

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Faculdade de Ciências Econômicas
Centro de Pós-Graduação e Pesquisa em Administração

Pedro Augusto Alvim Sabino

**DINÂMICA DA CURVA DE JUROS BRASILEIRA:
uma análise da contribuição informacional de indicadores
de incerteza na política econômica**

Belo Horizonte

2022

Pedro Augusto Alvim Sabino

**DINÂMICA DA CURVA DE JUROS BRASILEIRA:
uma análise da contribuição informacional de indicadores
de incerteza na política econômica**

Versão Final

Tese apresentada ao Centro de Pós-Graduação e Pesquisas em Administração da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Doutor em Administração.

Linha de Pesquisa: Finanças

Orientador: Prof. Dr. Robert Aldo Iquiapaza Coaguila

Belo Horizonte

2022

Ficha Catalográfica

S116d Sabino, Pedro Augusto Alvim.
2022 Dinâmica da curva de juros brasileira [manuscrito] : uma análise da contribuição informacional de indicadores de incerteza na política econômica / Pedro Augusto Alvim Sabino. – 2022.
1 v.: il. e tábs.

Orientador: Robert Aldo Iquiapaza.

Tese (doutorado) - Universidade Federal de Minas Gerais,
Centro de Pós-Graduação e Pesquisa em Administração.
Inclui bibliografia e apêndices.

1. Política econômica – Teses. 2. Juros – Teses. 3. Capital (Economia) – Teses. 4. Administração – Teses. I. Iquiapaza, Robert Aldo. II. Universidade Federal de Minas Gerais. Centro de Pós-Graduação e Pesquisa em Administração. III. Título.

CDD: 338.9

Elaborado por Adriana Kelly Rodrigues CRB-6/2572
Biblioteca da FACE/UFMG. – AKR/041/2023



UNIVERSIDADE FEDERAL DE MINAS GERAIS
FACULDADE DE CIÊNCIAS ECONÔMICAS
CENTRO DE PÓS-GRADUAÇÃO E PESQUISAS EM ADMINISTRAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO

ATA DE DEFESA DE TESE

ATA DA DEFESA DE TESE DE DOUTORADO EM ADMINISTRAÇÃO do Senhor **PEDRO AUGUSTO ALVIM SABINO**, REGISTRO Nº 301/2022. No dia 09 de dezembro de 2022, às 14:30 horas, reuniu-se remotamente, por videoconferência, a Comissão Examinadora de Tese, indicada pelo Colegiado do Centro de Pós-Graduação e Pesquisas em Administração do CEPEAD, em 01 de dezembro de 2022, para julgar o trabalho final intitulado "**DINÂMICA DA CURVA DE JUROS BRASILEIRA: uma análise da contribuição informacional de indicadores de incerteza na política econômica**", requisito para a obtenção do **Grau de Doutor em Administração**, linha de pesquisa: **Finanças**. Abrindo a sessão, o Senhor Presidente da Comissão, Prof. Dr. Robert Aldo Iquiapaza Coaguila, após dar conhecimento aos presentes o teor das Normas Regulamentares do Trabalho Final, passou a palavra ao candidato para apresentação de seu trabalho. Seguiu-se a arguição pelos examinadores com a respectiva defesa do candidato. Logo após, a Comissão se reuniu sem a presença do candidato e do público, para julgamento e expedição do seguinte resultado final:

APROVAÇÃO

REPROVAÇÃO

O resultado final foi comunicado publicamente ao candidato pelo Senhor Presidente da Comissão. Nada mais havendo a tratar, o Senhor Presidente encerrou a reunião e lavrou a presente ATA, que será assinada por todos os membros participantes da Comissão Examinadora. Belo Horizonte, 09 de dezembro de 2022.

Prof. Dr. Robert Aldo Iquiapaza Coaguila
ORIENTADOR - CEPEAD/UFMG

Prof. Dr. Aureliano Angel Bressan
CEPEAD/UFMG

Prof. Dr. Emerson Fernandes Marçal
EESP/FGV

Profª. Drª. Lucélia Viviane Vaz Raad
PPGA/CEFET-MG

Prof. Dr. Marcos Vinicius Lopes Pereira
DTECH/UFSJ



Documento assinado eletronicamente por **Robert Aldo Iquiapaza Coaguila, Professor do Magistério Superior**, em 12/12/2022, às 11:24, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Aureliano Angel Bressan, Professor do Magistério Superior**, em 12/12/2022, às 11:49, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Marcos Vinicius Lopes Pereira, Usuário Externo**, em 12/12/2022, às 14:19, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Lucélia Vaz Raad, Usuária Externa**, em 23/03/2023, às 14:23, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Emerson Fernandes Marçal, Usuário Externo**, em 29/03/2023, às 12:47, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1918545** e o código CRC **E5BC2BF0**.

Agradecimentos

Ao final desse ciclo, meus sinceros agradecimento àqueles sem os quais não seria possível concluí-lo. Agradeço à minha família, especialmente minha esposa Karla, pelo companheirismo e carinho constantes. Ao meu orientador, Prof. Dr. Robert Aldo Iquiapaza Coaguila, não só pelas orientações técnicas, mas também pela paciência e apoio. Aos meus irmãos de orientação Marcos Vinicius Lopes Pereira e Simone Evangelista Fonseca, sempre solícitos.

Resumo

O objetivo desta tese foi explicar como a dinâmica das curvas de juros brasileira é influenciada pelas variações de incerteza na política econômica do Brasil e na dos Estados Unidos. A amostra utilizada compreendeu fechamentos mensais da curva de *swap* DI \times Pré da B³, da Estrutura a Termo da Taxas de Juros estimada e fornecida pela ANBIMA e da Estruturas a Termo da Taxas de Juros dos Estados Unidos, indicadores compostos de incerteza (o IIE-Br de [Ferreira et al. \(2019\)](#) e o EPU de [Baker, Bloom e Davis \(2016\)](#)), além de variáveis macroeconômicas, compreendendo o período de fevereiro de 2010 a junho de 2022. Para tanto, foram avaliados os impactos dos indicadores de incerteza em regressões nos *spreads* da curva, regressões preditivas nos excessos de retorno, funções de resposta ao impulso sobre os fatores latentes da curva e, em especial, modelos dinâmicos de curva de juros. Complementarmente, também foram avaliados o grau de integração entre a curva de *Swap* e a da ANBIMA e os efeitos de *spillover* oriundos da incerteza e da curva de juros americanos. Os indicadores de incerteza foram significativos ao explicar os *spreads* das curvas brasileiras, mas não apresentaram poder preditivo sobre os excesso de retorno. Ainda, as respostas dos fatores latentes da curva brasileira a choques de incerteza brasileira não foram significativos, mas, posteriormente, foram levemente impactadas por choques na incerteza americana, que se propagaram ao longo do sistema econômico. Por outro lado, o teste da razão de verossimilhança reportou ganhos significativos no ajuste de modelos dinâmicos de curva de juros ao se incorporar *proxies* de incerteza, especialmente o IIE-Br. Esses resultados sugerem que, no período amostral avaliado, a incerteza na política econômica não apresentou poder preditivo sobre os fatores latentes, os quais sintetizam a forma funcional da curva de juros vigente nos meses posteriores. Todavia, também reforçam que ela é impactante na precificação de ativos, melhorando ajuste entre expectativas e prêmios de risco em modelos com não arbitragem. Como resultados adicionais, corroborou-se com a usual hipótese implícita de aderência entre a curva de *swap* e a da ANBIMA. Além disso, verificou-se que o *spillover* de choques na incerteza americana sobre os fatores latentes brasileiros foi expressivamente maior que o originado na incerteza brasileira, mas o *spillover* da incerteza americana sobre a brasileira foi baixo.

Palavras-chave: Curva de juros; Modelos dinâmicos de curva de juros; Incerteza na política econômica.

Abstract

This thesis aim was to explain how the Brazilian yield curves dynamics is influenced by variations in American and Brazilian economic policy uncertainty. The sample used comprised monthly closings of the *swap* DI \times Pre curve from B³, the Term Structure of Interest Rates estimated and provided by ANBIMA and the United States Term Structures of Interest Rates, uncertainty composite indicators (IIE-Br of [Ferreira et al. \(2019\)](#) and EPU of [Baker, Bloom e Davis \(2016\)](#)), in addition to macroeconomic variables, from February 2010 to June 2022. From this, the uncertainty indicators impacts were evaluated in regressions on the curve's *spreads*, predictive regressions on excess returns, impulse response functions on the curve latent factors and, in particular, dynamic term structure models. In addition, also were evaluated the degree of integration between the *swap* curve and the ANBIMA curve and the spillover effects from American yield curve and uncertainty. The uncertainty indicators were significant to explain the Brazilian curves *spreads*, but did not show predictive power over excess returns. Furthermore, the responses of the latent factors from the Brazilian curve to Brazilian uncertainty shocks were not significant, but, posteriorly, were slightly impacted by American uncertainty shocks, which propagated throughout the economic system. On the other hand, the likelihood ratio test reported significant fit gains in dynamic yield curve models when incorporating uncertainty *proxies*, especially the IIE-Br. This result suggests that, in the period evaluated, economic policy uncertainty did not show predictive power over the latent factors, which summarize the yield curve functional form in the following months. However, they also reinforce that it has an impact on bond pricing, improving the adjustment between expectations and risk premiums in no arbitrage models. As additional results, the usual implicit hypothesis of adherence between the *swap* curve and that of ANBIMA was corroborated. Also, it was found that the spillover from American uncertainty shocks on the Brazilian latent factors was significantly greater than that originated from Brazilian uncertainty, but the spillover from American uncertainty on the Brazilian was low.

Keywords: Yield curve; Dynamic yield curve models; Economic policy uncertainty.

Lista de ilustrações

Figura 1 – Curva de juros brasileira	25
Figura 2 – Possíveis formas funcionais da curva de juros	28
Figura 3 – Séries históricas do IIE-Br e do EPU-Br	62
Figura 4 – Curvas de juros - fevereiro/2010 a junho/2022	86
Figura 5 – L_t , S_t e C_t - <i>Swap</i> DI × Pré e ETTJ	91
Figura 6 – Correlograma: PCs da <i>Swap</i> DI × Pré e da ETTJ	92
Figura 7 – L_t , S_t e C_t - <i>Swap</i> DI × Pré, ETTJ e ETTJ americana	94
Figura 8 – Correlograma: <i>Swap</i> DI × Pré, ETTJ americana e indicadores de incerteza	95
Figura 9 – Resposta de $L_{BR,t}$, $S_{BR,t}$, $C_{BR,t}$ e <i>IIE</i> (<i>Swap</i> DI × Pré) a choques em $L_{BR,t}$, $S_{BR,t}$, $C_{BR,t}$, <i>IIE</i> , $L_{EUA,t}$, $S_{EUA,t}$, $C_{EUA,t}$ e <i>EPU</i>	98
Figura 10 – Resposta de $L_{BR,t}$, $S_{BR,t}$, $C_{BR,t}$ a choques em <i>IIE</i> e <i>EPU</i> (curva de <i>Swap</i>)	106
Figura 11 – Resposta de $L_{BR,t}$, $S_{BR,t}$, $C_{BR,t}$ a choques em <i>IIE</i> e <i>EPU</i> , controlados por variáveis macroeconômicas (curva de <i>Swap</i>)	107
Figura 12 – Estabilidade nas cargas das cinco primeiras componentes principais (curva de <i>Swap</i>)	136
Figura 13 – Estabilidade nas cargas das cinco primeiras componentes principais (ETTJ)	137
Figura 14 – Correlograma: ETTJ, ETTJ americana e indicadores de incerteza	138
Figura 15 – Resposta de $L_{BRn,t}$, $S_{BRn,t}$, $C_{BRn,t}$ e <i>IIE</i> (ETTJ) a choques em em $L_{BRn,t}$, $S_{BRn,t}$, $C_{BRn,t}$, <i>IIE</i> , $L_{EUA,t}$, $S_{EUA,t}$, $C_{EUA,t}$ e <i>EPU</i>	139
Figura 16 – Resposta de $L_{BRn,t}$, $S_{BRn,t}$, $C_{BRn,t}$ a choques em <i>IIE</i> e <i>EPU</i> (curva de <i>Swap</i>)	140
Figura 17 – Resposta de $L_{BRn,t}$, $S_{BRn,t}$, $C_{BRn,t}$ a choques em <i>IIE</i> e <i>EPU</i> , controlados por variáveis macroeconômicas (ETTJ)	141
Figura 18 – Correlograma: <i>spreads</i> , fatores latentes e fatores exógenos (<i>Swap</i> DI × Pré)	142
Figura 19 – Correlograma: <i>spreads</i> , fatores latentes e fatores exógenos (ETTJ)	143
Figura 20 – Correlograma: excessos de retorno, fatores latentes e fatores exógenos (<i>Swap</i> DI × Pré)	144
Figura 21 – Correlograma: excessos de retorno, fatores latentes e fatores exógenos (ETTJ)	145

Lista de tabelas

Tabela 1 – Variáveis dependentes	70
Tabela 2 – Variáveis independentes	71
Tabela 3 – Cargas das primeiras componentes principais - <i>Swap</i> DI × Pré	87
Tabela 4 – Cargas das primeiras componentes principais - ETTJ	88
Tabela 5 – Cargas das primeiras componentes principais - ETTJ americana	88
Tabela 6 – Proporção da variância na componente principal	89
Tabela 7 – Estatísticas descritivas das variáveis (fev./2010 - jun./2022)	89
Tabela 8 – <i>Spillover</i> líquido $Trp_{i,j}^H$ - <i>Swap</i> DI × Pré e ETTJ	93
Tabela 9 – <i>Spillover</i> parcial $Trp_{i\leftarrow\bullet}^H$ - <i>Swap</i> DI × Pré e ETTJ	93
Tabela 10 – <i>Spillover</i> parcial $Trp_{i\leftarrow EUA}^H$	96
Tabela 11 – <i>Spillover</i> simples $\psi_{i,j}^H$, originados em <i>IIE</i> e <i>EPU</i>	97
Tabela 12 – Regressões de $sp_t(\tau)$ (<i>Swap</i> DI × Pré)	100
Tabela 13 – Regressões de $sp_t(\tau)$ (ETTJ)	101
Tabela 14 – Regressões de $rx_{t,t+12}(\tau)$ (<i>Swap</i> DI × Pré)	103
Tabela 15 – Regressões de $rx_{t,t+12}(\tau)$ (ETTJ)	104
Tabela 16 – Regressões completas de $sp_t(\tau)$	109
Tabela 17 – Regressões reduzidas de $sp_t(\tau)$	110
Tabela 18 – Regressões completas de $rx_{t,t+12}(\tau)$	112
Tabela 19 – Regressões reduzidas de $rx_{t,t+12}(\tau)$	113
Tabela 20 – Teste LR dos DTSMs (<i>Swap</i> DI × Pré)	115
Tabela 21 – Teste LR dos DTSMs (ETTJ)	116
Tabela 22 – Comparativo de variáveis selecionadas para $sp_t(\tau)$ (<i>Swap</i> DI × Pré)	146
Tabela 23 – Comparativo de variáveis selecionadas para $sp_t(\tau)$ (ETTJ)	147
Tabela 24 – Comparativo de variáveis selecionadas para $rx_{t,t+12}(\tau)$ (<i>Swap</i> DI × Pré)	148
Tabela 25 – Comparativo de variáveis selecionadas para $rx_{t,t+12}(\tau)$ (ETTJ)	149

Lista de abreviaturas e siglas

AFNS	<i>Arbitrage-free Nelson–Siegel</i>
AIC	Estatística de Akaike
ARCH	<i>Autoregressive Conditional Heteroscedastic</i>
ANBIMA	Associação Brasileira das Entidades dos Mercados Financeiro e de Capitais
B ³	Brasil Bolsa Balcão (Bolsa de Valores de São Paulo)
Bacen	Banco Central do Brasil
BIC	Critério Bayesiano de Schwarz
BVAR	Vetor Autoregressivo Bayesiano
BR	Brasil
CAPM	<i>Capital Asset Pricing Model</i>
CDS	<i>Credit Default Swap</i>
CMN	Conselho Monetário Nacional
CNI	Confederação Nacional da Indústria
Copom	Comitê de Política Monetária
DNSM	<i>Dynamic Nelson-Siegel Model</i>
DNSSM	<i>Dynamic Nelson-Siegel-Svensson Model</i>
DTSM	<i>Dynamic Term Structure Models</i> - Modelos Dinâmicos de Curvas de Juros
EMBI+ Br	Emerging Markets Bond Index Plus - Brasil
EPU	<i>Economic Policy Uncertainty</i> - índice de Incerteza na Política Econômica
ETTJ	Estrutura a termo da Taxa de Juros
EUA	Estados Unidos da América
FAVAR	Vetor Autoregressivo com Fator Aumentado

FED	<i>Federal Reserve System</i> (autoridade monetária americana)
FOMC	<i>Federal Open Market Committee</i>
FRED	<i>Federal Reserve Economic Data</i> (St. Louis Fed)
G7	Grupo dos Sete (países mais industrializados)
HEAVY	<i>High-frequency-based-volatility</i>
HP	Filtro Hodrick–Prescott
IBC-Br	Índice de Atividade Econômica do Banco Central - Brasil
IBGE	Instituto Brasileiro de Geografia e Estatística
IBRE/FGV	Instituto Brasileiro de Economia / Fundação Getúlio Vargas
IRF	Função de Resposta ao Impulso
IIE-Br	Indicador de Incerteza da Economia - Brasil
IMF	Fundo Monetário Internacional
IPCA	Índice Nacional de Preços ao Consumidor Amplo
IPEA	Instituto de Pesquisa Econômica Aplicada
LASSO	<i>Least Absolute Shrinkage and Selection Operator</i>
LR	Teste da razão de verossimilhança
MCMC	<i>Markov Chain Monte Carlo</i>
MLE	Máximo Verossimilhança
MPU	<i>Monetary Policy Uncertainty</i>
MQO	Mínimos Quadrados Ordinários
PCA	Análise de Componentes Principais
PIB	Produto Interno Bruto
PME	Pequisa Mensal de Emprego
PNAD	Pesquisa Nacional por Amostra de Domicílios
SELIC	Sistema Especial de Liquidação e de Custódia
TVP-VAR	Vetor Autorregressivo com Parâmetros Variantes no Tempo

UCI	Utilização da Capacidade Instalada
VAR(p)	Vetor Autorregressivo de ordem p
VIX	<i>Volatility Index</i> da <i>Chicago Board Options Exchange</i>

Lista de símbolos

A_i, B_i	Matrizes de coeficientes
C_t	Coefficiente de curvatura
CAM	Taxa de câmbio
CRE	Crescimento econômico
DIV_t	Dívida pública (% do PIB) no momento t
DUR_t	<i>Duration</i> de Macaulay (prazo médio) da carteira de títulos do governo no momento t
$EMBI_t$	<i>Emerging Markets Bond Index Plus</i> - Brasil no momento t
EPU_t	<i>Economic Policy Uncertainty</i> (americano) no momento t
IIE	Indicador de Incerteza Econômica (Brasil) no momento t
INF_t	Expectativa de inflação no momento t
$f_t(\tau_1, \tau_2)$	Taxa <i>forward</i> , entre os vértices τ_1 e τ_2
g_t	Produto real (atividade econômica)
INF_t	Inflação no momento t
K_0	Vetor de constantes de um VAR
K_1	Vetor de coeficientes lineares de um VAR(1)
L_t	Coefficiente de nível
M_t	Vetor de variáveis macroeconômicas
$p_t(\tau)$	Preço de um título (zero-cupom) em t , com vencimento em τ
PC_{it}	Vetor com a i -ésima componente principal da curva $Y_t(\cdot)$
$PC_t^{\mathcal{L}}$	Matriz com as \mathcal{L} primeiras componentes principais da curva $Y_t(\cdot)$
$PRI_t(\tau)$	Prêmio de Risco Inflacionário em t , para o horizonte τ
r_t	Taxa de juros de curto prazo (instantânea) em t

$rx_{t,t+h}(\tau)$	O excesso de retorno em segurar um título com vencimento em τ por h períodos;
$sp_t(\tau)$	O <i>spread</i> entre o retorno de um título com vencimento em τ e o de um título de um período;
S_t	Coefficiente de inclinação
t	Índice de tempo, tal que $t \in T$
T	Espaço de tempo ou espaço paramétrico (se for marcador temporal de um processo estocástico)
$TP_t(\tau)$	Prêmio de Risco em t para o vencimento de τ
Tr	Medida de <i>spillover</i> (transbordamento)
UCI	Utilização da Capacidade Instalada
X_t	Variável aleatória ou vetor de fatores de risco (ou de fatores dinâmicos)
$\{X_t\}_{t \in T}$	Sequência de variáveis aleatórias, ou seja, um processo estocástico
$y_t(\tau)$	Taxa de rendimento ou <i>spot</i> no período t com vencimento em τ , ou funcional da curva de juros no período t
$\tilde{y}_t(\tau)$	Taxa de rendimento neutra ao risco (estimada) no período t com vencimento em τ
VIX_t	<i>Volatility Index</i> no momento t
Y_t	Vetor das τ taxas de rendimento ou <i>spot</i> no período t
\mathcal{F}	σ -álgebra (sigma-álgebra) sobre um conjunto X
\mathcal{L}	Número de fatores latentes (componentes principais)
\mathcal{M}	Número de fatores macroeconômicos
\mathbb{N}	Conjunto dos números naturais
\mathcal{N}	Número de fatores de risco (latentes e macroeconômicos)
\mathbb{P}	Uma medida de probabilidade ou processo gerador de dados
\mathbb{Q}	Medida de probabilidade neutra ao risco (caso particular de \mathbb{P})
\mathbb{R}	Conjunto dos números reais
α	Coefficiente/parâmetro linear <i>alpha</i>

β	Coefficiente/parâmetro linear <i>Beta</i>
δ	Parâmetro de penalização
ϵ, η	Resíduo (variável aleatória ruído branco, $\epsilon, \eta \sim N(0, 1)$)
λ	Preço do risco (classe com não arbitragem) ou Taxa (ou parâmetro) de decaimento (classe NS)
μ	Retorno esperado ou coeficiente de <i>drift</i>
Ω	Espaço amostral
π	Taxa de inflação
ϕ	Função de densidade de probabilidade
Ψ_{ij}^H	H -ésimo passo da decomposição generalizada da variância do erro de previsão entre x_i e x_j
σ	Volatilidade ou coeficiente de difusão
Σ	Matriz de covariância dos resíduos (em um VAR)
τ	Vértice na curva de juros (ou horizonte de vencimento do título)
θ_t	Função de <i>drift</i>
$\xi_{t,t+1}$	<i>Pricing kernel</i> ou taxa estocástica de desconto entre os período t e $t + 1$

Sumário

1	INTRODUÇÃO	18
1.1	Contextualização	19
1.2	Problema de Pesquisa	22
1.3	Objetivos	22
1.4	Justificativa e relevância	23
1.5	Estrutura da tese	24
2	REVISÃO TEÓRICA	25
2.1	Introdução à modelagem da curva de juros	25
2.1.1	Teorias tradicionais sobre a curva de juros	28
2.1.2	Modelos estáticos de curva de juros	31
2.1.2.1	Modelos estocásticos de taxa de curto prazo	32
2.1.2.2	Modelos de interpolação da curva de juros	36
2.2	Modelos dinâmicos de curvas de juros	39
2.2.1	O problema de <i>spanning</i>	45
2.3	Fatores de risco associados às curvas de juros	48
2.3.1	Modelos dinâmicos macro-financeiros de curva de juros	50
2.3.2	Impactos da estrutura da dívida pública	53
2.3.3	Fatores internacionais e curva de juros	55
2.4	Incerteza na política econômica	59
2.4.1	Incerteza na política econômica e curvas de juros	63
2.4.2	<i>Spillovers</i> da incerteza na política econômica	67
3	METODOLOGIA	69
3.1	Caracterização da pesquisa	69
3.2	Fontes de dados e variáveis	69
3.3	Procedimentos econométricos	75
3.3.1	Integração entre a curva de <i>Swap DI</i> \times <i>Pré</i> e a <i>ETTJ</i>	76
3.3.2	<i>Spillovers</i> de choques americanos	78
3.3.3	Incerteza na política econômica e curva de juros brasileira	79
3.3.4	Poder explicativo com muitas variáveis independentes	82
3.3.5	Impacto informacional de indicadores de incerteza em <i>DTSMs</i>	84
4	RESULTADOS	86
4.1	Análise prévia dos dados	86
4.2	Integração entre a curva de <i>Swap DI</i> \times <i>Pré</i> e a <i>ETTJ</i>	91

4.3	<i>Spillovers</i> de choques americanos	93
4.4	Incerteza na política econômica brasileira e curva de juros	99
4.5	Análise do poder explicativo das variáveis	108
4.6	Impacto informacional dos indicadores de incerteza em DTSMs	115
5	CONCLUSÃO	117
	REFERÊNCIAS	120
	APÊNDICES	135
	APÊNDICE A – FIGURAS E TABELAS COMPLEMENTARES	136
	APÊNDICE B – CÓDIGO EM R DOS PROCEDIMENTOS ECONÔMICOS	150

1 INTRODUÇÃO

A taxa de juros é um dos instrumentos de política monetária utilizados pelo Banco Central para alcançar suas metas econômicas. Como efeito, a curva de juros corrente contempla expectativas acerca das atuações futuras da autoridade monetária sobre o juro. Nesse contexto, a literatura de curva de juros vem, cada vez mais, incorporando aspectos macroeconômicos em sua modelagem ([Ang e Piazzesi \(2003\)](#), [Diebold e Li \(2006\)](#), [Rudebusch e Wu \(2008\)](#), [Joslin, Le e Singleton \(2013\)](#), [Bauer e Hamilton \(2018\)](#)). Isto posto, a política econômica do governo é permeada por incertezas. Consequentemente, conjuntura-se que variações nessa incerteza influenciam a dinâmica da curva de juros brasileira.

Após a crise de 2007-2008, um questionamento que vem ressurgindo na literatura macro-financeira é quanto ao impacto das variações temporais da incerteza inerente à política econômica. Estudos têm demonstrados os efeitos desta sobre as flutuações econômicas ([Bloom \(2014\)](#), [Basu e Bundick \(2017\)](#) e [Carriero, Clark e Marcellino \(2018\)](#)), o mercado acionário ([Antonakakis, Chatziantoniou e Filis \(2013\)](#), [Pástor e Veronesi \(2013\)](#) e [Gilchrist, Sim e Zakrajšek \(2014\)](#)) e, mais recentemente, a curva de juros ([Creal e Wu \(2017\)](#), [Ioannidis e Ka \(2021\)](#) e [Leippold e Matthys \(2022\)](#)). Concomitantemente, desde [Baker, Bloom e Davis \(2016\)](#), a pesquisa nessa área vem desenvolvendo indicadores para mensurar adequadamente a incerteza, um conceito abstrato, que não pode ser medido diretamente e que deve refletir a percepção de incerteza na mente dos agentes econômicos.

Além do ambiente macroeconômico e da incerteza na política econômica, a literatura recente tem identificado outras fontes (isoladas) de fatores explicativos da dinâmica na curva de juros, como a segmentação na curva ([Greenwood e Vayanos \(2010\)](#), [Greenwood e Vayanos \(2014\)](#) e [Marçal e Marinho \(2014\)](#)) e o mercado internacional de crédito ([Sowmya, Prasanna e Bhaduri \(2016\)](#), [Stona e Caldeira \(2019\)](#) e [Cavaca e Meurer \(2021\)](#)). Todavia, um questionamento prático importante é quais destas possuem conteúdo informacional adicional para modelar a dinâmica da curva de juros. Um poderoso argumento teórico debatido na última década sugere que a própria curva corrente contém a maior parte (se não toda) da informação útil para prever as taxas de juros ([BAUER; HAMILTON, 2018](#)). Essa possibilidade de *span* das variáveis latentes à curva sobre as exógenas não refuta a relevância teórica destas, mas tem uma implicação prática relevante: a de que fatores exógenos são desnecessários para estimar os juros futuros e os prêmios de risco ([BAUER; RUDEBUSCH, 2017](#)). Em vista disso, uma extensão desse questionamento é se, em termos operacionais, a influência da incerteza na política econômica já está contemplada em outras variáveis (latentes ou exógenas).

1.1 Contextualização

Participantes do mercado e autoridades monetárias acompanham de perto a curva de juros, para precificar ativos e para obter informações acerca das expectativas do mercado. Ao compreender sua dinâmica, investidores podem especular ou se proteger de variações nos preços dos ativos. Por isso, o estudo da dinâmica na curva de juros tem ganhado cada vez mais importância na pesquisa de precificação de ativos (CHRISTENSEN; DIEBOLD; RUDEBUSCH, 2011; ALBUQUERQUE et al., 2016; BINSBERGEN; KOIJEN, 2017).

Por sua vez, ao observá-la, o governo pode traçar políticas econômicas mais adequadas às reações do mercado, ou mesmo atuar diretamente sobre a curva, afetando taxa de juros de longo prazo. A taxa de juros de curto prazo é um instrumento de política monetária sob controle direto dos bancos centrais - direcionando as taxas de longo prazo (DIEBOLD; PIAZZESI; RUDEBUSCH, 2005). Mais recentemente, devido ao esgotamento desse instrumento quando se aproxima do limiar (nominal) de taxa zero, alguns bancos centrais têm recorrido a programas de enxugamento na oferta de títulos de médio e de longo prazo para reduzir as taxas com vencimentos maiores (LEIPPOLD; MATTHYS, 2022). Como as taxas de longo prazo afetam as decisões de consumo e investimento de famílias e firmas, os bancos centrais têm utilizado essas duas formas de atuação para alcançar suas metas de controle inflacionário e de crescimento econômico.

Em vista disso, desde Ang e Piazzesi (2003), a literatura vem incorporando variáveis macroeconômicas para modelar a dinâmica da curva de juros. Em especial, devido à tratabilidade computacional e interpretativa, o carro-chefe desses estudos tem sido os modelos dinâmicos de não arbitragem Gaussianos afins (DUFFEE, 2013b; JOSLIN; LE; SINGLETON, 2013; BAUER; RUDEBUSCH, 2017). Nestes, a dinâmica dos rendimentos e dos prêmios de risco é ditada exclusivamente pelas variações nos fatores de risco. Não obstante, a pesquisa sobre os determinantes da dinâmica da curva de juros tem produzido uma enorme literatura, com obstáculos consideráveis (PIAZZESI, 2010).

O ponto de partida na identificação dos fatores de risco (determinantes da dinâmica da curva) é a própria curva de juros. Um fato estabelecido há tempo é que a curva corrente contém informações sobre a curva de juros futura, e, por isso, a previsão da taxa de juros pode ser feita utilizando o arcabouço de séries temporais (DUFFEE, 2002). Em especial, desde que Litterman e Scheinkman (1991) demonstraram que o conteúdo informacional nos diversos vértices da curva pode ser reduzido a poucos fatores (via componentes principais), a literatura tem adotado a projeção desses (poucos) fatores como método para modelar a dinâmica da curva como um todo - denominando-os como fatores latentes.

No tocante ao uso de séries macroeconômicas como fatores de risco, isso não só incorpora a evolução de fatores de risco sistêmico como também antecipa os choques oriundos da atuação da autoridade monetária. Ao revisar a literatura, Duffee (2013b)

levantou que, além das latentes à curva de juros, as principais variáveis macroeconômicas empregadas na modelagem macro-financeira de títulos públicos são *proxies* para: a inflação, o hiato do produto (*output gap*) e componentes cíclicas da atividade econômica (como a Produção Industrial ou o Produto Interno Bruto (PIB)), assim como postulado pela Regra de Taylor (em Taylor (1993)). Além destas, para o mercado brasileiro, também são utilizadas variáveis associadas ao mercado externo e ao endividamento do governo, como em Matsumura e Moreira (2015) e em Ferreira (2022).

Contudo, apesar de parcialmente reconhecerem que a dinâmica da curva de juros antecipa a atuação dos bancos centrais, tais modelos macro-financeiros não abarcam a incerteza que permeia essa atuação. Como exposto em IMF (2012) e em IMF (2013), a incerteza quanto às políticas econômicas dos EUA e da Europa contribuíram para o declínio econômico mundial acentuado em 2008-2009 e a lenta recuperação posterior. No tocante a curva de juros, pela Teoria da Preferência pela Liquidez, as taxas de longo prazo são definidas pela soma das expectativas de taxas de curto prazo mais o prêmio de risco de liquidez - não observáveis diretamente, exigindo um modelo teórico para segregá-los (BAUER; HAMILTON, 2018). Em razão das flutuações da incerteza na política econômica, esse prêmio deverá variar ao longo do tempo, tornando, assim, o mecanismo de transmissão da política monetária ainda mais complexo, ao obscurecer a relação entre as taxas de curtíssimo prazo - controladas pelos bancos centrais - e as de longo prazo (WRIGHT, 2011). Dessa forma, mensurar o impacto da incerteza econômica sobre a dinâmica do prêmio de risco auxilia a: i) identificar as expectativas de juros do mercado; e ii) avaliar a efetividade da política monetária sobre as taxas de longo prazo.

Pontua-se que a influência da incerteza sobre decisões individuais é um aspecto central na teoria de finanças, sendo explorada desde Markowitz (1952). Por sua vez, a teoria econômica considera os efeitos da incerteza sobre a atividade desde Knight (1921) e Keynes (1936). Todavia, o debate acerca das flutuações na incerteza inerente à política econômica é relativamente recente. Seu início é demarcado por Bloom (2009), e, desde então, um grande corpo de pesquisa tem se formado (CARRIERO; CLARK; MARCELLINO, 2020). A incerteza é um conceito amorfo e não pode ser medida objetivamente. Para quantificar suas variações temporais, geralmente utiliza-se *proxies* como: a volatilidade de retornos acionários; a dispersão transversal em *surveys* de expectativas; e a contagem de palavras-chave relacionadas à incerteza nas publicações de notícias. Contudo, toda *proxy* tem suas limitações. Visando suprimi-las, a pesquisa recente tem desenvolvido indicadores compostos como o *Economic Policy Uncertainty* (EPU) de Baker, Bloom e Davis (2016), o *Monetary Policy Uncertainty* (MPU) de Husted, Rogers e Sun (2019) e o Indicador de Incerteza da Economia - Brasil (IIE-Br) de Ferreira et al. (2019).

Uma vasta literatura tem relacionado a incerteza capturada nesses indicadores aos mais diversos problemas financeiros e econômicos. Porém, poucos trabalhos avaliaram o

impacto da incerteza da política econômica sobre a curva de juros. [Leippold e Matthys \(2022\)](#) utilizaram um modelo de equilíbrio geral para demonstrar que mudanças no EPU podem causar efeitos distintos entre os prêmios de risco de curto e os de longo prazo. [Ioannidis e Ka \(2021\)](#) constataram que o EPU contém informação acerca dos rendimentos futuros e que adicioná-lo como fator de risco no modelo dinâmico de curva de juros não explica significativamente as variações dos rendimentos na curva, mas impacta a identificação do prêmio de risco. Adicionalmente, [Tillmann \(2020\)](#) e [Shang \(2022\)](#) verificaram que a sensibilidade da curva de juros a choques na política monetária é condicionada ao grau de incerteza - mensurado pelo EPU ou pelo MPU.

A despeito disso, a pesquisa empírica recente tem identificado outras fontes de fatores de risco, além das variáveis latentes e das macroeconômicas. Após a crise de 2008, alguns bancos centrais recorreram a programas de enxugamento na oferta de títulos de médio e de longo prazo, para reduzir as taxas com vencimentos maiores. Essa abordagem não-ortodoxa pode ser explicada pela Teoria do Habitat Preferido formalizada em [Vayanos e Vila \(2021\)](#), trabalho que circulou a partir de 2009. Ela não revoga a importância das expectativas (ou dos prêmios) na precificação das taxas de juros, mas, ao considerar a existência de agentes com preferências por vencimentos específicos, explica porque choques na demanda ou na oferta de vencimentos específicos são localmente mais impactantes do que no restante da curva.

Baseado nesta teoria, [Greenwood e Vayanos \(2014\)](#) avaliaram os efeitos da oferta segmentada de títulos sobre a curva de juros, sendo seguidos por [Marçal e Marinho \(2014\)](#), [Santana \(2022\)](#) e [Ferreira \(2022\)](#) para o mercado brasileiro. Eles constataram que o prazo médio da dívida pública (a *Duration* de Macaulay) é uma variável explicativa significativa, mesmo quando controlada por outros fatores e com o uso de estimadores robustos. Logo, assumindo que a dinâmica da curva de juros se encontra em um campo intermediário à Teoria da Preferência pela Liquidez e à do Habitat Preferido, uma lacuna em aberto é se a *Duration* de Macaulay não se enquadra como fator de risco na dinâmica da curva de juros.

Outra fonte de fatores de risco é o ambiente internacional. Estudos recentes constataram a existência de fatores globais em comum nas curvas de juros de diversos países ou de co-movimentos entre curvas de juros de países distintos ([Graveline e Joslin \(2010\)](#), [Sarno, Schneider e Wagner \(2012\)](#), [Bauer e Rios \(2012\)](#), [Jotikasthira, Le e Lundblad \(2015\)](#), [Abbritti et al. \(2018\)](#)). No tocante à curva brasileira, [Stona e Caldeira \(2019\)](#) estimaram que o fator de nível da curva americana explica quase metade da variação no fator de nível da curva brasileira, além de impactar os fatores de inclinação e de curvatura no longo prazo. De forma convergente, [Cavaca e Meurer \(2021\)](#) demonstraram alto grau de *spillover* (transbordamento) da curva americana sobre as curvas de países na América Latina (Brasil, Chile, Colômbia e Peru), com aumento substancial no índice de *spillover* durante crises financeiras e outros períodos de alta volatilidade.

Neste tópico, um questionamento a ser feito é quanto às duas curvas brasileiras exploradas na literatura, a curva de *Swap* DI \times Pré da B³ (Bolsa de Valores brasileira) e a estrutura a termo da taxa de juros dos títulos soberanos estimada pela ANBIMA (Associação Brasileira das Entidades dos Mercados Financeiro e de Capitais). As teorias macro-financeiras perpassam pela curva de juros do governo. Todavia, devido à maior liquidez nos vértices, boa parte dos estudos brasileiros adotam a curva de *swap*, assumindo implicitamente que as duas são aderentes. Entretanto, não foi encontrado estudo acerca do grau de integração entre elas, deixando uma lacuna a ser explorada.

Por fim, o *spillover* de choques entre países não se dá apenas entre as curvas de juros. Segundo relatórios do Fundo Monetário Internacional (IMF (2012) e IMF (2013)), a incerteza na política econômica de países centrais têm efeitos globais. De acordo com Trung (2019), a incerteza de uma economia líder como a americana não está confinada dentro de suas fronteiras, podendo se espalhar para o resto do mundo. Complementarmente, vale ressaltar que economias emergentes são muito mais sensíveis a choques de incerteza exógenos (CARRIÈRE-SWALLOW; CÉPEDES, 2013; AIZENMAN; CHINN; ITO, 2016; ANAYA; HACHULA; OFFERMANN, 2017).

Neste aspecto, Colombo (2013) demonstrou que variações da incerteza na política econômica americana são mais impactantes na produção industrial e na inflação de países da zona do euro do que as variações oriundas dos demais países no próprio bloco. Em linha, estudos como Kido (2016), Demir e Ersan (2017), Trung (2019), Caggiano, Castelnuovo e Figueres (2020), Lakdawala, Moreland e Schaffer (2021) e Karanasos, Yfanti e Hunter (2022) encontraram efeitos significativos de *spillover* do EPU americano para outros países, impactando a incerteza e as variáveis macro-financeiras nestes. Em especial, nos últimos dois anos, estudos como Umar et al. (2021), Umar, Riaz e Zaremba (2021), Benlagha e Hemrit (2022) e Umar, Riaz e Aharon (2022) também avaliaram o *spillover* da incerteza na política econômica sobre títulos ou curvas de juros de outros países, mas o foco foi avaliar a conectividade entre as curvas dos países.

1.2 Problema de Pesquisa

Uma vez contextualizada a modelagem macro-financeira da curva de juros, enuncia-se a seguinte questão de pesquisa: *em que medida as variações da incerteza na política econômica, brasileira e americana, explicam a dinâmica das curvas de juros brasileira?*

1.3 Objetivos

O objetivo geral desta tese é: explicar como a dinâmica da curva de juros brasileira é influenciada pelas variações de incerteza na política econômica do Brasil e na dos Estados

Unidos.

Associado ao objetivo geral, tem-se os seguintes objetivos específicos:

- i) avaliar comparativamente as duas curvas de juros brasileiras exploradas na literatura, a curva de Swap DI \times Pré e a estrutura a termo das taxas de juros dos títulos soberanos;
- ii) mensurar o grau de *spillover* de choques da curva de juros e da incerteza na política econômica americana sobre a curva de juros brasileira;
- iii) auferir o processo de propagação de choques dos fatores de risco de incerteza na política econômica, doméstica e americana, sobre os fatores latentes da curva brasileira - que sintetizam a forma funcional da curva;
- iv) identificar os fatores de risco mais relevantes para explicar a dinâmica da curva de juros brasileira.

1.4 Justificativa e relevância

Como destacado por Fabozzi (2013), a curva de juros é um tema central na teoria financeira, referenciando as taxas de desconto para precificar qualquer fluxo de caixa. Ainda, ela não só referencia o mercado de títulos corrente como também contém expectativas acerca do futuro nesse mercado (CHOUDHRY, 2019). Contudo, ao revisar a literatura de modelagem macro-financeira de curva de juros, Duffee (2013a) concluiu que o progresso tem sido no sentido de entender o quão difícil é reconciliar o comportamento dessa curva com os modelos tradicionais, os de macroeconomia e os de preferências dos investidores. Em particular, ele levantou que, apesar da forma da curva variar substancialmente no tempo, ainda é expressivamente difícil alinhá-la com as variações na atividade macroeconômica, na expectativa de inflação ou em medidas plausíveis de prêmio de risco.

Nessa perspectiva, esta tese contribuiu com a literatura teórica ao explorar o papel da incerteza na política econômica sobre dinâmica da curva de juros, investigando aspectos relacionados à capacidade preditiva, aos impactos sobre forma funcional da curva e ao conteúdo informacional agregado em modelos dinâmicos macro-financeiros. Em particular, esse processo explorou a lacuna relacionada ao impacto da incerteza doméstica e da americana sobre a curva de juros brasileira. Complementarmente, também contribuiu com a literatura de curva de juros ao avaliar:

- i) o grau de integração entre a curva de Swap DI \times Pré da B³ e a estrutura a termo da taxa de juros dos títulos soberanos estimada pela ANBIMA;

- ii) efeitos de *spillover* da curva e da incerteza americana sobre a curva e a incerteza brasileira; e
- iii) a capacidade explicativa de variáveis elencados na literatura como fatores de risco, uma vez controladas pelas demais.

Por fim, sob uma perspectiva prática, Piazzesi (2010) destacou que entender a dinâmica da curva de juros é importante por ao menos quatro motivos:

- i) para prever não só as taxas futuras de juros (após o ajuste ao risco de liquidez) como também a trajetória futura da atividade econômica e da inflação. Essas previsões são essenciais para a tomada de decisão de investimento das firmas, de poupança dos investidores e de política econômica do governo;
- ii) para a política monetária dos bancos centrais, pois estes ditam as taxas de curto prazo mas as decisões da “demanda agregada” são balizadas pela taxa de longo prazo. Dessa forma, é essencial entender como as alterações da taxa de curto prazo em função da atuação da autoridade monetária são refletidas nas de longo prazo.
- iii) para a política fiscal do governo, que utiliza a curva de juros para decidir a respeito do vencimento dos títulos a serem emitidos.
- iv) para precificar derivativos e gerenciamento de risco, especialmente no tocante a estratégias de *hedging*.

1.5 Estrutura da tese

Este capítulo introduziu a tese, contextualizando o problema de pesquisa, apresentando o objetivo e justificando a relevância do estudo realizado. Adiante, o capítulo 2 revisa as teorias a respeito da curva de juros, desde os aspectos mais básicos de construção da mesma, passando pela modelagem dinâmica usual, até os fatores de risco associados à dinâmica da curva de juros na literatura: os latentes, os macroeconômicos, os oriundos da segmentação na curva, os internacionais e, em destaque, a incerteza na política econômica. O capítulo 3 apresenta a metodologia, caracterizando a pesquisa, descrevendo as fontes de dados e as variáveis utilizadas e apresentando os procedimentos econométricos adotados. O capítulo 4 expõem os resultados obtidos e, por fim, o capítulo 5 apresenta as considerações finais, as limitações do trabalho e algumas propostas de pesquisa futura.


2 REVISÃO TEÓRICA

Esse capítulo revisa a literatura de modelagem dinâmica da curva de juros e, complementarmente, explora fontes de fatores de risco. A seção 2.1 introduz os aspectos básicos sobre curva de juros, as principais teorias quanto às formas funcionais (subseção 2.1.1) e a modelagem da curva de juros (subseção 2.1.2). A seção 2.2 apresenta a estrutura geral dos modelos dinâmicos e, em particular, a subseção 2.2.1 discute a possibilidade de *spanning* nos modelos afins - a abordagem utilizada nesta tese. Em especial, a seção 2.3 apresenta os principais fatores de risco explorados na literatura. Nesta, além dos fatores latentes à curva, são abarcadas três fontes de fatores associados à dinâmica da curva de juros brasileira: i) o ambiente macroeconômico doméstico (subseção 2.3.1); ii) mudanças na oferta de títulos para cada vencimento na curva (subseção 2.3.2); e iii) o mercado de crédito estrangeiro (subseção 2.3.3). Por fim, adicionalmente a estas três fontes, a seção 2.4 explora a incerteza na política econômica e suas formas de mensuração. Em especial, ela também revisa estudos acerca da influência da incerteza sobre a curva de juros e de *spillovers* internacionais da incerteza.

2.1 Introdução à modelagem da curva de juros

A representação gráfica entre o retorno (*yield to maturity*) de títulos com mesma classificação de risco, mas maturidades distintas, é conhecida como curva de juros (curva de retornos, ou *yield curve*). Ilustrativamente, a Figura 1 apresenta a curva de juros estimada pela ANBIMA em três datas, 26/02/2010, 29/04/2016 e 30/06/2022.

Figura 1 – Curva de juros brasileira



Fonte: ANBIMA , elaboração própria.

A figura apresenta as taxas anualizadas de rendimento dos títulos públicos brasileiros para cada horizonte de vencimento. Por exemplo, em 30/06/2022, o rendimento para uma aplicação de um ano (12 meses) era de 13,8% ao ano, enquanto o rendimento para uma aplicação de três anos (36 meses) era de 12,8% ao ano.

De acordo com Fabozzi (2013), a curva de juros é um tema central na teoria financeira (utilizada para precificação em qualquer fluxo de caixa) e, segundo Christensen, Diebold e Rudebusch (2011), Albuquerque et al. (2016) e Binsbergen e Koijen (2017), entre outros, o estudo da dinâmica na estrutura da taxa de desconto tem ganhado cada vez mais importância na pesquisa de precificação de ativos. Segundo Cochrane (2011), enquanto Fama (1970) argumentou que os fatores “esperados” do fluxo de caixa - testando a condição de eficiência do mercado - forneceram o arcabouço técnico para organizar a pesquisa em precificação de ativos naquela era (quarenta anos atrás), é a componente de “desconto” que melhor organiza esse campo de pesquisa atualmente.

Todavia, alguns pontos devem ser esclarecidos quanto à escolha dos títulos públicos para a determinação de uma curva de juros tomada como referência pelo mercado. Segundo Fabozzi (2013), é antiga a prática de construir curvas de retornos a partir de preços e retornos no mercado de títulos do Tesouro, visando, com isso, estabelecer um *benchmark* para a precificação de juros nos demais setores do mercado de crédito. Contudo, ainda que dois títulos tenham a mesma maturidade e a mesma classificação de risco, os respectivos retornos serão diferentes, caso eles possuam programas distintos de pagamento de cupons. Para evitar tal problema, desenvolveu-se uma maneira mais precisa de estimar a relação Retorno X Maturidade ao utilizar apenas títulos de zero-cupom.

Obtém-se, assim, um caso particular de curva de juros denominado Estrutura a Termo da Taxa de Juros (ET TJ), mais adequado para a avaliação dos demais ativos de renda fixa. Destaca-se que o Tesouro emite títulos zero-cupom para poucas maturidades. Por isso, é usual derivar essa curva a partir de considerações teóricas sobre os títulos negociados pelo tesouro. Como cada pagamento de cupom de um título qualquer pode ser interpretado isoladamente como um título de zero-cupom, qualquer título pode ser visto como uma composição de títulos de zero-cupom. Conseqüentemente, o valor deste título deverá ser igual à soma dos valores das suas componentes zero-cupom (caso contrário, seria possível estabelecer estratégias de ganho com arbitragem). Como os títulos do Tesouro balizam o risco sistêmico, é a partir da estrutura a termo que os prêmios de risco devem ser adicionados de forma a precificar os demais títulos no mercado. Todavia, cabe antecipar que há outras curvas de juros relevantes para analistas de mercado, e, por isso, esta tese não se restringe à ET TJ.

Alguns conceitos básicos para a análise da curva de juros são apresentados a seguir. O retorno $y(\tau)$ de um título do Tesouro para dada maturidade τ é chamado de taxa *spot* (ou taxa à vista), e a representação gráfica entre esta taxa (em termos anualizados) e sua

respectiva maturidade é denominada curva da taxa *spot*. A curva derivada a partir dessas considerações teóricas sobre os títulos é conhecida como curva de taxas *spot* teórica e sua representação gráfica é a ETTJ. De acordo com Fabozzi (2012), esta consiste, portanto, no conjunto de taxas aplicadas ao fluxo de caixa para a precificação de títulos públicos.

Assim como a ETTJ permite extrapolar taxas *spot* para outras maturidades, ela também é base para a extrapolação de expectativas do mercado quanto às taxas futuras (com horizonte h a partir do vencimento τ), através da denominada taxa *forward* $f(\tau + h, \tau)$ (ou a termo). Suponha que, no período t , um investidor possua duas alternativas: i) aplicar em um título de dois anos na taxa *spot* $y_t(2)$; ou ii) investir por um ano na taxa $y_t(1)$ e reaplicar por mais um ano na taxa chamada de $f_t(2, 1)$. Pela hipótese de não arbitragem,

$$(1 + y_t(2))^2 = (1 + y_t(1)) (1 + f_t(2, 1)) \quad (2.1)$$

permite determinar o valor de $f_t(2, 1)$. A princípio, a taxa *forward* $f_t(2, 1)$ contempla a expectativa de mercado para a taxa vigente no intervalo entre o final do primeiro período e o final do segundo (*i.e.*, vértices 1 e 2 da curva de juros *spot*). Ainda, ampliando o horizonte de vencimento para τ períodos, tem-se:

$$(1 + y_t(\tau))^\tau = (1 + s_t(1)) (1 + f_t(2, 1)) (1 + f_t(3, 2)) \dots (1 + f_t(\tau, \tau - 1)). \quad (2.2)$$

Portanto, a taxa *spot* $y(\tau) = [(1 + s_t(1))(1 + f_t(2, 1))(1 + f_t(3, 2)) \dots (1 + f_t(\tau, \tau - 1))]^{1/\tau} - 1$ é uma média geométrica entre a taxa *spot* de curto prazo e as expectativas fornecidas pelas taxas *forwards*. Isto posto, cabe pontuar que estudos empíricos demonstram que a taxa *forward* não é uma boa previsora dos juros futuros (FABOZZI, 2013). De todo modo, ela é um importante balizador para decisões individuais, ao capturar o consenso do mercado.

Além da curva de juros oriunda de títulos do governo - a ETTJ -, outro *benchmark* relevante é a curva de juros derivada de contratos de *swap*, *Pré-fixado* \times *Taxas Referenciais do mercado interbancário* (tais como a *LIBOR* (*London Interbank Offered Rate*) na Inglaterra, a *Euribor* para a zona do Euro e o *DI* no Brasil). De acordo com Fabozzi (2013), cada vez mais tais curvas vêm sendo utilizadas como referencial em diversos países, mesmo quando o mercado de títulos públicos é líquido. Apesar de não serem livre do risco de *default* como as do governo, há três vantagens principais ao optar pela curva de *swap*:


- i) pode haver razões técnicas ou regulatórias/tributárias para alguma taxa de juros de títulos públicos (vértice da curva) ser enviesada;
- ii) é necessária uma grande variedade vencimentos para criar uma curva de juros representativa, mas a maioria dos governos ofertam títulos com pouca variedade; e
- iii) a comparação entre países a partir da taxa inter-bancária é mais fácil do que a entre governos - dadas as peculiaridades dos mesmos.

Em linha, a literatura brasileira recorrentemente adota a curva *swap* $DI \times Pré$ para contornar a escassez de títulos públicos negociados para vencimentos mais longos. Entre outros, a curva *swap* é utilizada em [Tabak \(2003\)](#), [Caldeira, Moura e Portugal \(2010\)](#), [Matsumura, Moreira e Vicente \(2011\)](#), [Laurini e Hotta \(2010\)](#), [Almeida e Faria \(2014\)](#), [Matsumura e Moreira \(2015\)](#) e [Caldeira et al. \(2016\)](#).

2.1.1 Teorias tradicionais sobre a curva de juros

Uma série de teorias foram desenvolvidas visando explicar o formato da curva e suas mudanças ao longo do tempo. Nessa seção, são apresentadas as principais teorias na literatura a respeito das mudanças dinâmicas da curva de juros. Ilustrativamente, a Figura 2 apresenta as possíveis formas funcionais de uma curva de juros em dado instante t :

Figura 2 – Possíveis formas funcionais da curva de juros



Fonte: elaboração própria.

Geralmente, a curva de juros é ascendente (a). Todavia, expectativas de queda na taxa futura podem reduzir a inclinação (c) ou mesmo revertê-la (b).

De forma sucinta, além das expectativas do mercado, a literatura também considera prêmios de liquidez e falhas de mercado como responsáveis pela dinâmica da curva de juros. Entre as teorias mais tradicionais, [Sharpe, Alexander e Bailey \(1999\)](#), [Fabozzi \(2013\)](#) e [Petitt, Pinto e Pirie \(2015\)](#) destacaram quatro como as mais relevantes: i) a Teoria de Expectativas Puras; ii) a Teoria da Preferência pela Liquidez; iii) a Teoria dos Mercados Segmentados; e iv) a Teoria do Hábitat Preferido. De todo modo, isoladamente, nenhuma dessas teorias é capaz de explicar completamente a dinâmica funcional das curvas de juros, sendo mais adequado adotar combinações dessas teorias ([CHOUDHRY, 2019](#)).

Cronologicamente, a primeira teoria é a conhecida como Teoria das Expectativas Puras ou Teoria das Expectativas Imparciais. Segundo [Shiller e McCulloch \(1990\)](#), em termos gerais, a hipótese quanto às expectativas é certamente muito antiga, porém, não recebeu atenção acadêmica até o trabalho de [Fisher \(1896\)](#). Essa teoria afirma que a taxa *forward* é um preditor não enviesado da taxa *spot* futura e sua interpretação mais ampla é a de que os títulos de qualquer maturidade são substitutos perfeitos um do outro. Por exemplo, comprar um título com vencimento de cinco anos e mantê-lo por três anos tem o

mesmo retorno esperado que comprar um título de três anos ou comprar uma série de três títulos de um ano. Dessa forma, as taxas *forward* representam exclusivamente as taxas futuras esperadas. Adicionalmente, as previsões da teoria de expectativas imparciais são consistentes com a suposição de neutralidade de risco¹.

De acordo com [Cochrane \(2005\)](#), a hipótese de expectativas (enviesada pelo prêmio de liquidez ou não) pode ser matematicamente estabelecida através de três formas equivalentes:

1. O rendimento de vencimento N é a média dos rendimentos futuros esperados de um período.

$$y_t(N) = \frac{1}{N} \sum_{i=0}^N E_t(y_{t+i}(1)) \text{ (+ prêmio de risco)}; \quad (2.3)$$

2. A taxa *forward* é igual à taxa *spot* futura esperada.

$$f_t(N + 1, N) = E_t(y_{t+N}(1)) \text{ (+ prêmio de risco)}; \text{ e} \quad (2.4)$$

3. Os retornos esperados em determinado período de retenção de um título são os mesmos independentemente dos vencimentos envolvidos.

$$E_t \left(\frac{p_{t+1}(N-1)}{p_t(N)} \right) = y_t(1) \text{ (+ prêmio de risco)}, \quad (2.5)$$

onde $p_t(\tau)$ é o preço de um título em t cujo vencimento seja em τ . Assim, $\frac{p_{t+1}(N-1)}{p_t(N)}$ é o retorno ao comprar um título com vencimento em N períodos e retê-lo por um ano (quando seu preço será $p_{t+1}(N-1)$).

Além dessa interpretação, uma variação mais rigorosa da Teoria das Expectativas Puras é a Teoria das Expectativas Locais. Amparada na hipótese de não haver ganhos de arbitragem, ela sugere que o retorno de títulos de maturidades distintas será o mesmo no curto prazo (a taxa livre de risco), não havendo, assim, prêmios de risco de curto prazo. Contudo, essa teoria é mais flexível ao permitir a existência de prêmios de liquidez para investimentos de horizonte maior.

Apesar do apelo econômico dessa teoria, empiricamente, os retornos obtidos ao manter títulos de longo prazo por curto períodos de tempo são superiores aos obtidos nas aplicações em títulos de curto prazo - com maior liquidez ([PETITT; PINTO; PIRIE, 2015](#)). Por outro lado, como demonstrado em [Cox, Ingersoll e Ross \(1981\)](#), essa é a única interpretação da teoria de expectativas sustentável em um modelo de equilíbrio.

¹ Em um mundo neutro ao risco, os investidores não são afetados pela incerteza, e os prêmios de risco não existem. Todo título é livre de risco e, portanto, está sujeito à taxa livre de risco para o seu vencimento. Todavia, embora essa suposição leve a resultados interessantes, está claramente em conflito com o grande conjunto de evidências que mostram que os investidores são avessos ao risco.

Tanto a Teoria da Preferência pela Liquidez quanto a Teoria do Hábital Preferido aceitam que as expectativas sobre as taxas de juros futuras desempenhem um papel predominante na determinação dos rendimentos das obrigações de longo prazo (INGERSOLL, 1987). Contudo, ambas trabalham com expectativas enviesadas, contrapondo a Teoria de Expectativas Puras. Todavia, cada uma atribui um papel diferente ao risco e aos prêmios resultantes sobre os rendimentos de títulos distintos. Como, em parte, a Teoria do Hábital Preferido incorpora aspectos da Teoria dos Mercados Segmentados, ela será apresentada posteriormente.

A Teoria da Preferência pela Liquidez tenta explicar a aversão ao risco (ausente na teoria da expectativa pura) ao considerar que as taxas *forward* incorporam o prêmio de risco pela liquidez - além das expectativas do mercado. Segundo Cochrane (2011), há muito tempo se reconhece que alguns ativos têm taxas de desconto mais altas (ou mais baixas) em compensação por uma maior (ou menor) liquidez. Assim, dada a expectativa de taxas *spot* de curto prazo (imutáveis), essa teoria prevê que uma curva de rendimento tipicamente apresentará uma inclinação ascendente, em que as taxas *forward* fornecem uma estimativa da taxa *spot* esperada, sendo enviesada para cima devido ao valor do prêmio de liquidez.

Como exposto em Petitt, Pinto e Pirie (2015), a Teoria das Preferências de Liquidez não oferece uma explicação completa da estrutura a termo - simplesmente argumentando a favor da existência de prêmios de liquidez. Contudo, Hull (2016) a classificou como a mais atraente (em comparação com as demais Teorias de Expectativas e com a de Segmentação do Mercado), em que as taxas *forwards* são maiores que as taxas futuras esperadas.

Por sua vez, diferentemente das teorias baseadas nas expectativas dos agentes, a Teoria dos Mercados Segmentados foca nas diferenças de preferências entre credores e devedores, elencando-as como fator de influência na forma da curva de juros. Ela pressupõe que os participantes do mercado não estão dispostos a investir, ou não podem, em nada além de títulos com seu vencimento preferido. Por isso, o rendimento dos títulos de um determinado vencimento não reflete as taxas *spot* esperadas ou mesmo os prêmios de liquidez, mas sim o equilíbrio entre a oferta e a demanda de fundos desse vencimento específico. Portanto, cada ponto de vencimento da curva pode ser pensado como um mercado segmentado, em que o rendimento é determinado independentemente dos rendimentos que prevalecem em outros segmentos de vencimento. Adicionalmente, de acordo com Cochrane (2011), as razões pela qual a segmentação ocorre podem nos ajudar a entender quando e por quanto tempo a hipótese de segmentação pode ser aplicada. Por exemplo, fatores como custo de transação, custo de monitoramento ou expertise limitada sugerem que os mercados podem ser segmentados - até certo ponto.

A Teoria do Hábital Preferido se assemelha à Teoria dos Mercados Segmentados ao propor que tomadores de empréstimos e credores possuem fortes preferências por

vencimentos específicos. Contudo, ela considera que os rendimentos de vencimentos distintos não são determinados independentemente um do outro, pois, caso os retornos esperados adicionais sejam suficientemente grandes, os agentes estarão dispostos a se desviar de seus vencimentos (ou habitat) preferenciais. Dessa forma, ela contempla tanto elementos da Teoria dos Mercados Segmentados quanto da Teoria das Expectativas Puras.

Por fim, é válido notar que a maior parte da literatura moderna pressupõe que a curva de juros é pautada nas teorias de expectativas, especialmente a Teoria de Preferência da Liquidez. As seções 2.1.2.1 e 2.2 apresentam modelos quantitativos de curva de juros nos quais, essencialmente, as taxas de juros são formadas pela composição de expectativas de taxas mais um prêmio de risco. Não obstante, trabalhos recentes têm formalizado abordagens acerca da segmentação da ETTJ, como o modelo de habitat preferido de Vayanos e Vila (2021) ou a adaptação deste realizada por Almeida et al. (2017). Em particular, mais alinhado à modelagem utilizada nessa tese, Greenwood e Vayanos (2014) demonstraram empiricamente que a oferta de títulos do governo por vencimentos e as consequentes mudanças na estrutura de maturidades da dívida pública afetam os retornos esperados na ETTJ - resultado observado para o mercado brasileiro em Marçal e Marinho (2014), Santana (2022) e Ferreira (2022). Em vista disso, após a modelagem de curva de juros ser apresentada nas seções a seguir, a subseção 2.3.2 retoma essa discussão acerca da segmenta da curva com foco no problema de estrutura da dívida pública brasileira.

2.1.2 Modelos estáticos de curva de juros

Em sua origem, as teorias tradicionais não foram formalmente estabelecidas. A partir das décadas de 70 e 80, a pesquisa relacionada passou a desenvolver modelos quantitativos que buscavam descrever precisamente como as taxas de juros evoluem ao longo da curva. Neste campo de pesquisa, as teorias tradicionais, especialmente a de expectativa ou a de preferência por liquidez, foram utilizadas como pressupostos axiomáticos para a construção matemática dos modelos, especialmente os modelos estocásticos de taxa de juros. Não obstante, concomitantemente, um segundo campo de pesquisa desenvolveu-se visando suprir um problema prático: identificar as taxas em vencimentos da curva onde não existisse um título para prover uma observação direta. Consequentemente, a literatura de modelagem da curva de juros é tipicamente dividida em dois grandes grupos: i) o de modelos estocásticos (subseção 2.1.2.1); e ii) o de modelos de interpolação (subseção 2.1.2.2). De acordo com Rebonato (2016), o primeiro grupo visa explicar a curva de juros com base em fundamentos teóricos da economia, e, contrapondo este, o segundo grupo busca descrever adequadamente as curvas quanto a forma funcional. Por fim, nos anos 2000, ambas as literaturas passaram a modelar a evolução da curva de juros como um todo ao longo do tempo, o que não é abordado nos modelos estáticos nesta subseção. Tal extensão será apresentada na seção 2.2.

2.1.2.1 Modelos estocásticos de taxa de curto prazo

Diante da variedade e do rigor matemático desses modelos, a revisão teórica adiante se restringe à formalização geral dos mesmos, sem desenvolver as demonstrações matemáticas. Esses modelos buscam caracterizar o processo estocástico da taxa de curto prazo, uma vez que a curva de juros seria dada pela composição dessa taxa para horizontes maiores. Para tanto, são construídos a partir de duas estruturas, a de equilíbrio ou a de não arbitragem, ambas discutidas mais adiante. Em especial, aborda-se com mais profundidade a (sub)classe dos modelos afins (lineares) com não arbitragem - a qual tem sido o carro-chefe na pesquisa de modelos dinâmicos macro-financeiros de curva de juros (HAMILTON; WU, 2012b; DUFFEE, 2013b; BAUER; RUDEBUSCH, 2017).

Em síntese, um processo estocástico consiste em uma sequência (finita ou infinita) de variáveis aleatórias $\{X_t\}_{t \in T}$. Ou seja, para cada $t \in T \subset \mathbb{N}$ (sendo T um conjunto não-vazio, chamado de espaço paramétrico) associa-se uma variável aleatória $X_t : \Omega \rightarrow \mathbb{R}$, todas definidas sobre o mesmo espaço de probabilidades $(\Omega, \mathcal{F}, \mathbb{P})$ onde Ω é o espaço amostral, \mathcal{F} é uma σ -álgebra², e \mathbb{P} é uma medida de probabilidade.

Como introduzido por Fabozzi (2013), o ferramental matemático usualmente adotado para descrever o movimento das taxas de juros é o de equação diferencial estocástica. Em particular, a modelagem mais recorrente para descrever a dinâmica da taxa de juros assume que a taxa de curto prazo segue um processo estocástico e as demais taxas na curva de juros são relacionadas à primeira. Dessa forma, apenas a taxa de curto prazo é randômica enquanto as demais são determinadas a partir da de curto prazo - por exemplo, através de argumentos de não arbitragem.

Seja r a taxa de juros livre de risco de curto prazo (ou instantânea) considerando um contínuo temporal T . Assumindo que os preços dos títulos (assim como seus derivativos) são definidos em um mundo neutro ao risco, *i.e.*, dependem apenas do processo seguido por r . Conseqüentemente, o preço $p_t(\tau)$ de um título (zero cupom) livre de risco no período t , com pagamento de \$ 1,00 no horizonte τ , é dado por

$$p_t(\tau) = E_{\mathbb{Q}} \left[e^{-r \times \tau} \right], \quad (2.6)$$

onde $E_{\mathbb{Q}}$ é a esperança sobre a variável aleatória r , segundo a distribuição de probabilidade neutra ao risco \mathbb{Q} . Por conseguinte, ao definir $y_t(\tau)$ como a taxa de juros (*spot*) livre de risco com capitalização contínua no tempo t , para um horizonte τ , tem-se:

$$p_t(\tau) = e^{-y_t(\tau) \times \tau} \Leftrightarrow y_t(\tau) = -\frac{1}{\tau} \ln(p_t(\tau)). \quad (2.7)$$

Logo, pela equação (2.6), vale:

$$y_t(\tau) = -\frac{1}{\tau} \ln \left(E_{\mathbb{Q}} \left[e^{-r \times \tau} \right] \right). \quad (2.8)$$

² σ -álgebra (ou sigma-álgebra) é uma álgebra (coleção) de subconjuntos de Ω . Em particular, ela contém \emptyset e Ω e é fechada nos complementos e nas uniões enumeráveis. Na teoria da probabilidade, essa estrutura é utilizada para identificar os possíveis eventos e atribuir uma probabilidade aos mesmos.

Dessa forma, através da equação (2.8), pode-se estimar a curva de juros (*spot*) em t a partir do valor esperado sobre r . Por conseguinte, ao especificar o processo estocástico (neutro ao risco) sobre r , descreve-se, também, o processo estocástico sobre a curva inteira.

Por sua vez, a abordagem teórica clássica assume que as variações (infinitesimais) na taxa de curto prazo r seguem um processo de Itô (ou de Wiener generalizado). Assim, em linhas gerais, vale o processo de difusão (*i.e.*, processo contínuo Markoviano) descrito pela equação (2.9).

$$dr = \mu(r(t), t) dt + \sigma(r(t), t) dz, \quad (2.9)$$

onde $\mu(r(t), t)$ é a função/coeficiente de *drift*³, enquanto $\sigma(r, t)$ é a função/coeficiente de difusão que multiplica o processo de Wiener⁴ dz . Adicionalmente, para qualquer derivativo $G(r(t), t)$ adjacente a r , pelo Lema de Itô, tem-se

$$dG = \left(\frac{\partial G}{\partial t} + \mu \frac{\partial G}{\partial r} + \frac{\sigma^2}{2} \frac{\partial^2 G}{\partial r^2} \right) dt + \sigma \frac{\partial G}{\partial r} dz. \quad (2.10)$$

Em boa parte, os modelos (introdutórios) nessa literatura adotam um único fator como variável de estado para explicar a dinâmica da taxa de curto prazo. Todos esses modelos são casos particulares do processo diferencial estocástico descrito na equação (2.9), diferenciando-se quanto às caracterizações dos termos $\mu(r(t), t)$ e $\sigma(r(t), t)$.

Em linhas gerais, como destacado por Hull (2016) e por Choudhry (2019), as formas funcionais mais recorrentes para o termo de *drift* são:

- i) $\mu(r(t), t) = \mu r$, onde μ é uma constante; e
- ii) $\mu(r(t), t) = a(\mu - r)$, onde a mede a velocidade de reversão de r à média μ .

Já os processos mais usuais para descrever a dinâmica aleatória de r são:

- i) $\sigma(r(t), t) = \sigma$, o processo Gaussiano (ou normal);
- ii) $\sigma(r(t), t) = \sigma r$, o processo log-normal; e
- iii) $\sigma(r(t), t) = \sigma \sqrt{r}$, o processo Gaussiano quadrático.

Na prática, a adoção de modelos estocásticos com um único fator de estado para calcular toda a curva de juros pode ser inadequada quanto à qualidade no ajuste da curva, especialmente para os vencimentos de longo prazo. Em resposta a essa limitação, foram desenvolvidos modelos estocásticos multi-fatores - mais flexíveis -, tais como: o de Heath,

³ Mudança determinística no processo estocástico, também referida como taxa de deriva, taxa de crescimento ou média do processo.

⁴ Um processo markoviano definido por $dz = \epsilon \sqrt{dt}$ onde $\epsilon \sim N(0, 1)$, tal que a média de dz é 0 e a variância é dt . Por conseguinte, para um intervalo de tempo τ , a média de dr será $\mu(r, t) \times \tau$ e a variância será $\sigma^2(r(t), t) \times \tau$.

Jarrow e Morton (1990), o de Das e Foresi (1996), o de Baz e Das (1996), o de Brace, atarek e Musiela (1997) e o de Jamshidian (1997). Contudo, como levantado por Choudhry (2019), o modelo de um único fator pode ser adotado na maioria das aplicações. Em particular, cabe antecipar que a abordagem econométrica macro-financeira nesta tese combina os modelos estocásticos contínuos à adoção de vários fatores de risco (ou de estado) discretos, mensurados por variáveis latentes e por exógenas (observáveis) como as macroeconômicas. A estrutura formal base desta abordagem será apresentada na seção 2.2.

Sendo assim, os principais modelos desenvolvidos nessa literatura são categorizados em duas classes: i) modelos de equilíbrio; e ii) modelos de não arbitragem (FABOZZI, 2013; PETITT; PINTO; PIRIE, 2015; HULL, 2016; CHOUDHRY, 2019)⁵.

Como Hull (2016) afirma, os modelos de equilíbrio partem de pressupostos sobre variáveis econômicas para derivar o processo estocástico da taxa de curto prazo r . Como Diebold e Li (2006) complementam, após derivar a taxa de curto prazo, as taxas para outros vencimentos são derivadas ao impor uma série de premissas sobre os prêmios de risco. Segundo Pettitt, Pinto e Pirie (2015), visando derivar fórmulas fechadas para os preços de equilíbrio dos títulos e das taxas de juros, essa classe recorre a restrições quanto à: i) caracterização do termo de *drift* do processo estocástico; e ii) forma funcional da volatilidade na taxa de juros. Eles podem ser tanto modelos com um único fator de estado quanto modelos multi-fatores (capazes de modelar a forma da curva de juros com maior precisão, ao custo de uma maior complexidade) e precisam fazer suposições sobre o comportamento de fatores. Por exemplo, em um modelo com fator único, a taxa de curto prazo deve ser modelada como reversível à média ou deve exibir saltos? Ainda, como deve ser modelada a volatilidade da taxa instantânea?

Os modelos de equilíbrio (de um único fator) mais conhecidos são:

- o de Rendleman e Bartter (1980), cuja equação do processo de r (neutro ao risco) é

$$dr = \mu r dt + \sigma r dz; \quad (2.11)$$

- o de Cox, Ingersoll e Ross (1981), cuja equação do processo de r (neutro ao risco) é

$$dr = a(\mu - r) dt + \sigma dz, \quad (2.12)$$

sendo a o parâmetro de velocidade de reversão de r à média μ ;

- o de Vasicek (1977), cuja equação do processo de r (neutro ao risco) é

$$dr = a(\mu - r) dt + \sigma \sqrt{r} dz. \quad (2.13)$$

⁵ Alternativamente, uma categorização distinta é a proposta de James e Webber (2000).

Como observado em Hull (2016), os modelos de equilíbrio são úteis para a análise de cenários em longos períodos de tempo. Contudo, eles não são calibrados para o mercado, estimando curvas de juros nas quais pode haver oportunidades de arbitragem e pequena aderência aos dados correntes. Todavia, essa capacidade de calibragem é uma característica desejável a qualquer modelo, especialmente para a avaliação de derivativos. Esse problema é superado pelos modelos de não arbitragem (ou seja, livres de oportunidades de ganhos com arbitragem).

Segundo Diebold e Li (2006), tradicionalmente os modelos não arbitragem se concentram em ajustar perfeitamente a curva de juros em um determinado momento para garantir que não exista nenhuma possibilidade de arbitragem - assumindo que se pode confiar nos preços de mercado utilizados. Por outro lado, os modelos de não arbitragem têm a deficiência de tomar a curva de juros inicial como uma entrada, em vez de ela ser explicada pelo modelo. Ainda, a precisão nos modelos de não arbitragem exige um número maior de parâmetros a serem estimados frente aos modelos de equilíbrio. Em síntese, Hull (2016, p. 774) diferenciou essas duas classes da seguinte forma: “Em um modelo de equilíbrio, a estrutura a termo das taxas de juros corrente é um produto. Em um modelo de não arbitragem, a estrutura a termo da taxa de juros é um insumo”.

No tocante à formalização, o termo de *drift* $\mu(r(t), t)$ normalmente é invariante no tempo em modelos de equilíbrio, mas é dependente do tempo nos de não arbitragem - pois, nesta classe, o formato da curva *spot* reage às mudanças futuras de trajetória na taxa instantânea r ⁶. Complementarmente, os modelos de equilíbrio podem ser categorizados como de não arbitragem caso incluam um parâmetro dependente do tempo no termo de *drift*, na equação que define taxa de curto prazo r .

Isto posto, os modelos de não arbitragem (de um único fator) mais conhecidos são:

- o de Ho e Lee (1986), o primeiro modelo de não arbitragem, cuja equação do processo de r (neutro ao risco) é

$$dr_t = \theta_t dt + \sigma dz, \quad (2.14)$$

onde θ_t define a direção média na qual r se move ao longo do tempo t , independentemente do nível em que r se encontra, tal que $\theta_t = f_t(t, 0)dt + \sigma^2 dz$, onde $f_t(t, 0)$ é a taxa *forward* instantânea de vencimento t ;

- o de Hull e White (1990), cuja equação do processo de r (neutro ao risco) é:

$$dr_t = [\theta_t - ar]dt + \sigma dz \text{ ou } dr_t = a \left[\frac{\theta_t}{a} - r \right] dt + \sigma dz. \quad (2.15)$$

⁶ Se a curva for ascendente entre τ_1 e τ_2 , r apresentará um termo de *drift* positivo entre essas duas datas. Da mesma forma, se a curva for descendente nesse intervalo, r apresentará um *drift* médio negativo.

Sendo assim, ele pode ser caracterizado como o modelo de [Ho e Lee \(1986\)](#) com reversão à média (em que a parametriza a velocidade de reversão à média) ou como o modelo de [Vasicek \(1977\)](#) com o nível de reversão dependente do tempo;

- o de [Black, Derman e Toy \(1990\)](#), cuja equação do processo de r (neutro ao risco) é:

$$d \ln(r_t) = [\theta_t - a(t) \cdot \ln(r)]dt + \sigma(t) dz, \quad (2.16)$$

com $a(t) = -\frac{\sigma'(t)}{\sigma(t)}$, onde $\sigma'(t)$ é a derivada de σ com relação à t . Na prática, a versão mais útil desse modelo é quando $\sigma(t)$ é constante (*i.e.*, $\sigma'(t) = 0$ e $a(t) = 0$), definida por $d \ln(r_t) = \theta_t dt + \sigma dz$, a versão lognormal de [Ho e Lee \(1986\)](#).

Os modelos estocásticos apresentados anteriormente foram desenvolvidos ao longo das décadas de 70 e de 80, considerando apenas um ou dois fatores de risco. Na década de 90, a pesquisa passou a buscar por modelos com ao menos três fatores e houve uma mudança de o foco, do ajuste da curva para a previsão e a identificação dos prêmios de risco. Nesta fase, destacaram-se trabalhos como [Duffie e Kan \(1996\)](#) e [Dai e Singleton \(2000\)](#). Por fim, com a maior flexibilidade dos modelos vieram os problemas de estimação, guiando o foco para questões econométricas e problemas de identificação, destacando a adoção de modelos dinâmicos discretos, explorados na seção 2.2.

2.1.2.2 Modelos de interpolação da curva de juros

Esta seção introduz as principais técnicas de interpolação, na literatura e na prática de mercado. Em seguida, ela explora a metodologia de componentes principais e a família de modelos exponenciais de interpolação denominada Nelson-Siegel, ambas amplamente utilizadas na literatura macro-financeira de curva de juros.

Como [Diebold, Rudebusch e Aruoba \(2006\)](#) esclareceram, os modelos na literatura de curva de juros, como um todo, resultam em curvas distintas quanto à forma e ao ajuste (aderência aos dados). O desenvolvimento de diversas abordagens se deve às diferenças nas motivações e nas demandas matemáticas de macroeconomistas, economistas (financeiros) e participantes do mercado, por exemplo, se querem prever a taxa de juros ou realizar uma simulação, ou se estão precificando títulos ou derivativos.

Os primeiros modelos desenvolvidos na classe de interpolação eram instantâneos (sem estrutura condicionada temporalmente), e seus parâmetros não eram passíveis de interpretação econômica/financeira. Dessa forma, não se enquadrariam como abordagens teóricas da dinâmica na curva de juros. Todavia, mais recentemente, avanços nessa classe têm conferido características dinâmicas aos parâmetros funcionais (através do arcabouço de séries temporais), além de fornecer interpretação aos mesmos ([DIEBOLD; RUDEBUSCH, 2013](#)).

Mais precisamente, contrapondo a classe estocástica, a classe de interpolação consiste em modelos estatísticos sem uma interpretação estrutural. Isto é, sintetizam o padrão gerador de dados e permitem a previsão da curva sem necessariamente representá-las em estruturas teóricas, que se ajustam a condições de equilíbrio e/ou de não arbitragem (LAURINI; HOTTA, 2010). Em particular, apesar do apelo explicativo dos modelos estocásticos, eles não foram desenvolvidos visando a previsão da taxa de juros - essencial para o gerenciamento de portfólios com títulos, a precificação de derivativos e o gerenciamento de risco. De acordo com Diebold e Li (2006), a literatura de não arbitragem tem pouco a dizer sobre dinâmica ou previsão, pois se preocupa principalmente com o ajuste da curva de juros em um determinado momento. Por sua vez, apesar de a literatura de equilíbrio partir da dinâmica impulsionada pela taxa instantânea (potencialmente ligada à previsão), a maioria dos trabalhos dessa tradição concentra-se apenas no ajuste dentro da amostra, ou, quando avaliam previsões fora da amostra, não apresentam um desempenho adequado.

Dessa forma, o ponto de partida da classe de interpolação está na constatação de que, em uma data t , o número de ativos com vencimento distintos é finito - sendo particularmente escassos nos mercados em desenvolvimento. Logo, para estabelecer graficamente uma curva de juros, *a priori*, tem-se apenas uma série de pontos discretos de rendimentos (ou taxas *spot*) em relação à maturidade. Por outro lado, é desejável que a curva de juros seja suave (sem saltos no espectro de maturidades) e que, mesmo não havendo um ativo (título) negociável para determinado vencimento, seja possível estabelecer implicitamente a taxa de juros para esse vencimento. Por isso, foram desenvolvidos diferentes métodos de interpolação para estimar uma curva contínua de juros, suave e aderente aos dados (pontos discretos).

Como esclarece Securato et al. (2005), o objetivo da interpolação é estabelecer uma função contínua $y_t(\tau)$, que defina os valores de taxas de juros vigentes em dado instante t para qualquer vencimento τ - conhecido como vértice da curva. A partir de Filipovic (2009) e de Choudhry (2019), podem-se elencar os seguintes métodos de modelagem (ou interpolação) da curva de juros, por ordem de complexidade.

- Interpolação linear - envolve unir cada par de vértices de juros disponível através de uma linha. Assim, dadas as taxas $y_t(\tau_1)$ e $y_t(\tau_2)$, a taxa $y_t(\tau_x)$ com vencimento em τ_x , tal que $\tau_1 < \tau_x < \tau_2$, é definida por:

$$y_t(\tau_x) = y_t(\tau_1) + \frac{\tau_x - \tau_1}{\tau_2 - \tau_1} \times (y_t(\tau_2) - y_t(\tau_1)). \quad (2.17)$$

- Aproximações polinomiais - consiste em estimar polinômios de ordem n , tais como

$$y_t(\tau_x) = \alpha + \sum_{i=1}^n \beta_i [y_t(\tau_x)]^i + \epsilon_t(\tau_x), \quad (2.18)$$

onde α e β_i são os coeficientes a serem estimados de modo a minimizar a soma do quadrado do resíduo, $\sum \epsilon_t(\tau_x)^2$. Quanto maior for o tamanho de n (escolhido pelo

analista) maior será a aderência aos dados e menor será a suavidade - levando a um problema de *over-fitting*. Por outro lado, se o tamanho de n é demasiadamente pequeno, pode haver um problema de *over-estimation*. Observa-se que essa metodologia é muito sensível aos pontos de vértices disponíveis, podendo causar oscilações bruscas na curva - com taxas *forward* negativas. Adicionalmente, uma classe relevante é a dos modelos polinomiais exponenciais, cuja caracterização geral é dada por:

$$y_t(\tau_x) = \sum_{i=0}^n \beta_i(\tau) \left[e^{-\alpha_i \cdot \tau_x} \right] + \epsilon_t(\tau_x), \quad (2.19)$$

onde $\beta_i(\tau)$ denota um termo polinomial de grau i (ou seja, $\beta_i(\tau) = \alpha + \sum_{j=1}^i \beta_j [y_t(\tau_x)]^j$) enquanto os parâmetros α_i são constantes. Essa classe é amplamente utilizada na prática de mercado, especialmente os modelos pertencentes à subclasse Nelson-Siegel, após o trabalho pioneiro de [Nelson e Siegel \(1987\)](#).

- *Splines* cúbicos - envolve particionar a curva em determinado número de vértices e conectar cada par de vértices nessa partição através de uma equação cúbica (polinomial com $n = 3$) exclusiva entre eles. Dessa forma, a curva obtida é representada por uma cadeia de equações cúbicas, em vez de um único polinômio. Portanto, para cada vértice $y_t(\tau_y)$ e $y_t(\tau_z)$ com $\tau_y < \tau_x < \tau_z$, tem-se

$$y_t(\tau_x) = \alpha_{y,z} + \beta_{y,z;1} [y_t(\tau_x)]^1 + \beta_{y,z;2} [y_t(\tau_x)]^2 + \beta_{y,z;3} [y_t(\tau_x)]^3 + u_t \tau_x. \quad (2.20)$$

Dessa forma, há quatro parâmetros para serem estimados, o que demanda a utilização de pelo menos quatro pontos (vértices) τ_x no intervalo entre τ_y e τ_z . Ainda, para garantir suavidade à curva, a técnica de *spline* exige que não só os polinômios estimados tenham valor idêntico nos vértices limitantes (denominados “nós”) como também possuam derivada de primeira ordem idênticas e que as derivadas de segunda ordem existam ⁷.

Como discutido em [Rebonato \(2016\)](#), os métodos de interpolação também são importantes por serem “*building blocks*” em modelos estruturais - que explicam e/ou projetam as curvas de juros recorrendo aos modelos teóricos de equilíbrio ou de não arbitragem para a modelagem teórica, mas assumindo que a função geradora dos dados não segue necessariamente uma medida de probabilidade neutra ao risco. Para tanto, duas técnicas se destacam: i) a Análise de Componentes Principais (PCA); e ii) os modelos da classe Nelson-Siegel (um modelo polinomial exponencial). A PCA é uma técnica de estatística multivariada utilizada para reduzir as dimensões de uma matriz de variáveis, sendo dominante nos modelos dinâmicos com não arbitragem - como os apresentados na seção 2.2. Alternativamente, os modelos dinâmicos com origem na temática de interpolação

⁷ A demonstração formal do método de estimação para aproximações *spline* (em particular, a *B-spline* ou *basis spline*) pode ser encontrada em [Filipovic \(2009, p. 38\)](#).

adotam os parâmetros estimados na classe Nelson-Siegel como forma de sintetizar o conteúdo informacional da curva de juros. A seguir, os modelos da classe Nelson-Siegel são introduzidos. Na seção 2.3, a utilização das componentes principais ou dos parâmetros latentes no modelo Nelson-Siegel como fatores de risco em modelos dinâmicos é apresentada.

Após Nelson e Siegel (1987) apresentarem seu modelo de aproximação polinomial exponencial, uma série de modificações deste foram desenvolvidas por outros autores, motivo pelo qual esses modelos são usualmente classificados como “família” de curvas do tipo Nelson-Siegel. Essas curvas fornecem um ajuste aproximado satisfatório da estrutura completa do termo, com alguma perda de precisão no início e no final da curva. Em particular, desde o desenvolvimento de Diebold e Li (2006), essa família, amplamente utilizada por praticantes de mercado e por bancos centrais, passou a ser uma técnica central na projeção de curvas de juros.

O modelo de Nelson e Siegel assume que a curva de juros pode ser equacionada pela seguinte função:

$$y_t(\tau) = \beta_1 + \beta_2 \left(\frac{1 - e^{-\lambda \cdot \tau}}{\lambda \cdot \tau} \right) + \beta_3 \left(\frac{1 - e^{-\lambda \cdot \tau}}{\lambda \cdot \tau} - e^{\lambda \cdot \tau} \right) + \epsilon_t(\tau), \quad (2.21)$$

um modelo não-linear com quatro parâmetros (β_1 , β_2 , β_3 e λ) estimados de forma a minimizar a soma do quadrado do resíduo, $\sum \epsilon_{t,x}^2$. O parâmetro λ governa a taxa de decaimento exponencial na curva. Ainda, os parâmetros β_1 , β_2 e β_3 , denominados fatores latentes, possuem interpretação econômica análoga às três primeiras componentes principais da curva (como proposto por Litterman e Scheinkman (1991)), debatidos na seção 2.3.

Complementarmente, outro modelo popular dessa família é a expansão em quatro fatores de Svensson e Lachman (1994) - adotado pela ANBIMA para estimar a curva de juros títulos do governo (zero cupom, livre da inflação implícita). Nesse modelo, a curva de juros é definida por:

$$y_t(\tau) = \beta_1 + \beta_2 \left(\frac{1 - e^{-\lambda_1 \cdot \tau}}{\lambda_1 \cdot \tau} \right) + \beta_3 \left(\frac{1 - e^{-\lambda_1 \cdot \tau}}{\lambda_1 \cdot \tau} - e^{\lambda_1 \cdot \tau} \right) + \beta_4 \left(\frac{1 - e^{-\lambda_2 \cdot \tau}}{\lambda_2 \cdot \tau} - e^{\lambda_2 \cdot \tau} \right) + \epsilon_t(\tau), \quad (2.22)$$

que adiciona mais dois parâmetros em relação ao modelo de Nelson-Siegel, β_4 e λ_2 .

2.2 Modelos dinâmicos de curvas de juros

Os denominados Modelos Dinâmicos de Curvas de Juros (DTSM, *Dynamic Term Structure Models*) visam explicar (e, por vezes, prever) o que guia as alterações na curva de juros ao longo do tempo. Como exposto em Piazzesi (2010), a princípio, os movimentos nos retornos dos títulos públicos podem ser capturados por um simples VAR contendo tais

retornos e, possivelmente, outras variáveis como as macroeconômicas. Todavia, em cada período t de tempo existe uma gama de títulos com diversos vencimentos, para os quais os investidores aversos ao risco irão demandar uma compensação pela liquidez conforme o horizonte dos vencimentos. Nesse contexto, haverá oportunidades de arbitragem nesse mercado a não ser que os rendimentos de longo prazo sejam formados pela composição das expectativas de taxas de curto prazo ajustadas ao risco de liquidez. Dessa forma, a condição de não arbitragem impõe uma *cross-section* entre os rendimentos dos títulos no período t , uma restrição ao VAR que projeta as séries de rendimentos para cada vencimento. Adicionalmente, a condição de não arbitragem permite segregar as expectativas de taxas de curto prazo futuras e os prêmios de risco.

Portanto, de modo generalizado, os DTSM são constituídos não só por um funcional de transição da curva de juros entre os períodos (discretos), como também por uma restrição transversal em cada período que precificar o prêmio de risco, garantindo, assim, a existência de não arbitragem entre os rendimentos com vencimentos distintos. Nessa literatura, destacam-se os modelos categorizados como “afins⁸ com multi-fatores de risco”, considerados como o arcabouço teórico central em estudos macro-financeiros de curva de juros (DAI; SINGLETON, 2000; ANG; PIAZZESI, 2003; HAMILTON; WU, 2012b; DUFFEE, 2013b; BAUER, 2018). Não obstante, cabe antecipar que esses modelos apresentam baixo poder preditivo, especialmente fora da amostra (DUFFEE, 2002). Por isso, eles são mais utilizados para fins explicativos do que preditivos.

A parametrização “afim” é extremamente conveniente, tanto do ponto de vista analítico (interpretativo) quanto do computacional. Duffee (2002) e Duffee (2013b) argumentam que, aparentemente, apesar de uma variedade de modelos não afins terem sido desenvolvidos, a maior tratabilidade somada à relativa riqueza capturada pela classe afim têm levado profissionais e pesquisadores de finanças a darem maior foco nesta. Cabe pontuar que os trabalhos pioneiros de Vasicek (1977) e Cox, Ingersoll e Ross (1981) (na subseção 2.1.2.1) são categorizados como “afim”. Nesses, o vetor de estados é constituído por um único elemento, a variável r , e os rendimentos de títulos com maturidades distintas são perfeitamente correlacionados. A literatura subsequente buscou ampliar o número de variáveis de estado, caracterizadas pelo vetor X , e tratar o processo gerador de dados dessas $X_t \sim \mathbb{P}$, não necessariamente neutro ao risco assim como os modelos de não arbitragem geralmente pressupõem. Em particular, destaca-se a estrutura de multi-fatores afim desenvolvida por Duffie e Kan (1996). Esta classe abarca tanto modelos homocedásticos Gaussianos quanto heterocedásticos. Não obstante, Duffee (2002) demonstrou que, entre esses, apenas os Gaussianos são suficientemente flexíveis para gerar previsões plausíveis para os rendimentos futuros. Em linha, Duffee (2013b) constatou que o arcabouço central dessa literatura tem sido os (modelos afins com multi-fatores de risco) Gaussianos.

⁸ Isto é, constante mais um coeficiente linear, tanto no funcional de transição quanto na *cross-section* entre os rendimentos e os fatores de risco.

Isto posto, a caracterização geral dos DTSM Gaussiano é dada por:

- i) A taxa de curto prazo r_t é uma função afim dos fatores de risco X_t . Formalmente,

$$r_t = \rho_0 + \rho_1' X_t, \quad (2.23)$$

onde ρ_0 é um coeficiente linear constante e ρ_1' é um vetor de coeficientes lineares constantes (transposto). Em análises empíricas, a taxa r_t é usualmente mensurada pela taxa de juros de um período, geralmente um ano.

- ii) O vetor de fatores de risco X_t $1 \times N$ segue um VAR Gaussiano de primeira ordem sob o processo gerador de dados \mathbb{P} ,

$$X_t = K_0 + K_1 X_{t-1} + \Sigma \epsilon_t \quad \epsilon_t \stackrel{iid}{\sim} N(0, I_N), \quad (2.24)$$

onde K_0 e K_1 são vetores constantes e, sem perda de generalidade, Σ é uma matriz triangular inferior com $E(\epsilon_t, \epsilon_{t'}) = 0$ se $t \neq t'$.

Sob as caracterizações i) e ii), todo o excesso de retorno deve ser explicado pelo mecanismo de compensação do risco capturado em X_t , descrito em iii). De forma resumida, este vetor é composto por dois perfis de variáveis, os fatores latentes - extraídos da curva de juros corrente - e os fatores adicionais - geralmente macroeconômicos. Uma revisão das variáveis utilizadas na literatura como fatores de risco em X_t é realizada na seção 2.3.

- iii) Sob a hipótese de não arbitragem, existe uma medida neutra ao risco, denotada \mathbb{Q} , que precifica todos os ativos financeiros via 2.6. Ainda, assume-se que o fator estocástico de desconto ξ_{t+1} (uma medida de Radon-Nikodin) que transforma o processo neutro ao risco \mathbb{Q} no processo gerador de dados \mathbb{P} é log-linear. Portanto, pela caracterização Gaussiana,

$$\xi_{t+1} = e^{-r_t - (1/2)\lambda_t' \lambda_t - \lambda_t' \epsilon_{t+1}}, \quad (2.25)$$

tal que

$$p_t(\tau) = E_{\mathbb{P}} [\xi_{t+1} p_{t+1}(\tau - 1)], \quad (2.26)$$

onde λ_t é um vetor contendo os preços do risco do mercado. Mais especificamente, o preço do risco λ_t é a compensação exigida pelos investidores para um choque unitário ϵ_{t+1} , sendo uma função afim dos fatores de risco

$$\lambda_t = \Sigma^{-1} (\lambda_0 + \lambda_1' X_t), \quad (2.27)$$

onde λ_0 é um coeficiente linear constante e λ_1' é um vetor de coeficientes lineares constantes (transposto). Logo, as variações no preço do risco ao longo do tempo neste modelo se devem às mudanças em X_t . Em particular, o investidor será neutro ao risco se $\lambda_t = 0$.

Essa especificação do preço de risco λ_t , denominada “essencialmente afim”, é estabelecida em [Duffee \(2002\)](#).

- iv) Pelas condições anteriores, os títulos são precificados através do processo dinâmico neutro ao risco sobre os fatores de risco estabelecido por

$$X_t = K_0^{\mathbb{Q}} + K_1^{\mathbb{Q}} X_{t-1} + \Sigma \epsilon_t^{\mathbb{Q}} \quad \epsilon_t^{\mathbb{Q}} \stackrel{iid}{\sim} N(0, I_{\mathcal{N}}), \quad (2.28)$$

onde os parâmetros martingais equivalentes são dados por $K_0^{\mathbb{Q}} = K_0 - \lambda_0$ e $K_1^{\mathbb{Q}} = K_1 - \lambda_1$.

- v) Conseqüentemente, os preços dos títulos $p_t(\tau)$ podem ser escritos como

$$p_t(\tau) = e^{A + \mathcal{B}X_t}, \quad (2.29)$$

onde as cargas $\mathcal{A}(\tau, K_0^{\mathbb{Q}}, K_1^{\mathbb{Q}}, \rho_0, \rho_1, \Sigma)$ e $\mathcal{B}(\tau, K_1^{\mathbb{Q}}, \rho_1)$ seguem o processo recursivo⁹

$$\begin{aligned} \mathcal{A}(\tau + 1) &= \mathcal{A}(\tau) + (K_0^{\mathbb{Q}})' \mathcal{B}(\tau) + \frac{1}{2} \mathcal{B}'(\tau) \Sigma \Sigma' \mathcal{B}(\tau) - \rho_0, e \\ \mathcal{B}(\tau + 1) &= (K_1^{\mathbb{Q}})' \mathcal{B}(\tau) - \rho_1, \end{aligned} \quad (2.30)$$

com valores iniciais de $\mathcal{A}(\tau = 0) = 0$ e $\mathcal{B}(\tau = 0) = 0$.

Em linha, o vetor de retornos (logarítmicos) é dado por

$$Y_t(\tau) = \mathcal{A}(\tau) + \mathcal{B}(\tau) X_t. \quad (2.31)$$

Por sua vez, os rendimentos neutros ao risco são definidos por

$$\tilde{Y}_t(\tau) = \tilde{A}(\tau) + \tilde{B}(\tau) X_t, \quad (2.32)$$

onde $\tilde{A}(\tau) = -\frac{1}{\tau} \mathcal{A}(\tau, K_0^{\mathbb{Q}}, K_1^{\mathbb{Q}}, \rho_0, \rho_1, \Sigma)$ e $\tilde{B}(\tau) = -\frac{1}{\tau} \mathcal{B}(\tau, K_1^{\mathbb{Q}}, \rho_1)$.

Desta forma, o termo de prêmio de risco $TP_t(\tau)$ é dado pela diferença entre o rendimento $y_t(\tau)$ e o respectivo rendimento neutro ao risco $\tilde{y}_t(\tau)$ (estimado em [2.32](#)), ou seja,

$$TP_t(\tau) = Y_t(\tau) - \tilde{Y}_t(\tau). \quad (2.33)$$

Em especial, como a matriz de covariância é constante no modelo Gaussiano, a única fonte de variação do prêmio de risco são os fatores de risco.

- vi) Por fim, para identificação econométrica dos parâmetros é necessário impor algumas restrições normalizadoras. Tal característica é comum na identificação de VARs estruturais como nos processos Markovianos [2.24](#) e [2.28](#).

⁹ Mais precisamente, como em [Joslin, Singleton e Zhu \(2011\)](#), uma equação diferencial de Riccati.

Segundo Bauer (2018), o DTSM é dito canônico se ele satisfizer a identificação em i) até v), sendo o mais flexível possível, sujeito apenas as restrições normalizadoras em vi).

De modo geral, os DTSMs podem ser estimados via filtro de Kalman, ao maximizar a verossimilhança (Gaussiana) do sistema de espaço de estados formado pela equação de medida (2.23) e pela equação de transição (2.24). Todavia, deve-se observar que esse procedimento permite que o vetor de fatores X_t seja rotacionado durante o processo de estimação, permitindo certa multiplicidade nos pontos que maximizam a verossimilhança. Consequentemente, dois pesquisadores podem chegar a resultados distintos apesar de utilizar o mesmo modelo, na mesma amostra de dados e com o mesmo método de estimação. Neste aspecto, recentemente, tem se destacado o algoritmo de estimação para DTSM Gaussianos afins desenvolvidos por Joslin, Singleton e Zhu (2011) assim como o desenvolvido por Hamilton e Wu (2012b), por garantirem a unicidade da solução. Em particular, por ser extremamente eficiente computacionalmente, esta tese recorre a algoritmos derivados de Joslin, Singleton e Zhu (2011), especialmente a extensão realizada por Joslin, Le e Singleton (2013) para incorporar fatores exógenos de risco como os macroeconômicos.

Joslin, Singleton e Zhu (2011) demonstraram que as previsões condicionadas dos fatores de risco são invariantes à imposição de restrições de não arbitragem e, consequentemente, a adoção de Mínimos Quadrados Ordinários (MQO) é suficiente para obter a máxima verossimilhança do processo físico na equação (2.24). Isso permite a adoção de um procedimento de estimação em dois estágios, em que, primeiramente, estima-se (2.24) por MQO. Na segunda etapa, utilizando K_0 e K_1 como *input* e Σ como valor inicial na otimização, aplica-se o filtro de Kalman para maximizar a verossimilhança deduzida conjuntamente de (2.24), (2.28) e (2.23). A segunda etapa fornece estimativas de λ^Q (os autovalores de K_1^Q), $K_{0,\infty}^Q$ (o primeiro e único elemento não nulo do vetor K_0^Q , que determina a taxa de curto prazo neutra ao risco $r_\infty^Q = K_{0,\infty}^Q / (1 - \lambda_1^Q)$) e Σ . Os demais parâmetros são calculados a partir destes, conforme a caracterização geral dos DTSMs.

Complementarmente ao DTSM, um modelo particularmente relevante para projetar curvas é DNSM (*Dynamic Nelson-Siegel Model*), uma extensão dinâmica do modelo Nelson-Siegel estabelecida por Diebold e Li (2006). De forma sucinta, o DNSM e suas variantes apresentam bom poder preditivo da curva como um todo (GASHA et al., 2010), fornecendo funcionais de curva de juros mais aderentes em suas projeções. Por outro lado, ele permite a existência de oportunidades de arbitragem, uma inconsistência teórica que acaba por impossibilitar a decomposição dos rendimentos na curva em retorno esperado e prêmios de risco. Em particular, os fatores latentes adotados no DTSM (as componentes principais da curva) são melhores em capturar o conteúdo informacional da curva do que os fatores latentes utilizados nos DNSMs (parâmetros L , S e C do funcional de Nelson-Siegel na equação (2.21)). Por isso, o DTSM tem sido utilizado para análises explicativas da dinâmica da curva de juros enquanto o DNSM tem sido utilizado para previsões da curva -

e, conseqüentemente, para a precificação e o *hedging* de ativos a partir desta.

Isto posto, o DNSM é apresentado a seguir, de forma sucinta. Ele consiste em indexar o funcional da equação (2.21) no tempo, tal como

$$y(\tau) = L_t + S_t \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau} \right) + C_t \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau} \right) \quad (2.34)$$

onde L_t , S_t e C_t são parâmetros variantes no tempo - usualmente denominados por nível (*level*), inclinação (*slope*) e curvatura (*curvature*) - correspondentes aos parâmetros lineares β_1 , β_2 e β_3 na equação (2.21). Destarte, Diebold e Li (2006) preveem a curva futura $y_{t+1}(\cdot)$ a partir da curva corrente $y_t(\cdot)$ através de um procedimento em três etapas:

1. O modelo Nelson-Siegel (com λ fixo, tornando-o linear nos parâmetros) é ajustado via MQO para cada data t , fornecendo os parâmetros L_t , S_t e C_t para cada período t .
2. Em um primeiro estágio, a dinâmica do sistema é modelada por um VAR sobre o vetor de parâmetros $X_t = [L_t \ S_t \ C_t]'$.
3. No segundo estágio, as previsões $X_{t+1} = [\hat{L}_{t+1} \ \hat{S}_{t+1} \ \hat{C}_{t+1}]'$ fornecidas pelo VAR estimado são aplicadas na equação (2.34), fornecendo a curva de juros prevista $\hat{y}_{t+1}(\cdot)$.

Uma alternativa ao procedimento de estimação em Diebold e Li (2006) é estimar simultaneamente os parâmetros λ , L_t , S_t e C_t via filtro de Kalman, ao escrever a equação (2.34) na forma de espaço de estados. Dessa forma, sejam $Y_t = [y_t(\tau_1) \ y_t(\tau_2) \ \cdots \ y_t(\tau_k)]'$ o vetor $k \times 1$ de taxas *spot* em t e $X_t = [L_t \ S_t \ C_t]'$ o vetor de fatores, a representação da equação (2.34) na forma de espaço de estados é dada por:

$$Y_t = A_0 + A_1 X_t + \epsilon_t, \text{ com } \epsilon_t \sim NID(0, \Sigma_{\epsilon,t}) \quad (2.35)$$

$$X_t = B_0 + B_1 X_{t-1} + \eta_t, \text{ com } \eta_t \sim NID(0, \Sigma_{\eta,t}) \quad (2.36)$$

onde A_0 ($k \times 1$) e B_0 (3×1) são vetores de constantes, B_1 é a matriz 3×3 de transição, $\Sigma_{\epsilon,t}$ e $\Sigma_{\eta,t}$ são as matrizes de covariância dos resíduos (ϵ_t e η_t , respectivamente) e A_1 ($k \times 3$) é a matriz de decaimento, onde cada linha corresponde a $A_1[i,] = \left[1 \ \frac{1 - e^{-\lambda\tau_i}}{\lambda\tau_i} \ \frac{1 - e^{-\lambda\tau_i}}{\lambda\tau_i} - e^{-\lambda\tau_i} \right]'$.

Essa representação é similar ao DTSM, inclusive os macro-financeiros desenvolvidos a partir de Ang e Piazzesi (2003). A equação (2.35) é uma *cross-section* de precificação similar à (2.31), mas não-linear, dado que os fatores latentes L_t , S_t e C_t são relacionados a cada rendimento pelos coeficientes

$$A_1 = \left[1 \ \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau} \right) \ \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau} \right) \right],$$

respectivamente. Por sua vez, a equação (2.36) é um VAR sobre os fatores de risco X_t , que na classe DNS compreende os fatores L_t , S_t e C_t do funcional de Nelson-Siegel (como em 2.34), e não as componentes principais (como em um DTSM). Em particular, X_t pode conter outros fatores além dos latentes, como no modelo macro-financeiro de Diebold, Rudebusch e Aruoba (2006) desenvolvido a partir de Diebold e Li (2006)

Adicionalmente, uma extensão do DNSM introduzida por Diebold e Rudebusch (2013) é o *Dynamic Nelson-Siegel-Svensson Model* (DNSSM). Neste, a equação (2.22) é representada dinamicamente de forma análoga à equação (2.34) e estimada na forma de espaço de estados como nas equações (2.35) e (2.36), mas incorporando os fatores β_4 e λ_2 .

Por fim, cabe pontuar que estudos recentes como Christensen, Diebold e Rudebusch (2009) e Christensen, Diebold e Rudebusch (2011) têm desenvolvido modelos híbridos, incorporando a restrição de não arbitragem ao DNSM, usualmente denominados AFNS (*Arbitrage-free Nelson-Siegel*). Nestes, a estrutura de não arbitragem dada por Duffie e Kan (1996) é adotada¹⁰, e, conseqüentemente, deduz-se a formula fechada:

$$y(\tau) = L_t + S_t \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau} \right) + C_t \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau} \right) - \frac{\Gamma_t(\tau)}{\tau}, \quad (2.37)$$

onde, fixando os termos de *drift* $\bar{L}_t = \bar{S}_t = \bar{C}_t = 0$, tem-se

$$\Gamma_t(\tau) = \frac{1}{2\tau} \sum_{i=1}^3 \int_0^\tau [\Sigma' B(x, \tau) B(x, \tau)' \Sigma]_{ii} dx, \quad (2.38)$$

com $B^1(x, \tau) = -(\tau - x)$, $B^2(x, \tau) = -\frac{1 - e^{-\lambda(\tau - x)}}{\lambda}$ e $B^3(x, \tau) = -\frac{1 - e^{-\lambda(\tau - x)}}{\lambda} + (\tau - x)e^{-\lambda(\tau - x)}$.

Nesse modelo, o termo independente no tempo $-\frac{\Gamma_t(\tau)}{\tau}$ garante que a curva estimada seja livre de oportunidades de arbitragem. A derivação formal do resultado em (2.37) encontra-se tanto em Christensen, Diebold e Rudebusch (2011) quanto em Caldeira et al. (2016). Em particular, assim como nos testes de desempenho preditivo feitos em Christensen, Diebold e Rudebusch (2011) para a curva americana, Caldeira et al. (2016) demonstraram empiricamente que a restrição de não arbitragem ao modelo dinâmico de Nelson-Siegel ajuda a obter previsões mais precisas da curva de juros brasileira para horizontes maiores.

2.2.1 O problema de *spanning*

Em síntese, a possibilidade teórica de *spanning* (ou invertibilidade) nos DTSMs Gaussianos afins sugere que o conteúdo informacional nos fatores de risco exógenos - como variáveis macroeconômicas - é completamente capturado pelos fatores latentes - extraídos da curva de juros contemporânea (DUFFEE, 2013b). Desde o trabalho seminal

¹⁰ Considerando-se que a taxa de juros instantânea é uma função linear das variáveis de estado, *i.e.*, $r_t = \rho_0 + \rho_1' X_t$ tal que X_t é um vetor de estados.

de [Ang e Piazzesi \(2003\)](#), a caracterização afim Gaussiana tem dominado a literatura macro-financeira de curva de juros, sendo similar ao DTSM caracterizado nas equações (2.23) a (2.32). Apesar de ser discutido dentro da literatura macro-financeira, vale enfatizar que a possibilidade de *spanning* se estende para qualquer fator de risco exógeno em X_t .

Para demonstrá-la, considere o vetor de retornos Y_t de comprimento J e o vetor $X_t = [PC_t^{\mathcal{L}}; M_t^{\mathcal{M}}]'$ com $\mathcal{N} = \mathcal{L} + \mathcal{M}$ fatores de risco no período t , dos quais \mathcal{L} são fatores latentes (derivados da curva de juros) e \mathcal{M} são fatores exógenos (macroeconômicos). Ainda, seja W uma matriz ($\mathcal{L} \times J$ de posto completo) de combinações lineares (portfólios) dos retornos em Y_t . Tomando $W^{\mathcal{L}}$ como a matriz de cargas das \mathcal{L} primeiras componentes principais, tem-se $PC_t^{\mathcal{L}} = W^{\mathcal{L}}Y_t$. Consequentemente, ao multiplicar a equação de retornos dos títulos (2.31) por $W^{\mathcal{L}}$, tem-se

$$PC_t^{\mathcal{L}} = W^{\mathcal{L}}Y_t = W^{\mathcal{L}}A + W^{\mathcal{L}}BX_t, \quad (2.39)$$

De acordo com [Joslin, Singleton e Zhu \(2011\)](#), exceto em casos especiais, (2.39) pode ser invertida para

$$M_t^{\mathcal{M}} = \gamma_0 + \gamma_1 PC_t^{\mathcal{L}}, \quad (2.40)$$

uma função determinística de PC_t , ou qualquer combinação linear dos retornos em Y_t .

Assim como comentado em [Joslin, Pribsch e Singleton \(2014\)](#), a hipótese de invertibilidade, ou de “*spanning*”, tem forte implicação sobre todos os modelos macro-financeiros afins de estrutura a termo (tanto na forma reduzida quanto em equilíbrio). Segundo esta, os fatores macroeconômicos que determinam os preços dos títulos são completamente abarcados pela curva corrente de juros. Consequentemente, esses fatores não trazem conteúdo informativo adicional quanto aos prêmios de risco e aos valores futuros destas mesmas variáveis macroeconômicas.

Mais precisamente, a hipótese de *spanning* não significa que as variáveis macroeconômicas sejam irrelevantes para a taxa de juros e o prêmio de risco. Pelo contrário, afirmam que as primeiras são *drivers* das segundas. Caso seja verdadeira, o que a hipótese de *spanning* de fato implica é que a curva de juros reflete toda informação nas variáveis macroeconômicas, tornando desnecessário incluí-las ao estimar os juros futuros e os prêmios de risco ([BAUER; HAMILTON, 2018](#)). Isso tem duas grandes implicações práticas ao estimar expectativas de política monetária e prêmios de risco. Primeiramente, a estimação dessas duas não requer qualquer dado ou modelo envolvendo séries macroeconômicas, preços e quantidades de outros ativos financeiros, volatilidades ou pesquisas de expectativas, apenas a informação contida na taxa de juros. Segundo, tudo o que é necessário para resumir a informação na taxa de juros está no formato da curva de juros, capturado pelas componentes principais.

Em particular, cabe pontuar que nem todo modelo de curva de juros permite essa linearidade teórica entre fatores macroeconômicos e fatores latentes. Por exemplo,

os DNSMs são não lineares e, conseqüentemente, não invertíveis. Igualmente, foram desenvolvidos DTSMs robustos ao *spanning*, como o de [Joslin, Pribsch e Singleton \(2014\)](#). Neste, apenas os fatores latentes $PC_t^{\mathcal{L}}$ precificam os títulos em (2.31). Assim, a influência dos fatores macroeconômicos $M_t^{\mathcal{M}}$ fica restrita a efeitos indiretos, via propagação sobre os fatores latentes, através do VAR em (2.24).

Contudo, apesar da possibilidade empírica de *spanning* nos DTSMs afins, existem três regressões padrões na literatura cujos resultados têm exposto o contrário, há conteúdo informacional nas variáveis macroeconômicas que não são capturados pelos \mathcal{L} fatores latentes - $PC_t^{\mathcal{L}}$. São estas:

$$M_t^i = \beta_{1;0} + \beta_{1;1:3}PC_t^3 + \epsilon_{1,t} \quad (2.41)$$

$$rx_{t,t+12}^{\tau} = \beta_{2;0} + \beta_{2;1:3}PC_t^3 + \beta_{2;4:(\mathcal{M}+4)}M_t^{\mathcal{M}} + \epsilon_{2,t+12} \quad (2.42)$$

$$M_{t+1}^i = \beta_{3;0} + \beta_{3;1:3}PC_t^3 + \beta_{4;4:(\mathcal{M}+4)}M_t^{\mathcal{M}}\epsilon_{3,t} \quad (2.43)$$

onde:

M_t^i é a i -ésima variável macroeconômica dentre as \mathcal{M} avaliadas, no período t ;

$M_t^{\mathcal{M}}$ são as \mathcal{M} variáveis macroeconômicas avaliadas, no período t ;

PC_t^3 são as três primeiras componentes principais sobre os retornos em Y_t ;

$rx_{t,t+12}^{\tau}$ é o excesso de retorno esperado para o horizonte de um ano para um título com vencimento em τ , *i.e.*, $rx_{t,t+12}(\tau) = (\tau \times y_t(\tau) - (\tau - 12) \times y_{t+12}(\tau - 12)) - 12 \times r_t$, o retorno (logarítmico) em segurar o título de vencimento τ por um ano (12 meses), vendendo-o com vencimento em $\tau - 12$;

$\beta_{j;i}$ é o parâmetro linear correspondente à variável explicativa i na regressão j , para $j = 1, 2, 3$; e

$\epsilon_{j,t}$ e $\epsilon_{j,t+12}$ é o resíduo em cada regressão j , para $j = 1, 2, 3$.

Nestas, faz-se importante sinalizar que a medida de excesso de retorno $rx_{t,t+1}(\tau)$ (logarítmico) apresenta ligeiras variações na literatura, conforme a metodologia do trabalho. A notação anterior é utilizada em modelos com capitalização continuamente composta, em que há efetivamente a estimação de uma taxa de curto prazo r_t , tais como nos DTSMs. Por outro lado, uma série de estudos avaliam o impacto de fatores sobre a curva sem estimar o processo estocástico ou o funcional que caracteriza a curva. Para tanto, estes recorrem a medidas como o n -ésimo *spread* na curva ou o excesso de retorno, definidos respectivamente por

$$sp_t(\tau) = y_t(\tau) - y_t(1) \quad (2.44)$$

$$rx_{t,t+h}(\tau) = \tau \times y_{t+1}(\tau) - (\tau - h) \times y_t(\tau - h) - y_t(1) \quad (2.45)$$

Retomando as regressões (2.41), (2.42) e (2.41), Joslin, Priebisch e Singleton (2014), Duffee (2013a) e Duffee (2013b), entre outros, estimaram baixo R^2 na primeira, indicando que a correlação entre as variáveis macroeconômicas e a informação contida na curva de juros é baixa. Joslin, Priebisch e Singleton (2014), Cooper e Priestley (2008), Ludvigson e Ng (2010) e Greenwood e Vayanos (2014), entre outros, estimaram valores significativamente diferentes de zero para os betas $\beta_{2;4;m}$ na segunda, indicando que riscos macroeconômicos têm poder preditivo sobre o excesso de retorno dos títulos, no horizonte de um ano. Por fim, Duffee (2013a) e Duffee (2013b) encontraram fortes evidências contra a hipótese de que $\beta_{3;4;m}$ sejam iguais a zero na terceira, sugerindo que as variáveis macroeconômicas não possuem poder preditivo para as variáveis macro futuras após serem condicionadas pela curva corrente de juros.

A aparente inconsistência entre as evidências nessas regressões (contrárias à hipótese de *spanning*) e as previsões dos modelos padrões de macro-financeiras constituíram o denominado *spanning puzzle*. Isto posto, além dos resultados empíricos supracitados, Bauer e Rudebusch (2017) refutaram as previsões da hipótese de *spanning* através de testes empíricos e de simulações. Não obstante, pontua-se que não foram encontrados estudos no Brasil acerca desta problemática. Logo, não se deve ignorar a possibilidade do conteúdo informacional de fatores de risco da curva brasileira validados em testes mais simples serem irrelevantes quando controlado por outros fatores.

2.3 Fatores de risco associados às curvas de juros

Nos modelos DTSM, a dinâmica dos rendimentos neutros ao risco y_t^Q e dos prêmios de risco TP_t é ditada exclusivamente pelas alterações nos fatores de risco em X_t . Contudo, o foco tem sido o aperfeiçoamento da modelagem em si. Mesmo na literatura macro-financeira, boa parte dos estudos se limitam a três (ou dois) fatores latentes e dois macroeconômicos - geralmente, inflação e atividade econômica. Isso perpassa pela meta de parcimônia, ainda mais impactante em modelos de previsão com um grande número de parâmetros como os DTSMs, e a possibilidade de o conteúdo informacional de outras variáveis já ser contemplado nos fatores latentes, conforme desenvolvido na subseção 2.2.1.

Não obstante, estudos recentes vêm apontando outras variáveis como fontes de poder explicativo da dinâmica da curva, seja através de modelos dinâmicos como DTSM e DNSM ou via regressões contra excessos de retornos $rx_{t,t+1}$. Em vista disso, esta seção começa pela apresentação dos principais fatores latentes adotados na literatura - ponto de partido dos modelos multifatores e variáveis de controle nas regressões. Em seguida, a subseção 2.3.1 revisa a literatura macro-financeira e os fatores macroeconômicos abarcados nesta desde Ang e Piazzesi (2003), de forma adicional aos latentes. Na sequência, as subseções 2.3.2 e 2.3.3 revisam resultados recentes acerca de fatores adicionais associados

às curvas de juros. Mais especificamente, fatores relacionados à segmentação na curva e às influências internacionais no mercado de crédito, respectivamente.

No tocante aos fatores latentes, um fato estabelecido há tempo na literatura é que a curva de juros corrente contém informações sobre a curva de juros futura e, por isso, a previsão da taxa de juros pode ser feita utilizando o arcabouço de séries temporais (DUFFEE, 2002). Em particular, desde que Litterman e Scheinkman (1991) demonstraram que a maior parte do conteúdo informacional nos diversos vértices da curva corrente pode ser reduzida a poucos fatores (via PCA), a literatura tem adotado a projeção desses (poucos) fatores como método para modelar a dinâmica da curva como um todo, interpretando-os como fatores de risco latentes em X_t - derivados do conteúdo informacional na curva corrente. Desta forma, os modelos dinâmicos (seção 2.2) têm reduzido o número de variáveis nos VARs expressos em (2.24) e (2.28).

Mais especificamente, os modelos da classe DTSM têm recorrido às três primeiras componentes principais sobre a matriz de covariância dos rendimentos Y_t na curva, enquanto os da classe DNSM têm adotado os parâmetros β_1 , β_2 e β_3 do funcional de Nelson-Siegel. Em particular, Litterman e Scheinkman (1991) definiram as três primeiras componentes principais como “nível” L_t , “inclinação” S_t e “curvatura” C_t , pois, alterações em L_t impactam significativamente todos os vértices da curva de juros de forma igualitária, modificações em S_t movimentam os vértices de curto prazo e os vértices de longo prazo em direções opostas, e mudanças C_t movem os vértices de curto e de longo prazo (a ponta curta e a ponta longa) na mesma direção, afastando-os dos vencimentos intermediários. Por sua vez, a interpretação econômica dos parâmetros β_1 , β_2 e β_3 nos modelos da classe Nelson-Siegel é análoga. Como a carga em β_1 é um, uma constante que não decai com o vencimento ($\tau \rightarrow 0$), o parâmetro β_1 é visto como um fator de longo prazo. Como $(1 - e^{-\lambda \cdot \tau})/\lambda \cdot \tau$ começa em um, mas decai monotônica e rapidamente para zero, β_2 é interpretado como um fator de curto prazo. Por fim, como $((1 - e^{-\lambda \cdot \tau})/\lambda \cdot \tau) - e^{\lambda \cdot \tau}$ começa em zero, gradativamente cresce e posteriormente decai até zero, β_3 é o fator associado ao médio prazo. Seguindo a literatura baseada em Litterman e Scheinkman (1991), os fatores de longo, curto e médio prazo também podem ser interpretados em termos de “nível” L_t , “inclinação” S_t e “curvatura” C_t , respectivamente.

Adicionalmente, alguns estudos como Cochrane e Piazzesi (2005) demonstraram que também há conteúdo informacional na quarta e quinta componentes principais. Em especial, eles esclareceram que uma componente (ou fator) não precisa ter um grande impacto na curva de juros corrente para ser relevante quanto às expectativas correntes sobre os retornos esperados.

2.3.1 Modelos dinâmicos macro-financeiros de curva de juros

Como exposto por [Cochrane \(2017\)](#), a macro-finanças estuda a relação entre os preços dos ativos e as flutuações econômicas a partir de teorias baseadas em alguns fatos simples, como: i) os preços e retornos dos ativos estão correlacionados com os ciclos de negócios; ii) as ações na bolsa de valores sobem em momentos de crescimento e estabilidade econômica e caem em períodos de recessão e instabilidade; iii) as taxas de juros reais e nominais aumentam e diminuem com o ciclo de negócios; e iv) o retorno das ações e o rendimento dos títulos também ajudam a prever eventos macroeconômicos, como o crescimento do PIB e a inflação.

O estudo da curva de juros frente aos ciclos econômicos remonta à [Mitchell \(1913\)](#). Entretanto, somente a partir do final da década de 80, foram realizados estudos mais formais sobre a relação informacional da curva de juros com o estado futuro da economia, como [Fama \(1990\)](#), [Mishkin \(1990\)](#), [Jorion e Mishkin \(1991\)](#), [Estrella e Mishkin \(1998\)](#), [Haubrich, Dombrosky et al. \(1996\)](#) e [Hamilton e Kim \(2002\)](#), e, para o mercado de títulos brasileiro, [Shousha \(2008\)](#), [Leite et al. \(2009\)](#), [Franklin Jr et al. \(2012\)](#).

Segundo [Ait-Sahalia e Kimmel \(2016\)](#), mesmo diante do problema em conciliar as frequências dos dados de curva de juros (diários) com os dados macroeconômicos (mensais, trimestrais ou menos frequentes), a adoção de fatores macroeconômicos não só adiciona poder preditivo aos modelos de projeção de curvas de juros como, complementarmente, permite acessar o conteúdo informacional das curvas de juros para melhorar as previsões de variáveis macroeconômicas. Em vista disso, frequentemente fatores macroeconômicos têm sido utilizados em modelos que envolvam a previsão da curva de juros, ainda que não seja usual para precificar de derivativos através da curva de juros.

Econometricamente, dado o grande número de títulos negociados e de variáveis macroeconômicas, o primeiro problema em modelar a dinâmica da curva de juros é quanto ao tratamento parcimonioso do conjunto de informações para a precificação dos títulos, em dado período e para qualquer vencimento. Segundo [Diebold e Rudebusch \(2013\)](#), os modelos de fatores dinâmicos - como o DTSM e o DNSM na seção 2.2 - são atraentes para tal, pois resumem o conteúdo informacional em poucos fatores, permitindo a inferência estatística e a interpretação econômico/financeira dos resultados. Como os retornos dos títulos de diferentes vencimentos são altamente correlacionados, não faz sentido estimar regressões para a previsão de cada vencimento isoladamente ([DUFFEE, 2013b](#)). Em linha, DTSMs macro-financeiros seguem a estratégia no trabalho seminal de [Ang e Piazzesi \(2003\)](#), reduzir as informações da curva de juros em três fatores latentes - as componentes principais exploradas desde [Litterman e Scheinkman \(1991\)](#). Por sua vez, DNSMs macro-financeiros adotam uma abordagem similar, iniciada em [Diebold e Li \(2006\)](#) e expandida para a classe macro-financeira por [Diebold, Rudebusch e Aruoba \(2006\)](#), de sintetizar o conteúdo da curva corrente através dos parâmetros betas do funcional de Nelson-Siegel.

Logo, DTSMs e DNSMs macro-financeiros reconhecem o conteúdo informacional da curva corrente, sintetizando-o em poucos fatores latentes. Ainda, em ambos, a extensão da modelagem dinâmica usual à macro-financeira é feita ao incluir variáveis macroeconômicas no vetor de fatores de risco X_t . Dessa forma, a dinâmica da curva estabelecida na equação de transição (2.24) passa a ser ditada não só pelos fatores latentes da curva mas também por variáveis exógenas, como as macroeconômicas. Ao adotarem séries macroeconômicas, não só incorporam a evolução de fatores de risco sistêmico como também antecipam choques oriundos da atuação da autoridade monetária, pois, como observado por [Diebold, Piazzesi e Rudebusch \(2005\)](#), sob a perspectiva financeira, a taxa de curto prazo é um alicerce fundamental para rendimentos de outros vencimentos, os quais são apenas médias ajustadas ao risco das expectativas quanto às taxas de curto prazo futuras - além do prêmio pela liquidez. Ainda, os mesmos argumentam que, sob a perspectiva macroeconômica, a taxa de juros de curto prazo é um instrumento de política monetária sob controle direto dos bancos centrais. Estes ajustam essa taxa de forma a influenciar a taxa de longo prazo, impactante para as decisões de consumo e de investimento das famílias e das firmas, visando atingir suas metas de crescimento na atividade econômica e de controle inflacionário. Mais recentemente, assim como exposto em [Tillmann \(2020\)](#), autoridades monetárias também têm atuado diretamente sobre os vencimentos longos da curva, enxugando a oferta de títulos com vencimentos correspondentes. Isso tem ocorrido quando as taxas de curto prazo já se encontram extremamente próximas a zero, limitando a possibilidade de utilizá-las como instrumento de política monetária.

No tocante às variáveis macroeconômicas mais usuais na literatura, [Duffee \(2013b\)](#) levantou que, além das latentes, as mais recorrentes são *proxies* para a inflação, o hiato do produto (*output gap*) e as componentes cíclicas da atividade econômica (como a Produção Industrial, o PIB, ...), em linha com a lógica da regra de Taylor. Essa regra é referência na literatura de política monetária, ao estabelecer uma equação de reação para a dinâmica da taxa de juros, sendo definida por

$$y = y^* + \alpha_\pi(\pi - \pi^*) + \alpha_g(g - g^*) \quad (2.46)$$

em que y é a taxa de juros (a vista), y^* é a taxa de juros de equilíbrio, π é a taxa de inflação, π^* é a meta de inflação, g é o produto real (PIB), g^* é o produto potencial (geralmente, estimado através do filtro HP (Hodrick–Prescott) e α_π e α_g são parâmetros (lineares) de sensibilidade a serem estimados.

Mais especificamente, como *proxy* para a inflação, a literatura recente tem utilizado tanto medidas extraídas de *surveys* de expectativas de inflação ([Joslin, Le e Singleton \(2013\)](#), [Matsumura e Moreira \(2015\)](#), [Bauer e Rudebusch \(2017\)](#), ...) quanto a inflação anual passada ([Diebold, Rudebusch e Aruoba \(2006\)](#), [Matsumura, Moreira e Vicente \(2011\)](#), [Stona e Caldeira \(2019\)](#), ...). No tocante à atividade econômica, têm sido utilizadas medidas de nível e de crescimento. Mais precisamente, as de nível capturam os desvios da

atividade em relação ao nível de pleno emprego ou potencial, como o hiato do produto, o hiato do desemprego ou a utilização da capacidade instalada. Já as de crescimento, como a variação anual do produto ou a variação mensal (em média móvel de três meses), reportam a tendência de variação na atividade, independentemente do quadro vigente ser de alta ociosidade nos fatores de produção ou não. Segundo [Bauer e Rudebusch \(2017\)](#), essencialmente, essas duas classes de medidas de atividade econômica não são correlacionadas entre si ao longo do ciclo econômico. Ainda, conforme os resultados na literatura empírica sobre política monetária, as variáveis de nível têm sido consideradas mais importantes para os bancos centrais fixarem a taxa de juros de curto prazo. Alternativamente, alguns estudos recorrem à primeira componente principal extraída de um conjunto de *proxies* de inflação e outra extraída de um conjunto de *proxies* de atividade econômica, tais como [Ang e Piazzesi \(2003\)](#), [Hamilton e Wu \(2012b\)](#), [Joslin, Le e Singleton \(2013\)](#) e [Bernz \(2014\)](#).

A lógica da regra de Taylor relaciona inflação, crescimento e juros. Entretanto, os efeitos da política monetária perpassam por outras variáveis macroeconômicas. Por exemplo, no Brasil, as decisões do [Copom](#) a respeito da política de taxa de juros visa alinhar a inflação à meta definida pelo Conselho Monetário Nacional ([CMN](#)). Todavia, para isso, declaradamente levam em conta a atividade econômica, a dívida pública e o cenário externo. Em linha, a literatura relacionada à curva de juros brasileira abarca variáveis explicativas como Dívida Pública (Dívida Total/PIB), Câmbio, Taxa base de juros nacional e internacional, Risco (VIX, EMBI, Volatilidade do Ibovespa, Volatilidade na expectativa de IPCA), Retorno do Ibovespa, entre outros. Alguns exemplos destes são [Bernz \(2014\)](#), [Marçal e Marinho \(2014\)](#), [Matsumura e Moreira \(2015\)](#), [Figueiredo \(2018\)](#), [Stona e Caldeira \(2019\)](#), [Andreotti Filho \(2021\)](#) e [Santana \(2022\)](#).

Adicionalmente, estudos como [Ludvigson e Ng \(2009\)](#), [Almeida e Faria \(2014\)](#), [Vieira, Fernandes e Chague \(2017\)](#) e [Fernandes e Vieira \(2019\)](#) utilizam a(s) primeira(s) componente(s) principal(is) sobre uma vasta gama de variáveis macroeconômicas (e financeiras) como forma de sintetizar o conteúdo informacional destas em poucos fatores de risco. Nestes últimos, o objetivo em utilizar um grande número de variáveis é aumentar o poder preditivo dos modelos dinâmicos (DTSM ou DNSM), sem considerar a interpretação de cada variável e seu poder explicativo - como nesta tese.

Por fim, a literatura recente tem levantado fatores adicionais, como a influência dos movimentos no mercado internacional de crédito e da incerteza na política econômica. Estas variáveis não deixam de ser relacionadas à macroeconomia. Entretanto, por serem mais recentes, não se limitando à literatura macro-financeira usual, tais fatores foram explorados separadamente e com mais profundidade na subseção [2.3.3](#) e na seção [2.4](#), respectivamente. Ainda, cabe ressaltar que os \mathcal{M} fatores exógenos em X_t não precisam ser necessariamente macroeconômicos, ou mesmo domésticos (do país). A princípio, qualquer variável observável que teoricamente afete prêmio de risco pode ser incorporada como fator

de risco, como a *Duration* de Macaulay da carteira de títulos do governo, na subseção 2.3.2.

2.3.2 Impactos da estrutura da dívida pública

Entre as teorias que buscam explicar a relação entre os vértices na ETTJ, as mais difundidas são as variantes da Teoria das Expectativas, em que a taxa de longo prazo é dada pela composição das taxas esperadas de curto prazo mais um prêmio de liquidez. Isso ocorre porque, caso contrário, haveria oportunidade de arbitragem entre os vencimentos. Contudo, após a crise de 2008, o *Federal Reserve* e o Banco Central Europeu têm recorrido ao *quantitative easing*, um programa de enxugamento na oferta de títulos de médio e de longo prazo, para reduzir as taxas com vencimentos maiores. Um dos questionamentos gerados por essa política monetária não-ortodoxa é: como a oferta de títulos e a estrutura da dívida pública podem afetar as taxas de juros?

Contrapondo a visão dominante na literatura de curva de juros, o debate dessa questão passa pela Teoria do Habitat Preferido proposta por Culbertson (1957) e Modigliani e Sutch (1966), uma versão intermediária entre a Teoria de Segmentação do Mercado e a Teoria de Expectativas introduzidas na subseção 2.1.1. Segundo ela, existem agentes com preferências por vencimentos específicos – por exemplo, fundos de pensão preferem títulos mais longos. Por isso, a taxa de juros para cada vencimento é pressionada pela interação entre demanda e oferta de títulos com vencimento correspondente. Ainda, essa teoria não revoga a importância das expectativas na precificação das taxas de juros como na teoria de mercados segmentados, apenas considera o viés gerado pelas preferências por vencimentos específicos. Assim, caso o retorno esperado para um vencimento seja suficientemente grande em relação a outro, os agentes irão se desviar do seu vencimento preferido em busca de maiores ganhos. Consequentemente, as taxas ao longo da estrutura a termo não são desconexas, mas choques na demanda ou na oferta de vencimentos específicos serão localmente mais impactantes do que no restante da curva.

De acordo com Greenwood e Vayanos (2010), apesar do apelo intuitivo da Teoria do Habitat Preferido e de ter sido incorporada ao *mainstream* acadêmico, ela foi relegada a parágrafos em livros de MBA por dois motivos: i) os resultados divergentes entre estudos empíricos, especialmente a falta de evidência corroborando com a efetividade do *Operation Twist* (1962-1964)¹¹; e ii) sob uma perspectiva teórica, uma visão extrema de independência entre os vencimentos permitiria ganhos de arbitragem. Mais recentemente, a discussão sobre a Teoria do Habitat Preferido tem sido retomada por auxiliar na compreensão de eventos como a reforma da previdência britânica em 2004, o programa de recompra do tesouro americano em 2000-2001 e, especialmente, o *quantitative easing* adotado pelos

¹¹ Programa americano de oferta de títulos que buscava melhorar o balanço de pagamentos via aumento da taxa de curto prazo e, simultaneamente, estimular o investimento privado via redução da taxa de longo prazo.

Estados Unidos e pela União Europeia após a crise de 2008. No primeiro caso, a demanda por títulos de longo prazo foi estimulada por alterações regulatórias, e, nos demais, o programa de recompra reduziu a oferta de títulos de médio e de longo prazo. Portanto, adotaram-se medidas que afetam o equilíbrio entre oferta e demanda de títulos de longo prazo, levando a redução das taxas longas para estimular a atividade econômica. Em linha, [Greenwood e Vayanos \(2010\)](#) observaram que as respostas do mercado de títulos ao programa de compra do *Federal Reserve* têm apresentado o resultado desejado.

Isto posto, a versão original da Teoria do Habitat Preferido não é formal e, por si só, não descreve o mecanismo pelo qual flutuações na demanda e na oferta por vencimentos específicos impactam a ETTJ. Não obstante, a versão formal desenvolvida por [Vayanos e Vila \(2021\)](#) tem se destacado na literatura recente, fundamentando uma série de estudos acerca desta temática. Esta versão é formalizada por um modelo de equilíbrio geral composto por dois tipos de agentes: investidores com preferências específicas de vencimentos e ii) arbitradores avessos ao risco. Assim, os choques na taxa de curto prazo são transmitidos para as taxas de longo prazo através das operações de “carry trade” dos arbitradores, o que torna a estrutura a termo livre de arbitragem. Todavia, como esses arbitradores são avessos ao risco, choques de demanda ou de oferta afetam a precificação dos títulos. Portanto, os arbitradores ganham rendas adicionais ao transmitir os choques por meio dos prêmios de risco de títulos, que se relacionam positivamente com a inclinação da estrutura a termo. Ainda, quando a taxa de curto prazo é o único fator de risco, as mudanças na demanda dos investidores (com preferência por vencimentos específicos) têm o mesmo efeito relativo nas taxas de juros entre os vencimentos, independentemente dos vencimentos de onde se originam. Por outro lado, quando a demanda do investidor também é estocástica, os efeitos da demanda tornam-se mais localizados. Complementarmente, uma versão discreta de DTSM baseada no modelo de [Vayanos e Vila \(2021\)](#) foi desenvolvida por [Hamilton e Wu \(2012a\)](#), ao apresentar que, em equilíbrio, a demanda líquida de crédito pelos investidores com habitat preferido deve ser igual à oferta líquida dos arbitradores.

De acordo com [Greenwood e Vayanos \(2014\)](#), o modelo de [Vayanos e Vila \(2021\)](#) prevê que um aumento na oferta de títulos eleva os rendimentos dos títulos e dos retornos esperados, com efeitos mais fortes quanto maior for o vencimento, e que a dívida ponderada pela maturidade – a *Duration* – é uma medida empiricamente relevante da oferta de títulos como um todo. Baseados nas observações de [Greenwood e Vayanos \(2014\)](#), [Doh \(2010\)](#), [Swanson \(2011\)](#), [Marçal e Marinho \(2014\)](#), [Greenwood e Vayanos \(2014\)](#) e [Ferreira \(2022\)](#) evidenciaram empiricamente que as ofertas relativas de títulos com diferentes vencimentos estejam correlacionadas aos *spreads* e aos excessos de retornos, corroborando esta teoria.

Em particular, [Marçal e Marinho \(2014\)](#), [Santana \(2022\)](#) e [Ferreira \(2022\)](#) avaliaram o mercado brasileiro. [Marçal e Marinho \(2014\)](#) regrediram os *spreads* e os excessos de retorno na curva de *Swap DI* × Pré-fixado brasileira contra o prazo médio da dívida

mobiliária federal interna, para o período de 2000 a 2010. Para tanto, testaram três perfis de regressão, contra o *spread* $sp_t(\tau)$ (para $\tau = 6, 12, 24, 36, 48, 60$ meses) e contra o excesso de retorno $rx_{t,t+1}^\tau$ (para $\tau = 12, 24$ e 36 meses), similar à regressão 2.42 e às definições de *spread* e excesso de retorno na subseção 2.2.1. Formalmente, elas são definidas por:

$$sp_t(\tau) = a + bX_t + \eta_t, \quad (2.47)$$

$$rx_{t,t+1}^\tau = a + bX_t + \eta_{t+1}, \quad (2.48)$$

$$rx_{t,t+1}^\tau = a + bX_t + c(y_t(\tau) - y_t(1)) + \eta_{t+1}, \quad (2.49)$$

onde a , b e C são parâmetros a serem estimados, η_t e η_{t+1} são os respectivos erros e X_t contém a variável de *Duration* e, em uma análise posterior de robustez dos resultados, variáveis de controle (crescimento da economia, expectativa de inflação para os próximos doze meses, índice Ibovespa e sua volatilidade). Eles estimaram resultados significativos, mesmo quando são incorporadas variáveis de controle e utilizando estimadores robustos à heterocedasticidade e à autocorrelação dos resíduos. Estes resultados foram estendidos por Santana (2022) ao considerar o período amostral entre 2000 e 2019. Ferreira (2022) também estudou essa influência da estrutura da dívida brasileira sobre os rendimentos na curva de juros. Em especial, ao replicar os procedimentos de Greenwood e Vayanos (2014), demonstrou que, entre 2006 e 2021, tanto o *spread* quanto o excesso de retorno da curva brasileira é muito mais sensível que os da americana frente a aumentos na dívida de longo prazo ou na Duração da dívida do respectivo país. Ainda, seus resultados mostram que a média de maturidade ponderada pelo valor do estoque é a melhor medida para as previsões das hipóteses testáveis (FERREIRA, 2022).

Diante de resultados como os de Marçal e Marinho (2014), Santana (2022) e Ferreira (2022) para a curva de juros brasileira, deve-se considerar que os movimentos na estrutura a termo nem sempre podem ser entendidos apenas pelas mudanças nas expectativas sobre as taxas de juros de curto prazo, na inflação ou em outras variáveis macroeconômicas – que impactam o prêmio de risco. Ainda, cabe observar que as regressões em (2.48) são similares às (2.42) na subseção 2.2.1. Dessa forma, uma análise adequada da curva brasileira também deve observar fatores associados à dívida pública e à *Duration* da carteira do governo como fatores de risco relevantes, ao menos como variável de controle.

2.3.3 Fatores internacionais e curva de juros

A vasta maioria da literatura sobre curva de juros estuda curvas de um único país, relacionando os retornos domésticos a fatores domésticos, sem considerar possíveis interações com o mercado internacional. Mesmo entre os estudos que avaliam as taxas base de juros de diferentes países, muitos levantam uma relação significativa entre as mesmas, mas não investigam como se dá a dinâmica entre as mesmas - principalmente quanto a expectativas e prêmios de risco (DIEBOLD; LI; YUE, 2008). Por exemplo, Moon

e Perron (2007) encontraram a existência de um fator em comum entre a curva americana e a canadense, ao cointegrar os fatores extraídos de um painel de títulos de diferentes maturidades. Além deste, Henriksen, Kydland e Sustek (2010) avaliaram o sincronismo na frequência dos agregados macroeconômicos dentro dos ciclos de negócios, especialmente, os monetários. Todavia, ambos não avaliaram a influência do choque em uma curva sobre a outra curva.

Contudo, apesar do pouco conhecimento teórico acerca de como os fatores globais de risco se relacionam, uma conjectura natural e rotineira em mercados financeiros é que tais fatores não só existem como são certamente cruciais para o entendimento dos mercados de títulos nacionais (DIEBOLD; LI; YUE, 2008). Em linha, as crises financeiras internacionais recentes (principalmente a crise financeira de 2007-2008) expõem como, em um mercado de crédito internacionalmente integrado, choques macro-financeiros podem se propagar intensamente.

Mais aderentes a essa conjectura, Abbritti et al. (2018) utilizaram um FAVAR (*factor-augmented vector autoregressive*) para explicar a curva de juros doméstica futura a partir da curva de juros corrente e de fatores globais correntes. Mais especificamente, eles empregaram as três primeiras componentes principais extraídas da curva de juros global - formada por um painel de curvas de juros de sete países: Reino Unido, Canada, Alemanha, Japão, Austrália, Nova Zelândia e Suíça, de 1990 até o primeiro trimestre de 2009. Em seus resultados, estimaram que os fatores globais explicam mais de 80% dos termos de prêmio na curva de economias desenvolvidas. Em particular, os fatores globais tendem a explicar dinâmicas de longo prazo na curva de juros, enquanto os fatores domésticos são mais relevantes para movimentos no curto prazo.

Por sua vez, Jotikasthira, Le e Lundblad (2015) incorporaram fatores de risco americanos (latentes à curva e macroeconômicos) à modelagem de Ang e Piazzesi (2003) para as curvas alemã e inglesa. Eles consideraram dois caminhos pelos quais esses choques se propagam: i) através da dinâmica conjunta das variáveis de estado, inclusive aquelas que a política econômica visa controlar/estimular (inflação, produção, ...); e ii) pelos prêmios de risco associados aos estados. No primeiro canal - da política econômica -, como a taxa de juros é um instrumento de política monetária, os co-movimentos na taxa de curto prazo no início da curva de juros tendem a refletir os co-movimentos nos fundamentos econômicos (como a inflação, a produção, o emprego, o câmbio, ...) aos quais as autoridades monetárias respondem¹². Por outro lado, a correlação nas taxas de longo-prazo entre os países está associada não só ao canal da política econômica, mas também ao canal da compensação do risco. Conseqüentemente, os vencimentos mais longos na curva serão ainda mais impactados pelos fatores econômicos e monetários do que fora previsto pelos

¹² Segundo os resultado de Kose, Otrok e Whiteman (2003), o fator internacional é uma importante fonte de volatilidade para os agregados macroeconômicos na maioria dos países, evidenciando, assim, a existência de um ciclo de negócios global.

modelos de expectativas racionais.

Adicionalmente, examinando o impacto da política monetária americana sobre a atividade econômica de outros países, tanto [Canova \(2005\)](#) quanto [Kim \(2001\)](#) relataram que as reações às alterações na taxa de juros (básica) é o principal canal de transmissão de choques. Além desses, alguns artigos recentes que modelam a estrutura a termo de juros considerando relações entre diferentes países são: o de [Graveline e Joslin \(2010\)](#), o qual não explora os co-movimentos entre as curvas mas considera um modelo que abar simultaneamente a taxa de juros e a de câmbio; o de [Sarno, Schneider e Wagner \(2012\)](#), que estuda as propriedades dos prêmios de risco cambial e acabam observando uma relação entre esse e os prêmios de risco nas curvas de juros; e o de [Bauer e Rios \(2012\)](#), que estudam os determinantes dos prêmios de risco no mercado de títulos e no de câmbio.

Alguns estudos mais alinhados aos objetivos desta tese, em também considerar os co-movimentos entre curvas de juros, são [Sowmya, Prasanna e Bhaduri \(2016\)](#), [Stona e Caldeira \(2019\)](#) e [Cavaca e Meurer \(2021\)](#), ambos adotando o modelo dinâmico de Nelson-Siegel desenvolvido por [Diebold e Li \(2006\)](#).

[Sowmya, Prasanna e Bhaduri \(2016\)](#) investigaram as ligações nos rendimentos de títulos soberanos em diferentes espectros de maturidade entre países desenvolvidos e países asiáticos, através da decomposição da variância na modelagem VAR. Seus resultados demonstraram que o fator de nível (L_t) da curva de juros (conforme a equação (2.34)) apresenta maior índice de *spillover* entre os países e que a influência regional é maior nos fatores de inclinação (S_t) e curvatura (C_t) entre os países asiáticos. Além disso, observaram que as correlações são altas durante os períodos de crise.

[Stona e Caldeira \(2019\)](#) examinaram a dinâmica da curva brasileira, entre 2004 e 2016, frente a americana e a fatores macroeconômicos brasileiros. Para tanto, estimaram quatro variações de modelos dinâmicos similares ao sistema nas equações (2.35) e (2.36):

- i) Modelo macro-financeiro idêntico ao de [Diebold, Rudebusch e Aruoba \(2006\)](#), que associa os fatores latentes da curva brasileira ($L_{t,Br}$, $S_{t,Br}$ e $C_{t,Br}$) às variáveis macroeconômicas uci_t (Utilização da Capacidade (industrial) Instalada), $selic_t$ (taxa Selic) e $ipca_t$ (taxa de inflação);
- ii) Modelo apenas com fatores latentes da curva brasileira ($L_{t,Br}$, $S_{t,Br}$ e $C_{t,Br}$) e da curva americana ($L_{t,US}$, $S_{t,US}$ e $C_{t,US}$);
- iii) Modelo apenas com fatores latentes da curva brasileira ($L_{t,Br}$, $S_{t,Br}$ e $C_{t,Br}$), fatores latentes da curva americana ($L_{t,US}$, $S_{t,US}$ e $C_{t,US}$) e variáveis macroeconômicas brasileiras (uci_t , $selic_t$ e $ipca_t$);
- iv) Modelo apenas com fatores latentes da curva brasileira ($L_{t,Br}$, $S_{t,Br}$ e $C_{t,Br}$), fatores latentes da curva americana ($L_{t,US}$, $S_{t,US}$ e $C_{t,US}$) e variáveis macroeconômicas

brasileiras ($uci_t, selic_t$ e $ipca_t$), além de exr_t (a variação na taxa de câmbio).

Seus resultados identificaram uma clara evidência de co-movimento entre os fatores da curva americana com a curva brasileira. Destacadamente, o fator de nível americano $L_{t,US}$ explica quase metade da variação no fator de nível brasileiro $L_{t,Br}$, além de impactar os fatores de inclinação $S_{t,Br}$ e curvatura $C_{t,Br}$ no longo prazo. Ainda, no aspecto preditivo, observaram que adotar apenas fatores americanos é melhor para horizontes curtos e longos.

Por sua vez, Cavaca e Meurer (2021) fizeram uma análise similar à de Stona e Caldeira (2019) para o mercado brasileiro. Em especial, Cavaca e Meurer (2021) utilizaram uma adaptação do índice de *spillover* para mercados acionários desenvolvido por Diebold e Yilmaz (2009) e Diebold e Yilmaz (2012), posteriormente adaptados para o contexto de curva de juros em trabalho como Cavaca e Meurer (2021), Umar, Riaz e Zaremba (2021) e Umar, Riaz e Aharon (2022).

De forma sucinta, esse índice de *spillover* é baseado na decomposição da variância do erro de previsão de um VAR (de ordem p) sobre o vetor de variáveis X_t . No contexto de curva de juros, este contempla os fatores latentes de risco da curva doméstica ($L_{BR,t}$, $S_{BR,t}$ e $C_{BR,t}$) e, complementarmente, os fatores de curvas estrangeiras ($L_{i,t}$, $S_{i,t}$ e $C_{i,t}$, para o país i). Portanto, tem-se

$$X_t = \sum_{n=1}^p K_n X_{t-n} + \epsilon_t, \quad (2.50)$$

o VAR(p) sobre os fatores de risco $X_t = [L_{BR,t} \ S_{BR,t} \ C_{BR,t} \ L_{i,t} \ S_{i,t} \ C_{i,t}]'$, com resíduos iid $\epsilon \sim N(0, \Sigma)$, cuja representação em termos de média móvel é dada por

$$X_t = \sum_{n=1}^{\infty} A_n \epsilon_{t-n}. \quad (2.51)$$

Após estimar o modelo em (2.50), estima-se a decomposição generalizada da variância do erro de previsão desenvolvida por Pesaran e Shin (1998). Nesta, o H -ésimo passo à frente da decomposição generalizada da variância do erro de previsão entre as variáveis $x_i, x_j \in X_t$ é fornecido por

$$\Psi_{i,j}^H = \frac{\sigma_{jj}^{-1} \sum_{h=0}^{H-1} (e_i' A_h \Sigma e_j)^2}{\sum_{h=0}^{H-1} (e_i' A_h \Sigma A_h' e_j)}, \quad (2.52)$$

onde Σ é a matriz de covariância do vetor de erros ϵ_t , σ_{jj} é o j -ésimo elemento diagonal de Σ e e_j é um vetor de seleção com j -ésimo elemento igual a 1 e, nos demais elementos, igual a 0. $\Psi_{i,j}^H$ representa a contribuição dos choques na variável x_j à variância de x_i em H -passos. Para garantir que a soma das N contribuições à x_i seja igual a 1, adota-se a normalização

$$\tilde{\Psi}_{i,j}^H = \frac{\Psi_{i,j}^H}{\sum_{j=1}^N \Psi_{i,j}^H}. \quad (2.53)$$

A partir de $\tilde{\Psi}_{i,j}^H$, Diebold e Yilmaz (2009) e Diebold e Yilmaz (2012) fixaram $H = 10$ e propuseram uma série de medidas de conectividade, tais como:

$$Tr_{ij}^H = \tilde{\Psi}_{ij}^H - \tilde{\Psi}_{j,i}^H, \text{ o } spillover \text{ líquido entre } x_i \text{ e } x_j;$$

$$Tr_{i\leftarrow\bullet}^H = \sum_{j=1}^N \tilde{\Psi}_{i,j}^H, \text{ o } spillover \text{ total para } x_i;$$

$$Tr_{i\rightarrow\bullet}^H = \sum_{j=1}^N \tilde{\Psi}_{j,i}^H, \text{ o } spillover \text{ total de } x_i;$$

$$Tr_i^H = Tr_{i\leftarrow\bullet}^H - Tr_{i\rightarrow\bullet}^H, \text{ o } spillover \text{ líquido de } x_i; \text{ e, em especial,}$$

$$Tr^H = \frac{1}{N} \sum_{i,j=1}^N \tilde{\Psi}_{i,j}^H, \text{ a conectividade total.}$$

Cavaca e Meurer (2021) utilizaram essas medidas para avaliar o *spillover* de fatores latentes (modelo DNSM) da curva de juros americana sobre as curvas de países na América Latina (Brasil, Chile, Colômbia e Peru). Seus resultados demonstraram alto grau de *spillover* nos fatores nível (22,79%), inclinação (25,53%) e curvatura (15,18%), com alta oscilação das intensidades de transmissão ao longo do tempo. Em especial, alinhado ao problema de pesquisa desta tese, constataram um aumento substancial no índice de *spillover* durante crises financeiras e outros períodos de alta volatilidade. Complementarmente, estudos como Umar et al. (2021), Umar, Riaz e Zaremba (2021), Umar, Riaz e Aharon (2022) e Amaral (2019) utilizaram essas medidas para avaliar o *spillover* da incerteza entre países, explorado na subseção 2.4.2.

2.4 Incerteza na política econômica

A influência da incerteza sobre decisões individuais é um aspecto central na teoria de finanças, sendo explorada desde o trabalho seminal de Markowitz (1952). Por sua vez, a incerteza é um tema de pesquisa fundamental para a teoria macroeconômica, desde Keynes (1936). Segundo Keynes, a incerteza quanto ao futuro e, conseqüentemente, sobre os resultados dos investimentos gera maior preferência pela liquidez por parte dos agentes, impactando negativamente a atividade econômica do país. Dessa forma, a incerteza afeta não só processos decisórios individuais como, em níveis macroeconômicos, impacta o desempenho da economia como um todo.

Contudo, o debate acerca dos impactos da flutuação na incerteza inerente à política econômica é relativamente recente. Seu início foi impulsionado pela crise financeira de 2007-2008 e a conseqüente alteração na forma de atuação das autoridades monetárias. O trabalho de Bloom (2009) é recorrentemente tratado como marco seminal desse campo. Neste, evidenciou-se uma forte relação contra-cíclica entre a atividade e a incerteza - mensurada pela volatilidade do mercado de ações. Conforme Carriero, Clark e Marcellino (2020), desde Bloom (2009), um grande corpo de pesquisa vem examinando a medição da

incerteza econômica assim como seus efeitos, como [Carrière-Swallow e Céspedes \(2013\)](#), [Gilchrist, Sim e Zakrajšek \(2014\)](#), [Jurado, Ludvigson e Ng \(2015\)](#), [Basu e Bundick \(2017\)](#) e [Carriero, Clark e Marcellino \(2018\)](#). Em linha com as previsões teóricas, esta literatura tem recorrentemente confirmado empiricamente o resultado em [Bloom \(2009\)](#), de que a incerteza é fortemente contra-cíclica, independentemente da *proxy* utilizada para medi-la.

De acordo com [Jurado, Ludvigson e Ng \(2015\)](#) e [Husted, Rogers e Sun \(2019\)](#), a literatura acerca da incerteza tipicamente a define como a volatilidade condicional de distúrbios, imprevisíveis sob a perspectiva dos agentes econômicos. Não obstante, o conceito de incerteza não pode ser completamente capturado por medidas como a volatilidade - usual, também, na literatura financeira clássica. Segundo [Bloom \(2014\)](#), esse conceito deve refletir a incerteza na mente de consumidores, de gestores privados e de gestores públicos acerca do futuro, incluindo aspectos: macroeconômicos como o crescimento do PIB; micro-fenômenos como o crescimento das firmas; e não econômicos como guerras ou mudanças climáticas.

Em linha, um marco conceitual é a distinção entre risco e incerteza feita por [Knight \(1921\)](#). Nesta, enquanto o risco pode ser descrito por distribuições de probabilidade bem definidas, a incerteza (ou ambiguidade) se relaciona à incapacidade dos agentes em atribuir medidas de probabilidades aos eventos factíveis. Nessa perspectiva, por ser mensurável através de métricas como a volatilidade, o risco pode ser gerenciado pelos agentes durante o processo de tomada de decisão. Por outro lado, diante da incerteza (knightiana), os agentes tendem a postergar suas decisões (de investimento, de contratação de trabalhadores, ...) e, assim como postulado em [Keynes \(1936\)](#), a optar por maior liquidez.

Sendo assim, a incerteza é um conceito amorfo [Bloom \(2014\)](#), que não pode ser mensurado objetivamente ([JURADO; LUDVIGSON; NG, 2015](#)). De acordo com [Jurado, Ludvigson e Ng \(2015\)](#), a literatura sobre a medição da incerteza ainda está em sua infância, o desafio tem sido quanto à forma de examinar empiricamente o seu comportamento e a sua relação com a atividade macroeconômica. Segundo eles, entre as métricas mais utilizadas nessa literatura, pode-se elencar as seguintes:

- i) a volatilidade implícita ou realizada dos retornos acionários;
- ii) a dispersão transversal dos lucros das empresas, dos retornos das ações ou da produtividade;
- iii) a dispersão transversal das previsões em *surveys* de expectativas de mercado;
- iv) a contagem de certas palavras-chave relacionadas à incerteza nas publicações de notícias.

Realizando uma análise bibliométrica desse campo, a publicação com o maior número de citações é [Baker, Bloom e Davis \(2016\)](#). Nesta, foi apresentado o índice de

Incerteza na Política Econômica (EPU, *Economic Policy Uncertainty*), que utiliza contagem de termos-chaves em artigos de revistas para capturar as flutuações na incerteza. Em seguida, esses pesquisadores estenderam esse índice, transformando-o em um indicador composto, formado por três tipos de componentes:

- i) um que quantifica o volume de notícias que discutem a incerteza na política econômica dentre os dez maiores jornais do país, correspondendo a 50% do indicador composto;
- ii) um que mede o número de disposições do código tributário federal que estejam previstas para expirar nos próximos anos, correspondendo a cerca de 17,7% do indicador; e,
- iii) um que captura a dispersão das projeções de analistas profissionais sobre variáveis relacionadas à política econômica (inflação e gasto público), coletadas pelo *Federal Reserve* da Filadélfia, correspondendo a 33,3% do indicador composto.

Esta abordagem, de indicador composto com grande peso na contagem de termos-chaves em notícias, vem sendo amplamente explorada nessa literatura, sendo conceitualmente mais alinhada às definições de incerteza de Knight (1921) e de Bloom (2014). A série histórica do EPU tem sido atualizada e divulgada¹³ para os Estados Unidos e para outros países, como o Brasil. Sendo, por isso, base para uma série de estudos posteriores como Kido (2016), Demir e Ersan (2017) e Aastveit, Natvik e Sola (2017), entre outros.

Indicadores similares têm sido desenvolvidas em outros trabalhos, como o *Monetary Policy Uncertainty* (MPU) de Husted, Rogers e Sun (2019). Entretanto, destaca-se que o EPU tem sido continuamente atualizado, além de ser um indicador exógeno de incerteza na política econômica. Não obstante, o EPU calculado para o Brasil se restringe à componente de volume de notícias que discutem a incerteza na política econômica, considerando apenas em matérias publicadas no jornal Folha de São Paulo. Alternativamente, um indicador similar ao EPU para o Brasil é o Indicador de Incerteza da Economia - Brasil (IIE-Br) de Ferreira et al. (2019), produzido pelo Instituto Brasileiro de Economia (IBRE/FGV). Este é formado por duas componentes:

- i) o Indicador de Incerteza na Mídia, que reflete a incidência de termos relacionados à incerteza em artigos publicados em seis dos principais jornais do país (Folha de São Paulo, Valor Econômico, O Globo, Estado de São Paulo, Correio Braziliense e Zero Hora), possuindo um peso de 80% no indicador agregado; e
- ii) o Indicador de Dispersão de Expectativas, elaborado com base na dispersão das previsões de especialistas (divulgados pelo Banco Central) para a taxa de câmbio, a


¹³ Em <<https://www.policyuncertainty.com/index.html>>.

Selic e o Índice Nacional de Preços ao Consumidor Amplo (IPCA), possuindo um peso de 20% no indicador agregado.

Em vista da maior cobertura para o Brasil, a equipe responsável pelo EPU referencia o IIE-Br como *proxy* para o Brasil.

Ilustrativamente, a Figura 3 compara o IIE-Br com o EPU-Br.

Figura 3 – Séries históricas do IIE-Br e do EPU-Br



Fonte: elaboração própria.

Nesta, destaca-se as diferenças entre as volatilidade nos dois indicadores, em virtude das limitações no cálculo do EPU para o Brasil, de ser composto apenas pelo indicador de notícias e este considerar um único jornal como fonte.

Tanto o EPU (Brasil) quanto o IIE-Br têm sido adotados em estudos sobre impactos da incerteza na política econômica no Brasil. Por exemplo, [Marschner e Ceretta \(2021\)](#) utilizam o IIE-Br para avaliar como a incerteza econômica afeta o sentimento do investidor no Brasil. [Schwarz e Dalmácio \(2021\)](#) recorreram ao EPU para avaliar a relação entre a incerteza na política econômica e a alavancagem de companhias brasileiras. [Souza, Batista e Cunha \(2022\)](#) utilizaram tanto o EPU quanto o IIE-Br para investigar os efeitos da incerteza da política econômica sobre o caixa e a folga financeira das empresas de capital aberto listadas no mercado acionário brasileiro. Adicionalmente, há trabalhos que combinam esses indicadores a outros, como o estudo de [Barboza e Zilberman \(2018\)](#) acerca dos efeitos da incerteza sobre a atividade econômica brasileira. Mais especificamente, recorreram a seis *proxies* de incerteza econômica: i) uma média ponderada entre o EPU brasileiro construído por [Baker, Bloom e Davis \(2016\)](#) e uma *proxy* de construção própria, como metodologia idêntica ao EPU, mas considerando o jornal O Globo como fonte de notícias; ii) a volatilidade implícita dos contratos de opção de câmbio “*at the money*” com

vencimento de um mês; iii) o desvio padrão dos retornos diários do Ibovespa; iv) o desvio padrão das expectativas de inflação Focus 12 meses à frente; v) a primeira componente principal extraída das quatro medidas anteriores; e vi) o IIE-Br.

Em particular, [Souza, Zabot e Caetano \(2019\)](#) analisaram o efeito de choques na dinâmica da incerteza ao testar a raiz unitária via modelo autorregressivo quantílico e encontraram um efeito assimétrico, tanto no EPU quanto no IIE-Br. Isto é, localmente, observou-se uma tendência de reversão à média em quantis condicionais mais baixos, mas um comportamento não estacionário para quantis condicionais mais altos. Em vista disso, concluem que choques que tendam a elevar a incerteza, como o de 2008/2009, podem ter efeitos permanentes na economia.

Dada sua robustez e a vantagem de serem diretamente observáveis, cada vez mais, a pesquisa acerca de impactos da incerteza tem recorrido a indicadores compostos como o EPU e o IIE-Br. Contudo, a adequação de qualquer *proxy* da incerteza depende do quão fortemente ela está correlacionada ao processo estocástico latente a ser explicado em cada estudo ([CREAL; WU, 2017](#)). Logo, ainda assim, deve-se avaliar outras variáveis enquanto balizadoras dos efeitos da incerteza econômica sobre a curva de juros.

2.4.1 Incerteza na política econômica e curvas de juros

No tocante aos efeitos da incerteza sobre a curva de juros, o impacto da incerteza sobre o mercado de crédito é reconhecido por teóricos e participantes do mercado há tempo. Entretanto, só recentemente, a pesquisa empírica começou a buscar por formas de mensurar a incerteza e avaliar o seu impacto sobre a curva de juros. Como a literatura acerca da dinâmica entre incerteza e curva de juros está relacionada a diferentes temáticas de pesquisa macro-financeiras, a seguir ela é categorizada entre os seguintes problemas de pesquisa: i) o impacto, em si, de medidas empíricas de incerteza sobre a curva de juros - foco desta tese -; ii) a relação entre a incerteza inflacionária (ou a macroeconômica) e o prêmio de risco da curva de juros (ou o inflacionário); iii) o desenvolvimento de modelos de estimação que incorporam elementos de incerteza endógena como fator explicativo; e iv) mudanças na sensibilidade da curva de juros a choques macroeconômicos devido ao grau de incerteza vigente no momento do choque. Isto posto, alguns resultados da literatura são apresentados a seguir e, ao final, são relacionados à proposta desta tese.

No primeiro campo de pesquisa, destacam-se [Jordà e Salyer \(2003\)](#), os primeiros a avaliar o impacto da incerteza na política monetária sobre a estrutura a termo (americana). Mais especificamente, eles utilizaram a variância condicional (dinâmica) da taxa de crescimento da base monetária como *proxy* da incerteza econômica. Conforme as estimativas no modelo de equilíbrio geral que postularam, o aumento da incerteza gera uma queda na taxa de juros nominal dos títulos. Segundo eles, nos rendimentos de curto prazo, isso se deve ao aumento da liquidez no setor bancário causado pelo setor doméstico; já nos de

longo prazo, isso se deve ao efeito da incerteza sobre a taxa intertemporal de substituição, que é convexa em função do crescimento na base monetária. Mais recentemente, [Leippold e Matthys \(2022\)](#) também avaliaram o impacto da incerteza sobre a curva de juros americana, mas mensurando-a pelo EPU e em um modelo de equilíbrio geral com agentes aversos à incerteza. Eles também constataram que uma maior incerteza na política econômica leva à significativa redução no nível das taxas de juros, além de aumentar a volatilidade dos rendimentos dos títulos. Em particular, também observaram um efeito ambíguo do aumento da incerteza sobre o prêmio de risco, com resposta positiva nos títulos de curto prazo, mas negativa nos de longo. Mais alinhado à proposta desta tese, [Ioannidis e Ka \(2021\)](#) buscaram avaliar o poder preditivo da incerteza econômica sobre retornos futuros dos títulos americanos. Para tanto, avaliaram o impacto do EPU sobre os excessos de retorno e, complementarmente, sobre o prêmio de risco - controlados pelas três componentes principais da curva de juros. Seus resultados apontaram que o EPU contém informação acerca dos rendimentos futuros, especialmente os de curto prazo. Ainda, constataram que adicionar o EPU como fator de risco no DTSM não explica significativamente as variações dos rendimentos na curva, mas impacta a identificação do prêmio de risco, que passou a exibir movimentos contracíclicos significativamente mais fortes, explicando melhor a compensação de risco mais elevada em condições econômicas adversas.

No segundo campo, destacam-se [Ang, Bekaert e Wei \(2008\)](#) e de [Wright \(2011\)](#) na literatura internacional. O ponto de partida de [Ang, Bekaert e Wei \(2008\)](#) foi, através de um DTSM afim com mudança de regime, decompor a diferença entre as taxas na estrutura a termo nominal e as na estrutura a termo real em: inflação esperada e prêmio de risco inflacionário. Ao avaliar o mercado americano de 1952 a 2004, estimaram que a expectativa de inflação e o risco de inflação explicam 80% da variação nos juros nominais. Contudo, ressaltam que os *spreads* (entre vencimentos) na curva nominal são impulsionados principalmente por mudanças na expectativa de inflação, especialmente em períodos de normalidade. Por sua vez, [Wright \(2011\)](#) constatou uma queda no prêmio de risco causada pela retração na incerteza inflacionária ao avaliar um painel internacional¹⁴. Para tanto, o termo de prêmio foi identificado por um DTSM canônico e pela diferença entre a expectativa da taxa de três meses nos *surveys* e a taxa *forward* de três meses, enquanto a incerteza inflacionária foi mensurada pela volatilidade condicional da série de inflação e pela dispersão nos *surveys* de expectativa de inflação. Em especial, a comparação internacional lhes permitiu inferir que as maiores quedas nos prêmios de risco foram em países que adotaram medidas visando maior credibilidade à política de controle inflacionário da autoridade monetária, como a adoção de metas de inflação e a autonomia do banco central.

No Brasil, trabalhos como [Lowenkron e Garcia \(2007\)](#), [Vicente e Graminho \(2015\)](#), [Montes e Curi \(2017\)](#), [Reis \(2018\)](#) e [Figueiredo \(2018\)](#) buscaram identificar os determinantes

¹⁴ Estados Unidos, Reino Unido, Canadá, Japão, Alemanha, Noruega, Suécia, Suíça, Austrália e Nova Zelândia.

do prêmio de risco inflacionário. Todos estes identificaram o prêmio de risco inflacionário através da diferença entre: o *gap* da estrutura a termo nominal com a real, e a expectativa de inflação fornecida em *surveys* de *forecasters* - exceto por Lowenkron e Garcia (2007), que estimaram a expectativa de inflação através da média móvel de 12 meses. Formalmente, tem-se

$$y(\tau)_t^{nominal} - y(\tau)_t^{real} = \pi_t^{implicita} = E_t[\pi(\tau)] - PRI_t(\tau), \quad (2.54)$$

onde $\pi_t^{implicita}$ é a inflação implícita entre a estrutura a termo nominal e a real, $E[\pi(\tau)]$ é a expectativa de inflação para o horizonte τ e $PRI_t(\tau)$ é o prêmio de risco inflacionário.

Lowenkron e Garcia (2007) constataram que surpresas inflacionárias elevaram as expectativas de inflação para além da meta inflacionária do governo, além de aumentar o prêmio de risco inflacionário em grande parte do período amostral (2001-2007). Seus resultados também apontaram que esses impactos da surpresa inflacionária gradativamente perderam efeito ao longo do período amostral, o que interpretam como um indicador de melhoria na credibilidade na política monetária brasileira no período. Vicente e Graminho (2015) estimaram que, para horizontes longos, este prêmio de risco é variável no tempo e relacionado com o consumo e a volatilidade do mercado de ações. Montes e Curi (2017) se diferenciaram ao adicionar duas variáveis, a divergência quanto às expectativas da dívida pública e a credibilidade da política monetária (dada pelo grau de ancoragem das expectativas em relação à meta inflacionária), para avaliar determinantes do prêmio de risco inflacionário. Para o período de 2005 a 2015, constataram que aumentos nesse prêmio de risco são influenciados por altas na incerteza fiscal e quedas na credibilidade. Em Reis (2018), destacou-se o impacto do CDS (*proxy* de risco de *default* dos títulos públicos brasileiros) e as expectativas de inflação sobre o prêmio de risco inflacionário. Por fim, mais alinhado à proposta de avaliar o impacto da incerteza (nacional e externa) sobre o prêmio de risco, Figueiredo (2018) analisou como o prêmio de risco inflacionário de distintas maturidades é afetado por choques na incerteza financeira global, medido pelo VIX (*Volatility Index* da *Chicago Board Options Exchange*), e por choques de incerteza econômica doméstica, medida pelo EMBI+ Br. Neste, os choques de incerteza doméstica produziram aumento dos prêmios inflacionários enquanto os choques de incerteza externa, apesar de recessivos, geraram aumentos iniciais nos prêmios de riscos, mas decaíram posteriormente, prevalecendo incertezas deflacionárias causadas por um ambiente recessivo.

No terceiro campo, sublinha-se o trabalho de Creal e Wu (2017), que desenvolveu um DTSM afim condicionado à volatilidade - *i.e.*, o segundo momento nos fatores de risco tem efeito de primeira ordem sobre eles. Mais precisamente, eles decompõem a incerteza em duas *proxies*, a volatilidade nas variáveis macroeconômicas como *proxy* de incerteza na política econômica e a volatilidade nos rendimentos na curva (nas componentes principais) como *proxy* de incerteza nos prêmios de risco dos títulos. Alinhados à literatura, demonstram que a incerteza contribui negativamente para a atividade econômica

americana. Contudo, a resposta da inflação a choques de incerteza varia ao longo do período analisado. Por exemplo, durante a Grande Inflação (a partir de 1965), a incerteza econômica impulsionou a inflação, associado ao quadro ruim na economia. Por outro lado, no período Volcker (1979-1987) - reconhecido pelo combate agressivo à inflação - e na crise de 2007-2009, essa incerteza pressionou a inflação para baixo, sugerindo que neste período os agentes econômicos estavam mais preocupados com a desinflação - geralmente associada à recessão econômica nos ciclos recente americanos - do que com uma hiperinflação. Ainda, constataram que tanto a incerteza econômica quanto a no prêmio de risco são impulsionadas por choques inflacionários. Contudo, enquanto a incerteza econômica respondeu negativamente a mudanças na atividade econômica - maior desemprego gerou maior incerteza econômica-, a incerteza no prêmio de risco diminui em momentos de recessão econômica. Adicionalmente, Ulrich (2013) desenvolveu um modelo de equilíbrio com incerteza e Knightiana . Ele demonstrou que as variações na curva nominal são explicadas principalmente pelas alterações na tendência inflacionária e que o termo de prêmio nos títulos americanos pode ser explicado pela combinação de uma função de utilidade convexa com a ambiguidade sobre a tendência inflacionária - enquadrando-o no segundo campo também, ao relacionar expectativa inflacionária e termo de prêmio.

No quarto campo, assim como Aastveit, Natvik e Sola (2017) investigaram a eficácia da política monetária americana condicionada ao grau de incerteza econômica no período; Tillmann (2020) e Shang (2022) avaliaram a sensibilidade da curva de juros aos choques na política monetária, condicionados ao grau de incerteza mensurado por indicadores como o de Baker et al. (2019) (EPU) e o indicador o de Jurado, Ludvigson e Ng (2015). Mais especificamente, Tillmann (2020) adotou um VAR contendo termos de interação entre o grau de incerteza e as variáveis defasadas. Por sua vez, Shang (2022) empregou um FAVAR com *regime switching*, em que o limiar de mudança no regime é delimitado pelo grau de incerteza econômica. Todavia, os resultados foram opostos. Tillmann (2020) constatou que a resposta das taxas de longo prazo a choques na política monetária são menores em momentos de maior incerteza, devido à redução do prêmio de risco nesses períodos. Por outro lado, Shang (2022) observou um aumento significativo na sensibilidade da curva de juros quando a incerteza é alta, principalmente nos fatores de nível e de inclinação.

Em síntese, esses quatro campos de pesquisa são recentes. Ainda, a literatura para o mercado brasileiro se restringe ao segundo campo - tema mais impactante em economias emergentes, com expressivo histórico inflacionário. Apesar do fato desta tese se enquadrar no primeiro campo, adotando *proxies* exógenas que buscam capturar a percepção de incerteza dos agentes econômicos, destaca-se que o terceiro (modelagem da incerteza endógena como fator explicativo) e o quarto campo (interação entre incerteza e demais fatores explicativos) são formas complementares de avaliar o impacto da incerteza sobre a dinâmica na curva de juros. Um questionamento imediato é a combinação dessas três abordagens em uma única modelagem. Todavia, é plausível retomar que modelar a curva

de juros por si só (segregando expectativa e prêmio de risco) é um problema computacional complexo e, por isso, aumentar a quantidade de parâmetros ao se adotar uma modelagem mais abrangente pode levar a resultados ineficientes.

2.4.2 *Spillovers* da incerteza na política econômica

Por fim, embora grande parte da literatura tenha se concentrado na incerteza em uma única economia, há pesquisas empíricas que estudam aspectos internacionais comuns da incerteza e seus efeitos (CARRIERO; CLARK; MARCELLINO, 2020). Em particular, os resultados em Colombo (2013) apontaram que variações da incerteza na política econômica americana são mais impactantes sobre a produção industrial e a inflação de países na zona do euro do que as variações de incerteza oriundas dos demais países do bloco. Além desse, os estudos de Klößner e Sekkel (2014), Kido (2016), Demir e Ersan (2017), Trung (2019), Caggiano, Castelnuovo e Figueres (2020), Lakdawala, Moreland e Schaffer (2021) e Karanasos, Yfanti e Hunter (2022) encontraram efeitos significativos de *spillover* do EPU americano para outros países, impactando a incerteza nestes ou mesmo variáveis macro-financeiras como a atividade econômica, a decisão de reter caixa ou a volatilidade no mercado de acionário.

Em especial, nos últimos dois anos, estudos como Umar et al. (2021), Umar, Riaz e Zaremba (2021), Benlagha e Hemrit (2022) e Umar, Riaz e Aharon (2022) também avaliaram efeitos do *spillover* da incerteza na política econômica sobre títulos ou curvas de juros de outros países. Contudo, o foco destes esteve em avaliar o grau de conectividade entre as curvas dos países, medida através do indicador de *spillover* entre países de Diebold e Yilmaz (2012), e não em avaliar o *spillover* da incerteza enquanto fator de risco para a precificação em curvas estrangeiras.

Umar et al. (2021), Umar, Riaz e Zaremba (2021) e Umar, Riaz e Aharon (2022) investigaram a conectividade entre os movimentos dos retornos dos títulos na estrutura a termo (capturados pelos fatores latentes de um DNSM) e dos níveis de sentimento dos mercados (capturado por um indicador de cobertura de notícias). Complementarmente, eles avaliaram os graus de *spillover* na volatilidade dessas variáveis (uma *proxy* para incerteza), mas o objetivo não foi mensurar o impacto da incerteza sobre as curvas. Umar et al. (2021) avaliaram o período de pandemia da Covid-19 e constataram que o mercado de títulos americano foi menos vulnerável e mais resiliente a mudanças no sentimento de mercado do que os países emergentes (no agregado). Ainda, notaram um aumento significativo na conectividade das variáveis e das volatilidades entre os mercados durante a pandemia, onde o mercado americano foi receptor líquido de choques enquanto os mercados emergentes foram transmissores líquidos. Umar, Riaz e Zaremba (2021) analisaram a dinâmica da curva de rendimentos de curto, médio e longo prazo de 11 economias da zona euro, seis países centrais (Alemanha, Holanda, Finlândia, Áustria, Bélgica, França) e cinco países

periféricos (Grécia, Irlanda, Itália, Portugal e Espanha), de 2000 a 2020. Eles constataram três fases distintas, a de maior conectividade entre os países se encerrou com a crise financeira mundial em 2008, passando para os níveis mais baixos durante a crise da dívida europeia e voltando a níveis mais altos após esta. Ainda, verificaram que os países centrais foram transmissores líquidos de *spillover*, enquanto os países periféricos foram receptores líquidos de *spillover* para os três componentes da curva de juros. Por sua vez, [Umar, Riaz e Aharon \(2022\)](#) investigaram a conectividade entre as curvas dos países no G7. Na análise estática, constataram um aumento da conectividade no longo prazo em comparação com os fatores de médio e curto prazo. Já na análise dinâmica, identificaram três fases distintas quanto a conectividade: estabilidade até a crise de 2008, queda durante a crise e crescimento após esta.

Um pouco mais alinhado à proposta desta tese, tanto [Benlagha e Hemrit \(2022\)](#) quanto [Karanasos, Yfanti e Hunter \(2022\)](#) adotaram o EPU para mensurar a incerteza na política econômica. Em particular, assim como os trabalhos supracitados, [Benlagha e Hemrit \(2022\)](#) utilizaram o indicador de *spillover* entre países de [Diebold e Yilmaz \(2012\)](#) para avaliar a conectividade dos títulos soberanos dos países no G7, de 2015 a 2019. Seus resultados sugerem que o EPU é um canal que exacerba a transmissão de choques entre os rendimentos dos títulos de dois anos dos países. Por outro lado, no geral, a EPU não pareceu afetar a conexão dos rendimentos dos títulos de trinta anos em vários mercados.

Por fim, [Creal e Wu \(2017\)](#) averiguaram que a curva de juros americana por si só é um dos canais de transmissão de variações temporais da incerteza na política econômica desse país. Dessa forma, uma conjuntura imediata é que o co-movimento entre a curva americana e a curva brasileira constatado por [Stona e Caldeira \(2019\)](#) e [Cavaca e Meurer \(2021\)](#) se deve, em parte, às variações da incerteza na política econômica dos EUA.

3 METODOLOGIA

3.1 Caracterização da pesquisa

Considerando o objetivo desta tese, de explicar como a dinâmica da curva de juros brasileira é influenciada pelas variações de incerteza na política econômica do Brasil e na dos Estados Unidos, a pesquisa classificar-se-á como descritiva. As pesquisas descritivas têm como objetivo “a descrição das características de determinada população, fenômeno ou estabelecimento de relações entre variáveis” (GIL, 2008, p. 44).

Em relação aos procedimentos adotados, a pesquisa classifica-se como *ex-post-facto* e documental. As pesquisas documentais são aquelas em que as evidências são coletadas em fontes não bibliográficas, tais como relatórios, pareceres, tabelas estatísticas, etc (RAUPP; BEUREN, 2006). No que se refere à abordagem do problema, a pesquisa classifica-se como quantitativa. Pesquisas quantitativas são aquelas em que os dados serão analisados utilizando-se técnicas matemáticas ou estatísticas (MALHOTRA, 2019).

3.2 Fontes de dados e variáveis

Os dados analisados são secundários e, em sua maioria, de acesso público. Eles foram coletados em fontes *online* como: o [Market Data](#) da B³, o [Data Download Program](#) do FED, o [Sistema Gerenciador de Séries Temporais](#) do Bacen, o [Sistema Expectativas de Mercado](#) do Bacen, no [SIDRA](#) do IBGE, o sítio da [CNI](#) (Confederação Nacional da Indústria), o sítio do [IBRE/FGV](#), o sítio do [IPEA](#) (Instituto de Pesquisa Econômica Aplicada) e o [FRED](#) do FED de St Louis.

Devido à frequência dos dados macroeconômicos, todos os dados coletado seguiram a periodicidade mensal. Para tanto, consideraram-se as curvas de juros e as expectativas macroeconômicas diárias em seus fechamentos mensais. Como um dos objetivos é confrontar os resultados para a curva de Swap DI \times Pré com os para a ETTJ, foi utilizado o mesmo período amostral em ambas análises. Dado que a ETTJ disponibilizada compreendeu o intervalo de fevereiro de 2010 a junho de 2022, todos os dados analisados compreenderam essa janela amostral, totalizando 149 observações.

As tabelas 1 e 2 elencam as variáveis abordadas nesta tese. Retomando o Referencial Teórico (seções 2.3 e 2.4), essa tabela também lista estudos que utilizaram alguma *proxy* das respectivas variáveis. Em particular, algumas destas são usualmente avaliadas em nível como em [Diebold, Rudebusch e Aruoba \(2006\)](#), [Hamilton e Wu \(2012b\)](#) e [Bauer e Hamilton \(2018\)](#), mesmo quando não são estacionárias. Ao associar variáveis estacionárias

com não estacionárias, a literatura macro-financeira tem priorizado a interpretação da relação entre as variáveis. Adicionalmente, combinações de variáveis macroeconômicas geralmente são cointegráveis, como as utilizadas nesta tese, e, conforme demonstrado em Sims (1980), a utilização das variáveis no nível tem a vantagem de capturar a dinâmica de longo prazo entre elas.

Tabela 1 – Variáveis dependentes

Variável	Proxy(ies)	Estudos relacionados
Curva de juros	Y_t, L_t, S_t e C_t	Ang e Piazzesi (2003), Diebold, Rudebusch e Aruoba (2006), Leite et al. (2009), Bikbov e Chernov (2010), Matsumura, Moreira e Vicente (2011), Hamilton e Wu (2012b), Joslin, Le e Singleton (2013), Joslin, Priebsch e Singleton (2014), Ullah (2016), Bauer e Rudebusch (2017), Creal e Wu (2017), Bauer e Hamilton (2018), Stona e Caldeira (2019) e Cavaca e Meurer (2021).
Spreads e Excessos de Retorno	$sp_t(\tau)$ e $rx_{t,t+12}(\tau)$	Greenwood e Vayanos (2014), Marçal e Marinho (2014), Bauer e Rudebusch (2017), Bauer e Hamilton (2018), Ferreira (2022), Ioannidis e Ka (2021) e Santana (2022).

Fonte: elaboração própria.

Na Tabela 1, constam dois grupos de variáveis:

i) As relacionadas aos DTSMs em si:

- O vetor de taxas $Y_t = [y_{1,t} \dots y_{n,t}]'$ com n vértices da curva de juros brasileira, em cada período t ; e
- As três primeiras componentes principais da curva no período t : L_t (nível), S_t (inclinação) e C_t (curvatura).

ii) Os *spreads* e os excessos de retorno da curva brasileira frente a taxa de 12 meses ($y_{12,t}$, um ano), $rx_{t,t+12}(\tau)$.

As variáveis dependentes foram estimadas para duas curvas de juros brasileiras, a curva de *Swap* DI \times Pré da B³ e a Estrutura a Termo da Taxa de Juros dos títulos sobreanos estimados e cedidos pela ANBIMA, doravante, ETTJ. O contrato de DI é um dos maiores mercados de renda fixa entre as economias emergentes. Como revisado na seção 2.1, a curva de *Swap* DI \times Pré tem sido amplamente utilizada em estudos acerca do mercado

brasileiro como [Marçal e Marinho \(2014\)](#), [Matsumura e Moreira \(2015\)](#) e [Stona e Caldeira \(2019\)](#), por apresentar maior liquidez nos vértices, especialmente nos mais longos. Por outro lado, as teorias macro-financeiras são postuladas para a curva de títulos soberanos, que, no caso brasileiro, é a ETTJ. Por isso, tanto Y_t e suas componentes principais (L_t , S_t e C_t) quanto $sp_t(\tau)$ e $rx_{t,t+12}(\tau)$ consideraram as duas curvas de juros.

A curva de *Swap* DI \times Pré é disponibilizada no [Market Data](#) da B³. De acordo com o [manual de curvas da B³](#), sua construção é feita a partir dos preços de ajustes dos vencimentos do Contrato Futuro de Taxa Média de Depósitos Interfinanceiros de Um Dia (DI1) negociados na B³, através da interpolação *Flat Forward* 252. Os vencimentos utilizados para análise foram de os 1, 3, 6, 12, 18, 21, 24, 27, 30, 33, 36, 48, 60, 96 e 120 meses na curva de dias úteis, totalizando 15 vértices da curva a cada mês t . Por conseguinte, os rendimentos dos respectivos vértices no momento t foram contemplados no vetor $Y_{BR,t} = [y_{1,t} \ y_{3,t} \ y_{6,t} \ \dots \ y_{120,t}]'$. Ainda, como variáveis dependentes (Tabela 1), também foram utilizadas variáveis derivadas desta curva, como as três primeiras componentes principais ($L_{BR,t}$, $S_{BR,t}$ e $C_{BR,t}$), além dos *spreads* e dos excessos de retorno (de 12 meses), definidos por, respectivamente,

$$\begin{aligned} sp_t(\tau) &= y_{BR,t}(\tau) - y_{BR,t}(12), \text{ e} \\ rx_{BR,t,t+12}(\tau) &= [\tau \times y_{BR,t}(\tau) - (\tau - 12) \times y_{BR,t+12}(\tau - 12)] - 12 * y_{BR,t}(1), \end{aligned} \tag{3.1}$$

para $\tau = 24, 36, 48$ e 60 meses.

Por sua vez, as ETTJs (mensais) utilizadas foram calculadas e cedidas pela AN-BIMA. Essas curvas foram interpoladas utilizando o modelo de [Svensson e Lachman \(1994\)](#), apresentado na subseção 2.1.2.2. Os vencimento adotados foram 1, 3, 6, 12, 18, 24, 30, 36, 42, 48, 54, 60, 72, 84 e 96 para a curva nominal, totalizando 15 vértices. Os rendimentos em cada vértice da ETTJ no momento t foram contemplados no vetor $Y_{BRn,t} = [y_{1,t} \ y_{3,t} \ y_{6,t} \ \dots \ y_{96,t}]'$. De forma similar aos procedimentos para a curva de *Swap* DI \times Pré, para a ETTJ também foram avaliadas as três primeiras componentes principais ($L_{BRn,t}$, $S_{BRn,t}$ e $C_{BRn,t}$), os *spreads* $sp(\tau)_{BRn}$ e o excesso de retorno $rx_{BRn,t,t+12}(\tau)$, conforme a equação (3.1).

Tabela 2 – Variáveis independentes

Variável	Proxy(ies)	Estudos relacionados
Fatores latentes (domésticos)	L_t, S_t e C_t	Ang e Piazzesi (2003) , Diebold, Rudebusch e Aruoba (2006) , Bikbov e Chernov (2010) , Hamilton e Wu (2012b) , Joslin, Le e Singleton (2013) , Joslin, Priebsch e Singleton (2014) , Bauer e Rudebusch (2017) , Creal e Wu (2017) , Bauer e Hamilton (2018) e Stona e Caldeira (2019) .

Fatores latentes adicionais	$PC_{4,t}$ e $PC_{5,t}$	Cochrane e Piazzesi (2005) e Bauer e Hamilton (2018).
Atividade econômica	UCI_t	Diebold, Rudebusch e Aruoba (2006), Bikbov e Chernov (2010), Matsumura, Moreira e Vicente (2011), Hamilton e Wu (2012b), Bauer e Rudebusch (2017), Creal e Wu (2017), Bauer e Hamilton (2018) e Stona e Caldeira (2019).
Crescimento econômico	CRE_t	Ang e Piazzesi (2003), Joslin, Le e Singleton (2013), Joslin, Priebisch e Singleton (2014), Marçal e Marinho (2014), Stona et al. (2015), Ullah (2016), Bauer e Rudebusch (2017), Bauer e Hamilton (2018), Andreotti Filho (2021) e Santana (2022).
Expectativa de inflação	$EINF_t$	Pinheiro, Almeida e Vicente (2007), Leite et al. (2009), Joslin, Priebisch e Singleton (2014), Marçal e Marinho (2014), Matsumura e Moreira (2015), Bauer e Rudebusch (2017), Bauer e Hamilton (2018), Reis (2018) e Santana (2022).
Inflação	INF_t	Ang e Piazzesi (2003), Diebold, Rudebusch e Aruoba (2006), Bikbov e Chernov (2010), Matsumura, Moreira e Vicente (2011), Hamilton e Wu (2012b), Joslin, Le e Singleton (2013), Stona et al. (2015), Ullah (2016), Bauer e Rudebusch (2017), Creal e Wu (2017), Bauer e Hamilton (2018), Figueiredo (2018), Stona e Caldeira (2019) e Andreotti Filho (2021).
Câmbio	CAM_t	Matsumura e Moreira (2015), Ullah (2016), Figueiredo (2018), Reis (2018) e Stona e Caldeira (2019).
Dívida pública	DIV_t	Andreotti Filho (2021), Ferreira (2022) e Santana (2022).
<i>Duration</i>	DUR_t	Greenwood e Vayanos (2014), Marçal e Marinho (2014), Bauer e Hamilton (2018), Ferreira (2022) e Santana (2022).
Fatores latentes de outras curvas	$L_{j,t}$, $S_{j,t}$ e $C_{j,t}$	Stona e Caldeira (2019) e Cavaca e Meurer (2021).

Incerteza (BR)	IIE_t	Barboza e Zilberman (2018), Souza, Zabot e Caetano (2019) Marschner e Ceretta (2021) e Souza, Batista e Cunha (2022).
	$EMBI_t$	Pinheiro, Almeida e Vicente (2007) e Figueiredo (2018).
Incerteza (US)	EPU_t	Tillmann (2020), Ioannidis e Ka (2021) e Leippold e Matthys (2022)
	VIX_t	Matsumura e Moreira (2015), Figueiredo (2018) e Leippold e Matthys (2022).

Fonte: elaboração própria.

Na Tabela 2, o primeiro grupo de variáveis são os fatores latentes L_t , S_t e C_t derivados da respectiva curva, a de *Swap* DI \times Pré ou a ETTJ. Elas são dominantes na literatura sobre dinâmica da curva de juros, sendo utilizadas ao menos como variável de controle. Adicionalmente, também foi testado o poder explicativo da quarta e da quinta componente principal da respectiva curva, $PC_{4,t}$ e $PC_{5,t}$.

Em relação às variáveis macroeconômicas, foram utilizadas *proxies* para as metas das autoridades monetárias. De forma abrangente, elas buscam controlar a inflação e, concomitantemente, estimular a atividade econômica e o emprego, em linha com a regra de Taylor. Com base na revisão na seção 2.3.1, foram utilizadas as seguintes *proxies*:

UCI_t - A Utilização da Capacidade Instalada da indústria de transformação (em termos percentuais, dessazonalizada), produzida e disponibilizada pela CNI (Confederação Nacional da Indústria).

CRE_t - A variação anual do Índice de Atividade Econômica do Banco Central - Brasil (IBC-Br), produzido pelo Bacen como *proxy* para as variações mensais na atividade econômica;

$EINF_t$ - A expectativa de IPCA para o horizonte (móvel) de um ano, no fechamento do mês, disponibilizada pelo sistema de expectativas do Bacen;

INF_t - A variação anual do IPCA, índice produzido pelo IBGE e adotado oficialmente como indicador para a meta inflacionária do Bacen.

Mais alinhados à literatura empírica de política monetária, trabalhos como Matsumura, Moreira e Vicente (2011) utilizaram o hiato do produto estimado via filtro HP como *proxy* do nível da atividade econômica. Todavia, essa metodologia tem sido questionada desde Hamilton (2018), e, por isso, utilizou-se a UCI como *proxy* de nível da atividade econômica. Ainda, pela lei de Okun (em Okun (1963)), a atividade econômica e o desemprego possuem relação direta, sendo fortemente correlacionadas. Apesar da maior parte da literatura

sobre a curva americana adotar a taxa de desemprego, essa variável não se encontra continuamente disponível para o Brasil durante o período amostral avaliado. Em síntese, há duas séries oficiais de desemprego no Brasil, a Pesquisa Mensal de Emprego (PME) e a Pesquisa Nacional por Amostra de Domicílios (PNAD) Contínua, ambas produzidas pelo IBGE. A primeira foi encerrada após a adoção da segunda e possui abrangência e metodologia distintas. Consequentemente, o período disponível para a PME se encerra em março de 2016 enquanto a PNAD Contínua tem início no primeiro trimestre (móvel) de 2012. Por isso, *proxies* de nível ou de crescimento baseados em medidas de desemprego geralmente não são utilizados no Brasil. No caso da *proxy* para o crescimento, a alternativa mais usual tem sido a variação do IBC e, alternativamente, a da Produção Industrial Mensal estimada pelo IBGE.

Não obstante, além da meta inflacionária, o Copom também leva em conta a atividade econômica, o cenário externo e as contas públicas para suas decisões. Consequentemente, trabalhos como [Matsumura e Moreira \(2015\)](#), [Bauer e Hamilton \(2018\)](#), [Stona e Caldeira \(2019\)](#) e [Andreotti Filho \(2021\)](#) também consideram outras variáveis macroeconômicas para avaliar o mercado brasileiro, além da atividade econômica e a inflação. Por conseguinte, adotaram-se:

CAM_t - A variação mensal da taxa de câmbio do dólar americano (nos fechamentos de cada mês), fornecida pelo [Bacen](#).

DIV_t - A Dívida Líquida do Setor Público (governo federal) em percentual do PIB, estimada e disponibilizada pelo [Bacen](#).

Por sua vez, conforme a discussão nas subseções [2.3.2](#) e [2.3.3](#), também foram consideradas como variáveis explicativas:

DUR_t - O logaritmo da *Duration* da carteira de títulos do governo, calculada e disponibilizada pelo [Bacen](#); e

$L_{EUA,t}$, $S_{EUA,t}$ e $C_{EUA,t}$ - As três primeiras componentes principais extraídas da ETTJ americana (similar a [Stona e Caldeira \(2019\)](#) e [Cavaca e Meurer \(2021\)](#)).

Mais especificamente, para estimar L_{EUA} , S_{EUA} e C_{EUA} , utilizou-se a ETTJ do *U.S. Department of the Treasury*, atualmente calculada pela interpolação convexa (dos rendimentos de entrada), disponibilizada pelo [Data Download Program](#) do FED - a autoridade monetária americana. Ainda, os vencimentos adotados foram 1, 3, 6, 12, 24, 36, 60, 84, 120 e 240 meses (10 vértices). Os rendimentos de cada vértice da ETTJ americana no momento t são contemplados no vetor $Y_{EUA,t} = [y_{1,t} \ y_{3,t} \ y_{6,t} \ \dots \ y_{240,t}]'$.

Por fim, as *proxies* utilizadas para incerteza na política econômica são:

- Brasil:

IIE_t - O logaritmo do Índice de Incerteza da Economia - Brasil (IIE-Br) mensal, desenvolvido e disponibilizado pelo [IBRE/FGV](#);

$EMBI_t$ - O logaritmo do *Emerging Markets Bond Index Plus* mensal para o Brasil, calculado pelo banco de investimento JP Morgan e disponibilizado pelo Instituto de Pesquisa Econômica Aplicada ([IPEA](#));

- Estados Unidos:

EPU_t - O logaritmo do *Economic Policy Uncertainty* desenvolvido por [Baker, Bloom e Davis \(2016\)](#) mensal, medido para os Estados Unidos, disponível no domínio [<https://www.policyuncertainty.com/>](https://www.policyuncertainty.com/);

VIX_t - O *Volatility Index* no fechamento do mês, computado pelo Chicago Board Options Exchange (CBOE) e disponibilizado no [FRED](#) (sistema de dados econômicos do FED de St Louis).

Conforme a seção 2.4, os indicadores compostos como o IIE-BR e o EPU são mais adequados enquanto *proxies* da incerteza na política econômica. Eles têm sido continuamente atualizados¹ e, em particular, o EPU tem sido utilizado em uma série de trabalhos acadêmicos, tornando-o a principal referência nessa temática, inclusive em trabalhos de *spillover* da incerteza entre países (subseção 2.4.2). Todavia, o EPU calculado para o Brasil se restringe à componente de volume de notícias que discutem a incerteza na política econômica, considerando apenas em matérias publicadas no jornal Folha de São Paulo. Como o IIE-Br segue uma metodologia similar ao EPU completo (medido para os Estados Unidos), ele foi escolhido como *proxy* de incerteza para o Brasil. Não obstante, apesar do crescente uso do IIE-Br como *proxy* da incerteza, não foi encontrado estudo que o relaciona a modelagem da curva de juros brasileira - os demais na Tabela 2 tratam de impactos da incerteza em outros contextos. Também não foram encontrados estudos relacionando efeitos das oscilações no EPU americano sobre o mercado brasileiro. Por fim, como o EMBI+ Br e o VIX também são utilizados como *proxies* de incerteza, eles foram adotados de forma complementar aos dois primeiros.

3.3 Procedimentos econométricos

O objetivo geral desta tese foi explicar como a dinâmica da curva de juros brasileira é influenciada pelas variações de incerteza na política econômica do Brasil e na dos Estados Unidos. Para tanto, o primeiro passo foi estimar os fatores latentes (componentes principais)

¹ O que não ocorre com o MPU de [Husted, Rogers e Sun \(2019\)](#), um indicador alternativo ao EPU, também muito explorado na literatura.

e as medidas de *spread* e de excesso de retorno, descritas na seção 3.2, seguido pelas estatísticas descritivas das variáveis analisadas. Na sequência, foram realizados uma série de procedimentos alinhados aos objetivos, geral e específicos.

Visando verificar a robustez dos resultados, todos os procedimentos foram aplicados para a curva de *Swap* DI \times Pré e para a ETTJ. Para apurar a usual hipótese implícita na literatura quanto à aderência entre essas curvas, previamente, a conectividade e os efeitos de *spillover* entre elas foram avaliados conforme os procedimentos descritos na subseção 3.3.1. Em seguida, os efeitos de *spillovers* da curva e da incerteza americana sobre a curva e a incerteza brasileira foram explorados pela metodologia descrita na subseção 3.3.2. Isto posto, a subseção 3.3.3 apresenta as técnicas adotadas para as primeiras análises acerca do impacto da incerteza na política econômica, brasileira e americana, sobre a dinâmica da curva brasileira. A subseção 3.3.4 descreve os procedimentos de *stepwise* utilizados para selecionar as variáveis explicativas significativas dentre a gama identificada na literatura, elencadas na seção 3.2. Por testar a manutenção dos indicadores de incerteza na política econômica, os procedimentos de *stepwise* complementam a análise da relevância dos indicadores de incerteza ao controlá-los por um conjunto maior de variáveis explicativas. Por fim, a subseção 3.3.5 conclui os procedimentos de análise econométrica, apresentando a metodologia de estimação e avaliação de ganho informacional ao se considerar indicadores de incerteza em DTSMs.

O foco desta tese está no impacto dos indicadores de incerteza sobre a modelagem da curva de juros, o que ocorre através de modelos como o DTSM, na subseção 3.3.5. Não obstante, DTSMs abarcam uma quantidade grande de parâmetros e a amostra de dados é curta, limitando a capacidade de avaliar o impacto informacional em DTSMs com um número alto de fatores de risco - com mais de cinco fatores, o algoritmo de otimização pode não convergir. Nesse sentido, as regressões em 3.3.3 e em 3.3.4, recorrentes na literatura, auxiliam a análise não só por fornecer a significância das variáveis individualmente mas também por permitir a inclusão de um número maior de fatores de risco. Ainda na subseção 3.3.3, destaca-se que, como demonstrado em Joslin, Singleton e Zhu (2011), os VARs estimados não são afetados pela restrição de não arbitragem que os DTSMs adicionam a estes e, portanto, os resultados para as propagações nos fatores de risco são essencialmente os mesmos que seriam dentro de um DTSM. Ainda, as subseções 3.3.1 e 3.3.2 não fornecem análises prévias para a análise do impacto da incerteza sobre a curva de juros, foco da tese, como também fornecem análises complementares à literatura, avaliando os *spillovers* entre curvas e dos indicadores de incerteza.

3.3.1 Integração entre a curva de *Swap* DI \times Pré e a ETTJ

Uma vez que os fatores latentes L_i , S_i e C_i descrevem a forma funcional da curva i , a análise do alinhamento entre a curva de *Swap* DI \times Pré e a ETTJ iniciou-se com o estudo

das correlações entre esses fatores. Ainda, como as componentes principais sintetizam o conteúdo informacional das respectivas curvas, essa análise também considerou a quarta e a quinta componente principal para esta investigação.

O alinhamento contemporâneo entre as curvas é dado por correlações contemporâneas. Todavia, assim como choques nos fatores latentes afetam a forma funcional futura da sua curva de juros, esses choques podem transbordar para outras curvas cujos mercados possuam algum grau de integração. Visando avaliar a possibilidade de *spillovers* de uma curva sobre a outra, foram avaliadas medidas de conectividade e de *spillover* variantes dos indicadores de *spillover* desenvolvidos por Diebold e Yilmaz (2009) e Diebold e Yilmaz (2012). Estes foram originalmente aplicados para avaliar transmissões entre mercados acionários e, posteriormente, adaptados para avaliar curvas de juros em estudos como Cavaca e Meurer (2021), Umar, Riaz e Zaremba (2021) e Umar, Riaz e Aharon (2022) - conforme a revisão na seção 2.3.3.

O ponto de partida para o cálculo desses indicadores é estimar o VAR (de ordem p) sobre os fatores de risco $L_{j,t}$, $S_{j,t}$, $C_{j,t}$ da curva $j \in \{BR, BRn\}$ mais os fatores $L_{i,t}$, $S_{i,t}$, $C_{i,t}$ da curva i complementar, ou seja,

$$X_t = \sum_{n=1}^p K_n X_{t-1} + \epsilon_t, \quad (3.2)$$

com $X_t = [L_{j,t} \ S_{j,t} \ C_{j,t} \ L_{i,t} \ S_{i,t} \ C_{i,t}]'$, com resíduos iid $\epsilon \sim N(0, \Sigma)$.

É válido sublinhar que nem todas as componentes principais são estacionárias, impactando a estimação do VAR. Todavia, assim como proposto desde Sims (1980) e Sims, Stock e Watson (1990), o VAR é fundamentalmente uma metodologia de inter-relações entre variáveis. Por isso, a literatura macro-financeira tem adotado misturas de variáveis estacionárias com não estacionárias, dando prioridade à interpretação e reduzindo a análise aos efeitos de choques, via Função de Resposta ao Impulso (*Impulse Response Function*, IRF) ou Decomposição da Variância do Erro de Previsão. Não obstante, para todos os VARs estimados nesta tese, foram verificadas as hipóteses de normalidade (teste de Jarque-Bera), correlação serial dos resíduos (teste de Breusch-Godfrey) e de heterocedasticidade (teste ARCH (*Autoregressive Conditional Heteroscedastic*)). Por sua vez, como o histórico de dados é pequeno, o critério de Akaike (AIC) foi adotado para definir o número de defasagens dos VARs.

A partir do VAR estimado em (3.2), calculou-se a decomposição generalizada da variância do erro de previsão de Pesaran e Shin (1998), em que o H -ésimo passo a frente entre as variáveis $i, j \in X_t$ é fornecido por

$$\Psi_{i,j}^H = \frac{\sigma_{jj}^{-1} \sum_{h=0}^{H-1} (e_i' A_h \Sigma e_j)^2}{\sum_{h=0}^{H-1} (e_i' A_h \Sigma A_h' e_j)}, \quad (3.3)$$

onde Σ é a matriz de covariância do vetor de erros ϵ_t , σ_{jj} é o j -ésimo elemento diagonal de Σ e e_j é um vetor de seleção com j -ésimo elemento igual a 1 e, nos demais elementos,

igual a 0. $\Psi_{i,j}^H$ representa a contribuição dos choques na variável x_j à variância de x_i em H -passos. Para garantir que a soma das N contribuições à x_i seja igual a 1, adotou-se a normalização

$$\tilde{\Psi}_{i,j}^H = \frac{\Psi_{i,j}^H}{\sum_{j=1}^N \Psi_{i,j}^H}. \quad (3.4)$$

Diebold e Yilmaz (2009) e Diebold e Yilmaz (2012) fixaram $H = 10$ e propuseram uma série de medidas de conectividade a partir de $\tilde{\Psi}_{i,j}^H$, tais como:

$$Tr_{ij}^H = \tilde{\Psi}_{ij}^H - \tilde{\Psi}_{j,i}^H, \text{ o } spillover \text{ líquido entre } i \text{ e } j;$$

$$Tr_{i\leftarrow\bullet}^H = \sum_{j=1}^N \tilde{\Psi}_{i,j}^H, \text{ o } spillover \text{ total para } i;$$

$$Tr_{i\rightarrow\bullet}^H = \sum_{j=1}^N \tilde{\Psi}_{j,i}^H, \text{ o } spillover \text{ total de } i;$$

$$Tr_i^H = Tr_{i\leftarrow\bullet}^H - Tr_{i\rightarrow\bullet}^H, \text{ o } spillover \text{ líquido de } i; \text{ e, em especial,}$$

$$Tr^H = \frac{1}{N} \sum_{i,j=1}^N \tilde{\Psi}_{i,j}^H, \text{ a conectividade total.}$$

Nesta tese, foi utilizado o *spillover* líquido Tr_{ij}^H para identificar, para cada um dos fatores correspondentes (L_i e L_j , S_i e S_j , e C_i e C_j), o de qual curva é transmissor líquido e qual é receptor líquido de choques. Além deste, foram adaptadas duas medidas:

$$Trp_{i\leftarrow\bullet}^H = \sum_{j=1}^n \tilde{\Psi}_{i,j}^H, \text{ o } spillover \text{ parcial para o fator } i \text{ oriundo dos } n \text{ fatores da outra curva; e}$$

$$Tra^H = \frac{1}{N} \sum_{i,j=1}^N \tilde{\Psi}_{i,j}^H, \text{ a conectividade total ajustada, com apenas os } spillovers \text{ em } L_i, S_i, C_i \in Y \text{ oriundos da curva complementar via } L_j, S_j, C_j \in Y^c.$$

3.3.2 Spillovers de choques americanos

Por si só, avaliar os *spillovers* de choques na curva e na incerteza americana sobre a curva brasileira já é um problema de pesquisa relevante. Em uma tese na qual se confrontam efeitos da incerteza doméstica e da estrangeira sobre a curva de juros nacional, isso é essencial. Parte dos choques nos indicadores de incerteza domésticos pode decorrer da propagação de choques oriundos do exterior. Logo, os choques de incerteza que ditam a dinâmica da curva de juros podem ter sua origem no exterior, ainda que o efeito atual seja relacionado à incerteza no país.

Para tanto, foram avaliados os fatores latentes L , S e C da curva brasileira e os da curva americana, os indicadores *IIE* como *proxy* da incerteza na política econômica brasileira e *EPU* como da americana, além de *CAM* como variável de controle. Em síntese, foram avaliadas as correlações entre essas variáveis, medidas de *spillover* sobre a curva brasileira e as IRFs sobre os fatores latentes da curva brasileira. Assim como nas demais

análises econométricas, concomitantemente foram avaliadas a curva de *Swap* DI \times Pré e sobre a ETTJ enquanto curva de juros brasileira. Para tanto, após a análise das correlações, foram estimados três modelos de VAR para cada uma das duas curvas brasileiras, conforme a equação 3.2:

- um VAR(p) considerando apenas os fatores latentes da curva americana e da brasileira e, como controle, o câmbio - *i.e.*, $X_t = [L_{i,t} \ S_{i,t} \ C_{i,t} \ CAM_t \ L_{EUA,t} \ S_{EUA,t} \ C_{EUA,t}]'$ para $i = BR, BRn$;
- um VAR(p) considerando os fatores latentes da curva americana e da brasileira, além de *IIE*, e, como controle, o câmbio - portanto, $X_t = [L_{i,t} \ S_{i,t} \ C_{i,t} \ CAM_t \ IIE_t \ L_{EUA,t} \ S_{EUA,t} \ C_{EUA,t}]'$ para $i = BR, BRn$; e
- um VAR(p) considerando os fatores latentes da curva americana e da brasileira, com *IIE* e *EPU*, e, como controle, o câmbio - logo, $X_t = [L_{i,t} \ S_{i,t} \ C_{i,t} \ CAM_t \ IIE_t \ L_{EUA,t} \ S_{EUA,t} \ C_{EUA,t} \ EPU_t]'$ para $i = BR, BRn$;

Assim como nos demais VARs estimados, o foco está na interpretação das variáveis, sem diferenciar as não estacionárias. Além disso, como o Brasil é uma economia aberta e pequena, choques brasileiros não devem impactar uma grande economia como a americana. Por isso, foram inseridas restrições aos VARs estimados, fixando os coeficientes que relacionam (diretamente) as variáveis brasileiras às americanas como sendo iguais a zero.

Por conseguinte, para avaliar os *spillovers* de choques na curva e na incerteza americana sobre a curva brasileira, recorreu-se às medidas de *spillover* de Diebold e Yilmaz (2009) e Diebold e Yilmaz (2012), de forma similar aos procedimentos na subseção 3.3.1. A análise de *spillover* recorreu às medidas de: i) *spillover* simples $\tilde{\Psi}_{i,j}^H$, para os choques provenientes da incerteza; e ii) *spillover* parcial $Trp_{i\leftarrow\bullet}^H$. Dessa forma, essa tese complementou a análise de Cavaca e Meurer (2021) ao considerar outras variáveis além dos fatores latentes na curva. Mais especificamente, os indicadores de incerteza e o câmbio, equalizador dos movimentos entre o mercado americano e o brasileiro.

Por fim, a análise de *spillovers* foi complementada através da avaliação das IRFs no último modelo - mais completo -, considerando respostas dos fatores latentes brasileiros a choques nos fatores latentes americanos e nos indicadores de incerteza.

3.3.3 Incerteza na política econômica e curva de juros brasileira

Para uma primeira análise acerca do impacto dos indicadores de incerteza na política econômica (*IIE* (brasileira) e *EPU* (americano)) sobre a curva juros, foram implementados testes simples, mas recorrentes na literatura. São estes:

- regressões do *spread* sp_t e regressões preditivas do excesso de retorno rx_t contra *IIE* e/ou *EPU*;
- IRFs de choques no indicador de incerteza sobre os fatores latentes L_t , S_t e C_t ; e
- IRFs de choques no indicador de incerteza sobre os fatores latentes controlados L_t , S_t e C_t por variáveis macroeconômicas.

Complementando a análise na subseção 3.3.1 e para verificar a robustez dos resultados, os procedimentos adotaram tanto a curva de *Swap* DI \times Pré quanto a ETTJ. Posteriormente, as subseções 3.3.4 e 3.3.5 complementam essa análise nesta subseção.

Para cada variável dependente, foram avaliadas três modelos de regressão:

$$\text{M1: } sp_t(\tau) = \beta_0 + \beta_1 Y12_t + \beta_2 CRE_t + \beta_3 INF_t + \beta_4 CAM_t + \beta_5 DIV_t + \beta_5 IIE_t + \eta_t;$$

$$\text{M2: } sp_t(\tau) = \beta_0 + \beta_1 CRE_t + \beta_2 INF_t + \beta_3 CAM_t + \beta_4 DIV_t + \beta_5 EPU_t + \eta_t;$$

$$\text{M3: } sp_t(\tau) = \beta_0 + \beta_1 CRE_t + \beta_2 INF_t + \beta_3 CAM_t + \beta_4 DIV_t + \beta_5 IIE_t + \beta_6 EPU_t + \eta_t;$$

e

$$\text{M1: } rx_{t;t+12}(\tau) = \beta_0 + \beta_1 L_t + \beta_2 S_t + \beta_3 C_t + \beta_4 IIE + \epsilon_{t+12};$$

$$\text{M2: } rx_{t;t+12}(\tau) = \beta_0 + \beta_1 L_t + \beta_2 S_t + \beta_3 C_t + \beta_4 EPU + \epsilon_{t+12};$$

$$\text{M3: } rx_{t;t+12}(\tau) = \beta_0 + \beta_1 L_t + \beta_2 S_t + \beta_3 C_t + \beta_4 IIE + \beta_5 EPU + \epsilon_{t+12}.$$

Mais precisamente, estimou-se uma regressão para cada horizonte $\tau = 24, 36, 48$ e 60 . Logo, considerando as duas curvas (*Swap* DI \times Pré e ETTJ) e para as três combinações de variáveis explicativas, foram estimadas um total de 24 regressões para o *spread* sp_t e 24 para o excesso de retorno rx_t). A interpretação para os dois grupos de regressões é distinta. Como sp_t é relacionado à inclinação da curva, a regressão desta avalia determinantes da combinação das expectativas de juros futuros com o prêmio de risco. Por isso, além de *IIE* e *EPU*, foram utilizadas as variáveis macroeconômicas *CRE*, *INF*, *CAM* e *DIV* como controle - que balizam a atuação do Bacen na curva de juros e as expectativas do mercado acerca do ambiente econômico. Por sua vez, como $rx_{t;t+12}$ é uma variável futura (em $t + 12$), a regressão desta analisa o poder preditivo das variáveis explicativas sobre o prêmio de risco. De forma generalizada na literatura, a adoção desta regressão recorre às três primeiras componentes principais da curva (L , S e C) como controle, avaliando, assim, se há conteúdo informacional adicional na variável em análise, além do já contido na própria curva de juros.

Apesar do uso recorrente das regressões preditivas de $rx_{t;t+12}$ na literatura, elas apresentam uma série de características problemáticas:

- i) Caso a hipótese de *spanning* seja verdadeira (subseção 2.2.1), os fatores latentes serão os únicos previsores do excesso de retorno. Nesse caso, por sintetizarem a informação da curva corrente, eles necessariamente serão correlacionados com defasagens de erros de previsão, violando a condição econométrica de exogeneidade estrita.
- ii) As variáveis preditivas (fatores latentes e exógenos) são tipicamente persistentes, exibindo, por vezes, tendência. Isso pode levar a vieses substanciais, especialmente em amostras pequenas - como as em estudos sobre o Brasil. Problema, este, presente, também, nas regressões de *spread* sp_t .
- iii) Usualmente, adota-se o excesso de retorno de um ano como variável dependente, mas com dados de frequência mensal. Isso gera sobreposição das observações, induzindo uma substancial correlação serial nos erros.

Por isso, a inferência dos coeficientes betas nessas duas classes de regressões foi realizada através do erro padrão de Newey-West (em Newey e West (1987)), estimado com 18 defasagens (conforme Cochrane e Piazzesi (2005) e Bauer e Hamilton (2018)), robusto à heterocedasticidade e autocorrelação serial. A necessidade de utilizar desvios padrão robustos foi confirmada pelo teste de Breusch-Pagan para a heterocedasticidade e pelo teste de Breusch-Godfrey para a correlação serial.

Assim como na de regressões, a análise de choques de incerteza sobre os fatores latentes da curva (L_t (nível), S_t (inclinação) e C_t (curvatura)) considerou três modelos de VAR(p):

M1: para $X_t = [L_t \ S_t \ C_t \ IIE_t]'$;

M2: para $X_t = [L_t \ S_t \ C_t \ EPU_t]'$; e

M3: para $X_t = [L_t \ S_t \ C_t \ IIE_t \ EPU_t]'$.

Como nos VARs anteriores, o foco está na interpretação das variáveis, o que perpassa pelos problemas econométricos citados na subseção 3.3.2. Sendo equivalente à equação de transição no DTSM (equação (2.24)), para fins comparativos, foram estimados VAR(1). Uma vez estimados os VARs, foram avaliadas as IRFs derivadas dos mesmos.

Bloom (2014) esclareceu que é difícil separar causa e efeito da incerteza, pois, mudanças no ambiente econômico podem causar incerteza assim como esta pode gerar mudanças no ambiente econômico. Portanto, alterações na incerteza podem ser um reflexo do quadro macro-financeiro, ao invés do oposto. Por isso, visando confrontar a segunda análise, também foram analisados os choques de incerteza controlados por variáveis macroeconômicas. De forma similar à anterior, foram adotados três modelos de VAR(p):

M1: para $X_t = [L_t \ S_t \ C_t \ CRE_t \ INF_t \ CAM_t \ DIV_t \ IIE_t]'$;

M2: para $X_t = [L_t \ S_t \ C_t \ CRE_t \ INF_t \ CAM_t \ DIV_t \ EPU_t]'$; e

M3: para $X_t = [L_t \ S_t \ C_t \ CRE_t \ INF_t \ CAM_t \ DIV_t \ IIE_t \ EPU_t]'$.

A partir destes modelos, avaliou-se as respectivas IRFs de choques no indicador de incerteza.

3.3.4 Poder explicativo com muitas variáveis independentes

O número crescente de fatores explicativos associados à dinâmica da curva de juros perpassa pela utilização de poucas variáveis de controle ao testá-los. Geralmente, a significância da variável (e a respectiva teoria de base) é verificada utilizando apenas os fatores latentes como controle. Um argumento poderoso é que os fatores latentes podem capturar (quase) todo o conteúdo informacional necessário para modelar a dinâmica da curva de juros. Contudo, esse número crescente de variáveis exógenas significativas (controlados pelos latentes) contestam esse argumento.

O objetivo desta tese aborda a dinâmica da curva de juros brasileira. Todavia, os DTSMs possuem muitos parâmetros, não sendo possível estimá-los com um número grande de fatores de risco em X . Por conseguinte, foi realizado um procedimento de *stepwise backward* para selecionar as variáveis exógenas quanto ao poder explicativo sobre a dinâmica da curva de juros. Cabe frisar que este procedimento não avalia a força de uma teoria, sendo apenas um processo básico de mineração de dados. Por outro lado, do ponto de vista prático da modelagem da curva de juros, essa abordagem auxilia a análise sobre o poder explicativo da incerteza, controlada por outras variáveis, avaliando se os indicadores correspondentes sobrevivem ao processo *stepwise*.

O *stepwise backward* avaliou regressões dos *spreads* $sp_t(\tau)$ e dos excessos de retorno $rx_{t,t+12}(\tau)$, definidas por:

$$sp_t(\tau) = \beta_0 + BX + \epsilon_t \text{ para } \tau = 24, 36, 48 \text{ e } 60. \quad (3.5)$$

$$rx_{t,t+12}(\tau) = \beta_0 + BX + \epsilon_{t+12} \text{ para } \tau = 24, 36, 48 \text{ e } 60. \quad (3.6)$$

onde:

X é o vetor de fatores de risco (na Tabela 2) que, em um primeiro momento, contempla:

para $sp_t(\tau)$: $X = \{L_{EUA}, S_{EUA}, C_{EUA}, UCI, CRE, EINF, INF, CAM, DIV, DUR, IIE, EMBI, EPU, VIX\}$; e

para $rx_{t,t+12}(\tau)$: $X = \{L_i, S_i, C_i, PC_{4i}, PC_{5i}, L_{EUA}, S_{EUA}, C_{EUA}, UCI, CRE, EINF, INF, CAM, DIV, DUR, IIE, EMBI, EPU, VIX\}$.

B é o vetor de coeficientes lineares para a n variáveis empregadas como fator de risco, contendo um β_i para cada $x_i \in X$.

Os procedimentos mais usais de *stepwise* selecionam variáveis de forma a maximizar a capacidade preditiva da regressão como um todo, considerando critérios como a Soma dos Quadrados dos Resíduos, o AIC, o BIC (Bayesiano de Schwarz) ou o R^2 ajustado. Entretanto, a meta nesta teste é avaliar a significância das variáveis testadas em ao aplicar controles previstos nas demais teorias de curva de juros. Por isso, o procedimento adotado foi baseado na significância estatística dos coeficientes. Em cada rodada do *stepwise backward*, foi retirada a variável de pior significância (média do p -valor do teste t) dentre as que não foram significativas em todas as quatro regressões - para $\tau = 24, 36, 48$ e 60 . O nível de significância considerado foi de $\alpha = 10\%$ e, devido aos problemas usais nessas regressões (ênfatisados na subseção 3.3.3), a inferência dos coeficientes foi realizada utilizando o erro padrão de Newey-West estimado com 18 defasagens, robusto à heterocedasticidade e autocorrelação serial. Para confirmar a necessidade do uso de desvios padrão robustos, a heterocedasticidade foi verificada pelo teste de Breusch-Pagan e a correlação serial foi avaliada pelo teste de Breusch-Godfrey.

Complementarmente, foram utilizados procedimentos de seleção de variáveis em cada regressão $sp_t(\tau)$ baseados na qualidade do ajuste do modelo de regressão. Nesta categoria, destaca-se o LASSO (*Least Absolute Shrinkage and Selection Operator*), desenvolvido por Tibshirani (1996). Ele consiste em um método de encolhimento da matriz de coeficientes (ou de regularização), capaz de selecionar variáveis. Para tanto, estima os coeficientes β ao minimizar a função

$$\sum_{i=1}^N \left(y_i - \beta_0 - \sum_{j=1}^M \beta_j x_j \right)^2 + \delta \sum_{j=1}^M |\beta_j| = RSS + \delta \sum_{j=1}^M |\beta_j|, \quad (3.7)$$

onde N é o número de observações, M é o número de variáveis explicativas, RSS é a Soma dos Quadrados dos Resíduos e $\delta \sum_{j=1}^M |\beta_j|$ é um termo de penalização². Quando λ é suficientemente grande, o algoritmo de estimação do LASSO força alguns coeficientes a serem exatamente iguais a zero, permitindo, assim, a exclusão de variáveis. Por outro lado, se $\delta = 0$, tem-se a estimação via MQO usual. Logo, a seleção de um valor adequado para δ é crítico. Para tanto, utiliza-se um procedimento de validação cruzada de k -fold, adotando $k = 10$ subconjuntos (*folds*). Por fim, o melhor δ é definido como aquele que gera os coeficiente de menor o erro quadrado médio.

Adicionalmente, como o LASSO pode performar mal em casos de correlações altas entre as variáveis independentes, também foi implementado uma variante deste, denominada Elastic Net. Este algoritmo, desenvolvido por Zou e Hastie (2005), supera o LASSO no que tange o problema de alta correlação entre as variáveis independentes ao mesclar o termo de penalização do LASSO com o de outro método de encolhimento de

² Ao invés de λ , a literatura relacionada ao LASSO utiliza o nomenclatura λ para o parâmetro de penalização. Todavia, devido ao foco na literatura de DTSM, onde λ é o preço do risco, esta tese utilizará a letra grega δ para tal parâmetro.

coeficientes, a regressão Ridge. Pontua-se que esta foi introduzida pela primeira vez em 1970, por [Hoerl e Kennard \(2000\)](#)), mas não é método, em si, capaz de selecionar variáveis. Em síntese, o Elastic Net estima os coeficientes β da regressão ao minimizar

$$\sum_{i=1}^N \left(y_i - \beta_0 - \sum_{j=1}^M \beta_j x_j \right)^2 + \delta \left[(1 - \alpha) \sum_{j=1}^M \beta_j^2 + \alpha \sum_{j=1}^M |\beta_j| \right]. \quad (3.8)$$

Nesta, tem-se o método Rigid se $\alpha = 0$, o LASSO se $\alpha = 1$ e o Elastic Net se $\alpha = 0,5$.

3.3.5 Impacto informacional de indicadores de incerteza em DTSMs

Para avaliar o impacto informacional de se incorporar indicadores de incerteza na política econômica como fatores de risco da curva de juros, foram realizados testes da razão de verossimilhança (LR) entre modelos de DTSM sem indicadores de incerteza (modelo restrito) e de DTSM com o um (ou os dois) indicador(es) de incerteza (modelo irrestrito). Mais especificamente, comparou-se a inclusão desses indicadores a partir de dois modelos bases:

- O modelo macro-financeiro usual, denominado M0, cujo vetor de fatores de risco é dado por $X_t = [L_t \ S_t \ C_t \ Z_t]'$. Neste, Z_t é um vetor de variáveis que refletem o quadro econômico brasileiro, a serem selecionadas a partir dos resultados observados para a seção 3.3.4. Este modelo base (M0) foi comparado a:

M1: para $X_t = [L_t \ S_t \ C_t \ Z_t \ IIE_t]'$;

M2: para $X_t = [L_t \ S_t \ Z_t \ EPU_t]'$; e

M3: para $X_t = [L_t \ S_t \ Z_t \ IIE_t \ EPU_t]'$;

- O modelo macro-financeiro usual, também denominado M0, mas cujo vetor de fatores de risco é dado por $X_t = [L_t \ S_t \ C_t \ L_{t,EUA} \ S_{t,EUA} \ C_{t,EUA}]'$, ou seja, controlando os efeitos de propagação derivados da curva de juros americana. Por sua vez, este modelo base (M0) foi comparado a:

M1: para $X_t = [L_t \ S_t \ C_t \ L_{t,EUA} \ S_{t,EUA} \ C_{t,EUA} \ IIE_t]'$;

M2: para $X_t = [L_t \ S_t \ C_t \ L_{t,EUA} \ S_{t,EUA} \ C_{t,EUA} \ EPU_t]'$; e

M3: para $X_t = [L_t \ S_t \ C_t \ L_{t,EUA} \ S_{t,EUA} \ C_{t,EUA} \ IIE_t \ EPU_t]'$.

Para estimar o DTSM, esta tese adotou o modelo de [Joslin, Le e Singleton \(2013\)](#), a versão macro-financeira de [Joslin, Singleton e Zhu \(2011\)](#) apresentada na seção 2.2. Ele foi escolhido por ser computacionalmente eficiente e impedir rotações entre os fatores de risco ao longo da estimação do DTSM. Em síntese, trata-se de um modelo dinâmico afim

com não arbitragem Gaussiano, representado por:

$$r_t = \rho_0 + \rho_1 X_t, \quad (3.9)$$

$$X_t = K_0 + K_1 X_{t-1} + \Sigma \epsilon_t \quad \epsilon_t \stackrel{iid}{\sim} N(0, I_N), \quad (3.10)$$

$$X_t = K_0^Q + K_1^Q X_{t-1} + \Sigma \epsilon_t^Q \quad \epsilon_t^Q \stackrel{iid}{\sim} N(0, I_N). \quad (3.11)$$

Como em [Joslin, Le e Singleton \(2013\)](#), o sistema em (3.9) foi estimado em duas etapas, nas quais, primeiramente, estimou-se (3.10) por MQO. A segunda etapa adotou o filtro de Kalman para maximizar a verossimilhança deduzida conjuntamente de (3.9), (3.10) e (3.11). Nesta, utilizou-se K_0 e K_1 como *input* e Σ como valor inicial na otimização. Ainda, a segunda etapa forneceu estimativas de λ^Q (os autovalores de K_1^Q), $K_{0,\infty}^Q$ (o primeiro e único elemento não nulo do vetor K_0^Q , que determina a taxa de curto prazo neutra ao risco $r_\infty^Q = K_{0,\infty}^Q / (1 - \lambda_1^Q)$) e Σ . Os demais parâmetros foram calculados a partir destes, conforme a caracterização geral dos DTSMs.

Por conseguinte, o ganho informacional ao se incluir os indicadores de incerteza foi avaliado ao comparar as verossimilhanças do DTSM inicial (modelo restrito) com o DTSM estimado com um fator de risco a mais (modelo irrestrito) através de um teste LR. Para tanto, deve-se destacar que as condições de regularidade para assumir assintoticamente uma distribuição χ^2 não são cumpridas e, portanto, não se deve comparar a razão da verossimilhança dos DTSMs ao valor crítico da χ^2 com os respectivos graus de liberdade. Todavia, há uma alternativa simples proposta por [Bauer e Rudebusch \(2017\)](#). Como exposto em [Joslin, Le e Singleton \(2013\)](#), um DTSM macro-financeiro - *i.e.*, com fatores exógenos - trata-se de um caso onde se impõem restrições de não arbitragem à forma reduzida do VAR sobre os fatores de risco em X_t . Dessa forma, tem-se um VAR com $\mathcal{N} + 1$ graus de liberdade (para $\mathcal{N} = \mathcal{L} + \mathcal{M}$) e uma equação de medida $J - \mathcal{L}$, para os J vértices em Y_t menos as \mathcal{L} componentes principais (formados a partir de Y_t , sem erro de mensuração, mas fator em X_t). Portanto, como a cada passo *forward* adiciona-se uma variável exógena a \mathcal{N} , têm-se

$$(J - \mathcal{L})(1 + \mathcal{N} + 1) - (J - \mathcal{L})(1 + \mathcal{N}) = (J - \mathcal{L}). \quad (3.12)$$

Portanto, tem-se $J - \mathcal{L}$ graus de liberdade na diferença entre os dois modelos. Logo, a significância do teste é obtida ao comparar a estatística calculada pela razão da verossimilhança com o valor crítico de uma χ^2 bi-caudal com $(J - \mathcal{L})$ graus de liberdade.

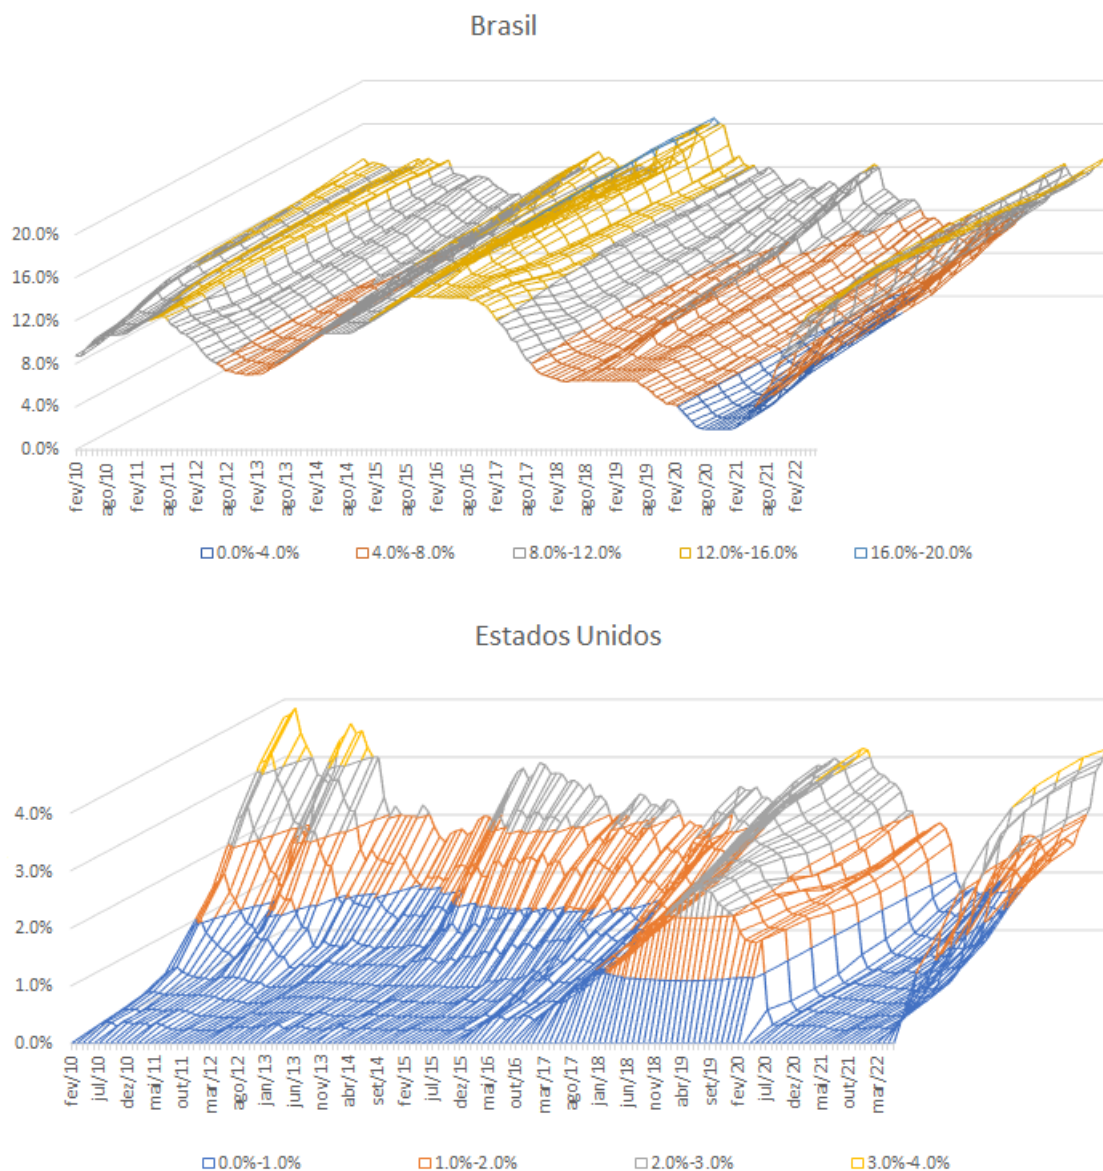
Por fim, cabe esclarecer que os procedimentos econométricos utilizados nessa tese foram implementados no *software* R, o código se encontra no apêndice B. Ainda, foram utilizados os pacotes `corrgram`, `devtools`, `ggplot2`, `glmnet`, `lmtest`, `MASS`, `randtoolbox`, `readxl`, `sandwich`, `stargazer`, `Spillover`, `tseries`, `urca`, `vars`, `xtable` e `writexl`. Em especial, foram criadas funções auxiliares para estimar o DTSM, escritas a partir dos códigos disponibilizados por Michael Bauer em <https://www.michaeldbauer.com/research/>.

4 RESULTADOS

4.1 Análise prévia dos dados

A figura 4 permite analisar visualmente o comportamento das curvas de juros brasileira (*Swap* DI \times Pré) e americana (ETTJ do tesouro americano), respectivamente, de fevereiro de 2010 a junho de 2022, para vencimentos entre 1 e 120 meses.

Figura 4 – Curvas de juros - fevereiro/2010 a junho/2022



Fonte: elaboração própria.

Ao longo do período amostral, a curva brasileira apresentou um padrão mais errático, contrapondo a estabilidade da curva americana, próxima a zero. Como em outros países desenvolvidos, os Estados Unidos adotaram uma política monetária de estímulo econômico após a crise financeira de 2008-2009 e durante a crise global do Covid-19, combinando redução da taxa base de juros com *Quantitative Easing*. Nesse período, a volatilidade no *spread* da curva brasileira frente à americana foi devido a mudanças no prêmio de risco e na expectativa de inflação brasileira. Destaca-se o período de 2014 a 2016, quando a crise fiscal (elevando o prêmio de risco) combinada à alta da inflação levou à elevação da taxa de juros, apesar da concomitante recessão na atividade econômica. Após este período, a curva de juros exibiu uma inclinação negativa, de abril de 2016 a abril de 2017. Contrastando com a literatura americana sobre curva de juros, a inclinação negativa da curva brasileira não antecipou uma recessão posterior. Ela é devida à estabilização do quadro econômico e fiscal observada após alterações na política econômica em 2016. Já em 2021, a retomada pós pandemia da Covid-19 foi acompanhada por um processo inflacionário global, que se intensificou com o início da guerra entre Rússia e Ucrânia em fevereiro de 2022. No Brasil, isso pressionou os juros de forma ainda mais forte.

Desde [Litterman e Scheinkman \(1991\)](#), sabe-se que os movimentos na curva de juros podem ser capturados pelas primeiras componentes principais dos seus vértices. Por conseguinte, foram extraídas as três primeiras componentes principais de cada uma das três curvas. Ainda, como variável de controle adicional, também foram extraídas a quarta e a quinta componente principal da curva *Swap DI × Pré* e da ETTJ. As respectivas cargas de cada componente principal foram apresentadas nas tabelas 3, 4 e 5.

Tabela 3 – Cargas das primeiras componentes principais - *Swap DI × Pré*

	<i>Swap DI × Pré</i> (B ³)							
	1	3	6	12	18	21	24	27
<i>L</i>	0,285	0,288	0,293	0,293	0,285	0,280	0,274	0,268
<i>S</i>	0,508	0,449	0,331	0,137	0,005	-0,041	-0,082	-0,118
<i>C</i>	0,361	0,233	0,015	-0,230	-0,281	-0,272	-0,243	-0,198
<i>PC</i> ₄	0,266	0,075	-0,202	-0,401	-0,266	-0,145	-0,024	0,095
<i>PC</i> ₅	0,377	0,003	-0,506	-0,343	0,101	0,237	0,254	0,210
	30	32	35	48	59	95	120	
<i>L</i>	0,262	0,256	0,250	0,229	0,214	0,184	0,172	
<i>S</i>	-0,148	-0,171	-0,190	-0,244	-0,264	-0,290	-0,298	
<i>C</i>	-0,147	-0,097	-0,046	0,135	0,259	0,417	0,467	
<i>PC</i> ₄	0,190	0,257	0,308	0,318	0,182	-0,248	-0,478	
<i>PC</i> ₅	0,122	0,019	-0,070	-0,384	-0,296	0,075	0,220	

Fonte: elaboração própria.

Tabela 4 – Cargas das primeiras componentes principais - ETTJ

		ETTJ (ANBIMA)							
		1	3	6	12	18	24	30	36
<i>L</i>		0,306	0,317	0,323	0,313	0,295	0,277	0,261	0,247
<i>S</i>		0,491	0,434	0,329	0,139	0,007	-0,078	-0,133	-0,169
<i>C</i>		0,521	0,178	-0,163	-0,418	-0,396	-0,287	-0,169	-0,065
<i>PC₄</i>		0,381	-0,141	-0,418	-0,262	0,040	0,232	0,302	0,289
<i>PC₅</i>		0,362	-0,289	-0,343	0,150	0,324	0,224	0,043	-0,117
		42	48	54	60	72	84	96	
<i>L</i>		0,235	0,226	0,218	0,211	0,200	0,193	0,187	
<i>S</i>		-0,194	-0,212	-0,225	-0,235	-0,249	-0,260	-0,268	
<i>C</i>		0,018	0,082	0,131	0,167	0,215	0,242	0,256	
<i>PC₄</i>		0,227	0,143	0,053	-0,036	-0,190	-0,308	-0,393	
<i>PC₅</i>		-0,221	-0,264	-0,257	-0,209	-0,034	0,199	0,453	

Fonte: elaboração própria.

Tabela 5 – Cargas das primeiras componentes principais - ETTJ americana

		ETTJ americana							
		1	3	6	12	24	36	60	84
<i>L</i>		0,328	0,347	0,369	0,387	0,384	0,365	0,306	0,251
<i>S</i>		0,237	0,231	0,220	0,187	0,080	-0,032	-0,242	-0,377
<i>C</i>		0,482	0,354	0,174	-0,049	-0,321	-0,423	-0,317	-0,129
		120	240						
<i>L</i>		0,191	0,113						
<i>S</i>		-0,494	-0,596						
<i>C</i>		0,174	0,424						

Fonte: elaboração própria.

Em linha com a literatura originada em [Litterman e Scheinkman \(1991\)](#), em todas as três curvas de juros, a primeira componente principal apresentou pesos similares em todos os vértices da respectiva curva - com leve decaimento para vencimentos mais longínquos - sendo, por isso, denominada por *L* (*level*). A segunda componente *S* (*slope*) conferiu pesos gradativamente menores à medida que o vencimento cresce. Por fim, a terceira componente *C* (*curvature*) apresentou pesos maiores nas pontas, similar a uma parábola. Conforme a prática nesse campo de pesquisa, essas cargas estimadas no período amostral total foram utilizadas no cálculo dos *scores* em cada mês *t*. Pois, de acordo com a lei dos grandes números, a adoção da amostra total induz a estimativas mais próximas do valor esperado correspondente. Todavia, isso presume que a estrutura teórica de cargas é invariante no tempo, onde dados futuros a *t* são utilizados para calcular as cargas da

componente principal no período t . Para verifica isso, a estabilidade das cargas foi avaliada através de um procedimento de janela expansiva na amostra, partindo de uma janela inicial de 36 meses (3 anos). Neste, constatou-se certa estabilidade nas cargas das curvas brasileiras, conforme exposto nas figuras 12 e 13 no apêndice A - resultado semelhante para a curva americana, exceto por alguns choques temporários, mas com posterior reversão aos valores prévios.

Quanto ao conteúdo informacional capturado pelas componentes principais, a tabela 6 apresenta a proporção da variância das respectivas componentes para cada curva e o percentual total acumulado pelas três componentes.

Tabela 6 – Proporção da variância na componente principal

	L	S	C	Total
$DI \times \text{Pré}$	0,777	0,124	0,059	0,983
$ETT J_{nominal}$	0,759	0,148	0,061	0,997
$ETT J_{EUA}$	0,523	0,303	0,101	0,927

Fonte: elaboração própria.

Em todos os casos, a três primeiras componentes principais (L , S e C) correspondem a mais de 90,0% da variabilidade das respectivas curvas, sendo maior que 98% para as brasileiras. Ainda, enquanto a componente de inclinação S chega no máximo a 14,8% da variabilidade das curvas brasileiras, ela marca 30,3% na americana.

Uma vez computados L_t , S_t , C_t , $PC_{4,t}$ e $PC_{5,t}$, além das medidas de *spread* e de excesso de retornos das curvas de juros correspondentes, a Tabela 7 apresenta as estatísticas descritivas das variáveis analisadas nos procedimentos econométricos posteriores.

Tabela 7 – Estatísticas descritivas das variáveis (fev./2010 - jun./2022)

	Obs.	Média	Desv. Pad.	Mínimo	Máximo
<i>Spread</i>					
$sp_{BR}(24)$	149	0,003	0,005	-0,009	0,015
$sp_{BR}(36)$	149	0,006	0,008	-0,013	0,025
$sp_{BR}(48)$	149	0,009	0,011	-0,015	0,032
$sp_{BR}(60)$	149	0,011	0,013	-0,016	0,038
$sp_{BRn}(24)$	149	0,005	0,006	-0,008	0,019
$sp_{BRn}(36)$	149	0,009	0,010	-0,013	0,030
$sp_{BRn}(48)$	149	0,011	0,013	-0,015	0,036
$sp_{BRn}(60)$	149	0,013	0,014	-0,016	0,042
Excesso de Retorno					
$rx_{BR}(24)$	137	0,095	0,340	-0,800	0,736
$rx_{BR}(36)$	137	0,191	0,696	-1,620	1,540

$rx_{BR}(48)$	137	0,261	0,998	-2,170	2,316
$rx_{BR}(60)$	137	0,306	1,274	-2,557	2,956
$rx_{BRn}(24)$	137	1,241	0,619	-0,356	2,575
$rx_{BRn}(36)$	137	1,332	0,892	-0,793	3,332
$rx_{BRn}(48)$	137	1,377	1,145	-1,142	3,954
$rx_{BRn}(60)$	137	1,400	1,393	-1,504	4,515
Fatores de Risco Latentes					
L_{BR}	149	0,000	0,118	-0,254	0,241
S_{BR}	149	-0,000	0,019	-0,044	0,041
C_{BR}	149	0,000	0,009	-0,027	0,023
PC_{4BR}	149	-0,000	0,003	-0,008	0,006
PC_{5BR}	149	0,000	0,001	-0,003	0,003
L_{BRn}	149	0,000	0,107	-0,233	0,230
S_{BRn}	149	-0,000	0,021	-0,049	0,046
C_{BRn}	149	-0,000	0,009	-0,029	0,022
PC_{4BRn}	149	-0,000	0,003	-0,009	0,007
PC_{5BRn}	149	-0,000	0,001	-0,002	0,002
L_{BRr}	149	0,000	0,057	-0,126	0,091
S_{BRr}	149	0,000	0,010	-0,024	0,022
C_{BRr}	149	-0,000	0,003	-0,009	0,010
$LEUA$	149	0,000	0,020	-0,025	0,051
$SEUA$	149	-0,000	0,012	-0,030	0,022
$CEUA$	149	0,000	0,004	-0,015	0,008
Fatores de Risco Exógenos					
CRE	149	0,009	0,045	-0,151	0,173
UCI	149	0,799	0,026	0,731	0,840
$EINF$	149	0,051	0,011	0,025	0,073
INF	149	0,060	0,024	0,019	0,121
CAM	149	0,008	0,047	-0,107	0,168
DIV	149	0,340	0,114	0,201	0,541
DUR	149	1,536	0,068	1,431	1,653
IIE	149	2,042	0,067	1,930	2,323
$EMBI$	149	2,409	0,117	2,134	2,726
EPU	149	2,128	0,133	1,853	2,545
VIX	149	1,246	0,144	0,975	1,756

Fonte: elaboração própria.


Na Tabela 7, quanto maior o vencimento, maiores foram os *spreads* e os excessos de retornos médios, assim como suas dispersões. De acordo com o fator de inclinação S , as curvas brasileiras apresentaram inclinação média negativa neste período, mas, ainda assim, próxima a zero. Curiosamente, a expectativa de inflação $EINF$ foi menor, em média, que

a inflação realizada INF . Ainda, o EPU (americano) apresentou maior média e maior volatilidade que o IIE (brasileiro).

4.2 Integração entre a curva de Swap DI \times Pré e a ETTJ

Uma primeira análise se disponibiliza pela comparação gráfica entre as componentes principais das duas curvas, fornecida pela Figura 5, e pelo correlograma na Figura 6.


Figura 5 – L_t, S_t e C_t - Swap DI \times Pré e ETTJ



Fonte: elaboração própria.

Na Figura 5, as variáveis $L_{BR,t}$ (*Swap* DI \times Pré) e $L_{BRn,t}$ (ETTJ) foram muito aderentes, assim como $S_{BR,t}$ e $S_{BRn,t}$ ou $C_{BR,t}$ e $C_{BRn,t}$. O resultado visual é confirmado pelo correlograma na Figura 6.

Figura 6 – Correlograma: PCs da *Swap* DI \times Pré e da ETTJ



Fonte: elaboração própria.

Neste, sublinha-se as fortes correlações entre as quatro primeiras componentes principais da curva de *swap* com as da ETTJ, de 1,00, 0,97, 0,96 e 0,91, respectivamente - não tão acentuada para a quinta componente, de 0,44. Ainda, as correlações entre componentes distintas são quase nulas, reforçando ao alinhamento entre as curvas. Como L_i , S_i e C_i sintetizam a forma funcional da curva i e explicam mais de 98% da variabilidade nestas curvas, a correlação quase perfeita entre as componentes correspondentes - e apenas estas - corrobora com a hipótese (implícita) de aderência entre elas quanto aos seus movimentos contemporâneos.

Após esta análise prévia, a avaliação do *spillover* de choques foi realizada através das medidas de conectividade. Para tanto, seguindo o critério de AIC, foi estimado um VAR(1) considerando as três primeiras componentes principais da cada curva. Não obstante, o teste de Jarque-Bera, o teste de Breusch-Godfrey e o teste ARCH rejeitaram a normalidade dos resíduos, a não correlação serial e a homoscedasticidade, respectivamente. Uma vez estimado o VAR, foram calculadas as medidas de *spillover*. Começando pela conectividade total ajustada, estimou-se $Tra^H = 49,52$ indicando certo equilíbrio, onde metade dos erros de previsão em cada curva são oriundos de choques na curva complementar. Por sua vez, as medidas de *spillover* estimadas são apresentadas nas tabelas 8 e 9.

Tabela 8 – *Spillover* líquido $Tr_{i,j}^H$ - *Swap* DI \times Pré e ETTJ

$L_{BR} \times L_{BRn}$	$S_{BR} \times S_{BRn}$	$C_{BR} \times C_{BRn}$
-0,021	0,025	-0,022

Fonte: elaboração própria.

Tabela 9 – *Spillover* parcial $Trp_{i\leftarrow\bullet}^H$ - *Swap* DI \times Pré e ETTJ

	$L_{i\leftarrow\bullet}$	$S_{i\leftarrow\bullet}$	$C_{i\leftarrow\bullet}$
$i = BR$	0,465	0,501	0,519
$i = BRn$	0,529	0,486	0,472


Fonte: elaboração própria.

As estimativas de Tr^H apontam que L_{BR} e C_{BR} são transmissores líquidos de choques para L_{BRn} e C_{BRn} , respectivamente. Por outro lado, S_{BR} é um receptor líquido de S_{BRn} . Ainda, os fatores S_{BR} e C_{BR} recebem um pouco mais influência da ETTJ, como um todo, do que S_{BRn} e C_{BRn} recebem da curva de *swap*. Em contrapartida, L_{BRn} recebe mais influência da curva de *swap* do que L_{BR} recebe da ETTJ. Logo, não há uma clara orientação sobre qual curva é receptora (líquida) e qual é transmissora (líquida). Sublinha-se que, alinhados ao resultado da conectividade total ajustada, os *spillovers* parciais $Trp_{i\leftarrow\bullet}^H$ demonstraram que cerca de metade dos efeitos de propagação de choques são oriundos da curva complementar.

Como um todo, as medidas de *spillover* não só reforçaram a conexão entre a curva de *swap* e a ETTJ como demonstraram um certo equilíbrio na propagação de choques, não havendo uma espécie de antecedente entre elas. Em vista disso, adiante, quando as figuras e tabelas para a ETTJ foram semelhantes às da curva de *swap*, elas foram anexadas ao apêndice A como forma de robustez.

4.3 *Spillovers* de choques americanos

Como na seção 4.2, uma primeira análise se deu pela comparação gráfica entre as componentes principais das três curvas, na Figura 7, e pelo correlograma para a curva de *swap*, na Figura 8. Adicionalmente, o correlograma para a ETTJ é apresentado na Figura 14 (apêndice A).

Figura 7 – L_t , S_t e C_t - Swap DI \times Pré, ETTJ e ETTJ americana

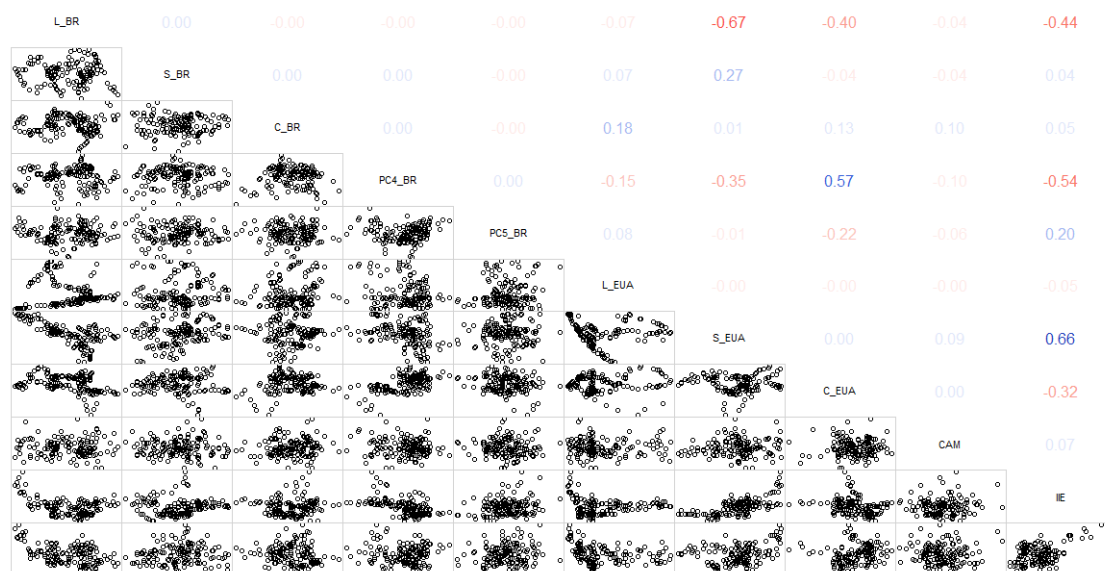
Fonte: elaboração própria.

Contrapondo o alinhamento entre os respectivos fatores latentes das curvas brasileiras na Figura 5, a Figura 7 destaca o desalinhamento dos fatores latentes brasileiros com os respectivos fatores da curva americana. Constata-se, também, uma volatilidade menor nos fatores latentes americanos. A curva americana é tradicionalmente mais estável do que a de países emergentes como o Brasil. Mas, em particular, ela foi ainda mais estável no período amostral avaliado - pós crise financeira de 2007-2008 -, quando se manteve *flat* e próxima ao limiar de zero na maior parte do recorte temporal da amostra.

Esse desalinhamento visual é confirmado pelo correlograma na Figura 6, entre os fatores latentes americanos e os brasileiros (da curva de *swap*). Cabe destacar que os padrões de correlações foram semelhantes na Figura 14 (no apêndice A), o correlograma entre os fatores americanos e os da ETTJ. Isso complementa o alinhamento entre as duas

curvas brasileiras, constatado na Figura 5, sendo uma primeira evidência da similaridade na dinâmica das curvas brasileiras em função de movimentos na curva americana.

Figura 8 – Correlograma: *Swap* DI \times Pré, ETTJ americana e indicadores de incerteza



Fonte: elaboração própria.

Segundo este, as correlações mais expressivas dos fatores americanos (S_{EUA} e C_{EUA}) e do indicadores de incerteza (IIE e EPU) foram com os fatores L e, atualizando a literatura, PC_4 , das curvas brasileiras. Enquanto o fator L contempla mais de 75% do conteúdo informacional das curvas brasileiras, PC_4 não chega a 2,5%. Reforçando, assim, a contestação em [Cochrane e Piazzesi \(2005\)](#) de que, apesar de componentes principais adicionais não capturarem grandes volumes de informação, elas podem contemplar informações preciosas - como as associadas a mudanças no cenário de crédito internacional ou na percepção de incerteza na política econômica. Ainda, vale sublinhar que IIE é mais correlacionada à S_{EUA} do que aos fatores das curvas brasileiras ou à EPU . Não se espera que IIE tenha uma relação de causa sobre S_{EUA} e nem sobre EPU , pois o Brasil é uma economia pequena. Todavia, uma interpretação plausível é que expectativas de alta na taxa base americana (contidas em S_{EUA}) sejam impactantes na incerteza brasileira, até mais do que a próprio *spillover* da incerteza americana.

Para a avaliar os *spillovers* e estimar as IRFs, foram estimados três VARs: i) M1, com os três fatores latentes de cada curva e CAM ; ii) M2, com os três fatores latentes de cada curva, CAM e IIE ; e iii) M3, com os três fatores latentes de cada curva, CAM , IIE e EPU . Conforme o critério AIC, todos consistiram em um VAR(1). Para todos eles, foram rejeitadas as hipóteses de normalidade, de não correlação serial e de homoscedasticidade, o que, todavia, não impede a análise do *spillover*.

As estimativas de *spillover* parcial $Trp_{i\leftarrow\bullet}^H$ da curva americana sobre os fatores das curvas brasileiras são apresentadas na Tabela 10.

Tabela 10 – *Spillover* parcial $Trp_{i\leftarrow EUA}^H$

	$Trp_{i\leftarrow EUA}^H$ (M1)	$Trp_{i\leftarrow EUA}^H$ (M2)	$Trp_{i\leftarrow EUA}^H$ (M3)
L_{BR}	0,169	0,156	0,158
S_{BR}	0,086	0,081	0,080
C_{BR}	0,029	0,027	0,030
L_{BRn}	0,194	0,181	0,178
S_{BRn}	0,069	0,066	0,062
C_{BRn}	0,060	0,058	0,069

Nota: M1 = Modelo1, M2 = Modelo 2 e M3 = Modelo3.

Um primeiro ponto a ser destacado é que foram impostas restrições a todos os VARs estimados, dado que o Brasil é uma economia pequena. ^{Fonte: elaboração própria.} Consequentemente, as medidas de *spillover* para o horizonte $H = 10$ acabam refletindo apenas efeitos diretos dos choques americanos sobre as variáveis brasileiras - limitando a propagação de choques no sistema de equações do VAR. Ainda assim, na Tabela 10, destaca-se o impacto de choques oriundos da curva americana sobre o fator de nível brasileiro L , estendendo a concepção de que a taxa base de juros brasileira é sensível ao movimento da taxa americana, para a sensibilidade da taxa média na curva brasileira, como um todo, é sensível às movimentações na curva americana. Este resultado reforça as fortes correlações entre os fatores S_{EUA} e C_{EUA} com L_{BR} (ou L_{BRn}) no correlograma 8 (ou no 14).

Além disso, curiosamente, o *spillover* sobre C_{BRn} foi o dobro do sobre C_{BR} , apesar de ambas terem correlações igualmente baixas com os fatores latentes americanos. Como C é associada ao prêmio de risco, esse resultado sugere que o prêmio na curva de títulos soberanos sofre maior influência do *spillover* de choques da curva americana, uma primeira discrepância quanto às similaridades das duas curvas brasileiras. Também foi constatada uma leve queda nas medidas de *spillover* do modelo M1 para o M2, um resultado esperado ao se incorporar mais variáveis no VAR. Por outro lado, indo do M2 para o M3, a alteração no *spillover* foi difusa. Em particular, a inclusão de EPU (M2 para M3) aumentou a medida de *spillover* da curva americana sobre o prêmio de risco capturado em C , especialmente na ETTJ (C_{BRn}). Logo, uma vez controlado o *spillover* da incerteza proveniente de EPU , fica mais evidente o *spillover* de choques na curva americana sobre o prêmio de risco da curva brasileira, capturado em C_{BRn} .

Assim sendo, a Tabela 11 apresenta os *spillovers* simples $\psi_{i,j}^H$ dos indicadores de incerteza sobre os fatores latentes brasileiros e a incerteza brasileira.

Tabela 11 – *Spillover* simples $\psi_{i,j}^H$, originados em *IIE* e *EPU*

	<i>IIE</i> (M2)	<i>IIE</i> (M3)	<i>EPU</i> (M3)
L_{BR}	0,019	0,009	0,121
S_{BR}	0,002	0,002	0,022
C_{BR}	0,032	0,025	0,023
IIE_{BR}	0,588	0,518	0,075
L_{BRn}	0,013	0,006	0,109
S_{BRn}	0,006	0,004	0,011
C_{BRn}	0,027	0,028	0,046
IIE_{BRn}	0,584	0,505	0,084

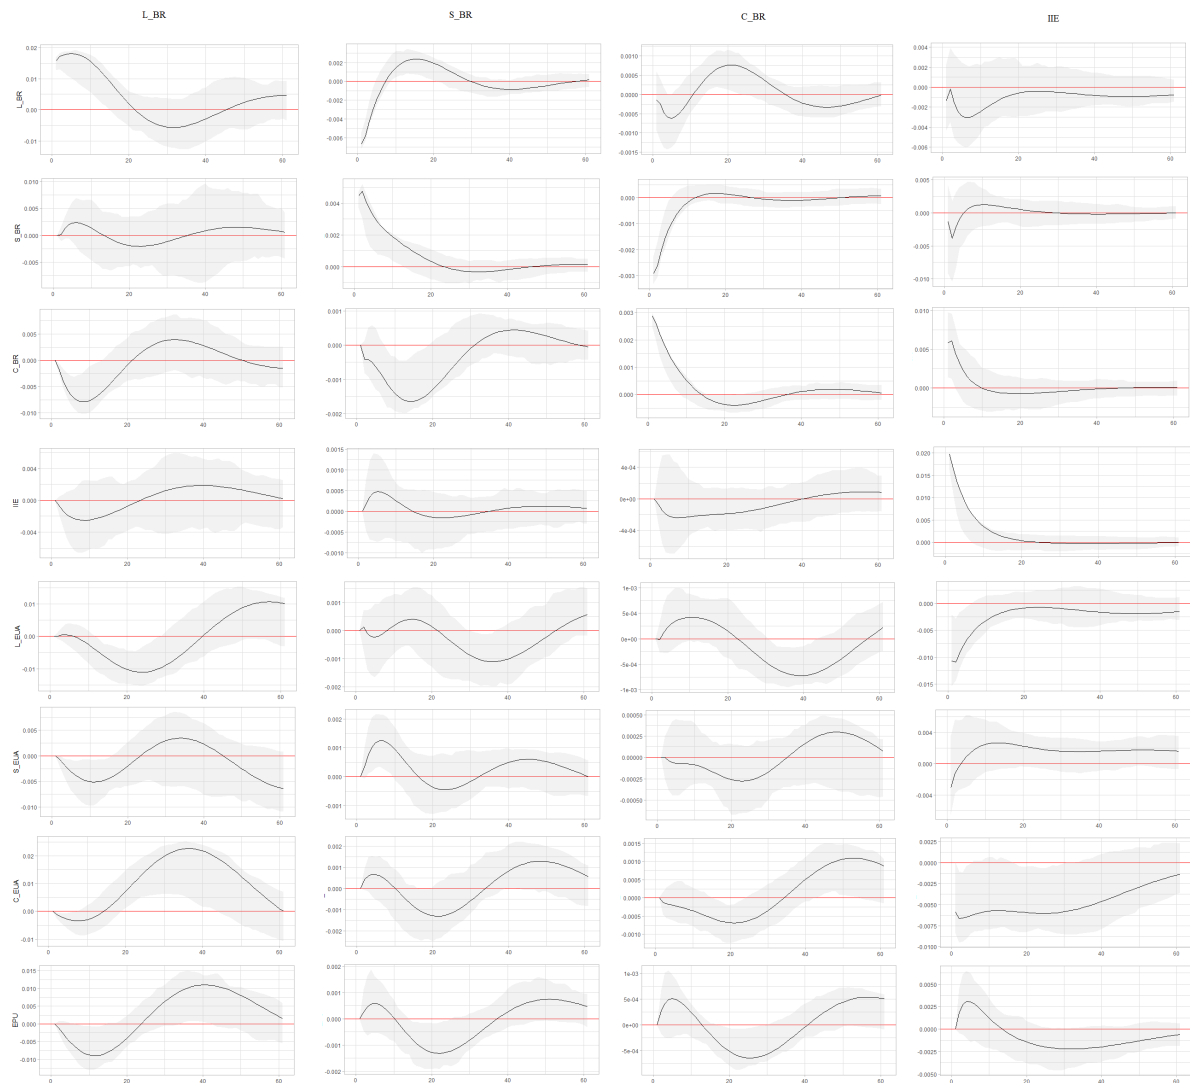
Nota: M2 = Modelo 2 e M3 = Modelo3.

Fonte: elaboração própria.

Nesta tabela, constata-se que os *spillovers* do *EPU* sobre os fatores latentes brasileiros são consideravelmente maiores que os oriundo de *IIE* - especialmente em L -, mesmo quando *IIE* é a única variável de incerteza (em M2). Ainda, o *spillover* de *IIE* sobre L caiu pela metade ao ser controlado por *EPU*, o que não ocorreu com os outros fatores. Isso reforça a concepção de que o risco americano impacta o prêmio exigido na taxa base brasileira enquanto o risco da incerteza na política econômica brasileira está mais associado ao prêmio de risco pela liquidez - proporcional ao vencimento na curva. Adicionalmente, apesar da correlação moderada entre *IIE* e *EPU* (0,47), os *spillovers* de *EPU* para *IIE* não foram expressivos e a inclusão de *EPU* pouco impactou o percentual de erros de previsão em *IIE* oriundo de choques em suas próprias defasagens, indicando que não há efeitos posteriore de choques em *EPU* que seriam propagados para *IIE*.

Por fim, a Figura 9 exibe as IRFs para um horizonte de 60 meses, maior que o de 10 meses capturado nas medidas de *spillover*. Não obstante, cabe reforçar que algumas séries não são estacionárias - além dos problemas (normalidade, heterocedasticidade e autocorrelação) na validação dos VARs. Devido a isso, os choques podem se propagar de maneira indefinida e permanentemente, o que, todavia, é interessante de ser avaliado na perspectiva da autoridade monetária. Complementarmente, os resultados para a ETTJ foram similares e, por isso, foram apresentados na Figura 15), no apêndice A.

Figura 9 – Resposta de $L_{BR,t}$, $S_{BR,t}$, $C_{BR,t}$ e IIE ($Swap\ DI \times Pr\acute{e}$) a choques em $L_{BR,t}$, $S_{BR,t}$, $C_{BR,t}$, IIE , $L_{EUA,t}$, $S_{EUA,t}$, $C_{EUA,t}$ e EPU



Fonte: elaboração própria.

Nestas IRFs, as respostas mais intensas (em termos absolutos) ocorreram em L_{BR} . Ainda, L_{BR} e S_{BR} foram mais sensíveis a choques em EPU do que aos oriundos de IIE . Um destaque é que as respostas dos fatores brasileiros a choques americanos não foram imediatas, mas, devido aos efeitos indiretos, posteriormente, essas respostas atingiram patamares mais elevados do que os oriundos da variáveis brasileiras (L_{BR} , S_{BR} , C_{BR} e EPU) e com efeitos muito mais longínquos. Ainda, IIE foi mais sensível a choques nos fatores latentes americanos do que no EPU ou nos fatores latentes brasileiros. Em vista disso, levanta-se a hipótese de que, em parte, o IIE antecipa os efeitos de choques oriundos dos Estados Unidos, posteriormente propagados na curva brasileira. De todo modo, as reações dos fatores latentes brasileiros aos choques em IIE foram relativamente fracas e, pelos respectivos intervalos de confiança, não foram significativamente diferentes de zero.

4.4 Incerteza na política econômica brasileira e curva de juros

As figuras 18, 19, 20, 21 (apêndice A) apresentam os correlogramas contemplando as variáveis utilizadas nesta seção. Para a curva de *swap* (Figura 18), além das altas correlações entre os *spreads*, observa-se correlações leves destes com *CRE*, *INF*, *IIE* e *EPU* e moderada com *INF*. Comparativamente, na ETTJ (Figura 19), as correlações dos *spreads* com as demais variáveis são ligeiramente maiores, exceto por *CAM* que permaneceu praticamente nula e por *CRE* que foi menor - próxima a zero. Os resultados apresentados nas seções 4.2 e 4.3 corroboram com o alinhamento na dinâmica da curva de *swap* com a da ETTJ, havendo, inclusive, equilíbrio no *spillover* entre elas. Adicionalmente, na seção 4.3 constatou-se que o fator latente C_{BRn} (da ETTJ) sofre maior *spillover* da curva americana do que C_{BR} (da *swap*). As correlações ligeiramente mais intensas dos fatores macroeconômicos e da incerteza com os *spreads* da ETTJ são um primeiro indício de maior sensibilidade da forma funcional desta curva a choques no ambiente macroeconômico, o que será melhor explorado nos testes posteriores.

No tocante aos excessos de retorno da curva de *swap* (correlograma na Figura 20), apenas L_{BR} e, um pouco menos, C_{BR} apresentaram correlação moderada com $rx_{t,t+12}(\tau)$. Na ETTJ (Figura 21), essas correlações foram levemente maiores e *INF* também passou a apresentar uma correlação moderada. Reforçando, assim, a maior sensibilidade da ETTJ, inclusive em termos preditivos, às flutuações macroeconômicas.

Após a análise prévia das correlações entre as variáveis, uma série de testes foram implementados para avaliar o impacto da incerteza na política econômica sobre a curva de juros brasileira. O primeiro conjunto de testes consistiu em regressões recorrentes na literatura (equações na seção 3.3.3), utilizadas para avaliar o poder explicativo sobre os *spreads* $sp_t(\tau)$ e o poder preditivo sobre os excessos de retorno $rx_{t,t+12}(\tau)$.

Começando pela análise das regressões dos *spread* $sp_{t,t+12}(\tau)$, foram estimados três modelos de regressão: M1 (com *CRE*, *INF*, *CAM*, *DIV* e *IIE*); M2 (com *CRE*, *INF*, *CAM*, *DIV* e *EPU*); e M3 (com *CRE*, *INF*, *CAM*, *DIV*, *IIE* e *EPU*). Considerando as duas curvas de juros (de *swap* e a ETTJ), com $\tau = 24, 26, 48$ e 60 , totalizaram-se 24 regressões. As tabelas 12 e 13 apresentam os resultados para a curva de *swap* e a ETTJ, respectivamente. Nestas, conforme os testes de Breusch-Pagan e de Breusch-Godfrey apresentados, foram rejeitadas as hipóteses de homoscedasticidade e de não correlação serial do resíduo, respectivamente, em todas as regressões. Visando mitigar esses problemas, a significância dos coeficientes exibidos nestas tabelas adotam o erro padrão de Newey-West.

Tabela 12 – Regressões de $sp_t(\tau)$ (*Swap* DI × Pré)

	M1				M2				M3			
	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)
β_0	-0,025	-0,044	-0,062	-0,075	0,001	0,006	0,010	0,012	-0,026	-0,045	-0,063	-0,077
<i>CRE</i>	0,045***	0,063**	0,066*	0,064	0,036***	0,044*	0,040	0,032	0,046***	0,064***	0,068**	0,066*
<i>INF</i>	-0,055	-0,160	-0,248	-0,309*	-0,054	-0,158	-0,244	-0,305	-0,056	-0,162	-0,250	-0,311**
<i>CAM</i>	0,006	0,012	0,018	0,022	0,007	0,013	0,021	0,025	0,006	0,012	0,018	0,022
<i>DIV</i>	0,001	-0,0000	0,002	0,005	0,007	0,011	0,018	0,024	0,001	-0,000	0,001	0,004
<i>IIE</i>	0,015	0,029	0,041	0,050*					0,016	0,031	0,044	0,053*
<i>EPU</i>					0,001	0,002	0,003	0,004	-0,001	-0,001	-0,002	-0,003
Obs.	149	149	149	149	149	149	149	149	149	149	149	149
R ²	0,263	0,367	0,437	0,488	0,251	0,353	0,421	0,471	0,263	0,367	0,438	0,489
R ² aju.	0,237	0,345	0,418	0,470	0,225	0,330	0,401	0,452	0,232	0,340	0,414	0,467
Teste F	10,2***	16,6***	22,2***	27,3***	9,6***	15,6***	20,8***	25,4***	8,4***	13,7***	18,4***	22,6***
Teste BP	23,4***	28,0***	28,1***	24,0***	26,8***	35,0***	36,5***	32,5***	28,6***	32,9***	32,4***	28,1***
Teste BG	108,4***	110,5***	113,6***	115,3***	113,2***	115,6***	118,6***	119,9***	108,5***	110,8***	113,8***	115,6***

Nota:

BP = Breusch-Pagan; BG = Breusch-Godfrey

*p<0,1; **p<0,05; ***p<0,01

Fonte: elaboração própria.

Tabela 13 – Regressões de $sp_t(\tau)$ (ETTJ)

	M1				M2				M3			
	$sp(24)$	$sp(36)$	$sp(48)$	$sp(60)$	$sp(24)$	$sp(36)$	$sp(48)$	$sp(60)$	$sp(24)$	$sp(36)$	$sp(48)$	$sp(60)$
β_0	-0,038	-0,065	-0,085	-0,100*	0,005	0,008	0,008	0,006	-0,038	-0,066	-0,085	-0,100*
<i>CRE</i>	0,041**	0,049	0,050	0,050	0,025	0,022	0,015	0,009	0,042**	0,050	0,051	0,050
<i>INF</i>	-0,142*	-0,261***	-0,335***	-0,379***	-0,139	-0,257*	-0,329**	-0,371***	-0,142*	-0,262***	-0,336***	-0,379***
<i>CAM</i>	0,010	0,019	0,025*	0,029*	0,012	0,021*	0,028*	0,032*	0,010	0,018	0,025*	0,029*
<i>DIV</i>	-0,001	0,002	0,005	0,009	0,009	0,018	0,027	0,034	-0,001	0,001	0,005	0,009
<i>IIE</i>	0,025*	0,043*	0,056**	0,064**					0,026	0,045*	0,057*	0,064*
<i>EPU</i>					0,003	0,004	0,006	0,008	-0,001	-0,001	-0,001	0,000
Obs.	149	149	149	149	149	149	149	149	149	149	149	149
R ²	0,446	0,537	0,581	0,604	0,429	0,517	0,561	0,583	0,447	0,537	0,581	0,604
R ² aju.	0,427	0,520	0,567	0,590	0,409	0,500	0,546	0,568	0,423	0,517	0,564	0,587
Teste F	23,1***	33,2***	39,8***	43,6***	21,5***	30,6***	36,5***	40,0***	19,1***	27,4***	32,9***	36,1***
Teste BP	30,9***	24,3***	17,4***	12,9**	39,8***	33,9***	26,2***	20,3***	33,7***	27,2***	20,3***	15,5**
Teste BG	110,2***	110,7***	111,1***	111,6***	116,0***	115,6***	115,0***	114,7***	110,7***	111,2***	111,6***	112,2***

Nota:

BP = Breusch-Pagan; BG = Breusch-Godfrey

*p<0,1; **p<0,05; ***p<0,01

Fonte: elaboração própria.

Quanto maior o vencimento τ do *spread* regredido, maior foi o R^2 ajustado, exibindo uma maior influência do quadro macroeconômico (inclusive a incerteza) na formação das expectativas de taxas futuras de curto prazo e do prêmio de liquidez. Comparando as duas curvas, os R^2 ajustados foram maiores nas regressões para a ETTJ do que nas para a curva de *swap*, especialmente nos *spreads* mais curtos. Ainda, nas regressões para a ETTJ, constatou-se um número maior de variáveis explicativas (macroeconômicas) significativas sobre os *spreads*. Logo, apesar do alinhamento entre as duas curvas constatado nas últimas seções, essas regressões expõem uma maior sensibilidade dos *spreads* da ETTJ às mudanças no ambiente macroeconômico, complementando os resultados nos correlogramas.

Em ambas as curvas, a significância de *CRE* foi maior nos *spreads* mais curtos enquanto a de *INF* se deu nos *spreads* mais longos. O coeficiente positivo em *CRE* reforça as expectativas do mercado quanto à atuação contracíclica da autoridade monetária, ao menos nos horizontes relativamente curtos. O coeficiente negativo em *INF*, significativos nos *spreads* mais longos, se deve às expectativas de que a política de alta no juro (nominais) visando conter altas na inflação vigente seja efetiva, permitindo, assim, ao menos após alguns anos, a redução das taxas de curto prazo. Não obstante, *CRE* foi significativo em quase todos os *spreads* da curva de *swap*, mas apenas para $sp_t(24)$ na ETTJ. Por outro lado, *INF* foi significativa em quase todos os *spreads* da ETTJ, mas apenas para $sp_t(60)$ na curva de *Swap*. Ainda, *CAM* foi significativo para os *spreads* mais longos da ETTJ, o que não ocorreu para a curva de *swap*. O coeficiente positivo na variação do câmbio (*CAM*) está associado à expectativa de alta na taxa base de juro para conter saídas de capital, assim como à elevação do prêmio de risco característico nesses períodos.

Em especial, *IIE* foi significativamente positivo nas regressões para quase todos os *spreads* da ETTJ e para $sp_t(60)$ da curva de *swap*. Corroborando, portanto, com a ideia de que o indicador de incerteza na política econômica brasileira está associado a maiores prêmios de risco na curva de juro. Aí, a inclusão de *IIE* melhorou a significância das demais variáveis explicativas, macroeconômicas. Como elas estão mais associadas à formação de expectativas, a inclusão de *IIE*, ao controlar os efeitos de incerteza inerentes às flutuações macroeconômicas, melhorou a identificação dos efeitos das demais sobre os *spreads*. Por fim, cabe pontuar que *EPU* não foi significativamente diferente de zero em qualquer regressão, mesmo em M2 - sem *IIE*. Isso evidencia que a incerteza na política econômica americana não está relacionada ao *spread* da curva de juro brasileira. Todavia, como demonstrado na seção anterior, ela afeta a dinâmica da curva, impactando especialmente o fator de nível L .

Na sequência, foram avaliadas as regressões dos excessos de retorno $rx_{t,t+12}(\tau)$ (equações em 3.3.3), com $\tau = 24, 26, 48$ e 60 , para três modelos: M1 (com L, S, C e *IIE*); M2 (com L, S, C e *EPU*); e M3 (com L, S, C, IIE e *EPU*). As tabelas 12 e 13 apresentam os resultados para a curva de *swap* e a ETTJ, respectivamente.

Tabela 14 – Regressões de $rx_{t,t+12}(\tau)$ (*Swap* DI \times Pré)

	M1				M2				M3			
	$rx(24)$	$rx(36)$	$rx(48)$	$rx(60)$	$rx(24)$	$rx(36)$	$rx(48)$	$rx(60)$	$rx(24)$	$rx(36)$	$rx(48)$	$rx(60)$
β_0	0,120	0,057	-0,908	-2,267	-0,066	-0,084	-0,075	-0,205	0,054	-0,036	-0,948	-2,275
L_{BR}	1,286*	2,523*	3,541*	4,486*	1,331	2,573	3,462	4,257	1,317	2,568	3,560	4,490
S_{BR}	2,306	5,469	4,962	3,062	2,278	5,447	5,079	3,356	2,295	5,453	4,955	3,061
C_{BR}	8,756	28,830*	49,669**	69,253**	8,783	29,026*	50,900**	71,937***	8,936	29,087*	49,777**	69,274**
IIE	-0,016	0,050	0,545	1,223					-0,070	-0,028	0,513	1,216
EPU					0,072	0,114	0,130	0,200	0,083	0,118	0,050	0,010
Obs.	137	137	137	137	137	137	137	137	137	137	137	137
R ²	0,271	0,324	0,347	0,368	0,272	0,324	0,346	0,365	0,272	0,324	0,347	0,368
R ² aju.	0,249	0,303	0,327	0,349	0,250	0,304	0,326	0,346	0,244	0,298	0,322	0,344
Teste F	12,3***	15,8***	17,5***	19,2***	12,3***	15,8***	17,5***	19,0***	9,8***	12,6***	13,9***	15,2***
Teste BP	20,3***	19,0**	18,783**	18,1**	25,3***	23,4***	21,5***	19,7**	25,0***	23,4***	22,4***	21,2**
Teste BG	116,6***	116,5***	116,4***	115,8***	116,9***	116,5***	116,3***	115,6***	116,9***	116,7***	116,6***	116,0***

Nota:

BP = Breusch-Pagan; BG = Breusch-Godfrey

*p<0,1; **p<0,05; ***p<0,01

Fonte: elaboração própria.

Tabela 15 – Regressões de $rx_{t,t+12}(\tau)$ (ETTJ)

	M1				M2				M3			
	$rx(24)$	$rx(36)$	$rx(48)$	$rx(60)$	$rx(24)$	$rx(36)$	$rx(48)$	$rx(60)$	$rx(24)$	$rx(36)$	$rx(48)$	$rx(60)$
β_0	1,326	0,517	-0,645	-1,764	1,082	1,152	1,031	0,764	1,255	0,509	-0,632	-1,789
$LBRn$	4,757***	5,927***	6,955***	7,944***	4,815***	5,852***	6,744***	7,643***	4,794***	5,931***	6,948***	7,957***
$SBRn$	4,601*	3,394	0,182	-3,420	4,610**	3,364	0,106	-3,536	4,602**	3,394	0,182	-3,419
$CBRn$	18,214**	41,252***	61,692***	80,872***	18,126**	42,085***	63,782***	84,161***	18,346**	41,268***	61,670***	80,918***
IIE	-0,045	0,383	0,963	1,512					-0,101	0,376	0,972	1,493
EPU					0,072	0,068	0,134	0,259	0,087	0,011	-0,015	0,030
Obs.	137	137	137	137	137	137	137	137	137	137	137	137
R ²	0,793	0,658	0,604	0,580	0,793	0,657	0,602	0,576	0,794	0,658	0,604	0,580
R ² aju.	0,787	0,648	0,592	0,567	0,787	0,647	0,590	0,564	0,786	0,645	0,589	0,564
Teste F	126,7***	63,5***	50,3***	45,6***	126,8***	63,3***	49,8***	44,9***	100,7***	50,4***	39,9***	36,2***
Teste BP	19,5**	19,09**	18,6**	17,3**	22,8***	19,2**	17,6**	17,1**	22,6***	21,0**	20,4**	19,8**
Teste BG	112,5***	112,3***	111,4***	110,5***	112,6***	112,1***	111,1***	110,1***	112,6***	112,5***	111,7***	110,7***

Nota: BP = Breusch-Pagan; BG = Breusch-Godfrey
 *p<0,1; **p<0,05; ***p<0,01

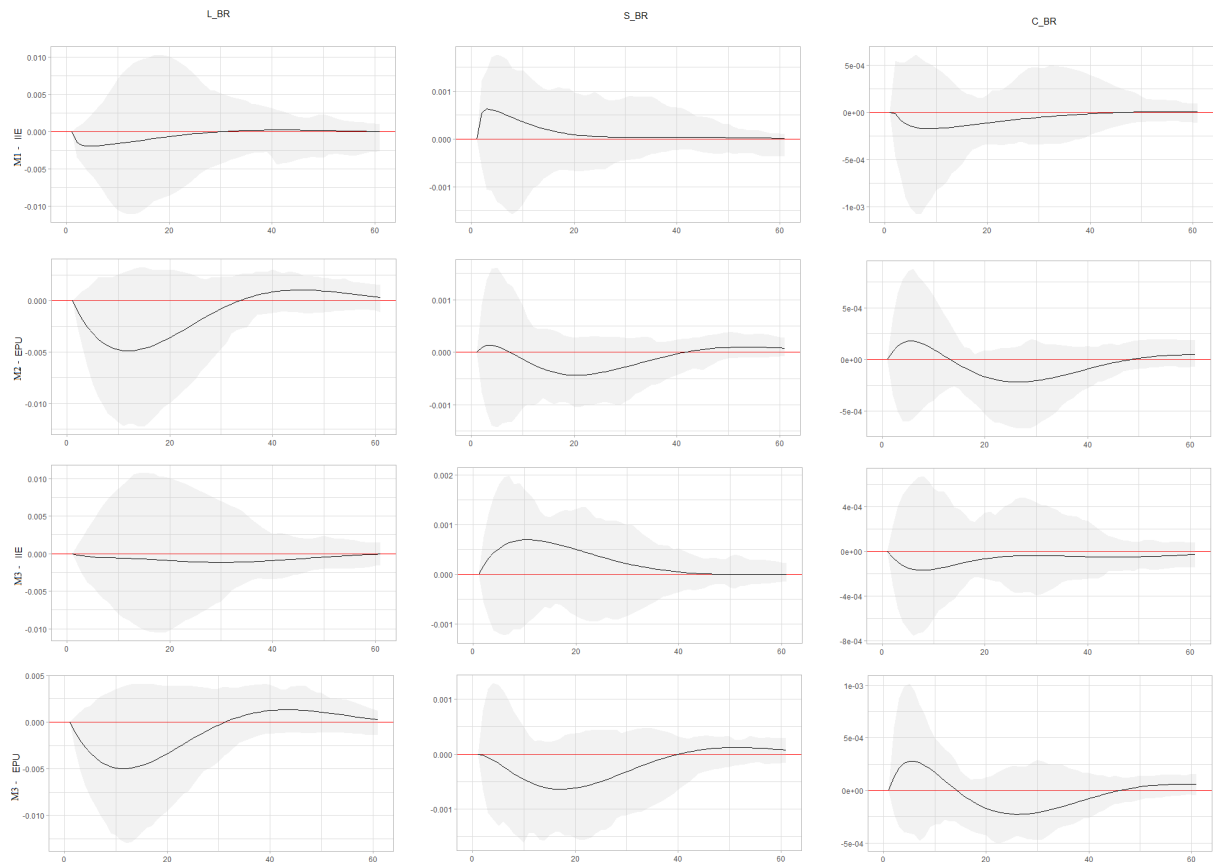
Fonte: elaboração própria.

Segundo as tabelas 14 e 15, apenas os fatores latentes das curvas possuem poder preditivo sobre os excessos de retorno em 12 meses ($rx_{t,t+12}(\tau)$), com destaques para o fator de curvatura C - associado ao prêmio de risco contido na curva corrente. Uma interpretação para o baixo poder preditivo de IIE apesar do poder explicativo significativo sobre a curva corrente (tabelas 12 e 13) é que esse indicador esteja associado ao prêmio de risco de liquidez exigido em t , afetando a forma funcional apenas no momento t . Ainda, apesar de EPU não ser um bom previsor para o excesso de retorno em um ano, cabe lembrar que a curva brasileira reage com certa intensidade a choques americanos, inclusive os de EPU (Figura 9). Todavia, isso não é imediato, devendo-se a efeitos indiretos de propagação.

Comparando os resultados para as duas curvas de juros, constatam-se diferenças nos R^2 ajustados e no números de variáveis preditivas significativas. Os R^2 ajustados ficaram entre 0,244 e 0,346 nas regressões para a curva de *swap*, sendo crescente quanto mais longínquos foram os excessos de retornos regredidos. Todavia, os mesmos ficaram entre 0,564 e 0,787 nas regressões para a ETTJ, sendo decrescentes em função do horizonte τ em $rx_{t,t+12}(\tau)$. Além disso, não só a significância em C foi maior para a ETTJ, como os demais fatores latentes L e S também apresentaram resultados melhores para esta curva. Portanto, assim como para as regressões de *spread* (tabelas 12 e 13), a ETTJ apresentou maior sensibilidade às mudanças nas variáveis independentes.

Por sua vez, a segunda análise sobre impactos da incerteza na política econômica sobre a curva de juros testou a propagação de choques nos fatores latentes - nível (L_t), inclinação (S_t) e curvatura (C_t) -, que capturam a forma funcional da curva em t . Para tanto, foram estimados três modelos de VAR: M1, um VAR(1) com L_t , S_t , C_t e IIE ; M2, um VAR(1) com L_t , S_t , C_t e EPU ; e M3, um VAR(1) com L_t , S_t , C_t , IIE e EPU . Nestes, foram rejeitadas as hipóteses de normalidade, não correlação serial e homoscedasticidade dos resíduos.

A partir destes modelos, foram estimadas IRFs com propagações ao longo de 60 períodos, expostas na Figura 10 para a curva de *swap*. Como as IRFs para a ETTJ foram semelhantes, elas foram incorporadas ao exibidas apêndice A), na Figura 16.

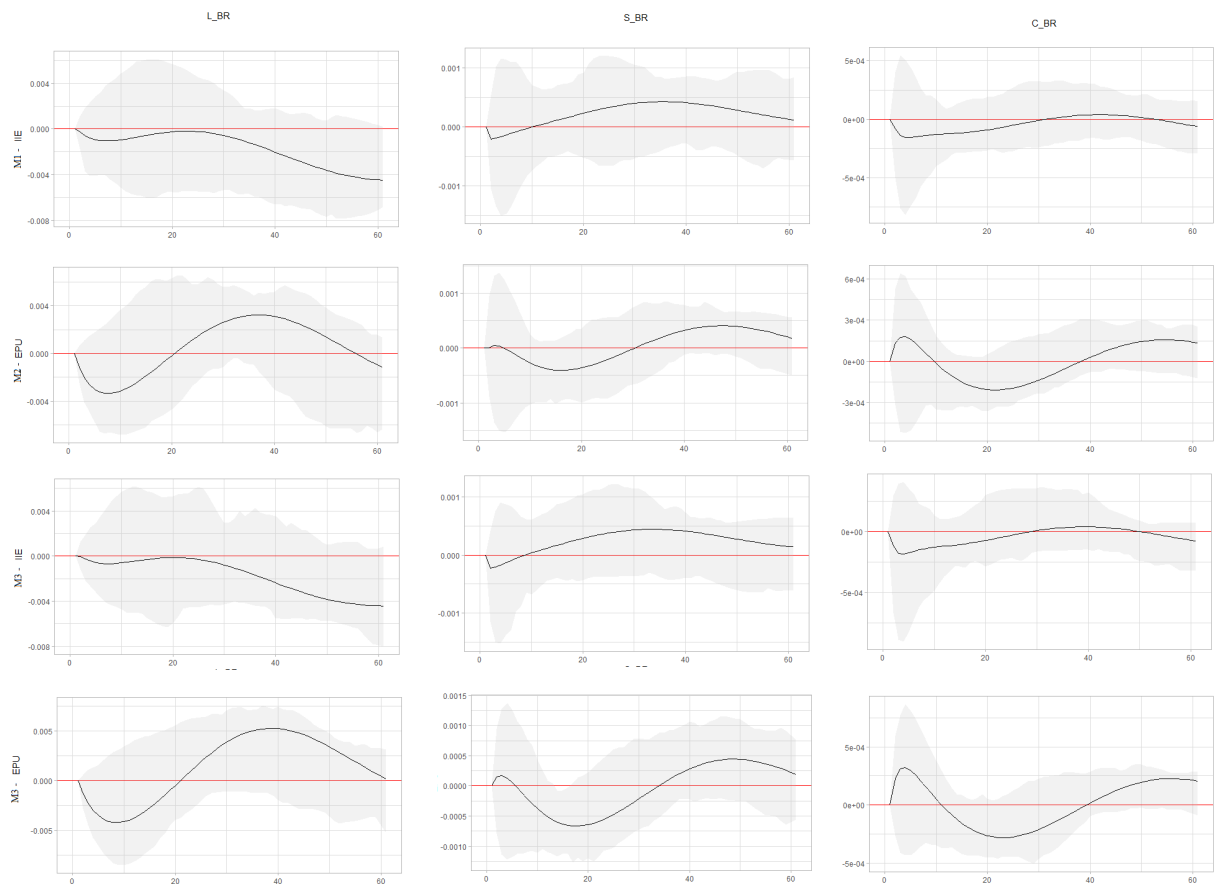
Figura 10 – Resposta de $L_{BR,t}$, $S_{BR,t}$, $C_{BR,t}$ a choques em IIE e EPU (curva de *Swap*)

Fonte: elaboração própria.

Devido à alta variabilidade, essas IRFs não foram significativas. Sem perder isso de foco, alguns apontamentos peculiares podem ser realizados. Primeiramente, o aumento da incerteza causou queda no fator de nível L , assim como em [Jordà e Salyer \(2003\)](#) e em [Leippold e Matthys \(2022\)](#). Desde 2016, intensificando-se em 2018 e ainda mais em 2020, o país registrou quedas seguidas na taxa de juros apesar da alta nos indicadores de incerteza, especialmente o IIE . Isso se deve a relação contracíclica da incerteza econômica, um ponto convergente na literatura empírica. Visando estimular a atividade produtiva, autoridades monetárias buscam reduzir as taxas de juros em períodos de alta incerteza econômica. Adicionalmente, sublinha-se que as cargas no fator S designam uma inclinação negativa. Logo, os choques positivos em S oriundos dos indicadores de incerteza apontaram uma queda na inclinação da curva. Estes resultados reforçam a leitura de que no período amostral houve, em média, queda nos juros acompanhada por alta na incerteza. Assim como constatado em [Azad, Serletis e Xu \(2021\)](#) e em [Janus \(2021\)](#), a pandemia do Covid-19 foi altamente impactante nesses resultados, exemplificando como a percepção de incerteza ultrapassa o quadro econômico, ocorrendo, inclusive, fenômenos com incerteza elevada combinada a juros baixos.

Por fim, a terceira análise confrontou a segunda ao incorporar as variáveis macroeconômicas de controle CRE , INF , CAM e DIV aos modelos M1, M2 e M3. O critério de AIC determinou a estimação de três VAR(1), com resultados de validações (normalidade, não correlação serial e heterocedasticidade) similares aos anteriores. As IRFs para a curva de $swap$ são expostas na Figura 11 - os para a ETTJ constam na Figura 17 (apêndice A).

Figura 11 – Resposta de $L_{BR,t}$, $S_{BR,t}$, $C_{BR,t}$ a choques em IIE e EPU , controlados por variáveis macroeconômicas (curva de $Swap$)



Fonte: elaboração própria.

Frente às IRFs na Figura 10, constata-se uma redução na amplitude dos intervalos de confiança (90%), especialmente nos primeiros períodos, sugerindo uma melhora no ajuste dos modelos. Porém, ainda assim, os resultados não foram significativos. Contrastando a IRF na Figura 9 (com fatores latentes da curva americana), a inserção de variáveis macroeconômicas como controle não foram suficientes para tornar significativos os choques derivados de EPU , mesmo que tenham aproximado mais a forma da IRF em 10 à da em 9. Adicionalmente, a inclusão das variáveis macroeconômicas nos modelos gerou IFRs de choques em IIE com quedas posteriores em L , após cerca de 25 meses. Esse resultado, ainda que não significativo, está alinhado à queda no juros observada nos períodos de alta dos indicadores compostos de incerteza, mais abrangentes que os usais - associados ao risco.

4.5 Análise do poder explicativo das variáveis

Os correlogramas entre as variáveis avaliadas nessa seção se encontram nas figuras 18 e 20 para a curva de *swap* e nas 19 e 21 para a ETTJ, todas no apêndice A. Nestes, destacam-se as diferenças nos resultados entre as duas curvas. Comparado à curva de *swap*, as variáveis exógenas apresentaram correlações relativamente mais fortes com $sp_t(\tau)$ e com $rx_{t,t+12}(\tau)$ na ETTJ. Por sua vez, as variáveis latentes foram mais correlacionadas a $rx_{t,t+12}(\tau)$ na curva de *swap* do que na ETTJ. No geral, as variáveis exógenas apresentaram correlações mais fortes com $sp_t(\tau)$ do que com $rx_{t,t+12}(\tau)$. Os fatores L_{BR} , L_{BRn} e L_{EUA} possuem correlação moderada com $rx_{t,t+12}(\tau)$. Exclusivamente para a ETTJ, S_{EUA} , $EINF$, INF , DIV e EPU também possuem certa correlação com $rx_{t,t+12}(\tau)$.

Para avaliar os fatores de risco mais relevantes para a dinâmica das curvas de juros brasileiras, foram aplicados procedimentos de seleções de variáveis em regressões do *spread* $sp_t(\tau)$ e do excesso de retorno $rx_{t,t+12}(\tau)$, complementando os resultados na seção 4.4. O foco foi avaliar o poder explicativo de diversas variáveis explicativas exploradas na literatura ao controla-las pelas demais. Em linha, adotou-se um procedimento de *stepwise backward*, no qual, a cada interação, foi retirada a variável de pior p-valor considerando quatro regressões, para $\tau = 24, 36, 48$ e 60 . Devido à heterocedasticidade e à correlação serial não terem sido rejeitadas nos testes de Breusch-Pagan e Breusch-Godfrey, a análise da significância dos coeficientes foi realizada através do erro padrão de Newey-West.

As regressões estimadas para os *spreads* ($sp_t(\tau)$), antes e depois do *stepwise backward*, são apresentadas nas tabelas 16 e 17, respectivamente. A ordem de retirada das variáveis explicativas foi:

- Swap DI × Pré: $CRE \rightarrow S_{EUA} \rightarrow L_{EUA} \rightarrow VIX \rightarrow DUR \rightarrow EINF \rightarrow C_{EUA}$; e
- ETTJ: $VIX \rightarrow CRE \rightarrow S_{EUA} \rightarrow L_{EUA} \rightarrow EINF \rightarrow DUR \rightarrow C_{EUA} \rightarrow EPU \rightarrow DIV \rightarrow CAM$.

Ainda, complementarmente, foram implementadas dois processos de seleção de variáveis pautados na qualidade do ajuste do modelo de regressão, o LASSO e o Elastic Net. Estes não avaliam o poder explicativo de cada variáveis individualmente, mas, ao reduzirem o número de variáveis, permitem avaliar a robustez dos resultados do *stepwise backward* quanto ao poder preditivo das variáveis selecionadas. Os resultados dos três procedimentos foram pareados nas tabelas 22 e 23, no apêndice A.

Tabela 16 – Regressões completas de $sp_t(\tau)$

	<i>Swap</i> DI × Pré				ETTJ			
	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)
β_0	-0,261**	-0,430***	-0,551***	-0,630***	-0,289***	-0,446***	-0,548***	-0,617***
L_{EUA}	0,013	0,023	0,037	0,057	0,006	0,033	0,064	0,089
S_{EUA}	-0,047	-0,045	-0,009	0,036	-0,029	0,018	0,088	0,156
C_{EUA}	0,353	0,779*	1,023	1,090	0,621*	0,910	1,001	1,013
UCI	0,196*	0,289**	0,342**	0,378**	0,173*	0,246*	0,295*	0,332**
CRE	-0,005	-0,002	0,001	0,001	0,004	0,009	0,012	0,013
$EINF$	0,232	0,316	0,334	0,342	0,199	0,217	0,187	0,154
INF	-0,166***	-0,300***	-0,394***	-0,460***	-0,223***	-0,349***	-0,417***	-0,455***
CAM	0,011	0,020*	0,029**	0,033**	0,017**	0,028**	0,034***	0,037***
DIV	0,032***	0,049***	0,059**	0,064**	0,034**	0,045**	0,049*	0,050*
DUR	0,006	0,024	0,042	0,052	0,022	0,042	0,055	0,063
IIE	0,038***	0,062***	0,079***	0,094***	0,042***	0,068***	0,086***	0,098***
$EMBI$	0,013	0,024	0,032	0,035	0,018	0,027	0,031	0,033
EPU	-0,010***	-0,012**	-0,012	-0,012	-0,006	-0,006	-0,005	-0,005
VIX	-0,002	-0,003	-0,003	-0,004	-0,001	-0,002	-0,001	-0,001
Obs.	149	149	149	149	149	149	149	149
R^2	0,522	0,567	0,601	0,628	0,610	0,654	0,680	0,694
R^2 aju.	0,472	0,522	0,559	0,589	0,569	0,618	0,646	0,662
Teste F	10,5***	12,6***	14,4***	16,2***	15,0***	18,1***	20,3***	21,7***
Teste BP	40,5***	39,2***	40,4***	40,6***	38,6***	39,9***	40,4***	40,3***
Teste BG	88,5***	92,0***	94,7***	97,3***	94,5***	95,6***	95,6***	95,5***

Nota:

BP = Breusch-Pagan; BG = Breusch-Godfrey

*p<0,1; **p<0,05; ***p<0,01

Fonte: elaboração própria.

Tabela 17 – Regressões reduzidas de $sp_t(\tau)$

	<i>Swap</i> DI × Pré				ETTJ			
	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)
β_0	-0,222***	-0,321***	-0,371***	-0,393***	-0,193**	-0,255**	-0,285*	-0,307*
<i>UCI</i>	0,206***	0,290***	0,321***	0,326**	0,144**	0,171*	0,173	0,172
<i>INF</i>	-0,140***	-0,284***	-0,389***	-0,454***	-0,209***	-0,344***	-0,420***	-0,463***
<i>CAM</i>	0,010	0,018	0,027*	0,032*				
<i>DIV</i>	0,016**	0,021	0,024	0,027				
<i>IIE</i>	0,024*	0,039	0,049	0,059	0,028	0,049*	0,068**	0,083***
<i>EMBI</i>	0,016*	0,025	0,031	0,033	0,016*	0,019	0,019	0,017
<i>EPU</i>	-0,012**	-0,016**	-0,017*	-0,018				
Obs.	149	149	149	149	149	149	149	149
R ²	0,483	0,513	0,541	0,570	0,497	0,558	0,589	0,604
R ² aju.	0,457	0,489	0,518	0,548	0,483	0,545	0,577	0,593
Teste F	18,8***	21,2***	23,8***	26,7***	35,6***	45,4***	51,6***	54,9***
Teste BP	32,9***	39,6***	39,0***	35,2***	38,4***	35,0***	29,3***	24,4***
Teste BG	88,3***	96,7***	102,6***	106,1***	103,2***	104,6***	105,6***	106,3***

Nota:

BP = Breusch-Pagan; BG = Breusch-Godfrey
*p<0,1; **p<0,05; ***p<0,01

Fonte: elaboração própria.

Comparando as seleções de variáveis realizadas pelo LASSO e pelo Elastic Net com as na Tabela 17, os três procedimentos excluíram *EINF* e *VIX* e, ao final, impactaram pouco o R^2 ajustado - vide o pareamento de resultados nas tabelas 22 e 23. Em particular, apesar do foco no ajuste do model, os R^2 ajustados alcançados via LASSO e via Elastic Net foram similares aos obtidos via *stepwise*. Como o *stepwise* retirou um número maior de variáveis, seus resultados foram mais parcimoniosos para as regressões dos *spreads*.

Devido à falta de significância, o *stepwise* retirou *CRE*, *EINF*, *DUR*, *VIX* e os fatores latentes da curva americana (L_{EUA} , S_{EUA} e C_{EUA}) das regressões de *spread* nas duas curvas brasileiras. Ainda, *CAM* e *DIV* se mantiveram significativos para *spreads* específicos da curva de *swap* e *EMBI* foi significativo para $sp_t(24)$ em ambas as curvas. Frente aos resultados na seção 4.4, a inclusão de *UCI* foi particularmente impactante. Na Tabela 12 (curva de *swap*), os *spreads* foram explicados principalmente por *CRE*. Porém, ao incorporar *UCI*, o *stepwise* resultou na exclusão de *CRE* para ambas as curvas. Apesar de *UCI* ser restrito à atividade na Indústria brasileira, destaca-se que a produção nesse setor é vista como indicador antecedente do ciclo econômico e que a Regra de Taylor abarca o hiato na atividade produtiva, para o qual *UCI* é uma *proxy*, não o crescimento. Além disso, *UCI* impactou positivamente os R^2 ajustados baixos para os *spreads* mais curtos da curva de *swap*, tornando-os similares aos valores observados nas demais regressões de *spread*. Essa inclusão também controlou melhor o efeito de outras variáveis para a curva de *swap*, resultando na significância de *CAM*, *DIV* e, especialmente, *EPU* e *INF* - sendo esta a única variável significativa para todos os *spreads* em ambas as curvas brasileiras.

No tocante aos indicadores compostos de incerteza, *IIE* se manteve significativo (tabelas 12 e 17), demarcando seu papel no prêmio de risco, principalmente nos *spreads* mais longos da ETTJ. Após o *stepwise*, *EPU* passou a apresentar coeficientes negativos significativos para a curva de *swap*, apesar da correlação levemente positiva (tabela 18). Isso se deve ao melhor controle das fontes de incerteza, com a manutenção de *DIV*, *IIE*, *EMBI* e *EPU*, associadas ao prêmio de risco. Logo, os efeitos diretos de *EPU* estão associados às curvas de *swap* mais *flat*, ou mesmo negativas, ocorridas durante os períodos de crise global. Adicionalmente, isso também impactou o *IIE* na curva de *swap*, que passou a ser relevante para $sp_t(24)$ mas deixou de ser para $sp_t(60)$.

Por sua vez, as regressões dos excessos de retorno ($rx_{t,t+12}(\tau)$) são apresentadas nas tabelas 18 e 19. A ordem de retirada das variáveis foi:

- Swap DI × Pré: $IIE \rightarrow EMBI \rightarrow PC_{4BR} \rightarrow S_{EUA} \rightarrow S_{BR} \rightarrow EPU \rightarrow PC_{5BR} \rightarrow CRE$;
- ETTJ: $IIE \rightarrow EMBI \rightarrow PC_{4BRn} \rightarrow S_{EUA} \rightarrow EPU$.

O pareamento de resultados dessa seleção com as realizadas pelo LASSO e pelo Elastic Net são apresentadas nas tabelas 24 e 25, no apêndice A.

Tabela 18 – Regressões completas de $rx_{t,t+12}(\tau)$

	<i>Swap</i> DI × Pré				ETTJ			
	<i>rx</i> (24)	<i>rx</i> (36)	<i>rx</i> (48)	<i>rx</i> (60)	<i>rx</i> (24)	<i>rx</i> (36)	<i>rx</i> (48)	<i>rx</i> (60)
β_0	12,921***	22,011***	27,412***	31,927***	12,829***	17,441***	21,119***	26,025***
L_{BR}/L_{BRn}	2,591***	4,919***	6,258***	7,115***	6,012***	7,856***	8,838***	9,333***
S_{BR}/S_{BRn}	-1,410	-1,303	-3,267	-5,647*	2,586***	0,481	-3,162	-7,201***
C_{BR}/C_{BRn}	2,980	20,380***	40,450***	59,593***	11,460***	31,371***	49,557***	66,055***
PC_{4BR}/PC_{4BRn}	-7,764	2,999	12,275	5,391	4,932	12,211	9,965	0,904
PC_{5BR}/PC_{5BRn}	-30,878	-49,077	-56,791	-45,158	-47,995***	-67,237***	-75,558***	-74,824**
$LEUA$	6,180***	13,863***	20,647***	26,441***	6,381***	13,832***	19,542***	24,302***
$SEUA$	3,824	8,776	8,426	5,157	4,709	6,272	3,607	-0,546
$CEUA$	35,159***	71,484***	109,651***	143,218***	33,647***	67,302***	97,330***	122,625***
UCI	-7,170***	-11,555***	-14,737***	-16,975***	-6,028***	-7,776**	-9,387**	-11,979**
CRE	-0,290	-0,930	-1,700	-2,673	-0,323	-1,365*	-2,492***	-3,401***
$EINF$	-7,044	-16,490**	-23,867***	-31,395***	-5,842	-13,190**	-21,171**	-29,827**
INF	1,701	6,832**	14,293***	22,358***	2,951*	9,509***	16,947***	24,632***
CAM	-0,426	-0,875	-1,081	-1,309	-0,535**	-0,865*	-1,131	-1,402
DIV	-1,896**	-3,281**	-3,901**	-4,307**	-1,704***	-2,168***	-2,586***	-3,438***
DUR	-3,321***	-6,206***	-8,233***	-9,984***	-3,323***	-5,429***	-7,053***	-8,683***
IIE	-0,131	-0,130	0,064	0,024	-0,167	-0,004	-0,146	-0,664
$EMBI$	-0,331	-0,466	-0,371	-0,261	-0,233	-0,199	0,038	0,394
EPU	0,142	0,241	0,246	0,216	0,151	0,200	0,255	0,369
VIX	-0,287	-0,552*	-0,707*	-0,771	-0,325**	-0,552**	-0,675*	-0,744
Obs.	137	137	137	137	137	137	137	137
R ²	0,876	0,898	0,907	0,908	0,970	0,954	0,942	0,931
R ² aju.	0,856	0,882	0,892	0,893	0,966	0,947	0,933	0,920
Teste F	43,5***	54,3***	59,9***	60,8***	201,7***	128,6***	100,2***	82,9***
Teste BP	24,3	17,4	15,4	15,2	15,5	13,2	14,8	15,7
Teste BG	56,8***	47,8***	40,7***	35,4***	41,1***	33,0***	29,7***	29,0***

Nota:

BP = Breusch-Pagan; BG = Breusch-Godfrey
*p<0,1; **p<0,05; ***p<0,01

Fonte: elaboração própria.

Tabela 19 – Regressões reduzidas de $rx_{t,t+12}(\tau)$

	<i>Swap</i> DI × Pré				ETTJ			
	<i>rx</i> (24)	<i>rx</i> (36)	<i>rx</i> (48)	<i>rx</i> (60)	<i>rx</i> (24)	<i>rx</i> (36)	<i>rx</i> (48)	<i>rx</i> (60)
β_0	12,258***	23,605***	29,638***	33,711***	12,435***	17,762***	21,875***	26,875***
L_{BR}/L_{BRn}	1,908***	3,772***	5,043***	5,919***	5,456***	7,294***	8,584***	9,414***
S_{BRn}					3,350***	1,415	-2,606*	-7,207***
C_{BR}/C_{BRn}	3,906**	20,237***	41,497***	63,335***	11,674***	31,151***	49,417***	66,634***
PC_{5BRn}					-48,842***	-67,759***	-76,641***	-77,353**
$LEUA$	6,522***	12,916***	19,761***	26,468***	6,093***	12,944***	18,661***	23,878***
$CEUA$	37,989***	83,787***	119,077***	141,469***	38,562***	75,240***	103,484***	124,843***
UCI	-7,372***	-14,524***	-18,125***	-19,992***	-5,925***	-8,111***	-9,870***	-12,487***
CRE					-0,502	-1,634**	-2,664***	-3,372***
$EINF$	-6,834	-14,447*	-17,656**	-22,066***	-3,721	-9,856*	-18,275**	-27,768**
INF	3,367*	8,823***	15,953***	23,858***	3,080**	9,242***	16,426***	24,150***
CAM	-0,181	-0,544*	-0,685	-0,844	-0,444***	-0,798**	-1,188**	-1,637**
DIV	-2,161***	-3,882***	-4,305***	-4,652***	-1,765***	-2,022***	-2,428**	-3,457**
DUR	-3,323***	-6,336***	-8,407***	-10,196***	-3,534***	-5,631***	-7,225***	-8,870***
VIX	-0,259	-0,504*	-0,541	-0,484	-0,358**	-0,555**	-0,622**	-0,624
Obs.	137	137	137	137	137	137	137	137
R ²	0,864	0,890	0,901	0,902	0,969	0,953	0,941	0,930
R ² aju.	0,852	0,881	0,892	0,893	0,965	0,947	0,935	0,922
Teste F	72,3***	92,3***	103,4***	104,527***	271,6***	175,9***	140,2***	116,6***
Teste BP	15,5	12,6	9,5	8,3	13,4	12,9	13,4	14,3
Teste BG	54,2***	42,4***	35,3***	33,4***	31,0***	24,6***	24,9***	27,7***

Nota:

BP = Breusch-Pagan; BG = Breusch-Godfrey

*p<0,1; **p<0,05; ***p<0,01

Fonte: elaboração própria.

Contra-pondo o constatado para as regressões de *spread*, no *stepwise*, também foi observado um número maior de variáveis predictoras significativas para $rx_{t,t+12}(\tau)$, especialmente para a ETTJ. Isso não só resultou em R^2 s ajustados altos com, principalmente, corrobora fortemente com as evidências contrárias à hipótese de *spanning* da curva de juros - segundo, a qual, os fatores latentes cobrem todo (ou quase todo) o conteúdo informacional necessário para prever o movimento da curva. Mais precisamente, o poder preditivo associado aos fatores latentes foram destacados em L e C , tanto da própria curva quanto da curva de juros americana, e, especificamente para a ETTJ, em PC_{5BRn} . Adicionalmente, sem deixar de destacar a relevância do quadro econômico como um todo, UCI foi significativa que CRE enquanto INF foi mais que $EINF$. Portanto, assim como nas regressões de *spread*, UCI e INF apresentaram melhores resultados enquanto *proxies* para capturar efeitos da atividade econômica e da inflação, respectivamente, sobre a curva de juros - frente às alternativas, CRE e $EINF$.

Comparativamente, os métodos de LASSO e de Elastic Net excluíram um pouco mais de variáveis do que o *stepwise* (tabelas 24 e 25), oposto ao observado para as regressões de *spread*. Todavia, destaca-se que os três métodos de seleção de variáveis foram unânimes ao retirar S_{EUA} e IIE como variáveis preditiva para qualquer excesso de retorno nas duas curvas brasileiras, com IIE sendo a primeira variável a ser retirada para as duas curvas de juros. Desse modo, foram reforçados os resultados na seção 4.4 e nas IRFs (Figuras 10, 16, 11 e 17), de que IIE não possui poder preditivo sobre os excessos de retornos e os fatores latentes das curvas de juros brasileira. Quanto às demais *proxies* de incerteza, $EMBI$ e EPU foram mantidas para poucas regressões de $rx_{t,t+12}(\tau)$ no LASSO ou no Elastic Net, mas não foram significativas em qualquer regressão reduzida pelo *stepwise*. Um caso a parte foi VIX , significativo para alguns excessos de retorno em ambas as curvas.

Isto posto, cabe ressaltar que os procedimentos de seleção de variáveis adotados não refutam as teorias vinculadas às respectivas variáveis. Eles são, essencialmente, procedimentos de mineração de dados que auxiliam a prática de se modelar as curvas de juros, ou prevê-las, recorrendo a variáveis auxiliares. Em especial, uma variável pode ter contribuições restritas a contextos específicos, como a previsão da curva, a forma funcional dela ou a identificação do prêmio de risco. Por exemplo, os indicadores compostos de incerteza EPU e, principalmente, IIE estão relacionados à forma funcional corrente da curva de juros brasileira, impactando o prêmio de risco embutido nas taxas *spot* de vencimentos maiores. Por outro lado, EPU e IIE não apresentaram indícios de poder preditivos acerca da forma funcional ou de prêmios de risco nas curva de juros em períodos futuros. Dessa forma, em um sistema de equações mais abrangente como os DTSMs, é possível que os indicadores compostos de incerteza auxiliem na previsão da dinâmica da curva de juros, não por possuírem poder preditivo sobre essa dinâmica, mas por melhorarem o ajuste interno do modelo, propiciando maior capacidade preditiva deste como um todo. Essa possibilidade é verificada na seção seguinte, a 4.6.

4.6 Impacto informacional dos indicadores de incerteza em DTSMs

Conforme a metodologia proposta na seção 3.3.5, o impacto informacional dos indicadores de incerteza foi avaliado ao comparar DTSM contendo esses indicadores frente a dois modelos macro-financeiros de referência, denominados M0. O primeiro contempla o quadro econômico brasileiro e, seguindo os resultados na seção 4.5, contempla os fatores exógenos de risco $Z_t = [UCI_t \ INF_t \ CAM_t \ DIV_{t,EUA}]'$, os quais balizam as decisões de política monetária do Copom. O segundo considera a influência da curva americana sobre a brasileira, incorporando os fatores exógenos de risco $Z_t = [L_{t,EUA} \ S_{t,EUA} \ C_{t,EUA}]'$.

Esses dois modelos bases foram confrontados com versões mais abrangentes, que incorporam indicadores de incerteza como fatores de risco em X_t . São estes:

M1 - com $X_t = [L_t \ S_t \ C_t \ Z_t \ IIE_t]'$;

M2 - com $X_t = [L_t \ S_t \ C_t \ Z_t \ EPU_t]'$;

M3 - com $X_t = [L_t \ S_t \ C_t \ Z_t \ IIE_t \ EPU_t]'$.

Portanto, os modelos de referência (M0) são versões restritas dos respectivos M1, M2 e M3. Permitindo, assim, a adoção do teste de razão de verossimilhança (LR).

As verossimilhanças de cada DTSM assim como o p -valor do teste LR contra o respectivo modelo restrito M0 são apresentados nas tabelas 20 e 21.

Tabela 20 – Teste LR dos DTSMs (*Swap* DI × Pré)

	$Z_t=(UCI,INF,CAM,DIV)$		$Z_t=(L_{EUA},S_{EUA},C_{EUA})$	
	llk	LR (p-valor)	llk	LR (p-valor)
M0	14392,94		14393,76	
M1	14789,54	0,000	14914,89	0,000
M2	14590,50	0,000	14696,77	0,000
M3	14946,65	0,000	15045,35	0,000

Nota: llk = log-verossimilhança e LR = razão de verossimilhança.

Fonte: elaboração própria.

Tabela 21 – Teste LR dos DTSMs (ETTJ)

	$Z_t=(UCI,INF,CAM,DIV)$		$Z_t=(L_{EUA},S_{EUA},C_{EUA})$	
	llk	LR (p-valor)	llk	LR (p-valor)
M0	14216,55		14298,10	
M1	14625,84	0,000	14695,43	0,000
M2	14414,22	0,000	14538,13	0,000
M3	14803,83	0,000	14932,31	0,000

Nota: llk = log-verossimilhança e LR = razão de verossimilhança.

Fonte: elaboração própria.

Em todos os modelos, rejeitou-se fortemente a hipótese nula de que a restrição é válida. Portanto, há ganhos de desempenho no ajuste de DTSMs macro-financeiros ao incluir indicadores de incerteza na política econômica como um dos fatores de risco em X_t . Ainda, o ganho de desempenho ao incorporar o *IIE* é expressivamente maior do que proporcionado por *EPU*, tanto na curva de *swap* quanto na ETTJ. Esse resultado corrobora com a relevância dos indicadores de incerteza ao modelar a curva de juros, mas também confronta o baixo desempenho deles nas regressões preditivas de $rx_{t,t+12}$ e nos IRFs (seção 4.4). Os VAR(1) na seção 4.4 são similares à equação de transição dos fatores de risco no DTSM. Essencialmente, a diferença entre as duas abordagens está na restrição de não-arbitragem imposta ao VAR. Conforme os resultados anteriores, esses indicadores não possuem poder preditivos sobre os fatores latentes, que descrevem a forma funcional da curva em períodos posteriores. Por outro lado, os bons resultados para as regressões dos *spreads* (seções 4.4 e 4.5) combinados ao impacto informacional nos DTSMs estimados sugerem que esses indicadores são relevantes para a precificação dos prêmios de risco na curva corrente e, conseqüentemente, a identificação das expectativas de taxas futuras contidas nas curvas de juros.

5 CONCLUSÃO

Como elencando em Piazzesi (2010), entender a dinâmica da curva juros auxilia a previsão da taxa de juros, a precificação de derivativos, a análise da dívida pública e a da política monetária. Como a curva contempla expectativas acerca de atuações futuras dos bancos centrais, desde Ang e Piazzesi (2003) a literatura vem adotando tanto fatores latentes quanto fatores macroeconômicos para modelá-la. Mais recentemente, trabalhos como Ioannidis e Ka (2021) e Leippold e Matthys (2022) também têm explorado impactos da incerteza na política econômica sobre a curva de juros. Nesse contexto, esta tese buscou explorar em que medida indicadores de incerteza efetivamente contribuem em termos informacionais para modelar a curva de juros.

Ao conceituar a incerteza, Bloom (2014) defendeu que ela deve refletir a percepção acerca do futuro na mente dos agentes, o que perpassa por muitos aspectos, econômicos e não econômicos. Visando mitigar as limitações das *proxies* usuais em capturar a abrangência desse conceito, a literatura recente tem desenvolvido indicadores compostos para avaliar a incerteza na política econômica, tais como o EPU de Baker, Bloom e Davis (2016) e o IIE-Br de Ferreira et al. (2019), adotados nesta tese. O período amostral estudado, fev./2010 a jun./2022, exemplificou o impacto em se adotar indicadores mais abrangentes. Especialmente com a pandemia da Covid-19, foram registradas altas no EPU e no IIE-Br acompanhadas por quedas no mercado de juros - fenômeno similar ao registrado em Azad, Serletis e Xu (2021) e Janus (2021) para outros países. Conseqüentemente, as correlações entre os indicadores de incerteza e o fator de nível (L) da curva brasileira foram negativas, o que não aconteceu com outras *proxies* de incerteza como o EMBI+Br e o VIX. Essa correlação negativa se estendeu para os resultados das regressões e dos vetores autorregressivos, onde os impactos do EPU e do IIE-Br foram negativos.

Isso não quer dizer que há uma relação causal na qual o aumento na incerteza gera a queda no juros, nem mesmo que a incerteza não tenha impacto na precificação de ativos, sendo uma correlação espúria. Todavia, esse fenômeno corrobora com a definição de incerteza de Bloom (2014) e a necessidade de explorar uma visão mais abrangente acerca desse conceito. Os impactos da incerteza sobre a economia brasileira foram extensos ao longo da pandemia. A queda no juros foi proveniente da atuação das autoridades monetárias no mundo para estimular a atividade econômica, paralisada por *lockdowns*, problemas de logística e precaução dos agentes econômicos diante da incerteza que se instaurou. Nesse contexto macroeconômico, torna-se mais difícil segregar quantitativamente as causas da incerteza ou o que causa ela.

Buscando explorar essas nuances, uma série de procedimentos econométricos foram

utilizados nesta tese. Em síntese, os indicadores compostos de incerteza não apresentaram poder preditivo, principalmente para os excessos de retorno. Quanto a propagação de choques nas curvas de juros brasileiras ao longo do tempo, apenas o indicador de incerteza na política americana apresentou um impacto significativo, mas leve, sobre os fatores latentes que sintetizam a forma funcional das curvas de juros brasileiras em cada período. Por outro lado, o indicador de incerteza na política brasileira foi impactante nos *spreads* da curva brasileira, especialmente a estrutura a termo dos títulos soberanos, enquanto o indicador americano foi significativo para *spreads* na curva de *Swap* DI \times Pré. Em especial, o teste da razão de verossimilhança reportou ganhos significativos no ajuste de modelos dinâmicos de curva de juros ao se incorporar *proxies* de incerteza, especialmente o IIE-Br. Como os modelos dinâmicos essencialmente adicionam a restrição de não arbitragem ao vetor autorregressivo dos fatores de risco, o ganho informacional se deve a melhora do ajuste na restrição de precificação. Dessa forma, em resposta ao objetivo dessa tese, os resultados corroboraram com a ideia de que os indicadores de incerteza na política econômica não tem poder preditivo acerca dos fatores que descrevem a forma funcional das curvas de juros. Todavia, eles possuem conteúdo informacional relevante para precificar a curva, melhorando a segregação entre expectativas e prêmio de risco. Permitindo, assim, o melhor ajuste em modelos dinâmicos. Adicionalmente, a análise de *spillover* e as IRFs demonstraram certa independência nas variações da incerteza brasileira frente a choques oriundos da americana. Portanto, ambas agregam informação de fontes relativamente distintas.

Ainda, ao longo das análises nesta tese, os procedimentos realizados corroboraram com resultados que ultrapassaram o foco desta tese, a incerteza, mas atenderam a objetivos específicos que contribuem para a literatura de curva de juros brasileira. A comparação entre a curva de *Swap* DI \times Pré e a ETTJ estimada pela ANBIMA corroborou com a aderência no funcional destas de forma contemporânea, com correlações quase perfeitas entre os fatores de nível L , inclinação S e curvatura C . Além disso, a análise do *spillover* entre elas não só reforçou a conectividade entre as duas como exibiu um padrão equilibrado na transmissão e na recepção de choques. Logo, não há, entre elas, uma que antecipe os choques no mercado, propagando-os a outra posteriormente. Ainda assim, pontua-se que a ETTJ se mostrou mais sensível às variáveis explicativas exógenas. Por sua vez, a avaliação de *spillovers* de choques americanos sobre a curva brasileira complementou o estudo de Cavaca e Meurer (2021) ao avaliar, inclusive, efeitos de *spillover* oriundos da incerteza na política econômica americana. O *spillover* da incerteza americana sobre os fatores latentes brasileiros foi expressivamente maior que o originado na incerteza brasileira, mas o *spillover* da primeira sobre a incerteza brasileira foi baixo. Complementarmente, os choques propagados da curva ou da incerteza americana para a curva brasileira registraram maior efeito em períodos posteriores, quando efeitos indiretos se propagam ao longo do sistema de variáveis - mesmo quando se utiliza variáveis macroeconômicas como controle.

Isto posto, uma limitação desta tese foi o histórico curto de dados, demarcado pelo quadro de queda no juro com alta na incerteza. Este problema é especialmente impactante ao estimar modelos como os dinâmicos de curva de juro, onde há uma quantidade maior de parâmetros a serem estimados. Outro aspecto limitador passou pelo *trade-off* entre interpretação e adequação econométrica. Como as autoridades estão preocupadas com os choques nas séries, sem transformá-las, essa literatura tem utilizado modelos temporais onde as séries não são estacionárias - ou têm memória longa. Por fim, a combinação de poucos dados, muitos parâmetros e demandas interpretativas tem levado à adoção de modelos menos complexos, em detrimento a ajustes que normalmente ocorreriam nesse perfil de dados, como a possibilidade de cointegração das séries ou a adoção de uma abordagem condicionada à heterocedasticidade.

Em linha, a título de pesquisa futura, fica em aberto o estudo acerca dessa temática considerando outros aspectos, tais como: possíveis impactos nos resultados ao se adotar modelos de *Zero Lower Bound*, como os de [Christensen e Rudebusch \(2016\)](#) e [Wu e Zhang \(2019\)](#); ou a adoção de modelos dinâmicos condicionados à heterocedasticidade, como o de [Creal e Wu \(2017\)](#).

Referências

- AASTVEIT, K. A.; NATVIK, G. J.; SOLA, S. Economic uncertainty and the influence of monetary policy. *Journal of International Money and Finance*, v. 76, p. 50–67, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0261560617300943>>. Citado 2 vezes nas páginas 61 e 66.
- ABBRIITI, M. et al. Global factors in the term structure of interest rates. *International Journal of Central Banking*, International Journal of Central Banking, v. 14, n. 2, p. 301–340, 2018. Citado 2 vezes nas páginas 21 e 56.
- AÏT-SAHALIA, Y.; KIMMEL, R. L. The econometrics of fixed-income markets. In: VERONESI, P. (Ed.). *Handbook of Fixed-Income Securities*. [S.l.]: Wiley Online Library, 2016. p. 265–281. Citado na página 50.
- AIZENMAN, J.; CHINN, M. D.; ITO, H. Monetary policy spillovers and the trilemma in the new normal: Periphery country sensitivity to core country conditions. *Journal of International Money and Finance*, Elsevier, v. 68, p. 298–330, 2016. Citado na página 22.
- ALBUQUERQUE, R. et al. Valuation risk and asset pricing. *The Journal of Finance*, Wiley Online Library, v. 71, n. 6, p. 2861–2904, 2016. Citado 2 vezes nas páginas 19 e 26.
- ALMEIDA, C. et al. Forecasting Bond Yields with Segmented Term Structure Models*. *Journal of Financial Econometrics*, v. 16, n. 1, p. 1–33, 02 2017. Disponível em: <<https://doi.org/10.1093/jjfinec/nbx002>>. Citado na página 31.
- ALMEIDA, C.; FARIA, A. Forecasting the Brazilian term structure using macroeconomic factors. *Brazilian Review of Econometrics*, v. 34, n. 1, p. 45–77, 2014. Citado 2 vezes nas páginas 28 e 52.
- AMARAL, J. M. T. d. *Fatores globais e regionais na estrutura a termo da taxa de juros: o caso da América Latina*. Dissertação (Mestrado), 2019. Citado na página 59.
- ANAYA, P.; HACHULA, M.; OFFERMANN, C. J. Spillovers of US unconventional monetary policy to emerging markets: The role of capital flows. *Journal of International Money and Finance*, Elsevier, v. 73, p. 275–295, 2017. Citado na página 22.
- Andreotti Filho, R. A. *Prêmio de risco da taxa de juros brasileira: uma abordagem com fatores macroeconômicos*. Dissertação (Mestrado), 2021. Citado 3 vezes nas páginas 52, 72 e 74.
- ANG, A.; BEKAERT, G.; WEI, M. The term structure of real rates and expected inflation. *The Journal of Finance*, v. 63, n. 2, p. 797–849, 2008. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1540-6261.2008.01332.x>>. Citado na página 64.
- ANG, A.; PIAZZESI, M. A no-arbitrage vector autoregression of term structure dynamics with macroeconomic and latent variables. *Journal of Monetary Economics*, Elsevier, v. 50, n. 4, p. 745–787, 2003. Citado 13 vezes nas páginas 18, 19, 40, 44, 46, 48, 50, 52, 56, 70, 71, 72 e 117.

- ANTONAKAKIS, N.; CHATZIANTONIOU, I.; FILIS, G. Dynamic co-movements of stock market returns, implied volatility and policy uncertainty. *Economics Letters*, v. 120, n. 1, p. 87–92, 2013. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0165176513001754>>. Citado na página 18.
- AZAD, N. F.; SERLETIS, A.; XU, L. Covid-19 and monetary–fiscal policy interactions in canada. *The Quarterly Review of Economics and Finance*, v. 81, p. 376–384, 2021. ISSN 1062-9769. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1062976921001095>>. Citado 2 vezes nas páginas 106 e 117.
- BAKER, S. R.; BLOOM, N.; DAVIS, S. J. Measuring Economic Policy Uncertainty. *The Quarterly Journal of Economics*, v. 131, n. 4, p. 1593–1636, 07 2016. Disponível em: <<https://doi.org/10.1093/qje/qjw024>>. Citado 8 vezes nas páginas 6, 7, 18, 20, 60, 62, 75 e 117.
- BAKER, S. R. et al. *Policy News and Stock Market Volatility*. [S.l.], 2019. (Working Paper Series, 25720). Disponível em: <<http://www.nber.org/papers/w25720>>. Citado na página 66.
- BARBOZA, R. d. M.; ZILBERMAN, E. Os efeitos da incerteza sobre a atividade econômica no Brasil. *Revista Brasileira de Economia*, SciELO Brasil, v. 72, n. 2, p. 144–160, 2018. Citado 2 vezes nas páginas 62 e 73.
- BASU, S.; BUNDICK, B. Uncertainty shocks in a model of effective demand. *Econometrica*, Wiley Online Library, v. 85, n. 3, p. 937–958, 2017. Citado 2 vezes nas páginas 18 e 60.
- BAUER, G. H.; RIOS, A. Diez de los. *An international dynamic term structure model with economic restrictions and unspanned risks*. [S.l.], 2012. Citado 2 vezes nas páginas 21 e 57.
- BAUER, M. D. Restrictions on risk prices in dynamic term structure models. *Journal of Business & Economic Statistics*, Taylor & Francis, v. 36, n. 2, p. 196–211, 2018. Disponível em: <<https://doi.org/10.1080/07350015.2016.1164707>>. Citado 2 vezes nas páginas 40 e 43.
- BAUER, M. D.; HAMILTON, J. D. Robust bond risk premia. *The Review of Financial Studies*, v. 31, n. 2, p. 399–448, 09 2018. Disponível em: <<https://doi.org/10.1093/rfs/hhx096>>. Citado 9 vezes nas páginas 18, 20, 46, 69, 70, 71, 72, 74 e 81.
- BAUER, M. D.; RUDEBUSCH, G. D. Resolving the spanning puzzle in macro-finance term structure models. *Review of Finance*, Oxford University Press, v. 21, n. 2, p. 511–553, 2017. Citado 10 vezes nas páginas 18, 19, 32, 48, 51, 52, 70, 71, 72 e 85.
- BAZ, J.; DAS, S. R. Analytical approximations of the term structure for jump-diffusion processes: a numerical analysis. *The Journal of Fixed Income*, Institutional Investor Journals Umbrella, v. 6, n. 1, p. 78–86, 1996. Citado na página 34.
- BENLAGHA, N.; HEMRIT, W. Does economic policy uncertainty matter to explain connectedness within the international sovereign bond yields? *Journal of Economics and Finance*, Springer, v. 46, n. 1, p. 1–21, 2022. Citado 3 vezes nas páginas 22, 67 e 68.

- BERNZ, B. M. *Modelo Nelson-Siegel dinâmico da estrutura a termo da taxa de juros com fatores exógenos macroeconômicos: uma aplicação ao mercado brasileiro*. Dissertação (Mestrado), 2014. Citado na página 52.
- BIKBOV, R.; CHERNOV, M. No-arbitrage macroeconomic determinants of the yield curve. *Journal of Econometrics*, Elsevier, v. 159, n. 1, p. 166–182, 2010. Citado 3 vezes nas páginas 70, 71 e 72.
- BINSBERGEN, J. H. V.; KOIJEN, R. S. The term structure of returns: Facts and theory. *Journal of Financial Economics*, Elsevier, v. 124, n. 1, p. 1–21, 2017. Citado 2 vezes nas páginas 19 e 26.
- BLACK, F.; DERMAN, E.; TOY, W. A one-factor model of interest rates and its application to treasury bond options. *Financial analysts journal*, Taylor & Francis, v. 46, n. 1, p. 33–39, 1990. Citado na página 36.
- BLOOM, N. The impact of uncertainty shocks. *Econometrica*, v. 77, n. 3, p. 623–685, 2009. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.3982/ECTA6248>>. Citado 3 vezes nas páginas 20, 59 e 60.
- BLOOM, N. Fluctuations in uncertainty. *Journal of Economic Perspectives*, v. 28, n. 2, p. 153–76, 2014. Citado 5 vezes nas páginas 18, 60, 61, 81 e 117.
- BRACE, A.; ATAREK, D. G.; MUSIELA, M. The market model of interest rate dynamics. *Mathematical finance*, Wiley Online Library, v. 7, n. 2, p. 127–155, 1997. Citado na página 34.
- CAGGIANO, G.; CASTELNUOVO, E.; FIGUERES, J. M. Economic policy uncertainty spillovers in booms and busts. *Oxford Bulletin of Economics and Statistics*, Wiley Online Library, v. 82, n. 1, p. 125–155, 2020. Citado 2 vezes nas páginas 22 e 67.
- CALDEIRA, J.; MOURA, G. V.; PORTUGAL, M. S. Efficient yield curve estimation and forecasting in Brazil. *Revista Economia*, v. 11, n. 1, p. 27–51, 2010. Citado na página 28.
- CALDEIRA, J. F. et al. Forecasting the yield curve with the arbitrage-free dynamic Nelson-Siegel model: Brazilian evidence. *Economia*, Elsevier, v. 17, n. 2, p. 221–237, 2016. Citado 2 vezes nas páginas 28 e 45.
- CANOVA, F. The transmission of US shocks to Latin America. *Journal of Applied econometrics*, Wiley Online Library, v. 20, n. 2, p. 229–251, 2005. Citado na página 57.
- CARRIÈRE-SWALLOW, Y.; CÉPEDES, L. F. The impact of uncertainty shocks in emerging economies. *Journal of International Economics*, v. 90, n. 2, p. 316–325, 2013. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0022199613000305>>. Citado 2 vezes nas páginas 22 e 60.
- CARRIERO, A.; CLARK, T. E.; MARCELLINO, M. Measuring uncertainty and its impact on the economy. *Review of Economics and Statistics*, MIT Press, v. 100, n. 5, p. 799–815, 2018. Citado 2 vezes nas páginas 18 e 60.
- CARRIERO, A.; CLARK, T. E.; MARCELLINO, M. Assessing international commonality in macroeconomic uncertainty and its effects. *Journal of Applied Econometrics*, v. 35, n. 3, p. 273–293, 2020. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/jae.2750>>. Citado 3 vezes nas páginas 20, 59 e 67.

- CAVACA, I. B.; MEURER, R. International monetary policy spillovers: Linkages between U.S. and South American yield curves. *International Review of Economics & Finance*, v. 76, p. 737–754, 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1059056021001507>>. Citado 12 vezes nas páginas 18, 21, 57, 58, 59, 68, 70, 72, 74, 77, 79 e 118.
- CHOUDHRY, M. *Analysing and interpreting the yield curve*. [S.l.]: John Wiley & Sons, 2019. Citado 5 vezes nas páginas 23, 28, 33, 34 e 37.
- CHRISTENSEN, J. H.; DIEBOLD, F. X.; RUDEBUSCH, G. D. The affine arbitrage-free class of nelson-siegel term structure models. *Journal of Econometrics*, Elsevier, v. 164, n. 1, p. 4–20, 2011. Citado 3 vezes nas páginas 19, 26 e 45.
- CHRISTENSEN, J. H.; RUDEBUSCH, G. D. *Modeling yields at the zero lower bound: Are shadow rates the solution?* [S.l.]: Emerald Group Publishing Limited, 2016. Citado na página 119.
- CHRISTENSEN, J. H. E.; DIEBOLD, F. X.; RUDEBUSCH, G. D. An arbitrage-free generalized Nelson-Siegel term structure model. *The Econometrics Journal*, [Royal Economic Society, Wiley], v. 12, n. 3, p. C33–C64, 2009. Disponível em: <<http://www.jstor.org/stable/23116046>>. Citado na página 45.
- COCHRANE, J. H. *Asset pricing: Revised edition*. [S.l.]: Princeton university press, 2005. Citado na página 29.
- COCHRANE, J. H. Presidential address: Discount rates. *The Journal of finance*, Wiley Online Library, v. 66, n. 4, p. 1047–1108, 2011. Citado 2 vezes nas páginas 26 e 30.
- COCHRANE, J. H. Macro-finance. *Review of Finance*, Oxford University Press, v. 21, n. 3, p. 945–985, 2017. Citado na página 50.
- COCHRANE, J. H.; PIAZZESI, M. Bond risk premia. *American Economic Review*, v. 95, n. 1, p. 138–160, 2005. Citado 4 vezes nas páginas 49, 72, 81 e 95.
- COLOMBO, V. Economic policy uncertainty in the US: Does it matter for the Euro area? *Economics Letters*, v. 121, n. 1, p. 39 – 42, 2013. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0165176513003066>>. Citado 2 vezes nas páginas 22 e 67.
- COOPER, I.; PRIESTLEY, R. Time-Varying Risk Premiums and the Output Gap. *The Review of Financial Studies*, v. 22, n. 7, p. 2801–2833, 10 2008. Disponível em: <<https://doi.org/10.1093/rfs/hhn087>>. Citado na página 48.
- COX, J. C.; INGERSOLL, J. E.; ROSS, S. A. A re-examination of traditional hypotheses about the term structure of interest rates. *The Journal of Finance*, Wiley Online Library, v. 36, n. 4, p. 769–799, 1981. Citado 3 vezes nas páginas 29, 34 e 40.
- CREAL, D. D.; WU, J. C. Monetary policy uncertainty and economic fluctuations. *International Economic Review*, Wiley Online Library, v. 58, n. 4, p. 1317–1354, 2017. Citado 8 vezes nas páginas 18, 63, 65, 68, 70, 71, 72 e 119.
- CULBERTSON, J. M. The Term Structure of Interest Rates. *The Quarterly Journal of Economics*, v. 71, n. 4, p. 485–517, 08 1957. Disponível em: <<https://doi.org/10.2307/1885708>>. Citado na página 53.

- DAI, Q.; SINGLETON, K. J. Specification analysis of affine term structure models. *The Journal of Finance*, v. 55, n. 5, p. 1943–1978, 2000. Citado 2 vezes nas páginas 36 e 40.
- DAS, S. R.; FORESI, S. Exact solutions for bond and option prices with systematic jump risk. *Review of derivatives research*, Springer, v. 1, n. 1, p. 7–24, 1996. Citado na página 34.
- DEMIR, E.; ERSAN, O. Economic policy uncertainty and cash holdings: Evidence from BRIC countries. *Emerging Markets Review*, Elsevier, v. 33, p. 189–200, 2017. Citado 3 vezes nas páginas 22, 61 e 67.
- DIEBOLD, F. X.; LI, C. Forecasting the term structure of government bond yields. *Journal of econometrics*, Elsevier, v. 130, n. 2, p. 337–364, 2006. Citado 10 vezes nas páginas 18, 34, 35, 37, 39, 43, 44, 45, 50 e 57.
- DIEBOLD, F. X.; LI, C.; YUE, V. Z. Global yield curve dynamics and interactions: a dynamic Nelson-Siegel approach. *Journal of Econometrics*, Elsevier, v. 146, n. 2, p. 351–363, 2008. Citado 2 vezes nas páginas 55 e 56.
- DIEBOLD, F. X.; PIAZZESI, M.; RUDEBUSCH, G. D. Modeling bond yields in finance and macroeconomics. *American Economic Review*, v. 95, n. 2, p. 415–420, 2005. Citado 2 vezes nas páginas 19 e 51.
- DIEBOLD, F. X.; RUDEBUSCH, G. D. *Yield curve modeling and forecasting: the dynamic Nelson-Siegel approach*. [S.l.]: Princeton University Press, 2013. Citado 3 vezes nas páginas 36, 45 e 50.
- DIEBOLD, F. X.; RUDEBUSCH, G. D.; ARUOBA, S. B. The macroeconomy and the yield curve: a dynamic latent factor approach. *Journal of econometrics*, Elsevier, v. 131, n. 1-2, p. 309–338, 2006. Citado 9 vezes nas páginas 36, 45, 50, 51, 57, 69, 70, 71 e 72.
- DIEBOLD, F. X.; YILMAZ, K. Measuring financial asset return and volatility spillovers, with application to global equity markets. *The Economic Journal*, v. 119, n. 534, p. 158–171, 1 2009. Disponível em: <<https://doi.org/10.1111/j.1468-0297.2008.02208.x>>. Citado 5 vezes nas páginas 58, 59, 77, 78 e 79.
- DIEBOLD, F. X.; YILMAZ, K. Better to give than to receive: Predictive directional measurement of volatility spillovers. *International Journal of Forecasting*, v. 28, n. 1, p. 57–66, 2012. Special Section 1: The Predictability of Financial Markets Special Section 2: Credit Risk Modelling and Forecasting. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S016920701100032X>>. Citado 7 vezes nas páginas 58, 59, 67, 68, 77, 78 e 79.
- DOH, T. The efficacy of large-scale asset purchases at the zero lower bound. *Federal Reserve Bank of Kansas City Economic Review*, Citeseer, v. 95, n. 2, p. 5–34, 2010. Citado na página 54.
- DUFFEE, G. R. Term premia and interest rate forecasts in affine models. *The Journal of Finance*, Wiley Online Library, v. 57, n. 1, p. 405–443, 2002. Citado 4 vezes nas páginas 19, 40, 42 e 49.
- DUFFEE, G. R. Bond pricing and the macroeconomy. In: ARROW, K. J.; INTRILIGATOR, M. D. (Ed.). *Handbook of the economics of finance*. [S.l.]: Elsevier, 2013. v. 2, p. 907–967. Citado 2 vezes nas páginas 23 e 48.

- DUFFEE, G. R. Forecasting interest rates. In: ELLIOTT, G.; TIMMERMANN, A. (Ed.). *Handbook of economic forecasting*. [S.l.]: Elsevier, 2013. v. 2, p. 385–426. Citado 7 vezes nas páginas 19, 32, 40, 45, 48, 50 e 51.
- DUFFIE, D.; KAN, R. A yield-factor model of interest rates. *Mathematical finance*, Wiley Online Library, v. 6, n. 4, p. 379–406, 1996. Citado 3 vezes nas páginas 36, 40 e 45.
- ESTRELLA, A.; MISHKIN, F. S. Predicting US recessions: Financial variables as leading indicators. *Review of Economics and Statistics*, MIT Press, v. 80, n. 1, p. 45–61, 1998. Citado na página 50.
- FABOZZI, F. J. *The handbook of fixed income securities*. [S.l.]: McGraw-Hill, 2012. Citado na página 27.
- FABOZZI, F. J. *Bond markets, analysis and strategies*. [S.l.]: Prentice Hall, 2013. Citado 6 vezes nas páginas 23, 26, 27, 28, 32 e 34.
- FAMA, E. F. Efficient capital markets: A review of theory and empirical work. *The journal of Finance*, Wiley Online Library, v. 25, n. 2, p. 383–417, 1970. Citado na página 26.
- FAMA, E. F. Term-structure forecasts of interest rates, inflation and real returns. *Journal of Monetary Economics*, North-Holland, v. 25, n. 1, p. 59–76, 1990. Citado na página 50.
- FERNANDES, M.; VIEIRA, F. A dynamic nelson–siegel model with forward-looking macroeconomic factors for the yield curve in the us. *Journal of Economic Dynamics and Control*, v. 106, p. 103720, 2019. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165188919301137>>. Citado na página 52.
- FERREIRA, G. A. P. *Preferência por habitat no mercado brasileiro de títulos públicos*. Dissertação (Mestrado), 2022. Citado 7 vezes nas páginas 20, 21, 31, 54, 55, 70 e 72.
- FERREIRA, P. C. et al. Measuring brazilian economic uncertainty. *Journal of Business Cycle Research*, Springer, v. 15, n. 1, p. 25–40, 2019. Citado 5 vezes nas páginas 6, 7, 20, 61 e 117.
- FIGUEIREDO, J. M. *Prêmio de Risco Inflacionário: impacto de incerteza doméstica e externa e a credibilidade da política monetária*. Dissertação (Mestrado), 2018. Citado 5 vezes nas páginas 52, 64, 65, 72 e 73.
- FILIPOVIC, D. *Term-Structure Models. A Graduate Course*. [S.l.]: Springer, 2009. Citado 2 vezes nas páginas 37 e 38.
- FISHER, I. *Appreciation and Interest*. [S.l.]: Publications of American Economic Association, 1896. v. 11. Citado na página 28.
- FRANKLIN JR, S. L. et al. A estrutura a termo de taxas de juros no Brasil: modelos, estimação e testes. *Economia Aplicada*, SciELO Brasil, v. 16, n. 2, p. 255–290, 2012. Citado na página 50.
- GASHA, J. G. et al. On the estimation of term structure models and an application to the United States. *IMF Working Papers*, p. 1–62, 2010. Citado na página 43.

- GIL, A. C. *Métodos e técnicas de pesquisa social*. [S.l.]: 6. ed. Editora Atlas SA, 2008. Citado na página 69.
- GILCHRIST, S.; SIM, J. W.; ZAKRAJŠEK, E. *Uncertainty, financial frictions, and investment dynamics*. [S.l.], 2014. Citado 2 vezes nas páginas 18 e 60.
- GRAVELINE, J. J.; JOSLIN, S. G10 swap and exchange rates. 2010. Citado 2 vezes nas páginas 21 e 57.
- GREENWOOD, R.; VAYANOS, D. Price pressure in the government bond market. *American Economic Review*, v. 100, n. 2, p. 585–90, May 2010. Disponível em: <<https://www.aeaweb.org/articles?id=10.1257/aer.100.2.585>>. Citado 3 vezes nas páginas 18, 53 e 54.
- GREENWOOD, R.; VAYANOS, D. Bond Supply and Excess Bond Returns. *The Review of Financial Studies*, v. 27, n. 3, p. 663–713, 01 2014. Disponível em: <<https://doi.org/10.1093/rfs/hht133>>. Citado 8 vezes nas páginas 18, 21, 31, 48, 54, 55, 70 e 72.
- HAMILTON, J. D. Why You Should Never Use the Hodrick-Prescott Filter. *The Review of Economics and Statistics*, v. 100, n. 5, p. 831–843, 12 2018. Disponível em: <https://doi.org/10.1162/rest_a_00706>. Citado na página 73.
- HAMILTON, J. D.; KIM, D. H. A re-examination of the predictability of the yield spread for real economic activity. *Journal of Money, Credit, and Banking*, v. 34, n. 2, p. 340–360, 2002. Citado na página 50.
- HAMILTON, J. D.; WU, J. C. The effectiveness of alternative monetary policy tools in a zero lower bound environment. *Journal of Money, Credit and Banking*, v. 44, n. s1, p. 3–46, 2012. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1538-4616.2011.00477.x>>. Citado na página 54.
- HAMILTON, J. D.; WU, J. C. Identification and estimation of Gaussian affine term structure models. *Journal of Econometrics*, v. 168, n. 2, p. 315 – 331, 2012. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0304407612000450>>. Citado 8 vezes nas páginas 32, 40, 43, 52, 69, 70, 71 e 72.
- HAUBRICH, J. G.; DOMBROSKY, A. M. et al. Predicting real growth using the yield curve. *Economic Review*, Federal Reserve Bank of Cleveland, v. 32, n. 1, p. 26–35, 1996. Citado na página 50.
- HEATH, D.; JARROW, R.; MORTON, A. Bond pricing and the term structure of interest rates: A discrete time approximation. *Journal of Financial and Quantitative analysis*, Cambridge University Press, v. 25, n. 4, p. 419–440, 1990. Citado na página 34.
- HENRIKSEN, E.; KYDLAND, F.; SUSTEK, R. The high cross-country correlations of prices and interest rates. 2010. Citado na página 56.
- HO, T. S.; LEE, S.-B. Term structure movements and pricing interest rate contingent claims. *the Journal of Finance*, Wiley Online Library, v. 41, n. 5, p. 1011–1029, 1986. Citado 2 vezes nas páginas 35 e 36.

- HOERL, A. E.; KENNARD, R. W. Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics*, Taylor & Francis, v. 42, n. 1, p. 80–86, 2000. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/00401706.2000.10485983>>. Citado na página 84.
- HULL, J.; WHITE, A. Pricing interest-rate-derivative securities. *The review of financial studies*, Oxford University Press, v. 3, n. 4, p. 573–592, 1990. Citado na página 35.
- HULL, J. C. *Opções, futuros e outros derivativos*. [S.l.]: Bookman Editora, 2016. Citado 4 vezes nas páginas 30, 33, 34 e 35.
- HUSTED, L.; ROGERS, J.; SUN, B. Monetary policy uncertainty. *Journal of Monetary Economics*, 2019. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0304393218301661>>. Citado 4 vezes nas páginas 20, 60, 61 e 75.
- IMF. *World economic outlook: Coping with high debt and sluggish growth*. [S.l.]: International Monetary Fund Press, 2012. Citado 2 vezes nas páginas 20 e 22.
- IMF. *World Economic Outlook, April 2013: Hopes, Realities, Risks*. [S.l.]: International Monetary Fund Press, 2013. Citado 2 vezes nas páginas 20 e 22.
- INGERSOLL, J. E. *Theory of financial decision making*. [S.l.]: Rowman & Littlefield, 1987. v. 3. Citado na página 30.
- IOANNIDIS, C.; KA, K. Economic policy uncertainty and bond risk premia. *Journal of Money, Credit and Banking*, v. 53, n. 6, p. 1479–1522, 2021. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/jmcb.12748>>. Citado 6 vezes nas páginas 18, 21, 64, 70, 73 e 117.
- JAMES, J.; WEBBER, N. *Interest rate modelling*. [S.l.]: John Wiley & Sons Chichester, UK, 2000. v. 20. Citado na página 34.
- JAMSHIDIAN, F. LIBOR and swap market models and measures. *Finance and Stochastics*, Springer, v. 1, n. 4, p. 293–330, 1997. Citado na página 34.
- JANUS, J. The covid-19 shock and long-term interest rates in emerging market economies. *Finance Research Letters*, v. 43, p. 101976, 2021. ISSN 1544-6123. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S154461232100057X>>. Citado 2 vezes nas páginas 106 e 117.
- JORDÀ, Ò.; SALYER, K. D. The response of term rates to monetary policy uncertainty. *Review of Economic Dynamics*, v. 6, n. 4, p. 941–962, 2003. Finance and the Macroeconomy. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S109420250300022X>>. Citado 2 vezes nas páginas 63 e 106.
- JORION, P.; MISHKIN, F. A multicountry comparison of term-structure forecasts at long horizons. *Journal of Financial Economics*, Elsevier, v. 29, n. 1, p. 59–80, 1991. Citado na página 50.
- JOSLIN, S.; LE, A.; SINGLETON, K. J. Why Gaussian macro-finance term structure models are (nearly) unconstrained factor-VARs. *Journal of Financial Economics*, v. 109, n. 3, p. 604–622, 2013. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0304405X13001116>>. Citado 10 vezes nas páginas 18, 19, 43, 51, 52, 70, 71, 72, 84 e 85.

JOSLIN, S.; PRIEBSCHE, M.; SINGLETON, K. J. Risk premiums in dynamic term structure models with unspanned macro risks. *The Journal of Finance*, v. 69, n. 3, p. 1197–1233, 2014. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/jofi.12131>>. Citado 6 vezes nas páginas 46, 47, 48, 70, 71 e 72.

JOSLIN, S.; SINGLETON, K. J.; ZHU, H. A new perspective on gaussian dynamic term structure models. *The Review of Financial Studies*, v. 24, n. 3, p. 926–970, 01 2011. Disponível em: <<https://doi.org/10.1093/rfs/hhq128>>. Citado 5 vezes nas páginas 42, 43, 46, 76 e 84.

JOTIKASTHIRA, C.; LE, A.; LUNDBLAD, C. Why do term structures in different currencies co-move? *Journal of Financial Economics*, Elsevier, v. 115, n. 1, p. 58–83, 2015. Citado 2 vezes nas páginas 21 e 56.

JURADO, K.; LUDVIGSON, S. C.; NG, S. Measuring uncertainty. *American Economic Review*, v. 105, n. 3, p. 1177–1216, 2015. Citado 2 vezes nas páginas 60 e 66.

KARANASOS, M.; YFANTI, S.; HUNTER, J. Emerging stock market volatility and economic fundamentals: the importance of US uncertainty spillovers, financial and health crises. *Annals of operations research*, Springer, v. 313, n. 2, p. 1077–1116, 2022. Citado 3 vezes nas páginas 22, 67 e 68.

KEYNES, J. M. *The general theory of employment, interest, and money*. [S.l.]: Palgrave Macmillan, 1936. Citado 3 vezes nas páginas 20, 59 e 60.

KIDO, Y. On the link between the US economic policy uncertainty and exchange rates. *Economics Letters*, Elsevier, v. 144, p. 49–52, 2016. Citado 3 vezes nas páginas 22, 61 e 67.

KIM, S. International transmission of US monetary policy shocks: Evidence from VAR's. *Journal of Monetary Economics*, Elsevier, v. 48, n. 2, p. 339–372, 2001. Citado na página 57.

KLÖSSNER, S.; SEKKEL, R. International spillovers of policy uncertainty. *Economics Letters*, Elsevier, v. 124, n. 3, p. 508–512, 2014. Citado na página 67.

KNIGHT, F. H. *Risk, uncertainty and profit*. [S.l.]: Houghton Mifflin Company., 1921. Citado 3 vezes nas páginas 20, 60 e 61.

KOSE, M. A.; OTROK, C.; WHITEMAN, C. H. International business cycles: World, region, and country-specific factors. *American Economic Review*, v. 93, n. 4, p. 1216–1239, 2003. Citado na página 56.

LAKDAWALA, A.; MORELAND, T.; SCHAFFER, M. The international spillover effects of US monetary policy uncertainty. *Journal of International Economics*, v. 133, p. 103525, 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0022199621001057>>. Citado 2 vezes nas páginas 22 e 67.

LAURINI, M. P.; HOTTA, L. K. Bayesian extensions to Diebold-Li term structure model. *International Review of Financial Analysis*, v. 19, n. 5, p. 342–350, 2010. Citado 2 vezes nas páginas 28 e 37.

- LEIPPOLD, M.; MATTHYS, F. Economic policy uncertainty and the yield curve. *Swiss Finance Institute Research Paper*, n. 22–36, 2022. Citado 7 vezes nas páginas 18, 19, 21, 64, 73, 106 e 117.
- LEITE, A. L. et al. *Previsão da Curva de Juros: um modelo estatístico com variáveis macroeconômicas*. [S.l.], 2009. Disponível em: <<https://ideas.repec.org/p/bcb/wpaper/186.html>>. Citado 3 vezes nas páginas 50, 70 e 72.
- LITTERMAN, R.; SCHEINKMAN, J. Common factors affecting bond returns. *Journal of fixed income*, v. 1, n. 1, p. 54–61, 1991. Citado 6 vezes nas páginas 19, 39, 49, 50, 87 e 88.
- LOWENKRON, A.; GARCIA, M. Monetary policy credibility and inflation risk premium: a model with application to Brazilian data. *Textos para discussão*, n. 543, 2007. Citado 2 vezes nas páginas 64 e 65.
- LUDVIGSON, S. C.; NG, S. Macro factors in bond risk premia. *The Review of Financial Studies*, [Oxford University Press, The Society for Financial Studies], v. 22, n. 12, p. 5027–5067, 2009. Disponível em: <<http://www.jstor.org/stable/40468337>>. Citado na página 52.
- LUDVIGSON, S. C.; NG, S. A factor analysis of bond risk premia. In: ULLAH, A.; GILES, D. E. A. (Ed.). *Handbook of Empirical Economics and Finance*. [S.l.]: Chapman and Hall/CRCr, 2010. p. 313–372. Citado na página 48.
- MALHOTRA, N. K. *Pesquisa de marketing: uma orientação aplicada. Tradução de Nivaldo Montingelli Jr. e Alfredo Alves de Farias*. [S.l.]: Porto Alegre: Bookman, 2019. Citado na página 69.
- MARÇAL, E. F.; MARINHO, C. R. V. A estrutura a termo da taxa de juros brasileira e a oferta de títulos públicos. In: *Anais do XL Encontro Nacional de Economia [Proceedings of the 40th Brazilian Economics Meeting]*. [s.n.], 2014. Disponível em: <<https://ideas.repec.org/p/anp/en2012/053.html>>. Citado 9 vezes nas páginas 18, 21, 31, 52, 54, 55, 70, 71 e 72.
- MARKOWITZ, H. Portfolio selection. *The Journal of Finance*, v. 7, n. 1, p. 77–91, 1952. Citado 2 vezes nas páginas 20 e 59.
- MARSCHNER, P. F.; CERETTA, P. S. Sentimento do investidor, incerteza econômica e política monetária no Brasil. *Revista Contabilidade & Finanças*, SciELO Brasil, v. 32, n. 87, p. 528–540, 2021. Citado 2 vezes nas páginas 62 e 73.
- MATSUMURA, M.; MOREIRA, A.; VICENTE, J. Forecasting the yield curve with linear factor models. *International Review of Financial Analysis*, Elsevier, v. 20, n. 5, p. 237–243, 2011. Citado 5 vezes nas páginas 28, 51, 70, 72 e 73.
- MATSUMURA, M. S.; MOREIRA, A. R. Identification of affine term structure models with observed factors: economic shocks on Brazilian yield curves. Instituto de Pesquisa Econômica Aplicada (Ipea), 2015. Citado 8 vezes nas páginas 20, 28, 51, 52, 71, 72, 73 e 74.
- MISHKIN, F. S. What does the term structure tell us about future inflation? *Journal of monetary economics*, Elsevier, v. 25, n. 1, p. 77–95, 1990. Citado na página 50.

- MITCHELL, W. C. *Business cycles*. [S.l.]: University of California Press, 1913. v. 3. Citado na página 50.
- MODIGLIANI, F.; SUTCH, R. Innovations in interest rate policy. *The American Economic Review*, American Economic Association, v. 56, n. 1/2, p. 178–197, 1966. Disponível em: <<http://www.jstor.org/stable/1821281>>. Citado na página 53.
- MONTES, G. C.; CURI, A. Disagreement in expectations about public debt, monetary policy credibility and inflation risk premium. *Journal of Economics and Business*, v. 93, p. 46–61, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0148619517301522>>. Citado 2 vezes nas páginas 64 e 65.
- MOON, H. R.; PERRON, B. An empirical analysis of nonstationarity in a panel of interest rates with factors. *Journal of Applied Econometrics*, Wiley Online Library, v. 22, n. 2, p. 383–400, 2007. Citado na página 56.
- NELSON, C. R.; SIEGEL, A. F. Parsimonious modeling of yield curves. *Journal of business*, JSTOR, p. 473–489, 1987. Citado 2 vezes nas páginas 38 e 39.
- NEWKEY, W. K.; WEST, K. D. A simple, positive semi-definite, heteroskedasticity and autocorrelation consistent covariance matrix. *Econometrica*, [Wiley, Econometric Society], v. 55, n. 3, p. 703–708, 1987. Disponível em: <<http://www.jstor.org/stable/1913610>>. Citado na página 81.
- OKUN, A. M. *Potential GNP: its measurement and significance*. [S.l.]: Yale University, Cowles Foundation for Research in Economics New Haven, 1963. Citado na página 73.
- PÁSTOR, L.; VERONESI, P. Political uncertainty and risk premia. *Journal of Financial Economics*, Elsevier, v. 110, n. 3, p. 520–545, 2013. Citado na página 18.
- PESARAN, H. H.; SHIN, Y. Generalized impulse response analysis in linear multivariate models. *Economics Letters*, v. 58, n. 1, p. 17–29, 1998. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165176597002140>>. Citado 2 vezes nas páginas 58 e 77.
- PETITT, B. S.; PINTO, J. E.; PIRIE, W. L. *Fixed Income Analysis*. [S.l.]: John Wiley & Sons, 2015. Citado 4 vezes nas páginas 28, 29, 30 e 34.
- PIAZZESI, M. Affine term structure models. In: AÏT-SAHALIA, Y.; HANSEN, L. P. (Ed.). *Handbook of financial econometrics: Tools and Techniques*. [S.l.]: Elsevier, 2010. p. 691–766. Citado 4 vezes nas páginas 19, 24, 39 e 117.
- PINHEIRO, F.; ALMEIDA, C. I. R. de; VICENTE, J. V. Um modelo de fatores latentes com variáveis macroeconômicas para a curva de cupom cambial. *Brazilian Review of Finance*, v. 5, n. 1, p. 79–92, 2007. Citado 2 vezes nas páginas 72 e 73.
- RAUPP, F. M.; BEUREN, I. M. Metodologia da pesquisa aplicável às ciências. *Como elaborar trabalhos monográficos em contabilidade: teoria e prática*. São Paulo: Atlas, p. 76–97, 2006. Citado na página 69.
- REBONATO, R. Structural affine models for yield curve modeling. In: VERONESI, P. (Ed.). *Handbook of Fixed-Income Securities*. [S.l.]: Wiley Online Library, 2016. p. 265–281. Citado 2 vezes nas páginas 31 e 38.

- REIS, M. T. *Análise do prêmio de risco de inflação: evolução e determinantes*. Dissertação (Mestrado), 2018. Citado 3 vezes nas páginas 64, 65 e 72.
- RENDLEMAN, R. J.; BARTTER, B. J. The pricing of options on debt securities. *Journal of Financial and Quantitative Analysis*, Cambridge University Press, v. 15, n. 1, p. 11–24, 1980. Citado na página 34.
- RUDEBUSCH, G. D.; WU, T. A macro-finance model of the term structure, monetary policy and the economy. *The Economic Journal*, Wiley Online Library, v. 118, n. 530, p. 906–926, 2008. Citado na página 18.
- SANTANA, V. C. *Efeitos da maturidade dos títulos públicos na estrutura a termo da taxa de juros*. Dissertação (Mestrado), 2022. Citado 7 vezes nas páginas 21, 31, 52, 54, 55, 70 e 72.
- SARNO, L.; SCHNEIDER, P.; WAGNER, C. Properties of foreign exchange risk premiums. *Journal of Financial Economics*, Elsevier, v. 105, n. 2, p. 279–310, 2012. Citado 2 vezes nas páginas 21 e 57.
- SCHWARZ, L. A. D.; DALMÁCIO, F. Z. The relationship between economic policy uncertainty and corporate leverage: Evidence from Brazil. *Finance Research Letters*, v. 40, p. 101676, 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1544612320302890>>. Citado na página 62.
- SECURATO, J. R. et al. *Cálculo financeiro das tesourarias: bancos e empresas*. [S.l.]: SaintPaul, 2005. Citado na página 37.
- SHANG, F. The effect of uncertainty on the sensitivity of the yield curve to monetary policy surprises. *Journal of Economic Dynamics and Control*, v. 137, p. 104355, 2022. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165188922000604>>. Citado 2 vezes nas páginas 21 e 66.
- SHARPE, W. F.; ALEXANDER, G. J.; BAILEY, J. W. *Investments*. [S.l.]: Prentice-Hall, 1999. Citado na página 28.
- SHILLER, R.; MCCULLOCH, J. H. The term structure of interest rates. In: FRIEDMAN, B. M.; HAHN, F. H. (Ed.). *Handbook of monetary economics*. 1. ed. Elsevier, 1990. v. 1, cap. 13, p. 627–722. Disponível em: <<https://EconPapers.repec.org/RePEc:eee:monchp:1-13>>. Citado na página 28.
- SHOUSA, S. *Estrutura a termo da taxa de juros e dinâmica macroeconômica no Brasil*. [S.l.]: Banco Nacional de Desenvolvimento Econômico e Social, 2008. Citado na página 50.
- SIMS, C. A. Macroeconomics and reality. *Econometrica*, [Wiley, Econometric Society], v. 48, n. 1, p. 1–48, 1980. Disponível em: <<http://www.jstor.org/stable/1912017>>. Citado 2 vezes nas páginas 70 e 77.
- SIMS, C. A.; STOCK, J. H.; WATSON, M. W. Inference in linear time series models with some unit roots. *Econometrica*, [Wiley, Econometric Society], v. 58, n. 1, p. 113–144, 1990. Disponível em: <<http://www.jstor.org/stable/2938337>>. Citado na página 77.

- SOUZA, G. H. D.; BATISTA, A. T. N.; CUNHA, J. V. A. da. Efeitos da incerteza da política econômica no caixa das empresas brasileiras. *Revista de Educação e Pesquisa em Contabilidade (REPeC)*, v. 16, n. 1, 2022. Citado 2 vezes nas páginas 62 e 73.
- SOUZA, M. C. d.; ZABOT, U. C.; CAETANO, S. M. Dinâmica e transição da incerteza no brasil: uma investigação de autorregressão quantílica. *Estudos Econômicos (São Paulo)*, SciELO Brasil, v. 49, p. 305–335, 2019. Citado 2 vezes nas páginas 63 e 73.
- SOWMYA, S.; PRASANNA, K.; BHADURI, S. Linkages in the term structure of interest rates across sovereign bond markets. *Emerging Markets Review*, v. 27, p. 118–39, 2016. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1566014116300188>>. Citado 2 vezes nas páginas 18 e 57.
- STONA, F. et al. Análise da estrutura a termo das taxas de juros em países América Latina entre 2006 a 2014. *Revista Brasileira de Finanças*, Sociedade Brasileira de Finanças, v. 13, n. 4, 2015. Citado na página 72.
- STONA, F.; CALDEIRA, J. F. Do US factors impact the Brazilian yield curve? evidence from a dynamic factor model. *The North American Journal of Economics and Finance*, Elsevier, v. 48, p. 76–89, 2019. Citado 11 vezes nas páginas 18, 21, 51, 52, 57, 58, 68, 70, 71, 72 e 74.
- SVENSSON, L. E.; LACHMAN, D. Estimating and interpreting forward interest rates: Sweden 1992-1994. *IMF Working Papers*, International Monetary Fund, v. 1994, n. 114, 1994. Citado 2 vezes nas páginas 39 e 71.
- SWANSON, E. T. Let's twist again: a high-frequency event-study analysis of operation twist and its implications for qe2. *Brookings Papers on Economic Activity*, Brookings Institution Press, v. 2011, n. 1, p. 151–188, 2011. Disponível em: <<https://muse.jhu.edu/article/449776>>. Citado na página 54.
- TABAK, B. *Monetary Policy Surprises and the Brazilian Term Structure of Interest Rates*. [S.l.], 2003. Disponível em: <<https://EconPapers.repec.org/RePEc:bcb:wpaper:70>>. Citado na página 28.
- TAYLOR, J. B. Discretion versus policy rules in practice. In: ELSEVIER. *Carnegie-Rochester conference series on public policy*. [S.l.], 1993. v. 39, p. 195–214. Citado na página 20.
- TIBSHIRANI, R. Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, v. 58, n. 1, p. 267–288, 1996. Disponível em: <<https://rss.onlinelibrary.wiley.com/doi/abs/10.1111/j.2517-6161.1996.tb02080.x>>. Citado na página 83.
- TILLMANN, P. Monetary policy uncertainty and the response of the yield curve to policy shocks. *Journal of Money, Credit and Banking*, v. 52, n. 4, p. 803–833, 2020. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/jmcb.12657>>. Citado 4 vezes nas páginas 21, 51, 66 e 73.
- TRUNG, N. B. The spillover effects of US economic policy uncertainty on the global economy: A global VAR approach. *The North American Journal of Economics and Finance*, Elsevier, v. 48, p. 90–110, 2019. Citado 2 vezes nas páginas 22 e 67.

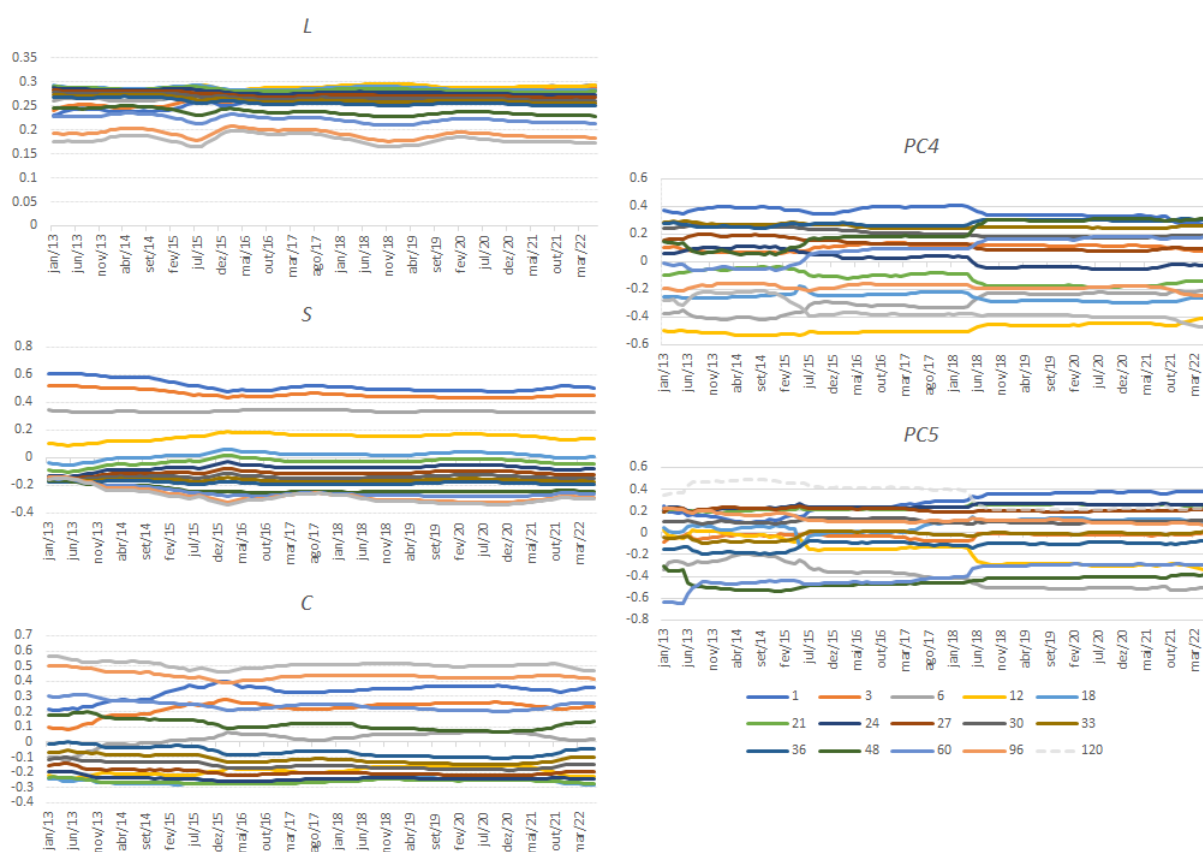
- ULLAH, W. Affine term structure model with macroeconomic factors: Do no-arbitrage restriction and macroeconomic factors imply better out-of-sample forecasts? *Journal of Forecasting*, v. 35, n. 4, p. 329–346, 2016. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/for.2378>>. Citado 2 vezes nas páginas 70 e 72.
- ULRICH, M. Inflation ambiguity and the term structure of U.S. government bonds. *Journal of Monetary Economics*, v. 60, n. 2, p. 295–309, 2013. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0304393212001304>>. Citado na página 66.
- UMAR, Z. et al. Return and volatility transmission between emerging markets and US debt throughout the pandemic crisis. *Pacific-Basin Finance Journal*, v. 67, p. 101563, 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0927538X21000706>>. Citado 3 vezes nas páginas 22, 59 e 67.
- UMAR, Z.; RIAZ, Y.; AHARON, D. Y. Network connectedness dynamics of the yield curve of G7 countries. *International Review of Economics & Finance*, v. 79, p. 275–288, 2022. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1059056022000739>>. Citado 6 vezes nas páginas 22, 58, 59, 67, 68 e 77.
- UMAR, Z.; RIAZ, Y.; ZAREMBA, A. Spillover and risk transmission in the components of the term structure of eurozone yield curve. *Applied Economics*, Taylor & Francis, v. 53, n. 18, p. 2141–2157, 2021. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/00036846.2020.1856322>>. Citado 5 vezes nas páginas 22, 58, 59, 67 e 77.
- VASICEK, O. An equilibrium characterization of the term structure. *Journal of financial economics*, Elsevier, v. 5, n. 2, p. 177–188, 1977. Citado 3 vezes nas páginas 34, 36 e 40.
- VAYANOS, D.; VILA, J.-L. A preferred-habitat model of the term structure of interest rates. *Econometrica*, v. 89, n. 1, p. 77–112, 2021. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.3982/ECTA17440>>. Citado 3 vezes nas páginas 21, 31 e 54.
- VICENTE, J. V. M.; GRAMINHO, F. M. Decompondo a inflação implícita. *Revista Brasileira de Economia*, SciELO Brasil, v. 69, p. 263–284, 2015. Citado 2 vezes nas páginas 64 e 65.
- VIEIRA, F.; FERNANDES, M.; CHAGUE, F. Forecasting the brazilian yield curve using forward-looking variables. *International Journal of Forecasting*, v. 33, n. 1, p. 121–131, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169207016300875>>. Citado na página 52.
- WRIGHT, J. H. Term premia and inflation uncertainty: Empirical evidence from an international panel dataset. *American Economic Review*, v. 101, n. 4, p. 1514–34, 2011. Citado 2 vezes nas páginas 20 e 64.
- WU, J. C.; ZHANG, J. A shadow rate new keynesian model. *Journal of Economic Dynamics and Control*, v. 107, p. 103728, 2019. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0165188919301289>>. Citado na página 119.

ZOU, H.; HASTIE, T. Regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, v. 67, n. 2, p. 301–320, 2005. Disponível em: <<https://rss.onlinelibrary.wiley.com/doi/abs/10.1111/j.1467-9868.2005.00503.x>>. Citado na página 83.

Apêndices

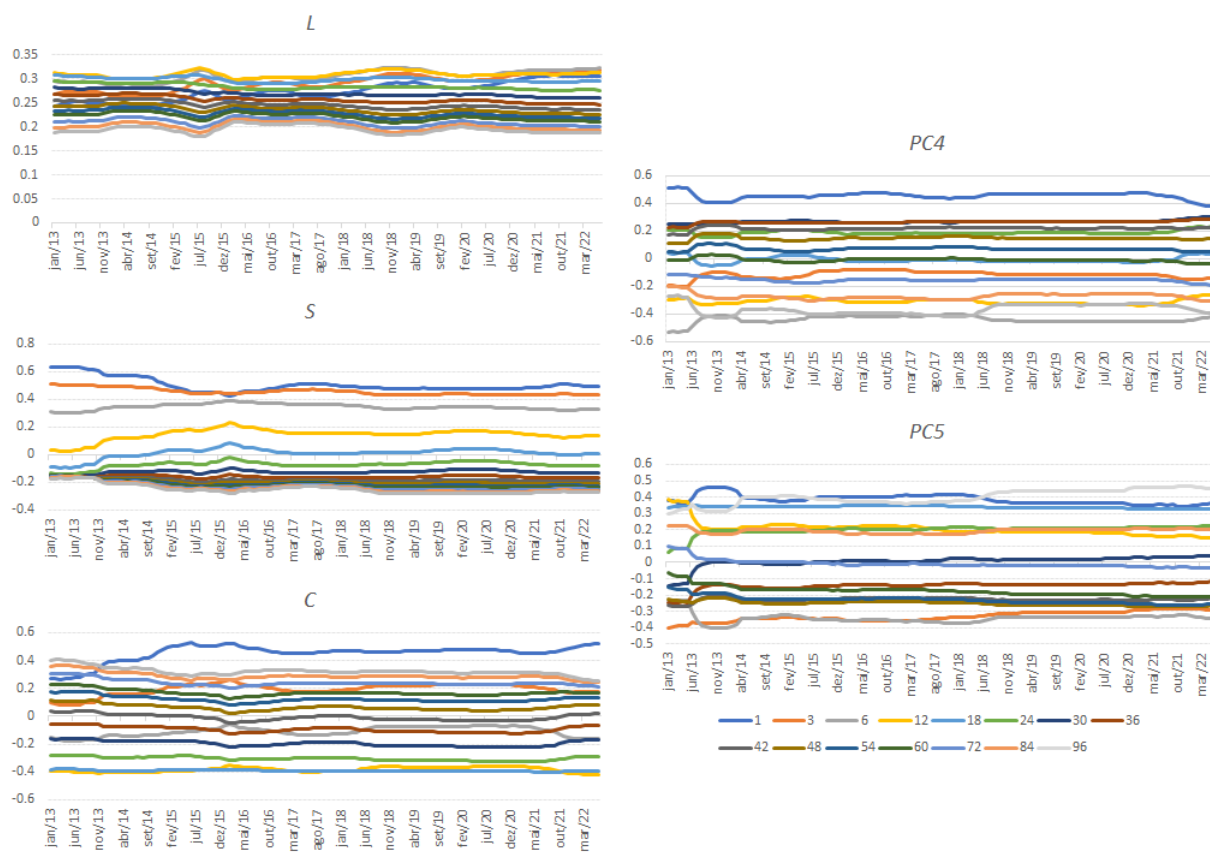
APÊNDICE A – Figuras e tabelas complementares

Figura 12 – Estabilidade nas cargas das cinco primeiras componentes principais (curva de *Swap*)




Fonte: elaboração própria.

Figura 13 – Estabilidade nas cargas das cinco primeiras componentes principais (ETTJ)



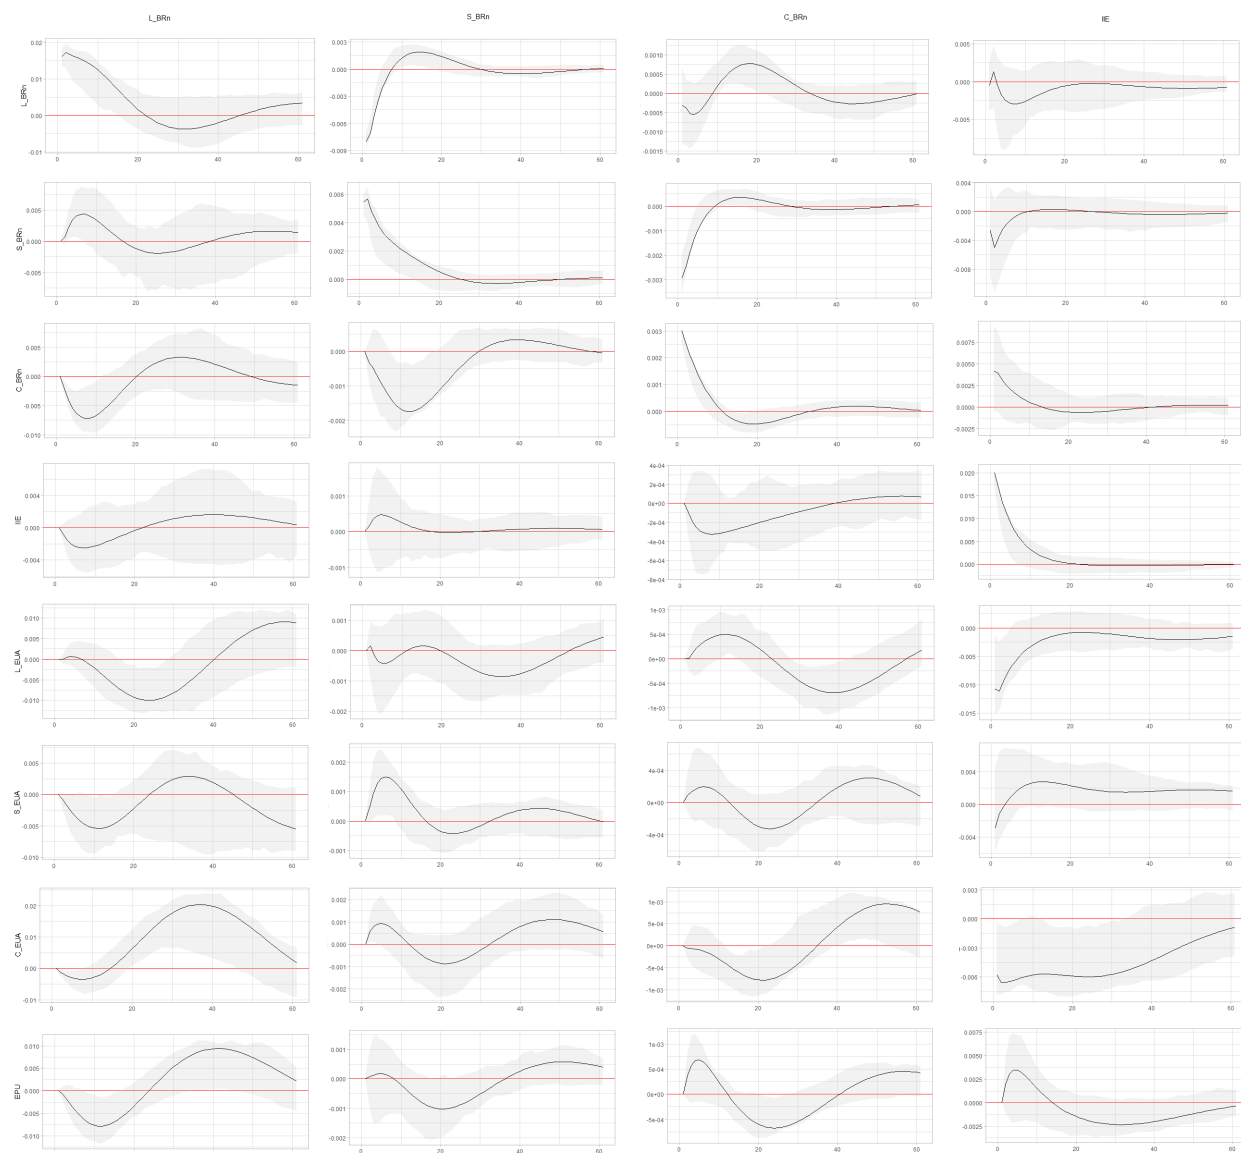
Fonte: elaboração própria.

Figura 14 – Correlograma: ETTJ, ETTJ americana e indicadores de incerteza



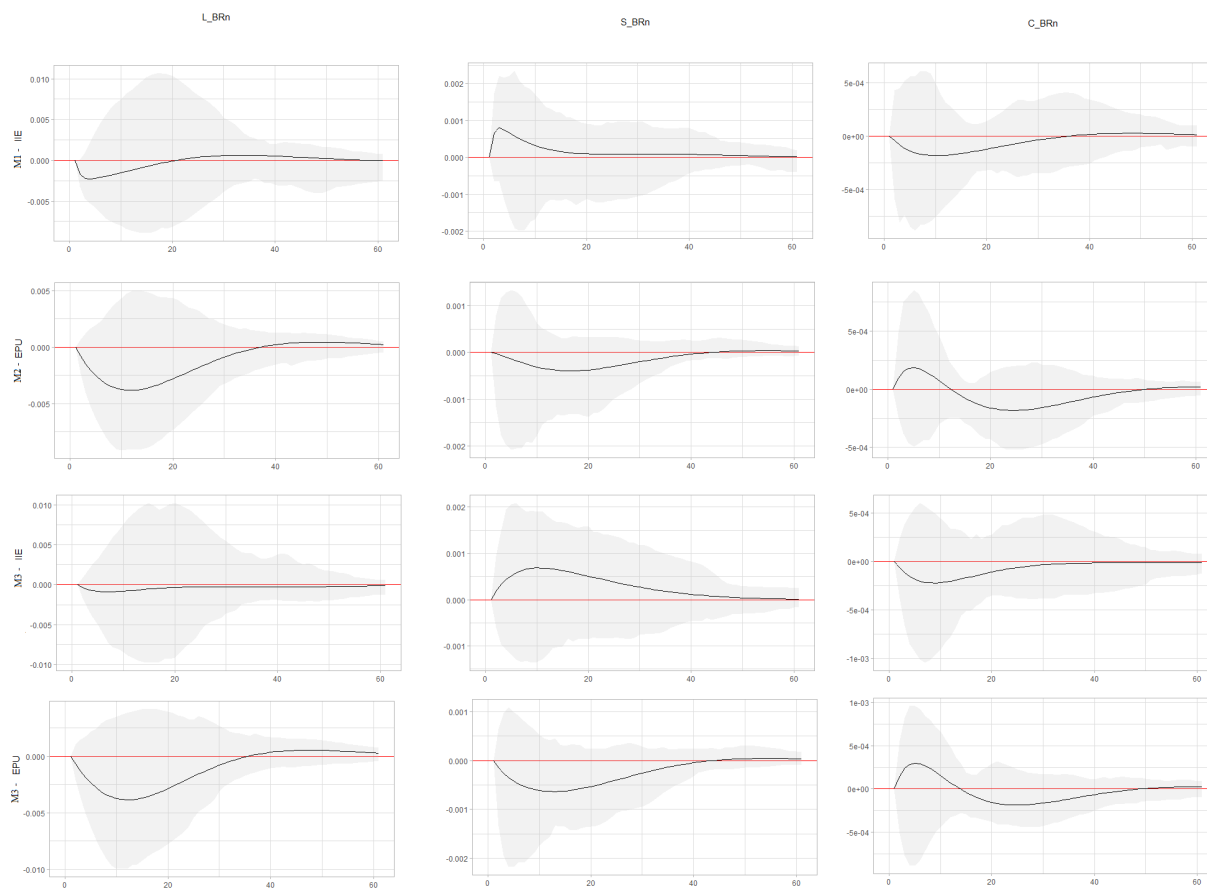
Fonte: elaboração própria.

Figura 15 – Resposta de $L_{BRn,t}$, $S_{BRn,t}$, $C_{BRn,t}$ e IIE (ETTJ) a choques em em $L_{Bn,t}$, $S_{BRn,t}$, $C_{BRn,t}$, IIE , $L_{EUA,t}$, $S_{EUA,t}$, $C_{EUA,t}$ e EPU



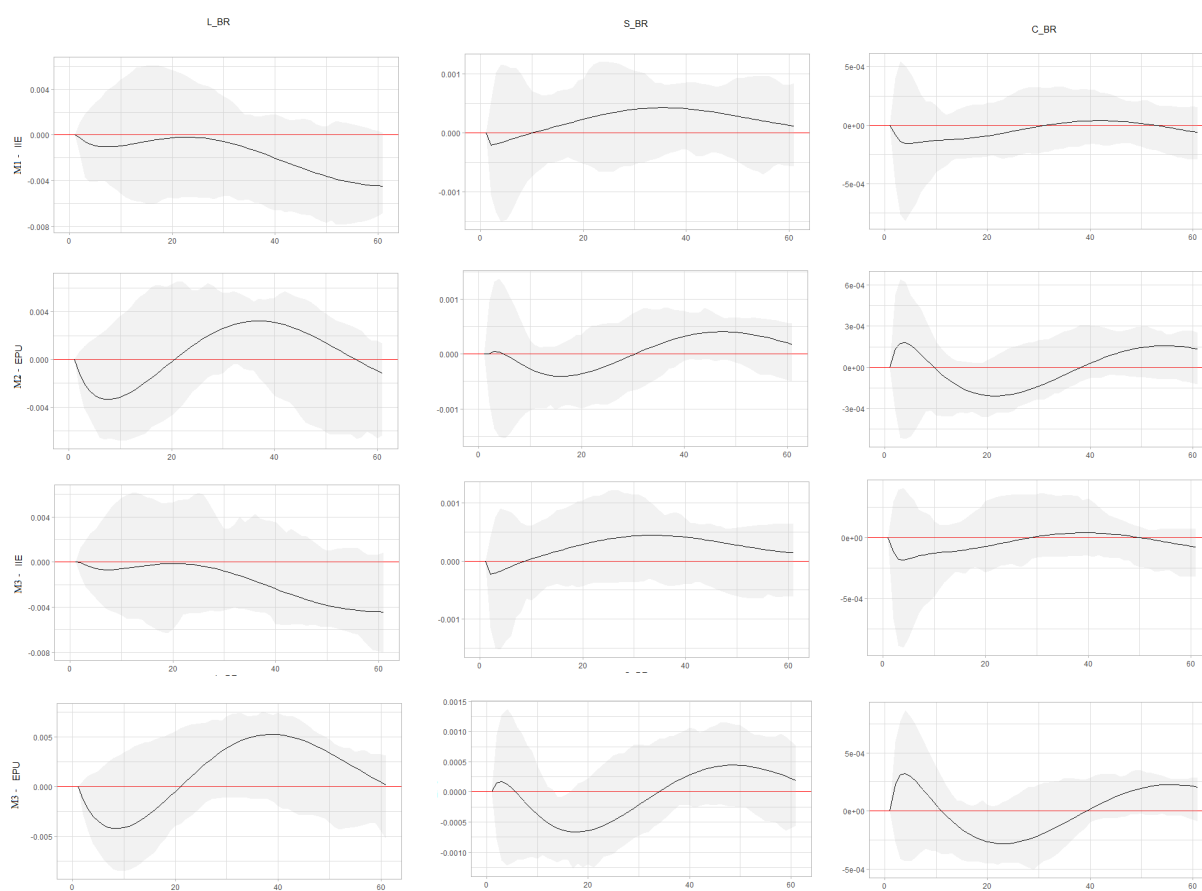
Fonte: elaboração própria.

Figura 16 – Resposta de $L_{BRn,t}$, $S_{BRn,t}$, $C_{BRn,t}$ a choques em IIE e EPU (curva de *Swap*)




Fonte: elaboração própria.

Figura 17 – Resposta de $L_{BRn,t}$, $S_{BRn,t}$, $C_{BRn,t}$ a choques em IIE e EPU , controlados por variáveis macroeconômicas (ETTJ)




Fonte: elaboração própria.

Figura 18 – Correlograma: *spreads*, fatores latentes e fatores exógenos (Swap DI × Pré)



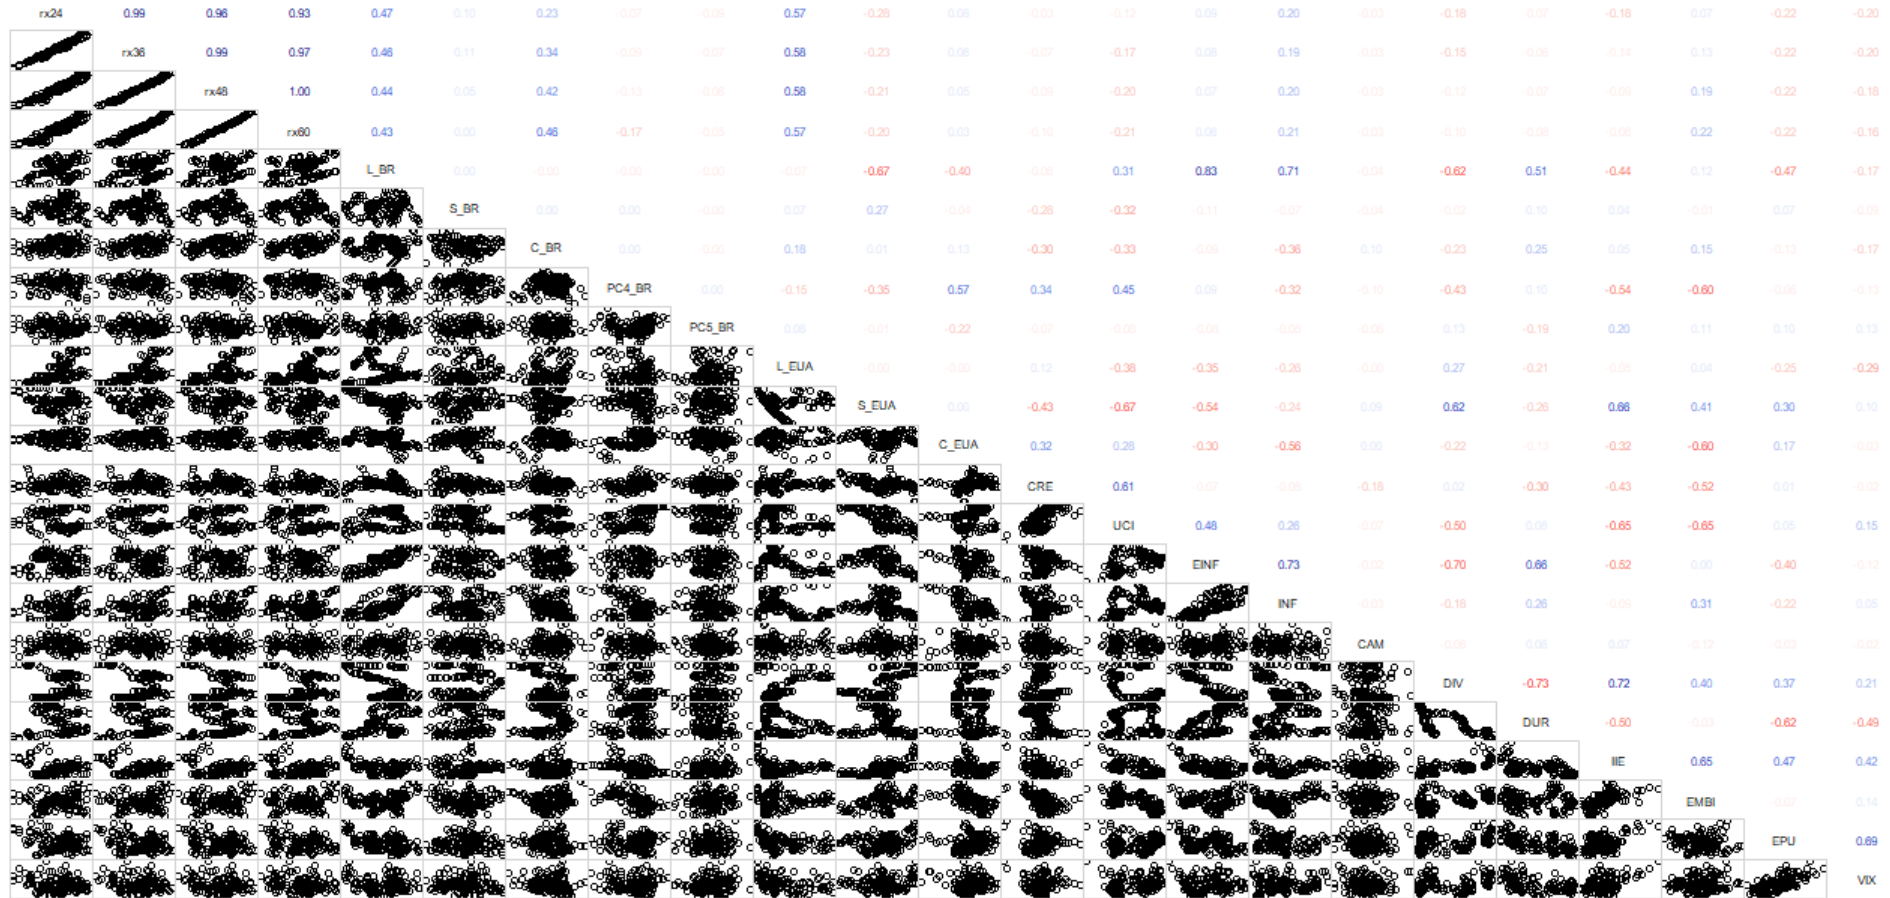
Fonte: elaboração própria.

Figura 19 – Correlograma: *spreads*, fatores latentes e fatores exógenos (ETTJ)



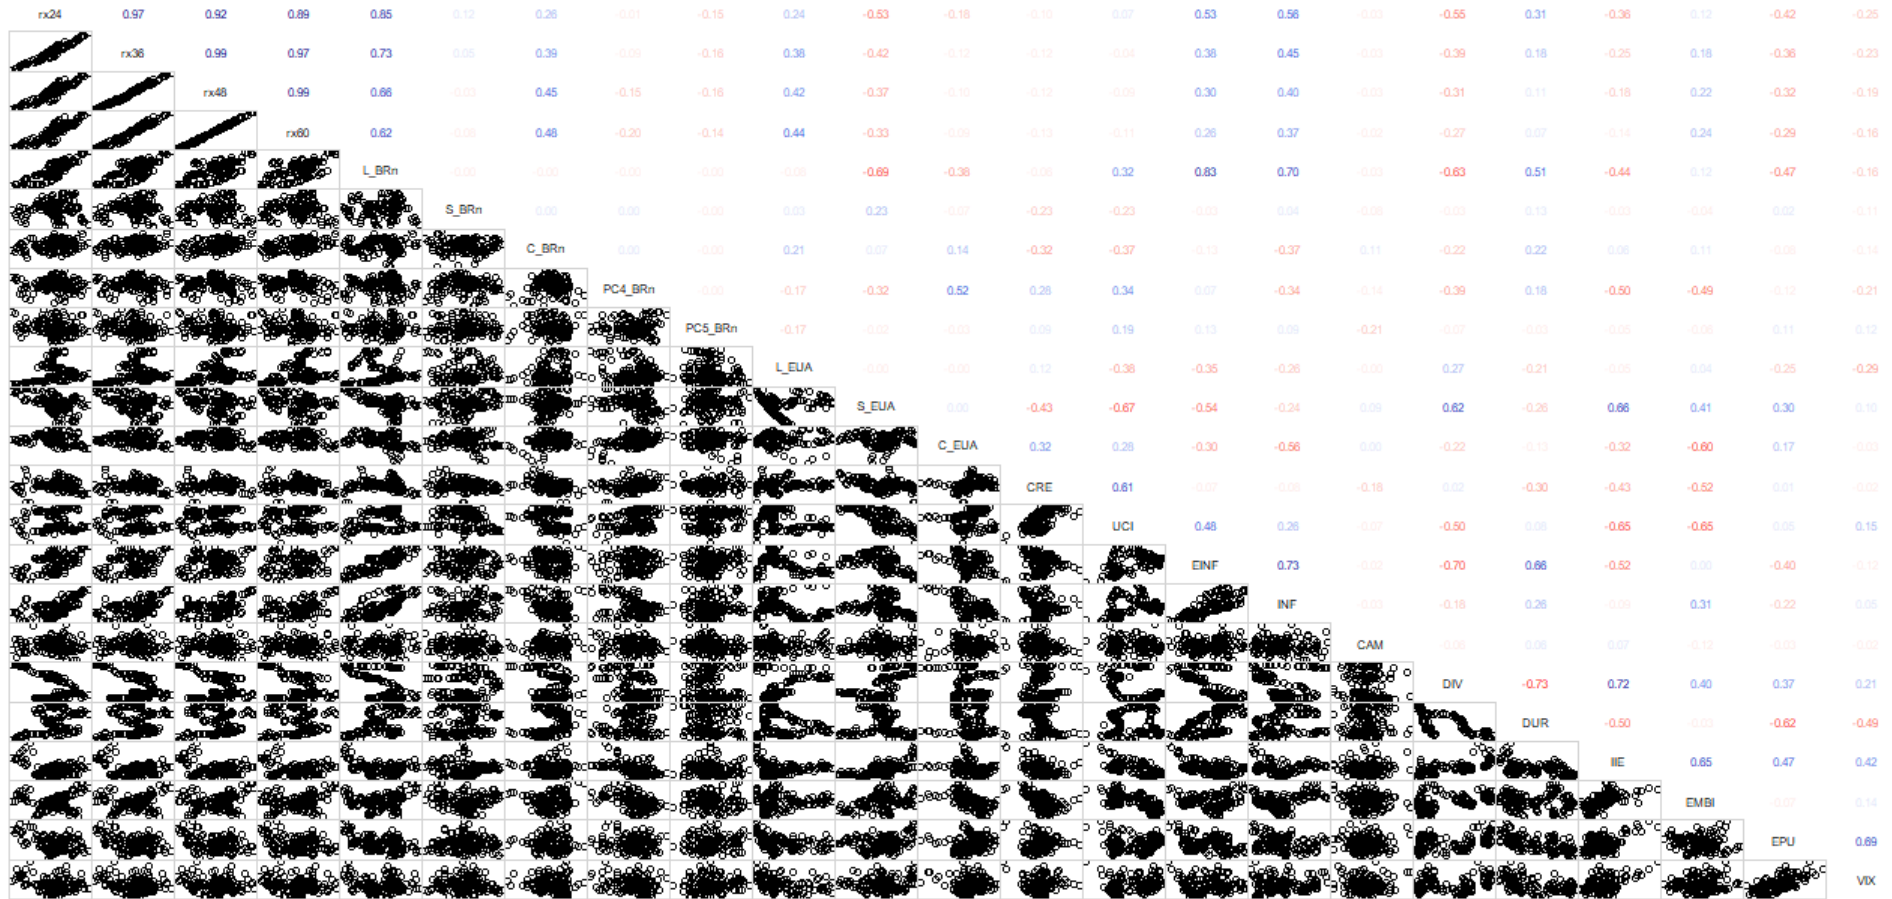
Fonte: elaboração própria.

Figura 20 – Correlograma: excessos de retorno, fatores latentes e fatores exógenos (Swap DI × Pré)



Fonte: elaboração própria.

Figura 21 – Correlograma: excessos de retorno, fatores latentes e fatores exógenos (ETTJ)



Fonte: elaboração própria.

Tabela 22 – Comparativo de variáveis selecionadas para $sp_t(\tau)$ (*Swap* DI × Pré)

	<i>Stepwise Backward</i>				LASSO				Elastic Net			
	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)
β_0	-0,222***	-0,321***	-0,371***	-0,393***	-0,136	-0,196	-0,243	-0,281	-0,121	-0,181	-0,2	-0,2
L_{EUA}						-0,009	-0,015	-0,007	-0,02	-0,013		
S_{EUA}								0,013		0,002	0,064	0,123
C_{EUA}					0,08	0,378	0,596	0,665	0,346	0,592	0,626	0,605
UCI	0,206***	0,290***	0,321***	0,326**	0,133	0,178	0,194	0,198	0,101	0,111	0,11	0,107
CRE									0,003	0,007	0,011	0,014
$EINF$												
INF	-0,140***	-0,284***	-0,389***	-0,454***	-0,091	-0,194	-0,276	-0,33	-0,157	-0,259	-0,319	-0,355
CAM	0,010	0,018	0,027*	0,032*	0,003	0,01	0,018	0,021	0,01	0,018	0,022	0,024
DIV	0,016**	0,021	0,024	0,027	0,014	0,02	0,027	0,032	0,014	0,022	0,022	0,022
DUR							0,006	0,014		0,01	0,011	0,008
IIE	0,024*	0,039	0,049	0,059	0,013	0,022	0,031	0,041	0,014	0,029	0,039	0,045
$EMBI$	0,016*	0,025	0,031	0,033	0,008	0,015	0,021	0,022	0,013	0,016	0,016	0,015
EPU	-0,012**	-0,016**	-0,017*	-0,018	-0,005	-0,008	-0,008	-0,007	-0,004	-0,002	0,000	
VIX												
R^2	0,483	0,513	0,541	0,570	0,443	0,507	0,553	0,585	0,562	0,615	0,642	0,656
R^2 aju.	0,457	0,489	0,518	0,548	0,385	0,456	0,506	0,542	0,516	0,575	0,604	0,620

Nota:

*p<0,1; **p<0,05; ***p<0,01 (para *Stepwise*/MQO)

Fonte: elaboração própria.

Tabela 23 – Comparativo de variáveis selecionadas para $sp_t(\tau)$ (ETTJ)

	<i>Stepwise Backward</i>				LASSO				Elastic Net			
	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)	<i>sp</i> (24)	<i>sp</i> (36)	<i>sp</i> (48)	<i>sp</i> (60)
β_0	-0,193**	-0,255**	-0,285*	-0,307*	-0,121	-0,181	-0,200	-0,200	-0,112	-0,167	-0,183	-0,186
L_{EUA}					-0,02	-0,013			-0,023	-0,017	-0,001	
S_{EUA}						0,002	0,064	0,123		0,010	0,070	0,125
C_{EUA}					0,346	0,592	0,626	0,605	0,359	0,599	0,641	0,635
CRE					0,003	0,007	0,011	0,014	0,008	0,012	0,015	0,017
UCI	0,144**	0,171*	0,173	0,172	0,101	0,111	0,11	0,107	0,088	0,097	0,094	0,093
$EINF$												
INF	-0,209***	-0,344***	-0,420***	-0,463***	-0,157	-0,259	-0,319	-0,355	-0,149	-0,249	-0,304	-0,34
CAM					0,01	0,018	0,022	0,024	0,011	0,018	0,022	0,024
DIV					0,014	0,022	0,022	0,022	0,013	0,02	0,02	0,021
DUR						0,01	0,011	0,008	0,001	0,009	0,01	0,008
IIE	0,028	0,049*	0,068**	0,083***	0,014	0,029	0,039	0,045	0,015	0,03	0,039	0,046
$EMBI$	0,016*	0,019	0,019	0,017	0,013	0,016	0,016	0,015	0,011	0,015	0,014	0,013
EPU					-0,004	-0,002	0,000		-0,004	-0,002	0,000	
VIX												
R^2	0,497	0,558	0,589	0,604	0,562	0,615	0,642	0,656	0,558	0,613	0,638	0,654
R^2 aju.	0,483	0,545	0,577	0,593	0,516	0,575	0,604	0,620	0,512	0,572	0,600	0,617

Nota:

* $p < 0,1$; ** $p < 0,05$; *** $p < 0,01$ (para *Stepwise*/MQO)

Fonte: elaboração própria.

Tabela 24 – Comparativo de variáveis selecionadas para $rx_{t,t+12}(\tau)$ (*Swap* DI × Pré)

	<i>Stepwise Backward</i>				LASSO				Elastic Net			
	<i>rx</i> (24)	<i>rx</i> (36)	<i>rx</i> (48)	<i>rx</i> (60)	<i>rx</i> (24)	<i>rx</i> (36)	<i>rx</i> (48)	<i>rx</i> (60)	<i>rx</i> (24)	<i>rx</i> (36)	<i>rx</i> (48)	<i>rx</i> (60)
β_0	12,258***	23,605***	29,638***	33,711***	4,102	8,552	12,654	14,726	4,701	8,735	12,145	14,706
L_{BR}	1,908***	3,772***	5,043***	5,919***	2,388	4,317	5,541	6,178	2,078	3,953	5,278	6,007
S_{BR}					0,735	2,66	1,163		0,894	2,965	1,681	
C_{BR}	3,906**	20,237***	41,497***	63,335***	2,153	18,737	37,531	56,91	2,915	19,516	38,374	57,049
PC_{4BR}					-7,18				-5,649			
PC_{5BR}					-11,34	-12,387	-5,606		-12,934	-14,129	-10,153	
$LEUA$	6,522***	12,916***	19,761***	26,468***	8,088	16,825	24,02	31,143	8,305	17,145	24,405	31,05
$SEUA$												
$CEUA$	37,989***	83,787***	119,077***	141,469***	34,337	70,425	101,855	114,933	30,843	66,773	99,634	116,656
CRE					-0,782	-1,58	-2,037	-2,578	-0,651	-1,49	-2,143	-2,645
UCI	-7,372***	-14,524***	-18,125***	-19,992***	-1,822	-3,935	-6,313	-6,377	-2,172	-3,948	-5,763	-6,551
$EINF$	-6,834	-14,447*	-17,656**	-22,066***								
INF	3,367*	8,823***	15,953***	23,858***		3,471	8,853	14,8	0,861	4,636	9,968	15,63
CAM	-0,181	-0,544*	-0,685	-0,844								
DIV	-2,161***	-3,882***	-4,305***	-4,652***					-0,31	-0,238		
DUR	-3,323***	-6,336***	-8,407***	-10,196***	-1,675	-3,538	-5,142	-6,66	-1,849	-3,642	-5,138	-6,588
IIE												
$EMBI$												
EPU					0,012				0,016	0		
VIX	-0,259	-0,504*	-0,541	-0,484					-0,008	-0,002		
R^2	0,864	0,890	0,901	0,902	0,828	0,862	0,878	0,88	0,831	0,862	0,878	0,88
R^2 aju.	0,852	0,881	0,892	0,893	0,8	0,839	0,858	0,861	0,804	0,84	0,858	0,861

Nota:

*p<0,1; **p<0,05; ***p<0,01 (para *Stepwise*/MQO)

Fonte: elaboração própria.

Tabela 25 – Comparativo de variáveis selecionadas para $rx_{t,t+12}(\tau)$ (ETTJ)

	<i>Stepwise Backward</i>				LASSO				Elastic Net			
	<i>rx</i> (24)	<i>rx</i> (36)	<i>rx</i> (48)	<i>rx</i> (60)	<i>rx</i> (24)	<i>rx</i> (36)	<i>rx</i> (48)	<i>rx</i> (60)	<i>rx</i> (24)	<i>rx</i> (36)	<i>rx</i> (48)	<i>rx</i> (60)
β_0	12,435***	17,762***	21,875***	26,875***	5,393	9,152	11,801	13,361	5,937	8,812	11,264	12,696
L_{BRn}	5,456***	7,294***	8,584***	9,414***	5,839	7,322	8,243	9,061	5,428	7,009	7,914	8,799
S_{BRn}	3,350***	1,415	-2,606*	-7,207***	4,344	2,77		-1,287	4,283	2,911		-1,572
C_{BRn}	11,674***	31,151***	49,417***	66,634***	11,702	30,749	49,807	69,101	12,474	32,018	50,529	68,839
PC_{4BR}								-4,89				-5,943
PC_{5BRn}	-48,842***	-67,759***	-76,641***	-77,353**	-27,588	-35,639	-37,734	-35,237	-32,427	-44,025	-46,96	-43,166
$LEUA$	6,093***	12,944***	18,661***	23,878***	7,814	15,632	22,347	29,019	8,095	15,96	22,704	28,984
$SEUA$												
$CEUA$	38,562***	75,240***	103,484***	124,843***	33,236	59,657	77,942	94,263	29,791	58,738	77,117	94,573
CRE	-0,502	-1,634**	-2,664***	-3,372***	-0,707	-1,269	-2,029	-3,001	-0,693	-1,571	-2,178	-3,011
UCI	-5,925***	-8,111***	-9,870***	-12,487***	-1,698	-3,484	-4,13	-3,412	-1,741	-2,688	-3,664	-3,168
$EINF$	-3,721	-9,856*	-18,275**	-27,768**								
INF	3,080**	9,242***	16,426***	24,150***	1,068	5,621	11,228	17,169	2,231	7,042	12,448	17,686
CAM	-0,444***	-0,798**	-1,188**	-1,637**			-0,071	-0,259	-0,025	-0,126	-0,251	-0,39
DIV	-1,765***	-2,022***	-2,428**	-3,457**					-0,317			
DUR	-3,534***	-5,631***	-7,225***	-8,870***	-1,844	-3,501	-5,079	-6,78	-2,104	-3,667	-5,015	-6,58
IIE												
$EMBI$								0,065				0,121
EPU												
VIX	-0,358**	-0,555**	-0,622**	-0,624	-0,019				-0,077	-0,097		
R ²	0,969	0,953	0,941	0,930	0,959	0,94	0,927	0,916	0,96	0,941	0,927	0,916
R ² aju.	0,965	0,947	0,935	0,922	0,952	0,93	0,916	0,903	0,953	0,931	0,915	0,902

Nota:

*p<0,1; **p<0,05; ***p<0,01 (para *Stepwise*/MQO)

Fonte: elaboração própria.

APÊNDICE B – Código em R dos procedimentos econométricos

Código B.1 – Código principal

```

1
2 #####
3 ##### Codigo da Tese (Pedro Sabino) #####
4 #####
5
6 #Set de work drive
7 setwd("C:/Doutorado/Tese/Analise dos dados")
8
9 ## Pacotes
10 rm(list=ls())
11 library(corrgram)
12 library(ggplot2)
13 library(glmnet)
14 library(lmtest)
15 library(MASS)
16 library(randtoolbox)
17 library(readxl)
18 library(sandwich)
19 library(Spillover)
20 library(stargazer)
21 library(tseries)
22 library(urca)
23 library(vars)
24 library(xtable)
25 library(writexl)
26 source("DTSMs.r") # funcoes do DTSM
27 set.seed(616)
28
29
30 ## Carrega os dados
31 ybr <- read_excel("data/YBR.xlsx") # Curva Pre x DI, da B3
32 ybr_ettjn <- read_excel("data/YBR_ETTJn.xlsx") # ETTJ nominal,
   ANBIMA
33 yeua <- read_excel("data/YEUA.xlsx") # ETTJ nominal, EUA

```

```
34 ebr <- read_excel("data/Exogenas.xlsx") # Variaveis exogenas
35
36
37 ## Calcula as Componentes Principais
38 CL <- 5 # 5 fatores
39 PC_ybr <- princomp(ybr[, -1], cor=FALSE)$scores[, 1:CL]
40 colnames(PC_ybr) <- c("L_BR", "S_BR", "C_BR", "PC4_BR", "PC5_BR")
41
42 Loadings_ybr <- princomp(ybr[, -1], cor=FALSE)$loadings[, 1:CL]
43 colnames(Loadings_ybr) <- c("L", "S", "C", "PC4", "PC5")
44 DesvPad_ybr <- princomp(ybr[, -1], cor=FALSE)$sdev[1:CL]/sum(
45 princomp(ybr[, -1], cor=FALSE)$sdev)
46 DesvPad_ybr <- matrix(c(DesvPad_ybr, sum(DesvPad_ybr)), nrow=1)
47 colnames(DesvPad_ybr) <- c("L", "S", "C", "PC4", "PC5", "Total")
48
49 PC_ettjn <- princomp(ybr_ettjn[, -1], cor=FALSE)$scores[, 1:CL]
50 colnames(PC_ettjn) <- c("L_BRn", "S_BRn", "C_BRn", "PC4_BRn", "PC5_BRn")
51
52 Loadings_ettjn <- princomp(ybr_ettjn[, -1], cor=FALSE)$loadings
53 [, 1:CL]
54 colnames(Loadings_ettjn) <- c("L", "S", "C", "PC4", "PC5")
55 DesvPad_ettjn <- princomp(ybr_ettjn[, -1], cor=FALSE)$sdev[1:CL]
56 /sum(
57 princomp(ybr_ettjn[, -1], cor=FALSE)$sdev)
58 DesvPad_ettjn <- matrix(c(DesvPad_ettjn, sum(DesvPad_ettjn)),
59 nrow=1)
60 colnames(DesvPad_ettjn) <- c("L", "S", "C", "PC4", "PC5", "Total")
61
62 CL <- 3 # 3 fatores
63 PC_yeua <- princomp(yeua[, -1], cor=FALSE)$scores[, 1:CL]
64 colnames(PC_yeua) <- c("L_EUA", "S_EUA", "C_EUA")
65 Loadings_yeua <- princomp(yeua[, -1], cor=FALSE)$loadings[, 1:CL]
66 colnames(Loadings_yeua) <- c("L", "S", "C")
67 DesvPad_yeua <- princomp(yeua[, -1], cor=FALSE)$sdev[1:CL]/sum(
68 princomp(yeua[, -1], cor=FALSE)$sdev)
69 DesvPad_yeua <- matrix(c(DesvPad_yeua, sum(DesvPad_yeua)), nrow=
70 =1)
71 colnames(DesvPad_yeua) <- c("L", "S", "C", "Total")
72 # Cria um banco de PCs e agrupa os desvios padroes acumulados
73 PCaux1 <- data.frame(ybr$mes, PC_ybr)
74 colnames(PCaux1) <- c("mes", "L_BR", "S_BR", "C_BR", "PC4_BR", "PC5_BR")
```



```

67 PCaux2 <- data.frame(ybr_ettjn$mes,PC_ettjn)
68 colnames(PCaux2) <- c("mes", "L_BRn", "S_BRn", "C_BRn", "PC4_
    BRn", "PC5_BRn")
69 PCaux3 <- data.frame(yeua$mes, PC_yeua)
70 colnames(PCaux3) <- c("mes", "L_EUA", "S_EUA", "C_EUA")
71 PCs <- merge(PCaux1, PCaux2, by="mes")
72 PCs <- merge(PCs, PCaux3, by="mes")
73 write_xlsx(PCs, "data/PCs.xlsx")
74 DesvPad <- rbind(DesvPad_ybr[,c(1:3,6)], DesvPad_ettjn[,c
    (1:3,6)], DesvPad_yeua)
75
76 # Teste de estabilidade das cargas das PCs
77 # Swap Di x Pre
78 CL <- 5 # 5 fatores
79 JA <- 36 # tamanho da janela amostral
80 LEN <- nrow(ybr) # n de linhas
81 VER <- ncol(ybr)-1 # n de vertices
82 LIM <- LEN - JA +1
83 PC_ybr_m <- matrix(0, ncol=CL, nrow=LIM)
84 Loadings_ybr_m1 <- matrix(0, nrow=LIM, ncol=VER)
85 Loadings_ybr_m2 <- matrix(0, nrow=LIM, ncol=VER)
86 Loadings_ybr_m3 <- matrix(0, nrow=LIM, ncol=VER)
87 Loadings_ybr_m4 <- matrix(0, nrow=LIM, ncol=VER)
88 Loadings_ybr_m5 <- matrix(0, nrow=LIM, ncol=VER)
89 for(i in 1:LIM){
90 m <- JA+i-1
91 PC_ybr_m[i,] <- princomp(ybr[1:m,-1], cor=FALSE)$scores[m,1:CL]
92 Loadings_ybr_m1[i,] <- matrix(princomp(ybr[1:m,-1], cor=FALSE)$
    loadings[,1], nrow=1)
93 Loadings_ybr_m2[i,] <- matrix(princomp(ybr[1:m,-1], cor=FALSE)$
    loadings[,2], nrow=1)
94 Loadings_ybr_m3[i,] <- matrix(princomp(ybr[1:m,-1], cor=FALSE)$
    loadings[,3], nrow=1)
95 Loadings_ybr_m4[i,] <- matrix(princomp(ybr[1:m,-1], cor=FALSE)$
    loadings[,4], nrow=1)
96 Loadings_ybr_m5[i,] <- matrix(princomp(ybr[1:m,-1], cor=FALSE)$
    loadings[,5], nrow=1)
97 }
98 PC_ybr_m <- data.frame(ybr$mes[JA:LEN],PC_ybr_m)
99 colnames(PC_ybr_m ) <- c("mes", "L_BR", "S_BR", "C_BR", "PC4_BR
    ", "PC5_BR")
100 write_xlsx(PC_ybr_m , "data/PC_ybr_m.xlsx")

```

```
101 Loadings_ybr_m1 <- data.frame(ybr$mes[JA:LEN],Loadings_ybr_m1)
102 colnames(Loadings_ybr_m1) <- colnames(ybr)
103 write_xlsx(Loadings_ybr_m1, "data/Loadings_ybr_m1.xlsx")
104 Loadings_ybr_m2 <- data.frame(ybr$mes[JA:LEN],Loadings_ybr_m2)
105 colnames(Loadings_ybr_m2) <- colnames(ybr)
106 write_xlsx(Loadings_ybr_m2, "data/Loadings_ybr_m2.xlsx")
107 Loadings_ybr_m3 <- data.frame(ybr$mes[JA:LEN],Loadings_ybr_m3)
108 colnames(Loadings_ybr_m3) <- colnames(ybr)
109 write_xlsx(Loadings_ybr_m3, "data/Loadings_ybr_m3.xlsx")
110 Loadings_ybr_m4 <- data.frame(ybr$mes[JA:LEN],Loadings_ybr_m4)
111 colnames(Loadings_ybr_m4) <- colnames(ybr)
112 write_xlsx(Loadings_ybr_m4, "data/Loadings_ybr_m4.xlsx")
113 Loadings_ybr_m5 <- data.frame(ybr$mes[JA:LEN],Loadings_ybr_m5)
114 colnames(Loadings_ybr_m5) <- colnames(ybr)
115 write_xlsx(Loadings_ybr_m5, "data/Loadings_ybr_m5.xlsx")
116 # ETTJn
117 CL <- 5 # 5 fatores
118 JA <- 36 # tamanho da janela amostral
119 LEN <- nrow(ybr_ettjn) # n de linhas
120 VER <- ncol(ybr_ettjn)-1 # n de vertices
121 LIM <- LEN - JA +1
122 PC_ettjn_m <- matrix(0, ncol=CL, nrow=LIM)
123 Loadings_ettjn_m1 <- matrix(0, nrow=LIM, ncol=VER)
124 Loadings_ettjn_m2 <- matrix(0, nrow=LIM, ncol=VER)
125 Loadings_ettjn_m3 <- matrix(0, nrow=LIM, ncol=VER)
126 Loadings_ettjn_m4 <- matrix(0, nrow=LIM, ncol=VER)
127 Loadings_ettjn_m5 <- matrix(0, nrow=LIM, ncol=VER)
128 for(i in 1:LIM){
129 m <- JA+i-1
130 PC_ettjn_m[i,] <- princomp(ybr_ettjn[1:m,-1], cor=FALSE)$scores
    [m,1:CL]
131 #colnames(PC_ybr_m) <- c("L_BR", "S_BR", "C_BR", "PC4_BR", "PC5
    _BR")
132 Loadings_ettjn_m1[i,] <- matrix(princomp(ybr_ettjn[1:m,-1], cor
    =FALSE)$loadings[,1], nrow=1)
133 Loadings_ettjn_m2[i,] <- matrix(princomp(ybr_ettjn[1:m,-1], cor
    =FALSE)$loadings[,2], nrow=1)
134 Loadings_ettjn_m3[i,] <- matrix(princomp(ybr_ettjn[1:m,-1], cor
    =FALSE)$loadings[,3], nrow=1)
135 Loadings_ettjn_m4[i,] <- matrix(princomp(ybr_ettjn[1:m,-1], cor
    =FALSE)$loadings[,4], nrow=1)
```

```
136 Loadings_ettjn_m5[i,] <- matrix(princomp(ybr_ettjn[1:m,-1], cor
      =FALSE)$loadings[,5], nrow=1)
137 #colnames(Loadings_ybr) <- c("L", "S", "C", "PC4", "PC5")
138 }
139 PC_ettjn_m <- data.frame(ybr_ettjn$mes[JA:LEN],PC_ettjn_m)
140 colnames(PC_ettjn_m ) <- c("mes", "L_BRn", "S_BRn", "C_BRn", "
      PC4_BRn", "PC5_BRn")
141 write_xlsx(PC_ettjn_m , "data/PC_ettjn_m.xlsx")
142 Loadings_ettjn_m1 <- data.frame(ybr_ettjn$mes[JA:LEN],Loadings_
      ettjn_m1)
143 colnames(Loadings_ettjn_m1) <- colnames(ybr_ettjn)
144 write_xlsx(Loadings_ettjn_m1, "data/Loadings_ettjn_m1.xlsx")
145 Loadings_ettjn_m2 <- data.frame(ybr_ettjn$mes[JA:LEN],Loadings_
      ettjn_m2)
146 colnames(Loadings_ettjn_m2) <- colnames(ybr_ettjn)
147 write_xlsx(Loadings_ettjn_m2, "data/Loadings_ettjn_m2.xlsx")
148 Loadings_ettjn_m3 <- data.frame(ybr_ettjn$mes[JA:LEN],Loadings_
      ettjn_m3)
149 colnames(Loadings_ettjn_m3) <- colnames(ybr_ettjn)
150 write_xlsx(Loadings_ettjn_m3, "data/Loadings_ettjn_m3.xlsx")
151 Loadings_ettjn_m4 <- data.frame(ybr_ettjn$mes[JA:LEN],Loadings_
      ettjn_m4)
152 colnames(Loadings_ettjn_m4) <- colnames(ybr_ettjn)
153 write_xlsx(Loadings_ettjn_m4, "data/Loadings_ettjn_m4.xlsx")
154 Loadings_ettjn_m5 <- data.frame(ybr_ettjn$mes[JA:LEN],Loadings_
      ettjn_m5)
155 colnames(Loadings_ettjn_m5) <- colnames(ybr_ettjn)
156 write_xlsx(Loadings_ettjn_m5, "data/Loadings_ettjn_m5.xlsx")
157 # Curva EUA
158 CL <- 5 # 5 fatores
159 JA <- 36 # tamanho da janela amostral
160 LEN <- nrow(yeua) # n de linhas
161 VER <- ncol(yeua)-1 # n de vertices
162 LIM <- LEN - JA +1
163 PC_yeua_m <- matrix(0, ncol=CL, nrow=LIM)
164 Loadings_yeua_m1 <- matrix(0, nrow=LIM, ncol=VER)
165 Loadings_yeua_m2 <- matrix(0, nrow=LIM, ncol=VER)
166 Loadings_yeua_m3 <- matrix(0, nrow=LIM, ncol=VER)
167 Loadings_yeua_m4 <- matrix(0, nrow=LIM, ncol=VER)
168 Loadings_yeua_m5 <- matrix(0, nrow=LIM, ncol=VER)
169 for(i in 1:LIM){
170 m <- JA+i-1
```

```
171 PC_yeua_m[i,] <- princomp(yeua[1:m,-1], cor=FALSE)$scores[m,1:
    CL]
172 Loadings_yeua_m1[i,] <- matrix(princomp(yeua[1:m,-1], cor=FALSE
    )$loadings[,1], nrow=1)
173 Loadings_yeua_m2[i,] <- matrix(princomp(yeua[1:m,-1], cor=FALSE
    )$loadings[,2], nrow=1)
174 Loadings_yeua_m3[i,] <- matrix(princomp(yeua[1:m,-1], cor=FALSE
    )$loadings[,3], nrow=1)
175 Loadings_yeua_m4[i,] <- matrix(princomp(yeua[1:m,-1], cor=FALSE
    )$loadings[,4], nrow=1)
176 Loadings_yeua_m5[i,] <- matrix(princomp(yeua[1:m,-1], cor=FALSE
    )$loadings[,5], nrow=1)
177 }
178 PC_yeua_m <- data.frame(yeua$mes[JA:LEN],PC_yeua_m)
179 colnames(PC_yeua_m ) <- c("L_EUA", "S_EUA", "C_EUA", "PC4_EUA",
    "PC5_EUA")
180 write_xlsx(PC_yeua_m , "data/PC_yeua_m.xlsx")
181 Loadings_yeua_m1 <- data.frame(yeua$mes[JA:LEN],Loadings_yeua_
    m1)
182 colnames(Loadings_yeua_m1) <- colnames(yeua)
183 write_xlsx(Loadings_yeua_m1, "data/Loadings_yeua_m1.xlsx")
184 Loadings_yeua_m2 <- data.frame(yeua$mes[JA:LEN],Loadings_yeua_
    m2)
185 colnames(Loadings_yeua_m2) <- colnames(yeua)
186 write_xlsx(Loadings_yeua_m2, "data/Loadings_yeua_m2.xlsx")
187 Loadings_yeua_m3 <- data.frame(yeua$mes[JA:LEN],Loadings_yeua_
    m3)
188 colnames(Loadings_yeua_m3) <- colnames(yeua)
189 write_xlsx(Loadings_yeua_m3, "data/Loadings_yeua_m3.xlsx")
190 Loadings_yeua_m4 <- data.frame(yeua$mes[JA:LEN],Loadings_yeua_
    m4)
191 colnames(Loadings_yeua_m4) <- colnames(yeua)
192 write_xlsx(Loadings_yeua_m4, "data/Loadings_yeua_m4.xlsx")
193 Loadings_yeua_m5 <- data.frame(yeua$mes[JA:LEN],Loadings_yeua_
    m5)
194 colnames(Loadings_yeua_m5) <- colnames(yeua)
195 write_xlsx(Loadings_yeua_m5, "data/Loadings_yeua_m5.xlsx")
196
197
198 ## Calcula os Spreads
199 # Swap DI x Pre
200 SP <- ybr[,c(1,8,12,13,14)] # mes, 1, 2, 3, 4 e 5 anos
```

```

201 for(i in 2:length(SP)){
202 SP[,i] <- SP[,i] - ybr$"12"
203 }
204 colnames(SP) <- c("mes", "sp24", "sp36","sp48","sp60")
205 # ETTJn
206 SPn <- ybr_ettjn[,c(1,7,9,11,13)] # mes, 1, 2, 3, 4 e 5 anos
207 for(i in 2:length(SPn)){
208 SPn[,i] <- SPn[,i] - ybr_ettjn$"12"
209 }
210 colnames(SPn) <- c("mes", "sp24", "sp36","sp48","sp60")
211
212
213 ## Calcula os Excessos de retorno
214 # Swap DI x Pre
215 T <- nrow(ybr)
216 RX_aux <- ybr[,c(1,5,8,12,13,14)] # mes, 1, 2, 3, 4 e 5 anos
217 RX_aux2 <- RX_aux[(T-11):T,-2]
218 RX_aux2[,2:5] <- NA
219 colnames(RX_aux2) <- c("mes", "rx24", "rx36", "rx48", "rx60")
220 RX <- RX_aux[1:(T-12),-2]
221 for(i in 2:length(RX)){
222 t <- as.numeric(colnames(RX[,i]))
223 RX[,i] <- (t*RX_aux[1:(T-12),(i+1)]-(t-12)*RX_aux[13:T,i])-12*
      ybr[1:(T-12),2]
224 }
225 colnames(RX) <- c("mes","rx24","rx36","rx48","rx60")
226 RX <- data.frame(rbind(RX, RX_aux2))
227 # ETTJn
228 T <- nrow(ybr_ettjn)
229 RX_aux <- ybr_ettjn[,c(1,5,7,9,11,13)] # mes, 1, 2, 3, 4 e 5
      anos
230 RX_aux2 <- RX_aux[(T-11):T,-2]
231 RX_aux2[,2:5] <- NA
232 colnames(RX_aux2) <- c("mes", "rx24", "rx36", "rx48", "rx60")
233 RXn <- RX_aux[1:(T-12),-2]
234 for(i in 2:length(RXn)){
235 t <- as.numeric(colnames(RXn[,i]))
236 RXn[,i] <- (t*RX_aux[1:(T-12),(i+1)]-(t-12)*RX_aux[13:T,i])
237 -12*ybr_ettjn[1:(T-12),2]
238 }
239 colnames(RXn) <- c("mes","rx24","rx36","rx48","rx60")
240 RXn <- data.frame(rbind(RXn, RX_aux2))

```

```
241
242
243 ##### Estatísticas Descritivas
244 #####
245 ## Resultados dos PCS
246 stargazer(t(Loadings_ybr), t(Loadings_ettjn), t(Loadings_yeua))
247 stargazer(DesvPad)
248
249
250 ## Estatísticas Descritivas
251 dados <- merge(SP, SPn, by="mes")
252 dados <- merge(dados, RX, by="mes")
253 dados <- merge(dados, RXn, by="mes")
254 dados <- merge(dados, PCs, by="mes")
255 dados <- merge(dados, ebr, by="mes")
256 stargazer(dados)
257
258 # Teste de estacionariedade
259 dados_aux <- dados[,-c(1,10:17)]
260 dados_aux2 <- dados[1:(length(dados)-12),10:17]
261
262 adftest <- apply(dados_aux,2,function(x) c(tseries::adf.test(x)
263 $statistic,
264 p.valor=tseries::adf.test(x)$p.value))
265 kpsstest <- apply(dados_aux,2,function(x) c(tseries::kpss.test(
266 x)$statistic,
267 p.valor=tseries::kpss.test(x)$p.value))
268 kpssttest <- apply(dados_aux,2,function(x) c(tseries::kpss.test
269 (x, null =
270 "Trend")$statistic, p.valor=tseries::kpss.test(x)$p.value))
271 fdSperiotest <- apply(dados_aux,2,function(x) fracdiff::
272 fdSperio(x)$d)
273 adftest2 <- apply(dados_aux2,2,function(x) c(tseries::adf.test(
274 x)$statistic,
275 p.valor=tseries::adf.test(x)$p.value))
276 kpsstest2 <- apply(dados_aux2,2,function(x) c(tseries::kpss.
277 test(x)$statistic,
278 p.valor=tseries::kpss.test(x)$p.value))
279 kpssttest2 <- apply(dados_aux2,2,function(x) c(tseries::kpss.
280 test(x, null =
281 "Trend")$statistic, p.valor=tseries::kpss.test(x)$p.value))
```

```

275 fdSperiotest2 <- apply(dados_aux2,2,function(x) fracdiff::
      fdSperio(x)$d)
276
277 estacionariedade <- t(rbind(cbind(adftest,adftest2), cbind(
      kpsstest,kpsstest2),
278 cbind(kpssttest,kpssttest2), cbind(t(fdSperiotest),
279 t(fdSperiotest2))))
280 stargazer(estacionariedade)
281
282
283
284 ##### SWAP X ETTJn
      #####
285
286 ## Dados e correlograma
287 dados1 <- merge(PCaux1, PCaux2, by="mes")
288 corrgram(dados1,lower.panel=panel.pts, upper.panel=panel.cor,
289 text.panel=panel.txt)
290
291
292 ## VAR
293 dados1 <- ts(data.frame(dados1[,-c(1,5:6,10:11)]))
294 coint_test <- ca.jo(dados1, ecdet = "none", type="eigen", K=2,
      spec="longrun")
295 summary(coint_test) # teste de cointegracao
296 var_aux <- VAR(dados1, lag.max=10, type = "const", ic="AIC")
297 summary(var_aux)
298 #stargazer(round(Bcoef(var_aux),digits = 3))
299 normality.test(var_aux) # teste de normalidade
300 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
301 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedasticidade
302 PsiH <- g.fevd(var_aux, n.ahead=10)
303
304 # Conectividade total ajustada
305 TRa <- (sum(PsiH$L_BR[10,-(1:3)]) +sum(PsiH$S_BR[10,-(1:3)])
306 +sum(PsiH$C_BR[10,-(1:3)]) +sum(PsiH$L_BRn[10,-(4:6)])
307 +sum(PsiH$S_BRn[10,-(4:6)]) +sum(PsiH$C_BRn[10,-(4:6)]))/6
308 TRa
309
310 # Spillover liquido

```

```

311 Tr_LSC <- matrix(0, ncol = 3)
312 Tr_LSC[1] <- PsiH$L_BR[10,4] - PsiH$L_BRn[10,1]
313 Tr_LSC[2] <- PsiH$S_BR[10,5] - PsiH$S_BRn[10,2]
314 Tr_LSC[3] <- PsiH$C_BR[10,6] - PsiH$C_BRn[10,3]
315 colnames(Tr_LSC) <- c("L_BR x LBRn", "S_BR x SBRn", "C_BR x CBRn
    ")
316 Tr_LSC
317
318 # Spillover parcial
319 Trp <- matrix(0, nrow=2, ncol = 3)
320 colnames(Trp) <- c("L", "S", "C")
321 rownames(Trp) <- c("Swap", "ETTJn")
322 Trp[1,1] <- sum(PsiH$L_BR[10,4:6])
323 Trp[1,2] <- sum(PsiH$S_BR[10,4:6])
324 Trp[1,3] <- sum(PsiH$C_BR[10,4:6])
325 Trp[2,1] <- sum(PsiH$L_BRn[10,1:3])
326 Trp[2,2] <- sum(PsiH$S_BRn[10,1:3])
327 Trp[2,3] <- sum(PsiH$C_BRn[10,1:3])
328 Trp
329
330
331
332 ##### Spillover americano
333     #####
334
335 ## Dados e correlogramas
336 dados31 <- merge(PCaux1, PCaux3, by="mes")
337 dados31 <- merge(dados31, ebr[,c(1,6,9,11)], by="mes")
338 dados32 <- merge(PCaux2, PCaux3, by="mes")
339 dados32 <- merge(dados32, ebr[,c(1,6,9,11)], by="mes")
340 # Correlogramas
341 corrgram(dados31, lower.panel=panel.pts, upper.panel=panel.cor,
342 text.panel=panel.txt)
343 corrgram(dados32, lower.panel=panel.pts, upper.panel=panel.cor,
344 text.panel=panel.txt)
345
346
347 ### VARs
348 # Medidas de tranbordamento
349 Trp <- matrix(0, nrow=6, ncol = 3) # Spillover parcial

```



```
350 colnames(Trp) <- c("SwapM1", "SwapM2", "SwapM3", "ETTJM1", "
    ETTJM2", "ETTJM3")
351 rownames(Trp) <- c("L", "S", "C")
352 TS <- matrix(0, nrow=8, ncol=3) # Spillover simples
353 colnames(TS) <- c("IIE_M2", "IIE_M3", "EPU_M3")
354 rownames(TS) <- c("L_BR", "S_BR", "C_BR", "IIEbr",
355 "L_BRn", "S_BRn", "C_BRn", "IIEbrn")
356
357
358 ## Swap X EUA
359 # M1
360 d_aux <- ts(data.frame(dados31[,c(2:4,7:9,10)]))
361 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
    spec="longrun")
362 summary(coint_test) # teste de cointegracao
363 var_aux <- VAR(d_aux, lag.max=10, type = "const", ic="AIC")
364 restriction <- matrix(1, nrow = 7, ncol = 8) # Restricoes de
    economia aberta
365 restriction[4:6, c(1:3,7)] <- 0
366 var_aux <- restrict(var_aux, method = "man", resmat =
    restriction)
367 summary(var_aux)
368 normality.test(var_aux) # teste de normalidade
369 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
    serial
370 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
    heterocedasticidade
371 PsiH <- g.fevd(var_aux, n.ahead=10)
372 Trp[1,1] <- sum(PsiH$L_BR[10,4:6])
373 Trp[2,1] <- sum(PsiH$S_BR[10,4:6])
374 Trp[3,1] <- sum(PsiH$C_BR[10,4:6])
375 # M2
376 d_aux <- ts(data.frame(dados31[,c(2:4,7:9,10:11)]))
377 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
    spec="longrun")
378 summary(coint_test) # teste de cointegracao
379 var_aux <- VAR(d_aux, lag.max=10, type = "const", ic="AIC")
380 restriction <- matrix(1, nrow = 8, ncol = 9) # Restricoes de
    economia aberta
381 restriction[4:6, c(1:3,7:8)] <- 0
382 var_aux <- restrict(var_aux, method = "man", resmat =
    restriction)
```

```
383 summary(var_aux)
384 normality.test(var_aux) # teste de normalidade
385 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
386 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedasticidade
387 PsiH <- g.fevd(var_aux, n.ahead=10)
388 Trp[1,2] <- sum(PsiH$L_BR[10,4:6])
389 Trp[2,2] <- sum(PsiH$S_BR[10,4:6])
390 Trp[3,2] <- sum(PsiH$C_BR[10,4:6])
391 TS[1,1] <- PsiH$L_BR[10,8]
392 TS[2,1] <- PsiH$S_BR[10,8]
393 TS[3,1] <- PsiH$C_BR[10,8]
394 TS[4,1] <- PsiH$IIE[10,8]
395 # M3
396 d_aux <- ts(data.frame(dados31[,c(2:4,7:9,10:12)]))
397 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
      spec="longrun")
398 summary(coint_test) # teste de cointegracao
399 var_aux <- VAR(d_aux, lag.max=1, type = "const", ic="AIC")
400 restriction <- matrix(1, nrow = 9, ncol = 10) # Restricoes de
      economia aberta
401 restriction[c(4:6,9), c(1:3,7:8)] <- 0
402 var_aux <- restrict(var_aux, method = "man", resmat =
      restriction)
403 summary(var_aux)
404 normality.test(var_aux) # teste de normalidade
405 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
406 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedasticidade
407 PsiH <- g.fevd(var_aux, n.ahead=10)
408 Trp[1,3] <- sum(PsiH$L_BR[10,4:6])
409 Trp[2,3] <- sum(PsiH$S_BR[10,4:6])
410 Trp[3,3] <- sum(PsiH$C_BR[10,4:6])
411 TS[1,2] <- PsiH$L_BR[10,8]
412 TS[2,2] <- PsiH$S_BR[10,8]
413 TS[3,2] <- PsiH$C_BR[10,8]
414 TS[4,2] <- PsiH$IIE[10,8]
415 TS[1,3] <- PsiH$L_BR[10,9]
416 TS[2,3] <- PsiH$S_BR[10,9]
417 TS[3,3] <- PsiH$C_BR[10,9]
```

```
418 TS[4,3] <- PsiH$IIE[10,9]
419 # FRIs
420 latentes <- c("L_BR","S_BR","C_BR", "IIE",
421 "L_EUA","S_EUA","C_EUA", "EPU")
422 latentes_BR <- c("L_BR","S_BR","C_BR", "IIE")
423 periodo <- matrix(1:61, ncol=1)
424 for(i in latentes){
425   for(j in latentes_BR){
426     IRFV <- irf(var_aux, impulse = i, response = j,
427 n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
428 ci = 0.90, runs = 100)
429     IRFVd <- data.frame(cbind(periodo,unlist(eval(parse(text=paste0
430 ("IRFV$irf$",
431 i))))), unlist(IRFV$Lower), unlist(IRFV$Upper)))
432     colnames(IRFVd) <- c("periodo","oi","lower","upper")
433     print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
434 upper)) +
435 scale_x_continuous(limits = c(0, 61)) +
436 geom_hline(yintercept = 0, color="red") +
437 geom_ribbon(fill="grey", alpha=0.2) +
438 geom_line() +
439 theme_light() +
440 ylab(i)+
441 xlab(j)+
442 theme(plot.title = element_text(size = 11, hjust=0.5),
443 axis.title.y = element_text(size=11)))
444   }
445 }
446
447 ## ETTJ X EUA
448 # M1
449 d_aux <- ts(data.frame(dados32[,c(2:4,7:9,10)]))
450 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
451 spec="longrun")
452 summary(coint_test) # teste de cointegracao
453 var_aux <- VAR(d_aux, lag.max=10, type = "const", ic="AIC")
454 restriction <- matrix(1, nrow = 7, ncol = 8) # Restricoes de
455 economia aberta
456 restriction[4:6, c(1:3,7)] <- 0
```

```
455 var_aux <- restrict(var_aux, method = "man", resmat =
      restriction)
456 summary(var_aux)
457 normality.test(var_aux) # teste de normalidade
458 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
459 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedastcidade
460 PsiH <- g.fevd(var_aux, n.ahead=10)
461 Trp[4,1] <- sum(PsiH$L_BR[10,4:6])
462 Trp[5,1] <- sum(PsiH$S_BR[10,4:6])
463 Trp[6,1] <- sum(PsiH$C_BR[10,4:6])
464 # M2
465 d_aux <- ts(data.frame(dados32[,c(2:4,7:9,10:11)]))
466 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
      spec="longrun")
467 summary(coint_test) # teste de cointegracao
468 var_aux <- VAR(d_aux, lag.max=10, type = "const", ic="AIC")
469 restriction <- matrix(1, nrow = 8, ncol = 9) # Restricoes de
      economia aberta
470 restriction[4:6, c(1:3,7:8)] <- 0
471 var_aux <- restrict(var_aux, method = "man", resmat =
      restriction)
472 summary(var_aux)
473 normality.test(var_aux) # teste de normalidade
474 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
475 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedastcidade
476 PsiH <- g.fevd(var_aux, n.ahead=10)
477 Trp[4,2] <- sum(PsiH$L_BR[10,4:6])
478 Trp[5,2] <- sum(PsiH$S_BR[10,4:6])
479 Trp[6,2] <- sum(PsiH$C_BR[10,4:6])
480 TS[5,1] <- PsiH$L_BR[10,8]
481 TS[6,1] <- PsiH$S_BR[10,8]
482 TS[7,1] <- PsiH$C_BR[10,8]
483 TS[8,1] <- PsiH$IIE[10,8]
484 # M3
485 d_aux <- ts(data.frame(dados32[,c(2:4,7:9,10:12)]))
486 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
      spec="longrun")
487 summary(coint_test) # teste de cointegracao
```

```

488 var_aux <- VAR(d_aux, lag.max=1, type = "const", ic="AIC")
489 restriction <- matrix(1, nrow = 9, ncol = 10) # Restricoes de
      economia aberta
490 restriction[c(4:6,9), c(1:3,7:8)] <- 0
491 var_aux <- restrict(var_aux, method = "man", resmat =
      restriction)
492 summary(var_aux)
493 normality.test(var_aux) # teste de normalidade
494 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
495 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedasticidade
496 PsiH <- g.fevd(var_aux, n.ahead=10)
497 Trp[4,3] <- sum(PsiH$L_BR[10,4:6])
498 Trp[5,3] <- sum(PsiH$S_BR[10,4:6])
499 Trp[6,3] <- sum(PsiH$C_BR[10,4:6])
500 TS[5,2] <- PsiH$L_BR[10,8]
501 TS[6,2] <- PsiH$S_BR[10,8]
502 TS[7,2] <- PsiH$C_BR[10,8]
503 TS[8,2] <- PsiH$IIE[10,8]
504 TS[5,3] <- PsiH$L_BR[10,9]
505 TS[6,3] <- PsiH$S_BR[10,9]
506 TS[7,3] <- PsiH$C_BR[10,9]
507 TS[8,3] <- PsiH$IIE[10,9]
508 # FRIs
509 latentes <- c("L_BRn","S_BRn","C_BRn", "IIE",
510 "L_EUA","S_EUA","C_EUA", "EPU")
511 latentes_BR <- c("L_BRn","S_BRn","C_BRn", "IIE")
512 periodo <- matrix(1:61, ncol=1)
513 for(i in latentes){
514   for(j in latentes_BR){
515     IRFV <- irf(var_aux, impulse = i, response = j,
516 n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
517 ci = 0.90, runs = 100)
518 IRFVd <- data.frame(cbind(periodo,unlist(eval(parse(text=paste0
      ("IRFV$irf$",
519 i))))), unlist(IRFV$Lower), unlist(IRFV$Upper)))
520 colnames(IRFVd) <- c("periodo","oi","lower","upper")
521
522 print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
      upper)) +
523 scale_x_continuous(limits = c(0, 61)) +

```

```
524 geom_hline(yintercept = 0, color="red") +
525 geom_ribbon(fill="grey", alpha=0.2) +
526 geom_line() +
527 theme_light() +
528 ylab(i)+
529 xlab(j)+
530 theme(plot.title = element_text(size = 11, hjust=0.5),
531 axis.title.y = element_text(size=11)))
532 }
533 }
534
535
536 ## Resultados de spillovers entre curvas
537 stargazer(Trp)
538 stargazer(TS)
539
540
541
542
543 ##### INCERTEZA NA CURVA DE JUROS
544 #####
545
546 ### 1- Regressoes
547
548 ## Dados
549 dados2SSP <- merge(SP, PCaux1[,1:4], by="mes") #swap, spread
550 dados2SSP <- merge(dados2SSP, ebr[,c(1:7,9,11)], by="mes")
551 dados2ESP <- merge(SPn, PCaux2[,1:4], by="mes") #ettjn, spread
552 dados2ESP <- merge(dados2ESP, ebr[,c(1:7,9,11)], by="mes")
553 T <- nrow(ybr)# Retira NAs de RX
554 RX <- data.frame(RX[1:(T-12),])
555 RXn <- data.frame(RXn[1:(T-12),])
556 dados2SRX <- merge(RX, PCaux1[,1:4], by="mes") #swap, rx
557 dados2SRX <- merge(dados2SRX, ebr[,c(1:7,9,11)], by="mes")
558 dados2ERX <- merge(RXn, PCaux2[,1:4], by="mes") #ettjn, rx
559 dados2ERX <- merge(dados2ERX, ebr[,c(1:7,9,11)], by="mes")
560 # Correlogramas
561 corrgram(dados2SSP, lower.panel=panel.pts, upper.panel=panel.cor
562 ,
563 text.panel=panel.txt)
564 corrgram(dados2SRX, lower.panel=panel.pts, upper.panel=panel.cor
565 ,
```

```
563 text.panel=panel.txt)
564 corrgram(dados2ESP, lower.panel=panel.pts, upper.panel=panel.cor
,
565 text.panel=panel.txt)
566 corrgram(dados2ERX, lower.panel=panel.pts, upper.panel=panel.cor
,
567 text.panel=panel.txt)
568
569
570 ## SP
571 vd <- c("sp24", "sp36", "sp48", "sp60")
572 # Swap
573 M1 <- regressoes(vd, f_vis = "CRE +INF +CAM +DIV +IIE",
dados2SSP)
574 M2 <- regressoes(vd, f_vis = "CRE +INF +CAM +DIV +EPU",
dados2SSP)
575 M3 <- regressoes(vd, f_vis = "CRE +INF +CAM +DIV +IIE +EPU",
dados2SSP)
576 stargazer(M1$modelos, M2$modelos, M3$modelos)
577 stargazer(M1$NW, M2$NW, M3$NW)
578 xtable(cbind(M1$BPBG, M2$BPBG, M3$BPBG), digits = 3)
579 # ETTJ
580 M1 <- regressoes(vd, f_vis = "CRE +INF +CAM +DIV +IIE",
dados2ESP)
581 M2 <- regressoes(vd, f_vis = "CRE +INF +CAM +DIV +EPU",
dados2ESP)
582 M3 <- regressoes(vd, f_vis = "CRE +INF +CAM +DIV +IIE +EPU",
dados2ESP)
583 stargazer(M1$modelos, M2$modelos, M3$modelos)
584 stargazer(M1$NW, M2$NW, M3$NW)
585 xtable(cbind(M1$BPBG, M2$BPBG, M3$BPBG), digits = 3)
586
587 ## RX
588 vd <- c("rx24", "rx36", "rx48", "rx60")
589 # Swap
590 M1 <- regressoes(vd, f_vis = "L_BR +S_BR +C_BR +IIE", dados2SRX
)
591 M2 <- regressoes(vd, f_vis = "L_BR +S_BR +C_BR +EPU", dados2SRX
)
592 M3 <- regressoes(vd, f_vis = "L_BR +S_BR +C_BR +IIE +EPU",
dados2SRX)
593 stargazer(M1$modelos, M2$modelos, M3$modelos)
```

```

594 stargazer(M1$NW, M2$NW, M3$NW)
595 xtable(cbind(M1$BPBG, M2$BPBG, M3$BPBG), digits = 3)
596 # ETTJ
597 M1 <- regressoes(vd, f_vis = "L_BRn +S_BRn +C_BRn +IIE",
598 dados2ERX)
598 M2 <- regressoes(vd, f_vis = "L_BRn +S_BRn +C_BRn +EPU",
599 dados2ERX)
599 M3 <- regressoes(vd, f_vis = "L_BRn +S_BRn +C_BRn +IIE +EPU",
600 dados2ERX)
600 stargazer(M1$modelos, M2$modelos, M3$modelos)
601 stargazer(M1$NW, M2$NW, M3$NW)
602 xtable(cbind(M1$BPBG, M2$BPBG, M3$BPBG), digits = 3)
603
604
605
606 ### 2- VAR e IRF sobre L, S, e C
607
608 ## Swap
609 # Dados
610 dados2VARS1 <- merge(PCaux1[1:4], ebr[,c(1,9)], by="mes")
611 dados2VARS2 <- merge(PCaux1[1:4], ebr[,c(1,11)], by="mes")
612 dados2VARS3 <- merge(PCaux1[1:4], ebr[,c(1,9,11)], by="mes")
613 # M1
614 d_aux <- ts(data.frame(dados2VARS1[, -1]))
615 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
616 spec="longrun")
616 summary(coint_test) # teste de cointegracao
617 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
618 summary(var_aux)
619 normality.test(var_aux) # teste de normalidade
620 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
621 serial
621 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
622 heterocedasticidade
622 v_resp <- c("L_BR", "S_BR", "C_BR")
623 periodo <- matrix(1:61, ncol=1)
624 for(j in v_resp){
625 IRFV <- irf(var_aux, impulse = "IIE", response = j,
626 n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
627 ci = 0.90, runs = 100)
628 IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$IIE), unlist(
629 IRFV$Lower),

```



```
629 unlist(IRFV$Upper)))
630 colnames(IRFVd) <- c("periodo","oi","lower","upper")
631
632 print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
  upper)) +
633 scale_x_continuous(limits = c(0, 61)) +
634 geom_hline(yintercept = 0, color="red") +
635 geom_ribbon(fill="grey", alpha=0.2) +
636 geom_line() +
637 theme_light() +
638 ylab("IIE")+
639 xlab(j)+
640 theme(plot.title = element_text(size = 11, hjust=0.5),
641 axis.title.y = element_text(size=11)))
642 }
643 # M2
644 d_aux <- ts(data.frame(dados2VARS2[, -1]))
645 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
  spec="longrun")
646 summary(coint_test) # teste de cointegracao
647 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
648 restriction <- matrix(1, nrow = 4, ncol = 5) # Restricoes de
  economia aberta
649 restriction[4,1:3] <- 0
650 var_aux <- restrict(var_aux, method = "man", resmat =
  restriction)
651 summary(var_aux)
652 normality.test(var_aux) # teste de normalidade
653 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
  serial
654 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
  heterocedasticidade
655 v_resp <- c("L_BR", "S_BR", "C_BR")
656 periodo <- matrix(1:61, ncol=1)
657 for(j in v_resp){ # FRIs
658 IRFV <- irf(var_aux, impulse = "EPU", response = j,
659 n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
660 ci = 0.90, runs = 100)
661 IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$EPU), unlist(
  IRFV$Lower),
662 unlist(IRFV$Upper)))
663 colnames(IRFVd) <- c("periodo","oi","lower","upper")
```

```
664
665 print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
        upper)) +
666 scale_x_continuous(limits = c(0, 61)) +
667 geom_hline(yintercept = 0, color="red") +
668 geom_ribbon(fill="grey", alpha=0.2) +
669 geom_line() +
670 theme_light() +
671 ylab("EPU")+
672 xlab(j)+
673 theme(plot.title = element_text(size = 11, hjust=0.5),
674 axis.title.y = element_text(size=11)))
675 }
676 # M3
677 d_aux <- ts(data.frame(dados2VARS3[,-1]))
678 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
        spec="longrun")
679 summary(coint_test) # teste de cointegracao
680 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
681 restriction <- matrix(1, nrow = 5, ncol = 6) # Restricoes de
        economia aberta
682 restriction[5,1:4] <- 0
683 var_aux <- restrict(var_aux, method = "man", resmat =
        restriction)
684 summary(var_aux)
685 normality.test(var_aux) # teste de normalidade
686 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
        serial
687 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
        heterocedastcidade
688 v_resp <- c("L_BR","S_BR","C_BR")
689 periodo <- matrix(1:61, ncol=1)
690 for(j in v_resp){ # FRIs
691 IRFV <- irf(var_aux, impulse = "IIE", response = j,
692 n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
693 ci = 0.90, runs = 100)
694 IRFVd <- data.frame(cbind(periodo,unlist(IRFV$irf$IIE), unlist(
        IRFV$Lower),
695 unlist(IRFV$Upper)))
696 colnames(IRFVd) <- c("periodo","oi","lower","upper")
697
```

```
698 print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
699   upper)) +
700   scale_x_continuous(limits = c(0, 61)) +
701   geom_hline(yintercept = 0, color="red") +
702   geom_ribbon(fill="grey", alpha=0.2) +
703   geom_line() +
704   theme_light() +
705   ylab("IIE")+
706   xlab(j)+
707   theme(plot.title = element_text(size = 11, hjust=0.5),
708     axis.title.y = element_text(size=11)))
709 }
710 for(j in v_resp){ # FRIs
711   IRFV <- irf(var_aux, impulse = "EPU", response = j,
712     n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
713     ci = 0.90, runs = 100)
714   IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$EPU), unlist(
715     IRFV$Lower),
716     unlist(IRFV$Upper)))
717   colnames(IRFVd) <- c("periodo", "oi", "lower", "upper")
718
719   print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
720     upper)) +
721     scale_x_continuous(limits = c(0, 61)) +
722     geom_hline(yintercept = 0, color="red") +
723     geom_ribbon(fill="grey", alpha=0.2) +
724     geom_line() +
725     theme_light() +
726     ylab("EPU")+
727     xlab(j)+
728     theme(plot.title = element_text(size = 11, hjust=0.5),
729       axis.title.y = element_text(size=11)))
730 }
731
732 ## ETTJ
733 # Dados
734 dados2VARS1 <- merge(PCaux2[1:4], ebr[,c(1,9)], by="mes")
735 dados2VARS2 <- merge(PCaux2[1:4], ebr[,c(1,11)], by="mes")
736 dados2VARS3 <- merge(PCaux2[1:4], ebr[,c(1,9,11)], by="mes")
737
738 # M1
739 d_aux <- ts(data.frame(dados2VARS1[, -1]))
```

```
737 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
738   spec="longrun")
739 summary(coint_test) # teste de cointegracao
740 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
741 summary(var_aux)
742 normality.test(var_aux) # teste de normalidade
743 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
744   serial
745 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
746   heterocedastcidade
747 v_resp <- c("L_BRn", "S_BRn", "C_BRn")
748 periodo <- matrix(1:61, ncol=1)
749 for(j in v_resp){
750   IRFV <- irf(var_aux, impulse = "IIE", response = j,
751     n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
752     ci = 0.90, runs = 100)
753   IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$IIE), unlist(
754     IRFV$Lower),
755     unlist(IRFV$Upper)))
756   colnames(IRFVd) <- c("periodo", "oi", "lower", "upper")
757
758   print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
759     upper)) +
760     scale_x_continuous(limits = c(0, 61)) +
761     geom_hline(yintercept = 0, color="red") +
762     geom_ribbon(fill="grey", alpha=0.2) +
763     geom_line() +
764     theme_light() +
765     ylab("IIE")+
766     xlab(j)+
767     theme(plot.title = element_text(size = 11, hjust=0.5),
768     axis.title.y = element_text(size=11)))
769 }
770 # M2
771 d_aux <- ts(data.frame(dados2VARS2[, -1]))
772 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
773   spec="longrun")
774 summary(coint_test) # teste de cointegracao
775 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
776 restriction <- matrix(1, nrow = 4, ncol = 5) # Restricoes de
777   economia aberta
778 restriction[4,1:3] <- 0
```

```
772 var_aux <- restrict(var_aux, method = "man", resmat =
      restriction)
773 summary(var_aux)
774 normality.test(var_aux) # teste de normalidade
775 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
776 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedastcidade
777 v_resp <- c("L_BRn", "S_BRn", "C_BRn")
778 periodo <- matrix(1:61, ncol=1)
779 for(j in v_resp){ # FRIs
780   IRFV <- irf(var_aux, impulse = "EPU", response = j,
781     n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
782     ci = 0.90, runs = 100)
783   IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$EPU), unlist(
      IRFV$Lower),
784     unlist(IRFV$Upper)))
785   colnames(IRFVd) <- c("periodo", "oi", "lower", "upper")
786
787   print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
      upper)) +
788     scale_x_continuous(limits = c(0, 61)) +
789     geom_hline(yintercept = 0, color="red") +
790     geom_ribbon(fill="grey", alpha=0.2) +
791     geom_line() +
792     theme_light() +
793     ylab("EPU")+
794     xlab(j)+
795     theme(plot.title = element_text(size = 11, hjust=0.5),
796       axis.title.y = element_text(size=11)))
797 }
798 # M3
799 d_aux <- ts(data.frame(dados2VARS3[, -1]))
800 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
      spec="longrun")
801 summary(coint_test) # teste de cointegracao
802 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
803 restriction <- matrix(1, nrow = 5, ncol = 6) # Restricoes de
      economia aberta
804 restriction[5,1:4] <- 0
805 var_aux <- restrict(var_aux, method = "man", resmat =
      restriction)
```

```
806 summary(var_aux)
807 normality.test(var_aux) # teste de normalidade
808 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
809 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedasticidade
810 v_resp <- c("L_BRn", "S_BRn", "C_BRn")
811 periodo <- matrix(1:61, ncol=1)
812 for(j in v_resp){ # FRIs
813   IRFV <- irf(var_aux, impulse = "IIE", response = j,
814     n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
815     ci = 0.90, runs = 100)
816   IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$IIE), unlist(
      IRFV$Lower),
817     unlist(IRFV$Upper)))
818   colnames(IRFVd) <- c("periodo", "oi", "lower", "upper")
819
820   print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
      upper)) +
821     scale_x_continuous(limits = c(0, 61)) +
822     geom_hline(yintercept = 0, color="red") +
823     geom_ribbon(fill="grey", alpha=0.2) +
824     geom_line() +
825     theme_light() +
826     ylab("IIE")+
827     xlab(j)+
828     theme(plot.title = element_text(size = 11, hjust=0.5),
829       axis.title.y = element_text(size=11)))
830 }
831 for(j in v_resp){ # FRIs
832   IRFV <- irf(var_aux, impulse = "EPU", response = j,
833     n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
834     ci = 0.90, runs = 100)
835   IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$EPU), unlist(
      IRFV$Lower),
836     unlist(IRFV$Upper)))
837   colnames(IRFVd) <- c("periodo", "oi", "lower", "upper")
838
839   print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
      upper)) +
840     scale_x_continuous(limits = c(0, 61)) +
841     geom_hline(yintercept = 0, color="red") +
```

```
842 geom_ribbon(fill="grey", alpha=0.2) +
843 geom_line() +
844 theme_light() +
845 ylab("EPU")+
846 xlab(j)+
847 theme(plot.title = element_text(size = 11, hjust=0.5),
848 axis.title.y = element_text(size=11))
849 }
850
851
852
853 ##### 3- VAR e IRF sobre L, S, C, CRE, INF, CAM, DIV
854
855 ## Swap
856 # Dados
857 dados2VARS1 <- merge(PCaux1[1:4], ebr[,c(1,2,5,6,7,9)], by="mes
858 ")
859 dados2VARS2 <- merge(PCaux1[1:4], ebr[,c(1,2,5,6,7,11)], by="
860 mes")
861 dados2VARS3 <- merge(PCaux1[1:4], ebr[,c(1,2,5,6,7,9,11)], by="
862 mes")
863 # M1
864 d_aux <- ts(data.frame(dados2VARS1[,-1]))
865 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
866 spec="longrun")
867 summary(coint_test) # teste de cointegracao
868 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
869 summary(var_aux)
870 normality.test(var_aux) # teste de normalidade
871 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
872 serial
873 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
874 heterocedastcidade
875 v_resp <- c("L_BR", "S_BR", "C_BR")
876 periodo <- matrix(1:61, ncol=1)
877 for(j in v_resp){
878 IRFV <- irf(var_aux, impulse = "IIE", response = j,
879 n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
880 ci = 0.90, runs = 100)
881 IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$IIE), unlist(
882 IRFV$Lower),
883 unlist(IRFV$Upper)))
```

```
877 colnames(IRFVd) <- c("periodo","oi","lower","upper")
878
879 print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
      upper)) +
880 scale_x_continuous(limits = c(0, 61)) +
881 geom_hline(yintercept = 0, color="red") +
882 geom_ribbon(fill="grey", alpha=0.2) +
883 geom_line() +
884 theme_light() +
885 ylab("IIE")+
886 xlab(j)+
887 theme(plot.title = element_text(size = 11, hjust=0.5),
888 axis.title.y = element_text(size=11)))
889 }
890 # M2
891 d_aux <- ts(data.frame(dados2VARS2[,-1]))
892 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
      spec="longrun")
893 summary(coint_test) # teste de cointegracao
894 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
895 restriction <- matrix(1, nrow = 8, ncol = 9) # Restricoes de
      economia aberta
896 restriction[9,1:7] <- 0
897 var_aux <- restrict(var_aux, method = "man", resmat =
      restriction)
898 summary(var_aux)
899 normality.test(var_aux) # teste de normalidade
900 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
901 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedasticidade
902 v_resp <- c("L_BR","S_BR","C_BR")
903 periodo <- matrix(1:61, ncol=1)
904 for(j in v_resp){ # FRIs
905 IRFV <- irf(var_aux, impulse = "EPU", response = j,
906 n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
907 ci = 0.90, runs = 100)
908 IRFVd <- data.frame(cbind(periodo,unlist(IRFV$irf$EPU), unlist(
      IRFV$Lower),
909 unlist(IRFV$Upper)))
910 colnames(IRFVd) <- c("periodo","oi","lower","upper")
911
```



```

912 print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
      upper)) +
913 scale_x_continuous(limits = c(0, 61)) +
914 geom_hline(yintercept = 0, color="red") +
915 geom_ribbon(fill="grey", alpha=0.2) +
916 geom_line() +
917 theme_light() +
918 ylab("EPU")+
919 xlab(j)+
920 theme(plot.title = element_text(size = 11, hjust=0.5),
921 axis.title.y = element_text(size=11)))
922 }
923 # M3
924 d_aux <- ts(data.frame(dados2VARS3[, -1]))
925 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
      spec="longrun")
926 summary(coint_test) # teste de cointegracao
927 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
928 restriction <- matrix(1, nrow = 9, ncol = 10) # Restricoes de
      economia aberta
929 restriction[9,1:8] <- 0
930 var_aux <- restrict(var_aux, method = "man", resmat =
      restriction)
931 summary(var_aux)
932 normality.test(var_aux) # teste de normalidade
933 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
934 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedasticidade
935 v_resp <- c("L_BR", "S_BR", "C_BR")
936 periodo <- matrix(1:61, ncol=1)
937 for(j in v_resp){ # FRIs
938 IRFV <- irf(var_aux, impulse = "DIV", response = j,
939 n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
940 ci = 0.90, runs = 100)
941 IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$DIV), unlist(
      IRFV$Lower),
942 unlist(IRFV$Upper)))
943 colnames(IRFVd) <- c("periodo", "oi", "lower", "upper")
944
945 print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
      upper)) +

```

```
946 scale_x_continuous(limits = c(0, 61)) +
947 geom_hline(yintercept = 0, color="red") +
948 geom_ribbon(fill="grey", alpha=0.2) +
949 geom_line() +
950 theme_light() +
951 ylab("IIE")+
952 xlab(j)+
953 theme(plot.title = element_text(size = 11, hjust=0.5),
954 axis.title.y = element_text(size=11))
955 }
956 for(j in v_resp){ # FRIs
957 IRFV <- irf(var_aux, impulse = "EPU", response = j,
958 n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
959 ci = 0.90, runs = 100)
960 IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$EPU), unlist(
961 IRFV$Lower),
962 unlist(IRFV$Upper)))
963 colnames(IRFVd) <- c("periodo", "oi", "lower", "upper")
964 print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
965 upper)) +
966 scale_x_continuous(limits = c(0, 61)) +
967 geom_hline(yintercept = 0, color="red") +
968 geom_ribbon(fill="grey", alpha=0.2) +
969 geom_line() +
970 theme_light() +
971 ylab("EPU")+
972 xlab(j)+
973 theme(plot.title = element_text(size = 11, hjust=0.5),
974 axis.title.y = element_text(size=11))
975 }
976
977 ## ETTJ
978 # Dados
979 dados2VARS1 <- merge(PCaux2[1:4], ebr[,c(1,2,5,6,7,9)], by="mes
980 ")
981 dados2VARS2 <- merge(PCaux2[1:4], ebr[,c(1,2,5,6,7,11)], by="
982 mes")
983 dados2VARS3 <- merge(PCaux2[1:4], ebr[,c(1,2,5,6,7,9,11)], by="
984 mes")
985 # M1
```

```

983 d_aux <- ts(data.frame(dados2VARS1[,-1]))
984 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
985   spec="longrun")
986 summary(coint_test) # teste de cointegracao
987 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
988 summary(var_aux)
989 normality.test(var_aux) # teste de normalidade
990 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
991   serial
992 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
993   heterocedasticidade
994 v_resp <- c("L_BRn", "S_BRn", "C_BRn")
995 periodo <- matrix(1:61, ncol=1)
996 for(j in v_resp){
997   IRFV <- irf(var_aux, impulse = "IIE", response = j,
998     n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
999     ci = 0.90, runs = 100)
1000   IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$IIE), unlist(
1001     IRFV$Lower),
1002     unlist(IRFV$Upper)))
1003   colnames(IRFVd) <- c("periodo", "oi", "lower", "upper")
1004   print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
1005     upper)) +
1006     scale_x_continuous(limits = c(0, 61)) +
1007     geom_hline(yintercept = 0, color="red") +
1008     geom_ribbon(fill="grey", alpha=0.2) +
1009     geom_line() +
1010     theme_light() +
1011     ylab("IIE")+
1012     xlab(j)+
1013     theme(plot.title = element_text(size = 11, hjust=0.5),
1014     axis.title.y = element_text(size=11)))
1015 }
1016 # M2
1017 d_aux <- ts(data.frame(dados2VARS2[,-1]))
1018 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
1019   spec="longrun")
1020 summary(coint_test) # teste de cointegracao
1021 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
1022 restriction <- matrix(1, nrow = 8, ncol = 9) # Restricoes de
1023   economia aberta

```

```
1018 restriction[8,1:7] <- 0
1019 var_aux <- restrict(var_aux, method = "man", resmat =
      restriction)
1020 summary(var_aux)
1021 normality.test(var_aux) # teste de normalidade
1022 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
1023 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedastcidade
1024 v_resp <- c("L_BRn", "S_BRn", "C_BRn")
1025 periodo <- matrix(1:61, ncol=1)
1026 for(j in v_resp){ # FRIs
1027 IRFV <- irf(var_aux, impulse = "EPU", response = j,
1028 n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
1029 ci = 0.90, runs = 100)
1030 IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$EPU), unlist(
      IRFV$Lower),
1031 unlist(IRFV$Upper)))
1032 colnames(IRFVd) <- c("periodo", "oi", "lower", "upper")
1033
1034 print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
      upper)) +
1035 scale_x_continuous(limits = c(0, 61)) +
1036 geom_hline(yintercept = 0, color="red") +
1037 geom_ribbon(fill="grey", alpha=0.2) +
1038 geom_line() +
1039 theme_light() +
1040 ylab("EPU")+
1041 xlab(j)+
1042 theme(plot.title = element_text(size = 11, hjust=0.5),
1043 axis.title.y = element_text(size=11)))
1044 }
1045 # M3
1046 d_aux <- ts(data.frame(dados2VARS3[, -1]))
1047 coint_test <- ca.jo(d_aux, ecdet = "none", type="eigen", K=2,
      spec="longrun")
1048 summary(coint_test) # teste de cointegracao
1049 var_aux <- VAR(d_aux, p=1, type = "const") # p=1, como o DTSM
1050 restriction <- matrix(1, nrow = 9, ncol = 10) # Restricoes de
      economia aberta
1051 restriction[9,1:8] <- 0
```

```
1052 var_aux <- restrict(var_aux, method = "man", resmat =
      restriction)
1053 summary(var_aux)
1054 normality.test(var_aux) # teste de normalidade
1055 serial.test(var_aux, lags.bg=1, type="BG") #teste de correlacao
      serial
1056 arch.test(var_aux, lags.single = 1, lags.multi = 1) # teste
      heterocedastcidade
1057 v_resp <- c("L_BRn", "S_BRn", "C_BRn")
1058 periodo <- matrix(1:61, ncol=1)
1059 for(j in v_resp){ # FRIs
1060   IRFV <- irf(var_aux, impulse = "IIE", response = j,
1061     n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
1062     ci = 0.90, runs = 100)
1063   IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$IIE), unlist(
      IRFV$Lower),
1064     unlist(IRFV$Upper)))
1065   colnames(IRFVd) <- c("periodo", "oi", "lower", "upper")
1066
1067   print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
      upper)) +
1068     scale_x_continuous(limits = c(0, 61)) +
1069     geom_hline(yintercept = 0, color="red") +
1070     geom_ribbon(fill="grey", alpha=0.2) +
1071     geom_line() +
1072     theme_light() +
1073     ylab("IIE")+
1074     xlab(j)+
1075     theme(plot.title = element_text(size = 11, hjust=0.5),
1076       axis.title.y = element_text(size=11)))
1077 }
1078 for(j in v_resp){ # FRIs
1079   IRFV <- irf(var_aux, impulse = "EPU", response = j,
1080     n.ahead = 60, ortho = TRUE, cumulative = FALSE, boot = TRUE,
1081     ci = 0.90, runs = 100)
1082   IRFVd <- data.frame(cbind(periodo, unlist(IRFV$irf$EPU), unlist(
      IRFV$Lower),
1083     unlist(IRFV$Upper)))
1084   colnames(IRFVd) <- c("periodo", "oi", "lower", "upper")
1085
1086   print(ggplot(data=IRFVd, aes(x=periodo, y=oi, ymin=lower, ymax=
      upper)) +
```

```

1087 scale_x_continuous(limits = c(0, 61)) +
1088 geom_hline(yintercept = 0, color="red") +
1089 geom_ribbon(fill="grey", alpha=0.2) +
1090 geom_line() +
1091 theme_light() +
1092 ylab("EPU")+
1093 xlab(j)+
1094 theme(plot.title = element_text(size = 11, hjust=0.5),
1095 axis.title.y = element_text(size=11))
1096 }
1097
1098
1099
1100 ##### SETPWISE BACKWARD
1101 #####
1102
1103 ## Dados
1104 dados4SP1 <- merge(SP, PCaux1, by="mes")
1105 dados4SP1 <- merge(dados4SP1, PCaux3, by="mes")
1106 dados4SP1 <- merge(dados4SP1, ebr, by="mes")
1107 dados4SP2 <- merge(SPn, PCaux2, by="mes")
1108 dados4SP2 <- merge(dados4SP2, PCaux3, by="mes")
1109 dados4SP2 <- merge(dados4SP2, ebr, by="mes")
1110 dados4RX1 <- merge(RX, PCaux1, by="mes")
1111 dados4RX1 <- merge(dados4RX1, PCaux3, by="mes")
1112 dados4RX1 <- merge(dados4RX1, ebr, by="mes")
1113 dados4RX2 <- merge(RXn, PCaux2, by="mes")
1114 dados4RX2 <- merge(dados4RX2, PCaux3, by="mes")
1115 dados4RX2 <- merge(dados4RX2, ebr, by="mes")
1116
1117 # Correlogramas
1118 corrgram(dados4SP1, lower.panel=panel.pts,
1119 upper.panel=panel.cor, text.panel=panel.txt)
1120 corrgram(dados4SP2, lower.panel=panel.pts,
1121 upper.panel=panel.cor, text.panel=panel.txt)
1122 corrgram(dados4RX1, lower.panel=panel.pts,
1123 upper.panel=panel.cor, text.panel=panel.txt)
1124 corrgram(dados4RX2, lower.panel=panel.pts,
1125 upper.panel=panel.cor, text.panel=panel.txt)
1126
1127 #PCA
1128 PC_exo <- princomp(dados21[, -(1:8)], cor=FALSE)
1129 PC_exo$loadings
1130 PC_exo <- princomp(dados22[, -(1:8)], cor=FALSE)

```

```
1128 PC_exo$loadings
1129
1130
1131
1132 ### Reg SP
1133 vd <- c("sp24", "sp36", "sp48", "sp60")
1134
1135 ## Swap
1136 # Regressao completa
1137 MSPs <- regressoes(vd, f_vis = "L_EUA +S_EUA +C_EUA +UCI +CRE +
      EINF +INF +CAM +DIV +DUR +IIE +EMBI +EPU +VIX", dados4SP1)
1138 # Regressao reduzida
1139 MSPsr <- regressoes(vd, f_vis = "UCI +INF +CAM +DIV +IIE +EMBI
      +EPU", dados4SP1)
1140 # P-valores
1141 max(colMeans(rbind(MSPsr$NW[[1]][,4], MSPsr$NW[[2]][,4], MSPsr$
      NW[[3]][,4],
1142 MSPsr$NW[[4]][,4])))
1143 colMeans(rbind(MSPsr$NW[[1]][,4], MSPsr$NW[[2]][,4], MSPsr$NW
      [[3]][,4],
1144 MSPsr$NW[[4]][,4]))
1145 rbind(MSPsr$NW[[1]][,4], MSPsr$NW[[2]][,4], MSPsr$NW[[3]][,4],
      MSPsr$NW[[4]][,4])
1146
1147 ## ETTJ
1148 # Regressao completa
1149 MSPe <- regressoes(vd, f_vis = "L_EUA +S_EUA +C_EUA +UCI +CRE +
      EINF +INF +CAM +DIV +DUR +IIE +EMBI +EPU +VIX", dados4SP2)
1150 # Regressao reduzida
1151 MSPer <- regressoes(vd, f_vis = "UCI +INF +IIE +EMBI",
      dados4SP2)
1152 # P-valores
1153 max(colMeans(rbind(MSPer$NW[[1]][,4], MSPer$NW[[2]][,4], MSPer$
      NW[[3]][,4],
1154 MSPer$NW[[4]][,4])))
1155 colMeans(rbind(MSPer$NW[[1]][,4], MSPer$NW[[2]][,4], MSPer$NW
      [[3]][,4],
1156 MSPer$NW[[4]][,4]))
1157 rbind(MSPer$NW[[1]][,4], MSPer$NW[[2]][,4], MSPer$NW[[3]][,4],
      MSPer$NW[[4]][,4])
1158
1159 ## Resultados
```

```
1160 # Regressoes completas
1161 stargazer(MSPs$modelos, MSPe$modelos)
1162 stargazer(MSPs$NW, MSPe$NW)
1163 xtable(cbind(MSPs$BPBG, MSPe$BPBG), digits = 3)
1164 # Regressoes reduzidas
1165 stargazer(MSPsr$modelos, MSPer$modelos)
1166 stargazer(MSPsr$NW, MSPer$NW)
1167 xtable(cbind(MSPsr$BPBG, MSPer$BPBG), digits = 3)
1168
1169
1170
1171 ### Reg RX
1172 vd <- c("rx24", "rx36", "rx48", "rx60")
1173
1174 ## Swap
1175 # Regressao completa
1176 MRXs <- regressoes(vd, f_vis = "L_BR +S_BR +C_BR +PC4_BR +PC5_
      BR +L_EUA +S_EUA +C_EUA +UCI +CRE +EINF +INF +CAM +DIV +DUR +
      IIE +EMBI +EPU +VIX", dados4RX1)
1177 # Regressao reduzida
1178 MRXsr <- regressoes(vd, f_vis = "L_BR +C_BR +L_EUA +C_EUA +UCI
      +EINF +INF +CAM +DIV +DUR +VIX", dados4RX1)
1179 # P-valores
1180 max(colMeans(rbind(MRXsr$NW[[1]][,4], MRXsr$NW[[2]][,4], MRXsr$
      NW[[3]][,4],
1181 MRXsr$NW[[4]][,4])))
1182 colMeans(rbind(MRXsr$NW[[1]][,4], MRXsr$NW[[2]][,4], MRXsr$NW
      [[3]][,4],
1183 MRXsr$NW[[4]][,4]))
1184 rbind(MRXsr$NW[[1]][,4], MRXsr$NW[[2]][,4], MRXsr$NW[[3]][,4],
      MRXsr$NW[[4]][,4])
1185
1186 ## ETTJ
1187 # Regressao completa
1188 MRXe <- regressoes(vd, f_vis = "L_BRn +S_BRn +C_BRn +PC4_BRn +
      PC5_BRn +UCI +CRE +EINF +INF +CAM +DIV +DUR +L_EUA +S_EUA +C_
      EUA +IIE +EMBI +EPU +VIX", dados4RX2)
1189 # Regressao reduzida
1190 MRXer <- regressoes(vd, f_vis = "L_BRn +S_BRn +C_BRn +PC5_BRn +
      UCI +CRE +EINF +INF +CAM +DIV +DUR +L_EUA +C_EUA +VIX",
      dados4RX2)
1191 # P-valores
```



```
1192 max(colMeans(rbind(MRXer$NW[[1]][,4], MRXer$NW[[2]][,4], MRXer$
1193   NW[[3]][,4],
1194   MRXer$NW[[4]][,4]))
1195 colMeans(rbind(MRXer$NW[[1]][,4], MRXer$NW[[2]][,4], MRXer$NW
1196   [[3]][,4],
1197   MRXer$NW[[4]][,4]))
1198 rbind(MRXer$NW[[1]][,4], MRXer$NW[[2]][,4], MRXer$NW[[3]][,4],
1199   MRXer$NW[[4]][,4])
1200
1201 ## Resultados
1202 # Regressoes completas
1203 stargazer(MRXs$modelos, MRXe$modelos)
1204 stargazer(MRXs$NW, MRXe$NW)
1205 xtable(cbind(MRXs$BPBG, MRXe$BPBG), digits = 3)
1206 # Regressoes reduzidas
1207 stargazer(MRXsr$modelos, MRXer$modelos)
1208 stargazer(MRXsr$NW, MRXer$NW)
1209 xtable(cbind(MRXsr$BPBG, MRXer$BPBG), digits = 3)
1210
1211 ### Comparacao com Lasso e com Elastic Net
1212
1213 ## Spread
1214 Sel_lasso_s <- lapply(dados4SP1[,2:5], function(j) {
1215   vselection(as.matrix(dados4SP1[,11:24]), j, type = "LASSO")
1216 })
1217 Sel_elastic_s <- lapply(dados4SP1[,2:5], function(j) {
1218   vselection(as.matrix(dados4SP1[,11:24]), j, type = "ELASTIC NET"
1219   )
1220 })
1221 Sel_lasso_e <- lapply(dados4SP2[,2:5], function(j) {
1222   vselection(as.matrix(dados4SP2[,11:24]), j, type = "LASSO")
1223 })
1224 Sel_elastic_e <- lapply(dados4SP2[,2:5], function(j) {
1225   vselection(as.matrix(dados4SP2[,11:24]), j, type = "ELASTIC NET"
1226   )
1227 })
1228 #Swap
1229 stargazer(MSPsr$NW)
1230 stargazer(MSPsr$modelos)
```

```
1228 rbind(cbind(Sel_lasso_s$sp24$coeficientes, Sel_lasso_s$sp36$
      coeficientes,
1229 Sel_lasso_s$sp48$coeficientes, Sel_lasso_s$sp60$coeficientes,
1230 Sel_elastic_s$sp24$coeficientes, Sel_elastic_s$sp36$
      coeficientes,
1231 Sel_elastic_s$sp48$coeficientes, Sel_elastic_s$sp60$
      coeficientes),
1232 cbind(Sel_lasso_s$sp24$R2, Sel_lasso_s$sp36$R2,
1233 Sel_lasso_s$sp48$R2, Sel_lasso_s$sp60$R2,
1234 Sel_elastic_s$sp24$R2, Sel_elastic_s$sp36$R2,
1235 Sel_elastic_s$sp48$R2, Sel_elastic_s$sp60$R2),
1236 cbind(Sel_lasso_s$sp24$"R2 ajustado", Sel_lasso_s$sp36$"R2
      ajustado",
1237 Sel_lasso_s$sp48$"R2 ajustado", Sel_lasso_s$sp60$"R2 ajustado",
1238 Sel_elastic_s$sp24$"R2 ajustado", Sel_elastic_s$sp36$"R2
      ajustado",
1239 Sel_elastic_s$sp48$"R2 ajustado", Sel_elastic_s$sp60$"R2
      ajustado"))
1240 #ETTJ
1241 stargazer(MSPer$NW)
1242 stargazer(MSPer$modelos)
1243 rbind(cbind(Sel_lasso_e$sp24$coeficientes, Sel_lasso_e$sp36$
      coeficientes,
1244 Sel_lasso_e$sp48$coeficientes, Sel_lasso_e$sp60$coeficientes,
1245 Sel_elastic_e$sp24$coeficientes, Sel_elastic_e$sp36$
      coeficientes,
1246 Sel_elastic_e$sp48$coeficientes, Sel_elastic_e$sp60$
      coeficientes),
1247 cbind(Sel_lasso_e$sp24$R2, Sel_lasso_e$sp36$R2,
1248 Sel_lasso_e$sp48$R2, Sel_lasso_e$sp60$R2,
1249 Sel_elastic_e$sp24$R2, Sel_elastic_e$sp36$R2,
1250 Sel_elastic_e$sp48$R2, Sel_elastic_e$sp60$R2),
1251 cbind(Sel_lasso_e$sp24$"R2 ajustado", Sel_lasso_e$sp36$"R2
      ajustado",
1252 Sel_lasso_e$sp48$"R2 ajustado", Sel_lasso_e$sp60$"R2 ajustado",
1253 Sel_elastic_e$sp24$"R2 ajustado", Sel_elastic_e$sp36$"R2
      ajustado",
1254 Sel_elastic_e$sp48$"R2 ajustado", Sel_elastic_e$sp60$"R2
      ajustado"))
1255
1256
1257 ## Excesso de retorno
```

```
1258 Sel_lasso_s <- lapply(dados4RX1[,2:5], function(j) {
1259 vselection(as.matrix(dados4RX1[,6:24]), j, type = "LASSO")
1260 })
1261 Sel_elastic_s <- lapply(dados4RX1[,2:5], function(j) {
1262 vselection(as.matrix(dados4RX1[,6:24]), j, type = "ELASTIC NET")
1263 })
1264 Sel_lasso_e <- lapply(dados4RX2[,2:5], function(j) {
1265 vselection(as.matrix(dados4RX2[,6:24]), j, type = "LASSO")
1266 })
1267 Sel_elastic_e <- lapply(dados4RX2[,2:5], function(j) {
1268 vselection(as.matrix(dados4RX2[,6:24]), j, type = "ELASTIC NET")
1269 })
1270 #Swap
1271 stargazer(MRXsr$NW)
1272 stargazer(MRXsr$modelos)
1273 rbind(cbind(Sel_lasso_s$rx24$coeficientes, Sel_lasso_s$rx36$
1274             coeficientes,
1275             Sel_lasso_s$rx48$coeficientes, Sel_lasso_s$rx60$coeficientes,
1276             Sel_elastic_s$rx24$coeficientes, Sel_elastic_s$rx36$
1277             coeficientes,
1278             Sel_elastic_s$rx48$coeficientes, Sel_elastic_s$rx60$
1279             coeficientes),
1280       cbind(Sel_lasso_s$rx24$R2, Sel_lasso_s$rx36$R2,
1281             Sel_lasso_s$rx48$R2, Sel_lasso_s$rx60$R2,
1282             Sel_elastic_s$rx24$R2, Sel_elastic_s$rx36$R2,
1283             Sel_elastic_s$rx48$R2, Sel_elastic_s$rx60$R2),
1284       cbind(Sel_lasso_s$rx24$"R2 ajustado", Sel_lasso_s$rx36$"R2
1285             ajustado",
1286             Sel_lasso_s$rx48$"R2 ajustado", Sel_lasso_s$rx60$"R2 ajustado",
1287             Sel_elastic_s$rx24$"R2 ajustado", Sel_elastic_s$rx36$"R2
1288             ajustado",
1289             Sel_elastic_s$rx48$"R2 ajustado", Sel_elastic_s$rx60$"R2
1290             ajustado"))
1291 #ETTJ
1292 stargazer(MRXer$NW)
1293 stargazer(MRXer$modelos)
1294 rbind(cbind(Sel_lasso_e$rx24$coeficientes, Sel_lasso_e$rx36$
1295             coeficientes,
1296             Sel_lasso_e$rx48$coeficientes, Sel_lasso_e$rx60$coeficientes,
1297             Sel_elastic_e$rx24$coeficientes, Sel_elastic_e$rx36$
1298             coeficientes,
```

```
1291 Sel_elastic_e$rx48$coeficientes, Sel_elastic_e$rx60$
      coeficientes),
1292 cbind(Sel_lasso_e$rx24$R2, Sel_lasso_e$rx36$R2,
1293 Sel_lasso_e$rx48$R2, Sel_lasso_e$rx60$R2,
1294 Sel_elastic_e$rx24$R2, Sel_elastic_e$rx36$R2,
1295 Sel_elastic_e$rx48$R2, Sel_elastic_e$rx60$R2),
1296 cbind(Sel_lasso_e$rx24$"R2 ajustado", Sel_lasso_e$rx36$"R2
      ajustado",
1297 Sel_lasso_e$rx48$"R2 ajustado", Sel_lasso_e$rx60$"R2 ajustado",
1298 Sel_elastic_e$rx24$"R2 ajustado", Sel_elastic_e$rx36$"R2
      ajustado",
1299 Sel_elastic_e$rx48$"R2 ajustado", Sel_elastic_e$rx60$"R2
      ajustado"))
1300
1301
1302
1303 ##### Incerteza no DTSM
      #####
1304
1305
1306 ### Swap
1307 #Preparacao dos dados
1308 dates <- as.numeric(format(ybr$mes,"%Y%m%d"))
1309 n.per <- 12
1310 Y <- as.matrix(ybr[,-1])
1311 mats <- c(1, 3, 6, 12, 18, 21, 24, 27, 30, 33, 36, 48, 60, 96,
      120) # Vertices
1312 J <- length(ybr[,-1])
1313 cL <- 3 # Numero de PCs
1314 eig <- eigen(cov(Y)) # Para criar as PCs
1315 W <- t(eig$vectors)
1316 W[1,] <- W[1,]/sum(W[1,])
1317 W <- W
1318
1319 ### UCI / INF / CAM / DIV
1320 # MO
1321 cE <- 0 # Numero de fatores estrangeiros
1322 M.o <- as.matrix(cbind(ebr$UCI, ebr$INF, ebr$CAM, ebr$DIV))
1323 MOS1 <- JLS(Y, W, M.o, mats, cL, cE=3)
1324 # M1
1325 cE <- 0 # Numero de fatores estrangeiros
```

```
1326 M.o <- as.matrix(cbind(ebr$UCI, ebr$INF, ebr$IIE, ebr$CAM, ebr
      $DIV))
1327 M1S1 <- JLS(Y, W, M.o, mats, cL, cE=3)
1328 #M2
1329 cE <- 1 # Numero de fatores estrangeiros
1330 M.o <- as.matrix(cbind(ebr$UCI, ebr$INF, ebr$CAM, ebr$DIV, ebr
      $EPU))
1331 M2S1 <- JLS(Y, W, M.o, mats, cL, cE=3)
1332 #M3
1333 cE <- 1 # Numero de fatores estrangeiros
1334 M.o <- as.matrix(cbind(ebr$UCI, ebr$INF, ebr$CAM, ebr$DIV,
1335 ebr$IIE, ebr$EPU))
1336 M3S1 <- JLS(Y, W, M.o, mats, cL, cE=3)
1337 # LLKs
1338 cbind(MOS3$llk, M1S1$llk, M2S1$llk, M3S1$llk)
1339 #Teste LR
1340 #M1
1341 chisq_est <- 2*(M1S1$llk - MOS1$llk) #estatistica X2
1342 df <- (J - cL)
1343 qchisq(.05, df, lower.tail=F) # Valor critico
1344 pchisq(chisq_est, df, lower.tail=F) # p-valor
1345 #M2
1346 chisq_est <- 2*(M2S1$llk - MOS1$llk) #estatistica X2
1347 df <- (J - cL)
1348 qchisq(.05, df, lower.tail=F) # Valor critico
1349 pchisq(chisq_est, df, lower.tail=F) # p-valor
1350 #M3
1351 chisq_est <- 2*(M3S1$llk - MOS1$llk) #estatistica X2
1352 df <- 2*(J - cL)
1353 qchisq(.05, df, lower.tail=F) # Valor critico
1354 pchisq(chisq_est, df, lower.tail=F) # p-valor
1355
1356 ## L_EUA / S_EUA / C_EUA
1357 # M0
1358 cE <- 0 # Numero de fatores estrangeiros
1359 M.o <- as.matrix(cbind(PCaux3$L_EUA, PCaux3$S_EUA, PCaux3$C_
      EUA))
1360 MOS2 <- JLS(Y, W, M.o, mats, cL, cE=3)
1361 # M1
1362 cE <- 0 # Numero de fatores estrangeiros
1363 M.o <- as.matrix(cbind(PCaux3$L_EUA, PCaux3$S_EUA, PCaux3$C_
      EUA, ebr$IIE))
```

```
1364 M1S2 <- JLS(Y, W, M.o, mats, cL, cE=3)
1365 #M2
1366 cE <- 1 # Numero de fatores estrangeiros
1367 M.o <- as.matrix(cbind(PCaux3$L_EUA, PCaux3$S_EUA, PCaux3$C_
      EUA, ebr$EPU))
1368 M2S2 <- JLS(Y, W, M.o, mats, cL, cE=3)
1369 #M3
1370 cE <- 1 # Numero de fatores estrangeiros
1371 M.o <- as.matrix(cbind(PCaux3$L_EUA, PCaux3$S_EUA, PCaux3$C_
      EUA,
1372 ebr$IIE, ebr$EPU))
1373 M3S2 <- JLS(Y, W, M.o, mats, cL, cE=3)
1374 #Teste LR
1375 #M1
1376 chisq_est <- 2*(M1S2$llk - MOS2$llk) #estatistica X2
1377 df <- (J - cL)
1378 qchisq(.05, df, lower.tail=F) # Valor critico
1379 pchisq(chisq_est, df, lower.tail=F) # p-valor
1380 #M2
1381 chisq_est <- 2*(M2S2$llk - MOS2$llk) #estatistica X2
1382 df <- (J - cL)
1383 qchisq(.05, df, lower.tail=F) # Valor critico
1384 pchisq(chisq_est, df, lower.tail=F) # p-valor
1385 #M3
1386 chisq_est <- 2*(M3S2$llk - MOS2$llk) #estatistica X2
1387 df <- 2*(J - cL)
1388 qchisq(.05, df, lower.tail=F) # Valor critico
1389 pchisq(chisq_est, df, lower.tail=F) # p-valor
1390
1391
1392
1393 ### ETTJ
1394 #Preparacao dos dados
1395 dates <- as.numeric(format(ybr_ettjn$mes, "%Y%m%d"))
1396 n.per <- 12
1397 Y <- as.matrix(ybr_ettjn[, -1])
1398 mats <- c(1, 3, 6, 12, 18, 24, 30, 36, 42, 48, 54, 60, 72, 84,
      96) # Vertices
1399 J <- length(ybr_ettjn[, -1])
1400 cL <- 3 # Numero de PCs
1401 eig <- eigen(cov(Y)) # Para criar as PCs
1402 W <- t(eig$vectors)
```

```
1403 W[1,] <- W[1,]/sum(W[1,])
1404 W <- W
1405
1406 ## UCI / INF / CAM / DIV
1407 # M0
1408 cE <- 0 # Numero de fatores estrangeiros
1409 M.o <- as.matrix(cbind(ebr$UCI, ebr$INF, ebr$CAM, ebr$DIV))
1410 MOE1 <- JLS(Y, W, M.o, mats, cL, cE=3)
1411 # M1
1412 cE <- 0 # Numero de fatores estrangeiros
1413 M.o <- as.matrix(cbind(ebr$UCI, ebr$INF, ebr$IIE, ebr$CAM, ebr
    $DIV))
1414 M1E1 <- JLS(Y, W, M.o, mats, cL, cE=3)
1415 #M2
1416 cE <- 1 # Numero de fatores estrangeiros
1417 M.o <- as.matrix(cbind(ebr$UCI, ebr$INF, ebr$CAM, ebr$DIV, ebr
    $EPU))
1418 M2E1 <- JLS(Y, W, M.o, mats, cL, cE=3)
1419 #M3
1420 cE <- 1 # Numero de fatores estrangeiros
1421 M.o <- as.matrix(cbind(ebr$UCI, ebr$INF, ebr$CAM, ebr$DIV,
1422 ebr$IIE, ebr$EPU))
1423 M3E1 <- JLS(Y, W, M.o, mats, cL, cE=3)
1424 # LLKs
1425 cbind(MOE1$llk, M1E1$llk, M2E1$llk, M3E1$llk)
1426 #Teste LR
1427 #M1
1428 chisq_est <- 2*(M1E1$llk - MOE1$llk) #estatistica X2
1429 df <- (J - cL)
1430 qchisq(.05, df, lower.tail=F) # Valor critico
1431 pchisq(chisq_est, df, lower.tail=F) # p-valor
1432 #M2
1433 chisq_est <- 2*(M2E1$llk - MOE1$llk) #estatistica X2
1434 df <- (J - cL)
1435 qchisq(.05, df, lower.tail=F) # Valor critico
1436 pchisq(chisq_est, df, lower.tail=F) # p-valor
1437 #M3
1438 chisq_est <- 2*(M3E1$llk - MOE1$llk) #estatistica X2
1439 df <- 2*(J - cL)
1440 qchisq(.05, df, lower.tail=F) # Valor critico
1441 pchisq(chisq_est, df, lower.tail=F) # p-valor
1442
```

```
1443 ## L_EUA / S_EUA / C_EUA
1444 # M0
1445 cE <- 0 # Numero de fatores estrangeiros
1446 M.o <- as.matrix(cbind(PCaux3$L_EUA, PCaux3$S_EUA, PCaux3$C_
      EUA))
1447 MOE2 <- JLS(Y, W, M.o, mats, cL, cE=3)
1448 # M1
1449 cE <- 0 # Numero de fatores estrangeiros
1450 M.o <- as.matrix(cbind(PCaux3$L_EUA, PCaux3$S_EUA, PCaux3$C_
      EUA, ebr$IIE))
1451 M1E2 <- JLS(Y, W, M.o, mats, cL, cE=3)
1452 #M2
1453 cE <- 1 # Numero de fatores estrangeiros
1454 M.o <- as.matrix(cbind(PCaux3$L_EUA, PCaux3$S_EUA, PCaux3$C_
      EUA, ebr$EPU))
1455 M2E2 <- JLS(Y, W, M.o, mats, cL, cE=3)
1456 #M3
1457 cE <- 1 # Numero de fatores estrangeiros
1458 M.o <- as.matrix(cbind(PCaux3$L_EUA, PCaux3$S_EUA, PCaux3$C_
      EUA,
1459 ebr$IIE, ebr$EPU))
1460 M3E2 <- JLS(Y, W, M.o, mats, cL, cE=3)
1461 # LLKs
1462 cbind(MOS3$llk, M1S3$llk, M2S3$llk, M3S3$llk)
1463 #Teste LR
1464 #M1
1465 chisq_est <- 2*(M1E2$llk - MOE2$llk) #estatistica X2
1466 df <- (J - cL)
1467 qchisq(.05, df, lower.tail=F) # Valor critico
1468 pchisq(chisq_est, df, lower.tail=F) # p-valor
1469 #M2
1470 chisq_est <- 2*(M2E2$llk - MOE2$llk) #estatistica X2
1471 df <- (J - cL)
1472 qchisq(.05, df, lower.tail=F) # Valor critico
1473 pchisq(chisq_est, df, lower.tail=F) # p-valor
1474 #M3
1475 chisq_est <- 2*(M3E2$llk - MOE2$llk) #estatistica X2
1476 df <- 2*(J - cL)
1477 qchisq(.05, df, lower.tail=F) # Valor critico
1478 pchisq(chisq_est, df, lower.tail=F) # p-valor
```


Código B.2 – Código das funções auxiliares - DTSM

```
1
2 #Funcao para estimar os parametros do DTSM gaussiano, como em
3   JLS (2013)
4
5 JLS <- function(Y, W, M.o, mats, cL, pars.start, cE) {
6   getStartingValuesJLS <- function(Sigma) {
7
8     cM <- ncol(M.o)
9     cN <- ncol(Sigma)
10    J <- ncol(Y)
11    WN <- matrix(W[1:cN,], cN, J)
12
13    ## starting values for gam0 and gam1: regress macro on cN yield
14    factors
15    gam0 <- matrix(NA, cM, 1)
16    gam1 <- matrix(NA, cM, cN)
17    PN.o <- Y %*% t(WN)
18    xdat <- PN.o
19    for (i in 1:cM) {
20      ydat <- M.o[,i]
21      res <- lm(ydat ~ xdat)
22      gam0[i] <- res$coef[1]
23      gam1[i,] <- res$coef[2:(cN+1)]
24    }
25
26    ## random starting values for lamQ and kinfQ
27    n.seeds <- 500
28    best.llk <- Inf
29    pars <- list(gam0 = gam0, gam1 = gam1, Sigma = Sigma)
30    for (i in 1:n.seeds) {
31      pars$lamQ <- -sort(abs(.1*rnorm(cN)))
32      theta <- pars2theta.jls(pars)
33      llk <- obj.jls(theta)
34      if (llk < best.llk) {
35        cat("Improved seed llk to ", llk, "\n")
36        best.llk <- llk
37        best.pars <- pars
38      }
39    }
40    return(best.pars)
41  }
```

```

40  theta2pars.jls <- function(theta) {
41  cM <- ncol(M.o)
42  cN <- cM+cL
43  pars <- list(dlamQ = theta[1:cN])
44  pars$lamQ <- cumsum(pars$dlamQ)
45  pars$gam0 <- matrix(theta[(cN+1):(cN+cM)], cM, 1)
46  pars$gam1 <- matrix(theta[(cN+cM+1):(cN+cM+cM*cN)], cM, cN)
47  pars$Sigma <- matrix(0, cN, cN);
48  pars$Sigma[lower.tri(pars$Sigma,diag=TRUE)] <- tail(theta, cN*(
      cN+1)/2)
49  pars$Omega <- pars$Sigma %*% t(pars$Sigma)
50  return(pars)
51  }
52  pars2theta.jls <- function(pars) {
53  cM <- nrow(pars$gam0)
54  cN <- ncol(pars$gam1)
55  cL <- cN-cM
56  dlamQ <- c(pars$lamQ[1],diff(pars$lamQ))
57  if (length(pars$lamQ)!=cN) stop("lamQ has wrong length")
58  Sigma.vec <- pars$Sigma[lower.tri(pars$Sigma,diag=TRUE)]
59  theta <- c(dlamQ, pars$gam0, as.numeric(pars$gam1), Sigma.vec)
60  return(theta)
61  }
62  checkPars <- function(pars) {
63  valid <- TRUE
64  if (any(diag(pars$Sigma)<1e-7)) valid <- FALSE
65  if (any(diag(pars$Sigma)>1)) valid <- FALSE
66  if (any(pars$lamQ>0)) valid <- FALSE
67  if (any(pars$lamQ< -.4)) valid <- FALSE
68  if (any(pars$dlamQ>0)) valid <- FALSE
69  return(valid)
70  }
71  obj.jls <- function(theta) {
72  cN <- ncol(M.o) + cL
73  pars <- theta2pars.jls(theta)
74
75  valid <- checkPars(pars)
76  if (valid) {
77  res.llk <- jls.llk.kinfQ(Y, M.o, W, cL, lamQ=pars$lamQ, gam0=
      pars$gam0,
78  gam1=pars$gam1, Sigma=pars$Sigma, mats=mats, dt=1)
79  obj <- sum(res.llk$llk)

```

```
80 } else {
81   obj <- 1e6
82 }
83 }
84
85 cM <- ncol(M.o)
86 cN <- cM + cL
87 J <- ncol(Y)
88 WL <- matrix(W[1:cL,], cL, J)
89 PL.o <- Y %*% t(WL)
90 Z <- cbind(M.o, PL.o)
91
92 ## starting values
93 if (missing(pars.start)) {
94   require(vars)
95   Zts <- ts(data.frame(Z))
96   modelo_var <- VAR(Zts, p = 1, type = "const")
97   if(cE > 0){
98     restriction <- matrix(1, nrow = cN, ncol = cN+1)
99     restriction[(cN-cE+1):cN, 1:(cN-cE)] <- 0
100    m_var <- restrict(modelo_var, method = "man", resmat =
      restriction)
101  } else if(cE == 0){
102    m_var <- modelo_var
103  } else stop(cat("cE cant be negative"))
104  coefs_var <- Bcoef(m_var)
105  K1P <- coefs_var[,1:(ncol(coefs_var)-1)] - diag(cN)
106  K0P <- coefs_var[,ncol(coefs_var)]
107  Omega <- summary(m_var)[[3]]
108  Sigma <- t(chol(Omega))
109  Sigma.ols <- Sigma
110  pars.start <- getStartingValuesJLS(Sigma)
111  }
112
113  theta.start <- pars2theta.jls(pars.start)
114  stopifnot(isTRUE(all.equal(theta.start, pars2theta.jls(
    theta2pars.jls(theta.start)),
115    check.attributes=FALSE)))
116
117  ## optimization over (lamQ, gam0, gam1, Sigma)
118  theta <- getOptim(theta.start, obj.jls)
119  pars <- theta2pars.jls(theta)
```

```

120
121 pars$KOP <- KOP
122 pars$K1P <- K1P
123 pars$Omega <- pars$Sigma %*% t(pars$Sigma)
124
125 ## value of likelihood
126 res.llk <- jls.llk.kinfQ(Y, M.o, W, cL, lamQ=pars$lamQ, gam0=
    pars$gam0,
127 gam1=pars$gam1, Sigma=pars$Sigma, mats=mats, dt=1)
128 pars$sigma.e <- res.llk$sigma.e
129 pars$kinfQ <- res.llk$kinfQ
130 pars$llkP <- -sum(res.llk$llkP)
131 pars$llkQ <- -sum(res.llk$llkQ)
132 pars$llk <- pars$llkP + pars$llkQ
133 pars$mu <- pars$KOP
134 pars$Phi <- pars$K1P + diag(cN)
135 pars$rho0 <- as.numeric(res.llk$rho0)
136 pars$rho1 <- as.numeric(res.llk$rho1)
137 pars$muQ <- as.numeric(res.llk$KOQ)
138 pars$PhiQ <- res.llk$K1Q + diag(cN)
139 pars$cL <- cL
140 pars$A <- res.llk$A
141 pars$B <- res.llk$B
142 pars$Gam1 <- rbind(pars$gam1, cbind(diag(cL), matrix(0, cL, cM)
    ))
143 pars$Gam0 <- rbind(pars$gam0, matrix(0, cL,1))
144 pars$Z <- Z
145 cat("LLK          =", -sum(res.llk$llk), " \n")
146 cat("check        =", -obj.jls(theta), "\n")
147
148 pars2 <- pars
149 pars2$Sigma <- Sigma.ols
150 theta2 <- pars2theta.jls(pars2)
151 cat("w/ Sigma.ols =", -obj.jls(theta2), "\n")
152
153 pars$VAR <- m_var
154
155 return(pars)
156 }
157
158
159

```

```

160  ##### Funcoes internas do DTSM
161      #####
162  jls.llk.kinfQ <- function (yields.o, M.o, W, cL, kinfQ=NA, lamQ
163      , gam0, gam1, KOP=NA, K1P=NA, Sigma, mats, dt, sigma.e=NA) {
164  T <- nrow(yields.o)-1
165  J <- ncol(yields.o)
166  cM <- ncol(M.o)
167  cN <- cL + cM
168  WN <- matrix(W[1:cN,], cN, J)
169  WL <- matrix(W[1:cL,], cL, J)
170  PL.o <- ts( yields.o %*% t(WL))
171  Z <- cbind(M.o, PL.o)
172  Omega <- Sigma %*% t(Sigma)
173
174  if (is.na(kinfQ)) {
175  rho0 <- 0
176  loads <- jls.loadings.rho0(W, rho0, lamQ, gam0, gam1, Omega,
177      mats, dt)
178  B <- loads$B
179  alpha0.Z <- loads$alpha0.Z
180  alpha1.Z <- loads$alpha1.Z
181
182  require(MASS)
183  V <- t(Null(t(WL)))
184  kinfQ <- as.numeric(t(colMeans(yields.o[2:(T+1),]) - t(alpha1.Z
185      ) - t(B)%*%colMeans(Z[2:(T+1),]))%*%(t(V)%*%V)%*%t(alpha0.Z))
186      / (alpha0.Z)%*%t(V)%*%V)%*%t(alpha0.Z))
187
188  A <- alpha0.Z*kinfQ + alpha1.Z;
189
190  AX <- loads$alpha0.X*kinfQ + loads$alpha1.X;
191  BX <- loads$BX
192  rho1 <- loads$rho1
193  K1Q <- loads$K1Q
194  U0 <- loads$Gam0 + loads$Gam1 %*% WN %*% t(AX)
195  rho0 <- -crossprod(rho1, U0)
196  KOQ.X <- matrix(0, cN, 1)
197  KOQ.X[loads$m1] <- kinfQ
198  KOQ <- loads$U1inv %*% KOQ.X - K1Q %*% U0
199  } else {
200  loads <- jls.loadings.kinfQ(W, kinfQ, lamQ, gam0, gam1, Omega,

```

```

      mats, dt)
197 B <- loads$B; A <- loads$A
198 AX <- loads$AX; BX <- loads$BX
199 KOQ <- loads$KOQ; K1Q <- loads$K1Q
200 rho0 <- loads$rho0; rho1 <- loads$rho1
201 }
202
203 yields.m <- rep(1,T+1)%*%A + Z %*% B
204 yield.errors <- yields.o[2:(T+1),] - yields.m[2:(T+1),]; # T*J
205 squared.errors <- yield.errors^2;
206
207 if (is.na(sigma.e))
208 sigma.e <- sqrt( sum(squared.errors)/(T*(J-cL)) )
209
210 llkQ <- .5*rowSums(squared.errors)/sigma.e^2 + (J-cL)*.5*log(2*
      pi) + .5*(J-cL)*log(sigma.e^2) # 1*T
211
212 if (missing(KOP)|missing(K1P)) {
213 Zts <- ts(data.frame(Z))
214 modelo_var <- VAR(Zts, p = 1, type = "const")
215 if(cE > 0){
216 restriction <- matrix(1, nrow = cN, ncol = cN+1)
217 restriction[(cN-cE+1):cN, 1:(cN-cE)] <- 0
218 m_var <- restrict(modelo_var, method = "man", resmat =
      restriction)
219 } else if(cE == 0){
220 m_var <- modelo_var
221 } else stop(cat("cE cant be negative"))
222 coefs_var <- Bcoef(m_var)
223 K1P <- coefs_var[,1:(ncol(coefs_var)-1)] - diag(cN)
224 KOP <- coefs_var[,ncol(coefs_var)]
225 Omega <- summary(m_var)[[3]]
226 }
227
228 innovations = t(Z[2:(T+1),]) - (KOP%*%matrix(1,1,T) + (K1P+diag
      (cN))%*%t(Z[1:T,])) # N*T
229
230 llkP = .5*cN*log(2*pi) + .5*log(det(Omega)) + .5*colSums(
      innovations*solve(Omega, innovations)) # 1*T
231
232 #####
233 jsz.llk <- list(llk=t(llkQ + llkP), A=A, B=B, AX=AX, BX=BX, KOP

```

```

    =KOP, K1P=K1P, sigma.e=sigma.e, llkQ=llkQ, llkP=llkP, kinfQ =
      kinfQ, KOQ=KOQ, K1Q=K1Q, rho0=rho0, rho1=rho1)
234 }
235
236 jls.loadings.kinfQ <- function(W, kinfQ, lamQ, gam0, gam1,
      Omega, mats, dt) {
237   J <- length(mats)
238   cN <- length(lamQ)
239   cM <- ncol(M.o) ## default
240   cL <- cN - cM
241   WN <- matrix(W[1:cN,], cN, J)
242   mats.periods <- round(mats/dt)
243   M <- max(mats.periods)
244   rho0.X <- 0;   rho1.X <- rep(1, cN)
245
246   ## 1. based on primitive parameters, find (rho0, rho1, KOQ, K1Q
      )
247   Gam1 <- rbind(gam1, cbind(diag(cL), matrix(0, cL, cM)))
248   Gam0 <- rbind(gam0, matrix(0, cL, 1))
249
250   ## 1.1. find loadings of yields on Xt (Jordan-normalized
      factors)
251   K1Q.X <- diag(lamQ)
252   m1 <- 1
253   KOQ.X <- matrix(0, cN, 1);
254   KOQ.X[m1] <- kinfQ
255
256   ## 1.1.1. first compute the loadings ignoring convexity term
257   loads.X.prelim <- gaussian.loadings(mats.periods, KOQ.X, K1Q.X,
      matrix(0, cN, cN), rho0.X*dt, rho1.X*dt, dt)
258   BX <- loads.X.prelim$B ## cN * J
259   U1inv <- Gam1 %*% WN %*% t(BX)
260   U1 <- solve(U1inv)
261   ## 1.1.2. calc. Omega.X and calculate correct loadings
262   Omega.X <- U1 %*% Omega %*% t(U1)
263   loads.X <- gaussian.loadings(mats.periods, KOQ.X, K1Q.X, Omega.
      X, rho0.X*dt, rho1.X*dt, dt)
264   AX <- loads.X$A ## 1 * J
265
266   ## 1.2. calculate remaining parameters
267   U0 <- Gam0 + Gam1 %*% WN %*% t(AX)
268   rho1 <- t(U1) %*% rep(1, cN)

```

```

269 rho0 <- - crossprod(rho1, U0)
270 K1Q <- U1inv %*% K1Q.X %*% U1
271 KOQ <- U1inv %*% KOQ.X - K1Q %*% U0
272
273 ## 2. compute affine loadings for Z
274 loads.Z <- gaussian.loadings(mats.periods, KOQ, K1Q, Omega,
    rho0*dt, rho1*dt, dt)
275
276 #####
277 jls.loadings <- list(A=loads.Z$A, B=loads.Z$B, AX=AX, BX=BX,
    KOQ=KOQ, K1Q=K1Q, rho0=rho0, rho1=rho1, U0=U0, U1=U1, Gam0=
    Gam0, Gam1=Gam1, AX=AX, BX=BX)
278 }
279
280 jls.loadings.rho0 <- function(W, rho0, lamQ, gam0, gam1, Omega,
    mats, dt) {
281 J <- length(mats)
282 cN <- length(lamQ)
283 cM <- ncol(M.o)
284 WN <- matrix(W[1:cN,], cN, J)
285 mats.periods <- round(mats/dt)
286 M <- max(mats.periods)
287 rho0.X <- 0; rho1.X <- rep(1, cN)
288
289 ## 1. based on primitive parameters, find (rho0, rho1, KOQ, K1Q
    )
290 Gam1 <- rbind(gam1, cbind(diag(cL), matrix(0, cL, cM)))
291 Gam0 <- rbind(gam0, matrix(0, cL, 1))
292
293 ## 1.1. find loadings of yields on Xt (Jordan-normalized
    factors)
294 K1Q.X <- diag(lamQ)
295 m1 <- 1
296 KOQ.X <- matrix(0, cN, 1);
297 KOQ.X[m1] <- 1 ## changed -- 1 instead of kinfQ
298
299 ## 1.1.1. first compute the loadings ignoring convexity term
300 loads.X.prelim <- gaussian.loadings(mats.periods, KOQ.X, K1Q.X,
    matrix(0, cN, cN), rho0.X*dt, rho1.X*dt, dt)
301 BX <- loads.X.prelim$B ## cN * J
302 alpha0.X <- loads.X.prelim$A ### added
303 U1inv <- Gam1 %*% WN %*% t(BX)

```



```

304 U1 <- solve(U1inv)
305 ## 1.1.2. calc. Omega.X and calculate correct loadings
306 Omega.X <- U1 %*% Omega %*% t(U1)
307 loads.X <- gaussian.loadings(mats.periods, KOQ.X, K1Q.X, Omega.
      X, rho0.X*dt, rho1.X*dt, dt)
308 AX1 <- loads.X$A ## 1 * J
309 alpha1.X <- AX1 - alpha0.X
310
311 a0 <- -matrix(1,1,cN) %*% U1 %*% Gam1 %*% WN %*% t(alpha0.X)
312 a1 <- -matrix(1,1,cN) %*% U1 %*% (Gam0 + Gam1 %*% WN %*% t(
      alpha1.X))
313 kinfQ <- as.numeric((rho0 - a1)/a0); ## a0*kinfQ + a1 = rho0
314 KOQ.X[m1] <- kinfQ;
315 AX <- alpha0.X*kinfQ + alpha1.X
316 C <- diag(J) - t(BX) %*% U1 %*% Gam1 %*% WN
317 alpha0.Z <- t(C %*% t(alpha0.X))
318 alpha1.Z <- t(C %*% t(alpha1.X) - t(BX) %*% U1 %*% Gam0)
319
320 ## 1.2. calculate remaining parameters
321 U0 <- Gam0 + Gam1 %*% WN %*% t(AX)
322 rho1 <- t(U1) %*% rep(1, cN)
323 K1Q <- U1inv %*% K1Q.X %*% U1
324 KOQ <- U1inv %*% KOQ.X - K1Q %*% U0
325
326 ## 2. compute affine loadings for Z
327 loads.Z <- gaussian.loadings(mats.periods, KOQ, K1Q, Omega,
      rho0*dt, rho1*dt, dt)
328
329 #####
330 jls.loadings <- list(A=loads.Z$A, B=loads.Z$B, AX=AX, BX=BX,
      KOQ=KOQ, K1Q=K1Q, rho0=rho0, rho1=rho1, U0=U0, U1=U1, U1inv=
      U1inv, Gam0=Gam0, Gam1=Gam1, AX=AX, BX=BX, alpha0.X=alpha0.X
      , alpha1.X=alpha1.X, alpha0.Z=alpha0.Z, alpha1.Z=alpha1.Z, m1
      =m1)
331 }
332
333 gaussian.loadings <- function(maturities, K0d, K1d, H0d, rho0d,
      rhod, timestep=1) {
334 M = length(maturities)
335 N = length(K0d)
336 Atemp = 0
337 Btemp = matrix(0,N,1)

```

```
338 Ay = matrix(NA,1,M)
339 By = matrix(NA,N,M)
340
341 curr_mat = 1
342 K0dp <- t(K0d)
343 K1dp <- t(K1d)
344 for (i in 1:maturities[M]) {
345 Atemp <- Atemp + K0dp**Btemp +.5**t(Btemp)**H0d**Btemp -
      rho0d
346 Btemp <- Btemp + K1dp**Btemp - rho1d
347 if (i==maturities[curr_mat]) {
348 Ay[1,curr_mat] <- -Atemp/maturities[curr_mat]
349 By[,curr_mat] <- -Btemp/maturities[curr_mat]
350 curr_mat <- curr_mat + 1
351 }
352 }
353 gaussian.loadings <- list(A = Ay/timestep, B = By/timestep)
354 }
355
356
357
358 ### Funccao de otimizacao
359 getOptim <- function(theta, obj, ..., trace=0) {
360 obj <- match.fun(obj)
361 if (trace>0) {
362 cat("Starting optimization...\n")
363 cat("Function value at starting point = ",
364 sprintf("%10.4f", obj(theta, ...)), "\n")
365 }
366 i <- 1; improvement <- Inf; prev.llk <- 0
367 myparscale <- 10^round(log10(abs(theta)))
368 while (improvement>.1) {
369 res <- optim(theta, obj, gr=NULL, ..., control=list(trace=trace
      , parscale=myparscale) )
370 improvement <- abs(res$value-prev.llk)
371 prev.llk <- res$value
372 theta <- res$par
373 if (trace > 0)
374 cat("iteration ", i,", likelihood = ", sprintf("%10.4f", res$
      value),"\n")
375 i <- i + 1
376 }
```

```
377   if (trace > 0)
378   cat("improvement = ", improvement, " -- proceed to final step\n
      ")
379   res <- optim(theta, obj, gr=NULL, ..., control=list(trace=trace
      , maxit=50000, parscale=myscale) )
380   if (trace > 0) {
381   cat("final Nelder-Mead step, likelihood = ",
382   sprintf("%10.4f", res$value),"\n")
383   cat("Convergence:", res$convergence, "\n")
384   print(res$message)
385   }
386   return(res$par)
387   }
388
389   ##### Analises auxiliares #####
390
391   # Definicao da funcao para a analise de regressoes
392   regressoes <- function(vd, f_vis, Dados){
393   modelos <- lapply(vd, function(j) {
394   lm(as.formula(paste(j,"~", f_vis)), data= Dados)
395   })
396   NW <- lapply(modelos, function(j) coeftest(j, vcov=NeweyWest(j,
      lag=18)))
397   BPs <- lapply(modelos, function(j) bptest(j)$statistic)
398   BPp <- lapply(modelos, function(j) bptest(j)$p.value)
399   BP <- t(cbind(BPs, BPp))
400   colnames(BP) <- vd
401   BGs <- lapply(modelos, function(j) bgtest(j)$statistic)
402   BGp <- lapply(modelos, function(j) bgtest(j)$p.value)
403   BG <- t(cbind(BGs, BGp))
404   colnames(BG) <- vd
405   BPBG <- rbind(BP, BG)
406   rownames(BPBG) <- c("BP", "BP p-valor", "BG", "BG p-valor")
407   MX <- list(modelos, NW, BPBG)
408   names(MX) <- c("modelos", "NW", "BPBG")
409   return(MX)
410   }
411
412   vselection <- function(X, Y, type){
413   library(glmnet)
414   set.seed(616)
415   if(type == "LASSO"){a1=1}
```

```
416   if(type == "ELASTIC NET"){al=0.5}
417   #treino <- sample(1:nrow(X), nrow(X)*(0.7))
418   #teste <- -treino
419   lambda_seq <- 10^seq(10, -100, by = -.01)
420   cv_resultado <- cv.glmnet(X, Y, alpha = al, lambda = lambda_seq
421     )
422   best_lambda <- cv_resultado$lambda.1se
423   best_modelo <- glmnet(X, Y, alpha = al, lambda = best_lambda)
424   COEF <- coef(best_modelo)
425   Yhat <- predict(best_modelo, s = best_lambda, newx= X)
426   sst <- sum((Y-mean(Y))^2)
427   ssr <- sum((Yhat-Y)^2)
428   R2 <- 1 - ssr/sst
429   R2a <- 1-((length(Y)-1)/(length(Y)-ncol(X)-1))*(1-R2)
430   resultado <- list(COEF, R2, R2a, best_lambda)
431   names(resultado) <- c("coeficientes", "R2", "R2 ajustado", "
432     lambda")
433   return(resultado)
434 }
```