

برآورد بارش به کمک شبکه عصبی مصنوعی با داده‌های هواشناسی غیربارشی در سه منطقه شیراز، مشهد و کرمان

علی‌رضا ایلدرومی^۱
حمید زارع ایبانه^۲
مریم بیات ورکشی^۳

چکیده

عنصر بارش ماهیت آشوبناکی و تصادفی داشته و از این نظر دارای تغییرات ساختاری در زمان‌های مختلف است. در این راستا به دلیل عدم قطعیت‌هایی که وجود دارد، نوسان‌های زیادی در مقدار بارش ایجاد می‌شود که پیش‌بینی این کمیت مهم را با مشکل مواجه نموده است. در این مقاله با تکنیک مقیاس‌بندی مجدد (R/S) و محاسبه نمای هرست (H) پیش‌بینی‌پذیری بارش در سه منطقه شیراز، کرمان و مشهد انجام شد. نمای هرست نشان داد که پارامتر بارش قابلیت پیش‌بینی‌پذیری را دارد، زیرا H از ۰/۵ بزرگ‌تر بوده و بمراتب به مقدار ۱ نزدیک‌تر است. به طوری که نمای هرست از حداقل ۰/۸ در ایستگاه مشهد تا حداکثر ۰/۹۲ در ایستگاه شیراز در نوسان بود. به منظور پیش‌بینی بارش از شبکه‌های عصبی مصنوعی استفاده شد. نوع پارامترهای ورودی براساس آزمون همبستگی پیرسون از بین داده‌های غیربارشی، ترکیبی از داده‌های دمایی و رطوبتی بودند. تعداد پارامترهای ورودی، تعداد لایه‌های میانی و سایر اطلاعات مربوط به شبکه عصبی مصنوعی به صورت تصادفی انتخاب و پیشنهاد شدند. در مجموع از شبکه‌های عصبی پرسپترون چند لایه برای برآورد بارش

۱- استادیار گروه مهندسی آبخیزداری دانشکده محیط زیست و منابع طبیعی دانشگاه ملایر.

۲- استادیار گروه مهندسی آبیاری دانشکده کشاورزی دانشگاه بوعلی سینا.
Email:zareabyaneh@gmail.com

۳- دانشجوی دکتری رشته آبیاری و زهکشی گروه مهندسی آبیاری دانشگاه بوعلی سینا.

استفاده شد. مقایسه عملکرد شبکه‌های عصبی، نشان داد که استفاده از ۳ و ۴ پارامتر هواشناسی، بهترین رتبه برآوردگری را داشته‌اند. آرایش‌های پیشنهادی برای ایستگاه شیراز، ۱-۲۱-۲۱-۳، کرمان ۱-۲۵-۲۵-۳ و مشهد ۱-۱۹-۱۹-۴ دارای ضریب همبستگی بیش از ۹۱ درصد شد. اعتبارسنجی مدل‌های بارش نشان داد که شبکه‌های طراحی شده برای پارامتر بارش در ایستگاه‌های مشهد، شیراز و کرمان به ترتیب با خطای ۴، ۱۱ و ۱۴ درصد، دارای بهترین عملکرد بوده‌اند. در مجموع نتایج نشان می‌دهند که استفاده از روش شبکه عصبی با در نظر گرفتن اطلاعات دمایی و رطوبتی، نتایج مناسبی برای توصیف فرآیند و ترکیب آن‌ها در پیش‌بینی، به دست می‌دهند.

واژگان کلیدی: بارش سالانه، پیرسون، شبکه عصبی مصنوعی، دمای هوا، رطوبت نسبی، نمای هرست.

مقدمه

بارش یکی از مهم‌ترین عوامل مورد استفاده در مطالعات منابع طبیعی می‌باشد که با توجه به نوسان‌ها و بی‌نظمی‌های موجود در سری زمانی بارش، تشخیص پیش‌بینی‌پذیری و شناخت عوامل تاثیرگذار بر فرآیند بارش اهمیت دارد. پیش‌بینی‌پذیری یک سری زمانی مساله‌ای است که در مورد فرآیندهای هواشناسی کمتر مورد توجه قرار گرفته است. تحقیقات صورت گرفته در خصوص پیش‌بینی‌پذیری یک سری زمانی، به صورت محدود در بررسی فرآیندهایی مانند قیمت سهام در بازار بورس (خالوزاده و همکاران، ۱۳۷۷: ۹۷)، قیمت برق (احمری‌نژاد، ۱۳۸۴: ۴)، داده‌های هواشناسی (صوفی‌وند و همکاران، ۱۳۸۴: ۲) و بارش (خلیلی و همکاران، ۱۳۸۷: ۳۶۸) انجام شده است. پیش‌بینی‌پذیری برای تعیین میزان اغتشاش‌های یک سری زمانی و تصادفی بودن آن است. یکی از راه‌های تشخیص پیش‌بینی‌پذیری، تحلیل مقیاس‌بندی مجدد^۱ (R/S) است که در تشخیص یک سری تصادفی از غیرتصادفی، بدون توجه به نوع توزیع آن، کاربرد دارد (احمری‌نژاد و همکاران، ۱۳۸۴: ۳). تحلیل R/S، یک روش آماری مقاوم^۲ در سنجش میزان آشوبناکی یا اغتشاشات یک سری زمانی کاربرد

1- Rescaled range analysis

2- Robust statistical method

دارد. در حالی که عدم قطعیت‌های موجود در مقادیر کمی سری بارش‌ها، پیش‌بینی آن را تا حدودی مشکل ساخته است. روش‌های متعددی جهت پیش‌بینی مقدار بارش طرح شده‌اند که در افق‌های مختلف زمانی اعم از کوتاه‌مدت و بلندمدت از کارایی لازم برخوردارند. در این خصوص می‌توان به مدل پارامتریک پیشنهادی توسط قاسمی و سپاسخواه (۱۳۸۳: ۴۵) اشاره نمود. آن‌ها با روش رگرسیون و به‌کارگیری متغیرهای زمان وقوع رگبارهای پاییزه، میانگین درازمدت بارندگی، دمای سطح آب خلیج فارس و مشخصه‌های جغرافیایی ایستگاه-های هواشناسی موفق به پیش‌بینی مقدار بارش شدند. فولادمند (۱۳۸۵: ۱۱۵) با استفاده از مقادیر بارندگی بیش از ۵ میلی‌متر حادث شده طی دو روز متوالی طی یک دوره زمانی سالانه از تقریب اول زنجیر مارکوف و تابع توزیع گاما موفق به تعیین تعداد روزهای بارانی و مقدار بارش سالانه برای منطقه باجگاه شیراز شدند. صوفی‌وند و همکاران (۱۳۸۴: ۲) از روش مدل‌سازی چندگانه بر مبنای مجموعه مدل‌های ایجاد شده، داده‌های دما، فشار و رطوبت نسبی را برآورد کردند. برخی تحقیقات انجام شده در سال‌های اخیر نشان‌دهنده استفاده از مدل‌های هوشمند عصبی به‌واسطه سرعت دست‌یابی به نتایج دقیق‌تر به‌موازات دیگر مدل‌ها است (زارع ایبانه و همکاران، ۱۳۸۸: ۱۷۸؛ زارع ایبانه و بیات ورکشی، ۱۳۹۰: ۳۵). انجمن مهندسين آمریکا (۲۰۰۰) انعطاف‌پذیری شبکه عصبی مصنوعی^۱ (ANN) در مدل‌سازی فرآیندهای غیرخطی را عامل موفقیت آن در مباحث مربوط به مهندسی آب گزارش نموده است. با این حال فاتحی مرج و مهدیان (۱۳۸۸: ۳) اعتقاد دارند به‌کارگیری شبکه‌های عصبی مصنوعی در مباحث آب بیشتر به پیش‌بینی جریانات رودخانه‌ای محدود بوده و در خصوص پیش‌بینی بارش کمتر استفاده شده است. یک شبکه عصبی متشکل از نرون‌هایی به تعداد متغیرهای مستقل در لایه ورودی، یک لایه خروجی با نرون‌هایی به تعداد متغیر (های) مجهول و یک یا چند لایه میانی هستند (زارع ایبانه و همکاران، ۱۳۸۹: ۱۷). نتایج اکثر پژوهش‌ها عموماً بر استفاده از متغیرهای ورودی بیشتر برای برآوردهای مناسب‌تر تأکید دارند. کریمی گوغری و اسلامی (۱۳۸۷: ۱۲۵) از شبکه عصبی با ۵ متغیر زمان وقوع اولین بارش ۴۷/۵ میلی‌متر پاییزه ($t_{47.5}$)، میانگین بارش درازمدت (p_{mean}).

مقادیر بارش سال قبل (p_{t-1})، دو سال قبل (p_{t-2}) و سه سال قبل (p_{t-3}) در پیش‌بینی بارندگی استان کرمان استفاده کردند. در مطالعه‌ای دیگر با به‌کارگیری ۱۲ متغیر سینوپتیکی، توانایی سیستم تطبیقی عصبی فازی^۱ (ANFIS) در پیش‌بینی بارش مورد سنجش قرار گرفت (فلاح‌قاهری و همکاران، ۱۳۸۷). در مدل شبکه عصبی توسعه داده شده توسط ماریا و همکاران (۲۰۰۵: ۱۴۹) از متغیرهای دمای پتانسیل، مؤلفه قائم باد، رطوبت ویژه، دمای هوا، آب قابل بارش، چرخندگی نسبی و شار واگرایی رطوبت جهت مدل‌سازی بارش استفاده شد. در مطالعه‌ای دیگر توسط کاوازوس (۲۰۰۰: ۲۴۷) کارایی مناسب شبکه عصبی مصنوعی در پیش‌بینی بارش روزانه با استفاده از متغیرهای ضخامت بین سطوح ۵۰۰ و ۱۰۰۰ هکتوپاسکال، ارتفاع سطح ۵۰۰ هکتوپاسکال و رطوبت سطح ۷۰۰ هکتو گزارش شد. در پژوهش خلیلی و همکاران (۱۳۸۷: ۳۶۹) از اشکال مختلف زمانی مقدار بارش مثل بارش‌های ۱، ۲، ۳، ۴، ۵، ۱۲ ماه قبل و میانگین بارش ماه مورد نظر در سال‌های قبل در ورودی شبکه عصبی استفاده شد. نتایج این پژوهش‌ها نشان‌دهنده استفاده از متغیرهای بیشتر و جدیدتر برای بهبود عملکرد شبکه و مدل‌سازی دقیق‌تر بود. در مقابل برخی پژوهشگران تفاوت قابل ملاحظه‌ای بین مقادیر اندازه‌گیری و برآوردی به‌واسطه‌ی افزایش متغیرهای ورودی مشاهده نمودند (قربانی دشتکی و همکاران، ۱۳۸۸: ۱۸۷). ضمن آن‌که افزایش ورودی‌ها علاوه بر زمان بر بودن و هزینه‌بر بودن اندازه‌گیری‌ها باعث بزرگ شدن اندازه شبکه، کندی آموزش و افزایش خطای شبکه می‌شود (کریمی گوغری و همکاران، ۱۳۸۷: ۱۲۸). به اعتقاد بسیاری از پژوهشگران از جمله البرزی (۱۳۸۳: ۷۴) سرعت شبکه عصبی در پاسخ‌گویی به تغییرات ایجاد شده از طریق نرون‌های ورودی ارجح‌تر از تعداد متغیرهای ورودی است.

با وجود افزایش خطا در صورت به‌کارگیری ورودی‌های زیاد و حجیم شدن شبکه، لازم است تا بهترین و در عین حال کمترین تعداد ورودی در شبکه عصبی به‌کار گرفته شود. بنابراین هدف از این پژوهش ابتدا بررسی و اثبات پیش‌بینی‌پذیری بارش با روش آماری

مقاوم و سپس برآورد بارش براساس الگویهای مختلفی از پارامترهای اقلیمی موثر غیربارشی با استفاده از شبکه های عصبی مصنوعی می باشد.

مواد و روش ها

این پژوهش با استفاده از داده های ایستگاه های هواشناسی شیراز، کرمان و مشهد انجام گردید. ایستگاه های مورد مطالعه در گروه ایستگاه های همدید سازمان هواشناسی کشور بوده که دارای داده هایی با طول دوره آماری ۵۰ ساله از سال ۱۹۵۰ تا ۲۰۰۰ میلادی می باشند. این تحقیق سعی دارد تا پس از اثبات پیش بینی پذیری بارش، مقادیر سری زمانی بارش را با برقراری ارتباط بین عوامل اقلیمی غیربارشی سال های قبل با مقادیر متناظر زمانی بارش، پیش بینی نماید. پیش بینی پذیری بارش، با توجه به طول دوره آماری و تعداد داده های در دسترس، از روش آماری مقاوم با محاسبه نمای هرست $(H \in [0,1])$ بررسی شد. هال و همکاران (۱۹۹۹) بر مبنای یک قانون تجربی $\frac{R}{S} = N^H$ نشان دادند هرگاه نمای هرست یک متغیر وابسته بزرگ تر از ۰/۵ باشد آن متغیر تصادفی و پیش بینی پذیر است (لیف، ۱۹۹۵). به گونه ای که R دامنه مجموع انحرافات از میانگین و S انحراف معیار سری زمانی متغیر وابسته بوده که از روابط زیر بدست می آید:

$$R = \text{Max} [X_{t,n}] - \text{Min} [X_{t,n}] \quad t = 1, 2, \dots, n \quad X_{t,n} = \sum_{s=1}^n (X_s - \bar{X}) \quad (1)$$

$$S = \left[\sum_{t=1}^n \frac{(X_t - \bar{X})^2}{n} \right]^{1/2} \quad (2)$$

در روابط فوق: X_t نمونه t ام سری زمانی، n تعداد نمونه ها، \bar{X} میانگین داده های مقاطع زمانی حال و گذشته، $(X_s - \bar{X})$ انحراف از میانگین و $X_{t,n}$ مجموع انحرافات از میانگین (انحراف انباشته) می باشند. با اثبات پیش بینی پذیری بارش، نسبت به مدل سازی بارش (رابطه ۳) از راه شبکه عصبی مصنوعی اقدام شد. رابطه ۳ حاصل به کارگیری مقادیری از متغیرهای

اقلیمی غیربارشی (θ) در زمان‌های قبل برای پیش‌بینی مقدار بارش (R) در مقطع زمانی آینده است.

$$R_{(t+1)} = f(\theta_t, \theta_{(t-1)}, \dots, \theta_{(t-n)} + E_{(t)}) \quad (3)$$

در رابطه فوق $f(\theta)$ یک تابع غیرخطی نامعین، $E_{(t)}$ مقدار مجهول مربوط به خطای فرآیند و n تعداد داده‌های مقاطع زمانی گذشته است.

شبکه عصبی مصنوعی انتخابی براساس پژوهش‌های فریرا و همکاران (۲۰۰۵) از نوع پرسپترون چندلایه^۱ (MLP) با توانمندی نگاشت‌های پیچیده غیرخطی و قانون یادگیری پس‌انتشارخطا^۲ (BP) بود. این نوع شبکه قادر به تشخیص رابطه بین لایه‌ی اطلاعات خروجی با لایه اطلاعات ورودی و مدل‌سازی آن است (زاع ایبانه و بیات ورکشی، ۱۳۹۰). روند محاسبات در فرآیند آموزش به صورت جریان یک‌طرفه از لایه ورودی به ورودی لایه بعد و در نهایت به خروجی شبکه است. آموزش شبکه، چگونگی تنظیم وزن‌های شبکه را بیان می‌کند. برای تعیین تعداد لایه‌های مخفی شبکه و تعداد نرون‌های هر لایه با فرض ۱ و ۲ لایه مخفی، تعداد نرون‌ها ۱، ۲، ۳، و ۳۰ نرون در نظر گرفته شد.

در این راستا ۵ ساختار شبکه عصبی براساس نیازهای اطلاعاتی متفاوت به فرم کلی $n-m-k-1$ و $n-m-1$ طراحی شد. عدد ۱ نشانه یک متغیر مجهول بارش در لایه خروجی و n نشانه نیاز اطلاعاتی یا تعداد نرون‌های اطلاعاتی در لایه ورودی شبکه عصبی است. حروف m تعداد نرون‌های ساختاری از شبکه عصبی مصنوعی با یک لایه پنهان و $m-k$ تعداد نرون‌های ساختاری از شبکه عصبی مصنوعی با دو لایه پنهان می‌باشد. لایه ورودی شامل ترکیب‌های متفاوتی از عوامل هواشناسی دمای کمینه هوا (T_{min})، دمای بیشینه هوا (T_{max})، میانگین دمای هوا (T_{mean})، رطوبت نسبی کمینه هوا (RH_{min})، رطوبت نسبی بیشینه هوا (RH_{max})، میانگین رطوبت نسبی (RH_{mean})، دمای نقطه شبنم (T_{dew}) و سرعت باد در ارتفاع دو متری (U_2) بود. با اجرای آزمون پیرسون، عوامل دارای ضریب همبستگی

1- Multi layer perspetron

2- Back propagation

حدود ۴۰ درصد و بالاتر برای اعمال در ورودی شبکه عصبی استفاده شد. در طراحی شبکه‌های عصبی از روش سلسله‌ای استفاده گردید. در این روش، شبکه‌ها به گونه‌ای ایجاد شدند که در شبکه اول (ANN_1) دو ویژگی رطوبت نسبی حداقل (RH_{min}) و رطوبت نسبی حداکثر (RH_{max}) به عنوان متغیرهای ورودی به کار گرفته شد. در شبکه دوم (ANN_2)، دمای حداکثر هوا (T_{max}) به ورودی‌های شبکه ANN_1 اضافه گردید. شبکه سوم (ANN_3) با اضافه نمودن دمای حداقل هوا (T_{min}) به ورودی‌های شبکه ANN_1 ایجاد شد. به همین ترتیب با افزودن دو پارامتر T_{min} و T_{max} به ورودی‌های شبکه ANN_1 ، شبکه جدیدی تحت عنوان ANN_4 پی‌ریزی گردید. در ایجاد شبکه ANN_5 از دو پارامتر میانگین رطوبت نسبی (RH_{mean}) و میانگین دمای هوا (T_{mean}) استفاده شد. عوامل سرعت باد دو متری و دمای نقطه شبنم به دلیل کسب ضعیف بودن ضریب همبستگی صرف نظر گردید.

در انجام این بررسی پس از مطالعات مختلف، بسته نرم‌افزاری (Ver.5) NeuroSolution با قابلیت اجرا در محیط ویندوز مورد توجه قرار گرفت (زارع ایبانه و همکاران، ۱۳۸۸). این نرم‌افزار دارای توانمندی نرمال‌سازی داده‌ها و مجهز به ابزار اعتبارسنجی متقابل^۱ است که قادر به خاتمه آموزش شبکه در صورت کم بودن تفاوت خطای لحظه‌ای بین دو مقدار برآوردی و اندازه‌گیری طبق رابطه ۴ است. در غیر این صورت نرم‌افزار به دلیل ورآموزی شبکه^۲، آموزش شبکه را پایان می‌دهد. به بیان ریاضی اگر $\hat{R}_i(n)$ خروجی عنصر نام سیستم در n امین تکرار و مقدار واقعی آن به صورت متناظر $R_i(n)$ باشد، خطای لحظه‌ای به صورت زیر می‌باشد.

$$e_i(i) = R_i(n) - \hat{R}_i(n) \quad (4)$$

تصحیح مرتب خطا منجر به اصلاح وزن‌های مدل و انتخاب بهترین آن‌ها به منظور صحیح‌ترین خروجی می‌شود. با تعمیم رابطه ۴ به مجموعه فرایند مدل‌سازی و به عنوان یک قاعده کلی در پایان کار، می‌بایست خطای کل شبکه طبق رابطه ۵ به کمترین مقدار خود برسد.

1- Cross validation

2- Over training

$$E(t) = \sum_{i=1}^n (e_i(n))^2 \quad (5)$$

برای آموزش شبکه لازم است تا پیش‌پردازش داده‌ها شامل انتخاب متغیرهای موثر، انتخاب الگوهای آموزش‌ده و آزمون و دسته‌بندی الگوها صورت گیرد. برای این منظور ۷۰ درصد داده‌ها هر ایستگاه برای آموزش و ۳۰ درصد باقی‌مانده به آزمون شبکه اختصاص یافت. در اغلب موارد داده‌ها با مقداری خطا جمع‌آوری می‌شوند که با وجود آموزش مدل، اعتبار آن می‌تواند مورد تردید واقع شود. لذا قسمتی از داده‌های جدا شده تحت عنوان داده‌های آزمون برای اطلاع از دقت مدل ایجاد شده استفاده می‌شوند. برای تعیین مقدار بهینه تعداد تکرار محاسباتی شبکه^۱ از روش سعی و خطا استفاده شد. در این پژوهش از قوانین گوناگون آموزشی مانند لونیبرگ مارکوات و مومنتم و توابع آستانه‌ای مختلفی نظیر سیگموئید و تانژانت برای بسط و واسنجی شبکه عصبی برای مدل‌سازی اطلاعات بارش لایه خروجی بهره‌گیری شد. با داده‌های بخش آزمون، اعتباریابی شبکه یا قابلیت تعمیم‌دهی شبکه‌های پی‌ریزی شده در برآورد بارش بررسی گردید. اعتبار شبکه‌های ایجاد شده در برآورد بارش با محاسبه آماره‌های میانگین درصد خطا^۲ (MPE) و ضریب همبستگی^۳ (r) و از روابط ۶ و ۷ تعیین گشت. آماره‌های فوق به ترتیب نشان‌دهنده میزان خطا و تناسب برازش مدل رگرسیون خطی به جفت داده‌های برآوردی و مشاهداتی هستند.

$$MPE = \sum_{i=1}^n \frac{|X_i - Y_i|}{Y_i} \times 100 \quad (6)$$

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \quad (7)$$

در این روابط، X_i و Y_i به ترتیب i امین داده بارش برآوردی و اندازه‌گیری، \bar{X} و \bar{Y} به ترتیب متوسط داده‌های X_i و Y_i ، و n تعداد نمونه‌های مورد ارزیابی می‌باشند.

-
- 1- Epoch
 - 2- Mean Percent Error
 - 3- Correlation of coefficient

نتایج و بحث

پیش‌بینی‌پذیری پارامتر بارش در ایستگاه‌های مورد مطالعه با استفاده از تحلیل R/S مورد ارزیابی قرار گرفت. نمای هرست (H) به کمک محاسبه شیب منحنی برای هر یک از ایستگاه‌ها انجام شد. نمای هرست در ایستگاه‌های شیراز معادل ۰/۹۲، کرمان ۰/۸۹ و در مشهد برابر ۰/۸۰ به دست آمد. مقادیر H محاسباتی با توجه به محدوده $0.5 \leq H \leq 1$ ، نمایان‌گر رفتار پایای سری زمانی است و در چنین شرایطی احتمال تکرار روند سیستم در یک دوره، در آینده هم وجود دارد (احمری‌نژاد و همکاران، ۱۳۸۴). به این معنی که اگر سری زمانی در یک دوره، روند افزایشی یا کاهشی داشته است این احتمال وجود دارد که این روند در آینده نیز حفظ شود. به عبارت دیگر مقادیر H محاسبه شده نشان می‌دهد قابلیت پیش‌بینی فرآیند مقدار بارش در هر سه ایستگاه مورد مطالعه وجود دارد. بالا بودن نمای هرست بیان‌گر بالا بودن اثر حافظه بلندمدت در سری زمانی است (کانوونیکو و همکاران، ۱۹۹۹).

دینامیک و ساختار سری زمانی بارش بیان‌کننده تغییر بارش نسبت به زمان و تاثیر عوامل هواشناسی در تغییرات بارش است. برای مدل‌سازی، بایستی پارامترهای مناسب، از بین اطلاعات هواشناسی غیربارشی انتخاب شوند. با انجام آزمون همبستگی پیرسون از مجموعه عوامل اقلیمی غیربارشی پارامترهای مناسب مدل‌سازی بارش تعیین گردید. نتایج کلی اجرای آزمون همبستگی پیرسون بین سری زمانی بارش و سری زمانی هر یک از عوامل هواشناسی به تفکیک ایستگاه‌های مورد مطالعه در جدول ۱ آورده شده است.

جدول (۱) همبستگی پیرسون بین بارندگی و سایر عوامل هواشناسی

متغیر هواشناسی	دما (درجه سلسیوس)			دمای نقطه شبنم (درجه سلسیوس)	رطوبت نسبی (درصد)			سرعت باد ارتفاع دومتری (متر بر ثانیه)
	حداقل	حداکثر	میانگین		حداقل	حداکثر	میانگین	
شیراز	-۰/۵۴	-۰/۶۶	۰/۴۴	-۰/۱۸	۰/۷۹	۰/۶۹	۰/۶۰	-۰/۱۹
کرمان	-۰/۳۹	-۰/۵۷	۰/۲۰	-۰/۰۱	۰/۶۹	۰/۶۶	۰/۵۲	۰/۰۴
مشهد	-۰/۴۲	-۰/۵۴	۰/۵۱	-۰/۱۹	۰/۶۱	۰/۶۸	۰/۵۳	-۰/۱۴
میانگین	-۰/۴۵	-۰/۶۰	۰/۳۸	-۰/۱۹	۰/۷۰	۰/۶۸	۰/۵۵	۰/۱۲

نتایج بررسی آزمون پیرسون برای عوامل اقلیمی مختلف در جدول ۱، نشان می‌دهد که در هر سه ایستگاه دمای نقطه شبنم و سرعت باد کمترین همبستگی را در مقایسه با عوامل دمایی و رطوبتی دارند. در تایید نتایج این جدول فلاح قالمیری و همکاران (۱۳۸۷) نیز نقش عوامل دمایی و رطوبتی را بر بارش‌های رخ داده در منطقه خراسان گزارش نمودند. از طرف دیگر بدون توجه به جهت تأثیرگذاری عوامل هواشناسی بر بارش و از بین عوامل دارای ضریب همبستگی بالا، رطوبت نسبی حداقل در ایستگاه شیراز دارای بیشترین ضریب همبستگی معادل ۰/۷۹ است. به همین ترتیب میانگین دمای هوای ایستگاه کرمان دارای کمترین ضریب همبستگی برابر ۲۰ درصدی با بارش است. در مجموع جدول ۱ نشان می‌دهد که عوامل دمایی و رطوبتی به‌طور میانگین ۵۶ درصد از تغییرات بارش مناطق مورد مطالعه را توجیه می‌نمایند. بدین ترتیب از عوامل فوق به‌عنوان نرون‌های اطلاعاتی در لایه ورودی شبکه عصبی در قالب ۵ ساختار مختلف استفاده شد. در جدول ۲ نتایج مناسب‌ترین ساختار شبکه عصبی مصنوعی برای هر یک از نیازهای اطلاعاتی لایه ورودی و براساس دو آماره r و MPE در سه ایستگاه مورد مطالعه آورده شده است.

جدول (۲) نتایج ساختارهای بهینه شبکه عصبی مصنوعی در پیش‌بینی بارش سالانه

ایستگاه	ساختار شبکه	نیاز اطلاعاتی	قانون آموزش	تابع محرک	آرایش	شاخص‌های ارزیابی	
						r	MPE (%)
مشهد	ANN_1	RH_{max}, RH_{min}	لونیبرگ مارکوات	سیگموئید	۲-۲۰-۲۰-۱	۰/۷۷	۲۸
	ANN_2	$RH_{max}, RH_{min}, T_{max}$	لونیبرگ مارکوات	تانژانت	۳-۱۸-۱۸-۱	۰/۹۳	۱۵
	ANN_3	$RH_{max}, RH_{min}, T_{min}$	لونیبرگ مارکوات	تانژانت	۳-۲۱-۲۱-۱	۰/۹۳۳	۱۱
	ANN_4	$RH_{max}, RH_{min}, T_{max}, T_{min}$	مومنتم	تانژانت	۴-۲۰-۲۰-۱	۰/۹۰۸	۱۴
	ANN_5	RH_{mean}, T_{mean}	لونیبرگ مارکوات	تانژانت	۲-۲۳-۲۳-۱	۰/۹۱۱	۱۴
مشهد	ANN_1	RH_{max}, RH_{min}	لونیبرگ	تانژانت	۲-۲۰-۲۰-۱	۰/۸۲	۱۸

				مارکوات		
۱۹	۰/۸۷	۳-۲۰-۲۰-۱	تانزان	مومنتم	$RH_{max}, RH_{min}, T_{max}$	ANN ₂
۱۴	۰/۹۱	۳-۲۵-۲۵-۱	تانزان	لونبرگ مارکوات	$RH_{max}, RH_{min}, T_{min}$	ANN ₃
۱۸	۰/۸۸	۴-۲۰-۲۰-۱	تانزان	مومنتم	$RH_{max}, RH_{min}, T_{max}, T_{min}$	ANN ₄
۱۹	۰/۸۴	۲-۲۰-۲۰-۱	تانزان	لونبرگ مارکوات	RH_{mean}, T_{mean}	ANN ₅
۶	۰/۹۱	۲-۱۵-۱۵-۱	تانزان	لونبرگ مارکوات	RH_{max}, RH_{min}	ANN ₁
۱۳	۰/۸۴	۳-۲۴-۲۴-۱	تانزان	مومنتم	$RH_{max}, RH_{min}, T_{max}$	ANN ₂
۹	۰/۸۳	۳-۱۵-۱۵-۱	تانزان	لونبرگ مارکوات	$RH_{max}, RH_{min}, T_{min}$	ANN ₃
۴	۰/۹۴	۴-۱۹-۱۹-۱	تانزان	لونبرگ مارکوات	$RH_{max}, RH_{min}, T_{max}, T_{min}$	ANN ₄
۸	۰/۸۶	۲-۱۶-۱۶-۱	تانزان	لونبرگ مارکوات	RH_{mean}, T_{mean}	ANN ₅

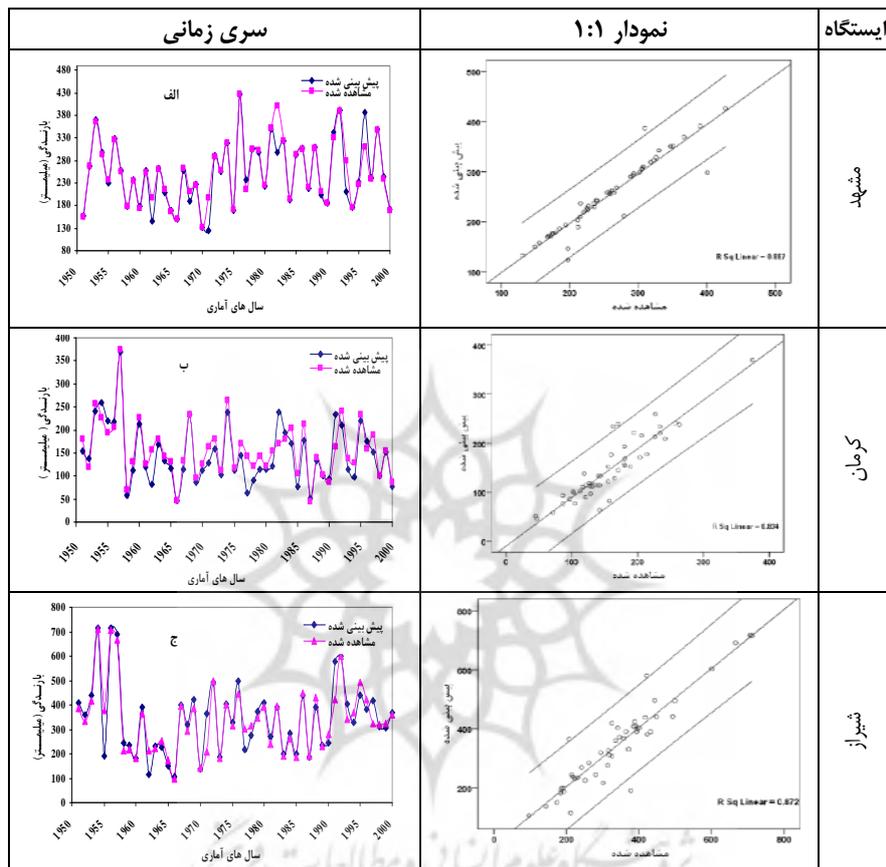
جدول ۲ حاصل آزمون شبکه با نرون‌های متفاوت در آرایش‌های یک و دو لایه پنهان با ۵ نوع نیاز اطلاعاتی در لایه اول است. این جدول نشان می‌دهد در همه ایستگاه‌ها آرایش دو لایه پنهان (n-m-k-1) نسبت به آرایش‌های دارای یک لایه پنهان (n-m-1) از جواب‌های بهتری برخوردار بود. به عبارت دیگر شبکه عصبی دارای دو لایه پنهان، به استناد مقادیر شاخص‌های ارزیابی r و MPE، در کشف روابط غیرخطی پارامتر بارش از عوامل غیربارشی هواشناسی موفق بوده است. همانگونه که از جدول ۲ مشاهده می‌شود، شبکه عصبی طراحی شده بر پایه ۴ ورودی (ANN₄) در ایستگاه مشهد کمترین خطا (MPE=۴٪) و بیشترین ضریب همبستگی ($r=۰/۹۴$) را دارد. در مقابل ساختار ANN₃ مشتمل بر ۳ پارامتر ورودی رطوبت نسبی حداقل، حداکثر و دمای حداقل، در دو منطقه شیراز و کرمان کمترین خطا و بیشترین همبستگی را در مقایسه با دیگر ساختارها دارد. مقایسه میزان خطای شبکه در برآورد بارش دو ایستگاه شیراز و کرمان نشان می‌دهد، شبکه طراحی شده به ترتیب در پیش‌بینی ۸۹ و ۸۶ درصد (MPE=۱۱٪ و MPE=۱۴٪) از بارش

دو منطقه موفق بوده است. مقادیر ضریب همبستگی موجود در جدول ۲ نیز موید توانایی شبکه‌های طراحی شده در برآورد بارش هر دو منطقه می‌باشد. به عبارت دیگر مقدار ضریب همبستگی دو منطقه بین ۰/۹۱ در ایستگاه کرمان تا ۰/۹۳ در ایستگاه شیراز است. فلاح قاله‌ری و خوشحال (۱۳۸۸) با انتخاب اطلاعات جو بالا در ورودی شبکه عصبی و اطلاعات بارش‌های بهار ۳۸ سال استان خراسان رضوی موفق به پیش‌بینی بارش با ضریب همبستگی ۰/۷۹ شدند. در مطالعه‌ای دیگر خلیلی و همکاران (۱۳۸۷) با در نظر گرفتن ۵ متغیر ورودی موفق به پیش‌بینی بارش در ایستگاه مشهد با ضریب همبستگی ۰/۹۲ و فلاح قاله‌ری و همکاران (۱۳۸۷) با استفاده از ۱۲ پارامتر سینوپتیکی بارش را با همبستگی ۰/۷۴ و خطای ۳۰ درصد، پیش‌بینی نمودند. در حالی که نتایج این مطالعه در محدوده سه استان با موقعیت‌های متفاوت جغرافیایی و برای تمام فصول سال با ضریب همبستگی بین ۰/۹۱ تا ۰/۹۴ و با اطلاعات ایستگاهی ساده‌تر قابل کاربرد است. مقایسه نتایج مطالعه حاضر با مطالعه فلاح قاله‌ری و خوشحال (۱۳۸۸) نقش نوع شبکه طراحی شده، نوع اطلاعات ورودی (اطلاعات زمینی) و طول دوره آماری را در دقت نتایج مطالعه حاضر به خوبی نشان می‌دهد. همچنین جدول ۲ نشان می‌دهد انتخاب داده‌های مناسب حتی در تعداد کم براساس سه نرون اطلاعاتی (ANN3) در ایستگاه‌های شیراز و کرمان، نسبت به اضافه نمودن تعدادی اطلاعات در ساختار ANN4 عملکرد بهتری داشته است. این موضوع در راستای نتایج زارع ایبانه و همکاران (۱۳۹۰) است که استفاده از داده‌های مناسب با تعداد کم را پیشنهاد نموده‌اند، در حالی که خلیلی و همکاران (۱۳۸۷) و فلاح قاله‌ری و همکاران (۱۳۸۷) استفاده از داده‌های بیشتر را سبب عملکرد بهتر شبکه عصبی دانسته‌اند. توجه به این نکته ضروری است که افزایش تعداد ورودی‌ها مستلزم تعداد داده بیشتر برای آموزش شبکه است که از نظر اقتصادی مقرون به صرفه نمی‌باشد. ضمن آن که افزایش تعداد ورودی، در شبکه منجر به مشکل نفرین ابعادی^۱ می‌شود که مانع طراحی و پی‌ریزی مناسب شبکه می‌شود. به طور کلی می‌توان گفت وقتی استفاده از ورودی‌های بیشتر منجر به پیشرفتی نسبت به ورودی‌های کمتر نمی‌شود، پس شبکه و پیش‌بینی‌های ناشی از آن، وابستگی

1- Curse of dimensionality

شدیدی به ورودی‌های جدید ندارد و شبکه نیازمند داده‌هایی با ماهیت متفاوت ندارد (محمدیان روشن و همکاران، ۱۳۸۷). از سویی صوفی‌وند و همکاران (۱۳۸۴) در گزارش خود روش شبکه عصبی را در گروه روش‌های تطبیقی فاقد حافظه بلندمدت دانسته و دقت آن را محدود به مدل‌سازی در فواصل زمانی کوتاه مدت گزارش کرده است. در حالی که معیارهای خطا در جدول ۲ نشان می‌دهد که شبکه عصبی طرح‌ریزی شده در این مطالعه برخلاف نتایج صوفی‌وند و همکاران (۱۳۸۴) در دنبال نمودن تغییرات ۵۰ ساله بارش‌های هر سه ایستگاه و ذخیره‌سازی تغییرات در حافظه خود موفق بوده است. علت این امر می‌تواند در ماهیت متغیر(های) مدل‌سازی، دقت اندازه‌گیری‌ها، انتخاب متغیرهای مناسب و مناسب بودن شبکه طرح‌ریزی شده باشد. از آنجاکه شبکه عصبی به خطای اطلاعات ورودی حساسیت کمتری دارد، بنابراین با آموزش صحیح شبکه عصبی و با توجه به مشخص شدن ساختار بهینه آن، برای سال‌های آتی نیز می‌توان با وارد نمودن داده‌های دمایی و رطوبتی، مقدار بارش را برآورد نمود (زارع ایبانه و بیات ورکشی، ۱۳۹۰). طبیعتاً با گذشت زمان و افزایش اطلاعات در دسترس، دقت آن نیز افزایش می‌یابد.

با استفاده از اطلاعات تعریف شده در بردار ورودی شبکه عصبی و در نظر گرفتن ساختارهای بهینه شبکه عصبی برای هر ایستگاه، مقدار بارش برآورد گردید. همچنین بارش برآوردی و اندازه‌گیری به‌عنوان تابعی از سال‌های مشاهداتی نیز برای هر ایستگاه ترسیم و نتایج با یکدیگر مقایسه شد. در شکل ۱ منحنی پیش‌بینی و واقعی سری زمانی مقادیر بارش هر سه ایستگاه مشهد، کرمان و شیراز در سمت راست آورده شده است. در سمت چپ شکل ۱ نیز مقادیر برآورد شده از شبکه‌های دارای عملکرد مناسب در مقابل مقادیر مشاهداتی بارش به‌صورت ترسیمی در قالب نمودار ۱:۱ نشان داده شده است.



شکل (۱) نتیجه پیش‌بینی بارندگی توسط شبکه عصبی مصنوعی با حدود اطمینان ۹۹ درصد

همانگونه که شکل ۱ نشان می‌دهد تطابق خوبی بین مقادیر بارش پیش‌بینی شده و مشاهده شده برقرار است. به عبارت دیگر این شکل بیان‌گر رفتار مناسبی از مدل‌سازی بارش توسط شبکه عصبی است. از نکات قابل توجه در شکل ۱ (سمت چپ) برآوردهای خوب شبکه عصبی در سال‌های حدی است. برآوردهای خوب شبکه عصبی در سال‌های حدی می‌تواند ناشی از آموزش خوب شبکه عصبی به واسطه تکرار این سال‌ها در مرحله آموزش باشد (فلاح قاهره و همکاران، ۱۳۸۷: ۱۳۲). در مطالعه صورت گرفته توسط فلاح قاهره

و همکاران (۱۳۸۷: ۱۳۲) عدم تکرار تصادفی سال‌های حدی در پیش‌بینی بارش منجر به تغییر تاکتیک در انتخاب تعدادی از داده‌های سال‌های حدی و وارد نمودن در مجموعه داده‌های آموزش به جهت بهبود نتایج شد. لیکن در مطالعه حاضر به دلیل برآوردهای مناسب نیاز به چنین عملیاتی نبود و این خود تأییدی بر آموزش خوب شبکه است.

در سمت راست شکل ۱ پراکنش نقاط نسبت به خط ۱:۱ در حد ۹۹ درصد اطمینان نشان داده شده است. پراکنش تقریباً مساوی نقاط در دو طرف خط ۱:۱ بر یکنواختی و همگنی برآوردها دلالت دارد. زیرا تجمع بیش از اندازه نقاط در ناحیه فوقانی و زیرین خط ۱:۱ به ترتیب نشانه بیش برآورد و کم برآورد مدل است. بدین ترتیب می‌توان گفت هیچ کدام از شبکه‌های پیشنهادی به‌طور سیستماتیک، مشکل بیش یا کم برآورد نداشته‌اند. مطابق نمودار ۱:۱ ضریب همبستگی هر سه ایستگاه بالا است. لیکن ضریب همبستگی ایستگاه مشهد ($R^2=0/887$) بیش از دو ایستگاه دیگر است. مطابق این شکل شبکه عصبی پی‌ریزی شده در ایستگاه مشهد پیش‌بینی‌های دقیق‌تری را داشته است. زیرا نقاط به خط ۱:۱ نزدیک‌تر هستند و از نظر ظاهری نیز خط ۱:۱ در این ایستگاه در مقایسه با دو ایستگاه دیگر به نیمساز ۴۵ درجه نزدیک‌تر است. این نتیجه با نتایج جدول ۲ هم‌خوانی دارد که میزان خطای مدل‌سازی بارش ایستگاه مشهد ۴ درصد بود و از کمترین درصد خطا در مقایسه با سایر ایستگاه‌ها برخوردار بود. ضریب همبستگی دو ایستگاه شیراز ($R^2=0/872$) و کرمان ($R^2=0/834$) نیز در حد قابل قبول می‌باشد که موید قابلیت شبکه عصبی طراحی شده در پیش‌بینی بارش هر سه منطقه است. همانگونه که از شکل ۱ مشاهده می‌شود، شبکه عصبی به خوبی توانسته است ساختار تغییرات زمانی را شناسایی کند. بنابراین کم بودن آماره‌های خطا در یک ایستگاه نسبت به ایستگاه دیگر، می‌تواند نتیجه تغییرات ساختاری کمتر بارش و شناسایی آن‌ها توسط روش مدل‌سازی و نوع ساختار طراحی شده باشد. به طوری که در این مطالعه مقایسه نتایج ایستگاه مشهد در شکل ۱، کمتر بودن تغییرات بارش را نسبت به سایر ایستگاه‌ها تأیید می‌کنند.

کارایی ساختار شبکه عصبی مصنوعی طراحی شده در این مطالعه در مقایسه با مطالعات دیگر از جهت استفاده از کمترین اطلاعات غیربارشی (دمایی و رطوبتی) در برآورد بارش،

اهمیت دارد. همانگونه که قبلاً نیز اشاره شد در بیشتر مطالعات انجام گرفته از اطلاعات بارش در شکل‌های مختلف آن یا تعداد متغیرهای زیاد به‌عنوان ورودی شبکه‌های عصبی استفاده شده است (فلاح قاله‌ری و همکاران، ۱۳۸۷؛ خلیلی و همکاران، ۱۳۸۷؛ کریمی گوغری و اسلامی، ۱۳۸۷؛ ماریا و همکاران، ۲۰۰۵ و کاوازوس، ۲۰۰۰). این در حالی است که در مطالعه حاضر از کمترین اطلاعات برای پیش‌بینی بارش با بیشترین دقت استفاده شده است.

در مجموع می‌توان اظهار داشت، مدل شبکه عصبی با فراگیری رفتار غیرخطی اطلاعات آموزشی و انجام عملیاتی موازی در تعداد زیادی از سلول‌های عصبی قادر به پردازش اطلاعات آزمون و برقراری ارتباط بین اطلاعات ورودی و خروجی برای پیش‌بینی است.

نتیجه‌گیری

پیش‌بینی بارش سالانه می‌تواند موفقیت در کشت دیم، طراحی پروژه‌های مهندسی منابع آب، برنامه‌ریزی‌های اقتصادی منطقه‌ای و مدیریت بهتر مراتع را تضمین نماید. این تحقیق با هدف ساده‌سازی پیش‌بینی و استفاده از حداقل متغیر ورودی در شبکه عصبی مصنوعی انجام گرفت. زیرا شبکه‌های عصبی مصنوعی به‌دلیل انعطاف‌پذیری، قادر به مدل‌سازی فرآیندهای غیرخطی هستند. بنابراین با منظور نمودن اطلاعات هواشناسی غیربارشی، ساختار مناسب شبکه عصبی مصنوعی در پیش‌بینی بارش سالانه ارائه شد. با انجام آزمون پیرسون مهم‌ترین پارامترهای هواشناسی تأثیرگذار بر بارش منطقه، پارامترهایی از جنس دما و رطوبت بود. به‌طوری‌که عوامل دمایی و رطوبتی به‌طور میانگین ۵۶ درصد از تغییرات بارش مناطق مورد مطالعه را توجیه می‌نمایند. با منظور نمودن اطلاعات فوق به‌عنوان ورودی شبکه عصبی مصنوعی در غالب ۵ شبکه با ورودی‌های متفاوت، بارش سالانه با دقت مناسب پیش‌بینی شد که نسبت به مطالعات انجام گرفته به‌دلیل تعداد متغیر ورودی کمتر و غیرهم‌جنس بودن اطلاعات ورودی و خروجی از شبکه عصبی قابل توجه بود.

نتایج اجرای شبکه عصبی در سه منطقه نشان داد شبکه عصبی طراحی شده بر پایه ۴ پارامتر ورودی دمای حداقل و حداکثر و رطوبت نسبی حداقل و حداکثر در ایستگاه مشهد

کمترین خطا ($MPE=4\%$) و بیشترین ضریب همبستگی ($r=0/94$) را دارد. در مقابل ساختار عصبی مشتمل بر ۳ پارامتر ورودی رطوبت نسبی حداقل، حداکثر و دمای حداقل، در دو منطقه شیراز و کرمان کمترین خطا (به ترتیب $MPE=11\%$ و $MPE=14\%$) و بیشترین همبستگی (به ترتیب $r=0/93$ و $r=0/91$) را در مقایسه با دیگر ساختارها دارند. در مجموع نتایج نشان داد برآورد بارش توسط شبکه عصبی مصنوعی در هر سه منطقه در محدوده ۹۹ درصد، قابل اطمینان هستند.



منابع

- ۱- احمدی نژاد، ا.؛ رجبی مشهدی، ح. و ساده، ج. (۱۳۸۴). «بررسی اهمیت پیش‌بینی میزان تقاضا در پیش‌بینی قیمت برق با تفکیک قیمت برق به مولفه‌های مختلف در فضای رقابتی انرژی الکتریکی»، *بیستمین کنفرانس بین‌المللی برق*، تهران. ص. ۱-۱۰.
- ۲- البرزی، م. (۱۳۸۳). «آشنایی با شبکه‌های عصبی»، تهران: موسسه انتشارات علمی دانشگاه صنعتی شریف، چاپ دوم.
- ۳- جهانگیر، ع.ر.؛ رائینی، م. و ضیا احمدی، م.خ. (۱۳۸۷). «شبیه‌سازی فرآیند بارش-رواناب با شبکه عصبی مصنوعی (ANN) با مدل HEC-HMS در حوضه معرف کارده»، *مجله علمی پژوهشی آب و خاک (علوم و صنایع کشاورزی)*. جلد ۲۲، شماره ۲: ۸۴-۷۲.
- ۴- خالوزاده، ح. و خاکی صدیق، ع. (۱۳۷۷). «ارزیابی روش‌های پیش‌بینی‌پذیری قیمت سهام و تعیین میزان قابلیت پیش‌بینی در بازار بورس تهران».
- ۵- خالوزاده، ح.؛ خاکی صدیق، ع. و لوکس، ک. (۱۳۷۷). «پیش‌بینی قیمت سهام در بازار بورس تهران با استفاده از مدل‌های خطی و غیر خطی»، *مجله علمی-پژوهشی مدرّس*، دانشگاه تربیت مدرّس. (۵۴): ۸۷-۱۰۲.
- ۶- خلیلی ن.؛ خدشناس س.ر.؛ داوری ک. و موسوی بایگی م. (۱۳۸۷). «پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی»، مطالعه موردی: ایستگاه سینوپتیک مشهد، *مجله علوم و صنایع کشاورزی (ویژه آب و خاک)*، ۲۲ (۱): ۸۹-۹۹.
- ۷- زارع ایبانه، ح. و بیات ورکشی، م. (۱۳۹۰). «ارزیابی مدل‌های هوشمند عصبی و تجربی در تخمین رواناب سالانه»، *نشریه آب و خاک (علوم و صنایع کشاورزی)*، ۲۵ (۲): ۳۶۵-۳۷۹.
- ۸- زارع ایبانه، ح.؛ قاسمی، ع.؛ بیات ورکشی، م. و معروفی، ص. (۱۳۸۸). «ارزیابی دقت شبکه عصبی مصنوعی (ANN) در پیش‌بینی تبخیر-تعرق گیاه سیر (ETc) در مقایسه با نتایج لایسیمتری در منطقه همدان»، *آب و خاک (علوم و صنایع کشاورزی)*، ۲۳ (۳): ۱۷۶-۱۸۵.

- ۹- زارع ابیانه، ح.؛ قاسمی، ع.؛ بیات ورکشی، م.؛ سبزی پرور، ع.ا. و محمدی، ک. (۱۳۸۹)، «ارزیابی کارایی دو نرم افزار شبکه عصبی مصنوعی در پیش بینی تبخیر- تعرق گیاه مرجع»، *دانش آب و خاک*، جلد ۱۹/۱ شماره ۲: ۱۱-۱۶۳.
- ۱۰- صوفی وند، ف.؛ فاتحی، ع.ر. و رمانیان، م. (۱۳۸۴)، «پیش بینی داده های هواشناسی به روش مدل سازی چندگانه»، *مجموعه مقالات سیزدهمین کنفرانس برق ایران*، جلد سوم، دانشگاه زنجان. ۱-۶.
- ۱۱- قاسمی، م.م. و سپاسخواه، ع.ر. (۱۳۸۳)، «پیش بینی بارندگی سالانه استان خوزستان از روی زمان وقوع رگبارهای پاییزه، علوم و فنون کشاورزی و منابع طبیعی»، سال هشتم، شماره اول: ۱-۹.
- ۱۲- قربانی دشتکی، ش.؛ همایی، م. و مهدیان، م.ح. (۱۳۸۸)، «برآورد پارامترهای نفوذ آب به خاک با استفاده از شبکه های عصبی مصنوعی»، *مجله آب و خاک (علوم و صنایع کشاورزی)*، جلد ۲۳، شماره ۱، ص. ۱۹۸-۱۸۵.
- ۱۳- فلاح قاله‌ری، غ.ح.؛ موسوی بایگی، م. و حبیبی نوخندان، م. (۱۳۸۷)، «پیش بینی بارش فصلی بر اساس الگوهای سینوپتیکی با استفاده از سیستم استنباط فازی عصبی تطبیق (ANFIS)»، *پژوهش های جغرافیای طبیعی*، شماره ۶۶: ۱۲۱-۱۳۹.
- ۱۴- فاتحی مرج، ا. و مهدیان، م.ح. (۱۳۸۸)، «پیش بینی بارش پاییزه با استفاده از شاخص های انسو به روش شبکه عصبی در حوضه دریاچه ارومیه»، *پژوهش های آبخیزداری (پژوهش و سازندگی)*، ۸۴: ۴۲-۵۲.
- ۱۵- فولادمند، ح.ر. (۱۳۸۵)، «پیش بینی بارندگی روزانه و سالانه و تعداد روزهای بارانی در سال با استفاده از زنجیره مارکوف در یک منطقه نیمه خشک»، سال دوازدهم شماره ۱: ۱۱۳-۱۲۳.
- ۱۶- کریمی گوگری ش. و اسلامی ا. (۱۳۸۷)، «پیش بینی بارندگی سالانه در استان کرمان با استفاده از شبکه های عصبی مصنوعی»، *مجله آبیاری و زهکشی ایران*، ۲ (۲): ۱۲۳-۱۳۲.
- ۱۷- محمدیان روشن، ی.؛ رئوف شبانی، ه. و کریم پور، ع. (۱۳۸۷)، «طراحی الگوریتم کاربردی پیش بینی بار به کمک شبکه های عصبی با هدف کاهش جریمه پرداختی خریداران بازار برق با استفاده از الگوریتم ژنتیک»، *بیست و سومین کنفرانس بین المللی برق*، صص. ۱-۶.

- 18- ASCE, (2000), "Task Committee on Plication of Artificial Neural Networks in Hydrology", *Artificial Neural Network in Hydrology*, Part I and II, J hydraulic Eng. 5(2): 115-137.
- 19- Cavazos, T. (2000). "Using Self-organizing Xaps to Investigate Extreme Climate Event: an Application to Wintertime Precipitation in the Balkans", *Journal of Climate*, 13: 1718-1732
- 20- Ferreira, N.J., Velho, H.F. and Ramizer, M.C.V. (2005), "Artificial Neural Network Technique for Rainfall Forecasting Applied to the Sao Paulo Region", J. *Hydrology*, 301: 146-162.
- 21- Hall, T., Brooks, H.E. and Doswell, C.A. (1999) "Precipitation Forecasting Use a Neural Network", *Weather and Forecasting Journal*, 14: 338-345.
- 22- Kanounikov, I.E., Antonova, E.V., Kiselev, B.V. and Belov, D.R. (1999), "Dependence of one of the Fractal Characteristics (Hurs exponent) of the Human Electroencephalogram on the cortical Area and Type of Activity", *International Joint Conference on Neural Networks*, Vol. 1. 243 - 246.
- 23- Leeph, T. (1995) "Analysis of Predictability of Topix Returns Using Neural Networks", *Neural Networks World*, 4: 485-501.
- 24- Maria, C. Haroldo, F and Ferreira, N., (2005), "Artificial Neural Network Technique for Rainfall Forecasting Applied to the S.o Paulo Tegion", *Journal of Hydrology*, Volume 301, Issues 1-4, PP.146-162.