

**Deep VAR : Impacto de modelos de risco baseados em
Machine Learning no Mercado Brasileiro**

Víctor de Souza Faria

Trabalho de Conclusão de Curso
MBA em Inteligência Artificial e Big Data

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

DeepVaR: Impacto de modelos de
risco baseados em Machine Learning
no Mercado Brasileiro

Víctor de Souza Faria

Víctor de Souza Faria

DeepVaR: Impacto de modelos de risco baseados em Machine Learning no Mercado Brasileiro

Trabalho de conclusão de curso apresentado ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientadora: Prof. Dr. Odemir M. Bruno

USP - São Carlos

2023

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

F224d Faria, Víctor de Souza
DeepVaR: Impacto de modelos de risco baseados em
Machine Learning no Mercado Brasileiro / Víctor de
Souza Faria; orientador Odemir Martinez Bruno. --
São Carlos, 2023.
33 p.

Trabalho de conclusão de curso (MBA em
Inteligência Artificial e Big Data) -- Instituto de
Ciências Matemáticas e de Computação, Universidade
de São Paulo, 2023.

1. INTELIGÊNCIA ARTIFICIAL. 2. RISCO DE MERCADO.
3. PREVISÃO (ANÁLISE DE SÉRIES TEMPORAIS). I. Bruno,
Odemir Martinez, orient. II. Título.

DEDICATÓRIA

*A minha esposa Michele que me
inspirou e motivou a me aperfeiçoar
a cada dia.*

*Aos meus filhos Guilherme e
Letícia, por me propiciarem as
alegrias necessárias para realizar
novas conquistas.*

RESUMO

FARIA, V. S. **DeepVaR**: Impacto de modelos de risco baseados em Machine Learning no Mercado Brasileiro. 2023. 33 f. Trabalho de conclusão de curso (MBA em Inteligência Artificial e Big Data) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2023.

O gerenciamento do risco de mercado é crucial para as instituições financeiras e para os investidores pois permite reduzir as incertezas e garantir a segurança dos investimentos. Uma das principais ferramentas para o gerenciamento do risco de mercado é o *Value-at-Risk* (VaR), sendo composto por um conjunto de modelos financeiros que buscam estimar a maior perda possível de uma carteira de ativos dado um intervalo de confiança e um horizonte de tempo. Recentemente o uso das tecnologias de aprendizado de máquina tem sido proposto para melhorar a eficiência destas análises, principalmente em momentos de crises. Neste contexto o DeepVaR surgiu como uma nova metodologia que utiliza os avanços das redes neurais recorrentes na previsão de séries de dados temporais para obter melhores estimativas da variação dos ativos. O objetivo do presente estudo consiste em avaliar a eficácia do modelo DeepVar no mercado mobiliário brasileiro, comparando-o com os modelos Paramétrico e Histórico em termos de precisão e confiabilidade.

Palavras-chave: redes neurais recorrentes; séries temporais; VaR; IBRX50.

ABSTRACT

FARIA, V. S. **DeepVaR:** Impact of risk models based on Machine Learning in the Brazilian Market. 2023. 52 f. Final Project (MBA in Artificial Intelligence and Big Data) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2023.

Market risk management is crucial for financial institutions and investors as it allows for the reduction of uncertainties and ensures the security of investments. One of the main tools for market risk management is Value-at-Risk (VaR), which consists of a set of financial models aiming to estimate the maximum potential loss of an asset portfolio given a confidence interval and a time horizon. Recently, machine learning technologies have been proposed to enhance the efficiency of these analyses, especially during times of crises. In this context, DeepVaR emerged as a new methodology leveraging the advancements of recurrent neural networks in forecasting time series data to obtain better estimates of asset fluctuations. The aim of the present study is to evaluate the efficacy of the DeepVar model in the Brazilian securities market, comparing it with Parametric and Historical models in terms of accuracy and reliability.

Keywords: recurrent neural networks; time series; VaR; IBRX50.

SUMÁRIO

1 Introdução	13
2. Fundamentação Teórica.....	14
2.1 Value-at-Risk (VaR)	14
2.2 DeepAR.....	15
3. DeepVAR: Modelando a Distribuição de Probabilidade.....	17
3.1 Estimativa da Distribuição de Probabilidade	17
3.2 Utilização da Distribuição Inferida para Estimativa do Risco.....	17
3.3 Comparação com o Modelo Paramétrico	18
4 Metodologia.....	18
4.1 Dados analisados.....	18
4.2 Modelo DeepVaR.....	24
4.3 Comparação com modelos histórico e paramétrico de VaR.....	25
4.4 Avaliação dos modelos	25
5. Resultados	27
5.1 Resultados sintéticos.....	27
5.2 Pior Caso	29
6. Conclusão	31
7. Referências Bibliográficas	33

Índice de tabelas

Tabela 1 - Composição da carteira teórica IBRX50.....	19
Tabela 2 - Teste de Shapiro-Wilk.....	23
Tabela 3 - Resultados das métricas	27
Tabela 4 - Distribuição do rv	28
Tabela 5 - Distribuição da Perda Quadrática.....	29
Tabela 6 - Correlação Modelos Pior Cenário	30
Tabela 7 - Resultados das métricas do pior cenário	31

Índice de gráficos

Gráfico 1 - Correlação	20
Gráfico 2 - Composição das carteiras.....	21
Gráfico 3 - Distribuição Retornos IBRX50.....	22
Gráfico 4 - Taxa de violação rv	28
Gráfico 5 - Perda Quadrática	29
Gráfico 6 - Retornos Pior Cenário.....	30

Índice de algoritmos

Algoritmo 1 - DeepVaR	24
-----------------------------	----

1 Introdução

O mercado financeiro é um ambiente complexo e volátil, sujeito a inúmeras variáveis que podem afetar o desempenho dos ativos e, consequentemente, a rentabilidade dos investimentos. Nesse contexto, o gerenciamento do risco de mercado é uma questão crítica para instituições financeiras e investidores, pois permite reduzir as incertezas e garantir a segurança dos investimentos.

Uma das principais ferramentas para o gerenciamento do risco de mercado é o *Value-at-Risk* (VaR), composto por um conjunto de modelos financeiros que buscam estimar a maior perda possível de uma carteira de ativos dado um intervalo de confiança e um horizonte de tempo e é, desde a década de 1990, uma das principais ferramentas para instituições financeiras gerenciarem o Risco de Mercado.

No entanto, o VaR é baseado em dados históricos e assume que o futuro seguirá o mesmo padrão do passado, o que pode levar a resultados imprecisos em períodos de crise, como pode ser observado na notícia divulgada pelo Risk Quantum em 2021, nos quais as unidades americanas do Deutsche Bank e do RBC registraram perdas que excederam em mil vezes o seu VaR. ORUGANTI; TAYAL (2023) explicam os efeitos do VaR nestas situações:

O problema aqui é que o VaR é calculado usando dados históricos e assume que o futuro seguirá o mesmo padrão do passado. Portanto, é voltado para o passado. Além disso, também é pró-cíclico, o que significa que antes de uma crise, quando é necessário mais capital, o VaR é tipicamente subestimado e, portanto, os requisitos de capital de risco de mercado dos bancos são baixos. Da mesma forma, quando uma crise passa e os bancos são obrigados a liberar capital para injetar liquidez no mercado, vemos números elevados de VaR e um alto requisito de capital. (ORUGANTI, S.; TAYAL, Y. *The Trouble with VaR: Rethinking a Key Metric Amid COVID-19*. In: *Global Association of Risk Professionals*. [Tradução livre por Vítor de Souza Faria]. Disponível em: <https://www.garp.org/risk-intelligence/market/the-trouble-with-var-rethinking-a-key-metric-amid-covid-19>. Acesso em: 10 fev. 2023)

Na última década trabalhos como o de Weng et al. (2017) têm proposto o uso de modelos de aprendizado de máquina para prever o movimento das séries temporais de preços dos ativos buscando, assim, resolver o problema pró-cíclico causado pelas abordagens atuais. Ao utilizar Redes Neurais Recorrentes (RNN), Fatouros et al. (2022) sugere um modelo mais eficiente ao modelo paramétrico substituindo a distribuição da série histórica pela distribuição prevista pelo DeepAR, proposta por Salinas (2019), denominando esse modelo de DeepVaR.

Em seu artigo, Fatouros et al. (2022) avalia a eficácia do modelo através de uma carteira composta por quatro ativos cambiais do *Foreign Exchange Market* (Forex). Tendo como base

esse mercado o artigo conclui que o modelo proposto com base em redes neurais profundas é mais eficiente em termos de violações e perda excessiva além do limiar de VaR.

O estudo tem como motivação a necessidade de desenvolver modelos mais precisos e confiáveis para gerenciamento do risco de mercado, especialmente em períodos de crise, quando a volatilidade e a incerteza são elevadas. Além disso, a validação do modelo no mercado mobiliário brasileiro pode contribuir para aprimorar as práticas de gestão de risco em instituições financeiras e aumentar a segurança dos investimentos dos clientes.

O objetivo do presente estudo consiste em avaliar a eficácia do modelo DeepVar no mercado mobiliário brasileiro, comparando-o com os modelos tradicionais em termos de precisão e confiabilidade.

2. Fundamentação Teórica

A fim de endossar e fundamentar o estudo aqui proposto, serão apresentados neste capítulo o aparato teórico do *Value-at-Risk* (VaR), quanto do DeepAR, modelo de rede neural recorrente utilizado no experimento.

2.1 Value-at-Risk (VaR)

No mercado financeiro, um dos grandes desafios no gerenciamento de portfólios é o gerenciamento de riscos. O risco refere-se à probabilidade de prejuízo ou insucesso em um empreendimento, projeto ou coisa, devido a eventos incertos e independentes da vontade dos envolvidos. No contexto financeiro, existem diversas categorias de risco, incluindo risco de crédito, risco operacional, risco de liquidez e risco de mercado.

Dentre essas categorias de risco, os modelos de risco de mercado têm como objetivo quantificar a perda financeira de um determinado portfólio em um horizonte de tempo específico. Embora o conceito pareça simples, o desenvolvimento desses modelos envolve uma série de desafios estatísticos complexos que, ao longo dos anos, resultaram no surgimento de diversos modelos e abordagens.

Esses modelos, apesar de diferirem em suas técnicas estatísticas, seguem um padrão comum. Primeiramente, é necessário realizar o apreçamento do portfólio à mercado, ou seja, determinar o valor atual dos ativos que compõem o portfólio com base nos preços de mercado. Em seguida, é realizada uma análise estatística para estimar a distribuição de probabilidade dos

retornos do portfólio, levando em consideração os preços de mercado e outros fatores relevantes.

Com base na distribuição de retornos estimada, é possível calcular medidas de risco, sendo uma das mais comuns o *Value-at-Risk* (VaR). O VaR é uma medida estatística que busca estimar a perda máxima esperada em um determinado nível de confiança durante um período especificado. A equação geral do VaR é dada por:

$$VaR = \text{Portfólio Inicial} \times [\text{Retorno Médio} - (Z \times \text{Desvio Padrão})] \quad (1)$$

Onde, Portfólio Inicial é o valor inicial do portfólio, Retorno Médio é a média dos retornos do portfólio, Z é o valor crítico associado ao nível de confiança desejado e Desvio Padrão é o desvio padrão dos retornos do portfólio.

O VaR é amplamente utilizado no mercado financeiro como uma ferramenta para gerenciamento de risco de mercado. No entanto, é importante destacar as limitações do VaR. O modelo é baseado em dados históricos e assume que o futuro seguirá o mesmo padrão observado no passado. Essa suposição pode levar a resultados imprecisos, especialmente em períodos de crise ou eventos extremos, onde as condições do mercado podem se desviar significativamente dos padrões históricos.

Diante dessas limitações, surgem novas abordagens e modelos que buscam aprimorar a precisão e confiabilidade do gerenciamento de risco de mercado. No presente estudo, exploraremos o uso de modelos de aprendizado de máquina como uma alternativa ao VaR tradicional. Esses modelos utilizam técnicas avançadas de análise de dados para prever o movimento das séries temporais de preços dos ativos, oferecendo uma abordagem mais adaptativa e flexível ao gerenciamento de risco.

2.2 DeepAR

Redes Neurais Recorrentes (RNNs) são arquiteturas fundamentais projetadas para lidar com dados sequenciais, onde a ordem e a dependência temporal das informações são cruciais. Ao contrário das redes neurais tradicionais, que operam com entradas independentes, as RNNs possuem conexões recorrentes que permitem a propagação de informações ao longo do tempo. Sua capacidade de capturar dependências temporais torna-as valiosas em tarefas como

processamento de linguagem natural, reconhecimento de fala, tradução automática e previsão de séries temporais.

No entanto, as RNNs convencionais apresentam limitações, como dificuldade em capturar dependências de longo prazo e problemas com o gradiente que podem desaparecer ou explodir durante o treinamento. Para superar essas limitações, as redes LSTM (*Long Short-Term Memory*) foram desenvolvidas (Hochreiter, 1997). As LSTMs são uma variante das RNNs que introduzem células de memória especializadas. Essas células possuem portões, como o de esquecimento, o de entrada e o de saída, que regulam o fluxo de informações na célula de memória, permitindo que a LSTM aprenda a reter e descartar informações relevantes ao longo do tempo.

Graças aos mecanismos de portões, as LSTMs são capazes de capturar dependências de longo prazo em sequências, tornando-as adequadas para lidar com informações sequenciais complexas e dependências temporais. No entanto, as LSTMs tradicionais têm limitações próprias, como a falta de modelagem de incerteza nas previsões e a limitação ao processar apenas a série temporal em si.

Nesse contexto, o DeepAR surge como uma evolução das LSTMs tradicionais para a previsão em séries temporais. O DeepAR incorpora melhorias cruciais, incluindo a capacidade de modelar distribuições de probabilidade para prever valores futuros, em contraste com as LSTMs tradicionais que geram apenas previsões pontuais. Isso permite ao modelo capturar a incerteza inerente às previsões e fornecer estimativas mais completas e informativas.

Além disso, o DeepAR foi projetado para lidar com informações contextuais adicionais, chamadas covariáveis. Enquanto as LSTMs tradicionais focam apenas na série temporal, o DeepAR permite a inclusão de múltiplas covariáveis no modelo. Essas covariáveis podem ser fatores externos que influenciam a série temporal, como dados meteorológicos, informações econômicas ou sazonais. Ao incorporar essas covariáveis, o modelo é capaz de capturar relações complexas e fornecer previsões mais precisas e personalizadas.

Outra contribuição do DeepAR é a capacidade de treinamento em lote (*batch training*), permitindo que o modelo seja treinado eficientemente em grandes conjuntos de dados. Esse recurso é particularmente útil em cenários com várias séries temporais para prever simultaneamente, como previsão de vendas em várias lojas ou previsão de tráfego em várias regiões. O treinamento em lote no DeepAR é escalável e eficiente, permitindo que o modelo aprenda padrões comuns entre as séries e faça previsões agregadas consistentes.

Em suma, o DeepAR representa uma evolução das LSTMs tradicionais, incorporando melhorias cruciais para a previsão de séries temporais. Com a capacidade de modelar

distribuições de probabilidade, lidar com covariáveis e realizar treinamento em lote, o DeepAR oferece uma abordagem avançada e precisa para a previsão, sendo aplicável em diversos setores e cenários onde a previsão de informações é essencial. Essas melhorias tornam o DeepAR uma ferramenta poderosa para análise e tomada de decisões baseadas em dados sequenciais.

3. DeepVAR: Modelando a Distribuição de Probabilidade

Neste capítulo, será discutido como o modelo DeepVAR utiliza o DeepAR para inferir a distribuição de probabilidade dos retornos e, assim, substituir a suposição da distribuição normal no modelo paramétrico de VaR. Exploraremos de que maneira o DeepVAR estima a distribuição de probabilidade e como essa informação é utilizada para obter estimativas mais robustas do risco.

3.1 Estimativa da Distribuição de Probabilidade

O modelo DeepVAR, baseado no DeepAR, possui a capacidade de modelar diretamente a distribuição de probabilidade dos retornos em séries temporais multivariadas. Enquanto o modelo paramétrico de VaR assume uma distribuição normal para os retornos, o DeepVAR é capaz de inferir uma distribuição mais flexível e adequada aos dados.

Durante o treinamento do DeepVAR, o modelo aprende a atribuir pesos diferentes para as diferentes partes da distribuição, permitindo que ele melhor capture as características complexas e não lineares dos dados. Isso resulta em uma distribuição inferida que pode ser assimétrica, com caudas mais pesadas, e melhor representação dos eventos extremos.

3.2 Utilização da Distribuição Inferida para Estimativa do Risco

Com a distribuição inferida pelo modelo DeepVAR, podemos obter estimativas mais precisas do risco por meio do VaR. Em vez de assumir uma distribuição normal, usamos a distribuição inferida para calcular o VaR com base no nível de confiança desejado.

O processo envolve a geração de várias amostras da distribuição inferida pelo DeepVAR e o cálculo do percentil $(1 - \text{nível de confiança})$ dessas amostras para obter o VaR. Essa abordagem leva em consideração as características específicas da distribuição inferida, como assimetria e caudas pesadas, resultando em estimativas mais realistas do risco.

3.3 Comparação com o Modelo Paramétrico

A substituição da distribuição normal pelo uso da distribuição inferida pelo DeepVAR permite uma abordagem mais flexível e precisa na estimativa do risco. Será realizada a comparação dos resultados obtidos no modelo paramétrico, baseado na distribuição normal, com os resultados do VaR utilizando a distribuição inferida pelo DeepVAR.

Por meio da comparação, poderemos avaliar a capacidade do DeepVAR em capturar eventos extremos e estimar de forma mais adequada o risco associado aos retornos do mercado financeiro. Isso nos ajudará a entender a melhoria proporcionada pelo uso do modelo DeepVAR em relação às suposições simplificadoras do modelo paramétrico.

4 Metodologia

Neste capítulo, será descrita a metodologia adotada para a realização deste estudo. Serão abordados os procedimentos de coleta e preparação dos dados, a utilização do modelo DeepVAR para a mensuração do risco de mercado, a comparação dos resultados obtidos com os modelos histórico e paramétrico de VaR e a avaliação dos modelos por meio de métricas de desempenho.

4.1 Dados analisados

Como o escopo deste trabalho é avaliar o modelo DeepVaR no mercado mobiliário brasileiro, serão criadas cem carteiras de investimento simuladas, compostas por vinte papéis escolhidos de forma aleatória dentre os ativos que compunham o Índice Brasil 50 (IBRX50 - carteira teórica com as cinquenta ações de maior negociabilidade e representatividade dentro da Bolsa Balcão Brasil (B3)), em 01/04/2023, como mostra a Tabela 1.

Tabela 1 - Composição da carteira teórica IBRX50

Código	Ação	Tipo		Qtde. Teórica	Part. (%)
RRRP3	3R PETROLEUM	ON	NM	196.144.421	0,349
ALSO3	ALIANSCSONAE	ON	NM	330.109.863	0,361
ABEV3	AMBEV S/A	ON		4.386.652.506	3,879
ASAI3	ASSAI	ON	NM	1.189.793.199	0,994
AZUL4	AZUL	PN	N2	327.646.296	0,216
B3SA3	B3	ON	EJ NM	5.901.731.302	3,87
BBSE3	BBSEGURIDADE	ON	NM	671.682.536	1,402
BBDC4	BRADESCO	PN	EJ N1	5.156.077.326	4,117
BBAS3	BRASIL	ON	NM	1.420.731.069	3,397
BRFS3	BRF SA	ON	NM	1.076.512.610	0,405
BPAC11	BTGP BANCO	UNT	N2	1.225.470.424	1,536
CMIG4	CEMIG	PN	N1	1.442.098.974	1,033
CIEL3	CIELO	ON	NM	1.095.401.258	0,314
CSAN3	COSAN	ON	NM	1.171.063.698	1,056
CVCB3	CVC BRASIL	ON	NM	275.967.676	0,047
CYRE3	CYRELA REALT	ON	NM	274.142.301	0,234
ELET3	ELETROBRAS	ON	N1	2.021.119.463	4,053
ELET6	ELETROBRAS	PNB	N1	275.526.814	0,607
EQTL3	EQUATORIAL	ON	NM	1.100.513.485	1,867
GGBR4	GERDAU	PN	N1	1.147.768.260	1,684
NTCO3	GRUPO NATURA	ON	NM	835.961.011	0,574
HAPV3	HAPVIDA	ON	NM	4.455.957.762	0,647
HYPE3	HYPERA	ON	EJ NM	400.842.480	0,93
ITSA4	ITAUSA	PN	N1	5.233.076.295	2,604
ITUB4	ITAUNIBANCO	PN	EJ N1	4.801.489.940	7,182
JBSS3	JBS	ON	NM	1.134.986.483	1,168
KLBN11	KLABIN S/A	UNT	N2	701.899.756	0,77
RENT3	LOCALIZA	ON	EJS NM	776.996.207	2,487
LWSA3	LOCAWEB	ON	NM	419.466.860	0,121
LREN3	LOJAS RENNER	ON	NM	965.528.807	0,93
MGLU3	MAGAZ LUIZA	ON	NM	2.874.188.573	0,594
MRFG3	MARFRIG	ON	NM	316.724.584	0,122
MULT3	MULTIPLAN	ON	EJ N2	268.145.328	0,416
PETR3	PETROBRAS	ON	N2	3.701.760.571	6,143
PETR4	PETROBRAS	PN	N2	4.566.441.248	6,716
PRIO3	PETRRIO	ON	NM	839.159.130	1,793
PETZ3	PETZ	ON	NM	335.724.569	0,117
RADL3	RAIADROGASIL	ON	EJ NM	1.196.069.386	1,833
RDOR3	REDE D OR	ON	NM	1.149.694.340	1,542
RAIL3	RUMO S.A.	ON	NM	1.215.642.613	1,39
SBSP3	SABESP	ON	NM	340.002.999	1,046
CSNA3	SID NACIONAL	ON		589.695.175	0,527
SUZB3	SUZANO S.A.	ON	NM	726.823.001	1,798
TOTS3	TOTVS	ON	NM	520.749.110	0,869


USIM5	USIMINAS	PNA	N1	515.014.562	0,221
VALE3	VALE	ON	NM	4.547.296.398	21,388
VIIA3	VIA	ON	NM	1.576.975.642	0,182
VBBR3	VIBRA	ON	NM	1.114.442.976	0,963
WEGE3	WEG	ON	NM	1.481.593.024	3,506
Quantidade Teórica Total				78.288.502.311	100
Redutor				96.875.111,40	

Fonte: site B3 (2023)

O índice nesse trabalho será utilizado para representar o mercado como um todo, no qual o DeepAR será treinado e, com isso, observar o comportamento do DeepVaR sendo aplicado a subconjuntos de ativos do mercado.

Além do índice, de maneira implícita, já ser uma representação importante do mercado, pode-se observar no Gráfico 1 que os ativos que o compõem apresentam uma correlação baixa entre seus retornos.


Gráfico 1 - Correlação



Fonte: Elaborado pelo autor (2023)

Ao gerar as cem carteiras de investimento de forma aleatória, foi realizada uma análise para verificar a composição destas, a fim de garantir que todos os ativos do índice estavam contidos em pelo menos uma carteira e se algum ativo não teria uma participação. No Gráfico 2, pode-se observar que todos os ativos foram alocados.

Gráfico 2 - Composição das carteiras



Fonte: Elaborado pelo autor (2023)


Para este conjunto de ativos foram coletadas as cotações de fechamento do período de 02/01/2010 a 30/11/2022, bem como os retornos logarítmicos no mesmo intervalo. Os retornos logarítmicos são calculados como o logaritmo natural do preço de fechamento dividido pelo logaritmo natural do preço de fechamento anterior, como mostra a equação:

$$r_t = \frac{\ln p_t}{\ln p_{t-1}} \quad (2)$$

Esta transformação é utilizada para normalizar a variação de preço dos ativos, a fim de que a diferença de magnitude do preço dos ativos não influencie a análise.

Como o modelo paramétrico assume distribuição normal dos retornos, no Gráfico 3 são apresentados os gráficos de distribuição dos ativos listados. Para verificar se os retornos apresentam distribuição normal foi utilizado o teste de Shapiro-Wilk (Shapiro, 1965) e os resultados obtidos na Tabela 2 demonstram que 42 dos 49 ativos apresentaram distribuição normal ($p\text{-valor} \leq 0,05$).

Gráfico 3 - Distribuição Retornos IBRX50



Fonte: Elaborado pelo autor (2023)

Tabela 2 - Teste de Shapiro-Wilk

Ativo	Estatística	p-valor
ELET6	0.979954	408,12
PETR4	0.849578	0,00
PETR3	0.860831	0,00
VALE3	0.991359	84658,14
ELET3	0.973901	36,57
BBDC4	0.969668	7,86
BBAS3	0.943381	0,00
CMIG4	0.987098	10326,67
ITSA4	0.987588	13093,35
CSNA3	0.994843	434708,10
USIM5	0.990945	68868,32
Sbsp3	0.962906	0,83
GGBR4	0.996118	691819,00
LREN3	0.983414	1847,29
NTCO3	0.928575	0,00
WEGE3	0.977931	176,71
RENT3	0.979346	316,24
CYRE3	0.988486	20306,09
CSAN3	0.972226	19,64
TOTS3	0.997671	955302,90
JBSS3	0.989164	28376,26
MRFG3	0.990301	49959,51
MULT3	0.995097	481703,10
SUZB3	0.990726	61735,73
EQTL3	0.974673	48,99
HYPE3	0.996348	740337,20
B3SA3	0.988762	23263,88
ITUB4	0.846561	0,00
BRFS3	0.954226	0,06
CIEL3	0.976582	102,91
MGLU3	0.972230	19,66
RADL3	0.988620	21689,67
VIIA3	0.993756	269958,30
BBSE3	0.990667	59967,63
ABEV3	0.959705	0,31
KLBN11	0.990712	61321,81
CVCB3	0.985469	4757,63
RAIL3	0.972864	24,83
PRI03	0.983087	1594,62
BPAC11	0.997200	897482,40
AZUL4	0.952299	0,04
VBBR3	0.987524	12691,35
HAPV3	0.991606	95693,83
ALSO3	0.993817	277677,00
LWSA3	0.992077	120787,70
PETZ3	0.993973	298121,50
RRRP3	0.981793	898,97
RDOR3	0.978774	249,41
ASAI3	0.949080	0,02

Fonte: Elaborado pelo autor (2023)

Os dados aqui citados foram cedidos pela empresa LUZ Soluções Financeiras, sua obtenção e manipulação fogem do escopo deste estudo.

4.2 Modelo DeepVaR

Para a implementação do DeepVaR, foi utilizado a linguagem de programação Python com o suporte das bibliotecas GluonTS Alexandrov (2019) e NumPy.

O DeepAR foi implementado utilizando a estrutura do MXNext, treinando o modelo com os seguintes parâmetros propostos por Fotouros (2022):

- a) prediction_length: 1 (previsão de um dia à frente)
- a) context_length: 15 (histórico de 15 dias anteriores para gerar a previsão)
- b) num_cells: 50 (número de células em cada camada da RNN)
- c) num_layers: 2 (número de camadas da RNN)
- d) dropout_rate: 0.1 (taxa de dropout para regularização)

Uma das diferenças deste trabalho com relação ao que foi proposto por Fotouros (2022), é que o VaR será calculado em moeda corrente, com o objetivo de incluir nas observações a alteração de participação de cada ativo ao longo do tempo devido as variações dos preços, como pode-se observar na Algoritmo 1.

Algoritmo 1 - DeepVaR

Algoritmo 1: DeepVaR

- 1: Montar um portfólio com 20 ativos $P_x \in IBRX50$
 - 2: Definir o intervalo de confiança α (p.e. $\alpha = 0,99$)
 - 3: Montar a matriz de Retornos do IBRX50 R_{treino}
 - 4: Montar a matriz de Retornos do portfólio R_p
 - 5: $Valor(x, t)$ = Valor do ativo x da data t
 - 6: $Previsão(x, \alpha)$ = Distribuição de probabilidade do ativo x inferido pelo DeepAR
 - 7: **Para** dia teste $t = 1$ **até** T **faça**
 - 8: Treinar o modelo com $R_{treino}[t - 1]$
 - 9: **Para** x em P **faça**
 - 10: **Se** $Valor(x, t) < 0$ **então**
 - 11: $V_i = Previsão(x, 1 - \alpha)Valor(x, t)$
 - 12: **Senão**
 - 13: $V_i = Previsão(x, \alpha)Valor(x, t)$
 - 14: **Fim**
 - 15: $VaR_t^\alpha = -\sqrt{VR_p V^t}$
-

Fonte: Fotouros (2022) modificado pelo autor (2023)

4.3 Comparação com modelos histórico e paramétrico de VaR

Além da previsão de risco com o modelo DeepVAR, também serão adotados outros dois modelos para fins de comparação: o modelo histórico e o modelo paramétrico.

O VaR histórico é uma abordagem não paramétrica que utiliza o histórico de retornos para estimar o risco. Para cada período de previsão, foi calculado o VaR histórico como o percentil $(1 - \text{intervalo de confiança})$ da distribuição dos retornos observados no período de treinamento correspondente.

Já o modelo paramétrico de VaR é baseado na suposição de uma distribuição de probabilidade para os retornos dos ativos financeiros. Neste estudo, foi utilizada a distribuição normal como a distribuição paramétrica para modelar os retornos. Estimando os parâmetros da distribuição normal a partir dos dados históricos e, em seguida, calculamos o VaR paramétrico com base nessa distribuição.

4.4 Avaliação dos modelos

Para todos os modelos e cenários foi utilizado o período de 03/01/2022 a 30/11/2022. Este intervalo de tempo foi escolhido para a análise devido a alta volatilidade do mercado mobiliário brasileiro neste momento, com o Ibovespa obtendo sua máxima em abril ao atingir os 121,6 mil pontos e a mínima em julho com 96 mil pontos sendo, portando, um período importante para verificar a qualidade do modelo em situações de incerteza.

Os modelos receberão como entrada o retorno de 252 (duzentos e cinquenta e dois) dias anteriores a data de cálculo, o intervalo de confiança (α) será de 99% e o horizonte de estimativa será de 1 (um) dia útil.

A fim de avaliar se o modelo de estudo é melhor que seus pares apresentados, serão utilizadas métricas consolidadas na indústria, a primeira delas é a variável de acerto, associada a uma observação pós fato, cujo valor é igual a 1 (um) se o VaR for maior que a variação do portfólio, e 0 (zero) caso o VaR for menor que a variação do portfólio:

$$I_t = \begin{cases} 1, & \text{se } VaR_t > PnL_t \\ 0, & \text{caso contrário} \end{cases} \quad (3)$$

Já o número de violações é a quantidade de vezes que a variável de acerto apresenta valor 1 (um), ou seja, o número de vezes que o VaR estimado foi aquém da perda real, é formalizado por:

$$N_v = \sum_{t=1}^T I_t \quad (4)$$

O número de violações esperadas é a quantidade de falhas prováveis, levando em conta o tamanho da amostra e o intervalo de confiança:

$$E[v] = (1 - \alpha)N_{dias} \quad (5)$$

A taxa de violação consiste na razão entre o número de violações e o tamanho da amostra:

$$r_v = \frac{N_v}{N_{dias}} \quad (6)$$

E a perda quadrática é a magnitude das violações do modelo:

$$l_{ql} = \sum_{i=0}^n I_t (1 + (PnL_t - VaR_t)^2) \quad (7)$$

Com a perda quadrática é possível verificar o tamanho do desvio da estimativa ao valor observado, ou seja, o quão longe ou perto o número estimado estava da realidade. Neste caso quanto menor for o resultado mais próximo o modelo esta da realidade.

Neste capítulo foram descritos os procedimentos de coleta e preparação dos dados, a utilização do modelo DeepVaR para previsão de risco de mercado, a comparação com os modelos histórico e paramétrico de VaR e a avaliação dos modelos por meio de métricas de desempenho. No próximo capítulo, serão apresentados os resultados obtidos e assim como suas implicações.

5. Resultados

Neste capítulo, serão apresentados os resultados obtidos por meio da aplicação do modelo DeepVaR e sua comparação com os modelos histórico e paramétrico de VaR. Os resultados são inicialmente apresentados de forma sintética e, posteriormente, serão apresentados os resultados da carteira que obteve o pior resultado em número de violações do modelo DeepVaR.

5.1 Resultados gerais

Na Tabela 3 apresentam-se os resultados médios das carteiras de investimento para cada um dos modelos analisados:

Tabela 3 - Resultados das métricas

Modelo	$E[v]$	N_v	r_v	l_{ql}
DeepVaR	2,3	3,24	0,014086	161103858,18
Histórico	2,3	3,05	0,013260	289324339,89
Paramétrico	2,3	4,92	0,021391	461590463,12

Fonte: elaborado pelo autor (2023)


Os resultados obtidos mostram que o modelo DeepVaR apresentou um bom desempenho em relação às métricas de avaliação. A taxa de violação média r_v para o DeepVar foi de 0,014086, o que indica que o modelo subestimou o risco em apenas 1,40% das observações, ficando bem próximo do modelo histórico que na média foi de 1,32%. O modelo paramétrico por sua vez apresentou o pior resultado com uma taxa de falha de 2,13%. Analisando a distribuição dos resultados da taxa de violação conforme ilustrado na Tabela 4, observa-se que os modelos DeepVaR e Histórico apresentaram uma distribuição praticamente equivalente (Gráfico 4), apresentando valores para o primeiro e terceiro quartis iguais e o mesmo para a mediana.

Tabela 4 - Distribuição do r_v

Modelo	1º Quartil	3º Quartil	Mediana	Média	Obliquidade
DeepVaR	0,00869	0,01739	0,01304	0,01408	0,08655
Histórico	0,00869	0,01739	0,01304	0,01326	0,47139
Paramétrico	0,01739	0,02608	0,02173	0,02139	-0,25744

Fonte: elaborado pelo autor (2023)

Quanto à perda quadrática (l_{ql}) (Tabela 5) o modelo DeepVaR registrou na média um valor de 161.103.858,18, representando a magnitude das violações. Em contraste, o modelo histórico e o modelo paramétrico apresentaram valores muito maiores, de 289.324.339,89 e 461.590.463,12, respectivamente. Isso reforça a superioridade do modelo DeepVaR em relação à minimização das perdas associadas a suas estimativas. Essa observação é sustentada ao observarmos as métricas sobre a distribuição das perdas, nos quais o DeepVaR obteve a melhor média e mediana, tendo a menor dispersão dentre os três modelos (Gráfico 5).

Gráfico 4 - Taxa de violação r_v 


Fonte: Elaborado pelo autor (2023)

Tabela 5 - Distribuição da Perda Quadrática

Modelo	1º Quartil	3º Quartil	Mediana	Média	Obliquidade
DeepVaR	38592190,13	228454193,55	110288897,35	161103858,18	1,8197
Histórico	50887007,95	411780036,63	160996537,24	289324339,89	1,5821
Paramétrico	158592066,18	653913500,46	338203281,86	461590463,12	1,31623

Fonte: Elaborado pelo autor (2023)

Gráfico 5 - Perda Quadrática



Fonte: Elaborado pelo autor (2023)


5.2 Pior Caso

Nesta etapa foi dado enfoque ao cenário que obteve o pior resultado, considerando o número de violações N_v do modelo DeepVaR. O objetivo é verificar, no seu pior cenário, se ele é pior que seus pares ou, ainda assim, apresenta melhores resultados. No Gráfico 6 é possível

observar o comportamento da variação do portfólio ao longo do período confrontado com o VaR estimado para cada modelo.

Analisando a correlação dos modelos dentro deste período, ilustrada na Tabela 6, pode-se observar que os modelos paramétrico e histórico estão altamente correlacionados, enquanto o modelo DeepVaR não tem correlação com os demais.

Gráfico 6 - Retornos Pior Cenário



Fonte: Elaborado pelo autor (2023)

Tabela 6 - Correlação Modelos Pior Cenário

Modelo	DeepVar	Histórico	Paramétrico
DeepVaR	1	0,451051	0,600630
Histórico	0,451051	1	0,921842
Paramétrico	0,600630	0,921842	1

Fonte: Elaborado pelo autor (2023)

Observando as métricas de avaliação deste cenário (Tabela 7), o DeepVaR apresentou métricas piores que o histórico, tendo uma maior taxa de violações

r_v e uma menor perda quadrática l_{ql} . Em contrapartida, neste cenário ele foi melhor que o modelo paramétrico a partir das mesmas métricas. O que demonstra que mesmo em cenários desfavoráveis ele apresenta resultados consistentes com seus pares, estando a frente em todas as métricas do modelo paramétrico.

Tabela 7 - Resultados das métricas do pior cenário

Modelo	$E[v]$	N_v	r_v	l_{ql}
DeepVaR	2,3	7	0,0304347	139658381,70
Histórico	2,3	6	0,0260869	56914008,13
Paramétrico	2,3	9	0,0391304	239834911,36

Fonte: Elaborado pelo autor (2023)

Este estudo ofereceu uma análise abrangente das métricas de desempenho dos modelos de estimativa de risco DeepVaR, histórico e paramétrico. Os resultados indicaram que o modelo DeepVaR se equipara a seus pares em termos de precisão, minimização de violações e redução de perdas. As implicações desses resultados ressaltam a importância de adotar abordagens mais avançadas e precisas na gestão de riscos financeiros. Ao considerar as limitações e oportunidades futuras, este estudo contribui para a evolução da prática de gestão de riscos e oferece uma base sólida para investigações subsequentes.

6. Conclusão

O presente trabalho teve como objetivo principal avaliar a eficácia do modelo DeepVaR em comparação com os modelos histórico e paramétrico de *Value-at-Risk* (VaR) na estimativa de riscos de mercado no contexto do mercado mobiliário brasileiro, utilizando-se de métricas de avaliação já consolidadas no mercado.

Ao aplicar o modelo neste cenário específico, diferentemente do trabalho original, o DeepVaR não foi superior ao modelo histórico em número de violações, mas, em contrapartida, apresentou uma média na perda quadrática inferior. Na média o modelo se equiparou aos modelos já estabelecidos, sendo menos conservador que o modelo histórico, que apresentou uma dispersão menor na taxa de violação r_v (Gráfico 3), ao mesmo tempo em que é um modelo

mais eficiente na alocação ao apresentar uma perda quadrática l_{ql} , com menor dispersão que o histórico (Gráfico 4).

Ao analisar a carteira na qual o DeepVaR obteve o maior número de violações entre todos os cenários, o modelo não chegou a obter os piores resultados comparados a seus pares, sendo pior que o histórico, mas consistentemente melhor que o paramétrico. Esses dados ajudam a corroborar que o modelo DeepVaR apresenta, do ponto de vista estatístico, uma relação interessante entre as violações e a perda quadrática, possibilitando uma gestão de capital mais eficiente e que, mesmo no cenário em que obteve os piores resultados em termos de violação, se mostrou dentro do esperado dos modelos equivalentes.

Nos resultados podemos verificar essencialmente um VaR mais próximo ao que foi observado na prática do que os demais modelos apresentados (observando a perda quadrática). Essa precisão aprimorada tem implicações diretas na tomada de decisões, na alocação de capital e na gestão de ativos em ambientes financeiros complexos e voláteis.

A aplicação do modelo DeepVaR não apenas contribui para uma gestão mais eficiente de riscos, mas também fortalece a confiabilidade das projeções financeiras e proporciona uma vantagem competitiva no mercado. Além disso, ressalta a importância da inovação tecnológica no campo da gestão de riscos, incentivando a adoção de abordagens mais avançadas e orientadas por dados.

Como conclusão, este estudo ressalta a relevância do modelo DeepVaR, sua aplicabilidade ao mercado de ações brasileiro, tornando-se uma ferramenta poderosa para aprimorar a capacidade de prever e gerenciar riscos de mercado. Suas contribuições podem ter um impacto significativo não apenas nas operações internas das instituições financeiras, mas também na confiança dos investidores e nas estratégias de negócios de longo prazo. Recomenda-se que futuras pesquisas explorem ainda mais a aplicabilidade do referido modelo em diferentes cenários e contextos, a fim de estender sua utilidade e compreensão no campo da gestão de riscos financeiros.

7. Referências Bibliográficas

ACERBI, C.; TASCHE, D. On the coherence of expected shortfall. **Journal of banking & finance**, v. 26, n. 7, p. 1487–1503, 2002.

ALEXANDROV, A.; BENIDIS, K.; BOHLKE-SCHNEIDER, M.; FLUNKERT, V.; GASTHAUS, J.; JANUSCHOWSKI, T; et al. Gluonts: Probabilistic time series models in python. **ICML 2019 Workshop on Time Series**, 2019

ANGELIDIS, T.; DEGIANNAKIS, S. A. Backtesting VaR models: A two-stage procedure. **Journal of Risk Model Validation**, v1, p. 1-2, 2007.

ENGLE, R. F.; MANGANELLI, S. CAViaR: Conditional autoregressive value at risk by regression quantiles. **Journal of business & economic statistics: a publication of the American Statistical Association**, v. 22, n. 4, p. 367–381, 2004.

FATOUROS, G. et al. DeepVaR: a framework for portfolio risk assessment leveraging probabilistic deep neural networks. **Digital finance**, p. 1–28, 2022.

HOCHREITER, S.; Schmidhuber, J. Long Short-Term Memory. **Neural Computation**, v. 9, n. 8, p. 1735-1780, 1997.

JORION, P. **Value at risk: The new benchmark for managing financial risk**. 2. ed. Montigny-le-Bretonneux, France: McGraw-Hill, 2000.

MANGANELLI, S.; ENGLE, R. F. Value at risk models in finance. **SSRN Electronic Journal**, 2001.

ORUGANTI, S.; TAYAL, Y. **The trouble with VaR: Rethinking a key metric amid COVID-19**. Garp.org Global Association of Risk Professionals, 2 jul. 2020. Disponível em: <<https://www.garp.org/risk-intelligence/market/the-trouble-with-var-rethinking-a-key-metric-amid-covid-19>>. Acesso em: 10 fev. 2023

SALINAS, D. et al. DeepAR: Probabilistic forecasting with autoregressive recurrent networks. **International journal of forecasting**, v. 36, n. 3, p. 1181–1191, 2020.

SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, v. 52, n. 3/4, p. 591, 1965.

WENG, B.; AHMED, M. A.; MEGAHED, F. M. Stock market one-day ahead movement prediction using disparate data sources. **Expert Systems with Applications**, v. 79, p. 153–163, 2017.

WOODALL, L. **Trading losses at US units of Deutsche, RBC exceed VAR by 1,000%**. Disponível em: <<https://www.risk.net/risk-quantum/7545691/trading-losses-at-us-units-of-deutsche-rbc-exceed-var-by-1000>>. Acesso em: 19 mar. 2023.