

# Previsão da Taxa de Câmbio para a Economia Brasileira Utilizando Preditores Macroeconômicos e Aprendizado de Máquina Supervisionado.

Diógenes Pinheiro de Medeiros Junior \*

Elvira Helena Oliveira de Medeiros †

Lucas Lúcio Godeiro‡

## Resumo

Este artigo tem o objetivo de utilizar técnicas de aprendizado de máquina supervisionado recursivamente via Ridge, LASSO e *Elastic Net* para melhorar a regressão de Kitchen-Skin na previsão da taxa de câmbio entre o Real (BRL) e o dólar (USD). Para verificar a robustez do método foi feita uma combinação com preditores dos fundamentos macroeconômicos entre eles: paridade de juros descoberta, paridade do poder de compra, fundamentos monetários, regra de Taylor e Termos de Troca a fim de verificar seu poder explicativo em relação ao modelo de referência (Passeio Aleatório) no período dentro da amostra de 2002 : 01 a 2010 : 06 e fora da amostra de 2010 : 07 a 2022 : 06. Os resultados encontrados mostraram que o modelo eficiente de Kitchen-Skin não consegue prever estatisticamente /economicamente a taxa de câmbio. Por outro lado, apenas o preditor UIP apresentou um bom desempenho, superando o *benchmark*, além de promover ganho de utilidade ao investidor avesso ao risco cambial.

**Palavras-Chave:** Taxa de Câmbio; Aprendizado de Máquina Supervisionado; Fundamentos Macroeconômicos; Regressão de Kitchen-Skin.

## Abstract

This paper aims to use supervised machine learning techniques recursively through the Ridge, LASSO e Elastic Net, to improve the regression of Kitchen-Skin in the forecast of the exchange rate between the Real (BRL) and the Dollar (USD). To verify the robustness of the method, a combination was made with predictors of the macroeconomic fundamentals between them, uncovered interest parity, purchasing power parity, monetary fundamentals, Taylor's rule and Terms of Exchange in order to verify their explanatory power in relation to the reference model (random walk) in the sample period from 2002 : 01 to 2010 : 06 and out of the sample from 2010 : 07 to 2022 : 06. The results found showed that the efficient Kitchen-Skin model cannot statistically/economically predict the exchange

---

\*Mestrando em Economia Aplicada - UERN e Especialização em Gestão Ambiental com Ênfase em Auditoria e Perícia - FVJ. e-mail: [diognspmjr@gmail.com](mailto:diognspmjr@gmail.com)

†Doutoranda em Economia Aplicada - UFJF e Mestre em Economia Aplicada - UERN. e-mail: [ravilelenna@yahoo.com.br](mailto:ravilelenna@yahoo.com.br)

‡Doutor em Economia Aplicada - UFPB e Professor da Universidade Federal Rural do Semi Árido. e-mail: [lucasgodeiro@ufersa.edu.br](mailto:lucasgodeiro@ufersa.edu.br)

rate. On the other hand, only the UIP predictor performed well, outperforming the benchmark, in addition to promoting a gain in utility for investors who are averse to exchange rate risk.

**Keywords:** Exchange Rate; Supervised Machine Learning; Macroeconomic Fundamentals; Kitchen-Skin Regression.

**Área 4:** - Macroeconomia, Economia Monetária e Finanças.

**JEL Classification:** C52, F31, F37.

## 1 Introdução

A previsão da taxa de câmbio entre moedas tem sido um assunto bastante debatido na literatura. Vários autores tentaram explicar o seu comportamento usando diversos fundamentos econômicos (macroeconômicos). Apesar dessas teorias serem bastante robustas, quando observado o seu comportamento fora da amostra o seu desempenho cai, gerando previsões não significativas em relação ao passeio aleatório, [Moosa and Burns \(2014\)](#). Segundo [Zhang and Hamori \(2020\)](#), esses modelos usuais não apresentaram melhores desempenhos quando comparado com o modelo de passeio aleatório, mesmo após a introdução do sistema de câmbio flutuante. [Meese and Rogoff \(1983\)](#), por sua vez, relacionam o poder preditivo de modelos específicos para taxa de câmbio fora da amostra, descobrindo que eles têm um desempenho inferior ao passeio aleatório.

Mais recentemente tem-se observado o uso de previsões através de especificações distintas, e para isso, existem formas de serem feitas. Primeiramente, introduzindo individualmente variáveis na equação. Posteriormente, pode-se gerar equações com várias covariáveis numa mesma modelagem. [Li et al. \(2015\)](#). Na literatura, esse método de introduzir várias variáveis juntas é conhecido por Kitchen-Sink. Esta técnica é usada para medir a capacidade de um único modelo condicionando diversos preditores, apesar de ser um modelo bastante utilizado devido a sua capacidade de previsão, quando aplicado a análise fora da amostra (OOS) com o Método de Mínimos Quadrados Ordinários (OLS) o seu desempenho cai, gerando resultados não robustos ao aumentar a variância do modelo.

Assim, dada a dificuldade de previsibilidade a literatura tem utilizado técnicas de aprendizado de máquina para melhorar a capacidade preditiva dos modelos. Isto posto, o presente estudo utiliza o aprendizado de máquina supervisionado recursivamente com as técnicas: Ridge, LASSO e *Elastic Net* para melhorar a capacidade preditiva do modelo Kitchen-Sink, conjuntamente com as teorias fundamentais macroeconômica de previsão da taxa de câmbio. Alguns trabalhos utilizaram o uso de combinações de teorias fundamentais da taxa de câmbio conjuntamente com técnicas específicas. [Da Silva and Junior \(2022\)](#) observaram que ao associar modelos de aprendizado de máquina com essas teorias, essas combinações geram resultados superiores ao passeio aleatório. Da mesma maneira, [Li et al. \(2015\)](#) encontraram que a combinação de métodos com a teoria gera resultados mais robustos para moedas de países desenvolvidos. O que diferencia um estudo do outro é que o primeiro utiliza métodos de aprendizado de máquina Floresta Aleatória (RF), Máquina de Vetor de Suporte (SVM) e *Elastic Net* com *Splines*. Já o segundo, por sua vez, utiliza o *Elastic Net* com o objetivo de melhorar a capacidade preditiva do modelo de Kitchen-Sink.

Diante disso, o objetivo do artigo é observar se os fundamentos macroeconômicos aliados as técnicas de aprendizado de máquina supervisionado recursivamente fora da amostra melhoram o poder preditivo da regressão de Kitchen-Sink na previsão da taxa de câmbio entre o real (BRL) e dólar (USD). O que

diferencia esse estudo dos anteriores é que, ao invés de utilizar quatro preditores dos fundamentos macroeconômicos que são usualmente empregado na literatura (Paridade de Juros Descoberta, Paridade do Poder de Compra, Fundamentos Monetários e Regra de Taylor), foi adicionado o preditor Termos de Troca, cuja a finalidade é verificar se houve um crescimento dos termos de troca da economia brasileira com a americana, uma vez que, a economia brasileira possui um grande *portfólio* de exportação e importação entre países.

Além disso, também calculamos o equivalente certeza (ganho de utilidade) de um investidor individual de média variância associado a cada modelo de previsão. Assim, para toda análise de previsão os dados foram calculados mensalmente e divididos em períodos dentro e fora da amostra. Os dados da janela de estimativa inicial (IS) começaram em 2002 : 01 e terminaram em 2010 : 06 (102 observações). Já a janela fora da amostra (OOS) varia de 2010 : 07 a 2022 : 06 (132 observações), gerando uma janela de 234 previsões. Além desta parte introdutória e das considerações finais, a seção 2 trata da metodologia e dos dados e a seção 3, aborda sobre os resultados da pesquisa.

## 2 Metodologia e Dados

Para nossa análise, tomamos como base o método empregado no artigo de [Li et al. \(2015\)](#) para prever a taxa de câmbio entre o real do Brasil (BRL) e o dólar americano (USD), abordando problemas que são frequentemente discutidos na literatura econômica, especificadamente, dificuldades de se obter resultados que sejam bons o suficientes para superar uma previsão sem mudança, como é o caso do passeio aleatório, [Moosa and Burns \(2014\)](#). Na literatura são encontrados diversos métodos usados para sua previsão. Tais métodos são baseados em fundamentos macroeconômicos. Atualmente, tem-se utilizado esses modelos combinados com técnicas de aprendizado de máquinas, que são modelos que possuem flexibilidades suficientes para capturar a relação entre taxa de câmbio e modelos macroeconômicos, [Da Silva and Junior \(2022\)](#).

Diante disso, nossa metodologia esta resumida em algumas etapas: Na primeira etapa é abordada a regressão *Kitchen-Sink*, denotando suas especificações e seu poder de previsão. Na segunda etapa, utilizamos modelos de aprendizado de máquina supervisionado (*SML*) para melhorar a capacidade preditiva da regressão *Kitchen-Sink*. Na terceira etapa, foi utilizado regressores baseados em fundamentos macroeconômicos sobre a teoria padrão de determinação da taxa de câmbio, usualmente utilizado na literatura. Por fim, avaliamos a capacidade preditiva dos modelos empíricos da taxa de câmbio fora da amostra com o modelo de comparação, o passeio aleatório (*benchmark*). Este procedimento fora da amostra é repetido recursivamente até o último período da amostra.

### 2.1 Regressão *Kitchen-Sink*

Conforme adotado em [Li et al. \(2015\)](#) a regressão *Kitchen - Sink* (KS) é usado para determinar a capacidade preditiva de uma única regressão condicionando o uso de diversos preditores. Intuitivamente quando adotado a preditores cambiais ele possui a seguinte estrutura:

$$\Delta s_{t+1} = \alpha + \sum_{j=1}^K \beta_j \chi_{j,t} + \varepsilon_{t+1} \quad (1)$$

Onde:  $s_{t+1}$  é a taxa de câmbio nominal do dólar americano para uma determinada moeda no tempo

$t + 1$ ,  $\Delta s_{t+1} = s_{t+1} - s_t$  é o retorno da taxa de câmbio logarítmica no tempo  $t + 1$ , e  $j \leq k$ ,  $\alpha$  e  $\beta = \beta_j$  são parâmetros constantes a serem estimados e  $\varepsilon_{t+1}$  é um termo de erro normal. Os parâmetros  $\alpha$  e  $\beta$  são preditores baseados em paridade de juros descoberta, paridade do poder de compra, fundamentos monetários, regra de Taylor e os termos de troca, [Li et al. \(2015\)](#). As especificações de tais modelos são apresentados nas seções posteriores.

Apesar de ser um modelo bastante utilizado devido a sua capacidade de previsão, quando aplicado a análise fora da amostra (OOS) com o Método de Mínimos Quadrados Ordinários (OLS) o seu desempenho geram resultados não robustos . <sup>1</sup> Visando corrigir possíveis erros de especificações no modelo, utilizamos os métodos de regularização para melhorar a precisão preditiva da regressão KS, [Li et al. \(2015\)](#).

## 2.2 Métodos de Regularização

Nesta seção, explicamos como encontramos o melhor modelo preditivo, observando seu desempenho estatístico de um agrupamento de modelos de previsão da taxa de câmbio para regressão KS.

O método dos Mínimos Quadrados Ordinários (MQO) conhecido na literatura como um modelo linear, é bastante utilizado devido a sua importância e eficiência satisfatória. Sob certas condições do teorema de *Gauss - Markov* ele possui variância mínima entre o melhor estimador linear não viesado. Apesar de ser uma técnica bastante atraente, para o objetivo proposto a sua acurácia e interpretabilidade diminui devido o aumento da variância entre as covariáveis da regressã KS. No entanto, relaxando a condição de imparcialidade chega-se a um melhor modelo. Devido a esses fatores, tem-se buscado modelos robustos.

A literatura tem destacado o método conhecido por *shrinkage* (encolhimento), por se tratar de uma técnica que visa solucionar tais problemas por meio do uso de penalização entre os coeficientes da regressão. No entanto, para isso há um ônus de viés (tendência) nos parâmetros, porém, gerando uma variância inferior ao do MQO. Por conta dessas características abordamos essas técnicas de regularização para a regressão KS. Segundo [Li et al. \(2015\)](#) esses métodos tem como objetivo reduzir os coeficientes para zero, que é o padrão de referência do modelo de passeio aleatório (*benchmark*).

## 2.3 LASSO, Ridge e Elastic Net

Nesta seção abordamos o aprendizado de máquina supervisionado recursivamente, aplicando o *Elastic Net* conjuntamente com a regressão *Kitchen-Sink* para estimar a seguinte equação de previsão:

$$\min_{\beta_t} \frac{1}{2} \sum_t^T (\Delta s_{t+1} - \alpha - \beta_j x_{j,t})^2 \quad (2)$$

$$s.a \sum_{j=1}^K \|\beta_j\| < s_1 \quad (3)$$

$$e \sum_{j=1}^K \beta_j^2 < s_2 \quad (4)$$

---

<sup>1</sup>Ao colocar todos os preditores numa mesma equação a variância do modelo aumenta, inferindo propriedades de *Gauss-Markov*.

De acordo com [Li et al. \(2015\)](#) esse modelo é chamado de regressão eficiente de *Kitchen-Sink* (E-KS), por levar a um modelo com menor variância quando comparado ao OLS e um MSE menor. Os termos  $s_1$  e  $s_2$  são constantes positivas a serem estimadas. Empiricamente a equação (2) esboça o modelo *Elastic Net* da seguinte forma:

Quando  $s_1 = s_2 = \infty$  então a função objetivo (2) torna-se igual à soma usual dos resíduos quadrados (OLS). Quando  $s_2 = \infty$ , então (2) se torna o estimador LASSO. Embora LASSO seja bem sucedido na seleção de variáveis, LASSO seleciona no máximo  $T$  covariáveis antes de saturar, excluindo, portanto, grandes porções do conjunto de informações de condicionais e reduzindo potencialmente a precisão das previsões. O caso com  $s_1 = \infty$  corresponde à Ridge, que não faz seleções de modelo porque não reduz os coeficientes para zero.

Por estas razões, [Zou and Hastie \(2005\)](#) sugeriram usar uma combinação de restrição- $s_1$  e restrição- $s_2$  que corresponde ao chamado estimador de “*Elastic Net*”. Nesse caso, os coeficientes  $\hat{\beta}_t$  são reduzidos para zero de duas maneiras diferentes, promovendo tanto a esparsidade como a estabilidade. Isso evita o conhecido “*overfitting*”<sup>2</sup> nos dados ao definir os coeficientes sem importância como zero.

Com o objetivo de utilizar supervisionamento de máquina, o artigo utilizou as técnicas de regularização, Ridge, LASSO e *Elastic Net*, conjuntamente com a regressão E-KS para previsão da taxa de câmbio no tempo. Em nosso exercício de previsão fora da amostra, a equação (2) é estimada recursivamente até o final da amostra, ou seja, para cada origem da previsão  $t = R, \dots, T - 1$ <sup>3</sup>, regredimos as observações  $\Delta s_{t+1}$  para  $s = 1, \dots, t - 1$ , implicando que o vetor de coeficiente  $\beta_t$  tem permissão para mudar com o tempo.

Por fim, além de estimarmos o E-KS, o supervisionamento de máquina nos permitirá verificar se algum ganho potencial vem da restrição  $s_1 = \infty$  (Ridge) ou da restrição  $s_2 = \infty$  (LASSO), ou da combinação dos dois  $s_1 = s_2 = \infty$  (*Elastic Net*).

De maneira mais geral, como todos os três modelos implementam a estimativa de encolhimento, uma comparação de seu desempenho nos permitirá determinar se é o encolhimento que impulsiona os resultados ou o tipo específico de encolhimento que combina as duas restrições no modelo E-KS, [Li et al. \(2015\)](#).

## 2.4 Preditores Macroeconômicos

Para a determinação da previsão da taxa de câmbio entre a moeda brasileira (BRL) e a moeda americana (USD), deve-se levar em conta quais teorias fundamentais da macroeconomia devem ser utilizadas. Dessa forma, foram utilizadas cinco modelos dos fundamentos macroeconômicos, conforme descritos abaixo.

### 2.4.1 Paridade de juros descoberta

A paridade de juros não coberta baseia-se na paridade de juros. É neutro em relação as expectativas racionais de juros, e implica em três equivalências, a saber: (i) taxa a termo e estimador imparcial da taxa futura à vista; (ii) retorno cambial esperado, caracterizado como o diferencial da taxa de juros; (iii) excesso de retorno cambial esperado que é igual a zero. Assim, podemos observá-lo da seguinte forma:

---

<sup>2</sup>No aprendizado de máquina, o *overfitting* ocorre quando dividimos a amostra em treino e teste e o modelo decorou tão bem a primeira parte que não generaliza para a etapa seguinte.

<sup>3</sup>Terminamos em  $T - 1$  porque precisamos usar a observação  $T$  para avaliar as previsões feitas em  $T - 1$

$$x_{1,t} = f_t - s_t \quad (5)$$

Onde  $f_t$  é o logaritmo da taxa de câmbio a termo de 1 mês no tempo, que é a taxa acordada no tempo  $t$  para uma troca de moedas em  $t + 1$ .

## 2.4.2 Paridade do Poder de Compra

A paridade do poder de compra foi inicialmente proposto por Cassel (1918). Para o autor a PPC implica que, a mesma quantidade de bens e serviços poderia ser comprada com a mesma quantidade inicial de moeda, o que implica dizer que a mesma unidade unitária no seu país de origem teria o mesmo poder de compra no outro país, ou seja, o estrangeiro, Zhang and Hamori (2020).

A paridade do poder de compra (PPC) basicamente é a conversão do índice de preço entre a taxa de câmbio. Para Li et al. (2015) a paridade do poder de compra no longo prazo gera níveis de preços nacionais e internacionais idênticos, quando apresentado numa mesma moeda. A PPC parte da noção de que a taxa cambial se acomoda às diferenças de níveis de preços entre países, Officer (1976); Dornbusch (1975); Frenkel (1978).

Desta forma, a PPC pode ser representada da seguinte forma:

$$S = \frac{P^*}{P} \quad (6)$$

Onde  $S$  representa a taxa de câmbio no período  $t$ ;  $P$  preço no país de origem e  $P^*$  é o preço no país estrangeiro. De acordo com a equação acima se assumirmos a paridade do poder de compra para o período  $t + 1$  ficaremos com a seguinte especificação:

$$S_{t+1} = \frac{P_{t+1}}{P_{t+1}^*} \quad (7)$$

Por outro lado, se a inflação for adotada no período  $t + 1$ , ela passa a ter o seguinte comportamento:

$$S_{t+1} = \frac{(1 + \pi)P_t}{(1 + \pi^*)P_t^*} = \frac{1 + \pi}{1 + \pi^*} S_t \quad (8)$$

De forma que:

$$\frac{S_{t+1}}{S_t} = \frac{1 + \pi}{1 + \pi^*} \quad (9)$$

Agora, se assumirmos que a taxa de câmbio é igual a  $\rho$ , obtemos a seguinte equação:

$$\frac{S_{t+1}}{S_t} = \rho + 1 \quad (10)$$

Usando as equações 7 e 8 obtemos a seguinte equação:

$$\rho + \rho\pi^* + 1 + \pi^* = 1 + \pi \quad (11)$$

O valor de  $\rho\pi^*$  é muito pequeno, de forma que podemos tirá-lo da equação. Desta forma, ficamos com uma nova equação:

$$\frac{S_{t+1} - S_t}{S_t} = \pi - \pi^* \quad (12)$$

Conforme encontrado em [Zhang and Hamori \(2020\)](#) a equação 10 mostra uma relação entre a taxa de câmbio e a taxa de inflação. Para se fazer tal relação, o presente artigo utilizou o Índice Nacional de Preços ao Consumidor Amplo (IPCA) de todos os itens, excluindo alimentos *in natura*. Para medir a produção, utilizamos o índice de produção industrial do Brasil e dos EUA.

### 2.4.3 Fundamentos Monetários

Para [Soares \(2008\)](#), um número considerável de trabalhos apontam para o crescimento descontrolado dos agregados monetários ou do crédito doméstico como uma das principais fontes causadoras de crises cambiais. Torna-se, então, necessário verificar o comportamento dessas variáveis para tentar estabelecer a suposta relação entre descontrolado monetário e desequilíbrios cambiais. Os primeiros modelos monetários foram introduzidos por [Frenkel \(1978\)](#) e por [Mussa \(2019\)](#). Ambos os modelos determinavam a taxa de câmbio como sendo o preço relativo de duas moedas. Empiricamente eles modelavam o seu comportamento utilizando a taxa de câmbio em termos de demanda relativa. Segundo [Zhang and Hamori \(2020\)](#) o equilíbrio entre o mercado nacional e o mercado estrangeiro é dado por:

$$m_t = p_t + ky_t - hi_t \quad (13)$$

$$m_t^* = p_t^* + ky_t^* - hi_t^* \quad (14)$$

Diferenciando 13 de 14 chegamos a seguinte equação:

$$m_t - m_t^* = p_t - p_t^* + k(y_t - y_t^*) - h(i_t - i_t^*) \quad (15)$$

Onde  $m_t$  é o logaritmo da oferta monetária doméstica e  $y_t$  é o logaritmo da produção doméstica. Da mesma forma,  $m_t^*$  é o logaritmo da oferta de moeda estrangeira e  $y_t^*$  é o logaritmo da produção real estrangeira,  $k$  denota a elasticidade-renda. Seguindo [Zhang and Hamori \(2020\)](#) assumindo a elasticidade igual a 1 e utilizando a paridade do poder de compra,  $i_t - i_t^* = S_{t+1} - S_t$ , temos:

$$S_{t+1} - S_t = p_t - p_t^* + y_t - y_t^* - (m_t - m_t^*) \quad (16)$$

O presente artigo se baseou no estudo de [Zhang and Hamori \(2020\)](#) ao utilizar variação entre a taxa de câmbio com outras variáveis. Especificadamente, foi utilizado a seguinte equação:

$$S_{t+1} - S_t = f(p_t - p_t^*, y_t - y_t^*, m_t - m_t^*) \quad (17)$$

Há evidência empírica de que a relação entre taxas de câmbio e fundamentos macroeconômicos é heterogênea. Por um lado, uma vasta literatura estabelece que os movimentos da taxa de câmbio no curto prazo parecem estar desconectados dos fundamentos, [Engel et al. \(2007\)](#). Por outro lado, há evidências de que as taxas de câmbio e os fundamentos se movem juntos no longo prazo [Rapach and Wohar \(2002\)](#).

#### 2.4.4 Modelos de Regras de Taylor

Inicialmente, a regra de Taylor determinava que a autoridade monetária fixava a taxa de juros real em conformidade com o diferencial entre a inflação e o hiato do produto, [Zhang and Hamori \(2020\)](#). Contudo, nos últimos anos tal teoria vem sendo modificada. Autores como [Engel and West \(2006\)](#) aprimoram a regra de Taylor em função da política monetária. Desta forma, a regra de Taylor relaciona à taxa de juros básica do Banco Central, seu instrumento de política, com a taxa de juros real de longo prazo, a taxa de inflação, e os hiatos da inflação e do produto real. Empiricamente, utilizamos o modelo adotado em [Li et al. \(2015\)](#) com as seguintes especificações:

$$i_t^T = 1,5(\pi_t - \pi_t^*) + 0,1(y_t^g - y_t^{*g}) + 0,1(S_t + p_t^* - p_t) \quad (18)$$

Onde  $\pi_t$  é a taxa de inflação interna,  $\pi_t^*$  a taxa de inflação externa,  $y_t^g$  o hiato do produto,  $y_t^{*g}$  o hiato do produto externo. [Li et al. \(2015\)](#) denota o hiato do produto como o desvio percentual do produto real a partir de uma estimativa de seu nível potencial. Na literatura sobre previsão da taxa de câmbio é comumente utilizado valores para padronizar as variáveis, a saber: (1, 5) para a diferença da taxa de inflação; (0, 1) para a diferença do hiato do produto; (0, 1) para a taxa de câmbio. [Li et al. \(2015\)](#)

#### 2.4.5 Termos de Troca

Termos de troca (TDT) é uma taxa de intercâmbio entre bens manufaturados e não manufaturados. É uma relação entre o valor das exportações e o valor das importações desses bens para um determinado período. Devido a sua característica torna-se uma importante variável para o comércio exterior de países. Empiricamente, tem a seguinte representação:

$$TDT = \frac{VE}{VI} \quad (19)$$

Onde: TDT é o termo de troca; VE o valor das exportações e VI o valor das importações.

O Brasil é uma economia emergente que possui um alto grau de exportação. Dentre do seu portfólio as *commodities* têm uma grande representatividade. Através da figura 1 podemos verificar o comportamento dos termos de troca entre Brasil e EUA com relação à exportação de *commodities* durante os períodos de 2002 : 01 a 2022 : 07. É notório observar que essa relação possui comportamento oscilatório, destacando o período de 2020 com o advento do início da pandemia do *Covid-19*. Desta forma, um crescimento viesado para as exportações devido aos impactos oriundos da pandemia levou uma piora dos termos de troca do Brasil/EUA. Por outro lado, a partir de 2021 é observado uma melhora do crescimento das exportações, restabelecendo os termos de troca da economia brasileira com a economia americana.



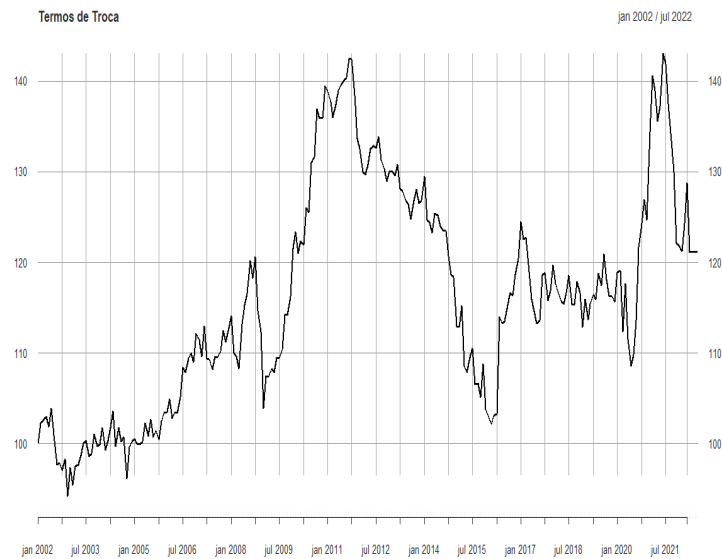


Figura 1: Termos de Troca da economia Brasileira com a economia dos EUA.

**Fonte:** Sistema Gerenciador de Séries Temporais (BCB) e *Federal Reserve Economic Data* (FRED).

**Nota:** Comportamento do gráfico através dos dados da pesquisa.

## 2.5 Base de Dados

A análise empírica do estudo foi fundamentada em séries temporais mensais. Todas as séries de dados coletados para os Estados Unidos são do *Federal Reserve Economic Data* (FRED). Já as variáveis para a Economia brasileira foram coletados do Sistema Gerenciador de Séries Temporais (BCB).<sup>4</sup>

Para os dados referente aos modelos de fundamentos macroeconômicos, na teoria da paridade do poder de compra foi utilizado o Índice Nacional de Preços ao Consumidor Amplo (IPCA) de todos os itens, excluindo alimentos *In Natura*. Tais níveis de preços foram usados para calcular a taxa de inflação brasileira. Para os EUA usamos os Índices de Preços Americanos (IPC -Índice de Preços ao Consumidor). Para medir a produção, foi utilizado o índice de produção industrial do Brasil e dos EUA. O hiato do produto utilizado na Regra de Taylor, é obtido por meio do produto potencial, auferido por meio do filtro Hodrick-Prescott.<sup>5</sup> Também foi utilizado a oferta de moeda M1<sup>6</sup> entre a economia brasileira e americana. Na figura 2 descrevemos o comportamento da oferta monetária M1 entre Brasil e EUA em que é visto que entre ambas as economias ela tem um comportamento distinto, sendo superior para a economia americana logo no início da pandemia do *Covid* - 19, e esta por sua vez, se manteve com o mesmo comportamento nos meses seguintes. Na mesma figura também observamos o comportamento dos Índices de Preços ao Consumidor em que é notório observar que os índices de preços do Brasil são maiores que o dos EUA, demonstrando superioridade em ambos os períodos. Quando observado o gráfico da taxa de crescimento anual da produção industrial entre países, é visto que eles andam conjuntamente,

<sup>4</sup>Banco Central do Brasil - (BCB).

<sup>5</sup>O filtro foi calculado usando o pacote *mFilter* - para remover o componente cíclico de uma série temporal de dados brutos

<sup>6</sup>moeda em poder do público (papel-moeda e moeda metálica) + depósitos à vista nos bancos comerciais. M1 é o total de moeda que não rende juros e é de liquidez imediata.

mas diferente do comportamento do gráfico anterior não há um salto entre países.<sup>7</sup>. As variáveis e suas respectivas fontes são apresentadas na tabela 1, conforme descrita abaixo.

Tabela 1: Variáveis Utilizadas na Descrição dos Fundamentos Macroeconômicos.

<b>Variáveis</b>	<b>Dados</b>	<b>Fontes</b>
Taxa de Câmbio	Taxa de câmbio (real/dólar)	BCB
Taxa de juros - BR	Taxa Selic	BCB
Taxa Efetiva de Fundos Federais	Taxa Efetiva de Fundos Federais	FRED
Produção Industrial (IPI)	Índice de Produção Industrial	BCB/FRED
Nível de Preços - Brasil(IPCA)	Índice Nacional de Preços ao Consumidor Amplo	BCB
Nível de Preços - EUA (IPC)	Índice de Preço ao Consumidor	FRED
Índice de preços (PPI)	Índice de Preço ao Produtor	FRED
<b>Código das Séries</b>		
Taxa de Câmbio	Sisbacen PTAX800	
Taxa de juros - BR	Copom	
Taxa Efetiva de Fundos Federais	DFE	
Produção Industrial (IPI)	IBGE /IndPRO	
Nível de Preços - Brasil(IPCA)	IBGE	
Nível de Preços - EUA (IPC)	USACPIALLMINMEI	
Índice de preços (PPI)	MANMM101USM189S	

**Fonte:** Elaborados pelos autores com a Base de Dados da Pesquisa.

**Nota:** A tabela reporta os Códigos das Séries utilizadas a partir de suas fontes.

Além disso, utilizamos o retorno da taxa de câmbio entre BRL e USD definido como a diferença do logaritmo entre log da taxa de câmbio no período  $t$  e  $t - 1$ . Outra variável observada através do gráfico é o hiato do produto. Esta variável em ambas as economias apresentaram comportamento similar destacando um salto em março de 2020. Por fim, a variável de Produção Industrial mostra que em 2008 a economia americana teve uma queda brusca de sua produção, tal período foi marcado pelo início da crise financeira. Outro ponto a destacar é o período da pandemia do *Covid* -19 em que ambas as economias foram afetadas, porém com maior significância para o Brasil. Utilizamos o logaritmo natural (log) em todas as variáveis.

<sup>7</sup>Os demais gráficos mostrando o comportamento das demais variáveis estão no Apêndice de Tabelas e Figuras.

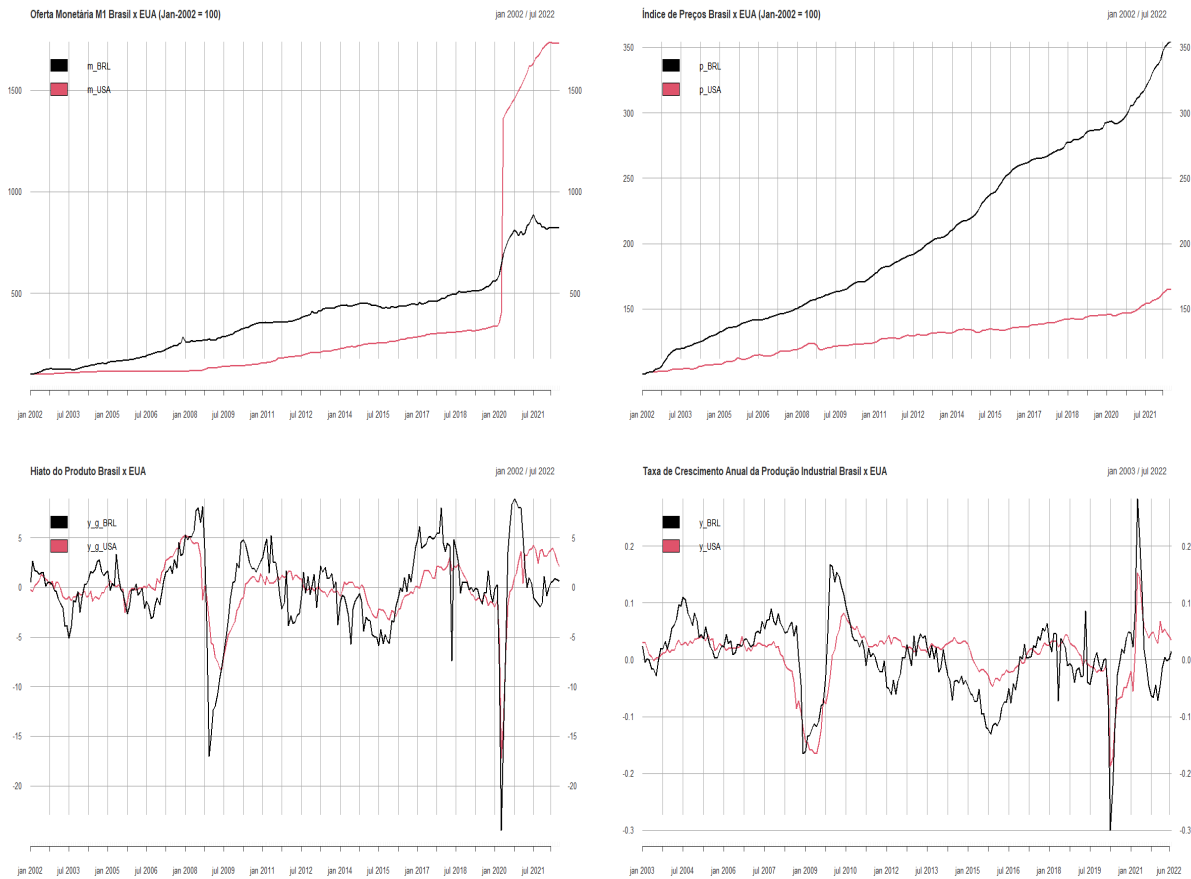


Figura 2: Comportamento da Oferta Monetária M1, Índices de Preços ao Consumidor, Hiato do Produto e Taxa de Crescimento da Produção Industrial para a Economia Brasileira e Americana.

Fonte: Federal Reserve Economic Data (FRED) e Sistema Gerenciador de Séries Temporais (BCB).

## 2.6 Prevendo Fora da Amostra

Especificamente, dividimos a amostra total de observações de  $T = R + P$  em porções dentro da amostra e fora da amostra. As observações dentro da amostra abrangem 1 a  $R$ , enquanto as observações fora da amostra abrangem  $R + 1$  até  $T$  para um total de  $P$  previsões fora da amostra. Para cada origem de previsão  $t = R, \dots, T - 1$ , estimamos recursivamente as regressões preditivas fora da amostra regredindo  $\Delta s_{t+1}$  sobre a constante e um único preditor observado  $x_s^i$  para  $s = 1, \dots, t - 1$  e, portanto, calculamos a previsão como  $\Delta s_{t+1} = \hat{\alpha}_t + \hat{\phi}_t x_t^i$ , onde  $\hat{\alpha}_t$  e  $\hat{\phi}_t$  são o estimativas OLS e  $x_t^i$  denotam um dos preditores (Preditores Macroeconômicos, KS e E-KS) introduzidos nas seções anteriores. Observe que, a estimação recursiva da equação de previsão implica que os coeficientes  $\alpha_t$  e  $\phi_t$  têm permissão para mudar ao longo do tempo.

Os dados na janela de estimativa inicial (IS) começa em 2002.01 e termina em 2010.06 (102 observações). Este período inicial ocorre após o período de três anos do Brasil ter adotado o regime de câmbio flutuante. Já a previsão fora da amostra (OOS) varia de 2010.07 a 2022.06, totalizando  $P = 132$  observações fora da amostra. Este período final é marcado por impactos econômicos ocorrido pela pandemia do *Covid -19*, que iniciou em 2020.03 em conjunto com a retomada da atividade econômica, conjuntamente

com a guerra na Ucrânia com início em 2022.02. Este procedimento de dividir a amostra dentro e fora da amostra nos permitiu estimar com precisão os dados iniciais e ter um período maior fora da amostra.

Nosso procedimento de avaliação de previsão é baseado no  $R^2$ ,  $R_{OS}^2$  fora da amostra, que compara a previsão fora da amostra do modelo de previsão  $\Delta s_{t+1} = \hat{\alpha}_t + \hat{\phi}_t x_t^i$ , para a previsão de *benchmark*<sup>8</sup>

$$\overline{\Delta s_{t+1}} = \frac{1}{t} \sum_{s=1}^t \Delta s_t.$$

Dessa forma, o  $R^2$  fora da amostra é calculado da seguinte forma:

$$R_{OS}^2 = 1 - \frac{\sum_{t=R}^{T-1} (\Delta s_{t+1} - \hat{\Delta s}_{t+1})^2}{\sum_{t=R}^{T-1} (\Delta s_{t+1} - \overline{\Delta s_{t+1}})^2}.$$

Se a previsão  $\hat{\Delta s}_{t+1}$  supera a previsão do *benchmark* então  $R_{OS}^2 > 0$ . Por esse motivo, a estatística  $R_{OS}^2$  está medindo a redução no erro de previsão quadrática média (MSPE) dos modelos de previsão em relação ao modelo de referência (passeio aleatório). Em prática, relatamos o valor de  $R_{OS}^2$  em termos percentuais que implica em multiplicar  $R_{OS}^2$  por 100, ou seja,  $R_{OS}^2 (\%) = 100 \times R_{OS}^2$ .

Ainda, além de observar a magnitude desta estatística verificamos se um determinado modelo preditivo possui uma estatística significativa. Para isso aplica-se o método adotado por [DIEBOLD and MARIANO \(1995\)](#). No entanto, devido ao fato de estarmos trabalhando com um modelo aninhado tal método se torna inviável. Assim, para modelos aninhados [Clark and West \(2007\)](#)<sup>9</sup> aprimoraram o modelo de [DIEBOLD and MARIANO \(1995\)](#) denominado de Erro Quadrado Médio de Previsão Ajustado (MSPE) que significa testar a hipótese nula contra a hipótese alternativa. Logo, tal teste pode ser estimado da seguinte forma:

$$\Delta s_{t+1} = (\Delta s_{t+1} - \overline{\Delta s_{t+1}})^2 - \left[ (\Delta s_{t+1} - \hat{\Delta s}_{t+1})^2 - (\overline{\Delta s_{t+1}} - \hat{\Delta s}_{t+1})^2 \right], \quad (20)$$

Desta forma, encontramos o MSPE regredindo a série  $\{\Delta s_{t+1}\}_{t=R}^{T-1}$  sobre o intercepto e calculamos sua estatística  $t$ . Logo, podemos verificar se as previsões baseadas em modelos  $\hat{r}_{t+1}$  têm um MSPE significativamente menor que o *benchmark* que corresponde a testar a hipótese nula de que  $R_{OS}^2 \leq 0$  contra a hipótese alternativa de que  $R_{OS}^2 > 0$ .

Na literatura de previsão de retorno, os valores percentuais de  $R_{OS}^2 (\%)$  são tipicamente pequenos, mas isso não significa que seu valor econômico é insignificante. De fato, como argumentado por [Campbell and Thompson \(2008\)](#), mesmo um  $R_{OS}^2 (\%)$  muito pequeno como 1.0 % para dados mensais podem ainda sinalizar um grau de previsibilidade do retorno economicamente significativo em termos de aumento do retorno anual da carteira para um investidor de média variância. Calculamos esse valor econômico de uma previsão pelo conhecido equivalente de certeza do retorno (ou ganho de utilidade), que pode ser interpretado como a taxa de administração que um investidor está disposto a pagar para ter acesso às informações adicionais fornecidas pelo modelo de previsão baseada no modelo em relação à informação disponível no modelo de referência (*benchmark*). Neste artigo, calculamos o ganho de utilidade dos modelos de previsão usando o método introduzido por [Campbell and Thompson \(2008\)](#) e [Rapach and Strauss \(2010\)](#).

<sup>8</sup>Nosso modelo *benchmark* é representado pelo Passeio Aleatório (*Random Walk*).

<sup>9</sup>Para modelos aninhados [Clark and West \(2007\)](#) mostram que as estatística de [DIEBOLD and MARIANO \(1995\)](#) tem distribuição fora do padrão, uma vez que, seu teste poderia ser subdimensionado sob a hipótese nula e com baixo poder de previsão sob a hipótese alternativa.

O método pressupõe um investidor avesso ao risco que tem uma função de utilidade de média variância e considera como alocar otimamente a riqueza total entre um ativo arriscado e um ativo livre de risco no momento  $t$  com base na taxa livre de risco atual e na previsão da taxa de câmbio,  $\Delta s_{t+1}$ . Dessa forma, o peso atribuído ao ativo arriscado é calculado da seguinte forma:  $\omega_t = \frac{1}{\gamma} \frac{\hat{\Delta} s_{t+1}}{\hat{\sigma}_{t+1}^2}$ .

Onde  $\gamma$  é o parâmetro de aversão ao risco e  $\hat{\sigma}_{t+1}^2$  é a variância da taxa de câmbio. Assim, o retorno realizado do portfólio no momento  $t + 1$  é  $R_{t+1} = \omega_t \Delta s_{t+1} + (1 - \omega_t)r_{t+1}^f$ . Impomos a restrição  $\omega_t \in (-1, 1)$  para garantir que haja venda a descoberta e/ou alavancagem.

Assim, durante o período fora da amostra, o investidor percebe um nível médio de utilidade de:

$$U = \hat{\mu} - \frac{1}{2}\gamma\hat{\sigma}^2 \quad (21)$$

onde  $\hat{\mu} = \frac{1}{P} \sum_t R_t$ ,  $\sigma_p^2 = Var(R_t) = \frac{1}{P} \sum_t (R_t - \hat{\mu}_p)^2$ , e  $P$  é a quantidade total de observações fora da amostra. O ganho de utilidade é a diferença entre a utilidade obtida usando um modelo baseado na previsão,  $\hat{r}_{t+1}$ , e o modelo de previsão baseado no Passeio Aleatório (*benchmark*),  $\overline{\Delta s_{t+1}}$ . Para facilitar a interpretação, multiplicamos os ganhos de utilidade por 1200, o que nos dá a taxa de administração anual que um investidor estaria disposto a pagar para obter acesso à informação adicional da previsão baseada no modelo  $\hat{r}_{t+1}$ . Além disso, reportamos os resultados utilizando  $\gamma = 3$ <sup>10</sup>.

## 2.7 Passeio Aleatório - *Benchmark*

Para Li et al. (2015) o passeio aleatório captura a visão predominante na literatura cambial de que as taxas de câmbio não são previsíveis quando condicionadas aos fundamentos econômicos, especialmente em horizontes curtos. O modelo também forma a base da estratégia de *carry trade*<sup>11</sup> amplamente utilizada no mercado financeiro.

Segundo Da Silva and Junior (2022) o passeio aleatório sem *drift* com previsões feita fora da amostra (OOS) e um passo a frente de uma variável dependente ( $\Delta s$ ) é descrita como:

$$\widehat{\Delta s}_{t+1} = \Delta s_t \quad (22)$$

Esta equação mostra que a cada horizonte de tempo os valores futuros da variável dependente será igual ao seu último valor observado em  $(t - 1)$ .

## 3 Resultados Empíricos

Para se fazer a previsão da taxa de câmbio entre o real brasileiro (BRL) para o dólar dos Estados Unidos (USD) foi feita uma estimação dentro da amostra de 2002 : 01 a 2010 : 6 (102 observações) e fora da amostra de 2010 : 07 a 2022 : 06 com um total de  $P = 132$  observações. Os dados foram estimados recursivamente ao longo do tempo e a divisão dos mesmos teve como objetivo ter uma amostragem fora da amostra superior. Em um segundo momento se procedeu a análise fora da amostra, traçando os resultados das previsões condicionais de acordo com a estatística  $R_{OS}^2$  (%) e sua significância através dos  $p$  valores

<sup>10</sup>Conforme adotado em Lima and Meng (2017) e Godeiro et al. (2018)

<sup>11</sup>A estratégia de carry trade consiste em tomar emprestado recursos no país com menor taxa de juros e investir no país com maior taxa de juros, a fim de obter-se o diferencial de juros. Nesse caso o investidor corre o risco da taxa de câmbio do país na qual está com a posição comprada.

do procedimentos do Erro Quadrado Médio de Previsão Ajustado (MSPE) de [Clark and West \(2007\)](#), teste (CW) demonstrando que, para valores positivos um dos modelos (Fundamentos Macroeconômicos, KS e E-KS) têm performance superior ao modelo de referência (Passeio Aleatório). Além disso, também foi observado o ganho de utilidade do investidor com preferência de média e variância,  $\Delta U\%$  (anual) associado a cada modelo de previsão. Por fim, os resultados das previsões dos preditores individuais foram expostos na tabela 2, conforme descrita abaixo.

Tabela 2: Resultado das Previsões Fora da Amostra para a Previsão da Taxa de Câmbio BRL (Brasil) e USD (EUA).

<b>Painel A: Modelo Baseado em Fundamentos Macroeconômicos</b>			
Modelo	$R_{OOS}^2\%$	CW	$\Delta U\%$
UIP	0.57	0.24	0.91
PPP	-0.23	0.56	-0.63
MF	-1.87	0.88	-0.31
TR	-0.67	0.67	-0.43
TT	-0.22	0.33	-0.23
<b>Painel B: Modelo Baseado em Regressão Kitchen - Sink</b>			
Modelo	$R_{OOS}^2\%$	CW	$\Delta U\%$
KS	-5.10	0.84	-2.27
<b>Painel C: Modelo Baseado em Regressão Eficiente de Kitchen - Sink</b>			
Modelo	$R_{OOS}^2\%$	CW	$\Delta U\%$
EKS	-0.24	0.93	-0.18
EKS - RIDGE	-5.95	0.75	-2.31
EKS - LASSO	-3.35	0.87	-0.73

A tabela 2 retrata dos valores  $R_{OOS}^2$  (%) fora da amostra em termos percentuais (%) e sua significância através dos  $p$  valores do teste de [Clark and West \(2007\)](#) (CW) além do ganho de utilidade do investidor com preferência média e variância em termos de  $\Delta\%$ . Se  $R_{OOS}^2 > 0$  a previsão condicional do Modelo Baseado Fundamentos Macroeconômicos, Regressão Kitchen-Sink e Regressão Eficiente de Kitchen-Sink supera o Passeio Aleatório (*benchmark*). O ganho de utilidade anual é a taxa de administração que o investidor estaria disposto a pagar para ter acesso às informações adicionais.

A tabela 2 tem-se os resultados referente aos modelos baseados nos Fundamentos Macroeconômicos, na Regressão Kitchen-Sink e na Regressão Eficiente de Kitchen-Sink. O objetivo foi observar se as técnicas de regularização Ridge, LASSO e *Elastic Net* geram robustez a regressão de Kitchen-Sink em combinação com os modelos fundamentais macroeconômicos. Assim, os resultados referente aos modelos baseados nos fundamentos macroeconômicos mostraram que apenas a paridade de juros a descoberta obteve o  $R_{OOS}^2$  (%) positivo e estatisticamente significativo maior que zero, com desempenho superior ao passeio aleatório em 0.57%. Outra observação é que, o preditor de Paridade do Poder de Compra (PPP) mostrou-se negativo, sendo inferior ao Passeio Aleatório em (-0.23%), o que implica dizer que há uma desvalorização cambial do BRL em relação ao USD, logo, uma unidade unitária comprada no seu país de origem (Brasil) não tem o mesmo poder de compra no outro país (EUA). Ainda na mesma tabela

observamos os resultados referente ao modelo baseado na regressão de Kitchen-Sink, é verificado um resultado não positivo, sendo seu valor inferior em  $(-5.10\%)$ .

Dando continuidade as classes dos demais modelos, temos que nos modelos baseados na Regressão Eficiente de Kitchen-Sink mostraram que são estatisticamente inferior ao Passeio Aleatório quando observado a estatística  $R_{OS}^2$  (%) sendo o EKS de  $(-0.24\%)$ , EKS-Ridge  $(-5.95\%)$  e o EKS-LASSO  $(-3.35\%)$ . Embora o *Elastic Net* seja aninhado aos dois anteriores, o seu resultado não obteve uma performance significativa. Ainda notamos que o MSPE do teste Clark and West (2007) demonstra que de fato ambos os modelos não apresentam superioridade em relação ao *benchmark*, sendo seus resultados acima de 80% para ambos os modelos.

Finalmente, são apresentados os resultados dos ganhos de utilidade do investidor de média variância, cuja alocação foi estabelecida a partir dos modelos de previsões. Desta forma, a Paridade de Juros a Descoberta apresentou o maior ganho de utilidade ao investidor, superando o Passeio Aleatório em 0.91%. Os demais preditores não apresentaram ganho de utilidade ao investidor, ocasionando a não maximização de sua função. Estes valores variaram de  $(-0.63\%)$  e  $(-0.23\%)$  para os modelos baseados em fundamentos macroeconômicos e de  $(-2.27\%)$  para a regressão Kitchen-Sink e por fim, a variação de  $(-0.18\%)$  a  $(-0.73\%)$  para os modelos Eficientes de Kitchen-Sink.

## 4 Considerações Finais

A utilização de modelos baseados em fundamentos macroeconômico combinado com técnicas específicas tem sido amplamente usado para se fazer a análise de previsão da taxa de câmbio entre países. Desta forma, o artigo investigou se técnicas de aprendizado de máquina aprimoraram a regressão de Kitchen-Sink combinadas com teorias fundamentais macroeconômicas para a previsão da taxa de câmbio entre BRL (Brasil) e o USD (EUA), e se tais procedimentos geraram resultados mais robustos que o passeio aleatório (*benchmark*).

Os resultados observados dos modelos em fundamentos macroeconômicos em sua maioria não conseguem bater o *benchmark* de Passeio Aleatório, a diferenciar o UIP que apresentou ganho estatístico em relação ao referencial, além de ser o único com ganho de utilidade ao investidor de média variância. Desta forma, este preditor consegue passar informação ao investidor avesso ao risco cambial de que na alocação dinâmica de ativos em um determinado mês ou meses o melhor para ele é ficar distante de ativos arriscados, maximizando sua utilidade ao alocar pesos em ativos com risco  $r_{t+1}$  e em ativo sem risco,  $r_{t+1}^f$ .

Posteriormente foi observado que, ao acrescentar o *Elastic Net* para aprimorar a modelagem de Kitchen-Sink é visto que não há significância quando observada a estatística de Clark and West (2007), (CW). Desta forma, a regressão Eficiente de Kitchen-Sink não geram resultados robustos na previsão, sendo este não eficiente para análise de taxa de câmbio entre o BRL e o USD. Este resultado é contrário aos trabalhos de Li et al. (2015) e Da Silva and Junior (2022) ao observarem que da associação de modelos de aprendizado de máquina com modelos de fundamentos macroeconômicos os resultados batem o modelo de passeio aleatório. Estes trabalhos adotam modelagens distintas para aprendizado de máquina, de forma que, o primeiro utiliza apenas o *Elastic Net* para aprimorar a regressão de Kitchen-Sink para a previsão da taxa de câmbio do G10; já o segundo por sua vez, utiliza três técnicas distintas de aprendizado de máquina para previsão entre BRL e o USD.

Diante disso, os resultados mostram que o aprimoramento da regressão de Kitchen-Sink em quase sua totalidade não foi possível fazer previsões sobre a taxa de câmbio entre o BRL e o USD, a diferenciar

de um único modelo de fundamentos macroeconômicos. Além disso, é importante destacar que para o comportamento do ganho de utilidade de um investidor esses preditores não ajudaram a diminuir o risco cambial ao investidor, mas apenas um preditor passa informação. Neste sentido, recomenda-se utilizar outros preditores como no estudo de [Da Silva and Junior \(2022\)](#), assim como, fazer análise para outras moedas, como em [Li et al. \(2015\)](#).

## Referências

- Campbell, J. Y. and Thompson, S. B. (2008). Predicting excess stock returns out of sample: Can anything beat the historical average? *The Review of Financial Studies*, 21(4):1509–1531.
- Cassel, G. (1918). Abnormal deviations in international exchanges. *The Economic Journal*, 28(112):413–415.
- Clark, T. E. and West, K. D. (2007). Approximately normal tests for equal predictive accuracy in nested models. *Journal of econometrics*, 138(1):291–311.
- Da Silva, G. P. and Junior, J. L. R. (2022). Real/dollar exchange rate prediction combining machine learning and fundamental models.
- DIEBOLD, F. and MARIANO, R. (1995). Comparing predictive accuracy. *journal of business and economics statistics*, v. 13.
- Dornbusch, R. (1975). Exchange rates and fiscal policy in a popular model of international trade. *The American Economic Review*, 65(5):859–871.
- Engel, C., Mark, N. C., West, K. D., Rogoff, K., and Rossi, B. (2007). Exchange rate models are not as bad as you think [with comments and discussion]. *NBER macroeconomics annual*, 22:381–473.
- Engel, C. and West, K. (2006). Taylor rules and the deutschmark dollar real exchange rate. *Journal of Money, Credit and Banking*, 38 : 1175.
- Frenkel, J. A. (1978). Purchasing power parity: doctrinal perspective and evidence from the 1920s. *Journal of International Economics*, 8(2):169–191.
- Godeiro, L. L. et al. (2018). Ensaios sobre modelos de previsão econômica.
- Li, J., Tsiakas, I., and Wang, W. (2015). Predicting exchange rates out of sample: Can economic fundamentals beat the random walk? *Journal of Financial Econometrics*, 13(2):293–341.
- Lima, L. R. and Meng, F. (2017). Out-of-sample return predictability: A quantile combination approach. *Journal of Applied Econometrics*, 32(4):877–895.
- Meese, R. A. and Rogoff, K. (1983). Empirical exchange rate models of the seventies: Do they fit out of sample? *Journal of international economics*, 14(1-2):3–24.
- Moosa, I. and Burns, K. (2014). The unbeatable random walk in exchange rate forecasting: Reality or myth? *Journal of Macroeconomics*, 40:69–81.



- Mussa, M. (2019). The exchange rate, the balance of payments and monetary and fiscal policy under a regime of controlled floating. In *Flexible Exchange Rates and Stabilization Policy*, pages 97–116. Routledge.
- Officer, L. H. (1976). The purchasing-power-parity theory of exchange rates: A review article. *Staff Papers*, 23(1):1–60.
- Rapach, D. E. and Strauss, J. K. (2010). Bagging or combining (or both)? an analysis based on forecasting us employment growth. *Econometric Reviews*, 29(5-6):511–533.
- Rapach, D. E. and Wohar, M. E. (2002). Testing the monetary model of exchange rate determination: new evidence from a century of data. *Journal of International Economics*, 58(2):359–385.
- Soares, Fernando Antônio Ribeiro e Pinto, M. B. d. P. (2008). Desequilíbrios cambiais e os fundamentos econômicos: uma análise do plano real. *Revista de Economia Contemporânea*, 12:5–40.
- Zhang, Y. and Hamori, S. (2020). The predictability of the exchange rate when combining machine learning and fundamental models. *Journal of Risk and Financial Management*, 13(3):48.
- Zou, H. and Hastie, T. (2005). Regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 67(2):301–320.

# Tabelas e Figuras



Figura 3: Os gráficos denotam o comportamento das variáveis: Produção Industrial e Taxa de Crescimento Mensal da Produção Industrial entre Brasil e EUA.

Comportamento das variáveis utilizadas para descrever os fundamentos macroeconômicos, com base na série temporal fora da amostra, 2010 : 07 a 2002 : 06. O primeiro gráfico denota o comportamento da produção industrial entre Brasil e EUA, mostrando um comportamento com quedas distintas, porém seguindo a mesma trajetória. Já o segundo gráfico, por sua vez, denota o comportamento da taxa mensal da produção industrial, constatando a mesma conduta oscilatória.

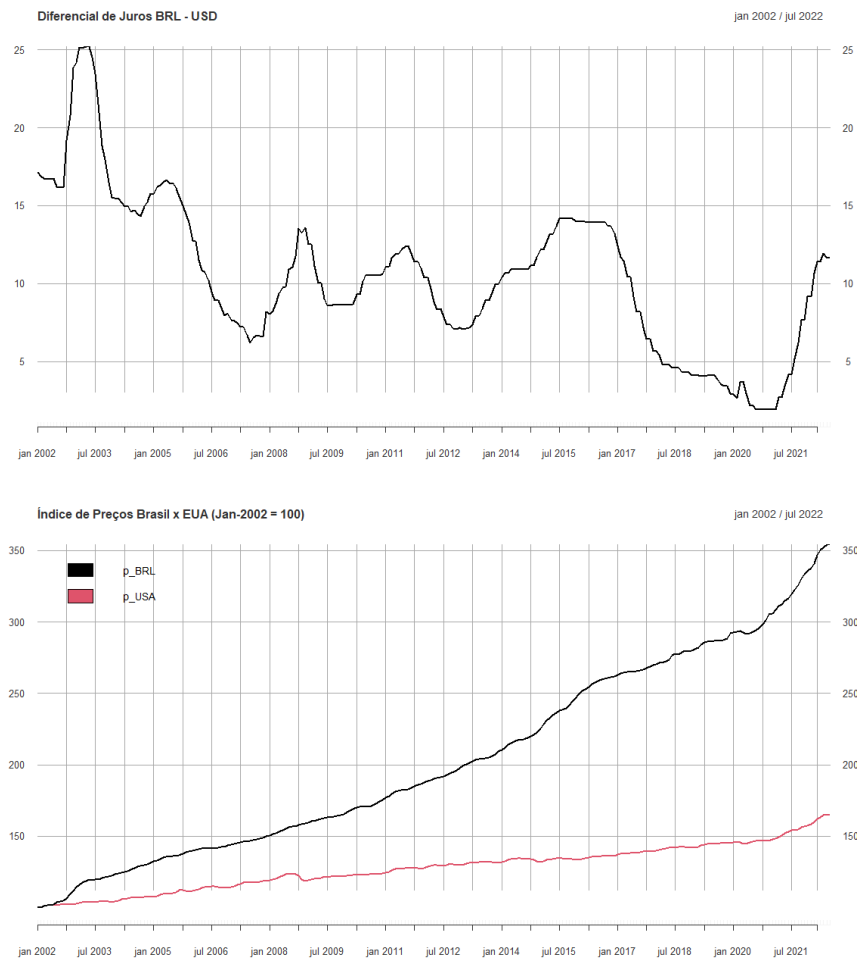


Figura 4: Os gráficos denotam o comportamento das variáveis Data pi, diferencial de juros, Stop x Forward Rate e o Índice de Preços do Brasil e EUA.

Comportamento das variáveis utilizadas para descrever os fundamentos macroeconômicos, com base na série temporal fora da amostra, 2010 : 07 a 2002 : 06. O primeiro gráfico denota os resultados do diferencial de juros (brl-usd) especificando choques em determinados períodos. Já o segundo gráfico denota o comportamento dos índices de preços brasil versus EUA, onde é visto que ambos seguem trajetória distintas, sendo para os EUA menor que no Brasil em ambos os períodos da série.