

## مقایسه مدل‌های شبکه عصبی مصنوعی و یادگیری عمیق در مدل‌سازی بارش-رواناب رودخانه کشف‌رود و پیش‌بینی اثر تغییر اقلیم بر پارامترهای هواشناسی و دبی رودخانه

محمد حسین شاهانی<sup>۱</sup>

وحید رضوردی‌نژاد<sup>۲\*</sup>

سید عباس حسینی<sup>۳</sup>

### چکیده

هدف از این تحقیق، مقایسه عملکرد مدل‌های شبکه عصبی مصنوعی (ANN) و شبکه عصبی عمیق (DNN) در مدل‌سازی بارش-رواناب رودخانه کشف‌رود در یکی از سرشاخه‌های دائمی آن و پیش‌بینی اثر تغییر اقلیم بر پارامترهای هواشناسی و دبی رودخانه می‌باشد. بدین منظور عملکرد دو مدل شبکه عصبی پیشخور چند لایه (MLP) و شبکه عصبی کانولوشن (CNN) در مدل‌سازی بارش-رواناب با ورودی‌هایی از بارش و دبی روزانه با تأخیرهای مختلف با یکدیگر مقایسه شد. سپس از پیش‌بینی مدل LARS-WG6 در دوره آبی (۲۰۲۱-۲۰۴۰) در سناریوهای مختلف تغییر اقلیم (RCP26، RCP45 و RCP85) به عنوان ورودی مدل هوش مصنوعی برتر استفاده شده و دبی رودخانه و مقادیر حدی آن پیش‌بینی گردید. یافته‌های تحقیق نشان داد که مدل CNN با ورودی بارندگی با تأخیر صفر تا ۲ روز و دبی رودخانه با تأخیر ۱ روز، بهترین عملکرد را در مدل‌سازی دبی رودخانه داشت. پیش‌بینی‌های LARS-WG6 نشان داد که افزایش حداقل و حداکثر دما در آینده در ماه‌های مختلف در محدوده ۰/۳ تا ۲/۱ درجه سانتیگراد خواهد بود. بارندگی سالانه در همه سناریوهای تغییر اقلیم در آینده افزایش خواهد یافت. بیشترین افزایش بارندگی سالانه در آینده، نسبت به دوره پایه در سناریوی RCP26 به میزان ۱۴٪ خواهد بود و حداکثر دبی در سناریوی مذکور، حدود ۱۸ درصد افزایش خواهد یافت.

### واژه‌های کلیدی

بارش-رواناب، تغییر اقلیم، شبکه عصبی مصنوعی، کشف‌رود، یادگیری عمیق

<sup>۱</sup> دانشجوی دکتری گروه مدیریت ساخت و آب، دانشکده عمران، معماری و هنر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی تهران، ایران

<sup>۲\*</sup> استاد گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران. ایمیل: [v.verdinejad@urmia.ac.ir](mailto:v.verdinejad@urmia.ac.ir)

<sup>۳</sup> استادیار گروه مدیریت ساخت و آب، دانشکده عمران، معماری و هنر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی تهران، ایران

## مقدمه

وضعیت اجتماعی-اقتصادی تعریف می‌کند (مک گوری<sup>۱۵</sup> و همکاران، ۲۰۰۱). جدیدترین سناریوهای تغییر اقلیم، تحت عنوان سناریوهای انتشار RCP<sup>۱۶</sup> (۲۶، ۴۵ و ۸۵ که به ترتیب مطابق با انتشار کم، متوازن و زیاد گازهای گلخانه‌ای هستند) بر اساس گزارش پنجم IPCC منتشر شده (شرافتی و همکاران، ۲۰۲۰) و در آخرین نسخه مدل LARS-WG (نسخه ۶) جهت ریزمقیاس‌نمایی پیش‌بینی پارامترهای هواشناسی در نقاط مختلف جهان قابل استفاده می‌باشند. پیش‌بینی پارامترهای هواشناسی تحت تأثیر تغییر اقلیم، در تحقیقات اخیر در مناطق مختلف جهان نتایج متفاوتی بر اساس اقلیم منطقه و مقیاس زمانی داشته است. ارزیابی اثرات تغییرات اقلیم بر بارش در آینده (۲۰۰۰-۲۰۹۰) در پورتوریکو نشان داد که فصل بارانی، مرطوب‌تر و فصل خشک، خشک‌تر خواهد شد (هارمسن<sup>۱۷</sup> و همکاران، ۲۰۰۹). پیش‌بینی اثرات تغییر اقلیم در سودان نشان داد که بارش در فصول بارانی ژوئن، جولای و آگوست، روند کاهشی در دوره‌های ۲۰۱۱-۲۰۳۰، ۲۰۴۶-۲۰۶۵ و ۲۰۸۰-۲۰۹۹ و روند افزایشی در سپتامبر، اکتبر و نوامبر داشته و دمای حداکثر و حداقل روند افزایشی مداوم خواهند داشت (چن<sup>۱۸</sup> و همکاران، ۲۰۱۳). طبق بررسی‌های انجام شده در میاندوآب، تغییر اقلیم در سال‌های ۲۰۴۶-۲۰۶۵ تأثیر فزاینده‌ای بر دما و تبخیر و تعرق مرجع و اثر کاهشی بر عملکرد گندم زمستانه خواهد داشت (آزاد<sup>۱۹</sup> و همکاران، ۲۰۱۸). پیش‌بینی دما و بارش در حوضه رودخانه شایر در مالاوی، با استفاده از LARS-WG6 نشان داد که افزایش مداوم دما در آینده (۲۰۷۰-۲۰۴۱ و ۲۰۷۱-۲۱۰۰)، در منطقه مورد مطالعه اتفاق خواهد افتاد (کاوونجه<sup>۲۰</sup> و همکاران، ۲۰۲۲).

تغییر اقلیم، در نتیجه افزایش غلظت گازهای گلخانه‌ای در جو، مرهون توسعه‌ی سریع صنعت و بی‌توجهی به مسائل زیست محیطی بوده و در دهه‌های گذشته به یک نگرانی بین‌المللی تبدیل شده است. تغییر اقلیم از طریق تغییر در الگوی دما، بارش و سایر متغیرهای آب و هوایی بر همه فرآیندهای هیدرولوژیک تأثیرگذار است. برای ارزیابی تأثیر تغییر اقلیم بر متغیرهای مختلف آب و هوایی، چندین مدل گردش عمومی (GCMs)<sup>۱</sup> برای پیش‌بینی پارامترهای هواشناسی در آینده، تحت سناریوهای مختلف توسعه داده شده است (استیونز<sup>۲</sup> و همکاران، ۲۰۱۳). با توجه به وضوح نامناسب مکانی خروجی‌های GCM، دقت آن‌ها در مقیاس محلی، پایین بوده و نمی‌توان از آن‌ها بطور مستقیم در پیش‌بینی متغیرهای اقلیمی استفاده کرد و لازم است ریزمقیاس شوند (حیدری تاشه کبود<sup>۳</sup> و همکاران، ۲۰۲۰؛ شرافتی و پزشکی<sup>۴</sup>، ۲۰۲۰؛ شرافتی<sup>۵</sup> و همکاران، ۲۰۲۰). مدل LARS-WG<sup>۶</sup> یکی از مولدهای اقلیمی جهت ریزمقیاس‌نمایی<sup>۷</sup> خروجی مدل‌های گردش عمومی است که به‌طور گسترده برای تولید متغیرهای آب و هوایی و پیش‌بینی آنها، برای دوره‌های آینده بر اساس سناریوهای مختلف تغییر اقلیم در مناطق مختلف استفاده می‌شود (سمنینو<sup>۸</sup> و همکاران، ۱۹۹۸؛ سمنینو و بروکس<sup>۹</sup>، ۱۹۹۹؛ لی و شریف<sup>۱۰</sup>، ۲۰۱۵؛ ژو<sup>۱۱</sup> و همکاران، ۲۰۱۶؛ صادقی<sup>۱۲</sup> و همکاران، ۲۰۱۹؛ شرافتی و همکاران، ۲۰۲۰؛ سیلاخوری<sup>۱۳</sup> و همکاران، ۲۰۲۲).

هیئت بین‌الدول تغییر اقلیم (IPCC)<sup>۱۴</sup>، مجموعه‌ای از سناریوهای تغییر اقلیم را بر اساس طیف وسیعی از تغییرات احتمالی در انتشار گازهای گلخانه‌ای آینده، جمعیت و

<sup>12</sup> Saddique

<sup>13</sup> Silakhori

<sup>14</sup> Intergovernmental Panel on Climate Change

<sup>15</sup> McGuire

<sup>16</sup> Representative Concentration Pathway (RCP) emission scenarios

<sup>17</sup> Harmsen

<sup>18</sup> Chen

<sup>19</sup> Azad

<sup>20</sup> Kavwenje

<sup>1</sup> General Circulation Models

<sup>2</sup> Stevens

<sup>3</sup> Heydari Tasheh Kabood

<sup>4</sup> Sharafati and Pezeshki

<sup>5</sup> Sharafati

<sup>6</sup> Long Ashton Research Station Weather Generator

<sup>7</sup> Downscaling

<sup>8</sup> Semenov

<sup>9</sup> Semenov and Brooks

<sup>10</sup> Le and Sharif

<sup>11</sup> Zhu

جهت برنامه‌ریزی و مدیریت منابع آب برای مقابله با پیامدهای آن در آینده ضروری است.

مدل‌های فرایند محور مذکور، علیرغم قابلیت بالایی که در شبیه‌سازی فرآیند پیچیده هیدرولوژیک دارند، جهت مدلسازی دقیق، نیازمند تعیین تعداد زیادی پارامتر در شبیه‌سازی فرآیند هیدرولوژیک می‌باشند (کورجیالاس<sup>۶</sup> و همکاران، ۲۰۱۵). ولی روش‌های داده‌محور نیازمند پارامترهای ورودی کمتر، زمان محاسباتی کوتاه‌تر و مدیریت ساده‌تر داده‌ها هستند (کورجیالاس و همکاران، ۲۰۱۵).

اخیراً هوش مصنوعی (AI)، توجه زیادی را در مدل‌سازی پارامترهای هواشناسی و هیدرولوژیک به خود جلب کرده است که قابلیت و عملکرد مناسب آن‌ها در مطالعات مختلف مدلسازی دبی رودخانه با استفاده از محدوده گسترده‌ای از مدل‌های ساده و معروف ANN<sup>۸</sup> تا تکنیک‌های پیشرفته‌تر یادگیری عمیق (DL)<sup>۹</sup> به اثبات رسیده است (کلتله<sup>۱۰</sup>، ۲۰۱۳؛ بزرگ حداد<sup>۱۱</sup> و همکاران، ۲۰۱۶؛ ون<sup>۱۲</sup> و همکاران، ۲۰۲۰؛ حسین<sup>۱۳</sup> و همکاران، ۲۰۲۰؛ لی<sup>۱۴</sup> و همکاران، ۲۰۲۱). مدل‌های هوش مصنوعی، از جمله روش‌های داده محور هستند که در تحقیقات اخیر با موفقیت جایگزین مدل‌های هیدرولوژیک در پیش‌بینی دبی رودخانه در آینده تحت تأثیر تغییر اقلیم در ترکیب با مدل‌های ریزمقیاس-نمایی شده‌اند که در آن‌ها از ورودی‌های مختلف بارش، پارامترهای هواشناسی و دبی رودخانه با تأخیرهای مختلف به عنوان ورودی مدل هوش مصنوعی استفاده شده است (کورجیالاس و همکاران، ۲۰۱۵؛ سرزعی<sup>۱۵</sup> و همکاران، ۲۰۱۷). هدف اصلی این مطالعه، پیش‌بینی تأثیر تغییر اقلیم بر دبی یکی از شاخه‌های دائمی رودخانه کشف‌رود در استان خراسان رضوی با ترکیب مدلسازی بارش-رواناب هوش مصنوعی و LARS-WG6 است. در این راستا، تأثیر تغییر

تغییر دما تحت تأثیر تغییر اقلیم، می‌تواند موجب تغییرات مکانی و زمانی تبخیر و تعرق، نوع بارش (برف یا بارندگی)، شدت، الگوهای رویدادهای حدی و مقدار تجمع یا ذوب برف و یخ شده و در نتیجه با تغییر منابع آب و دبی رودخانه، سبب ایجاد سیل در برخی مناطق یا خشکسالی‌های طولانی مدت/شدید در نقاط دیگر شود (نیجسن<sup>۱</sup> و همکاران، ۲۰۰۱؛ ییمر<sup>۲</sup> و همکاران، ۲۰۰۹؛ لی و شریف، ۲۰۱۵؛ حیدری تاشه کبود و همکاران، ۲۰۲۰؛ سیلاخوری و همکاران، ۲۰۲۲؛ شرافتی و پزشکی، ۲۰۲۰؛ شرافتی و همکاران، ۲۰۲۰).

جهت بررسی اثرات تغییر اقلیم بر دبی رودخانه در آینده، استفاده از پیش‌بینی‌های مدل‌های اقلیمی به عنوان ورودی مدل‌های هیدرولوژیک به‌طور گسترده در مطالعات اخیر مورد توجه قرار گرفته است. از جمله این مطالعات، می‌توان به استفاده از مدل‌های هیدرولوژیک CLHMS، SWAT، ARNO، JHACRES برای مدل‌سازی جریان رودخانه در ویتنام مرکزی (لی و شریف، ۲۰۱۵)، حوضه رودخانه زرد در چین (ژو و همکاران، ۲۰۱۶)، حوضه مگنا-بنگلادش (مسعود و تاکیوچی<sup>۳</sup>، ۲۰۱۶)، حوضه رودخانه جلوم در شمال پاکستان (صادیق و همکاران، ۲۰۱۹)، منطقه نیمه خشک حوضه رودخانه دهبار در ایران (شرافتی و پزشکی، ۲۰۲۰؛ شرافتی و همکاران، ۲۰۲۰)، حوضه دریاچه ارومیه (حیدری تاشه کبود و همکاران، ۲۰۲۰)، دبی ورودی به سد درودزن در شمال استان فارس (نادری<sup>۴</sup>، ۲۰۲۰)، رودخانه کرج (انسانیت<sup>۵</sup> و همکاران، ۲۰۲۱) و دبی رودخانه‌ای در استان گلستان (سیلاخوری و همکاران، ۲۰۲۲) اشاره نمود. نتایج مطالعات فوق، تغییرات افزایشی یا کاهش متغیوتی را در دبی رودخانه بر اساس سناریو و اقلیم منطقه مورد مطالعه نشان دادند. بنابراین، ارزیابی تغییرات اقلیمی و اثرات جانبی احتمالی آن بر فرآیندهای هیدرولوژیک در مقیاس منطقه‌ای

<sup>9</sup>- Deep Learning

<sup>10</sup> Kaltleh

<sup>11</sup> Bozorg-Haddad

<sup>12</sup> Van

<sup>13</sup> Hussain

<sup>14</sup> Le

<sup>15</sup> Sarzaim

<sup>1</sup> Nijssen

<sup>2</sup> Yimer

<sup>3</sup> Masood and Takeuchi

<sup>4</sup> Naderi

<sup>5</sup> Ensaniyat

<sup>6</sup> Kourgiyalas

<sup>7</sup>- Artificial Intelligence

<sup>8</sup>- Artificial Neural Networks

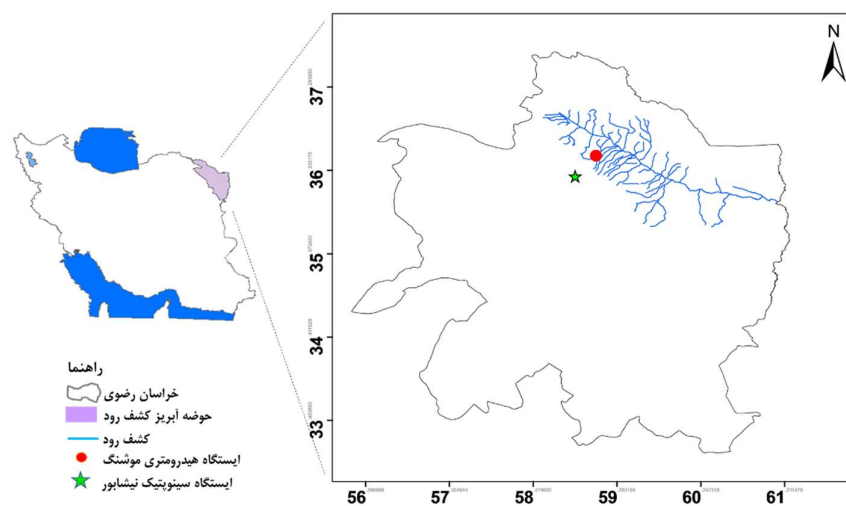
جمع‌آوری داده‌های مربوط به ایستگاه‌های مختلف هیدرومتری و تحلیل موقعیت آن‌ها در نرم‌افزار GIS و بررسی طول مدت و صحت داده‌های موجود در هر ایستگاه، در نهایت ایستگاه هیدرومتری موشنگ (در طول جغرافیایی ۵۳ درجه و ۲ دقیقه شرقی و عرض جغرافیایی ۳۷ درجه و ۳۰ دقیقه شمالی) انتخاب شده و داده‌های دبی روزانه آن از سال ۲۰۰۱ تا ۲۰۲۰ جمع‌آوری گردید. سپس داده‌های هواشناسی روزانه مورد نیاز، شامل دمای کمینه و بیشینه، بارش و ساعات آفتابی در طول دوره آماری مذکور، از ایستگاه سینوپتیک نیشابور، نزدیک‌ترین ایستگاه سینوپتیک به ایستگاه هیدرومتری مورد مطالعه، جمع‌آوری گردید. منطقه مورد مطالعه، دارای اقلیم نیمه‌خشک گرم، با متوسط درصد رطوبت ۳۸/۵ درصد بوده و گرم‌ترین ماه سال، تیر با دمای ۳۸/۷ درجه سانتیگراد (متوسط بلندمدت) و سردترین ماه سال، دی با دمای ۲/۳- درجه سانتیگراد می‌باشد. این منطقه دارای مجموع بارش سالانه (متوسط بلندمدت) ۲۳۵ میلیمتر بوده و مرطوب‌ترین و خشک‌ترین ماه‌های سال به ترتیب فروردین (با بارش ۵۵ میلیمتر در ماه) و مرداد (با بارش کمتر از ۱ میلیمتر) می‌باشد. شکل ۱ موقعیت رودخانه مورد مطالعه و ایستگاه‌های هیدرومتری و سینوپتیک را نشان می‌دهد.

اقلیم بر پارامترهای هواشناسی، دبی رودخانه و مقادیر حدی جریان رودخانه بر اساس سناریوهای گزارش پنجم تغییر اقلیم RCP26، RCP45 و RCP85 در آخرین نسخه مدل LARS-WG پیش‌بینی شده است. بدین منظور، عملکرد مدل شبکه عصبی پیشخور چند لایه (MLP<sup>۱</sup>) با مدل شبکه عصبی کانولوشن (CNN<sup>۲</sup>) در مدلسازی بارش-رواناب رودخانه مقایسه شده و از مدل منتخب، در پیش‌بینی دبی رودخانه در آینده بر اساس خروجی مدل LARS-WG استفاده شده است.

## مواد و روش‌ها

### منطقه مورد مطالعه

در این مطالعه اثر تغییر اقلیم بر دبی کشف‌رود در یکی از سرشاخه‌های دائمی رودخانه در خراسان رضوی بررسی شد. کشف‌رود از کوه‌های هزار مسجد سرچشمه می‌گیرد و پس از عبور از برخی شهرهای استان خراسان رضوی، در مرز ایران به هریرود وارد شده و در نهایت به صحرای ترکمن منتقل می‌شود. به منظور جمع‌آوری داده‌های دبی رودخانه، یک ایستگاه هیدرومتری در بالادست رودخانه که دارای جریان طبیعی دائمی بدون برداشت قابل توجه آب از رودخانه برای مصارف مختلف کشاورزی، شرب، صنعت یا سد در بالادست آن باشد انتخاب گردید. بدین منظور با



شکل (۱) موقعیت منطقه مورد مطالعه، رودخانه و ایستگاه‌های سینوپتیک و هیدرومتری

<sup>۲</sup> - Convolutional Neural Network

<sup>۱</sup> - Multilayer perceptron

## پیش‌بینی پارامترهای هواشناسی با مدل LARS-WG6

در این مطالعه از مدل LARS-WG، به عنوان یک مولد آب و هوایی برای ریزمقیاس‌نمایی و پیش‌بینی پارامترهای هواشناسی منطقه مورد مطالعه در آینده استفاده شد. LARS-WG (سمینو و بارو، ۱۹۹۷) یک مولد آب و هوایی تصادفی است که سری زمانی داده‌های هواشناسی روزانه (حداکثر و حداقل دما، بارش و تابش خورشیدی) را در مقیاس محلی برای دوره‌های گذشته و آینده تولید می‌کند. این مدل از یک توابع احتمال نیمه‌تجربی برای محاسبه طول روزهای تر و خشک بر اساس پارامترهای توزیع آماری داده‌های سری زمانی مشاهده‌شده تاریخی و شبیه‌سازی چرخه‌های فصلی از طریق سری فوریه استفاده می‌کند (راسکو<sup>۱</sup> و همکاران، ۱۹۹۱؛ سمینو و همکاران، ۱۹۹۸؛ سمینو و بروکس، ۱۹۹۹؛ سمینو و بارو<sup>۲</sup>، ۲۰۰۲). عملکرد LARS-WG، در مقایسه با سایر مولدهای اقلیمی (WG) در بسیاری از مطالعات تأیید شده است (مانند ماوروماتیس و هانسن<sup>۳</sup>، ۲۰۰۱؛ سمینو و همکاران، ۱۹۹۸؛ دیبیک و کولیبالی<sup>۴</sup>، ۲۰۰۵؛ سمینو و استراتونوویچ<sup>۵</sup>، ۲۰۱۰؛ مهان<sup>۶</sup> و همکاران، ۲۰۱۷). آخرین نسخه این مدل (LARS-WG6) که در سال ۲۰۱۸ به روز و منتشر شد، از گزارش پنجم IPCC (AR5) بر اساس سناریوهای انتشار RCP (۲۶، ۴۵ و ۸۵) برای پیش‌بینی آب و هوای آینده پیروی می‌کند (حیدری تاشه کبود و همکاران، ۲۰۲۰). سناریوهای RCP، شامل سناریوی خوش‌بینانه کاهش شدید گازهای گلخانه‌ای (RCP 26)، سناریوی بدبینانه با نرخ انتشار گازهای گلخانه‌ای بالا (RCP 85) و سناریو میانی (RCP 45) می‌باشد (IPCC، ۲۰۱۴). این سناریوها، تفاوت بین انرژی تابشی ساطع شده از خورشید و انرژی منعکس شده به جو توسط زمین را نشان می‌دهد (IPCC، ۲۰۱۴).

LARS-WG6 از مدل‌های مختلف GCM از قبیل GFDL-، MIROC5، ECEARTH، HadGEM2-EC، CM3 و MPIESM-MR برای شبیه‌سازی آب و هوای آینده تحت تأثیر تغییرات اقلیم استفاده می‌کند (شرافتی و پزشکی، ۲۰۲۰). در این مطالعه از مدل HadGEM2-ES برای ریزمقیاس‌نمایی پیش‌بینی پارامترهای هواشناسی استفاده شد. HadGEM2 که توسط مرکز پیش‌بینی و تحقیقات اقلیمی هادلی ایجاد شده است، شبکه‌ای را در محدوده ۱/۲۵ درجه عرض جغرافیایی در ۱/۸۷۵ درجه طول جغرافیایی را پوشش می‌دهد (حیدری تاشه کبود و همکاران، ۲۰۲۰). HadGEM2-ES به طور گسترده در ریزمقیاس-نمایی آماری متغیرهای اقلیمی در سراسر ایران نیز با عملکرد مناسب مورد استفاده قرار گرفته است (حیدری تاشه کبود و همکاران، ۲۰۲۰؛ شرافتی و پزشکی، ۲۰۲۰؛ شرافتی و همکاران، ۲۰۲۰). سیلاخوری و همکاران، ۲۰۲۲). کالیبراسیون خروجی LARS-WG با ارزیابی دقت مدل در بازتولید پارامترهای هواشناسی دوره پایه در برابر داده‌های مشاهده شده تاریخی ایستگاه سینوپتیک نیشابور در سطح اطمینان مورد نظر انجام شد؛ همان‌گونه که دقت آن در شبیه‌سازی متغیرهای هواشناسی دوره پایه در مطالعات دیگر تأیید شده است (عثمان<sup>۷</sup> و همکاران، ۲۰۱۹؛ شا<sup>۸</sup> و همکاران، ۲۰۱۹؛ شرافتی و پزشکی، ۲۰۲۰؛ شرافتی و همکاران، ۲۰۲۰). پس از کالیبراسیون، LARS-WG برای پیش‌بینی پارامترهای هواشناسی آینده تحت سه سناریوی RCP 26، RCP 45 و RCP 85 مورد استفاده قرار گرفت. LARS-WG با استفاده از داده‌های روزانه حداقل و حداکثر دما، بارش و تابش خورشیدی در یک دوره آماری پایه ۲۰ ساله (۲۰۲۰-۲۰۰۱) اجرا شد و برای شبیه‌سازی آب و هوای آینده در دوره زمانی ۲۰۴۰-۲۰۲۱ در منطقه مورد مطالعه استفاده شد.

<sup>5</sup> Semenov and Stratonovitch

<sup>6</sup> Mehan

<sup>7</sup> Osman

<sup>8</sup> Sha

<sup>1</sup> Racsko

<sup>2</sup> Semenov and Barrow

<sup>3</sup> Mavromatis and Hansen

<sup>4</sup> Dibike and Coulibaly

## مدل‌های هوش مصنوعی در مدل‌سازی بارش-رواناب

در این مطالعه، عملکرد مدل‌های هوش مصنوعی MLP و CNN در مدل‌سازی بارش-رواناب دبی رودخانه مورد مقایسه قرار گرفت. یک شبکه عصبی MLP، معمولاً از چند لایه و نورون تشکیل می‌یابد. اولین و پایین‌ترین لایه، لایه ورودی است که در آن داده‌های ورودی دریافت می‌گردد. آخرین یا بالاترین لایه، لایه خروجی است که در آن حل مسئله انجام شده و خروجی را در شبکه تولید می‌کند. لایه ورودی و خروجی توسط یک یا چند لایه واسطه که لایه میانی یا پنهان نامیده می‌شود، به یکدیگر متصل می‌شوند. در هر لایه، تعدادی پردازشگر به نام نرون وجود دارد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. در تحقیق حاضر، برای مدل‌سازی دبی رودخانه با استفاده از شبکه‌های MLP، از یک شبکه سه لایه پیشخور استفاده شد. یک تابع محرک سیگموئید (تانژانت هایپربولیک) در لایه پنهان و یک تابع محرک خطی، در لایه خروجی به کار گرفته شد. از میان روش‌های مختلف آموزش، الگوریتم لونیبرگ مارکوارت، به دلیل همگرایی سریع‌تر در آموزش شبکه، در تحقیق حاضر انتخاب شد.

CNN، یک نوع شبکه عصبی یادگیری عمیق (DL) با لایه‌های متناوب کانولوشنی است که وزن‌ها و بایاس‌ها با انتشار پس‌خور به‌روز می‌شوند و عمدتاً از طریق یک الگوریتم یادگیری نظارت‌شده آموزش داده می‌شوند (گبرهیوت<sup>۱</sup> و همکاران، ۲۰۱۹؛ کرانیاز<sup>۲</sup> و همکاران، ۲۰۲۱). CNN‌ها در ابتدا، برای کار بر روی داده‌های دو بعدی (تصاویر و فیلم‌ها) و استخراج ویژگی‌ها از حجم زیادی از داده‌های برچسب‌گذاری شده توسعه یافته‌اند (کبیر<sup>۳</sup> و همکاران، ۲۰۲۰؛ حسینی<sup>۴</sup>، ۲۰۲۱) و به دلیل موفقیت در تشخیص تصویر و مسائل طبقه‌بندی محبوبیت پیدا کرده‌اند (کرژیوسکی<sup>۵</sup> و همکاران، ۲۰۱۲؛ وانگ<sup>۶</sup> و همکاران، ۲۰۱۷). با این حال، تمایل به استفاده از ابزار CNN برای مدل‌سازی

داده‌های عددی اخیراً افزایش یافته و در زمینه‌های مختلف از جمله فرآیندهای هیدرولوژیک به‌ویژه مدل‌سازی بارش-رواناب با موفقیت مورد استفاده قرار گرفته است (ون و همکاران، ۲۰۲۰؛ حسین و همکاران، ۲۰۲۰؛ لی و همکاران، ۲۰۲۱). مدل‌سازی CNN در این مطالعه، با دو لایه کانولوشن و سه لایه کاملاً متصل با تابع فعال‌سازی ReLU اجرا شد. علاوه بر این، نرمال‌سازی داده batch برای متعادل‌سازی محدوده داده‌ها، استفاده شد و از روش dropout، برای جلوگیری از بیش‌برازش شبکه، استفاده شد (حسین و همکاران، ۲۰۲۰). معماری بهینه CNN با تغییر تعداد لایه‌های پنهان و نورون‌های آن در فرآیند آزمون و خطا، تعیین شد. روند آموزش تا رسیدن به حداقل خطا بین مقادیر هدف و مدل و حداکثر همبستگی بین آنها ادامه یافت.

انتخاب متغیرهای مناسب به عنوان ورودی مدل در روش شبکه عصبی یکی از مراحل مهم، در معماری بهینه مدل است (ون و همکاران، ۲۰۲۰). در این مطالعه، ترکیب‌های مختلفی از مقادیر بارندگی و دبی روزانه با تأخیرهای متفاوت طبق معادله (۱) به عنوان ورودی در مدل‌های هوش مصنوعی استفاده شد.

$$\hat{Q}_t = f(R_t, R_{t-1}, R_{t-2}, \dots, Q_{t-1}, Q_{t-2}, \dots) \quad (1)$$

که در آن،  $\hat{Q}_t$ ، دبی پیش‌بینی شده در زمان  $t$ ،  $Q_{t-i}$  دبی رودخانه در گام‌های زمانی قبلی و  $R_{t-i}$  بارندگی در گام‌های زمانی مختلف است. سناریوهای در نظر گرفته شده از متغیرهای ورودی در مدل‌سازی روزانه دبی رودخانه در جدول ۱ ارائه شده است. در هر سناریو، ۸۰ درصد داده‌های دبی روزانه (۲۰۰۱-۲۰۱۶) و ۲۰ درصد از داده‌ها (۲۰۱۷-۲۰۲۰) به ترتیب برای آموزش مدل و تست عملکرد آن در نظر گرفته شد. اعتبارسنجی عملکرد مدل در طول فرآیند آموزش با استفاده از ۱۰ درصد داده‌های آموزش انجام شد.

<sup>4</sup> Hosseiny  
<sup>5</sup> Krizhevsky  
<sup>6</sup> Wang

<sup>1</sup> Gebrehwot  
<sup>2</sup> Kiranyaz  
<sup>3</sup> Kabir

مدل هوش مصنوعی، در این مطالعه با برنامه‌نویسی در MATLAB R2021b انجام شد.

جدول (۱) سناریوهای مختلف ترکیب پارامترهای ورودی در مدلسازی هوش مصنوعی بارش-رواناب

سناریو	ورودی‌ها
S1	$R_t, Q_{t-1}$
S2	$R_t, R_{t-1}, Q_{t-1}$
S3	$R_t, R_{t-1}, R_{t-2}, Q_{t-1}$
S4	$R_t, R_{t-1}, R_{t-2}, R_{t-3}, Q_{t-1}$
S5	$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, Q_{t-1}$
S6	$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, R_{t-5}, Q_{t-1}$
S7	$R_t, R_{t-1}, R_{t-2}, Q_{t-1}, Q_{t-2}$
S8	$R_t, R_{t-1}, R_{t-2}, R_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3}$
S9	$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$
S10	$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, R_{t-5}, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$
	$Q_{t-i}$ دبی رودخانه در گام‌های زمانی مختلف و $R_{t-i}$ بارندگی در گام‌های زمانی مختلف

### روش انجام تحقیق در پیش‌بینی دبی رودخانه تحت تاثیر تغییر اقلیم

پس از انتخاب برترین مدل هوش مصنوعی و بهترین ترکیب متغیرهای ورودی در مدلسازی دبی رودخانه، پارامترهای هواشناسی پیش‌بینی‌شده توسط مدل LARS-WG6 به عنوان ورودی مدل هوش مصنوعی برتر استفاده شده و دبی رودخانه در دوره زمانی ۲۰۲۱-۲۰۴۰ در سه سناریوی RCP 26، RCP 45 و RCP 85 پیش‌بینی شد.

برای تجزیه و تحلیل، مقادیر حدی دبی پیش‌بینی شده و مقایسه آن‌ها با مقادیر متناظر دوره پایه، میانگین متحرک ۷ روزه داده‌های دبی روزانه محاسبه و مقادیر حداکثر ( $Q_{max}$ ) و حداقل ( $Q_{min}$ ) آن‌ها به دست آمد. میانگین متحرک ۷ روزه تغییرات جریان روزانه را حذف می‌کند، تجزیه و تحلیل بر اساس میانگین ۷ روزه نسبت به خطاهای اندازه‌گیری حساسیت کمتری دارد و در بیشتر موارد، تفاوت

برای ارزیابی عملکرد مدل‌های شبکه عصبی در هر سناریو و انتخاب بهترین سناریو و همچنین مقایسه مدل‌های هوش مصنوعی برای انتخاب مدل برتر، ترکیبی از ارزیابی نتایج گرافیکی و آمارهای مختلف، شامل ریشه میانگین مربعات خطا (RMSE)، ضریب تبیین ( $R^2$ )، میانگین خطا (ME) و ضریب NSE (Nash-Sutcliffe) در مطالعات مختلف توصیه شده است (موریاسی<sup>۱</sup> و همکاران، ۲۰۰۷؛ ریتتر و مونز کارپنا<sup>۲</sup>، ۲۰۱۳) و در این تحقیق طبق روابط زیر استفاده گردید:

$$RMSE = \left[ \frac{\sum_{i=1}^n (P_i - O_i)^2}{n} \right]^{1/2} \quad (2)$$

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

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

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

که در آن،  $P_i$  و  $O_i$  به ترتیب مقادیر دبی مشاهده شده و پیش‌بینی شده و  $\bar{P}$  و  $\bar{O}$ ، مربوط به میانگین مقادیر دبی مشاهده شده و پیش‌بینی شده و  $n$ ، تعداد مشاهدات است. RMSE، نشان‌دهنده تفاوت بین مقادیر پیش‌بینی شده و مشاهده شده و ME، نشان‌دهنده بیش‌برآوردی یا کم-برآوردی مدل است. بنابراین مقادیر کوچکتر و نزدیک به صفر این پارامترها، نشان‌دهنده عملکرد بهتر مدل است (بنایان و هوگنبوم<sup>۳</sup>، ۲۰۰۹). ضریب تبیین، نشانگر همبستگی مقادیر مشاهده شده و پیش‌بینی شده با دامنه بین ۰ و ۱ است.  $R^2$ ، برابر با ۱، دلالت بر برازش کامل دارد (بنایان و هوگنبوم، ۲۰۰۹). محدوده ضریب NSE بین ۱ و  $-\infty$  متغیر است و مقادیر نزدیک به ۱، دقت بالای مدل را نشان می‌دهد (نش و ساتکلیف<sup>۴</sup>، ۱۹۷۰). مدلسازی هر دو

<sup>3</sup> Bannayan and Hoogenboom

<sup>4</sup> Nash and Sutcliffe

<sup>1</sup> Moriasi

<sup>2</sup> Ritter and Muñoz-Carpena

زیادی بین جریان‌های کم یک روزه و ۷ روزه وجود ندارد (اسماختین، ۲۰۰۱).

## نتایج و بحث

### پیش‌بینی LARS-WG6 از پارامترهای هواشناسی در آینده

پیش‌بینی حداقل و حداکثر دما، بارندگی و تابش خورشیدی با استفاده از LARS-WG6 در سناریوهای مختلف در شکل ۲ و میزان تغییرات پارامترهای ذکر شده در جدول ۲ نشان می‌دهد که حداقل و حداکثر دما، در آینده نزدیک (۲۰۲۱-۲۰۴۰) در منطقه مورد مطالعه و در سه سناریوی تغییر اقلیم افزایش خواهد یافت. بیشترین افزایش دما در دمای حداقل و حداکثر اغلب مربوط به سناریوی RCP85 است و سناریوهای RCP26 و RCP45 به ترتیب در رتبه‌های بعد قرار دارند. افزایش دما در ماه‌های مختلف متفاوت است و این افزایش در دمای کمینه در سناریوهای مختلف در محدوده ۰/۴ تا ۱/۵ و برای دمای بیشینه در محدوده ۰/۳ تا ۲/۱ درجه سانتیگراد است.

تغییرات تابش خورشیدی پیش‌بینی شده در دوره ۲۰۲۱-۲۰۴۰ در شکل ۲ و جدول ۲، نشان می‌دهد که تابش خورشید، در اغلب ماه‌ها نسبت به دوره پایه (۲۰۰۱-۲۰۲۰) کاهش خواهد یافت. متوسط سالانه تابش خورشیدی در آینده، نسبت به دوره پایه در سناریوهای RCP26، RCP45 و RCP85، به ترتیب ۳/۳، ۳/۷ و ۳/۲ درصد کاهش خواهد یافت. بطوریکه تغییر تابش خورشیدی در ماه‌های مختلف در سناریوهای مذکور، به ترتیب در محدوده ۱۱/۱- تا ۲/۱+، ۱۰/۸- تا ۱/۶+ و ۱۰/۳- تا ۱/۸+ درصد می‌باشد. تابش خورشیدی در هر سه سناریو در یک ماه آخر

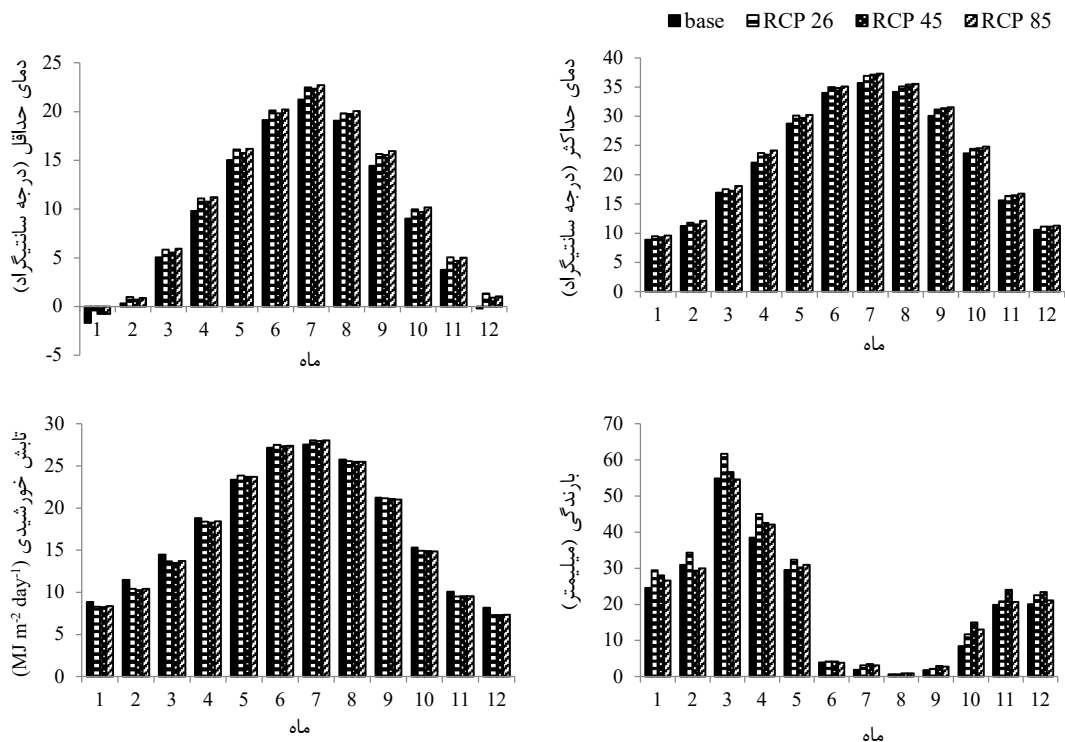
بهار و دو ماه اول تابستان افزایشی و در بقیه ماه‌ها کاهش‌ی پیش‌بینی شده است.

تغییرات ماهانه بارندگی، در سناریوهای مختلف دارای تنوع بیشتری نسبت به پارامترهای دما و تابش خورشید بوده و پیش‌بینی‌های افزایشی و کاهش‌ی متفاوتی را نشان می‌دهد. با این حال، مجموع بارندگی سالانه در تمام سناریوهای تغییر اقلیم در آینده افزایش خواهد یافت. بیشترین افزایش بارش سالانه در آینده نسبت به دوره پایه در RCP26 با حدود ۱۴ درصد و کمترین افزایش مربوط به سناریوی RCP85 در حدود ۶ درصد است. میزان افزایش بارش سالانه، در سناریوی RCP45، مابین دو سناریوی دیگر و حدود ۱۱ درصد می‌باشد. تغییر بارندگی ماهانه در آینده، نسبت به دوره پایه در سناریوی RCP26، در همه ماه‌ها افزایشی و در محدوده ۵/۱+ تا ۵۹/۹+ درصد می‌باشد. ولی در سناریوی RCP45، بارش در ماه‌های مختلف، محدوده گسترده‌تر افزایش و کاهش را خواهد داشت (۵/۲- تا ۸۰/۵+ درصد). تغییر بارش ماهانه در آینده، نسبت به دوره پایه در سناریوی RCP85 نیز در محدوده ۳- تا ۶۱/۳+ درصد خواهد بود.

مشابه نتایج به‌دست‌آمده از مطالعه حاضر، پیش‌بینی‌های چن و همکاران (۲۰۱۳) نشان داد که دمای حداکثر و حداقل در آینده، در سودان، روند افزایشی مستمری خواهند داشت، اما بارش ماهانه، روند افزایشی و کاهش‌ی متفاوتی خواهد داشت. هارمن و همکاران (۲۰۰۹) و باگیس<sup>۱</sup> و همکاران (۲۰۱۰) همچنین نتایج مشابهی را در مورد بارش به ترتیب در پورتوریکو و مرکز بلژیک گزارش کردند. مطابق با نتایج مطالعه حاضر، محمد و حسن<sup>۲</sup> (۲۰۲۲) پیش‌بینی کردند که افزایش حداقل و حداکثر دمای سالانه، در جنوب عراق، تحت سناریوی RCP85 (۵/۹۱- تا ۵/۶۷+ درجه سانتیگراد) بیشتر از RCP45 (۱/۵- تا ۱/۴۱+ درجه سانتیگراد) خواهد بود.

<sup>2</sup> Mohammed and Hassan

<sup>1</sup> Baguis



شکل (۲) مقایسه دمای حداقل، حداکثر، بارندگی و تابش خورشیدی در دوره پایه (۲۰۲۰-۲۰۰۱) و آینده (۲۰۴۰-۲۰۲۱) در سناریوهای مختلف تغییر اقلیم

جدول (۲) میزان تغییر پارامترهای هواشناسی پیش‌بینی شده توسط مدل LARS-WG6 در دوره آینده (۲۰۴۰-۲۰۲۱) در مقایسه با دوره پایه (۲۰۲۰-۲۰۰۱) در منطقه مورد مطالعه

پارامتر	سناریو	ژانویه	فوریه	مارس	آوریل	می	ژوئن	جولای	اگوست	سپتامبر	اکتبر	نوامبر	دسامبر	سالانه
دمای کمینه (درجه سانتیگراد)	RCP26	۱/۳	۰/۷	۰/۸	۱/۳	۱/۱	۱/۰	۱/۳	۰/۷	۱/۲	۱/۰	۱/۳	۱/۵	۱/۱
	RCP45	۰/۹	۰/۴	۰/۵	۱/۰	۰/۸	۰/۷	۱/۱	۰/۷	۱/۱	۰/۷	۰/۹	۱/۱	۰/۸
	RCP85	۰/۹	۰/۶	۰/۹	۱/۴	۱/۱	۱/۱	۱/۵	۱/۰	۱/۵	۱/۲	۱/۳	۱/۲	۱/۱
دمای بیشینه (درجه سانتیگراد)	RCP26	۰/۶	۰/۶	۰/۶	۱/۶	۱/۴	۱/۰	۱/۲	۰/۹	۱/۱	۰/۷	۰/۸	۰/۶	۰/۹
	RCP45	۰/۵	۰/۳	۰/۳	۱/۳	۱/۰	۰/۹	۱/۴	۱/۲	۱/۳	۰/۹	۰/۹	۰/۵	۰/۹
	RCP85	۰/۷	۰/۹	۱/۱	۲/۱	۱/۵	۱/۱	۱/۶	۱/۳	۱/۵	۱/۱	۱/۱	۰/۷	۱/۲
تابش خورشیدی (درصد)	RCP26	-۶/۳	-۹/۲	-۵/۷	-۲/۲	۲/۱	۱/۲	۱/۸	-۰/۶	-۰/۴	-۲/۷	-۶/۰	-۱۱/۱	-۳/۳
	RCP45	-۷/۰	-۱۰/۵	-۶/۹	-۲/۸	۱/۶	۰/۷	۱/۵	-۱/۰	-۰/۷	-۲/۸	-۵/۵	-۱۰/۸	-۳/۷
	RCP85	-۵/۷	-۹/۰	-۵/۴	-۲/۰	۱/۵	۰/۸	۱/۸	-۰/۹	-۱/۰	-۳/۱	-۵/۶	-۱۰/۳	-۳/۲
بارندگی (میلیمتر)	RCP26	۱۹/۹	۱۱/۱	۱۲/۴	۱۷/۱	۹/۶	۷/۱	۵۹/۹	۸/۹	۱۸/۱	۳۹/۴	۵/۱	۱۲/۱	۱۴/۱
	RCP45	۱۴/۰	-۵/۲	۳/۲	۱۰/۵	۲/۴	۶/۵	۸۰/۵	۴۳/۲	۶۳/۱	۷۸/۶	۲۱/۲	۱۶/۶	۱۰/۹
	RCP85	۸/۲	-۳/۰	-۰/۴	۹/۲	۵/۰	-۲/۱	۶۱/۳	۴۲/۷	۵۱/۳	۵۶/۰	۴/۱	۵/۰	۶/۲

**مقایسه مدل‌های هوش مصنوعی در مدل‌سازی بارش -**

**رواناب**

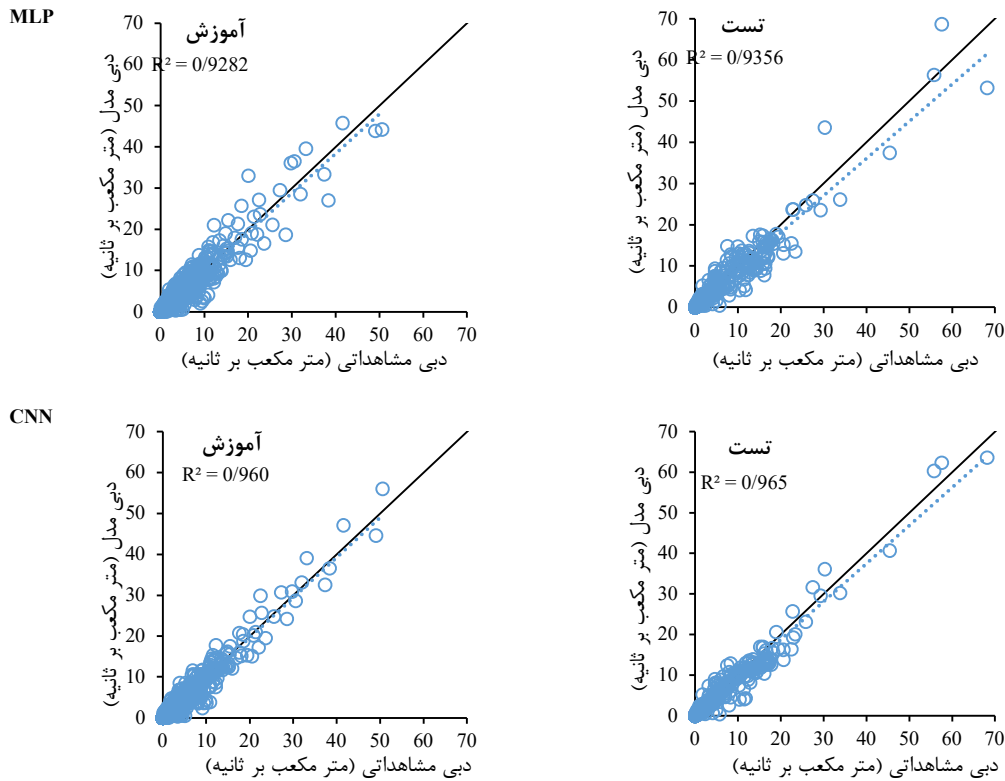
در این مطالعه، مدل‌سازی جریان روزانه رودخانه، با استفاده از مدل‌های هوش مصنوعی MLP و CNN، بر اساس داده‌های بارندگی و رواناب با تأخیرهای زمانی متفاوت، به عنوان ورودی مدل در سناریوهای تعریف شده جدول ۱ انجام شد. نتایج مربوط به مقایسه عملکرد سناریوهای مختلف و همچنین مقایسه دو مدل، در دو بخش آموزش و تست، در جدول ۳ ارائه شده است. با توجه به نتایج به دست آمده از این جدول، سناریوی S3، با ورودی‌های  $R_t$ ،  $R_{t-1}$ ،  $R_{t-2}$  و  $Q_{t-1}$ ، عملکرد بهتری نسبت به سناریوهای دیگر در هر دو مدل MLP و CNN دارد. سناریوی مذکور، دارای کمترین خطا و بیشترین همبستگی بین مقادیر مشاهده شده و پیش‌بینی شده جریان رودخانه در داده‌های آموزش و تست است. در مدل MLP سناریوی ۴ با ورودی‌های  $R_t$ ،  $R_{t-1}$ ،  $R_{t-2}$  و  $R_{t-3}$  نیز عملکرد مناسبی در مدل‌سازی دبی رودخانه دارد. در این جدول، مقادیر مثبت شاخص ME،

بیانگر بیش‌برآوردی و مقادیر منفی، نشان‌دهنده کم‌برآوردی مدل است. ارزیابی سناریوهای مختلف نشان داد که در سناریوهای آخر، با تعداد ورودی بیشتر، عملکرد هر دو مدل، در مدل‌سازی دبی رودخانه ضعیف‌تر است. مقایسه دو مدل هوش مصنوعی در جدول ۳، نشان‌دهنده عملکرد بهتر مدل CNN، نسبت به MLP، در مدل‌سازی دبی رودخانه می‌باشد. مقایسه مقادیر مشاهده شده و پیش‌بینی شده و همبستگی آن‌ها، در دو سری داده‌های آموزش و تست، در سناریوی برتر دو مدل (S3) در شکل-های ۳ و ۴ نیز نشان می‌دهد که مدل CNN، در معماری با ورودی‌های مناسب، قادر به پیش‌بینی جریان رودخانه با دقت بالایی می‌باشد. نتایج مطالعه ون و همکاران (۲۰۲۰)، حسین و همکاران (۲۰۲۰) و لی و همکاران (۲۰۲۱) نیز، عملکرد مناسب مدل CNN را در مدل‌سازی بارش-رواناب نشان دادند. بنابراین، این مدل را می‌توان با خروجی‌های LARS-WG6، برای پیش‌بینی تغییرات جریان رودخانه، تحت تأثیر تغییرات اقلیم، در آینده ترکیب کرد.

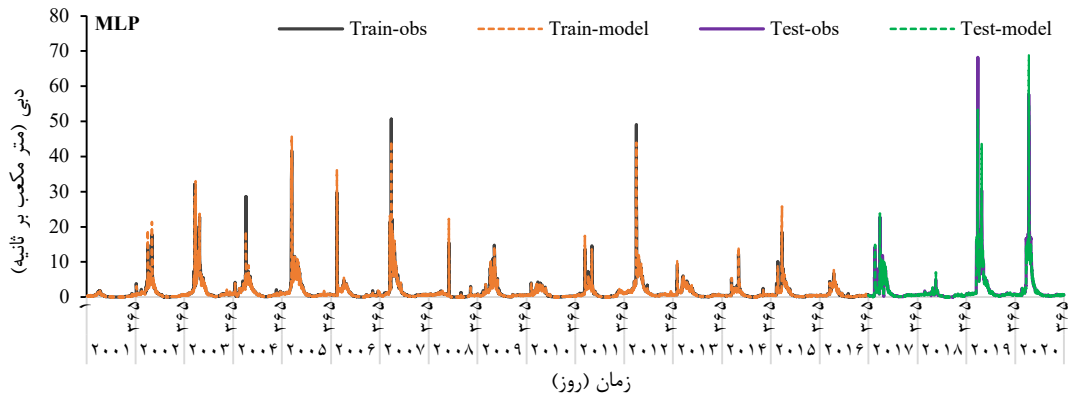
**جدول (۳) ارزیابی عملکرد مدل‌های MLP و CNN در مدل‌سازی دبی رودخانه در سناریوهای مختلف ترکیب ورودی**

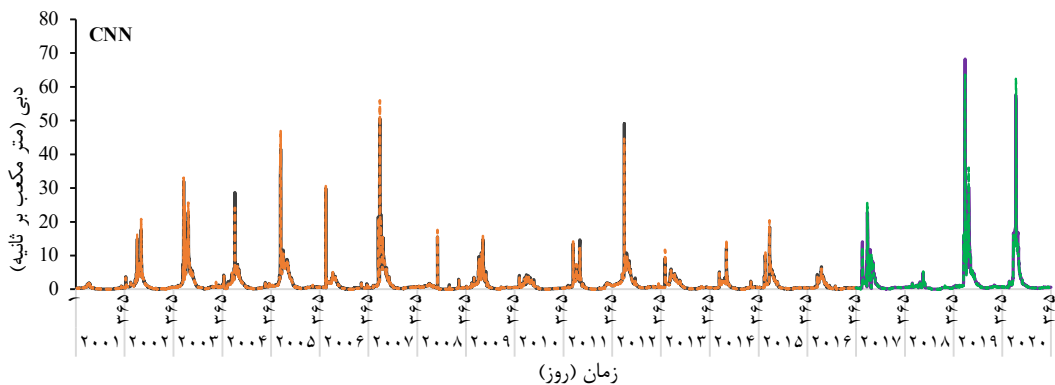
مدل	سناریو	آموزش				تست			
		Nash (-)	ME ( $m^3 s^{-1}$ )	RMSE ( $m^3 s^{-1}$ )	R <sup>2</sup> (-)	Nash (-)	ME ( $m^3 s^{-1}$ )	RMSE ( $m^3 s^{-1}$ )	R <sup>2</sup> (-)
MLP	S1	۰/۶۹۳	-۰/۲۰۹	۱/۴۹۷	۰/۶۸۳	-۰/۱۵۳۴	۲/۶۵۷	۰/۷۶۴	۰/۷۰۰
	S2	۰/۸۵۹	۰/۳۲۳	۱/۰۶۲	۰/۸۴۰	۰/۲۷۹	۱/۶۲۹	۰/۸۹۳	۰/۸۸۷
	S3	۰/۹۲۸	-۰/۰۵۵	۰/۷۲۰	۰/۹۲۷	-۰/۱۶۲	۱/۲۵۴	۰/۹۳۶	۰/۹۲۳
	S4	۰/۹۱۳	-۰/۰۱۸	۰/۷۹۰	۰/۹۱۲	-۰/۱۳۴	۱/۲۲۸	۰/۹۳۷	۰/۹۳۶
	S5	۰/۸۸۰	۰/۶۶۶	۱/۱۳۸	۰/۸۱۷	۰/۴۶۸	۱/۶۱۹	۰/۹۱۶	۰/۸۸۹
	S6	۰/۸۱۹	-۰/۳۳۳	۱/۱۸۸	۰/۸۰۰	-۰/۴۹۲	۱/۸۵۰	۰/۸۶۶	۰/۸۵۵
	S7	۰/۷۷۶	-۰/۰۸۰	۱/۲۶۶	۰/۷۷۳	-۰/۳۱۸	۲/۳۷۲	۰/۷۹۷	۰/۷۶۱
	S8	۰/۷۲۸	-۰/۵۵۵	۱/۴۹۴	۰/۶۸۴	-۰/۰۷۰	۲/۳۱۰	۰/۸۱۰	۰/۷۷۳
	S9	۰/۷۳۹	۰/۶۰۰	۱/۵۱۱	۰/۶۷۷	۰/۴۹۶	۲/۱۲۸	۰/۸۲۲	۰/۸۰۷
	S10	۰/۷۳۰	-۰/۳۸۵	۱/۴۳۹	۰/۷۰۷	-۰/۵۳۸	۲/۲۲۷	۰/۸۰۷	۰/۷۸۹
CNN	S1	۰/۷۵۱	-۰/۲۱۲	۱/۳۸۳	۰/۷۲۹	-۰/۵۲۹	۲/۵۵۱	۰/۸۱۴	۰/۷۲۴
	S2	۰/۹۰۹	۰/۳۲۹	۰/۸۷۰	۰/۸۹۳	۰/۲۲۵	۱/۲۶۴	۰/۹۳۵	۰/۹۳۲
	S3	۰/۹۶۰	-۰/۰۵۳	۰/۵۳۴	۰/۹۶۰	-۰/۱۳۷	۰/۹۲۲	۰/۹۶۵	۰/۹۶۴
	S4	۰/۹۳۱	-۰/۰۱۵	۰/۷۰۲	۰/۹۳۰	-۰/۱۰۵	۱/۰۵۶	۰/۹۵۴	۰/۹۵۳
	S5	۰/۹۰۲	۰/۰۷۱	۱/۰۷۱	۰/۸۳۸	۰/۴۹۰	۱/۵۷۶	۰/۹۱۸	۰/۸۹۵
	S6	۰/۸۴۰	-۰/۳۳۲	۱/۱۲۵	۰/۸۲۱	-۰/۴۹۷	۱/۷۹۱	۰/۸۷۶	۰/۸۶۴
	S7	۰/۸۰۰	-۰/۰۸۷	۱/۲۰۱	۰/۷۹۶	-۰/۳۲۴	۲/۲۹۷	۰/۸۲۲	۰/۷۷۶
	S8	۰/۷۳۲	-۰/۵۵۳	۱/۴۸۵	۰/۶۸۸	-۰/۶۹۴	۲/۲۰۷	۰/۸۳۰	۰/۷۹۳

۰/۸۱۳	۰/۵۰۰	۲/۱۰۰	۰/۸۲۸	۰/۶۹۴	۰/۶۰۶	۱/۴۷۰	۰/۷۵۵	S9
۰/۸۱۴	-۰/۵۱۴	۲/۰۹۳	۰/۸۲۹	۰/۷۱۷	-۰/۳۸۴	۱/۴۱۴	۰/۷۴۰	S10



شکل (۳) همبستگی بین مقادیر مشاهده شده و مدلسازی شده دبی رودخانه در سناریوی برتر مدل‌های MLP و CNN





شکل (۴) مقایسه دبی مشاهده شده و پیش‌بینی شده در سناریوی برتر مدل‌های MLP و CNN در دو فاز آموزش و تست

### پیش‌بینی دبی رودخانه تحت تأثیر تغییر اقلیم

پس از اطمینان از کارایی مدل CNN، با ترکیب ورودی‌های سناریوی S3، در پیش‌بینی دبی رودخانه، از خروجی مدل LARS-WG، به عنوان ورودی مدل CNN استفاده شده و دبی رودخانه در آینده (۲۰۲۱-۲۰۴۰) تحت تأثیر تغییر اقلیم، در سه سناریوی RCP26، RCP45 و RCP85، پیش‌بینی گردید. نتایج این پیش‌بینی، در مقایسه با متوسط بلندمدت ۲۰ ساله دوره پایه (۲۰۰۱-۲۰۲۰) در شکل ۵ نشان داده شده است. طبق نتایج به دست آمده از این شکل، افزایش جریان رودخانه در بهار، تحت تأثیر سناریوی RCP26 و همچنین در پاییز، تحت تأثیر سناریوی RCP45 پیش‌بینی می‌شود. این افزایش جریان در سناریوهای ذکر شده را می‌توان با افزایش بارندگی، در فصول مربوطه مرتبط دانست (شکل ۲ و جدول ۲).

به منظور مقایسه تغییرات مقادیر حدی دبی رودخانه، در سناریوهای مختلف با دوره پایه، میانگین متحرک ۷ روزه دبی محاسبه و مقادیر حداکثر و حداقل آنها به دست آمد. مقادیر حداکثر و حداقل دبی بدست آمده در شکل ۵ نشان داده شده است. بر اساس نتایج بدست آمده از این بخش، دبی حداکثر در سناریوی RCP26، نسبت به دوره پایه، حدود ۱۸ درصد افزایش خواهد یافت. این در حالی است که دبی حداکثر، در سناریوهای RCP45 و RCP85 نسبت به دوره پایه، به ترتیب حدود ۶ و ۱۰ درصد کاهش خواهد

یافت. نتایج پیش‌بینی بارش، در شکل ۲ و جدول ۲ نیز نشان داد که بیشترین افزایش بارش سالانه در آینده، نسبت به دوره پایه، مربوط به سناریوی RCP26، با حدود ۱۴ درصد خواهد بود. در سناریوی مذکور، بارش در تمام ماه‌های سال افزایش خواهد یافت. ولی در سناریوهای RCP45 و RCP85، بارندگی در برخی ماه‌ها در آینده کاهش خواهد یافت. با توجه به مقادیر کم جریان رودخانه در مواقع حداقل (تابستان)، تغییرات دبی حداقل در آینده، نسبت به دوره پایه نیز در سناریوهای مختلف ناچیز است. نتایج سایر مطالعات در مدل‌سازی بارش-رواناب با استفاده از مدل هیدرولوژیک در ترکیب با خروجی LARS-WG نیز، تغییرات افزایشی یا کاهش‌ی متفاوتی را برای دبی رودخانه‌ها در مناطق مختلف تحت تأثیر تغییر اقلیم پیش‌بینی کرده‌اند. در حوضه مگنا - بنگلادش، حداکثر افزایش میانگین سالانه بارندگی و رواناب، به ترتیب ۲۳+ و ۳۴+ درصد در آینده نزدیک (۲۰۳۹-۲۰۱۵) پیش‌بینی شده است (مسعود و تکیوچی، ۲۰۱۶). کاهش منابع آب در حوضه رودخانه زرد چین، بین ۳۰ تا ۲۴ درصد برای سناریوهای RCP 2.6 و RCP4.5 پیش‌بینی شده است (ژو و همکاران، ۲۰۱۶). پیش‌بینی تأثیر تغییر اقلیم بر تغییرات دبی رودخانه هروچای اردبیل، تا ۲۰۴۰ با استفاده از مدل‌های LARS-WG و SWAT، نشان داد که بارش و رواناب، طبق سناریوهای A2 و B1، افزایش و بر اساس سناریوی A1B، کاهش خواهد یافت (غزوی<sup>۱</sup> و همکاران، ۲۰۱۸). ارزیابی تأثیر تغییر اقلیم بر دبی

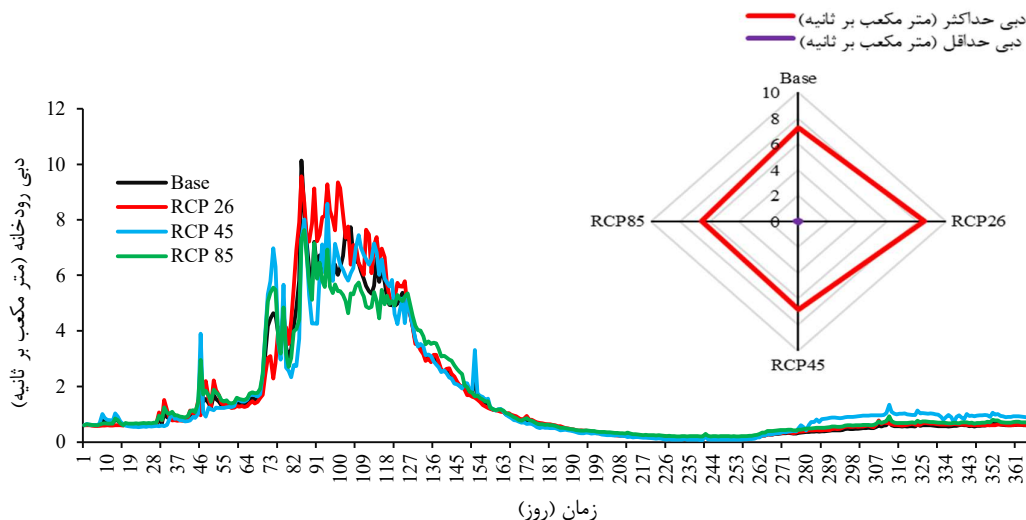
<sup>1</sup> Ghazavi

مختلف استفاده شده است (لی و شریف، ۲۰۱۵؛ مسعود و تاکیوچی، ۲۰۱۶؛ صادیق و همکاران، ۲۰۱۹؛ شرافتی و پزشکی، ۲۰۲۰؛ شرافتی و همکاران، ۲۰۲۰؛ حیدری تاشه کبود و همکاران، ۲۰۲۰؛ نادری، ۲۰۲۰؛ انسانیت و همکاران، ۲۰۲۱؛ سیلاخوری و همکاران، ۲۰۲۲)، این مدل‌ها جهت پیش‌بینی دبی رودخانه در آینده، علاوه بر ورودی‌های هواشناسی، نیازمند تعیین برخی ضرایب و پارامترهایی هستند که وضعیت آن‌ها تحت تاثیر تغییر اقلیم در آینده مشخص نبوده و مستلزم فرضیاتی از برخی شرایط در آینده می‌باشند. در این پژوهش تلاش گردید از روشی در پیش-بینی دبی رودخانه در آینده استفاده گردد که ضمن کاهش عدم اطمینان‌پذیری چنین فرضیاتی، در مقادیر پارامترهای هواشناسی مختلف (که در داده‌های دوره آبی در اثر تغییر اقلیم با آن مواجه می‌شود)، قادر به مدلسازی دبی با دقت مناسب باشد. بدین منظور، مدل عددی، با استفاده از محدوده گسترده‌ای از داده‌های بارش و دبی تاریخی آموزش دیده و نتایج تست آن نیز نشان داد که این مدل در مقادیر مختلف دبی و بارش ورودی قادر است دبی رودخانه را با دقت مناسب تخمین بزند. انجام تحقیقات بیشتر در اینخصوص در جهت افزایش اطمینان‌پذیری چنین پیش-بینی ضروری است.

رودخانه دهبار در ایران نشان داد که بیشترین افزایش در حداکثر مقادیر سالانه دبی رودخانه و عمق بارندگی بر اساس سناریوی RCP85 به ترتیب ۱۴۲٪ و ۸۱٪ در آینده (۲۰۲۱-۲۰۴۰) رخ خواهد داد (شرافتی و پزشکی، ۲۰۲۰؛ شرافتی و همکاران، ۲۰۲۰). پیش‌بینی اثر تغییر اقلیم بر دبی ورودی به مخزن سد درودزن در شمال استان فارس با ترکیب خروجی مدل LARS-WG به عنوان ورودی مدل SWAT نشان داد که متوسط بارش سالانه در دوره ۲۰۸۵-۲۰۲۶ در سناریوهای مختلف بین ۱۳ تا ۱۷ درصد کاهش و متوسط سالیانه دبی ورودی به سد ۴۸ تا ۵۰ درصد کاهش خواهد یافت (نادری، ۲۰۲۰). طبق پیش‌بینی‌های انجام شده توسط مدل LARS-WG در ترکیب با مدل هیدرولوژیک SIMHYD در حوضه آبریز سیلاخور رحیم‌آباد لرستان، بارش و رواناب در دوره ۲۰۶۵-۲۰۴۶، نسبت به دوره پایه کاهش خواهد یافت (کونانی<sup>۱</sup> و همکاران، ۲۰۲۱). تغییر میزان رواناب حوضه آبخیز زیارت استان گلستان ایران، در دو دوره ۲۰۶۰-۲۰۴۱ و ۲۰۸۰-۲۰۶۱، در مقایسه با دوره پایه، در سناریوهای RCP2.6، RCP4.5 و RCP8.5، در محدوده ۳۷۳/۰- تا ۲۰۸/۰+ متر مکعب بر ثانیه پیش‌بینی شده است (سیلاخوری و همکاران، ۲۰۲۲).

علیرغم قابلیت‌های چشمگیر مدل‌های فرایند محور از قبیل SWAT، CLHMS، IHACRES و ARNO که در مدل-سازی فرایندهای هیدرولوژیک و دبی رودخانه در تحقیقات

<sup>1</sup> Kounani



شکل (۵) دبی روزانه و دبی حداکثر و حداقل پیش‌بینی شده در آینده (۲۰۲۱-۲۰۴۰) در سناریوهای مختلف تغییر اقلیم در مقایسه با دبی دوره پایه (۲۰۰۱-۲۰۲۰)

### نتیجه‌گیری

را نشان داد. با این حال، مجموع بارندگی سالانه، در همه سناریوهای تغییر اقلیم در آینده افزایش خواهد یافت. بیشترین افزایش بارندگی سالانه در آینده، نسبت به دوره پایه، در سناریوی RCP26، به میزان ۱۴٪ مشاهده شد. طبق یافته‌های این تحقیق، حداکثر دبی، در سناریوی RCP26 حدود ۱۸ درصد افزایش خواهد یافت. بطور کلی می‌توان نتیجه گرفت که جهت‌های مختلف تغییر دبی پیش‌بینی‌شده رودخانه، در مناطق مختلف، نیازمند تحلیل دقیق ماهانه و فصلی و بررسی دلایل تأثیرگذار بر این تغییرات است. ارزیابی و پیش‌بینی دبی رودخانه‌ها، تحت تأثیر تغییرات اقلیم در آینده در مناطق مختلف با اقلیم‌های متفاوت و همچنین تحقیقات بیشتر، در سایر سناریوهای GCM، برای تهیه راهنمای جامع شرایط احتمالی آینده، جهت تصمیم‌گیری صحیح و به موقع، در مدیریت منابع آب، برای رفع مشکلات تأمین آب شرب و کشاورزی بر اساس چالش‌های خاص هر منطقه ضروری است.

در این مطالعه تلاش شد تا با استفاده از ترکیب هوش مصنوعی و ریزمقیاس‌نمایی مدل LARS-WG، تأثیر تغییر اقلیم بر دبی یکی از شاخه‌های رودخانه کشف‌رود در خراسان رضوی در سناریوهای مختلف تغییر اقلیم در دوره آتی (۲۰۲۱-۲۰۴۰) بررسی شود. عملکرد مدل‌های MLP و CNN در مدل‌سازی بارش-رواناب با ورودی‌هایی از بارش و دبی روزانه با تأخیرهای مختلف در چندین سناریو، با یکدیگر مقایسه شده و مدل CNN، به عنوان مدل برتر، انتخاب گردید. پیش‌بینی‌های LARS-WG6 نشان داد که حداقل و حداکثر دما در آینده (۲۰۴۰-۲۰۲۱)، در سه سناریوی تغییر اقلیم، در منطقه مورد مطالعه، افزایش خواهد یافت. بیشترین افزایش دمای حداقل و حداکثر، مربوط به سناریوی RCP85 بوده و پس از آن به ترتیب RCP26 و RCP45 قرار دارند که در آن، افزایش دما در ماه‌های مختلف در محدوده ۰/۳ تا ۲/۱ درجه سانتیگراد خواهد بود. تغییرات ماهانه بارش، در سناریوهای مختلف، پیش‌بینی افزایش و کاهش متفاوتی

irrigation in Myandoab-Iran. *Archives of Agronomy and Soil Science*, 64(5), 731-746.

2- Baguis, P., Roulin, E., Willems, P. and Ntegeka, V. (2010). Climate change scenarios for precipitation and

### مراجع

1- Azad, N., Behmanesh, J., Rezaverdinejad, V. and Tayfeh Rezaie, H. (2018). Climate change impacts modeling on winter wheat yield under full and deficit

- network model for rapid prediction of fluvial flood inundation. *Journal of Hydrology*, 590, 125481.
- 16- Kalteh, A. M. (2013). Monthly river flow forecasting using artificial neural network and support vector regression models coupled with wavelet transform. *Computers & Geosciences*, 54, 1-8.
- 17- Kavwenje, S., Zhao, L., Chen, L. and Chaima, E. (2022). Projected temperature and precipitation changes using the LARS-WG statistical downscaling model in the Shire River Basin, Malawi. *International Journal of Climatology*, 42(1), 400-415.
- 18- Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M. and Inman, D. J. (2021). 1D convolutional neural networks and applications: A survey. *Mechanical systems and signal processing*, 151, 107398.
- 19- Kounani, Z., Ildoromi, A., zenivand, H. and Nouri, H. (2021). Impact of climate change on runoff of Silakhor-Rahimabad Basin in Lorestan. *Hydrogeomorphology*, 7(25), 1-17. (In Persian)
- 20- Kourgialas, N. N., Dokou, Z., & Karatzas, G. P. (2015). Statistical analysis and ANN modeling for predicting hydrological extremes under climate change scenarios: The example of a small Mediterranean agro-watershed. *Journal of environmental management*, 154, 86-101.
- 21- Krizhevsky, A., Sutskever, I. and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- 22- Le, X. H., Nguyen, D. H., Jung, S., Yeon, M. and Lee, G. (2021). Comparison of deep learning techniques for river streamflow forecasting. *IEEE Access*, 9, 71805-71820.
- 23- Le, T. B. and Sharif, H. O. (2015). Modeling the projected changes of river flow in central Vietnam under different climate change scenarios. *Water*, 7(7), 3579-3598.
- 24- Masood, M. and Takeuchi, K. (2016). Climate change impacts and its implications on future water resource management in the Meghna Basin. *Futures*, 78, 1-18.
- 25- Mavromatis, T. and Hansen, J. W. (2001). Interannual variability characteristics and simulated crop response of four stochastic weather generators. *Agricultural and forest meteorology*, 109(4), 283-296.
- 26- McGuire, A. D., Sitch, S., Clein, J. S., Dargaville, R., Esser, G., Foley, J., ... and Wittenberg, U. (2001). Carbon balance of the terrestrial biosphere in the twentieth century: Analyses of CO<sub>2</sub>, climate and land use effects with four process-based ecosystem models. *Global biogeochemical cycles*, 15(1), 183-206.
- 27- Mehan, S., Guo, T., Gitau, M. W. and Flanagan, D. C. (2017). Comparative study of different stochastic weather generators for long-term climate data simulation. *Climate*, 5(2), 26.
- 28- Mohammed, Z. M. and Hassan, W. H. (2022). Climate change and the projection of future temperature and precipitation in southern Iraq using a potential evapotranspiration over central Belgium. *Theoretical and applied climatology*, 99(3), 273-286.
- 3- Bannayan, M. and Hoogenboom, G. (2009). Using pattern recognition for estimating cultivar coefficients of a crop simulation model. *Field Crops Research*, 111(3), 290-302.
- 4- Bozorg-Haddad, O., Zarezadeh-Mehrizi, M., Abdi-Dehkordi, M., Loáiciga, H. A. and Mariño, M. A. (2016). A self-tuning ANN model for simulation and forecasting of surface flows. *Water Resources Management*, 30(9), 2907-2929.
- 5- Chen, H., Guo, J., Zhang, Z. and Xu, C. Y. (2013). Prediction of temperature and precipitation in Sudan and South Sudan by using LARS-WG in future. *Theoretical and Applied Climatology*, 113(3), 363-375.
- 6- Dibike, Y. B. and Coulibaly, P. (2005). Hydrologic impact of climate change in the Saguenay watershed: comparison of downscaling methods and hydrologic models. *Journal of hydrology*, 307(1-4), 145-163.
- 7- Ensaniyat, N. H., Shahkarami, N., Jafarina, R. and Rezaei, J. (2021). Reducing Predictive Uncertainty in Real-Time Reservoir Operations by Coupling LARS-WG with ARNO Continuous Rainfall-Runoff Model. *Journal of Hydrologic Engineering*, 26(10), 05021025.
- 8- Gebrehiwot, A., Hashemi-Beni, L., Thompson, G., Kordjamshidi, P. and Langan, T. E. (2019). Deep convolutional neural network for flood extent mapping using unmanned aerial vehicles data. *Sensors*, 19(7), 1486.
- 9- Ghazavi, R., Nadimi, M., Omidvar, E. and Imani, R. (2018). The Study of the Effects of the Future Climate Change on Discharge Variation of the Herchay River using SWAT and LARS-WG. *Hydrogeomorphology*, 5(15), 54-79. (In Persian)
- 10- Harmsen, E. W., Miller, N. L., Schlegel, N. J. and Gonzalez, J. E. (2009). Seasonal climate change impacts on evapotranspiration, precipitation deficit and crop yield in Puerto Rico. *Agricultural water management*, 96(7), 1085-1095.
- 11- Heydari Tasheh Kabood, S., Hosseini, S. A. and Heydari Tasheh Kabood, A. (2020). Investigating the effects of climate change on stream flows of Urmia Lake basin in Iran. *Modeling Earth Systems and Environment*, 6(1), 329-339.
- 12- Hosseiny, H. (2021). A deep learning model for predicting river flood depth and extent. *Environmental Modelling & Software*, 145, 105186.
- 13- Hussain, D., Hussain, T., Khan, A. A., Naqvi, S. A. A. and Jamil, A. (2020). A deep learning approach for hydrological time-series prediction: A case study of Gilgit river basin. *Earth Science Informatics*, 13(3), 915-927.
- 14- IPCC. (2014). Synthesis Report. Contribution of working groups I, II and III to the fifth assessment report of the intergovernmental panel on climate change, 151(10.1017).
- 15- Kabir, S., Patidar, S., Xia, X., Liang, Q., Neal, J. and Pender, G. (2020). A deep convolutional neural

- 43- Sha, J., Li, X. and Wang, Z. L. (2019). Estimation of future climate change in cold weather areas with the LARS-WG model under CMIP5 scenarios. *Theoretical and Applied Climatology*, 137(3), 3027-3039.
- 44- Sharafati, A. and Pezeshki, E. (2020). A strategy to assess the uncertainty of a climate change impact on extreme hydrological events in the semi-arid Dehbar catchment in Iran. *Theoretical and Applied Climatology*, 139(1), 389-402.
- 45- Sharafati, A., Pezeshki, E., Shahid, S. and Motta, D. (2020). Quantification and uncertainty of the impact of climate change on river discharge and sediment yield in the Dehbar river basin in Iran. *Journal of Soils and Sediments*, 20(7), 2977-2996.
- 46- Silakhori, E., Dahmardeh Ghaleno, M. R., Meshram, S. G. and Alvandi, E. (2022). To assess the impacts of climate change on runoff in Golestan Province, Iran. *Natural Hazards*, 1-20.
- 47- Smakhtin, V. U. (2001). Low flow hydrology: a review. *Journal of hydrology*, 240(3-4), 147-186.
- 48- Stevens, B., Giorgetta, M., Esch, M., Mauritsen, T., Crueger, T., Rast, S., ... and Roeckner, E. (2013). Atmospheric component of the MPI-M Earth system model: ECHAM6. *Journal of Advances in Modeling Earth Systems*, 5(2), 146-172.
- 49- Van, S. P., Le, H. M., Thanh, D. V., Dang, T. D., Loc, H. H. and Anh, D. T. (2020). Deep learning convolutional neural network in rainfall-runoff modelling. *Journal of Hydroinformatics*, 22(3), 541-561.
- 50- Wang, Z., Yan, W. and Oates, T. (2017). Time series classification from scratch with deep neural networks: A strong baseline. In 2017 International joint conference on neural networks (IJCNN) (pp. 1578-1585). IEEE.
- 51- Yimer, G., Jonoski, A. and Griensven, A. V. (2009). Hydrological response of a catchment to climate change in the upper Beles river basin, upper blue Nile, Ethiopia. *Nile Basin Water Engineering Scientific Magazine*, 2(1), 49-59.
- 52- Zhu, Y., Lin, Z., Wang, J., Zhao, Y. and He, F. (2016). Impacts of climate changes on water resources in Yellow River Basin, China. *Procedia engineering*, 154, 687-695.
- LARS-WG model. *Modeling Earth Systems and Environment*, 5, 1-14.
- 29- Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D. and Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885-900.
- 30- Naderi, M. (2020). The impact of climate change on dorudzan dam inflow and reservoir volume, Northern Fars province. *Scientific Quarterly Journal, GEOSCIENCES*, 29 (115), 259-267. (In Persian)
- 31- Nash, J. E. and Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I—A discussion of principles. *Journal of hydrology*, 10(3), 282-290.
- 32- Nijssen, B., O'Donnell, G. M., Hamlet, A. F. and Lettenmaier, D. P. (2001). Hydrologic sensitivity of global rivers to climate change. *Climatic change*, 50(1), 143-175.
- 33- Osman, Y., Al-Ansari, N. and Abdellatif, M. (2019). Climate change model as a decision support tool for water resources management in northern Iraq: a case study of Greater Zab River. *Journal of Water and Climate Change*, 10(1), 197-209.
- 34- Racsco, P., Szeidl, L. and Semenov, M. (1991). A serial approach to local stochastic weather models. *Ecological modelling*, 57(1-2), 27-41.
- 35- Ritter, A. and Munoz-Carpena, R. (2013). Performance evaluation of hydrological models: Statistical significance for reducing subjectivity in goodness-of-fit assessments. *Journal of Hydrology*, 480, 33-45.
- 36- Saddique, N., Usman, M. and Bernhofer, C. (2019). Simulating the impact of climate change on the hydrological regimes of a sparsely gauged mountainous basin, Northern Pakistan. *Water*, 11(10), 2141.
- 37- Sarzaeim, P., Bozorg-Haddad, O., Bozorgi, A., & Loáiciga, H. A. (2017). Runoff projection under climate change conditions with data-mining methods. *Journal of Irrigation and Drainage Engineering*, 143(8), 04017026.
- 38- Semenov, M. A. and Barrow, E. M. (1997). Use of a stochastic weather generator in the development of climate change scenarios. *Climatic change*, 35(4), 397-414.
- 39- Semenov, M. A. and Barrow, E. M. (2002). LARS-WG A stochastic weather generator for use in climate impact studies. User Man Herts UK.
- 40- Semenov, M. A. and Brooks, R. J. (1999). Spatial interpolation of the LARS-WG stochastic weather generator in Great Britain. *Climate Research*, 11(2), 137-148.
- 41- Semenov, M. A., Brooks, R. J., Barrow, E. M. and Richardson, C. W. (1998). Comparison of the WGEN and LARS-WG stochastic weather generators for diverse climates. *Climate research*, 10(2), 95-107.
- 42- Semenov, M. A. and Stratonovitch, P. (2010). Use of multi-model ensembles from global climate models for assessment of climate change impacts. *Climate research*, 41(1), 1-14.

## Comparison of artificial neural network and deep learning models in rainfall-runoff modeling of Kashafrud river and predicting climate change impact on meteorological parameters and river flow

Mohamad Hossain Shahani <sup>1</sup>  
Vahid Rezaverdinejad \*<sup>2</sup>  
Seyed Abbas Hosseini <sup>3</sup>

### Abstract

The main objective of this research is to compare the performance of Artificial Neural Network (ANN) and Deep Neural Network (DNN) models in rainfall-runoff modeling of Kashafrud in one of its permanent branches and to predict the effects of climate change on meteorological parameters and river discharge. For this purpose, the performance of two models of Multilayer Perceptron (MLP) and Convolutional Neural Network (CNN) were compared in simulation of rainfall-runoff. The input data include daily rainfall and river discharge with different lags in several scenarios. The efficient model and scenario were selected. Then, the predicted data of LARS-WG6 in the future period (2021-2040) considering different "Representative Concentration Pathway" Scenarios (RCP26, RCP45 and RCP85) was used as the input of the best artificial intelligence model to predict the daily river discharge and extreme amounts. The results indicated that the CNN model based on the scenario, in which 0-2 days and 1-day lags were considered for rainfall and discharge data respectively, presented the best performance. The projected results of LARS-WG6 showed that the minimum and maximum temperature will increase in the range of 0.3 to 2.1 °C in different months. Annual precipitation will increase in all climate scenarios in the future. The most significant rise of the projected data compared to the historical period will happen in RCP26 by 14% and 18% in the rainfall and maximum discharge respectively.

### Keywords

Artificial Neural Network, Climate Change, Deep Learning, Kashafrud, Rainfall-Runoff

<sup>1</sup> Department of Civil Engineering, Faculty of Civil Engineering, Architecture and Art, Science and Research Branch, Islamic Azad University, Tehran, Iran

\*<sup>2</sup> Department of Water Engineering, Faculty of Agriculture, Urmia University, Urmia, Iran. E-mail: [v.verdinejad@urmia.ac.ir](mailto:v.verdinejad@urmia.ac.ir)

<sup>3</sup> Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.