
PREVISÃO DE TEMPERATURA EM SILOS COM TEMPORAL CONVOLUTIONAL NETWORK PARA CONTORNAR POSSÍVEIS FALHAS EM SENSORES DE TEMPERATURA DIGITAIS

Gustavo Queiroz Silveira¹

Ricardo Petri Silva²

RESUMO

A análise da termometria é uma técnica utilizada na indústria agrícola para monitorar a temperatura interna dos silos que armazenam grãos e outros produtos, sensores digitais instalados em cabos pêndulos são utilizados para esse fim. Entretanto, esses sensores podem sofrer consequências da má instalação elétrica da unidade da fazenda, o que pode gerar problemas como baixa capacitância, aterramento inadequado e interferência no sinal elétrico ou até mesmo problemas na construção do sensor que comprometem a qualidade e precisão da leitura da temperatura. Embora esses problemas muitas vezes não sejam preocupantes, alguns sensores podem falhar na sua leitura, deixando um espaço do silo sem a termometria. O presente trabalho tem como objetivo aplicar e analisar o comportamento do modelo padrão de Temporal Convolutional Network (TCN) em dados univariados que deve ser capaz de prever a temperatura que esses sensores afetados estariam indicando, fornecendo uma alternativa para o usuário até que a situação seja resolvida. Para avaliar o desempenho do modelo, foram utilizadas métricas estatísticas, o Root Mean Square Error (RMSE), o Mean Squared Error (MSE) e o Mean Absolute Error (MAE), fornecendo uma análise abrangente da precisão das previsões, com o melhor e mais importante resultado obtendo 3,405 para o RMSE, 11,595 para o MSE e 1.805 para o MAE. Este estudo busca contribuir para a solução de um problema comum na termometria de silos e pode ter impacto significativo na indústria agrícola e na qualidade dos produtos alimentícios armazenados, melhorando a qualidade de vida do consumidor final e facilitando o trabalho dos operadores do sistema de termometria.

408

Palavras-chave: temporal convolutional network; termometria; silo; predição; temperatura.

ABSTRACT

Termometry analysis is a technique used in the agricultural industry to monitor the internal temperature of silos storing grains and other products. Digital sensors installed on pendulum cables are employed for this purpose. However, these sensors can be adversely affected by poor electrical installation at the farm unit, resulting in issues such as low capacitance, inadequate grounding, electrical signal interference, or even

¹ Graduando em Ciência da Computação na UniFil, compgustavo@edu.unifil.br.

² Doutorando em Engenharia Elétrica na UEL e Coordenador Adjunto nos cursos de Tecnologia da Informação na UniFil, ricardo.petri@unifil.br

sensor construction problems that compromise temperature reading quality and accuracy. While these issues may not always be concerning, some sensors may fail to provide accurate readings, leaving gaps in temperature monitoring within the silo. The present study aims to apply and analyze the performance of the standard Temporal Convolutional Network (TCN) model on univariate data, with the objective of predicting the temperature that affected sensors would indicate, providing an alternative for users until the situation is resolved. To evaluate the model's performance, statistical metrics, including Root Mean Square Error (RMSE), Mean Squared Error (MSE), and Mean Absolute Error (MAE), were utilized. The best and most significant result obtained was 3.405 for RMSE, 11.595 for MSE, and 1.805 for MAE. This study seeks to contribute to the resolution of a common issue in silo thermometry and may have a substantial impact on the agricultural industry and the quality of stored food products. It aims to improve the quality of life for end consumers and streamline the work of thermometry system operators.

Keywords: temporal convolutional network; thermometry; silo; prediction; temperature.

1 INTRODUÇÃO

No Brasil, a demanda por sistemas de termometria tem crescido significativamente devido à sua obrigatoriedade na instalação de unidades armazenadoras de produtos a granel, como fazendas, coletoras e intermediárias, conforme estabelecido 1 2 pela Instrução Normativa nº 29/2011 do Ministério da Agricultura, Pecuária e Abastecimento (MAPA, 2011). Esse requisito legal impulsiona o mercado de armazenagem agrícola a adotar sistemas de termometria. Um sistema de termometria é uma infraestrutura composta por sensores de temperatura instalados em cabos pêndulos dentro de silos ou unidades de armazenamento agrícola, projetados para monitorar e registrar as variações de temperatura ao longo do tempo. É importante destacar que o setor de armazenagem agrícola apresenta um amplo potencial para a aplicação desses sistemas, considerando que, em maio de 2023, a capacidade estática de armazenamento de grãos no Brasil foi registrada em 189.524.288 toneladas, de acordo com os dados divulgados publicamente pela Companhia Nacional de Abastecimento (CONAB) por meio do Portal de Armazéns do Brasil (CONAB, 2023). Na tentativa de preencher esse espaço no mercado, a empresa TermoPlex sediada em Londrina-PR, iniciou em 2014 criando um sistema de termometria digital visando melhorar a área e espalhar a tecnologia dentro da agroindústria. Durante os anos de trabalho se depararam com diversos desafios

físicos que atrapalharam o funcionamento correto do sistema, dentre eles a distribuição de sensores contrafeitos por empresas terceiras, a má instalação da parte elétrica de uma unidade da fazenda permitindo o aumento de problemas sendo eles baixa capacitância, aterramento inadequado, interferência no sinal elétrico, entre outros. Esses problemas podem afetar a transmissão de informações lidas pelo sensor digital até a placa que envia os dados para o sistema causando uma anomalia nas leituras disponibilizadas para o usuário. O presente artigo propõe um método baseado em Inteligência Artificial (IA) para contornar a anomalia mencionada utilizando a predição gerada pelo modelo padrão de TCN. De acordo com os resultados obtidos por Gopali *et al.* (2021), o modelo de TCN, que é baseado em Convolutional Neural Network (CNN), apresenta uma pequena vantagem de desempenho e cria um modelo estável mais rápido em comparação ao seu principal concorrente, o modelo Long Short-Term Memory (LSTM), baseado em Recurrent Neural Network (RNN). Tendo como base os dados fornecidos pela empresa TermoPlex, este estudo apresenta uma abordagem alternativa para lidar com essas leituras problemáticas do sensor, seguindo uma linha de pesquisa similar à realizada por Duan *et al.* (2021), adaptada especificamente para este trabalho. Nessa adaptação, o conjunto de leituras 3 da temperatura realizada por cada sensor é tratado como uma série temporal e é utilizado tanto no treinamento quanto no teste do modelo. Portanto, o ambiente de análise é considerado univariado. Ao adotar essa abordagem alternativa, os usuários do sistema podem obter uma visão mais precisa do ambiente interno do silo, reduzindo assim a necessidade de manutenção elétrica da unidade. Além disso, essa solução traz benefícios econômicos significativos para a gestão da fazenda, como a redução de custos operacionais, a melhoria do processo de armazenamento e a garantia de um produto final de maior qualidade para o consumidor. Após a validação dos dados gerados pelo modelo treinado, o melhor resultado obtido indicou um RMSE de 3.405, um MSE de 11.595 e um MAE de 1.805. É importante ressaltar que, em termos de métricas de avaliação, menores valores indicam um desempenho superior do modelo. Este trabalho está estruturado em seções distintas que desempenham papéis específicos na apresentação e compreensão do estudo. Começamos com a seção "Trabalhos Relacionados", que contextualiza o trabalho em relação a pesquisas anteriores. A seção "Fundamentação

Teórica" estabelece uma base conceitual essencial para a compreensão dos conceitos utilizados. A "Metodologia" detalha o procedimento passo a passo para replicação dos resultados. Em "Desenvolvimento e Configuração do Modelo", descrevemos a estrutura, configurações e a aplicação do modelo. Os "Resultados" incluem pareceres parciais para cada resultado obtido. A "Conclusão" oferece um parecer final para os resultados mais destacados e sugestões para trabalhos futuros.

2 TRABALHOS RELACIONADOS

No presente trabalho, é de extrema importância enfatizar a confiabilidade das previsões geradas pelo modelo, o estudo conduzido por Tjoa e Guan (2020) é de grande relevância, uma vez que oferece uma visão abrangente das pesquisas relacionadas ao tema, categorizando as diversas abordagens de uma maneira que o usuário final consiga confiar no resultado apresentado.

Além disso, o trabalho de Gu *et al.* (2018) destaca os avanços significativos alcançados em modelos de CNNs e suas aplicações bem-sucedidas em diversas áreas. Essa revisão da literatura demonstra a importância de escolher o modelo correto para abordar a problemática em questão e reforça a relevância do TCN como uma escolha sólida.

O trabalho de Duan *et al.* (2021), que propõe a previsão de temperatura de sensores em celeiros, considerando as variáveis espaciais e temporais, ressalta a viabilidade do LSTM em um contexto multivariado. Essa pesquisa adiciona uma perspectiva adicional ao cenário, indicando que modelos como o LSTM também podem ser eficazes.

A pesquisa de Gopali *et al.* (2021), que compara o desempenho do TCN e do LSTM, oferece uma compreensão profunda da qualidade das previsões geradas pelos modelos, e em paralelo estudo de Lara-Benítez *et al.* (2020) é especialmente significativo, uma vez que demonstra a eficácia do TCN na previsão de séries temporais geradas. Essas pesquisas destacam uma pequena vantagem de desempenho do TCN em relação ao LSTM em cenários semelhantes, validando a escolha do TCN como modelo para a problemática proposta.

3 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, buscaremos estabelecer uma base sólida para a compreensão dos conceitos fundamentais que sustentam o contexto em análise. Com o objetivo principal de fornecer aos leitores uma visão abrangente e aprofundada dos elementos-chave discutidos neste trabalho. Dessa forma, garantindo não apenas a confiabilidade, mas também a excelência técnica e científica da pesquisa apresentada.

3.1 TERMOMETRIA EM SILOS

A termometria é uma área da física que estuda temperatura e escalas termométricas (Pires; Afonso; Chaves, 2006). Sendo fundamental no agronegócio, principalmente na pós-colheita, onde a análise termométrica das unidades de armazenamento desempenha um papel crucial na garantia da qualidade dos grãos armazenados. Sensores digitais de temperatura são comumente usados para realizar essas medições, de maneira precisa e automatizada nos silos (Ferrasa; Biaggioni; Dias, 2010).

412

No entanto, é importante reconhecer que esses sensores estão sujeitos a uma variedade de desafios, como instalação elétrica inadequada, construção deficiente dos sensores ou interferências momentâneas na comunicação dos dispositivos. Esses problemas têm o potencial de afetar de forma significativa a confiabilidade do sistema de termometria em silos, o que pode demandar intervenções de manutenção ou a exploração de alternativas, como a aplicação de inteligência artificial para a previsão de temperatura (Duan *et al.*, 2021). Medições essas que também exibem características típicas de séries temporais (Bhandari *et al.*, 2017).

3.2 SÉRIES TEMPORAIS

Séries temporais desempenham um papel fundamental no contexto da termometria em silos, uma vez que as medições de temperatura frequentemente se comportam como séries temporais. Essas séries representam dados coletados ao longo do tempo, onde cada ponto de dados está relacionado temporalmente ao

anterior, e podem ser influenciadas por fatores sazonais, tendências, sazonalidades e ruído (Mahalakshmi; Sridevi; Rajaram, 2016). A análise dessas séries permite que algoritmos de aprendizado de máquina identifiquem padrões e prevejam variações de temperatura com base em dados históricos (Gopali *et al.*, 2021).

O teste Augmented Dickey-Fuller (ADF) é uma ferramenta crucial na análise de séries temporais. Ele é utilizado para verificar se uma série temporal é estacionária, um requisito fundamental para muitos modelos de previsão e análises preditivas. O ADF avalia a presença de tendência ou sazonalidade significativa na série, o que pode impactar a eficácia de modelos de previsão. Ao calcular a estatística ADF e o valor-p, é possível determinar se a série é estacionária ou se requer ajustes para torná-la adequada para análises futuras. (Mushtaq, 2011)

3.3 SÉRIES TEMPORAIS

A Inteligência Artificial (IA) é um campo da ciência da computação que busca criar sistemas capazes de realizar tarefas que normalmente exigiriam inteligência humana, inteligência sendo o ato de pensar, alcançar objetivos, como realizar tarefas intelectuais, seja conversar, resolver problemas e tomar decisões (Turing, 1950).

413

3.4 APRENDIZADO DE MÁQUINA

O Aprendizado de Máquina é um subcampo da IA que se concentra no desenvolvimento de algoritmos e modelos que podem gradualmente melhorar sua precisão com base em dados. O aprendizado de máquina é um campo crescente na área de ciência de dados e IA, usando métodos estatísticos para realizar previsões e classificações. Uma das técnicas amplamente empregadas para a realização dessas tarefas é a Rede Neural, cujo nome e estrutura são inspirados no funcionamento do cérebro humano. Elas são compostas por uma camada de nós que inclui uma camada de entrada (input), uma ou mais camadas ocultas e uma camada de saída (output). Cada nó funciona como um neurônio artificial que processa o input recebido e o repassa para o próximo nó interconectado (IBM, 2023c).

O processo pelo qual as redes neurais aprimoram seus resultados com o

tempo envolve a adaptação dos pesos das conexões entre os neurônios. Os pesos representam a força das conexões entre os neurônios e são ajustados durante o treinamento com base nos dados de entrada e nas saídas desejadas. Além disso as redes neurais utilizam funções de ativação para determinar se um neurônio deve ou não enviar um sinal adiante, com base no resultado gerado pela função determinada. O processo de treinamento visa encontrar os pesos ideais e ajustar a função de ativação para que a rede seja capaz de se adaptar ao padrão de dado apresentado a ela (IBM, 2023d).

Com o avanço do aprendizado de máquina, surgiu um subcampo conhecido como Aprendizado Profundo (Deep Learning), que se caracteriza principalmente pelo uso de redes neurais com três ou mais camadas. Uma das variantes mais proeminentes do Aprendizado Profundo é a Rede Neural Convolutiva, amplamente empregada para identificar características e padrões complexos em vastos conjuntos de dados (IBM, 2023b).

3.5 CONVOLUTIONAL NEURAL NETWORK

414

As CNNs, são uma classe de algoritmos de aprendizado profundo amplamente empregados em tarefas de visão computacional, processamento de imagens e análise de séries temporais, como as leituras de temperatura em silos. Elas se destacam por sua notável eficácia na extração de características de dados que possuem uma estrutura espacial ou temporal (IBM, 2023a).

A principal diferença entre problemas de visão computacional e problemas de séries temporais reside na natureza dos dados de entrada fornecidos ao modelo. Em visão computacional, os modelos geralmente recebem uma matriz de pixels que representa uma imagem, enquanto em previsão de séries temporais, o modelo é alimentado com uma série de dados unidimensional. No entanto, a abordagem de aplicar CNNs à análise de séries temporais é uma maneira inovadora de extrair informações úteis desses dados. Em vez de tratar a série temporal como uma sequência de pontos de dados isolados, a abordagem citada trata a série temporal como uma espécie de imagem unidimensional que pode ser lida e filtrada pela CNN (Wibawa *et al.*, 2022).

Isso significa que, assim como as CNNs são altamente eficazes na extração de características de imagens, elas podem ser adaptadas para extrair padrões e informações significativas de séries temporais. Essa abordagem é utilizada em um algoritmo derivado da CNN, o Temporal Convolutional Network (TCN), que é específico para o processamento de séries temporais e é projetado para capturar dependências temporais em dados unidimensionais (Lea *et al.*, 2016).

3.6 TEMPORAL CONVOLUTIONAL NETWORK

A primeira proposta do TCN foi voltado para segmentação de ações em vídeos. O processo convencional para essa tarefa consiste em duas etapas: primeiramente, o cálculo de características de baixo nível usando geralmente uma CNN que codifica informações espaço-temporais e, em seguida, a entrada dessas características de baixo nível em um classificador que captura informações temporais de alto nível usando, em geral, uma RNN. Essa proposta permite a obtenção de características de baixo nível e a modelagem de informações de alto nível em uma única estrutura de rede, eliminando a necessidade de dois modelos distintos. Dessa forma, as TCNs simplificam o processo de segmentação de ações em vídeos, ao mesmo tempo em que mantêm a capacidade de capturar informações complexas em múltiplos níveis (Lea *et al.*, 2016).

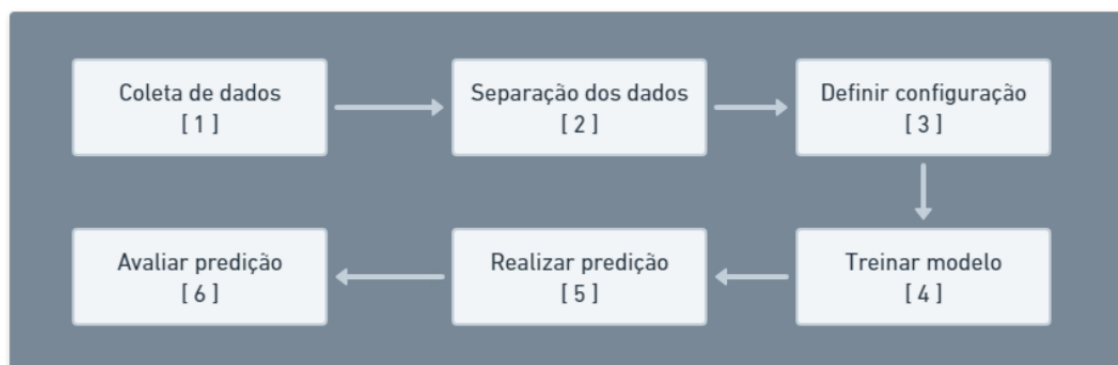
415

Para o processamento de séries temporais o TCN apresenta duas principais categorias, a primeira conhecida como Encoder-Decoder TCN (ED-TCN), emprega hierarquias de convoluções temporais, pooling e reamostragem para capturar padrões temporais de longo alcance seguido por filtros ou os chamados kernels de convolução. A segunda categoria utiliza Dilated TCN, a principal diferença é que ao invés de pooling e reamostragem, aplica dilatações (buracos) entre os valores do filtro, permitindo que a operação de convolução tenha um campo receptivo maior sem aumentar o tamanho do filtro, facilitando o processamento de grandes volumes de dados temporais. Ambas abordagens permitem que o TCN capture relacionamentos complexos na série temporal, mas diferem em como hierarquizam e processam os dados (Gopali *et al.*, 2021).

4 METODOLOGIA

Com base nos objetivos do trabalho, será realizado um estudo que envolve uma pesquisa quantitativa. O presente projeto realizará a uma abordagem da seguinte maneira.

Figura 1 – Metodologia



Fonte: Autor (2023)

1. Realizar uma coleta de dados das leituras de temperatura de cabos pêndulo com sensores, instalados dentro de um silo. É importante que essa coleta seja realizada em um grande espaço de tempo para transparecer mais a relação entre os dados através da série temporal. No presente trabalho foi realizada a coleta de dados das leituras de temperatura em um silo equipado com seis cabos, sendo que cada cabo contém onze sensores. Essa coleta de dados foi realizada ao longo de dois anos, com cada sensor realizando a leitura em média a cada 1 hora e 14 minutos;
2. Realizar a separação dos dados e análise dos dados caso seja necessário ajustar ou escalar a base de alguma maneira. A coleta de dados resultou em uma base de cerca de um milhão e trezentas mil amostras ao longo de dois anos, com cada sensor contendo aproximadamente 19 mil amostras com aproximadamente 0.05% de dados faltantes, pouco afetando o desempenho do modelo sendo possível ignorá-los durante o pré-processamento. Durante a análise dos dados, foram encontrados dois padrões de temperatura distintos. O primeiro, nomeado padrão interno, corresponde à temperatura dentro da massa de grãos e é influenciado pela temperatura do próprio grão. O segundo

416

padrão, nomeado como padrão externo, refere-se à temperatura fora da massa de grãos e é influenciado pela temperatura ambiente.

Para o treinamento é importante adotar uma abordagem que permita expor o modelo a uma quantidade significativa de dados e, ao mesmo tempo, testar sua capacidade de previsão em amostras que apresentam ambos padrões de temperatura, nesse caso separamos aproximadamente 16 mil amostras para o treinamento, enquanto reservamos 3 mil para testes ambas expressando significativamente os padrões identificados. Também foi realizado uma agregação do valor médio das leituras repetidas na mesma hora, gerando uma base com uma amostra por hora;

3. Definir uma configuração para o modelo de rede neural selecionado, no caso do presente trabalho o TCN. Para definir a configuração é importante conhecer a documentação do modelo utilizado para entender todos os hiperparâmetros disponíveis pelo modelo e suas funções. Conforme discutido na seção "Desenvolvimento e Configuração de Modelo", os valores dos hiperparâmetros foram escolhidos de forma arbitrária e empírica, alinhados com o propósito de cada uma das quatro configurações definidas no trabalho: uma configuração básica para melhor desempenho e compreensão simples, uma configuração mais complexa com maior poder computacional envolvendo mais camadas e neurônios na rede, e uma configuração mais regularizada para prevenir overfitting;
4. Treinar o modelo utilizando as configurações definidas anteriormente. A base de dados de 16 mil amostras foi empregada para o treinamento, enquanto um conjunto separado de 3 mil amostras foi reservado para fins de teste. O treinamento foi realizado utilizando "Adam" como otimizador para ajustar os pesos da rede neural, minimizando a função de perda MAE, durante o número de épocas definidas na configuração de cada modelo;
5. Para prever dados futuros é necessário utilizar conjuntos de dados de teste que não foram vistos durante o treinamento. O modelo aplicará sua aprendizagem para prever valores de temperatura em um ambiente do silo com base em entradas específicas;
6. A validação dos resultados obtidos se baseou nas métricas amplamente

utilizadas na literatura, nomeadamente o Erro Médio Absoluto (MAE), o Erro Médio Quadrático (MSE) e a Raiz do Erro Quadrático Médio (RMSE) (Shcherbakov *et al.*, 2013). O MAE oferece uma medida direta do erro médio entre as previsões do modelo e os valores reais, tornando-se uma métrica valiosa para avaliar o desempenho geral do modelo. Por sua vez, o MSE calcula a média das diferenças quadráticas entre as previsões e os valores de destino, proporcionando uma compreensão da dispersão do erro. O RMSE fornece uma métrica em unidades de medida originais, facilitando a interpretação das previsões

5 DESENVOLVIMENTO E CONFIGURAÇÕES DO MODELO TCN

Nesta seção, descreveremos quatro configurações de modelos TCN com diferentes níveis de complexidade e técnicas de regularização. Esses modelos foram projetados para tarefas de previsão temporal, com o objetivo de analisar séries temporais e fazer previsões numéricas contínuas. Todas as configurações são compiladas com o otimizador Adam visando proporcionar uma base sólida e consistente para o desenvolvimento do modelo.

Para o desenvolvimento do modelo, utilizou-se a biblioteca Darts na linguagem de programação Python. Darts é uma biblioteca que coloca foco na experiência do usuário e é especialmente projetada para previsão e detecção de anomalias, oferecendo uma ampla variedade de modelos que podem ser aplicados a séries temporais, juntamente com diversas ferramentas úteis (Herzen *et al.*, 2022). Todos os experimentos e testes foram realizados no ambiente interativo Colab disponibilizado pela Google.

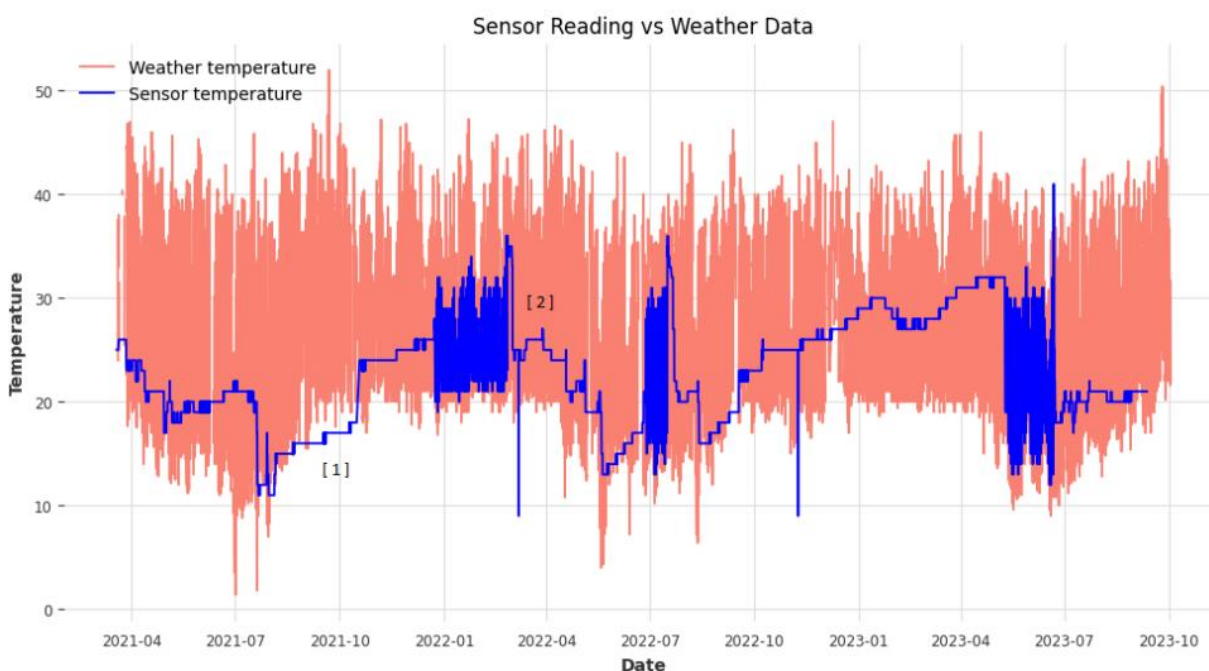
Durante a separação dos dados foi analisado que em alguns momentos durante os dois anos do estudo, duas ou mais amostras foram coletadas dentro da mesma hora, sendo necessário agrupar esses valores para instanciar um objeto TimeSeries, obrigatório para o treinamento do modelo TCN da biblioteca Darts, esse agrupamento foi realizado considerando a média desses valores. Também para criação do objeto TimeSeries foi necessário desconsiderar os minutos, segundos e milissegundos coletados, considerando agora apenas o dia, mês, ano e hora da

amostra.

Após ajustar adequadamente os dados e analisar seu comportamento, foram identificados dois padrões distintos na distribuição das temperaturas. O primeiro padrão, denominado "externo", refere-se ao sensor posicionado fora da massa de grãos. Este sensor é diretamente impactado pela temperatura ambiente, embora esteja parcialmente isolado dentro da estrutura metálica do silo, a qual possui propriedades reflexivas que visam reduzir a influência da temperatura ambiente em seu interior.

Por outro lado, o segundo padrão, denominado "interno", deve seu nome à localização do sensor no interior da massa de grãos. Este sensor está sujeito à influência direta da temperatura dos grãos, o que resulta em um comportamento mais estável, como ilustrado na Figura 2.

Figura 2 – Relação temperatura Sensor x Ambiente



Fonte: Autor (2023)

Com base nesta análise, identificamos sensores que apresentam predominantemente um histórico no padrão externo, bem como sensores que exibem predominantemente um histórico no padrão interno. No âmbito deste estudo, foram selecionados dois sensores exemplares, um representando predominantemente cada um dos padrões existentes, a fim de avaliar qual configuração de modelo se adapta

melhor a cada tipo de histórico.


Os sensores posicionados na parte superior do cabo, que refletem predominantemente o padrão externo, tendem a ser mais sensíveis às variações da temperatura ambiente, uma vez que estão sujeitos a influências externas mais diretas.

Em contrapartida, os sensores localizados na parte inferior do cabo, representando o padrão interno, exibem um desvio padrão menor em suas leituras. Isso sugere que esses sensores são menos suscetíveis às flutuações da temperatura ambiente devido à proteção fornecida pela massa de grãos circundante.

Na Figura 3, é apresentado o cálculo do desvio padrão das leituras desses sensores ao longo dos dois anos analisados. Esse desvio padrão é uma medida útil para avaliar a variabilidade das leituras e, conseqüentemente, a estabilidade das condições de temperatura em cada um dos padrões. Observando a plotagem gráfica dos sensores foi identificado que sensores com o desvio padrão acima de 5,5 são sensores com o padrão predominante externo e os demais possuem um padrão predominantemente interno, provavelmente devido a disposição desses sensores dentro do silo e a quantidade de grão que foi armazenado nele nesse espaço de tempo.

420

Figura 3 – Desvio padrão dos sensores



Fonte: Autor (2023)

Para definir as configurações do modelo foram analisados empiricamente os

hiperparâmetros mais influentes no resultado:

- Input Sequence: O número de amostras anteriores que o modelo considera durante o treinamento;
- Número de filtros: Refere-se à quantidade de filtros em cada camada convolucional da arquitetura do TCN. Cada filtro representa uma unidade de processamento que aprende padrões específicos, possibilitando que a rede neural aprenda uma ampla variedade de padrões;
- Tamanho do kernel: Determina quantas amostras são consideradas durante o processo de convolução. Ele influencia a capacidade da rede em detectar padrões de diferentes escalas temporais;
- Expoente de dilatação: Determinar a distância entre as dilatações temporais. Valores menores indicam que a rede está procurando relações mais próximas entre as amostras, enquanto valores maiores buscam padrões mais espaçados no tempo,
- Taxa de Dropout: Probabilidade de desligar neurônios aleatoriamente durante o treinamento para evitar o overfitting, tornando-o menos dependente de características ou neurônios específicos.

421

Além desses hiperparâmetros, é importante considerar o número de épocas. As épocas representam o número de vezes que o modelo percorre todo o conjunto de dados durante o treinamento e permite que o modelo ajuste seus pesos. Para este estudo, foram selecionadas 1000 épocas.

No entanto, vale destacar que após o processo de experimentação, observou-se que o desempenho do modelo não apresentou melhorias significativas com um número de épocas superior a 1000. Isso sugere que o treinamento já convergiu para um estado satisfatório e não se beneficia substancialmente de mais épocas, garantindo um uso eficiente dos recursos computacionais.

Após essas análises foram estruturadas as seguintes configurações:

5.1 CONFIGURAÇÃO 0 - PADRÃO

Esta configuração serve como ponto de partida para a comparação de desempenho com as configurações subsequentes. Nessa configuração, apenas o

hiperparâmetro obrigatório, o Input Sequence, é especificado, enquanto os demais hiperparâmetros são deixados à escolha do modelo.

5.2 CONFIGURAÇÃO 1 - BÁSICA

Na primeira configuração, apresentamos um modelo TCN com uma abordagem básica, ideal para problemas simples. Os principais detalhes dessa configuração incluem:

- Input Sequence: 24;
- Número de filtros: 64;
- Tamanho do kernel: 5;
- Expoente de dilatação: 2;
- Taxa de Dropout: 0.1.

5.3 CONFIGURAÇÃO 2 - AUMENTANDO COMPLEXIDADE

422

Na segunda configuração, aumentamos a complexidade do modelo TCN, visando aumentar principalmente o expoente de dilatação para tentar encontrar relações mais distantes entre os dados utilizados. Essa configuração foi pensada para problemas mais desafiadores e ricos em dados. Os principais detalhes dessa configuração são:

- Input Sequence: 24;
- Número de filtros: 128;
- Tamanho do kernel: 7;
- Expoente de dilatação: 16;
- Taxa de Dropout: 0.4.

5.4 CONFIGURAÇÃO 3 – REGULARIZAÇÃO

Na terceira configuração, focamos em aumentar a taxa de dropout para tentar reduzir a probabilidade da rede neural se tornar dependente de alguns neurônios ou características específicas. Os principais detalhes dessa configuração incluem:

- Input Sequence: 24;
- Número de filtros: 32;
- Tamanho do kernel: 3;
- Expoente de dilatação: 8;
- Taxa de Dropout: 0.8.

6 RESULTADOS

Nesta seção, apresentaremos as descobertas e resultados decorrentes da aplicação das configurações do modelo. Após a seleção de hiperparâmetros, este estudo busca avaliar o desempenho do modelo na previsão de temperaturas. Além disso, serão analisadas as diferenças entre os sensores posicionados internamente e externamente no silo, visando identificar as melhores configurações para cada cenário e será utilizado o teste ADF para determinar se o comportamento da base de dados de cada padrão é adequada.

423


6.1 PADRÃO EXTERNO

Para avaliar a estacionariedade, consideramos o valor-p. Quanto menor o valor-p, mais forte é a evidência de que a série é estacionária. No caso do padrão externo o valor-p é muito baixo, sugerindo fortemente a estacionariedade da série.

- Estatística ADF: -4.369568892744335
- Valor-p: 0.0003358863306078097

Na Figura 4, são apresentadas todas as leituras de um sensor com predominância do padrão externo. Este sensor é utilizado como referência para os demais sensores que seguem o mesmo padrão durante o processo de treinamento do modelo.

Figura 4 – Sensor exemplo para padrão externo



Fonte: Autor (2023)

424

Agora, procederemos à apresentação dos resultados das previsões geradas pelas quatro configurações distintas. Inicialmente, exibiremos uma representação visual dos resultados das previsões junto aos dados reais correspondentes. Essa visualização possibilitará uma análise mais nítida da capacidade do modelo em seguir as variações das temperaturas ao longo do tempo.

Em sequência, disponibilizaremos uma tabela que apresenta os valores das três métricas usadas para avaliar o desempenho do modelo, nomeadamente o RMSE, o MAE e o MSE. Essas métricas fornecem uma avaliação quantitativa da precisão das previsões em relação aos valores reais, contribuindo para uma análise objetiva dos resultados considerando que quanto menor a taxa de erro fornecida pela métrica melhor foi a previsão gerada pelo modelo.

6.1.1 Configuração 0

Os resultados obtidos com essa configuração não conseguiram alcançar resultados minimamente satisfatórios como observado nas métricas obtidas, isso indica a importância da escolha e otimização adequada dos hiperparâmetros.

Tabela 1 – Resultados das Métricas de Avaliação da Configuração 0 - Externo.

Métrica	Valor
RMSE	9,835
MSE	74,170
MAE	8,862

Fonte: Autor (2023)

6.1.2 Configuração 1

A configuração 1, embora tenha o menor custo computacional, demonstrou um desempenho pouco satisfatório, como evidenciado pelas métricas de avaliação.

O comportamento da previsão, quando comparado com os valores reais, apresentou discrepâncias consideráveis, especialmente nos picos e vales. Isso sugere que o modelo não tinha um domínio completo do funcionamento do padrão, dificultando a precisão de suas previsões.

425

Tabela 2 – Resultados das Métricas de Avaliação da Configuração 0 - Externo.

Métrica	Valor
RMSE	8,502
MSE	72,290
MAE	6,992

Fonte: Autor (2023)

6.1.3 Configuração 2


A configuração 2, como apresentado na Figura 5, se destacou ao revelar a sua capacidade de identificar relações mais distantes entre os dados, o que a levou a alcançar o melhor desempenho em relação às métricas de avaliação. No entanto, é importante ressaltar que esse êxito no desempenho veio acompanhado do custo computacional mais elevado entre todas as configurações. A configuração 2, ao se concentrar em compreender padrões mais complexos e distantes, pôde capturar nuances que as outras configurações não conseguiram abranger.

Tabela 3 – Resultados das Métricas de Avaliação da Configuração 2 - Externo.

Métrica	Valor
RMSE	8,329
MSE	69,374
MAE	6,936

Fonte: Autor (2023)

Figura 5 – Configuração 2 - Externo



Fonte: Autor (2023)

6.1.4 Configuração 3

A configuração 3, cujo custo computacional se situou em uma faixa intermediária como esperado, não conseguiu alcançar resultados tão satisfatórios. Isso pode ser atribuído à forma como os dados foram segregados e ao comportamento da série temporal nesse padrão externo.

Além disso, o fato de que essa configuração não obteve um melhor resultado com o aumento da taxa de dropout pode indicar que o modelo não estava sofrendo de overfitting de forma significativa. Essa característica sugere que o desafio estava mais relacionado à adaptação do modelo ao comportamento peculiar do padrão externo, exigindo uma abordagem mais específica.

Tabela 4– Resultados das Métricas de Avaliação da Configuração 3 - Externo.

Métrica	Valor
RMSE	8,375
MSE	70,153
MAE	6,892

Fonte: Autor (2023)

6.2 PADRÃO INTERNO


No caso do Padrão Interno, o valor-p é ainda menor, o que também fornece forte evidência de estacionariedade, provavelmente pois as variações de temperatura tendem a ser menos extremas e mais regulares dentro da massa de grãos.

- Estatística ADF: -6.365560008009675
- Valor-p: 2.4148111903945397e-08

Na Figura 6, são apresentadas todas as leituras de um sensor com predominância do padrão externo. Este sensor é utilizado como referência para os demais sensores que seguem o mesmo padrão durante o processo de treinamento do modelo.

427

Figura 6 - Sensor exemplo para padrão interno



Fonte: Autor (2023)

A seguir, apresentaremos os resultados obtidos no padrão interno, com a aplicação das quatro configurações distintas, com o intuito de analisar o desempenho de cada uma delas nesse cenário específico. Essa análise permitirá uma compreensão mais aprofundada de como as configurações se comportaram diante das particularidades desse padrão de temperatura e fornecerá reflexões valiosas sobre suas capacidades e limitações.

6.2.1 Configuração 0

Novamente a configuração 0 demonstra métricas com valores pouquíssimos satisfatórios para o intuito do trabalho, ressaltando a necessidade de escolher e otimizar adequadamente os hiperparâmetros.

Tabela 5– Resultados das Métricas de Avaliação da Configuração 0 - Interno.

Métrica	Valor
RMSE	3,822
MSE	14,614
MAE	2,119

Fonte: Autor (2023)

428

6.2.2 Configuração 1

Após uma análise dos resultados, nossa avaliação divergiu do padrão observado no contexto externo, na configuração 1, notamos que as métricas apresentaram um desempenho relevante, e o modelo conseguiu identificar e prever padrões de forma mais adequada, tudo isso com um custo computacional mais baixo, reforçando a eficiência dessa configuração. Esse resultado contrapõe a tendência anteriormente observada no padrão externo, onde a configuração 1 demonstrou um desempenho menos satisfatório.

Tabela 6 – Resultados das Métricas de Avaliação da Configuração 1 - Interno.

Métrica	Valor
RMSE	3,971
MSE	12,767
MAE	2,097

Fonte: Autor (2023)

6.2.3 Configuração 2

No caso da configuração 2, embora tenha apresentado métricas superiores em relação à configuração 1, seu custo computacional foi o mais elevado entre as quatro configurações. Essa configuração, que se destacou por sua capacidade de encontrar relações mais distantes entre os dados, enfrentou desafios notáveis na identificação de certos comportamentos na base de dados do padrão interno. Essa dificuldade pode ser atribuída à natureza das relações de dados nesse contexto, onde as 21 leituras de temperatura exibem predominantemente proximidade e estabilidade, dificultando a aplicação da abordagem mais complexa da configuração 2.

429

Tabela 7 – Resultados das Métricas de Avaliação da Configuração 2 - Interno.

Métrica	Valor
RMSE	3,535
MSE	12,499
MAE	1,858

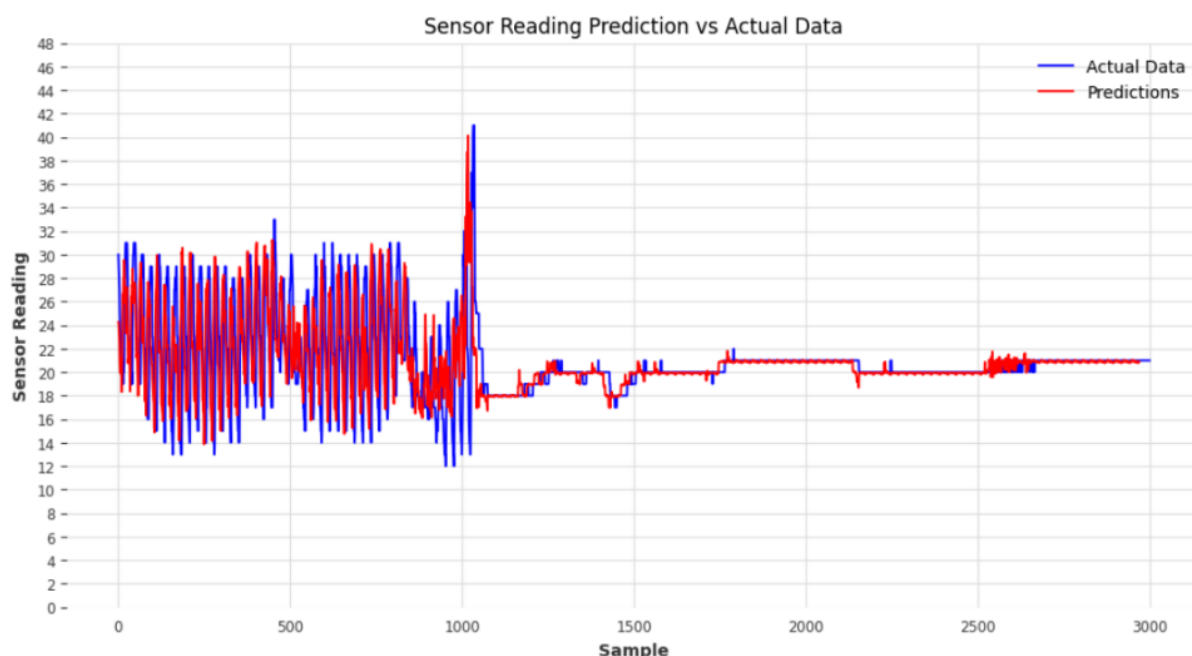
Fonte: Autor (2023)

6.2.4 Configuração 3

A configuração 3, com um custo computacional moderado, surpreendeu positivamente ao obter os melhores resultados dentre as quatro configurações. Observando o gráfico, fica evidente que o modelo buscou manter uma abordagem mais conservadora em relação ao comportamento da série temporal. Isso resultou em sua capacidade de se manter estável em termos de precisão, proporcionando o resultado mais satisfatório entre as quatro configurações, considerando que a parte mais crucial dessa previsão está relacionada à precisão do padrão interno, que é de

grande importância para o usuário final, visto que a temperatura do grão é uma informação de extrema importância para manter a qualidade do mesmo.

Figura 7 - Configuração 3 - Interno



430

Fonte: Autor (2023)

Tabela 8 – Resultados das Métricas de Avaliação da Configuração 3 - Interno.

Métrica	Valor
RMSE	3,405
MSE	11,595
MAE	1,805

Fonte: Autor (2023)

Após uma análise criteriosa dos resultados gerais, tornou-se claro que a abordagem mais eficaz seria a implementação de dois modelos especializados, um para cada um dos padrões de temperatura. Isso decorre da observação de que duas configurações diferentes demonstraram o melhor desempenho em seus respectivos ambientes, ressaltando a imprevisibilidade desse cenário.

7 CONCLUSÃO

A estratégia de empregar modelos especializados para cada padrão demonstrou ser a mais eficaz e adequada para atender às demandas de ambientes imprevisíveis e distintos. Mas além da necessidade dos dois modelos para cada padrão de temperatura, nenhum dos experimentos trouxe um resultado completamente satisfatório, todos tiveram pontualmente seus problemas, porém, o maior destaque vai para a configuração 3 dentro do padrão interno, pois para o usuário final a previsão mais importante seria a da temperatura do sensor imerso no grão, onde essa configuração trouxe pouca diferença do dado real apesar da sua oscilação.

Para trabalhos futuros, uma abordagem promissora seria a busca por um modelo mais abrangente capaz de compreender e prever tanto os padrões internos quanto externos de temperatura, superando a necessidade de dois modelos especializados. Isso poderia envolver a exploração de diferentes arquiteturas de redes neurais ou técnicas de aprendizado de máquina que sejam mais flexíveis em relação a padrões diversos que podem também considerar outras variáveis que influenciem o comportamento da leitura realizada pelo sensor.

431

REFERÊNCIAS

BHANDARI, S. *et al.* Time series data analysis of wireless sensor network measurements of temperature. **Sensors**, MDPI, v. 17, n. 6, p. 1221, 2017.

CONAB. **Portal de armazéns do Brasil**. 2023. Disponível em: <https://www.conab.gov.br/armazenagem>. Acesso em: 12 maio 2023.

DUAN, S. *et al.* Temperature forecasting for stored grain: A deep spatiotemporal attention approach. **IEEE Internet of Things Journal**, IEEE, v. 8, n. 23, p. 17147–17160, 2021.

FERRASA, M.; BIAGGIONI, M. A. M.; DIAS, A. H. Sistema de monitoramento da temperatura e umidade em silos graneleiros via radiofrequencia. **Energia na Agricultura**, p. 139–156, 2010.

GOPALI, S. *et al.* A comparison of tcn and lstm models in detecting anomalies in time series data. *In*: INTERNATIONAL CONFERENCE ON BIG DATA (Big Data), 2021. **Anais [...]**. [S.l.]: IEEE, 2021. p. 2415–2420.

GU, J. *et al.* Recent advances in convolutional neural networks. **Pattern recognition**, Elsevier, v. 77, p. 354–377, 2018.

HERZEN, J. *et al.* Darts: User-friendly modern machine learning for time series. **Journal of Machine Learning Research**, v. 23, n. 124, p. 1–6, 2022.

IBM. **What is convolutional neural network**. 2023. Disponível em: <http://jmlr.org/papers/v23/21-1177.html>. Acesso em: 7 out. 2023.

IBM. **What is deep learning**. 2023. Disponível em: <https://www.ibm.com/topics/deep-learning>. Acessado em: 7 out. 2023.

IBM. **What is machine learning**. 2023. Disponível em: <https://www.ibm.com/topics/machine-learning>. Acesso em: 7 out. 2023.

IBM. **What is neural network**. 2023. Disponível em: <https://www.ibm.com/topics/neural-networks>. Acesso em: 7 out. 2023.

LARA-BENÍTEZ, P. *et al.* Temporal convolutional networks applied to energy-related time series forecasting. **Applied Sciences**, MDPI AG, v. 10, n. 7, p. 2322, mar. 2020.

LEA, C. *et al.* **Temporal convolutional networks: A unified approach to action segmentation**. *In*: Computer Vision–ECCV 2016. Workshops: Amsterdam, The Netherlands, October 8-10 and 15-16, 2016, Proceedings, Part III 14. [S.l.], 2016. p. 47–54.

432

MAHALAKSHMI, G.; SRIDEVI, S.; RAJARAM, S. A survey on forecasting of time series data. *In*: INTERNATIONAL CONFERENCE ON COMPUTING TECHNOLOGIES AND INTELLIGENT DATA ENGINEERING, 2016. **Anais [...]**. [S.l.]: IEEE, 2016. p. 1–8.

MAPA. **Instrução Normativa nº 29**, de 8 de junho de 2011. 2011. Diário Oficial da União. Brasília, DF, 9 jun. 2011. Seção 1, p. 14.

MUSHTAQ, R. **Augmented dickey fuller test**. 2011.

PIRES, D. P. L.; AFONSO, J. C.; CHAVES, F. A. B. A termometria nos séculos XIX e XX. **Revista Brasileira de Ensino de Física**, SciELO Brasil, v. 28, p. 101–114, 2006.

SHCHERBAKOV, M. V. *et al.* A survey of forecast error measures. **World applied sciences journal**, v. 24, n. 24, p. 171–176, 2013.

TJOA, E.; GUAN, C. A survey on explainable artificial intelligence (xai): Toward medical xai. **IEEE transactions on neural networks and learning systems**, IEEE, v. 32, n. 11, p. 4793–4813, 2020.

TURING, A. M. Computing machinery and intelligence. **Mind**, Oxford University Press, v. 49, n. 236, p. 433–460, 1950.

WIBAWA, A. P. *et al.* Time-series analysis with smoothed convolutional neural network. **Journal of big Data**, Springer, v. 9, n. 1, p. 44, 2022.

ANEXO – Link para o Repositório

Para acessar o código-fonte do projeto, visite o seguinte repositório GitHub:

<https://github.com/gustavo-qs/TCC>