

# پیش‌بینی زمان واقعی سیل با استفاده از شبکه‌های عصبی ترکیبی

فرشاد کوهیان افضل<sup>\*</sup>، جمشید موسوی<sup>۲</sup>، حسین صدقی<sup>۳</sup>، جهانگیر پرهمت<sup>۴</sup>

- 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، ۱۴۵۱۵-۷۷۵

f.kohiyan@wri.ac.ir

**چکیده** - روش‌های مبتنی بر ترکیب مدل‌ها، با تقسیم مسئله پیچیده شبیه‌سازی به تعدادی مدل موضعی ساده و ترکیب جوابهای آنها ممکن است به جوابهای متفاوتی متبهمی 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 بدست آمده مشاهده می‌شود که مدل‌های ترکیبی در پیش‌بینی سیل - بهویژه در پیش‌بینی زمان و مقدار دبی اوج که افزایش دقیق 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، خوشبندی.

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

## ۱- مقدمه

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، ۰.۵۸٪ از کل تلفات ناشی از بلایای طبیعی و ۰.۳۳٪ از خسارت‌های اقتصادی مربوط به سیل بوده است. بخش اصلی این تلفات و خسارت‌ها در کشورهای درحال 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 مسئله شبیه‌سازی پیچیده به تعدادی مدل موضعی ساده و ترکیب جوابهای آنها می‌تواند به جوابهای بهتری متنه شوند. مدل‌های ترکیبی را می‌توان با توجه به روش ترکیب نتایج مدل‌ها به طور اجمالی به دو دسته روش مجموع<sup>۱</sup> و روش چندگزئی<sup>۲</sup> 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 زیرموضع تقسیم می‌شود و سپس حل مسئله، با مشارکت کل مدل‌های (رژیم‌های) منفرد به‌دست می‌آید. در مبحث پیش‌بینی سیل، در صورت استفاده از روش ترکیب چندگزئی، 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 به‌دست آورد. در راستای بهبود عملکرد شبکه‌های منفرد از شبکه‌های عصبی با ساختار درختی، مانند شبکه‌های عصبی Jacobs et al. (1991) چندگزئی (MNN) در تحقیقات (Jordan and Jacobs 1993) و Jacobs and Jordan (1993) 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 می‌توانند 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 همسنگی‌های 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 مغذوش منطبق ساخته و از توانایی خوبی در تعیین 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 هیدرولوگراف سیل بیشتر باشد. از طرفی عوامل و سازوکارهای تولید سیل بسیار متفاوت و پیچیده بوده و بنابراین یک مدل منفرد به‌نهایی نمی‌تواند تمامی بخش‌های هیدرولوگراف سیل و سازوکارهای تولید سیل را

1. Ensemble  
2. Modular

مدل ANN را توسعه داده و با ترکیب خروجی‌ها، هیدرولوگراف جریان را بازسازی کردند. آنان نتیجه گرفتند که رابطه بارش- رواناب در حوضه بزرگ، از حداقل ۳ یا ۴ نگاشت 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<sup>۱</sup>، شبکه عصبی با مبنای خوش‌های<sup>۲</sup> و شبکه عصبی دوره‌ای<sup>۳</sup> برای پیش‌بینی جریان روزانه رودخانه استفاده کردند. آنها در مدل CANN خود، ابتدا داده‌ها را با استفاده از روش خوش‌بندی میانگین‌های فازی<sup>۴</sup> خوش‌بندی و بر روی هریک از خوش‌های، نوعی مدل ANN را برآورد کردند. خروجی نهایی مدل آنها، میانگین وزنی خروجی شبکه‌های عصبی کلیه خوش‌های بوده است.

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

## ۲- مواد و روش‌ها

### ۱-۲- روش کار

در این تحقیق به منظور آزمودن کارایی شبکه‌های عصبی ترکیبی و مزیت آن نسبت به شبکه‌های عصبی فراغیر<sup>۵</sup> 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 خوش‌بندی 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 SOFM و MLP 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 تعیین 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 هیدرولوگراف جریان، آن را به بخش‌های متفاوت تفکیک کرده و سپس بر روی هر بخش از هیدرولوگراف نوعی

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

تابع در الگوریتم‌های مختلف خوش‌بایی 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 درجه عضویت داده‌ها دارد که در عمل از اهمیت فوق العاده‌ای برخوردار است. FCM یکی از الگوریتم‌های خوش‌بایی است که به طور وسیعی از آن استفاده می‌شود.

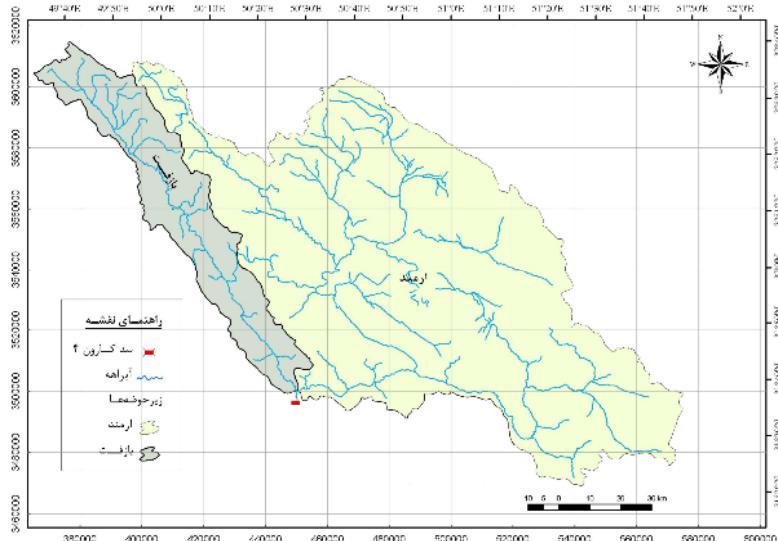
## ۲-۲-داده‌های مورد استفاده

با توجه به کمبود داده‌های کامل و همزمان بارش و رواناب و مشکل بودن دسترسی به این داده‌ها و به منظور حصول اطمینان از صحت داده‌ها، در این تحقیق از داده‌های سیل تولید شده<sup>۱</sup> 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، به طور تقریبی از مشخصات حوضه سد کارون<sup>۲</sup> به عنوان 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 به صورت 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 خوش‌بایی تقسیم شده است. سپس برای مدل ۴ خوش‌بایی، ۴ شبکه عصبی مجرا (هر یک برای یک خوش) و برای مدل ۸ خوش‌بایی، ۸ شبکه عصبی مجرا (هر یک برای یک خوش) بر روی داده‌های ورودی آموزش داده شد. پس از آن نتایج شبکه‌های عصبی فوق به روش چندجزئی ترکیب شده و نتیجه نهایی از برآیند نتایج مدل‌های اختصاص داده شده به خوش‌بایی به دست آمده است. به منظور مقایسه روش ترکیب مدل‌ها با روش فرآگیر، 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 به دست آمده از دو مدل ترکیبی ۴ و ۸ شبکه‌ای با یکدیگر و با شبکه عصبی فرآگیر در مراحل مختلف آموزش، آزمون و ارزیابی مقایسه شده است. هم‌چنانکه ذکر شد در تقسیم‌بندی فضای ورودی مدل بارش-رواناب از خوش‌بندی فازی استفاده شده است. این روش در گروه روش‌های جدایش فازی خوش‌بایی غیر سلسله مراتبی قرار می‌گیرد. روش فوق در سال ۱۹۸۱ توسط Bezdek به منظور وارد کردن عدم قطعیت در تعلق نمونه‌ها به خوش‌بایی، با دستکاری الگوریتم K-means آمیختن آن با تئوری فازی یا تعلق نسبی ارائه شد و الگوریتم خوش‌بندی میانگین‌های فازی یا FCM نام گرفت.

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

بیشتر الگوریتم‌های خوش‌بایی 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

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 با 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.

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)

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 به عنوان 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 IA، Type I، Type II و Type III (SCS) 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

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

در این تحقیق از گزینه هیدرولوگراف واحد SCS مدل HEC-HMS برای تبدیل بارش به رواناب استفاده شده است. برای استفاده از این روش، به صورت 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 هیدرولوگراف سیل برای سناریو تولید شد (شکل ۲). این هیدرولوگراف‌ها به عنوان

هیدرولوگراف مشاهده‌ای مورد استفاده قرار می‌گیرند.

امتداد بخش انتهایی برخی از هیدرولوگراف‌ها، نشانگر اثر ذوب برف است که در قسمت انتهایی هیدرولوگراف و پس از حذف اثر باران، اثر مستقل خود را نشان می‌دهد.

جدول ۲ مشخصات مدل‌های هواشناسی ایجاد شده

برای تولید سیل

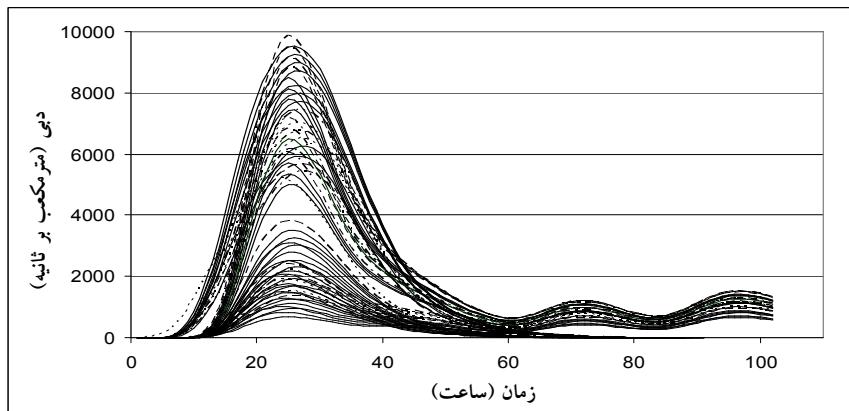
مدل هواشناسی	Met1	Met2	Met3	Met4
نوع توزیع	III	I	IA	II
میزان بارش، میلیمتر	۱۵۰	۸۵	۱۵۰	۸۵
ذوب برف	دارد	دارد	ندارد	ندارد

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

جدول ۳ پارامترهای مورد استفاده در مدل ذوب برف

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

به منظور 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



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

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

### ۳-۲- 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، گنجاند. 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  $t$  ساعت قبل حوضه، به عنوان بارش ورودی مدل در زمان حاضر در نظر گرفته شده که  $t$  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 ارمند در هر ساعت به صورت بارش  $P_{22}$  ساعت ۲۲ گذشته ( $P_{16}$ ) آن و بارش مربوط به زیرحوضه بازفت در هر ساعت به صورت بارش  $P_{16}$  ساعت ۱۶ 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 ارمند و بازفت با

چنانکه در شکل ۲ مشاهده می‌شود، شکل هیدرولیک را به ویژه در بخش دبی اوج و بخش انتهایی هیدرولیک، تا حدی یکسان است و شاید این شبکه را ایجاد کند که فرایند تشکیل هیدرولیک را 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 فرآگیر بوده که هر دو بر روی مجموعه داده واحد آزمایش شده‌اند. سوم آنکه روند خطی مورد اشاره، مربوط به فرایند تبدیل بارش به رواناب نیست (که در یک هیدرولیک راسورت 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 هیدرولیک را نزدیک به یکدیگر باشد و بنابراین نزدیک بودن زمان دبی اوج هیدرولیک را 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 ارمند ( $Q_A$ ) 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 فرآگیر 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 خوشبندی از آنها استفاده شده است.

ساختار شبکه NF و نتایج حاصل از آموزش و آزمودن 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 آزمودن آن در جدول ۷ ارائه شده است. پس از آموزش شبکه آزمون 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 آزمودن 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 آزمودن انجام شده که ضرایب آن در جدول ۸ مشاهده می‌شود.

#### ۴-۲- ارزیابی اعتبار مدل‌ها

پس از آموزش شبکه‌های عصبی، به منظور بررسی کارآیی HNF4 و HNF8 و مقایسه با NF، از معیارهای مختلفی استفاده شده است. از آنجا که در پیش‌بینی سیل زمان-واقعی<sup>۳</sup> به خصوص 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 به دست آوردن تأخیرهای زمانی از تحلیل همبستگی مقابل<sup>۱</sup> استفاده شده است. از آنجا که شبیه‌سازی دبی در خروجی حوضه در زمان  $t$  ( $Q(t)$ ) مد نظر است، بنابراین  $P_{22}(t-P_{16}(t-16))$  و  $HNF$  شامل  $(Q_A(t-6), Q_B(t-4), 16)$  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  $P_{22}(t-12), P_{16}(t-12)$  و  $HNF$  عبارت خواهند بود از  $(Q_A(t-2), Q_B(t-4))$  و در نتیجه  $Q(t+4)$  پیش‌بینی خواهد شد.

برای آموزش شبکه‌ها، داده‌های مربوط به هر شبکه به صورت تصادفی به سه گروه داده‌های آموزش (۵۰ درصد داده‌های گروه)، داده‌های آزمون (۲۵ درصد داده‌های گروه) و داده‌های کترسل (۲۵ درصد مابقی داده‌ها) تقسیم شده که داده‌های دسته آخر (عنی داده‌های کترسل برای استفاده از روش Early Stopping جهت جلوگیری از ورآموزی<sup>۲</sup> شبکه به کار 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 افزایش شده است. برای خوشبندی از خصوصیات  $P_{16}$  افزایش شده است. برای خوشبندی شده است. پس از خوشبندی، بر روی داده‌های مربوط به هر یک از خوشبندی و دبی‌های متناظر با آنها، یک شبکه عصبی آموزش داده می‌شود. ورودی‌های این شبکه‌ها عبارت

3. Real-time

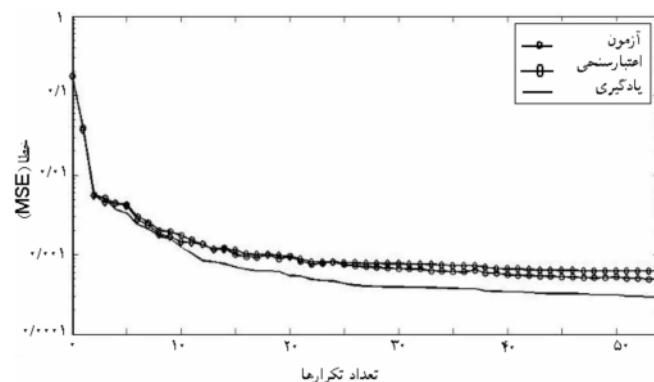
1. Cross Correlation  
2. overtraining

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

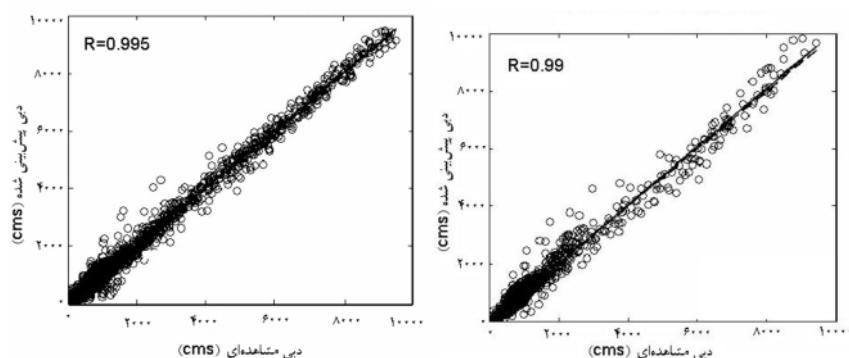
P <sub>14</sub> (mm)	P <sub>22</sub> (mm)	Q <sub>B</sub> (cms)	Q <sub>A</sub> (cms)	CN <sub>A</sub>	CN <sub>B</sub>	شماره خوش
-۱۳۲۹	-۱۴۷	۷۰/۳-۲۲۳۲/۱	۲۴۸/۶-۲۲۲۹/۷	۵۰-۶۵	۷۰-۸۵	خوش ۱
۱۳/۸-۱۳۷/۱	۱۳/۹-۱۴۷/۱	۴۰۹/۱-۳۲۶۶/۱	۱۵۲۸/۶-۴۴۱۴/۵	۵۰-۶۵	۷۰-۸۵	خوش ۲
-۷۵/۶	-۸۳/۱	-۱۱۲۱/۷	-۶۲۰/۵	۵۰-۶۵	۷۰-۸۵	خوش ۳
۲۸/۴-۱۳۷/۱	۲۸/۴-۱۴۷/۱	۱۰۵۴/۳-۳۲۶۶/۱	۴۱۷۶/۹-۷۲۵۶/۱	۵۵-۶۵	۷۰-۸۵	خوش ۴

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

P <sub>14</sub> (mm)	P <sub>22</sub> (mm)	Q <sub>B</sub> (cms)	Q <sub>A</sub> (cms)	CN <sub>A</sub>	CN <sub>B</sub>	شماره خوش
-۷۶/۶	-۸۳/۱	۱۵/۷-۱۳۵۲/۸	۷۸/۹-۷۰۱/۶	۵۰-۶۵	۷۰-۸۵	خوش ۱
۱۳/۸-۱۳۷/۱	۱۳/۹-۱۴۷/۱	۴۲۵/۴-۲۵۸۷	۱۵۲۸/۶-۳۵۸۴/۴	۵۰-۶۵	۷۰-۸۵	خوش ۲
۱۷/۱-۱۳۷/۱	۱۷/۱-۱۴۷/۱	۸۱۱/۷-۳۲۶۶/۱	۱۸۰۶/۷-۳۹۶۵/۵	۵۰-۶۵	۷۰-۸۵	خوش ۳
۲/۹-۱۳۲/۹	۷/۵-۱۴۷	۲۴۷/۲-۲۲۳۲/۱	۴۵۲/۲-۲۰۷۲	۵۰-۶۵	۷۰-۸۵	خوش ۴
-۷۶/۸	-۱۲۸/۱	۹۶/۱-۱۷۳۴/۱	۳۰۳/۷-۱۳۱۷/۶	۵۰-۶۵	۷۰-۸۵	خوش ۵
-۶۳/۴	-۸۰/۴	-۴۹۱/۵	-۲۷۷/۴	۵۰-۶۵	۷۰-۸۵	خوش ۶
۲۱/۹-۱۳۷/۱	۲۱/۹-۱۴۷/۱	۹۲۱/۶-۳۲۶۶/۱	۳۹۷۷/۸-۵۴۷۵/۸	۵۵-۶۵	۷۰-۸۵	خوش ۷
۳۷/۵-۱۳۷/۱	۳۷/۵-۱۴۳/۹	۱۳۸۲/۴-۳۲۶۶/۱	۵۴۳۳/۴-۷۲۵۶/۱	۶۰-۶۵	۷۰-۸۵	خوش ۸



شکل ۳ نمودارهای میزان خطأ 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

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

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	۰/۰۰۸	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	۰/۰۹۵	۰/۹۸	۰/۹۷	۰/۹۹۶	۰/۹۹۵
ضریب همبستگی	۰/۸۷۸	۰/۹۰۴	۰/۹۰۶	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 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 هریک از مدل‌ها به دست آمده و معیارهای فوق محاسبه شده است (جدول ۹).

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

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

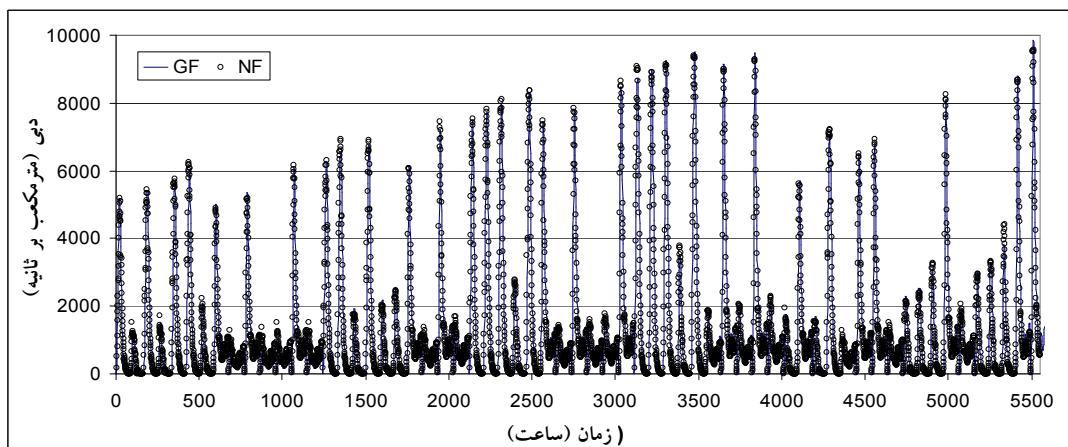
۱. خطای مثبت به معنی پیش‌بینی زمان وقوع دبی اوج، بعد از زمان واقعی است.

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

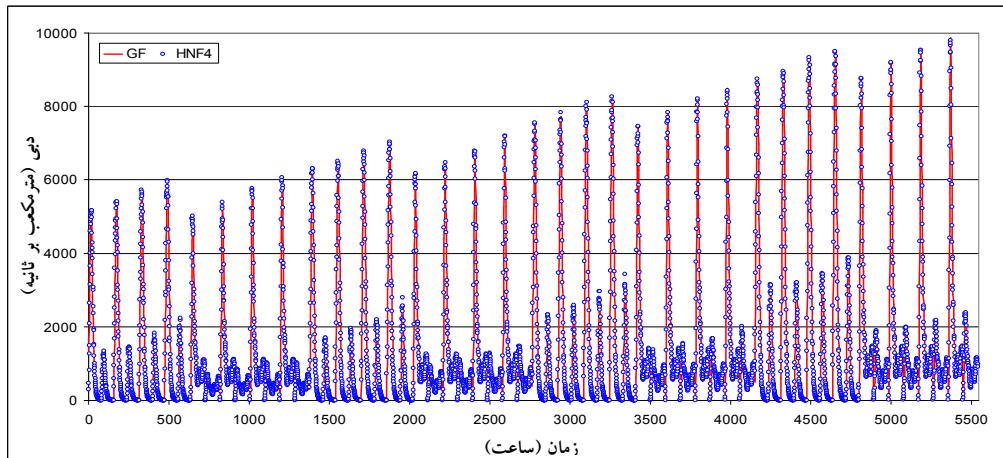
۳. خطای مثبت به معنی پیش‌بینی دبی اوج بیش از مقدار واقعی است.

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

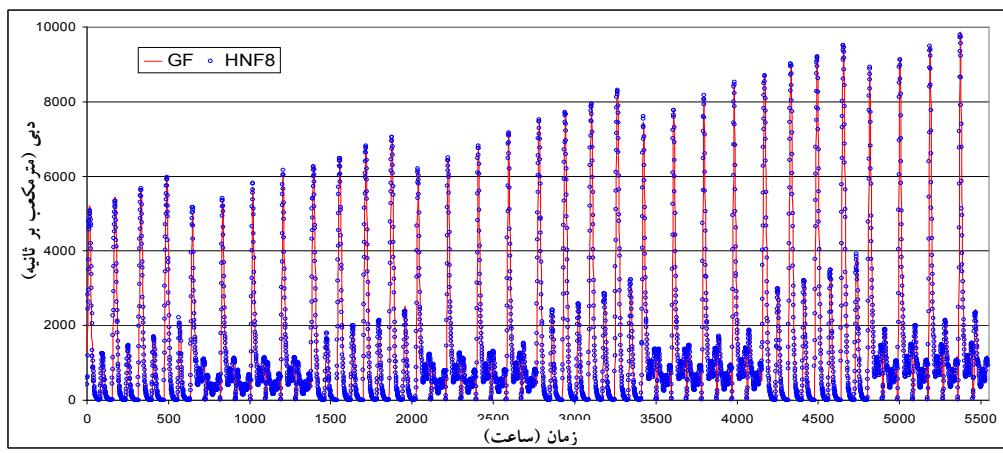
\* فاقد فرمول و نماد



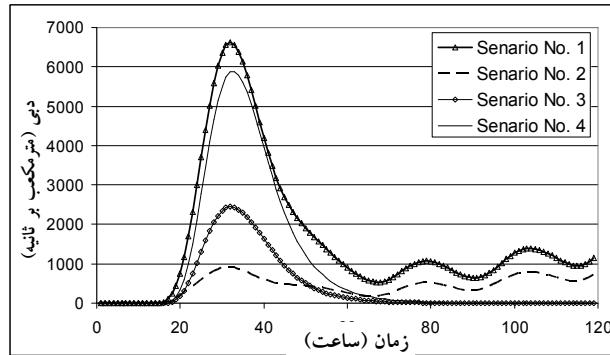
شکل ۵ مقایسه هیدروگراف‌های مشاهده‌ای و مدل NF



شکل ۶ مقایسه هیدروگراف‌های مشاهده‌ای و مدل HNF4



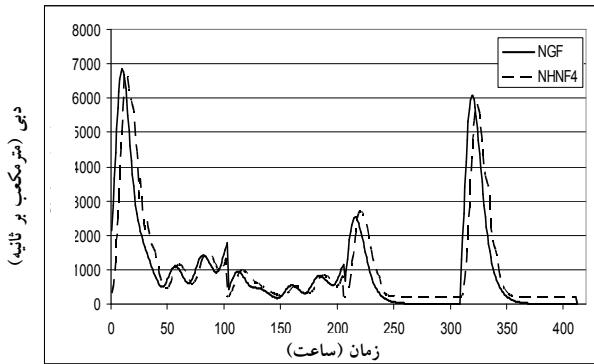
شکل ۷ مقایسه هیدروگراف‌های مشاهده‌ای و مدل HNF8



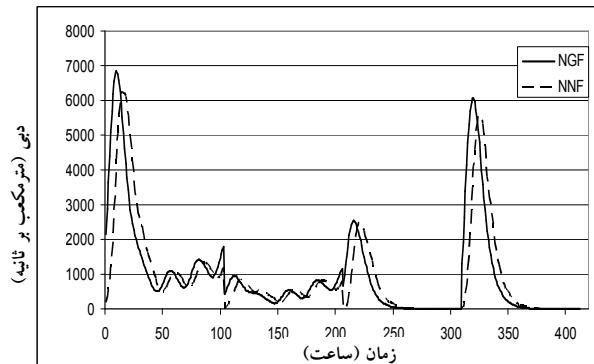
شکل ۸ هیدروگراف‌های تولید شده جدید توسط مدل مفهومی (NGF)

در روابط جدول ۹،  $i$  شماره هیدروگراف،  $n$  تعداد دبی‌های اوج،  $T_p$  زمان دبی اوج (ساعت)،  $Q_p$  دبی اوج (متر مکعب بر ثانیه)،  $\sigma_0$  شاخص مشاهده و  $\sigma_5$  شاخص شبیه‌سازی شده است.

برای مقایسه مدل‌های NNF و NHNF4، 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

ردیف	پارامتر ارزیابی		مقدار پارامتر
	NHNF4	NNF	
۱			AE(Tp)
۲			PE(Tp)
۳	*	*	NE(Tp)
۴	--	--	(NE(Tp)) <sub>max</sub>
۵	۳/۷۵	۵	(AE(Tp))av.
۶	۳/۷۵	۵	(PE(Tp))av.
۷	۱۰۰	۱۰۰	درصد موارد دارای خطای مشت در پیش‌بینی زمان دبی اوج
۸	*	*	درصد موارد دارای خطای منفی در پیش‌بینی زمان دبی اوج
۹	*	*	درصد موارد بدون خطای در پیش‌بینی زمان دبی اوج
۱۰	۶۳۸/۴	۱۳۸۷/۷	AE(Qp)
۱۱	۳۱۵	۲۲/۱	PE(Qp)
۱۲	۳۲۲/۴	۱۳۶۵/۶	NE(Qp)
۱۳	۴۹/۳	۱/۶	%PE(Qp)
۱۴	۵۰/۷	۹۸/۴	%NE(Qp)

دو گروه، در دبی‌های کم و متوسط بسیار خوب است، اما در دبی‌های اوج، این تطابق کمتر شده و دقیق 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 به خوبی یاد گرفته است. بنابراین مدل NF وقایع میانگین را به طور قابل قبولی پیش‌بینی می‌کند، لیکن در پیش‌بینی

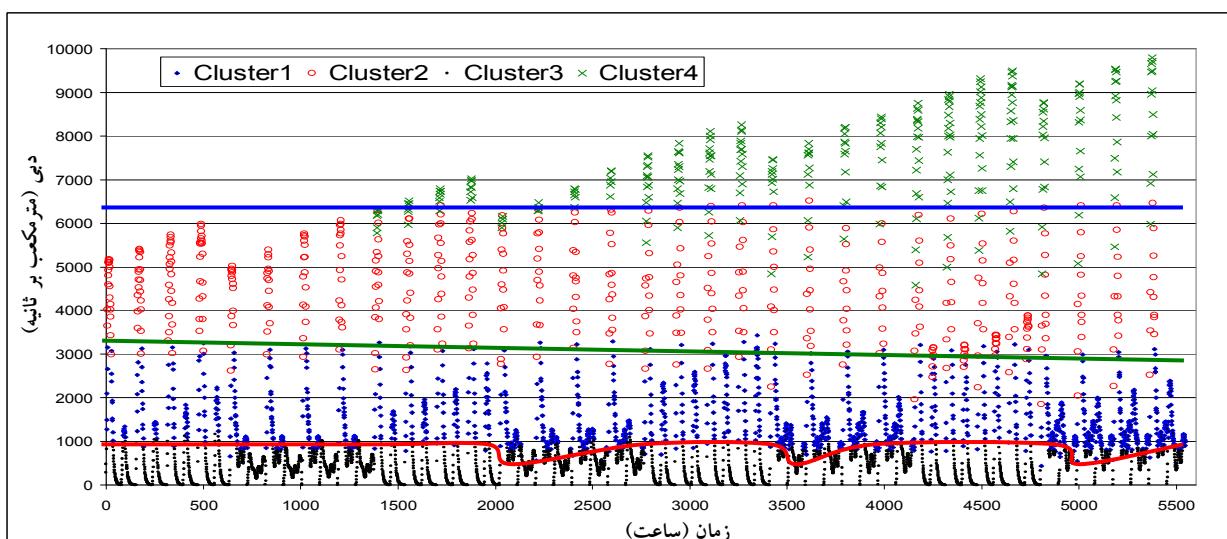
### ۳- نتایج و بحث

با ملاحظه شکل ۳ و جدول ۶ مشاهده می‌شود که شبکه NF به خوبی آموزش دیده و دقیق بالایی دارد. ضرایب برازش ۰/۹۹۵ و ۰/۹۹، به ترتیب در مراحل آموزش و آزمودن، 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

در نتیجه، خروجی نهایی مدل- که برایند 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 HNF 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 فوق العاده‌ای برخوردار است و دقت ناکافی در این موقع می‌تواند خسارهای جبران‌ناپذیری را بهبار آورد.

خوشبندی فضای ورودی شبکه عصبی که به مدل‌های HNF4 و HNF8 منتهی می‌شود، باعث تخصصی 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. همچنان که در شکل ۱۱ مشاهده می‌شود هر شبکه قسمت مشخصی از هیدروگراف‌ها را شبیه‌سازی می‌کند، به‌طوری‌که 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.

به منظور 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. در مدل AE(Tp) در مدل HNF4 به طور متوسط ۱ ساعت و در مدل HNF8 به طور متوسط ۰/۸۷ ساعت است، در حالی که مقدار آن در مدل NF حدود ۲/۳ ساعت است. در جدول ۹ مشاهده می‌شود که (PE(Tp))<sub>av.</sub> در مدل HNF4 جدول ۹ مشاهده می‌شود که در مدل (PE(Tp))<sub>av.</sub> در مدل NF در حدود ۸۵٪ و در مدل HNF8 در حدود ۹۳٪ کاهش یافته به طوری که از متوسط ۱/۶۲۵ ساعت به ترتیب به ۰/۲۳ و ۰/۱۱ ساعت و درصد موارد آن از ۷۲/۸٪ به ترتیب 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<sup>۳</sup> 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 می‌کند در حالی که در مدل NF این درصد برابر صفر است. از طرفی مشاهده می‌شود که (NE(Tp))<sub>max</sub> در مدل‌های HNF4 و

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

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

نکته دیگری که در مقایسه مدل‌های فوق کاملاً مشهود است، کاهش قابل ملاحظه تعداد تکرارها<sup>۱</sup> 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 حالی که در مدل HNF4 در خوش‌شامل‌های 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، به جای انتخاب یک بخش کوچک اما مرتبط از شبکه، تمایل به تغییر دادن تمامی وزن‌ها و آستانه‌های شبکه و یادگیری تمامی اختلافهای مختص فضای ورودی، به روش فرآگیر 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

2. Lead time

1. Epochs

در مدل NF، بیشتر مربوط به دبی‌های اوج هیدرولوگراف‌های کوچکتر بوده و هیدرولوگراف‌های 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 قبل آنها را ندیده‌اند) خطای دارند، لیکن مدل HNF4 تواناتر 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 خطای در مدل HNF4 برابر ۷۵٪ مقدار آن در مدل NNF است. از طرفی مشاهده می‌شود که مقدار خطای در دبی اوج در مدل NNF تقریباً دو برابر مقدار آن در مدل NHNF4 است که تقریباً تمامی آن (۴۸٪) خطای منفی است. این نشان می‌دهد که برآورد مدل NNF، همیشه کمتر از مقدار واقعی است، در حالی که نسبت خطاهای مثبت و منفی در مدل HNF4 تقریباً مساوی است، بنابراین از این نظر هم بر مدل NNF برتری دارد.

#### ۴- نتیجه‌گیری

در این تحقیق با استفاده از هیدرولوگراف‌های سیل تولید شده توسط مدل HEC-HMS، عملکرد مدل‌های شبکه عصبی فرآگیر با شبکه‌های عصبی ترکیبی ارزیابی و مقایسه شده است. بدین منظور هیدرولوگراف‌های 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 PE(Tp) به NE(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، به ویژه دبی اوج نیز از اهمیت فوق العاده‌ای 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 به عکس 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 به موقع شود. بنابراین اگرچه هر دو نوع خطای مضراتی را به‌دبی دارند، اما به‌نظر می‌رسد که خسارت‌های جانی و مالی متنه شود. بنابراین اگرچه هر دو نوع خطای منفی ناشی از خطای منفی، جدی‌تر و بیشتر باشد. مقایسه خطاهای مثبت و منفی در دبی سه مدل نشان می‌دهد که ۶٪ 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 خوشها
$n$	تعداد داده‌ها
$u$	تابع عضویت
$V$	مختصات مرکز خوش
$X$	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 فرآگیر، مدل ۴ شبکه‌ای و مدل ۸ شبکه‌ای) بازسازی شده است. برای اختصاص داده‌های فضای شبیه‌سازی به شبکه‌های مختلف مدل‌های ترکیبی، از تحلیل خوش‌بندی 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 فرآگیر 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 به عنوان 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 خوش‌بندی داده‌های ورودی به شبکه‌ها، به طور اختیاری از ۴ و ۸ خوش‌استفاده شده که احتمالاً تعداد بهینه خوش‌ها نیستند. بنابراین در صورتی که با استفاده از یکی از روش‌های بهینه‌سازی، تعداد بهینه خوش‌ها به دست آید، می‌توان نتایج بهینه‌ای را از نظر میزان اختلاف در مقدار و زمان رخ دادن دبی اوج به دست آورد. از طرفی روش پیدا کردن ساختار شبکه‌ها بر اساس سعی و خطأ، انتخاب ورودی‌های شبکه‌ها بر اساس تجارب شخصی و انتخاب زمان‌های تأخیر داده‌های ورودی بر اساس آزمون‌های آماری استوار بوده و مطمئناً با به کار 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 Engng.*, 9(6), pp. 491-501.