



The Temperature Effect on the Estimation of Basin Outflow by Perceptron and Convolutional Neural Networks with Wavelet Analysis

I. Naderirad¹, M. Saadat^{2*}, A. Avokh^{3,4}, and M. Mehrparvar⁵

Abstract

Estimation of basin outflow under the influence of various parameters is a complex process and in case of basin information lack, the analytical models are not applicable. On the other hand, Artificial Intelligence models do not require basin information, and some, such as the convolutional neural network (CNN), have recently been widely used in hydrology. The purpose of this study was to investigate the performance of CNN in estimating the outflow in terms of temperature, precipitation and inflow to the basin. In this study, CNN, combination of CNN with wavelet analysis (WCNN), and perceptron neural network (MLP) were used to evaluate the effect of temperature on the outflow within the Ghaleh Shahrokh Chelgard basin from 1992 to 2015. Each model was run 20 times and the mean values of correlation coefficient (\bar{R}), root mean square error (\overline{RMSE}) and Nash Sutcliffe coefficient (\overline{NS}) were calculated. Lags of one, two and three-month of temperature and rainfall data are also included as input data. Wavelet analysis was used for noise reduction and the results showed that CNN with a lag of three months had \overline{RMSE} , \bar{R} and \overline{NS} equal to 14.20 (m^3/s), 0.922 and 0.772, respectively. In contrast, the WCNN method with Daubechies wavelet, which is a combination of CNN and wavelet analysis, with level four performance and resolution two (WCNN3-db42) had indices respectively equal to 9.45 (m^3/s), 0.945 and 0.863. Accordingly, CNN performed better than MLP, and the WCNN method with wavelet analysis showed better performance than CNN.

Keywords: Basin Outflow, Convolutional Network, Wavelet Analysis, Noise Reduction, Ghaleh Shahrokh.

Received: February 12, 2022

Accepted: April 8, 2022

تأثیر دما بر برآورد جریان خروجی از حوضه آبریز توسط شبکه‌های عصبی پرسپترون و کانولوشنی همراه با تحلیل موجک

ایمان نادری‌راد^۱، محسن سعادت^{۲*}، آوید آوخ^{۳،۴} و میلاد مهرپرو^۵

چکیده

تخمین جریان خروجی از یک حوضه آبریز تحت تأثیر پارامترهای مختلف، فرایندی پیچیده بوده و در صورت کمبود اطلاعات حوضه، استفاده از مدل‌های تحلیلی امکان‌پذیر نیست. از سوی دیگر، مدل‌های هوش مصنوعی نیاز به مشخصات حوضه نداشته و برخی مانند شبکه عصبی کانولوشنی (CNN) اخیراً در هیدرولوژی کاربرد فراوانی داشته‌اند. هدف این تحقیق بررسی عملکرد CNN در برآورد جریان خروجی بر حسب پارامترهای دما، بارش و دبی ورودی به حوضه بوده است. در این تحقیق از CNN، ترکیب CNN با تحلیل موجک (WCNN) و از شبکه عصبی پرسپترون (MLP) جهت ارزیابی تأثیر دما بر برآورد جریان خروجی در حوضه آبریز قلعه شاهرخ چلگرد در بازه زمانی سال ۱۹۹۲ تا ۲۰۱۵ میلادی استفاده شد. هر مدل ۲۰ مرتبه اجرا شده و میانگین مقادیر ضریب همبستگی (\bar{R})، ریشه میانگین مربعات خطا (\overline{RMSE}) و ضریب نش- ساتکلیف (\overline{NS}) محاسبه شده‌اند. تأخیر یک، دو و سه ماهه داده‌های دما و بارندگی نیز به عنوان داده ورودی لحاظ شده است. همچنین، از تحلیل موجک جهت پیش‌پردازش داده‌ها در کاهش نوفه استفاده شده و نتایج نشان داد که CNN با تأخیر سه ماهه دارای مقادیر \overline{RMSE} ، \bar{R} و \overline{NS} به ترتیب برابر $14.20 (m^3/s)$ ، 0.922 و 0.772 بود. در مقابل، روش WCNN3 با موجک Daubechies که ترکیب CNN و تحلیل موجک است، با عملکرد سطح چهار و وضوح دو (WCNN3-db42) دارای مقادیر شاخص‌های ارزیابی برابر $9.45 (m^3/s)$ ، 0.945 و 0.863 بود. بر این اساس، عملکرد بهتری نسبت به MLP داشته و روش WCNN نیز با کمک تحلیل موجک، کارایی و عملکرد بهتری نسبت به CNN از خود نشان داد.

کلمات کلیدی: خروجی حوضه، شبکه کانولوشنی، تحلیل موجک، کاهش نوفه، قلعه شاهرخ.

تاریخ دریافت مقاله: ۱۴۰۰/۱۱/۲۳

تاریخ پذیرش مقاله: ۱۴۰۱/۱/۹

1- Ph.D. Candidate, Department of Civil Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran.

2- Assistant Professor, Department of Civil Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran. Email: mohsen.saadat@pci.iaun.ac.ir

3- Assistant Professor, Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran.

4- Digital Processing and Machine Vision Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran.

5- Ph.D., Expert in Design Unit, Water and Wastewater Consulting Engineering Research and Design, Isfahan, Iran.

*- Corresponding Author

Dor: [20.1001.1.17352347.1401.18.1.2.0](https://doi.org/10.1001.1.17352347.1401.18.1.2.0)

۱- دانشجوی دکتری، گروه مهندسی عمران، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران.

۲- استادیار، گروه مهندسی عمران، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران.

۳- استادیار، دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران.

۴- مرکز تحقیقات پردازش دیجیتال و بینایی ماشین، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران.

۵- دانش‌آموخته دکتری، کارشناس طراح، مهندسین مشاور طرح و تحقیقات آب و فاضلاب، اصفهان، ایران.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان تابستان ۱۴۰۱ امکانپذیر است.



۱- مقدمه

بارش را نسبت به روش‌های MLP و آریمایکس نشان داده است. Gorbani et al. (2015) با استفاده از روش W-ANN و MLP در برآورد جریان خروجی بر حسب بارش در حوضه آبریز بالبخ لوچای به این نتیجه رسیدند که روش W-ANN در این مدل‌سازی دارای دقت مناسبی است. در حوضه آبریز سد مارون جهت برآورد جریان خروجی بر حسب بارش تحقیقی با استفاده از MLP بر مبنای انتخاب متغیرهای مؤثر ورودی با الگوریتم اطلاعات متقابل جزئی^۵ انجام شده است. این الگوریتم میزان تأثیر روابط موجود بین داده‌های ورودی، خروجی و بین متغیرهای اضافی جهت انتخاب متغیرهای ورودی مؤثر بر مدل را تعیین می‌نماید. تأثیر به کارگیری این الگوریتم در برآورد جریان خروجی بر حسب بارش در این تحقیق مؤثر اعلام گردید (Shafeizadeh et al., 2019).

Shoab et al. (2019) در خصوص تأثیر تحلیل موجک بر مدل‌های جریان خروجی بر حسب بارش، کارایی روش‌های مختلف مدل‌سازی را مقایسه کردند. ایشان در تحقیق خود جهت برآورد جریان خروجی، از روش‌هایی مانند روش سیستم استنتاج عصبی-فازی سازگار، روش استنتاج عصبی فازی هم‌زمان فعال^۶ (CANFIS)، شبکه عصبی تعمیم یافته رو به جلو^۷ (GFFN) شبکه عصبی مدولار^۸ (MNN)، شبکه عصبی بازگشتی^۹ (RNN)، شبکه عصبی بازگشتی با تأخیر زمانی^{۱۰} (TLRNN)، (MLP) و برنامه ریزی بیان ژن^{۱۱} (GEP) استفاده کردند. در بخش اصلی این تحقیق ترکیب تحلیل موجک با روش‌های فوق مورد بررسی قرار گرفته و این اقدام توانایی روش‌ها را برای برآورد جریان خروجی افزایش داده است (Shoab et al., 2019). Van et al. (2020) نتایج روش‌های CNN و RNN را در مدل‌سازی جریان خروجی و بارش را در دو حوضه کشور ویتنام با یکدیگر مقایسه نمودند. ایشان در تحقیق خود برتری روش CNN را در برآورد جریان خروجی اعلام کرده‌اند (Van et al., 2020).

Anctil et al. (2004) و Van et al. (2020) در تحقیق خود و با بررسی تحقیقات دیگران نشان دادند که برآورد جریان خروجی بر اساس بارش، تبخیر، رطوبت و دما باعث ایجاد خطا در روش MLP و CNN می‌شود و فقط داده‌های بارش را در روش MLP و CNN به‌عنوان داده‌های ورودی در برآورد جریان خروجی مؤثر معرفی نموده‌اند. محققان متعددی در خصوص کاربرد روش CNN در مدل‌سازی جریان خروجی از حوضه بر حسب بارش تحقیقاتی انجام داده‌اند. ایشان در نتایج خود به برتری CNN در برآورد جریان خروجی نسبت به روش‌هایی مانند MLP و RNN اشاره کردند (Liu et al., 2021; Xu, 2021).

برآورد جریان خروجی از حوضه‌های آبریز یکی از موضوعات پیچیده هیدرولوژیک بوده و تحت تأثیر متغیرهای مختلف فیزیکی و هیدرولوژیک حوضه آبریز است. نظر به اینکه برآورد دقیق جریان خروجی از یک حوضه اهمیت زیادی در مدیریت منابع آب دارد، تاکنون روش‌های متعددی توسط محققان برای برآورد جریان خروجی ارائه شده است. نکته اصلی تأثیر پارامترهای مختلف مانند تبخیر، دمای بیشینه و کمینه و دبی ورودی به حوضه آبریز، تأثیر خصوصیات و مشخصات حوضه بر میزان جریان خروجی می‌باشد که نشان‌دهنده یک رابطه غیرخطی و پیچیده بین آنها می‌باشد. این موارد همیشه برآورد جریان خروجی با استفاده از روابط تحلیلی را با مشکل روبرو نموده است. استفاده از روش‌هایی مانند شبکه عصبی مصنوعی^۱ (ANN) روش ترکیبی شبکه عصبی و تحلیل موجک^۲ (W-ANN)، شبکه عصبی کانولوشنی^۳ (CNN) و روش‌های مشابه دیگر می‌تواند ابزار مناسبی جهت برآورد جریان خروجی باشند. در اکثر اوقات داده‌های موجود برای مدل‌سازی پدیده‌های هیدرولوژیک دارای نوفه هستند. با توجه به آن که روش ANN توانایی خوبی در مدل‌سازی پدیده‌های هیدرولوژیک دارد، با این وجود، نوفه داده‌ها توسط روش ANN قابل حذف نمی‌باشند و بنابراین در نتایج برآورد جریان خروجی توسط روش ANN تأثیر منفی دارند. در سال‌های اخیر تحلیل موجک توسط محققان مختلف به عنوان ابزاری مناسب جهت کاهش نوفه داده‌ها استفاده شده و می‌تواند نتایج مدل‌سازی را در روش ANN بهبود دهد (Nourani et al., 2009). Mosavi et al. (2018) در تحقیق خود به بررسی اکثر روش‌های ارائه شده در زمینه برآورد جریان خروجی پرداخته و اعلام کردند که محققین متعددی از انواع روش‌های ANN مانند شبکه پرسپترون چند لایه (MLP)^۴ و W-ANN جهت برآورد جریان خروجی از حوضه‌های آبریز استفاده نموده‌اند. به دلیل توانایی تحلیل موجک در کاهش نوفه از داده‌ها، در سال‌های اخیر استفاده از روش W-ANN نسبت به ANN در برآورد جریان خروجی بر حسب بارش موفقیت‌های قابل توجهی به همراه داشته است. همچنین نتایج استفاده از این روش در مدل‌سازی، انطباق خوبی با داده‌های واقعی نشان می‌دهد (Mosavi et al., 2018). در برآورد جریان خروجی در حوضه لیقوانچی تبریز نیز از روش W-ANN و MLP استفاده شده و محققین به برتری روش W-ANN نسبت به MLP اشاره نمودند (Nourani et al., 2009). (Nourani and Parhizkar (2013) برای برآورد جریان خروجی در حوضه آبریز کرک آمریکا، عملکرد روش W-ANN را با روش آریمایکس مقایسه نمودند. نتایج این تحقیق، برتری روش W-ANN جهت برآورد جریان خروجی بر حسب

توسط روش CNN از ویژگی‌های جریان سطحی^{۱۲} (SFF)، ویژگی‌های جریان پایه^{۱۳} (BFF) با استفاده از شماره منحنی خدمات حفاظت از خاک و سطح آب زیرزمینی در حوضه آبریزی از کره جنوبی استفاده شده است (Song, 2022). معماری و قابلیت CNN برای یک ساختار چند ورودی همراه با پردازش داده‌ها ارتقا یافته است. روش CNN در برآورد جریان خروجی با بکارگیری BFF و SFF جهت غلبه بر کمبود داده‌هایی مانند توپوگرافی، پوشش زمین و جنس خاک که عمدتاً به داده‌های هواشناسی بستگی دارند با دقت بالایی عمل می‌نماید (Song, 2022).

۲- منطقه مورد مطالعه

منطقه مورد مطالعه حوضه آبریز قلعه‌شاهرخ چلگرد یکی از زیر حوضه‌های آبریز حوضه زاینده‌رود بوده و در استان چهارمحال و بختیاری واقع شده است. بلندترین نقطه ارتفاعی این منطقه ۳۷۹۱ متر و کمترین نقطه ارتفاعی آن، ۲۰۶۲ متر از سطح دریا است. شکل ۱ موقعیت منطقه مورد مطالعه را نشان می‌دهد. بارش متوسط سالانه این منطقه برابر ۹۵۵ میلیون متر مکعب در ارتفاعات و ۱۳۵ میلیون متر مکعب در جلگه‌ها می‌باشد. همچنین، آب انتقال یافته بین حوضه‌ها توسط دو تونل کوه‌رنگ و همچنین آب تخلیه شده چشمه‌ها به عنوان آب ورودی به حوضه محسوب می‌شود. بر اساس داده‌های ماهانه بارش، دمای بیشینه و کمینه و دبی ورودی توسط دو تونل کوه‌رنگ از سال ۱۹۹۵ تا سال ۲۰۱۵ میلادی در حوضه آبریز شاهرخ چلگرد، برآورد جریان خروجی در این تحقیق انجام شده است (Mehrparvar and Asghari, 2018).

۳- مواد و روش‌ها

۳-۱- روش شبکه عصبی کانولوشنی

شبکه CNN یکی از مهم‌ترین روش‌های یادگیری عمیق است که در آنها چندین لایه آموزش می‌بینند. این روش بسیار کارآمد بوده و یکی از رایج‌ترین روش‌های شبکه عصبی است. به‌طور کلی، یک شبکه عصبی کانولوشن از سه لایه اصلی تشکیل می‌شود که عبارت هستند از: لایه کانولوشن، لایه ادغام^{۱۴} و لایه تماماً متصل^{۱۵}. لایه‌های مختلف وظایف مختلفی را انجام می‌دهند. در هر شبکه عصبی کانولوشن دو مرحله پیش‌انتشار و پس‌انتشار برای آموزش وجود دارد. به‌طور کلی در شبکه‌های کانولوشنی تمایل استفاده از تابع تحریک یکسوساز^{۱۶} نسبت به دیگر توابع غیرخطی بیشتر است؛ زیرا تابع یکسوساز، نحوه محاسبه ساده‌ای دارد و منابع محاسباتی زیادی را درگیر نمی‌کند. استفاده از این تابع منجر به رسیدن به دقت‌های قابل قبولی در مدل‌سازی می‌گردد.

اکثر تحقیقات انجام شده (Nourani et al., 2009; Mosavi et al., 2018; Nourani et al., 2011) در خصوص مدل‌سازی جریان خروجی به مؤثر بودن روش W-ANN در جهت بهبود نتایج مدل‌سازی اشاره نموده‌اند. اما در روش W-ANN انتخاب تابع موجک مادر، مسیر طولانی مدل‌سازی به دلیل ترکیب دو روش، همواره برای محققان استفاده از روش‌های کارآمدی چون CNN، جهت مدل‌سازی جریان خروجی را بیش از گذشته اجتناب‌ناپذیر می‌نماید. در ضمن روش CNN توانایی و قابلیت برآورد جریان خروجی با دقت بالا و پردازش داده‌ها را به‌صورت هم‌زمان دارا می‌باشد (Song, 2022; Van et al., 2020). مدل‌سازی جریان خروجی از یک حوضه به پارامترهای مختلفی مانند دما، بارش، دبی ورودی و خصوصیات فیزیکی حوضه وابسته است. اگر حتی تمام پارامترهای تأثیرگذار در برآورد جریان خروجی لحاظ گردد، همچنان امکان بهبود ساختار مدل‌سازی وجود دارد. استفاده از روش‌هایی مانند CNN که ساختاری با چندین ورودی دارند، می‌تواند در افزایش دقت برآورد جریان خروجی مؤثر باشد. تاکنون تحقیقی جهت ارزیابی تأثیر دما با استفاده از روش CNN در برآورد جریان خروجی انجام نشده است. همچنین، در تحقیقاتی که در خصوص مدل‌سازی جریان خروجی با روش CNN ارائه شده تاکنون تأثیر تحلیل موجک و کاهش نوفه داده‌ها را در نظر نگرفته‌اند. مقایسه نتایج CNN و WCNN همراه با بررسی تأثیر دمای بیشینه و کمینه در برآورد جریان خروجی از اهداف اصلی این تحقیق می‌باشد. در ضمن بررسی تأثیر تحلیل موجک در افزایش دقت برآورد جریان خروجی در روش WCNN با توجه به ساختار روش CNN و کارآمدی این روش در مدل‌سازی را می‌توان از اهداف دیگر این تحقیق دانست. مؤلفین مقاله حاضر در خصوص برآورد جریان خروجی بر حسب بارش معتقد هستند؛ هرچه داده‌های ورودی در روش‌های مدل‌سازی جریان خروجی بیشتر و متنوع‌تر باشد، برآورد جریان خروجی دقیق‌تر خواهد بود. استفاده از روش‌های جدید یا روش‌های ترکیبی برای برآورد جریان خروجی باید مورد توجه قرار گیرد و پیشنهاد حذف

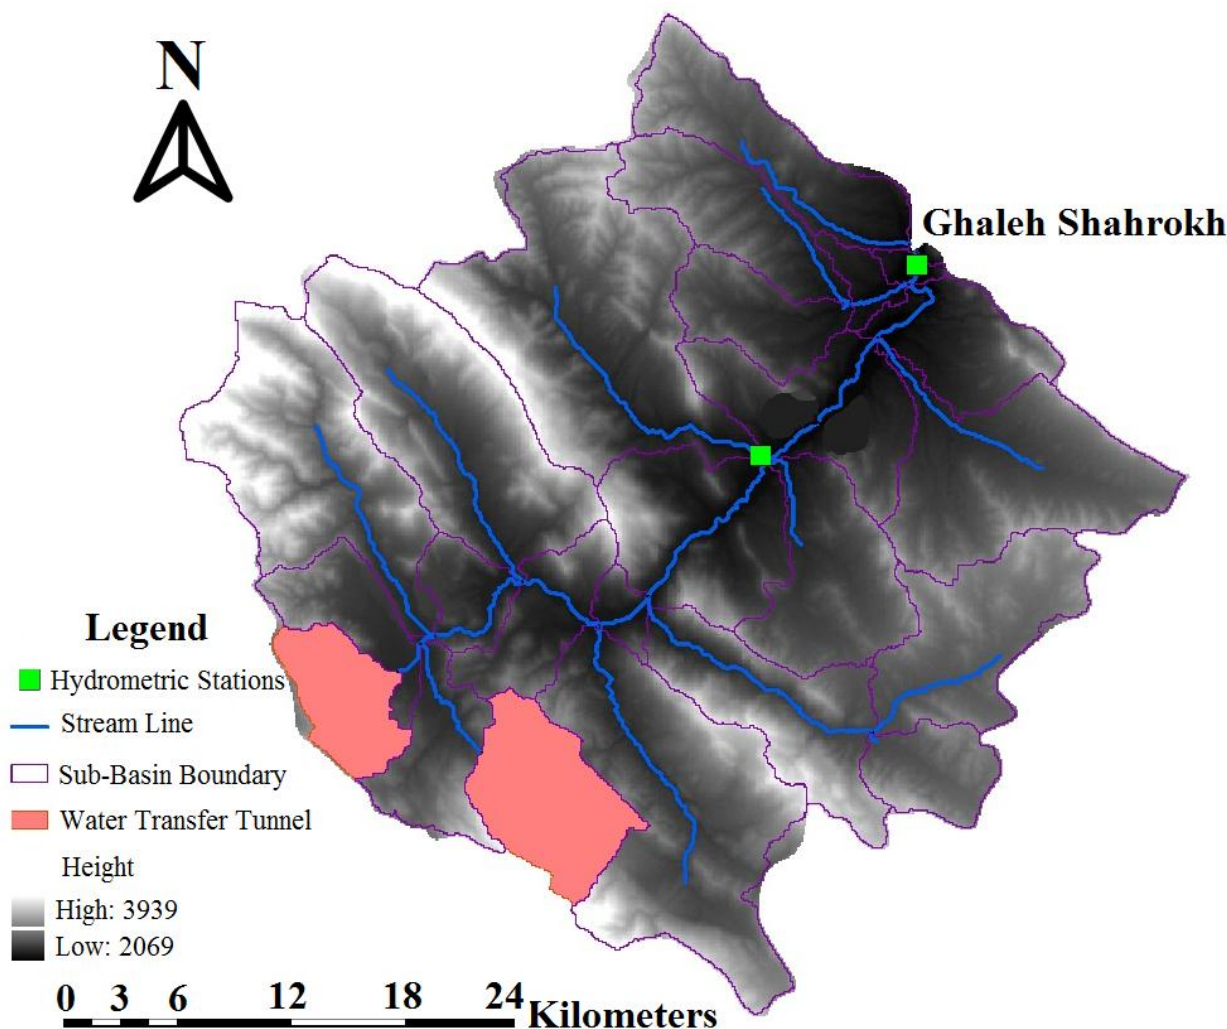


Fig. 1- Geographical location of the study area of Ghaleh Shahrokh Chelgard basin

شکل ۱- موقعیت جغرافیایی محدوده مطالعاتی زیرحوضه آبریز قلعه شاهرخ چلگرد

شبکه‌های عصبی سنتی یک اتصال کامل بین این لایه و لایه پیش از آن برقرار می‌شود. انتخاب تعداد لایه‌های CNN به صورت آزمون و خطا انجام می‌شود (Hu et al., 2018; Van et al., 2020). در این تحقیق نیز بعد از چند مرحله آزمون و خطا از شکل ۲ به‌عنوان مدل پیشنهادی جهت برآورد جریان خروجی توسط روش CNN استفاده شده است. در مدل پیشنهادی در حالت اول داده‌های ورودی شامل P , T_{min} , T_{max} و Q می‌باشد که به ترتیب دمای بیشینه، دمای کمینه، بارندگی و دبی ورودی به حوضه آبریز هستند. همچنین، O نشان دهنده جریان خروجی از حوضه است. در حالت دوم داده‌های ورودی دمای بیشینه و کمینه حذف شده است و برآورد جریان خروجی در این بخش بدون دما انجام شده است. در این تحقیق از شبکه سه لایه کانولوشن با تابع ادغام بیشینه استفاده شده است. لایه‌های کانولوشن به ترتیب 8×128 ، 4×64 و 1×32 است. در ادامه از سه لایه اتصال

در نهایت، مقادیر حاصل شده به زیر لایه بعدی برای انجام عملیات ادغام داده می‌شود. اعمال ادغام باعث پایدارتر شدن ویژگی‌ها و کاهش حساسیت نسبت به تغییرات ناخواسته می‌شود. از این رو اگر کاهش ابعادی در مرحله ادغام صورت بگیرد، می‌توان کاربرد دیگر این زیر لایه را نگهداشتن ویژگی‌های ارزشمندتر و کنار گذاشتن ویژگی‌های کم اهمیت‌تر دانست. انواع مختلفی از ادغام وجود دارد که محبوب‌ترین آنها ادغام بیشینه^{۱۳} است (Hu et al., 2018). اکنون یک لایه کانولوشنی به‌طور کامل بر روی داده‌ها اعمال شده است. حال بسته به نوع شبکه کانولوشنی مورد استفاده، این مرحله به تعداد معینی تکرار می‌شود. بعد از اتمام لایه‌های کانولوشنی می‌توان از یک یا چند لایه تمام متصل برای بررسی نهایی ویژگی‌های به دست آمده استفاده کرد. یک لایه تمام متصل دقیقاً مانند یک لایه کانولوشنی است با این تفاوت که در اینجا تعاملات پراکنده صورت نمی‌گیرد و دقیقاً مانند

نمی‌توانند آنها را به نمایش گذارند (Partovian et al., 2016). تابع موجک، تابعی است که دو ویژگی مهم نوسانی و کوتاه مدت بودن را دارا می‌باشد. $\Psi(x)$ تابع موجک است که اگر تبدیل فوریه آن $\psi(\omega)$ شرط معادله (۱) را داشته باشد.

$$\int_{-\infty}^{+\infty} \frac{|\psi(\omega)|}{|\omega|^2} d\omega \leq +\infty \quad (1)$$

معادله (۱) به عنوان شرط پذیرش موجک $\Psi(x)$ شناخته می‌شود. معادله (۲) نیز یکی از شرایط پذیرش موجک است.

$$\int_{-\infty}^{+\infty} \Psi(x) dx = 0 \quad (2)$$

در رابطه (۳)، (a) عامل مقیاس زمانی و (b) ضریب موقعیت زمانی می‌باشد (Partovian et al., 2016; Sang et al., 2009).

$$\Psi_{a,b}(x) = \frac{1}{\sqrt{a}} \Psi\left(\frac{x-b}{a}\right) \quad (a,b) \in \mathbb{R}^+ \times \mathbb{R} \quad (3)$$

در رابطه (۳)، \mathbb{R}^+ و \mathbb{R} مجموعه اعداد حقیقی مثبت و کل اعداد حقیقی هستند. در نهایت، تبدیل موجک پیوسته^{۱۸} (CWT) می‌تواند سیگنال $f(x)$ را در فضای دو بعدی طبق معادله (۴) تحلیل نماید. $W_f(a,b)$ تبدیل تابع موجک در معادله (۴) می‌باشد.

$$W_f(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(x) \Psi^*\left(\frac{x-b}{a}\right) dx = \int_{-\infty}^{+\infty} f(x) \Psi_{a,b}^*(x) dx$$

کامل بهره گرفته شده است. در اولین لایه اتصال از ۶۸ لایه، در لایه دوم اتصال از ۳۲ لایه و در لایه اتصال سوم از ۲۴ لایه استفاده شده است. لایه خروجی در این مدل پیشنهادی نیز دارای ابعاد ۱×۱ می‌باشد.

۲-۳- روش ترکیبی تحلیل موجک و شبکه عصبی کانولوشنی (W-CNN)

وجود نوفه در داده‌های ورودی باعث ایجاد خطا در نتایج مدل‌سازی جریان خروجی می‌شود و شبکه‌های عصبی توانایی رفع نوفه‌ها را ندارند. استفاده از تحلیل موجک که توانایی رفع نوفه داده‌ها را دارد می‌تواند در خصوص کاهش خطاهای برآورد جریان خروجی سودمند باشد. در این بخش از تحقیق، ابتدا معادلات حاکم بر تحلیل موجک بررسی می‌شود. توابع مادر مورد استفاده در تبدیل موجک یکی از تحولات ریاضی کارآمد در زمینه پردازش سیگنال است. موجک‌ها توابع ریاضی هستند که یک فرم داده را در مقیاس زمانی برای تحلیل سری داده‌ها شامل متغیرها و غیر متغیرها ارائه می‌دهند. تحلیل موجک استفاده از فواصل زمانی طولانی برای اطلاعات فرکانس پایین و فواصل کوتاه‌تر برای اطلاعات فرکانس بالا را فراهم می‌کند. این تحلیل می‌تواند جنبه‌های مختلف داده‌های نقاط شکست و ناپیوستگی‌ها را نشان دهد که سایر روش‌های تحلیل سیگنال

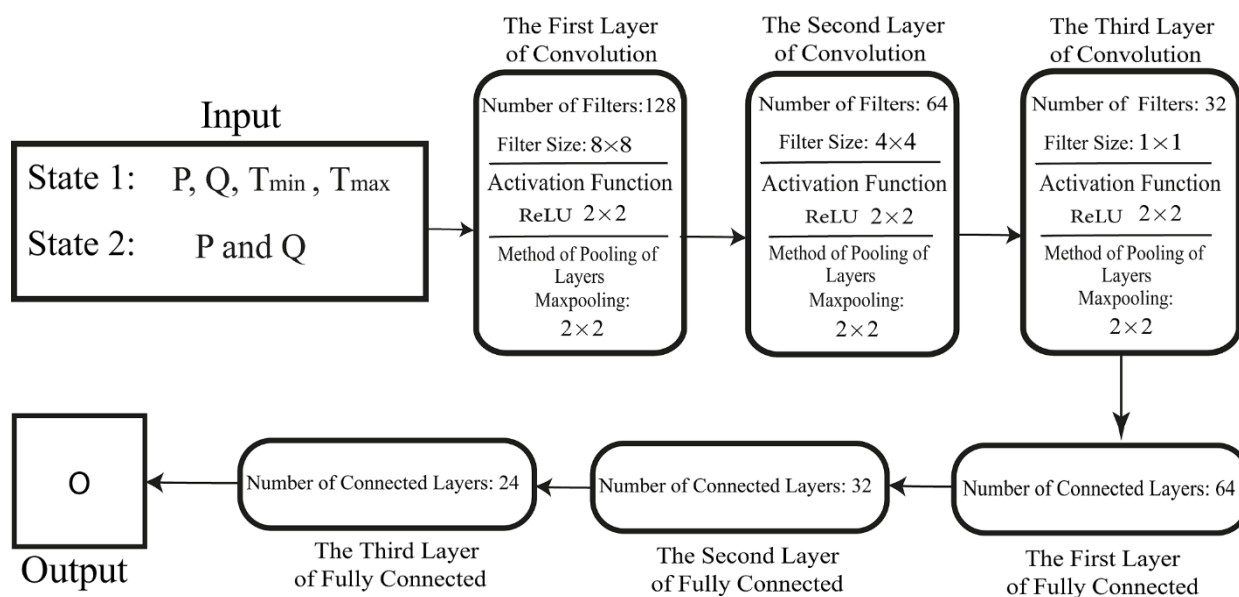


Fig. 2- The proposed model of CNN method for estimation in the present study
شکل ۲- مدل پیشنهادی در روش CNN برای برآورد جریان خروجی در تحقیق حاضر

۳-۳- روش شبکه عصبی چند لایه پرسپترون

یکی از متداول ترین شبکه‌های عصبی موجود، شبکه عصبی پرسپترون چندلایه موسوم به مدل MLP است که عملکرد مغز انسان را شبیه‌سازی کرده و در پیش‌بینی و حل مسائل غیرخطی استفاده می‌شود (Nourani et al., 2009). آموزش این شبکه‌ها با استفاده از الگوریتم معروف پس انتشار خطا^{۲۰} (BP) صورت می‌پذیرد. الگوریتم پس انتشار خطا، بردار ورودی به شبکه پرسپترون چند لایه اعمال نموده و تأثیراتش را از طریق لایه‌های پنهان، به لایه خروجی انتشار می‌دهد (Nourani et al., 2009). در این تحقیق جهت برآورد جریان خروجی از حوضه روش MLP استفاده شده است که لایه پنهان آن دارای سه نرون است. در این بخش دو حالت جهت ورودی به روش MLP در نظر گرفته شده است. در حالت اول ورودی‌ها شامل بارندگی، دمای بیشینه و کمینه و دبی ورودی به حوضه می‌باشد در حالت دوم برآورد جریان خروجی، داده‌های ورودی به حوضه بارندگی و دبی ورودی می‌باشد.

۳-۴- تولید داده‌های ورودی با ایجاد تأخیر

در این تحقیق جهت افزایش داده‌های ورودی به روش‌های مدل‌سازی در دمای بیشینه و کمینه و بارندگی، تأخیر یک ماهه، دو ماهه و سه ماهه ایجاد می‌شود. روش‌های MLP، CNN و WCNN که داده‌های ورودی دارای تأخیر بر آن اعمال می‌شود به ترتیب با عنوان MLPT^{۲۱}، CNNT^{۲۲} و WCCNT^{۲۳} نام‌گذاری می‌شوند. (به عنوان مثال: CNNT2، به معنای روش شبکه عصبی کانولوشنی با تأخیر زمانی دو ماهه می‌باشد). در این تحقیق تأخیر تا سه ماه در نظر گرفته شده است. در جدول ۱ تمامی روش‌های استفاده شده در این تحقیق با نام مخفف و حالت‌های داده‌های ورودی آنها نشان داده شده است. در جدول ۱ دو نوع حالت برای داده‌های ورودی ذکر شده است. حالت اول شامل پارامترهای T_{max} ، T_{min} ، P و Q می‌باشد و حالت دوم شامل پارامترهای P و Q ، که دمای کمینه و بیشینه حذف شده است. هدف اصلی از این دو حالت ورودی برای روش‌های مورد استفاده در این مطالعه بررسی تأثیر دما در برآورد جریان خروجی می‌باشد.

۴- ارزیابی روش‌ها

جهت ارزیابی نتایج برآورد جریان خروجی توسط روش‌های CNN، MLP و WCNN در این تحقیق از ضریب همبستگی (R)، ریشه میانگین مربعات خطا^{۲۴} (RMSE)، ضریب نش-سانکلیف^{۲۵} (NS) و انحراف معیار (SD) به ترتیب مطابق روابط (۸)، (۹)، (۱۰) و (۱۱) استفاده شده است (Mehrpour and Asghari, 2018).

$\Psi^*(x)$ مزدوج مختلط $\Psi(x)$ بوده و با گسترش $\Psi(x)$ در محدوده a و b ، $\Psi_{a,b}(x)$ به دست می‌آید. تبدیل موجک، $f(x)$ را در سطوح مختلف تجزیه می‌کند. طبق معادله (۵)، سیگنال اصلی $f(x)$ با استفاده از تبدیل معکوس، $W_f(a,b)$ و $\Psi_{a,b}(x)$ بازسازی می‌شود.

(۵)

$$f(x) = \frac{1}{\int_{-\infty}^{+\infty} \frac{|\psi(\omega)|}{|\omega|^2} d\omega} \times \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \frac{1}{a^2} W_f(a,b) \Psi_{a,b}(x) da db$$

در تحلیل سیگنال، شکل دیگری از تبدیل موجک به نام تبدیل موجک گسسته^{۱۹} (DWT) نیز استفاده می‌شود. پارامترهای انتقال و مقیاس به صورت ناپیوسته به شرح معادله (۶) انتخاب می‌شوند و k ، j اعداد صحیح هستند. در نتیجه، معادله (۷) با قرار دادن a ، b ایجاد می‌شود.

$$b=2^j k, a=2^j \quad (۶)$$

$$\Psi_{j,k}(x) = 2^{\frac{j}{2}} \Psi[2^j x - k] \quad (۷)$$

DWT برای پیش پردازش و تحلیل داده‌ها مناسب‌تر از CWT است. این روش هیچ اجزای اضافی ندارد، بنابراین می‌توان برای هر مجموعه داده‌ها از DWT استفاده کرد. فرایند تحلیل سیگنال شامل یک یا چند مرحله است که در تجزیه چند مرحله‌ای، پس از اولین مرحله جداسازی با تجزیه قسمت تقریب تحلیل موجک ادامه می‌یابد. موجک‌های Daubechies با عملکرد موجک db3، db4 و Haar با سطوح وضوح مختلف توسط محققان مختلف برای رفع نوفه در پدیده‌های هیدرولوژیک معرفی شدند (Kim et al., 2017; Maheswaran and Khosa, 2012; Nourani et al., 2009; Partovian et al., 2016; Wang and Ding, 2003). جهت برآورد جریان خروجی توسط روش WCNN، ابتدا داده‌های ورودی به شبکه توسط تحلیل موجک رفع نوفه می‌شوند. سپس داده‌ها به عنوان ورودی به شبکه CNN، داده شدند. جهت رفع نوفه داده‌ها از تابع موجک مادر Haar با سطوح ۱ و ۲ و db4 با سطوح وضوح ۲، ۳ و ۴ استفاده می‌شود. به منظور برآورد جریان خروجی در این تحقیق ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای صحت‌سنجی روش‌ها مورد استفاده قرار گرفته و بخش صحت‌سنجی روش‌ها با یکدیگر مقایسه شده است. لازم به ذکر است داده‌های ورودی در این تحقیق نرمال‌سازی شده‌اند؛ اما جهت مقایسه نتایج روش‌ها در بخش صحت‌سنجی، از مقادیر غیر نرمال استفاده شده است.

Table 1- Types of outflow estimation methods with their inputs

جدول ۱- انواع روش‌های برآورد جریان خروجی به همراه ورودی آنها

Type of Method	Input-1	Input-2
CNN		
CNNT1		
CNNT2		
CNNT3	P, T_{max}, T_{min}, Q	P, Q
MLP		
MLPT1		
MLPT2		
MLPT3		
WCNN		
WCNNT1	P, T_{max}, T_{min}, Q	-----
WCNNT2		
WCNNT3		

یک نکته مهم در آموزش ANN نرمال‌سازی داده‌ها قبل از استفاده در مدل‌سازی است. اصولاً ورودی‌های غیرنرمال، دقت ANN را در مدل‌سازی کاهش می‌دهند. ارائه داده‌های ورودی به شبکه یکی از نکات مهم در استفاده از ANNs می‌باشد. این پیش پردازش شامل تبدیل داده‌ها از دامنه تغییرات واقعی آن به دامنه‌ای است که ANN در آن عملکرد بهتری دارد. بسته به نوع تابع فعال‌سازی در شبکه، معمولاً دو نوع دامنه عددی $[0, 1]$ و $[-1, 1]$ به ورودی‌ها اعمال می‌شود (Maheswaran and Khosa, 2012). در این تحقیق مقیاس داده‌های ورودی به شبکه قبل از استفاده توسط معادله (۱۲) به بازه $[0, 1]$ تغییر کرده است. در معادله (۱۲)، مقادیر X_{max} ، X_{min} و X_n به ترتیب داده‌های نرمال شده، مقادیر داده‌های اصلی، داده‌های حداکثر و داده‌های حداقل هستند. لازم به ذکر است در این تحقیق جهت مدل‌سازی از داده‌های نرمال شده و جهت مقایسه نتایج روش‌ها از داده‌های غیر نرمال شده استفاده شده است.

$$X_n = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (12)$$

۵- بررسی نتایج

در این بخش، نتایج تخمین جریان خروجی از حوضه توسط روش‌های MLP، CNN و WCNN مورد بررسی قرار گرفته است. در مرحله اول به بررسی عملکرد روش MLP و تأثیر پارامتر دما در برآورد جریان خروجی توسط این روش پرداخته می‌شود. یکی از دلایلی که نتایج این تحقیق را قابل اطمینان می‌نماید استفاده از ۲۰ اجرا برای هر روش مدل‌سازی است. استفاده از میانگین شاخص‌های ارزیابی در هر روش برآورد جریان باعث می‌شود که از انتخاب سلیقه‌ای نتایج اجتناب شده و همه نتایج ۲۰ اجرا در ارزیابی عملکرد روش‌های مدل‌سازی مؤثر واقع شوند. با توجه به مقادیر \bar{R} ، $RMSE$ و \bar{NS} که در جدول ۲ قابل مشاهده هستند، می‌توان نتیجه گرفت روش MLPT3 در مدل‌سازی جریان خروجی بر حسب بارش، دما و جریان ورودی به حوضه دارای بهترین عملکرد بین انواع حالت‌های MLP می‌باشد. مقادیر \bar{NS} و \bar{R} در روش MLPT3 جهت برآورد جریان خروجی بر حسب بارش، دما و جریان ورودی به ترتیب برابر با ۰/۹۰۹ و ۰/۷۷۰ می‌باشد، در این روش مقادیر $RMSE$ و کمترین مقدار SD برای شاخص‌های ارزیابی به ترتیب برابر (m^3/s) ۱۴/۲۱۰ و ۰/۰۳۴ می‌باشند. حذف دما در برآورد جریان خروجی باعث شد که روش MLP کمترین مقادیر $RMSE$ ، \bar{R} و \bar{NS} به ترتیب (m^3/s) ۱۹/۱۵۸، ۰/۸۰۲ و ۰/۵۰۸ را در بین تمام روش‌ها داشته باشد این نتایج باعث اثبات کارایی ضعیف روش MLP به دلیل حذف دما در مدل‌سازی جریان خروجی شدند. اما نکته مهم و قابل

در هر روش ۲۰ اجرای مختلف انجام شده و برای هر اجرا شاخص‌های ارزیابی محاسبه شده و در انتها، میانگین شاخص‌ها به صورت \bar{R} ، $RMSE$ و \bar{NS} جهت مقایسه کارایی روش‌های مختلف در نظر گرفته شده است. در ادامه تحقیق برای تعیین میزان پراکندگی نتایج به دست آمده در خصوص برآورد جریان خروجی از شاخص انحراف معیار استفاده شده است. در معادلات زیر، n تعداد داده‌ها، O_i^0 داده‌های برآورد شده و O_i داده‌های اندازه‌گیری شده هستند. هرچه مقدار \bar{NS} و \bar{R} نزدیک به یک باشند، کارایی بهتر و دقیق‌تر روش‌ها را در برآورد جریان خروجی نشان می‌دهد. محدوده تغییرات \bar{NS} بین $-\infty$ تا یک می‌باشد. مقادیر $RMSE$ و انحراف معیار هرچه به صفر نزدیک‌تر باشند کارایی و عملکرد مؤثر روش‌ها را در مدل‌سازی نشان می‌دهند (Mehrparvar and Asghari, 2018).

$$R = \frac{\sum_{i=1}^n O_i O_i^0 - \sum_{i=1}^n O_i \sum_{i=1}^n O_i^0 / n}{\sqrt{\sum_{i=1}^n O_i^2 - \left(\sum_{i=1}^n O_i\right)^2 / n} \sqrt{\sum_{i=1}^n (O_i^0)^2 - \left(\sum_{i=1}^n O_i^0\right)^2 / n}} \quad (8)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - O_i^0)^2}{n}} \quad (9)$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - O_i^0)^2}{\sum_{i=1}^n (O_i - \sum_{i=1}^n O_i / n)^2} \quad (10)$$

$$SD = \sqrt{\frac{\sum_{i=1}^n (R_i - \bar{R})^2}{n-1}} \quad (11)$$

توجه این است که در روش‌های MLP، MLPT1 و MLPT2 حذف دما بر نتایج مدل‌سازی اثر داشته است و کاهش شاخص‌های ارزیابی نسبت به حالتی که دما نیز در برآورد جریان خروجی لحاظ شود در حدود سه درصد می‌باشد. اما در روش MLPT3 تأثیر حذف دما در شاخص‌های ارزیابی تأثیر چندانی نداشته است. از بررسی نتایج مربوط به مدل‌سازی جریان خروجی با روش MLP می‌تواند نتیجه گرفت که پارامتر دما در برآورد جریان خروجی مؤثر می‌باشد و افزایش داده‌ها توسط ایجاد تأخیر در داده‌های ورودی می‌تواند نتایج مدل‌سازی را بهبود بخشد. تأثیر افزایش داده‌ها در هر دو حالت برآورد جریان خروجی چه با حذف دما و چه با مشارکت دما در بهبود نتایج مدل‌سازی مشهود است. اما ایجاد تأخیر در داده‌ها باعث افزایش داده‌ها بوده که این موضوع خود نوعی شرط و محدودیت برای روش MLP می‌باشد؛ زیرا ایجاد تعداد تأخیرها در داده‌ها باید مطابق با شرایط فصلی و حوضه آبریز باشد و به هر میزانی قابل قبول نمی‌باشد و توجیه‌پذیر نخواهد بود. پس باید روش‌هایی را در مدل‌سازی به کار برد که دارای محدودیت‌های کمتری باشند.

در ادامه بررسی نتایج تحقیق حاضر، از مقایسه عملکرد روش MLP و CNN در برآورد جریان خروجی برحسب بارش، دما و جریان ورودی به حوضه، می‌توان برتری و توانایی روش CNN را نتیجه گرفت. مطابق جدول ۲، روش CNN در حالتی که دما در مدل‌سازی لحاظ شده است دارای شاخص‌های \overline{RMSE} ، \bar{R} و \overline{NS} به ترتیب (m³/s) ۱۶/۷۷، ۰/۸۷۰ و ۰/۵۷۹ می‌باشد که نسبت به روش MLP شاخص‌های ارزیابی \bar{R} و \overline{NS} به ترتیب تا حدود شش و سی و دو درصد افزایش و شاخص \overline{RMSE} در حدود یازده درصد کاهش داشته‌اند. نتایج به دست آمده برتری و کارایی روش CNN را در مدل‌سازی نسبت به روش MLP نشان می‌دهد. نتایج به دست آمده از بررسی عملکرد انواع حالت‌های CNN، نشان می‌دهد که روش CNNT3 بهترین نتایج را در برآورد جریان خروجی برحسب بارش و دما دارا می‌باشد.

نتایج مدل‌سازی در جدول ۲، نشان‌دهنده برتری روش CNNT3 با شاخص‌های ارزیابی \overline{RMSE} ، \bar{R} و \overline{NS} به ترتیب (m³/s) ۱۴/۲۰، ۰/۹۲۲ و ۰/۷۷۲ است. شاخص‌های ارزیابی \bar{R} و \overline{NS} در روش CNNT3 نسبت به روش CNN، به ترتیب شش و سی و سه درصد افزایش و \overline{RMSE} در حدود پانزده درصد کاهش را نشان می‌دهند که دلیلی بر کارایی و دقت روش CNNT3 در برآورد جریان خروجی در حضور پارامتر دما در مدل‌سازی است. لازم به ذکر است کاهش \bar{R} ، \overline{NS} و افزایش \overline{RMSE} نشان‌دهنده عدم کارایی و کاهش دقت روش‌ها در

مدل‌سازی می‌باشد. مقادیر SD برای شاخص‌های ارزیابی در روش‌های MLP و CNN نزدیک به صفر است که نشان از عدم پراکندگی نتایج است و موجب دستیابی به نتایج قابل اعتمادی جهت برآورد جریان خروجی می‌شود. در بین شاخص‌های ارزیابی، \overline{NS} بیشترین تغییرات روش‌های مدل‌سازی این تحقیق را نشان می‌دهد. حال آن که کدام شاخص ارزیابی کارایی بهتری در بررسی عملکرد روش‌های برآورد جریان خروجی دارند مسأله‌ای است که به متغیرهای درگیر در فرمول‌ها و روش محاسبه اولیه شاخص ارزیابی برمی‌گردد و قضاوت در این مورد فقط به صورت موردی امکان دارد و در حالت کلی نمی‌توان نتیجه‌گیری خاصی نمود. در این تحقیق ابتدا شاخص ارزیابی \overline{NS} بعد \overline{RMSE} و در مرحله آخر \bar{R} توانستند برتری‌ها و تفاوت‌های عملکرد روش‌های مدل‌سازی جریان خروجی را به منظور انتخاب بهترین روش نشان دهند.

کارایی روش‌های CNN و CNNT با حذف پارامتر دما در برآورد جریان خروجی تنزل پیدا کرده است. با بررسی شاخص‌های ارزیابی در روش‌های CNN و CNNT1 می‌توان دریافت که حذف دما در برآورد جریان خروجی، بیشترین تأثیر را در شاخص ارزیابی \overline{NS} داشته است. با حضور دما، مقادیر \overline{NS} در روش‌های CNN و CNNT1 به ترتیب در حدود صد و یک و صد و هفت درصد نسبت به شرایطی که پارامتر دما در برآورد جریان خروجی حذف شده، افزایش یافته است. شاخص‌های ارزیابی \bar{R} با حذف دما در روش CNN جهت مدل‌سازی به ترتیب در حدود هشت درصد کاهش و \overline{RMSE} در حدود هفتاد و هشت درصد افزایش و در روش CNNT1، \bar{R} شش درصد کاهش و \overline{RMSE} شصت و دو درصد افزایش داشته‌اند. ولی حذف دما در برآورد جریان خروجی باعث شد که شاخص‌های ارزیابی \bar{R} و \overline{NS} در روش CNNT2 به ترتیب تا پنج و سی و سه درصد و در روش CNNT3 به ترتیب چهار و هشت درصد کاهش یافتند. شاخص \overline{RMSE} در اثر حذف دما در روش‌های CNNT2 و CNNT3 به ترتیب بیست و یک و هفت درصد افزایش داشته است. مطابق نتایج به دست آمده و بررسی عملکرد روش‌های CNN و MLP می‌توان دریافت تأثیر حذف دما در روش‌های CNN و CNNT نسبت به روش MLP بیشتر بوده است. دلیل اصلی تأثیر منفی حذف دما در روش‌های CNN و CNNT1 به ساختار و معماری روش CNN مربوط می‌شود. کاهش داده‌های ورودی در روش CNN بسیار تأثیرگذار می‌باشد. حتی معماری و انتخاب تعداد لایه‌های کانولوشن، تعداد فیلترها و تعداد لایه اتصال کامل نیز به تعداد داده‌های ورودی وابسته می‌باشد. با حذف دما، داده‌های ورودی به CNN و CNNT کاهش یافته است و باعث ناکارآمدی CNN در مدل‌سازی شده است. در روش CNNT با اعمال تأخیر در داده‌های

مدل‌سازی جریان خروجی با روش CNN اعلام می‌نماید که برای افزایش کارایی و دقت روش CNN در مدل‌سازی جریان خروجی باید کمبود داده‌هایی مانند بارندگی، تبخیر، جنس خاک و توپوگرافی حوضه برطرف گردد. (Van et al., 2020) نیز از روش CNN و انواع تأخیرها در برآورد جریان خروجی بر حسب بارش استفاده نموده‌اند. ایشان این روش را در برآورد جریان خروجی مؤثر معرفی کرده‌اند. در تحقیق حاضر نیز تأثیر مثبت افزایش تعداد داده‌های ورودی بر برآورد جریان خروجی به دلیل تأخیرهای ایجاد شده و در نظر گرفتن پارامتر دما کاملاً مشهود است.

در ادامه این تحقیق مقادیر R برای ۲۰ اجرا جهت برآورد جریان خروجی بر حسب ورودی بارندگی، دمای کمینه و بیشینه و دبی ورودی به حوضه توسط روش CNN و WCNN با انواع موجک مادر در این تحقیق محاسبه گردید. جدول ۳ نتایج برآورد جریان خروجی در روش‌های CNN و WCNN را نشان می‌دهد. بهترین عملکرد در مدل‌سازی با \bar{R} برابر با ۰/۹۱۴، \overline{NS} برابر با ۰/۶۷۰، \overline{RMSE} برابر با $11/57 (m^3/s)$ و کمترین SD برابر ۰/۲۰ مربوط به روش WCNN-db42 می‌باشد.

شاخص‌های ارزیابی \bar{R} و \overline{NS} در روش WCNN-db42 نسبت به CNN به ترتیب در حدود پنج درصد و شانزده درصد افزایش داشته و شاخص \overline{RMSE} در حدود سی و یک درصد کاهش را نشان می‌دهد.

بارش حتی با حذف دما تا حدودی شاخص \overline{NS} بهبود یافت. افزایش داده‌های ورودی با اعمال تأخیر دو ماهه در بارش حتی در غیاب پارامتر دما تأثیر زیادی در کارایی مدل‌سازی جریان خروجی توسط روش CNNT2 نسبت به روش‌های CNN و CNNT1 داشته است.

ساختار شبکه CNN مانند MLP دارای لایه ورودی، لایه میانی و لایه خروجی است. در MLP فقط می‌توان تعداد لایه‌های میانی را تغییر داد ولی در روش CNN در لایه میانی امکان تغییر تعداد لایه‌های کانولوشنی، تعداد و ابعاد فیلترها در هر لایه و امکان استفاده از توابع ادغام در هر لایه جهت افزایش دقت مدل‌سازی امکان‌پذیر است. حتی در روش CNN تغییر تعداد و ابعاد لایه‌های اتصال کامل ممکن می‌باشد. وجود لایه‌های متعدد و پردازش چند مرحله‌ای داده‌ها در روش CNN باعث عملکرد بهتر و کارایی مؤثر این روش در مدل‌سازی جریان خروجی می‌گردد.

در این تحقیق، در همه حالت‌ها در روش‌های MLP و CNN تأثیر دما بر خروجی محاسباتی قابل تشخیص است. در حالی‌که (Van et al., 2020) با توجه به تحقیقات خود، به عدم تأثیر دما بر افزایش دقت برآورد جریان خروجی معتقد هستند. محققان مختلف اعتقاد دارند در برآورد جریان خروجی فقط بر حسب بارش می‌توان نتایج دقیقی را ارائه نمود (Anctil et al., 2004; Nourani, 2017; Van et al., 2020). اما (Song (2022) در تحقیق خود در خصوص

Table 2- Results obtained from CNN and MLP methods used to estimate outflow
جدول ۲- نتایج به دست آمده از روش‌های CNN و MLP جهت برآورد جریان خروجی

Type of Method	Input-1 P, T _{max} , T _{min} , Q						Input-2 P, Q					
	\bar{R}	SD for R	\overline{RMSE} ($\frac{m^3}{s}$)	for SD RMSE	\overline{NS}	SD for NS	\bar{R}	for SD R	\overline{RMSE} ($\frac{m^3}{s}$)	SD for RMSE	\overline{NS}	SD for NS
MLP	0.819	0.069	18.810	3.560	0.437	0.350	0.802	0.045	19.185	2.630	0.508	0.118
MLPT1	0.874	0.029	16.540	2.395	0.615	0.233	0.850	0.052	18.220	2.915	0.599	0.194
MLPT2	0.897	0.031	15.480	2.390	0.755	0.095	0.861	0.032	17.314	2.792	0.500	0.347
MLPT3	0.909	0.035	14.210	2.610	0.770	0.106	0.908	0.034	13.826	2.500	0.764	0.117
CNN	0.870	0.026	16.770	2.480	0.579	0.128	0.803	0.029	29.710	3.610	-53.08	30.95
CNNT1	0.880	0.030	16.100	2.570	0.670	0.104	0.830	0.042	26.020	6.610	-10.20	14.62
CNNT2	0.908	0.027	14.350	3.090	0.746	0.147	0.861	0.032	17.310	2.810	0.500	0.347
CNNT3	0.922	0.018	14.200	2.310	0.772	0.090	0.888	0.022	15.230	2.060	0.707	0.094

تحقیق افزایش سطح و وضوح تابع موجک مادر باعث افزایش دقت برآورد شد؛ اما افزایش سطح و وضوح تابع موجک مادر تا حدی ادامه داده شده است که داده‌ها شکل و ساختار اصلی خود را از دست ندهند. موجک مادر Daubechies بهتر از موجک مادر Haar در رفع نوفه جهت برآورد جریان خروجی عمل نموده است.

در بخش آخر این تحقیق، بهترین روش از زیر مجموعه WCNN جهت اعمال تأخیرهای یک، دو و سه ماهه در داده‌های ورودی بارندگی، دمای بیشینه و کمینه انتخاب می‌شود. با توجه به این موضوع که تابع موجک مادر Daubechies با سطح ۴ و وضوح ۲ در بخش بررسی روش WCNN بهترین نتیجه را در برآورد جریان خروجی ارائه نموده، در این بخش نیز تأخیرها بر روش WCNNdb42 اعمال شده‌اند.

بهترین عملکرد در برآورد جریان خروجی با توجه به نتایج جدول ۴ مربوط به روش WCNNdb42 است که دارای شاخص‌های \overline{RMSE} ، \overline{R} و \overline{NS} به ترتیب برابر $0.9/45$ ، $0.9/45$ و 0.860 است. با مقایسه شاخص‌های ارزیابی روش WCNNdb42 نسبت به روش WCNNdb42 این نتیجه حاصل می‌شود که \overline{R} و \overline{NS} به ترتیب در حدود سه و نیم و بیست و نه درصد افزایش و \overline{RMSE} کاهش در حدود هجده و نیم درصد داشته‌اند.

این تغییرات در مقادیر شاخص‌های ارزیابی، دلیل خوبی بر برتری عملکرد روش WCNNdb42 است. شاخص‌های ارزیابی \overline{R} و \overline{NS} در روش WCNNdb42 نسبت به روش CNN به ترتیب در حدود نه درصد و چهل و نه درصد افزایش داشته‌اند.

میزان بهبود شاخص‌های ارزیابی در روش WCNNdb42 نشان از عملکرد بهتر و کارایی مؤثر این روش نسبت به روش‌های دیگر در مدل‌سازی جریان خروجی دارد. نکته قابل توجه در بررسی عملکرد روش WCNNdb42 نسبت به روش CNNT3 می‌باشد؛ زیرا \overline{R} ، \overline{RMSE} و \overline{NS} به ترتیب در حدود یک درصد افزایش، نوزده درصد کاهش و سیزده درصد افزایش داشته‌اند. شاخص \overline{R} در هر دو روش تقریباً مساوی است، در حالی که شاخص \overline{RMSE} نشان از برتری کارایی روش WCNNdb42 نسبت به CNNT3 دارد و شاخص \overline{NS} دلیلی بر برتری عملکرد روش CNNT3 نسبت به WCNNdb42 است. در سخت‌گیرانه‌ترین حالت قضاوت در خصوص انتخاب بهترین روش مدل‌سازی، می‌توان هر دو روش را دارای عملکردی مشابه و یکسان معرفی نمود. در روش WCNNdb42 باید از ترکیب تحلیل موجک و روش CNN جهت مدل‌سازی بهره گرفت. انتخاب تابع موجک مادر نیز خود نیازمند سعی و خطا می‌باشد که این مراحل باعث طولانی‌تر شدن مسیر مدل‌سازی و امکان افزایش خطا در مدل‌سازی می‌گردد. در حالی که روش CNNT3 فقط با ایجاد تأخیر در داده‌های ورودی و با استفاده از قابلیت و ساختار مناسب روش CNN توانسته است این عملکرد مؤثر را در مدل‌سازی جریان خروجی ارائه نماید.

نتایج این تحقیق نشان می‌دهند که تحلیل موجک باعث افزایش دقت در نتایج برآورد جریان خروجی توسط روش CNN می‌شود. محققان مختلف در تحقیقات خود به این نکته اشاره کرده‌اند که در تحلیل موجک، افزایش سطح و وضوح تابع موجک مادر در بهبود نتایج مؤثر است (Mosavi et al., 2018; Nourani and Komasi, 2013; Nourani and Molajou, 2017; Sharghi et al., 2019).

Table 3- Results obtained from CNN and WCNN methods used to estimate outflow
جدول ۳- نتایج به دست آمده از روش‌های CNN و WCNN

Type of Method	Mother Wavelets	\overline{R}	SD for R	\overline{RMSE} ($\frac{m^3}{s}$)	for SD RMSE	\overline{NS}	SD for NS
CNN	-----	0.870	0.026	16.770	2.480	0.579	0.128
	Haar1	0.876	0.028	15.393	2.72	0.527	0.041
	Haar2	0.877	0.044	15.110	2.760	4.050	6.06
WCNN	db42	0.914	0.020	11.570	1.720	0.670	0.180
	db43	0.875	0.036	7.670	0.850	0.603	0.172
	db44	0.891	0.037	5.625	1.150	0.633	0.310

Table 4- Results obtained from WCNT methods used to estimate outflow

جدول ۴- نتایج به دست آمده از روش‌های WCNT

Type of Method	\bar{R}	SD for R	\overline{RMSE} ($\frac{m^3}{s}$)	SD for RMSE	\overline{NS}	SD for NS
WCNN-db42	0.914	0.020	11.570	1.720	0.670	0.180
WCNNT1-db42	0.924	0.015	10.673	1.454	0.798	0.059
WCNNT2-db42	0.931	0.013	10.392	1.010	0.830	0.036
WCNNT3-db42	0.945	0.012	9.450	1.160	0.863	0.037

عامل، معماری روش CNN است. لایه‌های میانی روش CNN بیشتر از MLP می‌باشند که این ساختار باعث افزایش دقت برآورد جریان خروجی می‌شود. ساختار CNN به گونه‌ای است که داده‌ها در لایه‌های کانولوشن که در هر لایه امکان تغییر تعداد و ابعاد فیلترها و توابع ادغام وجود دارد مورد پردازش قرار می‌گیرند. در مرحله بعد داده‌ها وارد لایه‌های اتصال کامل می‌شوند و مدل‌سازی جریان خروجی در روش CNN در لایه خروجی تکمیل می‌شود. بخش لایه‌های اتصال کامل در روش CNN خود دارای ساختاری مشابه لایه‌های میانی روش MLP می‌باشد. می‌توان گفت روش MLP خود بخشی از روش CNN است که با عنوان لایه‌های اتصال کامل معرفی شده است. دومین عامل، استفاده از تحلیل موجک است که باعث کاهش نوفه داده‌ها شده است. سومین عامل مؤثر در بهترین عملکرد برآورد جریان خروجی توسط روش WCNNT3-db42، ایجاد تأخیر در داده‌های ورودی می‌باشد که باعث افزایش تعداد داده‌های ورودی شده است. با این وجود دستاورد مهم در این تحقیق آن است که روش CNNT3 در برآورد جریان خروجی دارای عملکردی تقریباً یکسان با روش WCNN-db42 است که این موضوع نشان دهنده دقت و کارایی مناسب روش CNNT است و با توجه به آن که به کارگیری تحلیل موجک نیازمند رعایت نکات فنی خاص و انجام سعی و خطا برای یافتن سطح تجزیه مناسب است، شبکه کانولوشنی می‌تواند جایگزین مناسبی برای آن در برآوردهای هیدرولوژیک باشد.

همچنین این شاخص‌ها در روش WCNNT3-db42 نسبت به روش MLP به ترتیب در حدود پانزده و نیم درصد و نود و هشت درصد افزایش را نشان می‌دهند. شاخص ارزیابی \overline{RMSE} در روش WCNNT3-db42 نسبت به روش‌های CNN و MLP به ترتیب در حدود چهل و چهار درصد و پنجاه درصد کاهش داشته است. بررسی نتایج این تحقیق نشان می‌دهد افزایش تعداد داده‌ها به دلیل تأخیرهای ایجاد شده، کاهش نوفه توسط تحلیل موجک و توانایی روش CNN در مدل‌سازی باعث می‌شوند که روش WCNNT3-db42 بهترین نتایج را در برآورد جریان خروجی برحسب بارش، دما و جریان ورودی به حوضه را ارائه نماید.

۶- جمع‌بندی

در این تحقیق، برآورد جریان خروجی از حوضه آبریز بر حسب بارندگی، دمای بیشینه و کمینه و جریان ورودی به حوضه با روش‌های مختلف انجام شده است. با توجه به ماهیت تصادفی تخصیص داده‌های آموزش و ارزیابی، هر روش به تعداد ۲۰ بار اجرا شده و از میانگین مقادیر ضریب همبستگی بین داده‌های مشاهداتی و پیش‌بینی جهت مقایسه عملکرد روش‌های مختلف استفاده شده است. به طور کلی نتایج نشان می‌دهند به کارگیری دمای بیشینه و کمینه و همچنین تأخیرهای داده‌های دما و بارش، دقت برآورد جریان خروجی را بهبود می‌دهد. همچنین استفاده از روش CNN و CNNT باعث برآورد دقیق‌تر جریان خروجی نسبت به روش MLP می‌شود. علت این موضوع، وجود یک ساختار لایه‌ای و عمیق در روش CNN است. در ادامه مشخص شد استفاده از تحلیل موجک جهت حذف نوفه قبل از شبکه کانولوشنی (WCNNT) باعث می‌شود برآورد جریان خروجی از حوضه نسبت به CNN و MLP دارای دقت بیشتری باشد. در انتخاب بهترین روش جهت برآورد جریان خروجی سه عامل مهم تأثیرگذار بوده است. اولین

پی نوشتها

- 1- Artificial Neural Network
- 2- Combined Methods of Wavelet Analysis and Artificial Neural Network
- 3- Convolutional Neural Network
- 4- Multi-Layer Perceptron
- 5- Partial Mutual Information
- 6- Co-Active Neuro Fuzzy Inference System
- 7- Generalized Feed Forward Neural Network
- 8- Modular Neural Network
- 9- Recurrent Neural Network
- 10- Time Lagged Recurrent Neural Network
- 11- Gene Expression Programming
- 12- Surface Flow Features
- 13- Base Flow Features
- 14- Pooling Layer
- 15- Fully Connected Layers
- 16- ReLU Activation Function
- 17- Max Pooling Layer
- 18- Continuous Wavelet Transform
- 19- Discrete Wavelet Transform
- 20- Back-Propagation
- 21- MLP by Time Delay
- 22- CNN by Time Delay
- 23- WCNN by Time Delay
- 24- Root-Mean-Square Deviation
- 25- Nash-Sutcliffe Coefficient

۶- مراجع

- Anctil F, Perrin C, and Andréassian V (2004) Impact of the length of observed records on the performance of ANN and of conceptual parsimonious rainfall-runoff forecasting models. *Environmental Modelling and Software* 19(4):357–368
- Ghorbani MA, Azani A, and Vanolya SM (2015) Rainfall-runoff modeling using hybrid intelligent models. *Journal of Iran-Water Resources Research* 11(2):146-150 (In Persian)
- Hu G, Wang K, Peng Y, Qiu M, Shi J, and Liu L (2018) Deep learning methods for underwater target feature extraction and recognition. *Computational Intelligence and Neuroscience*, doi: 10.1155/2018/1214301
- Kim B, Jeong H, Kim H, and Han B (2017) Exploring wavelet applications in civil engineering. *KSCE Journal of Civil Engineering* 21(4):1076–1086
- Liu Y, Zhang T, Kang A, Li J, and Lei X (2021) Research on runoff simulations using deep-learning methods. *Sustainability (Switzerland)* 13(3):1–20
- Maheswaran R and Khosa R (2012) Comparative study of different wavelets for hydrologic forecasting. *Computers and Geosciences* 46:284–295

- Mehrpour M and Asghari K (2018) Modular optimized data assimilation and support vector machine for hydrologic modeling. *Journal of Hydroinformatics* 20(3):728–738
- Mosavi A, Ozturk P, and Chau KW (2018) Flood prediction using machine learning models: Literature review. *Water (Switzerland)* 10(11):1–40
- Nourani V (2017) An Emotional ANN (EANN) approach to modeling rainfall-runoff process. *Journal of Hydrology, Elsevier B.V.* 544:267–277
- Nourani V and Komasi M (2013) A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. *Journal of Hydrology, Elsevier B.V.* 490:41–55
- Nourani V, Komasi M, and Mano A (2009) A multivariate ANN-wavelet approach for rainfall-runoff modeling. *Water Resources Management* 23(14):2877–2894
- Nourani V and Molajou A (2017) Application of a hybrid association rules/decision tree model for drought monitoring. *Global and Planetary Change* 159:37–45
- Nourani V and Parhizkar M (2013) Conjunction of SOM-based feature extraction method and hybrid wavelet-ANN approach for rainfall-runoff modeling. *Journal of Hydroinformatics* 15(3):829–848
- Partovian A, Nourani V, and Alami MT (2016) Hybrid denoising-jittering data processing approach to enhance sediment load prediction of muddy rivers. *Journal of Mountain Science* 13(12):2135–2146
- Sang YF, Wang D, Wu JC, Zhu QP, and Wang L (2009) Entropy-based wavelet de-noising method for time series analysis. *Entropy* 11(4):1123–1147
- Shafeizadeh M, Fathian H, and Nikbakht AR (2019) Continuous rainfall-runoff simulation by artificial neural networks based on selection of effective input variables using partial mutual information (PMI) algorithm. *Journal of Iran-Water Resources Research* 15(2):144-161 (In Persian)
- Sharghi E, Nourani V, Molajou A, and Najafi H (2019) Conjunction of emotional ANN (EANN) and wavelet transform for rainfall-runoff modeling. *Journal of Hydroinformatics* 21(1):136–152
- Shoab M, Shamseldin AY, Khan S, Sultan M, Ahmad F, Sultan T, Dahri ZH, and Ali I (2019) Input selection of wavelet-coupled neural network models for rainfall-runoff modelling. *Water Resources Management* 33(3):955–973
- Song CM (2022) Data construction methodology for convolution neural network based daily runoff

- prediction and assessment of its applicability. *Journal of Hydrology*, Elsevier B.V. 605:127324
- Van SP, Le HM, Thanh DV, Dang TD, Loc HH, and Anh DT (2020) Deep learning convolutional neural network in rainfall-runoff modelling. *Journal of Hydroinformatics* 22(3):541–561
- Wang W and Ding J (2003) Wavelet network model and its application to the prediction of hydrology. *Nature and Science* 1(1):67–71
- Xu Y, Liu Yi, Jiang, Z and Yang, X (2021) Runoff prediction model based on improved convolutional neural network runoff prediction model based on improved convolutional neural network. *Journal of Water Resources Management*, 1-48, DOI: <https://doi.org/10.21203/rs.3.rs-760130/v1>.