

INFORMANDO PRIORS PARA MODELOS DSGE: UMA ANÁLISE EMPÍRICA DA DINÂMICA DO PRÊMIO DE RISCO-PAÍS DO BRASILPedro H. D. A. Vitor¹ (IC), Edson O. Pamplona (PQ)¹¹Universidade Federal de Itajubá.**Palavras-chave:** Aprendizado de Máquina. Estimação Bayesiana. Mercados Emergentes. Previsão de Séries Temporais. Volatilidade Estocástica.**Introdução**

O prêmio de risco-país constitui um determinante crítico dos resultados macroeconômicos em economias abertas emergentes. Suas flutuações exercem influência substancial sobre taxas de câmbio, fluxos de capital e as condições financeiras domésticas, representando um desafio significativo para a condução da política monetária e fiscal. Para a análise deste cenário complexo, formuladores de políticas recorrem a modelos de Equilíbrio Geral Dinâmico Estocástico (DSGE), dentre os quais o modelo Stochastic Analytical Model with a Bayesian Approach (SAMBA) do Banco Central do Brasil (BCB) se destaca como uma ferramenta proeminente para previsão e análise de políticas.

A estimação de tais modelos é tipicamente conduzida via métodos Bayesianos, que sintetizam a estrutura teórica do modelo com a evidência empírica contida nos dados. Este processo é condicionado a um conjunto de distribuições de probabilidade a priori, os priors, que formalizam as crenças iniciais sobre os parâmetros do modelo. A especificação desses priors é uma etapa crucial, porém frequentemente subestimada. Para muitos parâmetros-chave, particularmente a variância dos choques exógenos, os priors são definidos por convenção ou com escassa fundamentação empírica. A hipótese de homocedasticidade — ou seja, de variância constante — para o choque do prêmio de risco-país é um caso notável, contrastando fortemente com o robusto fato estilizado de agrupamento de volatilidade (volatility clustering), universalmente observado em dados financeiros de alta frequência. Esta desconexão representa uma vulnerabilidade potencial na capacidade do modelo de capturar adequadamente o impacto de crises financeiras.

O presente trabalho confronta diretamente essa questão. Realiza-se uma análise sistemática e orientada por dados

da dinâmica da volatilidade do prêmio de risco-país do Brasil, com o objetivo explícito de informar a especificação do modelo SAMBA. Para tal, implementa-se uma análise comparativa entre a abordagem econométrica canônica, o modelo GARCH(1,1), e uma alternativa moderna de aprendizado de máquina, uma rede neural recorrente do tipo Long Short-Term Memory (LSTM). A hipótese subjacente é a de que a flexibilidade do modelo de aprendizado de máquina pode capturar dinâmicas não-lineares presentes nos dados que são omitidas pelo modelo econométrico tradicional. A principal contribuição da pesquisa é, portanto, traduzir os achados empíricos em uma proposta metodológica concreta, demonstrando como os priors para um processo de volatilidade estocástica podem ser disciplinados pelos resultados desta análise, forjando assim uma ligação robusta entre dados de alta frequência e a estimação de modelos macroeconômicos estruturais.

Metodologia

A metodologia desta pesquisa articula-se em três etapas sequenciais: análise e tratamento dos dados, modelagem econométrica comparativa e derivação de distribuições a priori.

Dados e Fatos Estilizados: A proxy para o prêmio de risco-país utilizada foi a série diária do índice EMBI+ para o Brasil, obtida junto ao IpeaData. A série em nível (P_t) foi submetida a uma transformação logarítmica de primeira diferença para a obtenção dos retornos ($r_t = \ln(P_t) - \ln(P_{t-1})$), que representam os choques diários incidentes sobre o prêmio de risco. A volatilidade diária, nossa variável de interesse, foi aproximada pelos quadrados dos retornos (r_t^2). A análise descritiva da série de retornos confirmou a presença de fatos estilizados canônicos em dados financeiros,

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

notavelmente a leptocurtose (curtose excessiva de 15.5) e, de forma mais crucial, o agrupamento de volatilidade.

A evidência estatística formal para o agrupamento de volatilidade é apresentada na Figura 1, que exibe as funções de autocorrelação (ACF). O ACF dos retornos não demonstra correlação serial significativa, o que é consistente com a hipótese de mercado eficiente. Em marcante contraste, o ACF dos quadrados dos retornos exibe correlações estatisticamente significativas e de lento decaimento, constituindo a assinatura estatística de que o processo de volatilidade possui memória e é não-constante ao longo do tempo.

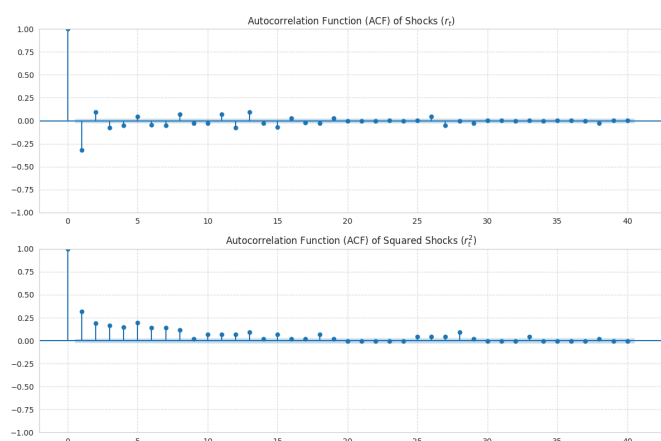


Figura 1 – Funções de Autocorrelação (ACF)¹
Fonte: Elaboração própria.

Modelagem Comparativa: Para capturar a dinâmica de volatilidade, implementamos uma análise competitiva entre duas classes de modelos:

1. GARCH(1,1): O modelo de referência econométrico, que modela a variância condicional (σ_t^2) como uma função linear do intercepto de longo prazo (ω), do quadrado do choque defasado (termo ARCH, αr_{t-1}^2) e da variância condicional defasada (termo GARCH, $\beta \sigma_{t-1}^2$).
2. Rede LSTM: Uma rede neural recorrente que

representa a abordagem de aprendizado de máquina. Diferentemente do GARCH, o LSTM não impõe uma estrutura funcional a priori, mas aprende mapeamentos complexos e não-lineares a partir de seqüências de dados passados.

A performance dos modelos foi avaliada tanto em sua capacidade de ajuste dentro da amostra (in-sample) quanto em sua acurácia de previsão fora da amostra (out-of-sample) para o período a partir de 2019, utilizando o Erro Quadrático Médio (RMSE) como métrica de validação.

Resultados e discussão

A análise empírica forneceu resultados claros e robustos. A estimação do modelo GARCH(1,1) revelou um parâmetro de persistência da volatilidade ($\alpha+\beta$) de 0.992, um valor extremamente elevado que indica que os choques na volatilidade do risco-país brasileiro são fundamentalmente persistentes, dissipando-se muito lentamente ao longo do tempo.

Na análise comparativa de performance, o modelo LSTM demonstrou superioridade em todas as métricas. A Figura 2 ilustra o comparativo do ajuste *in-sample*, onde a previsão do LSTM (linha azul) adere à volatilidade realizada (linha cinza) com uma precisão notavelmente maior do que a previsão parcimoniosa do GARCH (linha vermelha), capturando com maior acurácia a magnitude dos picos de crise.

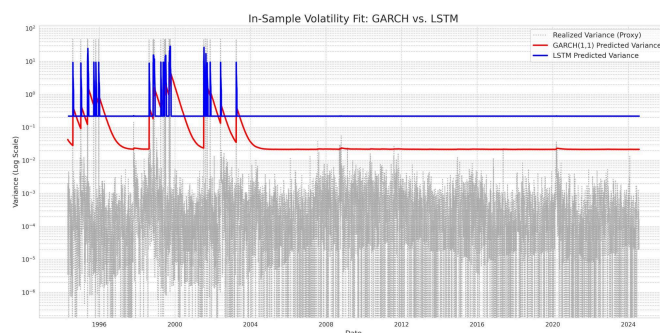


Figura 1 – Comparativo do Ajuste de Volatilidade In-Sample: GARCH vs. LSTM
Fonte: Elaboração própria.

¹ O painel superior mostra o ACF dos retornos diários (rt). O painel inferior mostra o ACF dos retornos ao quadrado (rt²), que exibe correlação serial significativa e persistente, confirmando o agrupamento de volatilidade.

Esta superioridade visual foi confirmada quantitativamente no exercício de previsão out-of-sample, cujos resultados são apresentados na

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

Tabela 1. O modelo LSTM alcançou um RMSE de 0.0001557, que é aproximadamente 51% do erro obtido pelo GARCH (0.0003028), indicando uma capacidade preditiva significativamente maior.

Modelo	Erro Quadrático Médio (RMSE)
GARCH(1,1)	0.0003028
LSTM Network	0.0001557

Tabela 1 – Performance de Previsão Fora da Amostra
Fonte: Elaboração própria.

A principal contribuição metodológica do trabalho é a aplicação prática destes resultados. Propõe-se um método para traduzir a superioridade preditiva do LSTM em uma ferramenta para a estimação Bayesiana do SAMBA. Utilizando a série completa de previsões de volatilidade do LSTM, ajusta-se uma distribuição Gama Inversa por Máxima Verossimilhança, como ilustrado na Figura 3. O resultado é um prior para a variância do choque de risco-país, $IG(1.4552, 0.0001)$, que é inteiramente derivado dos dados. Adicionalmente, o parâmetro de persistência estimado pelo GARCH (0.992) serve como um prior robusto para o correspondente parâmetro no processo de volatilidade estocástica.

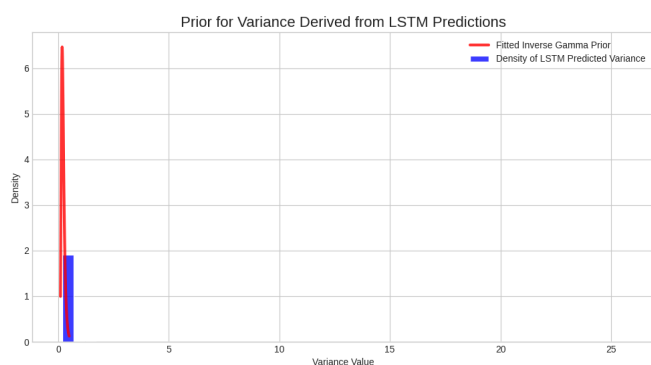


Figura 3 – Derivação do Prior a Partir das Previsões do LSTM²

Fonte: Elaboração própria.

² O histograma mostra a distribuição das previsões de volatilidade do LSTM. A linha vermelha representa a densidade da distribuição Gama Inversa ajustada a esses dados.

Conclusões

Este trabalho desafiou a hipótese de homocedasticidade dos choques do risco-país, uma premissa padrão em modelos DSGE. Por meio de uma análise comparativa rigorosa entre um modelo GARCH(1,1) e uma rede neural LSTM, demonstrou-se que o modelo de aprendizado de máquina é superior na captura da dinâmica complexa e não-linear da volatilidade do índice EMBI+ do Brasil, tanto em termos de ajuste in-sample quanto em capacidade de previsão out-of-sample. Este resultado transcende a mera superioridade estatística, sugerindo como descoberta econômica que a volatilidade do risco-país é um fenômeno estruturalmente mais complexo do que os modelos econométricos canônicos geralmente postulam. A principal contribuição da pesquisa é, portanto, a proposição de uma metodologia clara e data-driven para aprimorar a fundamentação empírica do modelo SAMBA, substituindo a hipótese de variância constante por um processo de volatilidade estocástica, cujos priors para a persistência e para o nível incondicional de volatilidade são disciplinados pelos métodos aqui demonstrados. Este trabalho constrói uma ponte entre a econometria financeira de alta frequência e a teoria macroeconômica estrutural, contribuindo para o desenvolvimento de ferramentas mais robustas para a análise de política econômica.

Enquanto este artigo oferece uma robusta ponte metodológica, diversas avenidas promissoras para pesquisa futura emergem de nossos achados. Primeiro, uma extensão natural seria a incorporação de fundamentos macroeconômicos nos modelos de previsão, expandindo o framework univariado para um modelo multivariado (GARCH-X ou LSTM com múltiplos regressores) que inclua variáveis como os termos de troca, o balanço fiscal ou proxies de aversão ao risco global como o VIX. Segundo, o passo mais crucial é a implementação formal desta proposta no framework do SAMBA, re-estimando o modelo completo para analisar quantitativamente como as funções de impulso-resposta e os mecanismos de propagação de choques se alteram ao incorporar uma volatilidade mais realista. Finalmente, a fronteira do Machine Learning avança rapidamente, e trabalhos futuros poderiam explorar arquiteturas mais sofisticadas, como redes baseadas em atenção ou Transformers, ou investigar modelos híbridos que combinam a estrutura paramétrica do GARCH com a flexibilidade não-linear

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

do LSTM, em busca de previsões ainda mais acuradas.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro ao desenvolvimento desse trabalho e pelo incentivo contínuo à pesquisa, bem como à Universidade Federal de Itajubá (UNIFEI), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG).

Referências

BLOOM, Nicholas. The Impact of Uncertainty Shocks. *Econometrica*, v. 77, n. 3, p. 623–685, 2009.

BOLLERSLEV, Tim. Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, v. 31, n. 3, p. 307–327, 1986.

BORN, Benjamin; PFEIFER, Johannes. Policy risk and the business cycle. *Journal of Monetary Economics*, v. 68, p. 68–85, 2014.

FASOLO, Angelo Marsiglia et al. Brazilian Macroeconomic Dynamics Redux: Shocks, Frictions, and Unemployment in SAMBA Model. Brasília: Banco Central do Brasil, 2023. (Working Paper Series, n. 578).

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long Short-Term Memory. *Neural Computation*, v. 9, n. 8, p. 1735–1780, 1997.

JUSTINIANO, Alejandro; PRIMICERI, Giorgio E. The Time-Varying Volatility of Macroeconomic Fluctuations. *American Economic Review*, v. 98, n. 3, p. 604–641, 2008.