

مقایسه کارایی رگرسیون بردار پشتیبان در پیش‌بینی خشکسالی کشاورزی با استفاده از الگوهای پیوند از دور و پارامترهای اقلیمی در نمونه‌های اقلیمی ایران

حسین زمانی^{۱*}، ام البنین بذرافشان^۲

۱- استادیار، گروه ریاضی و آمار، دانشکده علوم پایه، دانشگاه هرمزگان، بندرعباس

۲- دانشیار، گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس

چکیده

هدف از تحقیق حاضر، پیش‌بینی خشکسالی کشاورزی با استفاده از سیگنال‌های بزرگ مقیاس و متغیرهای اقلیمی در هشت نمونه اقلیمی ایران است. براین اساس، با استفاده از رگرسیون لاسو، مهم‌ترین متغیرها در هر اقلیم مشخص و با استفاده از رگرسیون بردار پشتیبان و سه تابع خطی، شعاعی و چندجمله‌ای، خشکسالی پیش‌بینی گردید. نتایج نشان داد، در اقلیم فراخشک معتدل و نیمه خشک سرد تابع خطی و در سایر اقلیم‌ها تابع شعاعی مناسب است. بر اساس نتایج، مقدار توافق بین مقدار پیش‌بینی کننده و پیش‌بینی شونده ۰/۹۱۲ تا ۰/۷۳۱ برآورد گردید. در بررسی خطای مدل براساس PE یا فرکانس خطا، بیش از ۵۵٪ خطا ناچیز و مربوط به دسته $\pm 0/5$ و ۲۷٪ مربوط به دسته $\pm 1/5$ تا ± 1 است که نشان دهنده کارایی مناسب مدل در برآورد SPEI است. برای بررسی عملکرد مدل در پیش‌بینی وقایع خشکسالی در طول دوره آزمایش، متغیرهای شدت خشکسالی، مدت زمان، شدت اوج و بزرگی مورد بررسی قرار گرفت. در متغیر شدت، بزرگی و پیک خشکسالی عموماً مدل دچار کم برآورد شده، به جز در اقلیم فراخشک و معتدل و نیمه خشک سرد که تابع خطی، رفتاری متفاوت را نشان داد. بیشترین اختلاف بین مقادیر مشاهده‌ای و پیش‌بینی شده در متغیر شدت خشکسالی در صدک ۱۷۵م در اقلیم خشک و گرم (بوشهر) مشاهده گردید. در نهایت، می‌توان بیان کرد، مدل SVR در پیش‌بینی SPEI برای اکثر اقلیم‌ها بسیار کارآمد است. با این حال، عملکرد آن در مناطق متنوع جغرافیایی متفاوت به نظر می‌رسد، که شاید نشان‌دهنده نقش متفاوت رگرسیون‌های مورد استفاده در آموزش مدل و متغیرهای مختلف باشد.

کلید واژه‌ها: خشکسالی، سیگنال‌های بزرگ مقیاس، رگرسیون بردار پشتیبان، رگرسیون لاسو.

مقدمه

اثر تغییر مقادیر تبخیر و تعرق و دما را در ارتباط با گرمایش جهانی، به‌ویژه در مناطق خشک و نیمه‌خشک دارد (Bazrafshan et al., 2019). شاخص SPEI به دلیل لحاظ نمودن بیلان آب، همبستگی قابل قبولی با میزان رطوبت خاک دارد پاسخ سریع‌تری نسبت به خشکسالی داشته است لذا شاخص مناسبی برای پیش‌بینی خشکسالی کشاورزی معرفی شده است (Sebghati et al., 2016).

مهمترین مسائل و مشکلات پیش روی ما در زمینه پیش‌بینی خشکسالی استفاده از داده‌های محلی و منطقه‌ای، نظیر ایستگاه‌های بارانسنجی و اقلیم‌شناسی است. از طرفی محدود بودن طول دوره آماری و کیفیت نامناسب آنها محققین را ناچار به بازسازی این داده‌ها می‌نماید (Gerkaninezhad moshozhi & Bazrafshan., 2018).

که طبیعتاً در چنین شرایطی قابلیت اعتمادپذیری داده‌ها کاهش می‌یابد. این در حالی است که طی دو دهه گذشته استفاده از سیگنال‌های اقلیمی و داده‌های پیوند از دور این مشکلات را مرتفع ساخته است (Ghasemieh et al., 2017). سیگنال‌های اقلیمی دارای طول دوره آماری بالا بوده، از کفایت و اعتماد بالایی برخوردار می‌باشند، به سادگی از وبسایت‌های اینترنتی مرتبط قابل دستیابی هستند و همچنین جهت پیش‌بینی خشکسالی و ترسالی، پیش‌بینی وقوع سیل، پیش‌بینی جریان کمینه یا بیشینه رودخانه، شروع فصل گرم یا سرد و... در دنیا مورد استفاده قرار می‌گیرند (Somali el al., 2019). تحقیقات زیادی که طی سال‌های اخیر انجام گرفته است نشان می‌دهد که روند خشکسالی و ترسالی با پدیده‌های اقلیمی در ارتباط است. این پدیده‌ها به صورت شاخص‌های عددی استاندارد شده نظیر SOI، NAO، PDO، NOI تعریف شده‌اند که با استفاده از این مقادیر عددی، همبستگی و روابط آنها با پارامترهای هیدرواقلمی در مناطق مختلف دنیا توسط محققین مورد بررسی قرار گرفته است. این شاخص‌ها با استفاده از اندازه‌گیری درجه حرارت و فشار هوا در نقاط مختلف اتمسفر بدست می‌آیند (Cordery & McCall., 2000).

بطورکلی، مدل‌های مورد استفاده در پیش‌بینی خشکسالی به سه دسته مدل‌های مفهومی، استوکاستیک و فیزیکی دسته‌بندی می‌شوند (Iraqinejad, Karamooz, 2018). در بین مدل‌های معرفی شده، مدل‌های مفهومی بدلیل دقت بالا

خشکسالی را می‌توان پدیده‌ای گذرا، آرام، تکرار شونده و جزئی جدا نشدنی از اقلیم هر منطقه دانست. اگرچه منشاء همه خشکسالی‌ها کاهش بارندگی است اما تاخیر تأثیرات آن بر منابع آبی موجب بروز خسارات زیادی می‌شود. لذا پیش‌بینی خشکسالی خصوصاً در مقیاس بلندمدت یکی از مهم‌ترین اهداف در مدیریت و برنامه ریزی خشکسالی بشمار می‌رود. متداول‌ترین روش‌ها برای پیش‌بینی پدیده خشکسالی استفاده از تئوری دنباله‌ها، مدل‌های استوکاستیکی و مدل‌های مفهومی است. پیش‌بینی دترمینیستیکی خشکسالی بیش از هر فرایند دیگر نظر محققین را به خود جلب نموده است. پدیده خشکسالی در بعد مکان و زمان بیشترین تغییرات را داشته و شبیه‌سازی آنها به لحاظ سرشت غیر خطی و ابعاد زیاد آن همواره با مشکلات زیادی روبرو بوده است (Iraqinejad et al., 2018).

کارایی سیستم پیش‌بینی خشکسالی متأثر از شاخصی است که با توجه به وضعیت خشکسالی منطقه انتخاب می‌گردد. طی سال‌های گذشته، شاخص‌های متعددی جهت پیش‌بینی خشکسالی در بخش‌های هواشناسی ابداع شده (Mendicino et al., 2008) مهم‌ترین عامل ایجاد خشکسالی بارندگی می‌باشد، اما افزایش و یا کاهش دما و به تبع آن تبخیر و تعرق می‌تواند شدت خشکسالی را تشدید و یا تعدیل نماید. شاخص‌های متعددی ابداع گردیده که عموماً مبتنی بر بارندگی و یا بارندگی و تبخیر و تعرق هستند و از طرف دیگر پیش‌بینی خشکسالی بر اساس شاخص‌های متفاوت، قطعاً نتایج متفاوت در بر خواهد داشت. بنابراین، از آنجا که خشکسالی پدیده‌ای وابسته به چند متغیر است، به نظر می‌رسد در کنار عامل بارش، می‌توان عامل تبخیر-تعرق را به‌ویژه برای مناطق خشک و نیمه‌خشک لحاظ کرد (Blenkinsop et al., 2007). شاخص‌هایی که علاوه بر بارش، مقدار تبخیر و تعرق را نیز در نظر می‌گیرند، می‌توانند برای پیش‌بینی تغییرات اقلیمی دوره‌های فعلی و آتی نیز به‌کار روند. عامل تبخیر-تعرق، نقش مؤثرتری در تغییر شدت خشکسالی دارد. به‌گونه‌ای که با وجود افزایش (کاهش) بارش در مقایسه با میانگین بلندمدت، شدت خشکسالی افزایش (کاهش) یافته است و شاخص فوق‌توانایی تشخیص

(۲۰۰۷) به پیش‌بینی خشکسالی با استفاده از شبکه عصبی مصنوعی، بارش و شاخص SOI و NAO در استان تهران پرداختند. نتایج نشان داد، بهترین متغیر پیشگو بارش بوده و دو سیگنال انتخاب شده در پیش‌بینی نقش چندانی نداشتند. همچنین نتایج ارتباط شاخص بارش استاندارد شده (SPI) و شاخص‌های ENSO و PDO نیز نشان داد که ارتباط قوی بین SPI دو سیگنال اقلیمی نامبرده در زمان وقوع خشکسالی و ترسالی وجود دارد. جولینو کانون و همکاران (۲۰۰۷). در چند دهه اخیر نیز مدل‌های یادگیری ماشین قابلیت بالای خود را در مدل‌سازی سری‌های نایستا و غیرخطی هیدرومتئورولوژیکی نشان داده‌اند.

مرور تحقیقات گذشته نشان می‌دهد، کمتر تحقیقی به پیش‌بینی SPEI با استفاده از متغیرهای اقلیمی و پیوند از دور به کمک مدل‌های ماشین بردار پشتیبان در اقلیم‌های مختلف ایران پرداخته است. لذا هدف از تحقیق حاضر، (۱) استخراج موثرترین متغیر در پیش‌بینی خشکسالی کشاورزی با استفاده از رگرسیون لاسو، (۲) پیش‌بینی خشکسالی کشاورزی با استفاده از مدل یادگیری ماشین SVM و سه تابع خطی، شعاعی و چندجمله‌ای (۳) مقایسه مشخصه‌های خشکسالی مقادیر مشاهده‌ای و پیش‌بینی شده و معرفی بهترین مدل در پیش‌بینی خشکسالی کشاورزی در هر نمونه اقلیمی ایران است.

داده‌ها و روش‌ها

منطقه مورد مطالعه

تحقیق حاضر در نمونه‌های اقلیمی ایران صورت گرفته است. براین اساس، با استفاده از روش دومارتن اصلاح شده تعیین اقلیم در ۳۹ ایستگاه سینوپتیک با ۵۰ سال آمار صورت گرفت. طبق روش فوق، ایران به ۸ اقلیم تقسیم بندی می‌گردد که در جدول (۱) مشخص گردید. لذا در این تحقیق هر ایستگاه نمونه یک منطقه اقلیمی انتخاب گردید و سایر تحلیل‌ها بر روی این مناطق صورت گرفت.

در پیش‌بینی و امکان استفاده از چندین متغیر از اهمیت خاصی برخوردار است.

در زمینه پیش‌بینی خشکسالی با متغیرهای اقلیمی و پیوند از دور قاضی‌پور و مهجوری (۲۰۲۲) با استفاده از مدل‌های SVM، ANN و ANFIS به پیش‌بینی خشکسالی با سیگنال‌های بزرگ مقیاس پرداختند. نتایج نشان داد، بهترین سیگنال پیشگو SST اقیانوس آرام است.

ملیک و همکاران (۲۰۲۱)، به پیش‌بینی خشکسالی در چندمقیاس زمانی با استفاده از شبکه عصبی مصنوعی و مدل رگرسیون پشتیبان در هند می‌پردازند. نتایج نشان داد، در اکثر ایستگاه‌ها مقیاس زمانی ۱۲ ماهه، بهترین پاسخ را ارائه داده است.

عباسی و همکاران (۲۰۲۰) با استفاده از شبکه بیزین و ماشین بردار پشتیبان به پیش‌بینی خشکسالی کشاورزی در حوزه آبخیز دریاچه ارومیه پرداختند. نتایج نشان داد، تابع خطی بهترین عملکرد را در پیش‌بینی خشکسالی دارد. ژانگ و همکاران (۲۰۲۰) به مقایسه سه مدل WNN، SVR و ARIMA در پیش‌بینی خشکسالی می‌پردازد. نتایج نشان داد، مدل ARIMA دارای قابلیت بالایی نسبت به مدل‌های ماشین یادگیری هستند. دئو و همکاران (۲۰۱۸). به پیش‌بینی خشکسالی کشاورزی با استفاده از متغیرهای اقلیمی و سیگنال‌های اقلیمی و مدل SVR در استرالیا می‌پردازد. نتایج نشان داد، مدل دارای قابلیت خوبی در برآورد خشکسالی است و تفاوت معنی داری بین مشخصه‌های خشکسالی در مقادیر مشاهده شده و برآورد شده وجود ندارد. تیان و همکاران (۲۰۱۸) به پیش‌بینی خشکسالی کشاورزی با استفاده از SPEI در مقیاس‌های زمانی مختلف و شاخص انسو، WHPS و SVR می‌پردازد. نتایج نشان داد، SPEI-6 بهتر از سایر مقیاس‌ها منعکس کننده رطوبت خاک است و WHPS عمدتاً کنترل کننده دمای منطقه است و افزودن این متغیر سبب بهبود دقت مدل می‌گردد. اژدری مقدم و همکاران (۲۰۱۱) به پیش‌بینی خشکسالی با استفاده از مدل شبکه عصبی- فازی و متغیرهای اقلیمی پرداختند. نتایج نشان داد، شاخص‌های SOI، NINO3 و AMO بهترین متغیرهای پیشگو در ایستگاه زاهدان هستند. مرید و همکاران

جدول ۱- ویژگی‌های ایستگاه‌های نماینده هر اقلیم

نام ایستگاه	نام اقلیم	ارتفاع از سطح دریا (متر)	متوسط دمای کمینه به درجه سلسیوس	متوسط دمای بیشینه	متوسط بارش	متوسط تبخیر و تعرق
رامسر	خیلی مرطوب	-۲۰	۱۲/۸	۱۹/۵	۱۲۱۷	۸۶۳
ارومیه	نیمه خشک و سرد	۱۶۱۱	۴/۹	۱۱/۴	۳۳۱	۷۴۵
همدان	نیمه خشک و فراسرد	۱۶۸۰	۲/۷	۱۹/۵۳	۳۱۱	۷۲۹
شیراز	سرد و خشک	۱۴۸۴	۱۰	۲۶	۳۱۸	۶۴۹
کرمان	فراخشک و معتدل	۱۷۵۳	۶/۹	۲۴/۸۵	۱۳۱	۷۲۴
طبرس	فراخشک و سرد	۷۱۱	۱۴	۲۸	۷۲	۷۶۶
بوشهر	خشک و گرم	۹	۲۰	۲۹	۲۴۷	۱۱۱۶
بندرعباس	فراخشک و گرم	۹/۸	۲۱	۳۲	۱۷۴	۱۸۳۰

شاخص‌های بزرگ مقیاس اقلیمی

به‌طور کلی شاخص‌های اقلیمی را به شش دسته تقسیم‌بندی می‌کنند که شامل الگوی پیوند از دور، الگوی اتمسفری (Atmosphere)، بارندگی (Precipitation)، انسو (ENSO)، دمای سطح اقیانوس آرام (SST Pacific) و دمای سطح اقیانوس اطلس (SST Atlantic) می‌باشد. مقادیر فوق به صورت استاندارد و نرمال شده موجود هستند. عناصر مورد استفاده در تحقیق حاضر از وبسایت نوا (www.cdc.noaa.gov/ClimateIndices/List/) (۲۰۰۸) تهیه گردید.

شاخص انسو در ارتباط با دو شاخص نوسانات جنوبی (SOI)، فشار سطح دریا (SLP: Sea Level Pressure) و دمای سطح دریا (SST: Sea Surface Temperature) در اقیانوس آرام استوایی است که مقدار منفی و مثبت آن بیانگر فازهای سرد و گرم انسو یا شرایط لانینا و ال‌نینو است (کائو و همکاران، ۲۰۰۹). نوسان دهه‌ای اقیانوس آرام یا PDO الگوی نوسانی تغییرات اقلیمی است که مرکز تغییرات آن روی اقیانوس آرام و شمال آمریکا است و مقادیر (SST) و (SLP) در اقیانوس آرام شمالی (۲۰°N)، در شمال ایالات متحد آمریکا اندازه‌گیری می‌شود (Kushnir et al., 2002).

شاخص SPEI بعنوان شاخص پیش‌بینی شونده خشکسالی

کشاورزی

شاخص خشکسالی استاندارد شده بارش و تبخیر-تعرق (SPEI) را که ویسنت سرنانو در ۲۰۱۰ عرضه کرد، در حکم

شاخصی مناسب در تعیین خشکسالی مورد استفاده قرار داد. در این شاخص سه متغیر بارش، دما و تبخیر-تعرق پتانسیل (PET) لحاظ شده است. شاخص SPEI، حساسیت شاخص خشکسالی پالم (PDSI) به تغییرات نیاز تبخیر را با محاسبات ساده و طبیعت چند مقیاسی شاخص استاندارد شده بارش ترکیب می‌کند. بنابراین می‌تواند هر دو ویژگی شاخص‌های SPI و PDSI را داشته باشد (Vicente-Serrano et al., 2010).

برای محاسبه شاخص SPEI در گام نخست باید مقدار تبخیر و تعرق در هر ماه برآورد شود سپس از طریق یک مدل ساده بیلان آب تفاوت بین مقدار بارندگی (P) مقدار تبخیر و تعرق پتانسی (PET) برای ماه i از رابطه ۱ محاسبه می‌گردد.

$$D_i = p_i - PET_i \quad (1)$$

محاسبه این شاخص همانند روش ارائه شده برای محاسبه شاخص SPI نیازمند برآورد مقادیر احتمال تجمعی مقادیر D_i از طریق i از برازش یک تابع چگالی احتمال می‌باشد. با توجه به آنکه مقادیر D کران پائین به مقادیر منفی منتهی می‌شوند توابع احتمال دو پارامتری نمی‌تواند برای این امر انتخاب شوند. ویسنت سرنانو و همکاران با بررسی توابع مختلف سه پارامتری، تابع چگالی احتمال لوگ- i لوجستیک سه پارامتری را دارای بهترین برازش بر مقادیر D تشخیص دادند. فرم کلی تابع چگالی احتمال این تابع به صورت رابطه زیر می‌باشد:

لاسو یک روش رگرسیونی است که برای انتخاب متغیرهای موثر در مدل بکار می‌رود. در این روش با بکارگیری یک تابع تاوان ضریب‌های بی‌تأثیر در مدل رگرسیونی را برابر صفر قرار داده و از مدل حذف می‌کند و سایر متغیرهای موثر را در مدل نگه می‌دارد (Deo et al., 2018).

در روش لاسو بجای کمینه کردن مجموع توان دوم خطا جهت برآورد پارامترهای مدل رگرسیونی از تابع

$$\psi(\beta, \lambda) = (\mathbf{y} - \mathbf{X}\beta)'(\mathbf{y} - \mathbf{X}\beta) + \lambda P(\beta) \quad (6)$$

استفاده می‌شود که در آن $P(\beta)$ تابع تاوان و λ پارامتر منظم‌سازی می‌باشد.

تابع تاوان می‌تواند انواع مختلفی داشته باشد که بر این اساس رگرسیون‌های مختلفی تعریف می‌شود. معروف‌ترین فرم تابع تاوان

$$P(\beta) = \sum_{i=1}^p |\beta_i|^q \quad (7)$$

است که به آن رگرسیون بریج گفته می‌شود. رگرسیون لاسو حالت خاصی از مدل فوق است که به ازای $q = 1$ تعریف می‌شود و به ازای $q = 2$ مدل فوق را رگرسیون ستیغی گویند. بنابراین در روش لاسو پارامترهای مدل از کمینه کردن تابع ۳ حاصل می‌شود.

$$\psi(\beta, \lambda) = (\mathbf{y} - \mathbf{X}\beta)'(\mathbf{y} - \mathbf{X}\beta) + \lambda \sum_{i=1}^p |\beta_i| \quad (8)$$

ضرایب رگرسیون لاسو در محدوده صفر قرار می‌گیرند بطوریکه ضرایب غیر موثر برابر صفر خواهند شد. بنابراین رگرسیون لاسو علاوه بر اینکه یک مدل رگرسیونی جهت پیشگویی متغیر پاسخ است یک روش انتخاب متغیر نیز می‌باشد.

رگرسیون بردار پشتیبان^۱

روشی است که در دهه ۱۹۹۰ به گسترش کامپیوترها توسعه یافت. ماشین بردار پشتیبان بسطی از یک روش طبقه‌بندی ساده است که به آن طبقه‌بندی بیشترین حاشیه (Maximal Margin Classifier) گفته می‌شود و برای طبقه‌بندی گروه‌هایی با مرزبندی خطی بکار می‌رود (Boser et al., 1992؛ 1992؛ 1995؛ Cortes & Vapnik., 1995). در همین راستا

$$f(x) = \frac{\beta}{\alpha} \left(\frac{n-\gamma}{\alpha} \right)^{\beta-1} \left[1 + \left(\frac{n-\gamma}{\alpha} \right)^2 \right] \quad (2)$$

که در آن پارامترهای α ، β و γ به ترتیب پارامترهای مقیاس، شکل و اصلی برای مقادیر D_i در دامنه $0 < D < \infty$ می‌باشند. فرم تابع احتمال تجمعی لوگ-لوجستیک سه پارامتری نیز مطابق رابطه (۳) است.

$$F(x) = \left[1 + \left(\frac{\alpha}{x - \gamma} \right)^\beta \right]^{-1} \quad (3)$$

تابع کلاسیک ابرامویچ و استیگان (۴) با استفاده از مقادیر تابع $F(X)$ تخمینی برای مقدار شاخص SPEI می‌باشد:

$$SEPI = W - \frac{C_0 + C_1 W + C_2 W^2}{1 + d_1 W + d_2 W^2 + d_3 W^3} \quad (4)$$

در رابطه (۵) مقدار W از رابطه زیر محاسبه می‌شود:

$$\text{for } p \leq 0.5 \quad (5)$$

$$W = \sqrt{-2 \ln(p)}$$

P احتمال بیشتر شدن مقادیر تعیین شده D است. مقادیر C_0 ، C_1 و C_2 و همچنین d_1 ، d_2 و d_3 ثابت هستند. شاخص SPEI یک متغیر استاندارد شده است و بنابراین می‌تواند با سایر مقادیر SPEI در مکان و زمان مقایسه شود. مقدار SPEI معادل صفر به معنای مقادیر منطبق با ۰/۰۵۰ احتمال تجمعی D است.

روش رگرسیون لاسو در حذف متغیرهای کم اثر

هر گاه در مدل‌های یادگیری ماشین تعداد زیادی متغیر پیشگو وجود داشته باشد معمولاً همه آنها موثر نبوده و باید در ساخت مدل یادگیری از مدل حذف نمود زیرا تعداد زیاد متغیر پیشگو در مدل باعث ایجاد بیش برآزش و در نتیجه افزایش خطای مدل می‌شود. در مدل‌های یادگیری ماشین روش‌های متعددی برای انتخاب متغیرها یا ویژگی‌ها جهت ورود به مدل وجود دارد که تعدادی از روش‌های مهم عبارتند از ضریب همبستگی پیرسن، آماره کای-دو، رگرسیون گام به گام، رگرسیون لاسو و روش‌های مبتنی بر درخت تصمیم (جنگل‌های تصادفی و بوستینگ). در این تحقیق ما از روش رگرسیون لاسو که یک روش قدرتمند آماري در حذف متغیرهای غیرموثر از مدل است استفاده می‌کنیم.

¹ Support Vector regression: SVR

کرنل سیگموئید

$$k(x_i, x_{i'}) = \tanh(-\gamma \sum_{j=1}^p x_{ij} x_{i'j} + \alpha)$$

روش ماشین بردار پشتیبان برای متغیر پاسخ عددی نیز می‌توان بکار برد که به آن رگرسیون بردار پشتیبان گفته می‌شود. در اینصورت برای مدل رگرسیونی

$$f(x) = \beta_0 + \sum_{i=s} \alpha_i k(x, x_i) \quad (13)$$

پارامترهای مدل از کمینه کردن عبارت زیر بدست می‌آید.

$$Q(\beta, \beta_0) = \sum_{i=1}^N V(y_i - f(x_i)) + \frac{\lambda}{2} \|\beta\|^2, \quad (14)$$

در رابطه فوق $V(\cdot)$ به یکی از حالت‌های زیر تعریف می‌شود.

$$V_\varepsilon(r) = \begin{cases} 0 & |r| < \varepsilon, \\ |r| - \varepsilon & \text{otherwise,} \end{cases} \quad (15)$$

$$V_H(r) = \begin{cases} r^2/2 & |r| \leq c, \\ c|r| - c^2/2 & |r| > c, \end{cases} \quad (16)$$

که $V_H(\cdot)$ ، $V_\varepsilon(\cdot)$ به ترتیب تابع خطای ε - غیرحساس و تابع هوبر گفته می‌شود.

معیارهای ارزیابی کارایی مدل SVR

به منظور مقایسه عملکرد مدل در پیش‌بینی، از معیارهای ارزیابی ریشه میانگین مربعات خطا، میانگین قدرمطلق خطا، ضریب همبستگی، شاخص توافق ویلمورت و ضریب کارایی نش - ساتکلیف استفاده گردید که روابط آنها در ادامه ارائه گردید Gerkaninezhad moshazi & Bazrafshan., (2018).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SPEI_p - SPEI_o)^2}{n}} \quad (17)$$

$$MAE = \frac{|SPEI_p - SPEI_o|}{n} \quad (18)$$

$$R^2 = \frac{\sum_{i=1}^n (SPEI_{o,i} - \overline{SPEI}_{o,i})(SPEI_{p,i} - \overline{SPEI}_{p,i})}{\sqrt{\sum_{i=1}^n (SPEI_{o,i} - \overline{SPEI}_{o,i})^2 \sum_{i=1}^n (SPEI_{p,i} - \overline{SPEI}_{p,i})^2}} \quad (19)$$

طبقه بندی کننده بردار پشتیبان¹ معرفی می‌شود که بسطی از طبقه بند بیشترین حاشیه است که علاوه بر مرز خطی بین طبقات، برای طیف وسیعتری از مرز بین طبقات بکار برده می‌شود. ماشین بردار پشتیبان نیز بسطی از طبقه بندی بردار پشتیبان است که برای مرزهای غیر خطی بین طبقات بکار برده می‌شود (Friedman et al., 2001).

فرض کنید متغیر زوج متغیرهای $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$ وجود داشته باشد بطوریکه $x_i \in \mathbb{R}^p$ و $y_i \in \{-1, 1\}$. حال ابر صفحه

$$\{x : f(x) = x^T \beta + \beta_0 = 0\}, \quad (9)$$

را در نظر می‌گیریم. در اینصورت ماشین بردار پشتیبان عبارتست از جداسازی مشاهدات در فضای p بعدی بر پایه

$$\min_{\beta, \beta_0} \|\beta\|^2 + C \sum_{i=1}^n \xi_i \quad (10)$$

$$\text{subject to } \xi_i \geq 0, \quad y_i(x_i^T \beta + \beta_0) \geq 1 - \xi_i \quad \forall i, \quad (11)$$

در رابطه فوق ξ_i پارامتر کمکی و C پارامتر هزینه می‌باشد (لین و لین، ۲۰۰۳) اما در عمل معمولاً مرز بین طبقات غیرخطی است و $f(x)$ بصورت

$$f(x) = \beta_0 + \sum_{i=s} \alpha_i k(x, x_i) \quad (12)$$

در نظر گرفته می‌شود که این تابع یک تابع غیرخطی بوده و $k(x, x_i)$ را تابع کرنل گویند. برخی از توابع کرنل معروف که در این مقاله مورد استفاده قرار گرفته اند عبارتند از (James et al., 2013).

کرنل خطی

$$k(x_i, x_{i'}) = \sum_{j=1}^p x_{ij} x_{i'j}$$

کرنل چندجمله‌ای

$$k(x_i, x_{i'}) = (\gamma \sum_{j=1}^p x_{ij} x_{i'j} + \alpha)^d$$

کرنل رادیال

$$k(x_i, x_{i'}) = \exp(-\gamma \sum_{j=1}^p (x_{ij} - x_{i'j})^2)$$

¹ Support Vector Classifier

(۱)، افزایش بارش سبب افزایش (ترسالی) SPEI و کاهش بارش سبب خشکسالی یا منفی شدن SPEI می‌گردد. لذا در تمام اقلیم‌ها این اصل استوار است. در خصوص دما که به نوعی در رابطه ۱، در تبخیر و تعرق پتانسیل دیده شده است، اثر هر سه متغیر در SPEI معکوس است. یعنی افزایش دما، سبب کاهش شاخص (خشکسالی) می‌گردد.

در خصوص تاثیر سیگنال‌های بزرگ مقیاس بر SPEI، شاخص نوسانات دمایی اقیانوس اطلس و آرام به همراه ضرایب آنها ارائه شده است. نتایج بسیاری از محققین (Nezamolsadat, 1999; Azizi, 2000; Gandomkar et al., 2014) مبنی بر اثر معکوس نوسانات اقیانوس آرام جنوبی بر ترسالی و خشکسالی در ایران است. این شاخص بیشترین اثر را در غرب و شمال‌غرب و کمترین اثر را در بخش‌های مرکزی و جنوبی ایران دارد. در بررسی اثر نوسانات اقیانوس آرام بر خشکسالی و ترسالی‌ها در ایران، فاتحی مرج و همکاران (۲۰۰۶)، عباسی و نبوی (۲۰۱۰)، ثمالی و همکاران (۲۰۱۹) گزارش نمودند، ارتباط معنی‌دار اما معکوس بین تغییرات خشکسالی و ترسالی در ایران وجود دارد.

$$d = 1 - \left[\frac{\sum_{i=1}^n (SPEI_{o,i} - SPEI_{p,i})^2}{\sum_{i=1}^n (|SPEI_{p,i} - \overline{SPEI}_o| + |SPEI_{o,i} - \overline{SPEI}_o|)^2} \right], 0 \leq d \leq 1 \quad (20)$$

$$E = 1 - \left[\frac{\sum_{i=1}^n (SPEI_{o,i} - SPEI_{p,i})^2}{\sum_{i=1}^n (SPEI_{o,i} - \overline{SPEI}_o)^2} \right], 0 \leq E \leq 1 \quad (21)$$

که در رابطه فوق SPEIo مقادیر مشاهده‌ای و SPEIp مقادیر پیش‌بینی شده است. پایین بودن ریشه میانگین مربعات خطا هر مدل نشان‌دهنده عملکرد بهتر آن است. لازم به ذکر است در تحقیق فوق، از برنامه اکسل و R نسخه‌ی ۵.۰.۵ برای کدنویسی و اخذ خروجی مدل‌های ذکر شده استفاده گردید.

نتایج و بحث

انتخاب مهم‌ترین متغیرها با رگرسیون لاسو

براساس روش لاسو مهم‌ترین متغیرها از بین بیش از ۳۲ متغیر برای هر نمونه اقلیمی در جدول (۲) ارائه شد. براساس نتایج در تمام نمونه‌های اقلیمی در بین متغیرهای اقلیمی متغیر بارش بعنوان مهم‌ترین متغیر موثر بر خشکسالی مشخص گردید. براساس نتایج بدست آمده، در تمام اقلیم‌ها بین خشکسالی و باران رابطه قوی وجود دارد. براساس رابطه

جدول ۲: ضرایب رگرسیون لاسو در انتخاب مهم‌ترین متغیرهای موثر بر خشکسالی

متغیرها	خیلی مرطوب	نیمه خشک فراسرد	نیمه خشک سرد	فراخشک سرد	سرد و خشک	فراخشک معتدل	خشک و گرم	فراخشک و گرم
P	۰/۷۲	۰/۸۵	۰/۷۶	۰/۵۸	۰/۷۸	۰/۵۷	۰/۸۱	۰/۶۳
Tmax	-۰/۴۲	-۰/۱۱	-۰/۱۲	-۰/۳۵	-۰/۲۰	-۰/۲۱	-۰/۱۳۴	-۰/۱۱
Tmin	-۰/۱۸	-۰/۱۶	-۰/۱۱	-۰/۰۳	-۰/۱۷۴	-۰/۱۹	-۰/۱۱۹	۰/۸۴۲
ETPc	-۰/۴	-۰/۴۷۴	-۰/۱۲	-۰/۱۶	-۰/۱۴۵	-۰/۱۶	-۰/۱۵	-۰/۱۹
MEI	۰/۱۴۸	۰/۱	۰/۱۲	۰/۲۳	-۰/۳۲۷	۰/۱۵	۰/۱۰۲	۰/۰۰۰
AMO	-۰/۱۲۷	-۰/۰۸۲	-۰/۶۸	-۰/۶۳۲	۰/۱۸۸	-۰/۱۵	-۰/۶۳۱	۰/۰۰۸
NAO	-۰/۳۶	۰/۱۱۹	-۰/۱۵	۰/۱۵۶	-۰/۱۳۴	-۰/۱۴۶	۰/۰۹۹	۰/۰۱۳
SOI	-۰/۱۴	-۰/۱۶۵	-۰/۱۸	-۰/۱۵۳	-۰/۱۴۷	-۰/۲۲	-۰/۱۵۲	-۰/۲۴۲
NINO3	-۰/۱۴	-۰/۱۶	-۰/۱۸	-۰/۰۵	-۰/۱۵	-۰/۲۲	-۰/۱۵	-۰/۴۰

براساس درجه پراکندگی بین SPEI مشاهده‌ای و پیش‌بینی شده، مهارت مدل SVR مشخص می‌گردد. مدل خطی بین SPEI مشاهده‌ای و پیش‌بینی شده نشان می‌دهد، در تمام ایستگاه‌ها بجز قلیم فراخشک گرم، دارای کارایی مناسبی

ارزیابی مدل SVR

به منظور ارزیابی کارایی مدل SVM در پیش‌بینی SPEI در مرحله آزمایش یا صحت‌سنجی مدل در سه تابع مورد استفاده، اسکتر پلات متغیرها رسم گردید (شکل ۱).

در ادامه ارزیابی کارایی مدل SVR، با جزئیات بیشتری خطای مدل مورد ارزیابی قرار گرفت. لذا هیستوگرام مقادیر فراوانی مطلق خطای مدل پیش‌بینی، برای هر تابع بهینه در هر نمونه اقلیمی طی دوره آزمایش (۲۰۰۰ تا ۲۰۱۵) مورد ارزیابی قرار گرفت (شکل ۲). تعداد ماه‌های دوره آزمایش یا صحت سنجی ۱۸۸ است. فراوانی هر هیستوگرام در هر محدوده خطا نشان‌دهنده میزان خطای برآورد در SPEI پیش‌بینی شده طی ۱۸۸ ماه است. در تمام ایستگاه‌ها بیشترین فراوانی خطا در محدوده ۰/۵ و -۰/۵ است. در ایستگاه رامسر و همدان بیشترین فراوانی خطا طی ۷۰ ماه (PE=-۰/۵)، در ارومیه و بندرعباس طی ۴۰ ماه (PE=+۰/۵)، در طبس طی ۴۰ ماه (PE=-۰/۵)، کرمان طی ۵۰ ماه (PE=-۰/۵)، شیراز طی ۵۰ ماه (PE=۰/۵) و بوشهر طی ۷۰ ماه با بالاترین خطا (PE=۱) در دوره آزمایش بودند. بنابراین می‌توانیم مقایسه جذابی در خصوص درصد خطای نسبی پیش‌بینی مدل‌ها در محدوده خطاها انجام دهیم. لذا می‌توانیم میزان قدرمطلق خطای نسبی را در محدوده صفر تا نیم، نیم تا یک، یک تا یک و نیم، یک و نیم تا دو و بیشتر از ۲ دسته بندی نماییم. لازم به ذکر است که فرکانس خطاهای موجود در هر دسته بسیار قابل تشخیص است و پیش‌بینی‌های کاملاً متفاوت برای هر ایستگاه منعکس می‌کند (جدول ۴). طبق نتایج بدست آمده براساس جدول ۴، در تمام ایستگاه‌ها، بیشترین فراوانی تجمعی خطا مربوط به دست خطای $0 \leq |PE| < 0.5$ است که نشان‌دهنده عملکرد عالی مدل SVM در برآورد SPEI است.

است. به منظور مقایسه بهتر نکوئی برازش، مدل رگرسیون خطی بصورت زیر برازش داده شد:

$$SPEI_p = mSPEI_o + C$$

در این رابطه، m شیب، C باقیمانده مدل است. در جدول (۲) مقادیر S (شیب خط) و R ضریب رگرسیون نیز ارائه شده است. هر چه ضریب S و R به یک نزدیک باشد، C به صفر نزدیک می‌شود. براساس جدول ۲؛ بیشترین شیب مربوط به بوشهر (۰/۶۰۰) و بندرعباس و کمترین شیب در رامسر (۰/۳۲۵) و کرمان (۰/۳۷۶) بدست آمد. این نشان می‌دهد، کارایی مدل SVR در بوشهر و بندرعباس در مقایسه با کرمان و بابلرسر پایین‌تر است، چرا که در ایستگاه‌های نامبرده ضریب R نیز پایین است. این امر احتمالاً به دلیل وجود داده‌های پرت در مقادیر پیش‌بینی شده است، چرا که در اکثر ایستگاه‌ها R و S نسبتاً بالاست. لذا بطور کل برداشت می‌شود که مهارت مدل SVR در پیش‌بینی قابل قبول است. به منظور ارزیابی کمی و آماری مقادیر پیش‌بینی شده و مشاهده شده از شاخص‌های MAE، RMSE، R^2 ، نش-ساتکلیف و شاخص توافق ویلموت (روابط ۱۷ تا ۲۱) استفاده شد و در جدول ۳ ارائه شد. در بین توابع خطی، چندجمله‌ای و شعاعی، عموماً تابع شعاعی بهترین کارایی را در ایستگاه‌های رامسر، همدان، شیراز، کرمان، بندرعباس و بوشهر نشان می‌دهد. این تابع در این ایستگاه‌ها کمترین میزان خطا و بیشترین ضریب همبستگی را داشته است. اما در دو ایستگاه طبس و ارومیه تابع خطی بهترین کارایی را نشان می‌دهد. شکل ۱، نمودار پراکندگی $SPEI_o$ و $SPEI_p$ را در مدل SVR با تابع بهینه نشان می‌دهد.

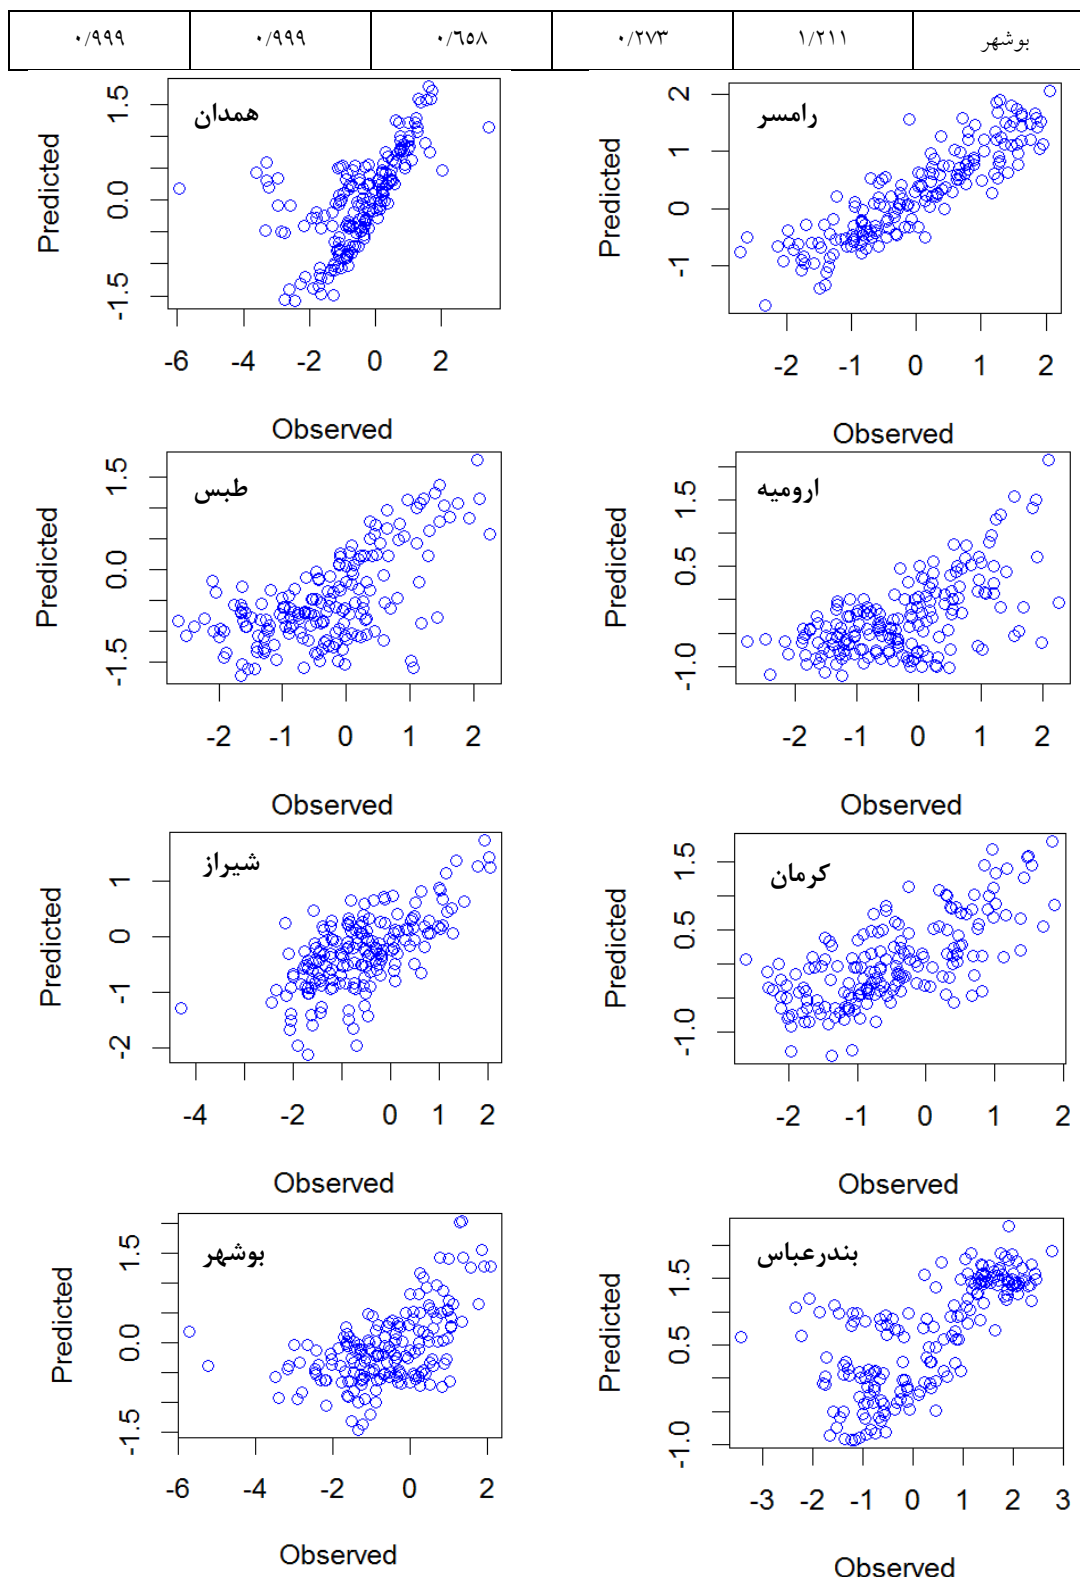
جدول ۳- ارزیابی کارایی مدل SVR براساس معادله رگرسیونی ($SPEI_p = mSPEI_o + c$) در دوره آزمایش

ایستگاه	m	S	R	C
رامسر	۰/۷۱۸	۰/۳۲۵	۰/۹۱۲	-۰/۰۱۲
همدان	۰/۶۵۴	۰/۴۲۲	۰/۸۵۷	-۰/۰۱۰
ارومیه	۰/۶۷۸	۰/۴۰۱	۰/۸۷۳	۰/۰۳۵
طبس	۰/۶۷۷	۰/۴۲۴	۰/۸۶۱	۰/۰۱۸
کرمان	۰/۶۵۸	۰/۳۷۶	۰/۸۸۱	۰/۰۱۰
شیراز	۰/۵۹۳	۰/۴۶۰	۰/۸۱۹	-۰/۰۲۲
بندرعباس	۰/۶۰۶	۰/۵۲۷	۰/۸۱۲	۰/۲۷۶

۰/۰۲۲	۰/۷۳۱	۰/۶۰۰	۰/۴۷۶	بوشهر
-------	-------	-------	-------	-------

جدول ۴- مقادیر کمی کارایی مدل SVR در مرحله صحت‌سنجی طی دوره ۲۰۰۱ تا ۲۰۱۵

E	d	R ²	MAE	RMSE	نام ایستگاه
تابع خطی					
۰/۲۲۷	۰/۹۹۷	۰/۴۲۶	۰/۶۵۷	۰/۹۷۵	رامسر
۰/۲۲۲	۰/۹۹۸	۰/۳۷۳	۰/۶۵۹	۱/۰۹۴	همدان
۰/۳۶۵	۰/۹۹۸	۰/۷۶۷	۰/۶۴۳	۰/۸۲۱	ارومیه
۰/۳۱۹	۰/۹۹۸	۰/۷۲۸	۰/۶۶۶	۰/۸۲۲	طیس
۰/۰۶۳	۰/۹۹۸	۰/۳۴۵	۰/۷۴۲	۱/۰۳۶	کرمان
۰/۲۶۸	۰/۹۹۸	۰/۳۱۳	۰/۶۷۷	۰/۸۵۶	شیراز
۰/۳۶۶	۰/۹۹۸	۰/۴۴۹	۰/۷۶۶	۱/۰۳۶	بندرعباس
۰/۱۸۹	۰/۹۹۹	۰/۱۷۴	۰/۹۹۱	۱/۳۹۳	بوشهر
چندجمله‌ای					
۰/۳۶۱	۰/۹۹۷	۰/۴۷۲	۰/۶۲۴	۰/۸۸۷	رامسر
۰/۲۳۸	۰/۹۹۹	۰/۳۹۶	۰/۶۷۶	۱/۰۸۳	همدان
۰/۱۳۰	۰/۹۹۸	۰/۲۲۶	۰/۷۵۴	۰/۹۶۱	ارومیه
۰/۹۴۰	۰/۹۹۷	۰/۱۰۲	۰/۹۹۶	۱/۳۸۹	طیس
۰/۸۸۷	۰/۹۹۷	۰/۱۱۳	۰/۹۷۸	۱/۳۸۰	کرمان
۰/۵۲۷	۰/۹۹۵	۰/۱۷۰	۰/۷۹۵	۱/۲۳۷	شیراز
۰/۲۵۲	۰/۹۹۹	۰/۳۲۹	۰/۸۶۱	۱/۱۲۵	بندرعباس
۰/۱۲۳	۰/۹۹۸	۰/۱۲۵	۱/۰۰	۱/۳۵۴	بوشهر
تابع شعاعی					
۰/۶۹۴	۰/۹۹۸	۰/۹۰۸	۰/۷۹۱	۰/۶۱۳	رامسر
۰/۲۶۰	۰/۹۹۸	۰/۶۹۸	۰/۴۰۵	۱/۰۶۷	همدان
۰/۳۶۱	۰/۹۹۸	۰/۶۳۸	۰/۶۶۱	۰/۸۲۳	ارومیه
۰/۱۷۵	۰/۹۹۸	۰/۶۸۳	۰/۴۴۵	۰/۹۰۵	طیس
۰/۲۱۷	۰/۹۹۸	۰/۷۱۱	۰/۴۸۳	۰/۸۸۹	کرمان
۰/۳۶۷	۰/۹۹۸	۰/۸۵۹	۰/۴۰۷	۰/۷۹۶	شیراز
۰/۴۴۵	۰/۹۹۸	۰/۶۶۹	۰/۵۲۰	۰/۹۶۹	بندرعباس



شکل ۱- نمودار پراکنندگی SPEI مشاهده شده و پیش‌بینی شده طی دوره صحت سنجی ۲۰۰۱ تا ۲۰۱۲

جدول ۵- فرکانس تجمعی (به درصد) خطای پیش‌بینی (PE) در محدوده خطای مشخص شده از SPEI شبیه‌سازی شده و مشاهده شده در دوره آزمایش (۲۰۰۱-۲۰۱۲)

ایستگاه	$0 \leq PE < 0.5$	$0.5 \leq PE < 1$	$1 \leq PE < 1.5$	$1.5 \leq PE < 2$	$ PE > 2$
رامسر	۰/۶۲	۰/۲۷	۰/۰۸	۰/۰۱	۰/۰۱
همدان	۰/۷۹	۰/۱۵	۰/۰۳	۰/۰۲	۰/۰۲
ارومیه	۰/۴۹	۰/۳۲	۰/۱۳	۰/۰۳	۰/۰۳
طبس	۰/۳۳	۰/۳۸	۰/۲	۰/۰۱	۰/۰۲
کرمان	۰/۴۴	۰/۲۸	۰/۱۸	۰/۰۷	۰/۰۲
شیراز	۰/۵۵	۰/۲۳	۰/۱۶	۰/۰۳	۰/۰۲
بندرعباس	۰/۵۱	۰/۲۹	۰/۰۹	۰/۰۴	۰/۰۷
بوشهر	۰/۶۹	۰/۲۴	۰/۰۶	۰/۰۱	-
متوسط ایستگاه‌ها	۰/۵۵	۰/۲۷	۰/۱۳	۰/۰۳	۰/۰۲

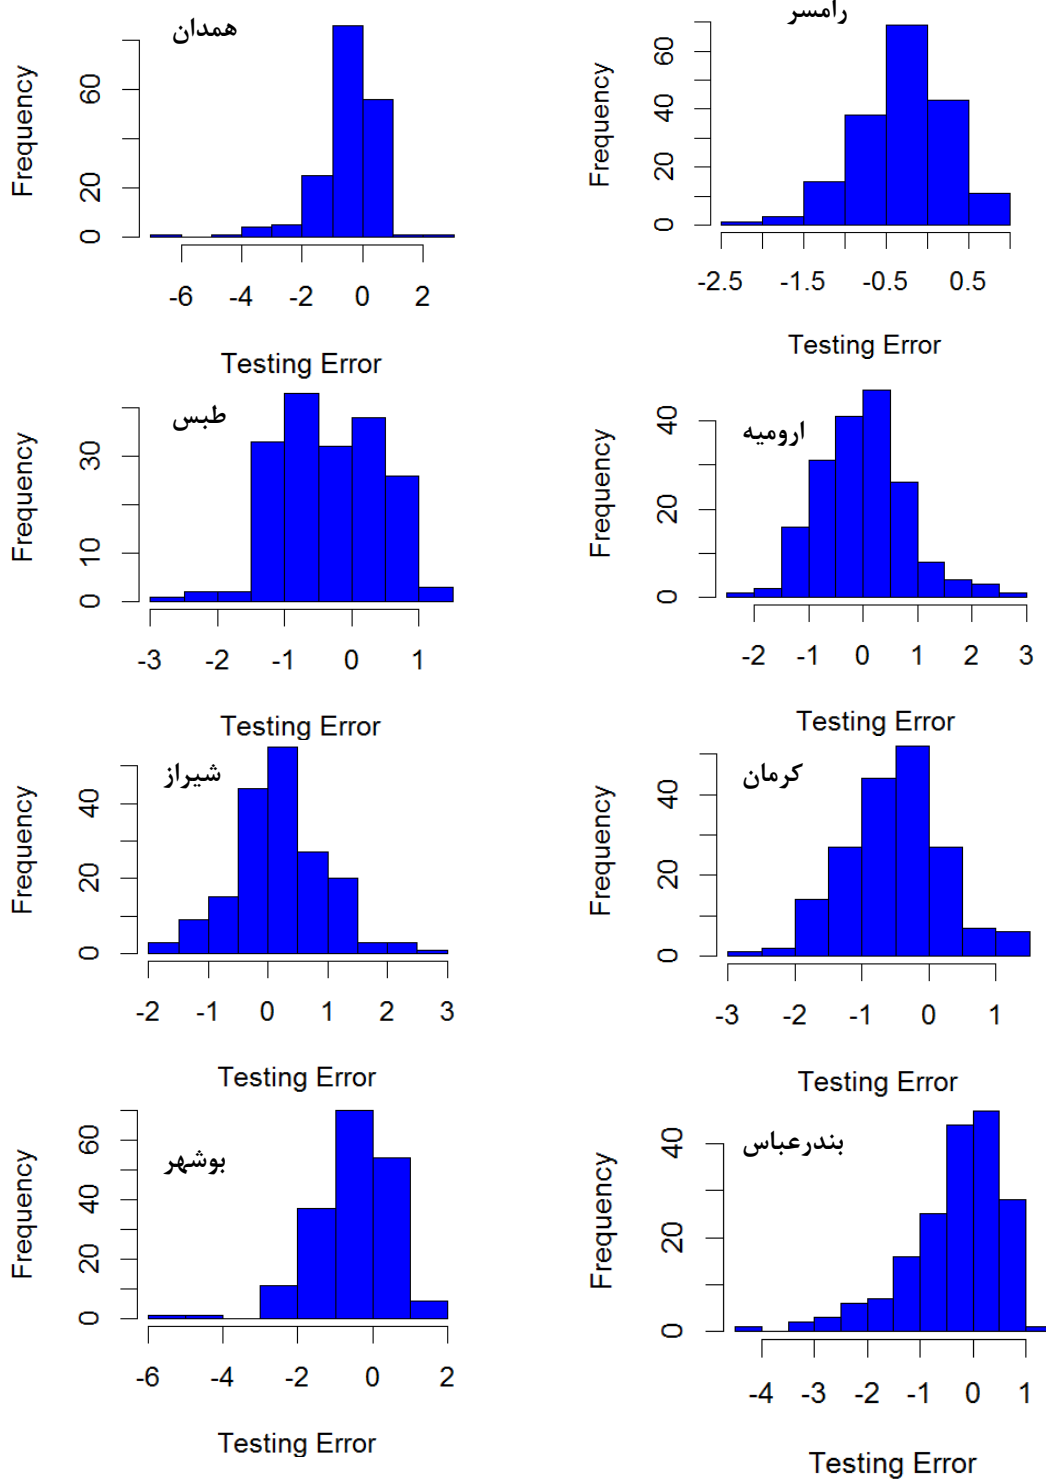
بررسی دقت مدل در مشخصه‌های خشکسالی

جهت بررسی دقت مدل SVR مقادیر مشخصه‌های خشکسالی شامل شدت، مدت، بزرگی و پیک خشکسالی در SPEI مشاهده‌ای و برآورد شده، محاسبه گردید و باکس پلات هر مشخصه بصورت جداگانه رسم و صدک ۲۵، ۵۰ و ۷۵ مورد مقایسه قرار گرفت. (جدول ۵) میزان اختلاف در صدک‌ها را در برآورد مشخصه‌های خشکسالی نشان می‌دهد. در شدت خشکسالی (شکل ۳)، در تمام اقلیم‌ها بجز نیمه خشک سرد (کرمان) و فراخشک معتدل (طبس) در صدک ۷۵ مدل دچار کم برآورد شده است. جالب توجه اینکه، بیشترین اختلاف مشاهده شده بین مقادیر مشاهده‌ای و پیش‌بینی شده در صدک ۷۵ مشاهده می‌شود. در مورد اقلیم نیمه خشک سرد در ایستگاه ارومیه میزان صدک ۵۰ یا میانه و صدک ۲۵، بطور معنی داری نسبت به بقیه کمتر است.

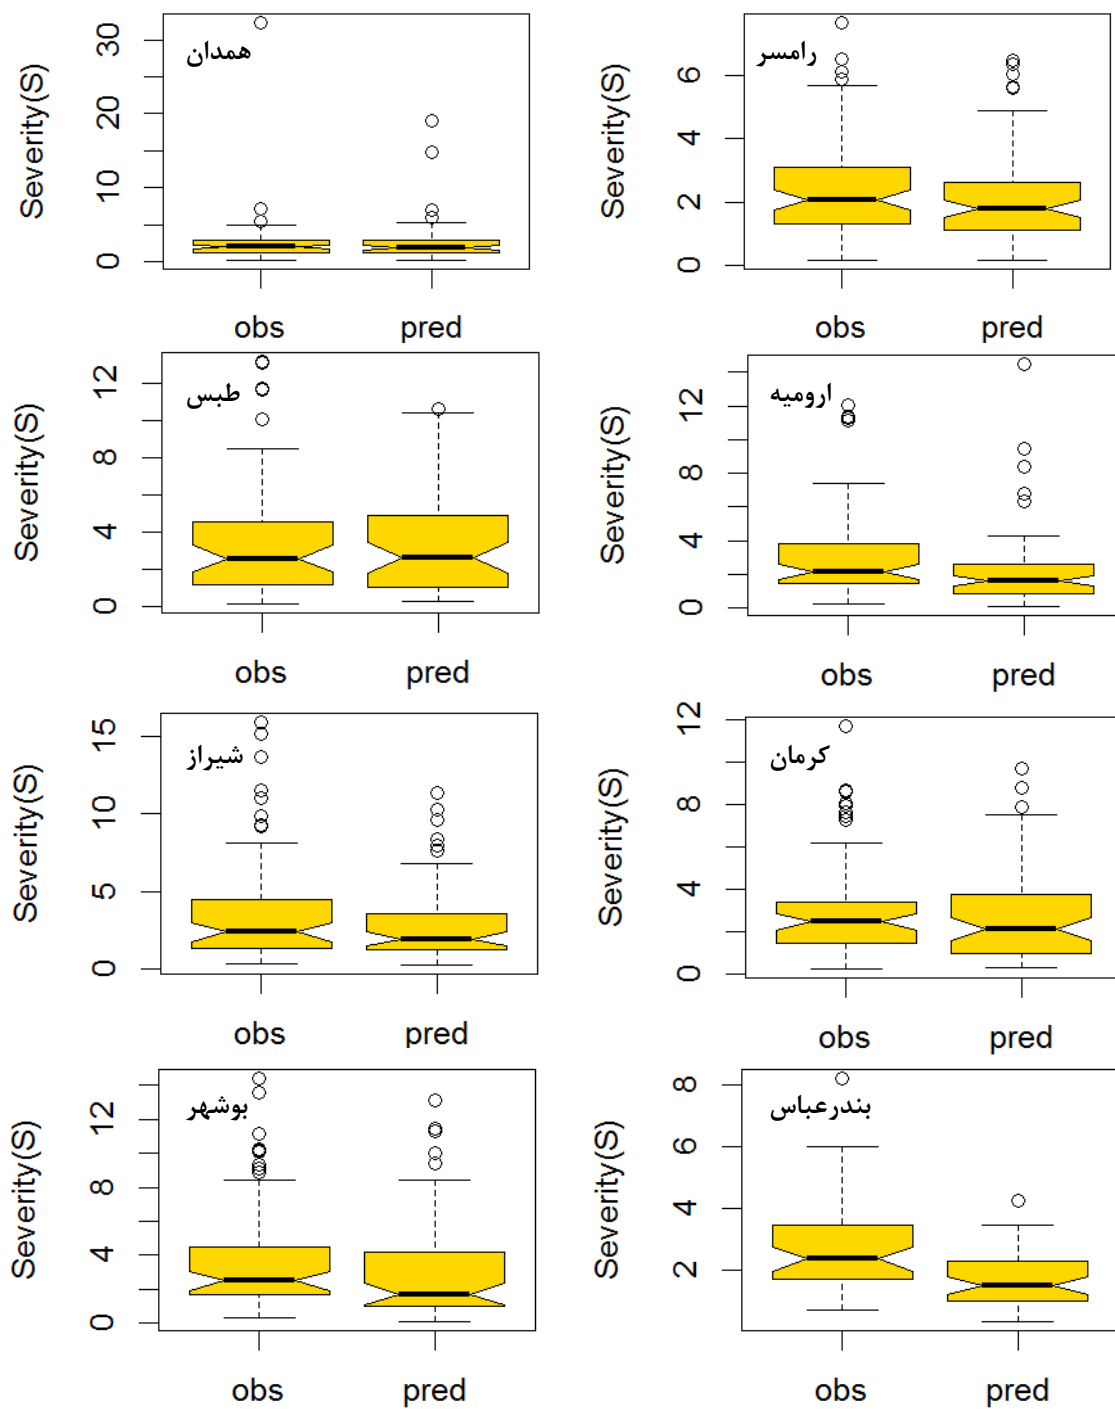
در خصوص تداوم خشکسالی (شکل ۴)، بهترین برآورد مربوط به اقلیم خیلی مرطوب (رامسر) بوده است. در تمام

صدک‌ها اختلافی بین مقادیر برآورد شده و مشاهده شده دیده نمی‌شود. در اقلیم فراخشک و گرم و خشک گرم در صدک ۷۵ ام، دارای بیشترین اختلاف بین مقادیر مشاهده‌ای و پیش‌بینی شده است، و به ترتیب مدل دچار کم برآورد و بیش برآورد شده است. در مورد تداوم نیز بیشترین اختلاف در صدک ۷۵ مشاهده می‌شود.

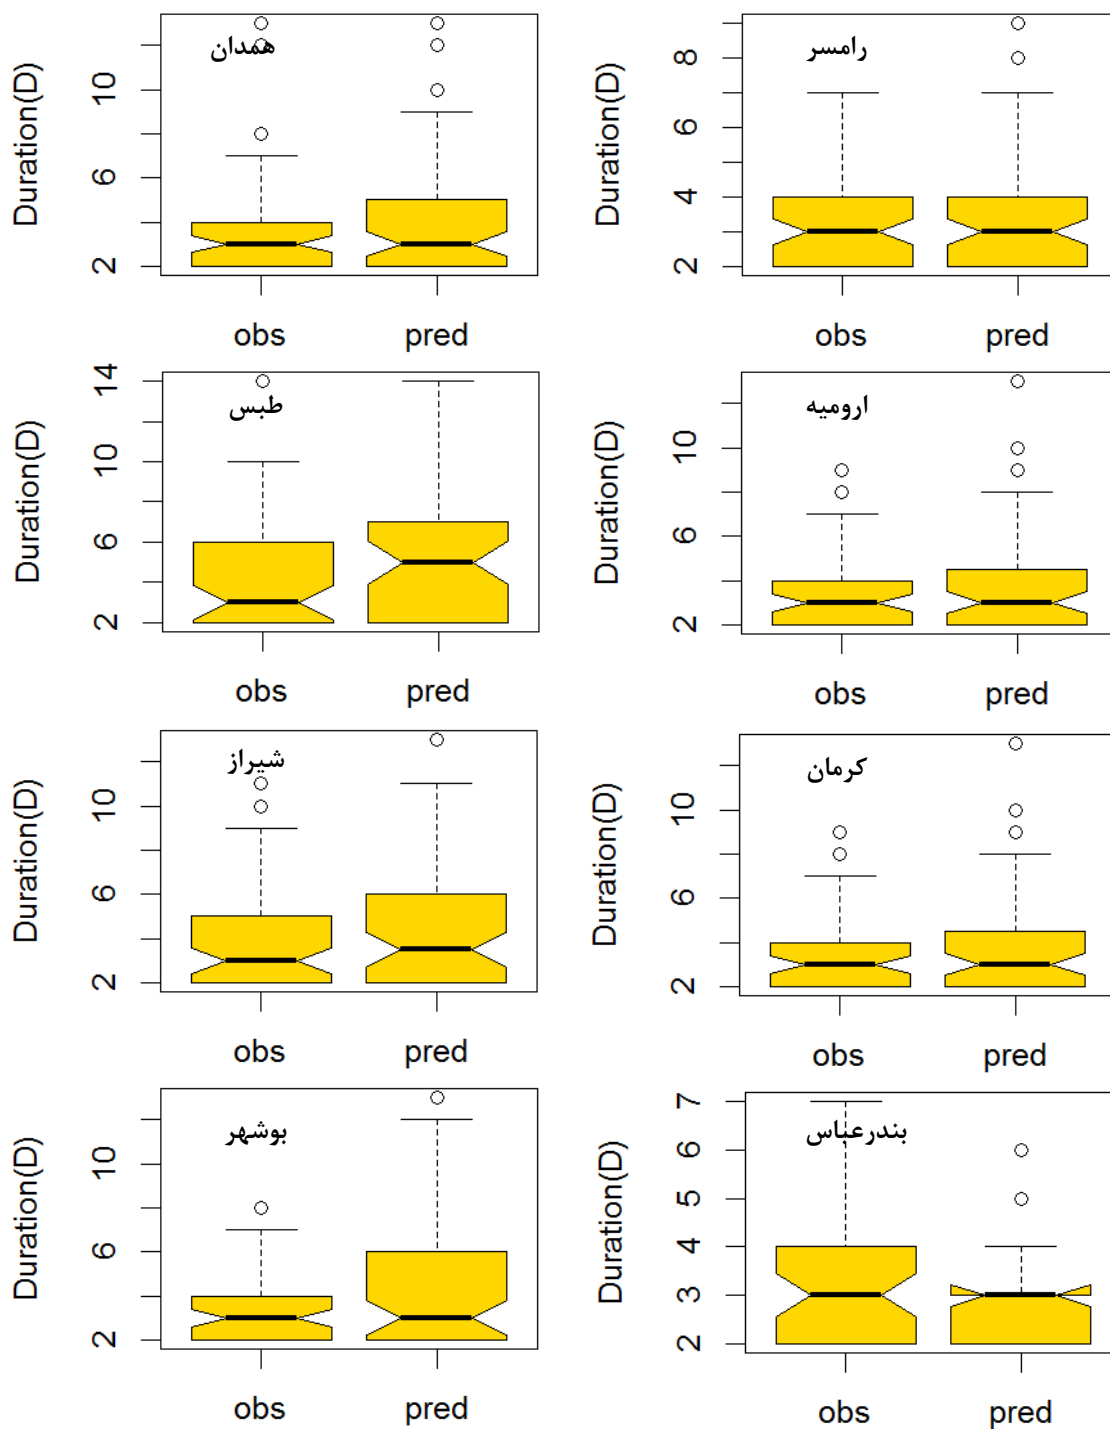
در خصوص بزرگی خشکسالی (شکل ۵)، در تمامی اقلیم‌ها مدل دچار کم برآورد شده است که بیشترین اختلاف نیز در دو اقلیم گرم و خشک و فراخشک و گرم مشاهده می‌شود. در این مشخصه نیز، صدک ۷۵ ام بیشترین اختلاف را نشان می‌دهد. در پیک خشکسالی (شکل ۶) نیز در تمام ایستگاه‌ها، مدل دچار کم برآورد شده (بجز اقلیم فراخشک و معتدل) و بیشترین اختلاف در اقلیم گرم و خشک دیده می‌شود. بطور کلی در ربع پایینی و میانی اختلاف چندانی در برآورد مدل دیده نمی‌شود، اما در ربع بالایی تقریباً در تمام مشخصه‌ها اختلاف قابل توجهی دیده می‌شود.



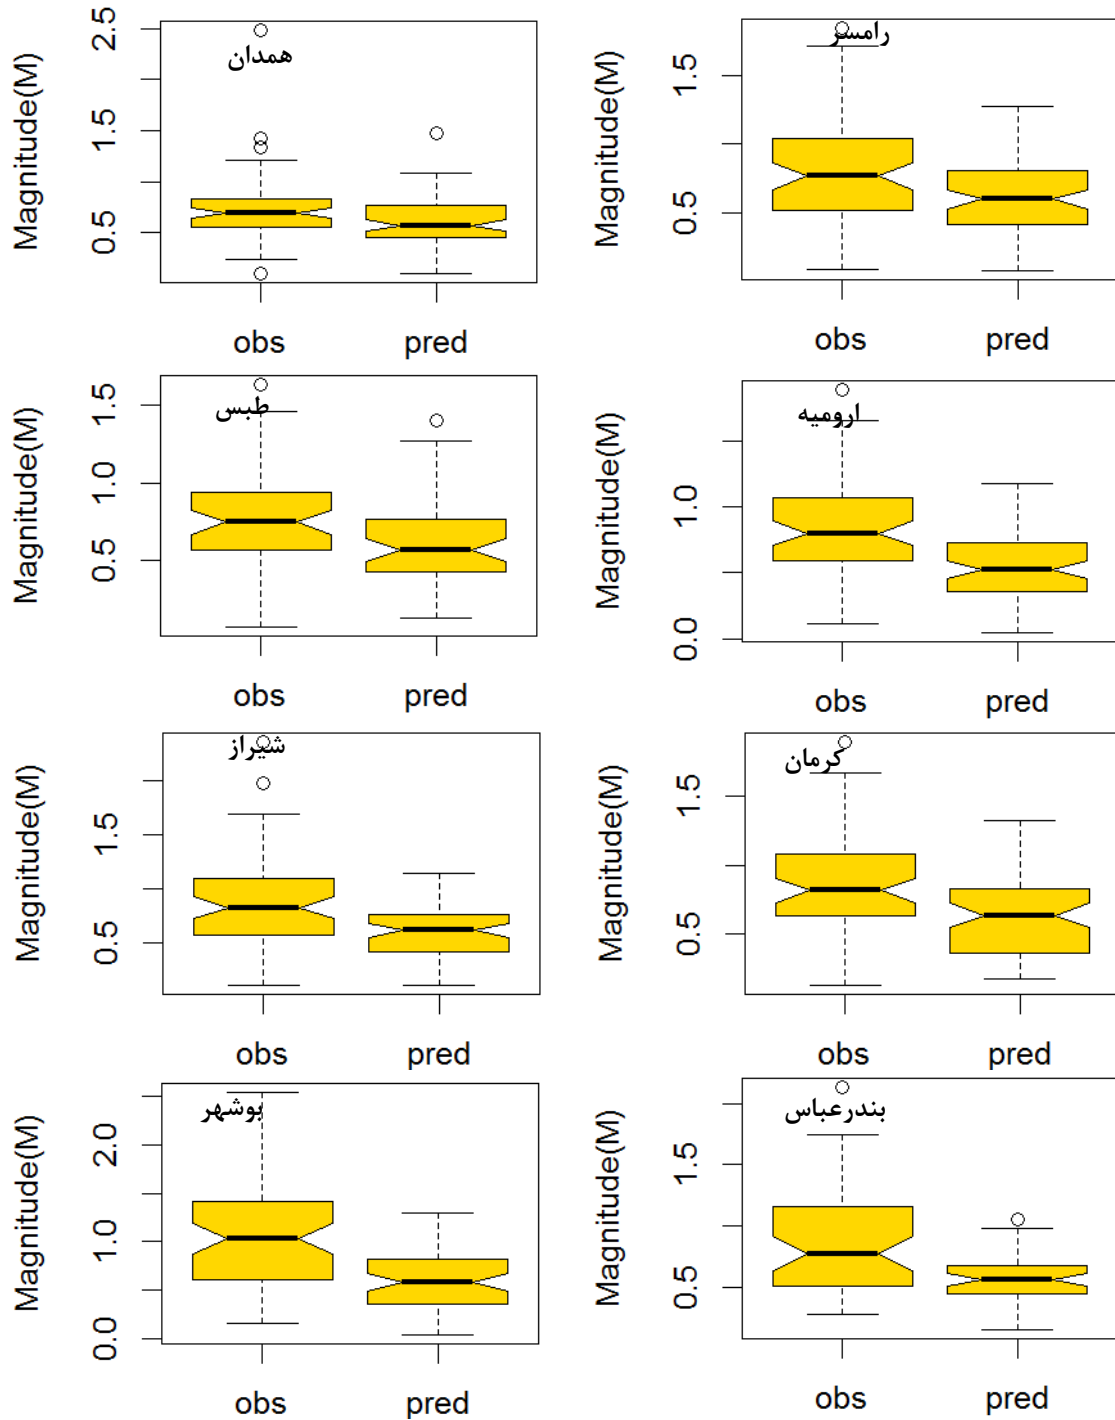
شکل ۲- هیستوگرام توزیع فراوانی در برابر مقدار خطاهای پیش‌بینی (PE) در دوره آزمایش ۲۰۰۰-۲۰۱۵



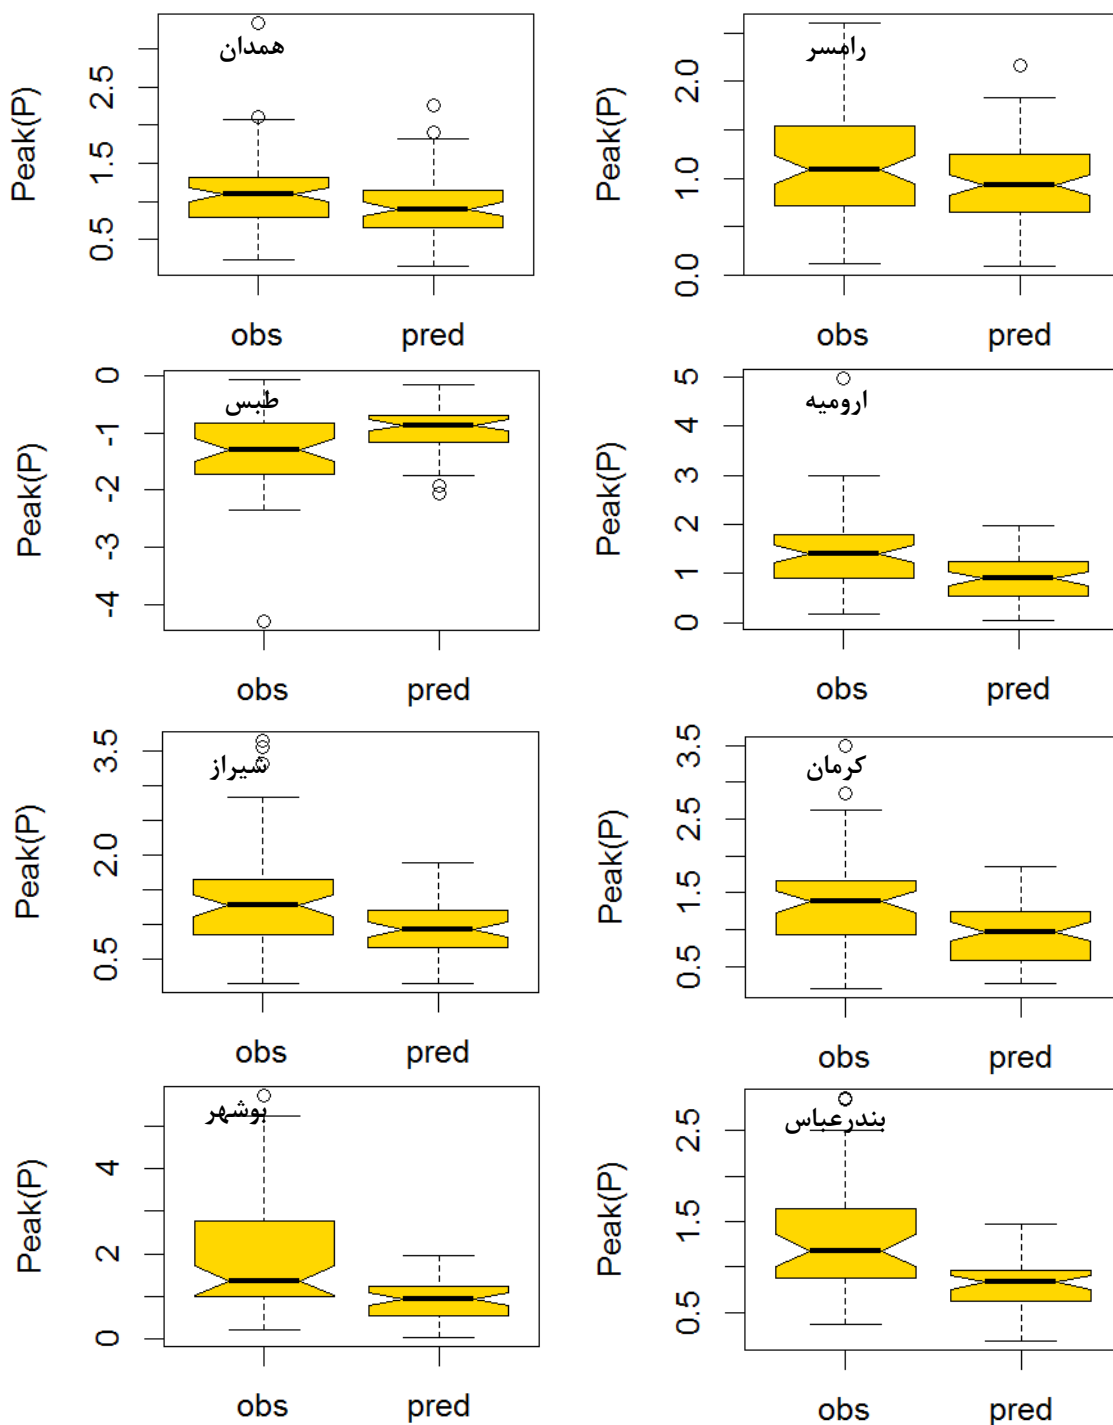
شکل ۳- نمودار جعبه‌ای توافق مشخصه شدت خشکسالی SPEI مشاهده ای و پیش‌بینی شده در دوره آزمایش مدل



شکل ۴- نمودار جعبه‌ای توافق مشخصه تداوم خشکسالی SPEI مشاهده ای و پیش‌بینی شده در دوره آزمایش مدل



شکل ۵- نمودار جعبه ای توافق مشخصه بزرگی خشکسالی SPEI مشاهده ای و پیش‌بینی شده در دوره آزمایش مدل



شکل ۶- نمودار جعبه‌ای توافق مشخصه پیک خشکسالی SPEI مشاهده‌ای و پیش‌بینی شده در دوره آزمایش مدل

جدول ۶- تفاوت آماری خصوصیات خشکسالی در دوره آزمایش

ایستگاه	صدک ۱۷۵ ام	صدک ۵۰ ام	صدک ۲۵ ام
شدت خشکسالی			
رامسر	-۲/۳۷	-۱/۳۲	-۰/۳۲
همدان	-۰/۱۱	-۰/۸۳	-۰/۸۵
ارومیه	۰/۳۹	-۰/۱۱	-۰/۰۱
طیس	۳/۷۱	-۲/۶۸	-۱/۱۶
کرمان	۵/۰۱	-۱/۷۴	-۱/۴۴
شیراز	۳/۱۲	۲/۴۶	۱/۱۵
بندرعباس	-۱/۳۹	-۰/۹۰	-۱/۱۹
بوشهر	-۵/۴۶	-۱/۷۷	-۱/۰۲
مدت خشکسالی			
رامسر	۰	۰	۰
همدان	۴	۰	۰/۵
ارومیه	۲/۲۰	۲	۱
طیس	۴	۳	۰/۰۰
کرمان	۱/۰۰	۰/۰۰	۰/۰۰
شیراز	۲	۱	۱/۰۰
بندرعباس	-۳	۰	۰/۰۰
بوشهر	۵	۰	۰
بزرگی خشکسالی			
رامسر	-۰/۶۶	-۰/۳۸	-۰/۱۷
همدان	-۰/۱۸	-۰/۱۹	-۰/۳۷
ارومیه	-۰/۴۵	-۰/۴۰	-۰/۲۳
طیس	-۰/۴۷	-۰/۳۶	-۰/۴۰
کرمان	-۰/۶۳	-۰/۵۳	-۰/۵۱
شیراز	-۰/۰۹	-۰/۰۲	-۰/۱۵
بندرعباس	-۰/۶۴	-۰/۵۳	-۰/۲۹
بوشهر	-۱/۱۲	-۰/۷۸	-۰/۶۹
اوج خشکسالی			
رامسر	-۰/۸۷	-۰/۶۴	-۰/۱۸
همدان	-۰/۳۵	-۰/۴۷	-۰/۵۴
ارومیه	-۰/۹۴	-۰/۷۱	-۰/۵۹
طیس	-۰/۵۹	۰/۷۷	۰/۶۲
کرمان	-۱/۲۴	-۱/۰۴	-۰/۷۴
شیراز	-۰/۴۲	-۰/۰۵	۰/۰۶
بندرعباس	-۰/۶۸	-۰/۵۳	-۰/۴۲
بوشهر	-۱/۹۶	-۱/۲۷	-۰/۷۲

نتیجه‌گیری

در تحقیق حاضر از یکی از الگوریتم‌های یادگیری ماشین به نام SVR برای پیش‌بینی اثر متغیرهای اقلیمی و پیوند از دور بر خشکسالی کشاورزی در ۸ نمونه اقلیمی ایران استفاده گردید. مهم‌ترین متغیرهای موثر بر SPEI از بین بارندگی، دما، تبخیر و تعرق و سیگنال‌های بزرگ مقیاس با استفاده از تکنیک رگرسیون لاسو انتخاب گردید. جهت پیش‌بینی SPEI داده‌ها به دو دسته آموزش (۸۰٪) و آزمایش (۲۰٪) دسته‌بندی و از توابع خطی، شعاعی و چندجمله‌ای جهت مدل کردن خشکسالی استفاده شد.

به منظور تأیید صحت مدل SVR و تعیین روابط غیرخطی بین متغیرهای پیش‌بینی شونده و پیش‌بینی کننده از معیارهای پیش‌بینی مانند ضریب همبستگی، RMSE و MAE، شاخص توافق Wilmort و ضریب کارایی Nash-Sutcliffe استفاده گردید. یافته‌های این مطالعه را می‌توان به شرح زیر برشمرد.

۱- نتایج رگرسیون لاسو نشان داد، در تمام اقلیم‌ها موثرترین متغیر، بارش است و درین متغیرهای پیوند از دور در تمام اقلیم‌ها در ایران به‌جز نیمه خشک سرد و خشک فراگرم، اثر نوسانات دمایی اقیانوس اطلس شمالی و آرام جنوبی بصورت مشترک بر نوسانات خشکسالی کشاورزی موثر هستند.

۲- نتایج در بررسی توابع مورد استفاده نشان داد، در تمام اقلیم‌ها تابع شعاعی بهترین نتایج را نشان داد، بجز اقلیم نیمه خشک سرد و فراخشک و معتدل که تابع خطی بهترین کارایی را داشت.

۳- بر اساس تجزیه و تحلیل نمودار پراکنندگی داده‌های آزمون و ضرایب مدل، مقدار توافق بین مقدار پیش‌بینی کننده و پیش‌بینی شونده؛ ۰/۹۱۲ تا ۰/۷۳۱ به ترتیب در اقلیم خیلی مرطوب و اقلیم خشک و گرم است. بنابراین بهترین پیش‌بینی مربوط به ایستگاه رامسر و ضعیف‌ترین پیش‌بینی مربوط به بوشهر است.

۴- در بررسی خطای مدل براساس PE یا فرکانس خطا، بیش از ۵۵٪ خطا ناچیز و مربوط به دسته $\pm 0/5$ تا $0/27$ مربوط به دسته $\pm 0/5$ تا ± 1 و $0/13$ در دسته ± 1 تا $1/5$ ±

قرار دارد که نشان دهنده کارایی مناسب مدل در برآورد SPEI است.

۵- برای بررسی عملکرد مدل SVR در پیش‌بینی وقایع خشکسالی در طول دوره آزمایش، متغیرهای شدت خشکسالی، مدت زمان و شدت اوج و بزرگی مورد بررسی قرار گرفت. در متغیر شدت، بزرگی و پیک خشکسالی عموماً مدل دچار کم برآورد شده است بجز در ایستگاه طس و ارومیه که تابع خطی در اقلیم فراخشک و معتدل و نیمه خشک سرد رفتاری متفاوت را نشان داد.

بیشترین اختلاف بین مقادیر مشاهده‌ای و پیش‌بینی شده در متغیر شدت خشکسالی و در صدک ۱۷۵ مشاهده گردید. این اختلاف در اقلیم خشک و گرم (بوشهر) ملاحظه گردید. در نهایت، می‌توان بیان نمود، مدل SVR در پیش‌بینی SPEI برای اکثر اقلیم‌ها بسیار کارآمد است. با این حال، عملکرد آن در مناطق متنوع جغرافیایی و اقلیمی، متفاوت به نظر می‌رسد که شاید نشان دهنده نقش متفاوت رگرسیون‌های مورد استفاده در آموزش مدل SVM و متغیرهای مختلف باشد.

سرانجام نتایج نشان داد، الگوریتم SVR یک ابزار جذاب یادگیری ماشین برای پیش‌بینی پارامترهای خشکسالی است و می‌تواند اطلاعات مفیدی برای مدیریت منابع آب، کشاورزی پایدار و اقلیم‌شناسی ارائه نماید.

منابع

1. Abbasi, A., K. Khalili, J. Behmanesh, A. Shirzad, 2020, Application of support vector machine and Bayesian network for agricultural drought prediction. J. Watershed engineering and management, NO. 12(1), PP. 107-124.
2. Abbasi, A., S. Nabavi, 2010, the effect of remote linking patterns on Iranian rains. J. Geography.
3. Azhdari Moghadam, M., Khosravi, M., Hosseinpour Niknam. H., Jaffari Nadoushan, E. 2011. Prediction of drought using Fuzzy-Neural network model, climatic indices, precipitation and drought index. Kournal of Geography and Development, 10(26): 61-72.
4. Azizi, gh. 2000, El Nino and drought- wet periods in the climate of Iran. J. Geographical reseach quarterly, NO. 32(38), PP. 71-84.

- uncertainty: Application of Bayesian maximum entropy. *Journal of Environmental Management*, 304, 114245.
17. Iraquejad, Sh., M. Karamooz, 2018, advanced hydrology, Amirkabir University. pp. 468.
 18. James, G., D. Witten, T. Hastie, R. Tibshirani, 2013, an introduction to statistical learning, PP. 18.
 19. Julio Canon, J., J. Gonzalez, J. Valde's, 2007, Precipitation in the Colorado River Basin an Its Low Frequency Associations With PDO and ENSO Signals, *J. Hydrology*, NO. 344, PP. 252-264.
 20. Kao, H. Y., J. Y. Yu, 2009, contrasting eastern-Pacific and central-Pacific types of ENSO, *J. Climate*, NO. 22(3), PP. 615-632.
 21. Kushnir, Y., W. A. Robinson, I. Bladé, N. M. J. Hall, S. Peng, R. Sutton, 2002, Atmospheric GCM response to extratropical SST anomalies: Synthesis and evaluation, *J. Climate*, NO. 15(16), PP. 2233-2256.
 22. Lin, H. T., C. J. Lin, 2003, a study on sigmoid kernels for SVM and the training of non-PSD kernels by SMO-type methods. *J. submitted to Neural Computation*, NO. 3(1-32), PP. 16.
 23. Malik, A., Kumar, A., Rai, P., & Kuriqi, A. (2021). Prediction of Multi-Scalar Standardized Precipitation Index by Using Artificial Intelligence and Regression Models. *Climate*, 9(2), 28.
 24. Mendicino, G., A. Senatore, P. Versace, 2008, Groundwater resource index (GRI) for drought monitoring and forecasting in a Mediterranean climate, *J. Hydrology*, NO. 357, PP. 282-302.
 25. Morid, S., V. Smakhtin, K. Bagherzadeh, 2007, Drought forecasting using artificial neural networks and time series of drought indices, *J. Climatology*, NO. 27(15), PP. 2103-2111.
 26. Nezamolsadat, S. 1999, Investigation of the effect of El Nino phenomenon- southern fluctuations (ENSO) on autumn rainfall in Iran. *J. Regional conference on climate change, meteorological organization*.
 27. Sebgati, M., H. Ahmadi Pirgani, A. Moghaddam, 2016, the calculation of continuity and intensity of droughts using modified SPEI index (Case study: Tabriz and Urmia cities). *J. Environment and water engineering*, NO. 2(2), PP. 188-195.
 28. Somali, R., O. Bazrafshan, M. Biniiaz, H. Moslemi, 2019, Investigation of the relationship between the phenomenon of enso on the drought and wet year in the douthern
 5. Bazrafshan, O., F. Mahmoudzadeh, A. Asgarinezhad, J. Bazrafshan, 2019, Adaptive Evaluation of SPI, RDI, and SPEI indices in analyzing the trend of intensity, duration, and frequency of drought in arid and semi- arid regions of Iran. *J. Agriculture*, NO. 42(3), PP. 117-131.
 6. Blenkinsop, S., H. J. Fowler, 2007, Changes in drought frequency, severity and duration for the British Isles projected by the PRUDENCE regional climate models. *J. Hydrology*, NO. 342, PP. 50-71.
 7. Boser, B., I. Guyon, V. Vapnik, 1992, A training algorithm for optimal margin classi_ers. In *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*.
 8. Cordery, I., M. McCall, 2000, a Model for Forecasting Drought from Teleconnections. *J. Water Resources Research*, NO. 36(3), PP. 763-76.
 9. Cortes, C., V. Vapnik, 1995, Support-vector network. *Machine Learning*, NO. 20, PP. 273-297.
 10. Deo, R. C., S. Salcedo-Sanz, L. Carro-Calvo, B. Saavedra-Moreno, 2018, Drought prediction with standardized precipitation and evapotranspiration index and support vector regression models, *J. In Integrating disaster science and management*, pp. 151-174.
 11. Fatehi Marj, A., A. Borhani darian, M. H. Mahdian, 2006, Seasonal rainfall using teleconnection pattern case stady: orumiyeh lake basin. *J. Soil and water sciences*, NO. 10(3), PP. 45-58.
 12. Friedman, J., T. Hastie, R. Tibshirani, 2001, the elements of statistical learning, NO. 10.
 13. Gandomkar, A., Y. Toloei, K. Esmaeili, R. Deghani, M. pour Gholami, 2014, Investigation of the effect of NAO fluctuations on precipitation Ardabil station. *J. Intrnational conference on sustainable development, strategies and challenges*.
 14. Gerkaninezhad moshofi, Z., O. Bazrafshan, 2018, Impact of climatic signals on the wet and dry season precipitation (Case study: Persian gulf and oman sea watersheds). *J. The earth and space physics*, NO. 44(2), PP. 333-349.
 15. Ghasemieh, H., O. Bazrafshan, k. Bakhshayesh manesh, 2017, artificial neural network for monthly rainfall forecasting using teleconnection patterns (Case study: central plateau basin of Iran). *J. The earth space physics*, NO. 43(2), PP. 405-418.
 16. Ghazipour, F., & Mahjouri, N. (2022). A multi-model data fusion methodology for seasonal drought forecasting under

30. Vicente-Serrano, S. M., S. Beguería, J. I. López-Moreno, 2010, A multiscalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index, *J. climate*, NO. 23(7), PP. 1696-1718.
31. Zhang, Y., H. Yang, H. Cui, Q. Chen, 2020, Comparison of the ability of ARIMA, WNN and SVM models for drought forecasting in the Sanjiang Plain, China. *J. Natural Resources Research*, NO. 29(2), PP. 1447-1464.
- coastal provinces of Iran. *J. Irrigation and drainage*, NO. 13(1), PP. 217-231.
29. Tian, Y., Y. P. Xu, G. Wang, 2018, Agricultural drought prediction using climate indices based on Support Vector Regression in Xiangjiang River basin, *J. Science of The Total Environment*, NO. 622, PP. 710-720.