تحلیل عدم قطعیت مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان در تخمین بارش

بابک محمدی[۱] روزبه موذن‌زاده[۲]

۱. دانشجوی کارشناسی ارشد مهندسی منابع آب دانشگاه تبریز

۲. استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه صنعتی شاهرود

تاریخ دریافت: ۹۵/۰۹

تاریخ پذیرش: ۹۵/۱۱

چکیده

در این تحقیق سعی گردید، ترکیب ورودی و مدل مناسب برای تخمین بارش‌های شهرستان شاهرود تعیین گردد. برای رسیدن به این هدف از داده‌های ماهانه هواشناسی شامل تبخیر، دما، رطوبت نسبی هوا، تابش‌های خورشیدی، سرعت باد در دوره آماری ۱۳۴۲ تا ۱۳۹۴ و مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان استفاده شده است. ۷۵ درصد از داده‌ها برای واسنجی و ۲۵ درصد دیگر جهت اعتبارسنجی مدل‌ها استفاده شده است. در این تحقیق از شبکه عصبی مصنوعی پرسپترون چند لایه با تابع تانژانت سیگموئید و ۱ تا ۳۰ نرون در لایه پنهان و از مدل ماشین بردار پشتیبان با تابع کرنل پایه شعاعی جهت تخمین بارش‌های منطقه شهرستان شاهرود استفاده شده است. عملکرد هر یک از مدل‌ها با استفاده از شاخص‌های آماری مجذور میانگین مربعات خطا و ضریب همبستگی ارزیابی شده است و عدم قطعیت مدل‌ها نیز به ازای دو پارامتر d-factor و p-factor تعیین گردیده است. با توجه به این که هر دو مدل عملکرد مناسبی در تخمین بارش داشته‌اند، ولی مدل ماشین بردار پشتیبان با خطا و عدم قطعیت کمتری نسبت به مدل شبکه عصبی مصنوعی، عملکرد بهتری در تخمین بارش شهرستان شاهرود داشته است. بنابراین مدل ماشین بردار پشتیبان می‌تواند به عنوان یک مدل بسیار مناسب در تخمین بارش مورد استفاده قرار گیرد.

واژه‌های کلیدی: تخمین بارش، شاهرود، شبکه عصبی مصنوعی، عدم قطعیت، ماشین بردار پشتیبان

مقدمه

مدیریت جامع و برنامه‌ریزی صحیح استفاده از منابع آب زیرزمینی بدون اطلاع درست از نحوه توزیع کمی نزولات جوی میسر نمی‌گردد. با توجه به این که نزولات جوی در اکثر مناطق ایران تامین کننده نیازهای آب‌های زیرزمینی، مخازن سدها، شرب، کشاورزی و صنعت هستند، مدیریت این منابع بسیار حیاتی و حائظ اهمیت می‌باشد. بنابراین اطلاع دقیق از نحوه توزیع بارش در حوضه آبریز می‌تواند به عنوان یک گام اساسی در مدیریت این منابع در نظر گرفته شود. به علت عدم وجود ایستگاه‌ها باران سنجی و هواشناسی در همه مناطق و نداشتن اطلاعات بارش دقیق برای همه مناطق ناچار به تخمین بارش از روی داده‌های در دسترس و یا از روی سایر پارامترهای مرتبط هستیم. بنابراین جهت بر طرف کردن این مشکل، در دهه‌های اخیر مدیران و محققان با استفاده از روش‌های ریاضی، آماری، هوشمند و ... مقادیر کمی بارش را با دقت قابل قبولی مورد تخمین قرار می‌دهند.

در زمینه تخمین بارش در داخل و خارج از کشور مطالعات زیادی انجام گرفته است که در ادامه به بخشی از آن‌ها اشاره می‌گردد. غلامی و جعفری (۱۳۸۹) در پژوهشی با استفاده از روش رگرسیون چند متغیره[۲] و شبکه عصبی مصنوعی[۳] بارش‌های استان مازندران را شبیه‌سازی کردند. نتایج به دست آمده از هر دو روش نشان داد که پارامترهای

[1] babakmsh@yahoo.com نویسنده مسئول: بابک محمدی

[2] Multivariate Regression

[3] Artificial Neural Network

[Downloaded from jircsa.ir on 2026-11-24]

[DOR: 20.1001.1.24235970.1396.5.1.6.0]

هواشناسی مرتبط و فاصله از دریا از عوامل اصلی در تخمین بارش می‌باشند. البته کارایی شبکه عصبی مصنوعی در برآورد نزولات جوی مناسب‌تر از روش رگرسیون چند متغیره بوده است. زارع ابیانه و همکاران (۱۳۹۰)، بارش‌های دشت همدان را با استفاده از شبکه عصبی مصنوعی و اثر تفکیک داده‌ها بر دقت پیش‌بینی آن مورد بررسی قرار دادند. نتایج حاکی از توانایی بالای شبکه عصبی مصنوعی[۴] در پیش‌بینی بارش بوده است. در پژوهشی توسط Kheradpisheh و همکاران (2015) کیفیت بارش‌های بهاباد یزد را با استفاده از شبکه عصبی مصنوعی مورد بررسی قرار دادند. در این پژوهش از شبکه عصبی مصنوعی برای تخمین نزولات جوی استفاده شده است. نتایج نشان‌دهنده این موضوع بود که مدل شبکه عصبی مصنوعی در تخمین بارش عملکرد مناسبی داشته است. در تحقیقی توسط Khaki و همکاران (2015) کاربرد شبکه عصبی مصنوعی و سیستم نروفازی[۵] را برای تخمین بارش مورد بررسی قرار دادند. در این تحقیق از شبکه عصبی مصنوعی و مدل سیستم استنتاجی عصبی- فازی تطبیقی برای پیش‌بینی بارش‌های واقع در حوضه لنگت مالزی استفاده شده است. نتایج حاکی از عملکرد بهتر مدل سیستم استنتاجی عصبی- فازی تطبیقی بوده است. Ghorbani و همکاران (2016) در تحقیقی عملکرد مدل‌های شبکه عصبی مصنوعی پرسپترون چندلایه[۶] و تابع پایه شعاعی را با ماشین بردار پشتیبان مقایسه کرده‌اند. آن‌ها عملکرد این مدل‌ها را در پیش‌بینی جریان ماهانه ایستگاه‌ها هیدرومتری صفاخانه، سنته و پل آنیان که در حوضه آبریز زرینه‌رود واقع هستند مورد ارزیابی قرار دادند. نتایج نشان-دهنده عملکرد بهتر شبکه عصبی پرسپترون چند لایه و تابع پایه شعاعی نسبت به مدل ماشین بردار بوده است و همچنین نتایج حاکی از عدم قطعیت پایین مدل ماشین بردار پشتیبان نسبت به دو مدل دیگر برای پیش‌بینی جریان رودخانه بوده است.

با توجه به مباحث ذکر شده، اهمیت تعیین وضعیت بارش‌ها در تصمیم‌گیری‌ها و سیاستگذاری‌های مختلف در زمینه‌های آب، محیط زیست، اقتصاد، توسعه شهری-روستایی و ... آشکار شده است. بنابراین در این تحقیق سعی گردید با استفاده از مدل هوشمند شبکه عصبی مصنوعی (ANN) و مدل ریاضی ماشین بردار پشتیبان (SVM) و با استفاده از پارامترهای هواشناسی شامل تبخیر، دما، رطوبت نسبی هوا، تابش‌های خورشیدی، سرعت باد، مقدار بارش شهرستان سار مورد تخمین قرار گیرد. با توجه به مطالعات صورت گرفته تا کنون عدم قطعیت شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان در شبیه‌سازی بارش مورد بررسی قرار نگرفته است، که این امر یکی از نوآوری‌های این تحقیق محسوب می‌گردد. بنابراین در ادامه عدم قطعیت ترکیب‌های برتر مدل‌ها در تخمین بارش تعیین گردیده است.

مواد و روش‌ها

داده‌ها و منطقه مورد مطالعه

یکی از استان‌های دارای کشاورزی ایران، استان سمنان است که این استان به عنوان قطب تولید پسته و زردآلو در ایران شناخته شده است. توزیع ناهماهنگ نزولات جوی و نقش آب در کشاورزی این منطقه، ضرورت بررسی و مطالعه سیستماتیک منابع آب را ایجاب نموده است. در این تحقیق جهت تخمین بارش از داده‌های ماهانه شامل، تبخیر، دما، رطوبت نسبی هوا، تابش‌های خورشیدی، سرعت باد استفاده شده است. در این تحقیق از داده‌هایی که در دوره آماری ۱۳۴۲ تا ۱۳۹۴ کامل، به صورت ماهانه و صحیح بوده‌اند استفاده گردیده است. بدین منظور از داده‌های هواشناسی نامبرده شده از ایستگاه سینوپتیک هواشناسی شهرستان شاهرود استفاده گردید. این داده‌ها به دو بخش صحت‌سنجی و آموزش تقسیم گردیده‌اند که ۷۵ درصد داده‌ها برای آموزش و ۲۵ درصد دیگر برای بخش صحت‌سنجی استفاده شده

[4] Artificial Neural Network
[5] Neuro-Fuzzy
[6] Multilayer Perceptron

[Downloaded from jircsa.ir on 2026-11-24]
[DOR: 20.1001.1.24235970.1396.5.1.6.0]

است. با توجه به ورودی‌های مورد نظر، جدول (۱) به عنوان مجموعه ترکیب‌های ورودی هر یک از مدل‌های تخمین‌گر تعیین گردید.

جدول (۱): ترکیب‌های ورودی مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان

شماره ترکیب	پارامترهای ورودی
۱	دما
۲	دما، تبخیر
۳	دما، تبخیر، رطوبت نسبی
۴	دما، تبخیر، رطوبت نسبی، تابش خورشیدی
۵	دما، تبخیر، رطوبت نسبی، تابش خورشیدی، سرعت باد

شبکه عصبی پیشرو با آموزش مارکورات-لوانبرگ

از اوایل دهه ۱۹۹۰ تا کنون، این شبکه‌های عصبی مصنوعی در زمینه هیدرولوژی نیز به طور موفقیت‌آمیز به کار گرفته شده که از آن جمله می‌توان به مدل کردن فرآیندهای بارش-رواناب، پیش‌بینی جریان رودخانه، مدل کردن آب زیرزمینی، کیفت آب، پیش‌بینی بارندگی و ... اشاره کرد (Dams et al., 2007). حدود ۹۰ ٪ شبکه‌هایی که در مسائل هیدرولوژی کاربرد دارد شبکه‌های پیشرو هستند (Coulibaly et al., 2000). معماری معمول این شبکه متشکل از سه لایه ورودی، پنهانی و خروجی است. تعداد نرون‌های موجود در لایه ورودی و خروجی بستگی به نوع مسئله دارد ولی تعداد گره‌های لایه پنهان با سعی و خطا به دست می‌آید.

لازم به ذکر است که در تحقیق حاضر از تعداد نرون‌های ۱ تا ۳۰ برای لایه پنهان شبکه استفاده گردید تا از این طریق تاثیر ساختار مختلف شبکه بر عملکرد آن در شبیه‌سازی مقادیر کیفی آبخوان را مورد ارزیابی قرار داد. از آنجا که متداول‌ترین نوع توابع محرک تابع تانژانت سیگموئید می‌باشد بنابراین در این مطالعه از آن برای نگاشت اطلاعات از لایه ورودی به لایه پنهان و همچنین برای نگاشت اطلاعات از لایه پنهان به لایه خروجی استفاده شد.

مدل ماشین بردار پشتیبان

اولین کاربرد این روش در مسائل آب توسط Dibike و همکاران (2001) با شبیه‌سازی بارش- رواناب ارائه شد. ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه-سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد. در مدل رگرسیون بردار پشتیبان تابعی مرتبط با متغیر وابسته y که خود تابعی از چند متغیر مستقل x است، برآورد می‌شود. مشابه سایر مسائل رگرسیونی فرض می‌شود رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند f(x) به علاوه مقداری اغتشاش (خطای مجاز ε) مشخص شود.

$$f(x) = W^T.\phi(x) + b \quad (۱)$$

$$y = f(x) + noise \quad (۲)$$

چنانچه W بردار ضرایب، b ثابت مشخصه‌های تابع رگرسیونی و $\phi(x)$ نیز تابع کرنل باشد، آنگاه هدف پیدا کردن فرم تابعی برای f(x) است. این مهم با واسنجی مدل ماشین بردار پشتیبان توسط مجموعه‌ای از نمونه‌ها (مجموعه واسنجی) محقق می‌شود. برای محاسبه W و b لازم است تابع خطا (رابطه ۳) در مدل ماشین بردار پشتیبان رگرسیونی با در نظر گرفتن شرایط مندرج (قیود) در رابطه (۴) بهینه شود.

$$W^T.\phi(x_i) + b - y_i \le \varepsilon + \varepsilon_i^* \quad (۳)$$

$$\frac{1}{2}W^T.w + C\sum_{i=1}^{N}\varepsilon_i + C\sum_{i=1}^{N}\varepsilon_i^* y_i - W^T.\phi(x_i) - b \le \varepsilon + \varepsilon_i \qquad \varepsilon_i, \varepsilon_i^* \ge 0, i = 1,2,...,N \quad (۴)$$

[Downloaded from jircsa.ir on 2026-11-24]

[DOR: 20.1001.1.24235970.1396.5.1.6.0]

در معادلات بالا C عددی صحیح و مثبت است که عامل تعیین جریمه در هنگام رخ دادن خطای واسنجی مدل است، $\phi(x)$ تابع کرنل، N تعداد نمونه‌ها و دو مشخصه ε_i^* و ε_i متغیرهای کمبود هستند. در نهایت، تابع رگرسیون بردار پشتیبان را می‌توان به فرم زیر باز نویسی کرد:

$$f(x) = \sum_{i=1}^{N} \overline{\alpha_i}.\phi(x_i)^T.\phi(x) + b \qquad (۵)$$

در رابطه (۵)، $\overline{\alpha_i}$ میانگین ضرایب لاگرانژ است. محاسبه $\phi(x)$ در فضای مشخصه آن ممکن است بسیار پیچیده باشد. برای حل این مشکل روند معمول در مدل رگرسیون بردار پشتیبان انتخاب یک تابع کرنل است. با توجه به این که در ماشین بردار پشتیبان معمولا از تابع کرنل پایه شعاعی استفاده می‌گردد، در این تحقیق نیز از این تابع استفاده گردیده است. فرمول کرنل پایه شعاعی (رابطه ۶) در زیر آورده شده است (Kavzoglu & Colkesen, 2009).

$$k(x, x_i) = \exp\left(-\|x - x_i\|^2 / \sigma^2\right) \qquad (۶)$$

لازم به ذکر است فرآیند محاسبات ماشین بردار پشتیبان، بر اساس کدنویسی در محیط متلب انجام و پارامترهای تابع کرنل از طریق سعی و خطا بهینه شدند.

عدم قطعیت

برای به کمیت درآوردن عدم قطعیت، ضرایب p-factor و d-factor پیشنهاد شده است، که به ترتیب برای به کمیت در آوردن قدرت واسنجی و تحلیل عدم قطعیت می‌باشند (Abbaspour et al, 2007). جهت تعیین شاخص فاکتور عرض متوسط باند (d-factor) از رابطه (۷) استفاده می‌شود:

$$d - factor = \frac{\bar{\mathrm{d}}\,\mathrm{x}}{\sigma \mathrm{x}} \qquad (۷)$$

که در آن σx انحراف استاندارد متغیر مشاهده شده و $\bar{\mathrm{d}}\mathrm{x}$ عرض متوسط باند اطمینان می‌باشد که رابطه (۸) به دست می‌آید (۱).

$$\bar{\mathrm{d}}\,\mathrm{x} = \frac{1}{\mathrm{n}}\sum_{\mathrm{t}=1}^{\mathrm{K}} (\mathrm{X_U} - \mathrm{X_L}) \qquad (۸)$$

درصد داده‌های قرار گرفته در باند اطمینان ۹۵٪ نیز به صورت زیر محاسبه شده است:

$$\text{Bracketed by 95PPU} = \frac{1}{\mathrm{k}}\mathrm{count}\left(\mathrm{j}\middle|\mathrm{X_L^l} \le \mathrm{X_{reg}^l} \le \mathrm{X_U^l}\right) \times 100 \qquad (۹)$$

در فرمول بالا k تعداد داده‌های مشاهداتی، l نشان‌دهنده شماره داده مورد نظر که از یک تا k در نظر گرفته می‌شود. $\mathrm{X_L^l}$ و $\mathrm{X_U^l}$ مشخص‌کننده حدود اطمینان در باند اطمینان ٪۲/۵ و ٪۹۷/۵، $\mathrm{X_{reg}^l}$ مقدار مشاهده شده در روز l، j پارامتر شمارنده تعداد مقادیر مشاهده شده قرار گرفته در باند 95PPU می‌باشد. اگر همه مقادیر در داخل باند اطمینان عدم قطعیت قرار بگیرند Bracketed by 95PPU=100 خواهد شد (Ghorbani et al., 2016).

برای ارزیابی نتایج از شاخص‌های آماری مجذور میانگین مربعات خطا (RMSE)، ضریب همبستگی (CC) استفاده شده است.

نتایج و بحث

پس از تعیین ساختار هر یک مدل‌ها و تعیین ترکیب‌های ورودی، هر یک از دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان به ازای داده‌های آموزش مورد واسنجی قرار گرفته و سپس عملکرد مدل‌های آموزش دیده به ازای داده‌های بخش صحت‌سنجی ارزیابی گردیده است. در ادامه خلاصه نتایج مربوط به هر یک دو مدل در تخمین بارش ارائه شده است.

[Downloaded from jircsa.ir on 2026-11-24]

[DOR: 20.1001.1.24235970.1396.5.1.6.0]

نتایج مدل شبکه عصبی مصنوعی

پس از شبیه‌سازی و تخمین بارش، مقادیر آماره‌های ضریب‌همبستگی و مجذور میانگین مربعات خطا در دوره‌های واسنجی و صحت‌سنجی به دست آمده و در جدول (۲) نشان داده شده است. از بین نتایج بدست آمده، نتیجه ترکیب شماره پنج به دلیل داشتن مجذور میانگین مربعات خطای کمتر و ضریب همبستگی بالاتر نسبت به چهار ترکیب دیگر به عنوان ترکیب برتر در تخمین بارش انتخاب گردید. ترکیب شماره پنج در دوره صحت‌سنجی دارای ضریب همبستگی ۰/۸۸۴ و مجذور میانگین مربعات خطای ۱/۰۰۷ می‌باشد. پس از ترکیب شماره پنج، ترکیب شماره چهار با مجذور میانگین مربعات خطای برابر با ۱/۱۹۴ نتیجه بهتری را نسبت به سایر ترکیب‌ها داشته است.

جدول (۲): نتایج شبکه عصبی مصنوعی به ازای پنج ترکیب ورودی در تخمین بارش

شماره ترکیب	صحت‌سنجی		واسنجی		تعداد نرون بهینه
	RMSE (mm)	CC	RMSE (mm)	CC	
۱	۱/۵۱۱	۰/۷۱۴	۱/۳۶۸	۰/۷۵۸	۳
۲	۱/۲۲۶	۰/۸۲۳	۱/۰۹۷	۰/۸۵۳	۵
۳	۱/۲۰۳	۰/۸۳۰	۱/۰۹۸	۰/۸۵۲	۱۳
۴	۱/۱۹۴	۰/۸۳۴	۱/۰۵۷	۰/۸۶۴	۹
۵	۱/۰۰۷	۰/۸۸۴	۰/۹۵۰	۰/۸۹۲	۱۵

نتایج مدل ماشین بردار پشتیبان

پس از تخمین بارش توسط مدل ماشین بردار پشتیبان، مقادیر آماره‌های ارزیابی هر ترکیب در جدول (۳) نشان داده شده است. مدل ماشین بردار پشتیبان در تخمین بارش دارای عملکرد بسیار مناسبی بوده است. نتایج این مدل با افزایش تعداد ورودی‌ها بر ترکیب اول تغییر زیادی پیدا نمی‌کند، این موضوع نشان‌دهنده قدرت این مدل در تخمین بارش فقط بر اساس دمای متوسط هوا می‌باشد.

با توجه به جدول (۳) مدل ماشین بردار پشتیبان مقادیر بارش را به ازای ترکیب پنج بهتر از سایر ترکیب‌ها تخمین زده است. ترکیب پنج با مقادیر ضریب همبستگی و مجذور میانگین مربعات خطا به ترتیب برابر با ۰/۸۵۶و ۱/۱۱۵ در دوره صحت‌سنجی پارامتر بارش را تخمین زده است.

جدول (۳): نتایج ماشین بردار پشتیبان به ازای پنج ترکیب ورودی در تخمین بارش

شماره ترکیب	صحت‌سنجی		واسنجی	
	RMSE (mm)	CC	RMSE (mm)	CC
۱	۱/۱۳۶	۰/۸۵۰	۰/۹۲۰	۰/۸۹۹
۲	۰/۱۳۳	۰/۸۵۱	۰/۹۲۳	۰/۸۹۹
۳	۱/۱۲۸	۰/۸۵۴	۰/۹۵۰	۰/۸۹۲
۴	۱/۱۱۷	۰/۸۵۶	۰/۹۷۲	۰/۸۸۶
۵	۱/۱۱۵	۰/۸۵۶	۰/۹۷۳	۰/۸۸۶

لازم به ذکر است که با توجه به نتایج جدول (۳) مدل ماشین بردار پشتیبان قادر است تا پارامتر بارش را بدون دخالت دادن سایر پارامترها و با استفاده از کمترین اطلاعات (دمای متوسط هوا) با دقت بالایی مورد تخمین قرار دهد.

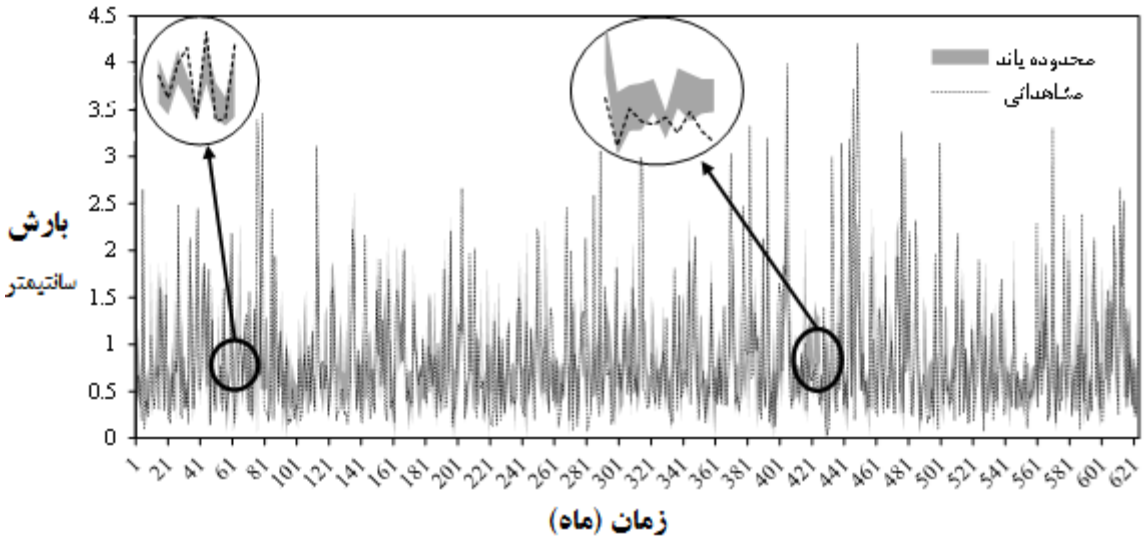
[Downloaded from jircsa.ir on 2026-11-24]
[DOR: 20.1001.1.24235970.1396.5.1.6.0]

مقایسه عملکرد و عدم قطعیت شبکه عصبی مصنوعی و ماشین بردار پشتیبان

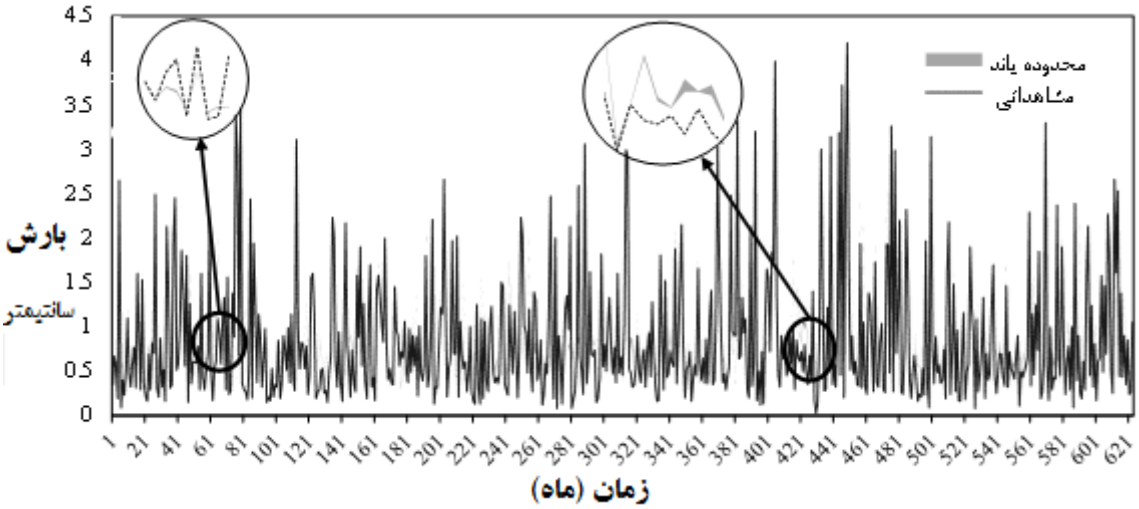
در ادامه بهترین عملکردهای مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان در تخمین هر یک از پارامترهای کیفی غلظت یون سولفات، غلظت یون کلر و هدایت الکتریکی مورد مقایسه قرار گرفته است که خلاصه نتایج آن در جدول (۴) نشان داده شده است.

جدول (۴): عدم قطعیت و نتایج ترکیب برتر هر یک از مدل‌ها در تخمین بارش

شماره ترکیب	مدل	واسنجی		صحت سنجی		فاکتورهای قطعیت	
		RMSE (mm)	CC	RMSE (mm)	CC	p-factor	d-factor
۵	ANN	۱/۰۰۷	۰/۸۸۴	۰/۹۵۰	۰/۸۹۲	۷۵٪	۰/۷۱۰
۵	SVM	۱/۱۱۵	۰/۸۵۶	۰/۹۷۳	۰/۸۸۶	۲۴٪	۰/۰۹۵



شکل (۱): نمودار مقادیر مشاهداتی و باند اطمینان محاسباتی برای مدل شبکه عصبی مصنوعی



شکل (۲): نمودار مقادیر مشاهداتی و باند اطمینان محاسباتی برای مدل ماشین بردار پشتیبان

با توجه به مقادیر p-factor و d-factor مدل شبکه عصبی مصنوعی در تخمین بارش معلوم می‌گردد که این مدل توانسته است با دقت قابل قبولی این مقادیر را مورد تخمین قرار دهد. همچنین مقادیر p-factor و d-factor مدل

[Downloaded from jircsa.ir on 2026-11-24]
[DOR: 20.1001.1.24235970.1396.5.1.6.0]

ماشین بردار پشتیبان نیز حاکی از دقت بالای این مدل در تخمین مقادیر بارش داشته است. البته مقایسه مقادیر p-factor و d-factor مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان نشان می‌دهد که مدل ماشین بردار پشتیبان دارای عدم قطعیت کمتری نسبت به مدل شبکه عصبی مصنوعی می‌باشد. عدم قطعیت کمتر می‌تواند یکی از معیارهای اساسی در انتخاب مدل برتر در تخمین پارامترهای مختلف مد نظر قرار گیرد، زیرا به نتایج مدلی که عدم قطعیت کمتری دارد بیشتر می‌توان استناد نمود. عدم قطعیت‌ها می‌تواند ناشی از ضعف مدل‌های تخمین‌گر، کیفیت نامناسب داده‌ها و ... باشد.

نتیجه‌گیری

با توجه به اهمیت اطلاع از وضعیت و توزیع مقادیر پارامتر بارش در مدیریت صحیح منابع آب، در این تحقیق سعی گردید تا با استفاده از مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان مقادیر بارش شهرستان شاهرود مورد تخمین قرار گیرد. در این راستا از ساختارهای مختلف مدل‌ها و همچنین ترکیب‌های ورودی مختلف استفاده گردید و در نهایت عدم قطعیت هر یک از مدل‌ها در تخمین پارامتر بارش تعیین گردیده است.

مقایسه عملکرد مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان در تخمین پارامتر بارش نشان داد که عملکرد مدل ماشین بردار پشتیبان در تخمین بارش از مدل شبکه عصبی مصنوعی بهتر بوده است. این بهبود نتایج در هر یک از دو بخش واسنجی و صحت‌سنجی و به ازای دو آماره مجذور میانگین مربعات خطا و ضریب همبستگی تایید شده است. مقادیر d-factor مدل شبکه عصبی مصنوعی در تخمین بارش برابر با ۰/۷۱۰ می‌باشد که حاکی از تخمین خوب این مدل و عدم قطعیت مناسب آن می‌باشد. همچنین مقادیر d-factor برابر با ۰/۰۹۵ توسط مدل ماشین بردار پشتیبان برای تخمین بارش به دست آمده است. مقایسه مقادیر d-factor هر یک از مدل‌ها که نشان‌دهنده میزان عدم قطعیت مدل‌ها بوده حاکی از عدم قطعیت بسیار کم مدل ماشین بردار پشتیبان می‌باشد.

با توجه به کلیه موارد ذکر شده مدل ماشین بردار پشتیبان در تخمین بارش نسبت به مدل شبکه عصبی مصنوعی عملکرد بهتری داشته و همچنین این مدل در تخمین این پارامتر دارای عدم قطعیت کمتری نسبت به مدل شبکه عصبی مصنوعی بوده است. بنابراین مدل ماشین بردار پشتیبان می‌تواند به عنوان یک مدل بسیار مناسب در تخمین پارامتر بارش در شهرستان شاهرود مورد استفاده قرار گیرد.

فهرست منابع

۱. زارع ابیانه، ح.، م. بیات ورکشی، س. اخوان و م. محمدی (۱۳۹۰). تخمین نیترات آب زیرزمینی دشت همدان - بهار با استفاده از شبکه عصبی مصنوعی و اثر تفکیک داده ها بر دقت پیش بینی. مجله محیط شناسی، دوره سی و هفتم - شماره ۵۸ علمی- پژوهشی. ISC، ۱۲ ص.، ۱۲۹- ۱۴۰.

۲. غلامی، و.، و م. جعفری (۱۳۸۹). بررسی عوامل مؤثر در شوری آب زیرزمینی به منظور ارائه مدل منطقه ای در سواحل جنوبی خزر، مجله پژوهش و سازندگی، شماره ۸۶، ص ۸۱-۸۷.

3. Abbaspour K.C., Yang J., Maximov I., Siber R., Bogner K., Mieleitner J., Zobrist. J. and Srinivasan R. *(2007). Modeling hydrology and water quality in the pre-alpine/alpine Thur watershed using SWAT*. Hydrology J. 333: 2-4. 413–430.
4. Coulibaly P., Anctil F. and Bobée B. *(2000). Daily reservoir inflow forecasting using artificial neural networks with stopped training approach*. Hydrology J. *230: 3-4. 244-257*.
5. Dams J., Woldeamlak S. and Batelaan O. *(2007). Forecasting land-use change and its impact on the groundwater system of the Kleine Nete catchment, Belgium*. Hydrology and Earth System Sciences J. *4: 6. 4265-4295*.
6. Dibike Y., Velickov S., Solomatine D. and Abbott M. *(2001). Model induction with of support vector machines: Introduction and applications*, Journal of Computing in Civil Engineering. *15: 3. 208- 216.*

[Downloaded from jircsa.ir on 2026-11-24]
[DOR: 20.1001.1.24235970.1396.5.1.6.0]

7. Ghorbani M.A., Ahmad Zadeh H., Isazadeh M., and Terzi O. *(2016). A comparative study of artificial neural network (MLP, RBF) and support vector machine models for river flow*. Environmental Earth Sciences J. *75: 476. 1-14.*
8. Kavzoglu T. and Colkesen I. *(2009). A kernel functions analysis for support vector machines for land cover classification.* Applied Earth Observation and Geoinformation J. 11: 5. 352-359.
9. Khaki M., Yusoff I. and Islami N. *(2015). Application of the Artificial Neural Network and Neuro-fuzzy System for Assessment of Groundwater Quality*. Clean Soil Air Water J. *43: 4. 551-560.*
10. Kheradpisheh Z., Talebi A., Rafati L., Ghaneian M.T. and Ehrampoush M.H. *(2015). Groundwater quality assessment using artificial neural network: A case study of Bahabad plain, Yazd, Iran*. Desert J. *20: 1. 65-71.*

Uncertainty analysis of artificial neural network models and support vector machine in rainfall estimation

Babak Mohammadi[1], Roozbeh Moazenzadeh[2]
[1] M.Sc student, Water Resources Engineering, University of Tabriz
[2] Assistant Professor, Department of Water Engineering, Faculty of Agriculture, Shahrood University of Technology

Received: 2016/11
Accepted: 2017/01

Abstract

In this research, we tried to determine the input composition and model for estimation of precipitation in Shahrood. To achieve this objective, monthly weather data including evaporation, temperature, relative humidity, solar radiation, wind speed during the period of 1963 to 1915, and artificial neural network and support vector machines have been used. 75% of the data was used for calibration and 25% for validation of the models. In this research, an artificial neural network of laminated perceptron with a sigmoid tangent function and 1 to 30 neurons in the hidden layer was used and a support vector machine model with radial base kernel function was used to estimate rainfall in Shahrood district. The performance of each model was evaluated using the statistical mean square error and correlation coefficient. The uncertainty of the models was also determined for two parameters, d-factor and p-factor. Considering that both models have good performance in rainfall estimation, the support vector machine model with less error and uncertainty than artificial neural network model has better performance in predicting rainfall in Shahrood. Therefore, a support vector machine model can be used as a very suitable model for precipitation estimation.

Keywords: Estimating precipitation, Shahrood, artificial neural network, uncertainty, SVM

[Downloaded from jircsa.ir on 2026-11-24]
[DOR: 20.1001.1.24235970.1396.5.1.6.0]