

ترکیب شبکه عصبی و تبدیل موجک به منظور پیش‌بینی خشک‌سالی کشور ایران با استفاده از داده‌های ماهواره‌ای مادیس و TRMM

رامین مختاری دهکردی^۱، مهدی آخوندزاده هنزائی^{۲*}

۱- دانشجوی کارشناسی ارشد سنجش از دور دانشکده مهندسی نقشه برداری و اطلاعات مکانی- پردیس دانشکده‌های فنی- دانشگاه تهران

۲- استادیار گرایش سنجش از دور دانشکده مهندسی نقشه برداری و اطلاعات مکانی- پردیس دانشکده‌های فنی- دانشگاه تهران

تاریخ دریافت مقاله: ۱۳۹۸/۰۵/۰۲ تاریخ پذیرش مقاله: ۱۳۹۸/۰۹/۰۶

چکیده

خشک‌سالی را می‌توان به عنوان یکی از بحران‌های طبیعی در هر منطقه‌ای نام برد. در این پژوهش یکی از عوامل مهم در خشک‌سالی یعنی پوشش گیاهی مد نظر قرار گرفته شده است. بدین منظور از تصاویر محصول ماهانه پوشش گیاهی و پوشش برف سنجنده مادیس و محصول بارش ماهواره TRMM از سال ۲۰۰۹ تا سال ۲۰۱۸ برای منطقه مورد مطالعاتی کشور ایران استفاده شده است. بعد از پیش‌پردازش‌های اولیه با استفاده از روش شبکه عصبی مصنوعی و نیز روش ترکیبی شبکه عصبی و تبدیل موجک، به پیش‌بینی شاخص نرمالایز شده تفاوت پوشش گیاهی پرداخته شده است. بعد از آموزش دو الگوریتم با استفاده از سری زمانی این شاخص و نیز سری زمانی میزان پوشش برف و بارش از سال ۲۰۰۹ تا سال ۲۰۱۷، شاخص نرمالایز شده تفاوت پوشش گیاهی برای دوازده ماه از سال ۲۰۱۸ پیش‌بینی شده است که در نهایت با مقادیر واقعی آن مورد ارزیابی قرار گرفته است. نتایج و دقت پیش‌بینی برای این دو الگوریتم متفاوت بوده و در کل روش ترکیبی شبکه عصبی و تبدیل موجک دارای دقت بالاتری نسبت به روش شبکه عصبی بوده است؛ به طوری که میانگین دوازده ماه سال ۲۰۱۸ برابر با خطای جذر میانگین مربعات ۰/۰۵۵ و ضریب تشخیص ۰/۸۰۴ بوده است. همچنین نتایج نشان داده است که در هر دو روش دقت شاخص مذکور در ماه‌های ابتدایی سال ۲۰۱۸ نسبت به ماه‌های انتهایی بهتر است؛ از این رو می‌توان از این روش برای پیش‌بینی این شاخص که یکی از پارامترهای خشک‌سالی محسوب می‌شود؛ استفاده نمود.

کلید واژه‌ها: خشک‌سالی، شبکه عصبی، تبدیل موجک، سری زمانی، پوشش گیاهی.

* نویسنده مکاتبه کننده: تهران- خیابان کارگر شمالی- بالاتر از تقاطع جلال آل احمد- دانشکده فنی دانشگاه تهران- دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی.

تلفن: ۰۲۱۶۱۱۱۴۵۲۲

Email: makhondz@ut.ac.ir

۱- مقدمه

خشک‌سالی یک بحران طبیعی بوده که می‌تواند در هر منطقه و هر آب‌وهوایی به صورت متناوب ایجاد شود. این پدیده نسبت به سایر بلایای طبیعی دیگر به صورت تدریجی و در یک دوره زمانی نسبتاً طولانی مدت که اثرات آن می‌تواند بعد از چند سال ماندگار باشد رخ می‌دهد [۱]. پدیده خشک‌سالی می‌تواند اثرات مخرب و زیان‌آوری بر روی عوامل مختلفی از جمله جوامع انسانی، محیط زیست و اقلیم منطقه داشته باشد؛ به همین دلیل مطالعه و نظارت بر این پدیده در کشور-هایی که به صورت مکرر با این پدیده مواجه‌اند امری بدیهی و ضروری به حساب می‌آید [۲]. امروزه می‌توان با استفاده از تکنیک‌های سنجش از دور، نظارتی دقیق‌تر بر این پدیده داشت. تصاویر و داده‌های سنجش از دور نسبت به داده‌های هواشناسی به صورت پیوسته از نظر مکانی به اخذ اطلاعات می‌پردازند و همچنین از دیگر مزایای این نوع از داده‌ها می‌توان به توان تفکیک مکانی و زمانی آنها اشاره کرد [۳]. پدیده خشک‌سالی را می‌توان به چهار دسته از جمله خشک‌سالی هواشناسی، خشک‌سالی کشاورزی، خشک‌سالی هیدرولوژیکی و در نهایت خشک‌سالی اجتماعی تقسیم بندی نمود [۴]. منظور از خشک‌سالی کشاورزی مربوط به پوشش گیاهی می‌باشد و زمانی که میزان رطوبت خاک از میزان آب مورد نیاز گیاه برای رشد و سلامت گیاه پایین‌تر و همچنین پوشش گیاهی نسبت به دوره‌های زمانی پیشین منطقه ضعیف‌تر باشد این نوع از خشک‌سالی پدید می‌آید [۵].

به منظور بررسی و پایش مکانی و زمانی خشک‌سالی، روش‌ها متفاوتی وجود دارد که یکی از آنها استفاده از شاخص‌های خشک‌سالی می‌باشد [۶]. مطالعات زیادی در مورد انواع شاخص‌های مربوط به خشک‌سالی با استفاده از داده‌های ماهواره‌ای از جمله داده‌های مربوط به پوشش گیاهی و حرارتی در مناطق مختلف جهان انجام شده‌است، ولی با این وجود هنوز چالش‌های عمده‌ای در مورد افزایش دقت و پیش‌بینی بهتر این

پدیده وجود دارد. این پدیده بیشتر به صورت غیر خطی عمل می‌کند در حالی که بیشتر مطالعات از مدل‌های خطی استفاده کرده‌اند [۷]. در یک مطالعه، ابتدا یک سری زمانی از شاخص غیرخطی تنش خشک‌سالی ($NADI^1$) با استفاده از میزان بارش در ایستگاه‌های هواشناسی در کشور استرالیا، تهیه شده و سپس با استفاده از دو روش شبکه عصبی چندمرحله‌ای بازگشتی و شبکه عصبی چندمرحله‌ای مستقیم به پیش‌بینی این شاخص تا شش ماه پرداخته شده است. نتایج این پژوهش نشان می‌دهد که هر دو روش شامل شبکه عصبی چند مرحله‌ای بازگشتی و شبکه عصبی چند مرحله‌ای مستقیم توانسته‌اند پیش‌بینی یک ماهه را با دقت بالاتری نسبت به پیش‌بینی‌های دو و سه ماهه به انجام برسانند و در دوره پیش‌بینی‌های دو و سه ماهه، روش شبکه عصبی چند مرحله‌ای بازگشتی نسبت به روش شبکه عصبی چند مرحله‌ای مستقیم دقت بهتری داشته است [۸]. در مطالعه‌ای ابتدا با استفاده از داده‌های بارش در ایستگاه‌های هواشناسی، شاخص بارش استاندارد شده (SPI^2) را به دست آورده‌اند و سپس با استفاده از سه روش یادگیری ماشین از جمله روش شبکه عصبی مصنوعی (ANN^3)، بردار رگرسیون پشتیبان (SVR^4) و شبکه عصبی-تبدیل موجک ($WA-ANN^5$) به پیش‌بینی این سری زمانی در دوره‌های (SPI) سه و شش ماهه پرداختند که نتایج نشان داد که روش شبکه عصبی موجک دقت بهتری نسبت به دو روش دیگر داشته است [۹]. در پژوهشی با استفاده از داده‌های بارش در کشور ایتالیایی، شاخص (SPI) تولید و سپس با استفاده از روش‌های یادگیری ماشین از جمله روش (ANN) و (SVR) و همچنین از

¹ Nonlinear Aggregated Drought Index² Standardized Precipitation Index³ Artificial Neural Networks⁴ Support Vector Regression⁵ Wavelet Artificial Neural Networks

گرمسیری ($TRMM^7$) که همگی مربوط به داده‌های بارش می‌باشند به منظور مدل‌سازی شاخص (SPI) از الگوریتم‌های چند لایه پرسپترون (MLP^8)، سیستم استنتاج فازی عصبی تطبیقی، (SVR) استفاده نموده و در نهایت با شاخص (SPI) حاصل شده با داده‌های هواشناسی ارزیابی شده است. در این پژوهش که به عنوان یک روش ادغام داده نیز یاد شده است فقط از داده‌های ماهواره‌ای بارش به منظور مدل‌سازی شاخص (SPI) که از نوع خشک‌سالی هواشناسی می‌باشد، استفاده شده است [۱۲]. در مطالعه ای دیگر با استفاده از داده‌های ماهواره‌ای از قبیل شاخص ($NDVI$) و شاخص نرمالایز شده تفاوت آبی ($NDWI^9$) سنجنده مادیس به پیش‌بینی سری زمانی شاخص (SPI) با روش ترکیبی تبدیل موجک و شبکه عصبی و نیز روش ترکیبی تبدیل موجک و بردار رگرسیون پشتیبان انجام شده است [۱۳]. نتایج نشان داده‌است که هر دو روش توانسته‌اند نتایج مناسبی را ارائه نمایند. در این مطالعه شاخص SPI با استفاده از شاخص پوشش گیاهی ($NDVI$) پیش‌بینی گردیده است در صورتی که شاخص ($NDVI$) در وقوع تغییرات شاخص (SPI) بی‌تاثیر است و تغییرات در شاخص $NDVI$ می‌تواند بعد از وقوع تغییرات در شاخص (SPI) ایجاد گردد. به طوری که کاهش و یا افزایش در میزان نزولات جوی با یک تاخیر زمانی می‌تواند بر پوشش گیاهی اثرگذار باشد. بنابراین می‌توان از شاخص (SPI) به منظور پیش‌بینی شاخص ($NDVI$) استفاده کرد. در مطالعه‌ای دیگر نیز با استفاده از تصاویر ماهواره‌ای $AVHRR$ شاخص‌های خشک‌سالی از قبیل شاخص ($NDVI$)، شاخص وضعیت پوشش گیاهی (VCI^{10}) و شاخص وضعیت دما (TCI^{11}) به

روش‌های بردار پشتیبان-تبدیل موجک ($WA-SVR^1$) و شبکه عصبی مصنوعی موجک ($WA-ANN$) بهره گرفته شد که بر اساس نتایج، مدل ($WA-ANN$) نتایج بهتری از خود نشان داده‌است [۱۰]. در دو مطالعه دیگر فقط با استفاده از داده‌های بارش که به عنوان داده‌های هواشناسی محسوب می‌شود به پیش‌بینی شاخص (SPI) پرداخته‌اند بنابراین می‌توان از داده‌های ماهواره‌ای نیز به منظور بهبود مدل‌سازی و پیش‌بینی این پدیده استفاده نمود [۹ و ۱۰]. در تحقیقی با استفاده از محصولات سنجنده مادیس از جمله دمای سطح زمین، شاخص نرمالایز شده تفاوت پوشش گیاهی ($NDVI^2$)، تبخیر و تعرق و میزان بارش با استفاده از داده‌های ماهواره $TRMM^3$ از سال ۲۰۰۰ تا سال ۲۰۱۲ در کشور ایالات متحده آمریکا به مدل‌سازی شاخص SPI با استفاده از سه روش جنگل تصادفی، درختان رگرسیون افزایش یافته و الگوریتم کابیسست پرداخته‌اند و نتایج نشان می‌دهد که روش جنگل تصادفی نسبت به دو روش دیگر توانسته است مدل‌سازی را بهتر انجام دهد. در همین تحقیق به مدل‌سازی شاخص (SPI) به عنوان خشک‌سالی هواشناسی در ایستگاه‌های هواشناسی پرداخته شده است با این وجود دو الگوریتم کابیسست و درختان رگرسیون افزایش یافته به خوبی نتوانسته‌اند مدل‌سازی را انجام دهند. همچنین در این پژوهش نوع منطقه مورد مطالعاتی از نظر اقلیم نیز در روند مدل‌سازی تاثیرگذار بوده‌است [۱۱]. در مقاله‌ای دیگر از داده‌هایی از قبیل پروژه جهانی بارش ($GPCP^4$)، ادغام داده‌های بارش ($CMAP^5$)، داده‌های بارش ماهواره‌ای اپتیک و ماکروبو با توان تفکیک مکانی بالا ($CHOMPS^6$) و ماموریت اندازه‌گیری بارش باران

Microwave Precipitation from Satellites

⁷ Tropical Rainfall Measuring Mission

⁸ Multilayer Perceptron

⁹ Normalized Difference Water Index

¹⁰ Vegetation Condition Index

¹ Wavelet Support Vector Regression

² Normalized Difference Vegetation Index

³ Tropical Rainfall Measuring Mission

⁴ Global Precipitation Climatology Project

⁵ CPC Merged Analysis of Precipitation

⁶ CICS High-Resolution Optimal Interpolation

داده‌های ماهواره‌ای قابل اندازه‌گیری است. به منظور پیش بینی دقیق تر پدیده مورد مطالعه در این پژوهش، از محصولات پوشش برف سنجنده مادیس و همچنین محصول میزان بارش ماهواره TRMM استفاده شده است. شاخص $NDVI$ یکی از مهم‌ترین عوامل خشکسالی کشاورزی محسوب می‌شود [۱۵]. از این رو این شاخص و شاخص‌های وابسته به آن از جمله شاخص (VCI) ، می‌توانند وضعیت خشکسالی کشاورزی را نشان دهند و برای پیش‌بینی این شاخص، روش‌های خطی به خوبی نمی‌توانند مدل‌سازی و پیش‌بینی را انجام دهند. بنابراین می‌توان از روش‌های یادگیری ماشین استفاده نمود که در مطالعات گذشته نیز اغلب از همین روش‌ها برای پیش‌بینی و مدل‌سازی داده‌های هیدرولوژیکی و هواشناسی استفاده شده است. در این پژوهش از روش شبکه عصبی مصنوعی و همچنین تبدیلات موجک به منظور پیش‌بینی دقیق‌تر پدیده خشکسالی که می‌تواند تاثیر فراوانی بر مدیریت جوامع انسانی داشته باشد، استفاده می‌شود.

۲- مبانی تئوری تحقیق

در این پژوهش به منظور مدل‌سازی شاخص پوشش گیاهی ($NDVI$) از روش شبکه عصبی مصنوعی و همچنین تبدیل موجک استفاده شده است، بنابراین بررسی اجمالی مبانی تئوری شبکه‌های عصبی مصنوعی و تبدیل موجک ضروری به نظر می‌رسد.

۲-۱- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی، جز روش‌های محاسباتی می‌باشند که رفتاری مشابه رفتار شبکه‌های عصبی طبیعی دارند. شبکه‌های عصبی مصنوعی می‌توانند با استفاده از یک سری از نمونه‌های تجربی موجود، آموزش دیده و برای داده‌های جدید به کار گرفته شوند. مزایایی از جمله ساختار غیرخطی، قابل استفاده با داده‌های خطا دار و همچنین عدم نیاز به آگاهی قبلی نسبت به سیستم مورد مطالعه باعث شده است که این روش در بسیاری از مطالعات مورد استفاده قرار گرفته و نتایج خوبی از خود نشان دهد. البته از معایب این روش می-

عنوان ورودی‌های شبکه عصبی MLP ، شبکه عصبی (RBF^2) و SVR و در نهایت شاخص SPI به عنوان خروجی در نظر گرفته شده است که نتایج نشان می‌دهد که روش شبکه عصبی MLP دارای بیشترین دقت نسبت به دو روش دیگر بوده است [۱۴].

در بیشتر مطالعات انجام شده با استفاده از داده‌های هواشناسی به مدل‌سازی و پیش‌بینی میزان بارش منطقه در ایستگاه‌های هواشناسی انجام شده است که مربوط به خشکسالی هواشناسی است ولی با این حال می‌توان به منظور بهبود دقت در پیش‌بینی خشکسالی با استفاده از داده‌های سنجش از دوری تنوع نوع داده‌ها را افزایش داد. با افزایش تنوع نوع داده‌های ماهواره‌ای می‌توان به درک درستی از خشکسالی رسید. همچنین در بعضی از مطالعات انجام شده از شاخص‌های خشک-سالی کشاورزی به منظور پیش‌بینی خشکسالی هواشناسی استفاده شده است در صورتی که خشک-سالی کشاورزی بعد از وقوع خشکسالی هواشناسی رخ می‌دهد. بنابراین از آنجایی که خشکسالی هواشناسی ابتدا به وقوع می‌پیوندد و بعد از آن خشکسالی کشاورزی، در روند پیش‌بینی خشکسالی کشاورزی باید میزان نزولات جوی و تاثیرات تاخیر زمانی آن بر پوشش گیاهی لحاظ گردد تا این پدیده را بتوان بهتر پیش‌بینی کرد. در این تحقیق هدف استفاده از عوامل تاثیرگذار بر روند خشکسالی کشاورزی از جمله میزان نزولات جوی با استفاده از داده‌های ماهواره‌ای می‌باشد تا بتوان به دقت مناسبی برای پیش‌بینی این پدیده دست یافت. همچنین در مطالعات گذشته عامل پوشش برف که به عنوان یکی از عوامل موثر بر روند خشک-سالی شناخته شده است، به طور مستقیم در مدل‌سازی و پیش‌بینی خشکسالی کشاورزی در نظر گرفته نشده است. بنابراین دو عامل میزان بارش و برف تاثیر زیادی بر میزان پوشش گیاهی منطقه دارد که با استفاده از

^۱ Temperature Condition Index

^۲ Radial Basis Function

توان به خاصیت بسته بودن شبکه‌های عصبی مصنوعی یا به اصطلاح جعبه سیاه بودن آن اشاره داشت. شبکه‌های عصبی مصنوعی در واقع از شبکه‌ای از نورون‌های متصل به هم تشکیل شده‌است. چگونگی ارتباط و رفتار خطوط ارتباطی، نوع شبکه را مشخص می‌کند [۱۶]. شبکه‌های عصبی مصنوعی را می‌توان بر اساس ساختار شبکه طبقه‌بندی کرد. به عنوان مثال شبکه‌های عصبی چندلایه پرسپترون ($MLP-NN$) یکی از پرکاربردترین شبکه‌های عصبی مصنوعی می‌باشد. در این نوع از شبکه‌ها نورون‌ها به صورت لایه به لایه قرار گرفته‌اند و سیگنال‌ها از یک لایه ورودی به سمت یک لایه خروجی و در طول شبکه‌ای از خطوط ارتباطی در جریان می‌باشند [۱۷]. در این نوع شبکه‌ها، نورون‌ها از لایه‌ای با لایه دیگر در ارتباط می‌باشند ولی میان نورون‌های یک لایه ارتباطی وجود ندارد. این نوع شبکه‌ها دارای یک لایه ورودی، یک لایه خروجی و حداقل یک لایه پنهان می‌باشند. لایه ورودی، داده‌های ورودی را دریافت کرده و در شبکه پخش می‌نماید. لایه خروجی لایه‌ای است که خروجی مورد نظر تولید گشته و پردازش‌های نهایی در این لایه صورت می‌گیرد. لایه‌های پنهان به عنوان لایه‌هایی می‌باشد که محاسبات اصلی بین لایه‌های ورودی و خروجی را انجام می‌دهد. هر یک از خطوط ارتباطی بین نورون‌ها دارای وزنی است و مقادیر ورودی در هنگام عبور از این خطوط وزن مربوطه ضرب می‌گردد. در هر نورون، این حاصل ضرب‌ها به عنوان ورودی‌های نورون، جمع شده و پس از عبور از یک تابع انتقال، خروجی نظیر نورون تولید می‌شود که خود یکی از ورودی‌های نورون‌های لایه بعد شبکه عصبی خواهد بود. شبکه‌های عصبی را می‌توان به دو دسته بانظارت و بدون نظارت تقسیم‌بندی کرد که شبکه‌های عصبی MLP جز دسته شبکه‌های عصبی با نظارت می‌باشند. در این نوع شبکه‌ها وزن ارتباط میان نورون‌ها بر اساس اختلاف بین خروجی شبکه و

¹ Multi-Layer Perceptron Neural Network

خروجی واقعی تنظیم می‌شود [۱۸ و ۱۹]. امروزه شبکه‌های عصبی در مسائل مختلفی از دنیای واقعی به کار گرفته می‌شوند و کاربردهای مختلفی از خود نشان داده‌اند که از مهم‌ترین کاربردهای آن می‌توان به تقریب توابع، طبقه‌بندی، خوشه‌بندی، بازیابی داده‌ها و موارد مختلف دیگر اشاره داشت. یکی از مهم‌ترین کاربردهای شبکه عصبی این است که می‌توان از آن به عنوان یک ابزار قدرتمند برای پیش‌بینی سری‌های زمانی استفاده نمود.

۲-۲- تبدیل موجک

تبدیل موجک در واقع شکل پیشرفته‌تر سری فوریه می‌باشد و به نوعی مکمل سری فوریه است که می‌تواند در برخورد با سیگنال، نسبت به سری فوریه بهتر عمل نماید. این تبدیل می‌تواند اطلاعات زمان و فرکانس را از سیگنال متغیر در زمان استخراج کند. منظور از تابع موجک مادر، تابعی است که اندازه آن می‌تواند در فضای پیوسته صفر شود. شکل ریاضی این تابع به صورت (رابطه ۱)) است که $\Psi(t)$ تابع موجک است [۲۰].

رابطه (۱)
$$\int_{-\infty}^{+\infty} \Psi(t) dt = 0$$
 توابع مختلفی برای آنالیز سیگنال با استفاده از تبدیل موجک استفاده می‌شود که می‌توان به موجک هار، مرلت، دابچیز، میر اشاره داشت. با استفاده از تاخیر و تغییر مقیاس موجک مادر، $\Psi_{(a,b)}(t)$ را ایجاد نمود که در (رابطه ۲)) آورده شده است. منظور از a انتقال و b مقیاس است.

رابطه (۲)
$$\Psi_{(a,b)}(t) = |a|^{-\frac{1}{2}} \Psi\left(\frac{t-b}{a}\right)$$
 $a \in \mathbb{R}, b \in \mathbb{R}, a \neq 0$ تبدیلات موجک را می‌توان به دو دسته پیوسته و گسسته تقسیم‌بندی نمود. بیشتر سیگنال‌های موجود به صورت ناپیوسته (گسسته) در دسترس محققان می‌باشد و به همین علت از تبدیلات موجک گسسته استفاده می‌شود. این تبدیل از بانک‌های فیلتر برای بازسازی سطح چند تفکیک زمان فرکانس بهره می‌برد. این تبدیل به صورت (رابطه ۳)) تعریف می‌شود که k

ضریب مقیاس می‌باشد [۲۱].

$$W_f(a, b) = |a|^{-\frac{1}{2}} \sum_{K=1}^N f(k\Delta t) \Psi^* \left(\frac{K\Delta t - b}{a} \right) \quad (۳) \text{ رابطه}$$

در این رابطه Ψ^* تابع مختلط و مزدوج $\Psi(t)$ است. $W_f(a, b)$ ضریب موجک است که تحت سطوح تجزیه و زمان‌های مختلف به دست آمده است. N تعداد گام زمانی گسسته و Δt فواصل زمانی نمونه است. این تابع می‌تواند ویژگی‌های سری زمانی اصلی را در زمان b و دامنه فرکانس a ، در زمان یکسان منعکس سازد. انتخاب تابع موجک و مقیاس موجک دو موضوع حائز اهمیت در تبدیل موجک می‌باشند [۲۲]. با استفاده از تبدیل موجک گسسته می‌توان به تجزیه سیگنال پرداخت به طوری که سیگنال مربوطه به مجموعه‌ای از فرکانس‌های بالا و پایین تجزیه می‌شود که اولین بار توسط ملات مطرح گردید [۲۳]. اگر این تبدیل در سطح تجزیه z باشد D_j که نشانگر زیر سری جزئی است را می‌توان به صورت (رابطه (۴)) تعریف نمود.

$$D_j(t) = \sum_{K \in Z} W_f(a, b) \Psi_{(a, b)}(t) \quad (۴) \text{ رابطه}$$


در رابطه (۴) $W_f(a, b)$ ضریب موجک در مقیاس a و زمان b بوده‌است و $\Psi_{a, b}(t)$ موجک مادر تبدیل یافته

یا به اصطلاح موجک دختر در مقیاس a و b نامیده می‌شود که برای بازسازی سیگنال اصلی (رابطه (۵)) می‌توان با جمع کردن D_j ها به آن دست یافت.

$$S = \sum_{j \in Z} D_j \quad (۵) \text{ رابطه}$$

۳- منطقه مورد مطالعه و داده‌های مورد استفاده

منطقه مورد مطالعه، کشور جمهوری اسلامی ایران می‌باشد. کشور ایران دارای فلاتی مرتفع است که در عرض جغرافیایی بیست و پنج تا چهل درجه در نیم کره شمالی و در منطقه گرمی واقع شده است. مناطق کویری و نیمه کویری بیش از نیمی از مساحت کشور را اشغال نموده است. حدود یک سوم از ایران نیز کوهستانی است و بخش کوچکی از ایران شامل جلگه جنوب دریای خزر و جلگه خوزستان می‌باشد. ایران دارای تنوع اقلیمی بالایی می‌باشد. از شمال تا جنوب کشور، به تدریج با مناطق آب‌وهوایی متفاوتی مواجه می‌شویم. ایران از نظر بارندگی جزو مناطق آب و هوایی خشک و نیمه خشک به شمار می‌رود. میزان بارش سالانه در نقاط مختلف کشور و در فصول مختلف سال متغیر است. در شکل (۱) موقعیت جغرافیایی منطقه مورد مطالعه نشان داده شده‌است.



شکل ۱: موقعیت جغرافیایی منطقه مورد مطالعاتی

در این مطالعه از محصول تصاویر پوشش گیاهی و پوشش برف سنجنده مادیس و همچنین محصول بارش

بارش ماهانه 3B43 ماهواره TRMM با قدرت تفکیک مکانی ۰/۲۵ درجه در کمربند جهانی از عرض جغرافیایی ۵۰ درجه جنوبی الی ۵۰ درجه شمالی از سال ۲۰۰۹ تا پایان سال ۲۰۱۸ از سایت مربوطه^۳ و در کل ۱۲۰ تصویر دریافت گردیده است.

با توجه به این که سیستم مختصات جغرافیایی تصاویر سنجنده مادیس سینوسی می باشد؛ برای پردازش صحیح جغرافیایی این تصاویر، سیستم تصویر آن ها به دیتوم جهانی (WGS1984^۴) به عنوان یک سیستم تصویر با مختصات متریک تعریف گردید. این عمل با استفاده از افزونه MCTK که بر روی نرم افزار (ENVI^۵) نصب می شود انجام شده است. تصاویر پوشش برف و بارش با استفاده از روش نزدیک ترین همسایه به قدرت تفکیک مکانی محصول پوشش گیاهی (یک کیلومتر) باز نمونه برداری شده است.

۴- روش تحقیق

در این مطالعه از دو روش به منظور پیش بینی شاخص پوشش گیاهی استفاده شده است. در روش اول تنها از روش شبکه عصبی مصنوعی و در روش دوم از ترکیب تبدیل های موجک و شبکه عصبی استفاده گردیده که در زیر به توضیح هر یک از روش ها پرداخته شده است.

۴-۱- روش شبکه عصبی

در این تحقیق ابتدا بدون هیچ پیش پردازشی، از شبکه عصبی برای مدل سازی شاخص (NDVI) استفاده شده است. بدین منظور پیش بینی شاخص (NDVI) با استفاده از محصول پوشش گیاهی و پوشش برف سنجنده مادیس و داده بارش ماهواره TRMM برای منطقه کشور ایران انجام شده است. داده های ماهانه از سال ۲۰۰۹ تا سال ۲۰۱۸ مورد استفاده قرار گرفته است که به منظور آموزش الگوریتم از سال ۲۰۰۹ تا پایان سال ۲۰۱۷ هفتاد درصد به عنوان آموزش شبکه،

ماهواره TRMM استفاده شده است. سنجنده مادیس به دلیل دارا بودن توان تفکیک مکانی، زمانی و طیفی مناسب ابزار بسیار کارآمدی جهت بررسی عوامل مرتبط با خشکسالی از جمله میزان پوشش گیاهی، دمای سطح زمین، تبخیر و میزان پوشش برف می باشد. این سنجنده دارای ۳۶ باند طیفی در محدوده ۰/۴ میکرومتر تا ۱۴/۴ میکرومتر می باشد که بیست باند آن در محدوده مرئی و ۱۶ باند آن در محدوده حرارتی است. قدرت تفکیک مکانی برای باندهای ۲۱، ۲۵۰ متر، برای باندهای ۳ الی ۷، ۵۰۰ متر و در نهایت برای باندهای ۸ الی ۳۶، یک کیلومتر می باشد [۲۴]. ماهواره TRMM پروژه ای مشترک میان سازمان فضایی آمریکا و آژانس اکتشاف فضایی ژاپن به منظور پایش بارش در مناطق حاره ای بوده و تا به امروز اطلاعات با ارزشی فراهم آورده است. این ماهواره شامل سنجنده های غیرفعال برای باندهای مرئی و مادون قرمز، ماکروویو و همچنین شامل یک رادار هواشناسی است [۲۵]. به منظور تشکیل سری زمانی شاخص پوشش گیاهی، از محصول سطح سه شاخص های پوشش گیاهی سنجنده مادیس (MOD13A3) با توان تفکیک مکانی یک کیلومتر و توان تفکیک زمانی ماهانه از سال ۲۰۰۹ تا پایان سال ۲۰۱۸ از سایت مربوطه^۱ و همچنین به علت وسعت زیاد منطقه مطالعاتی پنج تصویر کل منطقه مورد مطالعه را پوشش داده که این تصاویر شامل تصاویر (۰۶۷۲۲h-۰۵۷۲۲h-۰۶۷۲۲h-۰۵۷۲۳h) بوده و در کل ۶۰۰ تصویر مورد استفاده قرار گرفته شده است. استفاده از محصول پوشش برف (MOD10CM) مربوط به سنجنده مادیس با قدرت تفکیک ۰/۵ درجه و قدرت تفکیک زمانی ماهانه که این تصاویر پوشش جهانی را در برمی گیرند، از سال ۲۰۰۹ تا پایان سال ۲۰۱۸ از سایت مربوطه^۲ و در کل ۱۲۰ تصویر دریافت گردیده است. استفاده از محصول

^۳ <https://mirador.gsfc.nasa.gov>

^۴ World Geodetic System 1984

^۵ Environment for Visualizing Images

^۱ <https://earthexplorer.usgs.gov>

^۲ <https://search.earthdata.nasa.gov>

شبکه‌های دارای یک لایه پنهان، قادرند که هر تابع غیر خطی پیچیده‌ای را با هر دقتی تخمین بزنند [۲۷]. در بیشتر مطالعات گذشته به منظور تعیین تعداد لایه‌های پنهان و تعداد نورون‌های موجود در لایه‌های پنهان به صورت تجربی و روش آزمون و خطا استفاده شده است. در این پژوهش برای یافتن بهترین ساختار معماری شبکه، چندین نوع ساختار از شبکه برای پیش‌بینی شاخص (NDVI) ۱۲ ماه سال ۲۰۱۸ پیاده‌سازی شده است.

۴-۲- روش شبکه عصبی و تبدیل موجک

به منظور دستیابی به نتایج مدل ترکیبی تبدیل موجک و شبکه عصبی، ابتدا باید با استفاده از تبدیل موجک، پارامترهای ورودی به زیر سیگنال‌هایی تبدیل شود که این عملیات را تجزیه سیگنال^۱ گویند. در واقع هر سیگنال اصلی بعد از عملیات تجزیه شدن با استفاده از تبدیل موجک تبدیل به دو سیگنال، تقریب سیگنال اصلی^۲ و جزئیات سیگنال اصلی^۳ می‌شود که در اصل سیگنال تقریب معرف فرکانس پایین سیگنال اصلی و سیگنال جزئیات معرف فرکانس بالا سیگنال اصلی می‌باشند. بعد از انجام مرحله اول تجزیه سیگنال اصلی، می‌توان سیگنال جزئیات را به چندین مرحله تجزیه کرد که برآورد تعداد مراحل تجزیه از (رابطه (۷)) حاصل می‌شود [۲۸].

$$L = \text{Int}[\log(N)] \quad \text{رابطه (۷)}$$

در این رابطه L درجه تجزیه پیشنهادی و N تعداد سری زمانی است. یکی از نکات حائز اهمیت انتخاب نوع تبدیل موجک مادر می‌باشد که در واقع الگوهایی از توابع موجک مادر که بتواند به لحاظ شکل هندسی به خوبی بر منحنی سری زمانی منطبق شوند بهتر می‌توانند عمل نگاشت را انجام دهند و در نتیجه نتایج

پانزده درصد به عنوان اعتبارسنجی و پانزده درصد نیز به عنوان داده‌های تست مورد استفاده قرار گرفته شده است. در نهایت بعد از این که بهترین معماری شبکه یافت شد، بار دیگر کل داده‌ها از سال ۲۰۰۹ تا سال پایان ۲۰۱۷ به عنوان داده‌های آموزشی در اختیار شبکه عصبی مصنوعی MLP قرار گرفته و ۱۲ ماه از سال ۲۰۱۸ برای میزان دقت پیش‌بینی الگوریتم مورد استفاده قرار گرفته شده است. مدل‌سازی سری زمانی شاخص (NDVI) با استفاده از (رابطه (۶)) انجام شده است که در آن $X_{t-1}, X_{t-2}, \dots, X_{t-k}$ متغیرهای وابسته و ورودی و X_t متغیر مستقل و خروجی می‌باشد.

$$X_t = f(X_{t-1}, X_{t-2}, \dots, X_{t-k}) \quad \text{رابطه (۶)}$$

در این پژوهش از گام‌های زمانی مختلفی به منظور یافتن بهترین گام‌های زمانی استفاده شده است. با این حال بهترین نتایج و دقت گام‌های زمانی برای شاخص NDVI، گام زمانی یک ماهه و دوماهه و برای میزان بارش TRMM و پوشش برف، گام زمانی چهار ماهه بوده است. می‌توان گام زمانی چهار ماهه برای پوشش برف و میزان بارش را تأثیر طولانی مدت این دو پدیده بر پوشش گیاهی دانست.

شبکه‌های عصبی می‌توانند با استفاده از متغیرهای وابسته آموزش ببینند و یک یا چند متغیر مستقل را پیش‌بینی کنند و میزان دقت پیش‌بینی شده، وابستگی بالایی به آموزش مناسب شبکه دارد. شبکه‌های MLP از یک لایه ورودی به منظور دریافت اطلاعات، یک یا چند لایه پنهان و یک لایه خروجی به منظور ارائه جواب نهایی تشکیل شده است. تعداد گره‌های ورودی عموماً برابر با تعداد متغیرهای وابسته و تعداد گره‌های خروجی نیز برابر با افق زمانی پیش‌بینی، در مسائل پیش‌بینی سری زمانی استفاده می‌شود [۲۶].

تعداد لایه‌های پنهان و گره‌های آن در بعضی از مطالعات فقط یک لایه پنهان را برای شبکه‌های پیش‌بینی‌کننده در نظر می‌گیرند و معتقد می‌باشند که

^۱ Decomposition

^۲ Approximation

^۳ Detail

ضریب R^2 در واقع میزان انطباق داده‌هایی که توسط مدل به وجود آمده‌اند و داده‌های واقعی را نشان می‌دهد؛ که هر چه این ضریب به عدد یک نزدیک‌تر باشد نشان‌دهنده این است که انطباق به خوبی صورت گرفته است و هر چه این مقدار از عدد یک کمتر باشد نشانگر عدم انطباق داده‌های واقعی و داده‌های ایجاد شده توسط مدل، می‌باشد.

پارامتر $RMSE$ نیز جذر میانگین مربع خطاهای داده‌های محاسباتی و مشاهداتی را بیان می‌کند؛ بنابراین هرچه مقدار این پارامتر کمتر و به صفر نزدیک‌تر باشد نشان‌دهنده این است که شبیه‌سازی داده‌ها بهتر صورت پذیرفته‌است. به منظور شناسایی بهینه نوع ساختار و معماری شبکه عصبی، نوع موجک مادر، تعداد مراحل تجزیه سیگنال و تاخیرهای زمانی مناسب از معیارهای ارزیابی ضریب تشخیص و خطای جذر میانگین مربعات استفاده شده است. رابطه (۹) $RMSE$ و رابطه (۱۰) R^2 می‌باشد که y_i میزان پارامتر پیش‌بینی شده و $\hat{y}_i$ میانگین کل پارامتر واقعی و N تعداد پارامترها است [۱۱].

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad \text{رابطه (۹)}$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad \text{رابطه (۱۰)}$$

بهتر خواهد بود. با توجه به تأثیر نوع تبدیل موجک مادر، انواع تبدیل موجک مادر از قبیل $harr$, sym , $coif$, b , d مورد مقایسه قرار گرفته شده است. بنابراین از سریهای زمانی شاخص $(NDVI)$ ، پوشش برف و میزان بارش $TRMM$ ایجاد شده برای کل منطقه کشور ایران از سال ۲۰۰۹ تا سال ۲۰۱۷ به منظور آموزش شبکه (الگوریتم تبدیل موجک و شبکه عصبی) استفاده گردیده و در نهایت ۱۲ ماه از سال ۲۰۱۸ به عنوان پیش‌بینی در نظر گرفته شده است. شکل (۲) فلوچارت مراحل روش شبکه عصبی و تبدیل موجک را نشان می‌دهد.

۳-۴- شاخص وضعیت پوشش گیاهی VCI

این شاخص نشان می‌دهد که چگونه $NDVI$ ماه جاری به $NDVI$ در دوره دراز مدت نزدیک می‌شود. با استفاده (رابطه (۸)) می‌توان شاخص VCI را تعریف نمود.


$$VCI = \frac{NDVI_i - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \quad \text{رابطه (۸)}$$

منظور از $NDVI_{min}$ و $NDVI_{max}$ میزان کمترین و بیشترین شاخص $NDVI$ در دوره درازمدت و $NDVI_i$ شاخص $NDVI$ است. بنابراین میزان عددی این شاخص بین صفر و یک است که هر چقدر این شاخص به یک نزدیک‌تر باشد نشان‌دهنده ترسالی و هر چه به صفر نزدیک‌تر باشد، نشان از خشک‌سالی برای ماه مورد نظر است [۲۹].

۴-۴- معیارهای ارزیابی مدل

باید توجه داشت که در ارزیابی عملکرد مدل در پیش‌بینی نتایج باید پارامترهای کمی و کیفی مختلفی مورد بررسی قرارگیرد تا بتوان میزان درست‌بودن عملکرد مدل را به دست آورد. به همین منظور از دو معیار معتبر شامل ضریب R^2 (ضریب تشخیص) و $RMSE$ (خطای جذر میانگین مربعات) استفاده شده‌است.

^۱ Root Mean Square Error



شکل ۲: فلوچارت مراحل روش شبکه عصبی و تبدیل موجک

۵- ارزیابی نتایج

با استفاده از الگوریتم شبکه عصبی مصنوعی-تبدیل موجک و شبکه عصبی مصنوعی، دو الگوریتم پیاده-سازی شد که در روش شبکه عصبی مصنوعی برای ساختار معماری چندین ساختار شبکه پیاده-سازی شد که نتایج در جدول (۱) آمده است. در این جدول مقادیر ضریب R^2 (ضریب تشخیص) و $RMSE$ (خطای جذر میانگین مربعات) در واقع میانگین ضرائب R^2 و $RMSE$ دوازده ماه از سال ۲۰۱۸ می باشد. نتایج نشان می دهد که بهترین توپولوژی شبکه (۴*۶*۱) است که توانسته است بهترین دقت را از خود نشان دهد. همچنین نتایج نشان داده است که تعداد گره های لایه اول زمانی که برابر با تعداد ورودی های شبکه باشد، دقت شبکه به بیشترین مقدار خود رسیده است که این مقدار برابر با

چهار است و با کم تر یا بیشتر شدن این تعداد از گره، دقت شبکه نیز کاهش پیدا می کند. به علت طولانی بودن مدت زمان محاسبات به منظور شناسایی بهترین توپولوژی شبکه و بهترین نوع موجک از ده درصد یکسال های کل منطقه که تصادفی انتخاب شده اند، استفاده گردیده است.

در روش تبدیل موجک-شبکه عصبی از توابع موجک مادر مختلفی که در نرم افزار متلب موجود است استفاده شده است و همچنین بهترین معماری شبکه عصبی در این مرحله توپولوژی معماری (۱*۶*۷*۱۲) بوده که از آن استفاده گردیده است. نتایج نشان می دهد نوع تابع موجک تفاوت کوچکی در میزان $RMSE$ از خود نشان داده است ولی با این حال تابع موجک $Db(2)$ نسبت به سایر توابع موجک دیگر توانسته بهترین دقت

فرکانس بالا تبدیل شده است؛ بنابراین تعداد ورودی-
های شبکه دوازده ورودی بوده است که نسبت به حالت
ساده هشت ورودی افزایش داشته است.

را از خود نشان دهد. همچنین با استفاده از رابطه (۷)
میزان فرایند تجزیه سیگنال تا دو مرحله صورت
پذیرفته است که هر سیگنال و هر تاخیر به یک
زیرسیگنال با فرکانس پایین و دو زیر سیگنال با

جدول ۱: نتایج ارزیابی چندین نوع از توپولوژی شبکه عصبی

ورودی	توپولوژی شبکه	خطای پیش بینی	
		RMSE	R ²
$T_{t-4} \ S_{t-4}, \ N_{t-2}, \ N_{t-1},$	۴*۲*۱	۰٫۰۴۳۲	۰٫۸۶۳
$T_{t-4} \ S_{t-4}, \ N_{t-2}, \ N_{t-1},$	۴*۴*۱	۰٫۰۴۲۷	۰٫۸۶۷
$T_{t-4} \ S_{t-4}, \ N_{t-2}, \ N_{t-1},$	۴*۵*۱	۰٫۰۴۲۱	۰٫۸۸۳
$T_{t-4} \ S_{t-4}, \ N_{t-2}, \ N_{t-1},$	۴*۶*۱	۰٫۰۴۱۶	۰٫۸۹۷
$T_{t-4} \ S_{t-4}, \ N_{t-2}, \ N_{t-1},$	۴*۷*۱	۰٫۰۴۴۸	۰٫۸۵۶
$T_{t-4} \ S_{t-4}, \ N_{t-2}, \ N_{t-1},$	۴*۲*۶*۱	۰٫۰۴۶۲	۰٫۷۸۶
$T_{t-4} \ S_{t-4}, \ N_{t-2}, \ N_{t-1},$	۴*۳*۶*۱	۰٫۰۴۴۳	۰٫۸۲۳
$T_{t-4} \ S_{t-4}, \ N_{t-2}, \ N_{t-1},$	۴*۵*۶*۱	۰٫۰۴۷۳	۰٫۷۳۶
$T_{t-4} \ S_{t-4}, \ N_{t-2}, \ N_{t-1},$	۴*۶*۶*۱	۰٫۰۴۸۳	۰٫۶۸۳
$T_{t-4} \ S_{t-4}, \ N_{t-2}, \ N_{t-1},$	۴*۷*۶*۱	۰٫۰۴۸۹	۰٫۶۹۶
$T_{t-4} \ S_{t-4}, \ N_{t-2}, \ N_{t-1},$	۴*۸*۶*۱	۰٫۰۵۱۲	۰٫۷۰۱

جدول ۲: نتایج ارزیابی انواع توابع موجک

ورودی	توپولوژی شبکه	نوع موجک	خطای پیش بینی	
			RMSE	R ²
NDVI $A1(t-1), D1(t-1), D2(t-1)$ $A1(t-2), D2(t-2), D2(t-2)$ بارش $A1(t-4), D2(t-4), D2(t-4)$ پوشش برف $A1(t-4), D2(t-4), D2(t-4)$	۱۲*۷*۶*۱	Db(1)	۰٫۰۴۳۴	۰٫۸۶۹
	۱۲*۷*۶*۱	Db(2)	۰٫۰۴۲۰	۰٫۸۸۴
	۱۲*۷*۶*۱	Db(3)	۰٫۰۴۴۲	۰٫۸۶۳
	۱۲*۷*۶*۱	Db(4)	۰٫۰۴۳۹	۰٫۸۶۱
	۱۲*۷*۶*۱	Db(5)	۰٫۰۴۴۱	۰٫۸۷۷
	۱۲*۷*۶*۱	Sym(1)	۰٫۰۴۳۷	۰٫۸۶۷
	۱۲*۷*۶*۱	Sym(2)	۰٫۰۴۳۲	۰٫۸۷۳
	۱۲*۷*۶*۱	Sym(3)	۰٫۰۴۳۸	۰٫۸۶۱
	۱۲*۷*۶*۱	Sym(4)	۰٫۰۴۳۷	۰٫۸۱۹
	۱۲*۷*۶*۱	Coif(1)	۰٫۰۴۴۳	۰٫۷۷۷
	۱۲*۷*۶*۱	Coif(2)	۰٫۰۴۴۴	۰٫۷۵۶
	۱۲*۷*۶*۱	Coif(3)	۰٫۰۴۴۱	۰٫۸۵۳
	۱۲*۷*۶*۱	Coif(4)	۰٫۰۴۴۸	۰٫۸۴۳
	۱۲*۷*۶*۱	dmey	۰٫۰۴۴۹	۰٫۷۶۳

دقت آن با محصول شاخص $(NDVI)$ سنجنده مادیس ارزیابی شده است که نتایج در جدول (۳) آورده شده است. همچنین در روش ترکیبی شبکه عصبی و تبدیل موجک به مانند روش شبکه عصبی از تاریخ ۲۰۰۹ تا سال ۲۰۱۷ به آموزش شبکه پرداخته شده است که معماری شبکه حالت $(1*6*7*12)$ انتخاب گردیده و چهار ورودی حالت ساده شبکه به دوازده ورودی تبدیل شده که هر ورودی حالت ساده شبکه به یک زیر فرکانس پایین و دو زیر فرکانس بالاتر تیزه شده است. نتایج در جدول (۴) آورده شده است.

بعد از پیدا کردن بهترین حالت معماری شبکه عصبی و نیز بهترین تابع موجک برای کل پیکسل‌های منطقه مورد مطالعه پیش‌بینی شاخص $(NDVI)$ برای ۱۲ ماه از سال ۲۰۱۸ با استفاده از روش شبکه عصبی و نیز روش ترکیبی تبدیل موجک و شبکه عصبی صورت پذیرفته است؛ به این صورت که در روش شبکه عصبی از تاریخ سال ۲۰۰۹ تا سال ۲۰۱۷ به آموزش شبکه پرداخته شده است. معماری شبکه $(1*6*4)$ و ورودی‌های آن نیز چهار تأخیر زمانی N_{t-1} , N_{t-2} , N_{t-3} , N_{t-4} بوده است و در نهایت شاخص $(NDVI)$ برای ۱۲ ماه از سال ۲۰۱۸ برای کشور ایران پیش‌بینی نموده و

جدول ۳: نتایج دقت ماهانه شاخص $NDVI$ سال ۲۰۱۸ برای روش شبکه عصبی

ماه سال ۲۰۱۸	$RMSE$	R^2	ماه سال ۲۰۱۸	$RMSE$	R^2
۱	۰/۰۴۱	۰/۸۹۳	۷	۰/۰۶۲	۰/۷۸۲
۲	۰/۰۴۶	۰/۸۷۴	۸	۰/۰۶۳	۰/۷۷۹
۳	۰/۰۴۹	۰/۸۵۶	۹	۰/۰۶۸	۰/۷۳۳
۴	۰/۰۵۰	۰/۸۴۹	۱۰	۰/۰۶۶	۰/۷۵۰
۵	۰/۰۵۴	۰/۸۳۳	۱۱	۰/۰۷۳	۰/۶۶۲
۶	۰/۰۵۶	۰/۸۲۰	۱۲	۰/۰۸۲	۰/۶۰۳

جدول ۴: نتایج دقت ماهانه شاخص $NDVI$ سال ۲۰۱۸ برای روش شبکه عصبی و تبدیل موجک

ماه سال ۲۰۱۸	$RMSE$	R^2	ماه سال ۲۰۱۸	$RMSE$	R^2
۱	۰/۰۳۷	۰/۹۱۳	۷	۰/۰۵۹	۰/۸۰۱
۲	۰/۰۴۱	۰/۸۹۴	۸	۰/۰۶۲	۰/۷۹۹
۳	۰/۰۴۳	۰/۸۷۳	۹	۰/۰۶۵	۰/۷۵۳
۴	۰/۰۴۴	۰/۸۷۰	۱۰	۰/۰۶۴	۰/۷۶۱
۵	۰/۰۵۰	۰/۸۵۱	۱۱	۰/۰۷۰	۰/۶۸۳
۶	۰/۰۵۵	۰/۸۳۱	۱۲	۰/۰۷۵	۰/۶۲۶

با توجه به جدول (۳) و جدول (۴) میزان دقت برآورد شده در روش ترکیبی شبکه عصبی و تبدیل موجک نسبت به روش ساده شبکه عصبی بیشتر می‌باشد. به طوری که میانگین دقت برای دوازده ماه سال ۲۰۱۸ برای روش شبکه عصبی $RMSE=0/059$ و $R^2=0/786$ و برای روش ترکیبی شبکه عصبی و تبدیل موجک $RMSE=0/041$ و $R^2=0/893$ بوده است. همچنین میزان دقت برای دوازده ماه از سال برابر نیست و هر ماه دقت متفاوتی را از خود نشان داده است؛ در واقع به طور کل می‌توان گفت که با گذشت زمان، دقت هر دو روش کاهش می‌یابد.


شکل (۳-الف) تصویر شاخص $(NDVI)$ برای ماه آپریل

شکل (۳-الف) تصویر شاخص $(NDVI)$ برای ماه آپریل


پیش بینی دقیق تر خواهد بود که با این امر تصویر مجازی تولید شده توسط الگوریتم تبدیل موجک-شبکه عصبی نتایج بهتری از خود ارائه نموده است.

شکل (۵-الف) پلات سری زمانی میانگین کل پیکسل های شاخص $NDVI$ مشاهداتی و سری زمانی میانگین کل پیکسل های شاخص $NDVI$ آموزشی و ارزیابی با استفاده از روش ترکیبی شبکه عصبی و تبدیل موجک و همچنین شکل (۵-ب) پلات سری زمانی میانگین کل پیکسل های شاخص $NDVI$ مشاهداتی و سری زمانی میانگین کل پیکسل های شاخص $NDVI$ آموزشی و ارزیابی با استفاده از روش شبکه عصبی می باشد.


سال ۲۰۱۸، شکل (۳-ب) تصویر مجازی شاخص $NDVI$ برای ماه آپریل مدل سازی و پیش بینی شده توسط الگوریتم شبکه عصبی مصنوعی-تبدیل موجک و شکل (۳-ج) تصویر شاخص $NDVI$ برای ماه آپریل مدل سازی و پیش بینی شده توسط الگوریتم شبکه عصبی می باشد. شکل (۴) تصویر نمودار پراکنش داده واقعی (محصول $NDVI$ سنجنده مادیس) برای ماه آپریل سال ۲۰۱۸ در برابر تصویر مجازی تولید شده محصول $NDVI$ برای ماه آپریل سال ۲۰۱۸ با استفاده از الگوریتم شبکه عصبی مصنوعی و الگوریتم تبدیل موجک - شبکه عصبی است که هرچه داده ها به خط همانی (خط آبی رنگ) نزدیک تر باشد نشان دهنده



شکل ۳: الف: تصویر شاخص $NDVI$ برای ماه آپریل سال ۲۰۱۸. ب: تصویر مجازی و تولید شده شاخص $NDVI$ برای ماه آپریل سال ۲۰۱۸ با استفاده از الگوریتم شبکه عصبی-تبدیل موجک. ج: تصویر مجازی تولید شده شاخص $NDVI$ برای ماه آپریل سال ۲۰۱۸ با استفاده از الگوریتم شبکه عصبی




شکل ۴: الف: نمودار پراکنش تصویر واقعی و تصویر مجازی حاصل از الگوریتم شبکه عصبی. ب: نمودار پراکنش تصویر واقعی و تصویر مجازی حاصل از الگوریتم شبکه عصبی-تبدیل موجک



شکل ۵: الف: سری زمانی شاخص $NDVI$ برای مشاهدات، آموزش و تست شبکه با استفاده از روش تبدیل موجک و شبکه عصبی. ب: سری زمانی شاخص $NDVI$ برای مشاهدات، آموزش و تست شبکه با استفاده از روش شبکه عصبی

بعد از ایجاد و پیش‌بینی شاخص $NDVI$ برای دوازده ماه از سال ۲۰۱۸ با استفاده از روش ذکر شده، شاخص VCI با استفاده از مقادیر $NDVI$ ایجاد شده، حاصل گردید که این شاخص نشان‌دهنده میزان خشک‌سالی پوشش گیاهی در دوره زمانی و منطقه مورد مطالعه است. این شاخص می‌تواند در شناخت و روند خشک‌سالی مورد استفاده قرار گیرد. با این حال شکل (۶-الف) شاخص VCI تولید شده با استفاده از مقادیر واقعی شاخص $NDVI$ برای ماه آپریل، شکل (۶-ب) شاخص VCI تولید شده با استفاده از شاخص

$NDVI$ پیش‌بینی شده با روش شبکه عصبی مصنوعی-تبدیل موجک و در نهایت شکل (۶-ج) شاخص VCI تولید شده با استفاده از شاخص $NDVI$ پیش‌بینی شده با استفاده از روش شبکه عصبی است. میزان میانگین دقت کلی برای ۱۲ ماه سال ۲۰۱۸ شاخص VCI تولید شده با استفاده از روش شبکه عصبی $RMSE=0.19$ و $R^2=0.596$ و میزان میانگین دقت کلی برای دوازده روش تبدیل موجک و شبکه عصبی $RMSE=0.17$ و $R^2=0.636$ بوده است.



شکل ۶: الف: تصویر شاخص VCI برای ماه آپریل سال ۲۰۱۸. ب: تصویر مجازی و تولید شده شاخص VCI برای ماه آپریل سال ۲۰۱۸ با استفاده از الگوریتم شبکه عصبی - تبدیل موجک. ج: تصویر مجازی تولید شده شاخص VCI برای ماه آپریل سال ۲۰۱۸ با استفاده از الگوریتم شبکه عصبی

۶- نتیجه گیری

خشک سالی به عنوان یکی از برجسته ترین بلایای طبیعی محسوب می شود که تأثیرات مخربی از جمله از بین رفتن پوشش گیاهی، فرسایش خاک و کمبود مواد غذایی در منطقه جغرافیایی دارد که این تأثیرگذاری می تواند به مرور اثرات مخربی را ایجاد کند. امروزه، بیشتر جوامع بشری تحت تأثیر این پدیده قرار گرفته اند. با پیشرفت روش های سنجش از دوری، بسیاری از پارامترهای تأثیرگذار بر این رویداد قابل دستیابی و محاسبه هستند که می توان بر خلاف اندازه گیری های زمینی به طور پیوسته چه از نظر مکانی و چه از نظر زمانی اطلاعات مربوطه را در اختیار داشت. همچنین بیشتر این عوامل دارای ارتباط غیرخطی با یکدیگر می باشند؛ بنابراین روش های یادگیری ماشین می توانند

در مدل سازی بهتر این پدیده به ما کمک کنند. همچنین با استفاده از چند نوع داده ماهواره ای به منظور مدل سازی و پیش بینی، می توان به درک بهتر این پدیده دست یافت. شاخص های پوشش گیاهی یکی از پارامترهای خشک سالی است. در این مطالعه با استفاده از تشکیل سری زمانی شاخص پوشش گیاهی (NDVI)، پوشش برف و همچنین میزان بارش با استفاده از محصول ماهانه پوشش گیاهی سنجنده مادیس، محصول ماهانه پوشش برف سنجنده مادیس و محصول بارش ماهیانه ماهواره TRMM برای منطقه کشور ایران به پیش بینی شاخص NDVI با استفاده از دو روش شبکه عصبی و روش ترکیبی شبکه عصبی و تبدیل موجک برای سال ۲۰۱۸ انجام شده است. نتایج نشان داد که روش ترکیبی شبکه عصبی و تبدیل

پیش‌بینی پدیده خشک‌سالی استفاده نمود. از جمله مشکلات این مطالعه مدت زمان محاسبات زیاد بوده است. همچنین با استفاده از شاخص $NDVI$ پیش‌بینی شده توسط هر دو روش در سال ۲۰۱۸، شاخص VCI نیز محاسبه گردید که تا روند این شاخص پیش‌بینی شود. به عنوان پیشنهادات در این پژوهش می‌توان به افزایش تعداد نوع داده‌های مورد استفاده، شامل داده‌های ماهواره‌ای و داده‌های هواشناسی و همچنین می‌توان از سایر روش‌های یادگیری ماشین به منظور بهبود دقت مدل‌سازی استفاده کرد.

موجک می‌تواند این شاخص را با دقت مطلوبی پیش‌بینی نمایند؛ به طوری که میانگین دقت برای دوازده ماه سال ۲۰۱۸ برای روش شبکه عصبی $RMSE=0.059$ و $R^2=0.786$ و برای روش ترکیبی شبکه عصبی و تبدیل موج $RMSE=0.055$ و $R^2=0.804$ بوده است. همچنین میزان دقت برای دوازده ماه از سال برابر نیست و هر ماه دقت متفاوتی را از خود نشان داده است. با این وجود، نتایج نشان داده است که نوع تابع موجک نیز می‌تواند بر روند پیش‌بینی اثر گذار باشد که می‌توان از آن پیش‌بینی برای

مراجع

- [1] F. N. Kogan, "Contribution of remote sensing to drought early warning," *Early warning systems for drought preparedness and drought management*, pp. 75-87, 2000.
- [2] A. Zhang and G. Jia, "Monitoring meteorological drought in semiarid regions using multi-sensor microwave remote sensing data," *Remote Sensing of Environment*, vol. 134, pp. 12-23, 2013.
- [3] B. W. Heumann, "Satellite remote sensing of mangrove forests: Recent advances and future opportunities," *Progress in Physical Geography*, vol. 35, no. 1, pp. 87-108, 2011.
- [4] D. A. Wilhite and M. Buchanan-Smith, "Drought as hazard: understanding the natural and social context," *Drought and water crises: science, technology, and management issues*, pp. 3-29, 2005.
- [5] S. Szalai and C. Szinell, "Comparison of two drought indices for drought monitoring in Hungary—a case study," in *Drought and drought mitigation in Europe*: Springer, 2000, pp. 161-166.
- [6] F. N. Kogan, "Droughts of the late 1980s in the United States as derived from NOAA polar-orbiting satellite data," *Bulletin of the American Meteorological Society*, vol. 76, no. 5, pp. 655-668, 1995.
- [7] J. Bai et al., "Assessment of the SMAP-Derived Soil Water Deficit Index (SWDI-SMAP) as an Agricultural Drought Index in China," *Remote Sensing*, vol. 10, no. 8, p. 1302, 2018.
- [8] S. Barua, A. Ng, and B. Perera, "Artificial neural network-based drought forecasting using a nonlinear aggregated drought index," *Journal of Hydrologic Engineering*, vol. 17, no. 12, pp. 1408-1413, 2012.
- [9] A. Belayneh and J. Adamowski, "Drought forecasting using new machine learning methods/Prognozowanie suszy z wykorzystaniem automatycznych samouczących się metod," *Journal of Water and Land Development*, vol. 18, no. 9, pp. 3-12, 2013.
- [10] A. Belayneh, J. Adamowski, B. Khalil, and B. Ozga-Zielinski, "Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression models," *Journal of Hydrology*, vol. 508, pp. 418-429, 2014.
- [11] S. Park, J. Im, S. Park, and J. Rhee, "Drought monitoring using high resolution soil moisture through multi-sensor satellite data fusion over the Korean peninsula," *Agricultural and Forest Meteorology*, vol. 237, pp. 257-269, 2017.
- [12] M. R. Alizadeh and M. R. Nikoo, "A fusion-based methodology for meteorological drought estimation using remote sensing

- data," *Remote sensing of environment*, vol. 211, pp. 229-247, 2018.
- [13] R. Tan and M. Perkowski, "Wavelet-Coupled machine learning methods for drought forecast utilizing hybrid meteorological and remotely-sensed data," in *Proceedings of the International Conference on Data Mining (DMIN'15)*, 2015.
- [14] M. Jalili, J. Gharibshah, S. M. Ghavami, M. Beheshtifar, and R. Farshi, "Nationwide prediction of drought conditions in Iran based on remote sensing data," *IEEE Transactions on Computers*, vol. 63, no. 1, pp. 90-101, 2013.
- [15] A. AghaKouchak et al., "Remote sensing of drought: Progress, challenges and opportunities," *Reviews of Geophysics*, vol. 53, no. 2, pp. 452-480, 2015.
- [16] J. F. Mas and J. J. Flores, "The application of artificial neural networks to the analysis of remotely sensed data," *International Journal of Remote Sensing*, vol. 29, no. 3, pp. 617-663, 2008.
- [17] C. Dawson and R. Wilby, "Hydrological modelling using artificial neural networks," *Progress in physical Geography*, vol. 25, no. 1, pp. 80-108, 2001.
- [18] I. Ali, F. Cawkwell, E. Dwyer, and S. Green, "Modeling managed grassland biomass estimation by using multitemporal remote sensing data—A machine learning approach," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 7, pp. 3254-3264, 2017.
- [19] S. Mohammady and M. Delavar, "Urban Expansion Modeling with Logistic Regression," *Journal of Geomatics Science and Technology*, vol. 4, no. 2, pp. 77-86, 2014.
- [20] O. Rioul and M. Vetterli, "Wavelets and signal processing," *IEEE signal processing magazine*, vol. 8, no. ARTICLE, pp. 14-38, 1991.
- [21] R. Merry, "Wavelet theory and applications: a literature study," *DCT rapporten*, vol. 2005, 2005.
- [22] B.-L. Zhang and Z.-Y. Dong, "An adaptive neural-wavelet model for short term load forecasting," *Electric power systems research*, vol. 59, no. 2, pp. 121-129, 2001.
- [23] S. G. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," *IEEE Transactions on Pattern Analysis & Machine Intelligence*, no. 7, pp. 674-693, 1989.
- [24] F. Zambrano, M. Lillo-Saavedra, K. Verbist, and O. Lagos, "Sixteen years of agricultural drought assessment of the BioBío region in Chile using a 250 m resolution Vegetation Condition Index (VCI)," *Remote Sensing*, vol. 8, no. 6, p. 530, 2016.
- [25] D. B. Wolff et al., "Ground validation for the tropical rainfall measuring mission (TRMM)," *Journal of Atmospheric and Oceanic Technology*, vol. 22, no. 4, pp. 365-380, 2005.
- [26] X. Zhang, "Time series analysis and prediction by neural networks," *Optimization Methods and Software*, vol. 4, no. 2, pp. 151-170, 1994.
- [27] M. R. Peyghami and R. Khanduzi, "Predictability and forecasting automotive price based on a hybrid train algorithm of MLP neural network," *Neural Computing and Applications*, vol. 21, no. 1, pp. 125-132, 2012.
- [28] V. Nourani, M. Komasi, and A. Mano, "A multivariate ANN-wavelet approach for rainfall-runoff modeling," *Water resources management*, vol. 23, no. 14, p. 2877, 2009.
- [29] P. S. Thenkabail and M. Gamage, *The use of remote sensing data for drought assessment and monitoring in Southwest Asia*. Iwmi, 2004.



Combining Neural Network and Wavelet Transform to Predict Drought in Iran Using MODIS and TRMM Satellite Data

Ramin Mokhtari Dehkordi ¹, Mahdi Akhoondzadeh ^{*2}

1- Ms.c student of remote sensing in Faculty of Surveying and Geospatial, Tehran University of Thechnology, Tehran, Iran

2- Assistant professor in Faculty of Surveying and Geospatial, Tehran University of Thechnology, Tehran, Iran

Abstract

The drought can be described as a natural disaster in each region. In this study, one of the important factors in drought, vegetation, has been considered. For this purpose, monthly vegetation cover images and snow cover data of MODIS and TRMM satellite precipitation product from 2009 to 2018 were used for the study area of Iran. After initial preprocessing, we have used artificial neural network method and hybrid neural network and wavelet transform method to predict the normalized difference vegetation index (NDVI). After training the two algorithms using the time series of (NDVI) index as well as the time series of snow cover and precipitation from 2009 to 2017, the (NDVI) index is predicted for twelve months from 2018, which is finally estimated with real values. The results and prediction accuracy for these two algorithms are different and in general the combined neural network and wavelet transform method has higher accuracy compare to the neural network method so that the twelve average of 2018 is equal to the root mean square error of 0.055 and coefficient of determination was 0.804. The results also show that in both methods the accuracy of the index in the early months of 2018 is better than the end months. Therefore, this method can be used to predict this index, as one of the drought parameters.

Key words: Drought, Wavelet Artifical Neural Networks, Time Series, NDVI.