

تحلیل عدم قطعیت مدل های شبکه عصبی مصنوعی و ماشین بردار پشتیبان

در تخمین بارش

بابک محمدی^۱ روزبه مودن زاده^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 بارش های شهرستان شاهرود تعیین گردد. برای رسیدن به این هدف از داده های ماهانه هواشناسی شامل تبخیر، دما، رطوبت نسبی هوا، تابش های خورشیدی، سرعت باد در دوره آماری ۱۳۴۲ تا ۱۳۹۴ و مدل های شبکه عصبی مصنوعی و ماشین بردار پشتیبان استفاده شده است. ۷۵ درصد از داده ها برای واسنجی و ۲۵ درصد دیگر جهت اعتبارسنجی مدل ها 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 بارش های منطقه شهرستان شاهرود استفاده شده است. عملکرد هر یک از مدل ها با استفاده از شاخص های آماری مجذور میانگین مربعات خطا و ضریب همبستگی ارزیابی شده است و عدم قطعیت مدل ها 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 داشته اند، 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 می تواند به عنوان یک مدل بسیار مناسب در تخمین بارش مورد استفاده قرار گیرد.

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

مقدمه

مدیریت جامع و برنامه ریزی صحیح استفاده از منابع آب زیرزمینی بدون اطلاع درست از نحوه توزیع کمی نزولات جوی میسر نمی گردد. با توجه به این که نزولات جوی در اکثر مناطق ایران تامین کننده نیازهای آب های زیرزمینی، مخازن سدها، شرب، کشاورزی و صنعت هستند، مدیریت این منابع بسیار حیاتی و حائز اهمیت می باشد. بنابراین اطلاع دقیق از نحوه توزیع بارش در حوضه آبریز می تواند به عنوان یک گام اساسی در مدیریت این منابع در نظر گرفته شود. به علت عدم وجود ایستگاه ها باران سنجی و هواشناسی در همه مناطق و نداشتن اطلاعات بارش دقیق برای همه مناطق ناچار به تخمین بارش از روی داده های در دسترس و یا از روی سایر پارامترهای مرتبط هستیم. بنابراین جهت برطرف کردن این مشکل، در دهه های اخیر مدیران و محققان با استفاده از روش های ریاضی، آماری، هوشمند و ... مقادیر کمی بارش را با دقت قابل قبولی مورد تخمین قرار می دهند.

در زمینه تخمین بارش در داخل و خارج از کشور مطالعات زیادی انجام گرفته است که در ادامه به بخشی از آن ها اشاره می گردد. غلامی و جعفری (۱۳۸۹) در پژوهشی با استفاده از روش رگرسیون چند متغیره^۲ و شبکه عصبی مصنوعی^۳ بارش های استان مازندران را شبیه سازی کردند. نتایج به دست آمده از هر دو روش نشان داد که پارامترهای

^۱ نویسنده مسئول: بابک محمدی babakmsh@yahoo.com

^۲ Multivariate Regression

^۳ Artificial Neural Network

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 (۲۰۱۵) 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 (۲۰۱۵) 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 (۲۰۱۶) 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، سنه و پل آبیان که در حوضه آبریز زربنه‌رود 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 ناهم‌هنگ نزولات جوی و نقش آب در کشاورزی این منطقه، ضرورت بررسی و مطالعه سیستماتیک منابع آب را ایجاد 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

^۴ Artificial Neural Network

^۵ Neuro-Fuzzy

^۶ Multilayer Perceptron

است. با توجه به ورودی های مورد نظر، جدول (۱) به عنوان مجموعه ترکیب های ورودی هر یک از مدل های تخمین گر تعیین گردید.

جدول (۱): ترکیب های ورودی مدل های 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 شبکه های عصبی مصنوعی در زمینه هیدرولوژی نیز به طور موفقیت آمیز به کار گرفته شده که از آن جمله می توان به مدل کردن فرآیندهای بارش-رواناب، پیش بینی جریان رودخانه، مدل کردن آب زیرزمینی، کیفیت آب، پیش بینی بارندگی و ... اشاره کرد (Dams et al., 2007). حدود ۹۰٪ شبکه هایی که در مسائل هیدرولوژی کاربرد دارد شبکه های پیشرو هستند (Coulibaly et al., 2000). معماری معمول این شبکه متشکل از سه لایه ورودی، پنهانی و خروجی است. تعداد نرون های موجود در لایه ورودی و خروجی بستگی به نوع مسئله دارد ولی تعداد گره های لایه پنهان با سعی و خطا به دست می آید.

لازم به ذکر است که در تحقیق حاضر از تعداد نرون های ۱ تا ۳۰ برای لایه پنهان شبکه استفاده گردید تا از این طریق تاثیر ساختار مختلف شبکه بر عملکرد آن در شبیه سازی مقادیر کیفی آبخوان را مورد ارزیابی قرار داد. از آنجا که متداول ترین نوع توابع محرک تابع تانژانت سیگموئید می باشد 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 شبیه سازی بارش-رواناب ارائه شد. ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه سازی مقید است که از اصل استقرار کمینه سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می گردد. در مدل رگرسیون بردار پشتیبان تابعی مرتبط با متغیر وابسته y که خود تابعی از چند متغیر مستقل x است، برآورد می شود. مشابه سایر مسائل رگرسیونی فرض می شود رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند $f(x)$ به علاوه مقداری اغتشاش (خطای مجاز ε) مشخص شود.

$$f(x) = W^T \cdot \phi(x) + b \quad (1)$$

$$y = f(x) + \text{noise} \quad (2)$$

چنانچه W بردار ضرایب، b ثابت مشخصه های 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 مجموعه ای از نمونه ها (مجموعه واسنجی) محقق می شود. 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.

$$W^T \cdot \phi(x_i) + b - y_i \leq \varepsilon + \varepsilon_i^* \quad (3)$$

$$\frac{1}{2} W^T \cdot w + C \sum_{i=1}^N \varepsilon_i + C \sum_{i=1}^N \varepsilon_i^* y_i - W^T \cdot \phi(x_i) - b \leq \varepsilon + \varepsilon_i \quad \varepsilon_i, \varepsilon_i^* \geq 0, i = 1, 2, \dots, N \quad (4)$$

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:

$$f(x) = \sum_{i=1}^N \bar{\alpha}_i \cdot \phi(x_i)^T \cdot \phi(x) + b \quad (5)$$

در رابطه (۵)، $\bar{\alpha}_i$ 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 معمولاً 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).

$$k(x, x_i) = \exp\left(-\|x - x_i\|^2 / \sigma^2\right) \quad (6)$$

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:

$$d - factor = \frac{\bar{d}x}{\sigma x} \quad (7)$$

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

$$\bar{d}x = \frac{1}{n} \sum_{t=1}^K (X_U - X_L) \quad (8)$$

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

$$\text{Bracketed by 95PPU} = \frac{1}{K} \text{count}(j | X_L^1 \leq X_{\text{Reg}}^1 \leq X_U^1) \times 100 \quad (9)$$

در فرمول بالا k تعداد داده‌های مشاهداتی، l نشان‌دهنده شماره داده مورد نظر که از یک تا k در نظر گرفته می‌شود. X_U^1 و X_L^1 مشخص‌کننده حدود اطمینان در باند اطمینان ۲/۵٪ و ۹۷/۵٪ 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.

نتایج مدل شبکه عصبی مصنوعی

پس از شبیه سازی و تخمین بارش، مقادیر آماره های ضریب همبستگی و مجذور میانگین مربعات خطا در دوره های واسنجی و صحت سنجی 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 صحت سنجی دارای ضریب همبستگی ۰/۸۸۴ و مجذور میانگین مربعات خطای ۱/۰۰۷ می باشد. پس از ترکیب شماره پنج، ترکیب شماره چهار با مجذور میانگین مربعات خطای برابر با ۱/۱۹۴ نتیجه بهتری را نسبت به سایر ترکیب ها داشته است.

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

شماره ترکیب	صحت سنجی		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 آماره های 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 ورودی ها بر ترکیب اول تغییر زیادی پیدا نمی کند، این موضوع نشان دهنده قدرت این مدل در تخمین بارش فقط بر اساس دمای متوسط هوا می باشد.

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

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


شماره ترکیب	صحت سنجی		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.


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

ماشین بردار پشتیبان نیز حاکی از دقت بالای این مدل در تخمین مقادیر بارش داشته است. البته مقایسه مقادیر p -factor و d -factor مدل های شبکه عصبی مصنوعی و ماشین بردار پشتیبان نشان می دهد که مدل ماشین بردار پشتیبان دارای عدم قطعیت کمتری نسبت به مدل شبکه عصبی مصنوعی می باشد. عدم قطعیت کمتر می تواند 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 می توان استناد نمود. عدم قطعیت ها می تواند ناشی از ضعف مدل های تخمین گر، کیفیت نامناسب داده ها و ... باشد.

نتیجه گیری

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 مدل های شبکه عصبی مصنوعی و ماشین بردار پشتیبان مقادیر بارش شهرستان شاهرود مورد تخمین قرار گیرد. در این راستا از ساختارهای مختلف مدل ها و همچنین ترکیب های ورودی مختلف استفاده گردید و در نهایت عدم قطعیت هر یک از مدل ها در تخمین پارامتر بارش تعیین گردیده است.

مقایسه عملکرد مدل های 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 صحت سنجی 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 $0/710$ می باشد که حاکی از تخمین خوب این مدل و عدم قطعیت مناسب آن می باشد. همچنین مقادیر d -factor برابر با $0/095$ توسط مدل ماشین بردار پشتیبان برای تخمین بارش به دست آمده است. مقایسه مقادیر d -factor هر یک از مدل ها که نشان دهنده میزان عدم قطعیت مدل ها بوده حاکی از عدم قطعیت بسیار کم مدل ماشین بردار پشتیبان می باشد.

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 می تواند به عنوان یک مدل بسیار مناسب در تخمین پارامتر بارش در شهرستان شاهرود مورد استفاده قرار گیرد.

فهرست منابع

۱. زارع ایبانه، 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.، 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.

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 Mohammadi¹, Roozbeh Moazenzadeh²

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