



مدلسازی بارش-رواناب در حوزه آبخیز زهره

عبدال شهربور^۱ و حسین آبسوران^۲

^۱استادیار و عضو هیئت علمی مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان کهگیلویه و بویراحمد-آدرس: یاسوج-میدان جهاد-مرکز تحقیقات کشاورزی-معاونت پژوهشی مرکز تحقیقات کشاورزی. ایمیل: abdal_shahrivar@yahoo.com
^۲دانشجوی مهندسی عمران آب-دانشگاه آزاد اسلامی واحد یاسوج

چکیده

در این تحقیق از مدل‌های شبکه‌های عصبی مصنوعی MLP و RBF برای مدل‌سازی رواناب در مقیاس‌های زمانی مختلف استفاده گردید. در کدام از مدل‌ها به فراخور نیاز در ابتدا اقدام به آماده‌سازی و استانداردسازی داده‌ها گردید. سپس بسته به نوع شبکه مورد استفاده اقدام به تعیین معماری شبکه گردید. در مرحله بعد اقدام به تعیین پارامترهای شبکه مورد استفاده گردید. مهمترین پارامترهایی مورد استفاده در مدل mlp شامل، تعداد تکرار، تعداد نرون مخفی، تعداد لایه، خطای هدف و ضریب یادگیری بوده است. هم‌چنین مهمترین پارامترهای مورد استفاده در مدل rbf شامل تعداد تکرار، خطای هدف و ضریب گسترش می‌باشد. از توابع خود همبستگی و خود همبستگی جزئی به منظور تعیین تعداد گام‌های قبلی بارش به عنوان رطوبت قبلی خاک استفاده شد. نتایج ارزیابی عملکرد مدل MLP و RBF در حوزه آبخیز زهره در مقیاس زمانی روزانه نشان داد که مدل‌های روزانه با ورودی بارش و دبی با گام زمانی تا دور روز قبل بهترین عملکرد را چه از جهت دقت و چه از جهت پایین بودن خطا ارائه کرده است. در مقیاس روزانه دقت مدل RBF در مقایسه با مدل MLP در مجموع بالاتر بوده است ولی در مقیاس ماهانه، فصلی و سالانه مدل MLP دقت قابل قبولی جهت پیش‌بینی دبی ارائه می‌دهد.

کلمات کلیدی: شبکه عصبی مصنوعی، رواناب، شبیه‌سازی، زهره، مدل

مقدمه

از آنجاکه پیش‌بینی جریان رودخانه در منابع آب از اهمیت زیادی برخوردار است، محققین طی چندین دهه گذشته روش‌های مختلفی را در این زمینه مورد تحقیق و بررسی قرار داده‌اند. روش‌های پیش‌بینی راجع را به طور عمده می‌توان به روش‌های مبتنی بر سری زمانی، مدل‌های رگرسیونی، مدل‌های حوزه آبخیز و مدل‌های هوش مصنوعی تقسیم بندی نمود. از جمله مدل‌های پیش‌بینی رواناب مدل‌های جعبه سیاه می‌باشند که صرفاً مبتنی بر اطلاعات ورودی و خروجی بازایی شده از حوزه آبخیز می‌باشد که از آن جمله مدل شبکه عصبی مصنوعی ۱۰۴۱ (داوسون و ویلی، ۲۰۰۱) می‌باشد. شبکه عصبی مصنوعی یک سامانه پردازشی داده‌ها است که از مغز انسان ایده گرفته و پردازش داده‌ها را به عهده پردازنده‌های کوچک و بسیار زیادی سپرده که به صورت شبکه‌ای به هم پیوسته و موازی با یکدیگر رفتار می‌کنند تا یک مسئله را حل نمایند. این شیوه از ساختاری نرونی و هوشمند با الگوبرداری مناسب از نرون‌های موجود در مغز انسان سعی می‌کند تا از طریق توابع تعریف شده ریاضی رفتار درون سلولی نرون‌های مغز را شبیه‌سازی کند و از طریق وزن‌های محاسباتی موجود در خطوط ارتباطی نرون‌های مصنوعی، عملکرد سیناپسی را در نرون‌های طبیعی به مدل در آورد. ماهیت و

^۱Artificial Neural Network



ذات تجربی این روش باعث می‌شود تا در مسائلی مانند مقوله پیش‌بینی که یک چنین نگرشی در ساختار آن‌ها مشاهده می‌شود و از رفتاری غیرخطی و لجام‌گسیخته برخوردار هستند، به خوبی قابل استفاده باشد (منهاج، ۱۳۷۷ و ۱۳۸۱). با پیشرفت‌های چشمگیر در زمینه‌های مختلف هوش مصنوعی توجه بسیاری از محافل علمی جهان در زمینه‌های مختلف علمی و مهندسی به این مقوله معطوف شده است. در همین راستا هیدرولوژیست‌ها نیز بر آن شدند تا فرآیندهای پیچیده هیدرولوژیکی را با این تکنیک شبیه‌سازی کنند. انواع مختلفی از شبکه‌های عصبی مصنوعی برای پیش‌بینی بکار می‌رود که در این بین، هیدرولوژیست‌ها مدل پرسپترون چندلایه^۱ (MLP) را بیش‌تر برای این کار مناسب دانسته‌اند (انتر و همکاران، ۲۰۰۹) (شکل ۱). نتایج بعضی دیگر از محققین نیز نشان دهنده کارایی مناسب استفاده از مدل ۱۰۶RBF برای مدل‌سازی هیدرولوژی است، که زمان آموزش در این روش بطور معنی‌داری نسبت به MLP کمتر است (مولتا و همکاران، ۲۰۰۸).

مواد و روش‌ها موقعیت جغرافیایی

محدوده مطالعاتی رودخانه زهره واقع در استان کهگیلویه و بویراحمد در کشور ایران است (شکل ۱).



شکل ۱- حوزه آبخیز زهره در ایران و استان کهگیلویه و بویراحمد

روش تحقیق

برای مدل‌سازی رواناب با استفاده از روش شبکه عصبی مصنوعی از نرم افزار Matlab2009 استفاده گردید. براین اساس داده‌های موجود به دو دسته تقسیم شد به طوری که ۸۰ درصد آنها برای آموزش^۱ و ۲۰ درصد برای آزمایش^۲ استفاده گردید (انتر و همکاران، ۲۰۰۶).

^۱ Multilayer Perception

^۲ Radial Basis Function

^۳ Back propagation

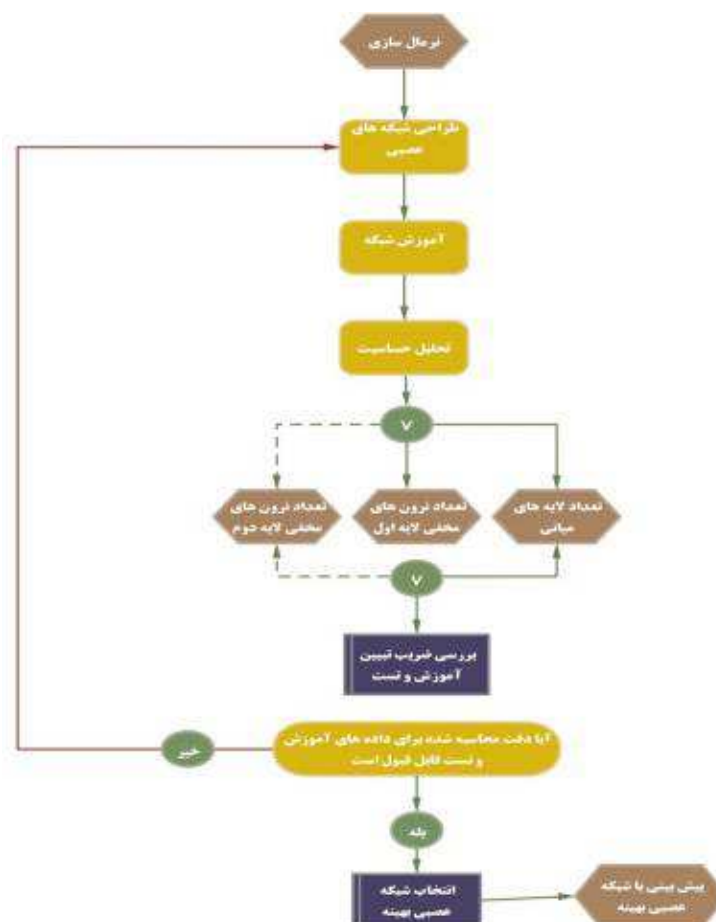
^۴ Training

^۵ Testing



قبل از آموزش، برای وارد کردن داده‌ها به شبکه عصبی مصنوعی، به منظور استانداردسازی و یکسان‌سازی واحدها ابتدا داده‌ها استاندارد گردیدند (سیگوزلو، ۲۰۰۳).

با توجه به توانایی یک شبکه عصبی مصنوعی چند لایه (MLP) با رویکرد پس انتشار (BP^۳) در این تحقیق از این شبکه و الگوریتم آموزشی لونیگ مارگوارت در مدل‌سازی رواناب استفاده شد. در شبکه MLP، تابع انتقال سیگموئیدی برای لایه اول و تابع انتقال خطی برای لایه دوم به عنوان بهترین معماری شبکه استفاده شد. در آموزش با تغییر پارامترهای مدل، بهترین مدل‌ها با کم‌ترین میزان خطا برای آزمایش انتخاب گردیدند. برای تعیین تعداد نرون‌های مطلوب در لایه مخفی، شبکه با فرض داشتن یک لایه مخفی و قرار دادن مقادیر مختلف نرون در این لایه مخفی، مورد آموزش قرار گرفت. بعد، تکنیک دوم برای مدل‌سازی با شبکه RBF می‌باشد. این شبکه از انواع نظارتی یا تغذیه رو به جلو نیز نامیده می‌شود. لایه مخفی در این شبکه شامل تعدادی گره و پارامتر بردار هم‌مرکز است که می‌توان به عنوان بردار وزن بررسی گردد. آموزش این شبکه دلالت بر یافتن مجموعه‌ای از گره‌ها و وزن‌های اولیه دارد. بنابراین فرآیند یادگیری به منظور پیدا کردن بهترین خط در داده‌های آموزشی می‌باشد. تابع انتقال در این نوع از شبکه عموماً از تابع گوسی ساخته می‌شود.



(شکل ۲): نحوه طراحی و پیش‌بینی شبکه عصبی مصنوعی

^۳ Back Propagation



تهیه آمار و اطلاعات:

سعی گردید از تمامی عوامل اصلی موثر بر دبی از جمله بارش، رطوبت قبلی، دما و تبخیر برای پیش‌بینی دبی استفاده گردد. متغیری چون بارش در ایستگاه‌های شرکت آب منطقه‌ای و هواشناسی تهیه گردید و از سازمان‌های مربوطه اخذ گردیدند. یکی از متغیرهای مهم و تأثیرگذار میزان رطوبت قبلی می‌باشد که معمولاً در ایستگاه‌ها ثبت نمی‌گردد. رطوبت قبلی نقش خود را به این صورت در میزان رواناب و سیلاب ایفا می‌کند در شرایط یکسان هرچه مقدار بارش بیشتر باشد، آبروی در رواناب سطحی بیشتری ایجاد می‌کند و در شرایط خاک اشباع، تمامی باران به صورت رواناب در سطح خاک جاری خواهد شد و قاعدتاً بین بارندگی و رواناب رابطه مستقیم وجود دارد ولی در صورتی که بارندگی به مدت چند روز اتفاق افتاده باشد برای ایجاد رواناب بارش کمتری مورد نیاز است. بر این اساس محققان بارش‌های تا پنج روز قبل را به عنوان معیاری از رطوبت خاک لحاظ نمودند.

ارزیابی عملکرد مدل‌های مختلف

برای انتخاب مدل بهینه از پارامترهای دقت‌سنجی از جمله (RMSE, MAE, R2) روابط (۳-۲) تا (۴-۳) استفاده گردید.

رابطه (۱): ریشه مجذور مربعات خطا

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Qy_o - Qy_e)^2}{n}}$$

رابطه (۲): ضریب تبیین

$$R^2 = \frac{\sum (Qy_o - \bar{Q}y_o)^2 (Qy_e - \bar{Q}y_e)^2}{\sum (Qy_o - \bar{Q}y_o)^2 \sum (Qy_e - \bar{Q}y_e)^2}$$

رابطه (۳): ریشه خطای مطلق

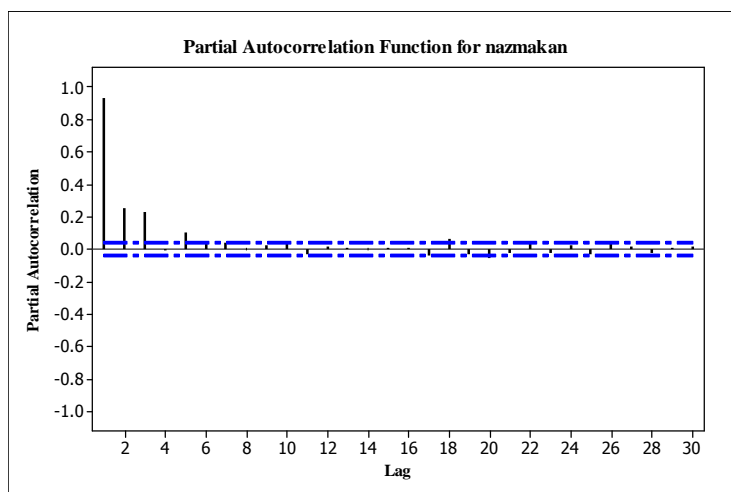
$$MAE = \left| \frac{\sum Qy_o - Qy_e}{N} \right|$$

در روابط بالا Qy_o دبی مشاهداتی، $\bar{Q}y_o$ میانگین دبی مشاهداتی، Qy_e دبی محاسباتی و $\bar{Q}y_e$ میانگین دبی محاسباتی می‌باشد.

نتایج:

در این بخش نتایج مربوط به مدل‌سازی و پیش‌بینی دبی با روش‌های هوش مصنوعی در حوزه آبخیز زهره ارائه شده است. نمودارهای مقایسه مقادیر دبی محاسباتی با روش‌های شبکه عصبی مصنوعی و مقادیر مشاهداتی در مقیاس‌های زمانی و با داده‌های ورودی مختلف ارائه شده است. نتایج کلی ارزیابی دو نوع شبکه عصبی MLP و RBF با معیارهای ارزیابی ضریب تبیین، ضریب کارایی، ریشه مجذورات خطا و میانگین خطای مطلق نیز در این فصل ارائه شده‌اند. هم‌چنین نمودار خط برازش رگرسیونی بین داده‌های مشاهداتی و محاسباتی در تعدادی از مدل‌ها ارائه شده است.

در این تحقیق از روش‌های خودهمبستگی و خودهمبستگی جزئی برای تعیین تعداد متغیرهای ورودی استفاده شد شکل ۳ نمودار خودهمبستگی جزئی داده‌های بارش حوزه آبخیز زهره را نشان داده است.




(شکل ۳): نمودار خود همبستگی جزئی با تغییرات تأخیر در داده‌ها

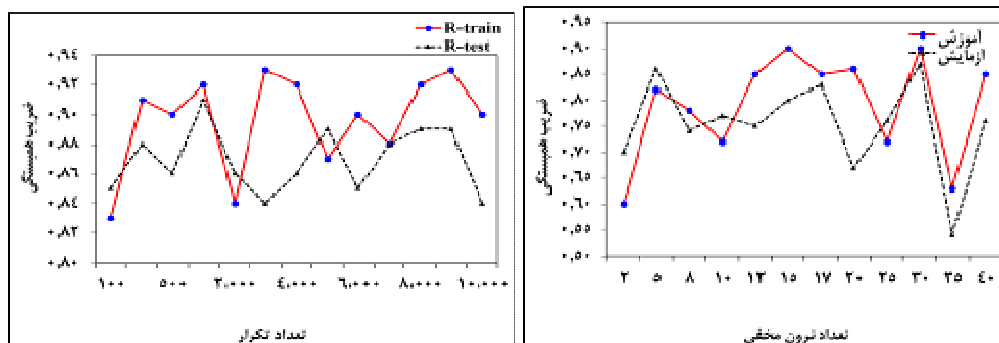
نتایج نمودار خود همبستگی جزئی (شکل ۳-۴) بهتر نشان دهنده تعداد تأخیرهای معنی‌دار بارش‌های قبلی است. به طوری مشاهده می‌گردد تا تأخیر سه روز قبل میزان همبستگی معنی‌دار می‌باشد ولی بعد از سه روز تأثیر معنی‌داری مشاهده نمی‌گردد.

پیدا کردن بهترین ساختار شبکه

با توجه به اینکه اجرای مدل‌های شبکه‌های عصبی مصنوعی نیاز به تعیین پارامترهای مؤثر بر طراحی این شبکه‌هاست. این پارامترها در هر کدام از شبکه‌ها متفاوت است. پارامترهای مهم تأثیرگذار بر طراحی شبکه‌ها در شبکه عصبی نوع MLP مشتمل بر تعداد نرون مخفی، ضریب یادگیری، تعداد تکرار، خطای بهینه و تعداد لایه‌ها، نوع الگوریتم آموزشی است در حالیکه در شبکه نوع RBF ضریب گسترش، تعداد تکرار و تعداد نرون مخفی از مهمترین پارامترهای مؤثر بر دقت شبکه می‌باشد. تعداد لایه‌های پنهان و نرون‌های لایه‌ها می‌توانند در محدوده مشخص تغییر کند برای پیدا کردن بهترین شبکه می‌توان با تغییر تعداد لایه‌های پنهان و تعداد نرون‌های آن‌ها شبکه‌های مختلفی را تعریف و سپس آزمایش نمود تا شبکه‌ای که دارای کمترین خطا است حاصل شود. برای انجام و اجرای هر مدل با قرار دادن مقادیر انتخابی و آزمایش و مشاهده میزان خطا و عملکرد شبکه مقادیر بهینه با سعی و خطا انتخاب گردید. در شکل‌های (۴ و ۵) نمونه‌ای از عملکرد پارامترهای انتخابی در هر دو نوع شبکه عصبی ارائه شده است.

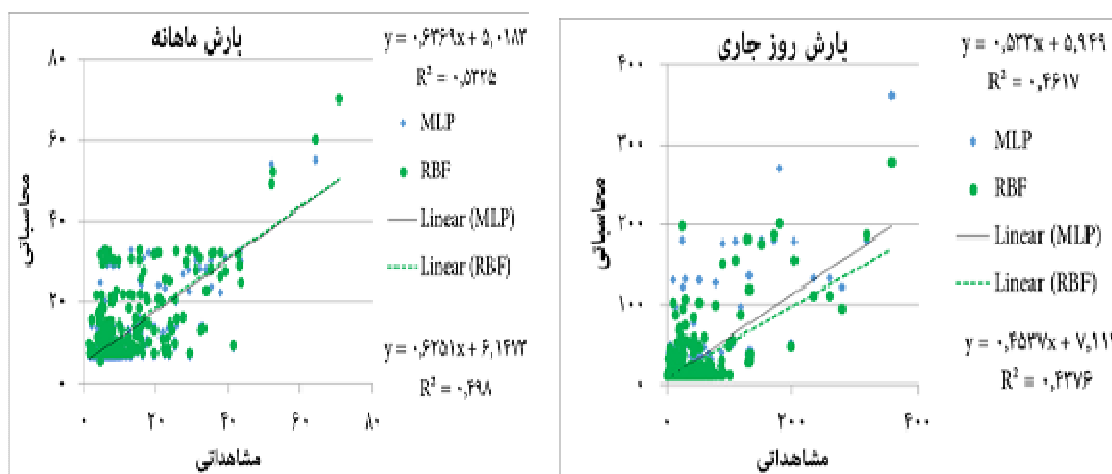


(شکل ۴): ریشه میانگین مجذور خطا با تغییر تعداد تکرار (سمت راست) و مقدار ضریب همبستگی با تغییرات ضریب گسترش در مراحل آموزش و آزمایش در یکی از مدل‌های مورد استفاده (سمت چپ)

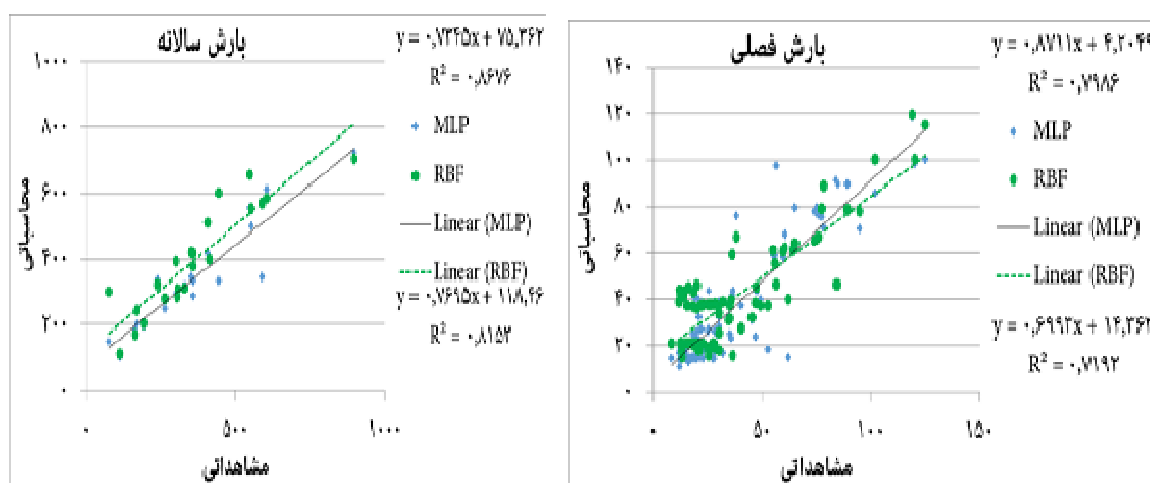


(شکل ۵): مقدار ضریب همبستگی با تغییرات تعداد نرون مخفی و تعداد تکرار در مراحل آموزش و آزمایش

بررسی تغییر ضریب گسترش با میزان خطا نشان می‌دهد که با تغییر این ضریب تا ۱۰۰ عدد میزان خطا بین ۰/۰۱ تا ۰/۰۴ متغیر است. به طوری که مشاهده می‌شود بهترین حالت در این شکل در ضریب گسترش معادل ۰/۵ می‌باشد که در هر دو مرحله آموزش و آزمایش میزان خطا حداقل است. بررسی تغییر تعداد تکرار با ضریب همبستگی نشان می‌دهد که با تغییر تعداد تکرار تا ۱۰۰۰۰ عدد میزان ضریب همبستگی بین ۰/۸۳ تا ۰/۹۳ متغیر است. در نتیجه می‌توان بیان نمود که تعداد تکرار پارامتر تعیین‌کننده در دقت پیش‌بینی مدل نمی‌باشد. به طوری که مشاهده شد بهترین حالت در این شکل در ۳۵۰۰ تکرار بیشترین ضریب همبستگی به دست آمده است. از بررسی شکل (۵) مشخص گردید که با تغییر تعداد نرون مخفی تا ۴۰ عدد میزان ضریب همبستگی بین ۰/۵۲۵ تا ۰/۹۰ تغییر کرده است. در نتیجه می‌توان بیان نمود که تعداد نرون مخفی از پارامترهای تعیین‌کننده در دقت پیش‌بینی مدل می‌باشد. به طوری که ملاحظه می‌گردد بهترین حالت در این شکل در تعداد ۳۰ نرون مخفی بیشترین ضریب همبستگی مشاهده شده است.



شکل (۶) خط رگرسیونی برازش شده به مقادیر دبی شبیه‌سازی شده (محاسباتی) و دبی مشاهده‌ای در مقیاس روزانه و ماهانه



شکل (۷) خط رگرسیونی برازش شده به مقادیر دبی شبیه‌سازی شده (محاسباتی) و دبی مشاهده‌ای در مقیاس فصلی و سالانه



(جدول ۱): نتایج ارزیابی مدل MLP در حوزه آبخیز زهره با معیارهای ارزیابی مختلف در مقیاس روزانه

ورودی	R2	CE	RMSE	MaE
R_t	0.46	0.35	22.30	10.2
R_t, R_{t-1}	0.37	0.14	19.9	9.5
$R_t, R_{t-1}, R_{t-2},$	0.39	0.38	16.7	10.3
$R_t, R_{t-1}, R_{t-2}, R_{t-3}$	0.48	0.39	16.5	9.0
$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}$	0.50	0.42	16.1	8.7
$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, R_{t-5}$	0.52	0.49	15.8	8.2
R_t, Q_{t-1}, Q_{t-2}	0.76	0.75	10.63	2.96
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4},$	0.50	0.46	15.58	3.83
$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4},$	0.81	0.77	10.28	4.75
$R_t, R_{t-1}, R_{t-2}, Q_{t-1}, Q_{t-2},$	0.83	0.82	8.94	2.50
$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, Q_{t-1},$	0.73	0.68	12.11	5.66

(جدول ۲): نتایج ارزیابی مدل RBF در حوزه آبخیز زهره با معیارهای ارزیابی مختلف در مقیاس روزانه

ورودی	R2	CE	RMSE	MaE
R_t	0.43	0.18	19.20	9.4
R_t, R_{t-1}	0.38	0.36	17.0	9.6
$R_t, R_{t-1}, R_{t-2},$	0.41	0.26	18.2	9.4
$R_t, R_{t-1}, R_{t-2}, R_{t-3}$	0.50	0.43	16.0	9.0
$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}$	0.53	0.47	15.5	8.5
$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, R_{t-5}$	0.55	0.53	15.2	7.2
R_t, Q_{t-1}, Q_{t-2}	0.84	0.83	8.68	2.19
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4},$	0.54	0.53	14.50	3.77
$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4},$	0.85	0.83	8.64	2.55
$R_t, R_{t-1}, R_{t-2}, Q_{t-1}, Q_{t-2},$	0.86	0.86	8.00	2.77
$R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, Q_{t-1},$	0.75	0.73	11.06	2.77

ارزیابی عملکرد مدل‌های MLP و RBF در مقیاس زمانی روزانه حوزه آبخیز زهره نشان داده است که مدل‌های با ورودی بارش و بارش‌های قبلی نتوانسته‌اند دقت قابل قبولی جهت پیش‌بینی دبی ارائه دهند در این مدل‌های روزانه با ورودی بارش با گام زمانی تا دو روز قبل و دبی تا دو روز قبل بهترین عملکرد را چه از جهت دقت و چه از جهت پایین‌بودن خطا ارائه کرده است.



جدول (۳) نتایج ارزیابی مدل MLP و RBF در حوزه آبخیز زهره با معیارهای ارزیابی مختلف در مقیاس ماهانه

MaE	RMSE	CE	R2	ورودی
5.10	7.60	0.51	0.53	MLP
5.60	8.10	0.45	0.50	RBF

نتایج ارزیابی عملکرد مدل MLP و RBF در حوزه آبخیز زهره در مقیاس زمانی ماهانه نشان داده است که مدل‌های با ورودی بارش تا حدودی توانسته‌اند دقت قابل قبولی جهت پیش‌بینی دبی ارائه دهند ولی در مجموع نمی‌توان با اطمینان کافی از این مدل برای پیش‌بینی دبی استفاده نمود.

جدول (۴) نتایج ارزیابی مدل MLP در حوزه آبخیز زهره با معیارهای ارزیابی مختلف در مقیاس فصلی

MaE	RMSE	CE	R2	ورودی
8.3	12.6	0.79	0.80	MLP
11.20	15.00	0.71	0.72	RBF

نتایج ارزیابی عملکرد مدل‌های MLP و RBF در حوزه آبخیز زهره در مقیاس فصلی نشان داده است که مدل‌ها توانسته‌اند دقت قابل قبولی جهت پیش‌بینی دبی ارائه دهند و می‌توان با اطمینان کافی از این مدل‌ها برای پیش‌بینی دبی فصلی استفاده نمود.

جدول (۵) نتایج ارزیابی مدل RBF در حوزه آبخیز زهره با معیارهای ارزیابی مختلف در مقیاس سالانه

MaE	RMSE	CE	R2	مدل
8.20	12.00	0.85	0.86	MLP
10.3	14.00	0.83	0.81	RBF

نتیجه‌گیری

نتایج ارزیابی عملکرد مدل MLP و RBF در حوزه آبخیز زهره در مقیاس زمانی روزانه نشان داد که مدل‌های روزانه با ورودی بارش و دبی با گام زمانی تا دور روز قبل بهترین عملکرد را چه از جهت دقت و چه از جهت پایین بودن خطا ارائه کرده است. نتایج ارزیابی عملکرد مدل MLP و RBF در مقیاس زمانی ماهانه نشان داده است که مدل‌های با ورودی فقط بارش تا حدودی توانسته‌اند دقت قابل قبولی جهت پیش‌بینی دبی ارائه دهند ولی در مجموع نمی‌توان با اطمینان کافی از این مدل برای پیش‌بینی دبی استفاده نمود. نتایج ارزیابی عملکرد مدل MLP و RBF در مقیاس زمانی فصلی نشان داده است که تمامی مدل‌ها توانسته‌اند دقت قابل قبولی جهت پیش‌بینی دبی ارائه دهند و می‌توان با اطمینان کافی از این مدل‌ها برای پیش‌بینی دبی فصلی استفاده نمود. مدل‌های با ورودی‌های ترکیبی بارش، تبخیر و دما توانسته‌اند بالاترین میزان ضریب تبیین و کارایی و کمترین میزان خطا را جهت محاسبه و پیش‌بینی دبی ارائه دهند.



مقایسه مدل‌های هوش مصنوعی برای مقیاس سالانه نشان داد که مدل MLP دقت قابل قبولی جهت پیش‌بینی دبی ارائه می‌دهد به طوری که می‌توان با اطمینان کافی از این مدل برای پیش‌بینی دبی سالانه استفاده نمود. مدل MLP نسبت به مدل RBF توانسته میزان ضریب تبیین بیشتری را جهت محاسبه و پیش‌بینی دبی ارائه دهد. از نتایج ارائه شده از پروژه حاضر جمع‌بندی می‌گردد که به طور کلی از بین تمام مدل‌های شبیه‌سازی شده، در مقیاس‌های روزانه و ماهانه دقت مدل RBF در مقایسه با مدل MLP در مجموع بالاتر بوده است ولی در مقیاس‌های فصلی و سالانه در مجموع دقت مدل MLP بیشتر از RBF بوده است. در تحقیق حاضر که با هدف مدل‌سازی رواناب صورت گرفته است مقدار بارندگی و تأثیرپذیری دبی از بارش نقش زیادی در دقت مدل سازی دارد. از طرفی با توجه به اینکه تغییرات بارش در ایران بالاست و بارندگی در فصل‌های سرد ریزش می‌شود در بیشتر ایام مقادیر بارش معادل صفر می‌باشد که متناظر آن در داده‌های ثبت شده مقادیر متفاوتی دبی ارائه شده است به همین علت شبکه‌های عصبی بیشتر برای مقادیر صفر آموزش دیده می‌شود و به همین علت در رابطه شناخته شده بیشتر این مقادیر را می‌تواند شبیه‌سازی کند.

منابع

- منهاج، م. ب. (۱۳۷۷). مبانی شبکه‌های عصبی. چاپ اول. مرکز نشر پروفسور حسابی. ص ۶۴۲.
- منهاج، م. ب. (۱۳۸۱). مبانی شبکه‌های عصبی مصنوعی (هوش محاسباتی). جلد اول. مرکز نشر دانشگاهی صنعتی امیرکبیر. ص ۷۱۵.
- Dawson., C.W., Wilby., R.L., (2001). Hydrological modelling using artificial neural networks. Progress in Physical Geography, Vol. 25, 1: pp.80-108.
- Mutlu E., Chaubey, H. Hexmoor and S. G. Bajwa. 2010. Comparison of artificial neural network models for hydrologic predictions at multiple gauging stations in an agricultural watershed. Hydrol. Process. 22, 5097–5106.
- Antar. A., Ellassiouti. I., & M. N. Allam., (2006). Rainfall-runoff modelling using artificial neural networks technique: a Blue Nile catchment case study. Hydrological Processes Journal. Vol. 20. pp1201– 1216.
- Cigizoglu, H.K., (2003). Estimation, forecasting and extrapolation of river flows by artificial neural networks. Hydrological Science Journal, vol. 48: pp.349-361