92	0.97	

Fonte: Elaboração própria.

As figuras 7, 8 e 9 apresentam, respectivamente, o comportamento dos modelos AR, ARMA e L2 *boosting* na produção de previsões para a inflação britânica. A linha preta traça os valores reais para o índice geral de preços aos consumidores no período de janeiro de 2004 a dezembro de 2014, ao passo em que a linha verde indica os valores previstos pelos algoritmos para o mesmo período. Percebe-se, sobretudo, a fragilidade do modelo autorregressivo de médias móveis: pouco após a 50ª observação, passa a selecionar sempre um ARMA(0, 0), que corresponde apenas à média da variável dependente. Esse comportamento é demonstrado pela linha verde na figura 8.


Figura 7 – Reino Unido: AR, previsão fora da amostra (2004-2014)

Fonte: Elaboração própria.

Figura 8 – Reino Unido: ARMA, previsão fora da amostra (2004-2014)

Fonte: Elaboração própria.

Figura 9 – Reino Unido: L2, previsão fora da amostra (2004-2014)



Fonte: Elaboração própria.

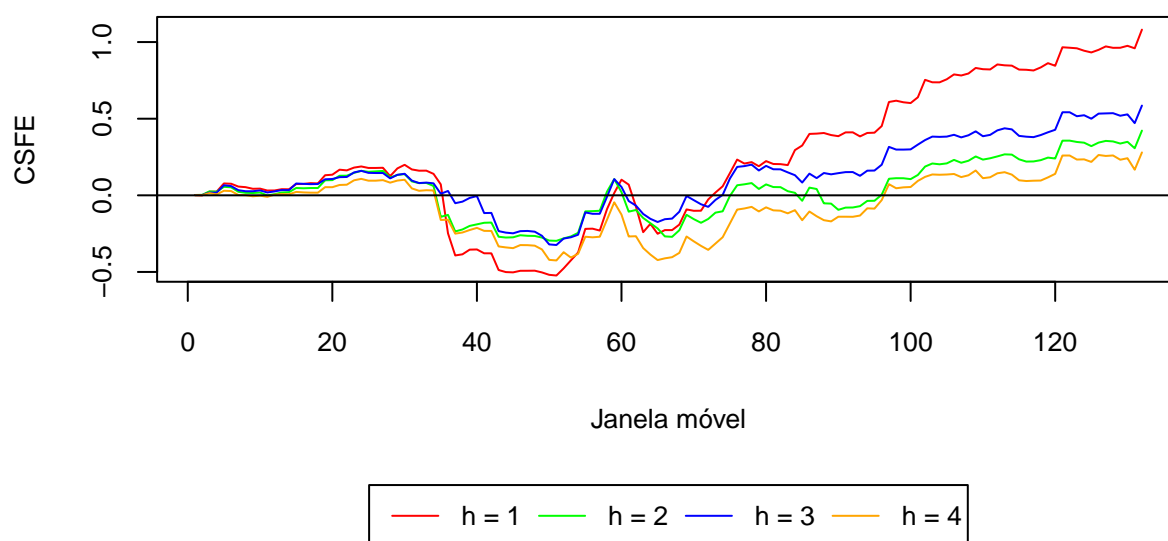
Contrastando os pontos nos quais as previsões do AR e do L2 se distanciam das linhas pretas nas figuras 7 e 9, percebe-se novamente que o *boosting* gera desvios menores, razão pela qual apresentou MAE e MAD mais baixos.

Já as figuras 10, 11 e 12 dizem respeito aos *cumulative squared forecast errors* (CSFE) de Welch e Goyal (2008) para o L2 em comparação com o AR. Quando o modelo concorrente supera o benchmark, o gráfico do CSFE é uma linha ascendente.

Nota-se que, de modo geral, o *boosting* produz previsões mais exatas apenas a partir da 90ª observação para os quatro primeiros horizontes. Com exceção do oitavo horizonte, onde performa bem, chega mesmo a gerar maiores erros do que o benchmark AR para a maior parte das observações fora da amostra do horizonte 5 em diante.

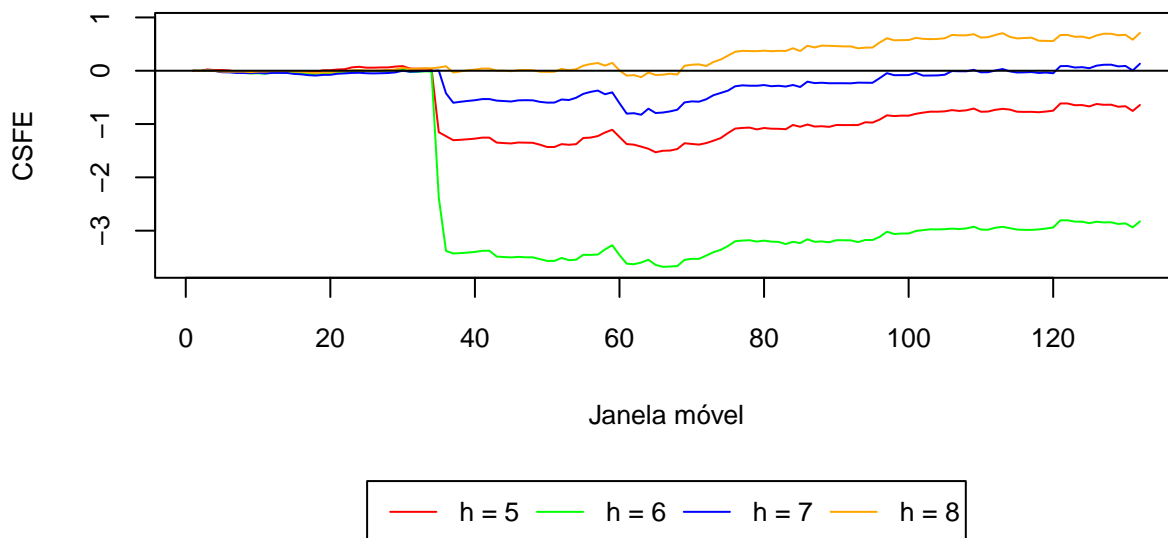
Como mencionado, o desempenho do *component-wise boosting* foi relativamente mais fraco no caso britânico. Somente tendo em conta as estatísticas MAE e MAD é que o algoritmo apresenta ganhos visíveis em comparação com os benchmarks. Mesmo assim, tais ganhos não são estatisticamente significantes de acordo com Giacomini-White.

Figura 10 – Reino Unido: CSFE, h = 1:4, Boosting vs. AR




Fonte: Elaboração própria.

Figura 11 – Reino Unido: CSFE, $h = 5:8$,
Boosting vs. AR



Fonte: Elaboração própria.

Figura 12 – Reino Unido: CSFE, $h = 9:12$,
Boosting vs. AR



Fonte: Elaboração própria.

6 CONCLUSÃO

Esta pesquisa buscou testar a validade de um algoritmo *component-wise boosting* com função de perda L2 e *learners* lineares contra os modelos AR, ARMA e passeio aleatório para a previsão do índice de preços da Alemanha no período 2007-2017 e do Reino Unido no período 2004-2014. Partindo de 18 variáveis independentes para a economia alemã e 19 para a economia britânica, os regressores em potencial englobaram 12 lags para cada variável e 12 termos autorregressivos para a própria variável dependente. A seleção das variáveis foi deixada a cargo do *boosting*.

O algoritmo de machine learning foi especialmente preciso no estudo da Alemanha, obtendo os menores RMSE e MAD em todos os horizontes de previsão, bem como o menor MAD em 11 dos 12 horizontes. Tais descobertas foram corroboradas pelo teste de Giacomini-White, que indicou diferença de capacidade preditiva estatisticamente significativa entre os modelos nos nove primeiros horizontes. Por fim, o esboço gráfico dos erros de previsão quadráticos cumulativos (CSFE) de Welch e Goyal demonstrou melhor performance acumulada do L2 *boosting* contra o AR em todos os horizontes.

No caso do Reino Unido, o L2 e o AR rivalizaram em termos de RMSE, embora o *boosting* permaneça vitorioso com a inclusão das medidas MAE e MAD, que são robustas para outliers. Contudo, o teste de Giacomini-White apontou diferença de capacidade preditiva estatisticamente significativa entre os modelos apenas nos horizontes 1 e 8. Por sua vez, os gráficos do CSFE evidenciaram que o *boosting* produziu previsões mais exatas apenas a partir da metade final das previsões no 1º e no 8º horizontes.

Deixa-se, como sugestão para trabalhos futuros, a aplicação do L2 *boosting* com *splines* penalizados como modelos base, o que pode vir a aprimorar a capacidade preditiva do algoritmo.

REFERÊNCIAS

- ARAUJO, Gustavo S.; GAGLIANONE, Wagner P. Machine Learning Methods for Inflation Forecasting in Brazil: New Contenders versus Classical Models. **Latin American Journal of Central Banking**, v. 4, n. 2, 2023. Disponível em: <https://doi.org/10.1016/j.latcb.2023.100087>. Acesso em: 30 jul. 2024.
- BAI, Jushan; NG, Serena. Boosting diffusion indices. **Journal of Applied Econometrics**, v. 24, n. 4, p. 607-629, jun/jul. 2009. Disponível em: <https://doi.org/10.1002/jae.1063>. Acesso em: 30 jul. 2024.
- BERNANKE, Ben. **Inflation Expectations and Inflation Forecasting**. Federal Reserve Board, jul. 2007. Disponível em: <https://www.federalreserve.gov/newsevents/speech/bernanke20070710a.htm>. Acesso em: 21 ago. 2024.
- BREIMAN, Leo. Arcing Classifiers. **The Annals of Statistics**, v. 26, n. 3, p. 801-849, jun. 1998. Disponível em: <https://doi.org/10.1214/aos/1024691079>. Acesso em: 30 jul. 2024.
- BROWNLEE, Jason. **A Gentle Introduction to the Gradient Boosting Algorithm for Machine Learning**, Machine Learning Mastery, 2016. Disponível em: <https://machinelearningmastery.com/gentle-introduction-gradient-boosting-algorithm-machine-learning/>. Acesso em: 30 jul. 2024.
- BUCHEN, Teresa; WOHLRABE, Klaus. Forecasting with Many Predictors: is Boosting a Viable Alternative? **Economics Letters**, v. 113, n. 1, p. 16-18, out. 2011. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0165176511002175>. Acesso em: 30 jul. 2024.
- BÜHLMANN, Peter; YU, Bin. Boosting with the L2-Loss: Regression and Classification. **Journal of the American Statistical Association**, v. 98, n. 462, p. 324-339, 2003. Disponível em: <https://doi.org/10.1198/016214503000125>. Acesso em: 30 jul. 2024.
- CALDEIRA, João F.; MOURA, Guilherme V.; SANTOS, André A. P. Predicting the Yield Curve Using Forecast Combinations. **Computational Statistics & Data Analysis**, v. 100, p. 79-98, ago. 2016. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0167947314001480>. Acesso em: 30 jul. 2024.
- COIBION, Olivier; GORODNICHENKO, Yuriy; KAMDAR, Rupal. The Formation of Expectations, Inflation, and the Phillips Curve. **Journal of Economic Literature**, v. 56, n. 4, p. 1447-1491, dez. 2018. Disponível em: <https://www.jstor.org/stable/26570578>. Acesso em: 30 jul. 2024.
- FISHER, Ronald Aylmer. A Mathematical Examination of the Methods of Determining the Accuracy of Observation by the Mean Error, and by the Mean Square Error.

Monthly Notices of the Royal Astronomical Society, v. 80, n. 8, p. 758-770, jun. 1920. Disponível em: <https://doi.org/10.1093/mnras/80.8.758>. Acesso em: 30 jul. 2024.

FREUND, Yoav. Boosting a Weak Learning Algorithm by Majority. **Information and Computation**, v. 121, n. 2, p. 256-285, set. 1995. Disponível em: <https://doi.org/10.1006/inco.1995.1136>. Acesso em: 30 jul. 2024.

FREUND, Yoav; SCHAPIRE, Robert E. Experiments with a New Boosting Algorithm. **Proceedings of the 13th International Conference on Machine Learning**, 1996.

FRIEDMAN, Jerome H. Greedy function approximation: A gradient boosting machine. **The Annals of Statistics**, v. 29, n. 5, p. 1189-1232, 2001. Disponível em: <https://doi.org/10.1214/aos/1013203451>. Acesso em: 30 jul. 2024.

FRISCH, Ragnar. Econometrics in the World of Today. *In*: ELTIS, Walter; SCOTT, Maurice; WOLFE, James. **Induction, Growth and Trade: Essays in Honour of Sir Roy Harrod**. Oxford: Clarendon Press, p. 163, 1970.

GIACOMINI, Raffaella; WHITE, Halbert. Tests of Conditional Predictive Ability. **Econometrica**, v. 74, n. 6, p. 1545-1578, nov. 2006. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1468-0262.2006.00718.x>. Acesso em: 30 jul. 2024.

HOTHORN, Torsten; BÜHLMANN, Peter; KNEIB, Thomas; SCHMID, Matthias; HOFNER, Benjamin. Model-based Boosting 2.0. **Journal of Machine Learning Research**, v. 11, p. 2109-2113, 2011. Disponível em: <https://cran.r-project.org/web/packages/mboost/vignettes/mboost.pdf>. Acesso em: 30 jul. 2024.

LINDENMEYER, Guilherme; SKORIN, Pedro Pablo; TORRENT, Hudson da Silva. Using boosting for forecasting electric energy consumption during a recession: a case study for the Brazilian State Rio Grande do Sul. **Letters in Spatial and Resource Sciences**, v. 14, p. 111-128, 2021. Disponível em: <https://doi.org/10.1007/s12076-021-00268-3>. Acesso em: 30 jul. 2024.

LUO, Ye; SPINDLER, Martin. L2-Boosting for Economic Applications. **American Economic Review**, v. 107, n. 5, p. 270-273, 2017. Disponível em: <https://doi.org/10.1257/aer.p20171040>. Acesso em: 30 jul. 2024.

MEDEIROS, Marcelo C.; VASCONCELOS, Gabriel F. R.; VEIGA, Álvaro; ZILBERMAN, Eduardo. Forecasting Inflation in a Data-Rich Environment: the Benefits of Machine Learning Methods. **Journal of Business & Economic Statistics**, v. 39, n. 1, p. 98-119, 2021. Disponível em: https://www.researchgate.net/publication/334155178_Forecasting_Inflation_in_a_Data-Rich_Environment_The_Benefits_of_Machine_Learning_Methods. Acesso em: 30 jul. 2024.

NG, Serena. Viewpoint: Boosting Recessions. **Canadian Journal of Economics**, v. 47, n. 1, p. 1-34, fev. 2014. Disponível em:

<https://onlinelibrary.wiley.com/doi/full/10.1111/caje.12070>. Acesso em: 30 jul. 2024.

ROBINZONOV, Nikolay; TUTZ, Gerhard; HOTHORN, Torsten. Boosting Techniques for Nonlinear Time Series Models. **AStA Advances in Statistical Analysis**, v. 96, p. 99-122, 2012. Disponível em: <https://doi.org/10.1007/s10182-011-0163-4>. Acesso em: 30 jul. 2024.

SCHAPIRE, Robert E. The strength of weak learnability. **Machine Learning**, v. 5, p. 197-227, jun. 1990. Disponível em: <https://link.springer.com/article/10.1007/BF00116037>. Acesso em: 30 jul. 2024.

SCHMID, Matthias; HOTHORN, Torsten. Boosting additive models using component-wise P-Splines. **Computational Statistics & Data Analysis**, v. 53, n. 2, p. 298-311, dez. 2008. Disponível em: <https://doi.org/10.1016/j.csda.2008.09.009>. Acesso em: 30 jul. 2024.

STOCK, James H.; WATSON, Mark W. Forecasting Inflation. **Journal of Monetary Economics**, v. 44, n. 2, p. 293-335, 1999. Disponível em: [https://doi.org/10.1016/S0304-3932\(99\)00027-6](https://doi.org/10.1016/S0304-3932(99)00027-6). Acesso em: 30 jul. 2024.

STOCK, James H.; WATSON, Mark W. Forecasting with Many Predictors. **Handbook of Economic Forecasting**, v. 1, p. 515-554, 2006. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1574070605010104>. Acesso em: 30 jul. 2024.

YOON, Jaehyun. Forecasting of Real GDP Growth Using Machine Learning Models: Gradient Boosting and Random Forest Approach. **Computational Economics**, v. 57, n. 1, p. 247-265, 2021. Disponível em: <https://link.springer.com/article/10.1007/s10614-020-10054-w>. Acesso em: 30 jul. 2024.

WELCH, Ivo; GOYAL, Amit. A Comprehensive Look at the Empirical Performance of Equity Premium Prediction. **The Review of Financial Studies**, v. 21, n. 4, p. 1455-1508, jul. 2008. Disponível em: <https://academic.oup.com/rfs/article-abstract/21/4/1455/1565737>. Acesso em: 30 jul. 2024.

BIBLIOGRAFIA CONSULTADA

ARRUDA, Elano F.; FERREIRA, Roberto T.; CASTELAR, Ivan. Modelos Lineares e Não Lineares da Curva de Phillips para Previsão da Taxa de Inflação no Brasil. **Revista Brasileira de Economia**, v. 65, n. 3, p. 237-252, 2011. Disponível em: <https://bibliotecadigital.fgv.br/ojs/index.php/rbe/article/view/1523>. Acesso em: 30 jul. 2024.

ATKESON, Andrew; OHANIAN, Lee E. Are Phillips Curves Useful for Forecasting Inflation? **Federal Reserve Bank of Minneapolis Quarterly Review**, v. 25, n. 1, p. 2-11, inverno 2001. Disponível em: <https://www.andrew.cmu.edu/course/88-301/phillips/forecasting-with-phillips-frbm.pdf>. Acesso em: 30 jul. 2024.

BROWNLEE, Jason. **Ensemble Learning Algorithms with Python: Make Better Predictions with Bagging, Boosting, and Stacking**. [s.l.]: [s.n.], 2021.

CHU, Jianghao; LEE, Tae-Hwy; ULLAH, Aman; WANG, Ran. Boosting. In: FULEKY, Peter (ed.). **Macroeconomic Forecasting in the Era of Big Data. Advanced Studies in Theoretical and Applied Econometrics**, v. 52, p. 431-463, nov. 2019. Disponível em: https://link.springer.com/chapter/10.1007/978-3-030-31150-6_14. Acesso em: 30 jul. 2024.

CORREIA, Fernando Motta; PEREIRA, João Basílio. Curva de Phillips e macrodinâmica do capital ótimo. **Revista de Economia Contemporânea**, Rio de Janeiro, v. 15, n. 2, p. 221-242, mai-ago. 2011. Disponível em: <https://doi.org/10.1590/S1415-98482011000200001>. Acesso em: 30 jul. 2024.

FISCHER, Stanley. Long-Term Contracts, Rational Expectations, and the Optimal Money Supply Rule. **Journal of Political Economy**, University of Chicago Press, v. 85, n. 1, p. 191-205, fev. 1977. Disponível em: <https://ideas.repec.org/a/ucp/jpolec/v85y1977i1p191-205.html>. Acesso em: 30 jul. 2024.

FRIEDMAN, Milton. The Role of Monetary Policy. **American Economic Review**, v. 58, n. 1, p. 1-17, mar. 1968. Disponível em: <https://www.aeaweb.org/aer/top20/58.1.1-17.pdf>. Acesso em: 30 jul. 2024.

GARCIA, Márcio G. P.; MEDEIROS, Marcelo C.; VASCONCELOS, Gabriel F. R. Real-time inflation forecasting with high-dimensional models: The case of Brazil. **International Journal of Forecasting**, v. 33, n. 3, p. 679-693, 2017. Disponível em: <http://dx.doi.org/10.1016/j.ijforecast.2017.02.002>. Acesso em: 30 jul. 2024.

IVERSEN, Jens; LASÉEN, Stefan; LUNDEVALL, Henrik; SÖDERSTRÖM, Ulf. Real-Time Forecasting for Monetary Policy Analysis: The Case of Sveriges Riksbank. **Sveriges Riksbank**, Working Paper Series, n. 318, mar. 2016. Disponível em: <https://dx.doi.org/10.2139/ssrn.2780417>. Acesso em: 30 jul. 2024.

LUCAS JR, Robert E. Econometric policy evaluation: A critique. **Carnegie-Rochester Conference Series on Public Policy**, v. 1, p. 19-46, 1976. Disponível em: [https://doi.org/10.1016/S0167-2231\(76\)80003-6](https://doi.org/10.1016/S0167-2231(76)80003-6). Acesso em: 30 jul. 2024.

LUCAS JR, Robert E. Expectations and the Neutrality of Money. **Journal of Economic Theory**, v. 4, n. 2, p. 103-124, abri. 1972. Disponível em: [https://doi.org/10.1016/0022-0531\(72\)90142-1](https://doi.org/10.1016/0022-0531(72)90142-1). Acesso em: 30 jul. 2024.

LUCAS JR, Robert E. Some International Evidence on Output-Inflation Tradeoffs. **The American Economic Review**, v. 63, n. 3, p. 326-334, jun. 1973. Disponível em: <https://www.jstor.org/stable/1914364>. Acesso em: 30 jul. 2024.

MANKIW, N. Gregory; REIS, Ricardo; WOLFERS, Justin. Disagreement About Inflation Expectations. In: GERTLER, Mark; ROGOFF, Kenneth. **NBER Macroeconomics Annual**, v. 18, p. 209-270, 2003. Disponível em: <https://www.nber.org/books-and-chapters/nber-macroeconomics-annual-2003-volume-18/disagreement-about-inflation-expectations>. Acesso em: 30 jul. 2024.

McCRACKEN, Michael W.; NG, Serena. FRED-MD: A Monthly Database for Macroeconomic Research. **Journal of Business & Economic Statistics**, v. 34, n. 4, p. 574-589, 2016. Disponível em: <https://www.jstor.org/stable/44166591>. Acesso em: 30 jul. 2024.

MEDEIROS, Marcelo C.; VASCONCELOS, Gabriel F. R.; Forecasting Macroeconomic Variables in Data-Rich Environments. **Economics Letters**, v. 139, p. 50-52, 2016. Disponível em: <https://doi.org/10.1016/j.econlet.2015.11.017>. Acesso em: 30 jul. 2024.

MEDEIROS, Marcelo C.; VASCONCELOS, Gabriel; FREITAS, Eduardo. Forecasting Brazilian Inflation with High-Dimensional Models. **Brazilian Review of Econometrics**, v. 36, n. 2, p. 223-254, 2016. Disponível em: <https://doi.org/10.12660/bre.v99n992016.52273>. Acesso em: 30 jul. 2024.

MISHKIN, Frederic S. Inflation Dynamics. **National Bureau of Economic Research**, v. 10, n. 3, p. 317-334, dez. 2007. Disponível em: <https://www.nber.org/papers/w13147>. Acesso em: 30 jul. 2024.

MUTH, John F. Rational Expectations and the Theory of Price Movements. **Econometrica**, v. 29, n. 3, p. 315-335, jul. 1961. Disponível em: <https://doi.org/10.2307/1909635>. Acesso em: 30 jul. 2024.

NATEKIN, Alexey; KNOLL, Alois. Gradient boosting machines, a tutorial. **Frontier in Neurorobotics**, v. 7, p. 1-21, dez. 2013. Disponível em: <https://doi.org/10.3389/fnbot.2013.00021>. Acesso em: 30 jul. 2024.

PHELPS, Edmund S. The New Microeconomics in Inflation and Employment Theory. **American Economic Review**, v. 59, n. 2, p. 147-160, mai. 1969. Disponível em: <https://ideas.repec.org/a/aea/aecrev/v59y1969i2p147-60.html>. Acesso em: 30 jul. 2024.

PHILLIPS, A. W. The Relation Between Unemployment and the Rate of Change of

Money Wage Rates in the United Kingdom, 1861-1957. **Economica**, v. 25, n. 100, p. 283-375, nov. 1958. Disponível em: <https://doi.org/10.1111/j.1468-0335.1958.tb00003.x>. Acesso em: 30 jul. 2024.

ROSSI, Alberto; TIMMERMANN, Allan. Modeling Covariance Risk in Merton's ICAPM. **The Review of Financial Studies**, v. 28, n. 5, p. 1428-1461, mai. 2015. Disponível em: <https://doi.org/10.1093/rfs/hhv015>. Acesso em: 30 jul. 2024.

SAMUELSON, Paul A.; SOLOW, Robert M. Analytical Aspects of Anti-Inflation Policy. **The American Economic Review**, v. 50, n. 2, p. 177-194, mai. 1960. Disponível em: <https://www.jstor.org/stable/1815021>. Acesso em: 30 jul. 2024.

SARGENT, Thomas J.; WALLACE, Neil. "Rational" Expectations, the Optimal Monetary Instrument, and the Optimal Money Supply Rule. **Journal of Political Economy**, v. 83, n. 2, p. 241-254, abr. 1975. Disponível em: <https://www.jstor.org/stable/1830921>. Acesso em: 30 jul. 2024.

SCHAPIRE, Robert E. **Boosting: Foundations and Algorithms**. Cambridge: The MIT Press, 2012.

SCORNET, Erwan; BIAU, Gérard; VERT, Jean-Philippe. Consistency of random forests. **The Annals of Statistics**, v. 43, n. 4, p. 1716-1741, 2015. Disponível em: <http://doi.org/10.1214/15-AOS1321>. Acesso em: 30 jul. 2024.

STOCK, James H.; WATSON, Mark W. Why Has U.S. Inflation Become Harder to Forecast? **Journal of Money, Credit and Banking**, v. 39, n. 1, p. 3-33, 2007. Disponível em: <https://doi.org/10.1111/j.1538-4616.2007.00014.x>. Acesso em: 30 jul. 2024.

TAYLOR, John B. Aggregate Dynamics and Staggered Contracts, **Journal of Political Economy**, University of Chicago Press, v. 88, n. 1, p. 1-23, fev. 1980. Disponível em: <https://ideas.repec.org/a/ucp/jpolec/v88y1980i1p1-23.html>. Acesso em: 30 jul. 2024.

VARIAN, Hal R. Big Data: New Tricks for Econometrics. **Journal of Economic Perspectives**, v. 28, n. 2, p. 3-28, primavera de 2014. Disponível em: <https://www.aeaweb.org/articles?id=10.1257/jep.28.2.3>. Acesso em: 30 jul. 2024.

WAGER, Stefan; ATHEY, Susan. Estimation and Inference of Heterogeneous Treatment Effects using Random Forests. **Journal of the American Statistical Association**, v. 113, n. 523, p. 1228-1242, 2018. Disponível em: <https://doi.org/10.1080/01621459.2017.1319839>. Acesso em: 30 jul. 2024.

YOUSUF, Kashif; NG, Serena. Boosting High Dimensional Predictive Regressions with Time Varying Parameters. **Journal of Econometrics**, v. 224, n. 1, p. 60-87, 2021. Disponível em: <https://doi.org/10.1016/j.jeconom.2020.08.003>. Acesso em: 30 jul. 2024.

APÊNDICE A - ALEMANHA: VARIÁVEIS E TRANSFORMAÇÕES

Tabela 9 – Variáveis da Alemanha

Sigla	Descrição	Unidade	Diferenças
DEEPUINDEXM	Economic Policy Uncertainty Index for Germany	Índice	—
DEUCPIALLMINMEI	Consumer Price Indices (CPIs, HICPs), COICOP 1999: Consumer Price Index: Total for Germany	Índice 2015 = 100	1
DEUCPICORMINMEI	Consumer Price Indices (CPIs, HICPs), COICOP 1999: Consumer Price Index: All Items Non-Food Non-Energy for Germany	Índice 2015 = 100	—
DEUCPIENGMINMEI	Consumer Price Indices (CPIs, HICPs), COICOP 1999: Consumer Price Index: Energy for Germany	Índice 2015 = 100	1
DEUCPIFODMINMEI	Consumer Price Index: Food for Germany	Índice 2010 = 100	1
DEUCPIHOUMINMEI	Consumer Price Index: Housing for Germany	Índice 2010 = 100	—
DEUODCNPI03MLM	Orders: Construction: Permits Issued: Dwellings and Residential Buildings for Germany	Número, nível mensal	1
DEUPPDMMINMEI	Producer Prices Index: Economic Activities: Manufacturing: Domestic for Germany	Índice 2015 = 100	1
DEUPRMNCG02IXOBSA M	Production: Manufacturing: Consumer Goods: Durable Goods for Germany	Índice 2015 = 100	1
DEUPRMNVG01IXOBSA M	Production: Manufacturing: Investment Goods: Total for Germany	Índice 2015 = 100	1
DEUPROINDMISMEI	Production, Sales, Work Started and Orders: Production Volume: Economic Activity: Industry (Except Construction) for Germany	Índice 2015 = 100	—
DEUPROMANMISMEI	Production, Sales, Work Started and Orders: Production Volume: Economic Activity: Manufacturing for Germany	Índice 2015 = 100	—

Sigla	Descrição	Unidade	Diferenças
EUEPUINDEXM	Economic Policy Uncertainty Index for Europe	Índice	—
IR3TIB01DEM156N	Interest Rates: 3-Month or 90-Day Rates and Yields: Interbank Rates: Total for Germany	Porcentagem	1
IRLTLT01DEM156N	Interest Rates: Long-Term Government Bond Yields: 10-Year: Main (Including Benchmark) for Germany	Porcentagem	1
LMUNRRTTDEM156S	Infra-Annual Registered Unemployment and Job Vacancies: Total Economy: Registered Unemployment for Germany	Taxa de crescimento para o período anterior	1
SPASTT01DEM661N	Financial Market: Share Prices for Germany	Índice 2015 = 100	1
XTEXVA01DEM667S	International Merchandise Trade Statistics: Exports: Commodities for Germany	Dólares americanos, convertidos pela taxa de câmbio	1
XTIMVA01DEM667S	International Merchandise Trade Statistics: Imports: Commodities for Germany	Dólares americanos, convertidos pela taxa de câmbio	1

Fonte: elaboração própria.

APÊNDICE B - REINO UNIDO: VARIÁVEIS E TRANSFORMAÇÕES

Tabela 10 – Variáveis do Reino Unido

Sigla	Descrição	Unidade	Diferenças
AURUKM	Unemployment Rate in the United Kingdom	Porcentagem	1
BOERUKM	Bank of England Policy Rate in the United Kingdom	Porcentagem por ano	—
EUEPUINDXM	Economic Policy Uncertainty Index for Europe	Índice	—
EXUSUK	U.S. Dollars to U.K. Pound Sterling Spot Exchange Rate	Dólares americanos por libra esterlina	1
GBRCP010000IXNBM	Consumer Price Index: Food and Non-Alcoholic Beverages (COICOP 01): Total for United Kingdom	Índice	1
GBRCPALTT01IXNBM	Consumer Price Index: All Items: Total for United Kingdom	Índice	1
GBRCPICORMINMEI	Consumer Price Indices (CPIs, HICPs), COICOP 1999: Consumer Price Index: All Items Non-Food Non-Energy for United Kingdom	Índice 2015 = 100	1
GBRCPIENGMINMEI	Consumer Price Indices (CPIs, HICPs), COICOP 1999: Consumer Price Index: Energy for United Kingdom	Índice 2015 = 100	1
GBRMABMM301IXOBSAM	Monetary Aggregates and Their Components: Broad Money and Components: M3 for United Kingdom	Índice 2015 = 100	1
GBRMANMM101IXOBSAM	Monetary Aggregates and Their Components: Narrow Money and Components: M1 and Components: M1 for United Kingdom	Índice 2015 = 100	1
GBRPPDMMINMEI	Producer Prices Index: Economic Activities: Manufacturing: Domestic for United Kingdom	Índice 2015 = 100	1
HVMRUKM	Household Variable Mortgage Rate in the United Kingdom	Porcentagem por ano	—
IPIUKM	Industrial Production Index in the United Kingdom	Índice 2012 = 100	1

Sigla	Descrição	Unidade	Diferenças
IR3TIB01GBM156N	Interest Rates: 3-Month or 90-Day Rates and Yields: Interbank Rates: Total for United Kingdom	Porcentagem	—
IRLTLT01GBM156N	Interest Rates: Long-Term Government Bond Yields: 10-Year: Main (Including Benchmark) for United Kingdom	Porcentagem	—
LIOR3MUKM	3-month London Interbank Offered Rate (LIBOR) in the United Kingdom	Porcentagem por ano	—
MBM0UKM	Monetary Base M0 in the United Kingdom	Milhões de libras britânicas	1
SPASTT01GBM661N	Financial Market: Share Prices for United Kingdom	Índice 2015 = 100	1
XTEXVA01GBM667S	International Merchandise Trade Statistics: Exports: Commodities for United Kingdom	Dólares americanos, convertidos pela taxa de câmbio	1
XTIMVA01GBM667S	International Merchandise Trade Statistics: Imports: Commodities for United Kingdom	Dólares americanos, convertidos pela taxa de câmbio	1

Fonte: elaboração própria.