

Introducing a Hybrid Method for Estimating Wind Speed Using Information from Neighboring Stations in Isfahan Province

BABAK MOHAMMADI¹, ZAHRA AGHASHARIATMADARI^{2**}

1. PhD Student in Agrometeorology, Department of Irrigation and Reclamation, Faculty of Agricultural Engineering and Technology, University of Tehran, Karaj, Iran.
2. Assistant professor, Department of Irrigation and Reclamation, Faculty of Agricultural Engineering and Technology, University of Tehran, Karaj, Iran.

(Received: Apr. 9, 2018- Revised: May. 21, 2018- Accepted: May. 22, 2018)

ABSTRACT

The prediction of wind components including wind speed is one of the important factors, especially in the case of evaporation in a watershed. In this paper, in order to increase the efficiency of support vector machines (SVM) for predicting wind speed, the SVM model was combined with the firefly optimization algorithm called hybrid model (HM). In this regard, the wind speed data from synoptic stations of Isfahan province were used to estimate the monthly wind speed values of the unknown neighboring stations. Then, the efficiency of the SVM and HM models was compared. Finally, the RMSE, MAE, WI, and NS indices were used to evaluate the both models performance efficiency. The results in the evaluation step showed that the hybrid model (HM) with high correlation and lower error values has higher performance efficiency as compared to the SVM model. as Also, the method of using neighboring stations data as inputs for the predictive models of unknown station is a proper method for estimation of wind speed.

Keywords: Firefly optimization algorithm, Neighboring station, Hybrid method, Support vector machine

معرفی یک روش ترکیبی برای تخمین سرعت باد با استفاده از اطلاعات ایستگاه‌های همسایه در استان اصفهان

بابک محمدی^۱، زهرا آقاشریعتمداری^{۲*}

۱. دانشجوی دکتری هواشناسی کشاورزی، گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، دانشگاه تهران، کرج، ایران

۲. استادیار گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، دانشگاه تهران، کرج، ایران
(تاریخ دریافت: ۱۳۹۷/۱/۲۰ - تاریخ بازنگری: ۱۳۹۷/۲/۳۱ - تاریخ تصویب: ۱۳۹۷/۳/۱)

چکیده

پیش‌بینی مؤلفه‌های باد از جمله سرعت باد یکی از عوامل مهم به‌خصوص در بحث تبخیر در یک حوزه آبخیز محسوب می‌شود. در این مقاله برای افزایش کارایی مدل ماشین بردار پشتیبان در پیش‌بینی سرعت باد، این مدل با الگوریتم بهینه‌سازی کرم شب‌تاب ترکیب شد که منبع به عنوان مدل ترکیبی از آن یاد می‌شود. در این راستا با استفاده از داده‌های سرعت باد ایستگاه‌های همسایه در استان اصفهان، مقادیر سرعت باد ماهانه در ایستگاه‌های مجهول همسایه در مقیاس ماهانه برآورد شد و سپس کارایی مدل‌های ماشین بردار پشتیبان و مدل ترکیبی مورد مقایسه قرار گرفت. در نهایت با استفاده از معیارهای RMSE، MAE، WI و NS، کارایی عملکرد دو مدل مورد ارزیابی قرار گرفت. نتایج نشان داد که در مرحله ارزیابی، مدل ترکیبی با مقادیر همبستگی بالا و خطای کم‌تر کارایی بالاتری نسبت به مدل دیگر دارد. همچنین روش استفاده از داده‌های ایستگاه‌های همسایه به‌عنوان ورودی مدل‌های تخمین‌گر ایستگاه مجهول، روش مناسبی برای تخمین سرعت باد می‌باشد.

واژه‌های کلیدی: الگوریتم کرم شب‌تاب، ایستگاه همسایه، روش ترکیبی، سرعت باد

مقدمه

امروزه کم‌آبی یکی از بزرگترین معضلات در بسیاری از نقاط جهان و از جمله ایران محسوب می‌گردد. کمبود بارش در مناطق مرکزی و عدم نفوذپذیری سریع آب در خاک منجر می‌شود که تبخیر از سطح آب افزایش پیدا کند. یکی از عوامل مهم و مؤثر در افزایش میزان تبخیر، سرعت باد می‌باشد (Afkhami et al., 2015). به همین دلیل اندازه‌گیری سرعت و جهت باد در مناطق مختلف بسیار حائز اهمیت است. علاوه بر این اندازه‌گیری سرعت و جهت باد از جمله مسائل مهم و مورد توجه در احداث سازه‌های آبی و حوضچه سدها نیز می‌باشد. از دیگر موارد اهمیت اندازه‌گیری سرعت باد، مقدار انرژی باد به‌عنوان یک منبع تجدیدپذیر می‌باشد که بیشترین رشد را در بخش‌های تولید انرژی در جهان طی سال‌های ۲۰۰۰ تا ۲۰۰۴ میلادی به خود اختصاص داده است (Potter & Negnevistsky, 2006). مطابق با بسیاری از پیش‌بینی‌ها، استفاده از انرژی باد، بیشترین پیشرفت را در بین تمامی منابع انرژی خواهد داشت (Burton et al., 2001). غیرقابل پیش‌بینی بودن متغیرهای باد در بسیاری از موارد گزارش شده است (Rahimzadeh et al., 2011). در بیشتر

زمینه‌ها، مهمترین مؤثر متغیر باد، سرعت باد می‌باشد. در نتیجه با توجه به اهمیت برآورد مؤلفه‌ی باد، توانایی پیش‌بینی سرعت باد الزامی به نظر می‌رسد (Damousis & Dokopoulos, 2001).

در دهه‌های اخیر تلاش‌های فراوانی برای پیش‌بینی متغیر سرعت باد انجام گرفته است که این تلاش‌ها به دو دسته اصلی تقسیم می‌شوند؛ دسته اول، بر پایه روش‌های آماری استوارند و شامل روش‌های پیش‌بینی هواشناسی عددی (NWP) می‌باشند. این روش که مدل سری زمانی نامیده می‌شود، یکی از ساده‌ترین روش‌هایی است که مورد استفاده قرار می‌گیرد (Zhang & Benveniste, 1992). فرض اصلی در این روش آن است که اندازه سرعت باد در گام بعدی از روی داده‌های سرعت باد قبلی با استفاده از روش‌های آماری همچون حداقل سازی میانگین مجذور خطا برآورد شود و فراگیرترین آن‌ها میانگین متحرک اتورگرسیون (ARMA) می‌باشد (Soder, 2004; Zhang & Benveniste, 1992; Watson et al., 1994). دسته دوم، مبتنی بر روش‌های هوش مصنوعی می‌باشند. امروزه روش‌های پیش‌بینی متعددی با استفاده از شبکه‌های عصبی مصنوعی و منطق فازی برای مدل کردن سرعت باد به عنوان یک پدیده فیزیکی کاملاً غیرخطی (Watson et al., 1994; Guangdian &

* نویسنده مسئول:

نشان داد که بهینه کردن پارامترهای مدل‌های تخمین‌گر با استفاده از الگوریتم کرم شب‌تاب می‌تواند آموزش مدل‌های تخمین‌گر را بهبود ببخشد (Mohammadi 2017). Deo et al. (2018) در پژوهشی به‌وسیله هیبرید شبکه عصبی مصنوعی و الگوریتم کرم شب‌تاب سرعت باد را در استان آذربایجان شرقی برآورد کردند. نتایج نشان داد تلفیق الگوریتم کرم شب‌تاب با شبکه عصبی مصنوعی می‌تواند دقت برآورد را بالا ببرد و به نتایج مطلوب‌تری دست پیدا کنند (Deo et al., 2018). Ghorbani et al. (2017a) از الگوریتم کرم شب‌تاب برای بهبود نتایج شبکه عصبی مصنوعی برای تخمین تبخیر روزانه در منطقه شمال ایران استفاده کردند و نتایج حاکی از موفقیت‌آمیز بودن هیبرید الگوریتم کرم شب‌تاب با شبکه عصبی مصنوعی بود. از جمله دیگر تحقیقات موفق در زمینه استفاده الگوریتم کرم شب‌تاب در علوم و مهندسی آب می‌توان به تحقیقات Hosseini- Kazemzadeh et al. (2015), Kisi et al. (2015) و Moghari and Banihabib (2014) اشاره کرد.

تلفیق الگوریتم بهینه‌سازی کرم شب‌تاب با ماشین بردار پشتیبان منجر به توسعه مدل‌های جدیدی به نام روش ترکیبی شده است (Kisi et al., 2015). Ghorbani et al. (2017b) از الگوریتم ترکیبی کرم شب‌تاب بر پایه ماشین بردار پشتیبان برای تخمین ظرفیت زراعی و نقطه پژمردگی دائم در استان آذربایجان شرقی استفاده کردند و نتایج حاکی از موفقیت‌آمیز بودن هیبرید الگوریتم کرم شب‌تاب با ماشین بردار پشتیبان بود. این مدل‌های ترکیبی، قابلیت‌های سودمند هر دو مدل (مدل-های عصبی و الگوریتم‌های بهینه‌سازی) به همراه کم کردن خطا و یافتن بهینه‌ترین پیش‌بینی را دارا می‌باشند (Deo et al., 2018) و به همین دلیل توانایی بالایی را در پیش‌بینی‌های سری زمانی دارند. تا کنون تحقیقات گسترده‌ای در مورد پیش‌بینی متغیرهای اقلیمی و سری‌های زمانی با استفاده از الگوریتم کرم شب‌تاب و تلفیق آن با هوش مصنوعی صورت گرفته است. بنابراین با توجه به ماهیت غیرخطی بودن سرعت باد، مدل‌های هوشمند مانند ماشین بردار پشتیبان (SVM) می‌توانند به‌عنوان ابزار مناسبی برای تخمین هرچه دقیق‌تر پارامتر سرعت باد به کار گرفته شوند. با توجه به اهمیت مولفه سرعت باد در مطالعات آب و خاک و چرخه هیدرولوژیک، هدف اصلی از این تحقیق برآورد متغیر سرعت باد در قالب مدل ماشین بردار پشتیبان (SVM) و الگوریتم هیبریدی کرم شب‌تاب بر پایه ماشین بردار پشتیبان (SVM-FA) در حواصل سال‌های ۲۰۰۵ تا ۲۰۱۵ در ایستگاه‌های همدید استان اصفهان بوده است.

(Zhijie, 1994)، مورد استفاده قرار گرفته‌اند تا مقدار سرعت باد را در چند گام زمانی بعدی پیش‌بینی کنند که بعضی نیز به نتایج مناسب‌تری نسبت به روش‌های قبلی دست یافته‌اند (Deo et al., 2018). با توجه به اینکه پیچیدگی سیستم‌های هیدرولوژیکی از نظر تعیین تمام پارامترهای دخیل و نقص اطلاعات آماری، امکان مدل‌سازی کامل سیستم‌های هیدرولوژیکی را غیرممکن می‌سازد، در چنین شرایطی استفاده از مدل‌سازی سیستمی که مبتنی بر روابط ریاضی باشد، مورد توجه قرار می‌گیرد (Kisi et al., 2016). از جمله تحقیقاتی که در زمینه تخمین سرعت باد توسط روش‌های هوش مصنوعی صورت گرفته است می‌توان به مطالعات (Alexiadis et al., 1998) اشاره کرد. در این تحقیق پیش‌بینی سرعت باد متوسط برای گام‌های زمانی ۱۰ دقیقه و یک ساعت با به‌کارگیری شبکه‌های عصبی انجام گرفت و از متغیرهای سرعت باد و جهت باد به‌عنوان ورودی شبکه‌های عصبی استفاده گردید. (Potter and Negnevitsky 2006) یک سیستم استنتاجی فازی را برای پیش‌بینی سرعت باد در فاصله زمانی بسیار کوتاه مدت باد به کار بردند. (Oztopal 2006) برای پیش‌بینی باد از داده‌های جمع‌آوری‌شده از چند منطقه با فواصل مشخص استفاده کرد و سپس برای یافتن ضرایب وزنی مربوط به هر یک، در پیش‌بینی نهایی، برای هر روز از شبکه عصبی مصنوعی استفاده نمود. (Cadenas and Rivera 2007) از دو روش شبکه‌های عصبی مصنوعی و روش آماری (ARIMA) به‌منظور پیش‌بینی سرعت باد استفاده کردند. نتایج برتری شبکه عصبی مصنوعی را در پیش‌بینی سرعت باد نسبت به روش دیگر نشان داد. از جمله دیگر تحقیقات موفق در زمینه تخمین سرعت باد توسط هوش مصنوعی می‌توان به تحقیقات (Liu et al 2012a), (Liu et al 2012b), Philippopoulos and Deligiorgi (2012), (Negnevitsky & Potter 2006) اشاره کرد.

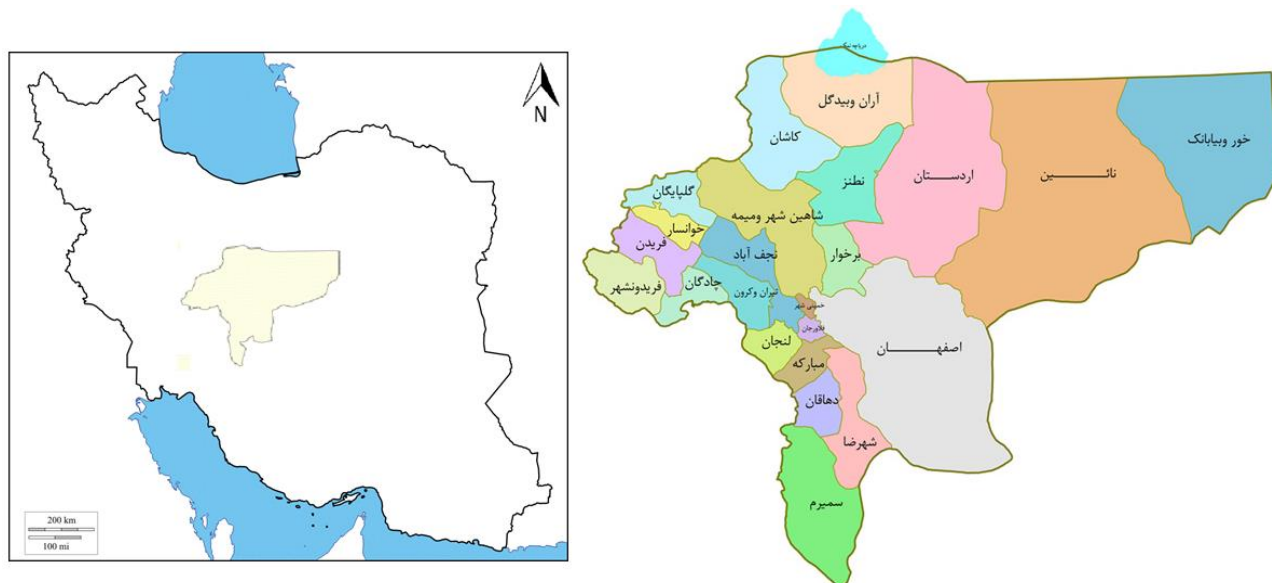
یکی از روش‌های موفق در زمینه پیش‌بینی غیرخطی سری‌های زمانی استفاده از الگوریتم‌های بهینه‌سازی کرم شب‌تاب در بهینه کردن پارامترهای روش‌های هوش مصنوعی می‌باشد (Yang and He, 2013) که به‌عنوان روشی نوین و بسیار مؤثر در زمینه آنالیز سیگنال‌ها و سری‌های زمانی مؤثر واقع شده است (Deo et al., 2018). در پژوهشی در سال ۲۰۱۷ با استفاده از ترکیب شبکه عصبی مصنوعی و الگوریتم ترکیبی کرم شب‌تاب، مدل جدیدی به نام الگوریتم ترکیبی کرم شب‌تاب معرفی شد که دقت این مدل از شبکه عصبی مصنوعی در برآورد تبخیر بهتر و قابل‌قبول‌تر بود. نتایج این تحقیق همچنین

مواد روش‌ها

منطقه مورد مطالعه و مشخصات آماری داده‌های مورد استفاده

داده‌های مورد استفاده در این تحقیق شامل متغیر سرعت باد در ارتفاع دو متری از سطح زمین ایستگاه‌های همدید استان اصفهان طی سال‌های ۲۰۰۵ تا ۲۰۱۵ در مقیاس ماهانه می‌باشد. ایستگاه‌های مورد استفاده در این پژوهش شامل ایستگاه-

های همدید اردستان، اصفهان، داران، سمیرم، شهرضا، فریدون‌شهر، کاشان، کبوترآباد، گلپایگان، مورچه‌خورت، میمه، نجف‌آباد و نطنز می‌باشد. مقادیر کمینه، بیشینه و میانگین اندازه‌گیری شده سرعت باد در ایستگاه‌های مورد مطالعه به همراه ارتفاع ایستگاه‌ها از سطح دریا و همچنین طول و عرض جغرافیایی ایستگاه‌ها در جدول (۱) و همچنین تصویری از منطقه مورد مطالعه در شکل (۱) درج شده است.



شکل ۱- تصویر منطقه مورد مطالعه

جدول ۱- مشخصات آماری داده‌های مورد استفاده در ایستگاه‌های مورد مطالعه

ایستگاه‌ها	ارتفاع از سطح دریا (متر)	میانگین سرعت باد (m/sec)	کمینه سرعت باد (m/sec)	بیشینه سرعت باد (m/sec)
اردستان	۱۲۳۸	۴/۴۸	۱/۲	۶/۷
اصفهان	۱۵۷۰	۱/۷۱	۰/۳	۴
داران	۱۶۸۰	۱/۹۲	۰/۴	۴/۵
سمیرم	۲۴۶۰	۳/۴	۱/۲	۷/۵
شهرضا	۱۸۲۴	۲/۹۲	۱/۹۲	۵/۶
فریدون‌شهر	۲۵۳۰	۲/۱۵	۰/۴	۵/۶
کاشان	۹۸۲	۱/۱۵	۰/۱	۲/۸
کبوتر آباد	۱۵۹۵	۱/۶۲	۰/۲	۴/۷
گلپایگان	۱۸۱۸	۳/۴۸	۰/۶	۷/۷
مورچه‌خورت	۱۵۹۵	۳/۲۵	۱/۴	۶/۲
میمه	۱۹۶۵	۳/۷۴	۱/۷	۵/۴
نجف‌آباد	۱۶۴۹	۳/۰۱	۰/۸	۵/۷
نطنز	۱۶۶۶	۳/۰۲	۰/۸	۵/۹

$$f(x) = \sum_{i=1}^N \bar{\alpha}_i \cdot \phi(x_i)^T \cdot \phi(x) + b \quad (\text{رابطه ۵})$$

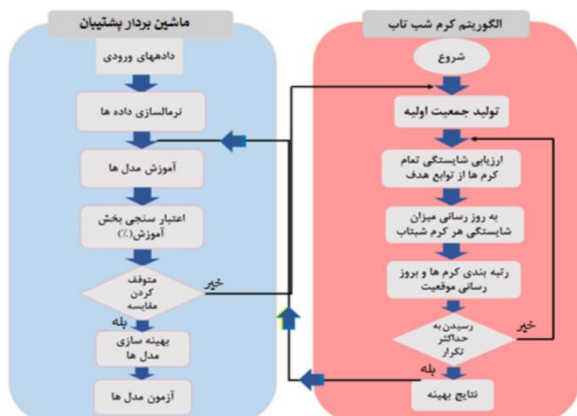
در معادله (۵)، $\bar{\alpha}_i$ میانگین ضرایب لاگرانژ است. محاسبه $\phi(x)$ در فضای مشخصه آن ممکن است بسیار پیچیده باشد. برای حل این مشکل، روند معمول در مدل رگرسیون بردار پشتیبان، انتخاب یک تابع کرنل است. با توجه به اینکه در ماشین بردار پشتیبان معمولاً از تابع کرنل پایه شعاعی استفاده می‌گردد، در این تحقیق نیز از این تابع استفاده گردیده است. فرمول کرنل پایه شعاعی در زیر آورده شده است (Mohammadi and moazenzadeh 2017).

$$k(x, x_i) = \exp\left(-\|x - x_i\|^2 / \sigma^2\right) \quad (\text{رابطه ۶})$$

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

الگوریتم کرم شب تاب

الگوریتم کرم شب تاب از الگوریتم‌های برگرفته از طبیعت است که رفتار اجتماعی کرم‌های شب تاب را شبیه‌سازی می‌کند. این الگوریتم توسط Yang (2009) معرفی گردید. کرم‌های شب تاب نورهایی تولید می‌کنند که الگوی نوری هر کدام با دیگری متفاوت است (Yang & He, 2013). آن‌ها به منظور جذب جفت و شکار از این نور استفاده می‌کنند، میزان این نور رابطه مستقیم با جذابیت کرم شب تاب دارد. با در نظر گرفتن میزان نور هر کرم به عنوان مقدار تابع هدف، می‌توان رفتار کرم‌های شب تاب را به صورت یک الگوریتم بهینه‌ساز مدل نمود (Mohammadi 2017). برای کسب اطلاعات بیشتر در خصوص الگوریتم کرم شب تاب می‌توان به منابع (Ghorbani et al, 2017a)، (Ghorbani et al, 2017b)، (Deo et al., 2018) و (Mohammadi 2017) مراجعه نمود. در شکل (۲) عملکرد الگوریتم ترکیبی کرم شب تاب بر پایه ماشین بردار پشتیبان نشان داده شده است.



شکل ۲- عملکرد الگوریتم ترکیبی کرم شب تاب بر پایه ماشین بردار پشتیبان

ماشین بردار پشتیبان

ماشین بردار پشتیبان مجموعه‌ای از روش‌های یادگیری نظارت شده^۱ است که برای طبقه‌بندی^۲ و رگرسیون استفاده می‌شود. ماشین بردار پشتیبان توسط Vapnik (1998) بر پایه‌ی تئوری یادگیری آماری معرفی شد. این روش مبتنی بر طبقه‌بندی دوتایی در فضای ویژگی‌های دلخواه است و از این رو روشی مناسب برای مسائل پیش‌بینی به شمار می‌رود (Pai & Hong, 2007). ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد (Mohammadi and Emamgholizadeh 2017).

در مدل ماشین بردار پشتیبان تابعی مرتبط با متغیر وابسته y که خود تابعی از چند متغیر مستقل x است، برآورد می‌شود. مشابه سایر مسائل رگرسیونی فرض می‌شود رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند $f(x)$ به‌علاوه مقداری اغتشاش (خطای مجاز ϵ) مشخص شود (Yoon et al., 2011).

$$f(x) = W^T \cdot \phi(x) + b \quad (\text{رابطه ۱})$$

$$y = f(x) + noise \quad (\text{رابطه ۲})$$

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

$$W^T \cdot \phi(x_i) + b - y_i \leq \epsilon + \epsilon_i^* \quad (\text{رابطه ۳})$$

$$\epsilon_i, \epsilon_i^* \geq 0, i = 1, 2, \dots, N \quad (\text{رابطه ۴})$$

$\frac{1}{2} W^T w + C \sum_{i=1}^N \epsilon_i + C \sum_{i=1}^N \epsilon_i^* y_i - W^T \cdot \phi(x_i) - b \leq \epsilon + \epsilon_i$
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 (Mohammadi and Emamgholizadeh 2017). در نهایت، تابع ماشین بردار پشتیبان را می‌توان به فرم زیر بازنویسی کرد:

1. Supervised learning
2. classification

نتایج و بحث

تعیین ساختار ورودی

ایستگاه‌های مورد مطالعه شامل ایستگاه‌های هواشناسی همدید استان اصفهان (اردستان، اصفهان، داران، سمیرم، شهرضا، فریدون‌شهر، کاشان، کبوتر آباد، گلپایگان، مورچه‌خورت، میمه، نجف‌آباد و نطنز) هستند. متغیر سرعت باد تحت ساختارهای متفاوتی به‌عنوان ورودی‌های دو مدل شبیه‌ساز ماشین بردار پشتیبان و الگوریتم ترکیبی کرم شب‌تاب بر پایه ماشین بردار پشتیبان تعریف شدند که ساختارهای ورودی تعریف شده در جدول (۳) ارائه شده است. برای تخمین سرعت باد در ایستگاه مذکور، از داده‌های سایر ایستگاه‌ها به‌عنوان ورودی در هر ساختار استفاده شده است.

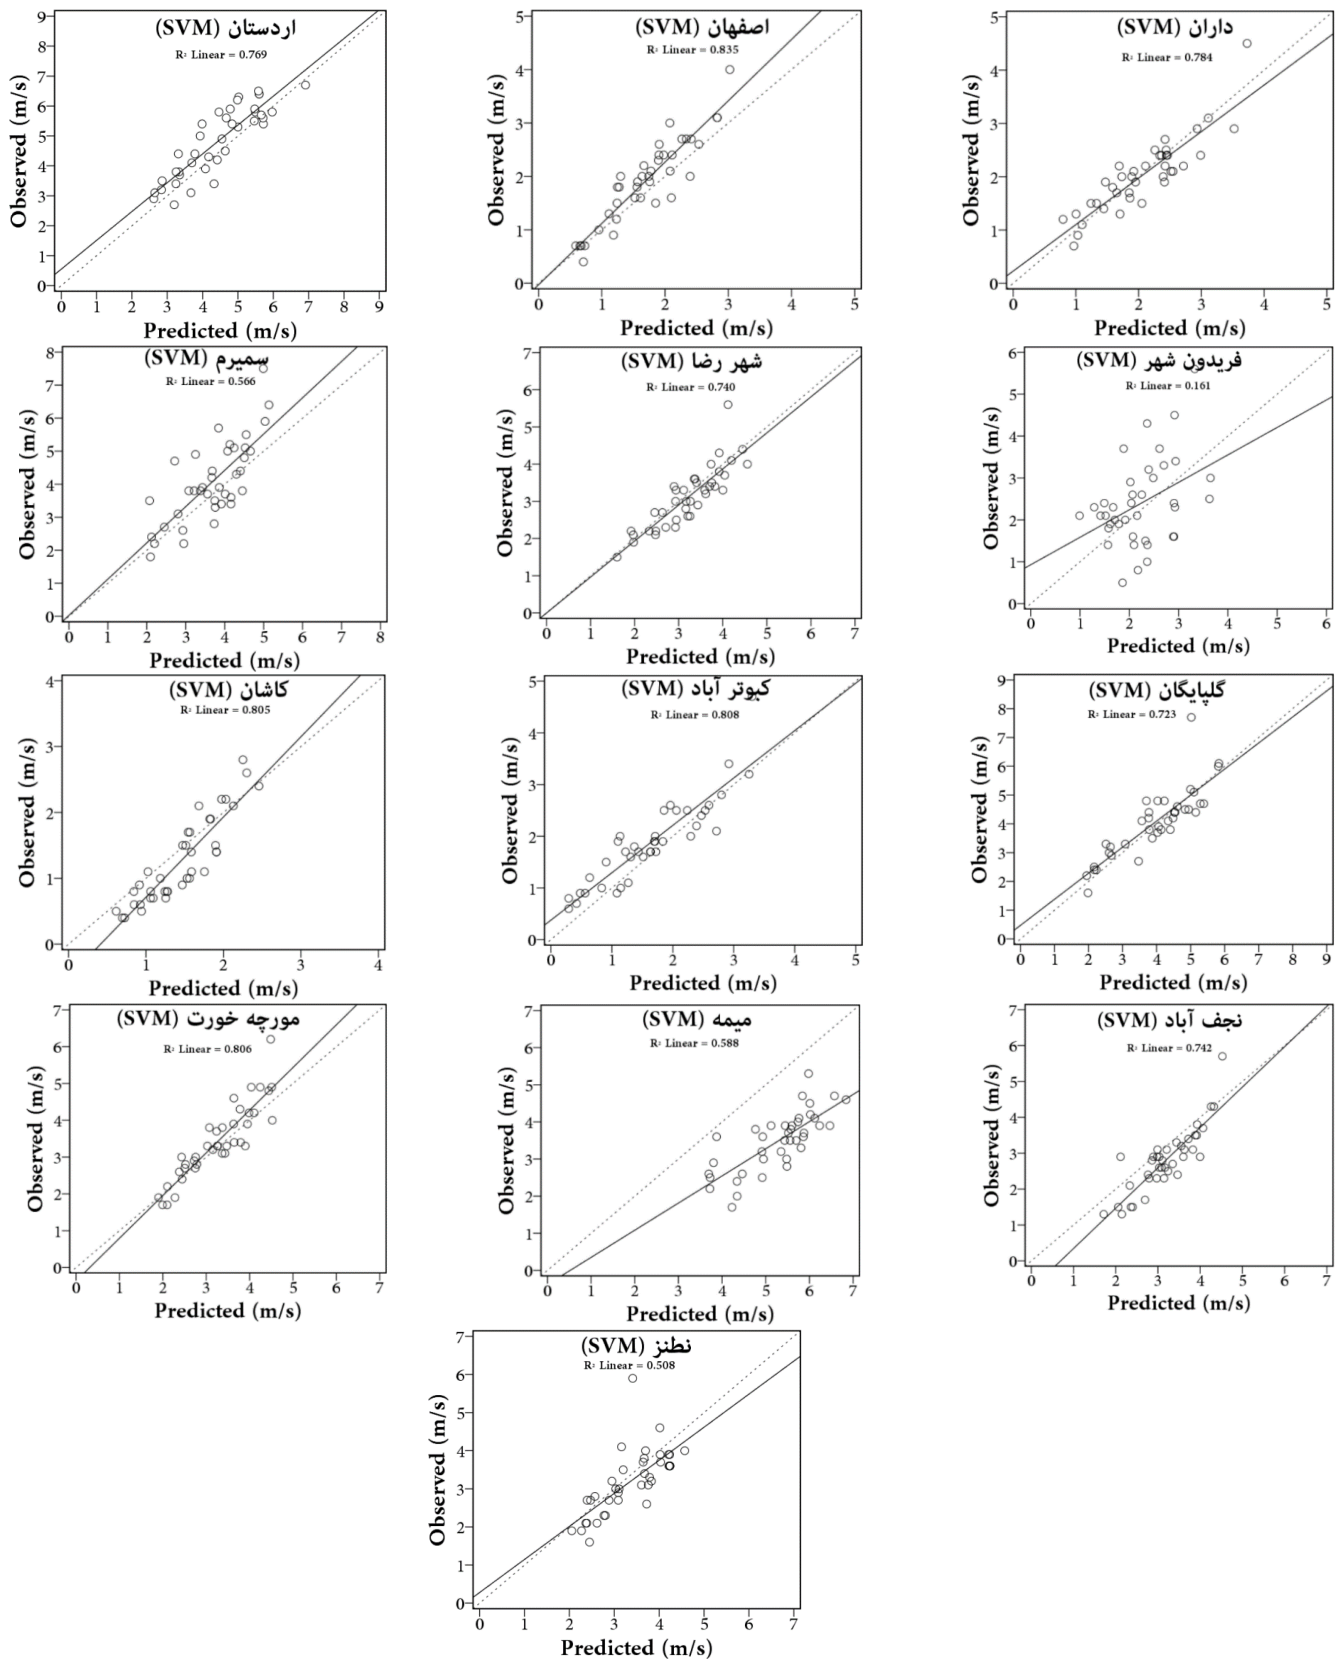
پس از تعیین ورودی‌ها برای برآورد سرعت باد، ساختارهای ورودی به ماشین بردار پشتیبان (SVM) و الگوریتم ترکیبی کرم شب‌تاب بر پایه ماشین بردار پشتیبان (SVM-FA) داده شدند. نتایج این شبیه‌سازی در جدول (۴) ذکر شده است. همان‌طور که انتظار می‌رفت از آنجا که مدل‌های آموزش داده‌شده برای مجموعه داده‌های مستقل مورد آزمون قرار گرفتند، نتایج در همه ایستگاه‌ها و هر دو مدل ماشین بردار پشتیبان و الگوریتم ترکیبی کرم شب‌تاب بر پایه ماشین بردار پشتیبان در مرحله آموزش و در تمامی ساختارهای تعریف شده کمی بهتر از نتایج متناظر در مرحله آزمون بوده است. این امر نشان‌دهنده آموزش خوب مدل تخمین‌گر ماشین بردار پشتیبان در هر دو مدل مذکور است. نتایج ساختارهای مختلف در مدل ماشین بردار پشتیبان نشان می‌دهد که این مدل بهترین آموزش را در ایستگاه اصفهان با مقدار مجذور ریشه میانگین مربعات خطای برابر $0/19$ متر بر ثانیه داشته است، این در حالی است که مدل ماشین بردار پشتیبان بهترین نتیجه برآورد سرعت باد را در ایستگاه داران با معیارهای مجذور ریشه میانگین مربعات خطای برابر $0/33$ متر بر ثانیه، قدر مطلق میانگین خطای برابر $0/26$ متر بر ثانیه، شاخص ویلموت برابر $0/76$ و ضریب نش ساتکلیف برابر $0/94$ داشته است.

همچنین مدل ماشین بردار پشتیبان ضعیف‌ترین عملکرد را در ایستگاه میمه با معیار مجذور میانگین ریشه مربعات خطای برابر $1/05$ متر بر ثانیه در تخمین سرعت باد داشته است. با توجه به نتایج جدول (۲)، عملکرد ساختارهای مختلف در مدل الگوریتم ترکیبی کرم شب‌تاب بر پایه ماشین بردار

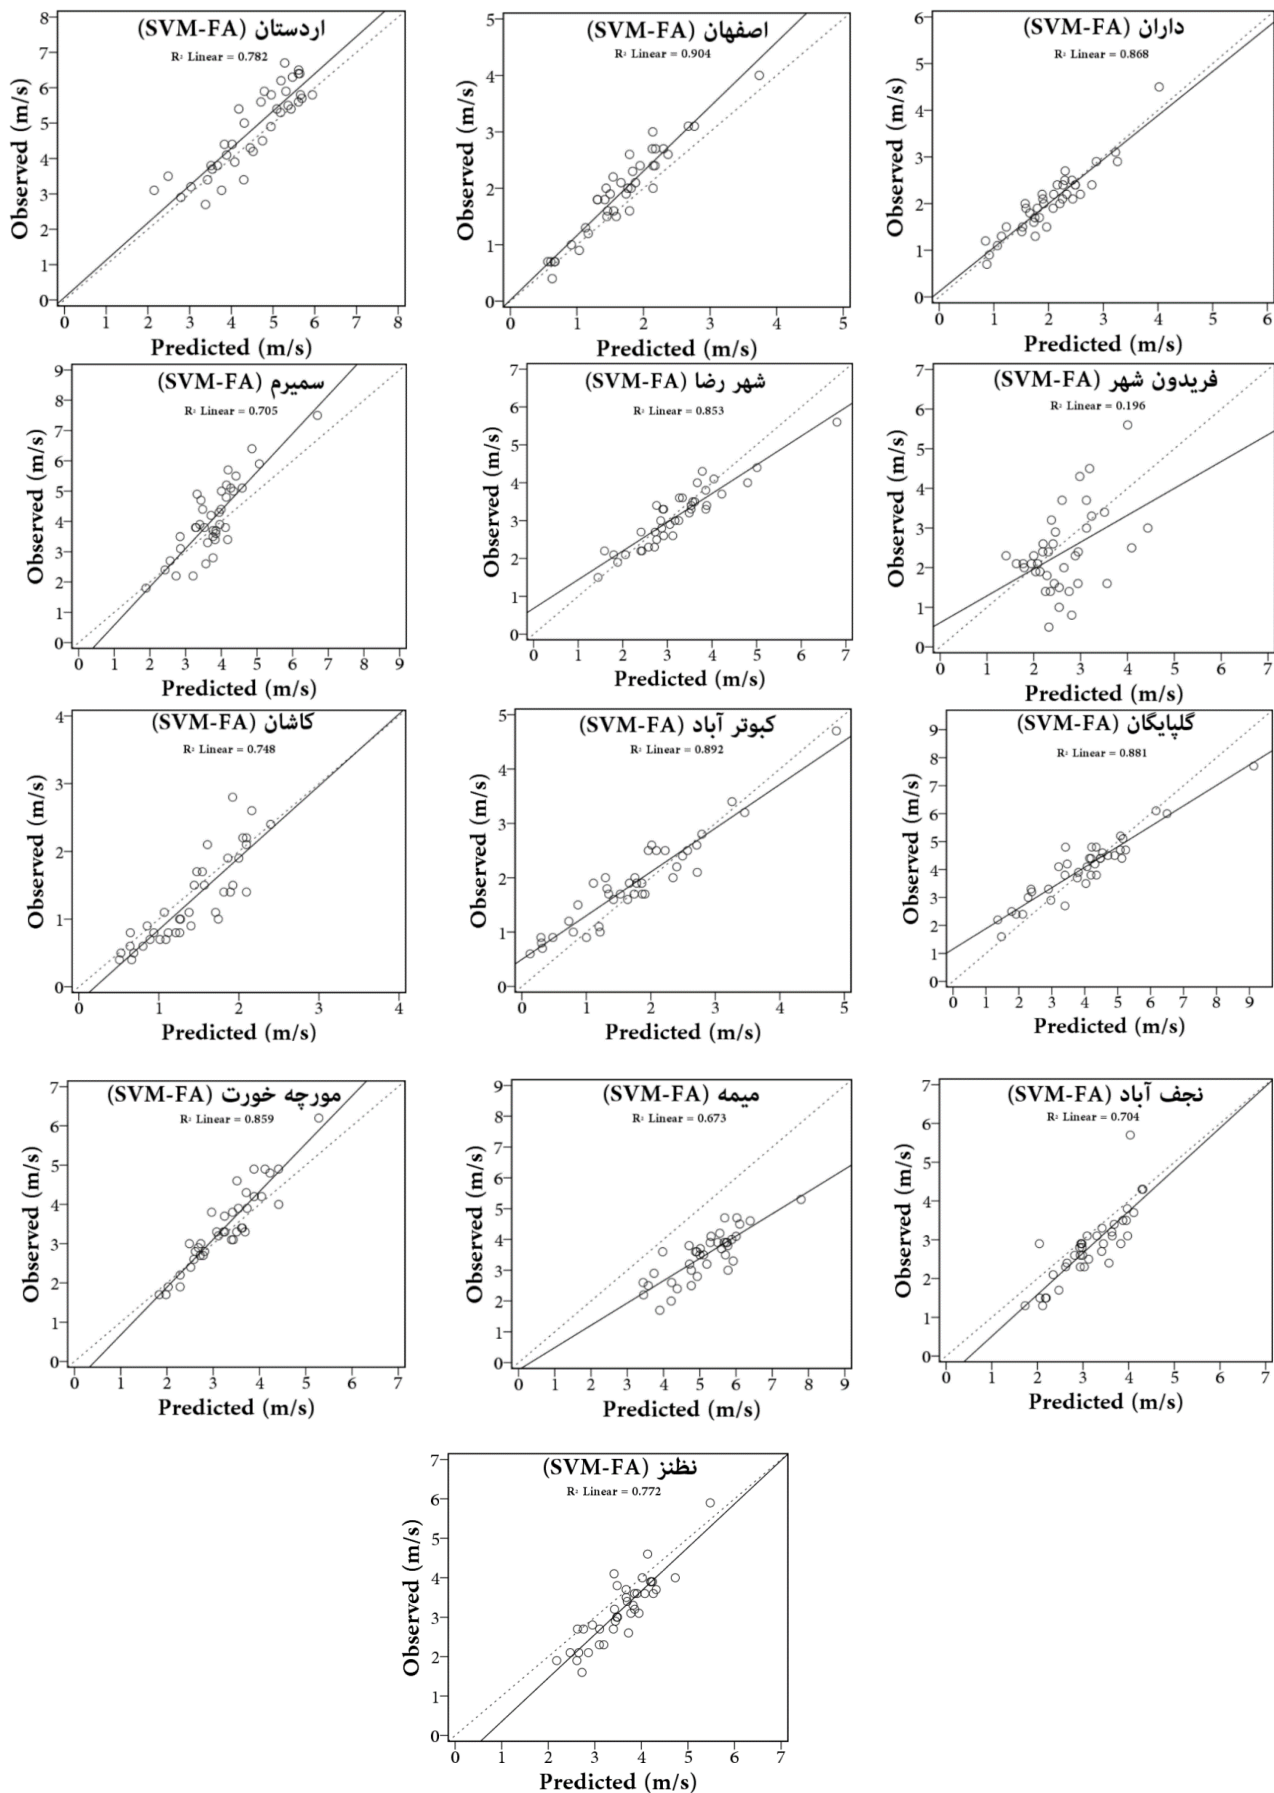
پشتیبان نشان می‌دهد که این مدل بهترین آموزش را در ایستگاه اصفهان با مقدار مجذور ریشه میانگین مربعات خطای برابر $0/146$ متر بر ثانیه داشته است، این در حالی است که مدل الگوریتم ترکیبی کرم شب‌تاب بر پایه ماشین بردار پشتیبان بهترین نتیجه برآورد سرعت باد را در ایستگاه داران با معیارهای مجذور ریشه میانگین مربعات خطای برابر $0/248$ متر بر ثانیه، قدر مطلق میانگین خطای برابر $0/207$ متر بر ثانیه، شاخص ویلموت برابر $0/865$ و ضریب نش ساتکلیف برابر $0/964$ داشته است.

و همچنین این مدل ضعیف‌ترین عملکرد را در ایستگاه فریدون‌شهر با معیار مجذور میانگین ریشه مربعات خطای برابر $0/967$ متر بر ثانیه در برآورد سرعت باد داشته است. نکته قابل توجه، عملکرد بهبودیافته مدل الگوریتم هیبریدی کرم شب‌تاب بر پایه ماشین بردار پشتیبان نسبت به ماشین بردار منفرد است، به طوری که در تمامی ساختارها نتایج الگوریتم ترکیبی کرم شب‌تاب بر پایه ماشین بردار پشتیبان نسبت به ساختارهای متناظرش در مدل ماشین بردار منفرد نتایج بهتری داشته است که این امر موفقیت‌آمیز بودن عملیات هیبرید کردن الگوریتم کرم شب‌تاب را با ماشین بردار پشتیبان نشان می‌دهد.

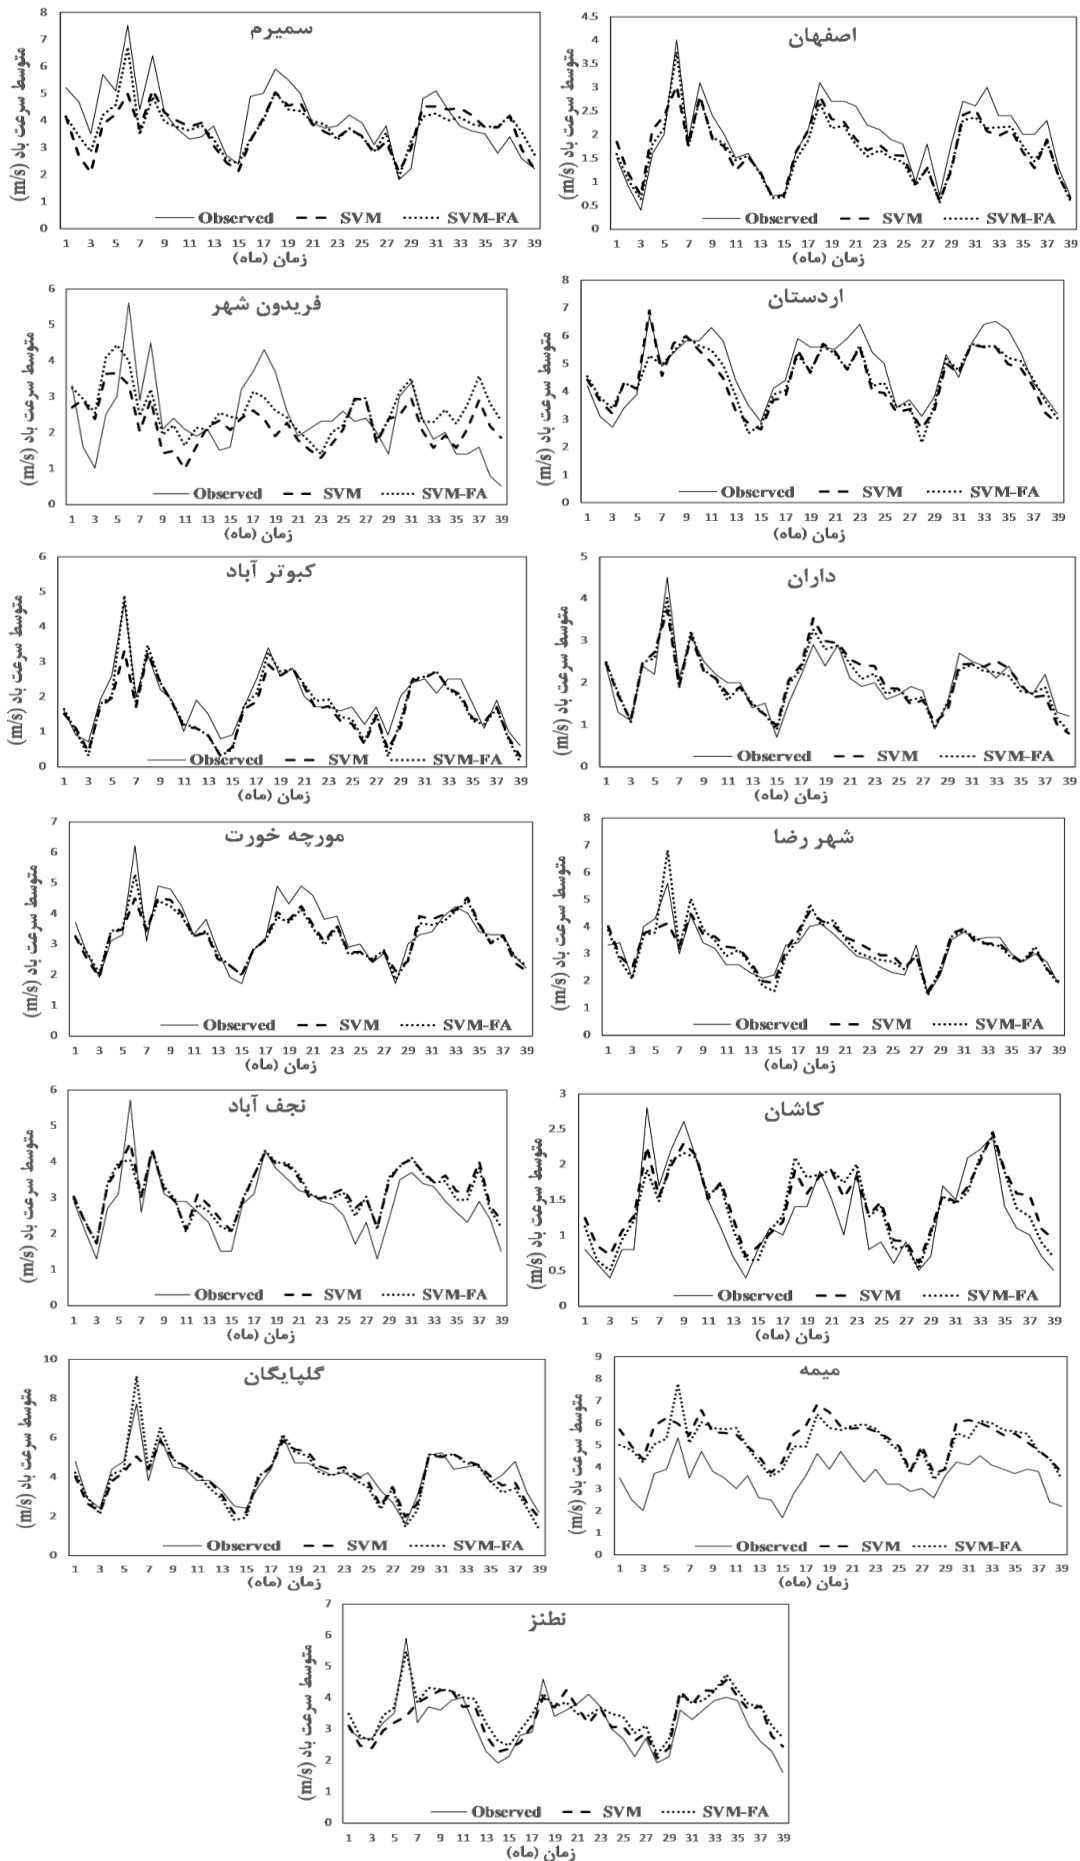
برای ارزیابی بهتر نتایج دو مدل SVM و SVM-FA در تخمین سرعت باد، از نمودار پراکنش نقاط داده‌های تخمین زده‌شده و مشاهداتی برای نتایج بخش آزمون دو مدل SVM و SVM-FA به ترتیب در شکل‌های (۳) و (۴) استفاده شده است. آن‌چنان‌که نتایج شکل (۳)، در برآورد سرعت باد توسط مدل ماشین بردار پشتیبان نشان می‌دهد مدل SVM2، یعنی برآورد سرعت باد شهر اصفهان با همبستگی $0/835$ ، بهترین نتیجه را در تخمین سرعت باد با مدل ماشین بردار پشتیبان نسبت به سایر شهرها داشته است. همچنین در مدل مذکور ضعیف‌ترین عملکرد مربوط می‌شود به مدل SVM6 که سرعت باد را در فریدون‌شهر با همبستگی پایین‌تری ($0/161$) نسبت به سایر شهرها تخمین زده است که علت این امر را می‌توان در شرایط جغرافیایی این منطقه جستجو کرد. از آنجا که فریدون‌شهر دارای بیشترین ارتفاع از سطح دریا (با توجه به جدول (۱) برابر 2530 متر) در بین ایستگاه‌های مذکور می‌باشد، به همین دلیل تنوع نوع بادها و جهت بادهای این منطقه و به‌طور کلی جغرافیای منطقه تفاوت بیش‌تری با سایر ایستگاه‌ها دارد و در تخمین سرعت متوسط باد رفتار متفاوتی نسبت به سایر ایستگاه‌ها از خود نشان داده است.



شکل ۳ - نمودار پراکنش نقاط تخمین زده شده و مشاهداتی مربوط به بخش آزمون مدل ماشین بردار پشتیبان



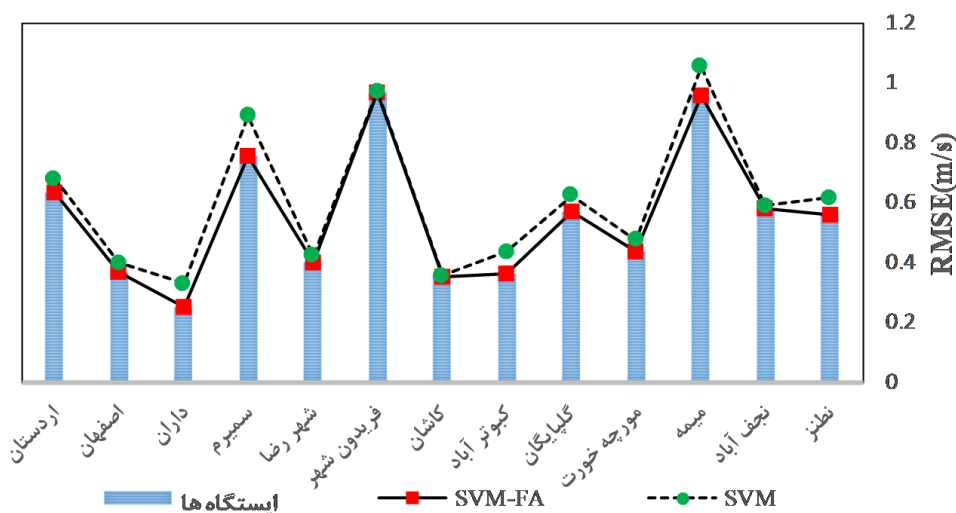
شکل ۴- نمودار پراکنش نقاط تخمین زده شده و مشاهداتی مربوط به بخش آزمون مدل الگوریتم ترکیبی کرم شب تاب بر پایه ماشین بردار پشتیبان



شکل ۵- نمودار سری زمانی مقادیر مشاهداتی و مقادیر تخمین زده شده سرعت باد، توسط دو مدل SVM و SVM-FA مربوط به بخش آزمون مدل‌ها

ضعیف‌تری داشته‌اند که علت این امر را می‌توان در همبستگی پایین داده‌های سایر شهرها با این دو شهر جستجو کرد. نتایج دو مدل در ایستگاه فریدون‌شهر، کاشان و نجف‌آباد به یکدیگر بسیار نزدیک بوده است و نقاط بر روی شکل (۶) تقریباً بر یکدیگر منطبق شده‌اند. و همچنین در شهرهای داران، سمیرم، کیوتر آباد و میمه نتایج دو مدل از یکدیگر فاصله بیشتری می‌گیرند.

برای بررسی بهتر نتایج، نمودار شکل (۶) ارائه شده است که این شکل به بررسی معیار مجذور ریشه میانگین مربعات خطای بخش آزمون مدل‌های مورد استفاده در ایستگاه‌های مورد مطالعه مربوط می‌شود. همان‌طور که در این شکل دیده می‌شود به‌طور کلی بهترین برآورد دو مدل از منظر شاخص مجذور ریشه میانگین مربعات خطا مربوط می‌شود به ایستگاه داران و در ایستگاه‌های میمه و فریدون‌شهر هر دو مدل عملکرد



شکل ۶ - مجذور ریشه میانگین مربعات خطای بخش آزمون مدل‌های مورد استفاده

بهبود بخشد، به‌طوری که توانایی مدل الگوریتم ترکیبی کرم شب‌تاب در پیش‌بینی ماهانه سرعت باد تأیید گردید. با توجه به اهمیت سرعت باد پیشنهاد می‌شود که قابلیت مدل‌های مذکور نسبت به سایر مدل‌های نوین به‌منظور توسعه مدل‌های تخمین-گر بررسی گردد. تفاوت در منطقه اقلیمی، تغییر در نتیجه یک تحقیق را به همراه خواهد داشت لذا توصیه می‌شود که در هر منطقه ابتدا عملکرد مدل‌ها مورد مقایسه قرار گرفته، سپس با توجه به هدف خاص مدل بهینه مورد استفاده قرار گیرد. در پایان پیشنهاد می‌گردد قابلیت مدل‌های مذکور در تخمین سرعت باد در اقلیم‌های متفاوت بررسی گردد تا قابلیت مدل‌های مذکور در اقلیم‌های مختلف کشور ایران هم بررسی گردد.

نتیجه‌گیری

به‌منظور مدل‌سازی سری زمانی سرعت باد از ایستگاه‌های همسایه هر ایستگاه کمک گرفته شد که این کار به‌نوبه خود یک روش جدید در برآورد سرعت باد در نقاط مختلف است. به‌طور کلی در همه ایستگاه‌ها الگوریتم ترکیبی ارائه‌شده موفق‌تر از ماشین بردار پشتیبان منفرد بوده است. همچنین نتایج حاکی از این بودند که شهرهای اصفهان، داران، شهررضا، کاشان، کیوتر آباد و مورچه‌خورد با روش تخمین سرعت باد با استفاده از ایستگاه همسایه و با استفاده از مدل‌های مذکور همخوانی بالایی داشته‌اند و نتایج رضایت بخشی را ارائه نمودند. نتیجه‌گیری دیگر اینکه الگوریتم کرم شب‌تاب می‌تواند به‌عنوان یک رهیافت بهینه‌کننده، نتایج مدل‌های تخمین‌گر را در برآورد سرعت باد

REFERENCES

Afkhami, H., Talebi, A., Mohammadi, M. and Fotouhi, F. (2015). Investigation of the feasibility of wind speed prediction using hybrid model of neural networks, neural-fuzzy networks and wavelet (Case Study: Station of Yazd). *jwmseir*. 9 (30): 31-40. (In Farsi)

Alexiadis, M. C., Dokopoulos, P. S. and Sahsamanoglou, H. S. (1998). Short-term forecasting of wind speed and related electrical power. *Solar Energy*. 63(1): 61-68, 1998.

Burton, T., Sharpe, D., Jenkins, N. and Bossanyi, E. (2001). *Wind energy handbook*. Chichester: John Wiley and Sons.

Cadenas, E. and Rivera, W. 2007. Wind speed forecasting in the south coast of Oaxaca, Mexico. *Renewable Energy*. 32 (12): 2116-2128.

Deo, R., Ghorbani, M.A., Samadianfard, S., Maraseni, T., Bilgili, M. and Biazar, M. (2017). Multi-layer perceptron hybrid model integrated with the firefly optimizer algorithm for wind speed prediction of target site using a limited set of neighboring reference station data. *Renewable*

- Energy. 116: 309-323.
- Damousis, I. G. and Dokopoulos, P. A. (2001). Fuzzy expert system for the forecasting of wind speed and power generation in wind farms. In Proceedings of the IE IEEE International Conference on Power Industry Computer Applications PICA 01. 63-69.
- Ghorbani, M. A., Deo, R., Yaseen, Z.M., Kashani, M.H. and Mohammadi, B. (2017a). Pan evaporation prediction using a hybrid multilayer perceptron-firefly algorithm (MLP-FFA) model: case study in North Iran. Theoretical and Applied Climatology. 129:1-13.
- Ghorbani, M. A., Shamshirband, SH., Zare Haghie, D., Azania, A., Bonakdarif, H. and Ebtehajf, I. (2017b). Application of firefly algorithm-based support vector machines for prediction of field capacity and permanent wilting point. Soil & Tillage Research. 172: 32-38.
- Guangdian, G.W. and Zhijie, D. (1994). Wind pattern recognition in neural fuzzy wind turbine control system. NAFIP, IFIS, NASA The Industrial Fuzzy and Intelligent Systems Conference and the NASA Joint Technology. 381-5 p.
- Hosseini-Moghari, S.M. and Banihabib, M.E. (2014). Optimizing operation of reservoir for agricultural water supply using firefly algorithm. Journal of Water and Soil Resources Conservation. 3(4). (In Farsi)
- Kazemzadeh, M.J., Daneshmand. and Ahmadfard, M. A. (2015). Optimal Remediation Design of Unconfined Contaminated Aquifers Based on the Finite Element Method and a Modified Firefly Algorithm. Water Resources Management. 29(8): 2895-2912.
- Kisi, O., Genc. O., S. Dinc and M. Zounemat-Kermani. (2016). Daily pan evaporation modeling using chi-squared automatic interaction detector, neural networks. Classification and Regression tree Computers and Electronics in Agriculture. 122: 112-117.
- Kisi, O., Shiri, J., Karimi, S., Shamshirband, Sh., Motamedi, Sh., Petkovic, D. and Hashim, R. (2015). A survey of water level fluctuation predicting in Urmia Lake using support vector machine with firefly algorithm. Applied Mathematics and Computation. 270: 731-743.
- Liu, H., Tian, H. and Li, Y. (2012a). Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction. Applied Energy. 98, 415-424.
- Liu, H., Chen, C., Tian, H. and Li., Y. (2012b). A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks. Renewable Energy. 48: 545-556.
- Mohammadi, B. (2017). Daily Evaporation prediction based on a hybridization of Artificial Neural Network and firefly Optimization Algorithm. Thesis is approved for the degree of Master of Science in Water Resources. Department of Water Engineering, Faculty of Agriculture, University of Tabriz. (In Farsi)
- Mohammadi, B. and Emamgholizadeh, S. (2017). Using principal component analysis to inputs the effective rainfall estimates based on entries to help support vector machine and artificial neural network. Journal of Rainwater Catchment Systems. 4(4): 67-75. (In Farsi)
- Mohammadi, B., Moazenzadeh, R. (2017). Uncertainty analysis of artificial neural network models and support vector machine in rainfall estimation. Journal of Rainwater Catchment Systems. 5(1): 43-50. (In Farsi)
- Oztopal, A. (2006). Artificial neural network approach to spatial estimation of wind velocity data. Energy Conversion and Management. 47(4): 395-406.
- Pai, PF. and Hong, WC. (2007). A recurrent support vector regression model in rainfall forecasting. Hydrological Process, 21:819-827.
- Philippopoulos, K. and Deligiorgi, D. (2012). Application of artificial neural networks for the spatial estimation of wind speed in a coastal region with complex topography. Renewable Energy. 38(1): 75-82.
- Potter, C. W. and Negnevitsky, M. (2006). Very short-term wind forecasting for Tasmanian power generation. IEEE Transaction on power systems. 21(2): 965-972.
- F. Rahimzadeh, A. M., Noorian, M., Pedram, and Kruk, M. C.(2011). Wind speed variability over Iran and its impact on wind power potential: A case study for Esfehan Province," Meteorol. Appl., METEOROLOGICAL APPLICATIONS Meteorol. Appl. 18: 198-210.
- Soder, L. (2004). Simulation of wind speed forecast errors for operation planning of multi-area power systems. 8th International conference on probabilistic methods applied to power systems. Iowa state university. Iowa. 23-28p.
- Vapnik, V. N. (1998). Statistical Learning Theory. Wiley, New York.
- Watson, S. J., Landberg, L. and Halliday, J.A. (1994). Application of wind speed forecasting to the integration of wind energy in to a large scale power system. In: IEE Proceedings of Generation, Transmission and Distribution, 141(4): 357-362.
- Yang, X.S. (2009). Firefly algorithms for multimodal optimization. In International symposium on stochastic algorithms. Springer, Berlin, Heidelberg. Pp: 169-178.
- Yang, X. S. and He, X. (2013). Firefly algorithm: recent advances and applications. International Journal of Swarm Intelligence. 1(1): 36-50.
- Yoon, H., Jun, S. C., Hyun, Y., Bae, G. O. and 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.
- Zhang, Q. and Benveniste, A. (1992). Wavelet networks. IEEE Transactions on Neural Networks. 3(6): 889-898.