

ارزیابی مدل‌های هوش مصنوعی در تخمین دبی سیلاب

مه‌دی سپهری^{*}، سید عباس عطاپور فرد^۲، علی‌رضا ایلدرومی^۳، حمید نوری^۴، صبا گودرزی^۵، محمد مه‌دی آرتیمانی^۶ و مرتضی سلگی^۷

^۱ و ^۵ کارشناس ارشد آبخیزداری، دانشکده منابع طبیعی، دانشگاه ملایر، ^۲ استادیار، پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران، ^۳ دانشیار، دانشکده منابع طبیعی، دانشگاه ملایر، ^۴ استادیار، دانشکده منابع طبیعی، دانشگاه ملایر و ^۶ و ^۷ کارشناس ارشد، بخش تحقیقات آبخیزداری و منابع طبیعی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان همدان، سازمان تحقیقات، آموزش و ترویج کشاورزی، همدان، ایران

تاریخ پذیرش: ۱۳۹۵/۰۶/۲۳

تاریخ دریافت: ۱۳۹۴/۱۲/۲۶

چکیده

برآورد دبی اوج به‌عنوان یکی از مباحث اصلی در مدیریت منابع آبی و سیلاب نقش اساسی در طراحی سازه‌های آبی و اقدامات بیومکانیکی در حوزه‌های آبخیز دارد، به‌طوری که برآورد صحیح آن نقش اساسی در موفقیت کارهای اجرایی دارد. در این بررسی، سعی شده با استفاده از روش‌های هوش مصنوعی (شبکه عصبی MLP، ترکیب شبکه عصبی MLP و شبکه SOFM، GRNN، ترکیب خوشه‌بندی FCM و ANFIS) دبی بیشینه رودخانه یلفان در محل ایستگاه هیدرومتری برآورد شود. به این منظور، در این دو مدل هشت متغیر که شامل بارندگی مربوط به روز وقوع سیل، بارندگی‌های پنج روز قبل، دبی پایه در روز وقوع سیل و CN حوضه به‌عنوان پارامترهای ورودی و دبی پیک به‌عنوان خروجی در نظر گرفته شده است. سپس، با استفاده از روش هوش مصنوعی و پیش پردازش داده‌ها، ساختار بهینه مدل‌ها با استفاده از داده‌های ورودی و خروجی و با ملاک قراردادن معیارهای ارزیابی، به روش سعی و خطا تعیین شد. نتایج نشان داد که شبکه عصبی پرسپترون چند لایه (MLP) عملکرد بهتری در برآورد دبی سیلاب نسبت به مدل ترکیبی ANFIS+FCM، MLP+SOFM، GRNN در حوضه یلفان دارد.

واژه‌های کلیدی: خوشه‌بندی، دبی اوج، شبکه عصبی، ANFIS، GRNN، MLP، SOFM

مقدمه

(۲۰۰۱). به همین دلیل، محققین سعی بر استفاده از مدل‌ها و روش‌هایی دارند که در عین سادگی، دقت بالایی داشته باشند. به‌طوری که بتوانند با توجه به شرایط عدم قطعیت موجود در طبیعت، یک برآورد با کمینه اختلاف بین نتایج خروجی و داده‌های ورودی داشته باشند. از این‌رو، در دهه‌های اخیر استفاده از روش‌های هوش مصنوعی در بین محققین گسترش زیادی داشته است. این روش‌ها به‌عنوان یک جعبه سیاه مناسب که کمتر در قید و بند مسائل فیزیکی

تخمین دبی اوج یکی از پارامترهای اصلی در طراحی سازه‌های آبی و همچنین، اقدامات بیومکانیکی در حوزه آبخیز می‌باشد، به‌طوری که موفقیت طرح‌های اجرایی به برآورد صحیح بستگی دارد. در این خصوص، می‌توان به مطالعه‌ای که روی شکست بیش از ۳۰۰ سد انجام شده است، اشاره کرد که مشخص شد در حدود ۳۵ درصد از شکست سدها به‌علت تحلیل ناکافی دبی اوج سیلاب بوده است (Seif).

خوشه‌بندی میانگین‌های c فازی خوشه‌بندی و بر روی هر یک از خوشه‌ها، نوعی مدل ANN را برآش دادند. خروجی نهایی مدل آن‌ها، میانگین وزنی خروجی شبکه‌های عصبی کلیه خوشه‌ها بوده است. Noorani و Salehi (۲۰۰۸) به مقایسه تکنیک‌های جدید مدل‌سازی هیدرولوژیکی پرداختند. نتایج حاصل از این تحقیق، بیانگر آن است که روش استنتاج فازی دارای خطای کمتری نسبت به روش شبکه عصبی مصنوعی است. به علاوه در این تحقیق بیان شده است که مدل فازی-عصبی نتایج بهتری از دو روش دیگر ارائه می‌دهد. به طوری که ضریب کارایی سامانه عصبی-فازی، استنتاج فازی و شبکه عصبی مصنوعی به ترتیب ۹۲/۹۷، ۰/۰ و ۰/۸۷ بوده است. Turan و Yurdusev (۲۰۰۹)، با به‌کارگیری تکنیک مدل‌های هوشمند عصبی در تخمین جریان رودخانه، مدل عصبی-فازی را نسبت به دیگر مدل‌های هوشمند عصبی کارا تر دانست. در پژوهش انجام شده Nayak (۲۰۰۴)، در پیش‌بینی دبی رودخانه بایتارانی در ایالت اروسیای هند، روش نورو-فازی^۲ ANFIS عملکرد بهتری نسبت به شبکه عصبی مصنوعی و مدل‌های سری‌های زمانی ARMA داشته است. Pahlavani (۲۰۰۹)، برای مدل‌سازی هوشمند آبنمود سیل ورودی به سد مخزنی شیرین دره در استان خراسان شمالی از مدل‌های شبکه عصبی (ANN) و ANFIS استفاده کرد. نتایج وی حاکی از برتری مدل ANFIS در شبیه‌سازی آبنمود سیل در مقایسه با مدل شبکه عصبی مصنوعی است. Najafi و همکاران (۲۰۰۶) در مقایسه منحنی سنج رسوب با مدل‌های MLP و GRNN^۳ در تخمین رسوبات معلق رودخانه زاینده رود نشان دادند که نتایج حاصل از مدل MLP در مقایسه با روش‌های GRNN و رگرسیون آماری، تطابق بیشتری با مقادیر اندازه‌گیری شده دارد. Ariffin و همکاران (۲۰۰۳) از مدل شبکه عصبی و مدل رگرسیونی خطی برای پیش‌بینی میزان رسوبات استفاده کردند. آن‌ها توانستند بین چهار پارامتر تأثیرگذار بر میزان رسوب و

بوده، قادرند فرایند غیر خطی و غیر ایستای جریان رودخانه را بدون نیاز به مدل‌سازی عامل‌های محیطی و ژئومتری موثر بر جریان رودخانه مدل‌سازی کنند (El-Shafie, ۲۰۰۴). شبکه عصبی مصنوعی^۱ (ANN) یکی از دستاوردهایی است که با الگوبرداری از شبکه مغزی انسان، می‌تواند پدیده‌های پیچیده و ناشناخته را به خوبی بررسی کند (Menhaj, ۲۰۰۱). دیدگاه نوین شبکه عصبی، با افزودن عمل شرط‌گذاری به عنوان قانون آموزش مطرح شد که با پیدایش شبکه پرسپترون تک لایه و قانون یادگیری‌ای با همین نام توسعه یافت. سپس با طرح الگوریتم پس پراکنش (BP) و گسترش ریزپردازنده‌ها، دگرگونی شگرفی در دنیای شبکه عصبی مصنوعی پدید آمد (Menhaj, ۲۰۰۱). از سوی دیگر در منطق فازی با استفاده از استدلال و دانش بشری در قالب ریاضی، سعی در حل عدم قطعیت‌های موجود در طبیعت شده است. با این وجود، مشکل اصلی منطق فازی این است که روند نظام‌مندی برای طراحی یک کنترل‌کننده فازی وجود ندارد. بدین‌منظور، ترکیب این دو روش با نام مدل نورو-فازی قادر است از توانایی‌های هر دو روش در امر مدل‌سازی استفاده کند (Dastorani, ۲۰۰۶). Xiong (۲۰۰۱)، شبکه‌های عصبی مصنوعی را در چند زمینه مرتبط با رواناب و بارش ارزیابی کرده، بر توانایی‌های این تکنیک در برآورد رواناب در حوضه‌های فاقد آمار، پیش‌بینی به‌هنگام سیل، بازسازی داده‌های هیدرولوژیکی و نیز بهینه‌سازی نتایج مدل‌های هیدرودینامیکی به‌وسیله این تکنیک مورد تأکید قرار دادند. Pal (۲۰۰۳) سامانه فازی Takagi-Sugeno مرتبه اول (TS1) برای ترکیب پیش‌بینی‌های پنج مدل مختلف بارش-رواناب استفاده کردند. در این تحقیق مشاهده شده که سامانه فازی TS1 روش ساده و کارآمدی برای بهبود پیش‌بینی سیل است. Wang (۲۰۰۵)، از سه مدل ANN پیوندی با نام‌های شبکه عصبی با مبنای آستانه‌ای، شبکه عصبی با مبنای خوشه‌ای و شبکه عصبی دوره‌ای برای پیش‌بینی جریان روزانه رودخانه استفاده کردند. آن‌ها در مدل CANN خود، ابتدا داده‌ها را با استفاده از روش

² Adaptive Neuro-Fuzzy Inference System (ANFIS)

³ Generalized Regression Neural Networks

¹ Artificial Neural Networks (ANNs)

کرخه، از شرق به بخشی از حوزه آبخیز قره‌چای و از غرب به حوزه آبخیز گاماسیاب منتهی می‌شود. منطقه منتهی به ایستگاه یلفان در محدوده مختصات جغرافیایی $34^{\circ} 34'$ تا $34^{\circ} 45'$ عرض شمالی و $48^{\circ} 48'$ تا $48^{\circ} 42'$ طول شرقی واقع شده است. مساحت این منطقه ۱۸۲ کیلومتر مربع است (شکل ۱). در این پژوهش از آمار ایستگاه یلفان در بالادست سد اکباتان که از شرکت آب منطقه‌ای استان همدان تهیه شده، استفاده شده است که برای این مقاله از ۱۱ سال آمار این ایستگاه تا سال ۱۳۹۱ که شامل بارندگی‌های روزانه، دبی سیلابی، دبی پایه و CN می‌باشد، استفاده شد.

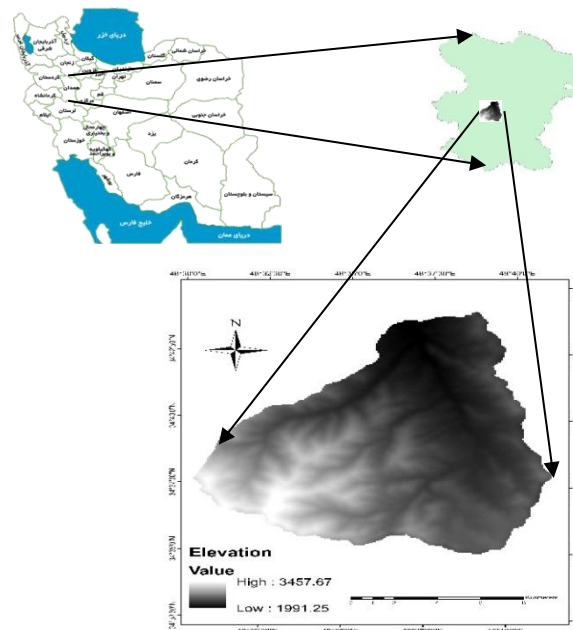
شبکه عصبی مصنوعی: شبکه‌های عصبی از عناصر عملیاتی ساده‌ای ساخته می‌شوند که به صورت موازی در کنار هم عمل می‌کنند. این عناصر از سامانه‌های عصبی زیستی الهام گرفته شده‌اند (Kia, ۲۰۱۲). در طبیعت، عملکرد شبکه‌های عصبی از طریق نحوه اتصال بین اجزا تعیین می‌شود. بنابراین، می‌توان یک ساختار مصنوعی به تبعیت از شبکه‌های طبیعی ساخت و با تنظیم مقادیر هر اتصال، تحت عنوان وزن اتصال، نحوه ارتباط بین اجزای آن را تعیین کرد (Kia, ۲۰۱۲).

غلظت رسوبات با استفاده از دو روش مذکور روابطی برقرار کنند.

در این تحقیق، سعی شده است با توجه به اهمیت حوزه یلفان به دلیل وجود آمار مناسب، سیلاب‌های مخرب فراوان موثر بر خاک و پوشش گیاهان مرتعی و نیز وجود سازه‌های آبی و عملیات بیومکانیکی آبخیزداری طی سال‌های گذشته، با استفاده از دو روش اصلی در هوش مصنوعی (مدل شبکه عصبی پرسپترون چند لایه (MLP)، مدل ترکیب خوشه‌بندی FCM و نوروفازی ANFIS، ترکیب MLP و SOFM و GRNN) که تاکنون در مطالعات مختلف کشورهای مختلف جهان به عنوان روش‌های مطلوب هوش مصنوعی در هیدرولوژی معرفی شده‌اند، دبی پیشینه رودخانه یلفان، یکی از زیر حوضه‌های سد اکباتان در غرب کشور برآورد و مقایسه شد.

روش تحقیق

منطقه مورد پژوهش: منطقه مورد مطالعه در این مقاله، رودخانه یلفان در محل ایستگاه هیدرومتری و رسوب‌سنجی یلفان می‌باشد. این حوزه آبخیز یکی از زیرحوضه‌های سد اکباتان و حوزه آبخیز سد اکباتان نیز زیرحوضه سد ورفقان (ساوه) است که از شمال به حوزه آبخیز قره‌چای، از جنوب به حوزه آبخیز سد



شکل ۱- منطقه مورد مطالعه

میزان خطای پیش‌بینی شده به خروجی مورد نظر نزدیک شود. در مقابل، در یادگیری بدون نظارت تنها نمونه‌هایی از مقادیر ورودی موجودند و تنظیم وزن‌ها تنها بر اساس مقادیر ورودی صورت می‌گیرد. از روش‌های یادگیری بدون نظارت بیشتر در مسائل طبقه‌بندی و بهینه‌سازی مورد استفاده قرار می‌گیرد. یکی از متداول‌ترین نوع شبکه‌های عصبی در دسته دوم، شبکه عصبی نگاشت خود سامانده (قاعده یادگیری کوهنن) است. نگاشت‌های ویژه خود سازمان یاد می‌گیرند تا علاوه بر توزیع بردارهای ورودی به دسته‌هایی از فضای ورودی، قسمت‌های همسایه از فضای ورودی را تشخیص دهند. بنابراین، شبکه‌های مذکور علاوه بر توزیع بردارهای ورودی، توپولوژی (تورانه‌ای، شش‌گوشه‌ای و تصادفی) آن‌ها را نیز یاد می‌گیرند (Kia, 2012). وقتی نمونه آموزشی جدید به شبکه اعمال می‌شود، فاصله اقلیدسی آن از بردار وزن تمام نرون‌ها (خوشه‌ها) شبکه حساب می‌شود. نرونی که بردار وزنش بیشترین شباهت را با بردار ورودی داشته باشد، برنده است. این نرون بهترین واحد تطبیق شده نامیده می‌شود (BMU¹). بردار وزن نرون برنده و همسایه‌هایش در شبکه کوهنن در راستای نزدیک شدن به بردار ورودی تغییر می‌کنند. میزان تغییرات بر اساس زمان و فاصله از BMU کاهش می‌یابد. وزن‌های هر نرون مطابق معادله (۳) به روزرسانی می‌شوند.

$$W_i(t+1) = W_i(t) + \theta(v,t)\alpha(t)(X(t) - W_i(t)) \quad (3)$$

که در آن، $\alpha(t)$ نرخ یادگیری کاهشی و $X(t)$ بردار ورودی می‌باشد. تابع همسایگی بستگی $\theta(v,t)$ وابسته به فاصله بین نرون i و BMU در شبکه است. همچنین، شعاع همسایگی و نرخ یادگیری در طول زمان به وسیله معادله‌های (۴) و (۵) کاهش می‌یابند.

$$\alpha(t) = \alpha_0 \exp(-t/\lambda), \quad t=1,2,3,\dots \quad (4)$$

که در آن، t شماره تکرار و λ مقدار ثابت و α_0 نرخ یادگیری اولیه می‌باشد.

$$\theta(t) = \exp(-dist^2 / 2\sigma^2(t)) \quad (5)$$

تعیین نوع شبکه عصبی: بر اساس پژوهش‌های انجام شده Braddock (۱۹۹۸) و ASCE Task Committee (۲۰۰۰)، ۹۰ درصد شبکه‌های عصبی مصنوعی که در مسائل آب‌شناختی مورد استفاده قرار گرفته‌اند، از نوع الگوریتم پس‌پراکنش (BP) هستند. در این شبکه هر نرون با کلیه نرون‌های لایه بعد در ارتباط می‌باشد کلیه ارتباطات به سمت جلو بوده و هیچ‌گونه ارتباط برگشتی وجود ندارد. این شبکه‌ها یکی از عمومی‌ترین و پرکاربردترین مدل‌ها می‌باشند (Mysaghi, 2002). از جمله ساختارهای مهم شبکه‌های عصبی، پرسپترون چندلایه است که کاربرد زیادی دارد و به خوبی قادر به تقریب توابع دلخواه می‌باشد (Kasi, 2005). در بررسی سامانه‌های پویای غیر خطی و دیگر مسائل تقریب تابع از اهمیت زیادی برخوردار است. به طور معمول پرسپترون‌های چند لایه با الگوریتم پس انتشار آموزش داده می‌شوند. پرسپترون چندلایه با قانون تصحیح خطا آموزش می‌بیند، پس نیاز به خروجی مشخص می‌باشد. از پاسخ سامانه $di(n)$ در واحد پردازشگر PE_i و تکرار n پاسخ مدنظر $di(n)$ با توجه به الگوی ورودی داده شده، خطا در هر تکرار $ei(n)$ به صورت زیر تعریف می‌شود.

$$ei(n) = di(n) - yi(n) \quad (1)$$

با توجه به نظریه یادگیری کاهش شیب هر وزن شبکه با توجه به مقادیر موجود وزن و نسبت ورودی به خطا تطبیق پیدا می‌کند:

$$wij(n+) = Wij(n) + \eta \theta ei(n) xj(n) \quad (2)$$

در رابطه فوق خطای موضعی می‌تواند به طور مستقیم از $ei(n)$ در خروجی واحد پردازشگر و یا مجموع وزنی خطاها در بین واحدهای پردازشگر محاسبه شود. ثابت η مبین اندازه گام می‌باشد. این روش الگوریتم پس‌پراکنش نامیده می‌شود.

شبکه عصبی نگاشت خود سامانده (SOFM): شبکه‌های عصبی را بر اساس الگوریتم یادگیری به دو دسته یادگیری نظارت شده و یادگیری بدون نظارت تقسیم‌بندی می‌کنند. در یادگیری با نظارت نمونه‌هایی از مقادیر ورودی و خروجی مورد نظر به عنوان الگوی آموزشی انتخاب می‌شوند و در روند یادگیری، وزن‌های ارتباطی شبکه به گونه‌ای تنظیم می‌شوند تا خروجی با

¹ Best Matching Unit

$$O_{i,1} = \mu_{Ai}(x), i=1,2, \quad (7)$$

$$O_{i,1} = \mu_{Bi} - 1(y), i=3,4, \quad (8)$$

که در آن‌ها، x و y ورودی گره I است و $A_i(B_i-2)$ مجموعه فازی مرتبط با این گره می‌باشد. همچنین، I, O درجه عضویت مجموعه فازی است. توابع عضویت می‌توانند به شکل زنگوله‌ای، مثلثی و دوزنقه‌ای نمایش داده شوند. توابع زنگوله‌ای شکل با توجه به مجموعه-های عضویت به صورت زیر برآورد می‌شوند.

$$\mu_{Ai}(x) = \frac{1}{1 + \frac{x - c_i}{a_i}; 2b_i} \quad (9)$$

که در آن، a, b و c پارامترهای مورد استفاده در مدل بوده، در آن بیشینه مقادیر یک و کمینه آن صفر در نظر گرفته شده است.

لایه ۲: هر گره در این لایه درجه فعالیت یک قانون را محاسبه می‌کند.

$$O_{2,i} = W_i = \mu_{Ai}(x) \mu_{Bi}(y), i=1,2 \quad (10)$$

لایه ۳: در این لایه W امین گره، نسبت درجه فعالیت قانون W را به مجموع درجه فعالیت کلیه قوانین به صورت زیر نرمال سازی می‌کند.

$$O_{3,1} = \frac{W_i}{W_1 + W_2}, i=1,2 \quad (11)$$

لایه ۴: در این لایه خروجی هر گره برابر است با:

$$O_{4,1} = \frac{W_i}{W_1 + W_2} f_i = \frac{W_i}{W_1 + W_2} (P_i X + Q_i Y + R_i), \quad (12)$$

لایه ۵: در این لایه هر گره مقدار خروجی نهایی را به صورت زیر محاسبه می‌کند (تعداد گره‌ها برابر تعداد خروجی‌هاست).

$$O_{5,i} = \sum \frac{W_i}{W_1 + W_2} f_i \quad (13)$$

الگوریتم خوشه‌بندی Fuzzy C-Mean (FCM): یک الگوریتم بازبینی نشده خوشه‌بندی بر اساس مجموعه تئوری fuzzy است که اجازه می‌دهد یک عامل متعلق به بیش از یک خوشه باشد. درجه ارتباط هر آیتم داده با خوشه، محاسبه شده، تصمیم می‌گیرد که کدام خوشه با کدام آیتم داده وابسته شود. برای هر آیتم، یک عامل مشترک وجود دارد که مشخصه‌های درجه عضویت (u_{ij}) از بودن در خوشه K th به صورت معده (۱۴) است.

$$u_{ij} = \sum_{k=1}^n \left(\frac{d_{ik}}{d_{ik}} \right)^{2(m-1)} \quad (14)$$

که در آن، d_{ij} فاصله آیتم i th از خوشه j th است.

که در آن، $dist$ فاصله نرون از BMU و $\sigma(t)$ با استفاده از معادله (۶) محاسبه می‌شود.

$$\sigma(t) = \sigma_0 \exp(-t/\lambda), t=1,2,3,\dots \quad (6)$$

که در آن، σ_0 عرض شبکه در زمان t_0 و λ مقدار ثابت و t شماره تکرار جاری است (Soltani, ۲۰۰۹). خروجی حاصل از شبکه عصبی نگاشت خودسامانده می‌تواند به عنوان ورودی برای سایر شبکه‌های عصبی با الگوریتم یادگیری نظارت شده وارد شود. در واقع کار شبکه عصبی نگاشت خود سامانده کاهش تعداد بردارهای ورودی با شرط رعایت نگهداری ساختار اساسی داده‌های ورودی است.

سامانه استنتاج تطبیقی عصبی- فازی: شبکه- های عصبی مصنوعی با الگوبرداری از سامانه کارکرد مغز انسان، با پردازش داده‌های تجربی و بدون توجه به فیزیک مسئله، قانون نهفته در ورای این اطلاعات را استخراج می‌کنند. در مقایسه با مدل‌های مرسوم، این مدل‌ها به ورودی‌های کمتر و تلاش محاسباتی اندکی نیاز دارند. سامانه فازی یک سامانه مبتنی بر قواعد منطقی "شرط-نتیجه" است که با استفاده از مفهوم متغیرهای زبانی و روند تصمیم‌گیری فازی، فضای متغیرهای ورودی را بر فضای متغیرهای خروجی تصویر می‌کند. ترکیب سامانه‌های فازی که مبتنی بر قواعد منطقی بوده و روش شبکه‌های عصبی مصنوعی که توان استخراج دانش از اطلاعات عددی را دارند، منجر به ارائه سامانه استنتاج تطبیقی عصبی-فازی شده است.

۱- معمولا در مدل ANFIS دو ورودی x و y

خروجی z در نظر گرفته می‌شود. در مدل فازی،

قوانین اگر آن‌گاه به صورت زیر بیان می‌شود.

$$1. \text{ If } x \text{ is } A_1 \text{ and } y \text{ is } B_1, \text{ then } f_1 = p_1 x + q_1 y + r_1,$$

$$2. \text{ If } x \text{ is } A_2 \text{ and } y \text{ is } B_2, \text{ then } f_2 = p_2 x + q_2 y + r_2,$$

که در آن، A_1, A_2, B_1, B_2 توابع عضویت ورودی‌های x و y است و p_1, q_1, r_1 و p_2, q_2, r_2 پارامترهای توابع خروجی هستند. توابع مدل ANFIS به صورت زیر است. مدل مذکور که از پنج لایه تشکیل شده، به شکل زیر تبیین می‌شود.

لایه ۱: هر گره (node) در این لایه، نشان‌دهنده درجه عضویت پارامترهای ورودی است.

که در آن، Y مقدار پیش‌بینی به‌وسیله شبکه، X بردار مشاهدات سری زمانی (X_1, X_2, \dots, X_m) ، $E(Y/X)$ امید ریاضی خروجی Y به شرط بردار مشاهدات X و $f(Y, X)$ تابع چگالی احتمال توأم Y و X است. این شبکه یک شبکه چهار لایه است. در هر لایه قسمتی از محاسبات مربوط به رگرسیون غیر خطی انجام می‌شود. لایه اول به‌عنوان لایه ورودی، صرفاً مسئول دریافت داده‌های بردار ورودی X می‌باشد. در این لایه برای هر درایه بردار ورودی X یک نرون وجود دارد و تعداد نرون‌های لایه دوم برابر با تعداد داده‌های آموزشی است. به این نرون‌ها، نرون‌های الگو نیز اطلاق می‌شود. در واقع کار این نرون‌ها به‌خاطر سپردن رابطه میان ورودی، خروجی‌های آموزشی می‌باشد. چنانچه از تابع گاوس چند متغیره به‌عنوان تابع هسته در رگرسیون استفاده شود، می‌توان عملکرد نرون‌های این لایه را به شکل زیر نوشت.

$$a_i = \exp\left(-\frac{\|X - X_i\|^2}{2\sigma^2}\right) \quad i = 1, 2, \dots, N \quad (16)$$

که در آن، a_i خروجی نرون i ام به ازای بردار ورودی X می‌باشد و X_i مرکز نرون i ام است. در فرمول فوق σ پارامتر هموار کننده نام دارد. در واقع شکل توابع هسته لایه دوم به‌وسیله این پارامتر تعیین می‌شود. در این حالت مقدار پیش‌بینی شبکه GRNN برای بردار ورودی X برابر خواهد شد با:

$$y^{\wedge} = \frac{\sum_{i=1}^N y_i \exp\left(-\frac{\|X - X_i\|^2}{2\sigma^2}\right)}{\sum_{i=1}^N \exp\left(-\frac{\|X - X_i\|^2}{2\sigma^2}\right)} \quad (17)$$

به‌عبارت دیگر، خروجی شبکه GRNN برابر با میانگین وزن دار مشاهدات، Y_i در اطراف بردار ورودی X می‌باشد. بنابراین، در لایه سوم شبکه میانگین وزن دار مشاهدات محاسبه می‌شود و پایه چهارم نیز لایه خروجی شبکه می‌باشد. برای استفاده از این شبکه، در ابتدا به بررسی نرمال بودن داده‌های بارندگی (واریانس پایین در سایر داده‌ها) پرداخته شد (Kia, 2012، جدول ۱).

فاصله آیتم i th از خوشه k th و m عامل نادقیق سازی است. وجود یک آیتم داده در بیش از یک خوشه وابسته به مقدار m یعنی نادقیق‌سازی تعریف شده به‌وسیله کاربر در حد $[0,1]$ است که درجه نادقیقی را در خوشه تعیین می‌کند. بدین ترتیب، آیتم‌های روی گوشه یک خوشه ممکن است، در خوشه‌ای با درجه کمتر از آیتم‌ها در مرکز خوشه باشد. وقتی m به مقدار یک برسد، الگوریتم شبیه یک الگوریتم قسمت‌بندی حلقوی کار می‌کند و برای مقادیر بزرگ‌تر از m خوشه‌های متمایل به بیشتر بودن به اشتراک گذاشته می‌شوند. هدف اصلی الگوریتم خوشه‌بندی fuzzy قسمت‌بندی داده درون خوشه‌هاست به‌طوری که تشابه آیتم‌های داده درون هر خوشه افزایش یافته، تشابه آیتم‌های داده در خوشه‌های مختلف کم می‌شود. به‌علاوه، این خوشه‌بندی، کیفیت قسمت‌بندی را طوری اندازه‌گیری می‌کند که یک مجموعه داده درون خوشه‌های C تقسیم شوند. الگوریتم FCM به کاهش میزان عملکرد عینی به شرح $J(U, V) = \sum_{i=1}^n \sum_{j=1}^c (u_{ij})^m \cdot \|x_i - v_j\|^2$ توجه می‌کند که در آن، m هر شماره واقعی بیش از یک باشد، u_{ij} درجه ارتباط x_i در خوشه j -th از داده اندازه‌گیری شده ابعادی، v_j فاصله مرکز ابعاد از خوشه و $\|x_i - v_j\|^2$ هر مقیاس که بیان کننده تشابه بین هر داده اندازه‌گیری شده و مرکز است.

شبکه عصبی رگرسیون عمومی (GRNN): این مدل در سال ۱۹۹۱ به‌وسیله Specht به‌عنوان ابزاری مطرح شد که توانایی تخمین هر تابع دلخواه را با استفاده از داده‌های گذشته دارد. ساختار شبکه GRNN بر پایه اصول تئوری رگرسیون هسته بنا شده است. از این دیدگاه، این شبکه معادل یک رابطه رگرسیون غیر خطی به فرم زیر است.

$$E(Y|X) = \frac{\int_{-\infty}^{+\infty} y f_{X,Y}(X,Y) dy}{f_X(X)} \quad (18)$$

جدول ۱- نتایج آماری دوره آزمون به وسیله شبکه عصبی

پارامتر	ورودی	نوع شبکه	آرایش	تابع محرک	روش آموزش	R2	RMSE
QP	Rt,Rt-1,Rt-2,Rt-3,Rt-4,Rt-5,CN,QB	MLP	۱-۵۰-۵۰-۵۰-۵۰-۵۰	Tanh	Momentum	۵۲	۳/۷۱

می‌باشد. لازم به ذکر است که برخی از داده‌های ورودی دارای مقادیر بسیار بزرگی هستند مشکلاتی در روال آموزش شبکه‌های عصبی ایجاد می‌شود. زیرا این اعداد در اصلاح وزن‌ها تأثیر زیادی گذاشته و در نتیجه تعداد زیادی داده دیگر نیاز است تا با تعدیل این داده نتیجه مطلوب را حاصل نمایند. بنابراین، نیاز به یک تابع تعدیل‌شده برای اصلاح وزن‌ها می‌باشد تا این مشکل از بین برود (Kia, ۲۰۱۲). بنابراین، در این مقاله با استفاده از رابطه (۱۸) داده‌های مورد استفاده چه در قسمت ورودی و چه در قسمت خروجی نرمال‌سازی کرده، از این داده‌ها به جای داده‌های خام اولیه استفاده شد و در نهایت پس از اجرای مدل‌ها، داده‌ها به‌صورت آنتی نرمال درآورده شدند.

$$X_n = a \left(\frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \right) + b \quad (18)$$

که در آن، X_n مقدار نرمال‌شده داده‌ها، X_{\min} و X_{\max} به‌ترتیب مربوط به مقادیر کمینه و بیشینه داده‌ها در قسمت آموزش و آزمون مدل، X_i مقادیر مشاهده شده داده‌ها است. ضرایب a و b مقادیر مختلفی می‌توانند اختیار کنند و قانون ثابتی که در شرایط خاص، چه شیوه استاندارد باید استفاده شود، وجود ندارد. در این تحقیق، ضرایب a و b به‌ترتیب برابر با $0/6$ و $0/2$ هستند (Altun و همکاران، ۲۰۰۸). **معیار ارزیابی:** در ارزیابی و مقایسه نتایج به‌دست آمده از روش‌ها و مدل‌های مختلف به‌کار برده شده در این تحقیق برای برآورد دبی بیشینه از معیار آماری ریشه میانگین مربعات خطا ($RMSE^1$) رابطه (۱۹) و ضریب همبستگی (R^2) رابطه (۲۰) که معیاری برای بیان میزان پراکندگی خطای حاصل از برآورد مدل محسوب می‌شود (Isaaks و Srivastava، ۲۰۰۸) استفاده شده است.

در این تحقیق، علاوه بر شاخص ضریب همبستگی و معیار آماری ریشه میانگین مربعات خطا، از معیار آماری آزمون t-test در خصوص داده‌های بارندگی با توجه به واریانس بالایی که بین مقادیر بارندگی وجود داشت، استفاده شد. معنی‌داری و عدم معنی‌داری اختلاف بین داده‌های مشاهداتی و شبیه‌سازی شده را می‌توان با آزمون t-test تشخیص داد. در این آزمون

الگوریتم خوشه‌بندی K-means: این الگوریتم مجموعه‌ای از N بردار ورودی را در M دسته از طریق روش تکرار، گروه‌بندی می‌کند. در ابتدا مرکز M دسته $W(m)$ تعیین می‌شوند. برای دسته‌بندی بردارهای ورودی، در صورتی که $d(X(n), W(m))$ که فاصله بردار ورودی n ام از مرکز دسته m ام است، نسبت به فاصله $X(n)$ از مراکز دسته‌های دیگر کمتر باشد، این بردار به دسته m تعلق می‌گیرد. سپس مراکز دسته‌ها، از طریق متوسط‌گیری روی بردارهای قرار گرفته در هر خوشه، محاسبه مجدد می‌شوند. این روش برای تمام بردارهای بار ورودی و به‌صورت تکراری، تا به تعادل رسیدن مراکز دسته‌ها ادامه می‌یابد.

انتخاب داده‌ها: اولین گام در طراحی شبکه‌های عصبی انتخاب داده‌های ورودی می‌باشد. به‌طور کلی، دو نوع داده را می‌توان به‌عنوان داده‌های ورودی به شبکه عصبی مورد استفاده قرار داد که شامل داده‌های صرفاً آماری که مربوط به مشاهدات بارندگی در طول زمان با درجه تفکیک مشخص مانند داده‌های ساعتی، روزانه یا ماهانه است. نوع دوم داده‌های ورودی شامل نوع اول به‌علاوه داده‌های فیزیکی حوزه آبخیز است که در رابطه بارندگی-رواناب نقش دارند. مانند رطوبت خاک، ضریب نفوذپذیری، تبخیر-تعرق، آب زیرزمینی و ... هستند (Chen و Adams، ۲۰۰۶؛ Ahmad و Simonovic، ۲۰۰۵). در این تحقیق، از داده‌های نوع اول که شامل بارندگی‌های مربوط به روز وقوع دبی پیک، بارندگی‌های پنج روز قبل، دبی پایه در روز وقوع دبی پیک و داده‌ی مربوط به CN (معرف خصوصیات نفوذپذیری منطقه است)، حوضه که به‌عنوان داده‌های ورودی به مدل و مقادیر دبی پیک نیز که به‌عنوان خروجی به مدل معرفی شده‌اند از شرکت آب منطقه‌ای استان همدان تهیه شده است. در خصوص انتخاب روش برای مجزا کردن دبی پایه از هیدروگراف بستگی به داده‌های موجود و دقت مورد نظر دارد. با این وجود، در بیشتر کارهای هیدرولوژی دبی پایه مقدار ثابتی در نظر گرفته می‌شود، که در این روش برای جداکردن دبی پایه در هیدروگراف رودخانه از نقطه‌ای که سیل شروع می‌شود یک خط مستقیم به نقطه‌ای که سیل خاتمه پیدا می‌کند، رسم می‌کنند و مقدار این خط مستقیم همان دبی پایه

¹ Root Mean Square Error (RMSE)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{Si} - X_{Ai})^2}{n}} \quad (19)$$

$$R^2 = \frac{\left[n \sum_{i=1}^n (X_{Si} X_{Ai}) - \left(\sum_{i=1}^n X_{Si} \times \sum_{i=1}^n X_{Ai} \right) \right]^2}{\left[n \sum_{i=1}^n X_{Ai}^2 - \left(\sum_{i=1}^n X_{Ai} \right)^2 \right] \times \left[n \sum_{i=1}^n X_{Si}^2 - \left(\sum_{i=1}^n X_{Si} \right)^2 \right]} \quad (20)$$

اگر مقدار آماره t بیشتر از سطح معنی‌دار باشد، اختلاف معنی‌داری بین مقادیر مشاهداتی و محاسباتی دیده نمی‌شود و اگر مقدار آماره t کمتر از سطح معنی‌دار باشد، اختلاف معنی‌داری بین مقادیر مشاهداتی و محاسباتی دیده می‌شود (جدول ۲).

جدول ۲- معیار آماری آزمون t-test

Sig. (2-tailed)	df	t	Paired Differences						
			95% Confidence Interval of the Difference		Std. Error Mean	Std. Deviation	Mean		
			Upper	Lower					
۰/۰۰۱	۱۰	۴/۳۷۲	۱۸/۵۲۶۹۸	۶/۰۱۸۴۷	۲/۸۰۶۹۴	۹/۳۰۹۵۷	۱۲/۲۷۲۷۳	داده‌های آزمون داده‌های آموزشی	Pair 1

نتایج و بحث

ساختار شبکه عصبی مصنوعی: ساختار شبکه که می‌توان آن را تحت عنوان معماری شبکه مطرح کرد، بر اساس انتخاب نوع شبکه، توابع یادگیری و تعداد لایه‌ها همراه با تعداد نرون‌ها (گره‌ها) مشخص می‌شود (Borhani Dariyan و Fatehi، ۲۰۰۸). در واقع معماری شبکه است که نحوه جریان داده‌های ورودی را برای رسیدن به خروجی مطلوب تعیین می‌کند (Borhani Dariyan و Fatehi، ۲۰۰۸). در این تحقیق، با استفاده از بررسی‌های انجام شده در این زمینه و سعی و خطای فراوان و با در نظر گرفتن معیارهای ارزیابی، بهترین ساختار شبکه عصبی را برای برآورد دبی پیک به دست آورده که نتایج آن در جدول ۲ نشان داده شده است.

ترکیب روش خوشه‌بندی FCM و مدل ANFIS: در مدل ANFIS برای ایجاد ساختار استنتاج فازی از دو روش تفکیک شبکه‌ای و تفکیک خوشه‌ای جهت طبقه‌بندی داده‌های حوضه یلغان استفاده شد. در تفکیک شبکه‌ای، داده‌های ورودی به چند قسمت مساوی تقسیم شد که در این حالت با افزایش تعداد تقسیمات، تعداد عامل‌ها به طور توانی افزایش پیدا نمود. در این بررسی از ساختار خوشه‌بندی در ایجاد سامانه استنتاج فازی استفاده و خوشه‌بندی داده‌های عددی، پایه و اساس بسیاری از الگوریتم‌های طبقه‌بندی و مدل‌سازی سامانه قرار گرفت که هدف از این

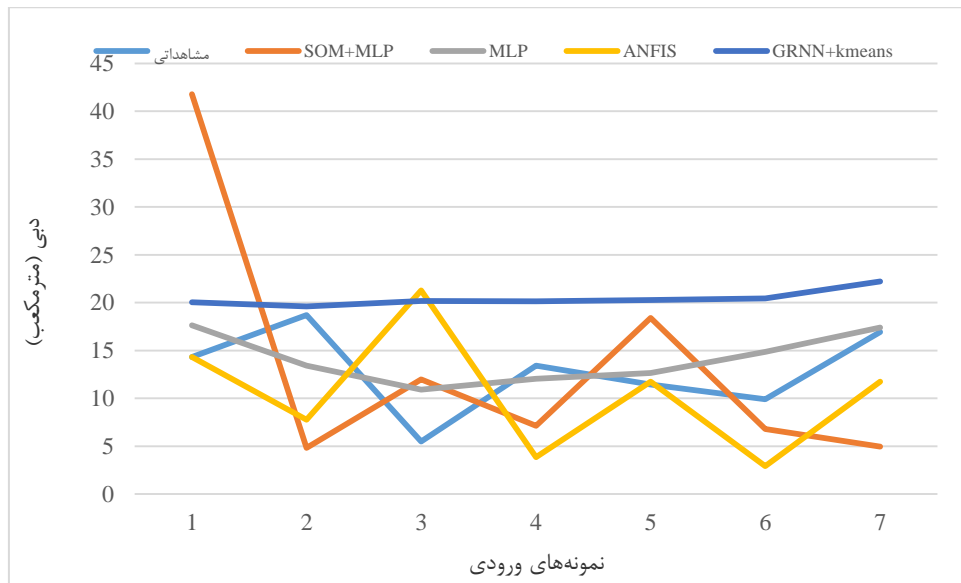
خوشه‌بندی گروه‌بندی مجموعه داده‌های بزرگ و فراهم آوردن یک نمایش ساده و مختصر از رفتار سامانه بود (Kia، ۲۰۱۲). با استفاده از خوشه‌بندی FCM خوشه‌بندی داده‌ها و یک الگوریتم سریع برای تخمین تعداد خوشه‌ها و مرکز آن‌ها تهیه شد، به طوری که خوشه‌های تخمین زده شده به عنوان مقدار اولیه در روش‌های خوشه‌بندی تکراری و روش‌های تشخیص مدل (مثل ANFIS) به کار گرفته شد (Kia، ۲۰۱۲). سپس در خوشه‌بندی تفاضلی پارامتر شعاع خوشه تعیین شد و برد موثر یک خوشه در فضای داده‌ها محاسبه شد به طوری که انتخاب یک شعاع کوچک معمولاً منجر به ایجاد تعداد زیادی خوشه کوچک و در نتیجه تعداد زیادی قواعد می‌شود، در عین حال انتخاب یک مقدار بزرگ به عنوان شعاع خوشه منجر به تولید خوشه‌های کمتر و بزرگ‌تر و در نتیجه قواعد کمتر می‌شود (Kia، ۲۰۱۲). یکی از پارامترهای موثر در تعیین مقدار عددی شعاع خوشه‌ها مربوط به تعداد زیاد پارامترهای ورودی است به طوری که مدل خوشه‌بندی حاصله از مقدار عددی شعاع مربوطه بایستی دست کم دارای دو قاعده در جهت قسمت آموزش مدل ANFIS به منظور تولید ساختار استنتاج فازی باشد. لذا، برای تعیین شعاع انتخابی با استفاده از سعی و خطا، مدل‌های خوشه‌بندی که تعداد قوانین آن بیشتر از دو مورد بود انتخاب شد که در این بررسی دامنه شعاع انتخابی در مقدار عددی زیر ۰/۵ قرار

مدل برای پیش‌بینی مقادیر دبی پیک در نظر گرفته شد که نتایج آن در جدول ۳ و شکل ۲ نشان داده شده است.

داشت. سپس در مرحله بعدی هر یک از مدل‌های خوشه‌بندی فوق به مدل ANFIS معرفی شدند و در این مرحله با در نظر گرفتن معیار RMSE بهترین

جدول ۳- نتایج آماری دوره آزمون به‌وسیله ترکیب شبکه عصبی MLP و نگاشت خود سازمانده

پارامتر	ورودی	نوع شبکه	آرایش	ابعاد نرون	تابع محرک	توپولوژی نرون‌ها	روش آموزش	R ²	RMSE
QP	R _t , R _{t-1} , R _{t-2} , R _{t-3} , R _{t-4} , R _{t-5} , CN, Q _B	MLP	-۱-۵۰-۵۰-۵۰-۸	۵×۵	Tanh	شش ضلعی	Momentum	۱۷	۱۳/۲۵



شکل ۲- مقادیر مشاهداتی و دبی برآوردی با استفاده از مدل‌های مختلف

کننده‌ای) بسته به میزان جزئی‌نگری در تحلیل دارد و به‌وسیله پژوهشگر تعیین می‌شود (Zamani, ۲۰۰۹). در این تحقیق، با استفاده از بررسی‌های انجام شده در این زمینه و سعی و خطای فراوان و با در نظر گرفتن معیارهای ارزیابی، بهترین ساختار شبکه عصبی را برای برآورد دبی پیک به‌دست آورده که نتایج آن در جداول ۴ و ۵ نشان داده شده است.

ساختار ترکیب شبکه عصبی نگاشت خود سازمانده و شبکه پرسپترون چند لایه: از ویژگی‌های برجسته روش SOFM خوشه‌بندی و تجسم (Visualization) هم‌زمان خوشه‌ها همراه با حفظ مکان‌شناسی است. در عین داشتن این ویژگی‌های بارز، تعداد خوشه‌های به‌دست آمده از داده‌های ورودی به‌وسیله SOFM (نیز مانند هر الگوریتم رده‌بندی

جدول ۴- نتایج آماری دوره آزمون به‌وسیله تلفیق مدل خوشه‌بندی و ANFIS

پارامتر	ورودی	شعاع خوشه‌بندی	نوع تابع عضویت ورودی	نوع تابع عضویت خروجی	R ²	RMSE
QP	R _t , R _{t-1} , R _{t-2} , R _{t-3} , R _{t-4} , R _{t-5} , CN, Q _B	۰/۱	مثلی	ثابت	۱۷/۳۸	۸/۷۵

جدول ۵- نتایج آماری دوره آزمون به‌وسیله ترکیب شبکه عصبی GRNN و K_means

پارامتر	ورودی	نوع شبکه	تابع محرک خروجی	تابع محرک ورودی	روش آموزش	R ²	RMSE
QP	R _t , R _{t-1} , R _{t-2} , R _{t-3} , R _{t-4} , R _{t-5} , CN, Q _B	GRNN	Tanh	گائوسین (نرمال)	Momentum	۱۷	۸/۵۷

مدل‌ها به‌عنوان مدل‌های رایج در مطالعات هیدرولوژی و سایر هوش‌های مصنوعی توانایی بالایی در مدل‌سازی رفتارهای غیر خطی را دارا هستند، ولی این توانایی در حضور غنی داده‌ها و مشاهدات فراوان در جهت بهینه‌سازی ضرایب معادلات در جعبه سیاه مدل‌های مذکور است. از این‌رو، با خوشه‌بندی داده‌ها که همراه با کاهش داده‌های ورودی می‌باشد، باعث تنزل کارایی این مدل‌ها در برآورد عدم قطعیت‌ها می‌شود که این خود به‌عنوان یک نقص، کارایی آن‌ها را نسبت به همین مدل‌ها اما با داده‌های بیشتر کم می‌کند که نتایج آن در شکل ۲ قابل مشاهده است. با توجه به شکل ۲، می‌توان فهمید که مدل MLP از معیار RMSE پایین و ضریب همبستگی بالایی نسبت به سایر شبکه‌ها از جمله مدل MLP+SOM برخوردار است. علاوه بر مورد فوق، نکته قابل ملاحظه دیگر این است که مدل MLP و سایر مدل‌ها از روش نرم‌سازی (کمینه کردن مقادیر بیشینه و بیشینه کردن مقادیر کمینه) در برآورد دبی سیلاب استفاده می‌کند که می‌تواند نکته‌ای منفی در طراحی‌ها و مباحث متبوع باشد. از این‌رو، در آخر پیشنهاد می‌شود که در مسائل مربوط به مطالعات هیدرولوژی که عمدتاً وقایع به‌صورت دوره‌ای تکرار می‌شوند، از هوش‌های مصنوعی پویا که علاوه بر ورودی فعلی آن به ورودی‌ها و خروجی‌های قبل و همچنین، به معماری شبکه می‌پردازد (Kia، ۲۰۱۰) استفاده نمود تا نتایج بهتری را نسبت به شبکه‌های ایستا، اخذ کرد.

ساختار ترکیبی شبکه عصبی رگرسیون عمومی و الگوریتم خوشه‌بندی K_means: شبکه‌های GRNN نیازمند نرون‌های بیشتری نسبت به شبکه‌های استاندارد پیش‌خور با الگوریتم پس انتشار خطا هستند ولی اغلب این شبکه‌ها را می‌توان در زمانی کوتاه‌تر نسبت به زمان مورد نیاز برای شبکه‌های پیش‌خور، آموزش داد. این شبکه‌ها زمانی که بردارهای ورودی فراوانی در دسترس باشد از عملکرد مطلوب‌تری برخوردارند (شکل ۲). برای افزایش کارایی عملکرد و سرعت آموزش این شبکه به‌جای قرار دادن تک‌تک داده‌ها ورودی به‌عنوان مراکز خوشه‌ها، می‌توان از روش‌های خوشه‌بندی برای کاهش تعداد داده‌های ورودی استفاده نمود. در این مطالعه از روش خوشه‌بندی متداول این شبکه (k_means) برای کاهش تعداد داده‌های ورودی استفاده شد.

نتیجه‌گیری

روش‌ها و مدل‌های مختلفی در برآورد دبی اوج در حوضه‌های مورد مطالعه وجود دارد که هر کدام با توجه به نوع کارکرد خود و نوع روابط بین عوامل درونی و بیرونی حوضه مورد مطالعه، دارای دقت‌های مختلفی نسبت به یکدیگر در برآورد عدم قطعیت‌ها هستند. در این تحقیق، با استفاده از چهار مدل شبکه عصبی MLP، GRNN، MLP+SOM و مدل ترکیبی خوشه‌بندی فازی (FCM) و ANFIS اقدام به برآورد دبی پیک در حوضه مورد مطالعه شد. اگرچه این

منابع مورد استفاده

- Ahmad, S. and S.P. Simonovic. 2005. An artificial neural network model for generating hydrograph from hydro-meteorological parameters. *Journal of Hydrology*, 315: 236-251.
- Ariffin, J., A. Abdul, N. Ghani Zakaria and A. Shukri Yahya. 2003. Sediment prediction using ANN and regression approach. Pp 930-945. 1st International Conference on Managing Rivers in the 21st Century Issues and Challenges. 23 September, Universiti Sains Malaysia, Penang, Malaysia.
- ASCE Task Committee. 2000. Artificial neural networks in hydrology, II: Hydrology application. *Journal of Hydrologic Engineering*, 5: 124-137.
- Borhani Dariyan, A. and A. Fatehi Marge. 2008. Application of artificial neural network in river flow prediction using climate indices, case study: Nazloochaei Basin. *Journal of Engineering*, 35(3): 12-26 (in Persian).
- Braddock, R.D., M.L. Kremmer and L. Sanzogni. 1998. Feedforward artificial neural network model for forecasting rainfall-runoff. *Environmental Sciences*, 9: 419-432.
- Chen, J. and B.I. Adams. 2006. Integration of artificial neural networks with conceptual models in rainfall-runoff modeling. *Journal of Hydrology*, 318: 232-249.

7. Dastorani, M. 2006. Artificial neural network approach in modeling of river flows (analysis of strengths and weaknesses). 7th International Conference on River Engineering, Ahvaz (2006) (IN Persian).
8. El-Shafie, A., M. Reda Taha and A. Noureldin. 2007. A neuro-fuzzy model for inflow forecasting of the Nile River at Aswam high dam. *Water Resources Management*, 21: 533-556.
9. Fathabadi, A., A. Salajegheh and M. Mahdavi. 2008. River flow forecasting using time series methods and ANFIS, *Watershed Science and Engineering*, Iran. 2nd year, No.5. 2008 Winter (in Persian).
10. Isaaks, E.H. and R.M. Srivastava. 1989. Introduction to applied geostatistics. Oxford University Press, New York, 538-561 pages.
11. Menhaj, M. 2001. Foundations of neural networks (computational intelligence). Volume 1, Amirkabir University Publication Center, 715 pages (in Persian).
12. Mysaghi, F. 2002. Development of fusion algorithms, artificial neural networks, geostatistics and spatial distribution of rainfall. MSc Thesis, Tarbiat Modarres University, 126 pages (in Persian).
13. Najafi, N., M. Heydarpoor and A. Asadi. 2006. Comparison curve sediment with estimate model sediment load Zayandehrood River. 7th International Conference on River Engineering (in Persian).
14. Nayak, P.C., K.P. Sudheer, D.M. Rangan and K.S. Ramasastri. 2004. A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*, 291: 52-66.
15. Noorani, V. and K. Salehi. 2008. Rainfall-runoff modeling using ANFIS and comparing with ANN and fuzzy logic. 4th National Conference on Civil Engineering, Tehran University, Tehran (in Persian).
16. Pahlavani, H. 2009. Efficiency of Artificial Neural Networks (ANNs) in intelligent estimation of flood hydrograph for Shirindarreh Reservoir dam in comparison with Adaptive Neuro-Fuzzy Inference System (ANFIS). MSc Thesis, Gorgan University of Agricultural Sciences and Natural Resources, 123 pages (in Persian).
17. Pal, N.R., S. Pal and J. Das and K. Majumdar. 2003. SOFM-MLP: a hybrid neural network for atmospheric emperature prediction. *IEEE Transactions on Geoscience and Remote Sensing*, 41(12): 2783- 2791.
18. Seif, A. 2001. Evaluation of data combined method on flood discharge estimation in a south west part of Iran. MSc Thesis, Tarbiat Modarres University, 158 pages.
19. Turan, M.E. and A. Yurdusev. 2009. River flow estimation from upstream flow records by artificial intelligence methods. *Journal of Hydrology*, 369: 71-77.
20. Wang, W., P. Van Gelder, J.K. Vrijling and J. Ma. 2005. Forecasting daily streamflow using hybrid ANN models. *Journal of Hydrology*, 324: 383-399.
21. Xiong, L., A.Y. Shamseldin and K.M. O'Connor. 2001. A non-linear combination of the forecasts of rainfall-runoff models by the first-order takagi-sugeno fuzzy system. *Journal of Hydrology*, 245: 196-217.
22. Zamani, A. and M. Nedaei. 2009. Aplication of Self Organized Map (SOM) neural network for zoning digital tectonic. A new approach for zoning digital tectonic Iran. Department of Earth Sciences, Faculty of Science, Shiraz University.

Evaluation of artificial intelligence in flood estimation

Mehdi Sepehri^{*1}, Seyyed Abbas Atapourfard², Alireza Ildoromi³, Hamid Nori⁴, Saba Goodarzi⁵,
Mohammadmehdi Artimani⁶ and Morteza Solgi⁷

^{1,5} MSc, Faculty of Natural Resources, Malayer University, Iran, ² Assistant Professor, Soil Conservation and Watershed Management Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran, ³ Associate Professor, Faculty of Natural Resources, Malayer University, Iran, ⁴ Assistant Professor, Faculty of Natural Resources, Malayer University, Iran and ^{6,7} MSc, Soil Conservation and Watershed Management Research Department, Hamedan Agricultural and Natural Resources Research and Education Center, AREEO, Hamedan, Iran

Received: 15 March 2016

Accepted: 13 September 2016

Abstract

Peak flow estimation is one of the major issues in water resources and flood management that have basic role in the design of hydraulic structures and biomechanics activities in basins. So that a proper assessment has a basic role in the success of administrative works. In this paper, using artificial intelligence methods (MLP Neural Network, the mixture of SOFM with MLP, the mixture of FCM with ANFIS) to estimate Yalfan River's peak discharge in hydrometer local station. For these models, eight variables have been considered as the inputs that includes rainfall amount in the occurrence time of flood, rainfall of five days ago from occurrence of flood, curve number of the basin (CN), basic discharge and finally peak discharge are considered as the output. In the artificial intelligences after preprocessing of the data, the optimal structure of the models are determined with input and output data, evaluation criteria and trial and error. At the end, the MLP model had better performance compared to ANFIS+FCM, MLP+SOFM, GRNN models.

Key words: ANFIS, Clustering, GRNN, MLP, Neural network, Peak flow, SOFM, Yalfan

* Corresponding author: n.sepehri@basu.ac.ir