

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
DE COMPUTAÇÃO**

LEMYSON OLIVEIRA LEMOS

**PREDIÇÃO DE APLICAÇÃO DE DOSES DE VACINAS COM N-BEATS: UMA
SOLUÇÃO DE SAÚDE DIGITAL PARA A GESTÃO DE IMUNOBIOLOGICOS NO
SUS**

**NATAL/RN
2025**

LEMYSON OLIVEIRA LEMOS

Predição de aplicação de doses de vacinas com N-BEATS: Uma solução de saúde digital para a gestão de imunobiológicos no SUS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação da Universidade Federal do Rio Grande do Norte (área de concentração: Engenharia de Computação) como parte dos requisitos para obtenção do título de Mestre em Ciências.

Orientador: Prof. Dr. Luiz Affonso Guedes

Número de Ordem do PPgEEC: M685

**NATAL/RN
2025**

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Lemos, Lemyson Oliveira.

Predição de aplicação de doses de vacinas com N-BEATS: uma solução de saúde digital para a gestão de imunobiológicos no SUS / Lemyson Oliveira Lemos. - 2025.
43f.: il.

Dissertação (mestrado) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Programa de Pós-graduação em Engenharia Elétrica e de Computação, Natal, 2025.

Orientação: Prof. Dr. Luiz Affonso Guedes.

1. Predição - Dissertação. 2. N-BEATS - Dissertação. 3. Vacina - Dissertação. 4. Modelo - Dissertação. I. Guedes, Luiz Affonso. II. Título.

RN/UF/BCZM

CDU 615.37

Elaborado por Jackeline dos Santos Pinheiro da Silva Maia
Cavalcanti - CRB-15/317

AGRADECIMENTOS

Aos meus pais, João Batista Lemos e Lucimar Felício de Oliveira, por nunca terem medido esforços para me proporcionar um ensino de qualidade durante todo o meu período escolar, e à minha noiva Micarla Liliane Alves, pelo apoio e companheirismo ao longo desta jornada.

RESUMO

A previsão de demanda por vacinas é essencial para a gestão eficiente dos estoques e a distribuição adequada dos imunobiológicos, garantindo cobertura vacinal e evitando desperdícios. Modelos de séries temporais são amplamente utilizados nesse contexto, permitindo antecipar a procura por vacinas e otimizar os recursos disponíveis. Com os avanços em *deep learning*, o algoritmo N-BEATS (*Neural Basis Expansion Analysis Time Series*) tem se destacado por sua eficácia em modelar dados complexos sem a necessidade de grande pré-processamento.

Introduzido por Oreshkin et al. (2020), o N-BEATS supera modelos tradicionais, como os autoregressivos e os MLPs (*Multi-Layer Perceptrons*), ao lidar com padrões não lineares por meio de uma arquitetura baseada em blocos empilhados, refinando iterativamente as previsões. Este estudo aplica o N-BEATS para prever semanalmente a quantidade de vacinas a serem aplicadas nos Estados do Rio Grande do Norte e Espírito Santo, utilizando dados dos sistemas RN+VACINA e Vacina e Confia. No Rio Grande do Norte, a previsão foca em uma análise macro, abrangendo esferas estadual e municipal, enquanto no Espírito Santo, a abordagem é mais granular, com previsões específicas por vacina.

Os resultados destacaram o desempenho superior do N-BEATS em relação a modelos tradicionais, como o XGBoost. No Rio Grande do Norte, o modelo alcançou um R^2 de 0,81 e um MAPE de 16,59%, enquanto o XGBoost obteve um R^2 de 0,73. Em Natal, município do estado, os valores foram R^2 de 0,77 e MAPE de 21,59%. No Espírito Santo, a análise foi realizada para o estado e o município de Cariacica, com foco na vacina BCG. Os resultados estaduais apresentaram um MAPE de 1,00% e R^2 de 0,83, enquanto no nível municipal os valores foram MAPE de 2,46% e R^2 de 0,85.

Essas métricas demonstram que o N-BEATS é uma solução robusta e eficiente para previsão de séries temporais em sistemas de vacinação. Sua capacidade de lidar com padrões não lineares e complexos, aliada à necessidade de um pré-processamento mínimo, o torna adequado para cenários onde rapidez e precisão são essenciais. Além disso, seu desempenho superior em comparação a modelos tradicionais reforça o potencial do N-BEATS como ferramenta confiável para a gestão de campanhas de vacinação, contribuindo para uma distribuição mais eficiente e estratégica dos imunizantes.

ABSTRACT

Vaccine demand forecasting is essential for the efficient management of stock and the proper distribution of immunobiologicals, ensuring vaccination coverage and preventing waste. Time series models are widely used in this context, allowing the anticipation of vaccine demand and the optimization of available resources. With advancements in deep learning, the N-BEATS (Neural Basis Expansion Analysis Time Series) algorithm has stood out for its effectiveness in modeling complex data without requiring extensive preprocessing.

Introduced by Oreshkin et al. (2020), N-BEATS outperforms traditional models, such as autoregressive models and Multi-Layer Perceptrons (MLPs), by handling nonlinear patterns through a block-stacking architecture that iteratively refines predictions. This study applies N-BEATS to forecast the weekly number of vaccines to be administered in the states of Rio Grande do Norte and Espírito Santo, using data from the RN+VACINA and Vacina e Confia systems. In Rio Grande do Norte, the forecast focuses on a macro analysis covering state and municipal levels, while in Espírito Santo, a more granular approach is taken, with vaccine-specific predictions.

The results highlighted the superior performance of N-BEATS compared to traditional models such as XGBoost. In Rio Grande do Norte, the model achieved an R^2 of 0.81 and a MAPE of 16.59%, while XGBoost obtained an R^2 of 0.73. In Natal, a municipality in the state, the values were R^2 of 0.77 and MAPE of 21.59%. In Espírito Santo, the analysis was conducted at the state level and for the municipality of Cariacica, focusing on the BCG vaccine. The state-level results showed a MAPE of 1.00% and R^2 of 0.83, while at the municipal level, the values were MAPE of 2.46% and R^2 of 0.85.

These metrics demonstrate that N-BEATS is a robust and efficient solution for time series forecasting in vaccination systems. Its ability to handle nonlinear and complex patterns, combined with minimal preprocessing requirements, makes it suitable for scenarios where speed and accuracy are essential. Additionally, its superior performance compared to traditional models reinforces the potential of N-BEATS as a reliable tool for managing vaccination campaigns, contributing to a more efficient and strategic distribution of immunizers.

SUMÁRIO

1 Introdução.....	9
2 Fundamentação Teórica	12
2.1- Redes Neurais	12
2.2 - Deep Learning	13
2.3 - Transformers.....	17
2.4 - N-BEATS (<i>Neural Basis Expansion Analysis Time Series Forecasting</i>)	19
2.4.1 - Arquitetura N-BEATS.....	19
2.4.2 - Formulação Matemática	24
2.4.3 - Hiperparâmetros.....	25
2.4.4 - Otimização dos Hiperparâmetros.....	27
3 Abordagem Proposta	28
3.1 Desenvolvimento da abordagem	29
3.1.1 Coleta e Preparação dos Dados.....	29
3.1.2 Etapas de Limpeza e Pré-Processamento.....	30
3.1.3 Divisão e modelagem.....	30
3.1.4 Configuração do Modelo N-BEATS	31
3.1.5 Método de Previsão	32
3.1.6 Métricas.....	32
4 Resultados	34
4.1 Resultados Gerais.....	34
4.2 Resultados Específicos	37
5 Conclusão	41
REFERÊNCIAS	43

LISTA DE FIGURAS

Figura 1 - Arquitetura Rede Neural.....	13
Figura 2 - Rede Neural Profunda.	14
Figura 3 - Gráfico da Função de Ativação ReLU.	15
Figura 4 - Fluxograma Deep Learning.	16
Figura 5 - Funcionamento de Redes Neurais Convolucionais (CNNs).....	17
Figura 6 - Funcionamento do Transformers.....	19
Figura 7 - Arquitetura do N-BEATS.....	20
Figura 8 - Representação do bloco no N-BEATS	22
Figura 9 - Arquitetura de pilha e blocos do N-BEATS.....	22
Figura 10 - Expansão da base neural.....	23
Figura 11 - Fluxo do N-BEATS	24
Figura 12 - Pipeline das etapas.....	29
Figura 13 - Previsão nível estadual com N-BEATS.....	35
Figura 14 - Previsão nível municipal.....	36
Figura 15 - Previsão nível estadual com XGBoost	36
Figura 16 - Previsão BCG Nível Estadual.....	38
Figura 17 - Previsão BCG Nível Municipal	39

1 INTRODUÇÃO

A vacinação é uma das estratégias de saúde pública mais eficazes na prevenção de doenças infecciosas. Desde o desenvolvimento das primeiras vacinas, a tecnologia no seu entorno tem evoluído constantemente, possibilitando o controle de epidemias, erradicação de doenças e previsão de campanhas de vacinação. Com o avanço científico e tecnológico no campo computacional da previsão, surgem novas oportunidades para enfrentar desafios complexos em diversas áreas, incluindo a saúde pública. Nesse contexto, a previsão precisa de demanda, comportamento de consumo e outras variáveis, por exemplo, tem se tornado cada vez mais crucial para a gestão eficiente de recursos. Entre as inovações mais promissoras para esse tipo de tarefa, destaca-se o algoritmo N-BEATS (*Neural Basis Expansion Analysis Time Series*), uma arquitetura de rede neural profunda que tem se mostrado particularmente eficaz na resolução de problemas de previsão em séries temporais. Introduzido por Oreshkin et al. (2020), o modelo de rede neural profunda N-BEATS foi projetado especificamente para lidar com previsões de séries temporais com comportamento complexo, oferecendo uma abordagem que supera modelos tradicionais baseados em métodos autoregressivos e em redes neurais com arquitetura MLP (*Multi Layer Perceptron*).

Uma das características fundamentais que diferencia o N-BEATS de outros modelos de redes neurais e séries temporais é sua capacidade de trabalhar diretamente com dados brutos, com um mínimo de limpeza, padronização ou normalização. Enquanto outros algoritmos dependem fortemente de um pré-processamento cuidadoso como suavização, remoção de picos ou padronização dos dados, o N-BEATS minimiza a necessidade dessa etapa, permitindo maior agilidade no pipeline de previsão. Essa capacidade de operar com dados mais próximos da realidade, sem exigir pré-processamento extensivo, é particularmente útil em contextos em que os dados são altamente variáveis ou de difícil tratamento. Em áreas como a saúde pública, onde os dados podem ser irregulares ou incompletos, o N-BEATS proporciona um avanço significativo em termos de simplicidade e flexibilidade.

O custo associado à limpeza, padronização ou normalização dos dados pode ser significativo, tanto em termos de tempo, quanto de recursos humanos e computacionais. A necessidade de especialistas para ajustar os dados de forma apropriada e garantir a compatibilidade com os modelos tradicionais frequentemente aumenta a complexidade e o tempo de desenvolvimento de soluções preditivas. Além disso, etapas como identificação de outliers, preenchimento de lacunas e transformação dos dados podem introduzir erros ou vieses, afetando a qualidade das previsões. Ao eliminar ou reduzir essas demandas, o N-BEATS não apenas acelera o processo de desenvolvimento, mas também torna a implementação mais acessível em cenários onde o volume de dados é elevado ou a equipe técnica é limitada. Essa eficiência no tratamento de dados não apenas acelera o tempo de entrega dos resultados, mas também contribui para a criação de soluções mais robustas em contextos de alta incerteza.

Ao contrário dos modelos convencionais, que frequentemente exigem conhecimento especializado sobre a estrutura e os parâmetros de uma série temporal, o N-BEATS se distingue por sua capacidade de operar com dados complexos e padrões não lineares. Sua arquitetura, composta por pilhas e blocos empilhados que refinam iterativamente as previsões, é capaz de capturar de forma precisa os padrões subjacentes nos dados. Essa flexibilidade e robustez

tornam o N-BEATS uma ferramenta particularmente útil em cenários onde a precisão das previsões é crítica. Essa capacidade de modelar complexidades não lineares torna o N-BEATS aplicável a uma gama ampla de problemas em diferentes setores. O modelo tem se mostrado eficaz em áreas como demanda e vendas, finanças, séries temporais multivariadas, carga e energia, saúde, meteorologia, entre outras (Oreshkin, B. N., 2020).

Na área da saúde, a previsão de aplicações de doses de vacinas é um problema de grande relevância, uma vez que as campanhas de vacinação são cruciais para o controle de doenças infecciosas e de saúde pública. Os dados históricos dos vacinados, podem ser utilizadas para prever o número de doses a serem aplicadas no futuro. O N-BEATS se destaca neste cenário, pois é capaz de identificar tanto padrões sazonais quanto tendências complexas, típicas de campanhas de vacinas, com o mínimo de pré-processamento. A flexibilidade do modelo permite que ele se ajuste a diferentes tipos de dados e situações, sem a necessidade de ajustes manuais constantes. Na literatura, já existem diferentes estudos que tratam da previsão de vacinas, mas geralmente é necessário realizar um extenso pré-processamento dos dados antes de treinar os modelos. Por exemplo, no artigo de Lemos, O. L. (2024), é apresentado o processo de tratamento de dados para a aplicação do algoritmo XGBoost (*Extreme Gradient Boosting*) na previsão de vacinados, evidenciando a dependência de processos de normalização, suavização e identificação de outliers, antes mesmo de iniciar a modelagem.

Em contextos de vacinação, em que a gestão eficaz de recursos pode significar a diferença entre vidas salvas ou perdidas, o N-BEATS oferece um potencial significativo. O modelo pode ser utilizado para prever a quantidade de vacinas necessárias, otimizar a distribuição, melhorar a alocação de insumos e formular estratégias de resposta a emergências sanitárias. A precisão e a adaptabilidade do N-BEATS permitem uma resposta mais ágil e inteligente, o que contribui para uma gestão mais eficaz dos recursos disponíveis e, consequentemente, para o sucesso das campanhas de vacinação.

O N-BEATS é amplamente reconhecido por suas vantagens, tornando-se uma escolha de destaque em problemas de previsão. Uma de suas principais características é a menor dependência de etapas de pré-processamento, o que simplifica consideravelmente o fluxo de trabalho e permite que o modelo lide diretamente com dados complexos. Sua arquitetura avançada é projetada para capturar padrões complexos nas séries temporais, incluindo tendências e sazonalidades, o que proporciona previsões mais precisas e confiáveis em uma ampla gama de cenários. Além disso, sua versatilidade o torna aplicável a diferentes tipos de séries temporais e setores, desde aplicações financeiras e econômicas até demandas em saúde e energia. Esses atributos tornam o N-BEATS uma ferramenta poderosa para resolver problemas que exigem alta precisão e robustez em suas previsões. Outro ponto de destaque é seu desempenho superior, comprovado em diversos benchmarks, onde frequentemente supera modelos tradicionais, como ARIMA e *Prophet*, bem como outras abordagens baseadas em aprendizado de máquina. Essa superioridade é evidenciada não apenas em termos de precisão, mas também na robustez frente a dados ruidosos ou incompletos, características comuns em séries temporais reais.

Entretanto, o N-BEATS não é isento de limitações. Seu alto custo computacional representa uma barreira significativa, especialmente em contextos com recursos limitados. A profundidade de sua arquitetura exige maior capacidade de processamento e memória, o que pode dificultar sua implementação em ambientes com restrições tecnológicas. Além disso, a

complexidade de sua estrutura implica que ajustes finos no modelo demandam conhecimentos avançados em rede neural profunda, tornando sua utilização desafiadora para equipes sem experiência nessa área.

Outro desafio relevante é o risco de *overfitting*, particularmente quando o modelo não é adequadamente regulado. Esse fenômeno ocorre quando o N-BEATS se ajusta excessivamente aos detalhes e ao “ruído” dos dados de treinamento, prejudicando sua capacidade de generalizar para novos dados. Para mitigar esse problema, é essencial aplicar técnicas de regularização, como *dropout* ou penalizações específicas, e adotar uma estratégia cuidadosa no particionamento dos dados entre treino, validação e teste.

Apesar de suas limitações, o N-BEATS continua a ser uma escolha altamente relevante para aplicações em séries temporais, especialmente em cenários onde a precisão e a capacidade de capturar padrões complexos são cruciais. Com os avanços contínuos em hardware e técnicas de rede neural profunda, muitas das limitações do modelo podem ser minimizadas, consolidando ainda mais seu papel como uma ferramenta inovadora e eficiente.

Com base nesse ambiente de predição de aplicação de doses de vacinas, o presente estudo propõe a utilização do N-BEATS para prever a quantidade de vacinados por semana, com base em dados históricos de aplicação de vacinas. Com o objetivo de desenvolver um modelo aplicável na previsão de vacinados na rede pública de saúde, considerando diferentes níveis de análise de dados, a fim de otimizar o planejamento e a gestão de estoque. Desta forma o modelo teria a capacidade de prever semanalmente a quantidade de vacinas, capacidade de lidar com dados agregados e segmentados, diminuir à necessidade de pré-processamentos dos dados, ajudar na tomada de decisão e incorporar futuramente mais variáveis e fatores externos na previsão da demanda vacinal.

O estudo será validado utilizando dados dos sistemas de vacinação do Rio Grande do Norte (RN+VACINA) e do Espírito Santo (Vacina e Confia), ambos com sistemas próprios de acompanhamento da vacinação, cujas informações estão disponíveis nos respectivos portais de transparência. A aplicação do N-BEATS visa otimizar o processo de distribuição de vacinas, promovendo uma gestão mais eficiente e proativa da vacinação.

Atualmente, a distribuição de vacinas é predominantemente reativa, ou seja, as doses são enviadas com base na demanda atual, o que pode resultar em desperdício de recursos e ineficiência. Com a utilização de modelos de previsão como o N-BEATS, é possível adotar uma abordagem mais proativa, na qual a distribuição é planejada com base nas previsões de demanda futura, o que permite otimizar a logística de entrega e reduzir o desperdício. Essa estratégia pode transformar o processo de distribuição, tornando-o mais inteligente e ágil, o que resulta em uma melhor alocação de recursos e uma resposta mais rápida às necessidades da população.

O remanescente deste trabalho está estruturado da seguinte forma: no Capítulo 2, apresenta-se a fundamentação teórica, abordando conceitos essenciais sobre redes neurais, *deep learning* (rede neural profunda) e o modelo N-BEATS, detalhando sua arquitetura, formulação matemática e hiperparâmetros. No Capítulo 3, descreve-se a proposta para a previsão da quantidade de vacinas a serem aplicadas, incluindo a coleta e preparação dos dados, a configuração e treinamento do modelo, e as ferramentas utilizadas. No Capítulo 4, são apresentados os resultados obtidos até o momento. No Capítulo 5, discutem-se a conclusão do trabalho e futuros trabalhos nessa linha de pesquisa.

2 FUNDAMENTAÇÃO TEÓRICA

Os conceitos essenciais que embasam o modelo N-BEATS (*Neural Basis Expansion Analysis Time Series Forecasting*), conectando as ideias apresentadas na introdução com a fundamentação teórica necessária para compreender seu funcionamento. O N-BEATS foi destacado como uma solução poderosa para lidar com séries temporais complexas, graças à sua arquitetura inovadora que reduz a necessidade de pré-processamento extenso e captura padrões não lineares com alta precisão.

Para aprofundar essa compreensão, iniciaremos com uma visão geral sobre redes neurais, *deep learning* e *transformers*, contextualizando como essas tecnologias formam a base do N-BEATS. Em seguida, detalharemos a arquitetura do modelo, seus componentes principais, como blocos empilhados e hiperparâmetros, e os mecanismos que permitem sua aplicação versátil em diferentes áreas, como saúde, energia e finanças. Essa abordagem permitirá entender como o N-BEATS combina simplicidade no uso de dados com sofisticação no processamento preditivo.

2.1- REDES NEURAIAS

As redes neurais são uma classe de modelos computacionais inspirados no funcionamento do cérebro humano, compostas por camadas de neurônios interconectados que processam e transmitem informações. Esses modelos têm se destacado áreas da inteligência artificial devido à sua capacidade de aprender padrões complexos e não lineares a partir dos dados. Ao ajustar seus pesos internos por meio de um processo chamado "treinamento", as redes neurais são capazes de realizar tarefas como classificação, regressão e previsão de séries temporais (Haykin, 2001).


A base teórica que sustenta o modelo N-BEATS, são as redes neurais artificiais. Conforme discutido na introdução, o N-BEATS se destaca por sua habilidade de capturar padrões complexos e não lineares em séries temporais. Essa capacidade é um reflexo direto dos princípios das redes neurais, que servem como a estrutura central de modelos preditivos avançados.

As redes neurais artificiais são modelos computacionais inspirados no funcionamento do cérebro humano, compostas por camadas de neurônios artificiais interconectados que processam e transmitem informações. Esses modelos são capazes de aprender a partir de dados, ajustando seus pesos internos através de um processo chamado de "treinamento" para resolver uma ampla variedade de problemas, como classificação, regressão, e previsão de séries temporais (Haykin, 2001). Segundo Bishop (1995), redes neurais são especialmente úteis para problemas onde os dados possuem padrões complexos e não lineares, tornando-as adequadas para tarefas como reconhecimento de padrões e predição.

Sua arquitetura é composta por três tipos principais de camadas (ver figura 1):

- Camada de Entrada (*Input Layer*): As informações do mundo externo entram na rede neural artificial pela camada de entrada. Os nós de entrada processam os dados, analisam ou categorizam esses dados e os encaminham para a próxima camada;

- Camada Oculta (*Hidden Layer*): As camadas ocultas usam as entradas da camada de entrada ou de outras camadas ocultas. As redes neurais artificiais podem ter várias camadas ocultas. Cada camada oculta analisa o resultado da camada anterior, processa-o mais um pouco e o encaminha para a próxima camada.;
- Camada de Saída (*Output Layer*): A camada de saída fornece o resultado final de todos os dados processados pela rede neural artificial. Ela pode ter um ou vários nós. Por exemplo, se tivermos um problema de classificação binária (sim/não), a camada de saída terá um nó de saída, o que fornecerá o resultado como 1 ou 0. Porém, se tivermos um problema de classificação de várias classes, a camada de saída poderá ter mais de um nó de saída.



Fonte: Compilação do autor.

Figura 1 - Arquitetura Rede Neural.


2.2 - DEEP LEARNING

Deep learning, ou aprendizado profundo, é um subcampo do machine learning que utiliza redes neurais artificiais com múltiplas camadas para extrair automaticamente padrões complexos dos dados. Diferente dos métodos tradicionais de aprendizado de máquina, que muitas vezes dependem de engenharia manual de características, as redes profundas são capazes de aprender representações hierárquicas a partir dos dados brutos, tornando-as especialmente poderosas para tarefas como reconhecimento de imagem, processamento de linguagem natural e previsão de séries temporais (LeCun, Bengio e Hinton, 2015).

No contexto do N-BEATS, *deep learning* é aplicado para modelar séries temporais de forma eficiente. O modelo utiliza redes neurais profundas compostas por múltiplos blocos empilhados, que atuam como camadas ocultas, permitindo a extração de características de alto nível sem necessidade de pré-processamento extensivo. Essa abordagem diferencia o N-

BEATS de redes neurais tradicionais, explorando a hierarquia e a abstração das redes profundas para identificar padrões sutis, como tendências, sazonalidades e irregularidades nas séries temporais. Essa estrutura permite que o modelo extraia características de alto nível diretamente dos dados brutos, dispensando a necessidade de engenharia manual de características – uma vantagem destacada por LeCun, Bengio e Hinton (2015) como um dos maiores benefícios do *deep learning*.

Ao contrário das redes neurais tradicionais com poucas camadas, o N-BEATS explora a hierarquia e a abstração oferecidas pelas redes profundas para identificar padrões presentes nas séries temporais. Essa hierarquia é particularmente relevante em tarefas como a previsão, onde há interações sutis entre tendências, sazonalidades e irregularidades nos dados. A arquitetura do N-BEATS é projetada para ser altamente adaptável a diferentes domínios, como saúde, energia e finanças, aproveitando essa capacidade de aprendizado direto a partir dos dados brutos. A sua arquitetura tem várias camadas ocultas (ver figura 2). Teoricamente, as redes neurais profundas podem direcionar qualquer tipo de entrada para qualquer tipo de saída. Porém, elas precisam de muito mais treinamento do que outros métodos e necessitam de um volume significativo de dados para treinamento, trazendo à tona uma das desvantagens, o custo computacional para processar os ajustes dos parâmetros.




Fonte: Compilação do autor.

Figura 2 - Rede Neural Profunda.

Um componente essencial das redes neurais profundas é a função de ativação *ReLU* (*Rectified Linear Unit*). A ativação refere-se ao processo pelo qual o neurônio processa a entrada e decide se ativa ou não a função, desta forma facilita a propagação de erros, com isso esses erros são propagados de volta através da rede para ajustar os pesos. A ReLU como função, retorna o valor de entrada se for positivo, caso contrário, retorna zero, pois é não linear (ver

figura 3), permitindo que a rede aprenda e modela relações complexas. No contexto do N-BEATS, a função ReLU é particularmente relevante devido à sua capacidade de evitar problemas de valores nulos durante o processo de aprendizado. Como a ReLU retorna zero para valores negativos, ele não permite a introdução de valores nulos ou "*vanishing gradients*", que podem prejudicar o treinamento da rede. Essa propriedade é importante porque, ao trabalhar com séries temporais, o N-BEATS precisa ser capaz de capturar variações sutis e dinâmicas dos dados ao longo do tempo. Se a rede fosse suscetível a valores nulos, isso poderia resultar em dificuldades na modelagem de relações complexas, prejudicando a precisão das previsões. Assim, a função ReLU ajuda o N-BEATS a manter sua robustez, garantindo que o aprendizado não seja interrompido por valores nulos, o que é essencial para obter previsões precisas e confiáveis.



Fonte: Compilação do autor.


Figura 3 - Gráfico da Função de Ativação ReLU.

Para a predição em séries temporais, as redes neurais profundas têm se mostrado eficazes, especialmente por lidar com padrões complexos, pois elas utilizam múltiplas camadas ocultas para aprender toda a complexibilidade dos dados. Desta forma a profundidade da rede permite a captura dos padrões complexos e hierárquicos, transformando a rede em um modelo capaz de generalizar bem para novos dados (Goodfellow 2016).

Em outras palavras a *deep learning* é uma técnica avançada de aprendizado de máquina que utiliza redes neurais com muitas camadas para aprender representações complexas dos dados. Diferente de algoritmos tradicionais, *deep learning* permite que o modelo extraia automaticamente características relevantes, o que é especialmente útil para grandes conjuntos de dados e tarefas de alta complexidade, como reconhecimento de imagem, tradução automática e previsão de séries temporais. De acordo com Haykin (2001), a profundidade das redes neurais utilizadas no *deep learning* permite que o modelo capte relações não lineares nos dados, oferecendo uma abordagem poderosa para resolver problemas complexos, através das diversas camadas ocultas (ver figura 4). Desta forma o modelo N-BEATS se alinha ao conceito de *deep*

learning, para extrair essas representações complexas, tornando suas camadas de empilhamento verdadeiras refinarias, para representar as abstrações dos dados, abordando relação que modelos mais simples poderiam não capturar.

Deep Learning usa múltiplas camadas ocultas para extrair características complexas e aprender representações dos dados.




Fonte: Compilação do autor.

Figura 4 - Fluxograma *Deep Learning*.

As principais características da *deep learning* são:

- **Camadas Profundas:** Em vez de usar apenas uma ou duas camadas ocultas, como em redes neurais tradicionais, o *deep learning* utiliza muitas camadas, permitindo que o modelo aprenda características mais complexas dos dados (ver Figura 2).
- **Redes Neurais Convolucionais (CNNs):** Utilizadas principalmente em visão computacional, são projetadas para processar e reconhecer padrões em imagens. Elas são um tipo de algoritmo de *deep learning*, que são usadas para tarefas que requerem reconhecimento de objetos utilizando convoluções, que são operações matemáticas que ajudam a detectar padrões locais. As camadas convolucionais agem como filtros que extraem características dos dados e as enviam para camadas subsequentes para processamento adicional (ver figura 5).

CNNs processam dados através de camadas convolucionais, que atuam como filtros para extrair características. Essas características são então reduzidas e refinadas por camadas de pooling antes de serem classificadas por camadas densas.



Os dados de entrada passam por filtros na camada convolucional, que detectam padrões.

A camada de Pooling gera uma simplificação na saída dos dados, facilitando a classificação.

As características extraídas são usadas para classificar os dados ou para outras análises específicas.

Fonte: Compilação do autor.

Figura 5 - Funcionamento de Redes Neurais Convolucionais (CNNs).

- **Redes Neurais Recorrentes (RNNs):** Indicadas para dados sequenciais, como séries temporais e linguagem natural, devido à sua capacidade de manter informações contextuais através de loops. Ela é um tipo de rede neural artificial que utiliza o *deep learning* para processar e converter dados sequenciais em saídas sequenciais específicas, para manter um estado que é atualizado à medida que novos dados são recebidos, o que as torna ideais para tarefas onde o contexto anterior é importante. Por exemplo: séries temporais.
- **Transformers:** Utilizado principalmente em processamento de linguagem natural (NLP), o *transformers* é uma rede neural que aprende o contexto, com dados sequenciais (Vaswani 2017). Ele utiliza mecanismos de atenção, que permite que o modelo foque em diferentes partes do *input*, como palavras ou regiões de dados, dependendo da tarefa (ver figura 6).

2.3 - TRANSFORMERS


Transformers são uma arquitetura de rede neural projetada para lidar com tarefas que envolvem dados sequenciais, como processamento de linguagem natural e séries temporais. Introduzidos por Vaswani et al. (2017), os *Transformers* utilizam mecanismos de atenção para capturar dependências de longo prazo e processar sequências de entrada de maneira paralela e eficiente, superando as limitações das redes neurais recorrentes (RNNs) em termos de aprendizado de contexto e escalabilidade (Goodfellow, 2016). Essa abordagem revolucionou

diversas áreas, permitindo avanços significativos em tradução automática, análise de sentimentos e previsão de séries temporais.

Embora o N-BEATS não utilize diretamente mecanismos de atenção como os Transformers, ele compartilha a capacidade de modelar relações complexas nos dados temporais. Durante o treinamento da rede neural, mecanismos de atenção podem ser empregados para otimizar a aprendizagem dos padrões. No entanto, o diferencial do N-BEATS está na sua arquitetura empilhada de blocos, que permite capturar dependências temporais sem a necessidade de estruturas recorrentes ou convolucionais, refinando previsões de forma iterativa. Essa abordagem torna o modelo eficiente para capturar tendências, sazonalidades e variações nos dados de séries temporais, garantindo alta precisão preditiva sem um pré-processamento extenso.

As principais características dos *Transformers* são:

- **Mecanismo de Atenção:** Em vez de processar dados sequenciais de forma linear, os Transformers utilizam mecanismos de atenção que permitem a cada posição na sequência de entrada focar em diferentes partes da sequência. Isso possibilita a modelagem de dependências de longo alcance e a consideração de contextos relevantes, sem a necessidade de processamento sequencial, como é comum em redes neurais recorrentes (Vaswani et al., 2017).
- **Paralelização:** Devido à sua estrutura baseada em atenção, os *Transformers* podem processar todas as posições da sequência de entrada simultaneamente, ao contrário das redes neurais recorrentes que processam dados sequencialmente. Isso resulta em uma maior eficiência e velocidade no treinamento e na inferência (Vaswani et al., 2017).
- **Codificador e Decodificador:** A arquitetura *Transformers* é composta por dois componentes principais: o codificador e o decodificador. O codificador transforma a entrada em uma representação intermediária, enquanto o decodificador gera a saída a partir dessa representação. Ambos os componentes utilizam camadas de atenção e *feed-forward* para processar os dados (Vaswani et al., 2017).
- **Camadas de Atenção Multi-Cabeça:** Essa técnica permite que o modelo de atenção capture diferentes tipos de relações e dependências nos dados ao mesmo tempo. Cada "cabeça" de atenção aprende a focar em diferentes aspectos das entradas, melhorando a capacidade do modelo de entender contextos complexos (Vaswani et al., 2017).
- **Positional Encoding:** Como os *Transformers* não possuem uma estrutura sequencial intrínseca, eles utilizam *embeddings* de posição para incorporar informações sobre a ordem dos elementos na sequência. Esses *embeddings* ajudam o modelo a aprender e a considerar a posição dos *tokens* na sequência (Vaswani et al., 2017).



Fonte: Compilação do autor

Figura 6 - Funcionamento do *Transformers*

2.4 - N-BEATS (*NEURAL BASIS EXPANSION ANALYSIS TIME SERIES FORECASTING*)

O N-BEATS (*Neural Basis Expansion Analysis Time Series Forecasting*) é uma arquitetura de rede neural profunda projetada especificamente para previsão de séries temporais. Lançada pela Uber AI Labs, N-BEATS se destaca por sua simplicidade e eficácia, não exigindo ajustes complexos ou conhecimento prévio detalhado sobre os dados temporais que está modelando. Ela pode lidar com uma ampla gama de tarefas de previsão, desde problemas univariados e multivariados (Oreshkin et al. 2019).

Seu funcionamento é através de blocos de expansão, que é explicado no item 2.4.1, por meio de *deep learning* que foram explicados no item 2.2 deste capítulo.

2.4.1 - Arquitetura N-BEATS

O modelo N-BEATS (*Neural Basis Expansion Analysis Time Series Forecasting*) tem uma arquitetura de rede neural profunda capaz de prever valores de séries temporais sem depender da criação de características específicas ou ajustes finos. Ela é baseada em blocos e pilhas, e foi projetada para ser genérica e flexível, permitindo que o modelo seja aplicado a uma ampla variedade de séries temporais sem a necessidade de características específicas da série (Oreshkin et al. 2019). A combinação de pilhas e blocos permite que o modelo capture padrões complexos e variados.


A pilha é uma coleção de blocos e são utilizadas para organizar os blocos em diferentes níveis de abstração. Cada pilha captura diferentes tipos de padrões na série temporal, como tendências de curto, médio e longo prazo, sazonalidades, irregularidades, entre outras.

A estrutura principal em pilhas do N-BEATS consiste em três componentes principais: propagação direta, empilhamento de pilhas e treinamento (ver figura 7).

A propagação direta ou *forward propagation* é a entrada inicial que é passada através de blocos, para cada pilha em sequência. Dentro de cada bloco, a entrada é transformada por camadas densamente conectadas, produzindo previsões e reconstruções. Essas reconstruções são subtraídas da entrada para produzir um residual que é passado para o próximo bloco da pilha. Por fim, as previsões de cada bloco são acumuladas para formar a previsão final da pilha.

O empilhamento de pilhas ou *stacking stacks* são as saídas das pilhas, combinadas para produzir a previsão final do modelo. Cada pilha pode especializar-se para diferentes componentes da série temporal, como tendências, sazonalidades ou ruídos. Essa combinação das previsões de várias pilhas permite que o modelo capture uma ampla gama de padrões temporais.

O treinamento é os ajustes que o modelo faz com os pesos de todas as camadas em todos os blocos e pilhas para minimizar a diferença entre a previsão e a série temporal real. Sendo feito através de retropropagação, onde o erro é propagado de volta através da rede e os pesos são atualizados usando algoritmos de otimização, como o gradiente descendente.



Fonte: Compilação do autor

Figura 7 - Arquitetura do N-BEATS

Os blocos são os componentes fundamentais da arquitetura N-BEATS, sendo compostos por várias camadas densamente conectadas que processam a entrada para produzir duas saídas (ver figura 8). As camadas densamente conectadas são compostas por várias camadas de neurônios, onde cada um está conectado a todos os neurônios da camada anterior, permitindo que o modelo aprenda diferentes tipos de configurações e comportamentos. A primeira saída de cada bloco é chamada de reconstrução ou *backcast*, essa saída tenta capturar a parte da entrada que o modelo não conseguiu explicar completamente, por tanto a

reconstrução representa os componentes do sinal de entrada que não foram utilizados na previsão, desta forma o objetivo do *backcast* é reduzir a diferença entre a entrada original e a entrada que o modelo consegue prever com base nos dados. A segunda saída é a previsão ou *forecast* que é a previsão da série temporal para o futuro, baseado na informação extraída pela camada densa, que foi explicada no começo deste parágrafo, do bloco, desta forma contribuindo com uma parte da previsão final, por fim elas são somadas ao longo dos blocos para formar a previsão final da série temporal. No final de cada pilha de blocos só a saída *forecast* é utilizada.

A fase de treinamento do N-BEATS acontece em cada bloco, através da propagação direta (*Forward Pass*), que é basicamente a entrada dividida em pilhas, onde cada pilha é alimentada no modelo, passando para o processamento em blocos, em que cada pilha passa por uma sequência de blocos, gerando as duas saídas em que a reconstrução ajuda a refinar a entrada do próximo bloco e a previsão é saída final do conjunto de blocos ou da pilha (ver figura 8). Desta forma temos a iteração ao longo dos blocos, onde cada bloco refina as previsões feitas pelo bloco anterior, fazendo um empilhamento e permitindo que o modelo capture os padrões complexos ao longo de várias iterações. Durante o treinamento também acontece a retropropagação que é usada para calcular os gradientes da função de perda, esses gradientes são usados para ajustar o modelo durante toda a iteração. A função de perda mede o erro entre as previsões do modelo e os valores reais da série temporal, em que sua principal função é focada em minimizar o erro da previsão em relação aos dados reais, por isso o N-BEATS foi configurado com as duas saídas, para que o *backcast* possa fazer a reconstrução no bloco e diminuir o erro a cada iteração.

Dentro de cada bloco ainda temos uma expansão da base neural, que é o conjunto de funções ou características que a rede neural usa para representar os dados de entrada, criando assim uma nova representação dos dados que é mais informativa e que captura a complexidade dos dados de entrada, devido a própria arquitetura de pilhas e blocos (ver figura 8), com isso temos a série temporal (entrada), sofrendo uma expansão de base (ver figura 10) e por fim temos a série temporal transformada. A transformada é a projeção de uma nova base de dados, que foi resultado da expansão neural anterior, gerando a entrada do próximo bloco (ver figura 10). Essa transformação é uma combinação linear de funções base não lineares (como funções ReLU), que ajudam a capturar padrões complexos na série temporal.


A estrutura principal em blocos consiste em três componentes principais: blocos de construção, camadas de expansão e conexões residuais.

Os blocos de construção ou *building blocks* é uma rede neural *feedforward* onde a informação flui apenas em uma direção, da entrada para a saída (GOODFELLOW; BENGIO; COURVILLE, 2016), desta forma processa a série temporal em duas saídas: previsão (*forecast*) e reconstrução (*backcast*). A previsão é a saída que será usada para o objetivo final, enquanto a reconstrução é utilizada para capturar e remover os componentes já explicados pela rede, melhorando assim as previsões subsequentes. Cada bloco é organizado sequencialmente, recebendo o residual da série temporal da saída do bloco anterior, permitindo que cada bloco capture diferentes aspectos da série.

As camadas de expansão ou *basis expansion layers* funcionam dentro de cada bloco, mapeando as entradas para uma representação de espaço maior, usando camadas densamente conectadas. Isso facilita a captura de padrões complexos na série temporal. Essas camadas de

expansão são fundamentais para a capacidade do modelo de lidar com diferentes tipos de séries temporais sem ajustes específicos.


As conexões residuais ou residual connections são usadas para transmitir informações não capturadas por um bloco para o próximo bloco, garantindo que os componentes importantes da série temporal não sejam perdidos ao longo da profundidade da rede. Isso também ajuda a mitigar problemas comuns em redes neurais profundas, como o desaparecimento do gradiente.



Fonte: Compilação do autor

Figura 8 - Representação do bloco no N-BEATS

Por tanto, nesta arquitetura, a pilha é composta por vários blocos, em que cada bloco é uma unidade de previsão. Sendo assim o bloco recebe uma entrada e produz uma previsão de saída, fazendo uma reconstrução organizada sequencialmente (ver figura 9).



Fonte: Compilação do autor

Figura 9 - Arquitetura de pilha e blocos do N-BEATS

. Assim, na figura 9 podemos visualizar a arquitetura de pilhas e blocos, em que cada bloco é representado por um retângulo cinza claro e as conexões entre os blocos e pilhas são indicadas pelas setas pretas. As pilhas (Pilha 1, Pilha 2, Pilha N) são compostas por três blocos (B1, B2, BN), cada bloco dentro de uma pilha processa a entrada e produz duas saídas: a Reconstrução (em azul) e a Previsão (em verde). As setas entre elas indicam o fluxo de dados entre os blocos e as pilhas, gerando a previsão final, que é a soma das previsões de todos os blocos.




A expansão de base neural cria uma nova representação mais rica da série temporal, capturando padrões complexos.

Fonte: Compilação do autor

Figura 10 - Expansão da base neural

Por fim temos o diagrama de funcionamento geral do N-BEATS (ver figura 11), desde a entrada até a saída final, seguindo o seguinte fluxo:

1. *Lookback Period*: Período de observação usado para prever valores futuros.
2. *Lookback Window (Input do Modelo)*: O intervalo de tempo observado é inserido no modelo.
3. *Stack Input*: A entrada inicial é processada pela primeira pilha (*Stack 1*).
4. *Forecast Period*: O período de previsão que o modelo está tentando estimar.
5. *Global Forecast (Output do Modelo)*: A previsão final acumulada é produzida após passar por todas as pilhas.



Fonte: Oreshkin, B. N., Carпов, D., Chapados, N., & Bengio, Y., 2020

Figura 11 - Fluxo do N-BEATS

2.4.2 - Formulação Matemática

O fluxo do modelo N-BEATS inicia-se com uma pilha de camadas totalmente conectadas que processam a entrada inicial do bloco, conhecida como *Block Input*. Essa pilha é composta por várias camadas que aplicam transformações lineares, com pesos ($W_k^{(l)}$) e viés ($b_k^{(l)}$), seguidas por funções de ativação não lineares (ϕ), como descrito na equação:

$$h_k^{(l)} = \phi(W_k^{(l)} h_k^{(l-1)} + b_k^{(l)}) \quad (\text{equação 2.1})$$

l - camada.

k - bloco.

$h_k^{(l)}$ - vetor de ativação da camada l no bloco k.

$W_k^{(l)}$ - matriz de pesos da camada l no bloco k.

$h_k^{(l-1)}$ - vetor de ativação na camada anterior (l-1) no bloco k.

$b_k^{(l)}$ - vetor de viés(bias).

O vetor de viés (componente em redes neurais que serve para ajustar a saída de um neurônio), ajuda a rede a aprender funções mais complexas, desta forma melhorando o *output* do *stack*, pois a saída desta parte do bloco alimenta a próxima etapa.

Sequencialmente temos o *Block Stack* (bloco do meio), que processa o *input* do bloco anterior e gera duas saídas: *Stack Forecast*, previsão intermediária do bloco; *Stack Residual*, residual que é passado para o próximo bloco. O processamento iterativo continua até o bloco final, refinando a previsão e os residuais em cada passo.

$$g_k^{(b)}(\theta_k^{(b)}) = \phi(W_k^{(l)}h_k^{(l-1)} + b_k^{(l)}) - \text{backcast} \quad (\text{equação 2.2})$$

$$g_k^{(f)}(\theta_k^{(f)}) = \phi(W_k^{(l)}h_k^{(l-1)} + b_k^{(l)}) - \text{forecast} \quad (\text{equação 2.3})$$

b - transformação aplicada no bloco de previsão *backcast*.

f - transformação aplicada no bloco de previsão *forecast*.

$g_k^{(b)}(\theta_k^{(b)})$ - previsão *backcast*.

$g_k^{(f)}(\theta_k^{(f)})$ - previsão *forecast*.

O cálculo do residual é a entrada para o próximo bloco, ajustando com a subtração da previsão do *backcast*:

$$x_{k+1} = x_k - g_k^{(b)}(\theta_k^{(b)}) \quad (\text{equação 2.4})$$

x_k - saída residual do bloco anterior.

x_{k+1} - iteração de cada saída.

Por fim temos o global *forecast* (bloco à direita), os *Stacks* (1 a M) integram os blocos para produzir a previsão global. Cada *stack* processa a saída do *stack* anterior, adicionando refinamentos à previsão. O final *Output* é a saída acumulada de todos os *Stacks*, conforme descrito pela equação 2.5.

$$\hat{y} = \sum_{k=1}^K g_k^f(\theta_k^{(f)}) \quad (\text{equação 2.5})$$

Em resumo, a entrada é processada por uma pilha de camadas totalmente conectadas, gerando previsões iniciais e estimativas. Essas previsões e residuais são refinadas ao longo de vários blocos, cujas saídas são combinadas em múltiplas pilhas para formar a previsão final.

2.4.3 - Hiperparâmetros

O modelo N-BEATS possui diversos hiperparâmetros que controlam sua estrutura, funcionamento e desempenho. Esses hiperparâmetros são divididos em categorias principais: estrutura do modelo, camadas e neurônios, treinamento, ativação e adicionais.

2.4.3.1 - Estrutura do modelo

Os hiperparâmetros relacionados à estrutura definem o formato e o comportamento dos blocos e pilhas que compõem o modelo:

- *input_chunk_length*: Tamanho da janela de entrada (quantidade de dados passados utilizados para fazer a previsão).
- *output_chunk_length*: Horizonte de previsão (quantidade de dados futuros que o modelo deve prever).
- *stack_types*: Tipo de blocos usados em cada pilha (*NBeatsNet.GENERIC_BLOCK*, *NBeatsNet.SEASONALITY_BLOCK*, ou *NBeatsNet.TREND_BLOCK*).
- *num_blocks*: Número de blocos em cada pilha.
- *num_layers*: Número de camadas por bloco.
- *num_stacks*: Número de pilhas
- *thetas_dim*: Dimensão do vetor theta, que corresponde ao número de coeficientes da função de base em cada bloco.
- *share_weights_in_stack*: Booleano que indica se os blocos em uma pilha compartilham os mesmos pesos.

2.4.3.2 - Camadas e Neurônios

Esta categoria define a configuração interna das camadas que compõem os blocos:

- *hidden_layer_units*: Número de neurônios em cada camada oculta dentro dos blocos.
- *nb_harmonics*: Número de harmônicos (relevante para blocos de sazonalidade).
- *layer_widths*: Largura das camadas.

2.4.3.3 - Treinamento

Os hiperparâmetros de treinamento controlam o processo de ajuste dos pesos do modelo:

- *learning_rate*: Taxa de aprendizado usada pelo otimizador.
- *batch_size*: Tamanho do batch usado durante o treinamento.
- *num_epochs*: Número de épocas (iterações completas sobre o conjunto de treinamento).
- *loss_function*: Função de perda usada para treinar o modelo, como *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), etc.
- *otimizar* - Algoritmo de otimização usado, como Adam, SGD, etc.
- *regularization*: Métodos de regularização, como *dropout* ou *L2 regularization*.
- *nr_epochs_val_period*: Período de validação por época.

2.4.3.4 - Ativação

Esses hiperparâmetros determinam as funções e o tipo de modelo utilizado:

- *activation*: Função de ativação usada nas camadas ocultas, como ReLU, Tanh, etc.
- *model_type*: Tipo de modelo, como *generic*, *trend*, *seasonality*.

2.4.3.5 - Adicionais

Parâmetros auxiliares que aprimoram a regularização e o controle do treinamento:

- *dropout_rate*: Taxa de *dropout* para regularização das camadas ocultas.
- *dropout* - Taxa de *dropout*
- *weight_decay*: Taxa de decaimento do peso (*L2 regularization*) aplicada aos pesos do modelo.
- *scheduler*: Agendador de taxa de aprendizado para ajuste dinâmico da taxa de aprendizado durante o treinamento.
- *validation_split*: Proporção dos dados de treinamento usados para validação.

2.4.4 - Otimização dos Hiperparâmetros

A escolha adequada dos hiperparâmetros é fundamental para garantir o desempenho do modelo. No caso do N-BEATS, é possível utilizar o método Grid Search por meio do *GridSearchModel* da biblioteca *darts*.

Esse método realiza uma busca exaustiva sobre todas as combinações possíveis de hiperparâmetros pré-definidos, avaliando cada configuração com base em métricas de validação, como o erro percentual médio absoluto (MAPE) ou o coeficiente de determinação (R^2) (Goodfellow, Bengio & Courville, 2016). A combinação que gera os melhores resultados é selecionada como ideal para o modelo.

O *Grid Search* é amplamente utilizado em problemas de otimização de hiperparâmetros, especialmente em modelos complexos de séries temporais. No contexto do N-BEATS, essa abordagem é crucial para ajustar as diversas variáveis que influenciam diretamente a qualidade das previsões (ver item 4).

Portanto, a configuração ideal dos hiperparâmetros permite que o N-BEATS explore todo o potencial da sua arquitetura, garantindo previsões mais precisas e generalizáveis.

3 ABORDAGEM PROPOSTA

A vacinação é um dos pilares fundamentais da saúde pública. Desde o início do uso de vacinas, campanhas de vacinação têm sido realizadas para proteger a população contra doenças contagiosas e mortais, como a poliomielite, o sarampo e, mais recentemente, a COVID-19. O sucesso de uma campanha de vacinação depende da capacidade de prever e suprir a demanda de imunizantes, garantindo que a população tenha acesso às doses necessárias no momento certo. A campanha de vacinação envolve a mobilização de recursos em larga escala, desde a distribuição e armazenamento de vacinas até a sensibilização e adesão da população-alvo.

Diante da complexidade envolvida na predição da quantidade de vacinados, este estudo propõe o desenvolvimento de um modelo de previsão da demanda de vacinas na rede pública de saúde, utilizando o algoritmo N-BEATS (*Neural Basis Expansion Analysis Time Series Forecasting*). O N-BEATS é uma ferramenta de ponta para análise de séries temporais, capaz de modelar padrões complexos e não lineares, o que é essencial para capturar as nuances da demanda por vacinas.


Além disso, o modelo será configurado para realizar previsões gerais e específicas por tipo de vacina, permitindo identificar as particularidades de cada imunizante, como sazonalidade, campanhas de vacinação e mudanças na demanda relacionadas a diferentes faixas etárias e condições de saúde.

Nesse contexto, um ponto-chave é o pré-processamento dos dados, utilizando o somatório da quantidade de vacinados por semana, em vez da quantidade diária. A decisão de agregar a demanda semanalmente é estratégica para lidar com as dinâmicas de consumo e reposição de vacinas. Ao utilizar a soma semanal da demanda como uma feature adicional, obtemos uma visão mais consolidada e representativa do consumo semanal de doses. Isso se alinha melhor aos processos logísticos, já que os estoques de vacinas muitas vezes são reabastecidos em ciclos semanais, otimizando a reposição e evitando escassez ou desperdício.

Além disso, a agregação semanal reduz a variabilidade diária dos dados, facilitando a identificação de padrões cíclicos. Durante as campanhas de vacinação, é comum observar flutuações na procura de doses, influenciadas por fatores como feriados, eventos públicos ou campanhas de conscientização. Ao concentrar a análise na demanda semanal, torna-se mais fácil ajustar o planejamento estratégico das campanhas e a gestão de estoques, permitindo uma alocação mais eficiente de recursos e garantindo que as doses estejam disponíveis de acordo com a demanda real.

Dessa forma, o uso de um modelo como o N-BEATS aliado ao pré-processamento semanal pode proporcionar previsões mais precisas e eficazes para apoiar campanhas de vacinação, contribuindo para a saúde pública de maneira significativa.

O desenvolvimento da predição seguiu uma abordagem linear, compreendendo a coleta de dados, o pré-processamento dos dados, divisão dos dados, modelagem com N-BEATS, avaliação do modelo e os resultados (ver figura 12).



Fonte: Compilação do autor

Figura 12 - Pipeline das etapas

3.1 DESENVOLVIMENTO DA ABORDAGEM

Para avaliar a eficácia do modelo N-BEATS na previsão da demanda por vacinas, foi desenvolvida uma metodologia estruturada que engloba a coleta e preparação dos dados, modelagem e divisão dos dados, seguida da avaliação do desempenho preditivo. O estudo foi conduzido com dados históricos de vacinação dos estados do Rio Grande do Norte e Espírito Santo, permitindo uma análise comparativa entre diferentes níveis de granularidade, desde previsões agregadas até segmentações específicas por imunobiológico.

A abordagem metodológica adotada visa garantir a confiabilidade das previsões e sua aplicabilidade em cenários reais de gestão de estoques e distribuição de vacinas. Para isso, foram seguidas etapas rigorosas de preparação dos dados, treinamento do modelo, ajuste de hiperparâmetros e validação dos resultados por meio de.

3.1.1 Coleta e Preparação dos Dados

Os dados utilizados neste estudo foram extraídos dos sistemas de vacinação RN+VACINA (Brasil, Governo do Estado do Rio Grande do Norte, 2024) e Vacina e Confia (Brasil, Governo do Estado do Espírito Santo, 2024), abrangendo o período de janeiro de 2021 a janeiro de 2024, totalizando 3 anos de dados históricos para o RN+VACINA e de março de 2022 a julho de 2024, totalizando 2 anos e 4 meses de dados históricos para o Vacina e Confia.

Esses sistemas fornecem informações detalhadas sobre o processo de imunização nos respectivos estados, consolidando dados relevantes para análises preditivas e estratégicas.

As informações coletadas incluíram:

- Quantidade de vacinas aplicadas: total de doses administradas por período.
- Data: registro cronológico de cada aplicação.
- Estratégia vacinal: categorização das ações de vacinação (como campanhas específicas ou vacinação de rotina).
- Calendário vacinal: associação das vacinas aos grupos populacionais-alvo e faixas etárias.
- Imunobiológico: descrição do tipo de vacina aplicada.

A qualidade inicial dos dados foi considerada alta, uma vez que as equipes responsáveis por ambas as plataformas realizam o pré-processamento e a padronização antes da disponibilização pública. No entanto, foram necessárias algumas etapas adicionais de preparação para adequar os dados ao modelo de previsão utilizado.

3.1.2 Etapas de Limpeza e Pré-Processamento

As seguintes etapas foram realizadas:

1. Remoção dos finais de semana:
Como os dados se destinavam a prever a quantidade semanal de vacinas aplicadas, os registros de finais de semana foram removidos. Essa decisão foi baseada na baixa representatividade dos dados nesses dias, evitando interferências na análise.
2. Somatório da quantidade de vacinas por semana:
Para transformar os dados diários em séries semanais, foi realizado o somatório das vacinas aplicadas em cada semana. Esse processo permitiu a criação de uma granularidade consistente com o horizonte de previsão desejado.
3. Agrupamento semanal:
Após o somatório, os dados foram agrupados por semana, consolidando as informações em períodos fixos para análise.

Essas etapas foram cruciais para criar uma base de dados estruturada e adequada ao modelo preditivo N-BEATS, que opera com séries temporais em janelas de tempo definidas. Além disso, a granularidade semanal facilita a interpretação dos resultados e o planejamento estratégico de vacinação, otimizando o uso dos recursos disponíveis.

Ao final do processo de preparação, a base de dados estava pronta para alimentar o modelo, com informações limpas, consistentes e alinhadas aos objetivos do estudo. Essa abordagem meticulosa garantiu que o modelo pudesse capturar tendências sazonais, variações no ritmo de vacinação e outros padrões relevantes ao longo do tempo.

3.1.3 Divisão e modelagem

Para garantir um treinamento eficiente e uma avaliação robusta, o conjunto de dados foi dividido em:

- 80% para treinamento: utilizado para ajustar os pesos e aprender os padrões temporais presentes nos dados históricos.
- 20% para teste/validação: destinado à avaliação do desempenho do modelo em dados que não participaram do treinamento.

Durante o treinamento, uma porção dos dados de treinamento (20%) foi reservada para validação interna. Essa abordagem, conhecida como validação cruzada interna, permite que o modelo ajuste seus hiperparâmetros de forma iterativa, utilizando métricas de desempenho para determinar a configuração ideal. Esse processo reduz o risco de *overfitting* ao garantir que o modelo se generalize bem, mesmo em um conjunto de dados relativamente pequeno.

Além disso, um conjunto de teste totalmente independente foi reservado para a avaliação final do modelo. Essa separação é essencial para validar a capacidade do modelo de prever dados fora do conjunto de treinamento, replicando condições reais de utilização.

3.1.4 Configuração do Modelo N-BEATS

O modelo N-BEATS foi configurado com os seguintes hiperparâmetros iniciais:

Os dados foram divididos em 80% para treinamento e 20% para teste/validação, com a validação ocorrendo durante o processo de treinamento graças aos parâmetros integrados de validação do modelo N-BEATS. Dentro do conjunto de treinamento, 20% dos dados são reservados para validação interna, permitindo que o modelo ajuste seus hiperparâmetros de forma otimizada.

Além disso, considerando o tamanho relativamente pequeno do conjunto de dados, mantém-se um conjunto independente de teste para avaliação final do desempenho do modelo. Essa estratégia garante que o modelo seja avaliado de maneira robusta, minimizando o risco de *overfitting* e assegurando a capacidade de generalização para novos dados.

O modelo foi configurado com os seguintes parâmetros iniciais:

- *input_chunk_length*: define o tamanho da janela de entrada (número de semanas anteriores usadas como entrada).
- *output_chunk_length*: define o horizonte de previsão (número de semanas futuras que o modelo prevê).
- *num_stacks*: número de pilhas no modelo, com cada pilha sendo responsável por um componente específico (genérico, sazonal ou de tendência).
- *num_blocks*: número de blocos por pilha.
- *num_layers*: número de camadas em cada bloco.
- *layer_widths*: número de neurônios em cada camada oculta.
- *n_epochs*: número total de épocas de treinamento.
- *nr_epochs_val_period*: frequência de validação durante o treinamento, permitindo ajustes contínuos.
- *batch_size*: tamanho do lote de dados processado em cada iteração de treinamento.
- *dropout*: taxa de *dropout* utilizada para regularizar o modelo e evitar *overfitting*.

3.1.5 Método de Previsão

Para a realização das previsões semanais, foi utilizado o método *historical_forecasts* da própria biblioteca do N-BEATS. Este método permite que as previsões sejam feitas de forma iterativa, replicando as condições reais de uma aplicação prática. O processo funciona da seguinte forma:

1. Em cada passo, o modelo utiliza apenas os dados disponíveis até o ponto atual para realizar a previsão do horizonte futuro definido por *output_chunk_length*.
2. Após a previsão, o horizonte é movido para frente, e o próximo conjunto de dados é processado.

Essa abordagem assegura que as previsões respeitem a ordem temporal dos dados, simulando um cenário em que o modelo é usado para prever eventos futuros com base em informações passadas. Além disso, ela permite avaliar o desempenho do modelo em diferentes pontos da série temporal, garantindo maior confiabilidade nos resultados obtidos.

Por fim, essa combinação de divisão de dados, configuração do modelo e método de previsão oferece uma base sólida para análise e interpretação, assegurando que o modelo N-BEATS seja treinado e avaliado de forma otimizada. O uso do método *historical_forecasts* também destaca a aplicabilidade prática do modelo, alinhando-o às necessidades reais de previsão no contexto da vacinação.

3.1.6 Métricas

Os procedimentos de avaliação do modelo foram realizados utilizando duas métricas amplamente empregadas na análise de séries temporais: o MAPE (*Mean Absolute Percentage Error*) e o R^2 (*Coeficiente de Determinação*). Essas métricas foram escolhidas devido à sua capacidade de oferecer uma visão clara sobre a precisão das previsões e a eficácia do modelo em capturar as variações dos dados.

O MAPE é uma medida de precisão que calcula a média do erro percentual absoluto entre os valores previstos e os valores reais, expressando o resultado como uma porcentagem. Segundo Hyndman e Athanasopoulos (2018, p. 74), "o MAPE é particularmente útil para interpretar o desempenho de modelos de previsão em termos de uma métrica intuitiva e fácil de compreender". Por exemplo, um MAPE de 5% indica que, em média, as previsões do modelo desviam apenas 5% dos valores reais, evidenciando uma precisão elevada.

Já o R^2 , ou Coeficiente de Determinação, mede a proporção da variabilidade total dos dados explicada pelo modelo. É uma métrica que varia entre 0 e 1, onde valores próximos de 1 indicam que o modelo consegue explicar quase toda a variabilidade presente nos dados (Brockwell & Davis, 2016, p. 82). Por exemplo, um R^2 de 0,95 significa que o modelo é capaz de explicar 95% da variação dos dados observados, demonstrando uma alta capacidade de ajuste aos padrões da série temporal.

Para analisar os resultados, foram gerados gráficos que apresentam tanto os dados originais quanto as previsões do modelo. Esses gráficos permitem visualizar de forma clara o

alinhamento entre as previsões e os dados reais, destacando os padrões capturados pelo modelo. Além disso, foram feitas comparações entre o modelo N-BEATS e um modelo já consolidado na literatura (*ver item 6*), a fim de contextualizar o desempenho obtido e validar a eficácia da abordagem proposta.

Os parâmetros utilizados no treinamento do modelo também foram apresentados, possibilitando a reprodutibilidade dos experimentos e facilitando a análise detalhada das escolhas de configuração. Por fim, o estudo incluiu a previsão para uma semana de vacinação, demonstrando a aplicabilidade prática do modelo na projeção da demanda por imunizantes. Essa etapa é crucial para auxiliar na tomada de decisões relacionadas à gestão de estoques e logística no sistema de saúde público.

4 RESULTADOS

Os resultados apresentados nesta seção são organizados em gerais e específicos, de modo a proporcionar uma análise abrangente do desempenho do modelo. Essa abordagem permite explorar tanto uma visão macro do comportamento da vacinação quanto uma análise detalhada de cada tipo de imunobiológico, atendendo às diferentes demandas do planejamento estratégico e operacional.

Os **resultados gerais** englobam a previsão da demanda total de vacinas, no sistema de vacinação RN+VACINA do Rio Grande Do Norte, sem distinção entre os diferentes tipos. Esse panorama consolidado reflete o comportamento agregado da aplicação de vacinas ao longo do tempo, permitindo uma visão macro sobre a dinâmica da vacinação. Tal abordagem é essencial para entender padrões globais, como tendências sazonais e flutuações gerais na procura por vacinas.

Por outro lado, os **resultados específicos** foram obtidos ao analisar individualmente cada tipo de vacina, no sistema de vacinação Vacina e Confia do Espírito Santo. Essa segmentação permite identificar padrões particulares associados a cada vacina, como diferenças na demanda por vacinas de campanha (ex.: gripe) e vacinas de rotina (ex.: hepatite B). Com isso, é possível obter uma previsão mais detalhada e precisa, atendendo às necessidades específicas de planejamento e distribuição para cada imunobiológico.

A análise combinada dos resultados gerais e específicos contribui para uma gestão mais eficiente e direcionada, destacando a flexibilidade e o potencial do modelo **N-BEATS** para atender a diferentes níveis de granularidade na previsão de demandas de vacinas.

4.1 RESULTADOS GERAIS


Os resultados gerais apresentados nesta seção têm como objetivo avaliar o desempenho do modelo **N-BEATS** na previsão agregada da demanda por vacinas no Estado do Rio Grande Do Norte, considerando todas as vacinas de forma consolidada, sem distinções individuais. Essa abordagem permite identificar padrões globais nos dados e comparar o desempenho do modelo com algoritmos previamente utilizados na literatura, destacando suas vantagens e limitações em um contexto geral.

Na sequência o processo de treinamento, teste e validação (ver item 4.3) ocorreu inicialmente com a definição dos parâmetros e os hiperparâmetros foram obtidos através da busca em grade, como mencionado no item 2.2.3, com os seguintes intervalos e resultando em:

- *input_chunk_length* = [10, 20, 30] -> Valor escolhido:10
- *output_chunk_length* = 1
- *num_stacks* = [10, 20, 30] -> Valor escolhido:10
- *num_blocks* = [3, 4, 5]> Valor escolhido:3
- *num_layers* = [3, 4, 5]> Valor escolhido:4
- *layer_widths* = 512
- *nr_epochs_val_period* = [1, 5, 10]> Valor escolhido:10
- *batch_size* = [16, 32]> Valor escolhido:32


- *dropout* = [0.1, 0.2, 0.3]> Valor escolhido:0.1
- *num_epochs* = [100, 200, 300, 400, 500]> Valor escolhido:500

Dando prosseguimento o modelo foi executado na base de dados mencionadas no item 4.1 deste estudo, essa execução foi dividida em 2 partes. A primeira foi com os dados de vacinação de todo o Estado, cujo resultados foram um R^2 de 0,81 e o MAPE em 16.59% (ver figura 13), e a segunda com os dados do município de Natal (ver figuras 14), que teve as seguintes métricas de validação: MAPE: 21,59% e R^2 : 0,77. Por tanto, temos os 2 cenários possíveis para uma implementação no sistema, a demanda Estadual e municipal. No contexto Estadual e municipal as secretarias de saúde passam a ter uma noção da quantidade de vacinas que vão adquirir ou distribuir durante uma semana.



Fonte: Compilação do autor


Figura 13 - Previsão nível estadual com N-BEATS



Fonte: Compilação do autor

Figura 14 - Previsão nível municipal

Para fins de comparação com modelos tradicionais da literatura, temos o estudo de Lemos, L. O., Guedes, L. A., & Valentim, R. A. M. (2023), intitulado *Predição de Aplicação de Vacinas Baseada em Gradient Boosting Regressor*, que utilizou a mesma base de dados, para fazer a predição da quantidade de vacinados para uma semana no Estado do Rio Grande Do Norte. Fazendo uma comparação direta podemos observar um ganho significativo nas métricas, pois o R^2 do artigo ficou em 0,73 (ver figura 15) e com o N-BEATS temos esse mesmo R^2 em 0,81 e MAPE em 16.59% (ver figura 13), portanto explicando uma quantidade relevante da variabilidade nos dados.



Fonte: Compilação do autor

Figura 15 - Previsão nível estadual com XGBoost

Por fim temos a previsão da quantidade de vacinados para a próxima semana (ver tabela 1 e tabela 2), comparando com as semanas anteriores podemos visualizar através dos valores como o modelo aprendeu com os dados. Mostrando que com uma entrada simples de dados o algoritmo consegue fazer previsões poderosas, com pouca ou nenhuma limitação.

Tabela 1: Previsão em nível Estadual

Semana	Quantidade de vacinados
217	6769
218	10346
219	9576
220 - Previsão	11832

Tabela 2: Previsão em nível Municipal

Semana	Quantidade de vacinados
176	2929
177	3588
178	2796
179 - Previsão	3638


4.2 RESULTADOS ESPECÍFICOS

Nesta seção, são apresentados os resultados específicos da análise detalhada da demanda individualizada para cada tipo de vacina no Estado do Espírito Santo. Essa abordagem segmentada visa capturar as particularidades e padrões únicos de cada imunobiológico, permitindo uma visão mais aprofundada que complementa a perspectiva consolidada apresentada anteriormente. A análise específica é crucial para o planejamento estratégico, possibilitando uma melhor gestão de estoques e distribuição, especialmente em cenários onde os recursos são limitados e a demanda é variável.

O modelo N-BEATS foi empregado exclusivamente para realizar previsões individualizadas, permitindo captar nuances e variações temporais que caracterizam a procura por cada vacina. Essa segmentação revelou a capacidade do modelo de lidar com diferentes dinâmicas de demanda, desde vacinas de rotina, como hepatite B e tríplice viral, até imunobiológicos voltados para campanhas específicas, como a vacina contra influenza. A versatilidade do N-BEATS, combinada com sua robustez, elimina a necessidade de ajustes manuais para cada imunobiológico, tornando-o uma ferramenta altamente eficiente e flexível.


Os resultados evidenciam o potencial do modelo para prever demandas específicas com alta precisão, oferecendo suporte estratégico às decisões no campo da saúde pública. Essa capacidade é essencial para otimizar a alocação de recursos, minimizar desperdícios e garantir que as vacinas estejam disponíveis nos locais e momentos mais críticos.

Para avaliar o desempenho do modelo em um caso real, foram utilizados dados históricos do sistema Vacina e Confia (Espírito Santo), conforme descrito no item 4.1 deste estudo. A análise concentrou-se na vacina BCG em nível Estadual e Municipal (utilizando a cidade de Cariacica), abrangendo o período de 11 de março de 2022 a 15 de julho de 2024, totalizando 119 semanas. O modelo foi configurado com os mesmos parâmetros descritos no item anterior e, após o treinamento, apresentou as seguintes métricas de validação para a rede estadual: MAPE: 1,00% e R^2 : 0,83 (ver Figura 16) e para a municipal: MAPE:2,46% e R^2 : 0,85(ver Figura 17).



Fonte: Compilação do autor

Figura 16 - Previsão BCG Nível Estadual



Fonte: Compilação do autor

Figura 17 - Previsão BCG Nível Municipal

Adicionalmente, foi gerada a previsão do número de vacinados para a semana subsequente (ver Tabela 3) e (ver Tabela 4), demonstrando a aplicabilidade prática do modelo na previsão de curto prazo. A utilização de uma abordagem sistemática e metodológica, com dados reais e métricas de avaliação robustas, reforça a aplicabilidade do N-BEATS em cenários reais de gestão de imunobiológicos.

Tabela 3: Previsão BCG Nível Estadual

Semana	Quantidade de vacinados
116	881
117	929
118	993
119	931
120 - Previsão	955
120 - Real	932

Tabela 3: Previsão BCG Nível Municipal

Semana	Quantidade de vacinados
116	63
117	58
118	48
119	52
120 - Previsão	58
120 - Real	57

5 CONCLUSÃO

Este estudo explorou o potencial do modelo N-BEATS na previsão de demandas por vacinas, tanto de maneira agregada quanto segmentada por tipo de imunobiológico. A abordagem geral demonstrou que o modelo é capaz de capturar padrões globais, oferecendo uma visão consolidada da demanda total, o que é essencial para o planejamento estratégico em larga escala. Por outro lado, a análise específica por tipo de vacina evidenciou a flexibilidade e robustez do N-BEATS, permitindo identificar nuances individuais de cada imunobiológico, como diferenças sazonais e padrões particulares de procura.

Os resultados destacaram a eficácia do modelo em ambas as abordagens. No caso das previsões gerais, o modelo apresentou métricas superiores às de estudos anteriores, com um R^2 de 0,81 e MAPE de 16,59%, explicando uma parcela significativa da variabilidade dos dados e validando sua capacidade de generalização. Já nas previsões específicas, o modelo demonstrou ser igualmente eficiente, ajustando-se automaticamente às características de cada vacina, sem necessidade de intervenção manual, o que reforça sua aplicabilidade em contextos reais, com um R^2 de 0,83 e MAPE de 1,00%.

Além disso, a utilização de um conjunto de dados reduzido, mas cuidadosamente dividido, e a aplicação de métricas consolidadas, como R^2 e MAPE, garantiram uma avaliação robusta do desempenho do modelo. A integração de técnicas de validação durante o treinamento e o uso de previsões históricas para cenários reais fortaleceram ainda mais a confiabilidade dos resultados obtidos.

O estudo contribui significativamente para o campo da previsão de demandas por vacinas, demonstrando como modelos de ponta como o N-BEATS podem ser integrados aos sistemas de saúde para otimizar o planejamento de estoques e a distribuição de imunobiológicos. A capacidade de lidar tanto com dados brutos, agregados e segmentados oferece uma ferramenta poderosa para decisões baseadas em dados, promovendo maior eficiência na gestão de recursos e redução de desperdícios. Desta forma auxiliando a tomada de decisão, visando otimizar o planejamento estratégico e a gestão dos estoques de vacinação.

No entanto, é importante ressaltar que qualquer modelo de previsão, por mais preciso que seja, não pode e não deve gerar estimativas idênticas à demanda real. No contexto da vacinação, sempre deve existir um estoque de segurança para lidar com variações inesperadas, como surtos, atrasos logísticos e mudanças no comportamento populacional. Dessa forma, as previsões devem servir como um suporte para o planejamento, garantindo que haja vacinas disponíveis para atender às necessidades da população sem comprometer a continuidade das campanhas de imunização.

Desta forma o modelo N-BEATS destaca-se pelo potencial para otimização e a previsão, considerando sua capacidade de lidar com dados complexos e sua baixa dependência de pré-processamento. A aplicação desse modelo no contexto da saúde pública, especialmente na previsão de doses de vacinas, tem o poder de transformar a gestão e a distribuição de imunobiológicos. Através deste estudo, foi possível demonstrar que o N-BEATS é capaz de capturar padrões e nuances específicas de cada vacina, validando sua eficácia para o planejamento estratégico de vacinação. Os resultados obtidos reforçam a promessa do modelo como uma solução robusta, prática e eficiente para os desafios enfrentados pelas autoridades de

saúde pública na gestão de recursos vacinais. Assim, a integração de técnicas avançadas de previsão com dados históricos e segmentados abre novas possibilidades para a melhoria contínua na alocação de vacinas, destacando o N-BEATS como uma ferramenta crucial para a tomada de decisões mais ágeis e informadas.

Os resultados obtidos reforçam o potencial do N-BEATS como uma solução prática e eficaz para desafios complexos no planejamento de saúde pública, abrindo caminho para futuras investigações e aprimoramentos no uso de algoritmos avançados em cenários de previsão de séries temporais.

Por fim, para um futuro próximo, pode ser explorado o uso de séries temporais multivariadas para aprimorar ainda mais a precisão e aplicabilidade das previsões no contexto da vacinação. A integração de múltiplas variáveis, como dados socioeconômicos, índices de cobertura vacinal, taxas de incidência de doenças, campanhas de conscientização e sazonalidade climática, pode oferecer uma visão mais holística do comportamento da demanda por imunobiológicos. Cada variável exerce uma influência distinta sobre o processo de predição, e a interligação dessas informações permite identificar relações causais e correlações que enriquecem a capacidade preditiva do modelo. No sistema de vacinação, essa abordagem multivariada poderia ser integrada para otimizar ainda mais o planejamento de estoques e distribuição, fornecendo insights detalhados sobre os fatores que impulsionam a demanda em diferentes regiões e períodos. O uso de modelos avançados que incorporem *deep learning* e mecanismos de atenção também pode permitir a ponderação dinâmica dessas variáveis, destacando as mais relevantes para cada cenário, promovendo decisões mais precisas e baseadas em dados integrados.

REFERÊNCIAS

BOX, George Edward Pelham; JENKINS, Gwilym M.; REINSEL, Gregory C.. **Time Series Analysis: forecasting and control**. 5. ed. [S. L.]: Wiley, 2015. 712 p. Acesso em: 23 abr. 2024.

BATISTA, André Filipe de Moraes; CHIAVEGATTO FILHO, Alexandre Dias Porto. **Machine Learning aplicado à Saúde**. [S. L.]: Sociedade Brasileira de Computação, 2019. Disponível em: <https://sol.sbc.org.br/sbc/catalog/download>. Acesso em: 23 abr. 2024.

DAMETTO, Ronaldo César. **Estudo da aplicação de redes neurais artificiais para predição de séries temporais financeiras**. 2018. Disponível em: <http://hdl.handle.net/11449/157058>. Acesso em: 23 abr. 2024.

ANTUNES, José Leopoldo Ferreira; CARDOSO, Maria Regina Alves. Uso da análise de séries temporais em estudos epidemiológicos. **Epidemiologia e Serviços de Saúde**, [S.L.], v. 24, n. 3, p. 565-576, set. 2015. FapUNIFESP (SciELO). <http://dx.doi.org/10.5123/s1679-49742015000300024>. Disponível em: <https://www.scielo.br/j/ress/a/zzG7bfRbP7xSmqgWX7FfGZL/?format=pdf&lang=pt>. Acesso em: 23 abr. 2024.

Ministério da Saúde. **Programa Nacional de Imunizações - Vacinação**. Disponível em: <https://www.gov.br/saude/pt-br/acesso-a-informacao/acoes-e-programas/pni>. Acesso em: 29 abr. 2024.

RN+VACINA. **Monitoramento**. Disponível em: <https://rnmaisvacina.lais.ufrn.br/>. Acesso em: 29 abr. 2024.

SCIKIT-LEARN. GridSearchCV. Disponível em: https://scikitlearn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html. Acesso em: 29 abr. 2024. KHAN ACADEMY. Raciocínio para o R². Disponível em: RACIOCÍNIO para o R². Disponível em: <https://pt.khanacademy.org/math/apstatistics/bivariate-data-ap/assessing-fit-leastsquares-regression/a/r-squared-intuition>. Acesso em: 29 abr. 2024.

AMAZON WEB SERVICES, Inc. *O que é uma rede neural?* Disponível em: <https://aws.amazon.com/pt/what-is/neural-network/>. Acesso em: 2 set. 2024.

IBM. *Neural networks*. Disponível em: <https://www.ibm.com/topics/neural-networks>. Acesso em: 2 set. 2024.

MICROSOFT AZURE. *What is deep learning?* Disponível em: <https://azure.microsoft.com/pt-br/resources/cloud-computing-dictionary/what-is-deep-learning>. Acesso em: 2 set. 2024.

BISHOP, Christopher M. *Pattern Recognition and Machine Learning*. 1. ed. New York: Springer, 2006.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. *Deep Learning*. Cambridge:

MIT Press, 2016.

ORESHKIN, Boris N.; CARPOV, Dmitri; CHAPADOS, Nicolas; BENGIO, Yoshua. *N-BEATS: Neural Basis Expansion Analysis Time Series Forecasting*. arXiv preprint arXiv:1905.10437, 2019. Disponível em: <https://arxiv.org/abs/1905.10437>. Acesso em: 2 set. 2024.

REMY, Philippe. *N-BEATS*. Disponível em: <https://github.com/philipperemy/n-beats>. Acesso em: 2 set. 2024.

NVIDIA. *O que é um modelo Transformer?* Disponível em: <https://blog.nvidia.com.br/blog/o-que-e-um-modelo-transformer/>. Acesso em: 2 set. 2024.

Lemos, L. O., Guedes, L. A., & Valentim, R. A. M. (2023). Predição de Aplicação de Vacinas Baseada em Gradient Boosting Regressor. [CBA].

Haykin, S. (2001). *Redes Neurais: Princípios e Prática*. Bookman.

Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Oxford University Press.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems* (NeurIPS).

Brockwell, P. J., & Davis, R. A. (2016). *Introduction to Time Series and Forecasting*. Springer.

Shmueli, G., Patel, N. R., & Bruce, P. C. (2019). *Data Mining for Business Intelligence: Concepts, Techniques, Tools, and Applications*. Wiley.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.