



دانشگاه گوارش و منابع طبیعی

نشریه پژوهش‌های حفاظت آب و خاک
جلد بیست و یکم، شماره ششم، ۱۳۹۳
<http://jwsc.gau.ac.ir>

گزارش کوتاه علمی

پیش‌بینی رواناب روزانه با مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM)

* محسن پوررضا بیلندی^۱، عباس خاشعی سیوکی^۱ و صادق صادقی طبس^۲

^۱ استادیار گروه مهندسی آب، دانشگاه بیرجند، دانشجوی کارشناسی ارشد گروه مهندسی آب، دانشگاه بیرجند

تاریخ دریافت: ۹۲/۷/۲۹؛ تاریخ پذیرش: ۹۳/۳/۸

چکیده

مدل‌های داده محور از جمله ابزارهایی هستند که به منظور شبیه‌سازی در علوم مختلف استفاده می‌شوند. روش ماشین بردار پشتیبان به عنوان یکی از جدیدترین این نوع ابزارها اخیراً در علوم مرتبط با آب مورد توجه قرار گرفته است. در هیدرولوژی و منابع آب، این مدل‌ها با شبیه‌سازی فرآیند بارش- رواناب، مقدار رواناب را در حوزه‌های آبخیز بدون ایستگاه اندازه‌گیری و با حداقل زمان ممکن و کم‌ترین هزینه برآورد می‌کنند. هدف از انجام این پژوهش شبیه‌سازی رواناب روزانه با کمک ماشین بردار پشتیبان و همچنین مقایسه نتایج آن با مدل هیدرولوژیکی Hymod می‌باشد. مدل Hymod نیز مدلی مفهومی بوده که رواناب را با استفاده از داده‌های بارش و تبخیر- تعرق پتانسیل روزانه محاسبه می‌نماید. ارزیابی روش‌های پیش‌بینی رواناب نام برده با استفاده از داده‌های روزانه بارش و تبخیر- تعرق پتانسیل برای ۵ سال میلادی (۶۲-۱۹۵۸) در حوضه معرف رودخانه لیف آمریکا به مساحت ۱۹۵۰ کیلومتر مربع انجام گردید. مقادیر آماره‌های کلینگ گوپتا (KGE)، ضریب تعیین (R^2) و ضریب ناش- ساتکلیف (NSE) به ترتیب در روش ماشین بردار پشتیبان ۰/۸۰، ۰/۷۹ و ۰/۷۸ و در مدل Hymod، ۰/۶۸، ۰/۷۹ و ۰/۷۶ به دست آمد. نتایج نشان از برتری نسبی روش ماشین بردار پشتیبان به شبیه‌سازی مدل مفهومی Hymod داد و بنابراین نتایج این ابزار می‌تواند در حوضه‌های بدون آمار به عنوان تخمین قابل قبول اولیه در نظر گرفته شود.

واژه‌های کلیدی: مدل بارش- رواناب Hymod، روش ماشین بردار پشتیبان، پیش‌بینی رواناب، حوزه آبخیز رودخانه لیف

* مسئول مکاتبه: mohsen.pourreza@birjand.ac.ir

مقدمه

مطالعات بسیار زیادی در داخل و خارج کشور تا به حال در موضوع واسنجی مدل‌های شبیه‌سازی بارش- رواناب انجام شده که در ادامه به برخی از آن‌ها اشاره می‌شود. در پژوهشی خزایی و همکاران (۲۰۰۹) با استفاده از الگوریتم ژنتیک مدل بارش- رواناب ARNO را بر روی یک حوضه در جنوب غربی ایران واسنجی نمودند، در پژوهش مورد نظر دوره واسنجی ۵ سال و دوره اعتبارسنجی ۴ سال مد نظر قرار گرفت. کمالی و موسوی (۲۰۱۲) مدل مفهومی HEC-HMS را با استفاده از الگوریتم بهینه‌سازی MOPSO^۱ کالیبره کردند. ژانگ و همکاران (۲۰۰۸) با استفاده از سه روش معمول بهینه‌سازی (GA،^۲ SCE و^۳ PSO) پارامترهای مدل هیدرولوژیکی SWAT را بهینه کرده و به مقایسه هر یک پرداختند. نتایج نشان داد الگوریتم PSO در مقایسه با دیگر روش‌ها، به هنگام وجود محدودیت زمانی در انجام محاسبات، دارای برتری است.

ماشین‌های بردار پشتیبان (SVM) نیز یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرایی کمینه‌سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد (کریستیانینی و شو- تیلور، ۲۰۰۰). اولین کاربرد این روش در مسایل آب توسط دیباک و همکاران (۲۰۰۱) با مدل‌سازی بارش- رواناب ارایه شد. از جمله کاربردهای SVM در زمینه شبیه‌سازی سیلاب و رواناب می‌توان به پژوهش‌های انجام گرفته توسط لیونگ و همکاران (۲۰۰۲)، که با استفاده از داده‌های سیلابی شهر داکا^۴ در بنگلادش توانایی پیش‌بینی مدل SVM را در تخمین تراز سیل و در قالب دوره‌های یک تا هفت روزه مورد بررسی قرار دادند، اشاره کرد. یو و همکاران (۲۰۰۶) در مطالعه‌ای با استفاده از مدل SVM به پیش‌بینی سطح رقوم سیل در رودخانه لن- یانگ تایوان پرداختند. نتایج نشان داد که مدل به خوبی سطح آب رودخانه را برای ۱ تا ۶ ساعت بعد پیش‌بینی می‌کند. همچنین میسرا و همکاران (۲۰۰۹) در پژوهشی به منظور شبیه‌سازی رواناب و رسوب روزانه، هفتگی و ماهانه از آبخیز هند با استفاده از SVM اقدام نمودند و نتایج را با ANN مقایسه کردند. نتایج بیانگر قدرت SVM در آموزش، کالیبراسیون و اعتبارسنجی در مقایسه با ANN بود که در پیش‌بینی رواناب و رسوب دقت قابل‌قبولی داشت. هوآنگ و همکاران (۲۰۱۲) امکان‌سنجی استفاده

- 1- Multi Objective Particle Swarm Optimization (MOPSO)
- 2- Genetic Algorithm (GA)
- 3- Shuffled Complex Evolution (SCE)
- 4- Particle Swarm Optimization (PSO)
- 5- Dhaka

از مدل LS-SVM را در پیش‌بینی سری زمانی هیدرولوژیکی غیرخطی در مقایسه با روش‌های آماری رگرسیون خطی چندگانه (MLR) و روش اکتشافی مانند شبکه عصبی (NNBP) بررسی نمودند. نتایج نشان‌دهنده دقت پیش‌بینی بالای این مدل پیشنهادی بود. انتخاب مدلی که بتواند در عین سادگی ساختار و با استفاده از حداقل عوامل، رواناب به‌دست آمده از بارندگی را به‌طور دقیق پیش‌بینی کند امری ضروری به‌نظر می‌رسد. مدل Hymod به‌عنوان مدلی مفهومی و ساده اولین بار توسط بویل (۲۰۰۰) ارائه گردید. این مدل قادر است با استفاده از مقادیر بارش و تبخیر-تعرق پتانسیل روزانه، رواناب روزانه را محاسبه نماید. این پژوهش قصد دارد تا رواناب به‌دست آمده از بارندگی روزانه را توسط دو مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM) و مدل مفهومی بارش-رواناب روزانه Hymod، برای ۵ سال داده روزانه بارش و تبخیر-تعرق پتانسیل در حوضه رودخانه لیف^۱ آمریکا محاسبه نموده و نتایج حاصله را توسط معیارهای ارزیابی با یکدیگر مقایسه نماید.

مواد و روش‌ها

منطقه مورد مطالعه: حوضه رودخانه لیف با مساحت تقریبی ۱۹۵۰ کیلومتر مربع در شمال شهر کالینزدر ایالت می‌سی‌سی‌پی کشور آمریکا به‌منظور مطالعه موردی انتخاب شده است. حوضه نام‌برده دارای آب و هوای مرطوب بوده و داده‌های هواشناسی (بارش و تبخیر-تعرق پتانسیل روزانه) و هیدرومتری (دبی روزانه) در مدل بارش-رواناب مربوط به آن از طریق مکاتبه با دکتر روت^۲ استاد بخش مهندسی منابع آب دانشگاه کالیفرنیا آمریکا به‌عنوان حوضه معرف دارای داده‌های موثق اخذ شده است. لازم به ذکر است از داده‌های حوضه نام‌برده تاکنون در پژوهش‌های بسیاری استفاده شده است (یاپو و همکاران، ۱۹۹۸؛ بویل و همکاران، ۲۰۰۰؛ روت و همکاران، ۲۰۰۲؛ میسرلی، ۲۰۰۳).

مدل بارش-رواناب روزانه: برای شبیه‌سازی فرآیند بارش-رواناب مدل‌های زیادی وجود دارد که همه آن‌ها برای واسنجی نیاز به حداقل داده‌های مشاهداتی بارش و رواناب متناظر دارند. در این پژوهش از مدل مفهومی Hymod استفاده گردید که برای شبیه‌سازی رواناب در مقیاس زمانی روزانه به‌کار می‌رود. به‌منظور واسنجی این مدل به کمک الگوریتم‌های فراکوشی، پارامترهای مدل به‌عنوان متغیرهای تصمیم در نظر گرفته می‌شوند. حدود تغییرات متغیرهای تصمیم، مطابق جدول ۱ تعریف می‌شود:


1- Leaf River Watershed

2- Vrugt

جدول ۱- حدود تغییرات پارامترهای مدل بارش- رواناب Hymod.

معرفی پارامتر- واحد	نام اختصاری	کمینه	بیشینه
میزان بیش‌ترین ذخیره رطوبتی در حوضه (میلی‌متر)	Cmax	۰/۱	۵۰۰
تغییرات مکانی ذخیره رطوبت خاک	Bexp	۰/۱	۲
فاکتور توزیع بین دو مخزن رطوبتی	Alpha	۰/۱	۰/۹۹
زمان ماندگاری در مخزن جریان آرام (روز)	Rs	۰/۰۰۱	۰/۱
زمان ماندگاری در مخزن جریان سریع (روز)	Rq	۰/۱	۰/۹۹

همچنین در شکل ۱ ارتباط بین پارامترهای مدل (پنج پارامتر جدول ۱) به همراه ورودی‌های مدل (بارش و تبخیر- تعرق پتانسیل روزانه) نشان داده شده است. مدل Hymod نیز به دلیل دقت به نسبت بالا، سادگی و همچنین بار محاسباتی کم آن در این پژوهش به کار گرفته شد. از آنجا که شرح کامل مدل نام‌برده در پژوهش‌های (بویل، ۲۰۰۰؛ وگنر و همکاران، ۲۰۰۱؛ روت و همکاران، ۲۰۰۳) به تفصیل بیان شده است بنابراین در این جا از ذکر جزئیات بیش‌تر در این باره صرف‌نظر می‌شود.



شکل ۱- نمایش مدل مفهومی Hymod (برگرفته از روت و همکاران، ۲۰۰۹).

مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM): اساس روش ماشین بردار پشتیبان توسط کورتز و وپنیک (۱۹۹۵) بر پایه تئوری یادگیری آماری ارائه گردید که از حداقل‌سازی ریسک ساختاری پیروی می‌کند. سویکنس و همکاران (۲۰۰۲) روش حداقل مربعات ماشین بردار پشتیبان را ارائه نمودند. این مدل بر خلاف مدل SVM به جای مسأله برنامه‌نویسی درجه دوم در حل از معادلات خطی استفاده می‌نماید، بنابراین دقت محاسباتی بالاتری نسبت به ماشین بردار پشتیبان کلاسیک دارد (سیفی، ۲۰۱۰).

مجموعه داده‌های $\{x_i, y_i\}_{i=1}^N$ داده شده است که $x_i \in R^p$ به‌عنوان بردار ورودی و $y_i \in R$ به‌عنوان بردار خروجی می‌باشند. ترسیم غیرخطی Φ ، ترسیم نمونه‌ها در فضای ویژگی است. مدل رگرسیونی LS-SVM از رابطه ۱ پیروی می‌کند:

$$y(x_i) = w^T \cdot \varphi(x_i) + b \quad (1)$$

که در آن، w و b به‌ترتیب مقادیر وزن‌ها و اربیبی تابع رگرسیون هستند. که از طریق حداقل‌سازی تابع هدف در رابطه ۲ تعیین می‌گردند:

$$\min_{w, e, b} j(w, e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^N e_i^2 \quad (2)$$

با محدودیت:

$$y_i = w^T \sigma(x_i) + b + e_i \quad (3)$$

که در آن‌ها، γ : پارامتر تنظیم‌کننده بخش خطا است و e_i : خطای داده‌های آموزشی می‌باشد. تجزیه و تحلیل داده‌ها: وارد کردن داده‌ها به‌صورت خام باعث کاهش سرعت و دقت شبکه‌ها می‌گردد. به‌منظور افزایش کارایی مدل (LS-SVM)، همه داده‌ها ابتدا به شکل نرمال بین دو عدد $0/1$ و $0/9$ استاندارد شدند سپس آن‌ها بعد از استفاده در شبیه‌سازی به مقادیر اولیه برگشتند (رحیمی خوب، ۲۰۰۸).

$$x_i = 0/8 \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) + 0/1 \quad (7)$$

که در آن، x_i : مقدار استاندارد شده، x : مقدار واقعی و x_{\min} و x_{\max} ، به‌ترتیب مقادیر حداقل و حداکثر داده‌ها می‌باشند. در بخش مدل‌سازی ۷۰ و ۳۰ درصد داده‌ها به‌ترتیب به داده‌های آموزشی و داده‌های بخش آزمون تعلق گرفت. در بخش اعتبارسنجی از تکنیک اعتبارسنجی تقاطعی^۱ با روش بهینه‌سازی سیمپلکس استفاده گردید. بعد از تعیین مقادیر ترکیب بهینه (γ و σ)، مدل LS-SVM ساخته شد.

معیارهای ارزیابی و سنجش مدل: برای ارزیابی و سنجش مدل از معیارهای کلینگ گوپتا (KGE)^۱ (گوپتا و همکاران، ۲۰۰۹)، ضریب تبیین (R^2)، معیار ناش-ساتکلیف (NSE) استفاده شد که روابط آنها در زیر ارائه گردیده است.

$$KGE = 1 - \sqrt{(cc-1)^2 + (\alpha-1)^2 + (\beta-1)^2} \quad (8)$$

$$R^2 = \left(\frac{\sum_{i=1}^n (Q_{oi} - \bar{Q}_o)(Q_{si} - \bar{Q}_s)}{\sqrt{\sum_{i=1}^n (Q_{oi} - \bar{Q}_o)^2} \sqrt{\sum_{i=1}^n (Q_{si} - \bar{Q}_s)^2}} \right)^2 \quad (9)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_{si} - Q_{oi})^2}{\sum_{i=1}^n (Q_{oi} - \bar{Q}_o)^2} \quad (10)$$

که در آنها، Q_{oi} : دبی مشاهده‌ای، Q_{si} : دبی شبیه‌سازی شده، \bar{Q}_o : میانگین دبی مشاهداتی، n : تعداد داده‌های مشاهداتی، cc : ضریب همبستگی خطی بین Q_o و Q_s ، α : نسبت انحراف معیار Q_s بر انحراف معیار Q_o و β : نسبت میانگین Q_s بر میانگین Q_o می‌باشد. لازم به ذکر است معیار معرفی شده در رابطه ۸، جدیدترین معیار ارزیابی مدل‌های هیدرولوژیکی می‌باشد که برای اولین بار در این مقاله از آن استفاده گردید. معیار نام‌برده در حقیقت تغییر یافته معیار ناش-ساتکلیف می‌باشد.

نتایج و بحث

واسنجی مدل Hymod توسط الگوریتم PSO (کدنویسی شده در زبان برنامه‌نویسی MATLAB) و با تکرار هزار مرتبه اجرای مدل، انجام شد. بدین ترتیب که، ابتدا متغیرهای تصمیم (پارامترهای مدل) در محدوده مشخص شده به صورت تصادفی مقداردهی اولیه شده و سپس الگوریتم PSO اجرا شده و سری پارامتر بهینه مطابق جدول ۲ محاسبه گردید.

1- Kling Gupta Efficiency (KGE)

جدول ۲- پارامترهای محاسبه شده به کمک الگوریتم PSO.

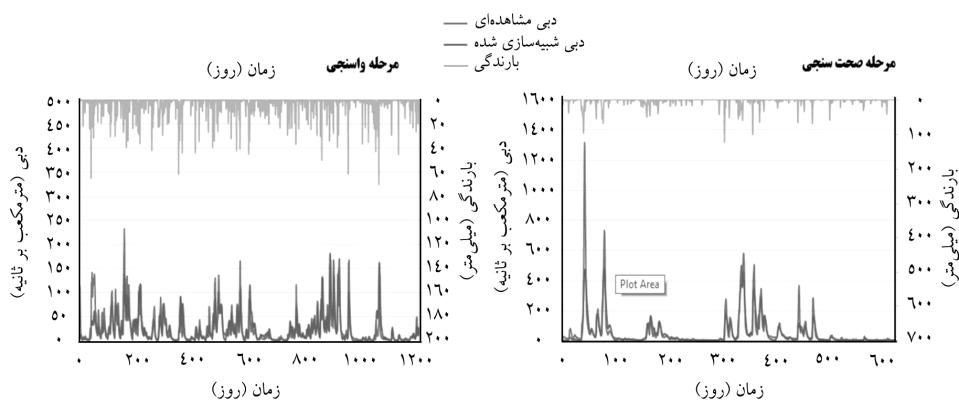
Cmax	bexp	Alpha	Rs	Rq
۴۷۵/۲۲	۱/۴۵	۰/۹۹	۰/۰۱۷	۰/۴۵

مقادیر دبی شبیه‌سازی با توجه به مقادیر به دست آمده در جدول بالا در مقابل مقادیر مشاهداتی برای یک دوره ۳ ساله (دوره واسنجی ۶۰-۱۹۵۸) و مقادیر بارش روزانه در شکل ۲ نشان داده شده است. همان‌طور که از شکل نتیجه می‌شود، مقادیر دبی‌های مشاهداتی در این شکل به خوبی شبیه‌سازی شده و در حقیقت تطابق بالایی دو هیدروگراف مشاهداتی و شبیه‌سازی شده را نشان می‌دهد. تنها برخی سیلاب‌های ابتدای دوره می‌باشد که با خطای بالایی برآورد گردیده‌اند که دلیل آن را می‌توان در شرایط اولیه مدل جستجو کرد. در حقیقت این مسأله در بسیاری از مدل‌های معروف دیگر مانند SWAT نیز وجود داشته که با ننگ داشتن یک دوره دو تا سه ساله به عنوان دوره گرم شدن^۱ قابل حل می‌باشد. دوره آموزش مدل LS-SVM نیز با همین دوره سه ساله انجام گردید که البته نتایج آن با توجه به ماهیت مدل‌های داده محور دارای اهمیت نمی‌باشد و بنابراین محاسبه معیارهای عملکرد در این مدل‌ها تنها در مرحله آزمون انجام می‌شود.


نمودار مقادیر هیدروگراف‌های مشاهداتی و شبیه‌سازی شده مدل Hymod در دوره صحت‌سنجی (۶۲-۱۹۶۱) نیز در شکل ۲ قرار گرفته است. در اینجا نیز مانند دوره واسنجی به جز مقادیر دبی اوج ابتدای دوره، باقی مقادیر مشاهداتی با دقت قابل قبولی شبیه‌سازی گردیده‌اند.

و در انتها شبیه‌سازی مقادیر دبی روزانه توسط مدل LS-SVM انجام شد و مقادیر دبی شبیه‌سازی شده حاصل در مقابل مقادیر مشاهداتی برای یک دوره آزمون ۲ ساله (۹۶۲-۱۹۶۱) در برابر مقادیر بارش روزانه در شکل ۳ نشان داده شده است. با مشاهده این شکل مشخص گردید که شبیه‌سازی مدل LS-SVM تا حدودی (شبیه‌سازی مقادیر دبی اوج ابتدای دوره صحت‌سنجی) بهتر از مدل مفهومی Hymod می‌باشد.

1- Warm-Up Period



شکل ۲- دبی روزانه مشاهده‌ای و شبیه‌سازی شده مدل Hymod در دوره واسنجی و صحت‌سنجی.



شکل ۳- دبی روزانه مشاهده‌ای و شبیه‌سازی شده مدل LS-SVM در دوره آزمون.

مقایسه مقادیر دبی شبیه‌سازی شده و مشاهده شده با کمک آماره‌های کلینگ گوپتا (KGE)، ضریب همبستگی (R^2) و ضریب ناش-ساتکلیف (NSE) در دوره‌های واسنجی و صحت‌سنجی مدل Hymod و دوره آزمون مدل LS-SVM انجام گرفت. نتایج ضرایب ناش-ساتکلیف بالا (۰/۷، ۰/۷۶ و ۰/۷۹ به ترتیب برای دوره‌های واسنجی و صحت‌سنجی مدل Hymod و دوره آزمون مدل LS-SVM) نشان‌دهنده شبیه‌سازی مناسب و قابل قبول در هر دو مدل می‌باشد. سایر معیارها نیز در حد قابل قبول بوده و در جدول ۳ نشان داده شده‌اند.

جدول ۳- مقایسه مقادیر دبی شبیه‌سازی شده و مشاهده شده با کمک معیارهای ارزیابی و سنجش مدل.

مدل	دوره	KGE	R ^۲	NSE
Hymod	واسنجی	۰/۷۸	۰/۷۰	۰/۷۰
	صحت‌سنجی	۰/۶۸	۰/۷۹	۰/۷۶
LS-SVM	آزمون	۰/۸۰	۰/۷۹	۰/۷۸

با توجه به مقادیر معیارهای ذکر شده و سایر مطالعات انجام شده در این زمینه مانند پژوهش لیونگ و همکاران (۲۰۰۲) و میسرا و همکاران (۲۰۰۹) که در مقدمه ذکر گردید، برتری نسبی روش ماشین بردار پشتیبان نشان داده شد.

نتیجه‌گیری

در این مقاله قابلیت روش ماشین بردار پشتیبان برای شبیه‌سازی رواناب روزانه و همچنین مقایسه نتایج آن با مدل هیدرولوژیکی Hymod انجام گرفت. مدل Hymod، مدلی مفهومی بوده که رواناب را با استفاده از داده‌های بارش و تبخیر- تعرق پتانسیل روزانه محاسبه می‌نماید. ارزیابی روش‌های پیش‌بینی رواناب نام برده با استفاده از داده‌های روزانه بارش و تبخیر- تعرق پتانسیل انجام گردید و مقادیر آماره‌های ریشه میانگین مربعات خطا (RMSE)، ضریب همبستگی (R^۲) و ضریب ناش- ساتکلیف (NS) به ترتیب در روش ماشین بردار پشتیبان ۰/۸۰، ۰/۷۹ و ۰/۷۸ (دوره آزمون) و در مدل Hymod، ۰/۶۸، ۰/۷۹ و ۰/۷۶ (دوره صحت‌سنجی) ارزیابی گردید. تنها برخی سیلاب‌های ابتدای دوره واسنجی مدل Hymod بود که با خطای بالایی برآورد گردیده‌اند که دلیل آن را می‌توان در شرایط اولیه مدل جستجو کرد.

به‌طور خلاصه با توجه به مقادیر معیارهای ذکر شده برتری نسبی روش ماشین بردار پشتیبان نشان داده شده و این روش به‌عنوان ابزاری جدید برای شبیه‌سازی رواناب روزانه در مناطق بدون شبکه هیدرومتری معرفی می‌گردد.

منابع

1. Boyle, D.P. 2000. Multi criteria calibration of hydrologic models. Ph.D. Dissertation, Department of Hydrology and Water Resources, University of Arizona, Tucson, USA.
2. Boyle, D.P., Gupta, H.V., and Sorooshian, S. 2000. Toward improved calibration of hydrological models: Combining the strengths of manual and automatic methods. *Water Resources Research*. 36: 3663-3674.
3. Cortes, C., and Vapnik, V. 1995. Support-vector networks. *Machine learning*, 20: 3. 273-297.
4. Cristianini, N., and Shawe-Taylor, J. 2000. *An Introduction to Support Vector Machines*. Cambridge University Press, New York, USA.
5. Dibike, Y.B., Velikov, S., Solomatine, D., and Abbot, M.B. 2001. Model Induction with Support Vector Machines-Introduction and Applications. *J. Comp. Civil Engin. ASCE*. 15: 208-216.
6. Gupta, H.V., Kling, H., Yilmaz, K.K., and Martinez, G.F. 2009. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *J. Hydrol.* 377: 1-2. 80-91.
7. Hwang, S.H., Ham, D.H., and Kim, J.H. 2012. Forecasting performance of LS-SVM for nonlinear hydrological time series. *KSCE J. Civil Engin.* 16: 5. 870-882.
8. Kamali, B., and Mousavi, S.J. 2012. Automatic Calibration of Hydrologic Event-Based Model Using PSO Meta-Heuristic Algorithm, *Amirkabir J. Civil Environ. Engin.* 44: 1. 77-88. (In Persian)
9. Khazaei, M.R., Zahabiyoun, B., and Saghafian, B. 2009. Automatic Calibration of the ARNO Conceptual Rainfall-Runoff Model. *Iran. J. Watershed Manage. Sci. Engin.* 3: 8. 21-28. (In Persian)
10. Liong, S.Y., and Sivapragasam, C. 2002. Flood Stage Forecasting with Support Vector Machines. *J. Amer. Water Resour. Assoc.* 38: 1. 173-186.
11. Misirli Baysal, F. 2003. Improving efficiency and effectiveness of Bayesian recursive parameter estimation for hydrologic models.
12. Misra, D., Oommen, Th., Agarwal, A., Mishra, S.K., and Thompson, A.M. 2009. Application and analysis of support vector machine based simulation for runoff and sediment yield. *Biosystems Engineering*. 103: 507-535.
13. Rahimi Khoob, A.R. 2008. Artificial neural network estimation of reference evapotranspiration from pan evaporation in a semi-arid environment. *Irrigation Science*. 27: 1. 35-39. (In Persian)
14. Seifi, A. 2010. Developing of expert system to prediction of daily evapotranspiration by support vector machine and compare results to ANN, ANFIS and experimental method. M.Sc. Thesis, Department of Water Engineering, Tarbiat Modarres University, Tehran, Iran. (In Persian)

15. Suykens, J., De Brabanter, J., De Moor, B., Vandewalle, J.A.K., and Van Gestel, T. 2002. Least squares support vector machines (Vol. 4). Singapore: World Scientific.
16. Vapnic, V.N. 1998. Statistical Learning Theory. Wiley, NEW YORK, USA.
17. Vrugt, J.A., Gupta, H.V., Bouten, W., and Sorooshian, S. 2003. A Shuffled Complex Evolution Metropolis algorithm for optimization and uncertainty assessment of hydrologic model parameters. *Water Resources Research*. 39: 8. 1201.
18. Vrugt, J.A., Bouten, W., Gupta, H.V., and Sorooshian, S. 2002. Toward improved identifiability of hydrologic model parameters: The information content of experimental data. *Water Resources Research*. 38: 12. 1312.
19. Wagener, T., Boyle, D.P., Lees, M.J., Wheater, H.S., Gupta, H.V., and Sorooshian, S. 2001. A framework for development and application of hydrologic models. *Hydrol Earth System Science*. 5: 1. 13-26.
20. Yapo, P.O., Gupta, H.V., and Sorooshian, S. 1998. Multi-objective global optimization for hydrologic models. *J. Hydrol*. 204: 83-97.
21. Yu, P.S., Chen, S.T., and Chan, I.F. 2006. Support vector regression for real-time flood stage forecasting. *Hydrology*. 328: 704-716.
22. Zhang, X., Srinivasan, R., and van Liew, M. 2008. Multi-Site Calibration of the SWAT Model for Hydrologic Modeling. *Transactions of the ASABE*. 51: 6. 2039-2049.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 21(6), 2015
<http://jwsc.gau.ac.ir>

Short Technical Report

Daily rainfall-runoff modeling with Least Square Support Vector Machine (LS-SVM)

*M. Pourreza Bilondi¹, A. Khashei-Siuki¹ and S. Sadeghi Tabas²

¹Assistant Prof., Dept. of Water Engineering, University of Birjand,

²M.Sc. Student, Dept. of Water Engineering, University of Birjand

Received: 10/21/2013; Accepted: 05/29/2014

Abstract

Accurate time and site-specific forecasts of streamflow are important in effective reservoir management and scheduling. The present study aimed to compare the efficiency of Least Square Support Vector Machine (LS-SVM) as a new data driven model and a conceptual hydrologic model (Hymod) to simulate the daily streamflow in a representative watershed in US, Leaf River Watershed (1950 km²). For this purpose, 5-years period (1958-1962) of daily data including rainfall, potential evapotranspiration and streamflow were used. First 3-years were used as calibration (training) period in Hymod and LS-SVM and two remaining years were selected for validation (testing) periods in two models respectively. Performances criteria (Kling Gupta Efficiency (KGE), correlation coefficient (R^2) and the Nash-Sutcliffe (NS) coefficient for both LS-SVM and Hymod models in verification period were calculated and found that LS-SVM is a very potential candidate for the prediction of long-term discharges and can be used as a promising method for hydrological prediction in un-gauged area.

Keywords: Daily streamflow simulation, Conceptual hydrologic model, Least square support vector machine, Lead river watershed

* Corresponding Author; Email: mohsen.pourreza@birjand.ac.ir