

پیش‌بینی زمان واقعی سیل با استفاده از شبکه‌های عصبی ترکیبی

فرشاد کوهیان افضل^{۱*}، جمشید موسوی^۲، حسین صدقی^۳، جهانگیر پرهت^۴

۱- دانشجوی سابق دکترای هیدرولوژی و منابع آب، دانشگاه آزاد اسلامی واحد علوم و تحقیقات

۲- دانشیار دانشکده عمران و محیط زیست، دانشگاه صنعتی امیرکبیر

۳- استاد گروه علوم و مهندسی آب، دانشگاه آزاد اسلامی واحد علوم و تحقیقات

۴- استادیار مرکز تحقیقات حفاظت خاک و آبخیزداری

* تهران، صندوق پستی، ۷۷۵-۱۴۵۱۵

f.koohiyani@wri.ac.ir

چکیده - روشهای مبتنی بر ترکیب مدل‌ها، با تقسیم مسأله پیچیده شبیه‌سازی به تعدادی مدل موضعی ساده و ترکیب جوابهای آنها ممکن است به جوابهای متفاوتی منتهی شوند. در این روش فضای ورودی به زیرفضاهایی تفکیک می‌شود و به هر بخش ویژه از این فضای ورودی تفکیک شده، مدل‌های مجزایی اختصاص می‌یابد. در این تحقیق با استفاده از سیل‌های تولید شده توسط یک مدل هیدرولوژیکی، مزیت استفاده از مدل‌های ترکیبی (Hybrid) نسبت به مدل‌های فراگیر در پیش‌بینی سیل زمان واقعی ارزیابی شده است. بدین منظور نتایج حاصل از یک شبکه عصبی فراگیر که کل فرایند سیل را توسط یک شبکه واحد شبیه‌سازی می‌کند با نتایج حاصل از دو مدل شبکه عصبی - یکی دارای ۴ شبکه عصبی و دیگری دارای ۸ شبکه عصبی - مقایسه شده است. براساس نتایج به دست آمده مشاهده می‌شود که مدل‌های ترکیبی در پیش‌بینی سیل - به ویژه در پیش‌بینی زمان و مقدار دبی اوج که افزایش دقت در پیش‌بینی آنها در سیستم‌های هشدار سیل از اهمیت ویژه‌ای برخوردار است - به طور قابل ملاحظه‌ای بهتر از مدل فراگیر عمل می‌کنند.

کلید واژگان: پیش‌بینی سیل، زمان- واقعی، شبکه‌های عصبی ترکیبی، بارش- رواناب، خوشه‌بندی.

۱- مقدمه

سیل، مدل پیش‌بینی سیل است که با پیش‌بینی به موقع سیل، باعث اعلام خطر و جلوگیری از ایجاد خسارتهای جانی و مالی می‌شود. پیش‌بینی سیل بر مدل‌های شبیه‌سازی بارش- رواناب استوار است که انواع گوناگونی دارند. در شبیه‌سازی بارش- رواناب، استفاده از مدل‌های مفهومی، به آگاهی از فیزیک فرایند نیاز دارد و از طرفی علاوه بر داشتن ورودی‌ها و خروجیهای سیستم، همچنین به در دست داشتن، به دست آوردن، اندازه‌گیری یا تخمین بسیاری دیگر از پارامترهای مدل نیاز است. به دست آوردن یا اندازه‌گیری پارامترهای فوق، اساساً

سیل یکی از مهمترین بلایای طبیعی است که زندگی انسان را تحت تأثیر قرار داده و خسارتهای اقتصادی قابل توجهی را در تمام دنیا ایجاد می‌کند. بر اساس مطالعه‌ای که توسط Berz (2000) انجام شده، ۵۸٪ از کل تلفات ناشی از بلایای طبیعی و ۳۳٪ از خسارتهای اقتصادی مربوط به سیل بوده است. بخش اصلی این تلفات و خسارتهای در کشورهای در حال توسعه رخ داده است. یکی از راههای اصلی مقابله با سیل، استفاده از سیستم‌های هشدار سیل است. بخش اصلی سیستم هشدار

با دقت مناسبی شبیه‌سازی کند. بدین دلیل، فکر استفاده از ترکیب نتایج مدل‌های مختلف مطرح شده که به‌طور روزافزونی بر تعداد طرفداران آن افزوده می‌شود.

روشهای مبتنی بر مدل‌های ترکیبی با تقسیم مسأله شبیه‌سازی پیچیده به تعدادی مدل موضعی ساده و ترکیب جوابهای آنها می‌توانند به جوابهای بهتری منتهی شوند. مدل‌های ترکیبی را می‌توان با توجه به روش ترکیب نتایج مدل‌ها به طور اجمالی به دو دسته روش مجموع^۱ و روش چندجزئی^۲ تقسیم کرد. در روش مجموع، تعدادی مدل بر روی موضوع مشابه آموزش داده شده و سپس خروجی‌های آنها با یکدیگر ترکیب می‌شود. در روش چند جزئی ابتدا موضوع به چند زیرموضوع تقسیم می‌شود و سپس حل مسأله، با مشارکت کل مدل‌های (رژیم‌های) منفرد به دست می‌آید. در مبحث پیش‌بینی سیل، در صورت استفاده از روش ترکیب چندجزئی، هریک از زیرفضاهای فوق منعکس کننده نوعی از شرایط هیدرولوژیکی ایجاد سیل است که از اندرکنش متغیرهای مختلف تولید سیل مانند بارش، دما، پوشش برف و شرایط رطوبتی پیشین خاک حاصل می‌شود. به این طریق می‌توان رابطه بسیار پیچیده بارش- رواناب را به چند رابطه موضعی ساده‌تر تبدیل کرده و سپس با ترکیب خروجی‌ها، نتیجه نهایی را با دقت بالاتری به دست آورد.

در راستای بهبود عملکرد شبکه‌های منفرد از شبکه‌های عصبی با ساختار درختی، مانند شبکه‌های عصبی چندجزئی (MNN) در تحقیقات (Jacobs et al. 1991) و (Jacobs and Jordan 1993) و (Jordan and Jacobs 1994) استفاده شده است.

به‌نظر می‌رسد (Shamseldin et al. 1997) اولین کسانی بودند که مفهوم ترکیب مدل‌ها را برای پیش‌بینی سیل در هیدرولوژی معرفی کردند. آنها از سه روش مختلف میانگین ساده، میانگین وزنی و شبکه‌های عصبی برای

کاری مشکل، وقت گیر و پر هزینه است. بنابراین تخمینی از این پارامترها را باید از طریق واسنجی مدل بر روی داده‌های ورودی و خروجی داد. انجام واسنجی مستلزم فرایند به‌گزینی پارامترهای مدل است که ممکن است فرایندی پیچیده و حساس باشد، به‌ویژه اگر پارامترهای مدل در مقایسه با تعداد وقایع ورودی و خروجی زیاد باشد. بهینه‌یابی پارامترهای مدل حتی با استفاده از روش‌های بهینه‌سازی خودکار ممکن است با چالش‌های مختلفی همراه باشد.

از آنجا که در پیش‌بینی و هشدار سیل هدف از شبیه‌سازی، شناسایی مبنای فیزیکی فرایند بارش- رواناب نبوده و فقط دقت و سرعت شبیه‌سازی اهمیت پیدا می‌کند، بنابراین می‌توان از روش‌های جعبه‌سیاهی که بتوانند دقت و سرعت کافی را داشته باشند استفاده کرد. از طرفی با توجه به غیرخطی بودن فرایند بارش- رواناب و همچنین وابسته بودن آن به بسیاری از فرایندهای فیزیوگرافیک و هیدرولوژیک دارای همبستگی‌های داخلی حوضه، باید از مدل‌هایی استفاده شود که از قابلیت برقراری نگاشت غیرخطی بین بارش و رواناب برخوردارند. چنین مشخصه‌ای در شبکه‌های عصبی مصنوعی وجود دارد. این مدل‌ها توانایی انطباق با رابطه غیرخطی و چندمتغیره بین بارش و رواناب را داشته و می‌توانند خود را با داده‌های مغشوش منطبق ساخته و از توانایی خوبی در تعمیم بخش بالایی نیز برخوردارند. علی‌رغم نتایج قابل قبول حاصل از مدل پیش‌بینی مبتنی بر شبکه‌های عصبی، اغلب مشاهده می‌شود که عملکرد مدل فقط بر روی مقادیر سیل کم تا متوسط رضایت‌بخش است و در مورد سیل‌های با دبی بالا ممکن است عملکرد خوبی نداشته و خطای شبیه‌سازی از بخش‌های دیگر هیدروگراف سیل بیشتر باشد. از طرفی عوامل و سازوکارهای تولید سیل بسیار متفاوت و پیچیده بوده و بنابراین یک مدل منفرد به‌تنهایی نمی‌تواند تمامی بخش‌های هیدروگراف سیل و سازوکارهای تولید سیل را

1. Ensemble
2. Modular

مدل ANN را توسعه داده و با ترکیب خروجی‌ها، هیدروگراف جریان را بازسازی کردند. آنان نتیجه گرفتند که رابطه بارش- رواناب در حوضه بزرگ، از حداقل ۳ یا ۴ نداشت متفاوت متناظر با دینامیک‌های متفاوت فرایندهای فیزیکی تشکیل می‌شود. نتایج شبیه‌سازی در این روش، از شبیه‌سازی با مدل‌های منفرد بهتر بوده است. Wang et al. (2005) از سه مدل ANN پیوندی با نام‌های شبکه عصبی با مبنای آستانه‌ای^۱، شبکه عصبی با مبنای خوشه‌ای^۲ و شبکه عصبی دوره‌ای^۳ برای پیش‌بینی جریان روزانه رودخانه استفاده کردند. آنها در مدل CANN خود، ابتدا داده‌ها را با استفاده از روش خوشه‌بندی میانگین‌های c فازی^۴ خوشه‌بندی و بر روی هر یک از خوشه‌ها، نوعی مدل ANN را برازش دادند. خروجی نهایی مدل آنها، میانگین وزنی خروجی شبکه‌های عصبی کلیه خوشه‌ها بوده است.

در این مقاله با استفاده از سیلاب‌های تولید شده توسط نوعی مدل هیدرولوژیکی و داده‌های حاصل از آن، شبکه‌های عصبی ترکیبی و فراگیر برای پیش‌بینی مشخصات سیل توسعه داده شده و عملکرد آنها با یکدیگر مقایسه شده‌اند. در تعیین و انتخاب تعداد شبکه‌ها از تحلیل‌های مبتنی بر خوشه‌بندی داده‌ها استفاده شده است.

۲- مواد و روش‌ها

۲-۱- روش کار

در این تحقیق به منظور آزمون کارایی شبکه‌های عصبی ترکیبی و مزیت آن نسبت به شبکه‌های عصبی فراگیر^۵ در پیش‌بینی زمان واقعی سیل، از مدل‌های ترکیبی نوع چندجزئی استفاده شده است. بدین منظور ابتدا داده‌های فضای ورودی مدل بارش- رواناب با استفاده از روش

ترکیب پیش‌بینی‌های پنج مدل مختلف بارش- رواناب در ۱۱ حوضه آبخیز متفاوت استفاده کردند. نتایج به دست آمده نشان داد که پیش‌بینی به دست آمده از این روش از بهترین پیش‌بینی مدل‌های منفرد بهتر بوده است.

See and Openshaw (1999) نوعی مدل پیوندی را براساس منطق فازی برای پیش‌بینی رقوم رودخانه توسعه دادند که در آن مجموعه داده‌های پیش‌بینی، ابتدا به چند زیرمجموعه تقسیم شده و سپس با مجموعه‌ای از شبکه‌های عصبی آموزش داده می‌شوند.

Abrahart and See (2000) نوعی مدل شبکه عصبی را ارائه کردند که در آن داده‌های هیدرولوژیکی ابتدا توسط یک شبکه عصبی از نوع SOM خوشه‌بندی می‌شد. Zhang and Govindaraju (2000) عملکرد شبکه‌های چندجزئی را در پیش‌بینی دبی‌های ماهیانه براساس مفهوم بیزی سنجیده‌اند. (Xiong et al. (2001) از سیستم فازی Takagi-Sugeno مرتبه اول (TS1) برای ترکیب پیش‌بینی‌های پنج مدل مختلف بارش- رواناب استفاده کردند. در این تحقیق مشخص شده که سیستم فازی TS1 روش ساده و کارآمدی برای بهبود پیش‌بینی سیل می‌باشد. Pal et al. (2003) از ترکیب شبکه‌های MLP و SOFM برای پیش‌بینی دما استفاده کردند. در این مدل ترکیبی از شبکه SOFM به منظور تقسیم داده‌های یادگیری استفاده شده بود.

Shu and Bum (2004) برای بالا بردن توانایی تعمیم شبکه‌های عصبی، آنها را ترکیب کرده و برای تحلیل فراوانی سیل به کار برده‌اند. آنان نتیجه گرفته‌اند که برآوردهای به دست آمده در این روش نسبت به شبکه‌های منفرد بهبود یافته، ضمن آنکه این روش نسبت به انتخاب پارامترهای اولیه - در مقایسه با مدل‌های منفرد- حساسیت کمتری نشان می‌دهد.

Jain and Srinivasulu (2005) برای شبیه‌سازی هیدروگراف جریان، آن را به بخش‌های متفاوت تفکیک کرده و سپس بر روی هر بخش از هیدروگراف نوعی

1. TANN
2. CANN
3. PANN
4. FCM
5. Global

تابع در الگوریتم‌های مختلف خوشه‌یابی فازی متفاوت است. در روش FCM تابع هدفی که باید کمینه شود به شکل زیر ارائه شده است:

$$J_{FCM}(U, V) = \sum_{i=1}^K \sum_{k=1}^n u_{ik}^m \|X_k - V_i\|^2 \quad (1)$$

الگوریتم FCM به دلیل مفهوم تابع عضویت فازی، توانایی بیشتری در کار با داده‌های پرت و درجه‌بندی درجه‌عضویت داده‌ها دارد که در عمل از اهمیت فوق‌العاده‌ای برخوردار است. FCM یکی از الگوریتم‌های خوشه‌یابی است که به‌طور وسیعی از آن استفاده می‌شود.

۲-۲- داده‌های مورد استفاده

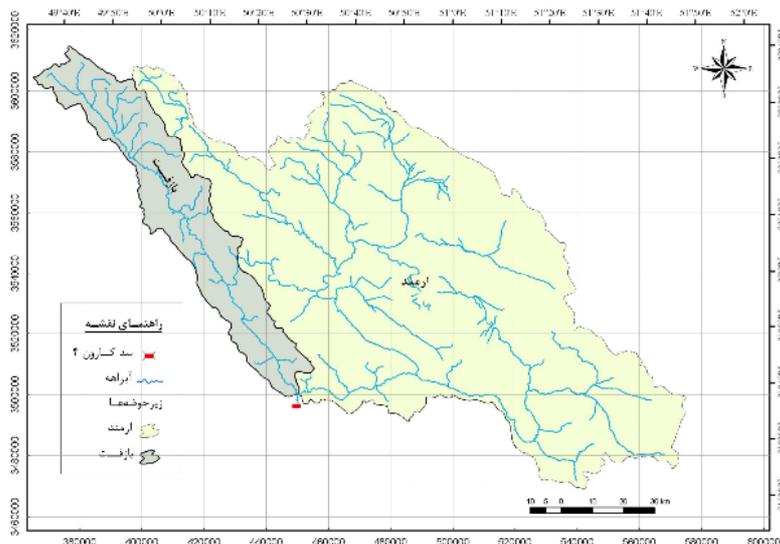
با توجه به کمبود داده‌های کامل و همزمان بارش و رواناب و مشکل بودن دسترسی به این داده‌ها و به‌منظور حصول اطمینان از صحت داده‌ها، در این تحقیق از داده‌های سیل تولید شده^۱ توسط نوعی مدل هیدرولوژیکی مفهومی به عنوان داده‌های مشاهده‌ای استفاده شده است. بدین منظور برای آنکه سیل‌های تولید شده تا حد امکان واقع بینانه باشند، به‌طور تقریبی از مشخصات حوضه سد کارون ۴ به‌عنوان حوضه‌ای نمادین استفاده شده است. این حوضه مشتمل بر دو زیرحوضه ارمند و بازفت است. مساحت زیرحوضه‌ها و نحوه اتصال آنها به یکدیگر تا حد امکان به‌صورت واقعی در نظر گرفته شده است. مشخصات حوضه فوق که برای تولید سیل استفاده شده در شکل ۱ و جدول ۱ ارائه شده است. برای در نظر گرفتن تنوع شرایط طبیعی در مدل‌سازی، مجموعه‌ای از شرایط گوناگون برای تولید سیل توسط مدل مفهومی در نظر گرفته شده است. با توجه به اینکه در این تحقیق داده‌های سیل تولید شده توسط مدل مفهومی نقش داده‌های مشاهده‌ای را ایفا می‌کنند، از این پس برای سهولت کار، از این داده‌ها با نام داده‌های مشاهده‌ای یاد می‌شود.

FCM به دو مدل ۴ و ۸ خوشه‌ای تقسیم شده است. سپس برای مدل ۴ خوشه‌ای، ۴ شبکه عصبی مجزا (هر یک برای یک خوشه) و برای مدل ۸ خوشه‌ای، ۸ شبکه عصبی مجزا (هر یک برای یک خوشه) بر روی داده‌های ورودی آموزش داده شد. پس از آن نتایج شبکه‌های عصبی فوق به روش چندجزئی ترکیب شده و نتیجه نهایی از برابند نتایج مدل‌های اختصاص داده شده به خوشه‌ها به‌دست آمده است. به‌منظور مقایسه روش ترکیب مدل‌ها با روش فراگیر، یک شبکه عصبی منفرد نیز به عنوان مبنای مقایسه بر روی کل داده‌های فضای ورودی مدل بارش- رواناب آموزش داده شده است. در نهایت نتایج به‌دست آمده از دو مدل ترکیبی ۴ و ۸ شبکه‌ای با یکدیگر و با شبکه عصبی فراگیر در مراحل مختلف آموزش، آزمون و ارزیابی مقایسه شده است.

هم‌چنانکه ذکر شد در تقسیم‌بندی فضای ورودی مدل بارش- رواناب از خوشه‌بندی فازی استفاده شده است. این روش در گروه روش‌های جدایش فازی خوشه‌یابی غیر سلسله‌مراتبی قرار می‌گیرد. روش فوق در سال ۱۹۸۱ توسط Bezdek به‌منظور وارد کردن عدم قطعیت در تعلق نمونه‌ها به خوشه‌ها، با دستکاری الگوریتم K-means و آمیختن آن با تئوری فازی یا تعلق نسبی ارائه شد و الگوریتم خوشه‌بندی میانگین‌های *c* فازی یا FCM نام گرفت.

بر خلاف خوشه‌یابی سنتی - که هر داده فقط باید به یک خوشه اختصاص یابد- خوشه‌یابی فازی با مجاز شمردن عضویت تدریجی، از این قید رها شده و بنابراین امکان بررسی داده‌هایی را که به‌صورت همزمان به بیش از یک خوشه تعلق دارند، فراهم ساخته است. در خوشه‌یابی فازی مشاهدات به‌طور همزمان به چند خوشه با درجات متفاوت عضویت تعلق دارند.

بیشتر الگوریتم‌های خوشه‌یابی فازی، بر تعریف تابع هدف استوارند. این الگوریتم‌ها با کمینه سازی یک تابع هدف مشخص، تقسیم‌بندی بهینه را تعیین می‌کنند. این



شکل ۱ نقشه حوضه سد کارون ۴

جدول ۱ مشخصات فیزیکی حوضه سد کارون ۴

زیرحوضه		مشخصه فیزیکی
B, بازفت	A, ارمنه	
۲۱۷۵	۱۰۰۰۰	مساحت (کیلومتر مربع)
۱۰	۱۲/۵	زمان تأخیر (ساعت)
۱۶	۲۲	زمان تمرکز (ساعت)
۸۵، ۸۰، ۷۵، ۷۰	۶۵، ۶۰، ۵۵، ۵۰	شماره منحنی (CN)

بارش، در مدل‌سازی با شبکه‌های عصبی که با استفاده از خروجی‌های این مدل صورت می‌گیرد تأثیری ندارد. دلیل این امر آن است که در شبکه عصبی از نوع MLP که در این تحقیق استفاده شده، شبیه‌سازی به صورت استاتیک (نه دینامیک) صورت می‌گیرد. به عبارت دیگر در هر الگو (داده‌های ورودی مربوط به یک ساعت) یک مقدار برای بارندگی وارد می‌شود و شبکه، ارتباط زمانی این بارش با بارش‌های قبلی و بعدی را درک نمی‌کند و فقط برای همان ساعت نیز خروجی را با توجه به ورودی‌ها شبیه‌سازی می‌کند و ارتباط زمانی بین خروجی‌های قبلی و بعدی را برقرار نمی‌کند. بنابراین، فقط از چهار مدل بارش که هر یک دارای یک نوع توزیع هستند، استفاده شده و ترکیبات مختلف توزیع‌های بارش‌های متفاوت مورد استفاده قرار نگرفته است.

برای نشان دادن نقش ذوب برف در ایجاد سیل، در نیمی از شبیه‌سازی‌ها، مدل ذوب برف HEC-MMS نیز فعال شده است. براساس مشخصه‌های مقدار بارش، نوع توزیع بارش و وجود یا نبود ذوب برف، چهار مدل هواشناسی مختلف برای تولید سیل توسط مدل ایجاد شده که مشخصات آنها در جدول ۲ ارائه شده است.

مدل مفهومی استفاده شده در این تحقیق برای تولید سیل، مدل HEC-HMS بوده که برای حوضه نمادین سد کارون ۴ و با در نظر گرفتن شرایط متفاوتی برای مشخصه‌های بارش و تلفات بارش و در نظر گرفتن مدل ثابتی برای تبدیل بارش به رواناب اجرا شده و سیل‌های تولید شده آن به‌عنوان داده‌های مشاهده‌ای در این تحقیق مورد استفاده قرار گرفته است.

برای آسان شدن مدل‌سازی، از دو مقدار ثابت بارش برابر ۱۵۰ و ۸۵ میلی‌متر به عنوان بارش ورودی در تمامی شبیه‌سازی‌ها استفاده شده اما برای توزیع زمانی بارش‌ها از چهار توزیع استاندارد (Type I، Type IA، Type، Type III و II) با تداوم بارش ۲۴ ساعته استفاده شده است. لازم است ذکر شود که از این توزیع‌های استاندارد فقط برای تولید داده‌های بارش استفاده شده و نوع توزیع

جدول ۲ مشخصات مدل‌های هواشناسی ایجاد شده

برای تولید سیل

Met1	Met2	Met3	Met4	مدل هواشناسی
III	I	IA	II	نوع توزیع
۱۵۰	۸۵	۱۵۰	۸۵	میزان بارش، میلی‌متر
دارد	دارد	ندارد	ندارد	ذوب برف

مشخصات پارامترهای مورد استفاده در مدل ذوب برف نیز در جدول ۳ ارائه شده است.

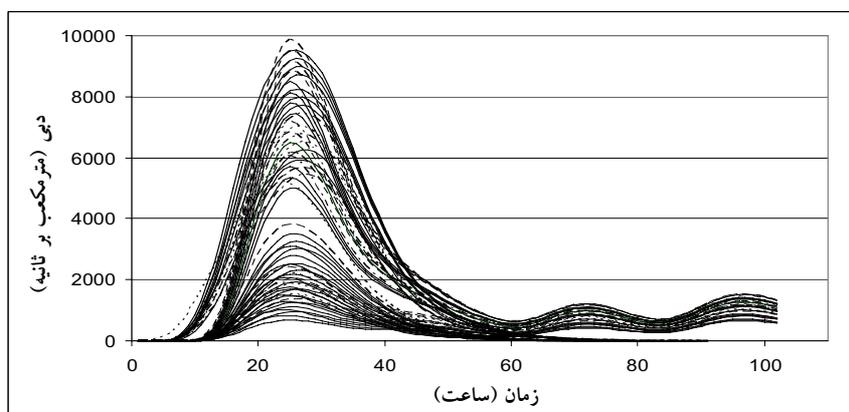
جدول ۳ پارامترهای مورد استفاده در مدل ذوب برف

پارامتر ذوب برف	مقدار پارامتر
Px Temperature (deg. c)	۲/۵
Base Temperature (deg. c)	۰
Wet meltrate (mm/deg. c-	۳/۲
Rain rate limit (mm/ day)	۰/۴
ATI-meltrate coefficient	۰/۸۵
Cold limit (mm/ day)	۲۰
Water capacity (%)	۵
Ground melt method	Fixed value
Ground melt (mm/ day)	۰

به‌منظور شبیه‌سازی تلفات زیرحوضه‌ها از روش شماره منحنی (CN) استفاده شده است. لذا برای در نظر گرفتن شرایط اولیه مختلف در مدل، ترکیبات متفاوتی از CN برای دو زیرحوضه (CN_A و CN_B) در نظر گرفته شده

است. مقادیر CN در نظر گرفته شده برای حوضه نمادین مفروض، با در نظر داشتن مقادیری که در طبیعت به‌طور متداول مشاهده می‌شوند، برای زیرحوضه ارمند ارقام ۵۰، ۵۵، ۶۰ و ۶۵ و برای زیرحوضه بازفت ارقام ۷۰، ۷۵، ۸۰ و ۸۵ در نظر گرفته شده است. شبیه‌سازی و تولید داده به ازای مقادیر مختلف از CN به‌منظور سنجش قابلیت مدل‌های پیش‌بینی عرضه شده در شرایط مختلف هیدرولوژیکی انجام شده است.

در این تحقیق از گزینه هیدروگراف واحد SCS مدل HEC-HMS برای تبدیل بارش به رواناب استفاده شده است. برای استفاده از این روش، به‌صورت اختیاری، زمان تأخیر زیرحوضه ارمند برابر ۱۲/۵ ساعت و زمان تأخیر زیرحوضه بازفت برابر ۱۰ ساعت (نزدیک به مقادیر واقعی) انتخاب شده است. از ترکیب‌های متفاوت مقادیر CN در دو زیرحوضه و مدل‌های هواشناسی مختلف، ۶۴ سناریوی متفاوت برای شبیه‌سازی و تولید سیل ایجاد و سپس توسط مدل HMS، ۶۴ هیدروگراف سیل برای ۶۴ سناریو تولید شد (شکل ۲). این هیدروگراف‌ها به‌عنوان هیدروگراف مشاهده‌ای مورد استفاده قرار می‌گیرند. امتداد بخش انتهایی برخی از هیدروگراف‌ها، نشانگر اثر ذوب برف است که در قسمت انتهایی هیدروگراف و پس از حذف اثر باران، اثر مستقل خود را نشان می‌دهد.



شکل ۲ هیدروگراف‌های سیل تولید شده توسط مدل مفهومی (GF)

HNF (نماد HNF4 برای مدل ۴ شبکه‌ای و نماد HNF8 برای مدل ۸ شبکه‌ای) نشان داده می‌شود.

۲-۳- تعیین ساختار شبکه‌های عصبی و آموزش آنها

تمامی شبکه‌های عصبی (شامل NF و HNF)، با توجه به کارایی اثبات شده برای شبکه‌های نوع MLP، از این نوع انتخاب شده است. تعیین ساختار شبکه‌ها به روش آزمون و خطا، در حین آموزش و بر اساس کمینه کردن مقدار خطای آموزش انجام شده است.

برای برطرف شدن مشکل عدم ارتباط زمانی داده‌های بارش در شبکه‌های عصبی MLP و استاتیک بودن (که در بخش قبل شرح داده شد) می‌توان سوابقی از داده‌های مربوط به زمان‌های قبل را در داده‌های زمان حاضر که قرار است خروجی زمان حاضر را تولید کنند، گنجانند. با این هدف اطلاعاتی از داده‌های بارش قبلی در بارش مربوط به هر زمان گنجانده شده و بارش‌ها به صورت تجمعی به مدل ارائه شده است. اما از آنجا که از نظر مفهومی دبی حوضه در هر لحظه، به بارش‌های قبل از آن لحظه تا زمان تمرکز حوضه بستگی داشته و بارش‌های قبل از زمان تمرکز حوضه نقشی در بالا بردن دبی اوج حوضه ندارند، در این تحقیق بارش تجمعی مربوط به t_0 ساعت قبل حوضه، به عنوان بارش ورودی مدل در زمان حاضر در نظر گرفته شده که t_0 زمان تمرکز حوضه را نشان می‌دهد. با توجه به مطلب فوق و با در نظر گرفتن زمان تمرکز دو زیرحوضه، برای ورودی شبکه‌های عصبی، بارش مربوط به زیرحوضه ارمنند در هر ساعت به صورت بارش تجمعی ۲۲ ساعت گذشته (P_{22}) آن و بارش مربوط به زیرحوضه بازفت در هر ساعت به صورت بارش تجمعی ۱۶ ساعت گذشته (P_{16}) آن در نظر گرفته شده است. برای در نظر گرفتن اثر تأخیرهای زمانی موجود در سیستم، زمان تأخیر زیرحوضه‌ها و تأخیر زمانی بین دبی خروجی زیرحوضه‌های ارمنند و بازفت با

چنانکه در شکل ۲ مشاهده می‌شود، شکل هیدروگراف‌ها به ویژه در بخش دبی اوج و بخش انتهایی هیدروگراف، تا حدی یکسان است و شاید این شبیه را ایجاد کند که فرایند تشکیل هیدروگراف‌ها، فرایندی خطی است و با تعریفی که از توانایی‌های شبکه‌های عصبی ارائه شد، به استفاده از این مدل‌ها نیازی نیست؛ در این زمینه ذکر چند نکته ضروری است.

اول آنکه فرایند تبدیل بارش به رواناب (حتی در ساده‌ترین روش‌های شبیه‌سازی آن مانند روش SCS) اساساً فرایندی غیرخطی است و بنابراین برای شبیه‌سازی آن می‌توان از قابلیت نگاشت غیرخطی شبکه‌های عصبی استفاده کرد. دوم آنکه هدف اصلی از ارائه این مقاله، مقایسه توانایی‌های مدل‌های ترکیبی (در این مقاله ترکیب مدل‌های شبکه عصبی) با مدل‌های فراگیر بوده که هر دو بر روی مجموعه داده واحدی آزمایش شده‌اند. سوم آنکه روند خطی مورد اشاره، مربوط به فرایند تبدیل بارش به رواناب نیست (که در یک هیدروگراف صورت می‌گیرد)، بلکه با توجه به اینکه از یک مدل HMS واحد دارای زمان تأخیر ثابت برای تولید سیل‌های با شرایط بارش و شرایط محیطی مختلف (CNهای متفاوت) استفاده شده، طبیعی است که زمان دبی اوج تمامی هیدروگراف‌ها نزدیک به یکدیگر باشد و بنابراین نزدیک بودن زمان دبی اوج هیدروگراف‌ها به دلیل استفاده از یک مدل ثابت تولید سیل، خللی در رابطه غیرخطی بارش- رواناب ایجاد نخواهد کرد.

پس از تولید سیل‌ها، از داده‌های ورودی به مدل مفهومی (بارش به شکل تجمعی که شرح داده شد و CN زیرحوضه‌ها) و دبی تولید شده در زیرحوضه‌های ارمنند (Q_A) و بازفت (Q_B) به عنوان فضای مدل‌سازی برای شبکه‌های عصبی استفاده شده است. از این پس برای سهولت کار، داده‌های سیل شبیه‌سازی شده توسط مدل شبکه عصبی فراگیر با نماد NF و داده‌های سیل شبیه‌سازی شده توسط شبکه‌های عصبی ترکیبی با نماد

است از P_{16} , P_{22} , Q_A و Q_B . از آنجا که مقادیر CN فقط در تعیین شرایط اولیه ایجاد سیل اهمیت داشته و در شبیه‌سازی هریک از هیدروگراف‌های سیل، در تمام زمان هیدروگراف مشاهده‌ای ثابت باقی می‌مانند، از شماره‌های منحنی حوضه‌ها برای ورودی شبکه‌ها استفاده نشده و فقط در انجام خوشه‌بندی از آنها استفاده شده است.

ساختار شبکه NF و نتایج حاصل از آموزش و آزمون آن در جدول ۶ و شکل ۳ ارائه شده است. پس از آموزش شبکه NF، نمودار همبستگی بین داده‌های مشاهده‌ای و NF در مراحل آموزش و آزمون ترسیم شده که در شکل ۴ ارائه شده است. معادلات برازش به دست آمده در شکل ۴ و ضرایب رگرسیون در جدول ۶ مشاهده می‌شوند.

ساختار شبکه HNF4 و نتایج حاصل از آموزش و آزمون آن در جدول ۷ ارائه شده است. پس از آموزش شبکه HNF4، نمودار همبستگی بین داده‌های GF و HNF4 در مراحل آموزش و آزمون انجام شده که ضرایب آن در جدول ۷ مشاهده می‌شود. ساختار شبکه HNF8 و نتایج حاصل از آموزش و آزمون آن در جدول ۸ ارائه شده است. در نهایت پس از آموزش شبکه HNF8 نیز آزمون همبستگی بین داده‌های GF و HNF8 در مراحل آموزش و آزمون انجام شده که ضرایب آن در جدول ۸ مشاهده می‌شود.

۲-۴- ارزیابی اعتبار مدل‌ها

پس از آموزش شبکه‌های عصبی، به منظور بررسی کارایی HNF4 و HNF8 و مقایسه با NF، از معیارهای مختلفی استفاده شده است. از آنجا که در پیش‌بینی سیل زمان-واقعی^۳ به‌خصوص برای سیستم‌های هشدار سیل، پیش‌بینی دبی‌های بالا و به‌ویژه دبی‌های اوج و زمان صحیح وقوع آنها از اهمیت زیادی برخوردار است، معیارهایی برای سنجش توانایی دو روش در شبیه‌سازی داده‌های حدی تعریف شده است (جدول ۹).

خروجی حوضه در نظر گرفته شده است. زمان تأخیر زیرحوضه‌ها (۱۶ ساعت)، مقدار متوسط زمان تأخیر بین بارش و دبی در زیرحوضه‌های ارمند و بازفت است. برای به‌دست آوردن تأخیرهای زمانی از تحلیل همبستگی متقابل^۱ استفاده شده است. از آنجا که شبیه‌سازی دبی در خروجی حوضه در زمان t ($Q(t)$) مد نظر است، بنابراین ورودیهای مدل‌های NF و HNF شامل $P_{16}(t-16)$, $P_{22}(t-16)$ ، $Q_A(t-6)$ و $Q_B(t-4)$ است. با توجه به اینکه زمان تأخیر بین دبی زیرحوضه‌ها با دبی خروجی حوضه برابر ۴ ساعت به دست آمده، مدلی که به دست خواهد آمد توانایی پیش‌بینی برای حدود ۴ ساعت آینده را خواهد داشت. بنابراین در مرحله پیش‌بینی، ورودیهای مدل‌های NF و HNF عبارت خواهند بود از $P_{16}(t-12)$, $P_{22}(t-12)$ ، $Q_A(t-2)$ و $Q_B(t)$ و در نتیجه $Q(t+4)$ پیش‌بینی خواهد شد.

برای آموزش شبکه‌ها، داده‌های مربوط به هر شبکه به‌صورت تصادفی به سه گروه داده‌های آموزش (۵۰ درصد داده‌های گروه)، داده‌های آزمون (۲۵ درصد داده‌های گروه) و داده‌های کنترل (۲۵ درصد مابقی داده‌ها) تقسیم شده که داده‌های دسته آخر یعنی داده‌های کنترل برای استفاده از روش Early Stopping جهت جلوگیری از وراآموزی^۲ شبکه به‌کار می‌روند.

برای شبیه‌سازی با استفاده از HNN، ابتدا به روش FCM داده‌های ورودی در یک نوبت به ۴ گروه و در نوبت دیگر به ۸ گروه تقسیم‌بندی شده است (جداول ۴ و ۵). به بیان دیگر، فضای ورودی سیستم به ۴ و ۸ زیرسیستم افزاز شده است. برای خوشه‌بندی از خصوصیات P_{16} , P_{22} , CN_A , CN_B ، Q_A و Q_B استفاده شده است. پس از خوشه‌بندی، بر روی داده‌های مربوط به هر یک از خوشه‌ها و دبی‌های متناظر با آنها، یک شبکه عصبی آموزش داده می‌شود. ورودی‌های این شبکه‌ها عبارت

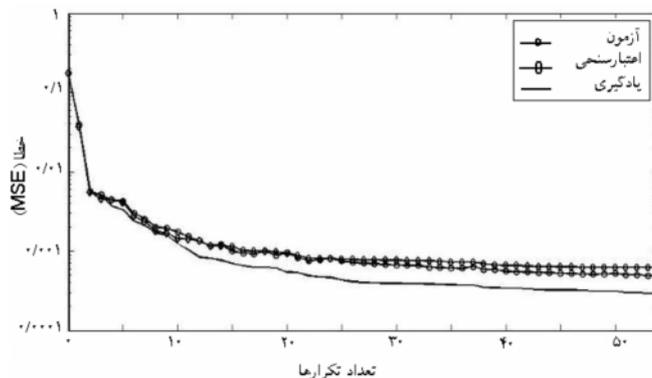
1. Cross Correlation
2. overtraining

جدول ۴ مشخصات داده‌های دسته‌بندی شده در هر یک از گروه‌های ۴ گانه

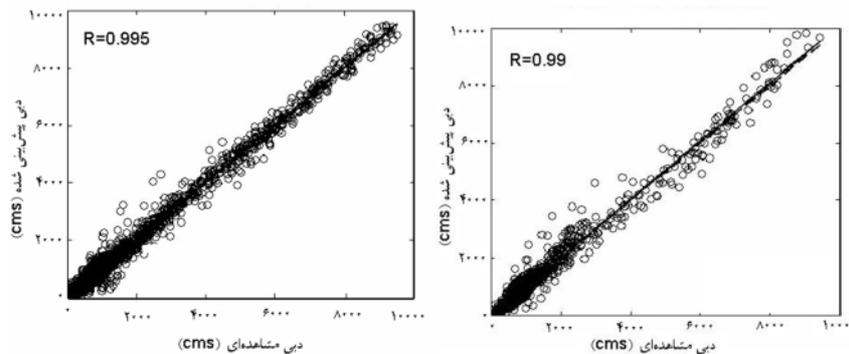
شماره خوشه	CN _B	CN _A	Q _A (cms)	Q _B (cms)	P ₂₂ (mm)	P ₁₄ (mm)
خوشه ۱	۷۰-۸۵	۵۰-۶۵	۲۴۸/۶-۲۲۲۹/۷	۷۰/۳-۲۳۳۲/۱	۰-۱۴۷	۰-۱۳۲۹
خوشه ۲	۷۰-۸۵	۵۰-۶۵	۱۵۲۸/۶-۴۴۱۴/۵	۴۵۹/۱-۳۲۶۶/۱	۱۳/۶-۱۴۷/۱	۱۳/۶-۱۳۷/۱
خوشه ۳	۷۰-۸۵	۵۰-۶۵	۰-۶۲۰/۵	۰-۱۱۲۱/۷	۰-۸۳/۱	۰-۷۵/۶
خوشه ۴	۷۰-۸۵	۵۵-۶۵	۴۱۷۶/۹-۷۲۵۶/۱	۱۰۵۴/۳-۳۲۶۶/۱	۲۸/۴-۱۴۷/۱	۲۸/۴-۱۳۷/۱

جدول ۵ مشخصات داده‌های دسته‌بندی شده در هر یک از گروه‌های ۸ گانه

شماره خوشه	CN _B	CN _A	Q _A (cms)	Q _B (cms)	P ₂₂ (mm)	P ₁₄ (mm)
خوشه ۱	۷۰-۸۵	۵۰-۶۵	۷۸/۹-۷۰/۱/۶	۱۵/۷-۱۳۵۲/۸	۰-۸۳/۱	۰-۷۶/۶
خوشه ۲	۷۰-۸۵	۵۰-۶۵	۱۵۲۸/۶-۳۵۸۴/۴	۴۲۵/۴-۲۵۸۷	۱۳/۶-۱۴۷/۱	۱۳/۶-۱۳۷/۱
خوشه ۳	۷۰-۸۵	۵۰-۶۵	۱۸۰۶/۷-۳۹۶۵/۵	۸۱۱/۷-۳۲۶۶/۱	۱۷/۱-۱۴۷/۱	۱۷/۱-۱۳۷/۱
خوشه ۴	۷۰-۸۵	۵۰-۶۵	۴۵۲/۲-۲۰۷۲	۲۴۷/۲-۲۳۳۲/۱	۷/۵-۱۴۷	۲/۹-۱۳۲/۹
خوشه ۵	۷۰-۸۵	۵۰-۶۵	۳۰۳/۷-۱۳۱۷/۶	۹۶/۱-۱۷۳۴/۱	۰-۱۲۸/۱	۰-۷۶/۸
خوشه ۶	۷۰-۸۵	۵۰-۶۵	۰-۲۷۷/۴	۰-۴۹۱/۵	۰-۸۰/۴	۰-۶۳/۴
خوشه ۷	۷۰-۸۵	۵۵-۶۵	۳۹۷۷/۸-۵۴۷۵/۸	۹۲۱/۶-۳۲۶۶/۱	۲۱/۹-۱۴۷/۱	۲۱/۹-۱۳۷/۱
خوشه ۸	۷۰-۸۵	۶۰-۶۵	۵۴۳۳/۴-۷۲۵۶/۱	۱۳۸۲/۴-۳۲۶۶/۱	۳۷/۵-۱۴۳/۹	۳۷/۵-۱۳۷/۱



شکل ۳ نمودارهای میزان خطا در داده‌های آموزش، آزمون و کنترل در شبکه NF



شکل ۴ همبستگی بین داده‌های مشاهده‌ای و NF در مراحل آموزش (چپ) و آزمون (راست)

جدول ۶ ساختار شبکه NF و نتیجه آموزش آن

تعداد داده‌ها	۵۵۴۴
خطای آموزش	۰/۰۰۰۳
خطای آزمون	۰/۰۰۰۵
ضریب همبستگی آموزش	۰/۹۹۵
ضریب همبستگی آزمون	۰/۹۹
تعداد تکرار	۵۴
ساختار شبکه	۶-۸-۱

جدول ۷ ساختار شبکه‌های مدل HNF4 و نتایج آموزش آنها

خوشه	۱	۲	۳	۴
تعداد داده‌های خوشه	۱۵۸۳	۴۶۰	۳۲۳۵	۲۶۶
خطای آموزش	۰/۰۳	۰/۰۱۸	۰/۰۳	۰/۰۰۵
خطای آزمون	۰/۰۴۵	۰/۰۵	۰/۰۳۶	۰/۰۲
ضریب همبستگی آموزش	۰/۹۸۳	۰/۹۸۷	۰/۹۸۳	۰/۹۹۷
ضریب همبستگی آزمون	۰/۹۷۶	۰/۹۷۶	۰/۹۸۲	۰/۹۹۲
تعداد تکرار	۲۲	۲۰	۱۸	۲۷
ساختار شبکه	۱۵-۱۰-۱	۱۰-۵-۱	۶-۳-۱	۱۰-۸-۱

جدول ۸ ساختار شبکه‌های مدل HNF8 و نتایج آموزش آنها

گروه	۱	۲	۳	۴	۵	۶	۷	۸
تعداد داده‌های گروه	۱۵۹۱	۲۳۹	۱۹۲	۴۱۳	۹۵۷	۱۸۴۴	۱۷۸	۱۳۰
خطای آموزش	۰/۱۴	۰/۰۴۵	۰/۰۵۸	۰/۰۷	۰/۰۳۴	۰/۰۴۵	۰/۰۰۶	۰/۰۰۵
خطای آزمون	۰/۲۵	۰/۱۸	۰/۰۸	۰/۱۲	۰/۰۹۵	۰/۰۲۵	۰/۰۱	۰/۰۳
ضریب همبستگی	۰/۹۱۷	۰/۹۶۴	۰/۹۶۴	۰/۹۵	۰/۹۸	۰/۹۷	۰/۹۹۶	۰/۹۹۵
ضریب همبستگی	۰/۸۷۸	۰/۹۰۴	۰/۹۵۶	۰/۹۳۳	۰/۹۵۶	۰/۹۸۸	۰/۹۹۵	۰/۹۸۳
تعداد تکرار	۱۵	۱۶	۱۳	۲۰	۳۷	۲۶	۲۴	۱۴
ساختار شبکه	۲۰-۱۰-۱	۱۰-۵-۱	۶-۳-۱	۱۰-۸-۱	۱۰-۸-۱	۸-۵-۱	۵-۳-۱	۵-۳-۱

روش دیگر به کار رفته برای ارزیابی اعتبار مدل‌های فوق، تولید تعدادی سیل جدید (NGF) با استفاده از مدل مفهومی (شکل ۸) و بازسازی آنها توسط شبکه‌های آموزش دیده NF و HNF4 و مقایسه نتایج حاصل است. داده‌های بازسازی شده توسط شبکه‌های NF و HNF4 به ترتیب با نمادهای NNF و NHNF4 مشخص شده است.

در ادامه از شبکه‌های آموزش دیده NF، HNF4 و HNF8 برای بازسازی کل هیدروگراف‌های مشاهده‌ای استفاده شده است. پس از آن مقادیر بازسازی شده در مقابل مقادیر واقعی ترسیم شده (شکل‌های ۵ تا ۷) و اختلاف دبی‌های اوج و اختلاف در زمان پیش‌بینی شده دبی اوج با مقادیر واقعی برای هر یک از مدل‌ها به دست آمده و معیارهای فوق محاسبه شده است (جدول ۹).

جدول ۹ مقادیر معیارهای مقایسه‌ای برای مدل‌های NF، HNF4 و HNF8

ردیف	نام معیار	نماد	فرمول	مقدار پارامتر		
				HNF8	HNF4	NF
۱	مجموع خطای مطلق در پیش‌بینی زمان دبی اوج (ساعت)	AE(Tp)	$AE(Tp) = \sum_{i=1}^n Tps_i - Tpo_i $	۱۱۱	۱۲۹	۲۸۲
۲	مجموع خطای مثبت در پیش‌بینی زمان دبی اوج (ساعت)	${}^1PE(Tp)$	$PE(Tp) = \sum_{i=1}^n (Tps_i - Tpo_i)(Tps_i - Tpo_i) > 0$	۱۴	۳۰	۲۰۳
۳	مجموع خطای منفی در پیش‌بینی زمان دبی اوج (ساعت)	${}^2NE(Tp)$	$NE(Tp) = \sum_{i=1}^n (Tps_i - Tpo_i)(Tps_i - Tpo_i) < 0$	۹۷	۹۹	۷۹
۴	حداکثر خطای منفی در پیش‌بینی زمان دبی اوج (ساعت)	$(NE(Tp))_{max}$	$(NE(Tp))_{max} = \min(NE(Tp))$	۳	۲	۷
۵	میانگین خطای مطلق در پیش‌بینی زمان دبی اوج	$(AE(Tp))_{av.}$	$(AE(Tp))_{av.} = \frac{AE(Tp)}{n}$	۰/۸۶۷	۱	۲/۲۶
۶	میانگین خطای مثبت در پیش‌بینی زمان دبی اوج	$(PE(Tp))_{av.}$	$(PE(Tp))_{av.} = \frac{PE(Tp)}{n}$	۰/۱۱	۰/۲۳	۱/۶۲۵
۷	درصد موارد دارای خطای مثبت در پیش‌بینی زمان دبی اوج	*	*	۹/۴	۱۸	۷۲/۸
۸	درصد موارد دارای خطای منفی در پیش‌بینی زمان دبی اوج	*	*	۵۵/۵	۵۷/۸	۲۷/۲
۹	درصد موارد بدون خطا در پیش‌بینی زمان دبی اوج	*	*	۳۵/۱	۲۴/۲	۰
۱۰	خطای مطلق در پیش‌بینی مقدار دبی اوج (مترمکعب بر ثانیه)	AE(Qp)	$AE(Qp) = \sum_{i=1}^n Qpo_i - Qps_i $	۴۶۱۷/۵	۴۱۶۳	۱۶۸۰۳/۹
۱۱	خطای مثبت در پیش‌بینی مقدار دبی اوج (مترمکعب بر ثانیه)	${}^2PE(Qp)$	$PE(Qp) = \sum_{i=1}^n (Qpo_i - Qps_i)(Qpo_i - Qps_i) > 0$	۲۳۷۹/۱	۱۲۴۵	۱۱۶۶۸/۱
۱۲	خطای منفی در پیش‌بینی مقدار دبی اوج (مترمکعب بر ثانیه)	${}^1NE(Qp)$	$NE(Qp) = \sum_{i=1}^n (Qpo_i - Qps_i)(Qpo_i - Qps_i) < 0$	۲۲۳۸/۴	۲۹۱۸	۵۱۳۵/۸
۱۳	درصد خطای مثبت در پیش‌بینی مقدار دبی اوج	%PE(Qp)	$\%PE(Qp) = \frac{PE(Qp)}{AE(Qp)} \times 100$	۵۲	۳۰	۷۰
۱۴	درصد خطای منفی در پیش‌بینی مقدار دبی اوج	%NE(Qp)	$\%NE(Qp) = \frac{NE(Qp)}{AE(Qp)} \times 100$	۴۸	۷۰	۳۰

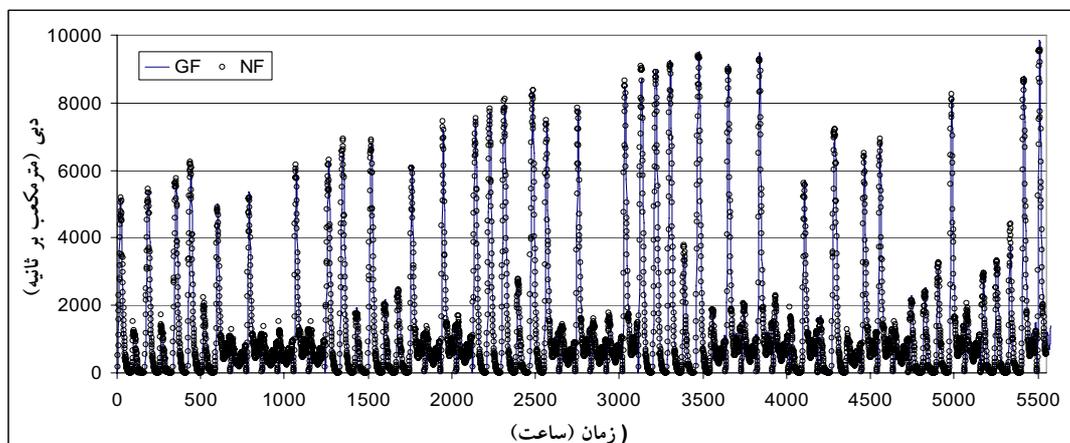
۱. خطای مثبت به معنی پیش‌بینی زمان وقوع دبی اوج، بعد از زمان واقعی است.

۲. خطای منفی به معنی پیش‌بینی زمان وقوع دبی اوج، قبل از زمان واقعی است.

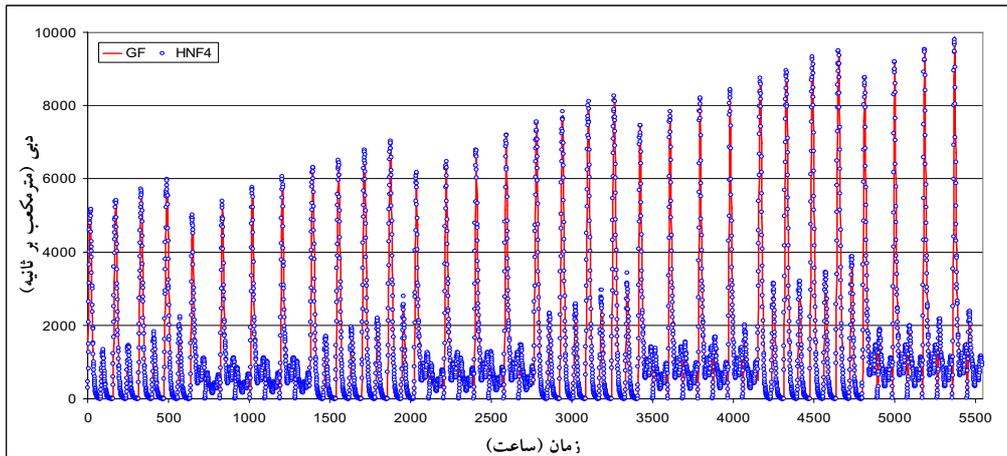
۳. خطای مثبت به معنی پیش‌بینی دبی اوج بیش از مقدار واقعی است.

۴. خطای منفی به معنی پیش‌بینی دبی اوج کمتر از مقدار واقعی است.

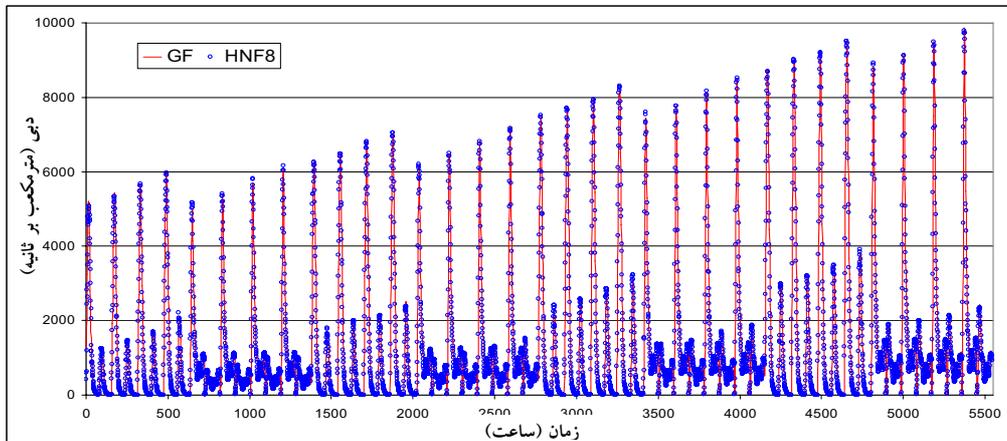
* فاقد فرمول و نماد



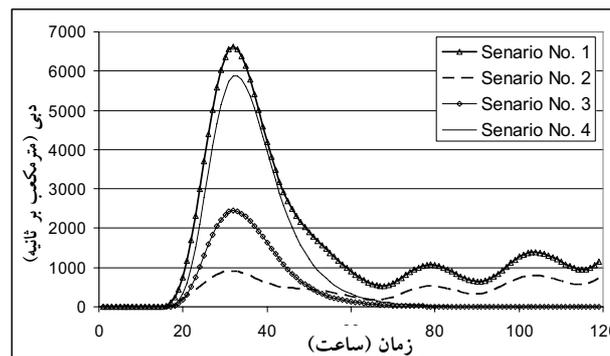
شکل ۵ مقایسه هیدروگراف‌های مشاهده‌ای و مدل NF



شکل ۶ مقایسه هیدروگراف‌های مشاهده‌ای و مدل HNF4



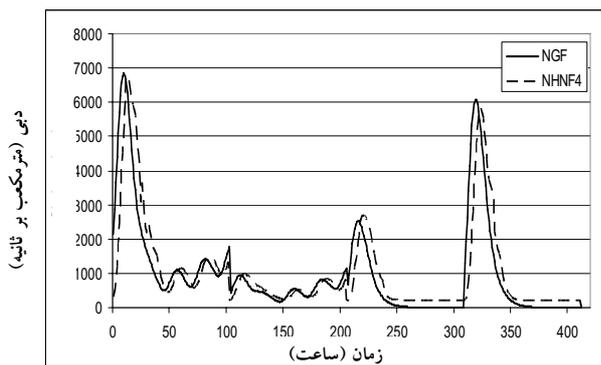
شکل ۷ مقایسه هیدروگراف‌های مشاهده‌ای و مدل HNF8



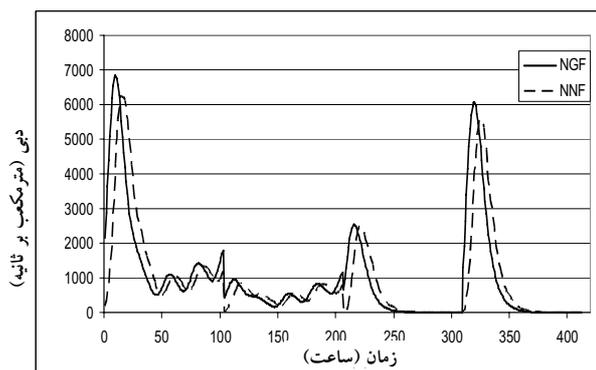
شکل ۸ هیدروگراف‌های تولید شده جدید توسط مدل مفهومی (NGF)

در روابط جدول ۹، شماره هیدروگراف، n تعداد دبی های اوج، Tp زمان دبی اوج (ساعت)، Qp دبی اوج (متر مکعب بر ثانیه)، o شاخص مشاهده و s شاخص شبیه‌سازی شده است.

برای مقایسه مدل‌های NNF و HNF4، هیدروگراف‌های آنها در مقابل هیدروگراف مدل NGF ترسیم شده (شکل‌های ۹ و ۱۰)، سپس مقادیر معیارهای مقایسه‌ای برای آنها استخراج شده است (جدول ۱۰).



شکل ۱۰ مقایسه هیدروگراف‌های دو مدل NGF و NHNF4



شکل ۹ مقایسه هیدروگراف‌های دو مدل NGF و NNF

جدول ۱۰ مقادیر معیارهای مقایسه‌ای برای مدل‌های NNF و NHNF4

مقدار پارامتر		پارامتر ارزیابی	ردیف
NHNF4	NNF		
۳۰	۴۰	AE(Tp)	۱
۳۰	۴۰	PE(Tp)	۲
۰	۰	NE(Tp)	۳
--	--	(NE(Tp)) _{max}	۴
۳/۷۵	۵	(AE(Tp)) _{av.}	۵
۳/۷۵	۵	(PE(Tp)) _{av.}	۶
۱۰۰	۱۰۰	درصد موارد دارای خطای مثبت در پیش‌بینی زمان دبی اوج	۷
۰	۰	درصد موارد دارای خطای منفی در پیش‌بینی زمان دبی اوج	۸
۰	۰	درصد موارد بدون خطا در پیش‌بینی زمان دبی اوج	۹
۶۳۸/۴	۱۳۸۷/۷	AE(Qp)	۱۰
۳۱۵	۲۲/۱	PE(Qp)	۱۱
۳۲۳/۴	۱۳۶۵/۶	NE(Qp)	۱۲
۴۹/۳	۱/۶	%PE(Qp)	۱۳
۵۰/۷	۹۸/۴	%NE(Qp)	۱۴

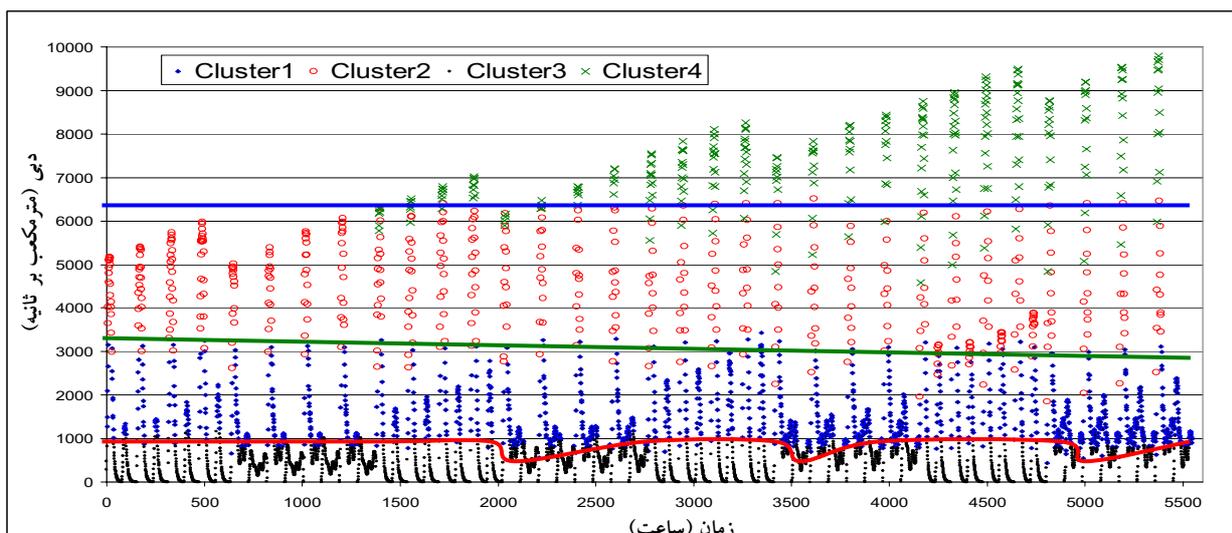
۳- نتایج و بحث

با ملاحظه شکل ۳ و جدول ۶ مشاهده می‌شود که شبکه NF به‌خوبی آموزش دیده و دقت بالایی دارد. ضرایب برازش ۰/۹۹۵ و ۰/۹۹، به‌ترتیب در مراحل آموزش و آزمون، نشانگر این موضوع است. این نتیجه از مقایسه هیدروگراف‌های ترسیم شده مشاهده‌ای و NF در شکل ۷ نیز حاصل می‌شود. نکته‌ای که در شکل ۷ قابل توجه است، اختلاف نسبی بیشتر بین دو نمودار در دبی‌های اوج هیدروگراف‌ها است. هم‌چنان‌که مشاهده می‌شود، تطابق

دو گروه، در دبی‌های کم و متوسط بسیار خوب است، اما در دبی‌های اوج، این تطابق کمتر شده و دقت مدل NF کاهش می‌یابد. دلیل این موضوع آن است که معمولاً تعداد دبی‌های اوج و بالا در مجموعه یادگیری، اندک است و بنابراین شبکه، آموزش کمتری بر روی این داده‌ها می‌بیند. اما تعداد وقایع دبی کم و متوسط در مجموعه داده‌های یادگیری، زیاد بوده و در نتیجه شبکه رفتار آنها را به‌خوبی یاد گرفته است. بنابراین مدل NF وقایع میانگین را به‌طور قابل قبولی پیش‌بینی می‌کند، لیکن در پیش‌بینی

در نتیجه، خروجی نهایی مدل - که برآیند نتایج تک‌تک شبکه‌ها است - تطابق بهتری با داده‌های واقعی داشته باشد. با ترسیم هیدروگرافهای مشاهده‌ای و HNF4 (شکل ۶) تطابق بهتر نتایج نسبت به روش قبل مشاهده می‌شود. با مقایسه نمودارها و ضرایب همبستگی مدل‌های NF و HNF4 مشاهده شد که اگرچه ضریب همبستگی در خوشه‌های ۱ تا ۳ از مدل HNF4 نسبت به ضریب همبستگی مدل NF اندکی کاهش یافته، اما در مقابل، تراکم نسبتی از داده‌ها که در نزدیکی خط برازش داده شده قرار می‌گیرند، افزایش یافته است. به عبارت دیگر، شبکه‌ای که بر روی داده‌های این خوشه آموزش دیده، شبیه‌سازی داده‌هایی را که به مرکز این خوشه نزدیک‌تر هستند با دقت بیشتری انجام داده و تعداد بیشتری از داده‌های شبیه‌سازی شده، به داده‌های واقعی نزدیک می‌شوند؛ اگرچه تعداد اندکی نیز - به دلیل تخصص یافتن شبکه - با داده‌های واقعی فاصله بیشتری پیدا می‌کنند. از طرفی در خوشه چهارم این مدل ضریب همبستگی نسبت به ضریب همبستگی مدل NF افزایش داشته است. خوشه ۴ خوشه‌ای است که اصولاً فضای ورودی دبی‌های بسیار بالا را در هیدروگراف‌های بزرگ‌تر تشکیل می‌دهد.

وقایع حدی ضعیف است. این مشکل هنگامی اهمیت بیشتری پیدا می‌کند که از این شبکه برای پیش‌بینی سیل در زمان واقعی و به منظور هشدار سیل استفاده شود که در این موارد، پیش‌بینی سیل‌های با دبی بالا - که بیشتر مخرب و زیانبار هستند - از اهمیت فوق‌العاده‌ای برخوردار است و دقت ناکافی در این مواقع می‌تواند خسارت‌های جبران‌ناپذیری را به بار آورد. خوشه‌بندی فضای ورودی شبکه عصبی که به مدل‌های HNF4 و HNF8 منتهی می‌شود، باعث تخصیص شدن هر یک از شبکه‌ها در بخشی از فضای مدل‌سازی شده و در نتیجه هر یک از شبکه‌ها مسئول تولید قسمتی از هیدروگراف سیل می‌شود. با ترسیم مقادیر مشاهده‌ای متناظر با هریک از داده‌های ورودی با توجه به خوشه‌ای که در آن قرار می‌گیرند، می‌توان این امر را مشاهده کرد. همچنان‌که در شکل ۱۱ مشاهده می‌شود هر شبکه قسمت مشخصی از هیدروگراف‌ها را شبیه‌سازی می‌کند، به طوری که یکی از شبکه‌ها دبی‌های پایین، یکی دبی‌های متوسط، یکی دبی‌های بالا و یکی دبی‌های بسیار بالا را شبیه‌سازی می‌کنند. بنابراین انتظار می‌رود که هر یک از این شبکه‌ها در فضای مربوط به خود عملکرد بهتری داشته و



شکل ۱۱ هیدروگراف‌های مشاهده‌ای و نحوه قرار گرفتن آنها در خوشه‌های مختلف

دیده و بنابراین با سرعت بیشتر و تعداد تکرار کمتری، الگوهای موجود در داده‌ها را یاد می‌گیرد. کاهش تعداد تکرارها از این نظر حائز اهمیت است که در مدل هشدار سیل، سرعت واسنجی و شبیه‌سازی حیاتی است.

به‌منظور مقایسه بهتر نتایج سه روش، می‌توان از معیارهای مقایسه‌ای ارائه شده در جدول ۹ استفاده کرد. هم‌چنان‌که مشاهده می‌شود، مقدار $AE(Tp)$ در مدل HNF4 تقریباً ۴۶٪ و در HNF8 تقریباً ۳۹٪ مقدار آن در مدل NF است. $AE(Tp)$ در مدل HNF4 به‌طور متوسط ۱ ساعت و در مدل HNF8 به‌طور متوسط ۰/۸۷ ساعت است، در حالی‌که مقدار آن در مدل NF حدود ۲/۳ ساعت است. در جدول ۹ مشاهده می‌شود که $(PE(Tp))_{av}$ در مدل HNF4 نسبت به مدل NF در حدود ۸۵٪ و در مدل HNF8 در حدود ۹۳٪ کاهش یافته به‌طوری‌که از متوسط ۱/۶۲۵ ساعت به‌ترتیب به ۰/۲۳ ساعت و ۰/۱۱ ساعت و درصد موارد آن از ۷۲/۸٪ به‌ترتیب به ۱۸٪ و ۹/۴٪ رسیده است. خطای مثبت در پیش‌بینی زمان دبی اوج به این معنا است که زمان دبی اوج پس از رخ دادن دبی اوج پیش‌بینی شود. لذا این نکته از آن جهت حائز اهمیت است که در سیستم‌های هشدار سیل، خطای مثبت در پیش‌بینی زمان دبی اوج می‌تواند موجب از دست دادن زمان و کاهش زمان پیشی^۲ شود که این ممکن است موجب بروز خسارتهای جبران‌ناپذیری شود. بنابراین یکی از مزیت‌های مهم مدل‌های HNF4 و HNF8 کاهش میزان خطای مثبت آنها در پیش‌بینی زمان دبی اوج نسبت به مدل NF است. دلیل این کاهش را می‌توان در افزایش $NE(Tp)$ و افزایش مواردی دانست که پیش‌بینی زمان دبی اوج بدون خطا بوده است. هم‌چنان‌که مشاهده می‌شود مدل HNF4 در ۲۴/۲٪ از موارد و مدل HNF8 در ۳۵/۱٪ از موارد در پیش‌بینی زمان دبی اوج، بدون خطا عمل می‌کنند در حالی‌که در مدل NF این درصد برابر صفر است. از طرفی مشاهده می‌شود که $(NE(Tp))_{max}$ در مدل‌های HNF4 و

بنابراین با توجه به اینکه فضای ورودی این خوشه شامل تعداد داده‌های کمتر و متمرکزتری است، بنابراین افزایش ضریب همبستگی در داده‌های این خوشه به دلیل فوق، توجیه‌پذیر است.

همین روند در مورد مدل HNF8 نیز قابل مشاهده است. البته در خوشه‌های این مدل به‌دلیل کمتر بودن تعداد داده‌ها و تخصص یافتن شبکه‌ها، وجود تعداد کمی داده‌های دورتر از مرکز خوشه، تأثیر منفی بیشتری بر ضریب همبستگی دارد که در جدول ۸ قابل مشاهده است. در این مدل نیز مشاهده شد که در خوشه‌های ۷ و ۸ که در واقع همان خوشه ۴ مدل HNF4 هستند، ضریب همبستگی بسیار بالا است.

نکته دیگری که در مقایسه مدل‌های فوق کاملاً مشهود است، کاهش قابل ملاحظه تعداد تکرارها^۱ در فرایند آموزش شبکه‌ها در مدل‌های HNF4 و HNF8 نسبت به مدل NF است. هم‌چنان‌که در جداول ۵ تا ۷ مشاهده می‌شود، تعداد تکرارها در مدل NF برابر ۵۴ است در حالی‌که در مدل HNF4 در خوشه‌های مختلف بین ۱۸ تا ۲۷ و در مدل HNF8 بین ۱۳ تا ۳۷ متغیر است. دلیل بیشتر بودن تکرارها در مدل NF نسبت به مدل‌های HNN آن است که آموزش شبکه NF بر روی کل داده‌های یادگیری، به علت متفاوت بودن کامل روابط تابعی بین بارندگی و رواناب برای وقایع دبی کم، دبی متوسط و دبی‌های بالا، کند است. در چنین مواردی، شبکه به تلاش زیادی در طی فرایند آموزش نیاز دارد. شبکه NF وقتی با نمونه جدیدی در حین آموزش مواجه می‌شود، به‌جای انتخاب یک بخش کوچک اما مرتبط از شبکه، تمایل به تغییر دادن تمامی وزن‌ها و آستانه‌های شبکه و یادگیری تمامی اختلافهای مختصر فضای ورودی، به روش فراگیر دارد، در نتیجه آموزش کند شده و تعداد تکرارها زیاد می‌شود. در مدل‌های HNN با تخصصی شدن شبکه‌ها، هر شبکه در فضایی محدودتر و با پراکندگی کمتر آموزش

در مدل NF، بیشتر مربوط به دبی‌های اوج هیدروگراف‌های کوچکتر بوده و هیدروگراف‌های بزرگ، بیشتر دارای خطای منفی در دبی هستند که از معایب مدل NF است.

با دقت در شکل‌های ۹ و ۱۰ مشاهده می‌شود که هرچند هر دو مدل NF و HNF4 (که خروجی‌های آنها بر مبنای داده‌های ورودی جدید با NNF و NHNF4 نشان داده شده است) در شبیه‌سازی داده‌های جدید (که شبکه‌ها قبلاً آنها را ندیده‌اند) خطا دارند، لیکن مدل HNF4 توانا تر از مدل NF بوده و خطای کمتری در پیش‌بینی مقدار و زمان وقوع دبی‌های بالا دارد. هم‌چنان‌که در این شکل‌ها مشاهده می‌شود در داده‌های NHNF4 هم مقدار دبی‌های اوج و هم زمان رخ دادن آنها نسبت به داده‌های NHNF4 به واقعیت نزدیکتر است. با استفاده از معیارهای ارزیابی محاسبه شده جهت دو سری داده فوق (جدول ۱۰) نیز این موضوع را می‌توان بررسی نمود. چنانکه در جدول (۹) مشاهده می‌شود، ۱۰۰ درصد خطای پیش‌بینی در زمان دبی اوج در هر دو مدل مثبت می‌باشد، لیکن مقدار این خطا در مدل NHNF4 برابر ۷۵٪ مقدار آن در مدل NNF است. از طرفی مشاهده می‌شود که مقدار خطا در دبی اوج در مدل NNF تقریباً دو برابر مقدار آن در مدل NHNF4 است که تقریباً تمامی آن (۹۸/۴٪) خطای منفی است. این نشان می‌دهد که برآورد مدل NNF، همیشه کمتر از مقدار واقعی است، در حالی‌که نسبت خطاهای مثبت و منفی در مدل NHNF4 تقریباً مساوی است، بنابراین از این نظر هم بر مدل NNF برتری دارد.

۴- نتیجه‌گیری

در این تحقیق با استفاده از هیدروگراف‌های سیل تولید شده توسط مدل HEC-HMS، عملکرد مدل‌های شبکه عصبی فراگیر با شبکه‌های عصبی ترکیبی ارزیابی و مقایسه شده است. بدین منظور هیدروگراف‌های سیل تولید شده توسط نوعی مدل بارش-رواناب مفهومی با

HNF8 به ترتیب برابر ۲ و ۳ ساعت است در حالی‌که در مدل NF برابر با ۷ ساعت است که اختلاف زیادی با دو مدل فوق دارد. در سیستم‌های هشدار سیل، خطر NE(Tp) کمتر از PE(Tp) است زیرا موجب صدور هشدار زودتر از موعد می‌شود، اگرچه این امر در صورت تکرار می‌تواند باعث سلب اطمینان مردم نسبت به سیستم هشدار سیل شود. از این نظر نیز مدل‌های ترکیبی نسبت به مدل NF برتری دارند، زیرا نسبت NE(Tp) به PE(Tp) از حدود ۰/۳۹ در مدل NF به ترتیب به ۳/۳ و ۶/۹۳ در مدل‌های HNF4 و HNF8 رسیده که نشانگر کاهش بسیار زیاد درصد موارد خطای مثبت و افزایش درصد موارد خطای منفی در این مدل‌ها است.

در سیستم‌های هشدار سیل، پیش‌بینی صحیح مقدار دبی، به‌ویژه دبی اوج نیز از اهمیت فوق‌العاده‌ای برخوردار است. مقایسه AE(Qp) در سه مدل (جدول ۹) نشان می‌دهد که مقدار آن در مدل‌های HNF4 و HNF8 حدود ۲۵٪ مدل NF است.

خطای مثبت در پیش‌بینی مقدار دبی اوج نشانگر آن است که دبی پیش‌بینی شده از دبی واقعی بیشتر است و به‌عکس خطای منفی نشانگر آن است که دبی اوج پیش‌بینی شده از دبی واقعی کمتر است. در هر سیستم هشدار سیل، پیش‌بینی بیش از مقدار واقعی دبی (با توجه به آستانه هشدار) می‌تواند باعث صدور هشدار کاذب شود و پیش‌بینی کمتر از مقدار واقعی دبی (با توجه به آستانه هشدار) می‌تواند باعث عدم صدور هشدار به‌موقع شود که این ممکن است به خسارت‌های جانی و مالی منتهی شود. بنابراین اگرچه هر دو نوع خطا مضراتی را به‌دنبال دارند، اما به نظر می‌رسد که خسارت‌های ناشی از خطای منفی، جدی‌تر و بیشتر باشد. مقایسه خطاهای مثبت و منفی در دبی سه مدل نشان می‌دهد که PE(Qp) در مدل NF بیش از مدل‌های HNF4 و HNF8 است. اگرچه این می‌تواند بهتر از خطای منفی باشد، اما با مشاهده شکل‌های ۵ تا ۷ می‌توان پی برد که خطای مثبت

بهینه‌سازی در هریک از این مراحل، دقت شبیه‌سازی‌ها را می‌توان افزایش داد.

۵- فهرست علائم

K	تعداد خوشه‌ها
n	تعداد داده‌ها
u	تابع عضویت
V	مختصات مرکز خوشه
X	مختصات مرکز داده

۶- منابع

Abrahart, R.J. and See, L. (2000). "Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments". *J. Hydrol. Process.*, 14, pp. 2157-2172.

Berz, G. (2000). "Flood disaster: Lessons from the past-worries for the future". *Water and Maritime Engineering*, 2000, 142(1), pp. 1-10.

Jacobs, R.A. and Jordan, M.I. (1993). "Learning piecewise control strategies in a modular neural network architecture". *IEEE Trans. Syst. Man Cybern.*, 23 (2), pp. 337-345.

Jacobs, R.A., Jordan, M.I., Nowlan, S.J. and Hinton, G.E. (1991). "Adaptive mixtures of local experts". *Neural Comput.*, 3, pp. 79-87.

Jain, A. and Srinivasulu, S. (2005). "Integrated approach to model decomposed flow hydrograph using artificial neural network and conceptual techniques". *J. Hydrol.*, xx, pp. 1-16.

Jordan, M.I. and Jacobs, R.A. (1994). "Hierarchical mixture of experts and the EM algorithm". *Neural Comput.*, 6, pp. 181-214.

Pal, N.R., Pal, S., Das, J. and Majumdar, K. (2003). "SOFM-MLP: a hybrid neural network for atmospheric emperature prediction". *IEEE transactions on geoscience and remote sensing*, 41(12), pp. 2783- 2791.

استفاده از سه مدل شبکه عصبی (مدل فراگیر، مدل ۴ شبکه‌ای و مدل ۸ شبکه‌ای) بازسازی شده است. برای اختصاص داده‌های فضای شبیه‌سازی به شبکه‌های مختلف مدل‌های ترکیبی، از تحلیل خوشه‌بندی فازی استفاده شده است. بررسی خطای پیش‌بینی سیل توسط مدل‌ها نشان می‌دهد که مدل ترکیبی ۴ شبکه‌ای، هم در پیش‌بینی زمان دبی اوج و هم در پیش‌بینی مقدار دبی اوج، دقت بسیار بیشتری نسبت به مدل فراگیر داشته و با تعداد تکرار کمتری به جواب می‌رسد. مدل ترکیبی ۸ شبکه‌ای نیز در مقایسه با نوع ۴ شبکه‌ای از دقت بیشتری در پیش‌بینی دبی اوج سیل برخوردار است و زمان وقوع دبی اوج را نیز با دقت بیشتری پیش‌بینی می‌کند.

دقت بیشتر شبکه‌های عصبی ترکیبی را می‌توان به بیشتر تخصص یافتن شبکه‌ها برای بخشی از فضای ورودی مدل‌ها نسبت داد. با توجه به نیاز سیستم‌های هشدار سیل به پیش‌بینی دقیق زمان و مقدار دبی اوج سیل در زمان واقعی، مدل‌های شبکه عصبی ترکیبی می‌توانند در این سیستم‌ها به‌عنوان مدل‌های بارش- رواناب برای پیش‌بینی سیل زمان- واقعی با دقت کافی مورد استفاده قرار گیرند. شبیه‌سازی ترکیبی ما را قادر می‌سازد که قوی‌ترین جنبه‌های مدل‌های مختلف را با یکدیگر ترکیب کنیم.

لازم است ذکر شود که در این تحقیق در تحلیل خوشه‌بندی داده‌های ورودی به شبکه‌ها، به‌طور اختیاری از ۴ و ۸ خوشه استفاده شده که احتمالاً تعداد بهینه خوشه‌ها نیستند. بنابراین در صورتی که با استفاده از یکی از روشهای بهینه‌سازی، تعداد بهینه خوشه‌ها به‌دست آید، می‌توان نتایج بهینه‌ای را از نظر میزان اختلاف در مقدار و زمان رخ دادن دبی اوج به‌دست آورد. از طرفی روش پیدا کردن ساختار شبکه‌ها بر اساس سعی و خطا، انتخاب ورودیهای شبکه‌ها بر اساس تجارب شخصی و انتخاب زمان‌های تأخیر داده‌های ورودی بر اساس آزمون‌های آماری استوار بوده و مطمئناً با به‌کار بردن روشهای

- Wang, W., Van Gelder, P. H.A.J.M., Vrijling, J.K. and Ma, J. (2005). "Forecasting daily streamflow using hybrid ANN models". *J. Hydrol.*, 324, pp. 383-399.
- Xiong, L., Shamseldin, A. Y. and O'Connor, K. M. (2001). "A non-linear combination of the forecasts of rainfall-runoff models by the first-order takagi-sugeno fuzzy system". *J. Hydrol.*, 245, pp.196-217.
- Zhang, B. and Govindaraju, R.S. (2000). "Prediction of watershed runoff using Bayesian concepts and modular neural networks". *Water Resour. Res.*, 36 (3), pp. 753-762.
- See, L. and Openshaw, S. (1999). "Applying soft computing approaches to river level forecasting". *Hydrol. Sci. J.*, 44 (5), pp. 763-778.
- Shamseldin, A.Y. (1997). "Application of a neural network technique to rainfall-runoff modelling". *J. Hydrol.*, 199, pp. 272- 294.
- Shu, C., and Bum, D. H. (2004). "Artificial neural network ensembles and their application in pooled flood frequency analysis". *Water Resour. Res.*, vol. 40, W09301, pp. 1-10.
- Solomatine, D. P. and Xue, Y. (2004) "M5 model trees and neural networks: application to flood forecasting in the upper reach of the Huai river in China. *J. Hydrologic Engrg.*, 9(6), pp. 491-501.