



بررسی کارایی مدل ماشین بردار پشتیبان در پیش‌بینی تغییرات پارامترهای کیفی آب (مطالعه موردی: تالاب بین‌المللی چغاخور)

احمدرضا پیرعلی زفره‌ئی^۱، سید علی اکبر هدایتی^{۱*}، سعید پورمنافی^۲، امید بیرق‌دار کشکولی^۳، رسول قربانی^۱

^۱ گروه تولید و بهره‌برداری آبزیان، دانشکده شیلات و محیط زیست، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

^۲ گروه محیط زیست، دانشکده منابع طبیعی، دانشگاه صنعتی اصفهان

^۳ گروه شیلات، دانشکده منابع طبیعی، دانشگاه صنعتی اصفهان

چکیده

نوع مقاله:

پژوهشی

تاریخچه مقاله:

دریافت: ۹۸/۰۳/۱۹

اصلاح: ۹۸/۰۴/۳۰

پذیرش: ۹۸/۰۷/۲۲

کلمات کلیدی:

تالاب چغاخور

کلروفیل a

RMSE

آب‌های داخلی از قبیل تالاب‌ها در زمره اکوسیستم‌های حساس محسوب می‌شوند که بهره‌وری پایدار از آن‌ها تنها با اتخاذ رویکرد زیست‌محیطی مناسب ممکن خواهد بود. برآورد پارامترهای کیفی آب با استفاده از مدل‌ها موجب کاهش هزینه‌ها و دسترسی سریع‌تر برای مدیریت منابع آب خواهد شد. در این مطالعه از مدل ماشین بردار پشتیبان در دوره زمانی ۳۲ ساله از ۱۳۶۴ تا ۱۳۹۶ برای شبیه‌سازی پارامتر کیفی کلروفیل a و شفافیت آب (عمق سشی دیسک) در تالاب بین‌المللی چغاخور استفاده شد. از ۷۰ درصد داده‌ها به منظور آموزش و از بقیه داده‌ها برای آزمون و تست مدل استفاده شد. ضریب تعیین (R^2) و خطای (RMSE) در روش ماشین بردار پشتیبان برای ترکیب بهینه کلروفیل a و سشی دیسک به ترتیب برابر ۰/۹۳، ۰/۹۱ و ۰/۰۹۷ میلی‌گرم بر مترمکعب، ۰/۰۴۹ متر است. همچنین مدل ماشین بردار پشتیبان با حداقل ورودی نیز قدرت پیش‌بینی لازم را داشت. نتایج این مطالعه نشان داد که ماشین بردار پشتیبان قابلیت بالایی در پیش‌بینی کلروفیل a و شفافیت آب دارد و می‌توان از آن در تعیین استراتژی‌های مناسب در مدیریت تالاب چغاخور بهره برد.

مقدمه

تالاب‌ها اکوسیستم‌هایی هستند که برای حفظ کیفیت محیط زیست، زیستگاه ماهیان و گونه‌های حیات وحش و دیگر نیازهای انسانی ضروری هستند (Tiner, 2010). با توجه به اثرات مختلف طبیعی و انسانی، تالاب‌ها با فشارهای جدی مرتبط با افزایش سطح دریا، تغییرات اقلیم، افزایش تقاضای استفاده از منابع طبیعی و اثرات تجمعی استرس‌زای محیطی مواجه هستند (Dahl, 2011). تالاب منابعی را برای مقاصد مختلف از قبیل خاک به منظور کشاورزی، ماهیگیری برای غذا و سودآوری، تأمین مواد مغذی و پناهگاه موجودات این اکوسیستم (Kar, 2013) فراهم می‌نماید و خدمات مختلف اکوسیستمی مانند تصفیه آب و ایجاد منطقه بافر برای موجودات ارائه می‌کند (Veronesi et al., 2013). امروزه نگاهی جامع و برخورد سیستمی در مدیریت کمی و کیفی منابع آب به علت افزایش مؤلفه‌های این منابع و پیچیدگی ارتباط و اثرات متقابل آن‌ها از اهمیت ویژه‌ای برخوردار است (Javid et al., 2013). برنامه‌ریزی صحیح جهت بهره‌برداری از این منابع که تحت تأثیر متغیرهای متعددی مانند برنامه‌های جامع کشاورزی و تولید غذا، گسترش صنایع، توسعه شهرها و شهرک‌ها، افزایش جمعیت، برداشت از منابع و

* نویسنده مسئول، پست الکترونیک: hedayati@gau.ac.ir

غیره قرار دارد، ضروری است (Sharma *et al.*, 2010). از طرفی مدل‌سازی اکوسیستم‌های آبی به دلیل پیچیدگی این سیستم‌ها به آسانی میسر نیست. مدل‌سازی آماری به دو روش پارامتریک و غیرپارامتریک صورت می‌گیرد. روش‌های پارامتریک نظیر رگرسیون لجستیک (Logistic regression) و روش‌های ترکیب خطی و رتبه‌ای (Linear combination)، قابلیت مدل‌سازی روابط پیچیده‌ی غیرخطی و اثر متقابل درجه بالا را ندارند. محدود بودن تعداد داده‌های ورودی، حساس بودن بیشتر این مدل‌ها به داده‌های غیرموجود یا پرت و پیش‌فرض‌های آن از محدودیت‌های این روش‌ها به شمار می‌آید (Samui, 2008).

در این راستا انتخاب مدلی که بتواند میزان فرایندهای فیزیکوشیمیایی در اکوسیستم‌های آبی را با دقت بالا و خطای کم مدل‌سازی نماید کمک شایانی در مدیریت صحیح منابع آبی و افزایش عملکرد آن‌ها دارد (Samsudin *et al.*, 2011). به این منظور روش‌های دقیق و نوین غیرپارامتریک جهت پیش‌بینی و مدل‌سازی مکانی پارامترهای کیفی آب مانند شبکه عصبی مصنوعی (ANN: Artificial Neural Network)، برنامه‌ریزی بیان ژن، شبکه بیزین، الگوریتم ماشین مانند ماشین بردار پشتیبان (SVM: Support vector machine) و جنگل تصادفی (Random Forest) توانایی مدل‌سازی بهینه ارتباطات پیچیده بین عوامل مؤثر بر پارامترهای آب در اکوسیستم را دارا هستند (Samui, 2008).

ماشین بردار پشتیبان یکی از روش‌های یادگیری تحت نظارت (Supervised learning) است که هم برای دسته‌بندی و هم رگرسیون و پیش‌بینی قابل استفاده است. این روش توسط Vapnik بر پایه تئوری یادگیری آماری (Statistical Learning Theory) بنا نهاده شده است (Pai and Hong, 2007). در سال‌های اخیر استفاده از مدل‌های هوشمند ماشین بردار پشتیبان در مطالعات پیش‌بینی اکوسیستم‌های آبی مورد توجه پژوهشگران قرار گرفته است؛ از جمله مطالعه Ghorbani و همکاران (۲۰۱۶a) در جهت پیش‌بینی جریان روزانه رودخانه سایپرس تگزاس، Sedighi و همکاران (۲۰۱۶) در زمینه پیش‌بینی فرآیند بارش رواناب حوضه آبریز رودک شمال شرق تهران با کمک اطلاعات سنجنده‌مودیس، Huang و همکاران (۲۰۱۴) در جریان دبی ماهانه رودخانه ایستگاه هواکسی چین، Mohammadpour و همکاران (۲۰۱۲) در پیش‌بینی جریان دبی روزانه حوضه آبریز قره سو، Kakaei Lafadani و همکاران (۲۰۱۳) در شبیه‌سازی جریان روزانه حوضه اسکندری، Xu و همکاران (۲۰۰۷) در مدل‌سازی کیفیت آب دریاچه Tai با کمک سنجش از دور که نتایج همه آن‌ها نشان داد مدل ماشین بردار پشتیبان عملکرد قابل قبولی در مقایسه با سایر روش‌ها در پیش‌بینی و شبیه‌سازی فرایندهای اکوسیستم‌های آبی دارد (Mohammadpour *et al.*, 2012; Kakaei Lafadani *et al.*, 2013; Huang *et al.*, 2014; Sedighi *et al.*, 2016; Ghorbani *et al.*, 2007; Xu *et al.*, 2016a; Xu *et al.*, 2007). Xu و همکاران (۲۰۰۷) با استفاده از مدل SVM و سنجش از دور، کیفیت آب دریاچه Tai را مدل‌سازی کردند. نتایج تخمین بالای مقادیر کلروفیل *a* در نقاط نمونه‌برداری شده توسط مدل SVM و همچنین توسط ماهواره در مقایسه با شبکه عصبی را نشان داد (Xu *et al.*, 2007). Sadeghi و همکاران (۲۰۱۲) با استفاده از مدل SVM به بررسی و پیش‌بینی توزیع مکانی گونه مهاجم آزولا (*Azolla filiculoides*) در تالاب انزلی پرداختند. عمق تالاب و اکسیژن محلول بر اساس این مدل بیشترین تأثیر را در پراکنش این گونه مهاجم داشتند (Sadeghi *et al.*, 2012). Huang و همکاران (۲۰۱۰) مدل SVM را برای پیش‌بینی کیفیت آب دریاچه Tai با استفاده از سنجش از دور به کار بردند. نتایج حاکی از عملکرد خوب و دقت مدل‌سازی بالای این مدل بود (Huang *et al.*, 2010). Najah و همکاران (۲۰۰۹) با استفاده از شبکه‌های عصبی، مقادیر EC و TDS و کدورت را در رودخانه جوهور مالزی بررسی کردند و کارایی این مدل را در ارزیابی کیفیت آب نشان دادند (Najah *et al.*, 2009). در اکوسیستم‌های آبی، فیتوپلانکتون‌ها از پایه‌های اساسی در زنجیره‌های غذایی و منبع اصلی غذا برای مصرف‌کنندگان اولیه هستند (Lurling *et al.*, 2006). از آنجایی که انرژی نورانی به وسیله کلروفیل در ارگانیزم‌های فتوسنتزکننده جذب می‌شود، بنابراین بررسی این پارامتر در مطالعات زیست‌محیطی دارای اهمیت است (Mallick *et al.*, 2003). از طرفی سنجش شفافیت (کدورت) در اکوسیستم‌های آبی جهت بررسی و مطالعه رسوبات معلق و کیفیت آب و مدیریت بخش زیرسطحی آب امری مهم به شمار می‌رود (Weeks *et al.*, 2012). مطالعه پارامترهای زیست‌محیطی مانند دما، شفافیت و کلروفیل *a*، با توجه به نقش تالاب‌ها در کنترل تغییرات اقلیمی (Climate change) در سال‌های اخیر به دلیل


وجود ذخایر کربن (۱۵-۳۰ درصد) در تالاب‌ها؛ بسیار مورد توجه قرار گرفته است (Limpens *et al.*, 2008). بر اساس مطالعه رتبه‌بندی تالاب‌ها، تالاب چغاخور پس از تالاب‌های هورالعظیم، میانکاله و خلیج گرگان، شادگان، دلتای حله، تالاب انزلی، دشت ارژن و پریشان و تالاب هامون پوزک، رتبه‌ی هشتم را در میان ۷۵ تالاب بر اساس معیارهای پنج گانه پرندگان، ماهیان، عوامل تهدیدکننده، مسائل اقتصادی و اجتماعی و موقعیت حفاظتی به خود اختصاص داده است (Kiabi *et al.*, 2004).

در مجموع با توجه به اینکه تالاب بین‌المللی چغاخور یکی از بزرگ‌ترین تالاب‌های استان چهارمحال و بختیاری و مهم‌ترین منبع تأمین‌کننده آب مجاور خود از لحاظ کشاورزی و شرب می‌باشد و کاهش حجم آب این تالاب مشکلات زیادی در حوضه آبریز به ویژه گونه‌های آبی آن ایجاد می‌کند؛ لذا، اهمیت شبیه‌سازی و پیش‌بینی پارامترهای کیفی آب و اقدامات مدیریتی جهت مدیریت آن بیش از پیش ضروری است. بنابراین هدف این پژوهش پیش‌بینی پارامترهای کلروفیل *a* و شفافیت (عمق سشی دیسک) به عنوان پارامترهای مهم کیفی آب در این تالاب با استفاده از مدل ماشین بردار پشتیبان در دوره زمانی ۱۳۶۴ تا ۱۳۹۶ می‌باشد.

مواد و روش‌ها

مشخصات منطقه مورد مطالعه

تالاب چغاخور در استان چهارمحال و بختیاری، شهرستان بروجن و بخش بلداجی قرار دارد این تالاب بین عرض‌های ۱۷° و ۵۴' و ۳۱" تا ۳۱° و ۵۶' و ۳۱" عرض شمالی و ۴۰" و ۵۲' و ۵۰" تا ۱۴" و ۵۶' و ۵۰" طول شرقی قرار گرفته است (شکل ۱) (Behrouzi-Rad, 2008). تالاب چغاخور بیست و سومین تالاب بین‌المللی ثبت‌شده‌ی کشور در کنوانسیون رامسر می‌باشد. این تالاب یکی از مهم‌ترین سایت‌های ایران از لحاظ گونه ماهی گورخری (*Aphanius vladykovi*) بوده و به لحاظ کنترل سیلاب، تغذیه آب‌های زیرزمینی و درکل به عنوان ذخیره‌گاه تنوع زیستی اهمیت دارد (Mahab Ghods Consulting Engineers, 2008). تالاب چغاخور از سال ۱۳۷۸ توسط سازمان حفاظت محیط زیست به عنوان منطقه شکارممنوع اعلام و مورد حفاظت قرار گرفت (Behrouzi-Rad, 2008).



داده‌های مورد استفاده

داده‌های کیفی تالاب چغاخور مورد استفاده در این مطالعه برای یک دوره ۳۲ ساله از سال ۱۳۶۴ تا ۱۳۹۶ می‌باشند. بدین منظور از پایگاه داده زمین‌شناسی آمریکا (سایت: earthexplorer.usgs.gov)، تصاویر ماهواره‌ای در بازه زمانی فوق از سنجنده لندست تهیه شد. پس از انجام تصحیحات مورد نیاز، جهت استخراج پارامترهای کلروفیل a و شفافیت پردازش‌ها و الگوریتم‌های مرتبط با آن لحاظ گردید. سپس لایه‌های رستری تهیه شده به داده‌های نقطه‌ای تبدیل شد. کلیه پردازش‌ها در محیط ArcGIS 10.2 صورت گرفت. وضعیت توصیف آماری داده‌های کیفی آب مورد استفاده در جدول ۱ نمایش داده شده است.

جدول ۱. مشخصات آماری پارامترهای کیفی تالاب چغاخور

کلروفیل a (میلی‌گرم بر مترمکعب)	ششی دیسک (متر)	دمای آب (سانتی‌گراد)	
حداکثر	۲/۲	۳۸/۵	۱/۶۴
حداقل	۱/۴۲	۷/۳۵	۰/۲۷
میانگین \pm انحراف معیار	۱/۷۶ \pm ۰/۲۲	۱۷/۱۹ \pm ۳/۵۷	۰/۸۳۲ \pm ۰/۳۴

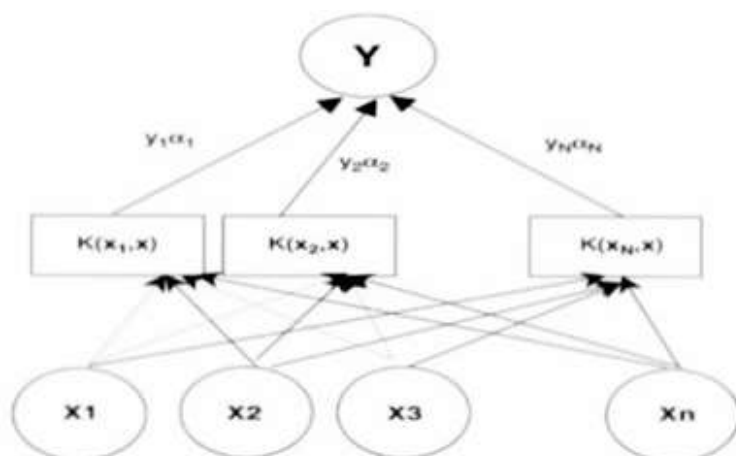
مدل ماشین بردار پشتیبان

ماشین‌های بردار پشتیبان در سال ۱۹۶۳ ابداع و در سال ۱۹۹۵ برای حالت غیرخطی تعمیم داده شدند (Bazargan-Lari et al., 2010). این ماشین‌ها که مشابه سایر روش‌های مرسوم در هوش مصنوعی نیازمند آموزش هستند، ابزاری قوی در حوزه شناسایی الگو و رگرسیون به شمار می‌روند و در چند سال اخیر برای شناسایی و شبیه‌سازی مشخصات کمی و کیفی منابع آب‌های سطحی و زیرزمینی به کار رفته‌اند (Mosleh et al., 2012). اولین کاربرد این روش (مدل ماشین بردار پشتیبان) در مسائل آب توسط Dibike و همکاران (۲۰۰۱) با شبیه‌سازی بارش - رواناب ارائه شد (Dibike et al., 2001). شکل ۲، نمای شماتیک این مدل را نشان می‌دهد.

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 (Vapnik, 1995).

رابطه ۱:

$$y = f(x) = \sum_{k=1}^m \bar{a}_k \cdot K(X, X_k) + b$$



شکل ۲. شمای عملکرد مدل ماشین بردار پشتیبان

$\bar{\alpha}_k$ ، میانگین مقادیر وزن یا بردار ضرایب (لاگرانژ) و b ، ثابت مشخصه‌های تابع رگرسیونی، $K(x, x_k)$ تابع کرنلی است که برای ایجاد ماشین‌هایی با انواع مختلفی از سطوح تصمیم‌گیری غیرخطی در فضای داده‌ها، ضرب‌های داخلی تولید می‌کند، آنگاه هدف پیدا کردن فرم تابعی برای $f(x)$ است. این مهم با آموزش مدل SVM، توسط مجموعه‌ای از نمونه‌ها (مجموعه الگوهای آموزش مدل) (N) محقق می‌شود (Misra et al., 2009). وپنیک برای کاربرد ماشین بردار پشتیبان در مسایل رگرسیون از تابع خطای جدیدی به نام ϵ -insensitive استفاده کرد، به گونه‌ای که این تابع، خطاهایی را که در یک فاصله معین از مقادیر واقعی می‌باشند، نادیده می‌گیرد. این تابع به صورت رابطه ۲ تعریف می‌گردد (Vapnik, 1995):

رابطه ۲:

$$L_{\epsilon}(f(x) - y) = \begin{cases} |f(x) - y| - \epsilon & \text{if } |f(x) - y| \geq \epsilon \\ 0 & \text{otherwise} \end{cases}$$

که در آن C (Capacity)، ثابت گنجایش، عددی صحیح و مثبت است که عامل تعیین جرمه در هنگام رخ دادن خطای آموزش مدل است. این تابع خطا مقادیر خطای کمتر از ϵ را نادیده می‌گیرد ولی برای داده‌هایی که مقادیر برآوردی اختلاف بیش از ϵ دارند، مقدار خطایی مطابق با آنچه که در رابطه ۲ ذکر گردیده در نظر می‌گیرد؛ با جایگزینی تابع فوق به عنوان خطای تجربی و با استفاده از اصل کمینه‌سازی خطای ساختاری و حل مسئله بهینه‌سازی حاصل در فرم دوگانه با استفاده از ضرایب لاگرانژ، روش ماشین بردار پشتیبان منجر به حل مسئله بهینه‌سازی در رابطه زیر می‌شود: به عبارتی برای محاسبه α و b ، لازم است تابع خطا (رابطه ۲) در مدل ϵ -SVM با در نظر گرفتن شرایط (قیود) در رابطه ۳ بهینه شود (Yoon et al., 2011).

رابطه ۳:

$$\max \quad -\frac{1}{2} \sum_i^N \sum_j^N (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)K(x_i, x_j) - \epsilon \sum_i^N (\alpha_i - \alpha_i^*) + \sum_i^N y_i (\alpha_i - \alpha_i^*)$$

$$\text{Subject to } \left\{ \begin{array}{l} \sum_i^N (\alpha_i - \alpha_i^*) = 0 \\ 0 \leq \alpha_i \leq C, i = 1, 2, \dots, N \\ 0 \leq \alpha_i^* \leq C, i = 1, 2, \dots, N \end{array} \right.$$

محاسبه α_i ، در فضای مشخصه آن ممکن است بسیار پیچیده باشد (Yoon et al., 2011). برای حل این مشکل روند معمول در مدل رگرسیونی، می‌توان از توابع مختلف کرنل برای ساخت انواع مختلف ϵ -SVM استفاده کرد. انواع توابع کرنل قابل استفاده در مدل SVM رگرسیونی عبارت‌اند از: کرنل چندجمله‌ای با سه مشخصه هدف و کرنل توابع پایه شعاعی (RBF) با یک مشخصه هدف؛ تابع به کار رفته در این مطالعه، تابع پایه شعاعی است و طبق رابطه ۴ محاسبه می‌شود (Hsu et al., 2003).

رابطه ۴:

$$K(X, X_k) = \exp\left(\frac{-1}{\sigma^2(X - X_k)^2}\right)$$

که در آن δ ، پهنای باند کرنل تابع پایه شعاعی (RBF) است. تابع پایه شعاع (RBF) با بیشترین میزان ضریب همبستگی از سوی هیدرولوژیست‌ها استفاده می‌شود (Ghorbani et al., 2016b). در نهایت برای به دست آوردن $f(x)$ از رابطه ۵، استفاده می‌شود (Yoon et al., 2011):

رابطه ۵:

$$f(x) = \sum_{k=1}^m (\alpha_i - \alpha_i^*) \cdot K(X_i, X_j) + b$$

که در آن α_i و α_i^* ضرایب لاگرانژ (ضرایب کمبود (Slack) و $k(x_i, x_j)$ تابع کرنلی است. برای حل مسئله باید مقادیر پارامترهای C و ε و گاما همچنین پارامترهای مربوط به تابع کرنل انتخابی مشخص شوند. برای بهینه‌سازی سه پارامتر مذکور از روش جستجوی شبکه (Grid Search) استفاده می‌شود (Hsu et al., 2003). شایان ذکر است برای بهره‌گیری از مدل ماشین بردار پشتیبان از محیط برنامه $R_{3.4}$ استفاده شد.

معیار ارزیابی مدل‌ها

برای ارزیابی مدل مورد استفاده در این پژوهش از دو شاخص آماری شامل ریشه میانگین مربعات خطا (RMSE) و همچنین ضریب تعیین (R^2) که در محدوده بین صفر و یک تغییر می‌کند و مقادیر بالای این ضریب نشان‌دهنده عملکرد بهتر مدل است استفاده گردید (رابطه ۶ و ۷).

رابطه ۶:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_{est,i} - x_{meas,i})^2}{N}}$$

که در آن x_{est} ، مقدار تخمین زده شده، x_{meas} مقدار اندازه‌گیری شده و N تعداد نمونه‌ها می‌باشد.

رابطه ۷:

$$R^2 = \left(\frac{n \sum(y) - (\sum x)(\sum y)}{\sqrt{n(\sum x^2) - (\sum x)^2} \sqrt{n(\sum y^2) - (\sum y)^2}} \right)^2$$

که در آن x ، مقدار تخمین زده شده، y مقدار اندازه‌گیری شده و n تعداد نمونه‌ها می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی - محاسباتی نسبت به زمان جهت مقایسه و تحلیل بیشتر استفاده شده است.

نتایج

در ابتدا به منظور تعیین ورودی‌های مدل، میزان همبستگی سایر پارامترهای کیفیت آب به کمک نرم افزار SPSS₂₂، در جدول ۲ محاسبه گردید.

با توجه به نتایج آنالیز مربوط به جدول (۲)، چهار ساختار (الگو) مدل شامل ورودی‌های متفاوت به منظور پیش‌بینی پارامترهای کیفی آب، توسط مدل ماشین بردار پشتیبان اجرا گردید. مشخصات مدل‌ها در جدول ۳ آورده شده است. لازم به ذکر است همبستگی بالا و منفی بین کلروفیل a و سشی دیسک در مطالعات مختلف مشاهده شده بود (Kordi et al., 2012) به طوری که گویای یک رابطه هیپربولیک معنی‌دار بین عمق شفافیت آب با زی‌توده جلبک (غلظت کلروفیل a) می‌باشد (Hosseini and Ordog, 1995). همچنین از ۷۰ درصد داده‌ها به منظور آموزش و از بقیه داده‌ها برای آزمون و تست مدل استفاده شد، تا گستره وسیعی از داده‌ها در برگردد.

پس از استانداردسازی داده‌ها به منظور کاهش دامنه تغییرات داده‌ها، مقادیر بهینه مشخصه‌های مدل، شامل C و ε ، گاما توسط الگوریتم بهینه‌سازی جستجوی شبکه تعیین شد و از تابع کرنل (RBF) در برآورد پارامترهای کلروفیل a و سشی

دیسک استفاده شد. متغیر گاما نیز به صورت آزمون و خطا محاسبه شد. در نهایت مشخصه‌های بهینه مذکور انتخاب و در مدل اعمال شد. نتایج حاصل در ساختارهای مختلف در جدول ۴ قابل مشاهده است. با توجه به جدول مذکور، ساختار شماره ۱، بیشترین میزان ضریب تعیین (۰/۹۳) و کمترین ریشه مربعات خطا (۰/۰۹۷۷ میلی گرم بر مترمکعب) در مرحله صحت سنجی برای پیش‌بینی کلروفیل a از خود نشان داده است. در مقایسه با ساختار دیگر این مدل (ساختار شماره ۲)، که تنها ورودی سشی دیسک دارد، این مقادیر تغییر محسوسی نداشت (ضریب تعیین (۰/۸۹) و ریشه مربعات خطا (۰/۰۹۷۸)). همچنین در مقایسه با سشی دیسک (ساختار ۴) با یک ورودی، هم می‌توان کمترین میزان خطا را در این ساختار دید. از طرفی مشاهده می‌شود در صورتی که تنها یک ورودی نیز استفاده شود (ساختار شماره ۲ و ۴) این مدل جهت پیش‌بینی کلروفیل a و سشی دیسک قابل استفاده است و نشان‌دهنده کارایی ماشین بردار پشتیبان در پیش‌بینی با یک ورودی می‌باشد.

جدول ۲. میزان همبستگی بین پارامترهای کیفی اب (پیرسون)

سشی دیسک	دمای آب	کلروفیل a	
		۱	کلروفیل a
	۱	۰/۰۲۲	دمای آب
۱	-۰/۰۴۹	**۰/۹۵۱	سشی دیسک

** معنی‌داری در سطح ۰/۰۰۱

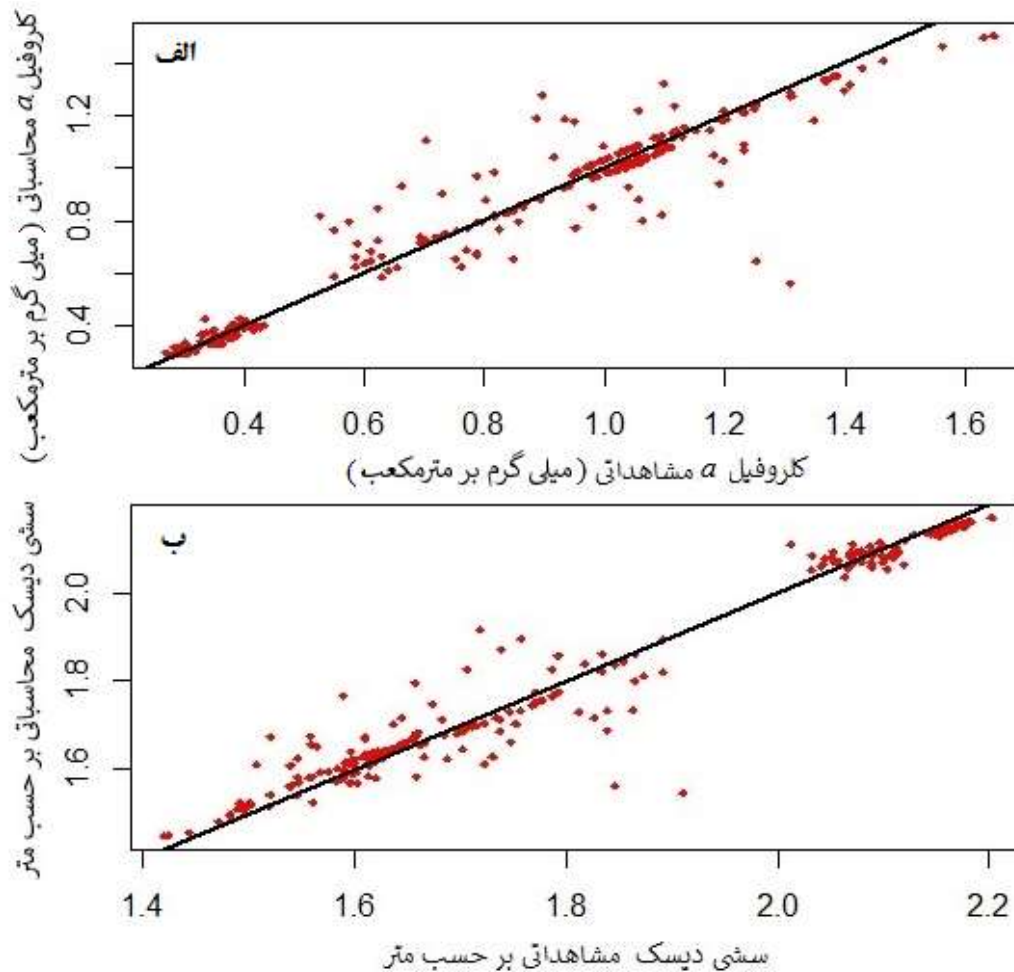
بررسی ساختارهای دیگر در پیش‌بینی سشی دیسک نشان داد، ساختار ۳ بهترین ترکیب را با بیشترین میزان ضریب تعیین (۰/۹۱) و کمترین ریشه مربعات خطا (۰/۰۴۹ متر) را در مرحله صحت سنجی دارد. در شکل ۵ و ۴ نمودار بهترین مدل‌های حاصل شده کلروفیل a و سشی دیسک برای داده‌های بخش صحت سنجی قابل مشاهده است. با توجه به شکل ۴ بیشتر مقادیر تخمین زده شده توسط مدل و مقادیر مشاهداتی سشی دیسک و کلروفیل a ، به غیر از چند نقطه روی خط نیمساز قرار دارد و این امر خود دلالت بر برابری مقادیر مشاهداتی و پیش‌بینی بر اساس خط برازش دارد. در شکل ۵ تغییرات مشاهداتی و پیش‌بینی کلروفیل a و سشی دیسک در مقیاس زمانی نشان داده شده است که حاکی از تخمین مناسب در اکثر نقاط است.

جدول ۳. مشخصات ساختارها برای پیش‌بینی پارامترهای کیفی


خروجی	ورودی به کار گرفته شده	
سشی دیسک	کلروفیل a	ساختار ۱
سشی دیسک	سشی دیسک	ساختار ۲
سشی دیسک	دمای آب و کلروفیل a	ساختار ۳
سشی دیسک	کلروفیل a	ساختار ۴


جدول ۴. تحلیل نتایج مدل ماشین بردار پشتیبان برای ساختارهای مختلف در تالاب چغاخور

متغیرهای مدل			صحت سنجی		آموزش		ساختار
δ	ε	C	RMSE	R ²	RMSE	R ²	
۰/۵	۰/۱	۱	۰/۰۹۷۷	۰/۹۳	۰/۹۱۲	۰/۸۴	۱
۱	۰/۱	۱	۰/۰۹۷۸	۰/۸۹	۰/۸۹۴	۰/۸۱	۲
۰/۵	۰/۱	۱	۰/۰۴۹	۰/۹۱	۱/۷۷۹	۰/۷۹	۳
۱	۰/۱	۱	۱/۰۸۸	۰/۸۸	۰/۹۵۶	۰/۸۵	۴



شکل ۴. نمودار پراکنش مقادیر مشاهداتی و محاسباتی حاصل از مدل ماشین بردار پشتیبان در مرحله صحت سنجی؛ الف) کروفیل a ، ب) سشی دیسک.





شکل ۵. نمودارهای سری زمانی مقادیر مشاهداتی - محاسباتی نسبت به زمان حاصل از مدل ماشین بردار پشتیبان در مرحله صحت سنجی؛ الف) کلروفیل a ، ب) سشی دیسک.

بحث

بررسی نمودار بهینه هر دو ساختار مورد مطالعه (شکل ۵) نشان داد مدل ماشین بردار پشتیبان در پیش‌بینی مقادیر در دامنه اعداد کلروفیل a و سشی دیسک عملکرد قابل قبولی دارد. در بررسی ساختارهای ۲ و ۴ نیز مشاهده می‌شود مدل ماشین بردار پشتیبان با حداقل ورودی نیز، قدرت پیش‌بینی لازم را دارد و در مواردی که با کمبود اطلاعات و نقص داده روبرو هستیم می‌توان از این قابلیت بهره گرفت.

در رابطه با برخی از نقاط در مدل‌ها که خارج از خط برازش می‌باشد (شکل ۴)، می‌توان بیان نمود با توجه به این که ماشین بردار پشتیبان بر مبنای استفاده از اصل استقرای کمینه‌سازی خطای ساختاری است، بنابراین در شبیه‌سازی، به کارگیری روش یادگیری با نظارت در توابع پایه شعاعی باعث می‌شود تخمین پارامتر از سرعت بالا و خطای کم‌تری نسبت به سایر کرنل‌ها داشته باشد و این یکی از ویژگی‌های ممتاز توابع پایه شعاعی محسوب می‌شود (Dehghani et al., 2017).

این نتایج با مطالعات دیگر در این زمینه (Mohammadpour et al., 2012; Kakaei Lafadani et al., 2013; Huang et al., 2007; Akhoni Pourousseini et al., 2014; Sedighi et al., 2016; Ghorbani et al., 2016a; Xu et al., 2007) مشاهده شد که در همه ترکیب‌های ورودی مدل، ماشین بردار پشتیبان با تابع کرنل پایه شعاعی RBF نسبت به مدل‌های با توابع کرنل خطی و چندجمله‌ای، مقادیر شبیه‌سازی شده‌ی بهتری ارائه می‌دهد. بنابراین می‌توان اطمینان داشت که تخمین ارائه شده توسط این تابع کرنل نسبت به توابع دیگر، دقیق‌تر است. Yoon و همکاران (۲۰۱۱) در پیش‌بینی تغییرات سطح آب زیرزمینی، برتری مدل ماشین بردار پشتیبان را نسبت به شبکه مصنوعی به اثبات رسانده بودند؛ آن‌ها این امر را به دلیل تغییر در ماهیت پدیده‌ها دانستند (Yoon et al., 2011). مطالعه Dehghani و همکاران (۲۰۱۷) نشان داد مدل ماشین بردار پشتیبان، بیش‌ترین دقت و کم‌ترین ریشه میانگین مربعات خطا در بین مدل‌های استفاده شده در مرحله صحت سنجی در مدل‌سازی جریان روزانه رودخانه کشکان لرستان را دارد (Dehghani et al., 2017). در مجموع می‌توان گفت با توجه به اینکه اساس کار در روش ماشین بردار پشتیبان بر مبنای قوانین منطقی بیان شده است، از دقت بالاتری نسبت به سیستم شبکه عصبی برخوردار است (Zabet Pishkhani et al., 2016).

از طرفی اکثراً مدل‌های داده محور، به صورت غیرخطی و پیچیده‌اند و به همین دلیل نیاز به معادلات با پایه فیزیکی خاصی ندارند (Zabet Pishkhani et al., 2016)، اما باید توجه کرد که تأثیر فرآیندها و عوامل فرا محیطی پدیده‌ها قابل انکار نیست.

با توجه به آنچه که درباره نتایج آنالیز ماشین بردار پشتیبان در این مطالعه بیان گردید، نکته قابل توجه در این روش این است که ساختار سیستمی شبکه برخلاف روش‌های کلاسیک یادگیری از قبیل شبکه‌های عصبی، از ابتدا و قبل از آموزش، مشخص نبوده و در طول فرایند آموزش، علاوه بر حداقل سازی خطای تجربی، خطای ساختاری نیز حداقل شده و همراه وزن‌ها بهینه‌ترین ساختار سیستم تعیین می‌گردد (Bazargan-Lari *et al.*, 2010). البته ماشین‌های بردار پشتیبان و شبکه‌های عصبی مصنوعی هر دو از سرعت محاسبه و دقت بالای برخوردارند، ولی در مقایسه با شبکه‌های عصبی، ماشین‌های بردار پشتیبان از پایداری بالاتر و قابلیت اجرای ساده‌تری برخوردار هستند (Xin *et al.*, 2010). این ماشین‌ها نسبت به بقیه روش‌های یادگیری از قدرت بالاتری برای داده‌های غیر آموزشی (داده‌های آزمایش) برخوردار می‌باشند. در پایان به نظر می‌رسد روش ارائه شده در این تحقیق که برای اولین بار در تالاب چغاخور مورد بررسی قرار گرفته است می‌تواند به عنوان الگو برای پیش‌بینی دیگر پارامترهای محیط آب مورد استفاده قرار گیرد.

تشکر و قدردانی

این مطالعه با حمایت دانشگاه علوم کشاورزی و منابع طبیعی گرگان انجام گرفت و بدین وسیله قدردانی می‌گردد.

منابع

- Akhoni Poursosseini, F., Asadi, E. 2017. Application of Bayesian Networks and Support Vector Machine Model to Predict Changes in Water Level (Case Study: Ardebil plain). *Iran-Watershed Management Science & Engineering*. 11(36): 33-42. (in Persian)
- Bazargan-Lari, M.R., Kerachian, R., Sedghi, H., Fallahnia, M., Abed-Elmdoust, A., Nikoo, M.R. 2010. Developing Probabilistic Operating Rules for Real-time Conjunctive Use of Surface and Groundwater Resources: Application of Support Vector Machines. *Journal of Water and Wastewater*. 21(4): 54-69. (in Persian)
- Behrouzi-Rad, B. 2008. *Wetlands of Iran*. Tehran: National Geographical Organization Publication. (in Persian)
- Dahl, T.E. 2011. *Status and Trends of Wetlands in the Conterminous United States 2004 to 2009*. US Department of the Interior, US Fish and Wildlife Service. Fisheries and Habitat Conservation.
- Dehghani, R., Younesi, H., Torabi Poteh, H. 2017. Comparing the performance of Support Vector Machines, Gene Expression Programming and Bayesian networks in predicting river flow (Case study: Kashkan River). *Journal of water and soil conservation*. 24(4): 161-176. (in Persian)
- Dibike, Y., Velickov, S., Solomatine, D., Abbott, M. 2001. Model induction with of support vector machines: Introduction and applications. *Journal of Computing in Civil Engineering*. 15(3): 208-216.
- Ghorbani, M.A., Khatibi, R., Geol, A., Fazelifard, M.H., Azani, A. 2016a. Modeling River Discharge time series using support vector machine and artificial neural networks. *Environmental Earth Sciences*. 75(4): 675-685.
- Ghorbani, M.A., Azani, A., Naghipour, L. 2016b. Comparison of the Performance of support vector machine with other intelligent techniques to simulate rainfall-runoff process. *Journal of Watershed Management Research*. 7(13): 92-103. (in Persian)
- Hsu, C.W., Chang, C.C., Lin, C.J. 2003. *A practical guide to support vector classification*. www.csie.ntu.edu.tw, 4 May 2009.
- Hosseini, S.A., Ordog, V. 1995. Relationships of chlorophyll a with some physical and chemical parameters in fish ponds. *Aquaculture. Hungarica*. 8: 64-66.
- Huang, S., Chang, J., Huang, Q., Chen, Y. 2014. Monthly streamflow prediction using modified EMD-based support vector machine. *Journal of Hydrology*. 511(4): 764-775.
- Huang, W., Huang, F., Song, J. 2010. An SVM model for water quality monitoring using remote sensing image. *Proceedings of the Second International Symposium on Networking and Network*

- Security (ISNNS '10). Jingtangshan, P.R. China, 2-4, April. 2010: 186-189.
- Javid, A.H., Mosikhani, M., Mirbagheri, A. 2013. Using supported vector machines in the classification of eutrophication and investigating the effect of pre-processing of input variables by principal component analysis – PCA. Third International Conference on Environmental Planning and Management. University of Tehran, 12 pages. (in Persian)
- Kar, D. 2013. Wetlands and Lakes of the World. Springer India. New Delhi.
- Kakaei Lafadani, E., Moghaddam Nia, A., Ahmadi, A., Jajarmizadeh, M., Ghafari, M. 2013. Stream flow simulation using SVM, ANFIS and NAM models (a case study). Caspian Journal of Applied Sciences Research. 2(4): 86-93.
- Kiabi, B., Madjnonian, H., Goshtasb Meigoni, H., Mansori, J. 2004. Criteria for assessing the conservation status of Iranian wetlands. Journal of Environmental Studies. 33: 74-89. (in Persian)
- Kordi, H., Hoseini, S.A., Sudagar, M., Alimohammadi, A.A. 2012. Correlation of Chlorophyll-a with secchi disk depth and water turbidity in aquaculture reservoirs a case study on Mohammadabad Reservoirs, Gorgan, Iran. World Journal of Fish and Marine Sciences. 4(4): 340-343.
- Limpens, J., Berendse, F., Blodau, C., Canadell, J.G., Freeman, C., Holden, J., Roulet, N., Rydin, H., Schaepman-Strub, G. 2008. Peatlands and the carbon cycle: From local processes to global implications—A synthesis. Biogeosciences Discuss. 5: 1379-1419.
- Lurling, M., Roessink, I. 2006. On the way to cyanobacterial blooms: Impact of the herbicide metribuzin on the competition between a green alga (*Scenedesmus*) and a cyanobacterium (*Microcystis*). Chemosphere. 65: 618-626.
- Mahab Ghods Consulting Engineers, 2008. Assessment of environmental impacts of water transfers of Sabzkuh and increasing barrier height. Mahab Ghods Consulting Engineers, Tehran, Iran. (in Persian)
- Mallick, N., Mohn, F.H. 2003. Use of chlorophyll fluorescence in metal-stress research: a case study with the green microalga *Scenedesmus*. Ecotoxicology and Environmental Safety. 55: 64-69.
- Mohammadpour, M., Mehrabi, A., Katouzi, M. 2012. Daily discharge forecasting using support vector machine. International Journal of Information and Electronics Engineering. 2(5): 769-772.
- Mosleh, M.A.A, Manssor, H., Malek, S., Milow, P., Salleh, A. 2012. A preliminary study on automated freshwater algae recognition classification system. Eleventh International Conference on Bioinformatics (InCoB2012): Bioinformatics, October, Bangkok, Thailand.
- Misra, D., Oommen, T., Agarwal, A., Mishra, S.K., Thompson, A.M. 2009. Application and analysis of support vector machine based simulation for runoff and sediment yield. Biosystems Engineering. 103(3): 527-535.
- Najah, A., Elshafie, A., Karim, O., Jaffar, O. 2009. Prediction of Johor river water quality parameters using artificial neural networks. European Journal of Scientific Research. 28(4): 22-35.
- Pai, P.F., Hong, W.C. 2007. A recurrent support vector regression model in rainfall forecasting. Hydrological Process. 21: 819-827.
- Sadeghi, R., Zarkamib, R., Sabetrafarb, K., Van Dammea, P. 2012. Use of support vector machines (SVMs) to predict distribution of an invasive water fern *Azolla filiculoides* (Lam.) in Anzali wetland, southern Caspian Sea, Iran. Ecological Modelling. 244(2012): 117-126.
- Samui, P. 2008. Support vector machine applied to settlement of shallow foundations on cohesion less soil. Journal Computers and Geotechnics. 35: 419-427.
- Samsudin, R., Saad, P., Shabri, A. 2011. River flow time series using least squares support vector machines. Hydrology and Earth System Sciences. 15: 1835-1852.
- Sedighi, F., Vafakhah, M., Javadi, M.R. 2016. Rainfall–Runoff modeling using support vector machine in snow-affected watershed. The Arabian Journal for Science and Engineering. 41(10): 4065-4076.
- Sharma, M.P., Kumar, A., Rajvanshi, S. 2010. Assessment of Trophic State of Lakes: A case of Mansi Ganga Lake in India. Hydro Nepal. Journal of Water, Energy and Environment. 6: 65-72.
- Tiner, R.W. 2010. NWIPlus: Geospatial database for watershed-level functional assessment. National Wetlands Newsletter. 32: 4-7.
- Vapnik, V.N. 1995. The nature of statistical learning theory. Springer, New York. pp. 250-320.
- Verones, F., Pfister, S., Hellweg, S. 2013. Quantifying area changes of internationally important wetlands due to water consumption in LCA. Environmental Science & Technology. 47(17):

- 9799-9807.
- Weeks, S., Werdell, P.J., Schaffelke, B., Canto, M., Lee, Z., Wilding, J.G., Feldman, G.C. 2012. Satellite-derived photic depth on the Great Barrier Reef: spatio-temporal patterns of water clarity. *Remote Sensing*, 4: 3781-3795.
- Xin, S., Qing, X., Lei, Y., Ning, L. 2010. A comparative study of eutrophication Evaluation Models Based on SOM Neural Network and SVM. *Journal of Chongqing University (Natural Science Edition)*, 33: 119-123.
- Xu, L., Wang, J., Guan, J., Huang, F. 2007. A support vector machine model for mapping of lake water quality from remote-sensed images. *IC-MED*, 1(1): 57-66.
- Yoon, H., Jun, S.C., Hyun, Y., Bae, G.O., Lee, K.K. 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of Hydrology*, 396: 128-138.
- Zabet Pishkhani, N., Seyedian, S.M., Heshmat Pour, A., Rouhani, H. 2016. SVM and ANFIS Models for precipitation Modeling (Case Study: Gonbad Kavouse). *Journal of Water and Soil*, 30(1): 236-246. (in Persian)