

## ارزیابی کارایی مدل‌های MLP و RBF در مدل‌سازی بارش-رواناب در مقیاس‌های زمانی مختلف

۱- مجید خزایی، دانشجوی دکتری علوم و مهندسی آبخیزداری، دانشگاه هرمزگان

khazaei.phd@hormozgan.ac.ir

۲- محمدرضا میرزایی، استادیار دانشکده‌ی کشاورزی، پژوهشکده‌ی منابع طبیعی و زیست‌محیطی، دانشگاه یاسوج

۳- آرش ملکیان، استادیار دانشکده منابع طبیعی دانشگاه تهران

دریافت: ۱۳۹۲/۰۹/۱۹

پذیرش: ۱۳۹۳/۰۲/۱۵

### چکیده

تحقیق حاضر با هدف مقایسه‌ی مدل‌های مختلف شبکه‌ی عصبی مصنوعی (MLP و RBF) در شش ایستگاه هیدرومتری در استان کهگیلویه و بویراحمد که دارای طول دوره‌ی آماری مناسب بودند در مقیاس‌های زمانی ماهانه، فصلی و سالانه برنامه‌ریزی شد. پارامترهای بهینه برای هر دو مدل MLP و RBF با انجام سعی و خطا و نظارت بر کمترین مقدار ریشه‌ی میانگین مربعات خطا (RMSE) بهینه گردید. جهت ارزیابی عملکرد مدل‌ها از پارامترهای دقت‌سنجی ضریب کارایی (CE)، ریشه‌ی مجذور مربعات (RMSE)، ضریب تبیین ( $R^2$ ) و ریشه‌ی خطای مطلق (MAE) استفاده گردید. نتایج نشان داد که کارایی هر دو مدل در مقیاس‌های زمانی مختلف ماهانه، فصلی و سالانه و در ایستگاه‌های مختلف متفاوت بوده اما به طور کلی ضرایب کارایی در مدل RBF بهتر از مدل MLP بوده است. در مقایسه‌ی بین مقیاس‌های مختلف مقیاس سالانه بهترین کارایی را ارائه داده است، به طوری که تفاوت معنی‌داری را با دیگر مقیاس‌ها در شبیه‌سازی رواناب ارائه داده است ( $P < 0.05$ ). روند پیش‌بینی مدل‌های مختلف به کار رفته در تحقیق حاضر تقریباً مشابه بوده است به طوری که بیش‌ترین دقت مدل‌ها در هر دو شبکه و مقیاس و ایستگاه‌ها، ایستگاه پل بریم و سیدآباد و کم‌ترین در ایستگاه کتا و زهره مشاهده گردید.

واژگان کلیدی: شبکه‌ی عصبی مصنوعی، مدل‌سازی، بارش-رواناب، حوزه‌ی آبخیز، کهگیلویه و بویراحمد.

### مقدمه

می‌باشد که به مقوله پیش‌بینی و تولید آمار مصنوعی در حوزه‌های آبریز کشورمان جلوه و نمودی کامل‌تر می‌بخشد (Soltani, Karamoz & Araghi nezhad, 2005). در همین راستا پیش‌بینی رواناب در منابع آب از اهمیت زیادی برخوردار است و می‌تواند در بهینه‌سازی مدیریت آبخیز و مدیریت منابع آب، بسیار مؤثر باشد (نورایی و همکاران، ۱۳۸۸).

روش‌های مختلفی برای مدل‌سازی در هیدرولوژی وجود دارد به طوری که روش‌های پیش‌بینی مختلف سعی در ارتباط بین متغیرهای مستقل و وابسته داشته دارد (Karamoz & Araghi nezhad, 2005). از جمله مدل‌های پیش‌بینی رواناب مدل‌های جعبه سیاه می‌باشند که

با توجه به اهمیت و حساسیت امر مهار آب‌های سطحی خصوصاً در کشور ما که اکثراً رودخانه‌های مناطق مختلف فصلی بوده و کمبود آبی که در پهنه وسیعی از کشور وجود دارد، نیاز به شناسایی و به مدل در آوردن رفتار رودها و شریان‌های آبی جهت برنامه‌ریزی‌های بلندمدت و استفاده بیش‌تر و بهتر از پتانسیل‌های آنها عمیقاً احساس می‌شود.

جدیدالتأسیس بودن بیش‌تر ایستگاه‌های هیدرومتری، نواقص موجود در آمار اکثر این ایستگاه‌ها، قرارگرفتن بیش‌تر رودها در مناطق خشک، وضعیت بحرانی برداشت آب‌های زیرزمینی و لزوم توجه بیش‌تر به آب‌های سطحی همه و همه دلایل بیش‌تر و ظریف‌تری

همچون پردازش موازی، هوشمندی و انعطاف‌پذیری جایگاه چشم‌گیری برای خود باز کرده و قابلیت مدل‌سازی، تخمین و پیش‌بینی دارند ( Rahmani & Sedehi, 2004). بدین لحاظ استفاده از ANN توسط محققان متعددی برای مدل‌سازی هیدرولوژیک استفاده شده است. هیدرولوژیست‌ها با استفاده از مدل‌های مختلف شبکه عصبی اقدام به مدل‌سازی بارش-رواناب کرده‌اند که به طور کلی مدل پرسپترون چندلایه (MLP) را برای این کار مناسب دانسته‌اند (Abrahart & See, 2000). نتایج بعضی دیگر از محققین نیز نشان دهنده کارایی مناسب استفاده از مدل RBF برای مدل‌سازی بارش-رواناب است، که زمان آموزش در این روش به طور معنی‌داری نسبت به MLP کمتر است (Abrahart & See, 2000). معمولاً در مطالعات، مدل‌های شبکه عصبی با دیگر مدل‌ها شبیه‌ساز رواناب مقایسه شده‌اند که به بعضی از موارد آن در جدول ۱ اشاره شده است. همان‌طور که مشاهده می‌شود در اغلب موارد روش شبکه عصبی نسبت به روش‌های دیگر برتری داشته است.

صرفاً مبتنی بر اطلاعات ورودی و خروجی بازیابی شده از حوزه آبخیز می‌باشد که از آن جمله مدل شبکه عصبی مصنوعی ۱ (Dawson & Wilby, 2001) می‌باشد. شبکه‌های عصبی نوعی مدل‌سازی ساده انگارانه از سیستم‌های عصبی واقعی هستند که کاربرد فراوانی در حل مسائل مختلف در علوم دارند. حوزه کاربرد این شبکه‌ها آن‌چنان گسترده است که از کاربردهای طبقه‌بندی گرفته تا کاربردهایی نظیر درون‌یابی، تخمین، آشکارسازی و غیره را شامل می‌شود. شاید مهم‌ترین مزیت این شبکه‌ها، توانایی وافر آن‌ها در کنار سهولت استفاده از آن‌ها باشد (Hagan & Menhaj, 1994). شبکه عصبی مصنوعی از جمله مدل‌های جعبه سیاه می‌باشد و مزیت‌های زیادی دارد که از جمله می‌توان به شبیه‌سازی هر سیستم غیرخطی بدون فرض قبلی از فرایند اشاره کرد. هم‌چنین وقتی که اطلاعات ورودی ناقص و یا مبهم باشند روش بسیار خوبی برای پیش‌بینی می‌باشد (Antar et al., 2006). این شبکه‌ها مبتنی بر فرآیند یادگیری داده‌ها و اطلاعات ذخیره شده می‌باشند (Zare Abyaneh & Bayat Varkeshi, 2011) و به دلیل ویژگی‌هایی

جدول ۱ - مطالعات صورت گرفته در ارتباط با شبکه عصبی مصنوعی در برآوردهای هیدرولوژیکی

منبع	محل تحقیق	مدل مورد استفاده	متغیر وابسته	متغیر مستقل	مقیاس زمانی	مدل برتر
Riad & Mania (2004)	مراکش	ANN, MLR	رواناب	بارش	ماهانه	ANN
Tombul & Oğul (2006)	اسپانیا	ANN, MLR	رواناب	بارش	ماهانه	ANN
Zhou et al (2008)	چین	ARIMA, ANN, Wavelet	دبی	بارش	روزانه	Wavelet
Borhani Darian & Fatehi Marj (2008)	نازلوچای	ANNS	دبی	شاخص‌های اقلیمی	ماهانه	MLP
Jahangeer et al (2008)	خراسان	ANN, HEC-HMS	رواناب	بارش	ماهانه	ANN
Antar et al (2006)	حوزه آبخیز نیل	ANN, Distributed models	رواناب	بارش	روزانه	ANN
Méndez et al (2004)	آمریکا	ANN, Box and Jenkinez	رواناب	بارش	روزانه و ماهانه	ANN
Tokar and Markus (2000)	آمریکا	ANN, Conceptual models	رواناب	بارش	روزانه و ماهانه	ANN
Zare Abyaneh and Bayat Varkeshi (2011)	اصفهان	ANN, CANFIS	رواناب سالانه	بارش	سالانه	ANN

ARIMA: مدل اتورگرسیو تلفیقی با میانگین متحرک؛ MLR: رگرسیون چندمتغیره؛ SRC: منحنی سنج رسوب؛ NF: منطق فازی؛ GRNN: شبکه عصبی مصنوعی Wavelet: شبکه عصبی موجکی

خیز می‌باشد و از طرفی منابع آب‌های سطحی از اهمیت بخصوصی در امر کشاورزی و تغذیه آب‌های زیرزمینی برخوردار است در همین راستا فهم رابطه بین بارش و

با توجه به این که استان کهگیلویه و بویراحمد دارای شرایط خاص فیزیوگرافی و اقلیمی می‌باشد که از چندین دهه گذشته نیز نشان داده که این منطقه از مناطق سیل

پیش‌بینی دبی شش ایستگاه هیدرومتر استان و در مقیاس‌های زمانی مختلف و با توجه به نبود و نیازمندی به انجام چنین مطالعه‌ای در استان کهگیلویه و بویراحمد پی‌ریزی گردید.

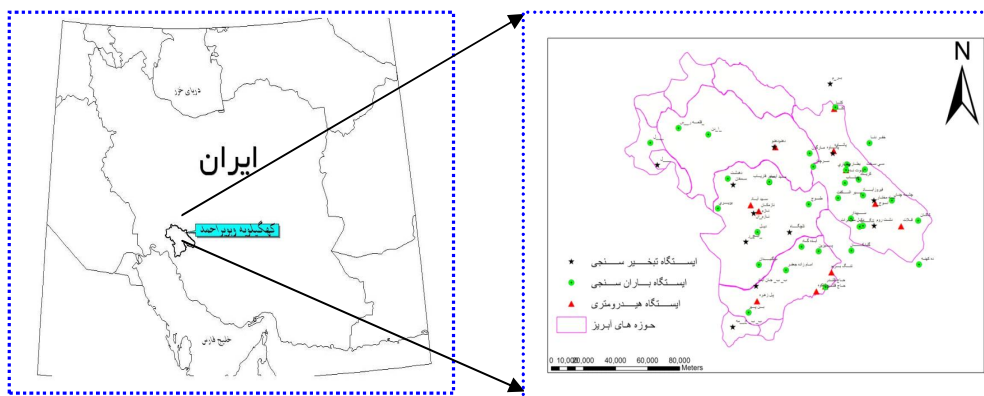
رواناب که یکی از مهم‌ترین مسائل در هیدرولوژی سطحی می‌باشد، می‌تواند در برنامه‌ریزی‌های توسعه‌ای برای مدیریت منابع آب در استان کمک‌یار باشد. تحقیق حاضر با هدف مقایسه کارایی شبکه‌های عصبی مصنوعی در

## مواد و روش‌ها

### منطقه مورد مطالعه

۳۱۰ عرض شمالی و ۲۶' ۵۳" تا ۴۹۰ ۵۳' ۱۶" تا ۵۱۰ طول شرقی واقع شده است (شکل ۱).

منطقه مطالعاتی محدوده استان کهگیلویه و بویراحمد بوده که در گسترده جغرافیائی ۲۶' ۳۸" تا ۲۹۰ ۴۸' ۴۵"



شکل ۱- نقشه حوزه‌های آبریز، شبکه هیدروگرافی و موقعیت ایستگاه‌های هواشناسی، هیدرومتری و کليمتولوژی استان

می‌باشد که می‌توان به رودخانه‌های بشار، سپیدار، و خرسان در حوضه کارون، رودخانه‌های سقاوه، لوداب، چاروسا و قلات در حوضه مارون و در نهایت رودخانه‌های شیو، خیرآباد و شمس عرب در حوضه زهره نام برد. در جدول ۲ مشخصات ایستگاه‌های هیدرومتری واقع در حوزه‌های آبریز کارون و زهره که در این تحقیق برای مدل‌سازی بکار رفته‌اند، ارائه شده است.

استان کهگیلویه و بویراحمد از نظر تقسیم‌بندی کلی هیدرولوژیکی ایران در زیر مجموعه‌ای از حوضه‌های آبریز رودخانه‌های مهمی چون کارون، مارون و زهره واقع شده است. با توجه به این که بخش عمده‌ای از مساحت استان کوهستانی می‌باشد و میزان ریزش‌های جوی در این مناطق قابل توجه می‌باشد، بنابراین این استان منشأ سرشاخه‌های پرآبی از رودخانه‌های کارون، مارون و زهره

جدول ۲ - مشخصات ایستگاه‌های هیدرومتری مطالعه شده در پژوهش حاضر

نام ایستگاه	حوزه آبریز	رودخانه	میانگین دبی	مساحت (کیلومتر مربع)	طول جغرافیائی	عرض جغرافیائی	ارتفاع (متر)	نحوه محاسبه بارندگی
بطاری	کارون	کبگیان	۲۰	۸۸۵	۵۱-۲۰-۰۷	۳۰-۵۱-۴۰	۱۶۵۰	باران سنج
کتا	کارون	بشار	۴۰	۳۰۵۹	۵۱-۱۵-۳۲	۳۱-۱۱-۰۴	۱۵۵۰	باران سنج
سیدآباد	خیرآباد	چم سیاه	۹	۸۰۰	۵۰-۴۲-۵۰	۳۰-۴۰-۳۵	۶۴۰	باران سنج
نازمکان	خیرآباد	شاه بهرام	۱۳	۱۰۶۰	۵۰-۴۶-۰۰	۳۰-۳۸-۴۰	۶۵۰	باران سنج
پل زهره	زهره	زهره	۶۰	۶۷۶۰	۵۰-۴۵-۲۵	۳۰-۱۰-۱۰	۳۹۰	زمین آمار
بریم	زهره	شیو	۳۲	۷۸۸	۵۱-۱۴-۲۱	۳۰-۱۹-۱۹	۸۰۰	باران سنج

**روش تحقیق**

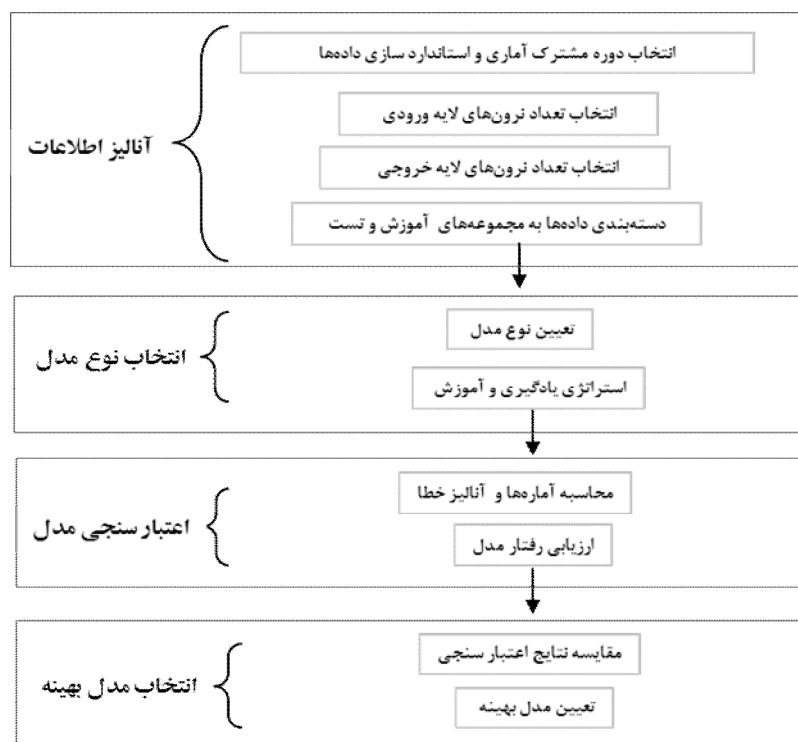
بر اساس اهداف تحقیق، ابتدا حوزه‌های دارای ایستگاه‌های هیدرومتری با داده‌های لازم انتخاب گردیدند. سپس داده‌ها را برای مدل‌سازی (تکمیل، تطویل، صحت و همگنی داده‌ها و کنترل داده‌ها) آماده نموده و در نهایت با استفاده از مدل‌های زیر اقدام به مدل‌سازی گردید. برای مدل‌سازی دبی با استفاده از روش شبکه عصبی مصنوعی از نرم افزار مطلب ۲۰۰۹ استفاده گردید. شکل ۲ نمایی از مراحل مدل‌سازی با شبکه عصبی مصنوعی را نشان داده است.

با توجه به تحقیقات متعدد انجام شده در تمام دنیا و در زمینه‌های مختلف مبنی بر توانایی یک شبکه عصبی مصنوعی چند لایه (MLP) با رویکرد پس انتشار (BP) و RBF در مدل‌سازی دبی، در تحقیق حاضر نیز از این دو نوع شبکه استفاده گردید. در تحقیق حاضر ابتدا برای هر کدام ایستگاه‌های انتخابی سال آماری مشترک برای داده‌های ورودی و خروجی در نظر گرفته شد. بعد از تکمیل و صحت و همگنی داده‌ها، برای وارد کردن داده‌ها به نرم افزار مطلب، به منظور استانداردسازی و یکسان‌سازی واحدها ابتدا داده‌ها را با استفاده از رابطه ۱ استاندارد کردیم.

$$X_s = 0.5 \times \left[ \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \right] + 0.5 \quad (1)$$


در رابطه بالا  $X_s$  متغیر استاندارد شده،  $X_i$  داده‌های اصلی،  $X_{\max}$  متغیر حداکثر و  $X_{\min}$  متغیر حداقل در بین کل داده‌ها می‌باشد. بعد از نرمال‌سازی داده‌های ورودی و خروجی، داده‌ها به دو دسته آموزش و تست تقسیم بندی گردید. سپس اقدام به انتخاب نوع مدل، نوع شبکه، الگوریتم آموزشی و الگوریتم یادگیری گردید. اولین تکنیک در مدل‌سازی با شبکه عصبی مدل MLP می‌باشد. این مدل پرکاربردترین روش برای مدل‌سازی هیدرولوژیکی می‌باشد. ساختار این روش در شکل ۲ نشان داده شده است.

بر اساس این شکل مدل MLP شامل سه لایه ورودی که داده‌ها به شبکه معرفی می‌شوند، لایه مخفی که داده‌ها پردازش می‌شوند و لایه خروجی که نتایج برای ورودی مشخص ایجاد می‌شوند. هر لایه از چندین گره ساخته شده و لایه‌ها به وسیله مجموعه‌ای از وزن‌های به هم وابسته متصل می‌شوند. هر گره ورودی در لایه ورودی باعث پخش سیگنال در لایه مخفی می‌گردد و هر لایه مخفی مجموعه‌ای از سیگنال‌های ورودی وزن دار می‌باشد.



شکل ۲ - مراحل مدل‌سازی با شبکه عصبی مصنوعی (دولینگ و وراس، ۲۰۰۳)

شبکه به لایه های قبل - ارزیابی عملکرد شبکه - سرانجام برگشت به قسمت پایان آموزش. پس از این که مرحله آموزشی شبکه تکمیل گردید شبکه برای سری اطلاعات معلوم امتحان می‌شود. در این نوع شبکه، تابع انتقال سیگموئیدی برای لایه اول و تابع انتقال خطی برای لایه دوم به عنوان بهترین معماری شبکه استفاده شد (شکل ۳).




شکل ۳- توابع آستانه در شبکه عصبی مصنوعی نوع پس انتشار خطا: خطی (راست) و تانژانت سیگموئید (چپ) (Hagan & Menhaj, 1994)

شبکه سه لایه است) را نشان می‌دهد. لایه مخفی در این شبکه شامل تعدادی گره و پارامتر بردار هم‌مرکز است که می‌توان به عنوان بردار وزن بررسی گردد. در این شبکه طراحی شبکه عصبی دارای مشکل برازش به صورت منحنی در ابعاد مکانی می‌باشد. آموزش این شبکه دلالت بر یافتن مجموعه‌ای از گره‌ها و وزن‌های اولیه دارد. بنابراین فرایند یادگیری به‌منظور پیدا کردن بهترین خط در داده‌های آموزشی می‌باشد. هم‌چنین تابع انتقال در این نوع از شبکه عموماً از تابع گوسی ساخته می‌شود (شکل ۴).

در شبکه عصبی MLP با رویکرد پس انتشار خطا از الگوریتم لونیبرگ مارگوارت LM استفاده گردید. مراحل آموزش به کمک این الگوریتم عبارتند از: اختصاص ماتریس وزن تصادفی به هریک از اتصالات - انتخاب بردار ورودی و خروجی - محاسبه خروجی نرون‌ها در لایه خروجی - بهنگام سازی وزن‌ها به روش انتشار خطای

برای تعیین تعداد نرون‌های مطلوب در لایه مخفی، شبکه با قراردادن مقادیر مختلف در لایه مخفی مورد آموزش قرار گرفت که این اقدام تا دستیابی به مقدار حداقل خطا و مقدار بهینه ضریب تبیین ادامه یافت. هم‌چنین بعد از انتخاب ساختار شبکه به منظور تعیین مقادیر تعداد تکرار، خطای هدف و ضریب یادگیری برای هر مدل نیز با استفاده سعی و خطا حاصل گردید. تکنیک دوم برای مدل‌سازی با شبکه RBF می‌باشد. این شبکه از انواع نظارتی یا تغذیه رو به جلو نیز نامیده می‌شود. شکل ۴ ساختار این نوع از شبکه (که به صورت



شکل ۴ ساختار شبکه عصبی نوع RBF (Hagan & Menhaj, 1994)

هیدرومتر به ایستگاه باران سنج نیز مجهز بود تنها ایستگاه زهره فاقد باران سنج بود که میزان بارندگی این ایستگاه با رسم مثلث‌های تیسن با نرم‌افزار ArcGIS 9.3 زیرحوزه‌های که در محدوده ایستگاه هیدرومتری قرار گرفته بودند مشخص شدند و با توجه به ارتفاع بارش هر ایستگاه، میزان بارش دریافتی به روش وزنی بدست آمد.

در شبکه RBF مقادیر خطای هدف، تعداد نرون و ضریب SPREAD نیز با استفاده از سعی و خطا حاصل شد. در نهایت خروجی‌های مدل‌های منتخب با مقادیر مشاهداتی مقایسه گردید و مدل‌های بهینه منتخب شدند. برای مدل‌سازی رواناب در تحقیق حاضر از ایستگاه‌های دارای آمار طولانی مدت استفاده گردید که هر ایستگاه

**ارزیابی عملکرد مدل‌های مختلف**

برای انتخاب مدل بهینه از پارامترهای دقت سنجی از جمله ( $CE$ ،  $MAE$ ،  $RMSE$ ،  $R^2$ ) روابط ۲ تا ۵ استفاده گردید.

$$CE = 1 - \frac{\sum_{t=1}^T (Qy_o - Qy_e)^2}{\sum_{t=1}^T (Qy_o - \bar{Qy}_o)^2} \quad (۲): \text{ضریب کارایی}$$

$$MAE = \left| \frac{\sum Qy_o - Qy_e}{N} \right| \quad (۵): \text{ریشه خطای مطلق}$$

در روابط بالا  $Qy_o$  دبی مشاهداتی،  $\bar{Qy}_o$  میانگین دبی مشاهداتی،  $Qy_e$  دبی محاسباتی و  $\bar{Qy}_e$  میانگین دبی محاسباتی می‌باشد.

**نتایج و بحث**

نتایج پارامترهای بهینه سازی مدل‌های مختلف بکار رفته در تحقیق حاضر شامل  $RBF$  و  $MLP$  در ایستگاه‌های هیدرومتر و مقیاس‌های زمانی مختلف که با استفاده از آزمون و خطا بدست آمده اند در جداول ۳ (مقیاس ماهانه)، ۴ (مقیاس فصلی) و ۵ (مقیاس سالانه) ارائه شده است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Qy_o - Qy_e)^2}{n}} \quad (۳): \text{ریشه مجذور مربعات خطا}$$

$$R^2 = \left( \frac{\sum (Qy_o - \bar{Qy}_o)(Qy_e - \bar{Qy}_e)}{\sqrt{\sum (Qy_o - \bar{Qy}_o)^2 \sum (Qy_e - \bar{Qy}_e)^2}} \right)^2 \quad (۴): \text{ضریب تبیین}$$

جدول ۳- مقادیر پارامترهای واسنجی شده مدل‌های مختلف در مقیاس ماهانه

نام ایستگاه	<i>MLP</i>			<i>RBF</i>			ضریب spread	تعداد تکرار	
	خطای نرون	تعداد تکرار	ضریب یادگیری	خطای هدف	خطای بهینه	نرون بهینه			
پل بریم	۰/۰۰	۱۸	۵۰۰۰	۰/۲۳	۰/۰۵	۰/۰۰	۵۰	۵۰	۱
نازمکان	۰/۰۳	۱۳	۱۰۰۰	۰/۲۲	.	۰/۰۰	۲۰	۵۰	۱
زهره	۰/۰۰	۲۰	۱۰۰۰	۰/۲۲	۰/۰۵	۰/۰۰	۲۰	۱۰۰	۱
سیدآباد	۰/۰۵	۲۰	۲۰۰۰	۰/۳۰	.	۰/۰۰	۵۰	۵۰	۵
کتا	۰/۰۵	۱۰	۱۸۰۰	۰/۴۲	۰/۰۵	۰/۰۰	۱۰۰	۱۰۰	۱
بطاری	۰/۰۰	۲۰	۲۰۰۰	۰/۱۲	۰/۰۱	۰/۰۰	۵۰	۵۰	۵

جدول ۴- مقادیر پارامترهای واسنجی شده مدل‌های مختلف در مقیاس فصلی

نام ایستگاه	<i>MLP</i>			<i>RBF</i>			ضریب spread	تعداد تکرار	
	خطای نرون	تعداد تکرار	ضریب یادگیری	خطای هدف	خطای بهینه	نرون بهینه			
پل بریم	۰/۰۰	۱۸	۵۰۰۰	۰/۲۳	.	۰/۰۰	۵۰	۱۰۰	۱
نازمکان	۰/۰۰	۱۸	۵۰۰۰	۰/۳۲	۰/۰۵	۰/۰۰	۱۰۰	۵۰	۵
زهره	۰/۰۰	۲۰	۱۰۰۰	۰/۳۲	.	۰/۰۰	۲۰	۱۰۰	۵
سیدآباد	۰/۰۵	۲۰	۱۰۰۰	۰/۲۲	۰/۰۵	۰/۰۰	۲۰	۵۰	۱
کتا	۰/۰۱	۲۰	۱۲۰۰	۰/۱۵	۰/۰۵	۰/۰۰	۱۰۰	۱۰۰	۵
بطاری	۰/۰۵	۱۳	۱۰۰۰	۰/۳۰	.	۰/۰۰	۱۰۰	۱۰۰	۱

جدول ۵ مقادیر پارامترهای واسنجی شده مدل‌های مختلف در مقیاس سالانه

MLP				RBF				نام ایستگاه
خطای هدف	نرون مخفی	تعداد تکرار	ضریب یادگیری	خطای هدف	خطای بهینه	نرون بهینه	تعداد تکرار	ضریب spread
۰/۱۵	۱۸	۲۰۰	۰/۲۵	۰/۰۰	۰/۰۱۷	۵	۲۰	۱
۰/۰۱۵	۱۴	۳۰۰	۰/۳۰	۰/۰۰۳	۰/۰۰۱۵	۷	۱۰	۱
۰/۰۲۵	۱۶	۱۰۰۰	۰/۳۵	۰/۰۰	۰/۰۰۱۲	۵	۱۰۰	۵
۰/۰۵	۱۵	۲۰۰۰	۰/۲۵	۰/۰۰	۰/۰۰۳۲	۵	۲۰	۴
۰/۰۰۱	۱۲	۲۰۰	۰/۳۲	۰/۰۰	۰/۰۰۰۴	۱۰	۵۰	۱
۰/۰۰۵	۱۳	۱۰۰۰	۰/۳۵	۰/۰۰	۰/۰۰۰۶	۴	۲۰	۵

مقیاس‌های مختلف برای یکی از مدل‌ها ارائه شده است. هم‌چنین در شبکه نوع MLP مهمترین پارامترها ضریب یادگیری، تعداد نرون در لایه مخفی، تعداد تکرار و خطای هدف می‌باشد که با تغییر آن‌ها نیز تغییر قابل توجهی در نتایج مقادیر تخمینی صورت می‌گیرد همان‌طور که از نتایج جداول ۳، ۴ و ۵ استنباط می‌شود مقادیر ضریب یادگیری بین مقادیر ۰/۱۲ تا ۰/۵ بهترین کارایی را ارائه داده است. هم‌چنین مقادیر تعداد نرون بین ۱۰ تا ۲۰، خطای هدف صفر و تعداد تکرار بین ۱۰۰۰ تا ۵۰۰۰ بهترین کارایی را ارائه داده است به‌طور مثال در نمونه‌های ارائه شده در شکل ۵ تغییرات پارامترهای بعضی مدل‌ها با میزان خطای ارائه شده است.

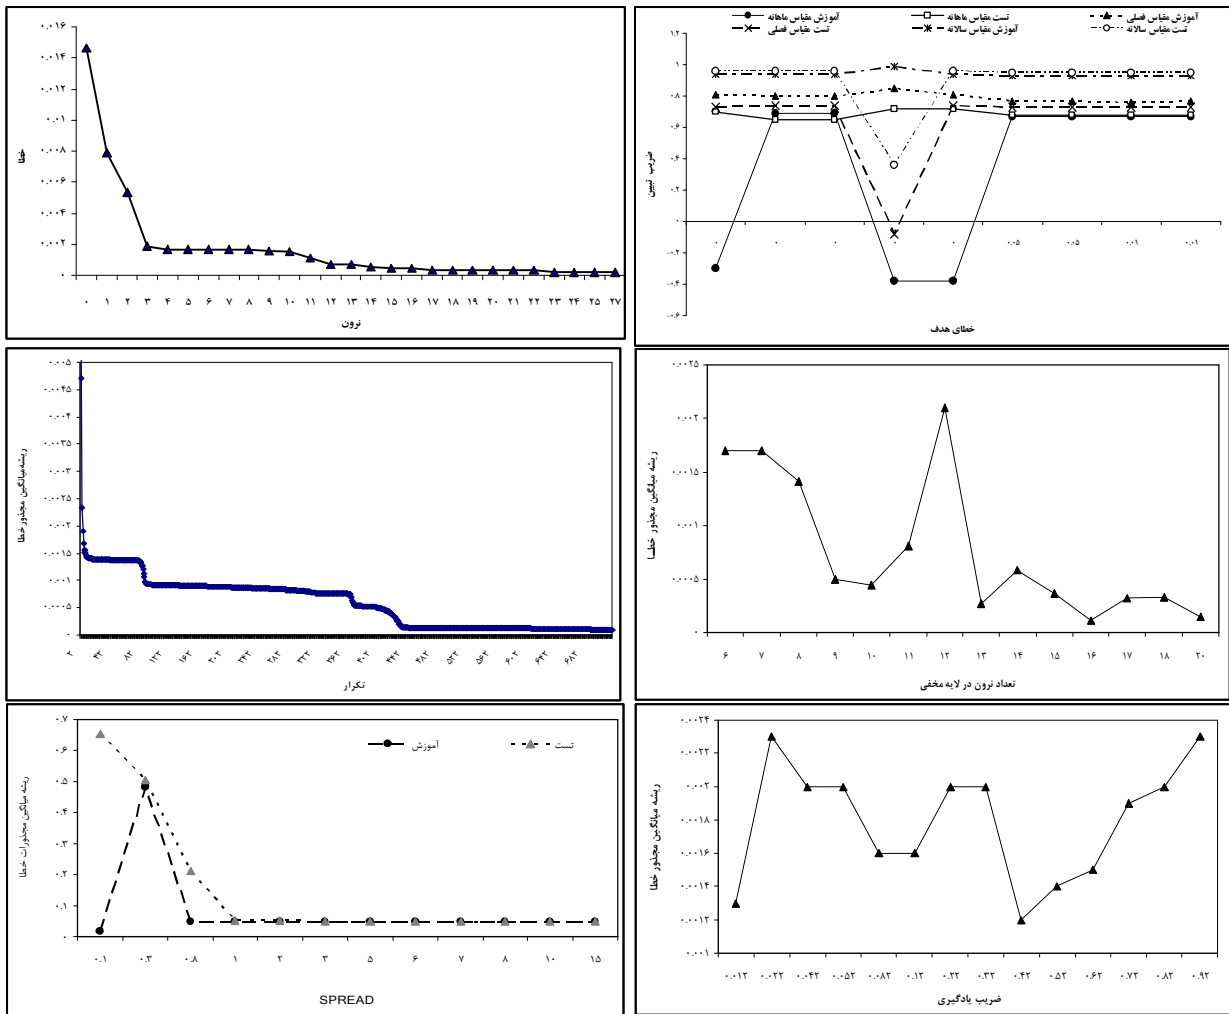
جداول ۶، ۷ و ۸ به ترتیب نتایج حاصل از شبیه‌سازی مدل‌های مختلف بکار رفته در تحقیق حاضر شامل MLP و RBF در ایستگاه‌های هیدرومتر و مقیاس‌های زمانی ماهانه (جدول ۶)، فصلی (جدول ۷) و سالانه (جدول ۸) ارائه شده است. در جداول ۶، ۷ و ۸ مقادیر دقت سنجی مختلفی برای ارزیابی مدل نهایی بکار رفته است.

نتایج جدول ۶ نشان می‌دهد که در مقیاس ماهانه ایستگاه بریم با میزان ضریب تبیین ۰/۴۵ برای شبکه‌ی RBF و ۰/۴۶ برای شبکه‌ی MLP بهترین کارایی را ارائه داده است. ایستگاه‌های سیدآباد و بطاری در اولویت‌های بعدی قرار دارند. هم‌چنین ایستگاه کتا با میزان ضریب تبیین ۰/۱۴ برای شبکه‌ی RBF و ۰/۱۵ برای شبکه‌ی MLP بدترین میزان کارایی را در بین مدل‌های مختلف ارائه داده است.

به طوری که از نتایج جدول ۳، ۴ و ۵ قابل مشاهده است پارامترهای مدل‌ها نقش تعیین کننده در میزان دقت نهایی شبکه‌ها ایفا می‌کنند مقادیر پارامترهای مدل‌ها برای شبکه‌های عصبی با بهینه‌سازی و کنترل مقادیر خطا با تغییر مقدار پارامترها بدست آمده‌اند. به طوری که برای پارامترهای مهم و مؤثر بر کارایی و دقت شبکه‌ها مقادیر ثابت و مشخصی را نمی‌توان ارائه داد و برای شرایط مختلف زمین شناسی و اقلیمی مقادیر مختلفی بعنوان مقادیر بهینه استخراج شده‌اند.

در شبکه‌ی نوع RBF مهم‌ترین پارامترها شاخص SPREAD و خطای هدف می‌باشد که با تغییر آن‌ها تغییر قابل توجهی در نتایج مقادیر تخمینی صورت می‌گیرد همان‌طور که از نتایج جداول ۳، ۴ و ۵ استنباط می‌شود، مقادیر SPREAD بین ۱ تا ۵ بهترین مقادیر در ایستگاه‌ها و مقیاس‌های مختلف می‌باشد. مقادیر SPREAD بیش از ۵ تغییر قابل توجهی در میزان خطا و کارایی شبکه ایجاد نمی‌کند. تغییرات مقدار SPREAD برای کارایی آموزش و تست نیز متفاوت می‌باشد به طوری که در شکل ۵ مشاهده می‌گردد برای مقادیر SPREAD در حد ۰/۱ میزان خطا برای آموزش قابل توجه می‌باشد در صورتی که برای تست این میزان حداقل می‌باشد.

میزان خطای هدف نیز بین مقادیر صفر تا ۰/۰۵ بهترین کارایی را ارائه داده است در حالی که در اکثر ایستگاه‌ها و مقیاس‌ها میزان خطای صفر بهترین کارایی و کمترین میزان خطا را ارائه داده است. همان‌طور که در شکل ۵ مشاهده می‌گردد تغییرات خطا با تغییر میزان خطای هدف در مراحل مختلف آموزش و تست و برای



شکل ۵- تغییرات خطا با تغییر پارامترهای شبکه‌های عصبی نوع MLP و RBF

فصلی بیشتر از ماهانه بوده است. بطور نمونه در شکل ۶ مقادیر محاسباتی و مشاهداتی رواناب در دو ایستگاه بطاری و زهره نمایش داده شده است. در جدول ۹ ارزیابی نهایی مدل‌ها برای مقیاس‌ها، ایستگاه‌ها و شبکه‌های مختلف ارائه شده است. نتایج حاصل از جدول ۹ نشان می‌دهد که برای ایستگاه‌ها و مقیاس‌های مختلف هر کدام از شبکه‌های MLP و RBF برتری‌های را در شبیه‌سازی ارائه داده‌اند به طوری که در مجموع مقیاس‌های ماهانه، فصلی و سالانه شبکه RBF دارای بیشترین تعداد برتری بوده است. همچنین ارزیابی رتبه‌بندی مدل‌ها نشان می‌دهد که در مجموع ایستگاه پل بریم در اولویت از لحاظ دقت پیش‌بینی و ایستگاه کتا در اولویت آخر قرار دارد.

نتایج جدول ۷ نشان می‌دهد که در مقیاس فصلی به مانند مقیاس ماهانه ایستگاه پل بریم با میزان ضریب تبیین ۰/۵۸ برای شبکه‌ی RBF و ۰/۵۶ برای شبکه‌ی MLP بهترین کارایی را ارائه داده است. ایستگاه‌های سیدآباد و بطاری در اولویت‌های بعدی قرار دارند. همچنین ایستگاه کتا با میزان ضریب تبیین ۰/۱۵ برای شبکه‌ی RBF و ۰/۱۷ برای شبکه‌ی MLP بدترین میزان کارایی را در بین مدل‌های مختلف ارائه داده است. نتایج جدول ۸ نشان می‌دهد که در مقیاس سالانه همانند مقیاس ماهانه و فصلی ایستگاه پل بریم بهترین کارایی را ارائه داده است. ایستگاه‌های سیدآباد و بطاری در اولویت‌های بعدی قرار دارند. در مجموع میزان دقت و کارایی مقیاس سالانه بیشتر از مقیاس فصلی و مقیاس



جدول ۶- مقادیر دقت سنجی کلی در میان مدل‌ها و ایستگاه‌های مختلف در مقیاس ماهانه

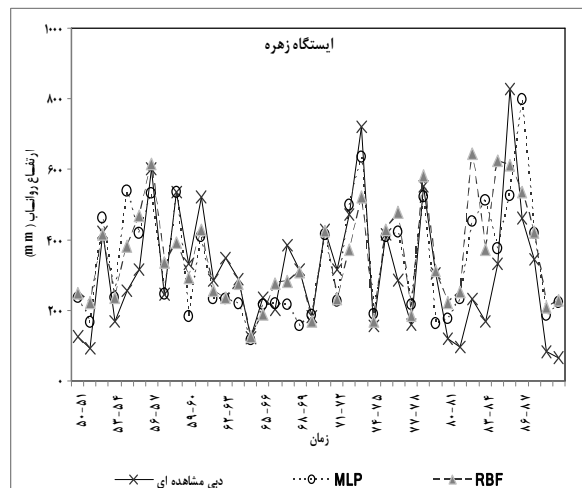
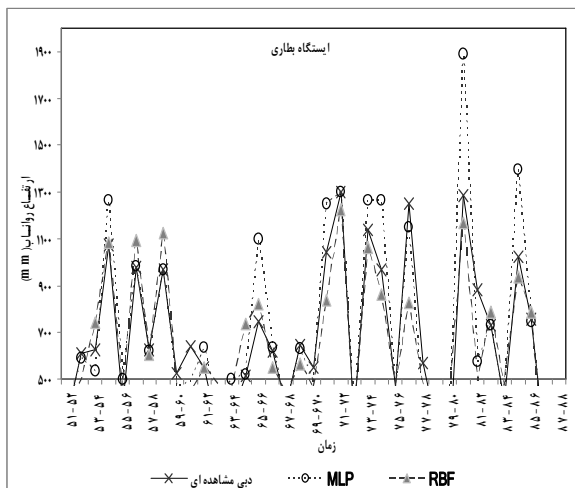
MLP				RBF				
R <sup>2</sup>	CE	RMSE	MAE	R <sup>2</sup>	CE	RMSE	MAE	
۰/۵۴	۰/۵۲	۱۴/۶	۱۰/۴۴	۰/۵۴	۰/۵۲	۱۳/۹	۹/۶۶	پل بریم
۰/۵۳	۰/۵۱	۷/۶۶	۵/۱۱	۰/۵۰	۰/۴۵	۸/۱۱	۵/۶۰	نازمکان
۰/۳۱	۰/۳۱	۶۹/۰۶	۴۲/۳۱	۰/۳۴	۰/۳۳	۶۷/۷۷	۴۲/۳۰	زهره
۰/۴۱	۰/۴۱	۶/۲۰	۴/۲۰	۰/۴۲	۰/۴۲	۶/۱۰	۴/۱۰	سیدآباد
۰/۱۵	۰/۱۳	۲۹/۵	۱۸/۲۰	۰/۱۳	۰/۱۳	۲۹/۰۴	۱۹/۲۳	کتا
۰/۳۹	۰/۳۳	۱۸/۰۶	۱۰/۸۳	۰/۴۰	۰/۳۴	۱۸/۱۶	۱۰/۶۷	بطاری

جدول ۷- مقادیر دقت سنجی کلی در میان مدل‌ها و ایستگاه‌های مختلف در مقیاس فصلی

MLP				RBF				
R <sup>2</sup>	CE	RMSE	MAE	R <sup>2</sup>	CE	RMSE	MAE	
۰/۵۶	۰/۵۰	۱۳/۲۲	۹/۲۵	۰/۵۸	۰/۵۸	۱۲/۰۲	۹/۰۲	پل بریم
۰/۸۰	۰/۸۰	۱۲/۶	۸/۰۳	۰/۷۲	۰/۷۱	۱۵/۱۵	۱۱/۲۶	نازمکان
۰/۳۸	۰/۳۷	۵۸/۶۵	۳۶/۷۰	۰/۳۴	۰/۳۵	۶۰/۲۰	۴۱/۰۱	زهره
۰/۵۲	۰/۳۷	۵/۴۰	۳/۹۱	۰/۵۲	۰/۵۰	۴/۸	۳/۴۰	سیدآباد
۰/۱۸	۰/۱۸	۲۴/۰۵	۱۷/۴۰	۰/۱۵	۰/۱۵	۲۴/۸۰	۱۷/۲۰	کتا
۰/۴۷	۰/۴۶	۱۱/۵	۷/۶۰	۰/۵۸	۰/۵۷	۱۰/۳۰	۷/۱۹	بطاری

جدول ۸- مقادیر دقت سنجی کلی در میان مدل‌ها و ایستگاه‌های مختلف در مقیاس سالانه

MLP				RBF				
R <sup>2</sup>	CE	RMSE	MAE	R <sup>2</sup>	CE	RMSE	MAE	
۰/۷۱	۰/۳۲	۳۲۷/۰۲	۲۵۷/۸۹	۰/۸۹	۰/۸۹	۱۳۰/۰۳	۸۷/۷۰	پل بریم
۰/۸۷	۰/۸۷	۷۶/۰۰	۴۴/۵۵	۰/۸۲	۰/۷۹	۸۸/۱۱	۶۰/۱۰	نازمکان
۰/۳۹	۰/۰۳	۱۷۲/۷۳	۷۱/۷۳	۰/۵۰	۰/۴۷	۱۲۹/۱۶	۹۷/۱۱	زهره
۰/۷۱	۰/۳۳	۷۶/۵	۶۲/۲۲	۰/۷۲	۰/۱۲	۹۴/۰۰	۷۰/۱۲	سیدآباد
۰/۳۳	۰/۰۶	۱۴۶/۳۰	۱۰۱/۶۶	۰/۴۰	۰/۳۸	۱۱۹/۱۷	۸۷/۹۸	کتا
۰/۸۳	۰/۷۰	۱۷۵/۳	۱۱۵/۷	۰/۷۸	۰/۷۸	۱۵۳/۵	۱۱۵/۶	بطاری



شکل ۶- مقایسه بین مقادیر مشاهداتی و محاسباتی ارتفاع رواناب سالانه در دو ایستگاه بطازی و زهره

جدول ۹- ارزیابی نهایی مدل‌های مختلف در ایستگاه‌ها و مقیاس‌های مختلف

رتبه نهایی	مدل نهایی	سالانه	فصلی	ماهانه	
۱	RBF	RBF	RBF	RBF	پل بریم
۲	MLP	MLP	MLP	MLP	نازمکان
۵	RBF	RBF	MLP	RBF	زهره
۴	RBF	MLP	RBF	RBF	سیدآباد
۶	MLP	RBF	MLP	MLP	کتا
۳	RBF	MLP	RBF	RBF	بطاری

### نتیجه گیری

داده‌اند به طوری که Borhani Darian & Fatehi Marj (2008) و Alp & Kerem Cigizoglu (2009) نتیجه گرفتند که شبکه‌ی MLP نسبت به RBF دقت بالاتری در شبیه سازی رواناب ارائه داده است.

علت دقت شبکه‌ی در مقیاس کوچکتر به مقیاس بزرگتر یعنی از ماهانه به سالانه، تغییرات مقدار بارندگی در مقیاس‌های کوچکتر مثل ماهانه می‌باشد در مقیاس‌های زمانی بزرگتر تأثیر دیگر متغیرها کمتر و تأثیر میزان بارندگی در تغییرات دبی قابل وضوح‌تر است به همین علت در تحقیق حاضر که با هدف مدل‌سازی بارش - 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 در مقیاس‌های کوچکتر شبکه‌های عصبی بیشتر برای مقادیر صفر آموزش دیده می‌شود و به همین علت در رابطه شناخته شده بیشتر این مقادیر را می‌تواند شبیه‌سازی کند ولی در مقیاس سالانه این موضوع کمتر به چشم می‌خورد که همین امر باعث افزایش دقت مدل‌ها در مقیاس سالانه شده باشد. همچنین در بین ایستگاه‌های مختلف همان طور که گفته شد ایستگاه پل برم، سید آباد، بطاری و نازمکان دقت بیش‌تر از دیگر ایستگاه‌ها بوده است در حالی که ایستگاه‌های زهره و کتا دقت پایین‌تری در پیش بینی رواناب را نشان داده است. علت دقت بالای مدل‌ها در ایستگاه پل بریم، سیدآباد، بطاری و نازمکان احتمالاً به علت کوچک بودن حوزه آبریز (کمتر از ۹۰۰

در جدول ۷، ۸ و ۹ مقادیر پارامترهای دقت سنجی برای کل داده‌ها یعنی ریشه خطای مطلق (MAE)، میزان ریشه میانگین مجموع مربعات خطا (RMSE)، ضریب کارایی (CE) و ضریب تبیین ( $R^2$ ) برای انتخاب مدل برتر استفاده گردید.

در مورد MAE و RMSE هر چه مقدار نزدیک به صفر باشد و عدد کوچک‌تر، نشان دهنده کارایی بالاتر، در حالی که در مورد CE و  $R^2$  هرچه مقدار نزدیک به یک باشد کارایی مدل بالاتر خواهد بود. همان طور که از نتایج این جداول بر می‌آید تنها با اکتفا به ضریب تبیین ( $R^2$ ) نمی‌توان مدل برتر را انتخاب کرد به طوری در بعضی موارد مدل‌های با ضریب تبیین بالا میزان کارایی پایین بوده است و برعکس. مدل MLP در بعضی ایستگاه‌ها برای دامنه‌ای از مقادیر پایین‌تر دبی، میزان دبی را تقریباً یکسان تخمین زده است به طور مثال در ایستگاه پل بریم برای ارتفاع روانابی بین ۳۰۰ تا ۶۰۰ میلی‌متر در سطح حوزه، میزان دبی حدود ۴۰۰ تخمین زده شده است که باعث کاهش کارایی مدل شده است. در صورتی که در همین ایستگاه مدل RBF با دقت و همچنین صحت بالایی توانسته است مقادیر دبی را شبیه‌سازی کند. در این مدل تقریباً هر چهار پارامتر ارزیابی کارایی (جدول ۹)، بهتر از بقیه مدل‌ها است.

در مطالعه حاضر مقایسه بین دو نوع شبکه RBF و MLP، شش مقیاس مکانی و سه مقیاس زمانی مدل سازی صورت گرفت که در مجموع شبکه‌ی نوع RBF، ایستگاه پل بریم و مقیاس سالانه بهترین کارایی را ارائه داده است. در زمینه مقایسه بین این دو نوع شبکه محققان مختلف در مناطق مختلف نتایج گوناگونی ارائه

تولید شده ناشی از برف می‌باشد و در تحقیق فعلی مقدار رواناب حاصل از برف لحاظ نگردیده و بهمین علت میزان رواناب شبیه سازی شده از کارایی، دقت و اعتبار پایین‌تری برخوردار است.

در مجموع می‌توان بیان داشت که شبکه عصبی مصنوعی به علت برخورداری از توانایی تشخیص الگو، رابطه خوبی میان ورودی و خروجی داده های پدیده مورد نظر برقرار می‌کند هم‌چنین حساسیت شبکه عصبی مصنوعی به خطای موجود در داده‌های ورودی کم است. Soltani (2002) و Ashrafzadeh (2008) دلیل این امر را به دلیل پردازش پخشیده اطلاعات می‌دانند به‌طوری‌که فرایند پردازش کاملاً موازی صورت گرفته و به جای این که تمام بار محاسبه به یک یکان پردازش گر تحمیل شود تعداد بسیاری از یکان‌های پردازش گر همزمان عمل کرده و با کم کردن سهم هر یک از آنها تأثیر منفی کم‌تری در عملکرد و خروجی شبکه ایجاد می‌شود ( Menhaj, 2002).

کیلومتر مربع) و متأثر شدن دبی از بارش، هم‌چنین وجود ایستگاه باران‌سنجی در محل ایستگاه هیدرومتری می‌باشد و در مقابل علت پایین‌تر بودن کارایی مدل‌ها در ایستگاه زهره و کتا از یک طرف به‌علت بزرگی حوزه آبریز بالا دست هیدرومتر و متأثرپذیری دبی از عوامل مختلف از جمله وضعیت آب‌های زیرزمینی، شرایط زمین شناسی و پوشش گیاهی و هم‌چنین استفاده‌های دیگر از آب رودخانه به منظور کشاورزی و باغبانی و هم‌چنین نبود ایستگاه باران‌سنجی در محل ایستگاه هیدرومتری و استفاده از ایستگاه‌های هم‌جوار و روش تیسن‌بندی برای بدست آوردن میانگین بارندگی در محل هیدرومتر می‌باشد، که دقت پایین‌تری از زمانی است که باران سنج در محل هیدرومتر واقع شده است.

در نهایت علت پایین بودن کارایی و بالا بودن میزان خطا در ایستگاه کتا بجز بزرگ بودن حوزه نسبت به ایستگاه‌های دیگر و تأثیرپذیری دبی از عوامل مختلف، علت دیگر این است که با توجه به این که این ایستگاه در پایین دست حوزه آبریز کوه دنا می‌باشد و این منطقه دارای بارش‌های برفی زیادی است و بخش زیادی از رواناب

## References

- [1] 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, *Journal of Hydrological Processes*, 14. 2157–2172.
- [2] Alp.M and Kerem Cigizoglu. H., 2009. Suspended sediment load simulation by two artificial neural network methods using hydrometeoro- logical data. *Environmental Modelling and Software*, 22: 2-13.
- [3] Antar. A., I., Elassiouti. and M. N. Allam, 2006: Rainfall-runoff modelling using artificial neural networks technique: a Blue Nile catchment case study. *Hydrological Processes Journal*. 20:1201– 1216.
- [4] Ashrafzadeh. A 2008. Application of artificial neural networks in evaporation estimation on evaporite basins. Master's thesis. Tehran University. 101 p. (in persion).
- [5] Borhani Darian, A. R., Fatehi Marj. A. 2008. Application of artificial neural network in prediction of streamflow using climate index in Nazlochae watershed. Tabriz University. (51):25-36. (in persion).
- [6] Dawson., C.W., Wilby., R.L., 2001. Hydrological modelling using artificial neural networks. *Progress in Physical Geography*, Vol. 25, 1: 80-108 (2001)
- [7] Hagan, M.T. and , M.B. Menhaj, 1994. Training feed forward networks with the Marquardt algorithm. *IEEE Trans Neural Netw* . 6: 989–993.
- [8] Jahangeer, A.R. Raeini, M. Ahmadi1, M.Z. 2008. Comparison of artificial neural networks (ANN) simulation of rainfall-runoff process with HEC-HMS model in Kardeh watershed. *Journal of Soil and Water (Agricultural Sciences and Technology)*, Volume 22, Number 2,72-84. (in persion).
- [9] Karamoz.M. Araghi nezhad.SH. 2005. Advanced Hydrology. Amirkabir University (Tehran Polytechnic). 44 p. (in persion).
- [10] Méndez, C. M., González Manteiga W., Febrero Bande, M., Manuel. J., Sánchez P. and R. Lozano Calderón, 2004: Modelling of the monthly and daily behaviour of the runoff of

the Xallas river using Box–Jenkins and neural networks methods . *Journal of Hydrology*. 296: 38–58.

[11] Menhaj, m. B. In 2002. *Fundamentals of Artificial Neural Networks (computational intelligence)*. The first volumenetwork. *Journal of Hydrology*. 285: 96–113.

[12] Riad, S., and Mania, J., 2004: Rainfall-runoff model using an artificial neural network approach; *Mathematical and Computer Modeling*. 40: 839–846.

[13] Soltani. SA., 2002: comparison of artificial neural networks and empirical models in rainfall-runoff estimation. Master's thesis. Tarbiat Modarres University, 98 p. (in persian).

[14] Tokar, A.S., Markus, M., 2000. *Precipitation*. Amirkabir University Publication Center. 715 p. (in persian).

[15] Rahmani, A. and Sedehi, M. 2004. Prediction of Groundwater Level Changes in the Plain of Hamedan-Bahar Using Time Series Model. *Journal of Water and Wastewater*.(2); 49-15. (in persian).

[16] Tombul, M. and Oğul, E., 2006: Modeling of Rainfall-Runoff Relationship at the Semi-arid Small Catchments Using Artificial Neural Networks. *Lecture Notes in Control and Information Sciences*. 309-318.

[17] Zare Abyaneh. H. Bayat Varkeshi.M. 2011. Evaluation of Artificial Intelligent and Empirical Models in Estimation of Annual Runoff. *Journal of Water and Soil Vol. 25, No.2, May -Jun 2011, p. 365-379.* (in persian).

[18] Zhou, H. C. Peng, Y. and G. H. Liang, 2008: The Research of Monthly Discharge Predictor-corrector Model Based on Wavelet Decomposition *Water Resour Manage* 22: 217–227.

## Evaluating the efficiency of two artificial neural network approach (MLP and RBF) for rainfall-runoff modeling

- 1- M. khazaei, PhD Student of Watershed Management, Hormozgan University  
khazaei.phd@hormozgan.ac.ir
- 2- M.R. Mirzaei, Assisstante Professor, Natural Resources and Environment Institute ,Yasuj University
- 3- A. Malekian, Assisstante Professor, Faculty of Natural Resources, Tehran University

Received: 10 Dec 2013

Accepted: 05 May 2014

### Abstract

this study aims to compare two different models of artificial neural network's approach (MLP and RBF) for rainfall-runoff modeling in Kohgiluyeh and Boyerahmad Province. First, six hydrometric gauges were selected in which the data were available in sufficient time periods. Then, the runoff-rainfall relationship was modeled at three different time scales: monthly, quarterly and annually. Furthermore, using "trial by error" method to achieve the lowest root mean square error (RMSE), optimal parameters were obtained for both MLP and RBF models. The models' efficiencies were taken into account using four criteria, including root mean squared error (RMSE), coefficient of determination ( $R^2$ ), mean absolute error (MAE) and efficiency coefficient (CE). Results show that the performance of both models may vary at different time scales, and gauge while the RBF model shows better results in comparison to the MLP model. The best efficiency was provided using annual data. Prediction trends of these models (ANNs & time scales) were almost identical to different gauges so that the highest and lowest observed accuracies were in Polberim, and Saiedabad gauges consecutively.

**Keywords:** Artificial Neural Networks, Kohgiluyeh and Boyerahmad, Modeling, Rainfall Runoff, Time Scale, Watershed