

پیش‌بینی کوتاه مدت بارندگی: روشی برای بهبود هشدار سیل‌های ناگهانی (مطالعه موردی - حوضه سد گلستان ۱ در استان گلستان)

*محمدابراهیم یخکشی^۱، بهرام ثقفیان^۲، حسین صدقی^۳، هدایت فهمی^۴ و حبیب موسوی جهرمی^۵

^۱ دانشجوی دکتری گروه آبیاری، دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران، استاد گروه عمران، دانشگاه آزاد اسلامی واحد علوم و تحقیقات

تهران، ^۲استاد گروه آبیاری، دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران، ^۳استادیار پژوهشی وزارت نیرو،

^۴دانشیار گروه مهندسی آب دانشگاه شهید چمران اهواز

تاریخ دریافت: ۸۷/۲/۲۸؛ تاریخ پذیرش: ۸۷/۶/۲

چکیده

برای افزایش کارایی سیستم‌های هشدار سیل در حوضه‌های کوهستانی کوچک و متوسط که زمان پاسخ حوضه کوتاه بوده و سیل‌های ناگهانی اتفاق می‌افتد پیش‌بینی کمی بارش کوتاه مدت ضروری است. پیش‌بینی کمی و کوتاه‌مدت بارش، زمان پیش‌هشدار را در یک سیستم هشدار سیل افزایش می‌دهد و آن را قابل اعتماد می‌سازد. پیش‌بینی دقیق بارش یکی از مشکل‌ترین موضوعات در هواشناسی است. در این مقاله یک مدل شبکه عصبی برای پیش‌بینی بارش کوتاه مدت ۱۵ ایستگاه باران‌سنجی حوضه سد گلستان یک در حوضه گرگان‌رود واقع در استان گلستان ارائه می‌شود. داده‌های ساعتی بارش و نیز سایر پدیده‌های هواشناسی با یک شبکه عصبی پرسپترون چند لایه پیشرو^۱ با الگوریتم آموزش پس انتشار^۲ خطا برای پیش‌بینی یک‌ساعته بارش آموزش داده شد و برای پیش‌بینی نقطه‌ای تا ۲ ساعت برای هر ایستگاه آزمون گردید. نتایج مدل عصبی با روش مرسوم پیش‌بینی از نوع پایا^۳ مقایسه گردید. نتایج نشان می‌دهد که دقت پیش‌بینی مدل شبکه عصبی در مقایسه با روش پایا بهتر است. استفاده از پارامترهای رطوبت و دما نیز پیش‌بینی را بهبود می‌دهد. مدل قادر است پیش‌بینی بارش را در طول رگبار به هنگام نماید و برای حوضه‌های با زمان تمرکز ۳ ساعت و بیشتر کارایی دارد. خروجی مدل پیش‌بینی بارش می‌تواند با یک مدل بارش-رواناب در زمان واقعی پیوند زده شود و با دقت قابل قبولی زمان پیش‌هشدار سیل را به میزان ۲ ساعت بهبود ببخشد.

واژه‌های کلیدی: پیش‌بینی بارش، هشدار سیل، شبکه‌های عصبی، زمان پیش‌هشدار، حوضه سد گلستان

*- مسئول مکاتبه: yakhkeshie@yahoo.com

1- Feed Forward Multi Layer Perceptron, MLP
2- Back Propagation
3- Persistent

مقدمه

در سال‌های اخیر، سیلاب‌ها خسارات زیادی را به زندگی بشر وارد ساخته است. خطر سیلاب‌های ناگهانی در حوضه‌های کوچک و کوهستانی به دلیل سرعت زیاد رواناب و جریان سیل به مراتب بیشتر است. کنترل کلیه سیلاب‌ها با روش سازه‌ای، اقتصادی نیست در نتیجه روش‌های غیرسازه‌ای از جمله هشدار سیل در مدیریت سیل‌های ناگهانی توسعه پیدا کرده است مهم‌ترین جزء یک سیستم هشدار سیل در واقع بخش پیش‌بینی سیلاب است (لوک و همکاران، ۲۰۰۰). در ارتباط با پیش‌بینی سیلاب و توسعه مدل‌های بارش- رواناب در زمان واقعی تحقیقات زیادی انجام شده است (کمپ و ساونچ، ۲۰۰۷؛ برات و همکاران، ۲۰۰۲). زمان پیش‌هشدار^۱ در این سیستم هشدار سیل محدود بوده و حداکثر معادل زمان تمرکز حوضه می‌باشد. به همین دلیل کارایی آنها به ویژه در حوضه‌های کوچک با سیل‌های ناگهانی کم می‌باشد. با پیش‌بینی بارش کمی^۲ (QPF) زمان پیش‌هشدار افزایش پیدا کرده و فرصت بیشتری برای مدیریت سیلاب و عملیات مقابله‌ای در زمان سیل فراهم می‌شود. در نتیجه کارایی و اعتمادپذیری سیستم هشدار بیشتر می‌شود.

برخلاف پیشرفت‌های اخیر هواشناسی در ایران تاکنون اقدام موثری برای پیش‌بینی کمی بارش کوتاه‌مدت و ساعتی صورت نگرفته است غالب پیش‌بینی‌های انجام شده هواشناسی، کیفی و احتمالی و به صورت منطقه‌ای در مقیاس چند حوضه آبریز بوده است. سازمان هواشناسی ایران اخیراً مدل عددی MM5 را در پیش‌بینی بارش ۱۲ ساعته در منطقه جنوب غرب به کار گرفته است، لیکن هنوز کاربرد نتایج مدل در سطح حوضه‌های آبریز کوچک و متوسط و در مقیاس محلی برای مقاصد عملیاتی روشن نیست. در حوضه سد گلستان نیز طی سال‌های ۸۰ تا ۸۴ سیل‌های ناگهانی و مخرب وقوع یافته و خسارات زیادی را از نظر مالی و جانی به جای گذاشته است. به همین دلیل هشدار سیل این حوضه در دستور کار وزارت نیرو قرار گرفته است و هم‌زمان با تدوین مقاله، سیستم هشدار سیل

مبتنی بر زمان واقعی در این حوضه در حال تهیه است که به دلیل پیش‌بینی نکردن کمی بارش کارایی آن کم خواهد بود و لذا انجام پیش‌بینی کمی بارش در افزایش پیش‌هشدار سیل در این حوضه و بهبود پیش‌بینی و هشدار سیل بسیار موثر می‌باشد.

بارش یکی از پیچیده‌ترین عناصر سیکل هیدرولوژیکی همراه با تغییرات زیاد در زمان و مکان است (فرنچ و همکاران، ۱۹۹۲). پیش‌بینی بارش کار ساده‌ای نیست و عدم قطعیت‌های زیادی در آن وجود دارد (تات و همکاران، ۲۰۰۱، کولیالی و اوورا، ۲۰۰۴). بلوک (۱۹۸۰) روش‌های مختلف پیش‌بینی بارش کمی را بررسی کردند. انتخاب هر یک از روش‌های پیش‌بینی به مقیاس موردنظر و نیز امکانات موجود بستگی دارد. استفاده از مدل‌های پیش‌بینی عددی هواشناسی گرچه برای مقیاس بزرگ بسیار مفیدند، لکن برای پیش‌بینی و هشدار سیل‌های ناگهانی در مقیاس حوضه‌های کوچک از دقت کافی برخوردار نیستند (فرنچ و همکاران، ۱۹۹۲). استفاده از داده‌های سنجش از دور شامل رادار هواشناسی و تصاویر ماهواره‌ای در پیش‌بینی‌های کوتاه‌مدت در حد ساعت و دقیقه از نوع نوکستینگ^۳ و تعیین الگوی بارش خیلی مفید هستند لکن شدت بارش را به خوبی برآورد نمی‌کنند. به علاوه در همه نقاط در دسترس نبوده و نیز کاربرد آنها در مناطق کوهستانی که وضعیت هوا به شدت متأثر از اثرات ارتفاعات و دره‌ها است، با دشواری روبرو می‌باشد (تات و همکاران، ۲۰۰۱). مشکلات فوق سبب گردید که از روش‌های مبتنی بر داده‌ها در پیش‌بینی کوتاه‌مدت بارندگی بهره‌گیری شود. در تحقیقات اندکی که در این زمینه صورت گرفته است از تکنیک‌های چون مدل‌های سری زمانی ARMA (برلاندو و همکاران، ۱۹۹۳)، نزدیک‌ترین همسایگی K-NN و شبکه‌های عصبی ANN به طور محدود استفاده شده است (فرنچ و همکاران، ۱۹۹۲، تات و همکاران، ۲۰۰۱؛ لوک و همکاران، ۲۰۰۰؛ کولیگوسکی و باروس، ۱۹۹۸ a). در تحقیقات گذشته اظهار شده است که تکنیک ANN در مقایسه با سایر روش‌ها پاسخ بهتری داده است.

1- Lead Time

2- Quantitative Precipitation Forecasting

3- Nowcasting

مواد و روش‌ها

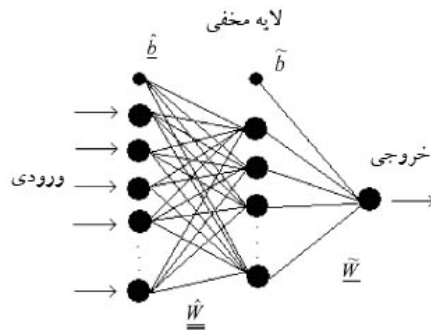
ساختار کلی شبکه عصبی: شبکه عصبی مصنوعی شبیه‌سازی ریاضی سیستم عصبی انسان است. فرآیند پردازش و شبیه‌سازی در این مدل مبتنی بر آموزش و یادگیری روابط متغیرهای مشاهده شده در گذشته و تعمیم این روابط برای آینده به‌منظور انجام پیش‌بینی‌های جدید است. نرون در این شبکه‌ها کوچک‌ترین واحد پردازش می‌باشد. ساختار این شبکه حداقل از سه لایه ورودی، پنهان و خروجی تشکیل شده‌است. تعداد نرون‌های لایه به‌تعداد ورودی‌ها بستگی دارد. لایه‌های ورودی، پنهان و خروجی همراه با نرون‌های هر لایه، معماری شبکه را تشکیل می‌دهد. در لایه پنهان، محاسبات حدواسط بین دو لایه ورودی و خروجی انجام می‌شود. تعداد نرون‌های این لایه و نیز تعداد لایه پنهان با توجه به نوع مسئله با سعی و خطا به‌دست می‌آید. تعداد نرون‌های لایه خروجی با توجه به نوع مسئله و خروجی‌های مورد نظر ممکن است یک یا بیشتر باشد. شکل ۱ یک شبکه عصبی سه لایه را نشان می‌دهد. اتصال و ارتباط نرون‌های لایه‌های ورودی، پنهان و خروجی به‌وسیله وزن‌ها که اتصالات نرونی تلقی می‌شوند برقرار می‌گردد. برای تولید خروجی، مقدار هرگره ورودی (X_i) در یک مقدار وزن (w) ضرب و سپس با هم جمع می‌شوند و مقدار خطای بایاس شامل (b_j) نیز به این مقدار اضافه می‌شود و با استفاده از تابع انتقال f مقدار خروجی y به‌دست می‌آید (معادله ۱).

$$y_j = f \left[\sum_{i=1}^n w_{ij} x_i + b_j \right] \quad (1)$$

آموزش شبکه یکی از مراحل مهم توسعه مدل شبکه عصبی است که به‌وسیله آن وزن‌های شبکه در یک فرآیند بهینه‌سازی غیرخطی تعیین می‌شوند. در فرآیند آموزش (کالیبراسیون)، الگوریتم‌های آموزشی مختلفی وجود دارد. این الگوریتم‌ها بر این مبنی استوار هستند که تابع خطای آموزش شبکه یا $E_r = \sum_{i=1}^n (y_c - y_o)$ مینیمم شود که در آن E_r تابع خطا، y_c مقادیر محاسباتی، y_o مقادیر واقعی و n نیز تعداد دوره تکرار (Epoch) است (کارآموز و عراقی‌نژاد، ۲۰۰۳). جزئیات روش در (ASCE-1, 2000)، (ASCE-II, 2000) و راهنمای نرم‌افزار MATLAB و سایر مراجع آمده است.

شبکه‌های عصبی مصنوعی به‌طور وسیعی در تحقیقات و مطالعات شبیه‌سازی و پیش‌بینی‌های هیدرومتئورولوژیکی به‌کار گرفته شده‌است. (کمپ و ساونج، ۲۰۰۷؛ ویوونی و همکاران، ۲۰۰۵؛ ریولتا و همکاران، ۲۰۰۶؛ کولیگوسکی و باروس، ۱۹۹۸b؛ کارآموز و همکاران، ۲۰۰۶؛ ستوده و همکاران، ۲۰۰۴؛ انجمن مهندسان عمران آمریکا، ۲۰۰۰ a و انجمن مهندسان آمریکا، ۲۰۰۰ b). در ارتباط با پیش‌بینی کمی بارش کوتاه‌مدت به روش شبکه‌های عصبی، تحقیقات اندکی صورت گرفته‌است. فرنچ و همکاران (۱۹۹۲) با استفاده از یک شبکه عصبی و سری زمانی داده‌های بارندگی، پیش‌بینی زمانی و مکانی بارش را در یک شبکه 25×25 کیلومتر مربعی با فواصل زمانی یک‌ساعت پیش‌بینی کردند و نتایج را با روش‌های نوکستینگ و پایا مقایسه کردند. کیم و باروس (۲۰۰۱) نیز شبکه‌های عصبی مصنوعی را برای پیش‌بینی بارندگی کمی ۶ ساعته با فاصله زمانی یک‌ساعت با استفاده از سری زمانی داده‌های ساعتی و نیز اطلاعات مربوط به جهت باد جو بالا به‌عنوان ورودی، به‌کار بردند. علاوه‌بر این تات و همکاران (۲۰۰۱) نیز با استفاده از داده‌های سری زمانی بارش ساعتی سه روش ANN, K-NN, ARMA را برای پیش‌بینی ۶ ساعته بارندگی در حوضه آرنو ایتالیا به‌کار بردند و دریافتند که ANN در مقایسه با روش‌های دیگر جواب بهتری می‌دهد. لوک و همکاران (۲۰۰۰) روش ANN را برای پیش‌بینی بارندگی کوتاه‌مدت در نقاط فاقد آمار با استفاده از ایستگاه‌های مجاور به‌کار بردند و بهترین تاخیر زمانی پیش‌بینی و نیز تعداد ایستگاه‌های لازم برای استفاده در داده‌های ورودی را تعیین کردند.

هدف این مقاله پیش‌بینی کمی و کوتاه‌مدت بارش به‌وسیله شبکه‌های عصبی برای بهبود هشدار سیل در حوضه‌های کوچک با سیل‌های ناگهانی است در این روش از داده‌های ساعتی بارش و سایر داده‌های هواشناسی بهره گرفته می‌شود.



شکل ۱- یک شبکه عصبی نمونه سه لایه.

حوضه بین ۳۰۰ تا ۱۰۰۰ میلی‌متر در سطح زیر حوضه‌های فرعی و مناطق مختلف متغیر است. برای پوشش کافی پیش‌بینی بارش در سطح حوضه‌ها، تعداد ۱۵ ایستگاه باران‌سنجی انتخاب شد که ۱۰ ایستگاه از نوع ثبات با طول آمار ۲ تا ۵ سال و ۵ ایستگاه از نوع باران‌سنج روزانه است. وقایع بارش بیشتر از ۱۰ میلی‌متر در روز از سری داده‌های باران‌سنج انتخاب شدند. برای استفاده از آمار باران‌سنج‌های روزانه، آمار هم‌زمان روزانه این ایستگاه‌ها استخراج شد و توزیع زمانی آنها از نزدیک‌ترین ایستگاه باران‌سنج ثبات به دست آمد. سعی گردید که از آمار بارش‌های بهار و تابستان که سیل‌های ناگهانی ناشی از بارش‌های همرفتی و با شدت بالا اتفاق می‌افتد، بیشتر استفاده شود. علاوه بر این، آمار رطوبت و دمای ۱۲ ساعته هم‌زمان ۳ ایستگاه هواشناسی موجود در منطقه جمع‌آوری شد تا در پیش‌بینی‌ها دخالت داده شود و اثر آنها روی کیفیت پیش‌بینی بررسی شود. از محدودیت‌های این تحقیق، کم بودن تعداد رگبارها و نیز دوام کم بارش برای ایستگاه‌های مختلف بوده‌است به طوری که تعداد آنها از ۱۲ رگبار در دشت و چشمه‌خان تا ۱۰۰ رگبار در ایستگاه گالیکش متفاوت است. دوام بارش‌ها نیز از ۱ ساعت تا ۱۰ ساعت و به طور متوسط ۳ تا ۴ ساعت بوده‌اند.

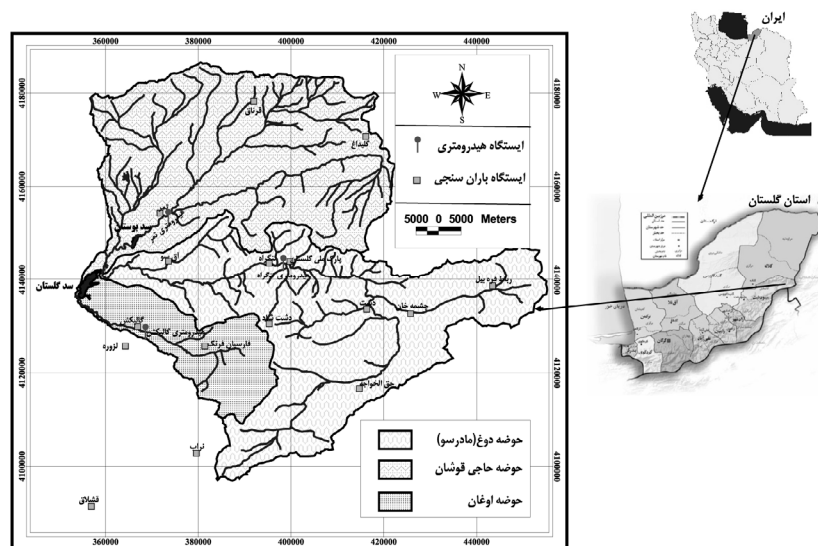
مبنای پیش‌بینی بارش با شبکه عصبی: مبنای استفاده از روش شبکه عصبی در پیش‌بینی کوتاه‌مدت بارندگی، بر این اساس صورت می‌گیرد که وقوع بارش از فرایند مارکف تبعیت می‌کند. براساس این فرایند، مقادیر بارش در یک منطقه در زمان و مکان تابعی از مقادیر جزئی قبلی خواهد بود. با چنین فرضی، ساختار اساسی یک مدل به شرح ذیل خواهد بود:

(۲)

$$x(t+1) = f[x(t), x(t-1), x(t-2), \dots, x(t-k+1)] + e(t)$$

$$x(t) = [x_{1t}, x_{2t}, \dots, x_{nt}]^T$$

که t یک شاخص زمانی با مقادیر مثبت صحیح و $x(t)$ نیز بردار مقادیر بارش در سری $(x_{1t}, x_{2t}, \dots, x_{nt})$ در n ایستگاه مختلف در زمان t و T اپراتور ترانسپوز، f نیز یک تابع غیرخطی، $e(t)$ خطای پیش‌بینی و k نیز عدد نامعلوم فاصله زمانی بارش قبلی نسبت به بارش بعدی است و معمولاً معادل تاخیر زمانی است. اگر k مساوی یک باشد، بارش آینده فقط به بارش زمان حال ارتباط پیدا می‌کند که در واقع بیان‌کننده تاخیر یک واحد زمانی است. **منطقه تحقیق و داده‌ها:** حوضه سد گلستان یک، واقع در شرق حوضه گرگان‌رود در شمال شرق ایران قرار دارد (شکل ۲)، این حوضه با مساحتی حدود ۵۰۰۰ کیلومتر مربع از سه زیر شاخه اصلی اوغان، دوغ (مادرسو) و ساری‌سو یا تمر تشکیل شده است. شیب زیر حوضه‌ها نسبتاً زیاد و زمان تمرکز آنها کم است. بارش سالانه



شکل ۲- منطقه تحقیق و موقعیت ایستگاه‌های باران‌سنجی و هیدرومتری.

ورودی در نظر گرفته شد. همه الگوهای تهیه شده بدون توجه به زمان وقوع بارش به صورت سری زمانی الگوهای سه‌ساعته مرتب شدند. با توجه به اینکه دامنه تغییرات تابع تبدیل منتخب بین صفر و ۱ است پس از تهیه الگوها، داده‌ها در فاصله ۰/۰۵ تا ۰/۹۵ با معادله ۵ نرمال شدند:

$$x_n = 0.05 + 0.9 \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) \quad (5)$$

که در آن x داده مشاهده‌ای، x_{\min} و x_{\max} مقادیر حداقل و حداکثر سری مشاهده‌ای و x_n نیز داده نرمال شده می‌باشد. پس از نرمال کردن، داده‌ها به دو سری آموزشی و آزمون تقسیم گردیدند. از نرم‌افزار MATLAB نسخه 7.3 و برنامه‌نویسی در محیط آن برای مدل‌سازی و انجام محاسبات استفاده شد.

طراحی و توسعه مدل: انتخاب مدل، تعیین معماری و آموزش مدل برای استخراج وزن‌ها از جمله مراحل طراحی و توسعه مدل شبکه عصبی می‌باشد. تحقیقات قبلی نشان داد که استفاده از MLP پیشرو در پیش‌بینی کوتاه‌مدت بارندگی در مقایسه با سایر روش‌ها جواب مناسبی می‌دهد (تات و همکاران، ۲۰۰۱ و لوک و همکاران، ۲۰۰۰). به همین دلیل شبکه مذکور برای ادامه تحقیق انتخاب شد.

پیش‌پردازش داده‌ها: به دلیل محدودیت در آمار و نیز تداوم پایین غالب بارش‌های سیل‌زای منطقه بین ۳ تا ۴ ساعت، امکان پیش‌بینی بارندگی ۶ ساعته با دقت قابل قبولی مورد انتظار نبود. لذا مدل‌سازی برای پیش‌بینی بارندگی دوساعته برای هر ایستگاه به‌طور جداگانه مدنظر قرار گرفت. از بارش‌های با تداوم حداقل ۳ ساعت و بیشتر برای تهیه الگوهای آموزش به صورت معادله ۳ از هر واقعه بارش استخراج گردید.

$$p(t+1) = f[p(t), p(t-1)] \quad (3)$$

که در آن t زمان به ساعت؛ $p(t)$ ، $p(t-1)$ و $p(t+1)$ مقدار ارتفاع بارش در زمان‌های مربوط و f یک تابع شبکه عصبی است. علاوه بر بارش زمان‌های t و $(t-1)$ به‌عنوان ورودی، مجموع و میانگین آنها نیز به‌عنوان ورودی در نظر گرفته شد. برای دخالت سایر پدیده‌های هواشناسی، به دلیل عدم وجود داده‌های دما و رطوبت ساعتی در ایستگاه‌ها، مقادیر ۱۲ ساعته این دو متغیر در تعیین الگوی آموزشی ایستگاه‌های منتخب لزوره، گلیداغ و قشلاق با الگوی معادله ۴ استخراج شد:

$$p(t+1) = f[p(t), p(t-1), Rh(d), T(d)] \quad (4)$$

که در آن $Rh(d)$ و $T(d)$ به ترتیب رطوبت و دمای ۱۲ ساعته نظیر روز وقوع بارش می‌باشد. در این حالت نیز مجموع و میانگین بارش زمان‌های t و $(t-1)$ به‌عنوان

در معماری اولیه، یک شبکه عصبی سه لایه با یک لایه ورودی با سه تا پنج ورودی یا نرون، یک لایه مخفی و یک لایه خروجی با یک نرون خروجی تعریف شد. تعداد ورودی‌ها حداقل ۳، شامل بارش‌های ساعت اول و دوم به تفکیک و نیز مجموع بارش دو ساعت اول و دوم یا میانگین دو ساعت اول و دوم و حداکثر ۵، شامل ورودی‌ها فوق و داده‌های رطوبت و دما خواهد بود تعداد نرون‌های لایه مخفی در مراحل بعدی با آزمون و خطا به دست آمد.

در فرآیند کالیبراسیون یا آموزش مدل‌ها با تعیین مقدار اولیه پارامترها از جمله وزن، بایاس، تعداد نرون لایه مخفی، گرادیان و انتخاب تابع انتقال غالباً از نوع سیگموئید و نیز به‌کارگیری هر یک از الگوریتم‌ها یا توابع آموزشی از جمله فلچر، لونیبرگ و بی‌زین، مدل‌ها

برای پیش‌بینی یک‌ساعته آموزش داده شدند. در فرآیند آموزش از توابع هدف همچون خطای میانگین مربعات (MSE) و یا خطای میانگین مربعات تعدیل شده (MSEReg) استفاده شد. با تعیین خطای اولیه، آموزش تا رسیدن به حداقل خطا ادامه می‌یابد. از روش توقف آموزش^۱ به‌صورت دستی برای تعیین تعداد تکرار آموزش استفاده شد. پس از اتمام آموزش، وزن‌ها نهایی شده و در واقع مدل کالیبره شده است. مدل کالیبره شده با استفاده از داده‌های سری آزمون یا تست اجرا شد و نتایج مرحله آموزش و تست مورد آزمون قرار گرفت. در نهایت خروجی مدل با تبدیل معکوس از رابطه ۵ به حالت اول برگردانده شد. مشخصات مدل‌های آموزش دیده شده در جدول ۱ ارائه شده است.

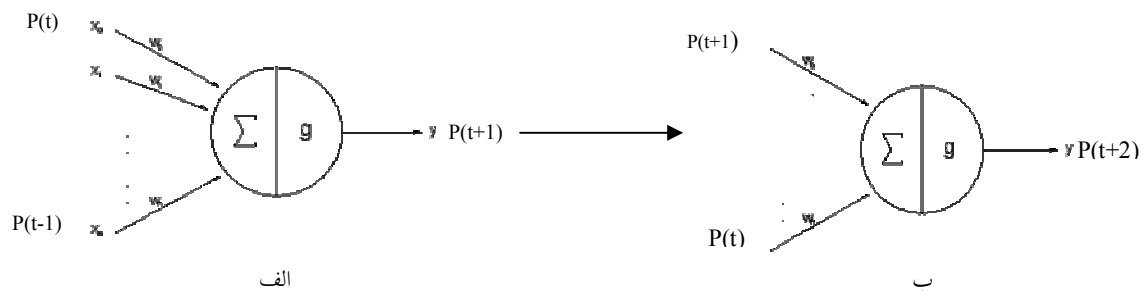
جدول ۱- مشخصات مدل‌های پیش‌بینی کننده بارش ایستگاه‌های مختلف.

نام ایستگاه	تعداد نرون‌ها در لایه‌های ورودی، میانی و خروجی	تابع خطا	تعداد الگوها	
			آموزش	آزمون
آق سو	۴-۶-۱	MSE	۴۲۵	۱۸۳
چشمه‌خان	۴-۶-۱	MSE	۳۰	۱۳
فارسیان	۴-۶-۱	MSE	۳۱۷	۱۳۷
دشت شاد	۳-۳-۱	MSE	۸۶	۳۷
گالیکش	۳-۳-۱	MSEReg	۲۶۴۲	۱۱۳۳
قشلاق	۵-۶-۱	MSE	۷۲	۳۱
گلیداغ	۵-۶-۱	MSEReg	۲۸۹	۱۲۴
حق الخواجه	۳-۶-۱	MSE	۹۲	۴۲
پارک ملی	۳-۶-۱	MSE	۵۱۷	۲۲۳
لزوره	۵-۷-۱	MSE	۲۴۰	۱۰۳
نراب	۴-۶-۱	MSE	۷۲	۳۱
قرناق	۳-۴-۱	MSE	۷۷	۳۴
تمر	۳-۴-۱	MSE	۱۳۱	۵۷
تنگراه	۳-۸-۱	MSE	۳۳۷	۱۴۵
دشت	۳-۳-۱	MSEReg	۳۷	۱۶

(۷) پیش‌بینی در گام زمانی

$$p(t+2) = f(p(t+1), p(t)) \quad ۲$$

که در آن $P(t+1)$ و $p(t+2)$ به ترتیب پیش‌بینی ساعت‌های اول و دوم و $p(t)$ و $p(t-1)$ به ترتیب مقادیر مشاهده‌ای در زمان t و $t-1$ می‌باشند. در پیش‌بینی بارش ساعت دوم از بارش مشاهده‌ای زمان فعلی و نتایج پیش‌بینی ساعت اول از مرحله قبلی استفاده شد (شکل ۳).



شکل ۳- فرایند محاسبه بارش در زمان‌های پیش‌هشدار ۱ و ۲ ساعته.
الف- پیش‌بینی ساعت اول
ب- پیش‌بینی ساعت دوم

روش پایا: علاوه بر ارزیابی مدل به وسیله هر یک از شاخص‌های آماری، برای ارزیابی نتایج مدل پیش‌بینی بارش لازم است با روش‌های پیش‌بینی استاندارد دیگر مقایسه صورت گیرد. روش‌های پایا و پایای اصلاح شده^۱ در تئوری‌های پیش‌بینی به‌طور وسیعی استفاده می‌شود (تات و همکاران، ۲۰۰۱)، در روش پایا، بارش آینده در هرگام زمانی پیش‌بینی معادل بارش گام زمان گذشته فرض می‌شود (معادله ۱۱) و در روش پایای اصلاح شده مقدار بارش در هر زمان پیش‌بینی L ، معادل متوسط اندازه L مشاهده قبلی است (معادله ۱۲).

$$p_{t+L} = p_t \quad (۱۱)$$

$$p_{t+1} = \frac{\sum_{i=1}^L p_{t+i}}{L} \quad (۱۲)$$

که در آن $t+1$ زمان پیش‌بینی و p_{t+1} مقدار بارش در زمان پیش‌بینی و p_t بارش در زمان t می‌باشد. پیش‌بینی

برای پیش‌بینی بارش دوساعت بعد نیز الگوهای چهارساعته از سری آمار استخراج شد و با استفاده از نتایج مدل کالیبره شده، مجدداً با استفاده از این الگوها، مدل برای گام‌های پیش‌بینی دو ساعته (اول و دوم) آزمون و ارزیابی شد (روابط ۶ و ۷). آزمون گام‌های زمانی پیش‌بینی ساعت‌های بعدی تا شش ساعت عملاً به دلیل تعداد کم آمار مشاهده‌ای مقدور نشد.

(۶) پیش‌بینی در گام زمانی ۱

$$p(t+1) = f(p(t), p(t-1))$$

شاخص‌های ارزیابی مدل: در این تحقیق از شاخص‌های $RMSE$ ، R^2 و CE برای ارزیابی خطای مدل استفاده شد. بعضی از این شاخص‌ها از جمله $RMSE$ بیشتر تحت تأثیر خطا در مقادیر بالا است ولی شاخص R^2 رفتار کلی مدل را بیان می‌نماید. CE نیز بیان‌کننده کارایی مدل در پیش‌بینی است (ناش و ساتکلاف، ۱۹۷۰).

$$Rmse = \sqrt{\frac{\sum_{i=1}^n (p_i - p_{fi})^2}{n}} \quad (۸)$$

$$R^2 = \left[\frac{\sum (p_i - \bar{p})(p_{fi} - \bar{p}_f)}{\sqrt{\sum_{i=1}^n (p_i - \bar{p})^2 \sum_{i=1}^n (p_{fi} - \bar{p}_f)^2}} \right]^2 \quad (۹)$$

$$CE = 1 - \frac{\sum_{i=1}^n (p_i - p_{fi})^2}{\sum_{i=1}^n (p_i - \bar{p}_i)^2} \quad (۱۰)$$

که در آن p_i مقدار مشاهده‌ای، p_{fi} مقدار پیش‌بینی شده، \bar{p}_i متوسط مقادیر مشاهده‌ای و \bar{p}_{fi} متوسط مقادیر پیش‌بینی شده و n تعداد داده‌ها می‌باشند.

بارش در همه ایستگاه‌ها در زمان‌های ۱ و ۲ ساعته با روش پایای اصلاح شده انجام شد و با نتایج مدل عصبی مقایسه گردید.

نتایج و بحث

طول دوره آماری کوتاه باعث شد که نتوان بارش‌های فصلی متأثر از سیستم‌های جوی مختلف از جمله

بارش‌های جبهه‌ای (زمستانه) و نیز همرفتی (تابستانه) را جداگانه مدل‌سازی کرد. با وجود طول دوره آماری متفاوت ایستگاه‌ها و محدودیت آمار در برخی از ایستگاه‌ها، نتایج مدل‌سازی شبکه عصبی بارش در اکثر ایستگاه‌های منتخب بیانگر دقت قابل قبول نتایج در مراحل آموزش و آزمون می‌باشد (جدول ۲).

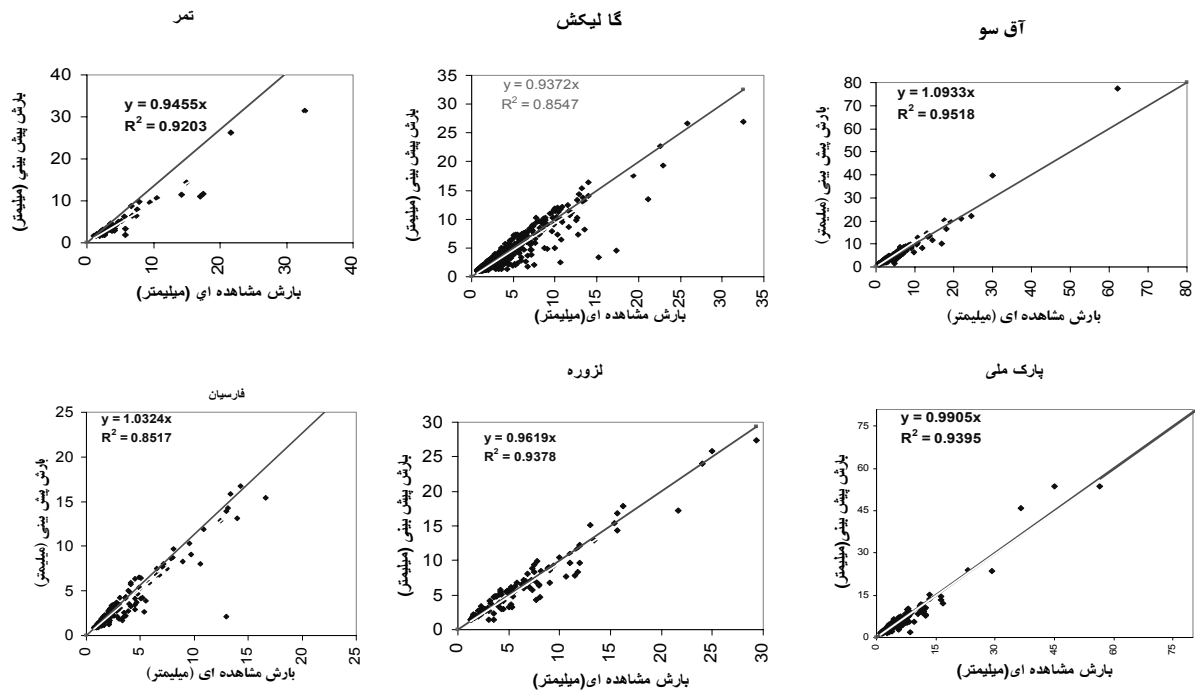
جدول ۲- نتایج خطا در مدل‌های پیش‌بینی‌کننده بارش.

آزمون (Test)			آموزش (Train)			نام ایستگاه
CE	RMSE (mm)	R ²	CE	RMSE (mm)	R ²	
0.924	1.701	0.953	0.938	1.677	0.925	آق سو
0.861	0.722	0.897	0.936	0.887	0.937	چشمه خان
0.881	5.171	0.740	0.861	6.592	0.904	فارسیان
0.704	2.231	0.885	0.970	0.841	0.970	دشت شاد
0.87	1.014	0.869	0.852	1.21	0.852	گالیکش
0.792	1.259	0.808	0.928	0.523	0.925	قشلاق
0.905	2.296	0.949	0.961	1.3	0.960	گلیداغ
0.879	1.196	0.916	0.969	0.587	0.966	حق الخواجه
0.937	1.537	0.939	0.952	1.31	0.943	پارک ملی
0.939	1.294	0.939	0.934	1.255	0.931	لزوره
0.842	0.945	0.850	0.933	0.640	0.931	نراب
0.943	1.008	0.943	0.976	1.014	0.972	قرناق
0.928	1.586	0.922	0.972	0.667	0.972	تمر
0.877	3.14	0.882	0.952	1.164	0.951	تنگراه
0.069	2.703	0.069	0.193	2.918	0.072	دشت
0.846	1.828	0.837	0.889	1.506	0.881	میانگین

در ایستگاه چشمه‌خان با وجود آمار کم (مشابه ایستگاه دشت)، مدل به‌خوبی آموزش دیده‌است اما در ایستگاه دشت به‌دلیل طول کوتاه دوره آماری، دامنه زیاد بارش‌های ثبت شده و احتمالاً خطاهای آمار امکان آموزش حتی با دقت کم نیز فراهم نشد. در سایر ایستگاه‌ها از جمله دشت شاد، نراب، حق الخواجه، پارک ملی، تنگراه و آق‌سو در حوزه دوغ و نیز فارسیان و گالیکش در حوزه اوغان و تمر، گلیداغ و قرناق در حوزه ساری سو، مدل به‌خوبی بارش را پیش‌بینی نموده است.

در ایستگاه‌هایی که از طول آماری بیشتری برخوردار بوده‌اند از جمله پارک ملی، گالیکش، آق سو، فارسیان و

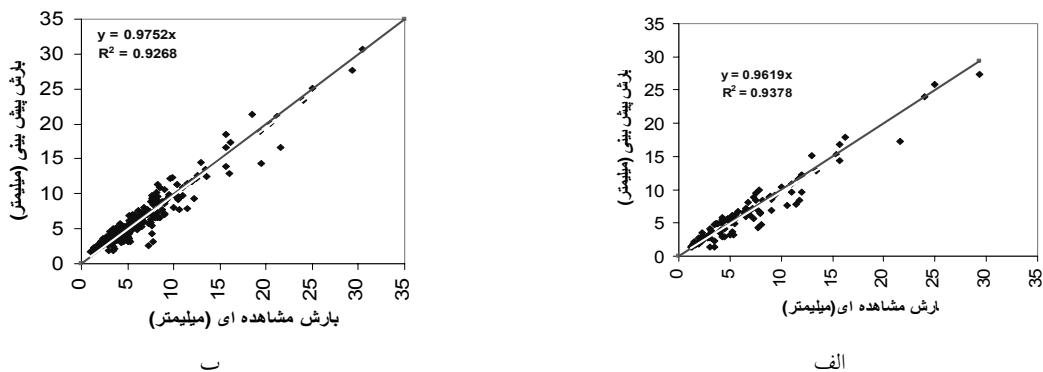
گلیداغ، نتایج بهتری به‌دست آمد که حاکی از نقش داده‌ها در آموزش بهتر مدل می‌باشد. برای رعایت اختصار نمودار پراکنندگی مقادیر پیش‌بینی و مشاهده‌ای در مرحله تست ایستگاه‌های پارک ملی، لزوره، گالیکش و فارسیان آق‌سو و تمر در (شکل ۴) ارائه شده است. در ایستگاه گالیکش که طول آمار آن از همه ایستگاه‌ها بیشتر است در مقایسه با سایر ایستگاه‌هایی که آمار زیادی دارند از جمله پارک ملی، لزوره، آق سو دقت کمتری نشان می‌دهد که احتمالاً ناشی از تفاوت ویژگی بارش‌ها تحت تأثیر فصول می‌باشد.



شکل ۴- دیاگرام پراکندگی مقادیر مشاهده‌ای و پیش‌بینی در مرحله تست در ایستگاه‌های منتخب.

پدیده‌های هواشناسی در افزایش دقت پیش‌بینی ساعتی کارایی زیادی ندارد و می‌بایست از آمارساعتی این پدیده‌ها استفاده کرد. شکل ۵ نمودار پراکندگی بارش‌های مشاهده‌ای و پیش‌بینی برای مرحله تست را در دو حالت فوق در ایستگاه لزوره نشان می‌دهد. همان‌طور که ملاحظه می‌گردد مقدار R^2 در حالت دوم حدود $0/01$ نسبت به حالت اول بهبود پیدا کرده است.

در ایستگاه‌های لزوره، گلیداغ و قشلاق مدل در دو حالت استفاده از آمار صرفاً بارش و نیز آمار بارش و دما و رطوبت به‌عنوان ورودی طراحی شد. نتایج نشان می‌دهد که استفاده از دما و رطوبت روزانه برای ایستگاه لزوره که آمار بیشتری در مقایسه با ایستگاه‌های قشلاق، گلیداغ دارد، مدل پیش‌بینی را به‌مقدار کمی بهبود داد. حال آنکه در ایستگاه‌های گلیداغ و قشلاق، تغییری در کارایی مدل حاصل نشد. به‌نظر می‌آید استفاده از آمار ۱۲ ساعته سایر



شکل ۵- پراکندگی بارش مشاهده‌ای و پیش‌بینی شده در مرحله تست در ایستگاه لزوره.

الف- ورودی‌ها بارش ساعت اول و دوم و مجموع دو ساعت به‌اضافه دما و رطوبت.

ب- ورودی‌ها بارش ساعت اول و دوم و مجموع دو ساعت.

نتایج حاصل از ارزیابی مدل‌های عصبی با پارامترهای آماری R^2 ، RMSE و CE بیانگر این است که به‌جزء ایستگاه دشت تقریباً همه مدل‌ها از کارایی نسبتاً خوبی برخوردار هستند (جدول ۲). ارزیابی نتایج پیش‌بینی بارش به روش شبکه عصبی در زمان پیش‌هشدار ۱ و ۲ ساعته در (جدول ۳) ارائه گردید. دامنه مقادیر حداقل و حداکثر و نیز میانگین پارامترهای آماری بیانگر پیش‌بینی گام‌های یک و دو ساعته در حد قابل قبول است. مدل‌سازی بارش یک ساعته به روش پایای اصلاح شده در ایستگاه‌های قرناق، چشمه‌خان و گالیکش جواب قابل قبولی ارائه نداده است ضمن اینکه پیش‌بینی ساعت

دوم نیز در ایستگاه‌های بیشتری قابل اعتماد نمی‌باشد. نتایج ارزیابی پیش‌بینی بارش به روش مذکور در (جدول ۴) ارائه شد. دامنه مقادیر حداقل و حداکثر و نیز میانگین پارامترهای ارزیابی در این روش بیانگر پیش‌بینی قابل قبول بارش یک‌ساعته در غالب ایستگاه‌ها می‌باشد. ولی در ساعت دوم، پیش‌بینی مناسبی نداشته است. مقایسه مقادیر میانگین پارامترهای ارزیابی در روش‌های عصبی و پایا (جدول‌های ۳ و ۴)، بیانگر بهتر بودن پیش‌بینی روش شبکه عصبی در مقایسه با روش پایای اصلاح شده می‌باشد چرا که غالب پارامترهای ارزیابی به‌ویژه R^2 و CE در روش عصبی بهتر از روش پایا می‌باشد.

جدول ۳- مقادیر حداقل، حداکثر و میانگین خطای پیش‌بینی بارش ایستگاه‌ها به روش شبکه عصبی.

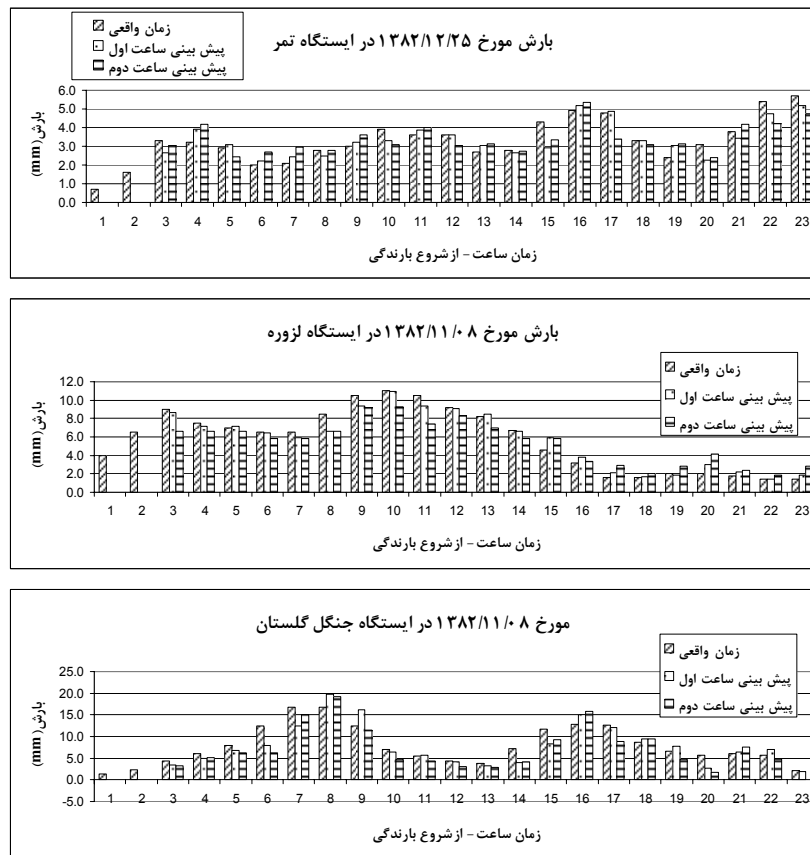
مقادیر	Lead time = 2 hr			Lead time = 1 hr		
	CE	RMSE (mm)	R^2	CE	RMSE (mm)	R^2
حداقل	0.312	1.365	0.48	0.381	1.432	0.671
حداکثر	0.822	5.188	0.91	0.929	4.940	0.935
میانگین	0.694	2.681	0.77	0.696	2.701	0.831

جدول ۴- مقادیر حداقل، حداکثر و میانگین خطای پیش‌بینی بارش ایستگاه‌ها به روش پایا.

مقادیر ایستگاه‌ها	Lead time = 2 hr			Lead time = 1 hr		
	CE	RMSE (mm)	R^2	CE	RMSE (mm)	R^2
حداقل	-1.125	0.958	0.172	-1.286	0.806	0.159
حداکثر	0.659	2.409	0.825	0.649	2.138	0.805
میانگین	-0.374	1.855	0.372	0.029	1.6	0.565

نتایج شبیه‌سازی بارش واقعی و پیش‌بینی ۱ و ۲ ساعته در ایستگاه‌های تمر، پارک ملی و لزوره در به‌عنوان نمونه نشان داده شده است (شکل ۶). همان‌طور که

ملاحظه می‌شود مدل‌ها به‌خوبی توانسته‌اند مقادیر بارش واقعی را در زمان‌های پیش‌بینی ۱ و ۲ ساعته شبیه‌سازی کنند.



شکل ۶- شبیه‌سازی بارش ایستگاه‌ها در تاریخ‌های مختلف.

پیش‌بینی بارش زمان واقعی و حتی قبل از وقوع بارش و افزایش پیش‌هشدار بسیار مفید است. شبکه عصبی با روش MLP در پیش‌بینی بارش زمان واقعی در مقایسه با روش مرسوم پایا نتایج بهتری ارائه داده است مقایسه این تحقیق با نتایج تحقیقات پیشین از جمله فرنچ و همکاران، ۱۹۹۲؛ لوک و همکاران، ۲۰۰۰ و تات و همکاران، ۲۰۰۱ بیانگر کارایی مناسب MLP در پیش‌بینی بارش کوتاه‌مدت است. خروجی مدل‌های پیش‌بینی در این تحقیق مستقیماً برای مدل‌های عصبی بارش-رواناب و نیز با متوسط‌گیری در حوضه برای مدل‌های یک‌پارچه بارش-رواناب قابل پیوند زدن می‌باشد.

محدودیت اصلی روش‌های ANN کمبود داده‌ها می‌باشد. لازم است ایستگاه‌های باران‌سنج ثبات به‌ویژه لاگرهای هواشناسی توسعه یابند. تا با تهیه آمار پیوسته بارش و سایر پدیده‌های هواشناسی در گام‌های زمانی ساعتی و کمتر از جمله ۱۵ دقیقه‌ای دقت پیش‌بینی و نیز فواصل زمانی پیش‌بینی را به روش مدل عصبی بهبود داد. این موضوع کارایی این مدل‌ها را در حوزه‌های کوچک

با شروع بارش و ثبت بارش‌های ساعت‌های اول و دوم و سوم، مدل قادر خواهد بود بارش ساعات بعد را پیش‌بینی و به‌هنگام کند. با ثبت وانتقال داده‌های حوضه آبریز سد گلستان و اجرای مدل شبکه عصبی پیش‌بینی بارش، می‌توان نتایج را با یک مدل بارش-رواناب از نوع مفهومی و یا شبکه عصبی پیوند زد و در قالب یک سیستم هشدار سیلاب به‌کار گرفت و زمان پیش‌هشدار را به‌مدت دو ساعت افزایش داد.

نتیجه‌گیری

مدل عصبی این تحقیق با پیش‌بینی بارش دوساعت، زمان پیش‌هشدار را به‌میزان دو ساعت افزایش می‌دهد. با افزایش طول آمار، امکان پیش‌بینی بارش‌های بیشتر از ۲ ساعت تا ۶ ساعته فراهم می‌گردد. استفاده از آمار هواشناسی روزانه مانند رطوبت و دما اندکی نتایج پیش‌بینی را در ایستگاه لزوره که آمار طولانی مدت دارد بهبود داد و مقدار R^2 حدود ۰/۰۱ افزایش یافت. استفاده از آمار هواشناسی به‌ویژه داده‌های ساعتی در بهبود

برای افزایش زمان پیش‌بینی و نیز سنجش بارش در مناطق فاقد ایستگاه پیشنهاد می‌شود.

سیاسگزاری

از سازمان هواشناسی کشور، اداره کل هواشناسی استان گلستان، موسسه تحقیقات آب وزارت نیرو به‌ویژه آقای مهندس قلخانی، شرکت آب منطقه‌ای گلستان به‌ویژه آقای مهندس فرازجو به‌خاطر در اختیار قراردادن آمار و اطلاعات پایه تحقیق تقدیر و قدردانی به‌عمل می‌آید.

افزایش می‌دهد. در این تحقیق، سری بارش‌های جبهه‌ای و همرفتی به‌دلیل کمبود داده‌ها تفکیک نشده‌اند برای تکمیل تحقیقات و استخراج مدل‌های مناسب، لازم است در آینده این کار انجام شود. استفاده از گام‌های زمانی حداقل ۱۵ دقیقه‌ای به‌ویژه در بارش‌های همرفتی توصیه می‌شود. با وجود کارایی مدل‌های عصبی در پیش‌بینی بارش نقطه‌ای، استفاده از سایر روش‌های پیش‌بینی از جمله مدل عددی پیش‌بینی بارش، فن‌آوری رادار و نیز استفاده از داده‌های جو بالا و رادیو سوند با شبکه عصبی

منابع

1. Asce task committee-I. 2000. Artificial neural networks in hydrology, II-Hydrologic applications, Journal of Hydrologic Engineering, Vol 5, NO. 2, 124-137.
2. Asce Task Committee-II. 2000. "Artificial neural networks in hydrology I: Preliminary concepts" Journal of Hydrologic Engineering, 5(2), 115-123.
3. Brath, A., Montanari, A., and Toth, E. 2002. Neural networks and non-parametric methods for improving real-time flood forecasting through conceptual hydrological models, Hydrology & Earth System Sciences, 6(4), 627-640.
4. Belloe, A., (1989)-Operational models of quantitative precipitation forecasts for hydrological purposes and possibilities of an intercomparison. WMO. Geneva. 6pp.
5. Burlando, P., Rosso, R., Cadavid, L., and Salas, J. 1993. Forecasting of short-term rainfall using ARMA Models, Journal of Hydrology, 144, 193-211.
6. Coulibaly, P., and Evora, N. 2004. Assessing the impact of Meteorological Predictions on Streamflow Forecasting Using Ann, 6th International Conference on Hydroinformatics, World Scientific Publishing Company, ISSN.
7. French, M., Krajewski, W., and Cuykendall, R. 1992. Rainfall forecasting in space and time using a neural network, Journal of Hydrology, Vol 132, P,1-31.
8. Kamp, R., and Savenije, H. 2007. Hydrological Model coupling with anns, Hydrology and Earth System Sciences, 11, 1869-1881.
9. Karamoz, M., and Araghinejad, S. 2003. Advanced Hydrology, Amirkabir University, 250 p.
10. Karamoz, M., Rahimi, M. and Moridi, A. 2006. longterm precipitation forecasting using meteorological signal, an application of artificial neural networks, south east of Iran, 2th Iranian conference on water Resources management, industrial Esfahan University, 8p.
11. Kim, G., and Barros, A. 2001. Quantitative flood forecasting using multisensor data and neural networks, Journal of Hydrology, 246, 45-62.
12. Kuligowski, R., and Barros, A. 1998a. Experiments in short-term precipitation forecasting using artificial neural networks, Monthly Weather Review, Vol 126, 470-482.
13. Kuligowski, R., and Barros, A. 1998b. Localized precipitation forecasts from a numerical weather prediction model using artificial neural networks, Weather and Forecasting, Vol 13, 1194-1204.
14. Luk, k., Ball, J., and sharma, A. 2000. a study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting, Journal of Hydrology, 227, 56-65.
15. Nash and Sutcliffe. 1970. River flow forecasting through conceptual models. Part I-a discussion of principles, 7. Hydrol, 10: 282-290 .
16. Rivolta, G., Marzano, F., Coppola, E., and Verdecchia, M. 2006. Artificial neural network technique for precipitation nowcasting from satellite imagery, Advances in Geosciences 7, 97-103.
17. Setoodeh, P., Safavi, A.A. and Nazemosadat, M.J. 2004. intelligent forecasting of Rainfall and temperature of shiraz city using neural networks, Iranian Journal of Science & Technology, Transaction B, Vol 28, No, B1, Shiraz University.
18. Toth, E., Brath, A., and Montanari, A. 2001. Comparison of short-term rainfall prediction models for real-time flood forecasting, Journal of Hydrology, 239, 132-147.
19. Vivoni, E., Entekhabi, D., Bras, R., Tvavoni, V., and Horne, M. 2005. Extending the predictability of hydrometeorological flood events using radar rainfall nowcasting, Journal of Hydrometeorology, Vol 7, 660-677.

The short term rainfall forecasting: an approach for flash floods warning improvement Case study: Golestan 1 Dam's Watershed, Golestan province)

***M.E. Yakhkeshi¹, B. Saghafian², H. Sedghi³, H. Fahmi⁴ and H. Mousavi jahromi⁵**

¹Ph.D. Student, Dept. of Irrigation, Islamic Azad University Science and Research branch Tehran, ²Prof. Dept. of civil, Islamic Azad University Science and Research branch Tehran, ³Prof., Dept. of Irrigation, Islamic Azad University Sciences and Research branch Tehran, ⁴Assistant Prof. of Research Ministry of Energy, ⁵Associate Prof. Dept. of Irrigation Shahid Chamran University Ahvaz, Iran

Abstract

For increase efficiency of flood warning system In the Small and medium mountainous basins, where the response time of watershed is short and occurs flash flood, a short term Quantitative Precipitation Forecast (QPF) is necessary. The QPF allows extending the lead time of flood forecast in flash flood warning system and it becomes reliable. Accurate prediction of precipitation is one of the most difficult subjects in meteorology. an Artificial Neural Network; ANN model for forecasting the short-term rainfall in 15 Rain gage station on the Golestan 1 Dam' watershed in Gorganroud basin in Golestan Province is presented in this article. Hourly precipitation and some other meteorological data is trained with feed forward Multi Layer Perceptron for 1 hr ahead forecasting and is tested for 2hr pointy precipitation for each stations. The model results compared with Persistent forecasting method. The results show that ANN accuracy is better than Persistent method. To use moisture and temperature data improve rainfall forecasting. The model would capable to update rainfall forecasting during the storm and can be applied in watershed with concentration time 3 hr and more. The results of QPF Models can be couple with the Real time Rainfall-Runoff models and improve the lead time of flood forecasting for 2hr acceptably.

Keywords: precipitation forecasting; flood warning; Artificial neural networks; lead time; Golestan 1 dam's watershed