

کاربرد ماشین‌های بردار پشتیبان در فرامدل‌سازی به منظور استفاده در بهینه‌سازی تخصیص منابع آب حوضه‌یی

گلناز السادات میرفندرسکی (دانشجوی کارشناسی ارشد)

سید جمشید موسوی* (دانشیار)

دانشکده‌ی عمران و محیط زیست، دانشگاه صنعتی امیرکبیر

مهندسی عمران: شریف
دوره ۲-۴۹، شماره ۲، ص. ۱۰۷-۱۱۶، (پادداشت فنی)

در این مطالعه، الگوریتم بهینه‌سازی PSO با مدل جامع شبیه‌ساز MODSIM به منظور حل مسئله‌ی تخصیص منابع آب حوضه‌ی رودخانه‌ی اترک تلفیق شده است. تابع هدف مدل منتج PSO-MODSIM، با مجموعه‌ی متغیرهای تصمیم بهره‌برداری و طراحی مخازن سدها، براساس بهبود شرایط تخصیص آب به نیازها نسبت به شرایط پیش از توسعه‌ی سیستم کالیبره شد. در ادامه، به منظور بهبود سرعت اجرا و تنظیم مؤثر پارامترهای مدل، نسبت به ساخت یک فرامدل جایگزین از نوع ماشین‌های بردار پشتیبان^۱ به جای مدل MODSIM که در آن ارزیابی تابع هدف با استفاده از مدل تقریبی جایگزین انجام می‌شود، اقدام شد. با توسعه‌ی مدل جایگزین (PSO-MODSIM~SVM) حل این مسئله‌ی حوضه‌یی با نتایج حاصل از مدل اصلی PSO-MODSIM و یک مدل مبتنی بر فرامدل شبکه‌های عصبی مصنوعی (ANN) مقایسه شد. نتایج حاصل از فرامدل‌سازی با روش SVM از منظر کیفیت جواب‌ها و بار محاسباتی، بیانگر عملکرد مطلوب این روش و برتری آن بر فرامدل از نوع ANN است.

واژگان کلیدی: تخصیص آب، حوضه‌ی رودخانه، بهینه‌سازی جایگزین، ماشین‌های بردار پشتیبان.

۱. مقدمه

مدل‌های شبیه‌سازی حوضه‌یی در برگزیده‌ی انواع فرایندهای فیزیکی، اقتصادی-اجتماعی و اداری، علی‌رغم قابلیت‌های بالا در مدل‌سازی و ارزیابی عملکرد سیستم‌های پیچیده از مشکل زمان محاسباتی زیاد رنج می‌برند. از طرفی افزودن جنبه‌های مختلف فرایندی در درون مدل شبیه‌سازی اگرچه جامعیت مدل و سیستم پشتیبان در تصمیم‌گیری را افزایش می‌دهد، اما به‌طور قابل توجهی بر بار محاسباتی آن نیز خواهد افزود. یکی از روش‌های موجود برای مقابله با افزایش بار محاسباتی در این مدل‌ها، توسعه‌ی یک فرامدل است. به عبارت دیگر، ایجاد یک مدل جایگزین برای مدل اصلی که دقیقاً روابط ورودی و خروجی را فرا گرفته باشد، می‌تواند از نظر کارایی محاسباتی در مواردی که مدل شبیه‌ساز باید به دفعات بسیار زیاد اجرا شود (نظیر استفاده از آن در یک الگوریتم بهینه‌سازی)، مؤثرتر از استفاده از مدل شبیه‌سازی باشد.


به کارگیری راهکارهای مناسب جهت افزایش دقت مدل‌های تقریب و استفاده‌ی کارآمد از آن‌ها در حل مسائل بهینه‌سازی را می‌توان با عنوان مدیریت فرامدل جایگزین^۲ شناخت. امروزه مبحث مدیریت مدل‌های جایگزین، به منزله‌ی یک زمینه‌ی تحقیقاتی

جدید شناخته شده و توجه زیادی را به سمت خود جلب کرده است. در زمینه‌ی کارهای معدود انجام شده در این زمینه می‌توان به این موارد اشاره کرد: در پژوهشی در سال ۱۹۹۹، از مدل‌های تحلیل خطای متغیرها و روش‌های تقریب برای افزایش کارایی EA در مسائل طراحی پیچیده استفاده شده است.^[۱] همچنین در سال ۲۰۰۱، ساختارهای محاسباتی جهت ترکیب یک دسته از مدل‌های تقریبی تک نقطه‌یی EA با مطرح شد.^[۲] در سال ۲۰۰۱ نیز یک استراتژی برای ترکیب جستجوی تکاملی با مدل‌های Krigging توسعه داده شد.^[۳] همچنین استفاده‌ی توأم و ترکیبی از EA و جستجوی محلی و روش‌های رویه‌ی پاسخ درجه‌ی دوم^۳ در سال ۲۰۰۰ مطرح شده است.^[۴] در سال ۲۰۰۵ نیز یک روش متوالی با تطبیق بر روی ناهمواری‌های تابع پاسخ با استفاده از مدل تقریبی بیزین^۴ در شبیه‌سازی طراحی یک مسئله‌ی مهندسی استفاده شد.^[۵]

در این راستا مدل جایگزین ANN با GA در سال ۲۰۰۵ برای یافتن جواب بهینه برای مسئله‌ی سیستم‌های توزیع آب که از ترکیب مدل EPANET و GA به دست آمده بود، به کار برده شد.^[۶] در سال ۲۰۰۶ هم روش سطح پاسخ استوکستیک^۵ معرفی شد، که چارچوبی برای بهینه‌سازی تصادفی سراسری توابع زمانبر با استفاده از مدل‌های سطح پاسخ است. همچنین عملکرد ۷ الگوریتم بهینه‌سازی سراسری

* نویسنده مسئول

تاریخ دریافت: ۱۳۸۹/۱۲/۱۰، اصلاحیه ۱۳۹۰/۸/۲۴، پذیرش ۱۳۹۰/۱۱/۲۹.



شکل ۱. تابع خطای ϵ غیرحساس.

به‌عنوان پیش‌فرض انتخاب می‌شود) باشد (دایره‌های سفید رنگ)، به‌عنوان خطا در نظر گرفته نشوند و در عوض برای آن دسته از داده‌هایی که اختلافی بیش از ϵ به مقادیر تخمینی دارند (دایره‌های سیاه رنگ)، مطابق تابع خطای مذکور، مقدار $\epsilon_i = |y_i - f(x_i, \alpha)| - \epsilon$ به‌عنوان خطا در نظر گرفته شود. برای توسعه‌ی الگوریتم، در ابتدا تخمین یک تابع خطای مطابق رابطه‌ی ۴ بررسی می‌شود.

$$f(x) = \langle w, x \rangle + b, \quad b \in \mathbf{R} \quad w, x \in \mathbf{X}, \quad (4)$$

به طوری که $\langle \cdot, \cdot \rangle$ مشخص‌کننده‌ی ضرب داخلی دو بردار در فضای هیلبرت (فضای ضرب داخلی یا نقطه‌یی که در آن ضرب داخلی دو بردار، یک عدد حقیقی شود) است و w بردار وزن مربوط به بردار ورودی است.

برای یافتن تابع f باید به کمینه‌سازی تابع خطای هموار شده R_{reg} ، براساس تابع خطای ϵ - insensitive R_{reg} را می‌توان براساس شکل باز شده‌ی R_{reg}^{ϵ} باز نویسی کرد و خطای آموزش را در قالب تابع خطای ϵ - insensitive محاسبه نمود. ضریب ثابت C بیانگر سازشی میان پیچیدگی تابع f (مقدار $\|w\|^2$) و بالاترین مقداری از انحرافات بیشتر از ϵ است که قابل تحمل خواهند بود. به‌طور مختصر کمینه‌سازی رابطه‌ی ۴، نشان‌دهنده‌ی ایده‌ی اصلی تئوری یادگیری آماری است که بیان می‌کند برای دستیابی به کمترین خطای واقعی، کنترل پیچیدگی مدل و همچنین خطای مربوط به داده‌های آموزش ضروری است. به عبارت دیگر، طبق گفته‌ی و پنیک عمومیت‌پذیری با استفاده از داده‌های محدود ممکن است؛ اگر و فقط اگر پیچیدگی تابع تخمین کنترل شود.^[۱۱]

۱.۲. یادگیری توابع غیرخطی

محدودیت‌هایی در ارتباط با قابلیت محاسباتی ماشین‌های یادگیر خطی وجود دارد. به‌طور کلی کاربردهای غیرخطی موجود، نیازمند فضاها‌ی فرضیه‌ی پیچیده‌تری نسبت به توابع خطی است. به بیان دیگر، نیل به یک حداکثر خطای هدف در بسیاری از موارد فقط با استفاده از ترکیب خطی خصیصه‌های بردار ورودی ممکن نیست. برای غلبه بر این محدودیت، از نمایش کرنلی که باعث افزایش توانایی محاسباتی ماشین‌های یادگیر خطی می‌شود، استفاده می‌شود.^[۱۰]

به‌منظور یادگیری روابط غیرخطی با استفاده از یک ماشین خطی نیازمند نمایش جدیدی از داده‌ها به صورت ویژگی‌های غیرخطی هستیم. این عمل معادل نگاشت ثابت و غیرخطی از فضای اصلی داده‌ها به فضای ویژگی است، به طوری که بتوان در این فضا از ماشین خطی استفاده کرد. تابع $\varphi: X \rightarrow F$ نگاشت غیرخطی از فضای ورودی به فضای ویژگی است.^[۱۰] بنابراین در نهایت تابع تخمین به صورت

بر روی دو مسئله‌ی ۱۴ و ۸ پارامتری کالیبراسیون مدل‌های هیدرولوژیک با استفاده از توابع شعاعی^۶ در سال ۲۰۰۷ مقایسه شد.^[۷] در سال ۲۰۰۶ نیز یک روش مدل‌سازی دینامیک به نام (ANGA)^۷ ارائه شد که در آن شبکه‌ی عصبی به صورت تطبیقی و اتوماتیک در ارتباط مستقیم با GA آموزش یافته و جایگزین یک مدل زمان‌بر شبیه‌سازی سیستم آب زیرزمینی می‌شود.^[۸]

همچنین در سال ۲۰۰۸ با اتصال مدل MODSIM به الگوریتم PSO از مدل ترکیبی PSO-MODSIM در مسئله‌ی بهینه‌سازی تخصیص منابع آب حوضه‌یی استفاده شد. سپس این مدل با توجه به بار محاسباتی قابل‌ملاحظه به مدل PSO-MODSIM-ANN که در آن مدل MODSIM با یک مدل شبکه‌ی عصبی به شکل غیر برخط تقریب زده شده است، تعمیم یافت. در ادامه، شکل بهبود یافته و برخط مدل مذکور در قالب فرامدل‌سازی متوالی تطبیقی نیز عرضه شد.^[۹]

در این مطالعه استفاده از یک فرامدل جدید با برخی مزیت‌های نسبی در مقایسه با ANN، در یک مسئله‌ی کاربردی منابع آب جدید در مقیاس حوضه مورد توجه قرار گرفته است.

۲. ماشین‌های بردار پشتیبان

ماشین‌های بردار پشتیبان^۸ که اولین بار توسط وپنیک و همکارانش معرفی شد و از اصل استقرایی کمینه‌سازی خطای ساختاری بهره می‌جوید،^[۱۰] یکی از روش‌های یادگیری با نظارت است. یادگیری تحت نظارت، یک روش عمومی در یادگیری ماشین است که در آن به سیستم، مجموعه‌ی جفت‌های ورودی و خروجی ارائه می‌شود و سیستم تلاش می‌کند تا تابعی از ورودی به خروجی را فرا گیرد. در این مطالعه، هدف از یادگیری، یافتن تابع $f(x)$ به منزله‌ی تقریبی از مقدار $y(x)$ با کمینه‌ی خطا و براساس داده‌های مستقل از یکدیگر است (رابطه‌ی ۱).

$$(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m) \subseteq (\mathbf{X} \subseteq \mathbf{R}^n \times \mathbf{Y} \subseteq \mathbf{R}) \quad (1)$$

در الگوریتم SVR تابع تقریب زده شده با استفاده از مجموعه‌یی از داده‌های آموزشی که بردارهای پشتیبان (SVs) نامیده می‌شوند، تعیین می‌شود. وپنیک برای توسعه‌ی ماشین‌های بردار پشتیبان از تابع خطای جدیدی استفاده کرد که تابع خطای ϵ - insensitive خوانده می‌شود و به صورت رابطه‌های ۲ و ۳ تعریف می‌شود:

$$R_{reg}[f] = \frac{1}{2} \|w\|^2 + \frac{C}{m} \sum_{i=1}^m |y_i - f(\mathbf{x}_i)|_{\epsilon} \quad (2)$$

$$R_{emp}^{\epsilon}[f] = \frac{1}{m} \sum_{i=1}^m |y_i - f(\mathbf{x}_i)|_{\epsilon} \quad (3)$$

$$L(y, f(\mathbf{x}, \alpha)) = |y - f(\mathbf{x}, \alpha)|_{\epsilon} = \begin{cases} 0 & \text{if } |y - f(\mathbf{x}, \alpha)| \leq \epsilon \\ |y - f(\mathbf{x}, \alpha)| - \epsilon & \text{otherwise} \end{cases} \quad (3)$$

شکل ۱، شماتیکی از رابطه‌ی بین داده‌های موجود (دایره‌های سفید و سیاه) را که در فضای یک بعدی و توسط تابع خطی f انجام پذیرفته است، نشان می‌دهد. مطابق این شکل، استفاده از تابع خطای ϵ - insensitive باعث می‌شود که اختلاف بین مقادیر تخمینی توسط تابع و مقادیر اندازه‌گیری شده‌ی y که کمتر از مقدار ϵ (که

رابطه‌ی ۵ حاصل می‌شود:

$$f(\mathbf{x}) = \sum_{i=1}^m (\alpha_i^* - \alpha_i) \langle \varphi(\mathbf{x}_i), \varphi(\mathbf{x}) \rangle + b$$

$$\mathbf{w} = \sum_{i=1}^m (\alpha_i^* - \alpha_i) \varphi(\mathbf{x}_i) \quad (5)$$

اگر بتوان به نحوی ضرب داخلی دو بردار $\varphi(x)$ و $\varphi(x_i)$ را در فضای ویژگی مستقیماً و به شکل تابعی از نقاط ورودی اصلی $\mathbf{x}_i$ محاسبه کرد، نیاز به نگاشت صریح داده‌های ورودی به فضای ویژگی نخواهد بود. به چنین شیوه‌ی محاسباتی مستقیمی روش کرنلی گفته می‌شود. تابع کرنل: تابعی است نظیر K به طوری که به ازای کلیه‌ی $x, z \in X$ داشته باشیم (رابطه‌ی ۶):

$$K(\mathbf{x}, \mathbf{z}) = \langle \varphi(\mathbf{x}), \varphi(\mathbf{z}) \rangle \quad (6)$$

تابعی که شرط‌های تئوری Mercer را احراز کنند، می‌توانند به‌منزله‌ی توابع کرنل استفاده شوند. به عبارت دیگر می‌توان آن‌ها را به صورت رابطه‌ی ۶ نوشت. توابع کرنل خطی، چندجمله‌یی، سیگموئید و (RBF) تعدادی از کرنل‌های رایج هستند. نهایتاً با جایگزین کردن مقادیر $\langle \varphi(x_i), \varphi(x) \rangle$ در تابع کرنل مناسب به رابطه‌ی ۷ خواهیم رسید:

$$f(\mathbf{x}) = \sum_{i=1}^m (\alpha_i^* - \alpha_i) K(\mathbf{x}_i, \mathbf{x}) + b \quad (7)$$

۲.۲. پیاده‌سازی مدل در محیط نرم‌افزار Matlab

برنامه‌های کامپیوتری متعددی در زمینه‌ی حل مسئله‌ی بهینه‌سازی مقید و درجه‌ی دوم مربوط به ماشین‌های بردار پشتیبان نوشته شده است که هر یک قابلیت‌های متفاوت و همچنین الگوریتم‌های مختلفی برای حل این مسئله ارائه می‌دهند. در این تحقیق، با توجه به بررسی‌های صورت‌گرفته بر روی پاره‌ی از این برنامه‌ها و همچنین سهولت کاربر در استفاده از آن‌ها، یکی از جعبه ابزارهای موجود در Matlab Exchange Files به نام (SVM and Kernel Methods Matlab Toolbox) انتخاب شد که تمامی دستورهای موجود در آن از جمله حل مسئله‌ی بهینه‌سازی درجه‌ی دوم (QP)^{۱۰} در محیط نرم‌افزار Matlab نوشته شده است و اجرای برنامه را از نظر زمانی تا حد زیادی سرعت می‌بخشد.

۳.۲. تنظیم پارامترهای مدل SVM

پارامترهای ماشین بردار پشتیبان شامل اپسیلن: مشخص‌کننده‌ی تابع خطای ε - insensitive، $\frac{C}{m}$ که پارامتر ظرفیت تابع محسوب می‌شود و نهایتاً پارامتر مربوط به تابع کرنل (نظیر پارامتر γ تابع کرنل RBF) می‌باشند که باید پیش از ساخت مدل تعیین شوند و لذا به این نام خوانده می‌شوند. پارامتر C حد بالای ضرایب بردارهای پشتیبان (α^*) را مشخص می‌کند. این پارامتر رابطه‌ی بین کمینه‌ساختن تابع خطا (ارضای قیود) و پیچیدگی تابع را کنترل می‌کند. با کاهش مقدار C ، پیچیدگی تابع نیز کاهش می‌یابد. هنگامی که C به سمت بی‌نهایت میل کند، مسئله، غیرمقید و ناپایدار خواهد شد. با توجه به اینکه کیفیت مدل SVM و خصوصیت عمومیت‌پذیری آن به پارامترهای مدل بستگی دارد، لذا انتخاب آن‌ها در ارائه‌ی مدلی کارآمد بسیار مهم خواهد بود. به‌طورکلی می‌توان گفت که انتخاب C و ε باید توسط کاربر و براساس اطلاعات قبلی و یا تجربه‌ی شخصی صورت گیرد.

از آنجایی که این پارامترها به یکدیگر وابسته هستند، مقادیر بهینه‌ی (یا نزدیک به بهینه) آن‌ها معمولاً از طریق یک فرایند حدس و خطا قابل دستیابی است. در این مطالعه از شیوه‌ی جستجوی شبکه‌یی^{۱۱} برای کالیبره کردن هر چه کاراتر پارامترها جهت غلبه بر کمبودهای روش‌های سعی و خطایی استفاده شده است.

۴.۲. کاربرد مدل SVM در تقریب توابع پایه

جهت بررسی عملکرد SVM به‌منزله‌ی فرامدل در تقریب تابع، از دو تابع پایه‌ی Dejong به عنوان یک تابع کلاسیک و هموار و تابع Ackley به‌منزله‌ی یک تابع پیچیده و دارای نقاط بهینه‌ی موضعی بسیار استفاده شده است. برای تنظیم پارامترهای مدل و نیز جلوگیری از ایجاد پدیده‌ی وراآموزی از واریسی اعتباری استفاده شده است. اندازه‌ی نمونه‌ی داده‌های استفاده‌شده برابر با 50×10 انتخاب شده است. همچنین برای تصدیق مدل‌ها از واریسی اعتباری 10×10 زیرمجموعه‌ی استفاده شده است که در آن داده‌ها به 10×10 زیرمجموعه تقسیم شده‌اند؛ آموزش مدل با استفاده از 9×10 زیرمجموعه انجام شده است؛ سپس تصدیق آن با استفاده از 1×10 زیرمجموعه باقی‌مانده انجام می‌شود. این عمل 9 مرتبه‌ی دیگر تکرار می‌شود.

۱.۴.۲. بهینه‌سازی توابع ریاضی پایه

تابع Dejong ساده‌ترین تابع چندبعدی موجود است، که با عنوان مدل کروی نیز شناخته می‌شود. این تابع پیوسته، محدب و یک نمایی است. تعریف تابع به شکل رابطه‌ی ۸ است:


$$f(x) = \sum_{i=1}^n x_i^2 \quad -0.12 < x_i < 0.12 \quad (8)$$

در شکل ۲، فضای جستجوی مسئله در حالت دوبعدی (Dejong-۲D) در بازه‌ی $[-0.12, 0.12]$ ، نمایش داده شده است. نقطه‌ی کمینه‌ی سراسری این تابع در بازه‌ی $(0, 0)$ واقع شده است.


رابطه‌ی تابع ریاضی Ackley، که یک تابع با بهینه‌های محلی بسیار زیاد و فضای غیرخطی نامحدب است، به صورت رابطه‌ی ۹ نمایش داده می‌شود:

$$f(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos 2\pi x_i\right) + 20 + e \quad (9)$$


که در این رابطه، e پایه‌ی طبیعی و n بعد مسئله است. مقدار کمینه‌ی سراسری تابع برابر $f(\underline{x}^*)$ در نقطه $\underline{x}^* = 0$ واقع شده است. در شکل ۳، فضای جستجوی مسئله در حالت دوبعدی (Ackley-۲D) در بازه‌ی $[-5, 5]$ نمایش داده شده است.




شکل ۲. تابع Dejong در حالت دوبعدی.




شکل ۶. نمودار مقادیر خروجی مدل SVM در برابر مقادیر واقعی تابع هدف، براساس داده‌های آموزشی تابع Dejong-10D.




شکل ۷. نمودار مقادیر خروجی مدل SVM در برابر مقادیر واقعی تابع هدف، براساس داده‌های آزمون تابع Dejong-10D.



شکل ۸. نمودار مقادیر خروجی مدل SVM در برابر مقادیر واقعی تابع هدف، براساس داده‌های آموزشی تابع Ackley-2D.




شکل ۹. نمودار مقادیر خروجی مدل SVM در برابر مقادیر واقعی تابع هدف، براساس داده‌های آزمون تابع Ackley-2D.




شکل ۳. تابع Ackley در حالت دو بعدی.

در این بخش نتایج ناشی از به‌کارگیری مدل SVM روی نمونه‌یی با ۵۰۰ داده ۱۲ نشان داده شده است. این نتایج شامل نمودارهای مقادیر خروجی مدل در مقابل مقادیر واقعی تابع هدف براساس داده‌های آموزشی و آزمون است. توابع Dejong و Ackley در حالت‌های دو بعدی و ده بعدی بررسی شده‌اند.


مطابق شکل‌های ۴ الی ۱۱، مدل SVM با دقتی خوب داده‌های آموزشی تولیدشده ناشی از توابع Dejong و Ackley را فرا گرفته است و با دقتی مناسب نیز داده‌های آزمون را پیش‌بینی کرده است. این امر نشان‌دهنده‌ی کفایت این مدل در تقریب توابع هموار و پیچیده است. لذا در بخش‌های بعدی به بررسی کاربرد این مدل به‌عنوان جایگزین مدل MODSIM و توسعه‌ی یک فرامدل که در آن ارزیابی تابع هدف با استفاده از مدل تقریبی جایگزین انجام می‌شود، اقدام شده است.



شکل ۴. نمودار مقادیر خروجی مدل SVM در برابر مقادیر واقعی تابع هدف، براساس داده‌های آموزشی تابع Dejong-2D.



شکل ۵. نمودار مقادیر خروجی مدل SVM در برابر مقادیر واقعی تابع هدف، براساس داده‌های آزمون تابع Dejong-2D.



شکل ۱۲. نحوه‌ی تغییر مکان یک ذره در الگوریتم PSO.

شده‌اند، در جهت اینکه در این فرایند به موقعیت بهتری برسند، صورت می‌گیرد. الگوریتم PSO به‌طور موفقیت‌آمیزی در زمینه‌های مختلف از جمله: توابع بهینه‌سازی، شبکه‌های عصبی مصنوعی و سیستم‌های کنترل کاربرد داشته است.

۴. مشخصات سیستم تحت مطالعه


سیستم تحت مطالعه حوضه‌ی اترک واقع در شمال شرق کشور است. این حوضه در ۳ استان خراسان رضوی، خراسان شمالی و گلستان واقع شده است. بخش اعظم این حوضه در استان خراسان شمالی قرار گرفته است، بخش سراب حوضه در استان خراسان رضوی و بخش پایاب آن در استان گلستان و در اتصال با دریای مازندران قرار دارد. این سیستم مشتمل بر ۶ سد در حال بهره‌برداری و ۷ سد عمده در دست مطالعه است. سدهای تبارک‌آباد، شیروان، شیرین‌دره، چری، شورک و آلاگل ساخته شده‌اند و سدهای قردانلو، دربند، گرماب، آمند، چابلی، چندیر و سومبار در مرحله‌ی مطالعات و طراحی‌اند.^[۱۳]

شبکه‌ی سیستم منابع حوضه‌ی اترک MODSIM در مدل شبیه‌ساز بالغ بر ۱۲۰ گره است که تعداد ۶۰ گره‌ی تقاضا در آن وجود دارد. مدل MODSIM یک مدل شبیه‌سازی اولویت-پایه^{۱۴} است. بدین معنی که مسئله‌ی تخصیص در این پژوهش با استفاده از حل یک الگوریتم شبکه‌ی جریان متوالی (NFP)^{۱۵} حل می‌شود. بدین منظور نیاز است که اولویت تأمین گره‌های نیاز توسط کاربر تعریف شوند. این امر در شبکه‌ی حوضه‌ی اترک، به‌صورت اختصاص اولویت بالاتر به گره‌های نیاز از بالادست حوضه به پایین‌دست و اولویت بالاتر به ترتیب برای گره‌های زیست‌محیطی، شرب، صنعت و کشاورزی انجام شده است.


متغیر تصمیم مدل بهینه‌سازی مشتمل بر ۶ متغیر است که در برگزیده‌ی ظرفیت مخازن ۳ سد در دست مطالعه‌ی دربند، گرماب و قوردانلو به‌عنوان متغیرهای طراحی و اولویت ذخیره‌ی آب در همین مخازن به‌عنوان متغیرهای بهره‌برداری است. این متغیرها به‌عنوان متغیرهای مسئله‌ی بهینه‌سازی و ورودی به مدل SVM هستند و خروجی مدل نیز تابع هدف مدل است.

۵. تابع هدف

از آنجایی که مطابق با مطالعات جامع منابع آب حوضه‌ی آبریز رودخانه‌ی اترک،^[۱۳] استان‌های گلستان و خراسان شمالی به ترتیب با مشکلات بیشتری جهت تأمین آب



شکل ۱۰. نمودار مقادیر خروجی مدل SVM در برابر مقادیر واقعی تابع هدف، براساس داده‌های آموزشی تابع Ackley-۱۰D.



شکل ۱۱. نمودار مقادیر خروجی مدل SVM در برابر مقادیر واقعی تابع هدف، براساس داده‌های آزمون تابع Ackley-۱۰D.

۳. الگوریتم PSO

الگوریتم بهینه‌سازی ازدحام ذرات (PSO) یکی از روش‌های الگوریتم‌های هوش جمعی به منظور حل مسائل GO است. این روش در اصل توسط J. Kennedy به‌منزله‌ی شبیه‌سازی رفتار اجتماعی ارائه و نیز برای اولین بار در سال ۱۹۹۵ به‌عنوان روشی برای بهینه‌سازی معرفی شد. PSO مرتبط با روش‌های الهام گرفته‌شده از حیات مصنوعی، خصوصاً تئوری‌های جمعیت پایه و همچنین EC، خصوصاً ES و GA است.^[۱۲]

الگوریتم PSO شبیه به شیوه‌های EC است که در آن جمعیتی از جواب‌های بالقوه برای مسئله‌ی موردنظر، به‌منظور اکتشاف در فضای جستجو، استفاده می‌شوند. در PSO، هر عنصر از جمعیت دارای سرعتی قابل تنظیم (تغییر مکان) است که مطابق با آن در فضای جستجو به حرکت در می‌آید. علاوه بر این، هر عنصر دارای یک حافظه است که بهترین نقطه از فضای جستجو را که تا به حال دیده است، به‌خاطر می‌سپارد.^[۱۲] در نتیجه، حرکت هر ذره یک شتاب نتیجه‌شده از جمع‌بندی جهت بهترین نقطه‌ی دیده‌شده تاکنون توسط خود ذره و یا بهترین نقطه در یک همسایگی تعیین‌شده باشد. به دلیل اینکه ترم «شتاب» در اصل برای سیستم‌های ذرات^{۱۳} در علم فیزیک ذرات به‌کار رفته بود، اولین توسعه‌دهندگان این الگوریتم تصمیم به استفاده از واژه‌ی Particle برای هر عنصر و نام Swarm برای جمعیت گرفتند که در نتیجه منجر به نام‌گذاری Particle Swarm برای این الگوریتم شد. در شکل ۱۲، نحوه‌ی تغییر مکان یک ذره در الگوریتم PSO نشان داده شده است. اساس این الگوریتم، جستجوی فضای جواب‌ها با استفاده از روشی مناسب است که توسط حرکت ذرات به سوی بهترین موقعیتی که در گذشته با آن روبرو

مورد نیاز روبرو هستند، تابع هدف مورد نیاز برای حل این مسئله به صورت رابطه‌ی ۱۰ تعریف شده است:

$$\begin{aligned} \cos t = & w_1 \times \left(\sum_{j=1}^{nDEM_{Kh-S hom ali}} Q_{supplyKh-S hom ali}(j) \right. \\ & \left. - TARGET_{Kh-S hom ali} \right) + w_7 \\ & \times \left(\sum_{j=1}^{nDEM_{Goles tan}} Q_{supplyGoles tan}(j) \right. \\ & \left. - TARGET_{Goles tan} \right)^t + w_7 \times (DamCap_{Darband}) \\ & + w_7 (DamCap_{Garmab}) + w_8 (DamCap_{Ghordanlu}) \end{aligned} \quad (10)$$

برای به دست آوردن مقادیر احجام مطلوب تأمین آب $Q_{supplyKh-S hom ali}$ و $Q_{supplyGoles tan}$ آب تأمین شده در محل‌های مصرف موجود به ترتیب در استان‌های خراسان شمالی و گلستان در شرایط توسعه؛ $TARGET_{Kh-S hom ali}$ و $TARGET_{Goles tan}$ آب تأمین شده در محل‌های مصرف موجود به ترتیب در استان خراسان شمالی و گلستان در شرایط موجود و $DamCap$ ظرفیت سازه‌ی ذخیره یا سد است.

برای به دست آوردن مقادیر احجام مطلوب تأمین آب ($TARGET$) در استان‌های گلستان و خراسان شمالی مدل MODSIM در شرایط موجود (بدون در نظر گرفتن سدهای در دست مطالعه و اثرات آن‌ها) و برای دوره‌ی ۲۰ سال اجرا شد. در این اجرا متوسط سالیانه تأمین نیازهای آبی حوضه آبریز در هر یک از استان‌های خراسان رضوی، خراسان شمالی و گلستان به ترتیب برابر با ۷۴۳/۳، ۷۵۶/۵ و ۱۹۵ میلیون مترمکعب برآورد شد. از طرفی متوسط سالیانه نیازهای آبی حوضه آبریز در هر یک از استان‌های خراسان رضوی، خراسان شمالی و گلستان نیز به ترتیب برابر با ۷۸۳/۳، ۱۲۰۲/۳ و ۵۳۱/۶ میلیون مترمکعب است. تابع هدف باید بر این مبنا تعریف شود که کمینه‌ی حجم و ظرفیت سدهای مطالعاتی در بالادست به گونه‌ای تأمین شود که ضمن بهبود شرایط تخصیص در بالادست، سهم تاریخی آب در استان پایین دست نقصان نیابد.

بنابراین مقادیر $TARGET_{Kh-S hom ali}$ و $TARGET_{Goles tan}$ تابع هدف به ترتیب باید برابر با متوسط سالیانه نیازهای آبی استان خراسان شمالی و متوسط سالیانه‌ی تأمین نیازهای آبی استان گلستان در شرایط موجود در نظر گرفته شد. برای یافتن بهترین مقادیر برای ضرایب w_1, w_2, w_3, w_4, w_5 و w_7 از سعی و خطا استفاده شد، به گونه‌ای که نیازهای موجود در هر سه استان خراسان شمالی، خراسان رضوی و گلستان را تا حد ممکن تأمین شود و در عین حال کمترین فاصله را نیز تا مقادیر $TARGET$ در این استان‌ها نتیجه شود.

با انجام تحلیل حساسیت روی وزن‌ها بهترین مجموع ضرایب برای مؤلفه‌های w_1, w_2, w_3, w_4, w_5 و w_7 به ترتیب برابر با ۱، ۱، ۱، ۱۰۰، ۱۰۰ و ۱ به دست آمد.

۶. تلفیق مدل MODSIM و الگوریتم PSO: مدل

PSO-MODSIM

در این بخش از تحقیق، یک مدل بهینه‌سازی مبتنی بر شبیه‌سازی به منظور پیدا کردن طرح بهینه‌ی توسعه و تخصیص آب در سیستم‌های منابع آب در سطح حوضه‌ی آبریز توسعه یافت. بدین منظور، MODSIM، مدل جامع شبکه‌ی جریان در سطح

حوضه‌ی آبریز، به عنوان مدل شبیه‌سازی سیستم در فرایند بهینه‌سازی تکاملی الگوریتم PSO درون‌گذاری شد. برای انجام این درون‌گذاری، با استفاده از قابلیت برنامه‌نویسی در محیط Custom Coding مدل MODSIM به زبان VB.NET می‌توان مقادیر متغیرهای مورد نظر مسئله را در هر بار اجرای مدل برابر با مقادیر دلخواه در نظر گرفت و نتایج حاصل از اجرای شبیه‌سازی رفتار سیستم را به ازای مقادیر مذکور مورد بررسی قرار داد.

با برنامه‌نویسی مدل PSO در این محیط و درون‌گذاری مدل MODSIM در آن، مقادیر این پارامترها و متغیرها برابر با مقادیر تولید شده توسط الگوریتم PSO و یا همان ذرات پخش شده در فضای جواب‌های الگوریتم PSO در نظر گرفته می‌شود. سپس به ازای مجموعه مقادیر مختلف از پارامترها و متغیرهای طراحی و بهره‌برداری که توسط PSO تولید می‌شوند، با اجرای مدل MOD-SIM به ازای هر مجموعه ذرات تولید شده توابع سود و هزینه متناظر با آن مجموعه جواب محاسبه می‌شود. ذرات PSO به سمت مقادیری با کمترین تابع هدف در طول افق برنامه‌ریزی و با در نظرگیری قیود مسئله حرکت می‌کنند. قیود این مدل بهینه‌سازی شامل قیده‌های حدود بالا و پایین متغیرهای تصمیم PSO و همچنین قیود الگوریتم شبکه‌ی جریان (NFP) مشتمل بر برقراری شرط پیوستگی و همچنین حدود کران‌های جریان در کانال‌های شبکه در هر گام زمانی هستند.

بر اساس روند شرح داده شده، مدل PSO-MODSIM در حل مسئله‌ی عملی مدیریت منابع آب حوضه‌ی به کار برده شد. تعداد جمعیت الگوریتم PSO برابر با ۱۰ ذره و مقادیر ضرایب الگوریتم برابر با: $c_1 = ۱/۷۵$ ، $c_2 = ۱/۲۵$ در صورت بهترین تکرار تا ۵۰ تکرار متوالی متوقف شده است. در جدول ۱، مقادیر کمینه و بیشینه دامنه‌ی تغییرات متغیرهای طراحی ارائه شده است. مقادیر ۱ و ۱۰ نیز به عنوان کمینه و بیشینه دامنه‌ی تغییرات متغیرهای اولویت ذخیره‌ی آب در مخازن لحاظ شده است.

بر اساس نتایج حاصل از اجرای مدل PSO-MODSIM، مقادیر بهینه‌ی به دست آمده برای متغیرهای طراحی و بهره‌برداری در جدول ۲ گزارش شده است.

جدول ۱. مقادیر کمینه و بیشینه‌ی دامنه‌ی تغییر.

حد بالا	حد پایین	سد
۱۰ MCM	۵ MCM	در بند
۱۰ MCM	۵ MCM	گرما
۵۰ MCM	۴۰ MCM	قوردانو

جدول ۲. نتایج حاصل از اجرای مدل PSO-MODSIM.

مقادیر به دست آمده	متغیرهای مسئله
۵ MCM	ظرفیت سد در بند
۵ MCM	ظرفیت سد گرما
۴۰ MCM	ظرفیت سد قوردانو
۵	اولویت سد در بند
۲	اولویت سد گرما
۴	اولویت سد قوردانو
۱۳۷۸۳۷	تابع هدف

۷. مدل PSO-MODSIM~SVM

مجموعه‌ای داده‌های Off-Line که تصادفی در فضای تصمیم مسئله تولید شده‌اند، در محیط MATLAB صورت می‌پذیرد. از بین داده‌های ورودی ۲۰٪ داده‌ها روی مرزهای فضای تصمیم در نظر گرفته شدند. پس از فراهم شدن مجموعه داده‌های لازم جهت ساخت مدل SVM، ۹۰٪ داده‌ها برای آموزش و ۱۰٪ دیگر برای آزمون مدل SVM در نظر گرفته شدند.

تعیین پارامترهای SVM با استفاده از جستجوی شبکه‌ی ۱۶ برای رسیدن به بهترین ساختار مدل که کمترین خطای تقریب و قابلیت تعمیم‌پذیری بالا^{۱۷} و همچنین عدم وقوع شرایط ورا-آموزی^{۱۸} را دارد، ممکن است. جهت بررسی عملکرد هر کدام از روش‌ها، این معیارها استفاده شده است (روابط ۱۱ الی ۱۳):

۱. متوسط مجموع مربعات خطا (MSE)^{۱۹}:

$$MSE = \sum_{i=1}^n (y_i - y'_i)^2 / n \quad (11)$$

۲. متوسط خطای مطلق (AAE)^{۲۰}:

$$AAE = \sum_{i=1}^n |y_i - y'_i| / n \quad (12)$$

۳. بیشینه‌ی خطای مطلق (MAE)^{۲۱}:

$$MAE = \max(|y_1 - y'_1|, |y_2 - y'_2|, \dots, |y_n - y'_n|) \quad (13)$$

y_i مقادیر مشاهده‌شده، y'_i مقادیر پیش‌بینی‌شده.

برای داده‌های آموزشی دو معیار MSE و ضریب همبستگی و برای داده‌های آزمون همه‌ی معیارها محاسبه شده‌اند. معیار MSE میزان فاصله‌ی مقادیر محاسبه‌شده با استفاده از فرامدل با مقادیر واقعی مشاهده‌شده را نشان می‌دهد. هر چه این معیار بزرگ‌تر باشد، پیش‌بینی فرامدل با خطای بیشتری همراه خواهد بود.

هر چه میزان RAAE کوچک باشد، دقت فرامدل بیشتر خواهد بود؛ ولی از آنجایی که این معیار میزان بزرگی یا کوچکی خطا را در هر نقطه نشان می‌دهد، قادر نخواهد بود برآورد درستی از خطای کلی ارائه دهد. پس استفاده از RMAE در کنار دو معیار فوق توصیه می‌شود.

روند آموزش مدل SVM با تولید ۵۰ داده‌ی تصادفی آغاز شد و با رسیدن به ۱۰۰ داده‌ی تصادفی، میزان خطای آزمون مدل (میانگین مجذور خطا) به سطح قابل قبول (در این مسئله برابر با ۰/۰۰۱ در نظر گرفته شده است) رسید. سپس مدل ساخته‌شده، جایگزین مدل شبیه‌ساز MODSIM شد و نتایج مربوط به مدل جدید PSO-MODSIM~SVM استخراج شد. جهت مقایسه‌ی نتایج حاصل از جایگزینی مدل تقریبی SVM با مدل شبکه‌ی عصبی (ANN)، نتایج مربوط به مدل PSO-MODSIM~ANN نیز در جدول ۳ آمده است. شکل‌های ۱۴ و ۱۵ نمودار خروجی مدل SVM را بر حسب مقادیر واقعی تابع هدف برای مجموعه داده‌های یادگیری و آزمون نشان می‌دهند.


همان‌طورکه در جدول ۳ مشاهده می‌شود، مقادیر تابع هدف تقریبی به‌دست آمده توسط مدل‌های PSO-MODSIM~SVM و PSO-MODSIM به‌ترتیب برابر با ۱۳۷۸۴۷ و ۱۳۷۸۳۷ به‌دست آمده است. مدل MODSIM تحت جواب به‌دست آمده توسط مدل PSO-MODSIM~SVM اجرا شد و مقدار واقعی تابع هدف متناظر با آن برابر با ۱۳۷۸۶۵ به‌دست آمد. نکته‌ی قابل توجه این است که جواب

در مسئله‌ی تخصیص آب ذکرشده زمان موردنیاز برای رسیدن به جواب مطلوب با وجود ۱۰ ذره‌ی جستجوگر در الگوریتم PSO جهت همگرایی به یک جواب مطلوب به تعداد ۲۵۰ تکرار زمانی (به عبارت دیگر در حدود ۲۵۰۰ بار اجرای MODSIM) در حدود ۱۰ تا ۲۰ ساعت با استفاده از پیشرفته‌ترین سیستم‌های رایانه‌ای رایج است. عمده‌ی این زمان محاسباتی، زمان لازم برای هر بار اجرای مدل شبیه‌ساز MODSIM است که در آن به تعداد گام‌های زمانی دوره‌ی شبیه‌سازی، یک مدل بهینه‌ساز با الگوریتم NFP باید حل شود. بدیهی است که در صورت وجود متغیرهای تصمیم بیشتر در مسئله، افزایش طول دوره‌ی هیدرولوژیک شبیه‌سازی و یا مدل‌سازی فرایندهای اندرکنش آب سطحی-زیرزمینی و یا فرایندهای کیفی آب زمان محاسباتی افزایش بیشتری نیز خواهد داشت. علاوه بر آن کالیبراسیون و تنظیم پارامترهای مدل PSO-MODSIM مستلزم حدس و خطا روی مقادیر این پارامترها و در نتیجه اجرای متعدد از مدل است که به دلیل زمان طولانی اجرای مدل انجام این مهم عملاً ممکن نیست.

به منظور بهبود مشکل زمان محاسباتی مدل PSO-MODSIM، ماشین‌های بردار پشتیبان جایگزین مدل شبیه‌سازی MODSIM با هدف تقریب تابع هدف در الگوریتم PSO شد. بدین معنی که در هر تکرار از الگوریتم PSO در مدل PSO-MODSIM~SVM، با تولید مقادیر متغیرهای تصمیم به‌عنوان بردار ورودی SVM، تابع هدف مدل با فراخوانی مدل SVM تقریب زده می‌شود (به جای مدل MODSIM) و محاسبات الگوریتم PSO تا زمان ارضای شرط توقف جستجو ادامه پیدا می‌کند. در شکل ۱۳، نمودار جریان مدل با استفاده از مدل PSO-MODSIM تقریبی نشان داده شده است.

زمان محاسباتی موردنیاز در مدل توسعه داده‌شده در این بخش شامل زمان لازم جهت تولید داده‌های یادگیری و همچنین آموزش مدل جایگزین است. این زمان بسیار کمتر از زمان لازم برای اجرای مدل PSO-MODSIM خواهد بود. تولید داده‌های یادگیری و آموزش مدل جایگزین برای یک بار صورت می‌پذیرد و مدل تقریبی، جایگزین مدل MODSIM می‌شود.

در مدل PSO-MODSIM~SVM آموزش مدل SVM با استفاده از



شکل ۱۳. نمودار روند حل مدل PSO-MODSIM با استفاده از مدل تقریبی.

جدول ۳. نتایج ناشی از اجرای مدل PSO-MODSIM~SVM و PSO-MODSIM~ANN.

خطا	تابع هدف		اولویت سد			ظرفیت سد		RMAE (test)	RAAE (test)	MSE		تعداد داده آموزشی	فرامدل
	تقریبی	دقیق	در بند گرماب	قوردانلو	در بند گرماب	قوردانلو	در بند گرماب			(test)	(train)		
-5.6×10^{-4}	۱۳۷۸۶۵	۱۳۷۸۴۷	۴	۲	۶	۴۱۲۵۶	۵۰۰۰	۵۰۰۰	1.52×10^{-5}	0.000028	1.47×10^{-6}	۱۰۰	SVM
0.0011	۱۳۸۰۸۳	۱۳۷۹۳۰	۴	۲	۳	۴۰۴۶۷	۶۲۹۴	۵۰۴۱	7.9×10^{-6}	7.9×10^{-7}	3.18×10^{-6}	۱۰۰	ANN


به مدل PSO-MODSIM~ANN به مقادیر به‌دست آمده توسط مدل PSO-MODSIM نزدیک‌تر است، که این امر نشان‌دهنده‌ی عملکرد مطلوب‌تر مدل SVM در تقریب تابع هدف است.

زمان محاسباتی موردنیاز در مدل‌های تقریبی توسعه داده‌شده در این بخش شامل زمان لازم جهت تولید داده‌های یادگیری و همچنین آموزش مدل جایگزین است. این زمان در مسئله‌ی موردبررسی شامل تولید ۱۰۰ داده‌ی تصادفی و آموزش مدل‌های تقریبی با استفاده از این داده‌ها بود. به علت اینکه زمان لازم برای آموزش مدل‌های SVM و ANN با استفاده از ۱۰۰ داده‌ی آموزشی بسیار اندک بود، لذا در ادامه از در نظر گرفتن آن صرف‌نظر شد. بدیهی است که در مسائل بزرگ‌مقیاس با تعداد داده‌های بیشتر، این زمان نیز باید در نظر گرفته شود. با توضیحات بالا زمان اجرای مدل‌های PSO-MODSIM~SVM و PSO-MODSIM~ANN برابر با ۱۰۰ بار اجرای مدل MODSIM است که این زمان بسیار کمتر از زمان لازم برای اجرای مدل PSO-MODSIM (۲۵۰۰ بار اجرای مدل MODSIM) خواهد بود، در حالی که دقت جواب‌های حاصل از استفاده از این فرامدل‌ها قابل‌قبولی نیز دارند.


در جدول ۴، وضعیت تأمین نیازهای استان‌های درون حوضه حاصل از اجرای مدل‌های PSO-MODSIM، PSO-MODSIM~SVM و PSO-MODSIM~ANN با یکدیگر مقایسه شده است. در این جدول مشاهده می‌شود که میزان تأمین متوسط سالانه‌ی نیازهای کل حوضه با استفاده از جواب به‌دست آمده توسط دو مدل تقریبی ذکرشده به میزان اندکی کمتر از مقدار به‌دست آمده توسط مدل PSO-MODSIM است. از طرفی مدل‌های تقریبی در میزان تأمین نیازهای کل حوضه و استان‌های موجود در آن نیز تفاوت اندکی با مدل PSO-MODSIM دارند.

۸. نتیجه‌گیری

جهت رفع مشکل زمان محاسباتی زیاد موردنیاز در مدل PSO-MODSIM، مدل SVM جایگزین مدل شبیه‌سازی MODSIM با هدف تقریب تابع هدف در الگوریتم PSO شد. مدل توسعه داده‌شده PSO-MODSIM~SVM، به دلیل برخورداری از زمان کم محاسباتی ابزار مناسبی جهت انجام عملیات تحلیل حساسیت نسبت به پارامترهای مؤثر در نحوه‌ی رفتار مدل و همچنین جستجوی ریزتر



شکل ۱۴. نمودار خروجی مدل SVM برحسب مقادیر واقعی تابع هدف برای مجموعه داده‌های یادگیری.



شکل ۱۵. نمودار خروجی مدل SVM برحسب مقادیر واقعی تابع هدف برای مجموعه داده‌های آزمون.

به‌دست آمده توسط مدل PSO-MODSIM~SVM به مقدار جواب به‌دست آمده توسط مدل PSO-MODSIM بسیار نزدیک است. همچنین نتایج به‌دست آمده حکایت از نزدیکی مقادیر بهینه‌ی به‌دست آمده برای متغیرهای طراحی توسط مدل‌های PSO-MODSIM و PSO-MODSIM~SVM و تفاوت اندک در مقادیر بهینه‌ی اولویت‌های ذخیره‌ی آب در مخازن به‌عنوان متغیرهای بهره‌برداری دارند. از طرفی نتایج به‌دست آمده از مدل PSO-MODSIM~SVM نسبت

جدول ۴. وضعیت تأمین نیازهای استان‌ها در بهترین جواب مدل‌های PSO-MODSIM و PSO-MODSIM~SVM.

مقدار تأمین شده (MCM)			مقدار نیاز (MCM)	آب‌م
PSO-MODSIM~SVM	PSO-MODSIM~ANN	PSO-MODSIM		
۱۰۶۲/۱۵	۱۰۶۲/۱	۱۰۶۲/۱۸۷	۱۸۸۷/۸۶	کل حوضه
۱۵۲/۳۸۹	۱۵۲/۳۸۳	۱۵۲/۳۸۹	۵۳۱/۶۱	استان گلستان
۸۳۵/۵۶۵	۸۳۵/۵۶۸	۸۳۵/۶۰۲	۱۲۷۷/۹۳	استان خراسان شمالی
۷۴/۱۹۶	۷۴/۱۹۶	۷۴/۱۹۶	۷۸/۳۱	استان خراسان رضوی

شرایط استفاده از فرامدل سازی به شکل برخط^{۲۲} که در آن فرایند آموزش و تقریب تابع در حین بهینه سازی و همراه با آن به پیش می رود، قابل توصیه است. نکته ی آخر، توجه بدین واقعیت است که توجیه استفاده از شیوه ی فرامدل سازی در مسائل متوسط مقیاس از نظر بار محاسباتی مدل شبیه ساز، ولی بزرگ مقیاس از منظر تعداد متغیرها و بعد مکانی مسئله فقط مسئله ی زمان اجرا نیست. مسئله ی کیفیت جواب ها و تحلیل حساسیت نتیجه ی مدل و تنظیم پارامترهای مدل بهینه سازی فراکاوشی نیز توجیه کننده ی استفاده از این ابزار است. یک مدل بهینه سازی با زمان اجرای حتی چندساعته نیز به منظور تنظیم پارامترهای آن باید به دفعات متعدد اجرا شود که به دلیل همین مشکل زمانی نمی تواند به طور مؤثر انجام پذیرد. به همین دلیل ارزیابی میزان بهینگی و کیفیت جواب های حاصل و درجه ی نزدیک به بهینه بودن جواب ها عملاً ممکن نخواهد بود. استفاده از فرامدل سبب می شود به علت سرعت بسیار بالای مدل نهایی تقریب زده شده بتوان فرایند تنظیم پارامترهای مدل بهینه سازی فراکاوشی را به شکل مؤثر انجام داد. در این گذر می توان یا کیفیت جواب ها را بهبود داد و یا دست کم در صورت نیل به جواب هایی نزدیک به آنچه مدل اصلی به دست آورده است، نسبت به احتمال نزدیک به بهینه ی سراسری بودن جواب حصول اطمینان بیشتر حاصل کرد. این مهم یکی از دلایل اصلی و توجیه کننده ی استفاده از فرامدل سازی در مدل های حتی با زمان اجرای چندین ساعت است که در سوابق نیز مورد تأکید قرار گرفته است.

۹. تقدیر و تشکر

نویسندگان از پژوهشکده ی منابع آب مؤسسه ی تحقیقات آب و آقای دکتر مجتبی شوریان به علت همکاری و در اختیار گذاشتن داده های مطالعه ی موردی کمال تشکر را دارد.

در فضای جستجوی مسئله با تعداد ذرات بیشتر است. استفاده از این قابلیت ها در مسئله ی تحت بررسی منجر به یافتن جوابی بهتر نسبت به مدل بهینه سازی مبتنی بر شبیه سازی واقعی سیستم تحت مطالعه در زمان کمتر شد. البته باید خاطرنشان کرد که زمان واقعی معرف در مدل PSO-MODSIM~SVM شامل زمان صرف شده برای آموزش و آزمون مدل SVM نیز است. لیکن این کار فقط یک بار انجام شده و تولید داده های لازم برای SVM مورد استفاده نیز به راحتی و به صورت اتوماتیک در محیط Custom Coding مدل MODSIM قابل انجام است.

نکته ی قابل ملاحظه در استفاده از روش مدل جایگزین به کاررفته در این مطالعه این است که در مدل PSO-MODSIM~SVM آموزش مدل با استفاده از یک مجموعه داده ی Off-Line که به صورت تصادفی در فضای تصمیم مسئله تولید شده اند، صورت پذیرفته است. نتایج به دست آمده از این مدل تقریبی بیانگر کیفیت مناسب پاسخ های این مدل (نزدیکی به پاسخ های حاصل از مدل PSO-MODSIM) و کاهش قابل توجه بار محاسباتی نسبت به مدل PSO-MODSIM~ANN است. از طرفی این مدل در مقایسه با مدل مشابه PSO-MODSIM~ANN با فرامدل از نوع شبکه های عصبی مصنوعی در مسئله ی مورد بررسی عملکرد مطلوب تری نشان داد.

لازم به توضیح است که استفاده از راهکار مدل جایگزین در مسائل با ابعاد کم و فضای تابع جستجوی ساده مشکل خاصی به همراه ندارد، چرا که با تولید داده به اندازه ی کافی می توان احتمال پوشش نواحی شامل جواب های مطلوب را افزایش داد؛ اما با افزایش ابعاد مسئله ی تولید داده ها به طور تصادفی حتی به مقدار زیاد نیز نمی تواند راهکار مناسبی برای ساخت یک مدل جایگزین مناسب باشد. در این

پانویس ها

1. support vector machines
2. meta-model management
3. quadratic response surface
4. Bayesian
5. Stochastic response surface
6. radial bases functions
7. adaptive neural network AG (ANGA)
8. SVMs
9. radial basis function (RBF)
10. quadratic program
11. grid search
12. data
13. particle systems
14. priority-base
15. network flow programming (NFP)
16. srld search
17. generalization
18. over-training
19. mean squared error (MSE)
20. average absolute error (AAE)
21. maximum absolute error (MAE)
22. on-line

منابع (References)

1. Robinson, G.M. and Keane, A.J. "A case for multi-level optimization in aeronautical design", *Aeronautical J.*, **103**(1028), pp. 481-485 (1999).
2. Nair, P.B. and Keane, A.J. "Passive vibration suppression of flexible space structures via optimal geometric re-design", *AIAA J.*, **39**(7), pp. 1338-1346 (2001).
3. Ratle, A. "Kriging as a surrogate fitness landscape in evolutionary optimization", *J. Artificial Intelligence for Eng. Design Analysis and Manufacturing*, **15**(1), pp. 37-49 (2001).
4. Liang, K.H., Yao, X. and Newton, C. "Evolutionary search of approximated N- dimensional landscapes", *Int. J. of Knowledge-Based Intelligent Eng. Systems*, **4**(3), pp. 172-183 (2000).
5. Farhang-Mehr, A. and Azarm, S. "Bayesian meta-modeling of engineering design simulations: A sequential approach with adaptation to irregularities in the response behavior", *Int. J. for Numerical Methods in Eng.*, **62**, pp. 2104-2126 (2005).

6. Broud, D.R., Dandy, G.C. and Maier, H.R. "Water distribution system optimization using meta-models", *J. Water Resources Planning and Management*, **131**(3), pp. 172-180 (2005).
7. Shoemaker, C.A., Regis, R.G. and Fleming, R.C. "Watershed calibration using multistate local optimization and evolutionary optimization with radial basis function approximation", *Hydrological Sciences J.*, **52**(3), pp. 450-465 (2007).
8. Yan, S. and Minsker B. "Optimal groundwater remediation design using adaptive neural network genetic algorithms", *J. Water Resources Research*, **42**, W05407, doi: 10.1029/2005WR004303 (2006).
9. Mousavi, S.J. and Shourian, M. "Adaptive sequentially space-filling metamodeling applied in optimal water quantity allocation at basin scale", *Water Resour. Res.*, **46**(3), W03520, doi:10.1029/2008WR007076 (2010).
10. Cristianini, N. and Shawe-Taylor, J., *An Introduction to Support Vector Machines*, Cambridge University Press, New York (2000).
11. Vapnik, V.N., *Statistical Learning Theory*, John Wiley, New York (1998).
12. Eberhart, R.C. and Kennedy, J. "A new optimizer using particle swarm theory", *Proceedings Sixth Symposium on Micro Machine and Human Science, IEEE Service Center, Piscataway, NJ*, pp. 39-43 (1995).
13. Integrated Water Resources Studies of Atrak Basin. "Water resources planning report", Water Resources Center, Water Research Institute (In Persian) (2010).

SUPPORT VECTOR MACHINE -BASED META-MODELING FOR BASIN-SCALE OPTIMUM WATER ALLOCATION

G. Mirfenderesgi

ginaz_2005@aut.ac.ir

S.J. Mousavi(corresponding author)

jmosavi@aut.ac.ir

**Dept. of Civil Environmental Engineering
Amir kabir University of Technology**

Sharif Civil Engineering Journal

Volume 29, Issue 2, Page 107-116, Original Article

© Sharif University of Technology

- Received 1 March 2011; received in revised form 15 November 2011; accepted 18 February 2012.

Abstract

Basin-scale river basin simulation models are vital tools in assessing and quantifying large-scale water resource systems performances under different scenarios. However, simulation models are not capable of doing multi-period optimization for optimal planning and management purposes. Linking river basin simulation models to multiperiod optimization algorithms could be a remedy to such shortcoming. Nevertheless, large-scale river basin models, when used as the simulation model of an optimization algorithm, may face difficulties, in terms of the needed time for combined optimization-simulation models to run. The more hydrologic and socio-economic processes to be addressed in the simulation model, the more the computational burden of the combined model would be. Meta-modeling is one of the useful approaches to dealing with this difficulty, where a fast-running approximate model, called meta-model, replaces the exact simulation model. This study presents application of the particle swarm optimization (PSO) algorithm, linked to the MODSIM decision support system (DSS), as a river basin simulation model, resulting in the integrated PSO-MODSIM optimization-simulation model, for solving basin-scale water allocation problems. The developed model was applied to the problem of optimal water resource development plans, as well as optimal water allocation of the Atrak River Basin, as a real case study in north-east Iran. Where there are serious competitions between upstream and downstream provinces of the basin in utilization of available water resources. The objective function of the model, which consists of design variables; i.e., reservoir capacities, and operational; i.e., priority numbers of reservoir target levels, was calibrated based on improving water allocation conditions compared to a benchmark scenario, in which development projects were not implemented. Since the integrated model was time consuming, support vector machines (SVMs) were used as a meta-model to develop the PSO-MODSIM~ SVM model, in which an SVM-based

surrogate model replaces MODSIM. The performance of the PSO-MODSIM, PSO-MODSIM~ SVM and another model, with a meta-model of artificial neural network (ANNs) type, were analyzed and compared through their application to optimal water allocation and planning water resource development projects in the basin. Before using SVMs as a meta-model, we first showed how well they perform in approximating benchmark multidimensional mathematical functions. Then, basin-scale optimal water allocation problems were solved using surrogate optimization techniques. Both SVM and ANN models were able to approximate and represent the MODSIM DSS reasonably. However, the results show that SVM-based surrogate optimization has performed satisfactorily in terms of both the quality of the solutions and the saving in computational burden compared to the model employing ANN as the meta-model.

Key Words: Water allocation; river basin; surrogate optimization; support vector machines.