

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
CURSO DE GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Josiane Cristine Aggens

**INVESTIGAÇÃO DE REDES KOLMOGOROV-ARNOLD E REDES
KOLMOGOROV-ARNOLD TEMPORAIS APLICADAS À PREVISÃO DA
INCIDÊNCIA DE DENGUE NO RIO GRANDE DO SUL: UM ESTUDO DE
MODELOS PREDITIVOS.**

Santa Maria, RS
2024

Josiane Cristine Aggens

**INVESTIGAÇÃO DE REDES KOLMOGOROV-ARNOLD E REDES
KOLMOGOROV-ARNOLD TEMPORAIS APLICADAS À PREVISÃO DA INCIDÊNCIA
DE DENGUE NO RIO GRANDE DO SUL: UM ESTUDO DE MODELOS PREDITIVOS.**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Ciência da Computação, Área de Concentração em Ciências Exatas e da Terra, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Bacharel em Ciência da Computação**.

Orientador: Prof. Joaquim Vinicius Carvalho Assunção

Santa Maria, RS
2024

Josiane Cristine Aggens

**INVESTIGAÇÃO DE REDES KOLMOGOROV-ARNOLD E REDES
KOLMOGOROV-ARNOLD TEMPORAIS APLICADAS À PREVISÃO DA INCIDÊNCIA
DE DENGUE NO RIO GRANDE DO SUL: UM ESTUDO DE MODELOS PREDITIVOS.**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Ciência da Computação, Área de Concentração em Ciências Exatas e da Terra, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Bacharel em Ciência da Computação**.

Aprovado em 12 de dezembro de 2024:

Joaquim Vinicius Carvalho Assunção, Dr. (UFSM)
(Presidente/Orientador)

Leonardo Ramos Emmendorfer, Dr. (UFSM)

Luís Alvaro de Lima Silva, Dr. (UFSM)

Santa Maria, RS
2024

RESUMO

INVESTIGAÇÃO DE REDES KOLMOGOROV-ARNOLD E REDES KOLMOGOROV-ARNOLD TEMPORAIS APLICADAS À PREVISÃO DA INCIDÊNCIA DE DENGUE NO RIO GRANDE DO SUL: UM ESTUDO DE MODELOS PREDITIVOS.

AUTORA: Josiane Cristine Aggens

Orientador: Joaquim Vinicius Carvalho Assunção

A dengue é uma doença recorrente no Brasil, caracterizada por padrões sazonais que podem estar relacionados a fatores climáticos. Apesar de ser um problema persistente, a previsão de surtos de dengue ainda representa um desafio significativo. Este estudo tem como objetivo investigar o uso de modelos de aprendizado de máquina, especificamente as *Kolmogorov Arnold Networks (KAN)* e as *Temporal Kolmogorov Arnold Networks (TKAN)*, em conjunto com técnicas de visualização, e a *Explainable Artificial Intelligence (XAI)*, para prever picos de incidência da doença no estado do Rio Grande do Sul. Além da previsão, a pesquisa busca oferecer uma compreensão mais aprofundada sobre a relação entre as condições climáticas e a propagação da dengue, contribuindo para um entendimento mais completo da dinâmica da doença na região. O estudo também explora métodos para explicar e representar os resultados dos modelos, promovendo maior confiabilidade nas ferramentas de aprendizado de máquina utilizadas.

Palavras-chave: Aprendizado de Máquina, Modelos preditivos, IA explicativa, Redes Kolmogorov-Arnold

ABSTRACT

INVESTIGATION OF KOLMOGOROV-ARNOLD NETWORKS AND KOLMOGOROV-ARNOLD TEMPORAL NETWORKS APPLIED TO THE PREDICTION OF DENGUE INCIDENCE IN RIO GRANDE DO SUL: A STUDY OF PREDICTIVE MODELS.

AUTHOR: Josiane Cristine Aggens

ADVISOR: Joaquim Vinicius Carvalho Assunção

Dengue is a recurring disease in Brazil, characterized by seasonal patterns that may be linked to climatic factors. Despite being a long-standing issue, predicting dengue outbreaks remains a significant challenge. This study aims to investigate the use of machine learning models, specifically *Kolmogorov Arnold Networks (KAN)* and *Temporal Kolmogorov Arnold Networks (TKAN)*, combined with visualization techniques such as *Explainable Artificial Intelligence (XAI)*, to forecast disease incidence peaks in the state of Rio Grande do Sul. In addition to prediction, this research seeks to provide insights into the relationship between climatic conditions and the spread of dengue, contributing to a deeper understanding of the disease's dynamics in the region. Furthermore, the study explores methods to explain and represent the model outcomes, enhancing the reliability of machine learning tools in this context.

Keywords: Machine Learning, Predictive models, eXplainable AI, Kolmogorov-Arnold Networks

LISTA DE FIGURAS

Figura 1 – Representação de uma Rede de Kolmogorov-Arnold gerada pelo <i>model.plot</i> , da biblioteca <i>pykan</i>	17
Figura 2 – Arquitetura da Temporal Kolmogorov-Arnold Network (TKAN)	20
Figura 3 – Tela do painel de casos de Dengue no Rio Grande do Sul	24
Figura 4 – Mapa de estações meteorológicas no Rio Grande do Sul	25
Figura 5 – Algumas variáveis meteorológicas contidas no conjunto de dados gerado .	29
Figura 6 – Exemplo de um resultado desejável	30
Figura 7 – A poda gerada a partir do resultado da Figura 6	30
Figura 8 – Resultado preliminares obtidos a partir de testes iniciais utilizando dados da dengue, após a poda	30
Figura 9 – KAN antes da poda	33
Figura 10 – KAN depois da poda	33
Figura 11 – MTKAN antes da poda	34
Figura 12 – MTKAN depois da poda	34
Figura 13 – Configuração da TKAN em Python	36
Figura 14 – Resultados com 1 passo futuro	36
Figura 15 – Resultados com 2 passos futuros	36
Figura 16 – Resultados com 12 passos futuros	37
Figura 17 – Predição da temperatura no estado	38
Figura 18 – Resultados das redes multivariadas, com 1 passo futuro	39
Figura 19 – Interface do <i>dashboard</i> disponibilizado	40
Figura 20 – Comparação entre a temperatura média semanal e a quantidade de casos de dengue. O eixo Y de ambas as séries está normalizado entre 0 e 1, a fim da comparação entre as séries	42

LISTA DE TABELAS

TABELA 1 – Dicionário dos dados conjunto de dados criado	28
TABELA 2 – Resultados das redes TKAN e LSTM utilizando apenas uma variável ...	37
TABELA 3 – Resultados das redes TKAN e LSTM, levando em consideração os fatores climáticos do conjunto de dados	39

LISTA DE ABREVIATURAS

LSTM	Long Short-Term Memory
KAN	Kolmogorov-Arnold Network
TKAN	Temporal Kolmogorov-Arnold Network
RKAN	Recurrent Kologorov-Arnold Network
AM	Aprendizado de Máquina
IA	Inteligência Artificial
RNA	Redes Neurais Artificiais
MLP	Multilayer Perceptron
ReLU	Rectified Linear Unit
RNN	Recurrent Neural Network
LIME	Local Interpretable Model-Agnostic Explanations
SHAP	SHapley Additive exPlanations
GRU	Gated Recurrent Unit
ARIMA	Autoregressive Integrated Moving Average

SUMÁRIO

1	INTRODUÇÃO	10
1.1	OBJETIVO GERAL	11
1.2	ORGANIZAÇÃO DO TRABALHO	11
2	REFERENCIAL TEÓRICO	13
2.1	APRENDIZADO DE MÁQUINA NA SAÚDE	13
2.1.1	Redes Neurais	14
2.1.2	Séries Temporais	15
2.1.3	Explicabilidade	15
2.2	REDES KOLMOGOROV-ARNOLD E REDES KOLMOGOROV-ARNOLD TEMPORAIS	17
2.2.1	O funcionamento da TKAN	18
2.2.1.1	Camadas e Neurônios na KAN	19
2.2.1.2	Funções de Ativação Aprendíveis e Representação de Funções Não-Lineares	19
2.2.1.3	Treinamento e Ajuste da Rede	19
3	TRABALHOS RELACIONADOS	21
4	METODOLOGIA	24
4.1	O CONJUNTO DE DADOS	24
4.1.1	Obtenção dos dados	24
4.1.2	Processamento e Unificação dos Dados Meteorológicos	25
4.1.3	Padronização e Preparação para Análise	26
4.1.4	Processamento dos Dados Meteorológicos	27
4.1.5	União com dados da Dengue	27
4.1.6	Exploração dos dados	28
4.2	APLICAÇÃO DOS MODELOS E AVALIAÇÃO DAS MÉTRICAS	29
4.2.1	Coeficiente de determinação	31
5	RESULTADOS	32
5.1	KOLMOGOROV-ARNOLD NETWORK	32
5.1.1	KAN Univariada	32
5.1.2	KAN Multivariada (MT-KAN)	34
5.1.3	Resultados da KAN	35
5.2	TEMPORAL KOLMOGOROV-ARNOLD NETWORK	35
5.2.1	TKAN Univariada	35
5.2.1.1	Predição de outros parâmetros	37
5.2.2	TKAN Multivariada	38
5.3	DISPONIBILIZAÇÃO DOS DADOS	39

6	CONCLUSÃO	41
6.1	LIMITAÇÕES.....	41
6.2	TRABALHOS FUTUROS	42
	REFERÊNCIAS BIBLIOGRÁFICAS	44

1 INTRODUÇÃO

A dengue é uma doença viral transmitida pela picada da fêmea infectada do mosquito *Aedes aegypti* (SECRETARIA DA SAÚDE DO RS, 2024b), tendo seu primeiro registro de epidemia no Brasil em 1981 (FIOCRUZ, 2024). Classificada como uma arbovirose, a dengue tem como principais vetores transmissores mosquitos, o que faz com que sua incidência seja mais comum em áreas tropicais (MINISTÉRIO DA SAÚDE DO BRASIL, 2024; SECRETARIA DA SAÚDE DE SP, 2024).

Nos últimos anos, o número de casos de dengue apresentou um aumento significativo (SECRETARIA DA SAÚDE DO RS, 2024c). Embora a doença fosse considerada sazonal, ela vem perdendo essa característica (SECRETARIA DA SAÚDE DO RS, 2024d), ocorrendo de forma mais recorrente ao longo do ano. Esse aumento é preocupante, pois, embora a dengue tenha formas mais brandas e de fácil recuperação, suas formas graves podem levar ao óbito (SECRETARIA DA SAÚDE DO RS, 2024a). Dessa forma, torna-se interessante para os serviços de saúde, tanto no âmbito sanitário quanto médico, prever a incidência de casos, visando uma melhor preparação e resposta ao atendimento da população.

Diversos fatores influenciam o surgimento e a proliferação dos vetores da dengue, como o crescimento acelerado das cidades, a falta de planejamento urbano e infraestrutura adequada de saneamento básico, além de fatores climáticos que se intensificaram nos últimos anos. Esse conjunto de fatores cria um cenário no qual o comportamento da doença se torna mais imprevisível, dificultando a previsão de surtos sem o auxílio de ferramentas adequadas (BUTANTAN, 2024). No estado do Rio Grande do Sul, em particular, observou-se um aumento significativo de casos, com padrões climáticos que diferem de outras regiões tradicionalmente afetadas pela dengue.

A partir dessa perspectiva, o uso de ferramentas de aprendizado de máquina e mineração de dados se mostra relevante para a análise de grandes volumes de dados relacionados à ocorrência de casos da doença (ROSTER; RODRIGUES, 2021). A aplicação de diferentes algoritmos pode revelar padrões ocultos aos olhos humanos, padrões esses que frequentemente são complexos, influenciados por múltiplas variáveis, ou resultam de interações que não podem ser captadas por métodos tradicionais de análise (ADEGOKE; ODUGBOSE; ADEYEMI, 2024).

Neste trabalho, exploramos o uso de redes neurais, como as *Long Short-Term Memory (LSTM)* (GRAVES; GRAVES, 2012), amplamente utilizadas na modelagem de séries temporais. Entretanto, apesar de sua eficiência, essas técnicas possuem limitações, especialmente no que tange à explicabilidade dos resultados, o que é um aspecto crítico na área da saúde. A falta de interpretabilidade em muitos modelos de aprendizado de máquina dificulta a adoção de suas previsões por profissionais de saúde, que precisam

entender os fatores subjacentes às decisões geradas pelos modelos (LOH et al., 2022).

Diante dessas limitações, surge a necessidade do uso de técnicas com resultados mais interpretáveis. Uma possível opção são as recentes Redes Kolmogorov-Arnold (*Kolmogorov-Arnold Networks - KANs*) (LIU et al., 2024), que buscam oferecer maior transparência e explicabilidade. Ademais, existe uma implementação de KAN criada especialmente para lidar com dados temporais: as Temporal Kolmogorov-Arnold Networks (TKANs) (GENET; INZIRILLO, 2024). Além disso, as KANs e TKANs buscam permitir que os padrões identificados sejam compreendidos de forma mais clara (XU; CHEN; WANG, 2024), facilitando sua aplicação em contextos críticos como o da saúde pública. Essas redes podem apresentar um potencial superior para a extração de informações úteis com menos recursos computacionais, tornando-se uma opção promissora para problemas como a previsão de surtos de dengue e a tomada de decisões informadas.

Portanto, este trabalho visa explorar as KANs e suas variantes em dados epidemiológicos e climáticos e medir desempenho, relevância dos resultados obtidos e a clareza com que os padrões são explicados. A partir de um *dataset* criado unindo dados de casos de dengue junto a dados meteorológicos, a KAN explora esse conjunto e durante o treino, em seus neurônios, suas funções buscam a aproximação da curva que melhor cabe no contexto dos dados que esta comparando, e prevê o número de casos de dengue também resultando em uma função matemática que explica seus resultados. Ao buscar promover uma maior compreensão dos fatores que influenciam a previsão de casos de dengue, as TKANs demonstram seu valor no aprimoramento das ferramentas de análise de dados temporais, especialmente em áreas que exigem altos níveis de explicabilidade, como a saúde pública.

1.1 OBJETIVO GERAL

Este trabalho tem como objetivo geral explorar técnicas de aprendizado de máquina, especialmente TKANs, para auxiliar a saúde pública na previsão de picos de dengue no estado do Rio Grande do Sul, ao mesmo tempo que busca explicar os resultados obtidos nos algoritmos utilizados.

1.2 ORGANIZAÇÃO DO TRABALHO

Esse trabalho está dividido em 6 seções. A primeira, introduz o tema e contextualiza o problema. Na segunda, temos o referencial teórico que explica os termos e ferramentas que serão mencionadas e utilizadas na pesquisa. A terceira traz alguns trabalhos

relacionados de forma resumida. Na quarta, temos a metodologia, explicando como o experimento foi feito, trazendo sessões sobre a obtenção, processamento e tratamento dos dados. Em seguida temos a seção de resultados onde é demonstrado o que foi obtido e observado com a execução deste trabalho. E, por último, temos a seção que traz a conclusão tida por meio do desenvolvimento, experimentos e resultados observados além de sugestões para trabalhos futuros.

2 REFERENCIAL TEÓRICO

Nessa seção estão descritas as principais técnicas e modelos utilizados para o desenvolvimento desse trabalho. Alguns conceitos estão pontuados de forma resumida já que o objetivo não é abordar esses assuntos diretamente mas sim visar o melhor entendimento do trabalho aqui desenvolvido. Na seção inicial está exposto o que é o aprendizado de máquina e como ele pode ser usado e vem adquirindo relevância para a área da saúde, seguido pelas subseções de Redes Neurais, Séries Temporais e Explicabilidade. Na subseção sobre Redes Neurais é trazida uma breve explicação do assunto para que sejam introduzidos conceitos relevantes para nosso experimento assim como o assunto da subseção seguinte, de séries temporais. Na terceira subseção descrevemos o conceito da explicabilidade e sua relevância crescente, principalmente para áreas que dependem de maior clareza nas decisões, juntamente com o que ela pode nos fornecer de útil. Então, na seção sobre as Redes Kolmogorov-Arnold tratamos sobre essas redes e a sua variação para dados temporais, as Redes Kolmogorov-Arnold Temporais. Trazemos a teoria de onde foi originada, seu funcionamento e construção, o que elas prometem trazer de novo e como diferem de outros modelos já consolidados e entre si mesmas.

2.1 APRENDIZADO DE MÁQUINA NA SAÚDE

O uso de tecnologias tem crescido continuamente ao longo dos anos, e o aprendizado de máquina (AM) se destaca como uma das áreas de maior relevância nesse contexto. Também referido como um subcampo da Inteligência Artificial (IA), o aprendizado de máquina vem sendo incorporado em diversas aplicações, incluindo a área da saúde (SHAILAJA; SEETHARAMULU; JABBAR, 2018), que busca explorar o potencial dessas ferramentas para melhorar processos e resultados. No entanto, essa inserção enfrenta desafios específicos, sobretudo relacionados à necessidade de explicabilidade e transparência nas decisões geradas pelos modelos (LOH et al., 2022).

O aprendizado de máquina começou a ser formalizado como um campo de estudo dentro da computação na década de 1990, impulsionado por pesquisadores como Mitchell (COZMAN; KAUFMAN, 2022) que buscavam criar soluções computacionais capazes de resolver problemas complexos por meio da identificação de padrões em dados. O objetivo inicial era desenvolver sistemas que aprendessem automaticamente a partir de exemplos, sem a necessidade de programação explícita para cada tarefa, revolucionando a forma como problemas computacionais poderiam ser abordados (DOMINGOS, 2017).

O funcionamento básico do aprendizado de máquina envolve algoritmos que são treinados em grandes conjuntos de dados para identificar relações e padrões (ZHOU,

2021). Esses algoritmos, após o treinamento, podem generalizar suas aprendizagens para prever ou classificar novos dados, com base nos dados adquiridas durante o processo de treinamento. Há diferentes tipos de aprendizado de máquina, como o supervisionado (NASTESKI, 2017), no qual o modelo é treinado com dados rotulados, e o não supervisionado (HAHNE et al., 2008), em que o modelo busca encontrar padrões sem orientação prévia. No entanto, independentemente da técnica, a aplicabilidade dessas ferramentas no contexto da saúde exige um equilíbrio entre desempenho e explicabilidade, para que seus resultados sejam úteis e confiáveis no apoio à tomada de decisões clínicas. Entre os métodos de aprendizado de máquina explicáveis que podem ser utilizados na área médica se encontram, por exemplo, as árvores de decisão e *Case-Based Reasoning* (KOLODNER, 2014).

Na saúde, o uso de aprendizado de máquina pode aumentar a precisão dos diagnósticos, melhorar a eficácia dos tratamentos e otimizar o desempenho em diversas etapas do cuidado médico. Modelos de IA podem auxiliar profissionais de saúde na tomada de decisões clínicas, oferecendo *insights* baseados em grandes volumes de dados (BELLE et al., 2015) e identificando padrões complexos que poderiam passar despercebidos por métodos convencionais. Assim, médicos e pacientes se beneficiam das tecnologias que promovem decisões mais informadas e assertivas. Contudo, para que essas soluções sejam amplamente adotadas, é crucial que as decisões sugeridas pelos modelos de AM sejam explicáveis e compreensíveis, garantindo a responsabilidade nas decisões médicas (SARANYA; SUBHASHINI, 2023).

2.1.1 Redes Neurais

Redes Neurais Artificiais são modelos computacionais inspirados no funcionamento do cérebro humano, compostos por neurônios artificiais organizados em camadas. Cada neurônio realiza operações matemáticas que transformam os dados de entrada em resultados de saída, ajustando os pesos das conexões entre eles através de algoritmos de aprendizado, como o gradiente descendente. As RNAs são amplamente utilizadas para resolver problemas de classificação, regressão e reconhecimento de padrões em diversas áreas, devido à sua capacidade de aprender e generalizar a partir de grandes volumes de dados. Entre as arquiteturas mais simples e difundidas de redes neurais estão os *Multilayer Perceptrons (MLPs)*. Eles consistem em uma camada de entrada, uma ou mais camadas intermediárias (também chamadas de camadas ocultas) e uma camada de saída. Cada camada é completamente conectada à seguinte, e os MLPs utilizam funções de ativação não-lineares, como a função ReLU (Equação 2.1), para aprender representações complexas dos dados. Apesar de sua simplicidade, os MLPs têm desempenho robusto em uma

ampla gama de aplicações, incluindo classificação e regressão.

$$\text{Relu}(z) = \max(0, z) \quad (2.1)$$

2.1.2 Séries Temporais

Séries temporais referem-se a conjuntos de dados organizados em uma linha do tempo, onde os pontos de dados são dependentes de seus valores anteriores. A análise de séries temporais busca identificar padrões e tendências ao longo do tempo para prever valores futuros, sendo amplamente utilizada em finanças, economia, climatologia e epidemiologia. Modelos como ARIMA (SHUMWAY et al., 2017) e as redes neurais, como as redes neurais recorrentes e as LSTMs, são frequentemente usados para capturar dependências temporais e realizar previsões precisas. O trabalho de Siami-Namini, Tavakoli e Namin (2018) compara o desempenho destes modelos em séries temporais.

As **Redes Neurais Recorrentes (RNNs)** são uma extensão das redes neurais tradicionais que incorporam *loops* direcionais, permitindo que informações de estados anteriores sejam levadas em conta no processamento atual. Essa característica torna as RNNs particularmente adequadas para modelagem de dados sequenciais, como séries temporais, textos e sinais. No entanto, as RNNs tradicionais enfrentam desafios relacionados ao problema do desaparecimento ou explosão do gradiente, o que limita seu desempenho em sequências longas.

As redes **Long Short-Term Memory (LSTM)** são uma variante das RNNs projetadas para superar as limitações de aprendizado em dependências de longo prazo (YU et al., 2019). As LSTMs utilizam uma arquitetura específica de células com mecanismos de portas de entrada, esquecimento e saída, que controlam o fluxo de informações e preservam gradientes ao longo de sequências extensas. Isso as torna extremamente eficazes em tarefas de previsão de séries temporais (MALHOTRA et al., 2015; FISCHER; KRAUSS, 2018; ZHA et al., 2022) e processamento de linguagem natural, onde a dependência contextual de longo prazo é crítica.

2.1.3 Explicabilidade

A explicabilidade de modelos de inteligência artificial (IA) é um tema central no campo, representando a dificuldade em compreender como e por que um modelo chega a determinadas decisões ou previsões. Essa questão é especialmente relevante em modelos complexos, como redes neurais profundas, cuja arquitetura é composta por múltiplas camadas e interações não lineares. Apesar do alto desempenho em precisão, a natureza

opaca desses modelos, muitas vezes descrita como uma caixa-preta, dificulta a interpretação humana e a auditoria de seu funcionamento interno (DHAR et al., 2023; LARASATI, 2023). Essa falta de transparência pode ocultar vieses ou comportamentos indesejados, gerando desafios em áreas críticas como saúde, finanças e justiça, onde a justificativa das decisões é essencial para garantir confiança e equidade (DURÁN, 2021).

Nesse contexto, emergiu a área de Inteligência Artificial Explicável (Explainable AI - XAI), cujo objetivo é desenvolver métodos que tornem os modelos mais interpretáveis sem comprometer significativamente sua precisão. Técnicas de XAI incluem desde visualizações de importância de características até métodos pós-modelagem, como *LIME (Local Interpretable Model-Agnostic Explanations)* e *SHAP (SHapley Additive exPlanations)*, que auxiliam na compreensão do impacto de diferentes variáveis nas decisões do modelo. Esses métodos possibilitam a categorização dos modelos em três níveis de explicabilidade: completamente explicáveis, parcialmente explicáveis e os modelos caixa-preta. A escolha entre eles depende das demandas específicas da aplicação, frequentemente exigindo um equilíbrio entre desempenho e interpretabilidade.

Além das aplicações generalistas, a XAI tem avançado na explicabilidade de modelos aplicados a séries temporais. Por exemplo, Nishimura et al. (2023) propõem um método para séries temporais que avalia a relevância da ordem temporal dos eventos por meio da inserção de perturbações e análise do comportamento do modelo diante dessas alterações. O método foi validado com classificadores simples em conjuntos de dados simulados e aplicado a dados de sensores de *smart homes*, demonstrando a capacidade de extrair informações sobre a importância temporal em diferentes contextos.

Na área da saúde, a aplicação de sistemas de IA tem potencial para prever diagnósticos, identificar fatores de risco e personalizar tratamentos. Contudo, a falta de transparência nos processos decisórios desses modelos pode comprometer a confiança de médicos, pacientes e gestores. Nesse cenário, a explicabilidade torna-se crucial para a confiabilidade e eficiência. A ausência de explicabilidade pode levar a erros graves, como diagnósticos inadequados (por exemplo, prever uma condição biológica impossível, como gravidez em pacientes masculinos ou câncer de próstata em pacientes femininas). Compreender as variáveis mais influentes na decisão dos modelos é fundamental para garantir a segurança e aumentar a confiança nos sistemas, permitindo validação por especialistas.

Além disso, a área da saúde apresenta desafios específicos em relação à qualidade e representatividade dos dados, que frequentemente refletem desigualdades históricas, como o acesso desigual a serviços de saúde ou a sub-representação de populações vulneráveis. Modelos não explicáveis podem amplificar esses vieses, resultando em diagnósticos ou tratamentos inadequados para determinados grupos. Ferramentas de XAI ajudam a mitigar tais problemas ao fornecer *insights* sobre os padrões aprendidos pelo modelo, permitindo ajustes direcionados.

Ferramentas como LIME e SHAP desempenham um papel importante ao identifi-

car os fatores que levam a previsões de maior risco para pacientes, como alterações em exames clínicos ou características ambientais. Modelos parcialmente ou totalmente explicáveis contribuem para a medicina personalizada, justificando escolhas de tratamentos específicos com base no perfil genético do paciente. Na administração da saúde, a explicabilidade auxilia na alocação ética e transparente de recursos, especialmente em situações emergenciais. Assim, o equilíbrio entre desempenho e interpretabilidade é essencial para que a IA possa efetivamente contribuir com avanços na área da saúde. Nesse contexto, a explicabilidade transcende a esfera técnica, sendo uma ponte vital para maior confiança, segurança e equidade nos cuidados médicos.

2.2 REDES KOLMOGOROV-ARNOLD E REDES KOLMOGOROV-ARNOLD TEMPORAIS

As **Kolmogorov-Arnold Networks (KANs)** (LIU et al., 2024), baseadas no teorema de representação de Kolmogorov-Arnold (SCHMIDT-HIEBER, 2021), são redes que buscam possibilitar a redução do custo computacional, diminuição da quantidade de neurônios e camadas necessárias e também oferecer interpretabilidade em decisões (LIU et al., 2024), evitando o problema da “caixa-preta”, comum em modelos de IA. Essas redes buscam representar qualquer função contínua multivariada por meio da composição de funções univariadas, o que as torna adequadas para modelagem de dados complexos. A inovação principal em relação às redes tradicionais, como MLPs, está na substituição de funções de ativação fixas por funções de ativação parametrizáveis e aprendíveis, situadas nas conexões, o que permite adaptação dinâmica às características dos dados. Para aprimorar a precisão na modelagem de não-linearidades, as KANs utilizam *Splines* (SCHUMAKER, 2007) para parametrizar essas funções de ativação, como é possível ver na Figura 1.

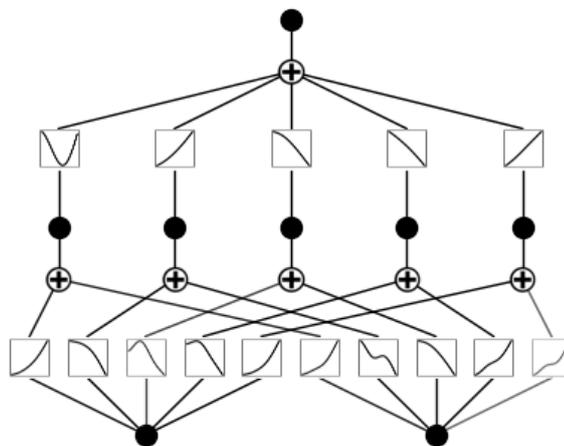


Figura 1 – Representação de uma Rede de Kolmogorov-Arnold gerada pelo *model.plot*, da biblioteca *pykan*

Pensando no potencial desse modelo, novas versões melhor adaptadas para tratar de séries temporais foram idealizadas. Para poder analisar mais adequadamente dados sequenciais, como dados epidemiológicos, começou-se a introdução das *Temporal Kolmogorov-Arnold Networks* (TKANs) que aproveita essa estrutura composicional para captura de padrões dinâmicos.

As KANs (*Kolmogorov-Arnold Networks*) e sua evolução, as TKANs (*Temporal Kolmogorov-Arnold Networks*), destacam-se de arquiteturas como LSTMs (*Long Short-Term Memory*) e GRUs (*Gated Recurrent Units*) por sua abordagem única que combina simplicidade estrutural e transparência. Enquanto LSTMs e GRUs empregam mecanismos complexos para lidar com dependências temporais, as KANs utilizam uma decomposição explícita das interações entre variáveis, o que facilita a interpretação dos resultados. Essa característica é especialmente valiosa em áreas críticas, como a saúde pública, onde a compreensão dos fatores subjacentes às previsões é essencial para tomadas de decisão informadas. Além disso, a estrutura das KANs permite otimizações como a redução de camadas e a poda de neurônios sem comprometer o desempenho, o que resulta em modelos mais eficientes e explicáveis. As TKANs buscam ir além ao incorporar aspectos temporais diretamente em sua arquitetura, possibilitando análises detalhadas de padrões temporais com a mesma clareza e eficiência. Apesar de estarem em estágios iniciais de desenvolvimento, essas redes demonstram potencial de transformar áreas onde a explicabilidade é tão importante quanto a precisão, destacando-se como uma alternativa promissora às arquiteturas tradicionais.

2.2.1 O funcionamento da TKAN

Baseada no teorema de Kolmogorov-Arnold, qualquer função contínua multivariada pode ser representada como uma composição de funções univariadas e operações de adição. Suponha funções φ_q e $\psi_{p,q}$ contínuas e univariadas, com índices p e q para representação da função f :

$$f(x_1, x_2, \dots, x_n) = \sum_{q=1}^{2n+1} \varphi_q \left(\sum_{p=1}^n \psi_{p,q}(x_p) \right) \quad (2.2)$$

Cada função univariada é parametrizada como uma B-spline com coeficientes aprendíveis. A estrutura de KAN organiza-se em duas camadas: uma camada inicial de $n_{in} = n$ e $n_{out} = 2n + 1$, e uma camada de saída de $n_{in} = 2n + 1$ e $n_{out} = 1$. Assim, temos duas camadas: uma composta pelas funções $\psi_{p,q}$, e outra pelas funções φ_q , permitindo que as relações entre variáveis sejam representadas de forma hierárquica.

2.2.1.1 Camadas e Neurônios na KAN

A KAN divide a rede em duas camadas principais, baseadas nas funções univariadas $\psi_{p,q}$ e nas operações de soma via φ_q . As funções $\psi_{p,q}$, parametrizadas por *Splines*, realizam a transformação dos valores de entrada, enquanto as funções φ_q combinam essas transformações, resultando em uma saída única. Durante o treinamento, os parâmetros das *Splines* são ajustados para capturar relações complexas entre as variáveis de entrada.

2.2.1.2 Funções de Ativação Aprendíveis e Representação de Funções Não-Lineares

As funções de ativação nas KANs são parametrizáveis por *Splines*, o que facilita a captura de não-linearidades dos dados. Em vez de ativação fixada nos neurônios, a ativação ocorre entre as camadas, o que torna a representação dos dados mais robusta. A flexibilidade das *Splines* evita problemas de sobreajuste, ao mesmo tempo que ajusta-se dinamicamente às necessidades dos dados.

2.2.1.3 Treinamento e Ajuste da Rede

O treinamento da KAN utiliza métodos como o gradiente descendente para ajustar os parâmetros das *Splines*, minimizando o erro de previsão e otimizando $\psi_{p,q}$ e φ_q para melhor representar os dados. Esse processo iterativo busca reduzir o erro sem comprometer a interpretabilidade, promovendo uma representação eficiente e ajustada aos padrões observados.

Para a modelagem de séries temporais, a TKAN adota uma estrutura baseada na Recurrent Kolmogorov-Arnold Network (RKAN), com células LSTM modificadas para capturar dados sequenciais e prever múltiplos passos adiante. Esta célula LSTM evita a perda de informações em sequências longas, característica das RNNs, e combinada com a RKAN permite capturar não-linearidades complexas enquanto mantém memória de eventos passados. Dessa forma, a TKAN se mostra especialmente eficaz para dados sequenciais complexos. Essa estrutura está representada¹ na Figura 2 que podemos ver a seguir.

¹Disponível em: github.com/remigenet/TKAN

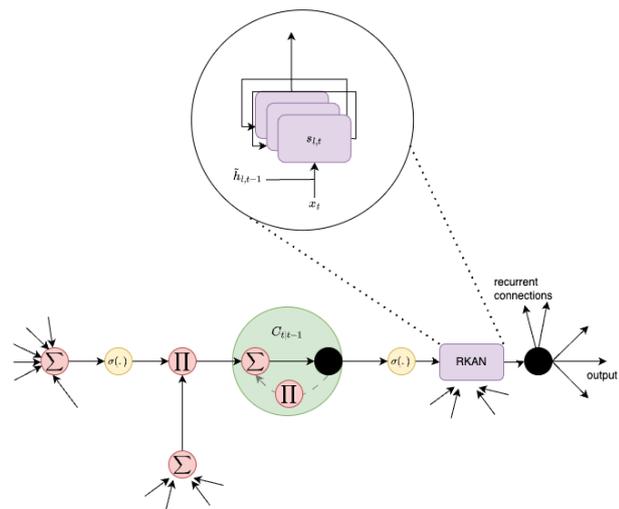


Figura 2 – Arquitetura da Temporal Kolmogorov-Arnold Network (TKAN)

Fonte: Genet e Inzirillo (2024)

3 TRABALHOS RELACIONADOS

Existe uma diversa literatura de pesquisas sobre modelagem de dados por meio de abordagens de aprendizado de máquina (WIEMKEN; KELLEY, 2020). Dentre essas, a dengue e as condições de sua ocorrência se apresentam de forma relevante diante do aumento de casos (SIRIYASATIEN et al., 2018; CHUMPU; KHAMSEMANAN; NATTEE, 2019). Os estudos buscam entender características de regiões mais afetadas, detectar surtos epidêmicos e prever o acometimento da população relacionando com as condições climáticas e socioeconômicas (ALEIXO et al., 2022). Nessa seção, são abordados, resumidamente, trabalhos relacionados à previsão de casos de dengue por modelos de aprendizado de máquina e da importância da explicabilidade para a área da saúde.

Na revisão de Roster e Rodrigues (2021) foram avaliadas as redes neurais relevantes utilizadas para a previsão da dengue. Nessa análise, foram investigados 19 artigos os quais resumem o desempenho de redes neurais e modelos comparadores, arquiteturas de modelos e hiperparâmetros, além das escolhas de recursos de entrada. Nestes, a maioria utiliza redes neurais superficiais junto com a incidência histórica da dengue e fatores meteorológicos à nível municipal.

Já em outros materiais avaliados, como em Ramadona et al. (2016), Chumpu, Khamsemanan e Nattee (2019) e Deb e Deb (2022), os principais modelos utilizados são de regressão com diferentes métodos, unidos a características climáticas e ambientais. Em Ramadona et al. (2016) foram analisados dados meteorológicos e da vigilância de doenças da Indonésia. Foram utilizados modelos de regressão linear generalizada para ajuste de relações entre as variáveis preditoras e os dados. Nesse estudo, chegou-se a resultados que demonstraram a habilidade de detectar os surtos com até 2 meses de antecedência. Já em Chumpu, Khamsemanan e Nattee (2019), foram analisadas informações da ocorrência de dengue em províncias na Tailândia avaliando o desempenho de 5 métodos, sendo eles: regressão de Poisson, regressão binomial negativa, regressão de quase-verossimilhança, ARIMA e SARIMA. Além disso, foram utilizadas diversas variáveis de ocorrência da doença e de características meteorológica, em busca da construção do melhor modelo de predição. Por meio da correlação das múltiplas condições climáticas, que variam entre as províncias, chegaram a precisão suficiente para previsão real da incidência da doença. Conclusão que, junto a McGough et al. (2021), aponta a influencia dos micro-climas, corroborando com a percepção de que este estudo não pode ser feito diretamente a nível nacional, pois em grandes escalas o resultado é prejudicado devido a diversos fatores. Já no estudo de Deb e Deb (2022) que combina regressão binomial negativa, modelo de média móvel integrada autorregressiva e modelo de média móvel autorregressiva linear generalizada, por meio de uma estrutura autorregressiva vetorial e valores covariáveis de terreno e clima. Utilizando dados reais de San Juan e Iquitos, mostra-se que o método

proposto geralmente incorre em um erro absoluto médio de menos de 10 casos quando as previsões são feitas com 8 semanas de antecedência.

Olhando para o Brasil como foco da dengue no momento, com aumento expressivo no acometimento da população, muitos fatores podem estar envolvidos nessa disseminação. Estudos como de (BOMFIM et al., 2020) trazem testes de redes naturais artificiais para prever dados de dengue em Fortaleza. Neste, as análises são feitas a nível de bairro devido ao tamanho populacional, no entanto, busca correlacionar os casos de dengue com a mobilidade urbana. Apontaram resultados positivos sobre momento e intensidade do pico do surto e as series temporais anuais da dengue. Já em (ENSLEN; NETO; CASTRO, 2020), foram analisadas as relações entre os casos por medição de presença das larvas em domicílios. Utilizaram índices de correlação e análise de classificação estratificados por ano, região, porte populacional e tempo após a coleta de dados das larvas de mosquito, a nível nacional. Essa análise larval pode ser bastante útil para avaliar o potencial de risco de uma região no entanto, indicam que essa informação não esta sendo bem utilizada. Segundo (MCGOUGH et al., 2021), a transmissão da dengue depende da interação complexa da dinâmica humana, climática do mosquito, e as mudanças no espaço ao longo do tempo, sendo assim, ele busca padrões nessa dinâmica que é influenciada por diversos fatores. Ele observou que, além da suscetibilidade da população a infecção, também presente em (RAMADONA et al., 2016; SIRIYASATIEN et al., 2018), os microclimas influenciam na reprodução e sobrevivência do mosquito, por sua criação de condições climáticas de pequenas áreas e ambientes. Ele faz o estudo a nível de cidades, no Brasil, mas com uso de dados sobre a imunidade da população. É feita a generalização da metodologia para qualquer local e dados de entrada, fato interessante a ser reproduzido.

Mas pensando no número crescente de informações disponíveis para serem adicionadas as investigações. Podemos observar a complexidade dos modelos utilizados para esses grandes conjuntos de dados progredirem com o passar dos anos. A dificuldade de entendimento dos resultados gerados por esses modelos aumenta também e novos métodos são propostos para acompanhar e facilitar a compreensão humana (LUNDBERG, 2017). Nessa ideia, o estudo de Prome et al. (2024) busca utilizar uma estrutura de IA explicável, baseada em Shapash, pra explicar os resultados da predição de dengue em 11 distritos de Bangladesh, utilizando 7 modelos de aprendizado de máquina, incluindo 3 técnicas de aprendizados em conjunto. Em Campanhol (2024), além do uso da LSTM com dados meteorológicos para previsão de dengue em Porto Alegre, uma grande cidade como citado em trabalhos anteriores, este estudo traz a análise de uma região de influencias climáticas diferentes das demais citadas. Ademais, busca trazer a explicabilidade para a previsão feita por meio do uso de árvores de decisão.

Ao nos depararmos com as Redes Kolmogorov-Arnold (LIU et al., 2024), um novo modelo de aprendizado de máquina que emergiu recentemente, surgiu o interesse de explorar sua viabilidade de uso. Elas intentam trazer a capacidade das redes neurais artifici-

ais com explicabilidade embutida. Estudos como de Vaca-Rubio et al. (2024), Xu, Chen e Wang (2024) já trazem as KANs para perspectivas de análises de séries temporais. Propondo variantes para esse objetivo, Xu, Chen e Wang (2024) descreve a como T-KAN sendo altamente interpretável e a MT-KAN para a melhora de previsões em séries temporais multivariadas. Já Genet e Inzirillo (2024) propõe ainda, uma TKAN com alterações de arquitetura pretendendo também explorar o poder da KAN em séries temporais, no entanto, neste caso, acaba pecando na interpretabilidade.

A partir desses estudos, esta pesquisa busca exploração da usabilidade dos modelos KAN como potencial preditivo de dengue. Dados meteorológicos das estações presentes no estado do Rio Grande do Sul foram utilizados junto a dados epidemiológicos da dengue em diversas cidades do estado. Os fatores climáticos podem influenciar em variados fatores referentes a doença, desde a larva, tempo de vida do mosquito e a exposição da população ao vetor infectado. Sendo assim, vamos avaliar apenas esses fatores climáticos, com potencial de redução para sub-regiões e até cidades, em uma região subtropical temperada. A partir disso, vamos explorar e comparar os resultados propostos pelas novas ferramentas citadas.

4 METODOLOGIA

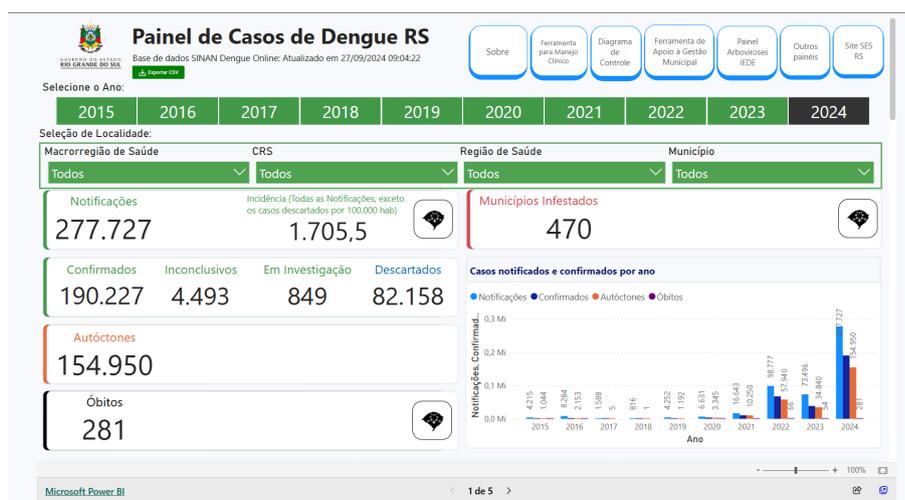
Nesta seção, são detalhadas as etapas metodológicas seguidas ao longo deste trabalho, desde a obtenção dos dados até a sua preparação para a aplicação dos métodos de análise apresentados na seção anterior. O processo é dividido em fases, que incluem a coleta de dados brutos, o pré-processamento e a unificação das diferentes fontes de dados utilizadas. As etapas descritas a seguir foram fundamentais para alcançar os objetivos propostos pela pesquisa.

4.1 O CONJUNTO DE DADOS

4.1.1 Obtenção dos dados

O conjunto de dados utilizado neste estudo é construído a partir de duas fontes públicas governamentais: Primeiramente, os dados epidemiológicos sobre casos de dengue são extraídos do portal oficial do Governo do Estado do Rio Grande do Sul¹. Esse portal disponibiliza dados de forma visual e em formato CSV, sendo acessado para coleta no dia 27 de setembro de 2024. A partir do painel de casos de dengue (Figura 3), são obtidos dados de incidência da doença por município e data.

Figura 3 – Tela do painel de casos de Dengue no Rio Grande do Sul



Fonte: Secretaria da Saúde do Rio Grande do Sul

Além disso, os dados meteorológicos são obtidos do Instituto Nacional de Meteoro-

¹Disponível em: ti.saude.rs.gov.br/dengue/painel_de_casos.html

Caso o arquivo seja identificado como pertencente ao RS, seus dados são adicionados a um arquivo consolidado que unifica todos os registros meteorológicos do estado. Para manter a rastreabilidade das cidades, o nome da cidade é extraído do nome do arquivo e adicionado como uma coluna adicional ao conjunto de dados. Ao ler os conjuntos de dados, as primeiras linhas são ignoradas, pois contêm o cabeçalho identificador de cada arquivo, como latitude, longitude, entre outros itens descritivos. Para a análise proposta neste trabalho, esses dados não são necessários.

Neste processo, algumas outras funções tiveram que ser usadas, a fim de melhorar a qualidade dos dados para posteriormente serem manipulados. Entre as mudanças, ao juntar os dados meteorológicos, o padrão do arquivo .csv foi modificado. Os dados meteorológicos, por padrão, estavam em um arquivo separado por ponto e vírgula (;). Para deixar no padrão da linguagem de programação, isto foi mudado para o arquivo ser separado apenas por vírgula (,). Também, um nome de arquivo não padronizado (o da estação meteorológica de Belém Novo, em Porto Alegre) teve seu nome padronizado, a fim de deixar o *dataset* o melhor possível.

Ao final desse processo, é gerado um único arquivo contendo todos os registros meteorológicos de 2015 até agosto de 2024 para o estado do Rio Grande do Sul. Esse arquivo final possui mais de 3,6 milhões de linhas, uma vez que os dados meteorológicos são registrados em diferentes horários para cada cidade ao longo de todo o período. A Tabela 1 mostra o dicionário dos dados utilizados.

4.1.3 Padronização e Preparação para Análise

Durante o processo de unificação dos dados meteorológicos, são enfrentadas algumas dificuldades devido às mudanças no formato de certas colunas a partir de 2019. Para evitar problemas de compatibilidade entre os diferentes anos, a solução adotada é ignorar os cabeçalhos ao unir os dados. Isso garante que, ao adicionar novos dados no futuro, bastará incluir a pasta correspondente ao ano e rodar o algoritmo novamente para processar e gerar o arquivo consolidado.

A unificação dos dados é realizada sem a necessidade de intervenções manuais, facilitando a escalabilidade do processo para futuras atualizações. Este procedimento garante que o conjunto de dados esteja sempre atualizado e pronto para análise, independentemente das mudanças que possam ocorrer na estrutura dos arquivos originais.

4.1.4 Processamento dos Dados Meteorológicos

Após a leitura e junção dos dados meteorológicos, iniciou-se o processo de tratamento e processamento dessas informações. Durante essa etapa, alguns desafios foram identificados, tais como:

- **Falta de padronização nas datas:** algumas datas eram representadas com separadores diferentes, utilizando '/' ou '-' de forma inconsistente.
- **Valores faltantes inadequadamente representados:** os dados ausentes não seguiam uma codificação padrão, dificultando sua identificação e tratamento.
- **Dimensão do conjunto de dados:** o volume de informações era muito grande, com registros diários, horários e por estação meteorológica.

Para resolver esses problemas, as seguintes ações foram realizadas: as datas foram padronizadas, e os valores faltantes foram devidamente identificados e substituídos por "NA", seguindo uma abordagem convencional para análise de dados.

Com o objetivo de reduzir o tamanho do conjunto de dados e adaptá-lo ao propósito do trabalho, foi gerado um novo conjunto com informações agregadas. Este novo conjunto foi criado a partir de operações como soma, média, máximo e mínimo diário, aplicadas a cada estação meteorológica, conforme descrito abaixo:

- Para a coluna de precipitação (chuva), calculou-se o acúmulo diário.
- Para colunas relacionadas a temperatura, pressão atmosférica, umidade, etc., foram criadas colunas registrando os valores médios, máximos e mínimos diários.

Ao final dessa etapa, o conjunto de dados consolidou informações diárias para cada estação meteorológica. Em seguida, foi calculada a média entre todas as estações meteorológicas para cada dia, resultando em um conjunto representativo das médias estaduais diárias. Por fim, os dados foram agregados semanalmente, gerando um conjunto de dados final contendo as médias semanais dos fatores meteorológicos para o estado do Rio Grande do Sul.

4.1.5 União com dados da Dengue

O conjunto de dados da dengue está disposto em semanas epidemiológicas, diferentemente dos conjuntos de dados climáticos onde são feitas medições em vários horários em um mesmo dia. Então, para fazer essa união foi necessário realizar a transformação dos dados meteorológicos.

Tabela 1 – Dicionário dos dados conjunto de dados criado

Variável	Descrição
DATA (YYYY-MM-DD)	Data do registro
PRECIPITAÇÃO TOTAL, HORÁRIO (mm)	Precipitação (chuva) total, em milímetros
PRESSAO ATMOSFERICA AO NIVEL DA ESTACAO, HORARIA (mB)	Pressão atmosférica que foi medida na estação, em milibar
PRESSÃO ATMOSFERICA MAX. NA HORA ANT. (AUT) (mB)	Medida da pressão atmosférica máxima, ocorrida na última hora, em milibar.
PRESSÃO ATMOSFERICA MIN. NA HORA ANT. (AUT) (mB)	Medida da pressão atmosférica mínima, ocorrida na última hora, em milibar.
RADIACAO GLOBAL (KJ/mš)	Toda radiação solar que chegou a superfície terrestre, em quilojoule por metro quadrado.
TEMPERATURA DO AR - BULBO SECO, HORARIA (°C)	Temperatura do ar, a partir do termômetro de bulbo seco do psicrômetro, em graus célsius.
TEMPERATURA DO PONTO DE ORVALHO (°C)	Indica a temperatura, em graus célsius, que o ar deveria ter, para que ele se tornasse saturado, e assim produzir orvalho. Medida indireta calculada a partir de valores de temperatura do ar e umidade relativa.
TEMPERATURA MÁXIMA NA HORA ANT. (AUT) (°C)	Medida da temperatura máxima do ar, em graus célsius.
TEMPERATURA MÍNIMA NA HORA ANT. (AUT) (°C)	Medida da temperatura mínima do ar, em graus célsius.
TEMPERATURA ORVALHO MAX. NA HORA ANT. (AUT) (°C)	Indica a temperatura, em graus célsius, que o ar deveria ter para produzir orvalho. Calculado a partir de valores máximos de temperatura do ar e umidade relativa.
TEMPERATURA ORVALHO MIN. NA HORA ANT. (AUT) (°C)	Indica a temperatura, em graus célsius, que o ar deveria ter para produzir orvalho. Calculado a partir de valores mínimos de temperatura do ar e umidade relativa.
UMIDADE REL. MAX. NA HORA ANT. (AUT) (%)	Medida máxima da umidade relativa do ar, em porcentagem.
UMIDADE REL. MIN. NA HORA ANT. (AUT) (%)	Medida mínima da umidade relativa do ar, em porcentagem.
UMIDADE RELATIVA DO AR, HORARIA (%)	Medida da umidade relativa do ar, ocorrida na última hora, em porcentagem.
VENTO, DIREÇÃO HORARIA (gr) (°(gr))	Medida em graus angulares da direção do vento (de onde o vento vem) (média)
VENTO, RAJADA MAXIMA (m/s)	Medida máxima da velocidade do vento, em metros por segundo.
VENTO, VELOCIDADE HORARIA (m/s);	Velocidade do vento (média), em metros por segundo.
CIDADE	Nome da cidade onde está a estação da medição.
CASOS	Número de casos de dengue

Fonte: Adaptado do glossário do INMET

Para os dados da dengue, foi feito agrupamento por semana de todas as cidades e características. Ao fim desta etapa, os conjuntos de dados meteorológicos e da dengue puderam ser juntados ligados, baseado na semana.

4.1.6 Exploração dos dados

O conjunto de dados gerado tem visualizações bastante interessantes, mostrando séries temporais do clima no estado do Rio Grande do Sul desde 2015. As Figuras 5a, 5b, 5c e 5d mostram um pouco da evolução climática no estado.

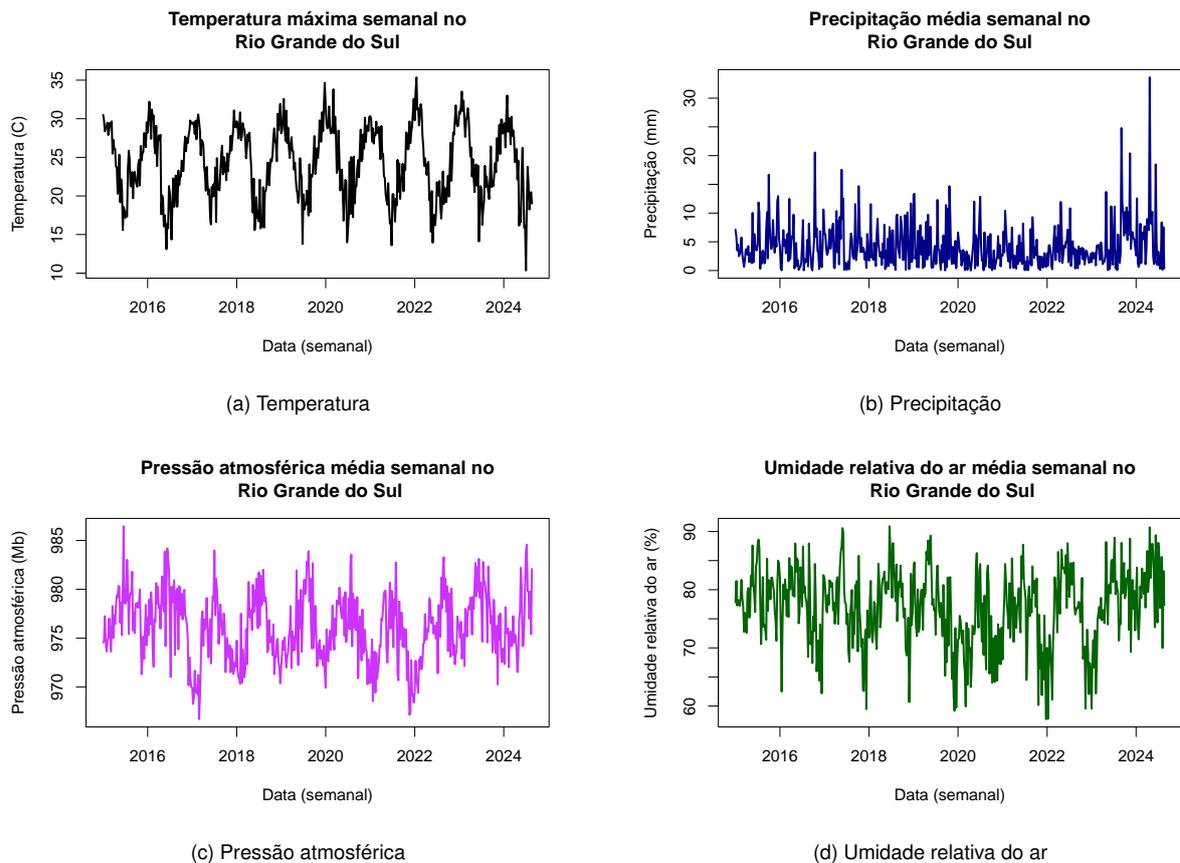


Figura 5 – Algumas variáveis meteorológicas contidas no conjunto de dados gerado

4.2 APLICAÇÃO DOS MODELOS E AVALIAÇÃO DAS MÉTRICAS

Com o objetivo de analisar o potencial da implementação original da KAN, foi utilizado o código base disponível no *GitHub* do autor³ com a base de dados apresentada na seção anterior. Inicialmente foram enfrentados problemas, possivelmente causados pelo uso de múltiplas variáveis. Essa intercorrência nos gerou um resultado parcial, pois diante do modelo gerado não foi possível a redução da rede para gerar a equação matemática que busca descrever as previsões da rede. Essa redução inadequada citada pode ser observada na Figura 8, e comparada com os exemplos de resultado e redução das Figuras 1 e 7, respectivamente. Foi necessária então, a mudança da abordagem, usando individualmente as variáveis para a previsão com o objetivo de analisar o potencial em sistemas mais controlados. Nesse caso, o desempenho dela foi relativamente positivo.

³Disponível em: github.com/KindXiaoming/pykan

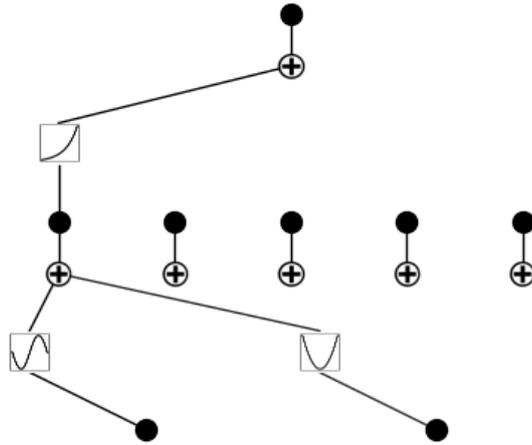


Figura 6 – Exemplo de um resultado desejável

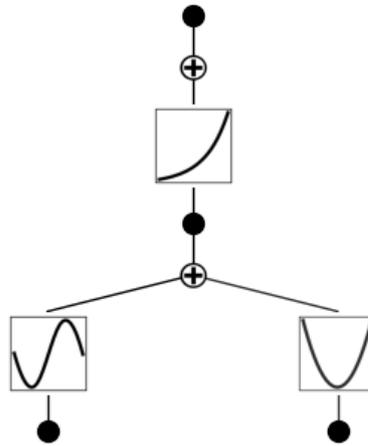


Figura 7 – A poda gerada a partir do resultado da Figura 6

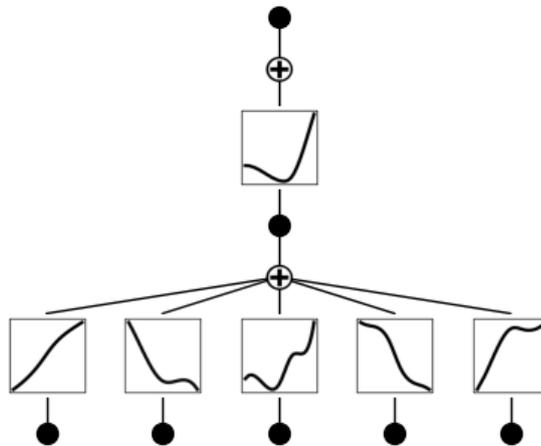


Figura 8 – Resultado preliminares obtidos a partir de testes iniciais utilizando dados da dengue, após a poda

Já, quando explorada a arquitetura de TKAN proposta por Genet e Inzirillo (2024), alguns resultados foram gerados para sistemas univariados também. No entanto, conforme

a implementação disponibilizada por eles, a rede deixou de ter seu potencial de explicabilidade, focando mais no uso das outras propriedades da KAN com adaptações para séries temporais. Também comparamos o resultado desse modelo com os demais.

4.2.1 Coeficiente de determinação

Para poder avaliar o desempenho dos modelos entre si, foi escolhida a métrica do coeficiente de determinação, ou R^2 (MILES, 2005), que representa o percentual da variância dos dados, os quais estão sendo explicados pelo modelo (CAMERON; WINDMEIJER, 1996). Essa medida estatística é usada para avaliar a qualidade do ajuste de um modelo preditivo (GELMAN et al., 2019) em relação aos dados observados pela proporção da variabilidade total. Ele é calculado da seguinte forma:

$$R^2 = 1 - \frac{SSE}{SST} \quad (4.1)$$

onde, SSE se refere a Soma dos Quadrados dos Erros (*Residual Sum of Squares*) e Representa a soma das diferenças ao quadrado entre os valores observados y_i e os valores previstos \hat{y}_i . E, SST é a Soma Total dos Quadrados (*Total Sum of Squares*) que representa a soma das diferenças ao quadrado entre os valores observados y_i e a média dos valores observados \bar{y} . E n representa o número de observações. Sendo assim, temos:

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.2)$$

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (4.3)$$

Os resultados entre 0 e 1 que indicam o quanto o modelo se aproxima de explicar os dados (CAMERON; WINDMEIJER, 1997), sendo o 0 representação de que o modelo não explica nenhuma variabilidade dos dados (equivalente a usar a média como predição), e 1 explica perfeitamente a variabilidade dos dados. Também pode apresentar valores negativos (até -1) indicam que o modelo e causa ainda mais erro sendo pior que outra abordagem mais simples.

5 RESULTADOS

Nesta seção estão expostos os os resultados produzidos com os testes, explorando por meio de tabelas e *plots*, para a averiguação do desempenho dos modelos trazidos para o cenário proposto.

5.1 KOLMOGOROV-ARNOLD NETWORK

Seguindo a metodologia proposta por Xu, Chen e Wang (2024), o primeiro experimento tentou utilizar as KANs da implementação do artigo original para a predição de séries temporais. Para a execução dos experimentos temporais é necessária a criação de uma janela temporal, que desliza e auxilia com que a rede possa prever o próximo passo. Neste experimento foi utilizada uma janela deslizante de 8 semanas, a previsão foi feita 1 passo de cada vez e o treinamento da rede foi feito com 20 épocas

5.1.1 KAN Univariada

Neste experimento, apenas os dados de casos de dengue são passados para a rede. Foi utilizada uma KAN com 3 camadas:

- Camada de entrada: tem o tamanho do *input* (8 semanas)
- Camada oculta: tem 5 unidades, seguindo o exemplo de Xu, Chen e Wang (2024).
- Camada de saída: tem 1 unidade, pois a previsão é feita um passo de cada vez.

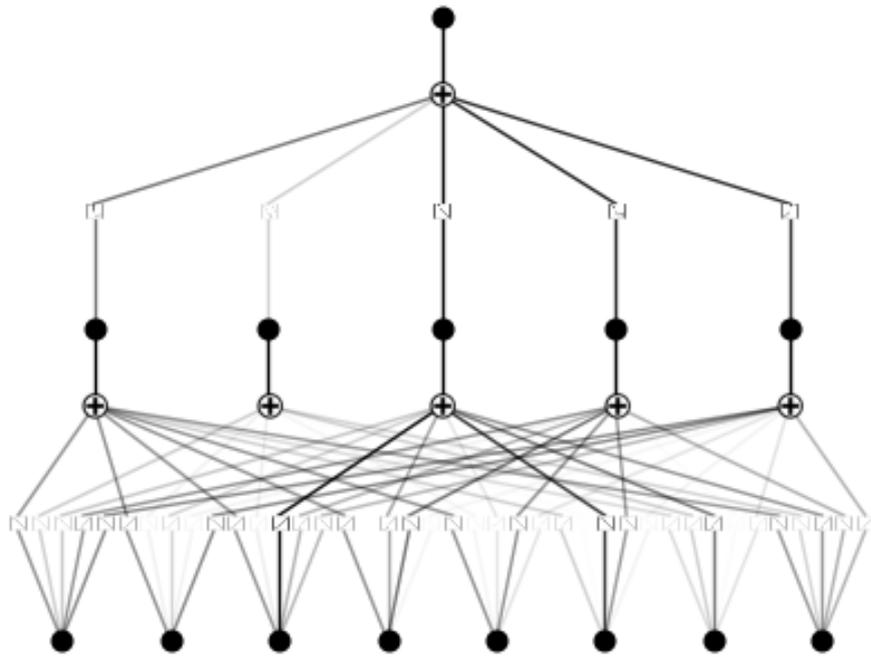


Figura 9 – KAN antes da poda

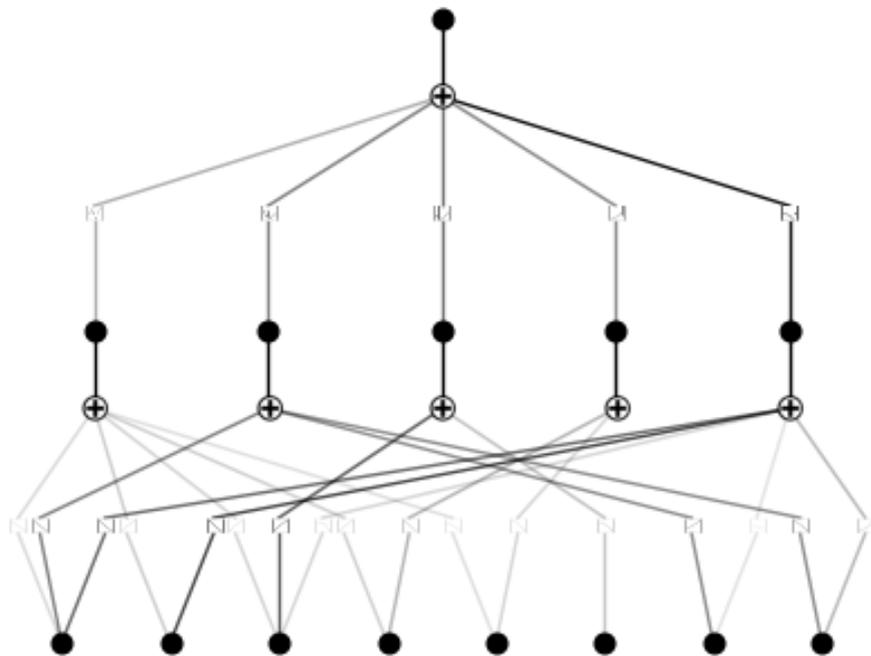


Figura 10 – KAN depois da poda

Após a execução dos experimentos, obteve-se como resultado a Equação 5.1.

$$-0.0002 \times x_1 + 0.0001 \times x_2 + 0.0001 \times x_3 - 0.0002 \times x_4 - 0.0003 \times x_5 + 0.0109 \quad (5.1)$$

5.1.2 KAN Multivariada (MTKAN)

Nesta etapa, tanto os dados da dengue quanto os meteorológicos são passados para a rede. Foi utilizada uma KAN com 3 camadas:

- Camada de entrada: tamanho_input \times quantidade_elementos (ou seja: $8 \times$ a quantidade de colunas de fatores meteorológicos)
- Camada oculta: tem 5 unidades, seguindo o exemplo de Xu, Chen e Wang (2024).
- Camada de saída: quantidade_passos \times quantidade_elementos

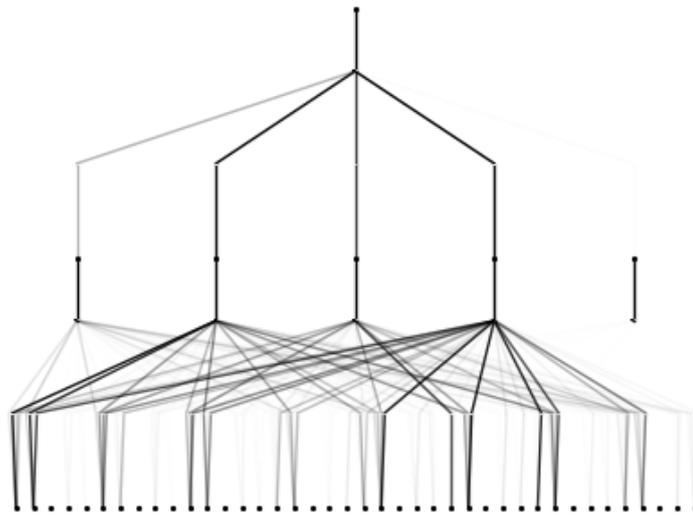


Figura 11 – MTKAN antes da poda

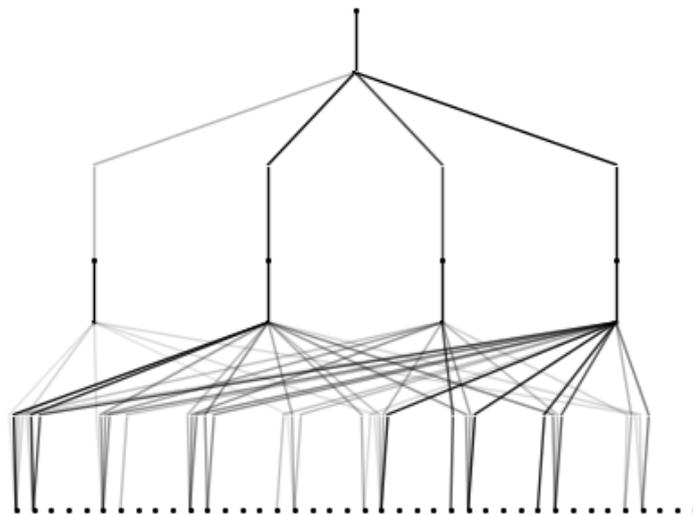


Figura 12 – MTKAN depois da poda

$$\begin{aligned}
&0.0031 \times x_1 - 0.0021 \times x_{11} - 0.001 \times x_{12} + 0.0001 \times x_{16} + 0.0005 \times x_{17} + 0.0035 \\
&\times x_2 + 0.0007 \times x_{21} - 0.0004 \times x_{22} - 0.0023 \times x_{26} + 0.0032 \times x_{27} + 0.0008 \quad (5.2) \\
&\times x_{31} - 0.0026 \times x_{32} + 0.0003 \times x_{36} - 0.0004 \times x_{37} + 0.0002 \times x_7 + 0.0102
\end{aligned}$$

5.1.3 Resultados da KAN

Nos resultados obtidos ao utilizar a KAN para séries temporais, é possível ver que, apesar de ser gerada uma fórmula com o intuito de representar o resultado, o resultado não é facilmente interpretado.

Isto acontece devido ao fato de ao lidar com séries temporais ser necessário o uso das janelas temporais. Essas janelas, transformam dados univariados (por exemplo os casos de dengue) em janelas do tipo:

$$[0, 0, 10, 12, 25, 200, 190, 150]$$

Então, a rede trabalha apenas com esta "janela". Sendo assim, na fórmula gerada, os elementos (x_1, x_2, \dots) se referem à posição da janela. Na seção de conclusão do trabalho fala-se um pouco mais sobre este problema.

5.2 TEMPORAL KOLMOGOROV-ARNOLD NETWORK

Nesta seção são explorados os modelos de TKAN, uma proposta de Genet e Inzirillo (2024) visando melhorar o resultado das KANs em séries temporais, porém perdendo a interpretabilidade dos modelos.

5.2.1 TKAN Univariada

Neste experimento, foi utilizada uma TKAN apenas a quantidade de casos como dados de entrada. A Figura 13 mostra as configurações da rede Temporal Kolmogorov-Arnold.

```

model_tkan = Sequential([
    TKAN(200, sub_kan_configs=[{'spline_order': 4, 'grid_size': 12},
                               {'spline_order': 3, 'grid_size': 10},
                               {'spline_order': 5, 'grid_size': 8}],
        return_sequences=False, use_bias=True),
    Dense(units=future_steps, activation='linear')
])

```

Figura 13 – Configuração da TKAN em Python

Para comparação, uma LSTM foi utilizada para a mesma tarefa. A quantidade de passos seguintes foi variada, para verificar como as redes desempenham. As Figuras 14, 15 e 16 mostram alguns resultados obtidos.

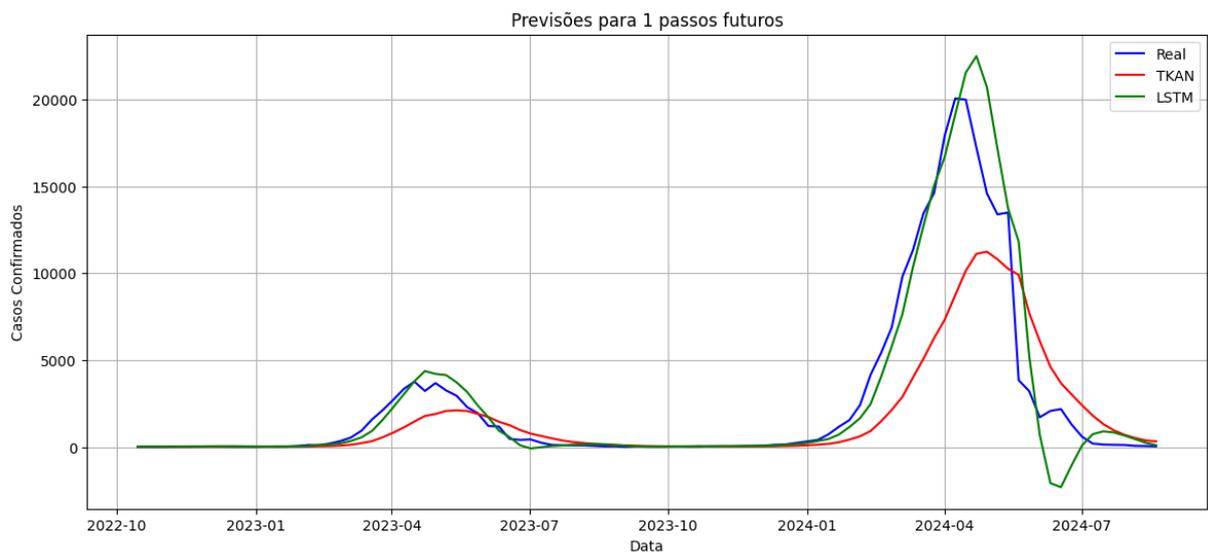


Figura 14 – Resultados com 1 passo futuro

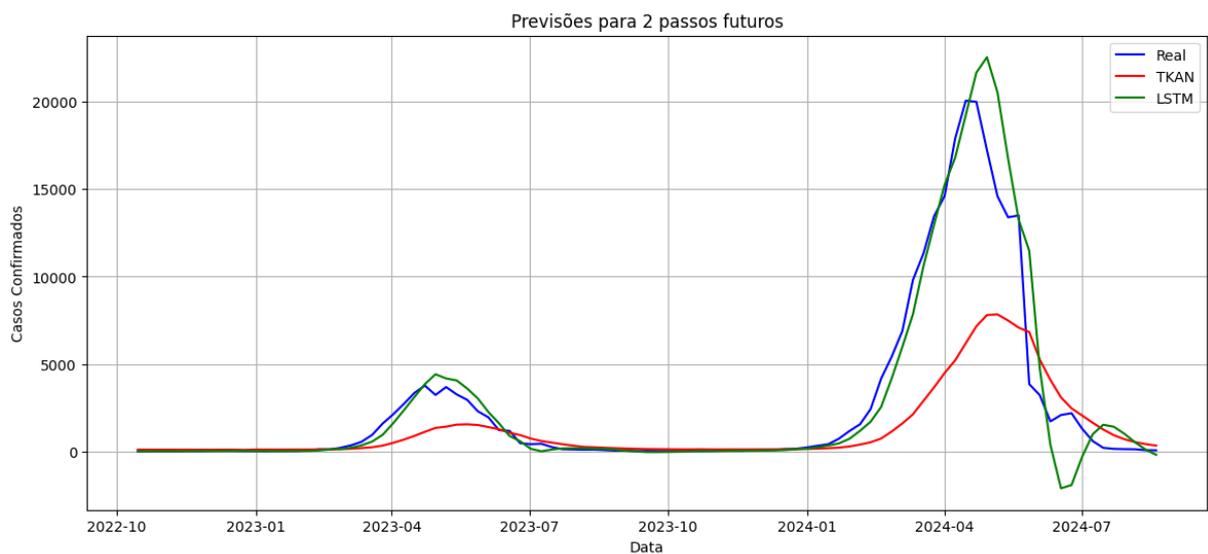


Figura 15 – Resultados com 2 passos futuros

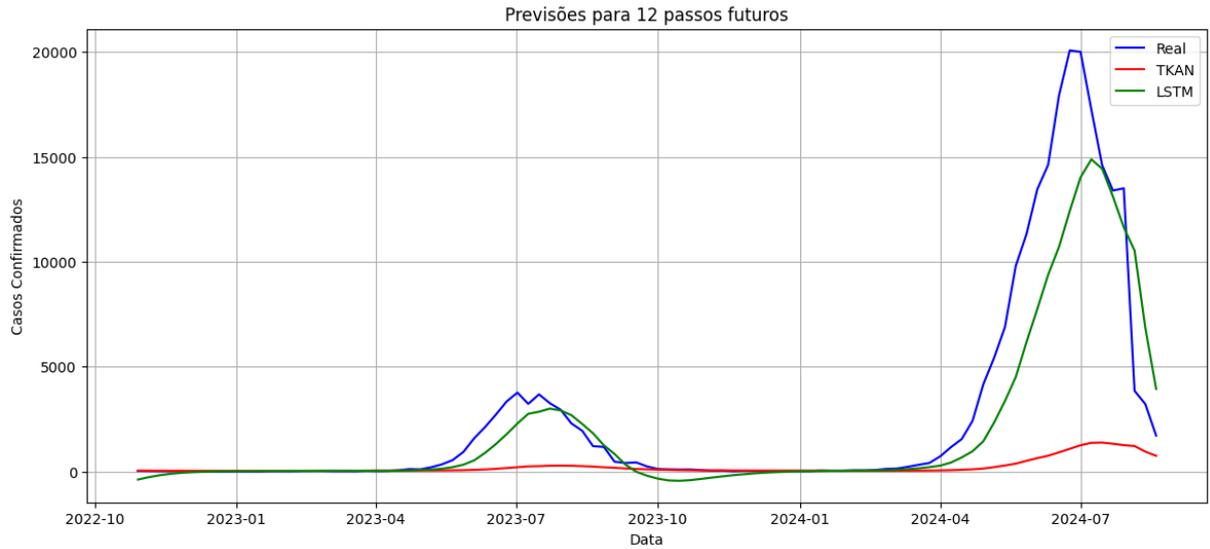


Figura 16 – Resultados com 12 passos futuros

A Tabela 2 mostra os resultados obtidos nestes testes. Nestes resultados, é possível ver que apesar de a TKAN não desempenhar tão bem quanto a LSTM, ela tem bons resultados, principalmente quando se trata da predição de poucos passos adiante.

Tabela 2 – Resultados das redes TKAN e LSTM utilizando apenas uma variável

<i>Passos futuros</i>	R^2_{TKAN}	R^2_{LSTM}
1	0.632837	0.903185
2	0.448783	0.845495
3	0.041943	0.768584
5	-0.055776	0.622695
6	-0.004877	0.560174
7	-0.098872	0.510313
10	-0.202256	0.299049
12	-0.216470	0.151444

5.2.1.1 Predição de outros parâmetros

Também é possível utilizar a TKAN univariada para predição em outras séries temporais do conjunto de testes. É o caso, por exemplo, da temperatura média no estado (Figura 17).

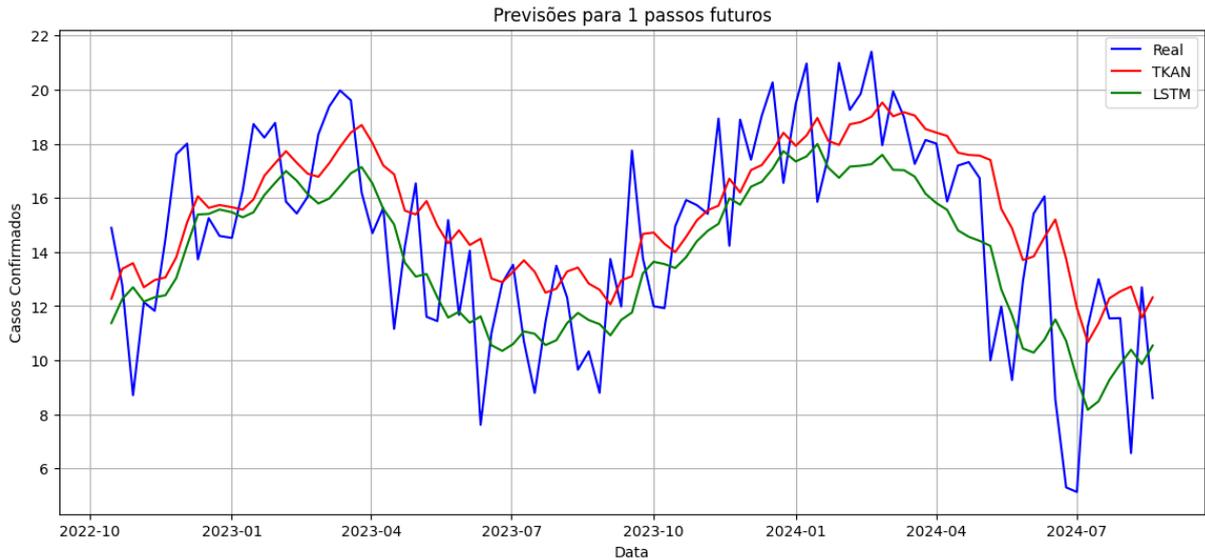


Figura 17 – Predição da temperatura no estado

Nesta figura é possível notar que ambos os modelos, LSTM e TKAN, conseguem captar a curva dos dados e se adaptar, tendo bons resultados.

5.2.2 TKAN Multivariada

Os testes também foram feitos utilizando as outras variáveis do conjunto de dados criado neste trabalho, supondo que o clima tenha influência na quantidade de casos de dengue. Como o mosquito da dengue leva, aproximadamente, duas semanas para passar da fase de ovo para a fase adulta, os dados climáticos, neste teste, foram atrasados em duas semanas. A tabela 3 mostra que utilizando as variáveis climáticas como parâmetros das redes, os resultados da TKAN melhoram enquanto os da LSTM pioram. A Figura 18 mostra a predição das redes, considerando previsões de 1 passo futuro (uma semana) de cada vez.

Tabela 3 – Resultados das redes TKAN e LSTM, levando em consideração os fatores climáticos do conjunto de dados

<i>Passos futuros</i>	$R^2 TKAN$	$R^2 LSTM$
1	0.747696	0.844984
2	0.597245	0.755622
3	0.325963	0.645172
5	0.138507	0.444467
6	-0.012055	0.339028
7	0.041355	0.237938
10	-0.176499	0.114009
12	-0.307946	0.022275

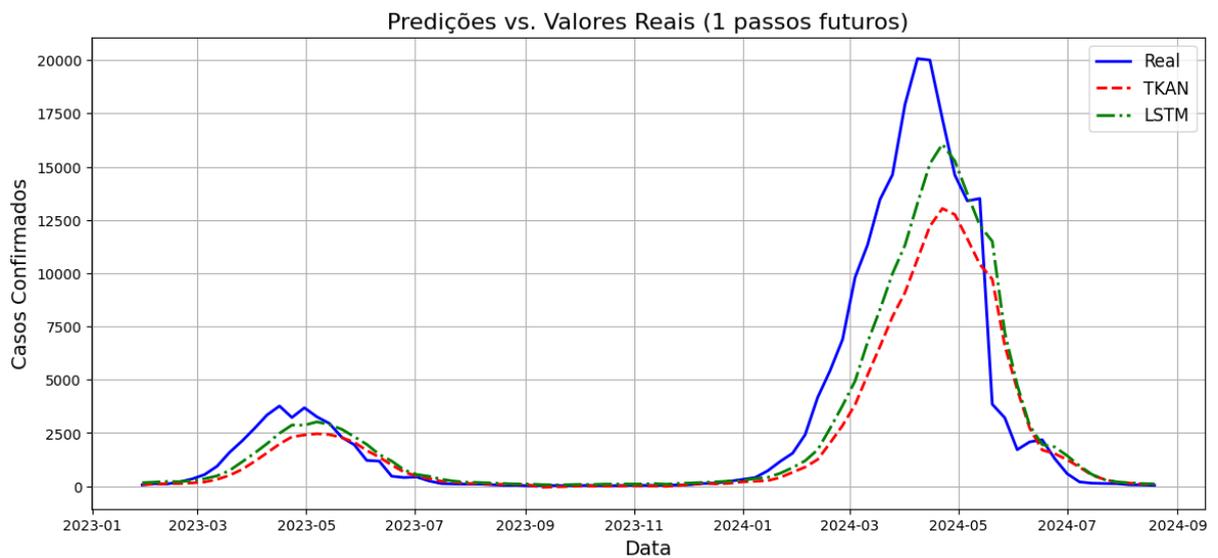


Figura 18 – Resultados das redes multivariadas, com 1 passo futuro

5.3 DISPONIBILIZAÇÃO DOS DADOS

Alguns dados obtidos neste trabalho foram disponibilizados *online* por meio de um *dashboard*¹. Isto foi feito pela falta de disponibilidade de acesso a dados meteorológicos históricos como estes, apesar de serem dados públicos. O *dashboard*, ainda em desenvolvimento, é mostrado na Figura 19.

¹Dashboard com alguns dados obtidos

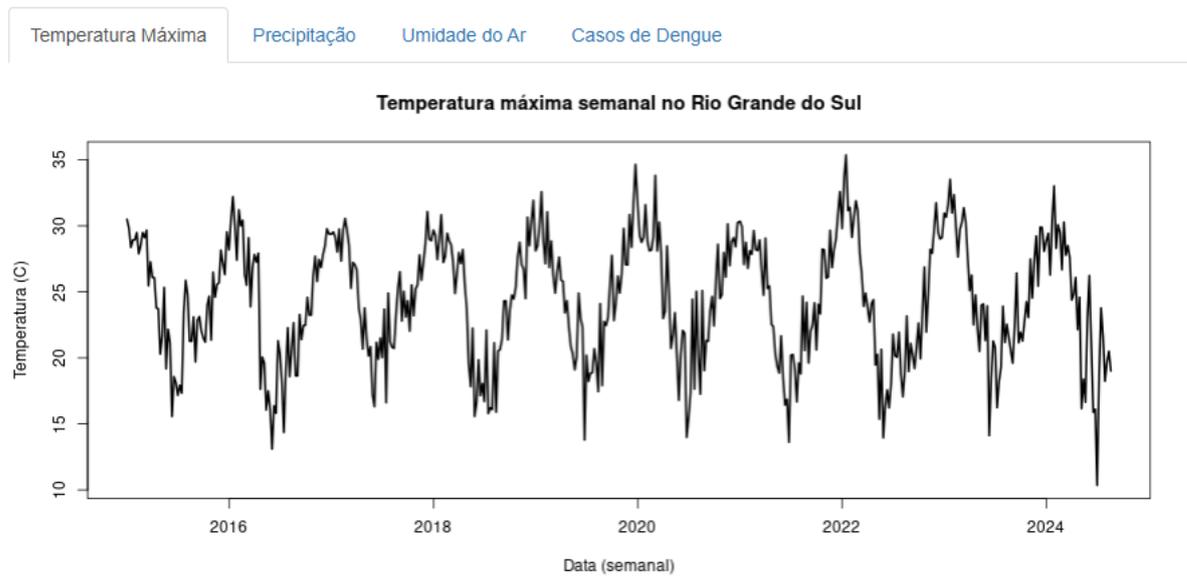


Figura 19 – Interface do *dashboard* disponibilizado

Também, o *dataset* completo será disponibilizado publicamente, com o objetivo de em trabalhos futuros a etapa de obtenção dos dados ser mais simples e rápida.

6 CONCLUSÃO

Este trabalho apresentou um estudo sobre a aplicação das Redes Kolmogorov-Arnold (KAN) e sua variante temporal (TKAN) para a previsão da incidência de dengue no estado do Rio Grande do Sul. Durante o desenvolvimento, foi possível explorar a potencialidade dessas redes na modelagem preditiva e ressaltar sua proposta de maior explicabilidade, um diferencial relevante em aplicações críticas como a saúde pública.

Entre os principais pontos positivos, destaca-se a relevância do uso de dados climáticos associados à incidência de dengue, proporcionando *insights* valiosos sobre a relação entre os padrões climáticos e a disseminação da doença. O uso das *TKANs* univariadas e multivariadas trouxe resultados interessantes em termos de previsões a curto prazo, mesmo que inferiores aos obtidos com redes LSTM em algumas configurações.

Outro aspecto importante foi a metodologia de processamento e integração de dados. A unificação de grandes volumes de dados meteorológicos e epidemiológicos, seguida por sua organização em um formato acessível e representativo. A disponibilização *online* dos dados busca reforçar o caráter colaborativo deste estudo, ampliando sua utilidade como base para futuras investigações na área.

Por outro lado, algumas limitações foram identificadas, especialmente em relação à dificuldade de adaptar as KANs para sistemas temporais sem comprometer sua capacidade de explicação. Essa limitação aponta para a necessidade de aprimoramentos arquiteturais que possam explorar melhor a complexidade dos dados sem sacrificar a interpretabilidade.

Por fim, este estudo contribui para o campo da saúde pública ao demonstrar ferramentas inovadoras no monitoramento e previsão de doenças como a dengue. Ele também visa abrir caminhos para a combinação futura de métodos explicáveis com técnicas robustas já consolidadas, como as redes LSTM, promovendo avanços na utilização de inteligência artificial para decisões mais informadas e eficazes.

6.1 LIMITAÇÕES

Por ser uma tecnologia bastante recente (LIU et al., 2024), as bibliotecas de redes Kolmogorov-Arnold ainda estão em desenvolvimento. Vários artigos trazem diferentes propostas de implementação do tema, porém em poucos casos códigos utilizados são disponibilizados. Outro problema é na representação da explicabilidade. Mesmo em trabalhos que prometem explicabilidade em séries temporais, como é o caso de Xu, Chen e Wang (2024), a explicabilidade apenas é citada, e não mostrada.

Outra possível limitação deste trabalho são os dados utilizados: apesar de a den-

que ser uma doença sazonal, pode ser que os fatores climáticos não sejam exatamente conclusivos para prever a quantidade de casos. Por exemplo, a Figura 20 mostra uma comparação entre a temperatura semanal e a quantidade de casos semanais. Apesar de possivelmente existir uma relação entre os fatores, não é possível a partir da temperatura prever grandes picos da doença, como é o que acontece.

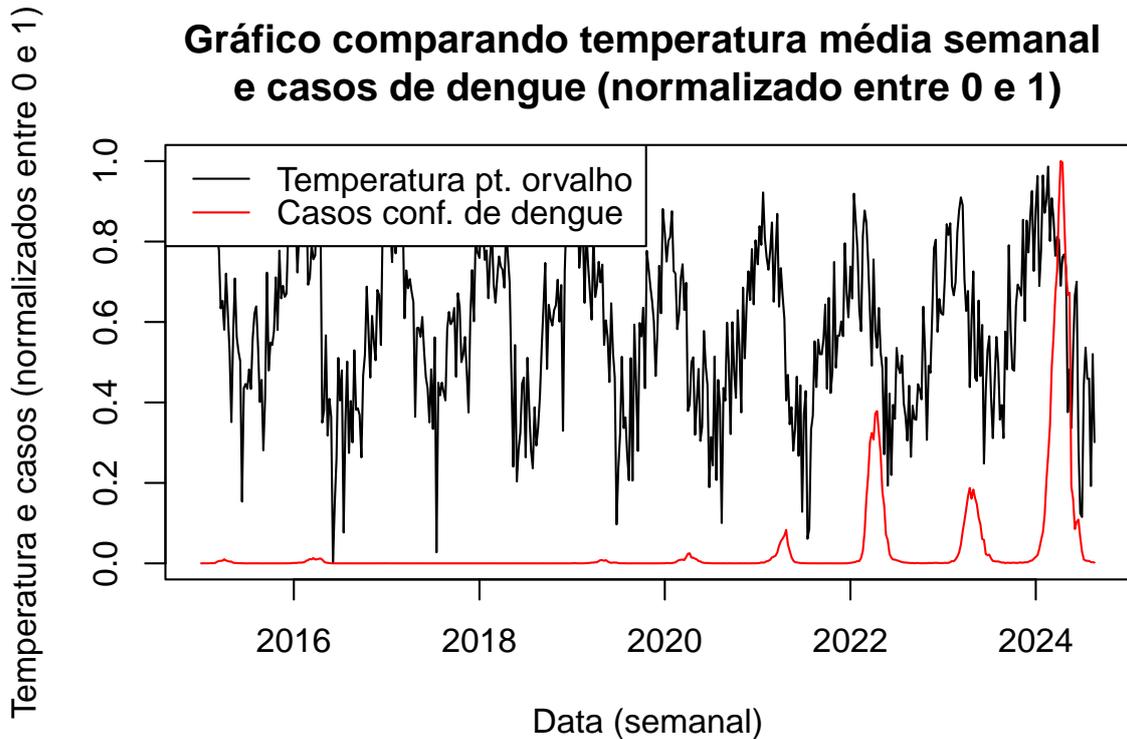


Figura 20 – Comparação entre a temperatura média semanal e a quantidade de casos de dengue. O eixo Y de ambas as séries está normalizado entre 0 e 1, a fim da comparação entre as séries

6.2 TRABALHOS FUTUROS

Este trabalho lança as bases para diversas direções de pesquisa futura, com foco em ampliar e aprofundar os resultados aqui obtidos:

- **Aprimoramento das TKANs:** Explorar melhorias arquiteturais para aumentar o desempenho das redes TKAN, especialmente em cenários multivariados, sem comprometer sua capacidade de explicação. Isso pode incluir ajustes na parametrização das funções de ativação aprendíveis ou na adaptação para captura de interações mais complexas entre variáveis.
- **Integração com LSTMs:** Desenvolver abordagens híbridas que combinem a explicabilidade das KANs com o desempenho robusto das redes LSTM.

- **Explicabilidade Avançada:** Investigar o uso de ferramentas de inteligência artificial explicável para melhorar ainda mais a transparência dos resultados obtidos pelas TKANs e LSTMs, validando a aplicabilidade em contextos de saúde pública.

REFERÊNCIAS

ADEGOKE, B. O.; ODUGBOSE, T.; ADEYEMI, C. Data analytics for predicting disease outbreaks: A review of models and tools. **International journal of life science research updates [online]**, v. 2, n. 2, p. 1–9, 2024.

ALEIXO, R. et al. Predicting dengue outbreaks with explainable machine learning. In: IEEE. **2022 22nd IEEE International Symposium on Cluster, Cloud and Internet Computing (CCGrid)**. [S.l.], 2022. p. 940–947.

BELLE, A. et al. Big data analytics in healthcare. **BioMed research international**, Wiley Online Library, v. 2015, n. 1, p. 370194, 2015.

BOMFIM, R. et al. Predicting dengue outbreaks at neighbourhood level using human mobility in urban areas. **Journal of the Royal Society Interface**, The Royal Society, v. 17, n. 171, p. 20200691, 2020.

BUTANTAN. **Por que os casos de dengue aumentaram no Brasil? Circulação dos quatro vírus e mudanças climáticas ajudam a explicar crescimento**: Presença simultânea dos quatro sorotipos da dengue favorece infecções; calor e chuvas intensas contribuem para reprodução do mosquito aedes aegypti. Portal do Butantan, 2024. Acessado em 21 out 2024. Disponível em: <<https://butantan.gov.br/noticias/por-que-os-casos-de-dengue-aumentaram-no-brasil-circulacao-dos-quatro-virus-e-mudancas-climaticas-ajudam-a-explicar-crescimento>>.

CAMERON, A. C.; WINDMEIJER, F. A. R-squared measures for count data regression models with applications to health-care utilization. **Journal of Business & Economic Statistics**, Taylor & Francis, v. 14, n. 2, p. 209–220, 1996.

_____. An r-squared measure of goodness of fit for some common nonlinear regression models. **Journal of econometrics**, Elsevier, v. 77, n. 2, p. 329–342, 1997.

CAMPANHOL, A. M. d. C. Explicabilidade de modelo long short-term memory (lstm) para previsão de dengue em porto alegre. **UFSM**, Universidade Federal de Santa Maria, 2024.

CHUMPU, R.; KHAMSEMANAN, N.; NATTEE, C. The association between dengue incidences and provincial-level weather variables in thailand from 2001 to 2014. **Plos one**, Public Library of Science San Francisco, CA USA, v. 14, n. 12, p. e0226945, 2019.

COZMAN, F. G.; KAUFMAN, D. Viés no aprendizado de máquina em sistemas de inteligência artificial: a diversidade de origens e os caminhos de mitigação. **Revista USP**, n. 135, p. 195–210, 2022.

DEB, S.; DEB, S. An ensemble method for early prediction of dengue outbreak. **Journal of the Royal Statistical Society Series A: Statistics in Society**, Oxford University Press, v. 185, n. 1, p. 84–101, 2022.

DHAR, T. et al. Challenges of deep learning in medical image analysisimproving explainability and trust. **IEEE Transactions on Technology and Society**, IEEE, v. 4, n. 1, p. 68–75, 2023.

DOMINGOS, P. **O algoritmo mestre: como a busca pelo algoritmo de machine learning definitivo recriará nosso mundo.** [S.l.]: Novatec Editora, 2017.

DURÁN, J. M. Dissecting scientific explanation in ai (sxai): A case for medicine and healthcare. **Artificial Intelligence**, Elsevier, v. 297, p. 103498, 2021.

ENSLEN, A. W.; NETO, A. S. L.; CASTRO, M. C. Infestation measured by aedes aegypti larval surveys as an indication of future dengue epidemics: an evaluation for brazil. **Transactions of the Royal Society of Tropical Medicine and Hygiene**, Oxford University Press, v. 114, n. 7, p. 506–512, 2020.

FIOCRUZ. **Longa trajetória:** O mosquito aedes aegypti faz parte da história e vem se espalhando pelo mundo desde o período das colonizações. Instituto Oswaldo Cruz (IOC/Fiocruz), 2024. Acessado em 21 out 2024. Disponível em: <<https://www.ioc.fiocruz.br/dengue/textos/longatraje.html>>.

FISCHER, T.; KRAUSS, C. Deep learning with long short-term memory networks for financial market predictions. **European journal of operational research**, Elsevier, v. 270, n. 2, p. 654–669, 2018.

GELMAN, A. et al. R-squared for bayesian regression models. **The American Statistician**, Taylor & Francis, 2019.

GENET, R.; INZIRILLO, H. Tkan: Temporal kolmogorov-arnold networks. **arXiv preprint arXiv:2405.07344**, 2024.

GRAVES, A.; GRAVES, A. Long short-term memory. **Supervised sequence labelling with recurrent neural networks**, Springer, p. 37–45, 2012.

HAHNE, F. et al. Unsupervised machine learning. **Bioconductor case studies**, Springer, p. 137–157, 2008.

KOLODNER, J. **Case-based reasoning.** [S.l.]: Morgan Kaufmann, 2014.

LARASATI, R. **Trust and explanation in Artificial Intelligence systems: a healthcare application in disease detection and preliminary diagnosis.** 2023. Tese (Doutorado) — The Open University, 2023.

LIU, Z. et al. Kan: Kolmogorov-arnold networks. **arXiv preprint arXiv:2404.19756**, 2024.

LOH, H. W. et al. Application of explainable artificial intelligence for healthcare: A systematic review of the last decade (2011–2022). **Computer Methods and Programs in Biomedicine**, Elsevier, v. 226, p. 107161, 2022.

LUNDBERG, S. A unified approach to interpreting model predictions. **arXiv preprint arXiv:1705.07874**, 2017.

MALHOTRA, P. et al. Long short term memory networks for anomaly detection in time series. In: **Esann.** [S.l.: s.n.], 2015. v. 2015, p. 89.

MCGOUGH, S. F. et al. A dynamic, ensemble learning approach to forecast dengue fever epidemic years in brazil using weather and population susceptibility cycles. **Journal of The Royal Society Interface**, The Royal Society, v. 18, n. 179, p. 20201006, 2021.

MILES, J. R-squared, adjusted r-squared. **Encyclopedia of statistics in behavioral science**, Wiley Online Library, 2005.

MINISTÉRIO DA SAÚDE DO BRASIL. **Dengue**. MINISTÉRIO DA SAÚDE DO BRASIL, 2024. Acessado em 05 out 2024. Disponível em: <<https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/d/dengue>>.

NASTESKI, V. An overview of the supervised machine learning methods. **Horizons. b**, v. 4, n. 51-62, p. 56, 2017.

NISHIMURA, Y. et al. Extraction of important temporal order for explainable ai on time-series data. In: IEEE. **2023 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)**. [S.l.], 2023. p. 659–664.

PROME, S. S. et al. Prediction of dengue cases in bangladesh using explainable machine learning approach. In: IEEE. **2024 International Conference on Inventive Computation Technologies (ICICT)**. [S.l.], 2024. p. 1–5.

RAMADONA, A. L. et al. Prediction of dengue outbreaks based on disease surveillance and meteorological data. **PloS one**, Public Library of Science San Francisco, CA USA, v. 11, n. 3, p. e0152688, 2016.

ROSTER K.; RODRIGUES F. A. Neural networks for dengue prediction: a systematic review. **arXiv preprint arXiv:2106.12905**, 2021.

SARANYA, A.; SUBHASHINI, R. **A systematic review of Explainable Artificial Intelligence models and applications: Recent developments and future trends. Decision Analytics Journal 7 (2023), 100230.** 2023.

SCHMIDT-HIEBER, J. The kolmogorov–arnold representation theorem revisited. **Neural networks**, Elsevier, v. 137, p. 119–126, 2021.

SCHUMAKER, L. **Spline functions: basic theory**. [S.l.]: Cambridge university press, 2007.

SECRETARIA DA SAÚDE DE SP. **INFORME TÉCNICO: DENGUE**. SECRETARIA DE ESTADO DA SAÚDE DE SP, 2024. Acessado em 21 out 2024. Disponível em: <https://saude.sp.gov.br/resources/cve-centro-de-vigilancia-epidemiologica/areas-de-vigilancia-doencas-de-transmissao-por-vetores-e-zoonoses/doc/dengue/dengue_inf2103.htm>.

SECRETARIA DA SAÚDE DO RS. **Aumento de casos de dengue em crianças e adolescentes impulsiona campanha de vacinação**: Vacina está disponível na capital, vale do gravataí, alto uruguai, vale do rio pardo e vale do sinos. SECRETARIA DA SAÚDE DO RS, 2024. Acessado em 07 out 2024. Disponível em: <<https://saude.rs.gov.br/aumento-de-casos-de-dengue-em-criancas-e-adolescentes-impulsiona-campanha-de-vacinacao>>.

_____. **Dengue**. SECRETARIA DA SAÚDE DO RS, 2024. Acessado em 06 out 2024. Disponível em: <<https://saude.rs.gov.br/dengue>>.

_____. **Nota Informativa nº 07/2024 DVE/ CEVS/SES-RS**. SECRETARIA DA SAÚDE DO RS, 2024. Acessado em 05 out 2024. Disponível em: <<https://saude.rs.gov.br/upload-arquivos/202404/18102525-nota-07-2024-perfil-obitos-dengue-rs.pdf>>.

_____. **Vigilância em Saúde monitora aumento de casos de dengue no RS**. SECRETARIA DA SAÚDE DO RS, 2024. Acessado em 05 out 2024. Disponível em: <<https://saude.rs.gov.br/vigilancia-em-saude-monitora-aumento-de-casos-de-dengue-no-rs>>.

SHAILAJA, K.; SEETHARAMULU, B.; JABBAR, M. Machine learning in healthcare: A review. In: IEEE. **2018 Second international conference on electronics, communication and aerospace technology (ICECA)**. [S.l.], 2018. p. 910–914.

SHUMWAY, R. H. et al. Arima models. **Time series analysis and its applications: with R examples**, Springer, p. 75–163, 2017.

SIAMI-NAMINI, S.; TAVAKOLI, N.; NAMIN, A. S. A comparison of arima and lstm in forecasting time series. In: IEEE. **2018 17th IEEE international conference on machine learning and applications (ICMLA)**. [S.l.], 2018. p. 1394–1401.

SIRIYASATIEN, P. et al. Dengue epidemics prediction: A survey of the state-of-the-art based on data science processes. **IEEE Access**, IEEE, v. 6, p. 53757–53795, 2018.

VACA-RUBIO, C. J. et al. Kolmogorov-arnold networks (kans) for time series analysis. **arXiv preprint arXiv:2405.08790**, 2024.

WIEMKEN, T. L.; KELLEY, R. R. Machine learning in epidemiology and health outcomes research. **Annu Rev Public Health**, v. 41, n. 1, p. 21–36, 2020.

XU, K.; CHEN, L.; WANG, S. Kolmogorov-arnold networks for time series: Bridging predictive power and interpretability. **arXiv preprint arXiv:2406.02496**, 2024.

YU, Y. et al. A review of recurrent neural networks: Lstm cells and network architectures. **Neural computation**, MIT Press One Rogers Street, Cambridge, MA 02142-1209, USA journals-info , v. 31, n. 7, p. 1235–1270, 2019.

ZHA, W. et al. Forecasting monthly gas field production based on the cnn-lstm model. **Energy**, Elsevier, v. 260, p. 124889, 2022.

ZHOU, Z.-H. **Machine learning**. [S.l.]: Springer nature, 2021.