

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

محمد مهدی خوش‌گفتار^۱

مهدی آخوندزاده هنزائی^۲

ایمان خسروی^۳

تاریخ دریافت مقاله: ۹۵/۰۷/۱۸

تاریخ پذیرش مقاله: ۹۶/۰۸/۱۹

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 در خصوص 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 متحرک تجمعی (ARIMA) و مدل شبکه عصبی برای مدل‌سازی خشکسالی براساس داده‌های سنجش 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 ویژگی‌ها شامل شاخص اختلاف نرمال شده پوشش گیاهی (NDVI)، شاخص وضعیت پوشش گیاهی (VCI) و شاخص پوشش گیاهی - دمایی (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، TVX و VCI و شاخص هواشناسی SPI بررسی شده و به ترتیب مقادیر ۰/۰۵۶۶، ۰/۱۴۷۵ و ۰/۰۵۱۹ بدست آمد. در این میان، شاخص‌های NDVI و TVX دارای بیشترین همبستگی با داده‌های SPI بودند. بنابراین از شاخص‌های 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 - دمایی

۱- باشگاه پژوهشگران جوان و نخبگان، واحد خمین، دانشگاه آزاد اسلامی، خمین، ایران (نویسنده 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 ir.ut.ac.makhonz@

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 داده‌ها به سرعت برای پایش خشکسالی مرتبط با وضعیت پوشش گیاهی در دنیا مورد استفاده قرار گرفته‌اند. از سال ۱۹۹۹ تصاویر MODIS (MOD11 و MOD13) برای استخراج دمای سطح زمین (LST) و شاخص اختلاف نرمال شده پوشش گیاهی (NDVI) مورد استفاده قرار گرفته‌اند و از روی این داده‌ها، شاخص‌های دیگری همچون شاخص وضعیت پوشش گیاهی (VCI)، شاخص پوشش گیاهی - دمایی (TVX) و شاخص انحراف NDVI (DEV) نیز قابل محاسبه می‌باشد. در نهایت این شاخص‌ها برای پایش وضعیت پوشش گیاهی مورد استفاده قرار می‌گیرند. از آنجائی که داده‌های تصویری MODIS دارای قدرت تفکیک زمانی بالا با پوشش منطقه‌ای وسیع می‌باشند، به همین دلیل ابزار مناسبی برای تهیه نقشه از سری‌های زمانی وضعیت پوشش گیاهی در سطح جهانی و منطقه‌ای می‌باشند. از میان این متریک‌ها، NDVI بطور گسترده به منظور پایش پوشش گیاهی و خشکسالی مورد استفاده قرار گرفته است که این امر بدلیل رابطه قوی میان پوشش گیاهی و رطوبت خاک می‌باشد (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) (Tucker, Rulinda, C.M., et al, 2012:169) (Lotsch, A., et al, 2003:1774) (C.J. & Choudhury, B.J., 1987:243).

در برخی مطالعات از روش شبکه عصبی برای پایش بینی خشکسالی استفاده شده است. به عنوان مثال می‌شرا و دسای نشان دادند که شبکه‌های عصبی بازگشتی برای پایش 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 پایش بینی مقادیر SPI در یک ایستگاه در مرکز ایران به کار بردند (Dastorani, M.T., et al, 2011:39). باروآ و همکارانش وکسکین و همکارانش نیز از شبکه عصبی برای پایش و تجزیه و تحلیل شاخص‌های هواشناسی استفاده

خشکسالی یک وضعیت اقلیمی جدی می‌باشد که بسیاری از مناطق کره زمین را تحت تأثیر خود قرار داده است و در واقع پیچیده‌ترین خطر طبیعی می‌باشد. شدت خشکسالی اغلب با ترکیب متغیرهایی شامل بارش، دما، رطوبت، باد و رطوبت خاک اندازه‌گیری می‌شود. همانطور که خشکسالی در یک منطقه وسیع منتشر می‌شود و بطور آرام توسعه می‌یابد، دارای دینامیک‌های پیچیده‌ای می‌باشد. ایران همیشه در معرض خشکسالی بوده ولی در دهه‌های اخیر این موضوع روند افزایشی داشته است. علل اصلی بروز خشکسالی در ایران، عدم بارش کافی و فقدان سیستم مدیریتی مناسب در منابع آبی می‌باشد. اگر مقدار بارش در منطقه‌ای به صورت نرمال باشد ولی افزایش دما بصورت غیرعادی رخ دهد، می‌تواند سبب ایجاد شرایط خشکسالی شود. ریسک بروز خشکسالی را می‌توان ابتدا با مدل‌سازی صحیح و سپس تلاش برای مدیریت منابع آبی موجود به حداقل ممکن رساند.

خشکسالی اغلب به سه نوع تقسیم‌بندی می‌شود: هواشناسی، کشاورزی و آبی. خشکسالی هواشناسی زمانی رخ می‌دهد که بارش نرمال در یک منطقه بطور قابل ملاحظه‌ای در یک دوره زمانی کاهش یابد. روش‌های مختلف برای تعیین کیفیت شدت خشکسالی وجود دارد که از این بین می‌توان به شاخص شدت خشکسالی پالمر، شاخص شدت بارش استانداردسازی شده (SPI) که نسبت به دیگر روش‌ها رایج‌تر 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 می‌شود، درحالی‌که میانگین و انحراف معیار از داده‌های اقلیمی و هواشناسی محاسبه می‌شوند. از آنجائی که داده‌های بارش دارای توزیع نرمال نمی‌باشند، تبدیل مناسبی مانند تابع گاما روی داده‌ها بکار می‌برند تا داده‌هایی با توزیع نرمال بدست آید. داده‌های سنجش از دوری می‌توانند به منظور پایش

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 برازش 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 VCI، NDVI و TVX را به عنوان ورودی، و خروجی‌های SPI را به عنوان نمایشگر شدت خشکسالی در نظر می‌گیرند. به همین منظور، سری زمانی SPI برای دوره زمانی ۲۰۰۰-۲۰۱۴ و VCI، NDVI و TVX 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 پهنای 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 هواهای متنوع نیمه بیابانی، معتدل کوهستانی و سرد کوهستانی وجود دارد.

کردند (Keskin, M.E., et al, 2011:4469) (Barua, S., et al, 2010:193). ابریشم‌چی و همکاران با استفاده از مدل تلفیقی غیرخطی مبتنی بر شبکه عصبی، خشکسالی را در حوضه زاینده رود پیش‌بینی کردند (ابریشم‌چی و همکاران، ۱۳۸۵). کارآموز و همکاران با استفاده از شبکه عصبی انواع خشکسالی‌های کشاورزی و آبی را در حوضه گاوخونی در استان اصفهان پیش‌بینی نمودند (م، کارآموز و همکاران، ۱۳۸۵). 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 VCI، NDVI 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 می‌باشند (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, et al, 2007:679) (Hu, W.B., et al, 2007:679). مدل‌های ARIMA به منظور تجزیه و تحلیل و مدل‌سازی سری‌های زمانی آبی مورد استفاده قرار گرفته‌اند (Fernando, D.A.K., & Jayawardena, et al, 2008:1063) (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

می‌گذارد (ع. سلیمانی، ۱۳۸۹) (ف. محمودی‌کهن، ۱۳۸۹). با توسعه فناوری سنجنش از دور، امکان تهیه و جمع‌آوری 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.

۲-۱-۱-۲-۱ - شاخص‌های گیاهی

روش‌های مبتنی بر سنجنش 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. وقوع خشکسالی به دلیل کاهش شدید باران، کاهش عمل فتوسنتز 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 سبزیگی گیاهان و در واقع تشخیص میزان پوشش گیاهی در یک منطقه استفاده می‌شود، شاخص گیاهی تفاضلی نرمال شده (NDVI) است.

الف) شاخص NDVI: این شاخص، یکی از کاربردی‌ترین شاخص‌ها در جهان 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، اما مفهوم آن اولین بار توسط

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 بخشیده‌است. 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 سانتی‌گراد است. میانگین رطوبت سالانه اراک ۴۶٪ می‌باشد. به دلیل فراگیری شهر اراک در منطقه نیمه خشک، میزان بارندگی از میانگین کشور پایین‌تر است.

۲-۲-۲-۲ - داده‌های مورد استفاده و آماده سازی داده‌ها

۱-۲-۲-۱ - شاخص‌های ماهواره‌ای

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

مقدار NDVI در یک دوره زمانی بلندمدت و مقدار NDVI 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 ترسالی بالاست. معمولاً آستانه ۳۵ را برای تعیین وضعیت خشکسالی در نظر می‌گیرند (ع. سلیمانی، ۱۳۸۹). این شاخص نسبت به NDVI_i نتایج بهتری را نسبت به میزان بارندگی بویژه در مناطقی که از نظر جغرافیایی ناهمگون هستند، ارائه می‌دهد (ف. محمودی‌کهن، ۱۳۸۹).

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، ۱۳۸۷: ۱۳۹). این شاخص بصورت رابطه ۳ قابل تعریف است که در آن \overline{NDVI} میانگین طولانی مدت NDVI برای زمان مشابه است.

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

۲-۱-۲-۲- 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، ۱۳۸۴). 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، ۱۳۸۴). سنجنده‌های ماهواره‌ای متعددی در محدوده مادون قرمز حرارتی داده اخذ می‌کنند همانند Landsat 4/5، Landsat 7، Landsat 8، AVHRR و MODIS (ی. جویباری، ۱۳۹۳).

جدول ۱: طبقه‌بندی دوره‌های ترسالی و خشکسالی براساس

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

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

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

NDVI دارای یک سری محدودیت است که مهمترین آنها عبارتند از (ع. سلیمانی، ۱۳۸۹) 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، ۱۳۸۹).

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, 1997:621) ارائه شد. این شاخص شدت خشکسالی در یک دوره زمانی بلند مدت را برحسب مقدار کمینه و بیشینه NDVI برآورد می‌کند. فرمول این شاخص بصورت رابطه (۲) می‌باشد (ع. سلیمانی، ۱۳۸۹):

$$\text{رابطه ۲: } \text{VCI} = \frac{\text{NDVI}_i - \text{NDVI}_{\min}}{\text{NDVI}_{\max} - \text{NDVI}_{\min}} \times 100$$

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	$1 \leq SPI < 1.5$
تقریباً 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 وقوع خشکسالی را نشان دهند (Orhan, O., et al, 2014). زیرا این دو شاخص نسبت به خشکسالی عکس‌العمل 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 (ف). محمودی‌کهن، (۱۳۹۹). 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.

۲-۱-۲-۳- شاخص پوشش گیاهی - دما (TVX)

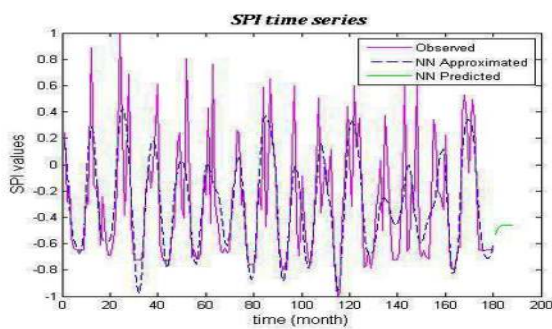
این شاخص نسبت بین LST و NDVI را نشان می‌دهد که توسط لامبینو ارلیش ارائه شد و از رابطه ۵ قابل محاسبه است (Lambin, E.F., & Ehrlich, D., 1996:463).

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


رابطه ۴:

۲-۲-۲- شاخص‌های هواشناسی

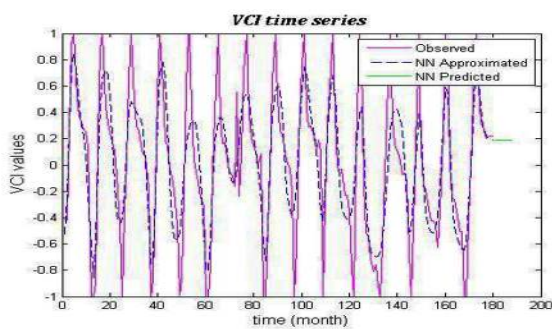
این شاخص‌ها مرتبط با داده‌های اقلیمی اندازه‌گیری شده در ایستگاه‌های هواشناسی مانند بارش، دما و



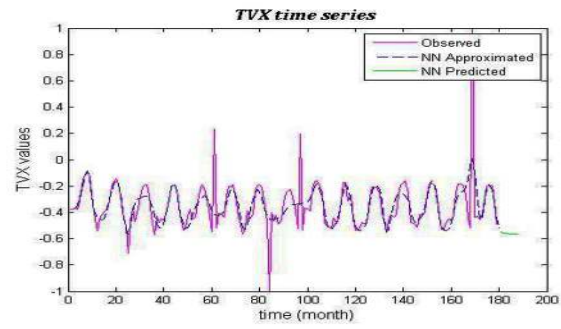
(ب)



(الف)



(د)



(ج)

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 AR, MA و ARMA 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 می‌شود. 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 فصلی $(P, D, Q)_s$ (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:

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

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

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

میزان تبخیر آب موجود در خاک می‌باشند. 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. باتوجه به اینکه آب‌های زیرزمینی و جریان آب‌های سطحی در ایجاد نابهنجاری‌های دراز مدت در بارش مؤثر می‌باشند، لذا شاخص SPI اساساً برای بازه‌های زمانی ۳، ۶، ۱۲، ۲۴ و ۴۸ ماهه محاسبه می‌شود. شاخص SPI برای هر منطقه براساس آمار بارندگی بلندمدت در یک دوره آماری دلخواه تعیین می‌شود. این شاخص از رابطه ۵ قابل محاسبه است (ف. محمودی‌کهن، ۱۳۸۹):

$$SPI = \frac{P - \mu(P)}{\sigma(P)} \quad \text{رابطه ۵:}$$

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 بر اساس 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:

$$f(s_i) = \text{logsig}(s_i) = \frac{1}{1 + \exp(-s_i)} \quad \text{تابع سیگموئید لگاریتمی}$$

$$f(s_i) = \text{purelin}(s_i) = s_i \quad \text{تابع خطی}$$

$$f(s_i) = \text{tansig}(s_i) = \frac{2}{1 + \exp(-2s_i)} - 1 \quad \text{تابع سیگموئید تانژانت هایپربولیک}$$

که در آن:
 رابطه ۱۱:

$$s_i = \sum_{j=1}^n w_{ij} x_j$$

سیگنال ورودی است که به عنوان جمع وزن دار 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:

$$\text{SSE} = \frac{1}{2} \sum_k (y_k - \hat{y}_k)^2 \quad \text{رابطه ۱۲:}$$

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

برای یک مسأله 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:

$$x_t = g(x_{t-1}, x_{t-2}, \dots, x_{t-p}, w) + \varepsilon_t \quad \text{رابطه ۱۳:}$$

Z_t سری زمانی مشاهده شده، θ_i و φ_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 p, d و q نیاز نیست که بزرگتر از ۲ باشند.

۲-۳- مدل شبکه عصبی

شبکه عصبی (NN)، یک سیستم کامپیوتری 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 معمولاً دارای سه لایه می‌باشد: لایه اول، لایه ورودی است که داده را به شبکه معرفی می‌کند، لایه دوم بنام 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_j بصورت رابطه ۹ می‌باشد:

$$x_i = g \left(\sum_{j=1}^h w_{ij} f(s_j) + b_k \right) \quad \text{رابطه ۹:}$$

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 (ص ۳۳)
 مقایسه روش‌های ARIMA و شبکه عصبی در مدل‌سازی ... / ۱۹۳

اعتبارسنجی و ۱۵٪ باقیمانده نیز بصورت آزمایشی وارد مسأله 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 توأم 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 NDVI، VCI، TVX 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 $g(\cdot)$ تابعی است که توسط ساختار شبکه و وزن‌های اتصال تعیین می‌شود. یک امتیاز بزرگ شبکه‌های عصبی، توانایی آنها در فراهم کردن یک نگاشت غیرخطی منطع 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 کولموگوروف، یک شبکه عصبی سه لایه توانایی استفاده برای حل هر مسأله 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، نرمال‌سازی داده‌ها در محدوده [۰-۱] 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، روند بهبود را 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




(ب)



(الف)



(د)



(ج)

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

و هواشناسی

به منظور تحلیل همبستگی میان شاخص های ماهواره ای و هواشناسی از ضریب تعیین (R2) استفاده شد و مقدار آن محاسبه گردید. آنچه که از جدول ۴ نتیجه می شود، این است که با توجه به مقادیر ضریب همبستگی بدست آمده میان شاخص ها، شاخص ماهواره ای TVX دارای همبستگی بیشتری با SPI می باشد. نتایج جدول ۴ بیانگر این مسأله است که شاخص بارش بطور مستقیم روی پوشش گیاهی تأثیر می گذارد که امری کاملاً صحیح و بدیهی می باشد، چراکه با افزایش بارش، میزان پوشش گیاهی نیز افزایش می یابد. در میان شاخص های پوشش گیاهی، شاخص NDVI نسبت به دو شاخص دیگر یعنی VCI و DEV دارای همبستگی بیشتری با شاخص SPI می باشد. بنابراین به نظر می رسد

بدست آمده برای شاخص ها

شاخص	مدل ARIMA	RMSE	MAE
NDVI	ARIMA(2,1,2)	۰/۰۷۷۰	۰/۰۶۱۶
VCI	ARIMA(2,1,1)	۳۷/۲۳۱۸	۳۰/۱۹۷۹
TVX	ARIMA(1,1,2)	۰/۲۶۵۸	۰/۲۰۵۹
SPI	ARIMA(1,1,1)	۱/۳۳۷۰	۱/۰۵۱۱

از آنجائی که مدل، مدل سازی شده و پارامترهای آن تخمین زده شده است، می توان داده ها را برای یک دوره زمانی مشخص پیش بینی نمود. البته این موضوع برای یک دوره زمانی کوتاه مدت مناسب می باشد. برای هر یک از شاخص ها، مقدار پیش بینی برای ۸ ماه آینده محاسبه گردید که نتایج آن در نگاره ۳ نمایش داده شده است.

۴-۳- تعیین همبستگی میان شاخص های ماهواره ای

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 پیش‌بینی 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 پیش‌وضعیت آن ارائه داده است.

۶- منابع و مآخذ

۱. آخوندزاده، م؛ (۱۳۸۴). تهیه نقشه‌های حرارتی سطح زمین با استفاده از تصاویر MODIS. پایان‌نامه کارشناسی ارشد، دانشگاه تهران، پردیس دانشکده‌های فنی، گروه مهندسی نقشه‌برداری.
۲. 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.
۳. جلیلی، ش؛ مرید، س؛ ضیائی‌ان فیروزآبادی، پ؛ (۱۳۸۷). مقایسه عملکرد شاخص‌های ماهواره‌ای و هواشناسی در پیش‌بینی خشکسالی. مجله تحقیقات آب و خاک ایران، دوره ۳۹، ش ۱، ص ۱۴۹-۱۳۹.
۴. جویباری، ی؛ (۱۳۹۳). تهیه نقشه ضریب گسیل و دما با استفاده از تصاویر ماهواره لندست-۸. پایان‌نامه کارشناسی ارشد، دانشگاه تهران، پردیس دانشکده‌های فنی، گروه مهندسی نقشه‌برداری.
۵. سلیمانی، ع؛ (۱۳۸۹). تحلیل خطرپذیری خشکسالی. پایان‌نامه کارشناسی ارشد، دانشگاه تهران، پردیس

استفاده از این شاخص‌ها در پیش‌بینی و پیش‌وضعیت 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 NDVI، VCI، TVX و SPI به ترتیب ۰/۱۹۴۴، ۰/۲۱۹۱، ۰/۱۲۹۵ و ۰/۲۹۹۰ و مقادیر نظیر حاصل از روش ARIMA به ترتیب ۰/۰۷۷۰، ۰/۲۶۵۸، ۳۷/۲۳۱۸ 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 NDVI و VCI، همبستگی شاخص NDVI با شاخص SPI 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. Krieglner 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.

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.

