

مقایسه مدل‌های هوشمند در تخمین بارش ماهانه حوضه کاکارضا

حمیدرضا باباعلی^{۱*}، رضا دهقانی^۲

۱. استادیار گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد خرم‌آباد

۲. دانشجوی دکتری سازه‌های آبی، دانشگاه لرستان

(تاریخ دریافت ۱۳۹۵/۱۰/۱۵؛ تاریخ تصویب ۱۳۹۵/۱۱/۳۰)

چکیده

برآورد بارش برای اجرای طرح‌های مطالعات منابع آب، خشک‌سالی، طرح‌های آمایش سرزمین، محیط زیست، آبخیزداری و طرح‌های جامع کشاورزی ضروری است. در این پژوهش برای تخمین بارش ماهانه دشت کاکارضا واقع در استان لرستان از مدل برنامه‌ریزی بیان ژن استفاده و نتایج آن با سایر روش‌های هوشمند از جمله سیستم استنتاج فازی-عصبی و شبکه عصبی مصنوعی مقایسه شد. بدین منظور از پارامترهای میانگین دما، رطوبت نسبی، تبخیر، سرعت باد در مقیاس زمانی ماهانه طی دوره آماری ۱۳۸۴-۱۳۹۴ به‌عنوان ورودی و بارش به‌منزله پارامتر خروجی مدل‌ها انتخاب شد. معیارهای ضریب همبستگی، ریشه میانگین مربعات خطا و میانگین قدر مطلق خطا برای ارزیابی و عملکرد مدل‌ها استفاده شد. از لحاظ دقت، مدل برنامه‌ریزی بیان ژن با ضریب همبستگی ۰/۹۷۸، ریشه میانگین مربعات خطا (۰/۰۲۶mm) و میانگین قدر مطلق خطا (۰/۰۱۷mm) در مرحله صحت‌سنجی در اولویت قرار گرفت. در مجموع، نتایج نشان داد روش برنامه‌ریزی بیان ژن توانایی زیادی در تخمین مقادیر کمینه و میانی بارش دارد.

کلیدواژگان: بارش، برنامه‌ریزی بیان ژن، تخمین، سیستم استنتاج فازی-عصبی، شبکه عصبی مصنوعی.

مقدمه

بارندگی یکی از پدیده‌های پیچیده طبیعی است و در وقایع طبیعی تأثیر عوامل محسوس و غیرمحسوس آن‌چنان در ایجاد حادثه دخیل است که این روند را از یک نظام قانونمند روشن به سوی ساختاری پیچیده و آشوبناک سوق داده است. بنابراین، پیش‌بینی بارش می‌تواند به‌عنوان یکی از جنبه‌های مؤثر مدیریتی در زمینه‌های مختلف به‌شمار رود. امروزه سیستم‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی استفاده می‌شود، که برنامه‌ریزی بیان ژن به‌عنوان یک تکنیک برنامه‌ریزی خودکار است که راه‌حل مسئله را با استفاده از برنامه‌ریزی کامپیوتر ارائه کرده و عضوی از خانواده الگوریتم تکاملی است [۱]. شبکه‌های عصبی مصنوعی با الهام از سیستم پردازش اطلاعات مغز طراحی که توانایی آن در تقریب الگوهای یک مسئله سبب افزایش دامنه کاربرد این شبکه‌ها شده است. سیستم‌های فازی بر پایه شبکه عصبی تطبیقی یکی از روش‌های کارآمد در زمینه پیش‌بینی سری‌های زمانی هیدرولوژیکی است. محققان طی سال‌های اخیر به استفاده از روش‌های هوشمند در مطالعات بارش حوضه‌های آبریز توجه کرده‌اند، که از جمله می‌توان به موارد زیر اشاره کرد:

خلیلی [۲] با استفاده از شبکه‌های عصبی مصنوعی بارش ماهانه ایستگاه سینوپتیک مشهد را مطالعه کرد. نتایج پژوهش او نشان داد شبکه‌های عصبی مصنوعی به‌خوبی روند بارش ماهانه را پیش‌بینی می‌کند. فلاح قاهری و همکارانش [۳] دو روش سیستم استنتاج فازی ممدانی و شبکه عصبی مصنوعی را برای پیش‌بینی بارش فصلی بررسی کردند و نشان دادند شبکه عصبی مصنوعی خطای کمتری نسبت به روش فازی دارد. فقیه [۴] برای پیش‌بینی بارش ماهانه استان کردستان از تلفیق شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک استفاده کرد. نتایج پژوهش ایشان نشان داد شبکه‌های عصبی در مدل‌سازی و برآورد مکانی بارش ماهانه دقت زیادی دارد و همچنین روش تلفیقی نسبت به شبکه‌های عصبی مصنوعی برتری شایان توجهی دارد. امران مقصود و همکارانش [۵] سرعت باد، رطوبت نسبی و دما را برای ۲۴ ساعت آینده در کانادا، ساسکاتچوان جنوبی با استفاده از مدل‌های شبکه‌های عصبی MLPN، المن ERNN، رادیان بیسیک RBFN، هوپ فیلد HFM و تکنیک‌های رگرسیونی پیش‌بینی کردند و به این نتیجه رسیدند که مدل شبکه‌های

عصبی نسبت به مدل‌های رگرسیونی پارامترهای آب و هوایی را با دقت بیشتری پیش‌بینی می‌کند. ماریا [۶] از شبکه‌های عصبی و مدل‌های رگرسیونی برای پیش‌بینی بارش در منطقه سائوپائولوی برزیل استفاده کرد. همچنین از متغیرهای دمای پتانسیل، مؤلفه قائم باد، رطوبت ویژه، دمای هوا، آب قابل بارش، چرخندگی نسبی و شار واگرایی رطوبت برای پیش‌بینی استفاده کرده که نتایج نشان‌دهنده کارایی زیاد هر دو روش در پیش‌بینی بارش است. ناصری و همکارانش [۷] برای پیش‌بینی بارش با استفاده از داده‌های هیتوگراف باران سنجی واقع در حوضه پاراماتا در حومه غربی سیدنی استرالیا، از هم‌کوپل کردن شبکه‌های عصبی و الگوریتم ژنتیک استفاده کردند و نشان دادند هنگامی که شبکه‌های عصبی و الگوریتم ژنتیک را با هم کوپل می‌کنند، نتایج بهتری نسبت به زمانی حاصل می‌شود که شبکه‌های عصبی به‌تنهایی به کار می‌رود. وو و همکارانش [۸] داده‌های بارش دوماهه و دوروزه مربوط به چهار بارش ثبت‌شده در مناطق مختلف را آزمایش کردند. همچنین مدل‌های شبکه عصبی مصنوعی مدولار (MANN) با سه مدل دیگر شبکه عصبی مصنوعی (ANN)، k- نزدیک‌ترین همسایگی (K-N-N) و رگرسیون خطی برای پیش‌بینی بارش مقایسه کردند. نتایج نشان داد MANN بهترین عملکرد را داشته، اما سودمندی MANN در برابر ANN در پیش‌بینی داده‌های بارش ماهانه شایان توجه نیست. مکانیک و همکارانش [۹] روش‌های رگرسیون چندگانه و شبکه‌های عصبی مصنوعی را برای پیش‌بینی بارش فصل بهار در حوضه ویکتوریای استرالیا با استفاده از حالت‌های هوایی بزرگ‌مقیاس به‌کار بردند و همچنین نوسانات ال‌نینوی جنوبی و اقیانوس دوقطبی هند را به‌عنوان پیش‌بینی‌کننده‌های پتانسیل به‌کار بردند. نتایج نشان داد شبکه‌های عصبی مصنوعی نسبت به رگرسیون چندگانه پتانسیل بیشتری در پیش‌بینی بارش با متغیرهای آب و هوایی بزرگ‌مقیاس دارد. چانگ و همکارانش [۱۰] با استفاده از شبکه‌های نروی فازی و با ادغام اطلاعات مولتی‌سنسور به پیش‌بینی بارش پرداختند. نتایج پیش‌بینی شده برای هشدار سیل در حوضه مطالعه شده در طول دوره‌های توفانی بسیار مفید واقع شده است که شبکه فازی عملکرد مطلوبی در پیش‌بینی بارش دارد. در مجموع، با توجه به پژوهش‌های انجام‌شده و همچنین اهمیت دشت کاکارضا از لحاظ شرب و کشاورزی تغییرات بارندگی به‌منظور پیش‌بینی و اقدامات

مدیریتی برای استفاده بهینه بیش از پیش ضروری است. بنابراین، هدف از تحقیق حاضر تخمین بارش دشت کاکارضا با استفاده از مدل برنامه‌ریزی بیان ژن، سیستم استنتاجی فازی-عصبی تطبیقی و شبکه‌های عصبی مصنوعی براساس پارامترهای میانگین دما، رطوبت نسبی، تبخیر و سرعت باد به‌عنوان پارامترهای ورودی و بارش به‌منزله خروجی مدل در مقیاس زمانی ماهانه است.

مواد و روش‌ها

منطقه مطالعه شده

منطقه مطالعه شده حوضه کاکارضا واقع در استان لرستان است. این حوضه دارای رودخانه کاکارضا که از رودخانه‌های دائمی استان لرستان و از کوه‌های جنوب شرقی شهرستان الشتر و بخش چغلوندی (هرو) سرچشمه گرفته و در محدوده شهرستان الشتر به نام کاکارضا معروف است. این رودخانه بین $15^{\circ} 48'$ تا 49° درجه طول شرقی و $32^{\circ} 22'$ تا 52° درجه عرض شمالی و در استان لرستان و شرق شهرستان خرم‌آباد واقع شده است و قسمتی از سرشاخه‌های رودخانه کرخه را در زاگرس تشکیل می‌دهد. رودخانه کاکارضا در ارتفاع ۱۵۵۰ متری از سطح آب‌های آزاد قرار دارد. مساحت حوضه کاکارضا ۱۱۴۸ کیلومتر مربع و دارای رودخانه‌ای به طول ۸۵ کیلومتر است. رودخانه کاکارضا پس از پیوستن به رودخانه‌های کشکان، سیمره و کرخه، در نهایت به خلیج فارس می‌ریزد که در شکل ۱ موقعیت جغرافیایی منطقه مطالعه شده نشان داده شده است.

سیستم استنتاجی فازی-عصبی تطبیقی سامانه استنتاج عصبی-فازی تطبیقی، یک روش نوین در حل مسائل پیچیده‌ای است که یا الگوریتم مشخصی برای حل آنها وجود ندارد و یا استفاده از روش‌های متعارف مستلزم به‌کارگیری راه‌حل‌های بسیار طولانی و زمان‌بر است. یکی از قابلیت‌های مهم سامانه استنتاج عصبی-فازی تطبیقی درک رفتار غیرخطی یک سیستم است. این روش در سال‌های اخیر در مسائل مختلف مدیریت منابع آب و خاک استفاده شده است [۱۱]. سیستم فازی-عصبی یک سیستم فازی سوگنو را در یک ساختار عصبی اجرا می‌کند. این سیستم برای فرایند آموزش با ترکیبی از روش‌های آموزش پس‌انتشار خطا و کمینه مربعات خطا بهره‌گیری می‌کند. برای یک مدل فازی سوگنو می‌توان یک مجموعه قانون نمونه را با دو قانون اگر-آن‌گاه فازی به‌صورت زیر بیان کرد [۱۲]:

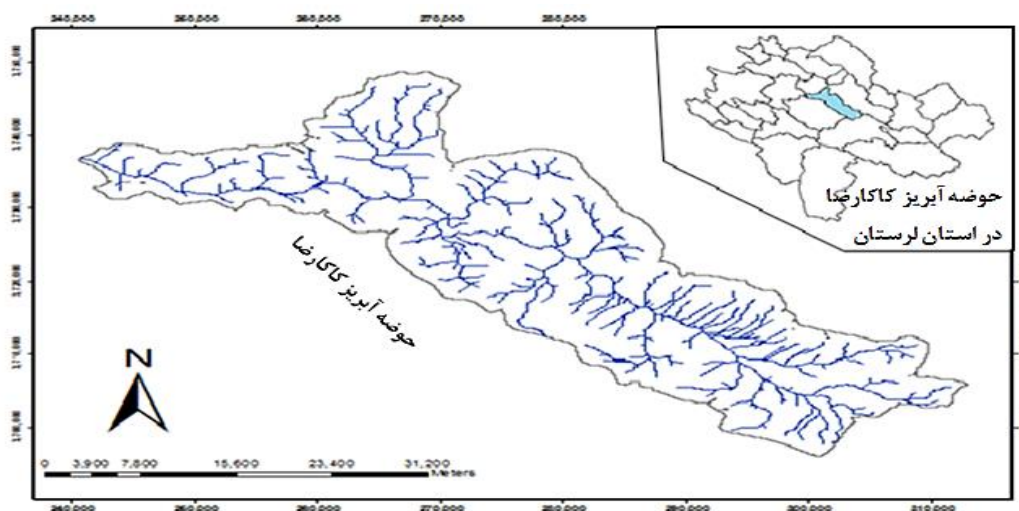
قانون اول: اگر x برابر A_1 و y برابر B_1 باشد، آن‌گاه

$$z_1 = p_1x + q_1y + r_1 \quad (1)$$


قانون دوم: اگر x برابر A_2 و y برابر B_2 باشد، آن‌گاه

$$z_2 = p_2x + q_2y + r_2 \quad (2)$$

که p_i ، q_i و r_i ($i=1, 2$) پارامترهای خطی تالی مدل سیستم استنتاج فازی-عصبی تطبیقی تاکاگی-سوگنو درجه اول هستند. یک نمونه طراحی شده از مدل تطبیقی عصبی-سیستم استنتاج فازی-عصبی تطبیقی در شکل ۲ آورده شده است.



شکل ۱. موقعیت محدوده مطالعاتی در استان لرستان



شکل ۲. معماری کلی مدل تطبیقی عصبی-فازی



شکل ۳. نمای کلی یک شبکه عصبی مصنوعی سه لایه

سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۳ نشان داده شده است.

برنامه‌ریزی بیان ژن

روش برنامه‌ریزی بیان ژن، در سال ۱۹۹۹ توسط فریرا ارائه شد [۱۶]. این روش ترکیبی از روش‌های برنامه‌ریزی ژنتیک (GP) و الگوریتم ژنتیک است (GA) که در آن، کروموزوم‌های خطی و ساده با طول ثابت، مشابه با آنچه در الگوریتم ژنتیک استفاده می‌شود و ساختارهای شاخه‌ای با اندازه‌ها و اشکال متفاوت، مشابه با درختان تجزیه در برنامه‌ریزی ژنتیک، ترکیب می‌شوند. در این روش پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و مجموعه‌ای از ترمینال‌ها، مدل‌سازی می‌شوند. مجموعه توابع، معمولاً شامل توابع اصلی حسابی $\{+, -, \times, /\}$ ، توابع مثلثاتی یا هر نوع تابع ریاضی دیگر $\{\sqrt{\quad}, \ln, \exp, \log, \sin, \cos, \dots\}$ و یا توابع تعریف شده توسط کاربر است که اعتقاد دارد می‌توانند برای تفسیر مدل مناسب باشند. مجموعه ترمینال‌ها، از مقادیر ثابت و متغیرهای مستقل مسئله تشکیل شده‌اند [۱۷ و ۱۸]. برای به‌کارگیری روش برنامه‌ریزی بیان ژن از نرم‌افزار GenXproTools 4.0 استفاده شد.

شبکه عصبی مصنوعی

امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد [۱۳]. ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌هاست. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه^۱ انجام شد. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس‌انتشار خطا^۲ با ساختار شبکه پیش‌خور^۳ و تعداد سه لایه به‌طور رضایت‌بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد [۱۴]. از رایج‌ترین توابع محرک استفاده‌شده در شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک را نام برد [۱۵]. نمونه‌ای از ساختار شبکه

1. Multi-Layer Perceptron
2. Back Propagation (BP)
3. Feed Forward

معیار ارزیابی

در این تحقیق ارزیابی دقت و قابلیت مدل با استفاده از نمایه‌های ضریب همبستگی (R)، ریشه میانگین مربعات خطا میانگین خطای مطلق (RMSE) و میانگین خطای مطلق (MAE) طبق روابط زیر صورت می‌گیرد. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و صفر است.

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad 1 \leq R \leq 1 \quad (3)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (4)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (5)$$

در روابط بالا، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی N ، تعداد گام‌های زمانی، و نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی است. علاوه بر معیارهای یادشده از نمودار سری زمانی مقادیر مشاهداتی-محاسباتی نسبت به زمان نیز برای مقایسه و تحلیل بیشتر نتایج استفاده شده است.

نتایج پژوهش

در این پژوهش برای تخمین بارش ماهانه حوضه کاکارضا

از پارامترهای دمای میانگین (T_{mean})، رطوبت نسبی (R)، تبخیر (E) و سرعت باد (W) به‌عنوان ورودی و بارش ماهانه (P) به‌عنوان پارامتر خروجی مدل‌ها به کار برده شد. در جدول ۱ خصوصیات آماری این پارامترها نشان داده شده است. از مهم‌ترین مراحل در مدل‌سازی، انتخاب ترکیب مناسبی از متغیرهای ورودی است. در مدل‌های هوشمند انتخاب ورودی‌های اولیه مناسب و تأثیرگذار در پدیده به‌منظور آموزش ماهیت سازوکار حاکم بر پدیده سبب بهبود عملکرد خواهد شد. بنابراین، در الگوسازی بارش ماهانه حوضه کاکارضا نیز سعی شد تا مؤثرترین داده‌های مشاهداتی به‌عنوان داده‌های آموزشی انتخاب شود. از این‌رو، ابتدا همبستگی متقابل^۱ بین متغیرهای ورودی و خروجی محاسبه شد و میزان همبستگی بین پارامترهای ورودی و خروجی به‌منظور دستیابی به مدل بهینه برای تخمین بارش ماهانه دشت کاکارضا در جدول ۲ ارائه شده است. با توجه به اینکه مقدار همبستگی متقابل بین داده‌های ورودی و خروجی که مطابق جدول ۲ بیشتر از ۰/۷۵۰ حاصل شد، ترکیب‌های مختلفی از پارامترهای ورودی به‌منظور دستیابی به مدل بهینه برای تخمین بارش ماهانه دشت کاکارضا استفاده شد که در جدول ۳ مشاهده می‌شود.

جدول ۱. خصوصیات آماری پارامترهای استفاده‌شده در دو مرحله آموزش و صحت‌سنجی

پارامتر	آموزش		صحت‌سنجی	
	مینیمم	ماکزیمم	مینیمم	ماکزیمم
Tmean (°C)	-۱۱	۱۱/۸۱۱	-۲/۹	۱۲/۳۰۸
R(t) %	۲۱	۵۵/۳۳۴	۱۹	۴۳/۰۹۷
E _i (mm)	-۴/۹۹	۱۱/۶۷۷	-۲/۹	۱۳/۰۱۵
W(t) (knot)	۱/۴۹۲	۳/۵۷۹	۱/۵۹	۳/۱۹۹
P(mm)	۰	۴۰/۴۷۳	۰	۴۲/۲۹۱

جدول ۲. همبستگی متقابل بین پارامترهای ورودی و خروجی

W(t)	E(t)	R(t)	Tmean(t)	P(t)
۷۸/۱۰۰	۸۲/۱۰۰	۷۶/۳۰۰	۸۳/۶۰۰	

جدول ۳. ترکیب‌های منتخب پارامترهای ورودی مدل‌های شبکه عصبی مصنوعی، فازی و برنامه‌ریزی بیان ژن

شماره مدل	ساختار ورودی	خروجی
۱	$T_{mean}(t)$	P(t)
۲	$T_{mean}(t), R(t)$	P(t)
۳	$T_{mean}(t), R(t), E(t)$	P(t)
۴	$T_{mean}(t), R(t), E(t), W(t)$	P(t)

داشته است. بنابراین، برنامه‌ریزی بیان ژن با عملگر F2 شامل چهار عملگر اصلی ریاضی، با وجود رابطه ساده ریاضی بیشترین دقت را در تخمین بارش حوضه کارضا داشته است. نمودار مقادیر بهینه محاسباتی و مشاهداتی برنامه‌ریزی بیان ژن مربوط به مرحله صحت‌سنجی در شکل ۴ نشان داده شده است. همان طور که از شکل مشخص است مدل برنامه‌ریزی ژن در تخمین بیشتر دقت‌های قابل قبولی داشته است به طوری که مقادیر محاسباتی را نزدیک به مقدار مشاهداتی تخمین زده است. این نتایج با نتایج پژوهش آیتیک و همکارانش [۲۰]، فربودنام و همکارانش [۲۱] مطابقت دارد. در تبیین این نتایج می‌توان بیان کرد که معادله به دست آمده از برنامه‌ریزی بیان ژن، از ترکیب تصادفی مجموع ترمینال‌ها و توابع به دست می‌آید. بنابراین، اگر رابطه بین ورودی‌ها و خروجی‌ها خطی باشد ولی عملگرهای sin, cos و... در مجموعه توابع انتخاب شود برنامه‌ریزی بیان ژن در استخراج رابطه از آن عملگرهای انتخابی استفاده می‌کند که این امر سبب کاهش دقت مدل می‌شود که در این پژوهش برای افزایش دقت مدل عملگرهای sin, cos و... کاربرد ندارد و نیز با توجه به دقت و سادگی، مدل به دست آمده از چهار عمل اصلی ریاضی {+, -, *, /} برای تخمین بارش پیشنهاد شد.

نتایج شبکه عصبی مصنوعی

به منظور مدل‌سازی بارش ماهانه از مدل شبکه عصبی مصنوعی پرسپترون چندلایه با تعداد نورون‌های متفاوت استفاده شده است. تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است، که در این پژوهش از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده شد. برای آموزش شبکه‌های پرسپترون چندلایه از الگوریتم آموزش پس‌انتشار خطا به نام الگوریتم لونیبرگ-مارکوارت به دلیل همگرایی سریع‌تر در آموزش شبکه، استفاده شد. در جدول ۵ نتایج مقایسه عملکرد ساختارهای مختلف به کاررفته به همراه پارامترهای آماری داده‌های بخش آموزش و صحت‌سنجی ارائه شده است.

بدین منظور از داده‌های ایستگاه هواشناسی کارضا استفاده شد که ۱۲۰ رکورد ثبت شده طی بازه زمانی ۱۳۸۴-۱۳۹۴ در مقیاس زمانی ماهانه دارد. در نهایت، تعداد ۹۶ رکورد برای آموزش و تعداد ۲۴ رکورد باقی‌مانده برای صحت‌سنجی روش‌های بررسی شده انتخاب شد. یک نکته مهم در آموزش شبکه‌های عصبی، نرمال‌سازی داده‌ها قبل از استفاده در مدل است. این عمل به خصوص وقتی دامنه تغییرات ورودی‌ها زیاد باشد، کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولاً وارد کردن داده‌ها به صورت خام سبب کاهش سرعت و دقت شبکه می‌شود [۱۹]. برای نرمال‌سازی داده‌های تحقیق از رابطه زیر استفاده شده است:

$$X_n = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (6)$$

که در آن X_n مقدار نرمال‌شده ورودی X_i ، X_{\max} و X_{\min} به ترتیب بیشترین و کمترین داده‌هاست.

نتایج برنامه‌ریزی بیان ژن

استفاده از برنامه‌ریزی بیان ژن به دلیل توان انتخاب متغیرهای مؤثر در مدل و حذف متغیرهایی با تأثیر کمتر و همچنین توانایی ارائه رابطه صریح برای تخمین بارش دشت کارضا مد نظر قرار گرفت. بنابراین، هر چهار ورودی برای تعیین متغیرهای معنادار استفاده، و برای بررسی بیشتر علاوه بر مجموعه چهار عملگر اصلی (F2)، حالت‌هایی براساس عملگرهای ریاضی پیش‌فرض برنامه (F1) لحاظ شده است. چگونگی و دلیل انتخاب این نوع عملگرها با توجه به مطالعات [۱۷ و ۱۸] صورت گرفته است.


$$F1: \{+, -, *, /, \sqrt{\quad}, \exp, \ln, \wedge, \sqrt{\quad}, \sin, \cos, \text{atan}\} \quad (7)$$

$$F2: \{+, -, *, /\} \quad (8)$$

نتایج مدل برنامه‌ریزی بیان ژن با هر دو عملگر در جدول ۴ بیان می‌کند که عملگر F2 در هر دو مرحله آموزش و صحت‌سنجی با بیشترین ضریب همبستگی $R=0.978$ ، کمترین میانگین خطای مطلق $MAE=0.17\text{mm}$ و کمترین ریشه میانگین مربعات خطا $RMSE=0.26\text{mm}$ نسبت به سایر عملگرها دقت بیشتری

جدول ۴. نتایج مدل برنامه ریزی بیان ژن

صحت سنجی			آموزش				
MAE (mm)	RMSE (mm)	R	MA (mm)	RMSE (mm)	R		
۰/۰۵۴	۰/۰۸۵	۰/۸۹۶	۰/۱۰۳	۰/۱۱۲	۰/۸۸۱	F1	۱
۰/۰۴۸	۰/۰۷۸	۰/۹۰۱	۰/۹۱	۰/۱۰۱	۰/۸۹۳	F2	
۰/۰۴۱	۰/۰۶۳	۰/۹۱۷	۰/۰۷۳	۰/۰۷۸	۰/۹۰۸	F1	۲
۰/۰۳۶	۰/۰۵۷	۰/۹۳۱	۰/۰۶۱	۰/۰۶۹	۰/۹۲۱	F2	
۰/۰۳۲	۰/۰۴۲	۰/۹۶۴	۰/۰۵۶	۰/۰۶۲	۰/۹۵۴	F1	۳
۰/۰۲۷	۰/۰۳۹	۰/۹۷۳	۰/۰۴۵	۰/۰۵۸	۰/۹۶۸	F2	
۰/۰۲۱	۰/۰۳۴	۰/۹۸۱	۰/۰۲۷	۰/۰۴۴	۰/۹۷۰	F1	۴
۰/۰۱۷	۰/۰۲۶	۰/۹۷۸	۰/۰۲۱	۰/۰۳۲	۰/۹۸۰	F2	



شکل ۴. نمودار مقادیر محاسباتی و مشاهداتی نسبت به زمان مدل برنامه ریزی بیان ژن برای داده های ثبت شده مرحله آموزش و صحت سنجی

جدول ۵. نتایج شبکه عصبی مصنوعی برای مدل های مختلف و شاخص های آماری در مراحل آموزش و صحت سنجی

شماره	ساختار	لایه پنهان	لایه خروجی	آموزش			صحت سنجی		
				MA (mm)	RMSE (mm)	R	MAE (mm)	RMSE (mm)	R
۱	۱-۵-۱	تانژانت هیپربولیک	خطی	۰/۱۰۹	۰/۱۱۴	۰/۸۹۱	۰/۰۹۲	۰/۱۱۴	۰/۸۰۱
۲	۲-۴-۱	تانژانت هیپربولیک	خطی	۰/۰۹۷	۰/۱۰۷	۰/۹۱۲	۰/۰۸۳	۰/۱۰۷	۰/۸۲۶
۳	۳-۸-۱	تانژانت هیپربولیک	خطی	۰/۰۷۴	۰/۰۸۳	۰/۹۳۱	۰/۰۶۱	۰/۰۸۳	۰/۸۴۳
۴	۴-۷-۱	تانژانت هیپربولیک	خطی	۰/۰۵۱	۰/۰۶۹	۰/۹۵۰	۰/۰۴۸	۰/۰۶۹	۰/۸۶۱

مصنوعی نشان داده شده است. در این شکل مدل شبکه عصبی مصنوعی در تخمین مقادیر بیشینه عملکرد قابل قبولی نداشته است به گونه ای که این مقادیر را (بیشینه) نزدیک به مقدار واقعیشان پیش بینی نکرده است. این نتایج با نتایج پژوهش صف شکن و همکارانش [۲۲] مطابقت دارد. در تبیین این نتایج می توان بیان کرد که با توجه به ساختار شبکه های عصبی مصنوعی، ویژگی عمده آن سرعت زیاد


همان طور که در جدول ۵ مشاهده می شود ساختار شماره ۴ با بیشترین ضریب همبستگی $R=0/861$ و کمترین میانگین خطای مطلق $MAE=0/048mm$ و کمترین ریشه میانگین مربعات خطا $RMSE=0/069mm$ در مرحله صحت سنجی نسبت به سایر ساختارها برای شبیه سازی فرایند بارش مناسب تر خواهد بود. در شکل ۵ نمودار مقادیر مشاهداتی و محاسباتی مدل شبکه عصبی

عضویت مثلثی و برای استلزام و انبوهش به ترتیب استفاده از روش‌های حداقل و حداکثر دقیق‌تر است. از طرفی، روش مرکز جرم برای غیرفازی‌سازی برگزیده شد. همان‌طور که در بالا اشاره شد، پس از انتخاب بهترین مدل استنتاجی برای تخمین بارش در مقیاس‌های زمانی ماهانه به بررسی تأثیرات مختلف پارامترهای مؤثر پرداخته شده است. همان‌طور که در جدول ۷ مشاهده می‌شود مدل سیستم استنتاج فازی-عصبی با بیشترین ضریب همبستگی $R=0.976$ و کمترین میانگین خطای مطلق $MAE=0.20\text{ mm}$ و ریشه میانگین مربعات خطا $RMSE=0.29\text{ mm}$ در مرحله صحت‌سنجی نسبت به سایر ساختارها برای مدل‌سازی میزان بارش مناسب‌تر خواهد بود. در شکل ۶ نمودار بهترین مدل به دست آمده برای داده‌های بخش صحت‌سنجی نشان داده شده است. همان‌طور که در شکل ۶ مشخص است مقادیر تخمینی و در بیشتر نقاط بیشینه با اختلاف زیادی نسبت به مقادیر واقعی تخمین زده شده است.

پردازش، توانایی یادگیری الگو، توانایی تعمیم الگو پس از یادگیری، انعطاف‌پذیری در برابر خطاهای ناخواسته و به‌وجود نیامدن اخلاص شایان توجه در صورت بروز اشکال در بخشی از اتصال‌ها به دلیل توزیع وزن‌های شبکه است.

نتایج سیستم استنتاجی فازی-عصبی تطبیقی


در این پژوهش برای ایجاد مدل ANFIS، در گام اول ابتدا بهترین ساختار مدل استنتاج فازی تعیین شد. در نظر گرفتن متغیرهای مختلف و پارامترهای مؤثر دیگر (بررسی و انتخاب روش غیرفازی‌سازی، شکل توابع عضویت، روش استلزام و انبوهش و غیره) به صورت هم‌زمان برای یافتن بهترین و مناسب‌ترین مدل صورت می‌گیرد. بنابراین، برای دستیابی آسان به دقیق‌ترین مدل، ابتدا با در نظر گرفتن یک متغیر ورودی (دمای میانگین، رطوبت نسبی، تبخیر و سرعت باد) بهترین ساختار مدل فازی را مشخص کرده و سپس تأثیر تعداد و نوع متغیر ورودی، بررسی شده است. دقیق‌ترین ساختار مدل استنتاجی براساس معیار کارایی و خطا به صورت زیر است. شکل توابع



شکل ۵. نمودار مقادیر محاسباتی و مشاهداتی نسبت به زمان مدل شبکه عصبی مصنوعی برای داده‌های ثبت‌شده مرحله آموزش و صحت‌سنجی

جدول ۶. نتایج مدل سیستم استنتاج فازی-عصبی برای مدل‌های مختلف و شاخص‌های آماری در مراحل آموزش و صحت‌سنجی

شماره	تابع ورودی	تابع خروجی	آموزش			صحت‌سنجی		
			RMSE (mm)	MA (mm)	R	RMSE (mm)	MA (mm)	R
۱	مثلثی	خطی	۰/۹۴۱	۰/۰۶۱	۰/۹۴۱	۰/۰۴۲	۰/۰۵۶	۰/۹۳۲
۲	مثلثی	خطی	۰/۹۶۸	۰/۰۵۶	۰/۹۵۵	۰/۰۳۷	۰/۰۴۸	۰/۹۵۵
۳	مثلثی	خطی	۰/۹۷۳	۰/۰۴۷	۰/۹۶۱	۰/۰۲۶	۰/۰۳۴	۰/۹۶۱
۴	مثلثی	خطی	۰/۹۸۰	۰/۰۳۴	۰/۹۷۶	۰/۰۲۰	۰/۰۲۹	۰/۹۷۶



شکل ۶. نمودار مقادیر محاسباتی و مشاهداتی نسبت به زمان مدل سیستم استنتاج فازی- عصبی برای داده‌های ثبت‌شده مرحله آموزش و صحت‌سنجی


در مرحله صحت‌سنجی در اولویت قرار گرفت. در شکل ۷ نتایج هر سه مدل نسبت به مقادیر مشاهداتی طی زمان نشان داده شده است. مدل برنامه‌ریزی بیان ژن دقت بیشتری نسبت به مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج فازی- عصبی در تخمین میزان بارش ماهانه از خود نشان داده است. همان‌طور که در این شکل مشخص است مدل برنامه‌ریزی بیان ژن بیشتر مقادیر را نزدیک به مقدار واقعی تخمین زده است.

مقایسه عملکرد مدل‌ها

در ادامه، با انتخاب جواب بهینه هر یک از مدل‌ها و مقایسه آنها با یکدیگر مشخص شد، هر سه روش با دقت خوبی می‌توانند فرایند بارش را شبیه‌سازی کنند. همان‌طور که در جدول ۷ مشاهده می‌شود، از بین مدل‌های به‌کاررفته مدل برنامه‌ریزی بیان ژن با بیشترین ضریب همبستگی $R=0/978$ و کمترین میانگین خطای مطلق $MAE=0/017mm$ و کمترین ریشه میانگین مربعات خطا $RMSE=0/026mm$

جدول ۷. نتایج نهایی به‌دست‌آمده از آموزش و صحت‌سنجی روش‌های شبکه عصبی، سیستم استنتاج فازی- عصبی و برنامه‌ریزی بیان ژن

صحت سنجی			آموزش			مدل
MAE (mm)	RMSE (mm)	R	MA (mm)	RMSE (mm)	R	
0/020	0/029	0/976	0/024	0/034	0/980	سیستم استنتاج فازی- عصبی
0/048	0/069	0/861	0/035	0/051	0/950	شبکه عصبی مصنوعی
0/017	0/026	0/978	0/021	0/022	0/980	برنامه‌ریزی بیان ژن



شکل ۷. نمودار پراکنش و مشاهداتی- محاسباتی مقادیر بهینه مدل شبکه عصبی مصنوعی، سیستم استنتاج فازی- عصبی و برنامه‌ریزی بیان ژن برای داده‌های ثبت‌شده مرحله آموزش و صحت‌سنجی

برنامه‌ریزی بیان ژن از دقت زیادی در مدل‌سازی فرایندهای هیدرولوژیکی برخوردار است. در مجموع، نتایج پژوهش حاضر مدل برنامه‌ریزی بیان ژن را به‌عنوان یک روش صریح و دقیق برای پیش‌بینی بارش ماهانه پیشنهاد می‌کند. این پیشنهاد با نتایج پژوهش سلطانی و همکارانش [۲۷] مطابقت دارد که به پیش‌بینی فرایند بارش رواناب با استفاده از برنامه‌ریزی بیان ژن پرداخته است. بنابراین، با توجه به اهمیت متغیر بارش به‌عنوان مهم‌ترین پارامتر هواشناسی در حوضه‌های مختلف منابع آب، کشاورزی و اقتصادی به‌منظور انجام مدیریت منابع آب با توجه به خشکسالی‌های اخیر و بحران جدی آب در منطقه، انجام پیش‌بینی بارش و شناخت پارامترهای مؤثر بر آن ضروری است.

منابع

- [1]. Ghorbani MA, Salehi A. The use of GEP in assessing changes in groundwater quality data with plain water level fluctuations in Shahr Isfahan. The Sixth National Congress of Civil Engineering; 2010. [Persian]
- [2]. khalili N. Forecasting precipitation with artificial neural networks, M.Sc Thesis. water engineering Department, Ferdowsi university of Mashhad; 2006. [Persian]
- [3]. Falah Ghalhari GA, Mousavi Bayegi SM, Habibi Nobakhtan M. Results Compression of Mamdani Fuzzy Interface System and Artificial Neural Networks into the Seasonal Rainfall Prediction, Case Study: Khorasan Region, Iran-Water Resources Research, 2006; 5(2): 40-52. [Persian]
- [4]. Faghih H. Evaluating Artificial Neural Network and its Optimization Using Genetic Algorithm in Estimation of Monthly Precipitation Data (Case Study: Kurdistan Region). JWSS - Isfahan University of Technology, 2010; 14(2): 27-44. [Persian]
- [5]. Imran M, Riaz Khan M, Ajith A. An ensemble of neural networks for weather forecasting. Neural Computing & Applications, 2004; 13(2): 58-69
- [6]. Maria C, Haroldo F, Ferreira N. Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region, Journal of Hydrology, 2005; 301(4): 146-162.
- [7]. Naseri HR, Adiehvand R, SalviTabar AA. Plain aquifer system dynamic modeling in operational management Kakarza, the Thirty meeting of Earth Sciences; 2012. [Persian]

در مجموع، با توجه به دقت و قابلیت تخمین زیاد مدل‌های شبکه عصبی مصنوعی، سیستم استنتاج فازی-عصبی و برنامه‌ریزی بیان ژن همبستگی بین مقادیر مشاهداتی و مقادیر محاسباتی مدل‌های یادشده بررسی شده و به ترتیب ۰/۸۶۱، ۰/۹۷۹ و ۰/۹۷۸ است. همچنین نتایج معنادار بودن مقادیر مشاهداتی و محاسباتی مدل‌های شبکه عصبی مصنوعی و فازی و برنامه‌ریزی بیان ژن در سطوح احتمال ۵ و ۱۰ درصد نشان داد مدل برنامه‌ریزی بیان ژن همبستگی معناداری در هر دو سطح احتمال دارد.

بحث و نتیجه‌گیری

بارش از مهم‌ترین داده‌های ورودی به سیستم‌های هیدرولوژیکی محسوب می‌شود. با توجه به اهمیت بارش برای کشور ایران تا کنون پژوهش‌های اندکی درباره پیش‌بینی بارش صورت گرفته است. از سوی دیگر، با توجه به روند غیرخطی بارش مدل‌های آماری نتایج قابل قبولی ارائه نمی‌کند. برای حل این مشکل باید از مدل‌هایی استفاده کرد که توانایی پیش‌بینی روندهای غیرخطی را دارند. بنابراین، در این پژوهش سعی شد عملکرد مدل‌هایی برای شبیه‌سازی بارش ماهانه حوضه کاکارزا واقع در استان لرستان با استفاده از داده‌های ماهانه طی سال آماری ۱۳۸۴-۱۳۹۴ ارزیابی شود. مدل‌های به‌کار گرفته‌شده شامل شبکه عصبی مصنوعی، برنامه‌ریزی بیان ژن و سیستم استنتاج فازی-عصبی است. مقادیر جریان مشاهداتی با جریان پیش‌بینی‌شده در مدل‌های یادشده (شبکه عصبی مصنوعی، برنامه‌ریزی بیان ژن و سیستم استنتاج فازی-عصبی)، با استفاده از معیارهای ارزیابی مقایسه شد. نتایج تحقیق را می‌توان به‌صورت زیر خلاصه کرد: نتایج نشان داد افزایش تعداد پارامترهای مؤثر در مدل‌های مختلف برای شبیه‌سازی موجب عملکرد بهتر مدل‌ها نسبت به سایر ساختارها در تخمین بارش می‌شود. همچنین با توجه به معیارهای ارزیابی نتیجه شد که هر سه مدل بررسی‌شده، می‌توانند با دقت نسبتاً زیادی میزان بارش ماهانه را پیش‌بینی کنند. در این میان، مدل برنامه‌ریزی بیان ژن دقت بیشتر و خطای کمتری نسبت به مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی از خود نشان داده است. این نتایج با نتایج پژوهش‌های کاشیت و ماریتی [۲۳]، دربندی و همکارانش [۲۴]، داننده‌مهر و همکارانش [۲۵] و قبادیان و همکارانش [۲۶] مطابقت دارد که در تحقیقات خود نشان دادند

- [8]. Wu CL, Chau KW, Fan C. Prediction of rainfall time series using modular artificial neural networks coupled with data preprocessing techniques, *journal of hydrology*,2010;389(2): 146-167.
- [9]. Mekanik F, Imteaz MA, Gato-Trinida DS, Elmahdi A. Multiple regression and artificial neural network for long term rainfall forecasting using large scale climate modes. *journal of hydrology*,2013;503(3): 11-21.
- [10]. Chang FJ, Chiang YM, Tsia MJ, Shieh MC, Hsu KL, Sorooshian S. Watershed rainfall forecasting using neuro fuzzy networks with the assimilation of multi-sensor information.*journal of hydrology*,2013;21(6):374-384.
- [11]. Ahmadi F, Aysham S, Khalili K, Behmanesh J. Application of ANFIS and GP Models to Estimate Monthly Reference Crop Evapotranspiration in Northwest of Iran, *Journal of water in agriculture*,2014;29.2(2):235-247.[Persian]
- [12]. Nabizadeh M, Mosaedi A, Dehghani AA. Study the efficacy of fuzzy logic to predict daily river flow. *Journal of Range and Watershed*.2012;65(4):569-580.[Persian]
- [13]. Nourani V, Alami MT, Aminfar MH. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*,2009; 22(2):466-472.
- [14]. Nourani V, Kisi Ö, Komasi M. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*.2011;402 (1-2): 41-59.
- [15]. Tokar AS, Johnson PA. Rainfall- Runoff modeling using artificial neural, *Journal of Hydrologic Engineering*,1999;4(3):232-239
- [16]. Ferreira C. Gene expression programming: a new adaptive algorithm for solving problems. *Complex Systems*,2001;13(2): 87-129.
- [17]. Khatibi R, Naghipour L, Ghorbani MA, Aalami MT. Predictability of relative humidity by two artificial intelligence techniques using noisy data from two Californian gauging stations. *Neural computing and application*,2012;23(7): 2241-2252
- [18]. Ghorbani MA, Singh VP, Kashani M, Kashani, A. Modelling pan evaporation using genetic programming. *Journal of Statistics: Advances in Theory and Application*,2012;503(3): 175-187.
- [19]. Zhu YM, Lu XX, ZhouY. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment. *Geomorphology*, 2007;84(2):111-125.
- [20]. Aytek A, Asce M, Alp M. An application of artificial intelligence for rainfall-runoff modeling. *J Earth System Science*, 2008;117(4):145-155.
- [21]. Ferbodnam N, Ghorbani MA, Alami MA. River Flow Prediction Using Genetic Programming (Case Study : Lighvan River Watershed),*Knowledge of soil and water*, 2008;19(1):107-123.[Persian]
- [22]. Saf Sheken F, Pir Moradian N, Sharifian R. Simulation of rainfall-runoff hydrograph and the use of artificial neural network model of rainfall in the catchment kasilian. *Iran-Watershed Management Science & Engineering*,2012;5(15):1-10. [Persian]
- [23]. Kashid S, Maity R. prediction of monthly rainfall on homogeneous monsoon region of India based on large scale circulation pattern using genetic programming, *journal of hydrology*,2012;454(4): 26-41.
- [24]. Darbandi S, Abaspour A, ShoeibiNobarian MR. Alawites inflow to the reservoir prediction using genetic programming, *The fifth Conference of watershed management and soil and water resources management*;2011.[Persian]
- [25]. Dannandeh Mehr A, Majdzadeh Tabatabaei MR. I Prediction of Daily Discharge Trend of River Flow Based on Genetic Programming, *Journal of water and soil*,2010;24(2):325-333.[Persian]
- [26]. Ghobadian R, Ghorbani MA, Khalaj M. Comparison of Performance of Dynamic Wave and Gen Expression Programming Methods to River flood routing, *Journal of water and soil*,2013;27(3):592-602.[Persian]
- [27]. Soltani A, Ghorbani MA, Fakheri Fard A, Darbandi S, Farsadi Zadeh D. Genetic Programming and Its Application in Rainfall-Runoff Modeling, *Journal of water and soil*,2010;20(4):62-71.[Persian]