



# Análise do Efeito de Índices Climáticos e Pluviométricos em Modelos de RNN LSTM para Pecuária de Precisão

Matheus C. Correia<sup>1</sup>; Bianca O. Durgante<sup>1</sup>; Davi L. Lemos<sup>1\*</sup>  
Naylor B. Perez<sup>2†</sup>; Teresa C. Genro<sup>2</sup>; Leonardo B. Pinho<sup>1‡</sup>

**Resumo:** Este estudo analisa a influência de índices climáticos e pluviométricos em modelos de redes neurais recorrentes aplicados à predição de forragem em pastagens naturais do bioma Pampa. O manejo adequado de pastagens é essencial para a sustentabilidade da pecuária, especialmente em sistemas extensivos, onde a oferta de forragem tem papel importante na produtividade. Foram utilizados dados climáticos históricos, como o Índice Oceânico Niño (ONI), variáveis pluviométricas e dados agronômicos, para treinar os modelos e prever a taxa de acúmulo de forragem. Quatro cenários experimentais foram analisados, variando na inclusão ou exclusão de índices pluviométricos e do Índice Oceânico Niño. Os resultados indicam que a pluviosidade impacta diretamente a precisão das predições, enquanto o ONI mostrou relevância apenas na ausência de dados pluviométricos. A análise estatística, com base em métricas como erro quadrático médio desvio padrão e variância, confirmou que o uso de dados pluviométricos melhora a acurácia das previsões, o que não ocorreu com a inclusão de variável com os dados explícitos do ONI. O estudo contribui para a compreensão dos efeitos de fenômenos climáticos no crescimento das pastagens e sugere que futuros modelos devem incorporar a interação entre variáveis meteorológicas e a carga animal, especialmente em cenários de eventos climáticos extremos, como secas ou chuvas excessivas.

**Palavras-chave:** Agricultura Digital; Inteligência Artificial; Taxa de Acúmulo

\*{matheuscorreia,biancadurgante,davilemos}.aluno@unipampa.edu.br

†{naylor.perez,cristina.genro}@embrapa.br

‡leonardopinho@unipampa.edu.br

<sup>1</sup>UNIPAMPA - Campus Bagé, 96.413-172 – Bagé – RS – Brasil.

<sup>2</sup>Embrapa Pecuária Sul, 96.401-970 – Bagé – RS – Brasil.

# 1 INTRODUÇÃO

Em 2023, o Brasil registrou o maior rebanho bovino comercial do mundo, com 238,6 milhões de cabeças, e consolidou-se como o maior exportador de carne bovina. No contexto regional, o Rio Grande do Sul possui um rebanho bovino superior a 12 milhões de cabeças (IBGE, 2023). A produtividade nesse setor, especialmente em sistemas de pastejo extensivo, está diretamente ligada à oferta de forragem, que é mensurada pela quantidade de matéria seca disponível por área. Segundo Salman, Soares, e Canesin (2006), a alimentação, que pode representar entre 50% e 80% dos custos de produção, exige um manejo eficiente das pastagens, sendo fundamental para a sustentabilidade e a lucratividade do sistema pecuário. Nesse sentido, pastagens bem manejadas não apenas evitam a degradação, mas também podem multiplicar a produção de peso vivo por hectare em comparação com áreas mal conservadas.

No contexto do bioma Pampa, que cobre 63% do território gaúcho, as pastagens nativas, que por sua vez, representam aproximadamente 36% da área estadual, desempenham um papel central na alimentação do rebanho, compostas por mais de 400 espécies de gramíneas e 150 de leguminosas forrageiras (Boldrini, 2020). Esse ambiente natural, quando manejado de forma adequada, oferece uma alimentação sustentável e equilibrada, integrando a produção pecuária com a preservação ambiental. Assim, o manejo eficiente da forragem, ao respeitar a capacidade de suporte das pastagens, não só otimiza o uso dos recursos naturais e reduz custos, mas também melhora a eficiência produtiva do sistema (Bencke, Chomenko, e Sant'Anna, 2016).

Dentre os principais desafios na gestão de pastagens está a influência de variáveis meteorológicas. Hipoteticamente, estas são impactadas pelo El Niño-Oscilação Sul (ENOS), um dos principais fenômenos naturais com impacto direto sobre o clima global e, portanto, com influência na produtividade das pastagens. O ENOS apresenta duas fases principais: El Niño, caracterizada pelo aquecimento anômalo das águas superficiais no Pacífico Tropical, e La Niña, marcada pelo resfriamento dessas águas. Durante o El Niño, o Brasil experimenta padrões climáticos alterados, como chuvas acima da média no sul do país e secas no norte e nordeste. Por outro lado, durante a La Niña, as condições são geralmente opostas, com chuvas mais intensas no norte e períodos de seca no sul (Ferreira e Mello, 2005).

A Empresa Brasileira de Pesquisa Agropecuária (Embrapa), através da Embrapa Pecuária Sul, realiza pesquisas sobre a disponibilidade de forragem para alimentação bovina, utilizando métodos de coleta direta com gaiolas de exclusão. Essas gaiolas isolam áreas das pastagens para o corte, secagem e pesagem da vegetação. Esses métodos são manuais e destrutivos, incentivando a busca por alternativas mais eficientes, com destaque para o desenvolvimento de modelos preditivos baseados em inteligência artificial (IA), como o de Schulte (2019), aprimorado por Soares (2021) e por Lemos *et al.* (2024).

Os modelos preditivos baseados em IA referenciados utilizam abordagens baseadas em redes neurais recorrentes (RNN), treinadas para prever a oferta de forragem. As RNN são capazes de lidar com séries temporais, o que é necessário para prever o crescimento

de pastagens com base em padrões meteorológicos históricos e variáveis representativas ambientais. Essa abordagem permite que o sistema capture comportamentos de longo prazo nos dados, realizando previsões com acurácia em comparação com métodos convencionais que consideram projeções empíricas dos pecuaristas, com base em experiências de anos anteriores combinadas com previsões meteorológicas. Entretanto, embora o uso de RNN apresente benefícios em relação à coleta manual, os modelos anteriormente propostos não incluíam explicitamente dados relacionados a índices climáticos, como o Índice Oceânico Niño (ONI). Desta forma especula-se que a inclusão do ONI poderia potencializar o desempenho da RNN, proporcionando previsões ainda mais precisas e em cenários de clima extremo, o que é importante para um manejo eficiente das pastagens.

Com base em uma metodologia exploratória experimental, este trabalho **contribui com o estado da arte por meio de uma análise estatística dos impactos da variável climática ONI e dos dados pluviométricos na predição da Taxa de Acúmulo (TA) de forragem sob diferentes cenários climáticos, a partir de um estudo de caso representativo de um sistema pecuário do bioma Pampa**. Espera-se que essa abordagem contribua para o aprimoramento de modelos de predição necessários à uma gestão mais eficiente das pastagens em diferentes contextos climáticos, otimizando o uso da pastagem e oferecendo maior previsibilidade para que os pecuaristas possam lidar com os efeitos de eventos climáticos extremos, como secas prolongadas ou chuvas excessivas.

O restante do trabalho está estruturado como segue: na Seção 2 são sintetizados os trabalhos correlatos à pesquisa; na Seção 3 são descritos os Materiais e Métodos; na Seção 4 são apresentados os Resultados e Discussões, com ênfase na análise dos achados experimentais; por fim, na Seção 5 são destacadas as Considerações Finais, incluindo as principais conclusões e as perspectivas para trabalhos futuros.

## 2 TRABALHOS CORRELATOS

Nos trabalhos precursores de Schulte (2019) e Schulte *et al.* (2019) foi proposto um modelo baseado em redes neurais recorrentes voltado a predição de oferta de massa de forragem em áreas de pastagem natural, utilizando Redes Neurais Artificiais com a arquitetura Long Short-Term Memory (LSTM). O modelo utiliza como base dados amostrais obtidos na área experimental, campo nativo do bioma Pampa, complementado por informações meteorológicas. Os resultados apontam que o sistema proposto consegue prever a massa de forragem com base nos dados meteorológicos históricos junto dos dados coletados da pastagem.

Posteriormente, nos trabalhos de Soares (2021) e Soares, Perez, e Pinho (2020) aprimorou-se o modelo previamente desenvolvido por Schulte (2019) para a predição de disponibilidade de forragem, passando a prever a TA, integrado a um protótipo de *farm management information system* (FMIS) capaz de coletar, armazenar e processar os dados históricos de vegetação campestre, dados meteorológicos obtidos de estações automáticas e previsões climáticas. O sistema se beneficia de dados meteorológicos remotos fornecidos

por instituições como o Instituto Nacional de Meteorologia (INMET), o Instituto Nacional de Pesquisas Espaciais (INPE) e a Administração Nacional Oceânica e Atmosférica (NOAA), do inglês National Oceanic and Atmospheric Administration, permitindo coletas periódicas automatizadas. A análise estatística desenvolvida demonstrou que o novo modelo, ajustado empiricamente, atingiu maior acurácia em comparação à versão original.

Complementarmente, o estudo de Lemos *et al.* (2024) analisou o impacto da ferramenta KerasTuner (O'Malley *et al.*, 2019) no ajuste automático de hiperparâmetros do modelo RNN LSTM proposto em Schulte *et al.* (2019). A aplicação dessa ferramenta resultou em uma melhora de 30% na acurácia do modelo original, mas com um aumento no tempo de treinamento entre 80% e 110%, dependendo do ambiente computacional (CPU, GPU ou TPU). O trabalho destaca a relevância de técnicas automatizadas de ajuste dos modelos de predição, contribuindo para decisões mais eficazes no manejo de pastagens.

Por outro lado, o trabalho de Hundertmarck (2023) investigou a influência de eventos climáticos extremos na resiliência e produção de pastagens naturais do bioma Pampa, manejadas sob diferentes ofertas de forragem. No primeiro estudo, avaliou-se a resiliência à seca em uma pastagem natural no sul do Brasil, utilizando dados de 15 anos e classificando os eventos climáticos com base no Índice de Precipitação-Evapotranspiração Padronizado (SPEI). O estudo concluiu que as pastagens do bioma Pampa são resistentes à seca, especialmente quando manejadas com oferta de forragem moderada (12% do peso vivo). O segundo estudo analisou a influência dos eventos ENOS nas estações de primavera e verão, observando que anomalias climáticas afetam a produção primária e secundária das pastagens.

Tendo em vista que os modelos de predição anteriormente propostos não incluíam explicitamente o ENOS, associado aos hipotéticos impactos da ocorrência de eventos climáticos extremos no crescimento das pastagens, neste trabalho busca-se analisar a incorporação destes dados no modelo RNN LSTM, avaliando-se quantitativa e qualitativamente o seu efeito na acurácia da previsão.

### **3 MATERIAIS E MÉTODOS**

Nesta seção são descritos os dados referentes ao estudo de caso (Subseção 3.1), detalhado o modelo de TA (Subseção 3.2), apresentado o processo de coleta e transformação do ONI para uma série mensal, contrastada com os índices pluviométricos (Subseção 3.3), destacados os cenários analisados (Subseção 3.4), o ambiente experimental (Subseção 3.5) e as métricas de avaliação dos modelos de predição (Subseção 3.6).

#### **3.1 Estudo de caso**

A área experimental, onde foram coletados os dados de treinamento dos modelos – 48 amostras estratificadas de massa de forragem coletadas entre janeiro de 2014 e agosto de 2019, a partir do método direto com gaiolas de exclusão (Machado e Kichel, 2004),

associadas a variáveis meteorológicas –, está localizada na fazenda da Embrapa Pecuária Sul, abrangendo aproximadamente 36 hectares de pastagem natural típica da Região da Campanha, no Rio Grande do Sul. O relevo é suavemente ondulado e apresenta alta infestação por *Eragrostis plana* (capim-annoni), uma gramínea invasora de difícil controle. O manejo da área envolve pastejo contínuo com lotação variável, o que possibilita a avaliação de diferentes estratégias para o controle dessa espécie invasora e o manejo da vegetação.

A área foi dividida em dois poteiros, nos quais foram aplicados dois tipos de tratamento para controle do capim-annoni. O primeiro tratamento, denominado “infestado”, caracteriza-se pela vegetação dominada por essa gramínea invasora, já o segundo, fundamentado no Método Integrado para Recuperação de Pastagens (MIRAPASTO) de Perez (2015), adota práticas de manejo que incentivam uma maior diversidade de espécies nativas, incluindo gramíneas dos gêneros *Paspalum*, *Axonopus* e *Cynodon*, além de outras espécies. O objetivo desses tratamentos é a recuperação de pastagens degradadas, buscando melhorar a qualidade do pasto disponível para o gado.

Dados relacionados ao clima da área experimental são obtidos da estação meteorológica automática (EMA) do INMET, localizada em Bagé, Rio Grande do Sul, a cerca de 4 km da área experimental da Embrapa Pecuária Sul, com o código de identificação A827, que está posicionada nas coordenadas 31°20'59"S e 54°06'25"O, a uma altitude de 212 metros. Ela coleta uma série de variáveis meteorológicas, como temperatura do ar, umidade relativa, precipitação, radiação solar, além de direção e velocidade do vento, informações necessárias para previsões da disponibilidade de massa de forragem por meio de modelos baseados em redes neurais recorrentes.

### 3.2 Detalhamento do modelo de previsão de TA

O modelo explorado neste trabalho utiliza séries temporais derivadas de um banco de dados geoespacial, com o objetivo de prever a TA como variável de saída. Cada amostra da série temporal inclui 36 atributos de entrada, conforme explicitados no trabalho de Soares (2021, p. 134):

- **Número de dias:** quantidade de dias referentes ao intervalo da estimativa atual e da anterior;
- **Altura da forragem média anterior:** altura média registrada na estimativa anterior;
- **MS total da forragem anterior:** massa de matéria seca total fora da gaiola na estimativa anterior;
- **Altura média:** altura média da pastagem na data da estimativa;
- **Percentual de annoni:** estimativa do percentual de infestação da vegetação pelo capim-annoni;
- **Temperaturas mínima, média e máxima (t min, t med, t max):** médias das temperaturas mínimas, médias e máximas registradas no intervalo;

- **Umidade:** média da umidade relativa do ar registrada no intervalo;
- **Velocidade do vento:** média da velocidade do vento registrada no intervalo;
- **Radiação solar:** somatório da radiação solar registrada no intervalo;
- **Chuva:** acumulado da precipitação registrada no intervalo;
- **Soma térmica:** acumulado da soma térmica, dada por:  $st = \frac{t_{\max} + t_{\min}}{2} - t_{\text{base}}$ , onde  $t_{\max}$  é a temperatura máxima registrada no dia,  $t_{\min}$  é a temperatura mínima registrada no dia e  $t_{\text{base}}$  é a temperatura basal para a vegetação estudada. No contexto deste trabalho, utilizou-se  $t_{\text{base}}$  igual a 7°C no inverno e 10°C no verão, devido à diversidade de espécies encontradas (Sentelhas, Pereira, e Angelocci, 1999);
- **Déficit e excedente hídrico (def e exc):** calculados através do método para cálculo de balanço hídrico proposto por Thornthwaite e Mather (1955).

Nota-se que os dados compreendem variáveis climáticas, coletadas pela estação do INMET, e dados históricos de disponibilidade de forragem. Adicionalmente, são consideradas variáveis agronômicas relacionadas ao manejo da pastagem, como massa seca total anterior, massa seca total e altura média do pasto. Em relação às variáveis meteorológicas utilizadas no modelo original, destaca-se que também são incorporados a variância e o desvio padrão associados a cada variável, como medidas de dispersão da variação ao longo do período que representam.

Além dos dados explícitos obtidos pelas medições de pastagem, meteorológicas e climáticas utilizadas no modelo, também é calculada a evapotranspiração, influenciada por fatores meteorológicos como disponibilidade de umidade do solo, radiação solar, temperatura do ar, umidade relativa e velocidade do vento. Esses dados são coletados pela estação meteorológica automática do INMET na região de estudo, apresentada na seção anterior. A disponibilidade de água no solo, que reflete o balanço hídrico a partir de eventos climáticos acumulados, indica situações de déficit ou excesso de água, conhecidas como "estresse hídrico".

Para automatizar o cálculo da evapotranspiração, utilizou-se a biblioteca Pyeto, desenvolvida em Python, que utiliza dados meteorológicos coletados pela EMA e calcula uma estimativa da evapotranspiração de referência por meio da fórmula de Penman-Monteith, obtendo um resultado expresso em milímetros por dia (mm/dia). Assim, a camada de entrada do modelo de RNA LSTM é composta pelas variáveis apresentadas, com suas medidas de dispersão associadas, mais a evapotranspiração, assim totalizando as 36 entradas.

O modelo LSTM teve seus parâmetros específicos configurados como uma arquitetura de rede neural recorrente com duas camadas, onde a primeira camada conta com 30 neurônios, configurados para retornar a sequência completa, e utiliza a função de ativação tangente hiperbólica (TANH). A segunda camada também conta com ativação TANH e possui 15 neurônios. A camada de saída é totalmente conectada e possui um único neurônio. Todas as camadas foram configuradas com inicialização normal do kernel.

O treinamento do modelo foi conduzido utilizando a função de perda de erro quadrático médio e o otimizador RMSprop, com 5000 épocas de treinamento e um tamanho de lote de 72 amostras por iteração. Antes do treinamento, os dados de entrada foram normalizados utilizando o método MinMaxScaler e reestruturados em um tensor tridimensional, com dimensões correspondentes ao número de amostras, passos temporais e características. Por fim, os dados foram divididos em conjuntos de treinamento, com 36 amostras e teste, com 12 amostras.

### 3.3 Coleta e transformação do ONI para Série Mensal


O ONI é utilizado pela Administração Nacional Oceânica e Atmosférica para classificar eventos ENOS no Pacífico tropical oriental. O ONI é calculado como a média móvel de três meses da anomalia da temperatura da superfície do mar (SST, na sigla em inglês) na região Niño 3.4 (5°N-5°S, 120°-170°W). Os eventos são definidos por 5 períodos consecutivos de três meses com anomalias de SST acima de +0,5°C para El Niño e abaixo de -0,5°C para La Niña. Estes eventos são então categorizados como fracos, moderados, fortes e muito fortes, com base na magnitude da anomalia e na sua persistência.

Como o modelo de predição da TA utiliza uma série de dados mensais para treinamento e teste, então foi necessário converter os dados trimestrais do ONI para uma série temporal mensal, esta conversão foi realizada distribuindo cada valor trimestral igualmente entre os três meses que o compõem. O processo de conversão dos dados trimestrais do ONI para série mensal foi realizado conforme descrito a seguir e é ilustrado na Figura 1:

- **Identificação dos Trimestres:** Cada valor trimestral (DJF, JFM, ...) corresponde a três meses consecutivos, sendo a sigla decorrente das iniciais dos meses do trimestre;
- **Atribuição mês a mês:** Agrupar e associar cada valor trimestral aos meses correspondentes;
- **Interpolação Mensal:** Continuar o processo para todos os trimestres, criando assim uma série mensal, como:
  - Janeiro 2016 = Média de NDJ (2.6) DJF (2.5) e JFM (2.1) = 2.4.
  - Fevereiro 2016 = Média de DJF (2.5), JFM (2.1) e FMA (1.6) = 2.05.
  - Março 2016 = Média de JFM (2.1), FMA (1.6) e MAM (0.9) = 1.6.

Este método tem com objetivo realizar uma conversão suave dos valores trimestrais para mensais, permitindo seu uso adequado no modelo preditivo. A Tabela 1 apresenta os dados trimestrais obtidos no site da NOAA, em contraste com os interpolados (Tabela 2).

A Figura 2 apresenta duas séries temporais – o ONI convertido para série mensal e a precipitação – correspondentes ao período de 2014 a 2019, a qual sugere uma aparente correlação entre o fenômeno climático e os padrões de chuva utilizados como entrada no modelo. O eixo X representa o período temporal em anos, enquanto os eixos Y contém os valores do índice ONI mensal e a precipitação acumulada durante o mês. Nos anos



**Figura 1:** Fluxograma do processo de transformação dos dados


**Tabela 1:** Dados trimestrais da NOAA referentes ao ONI de 2014 a 2019.

| Ano  | DJF  | JFM  | FMA  | MAM  | AMJ  | MJJ  | JJA  | JAS  | ASO  | SON  | OND  | NDJ  |
|------|------|------|------|------|------|------|------|------|------|------|------|------|
| 2014 | -0,4 | -0,5 | -0,3 | 0,0  | 0,2  | 0,2  | 0,0  | 0,1  | 0,2  | 0,5  | 0,6  | 0,7  |
| 2015 | 0,5  | 0,5  | 0,5  | 0,7  | 0,9  | 1,2  | 1,5  | 1,9  | 2,2  | 2,4  | 2,6  | 2,6  |
| 2016 | 2,5  | 2,1  | 1,6  | 0,9  | 0,4  | -0,1 | -0,4 | -0,5 | -0,6 | -0,7 | -0,7 | -0,6 |
| 2017 | -0,3 | -0,2 | 0,1  | 0,2  | 0,3  | 0,3  | 0,1  | -0,1 | -0,4 | -0,7 | -0,8 | -1,0 |
| 2018 | -0,9 | -0,9 | -0,7 | -0,5 | -0,2 | 0,0  | 0,1  | 0,2  | 0,5  | 0,8  | 0,9  | 0,8  |
| 2019 | 0,7  | 0,7  | 0,7  | 0,7  | 0,5  | 0,5  | 0,3  | 0,1  | 0,2  | 0,3  | 0,5  | 0,5  |

**Tabela 2:** Dados mensais interpolados referentes ao ONI de 2014 a 2019.

| Ano  | Jan  | Fev   | Mar   | Abr   | Mai   | Jun   | Jul   | Ago   | Set   | Out   | Nov   | Dez   |
|------|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| 2014 | -0,4 | -0,45 | -0,4  | -0,15 | 0,1   | 0,2   | 0,1   | 0,2   | 0,3   | 0,5   | 0,6   | 0,65  |
| 2015 | 0,5  | 0,5   | 0,7   | 0,9   | 1,05  | 1,35  | 1,5   | 1,7   | 1,9   | 2,2   | 2,5   | 2,55  |
| 2016 | 2,4  | 2,05  | 1,6   | 0,65  | 0,35  | -0,25 | -0,35 | -0,55 | -0,65 | -0,7  | -0,75 | -0,65 |
| 2017 | -0,2 | -0,25 | -0,3  | -0,4  | -0,55 | -0,75 | -0,85 | -0,85 | -0,7  | -0,55 | -0,4  | -0,35 |
| 2018 | -0,8 | -0,8  | -0,65 | -0,35 | -0,15 | -0,05 | 0,05  | 0,15  | 0,4   | 0,65  | 0,85  | 0,85  |
| 2019 | 0,7  | 0,7   | 0,7   | 0,6   | 0,5   | 0,5   | 0,4   | 0,25  | 0,2   | 0,3   | 0,45  | 0,5   |





**Figura 2:** Gráfico do índice ONI x chuvas no período de 2014 a 2019.

em que o índice ONI indica condições de El Niño, valores positivos e acima de 0.5, observa-se um aumento ou alteração na distribuição das chuvas.

### 3.4 Modelos analisados

Os experimentos realizados neste estudo envolvem o treinamento do modelo em diferentes cenários, mantendo sempre o mesmo número de amostras (48), porém variando o número de atributos para avaliar o impacto de diferentes variáveis no desempenho do modelo. Os cenários representam combinações distintas dos dados utilizados para treinar os modelos analisados, incorporando diferentes versões do conjunto de dados original. Cada cenário pode incluir mais ou menos atributos, conforme o planejamento experimental. Os dados relacionados às estimativas de pasto permanecem presentes em todos os cenários, variando apenas na inclusão ou exclusão dos índices pluviométricos e do índice obtido na seção anterior. Assim, os cenários experimentais propostos são:

- **Cenário 1 - Chuva:** O modelo é treinado com o conjunto de dados original, contendo 36 atributos e 48 amostras, abrangendo as variáveis climáticas obtidas pela estação meteorológicas.
- **Cenário 2 - Chuva + ONI:** Uma nova variável é adicionada ao conjunto de dados original: o índice mensal relacionado ao efeito climático do El Niño/La Niña, conforme apresentado na seção anterior e processado de acordo com o método descrito na próxima seção. Com essa adição, o conjunto de dados passa a ter 37 atributos, mantendo as 48 amostras.
- **Cenário 3 - ONI:** Os dados pluviométricos são removidos do conjunto de dados original, mas o índice mensal do efeito climático calculado na seção anterior é mantido. Isso resulta em um conjunto com 33 atributos, mantendo as mesmas 48 amostras.

- **Cenário 4 - Nenhum:** Tanto os dados pluviométricos quanto o índice mensal do efeito climático são excluídos do conjunto de dados original, reduzindo-o para 32 atributos, com as mesmas 48 amostras.

Essa estrutura experimental possibilita a investigação de como diferentes combinações da variável pluviométrica e do ONI afetam o desempenho do modelo, permitindo a análise de qual combinação resulta em maior/menor acurácia, dispersão e variabilidade.

### 3.5 Ambiente experimental

Os experimentos realizados nesta pesquisa foram conduzidos em um ambiente computacional local, utilizando um sistema equipado com um processador Intel Core i5-13450HX. Este processador opera a uma frequência base de 3,4 GHz e possui dez núcleos, sendo seis dedicados a desempenho e quatro a eficiência, além de vinte threads. A unidade de processamento gráfico (GPU) utilizada foi uma NVIDIA RTX 3050 Ti, com 6 GB de memória GDDR6. Complementando a configuração, o sistema conta com 16 GB de memória DDR5, operando a uma frequência de 4800 MHz, e utiliza o sistema operacional Linux Ubuntu 24.04 LTS. Para a construção, treinamento e teste do modelo RNN LSTM, foi utilizada a biblioteca TensorFlow na versão 2.16.2, em conjunto com Keras (versão 3.41) e Scikit-learn (versão 1.5.1), executado com Python 3 (versão 3.10.12).

### 3.6 Avaliação de Modelos de Predição

Para avaliar o desempenho dos modelos perante os resultados dos treinamentos e testes, foram escolhidas três métricas de avaliação principais: RMSE, desvio padrão e variância. Ao tratar da avaliação de modelos de redes neurais recorrentes, o RMSE é uma métrica estatística utilizada para avaliar a acurácia de modelos preditivos e calculado a partir da média das magnitudes dos erros de predição, onde o erro quadrático médio é definido como a diferença entre o valor observado e o valor predito pelo modelo. O RMSE é calculado conforme a equação (1):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

Onde  $y_i$  é o valor real,  $\hat{y}_i$  o valor predito e  $n$  a quantidade de predições.

O desvio padrão dos erros de predição indica quão dispersos estão os erros em relação à média dos erros, nesse sentido, um desvio padrão menor sugere que o modelo tem uma maior consistência nos resultados preditos. Neste caso, o desvio padrão ( $\sigma$ ) é calculado conforme elenca a equação (2):

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (e_i - \bar{e})^2} \quad (2)$$

Onde  $e_i = y_i - \hat{y}_i$  é o erro de predição, ou seja, a diferença entre o valor real  $y_i$  e o valor predito  $\hat{y}_i$ . A média dos erros de predição é  $\bar{e}$  e  $n$  é a quantidade de meses preditos.

A variância é o quadrado do desvio padrão e oferece uma medida de quão dispersos estão os erros de predição. Neste sentido, a variância avalia a variação dos erros em torno da média dos erros das predições feitas pelo modelo, sendo caracterizada pela equação (3):


$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (e_i - \bar{e})^2 \quad (3)$$

## 4 RESULTADOS E DISCUSSÕES

A análise comparativa dos modelos preditivos baseados nos cenários experimentais propostos permitiu avaliar o impacto das variáveis climáticas, em particular a pluviosidade e o índice ONI, sobre a acurácia dos modelos. As métricas de avaliação utilizadas (RMSE, desvio padrão e variância) demonstraram variações significativas conforme a inclusão ou exclusão de determinadas variáveis. Os resultados obtidos são apresentados de forma sumarizada na Tabela 3.


**Tabela 3:** Comparação dos resultados para os diferentes cenários

| Parâmetros        | Chuva   | Chuva + ONI | ONI      | Nenhum |
|-------------------|---------|-------------|----------|--------|
| RMSE              | 11,15   | 11,15       | 13,10    | 12,11  |
| R2 Linear         | 0,96288 | 0,969720    | 0,96031  | 0,9611 |
| R2 Polinomial     | 0,98441 | 0,984292    | 0,982609 | 0,9836 |
| Desvio Real       | 43,12   | 43,12       | 43,124   | 43,12  |
| Variância Real    | 1859    | 1859        | 1859     | 1859   |
| Desvio Predito    | 43,97   | 43,93       | 43,2975  | 43,32  |
| Variância Predito | 1937,93 | 1931        | 1876,2   | 1877,6 |



**Figura 3:** Série de predições para o período de 12 meses.

A Figura 3 apresenta graficamente as séries temporais resultantes dos experimentos, correspondente aos últimos doze meses do conjunto de dados. Embora as curvas pareçam similares, a análise quantitativa detalhada dos efeitos climáticos sobre o desempenho dos modelos de predição aponta importantes diferenças entre os cenários com e sem ONI, e com e sem pluviosidade. Além das métricas previamente discutidas, a análise do desvio padrão predito também fornece conclusões sobre a precisão do modelo.



**Figura 4:** Gráfico comparativo do RMSE nos diferentes cenários.

Os resultados detalhados do RMSE são apresentados na Figura 4, ordenados do cenário com menor para o de maior acurácia. Ao comparar cenários com e sem ONI, observa-se que, na presença de pluviosidade, o ONI não teve impacto significativo no RMSE (ambos com RMSE de 11,15 kg/ha/dia). No entanto, na ausência de pluviosidade, a presença do ONI aumentou o erro das predições em 8,2%, sugerindo que o ONI contribui para um aumento no erro preditivo quando a pluviosidade não está presente. No cenário com ONI, o RMSE aumentou de 11,15 kg/ha/dia para 13,10 kg/ha/dia quando a pluviosidade foi excluída, o que sugere que a pluviosidade melhora significativamente a precisão preditiva na presença do ONI. Da mesma forma, na ausência do ONI, o RMSE aumentou de 11,15 kg/ha/dia para 12,11 kg/ha/dia sem a pluviosidade, confirmando que a pluviosidade tem um impacto positivo na precisão dos modelos, independentemente da presença de ONI.

A variância predita e o desvio padrão predito refletem a dispersão e variabilidade dos resultados previstos pelos modelos. No cenário com ONI, a variância predita foi de 1931 kg/ha/dia com pluviosidade e 1876,2 kg/ha/dia sem pluviosidade, sugerindo que a pluviosidade aumenta a variabilidade dos resultados preditivos. O desvio padrão predito também foi maior com pluviosidade (43,93 kg/ha/dia) em comparação a sem pluviosidade

(43,2975 kg/ha/dia). No cenário sem ONI, a variância predita foi ligeiramente maior com pluviosidade (1937,93 kg/ha/dia) em relação a sem pluviosidade (1877,6 kg/ha/dia), indicando um aumento na variabilidade preditiva devido à pluviosidade. O desvio padrão predito acompanhou essa tendência, sendo maior com pluviosidade (43,97 kg/ha/dia) em comparação a sem pluviosidade (43,32 kg/ha/dia).

Esses resultados indicam que, embora a pluviosidade tenda a aumentar a variabilidade das previsões, ela contribui significativamente para uma maior precisão (menor RMSE) dos modelos. O efeito do ONI, por outro lado, é mais notável na ausência de pluviosidade, onde sua presença resulta em uma piora importante na acurácia do modelo de predição da TA. Por outro lado, é possível observar que a predição da TA, com ênfase no ONI, sem incorporar amostras de precipitação da região, tende a apresentar uma acurácia inadequada, inclusive significativamente pior do que a obtida com um modelo simplificado que representaria um cenário com ausência da informação de precipitação ou do ONI.

## **5 CONSIDERAÇÕES FINAIS**

Dados de pluviosidade nos modelos de predição se mostram essenciais para obter uma maior precisão e menor variabilidade nas predições, embora o ONI tenha um impacto limitado, sua interação com a pluviosidade deve ser considerada, especialmente em cenários onde a variabilidade dos resultados preditivos é uma preocupação. A análise do RMSE mostrou que a inclusão do efeito climático ONI não tornou o modelo mais preciso, quando este já foi treinado com dados pluviométricos. Por outro lado, agregou ao modelo originalmente proposto por Schulte *et al.* (2019) uma redução sensível na variância.

Novos aspectos vêm sendo explorados em pesquisas, sobretudo com foco no desenvolvimento de modelos que apresentem melhores estimativas da taxa de acúmulo de forragem com base do efeito direto da carga animal sobre a pastagem. Especula-se que a carga animal tenha influência significativa sobre o crescimento das pastagens, tendo potencial para determinar o equilíbrio entre o consumo de forragem e sua taxa de recuperação. Neste contexto, integrar a carga animal com fatores climáticos pode ajudar a prever como diferentes cenários de manejo impactariam a taxa de acúmulo de forragem ao longo do tempo, especialmente sob condições de eventos climáticos extremos, como secas prolongadas ou chuvas excessivas. Além disso, estudos futuros também pretendem explorar o uso de arquiteturas híbridas de redes neurais para modelar de forma mais precisa a interação entre a carga animal e variáveis climáticas, com o objetivo de aprimorar as previsões da taxa de acúmulo de forragem e, desta forma, amparar de forma mais precisa o FMIS proposto como ferramenta de apoio a decisão de produtores rurais, visando o ajuste de lotação ideal.

## AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, bem como ressalta-se o amparo da CAPES por meio da concessão de bolsa de mestrado de Demanda Social, além do suporte recebido através de editais relativos aos Programas Institucionais de Bolsas de Iniciação Científica do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ/PIBIC), da Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS/PROBIC) e da Universidade Federal do Pampa (UNIPAMPA/PRO-IC).

## REFERÊNCIAS

- Bencke, G. A., L. Chomenko, e D. M. Sant'Anna (2016). *Our Unknown Pampa*. Porto Alegre: Zoobotanical Foundation of Rio Grande do Sul.
- Boldrini, I. (2020). “Por que e para que conservar o Pampa?” Em: *Anais do I Congresso sobre o Bioma Pampa: Reunindo Saberes*. Ed. por A. T. Filho e L. T. Winckler. [recurso eletrônico]. Pelotas: Editora UFPel.
- Ferreira, A. e N. Mello (2005). “Principais sistemas atmosféricos atuantes sobre a região Nordeste do Brasil e a influência dos oceanos Pacífico e Atlântico no clima da região”. Em: *Revista Brasileira de Climatologia* 1.1.
- Hundertmarck, A. P. (2023). “Influência de eventos climáticos extremos na resiliência e produção primária e secundária de pastagens naturais do bioma Pampa manejadas sob ofertas de forragem”. Diss. de mest. Porto Alegre: Universidade Federal do Rio Grande do Sul.
- IBGE (2023). *Produção da Pecuária Municipal 2023*. <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9107-producao-da-pecuaria-municipal.html>. Acesso em: 23 set. 2024.
- Lemos, D. L., B. O. Durgante, N. B. Perez, e L. B. Pinho (2024). “Impactos da Ferramenta KerasTuner em Modelo de Predição Baseado em LSTM para Pecuária Sustentável”. Em: *Anais da XXIV Escola Regional de Alto Desempenho da Região Sul*. SBC, pp. 97–100.
- Machado, L. A. Z. e A. N. Kichel (2004). “Ajuste de lotação no manejo de pastagens.” Em: *Documentos / Embrapa Agropecuária Oeste*.
- O'Malley, T., E. Bursztein, J. Long, F. Chollet, H. Jin, L. Invernizzi, et al. (2019). *KerasTuner*. <https://github.com/keras-team/keras-tuner>. [online: acesso em 24-janeiro-2024].
- Perez, N. (2015). “Método integrado de recuperação de pastagens Mirapasto: foco capim-annoni.” Em.
- Salman, A. K. D., J. P. G. Soares, e R. C. Canesin (2006). *Métodos de amostragem para avaliação quantitativa de pastagens*. Circular Técnica. Porto Velho: Embrapa Rondônia.

- Schulte, L. G. (2019). “Suporte à decisão em pastagens: Análise espaço-temporal e aprendizado de máquina para predição da disponibilidade de forragem no contexto de smart farming”. Em.
- Schulte, L. G., N. B. Perez, L. B. Pinho, e G. Trentin (2019). “Decision Support System for Precision Livestock: Machine Learning-Based Prediction Module for Stocking Rate Adjustment”. Em: *Proceedings of the XV Brazilian Symposium on Information Systems*, pp. 1–8.
- Sentelhas, P. C., A. R. Pereira, e L. R. Angelocci (1999). “Meteorologia Agrícola”. Em: *Revista Brasileira de Agrometeorologia* 7.1, pp. 123–135.
- Soares, Â. F. (2021). “TouceiraTech: um Farm Management Information System para pecuária de precisão baseado em predição com redes neurais recorrentes”. Em.
- Soares, Â. F., N. B. Perez, e L. B. de Pinho (2020). “TouceiraTech: Uma Proposta de FMIS Inovador para Predição de Disponibilidade de Pasto e Ajuste de Lotação Animal”. Em: *XII Congresso de AgroInformática (CAI 2020)-JAIIO 49 (Modalidade Virtual)*.
- Thornthwaite, C. W. e J. R. Mather (1955). “The Water Balance”. Em: *Publications in Climatology* 8.1, pp. 1–104.