

پیش‌بینی مکانی- زمانی تغییرات پوشش گیاهی بر مبنای داده‌های سنجش از دور با استفاده از یادگیری عمیق

الهام زنگنه، هدی مشایخی و سعید قره‌چلو

تغییرات پوشش زمین به درک و فهم فرآیندهای تغییرات پوشش زمین و همچنین در آگاه‌سازی تصمیم‌گیرنده‌های زیست‌محیطی در مورد شرایط احتمالی آینده پوشش‌های زمین تحت سناریوهای مختلف، کمک می‌کند [۱] و [۲].

در مدل‌سازی‌های مکانی- زمانی، فناوری سنجش از دور و سیستم اطلاعات جغرافیایی نقشی محوری را ایفا می‌کنند، به گونه‌ای که این فناوری با فراهم‌آوردن داده‌های چندطیفی و چندزمانه از نظر هزینه و زمان، مقرون‌به‌صرفه بوده و اطلاعات ارزشمندی را برای درک و فهم و پیش‌الگوها و فرآیندهای پوشش زمین موجب می‌شود. بنابراین داده‌های به دست آمده به وسیله این فناوری‌ها می‌توانند به عنوان مهم‌ترین منبع در فراهم‌سازی داده‌های پایه برای پیش‌بینی تغییرات پوشش زمین به کار روند [۳] و [۴].

میزان تراکم و تغییرات پوشش گیاهی در یک ناحیه خاص توسط معیارهای گوناگونی قابل محاسبه است. معیارها متناسب با ناحیه مورد مطالعه دارای انواع مختلفی هستند. بررسی تغییرات پوشش گیاهی در سال‌های مختلف بسیار مهم و اطلاعات آن در تصمیم‌گیری مدیران بسیار مؤثر است. با توجه به این که اطلاعات پوشش گیاهی در سال‌های گذشته در دسترس نیست و از طرفی دستیابی به اطلاعات پوشش گیاهی کاری هزینه‌بر و زمان‌بر می‌باشد، می‌توان با تهیه تصاویر ماهواره‌ای و استخراج شاخص پوشش گیاهی، اطلاعات مربوط به پوشش گیاهی را تعیین نمود [۵].

در بسیاری از مطالعات، از داده‌های سری زمانی به خاطر داشتن سابقه طولانی‌مدت و حجم پایین استفاده می‌شود [۶]. داده‌های سری زمانی شامل تغییراتی آنی هستند و این، سبب آنالیز بهتری نسبت به دیگر پایگاه داده‌ها می‌شود. تغییرات فصلی و الگوهای سالانه تغییرات از جمله مواردی هستند که به خوبی توسط این داده‌ها قابل ارزیابی می‌باشد [۷]. مطالعات متعددی در زمینه بررسی پوشش گیاهی انجام گردیده است که از آن جمله می‌توان به مطالعات کالرا و همکاران (۲۰۰۱) اشاره کرد. آنها با بررسی تاج پوشش گیاهی به این نتیجه رسیدند که بین تغییرات پوشش گیاهی و شاخص‌های پوشش گیاهی، ارتباط معناداری وجود دارد [۸]. کوهن و همکاران (۲۰۰۳) با بررسی شاخص سطح برگ و شاخص‌های گیاهی محاسبه‌شده با داده‌های ماهواره لندست به این نتیجه رسیدند که ارتباط معناداری بین شاخص سطح برگ و شاخص‌های پوشش گیاهی وجود دارد [۹]. گورگل و فرتایا (۲۰۰۳) تغییرات پوشش گیاهی را در ارتباط با شرایط اقلیمی بررسی نمودند که نتایج نشان دادند که بارندگی، موجب تغییرات پوشش گیاهی می‌شود به طوری که بارندگی در فصل تابستان، همبستگی ۷۰٪ و در فصل بهار، ۹۱٪ با تغییرات پوشش گیاهی نشان می‌دهد [۱۰].

چکیده: درک و تحلیل تغییرات داده‌های مکانی- زمانی در کاربردهای مختلف از جمله انجام اقدامات حفاظت و توسعه منابع طبیعی اهمیت زیادی دارد. در مطالعات گذشته، عمدتاً از فرایند مارکوف و روش‌های مبتنی بر مقایسه جهت پیش‌بینی تغییرات شاخص‌های پوشش گیاهی استفاده گردیده که دقت آنها همچنان جای بهبود دارد. گرچه تحلیل‌های سری زمانی برای پیش‌بینی معدودی از شاخص‌ها مورد استفاده قرار گرفته است، اما روشی که این شاخص‌ها را از داده‌های سنجش از دور استخراج کرده و مدل‌سازی توالی آنها را با یادگیری عمیق انجام دهد، به ندرت مشاهده می‌شود. در این مقاله، روشی برای پیش‌بینی تغییرات شاخص‌های گیاهی مبتنی بر یادگیری عمیق ارائه می‌شود. داده‌های پژوهش شامل تصاویر ماهواره‌ای لندست از سال ۲۰۰۰ تا ۲۰۱۸، مربوط به چهار فصل سال در نواحی شمال و شرق شهرستان شاهرود در استان سمنان می‌باشند. گستره زمانی تصاویر استخراج‌شده، امکان پیش‌بینی تغییرات پوشش گیاهی را ممکن می‌سازند. شاخص‌های پوشش گیاهی استخراج‌شده از مجموعه داده، شامل NDVI، RVI و SAVI هستند. پس از انجام اصلاحات اتمسفری روی تصاویر، شاخص‌های مورد نظر استخراج شده و سپس داده‌ها به سری زمانی تبدیل می‌شوند. نهایتاً مدل‌سازی توالی این داده‌ها توسط شبکه حافظه کوتاه-بلندمدت انجام می‌شود. نتایج حاصل از آزمایش‌ها نشان می‌دهند که شبکه عصبی قادر به پیش‌بینی مقادیر آینده با دقت بالا است. میزان خطای شبکه بدون وجود داده‌های اضافی برای شاخص NDVI برابر ۰٫۰۳، شاخص SAVI برابر با ۰٫۰۲ و شاخص RVI برابر با ۰٫۰۶ گزارش می‌شود.

کلیدواژه: یادگیری عمیق، سری زمانی، سنجش از دور، شاخص پوشش گیاهی، مدل‌سازی توالی.

۱- مقدمه

اصطلاح پوشش زمین اشاره به پوشش فیزیکی و زیستی سطح زمین دارد. از جمله این پوشش‌ها می‌توان به پوشش‌هایی همچون جنگل‌ها، مراتع، پهنه‌های آبی و زمین‌های بایر اشاره کرد. اصطلاح تغییرات پوشش زمین، تمام انواع تغییراتی است که به وسیله انسان یا فرآیندهای زیست‌محیطی بر روی زمین انجام می‌گردد. مدل‌سازی روند تغییرات و پیش‌بینی آن برای آینده از اهمیتی زیاد برخوردار است. در واقع پیش‌بینی

این مقاله در تاریخ ۱۵ شهریور ماه ۱۳۹۹ دریافت و در تاریخ ۵ آذر ماه ۱۴۰۰ بازنگری شد.

الهام زنگنه، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شاهرود، شاهرود، ایران، (email: elhamzangeneh@gmail.com).

هدی مشایخی (نویسنده مسئول)، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شاهرود، شاهرود، ایران، (email: hmasayekhi@shahroodut.ac.ir).

سعید قره‌چلو، دانشکده مهندسی عمران، دانشگاه صنعتی شاهرود، شاهرود، ایران، (email: sgharachelo@shahroodut.ac.ir).

انتهای شبکه هستند، نسبت به وزن‌های موجود در لایه‌های اولیه به مقدار خیلی بیشتری تغییر کنند. هرچه تعداد لایه‌ها بیشتر باشد، مقدار پارامترهای لایه‌های اول، کمتر تغییر می‌کند و این مشکل‌ساز است، زیرا مقادیر وزن‌ها در ابتدای کار به صورت تصادفی مقداردهی می‌شوند و اگر این مقادیر به ندرت تغییر کنند، یا هیچ وقت نمی‌توانند مقدار صحیح را پیدا کنند یا این فرآیند خیلی خیلی زمان‌بر خواهد بود. مسأله ناپدیدشدن گرادیان در این مرحله به وجود می‌آید.

به همین جهت، بحث استفاده از شبکه‌های عصبی عمیق شبیه LSTM به عنوان راه حلی مناسب جهت غلبه بر مشکل ناپدیدشدن گرادیان مطرح می‌شود. ساختار داده‌های سنجش از دور به دلیل ماهیت سری زمانی بودن و همچنین دارای تغییرات با الگوی فصلی یا سالانه، نیازمند استفاده از نوعی از شبکه‌های عمیق است که از این نظر، مناسب آموزش و پیش‌بینی باشند. اهمیت وجود حافظه به دلیل استفاده از داده‌های نه چندان دور، بسیار بااهمیت است. در مطالعات محدودی از شبکه‌های عصبی جهت پیش‌بینی تغییرات پوشش گیاهی استفاده شده است [۲۳].

همان‌طور که مطرح شد، داده‌های در برخی مطالعات نیز از شبکه‌های عصبی عمیق جهت پیش‌بینی استفاده می‌شود. به طور مثال، ردی و همکارش (۲۰۱۸) به منظور پیش‌بینی تراکم پوشش گیاهی در دو ناحیه از جزیره Nicobar از داده‌های سری زمانی MODIS NDVI با تغییرات کم و شبکه‌های عصبی عمیق استفاده کردند و به دقت ۹۷ درصدی رسیدند [۲۴]. این پژوهش، مستقیماً از سری زمانی موجود شاخص‌ها استفاده کرده و استخراج شاخص‌ها را از داده‌های سنجش از دور انجام نداده است.

در این مقاله، روشی برای پیش‌بینی تغییرات شاخص‌های پوشش گیاهی با استفاده از یادگیری عمیق ارائه می‌شود. برخلاف روش‌های موجود، مقادیر شاخص‌ها را مستقیماً از داده‌های سنجش از دور استخراج می‌کنیم و مدل‌سازی توالی آنها را به دو صورت مختلف توسط شبکه عصبی انجام می‌دهیم. به این منظور، تصاویر ماهواره‌ای لندست را از گستره زمانی مناسب ۲۰۰۰ تا ۲۰۱۸، مربوط به چهار فصل سال برای نواحی شمال و شرق شهرستان شاهرود در استان سمنان استخراج نمودیم. شاخص‌های پوشش گیاهی استخراج‌شده از مجموعه داده شامل NDVI، SAVI و RVI هستند. در الگوریتم پیشنهادی، ابتدا اصلاحات اتمسفری روی تصاویر، انجام و سپس شاخص‌های مورد نظر، استخراج و سری زمانی مناسب تولید می‌شود. در نهایت مدل‌سازی توالی این داده‌ها توسط شبکه حافظه کوتاه-بلندمدت انجام می‌گردد. نتایج حاصل از آزمایش‌ها نشان می‌دهند که شبکه عصبی قادر به پیش‌بینی مقادیر آینده با دقت بالا است. میزان خطای شبکه بدون وجود داده‌های اضافی برای شاخص NDVI برابر با ۰/۰۳، شاخص SAVI برابر با ۰/۰۲ و شاخص RVI برابر با ۰/۰۶ گزارش می‌شود. در ادامه به شرح الگوریتم پیشنهادی که شامل مراحل پیش‌پردازش داده‌ها، استخراج شاخص‌های پوشش گیاهی، ساخت داده‌های سری زمانی و استفاده از شبکه عصبی عمیق است، پرداخته می‌شود. در بخش بعدی به بررسی آزمایش‌های انجام‌شده و نتایج آنها پرداخته خواهد شد.

حسینی و همکاران (۲۰۱۱)، نوسانات بارندگی و تغییرات پوشش گیاهی را در بخشی از مراتع شهر یزد بررسی نمودند که نتایج به دست آمده، ارتباط معناداری را بین پوشش گیاهی و بارندگی نشان می‌دهد [۱۱]. ارسنجانی و همکاران (۲۰۱۳) برای مدل‌سازی رشد، توسعه شهر تهران را برای سال ۲۰۱۶ و ۱۰ سال بعد یعنی ۲۰۲۶ با استفاده از مدل ترکیبی شامل رگرسیون لجستیک، مارکوف و سلول‌های خودکار بررسی کردند و به صحت ۸۹ درصدی دست یافتند [۱۲]. منصوری و همکاران (۱۳۹۴) از شاخص بارش سالانه و شاخص‌های پوشش گیاهی برای بررسی بارندگی و اثرات خشک‌سالی بر روی پوشش گیاهی مراتع استفاده نمودند. نتایج این تحقیق نشان داد که می‌توان برای بررسی میزان بارندگی و پیش‌خشک‌سالی از داده‌های سنجش از دور استفاده کرد [۱۳].

اغلب مطالعات انجام‌شده تا کنون به صورت مقایسه‌ای و توسط نرم‌افزارهای سنجش از دور انجام گردیده و عملیات پیش‌بینی نیز روی داده‌های لندست با استفاده از مدل‌های رگرسیون و مارکوف صورت گرفته است. در حیطه هوش مصنوعی، استفاده از الگوریتم‌های یادگیری عمیق در سال‌های اخیر سبب پیشرفت قابل ملاحظه‌ای در کاربردهای مختلف گردیده است. همچنین نشان داده شده که یادگیری عمیق از پتانسیلی بالا برای طبقه‌بندی داده‌های سنجش از دور برخوردار می‌باشد. یادگیری عمیق، رویکردی است که در آن ویژگی‌ها به صورت سلسله‌مراتبی در یک چارچوب با نظارت به دست می‌آیند. جهت پیش‌بینی مقادیر داده‌های سری زمانی از مدل‌های میانگین متحرک رگرسیونی خودکار استفاده می‌شود [۱۴] که این مدل‌ها از داده‌های مجاور برای پیش‌بینی مقادیر بعدی در سری زمانی استفاده می‌کنند. اما از آنجا که این مدل‌ها پارامتری هستند، برای پیش‌بینی دقیق سری‌های زمانی مناسب نمی‌باشند. مدل زنجیره مارکوف به صورت ساده یک تابع احتمال را به صورت تدریجی در سراسر حالت‌های بعدی ایجاد می‌کند [۱۵]. این روش به اصطلاح کم‌حافظه^۲ است، چرا که فقط از وضعیت فعلی فرآیند جهت پیش‌بینی آینده استفاده می‌نماید [۱۶]. در مقابل، شبکه‌های عصبی با افزایش در دسترس بودن داده‌های ماهواره‌ای، در تحلیل داده‌های سنجش از دور طرفداران زیادی پیدا کرده‌اند، زیرا برخلاف اکثر روش‌های آماری، غیر پارامتری هستند [۱۷] و [۱۸].

بسیاری از مطالعات نشان داده‌اند که شبکه‌های عصبی، کارایی بالایی دارند و در کار با داده‌های نویزی به خوبی عمل می‌کنند [۱۹] و [۲۰]. در مطالعات مختلف از انواع شبکه‌های عصبی در تحلیل و پیش‌بینی داده‌های سنجش از دور استفاده گردیده است. از این شبکه‌ها برای پیش‌بینی شاخص‌های پوشش گیاهی می‌توان استفاده کرد، اما از آنجا که حافظه‌ای برای نگهداری اطلاعات داده‌های گذشته ندارند، اغلب عملکرد مناسبی از خود نشان نداده‌اند [۲۱]. شبکه‌های عصبی بازگشتی^۳ را نیز که دارای حافظه هستند، می‌توان برای پیش‌بینی به کار برد اما مشکل ناپدیدشدن گرادیان نیز در این مورد، باعث نامناسب‌بودن این شبکه‌ها در پیش‌بینی می‌شود [۲۲]. مکانیزمی که باعث یادگیری در شبکه‌های عصبی می‌شود، گرادیان کاهشی نام دارد. در این مکانیزم برای هر پارامتر در شبکه، مشتق تابع هزینه نسبت به پارامتر، محاسبه و در مسیر مخالف به طور آهسته حرکت داده می‌شود. گاهی این الگوریتم ساده در برخی شبکه‌ها رفتار عجیبی از خود نشان می‌دهد و باعث می‌شود وزن‌هایی که نزدیک‌تر به

4. Long Short Term Memory

5. Normalized Difference Vegetation Index

6. Ratio Vegetation Index

7. Soil Adjusted Vegetation Index

1. Autoregressive Integrated Moving Average

2. Memory Less


3. Recurrent Neural Network



شکل ۳: فریم تصویر ماهواره لندست در منطقه و دو قاب انتخاب‌شده به عنوان نواحی مطالعاتی.



شکل ۱: موقعیت ناحیه مورد مطالعه در کشور ایران.




شکل ۴: تصاویر پوشش گیاهی نواحی شمال و شرق شهرستان شاهرود.

سال ۲۰۰۰، میانگین پوشش گیاهی برای شاخص‌های متفاوت بیشتر از سال ۲۰۰۶ مشاهده گردید. همچنین در سال ۲۰۰۶، تغییرات نسبت به سال ۲۰۱۲ به صورت کاهشی مشاهده می‌شود. این تغییرات تا سال ۲۰۱۸ به صورت کاهشی و در برخی فصول، افزایشی مشاهده گردید. به طور کلی در فصول مختلف، تغییرات به صورت عمدتاً کاهشی و گاهی افزایشی مشاهده می‌شود.

۲-۲ داده‌های مورد مطالعه

به منظور دسترسی به اطلاعات این نواحی از داده‌های سنجنش از دور مربوط به ماهواره‌های لندست ۵، ۷ و ۸ استفاده شده است. داده‌های سنجنش از دور به رایگان از طریق سایت زمین‌شناسی آمریکا (USGS) با داشتن اکانت، قابل دسترس هستند. اطلاعات این سنسورها در جدول ۱ قابل مشاهده است و داده‌های استخراج‌شده مربوط به داده‌های سطح ۱ می‌باشند. به منظور دریافت اطلاعات مناسب، از داده‌های با حداقل درصد ابرناکی استفاده شده و حداقل درصد ابر داده‌ها برابر با ۱۰ درصد است. داده‌های به دست آمده مربوط به چهار فصل سال‌های ۲۰۰۰ تا ۲۰۱۸



شکل ۲: باند پانکروماتیک از تصویر ماهواره لندست ۸ مربوط به سال ۲۰۱۸.

۲- مواد و روش‌ها

۱-۲ منطقه مورد مطالعه

منطقه مطالعه‌شده در این مقاله، شمال ۲ ناحیه در شمال شرق ایران در استان سمنان می‌باشد که از طول جغرافیایی ۵۵,۰۵۷۱۴۲۵۶۸۴۲۵۴۴ تا ۵۵,۲۸۷۳۲۳ عرض جغرافیایی ۳۶,۳۶۶۰۱۰ تا ۳۶,۵۱۴۴۳۳۳۴۰۳۲۲۵۱ قرار دارد. این نواحی پس از مطالعه و تحقیق و بررسی تصاویر تاریخی گوگل ارث^۱ و مشورت متخصصین سنجنش از دور به عنوان ناحیه‌هایی با تغییرات پوشش گیاهی در طی سال‌ها شناخته شدند و پوشش گیاهی در این نواحی در حد متوسط رو به کم می‌باشد. موقعیت شهرستان شاهرود در استان سمنان در شکل ۱ قابل مشاهده است. همچنین در شکل ۲، نمونه تصویر ماهواره‌ای دانلودشده از سایت USGS مربوط به فصل بهار از ماهواره لندست ۸، مربوط به شماره ردیف ۳۵ و گذر ۱۶۲ آمده و در شکل ۳، موقعیت قاب‌های انتخاب‌شده در تصاویر مشخص گردیده است. پوشش گیاهی در این نواحی به صورت متوسط تا کم و تغییرات در آن متوسط می‌باشد. در تصاویر شکل ۴، تغییرات پوشش گیاهی با اختلاف هر شش سال یک تصویر نشان داده شده است. تصاویر به ترتیب مربوط به سال‌های ۲۰۰۰، ۲۰۰۶، ۲۰۱۲ و ۲۰۱۸ مربوط به فصل بهار می‌باشند. لازم به ذکر است که نواحی از روی تصاویر اصلی برش داده شده‌اند و نقاط سفیدزنگ، شدت پوشش گیاهی را در نواحی مشخص می‌کنند. در

1. Google Earth

$$\rho_{\lambda} = \frac{\rho_{\lambda'}}{\sin \theta} \quad (۴)$$

جدول ۲: اطلاعات شاخص‌های پوشش گیاهی.

شماره	ایندکس
۱	$SAVI = \frac{(NIR - RED)(1 + L)}{NIR + RED + L}$
۲	$RVI = \frac{RED}{NIR}$
۳	$NDVI = \frac{NIR - RED}{NIR + RED}$

۳- روش پیشنهادی پیش‌بینی تغییرات پوشش گیاهی

روش تحقیق پیشنهادی در این مطالعه جهت پیش‌بینی شاخص‌های پوشش گیاهی داده‌های لندست، استفاده از شبکه عصبی عمیق و داده‌های سری زمانی است. در این روش، ابتدا شاخص‌های پوشش گیاهی مورد نظر، استخراج و داده‌های سری زمانی ایجاد می‌شوند. سپس از شبکه عصبی عمیق LSTM جهت آموزش، ارزیابی و پیش‌بینی مقادیر استفاده می‌گردد. در ادامه به شرح این مراحل پرداخته خواهد شد.

۳-۱ استخراج شاخص‌های پوشش گیاهی

در این مطالعه به بررسی سه شاخص از دسته معیارهای پوشش گیاهی با عنوان NDVI، SAVI و RVI پرداخته شده و میانگین این شاخص‌ها استخراج و مورد پیش‌بینی قرار می‌گیرند. این شاخص‌ها از اطلاعات دو باند از تصاویر ماهواره لندست با عناوین RED و NIR با فرمول‌های تعریف شده خاص قابل محاسبه هستند. شاخص NDVI مقادیر در بازه (+۱، -۱) را شامل می‌شود که مقادیر منفی به معنای عدم پوشش گیاهی و مقادیر صفر و بزرگ‌تر از آن، مقادیر پوشش گیاهی از ضعیف تا متراکم را شامل می‌شوند. شاخص SAVI نیز همانند شاخص NDVI مقادیری در بازه (+۱، -۱) را شامل می‌شود که در فرمول آن علاوه بر اطلاعات باندها از یک فاکتور تعدیل خاک L نیز که دارای مقادیر در بازه (۰، ۰.۵) می‌باشد، استفاده می‌کند. مقادیر از صفر به ترتیب برای نواحی با پوشش گیاهی متراکم به سمت ۰.۵ با پوشش گیاهی ضعیف، قابل استفاده هستند. شاخص RVI دارای مقادیر در بازه (۰، +∞) است که مقادیر کوچک‌تر پوشش گیاهی کم و مقادیر بزرگ‌تر پوشش گیاهی متراکم را شامل می‌شوند. فرمول محاسبه شاخص‌ها در (۱) تا (۳) در جدول ۲ قابل مشاهده است [۲۶] و [۲۷].

۳-۲ استفاده از شبکه عصبی عمیق و داده‌های

سری زمانی

در این مطالعه از شبکه عصبی عمیق LSTM جهت آموزش، آزمون و پیش‌بینی مقادیر داده‌های سری زمانی تولید شده استفاده می‌گردد. داده‌های سری زمانی با استفاده از مقادیر شاخص‌های استخراج شده در مرحله قبل تولید می‌شوند و جهت پیش‌بینی مقادیر در آینده، نیاز به داشتن مقادیر گذشته می‌باشد. در این پژوهش پس از به دست آوردن داده‌ها در چهار فصل مختلف سال‌های ۲۰۰۰ تا ۲۰۱۸، آنها به داده‌های سری زمانی تبدیل شدند. لازم به ذکر است که به دلیل کمبود نمونه‌ها و رسیدن به هدف مورد نظر جهت پیش‌بینی مکانی-زمانی داده‌های سنجش از دور، در هر عکس از دو ناحیه مربوط به نواحی شمال و شرق شهرستان شاهرود استفاده شده است (در ناحیه شمال ۴ قاب و در ناحیه شرق ۱ قاب

هستند. داده‌های مربوط به سال‌های ۲۰۰۰ تا ۲۰۱۷ مرتبط به سنسورهای جدول ۱: اطلاعات داده‌های لندست مورد مطالعه.

Satellite	LANDSAT5	LANDSAT7	LANDSAT8
Band	V Bands	۸ Bands	۱۱ Bands
Sensors	TM	ETM	OLI, TIRS

لندست ۵ و ۷ و داده‌های ۲۰۱۸ مربوط به لندست ۸ هستند و فونت پرینت هر تصویر ۱۸۵×۱۸۵ کیلومتر است. همان‌طور که در جدول ۲ گزارش می‌شود، تصاویر لندست ۵ دارای ۷ باند و سنسور TM، تصاویر لندست ۷ دارای ۸ باند و سنسور ETM و تصاویر لندست ۸ دارای ۱۱ باند شامل سنسورهای OLI و TIRS می‌باشند.

۳-۲ پیش‌پردازش داده‌ها

داده‌های سنجش از دور نیازمند تصحیحات اتمسفری، ژئومتریک و رادیومتریک هستند. تصحیحات رادیومتریک و ژئومتریک توسط خود سایت USGS بر روی داده‌های سطح ۱ انجام شده که در این مرحله لازم است تا تصحیحات اتمسفری روی تصاویر انجام شود. هدف از این تصحیح، جبران نویزهای ایجاد شده توسط عوامل مختلفی چون گردش زمین و تغییر در ارتفاع ماهواره است. جهت انجام عملیات پیش‌پردازش روی داده‌ها از روش TOA استفاده می‌شود. این عمل در سنسورهای مختلف طی دو مرحله با معادلات متفاوتی انجام می‌گردد [۲۵].

مرحله اول: در مرحله اول، تبدیل DN به RADIANCE انجام شده و مقادیر رقومی پیکسل‌ها به مقادیر تابش طیفی تبدیل می‌گردند. در سنسورهای TM و ETM با استفاده از (۱)، این تبدیل انجام می‌شود. مقادیر $L_{\max \lambda}$ و $L_{\min \lambda}$ بیشینه و کمینه مقادیر تابش طیفی و مقادیر $Q_{cal \min}$ و $Q_{cal \max}$ بیشینه و کمینه ارزش رقومی پیکسل‌ها هستند. در سنسورهای OLI و TIRS با استفاده از (۲)، این تبدیل انجام می‌شود. نماد A_p مربوط به REFLECTANCE_ADD_BAND و نماد M_p ، REFLECTANCE_MULT_BAND تصاویر است

$$L_{\lambda} = \frac{L_{\max \lambda} - L_{\min \lambda}}{Q_{cal \max} - Q_{cal \min}} (Q_{cal} - Q_{cal \min}) + L_{\min \lambda} \quad (۱)$$


$$\rho_{\lambda} = \frac{\pi L_{\lambda} d^{\tau}}{ESUN_{\lambda} \cos \theta_s} \quad (۲)$$

مرحله دوم: در مرحله دوم، تبدیل مقادیر RADIANCE به TOA انجام شده و مقادیر تابش طیفی حاصل از مرحله قبل به مقادیر صحیح تبدیل می‌گردند. این عملیات در سنسورهای TM و ETM با استفاده از (۳) و در سنسورهای OLI و TIRS با استفاده از (۴) انجام می‌شود. در معادلات ذکر شده، d بیانگر فاصله زمین تا خورشید و $ESUN$ مربوط به میانگین تابش اتمسفری خورشید است

$$\rho_{\lambda'} = M_p \times Q_{cal} + A_p \quad (۳)$$

1. United States Geological Survey
2. Top of Atmosphere
3. Digital Number
4. Thematic Mapper
5. Enhanced Thematic Mapper
6. Operational Land Imager
7. Thermal Infrared Sensor

در تمامی معادلات، V و W نماد مقادیر ماتریس وزن‌ها و b نماد بایاس می‌باشند.



شکل ۶: معماری شبکه استفاده‌شده.


۴- نتایج ارزیابی

پس از استخراج شاخص‌های پوشش گیاهی و ساخت سری زمانی، به منظور پیش‌بینی مقادیر داده‌ها از شبکه LSTM استفاده می‌شود. همان طور که در بخش ۲-۴-۲ در مورد تهیه داده‌های سری زمانی توضیح داده شد، نمونه‌های استخراج‌شده که به صورت میانگین شاخص‌های پوشش گیاهی در نواحی است، در دسترس می‌باشد. پس از آماده‌سازی تمامی نمونه‌ها، از ۷۵ درصد کل آنها جهت آموزش و از ۲۵ درصد جهت آزمون استفاده می‌شود. داده‌های سری زمانی ایجادشده به شبکه عصبی عمیق، وارد و پیش‌بینی انجام می‌شود. نمونه‌های سری زمانی ایجادشده مربوط به داده‌های سنجش از دور سال‌های ۲۰۰۰ تا ۲۰۱۸ از هر سال چهار عکس مربوط به چهار فصل سال می‌باشد. نمونه‌ها به ترتیب فصول سال و به صورت ترکیبی از ناحیه شمال و شرق به شبکه داده می‌شوند و داده در فصل سال بعد پیش‌بینی می‌گردد. پوشش گیاهی در نواحی مذکور متوسط تا کم و طی سال‌های ۲۰۰۰ تا ۲۰۱۸ تغییرات متوسطی در پوشش گیاهی رخ داده است. در شکل ۴ تغییرات پوشش گیاهی مربوط به این نواحی با فاصله شش سال نمایش داده شده است. جهت پیش‌بینی تغییرات پوشش گیاهی در نواحی مشخص‌شده، میانگین پوشش گیاهی در هر ناحیه، مشخص و میانگین در آینده پیش‌بینی می‌شود. پس از مراحل آموزش و آزمون، داده‌ها را مورد پیش‌بینی قرار خواهیم داد و با آزمایش تعداد مراحل مختلف، برچسب زمانی و تعداد نرون‌های مختلف شبکه، نتایج حاصل می‌شوند. نتایج آزمایش‌ها با برچسب‌های زمانی متفاوت بررسی شدند و همچنین تعداد نرون‌های لایه میانی بررسی گردید. تعداد نرون‌های مطلوب، ۳۲ نرون و برچسب زمانی مطلوب نیز شش گزارش می‌شود. در نهایت جهت اندازه‌گیری میزان خطای شبکه از معیار RMSE با (۱۰) که در آن y_i نماد مقدار واقعی نمونه i و $y_{\hat{i}}$ نماد مقدار پیش‌بینی شده نمونه می‌باشد، استفاده می‌شود. ساختار کلی شبکه مورد استفاده در شکل ۶ نشان داده شده است. لایه ورودی شبکه با ۳۲ نرون، دو لایه میانی به ترتیب با ۱۶ و ۸ نرون و یک لایه تجمیع با یک نرون طراحی شده است

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - y_{\hat{i}})^2}{n}} \quad (10)$$

پیاده‌سازی در محیط برنامه‌نویسی پایتون و با سیستم سرور ویندوز با اختصاص حجم حافظه حدود ۳۰۰ گیگابایت انجام شده است. نتایج آزمایش‌ها با تکرارها و برچسب‌های زمانی متفاوت در جداول ۳ تا ۵ نشان داده شده و همچنین نمودارهای حاصل از پیش‌بینی مقادیر هر ۳ شاخص در ادامه آمده است. جدول ۳ مربوط به نتایج حاصل از پیش‌بینی

استخراج گردید). نهایتاً از هر سال، داده‌های چهار فصل سال به تعداد پنج قاب استخراج شده‌اند. نمونه‌های به دست آمده در هر ناحیه به صورت



شکل ۵: ساختار یک سلول از شبکه [۳۰].

میانگین شاخص‌های پوشش گیاهی استخراج شده‌اند. توجه به این داده‌ها ضروری است و به صورت ترکیبی از نمونه‌های هر دو ناحیه استفاده می‌شود. ساخت سری زمانی مطلوب با انجام آزمایش‌های مختلف در مورد ترتیب ورودی شبکه، تغییرات فصلی سالیانه و مقدار برچسب زمانی صورت گرفت. داده‌ها به ترتیب فصول پشت سر هم قرار گرفتند و به عنوان مثال، جهت پیش‌بینی داده‌های فصل بهار سال آینده از داده‌های فصل بهار در پنج سال گذشته استفاده گردید. علت انتخاب پنج سال گذشته جهت رسیدن به دقت، مطلوب است چرا که در گذر زمان، مقادیر داده‌ها تغییر می‌یابند و کشف الگوی تغییرات جهت پیش‌بینی مقادیر آینده ضروری است. انجام آزمایش‌ها در استفاده از داده‌های پنج سال گذشته نتایج مطلوبی را گزارش کرد. پس از ساخت داده‌های سری زمانی جهت پیش‌بینی مقادیر آینده، از شبکه عصبی عمیق LSTM استفاده شد. همان طور که ذکر گردید، این شبکه با داشتن حافظه طولانی کوتاه‌مدت در نگهداری اطلاعات مهم بسیار دقیق است و از آن جهت آموزش داده‌ها و نهایتاً پیش‌بینی مقادیر مورد نظر استفاده می‌شود. در ادامه، نحوه عملکرد و ساختار یک شبکه عصبی عمیق مورد بحث قرار می‌گیرد. ساختار یک سلول از این شبکه در شکل ۵ نشان داده شده است [۲۸]. همان طور که در شکل پیداست، این سلول دارای حالات و گیت‌های مختلفی است که به طور مختصر شرح داده می‌شود.

گیت فراموشی با نماد f مشخص شده و (۵) نمایانگر اطلاعات باقیمانده در شبکه است [۲۹]

$$f_t = \sigma(W_f + h_{t-1} + V_f \times x_t + b_f) \quad (5)$$

گیت ورودی با نماد i و (۶) معرفی می‌شود و در ادامه تصمیم می‌گیرد که چه اطلاعاتی باید در شبکه به‌روز شوند. اطلاعات جدید ورودی به شبکه توسط معادله مربوط به اطلاعات پارامتر g با (۷) به سلول حالت اضافه می‌شوند

$$i_t = \sigma(W_i + h_{t-1} + V_i \times x_t + b_i) \quad (6)$$

$$g_t = \tanh(W_g + h_{t-1} + V_g \times x_t + b_g) \quad (7)$$

حالت سلول توسط (۸) با نماد C به‌روز می‌شود

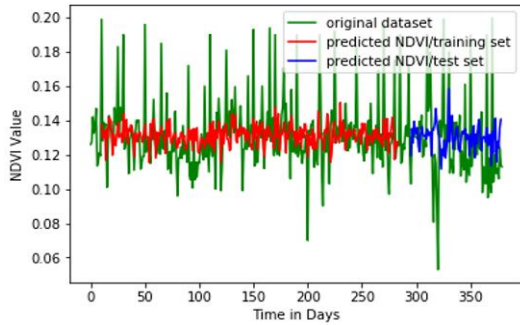
$$C_t = f_t \times C_{t-1} + i_t \times g_t \quad (8)$$

در نهایت مقدار خروجی یک سلول توسط گیت خروجی o با (۹) تولید می‌شود [۲۹]

$$Q_t = \sigma(W_o + h_{t-1} + V_o \times x_t + b_o) \quad (9)$$

همانند جدول ۳ مربوط به شاخص NDVI، نتایج در Epochهای متفاوت و دو برچسب زمانی گزارش شده و لازم به ذکر است که برچسبهای زمانی متفاوت دیگر نیز

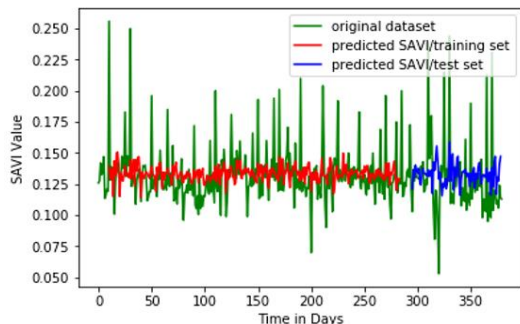
جدول ۳: نتایج خطای حاصل از پیش‌بینی شاخص NDVI.



شکل ۷: نمودار حاصل از پیش‌بینی شاخص NDVI.

Index_Name	Epochs	Time_Stamp	Train_RMSE	Test_RMSE
NDVI	۱۰۰	۱	۰/۰۳	۰/۰۴
	۲۰۰	۱	۰/۰۳	۰/۰۴
	۳۰۰	۱	۰/۰۳	۰/۰۴
	۱۰۰	۶	۰/۰۳	۰/۰۴
	۲۰۰	۶	۰/۰۳	۰/۰۳۱
	۳۰۰	۶	۰/۰۲	۰/۰۳


جدول ۴: نتایج خطای حاصل از پیش‌بینی شاخص SAVI.



شکل ۸: نمودار حاصل از پیش‌بینی شاخص SAVI.

Index_Name	Epochs	Time_Stamp	Train_RMSE	Test_RMSE
SAVI	۱۰۰	۱	۰/۰۴	۰/۰۵
	۲۰۰	۱	۰/۰۴	۰/۰۵
	۳۰۰	۱	۰/۰۳	۰/۰۴
	۱۰۰	۶	۰/۰۳	۰/۰۴
	۲۰۰	۶	۰/۰۲	۰/۰۳
	۳۰۰	۶	۰/۰۱	۰/۰۲

جدول ۵: نتایج خطای حاصل از پیش‌بینی شاخص RVI.



شکل ۹: نمودار حاصل از پیش‌بینی شاخص RVI.

Index_Name	Epochs	Time_Stamp	Train_RMSE	Test_RMSE
RVI	۱۰۰	۱	۰/۰۶	۰/۰۷
	۲۰۰	۱	۰/۰۶	۰/۰۷
	۳۰۰	۱	۰/۰۵	۰/۰۷
	۱۰۰	۶	۰/۰۶	۰/۰۶
	۲۰۰	۶	۰/۰۶	۰/۰۷
	۳۰۰	۶	۰/۰۵	۰/۰۶

می‌شود، تعداد اجراهای الگوریتم و برچسبهای زمانی متفاوت، نتایج مختلفی را گزارش می‌کنند. تعداد اجراهای بیشتر شبکه، نتیجه بهتری در پیش‌بینی داده‌های مراحل آموزش و آزمون دارد و خطای معیار RMSE با مقدار کمتر گزارش می‌شود. همچنین شبکه در برچسب زمانی شش، نتیجه بهتری را گزارش می‌کند. بهترین نتیجه حاصل از پیش‌بینی داده‌های آموزشی و آزمایشی مربوط به تعداد تکرار ۳۰۰ و برچسب زمانی شش می‌باشد.

مورد بررسی قرار گرفته است، اما برچسبهای نزدیک به هم نتایج یکسان را گزارش می‌کنند و همچنین از برچسب شش به بعد نیز نتایج مطلوب به دست نیامد. همان طور که در جدول ۳ مشاهده می‌شود، تعداد اجراهای الگوریتم و برچسبهای زمانی متفاوت نتایج مختلفی را گزارش می‌کنند. تعداد اجراهای بیشتر شبکه نتیجه بهتری در پیش‌بینی داده‌های مراحل آموزش و آزمون دارد و خطای معیار RMSE با مقادیر کمتر گزارش می‌شود. همچنین شبکه در برچسب زمانی شش، نتیجه بهتری را گزارش می‌کند. بهترین نتایج پیش‌بینی داده‌های آموزشی مربوط به تعداد تکرار شبکه برابر با ۳۰۰ و برچسب زمانی شش می‌باشد. همچنین بهترین نتیجه پیش‌بینی داده‌های آزمایشی نیز مربوط به همین تعداد تکرار و برچسب زمانی است.

جدول ۵ مربوط به نتایج حاصل از پیش‌بینی شاخص RVI است. همانند جداول ۴ و ۵، نتایج در Epochهای متفاوت و دو برچسب زمانی گزارش شده و همان طور که در جدول ۵ مشاهده می‌شود، تعداد اجراهای بیشتر شبکه، نتیجه بهتری در پیش‌بینی داده‌های مراحل آموزش و آزمون دارند و خطای معیار RMSE با مقدار کمتری گزارش می‌شود. از تعداد تکرار ۳۰۰ به بالا عملکرد شبکه یکسان است و تغییری حاصل نمی‌شود. همچنین شبکه در برچسب زمانی شش، نتیجه بهتری را گزارش می‌کند. بهترین نتیجه حاصل از پیش‌بینی داده‌های آموزشی و آزمایشی مربوط به تعداد تکرار شبکه در تکرار ۳۰۰ و برچسب زمانی شش می‌باشد. شکل‌های ۷ تا ۹، نمودارهای حاصل از پیش‌بینی شاخص‌های NDVI،

جدول ۴ مربوط به نتایج حاصل از پیش‌بینی شاخص SAVI است.

گونه اختلال منجر به از بین رفتن پوشش گیاهی کمک می‌کند. در این مطالعه به بررسی و تجزیه و تحلیل استفاده از این شبکه جهت پیش‌بینی پویایی پوشش گیاهی پرداختیم. چالش اصلی در این زمینه، دستیابی به داده استاندارد و کافی است که از خطای ابرناکی کمتری برخوردار باشند و همچنین تعداد نمونه‌های بیشتر در مطالعه بسیار کمک‌کننده خواهد بود. در مطالعات آینده می‌توان نواحی با تغییرات پوشش گیاهی بیشتر همراه با نمونه‌های بیشتری را در نظر گرفت و میزان دقت شبکه را بررسی کرد. علاوه بر آن با توجه به محدود بودن حافظه شبکه عصبی بازگشتی، مطالعات بیشتر در این زمینه راهگشا خواهد بود. استفاده از ساختارهای عمیق دیگر که مناسب پیش‌بینی سری زمانی باشند (مثل شبکه‌های کانولوشنی تک‌بعدی)، می‌تواند مد نظر قرار گیرد. همچنین بررسی دیگر شاخص‌های پوشش گیاهی در مناطق مختلف می‌تواند مورد مطالعه قرار گیرد. در نواحی مختلف با توجه به نوع و میزان پوشش گیاهی، شاخص‌های مناسب قابل استخراج خواهند بود.

مراجع

- [۱] ع. شمسی‌پور، س. حیدری و ک. باقری، "پایش روند تغییرات پوشش زمین در شهر کرمانشاه با مدل CA مارکوف، " پژوهش‌های جغرافیایی برنامه‌ریزی شهری، جلد ۵، شماره ۳، صص. ۴۹۵-۵۱۴، پاییز ۱۳۹۶.
- [۲] ع. کاظمی‌نیا، "کاربرد سنجنش از دور در بررسی پوشش گیاهی،" نشریه علمی-ترویجی مهندسی نقشه‌برداری و اطلاعات مکانی، جلد ۹، شماره ۱، صص. ۷۵-۸۵، بهمن ۱۳۹۶.
- [3] Q. Zhuang, S. Wu, X. Feng, and Y. Niu, "Analysis and prediction of vegetation dynamics under the background of climate change in Xinjiang, China," *Peer J. Computer Science*, vol. 23, no. 8, Article ID: 8282, 2020.
- [4] K. Nataliia, M. Lavreniuk, S. Skakun, and A. Shelestov, "Deep learning classification of land cover and crop types using remote sensing data," *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 5, pp. 778-782, May 2017.
- [5] O. H. Adedeji, O. O. Tope-Ajayi, and O. L. Abegunde, "Assessing and predicting changes in the status of Gambari forest reserve, Nigeria using remote sensing and GIS techniques," *J. of Geographic Information System*, vol. 7, no. 3, Article ID: 57588, Jun. 2015.
- [6] J. Xue and S. Baofeng, "Significant remote sensing vegetation indices: a review of developments and applications," *J. of Sensors*, vol. 5, no. 6, pp. 1353691, 2017.
- [7] F. Petitjean, J. Inglada, and P. Gancarski, "Assessing the quality of temporal high-resolution classifications with low-resolution satellite image time series," *International J. of Remote Sensing*, vol. 35, no. 7, pp. 2693-2712, 2014.
- [8] A. Calera, C. Martínez, and J. Melia, "A procedure for obtaining green plant cover: relation to NDVI in a case study for barley," *International J. of Remote Sensing*, vol. 22, no. 17, pp. 3357-3362, 2001.
- [9] W. B. Cohen, T. K. Maersperger, S. Gower, and D. Turner, "An improved strategy for regression of biophysical variables and Landsat ETM+ data," *Remote Sensing of Environment*, vol. 84, no. 4, pp. 561-571, Apr. 2003.
- [10] H. C. Gurgel and N. J. Ferreira, "Annual and interannual variability of NDVI in Brazil and its connections with climate," *International J. of Remote Sensing*, vol. 24, no. 18, pp. 3595-3609, 2003.
- [11] S. Z. Hosseini, M. Kappas, and P. Propastin, "Estimating relationship between vegetation dynamic and precipitation in central Iran," in *Proc. Int. SWAT Conf.*, 6 pp., Toledo, Spain, 15-17 Jul. 2011.
- [12] J. J. Arsanjani, M. Helbich, W. Kainz, and A. D. Boloorani, "Integration of logistic regression, Markov chain and cellular automata models to simulate urban expansion," *International J. of Applied Earth Observation and Geoinformation*, vol. 1, no. 21, pp. 265-275, Apr. 2013.
- [۱۳] ب. فرخ‌زاد، ش. منصوری و ع. سپهری، "بررسی همبستگی بین شاخص‌های پوشش گیاهی NDVI و EVI با شاخص خشک‌سالی هواشناسی SPI (مطالعه

SAVI و RVI را نشان می‌دهند. همان طور که از نمودارهای پیش‌بینی شاخص‌ها پیداست، شبکه با داده‌های سری زمانی به خوبی آموزش دیده و مقادیر آینده این شاخص‌ها با دقت مطلوبی پیش‌بینی شده‌اند. نمودار سبزرنگ داده‌های اصلی، نمودار قرمز رنگ داده‌های پیش‌بینی شده در مرحله آموزش و نمودار آبی رنگ داده‌های پیش‌بینی شده در مرحله آزمون هستند.

سری‌های زمانی پیش‌بینی شده نشان می‌دهند که شبکه حافظه کوتاه-بلندمدت، عملکرد مطلوبی در پیش‌بینی شاخص‌های پوشش گیاهی دارد. حافظه داخلی بلندمدت در آموزش داده‌های ورودی به شبکه به خوبی کمک می‌کند. ساختار سلول حافظه، یک مزیت بزرگ برای این شبکه در پیش‌بینی سری‌های زمانی است. برخلاف سایر شبکه‌های عصبی، این شبکه به تعداد مقادیر زیاد داده در گذشته نیاز ندارد، زیرا می‌تواند تمام اطلاعات مربوط به مقادیر قبلی را در حافظه داخلی خود ذخیره کند. شبکه حافظه کوتاه-بلندمدت، در زمینه‌هایی مانند ارزیابی کیفیت آب، تشخیص تغییر پوشش زمین، نظارت بر سطح زمین و غیره که شبکه بدون نیاز به اطلاعات اضافی به خوبی آموزش می‌بیند، کاربردهای متنوعی دارد. در نتایج نشان داده شد که استفاده از داده‌های چند سال گذشته به همراه آموزش طولانی‌تر شبکه در افزایش دقت پیش‌بینی آن مؤثر است. از طرف دیگر، شبکه در پیش‌بینی برخی شاخص‌ها موفق‌تر عمل کرده است. به طور مثال، در نتایج مشاهده شد که پیش‌بینی شاخص RVI نسبت به دو شاخص دیگر، خطای بیشتری دارد. در مقایسه با مطالعاتی که جهت پیش‌بینی شاخص‌های پوشش گیاهی روی داده‌های ماهواره لندست با استفاده از مدل‌های شبکه‌های عصبی بازگشتی، رگرسیون و مارکوف انجام گردید، مدل معرفی شده مطالعه کنونی دارای دقت بسیار مطلوب‌تری می‌باشد و نتایج بهتری را گزارش می‌کند. در سال ۹۶، در [۳۰] با استفاده از فرآیند مارکوف، مقادیر شاخص پوشش گیاهی برای شهرستان بجنورد در استان خراسان شمالی پیش‌بینی شده که میزان دقت مدل حدود ۸۰٪ گزارش شده است. همچنین در مطالعاتی دیگر با دریافت تصاویر لندست و استفاده از نرم‌افزارهای سنجنش از دور مانند ENVI، اقدام به بررسی تغییرات پوشش گیاهی شده است. در این دسته از مطالعات، تغییرات پوشش گیاهی مورد ارزیابی و مقایسه قرار گرفته و پیش‌بینی‌هایی جهت تغییرات پوشش گیاهی انجام شده که اغلب با خطای زیادی همراه هستند [۳۱]. لذا استفاده از مدل پیشنهادی مطالعه کنونی جهت ساخت داده‌های سری زمانی از داده‌های سالیان متوالی و استفاده از مدل شبکه عصبی مناسب در پیش‌بینی، به دقت مطلوب ۹۹ درصدی رسیده و در مقایسه با روش‌های قبلی مطلوب به نظر می‌رسد.

۵- نتیجه‌گیری

در این مقاله، روشی برای پیش‌بینی تغییرات پوشش گیاهی با استفاده از شبکه حافظه کوتاه-بلندمدت ارائه شده است. در الگوریتم پیشنهادی، ابتدا داده‌های ماهواره لندست ۵، ۷ و ۸ دریافت و پس از انجام اصلاحات اتمسفری روی تصاویر، شاخص‌های مورد نظر، استخراج و سپس داده‌ها به سری زمانی تبدیل شدند. نهایتاً پیش‌بینی این داده‌ها توسط یادگیری عمیق انجام گردیده است. با اجرای روش پیشنهادی جهت پیش‌بینی شاخص‌های پوشش گیاهی، راهی برای پیش‌بینی تغییرات پوشش گیاهی در سال‌های آینده و اتخاذ تدابیر لازم برای حفاظت و بهبود پوشش گیاهی در هر منطقه وجود دارد. شبکه حافظه کوتاه-بلندمدت می‌تواند به طور مؤثر، سری زمانی را نه فقط برای بازه زمانی بعدی، بلکه تا چندین بازه بعدی پیش‌بینی کند که به مراقبت از پوشش گیاهی جهت جلوگیری از هر

- Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B3, pp. 849-852, Jun. 2016.
- [27] E. Y. Liang, X. M. Shao, and J. C. He, "Relationships between tree growth and NDVI of grassland in the semiarid grassland of north China," *International J. of Remote Sensing*, vol. 26, no. 13, pp. 2901-2908, 2005.
- [28] A. Graves, *Supervised Sequence Labelling with Recurrent Neural Networks*, Springer, Berlin-Heidelberg, 2012.
- [29] F. A. Gers and J. Schmidhuber, "Recurrent nets that time and count," in *Proc. of the IEEE-INNS-ENNS Int. Joint Conf. on Neural Networks, IJCNN'00*, 5 pp., Como, Italy, 27-27 Jul. 2000.
- [۳۰] ز. پرور و ک. شایسته، "پیش‌بینی روند تغییرات و توسعه شهری با استفاده از تصاویر ماهواره‌ای چندزمانه و سیستم اطلاعات جغرافیایی (مطالعه موردی: شهر بجنورد)،" *محیط‌شناسی*، جلد ۴۳، شماره ۳، صص. ۵۱۳-۵۲۷، ۱۳۹۶.
- [31] T. Wu, F. Feng, Q. Lin, and H. Bai, "A spatio-temporal prediction of NDVI based on precipitation: an application for grazing management in the arid and semi-arid grasslands," *International J. of Remote Sensing*, vol. 41, no. 6, pp. 2359-2373, 2020.
- الهام زنگنه** تحصیلات خود را در مقطع کارشناسی، مهندسی کامپیوتر گرایش نرم افزار در سال ۱۳۹۳ از دانشگاه رازی کرمانشاه، در مقطع کارشناسی ارشد، مهندسی کامپیوتر گرایش هوش مصنوعی و رباتیک در سال ۱۳۹۸ از دانشگاه صنعتی شاهرود به پایان رسانده است و هم‌اکنون دانشجوی مقطع دکتری هوش مصنوعی و رباتیک در دانشگاه بوعلی سینا همدان می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان: هوش مصنوعی، یادگیری عمیق، پردازش متن و تصویر می‌باشد.
- هدی مشایخی** مدرک دکترای تخصصی رشته مهندسی کامپیوتر (نرم افزار) را از دانشگاه صنعتی شریف در سال ۱۳۹۲ اخذ نموده است. پیش از آن، مقاطع کارشناسی و کارشناسی ارشد را نیز در همان دانشگاه به پایان رسانیده است. یادگیری ماشین، داده کاوی و کاوش داده‌های بزرگ، پردازش توزیع‌شده، سیستم‌های توصیه‌گر و پشتیبان تصمیم، و مدیریت دانش از جمله علایق پژوهشی وی است.
- سعید قره چلو** تحصیلات دکترای تخصصی خود در را در رشته سنجش از دور در سال ۱۳۹۴ در دانشگاه چپا ژاپن به پایان رسانیده است. ایشان هم‌اکنون به عنوان هیأت علمی در دانشگاه صنعتی شاهرود در حال فعالیت آموزشی- تحقیقاتی می‌باشد. یکی از حوزه‌های تخصصی نام‌برده در استخراج و طبقه‌بندی اطلاعات نسبت به تغییرات زیست محیطی و آب با استفاده از تکنیک‌های پردازش داده‌های سنجش از دور ماهواره‌ای است.
- موردی: مراتع استان گلستان)، " *هوشناسی کشاورزی*، جلد ۵، شماره ۲، صص. ۵۶-۶۵ پاییز و زمستان ۱۳۹۶.
- [14] A. Stepchenko and J. Chizhov, "NDVI short-term forecasting using recurrent neural networks," in *Proc. of the 10th Int. Scientific and Practical Conf.*, vol. 3, pp. 180-185, Rēzekne, Latvija, 18-20 Jun. 2015.
- [15] A. Stepchenko, "NDVI index forecasting using a layer recurrent neural network coupled with stepwise regression and the PCA," in *Proc. 5th Int. Virtual Scientific Conf. on Informatics and Management Sciences*, vol. 5, pp. 130-135, Zilina, Slovakia, 24-25 Apr. 2016.
- [16] A. Stepchenko and J. Chizhov, "Applying markov chains for NDVI time series forecasting of Latvian regions," *Information Technology and Management Science*, vol. 18, no. 1, pp. 57-61, 2015.
- [17] E. Kriminger and H. Latchman, "Markov chain model of home-plug CSMA MAC for determining optimal fixed contention window size," in *Proc. of the IEEE Int. Symp. on Power Line Communications and Its Applications ISPLC'11*, pp. 399-404, Udine, Italy, 3-6 Apr. 2011.
- [18] T. Wu, F. Feng, Q. Lin, and H. Bai, "A spatio-temporal prediction of NDVI based on precipitation: an application for grazing management in the arid and semi-arid grasslands," *International J. of Remote Sensing*, vol. 41, no. 6, pp. 2359-2373, 2020.
- [19] P. M. Atkinson and A. R. L. Tatnall, "Introduction neural networks in remote sensing," *International J. of Remote Sensing*, vol. 18, no. 4, pp. 699-709, 1997.
- [20] T. S. Wu, H. P. Fu, G. Jin, H. F. Wu, and H. M. Bai, "Prediction of the livestock carrying capacity using neural network in the meadow steppe," *The Rangeland J.*, vol. 41, no. 1, pp. 65-72, 2019.
- [21] A. Stepchenko and J. Chizhov, "Applying Markov chain for NDVI time series for Latvian regions," *Information Technology Managements Science*, vol. 18, no. 1, pp. 57-61, 2015.
- [22] Y. Bengio, P. Simard, and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," *IEEE Trans. Neural Netw.*, vol. 5, no. 2, pp. 157-166, Mar. 1994.
- [23] P. R. Silva, F. W. Acerbi Júnior, L. M. T. de Carvalho, and J. R. S. Scolforo, "Use of artificial neural networks and geographic objects for classifying remote sensing imagery," *CERNE J.*, vol. 20, no. 2, pp. 267-276, Apr. 2014.
- [24] D. S. Reddy and P. R. C. Prasad, "Prediction of vegetation dynamics using NDVI time series data and LSTM," *Modeling Earth Systems and Environment*, vol. 4, pp. 409-419, 018.
- [25] D. Phiri and J. Morgenroth, "Developments in Landsat land cover classification methods: a review," *International of Remote Sensing*, vol. 9, no. 9, Article ID: 967, 2017.
- [26] Z. Chen, W. G. Jiang, Z. H. Tang, and K. Jia, "Spatial-temporal pattern of vegetation index change and the relationship to land surface temperature in Zoige," *International Archives of the*