

SpII - Arquitetura Computacional Inteligente para Manejo de Irrigação

Iuri Crisnei Kunz¹, Luis Claudio Gubert¹

¹Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Sul - *Campus* Ibirubá
Rua Nelsi Ribas Fritsch, 1111 – CEP: 98200-000 – Ibirubá – RS – Brasil

iurikunz@hotmail.com

luis.gubert@ibiruba.ifrs.edu.br

Abstract. *Efficient water management in irrigated agriculture is essential for hydrological sustainability, especially in regions with limited resources. Reference evapotranspiration (ET_o) is a key variable in irrigation planning and is traditionally estimated using methods such as Penman-Monteith, which require several meteorological variables that are not always available. This study proposes the use of artificial neural networks (ANNs), particularly the Long Short-Term Memory (LSTM) model, to estimate daily ET_o based on a reduced set of climatic variables, using data from the meteorological station at IFRS – Ibirubá Campus. Different configurations and input combinations were tested, and the models were evaluated using metrics such as RMSE, MAE, and the performance index “c”. The results showed that although the LSTM model performed well with reduced data, there is still significant room for improvement. The inclusion of additional variables, such as solar radiation, is suggested as a way to improve estimation accuracy and enable practical application in irrigation systems. The approach adopted proved to be a viable alternative in contexts with limited meteorological data availability, contributing to more efficient and sustainable irrigation management.*

Resumo. *Este trabalho propõe o uso de redes neurais artificiais (RNA), com destaque para o modelo LSTM (Long Short-Term Memory), para estimar a ET_o diária a partir de um conjunto reduzido de variáveis climáticas, utilizando dados da estação meteorológica do IFRS – Campus Ibirubá. Foram testadas diferentes configurações e combinações de entrada, avaliando-se os modelos por métricas como RMSE, MAE e o índice c de desempenho. Os resultados mostraram que, embora o modelo LSTM tenha apresentado desempenho promissor com dados reduzidos, ainda há margem significativa para melhorias. A inclusão de variáveis adicionais, como radiação solar, é sugerida como caminho para aumentar a precisão das estimativas e viabilizar o uso prático em sistemas de irrigação. A abordagem adotada demonstrou ser uma alternativa viável em contextos de baixa disponibilidade de dados meteorológicos, contribuindo para um manejo mais eficiente e sustentável da irrigação.*

1. Introdução

Os recursos hídricos são limitados e estratégicos para a humanidade, encontrando-se atualmente em situação vulnerável, marcada por degradação e escassez. A água é essencial à vida, aos processos relacionados à sustentabilidade e ao desenvolvimento econômico e social das regiões. Todos os organismos dependem da água para sua sobrevivência. Além de utilizá-la em suas funções vitais, a espécie humana também usa água para muitas outras atividades (TUCCI; HESPANHOL; NETTO, 2001; TUNDISI; MATSUMURA-TUNDISI, 2020).

Dentre os diversos usos da água, a agricultura irrigada se destaca por sua alta demanda e impacto sobre os recursos hídricos. Considerada um uso consuntivo da água por consumir e alterar suas características qualitativas e quantitativas, sendo que a maior parte é perdida por evapotranspiração a qual consiste na perda de água do ambiente para a atmosfera, representada pela associação dos fenômenos de evaporação da água do solo e transpiração das plantas, tornando-a temporariamente indisponível para outros usos. No Brasil, a irrigação é responsável pelo maior consumo hídrico, representando metade das retiradas de água do país. Em 2019, a área irrigada totalizava 8,2 milhões de hectares, com projeções de atingir 12,4 milhões até 2040, reforçando a necessidade de planejamentos adequados para garantir segurança hídrica. Esse crescimento não pode se basear apenas no aumento do consumo de recursos hídricos e no desenvolvimento de novos equipamentos de irrigação, mas depende cada vez mais de ganhos de eficiência nos sistemas existentes. Assim, a tecnologia no campo torna-se uma aliada crucial não apenas para otimizar rendimentos e garantir operações mais seguras, mas também para aumentar a produção agrícola de forma sustentável.

Em projetos de irrigação, diversas variáveis influenciam as metodologias utilizadas para promover o uso racional da água. Uma das técnicas mais implementadas no manejo da irrigação é a análise climatológica, na qual variáveis ambientais como *temperatura, pressão, umidade, velocidade do vento e radiação* são utilizadas para alimentar modelos de estimativa de evapotranspiração (MAROUELLI et al., 2011; DOORENBOS; PRUITT, 1977; ALLEN et al., 1998). Para tal estimativa, considera-se a metodologia de Penman-Monteith como o padrão, mas por requerer um elevado número de parâmetros meteorológicos, por vezes ele é substituído, visando a redução da complexidade de sua implementação (JHA et al., 2019; XUE et al., 2020; ALLEN, 1986; CAMARGO; SENTELHAS, 1997). Entretanto os demais métodos comumente utilizados para substituir o padrão PM é calibrado para condições específicas, não sendo aplicáveis universalmente. Nesse caso, uma opção extra para tentar contornar esses problemas acaba sendo justamente o uso de redes neurais, que foi a abordagem utilizada neste trabalho.

Este trabalho apresenta uma análise de rede neural artificial para auxiliar no manejo da irrigação com base na evapotranspiração de referência diária, utilizando uma rede LSTM devido a características que serão abordadas no capítulo 2.2, explorando dados climáticos obtidos na estação meteorológica situada no IFRS - Campus Ibirubá, utilizando um conjunto reduzido de variáveis meteorológicas em comparação aos métodos tradicionais, tornando a estimativa mais acessível e viável de ser implementada. Finalmente, os resultados obtidos pelo modelo de rede neural são comparados com o método padrão de Penman-Monteith. O artigo se encontra organizado da seguinte forma: na seção 2 apresenta a revisão bibliográfica. Na seção 3 é apresentado o estudo dos trabalhos re-

lacionados. A seção 4, são detalhados os materiais e métodos que foram aplicados no desenvolvimento. Por fim, nas seções 5 e 6 são apresentados e discutidos os resultados e conclusões obtidos neste trabalho.

2. Fundamentação Teórica

Nesta seção, são apresentados os conceitos teóricos referentes às temáticas da evapotranspiração, sua definição, importância e os métodos utilizados para sua estimativa, e fundamentos das redes neurais artificiais, com ênfase em sua aplicação na estimativa da evapotranspiração.

2.1. Evapotranspiração e Método Penman-Monteith

A evapotranspiração (ET) consiste na combinação de dois processos distintos por meio dos quais ocorre a perda de água, pela superfície do solo, via evaporação, e pelas plantas, por meio da transpiração, durante um determinado período de tempo (KRISHNA, 2019; SOARES, 2019; FENG et al., 2017). A quantidade de água requerida por uma cultura é calculada a partir da evapotranspiração de referência (E_{To}) e do coeficiente da cultura (K_c). Por isso, a compreensão da evapotranspiração é essencial para planejar economicamente a utilização dos recursos hídricos, como por exemplo a necessidade de reposição de água para as culturas feita por meio da evapotranspiração da cultura (E_{Tc}) (ALLEN et al., 1998; DOORENBOS; PRUITT, 1977).

A evapotranspiração de referência (E_{To}) é considerada a evapotranspiração de uma superfície de referência, em condições do solo sem restrição hídrica e com uma cultura rasteira em pleno desenvolvimento. Os únicos fatores que afetam a evapotranspiração de referência são parâmetros climáticos, consequentemente, ela é calculada a partir de dados meteorológicos. Dessa forma, os principais parâmetros climáticos que afetam a E_{To} são: radiação solar, velocidade do vento, temperatura e umidade do ar (ALLEN et al., 1998)

Os métodos de obtenção da evapotranspiração estão divididos em métodos diretos e indiretos. Entre os diretos o método mais preciso para medir a E_{To} é o lisímetro, mas devido aos altos custos dos equipamentos, tal método quase sempre se restringe à pesquisa, justificando seu uso apenas para desenvolver e calibrar métodos de estimativas (PEREIRA; NOVA; SEDIYAMA, 1997). Entre os métodos indiretos existem vários modelos disponíveis para estimar a E_{To} . Geralmente se baseiam em fórmulas que combinam diferentes elementos climáticos. Dentre eles, o método Penman-Monteith foi selecionado pela Organização das Nações Unidas para Alimentação e Agricultura como padrão no cálculo da evapotranspiração de referência. Ele é recomendado como o mais adequado e preciso, pois incorpora aspectos termodinâmicos e aerodinâmicos da cultura, considerando as resistências aerodinâmica e da vegetação, e por sua capacidade de proporcionar resultados similares aos que se obtém pelas medições diretas em diversos tipos de clima (ALLEN et al., 1998).

O método FAO Penman-Monteith é selecionado como o método pelo qual a evapotranspiração desta superfície de referência (E_{To}) pode ser determinada de forma inequívoca e como o método que fornece valores consistentes de E_{To} em todas as regiões e climas (ALLEN et al., 1998).

Para a estimativa de ETo pelo método de Penman-Monteith-FAO utiliza-se a seguinte expressão:

$$ET_o = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T+273} U_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34U_2)} \quad (1)$$

onde: ET_o é a evapotranspiração de referência, R_n é a radiação líquida na superfície da cultura, G é a densidade do fluxo de calor do solo, T é a temperatura média diária do ar a 2m de altura, U_2 é a velocidade do vento a 2m de altura, e_s é a pressão de vapor de saturação, e_a é a pressão de vapor real, $e_s - e_a$ é o déficit de pressão de vapor de saturação, Δ é a inclinação da curva de pressão de vapor de saturação em função da temperatura, uma constante derivada das propriedades termodinâmicas do ar e do vapor d'água, γ é a constante psicrométrica, determinada pelas propriedades do ar e da pressão atmosférica.

Contudo, esse modelo requer variáveis meteorológicas que nem sempre estão disponíveis. Sendo assim, pesquisas têm sido desenvolvidas no sentido de avaliar métodos que utilizem menor número de variáveis meteorológicas e apresentem desempenho semelhante ao método padrão. Como alternativa para solucionar este problema, destaca-se o uso dos métodos empíricos de estimativa da ETo, mas por serem calibrados para condições específicas, não são aplicáveis universalmente, porém apresentam melhores resultados do que aqueles mais genéricos e fisicamente mais reais (PEREIRA; NOVA; SEDIYAMA, 1997).

Assim, da mesma maneira, a tecnologia no campo emerge como uma importante aliada, não apenas para ajudar a suprir essa demanda com maiores produções, mas também para otimizar rendimentos, além de garantir maior segurança nas operações (PAZ; TEODORO; MENDONÇA, 2000). Na agricultura, as redes neurais artificiais têm sido amplamente aplicadas em diversas áreas. Vários pesquisadores realizaram trabalhos utilizando RNAs com a finalidade de estimar a evapotranspiração em função de elementos climáticos, produzindo resultados confiáveis (KUMAR et al., 2002; SUDHEER; GOSAIN; RAMASASTRI, 2003; TRAJKOVIC; TODOROVIC; STANKOVIC, 2003; ZANETTI et al., 2007; KHOOB, 2008; LANDERAS; ORTIZ-BARREDO; LÓPEZ, 2008).

2.2. Redes Neurais Artificiais

As redes neurais artificiais (RNAs) são sistemas computacionais inspirados no funcionamento do cérebro, compostos por unidades de processamento chamadas neurônios artificiais, organizadas em camadas e interconectadas por pesos sinápticos ajustáveis. O processo de treinamento consiste em ajustar esses pesos para que a rede aprenda padrões nos dados, enquanto a aplicação da rede envolve a generalização para novos dados (HAYKIN, 2001; BRAGA; LUDERMIR; CARVALHO, 2000; KOVÁCS, 2002). Cada neurônio recebe entradas ponderadas, soma-as junto a um *bias* e aplica uma função de ativação (como sigmoide, tangente hiperbólica ou linear) para gerar sua saída (VALENÇA, 2010).

Redes neurais recorrentes (RNN) são uma classe de RNAs projetadas para lidar com dados sequenciais, possuindo memória temporal que permite acumular informações de passos anteriores com ajuda de memórias ou estados, tornando-as adequadas para séries temporais (HAYKIN, 2001).

A Long Short Term Memory (LSTM) é uma variante especial de RNN, capaz de aprender dependências de longo prazo. As redes LSTM possuem as mesmas propriedades das redes RNN convencionais, entretanto possuem a capacidade de armazenar informações por longos períodos ao processar uma sequência temporal. Essa capacidade de operar com intervalos desconhecidos dá uma grande vantagem à LSTM em comparação as outras redes neurais recorrentes e outros métodos de aprendizado de sequências.

Diferentemente das RNNs padrão, cada módulo repetitivo de uma LSTM possui múltiplas camadas e estruturas chamadas *cells*, que armazenam informações relevantes e descartam dados irrelevantes por meio de mecanismos denominados *gates*.

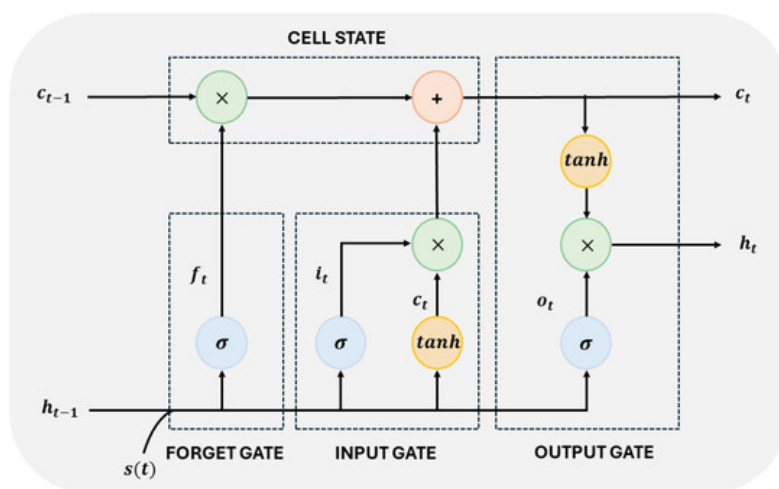


Figura 1. Esquema básico de uma LSTM.

Fonte: adaptado de (PEREIRA, 2017).

Existem três gates principais: o gate de entrada, que decide quais informações serão armazenadas; o gate de esquecimento, que define quais dados serão descartados; e o gate de saída, que determina a informação transmitida como saída do módulo. Essa arquitetura permite que as LSTM capturem padrões temporais complexos e realizem previsões mais precisas em séries temporais.

3. Trabalhos Relacionados

Na Tabela 1 é apresentada uma comparação entre os trabalhos relacionados a pesquisa. Observa-se que todos os trabalhos são semelhantes na questão do uso de redes neurais artificiais, e diferenciam-se nos algoritmos e informações meteorológicas utilizadas.

O trabalho de ZANETTI et al. (2007) objetivou estimar a evapotranspiração de referência por meio das redes neurais em função das temperaturas máximas e mínimas do ar, no município de Campos dos Goytacazes-RJ e Viçosa-MG. Embora tenha apresentado resultados satisfatórios localmente, sua aplicabilidade é limitada a outros locais devido à baixa capacidade de generalização, representando uma limitação importante na adoção do modelo em diferentes regiões.

Sampaio (2022) buscou estimar a evapotranspiração de referência por meio das redes neurais em função dos dados climáticos obtidos em uma estação da Inmet, localizada

Tabela 1. Comparação dos Trabalhos Relacionados.

Fonte: Elaborado pelo autor

Trabalho	Método	Variáveis	MAE	MSE	RMSE	R ²	c
(ZANETTI et al., 2007)	MLP	Temperaturas, radiação extra-terrestre e horas de luz solar no dia	-	0,356	-	0,8383	0,875
(SAMPAIO, 2022)	LSTM, BiLSTM, VAR+LSTM	Temperaturas, insolação, umidade relativa, velocidade do vento	0,293	-	0,387	-	-
(SANTOS; SILVA, 2020)	MLP	Temperaturas, umidade, velocidade do vento, radiação solar	0,081	0,114	0,106	0,9946	-

no município de Salvador, estado da Bahia. De acordo com os resultados obtidos, o uso de uma arquitetura BiLSTM gerou um resultado satisfatório para predição da evapotranspiração de referência, pois apresentou métricas com baixa taxa de erro médio absoluto e baixo erro médio quadrático, além de um viés muito próximo de zero, que significa que o modelo possui bom desempenho para dados desconhecidos e uma alta capacidade de generalização na sua aplicação. No entanto, a complexidade do modelo, aliada à necessidade de múltiplas variáveis meteorológicas, pode restringir a implementação prática em estações meteorológicas com dados limitados.

Santos e Silva (2020) aplicou redes neurais do tipo Perceptrons de Múltiplas Camadas (MLP) para estimar a evapotranspiração de referência (ET_o) diária em Teresópolis/RJ. Os dados meteorológicos utilizados abrangem temperaturas, umidade relativa do ar, velocidade do vento e radiação solar global, coletados entre 2010 e 2015. O modelo apresentou alta precisão (97,42%) ao ser comparado ao método padrão de Penman-Monteith, demonstrando a eficácia das redes neurais MLP na predição da ET_o, destacando seu potencial para complementar métodos tradicionais em cenários com dados meteorológicos limitados, apesar disso, os dados utilizados abrangem um período relativamente antigo, o que pode reduzir a relevância direta para condições climáticas atuais.

Referências mais antigas, como (ZANETTI et al., 2007), continuam sendo relevantes por fornecerem fundamentos metodológicos e históricos do uso de RNAs na estimativa de ET_o, servindo como base para comparação de abordagens e evolução de técnicas.

Em comparação com os trabalhos anteriores, a presente investigação propõe um modelo mais simples, utilizando apenas dados de temperatura e umidade como entrada, obtidos pela estação meteorológica de Ibirubá-RS, e a estimativa de evapotranspiração como saída, adotando o método Penman-Monteith como referência. Esta abordagem visa reduzir a dependência de múltiplas variáveis e facilitar a aplicação em contextos práticos, mantendo a precisão na previsão da ET_o.

Para validação, os resultados obtidos pela rede neural foram comparados com as estimativas de ET_o calculadas pelo aplicativo Sisdagro Evapotranspiração, que utiliza o método padrão PM.

4. Metodologia

A metodologia utilizada para o desenvolvimento deste trabalho foi definida com base em trabalhos correlatos e literatura científica pertinente.

Primeiramente foram definidas as variáveis que são importantes no cálculo da evapotranspiração e que seriam usadas para o treinamento da RNA neste trabalho, com o objetivo de reduzir o número de variáveis e tornar o cálculo mais acessível, foi optado por utilizar somente dados de temperatura e umidade, que após a radiação solar são os parâmetros que mais influenciam a ETo nas condições climáticas da região de estudo (ALLEN et al., 1998).

Os dados climáticos foram obtidos para o período de janeiro de 2013 até dezembro de 2023, oriundos das bases de dados INMET referentes a estação meteorológica de Ibirubá-RS, abrangendo medições horárias de temperatura, umidade e velocidade do vento, totalizando 96.408 registros correspondentes a 4.017 dias. Já a evapotranspiração de referência utilizada como verdade foi obtida no balanço hídrico sequencial do SISDAGRO, sistema desenvolvido pelo Inmet com o objetivo de apoiar usuários do setor agrícola em suas tomadas de decisão, auxiliando no planejamento e manejo agropecuário, cujo procedimento segue a metodologia parametrizada pela FAO (ALLEN et al., 1998). Após a coleta foram armazenados em planilhas do Excel, que serviram como ferramenta de armazenamento primário e posteriormente passou a ser utilizada a biblioteca Pandas do Python para análise e manipulação da base.

4.1. Pré-processamento dos dados

O pré-processamento envolveu uma análise e ajustes que foram necessários nos dados para dar sequência ao trabalho. Com os dados organizados, foram identificados valores ausentes na base de dados, ilustrados na tabela 2, sendo 3822 faltantes na coluna da temperatura e 6432 na umidade, representando 4% e 6,6% respectivamente.

Tabela 2. Apresentação dos dados faltantes.

Fonte: Elaborado pelo Autor

Variável	Quantidade faltante	Porcentagem representada
Temperatura	3822	4%
Umidade	6342	6.6%

Além da identificação de valores discrepantes da faixa esperada (outliers) na ETo registrada, utilizando-se o método Tukey, que consiste em definir um limite inferior e superior a partir da distância interquartil dos dados, sendo considerado outlier se for maior que o limite superior ou menor que o limite inferior, os quais foram substituídos por valores nulos (PEREIRA, 2022). Para evitar o comprometimento do desempenho da rede e a falta de registros históricos, os ausentes e outliers removidos da base foram preenchidos utilizando o método da Interpolação Linear, que utiliza valores do dia anterior e do dia seguinte ao dado faltante para realizar a imputação (YAGUCHI et al., 2016).

Após a imputação foram calculadas as temperaturas máximas e mínimas de cada dia, e as médias diárias para temperatura e umidade. Para o cálculo da média foram utilizadas fórmulas que são adotadas pelo próprio INMET, seguindo as normativas apresentadas no documento do Atlas Climático do Rio Grande do Sul (MATZENAUER et al., 2021):

Equação para temperatura média:

$$T = \frac{t_9 + 2.(t_{21}) + t_{max} + t_{min}}{5} \quad (2)$$

onde: T_9 é a temperatura do ar às 9 horas (°C); T_{21} é a temperatura do ar às 21 horas (°C); T_{max} é a temperatura máxima do ar (°C); e T_{min} é a temperatura mínima do ar (°C);

Equação para umidade média:

$$U = \frac{U_9 + U_{15} + 2.(U_{21})}{4} \quad (3)$$

onde: U_9 é a umidade do ar às 9 horas; U_{15} é a umidade do ar às 15 horas; e U_{21} é a umidade do ar às 21 horas;

Posteriormente, com as médias diárias já calculadas, a base de dados foi agrupada com a evapotranspiração de referência diária utilizada como variável alvo a ser estimada pela RNA. Em seguida foi realizada a normalização dos dados aplicando a técnica Min-MaxScaler, uma técnica aplicada na etapa de preparação dos dados, com o objetivo de padronizar a escala dos dados em um intervalo comum, para evitar que variáveis com escalas diferentes tenham uma influência desproporcional no modelo e para garantir que os dados estejam adequadamente escalonados para o treinamento da rede (SAMPALHO, 2022).

4.2. Construção do Modelo RNA

Baseando-se nos trabalhos relacionados apresentados na seção 3, foram testadas diferentes configurações de redes neurais com o objetivo de estimar a evapotranspiração para o município de Ibirubá-RS. Após testes iniciais, optou-se por concentrar a análise no modelo LSTM devido ao seu desempenho superior e ao potencial de melhores resultados para previsão de séries temporais. O estudo então compara o desempenho de redes neurais do tipo Long Short-Term Memory (LSTM) em relação ao método padrão Penman-Monteith (PM).

A rede LSTM foi implementada com diversas combinações de hiperparâmetros, a fim de identificar a configuração com melhor desempenho. Embora não tenham sido observadas variações significativas entre os resultados, após algumas iterações, a configuração que apresentou melhor desempenho e foi adotada como padrão neste trabalho consistiu em um modelo com uma única camada LSTM contendo 50 unidades, seguida de uma camada densa de saída. A taxa de aprendizagem utilizada foi de 0,001, com uma janela de entrada de 30 dias (look-back). A previsão da evapotranspiração de referência (ET_o) foi realizada com um horizonte de um dia à frente (*one-step-ahead forecasting*), abordagem que permite antecipar as necessidades hídricas da cultura e planejar adequadamente a irrigação do dia seguinte, utilizando os dados climáticos disponíveis até o dia anterior. O conjunto de dados foi dividido em 80% para treinamento e 20% para teste.

Foram considerados quatro cenários distintos na construção dos modelos LSTM, a 2 exibe de forma visual os diferentes cenários utilizados, onde cada etapa adiciona novas

variáveis à base original, permitindo avaliar o impacto incremental sobre o desempenho preditivo.




Figura 2. Fluxograma dos cenários de modelagem LSTM.

Após o treinamento da rede, foram gerados gráficos comparando os valores medidos e previstos (em mm/dia), permitindo uma avaliação visual da capacidade de generalização do modelo. O desempenho também foi avaliado quantitativamente utilizando as métricas de Raiz Quadrática Média do Erro (RMSE) e Erro Absoluto Médio (MAE), que quantificam as diferenças entre os valores preditos e reais (SAMPALHO, 2022). Além disso, foi utilizado o índice de confiança ou desempenho c (produto dos coeficientes de correlação r e de concordância d de Willmott) (CAMARGO; SENTELHAS, 1997), interpretado conforme apresentado na Tabela 3:

Tabela 3. Interpretação do índice c

Classificação	Intervalo de c
Ótimo	$> 0,85$
Muito bom	0,76 a 0,85
Bom	0,66 a 0,75
Mediano	0,61 a 0,65
Sofrível	0,51 a 0,60
Mau	0,41 a 0,50
Péssimo	$\leq 0,40$

5. Resultados e Discussão

Neste estudo, optou-se pelo uso de redes do tipo LSTM devido à sua capacidade de capturar dependências temporais de longo prazo em séries temporais, característica essencial para estimar a ETo, que apresenta variações sazonais e picos climáticos. Diferentemente de arquiteturas mais simples, a LSTM consegue manter informações de eventos passados relevantes, permitindo melhor previsão em séries com padrões não lineares e variabilidade diária.

A Figura 3 apresenta a série temporal do erro (ETo real - previsto) ao longo dos dias. Os erros oscilam em torno da linha zero (vermelha), sem tendência clara de aumento ou diminuição sistemática, o que sugere ausência de viés temporal acumulado e indica que os erros são predominantemente aleatórios. As flutuações, com amplitudes variando entre -4 e +4 mm/dia, apontam para variabilidade residual, possivelmente associada a eventos climáticos pontuais não modelados, como picos de temperatura ou umidade.

A Figura 4 ilustra distribuição temporal dos erros, valores de ETo reais - previstos pela rede LSTM. Os pontos azuis representam as observações individuais, com a linha vermelha indicando a linha de regressão perfeita ($y = x$). Observa-se uma correlação forte entre os valores reais e previstos, com a maioria dos pontos concentrados ao redor da

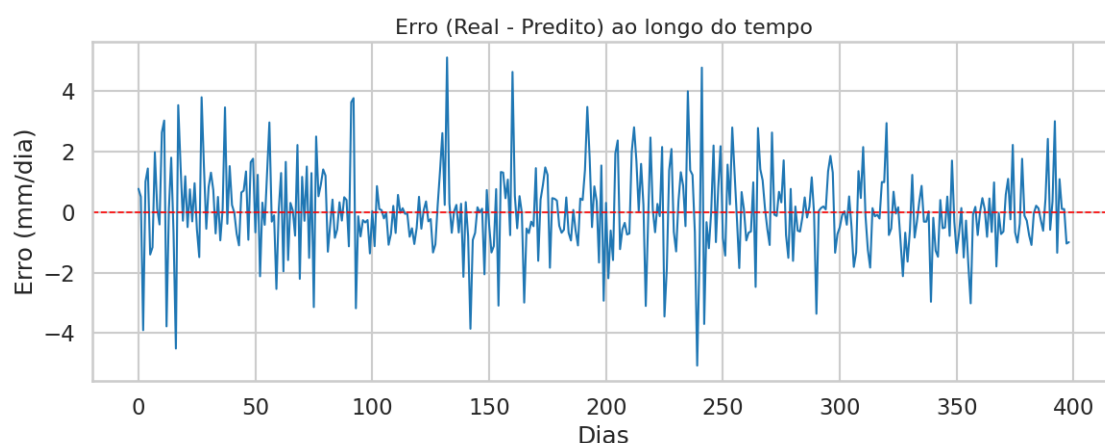


Figura 3. Diferença entre ETo real e previsto.

Fonte: autor.

linha, sugerindo um bom ajuste geral do modelo. No entanto, há picos pontuais, possivelmente devido a períodos de alta variabilidade climática, reforçando que o modelo tende a apresentar maior incerteza em condições extremas.

Tabela 4. Desempenho médio dos modelos LSTM com diferentes conjuntos de variáveis (média de 3 execuções).

Configuração do Modelo	MAE (mm/dia)	RMSE (mm/dia)	Índice c
Temperatura + Umidade (original)	1,4318	1,0773	0,7813
Original + Velocidade do vento	1,4303	1,0794	0,7814
Original + Mês codificado	1,4184	1,0547	0,7857
Completo (Original + Vento + Mês)	1,4141	1,0594	0,7871
Trabalho de (SAMPAIO, 2022) usando BiLSTM	0,293	0,387	-

A Tabela 4 resume as métricas de desempenho dos modelos LSTM testados, utilizando diferentes conjuntos de variáveis. Nota-se que a inclusão de velocidade do vento e codificação do mês trouxe melhorias modestas nos valores de MAE, RMSE e índice c , sugerindo que a LSTM é relativamente robusta mesmo com entradas reduzidas. Dessa maneira, consideramos o modelo mais simples como referência, levando em conta o custo x benefício do modelo, onde elevar o custo computacional não trouxe melhorias significativas.

Embora os resultados indiquem que a LSTM consegue estimar ETo com bom nível de concordância ($c = 0,7871$ classificado como "muito bom"), erros médios de aproximadamente 1,4 mm/dia podem gerar impactos relevantes no manejo de irrigação, com subestimação da evapotranspiração podendo levar à deficiência hídrica, enquanto superestimação pode causar desperdício de água. Para contextualizar, em uma área de 100 hectares, um erro de 1,4 mm/dia poderia resultar em uma variação diária de até 1.400.000 litros de água.

Comparando com trabalhos correlatos, observa-se que Sampaio (2022) obteve menor MAE e RMSE utilizando BiLSTM com múltiplas variáveis climáticas, confirmando

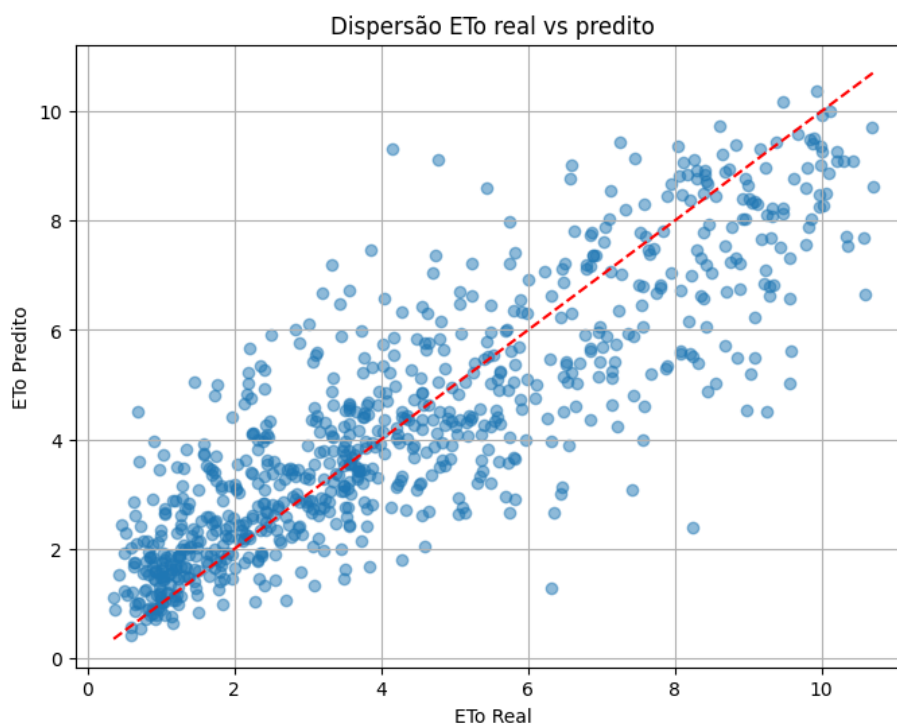


Figura 4. Gráfico de dispersão da ETo medida em comparação a prevista pela rede LSTM.

Fonte: autor.

que a disponibilidade de entradas relevantes aumenta a acurácia do modelo. Essa diferença pode ser atribuída ao uso de um conjunto de dados mais abrangente (incluindo radiação solar e pressão atmosférica) e à arquitetura bidirecional da BiLSTM, que captura contextos futuros nas sequências temporais. Em contraste, nosso modelo priorizou dados mínimos, resultando em erros maiores, mas com maior aplicabilidade em regiões com estações meteorológicas limitadas. Já estudos mais antigos, como ZANETTI et al. (2007), demonstraram limitações na generalização de MLPs, reforçando a vantagem da LSTM para séries temporais com maior variabilidade.

Apesar de a BiLSTM de Sampaio (2022) apresentar menor MAE e RMSE devido ao uso de múltiplas variáveis climáticas e arquitetura bidirecional, o nosso modelo demonstra que é possível obter estimativas razoavelmente confiáveis com um conjunto reduzido de dados. Essa abordagem mais simples apresenta vantagens práticas, especialmente em regiões onde nem todas as variáveis climáticas estão disponíveis, permitindo uma implementação mais acessível e de baixo custo computacional. Portanto, embora haja perda de precisão em relação a modelos mais complexos, o modelo proposto mantém boa aplicabilidade, evidenciando o trade-off entre simplicidade, custo e desempenho. Dessa forma, nosso modelo prioriza a simplicidade e acessibilidade, enquanto modelos mais complexos obtêm maior precisão.

Os resultados ainda apresentam margem de melhoria para aplicações operacionais em sistemas de irrigação de precisão, fato esse evidenciado quando comparado com o trabalho relacionado exibido na Tabela 4, indicando espaço para melhorias significativas. Isso pode ser atribuído ao uso de um conjunto mínimo de variáveis, que não fornecem

informações suficientes sobre os fatores que afetam a evapotranspiração de maneira mais abrangente, sugerindo fortemente que a adição de variáveis como a radiação solar poderia aumentar a precisão das estimativas, dada sua influência sobre a evapotranspiração. Variações modestas na estimativa da ETo podem levar a diferenças significativas no consumo de água, destacando a importância crítica de modelos mais precisos para o manejo sustentável da água.

Por fim, a análise dos erros demonstra que, apesar de alguns desvios pontuais, o modelo apresenta comportamento estável e previsível, o que o torna promissor como ferramenta de apoio à decisão no manejo de irrigação. Para uso prático, sua aplicação é mais indicada em janelas agregadas (semanais ou quinzenais), nas quais os erros diários tendem a se compensar.

A utilização de RNAs pode apresentar um desempenho melhor quando variáveis adicionais ou maior quantidade de dados são introduzidas. Além disso, o índice de desempenho proposto por Camargo e Sentelhas (1997) demonstrou-se eficaz para quantificar a precisão dos modelos, confirmando que, apesar de algumas vantagens, o uso de RNAs com dados limitados apresenta restrições quanto ao desempenho. Para melhorar os resultados, futuras implementações, além de explorar arquiteturas mais avançadas de redes neurais, poderiam considerar a adição de variáveis climáticas que comprovadamente tem maior influência sobre a ETo, como a radiação solar. Entretanto, o presente estudo teve como objetivo alcançar estimativas viáveis utilizando dados de fácil acesso, priorizando a simplicidade e aplicabilidade prática.

Em resumo, a LSTM mostrou-se adequada para estimar a ETo em cenários com dados climáticos limitados, apresentando resultados consistentes e interpretáveis, ainda que sujeitos a melhorias mediante expansão do conjunto de dados e refinamentos metodológicos.

6. Conclusão

Este trabalho evidenciou que as Redes Neurais Artificiais, especialmente o modelo LSTM, foi capaz de estimar a ETo com desempenho moderado, utilizando apenas temperatura e umidade, com melhora sensível ao incluir o mês no treinamento. Contudo, os índices obtidos ainda se mostraram insuficientes para aplicações que exigem alta precisão no manejo da irrigação.

Embora os resultados se aproximem dos valores desejados, mesmo pequenas imprecisões nas estimativas podem comprometer a eficiência hídrica do sistema de irrigação, pouca diferença no cálculo da ETo causaria grande impacto no consumo, visto que um excedente de apenas 1 milímetro por hectare pode representar um consumo adicional de 10 mil litros de água por hectare irrigado. Apesar das limitações, os resultados destacam o potencial das redes neurais artificiais como uma abordagem promissora e uma ferramenta prática para auxiliar no manejo de irrigação, especialmente em regiões com dados meteorológicos limitados. A metodologia adotada, baseada em dados acessíveis, demonstrou a viabilidade da técnica e pode ser expandida, ficando como sugestão de trabalhos futuros o uso de dados de pequenas estações comerciais e a implementação real em dispositivos com baixa capacidade de processamento ou voltados para IoT, possibilitando um manejo mais eficiente e sustentável dos recursos hídricos na agricultura.

Referências

- ALLEN, R. G. A penman for all seasons. *Journal of Irrigation and Drainage Engineering*, American Society of Civil Engineers, v. 112, n. 4, p. 348–368, 1986.
- ALLEN, R. G. et al. *Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56*. [S.l.]: Rome: Food and Agriculture Organization of the United Nations, 1998. v. 300.
- BRAGA, A. d. P.; LUDERMIR, T. B.; CARVALHO, A. C. P. d. L. F. *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro: LTC, 2000. 262 p.
- CAMARGO, A. d.; SENTELHAS, P. C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no estado de são paulo, brasil. *Revista Brasileira de agrometeorologia*, Santa Maria, v. 5, n. 1, p. 89–97, 1997.
- DOORENBOS, J.; PRUITT, W. Crop water requirements. fao irrigation and drainage paper 24. *Land and Water Development Division, FAO, Rome*, Food and Agriculture Organization of the United Nations (FAO), v. 144, n. 1, 1977.
- FENG, Y. et al. Evaluation of random forests and generalized regression neural networks for daily reference evapotranspiration modelling. *Agricultural Water Management*, Elsevier, v. 193, p. 163–173, 2017.
- HAYKIN, S. *Redes neurais: princípios e prática*. 2. ed. Porto Alegre, RS: Bookman Editora, 2001. ISBN 0-13-273350-1.
- JHA, K. et al. A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture*, Elsevier, v. 2, p. 1–12, 2019.
- KHOOB, A. R. Comparative study of hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. *Irrigation Science*, Springer, v. 26, n. 3, p. 253–259, 2008.
- KOVÁCS, Z. L. *Redes neurais artificiais: Fundamentos e Aplicações*. 3. ed. São Paulo: Livraria da Física, 2002. ISBN 85-88325-14-4.
- KRISHNA, P. Evapotranspiration and agriculture—a review. *Agricultural Reviews*, Agricultural Research Communication Centre, v. 40, n. 1, p. 1–11, 2019.
- KUMAR, M. et al. Estimating evapotranspiration using artificial neural network. *Journal of Irrigation and Drainage Engineering*, American Society of Civil Engineers, v. 128, n. 4, p. 224–233, 2002.
- LANDERAS, G.; ORTIZ-BARREDO, A.; LÓPEZ, J. J. Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the basque country (northern spain). *Agricultural Water Management*, Elsevier, n. 95, p. 553–565, 2008.
- MAROUELLI, W. A. et al. Manejo da água de irrigação. In: _____. *Irrigação e fertirrigação em fruteiras e hortaliças*. Brasília, DF: Embrapa Informação Tecnológica, 2011. p. 158–232.
- MATZENAUER, R. et al. *Atlas Climático do Rio Grande do Sul*. Porto Alegre, RS: Fundação Estadual de Pesquisa Agropecuária - FEPAGRO, 2021. Disponível em: <https://www.fepagro.rs.gov.br/atlas-climatico>.

- PAZ, V. P. d. S.; TEODORO, R. E. F.; MENDONÇA, F. C. Recursos hídricos, agricultura irrigada e meio ambiente. *Revista Brasileira de Engenharia Agrícola e Ambiental*, DEAg/UFPB, Campina Grande, PB, v. 4, n. 3, p. 465–473, 2000.
- PEREIRA, A. L. V. *Modelo baseado em aprendizado de máquina para classificar o conforto térmico de bezerras usando termografia por infravermelho*. 74 p. Dissertação (Dissertação de Mestrado) — Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, SP, 2022.
- PEREIRA, A. R.; NOVA, N. A. V.; SEDIYAMA, G. C. *Evapo(transpi)ração*. Piracicaba, SP: FEALQ, 1997. 183 p.
- PEREIRA, M. de M. *Aprendizado Profundo: Redes LSTM*. Tese (Trabalho de Conclusão de Curso) — Universidade Federal da Grande Dourados, Dourados, MS, Brasil, março 2017. Orientador: Prof. Ms Anderson Bessa da Costa.
- SAMPAIO, D. B. *Predição da Evapotranspiração de Referência Usando Rede LSTM Bidirecional e VAR+LSTM*. 120 p. Dissertação (Dissertação de Mestrado) — Instituto Federal do Espírito Santo, Serra, ES, 2022.
- SANTOS, D. da S.; SILVA, R. M. da. Aplicação de redes neurais mlp na predição da evapotranspiração de referência. *Brazilian Journal of Development*, Brazilian Journal of Development, v. 6, n. 5, p. 25293–25305, 2020. ISSN 2525-8761.
- SOARES, S. B. E. C. M. D. D. da Silva e A. A. *Manual de irrigação*. Viçosa, MG: Editora UFV, 2019.
- SUDHEER, K.; GOSAIN, A.; RAMASASTRI, K. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *Journal of irrigation and drainage engineering*, American Society of Civil Engineers, v. 129, n. 3, p. 214–218, 2003.
- TRAJKOVIC, S.; TODOROVIC, B.; STANKOVIC, M. Forecasting of reference evapotranspiration by artificial neural networks. *Journal of Irrigation and Drainage Engineering*, American Society of Civil Engineers, v. 129, n. 6, p. 454–457, 2003.
- TUCCI, C. E. M.; HESPANHOL, I.; NETTO, O. de M. C. *Gestão da água no Brasil*. Brasília, DF: Unesco, 2001. 156 p. ISBN 85-87853-26-0.
- TUNDISI, J. G.; MATSUMURA-TUNDISI, T. *A água*. São Carlos, SP: Scienza, 2020. 130 p. ISBN 978-65-5668-005-7.
- VALENÇA, M. Fundamentos das redes neurais: exemplos em java. *Livro Rápido*, 2010.
- XUE, J. et al. Evaluation of remote sensing-based evapotranspiration models against surface renewal in almonds, tomatoes and maize. *Agricultural Water Management*, Elsevier, v. 238, p. 106228, 2020.
- YAGUCHI, S. M. et al. Preenchimento de falhas dos dados diários de temperatura máxima e mínima do ar. *Ciência e Natura*, Universidad Federal de Santa Maria, v. 38, n. 3, p. 1419, 2016.
- ZANETTI, S. S. et al. Estimating evapotranspiration using artificial neural network and minimum climatological data. *Journal of Irrigation and Drainage Engineering*, American Society of Civil Engineers, v. 33, n. 2, p. 83–89, 2007.