



## بررسی توانمندی مدل شبکه عصبی مصنوعی در شبیه‌سازی فرآیند بارش-رواناب در شرایط تغییر اقلیم (مطالعه موردی: حوزه سد پاشاکلا بابل)

معصومه خادمی<sup>۱</sup>، رامین فضل‌اولی<sup>۲</sup> و علیرضا عمادی<sup>۳</sup>

۱- ۳- دانشجوی دکتری و دانشیار، دانشکده مهندسی زراعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری  
۲- دانشیار، دانشکده مهندسی زراعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری، (نویسنده مسوول: raminfazl@yahoo.com)  
تاریخ دریافت: ۹۵/۵/۳۱ تاریخ پذیرش: ۹۵/۱۱/۲۵

### چکیده

پیش‌بینی جریان رودخانه‌ها نقش بسزایی در برنامه‌ریزی، مدیریت و بهره‌برداری از منابع آب دارد. برای دستیابی به این هدف و با توجه به پدیده‌ی گرمایش جهانی، لازم است سری زمانی بارش و رواناب روزانه برای دوره‌های آبی شبیه‌سازی شود. لذا ضروریست آشکارسازی رخداد تغییر اقلیم و تأثیر آن بر بارش و رواناب در سطح حوزه مورد بررسی قرار گیرد. در گام اول این پژوهش، با استفاده از آزمون آماری روند من-کندال، رخداد تغییر اقلیم در حوزه پاشاکلا بابل در استان مازندران به اثبات رسید. نتایج بررسی ۳۶ سال آمار متوسط دمای روزانه، نشان‌دهنده روند افزایشی متوسط دما در سطح حوزه می‌باشد. در گام دوم، از مدل لاریس تحت مدل گردش عمومی جو HadCM3 و سناریوی A2، برای تولید سری زمانی بارش روزانه در دوره آبی استفاده شد. به این منظور داده‌های بارش، دمای کمینه، دمای بیشینه و ساعات آفتابی برای دوره پایه ۱۲ ساله (۲۰۱۵-۲۰۰۴) وارد مدل شده و سری زمانی بارش روزانه در سطح حوزه برای دوره آبی ۱۰ ساله (۲۰۲۵-۲۰۱۶) پیش‌بینی شد. در گام سوم، از مدل شبکه عصبی مصنوعی، برای شبیه‌سازی فرآیند بارش-رواناب در شرایط تغییر اقلیم و تولید سری زمانی رواناب روزانه در دوره آبی استفاده شد. در نهایت، به منظور بالا بردن قابلیت مدل شبکه عصبی مصنوعی در پیش‌بینی رواناب روزانه، علاوه بر داده‌های بارش روزانه پیش‌بینی شده، داده‌های بارش و رواناب یک روز قبل نیز به عنوان عوامل مؤثر در رواناب روز جاری وارد مدل شده و با استفاده از نرون‌های بارش و رواناب ضریب همبستگی برابر با ۰/۸ به دست آمد. این ضریب همبستگی در سطح ۱ درصد معنی‌دار بوده و نشان‌دهنده قابلیت مدل در شبیه‌سازی فرآیند بارش-رواناب می‌باشد.

واژه‌های کلیدی: تغییر اقلیم، رواناب روزانه، مدل شبکه عصبی مصنوعی، مدل لاریس

### مقدمه

تغییر اقلیم عبارت است از تغییرات رفتار آب و هوایی یک منطقه نسبت به رفتاری که در طول یک افق زمانی بلند مدت از اطلاعات مشاهده‌ای یا ثبت شده در آن منطقه مورد انتظار است (۱۲). با تغییر اقلیم، رژیم هیدرولوژیکی رودخانه‌ها و در نتیجه فراوانی وقوع و شدت سیلاب‌ها نیز تغییر می‌نماید. یکی از مهم‌ترین مسایل در مهندسی منابع آب، پیش‌بینی میزان دبی جریان رودخانه می‌باشد که از نظر برنامه‌ریزی منابع آب دارای اهمیت است. پیش‌بینی در هیدرولوژی به معنی تخمین شرایط هیدرولوژیکی و هواشناسی در یک بازه زمانی خاص می‌باشد (۱۳). بهره‌برداری بهینه و مناسب از منابع آب یکی از وظایف مهم مدیران منابع آب می‌باشد. لذا عدم تخمین مناسب رواناب حاصل از بارش در حوزه‌های آبریز، مدیریت بهینه منابع آبی، به‌ویژه مدیریت بهره‌برداری مخازن سدها را دچار مشکل می‌نماید. در این میان مقوله شبیه‌سازی به‌عنوان راهکاری مناسب به‌منظور تخمین رواناب، نمود می‌یابد. تاکنون مدل‌ها و روش‌های مختلفی برای شبیه‌سازی و تخمین فرآیند بارش رواناب ارایه شده است که با استفاده از آن‌ها دبی جریان رودخانه‌ها پیش‌بینی می‌شود. در این میان مدل شبکه عصبی مصنوعی ابزار قدرتمندی است که با تقلید ساده از سیستم عصبی بیولوژیک انسان ساخته شده و به‌منظور شبیه‌سازی و پیش‌بینی روزانه دبی جریان رودخانه در برنامه‌ریزی منابع آب مورد استفاده قرار می‌گیرد. ثانی خانی و همکاران (۱۹) به بررسی اثرات تغییر اقلیم بر رواناب در حوزه قره چای در استان مرکزی در سه افق زمانی آینده پرداختند. برای ریزمقیاس‌نمایی متغیرها از مدل لاریس با مدل گردش عمومی

HadCM3 تحت سناریوهای A1B، A2 و B1 استفاده شد. نتایج حاکی از روند کاهشی بارش و روند افزایشی دما در سطح حوزه در بازه‌های زمانی آینده بوده است. برای شبیه‌سازی رواناب از انواع مدل فازی-عصبی تطبیقی شامل افزاز شبکه و دسته‌بندی تفریقی استفاده شد. نتایج حاکی از روند کاهشی دبی در افق آبی بوده است. نتایج به‌دست آمده در این تحقیق وجود تغییر اقلیم در سطح حوزه را تأیید می‌نمایند.

احمدی و همکاران (۱) برای پیش‌بینی جریان روزانه رودخانه باراندوزچای ارومیه در دوره آماری (۱۳۸۸-۱۳۵۲) از مدل غیرخطی سری زمانی دوخطی و روش برنامه‌ریزی ژنتیک استفاده نمودند و نتایج را بر اساس شاخص‌های آماری جذر میانگین مربعات خطا و ضریب همبستگی مورد مقایسه قرار دادند. به‌طور کلی با مقایسه نتایج بدست آمده از دو الگوی نامبرده می‌توان نتیجه گرفت که روش برنامه‌ریزی ژنتیک با ۲۲/۹ درصد خطای کم‌تر نسبت به مدل دوخطی، جریان روزانه رودخانه باراندوزچای را پیش‌بینی می‌نماید.

حجازی زاده و همکاران (۸)، متغیرهای اقلیمی شامل بارش، دمای کمینه و دمای بیشینه را با استفاده از مدل لاریس و سناریوهای مدل گردش عمومی جو HadCM3 تحت سناریوهای B1، A2 و A1B برای استان سمنان شبیه‌سازی نمودند. نتایج نشان داد که این مدل، قابلیت بالایی در شبیه‌سازی سری‌های زمانی متغیرهای هواشناسی در این استان را دارد. در این بررسی روند افزایشی دما و کاهشی بارش در استان سمنان مشاهده شده که در تمام سطح استان این روند یکسان نیست.

هوانگ و همکاران (۱۰) تأثیر تغییر اقلیم بر شرایط سیلاب رودخانه‌ای در آلمان را بررسی نمودند. این محققین در این مطالعه برای شبیه‌سازی اقلیمی از دو مدل اقلیمی ناحیه‌ای (RCM) دینامیکی REMO و CCLM و یک مدل اقلیمی ناحیه‌ای آماری-تجربی تحت سناریوهای انتشار A2، B1 و A1B و به‌منظور شبیه‌سازی هیدرولوژیکی از مدل یکپارچه آب و خاک (SWIM) استفاده نمودند. نتایج نشان داد با استفاده از مدل آماری-تجربی تحت همه سناریوهای اقلیمی، در بیشتر رودخانه‌ها یک روند کاهشی در سطح سیلاب مشاهده شده است. در حالی که شبیه‌سازی‌های به‌دست آمده از مدل‌های دینامیکی، در بعضی رودخانه‌ها افزایش ۱۰ تا ۲۰ درصدی در سطح سیلاب و در برخی دیگر کاهش ۲۰ درصدی در سطح سیلاب مشاهده شده است. در نهایت افزایش معنی‌دار روند دبی‌های حداکثر با شبیه‌سازی تحت مدل‌های دینامیکی و کاهش معنی‌دار روند سیلاب در مدل آماری-تجربی مشاهده شده است.

کامیکی و همکاران (۲) از مدل‌های گردش عمومی جو (GCMs) و روش‌های ریزمقیاس‌نمایی به همراه یک مدل بارش-رواناب مداوم، برای تولید سری زمانی ساعتی دما، بارش و دبی استفاده نموده و با استفاده از این روش‌ها فراوانی حداکثر سالانه بارش و دبی، برای دوره زمانی آینده (۲۰۹۹-۲۰۷۰) را در بیش از سه زیر حوزه کوچک در حوزه رودخانه Upper Tiber در مرکز ایتالیا پیش‌بینی نمودند. مقایسه بین خروجی مدل‌های GCMs برای دوره زمانی آینده (۲۰۹۹-۲۰۷۰) و دوره زمانی پایه (۱۹۹۰-۱۹۶۱) حدود ۳۰ درصد کاهش در میزان متوسط سالانه بارش و حدود ۴۰ درصد افزایش در میزان متوسط درجه حرارت سالانه را نشان داده است. نتایج حاکی از آن است که ویژگی‌های هیدرولوژیکی حوزه مورد مطالعه نقش مهمی در ارزیابی اثرات تغییر اقلیم دارد و میزان حداکثر سالانه (بارش و دبی)، وابسته به مدل‌های GCMs و روش‌های ریزمقیاس‌نمایی انتخابی می‌باشد.

از پژوهش‌های متعدد می‌توان نتیجه گرفت که تغییر اقلیم، افزایش دمای متوسط کره زمین، افزایش پدیده‌های حدی اقلیمی نظیر سیل، طوفان، تگرگ، طوفان‌های حاره‌ای، امواج گرمایی، افزایش سطح آب دریاها، ذوب شدن یخ‌های قطبی، امواج گرمایی و سرماهای نابهنگام را به همراه خواهد داشت. لذا بررسی پدیده تغییر اقلیم و تأثیر آن بر بارش و رواناب محدوده مطالعاتی ضرورت می‌یابد تا بتوان براساس پیش‌بینی روزانه دبی جریان رودخانه به برنامه‌ریزی منابع آب و کنترل سیلاب سد پاشاکالا بابل پرداخت. هدف اصلی این پژوهش، آشکارسازی رخداد تغییر اقلیم در محدوده مطالعاتی (حوزه پاشاکالا) با استفاده از آزمون آماری روند من-کندال و شبیه‌سازی فرآیند بارش-رواناب در شرایط تغییر اقلیم می‌باشد. به‌این منظور از مدل لارس تحت مدل گردش عمومی جو HadCM3 و سناریوی A2 به‌منظور پیش‌بینی بارش در سطح حوزه برای دوره‌های آتی و از مدل شبکه عصبی مصنوعی به‌منظور پیش‌بینی سری زمانی روزانه استفاده شده است.

حسنپور کاشانی و همکاران (۷) به‌منظور شبیه‌سازی فرآیند بارش-رواناب در حوزه آبریز ناورود از مدل ولترای مرتبه محدود و شبکه‌های عصبی مصنوعی استفاده نمودند. به‌این منظور به ترتیب ۷۰ درصد رویدادها را برای آموزش و ۳۰ درصد رویدادها را برای تست مدل بکار بردند. نتایج نشان داد که مدل هوشمند شبکه عصبی مصنوعی از توانایی بالاتری نسبت به مدل ولترا در پیش‌بینی‌های رواناب حوزه آبریز ناورود برخوردار است.

حسینی و همکاران (۹) به‌منظور بررسی جریان‌ات رودخانه صوفیچای واقع در حوزه دریاچه ارومیه از مدل بارش-رواناب IHACRES استفاده نمودند. نتایج نشان داد که اختلاف میان مدل‌های اقلیمی تحت سناریو انتشار B1 و A2 برای دوره آتی نزدیک (۲۰۳۰-۲۰۱۱) و تحت سناریو انتشار B1 برای دوره آتی دور (۲۰۶۵-۲۰۴۶) به خصوص در فصول گرم سال نسبتاً اندک می‌باشد. اما این اختلاف تحت سناریو انتشار A2 برای دوره آتی دور (۲۰۶۵-۲۰۴۶) بسیار قابل توجه می‌باشد. همچنین عدم قطعیت انتخاب سناریوهای انتشار مختلف برای دوره نزدیک کم و برای اواسط قرن بیشتر می‌باشد.

زحمتکش و همکاران (۲۳) به بررسی اثر تغییر اقلیم بر رواناب شهری در حوزه رودخانه Bronx در شهر نیویورک پرداختند. این محققین به‌منظور نشان دادن اثر تغییر اقلیم بر بارش‌های آتی، از ۱۳۴ مدل پیش‌بینی گردش عمومی جو (GCM) استفاده نمودند. در این پژوهش برای انتخاب حداقل، حداکثر و متوسط سناریوهای بارش روزانه در دوره زمانی (۲۰۵۹-۲۰۳۰)، یک روش فاکتور تغییر جدید ارایه شده است. تجزیه و تحلیل نتایج فاکتور حساسیت تغییر اقلیم (SCSF) نشان داد که رواناب در چنین شرایطی بیشتر تابعی از شیب زیر حوزه می‌باشد. در زیر حوزه‌هایی با SCSF بیشتر از ۰/۱، تغییر اقلیم به میزان ۴۰ درصد یا بیشتر روی حجم رواناب اثر خواهد داشت.

لیو و همکاران (۱۴) برای بررسی اثر تغییر اقلیم بر دبی جریان در حوزه رودخانه زرد از مدل HadCM3، تحت سناریوهای A2 و B2 و به‌منظور ریزمقیاس‌نمایی خروجی‌های مدل اقلیمی از مدل SDSM استفاده نمودند. سپس مدل هیدرولوژیکی نیمه توزیعی SWAT را برای شبیه‌سازی دبی رودخانه به‌کار بردند. نتایج روند افزایشی میانگین سالانه دمای کمینه، دمای بیشینه و بارش را نشان داده است.

فیه‌ها و همکاران (۴) دو مدل SDSM و لارس را برای کوچک مقیاس‌سازی و شبیه‌سازی داده‌های بارندگی با داده‌های بزرگ مقیاس GGCM و HadCM3 تحت سناریوهای A2 و B2 برای حوزه رودخانه Upper Tiber در ایتالیای مرکزی مقایسه نمودند. اگرچه دو روش کوچک مقیاس‌سازی همان نتایج عددی یکسان را نشان ندادند؛ ولی هر دو مدل تأثیر تغییر اقلیم در حوزه مطالعاتی در تمام سری‌های زمانی از بارندگی و دما را یکسان نشان دادند. در مجموع عملکرد دو مدل با نتایج مطالعات قبلی و پروژه‌های IPCC AR4 یکسان بود.

## مواد و روش‌ها

### معرفی محل مطالعه (حوزه پاشاکلا)

حوزه آبریز پاشاکلا بخشی از حوزه آبریز رودخانه بابلرود می‌باشد که به‌طور تقریبی در طول جغرافیایی شرقی ۵۲ درجه و ۴۲ دقیقه و ۴۳ ثانیه تا ۵۲ درجه و ۵۵ دقیقه و ۵۰ ثانیه و عرض جغرافیایی شمالی ۳۶ درجه و ۴ دقیقه و ۳۴ ثانیه تا ۳۶ درجه و ۱۴ دقیقه و ۵۶ ثانیه واقع شده است. مساحت حوزه حدود ۲۱۱ کیلومتر مربع و محیط آن ۶۵ کیلومتر، حداقل ارتفاع حوزه ۲۴۶ متر، متوسط ارتفاع حوزه ۱۰۲۷ متر و حداکثر ارتفاع حوزه ۲۹۱۱ متر از سطح آب‌های آزاد می‌باشد. رودخانه‌های آذر رود، کارسنگ رود و اسکلیم رود به‌عنوان سه رودخانه اصلی ورودی به مخزن سد البرز در حوزه آبریز پاشاکلا می‌باشند (۳). شکل ۱ موقعیت حوزه آبریز پاشاکلا و ایستگاه‌های هواشناسی اطراف آن را نشان می‌دهد. در این پژوهش، به دلیل عدم وجود ایستگاه‌های هواشناسی در حوزه آبریز پاشاکلا، از داده‌های هواشناسی ایستگاه‌های مجاور تا محدوده ۲۵ کیلومتری حوزه به شرح ذیل استفاده شده است:


- ۱- به منظور بررسی آشکارسازی تغییر اقلیم در محدوده مطالعاتی از داده‌های مشاهداتی متوسط دما در ایستگاه سینوپتیک قراخیل در پایین دست حوزه آبریز پاشاکلا استفاده شد. در این بخش از داده‌های مشاهداتی متوسط دمای روزانه در ایستگاه سینوپتیک قراخیل برای مدت ۳۶ سال از سال ۱۳۵۹ لغایت ۱۳۹۴ هجری شمسی به‌منظور آشکارسازی تغییر اقلیم در محدوده مطالعاتی، مورد بررسی قرار گرفت. پارامترهای اقلیمی در مقیاس زمان و مکان به دلایل زیادی تغییر می‌کنند که باید نحوه تغییرات آن‌ها بر اساس مشاهدات و با بهره‌گیری از روش‌های آماری تعیین شود. برای تعیین نرمال بودن و یا نبودن توزیع داده‌های مشاهداتی متوسط دما در محدوده مطالعاتی (ایستگاه سینوپتیک قراخیل) از آزمون ناپارامتری کولموگروف-اسمیرنوف (K-S) استفاده شده که

پارامترهای آن عبارت است از: N تعداد داده‌ها، Avg میانگین، Std dev انحراف معیار، Skew چولگی، Kurt کشیدگی، D max+ حداکثر اختلاف مثبت، D max- حداکثر اختلاف منفی، D max abs حداکثر اختلاف مطلق، Z آماره آزمون K-S و P احتمال معنی‌داری. آزمون من-کندال یکی از رایج‌ترین آزمون‌های ناپارامتری تحلیل سری‌های هواشناسی و هیدرولوژیکی به شمار می‌رود. در این پژوهش، به‌منظور بررسی روند تغییرات زمانی دما در مقیاس فصلی و سالانه و آشکارسازی پدیده‌ی تغییر اقلیم در محدوده مطالعاتی (ایستگاه سینوپتیک قراخیل) از آزمون من-کندال استفاده شده است. چنانچه شاخص آماری آزمون من-کندال (Z) بزرگتر از  $+1/96$  و یا کوچکتر از  $-1/96$  باشد، داده‌ها دارای روند می‌باشند. در غیراین‌صورت داده‌ها تصادفی و بدون روند است.

۲- با استفاده از داده‌های مشاهداتی بارش ایستگاه‌های هواشناسی آلاشت، قرآن تالار و شیرگاه و به‌کارگیری روش چند ضلعی‌های تیسن، بارندگی در سطح حوزه آبریز پاشاکلا تخمین زده شد.

۳- با استفاده از داده‌های مشاهداتی دمای کمینه و بیشینه ایستگاه‌های هواشناسی آلاشت، پل سفید و قراخیل و به‌کارگیری گرادیان دمایی منطقه، دمای کمینه و بیشینه در سطح حوزه آبریز پاشاکلا تخمین زده شد.

۴- با استفاده از داده‌های مشاهداتی ساعات آفتابی ایستگاه‌های هواشناسی آلاشت، پل سفید و قراخیل و به‌کارگیری مقدار متوسط، ساعات آفتابی در سطح حوزه آبریز پاشاکلا تخمین زده شد. در ادامه ۱۲ سال داده مشاهداتی بارش، دمای کمینه و بیشینه و ساعات آفتابی در دوره پایه (۲۰۱۵-۲۰۰۴) در سطح حوزه آبریز پاشاکلا تهیه و به عنوان ورودی، وارد مدل لارس شده است. در جدول ۱ مشخصات ایستگاه‌های هواشناسی اطراف حوزه آبریز پاشاکلا ارائه شده است (۳).



شکل ۱- موقعیت حوزه پاشاکلا و ایستگاه‌های هواشناسی اطراف آن

Figure 1. The location of the Pashakola basin and the meteorological stations of around that

جدول ۱- مشخصات ایستگاه‌های هواشناسی اطراف حوزه آبریز پاشاکولا

Table 1. Specifications of meteorological stations around the Pashakola basin

نام ایستگاه	حوزه آبریز رودخانه	طول جغرافیایی شرقی	عرض جغرافیایی شمالی	ارتفاع از سطح آب‌های آزاد (متر)	سال تأسیس (هجری شمسی)	نوع ایستگاه
آلاشت	تالار	۵۲°۵۰'	۳۶°۰۴'	۱۶۸۰	۱۳۶۹	تبخیر سنجی
قرآن تالار	بابرود	۵۲°۴۶'	۳۶°۱۸'	۱۰۲	۱۳۲۸	باران سنجی
شیرگاه	تالار	۵۲°۵۳'	۳۶°۱۸'	۲۷۵	۱۳۳۷	باران سنجی
آلاشت	تالار	۵۲°۵۱'	۳۶°۰۵'	۱۹۰۰	۱۳۸۱	سینوپتیک
پل سفید	تالار	۵۳°۰۵'	۳۶°۰۸'	۶۱۰	۱۳۸۲	سینوپتیک
قراخیل	تالار	۵۲°۴۶'	۳۶°۲۷'	۱۴۷	۱۳۶۳	سینوپتیک

### مدل لارنس

مدل لارنس یک مدل مولد مصنوعی داده‌های آب و هوایی است که می‌توان از آن برای شبیه‌سازی داده‌های هواشناسی در یک مکان واحد تحت شرایط اقلیم حال و آینده استفاده نمود (۱۷). با استفاده از این مدل، برای یکسری از متغیرهای اقلیمی مانند بارش، دمای کمینه و بیشینه و تابش (یا ساعات آفتابی)، سری‌های زمانی روزانه تولید می‌شوند. در این پژوهش با استفاده از مدل لارنس سری‌های زمانی روزانه بارش برای سال‌های آتی تولید شده است. در این مدل فرآیند تولید داده‌های آب و هوایی مصنوعی در سه بخش انجام می‌گیرد (۲۱):

۱- واسنجی مدل (SITE ANALYSIS): در این بخش داده‌های آب و هوایی دیدبانی شده به‌منظور تعیین خصوصیات آماری تحلیل می‌شوند. در این بخش برای ارزیابی مدل لارنس از شاخص‌های آماری ضریب ناش-ساتکلیف (NS)، ضریب تبیین ( $R^2$ )، مجذور میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) استفاده شده است. ضریب ناش-ساتکلیف از منفی بی نهایت الی یک متغیر است. در صورتی که مقدار آن برابر با صفر یا کمتر از آن شود، مقادیر میانگین بارش ماهانه مشاهده شده بهتر از شبیه‌سازی شده توسط مدل می‌باشد. لذا هرچه مقدار ضریب ناش-ساتکلیف به عدد صفر نزدیک‌تر شود، بیانگر این است که شبیه‌سازی ضعیفی توسط مدل انجام گرفته است. در صورتی که مقدار آن برابر با یک شود، تطابق کامل بین مقادیر میانگین بارش ماهانه مشاهده شده و شبیه‌سازی شده برقرار می‌باشد. لذا هرچه مقدار ضریب ناش-ساتکلیف به عدد یک نزدیک‌تر شود، مدل از عملکرد بهتری برخوردار است.

### ضریب ناش-ساتکلیف (NS)

$$NS = 1 - \frac{\sum_{i=1}^n (obs_n - gen_n)^2}{\sum_{i=1}^n (obs_n - obs_n)^2} \quad (1)$$

### ضریب تبیین ( $R^2$ )

$$R^2 = \frac{\sum_{i=1}^n (obs_n - gen_n)^2}{\sqrt{\sum_{i=1}^n (obs_n)^2 \cdot \sum_{i=1}^n (gen_n)^2}} \quad (2)$$

### مدل‌های گردش عمومی جو (GCM)

مدل‌های گردش عمومی جو در واقع حل معادلات حاکم بر جو بر اساس قوانین نیوتن و ترمودینامیک می‌باشند که برای شبیه‌سازی و پیش‌بینی وقایع بزرگ مقیاس جو نظیر ارزیابی جبهه‌های طوفان‌های عظیم تا بیان فرآیندهای محلی و منطقه‌ای جو نظیر پدیده‌های بارش و رواناب بهتر عمل می‌نمایند (۲۲). ورودی اصلی مدل‌های اقلیمی راه، میزان انتشار گازهای گلخانه‌ای در دوره‌های آتی تشکیل می‌دهند. اما با توجه به این که تعیین میزان انتشار این گازها به‌طور قطعی امکان‌پذیر نیست؛ سناریوهای مختلفی به نام سناریوهای انتشار ارایه شده‌اند که در برگزیده مولفه‌هایی به‌منظور برآورد و تعیین تغییرات گازهای گلخانه‌ای مختلف در آینده می‌باشند. از آنجایی که ویژگی‌های سناریو انتشار A2 بدون توجه به محیط زیست و انتشار گازهای گلخانه‌ای بیشتر بر صنعتی شدن و رشد سریع کشورها تاکید دارد و از طرفی در سطح دنیا برای بررسی تغییرات تغییر اقلیم بر کشاورزی، منابع آب، هیدرولوژی و محیط زیست از این سناریو استفاده می‌شود، لذا این سناریو از میان سناریوهای موجود انتخاب شده است. در حال حاضر خروجی مدل‌های GCM، دقت مکانی و زمانی کمی دارند و هیچگاه نمی‌توانند مستقیماً برای پیش‌بینی‌های منطقه‌ای یا نقطه‌ای استفاده شوند. این مدل‌ها نیازمند ریزمقیاس‌نمایی می‌باشند تا با اعمال رفتارهای محلی در آن‌ها، پیش‌بینی‌ها در مقیاس محلی بهبود یابند (۲۲). در این پژوهش از بین مدل‌های ریزمقیاس‌نمایی، مدل لارنس به عنوان مولد مصنوعی داده‌های آب و هوایی و ابزاری برای تولید سناریوهای تغییر اقلیم چندساله در مقیاس زمانی روزانه استفاده شده است.


### مدل گردش عمومی جو HadCM3

مدل HadCM3 از نوع مدل‌های سه‌بعدی گردش عمومی اتمسفر-اقیانوس (AOGCM) می‌باشد و در مرکز هادلی سازمان هواشناسی انگلیس طراحی و توسعه یافته است. مدل HadCM3 از دو مولفه اتمسفری (HadAM3) و اقیانوسی (HadOM3) تشکیل شده است. شبیه‌سازی‌ها بر مبنای تقویم سال ۳۶۰ روزه و ماه‌های ۳۰ روزه انجام می‌شود. قدرت تفکیک بالای مولفه اقیانوسی، مهم‌ترین مزیت این مدل می‌باشد. مزیت دیگر این مدل، هماهنگی خوب بین مولفه‌های اتمسفری و اقیانوسی آن می‌باشد (۲۲).

۳- تولید داده (Generator): در اینجا داده‌های آب و هوایی مصنوعی با استفاده از فایل‌های بدست آمده از داده‌های آب و هوایی دیدبانی شده تولید می‌شوند که دارای خصوصیات آماری مشابه با دوره دیدبانی می‌باشد.

**مدل شبکه عصبی مصنوعی (ANN)**

مدل شبکه عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری و با استفاده از پردازشگرهایی به نام نرون تلاش می‌کند تا با شناخت روابط ذاتی بین داده‌ها، گاشتی (نظیر کردن یک عنصر به عنصر دیگر) میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارایه دهد. این سیستم از شمار زیادی عناصر پردازشی فوق العاده به هم پیوسته به نام نرون تشکیل شده که برای حل یک مسأله با هم هماهنگ عمل می‌کنند. هر شبکه عصبی مصنوعی از سه لایه‌ی: ورودی، پنهان و خروجی تشکیل شده که هر یک وظایف مجزایی دارند. 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. تابع انتقال بیان‌کننده پاسخ هر نرون به سیگنال ورودی آن نرون است. توابع انتقال معمول مورد استفاده در بکه‌های عصبی مصنوعی تابع سیگموئید و تانژانت هیپربولیک می‌باشد. هر شبکه با دریافت مثال‌هایی آموزش می‌بیند. آموزش فرآیندی است که در نهایت منجر به یادگیری می‌شود. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و محاسبه شده در حد قابل قبولی باشد (۲۰). ساختار شبکه عصبی مصنوعی پرسپترون چند لایه در شکل ۲ ارایه شده است.



شکل ۲- ساختار شبکه عصبی مصنوعی پرسپترون چند لایه  
Figure 2. Artificial Neural Network structure of Multi-Layer Perceptron (MLP)

مربعات خطا (MSE) و میانگین درصد خطای مطلق (MAPE) نیز استفاده شده است.

**ضریب رگرسیون (R)**

$$R = \frac{\overline{obs_n \cdot gen_n} - \overline{obs_n} \cdot \overline{gen_n}}{\sqrt{S_{obs_n}^2 \cdot S_{gen_n}^2}} \quad (5)$$

**مجدور میانگین مربعات خطا (RMSE)**

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (obs_n - gen_n)^2}{n}} \quad (3)$$

**میانگین خطای مطلق (MAE)**

$$MAE = \frac{\sum_{i=1}^n |obs_n - gen_n|}{n} \quad (4)$$

در روابط فوق  $obs_n$  مقادیر میانگین بارش ماهانه داده‌های مشاهده شده،  $gen_n$  مقادیر میانگین بارش ماهانه داده‌های شبیه‌سازی شده و  $n$  تعداد ماه‌ها است. آزمون‌های آماری به کار گرفته شده برای مقایسه توزیع‌های احتمالاتی و ارزیابی قابلیت مدل به شرح ذیل می‌باشد:

۱-۱- آزمون ناپارامتری نرمال بودن داده‌ها (آزمون کولموگروف-اسمیرنوف) (K-S): این آزمون برای تعیین نرمال بودن و یا نبودن توزیع مقادیر میانگین بارش ماهانه داده‌های مشاهده شده و شبیه‌سازی شده توسط مدل لارس در دوره پایه می‌باشد.

۱-۲- آزمون پارامتری مقایسه میانگین داده‌ها (t): این آزمون برای بررسی معنی‌دار بودن و یا نبودن تفاوت بین مقادیر میانگین بارش ماهانه داده‌های مشاهده شده و شبیه‌سازی شده توسط مدل لارس در دوره پایه می‌باشد.

۲- صحت سنجی مدل (Q-Test): در این بخش خصوصیات آماری داده‌های آب و هوایی دیدبانی شده و داده‌های آب و هوایی مصنوعی تولید شده توسط مدل به منظور تعیین این که آیا تفاوت‌های آماری قابل توجهی بین این دو گروه از داده‌ها وجود دارد یا خیر، مورد تجزیه و تحلیل قرار می‌گیرد.

در این مرحله از پژوهش، به منظور ارزیابی مدل شبکه عصبی مصنوعی در شبیه‌سازی فرآیند بارش-رواناب، از ۵ سال داده‌های مشاهداتی بارش-رواناب در ایستگاه هیدرومتری پاشاکلا در دوره پایه (۲۰۱۵-۲۰۱۱) استفاده شده است. در این بخش برای ارزیابی مدل شبکه عصبی مصنوعی علاوه بر شاخص‌های آماری به کار رفته در مدل لارس، از شاخص‌های آماری ضریب رگرسیون (R)، میانگین

### نتایج و بحث

#### بررسی وقوع پدیده تغییر اقلیم در منطقه

در جدول ۲ نتایج آزمون کولموگوروف-اسمیرنوف برای متوسط دمای سالانه در ایستگاه سینوپتیک قراخیل را نشان می‌دهد که حاکی از نرمال بودن داده‌ها می‌باشد.

در جدول ۳ نتایج آزمون من-کندال برای متوسط دما در ایستگاه سینوپتیک قراخیل ارائه شده است. طبق جدول، مقدار شاخص Z در مقیاس فصلی و سالانه، بزرگتر از  $+1/96$  بدست آمده است که نشان دهنده روند افزایشی متوسط دما در مقیاس فصلی و سالانه می‌باشد که در سطح ۹۵ درصد معنی‌دار می‌باشد و این امر پدیده‌ی تغییر اقلیم را در محدوده مطالعاتی (ایستگاه سینوپتیک قراخیل) آشکارسازی می‌نماید. رخداد پدیده تغییر اقلیم در استان مازندران در مطالعات حق طلب و همکاران (۶) نیز به اثبات رسیده است.

#### میانگین مربعات خطا (MSE)

$$MSE = \frac{\sum_{i=1}^n (obs_n - gen_n)^2}{n} \quad (6)$$

#### میانگین درصد خطای مطلق (MAPE)

$$MAPE = \frac{\sum_{i=1}^n \frac{|obs_n - gen_n|}{obs_n}}{n} \cdot 100 \quad (7)$$

در روابط فوق  $obs_n$ : مقادیر میانگین رواناب ماهانه داده‌های مشاهده شده،  $gen_n$ : مقادیر میانگین رواناب ماهانه داده‌های شبیه‌سازی شده،  $n$ : تعداد ماه‌ها،  $S_{obs}$  و  $S_{gen}$  به ترتیب انحراف معیار داده‌های رواناب مشاهده شده و شبیه‌سازی شده است.

جدول ۲- نتایج آزمون کولموگوروف-اسمیرنوف برای متوسط دمای سالانه در ایستگاه سینوپتیک قراخیل

Table 2. The results of the Kolmogorov-Smirnov test for the average annual temperature at the Gharakhail Synoptic Station

P	Z	D max abs	D max-	D max+	Kurt	Skew	Std dev	Avg	N
> ۰/۲۰۰	۰/۴۲۴	۰/۰۷۱	۰/۰۵۹	۰/۰۷۱	-۰/۵۵۰	۰/۰۱۶	۰/۶۶۳	۱۷/۰۰۸	۳۶

جدول ۳- نتایج آزمون من-کندال برای متوسط دما در ایستگاه سینوپتیک قراخیل

Table 3. The results of the Mann-Kendall tests for the mean temperature at the Gharakhail Synoptic Station

فصل	بهار	تابستان	پاییز	زمستان	سالانه
Z	۲/۱۰	۳/۸۴	۲/۰۷	۳/۲۵	۴/۶۲

و شبیه‌سازی شده توسط مدل لارس در دوره پایه، به ترتیب مربوط به بارندگی و دمای کمینه می‌باشد.

در شکل ۳ مقایسه مقادیر میانگین بارش ماهانه داده‌های مشاهده شده و شبیه‌سازی شده توسط مدل لارس در دوره پایه در مرحله واسنجی مدل نمایش داده شده است.

در جدول ۵ آزمون‌های آماری ارزیابی مدل لارس در دوره پایه در مرحله واسنجی مدل ارائه شده است. نتایج نشان می‌دهد که در تمام ماه‌ها در سطح احتمال ۵ درصد مقادیر میانگین بارش ماهانه مشاهده شده و شبیه‌سازی شده توسط مدل لارس در دوره پایه نرمال می‌باشد. همچنین غیر از ماه اکتبر در سایر ماه‌ها در سطح احتمال ۵ درصد اختلاف معنی‌داری بین مقادیر میانگین بارش ماهانه داده‌های مشاهده شده و شبیه‌سازی شده توسط مدل لارس در دوره پایه وجود ندارد.

### مدل لارس

#### ۱- واسنجی مدل


در جدول ۴ شاخص‌های آماری ارزیابی مدل لارس در دوره پایه (۲۰۰۴-۲۰۱۵) در مرحله واسنجی مدل ارائه شده است. از آنجایی که مقادیر ضریب ناش-ساتکلیف در ارامترهای دمای کمینه، دمای بیشینه و ساعات آفتابی برابر با یک می‌باشد، تطابق کامل بین مقادیر میانگین دمای کمینه، مای بیشینه و ساعات آفتابی ماهانه مشاهده شده و شبیه‌سازی شده برقرار می‌باشد لذا مدل از عملکرد مناسبی در مرحله واسنجی برخوردار است. پایین‌تر بودن مقدار ضریب ناش-ساتکلیف در پارامتر بارش می‌تواند ناشی از عدم وجود ایستگاه‌های هواشناسی در حوزه آبریز پاشاکلا، کم بودن طول دوره آماری مشابه داده‌های هواشناسی ایستگاه‌های مجاور حوزه و ضعف در صحت داده‌های هواشناسی اندازه‌گیری شده ایستگاه‌های مجاور حوزه باشد. با توجه به نتایج به دست آمده، بیشترین و کمترین اختلاف بین مقادیر داده‌های مشاهده شده

جدول ۴- شاخص‌های آماری ارزیابی مدل لارس در دوره پایه (۲۰۰۴-۲۰۱۵) در مرحله واسنجی مدل (n=12)

Table 4. Statistical indices of the LARS-WG model evaluation in the base period (2004-2015) in the stage of model calibration (n=12)

شاخص آماری	NS	R <sup>2</sup>	RMSE	MAE
بارش	۰/۶۸۳۴	۰/۹۹۱۵	۷/۶۰	۶/۵۴
دمای کمینه	۱/۰۰۰۰	۰/۹۹۹۷	۰/۳۱	۰/۲۴
دمای بیشینه	۰/۹۹۹۹	۰/۹۹۹۸	۰/۳۵	۰/۲۵
ساعات آفتابی	۰/۹۹۹۹	۰/۹۹۹۴	۰/۴۱	۰/۲۹





شکل ۳- مقایسه مقادیر میانگین بارش ماهانه داده‌های مشاهده شده و شبیه‌سازی شده توسط مدل لارس در دوره پایه (۲۰۰۴-۲۰۱۵) در مرحله واسنجی مدل

Figure 3. Comparison of the mean monthly rainfall of observed and simulated data by the LARS-WG model in the base period (2004-2015) in the stage of model calibration

جدول ۵- آزمون‌های آماری ارزیابی مدل لارس در دوره پایه (۲۰۰۴-۲۰۱۵) در مرحله واسنجی مدل (n=12)  
Table 5. Statistical tests of the LARS-WG model evaluation in the base period (2004-2015) in the stage of model calibration (n=12)

آزمون	ژانویه	فوریه	مارس	آوریل	مه	ژوئن	جولای	اگوست	سپتامبر	اکتبر	نوامبر	دسامبر
کولموگروف-اسمیرنوف	۰/۰۹	۰/۱۵	۰/۰۵	۰/۰۵	۰/۰۲	۰/۰۵	۰/۰۸	۰/۰۷	۰/۰۴	۰/۰۶	۰/۰۴	۰/۱۳
احتمال معنی‌داری P	۱/۰۰	۰/۹۳	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۰/۹۸
آماره t	-۰/۴۶	۰/۵۵	۰/۷۹	-۰/۹۲	-۰/۲۴	-۰/۴۶	-۰/۱۶	-۰/۴۶	۰/۶۳	-۲/۰۷	-۰/۶۹	۰/۶۸
احتمال معنی‌داری P	۰/۶۵	۰/۵۸	۰/۴۳	۰/۳۶	۰/۸۱	۰/۶۵	۰/۸۷	۰/۶۵	۰/۵۳	۰/۰۴	۰/۴۹	۰/۵۰


## ۲- صحت سنجی مدل

در شکل ۴ مقایسه مقادیر میانگین بارش ماهانه داده‌های مشاهده شده و شبیه‌سازی شده توسط مدل لارس در دوره پایه در مرحله صحت سنجی مدل نمایش داده شده است. در جدول ۷ آزمون‌های آماری ارزیابی مدل لارس در دوره پایه در مرحله صحت سنجی مدل ارائه شده است. نتایج نشان می‌دهد که در تمام ماه‌ها در سطح احتمال ۵ درصد مقادیر میانگین بارش ماهانه داده‌های مشاهده شده و شبیه‌سازی شده توسط مدل لارس در دوره پایه نرمال می‌باشد و اختلاف معنی‌داری نیز بین مقادیر میانگین بارش ماهانه داده‌های مشاهده شده و شبیه‌سازی شده توسط مدل لارس در دوره پایه وجود ندارد.

در جدول ۶ شاخص‌های آماری ارزیابی مدل لارس در دوره پایه (۲۰۰۴-۲۰۱۵) در مرحله صحت سنجی مدل ارائه شده است. با توجه به مقادیر ضریب ناش-ساتکلیف، مدل در مرحله صحت سنجی نیز از عملکرد مناسبی برخوردار است. پایین‌تر بودن مقدار ضریب ناش-ساتکلیف در پارامتر بارش در این مرحله نیز می‌تواند ناشی از عوامل مذکور در مرحله واسنجی مدل باشد. با توجه به نتایج بدست آمده، بیشترین و کمترین اختلاف بین مقادیر داده‌های مشاهده شده و شبیه‌سازی شده توسط مدل لارس در دوره پایه نیز، به ترتیب مربوط به بارندگی و دمای کمینه می‌باشد.

جدول ۶- شاخص‌های آماری ارزیابی مدل لارس در دوره پایه (۲۰۰۴-۲۰۱۵) در مرحله صحت سنجی مدل (n=12)  
Table 6. Statistical indices of the LARS-WG model evaluation in the base period (2004-2015) in the stage of model validation (n=12)

شاخص آماری	NS	R <sup>2</sup>	RMSE	MAE
بارش	۰/۵۲۴۷	۰/۹۸۷۱	۹/۳۰	۷/۴۰
دمای کمینه	۱/۰۰۰۰	۰/۹۹۹۶	۰/۳۳	۰/۲۲
دمای بیشینه	۰/۹۹۹۸	۰/۹۹۹۶	۰/۵۳	۰/۴۱
ساعات آفتابی	۰/۹۹۹۹	۰/۹۹۹۰	۰/۵۲	۰/۴۳



شکل ۴- مقایسه مقادیر میانگین بارش ماهانه داده‌های مشاهده شده و شبیه‌سازی شده توسط مدل لارس در دوره پایه (۲۰۰۴-۲۰۱۵) در مرحله صحت سنجی مدل

Figure 4. Comparison of the mean monthly rainfall of observed and simulated data by the LARS-WG model in the base period (2004-2015) in the stage of model validation

جدول ۷- آزمون‌های آماری ارزیابی مدل لارس در دوره پایه (۲۰۰۴-۲۰۱۵) در مرحله صحت سنجی مدل (n=12)


Table 7. Statistical tests of the LARS-WG model evaluation in the base period (2004-2015) in the stage of model validation (n=12)

آزمون	ماه	ژانویه	فوریه	مارس	آوریل	مه	ژوئن	جولای	اگوست	سپتامبر	اکتبر	نوامبر	دسامبر
کولموگروف-اسمیرنوف	آماره Z	۰/۰۹	۰/۱۶	۰/۰۵	۰/۰۷	۰/۰۵	۰/۰۸	۰/۰۸	۰/۰۶	۰/۰۸	۰/۰۸	۰/۰۵	۰/۱۵
اسمیرنوف	احتمال معنی‌داری P	۱/۰۰	۰/۹۲	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۰/۹۴
تی-استیودنت	آماره t	-۰/۱۹	۰/۵۷	-۰/۱۳	-۰/۵۰	-۰/۶۶	-۱/۶۴	-۰/۳۹	-۰/۴۸	۱/۹۹	-۰/۲۵	۰/۶۱	۰/۲۲
	احتمال معنی‌داری P	۰/۸۵	۰/۵۷	۰/۹۰	۰/۶۲	۰/۵۱	۰/۱۲	۰/۷۰	۰/۶۴	۰/۰۶	۰/۸۱	۰/۵۵	۰/۸۳

### ۳- تولید داده

A2 نمایش داده شده است. سری زمانی بارش روزانه شبیه‌سازی شده کاملاً به صورت تصادفی و بدون روند است و حداقل و حداکثر مقدار آن به ترتیب برابر صفر و ۶۹/۲ میلی‌متر می‌باشد.

در شکل ۵ سری زمانی روزانه بارش شبیه‌سازی شده توسط مدل لارس در دوره آتی به مدت ۱۰ سال (۲۰۱۶-۲۰۲۵)، تولید شده با مدل HadCM3 تحت سناریوی



شکل ۵- سری زمانی بارش روزانه شبیه‌سازی شده توسط مدل لارس در دوره آتی (۲۰۱۶-۲۰۲۵)

Figure 5. Time series of simulated daily rainfall by LARS-WG model in the future period (2016-2025)

### مدل شبکه عصبی مصنوعی (ANN)

مورد تحلیل قرار گرفت. با استفاده از نرون‌های بارش و رواناب ضریب همبستگی برابر با ۰/۸ به دست آمد که این ضریب همبستگی در سطح ۱ درصد معنی‌دار بوده و نشان از قابلیت مدل در شبیه‌سازی فرآیند بارش-رواناب می‌باشد. همانطور که مشاهده شده با وجود کم بودن تعداد متغیرهای ورودی به شبکه (دو متغیر ورودی بارش و رواناب) و روند واسنجی و صحت سنجی سریع‌تر و آسان‌تر، این مدل پیش‌بینی مناسبی از سری زمانی رواناب روزانه داشته است، زیرا هرچه که تعداد متغیرهای استفاده شده در شبکه بیشتر

یکی از مهمترین گام‌ها در پیشبرد رضایت‌بخش مدل شبکه عصبی مصنوعی، انتخاب متغیرهای ورودی مناسب است. به این منظور نیاز به ارزیابی عملکرد شبکه با متغیرهای ورودی مختلف می‌باشد. لذا سعی بر این است که شبکه‌ای با کمترین خطا و بالاترین همبستگی معرفی شود. در این بخش به منظور پیش‌بینی رواناب هر روز، داده‌های بارش همان روز و یک روز قبل و داده‌های رواناب یک روز قبل به عنوان عوامل مؤثر در رواناب روز جاری وارد شبکه شده و کارایی شبکه



روزانه کمتر از خطاهای مدل لارس در شبیه‌سازی بارش روزانه در مراحل واسنجی و صحت سنجی بوده است. در مطالعات نظری و همکاران (۱۵) نیز عملکرد مناسب شبکه عصبی مصنوعی در مدل‌سازی بارش-رواناب در رودخانه بابلرود به اثبات رسیده است. امیدوار و اژدرپور (۱۶) نیز با استفاده از این شاخص‌های ارزیابی نشان داده‌اند، غیر از مواردی که جریان افتاخیز زیادی دارد، شبکه عصبی مصنوعی از دقت بیشتری نسبت به مدل HEC-HMS در برآورد بارش-رواناب در حوزه رودخانه اعظم هرات برخوردار است.


باشد، پیش‌بینی به واقعیت نزدیک‌تر خواهد بود. غفاری و وفاخواه (۵) در پیش‌بینی رواناب روزانه با استفاده از شبکه عصبی مصنوعی، از ترکیب ورودی بارش روزانه با دو تاخیر استفاده نمودند. نتایج کمترین میزان خطا و بالاترین درجه همبستگی را نشان داده است که نشان از قابلیت مدل در شبیه‌سازی فرآیند بارش-رواناب می‌باشد. در جدول ۸ شاخص‌های آماری ارزیابی مدل شبکه عصبی مصنوعی ارایه شده است. با توجه به نتایج بدست آمده، خطاهای مدل شبکه عصبی مصنوعی در شبیه‌سازی رواناب

جدول ۸- شاخص‌های آماری ارزیابی مدل شبکه عصبی مصنوعی در دوره پایه (۲۰۰۱-۲۰۱۵) (n=15)  
Table 8. Statistical indices of the ANN model evaluation in the basic period (2001-2015) (n=15)


شاخص آماری	مقدار	شاخص آماری	مقدار
ضریب تبیین (R <sup>2</sup> )	۰/۷۹	ضریب رگرسیون (R)	۰/۸۹
مجنور میانگین مربعات خطا (RMSE)	۱/۹۸	میانگین مربعات خطا (MSE)	۳/۹۱
میانگین خطای مطلق (MAE)	۰/۹۴	میانگین درصد خطای مطلق (MAPE)	۴۴/۷۰

یافتن بهترین همبستگی بین رواناب پیش‌بینی شده و واقعی در ایستگاه کشتارگاه به اثبات رسیده است. این یافته‌ها با نتایج حسنیور کاشانی و همکاران (۷) نیز همخوانی دارد. در شکل ۸ سری زمانی رواناب روزانه شبیه‌سازی شده توسط مدل شبکه عصبی مصنوعی در دوره آتی به مدت ۱۰ سال (۲۰۱۶-۲۰۲۵) نمایش داده شده است. با توجه به همبستگی بالای بین رواناب مشاهده شده و شبیه‌سازی شده و قابلیت مدل شبکه عصبی مصنوعی در شبیه‌سازی رواناب می‌توان، سری زمانی رواناب روزانه را برای سال‌های آتی شبیه‌سازی نمود. در این شکل سری زمانی رواناب روزانه شبیه‌سازی شده کاملاً به صورت تصادفی و بدون روند است و حداقل و حداکثر مقدار آن به ترتیب برابر ۱/۶ و ۳۸/۷ متر مکعب بر ثانیه می‌باشد. از مزایای مدل شبکه عصبی مصنوعی، حساس نبودن آن به وجود تعداد محدودی خطا در داده‌های آماری بوده که همین امر موجب شده است تا این مدل برآورد مناسبی از سری زمانی رواناب روزانه داشته باشد. در نهایت می‌توان نتیجه گرفت که در صورت وجود داشتن اطلاعات غنی و کافی برای آموزش مدل شبکه عصبی مصنوعی می‌توان انتظار شبیه‌سازی‌های دقیق و مناسب‌تری را از این مدل داشت.


در شکل ۶ منحنی پراکندگی رواناب مشاهده شده و شبیه‌سازی شده توسط مدل شبکه عصبی مصنوعی در دوره پایه به مدت ۱۵ سال (۲۰۰۱-۲۰۱۵) نمایش داده شده است. بین رواناب مشاهده شده  $obs_n$  و شبیه‌سازی شده  $gen_n$  رابطه  $gen_n = 0.778obs_n + 1.026$  برقرار می‌باشد. در این شکل تطابق بین رواناب مشاهده شده و شبیه‌سازی شده را به وضوح می‌توان مشاهده نمود. جهانگیر و همکاران (۱۱) قابلیت شبکه عصبی مصنوعی در برآورد رخداد بارش-رواناب در حوزه معرف کارده تایید نمودند. در شکل ۷ سری زمانی رواناب روزانه مشاهده شده و شبیه‌سازی شده در دوره پایه به مدت ۱۵ سال (۲۰۰۱-۲۰۱۵) نمایش داده شده است. پس از ارزیابی قابلیت مدل شبکه عصبی مصنوعی در شبیه‌سازی فرآیند بارش-رواناب و مشخص شدن رابطه بین بارش-رواناب در حوزه پاشاکلا، برای سری زمانی بارش روزانه شبیه‌سازی شده توسط مدل لارس در دوره آتی، سری زمانی رواناب روزانه، شبیه‌سازی شده است. نکته قابل توجه در این شکل تطابق مقادیر رواناب مشاهده شده و شبیه‌سازی شده در دبی‌های پیک می‌باشد. در مطالعات نظری و همکاران (۱۵) نیز عملکرد مناسب شبکه عصبی مصنوعی در مدل‌سازی بارش-رواناب و



شکل ۶- منحنی پراکندگی رواناب مشاهده شده و شبیه‌سازی شده توسط مدل شبکه عصبی مصنوعی در دوره پایه (۲۰۰۱-۲۰۱۵)  
Figure 6. The dispersion curve of observed and simulated runoff by the ANN model in the base period (2001-2015)



شکل ۷- سری زمانی رواناب روزانه مشاهده شده و شبیه‌سازی شده توسط مدل شبکه عصبی مصنوعی در دوره پایه (۲۰۰۱-۲۰۱۵)  
Figure 7. Time series of observed and simulated daily runoff by the ANN model in the base period (2001-2015)



شکل ۸- سری زمانی رواناب روزانه شبیه‌سازی شده توسط مدل شبکه عصبی مصنوعی در دوره آتی (۲۰۱۶-۲۰۲۵)  
Figure 8. Time series of simulated daily runoff by the ANN model in the future period (2016-2025)

ایستگاه‌های هواشناسی در حوزه آبریز پاشاکلا، کم بودن طول دوره آماری مشابه داده‌های هواشناسی ایستگاه‌های مجاور حوزه و ضعف در صحت داده‌های هواشناسی اندازه‌گیری شده ایستگاه‌های مجاور حوزه باشد. لذا وجود ایستگاه‌های هواشناسی و آمار بلند مدت در حوزه مطالعاتی، به دقت خروجی مدل‌های پیش‌بینی سری زمانی بارش و رواناب روزانه خواهد افزود. در پارامتر رواناب، رابطه مشخصی بین پارامترهای جوی و ایجاد رواناب در حوزه مطالعاتی برقرار می‌باشد که می‌توان از این رابطه برای پیش‌بینی رواناب آتی استفاده نمود؛ زیرا امروزه بحث سیل و سیل‌خیزی از اهمیت به‌سزایی برخوردار است. رزاقیان و همکاران (۱۸) نیز در ارزیابی اثر تغییر اقلیم بر رواناب حوزه آبریز بابلرود، نشان دادند که افزایش بارش و دبی در ماه‌های پر بارش و افزایش دما و کاهش بارش و دبی در ماه‌های کم بارش با تأثیر بر اقلیم منطقه در آینده‌های نه چندان دور، تعداد و شدت وقایع حادی سیل و خشکسالی را افزایش خواهد داد.

در پژوهش حاضر، با مینا قرار دادن داده‌های هواشناسی بلند مدت ایستگاه سینوپتیک قراخیل رخداد تغییر اقلیم در سطح حوزه سد پاشاکلا بابل با استفاده از آزمون ناپارامتری من-کندال آشکارسازی شد. پس از بررسی تأثیر تغییر اقلیم بر بارش و رواناب حوزه، سری زمانی بارش و رواناب روزانه در سطح حوزه برای دوره آتی ۱۰ ساله (۲۰۱۶-۲۰۲۵) پیش‌بینی شد تا بتوان براساس آن به برنامه‌ریزی منابع آب و کنترل سیلاب سد پاشاکلا بابل پرداخت. در این راستا توانمندی مدل لارس تحت مدل گردش عمومی جو HadCM3 و سناریوی A2 در پیش‌بینی سری زمانی بارش روزانه و مدل شبکه عصبی مصنوعی در پیش‌بینی سری زمانی رواناب روزانه مورد ارزیابی قرار گرفت. با توجه به نتایج بدست آمده، خطاهای مدل شبکه عصبی مصنوعی در شبیه‌سازی رواناب روزانه کمتر از خطاهای مدل لارس در شبیه‌سازی بارش روزانه در مراحل واسنجی و صحت‌سنجی بوده است. در پارامتر بارش، پایین‌تر بودن مقدار ضریب ناش-ساتکلیف می‌تواند ناشی از عدم وجود

## منابع

1. Ahmadi, F., Y. Dinpazhouh, A. Fakhelifard, K. Khalili and C. Darbandi. 2015. Comparison of nonlinear time series models and genetic programming in daily river flow forecasting (Case study: Barandoezchay river in Orumieh). *Journal of Soil and Water Conservation*, 22(1): 151-169 (In Persian).
2. Camici, S., L. Brocca, F. Melone and T. Moramarco. 2014. Impact of climate change on flood frequency using different climate models and downscaling approaches. *Journal of Hydrologic Engineering*, ASCE, 19 (8): 1-15.
3. Dayhoff, J.E. 1990. *Neural network principles*. Prentice-Hall International, U.S.A., 197 pp.
4. Fiseha, B.M., A.M. Melesse, E. Romano, E. Volpi and A. Fiori. 2012. Statistical downscaling of precipitation and temperature for the Upper Tiber Basin in Central Italy. *International Journal of Water Sciences*, 1(3): 1-10.
5. Ghafari, Gh.A. and M. Vafakhah. 2013. Simulation of rainfall-runoff process using artificial neural network and adaptive neuro-fuzzy interface system(case study: Hajighoshan watershed). *Journal of Watershed Management Research*, 4 (8): 120-136 (In Persian).
6. Hagh Talab, N., M. Goudarzi, M. Habibi Nokhandan, A.R. Yavari and H.R. Jafari. 2013. Climate modeling of Tehran and Mazandaran provinces using climate model LARS-WG and to compare changes in northern and southern fronts of Central Alborz. *Environmental Sciences*, 1(15): 1-13 (In Persian).
7. Hasanpour Kashani, M., M.A. Ghorbani, Y. Dinpazhouh and S. Shahmorad. 2015. Rainfall-Runoff simulation in the Navrood river basin using truncated volterra model and artificial neural networks. *Journal of Watershed Management Research*, 6(12): 1-10 (In Persian).
8. Hejarizadeh, Z., S.M. Hoseyni and A.R. Karbalaee Doree. 2015. Simulation of climate variables in Semnan province by scenarios from general circulation models (HadCM3). *Journal of Geography of Environmental Hazards*, 4 (15): 1-24 (In Persian).
9. Hosseini, S.H., M.A. Ghorbani and A.R. Massah Bavani. 2015. Raifall-Runoff modelling under the climate change condition in order to project future streamflows of Sufichay Watershed. *Journal of Watershed Management Research*, 6 (11): 1-14 (In Persian).
10. Huang, S., F. Hattermann, V. Krysanova and A. Bronstert. 2013. Projections of climate change impacts on river flood conditions in Germany by combining three different RCMs with a regional eco-hydrological model. *Climate Change*, 116(3-4): 631-663.
11. Jahangeer, A.R., M. Raeini Sarjaz and M.Z. Ahmad. 2009. Comparison of artificial neural networks (ANN) simulation of rainfall-runoff process with HEC-HMS model in Kardeh watershed. *Journal of Soil and Water (Agricultural Science and Technology)*, 22(2): 72-84 (In Persian).
12. Karamouz, M. and Sh. Araghinezhad. 2005. *Advanced hydrology*. Amirkabir University Press, Tehran, 464 pp (In Persian).
13. Khazaei, M. and M.R. Mirzaee. 2013. Compare performance of monthly discharge prediction Using artificial neural network and time series methods. *Soil Conservation and Watershed Management Research Institute*, 5(2): 74-84 (In Persian).
14. Liu, L., Z. Liu, X. Ren, T. Fischer and Y. Xu. 2011. Hydrological impacts of climate change in the Yellow River Basin for the 21 st century using hydrological model and statistical downscaling model. *Quaternry International*, 244(2): 211-220.
15. Nazari, M., H. Ghasemieh, S.J. Sadatinejad and A. Vali. 2015. An investigation of artificial neural network performance in modeling rainfall-runoff and its comparison with multivariate regression method: a case study of Babolroud river. *International Bulletin of Water Resources & Development*, 3 (3): 119-133 (In Persian).
16. Omidvar, K. and M. Azhdarpoor. 2013. Comparison artificial neural network and model HEC-HMS in the estimation of rainfall – runoff in the Basin of Heart grand river. *Journal of Geographical Research*, 27 (4): 139-160 (In Persian).
17. Rasco, P., L. Szeidl and M.A. Semenov. 1991. A serial approach to local stochastic models. *Journal of Ecological Modeling*, 57: 27-41.
18. Razzaghian, H., K. Shahedi and M. Habibnejad-roshan. 2016. Evaluation of the climate change effect on Babol-rood watershed runoff using IHACRES model. *Journal of Irrigation & Water Engineering*, 7 (26): 159-172 (In Persian).
19. Sanikhani, H., M.R. Gohardoust and M. Sadeghi. 2016. Assessment of climate change effect on the runoff in Gharechay watershed in Markazi province. *Journal of Watershed Management Research*, 7 (13): 12-22 (In Persian).
20. Sazabshargh Consulting Engineers. 2010. *Updating the atlas of water resources (Mazandaran and Gwilan east rivers basin)*, 1: 262 pp (In Persian).
21. Semenov, M.A. and E.M. Barrow. 2002. *LARS-WG: A stochastic weather generator for use in climate impact studies*. User Manual, 27 pp.
22. Sheidaeian, M. 2013. *Assessment of climate change effect on the rice net irrigation requirement (Case Study: Tajan Plain)*. Master Thesis of Irrigation and Drainage Engineering, Sari Agricultural Science and Natural Resources University, Sari, Iran, 226 pp (In Persian).
23. Zahmatkesh, Z., M. Karamouz, E. Goharian and S. Burian. 2015. Analysis of the effects of climate change on urban storm water runoff using statistically downscaled precipitation data and a change factor approach. *Journal of Hydrologic Engineering*, ASCE, 20(7): 1-11.

## Investigation the Ability of Artificial Neural Network in Simulation of Rainfall-Runoff Process under the Climate Change Conditions (Case Study: Pashakola Babol Dam Basin)

Masoome Khademi<sup>1</sup>, Ramin Fazloulou<sup>2</sup> and Alireza Emadi<sup>3</sup>

---

1 and 3- PhD Student and Associate Professor, Faculty of Agricultural Engineering, Sari Agricultural Sciences and Natural Resources University

2- Associate Professor, Faculty of Agricultural Engineering, Sari Agricultural Sciences and Natural Resources University (Corresponding author: raminfazl@yahoo.com)

Received: August 21, 2016      Accepted: February 13, 2017

---

### Abstract

River flow forecasting plays an important role in planning, management and operation of water resources. To achieve this goal and according to the phenomenon of global warming, it is necessary to simulate the daily time series of rainfall and runoff for future periods. Therefore, it is important to survey the detection of climate change event and its impact on precipitation and runoff in the basin. In the first step of this research, using Mann-Kendall trend statistical test, climate change event in the Pashakola Babol basin in Mazandaran province is confirmed. The results of the survey on 36 years daily mean temperature data, reflect the increasing trend in average temperature in the basin. In the second step, the LARS-WG model under general circulation models HadCM3 and A2 scenario is used to generate the daily rainfall time series in the future period. In order to rainfall data, minimum temperature, maximum temperature and sunshine hours is entered in the model for 12-year base period (2004-2015) and Then daily rainfall time series in the basin is predicted for the next 10-year period (2016-2025). In the third step, the artificial neural network model is used to simulate the process of rainfall - runoff in the climate change condition and to generate the daily runoff time series in the future period. Finally, in order to enhance the capability of the artificial neural network model in predicting the daily runoff, besides the predicted daily precipitation data, the rainfall and runoff data one day before as effective factors on the current day runoff is also entered in the model and using rainfall and runoff neurons. Correlation coefficient was obtained equal to 0.8. This correlation coefficient is significant at 1% and show the ability of model to simulate rainfall-runoff process.

**Keywords:** Artificial Neural Networks Model, Climate Change, Daily Runoff, LARS-WG Model