

## پیش‌بینی مقادیر بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی و مدل درختی M5 (مطالعه موردی: ایستگاه اهر)

محمدتقی ستاری - استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز  
علی رضازاده جودی\* - دانشجوی کارشناسی ارشد عمران آب، دانشگاه آزاد اسلامی، واحد مراغه  
فرنáz نهرین - دانشجوی کارشناسی ارشد سازه‌های آبی، دانشکده کشاورزی، دانشگاه تبریز

تأثید نهایی: ۱۳۹۳/۰۳/۲۱ پذیرش مقاله: ۱۳۹۲/۰۶/۳۰

### چکیده

بارش یکی از مهم‌ترین اجزای چرخه آب بوده و در سنجش خصوصیات اقلیمی هر منطقه، نقش بسیار مهمی ایفا می‌کند. تخمین مقادیر بارش ماهانه برای اهداف مختلفی چون، برآورد سیلاب، خشکسالی، برنامه‌ریزی آبیاری و مدیریت حوضه‌های آبریز، اهمیت زیادی دارد. پیش‌بینی بارش در هر منطقه‌ای نیازمند وجود داده‌های دقیق اندازه‌گیری شده‌ای مانند، رطوبت، دما، فشار، سرعت باد و غیره است. محدودیت‌هایی چون، نبود اطلاعات کافی در مورد مقدار بارش در مقیاس‌های زمانی و مکانی و همچنین پیچیدگی روابط بین پارامترهای هواشناسی مرتبط با بارش، موجب می‌شود محاسبه این پارامتر با استفاده از روش‌های معمول به طور دقیق انجام نگیرد. در این پژوهش، ابتدا سناریوهای مختلفی از ترکیب پارامترهای هواشناسی در مقیاس ماهانه برای منطقه اهر در استان آذربایجان شرقی، بهمنزله ورودی شبکه‌های عصبی مصنوعی و مدل درختی M5 تعریف شد و سپس با در نظر گرفتن دو آماره R و RMSE بهترین سناریو برای هر یک از این دو مدل انتخاب شد. یافته‌ها نشان داد که هر دو روش نتایج نسبتاً دقیقی را برای پیش‌بینی ماهانه منطقه ارائه می‌کنند، ولی از آنچاکه مدل درختی M5 روابط خطی ساده‌ای در اختیار کاربر می‌گذارد، این روش کاربردی‌تر است.

کلیدواژه‌ها: اهر، پیش‌بینی بارش ماهانه، شبکه‌های عصبی مصنوعی، مدل درختی M5

### مقدمه

بارش یکی از مهم‌ترین داده‌های ورودی به سیستم هیدرولوژیکی است و یکی از مهم‌ترین پارامترهای اقلیمی در مدیریت منابع آبی محسوب می‌شود. پیش‌بینی این پدیده برای اهداف مختلفی مانند برآورد سیلاب، خشکسالی، رواناب، رسوب، مدیریت حوضه آبریز، کشاورزی، برنامه‌ریزی آبیاری و مانند این‌ها، اهمیت زیادی دارد. پیش‌بینی بارش در مدیریت و

هشدار سیل نقش ویژه و مهمی بر عهده دارد. برای مثال، در زمینه سیالاب با اطلاع از میزان بارندگی می‌توان امکان وقوع سیل را در منطقه پیش‌بینی کرد و اقدامات لازم را برای کاهش خسارات ناشی از سیل به عمل آورد (فلاحی، وروانی و گلیان، ۱۳۹۰). همچنین با اطلاع از میزان بارندگی مؤثر، می‌توان نیاز خالص آبیاری را برای تنظیم برنامه آبیاری محاسبه کرد. با توجه به پیشرفت‌های تکنولوژی، اگرچه این پیش‌بینی در دامنه زمان و مکان امری محال نیست، ولی از پیچیدگی زیادی برخوردار است؛ چرا که بارش خود تابع عوامل بسیاری از جمله فشار، دما، رطوبت و... است. گرچه تا به حال مدل‌های مفهومی و آماری زیادی برای پیش‌بینی و پیش‌آگاهی متغیرهای اقلیمی ارائه شده است، اما امروزه سیستم‌های هوشمندی همچون روش شبکه عصبی مصنوعی و مدل‌های درختی، برای مدل‌سازی فرآیندهای هیدرولوژیکی و مهندسی آب مورد توجه قرار گرفته‌اند. روش‌های مذکور، روش‌هایی معتبر و شناخته‌شده در مدل‌سازی فرآیندهای پیچیده غیرخطی هستند که قادرند با استفاده از داده‌های هواشناسی ثبت‌شده در ایستگاه‌های هواشناسی، تخمین دقیق تری از پارامترهای هواشناسی منطقه ارائه دهند. شبکه‌های عصبی مصنوعی جزء روش‌های جعبه سیاه بوده و بدون در نظر گرفتن فرآیند فیزیکی حاکم بر سیستم و فقط با کمک داده‌های ورودی و خروجی، قادر به ایجاد رابطه بین آن دو هستند. به تازگی شبکه‌های عصبی مصنوعی در بخش‌های مختلف مهندسی آب به کار گرفته می‌شوند. در سال‌های اخیر نیز، از مدل درختی M5 برای پیش‌بینی پارامترهای هواشناسی و هیدرولوژیکی استفاده شده است.

خلیلی، خداشناس، داوری و موسوی بایگی (۱۳۸۸) با استفاده از شبکه‌های عصبی پرسپترون چندلایه، میزان بارش را با دقت قابل قبولی در ایستگاه سینوپتیک مشهد پیش‌بینی کردند. گلی‌زاده و درند (۱۳۸۹) میزان بارش ماهانه را در تهران با استفاده از شبکه عصبی مصنوعی تخمین زدند. فاتحی‌مرج و مهدیان (۱۳۸۹) ارتباط بین پدیده انسو<sup>۱</sup> را با بارش در حوضه دریاچه ارومیه بررسی کرده و برای پیش‌بینی بارش پاییزه در دو ایستگاه تبریز و ارومیه از مدل شبکه‌های عصبی مصنوعی استفاده کردند. آنها نشان دادند که مدل غیرخطی با استفاده از شاخص‌های اقلیمی مورد استفاده، بارش پاییزه را با دقت بیشتری پیش‌بینی می‌کند. فلاخ قاله‌ری، موسوی بایگی و حبیبی نوخدان (۱۳۸۸)، کارکرد دو مدل سیستم استباط فازی و شبکه عصبی مصنوعی را در پیش‌بینی بارش منطقه خراسان بزرگ مقایسه کردند و نشان دادند که شبکه عصبی مصنوعی در پیش‌بینی بارش موفق‌تر از مدل فازی عمل می‌کند. قاله‌ری و همکارش در پژوهش دیگری با استفاده از شبکه‌های عصبی مصنوعی، میزان بارش استان خراسان رضوی را پیش‌بینی کردند و به این نتیجه رسیدند که شبکه عصبی مصنوعی در تمامی سال‌ها می‌تواند بارش را با دقت قابل قبولی پیش‌بینی کند (فلاح قاله‌ری و خوشحال دستجردی، ۱۳۸۸). حلیان (۱۳۸۸) مقدایر بارش ماهانه یزد را با استفاده از شبکه عصبی مصنوعی پیش‌بینی کرد. ترافلیس، سانتوزا و ریچمن (۲۰۰۵) از روش شبکه عصبی مصنوعی و چند روش دیگر برای تخمین بارش استفاده کردند که درنهایت، روش بردار پشتیانی رگرسیون (SVR)<sup>۲</sup> بهترین روش برای این تخمین بارش معرفی شد. هاکوترا (۲۰۰۸) با استفاده از مدل شبکه عصبی مصنوعی، بارش‌های موسمی درازمدت را برای ۳۶ زیربخش هواشناسی هند بررسی کرد.

1. El Nino Southern Oscillation  
2. Support Vector Regression

فلاحی و همکاران (۱۳۹۰) از مدل رگرسیون درختی بهمنزله روشی کارآمد برای پیش‌بینی بارندگی در سه ایستگاه هواشناسی بندرانزلی، اراک و قم استفاده کردند که نتایج بیانگر توانایی و دقت بالای این مدل در پیش‌بینی بارش بود. ستاری، نهرین و عظیمی (۱۳۹۲) به پیش‌بینی تبخیر - تعرق مرجع روزانه در منطقه بناب با استفاده از مدل درختی M5 پرداختند و نتایج حاصل را با شبکه عصبی مصنوعی مقایسه کردند. آنها دریافتند که مدل درختی M5 نیز مانند شبکه عصبی مصنوعی، می‌تواند برای مدل‌سازی تبخیر - تعرق مرجع روزانه به کار برد شود. در پژوهش دیگری ستاری و نهرین (۱۳۹۲) با استفاده از سیستم‌های هوشمند، مقادیر حداکثر بارش روزانه در منطقه اهر و جلفا را پیش‌بینی کردند و نتایج بدست‌آمده را با روش مدل درختی M5 مقایسه کردند. در پژوهش دیگری که ستاری و همکارانش انجام دادند، تبخیر و تعرق مرجع ماهانه آنکارا با استفاده از مدل درختان M5 و شبکه‌های عصبی مصنوعی مدل‌سازی شده است. یافته‌های این پژوهش نشان داد، هم شبکه عصبی مصنوعی و هم مدل درختی M5، برای مدل‌سازی تبخیر و تعرق ماهانه مناسب هستند (ستاری، پال، یورکلی و اونلوکارا، ۲۰۱۳). در مطالعه دیگری، ستاری و همکارانش به ارزیابی پتانسیل مدل درختی M5 برای پیش‌بینی جریان رودخانه سوهو در آنکارا پرداختند. آنها نتایج را با روش ماشین بردار پشتیبان مقایسه کردند و دریافتند که مدل درختی M5، نه تنها می‌تواند به خوبی ماشین بردار پشتیبان جریان رودخانه را پیش‌بینی کند، بلکه عملکرد بهتری از خود نشان می‌دهد؛ به‌گونه‌ای مدل درختی M5 روابط خطی ساده‌ای ارائه می‌کند و به زمان محاسباتی کمتری نیاز دارد (ستاری، پال، آپایدین و اوزتورک، ۲۰۱۳).

از جمله پژوهش‌های انجام‌یافته با مدل درختی M5 در زمینه‌های دیگری از مهندسی آب، می‌توان به مطالعه پال (۲۰۰۶) در مورد طبقه‌بندی پوشش گیاهی، پژوهش پال و سریندر (۲۰۰۹) برای مدل‌سازی تبخیر و تعرق، مطالعه سینگ، پال و سینگ، (۲۰۰۷، ۲۰۱۰) در پیش‌بینی سیالاب سالانه، پژوهش دیتحکیت و چیناراسی (۲۰۱۲) در تخمین ضریب تشک تبخیر و همچنین پژوهش نهرین، ستاری و سلاماسی (۱۳۹۲) در زمینه‌پیش‌بینی اتلاف کارماهی در سرریز توری سنگی پله‌ای اشاره کرد. در نتایج پژوهش نهرین و ستاری مشخص شد که مدل درختی M5 عملکرد موفقیت‌آمیزی در مسائل مختلف مربوط به علوم مهندسی منابع آب و هواشناسی دارد.

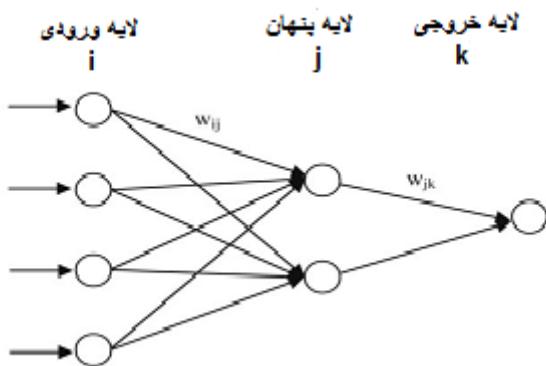
هدف از پژوهش پیش رو، مدل‌سازی بارش ماهانه شهرستان اهر با استفاده از شبکه‌های عصبی مصنوعی و مقایسه آن با مدل درختی M5 است. در این مدل‌سازی بهمنزله ورودی‌های مدل‌ها، سناریوهای مختلفی مرکب از پارامترهای هواشناسی مؤثر (دما، باد، رطوبت نسبی و...) برای محاسبه بارش ماهانه ارائه شده و از بین آنها بهترین سناریو که با حداقل تعداد پارامتر، پیش‌بینی دقیق‌تری از میزان بارش ماهانه ارائه می‌دهد، انتخاب شده است.

## مواد و روش‌ها

### شبکه‌های عصبی مصنوعی پرسپترون‌های چندلایه (MLP)

شبکه‌های عصبی مصنوعی<sup>۱</sup> جزء سیستم‌های دینامیکی هستند که با پردازش روی داده‌های تجربی، دانش یا قانون

نهمه در ورای داده‌ها را به ساختار شبکه منتقل می‌کند. به همین سبب به این سیستم‌ها هوشمند گفته می‌شود؛ زیرا بر مبنای محاسبات روی داده‌های مشاهداتی، قوانین کلی حاکم بر پدیده‌ها را کشف کرده و بر اساس آنها به پیش‌بینی‌هایی دست می‌زنند. در بیشتر موارد، مدل‌های اساساً فیزیکی را به دلیل سادگی می‌توان به کمک الگوریتم ANNs مدل‌سازی کرد. مدل‌های ANNs اغلب با ویژگی‌هایی مانند توپولوژی شبکه، خواص گره‌ها و قوانین آموزش و یادگیری مشخص می‌شوند. در میان الگوهای متفاوت ANNs، شبکه‌های پیش سو<sup>۱</sup> نسبت به سایر الگوها از محبوبیت بیشتری برخوردارند. ساختار شبکه شامل لایه‌هایی از المان‌های پردازشی موازی است که اصطلاحاً به آن نرون گفته می‌شود و در آن هر لایه توسط اتصال‌های میانی وزن دار، به لایه پردازشی متصل می‌شود. شکل ۱ یک شبکه عصبی سه‌لایه، شامل  $i$ ،  $j$  و  $k$  را با اتصال‌دهنده‌های میانی وزنی  $W_{ij}$  و  $W_{jk}$  بین نرون‌ها نشان می‌دهد. در هنگام شروع آموزش شبکه، وزن‌ها مقدار اولیه‌ای دارند که توسط مقادیری اتفاقی یا از نتایج آزمایشگاهی پیشین، مقداردهی می‌شوند.



شکل ۱. ساختار یک شبکه عصبی مصنوعی سه‌لایه

### مدل درختی M5

مدل درختی M5 گوئینان (۱۹۹۲: ۳۴۳) زیرمجموعه‌ای از روش‌های یادگیری ماشینی و داده‌کاوی است. داده‌کاوی به فرآیند جستجو و کشف مدل‌های گوناگون، مختصرسازی‌ها و اخذ مقادیر از مجموعه‌ای از مقادیر معلوم اطلاق می‌شود (علیخانزاده، ۱۳۸۵: ۱۴). روش‌های داده‌کاوی برای مجموعه داده‌های بزرگ با متغیرهای زیاد ساخته شده‌اند، بنابراین متفاوت از روش‌های آماری قدیمی هستند که برای مجموعه داده‌های کوچک با متغیرهای اندک طراحی شده بودند. روش‌های بر مبنای درخت، جزئی از روش‌های داده‌کاوی هستند که خروجی آنها با استفاده از داده‌های ورودی و خروجی، به صورت یک مدل با سازه درختی خواهد بود. نتایج مدل درختی، برای فهم و شبیه‌سازی آسان هستند، خروجی مدل از دقت بالایی برخوردار است و می‌توان آن را با مدل‌های دیگر مقایسه کرد. محققان می‌توانند در مسائل گوناگون از مدل درختی استفاده کنند (فلاحی، وروانی و گلیان، ۱۳۹۰).

1. Feed Forward Network  
2. Tree-Based Methods

یک درخت تصمیم معمولاً از چهار بخش ریشه<sup>۱</sup>، شاخه<sup>۲</sup>، گره‌ها<sup>۳</sup> و برگ‌ها<sup>۴</sup> تشکیل شده است که گره‌ها با دایره مشخص می‌شوند و شاخه‌ها نشان‌دهنده اتصال بین گره‌ها هستند. برای اینکه رسم درخت تصمیم آسان‌تر انجام گیرد، معمولاً آن را از چپ به راست یا از بالا به پایین می‌کشند؛ به طوری که ریشه (گره اول) در بالا قرار می‌گیرد. انتهای یک زنجیره را برگ می‌نامند. هر گره مربوط به یک ویژگی معین است و شاخه‌ها به معنای بازه‌ای از مقادیر هستند که این بازه‌های مقادیر، بخش‌های مختلف مجموعه مقادیر معلوم ویژگی‌ها را در اختیار کاربر قرار می‌دهند. عمل انشعاب توسط یکی از متغیرهای پیش‌بینی کننده انجام می‌پذیرد، بازه‌های انشعاب طوری انتخاب می‌شوند که مجموع مجذور انحراف از میانگین داده‌های هر گره را به حداقل برسانند (فلاحی، روانی و گلیان، ۱۳۹۰). مدل M5 یک مدل درختی برای پیش‌بینی صفات عددی پیوسته است که در آن، توابع رگرسیونی خطی در برگ‌های این درخت ظاهر می‌شوند (پال، ۲۰۱۲). این مدل در سال‌های اخیر، تحول چشمگیری را در مسائل طبقه‌بندی و پیش‌بینی ایجاد کرده است. اولین مرحله برای ایجاد یک مدل درختی، استفاده از یک معیار انشعاب است. معیار انشعاب برای الگوریتم M5 بر اساس عملکرد انحراف استاندارد مقادیر هر کلاس یا طبقه که در هر گره به دست آمده، در نظر گرفته می‌شود. این روش، اساس روش‌های طبقه‌بندی است که آنتروپی<sup>۵</sup> نامیده می‌شود. آنتروپی معیار میزان آشفتگی و بی‌نظمی یک سیستم تفسیر می‌شود. معیار انشعاب بیانگر میزان خطا در آن گره است و مدل، حداقل خطا مورد انتظار را به منزله نتیجه آزمایش هر صفت در آن گره، محاسبه می‌کند. خطا مدل عموماً با اندازه‌گیری دقت پیش‌بینی مقادیر هدف در قسمت مجموعه داده‌های آزمایش سنجش می‌شود. کاهش انحراف استاندارد (SDR) از رابطه ۱ محاسبه می‌شود.

$$SDR = Sd(T) - \sum_{i=1}^N \frac{|T_i|}{|T|} Sd(T_i) \quad \text{رابطه ۱}$$

$$Sd(T) = \sqrt{\frac{1}{N} \left( \sum_{i=1}^N y_i^2 - \frac{1}{N} \left( \sum_{i=1}^N y_i \right)^2 \right)} \quad \text{رابطه ۲}$$

در رابطه ۱؛  $T$ : مجموعه‌ای از نمونه‌های است (موارد) که به هر گره وارد می‌شود؛  $T_i$ : نشان‌دهنده زیرمجموعه‌ای از نمونه‌های است که آمین نتیجه تست پتانسیلی را دارند؛  $y_i$ : بیانگر انحراف معیار است؛  $i$ : مقدار عددی ویژگی هدف نمونه و N: شماره داده‌ها را نشان می‌دهد (آلبرگ، لست و کاندل، ۲۰۱۲).

مدل‌های تصمیم درختی انواع مختلفی دارند. در مواقعي که خروجی یک درخت، یک مجموعه گسسته از یک مجموعه مقادیر ممکن باشد، به آن طبقه‌بندی درختی گفته می‌شود. چنانچه بتوان خروجی درخت را یک عدد حقیقی در نظر گرفت، آن را رگرسیون درختی می‌نامند. به بیان دیگر، اگر متغیرهای ورودی به سیستم، عددی<sup>۶</sup> باشند، از رگرسیون

1. Root  
2. Beach  
3. Nodes  
4. Leafs  
5. Entropy  
6. Numerical

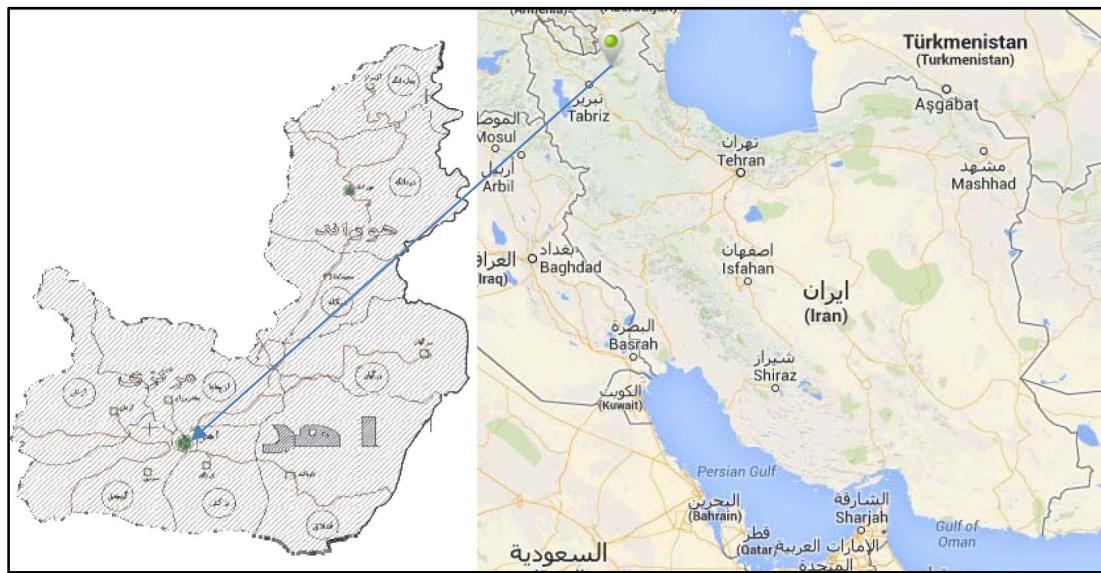
درختی<sup>۱</sup> و اگر مطلق و قیاسی باشد، از طبقه‌بندی درختی<sup>۲</sup> استفاده می‌کیم (فلاحی، وروانی و گلیان، ۱۳۹۰). فرآیند انشعاب در هر گره بارها تکرار می‌شود تا به گره پایانی (برگ) برسد که در این گره، مجموع مجذور انحراف از میانگین داده‌ها نقریباً به صفر می‌رسد. با این کار درخت بزرگی توسعه می‌یابد. کار با این درخت بزرگ که شاخه‌ها و گره‌های زیادی دارد، ساده نخواهد بود. بنابراین برای رسیدن به یک درخت بهینه و کارآمد، باید شاخه‌های اضافی درخت هرس شوند. دو روش برای هرس کردن درخت<sup>۳</sup> وجود دارد: ۱. هرس قبل از شکل‌گیری درخت حداکثر<sup>۴</sup> و ۲. هرس بعد از شکل‌گیری درخت حداکثر<sup>۵</sup>.

در روش اول، فرآیند هرس اجازه نمی‌دهد شاخه‌های اضافی تولید شوند، ولی در روش دوم ابتدا درخت حداکثر تشکیل می‌شود، سپس فرآیند هرس انجام می‌گیرد. درخت بهینه بر اساس حداقل کردن خطای پیش‌بینی انتخاب می‌شود. دو روش برای محاسبه خطای پیش‌بینی وجود دارد: ۱. آزمون دستگاه مستقل و ۲. آزمون صحتسنجی. هنگامی روش اول به کار می‌رود که تعداد داده‌ها زیاد باشد، در غیر این صورت از روش دوم استفاده می‌شود (فلاحی، وروانی و گلیان، ۱۳۹۰). پس از هرس کردن، نوبت به پروسه صاف کردن<sup>۶</sup> است و برای جبران گسیختگی‌های تندی که به طور اجتناب‌ناپذیر بین مدل‌های خطی هموار در برگ‌های درخت هرس شده، به خصوص برای مدل‌هایی که با تعداد نمونه‌های کمتری ساخته شده‌اند، انجام می‌گیرد (باچاربا و سولوماتین، ۲۰۰۴). در این پژوهش از نرم‌افزار WEKA<sup>۷</sup> که در دانشگاه وایکاتو نیوزلند توسعه داده شده برای مدل‌سازی روش M5 استفاده شده است. همچنین مدل‌سازی شبکه عصبی مصنوعی به کمک نسخه پنجم نرم‌افزار Neuro Solutions انجام گرفته است.

### معرفی منطقه مورد مطالعه و داده‌های مورد استفاده

شهرستان اهر در شرق استان آذربایجان شرقی واقع شده است. ایستگاه سینوپتیک این شهر که در سال ۱۹۸۵ تأسیس شده است، در طول جغرافیایی ۴۷ درجه و ۴ دقیقه شرقی و عرض جغرافیایی ۳۸ درجه و ۲۶ دقیقه شمالی قرار دارد و ارتفاع آن از سطح دریا ۱۳۹۱ متر است. شکل ۲ موقعیت جغرافیایی شهرستان اهر را نمایش می‌دهد. در این پژوهش داده‌های ۱۶ سال، از بهمن ماه سال ۱۳۶۴ تا اسفند ماه سال ۱۳۸۹ استفاده شده است که ۸۰ درصد از آنها داده‌های آموزشی<sup>۸</sup> و ۲۰ درصد داده‌ها، داده‌های آزمایشی<sup>۹</sup> هستند.

1. Regression Tree
2. Classification Tree
3. Tree Pruning
4. Pre-Pruning
5. Post-Pruning
6. Smoothing
7. Waikato Environment for Knowledge Analysis
8. Training Data
9. Testing Data



شکل ۲. موقعیت جغرافیایی شهرستان اهر

عملکرد مدل‌های مورد استفاده در این پژوهش بر پایه محاسبه ضریب همبستگی  $R$  و جذر میانگین مربعات خطای ارزیابی شده است. روش محاسبه دو آماره فوق به ترتیب در قالب روابط ۳ و ۴ آمده است.

$$R = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2 * \sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad \text{رابطه ۳}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Y_i - X_i)^2}{N}} \quad \text{رابطه ۴}$$

جدول ۱، خصوصیات آماری برای داده‌های مورد استفاده در این پژوهش را نشان می‌دهد. در این پژوهش با توجه به ماهیت مسئله، ابتدا سناریوهای مختلفی از لایه‌های ورودی، پنهان و خروجی برای شبکه عصبی مصنوعی تعریف شد و پس از اجرای مدل، براساس آماره‌های  $R$  و  $RMSE$ ، دقت پیش‌بینی مدل مورد بررسی قرار گرفت.

جدول ۱. مشخصات آماری داده‌های مورد استفاده

آماره	میانگین	انحراف استاندارد	حداکثر	متوسط حداقل دما	متوسط حداکثر دما	متوسط حداقل	متوسط حداکثر	متوسط سطح ایستگاه	متوسط حداکثر فشار	متوسط حداکثر HPA	بارش ماهانه (mm)
میانگین	۵/۲۸	۷/۲۳	۱۶/۴۳	۳۹/۹۲	۷۸/۷	۸۵۹/۲۳	۸۶۲/۵۷	۸۶۲/۵۷	۸۵۹/۲۳	۸۶۲/۵۷	۲۳/۷۴
استاندارد	۷/۲۳	۹/۱۹	۹/۱۹	۹/۹۳	۷/۳۹	۲/۲۷	۲/۱۶	۲/۱۶	۲/۲۷	۲/۱۶	۲۱/۷۶
حداکثر	۱۷/۱۶	۳۰/۷۵	۳۰/۷۵	۶۶/۹	۹۳/۵۳	۸۶۶/۰۶	۸۶۸/۶۴	۸۶۸/۶۴	۸۶۶/۰۶	۸۶۸/۶۴	۱۲۷/۴
حداکثر	-۱۳/۸۹	-۳/۷۹	-۳/۷۹	۲۰/۲۳	۵۴/۲۷	۸۵۱/۹۶	۸۶۸/۶۱	۸۶۸/۶۱	۸۵۱/۹۶	۸۶۸/۶۱	۰/۰۰

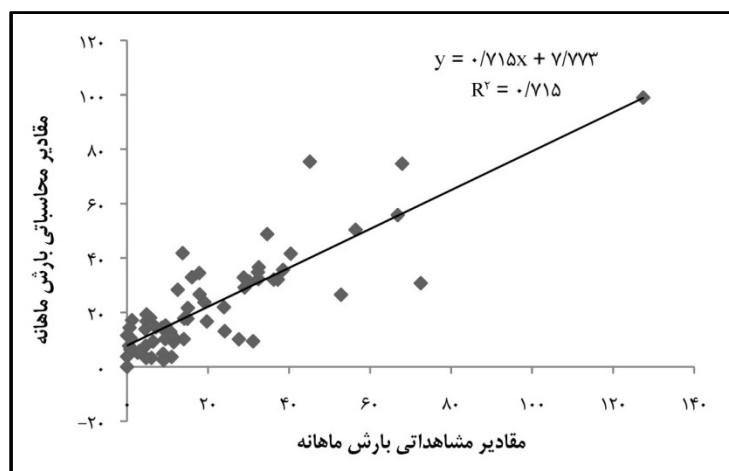
## یافته‌های پژوهش

در پژوهش پیش رو، ابتدا پارامترهای گوناگونی، شامل میانگین، متوسط مقدار حداقل و حداکثر دمای ماهانه، میانگین، متوسط مقدار حداقل و حداکثر رطوبت نسبی ماهانه، میانگین، متوسط مقدار حداقل و حداکثر فشار ماهانه سطح ایستگاه، ساعات آفتابی، جهت و سرعت شدیدترین باد، میزان ابرناکی و بارش در ماه قبل، به کار گرفته شدند. از آنجا که هدف پژوهش حاضر، به دست آوردن تأثیرگذارترین پارامترها در میزان بارش ماهانه و همچنین پیدا کردن روابط ساده برای تخمین میزان بارش ماهانه است، پارامترهایی که تأثیر چندانی نداشتند با استفاده از روش آزمون و خطا و همچنین ماتریس همبستگی، حذف شدند. سپس برای تعیین بهترین ترکیب پارامترها، هشت سناریو از ترکیب‌های متفاوت داده‌های ورودی، وارد شبکه عصبی مصنوعی و مدل درختی M5 شده است که این سناریوها و نتایج مربوط به هر سناریو، در دو مدل بر اساس دو آماره R و RMSE در جدول ۲ نشان داده شده است.

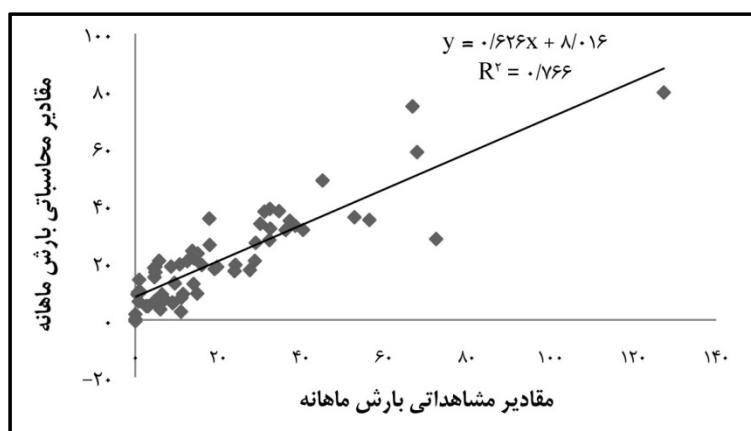
جدول ۲. نتایج دو روش ANN و M5 در سناریوهای مختلف از ترکیب پارامترهای ورودی

سناریو	پارامترهای ورودی			
	M5	ANN		
	R	RMSE (میلی‌متر)	R	RMSE (میلی‌متر)
۱	۰/۷۸	۱۴	۰/۸	۱۳/۸
	شاخص ماهانه، میانگین، متوسط مقدار حداقل و حداکثر دمای ماهانه، میانگین، متوسط مقدار حداقل و حداکثر رطوبت نسبی ماهانه، میانگین، متوسط مقدار حداقل و حداکثر فشار ماهانه سطح ایستگاه، بارش در ماه قبل			
۲	۰/۸۶	۱۱/۹	۰/۸۳	۱۲/۵۵
	میانگین، متوسط مقدار حداقل و حداکثر دمای ماهانه، میانگین، متوسط مقدار حداقل و حداکثر رطوبت نسبی ماهانه، میانگین، متوسط مقدار حداقل و حداکثر فشار ماهانه سطح ایستگاه، بارش در ماه قبل			
۳	۰/۸۶	۱۱/۸	۰/۸۳	۱۲/۵۱
	میانگین، متوسط مقدار حداقل و حداکثر دمای ماهانه، میانگین، متوسط مقدار حداقل و حداکثر رطوبت نسبی ماهانه، میانگین، متوسط مقدار حداقل و حداکثر فشار ماهانه سطح ایستگاه			
۴	۰/۸۷	۱۱/۴	۰/۸۳	۱۲/۲۷
	متوسط مقدار حداقل و حداکثر دمای ماهانه، متوسط مقدار حداقل و حداکثر رطوبت نسبی ماهانه، متوسط مقدار حداقل و حداکثر فشار ماهانه سطح ایستگاه			
۵	۰/۸۲	۱۲/۸	۰/۸	۱۳/۴۷
	شاخص ماهانه، میانگین دمای ماهانه، میانگین رطوبت نسبی ماهانه، میانگین فشار ماهانه سطح ایستگاه، بارش در ماه قبل			
۶	۰/۸	۱۳/۲	۰/۷۸	۱۳/۹۸
	شاخص ماهانه، میانگین دمای ماهانه، میانگین رطوبت نسبی ماهانه، میانگین فشار ماهانه سطح ایستگاه			
۷	۰/۸۵	۱۱/۴	۰/۸۱	۱۳/۲۳
	شاخص ماهانه، متوسط حداقل و حداکثر دمای ماهانه، متوسط حداقل و حداکثر رطوبت نسبی ماهانه، متوسط حداقل و حداکثر فشار ماهانه سطح ایستگاه، بارش در ماه قبل			
۸	۰/۸۷	۱۱/۶	۰/۸۴	۱۲/۱۴
	متوسط حداقل و حداکثر دمای ماهانه، متوسط حداقل و حداکثر رطوبت نسبی ماهانه، متوسط حداقل و حداکثر فشار ماهانه سطح ایستگاه، بارش در ماه قبل			

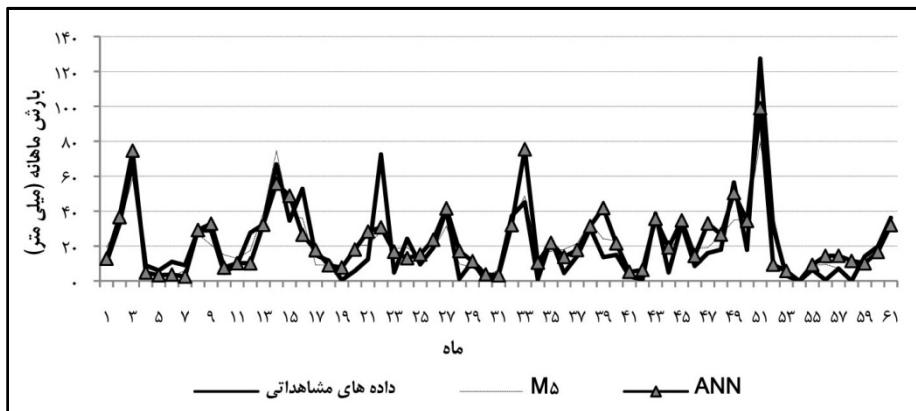
در مرحلهٔ بعدی مدل سازی شبکه‌های عصبی مصنوعی، از تابع تانژانت هیپربولیک بهمترلهٔ تابع محرک و قاعدهٔ آموخته مومنتوم استفاده شده است. گفتنی است این تابع باعث همگرا شدن سریع شبکه می‌شود. همان‌طور که از نتایج جدول ۲ پیداست، در مدل شبکهٔ عصبی مصنوعی، سناریوی ۸ با هفت پارامتر ورودی (با یک لایهٔ پنهان) بهترین نتیجه را می‌دهد ( $R = 0.84$ ) و در مدل درختی M5، بهترین نتیجه مربوط به سناریوی ۴ با شش پارامتر ورودی بوده ( $R = 0.87$ ) که برترین سناریو برای معرفی به مدل‌ها در نظر گرفته شده است. نتایج مربوط به مقادیر مشاهداتی بارش به دست آمده از مدل شبکهٔ عصبی مصنوعی و مدل درختی M5، در مقابل مقادیر محاسباتی برای پارامترهای ورودی در سناریوهای برتر مربوط به هر مدل، به ترتیب در شکل‌های ۳ و ۴ نشان داده شده است. مقدار نسبتاً بالای  $R^2$  در این شکل‌ها، نشان‌دهنده قدرت بالای مدل‌ها در پیش‌بینی بارش ماهانه منطقهٔ مورد مطالعه است. شکل ۵ نیز تشابه بالای نتایج حاصل از دو روش شبکهٔ عصبی مصنوعی و مدل درختی M5 را با نتایج مشاهداتی بارش برای داده‌های آزمایش نشان می‌دهد.



شکل ۳. مقادیر محاسباتی و مشاهداتی بارش ماهانه در مدل ANN



شکل ۴. مقادیر محاسباتی و مشاهداتی بارش ماهانه در مدل M5



شکل ۵. مقایسه نتایج سری زمانی بارش ماهانه بدستآمده از مدل‌ها با داده‌های مشاهداتی

نتایج حاصل از کاربرد مدل درختی M5 در پیش‌بینی بارش ماهانه ناحیه مذکور که منجر به ایجاد شش رابطه خطی شده است، در شکل ۶ مشاهده می‌شود.

$rh_{max} \leq 78/78 :$	$LM\ 1: rain = .1857 \times t_{min} + .1906 \times t_{max} + .842 \times rh_{max} + 17.51 \times qfe_{min} - 2485 \times qfe_{max} + 630/6767$
$  t_{min} \leq 8/59 : LM1$	
$  t_{min} > 8/59 : LM2$	$LM\ 2: rain = -.3118 \times t_{min} + .1778 \times t_{max} + .4269 \times rh_{max} + .693 \times qfe_{min} - .9013 \times qfe_{max} + 157/3147$
$rh_{max} > 78/78 :$	$LM\ 3: rain = .7857 \times t_{min} - .351 \times t_{max} + .188 \times rh_{min} + .5216 \times rh_{max} + .2768 \times qfe_{min} - .11124 \times qfe_{max} + 7.5/7729$
$  rh_{max} \leq 84/26 :$	
$    qfe_{max} \leq 861/235 : LM4$	$LM\ 4: rain = .3027 \times t_{min} - .351 \times t_{max} + .5748 \times rh_{min} + .5216 \times rh_{max} + .2768 \times qfe_{min} - .8688 \times qfe_{max} + 466/3929$
$  rh_{max} > 84/26 :$	$LM\ 5: rain = .3173 \times t_{min} - .39 \times t_{max} + .7791 \times rh_{min} + .12134 \times rh_{max} + .2768 \times qfe_{min} - .5855 \times qfe_{max} + 10.49/4156$
$    t_{min} \leq -.13 : LM5$	
$    t_{min} > -.13 : LM6$	$LM\ 6: rain = .586 \times t_{min} - .39 \times t_{max} + .3772 \times rh_{min} + .9792 \times rh_{max} + .2768 \times qfe_{min} - .6865 \times qfe_{max} + 4573/5648$

شکل ۶. مدل درختی M5 و روابط خطی برای پیش‌بینی بارش ماهانه

روابط خطی مذکور در بازه‌های مشخصی از داده‌های ورودی ارائه شده است. اعداد داخل پرانتز در مدل درختی M5 به ترتیب تعداد مواردی از داده‌ها را به صورت درصد نشان می‌دهد که در هر رابطه خطی صدق می‌کند و درصد خطای مربوط به هر رابطه خطی، ناظر به قانون مذکور است. برای مثال، چنانچه مقدار متوسط حداقل رطوبت نسبی کوچکتر از ۷۸/۷۸ درصد و متوسط حداقل دما نیز کوچکتر از ۸/۵۹ درجه سانتی‌گراد باشد، آنگاه مقدار بارش ماهانه را می‌توان با استفاده از رابطه خطی LM1 محاسبه کرد.

در روابط فوق؛  $t_{\min}$ : متوسط حداقل دما بر حسب درجه سانتی گراد؛  $t_{\max}$ : متوسط حداکثر دما بر حسب درجه سانتی گراد؛  $rh_{\min}$ : متوسط حداقل رطوبت نسبی بر حسب درصد؛  $rh_{\max}$ : متوسط حداکثر رطوبت نسبی بر حسب درصد؛  $qfe_{\min}$ : متوسط حداقل فشار ماهانه سطح ایستگاه بر حسب هکتوپاسکال و  $qfe_{\max}$ : متوسط حداکثر فشار ماهانه سطح ایستگاه بر حسب هکتوپاسکال است. مقادیر R و RMSE برای مقایسه دو روش شبکه عصبی مصنوعی و M5 در جدول ۳ نشان داده شده است.

جدول ۳. نتایج حاصل از دو روش متفاوت پیش‌بینی بارش ماهانه در سناریوی هشت

روش	R	RMSE (میلی‌متر)
ANN	-0.84	12/14
M5	-0.87	11/45

با توجه به جدول ۳ مشاهده می‌شود که به ترتیب روش‌های مدل درختی M5 و شبکه عصبی مصنوعی با دقت بالا و مطلوبی می‌توانند بارش ماهانه ایستگاه هواشناسی اهر را پیش‌بینی کنند. همان‌گونه که از شکل ۶ استنباط می‌شود، مزیت عمده مدل درختی M5 اینست که عامل رطوبت نسبی و محدوده تغییرات آن را یکی از تأثیرگذارترین پارامتر ورودی در مدل‌سازی بارش در نظر می‌گیرد و براساس مقادیر آن، مدل درختی را توسعه می‌دهد. در واقع این عملکرد مدل درختی M5 با واقعیت فیزیکی و سازوکار تشکیل بارش نیز سازگار است. این درحالیست که شبکه عصبی مصنوعی، بی‌آنکه به فیزیک مسئله توجهی داشته باشد و اهمیت هریک از پارامترهای هواشناسی را در نظر بگیرد، صرفاً با استفاده از حافظه سیستم اقدام به پیش‌بینی بارش می‌کند.

## بحث و نتیجه‌گیری

در این پژوهش از داده‌های ایستگاه هواشناسی اهر به منزله ورودی، برای پیش‌بینی بارش ماهانه به دو روش شبکه عصبی مصنوعی و مدل درختی M5 استفاده شد. نتایج نشان داد که در روش شبکه‌های عصبی مصنوعی، سناریویی که در آن ورودی مدل، از پارامترهای متوسط حداقل و حداکثر دمای ماهانه، متوسط حداقل و حداکثر رطوبت نسبی ماهانه، متوسط حداقل و حداکثر فشار ماهانه سطح ایستگاه و بارش ماه قبل تشکیل شده، از دقت قابل قبول و بالایی برخوردار است. همچنین در مدل درختی M5، سناریویی که ورودی آن شامل متوسط حداقل و حداکثر دمای ماهانه، متوسط حداقل و حداکثر رطوبت نسبی ماهانه و متوسط حداقل و حداکثر فشار ماهانه سطح ایستگاه بود، برترین سناریو انتخاب شد. با توجه به مقدار بالای ضریب همبستگی حاصل از دو روش شبکه عصبی مصنوعی و مدل درختی M5، نتیجه می‌شود که هر دو روش استفاده شده، می‌توانند با دقت نسبتاً بالایی میزان بارش ماهانه را تخمین بزنند. در این میان، مدل درختی M5 با توجه به دقت بالاتر ( $R = 0.87$ ) نسبت به روش شبکه عصبی ( $R = 0.84$ ) و تعداد کمتر متغیر ورودی مورد نیاز برای تخمین بارش ماهانه و نیز، به لحاظ سادگی، قابل فهم بودن و ارائه روابط خطی ساده در محدوده خاصی از داده‌های ورودی، بهتر از روش شبکه عصبی مصنوعی شناخته شد.

با در نظر گرفتن مطالعات پژوهشگران دیگر در زمینه پیش‌بینی بارش با استفاده از روش شبکه عصبی مصنوعی، مشاهده می‌شود که پژوهش حاضر نسبت به مطالعات دیگر از دقت مطلوبی برخوردار است. برای مثال، ترافالیس و همکاران (۲۰۰۵) بارش را با استفاده از روش شبکه عصبی مصنوعی برابر با  $R = 0.2$  تخمین زندن. فلاخ قالهری و همکاران مقدار  $R = 0.38$  را برای روش شبکه عصبی مصنوعی در پیش‌بینی بارش به دست آوردند. در حالیکه در پژوهش حاضر مقدار  $R = 0.71$  برای روش شبکه عصبی مصنوعی به دست آمد. نتایج برخی پژوهش‌ها نیز کمابیش نزدیک به یافته‌های این پژوهش بوده است. از جمله قلی‌زاده و دارند (۱۳۸۹)، میزان بارش در تهران را بدون اعمال الگوریتم ژنتیک در مدل شبکه‌های عصبی مصنوعی، مقدار  $R = 0.88$  پیش‌بینی کردند. فلاخی و همکاران (۱۳۹۰) با به کارگیری مدل رگرسیون درختی، میزان بارش روزانه را در سه ایستگاه هواشناسی بندرآزلی، اراک و قم با استفاده از داده‌های روزانه دما، رطوبت نسبی و ساعت آفتابی با میزان  $R = 0.86$  تخمین زندن.

با توجه به ساده و کارآمد بودن روش M5 که دقت قابل قبولی نیز از خود نشان داد، می‌توان کاربرد این روش را در مباحث مرتبط توصیه کرد.

## منابع

- حلیمان، ا. ح. (۱۳۸۸). پیش‌آگاهی و برآورد بارش یزد با استفاده از شبکه عصبی مصنوعی. *نشریه تحقیقات کاربردی علوم جغرافیایی*، دوره ۳، شماره ۱۴، صص. ۷-۲۸.
- خلیلی، ن؛ خداشناس، س. ر؛ داوری، ک. و موسوی بایگی، س. م. (۱۳۸۹). پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی (مطالعه موردی: ایستگاه سینوپتیک مشهد). *پژوهش‌های آبخیزداری*، دوره ۲۳، شماره ۸۹، صص. ۷-۱۵.
- ستاری، م. و نهرین، ف. (۱۳۹۲). پیش‌بینی مقادیر حداقل بارش روزانه با استفاده از سیستم‌های هوشمند و مقایسه آن با مدل درختی M5 (مطالعه موردی: ایستگاه‌های اهر و جلفا). *فصلنامه علمی پژوهشی مهندسی آبیاری و آب*، دوره ۴، شماره ۱۴، صص. ۸۳-۹۸.
- ستاری، م؛ نهرین، ف. و عظیمی، و. (۱۳۹۲). پیش‌بینی تبخیر - تعرق مرجع روزانه با استفاده از مدل شبکه عصبی مصنوعی و مدل درختی ام ۵. *نشریه آبیاری و زهکشی ایران*، دوره ۷، شماره ۱، صص. ۱۱۳-۱۰۴.
- علیخانزاده، ا. (۱۳۸۵). *داده‌کاوی*، چاپ اول، بابل: نشر علوم رایانه.
- فاتحی مرغ، ا. و مهدیان، م. ه. (۱۳۸۸). پیش‌بینی بارش پاییزه با استفاده از شاخص‌های انسو به روش شبکه عصبی در حوضه دریاچه ارومیه. *پژوهش‌های آبخیزداری*، دوره ۲۲، شماره ۸۴، صص. ۵۲-۴۲.
- فلاح قالهری، غ. ع. و خوشحال دستجردی، ج. (۱۳۸۸). پیش‌بینی بارش بهاره استان خراسان رضوی بر اساس سیگنال‌های بزرگ مقیاس اقلیمی با استفاده از شبکه‌های عصبی مصنوعی. *مجله پژوهش‌های جغرافیای طبیعی*، دوره ۴۰، شماره ۶۹، صص. ۱۳۳-۱۱۵.
- فلاح قالهری، غ. ع؛ موسوی بایگی، س. م. و حبیبی نوختدان، م. (۱۳۸۸). مقایسه نتایج به دست آمده از کاربرد سیستم استنباط فازی ممدانی و شبکه‌های عصبی مصنوعی در پیش‌بینی بارش فصلی (مطالعه موردی: منطقه خراسان). *تحقیقات منابع آب ایران*، دوره ۵، شماره ۲، صص. ۵۲-۴۰.
- فلاحی، م؛ وروانی، ه و گلیان، س. (۱۳۹۰). پیش‌بینی بارش با استفاده از مدل رگرسیون درختی به منظور کنترل سیل. پنجمین کنفرانس سراسری آبخیزداری و مدیریت منابع آب و خاک کشور، کرمان.

قلیزاده، م. ح. و دارند، م. (۱۳۸۹). پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی (سورد: تهران). پژوهش‌های جغرافیای طبیعی، دوره ۴۲، شماره ۷۱، صص. ۵۱-۶۳.

نهرین، ف؛ ستاری، م. و سلماسی، ف. (۱۳۹۲). پیش‌بینی اتلاف کارمایه در سریز توری سنگی پله‌ای با استفاده از شبیه‌سازی درختی M5. مجله مهندسی منابع آب، دوره ۶، شماره ۱۹، صص. ۷۵-۸۶.

Alberg, D., Last, M., Kandel, A., 2012, **Knowledge Discovery in Data Streams with Regression Tree Methods**. Wiley Interdisciplinary Reviews: Data Mining Knowledge Discovery, Vol. 2, No. 1, PP. 69-78.

Alikhanzadeh, A., 2006, **Data Mining**, First Eddition, Computer Scince Publication, Babol.

Bhattacharya, B., Solomatine, D.P., 2005, **Neural Networks and M5 Model Trees in Modeling Water Level-discharge Relationship**, Neurocomputing, Vol. 63, PP. 381-396

Ditthakit, P., Chinnarasri, C.H., 2012, **Estimation of Pan Coefficient Using M5 Model Tree**, American Journal of Environmental Sciences, Vol. 8, No. 2, PP. 95-103.

Fallah, G., Khoshhal Dastjerdi, J., 2010, **Spring Precipitation Prediction Province Based on Large-scale Climate Signals Using Artificial Neural Networks**, Research in Natural Geography, Vol 69. No. 40, PP. 115-133.

Fallahi, M., Varvani, H., Golian, S., 2011, **Rainfall Forecasting Using Regression Tree Model for Flood Control**, 5<sup>th</sup> National Conference on Watershed Management and Soil and Water Resource Management, Kerman, PP. 248-256, Kerman.

Fatehi Marj, A., Mahdian, M. H., 2009, **Autumn Rainfall Forecasting Using ENSO Indices by Neural Network Method**, Watershed Management Researches (Pajouhesh & Sazandegi), Vol. 84. No 22, PP. 42-52.

Fllah, G., Mousavi Baygi, S., Habibi Nokhandan, M., 2009, **Results Compression Mamdani Fuzzy Interface System and Artificial Neural Networks int the Seasonal Rainfall Prediction (Case Study: Khorasan Region)**, Iran-water Resources Research, Vol. 5, No, 2, PP.40-52.

Golizadeh, M H., Darand, M., 2010, **Forecasting Monthly Precipitation by Using Artificial Neural Networks (A Case Study: Tehran)**. Research in Natural Geography, Vol. 71, No. 42, PP.51-63.

Hakurta, P.G., 2008, **Long Lead Monsoon Rainfall Prediction for Meteorological Sub-divisions of India Using Deterministic Artificial Neural Network Model**, Meteorology and Atmospheric Physic, Vol. 101, No. 1-2, PP. 93-108.

Halabian, A. H., 2009, **The Prognosis of Yazd Precipitation Estimates Using an Artificial Neural Network**, Journal of Geographical Sciences and Applied Research, Vol 14. No 3., PP. 7-28.

Khalili, N., Khodashenas, S. R., Davari, K., Mousavi Baygi, S. M., 2008, **Forecasting Monthly Precipitation by Using Artificial Neural Networks (a Case Study: Mashhad Synoptic Station)**, Watershed Management Researches (Pajouhesh & Sazandegi), Vol 89, No. 23, PP. 7-15.

Nahrein, F., Sattari, M., Salmasi, F., 2013, **Predicting Energy Dissipation in Flowing Chiffon Stepping Stone Using a M5 Model Tree**, Journal of Water Resources Engineering, Vol. 6, No. 16, PP. 75-86.

Pal, M., 2006, **M5 Model Tree for Land Cover Classification**, International Journal of Remote Sensing, Vol. 27, No. 4, PP. 825-831.

Pal, M., Deswal, S., 2009, **M5 Model Tree Based Modeling of Reference Evaporation**, Hydrological Processes, Vol. 23, No. 10, PP. 1437-1443.

Pal, M., Singh, N.K., Tiwari, N. K., 2012, **M5 Model Tree for Pier Scour Prediction Using Field Dataset**, Kimberley Structural Consulting Engineers Journal of Civil Engineering, Vol. 16, No. 6, PP. 1079-1084.

Quinlan, J.R., 1992, **Learning with Continuous Classes**, In Proceedings AI, 92 (Adams & Sterling, Eds), Singapore: World Scientific, PP. 343-348.

Sattari, M., Nahrein, F., 2013, **Monthly Rainfall Prediction Using Artificial Neural Networks and M5 Model Tree (Case study: Stations of Ahar and Jolfa)**, Journal of Irrigation and Water, Vol. 14, No. 4, PP.83-98.

Sattari, M., Nahrein, F., Azimi, V., 2013, **M5 Model Trees and Neural Networks Based Prediction of Daily ET0 (Case Study: Bonab Station)**, Iranian Journal of Irrigation and Drainage, Vol. 7, No. 1, PP.104-113.

- Sattari, M.T., Pal, M. Apaydin, H. Ozturk, F, 2013, **M5 Model Tree Application in Daily River Flow Forecasting in Sohu Stream, Turkey**, Water Resources, Vol. 40, No. 3, PP. 233–242.
- Sattari, M.T., Pal, M., Yurekli, K., Unlukara, A., 2013, **M5 Model Trees and Neural Network Based Modeling of ET<sub>0</sub> in Ankara, Turkey**, Turkish Journal of Engineering and Environmental Sciences, Vol. 37, No. 2, PP. 211- 219.
- Singh, K.K., Pal, M., Singh, V.P., 2010, **Estimation of Mean Annual Flood in Indian Catchment Using Back Propagation Neural Network and M5 Model Tree**, Water Resour Manage, Vol. 24, No. 10, PP. 2007-2019.
- Trafalis, T.B., Santosa, B., Richman, M.B., 2005, **Learning Networks in Rainfall Estimation**, CMS, Vol. 2, No. 3, PP. 229-251.