

کاربرد روش ماشین بردار پشتیبان و شبکه بیزین در پیش‌بینی خشکسالی کشاورزی

عباس عباسی^۱، کیوان خلیلی^{۲*}، جواد بهمنش^۳ و اکبر شیرزاد^۴

^۱ دانشجوی دکتری مهندسی منابع آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه ارومیه، ^۲ استادیار، دانشکده کشاورزی و منابع طبیعی، دانشگاه ارومیه، ^۳ استادیار، گروه مهندسی عمران، دانشگاه صنعتی ارومیه

تاریخ پذیرش: ۱۳۹۷/۱۰/۳۰

تاریخ دریافت: ۱۳۹۷/۰۴/۲۳

چکیده

آگاهی از وضعیت خشکسالی و پیش‌بینی شرایط آبی آن نقش مهمی در برنامه‌های مدیریت منابع آب برعهده دارد و در این راستا متغیرهای بارش و دما تأثیر به‌سزایی در شدت و مدت وقوع این پدیده ایفا می‌کنند. با توجه به وضعیت حاکم بر دریاچه ارومیه در سال‌های اخیر و تنش آبی موجود در حوزه آبخیز آن، در این پژوهش، وضعیت خشکسالی در ایستگاه سینوپتیک سقز به‌عنوان یکی از ایستگاه‌های مهم جنوبی حوزه آبخیز این دریاچه در مقیاس‌های زمانی مختلف با استفاده از شاخص بارش-تبخیر و تعرق استاندارد شده (SPEI) و مدل ماشین بردار پشتیبان (SVM) با سه تابع هسته‌ای خطی، چند جمله‌ای و پایه شعاعی و شبکه بیزین (BN) مورد بررسی قرار گرفت. برای این منظور از شاخص SPEI در مقیاس‌های زمانی کوتاه‌مدت یک و سه ماهه، میان‌مدت شش و ۱۲ ماهه و بلندمدت ۲۴ و ۴۸ ماهه در طی دوره آماری ۴۹ ساله برای پایش وضعیت خشکسالی در این ایستگاه استفاده شد. نتایج نشان داد، هشت دوره طولانی مدت خشکسالی مربوط به سال‌های ۱۹۶۲-۱۹۶۸، ۱۹۷۲-۱۹۷۴، ۱۹۷۸-۱۹۷۹، ۱۹۸۰-۱۹۸۲، ۱۹۸۳-۱۹۸۴، ۱۹۸۷-۱۹۸۸، ۱۹۹۹-۲۰۰۳ و ۲۰۰۷-۲۰۰۹ در طول دوره آماری وجود دارد. سپس، با استفاده از سری زمانی مقادیر SPEI در پنج مدل ورودی با تأخیرهای یک تا پنج ماهه و مدل‌های SVM و BN نسبت به پیش‌بینی خشکسالی اقدام شد. نتایج نشان داد که در هر دو روش، مدل با پنج تأخیر زمانی عملکرد بهتری داشته و تابع هسته‌ای خطی در روش SVM نسبت به دو تابع دیگر دقت بیشتری داشته است. همچنین، دقت پیش‌بینی این مدل‌ها با افزایش مقیاس محاسبه SPEI رابطه مستقیم دارد، به‌نحوی که ضریب همبستگی در روش شبکه بیزین در مرحله آزمون از ۰/۱۷۴ در مقیاس یک ماهه به ۰/۹۸۵ در مقیاس ۴۸ ماهه و در روش SVM با تابع هسته‌ای خطی نیز از ۰/۱۴۹ به ۰/۹۸۳ رسیده است.

واژه‌های کلیدی: پایش، دریاچه ارومیه، شاخص SPEI، BN، SVM

مقدمه

کمبود آب تقریباً هر ساله در بسیاری از بخش‌های کره زمین اتفاق می‌افتد که یکی از علل مهم کمبود آب، رخداد خشکسالی است. کارهای اولیه در خصوص پایش خشکسالی عمدتاً با تحلیل فراوانی منطقه‌ای

به‌دلیل رشد جمعیت جهان و توسعه بخش‌های کشاورزی، انرژی و صنعت، نیاز به آب در دهه‌های اخیر به‌طور فزاینده‌ای افزایش یافته است، آن‌چنان که

همکاران (۲۰۱۵) نیز به مقایسه توزیع‌های فراوانی شاخص‌های SPI و SPEI در اروپا پرداختند که در این پژوهش توزیع‌های دو پارامتری گاما و مقادیر حد عمومی را به ترتیب برای شاخص‌های SPI و SPEI مناسب تشخیص دادند. Vicente-Serrano و همکاران (۲۰۱۱) در پژوهشی دیگر، اثرات فرایند شدن بر خشکسالی‌ها و منابع آب در اسپانیا را با به‌کارگیری دو شاخص SPI و SPEI مورد تحلیل قرار دادند که نتایج این پژوهش نشان داد که بارش و تبخیر و تعرق پتانسیل در دوره زمانی ۱۹۳۰ تا ۲۰۰۶ افزایش یافته و نتایج دو شاخص خشکسالی مشابه بوده است. در پژوهشی دیگر، Potop و Mozny (۲۰۱۱) کاربرد شاخص SPEI را به‌عنوان یک شاخص جدید خشکسالی در جمهوری چک مورد بررسی قرار دادند و به این نتیجه رسیدند که این شاخص دارای قابلیت تشخیص شدت خشکسالی تحت تأثیر افزایش شرایط دمایی در دهه‌های ۱۹۸۰، ۱۹۹۰ و ۲۰۰۰ است. در بسیاری از برنامه‌های بلندمدت منابع آب، لازم است که چشم‌اندازی از وضعیت آینده بارندگی و دوره‌های خشک و تر برای منطقه ترسیم شود. به‌همین دلیل، موضوع پیش‌بینی خشکسالی و تخمین ویژگی‌های آن از اهمیت بسیار زیادی در مدیریت منابع آب برخوردار است (Rezaei, ۲۰۰۷). تا کنون، بیشتر مدل‌های پیش‌بینی خشکسالی بر اساس تحلیل سری‌های زمانی و یا روش‌های شبکه عصبی مصنوعی بوده و کمتر از روش‌های هوشمند در این زمینه استفاده شده است. شبکه‌های بیزین که اصولی از نظریه گراف، نظریه احتمالات، علوم کامپیوتر و آمار را با هم ترکیب می‌کند، از جمله مدل‌های مطرح در زمینه پیش‌بینی در دهه‌های اخیر می‌باشند. از جمله مطالعات انجام گرفته در رابطه با شبکه‌های بیزین در مباحث منابع آب و هیدرولوژی می‌توان به پژوهش Borsuk و همکاران (۲۰۰۱) اشاره کرد که با استفاده از شبکه‌های تصمیم‌گیری بیزین به پیش‌بینی متغیرهای مربوط به اکوسیستم و کیفیت آب در مصب رودخانه‌ای در شمال کارولینا پرداختند که نتایج این پژوهش نشان داد که روش شبکه بیزین توانایی لازم در پیش‌بینی پارامترهای کیفی در حوضه مورد نظر را داراست. Brandt و Henriksen (۲۰۰۳) با استفاده از

خشکسالی در مقیاس کوچک به‌وسیله Whipple (۱۹۶۶) آغاز شد. اصولاً برای تحلیل کمی خشکسالی، وجود یک شاخص مناسب برای تعیین دقیق دوره‌های تر و خشک بسیار ضروری است (Da Silva, ۲۰۰۴). اما کمبود آب در یک حوضه با وجود بارش کافی، می‌تواند به واسطه تبخیر بالا، تغییر در کاهش ذخایر آب سطحی و حتی مصرف بیش از حد رخ دهد. کاهش میزان بارندگی و افزایش دما، هر یک به تنهایی و یا به کمک هم می‌توانند موجب خشکسالی شوند (Miller, ۲۰۰۰). شاخص‌های رایج تعیین خشکسالی مانند SPI صرفاً از میزان بارندگی روزانه و یا ماهانه استفاده می‌کنند. اما صرفاً در نظر گرفتن عامل بارش در تعیین خشکسالی یک منطقه، از جمله انتقاداتی است که بر شاخص‌های خشکسالی مبتنی بر بارش خصوصاً شاخص SPI وارد است و بسیاری از محققان بر اهمیت درجه حرارت بر شرایط خشکسالی تأکید کرده‌اند که منجر به افزایش تقاضای آب در اثر افزایش تبخیر و تعرق می‌شود (Kempes و همکاران، ۲۰۰۸). با این اوصاف، اثر افزایش دما در تشدید خشک شدن به مراتب بیشتر از کاهش بارندگی است و این می‌تواند نقش مؤثر دما در تقویت یا تضعیف خشکسالی را تأیید کند. بر همین اساس، می‌توان شاخص خشکسالی استاندارد شده بارش و تبخیر-تعرق (SPEI¹) را که Vicente-Serrano در سال ۲۰۱۰ عرضه کرد، در حکم شاخصی مناسب در تعیین خشکسالی مورد استفاده قرار داد. در این شاخص، سه متغیر بارش، دما و تبخیر و تعرق پتانسیل (PET²) لحاظ شده است و بر اساس میزان بارندگی و درجه حرارت و محاسبه تبخیر و تعرق و بیلان آب می‌تواند اثرات تغییرات درجه حرارت را در ارزیابی خشکسالی لحاظ کند. Labudova و همکاران (۲۰۱۴)، شاخص‌های خشکسالی SPI و SPEI را با استفاده از داده‌های مدل COSMO در دو حوزه آبخیز اسلوواکی مقایسه کردند و به این نتیجه رسیدند که همبستگی کمی بین این دو شاخص در مقیاس زمانی سه ماهه وجود دارد. همچنین، در این پژوهش، بر نقش مهم تبخیر و تعرق در خشکسالی در منطقه مورد بررسی در فصل تابستان تأکید شد. Stagge و

¹ Standard Precipitation and Evapotranspiration

² Potential Evapotranspiration

اساس خشکسالی‌های گذشته، در رودخانه گانسین آمریکا از روش شبکه بیزین استفاده کردند. در این پژوهش، یک مدل پیش‌بینی آماری چند متغیره با توجه به میزان رواناب در حوضه طرح‌ریزی شد که مهمترین مزیت مدل داشتن ویژگی‌های احتمالی در تجزیه و تحلیل خشکسالی در سال‌های آتی بوده است. در این مدل، بالاترین پیش‌بینی احتمالی با یک ارزیابی از عدم قطعیت‌ها مورد تحلیل قرار گرفت و شبکه‌های بیزین، احتمال خشکسالی در سال‌های آینده را با شدت‌های مختلف نشان دادند. ایده اصلی مدل SVM به‌وسیله Vapnik (۱۹۹۸)، ریاضیدان روسی، ارائه شد. مدل‌های SVM که جزء مدل‌های هوشمند محسوب می‌شوند، به‌منظور طبقه‌بندی و پیش‌بینی در علوم مختلف نظیر هیدرولوژی، کشاورزی، اقتصاد، پزشکی، هواشناسی و زمین‌شناسی استفاده شده‌اند. مزیت روش ماشین بردار پشتیبان نسبت به سایر روش‌ها، آموزش با تعداد داده‌ها و متغیرهای کمتر و همچنین، حساسیت نسبت به تغییر متغیرها و کوتاه‌تر بودن زمان اجرای مدل نسبت به سایر روش‌ها می‌باشد. نخستین کاربردهای SVM در زمینه منابع آب را می‌توان به تحقیقات Dibike و همکاران (۲۰۰۱) نسبت داد که با استفاده از SVM پیش‌بینی هیدرولوژیکی و همچنین، مدل‌سازی فرایند بارش-رواناب را انجام دادند. Behzad و همکاران (۲۰۰۹) برای پیش‌بینی رواناب روزانه در رودخانه بختیاری، مدل SVM را با بهره گرفتن از مسئله بهینه‌سازی دوگانه و استفاده از داده‌های هواشناسی و بارندگی به‌کار گرفتند و نتایج آن را با مدل ANN و ANN-GA مقایسه کردند و به این نتیجه رسیدند که روش ماشین بردار پشتیبان خطای کمتری نسبت به دو روش دیگر دارد و از سرعت و دقت بالاتری برخوردار است. Ahmadi و همکاران (۲۰۱۴)، در پژوهشی از روش برنامه‌ریزی بیان ژن و ماشین بردار پشتیبان به‌منظور پیش‌بینی جریان روزانه رودخانه باراندوزچای استفاده کردند که نتایج نشان داد، هر دو مدل دارای دقت قابل قبول در برآورد میزان دبی هستند و دقت روش GP از روش SVM اندکی بیشتر می‌باشد. این پژوهشگران در پژوهشی دیگر، برای برآورد میزان آبدهی روزانه رودخانه شهرچای از دو

شبکه‌های بیزین به حفاظت و مدیریت کمی و کیفی آب شرب استحصالی از منابع آب زیرزمینی در دانمارک پرداختند. در این پژوهش منابع آب زیرزمینی منطقه تحت تأثیر منابع آلوده کننده نقطه-ای و منابع پراکنده (مانند آفت‌کش‌ها و سموم کشاورزی) بود. نتایج نشان داد که کاربرد شبکه‌های بیزین به‌عنوان یک ابزار تصمیم‌گیری در مدیریت منابع آب زیرزمینی موجود بسیار مؤثر است. در تحقیقی دیگر، Dorner و همکاران (۲۰۰۷) نیز با استفاده از شبکه‌های بیزین یک مدل چند هدفه در زمینه مدل‌سازی آلودگی غیر نقطه‌ای و اتخاذ تصمیمات لازم در همین رابطه در منطقه انتاریو کانادا ارائه کردند. در این پژوهش، مسئله منابع آلودگی غیر نقطه‌ای کشاورزی با رویکردهای اقتصادی ترکیب شده است و ساختار یک مدل فیزیکی در خلال یک شبکه بیزین ارائه شده است. Nikoo و Karachian (۲۰۰۹) نیز با توجه به جهت یک‌طرفه جریان آب در رودخانه، از سامانه نسبت-تجارت و شبکه‌های بیزین به‌منظور تهیه یک مدل مدیریت کیفی رودخانه در زمان واقعی استفاده کردند و از نتایج حاصل از سامانه نسبت-تجارت برای آموزش شبکه بیزین استفاده شد. نتایج این پژوهش نشان داد که تلفیق تحلیل عدم قطعیت مونت کارلو، روش سامانه نسبت-تجارت و شبکه بیزین نسبت به مدل کلاسیک سامانه نسبت-تجارت از کارایی بالاتری در مدیریت کیفی سامانه رودخانه‌ای برخوردار است. Reggiani و Weerts (۲۰۰۸)، با کاربرد شبکه‌های بیزین و با در نظر گرفتن عدم قطعیت‌های موجود به پیش‌بینی تراز سطح آب در سامانه پیش‌بینی جریان رودخانه راین پرداختند. در این پژوهش، با ترکیب یک تابع هزینه در مدل برای برآورد ارزش اقتصادی ارسال هشدار سیلاب، می‌توان خسارت ناشی از هر تراز سطح آب پیش‌بینی شده را تعیین کرد و به‌کمک این روش با یک ریسک قابل قبول می‌توان خسارت ناشی از هر تراز سطح آب پیش‌بینی شده را تعیین کرد. نتایج نشان داد که با بهره‌گیری از این روش، تصمیم‌گیری در شرایط عدم قطعیت برای پیش‌بینی جریان رودخانه تسهیل می‌شود. Madadgar و Moradkhani (۲۰۱۴)، برای بررسی تغییرات مکانی خشکسالی و توسعه مدلی بر

مواد و روش‌ها

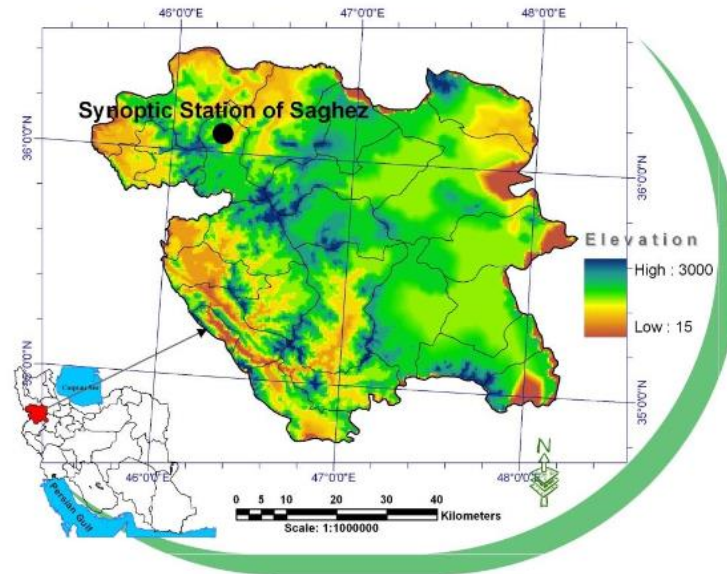
منطقه مورد پژوهش: در این پژوهش، به بررسی خشکسالی در ایستگاه سینوپتیک سقز که یکی از ایستگاه‌های شاخص در جنوب حوزه آبخیز دریاچه ارومیه می‌باشد، پرداخته شده است. بدین‌منظور، از داده‌های بلندمدت بارندگی و دمای ماهانه این ایستگاه در یک دوره آماری ۴۸ ساله مربوط به سال‌های ۲۰۰۹-۱۹۶۱ به‌علت کفایت داده‌ها و کامل بودن آن‌ها استفاده شده که از سازمان هواشناسی ایران دریافت شده است. این ایستگاه در طول جغرافیایی $۱۷^{\circ} ۴۶'$ شرقی و عرض جغرافیایی $۵^{\circ} ۳۸'$ شمالی واقع شده است. در شکل ۱، موقعیت ایستگاه سینوپتیک سقز نشان داده شده است.

شاخص SPEI: این شاخص مبتنی بر محاسبه ترازمندی آب اقلیمی بوده و برای محاسبه آن به داده‌های ماهانه بارندگی و دمای هوا نیاز است. معادله ترازمندی آب اقلیمی به‌صورت رابطه (۱) تعریف شده است.

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

که در آن، P و PET به‌ترتیب بارندگی و تبخیر و تعرق پتانسیل، D اختلاف آن‌ها و i شماره ماه مورد نظر است. معادلات مختلفی برای محاسبه PET وجود دارد که در استفاده از هر یک از آن‌ها محدودیتی برای SPEI وجود ندارد. در نسخه نخست SPEI از روش ساده Thorntwaite (۱۹۴۸) استفاده شد، ولی در نسخه دوم آن (در صورت عدم محدودیت داده) توصیه شده است که از روش پنمن-مانتیت فائو (Allen و همکاران، ۱۹۹۸) استفاده شود. پس از محاسبه مقادیر D ، از رهیافتی همانند شاخص SPEI برای محاسبه SPEI استفاده می‌شود. برای این منظور، ابتدا مجموع مقادیر متوالی سری D در پنجره‌های زمانی مختلف محاسبه می‌شود. اگر x سری تجمعی D در پنجره زمانی معین باشد، در مرحله بعد یک توزیع احتمال مناسب بر سری x برازش می‌یابد. طبق بررسی‌های Vicente-Serrano و همکاران (۲۰۱۰) توزیع لوگ لجستیک سه پارامتری کارایی مناسبی در مدل‌سازی سری x دارد. فرم تابع چگالی احتمال توزیع مذکور به‌صورت زیر بیان شده است.

روش شبکه بیزین و برنامه‌ریزی ژنتیک استفاده کردند. نتایج این پژوهش نشان داد که روش برنامه‌ریزی ژنتیک نسبت به روش شبکه بیزین از دقت بالاتری برخوردار است و همچنین، این روش در تخمین دی‌های کمینه و متوسط به‌مراتب بهتر از روش شبکه‌های بیزین عمل می‌کند (Ahmadi و همکاران، ۲۰۱۶). Nikbakht Shabazi (۲۰۰۸)، برای پیش‌بینی شاخص SPI در حوزه سدهای طالقان و ماملو از روش SVM استفاده کردند. نتیجه این پژوهش نشان داد، روش SVM دارای دقت مناسب در پیش‌بینی شاخص SPI می‌باشد. Adamowski و Prasher (۲۰۱۲)، در مطالعه‌ای به بررسی تأثیرگذاری روش‌های شبکه عصبی مصنوعی، رگرسیون بردار پشتیبان و شبکه عصبی-موجکی در پیش‌بینی شاخص‌های SPI3 و SPI2 در حوزه رودخانه آواش در اتیوپی پرداختند. ارزیابی عملکرد روش‌های مورد مطالعه نشان داد که روش عصبی-موجکی پیش‌بینی‌های دقیق‌تری از نمایه‌های خشکسالی ارائه کرده است. Samadianfard و Asadi (۲۰۱۷)، برای پیش‌بینی شاخص SPI در ایستگاه سینوپتیک تبریز از روش‌های رگرسیون بردار پشتیبان و خطی چندگانه استفاده کردند. نتایج این پژوهش نیز حاکی از دقت مناسب هر دو روش در پیش‌بینی شاخص مذکور می‌باشد. یکی از نمودهای بارز خشکسالی در سطح ایران مسئله مربوط به دریاچه ارومیه می‌باشد که طی سال‌های اخیر با کاهش شدید ورودی‌های آبی و تراز مواجه شده است که یکی از علل اصلی آن را به خشکسالی‌های سال‌های اخیر نسبت می‌دهند. لذا، آگاهی از وضعیت خشکسالی در این حوزه و پیش‌بینی شرایط آبی آن با استفاده از مدلی که دارای دقت مناسب باشد، از اهمیت ویژه‌ای برخوردار است. در این پژوهش، وضعیت خشکسالی ایستگاه سینوپتیک سقز به‌عنوان یکی از ایستگاه‌های شاخص بخش جنوبی دریاچه ارومیه با استفاده از شاخص SPEI مورد بررسی و سپس، با استفاده از دو روش ماشین بردار پشتیبان و شبکه بیزین نسبت به پیش‌بینی خشکسالی در این ایستگاه در مقیاس‌های زمانی مختلف شاخص مذکور اقدام می‌شود و کارایی این دو روش مورد مقایسه و بررسی قرار می‌گیرد.



شکل ۱- نقشه توپوگرافی استان کردستان و موقعیت ایستگاه سینوپتیک سقز

شاخص SPEI مطابق رابطه (۷) استخراج می‌شود.

$$F(x) = \left[1 + \left(\frac{\alpha}{x - \gamma} \right)^\beta \right]^{-1} \quad (۶)$$

$$SPEI = W - \frac{C_0 + C_1W + C_2W^2}{1 + d_1W + d_2W^2 + d_3W^3} \quad (۷)$$

که در آن، $C_0, C_1, C_2, d_1, d_2, d_3$ مقادیر ثابت معادله SPEI می‌باشد و W از رابطه (۸) به دست می‌آید.

$$W = \sqrt{-2 \ln(P)} \quad \text{for } P \leq 0.5 \quad (۸)$$

و اگر $P > 0.5$ آن‌گاه عبارت $P = 1 - F(x)$ در معادله (۸) جایگزین P می‌شود. این شاخص می‌تواند برای پایش دوره‌های خشک و مرطوب مورد استفاده قرار گیرد. خشکسالی زمانی شروع می‌شود که مقادیر شاخص به منفی یک برسد و با مثبت شدن آن خاتمه می‌یابد. طبقه‌بندی این شاخص در جدول ۱ نشان داده شده است.

$$f(x) = \frac{\beta}{\alpha} \left(\frac{x - \gamma}{\alpha} \right)^{\beta-1} \left[1 + \left(\frac{x - \gamma}{\alpha} \right)^\beta \right]^{-2} \quad (۲)$$

که در آن، α, β و γ به ترتیب پارامترهای مقیاس، شکل و مبدأ و x سری تجمعی مقادیر D در پنجره زمانی معین است. پارامترهای این تابع با استفاده از روش L-گشتاور (Hosking, ۲۰۰۹) از معادلات زیر به دست می‌آیند.

$$\beta = \frac{2w_1 - w_0}{6w_1 - w_0 - 6w_2} \quad (۳)$$

$$\alpha = \frac{(w_0 - 2w_1)\beta}{\Gamma(1 + \frac{1}{\beta}) \Gamma(1 - \frac{1}{\beta})} \quad (۴)$$

$$\gamma = w_0 - \alpha \Gamma(1 + \frac{1}{\beta}) \Gamma(1 - \frac{1}{\beta}) \quad (۵)$$

که در آن، $\Gamma(\cdot)$ تابع گاما و w_0, w_1, w_2 گشتاورهای وزنی احتمال هستند. بدین ترتیب پس از محاسبه تابع توزیع تجمعی لوگ-لوگستیک مطابق رابطه (۶) و تبدیل آن به توزیع نرمال استاندارد با استفاده از تقریب Abramowitz و Stegun (۱۹۶۵)،

جدول ۱- طبقه‌بندی شاخص SPEI

طبقات شاخص	توصیف وضعیت
بیشتر از ۲	رطوبت بسیار شدید
۱/۵ تا ۱/۹۹	رطوبت شدید
۱ تا ۱/۴۹	رطوبت متوسط
۰/۹۹ تا -۰/۹۹	نرمال
-۱ تا -۱/۴۹	خشکسالی متوسط
-۱/۹۹ تا -۱/۵	خشکسالی شدید
کمتر از -۲	خشکسالی بسیار شدید

$$\begin{aligned} & \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^N (\alpha_i + \alpha_i^*) \\ & - \frac{1}{2} \sum_{i=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \phi(x_i)^T \cdot \phi(x_j) \\ & \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) = 0 \end{aligned} \quad (11)$$

$$0 \leq \alpha_i \leq C$$

$$0 \leq \alpha_i^* \leq C, \quad i = 1, 2, \dots, N$$

بعد از این که ضرایب لاگرانژ α_i و α_i^* تعیین شدند، می‌توان بردارهای پارامتر w و b را تحت شرایط KKT³ تعیین کرد که در آن $w = \sum_{i=1}^N \phi(x_i) \cdot (\alpha_i - \alpha_i^*)$ با توجه به این که ترم‌های لاگرانژ $(\alpha_i - \alpha_i^*)$ می‌تواند مقادیر صفر و غیر صفر را لحاظ کنند، بنابراین، تنها مجموعه داده‌هایی که ضرایب α_i آن‌ها غیر صفر باشد، در معادله نهایی وارد می‌شوند که به آن‌ها بردارهای پشتیبان می‌گویند. تابع SVM رگرسیونی به صورت رابطه (۱۲) بیان می‌شود (Yu و همکاران، ۲۰۰۶).

$$f(x) = \sum_{i=1}^N \alpha_i \cdot \phi(x_i)^T \cdot \phi(x) + b \quad (12)$$

محاسبه $\phi(x)$ در فضای مشخصه آن ممکن است، بسیار پیچیده باشد. برای حل این مشکل از تابع کرنل در مدل SVM رگرسیونی استفاده می‌شود. در این پژوهش از سه تابع هسته‌ای مختلف شامل خطی (Linear)، چند جمله‌ای (Polynomial) و پایه شعاعی (RBF) استفاده شده است که مشخصات آن‌ها در جدول ۲ ارائه شده است.

شبکه بیزین: یک مدل گرافیکی احتمالاتی است که مجموعه‌ای از متغیرها و احتمالات مرتبط به هر کدام را نشان می‌دهد. این شبکه، یک گراف مستقیم و غیرچرخه‌ای است که در آن گره‌ها در حکم متغیرهای مسئله هستند. شبکه‌های بیزین محدودیتی در نمایاندن متغیرهای تصادفی ندارند. ساختار یک شبکه بیزین در واقع یک نمایش گرافیکی از اثرات متقابل متغیرهایی است که باید مدل شوند و علاوه بر این که کیفیت رابطه بین متغیرهای مسئله را نشان می‌دهد، کمیت ارتباط بین این متغیرها را نیز به نمایش می‌گذارد که به صورت عددی از توزیع احتمال مشترک آن‌ها استفاده می‌کند. شبکه‌های بیزین را با نام‌هایی

ماشین بردار پشتیبان SVM: یک مدل داده‌محور بر پایه یادگیری با نظارت است که در مسائل مربوط به طبقه‌بندی و رگرسیون از آن استفاده می‌شود و مبنای آن تئوری جداسازی خطی می‌باشد. رویکرد SVM به این صورت است که در فاز آموزش، سعی می‌شود که مرز تصمیم‌گیری به گونه‌ای انتخاب شود که کمینه فاصله آن با هر یک از دسته‌های دیگر بیشترین مقدار را به خود بگیرد که این نحوه انتخاب مرز بر اساس نقاطی به نام بردارهای پشتیبان انجام می‌شود. در مدل رگرسیونی SVM، تابعی از متغیر وابسته Y که خود تابعی از چندین متغیر مستقل x می‌باشد، مورد تخمین واقع می‌شود. فرض می‌شود که رابطه بین متغیرهای وابسته و مستقل مطابق رابطه (۹) با تابع جبری $f(x)$ به علاوه مقداری اغتشاش تحت عنوان خطای مجاز (ε) تعریف می‌شود.

$$Y = f(x) + noise$$

$$f(x) = w^T \cdot \phi(x) + b \quad (9)$$

که در آن، w بردار ضرایب و b ثابت مشخصه‌های تابع رگرسیونی و ϕ نیز تابع هسته‌ای می‌باشد. هدف از رابطه فوق جستجو برای تعیین فرم تابع $f(x)$ می‌باشد که بدین‌منظور با استفاده از داده‌هایی که برای آموزش مدل لحاظ می‌شوند، این امر محقق می‌شود و این روند با بهینه‌سازی متوالی تابع خطا همراه خواهد بود. برای محاسبه‌ی متغیرهای w و b بایستی تابع خطا در رابطه (۱۰) با لحاظ کردن قیود زیر به سمت کمترین مقدار خود بهینه شود (Hamel، ۲۰۱۱).

$$\begin{aligned} & \text{Minimize } \frac{1}{2} w^T \cdot w + c \sum_{i=1}^n \xi_i + c \sum_{i=1}^n \xi_i \\ & w^T \cdot \phi(x_i) + b - Y_i \leq \varepsilon + \xi_i \\ & Y_i - w^T \cdot \phi(x_i) - b \leq \varepsilon + \xi_i \\ & \xi_i, \xi_i \geq 0, \quad i = 1, \dots, N \end{aligned} \quad (10)$$

که در آن، c ثابت گنجایش^۱، ξ_i, ξ_i ضرایب کمبود^۲ که حد بالا و پایین خطای آموزش مرتبط با مقدار خطای مجاز ε را تعیین می‌کنند، است. با استفاده از ضرایب لاگرانژ α_i و α_i^* مسئله بهینه‌سازی با سادگی بیشتری در فرم دوگانه به‌وسیله کاربرد الگوریتم برنامه‌نویسی درجه دوم مطابق رابطه (۳) حل شود.

¹ Capacity constant

² Slack variables

³ Karush-Khuan-Tucker

بوده، تنها بخشی از داده‌ها که به‌وسیله این توزیع احتمالاتی تولید شده‌اند، در دسترس است، مورد استفاده قرار می‌گیرد. در صورتی که مجموعه داده‌های مشاهداتی به‌صورت $X = \{x_1, x_2, \dots, x_m\}$ و با فرض مستقل از هم بوده، مجموعه داده‌های نامرئی به‌صورت $Z = \{z_1, z_2, \dots, z_m\}$ و کل داده‌ها به‌صورت $Y = X \cup Z$ باشد، الگوریتم EM با فرض بیشینه نزدیکی (ML) تبدیل به h' می‌شود، به‌نحوی که $P(Y|h')$ بیشینه شود، در این صورت این الگوریتم برای تخمین توزیع احتمالی روی Y به‌جای پارامترهای واقعی (Θ) از فرض فعلی h استفاده می‌کند. تابع $Q(h|h')$ به‌نحوی تعریف می‌شود که $E(\ln P(Y|h'))$ به‌صورت تابعی از h' تبدیل شود. لذا با فرض، $h = \Theta$ و این‌که داده‌های X بخشی از کل داده‌های مشاهداتی (Y) می‌باشد، نتیجه خواهد شد (Neapolitan, ۲۰۰۳).

چون شبکه‌های تصمیم، شبکه‌های تصادفی، نمودارهای تأثیر و شبکه‌های بیز نیز می‌خوانند. این روش بر مبنای محاسبات احتمالات وابسته (قانون بیز) می‌باشد. آموزش شبکه بیزین شامل دو مرحله آموزش ساختاری و پارامتری می‌باشد. در بخش آموزش ساختاری فضای ممکن شکل ارتباطات با توجه به داده‌های مورد استفاده مشخص می‌شود که در این پژوهش از روش شرط مسیر (PC) استفاده شده است. در بخش آموزش پارامتری تخمین توزیع‌های احتمالاتی شرطی (Θ) مدنظر می‌باشد که بدین‌منظور نخست یک توزیع یکنواخت اولیه بر پارامترهای ناشناخته برازش داده شده، سپس مقادیر (Θ) با روش بیشینه درست‌نمایی داده‌های مورد استفاده مشخص می‌شود که برای این بخش نیز در این پژوهش از روش تخمین بیشینه (EM) استفاده شده است. الگوریتم EM در مواردی که هدف تخمین مجموعه‌ای از پارامترهای (Θ) که مبتنی بر یک توزیع احتمالاتی

جدول ۲- مشخصات توابع هسته‌ای در روش SVM

توابع هسته‌ای	رابطه ریاضی	پارامترهای مورد نیاز
خطی	$\phi(x_i, x_j) = x_i^T \cdot x_j$	C
چند جمله‌ای	$\phi(x_i, x_j) = (x_i^T \cdot x_j + \epsilon)^d$	درجه (d)، C، ضریب ثابت t
پایه شعاعی	$\phi(x_i, x_j) = \exp\left(-\frac{\ x_i - x_j\ ^2}{\sigma^2}\right)$	$C \cdot \sigma^2$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_i - \hat{Q}_i| \quad (۱۶)$$

$$RMSE = \left(\frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{n} \right)^{0.5} \quad (۱۷)$$

که در آن‌ها، Q_i مقدار داده مشاهداتی در گام زمانی t ام، \hat{Q}_i مقدار داده پیش‌بینی شده در همان زمان، n تعداد داده‌ها، \bar{Q}_i میانگین مقادیر مشاهداتی و $\bar{\hat{Q}}_i$ میانگین مقادیر پیش‌بینی شده می‌باشد. هر چه مقادیر R به یک نزدیک‌تر باشد و RMSE و MAE به صفر نزدیک‌تر باشد، نتایج دقیق‌تر و قابل اعتمادتر می‌باشد.

نتایج و بحث

پایش خشکسالی: به‌منظور پایش خشکسالی در ایستگاه سقز، شاخص SPEI در مقیاس‌های زمانی ۴۸،

$$Q(h|h') = E[\ln P(Y|h')|h, X] \quad (۱۳)$$

مراحل الگوریتم EM به‌صورت زیر می‌باشد.

گام ۱ مرحله تخمین (E): با استفاده از مقدار فرض فعلی h و داده‌های مشاهداتی X مقدار $Q(h|h')$ را محاسبه می‌کند تا توزیع احتمالی روی Y تخمین زده شود.

گام ۲ مرحله بیشینه‌سازی (M): فرض h را با فرض h' جایگزین می‌کند تا تابع Q بیشینه شود.

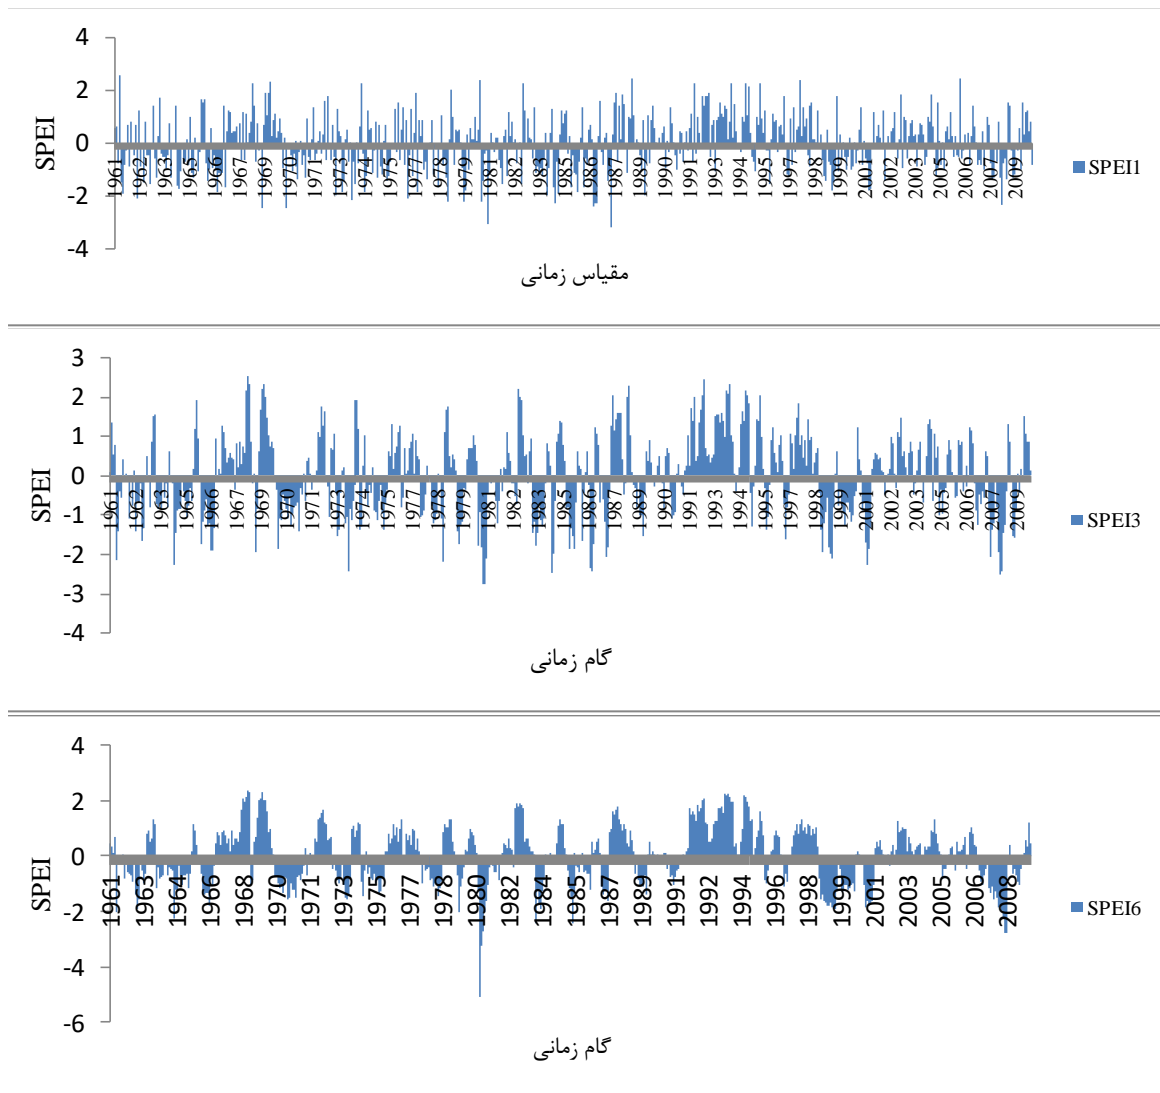
$$\max_{h \rightarrow h'} Q(h|h') \quad (۱۴)$$

معیارهای ارزیابی: در این پژوهش به‌منظور ارزیابی مدل‌های مورد نظر از معیارهای ضریب همبستگی، میانگین قدر مطلق خطا و جذر میانگین مربعات خطا استفاده می‌شود که روابط آن‌ها به‌شرح زیر است.


$$R = \frac{\sum_{i=1}^n (Q_i - \bar{Q}_i)(\hat{Q}_i - \bar{\hat{Q}}_i)}{\sqrt{\sum_{i=1}^n (Q_i - \bar{Q}_i)^2 \sum_{i=1}^n (\hat{Q}_i - \bar{\hat{Q}}_i)^2}} \quad (۱۵)$$

۱۹۹۹ و ۲۰۰۷-۲۰۰۹ را تشخیص داد که با خشکسالی‌های تاریخی به‌وقوع پیوسته در سطح منطقه هم‌خوانی دارد. همچنین، با لحاظ شدن عامل دما در تعیین خشکسالی با استفاده از شاخص SPEI و لحاظ کردن اثرات متقابل بارش و دما در این شاخص، شدت خشکسالی افزایش یافته است. به‌عبارت دیگر علاوه بر کاهش بارش در این منطقه، افزایش دما نیز بر وقوع پدیده خشکسالی مزید بر علت شده است که این نتایج با تحقیقات Zarebyaneh و همکاران (۲۰۱۶) و Mostafazadeh و همکاران (۲۰۱۵) مبنی بر لزوم استفاده از سایر عوامل اقلیمی علاوه بر بارش در تعیین خشکسالی مطابقت دارد.

۲۴، ۱۲، شش، سه و یک ماهه محاسبه شد که شکل ۲ نمودار تغییرات این شاخص را در دوره آماری مورد بررسی نشان می‌دهد. بر اساس این نمودار، شاخص SPEI در مقیاس زمانی کوتاه‌مدت دارای تغییرات و نوسانات زیادی است که با افزایش گام زمانی محاسبه SPEI از میزان این نوسانات کاسته می‌شود. با افزایش مقیاس زمانی محاسبه SPEI تعداد وقوع خشکسالی‌ها کاهش یافته، اما تداوم آن‌ها افزایش داشته است. بر اساس شکل ۲ و مقیاس زمانی ۲۴ و ۴۸ ماهه می‌توان هشت دوره طولانی‌مدت خشکسالی مربوط به سال -های ۱۹۶۸-۱۹۶۲، ۱۹۷۴-۱۹۷۲، ۱۹۷۹-۱۹۷۸، ۱۹۸۲-۱۹۸۰، ۱۹۸۴-۱۹۸۳، ۱۹۸۷-۱۹۸۶، ۲۰۰۳-



شکل ۲- سری زمانی شاخص SPEI در مقیاس‌های زمانی مختلف برای ایستگاه سقر



ادامه شکل ۲- سری زمانی شاخص SPEI در مقیاس‌های زمانی مختلف برای ایستگاه سقز

بهینه‌ترین مدل در پیش‌بینی شاخص خشکسالی در مقیاس‌های زمانی مختلف انتخاب شد. در مدل ۱، برای پیش‌بینی شاخص SPEI در ماه بعد از سری زمانی SPEI در ماه جاری استفاده شد. در مدل ۲ پیش‌بینی شاخص در ماه بعد بر اساس مقادیر شاخص تا یک ماه قبل صورت پذیرفت و به‌طور مشابه در مدل ۳، ۴ و ۵ پیش‌بینی بر اساس مقادیر شاخص تا دو، سه و چهار ماه قبل انجام شد.

پیش‌بینی خشکسالی: در مدل‌های پیش‌بینی تعیین بهترین الگوی ورودی برای آموزش مدل سبب افزایش عملکرد و دقت این مدل‌ها می‌شود، لذا، ابتدا باید بهترین الگوی ورودی به مدل پیش‌بینی خشکسالی مشخص شود. از بین الگوهای مختلف، الگویی که بهترین کارایی را ایجاد می‌کند، به‌عنوان مناسب‌ترین الگوی ورودی در نظر گرفته می‌شود. به‌منظور پیش‌بینی خشکسالی پنج مدل مختلف مورد استفاده قرار گرفت. سپس بر اساس معیارهای ارزیابی

$$1 \text{ مدل: } SPEI_{(t+1)} = f(SPEI_{(t)}) \quad (18)$$

$$2 \text{ مدل: } SPEI_{(t+1)} = f(SPEI_{(t)}, SPEI_{(t-1)}) \quad (19)$$

$$3 \text{ مدل: } SPEI_{(t+1)} = f(SPEI_{(t)}, SPEI_{(t-1)}, SPEI_{(t-2)}) \quad (20)$$

$$4 \text{ مدل: } SPEI_{(t+1)} = f(SPEI_{(t)}, SPEI_{(t-1)}, SPEI_{(t-2)}, SPEI_{(t-3)}) \quad (21)$$

$$SPEI_{(t+1)} = f(SPEI_{(t)}, SPEI_{(t-1)}, SPEI_{(t-2)}, SPEI_{(t-3)}, SPEI_{(t-4)}) \quad (22)$$

شناسایی رابطه ریاضی بین ورودی و خروجی مدل شد، که بر اساس این می‌توان داده‌های مربوط به شاخص SPEI را به صورت مصنوعی تولید کرده، عملکرد مدل را ارزیابی کرد. در خاتمه با استفاده از معیارهای ارزیابی مختلف عملکرد مدل پیش‌بینی مورد مقایسه قرار می‌گیرد و مدل برتر بر اساس آماره‌های ارزیابی انتخاب می‌شود. برای ایجاد شبکه بیزین در این پژوهش از نرم‌افزار GeNIe استفاده شد. مدل مفهومی مربوط به ساختار شبکه بیزین مورد استفاده در این پژوهش به عنوان نمونه برای مدل ۵ شاخص SPEI48 در شکل ۳ نشان داده شده است. در این ساختار، جهت بردارها نشانگر ارتباط یک متغیر با تأخیر مورد نظر با متغیر دیگر می‌باشد.

در جدول ۳، نتایج مربوط به الگوهای مختلف ورودی شبکه بیزین در مقیاس‌های زمانی مختلف شاخص SPEI در دو مرحله آموزش و آزمون نشان داده شده است. بر اساس آماره‌های ارزیابی موجود در این جدول، مشخص می‌شود که در مقیاس زمانی کوتاه مدت عملکرد شبکه بیزین مناسب نبوده، با افزایش مقیاس زمانی شاخص مذکور میزان عملکرد شبکه بیزین نیز افزایش پیدا کرده، عملکرد مدل پیش‌بینی با مقیاس زمانی شاخص SPEI رابطه مستقیم دارد. در مقیاس زمانی ۴۸ ماهه در مرحله آزمون مدل ۵ با ضریب همبستگی، RMSE و MAE به ترتیب ۰/۹۸۵، ۰/۰۶۴ و ۰/۰۴۳ بهترین عملکرد را داشته است. همچنین، بر اساس آماره‌های ارزیابی بهترین مدل برای پیش‌بینی در کلیه مقیاس‌های زمانی مدل ۵ است، ولی با توجه به این که در سایر مدل‌ها نیز دقت پیش‌بینی نسبت به مدل ۵ تفاوت چندانی ندارد، لذا برای مقیاس‌های زمانی مختلف نیازی به تأخیرهای بالا جهت ورودی به شبکه بیزین وجود ندارد و با یک تأخیر شاخص SPEI نیز می‌توان دقت قابل قبول در پیش‌بینی این شاخص را به دست آورد.

از میان داده‌های شاخص SPEI با بازه‌های زمانی مختلف در طی دوره آماری ۵۳ ساله، ۸۰ درصد داده‌ها برای واسنجی مدل و ۲۰ درصد بقیه برای صحت-سنجی مدل استفاده شد. بر این اساس ابتدا برای هر بازه زمانی، داده‌های شاخص مطابق رابطه زیر نرمال شده، سپس شاخص‌های ماه‌های گذشته به عنوان ورودی و شاخص ماه آتی به عنوان خروجی در مدل SVM و BN مورد استفاده قرار گرفت.


$$Y_i = \frac{X_{oi}}{X_o \max}, X_{oi} \geq 0 \quad (23)$$

$$Y_i = \frac{X_{oi}}{|X_o \min|}, X_{oi} < 0 \quad (24)$$

که در آن‌ها، Y_i مقادیر استاندارد شده شاخص، X_{oi} مقادیر شاخص مشاهداتی، $X_o \max$ بیشینه مقدار شاخص مشاهداتی و $X_o \min$ کمینه مقدار شاخص مشاهداتی می‌باشد. در ادامه با در دست بودن سری زمانی شاخص SPEI اقدام به پیش‌بینی خشکسالی با استفاده از روش‌های ماشین بردار پشتیبان و شبکه بیزین شد که نتایج آن‌ها به تفکیک در زیر ارائه شده است.

نتایج پیش‌بینی خشکسالی با استفاده از شبکه

بیزین: در این پژوهش با فرض وابستگی شاخص SPEI به مقادیر قبلی خود و انتخاب الگوریتم PC با سطح معنی‌داری پنج درصد ساختار شبکه با توجه به تأثیر پارامترها بر روی یکدیگر و پنج مدل ورودی در مقیاس‌های زمانی مختلف ایجاد شد. برای ایجاد و توسعه شبکه بیزین نخست چارچوب آن به معنی تعریف متغیرها و بررسی روابط موجود بین آن‌ها بر اساس یک مدل مفهومی ایجاد شد و سپس، نوع ارتباط بین متغیرهای مختلف در شبکه که در این پژوهش مقادیر شاخص در یک ماه آینده متأثر از مقادیر شاخص با تأخیرهای زمانی مختلف می‌باشد، تعیین شد. در ادامه آموزش شبکه و به دست آوردن رابطه بین متغیرها مورد بررسی قرار گرفت که در این مرحله با استفاده از مقادیر شاخص SPEI با تأخیرهای زمانی مختلف به عنوان ورودی شبکه بیزین سعی در



شکل ۳- مدل مفهومی ساخته شده برای شبکه بیزین

جدول ۳- نتایج شبکه بیزین در مقیاس‌های زمانی مختلف شاخص SPEI

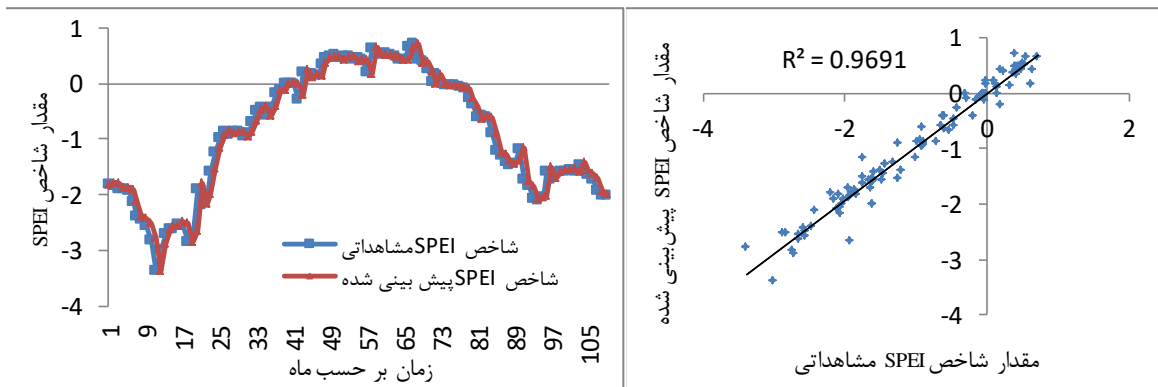
دوره آزمون			دوره آموزش			مدل	مقیاس زمانی
MAE	RMSE	R	MAE	RMSE	R		
۰/۲۵۷۹	۰/۳۱۴۶	۰/۱۵۳	۰/۲۹۹	۰/۳۶۷	۰/۱۹۷	۱	
۰/۲۵۷۱	۰/۳۱۳۸	۰/۱۶۵	۰/۲۹۸۴	۰/۳۶۴	۰/۲۳	۲	
۰/۲۵۶۶	۰/۳۱۳۵	۰/۱۷۱	۰/۲۹۸۳	۰/۳۶۳۷	۰/۲۳۱	۳	۱
۰/۲۵۶۷	۰/۳۱۳۳	۰/۱۷۳	۰/۲۹۸۱	۰/۳۶۳۵	۰/۲۳۲	۴	
۰/۲۵۷۴	۰/۳۱۳۱	۰/۱۷۴	۰/۲۹۸	۰/۳۶۳	۰/۲۳۸	۵	
۰/۱۸۹۸	۰/۲۴۹۷	۰/۶۶۲۵	۰/۲۲۱۳	۰/۲۸۶	۰/۷۱۳۷	۱	
۰/۱۸۹	۰/۲۴۵۹	۰/۶۷۵۴	۰/۲۱۹۳	۰/۲۸۲	۰/۷۲۱۹	۲	
۰/۱۸۰۶	۰/۲۴۰۷	۰/۶۹۲۲	۰/۲۱۶۶	۰/۲۷۸	۰/۷۳۱۸	۳	۳
۰/۱۷۶۱	۰/۲۳۲۷	۰/۷۱۶۱	۰/۲۰۳۷	۰/۲۶۴۷	۰/۷۶۱۴	۴	
۰/۱۷۶۱	۰/۲۳۳۵	۰/۷۱۶۸	۰/۲۰۳۹	۰/۲۶۴۵	۰/۷۶۱۷	۵	
۰/۱۰۲۸	۰/۱۳۷۹	۰/۸۰۲	۰/۱۲۴۶	۰/۱۷۸۱	۰/۸۵۶۴	۱	
۰/۱۰۲۶	۰/۱۳۷۷	۰/۸۰۲۱	۰/۱۲۵۱	۰/۱۷۷۹	۰/۸۵۶۸	۲	
۰/۱۰۲۵	۰/۱۳۷۶	۰/۸۰۲۳	۰/۱۲۵	۰/۱۷۷۶	۰/۸۵۷۶	۳	۶
۰/۱۰۱۸	۰/۱۳۷۳	۰/۸۰۲۴	۰/۱۲۴۵	۰/۱۷۷۴	۰/۸۵۸۲	۴	
۰/۱۰۲۱	۰/۱۳۷۱	۰/۸۰۲۵	۰/۱۲۴۴	۰/۱۷۷۱	۰/۸۵۹	۵	
۰/۰۸۹۱	۰/۱۲۶۹	۰/۹۳۳	۰/۰۹۵۷	۰/۱۴۱۴	۰/۹۴۴	۱	
۰/۰۸۸	۰/۱۲۶۷	۰/۹۳۴	۰/۰۹۵۵	۰/۱۴۰۸	۰/۹۴۵	۲	
۰/۰۸۷۶	۰/۱۲۶۶	۰/۹۳۴	۰/۰۹۵۴	۰/۱۴	۰/۹۴۶	۳	۱۲
۰/۰۸۷۳	۰/۱۲۶۴	۰/۹۳۵	۰/۰۹۵۳	۰/۱۳۹۸	۰/۹۴۶	۴	
۰/۰۸۷۳	۰/۱۲۶۳	۰/۹۳۶	۰/۰۹۵۳	۰/۱۳۹۷	۰/۹۴۶۱	۵	
۰/۰۵۷۹	۰/۰۸۰۳	۰/۹۷۹۱	۰/۰۶۴۲	۰/۰۹۷۹	۰/۹۷۱	۱	
۰/۰۵۸	۰/۰۸۰۳	۰/۹۷۹۲	۰/۰۶۳۱	۰/۰۹۷۶	۰/۹۷۲	۲	
۰/۰۵۷۱۴	۰/۰۷۹۹	۰/۹۷۹۳	۰/۰۶۲۹	۰/۰۹۷	۰/۹۷۲	۳	۲۴
۰/۰۵۷	۰/۰۷۹۸	۰/۹۷۹۵	۰/۰۶۲۷	۰/۰۹۷	۰/۹۷۲۵	۴	
۰/۰۵۷	۰/۰۷۹۷	۰/۹۷۹۶	۰/۰۶۲۴	۰/۰۹۶۸	۰/۹۷۲۸	۵	
۰/۰۴۴۸	۰/۰۶۴۸	۰/۹۸۳	۰/۰۴۳۲	۰/۰۶۴۷	۰/۹۸۴	۱	
۰/۰۴۴۷	۰/۰۶۴۲	۰/۹۸۴	۰/۰۴۳	۰/۰۶۴۳	۰/۹۸۴۱	۲	
۰/۰۴۴	۰/۰۶۴۱	۰/۹۸۴	۰/۰۴۲۸	۰/۰۶۴۳	۰/۹۸۴۲	۳	۴۸
۰/۰۴۳	۰/۰۶۴۱	۰/۹۸۵	۰/۰۴۲۷	۰/۰۶۴۲	۰/۹۸۴۳	۴	
۰/۰۴۳	۰/۰۶۴	۰/۹۸۵	۰/۰۴۲۶	۰/۰۶۴۲	۰/۹۸۴۵	۵	

در شکل ۴، سری زمانی و پراکنش مقادیر مشاهداتی و پیش‌بینی شده شاخص SPEI برای مقیاس زمانی ۴۸ ماهه به‌عنوان نمونه در مرحله آزمون ارائه شده است که نشانگر دقت بالای مدل BN در پیش‌بینی شاخص SPEI در مقیاس زمانی بلندمدت می‌باشد.

رابطه ریاضی حاصل از مدل برتر برای مقیاس‌های زمانی مختلف در جدول ۴ ارائه شده است که بر اساس رابطه خرجی شبکه بیزین در گام‌های زمانی مختلف نیز مشاهده می‌شود که متغیر شاخص SPEI با یک گام زمانی تأخیر بیشترین ضریب را در معادله ریاضی به خود اختصاص داده است و بیشترین تأثیر را در مدل پیش‌بینی بر عهده دارد.

جدول ۴- رابطه ریاضی حاصل از شبکه بیزین در مقیاس‌های زمانی مختلف شاخص SPEI

مقیاس زمانی شاخص SPEI	مدل برتر	رابطه ریاضی
۱	۵	$SPEI_{t+1} = 0.0526 SPEI_{t-4} + 0.0166 SPEI_{t-3} + 0.00055 SPEI_{t-2} + 0.1141 SPEI_{t-1} + 0.172 SPEI_t$
۳	۵	$SPEI_t = -0.0374 SPEI_{t-4} + 0.3364 SPEI_{t-3} - 0.41 SPEI_{t-2} - 0.02956 SPEI_{t-1} + 0.8623 SPEI_t$
۶	۵	$SPEI_t = -0.0698 SPEI_{t-4} - 0.0019 SPEI_{t-3} - 0.0149 SPEI_{t-2} + 0.01209 SPEI_{t-1} + 0.88699 SPEI_t$
۱۲	۵	$SPEI_t = -0.0695 SPEI_{t-4} + 0.064 SPEI_{t-3} - 0.1016 SPEI_{t-2} + 0.01352 SPEI_{t-1} + 1.0203 SPEI_t$
۲۴	۵	$SPEI_t = -0.0073 SPEI_{t-4} - 0.0205 SPEI_{t-3} - 0.07252 SPEI_{t-2} + 0.0174 SPEI_{t-1} + 1.045 SPEI_t$
۴۸	۵	$SPEI_t = 0.0201 SPEI_{t-4} - 0.0264 SPEI_{t-3} - 0.0004 SPEI_{t-2} - 0.1049 SPEI_{t-1} + 1.091 SPEI_t$



شکل ۴- نمودارهای سری زمانی و پراکنش مقادیر مشاهداتی و پیش‌بینی شده حاصل از بهترین مدل شبکه بیزین در مقیاس زمانی ۴۸ ماهه در مرحله آزمون

دقت هر کدام از آن‌ها در پیش‌بینی شاخص موصوف مورد بررسی قرار گیرد. هر کدام از پارامترهای بهینه مربوط به کرنل‌های مختلف با استفاده از کدنویسی در محیط نرم‌افزار MATLAB و روش آزمون و خطا تعیین شد که در جدول ۵ مشخصات روش SVM با توابع هسته‌ای مختلف ارائه شده است. در جدول ۵ مشخصات مربوط به مدل SVM در مقیاس‌های زمانی و مدل‌های ورودی مختلف و همچنین، نتایج مربوط به ارزیابی آن در مرحله آزمون ارائه شده است. بر اساس این جدول مشاهده می‌شود، در روش SVM نیز با

نتایج پیش‌بینی خشکسالی با استفاده از ماشین بردار پشتیبان: با توجه به این‌که در بسیاری از مطالعات مربوط به داده‌های هیدرولوژیکی تابع هسته‌های RBF به‌عنوان تابع پیش‌فرض و منتخب استفاده شده است، اما در مطالعات دیگر از قبیل Botsis و همکاران (۲۰۱۱) تابع کرنل خطی در مدل‌سازی بارش-رواناب دقت بیشتری داشته است، لذا، در این مطالعه از سه تابع هسته‌ای (کرنل) خطی، چند جمله‌ای و RBF به‌منظور ایجاد روش ماشین بردار پشتیبان در پیش‌بینی شاخص SPEI استفاده شد تا

این جدول همچنین مشاهده می‌شود که با افزایش مقادیر شاخص‌های گذشته به‌عنوان ورودی مدل پیش‌بینی، دقت آن افزایش پیدا می‌کند و در همه توابع هسته‌ای مدل ۵ بهترین عملکرد را داشته است.

افزایش مقیاس زمانی شاخص SPEI دقت عملکرد مدل پیش‌بینی افزایش پیدا می‌کند، به‌نحوی که در مقیاس زمانی ۴۸ ماهه بیشترین دقت و در مقیاس زمانی یک ماهه دارای کمترین دقت می‌باشد. بر اساس

جدول ۵- نتایج مدل SVM در مقیاس‌های زمانی مختلف شاخص SPEI در مرحله آزمون

آماره‌های ارزیابی			پارامترهای مدل SVM					مدل	نوع تابع	مقیاس زمانی SPEI
MAE	RMSE	R	ϵ	degree	t	σ^2	C			
۰/۲۶۴	۰/۳۱۹	۰/۰۵۶	۰/۲	-	-	۷۴۹۲۲/۴۱	۳۷۹/۷۵	۱		
۰/۲۶۶	۰/۳۱۸	۰/۰۱۷	۰/۲	-	-	۰/۳۲۴۶	۰/۰۱۹۲	۲		
۰/۲۶۴	۰/۳۱۹	۰/۰۹۶	۰/۲	-	-	۵/۸۷۴	۰/۲۰۶	۳	RBF	
۰/۲۶۸	۰/۳۲۳	۰/۰۲۹	۰/۳	-	-	۲/۳۶۷	۰/۰۴۴	۴		
۰/۲۶۲	۰/۳۱۸	۰/۱۱۴	۰/۱	-	-	۳/۰۶	۰/۱۵۱۸	۵		
۰/۲۶۴	۰/۳۱۹	۰/۰۵۶	۰/۲	-	-	-	۰/۰۰۸۶	۱		
۰/۲۶۵	۰/۳۱۹	۰/۰۷۰۹	۰/۲	-	-	-	۰/۰۰۳۶	۲		
۰/۲۶۳	۰/۳۱۸	۰/۰۶۴۷	۰/۳	-	-	-	۰/۰۰۱۵	۳	Linear	۱ ماهه
۰/۲۶۳	۰/۳۱۸	۰/۰۳۰۶	۰/۱	-	-	-	۰/۰۰۳۲	۴		
۰/۲۵۸	۰/۳۱۴	۰/۱۴۹	۰/۲	-	-	-	۰/۰۰۶۸	۵		
۰/۲۶۴	۰/۳۱۸	۰/۰۰۵	۰/۳	۳	۱۰۸۶	-	$۷/۷۸ * 10^{-10}$	۱		
۰/۲۶۴	۰/۳۱۸	۰/۰۷۱	۰/۳	۳	۲۰۱۰	-	$۱/۳۸ * 10^{-10}$	۲		
۰/۲۶۳	۰/۳۱۸	۰/۰۶۸	۰/۳	۳	۵۹	-	$۵/۶۴ * 10^{-8}$	۳	Polynomial	
۰/۲۶۲	۰/۳۱۸	۰/۰۳۲	۰/۱	۳	۳۳۴۸	-	$۱/۳۸ * 10^{-10}$	۴		
۰/۲۵۹	۰/۳۱۴	۰/۱۴۵	۰/۱	۳	۱۶/۲	-	$۶/۷۶ * 10^{-6}$	۵		
۰/۲۶۴	۰/۳۳	۰/۱۲۴	۰/۲	-	-	۳۷/۹۷	۶۰۵۸	۱		
۰/۲۶۴	۰/۳۲۹	۰/۱۲۴	۰/۲	-	-	۴/۳۷۶	۰/۰۵۶	۲		
۰/۲۶۹	۰/۳۳۶	۰/۰۰۶	۰/۲	-	-	۳/۹۱۷	۰/۰۲۶	۳	RBF	
۰/۲۴۱	۰/۲۹۹	۰/۶۵۷	۰/۲	-	-	۴/۳۷۶	۶/۱۶	۴		
۰/۱۷۹	۰/۲۳۶	۰/۷۰۶	۰/۲	-	-	۳۷/۹۷	۱۴/۱۵	۵		
۰/۲۶۷	۰/۳۳۸	۰/۰۱۸	۰/۲	-	-	-	۰/۰۱۳	۱		
۰/۲۶۶	۰/۳۳۴	۰/۰۱۶	۰/۲	-	-	-	۰/۰۰۴	۲		
۰/۲۶۶	۰/۲۹۹	۰/۰۰۳	۰/۲	-	-	-	۰/۰۰۶	۳	Linear	۳ ماهه
۰/۲۴۱	۰/۲۳۲	۰/۴۳۹	۰/۴	-	-	-	۰/۲۰۹	۴		
۰/۱۷۵	۰/۲۳	۰/۷۱۷	۰/۴	-	-	-	۰/۸۴۲	۵		
۰/۲۶۴	۰/۳۳	۰/۱۱۸	۰/۴	۶	۰/۳۹۶	-	۰/۱۶۵	۱		
۰/۲۶۶	۰/۳۳۴	۰/۰۱۷	۰/۴	۳	۱۱۷/۵	-	$۸/۲ * 10^{-8}$	۲		
۰/۲۷۲	۰/۳۳۷	۰/۰۰۹	۰/۴	۳	۴/۲۷	-	۰/۰۰۰۳	۳	Polynomial	
۰/۲۴۷	۰/۳۰۵	۰/۴۰۹	۰/۳	۳	۳۶/۲۴	-	$۵/۵ * 10^{-5}$	۴		
۰/۱۷۶	۰/۲۳۴	۰/۷۰۹	۰/۳	۳	۱۵۴/۱	-	$۱/۰۵ * 10^{-5}$	۵		

ادامه جدول ۵- نتایج مدل SVM در مقیاس‌های زمانی مختلف شاخص SPEI در مرحله آزمون

آماره‌های ارزیابی			پارامترهای مدل SVM					مدل	نوع تابع	مقیاس زمانی SPEI
MAE	RMSE	R	ϵ	degree	t	σ^2	C			
۰/۱۷۸	۰/۲۲۴	۰/۲۹۳	۰/۳	-	-	۰/۳۷۵	۸/۴	۱		
۰/۱۷۷	۰/۲۱۴	۰/۴۲۱	۰/۴	-	-	۱/۲۱	۱/۹۸	۲		
۰/۱۶۲	۰/۱۹۶	۰/۸۱۸	۰/۳	-	-	۴۴۳۰/۸	۸۸۳۷/۴	۳	RBF	
۰/۱۴۱	۰/۱۷۶	۰/۵۵۲	۰/۳	-	-	۳/۱۲۸	۷/۴۰۴	۴		
۰/۱۰۴	۰/۱۳۹	۰/۷۹۹	۰/۴	-	-	۷۳/۶	۱۵/۴۴	۵		
۰/۱۰۴	۰/۲۲۴	۰/۳۰۳	۰/۲	-	-	-	۰/۴۲۳	۱		
۰/۱۸	۰/۲۱۳	۰/۴۱۸	۰/۲	-	-	-	۰/۲۰۸	۲		
۰/۱۷۶	۰/۱۹۹	۰/۵۲۹	۰/۲	-	-	-	۰/۲۰۱	۳	Linear	۶ ماهه
۰/۱۶۳	۰/۱۷۹	۰/۷۳۹	۰/۲	-	-	-	۰/۱۱۴	۴		
۰/۱۴۴	۰/۱۳۸	۰/۸۰۲	۰/۳	-	-	-	۰/۲۴۶	۵		
۰/۱۸	۰/۲۲۴	۰/۳۰۳	۰/۳	۳	۶۲۵۵	-	$9/5 * 10^{-21}$	۱		
۰/۱۷۷	۰/۲۱۳	۰/۴۱۵	۰/۳	۳	۲/۲۱	-	۰/۰۱۴	۲		
۰/۱۶۳	۰/۱۹۷	۰/۵۳۹	۰/۳	۳	۳/۴۱	-	۰/۰۰۹	۳	Polynomial	
۰/۱۴۳	۰/۱۷۷	۰/۶۵۱	۰/۳	۳	۳/۶۹	-	۰/۰۰۸۴	۴		
۰/۱۰۴	۰/۱۴	۰/۷۹۸	۰/۳	۳	۱۸/۲	-	۰/۰۰۰۹۷	۵		
۰/۰۲	۰/۲۵۴	۰/۷۲۹	۰/۳	-	-	۳/۸۲	۹/۶۸	۱		
۰/۰۱۷۹	۰/۲۳۵	۰/۷۷۲	۰/۱	-	-	۹۰۷/۹	۱۶۲۰/۸	۲		
۰/۰۱۶۱	۰/۲۱۲	۰/۸۱۶	۰/۱	-	-	۸/۵۹	۴/۲۴	۳	RBF	
۰/۰۱۲۷	۰/۱۷۸	۰/۸۷۳	۰/۱	-	-	۶۵۹۴	۱۳۷۰۰۶	۴		
۰/۰۰۹	۰/۱۲۸	۰/۹۳۵	۰/۱	-	-	۳۴۵۷/۳	۷۵۷۷۲۳	۵		
۰/۰۱۹۵	۰/۲۴۷	۰/۷۴۶	۰/۳	-	-	-	۰/۳۶۶	۱		
۰/۰۱۷۷	۰/۲۳۲	۰/۷۷۵	۰/۳	-	-	-	۰/۵۷	۲		
۰/۱۵۷	۰/۲۱	۰/۸۲	۰/۳	-	-	-	۰/۴۳۷	۳	Linear	۱۲
۰/۰۱۲۶	۰/۱۷۷	۰/۸۷۴	۰/۳	-	-	-	۰/۹۳۴	۴		
۰/۰۰۹	۰/۱۲۷	۰/۹۳۵	۰/۳	-	-	-	۱/۲۱۵	۵		
۰/۰۲	۰/۲۵۶	۰/۷۱۸	۰/۴	۶	۰/۷۸۱	-	۰/۳۵۱	۱		
۰/۰۱۸	۰/۲۳۵	۰/۷۷۱	۰/۴	۳	۲۲۴۹	-	$2/0.7 * 10^{-y}$	۲		
۰/۰۱۶	۰/۲۱۴	۰/۸۰۹	۰/۴	۳	۱/۲۶۵	-	۰/۳۷۱	۳	Polynomial	
۰/۰۱۳	۰/۱۷۷	۰/۸۷۴	۰/۴	۳	۷۴۴/۸	-	$2 * 10^{-y}$	۴		
۰/۰۰۹	۰/۱۲۹	۰/۹۳۵	۰/۴	۳	۹۶۶۰	-	$1/8 * 10^{-y}$	۵		
۰/۱۵۴	۰/۲۰۳	۰/۸۸	۰/۲	-	-	۰/۵۷۹	۴/۹۳	۱		
۰/۱۴۳	۰/۱۸۳	۰/۹۰۹	۰/۳	-	-	۰/۹۹۹	۳/۰۲	۲		
۰/۱۲۹	۰/۱۶۳	۰/۹۳۴	۰/۲	-	-	۱/۸۹	۷/۲۷	۳	RBF	۲۴
۰/۱۱	۰/۱۵۲	۰/۹۳۶	۰/۳	-	-	۱۹/۱۴	۶۷۳/۸	۴		
۰/۰۶	۰/۰۸۲	۰/۹۷۹	۰/۱	-	-	۵۷۹۳/۵	۹۵۳۵/۸	۵		

ادامه جدول ۵- نتایج مدل SVM در مقیاس‌های زمانی مختلف شاخص SPEI در مرحله آزمون

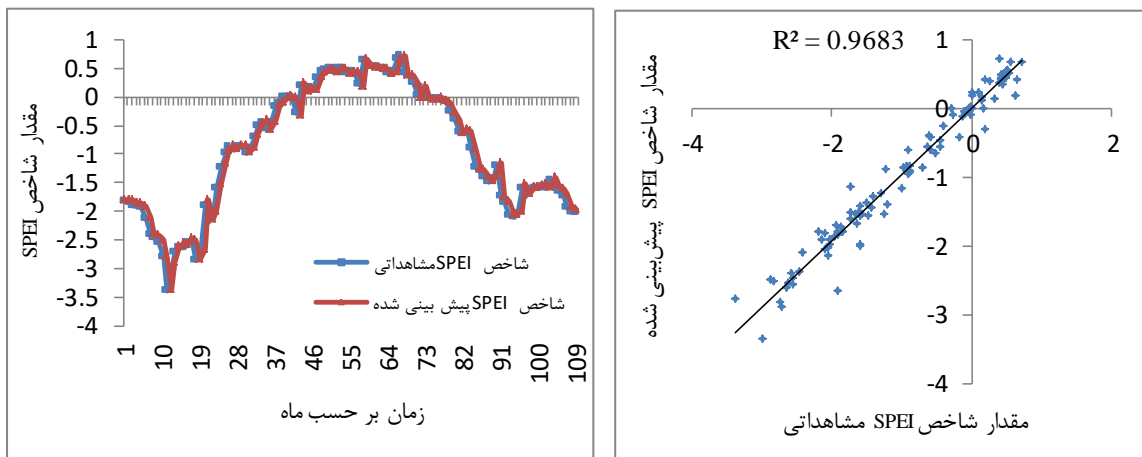
آماره‌های ارزیابی			پارامترهای مدل SVM					مدل	نوع تابع	مقیاس زمانی SPEI
MAE	RMSE	R	ϵ	degree	t	σ^2	C			
۰/۱۳۷	۰/۱۸۸	۰/۸۸۳	۰/۴	-	-	-	۱۲/۴۸	۱	Linear	۲۴
۰/۱۲۳	۰/۱۶۴	۰/۹۱۲	۰/۴	-	-	-	۴/۲۲	۲		
۰/۱۰۴	۰/۱۳۷	۰/۹۴	۰/۲	-	-	-	۱/۲۸۹	۳		
۰/۰۸۳	۰/۱۱۱	۰/۹۶۱	۰/۲	-	-	-	۴/۳۹	۴		
۰/۰۵۷	۰/۰۸	۰/۹۷۹	۰/۱	-	-	-	۶/۵۷	۵		
۰/۱۴۸	۰/۱۹۹	۰/۸۸۳	۰/۱	۳	۵۳۲۴	-	$۱/۰۲ * ۱۰^{-۶}$	۱	Polynomial	
۰/۱۲۷	۰/۱۷۲	۰/۹۱۲	۰/۱	۳	۳۲۹۱	-	$۱/۶۸ * ۱۰^{-۱۰}$	۲		
۰/۱۲۵	۰/۱۶۲	۰/۹۲۷	۰/۲	۳	۲۳۲/۶	-	۰/۰۰۷	۳		
۰/۱۰۲	۰/۱۳۴	۰/۹۵۱	۰/۳	۳	۱۴/۱۹	-	۰/۰۰۱۲	۴		
۰/۰۶۷	۰/۰۸۹	۰/۹۷۷	۰/۳	۳	۲۹/۲۳	-	۰/۰۰۰۴	۵		
۰/۱۷۳	۰/۲۴۵	۰/۸۱۲	۰/۲	-	-	-	۱۴۲۵۸	۱	RBF	
۰/۱۲۴	۰/۱۵۷	۰/۸۹۷	۰/۴	-	-	-	۲۰۵/۴	۲		
۰/۱	۰/۱۲۶	۰/۹۳۴	۰/۳	-	-	-	۳۲۸/۵	۳		
۰/۰۷	۰/۰۹	۰/۹۶۲	۰/۳	-	-	-	۱۷۵/۸	۴		
۰/۰۵	۰/۰۷	۰/۹۸۳	۰/۲	-	-	-	۱۲۷۴/۹	۵		
۰/۱۳۲	۰/۱۶۲	۰/۸۹۴	۰/۳	-	-	-	۴/۴۸	۱	Linear	۴۸ ماهه
۰/۱۱	۰/۱۳۷	۰/۹۲۴	۰/۴	-	-	-	۲/۸	۲		
۰/۰۹	۰/۱۱۴	۰/۹۴۷	۰/۴	-	-	-	۵/۵۴	۳		
۰/۰۷	۰/۰۹۲	۰/۹۶۶	۰/۱	-	-	-	۵/۲۶	۴		
۰/۰۴۵	۰/۰۶۴	۰/۹۸۳	۰/۱	-	-	-	۵/۶۴	۵		
۰/۱۹۶	۰/۳۰۵	۰/۷۷۸	۰/۱	۳	۸/۱۴	-	۰/۰۱۱	۱	Polynomial	
۰/۱۶۵	۰/۲۶۱	۰/۸۳۶	۰/۱	۳	۲/۳۲	-	۰/۰۰۰۷	۲		
۰/۱	۰/۱۲۸	۰/۹۴۹	۰/۱	۳	۸۸۶/۶	-	$۹/۰۴ * ۱۰^{-۷}$	۳		
۰/۰۸	۰/۱	۰/۹۶۶	۰/۲	۴	۱۸۹۷	-	$۳/۳ * ۱۰^{-۷}$	۴		
۰/۰۵	۰/۰۶۷۵	۰/۹۸۳	۰/۲	۴	۴۹۴۳	-	$۲/۸ * ۱۰^{-۶}$	۵		

دقت و عملکرد قرار گرفته‌اند که این نتیجه با پژوهش Botsis و همکاران (۲۰۱۱) مطابقت دارد. در شکل ۵، سری زمانی و پراکنش مقادیر مشاهداتی و پیش‌بینی شده شاخص SPEI برای مقیاس زمانی ۴۸ ماهه به‌عنوان نمونه در مرحله آزمون به‌وسیله روش SVM با تابع هسته‌ای خطی ارائه شده است که بر اساس آن مشخص می‌شود که روش SVM با تابع هسته‌ای خطی در مقیاس زمانی بلندمدت شاخص SPEI دقت و عملکرد مناسبی داشته است. بررسی دو روش شبکه بیزین و SVM نیز نشان می‌دهد، هر دو روش از دقت مناسب در پیش‌بینی شاخص SPEI خصوصاً در مقیاس‌های بلندمدت برخوردار هستند، اما روش BN نسبت به روش SVM در مقیاس‌های زمانی کوتاه‌مدت عملکرد مناسب‌تری

مقایسه توابع هسته‌ای مختلف نیز نشان می‌دهد، هر سه تابع هسته‌ای دارای دقت مناسب در مقیاس‌های زمانی بلندمدت شاخص SPEI هستند، اما با لحاظ کردن معیارهای ارزیابی در همه مقیاس‌های زمانی تابع هسته‌ای خطی دقت نسبتاً بیشتری را داشته است. به‌عنوان نمونه در مقیاس زمانی سه ماهه تابع هسته‌ای خطی با R، RMSE و MAE به‌ترتیب ۰/۱۷۵، ۰/۲۳ و ۰/۷۱۷، در مقیاس زمانی ۱۲ ماهه با R، RMSE و MAE به‌ترتیب ۰/۹۳۵، ۰/۱۲۷ و ۰/۰۰۹ و در مقیاس زمانی ۴۸ ماهه به‌ترتیب با R، RMSE و MAE، ۰/۹۸۳، ۰/۰۶۴ و ۰/۰۴۵ نسبت به دو تابع هسته‌ای دیگر عملکرد بهتری داشته است. پس از تابع خطی، بر اساس آماره‌های ارزیابی، توابع هسته‌ای چند جمله‌ای و RBF در رتبه بعدی از نظر

برای پیش‌بینی خشکسالی استفاده کرد.

داشته است و در مقیاس‌های زمانی کوتاه‌مدت از روش BN و در مقیاس‌های بلندمدت از هر دو روش می‌توان



شکل ۵- نمودارهای سری زمانی و پراکنش مقادیر مشاهداتی و پیش‌بینی شده حاصل از بهترین مدل SVM در مقیاس زمانی ۴۸ ماهه در مرحله آزمون

نتیجه‌گیری

مربوط به پیش‌بینی خشکسالی نشان داد که پیش‌بینی SPEI در گام زمانی کوتاه‌مدت خصوصاً مقیاس یک ماهه با دقت بسیار پایینی انجام می‌گیرد. به‌نحوی که در بهترین حالت در این مقیاس، روش شبکه بیزین در مدل ۵ در مرحله آزمون به‌ترتیب با MAE و RMSE برابر ۰/۱۷۴، ۰/۲۵۷۴ و ۰/۳۱۳۱، بهترین عملکرد را داشته است. همچنین، با افزایش مقیاس محاسبه SPEI دقت پیش‌بینی مدل‌های پیش‌بینی افزایش می‌یابد، به‌طوری که در SPEI1 عملکرد نامناسب و در SPEI48 بهترین عملکرد را داشته است. نتایج توابع هسته‌ای مختلف در روش SVM نشان داد که تابع هسته‌ای خطی نسبت به دو تابع دیگر از دقت بالاتری برخوردار است و همچنین، در هر دو روش مدل ۵ بهترین عملکرد را داشته است. صرف نظر از دقت مناسب این دو روش یک مزیت دیگر آن‌ها نسبت به سایر روش‌ها را می‌توان در سرعت آموزش بالای مدل و ارائه رابطه ریاضی بین متغیرهای مستقل و وابسته در روش شبکه بیزین دانست، به‌نحوی که این روش‌ها می‌توانند به‌عنوان یک مدل مناسب برای پیش‌بینی خشکسالی و سایر مسائل رگرسیونی مورد استفاده قرار گیرند.

هدف از این پژوهش، پایش و پیش‌بینی خشکسالی بر مبنای شاخص SPEI در مقیاس‌های زمانی مختلف بود. بدین منظور، از اطلاعات بارش و دمای ایستگاه سقز در یک دوره ۴۹ ساله استفاده شد. سپس، با در دست بودن سری زمانی شاخص SPEI با استفاده از روش ماشین بردار پشتیبان با سه تابع هسته‌ای RBF، خطی و چند جمله‌ای و پنج حالت ورودی به مدل، اقدام به پیش‌بینی خشکسالی شاخص خشکسالی SPEI با در نظر گرفتن اثرات ترکیبی بارندگی و تبخیر و تعرق می‌تواند تغییرات منابع آب را در مقایسه با شاخص‌هایی که تنها از بارندگی استفاده می‌کنند، توجیه کند که از محاسن این شاخص محسوب می‌شود. بنابراین، این شاخص می‌تواند یک شاخص حساس به خشکسالی هیدرولوژیک و راهی برای ارتباط خشکسالی هواشناسی و هیدرولوژیک باشد. بر اساس شاخص SPEI در دو گام زمانی ۲۴ و ۴۸ ماهه، هشت دوره طولانی مدت خشکسالی مربوط به سال‌های ۱۹۶۸-۱۹۶۲، ۱۹۷۴-۱۹۷۲، ۱۹۷۹-۱۹۷۸، ۱۹۸۲-۱۹۸۰، ۱۹۸۴-۱۹۸۳، ۱۹۸۷-۱۹۸۶، ۲۰۰۳-۱۹۹۹ و ۲۰۰۹-۲۰۰۷ در طول دوره آماری وجود دارد. نتایج

منابع مورد استفاده

1. Abramopoulos, F., C. Rosenzweig and B. Choudhury. 1988. Improved ground hydrology calculations for global climate models (GCMs): soil water movement and evapotranspiration. *Journal of Climate*, 1(9): 921-941.
2. Adamowski, J and S.O. Prasher. 2012. Comparison of machine learning methods for runoff forecasting in mountainous watersheds with limited data/Porównanie metod uczenia maszynowego do prognozowania spływu w zlewniach górskich na podstawie ograniczonych danych. *Journal of Water and Land Development*, 17(1): 89-97.
3. Ahmadi, F., F. Radmanesh, and R. Mirabbasi Najaf Abadi. 2014. Comparison between genetic programming and support vector machine methods for daily river flow forecasting, case study: Barandoozchay River. *Journal of Water and Soil*, 28(6): 1162-1171. (In Persian)
4. Ahmadi, F., F. Radmanesh, R. Mir Abbasi Najf Abadi. 2016. Application of bayesian networks and genetic programming for predicting daily river flow, case study: Barandoozchay River. *Irrigation Sciences and Engineering*, 39(4): 213-223. (In Persian)
5. Allen, R.G., L.S. Pereira, D. Raes and M. Smith. 1998. Crop evapotranspiration. Guidelines for computing crop water requirements, FAO Irrigation and drainage Paper 56, FAO, Rome, 300(9): D05109.
6. Behzad, M., K. Asghari, M. Eazi and M. Pallhang. 2009. Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with Applications*, 36: 7624-7629.
7. Borsuk, M.E., D. Higdon, C.A. Stow and K.H. Reckhow. 2001. A bayesian hierarchical model to predict benthic oxygen demand from organic matter loading in estuaries and coastal zones. *Ecological Modelling*, 143: 165-181.
8. Botsis, D., P. Latinopoulos and K. Diamantaras. 2011. Rainfall-runoff modeling using support vector. Regression and Artificial Neural Networks. 12th International Conference on Environmental Science and Technology (CEST2011), Rhodes, Greece, 8-10 September.
9. Brandt, G and H. Henriksen. 2003. Protection of drinking water sources for quality and quantity, groundwater protection in the Greater Copenhagen area. In: Future Scenarios for Water Management in Europe. FIRMA Conference, 19-20 February, Barcelona, SP.
10. Da Silva, V.D.P.R. 2004. On climate variability in northeast of Brazil. *Journal of Arid Environments*, 58, 575-596.
11. Dibike, Y.B., S. Velickov, D. Solomatine and M.B. Abbott. 2001. Model induction with support vector machines: introduction and applications. *Journal of Computing in Civil Engineering* 15(3): 208-216
12. Dorner, S., J. Shi and D. Swayne. 2007. Multi-objective modelling and decision support using a bayesian network approximation to a non-point source pollution model. *Environmental Modelling and Software*, 22: 211-222.
13. Hamel, L.H. 2011. Knowledge discovery with support vector machines. Vol. 3, John Wiley and Sons.
14. Hosking, J.R. 2009. L-Moments. Wiley StatsRef: Statistics Reference Online.
15. Kempes, C., O. Myers, D. Breshears and J. Ebersole. 2008. Comparing response of Pinus edulis tree-ring growth to five alternate moisture indices using historic meteorological data. *Journal of Arid Environments*, 72(4): 350-357.
16. Labudova, L., L. Schefczyk and G. Heinemann. 2014. The comparison of the SPI and the SPEI using COSMO model data in two selected Slovakian river basins. Paper presented at the EGU General Assembly Conference Abstracts.
17. Madadgar, S. and H. Moradkhani. 2014. Spatio-temporal drought forecasting within bayesian networks. *Journal of Hydrology*, 512: 134-146.
18. Miller, J.F and P. Thomson. 2000. Cartesian genetic programming. Paper presented at the European Conference on Genetic Programming. *Climatology*, 35(13): 4027-4040.
19. Mostafazadeh, R., M. Shahabi and M. Zabihi. 2015. Analysis of meteorological drought using Triple Diagram Model in the Kurdistan Province, Iran. *Geographical Planning of Space Quarterly Journal*, 17: 129-140 (in Persian).
20. Neapolitan, R.E. 2003. Learning bayesian networks. Prentice Hall Series in Artificial Intelligence, 693 pages.
21. Nikbakht Shabazi, A.R. 2008. Application of SVM in predicting the river flow. In: Proceedings of 8th Iranian Hydraulic Conference, 24-26 Nov, Tehran University, Tehran, Iran (in Persian).
22. Nikoo, M.R and R. Karachian. 2009. Bayesian network performance assessment on river water quality management: application of the ratio-trade systems. *Journal of Water and Wastewater*, 20(1): 23-33. (In Persian)

23. Potop, V., and M. Možný. 2011. The application a new drought index–standardized precipitation evapotranspiration index in the Czech Republic. *Mikroklima a Mezoklima Krajinných Struktur a Antropogenních Prostředí*, 2: 2-14.
24. Razinei, T., P. Daneshkar Arasteh, R. Akhtari and B. Saghafian. 2007. Investigation of meteorological droughts in the Sistan and Balouchestan Province, using the standardized precipitation index and Markov chain model. *Iran-Water Resources Research*, 3(1): 25-35 (in Persian).
25. Reggiani, P. and A.H. Weerts. 2008. A bayesian approach to decision-marking under uncertainty: an application to real-time forecasting in the River Rhine. *Journal of Hydrology*, 356: 56-69
26. Samadianfard, S. and E. Asadi. 2017. Prediction of SPI drought index using support vector and multiple linear regressions. *Journal of Soil and Water Resources Conservation*, 6(4): 1-16 (in Persian).
27. Stage, J.H., L.M. Tallaksen, L. Gudmundsson, A.F. Van Loon and K. Stahl. 2015. Candidate distributions for climatological drought indices (SPI and SPEI). *International Journal of Climatology*, 35(13): 4027-4040.
28. Thornthwaite, C.W. 1948. An approach toward a rational classification of climate. *Geographical Review*, 38(1): 55-94.
29. Vapnik, V.N. 1998. *Statistical learning theory*. Wiley, New York.
30. Vicente-Serrano, S.M., S. Beguería and J.I. López-Moreno. 2010. A multiscalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index. *Journal of Climate*, 23(7): 1696-1718.
31. Vicente-Serrano, S.M., J.I. López-Moreno, A. Drumond, L. Gimeno, R. Nieto, E. Morán-Tejeda and J. Zabalza. 2011. Effects of warming processes on droughts and water resources in the NW Iberian Peninsula (1930–2006). *Climate Research*, 48(2/3): 203-212.
32. Whipple, W. 1966. Regional drought frequency analysis. *Journal of the Irrigation and Drainage Division*, 92, 11-32.
33. Yu, P.S., S.T. Chen and I.F. Chang. 2006. Support vector regression for real-time flood stage forecasting. *Journal of Hydrology*, 328: 704-716.
34. Zareabyaneh, H., M. GHobaeisooogh and A. Mosaedi. 2016. Drought monitoring based on Standardized Precipitation Evapotranspiration Index (SPEI) under the effect of climate change. *Water and Soil (Agricultural Sciences and Technology)*, 29(2): 374-392 (in Persian).