

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

*Diógenes Pinheiro de Medeiros Júnior

† Elvira Helena Oliveira de Medeiros

‡ Lucas Lucio Godeiro

§ Diego Pitta de Jesus

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-Sink 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 2012:12 e fora da amostra de 2013:01 a 2024:06. Os resultados encontrados mostraram que o modelo eficiente de Kitchen-Sink 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. Por fim, foi realizada uma análise de robustez em que os modelos foram estimados em subamostras. Os resultados encontrados com a robustez confirmaram a acurácia da modelagem.

Palavras-chave: Taxa de Câmbio; Aprendizado de Máquina Supervisionado; Fundamentos Macroeconômicos; Regressão de Kitchen-Sink.

Abstract

The paper aims to use recursively supervised machine learning techniques via Ridge, LASSO and Elastic Net to improve the Kitchen-Sink regression in predicting 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 macroeconomic fundamentals, among them: uncovered interest parity, purchasing power parity, monetary fundamentals, Taylor rule and terms of trade, in order to verify their explanatory power in relation to the model. reference (Random Walk) in the in-sample period from 2002:01 to 2012:12 and out-of-sample from 2013:01 to 2024:06. The results found showed that the efficient Kitchen-Sink model cannot statistically/economically predict the exchange rate. On the other hand, only the UIP predictor performed well, outperforming the benchmark, in addition to promoting utility gains for investors averse to exchange rate risk. Finally, a robustness analysis was performed in which the models were estimated in subsamples. The results found with robustness confirmed the accuracy of the modeling.

Keywords: Exchange Rate; Supervised Machine Learning; Macroeconomic Fundamentals; Kitchen-Sink regression.

JEL Classification: C01, C22.

Área Temática - Econometrics and Numerical Methods

*Mestre em Economia Aplicada - UERN e Especialização em Gestão Ambiental com Ênfase em Auditoria e Perícia - FVJ diognspmjr@gmail.com

†Doutoranda em Economia Aplicada - UFJF e Mestre em Economia Aplicada – UERN ravilelenna@yahoo.com.br - Financiada por meio de bolsa CAPES.

‡Doutor em Economia Aplicada - UFPB e Professor da Universidade Federal Rural do Semi Árido lucasgodeiro@ufersa.edu.br

§Doutor em Economia Aplicada - UFPB e Professor da Universidade Federal Rural de Pernambuco diegopitta13@hotmail.com

1 – Introdução

A taxa de câmbio é um dos principais indicadores econômicos que afeta a economia brasileira, e como tal, enfrenta vários desafios. O trabalho tenta modelar alguns aspectos baseados nos princípios macroeconômicos e técnicas aprendizado de máquina supervisionado.

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 e Burns (2014). Segundo Zhang e Hamori (2020), esses modelos de fundamentos macroeconômicos usuais não apresentaram melhores desempenhos quando comparado com o modelo de passeio aleatório, mesmo após a introdução do sistema de câmbio flutuante. Meese e 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 macroeconômica fundamentais 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 e Rossi 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*.

O objetivo deste projeto é avaliar se a combinação de fundamentos macroeconômicos e técnicas de aprendizado de máquina supervisionado recursivamente fora da amostra melhora a capacidade preditiva da regressão de *Kitchen-Sink* na previsão da taxa de câmbio entre o real (BRL) e o dólar (USD). Este estudo apresenta um diferencial em relação a pesquisas anteriores ao incluir um novo preditor, os Termos de Troca, com o objetivo de avaliar o impacto do crescimento desses termos no comércio

internacional brasileiro. Para fornecer uma análise mais precisa, foram contemplados dois diferentes níveis de agregação: o total das exportações e importações brasileiras e os setores produtivos relacionados aos bens exportados e importados, considerando a importância do comércio internacional para a economia do país. Além disso, o estudo utiliza os quatro preditores dos fundamentos macroeconômicos mais comumente empregados na literatura: Paridade de Juros Descoberta, Paridade do Poder de Compra, Fundamentos Monetários e Regra de Taylor. A inclusão do novo preditor, juntamente com os preditores já estabelecidos, pode fornecer informações adicionais e significativas para entender o comportamento do câmbio brasileiro.

Além disso, também pretende-se calcular 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 serão calculados mensalmente e divididos em períodos dentro e fora da amostra. Os dados da janela de estimativa inicial (IS) começaram em 01/2002 e terminaram em 12/2012 (132 observações). Já a janela fora da amostra (OOS) varia entre 01/2013 a 06/2024 (138 observações), gerando uma janela de 270 previsões.

O período de observação fora da amostra utilizado neste estudo foi o mesmo utilizado no artigo de Li (2015), uma vez que o objetivo é aplicar métodos semelhantes aos utilizados em seu trabalho. Por essa razão, optamos por adotar o mesmo período de tempo utilizado no artigo original.

2 – Metodologia e Dados

Para nossa análise, tomamos como base o método empregado no artigo de Li (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 os suficientes para superar uma previsão sem mudança, como é o caso do passeio aleatório, Moosa e 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 e Rossi Junior (2022).

Nossa metodologia consiste em várias etapas. Na primeira etapa, abordaremos a regressão *Kitchen-Sink*, descrevendo suas especificações e seu poder de previsão. Na segunda etapa, utilizaremos modelos de aprendizado de máquina supervisionado (SML) para aprimorar a capacidade preditiva da regressão *Kitchen-Sink*. Na terceira etapa, utilizaremos regressores baseados em fundamentos macroeconômicos, seguindo a teoria padrão de determinação da taxa de câmbio comumente utilizada na literatura, para aplicação dos dados usaremos a linguagem de programação R, o desenvolvimento será em conjunto com os aplicativos R e RStudio. Por fim, avaliaremos a capacidade preditiva dos modelos empíricos da taxa de câmbio fora da amostra, comparando-os com o modelo de referência, o passeio aleatório (*benchmark*).

2.1 – Regressão *Kitchen-Sink*

A regressão *kitchen-sink* é uma técnica de análise estatística que envolve o uso de um grande número de variáveis explicativas para modelar um resultado. Essa abordagem é conhecida por incluir muitas variáveis independentes, mesmo aquelas que podem não ter relação clara com o resultado, em um modelo de regressão.

No entanto, o uso da regressão *kitchen-sink* tem sido criticado por levar a modelos excessivamente complexos e, muitas vezes, de difícil interpretação. Além disso, a inclusão de variáveis irrelevantes pode afetar negativamente a precisão das previsões do modelo.

Existem abordagens mais recentes que tentam abordar essas questões, como a seleção de variáveis Lasso (Least Absolute Shrinkage and Selection Operator) ou a análise de componentes principais para reduzir a dimensão dos dados antes de executar uma regressão.

Conforme adotado em Li (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 ε_{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 apresentadas 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 gera resultados não robustos¹. Visando corrigir possíveis erros de especificações no modelo, utilizamos os métodos de regularização para melhorar a precisão preditiva da regressão KS, Li (2015).

2.2 – Métodos de Regularização

Nesta seção, detalharemos o processo pelo qual determinamos o modelo preditivo mais eficiente, avaliando o desempenho estatístico de um conjunto de modelos de previsão da taxa de câmbio para a regressão KS. Para tanto, utilizamos diversas técnicas de avaliação de modelos, a fim de garantir a precisão e consistência dos resultados obtidos.

Para avaliar o desempenho de cada modelo, utilizamos técnicas estatísticas, como o coeficiente de determinação (R^2) e o Mínimos Quadrados Ordinários (MQO). Além disso, dividimos os dados em um conjunto de treinamento e um conjunto de teste para avaliar o desempenho dos modelos fora da amostra.

Medeiros (2021) interpreta o método dos Mínimos Quadrados Ordinários (MQO) sendo 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 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

¹ Ao colocar todos os preditores numa mesma equação a variância do modelo aumenta, violando propriedades de Gauss-Markov.

diminui devido ao aumento da variância entre as covariáveis da regressão 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 sobre análise de regressão tem destacado a importância de lidar com problemas de multicolinearidade, uma vez que esse fenômeno pode afetar a precisão e a interpretação dos resultados da regressão. Felizmente, um método eficaz para solucionar a multicolinearidade é conhecido como "*shrinkage*", ou encolhimento, que tem se mostrado uma técnica promissora.

Em essência, o encolhimento consiste em ajustar os coeficientes da regressão de modo a reduzir sua variabilidade, ao mesmo tempo em que se mantém a acurácia das estimativas. Isso é feito introduzindo um termo de penalização na função de perda utilizada na regressão. O termo de penalização funciona reduzindo a magnitude dos coeficientes, de forma que eles se aproximem de zero, o que pode ajudar a resolver o problema de multicolinearidade.

O encolhimento pode ser realizado de diversas maneiras, sendo que duas das mais populares são a regressão Ridge e a regressão lasso. Na regressão Ridge, a penalização é aplicada adicionando um termo quadrático aos coeficientes na função de perda, enquanto na regressão lasso, é aplicado um termo linear. Cada método tem suas vantagens e desvantagens, e a escolha entre eles depende das características específicas do problema em questão.

Em suma, o encolhimento tem se mostrado uma técnica eficaz para solucionar problemas de multicolinearidade na regressão. É importante lembrar que a multicolinearidade pode afetar negativamente a qualidade dos resultados da regressão, e que, portanto, é fundamental utilizar métodos adequados para lidar com esse problema. O encolhimento é uma ferramenta poderosa que pode ajudar a melhorar a precisão e a interpretação dos resultados da regressão, e merece ser considerado em qualquer análise estatística que envolva múltiplas variáveis correlacionadas.

Essa técnica se baseia na aplicação de penalidades entre os coeficientes da regressão, a fim de evitar a instabilidade dos parâmetros. No entanto, há um ônus de vies nos parâmetros resultantes, embora a variância seja menor em comparação ao método de mínimos quadrados ordinários (MQO). Nesse contexto, exploramos técnicas de regularização para a regressão KS, com o objetivo de reduzir o impacto da multicolinearidade nos resultados. Conforme destacado por Li (2015), esses métodos buscam reduzir os coeficientes a zero, o que é o padrão de referência do modelo de passeio aleatório (*benchmark*).

2.3 – LASSO, Ridge e Elastic Net

LASSO, Ridge e Elastic Net são técnicas de regressão utilizadas para lidar com problemas de multicolinearidade e seleção de variáveis em modelos com muitas variáveis independentes.

A técnica LASSO (Least Absolute Shrinkage and Selection Operator) é usada para selecionar um subconjunto de variáveis independentes relevantes para o modelo, enquanto o restante é reduzido a zero. A técnica de Ridge, por sua vez, é usada para reduzir a magnitude dos coeficientes do modelo, limitando sua magnitude total. Por fim, a técnica Elastic Net é uma combinação das duas técnicas anteriores, utilizando tanto a penalização L1 (utilizada pelo LASSO) quanto a penalização L2 (utilizada pelo Ridge).

A principal diferença entre as três técnicas é a forma como as penalidades são aplicadas aos coeficientes do modelo, o que resulta em diferentes padrões de seleção de variáveis e redução de magnitude dos coeficientes.

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:

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

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

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

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 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 e 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*”² 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) teremos que estimada recursivamente até o final da amostra, ou seja, para cada origem da previsão $t = R, \dots, T - 1$ ³, regredimos as observações Δs_{t+1} para $s = 1, \dots, t - 1$, implicando que o vetor de coeficiente β_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

² 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.

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

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 (2015).

2.4 – Preditores Macroeconômicos

A previsão da taxa de câmbio é uma questão importante em finanças e economia, pois influencia o comércio internacional e o fluxo de capitais. Para determinar a previsão da taxa de câmbio entre o real brasileiro (BRL) e o dólar americano (USD), é necessário considerar as teorias fundamentais da macroeconomia.

Existem diversas teorias macroeconômicas que podem ser utilizadas para prever a taxa de câmbio, deve-se levar em consideração 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 Descoberta é uma teoria que postula que as taxas de juros de diferentes países são determinadas pela taxa de câmbio entre suas moedas. Essa teoria sugere que, em um mercado financeiro eficiente, a diferença entre as taxas de juros de dois países deve ser igual à taxa de câmbio esperada entre suas moedas. Em outras palavras, a Paridade de Juros Descoberta implica que a diferença entre as taxas de juros nominais em dois países deve ser igual à diferença entre as taxas de câmbio esperadas entre suas moedas.

A Paridade de Juros Descoberta tem sido objeto de muita pesquisa e debate na literatura econômica. Alguns estudos sugerem que a Paridade de Juros Descoberta pode ser uma boa aproximação do comportamento do mercado financeiro em curtos períodos de tempo. No entanto, outros estudos mostram que a Paridade de Juros Descoberta pode ser violada em períodos mais longos, devido a fatores como riscos cambiais, custos de transação e incertezas na previsão da taxa de câmbio.

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:

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

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 (PPC) estabelece uma relação entre os preços de bens e serviços em diferentes países e a taxa de câmbio entre suas moedas. De acordo com a PPC, em um mercado financeiro eficiente, a taxa de câmbio deve refletir a diferença entre os níveis de preços de bens e serviços em diferentes países.

Em outras palavras, se um determinado bem ou serviço tem um preço maior em um país do que em outro, a moeda desse país deve se desvalorizar em relação à moeda do país onde o bem ou serviço é mais barato. Por exemplo, se uma lata de refrigerante

custa US\$ 1,50 nos Estados Unidos e R\$ 5 no Brasil, a PPC sugere que a taxa de câmbio entre o dólar americano e o real brasileiro deve ser de cerca de 1 dólar para 3,33 reais.

A PPC é uma teoria importante na análise dos mercados financeiros internacionais e tem implicações significativas para a formulação de políticas econômicas. Os governos podem monitorar os níveis de preços de bens e serviços em seu país em relação a outros países para avaliar a competitividade de sua economia e identificar possíveis barreiras comerciais.

Apesar das limitações da PPC, ela continua sendo uma teoria importante na análise dos mercados financeiros globais e na formulação de políticas econômicas. Por exemplo, a PPC pode ser utilizada para avaliar o comportamento de diferentes moedas em relação umas às outras e identificar possíveis desequilíbrios comerciais.

A paridade do poder de compra (PPC) basicamente é a conversão do índice de preço entre a taxa de câmbio. Para Li (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 foi 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 p , obtemos a seguinte equação:

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

Usando as equações 7 e 8 obtemos a seguinte equação:

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

O valor de $p\pi^*$ 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 e Hamori (2020) a equação (10) mostra uma relação entre a taxa de câmbio a taxa de inflação. Para fazer tal relação o projetamos utilizar o Índice Nacional de Preços ao Consumidor Amplo (IPCA) de todos os itens, excluindo alimentos in natura. Para medir a produção, utilizaremos o índice de produção industrial do Brasil e dos EUA.

2.4.3 – Fundamentos Monetários

Fundamentos monetários referem-se aos elementos básicos que compõem a política monetária de um país. Como explicado por Mankiw (2016), os fundamentos monetários são compostos pelas medidas adotadas pelo banco central para controlar a oferta de dinheiro na economia, as taxas de juros, a base monetária, a inflação e a taxa de câmbio.

Para Soares (2008), um número considerável de trabalhos aponta 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 descontrole 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 e 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. Segundo 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 trabalho se baseou no estudo de Zhang e 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 e Wohar (2002).

Em resumo, os fundamentos monetários são essenciais para a estabilidade econômica de um país. Eles são compostos pela oferta de dinheiro, taxa de juros, base monetária, inflação e taxa de câmbio, e são influenciados pelas políticas monetárias adotadas pelo banco central.

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 e Hamori (2020). Contudo, nos últimos anos tal teoria vem sendo modificada. Autores como Engel e West (2006) aprimoram a regra de Taylor e função da política monetária. Desta forma, a regra de Taylor relaciona a 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 π_t é a taxa de inflação interna, π_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

Os termos de troca (TDT) representam a relação entre o preço das exportações e o preço das importações de um país em um determinado período. Essa relação é importante para a economia, pois afeta a capacidade de um país de gerar receita com suas exportações e, conseqüentemente, seu poder de compra de bens importados. Os termos de troca são calculados como a razão entre o índice de preços das exportações e o índice de preços das importações, normalmente expressos como uma porcentagem. Essa relação pode ser influenciada por fatores como a demanda global por bens, a oferta de bens no mercado internacional, flutuações cambiais e políticas comerciais. Portanto, os termos de troca são uma variável importante a ser considerada ao analisar o comércio internacional de um país, por conseqüente é um preditor que provavelmente possui expectativas em nosso trabalho. Empiricamente, tem a seguinte representação:

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

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

O Brasil é uma das principais economias emergentes do mundo e possui um setor exportador diversificado, com destaque para as commodities. A figura 1 apresenta a evolução dos termos de troca no Brasil no período de 2002 a dezembro de 2022, tendo como base a exportação de commodities.

Observa-se na figura 1 que os termos de troca apresentam uma tendência oscilatória ao longo do período analisado, com variações que refletem tanto as flutuações do mercado internacional de commodities quanto as mudanças nas políticas econômicas dos países.

Em particular, destaca-se a queda acentuada dos termos de troca em 2020, que coincidiu com o início da pandemia da COVID-19. O impacto negativo da crise sanitária na economia global resultou em uma diminuição da demanda por commodities e uma redução nos preços desses produtos. Como resultado, o Brasil enfrentou uma piora dos termos de troca.

No entanto, a partir de 2021, verifica-se uma recuperação das exportações de commodities do Brasil, o que contribuiu para a melhora dos termos de troca. Esse resultado pode ser atribuído à retomada do crescimento da economia global e ao aumento da demanda por commodities, impulsionado pela recuperação das principais economias mundiais.

Em resumo, a figura 1 evidencia a relação entre as exportações de commodities do Brasil e os termos de troca, mostrando que essa relação é influenciada por diversos fatores econômicos e políticos. A análise dos termos de troca é importante para compreender a dinâmica do comércio internacional e avaliar a competitividade da economia brasileira em relação a outros países.

Figura 1: Termos de Troca da economia Brasileira.



Fonte: Ipea data

Nota: Comportamento do gráfico através dos dados da pesquisa.

2.5 – Base de Dados

A análise empírica deste estudo se baseou em séries temporais mensais, sendo que todas as séries de dados coletadas para os Estados Unidos foram obtidas do Federal Reserve Economic Data (FRED). As variáveis correspondentes à economia brasileira, por

sua vez, foram coletadas do Sistema Gerenciador de Séries Temporais do Banco Central do Brasil (BCB)⁴.

Para a modelagem dos fundamentos macroeconômicos, utilizamos a teoria da paridade do poder de compra e, para isso, utilizamos o Índice Nacional de Preços ao Consumidor Amplo (IPCA) de todos os itens, excluindo alimentos *in natura*, como medida da inflação brasileira. No caso dos Estados Unidos, utilizamos os Índices de Preços ao Consumidor (IPC) como medida da inflação. Essas séries de dados foram coletadas do Federal Reserve Economic Data (FRED) para os Estados Unidos e do Sistema Gerenciador de Séries Temporais (SGS) do Banco Central do Brasil para a economia brasileira. A utilização dessas variáveis é importante para a compreensão das forças que afetam a taxa de câmbio entre o real (BRL) e o dólar (USD).

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-Prescott⁵. Também será utilizado a oferta de moeda M1⁶ 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 está 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, mas diferente do comportamento do gráfico anterior não há um salto entre países⁷. As variáveis e suas respectivas fontes são apresentadas na tabela 1, conforme descrita abaixo.

Tabela 1: Variáveis Utilizadas na Descrição dos Fundamentos Macroeconômicos.

Variáveis	Dados	Fontes
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	BCB
Nível de Preços - EUA (IPC)	Índice de Preço ao Consumidor	FRED
Índice de preços (PPI)	Índice de Preço ao Produtor	FRED
Código das Séries		
Taxa de Cambio	SISBACEN PTAX800	
Taxa de Juros – BR	COPOM	
Taxa Efetiva de Fundos Federais	DFE	

⁴ Banco Central do Brasil - (BCB).

⁵ O filtro foi calculado usando o pacote mFilter - para remover o componente cíclico de uma serie temporal de dados brutos

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

⁷ Os demais gráficos mostrando o comportamento das demais variáveis estão no Apêndice de Tabelas e Figuras

Produção Industrial (IPI)
Nível de Preços – Brasil (IPCA)
Nível de Preços - EUA (IPC)
Índice de Preços (PPI)

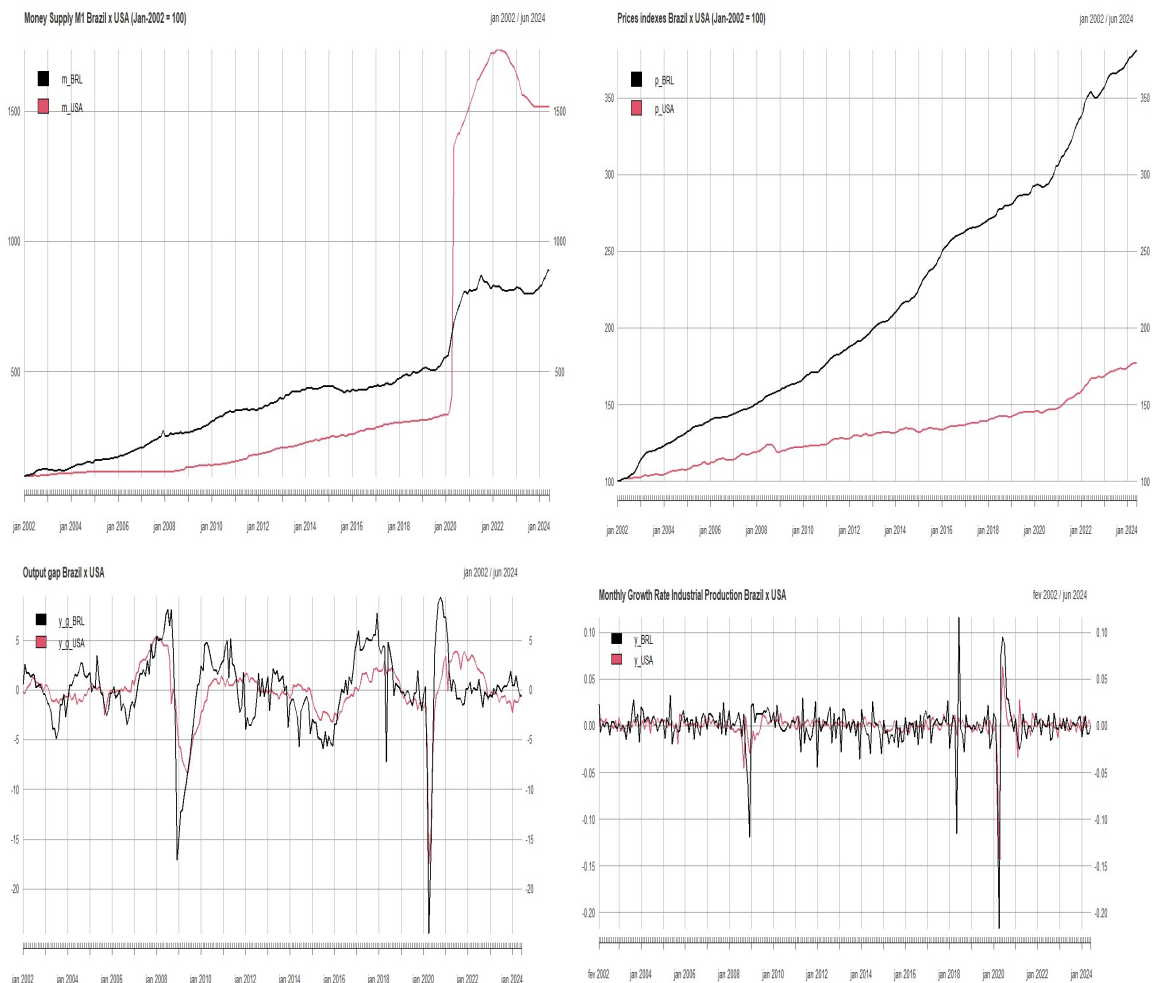
IBGE /IndPRO
IBGE
USACPIALLMINMEI
MANMM101USM189S

Fonte: Elaborado pelo autor com a Base de Dados da Pesquisa.

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

Além disso, utilizaremos 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 apresentou 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.

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





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

2.6 – Prevendo Fora da Amostra

Nesta seção, apresentaremos a metodologia que utilizaremos para realizar previsões fora da amostra. Essa abordagem já foi aplicada em alguns trabalhos anteriores, como os estudos de Godeiro e Lima (2018) e Medeiros (2021). Para isso, faremos uso de conteúdos e citações desses trabalhos, tanto de forma direta quanto indireta.

De forma convergente utilizada por (Medeiros, 2021, *apud* Godeiro e Lima, 2018) 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 $t = R, \dots, T - 1$, devemos estimar recursivamente as regressões preditivas fora da amostra regredindo Δs_{t+1} sobre a constante e um único preditor observado x_s^t 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 α_t e ϕ_t têm permissão para mudar ao longo do tempo.

Os dados na janela de estimativa inicial começam em janeiro de 2002 e termina em dezembro de 2012 (132 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 janeiro de 2013 a junho de 2024, totalizando $P = 138$ observações fora da amostra, realizaremos outro teste para avaliar o poder preditivo em diferentes períodos, dividindo a amostra de 138 observações em três subamostras de períodos diferentes para analisar os impactos auferidos pela COVID-19, sendo esses; Pré-Covid que são os dados da economia antes do período pandêmico, período Covid-19 este dados são do ciclo da pandemia e por último o período pós-covid que são dados de todo o período durante e até o mês de junho de 2024. Todo o período pandêmico é marcado por impactos econômicos ocorrido pela pandemia do Covid-19, que iniciou em 2020/02 em conjunto com a retomada da atividade econômica, conjuntamente com a guerra na Ucrânia com início em 2022/02.

Para realizar a avaliação da previsão, utilizaremos o modelo descrito por Godeiro e Lima (2018). Este modelo realiza a avaliação por meio dos seguintes procedimentos:

no R^2 , R_{OS}^2 fora da amostra, que compara a previsão fora da amostra do modelo de previsão $\Delta s_{t+1} = \hat{\alpha}_t + \hat{\varphi}_t x_t^i$, para a previsão de *benchmark*⁸. $\bar{\Delta} s_{t+1} = \frac{1}{t} \sum_{s=1}^t \Delta s_t$

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

$$R_{OS}^2 = 1 - \frac{\sum_{t=R}^{T-1} (\Delta s_{t+1} - \hat{\Delta} s_{t+1})^2}{\sum_{t=R}^{T-1} (\Delta s_{t+1} - \bar{\Delta} s_{t+1})^2} \quad (20)$$

Onde Medeiros (2021) enfatiza que $\hat{\Delta} s_{t+1}$ 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 R_{OS}^2 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, $R_{OS}^2 (\%) = 100 \times R_{OS}^2$.

O modelo Clark e West é um aprimoramento do método proposto por Diebold e Mariano (1995) para avaliar a precisão de previsões. Em vez de comparar os erros de previsão médios entre dois modelos, como no método de Diebold e Mariano, o modelo Clark e West compara as previsões dos modelos diretamente com a série temporal observada.

Segundo Clark e West (2007), o MSPE pode ser estimado da seguinte maneira: primeiro, a série temporal $\{\Delta s_{t+1}\}_{t=R}^{T-1}$ é regredida em um modelo de referência e em um modelo alternativo, e então o erro quadrático médio de previsão é calculado para cada modelo. Em seguida, é calculada a diferença entre os dois erros de previsão, ajustando-se para a possível correlação entre os erros de previsão. Finalmente, é realizado um teste de hipótese para determinar se o MSPE ajustado é estatisticamente diferente de zero.

Logo, tal teste pode ser estimado da seguinte forma:

$$\Delta s_{t+1} = (\Delta s_{t+1} \bar{\Delta} s_{t+1})^2 - [(\Delta s_{t+1} - \hat{\Delta} s_{t+1})^2 - (\bar{\Delta} s_{t+1} - \hat{\Delta} s_{t+1})^2] \quad (21)$$

Ainda seguindo Medeiros, 2021 *apud* Godeiro e Lima, 2018, podemos verificar se as previsões baseadas em modelos $\hat{\tau}_{t+1}$ 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 área de previsão de retorno, é comum encontrarmos valores percentuais baixos para $R_{OS}^2 (\%)$. No entanto, é importante destacar que isso não significa que seu valor econômico seja insignificante. Na verdade, como argumentado por Campbell e Thompson (2008), mesmo um $R_{OS}^2 (\%)$ muito pequeno, como 1,0% para dados mensais, pode sinalizar um grau de previsibilidade do retorno que é economicamente relevante, resultando em um aumento do retorno anual da carteira para um investidor de média variância.

Neste trabalho, também iremos aplicar o método introduzido por Campbell e Thompson (2008) e Rapach e Strauss (2010) para calcular o ganho de utilidade dos modelos de previsão. Com isso, podemos avaliar o valor econômico dessas previsões e entender se elas podem realmente gerar ganhos significativos para os investidores.

⁸ Nosso modelo *benchmark* é representado pelo Passeio Aleatório (Random Walk).

Para calcular o valor econômico de uma previsão, utilizamos o conhecido equivalente de certeza do retorno (ou ganho de utilidade). Esse valor pode ser interpretado como a taxa de administração que um investidor estaria disposto a pagar para ter acesso às informações adicionais fornecidas pelo modelo de previsão baseado em comparação com as informações disponíveis no modelo de referência (*benchmark*).

Para Medeiros (2021) 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: $\omega_t = \frac{1}{\gamma} \frac{\hat{\Delta} s_{t+1}}{\sigma_{t+1}^2}$

Medeiros (2021) continua sua explanação sobre o método implantado, onde γ é o parâmetro de aversão ao risco e σ_{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:

$$U = \hat{\mu} - \frac{1}{2} \gamma \hat{\sigma}^2 \quad (22)$$

Onde $\hat{\mu} = \frac{1}{p} \sum_t R_t$, $\hat{\sigma}_p^2 = Var (R_t = \frac{1}{p} \sum_t (R_t - \hat{\mu}_t)^2$ 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*), $\bar{\Delta} s_{t+1}$. 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 $\gamma = 3^9$. Este mesmo método é adotado por (MEDEIROS, 2021); (GODEIRO e LIMA, 2018); (FRANÇA, 2015); (RAPACH e STRAUSS,2010), dentre outros.

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*¹⁰ amplamente utilizada no mercado financeiro.

Seguindo Da Silva e Rossi Junior (2022) o passeio aleatório sem drift com previsões feita fora da amostra (OOS) e um passo à frente de uma variável dependente (Δs) é descrita como:

$$\bar{\Delta} s_{t+1} = \Delta s_t \quad (23)$$

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

⁹ Conforme adotado em Lima and Meng (2017) e Godeiro et al. (2018)

¹⁰ 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.

3 – Resultados Empíricos

Para fazer a previsão da taxa de câmbio entre o real brasileiro (BRL) e o dólar dos Estados Unidos (USD), foram utilizadas dois conjuntos de amostras: um período dentro da amostra de 01/2002 a 12/2012 (com 132 observações) e outro período fora da amostra de 01/2013 a 06/2024 (com um total de $P = 138$ observações). Os dados foram estimados recursivamente ao longo do tempo e a divisão das amostras teve como objetivo garantir uma melhora fora da amostra.

Em seguida, realizou-se uma análise fora da amostra, traçando os resultados das previsões condicionais com base no valor da estatística R^2 (%) e na significância dos p-values do procedimento do Erro Quadrado Médio de Previsão Ajustado (MSPE) de Clark and West (2007). O teste CW demonstrou que um dos modelos (Fundamentos Macroeconômicos, KS e E-KS) apresentou desempenho superior ao modelo de referência (Passeio Aleatório) para valores positivos. Além disso, foi observado o ganho de utilidade do investidor com preferência de média e variância $\Delta U\%$ (anual) associado a cada modelo de previsão.

3.1 – Resultados Fora da Amostra

Por fim, os resultados das previsões dos preditores individuais foram apresentados na tabela 2, descrita abaixo.

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

Painel A: Modelo Baseado em Fundamentos Macroeconômicos			
Modelo	$R_{OOS}^2\%$	CW	$\Delta U\%$
UIP	0.65	0.22	0.46
PPP	-0.10	0.47	-1.55
MF	-1.66	0.78	-1.88
TR	-0.79	0.77	-0.52
TT	-0.45	0.36	-0.56
Painel B: Modelo Baseado em Regressão <i>Kitchen-Sink</i>			
Modelo	$R_{OOS}^2\%$	CW	$\Delta U\%$
KS	-0.18	0.93	-0.08
Painel C: Modelo Baseado em Regressão Eficiente de <i>Kitchen-Sink</i>			
Modelo	$R_{OOS}^2\%$	CW	$\Delta U\%$
EKS	-4.49	0.77	-1.62
EKS- <i>RIDGE</i>	-4.59	0.68	-0.16
EKS- <i>LASSO</i>	-2.89	0.85	-0.48

Fonte: Autor

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 e 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 referentes aos modelos baseados nos fundamentos macroeconômicos mostraram que apenas a paridade de juros a descoberta obteve o R_{00s}^2 (%) positivo e estatisticamente significativo maior que zero, com desempenho superior ao passeio aleatório em 0.65%. Outra observação é que, o preditor de Paridade do Poder de Compra (PPP) mostrou-se negativo, sendo inferior ao Passeio Aleatório em (-0.10%), 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 (-0.18%).

Dando continuidade as classes dos demais modelos, temos que nos modelos baseados na Regressão Eficiente de *Kitchen-Sink* mostraram que são estatisticamente inferiores ao Passeio Aleatório quando observado a estatística R_{00s}^2 (%) sendo o EKS de (-4,49%), EKS-Ridge (-4,59%) e o EKS-LASSO (-2.89%). 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 e 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 0.46%. Os demais preditores não apresentaram ganho de utilidade ao investidor, ocasionando a não maximização de sua função. Estes valores variaram de (-1.88%) a (-0.52%) para os modelos baseados em fundamentos macroeconômicos e de (-0.08%) para a regressão *Kitchen-Sink* e por fim, a variação de (-1.62%) a (-0.16%) para os modelos Eficientes de *Kitchen-Sink*

3.2 – Teste de robustez.

Com o objetivo de avaliar a solidez da metodologia utilizada, realizamos um exercício para testar sua robustez. Dividimos a amostra em três partes em períodos diferentes, conforme mencionado anteriormente, e realizamos uma análise comparativa das três subamostras. O período de análise utilizado foi de 138 meses, compreendendo informações entre janeiro de 2013 e junho de 2024.

A primeira subamostra, chamada de Pré-Covid, compreende o período de janeiro de 2013 a janeiro de 2020, totalizando 85 meses. A segunda subamostra, chamada de Pós-Covid, compreende o período de fevereiro de 2020 a junho de 2024 num total de 53 meses e por último a terceira amostra contempla o período de fevereiro de 2020 até maio 2023, totalizando 26 meses.

As sub amostras tiveram os seguintes critérios, na primeira decorre no período pré-covid dentro do período de teste da amostra principal, tendo como objetivo verificar os preditos no período antes da pandemia. A segunda sub amostra denominada de pós-covid resulta no estudo dos preditores no período do início da pandemia até o mês de junho de 2024 e por fim temos o período da sub amostra covid-19 esses dados são observados apenas dentro do período pandêmico. A análise comparativa das três subamostras permitiu verificar a consistência da metodologia utilizada e a sua aplicabilidade ao longo do tempo e analisar os impactos do período da pandemia.

Dessa forma, podemos afirmar que a metodologia aplicada demonstrou ser robusta e confiável, visto que se manteve consistente em todas as subamostras. Esse tipo de exercício é importante para garantir a qualidade e a validade dos resultados obtidos e é comumente utilizado em pesquisas acadêmicas e estudos de mercado.

Tabela 3: Pré-Covid. Resultado das Previsões Fora da Amostra para a Previsão da Taxa de Câmbio BRL (Brasil) e USD (EUA).

Painel A: Modelo Baseado em Fundamentos Macroeconômicos			
Modelo	$R_{00s}^2\%$	CW	$\Delta U\%$
UIP	0.46	0.27	0.53
PPP	0.44	0.21	1.30
MF	-0.78	0.71	-1.16
TR	-1.13	0.92	-0.73
TT	0.83	0.18	1.41
Painel B: Modelo Baseado em Regressão <i>Kitchen-Sink</i>			
Modelo	$R_{00s}^2\%$	CW	$\Delta U\%$
KS	-0.09	0.93	0.00
Painel C: Modelo Baseado em Regressão Eficiente de <i>Kitchen-Sink</i>			
Modelo	$R_{00s}^2\%$	CW	$\Delta U\%$
EKS	-5.29	0.97	-3.55
EKS- <i>RIDGE</i>	-3.43	0.79	-5.39
EKS- <i>LASSO</i>	-0.53	0.76	-1.24

Fonte: Autor

Tabela 4: Pós-Covid. Resultado das Previsões Fora da Amostra para a Previsão da Taxa de Câmbio BRL (Brasil) e USD (EUA).

Painel A: Modelo Baseado em Fundamentos Macroeconômicos			
Modelo	$R_{00s}^2\%$	CW	$\Delta U\%$
UIP	0.92	0.29	0.18
PPP	-0.90	0.67	-1.97
MF	-2.95	0.72	-2.18
TR	-0.28	0.48	-0.47
TT	-2.32	0.62	-1.73
Painel B: Modelo Baseado em Regressão <i>Kitchen-Sink</i>			
Modelo	$R_{00s}^2\%$	CW	$\Delta U\%$
KS	-0.30	0.855	-0.25
Painel C: Modelo Baseado em Regressão Eficiente de <i>Kitchen-Sink</i>			
Modelo	$R_{00s}^2\%$	CW	$\Delta U\%$
EKS	-3.32	0.47	-8.31
EKS- <i>RIDGE</i>	-6.28	0.55	-3.74
EKS- <i>LASSO</i>	-6.36	0.82	-0.18

Fonte: Autor

Tabela 5: Covid. Resultado das Previsões Fora da Amostra para a Previsão da Taxa de Câmbio BRL (Brasil) e USD (EUA).

Painel A: Modelo Baseado em Fundamentos Macroeconômicos			
Modelo	$R_{OOS}^2\%$	CW	$\Delta U\%$
UIP	1.07	0.31	1.84
PPP	-1.08	0.71	-0.83
MF	-2.49	0.75	-3.70
TR	-0.33	0.48	-0.34
TT	-2.20	0.60	-0.62
Painel B: Modelo Baseado em Regressão <i>Kitchen-Sink</i>			
Modelo	$R_{OOS}^2\%$	CW	$\Delta U\%$
KS	-0.39	0.85	-0.67
Painel C: Modelo Baseado em Regressão Eficiente de <i>Kitchen-Sink</i>			
Modelo	$R_{OOS}^2\%$	CW	$\Delta U\%$
EKS	-0.91	0.45	-2.23
EKS- <i>RIDGE</i>	-1.87	0.38	-3.34
EKS- <i>LASSO</i>	-7.87	0.90	-3.12

Fonte: Autor

Os resultados obtidos revelam que no período inicial, Pré-Covid, gerou um aumento na quantidade de preditores macroeconômicos mais aprimorado que contribuiu para aumentar a acurácia das previsões, principalmente em períodos de curto prazo e com dados mais consistentes. Anteriormente, apenas o UIP foi significativo com a amostra de 138 meses, mas a redução do número de meses incluídas no modelo, assim também como os dados do período que antecedeu a pandemia da covid-19, houve uma melhoria significativa nos resultados.

Os resultados apontaram que o UIP apresentou um valor de acurácia de (0.46), enquanto o PPP e o TT se mostraram eficientes, com acurácias de (0.44) e (0.83), respectivamente. O Termo de Troca foi incluído no estudo devido as observações de inúmeras transações comerciais entre o Brasil e EUA, o que torna essa variável relevante para a previsão da taxa de câmbio a período mais estável.

Esses resultados são importantes, pois evidenciam que a inclusão de múltiplos preditores macroeconômicos pode melhorar significativamente a precisão das previsões, contribuindo para uma tomada de decisão mais fundamentada por parte de investidores, empresas e governos. Os resultados da segunda e terceira subamostras Pós-Covid e Covid designam o aumento da dificuldade em previsão de taxa de câmbio em períodos de pestilência com apenas o UIP (0.92) e (1.07), se mostrando eficiente em relação aos demais preditores, com isso percebe-se que o UIP tem uma tendência de melhorar sua previsão com a redução do tempo. A UIP demonstrou também ser um preditor eficaz para períodos de incertezas severas, visto que seu poder de acurácia aumenta em quanto maior a insegurança do período.

Realizamos análises dos resultados de modelos baseados em Fundamentos Macroeconômicos, Regressão *Kitchen-Sink* e Regressão Eficiente de *Kitchen-Sink*, a fim de observar se as técnicas de regularização Ridge, LASSO e Elastic Net geram robustez à regressão de *Kitchen-Sink* em combinação com os modelos fundamentais macroeconômicos.

Os resultados obtidos a partir dos modelos baseados nos fundamentos macroeconômicos indicaram que apenas a Paridade de Juros a Descoberta obteve um $R_{OOS}^2(\%)$ positivo e estatisticamente significativo em todos os exercícios, com desempenho superior ao passeio aleatório ficando em 0.46%, 0.92% e 1.07%, respectivamente nos períodos 1º, 2º e 3º, apresentando uma tendência de quanto maior a seu período dentro da pandemia maior seu poder preditivo. Por outro lado, os demais preditores apresentaram valor negativo período 2º e 3º, apenas o período 1º houve uma ascensão de mais preditores com três UIP, PPP e TT com valores acima do *benchmark*.

Em relação aos modelos baseados na Regressão Eficiente de *Kitchen-Sink*, verificamos que todos foram estatisticamente inferiores ao Passeio Aleatório quando observada a estatística $R_{OOS}^2(\%)$, sendo que o EKS teve um valor inferior, mostrando um comportamento de distanciamento quanto maior seu período fora da amostra, oscilando entre -5.29% até -0.91%, o EKS-Ridge de também não houve resultados positivos e o EKS-LASSO segue a dinâmica anterior. Embora o Elastic Net seja aninhado aos dois anteriores, o seu resultado não obteve uma performance significativa.

Neste estudo, analisamos os ganhos de utilidade do investidor de média variância com base em modelos de previsões. Os resultados mostraram que a Paridade de Juros a Descoberto foi o preditor mais eficaz em todas as amostras no período covid, proporcionando um ganho de utilidade ao investidor que superou o Passeio Aleatório em uma faixa de 0.18 a 1.84. No entanto, os demais preditores não resultaram em ganhos de utilidade ao investidor se incluso o período pandêmico, o que indica que sua função não foi maximizada.

Esses resultados reforçam os dados coletados e destacam a importância da Paridade de Juros a Descoberto como um preditor confiável da taxa de câmbio entre dólar e real. Em suma, os resultados sugerem que investidores que utilizam esse modelo podem obter ganhos significativos em suas decisões de investimento.

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 trabalho 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 dentro do período pandêmico, a diferenciar o UIP que apresentou ganho estatístico em relação ao referencial e quanto maior o período dentro da pandemia ele melhora sua acurácia, além de ser o único com ganho de utilidade ao investidor de média variância em períodos maiores de tempo. 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 e West (2007), (CW). Desta forma, a regressão Eficiente de *Kitchen-*

Sink não gera 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 e Rossi 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 e Rossi Junior (2022), assim como, fazer análise para outras moedas, como em Li et al. (2015).

Com o objetivo de expandir ainda mais as aplicações e aumentar a eficácia do trabalho, há diversas possibilidades de incluir novos regressores e regressões que possam melhorar a explicação e aplicação do modelo.

Para isso, pode-se considerar a inclusão de mais variáveis macroeconômicas, entre outras. Variáveis que podem fornecer informações adicionais sobre a dinâmica econômica do país, e ajudar a prever as mudanças na taxa de câmbio com maior precisão.

Além disso, a expansão para novas regressões pode ser uma abordagem promissora para melhorar o modelo. Além disso, é importante lembrar que a taxa de câmbio é influenciada por fatores externos, como flutuações no mercado global, políticas econômicas de outros países e eventos geopolíticos. Portanto, a inclusão de novas variáveis externas pode ser relevante para melhorar a precisão do modelo e prever possíveis desequilíbrios.

Em suma, a ampliação das aplicações de novos fundamentos macroeconômicos e a expansão para novas regressões pode ser uma abordagem promissora para melhorar a precisão e eficácia do modelo de previsão da taxa de câmbio. A incorporação de novas variáveis e técnicas pode fornecer insights adicionais sobre a dinâmica econômica do país e ajudar a prever as mudanças na taxa de câmbio de maneira mais precisa e eficiente.

5 – Referências

BELL, A., & FAIRBROTHER, M. (2019). Contemporary regression analysis. Guilford Publications.

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. e WEST, K. D. (2007). Approximately normal tests for equal predictive accuracy in nested models. *Journal of econometrics*, 138(1):291–311.
- SILVA, G. P. da e ROSSI JUNIOR, J. L. (2022). Real/dollar exchange rate prediction combining machine learning and fundamental models.
- MEDEIROS, Elvira Helena Oliveira de (2021). Previsão do Prêmio de Risco para a Economia Brasileira Utilizando Notícias Financeiras, Indicadores Técnicos e Aprendizado de Máquina Supervisionado. Dissertação (Mestrado em economia), Programa de Pós Graduação em Economia Aplicada, Mossoró-RN, 2021.
- DIEBOLD, F. e MARIANO, R. (1995). Comparing predictive accuracy. *Journal of business and economic 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.
- DUARTE, A. P. (2001). Paridade do poder de compra e das taxas de juro: Um estudo aplicado a três países da uem.
- 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. e WEST K. (2006) Taylor rules and the Deutschmark dollar real exchange rate, *Journal of Money, Credit and Banking*, 38 : 1175.
- ENGEL, C. (2014). Exchange rates and interest parity. *Handbook of international economics*, 4, 453-522.
- FAMA, E. F. (1984). Forward and spot exchange rates. *Journal of monetary economics*, 14(3), 319-338.
- FAN, J., & Li, R. (2001). Variable selection via nonconcave penalized likelihood and its oracle properties. *Journal of the American Statistical Association*, 96(456), 1348-1360.
- 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.
- HOERL, A. E., & KENNARD, R. W. (1970). Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics*, 12(1), 55-67.
- JAMES, G., WITTEN, D., HASTIE, T., & TIBSHIRANI, R. (2013). An introduction to statistical learning (Vol. 112). New York: Springer.
- 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.

MANKIW, N. G. (2016). *Macroeconomia* (9a ed.). LTC.

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. e 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. e 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 WOCHAR, 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.

TAYLOR, M. P. (1995). The economics of exchange rates. *Journal of economic literature*, 33(1), 13-47.

TIBSHIRANI, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267-288.

ZHANG, Y. e 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. e 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.

6 – Apêndice

Tabelas e Figuras

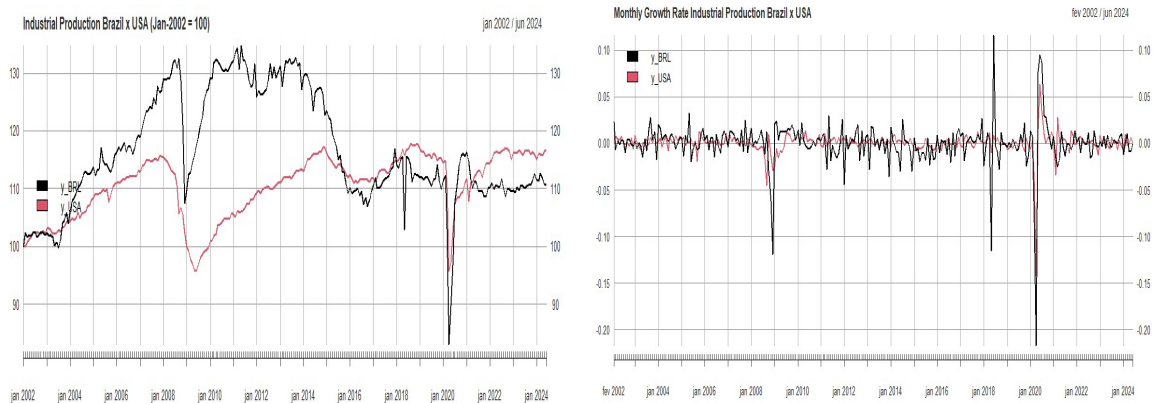


Figura 3: Os gráficos denotam o comportamento das variáveis: Produção Industrial e Taxa de Crescimento Mensal da Produção Industrial entre Brasil e EUA.

Com base na série temporal fora da amostra de janeiro de 2012 a dezembro de 2022, analisamos o comportamento das variáveis macroeconômicas fundamentais. O primeiro gráfico apresenta a produção industrial do Brasil e dos Estados Unidos, evidenciando quedas distintas, mas seguindo a mesma trajetória geral. Já o segundo gráfico ilustra a taxa mensal de produção industrial, que demonstra um comportamento oscilatório similar em ambos os países.

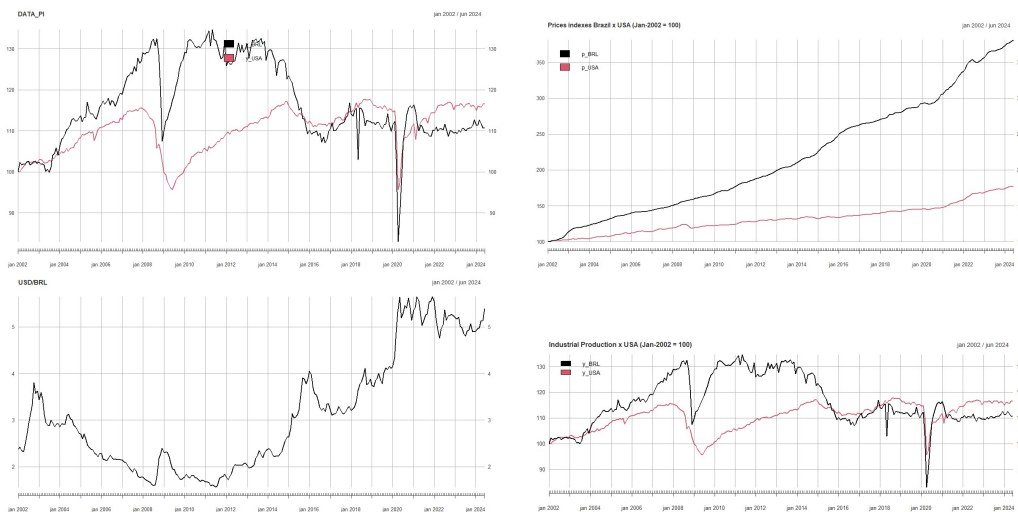


Figura 4: Os gráficos denotam o comportamento das variáveis Data pi, diferencial de juros, Stop x Forward Rate e o Índice de Preços do Brasil e EUA.

Com base na série temporal fora da amostra de janeiro de 2012 a dezembro de 2022, examinamos o comportamento das variáveis macroeconômicas fundamentais. O primeiro gráfico mostra o diferencial de juros (BRL-USD) e destaca choques em períodos específicos. Por sua vez, o segundo gráfico compara os índices de preços do Brasil e dos Estados Unidos, demonstrando trajetórias distintas, sendo o índice dos EUA menor do que o do Brasil em ambos os períodos da série.