

مقایسه روش‌های ARIMA و شبکه عصبی در مدل‌سازی و پیش‌وضعیت خشکسالی با استفاده از داده‌های سری زمانی سنجش از دوری مطالعه موردی: شهر اراک

مهندی آخوندزاده هنرمند^۱

محمد‌مهدی خوش‌گفتار^۱

ایمان خسروی^۲

تاریخ پذیرش مقاله: ۹۶/۰۸/۱۹

تاریخ دریافت مقاله: ۹۵/۰۷/۱۸

چکیده

خشکسالی پدیده‌ای طبیعی، تکراری و موقتی است که به سبب بارش اندک رخ می‌دهد و تقریباً تمامی مناطق اقلیمی جهان را تحت تأثیر خود قرار می‌دهد، بویژه مناطق نیمه خشک که بدلیل میزان پائین بارش سالانه و حساسیت به تغییرات اقلیمی مستعد وضعیت خشکسالی می‌باشند. خشکسالی می‌تواند بر سلامت انسان‌ها و همچنین وضعیت اقتصادی و سیاسی جامعه تأثیرگذار باشد. اطلاعات در مورد شدت، طول مدت و پوشش مکانی خشکسالی می‌تواند به کارشناسان درخصوص کاهش آسیب‌پذیری مناطقی که تحت تأثیر خشکسالی هستند، کمک کند. یکی از چالش‌های اصلی در مدل‌سازی خشکسالی در ایران که در بخش خشک کره زمین واقع شده است، عدم وجود داده‌های هواشناسی بلند مدت برای اکثر مناطق کشور می‌باشد. داده‌های سنجش از دوری می‌توانند اطلاعاتی را در خصوص وضعیت پوشش گیاهی در اختیار قرار دهند. در این مقاله مدل‌های آماری خطی اتورگرسیو- میانگین متغیر کوچک (ARIMA) و مدل شبکه عصبی برای مدل‌سازی خشکسالی براساس داده‌های هواشناسی از دوری مورد استفاده قرار گرفته است. به همین منظور، شاخص بارش استانداردسازی شده (SPI) با استفاده از داده‌های هواشناسی به عنوان میزان شدت خشکسالی مورد استفاده قرار گرفت. تعدادی از بویژگی‌ها شامل شاخص اختلاف نرمال شده پوشش گیاهی (NDVI)، شاخص وضعیت پوشش گیاهی (VCI) و شاخص پوشش گیاهی - دما (TVX) که از تصاویر MODIS استخراج شده است، بکار برده شدند. با استفاده از مدل‌ها، شاخص‌های بدست آمده مدل‌سازی شدند و خطاهای RMSE و MAE برای آنها محاسبه گردید. سپس همبستگی میان شاخص‌های سنجش از دوری NDVI، VCI و TVX و شاخص هواشناسی SPI بررسی شده و به ترتیب مقادیر 0.0546 , 0.1475 , 0.0519 و 0.0519 بدست آمد. در این میان، شاخص‌های SPI و NDVI دارای بیشترین همبستگی با داده‌های SPI بودند. بنابراین از شاخص‌های SPI, NDVI, TVX به همراه شاخص SPI می‌توان در پیش‌بینی وضعیت خشکسالی در منطقه مورد پژوهش استفاده نمود.

واژه‌های کلیدی: شبکه عصبی، ARIMA، شاخص بارش استانداردسازی شده، شاخص اختلاف نرمال شده پوشش گیاهی، شاخص وضعیت پوشش گیاهی، شاخص پوشش گیاهی - دما

۱- باشگاه پژوهشگران جوان و نخبگان، واحد خمین، دانشگاه آزاد اسلامی، خمین، ایران (نوبنده مسئول) mm.khoshgoftar@gmail.com

۲- استادیار دانشکده مهندسی نقشه برداری و اطلاعات مکانی، گروه سنجش از دور، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران makhonz@ut.ac.ir

۳- دانشجوی دکتری دانشکده مهندسی نقشه برداری و اطلاعات مکانی، گروه سنجش از دور، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران

iman.khosravi@ut.ac.ir

و پیش بینی مباحث زیست محیطی مورد استفاده قرار گیرند (Weerts, A.H., et al, 2010:386). این داده ها به سرعت برای پایش خشکسالی مرتبط با وضعیت پوشش گیاهی در دنیا مورد استفاده قرار گرفته اند. از سال ۱۹۹۹ تصاویر MOD11 (MODIS) برای استخراج دمای سطح زمین (LST) و شاخص اختلاف نرمال شده پوشش گیاهی (NDVI) مورد استفاده قرار گرفته اند و از روی این داده ها، شاخص های دیگری همچون شاخص وضعیت پوشش گیاهی (VCI)، شاخص پوشش گیاهی - دمایی (TVX) و شاخص انحراف NDVI (DEV) نیز قابل محاسبه می باشد. در نهایت این شاخص ها برای پایش وضعیت پوشش گیاهی مورد استفاده قرار می گیرند. از آنجائی که داده های تصویری MODIS دارای قدرت تفکیک زمانی بالا با پوشش منطقه ای وسیع می باشند، به همین دلیل ابزار مناسبی برای تهیه نقشه از سری های زمانی وضعیت پوشش گیاهی در سطح جهانی و منطقه ای می باشند. از میان این متريک ها NDVI بطور گسترده به منظور پایش پوشش گیاهی و خشکسالی مورد استفاده قرار گرفته است که اين امر بدليل رابطه قوي ميان (Bhuiyan,C., et al, 2006:289) (Hopfner, C. & Scherer, D., 2011:3359) (Jain, S.K., et al, 2010:643) (Kinyanjui, M.J., 2011:165) (Li, B. & Tao, S., 2002:989) (Lotsch, A., et al, 2003:1774) (Rulinda, C.M., et al, 2012:169) (Tucker, C.J. & Choudhury, B.J., 1987:243).

در برخی مطالعات از روش شبکه عصبی برای پیش بینی خشکسالی استفاده شده است. به عنوان مثال Mishra و دسای نشان دادند که شبکه های عصبی بازگشتی برای پیش بینی مقادیر SPI برای حوضه آبریز رودخانه کانساباتی از کارایی خوبی برخوردار هستند (Mishra, A.K. & Desai, V.R., 2006:127). دستورانی و همکارانش نیز شبکه عصبی را برای پیش بینی مقادیر SPI در یک ایستگاه در مرکز ایران به کار برداشتند (Dastorani, M.T., et al, 2011:39). باروا و همکارانش وکسکین و همکارانش نیز از شبکه عصبی برای پایش و تجزیه و تحلیل شاخص های هواشناسی استفاده

خشکسالی یک وضعیت اقلیمی جدی می باشد که بسیاری از مناطق کره زمین را تحت تأثیر خود قرار داده است و در واقع پیچیده ترین خطر طبیعی می باشد. شدت خشکسالی اغلب با ترکیب متغیرهایی شامل بارش، دما، رطوبت، باد و رطوبت خاک اندازه گیری می شود. همانطور که خشکسالی در یک منطقه وسیع منتشر می شود و بطور آرام توسعه می یابد، دارای دینامیک های پیچیده ای می باشد. ایران همیشه در معرض خشکسالی بوده ولی در دهه های اخیر این موضوع روند افزایشی داشته است. علل اصلی بروز خشکسالی در ایران، عدم بارش کافی و فقدان سیستم مدیریتی مناسب در منابع آبی می باشد. اگر مقدار بارش در منطقه ای به صورت نرمال باشد ولی افزایش دما بصورت غیرعادی رخ دهد، می تواند سبب ایجاد شرایط خشکسالی شود. رسیک بروز خشکسالی را می توان ابتدا با مدل سازی صحیح و سپس تلاش برای مدیریت منابع آبی موجود به حداقل ممکن رساند.

خشکسالی اغلب به سه نوع تقسیم بندی می شود: هواشناسی، کشاورزی و آبی. خشکسالی هواشناسی زمانی رخ می دهد که بارش نرمال در یک منطقه بطور قابل ملاحظه ای در یک دوره زمانی کاهش یابد. روش های مختلف برای تعیین کیفیت شدت خشکسالی وجود دارد که از این بین می توان به شاخص شدت خشکسالی پالمر، شاخص شدت بارش استانداردسازی شده (SPI) که نسبت به دیگر روش ها رایج تر هستند، اشاره نمود. شاخص SPI به عنوان یک معیار خوب در تعیین شدت خشکسالی مورد تأیید قرار گرفته است. این شاخص، به صورت اختلاف میزان بارش از مقدار میانگین در یک دور زمانی مشخص تعریف می شود، در حالیکه میانگین و انحراف معیار از داده های اقلیمی و هواشناسی محاسبه می شوند. از آنجائی که داده های بارش دارای توزیع نرمال نمی باشند، تبدیل مناسبی مانند تابع گاما روی داده ها بکار می برند تا داده هایی با توزیع نرمال بدست آید.

داده های سنجش از دوری می توانند به منظور پایش

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (جغرافیا)

مقایسه روش‌های ARIMA و شبکه عصبی در مدل‌سازی ... / ۱۸۷

زمانی SPI به عنوان شاخص خشکسالی توسعه داده است (Durdu, O.F., 2010:1145). هان و همکاران مدل‌های ARIMA را روی سری زمانی VTCI که براساس داده‌های سنجش از دوری بدست آمده، مورد استفاده قرار داده و تغییرات آن در آینده را برای پیش‌بینی خشکسالی بکار برده‌اند (Han, P., et al, 2010:1398). همچنین هان و همکاران مدل‌های ARIMA را برای برآذش و پیش‌بینی سری زمانی SPI به عنوان شاخص خشکسالی توسعه داده‌اند (Han, P., et al, 2013:352).

در این مقاله مدل‌های ARIMA و شبکه عصبی به منظور مدل‌سازی شدت خشکسالی براساس داده‌های ماهواره‌ای توسعه داده شده‌اند. این مدل‌ها ویژگی‌های ماهواره‌ای مانند SPI را به عنوان ورودی، و خروجی‌های TVX، NDVI، VCI و TVX را به عنوان ورودی، و خروجی‌های SPI به همین منظور، سری زمانی SPI برای دوره زمانی ۲۰۰۰-۲۰۱۴ و TVX، NDVI، VCI نیز در همین دوره زمانی استخراج شده است. در این مقاله سعی شده است تا کارایی بهترین شاخص پوشش گیاهی ماهواره‌ای برای مدل‌سازی وضعیت خشکسالی که توسط SPI بیان شده است، شناسایی شود. مهارت پیش‌بینی مدل‌ها با خطای میانگین مطلق (MAE) و خطای ریشه میانگین مربعی (RMSE) ارزیابی شده است.

۲- مواد، روش‌ها و منطقه پژوهش

۲-۱- استان مرکزی

استان مرکزی به مرکزیت شهر اراک؛ تقریباً در مرکز ایران بین ۳۳ درجه و ۳۰ دقیقه تا ۳۵ درجه و ۳۵ دقیقه پهناهی شمالی و ۴۸ درجه و ۵۷ دقیقه تا ۵۱ درجه درازای خاوری از نصف النهار گرینویچ قرار دارد. این استان از شمال به استان‌های تهران و قزوین، از غرب به استان همدان، از جنوب به استان‌های لرستان و اصفهان و از شرق به استان‌های تهران، قم و اصفهان محدود است (نگاره ۱). در قسمت‌های مختلف استان مرکزی آب و هوایی متنوع نیمه بیابانی، معتدل کوهستانی و سرد کوهستانی وجود دارد.

کردن (Barua, S., et al, 2011:4469) (Keskin, M.E., et al, 2010:193) ابریشم‌چی و همکاران با استفاده از مدل تلفیقی غیرخطی مبتنی بر شبکه عصبی، خشکسالی را در حوضه زاینده رود پیش‌بینی کرده‌اند. ابریشم‌چی و همکاران، (۱۳۹۵). کارآموز و همکاران با استفاده از شبکه عصبی انواع خشکسالی‌های کشاورزی و آبی را در حوضه گاوخرونی در استان اصفهان پیش‌بینی نمودند (م، کارآموز و همکاران، ۱۳۹۵). این مطالعات تنها از شاخص‌های هواشناسی به منظور پایش وضعیت خشکسالی استفاده نموده‌اند. در تازه‌ترین پژوهش، جلیلی و همکاران با استفاده از روش‌های شبکه عصبی و ماشین‌های بردار پشتیبان و استفاده از شاخص‌های TCI و NDVI، VCI و TCI وضعیت خشکسالی کل ایستگاه‌های ایران را مدل‌سازی و پیش‌بینی نمودند (Jalili, M., et al, 2014:90).

مدل‌های اتورگرسیو - میانگین متحرک تجمعی (ARIMA) از پرکاربردترین مدل‌های سری زمانی می‌باشد (Box, G.E.P., & Jenkins, G.M., 1976:525). مدل‌های ARIMA عموماً از سه مدل زمانی پایه استخراج می‌شوند: مدل اتورگرسیو (AR)، مدل میانگین متحرک (MA) و مدل اتورگرسیو-میانگین متحرک (ARMA). کاربرد گسترده مدل ARIMA در اکثر مناطق به دلیل انعطاف‌پذیری و جستجوی سیستماتیک آن در هر مرحله (تشخیص، تخمین و ارزیابی) برای یک مدل مناسب است (Zhang, G.P., 2003:159). روش مدل ARIMA دارای چندین مزیت بویژه قابلیت پیش‌بینی و اطلاعات غنی‌تر آن روی تغییرات مرتبط با زمان نسبت به روش‌های دیگر می‌باشد (Yurekli, K., 2005:67) (Hu, W.B., et al, 2007:679) (Yurekli, K., 2005:67). مدل‌های ARIMA به منظور تجزیه و تحلیل و مدل‌سازی سری‌های زمانی آبی مورد استفاده قرار گرفته‌اند (Fernandez, C., et al, 2008:1063) (Fernando, D.A.K., & Jayawardena, A.W., 1994:310) (Modarres, R., 2006:223) (Fernandez, C., et al, 2008:1063) فرناندز و همکاران در سال ۲۰۰۸ مدل SARIMA را برای پیش‌بینی جریان سیل در یک آبشار کوچک در Galicia به کار برده‌اند (Fernandez, C., et al, 2008:1063). دوردو در سال ۲۰۱۰، مدل‌های خطی آماری را برای پیش‌بینی خشکسالی در ترکیه با استفاده از سری



نگاره ۱: منطقه مورد مطالعه

می گذارد (ع. سلیمانی، ۱۳۹۴) (ف. محمودی کهن، ۱۳۹۴). با توسعه فناوری سنجش از دور، امکان تهیه و جمع آوری داده‌ها در مقیاس‌های جهانی و منطقه‌ای با سرعت اخذ بالا و به صورت رقومی و با هزینه کمتر فراهم گردید. ضمن اینکه دقت بالاتر و بهتر با وابستگی کمتر به شرایط محیطی به دست آمد.

شهر اراک خصوصیات اقلیمی فلات مرکزی ایران (زمستان‌های سرد و مرطوب و تابستان‌های گرم و خشک) را داراست. کوه‌های اطراف اراک و تالاب میقان و دشت فراهان در آب و هوای این منطقه اثر کرده و ویژگی‌های خاصی به آن بخشیده است. ابرها و جریان‌های غربی در پاییز و زمستان بیشتر رطوبت خود را در ارتفاعات غرب منطقه به خصوص رشته کوه زاگرس از دست می‌دهند و در زمستان جبهه سردی هوای اراک را اشغال می‌کند که بر اثر ارتفاعات اطراف و فشاری که تالاب میقان بر هوا وارد می‌کند، مدت زیادی در منطقه می‌ماند. متوسط دمای سالانه شهر اراک ۱۴ درجه سانتی گراد است. میانگین رطوبت سالیانه اراک ۴۶٪ می‌باشد. به دلیل قراگیری شهر اراک در منطقه نیمه خشک، میزان بارندگی از میانگین کشور پایین‌تر است.

۲-۲- داده‌های مورد استفاده و آماده سازی داده‌ها

۲-۲-۱- شاخص‌های ماهواره‌ای

روش‌های مبتنی بر سنجش از دور، با ذخیره اطلاعات گیاهی در سنجنده‌های ماهواره‌ای، امکان بسیار مناسبی را جهت توسعه شاخص‌های خشکسالی با نظارت بر وضعیت پوشش گیاهی منطقه بوجود می‌آورند. قوع خشکسالی به دلیل کاهش شدید باران، کاهش عمل فتوسترن در گیاهان را موجب می‌شود. این امر میزان تشعشعات و انعکاس‌های حاصل از پوشش گیاهی در تصاویر ماهواره‌ای را تحت تأثیر قرار می‌دهد. مهمترین و مشهورترین شاخصی که برای برآورد میزان سبزینگی گیاهان و در واقع تشخیص میزان پوشش گیاهی در یک منطقه استفاده می‌شود، شاخص گیاهی تفضیلی نرمال شده (NDVI) است.

الف) شاخص NDVI: این شاخص، یکی از کاربردی‌ترین شاخص‌ها درجهان است که بطور وسیع در مسایل مختلف بکار می‌رود. این شاخص به روس و همکاران (Rouse, J.W., et al, 1973:309) نسبت داده شده، امام‌مفهوم آن اولین بار توسط

شاخص‌های قدیمی دارای چند آسیب اصلی هستند. اولاً برای تعیین این شاخص‌ها نیاز به ابزارهای دقیق است. ثانیاً این شاخص‌ها هزینه بالایی مصرف می‌کنند. از طرفی نقطه ضعف اساسی این شاخص‌ها، فقدان قدرت تفکیک مکانی خوب است. وابستگی این شاخص‌ها به ایستگاه‌های هواشناسی که اغلب با فاصله مکانی زیاد از هم توزیع شده‌اند، بر روی قابلیت اعتماد این شاخص‌ها تأثیر منفی

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (میر)

مقایسه روش‌های ARIMA و شبکه عصبی در مدل‌سازی ... / ۱۸۹

مقدار NDVI در یک دوره زمانی بلندمدت و مقدار در ماه کنونی است. بازه تغییرات این شاخص بین ۰ تا ۱۰۰ است که اعداد نزدیک به صفر نمایش دهنده شدت بالای خشکسالی و نزدیک به ۱۰۰ نشان دهنده تراسالی بالاست. معمولاً آستانه ۳۵ را برای تعیین وضعیت خشکسالی در نظر می‌گیرند (ع. سلیمانی، ۱۳۹۹). این شاخص نسبت به NDVI نتایج بهتری را نسبت به میزان بارندگی بویژه در مناطقی که از نظر جغرافیایی ناهمگون هستند، ارائه می‌دهد (ف. محمودی کهنه، ۱۳۹۹).

ج) شاخص انحراف NDVI: شاخص دیگری که می‌توان از NDVI استخراج نمود، شاخص انحراف (DEV) است که نشان‌دهنده تغییرات شرایط آب و هوایی است و بطور گسترده در مطالعات خشکسالی استفاده شده است (ش. جلیلی و همکاران، ۱۳۹۷). این شاخص بصورت رابطه ۳ قابل تعریف است که در آن \overline{NDVI} میانگین طولانی مدت NDVI برای زمان مشابه است.

$$DEV = NDVI - \overline{NDVI} \quad \text{رابطه ۳:}$$

۲-۱-۲- شاخص دمای سطح زمین (LST)
دمای سطح زمین یکی از پارامترهای فیزیکی مهم در پردازش‌های مربوط به سطح زمین در مقیاس منطقه‌ای و جهانی است (م. آخوندزاده، ۱۳۹۴). از دمای سطح زمین به عنوان پارامتر مؤثر در مطالعه مدل‌های انرژی، چرخه‌های آبی و مباحث کشاورزی استفاده می‌شود. اهمیت فراوان این پارامتر باعث شده که تعیین دمای سطح زمین از طریق فضا از موضوعات مورد علاقه بسیاری از محققان سنجش از دوری قرار بگیرد. در دهه اخیر سنجنده MODIS با عملکرد زمانی، طیفی و مکانی مناسب، پیشرفت‌های قابل توجهی را باعث شده است (م. آخوندزاده، ۱۳۹۴). سنجنده‌های ماهواره‌ای متعددی در محدوده مادون قرمز حرارتی داده اخذ می‌کنند همانند Landsat 4/5، Landsat 7، AVHRR و MODIS (ر. جویباری، ۱۳۹۳).

جدول ۱: طبقه‌بندی دوره‌های تراسالی و خشکسالی براساس

کریگلر و همکاران (Kriegler, F.J, et al, 1969) بیان شد که از رابطه ۱ قابل محاسبه است (ر. جویباری، ۱۳۹۳):

$$\text{NDVI} = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R} \quad \text{رابطه ۱:}$$

که در آن، ρ_{NIR} و ρ_R به ترتیب انعکاس در باندهای مادون قرمز نزدیک و باند قرمز است. مقدار این شاخص بین ۱- تا ۱+ تغییر می‌کند. مقدار NDVI برای زمین پوشیده از گیاهان معمولاً از حدود ۰/۱ تا ۰/۷ تغییر می‌کند، که مقدار بزرگتر از ۰/۵ نشان‌دهنده بدون پوشش گیاهی (شامل مناطق بانیر، سنگ، ماسه و یا برف) است (Sharma, A., 2006).

آنها عبارتند از (ع. سلیمانی، ۱۳۹۹) و (Rulinda, C.M., 2007):

۱- این شاخص تنها از دو باند استفاده می‌کند و خیلی حساس به تأثیرات انعکاس پس زمینه خاک در پوشش گیاهی کم تراکم نیست.

۲- از طرفی، مقدار NDVI در یک ماه نمی‌تواند دقیقاً معرف وضعیت خشکسالی در همان ماه باشد و ممکن است تأثیر آن در چند ماه بعد دیده شود. به همین دلیل، از خود NDVI نمی‌توان به صورت خام برای برآورد میزان خشکسالی در یک ناحیه بهره برد. بلکه از طریق تحلیلی که روی داده‌های بلند مدت NDVI انجام می‌شود، می‌توان به شاخص‌هایی جهت برآورد خشکسالی بر مبنای پوشش گیاهی رسید (ع. سلیمانی، ۱۳۹۹).

ب) شاخص وضعیت گیاهی (VCI): شاخص گیاهی‌ای که معمولاً برای برآورد میزان خشکسالی به کار می‌رود، شاخص VCI است. شاخص VCI اولین بار توسط کوگان (Kogan, F.N., 1997:621) ارائه شد. این شاخص شدت خشکسالی در یک دوره زمانی بلند مدت را بر حسب مقدار کمینه و بیشینه NDVI برآورد می‌کند. فرمول این شاخص بصورت رابطه (۲) می‌باشد (ع. سلیمانی، ۱۳۹۹):

$$VCI = \frac{NDVI_i - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \times 100 \quad \text{رابطه ۲:}$$

که در آن $NDVI_{max}$ و $NDVI_{min}$ ، به ترتیب کمینه و بیشینه

مقدار شاخص SPI

وضعیت	مقدار شاخص SPI
ترسالی بسیار شدید	$SPI \geq 2$
خیلی مرطوب	$1.5 \leq SPI < 2$
ترسالی متوسط	$1 \leq SPI < 1.5$
تقريباً نرمال	$-1 \leq SPI < 1$
خشکسالی متوسط	$-1.5 \leq SPI < -1$
خشکسالی شدید	$-2 < SPI < -1.5$
خشکسالی بسیار شدید	$SPI \leq -2$

مطالعات نشان داده‌اند که ترکیب NDVI و LST بهتر می‌توانند موقع خشکسالی را نشان دهند (Orhan, O., et al, 2014). زیرا این دو شاخص نسبت به خشکسالی عکس العمل متضادی از هم نشان می‌دهند، به گونه‌ای که با افزایش خشکسالی، دما یا LST بالا می‌رود و NDVI کاهش پیدا می‌کند و بنابراین مقدار این شاخص نیز افزایش می‌یابد (۱۳۱۹). همچنین ثابت شده است که شاخص TVX همبستگی عمده‌ای با رطوبت محصول و رطوبت خاک در اکثر شرایط پوشش گیاهی و اقلیمی دارد. نتایج نشان داده که استفاده از TVX یک شاخص کارا و سریع برای ارزیابی خشکسالی در سطح استان و کشور بوده است.

۲-۲-۲- شاخص‌های هواشناسی

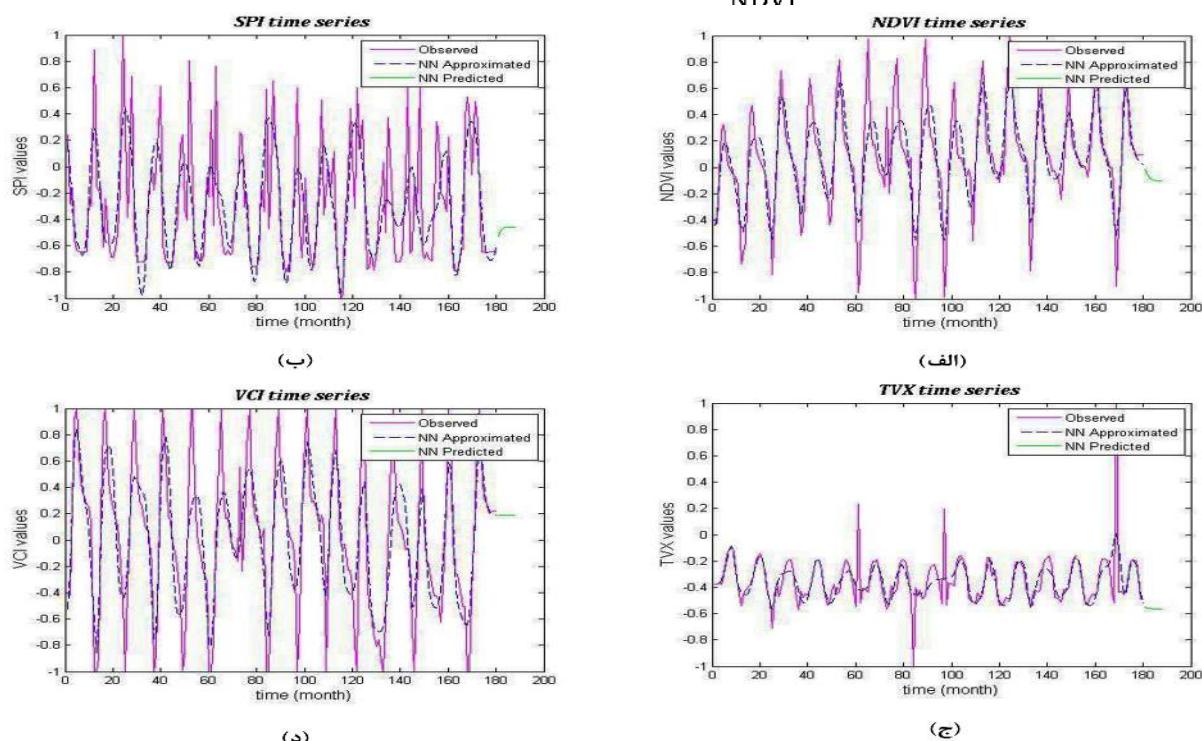
این شاخص‌ها مرتبط با داده‌های اقلیمی اندازه‌گیری شده در ایستگاه‌های هواشناسی مانند بارش، دما و

۲-۲-۳-۱-۲-۲- شاخص پوشش گیاهی - دما (TVX)

این شاخص نسبت بین NDVI و LST را نشان می‌دهد که توسط لامبینو ارلیش ارائه شد و از رابطه ۵ قابل محاسبه است (Lambin, E.F., & Ehrlich, D., 1996:463).

$$\text{TVX} = \frac{\text{LST}}{\text{NDVI}}$$

رابطه ۴:



نگاره ۲: نتایج بدست آمده از مدل‌سازی شبکه عصبی روی داده سری زمانی (الف) NDVI، (ب) SPI، (ج) TVX و (د) VCI

۳-۱- مدل‌های اتورگرسیو - میانگین متحرک تجمعی (ARIMA)

مدل‌های آماری که اغلب به عنوان مدل‌های سری زمانی شناخته می‌شوند، در کاربردهای علمی، اقتصادی و مهندسی برای تجزیه و تحلیل سری‌های زمانی مورد استفاده قرار گرفته‌اند. تکنیک‌های مدل‌سازی سری‌های زمانی به منظور مهیا کردن یک روش تجربی سیستماتیک برای شبیه‌سازی و پیش‌بینی رفتار سیستم‌های متغیر آبی و برای تعیین دقت مورد انتظار پیش‌بینی‌ها، نمایش داده شده‌اند. مدل‌های ARIMA عموماً از سه مدل زمانی پایه استخراج می‌شوند: مدل اتورگرسیو (AR)، مدل میانگین متحرک (MA) و مدل ترکیبی اتورگرسیو - میانگین متحرک (ARMA). مدل‌های ARMA و AR_{MA} زمانی مورد استفاده قرار می‌گیرند که داده‌های سری زمانی مانا و ایستا باشند. یک سری زمانی ایستا را زمانی می‌توان تعریف نمود که داده‌ها دارای یک میانگین ثابت باشند و در طول زمان دارای هیچ روندی نمی‌باشند. سری‌های زمانی عموماً روندهای بالارونده یا پائین رونده را نمایش می‌دهند. برخی سری‌های زمانی غیرایستا هستند. این نوع از سری‌های زمانی را می‌توان با تفاضل‌گیری داده‌های سری زمانی نسبت به سری زمانی ایستا مدل‌سازی نمود. سری‌های زمانی اغلب دارای ویژگی‌های دوره‌ای (اثرات فصلی) می‌باشند که اغلب از تفاضل‌گیری فصلی برای حذف اثرات فصلی استفاده شود. این نوع از مدل‌ها به عنوان مدل‌های SARIMA شناخته می‌شوند. از این‌رو، مدل‌های ARIMA دارای دو شکل کلی هستند: مدل ARIMA غیرفصلی (p,d,q) و مدل ARIMA فصلی (p,d,q)(P,D,Q). p، d و q بخش‌های غیرفصلی و P، D و Q بخش‌های فصلی مدل می‌باشند. شکل مدل ARIMA(p,q,d) بصورت رابطه ۶ نوشته می‌شود:

$$\varphi(B)\nabla^d Z_t = \theta(B)a_t \quad \text{رابطه ۶:} \quad \text{که در آن:}$$

$$\theta(B) = 1 - \sum_{i=1}^p \theta_i B^i \quad \text{رابطه ۷:}$$

$$\varphi(B) = 1 - \sum_{i=1}^q \varphi_i B^i \quad \text{رابطه ۸:}$$

میزان تبخیر آب موجود در خاک می‌باشد. مهمترین شاخص‌های استفاده شده هواشناسی، شاخص بارش استاندارد شده (SPI)، شاخص شدت خشکسالی پالمر (PDSI) و شاخص دهک‌هاست.

در بین این شاخص‌ها، شاخص SPI از اعتبار بیشتری در کشورمان برخوردار است. شاخص SPI اولین بار توسط مک کی و همکارانش ارائه شد که شاخصی براساس احتمال بارش برای هر بازه زمانی است (McKee, T.B., et al, 1995:233) (McKee, T.B., et al, 1993:179).

این شاخص برای بازه‌های زمانی مختلف قابل محاسبه است و جهت ارائه هشدار اولیه و کمک به ارزیابی شدت خشکسالی اهمیت زیادی دارد. این شاخص برای کمی کردن کمبود بارش در بازه‌های زمانی چندگانه طراحی شده است و اثرات خشکسالی را بر منابع آب قابل دسترس در این بازه‌های زمانی نشان می‌دهد. با توجه به اینکه آب‌های زیرزمینی و جریان آب‌های سطحی در ایجاد نابهنجاری‌های دراز مدت در بارش مؤثر می‌باشد، لذا شاخص SPI اساساً برای بازه‌های زمانی ۳، ۶، ۱۲، ۲۴ و ۴۸ ماهه محاسبه می‌شود. شاخص SPI برای هرمنطقه براساس آمار بارندگی بلندمدت در یک دوره آماری دلخواه تعیین می‌شود. این شاخص از رابطه ۵ قابل محاسبه است (ف. محمودی کهن، ۱۳۹۶):

$$SPI = \frac{P - \mu(P)}{\sigma(P)}$$

که در آن P مقدار بارش، $\mu(P)$ میانگین مقدار بارش برای یک بازه زمانی مشخص و $\sigma(P)$ انحراف معیار آن است. مقادیر مثبت SPI مقادیر بیشتر از میانه بارندگی و مقادیر منفی آن، مقادیر کمتر از میانه بارش را نشان می‌دهد. طبقه‌بندی دوره‌های خشکسالی و ترسالی براساس شاخص SPI مطابق جدول ۱ است. مطابق جدول، مقادیر کمتر از ۱، معرف وقوع خشکسالی و مقادیر مثبت آن نشان‌دهنده خاتمه خشکسالی است.

۳- روش‌شناسی

لایه‌های پنهان و واحدهای خروجی است و تابع $f(\cdot)$ تابع انتقال لایه پنهان است. تابع انتقال دارای شکل‌های مختلفی است که رایج‌ترین شکل آن‌ها بصورت زیر است:

رابطه ۱۰:

$$f(s_i) = \log \text{sig}(s_i) = \frac{1}{1 + \exp(-s_i)}$$

تابع سیگموئید لگاریتمی

$$f(s_i) = \text{purelin}(s_i) = s_i$$

تابع خطی

$$f(s_i) = \tan \text{sig}(s_i) = \frac{2}{1 + \exp(-2s_i)} - 1$$

تابع سیگموئید تانژانت هایبربولیک

که در آن:

رابطه ۱۱:

$$s_i = \sum_{i=1}^n w_i x_i$$

سیگنال ورودی است که به عنوان جمع وزن‌دار اطلاعات ورودی بکار می‌رود.

آموزش یک شبکه، یک فاکتور ضروری برای موفقیت شبکه‌های عصبی می‌باشد. در بین چندین الگوریتم یادگیری موجود، الگوریتم پس انتشار خطا (BP) رایج‌تر از سایر الگوریتم‌ها برای یادگیری تمام طرح‌های شبکه عصبی، استفاده می‌شود. برای کاهش خطا توسط وزن‌های ارتباط در شبکه، روش BP تکرار می‌شود. روش نزول گرادیان برای محاسبه وزن شبکه و تعدیل وزن ارتباطات داخلی استفاده می‌شود تا خطای مجموع مربعات (SSE) که بصورت زیر محاسبه می‌شود را کمینه کند:

$$\text{SSE} = \frac{1}{2} \sum_k (y_k - \hat{y}_k)^2$$

رابطه ۱۲:

که y_k و \hat{y}_k به ترتیب بردار مقدار واقعی و بردار مقدار خروجی پیش‌بینی شده نود خروجی k است.

برای یک مسئله پیش‌بینی سری زمانی یک متغیری، ورودی شبکه عصبی همان مشاهدات گام‌های قبلی یعنی $(x_{t-1}, x_{t-2}, \dots, x_{t-p}, w)$ است و خروجی، مقدار پیش‌بینی شده x_t است که معادله آن بصورت زیر می‌باشد:

رابطه ۱۳:

$$x_t = g(x_{t-1}, x_{t-2}, \dots, x_{t-p}, w) + \varepsilon_t$$

Z_t : سری زمانی مشاهده شده، i و θ_i ، پارامترهای مدل و p و q ، مرتبه‌های مدل هستند. B، عملگر انتقال پسرو می‌باشد. فرض می‌شود که خطاهای تصادفی، بصورت مستقل و یکسان با یک میانگین صفر و واریانس ثابت σ^2 (نویز سفید) توزیع شوند. d، عمل تفاضل‌گیری را روی داده‌های سری زمانی برای ایجاد سری زمانی ایستا انجام می‌دهد و d، تعداد تفاضل‌گیری را نشان می‌دهد. اگر سری زمانی مورد بررسی دارای الگوی فصلی نباشد، مقادیر d، p و q نیاز نیست که بزرگتر از ۲ باشند.

۲-۳ - مدل شبکه عصبی

شبکه عصبی (NN)، یک سیستم کامپیوتی است که برای شبیه‌سازی فرایندهای یادگیری مغز انسان طراحی شده است. بزرگترین امتیاز شبکه عصبی، توانایی آن در مدل‌سازی داده‌های سری زمانی غیرخطی پیچیده می‌باشد. این مدل عموماً دارای سه لایه می‌باشد: لایه اول، لایه ورودی است که داده را به شبکه معرفی می‌کند، لایه دوم لایه پنهان است که داده‌ها درون آن پردازش می‌شوند و لایه آخر یعنی لایه خروجی که نتایج داده ورودی در آن تولید می‌شود. لایه یا لایه‌های پنهان به منظور حل مسائل غیرخطی اضافه می‌شوند. شبکه‌های عصبی جلو رونده تک لایه پنهانی، پرکاربردترین شکل مدل شبکه عصبی برای مدل‌سازی و پیش‌بینی سری‌های زمانی است.

خروجی شبکه عصبی با فرض یک خروجی خطی از نرون j یک لایه پنهان منفرد با h نود پنهان سیگموئید و یک متغیر ورودی x_i بصورت رابطه ۹ می‌باشد:

رابطه ۹:

$$x_i = g\left(\sum_{j=1}^h w_j f(s_j) + b_k \right)$$

که در آن، $g(\cdot)$ تابع انتقال (تحریک) خطی نرون خروجی k و b_k ، بایاس آن و w_j ، وزن‌های اتصال بین

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (جص)
مقایسه روش‌های ARIMA و شبکه عصبی در مدل‌سازی ... / ۱۹۳

اعتبارسنجی و ۱۵٪ باقیمانده نیز بصورت آزمایشی وارد مسئله گردید. به این دلیل که شبکه عصبی همواره دارای جواب منحصر بفرد نمی‌باشد و با هر بار اجرای این روش، جواب‌ها و نتایج ارزیابی مختلفی حاصل می‌شود، لذا در این بخش سعی شد تا یک روند بهبود برای شبکه عصبی و بر مبنای کمیت RMSE کل ارائه شود.

برای آموزش شبکه از روش پس انتشار خطای گرادیان توانم مقیاس شده (SCGBP) استفاده گردید. تعداد لایه‌های پنهان بین ۱ تا ۴۰ لایه و تعداد تکرار فرایند آموزش نیز ۳۰ بار انتخاب گردید. پس از اجرای روش، بهترین نتیجه ارزیابی دقت حاصل از این روش در جدول ۲ برای شاخص‌های TVX، VCI، NDVI و SPI ارائه شده است.

همچنین نمودارهای حاصل از مدل‌سازی شبکه عصبی برای این شاخص‌ها در نگاره ۲ مشاهده می‌شود. به علاوه مقادیر هر یک از شاخص‌ها برای ۸ ماه آینده با استفاده از شبکه عصبی پیش‌بینی شد.

۴-۲- مدل‌سازی و پیش‌بینی مدل ARIMA
در این مدل ابتدا به بررسی وجود مؤلفه‌های روند یا فصلی که نیازمند مدل‌سازی هستند، پرداخته شد. اگر این مقادیر وجود داشته باشند، باید آنها را به کمک تکنیک‌های استاندارد حذف نمود. سپس توابع خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) برای شناسایی مدل (AR, MA و یا ARMA/ARIMA) تشکیل گردید. پس از آن، درجه مدل با استفاده از معیارهای مبتنی بر اطلاعات مانند روش‌های معیار اطلاعات آکائیک (AIC) و معیار اطلاعات بیزین (BIC) شناسایی شد. با توجه روش‌های AIC و BIC، بهترین مدل ARIMA از میان مدل‌های ARIMA تولید شده انتخاب گردید و در نهایت براساس مدل تعیین شده مقادیر خطای RMSE و MAE برای شاخص‌ها محاسبه گردید، که در جدول ۳ نمایش داده شده است.

جدول ۳: مدل ARIMA و مقادیر خطای RMSE و MAE

که در آن، w یک بردار از تمامی پارامترها و (g) تابعی است که توسط ساختار شبکه و وزن‌های اتصال تعیین می‌شود. یک امتیاز بزرگ شبکه‌های عصبی، توانایی آنها در فراهم کردن یک نگاشت غیرخطی منطفع بین ورودی‌ها و خروجی‌ها است. بنابراین، می‌توانند خصوصیات سری‌های زمانی را به خوبی حفظ نمایند. شبکه عصبی می‌تواند با هر تعداد لایه ساخته و بکار گرفته شود، با اینحال براساس قضیه‌ای بنام قضیه کولموگوروฟ، یک شبکه عصبی سه لایه توانایی استفاده برای حل هر مسئله در هر نوع فضایی را دارد.

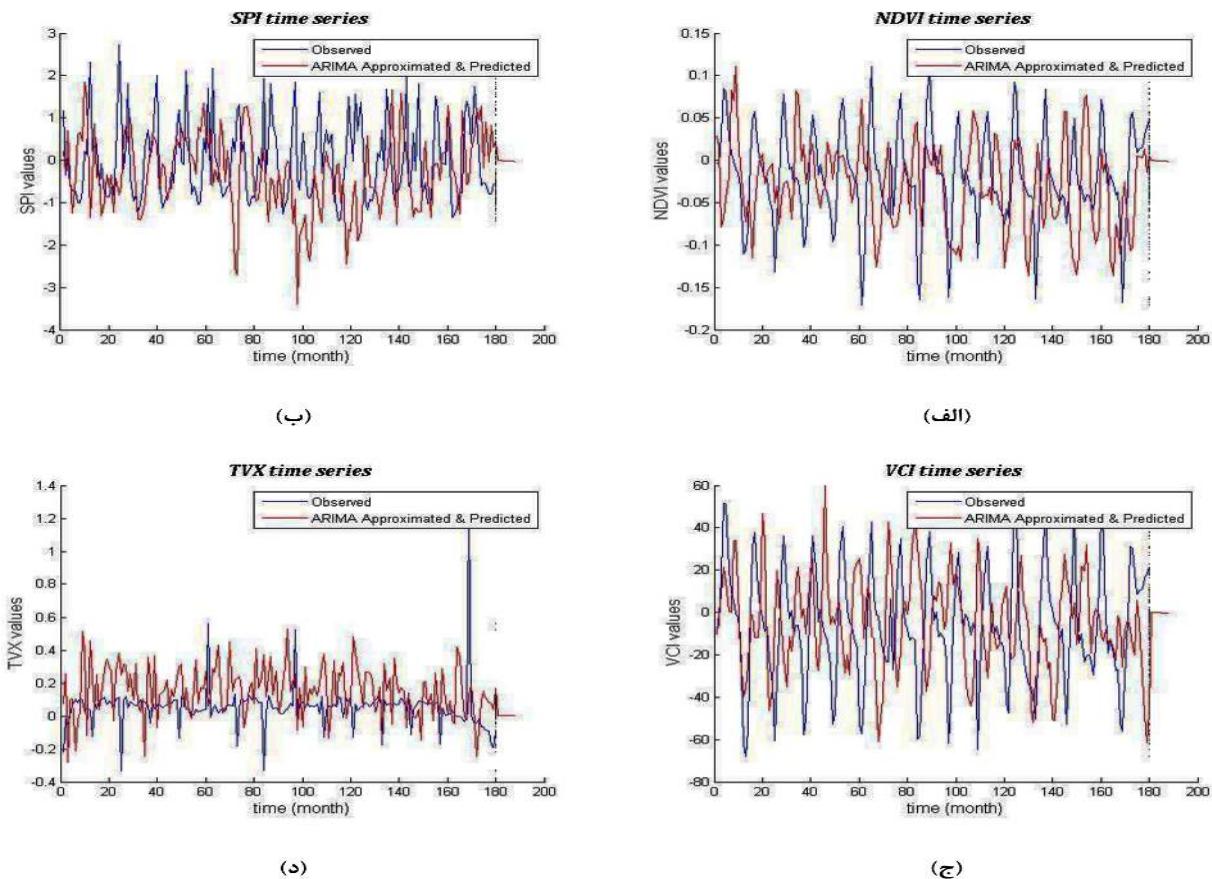
جدول ۲: مقادیر کمیت RMSE و MAE برای مدل‌سازی شاخص‌ها با روش شبکه عصبی

شاخص	RMSE	MAE
NDVI	۰/۱۹۴۴	۰/۱۵۰۱
VCI	۰/۲۱۹۱	۰/۲۷۸۳
TVX	۰/۱۲۹۵	۰/۰۶۴۳
SPI	۰/۲۹۹۰	۰/۲۱۷۴

۴- نتایج

۴-۱- مدل‌سازی و پیش‌بینی شبکه عصبی

در ابتدا به منظور کاهش حجم محاسبات، نرم‌افزاری داده‌ها در محدوده [۱۱-۱] صورت گرفت. سپس داده‌ها به سه بخش آموزشی، اعتبارسنجی و آزمایشی تقسیم‌بندی شدند. داده‌های آموزشی تنها برای آموزش شبکه ارائه می‌شوند و شبکه براساس خطای آنها تنظیم می‌شود. داده‌های اعتبارسنجی برای اندازه‌گیری تعمیم‌پذیری شبکه استفاده می‌شود و زمانی که تعمیم‌پذیری شبکه کاهش دهد، فرایند آموزش را متوقف می‌کند. داده‌های آزمایشی نیز که در فرایند آموزشی نقشی ندارند، یک معیار مستقل از کارایی شبکه پس از آموزش آن ارائه می‌دهند. در این بخش ۷۰٪ داده‌ها بصورت آموزشی، ۱۵٪ بصورت



نگاره ۳: نتایج بدست آمده از مدل‌سازی ARIMA روی داده سری زمانی (الف) NDVI، (ب) SPI، (ج) TVX و (د) VCI

و هواشناسی
 به منظور تحلیل همبستگی میان شاخص‌های ماهواره‌ای و هواشناسی از ضریب تعیین (R^2) استفاده شد و مقدار آن محاسبه گردید. آنچه که از جدول ۴ نتیجه می‌شود، این است که با توجه به مقادیر ضریب همبستگی بدست آمده میان شاخص‌ها، شاخص ماهواره‌ای TVX دارای همبستگی بیشتری با SPI می‌باشد. نتایج جدول ۴ بیان‌گر این مسئله است که شاخص بارش بطور مستقیم روی پوشش گیاهی تأثیر می‌گذارد که امری کاملاً صحیح و بدیهی می‌باشد، چراکه با افزایش بارش، میزان پوشش گیاهی نیز افزایش می‌یابد. در میان شاخص‌های پوشش گیاهی، شاخص NDVI نسبت به دو شاخص دیگر یعنی VCI و DEV دارای همبستگی بیشتری با شاخص SPI می‌باشد. بنابراین به نظر می‌رسد

بدست آمده برای شاخص‌ها			
MAE	RMSE	ARIMA	شاخص
۰.۰۶۱۶	۰.۰۷۷۰	ARIMA(2,1,2)	NDVI
۳۰/۱۹۷۹	۳۷/۲۳۱۸	ARIMA(2,1,1)	VCI
۰/۲۰۵۹	۰/۲۶۵۸	ARIMA(1,1,2)	TVX
۱/۰۵۱۱	۱/۳۳۷۰	ARIMA(1,1,1)	SPI

از آنجائی که مدل، مدل‌سازی شده و پارامترهای آن تخمین زده شده است، می‌توان داده‌ها را برای یک دوره زمانی مشخص پیش‌بینی نمود. البته این موضوع برای یک دوره زمانی کوتاه مدت مناسب می‌باشد. برای هر یک از شاخص‌ها، مقدار پیش‌بینی برای ۸ ماه آینده محاسبه گردید که نتایج آن در نگاره ۳ نمایش داده شده است.

۴-۳- تعیین همبستگی میان شاخص‌های ماهواره‌ای

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (جص) ۱۹۵ / مقایسه روش‌های ARIMA و شبکه عصبی در مدل‌سازی ...

با بررسی رابطه همبستگی بین این دو سری داده، بهترین شاخص‌ها را انتخاب کرد.

برخلاف اکثر پژوهش‌های انجام شده که تنها از شاخص‌های هواشناسی (و بدون شاخص‌های سنجش از دوری) برای پایش وضعیت خشکسالی استفاده کرده‌اند، این پژوهش ترکیبی از هر دو داده را به کار گرفت که موجب کسب نتایج مطلوب‌تری شد. بنابراین، می‌توان ادعا نمود که این پژوهش با بکارگیری روش‌های هوش مصنوعی و استفاده از ترکیب سری زمانی داده‌های سنجش از دور و هواشناسی، راهکار مناسب‌تر و مطمئن‌تری جهت مدل‌سازی رفتار خشکسالی و پیش‌بینی و پایش وضعیت آن ارائه داده است.

۶- منابع و مأخذ

- آخوندزاده، م.؛ (۱۳۸۴). تهیه نقشه‌های حرارتی سطح زمین با استفاده از تصاویر MODIS. پایان‌نامه کارشناسی ارشد، دانشگاه تهران، پردیس دانشکده‌های فنی، گروه مهندسی نقشه‌برداری.
- ابریشم‌چی، ا.؛ مهدیخانی، ح.؛ تجریشی، م.؛ (۱۳۸۵). توسعه مدل تلفیقی غیرخطی پیش‌بینی خشکسالی مبتنی بر شبکه عصبی مصنوعی و تبدیلات موجک، مطالعه موردی: زیر حوضه سد زاینده رود. دومین کنفرانس مدیریت منابع آب، اصفهان، دانشگاه صنعتی اصفهان، انجمن علوم و مهندسی منابع آب ایران.
- جلیلی، ش.؛ مرید، س.؛ ضیائیان فیروزآبادی، پ.؛ (۱۳۸۷). مقایسه عملکرد شاخص‌های ماهواره‌ای و هواشناسی در پایش خشکسالی. مجله تحقیقات آب و خاک ایران، دوره ۳۹، ش. ۱، ص ۱۴۹-۱۳۹.

- جویباری، ی.؛ (۱۳۹۳). تهیه نقشه ضریب گسیل و دما با استفاده از تصاویر ماهواره لنdest-۸. پایان‌نامه کارشناسی ارشد، دانشگاه تهران، پردیس دانشکده‌های فنی، گروه مهندسی نقشه‌برداری.
- سلیمانی، ع.؛ (۱۳۸۹). تحلیل خطرپذیری خشکسالی. پایان‌نامه کارشناسی ارشد، دانشگاه تهران، پردیس

استفاده از این شاخص‌ها در پیش‌بینی و پایش وضعیت خشکسالی بهتر از شاخص‌های VCI و DEV می‌باشد.

جدول ۴: ضریب همبستگی میان شاخص‌های ماهواره‌ای و شاخص هواشناسی

	NDVI	TVX	VCI
SPI	۰/۰۵۴۶	۰/۱۴۷۵	۰/۰۵۱۹

۵- نتیجه‌گیری

در این پژوهش، وضعیت خشکسالی اقلیم منطقه مرکزی استان مرکزی بین سال‌های ۲۰۰۰ تا ۲۰۱۴ با استفاده از سری زمانی شاخص‌های سنجش از دوری NDVI، VCI و TVX و شاخص هواشناسی SPI مورد بررسی قرار گرفت. همچنین دو روش شبکه عصبی و ARIMA جهت مدل‌سازی سری زمانی این شاخص‌ها و پیش‌بینی مقادیر آنها در ۸ ماه آینده به کار گرفته شد. نتایج RMSE کل حاصل از روش شبکه عصبی در مدل‌سازی شاخص‌های TVX، VCI، NDVI و SPI به ترتیب ۰/۱۲۹۵، ۰/۲۱۹۱، ۰/۲۹۹۰ و ۰/۱۹۴۴ و مقادیر نظری حاصل از روش ARIMA به ترتیب ۰/۰۷۷۰، ۰/۲۶۵۸، ۳/۷/۲۳۱۸ و ۱/۳۳۷۰ بود. بنابراین طبق این نتایج، می‌توان نتیجه گرفت که به طور کلی، روش شبکه عصبی برای مدل‌سازی و پیش‌بینی شاخص‌های خشکسالی در منطقه مطالعاتی این پژوهش مناسب‌تر و کارآمدتر از روش ARIMA بود.

هدف دیگر این مقاله، بررسی رابطه همبستگی میان شاخص‌های سنجش از دوری و شاخص هواشناسی SPI بود. طبق نتایج، شاخص TVX دارای بیشترین همبستگی با داده‌های SPI بود. همچنین، در بین شاخص‌های گیاهی SPI و NDVI، همبستگی شاخص NDVI با شاخص TVX بیشتر بود. بنابراین شاخص‌های TVX و NDVI به همراه شاخص SPI را می‌توان در پیش‌بینی وضعیت خشکسالی در منطقه مطالعاتی این پژوهش مورد استفاده قرار داد. برای بررسی وضعیت خشکسالی سایر مناطق نیز می‌توان

15. Han, P.; Wang, P.X.; Zhang, S.Y. and Zhu, D.H.; (2010). "Drought forecasting based on the remote sensing data using ARIMA models", Mathematical and Computer Modelling, Vol 51, pp 1398–1403.
16. Han, P.; Wang, P.; Tian, M.; Zhang, S. and Liu, J.; (2013). "Application of the ARIMA Models in Drought Forecasting Using the Standardized Precipitation Index", IFIP International Federation for Information Processing, Vol 392, pp. 352–358.
17. Hopfner, C. and Scherer, D.; (2011). "Analysis of Vegetation and Land Cover Dynamics in North-Western Morocco during the Last Decade Using Modis NDVI Time Series Data," Biogeosciences, vol. 8, pp. 3359–3373.
18. Hu, W.B.; Tong, S.L.; Mengersen, K. and Connell, D.; (2007). "Weather variability and the incidence of cryptosporidiosis: Comparison of time series Poisson regression and SARIMA models", Annals Epidemiology, Vol 17, pp 679–688.
19. Jalili, M.; Gharibshah, J.; Ghavami, S.M.; Beheshtifar, M.R. and Farshi, R.; (2014). "Nationwide Prediction of Drought Conditions in Iran Based on Remote Sensing Data", IEEE Transactions on Computers, Vol 63, No 1, pp:90-101.
20. Jain, S.K.; Keshri, R.; Goswami, A. and Sarkar, A.; (2010). "Application of Meteorological and Vegetation Indices for Evaluation of Drought Impact: A Case Study for Rajasthan, India," Natural Hazards, vol. 54, pp. 643–656.
21. Keskin, M.E.; Terzi, O.; Taylan, E.D. and Kucukyaman, D.; (2011). "Meteorological Drought Analysis Using Artificial Neural Networks", Scientific Research and Essays, Vol 6, pp 4469–4477.
22. Kinyanjui, M.J.; (2011). "NDVI-Based Vegetation Monitoring in Mau Forest Complex, Kenya," African J. Ecology, vol. 49, pp. 165–174.
23. Kriegler F.J.; Malila W.A.; Nalepka R.F. and Richardson W.; (1969). "Preprocessing transformations and their effects on multispectral recognition", in: Proceedings of the Sixth International
24. Kogan, F.N.; (1997). "Global Drought Watch From Space", Bull. Am. Met. Soc., Vol 78, pp 621-636.
- دانشکده‌های فنی، گروه نقشه برداری.
۶. کارآموز، م.; رسولی، ک.; نظیف، س.; (۱۳۸۵). تدوین ترکیبی خشکسالی با استفاده از شبکه‌های عصبی. دومین کنفرانس مدیریت منابع آب، اصفهان، دانشگاه صنعتی اصفهان، انجمن علوم و مهندسی منابع آب ایران.
۷. محمودی کهن، ف.; (۱۳۸۹). مطالعه قابلیت شاخص‌های گیاهی ماهواره‌ای در پیش‌بینی و آشکارسازی خشکسالی. پایان‌نامه کارشناسی ارشد، دانشگاه تحصیلات تکمیلی صنعتی کرمان، دانشکده عمران و نقشه‌برداری، گروه سنجش از دور.
8. Barua, S.; Perera, B.J.C.; Ng, A.W.M. and Tran, D.; (2010). "Drought Forecasting Using an Aggregated Drought Index and Artificial Neural Networks", Journal of Water and Climate Change, Vol 1, pp 193–206.
9. Bhuiyan, C.; Singh, R.P. and Kogan, F.N.; (2006). "Monitoring Drought Dynamics in the Aravalli Region (India) Using Different Indices Based on Ground and Remote Sensing Data," Int'l J. Applied Earth Observation and Geoinformation, vol. 8, pp. 289-302.
10. Box, G.E.P. and Jenkins, G.M.; (1976). "Time Series Analysis: Forecasting and Control", Holden-Day, San Francisco, 525 pp.
11. Dastorani, M.T. Afkhami, H. and Borroni, B.; (2011). "Application of Artificial Neural Networks on Drought Prediction in Yazd (Central Iran)", Desert, Vol 16, pp 39–48.
12. Durdu, O.F.; (2010). "Application of Linear Stochastic Models for Drought Forecasting in the Buyuk Menderes River Basin, Western Turkey". Stochastic Environmental Research and Risk Assessment, Vol 24, pp 1145–1162.
13. Fernandez, C.; Vega, J.A.; Fonturbel, T. and Jimenez, E.; (2008). "Streamflow Drought Time Series Forecasting: a Case Study in a Small Watershed in North West Spain". Stochastic Environmental Research and Risk Assessment, Vol 23, pp 1063–1070.
14. Fernando, D.A.K. and Jayawardena, A.W.; (1994). "Generation and forecasting of monsoon rainfall data", in: Proceedings of the 20th WEDC Conference, Colombo, Sri Lanka, pp 310–313.

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (جغرافیا)
مقایسه روش‌های ARIMA و شبکه عصبی در مدل‌سازی ... / ۱۹۷

36. Sharma, A.; (2006). "Spatial Data Mining for Drought Monitoring: An Approach Using temporal NDVI and Rainfall Relationship", MSc thesis, Geo-information Science and Earth Observation.
37. Tucker, C.J. and Choudhury, B.J.; (1987). "Satellite Remote Sensing of Drought Conditions," *Remote Sensing of Environment*, vol. 23, pp. 243-251, 1987.
38. Weerts, A.H.; Schellekens, J. and Weiland, F.S.; (2010). "Real-Time Geospatial Data Handling and Forecasting: Examples from Delft-FEWS Forecasting Platform/System," *IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 3, no. 3, pp. 386-394.
39. Yurekli, K.; Kurunc, K. and Ozturk, F.; (2005). "Application of linear stochastic models to monthly flow data of Kelkit stream", *Ecological Modeling*, Vol 183,pp 67-75.
40. Zhang, G.P.; (2003). "Time series forecasting using a hybrid ARIMA and neural network model", *Neurocomputing*, Vol 50,pp 159-175.
25. Lambin, E.F. and Ehrlich, D.; (1996). "The surface temperature-vegetation index for land cover and land cover change analysis". *International Journal of Remote Sensing*, Vol 17, pp 463–487.
26. Li, B. and Tao, S.; (2002). "Relations between AVHRR NDVI and Ecoclimatic Parameters in China," *Int'l J. Remote Sensing*, vol. 23, pp. 989-999.
27. Lotsch, A.; Friedl, M.A. and Anderson, B.T.; (2003). "Coupled Vegetation-Precipitation Variability Observed from Satellite and Climate Records," *Geophysical Research Letters*, vol. 30, pp. 1774-1777.
28. McKee, T. B.; Doesken, N.J. and Kleist, J.; (1995). "Drought monitoring with multiple time scales". Ninth Conference on Applied Climatology, American Meteorological Society, Dallas TX, pp.233-236.
29. McKee, T. B., Doesken, N.J. and Kleist, J.; (1993). "The relationship of drought frequency and duration of time scales". Eighth Conference on Applied Climatology, American Meteorological Society, Anaheim CA, pp.179-186.
30. Mishra, A.K.; Desai, V.R.; (2006). "Drought Forecasting Using Feed-Forward Recursive Neural Network", *Ecological Modelling*, Vol 198, pp 127–138.
31. Modarres, R.; (2006). "Streamflow drought time series forecasting", *Stochastic Environmental Research and Risk Assessment*, Vol 21, pp 223–233.
32. Orhan, O.; Ekercin, S. and Dadaser-Celik, F.; (2014). "Use of Landsat Land Surface Temperature and Vegetation Indices for Monitoring Drought in the Salt Lake Basin Area, Turkey". *The Scientific World Journal*, Vol 2014.
33. Rouse, J. W.; Haas, R.H.; Schell, J. A. and Deering, D.W.; (1973). :Monitoring vegetation systems in the Great Plains with ERTS", Third ERTS Symposium, NASA SP-351 I, pp 309-317.
34. Rulinda, C.M.; (2007). "Mining Drought from Remote Sensing Images", MSc thesis, Geo-information Science and Earth Observation.
35. Rulinda, C.M.; Dilo, A.; Bijker, W. and Steina, A.; (2012). "Characterising and Quantifying Vegetative Drought in East Africa Using Fuzzy Modelling and NDVI Data," *J. Arid Environments*, vol. 78, pp. 169-178.

