

The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering

مقایسه عملکرد شبکه عصبی مصنوعی (ANN) و شبکه عصبی بازگشتی (LSTM) در مدل سازی تبخیر-تعرق پتانسیل در حوضه کرخه

چکیده

تبخیر-تعرق پتانسیل یکی از مهم ترین مؤلفه های چرخه هیدرولوژیک و عامل کلیدی در مدیریت منابع آب، برنامه ریزی آبیاری، طراحی سامانه های آبیاری و بهره برداری بهینه از مخازن سدها به شمار می رود. تخمین دقیق آن به ویژه در مناطق خشک و نیمه خشک مانند ایران، اهمیت ویژه ای دارد. در این پژوهش از تبخیر-تعرق پتانسیل و دمای متوسط با تاخیر زمانی برای تخمین تبخیر و تعرق پتانسیل در حوضه آبریز کرخه استفاده شده است. بدین منظور از داده های ماهانه این دو متغیر در بازه زمانی ۲۰۲۴-۱۹۹۵ که از پایگاه داده Terra Climate استخراج شده اند، استفاده شد و همبستگی تبخیر-تعرق پتانسیل هر ماه با مقادیر یک تا پنج ماه قبل و همچنین با دمای متوسط همان ماه و یک تا پنج ماه قبل محاسبه گردید. برای مدل سازی این فرآیند نیز از دو رویکرد هوش مصنوعی شامل شبکه عصبی مصنوعی^۱ (ANN) و مدل حافظه بلندمدت کوتاه مدت^۲ (LSTM) به کار گرفته شد. نتایج نشان داد که بیشترین همبستگی مربوط به سه متغیر تبخیر-تعرق پتانسیل ماه قبل، دمای متوسط همان ماه، دمای متوسط ماه قبل می باشد. همچنین، نتایج نشان داد که هر دو مدل ANN و LSTM توانایی مناسبی در برآورد تبخیر-تعرق پتانسیل دارند، اما مدل LSTM با مقادیر بالاتر ضریب همبستگی ($R \approx 0.996$)، شاخص نش-ساتکلیف ($NSE \approx 0.989$) و خطای کمتر در مرحله صحت سنجی نسبت به ANN، عملکرد پایدارتر و تعمیم پذیری بهتری ارائه داد. بنابراین استفاده از مدل LSTM در مدل سازی تبخیر-تعرق پتانسیل در حوضه کرخه توصیه می شود.

واژه های کلیدی: تبخیر تعرق پتانسیل، شبکه عصبی مصنوعی، یادگیری ماشین، LSTM، Terra Climate

۱- مقدمه

تبخیر و تعرق (ET) یک جزء کلیدی در چرخه هیدرولوژیک و یک عامل اساسی در آبیاری، تخمین عملکرد محصول، جنگل داری و مدیریت محیط زیست در نظر گرفته می شود [۱، ۲، ۳]. تخمین دقیق تبخیر و تعرق برای درک فرآیندهای هیدرولوژیک و اکولوژیک [۴]، تشخیص و کاهش خشکسالی کشاورزی و مدیریت

^۱ Artificial Neural Network
^۲ Long Short-Term Memory

The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering

منابع آب [۵،۶] بسیار مهم است. تخمین تبخیر و تعرق همچنین برای مطالعه رویدادهای اقلیمی (سیلاب و خشکسالی) و درک روابط بین سیستم‌های جو، هیدروسفر و زیست کره ضروری است [۷].

در دهه‌های اخیر، رویکردهای متنوعی برای تخمین تبخیر و تعرق پیشنهاد شده است و می‌توان آنها را به دو دسته کلی روش‌های نقطه‌ای (شامل مستقیم و غیرمستقیم) و منطقه‌ای تقسیم کرد. روش‌های نقطه‌ای مستقیم شامل لایسیمتر، تغییرات رطوبت خاک، نسبت بوون، سینتیلومتری، کوواریانس گردابی، جریان شیره گیاهی و غیره می‌شود [۸]. لایسیمتر که برای اندازه‌گیری مستقیم تبخیر و تعرق بدون هیچ فرضی استفاده می‌شود [۹]، می‌تواند دقیق‌ترین تخمین تبخیر و تعرق را ارائه دهد و به عنوان معیاری برای کالیبراسیون سایر روش‌ها مورد استفاده قرار گیرد [۱۰،۱۱]؛ با این حال، این روش گران، دشوار و با تخریب محیط زیست مرتبط است [۱۲،۱۳،۱۴]. در نتیجه، برخی روش‌های غیرمستقیم، مانند معادلات تجربی و شبه‌آزمایشی، توسعه یافته‌اند که در آن‌ها ET با در نظر گرفتن مؤثر تخمین زده می‌شود [۱۵].

در طول سال‌ها، استفاده از مدل‌های یادگیری ماشین برای تخمین ET افزایش یافته است. مدل‌های یادگیری ماشین نشان داده‌اند که رقابتی هستند یا عملکرد بهتری نسبت به روش‌های فیزیکی و تجربی دارند. تا به امروز، شبکه‌های عصبی مصنوعی با معماری‌های مختلف توسعه یافته و در رشته‌های مختلف به کار گرفته شده‌اند. فرآیند یادگیری در شبکه‌های عصبی مصنوعی با معرفی برخی وزن‌های تصادفی و سپس بهینه‌سازی وزن‌ها برای به حداقل رساندن خطای پیش‌بینی انجام می‌شود. شبکه‌های عصبی مصنوعی می‌توانند از داده‌ها یاد بگیرند و خود را با آنها وفق دهند، که آنها را برای پیش‌بینی قدرتمند می‌کند. آنها می‌توانند به طور مؤثر روابط غیرخطی پیچیده بین متغیرها را مدل‌سازی کنند [۱۶].

اخیراً مطالعات مختلفی در مورد کاربرد شبکه‌های عصبی مصنوعی (ANNs) در حوزه مدل‌سازی تبخیر و تعرق مرجع منتشر شده است [۱۷،۱۸،۱۹،۲۰،۲۱،۲۲،۲۳،۲۴]. از این پژوهش‌ها می‌توان به ارزیابی روش‌های شبکه عصبی برای مدل‌سازی تبخیر-تعرق واقعی محصول در زمین‌های با و بدون پوشش مالت [۲۵] اشاره کرد. همچنین در تحقیقی [۲۶]، به مدل‌سازی تبخیر و تعرق ماهانه گیاه مرجع در ایستگاه مرزی هومز سوریه پرداختند. آنها با به کارگیری داده‌های هواشناسی اندازه‌گیری شده و استفاده از شبکه عصبی مصنوعی، تبخیر و تعرق مرجع ماهانه را برآورد کردند، سپس تبخیر و تعرق مرجع ماهانه به وسیله فرمول فائو پنمن مانیت، به عنوان خروجی مدل فراخوانی شدند. یافته‌ها نشان داد شبکه عصبی مصنوعی در تخمین تبخیر و تعرق مرجع به صورت ماهانه، کارایی بالایی دارد. در پژوهش دیگری [۲۷] به تحلیل روش‌های برآورد تبخیر و تعرق پرداختند. آنها از مدل‌های شبکه عصبی غیرخطی و همچنین تکنیک‌های استنتاج فازی که با سیستم عصبی سازگار هستند استفاده کردند و در پایان نتیجه گرفتند که هر دو رویکرد، نسبت به فرمول‌های تجربی پیشین، کارایی به مراتب بالاتری دارند. در مطالعه دیگری نیز نشان داده شده است که برای تخمین ET، مدل ANN در شبه جزیره کره عملکرد بهتری نسبت به مدل‌های تجربی دارد [۲۸].



The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering

یادگیری عمیق، دسته خاصی از الگوریتم‌های یادگیری ماشین است که از چندین لایه برای استخراج تدریجی ویژگی‌های سطح بالاتر از داده‌های ورودی استفاده می‌کند [۲۹]. یادگیری عمیق مبتنی بر معماری‌های خاص شبکه‌های عصبی مصنوعی است. در حال حاضر، هنوز کاربردهای بسیار کمی از الگوریتم‌های یادگیری عمیق برای پیش‌بینی مقادیر تبخیر و تعرق وجود دارد. چن و همکاران [۳۰] از سه مدل یادگیری عمیق، یعنی شبکه عصبی عمیق^۳ (DNN)، شبکه عصبی پیچشی زمانی^۴ (TCN) و شبکه عصبی حافظه کوتاه مدت بلند (LSTM) برای تخمین تبخیر و تعرق مرجع روزانه در دشت شمال شرقی چین استفاده کردند و کارایی بالای دو مدل TCN و LSTM را نشان دادند.

با توجه به اثرپذیری تبخیر و تعرق مرجع از متغیرهای متنوع اقلیمی نظیر دما و فشار هوا، سرعت باد، ساعات آفتابی، تشعشع و از آنجایی که این متغیرها در همه جا به‌طور مداوم اندازه‌گیری نمی‌شوند، در پژوهش حاضر، برای تخمین تبخیر و تعرق مرجع ماهانه از وابستگی زمانی داده‌های این متغیر و نیز دمای متوسط ماهانه استفاده شده است و حوضه آبریز کرخه که تأمین کننده آب دشت خوزستان است به عنوان منطقه مطالعاتی انتخاب شده است. دو مدل شبکه عصبی مصنوعی (ANN) و شبکه عصبی حافظه بلندمدت-کوتاه مدت (LSTM) برای مدل‌سازی این فرآیند بکار گرفته شده‌اند. با توجه به رابطه مستقیم دما و تبخیر و تعرق مرجع، مدل ANN به عنوان یک مدل داده‌محور مبتنی بر روابط خطی در نوروها و مدل LSTM به عنوان یکی از انواع شبکه‌های عصبی بازگشتی با قابلیت یادگیری وابستگی‌های زمانی بلندمدت انتخاب گردید و کارایی این دو مدل مورد ارزیابی قرار گرفت. همچنین، با توجه به کمبود داده‌های مشاهداتی تبخیر و تعرق پتانسیل، در این پژوهش داده‌های تبخیر-تعرق پتانسیل و دمای متوسط از پایگاه داده Terra Climate استخراج شده است.


۲- مواد و روش‌ها

محدوده مطالعاتی

حوضه کرخه در غرب کشور در مناطق میانی و جنوبی زاگرس قرار دارد و دارای مساحتی بالغ بر ۵۰۷۶۸ کیلومتر مربع است که حدود ۳۳۶۷۴ کیلومتر مربع آن در مناطق کوهستانی و مرتفع و حدود ۱۷۰۹۴ کیلومتر مربع آن را دشت‌ها و کوهپایه‌ها تشکیل می‌دهند. از نظر مختصات جغرافیایی بین ۴۶ درجه و ۶ دقیقه و ۴۹ درجه و ۱۰ دقیقه طول شرقی و ۳۳ درجه و ۱۵ دقیقه و ۳۴ درجه و ۳۳ دقیقه عرض شمالی قرار گرفته است [۳۱]. این حوضه از شمال به حوضه رودخانه‌های سیروان، سفیدرود و قره چای، از غرب به حوضه رودخانه‌های مرزی ایران و عراق، از شرق به حوضه رودخانه دز و از جنوب به قسمتی از مرز غربی کشور محدود می‌گردد [۳۲] این حوضه در بردارنده استان‌های لرستان و کرمانشاه و بخش‌هایی از استان‌های کردستان، همدان، ایلام و خوزستان است که در شکل ۱ موقعیت آن بر روی استان‌ها نشان داده شده است.

^۳ Deep Neural Networks
^۴ Temporal Convolutional Network

The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering



شکل ۱- موقعیت جغرافیایی حوضه آبریز کرخه در ایران، الف) نقشه ایران ب) حوضه کرخه [۳۳]

داده‌های مورد استفاده

در پژوهش حاضر داده‌های دمای متوسط و تبخیر تعرق پتانسیل (PET) برای دوره زمانی ۱۹۹۵ تا ۲۰۲۴ از پایگاه داده Terra Climate استخراج شده‌اند. داده‌های Terra Climate با دقت مکانی و زمانی مناسب برای تحلیل‌های مقیاسی اقلیمی ارائه می‌شود و ترکیبی از چندین منبع داده‌ای معتبر به همراه اصلاحات همگن‌سازی و کراس ولیدیشن‌های فضایی-زمانی است. این مجموعه داده به صورت سالانه-ماهانه در دسترس است و به طور مستقیم برای ارزیابی روندهای گرمایشی-فصلی، و تغییرات میان مدت استفاده می‌شود. با توجه به هدف مطالعه و نیاز به ارزیابی مدل در مقابل داده‌های مستقل، این مجموعه داده به عنوان منبع ورودی اولیه تعیین شد.

روش تحقیق

در این پژوهش به منظور بررسی ساختار وابستگی زمانی، همبستگی تبخیر-تعرق پتانسیل هر ماه با مقادیر یک تا پنج ماه قبل و همچنین با دمای متوسط همان ماه و یک تا پنج ماه قبل محاسبه گردید و متغیرهای



The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering

دارای همبستگی معنادار در سطح اعتماد ۹۵٪ به عنوان متغیرهای ورودی مدل سازی انتخاب شدند. نتایج نشان داد که بیشترین همبستگی مربوط به سه متغیر تبخیر-تغرق ماه قبل، دمای متوسط همان ماه، دمای متوسط ماه قبل می باشد. بنابراین، این سه متغیر به عنوان ورودی مدل های پیش بینی انتخاب شدند. همچنین برای مدل سازی، دو رویکرد هوش مصنوعی شامل شبکه عصبی مصنوعی (ANN) و مدل حافظه بلندمدت (LSTM) به کار گرفته شد. برای ارزیابی کارایی مدل ها، داده ها به دو زیرمجموعه تقسیم شدند: ۷۵٪ از کل داده ها به عنوان مجموعه آموزشی/کالیبراسیون در نظر گرفته شد تا مدل ها بتوانند پارامترهای خود را با داده های مربوط به کالیبره تنظیم کنند و فرآیند یادگیری را به خوبی انجام دهند. ۲۵٪ باقی مانده به عنوان مجموعه صحت سنجی استفاده شد تا عملکرد مدل را به طور مستقل ارزیابی شود.

شبکه عصبی مصنوعی

در این مقاله، یک شبکه عصبی چهار لایه با ساختار پرسپترون (MLP) استفاده شده است. در این نوع شبکه عصبی، تعداد نورون های لایه ورودی و خروجی به ترتیب برابر با تعداد متغیرهای پیش بینی کننده (m) پیش بینی شونده است، در حالی که تعداد نورون های دو لایه میانی قابل تغییر می باشد که مقدار بهینه آن باید محاسبه شود [۳۴]. توابع مورد استفاده در نورون های لایه میانی و خروجی به ترتیب از نوع تانژانت هایپربولیک و سیگموئیدی هستند که در معادله ۱ و ۲ ارائه شده است:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (1)$$

$$f(x) = \frac{1}{1 + e^{-ax}} \quad a > 0 \quad (2)$$

برای محاسبه توابع در هر نورون، وزن (w) و بایاس (b) برای ورودی های نورون ها به صورت $w_j x_j + b_j$ در نظر گرفته می شود.

(j = 1, 2, ..., m) که مقادیر بهینه آن باید از طریق واسنجی مدل تعیین شود.


برای تعیین معماری بهینه شبکه، تعداد نورون های هر یک از دو لایه پنهان به صورت آزمایشی در بازه ۳ تا ۸ نورون تغییر داده شد و مدل های مختلفی آموزش داده شدند. هدف از این آزمایش، بررسی تأثیر تعداد نورون ها بر دقت پیش بینی و یافتن بهترین ساختار شبکه بود.

شبکه عصبی حافظه کوتاه و بلند مدت

یکی از مدل های محبوب در شبکه های بازگشتی، مدل LSTM است. این نوع شبکه برای اولین بار در سال ۱۹۹۷ میلادی توسط هوخرایتر و اشمیدهور [۳۵] معرفی شد. طراحی شبکه های LSTM به منظور حل مشکلات ناشی از وابستگی بلندمدت داده ها انجام شد [۳۶]. این مدل نوع خاصی از شبکه عصبی بازگشتی بوده که بجای توابع ساده، از توابع پیچیده و ترکیبی به منظور تنظیم و تقویت حافظه کوتاه مدت استفاده می کند و قابلیت یادگیری وابستگی های بلندمدت را علاوه بر وابستگی های کوتاه مدت دارد. هدف این نوع شبکه، پردازش داده هایی است که نیاز است وابستگی های بلندمدت آنها در مدل در نظر گرفته شود. این نوع از شبکه عصبی می تواند در پیش بینی داده های سری زمانی استفاده شود. LSTM می تواند به صورت تک متغیره و چند

The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering

متغیره بر اساس تعداد سری زمانی ورودی تقسیم‌بندی شوند. در توسعه مدل، ابتدا مدل پیش‌بینی یک گام جلوتر در فرآیند توسعه مدل به دست می‌آید، سپس یک راهبرد بازگشتی در مدل‌های آموزش دیده اتخاذ می‌شود تا بتوان پیش‌بینی چندمرحله‌ای را به دست آورد. مطابق شکل ۲ شبکه LSTM نیز شبیه ساختار استاندارد شبکه‌های بازگشتی دارای زنجیره‌ای از سلول‌ها است، با این تفاوت که ساختار هر سلول بجای یک لایه دارای چهار لایه مرتبط و متعامل است [۳۷].



شکل ۲- ساختار شبکه‌های بازگشتی LSTM [۳۶]

شاخص‌های ارزیابی

برای ارزیابی و مقایسه کارایی مدل‌های بکار رفته در این تحقیق از سه شاخص ارزیابی نش-ساتکلیف (NSE)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی پیرسون (R) استفاده شد که به ترتیب در روابط ۳، ۴ و ۵ ارائه شده است [۳۸]:

$$NSE = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad (4)$$

$$R = \frac{\sum_{i=1}^n (P_i - \bar{P}) - (O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (P_i - \bar{P})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (5)$$

در روابط فوق، P_i و O_i به ترتیب تبخیر و تعرق پتانسیل ماهانه مشاهداتی و پیش‌بینی شده در زمان i ، $\bar{P}$ و $\bar{O}$ به ترتیب میانگین تبخیر و تعرق پتانسیل ماهانه مشاهداتی و پیش‌بینی شده و N تعداد داده‌ها می‌باشد. دامنه تغییرات شاخص نش-ساتکلیف از منفی بی‌نهایت تا یک می‌باشد. هرچه مقدار این شاخص به یک نزدیکتر باشد، خطای مدل کمتر است. شاخص RMSE از صفر تا بی‌نهایت تغییر می‌کند. هرچه مقدار این شاخص به صفر نزدیکتر باشد، نشان دهنده خطای کمتر و کارایی بهتر مدل می‌باشد. شاخص R در دامنه -1 تا 1 تغییر می‌کند. مقدار 1 و -1 به ترتیب نشان دهنده همبستگی کامل مستقیم و معکوس مقادیر مشاهداتی و پیش‌بینی شده می‌باشد. همچنین مقدار صفر این شاخص نشان می‌دهد که مقادیر مشاهداتی و



The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering

پیش‌بینی شده هیچگونه همبستگی خطی معنی‌داری ندارند. بنابراین هرچه مقدار این شاخص به یک نزدیکتر باشد، کارایی مدل بهتر است و تغییرات مقادیر مشاهداتی و تخمین زده شده همسو می‌باشد.

۵- نتایج و بحث

- نتایج مدل شبکه عصبی مصنوعی: همانطور که گفته شد برای تنظیم شبکه عصبی تعداد نورون‌های هر لایه میانی از ۳ تا ۸ تغییر داده و مدل برای هر یک از حالات، اجرا گرفته شده است و نتایج زیر حاصل شده است.

جدول ۱: نتایج شبکه عصبی مصنوعی

تعداد نورون‌ها	R_{cal}	R_{val}	$RMSE_{cal}$	$RMSE_{val}$	NSE_{cal}	NSE_{val}
(3,3)	0.995	0.990	8.009	10.938	0.990	0.980
(3,4)	0.994	0.991	8.984	10.672	0.987	0.981
(3,5)	0.996	0.992	7.540	9.981	0.991	0.983
(3,6)	0.995	0.992	7.753	9.834	0.990	0.983
(3,7)	0.996	0.993	7.138	9.449	0.992	0.985
(3,8)	0.995	0.991	7.820	10.338	0.990	0.982
(4,3)	0.996	0.992	7.633	9.841	0.991	0.984
(4,4)	0.994	0.993	8.578	9.176	0.988	0.986
(4,5)	0.995	0.992	8.055	9.404	0.990	0.985
(4,6)	0.995	0.992	7.723	9.968	0.990	0.983
(4,7)	0.995	0.993	8.150	9.133	0.989	0.986
(4,8)	0.996	0.992	7.578	9.974	0.991	0.983
(5,3)	0.996	0.990	7.596	10.913	0.991	0.980
(5,4)	0.996	0.991	7.597	10.096	0.991	0.982
(5,5)	0.996	0.992	7.508	9.966	0.991	0.983
(5,6)	0.995	0.993	8.137	9.343	0.989	0.985
(5,7)	0.996	0.990	7.656	10.704	0.991	0.980
(5,8)	0.995	0.992	8.024	10.360	0.990	0.982
(6,3)	0.996	0.992	7.657	9.962	0.991	0.983
(6,4)	0.995	0.991	7.908	10.208	0.990	0.982
(6,5)	0.995	0.992	8.077	9.581	0.990	0.984
(6,6)	0.995	0.992	7.706	9.802	0.990	0.984
(6,7)	0.995	0.992	7.870	9.781	0.990	0.983
(6,8)	0.996	0.989	7.354	11.370	0.991	0.978
(7,3)	0.995	0.992	7.818	9.585	0.990	0.984
(7,4)	0.995	0.992	7.764	9.457	0.990	0.985

The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering

(7,5)	0.995	0.991	7.738	10.243	0.990	0.982
(7,6)	0.995	0.992	7.804	9.750	0.990	0.983
(7,7)	0.996	0.992	7.389	9.968	0.991	0.983
(7,8)	0.995	0.991	8.252	10.369	0.989	0.982
(8,3)	0.996	0.992	7.474	9.711	0.991	0.984
(8,4)	0.995	0.993	7.800	9.330	0.990	0.985
(8,5)	0.995	0.992	7.867	9.826	0.990	0.984
(8,6)	0.996	0.991	7.656	10.213	0.990	0.982
(8,7)	0.996	0.992	7.395	9.646	0.991	0.984
(8,8)	0.996	0.992	7.699	9.891	0.990	0.984

در بررسی عملکرد مدل‌های شبکه عصبی با ساختار ۲ لایه پنهان و ترکیب‌های مختلف نورون‌ها (از (۳,۳) تا (۸,۸))، روند کلی نتایج نشان می‌دهد که افزایش تعداد نورون‌ها به صورت یکنواخت منجر به بهبود کیفیت مدل نشده، بلکه در برخی موارد دقت مدل در آزمون کاهش یافته که نشان‌دهنده پتانسیل بیش‌برازش در ساختارهای پیچیده‌تر است. در مدل‌هایی با ترکیب نورونی پایین (مثل (۳,۳) و (۳,۴))، دقت مدل در داده‌های آموزش بالا بوده ولی خطای نسبی در داده‌های آزمون بیشتر مشاهده شده است. به عنوان مثال، در مدل (۳,۳) مقدار R_{val} برابر ۰.۹۹۰ و $RMSE_{val}$ برابر ۱۰.۹۳۸ بود که نشان می‌دهد مدل گرچه از دقت مناسبی برخوردار است، اما توانایی تعمیم به داده‌های جدید اندکی محدود است. با افزایش تدریجی نورون‌ها، به‌ویژه در ترکیب‌های (۳,۵) تا (۳,۷)، عملکرد مدل در آزمون بهبود یافت و مقادیر $RMSE_{val}$ به زیر ۱۰ رسید. به‌ویژه ترکیب (۳,۶) با عملکرد قابل توجهی نسبت به ترکیب‌های دیگر در همان گروه داشت.

در گروه ترکیب‌های با ۴ نورون در لایه اول، نتایج مشابهی مشاهده شد. ترکیب‌هایی مانند (۴,۴) و (۴,۵) با $RMSE_{val}$ حدود ۹.۱۷۶ و ۹.۴۰۴ عملکرد بسیار پایداري ارائه دادند. این مدل‌ها توانستند تعادل نسبی بین دقت آموزش و ارزیابی برقرار کنند. در این بین، مدل (۴,۶) با R_{val} و $RMSE_{val}$ حدود ۰.۹۹۲ و ۹.۹۶۸ اندکی عملکرد پایین‌تری در آزمون نشان داد که حاکی از آن است که افزایش بیش از حد نورون در لایه دوم در این سطح از پیچیدگی تأثیر معکوس داشته است. در ترکیب (۷,۴) مقدار $RMSE_{val}$ است که این مدل را در صدر مدل‌ها از نظر تعادل بین دقت و کمترین خطا در آزمون قرار می‌دهد.

در ساختارهای با نورون‌های ۵ و بالاتر، مدل‌ها عموماً دقت بالاتری در آموزش داشتند، اما روند عملکرد در ارزیابی چندان یک‌دست نبود. مدل‌هایی مانند (۵,۳)، (۵,۴) و (۵,۵) با $RMSE_{val}$ نزدیک به ۱۰، نسبت به مدل‌هایی با نورون کمتر عملکرد ضعیف‌تری در آزمون داشتند. با این حال، در ترکیب (۵,۶) مقدار $RMSE_{val}$ به ۹.۳۴۳ کاهش یافت که نشان می‌دهد ترکیب خاصی از نورون‌های لایه‌های پنهان می‌تواند عملکرد را بهینه کند. در مدل‌های (۵,۷) و (۵,۸) نیز با وجود حفظ R_{val} بالا، مقادیر $RMSE_{val}$ به حدود ۱۰.۷ رسیدند که مجدداً نشانه‌ای از بیش‌برازش احتمالی در ساختارهای پیچیده‌تر است.

The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering

در ترکیب‌هایی با لایه اول ۶ نورون، به‌ویژه مدل (۶،۵)، عملکردی بسیار مطلوب ثبت شد. مقدار R_{val} برابر ۰.۹۹۵ و $RMSE_{val}$ ۹.۵۸۱ بوده است. همچنین مقدار NSE_{val} برابر ۰.۹۸۳ است که تأییدکننده پایداری بسیار خوب این ساختار است. مدل‌های مشابه مانند (۶،۴)، (۶،۵) و (۶،۶) نیز عملکرد قابل قبولی داشتند اما مقادیر $RMSE_{val}$ در آن‌ها افزایش یافت و به بیش از ۱۰ رسید، نشان‌دهنده آنکه مدل (۶،۳) در این دسته بهترین بوده است. در گروه مدل‌های با نورون‌های بیشتر در هر دو لایه (۷ و ۸ نورون)، با وجود ثبت مقادیر بالای R_{val} (تا ۰.۹۹۶)، مدل‌ها عموماً دچار افزایش $RMSE_{val}$ شدند. مدل‌هایی مانند (۷،۴) و (۸،۴) $RMSE_{val}$ بین ۹.۵ تا ۹.۷ داشتند و از نظر عملکرد در داده‌های آزمون نسبت به (۶،۵) در رتبه پایین‌تری قرار گرفتند. ساختارهایی مانند (۸،۶) و (۸،۷) حتی با وجود دقت بالا، $RMSE$ بالای ۱۰.۵ داشتند که نشان می‌دهد این مدل‌ها احتمالاً به داده‌های آموزشی بیش از حد وابسته شده‌اند و تعمیم‌پذیری آن‌ها پایین‌تر است.


- نتایج شبکه عصبی حافظه کوتاه و بلند مدت: در این مدل‌سازی تعداد تکرارها بین ۱۰۰ تا ۴۰۰ تغییر کرده و نتایج زیر حاصل شده است:

جدول ۱: نتایج شبکه عصبی حافظه کوتاه و بلند مدت

تعداد تکرارها	R_{cal}	R_{val}	$RMSE_{cal}$	$RMSE_{val}$	NSE_{cal}	NSE_{val}
100	0.997	0.996	6.139	8.650	0.994	0.988
200	0.997	0.996	5.850	8.422	0.995	0.989
300	0.998	0.996	5.360	8.991	0.996	0.987
400	0.998	0.995	5.224	8.850	0.996	0.988

نتایج حاصل از اجرای مدل LSTM با تعداد تکرارهای مختلف (از ۱۰۰ تا ۴۰۰) نشان داد که این مدل در تمام حالت‌ها توانایی بسیار بالایی در برآورد تبخیر-تعرق پتانسیل دارد. مقدار ضریب همبستگی (R) در هر دو مرحله آموزش و اعتبارسنجی همواره در محدوده ۰.۹۹۵ تا ۰.۹۹۸ به دست آمد که بیانگر انطباق بسیار خوب مقادیر شبیه‌سازی شده با مقادیر مشاهداتی است. همچنین شاخص نش-ساتکلیف (NSE) نیز برای تمامی تکرارها بالاتر از ۰.۹۸ بوده و دقت بالای مدل را تأیید می‌کند. بررسی تغییرات $RMSE$ نشان داد که با افزایش تعداد تکرارها، خطای آموزش تا حدودی کاهش یافته است، به گونه‌ای که مقدار $RMSE$ در مرحله آموزش از ۶.۱۳۹ در ۲۰۰ تکرار به ۵.۲۲۴ در ۴۰۰ تکرار کاهش یافت. با این حال، در مرحله اعتبارسنجی تغییر محسوسی در $RMSE$ مشاهده نشد و مقدار آن در بازه ۸.۴۲۲ تا ۸.۹۹۱ باقی ماند. این موضوع بیانگر آن است که افزایش تعداد تکرارها عمدتاً موجب بهبود دقت در مرحله آموزش شده، اما بر نتایج مرحله آزمون تأثیر چندانی نداشته است. بنابراین می‌توان نتیجه گرفت که مدل LSTM از همان تکرارهای کمتر نیز به سطح مناسبی از پایداری و دقت رسیده و افزایش بیشتر تعداد تکرارها تنها موجب صرف زمان محاسباتی بیشتر شده است.


The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering



شکل ۳- مقادیر مشاهداتی و مدل شده در بخش واسنجی

شکل ۳ مقادیر مدل سازی شده را در مقابل مقادیر مشاهداتی نشان می دهد، واضح است که LSTM خیلی نزدیک به داده های مشاهداتی قرار گرفته و تقریباً نوسانات را دقیق دنبال کرده است. ANN هم روند کلی را درست پیش رفته است، اما در بعضی نقاط (به ویژه در قله ها و کف ها) اختلاف دارد. در واقع LSTM چون حافظه زمانی دارد در بخش واسنجی نسبت به ANN عملکرد بهتری داشته است.

The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering



شکل ۴- مقادیر مشاهداتی و مدل شده در بخش صحت سنجی

شکل ۴ مقادیر تبخیر تعرق پتانسیل مدل شده توسط ANN و LSTM را با مقادیر مشاهداتی در دوره صحت سنجی نشان می‌دهد؛ در این بخش نیز هر دو مدل ANN و LSTM روند کلی مقادیر مشاهداتی PET را به خوبی دنبال می‌کنند. این نشان می‌دهد که هر دو مدل توانایی یادگیری الگوهای موجود در داده‌ها را دارند. با این وجود، مدل LSTM انطباق بهتری با مقادیر مشاهداتی دارد و به نظر می‌رسد در برآورد مقادیر پیک دقیق‌تر عمل می‌کند. این مدل کمترین انحراف از مقادیر واقعی را نشان می‌دهد.

۶- نتیجه‌گیری

نتایج مدل‌های شبکه عصبی مصنوعی نشان داد که افزایش تعداد نورون‌ها در هر لایه به صورت یکنواخت منجر به بهبود عملکرد مدل نشده است. به طور کلی، مدل‌های ANN در مرحله آموزش دقت بسیار بالایی داشتند، اما در مرحله صحت سنجی در برخی ساختارهای پیچیده‌تر با مشکل بیش‌برازش مواجه شدند. در مقایسه، نتایج مدل LSTM نشان داد که این مدل از پایداری و دقت بالاتری برخوردار است. مقدار R_{val} در تمامی تکرارها در محدوده ۰.۹۹۵ تا ۰.۹۹۶ و مقدار NSE_{val} بین ۰.۹۸۷ تا ۰.۹۸۹ قرار داشت، در حالی که مقدار $RMSE_{val}$ تقریباً ثابت و در بازه ۸.۴۲۲ تا ۸.۹۹۱ باقی ماند. نکته قابل توجه این است که برخلاف مدل ANN که افزایش تعداد نورون‌ها در برخی موارد باعث افت عملکرد شد، در مدل LSTM تغییر تعداد تکرارها

(از ۱۰۰ تا ۴۰۰) موجب تغییر معناداری در دقت مرحله صحت‌سنجی نشد و مدل در تمام حالت‌ها تعمیم‌پذیری بالایی داشت. در مجموع، اگرچه مدل ANN در برخی ساختارهای خاص مانند (۶,۵) یا (۴,۴) توانست عملکرد قابل قبولی ارائه دهد، اما نتایج مدل LSTM نشان داد که این روش در مقایسه با ANN از پایداری بیشتر، خطای کمتر در داده‌های آزمون و مقاومت بالاتر در برابر بیش‌برازش برخوردار است. بنابراین می‌توان نتیجه گرفت که LSTM به دلیل ماهیت بازگشتی و قابلیت ذخیره و یادگیری وابستگی‌های زمانی، ابزار کارآمدتری برای مدل‌سازی تبخیر-تعرق پتانسیل در حوضه کرخه محسوب می‌شود.



The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering

مراجع

- [1] Ferreira, L.B., da Cunha, F.F., de Oliveira, R.A., Fernandes Filho, E.I., 2019. Estimation of reference evapotranspiration in Brazil with limited meteorological data using ANN and SVM–A new approach. *J. Hydrol.* 572, 556–570. <https://doi.org/10.1016/j.jhydrol.2019.03.028>.
- [2] Maroufpoor, S., Bozorg-Haddad, O., Maroufpoor, E., 2020. Reference evapotranspiration estimating based on optimal input combination and hybrid artificial intelligent model: Hybridization of artificial neural network with grey wolf optimizer algorithm. *J. Hydrol.* 588, 125060 <https://doi.org/10.1016/j.jhydrol.2020.125060>.
- [3] Schlesinger, W.H., Jasechko, S., 2014. Transpiration in the global water cycle. *Agric. For. Meteorol.* 189, 115–117.
- [4] Allen, R.G., Clemmens, A.J., Burt, C.M., Solomon, K., O'Halloran, T., 2005. Prediction accuracy for projectwide evapotranspiration using crop coefficients and reference evapotranspiration. *J. Irrig. Drain. Eng.* 131 (1), 24–36. [https://doi.org/10.1061/\(ASCE\)0733-9437\(2005\)131:1\(24\)](https://doi.org/10.1061/(ASCE)0733-9437(2005)131:1(24)).
- [5] Teuling, A.J., Hirschi, M., Ohmura, A., Wild, M., Reichstein, M., Ciais, P., Buchmann, N., Ammann, C., Montagnani, L., Richardson, A.D., Wohlfahrt, G., 2009. A regional perspective on trends in continental evaporation. *Geophys. Res. Lett.* 36 (2) <https://doi.org/10.1029/2008GL036584>. Anderson, M.C., Norman, J.M., Mecikalski, J.R., Otkin, J.A., Kustas, W.P., 2007.
- [6] A climatological study of evapotranspiration and moisture stress across the continental United States based on thermal remote sensing: 1. Model formulation. *J. Geophys. Res. Atmos.* 112 (D10) <https://doi.org/10.1029/2006JD007506>.
- [7] Orth, R., Destouni, G., 2018. Drought reduces blue-water fluxes more strongly than green-water fluxes in Europe. *Nat. Commun.* 9 (1), 1–8. <https://doi.org/10.1038/s41467-018-06013-7>.
- [8] Zhang, Z., Tian, F., Hu, H., Yang, P., 2014. A comparison of methods for determining field evapotranspiration: photosynthesis system, sap flow, and eddy covariance. *HESS* 18 (3), 1053–1072. <https://doi.org/10.5194/hess-18-1053-2014>.
- [9] Holmes, J.W., 1984. Measuring evapotranspiration by hydrological methods. *Agric. Water Manag.* 8 (1–3), 29–40. [https://doi.org/10.1016/0378-3774\(84\)90044-1](https://doi.org/10.1016/0378-3774(84)90044-1).
- [10] Anapalli, S.S., Ahuja, L.R., Gowda, P.H., Ma, L., Marek, G., Evett, S.R., Howell, T.A., 2016. Simulation of crop evapotranspiration and crop coefficients with data in weighing lysimeters. *Agric. Water Manag.* 177, 274–283. <https://doi.org/10.1016/j.agwat.2016.08.009>.
- [11] Xue, J., Su, B., 2017. Significant remote sensing vegetation indices: a review of developments and applications. *J. Sens.* 2017, 1353691. <https://doi.org/10.1155/2017/1353691>.
- [12] Baïamonte, G., Motisi, A., 2020. Analytical approach extending the Granier method to radial sap flow patterns. *Agric. Water Manag.* 231, 105988 <https://doi.org/10.1016/j.agwat.2019.105988>.
- [13] Fan, J., Guyot, A., Ostergaard, K.T., Lockington, D.A., 2018. Effects of earlywood and latewood on sap flux density-based transpiration estimates in conifers. *Agric. Meteorol.* 249, 264–274. <https://doi.org/10.1016/j.agrformet.2017.11.006>.
- [14] Kisi, O., Sanikhani, H., Zounemat-Kermani, M., Niazi, F., 2015. Long-term monthly evapotranspiration modeling by several data-driven methods without climatic data.



The First National Conference on Hydro-Informatics and Artificial Intelligence in Water Engineering

Comput. Electron Agric. 115, 66–77. <https://doi.org/10.1016/j.compag.2015.04.015>.

[15] Almorox, J., Quej, V.H., Martí, P., 2015. Global performance ranking of temperaturebased approaches for evapotranspiration estimation considering Koppen " climate classes. J. Hydrol. 528, 514–522. <https://doi.org/10.1016/j.jhydrol.2015.06.057>.

[16] Amani, Sh., Shafizadeh-Moghadam, H., 2023. A review of machine learning models and influential factors for estimating evapotranspiration using remote sensing and ground-based data. Agricultural Water Management. 284. <https://doi.org/10.1016/j.agwat.2023.108324>

[17] Sudheer, K.P.; Gosain, A.K.; Ramasastri, K.S. Estimating actual evapotranspiration from limited climatic data using neural computing technique. J. Irrig. Drain. Eng. 2003, 129, 214–218.

[18] Kumar, M.; Raghuwanshi, N.S.; Singh, R.; Wallender, W.W.; Pruitt, W.O. Estimating evapotranspiration using artificial neural network. J. Irrig. Drain. Eng. 2002, 128, 224–233.

[19] Trajkovic, S.; Todorovic, B.; Stankovic, M. Forecasting reference evapotranspiration by artificial neural networks. ASCE J. Irrig. Drain. Engng. 2003, 129, 454–457.

[20] Keskin, M.E.; Terzi, O. Artificial Neural Network Models of Daily Pan Evaporation. J. Hydrol. Eng. 2006, 11, 65–70

[21] Gonzalez-Camacho, J.M.; Cervantes-Osornio, R.; Ojeda-Bustamante, W.; Lopez-Cruz, I. Forecasting reference evapotranspiration using artificial neural networks. Ing. Hidráulica México 2008, 23, 127–138.

[22] Kumar, M.; Raghuwanshi, N.S.; Singh, R. Development and validation of GANN model for evapotranspiration estimation. J. Hydrol Eng. ASCE 2009, 44, 131–140.

[23] Falamarzi, Y.; Palizdan, N.; Huang, Y.F.; Lee, T.S. Estimating evapotranspiration from temperature and wind speed data using artificial and wavelet neural networks (WNNs). Agric. Water Manag. 2014, 140, 26–36.

[24] Traore, S.; Wang, Y.M.; Chung, W. Predictive accuracy of backpropagation neural network methodology in evapotranspiration forecasting in Dédougou region, western Burkina Faso. J. Earth Syst. Sci. 2014, 123, 307–318.

[25] Tang, D., Feng, Y., Gong, D., Hao, W., and Cui, N. 2018. 'Evaluation of artificial intelligence models for actual crop evapotranspiration modeling in mulched and non-mulched maize croplands', Computers and Electronics in Agriculture. 152: 375-84.

[26] Ghatfan A, Ammar Badia Y H and Alaa A S (2017) Estimation of reference evapotranspiration based on only temperature data using artificial neural network. American Journal of Innovative Research and Applied Sciences 157-162

[27] پیری، جمشید و انصاری، حسین . (۱۳۹۱). مدل سازی تبخیر روزانه تشتک با استفاده از ANFIS و NN_ARX. *Iran Agricultural Research*, 31(2), 51-64. doi: 10.22099/iar.2013.1527

[28] Jang, J.C., Sohn, E.H., Park, K.H., Lee, S., 2021. Estimation of Daily Potential Evapotranspiration in Real-Time from GK2A/AMI Data Using Artificial Neural Network for the Korean Peninsula. J. Hydrol. 8 (3), 129. <https://doi.org/10.3390/hydrology8030129>.

[29] Deng, L., Yu, D., 2014. Deep learning: methods and applications. Found. Trends Signal Process. 7 (3–4), 197–387.

[30] Chen, Z., Zhu, Z., Jiang, H., Sun, S., 2020a. Estimating daily reference evapotranspiration based on limited meteorological data using deep learning and classical machine learning methods. J. Hydrol. 591, 125286.

[31] افشین، ی. رودهای ایران (جلد ۱). وزارت نیرو – مهندسين مشاور جاماب



[32] مصباح زاده، ط، سلیمان‌ساردو، ف. ۱۳۹۷. بررسی روند زمانی خشکسالی هیدرولوژیک و هواشناسی در حوضه آبریز کرخه. مجله علوم و مهندسی آبخیزداری ایران: ۱۱۵-۱۰۵

[33] سعدیان، علی و شفیعی زاده مقدم، حسین . (۱۴۰۰). بررسی تغییرات کاربری اراضی حوضه آبریز کرخه در سال‌های ۱۹۹۰ و ۲۰۲۰ با استفاده از پلتفرم گوگل ارث انجین و تصاویر ماهواره‌ای لندست. تحقیقات آب و خاک ایران: 52(10), 2569-2580. doi: 10.22059/ijswr.2021.330075.669068

[34] Modaresi, F., Araghinejad, s., Ebrahimi, k. (2017). A comparative assessment of artificial neural network, generalized regression neural network, least-square support vector regression, and k-nearest neighbor regression for monthly streamflow forecasting in linear and nonlinear conditions. Water Resources Management, 32(5): 243-258. <https://doi.org/10.1007/s11269-017-1807-2>

[35] Hochreiter, S., Schmidhuber, J., (1997). Long short-term memory. Neural Comput. 9, 1735–1780.

[36] Olah, C. (2015). Understanding LSTM Networks Browning KA, Collier CG (1989) Nowcasting of precipitation systems. Rev Geophys 27:345– 370.

[37] زینعلی، معصومه ، بزرگ حداد، امید ، یاسی، مهدی و علیزاده، حسین . (۱۴۰۳). ارزیابی کارایی مدل LSTM در پیش‌بینی جریان روزانه ورودی به مخازن سدها. تحقیقات آب و خاک ایران: doi: 10.22059/ijswr.2024.378146.669738, 55(10), 1863-1883.

[38] Moriasi, D.N., Arnold, J.G., Van Liew, M.W. (2007). Model evaluation guidelines for systemic quantification of accuracy in watershed simulations. Transactions of ASABE, 50(3) :885-900. <https://doi.org/10.13031/2013.23153>