





دانشکده مهندسی کامپیوتر

پایان نامه کارشناسی ارشد هوش مصنوعی

پیش بینی مکانی - زمانی داده های سنجش از دور با استفاده از یادگیری عمیق

نگارنده: الهام زنگنه

استادان راهنما

دکتر هدی مشایخی
دکتر سعیده فردوسی

استاد مشاور
دکتر سعید قره چلو

شهریور ۹۸

شماره: ۶۴۶

تاریخ: ۹۸/۶/۲۳

باسمه تعالی



مدیریت تحصیلات تکمیلی

فرم شماره (۳) صورتجلسه نهایی دفاع از پایان نامه دوره کارشناسی ارشد

با نام و یاد خداوند متعال، ارزیابی جلسه دفاع از پایان نامه کارشناسی ارشد خانم / آقای: الهام زنگنه
با شماره دانشجویی: ۹۶۰۸۰۴۴ رشته: مهندسی کامپیوتر گرایش: هوش مصنوعی
تحت عنوان: پیش بینی مکانی - زمانی داده های سنجش از دور با استفاده از یادگیری عمیق
که در تاریخ: ۹۸/۰۶/۱۷ با حضور هیأت محترم داوران در دانشگاه صنعتی شاهرود برگزار گردید به شرح
ذیل اعلام می گردد:

☐ مردود ☒ قبول (با درجه: ...)			
نوع تحقیق: ☐ نظری ☐ عملی			
عضو هیأت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱- استاد راهنمای اول	هروی مسیحی	استادیار	
۲- استاد راهنمای دوم			
۳- استاد مشاور			
۴- نماینده تحصیلات تکمیلی	حسن زحادی	برین	
۵- استاد ممتحن اول	فاطمه حسینی نژاد	استادیار	
۶- استاد ممتحن دوم	مهری دقچویی	استادیار	

نام و نام خانوادگی رئیس دانشکده:

تاریخ و امضاء و مهر دانشکده:

تبصره: در صورتی که کسی مردود شود حداکثر یکبار دیگر (در مدت مجاز تحصیل) می تواند از پایان نامه خود دفاع نماید (دفاع مجدد نباید زودتر از ۴ ماه برگزار شود).

تقدیم به پدر و مادرم.

سپاس‌گزاری...

سپاس و ستایش مر خدای را جل و جلاله که آثار قدرت او بر چهره روز روشن، تابان است و انوار حکمت او در دل شب تار، درفشان. آفریدگاری که خویشتن را به ما شناساند و درهای علم را بر ما گشود و عمری و فرصتی عطا فرمود تا بدان، بنده ضعیف خویش را در طریق علم و معرفت بیازماید. اکنون که به یاری خداوند این دوره را به پایان رسانیده‌ام بر خود لازم می‌دانم تا مراتب سپاس و قدردانی از زحمات بی شائبه بزرگوارانی که افتخار شاگردی ایشان را داشته‌ام و به بنده در این راه بسیار لطف داشتند، تقدیم نمایم. از استاد راهنمای گرامیم سرکار خانم هدی مشایخی که در این راه بنده را راهنمایی نمودند و به بنده بسیار لطف داشتند، همچنین سرکار خانم سعیده فردوسی و جناب آقای سعید قره‌چلو اساتید گرامی راهنمای دوم و مشاور بنده که بنده را در این راه یاری نمودند، نهایت قدر دانی و سپاس را دارم. بدون شک بدون راهنمایی‌ها و لطف این عزیزان به پایان رساندن این دوره بر من مشکل می‌نمود.

الهام زنگنه

شهریور ۹۸

تعهد نامه

اینجانب الهام زنگنه دانشجوی کارشناسی ارشد رشته کامپیوتر مهندسی کامپیوتر دانشگاه شاهرود، نویسنده پایان نامه با عنوان پیش بینی مکانی-زمانی داده های سنجش از دور با استفاده از یادگیری عمیق، تحت راهنمایی هدی مشایخی و سعیده فردوسی متعهد می شوم:

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهش های دیگر پژوهش گران، به مرجع مورد استفاده استناد شده است.
- مطالب این پایان نامه، تا کنون توسط خود، یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارایه نشده است.
- حقوق معنوی این اثر، به دانشگاه صنعتی شاهرود تعلق دارد، و مقالات مستخرج با نام “دانشگاه صنعتی شاهرود” یا “Shahrood University of Technology” به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آوردن نتایج اصلی پایان نامه تاثیرگذار بوده اند، در مقالات مستخرج از پایان نامه رعایت می گردد.
- در تمام مراحل انجام این پایان نامه، در مواردی که از موجود زنده (یا بافت های آنها) استفاده شده است، ضوابط و اصول اخلاقی رعایت شده است.
- در تمام مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته (یا استفاده شده است)، اصل رازداری و اصول اخلاق انسانی رعایت شده است.

الهام زنگنه

شهریور ۹۸

مالکیت نتایج و حق نشر

- تمام حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزارها و تجهیزات ساخته شده) متعلق به دانشگاه صنعتی شاهرود می باشد. این مطلب باید به نحو مقتضی، در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات و نتایج موجود در این پایان نامه بدون ذکر منبع مجاز نمی باشد.

چکیده

سنجش از دور به معنای دریافت اطلاعات بدون تماس مستقیم با سطح است که نیازمند واسطه امواج مغناطیسی است. داده‌های این فناوری از نوع داده‌های مکانی-زمانی هستند. ماهواره لندست از جمله ماهواره‌هایی است که دارای انواع مختلف ۵، ۷ و ۸ است. درک و تحلیل تغییرات داده‌های مکانی-زمانی در جنبه‌های مختلف از جمله برای انجام اقدامات حفاظتی اهمیت زیادی دارد. همچنین اخیراً شبکه عصبی با توجه به کارایی و دقت بالا، در تحلیل داده‌های مختلف از جمله داده‌های سنجش از دور اهمیت زیادی یافته است. به همین منظور در این تحقیق به پیش‌بینی مکانی-زمانی داده‌های سنجش از دور در ناحیه‌ای از شرق کشور ایران می‌پردازیم. مجموعه داده انتخاب شده از داده‌های مکانی-زمانی ماهواره لندست ۵، ۷ و ۸ می‌باشند.

این داده‌ها شامل تصاویر از سال ۲۰۰۰ تا ۲۰۱۸، مربوط به چهار فصل سال در نواحی شمال و شرق شهرستان شاهرود در استان سمنان می‌باشند. شاخص‌های استخراج شده از مجموعه داده جهت پیش‌بینی از دسته شاخص‌های پوشش گیاهی با عنوان $NDVI$ ، $SAVI$ و RVI هستند. روش پیشنهادی جهت پیش‌بینی تغییرات این شاخص‌ها مبتنی بر یادگیری عمیق است. در مطالعات گذشته از روش‌های مارکوف و روش‌های بر مبنای مقایسه جهت پیش‌بینی تغییرات آینده استفاده می‌شده است که دقت گزارش شده در این مطالعات مقدار متوسطی است. در الگوریتم پیشنهادی پس از انجام اصلاحات اتمسفری روی تصاویر، شاخص‌های مورد نظر استخراج می‌شوند و سپس داده‌ها به سری زمانی تبدیل می‌شوند. در نهایت پیش‌بینی این داده‌ها توسط الگوریتم یادگیری عمیق انجام می‌شود.

جهت اندازه‌گیری دقت الگوریتم از میانگین مجذور خطا ریشه یا $RMSE$ استفاده می‌شود. نتایج حاصل از آزمایش‌ها دقت بالای الگوریتم را بازگو می‌کند به طوریکه شبکه عصبی با وجود تغییرات موجود در شاخص‌ها، به خوبی آموزش دیده و مقادیر را پیش‌بینی می‌کند. میزان خطای شبکه بدون وجود داده‌های اضافی برای شاخص $NDVI$ برابر با ۰.۰۲، شاخص $SAVI$ برابر با ۰.۰۳ و شاخص RVI برابر با ۰.۰۵ گزارش می‌شود.

با اتخاذ روش ارائه شده در این تحقیق، پیش‌بینی تغییرات پوشش گیاهی می‌تواند با دقتی بیش از ۹۹ درصد انجام شود. در مطالعات گذشته با استفاده از مدل مارکوف و رگرسیون لجستیک تغییرات پوشش گیاهی داده‌های ماهواره لندست، مورد بررسی قرار گرفتند و پیش‌بینی‌های انجام شده دقت کار را تا ۸۰ درصد گزارش می‌کند.

کلمات کلیدی: یادگیری عمیق، پیش‌بینی، مکانی-زمانی، سری زمانی

فهرست مطالب

س	فهرست تصاویر	
ف	فهرست جداول	
۱	مقدمه	۱
۱	۱.۱ تعریف مساله	۱
۲	۲.۱ اهمیت موضوع	۲
۳	۳.۱ مشکلات موجود و راه کار پایان نامه	۳
۳	۴.۱ ساختار پایان نامه	۳
۵	۲ پژوهش های پیشین	۵
۵	۱.۲ مقدمه	۵
۶	۲.۲ نگاهی به مفاهیم مساله	۶
۶	۱.۲.۲ سنجش از دور	۶
۱۳	۲.۲.۲ یادگیری عمیق	۱۳
۱۶	۳.۲.۲ شاخص های پوشش گیاهی	۱۶
۱۷	۳.۲ سیر تکاملی داده های ماهواره ای لندست	۱۷
۱۹	۴.۲ سیر تکاملی شبکه های حافظه ی طولانی کوتاه- مدت	۱۹
۱۹	۱.۴.۲ شبکه های عصبی بازگشتی	۱۹
۲۰	۲.۴.۲ شبکه های حافظه طولانی کوتاه- مدت	۲۰
۲۱	۳.۴.۲ ساختار و نحوه ی عملکرد شبکه حافظه ی طولانی کوتاه- مدت	۲۱
۲۵	۵.۲ انواع روش های پیش بینی در مطالعات	۲۵
۲۶	۶.۲ مطالعات انجام شده در ایران و جهان	۲۶
۲۹	۷.۲ نتیجه گیری	۲۹
۳۱	۳ روش پیشنهادی جهت پیش بینی داده های مکانی- زمانی	۳۱
۳۱	۱.۳ مقدمه	۳۱

۳۲		۲.۳ ساختار داده‌ها
۳۲		۳.۳ مراحل انجام پژوهش
۳۵		۱.۳.۳ پیش‌پردازش داده‌ها
۳۶		۲.۳.۳ محاسبه‌ی شاخص‌های پوشش گیاهی
۳۸		۳.۳.۳ استخراج نواحی و ساخت داده‌های سری زمانی
۴۰		۴.۳ استفاده از شبکه حافظه طولانی کوتاه-مدت جهت پیش‌بینی
۴۱		۵.۳ نتیجه‌گیری
۴۳		۴ نتایج آزمایش‌ها
۴۳		۱.۴ مقدمه
۴۳		۲.۴ نمونه‌ها و معیار ارزیابی
۴۴		۳.۴ نتایج الگوریتم
۴۹		۴.۴ مقایسه نتایج با مطالعات مرتبط اخیر
۵۱		۵ نتیجه‌گیری و کارهای آینده
۵۱		۱.۵ مقدمه
۵۱		۲.۵ مشکلات و محدودیت‌های موجود
۵۲		۳.۵ کارهای آینده
۵۳		مراجع

فهرست تصاویر

۷	فرآیند سنجش از دور [۱۴]	۱.۲
۸	تفکیک مکانی [۱۱]	۲.۲
۱۶	ساختار یک شبکه عصبی پیشخور	۳.۲
۱۶	ساختار یک شبکه عصبی بازگشتی	۴.۲
۱۸	بازه زمانی سنسورهای ماهواره لندست در فضا [۷۸]	۵.۲
۱۹	ساختار یک شبکه عصبی بازگشتی ساده	۶.۲
۲۱	ساختار یک شبکه <i>LSTM</i>	۷.۲
۲۲	ساختار یک بلوک شبکه <i>LSTM</i> [۸۰]	۸.۲
۲۴	لایه دروازه فراموشی در شبکه <i>LSTM</i> [۸۰]	۹.۲
۲۴	لایه دروازه ورودی در شبکه <i>LSTM</i> [۸۰]	۱۰.۲
۲۵	به روز رسانی حالت قدیم سلول به حالت جدید در شبکه <i>LSTM</i> [۸۰]	۱۱.۲
۲۵	به روز رسانی حالت قدیم سلول به حالت جدید در شبکه <i>LSTM</i> [۸۰]	۱۲.۲
۳۴	فلوچارت کلی معماری	۱.۳
۳۷	فلوچارت تصحیحات اتمسفری	۲.۳
۳۹	موقعیت عکس دریافت شده از سایت <i>USGS</i>	۳.۳
۴۷	مقادیر پیش‌بینی شده برای دو دسته آموزش و آزمون شاخص <i>NDVI</i>	۱.۴
۴۸	مقادیر پیش‌بینی شده برای دو دسته آموزش و آزمون شاخص <i>SAVI</i>	۲.۴
۴۸	مقادیر پیش‌بینی شده برای دو دسته آموزش و آزمون شاخص <i>RVI</i>	۳.۴

فهرست جداول

۱۰	۱.۲	مشخصات ماهواره‌هایی که داده‌های آن‌ها برای انواع مختلف مطالعات استفاده می‌شود
۳۳	۱.۳	اطلاعات باندهای لندست ۴ و ۵
۳۳	۲.۳	اطلاعات باندهای لندست ۷
۳۴	۳.۳	اطلاعات باندهای لندست ۸
۴۴	۱.۴	اطلاعات شبکه استفاده شده
۴۵	۲.۴	نتایج حاصل از پیش‌بینی شاخص‌ها در مرحله اول آزمایش
۴۵	۳.۴	نتایج حاصل از پیش‌بینی شاخص‌ها در مرحله دوم آزمایش
۴۶	۴.۴	نتایج نهایی حاصل از پیش‌بینی شاخص <i>NDVI</i>
۴۷	۵.۴	نتایج نهایی حاصل از پیش‌بینی شاخص <i>SAVI</i>
۴۹	۶.۴	نتایج نهایی حاصل از پیش‌بینی شاخص <i>RVI</i>

فصل ۱

مقدمه

۱.۱ تعریف مساله

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 فرایندهای زیست محیطی بر روی زمین، انجام می‌گردد. برنامه‌ریزی مدلسازی روند تغییرات و پیش‌بینی آن برای آینده از اهمیت زیادی برخوردار می‌باشد. در واقع پیش‌بینی تغییرات پوشش زمین، به درک و فهم فرایندهای تغییرات پوشش زمین کمک می‌کند و همچنین در آگاه‌سازی تصمیم‌گیرنده‌های زیست محیطی در مورد شرایط آینده احتمالی پوشش‌های زمین تحت سناریوهای مختلف، می‌تواند مورد استفاده قرار بگیرد. در مدل‌سازی‌های زمانی و مکانی، فناوری سنجش از دور و سیستم اطلاعات جغرافیایی نقش محوری را ایفا می‌کنند، به گونه‌ای که فناوری سنجش از دور با فراهم آوردن داده‌های چند طیفی و چند زمانه‌ای از نظر هزینه و زمان مقرون به صرفه بوده و اطلاعات ارزشمندی را برای درک و فهم و پایش الگوها و پروسه‌های پوشش زمین موجب می‌شود؛ بنابراین داده‌های به دست آمده به وسیله این فناوری می‌توانند به عنوان مهم‌ترین منبع در فراهم سازی داده‌های پایه‌ای برای پیش‌بینی تغییرات پوشش زمین به کار روند. در سال‌های اخیر نشان داده شده است که یادگیری عمیق از پتانسیل بالایی برای طبقه‌بندی داده‌های سنجش از دور برخوردار می‌باشد [۱].

یادگیری عمیق رویکردی است که در آن ویژگی‌ها به صورت سلسله مراتبی در یک چهارچوب یادگیری با نظارت به دست می‌آیند [۱۵]. بنابراین با توجه به اینکه در مطالعات پیشین در این حوزه اغلب با استفاده از روش‌های مقایسه‌ای با استفاده از نرم‌افزارهای سنجش از دور، شبکه‌های عصبی و یا استفاده از مدل مارکوف به بررسی و پیش‌بینی تغییرات پرداخته شده است، در این پژوهش به قصد بهبود دقت و پیش‌بینی مناسب از مدل‌های شبکه عصبی عمیق استفاده خواهیم کرد.

مطالعه موردی پایان نامه در نواحی از شمال و شرق شهرستان شاهرود از توابع استان سمنان در ناحیه شرق ایران است که در دسترس دخالت‌های انسانی نبوده و در طی زمان دارای تغییر پوشش گیاهی بوده است. با استفاده از داده‌های سنجش از دور مربوط به ماهواره‌های لندست ۵ و ۷ و ۸ محاسبه شاخص‌های مناسب پوشش گیاهی از شبکه‌های یادگیری عمیق استفاده کرده و نتایج پیش‌بینی تغییرات جهت برنامه‌ریزی‌های مهم آینده ثبت شده است. این تحقیق در ادامه تحقیقات پیشین انجام شده در حوزه داده‌های لندست که اغلب به صورت مقایسه تغییرات پوشش گیاهی در نواحی مختلف و یا استفاده از مدل‌های مارکوف جهت پیش‌بینی تغییرات آینده است، انجام می‌شود. نتایج حاصل از تحقیق کنونی دقتی بالاتر از ۹۹ درصد را گزارش می‌کند.

۲.۱ اهمیت موضوع

تغییرات در پوشش زمین که در سطوح مختلف فضایی و در دوره‌های زمانی متفاوت رخ می‌دهد، گاه سودمند بوده و گاهی تأثیرات زیانبار قابل ملاحظه‌ای را در پی دارد که این اثرات نگران‌کننده، منشاء بروز آثار غیر قابل جبرانی بر منابع زمینی و محیط زیست است [۲]. از مهم‌ترین این نگرانی‌ها تغییر در کاهش وسعت جنگل‌ها، تبدیل مراتع و پوشش‌های طبیعی به نواحی بایر، تبدیل در زمین‌های زراعی و باغی به کاربری‌های شهری می‌توان اشاره کرد. تأثیر این تغییرات چه در کوتاه‌مدت و چه در بلندمدت باعث از بین رفتن معادلات طبیعی شده و اثرات زیانباری بر روی منابع طبیعی خواهد داشت و در نتیجه بوم سازگان‌های محیطی با مشکلات عدیده‌ای مواجه خواهند شد. اطلاع از نسبت کاربری‌ها/پوشش اراضی در یک محیط طبیعی و نحوه تغییرات آن در گذر زمان یکی از مهمترین موارد در برنامه‌ریزی‌ها می‌باشد. با اطلاع از نسبت تغییرات کاربری‌ها در گذر زمان می‌توان تغییرات آتی را پیش‌بینی نموده و اقدامات مقتضی را انجام داد. تهیه نقشه‌های به‌روز و پیش‌بینی تغییرات مکانی- زمانی، در زمینه‌های توسعه کشاورزی، برنامه‌ریزی منابع آبی، کاهش اثرات خشکسالی و غیره بسیار مورد توجه است [۳]. بنابراین پژوهش حاضر با هدف پیش‌بینی آینده تغییرات پوشش زمین با استفاده از الگوریتم‌های یادگیری عمیق و همچنین استفاده از شاخص‌های پوشش گیاهی مناسب، سعی در پیش‌بینی دقیق شاخص‌های پوشش گیاهی در نواحی از کشور ایران را خواهد داشت.

۳.۱ مشکلات موجود و راه کار پایان نامه

داده‌های مکانی-زمانی ماهواره لندست در مطالعات اخیر و گذشته مورد استفاده قرار گرفته‌اند. اغلب پژوهش‌های انجام شده در این مورد معمولاً توسط متخصصان با استفاده از نرم افزارهای سنجش از دور انجام می‌شود. به این صورت که تصاویر به نرم افزار داده می‌شوند و سپس عملیات پیش پردازش و استخراج ویژگی‌ها توسط نرم افزار انجام می‌شود. نتایج، حاصل از مقایسه‌ی تغییرات مشاهده شده می‌باشد [۱۳].

در نوعی دیگر از مطالعات عملیات پیش‌بینی با استفاده از مدل‌های مخفی مارکوف^۱ انجام می‌شوند. در سال ۱۳۹۶ مطالعه‌ای در این زمینه با مدل مارکوف در شهرستان بجنورد از توابع استان خراسان انجام شده است که دقت نهایی کار ۸۰ درصد گزارش شده است [۱۲]. مطالعات دیگر نیز مشابه با کارهای انجام شده دقت بسیار خوبی را در پیش‌بینی ارائه نکرده‌اند. بنابراین وجود الگوریتمی کارا با دقتی مناسب جهت پیش‌بینی تغییرات آینده لازم است. مشکل دیگر در دستیابی به داده‌های استاندارد است، چرا که داده‌های سنجش از دور معمولاً متأثر از نویزهایی مانند ابر هستند که سبب کاهش کیفیت داده می‌شوند. بنابراین استفاده از داده‌های مناسب جهت انجام تحقیق بسیار مهم است.

روش پیشنهادی پایان‌نامه مبتنی بر یادگیری عمیق است. در این الگوریتم وجود داده‌های سری زمانی لازم است. ما با استفاده از داده‌های مکانی-زمانی ماهواره لندست، با درصد ابر کمتر از ده درصد، شاخص‌های مناسب پوشش گیاهی را استخراج می‌کنیم. پس از استخراج شاخص‌ها داده‌های سری زمانی ساخته می‌شوند. سپس با استفاده از الگوریتم *LSTM*^۲ به پیش‌بینی تغییرات شاخص‌ها اقدام می‌شود. نتایج به دست آمده از الگوریتم پیشنهادی دقتی بیش از ۹۹ درصد را گزارش می‌کند و شاخص‌های استخراج شده با دقتی بسیار بالا پیش‌بینی می‌شوند.

۴.۱ ساختار پایان‌نامه

این پایان‌نامه با هدف پیش‌بینی تغییرات پوشش گیاهی با استفاده از الگوریتم یادگیری عمیق، در پنج فصل تهیه و تدوین شده است. فصل اول مربوط به مقدمه، تعریف پژوهش و ادبیات آن است. فصل دوم، سیری بر مطالعات انجام شده در گذشته و مفاهیم پژوهش دارد. فصل سوم روش پیشنهادی پایان‌نامه، فصل چهارم نتایج انجام پژوهش و فصل آخر در مورد نتیجه‌گیری و کارهای آینده صحبت خواهد کرد.

^۱CA-Markov

^۲Long Short Term Memory

فصل ۲

پژوهش‌های پیشین

۱.۲ مقدمه

پیش‌بینی تغییرات پوشش زمین، به درک و فهم فرآیندهای تغییرات پوشش زمین کمک می‌کند. در مدل‌سازی‌های زمانی و مکانی، فناوری سنجش از دور و سیستم اطلاعات جغرافیایی نقش محوری را ایفا می‌کنند، به گونه‌ای که فناوری سنجش از دور با فراهم آوردن داده‌های چند طیفی و چند زمانه‌ای از نظر هزینه و زمان مقرون به صرفه بوده و اطلاعات ارزشمندی را برای درک و فهم و پایش الگوها و فرآیندهای پوشش زمین موجب می‌شود؛ بنابراین داده‌های به دست آمده به وسیله این فناوری می‌توانند به عنوان مهم‌ترین منبع در فراهم سازی داده‌های پایه‌ای برای پیش‌بینی تغییرات پوشش زمین به کار روند. استفاده از الگوریتم مناسب جهت استفاده از این داده‌ها بسیار با اهمیت است و الگوریتم‌های یادگیری عمیق از جایگاه ویژه‌ای در یادگیری، دسته‌بندی و پیش‌بینی داده‌ها برخوردار هستند و پس از الگوریتم‌های شبکه عصبی بازگشتی و مدل‌های مارکوف دقت بسیار بالایی را در یادگیری به دست آورده و هم‌اکنون در صدر رده‌بندی دقت این الگوریتم‌ها قرار دارند. در ادامه فصل ابتدا نگاهی به مفاهیم مساله خواهیم داشت و سپس به سیر تکاملی داده‌های ماهواره لندست، الگوریتم‌های شبکه عصبی و مقایسه آن‌ها با هم می‌پردازیم و در آخر نیز مطالعات انجام شده در ایران و جهان را مورد بررسی قرار خواهیم داد.

۲.۲ نگاهی به مفاهیم مساله

۱.۲.۲ سنجش از دور

سنجش از دور^۱ اشاره به علم شناسایی ویژگی‌های سطح زمین و برآورد خواص ژئو-بیوفیزیکی مانند مشخصه‌های مکانی، طیفی و زمانی اشیا یا پدیده‌های آن‌ها بدون تماس مستقیم و با استفاده از واسطه‌هایی مانند امواج الکترومغناطیسی دارد [۱۶]. سنجش از دور امکان گردآوری اطلاعات از مناطق غیر قابل دسترس و پر خطر را ایجاد می‌کند و همچنین می‌تواند جایگزین روش‌های جمع‌آوری اطلاعات پر هزینه باشد [۱۷] و [۱۸].

تاریخچه سنجش از دور به بیش از یک قرن می‌رسد. این کار با عکس‌برداری هوایی از بالن‌ها و سپس هواپیما و فضاپیما آغاز شد. ثابت شده است که سنجش از دور منبع بارزش و مطمئنی برای اطلاعات جغرافیایی مختلف است. انواع گوناگون سنجنده‌های هوایی و فضایی تصاویری را تولید کرده‌اند که در دامنه وسیعی از کاربردها، از پیش‌بینی هوا و تغییر و تبدیل منابع تا برنامه‌ریزی سرزمین و دفاع، استفاده شده‌اند. در سال ۱۸۵۹ اولین عکس هوایی توسط گاسپارد فلیکس از یک بالون هوایی تهیه شد [۲۱]. در سال ۱۹۰۸ ویلبرایت اولین هواپیمای عکاس را رهبری نمود و بونویلان عکس‌های هوایی را تهیه کرد. در سال‌های آخر جنگ جهانی اول عکس‌های هوایی به سرعت برای اهداف شناسایی به کار گرفته شدند. اما جنگ جهانی دوم دوره جدیدی برای عکس‌برداری‌های هوایی به همراه داشت. به طوریکه پیشرفت‌های مهمی در صنعت عکس‌برداری حاصل شد و استفاده از فیلم‌های حساس مادون قرمز رایج گردید [۱۹] و [۲۰]. در دهه ۱۹۶۰ آمریکا از طریق ماهواره‌های جاسوسی خود شروع به جمع‌آوری اطلاعات بر علیه کوبا و شوروی سابق نمود. در سال ۱۹۷۲ ناسا^۲ اولین ماهواره ارزیابی منابع زمینی به نام ۱-ERTS^۳ را به فضا پرتاب کرد که بعدها تحت نام لندست^۴ شناخته شد [۲۲]. به دنبال پرتاب اولین ماهواره مطالعه منابع زمینی آمریکا که بعدها به سری لندست تغییر نام داد، دفتر جمع‌آوری اطلاعات ماهواره‌ای در سازمان برنامه و بودجه وقت در سال ۱۳۵۳ تاسیس گردید. پس از مطالعات اولیه و کسب نتایج مطلوب از تصاویر ماهواره‌ای و به منظور دسترسی مستقیم به تصاویر ماهواره‌ای، دفتر مذکور به مرکز سنجش از دور تغییر نام داد. در سال ۱۳۵۵ در قالب "طرح استفاده از ماهواره" با هدف دریافت مستقیم اطلاعات ماهواره‌ای، پردازش، تکثیر و توزیع اقدام به خرید و نصب یک ایستگاه گیرنده تصاویر ماهواره‌ای در ماهدشت کرج گردید. در ایستگاه مذکور سیستم‌های زیر پیش‌بینی گردید:

۱. سیستم ردیابی و دریافت اطلاعات

¹ Remote Sensing

² National Aeronautics and Space Administration (NASA)

³ Earth Resources Technology Satellite 1

⁴ landsat


۲. سیستم فرآیند و تصحیح اطلاعات

۳. سیستم تفسیر اطلاعات

۴. سیستم مدیریت اطلاعات

۵. سیستم تکثیر و چاپ اطلاعات

امروزه فناوری سنجش از دور گسترش بسیار زیادی یافته است. سنجش از دور علاوه بر جایگاه علمی ویژه خود به عنوان ابزاری در دست دانشمندان علوم مختلف، به عنوان یک تجارت گسترده نیز مطرح است و کشورهای بسیاری وارد این حوزه شده‌اند [۲۳]. این فناوری در ساخت انواع سنسورها^۵ پیشرفت زیادی داشته است، به طوریکه امروزه نقشه‌برداری، هواشناسی، زمین‌شناسی و تمامی موارد مشابه وابسته به این علم و داده‌های آن هستند [۲۴]. در شکل ۱.۲ فرآیند سنجش از دور نشان داده شده است [۲۵]. همان طور که در شکل پیداست وجود یک منبع نور لازمه انجام فرآیند است، این منبع عمل روشن‌سازی هدف مورد مطالعه را بر عهده دارد. پس از تابش انرژی از منبع به جسم هدف تعامل صورت می‌گیرد و بازتاب الکترومغناطیس از سطح هدف حاوی اطلاعات سطح می‌باشد سنسور ماهواره آن اطلاعات را جمع‌آوری کرده و ثبت می‌کند. انرژی ضبط شده توسط سنسور به شکل الکترونیکی به یک ایستگاه دریافت و پردازش برای بازسازی تصویر اخذ شده انتقال می‌یابد. تصویر به صورت بصری و یا رقمی تفسیر شده و اطلاعات لازم درباره هدف استخراج می‌شوند. از اطلاعات استخراج شده برای درک بهتر، کشف اطلاعات جدیدتر و یا کمک به حل یک مساله خاص استفاده می‌شود.




شکل ۱.۲: فرآیند سنجش از دور [۱۴]

هر وسیله‌ای که اشعه الکترومغناطیسی منعکس شده از پدیده‌های مختلف یا سایر انرژی‌های ساطع شده (مثل مادون قرمز حرارتی) را جمع‌آوری نموده و به شکلی مناسب، برای کسب اطلاعات از محیط اطراف ارائه دهد، سنجنده نامیده می‌شود [۲۶]. سنجنده را می‌توان

⁵sensor

دستگاهی دانست که انرژی الکترومغناطیسی را دریافت کرده و انرژی دریافتی را پس از اعمال یک سری تبدیلات به صورتی قابل بازیافت (به صورت عددی یا آنالوگ) ذخیره می‌نماید. شناخت خصوصیات سنجنده‌ها در انتخاب هر چه بهتر تصویرهای مورد نیاز در یک پروژه کمک می‌کند. در کنار اصطلاح سنجنده دو اصطلاح دیگر نیز بکار برده می‌شود که عبارتند از: آشکارساز^۶ و دستگاه^۷ [۴]. مشخصه سنجنده‌های تصویربرداری که در محدوده مرئی و مادون قرمز کار می‌کنند را می‌توان در عبارت قدرت تفکیک^۸ بیان کرد که عبارتند از: قدرت تفکیک مکانی، قدرت تفکیک طیفی، قدرت تفکیک رادیومتریکی و قدرت تفکیک زمانی. از دیگر مشخصه‌های مهم می‌توان به رفتار بخش اسکن کننده‌ی دستگاه و خواص هندسی تصاویر فراهم شده توسط سیستم اشاره کرد. رابطه‌ی بین توان تفکیک مکانی سنجنده و دوره تناوب مداری سکو، تعداد دفعاتی که یک نقطه‌ی مشخص روی زمین در طول هر پاره‌ی زمانی دلخواه مشاهده می‌شود را تعیین می‌کنند.

۱. قدرت تفکیک مکانی: برای تعریف توان تفکیک مکانی از چهار معیار خواص هندسی سیستم تصویربردار، قابلیت تشخیص بین نقاط نشانه، قابلیت اندازه‌گیری تناوب نشانه‌های تکراری و قابلیت اندازه‌گیری خواص طیفی نشانه‌های کوچک استفاده می‌کنند. مشهورترین معیار سنجش، براساس خواص هندسی سیستم تصویربرداری، میدان دید لحظه‌ای (IFOV)^۹ سیستم است. IFOV در تئوری، مساحتی است روی زمین که توسط دستگاه از یک ارتفاع مشخص و در یک لحظه دلخواه دیده می‌شود. IFOV را می‌توان به دو روش بیان کرد، یکی به صورت زاویه و دیگری بصورت فاصله متناظر X-Y روی زمین.



شکل ۲.۲: تفکیک مکانی [۱۱]

۲. قدرت تفکیک رادیومتری: قدرت تفکیک رادیومتری یا حساسیت رادیومتریکی، به تعداد

^۶Detector

^۷Instrument

^۸Resolution

^۹Instantaneous field of view

سطوح کوانتیزه شده‌ی رقومی مورد استفاده در بیان داده‌های گردآوری شده توسط سنجنده، اشاره می‌کند. به طور کلی هر چه سطوح کوانتیزه بیشتر باشد، جزئیات اطلاعات جمع‌آوری شده توسط سنجنده بیشتر خواهد بود. هر زمان که تصویری بر روی فیلم و یا توسط یک سنجنده دریافت می‌گردد، حساسیت آن نسبت به انرژی الکترومغناطیسی، تعیین کننده قدرت تفکیک رادیومتریک سنجنده است. در حالت ساده می‌توان یک تصویر رقومی را با دو سطح در نظر گرفت که در آن سطح صفر به صورت مشکی و سطح یک به صورت سفید نمایش داده شود. اگر تعداد سطوح به ۱۶ افزایش یابد میزان جزئیات قابل مشاهده بر روی تصویر نیز بیشتر می‌شود.

۳. قدرت تفکیک طیفی: این خصوصیت در سنجنده‌ها را می‌توان به دو بخش تقسیم نمود. اولین مورد تعداد و دومین مورد فاصله میان باندها بر حسب طول موج در طیف الکترو مغناطیس می‌باشد. برداشت اطلاعات از پدیده‌ها در سنجنده‌های دارای باندهای بیشتر منجر به بالا رفتن قدرت تمایز میان اشیاء گوناگون می‌شود.

قدرت تفکیک طیفی یک سنجنده تعداد باند و کمترین پهنای باندی است که سنجنده می‌تواند تشخیص دهد، که بر حسب میکرومتر یا نانومتر اندازه‌گیری می‌شود.

۴. قدرت تفکیک زمانی: علاوه بر قدرت تفکیک‌های رادیومتری، طیفی و مکانی، قدرت تفکیک زمانی نیز برای سنجنده از اهمیت زیادی برخوردار است. قدرت تفکیک زمانی عبارت است از مدت زمانی که یک سنجنده بتواند دقیقاً منطقه‌ی مشخصی را با یک زاویه‌ی دید مشخص دوباره در دید خود داشته باشد.

در جدول ۱.۲ مشخصات ماهواره‌هایی که داده‌های آن‌ها برای انواع مطالعات مورد استفاده قرار می‌گیرد، وجود دارد که تنوع نوع سنجنده و داده‌ها در آن قابل مشاهده است [۲۳].

براساس نوع منبع انرژی مورد استفاده، دو نوع سنجش از دور فعال و سنجش از دور غیر فعال داریم. در سنجش از دور فعال، سنسورها امواجی را از خود تولید می‌کنند و با تاباندن آن به سمت هدف و دریافت بازتاب حاصل از آن، به اطلاعات هدف دست می‌یابند. در سنجش از دور غیر فعال، منبع مورد استفاده انرژی یک منبع طبیعی مانند نور خورشید است [۲۷].

سنجش از دور در بسیاری از زمینه‌های علمی - تحقیقاتی کاربرد دارد. از جمله توانمندی‌های این فناوری می‌توان به استفاده از آن در زمین شناسی، آب شناسی، معدن، شیلات، کارتوگرافی، جغرافیا، مطالعات زیست شناسی، مطالعات زیست محیطی، سیستم‌های اطلاعات جغرافیایی، هواشناسی، کشاورزی، جنگلداری، توسعه اراضی و به طور کلی مدیریت منابع زمینی و غیره اشاره کرد [۲۸]. به طور کلی می‌توان کاربردهای سنجش از دور را به چهار دسته سنجش از دور پوشش گیاهی، سنجش از دور آب، سنجش از دور خاک، زمین شناسی و زمین‌ریخت شناسی و همچنین سنجش از دور اتمسفری و بررسی تغییرات اقلیمی و آب و هوایی دسته‌بندی کرد که در ادامه به طور مختصر به معرفی هر کدام می‌پردازیم. لازم به ذکر است که سنجش

جدول ۱.۲: مشخصات ماهواره‌هایی که داده‌های آن‌ها برای انواع مختلف مطالعات استفاده می‌شود

<i>RevisitCapability</i>	<i>Spatialresolution(m)</i>	<i>Swath(Km)</i>	<i>Sensor</i>	<i>Satellite</i>
<i>Mobilizedtoorder</i>	1.0 < 2-1 10-2	<i>Variable</i> <i>Variable</i> 225-100	<i>Variable</i> <i>CASI</i> Hymap	<i>Aireborne</i>
1.1days	45.0 85.1	4.16 4.16	<i>Panchromatic</i> <i>MultiSpectral</i>	<i>WoldView</i>
1.5-3 days	0.6 2.4	16.5 16.5	<i>Panchromatic</i> <i>MultiSpectral</i>	<i>Quickbird</i>
1.5-3 days	1 4	11 11	<i>Panchromatic</i> <i>MultiSpectral</i>	<i>IKONOS</i>
1 days	6.5	77 * 1500	<i>MultiSpectral</i>	<i>RapidEye</i>
16 days	30 30	60 7.5	<i>ALI</i> <i>Hypersion</i>	<i>EO – 1</i>
4-16 days	90, 30, 15	60	<i>ASTER</i>	<i>TERRA</i>
<i>Atleasttwicedaily</i>	250, 500, 1000	2300	<i>MODIS</i>	<i>TERRA/Aqua</i>
<i>RealTime</i>		1, 4, 8	<i>Variable</i>	<i>GOES</i>
<i>Severaltimesperyear</i>	45	35	<i>PRISM</i>	<i>ALOS</i>
11timesevery26days	10 20	60-80 60-80	<i>Panchromatic</i> <i>MultiSpectral</i>	<i>SPOT – 4</i>
11timesevery26days	5 10	60-80 60-80	<i>Panchromatic</i> <i>MultiSpectral</i>	<i>SPOT – 5</i>
2 – 3days	1 15	15 15	<i>Panchromatic</i> <i>MultiSpectral</i>	<i>Kompsat</i>
<i>Every26days</i>	30 120	185 185	<i>TM_Multispectral</i> <i>TM_Thermal</i>	<i>Landsat – 5</i>
<i>Every16days</i>	15 30 60	185 185 185	<i>ETM + Panachromatic</i> <i>ETM + Multispectral</i> <i>ETM + Thermal</i>	<i>Landsat – 7</i>
<i>Severaltimesperday</i>	1100	2399	<i>AVHRR</i>	<i>NOAA</i>
2 – 3day	300	575	<i>MERIS</i>	<i>Envisat</i>
<i>Everyfewdays</i>	3 8 25	20 25 25	<i>Ultra – fine</i> <i>Quad – polfine</i> <i>Quad – polsatandard</i>	<i>Radarsat – 2</i>
	30 35	150 170	<i>Wide</i> <i>Extended – low</i>	<i>Radarsat – 1</i>

از دور مورد مطالعه در این پژوهش، از نوع سنجش از دور پوشش گیاهی است، و در آن از تصاویر ماهواره لندست شاخص‌های پوشش گیاهی به این منظور استخراج می‌شوند.

۱. سنجش از دور پوشش گیاهی: گیاهان اولین سطح زنجیره غذایی در یک زیست بوم را تشکیل می‌دهند. بنابراین پایش شرایط پوشش گیاهی به عنوان یک شاخص سلامتی محیط، از اولین مأموریت‌های ماهواره‌ای، همواره مد نظر قرار داشته است. فرآیندهای سنجش از دوری جهت ارزیابی پوشش گیاهی و پایش تغییرات آن به صورت کمی و کیفی توسعه یافته است تا آنجا که حتی برای این کار محصولات خاص ماهواره‌ای به صورت سری‌های زمانی تولید و در اختیار پژوهشگران قرار گرفته است. به کمک این محصولات امکان بررسی تغییرات توان تولیدی و تغییر در مراحل فنولوژیکی گیاهی نیز فراهم شده است [۵].

۲. سنجش از دور آب: وابستگی شدید حیات انسانی به کمیت و کیفیت آب باعث شده است پایش مداوم این پارامتر همواره مورد توجه دانشمندان باشد. خوشبختانه رفتار طیفی آب بسیار متفاوت از سایر مواد است، بنابراین تشخیص آن از سایر پدیده‌های سطح زمین بوسیله سنجش از دور به راحتی امکان‌پذیر است. با این وجود سامانه‌های سنجش از دور نیز به گونه‌ای تغییر ساختار یافته‌اند که بتوانند وضعیت کمی و کیفی پیکره‌های آبی را به راحتی رصد کنند. علاوه بر آن محصولات ماهواره‌ای خاصی جهت بررسی سلامت پیکره‌های آبی تولید می‌شود که می‌تواند در بررسی روند تغییرات این زیست بوم‌ها بسیار کارآمد باشند. معمولاً از این محصولات جهت استقرار سامانه‌های هشداردهی خطرهای محیطی یا مدیریت پایدار این پیکره‌ها استفاده می‌شود [۶].

۳. زمین‌شناسی و زمین ریخت‌شناسی: تاکنون خصوصیات مختلف خاک مانند طبقه خاک، افق خاک، بافت خاک و ویژگی‌هایی مانند شوری، پوسته سطحی، ماده آلی، زبری، وضعیت سلامت و تخریب خاک و غیره به کمک داده‌های سنجش از دور مورد بررسی قرار گرفته‌اند و در این مطالعات توان سنجش از دور به اثبات رسیده است. از دیگر کاربردهای سنجش از دور می‌توان به تهیه نقشه‌های مختلف زمین‌شناسی و زمین ریخت‌شناسی اشاره نمود. در حال حاضر یکی از جذابترین کاربردهای داده‌های ماهواره‌ای به اکتشاف‌های معادن مربوط می‌شود که توجه متخصصین بشماره‌ی را در سراسر جهان به خود جلب نموده است تا جایی که اکنون بسیاری از نرم افزارهای حرفه‌ای پردازش تصویر ماهواره‌ای ابزارهایی برای تشخیص مواد خاص ابر طیفی ماهواره‌ای توسعه داده‌اند [۷].

۴. سنجش از دور اتمسفری و بررسی تغییرات اقلیمی و آب و هوایی: کاربرد سنجش از دور به مطالعه سطحی زمین محدود نمی‌شود و سنجنده‌های ماهواره‌ای ویژه‌ای جهت بررسی پارامترهای اتمسفری چون مقدار ازن، ذرات معلق، ریزگردها و گازها وجود

دارند. بررسی روند تغییرات این پارامترهای اتمسفری در طول زمان همواره یکی از جذابیت‌های فن سنجش از دور به شمار می‌رود. مطالعه پیوسته پارامترهایی که تغییرات آب و هوایی و اقلیمی را نشان می‌دهند مانند درجه حرارت، بارش، رطوبت، برف و غیره توسط سنجنده‌های ماهواره‌ای امکان‌پذیر است و اخیراً محصولات ماهواره‌ای جهت بررسی روند تغییرات آب و هوا تولید شده‌اند که می‌توانند به خوبی خلا موجود در بانک اطلاعات داده‌های هواشناسی را از بین ببرند [۸].

داده‌های سنجش از دور عموماً به داده‌های کلان^{۱۰} معروفند. داده‌های کلان به مجموعه داده‌هایی گفته می‌شود که پردازش آن‌ها به وسیله پایگاه داده‌های سنتی و ابزارهای پردازش و تحلیل سنتی قابل انجام نیست. از یک جهت ارزش بالقوه نهفته در کلان داده‌ها آنقدر بالا است که در دهه آتی می‌توان آن را به مثابه یک چاه جدید نفتی کشف نشده دانست؛ لذا، امروزه داده‌ها به عنوان یک دارائی ملی شناخته می‌شوند. چالش اصلی شامل تجزیه و تحلیل، جمع‌آوری و جستجو در میان داده‌ها است. همچنین فرآیندهایی مانند به اشتراک‌گذاری، انباشت، انتقال و حفظ امنیت داده‌ها از دیگر چالش‌هایی است که در پردازش این داده‌ها با آن‌ها سرو کار داریم [۲۹] و [۳۰].

حجم داده‌های سنجش از دور برای یک صحنه^{۱۱} برای ماهواره‌لندست ۸ در حد گیگابایت، و برای بقیه ماهواره‌ها در حدود صدها مگابایت است. در جدول ۱.۲ تنوع داده‌های ماهواره‌ای از نظر رزولوشن مکانی، زمانی و طیفی بیان شده است. بنابراین داده‌های سنجش از دور بطور واضح داده‌های کلان محسوب می‌شوند و نیاز به ابزارهایی برای تحلیل و آنالیز این داده‌ها به شدت احساس می‌شود. داده‌های سنجش از دور دارای چندین مشخصه هستند، که از مهم‌ترین آن‌ها می‌توان به مشخصه‌های چند منبعی بودن،^{۱۲} چند مقیاسی بودن،^{۱۳} ابعاد بزرگ،^{۱۴} حالت پویا داشتن،^{۱۵} ایزومر^{۱۶} و غیر خطی بودن^{۱۷} اشاره کرد [۲۳]. در ادامه هریک از این ویژگی‌ها را با جزئیات شرح می‌دهیم. همچنین با توجه به اینکه آیا این ویژگی‌ها وابسته به ابزارها یا روش‌های دریافت داده هستند یا نه، در می‌یابیم که حالت پویا داشتن و غیرخطی بودن از مشخصه‌های ذاتی و درونی داده‌های سنجش از دور هستند در حالیکه چند منبعی بودن، ابعاد بزرگ و ایزومر از مشخصه‌های بیرونی یا خارجی داده‌های سنجش از دور هستند.

چند منبعی بودن این داده‌ها که واضح و آشکار است. همانطور که جدول ۱.۲ نشان می‌دهد، از ابزارها و سنسورهای مختلف برای به دست آوردن داده‌ها استفاده می‌شود. چند

¹⁰Big Data

¹¹Scene

¹²multi – source

¹³multi – scale

¹⁴high – dimensional

¹⁵dynamic – state

¹⁶isomer

¹⁷non – linearity

مقیاسی بودن این داده‌ها نیز مشهود است، مقیاس مشاهده^{۱۸} به وضوح یا رزولوشن، فاصله زمانی و محدوده طیفی اشاره دارد [۳۱]. مقیاس مکانی به وضوح مکانی اشاره می‌کند و به معنی اندازه کوچکترین اشیایی است که بتوان توسط سنسور تشخیص داد. همچنین منظور از فاصله زمانی، دوره‌ای است که طول می‌کشد تا ماهواره از یک ناحیه مجدداً عکسبرداری کند. ویژگی ابعاد بزرگ داده‌های کلان سنجش از دور بطور عمده از ابعاد طیفی و زمانی داده‌ها منعکس شده است. برای مثال سیستم AVIRIS^{۱۹} با ۲۲۴ باند طیفی در ناحیه ۰.۴ تا ۰.۲۵ میکرومتر از نظر ابعاد طیفی و MODIS^{۲۰} با چرخه بازدید یک روزه، داده‌های سری‌های زمانی بلند مدت آماده می‌کند، که از نظر زمانی ابعاد بالا محسوب می‌شوند [۳۲].

داده‌های کلان سنجش از دور همیشه به دلیل تغییرات سطح زمین و حرکت ماهواره‌ها حالت پویا دارند. حالت پویا داده‌های کلان سنجش از دور شامل هر دو بخش‌های ساکن و غیرساکن می‌باشد. تغییرات ناشی از چرخش زمین به دور خورشید و چرخش به دور محور خود یک فرآیند ایستا هستند. تغییرات ناشی از فعالیت‌های انسانی و بلایای طبیعی، مانند تکامل یک شهرستان و فوران‌های آتشفشان و زلزله‌ها فرآیندهای تصادفی غیرایستا هستند. ویژگی‌های ایستا داده‌های کلان سنجش از دور، این را بیان می‌کند که به آسانی توسط روش‌های آماری قابل ارائه هستند. در حالی که ویژگی‌های غیر ایستا، دشواری تجزیه و تحلیل داده‌های کلان سنجش از دور را افزایش می‌دهند.

ویژگی ایزومر داده‌های سنجش از دور، اغلب به ساختارهای مختلف نمایش داده‌ها برای مختصات جغرافیایی یکسان اشاره می‌کند. بارزترین آن‌ها *vector* و *raster* می‌باشد. نوع داده *Raster* شامل ستون‌ها و ردیف‌هایی از سلول‌ها است که هر سلول یک مقدار واحد را ذخیره می‌کند. نوع داده *Vector* ویژگی‌های جغرافیایی و اشکال هندسی را به صورت بردار بیان می‌کند.

۲.۲.۲ یادگیری عمیق

یادگیری عمیق^{۲۱} یک زیرشاخه از یادگیری ماشینی و بر مبنای مجموعه‌ای از الگوریتم‌ها است که در تلاش هستند مفاهیم انتزاعی سطح بالا در دادگان را مدل نمایند. این فرایند را با استفاده از یک گراف عمیق که دارای چندین لایه پردازشی متشکل از چندین لایه تبدیلات خطی و غیر خطی هستند، مدل می‌کنند. به بیان دیگر پایه آن بر یادگیری نمایش دانش و ویژگی‌ها در لایه‌های مدل است. برای بهتر درک کردن و فهم مفهوم یادگیری عمیق لازم است تا با مفاهیمی پایه‌ای آشنا شویم. در ادامه این مفاهیم شرح داده می‌شوند [۳۳] و [۳۴].

۱. شبکه‌های عصبی مصنوعی: شبکه‌های عصبی مصنوعی یا سیستم‌های اتصالگر، سیستم‌های

¹⁸Observation Scale

¹⁹Airborne Visible / Infrared Imaging Spectrometer

²⁰Moderate-resolution Imaging Spectroradiometer

²¹Deep Learning

محاسبه‌گری هستند که از شبکه‌های عصبی زیستی تشکیل دهنده ذهن حیوانات الهام گرفته شده‌اند. این سیستم‌ها، با بررسی مثال‌ها، فعالیت‌ها را یادگیری می‌کنند و عموماً این اتفاق بدون هیچ برنامه نویسی مختص به فعالیتی انجام می‌شود. برای مثال، در شناسایی تصویر، این شبکه‌ها می‌توانند یاد بگیرند که تصاویر شامل گربه را با تحلیل تصاویر مثالی که قبلاً بطور دستی به عنوان “با گربه” یا “بدون گربه” برچسب گذاری شدند، شناسایی کنند و از این نتایج تحلیلی برای شناسایی گربه در تصاویر دیگر استفاده نمایند. این شبکه‌ها بیشترین استفاده را در کاربردهایی دارند که بیان آن‌ها با یک الگوریتم سنتی که از برنامه نویسی قاعده-بنیان استفاده می‌کند، دشوار است.

یک شبکه عصبی مصنوعی بر مجموعه‌ای از واحدهای متصل یا گره، به نام نورون‌های مصنوعی (مشابه نورون‌های زیستی در یک مغز زیستی)، مبتنی است. هر اتصال^{۲۲} میان نورون‌ها می‌تواند سیگنالی را از یک نورون به نورون دیگر انتقال دهد. نورون دریافت کننده^{۲۳} می‌تواند سیگنال و سپس نورون‌های پایین دستی سیگنال متصل به آن را پردازش کند. نورون‌ها ممکن است دارای حالت باشند، که معمولاً با اعداد حقیقی بین ۰ و ۱ نمایش داده می‌شود. نورون‌ها و سیناپس‌ها همچنین ممکن است وزن داشته باشند که با پیشرفت یادگیری، تنظیم می‌شود. این وزن، قدرت سیگنالی را که به نورون‌های پایین دستی فرستاده می‌شود، افزایش یا کاهش می‌دهد. معمولاً نورون‌ها در لایه‌ها سازماندهی می‌شوند. لایه‌های مختلف ممکن است تبدیلات مختلفی روی ورودی خود، اعمال کنند. سیگنال‌ها از اولین لایه (ورودی) به آخرین لایه (خروجی) سفر می‌کنند، و در این بین ممکن است لایه‌هایی را چند بار طی کنند. هدف آغازین رویکرد شبکه‌های عصبی، حل مسئله به روش ذهن انسان بود. با مرور زمان، توجه صرفاً روی برابری با برخی توانایی‌های خاص ذهنی معطوف شد، و به انحرافات از زیست‌شناسی، مثل پس-نشر، یا انتقال اطلاعات در جهت عکس و تنظیم شبکه برای انعکاس این اطلاعات، منجر شد. شبکه‌های عصبی در فعالیت‌های متنوعی استفاده شده‌اند، از جمله بینایی رایانه، شناسایی گفتار، ترجمه ماشینی، فیلترینگ شبکه‌های اجتماعی، بازی‌های رومیزی و بازی‌های ویدیویی و تشخیص پزشکی.

تا سال ۲۰۱۷، شبکه‌های عصبی معمولاً از چند هزار تا چند میلیون واحد و چند میلیون اتصال برخوردار هستند. گرچه این عدد به مراتب کوچکتر از تعداد نورون‌های مغز انسان است، اما این شبکه‌ها می‌توانند فعالیت‌های زیادی را در سطح فرا انسانی انجام دهند [۴۰].

۲. شبکه‌های عصبی عمیق: شبکه عصبی عمیق^{۲۴}، یک نوع شبکه عصبی مصنوعی با لایه‌های متعددی بین ورودی و خروجی است. شبکه عصبی عمیق روابط ریاضی

²²Cynapse

²³Post Cynapse

²⁴Deep Neural Network


صحیح را برای تبدیل ورودی به خروجی پیدا می‌کند، خواه این روابط خطی باشند خواه غیرخطی. شبکه با حرکت در لایه‌ها، احتمال هر خروجی را محاسبه می‌کند. برای مثال، شبکه عمیقی که آموزش دیده تا نژادهای سگ را تشخیص دهد، تصویر داده شده را بررسی و احتمال اینکه سگ داخل تصویر، نژادی خاص باشد را محاسبه می‌کند. کاربر می‌تواند نتایج را بررسی و تعیین کند که شبکه چه احتمالاتی را باید نشان دهد (مثلاً احتمالات بالاتر از یک مقدار خاص و غیره) و برچسب پیشنهادی را بازگرداند. هر محاسبه ریاضی این چینی را به عنوان یک لایه در نظر می‌گیرند، و شبکه‌های عمیق پیچیده لایه‌های زیادی دارند، لذا نام شبکه‌های “عمیق” برایشان انتخاب شده است. هدف نهایی این است که شبکه‌ای آموزش داده شود تا تصویر را به ویژگی‌های آن تجزیه، روندهای موجود در تمام نمونه‌ها را شناسایی، و تصاویر جدید را طبق شباهت‌هایشان بدون نیاز به ورودی انسانی طبقه‌بندی کند. شبکه‌های عمیق می‌توانند روابط پیچیده غیرخطی را مدل‌سازی کنند. معماری‌های عمیق، مدل‌هایی ترکیبی تولید می‌کنند که در آن شیء به عنوان ترکیبی لایه‌ای از داده‌های اولیه بیان می‌شود. لایه‌های اضافی، ترکیب ویژگی‌های لایه‌های پایین‌تر را ممکن می‌سازند، که بطور بالقوه موجب مدل‌سازی داده‌ها با واحدهایی کمتر از یک شبکه کم عمق با عملکرد مشابه می‌شود. معماری‌های عمیق شامل اشکال متعددی از چند روش اساسی هستند. هر معماری در زمینه‌ی خاص موفق بوده است. مقایسه عملکرد چند معماری همواره ممکن نیست، مگر اینکه روی یک مجموعه داده ارزیابی شوند [۴۱].

شبکه‌های عمیق معمولاً شبکه‌هایی پیشخور^{۲۵} هستند که در آن داده‌ها از لایه ورودی، بدون حلقه، به سمت لایه خروجی جریان پیدا می‌کند. ابتدا شبکه نگاشتی از نورون‌های مجازی درست می‌کند و به اتصالات میان آن‌ها، مقادیر عددی تصادفی یا “وزن” تخصیص می‌دهد. وزن‌ها و ورودی‌ها ضرب می‌شوند و یک خروجی بین ۰ و ۱ را باز می‌گردانند. اگر شبکه بطور دقیق الگوی مورد نظر را تشخیص ندهد، یک الگوریتم وزن‌ها را تنظیم می‌کند. به این طریق الگوریتم می‌تواند تاثیر برخی پارامترها را بیشتر کند، تا وقتی که محاسبات ریاضی صحیح را برای پردازش کامل داده‌ها پیدا کند. شکل ۳.۲ یک شبکه پیشخور را نشان می‌دهد.


شبکه‌های عصبی بازگشتی^{۲۶}، که داده‌های آن‌ها می‌توانند در هر جهتی جریان پیدا کنند، برای کاربردهایی مثل مدل‌سازی زبان استفاده می‌شوند. حافظه طولانی کوتاه-مدت بطور ویژه‌ای برای این مصرف اثربخش است. شکل ۴.۲ ساختار یک شبکه عصبی بازگشتی را نشان می‌دهد. همانطور که در شکل پیداست شبکه برخلاف شبکه‌های پیشخور یک حلقه بازگشتی دارد.

^{۲۵}Feed Forward Network

^{۲۶}Recurrent Neural Network



شکل ۳.۲: ساختار یک شبکه عصبی پیشخور



شکل ۴.۲: ساختار یک شبکه عصبی بازگشتی

شبکه‌های عصبی عمیق در مواردی چون شناسایی تصویر، شناسایی خودکار رفتار، پردازش هنر بصری، پردازش زبان طبیعی، کشف دارو و سم‌شناسی، مدیریت رابطه مشتری، بیوانفورماتیک، تبلیغ در تلفن همراه، بازیابی تصاویر، شناسایی کلاهبرداری مالی، امور نظامی و غیره کاربرد دارد.

۳.۲.۲ شاخص‌های پوشش گیاهی

شاخص پوشش گیاهی یک شاخص عددی است تا ارتباطی با مفاهیم بیولوژی، شیمی و یا فیزیک داشته باشد. اما می‌تواند اطلاعات مفیدی را در خصوص وضعیت پوشش گیاهی در اختیار ما قرار دهد و در واقع از آن به عنوان شاهد تجربی می‌توانیم نام ببریم. برای بررسی شاخص‌های پوشش گیاهی بهتر است در ابتدا خط خاکی یا خط با پوشش گیاهی صفر را تعریف کنیم. خط خاکی یک خط فرضی در فضای طیفی است که تغییرات طیفی خاک‌های بدون پوشش گیاهی را نشان می‌دهد. این خط به وسیله دو یا چند بخش از خاک‌های با ضخامت از یک تصویر که ممکن است انعکاس متفاوت داشته باشند، مشخص می‌شوند. در حالت کلی شاخص‌های پوشش گیاهی به دو دسته اصلی تقسیم می‌شوند و در واقع تقسیم‌بندی آن‌ها بر

اساس ارتباط این شاخص‌ها با خط خاکی است [۹].

۱. خطوط هم‌سبزی‌نگی از مرکز خط خاکی عبور می‌کنند و یا در یک نقطه به هم می‌رسند، نمونه‌های این گروه، $NDVI$ ، $SAVI$ ^{۲۷} و RVI ^{۲۹} هستند.

۲. خطوط هم‌سبزی‌نگی موازی خط خاکی هستند. نمونه‌های این شاخص‌ها $WDVI$ ، ^{۳۰} PVI و DVI ^{۳۲} هستند.

شاخص اختلاف نرمال شده پوشش گیاهی $NDVI$ از مهم‌ترین شاخص‌ها جهت پایش پوشش گیاهی است. این شاخص مقداری بین +۱ تا -۱ دارد. میزان شاخص هرچه به مقادیر مثبت و ۱ نزدیک شود نشان‌دهنده پوشش گیاهی متراکم و هرچه به صفر و مقادیر منفی نزدیک شود به مقادیر تنک ^{۳۳} و آب و یخ نزدیک می‌شوند [۴۲]. این شاخص برای مناطقی که دارای پوشش گیاهی متوسط رو به بالا هستند نتایج خوبی را ارائه می‌دهد اما اگر پوشش گیاهی در ناحیه‌ای از مقدار متوسط کمتر باشد شاخص‌های $SAVI$ و RVI موثرتر هستند. این شاخص‌ها در فرمول محاسبه با شاخص $NDVI$ متفاوتند. فرمول محاسبه شاخص‌ها و مقادیر آن‌ها در فصل سوم به طور مفصل شرح داده می‌شوند.

۳.۲ سیر تکاملی داده‌های ماهواره‌ای لندست

در چهار دهه گذشته، از ۴ نوع تصویر لندست MSS ^{۳۴}، TM ^{۳۵}، $ETM+$ ^{۳۶}، OLI ^{۳۷} در کاربردهای طبقه‌بندی پوشش زمین استفاده شده است. برنامه ماهواره لندست نسل‌های مختلف خود را به طور منظم از نظر رزولوشن مکانی، زمانی، طیفی و رادیومتریک به روزرسانی می‌کند [۴۳] و [۴۴]. در جولای سال ۱۹۷۲، ناسا ماهواره فناوری منابع زمینی ۱-ERTS اولین ماهواره‌ای که برای جمع‌آوری داده‌های منابع زمینی با تفکیک مکانی متوسط و به صورت چند طیفی طراحی شده بود را به فضا پرتاب کرد. این ماهواره بعدها با عنوان لندست-۱ شناخته می‌شد [۴۵]. پس از لندست-۱ ناسا لندست‌های ۲-۸ را نیز طبق شکل ۵.۲ پرتاب کرد [۷۸]. لندست‌های ۳ و ۲ به ترتیب در سال‌های ۱۹۷۵ و ۱۹۷۸ به فضا پرتاب شدند. لندست‌های ۱ تا ۳ یک سامانه اسکنر چند طیفی را حمل می‌کردند. اسکنر چند طیفی با اسکن نوارهایی

^{۲۷}Normalized Difference Vegetation Index

^{۲۸}Soil Adjusted Vegetation Index

^{۲۹}Ratio Vegetation Index

^{۳۰}Weighted Difference Vegetation Index

^{۳۱}Perpendicular Vegetation Index

^{۳۲}D Vegetation Index


^{۳۳}Sparce

^{۳۴}Multispectral Scanner System

^{۳۵}Thematic Mapper

^{۳۶}Enhanced Thematic Mapper Plus

^{۳۷}Operational Land Imager



شکل ۵.۲: بازه زمانی سنسورهای ماهواره لندست در فضا [۷۸]

باریک از زمین و عمود بر مسیر پرواز، تصاویر رقومی ایجاد می‌کرد. همزمان تصاویر جداگانه‌ای در چهار طول موج تولید می‌شد. تصاویر *MSS* که از این نوع تصاویر هستند به عنوان نقطه مهم سنجش از دور ماهواره‌ای منابع زمینی، تبدیل شدند [۴۶]. در واقع لندست قسمت اعظم جهان را پوشش می‌داد. آن‌ها هر ۱۸ روز تصویربرداری می‌شدند. تصاویر ارزان، بدون محدودیت سیاسی یا امنیتی و حق چاپ بود. لندست ۵۴ به ترتیب در سال‌های ۱۹۸۲ و ۱۹۸۴ به فضا پرتاب شدند. در این لندست‌ها اسکنر بسیار پیشرفته چند طیفی نقشه‌کش موضوعی یا همان *TM* مورد استفاده قرار گرفت. این سنسور دارای تفکیک مکانی ۳۰ متر در باندهای مرئی، مادون قرمز نزدیک و میانی و تفکیک ۱۲۰ متر در مادون قرمز حرارتی بود [۴۷]. لندست ۶ در اکتبر ۱۹۹۳ با پرتاب ناموفق مواجه شد. اما تولید داده با لندست‌های ۵۴ و همچنین ۷ در سال ۱۹۹۹، ادامه داشت. لندست ۷ یک سنسور بهبود یافته با نام *ETM+* را حمل می‌کرد. این سنسور دارای تفکیک ۱۵ متر بود. آخرین سنسور لندست که با موفقیت پرتاب شد و در مدار قرار گرفت لندست ۸ بود که در سال ۲۰۱۳ پرتاب شد [۴۸]. در حال حاضر این ماهواره روی مدار است و ناسا و سازمان زمین‌شناسی آمریکا ۲۸ در حال کار بر روی پروژه لندست ۹ می‌باشند تا در ادامه کار لندست‌های قبلی قرار گیرد، این ماهواره قرار است در سال ۲۰۲۳ به فضا پرتاب شود. نسل‌های مختلف ماهواره لندست به طور دائم از نظر مکانی، زمانی، طیفی و رادیومتریکی در حال به روز رسانی هستند. رزولوشن مکانی *MSS* ۶۰ متر می‌باشد در حالیکه رزولوشن مکانی *TM*، *ETM+* و *OLI* ۳۰ متر است. به علاوه، سنسورهای *ETM+*، *OLI* دارای یک باند با رزولوشن ۱۵ متر هستند که می‌توانند با تکنیک *pan-sharpening* رزولوشن سایر باندهای خود را نیز به ۱۵ متر افزایش دهند. رزولوشن رادیومتریکی در *MSS* از ۶ بیت، در *TM* از ۸ بیت، در *ETM+* از ۹ بیت و در *OLI* از ۱۲ بیت استفاده می‌شود. از نظر رزولوشن طیفی، سنسور *MSS* دارای ۴ باند، سنسور *TM* دارای ۷ باند، سنسور *ETM+* دارای ۸ باند و *OLI* دارای ۱۱ باند می‌باشند. بازه زمانی عکسبرداری در سنسور *MSS* هر ۱۸ روز یکبار و در *ETM+*، *OLI* و *TM* هر ۱۶ روز یکبار است.

³⁸United States Geological Survey (USGS)


۴.۲ سیر تکاملی شبکه‌های حافظه‌ی طولانی کوتاه-مدت

۱.۴.۲ شبکه‌های عصبی بازگشتی

ساختار یک شبکه عصبی بازگشتی RNN ^{۳۹} معمولی در شکل ۶.۲ نشان داده شده است. در این شکل x یک ورودی شبکه در زمان t (که یک بردار یک بعدی است به این معنا که در یک بعد ۱ و در بقیه ابعاد مقدار ۰ دارد). s حالت پنهان در زمان t است. این قسمت همان جایی است که حافظه شبکه در آن قرار گرفته است. s بر اساس حالت پنهان قبلی و ورودی که در زمان جاری به آن داده میشود تغییر می‌کند، که به شکل رابطه ۱.۲ است.

$$S(t) = F(Ux(t)) + W(S(t-1)) \quad (1.2)$$

تابع F معمولاً یک تابع غیر خطی مثل $\tanh$ یا $ReLU$ است. O خروجی در گام زمانی t می‌باشد. حالت پنهان S در واقع جایی است که حافظه شبکه در آن قرار گرفته است. S اطلاعاتی درباره



شکل ۶.۲: ساختار یک شبکه عصبی بازگشتی ساده

اینکه تاکنون در شبکه چه رخ داده است را ضبط می‌کند. خروجی S با توجه به حالات قبلی محاسبه می‌شود اما S نمی‌تواند اطلاعات موجود در گام‌های زمانی (به عنوان مثال ۱۰ گام قبل) را ضبط کند. برخلاف شبکه‌های معمولی که از پارامترهای متفاوتی در هر لایه استفاده می‌کند، یک شبکه RNN پارامترهای مشابهی را بین همه گام‌های زمانی به اشتراک می‌گذارد (U, V, W). این بدین معنی است که ما در هر گام زمانی عملیات مشابهی را انجام می‌دهیم فقط ورودی‌ها متفاوت هستند. با این تکنیک تعداد کلی پارامترهایی که شبکه بایستی یاد بگیرد به شدت کاهش پیدا می‌کند.

اصلی‌ترین ویژگی RNN حالت پنهان آن است که اطلاعات یک توالی را ذخیره می‌کند. همچنین

³⁹Recurrent Neural Network

حتما نیاز نیست ما در هر گام زمانی یک خروجی و یا حتما یک ورودی داشته باشیم. بر اساس کار مورد نظر این دیاگرام می‌تواند تغییر کند. شبکه‌های RNN به این علت بازگشتی نامیده می‌شوند که خروجی هر لایه به محاسبات لایه‌های ماقبل آن وابسته است. به عبارتی دیگر این شبکه‌ها دارای حافظه هستند که اطلاعات مربوط به داده‌های دیده شده را ذخیره می‌کند. این شبکه‌ها در واقع کپی‌های متعددی از شبکه‌های عصبی معمولی هستند که کنار هم چیده شده‌اند و هر کدام پیغامی را به دیگری انتقال می‌دهند. یک شبکه عصبی بازگشتی فقط می‌تواند تعداد محدودی از وابستگی‌های کوتاه‌مدت را یاد بگیرد، اما سری‌های زمانی بلندمدت مثل ۱۰۰۰ گام زمانی قابل یادگیری توسط RNN ‌ها نیستند. این شبکه‌ها با مشکلی به نام ناپدید شدن گرادینان روبرو می‌شوند، که برای غلبه بر آن شبکه‌های $LSTM$ ساخته شدند. به طور مختصر این مشکل را شرح می‌دهیم و سپس به جزئیات ساختار $LSTM$ می‌پردازیم.

دو متد $BPTT$ ^{۴۰} و $RTLL$ ^{۴۱} برای آموزش شبکه‌های RNN وجود دارد. هر دو این متدها بر پایه مشتق‌گیری کار می‌کنند. گرادینان الگوریتم‌هایی از این نوع در انتشار رو به عقب در سری‌هایی با وابستگی بلندمدت، ممکن است ناپدید یا به بی‌نهایت میل کنند. این مشکل نه تنها در RNN ‌ها بلکه در شبکه‌های عمیق عصبی جایی که گرادینان از میان چندین گام عبور می‌کند نیز رایج بود. فرآیندی که باعث می‌شود شبکه‌های عصبی یاد بگیرند بسیار ساده است، این فرآیند گرادینان نزولی کاهشی نام دارد. به صورت خلاصه برای هر پارامتر در شبکه‌ها (وزن‌ها و بایاس‌ها)، کاری که ما باید انجام دهیم محاسبه مشتق تابع هزینه نسبت به پارامترها و حرکت دادن آن به مقدار کم در سمت مسیر مخالف آن است. این الگوریتم بسیار ساده، در برخی از شبکه‌ها رفتار عجیب و غریبی نشان می‌دهد، بطوری که وزن‌هایی که نزدیک‌تر به انتهای شبکه هستند نسبت به وزن‌های موجود در لایه‌های اولیه با مقدار خیلی بیشتری تغییر می‌کنند. هر چه تعداد لایه‌های شبکه ما 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 بسیار زمانبر خواهد بود، به این مشکل پدیده ناپدید شدن گرادینان می‌گویند. شبکه‌های $LSTM$ برای غلبه بر این مشکل به وجود آمدند [۴۹].


۲.۴.۲ شبکه‌های حافظه طولانی کوتاه-مدت

این شبکه یک نوع مدل و ساختار برای داده‌های ترتیبی است که در سال ۱۹۹۵ برای توسعه شبکه‌های عصبی بازگشتی ظهور پیدا کرد. $LSTM$ مخفف عبارت $LongShortTermMemory$ است که در آن، عبارت $LongTermMemory$ به وزن‌های یادگرفته شده و عبارت $ShortTermMemory$ به حالت‌های درونی سلول‌ها اطلاق می‌شود. $LSTM$ برای حل مشکل پدیده ناپدید شدن

⁴⁰Back-Propagation Through Time

⁴¹Real-Time Recurrent Learning

گرادیان در شبکه های عصبی بازگشتی بوجود آمد که تغییر عمده آن جایگزین کردن لایه میانی RNN با یک بلاک که بلاک $LSTM$ نام دارد است. ساختار این شبکه در شکل ۷.۲ قابل مشاهده است. بزرگترین ویژگی $LSTM$ امکان یادگیری وابستگی بلندمدت است که



شکل ۷.۲: ساختار یک شبکه $LSTM$

توسط شبکه های عصبی بازگشتی امکان پذیر نبود. برای پیش بینی گام زمانی بعدی نیاز است که مقادیر وزن ها در شبکه به روز رسانی شوند که این کار مستلزم حفظ اطلاعات گام های زمانی ابتدایی است. $LSTM$ ها می توانند این وابستگی های بلند مدت را به درستی یاد بگیرند [۴۹].


۳.۴.۲ ساختار و نحوه عملکرد شبکه حافظه طولانی کوتاه-مدت

اجزای اصلی یک شبکه حافظه طولانی کوتاه-مدت شامل ۵ جزء ورودی بلوک، دروازه ورودی، حالت سلول، دروازه فراموشی و دروازه خروجی است. این اجزا در شکل ۸.۲ قابل مشاهده هستند.

متغیرهای موجود در شکل:

۱. نماد C_t ، حالت سلول را در زمان t مشخص می کند.
۲. نماد h_t ، مقدار خروجی در زمان t را مشخص می کند.
۳. نماد i_t ، گیت ورودی سلول، نماد f_t ، گیت فراموشی سلول و نماد O_t ، گیت خروجی سلول را مشخص می کنند.
۴. نمادهای U_t و W_t مقادیر ماتریس های وزن و نماد b_C بردار بایاس شبکه می باشند.

در ادامه هر جزء را شرح می دهیم.



شکل ۸.۲: ساختار یک بلوک شبکه $LSTM$ [۸۰]

۱. ورودی بلوک: این واحد که با C_t در رابطه ۲.۲ نشان داده شده است، یک گره است که فعال‌ساز را از لایه ورودی x_t در مرحله زمانی فعلی و همچنین از لایه مخفی در مرحله زمانی پیشین h_{t-1} دریافت می‌کند. هر بلوک در لایه مخفی شبکه به صورت یک مرحله زمانی مستقل در نظر گرفته می‌شود. به طور کلی جمع وزن‌های ورودی طی یک تابع فعال‌ساز تانژانت هایپربولیک اجرا می‌شوند [۷۶].

$$C_t = \tan(W_C \cdot x_t + U_C \cdot h_t - 1 + b_C) \quad (2.2)$$

۲. دروازه ورودی: دروازه ۴۲ یک واحد سیگموئید است که همانند گره ورودی، فعال‌ساز را از داده‌های حاضر x_t و همچنین لایه مخفی در مرحله زمانی پیشین می‌گیرد. مقدار دروازه ورودی i_t در مقدار گره ورودی ضرب می‌شود.

۳. حالت سلول ۴۳: در مرکز هر سلول یک گره C_t وجود دارد. حالت سلول C_t دارای یک نوار بازگشتی متصل به خود است. این نوار، در امتداد مراحل زمانی دارای عملگر جمع است و خطامی‌تواند طی مراحل زمانی بدون ناپدید شدن گسترش یابد [۷۶].

۴. دروازه فراموشی ۴۴: این دروازه با نماد f_t نمایش داده می‌شود. در واقع یک روش است که شبکه به وسیله آن می‌تواند یاد بگیرد که محتوای حالت سلول را تخلیه کند. رابطه ۳.۲ محاسبه حالت سلول در جریان رو به جلو را نشان می‌دهد. در به‌روز رسانی برای حالت سلول، نماد $\odot$ یک ضرب نقطه‌ای است.

$$C_t = f_t \odot C_{t-1} + i_t \odot C_t \quad (3.2)$$

⁴²Gate

⁴³Cell state

⁴⁴Forget Gate

۵. خروجی بلوک: در نهایت مقدار h_t یا خروجی بلوک توسط یک سلول که مقدار حالت سلول را در دروازه خروجی ضرب می‌کند، محاسبه می‌شود. مرسوم است که حالت سلول ابتدا طی یک تابع فعالساز هایپربولیک اجرا شود که با این کار خروجی هر سلول را به صورت یک دامنه یکسان به دست می‌دهد. در بعضی جاها از تابع $RELU$ که دامنه بزرگتری استفاده شده است که برای آموزش ساده‌تر است. خروجی بلوک در رابطه ۴.۲ نمایش داده شده است [۷۶].

$$h_t = O_t \odot \tanh(C_t) \quad (4.2)$$

نمادهای f ، i و o به ترتیب نمایانگر گیت فراموشی، گیت ورودی و گیت خروجی بلوک شبکه هستند و معادلات آن‌ها در روابط ۵.۲ تا ۷.۲ نشان داده شده است.

$$f_t = \sigma(W_f.x_t + U_f.h_{t-1} + b_f) \quad (5.2)$$

$$i_t = \sigma(W_i.x_t + U_i.h_{t-1} + b_i) \quad (6.2)$$


$$o_t = \sigma(W_o.x_t + U_o.h_{t-1} + b_o) \quad (7.2)$$

$$C_t = \tanh(W_c.x_t + U_c.h_{t-1} + b_c) \quad (8.2)$$


مراحل کار شبکه به سه قسمت تقسیم می‌شود که در ادامه با این مراحل آشنا خواهیم شد. مرحله اول: مرحله اول تصمیم‌گیری برای این است که کدام اطلاعات از حالت سلول دور ریخته شوند. این تصمیم با یک لایه سیگموئیدی به نام “دروازه فراموشی” گرفته می‌شود. این لایه به خروجی بلوک در زمان پیشین h_{t-1} و ورودی در زمان x_t نگاه می‌کند و یک عدد بین صفر و یک برای هر ورودی در حالت پیشین C_{t-1} خارج می‌کند. شکل ۹.۲ و رابطه ۵.۲ نشان دهنده دروازه فراموشی هستند.

مرحله دوم: مرحله دوم تصمیم‌گیری درباره این است که چه اطلاعات جدیدی باید در حالت سلول ذخیره شود. این مرحله شامل دو قسمت است، ابتدا یک لایه سیگموئیدی به نام دروازه ورودی تصمیم می‌گیرد کدام مقادیر می‌بایست به‌روز رسانی شود، سپس یک لایه تانژانت هایپربولیک یک بردار از مقادیر جدید به عنوان ورودی بلوک C_t می‌سازد که می‌تواند به حالت سلول اضافه شود. در مرحله بعد این دو لایه برای به‌روز رسانی حالت سلول با هم ترکیب می‌شوند. شکل ۱۰.۲ و روابط ۶.۲ و ۷.۲ نشان دهنده ورودی بلاک و دروازه ورودی هستند و رابطه ۲.۳ نشان دهنده بردار مقادیری است که قرار است در سلول به‌روز رسانی شوند.

حال زمان این است که حالت قدیم سلول C_{t-1} به حالت جدید سلول C_t به‌روز رسانی شود. در مراحل قبل تصمیم به چگونگی این کار گرفته شده است و اینجا انجام می‌پذیرد. با ضرب حالت قدیم در دروازه فراموشی f_t اطلاعاتی که قبلاً می‌بایست فراموش شوند، فراموش



شکل ۹.۲: لایه دروازه فراموشی در شبکه LSTM [۸۰]



شکل ۱۰.۲: لایه دروازه ورودی در شبکه LSTM [۸۰]


می‌شوند. سپس ضرب دروازه ورودی در ورودی بلاک به آن اضافه می‌شود. این مقادیر جدید کاندید است که نشان می‌دهد شبکه، هر مقدار حالت سلول را به چه اندازه می‌خواهد به‌روز رسانی کند. شکل ۱۱.۲ و رابطه ۹.۲ نشان‌دهنده به‌روز رسانی سلول هستند.

$$C_t = f_t \odot C_{t-1} + i_t \odot C_t \quad (9.2)$$


مرحله سوم: در نهایت می‌بایست تصمیم گرفته شود که چه چیزی در خروجی وجود داشته باشد. این خروجی براساس حالت سلول خواهد بود. ابتدا یک لایه سیگموئیدی به نام دروازه خروجی o_t اجرا می‌شود که تصمیم می‌گیرد چه بخش‌هایی از حالت سلول می‌بایست به خروجی داده شود، سپس حالت سلول در یک تانژانت هایپربولیک قرار داده می‌شود و در دروازه خروجی ضرب می‌شود، بنابراین فقط قسمت‌های مورد نظر و تصمیم گرفته شده به خروجی می‌روند. شکل ۱۲.۲ و روابط ۱۰.۲ و ۱۱.۲ نشان‌دهنده دروازه خروجی و خروجی بلوک هستند.

$$o_t = \sigma(W_o.x_t + U_o.h_{t-1} + b_o) \quad (10.2)$$

$$h_t = o_t \odot \tanh(C_t) \quad (11.2)$$



شکل ۱۱.۲: به روز رسانی حالت قدیم سلول به حالت جدید در شبکه LSTM [۸۰]



شکل ۱۲.۲: به روز رسانی حالت قدیم سلول به حالت جدید در شبکه LSTM [۸۰]

۵.۲ انواع روش‌های پیش‌بینی در مطالعات

از انواع مختلف روش‌ها جهت پیش‌بینی تغییرات پوششی در داده‌های سری زمانی استفاده می‌شود، در تمام این روش‌ها با داشتن مقادیر مجاور مقادیر آینده پیش‌بینی می‌شوند. این روش‌ها پارامتری هستند و فرض می‌کنند که داده‌ها خطی و ثابت هستند، که آن‌ها را برای پیش‌بینی مناسب می‌سازد. مدل زنجیره‌ای مارکوف به سادگی توابع احتمالی را در سراسر حالت‌های بعدی ممکن می‌سازد [۵۱]. این روش حافظه کمی مصرف می‌کند و فقط حالات مجاور را در نظر می‌گیرد اما از یک پنجره ثابت استفاده می‌کند [۵۲].

شبکه‌های عصبی روش‌های مشهوری برای آنالیز داده‌های مکانی-زمانی ماهواره‌ای هستند، این روش‌ها برخلاف اغلب روش‌های دیگر بدون پارامتر هستند [۵۳]. بسیاری از مطالعات نشان می‌دهند که شبکه‌های عصبی در این زمینه به خوبی عمل کرده و مدل‌هایی غیر خطی هستند که با داده‌های نویزی به خوبی کار می‌کنند. انواع مختلف شبکه‌ها شامل شبکه‌های

عصبی^{۴۵} شبکه‌های عصبی چند لایه^{۴۶}، شبکه‌های بازگشتی^{۴۷}، شبکه‌های کانولوشنی^{۴۸} برای طبقه‌بندی تصاویر ماهواره‌ای استفاده می‌شوند.

شبکه‌های عصبی برای پیش‌بینی تغییرات شاخص نرمال شده پوشش گیاهی (*NDVI*) استفاده می‌شوند [۵۴]. اما این شبکه‌ها حافظه لازم برای ذخیره‌سازی اطلاعات گذشته را ندارند. بنابراین بحث شبکه‌های عصبی عمیق *LSTM* مطرح می‌شود که این شبکه‌ها با داشتن حافظه برای نگهداری اطلاعات گذشته به خوبی در پیش‌بینی داده‌های سری زمانی کمک می‌کنند [۵۵]. *DOS* و همکاران در زمینه پیش‌بینی تغییرات پوششی زمین با استفاده از شاخص نرمال شده پوشش گیاهی [۵۵] و *Kussul* و همکارانش در مورد تغییرات پوشش گیاهی زمین با استفاده از الگوریتم‌های یادگیری عمیق، تحقیقاتی به انجام رسانده‌اند [۵۶]. *Sashma* و همکاران با مطالعه در دو ناحیه هند و با استفاده از تصاویر ماهواره‌ای سری زمانی *NDVI MODIS*، پایگاه داده‌ای شامل ۸۶۱ تصویر از سال‌های ۲۰۰۰ تا ۲۰۱۶ به پیش‌بینی تغییرات پوشش گیاهی با *RMSE* کمتر از ۰.۰۳ رسیدند [۵۷].

۶.۲ مطالعات انجام شده در ایران و جهان

با توجه به رشد روز افزون داده‌های مکانی-زمانی نیاز به تکنولوژی‌هایی با دقت و سرعت بالا جهت کشف دانش ضروری است. از این جمله، داده‌های سنجش از دور هستند که دارای حجم بالا و نیز نیازمند الگوریتم‌هایی جهت استخراج ویژگی می‌باشند. از کاربردهای این داده‌ها در علوم زمین به تغییرات پایشی زمین می‌توان اشاره کرد. کشف و پیش‌بینی تغییرات پوششی زمین جهت پیش‌بینی تغییرات فصلی، خشکسالی‌های آینده، رشد روند مناطق شهری، تخریب زیستگاه‌ها و غیره اهمیت دارد [۵۸]. نقشه‌برداری و نظارت بر آن به ارزیابی سلامت پوشش گیاهی کمک می‌کند و به منظور حفاظت از آن‌ها شیوه‌های مدیریت بهتری را به همراه دارد [۵۹]. بررسی تغییرات پوشش گیاهی در سال‌های مختلف مهم می‌باشد و اطلاعات آن کمک زیادی به تصمیم‌گیری مدیران می‌کند. با توجه به اینکه 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. از طرفی با توجه به اینکه تغییرات اقلیمی بر روی پوشش گیاهی تاثیر زیادی دارد، با بررسی و تعیین ارتباط بین شاخص‌های پوشش گیاهی و پارامترهای اقلیمی مانند دما می‌توان وضعیت پوشش گیاهی را تعیین نمود [۶۰].

⁴⁵ *Artificial Neural Network*

⁴⁶ *Multiple Layer Perceptron*

⁴⁷ *Backpropagation Neural Network*

⁴⁸ *Convolution*

شاخص‌های پوشش گیاهی توسط بسیاری از دانشمندان به عنوان یکی از مهم‌ترین پارامترها برای نقشه‌برداری زمین‌های کشاورزی، بررسی بارش، تخمین اثرات آب و هوایی، محاسبه میزان بیوماس، بازدهی محصول و فرآوری چراگاه و غیره مطرح شده است. یکی از موثرترین شاخص‌ها شاخص $NDVI$ ^{۴۹}، که شاخص نرمال شده پوشش گیاهی است می‌باشد. این شاخص نخستین به عنوان شاخص سلامت تراکم پوشش گیاهی مطرح گردید. شاخص $NDVI$ به طور گسترده‌ای برای ارزیابی پوشش گیاهی، محصولات کشاورزی و تشخیص خشکسالی مورد استفاده قرار گرفته است. از دیگر شاخص‌ها می‌توان به شاخص‌های RVI ^{۵۰}، $SAVI$ ^{۵۱} و $WAVI$ ^{۵۲} اشاره کرد.

در بسیاری از مطالعات از داده‌های سری زمانی به خاطر سابقه‌ی طولانی مدت و حجم حافظه‌ی پایین استفاده می‌شود [۶۱]. داده‌های سری زمانی شامل تغییرات آبی هستند و این سبب آنالیز بهتری نسبت به دیگر پایگاه داده‌ها می‌شود. تغییرات فصلی و الگوهای سالانه تغییرات از جمله مواردی است که به خوبی توسط این داده‌ها قابل ارزیابی است [۶۲]. مطالعات متعددی در زمینه بررسی پوشش گیاهی از طریق شاخص‌های پوشش گیاهی انجام شده است که از آن جمله می‌توان به مطالعات *kalera* و همکاران اشاره نمود. آن‌ها با بررسی تاج پوشش گیاهی و شاخص‌های پوشش گیاهی به این نتیجه رسیدند که بین تغییرات پوشش گیاهی و شاخص‌های پوشش گیاهی ارتباط معناداری وجود دارد [۶۳].

Kohen و همکاران با بررسی شاخص سطح برگ و شاخص‌های گیاهی محاسبه شده با داده‌های ماهواره لندست به این نتیجه رسیدند که ارتباط معناداری بین شاخص سطح برگ و شاخص‌های پوشش گیاهی وجود دارد [۶۴]. *Gorgel* تغییرات پوشش گیاهی را در ارتباط با شرایط اقلیمی در برزیل بررسی نمودند. نتایج نشان داد که زمان بارندگی منجر به تغییرات در پوشش گیاهی منطقه مورد مطالعه می‌شود. به طوریکه بارندگی در فصل تابستان همبستگی ۷۰ درصد و در فصل بهار ۹۱ درصد با تغییرات پوشش گیاهی نشان می‌دهد [۶۵].

Sou و همکاران، با استفاده از داده‌های ماهواره‌ای، ارتباط بین رطوبت خاک با این داده‌ها را ارزیابی نمودند. همچنین از شاخص رطوبت خاک برای پایش سطح پوشش گیاهی در دشت شمال چین استفاده کردند. در مطالعات ایشان، مقایسه بین شاخص رطوبت خاک و اندازه‌گیری‌های واقعی رطوبت خاک، اعتبار و توانایی این تئوری را نشان داد. *Tonekabil* و همکاران، در مطالعه خود با استفاده از داده‌های سنجش از دور پوشش گیاهی را در جنوب غرب آسیا، پایش کردند. آن‌ها در مناطق مورد بررسی خود شامل افغانستان، پاکستان و قسمت‌های غربی هند، از دو شاخص اختلاف نرمال شده پوشش گیاهی و شاخص شرایط گیاهی استفاده نمودند.

Lyang و همکاران از تصاویر ماهواره‌ای لندست ۸ $ETM+$ به منظور بررسی تغییرات پوشش

⁴⁹Normalized Difference Vegetation Index

⁵⁰Ratio Vegetation Index

⁵¹Soil Adjusted Vegetation Index

⁵²Water Adjusted Vegetation Index

گیاهی و میزان بارندگی در شمال چین استفاده نمودند. نتایج نشان داد که در مناطق علفزار همبستگی بسیار زیادی بین پوشش گیاهی و بارندگی وجود دارد [۶۶]. *liv* و *vou* با استفاده از شاخص‌های پوشش گیاهی برگرفته از داده‌های *MODIS*، خشکسالی کشاورزی را در چین میانی بررسی کردند. نتایج مطالعه آن‌ها نشان داد که این شاخص می‌تواند در محدوده‌های زمانی و طیفی متفاوت از خشکسالی منطقه‌ای، قاره‌ای و جهانی مورد استفاده قرار گیرد. مطالعات مشابهی نیز در ایران انجام شده است که برخی را ذکر می‌کنیم. حسینی و همکاران نوسانات بارندگی و تغییرات پوشش گیاهی را در بخشی از مراتع یزد بررسی نمودند. نتایج بدست آمده ارتباط معنی‌دار پوشش گیاهی با بارندگی را نشان می‌دهد [۶۷]. هادیان و همکاران تغییرات پوشش گیاهی را با استفاده از اطلاعات بارندگی و تصاویر ماهواره‌ای *ETM+ ۸* برای استان کرمانشاه انجام دادند. نتایج نشان داد که در مناطق مرتعی بالاترین میزان همبستگی بین بارندگی و پوشش گیاهی در فصل بهار دیده شد [۶۸]. *Arsanjani* و همکاران برای مدلسازی رشد، توسعه شهر تهران را برای سال ۲۰۱۶ و ۲۰۲۶ با استفاده از مدل ترکیبی شامل رگرسیون لجستیک، مارکوف و سلول‌های خودکار بررسی کردند و به صحت ۸۹ درصدی دست یافتند، همچنین بیان کردند که رشد زیادی در دهه‌های آینده در حاشیه غربی تهران رخ خواهد داد [۶۹].

جباری و همکاران بررسی تغییرات درصد پوشش گیاهی مراتع را با استفاده از تصاویر ماهواره‌ای در سمیرم اصفهان انجام دادند. برای این منظور از تصاویر سنجنده‌های *WIFS* و *AWIFS* به ترتیب در سال‌های ۱۳۸۴ و ۱۳۸۸ استفاده نمودند تا درصد پوشش گیاهی به طور همزمان برای منطقه مورد مطالعه تعیین شود. در نهایت به منظور پیش‌بینی پوشش گیاهی منطقه مورد مطالعه معادله رگرسیونی با استفاده از فاکتورهای محیطی مانند ارتفاع از سطح دریا، شیب، فاکتورهای اقلیمی و شاخص پوشش گیاهی منطقه تهیه شد. نتایج نشان داد که هر چه میزان *NDVI* بیشتر باشد نشان‌دهنده پوشش گیاهی متراکم در منطقه می‌باشد [۷۰]. منصوری و همکاران از شاخص بارش استاندارد *SPI* سالانه، شاخص پوشش گیاهی بارزسازی شده (*EVI*) و شاخص تفاضل نرمال شده پوشش گیاهی^{۵۳} به منظور بررسی بارندگی و اثرات خشکسالی بر روی پوشش گیاهی مراتع استفاده نمودند. میزان همبستگی بین شاخص خشکسالی *SPI* با *NDVI* و *EVI* به ترتیب برابر با ۷۵٪ و ۷۸٪ است که در سطح ۵۰٪ معنی‌دار می‌باشد. نتایج این تحقیق نشان داد که می‌توان برای بررسی میزان بارندگی و پایش خشکسالی از داده‌های سنجنش از دور پوشش گیاهی استفاده کرد [۷۱]. *yen* و همکاران تغییرات اقلیم را بر اساس پوشش گیاهی در آسیای مرکزی مورد مطالعه قرار دادند. نتایج نشان داد که با استفاده از شاخص پوشش گیاهی *NDVI* می‌توان تغییرات اقلیم را پیش‌بینی نمود [۷۲]. *chen* و همکاران ارتباط دمای سطح زمین و شاخص پوشش گیاهی *EVI* را مورد بررسی قرار دادند. همبستگی بین دو پارامتر نشان داد که با افزایش دما میزان این شاخص کاهش پیدا می‌کند [۷۳].

به طور کلی نتایج مطالعات مختلف حاکی از این است که با گرم شدن کره زمین تغییرات

⁵³ *Normalized Difference Vegetation Index (NDVI)*

زیادی در کاربری اراضی و به خصوص پوشش گیاهی اتفاق افتاده است که این تغییرات به کمک تصاویر ماهواره‌ای قابل بررسی می‌باشد. به طوریکه ارتباط تنگاتنگ بین تغییرات پوشش گیاهی و تغییرات اقلیم وجود دارد [۷۴] و [۷۵]. تمامی مطالعات انجام شده با استفاده از نرم‌افزارهای سنجش از دور انجام شده‌اند و با داده مستقیم تصاویر به نرم افزارهایی مانند، *ENVI* و *ARCMAP* به پیش‌پردازش و بررسی تغییرات پرداخته‌اند.

۷.۲ نتیجه‌گیری

در اغلب مطالعات گذشته که در بخش قبلی به آن‌ها اشاره شد، در کشور ایران اغلب از نرم‌افزارهای سنجش از دور جهت مقایسه تغییرات استفاده شده است. در برخی موارد دیگر نیز توسط شبکه مارکوف و لجستیک رگرسیون به پیش‌بینی پرداخته شده است. لازم به ذکر است که استفاده از داده‌های مربوط به سنسورهای متفاوت از جهت بازه‌های زمانی در دسترس بودن آن‌ها، پیش‌پردازش‌ها و همچنین نواحی مختلف با هم تفاوت داشته و نتایج متفاوتی از هر گروه حاصل می‌گردد. استفاده از تصاویر لندست اغلب به صورت مقایسه‌ای بوده و نتایج حاصل از مقایسه تغییرات گزارش شده است. در این مطالعه با استفاده از داده‌های تصاویر لندست، برخلاف داده‌های سنجنده *MODIS* که به صورت سری زمانی آماده شده‌اند، سری زمانی برای شاخص‌های مختلف ساخته شده است. سری زمانی ساخته شده به منظور ارزیابی به شبکه عصبی عمیق داده می‌شود و نتایج پیش‌بینی تغییرات سالیانه گزارش می‌شود.

فصل ۳

روش پیشنهادی جهت پیش‌بینی داده‌های مکانی-زمانی

۱.۳ مقدمه

باتوجه به اهمیت پیش‌بینی تغییرات پوشش گیاهی و همچنین کمبود تحقیقات مناسب در زمینه پیش‌بینی شاخص‌های پوشش گیاهی، این پایان‌نامه با عنوان پیش‌بینی مکانی-زمانی داده‌های سنجش از دور با استفاده از الگوریتم‌های یادگیری عمیق، به مطالعه پیش‌بینی تغییرات پوشش گیاهی پرداخته و در آن از داده‌های سنجش از دور ماهواره‌ای مربوط به ماهواره‌های لندست ۷ و ۸ استفاده شده است. با استفاده از تصاویر سری زمانی و استخراج شاخص‌های پوشش گیاهی به بررسی پویایی و تغییرات پوشش گیاهی در نواحی شمال و شرق شهرستان شاهرود در استان سمنان، پرداخته می‌شود. سپس با بهره‌گیری از الگوریتم حافظه طولانی کوتاه-مدت، به پیش‌بینی تغییرات آینده پرداخته می‌شود.

۲.۳ ساختار داده‌ها

داده‌های سنجش از دور به طور رایگان از طریق سایت زمین شناسی آمریکا (USGS)^۱ قابل دسترس هستند. با انتخاب نوع داده مورد نیاز و همچنین جزئیاتی چون تاریخ داده و درصد ابر مورد نظر داده آن را فیلتر کرده و در نهایت به آن دسترسی خواهیم داشت. حجم داده‌ها بسته به نوع سنسوری که از آن دریافت شده‌اند از صدها مگابایت تا بیشتر از یک گیگابایت در دسترس هستند. داده‌های استفاده شده در این تحقیق، داده‌های ماهواره‌ای مربوط به لندست ۵ و ۷ و ۸ هستند که به ترتیب دارای سنسورهای *TM*، *ETM* و لندست ۸ دارای دو سنسور *OLI* و *TIRS* است. این سنسورها طول موج‌های مختلف نور را مشاهده کرده و محدوده‌های مختلفی از فرکانس‌ها را در امتداد طیف الکترومغناطیس اندازه‌گیری می‌کنند، به هر کدام از این محدوده‌ها باند گفته می‌شود. داده‌های به دست آمده از هر کدام از ماهواره‌ها دارای باندهای متفاوتی می‌باشند، ابتدا به تفاوت هر کدام با دیگری می‌پردازیم. داده‌های لندست ۵ و ۴ مطابق جدول ۱.۳ از ۷ باند تشکیل شده و لندست ۷ دارای ۸ باند است در هر دو این ماهواره‌ها باند ۶ مربوط به باند حرارتی مادون قرمز می‌باشد. جدول ۲.۳ این اطلاعات را نشان می‌دهد. لندست ۸ مطابق جدول ۳.۳ از ۱۱ باند تشکیل شده است، *OLI* داده‌ها را در ۹ باند طیف جمع‌آوری می‌کند. هفت مورد از این نه باند با سنسورهای *TM* و *ETM* سازگاری داشته و تک باند مادون قرمز دو لندست ۵ و ۷ به دو باند حرارتی برای کمک به بهبود حساسیت به دمای سطح با سنسور *TIRS* تبدیل می‌شود. داده‌های دریافت شده از سایت USGS مربوط به داده‌های سطح ۱ و از سال ۲۰۰۰ تا سال ۲۰۱۸، می‌باشند. داده‌های سال‌های ۲۰۰۰ تا ۲۰۰۳ مربوط به لندست ۵، داده‌های مربوط به سال‌های ۲۰۰۴ تا ۲۰۱۶ از لندست ۷ و مابقی از لندست ۸ می‌باشند. مساحتی که توسط تصاویر پوشش داده می‌شود مربعی به اضلاع ۱۸۵ کیلومتر است. این داده‌ها پس از دریافت با پسوند *.tar.gz* فشرده شده هستند که پس از استخراج جهت عملیات بعدی در دسترس قرار می‌گیرند. از جمله مشکلاتی که در حین کار با داده‌ها وجود داشت، درصد ابر بالای برخی از داده‌ها، که نیاز به تعویض و یا پر کردن پیکسل‌های ابر گرفته با داده‌های معادل سال قبل داشت. پیکسل‌هایی از تصاویر که دارای نویز ابری هستند را می‌توان با استفاده از جایگزینی مقادیر آن‌ها با مقادیر پیکسل‌های معادل در سال قبل جایگزین کرد.

۳.۳ مراحل انجام پژوهش

مراحل پیاده‌سازی روش پیشنهادی تحقیق، در ادامه شرح داده خواهد شد. این مراحل که در شکل ۱.۳ نشان داده شده است، شامل پیش‌پردازش داده‌ها، محاسبه شاخص‌های پوشش

¹United States Geological Survey

جدول ۱.۳: اطلاعات باندهای لندست ۵۴

<i>Band – Number</i>	<i>Band – description</i>	<i>Wavelength</i>	<i>Resolution(meter)</i>
<i>Band1</i>	<i>VisibleBlue</i>	0.45 – 0.52	30
<i>Band2</i>	<i>Visiblegreen</i>	0.52 – 0.6	30
<i>Band3</i>	<i>VisibleRed</i>	0.63 – 0.69	30
<i>Band4</i>	<i>Near – infrared</i>	0.76 – 0.9	30
<i>Band5</i>	<i>Short – waveinfrared</i>	1.75 – 10.55	30
<i>Band6</i>	<i>Thermal</i>	10.4 – 12.3	120
<i>Band7</i>	<i>Short – waveinfrared</i>	2.08 – 2.35	30


جدول ۲.۳: اطلاعات باندهای لندست ۷

<i>Band – Number</i>	<i>Band – description</i>	<i>Wavelength</i>	<i>Resolution(meter)</i>
<i>Band1</i>	<i>VisibleBlue</i>	0.45 – 0.52	30
<i>Band2</i>	<i>Visiblegreen</i>	0.52 – 0.6	30
<i>Band3</i>	<i>VisibleRed</i>	0.63 – 0.69	30
<i>Band4</i>	<i>Near – infrared</i>	0.76 – 0.9	30
<i>Band5</i>	<i>Near – infrared</i>	1.75 – 10.55	30
<i>Band6</i>	<i>Thermal</i>	10.45 – 12.3	30
<i>Band7</i>	<i>Mid – infrared</i>	2.08 – 2.35	30
<i>Band8</i>	<i>Panchromatic</i>	0.52 – 0.9	15

گیاهی، استخراج نواحی مدنظر، ساخت سری زمانی و پیش‌بینی مقادیر با استفاده از شبکه حافظه طولانی کوتاه-مدت است. همانطور که در آن نمایش داده شده است ابتدا داده‌ها پیش‌پردازش شده و سپس شاخص‌ها استخراج می‌شوند، در مرحله بعدی نواحی مورد نظر از تصاویر تک باند به دست آمده (شاخص‌ها) استخراج می‌شوند و پس از به دست آوردن داده‌ها سری زمانی، مدل آموزش دیده و عمل پیش‌بینی انجام می‌شود. عمل پیش‌بینی روی هر دو دسته داده آموزش و آزمون انجام می‌شود و میزان خطای حاصل از پیش‌بینی هر دو دسته گزارش می‌گردد. در ادامه ابتدا در مورد ساختار و مفهوم داده‌ها و شبکه *LSTM* توضیح داده خواهد شد. سپس مراحل و نحوه انجام کار شرح داده می‌شود.

جدول ۳.۳: اطلاعات باندهای لندست ۸

<i>Band – Number</i>	<i>Band – description</i>	<i>Wavelength</i>	<i>Resolution(meter)</i>
<i>Band1</i>	<i>Coastal/Aerosol</i>	0.433 – 0.453	30
<i>Band2</i>	<i>Visibleblue</i>	0.450 – 0.515	30
<i>Band3</i>	<i>Visiblegreen</i>	0.525 – 0.6	30
<i>Band4</i>	<i>Visibleref</i>	0.63 – 0.68	30
<i>Band5</i>	<i>Near – infrared</i>	0.845 – 0.885	30
<i>Band6</i>	<i>Shortwavelengthinfrared</i>	1.56 – 1.66	30
<i>Band7</i>	<i>Shortwavelengthinfrared</i>	2.1 – 2.3	60
<i>Band8</i>	<i>Panchromatic</i>	0.5 – 0.68	15
<i>Band9</i>	<i>Cirrus</i>	1.36 – 1.39	30
<i>Band10</i>	<i>Longwavelengthinfrared</i>	10.3 – 11.3	100
<i>Band11</i>	<i>Longwavelengthinfrared</i>	11.5 – 12.5	100



شکل ۱.۳: فلوچارت کلی معماری

۱.۳.۳ پیش‌پردازش داده‌ها

برای به دست آوردن دقیق‌ترین اطلاعات از تصاویر نیاز است که تعدادی عوامل در نظر گرفته شوند. به همین علت پیش‌پردازش‌هایی روی این تصاویر تعریف می‌شوند که شامل تصحیحات هندسی و رادیومتریک هستند. محصولات سطح ۱ لندست به صورت رقمی تحویل داده می‌شوند. می‌توان آن‌ها را به واحدهای مطلق تابش یا بازتاب تبدیل کرد. انواع تصحیحاتی که روی تصاویر انجام می‌شوند به دو دسته هندسی و رادیومتری تقسیم می‌شوند که هر دو دسته را در ادامه شرح می‌دهیم [۷۷].

تصحیحات هندسی: هدف از تصحیح هندسی، جبران نویزهای ایجاد شده توسط عوامل مختلفی چون گردش زمین و تغییر در ارتفاع ماهواره است که سبب می‌شوند داده‌های خام ماهواره‌ای دارای هندسه ناصحیح باشند.

تصحیحات رادیومتری: این نوع تصحیح به دو دسته تقسیم می‌شوند: تصحیحات اتمسفری و تصحیحات توپوگرافی.

دسته اول تصحیح خطای ناشی از اثرات پراکندگی و جذب امواج الکترومغناطیسی در فضا و دسته دوم تصحیح خطای ناشی از تغییرات سطح زمین می‌باشند. تمامی تصاویر سطح اول، که توسط سایت *USGS* در دسترس کاربران قرار گرفته می‌شوند از نظر هندسی و رادیومتری تصحیح شده‌اند، اما چون ما در این تحقیق نیاز به استخراج شاخص‌های پوشش گیاهی داریم نیاز است که تصحیحات اتمسفری را روی تمام تصاویر اعمال کنیم.

منظور از تصحیح اتمسفری، تبدیل مقادیر تابش طیفی به بازتاب می‌باشد. بازتاب طیفی بالای جو، معیاری از نسبت انرژی ساطع شده از سطح است. در طی این تصحیح آثار مربوط به تغییر شرایط نوردهی، فصل، عرض جغرافیایی و آب و هوا روی تصاویر حذف می‌شود. تصاویر ماهواره‌های لندست دارای ضرایب مناسب جهت اعمال تصحیحات در فایل *MTL* خود هستند، ما با استفاده از این اطلاعات و باندهای مورد نظر مقادیر DN ^۲ را به TOA ^۳ تبدیل می‌کنیم که نحوه تبدیل در ادامه شرح داده خواهد شد.

تصحیحات اتمسفری: برای سنجنده‌های مختلف روش محاسبه متفاوت است، با توجه به اینکه ما در این تحقیق از سنجنده‌های TM ، ETM و OLI مربوط به ماهواره‌های لندست ۵ و ۷ و ۸، استفاده کرده‌ایم. نحوه به دست آوردن هر سه مورد را شرح خواهیم داد:

تصحیحات اتمسفری سنسورهای TM و ETM :

مرحله اول: تبدیل مقادیر رقمی پیکسل‌ها به مقادیر تابش طیفی^۴:

$$L_{\lambda} = \left(\frac{LMAX_{\lambda} - LMIN_{\lambda}}{Q_{calmax} - Q_{calmin}} \right) (Q_{cal} - Q_{calmin}) + LMIN_{\lambda} \quad (1.3)$$

در این رابطه $LMAX$ و $LMIN$ ، ماکزیمم و مینیمم تابش‌های طیفی در سنسورها و Q_{calmin}

^۲Digital Number

^۳Top Of Atmosphere

^۴Radiance

Q_{calmax} ، حداقل و حداکثر مقدار ارزش رقومی پیکسل‌ها در سطح ۱ هستند. مرحله دوم: مقادیر تابش طیفی را به TOA تبدیل می‌کنیم:

$$\rho_{\lambda} = \frac{\pi L_{\lambda} d^2}{ESUN_{\lambda} \cos \theta_s} \quad (2.3)$$

که در آن d بیانگر فاصله زمین تا خورشید، $ESUN$ میانگین تابش اتمسفری خورشید و θ زاویه خورشیدی است. تمامی ضرایب استفاده شده در فرمول‌ها در فایل متا تصاویر موجود است.

تصحیحات اتمسفری سنسورهای OLI و $TIRS$:

همانند دو سنسور قبلی ابتدا مقادیر را به تابش طیفی تبدیل می‌کنیم:

$$\rho'_{\lambda} = M_p * Q_{cal} + A_p \quad (3.3)$$

که تمامی ضرایب استفاده شده در فرمول در فایل متا تصاویر موجود است و نماد M_p ، در فایل با $REFLECTANCE-ADD-BAND$ و نماد A_p ، با $REFLECTANCE-MULT-BAND$ معرفی می‌شوند.

مرحله دوم: سپس مقادیر به دست آمده به TOA تبدیل می‌شوند:

$$\rho_{\lambda} = \frac{\rho'_{\lambda}}{\sin \theta} \quad (4.3)$$


که در آن θ ، نمایانگر زاویه ارتفاع تا خورشید است و با نماد $SUN_{ELEVATION}$ در فایل متا تصاویر موجود است. شکل ۲.۳ فلوجارت تصحیحات اتمسفری را نشان می‌دهد.

۲.۳.۳ محاسبه شاخص‌های پوشش گیاهی

جهت انجام تحقیق با عنوان پیش‌بینی مکانی-زمانی داده‌های سنجش از دور با استفاده از یادگیری عمیق، مطالعه موردی شاخص‌های پوشش گیاهی انجام می‌شود. بنابراین لازم است تا شاخص‌های مناسب جهت این امر از تصاویر استخراج شوند. از مهمترین شاخص‌های پوشش گیاهی می‌توان به $NDVI$ ، $SAVI$ ، RVI و غیره اشاره کرد که در این میان شاخص $NDVI$ از قدرت بالاتری برای نمایش پوشش گیاهی نواحی برخوردار است، اما در نواحی که دارای پوشش گیاهی متوسط و فقیر هستند استفاده از شاخص‌های $SAVI$ و RVI بسیار کارآمد است.

شاخص $NDVI$

به طور طبیعی پوشش گیاهی بخش‌های آبی و قرمز طیف مرئی را به طور قابل ملاحظه‌ای جذب می‌کند. هرچه تراکم پوشش گیاهی در یک ناحیه بیشتر باشد، بخش مرئی نور را بیشتر جذب می‌کند و بازتاب بهتری نیز در بخش $near-IR$ به فضا خواهد فرستاد. فناوری سنجش



شکل ۲.۳: فلوچارت تصحیحات اتمسفری

از دور این مورد را به خوبی درک کرده و این ویژگی‌ها را در اختیار کاربران جهت استخراج پوشش گیاهی قرار می‌دهد. جهت محاسبه این شاخص از رابطه ۵.۳ استفاده می‌شود.

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (۵.۳)$$

که در آن NIR و RED ، دو باند از باندهای تصاویر هستند. این دو باند با نام‌های مادون قرمز و مادون قرمز نزدیک شناخته می‌شوند. این باندها در ماهواره‌ها با سنجنده‌های متفاوت شماره‌های متفاوتی دارند، به گونه‌ای که در تصاویر لندست ۵ و ۷ با شماره‌های ۴ و ۳ و در تصاویر لندست ۸ با شماره‌های ۴ و ۵، به ترتیب RED و NIR شناخته می‌شوند. تغییرات این شاخص بین +۱ تا -۱ است مقادیر منفی به معنای پوشش آب و یخ و مقادیر صفر و مثبت پوشش گیاهی ضعیف تا بسیار متراکم را نشان می‌دهند [۱۰].

شاخص SAVI

شاخص طیفی پوشش گیاهی تعدیل شده $SAVI$ برای نخستین بار توسط $Ltuet$ در سال ۱۹۸۸ ارائه گردید. این شاخص تفاوت بسیار کوچکی با شاخص $NDVI$ دارد و برای محاسبه‌ی پوشش گیاهی سطح زمین استفاده می‌شود که اثر خاک را در آن تعدیل کرده است. فرمول محاسبه‌ی آن در ۶.۳ قابل مشاهده است که در آن همانند $NDVI$ از باندهای مادون قرمز و مادون قرمز نزدیک استفاده می‌شود. این شاخص نیز دارای تغییرات بین +۱ تا -۱ می‌باشد

[۹].

$$SAVI = \frac{(NIR - RED)(1 + L)}{NIR + RED + L} \quad (۶.۳)$$

L فاکتور تعدیل خاک است و مقادیری در بازه ۰/۵-۱ دارد، به این صورت که مقادیر صفر برای نواحی با پوشش گیاهی متراکم و هر چه پوشش گیاهی کم شود مقدار به سمت ۰/۵ افزایش پیدا می‌کند.

شاخص RVI

این شاخص اولین بار توسط Jordan ۱۹۶۹ مطرح شد. شاخصی بر اساس نسبت باندهاست که تغییرات آن از صفر تا بی نهایت است. جهت محاسبه این شاخص از رابطه ۷.۳ استفاده می‌شود [۹].


$$RVI = \frac{RED}{NIR} \quad (۷.۳)$$

مقدار صفر به معنی عدم پوشش گیاهی، مقادیر بالاتر به ترتیب از کم به زیاد معنی پوشش گیاهی ضعیف تا متراکم هستند.

۳.۳.۳ استخراج نواحی و ساخت داده‌های سری زمانی

پس از مشورت با یک متخصص سنجش از دور، جهت انتخاب ناحیه مورد نظر، تصمیم بر آن شد که ناحیه‌ای انتخاب شود که از نظر تغییرات پوشش گیاهی، دور از دخالت‌های انسانی و در اثر تغییر اقلیم دچار تغییرات شده باشد. بر همین اساس نواحی در شمال و شرق شهرستان شاهرود در استان سمنان، که در سال‌های گذشته در معرض خشکسالی‌ها و تغییرات اقلیمی قرار داشته و ناحیه‌ای با پوشش گیاهی متوسط هستند انتخاب شدند. برای دریافت ناحیه مورد نظر در سایت زمین شناسی آمریکا USGS با انتخاب مختصات مد نظر عکسی که ناحیه مورد نظر را پوشش دهد انتخاب شد، موقعیت عکس انتخاب شده در شکل ۳.۳ نشان داده شده است. فریم بزرگ نشان دهنده تصویر اصلی دریافت شده است. دو ناحیه کوچک مشخص شده در تصویر مربوط به نواحی شمال و شرق شهر شاهرود هستند.

پس از انجام پیش‌پردازش روی داده‌ها و استخراج شاخص‌های مورد نظر، نواحی مد نظر در ناحیه شمال و شرق شهرستان شاهرود واقع در استان سمنان از تصاویر جدا شدند. برای انجام این مرحله از کار لازم است که ابتدا فایل *kml*. ناحیه مورد نظر از طریق گوگل ارث استخراج شوند. سپس با استفاده از این فایل، فایل *shape* نواحی ساخته می‌شود و مختصات محل مورد نظر جهت جدا شدن از تصویر اصلی استخراج می‌شود. پس از آن با داشتن مختصات، اقدام به جداسازی ناحیه مورد نظر می‌شود. این نواحی پس از جداسازی، مقدار میانگین پوشش گیاهی‌شان در نظر گرفته می‌شود و به عنوان یک نمونه استفاده می‌شود. پس از آماده‌سازی



شکل ۳.۳: موقعیت عکس دریافت شده از سایت USGS

نمونه‌ها اقدام به ساخت سری زمانی انجام می‌شود. جهت ساخت داده‌های سری زمانی مناسب جهت پیش‌بینی تغییرات آینده، چند آزمایش مورد ارزیابی قرار گرفت که در ادامه توضیح داده خواهند شد.

۱. داده‌های سری زمانی مرحله اول: در ابتدا از ناحیه شمال شهرستان شاهرود، اقدام به استخراج داده شد. به طوریکه از این ناحیه یک فریم، انتخاب می‌شود. داده‌ها با ترتیب فصل و سال انتخاب شدند و نتایج حاصل از استخراج شاخص $NDVI$ ، $SAVI$ و RVI جهت پیش‌بینی تغییرات فصلی و سالیانه مورد ارزیابی قرار گرفتند. در این مرحله ورودی شبکه، داده فصل سال قبل و خروجی، داده فصل سال بعد است.

۲. داده‌های سری زمانی مرحله دوم: این مرحله به دلیل پایین بودن دقت در نتیجه استفاده از داده‌های مرحله اول پیشنهاد شد. دلیل پایین بودن دقت در مرحله اول وجود نمونه‌های کم گزارش شد. با افزایش درصد نمونه‌های آموزشی دقت الگوریتم افزایش می‌یافت. بنابراین در مرحله دوم ناحیه دیگری در عکس نیز به عنوان نمونه انتخاب شد. این ناحیه واقع در شرق شهرستان شاهرود است. داده‌های این ناحیه پس از استخراج ناحیه مد نظر از عکس، تهیه شدند. در این مرحله، در یک مورد از شاخص‌ها دقت به خوبی دو شاخص دیگر گزارش نمی‌شد. در نتیجه روی ترتیب ورودی‌ها و مقدار برچسب زمانی آزمایش‌هایی انجام شد و مرحله سوم از کار ایجاد شد. در این مرحله نیز

ورودی شبکه داده فصل سال قبل و خروجی، داده فصل سال بعد است.

۳. داده‌های سری زمانی مرحله سوم: با انجام آزمایش‌های مختلف در مورد ترتیب ورودی شبکه و خروجی پیش‌بینی، همچنین مقدار برچسب زمانی، داده‌های سری زمانی مختلف مورد آزمایش قرار گرفت. تغییرات فصلی و سالیانه مربوط به ورودی‌های مختلف و پیش‌بینی آینده مورد نظر، داده‌های سری زمانی متفاوتی را ایجاد می‌کند. در نهایت ترتیب نهایی ورودی شبکه و برچسب زمانی به صورت داده‌های فصل‌های مشابه چند سال قبل و خروجی، پیش‌بینی فصل سال آینده آن سال‌ها می‌باشد. به دلیل وجود نمونه‌های کم از ناحیه شرق چهار فریم انتخاب می‌شود، در ساخت سری زمانی توجه به وجود این داده‌ها ضروری است و از ترکیب هر دو ناحیه برای آموزش و آزمون استفاده می‌شود. ورودی شبکه، داده‌های پنج سال گذشته و خروجی، داده سال بعد است.

پس از ایجاد سری زمانی، نوبت به استخراج نمونه‌های آموزشی و آزمایشی است. در این مرحله به میزان ۰.۷۵ درصد از نمونه‌ها برای آموزش و مابقی برای آزمایش مورد استفاده قرار می‌گیرند.

۴.۳ استفاده از شبکه حافظه طولانی کوتاه-مدت جهت پیش‌بینی

پس از آماده سازی داده‌های مورد نظر، شبکه حافظه طولانی کوتاه-مدت، جهت پیش‌بینی مورد استفاده قرار می‌گیرد. در این شبکه پارامترهایی جهت رسیدن به نتیجه مطلوب اهمیت دارد. این پارامترها شامل تعداد نرون‌های لایه میانی، تعداد تکرارهای شبکه، برچسب زمانی و نوع سری زمانی ورودی به شبکه می‌شوند. جهت رسیدن به نتیجه مطلوب لازم است که تمام این موارد مورد آزمایش قرار بگیرند و در نهایت بهترین مقدار برای هر کدام گزارش شود. در مرحله اول با استفاده از داده‌های سری زمانی اول شبکه جهت پیش‌بینی مورد آموزش و آزمایش قرار گرفت. تعداد تکرارهای مختلف و همچنین برچسب زمانی‌های مختلف آزمایش شدند، در نهایت بهترین نتیجه ثبت گردید.

نتایج دقت خوبی را با توجه به قدرت شبکه نشان نمی‌دادند. با آزمایش تعداد نمونه‌های آموزشی بیشتر میزان خطای پیش‌بینی شبکه کمتر می‌شد. در نتیجه در مرحله دوم تصمیم به استخراج نمونه‌های بیشتری گرفته شد. ناحیه دوم برای استخراج نمونه‌ها در شرق شهرستان شاهرود انتخاب شد و تعداد بیشتری نمونه از آن ناحیه استخراج شدند. نتایج اولیه حاصل از پیش‌بینی برای دو شاخص $NDVI$ و $SAVI$ بهتر از مرحله اول بود و به میزان قابل قبولی رسید اما شاخص RVI با وجود کمتر شدن خطا نسبت به مرحله اول، میزان خطایی بیشتر از دو شاخص دیگر را نشان می‌داد.

بنابراین تصمیم به آزمایش ترتیب ورودی‌ها و برچسب زمانی‌های دیگر گرفته شد، چرا که

با تغییر این دو پارامتر نتایج تغییری مثبت را نشان می‌داد. بهترین وضعیت مربوط شد به زمانی که برچسب زمانی از یک به مقدار بزرگتر از ۵ و ترتیب ورودی‌های سری زمانی به صورت نواحی مشابه پشت سر هم بود. در نتیجه نتایج نهایی با میزان خطای بسیار پایین و کمتر از ۰.۰۶ به دست آمد. نتایج حاصل از مراحل مختلف در فصل بعدی گزارش داده شده است.

۵.۳ نتیجه گیری

در این فصل در مورد داده‌ها، پیش‌پردازش آن‌ها، استخراج شاخص‌های مورد نظر، داده‌های سری زمانی و الگوریتم حافظه طولانی کوتاه-مدت صحبت شد. در ادامه نحوه انجام کار و محاسبات توضیح داده شد. نتایج حاصل از کار در فصل چهارم گزارش می‌شود.

فصل ۴

نتایج آزمایش‌ها

۱.۴ مقدمه

در فصل قبل داده‌ها و الگوریتم مورد استفاده شرح داده شد. در این فصل الگوریتم را مورد ارزیابی قرار داده و نتایج حاصل را گزارش خواهیم کرد.

۲.۴ نمونه‌ها و معیار ارزیابی

پس از آماده سازی تمام نمونه‌ها که ۳۸۰ مورد هستند، از ۷۵ درصد کل آن‌ها به عنوان نمونه آموزشی و ۲۵ درصد باقی مانده جهت آزمون الگوریتم استفاده می‌شود. در الگوریتم شبکه حافظه طولانی کوتاه-مدت، داده‌ها به صورت سری زمانی وارد می‌شوند. لذا داده‌ها باید به سری زمانی تبدیل شوند.

از هر سال چهار عکس مربوط به چهار فصل سال انتخاب شده است. در هر عکس دو ناحیه شمال و شرق شاهرود استخراج می‌شود. از ناحیه شمال یک فریم و ناحیه شرق ۴ فریم انتخاب شده است. در مجموع ۳۸۰ نمونه از تمام عکس‌ها استخراج شده است. از سال ۲۰۰۰ تا ۲۰۱۸ نواحی مربوط به شرق و شمال به ترتیب فصل‌های سال قرار داده می‌شوند. با آزمایش تعداد

مرحله‌ها^۱ و برچسب زمانی‌های^۲ مختلف عمل پیش‌بینی انجام می‌گیرد. جهت پیش‌بینی آینده لازم است که داده‌های مناسب قبلی به شبکه داده شوند. به همین جهت برای پیش‌بینی داده‌های فصل سال بعد نیاز است که داده‌های فصل زمان قبل به شبکه داده شوند، چرا که به دلیل تغییرات مشابه در فصول نزدیک به هم و سال‌های پشت سر هم عمل پیش‌بینی با دقت بیشتری انجام می‌شود. در این مطالعه با آزمون ترتیب‌های مختلف، بهترین ترتیب داده سری زمانی، مربوط به قرار گیری نواحی مشابه و فصول سال به ترتیب است. پس از انجام مراحل آموزش و آزمون، داده‌ها را در هر دو مورد آموزش و آزمون مورد پیش‌بینی قرار می‌دهیم و با آزمایش تعداد مرحله‌های مختلف و نرون‌های مختلف شبکه، مراحل پیش‌بینی را انجام می‌دهیم. در نهایت میزان خطای حاصل از پیش‌بینی که از خطای $RMSE$ با رابطه ۱.۴ استفاده می‌کنیم، برآورد شده و نمودار حاصل از پیش‌بینی داده‌ها ترسیم می‌شود.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y'_i - y_i)^2}{n}} \quad (1.4)$$

در این معادله y'_i نمایانگر مقدار پیش‌بینی شده نمونه i و y_i نمایانگر مقدار واقعی نمونه است. همچنین اطلاعات پارامترهای استفاده شده در شبکه در جدول ۱.۴ نشان داده شده است.

جدول ۱.۴: اطلاعات شبکه استفاده شده

<i>nerouns</i>	<i>LearningRate</i>	<i>Errors</i>	<i>Optimiser</i>
16	0.1	<i>RMSE</i>	<i>SGD</i>

۳.۴ نتایج الگوریتم

پس از جداسازی داده‌های آموزش و آزمون، به صورت ۰.۷۵ درصد آموزش و ۰.۲۵ درصد آزمون، داده‌ها با ترتیب‌ها، تکرارها و برچسب زمانی‌های متفاوت مورد بررسی قرار گرفتند. همانطور که در فصل گذشته در مورد نمونه‌ها و ساخت سری زمانی مناسب صحبت شد، نتایج نهایی طی مراحل حاصل شده است. مراحل مختلف آزمایش شبکه براساس فاکتورهای موثر در نتیجه در ادامه نشان داده می‌شود.

در اولین آزمایش از داده‌های سری زمانی استفاده می‌شود که شامل داده‌های ناحیه شمال شاهرود می‌باشند، تعداد این نمونه‌ها ۷۶ مورد است. تغییرات فصلی و سالیانه برای این

¹Epochs

²TimeStamps

شاخص‌ها مورد ارزیابی قرار می‌گیرد. ورودی شبکه در این مرحله داده فصل سال قبل و خروجی، پیش‌بینی داده فصل مشابه در سال بعد است. نتایج حاصل از این ارزیابی در جدول ۲.۴ قابل مشاهده است. در ستون اول جدول نام شاخص، ستون دوم تعداد تکرارهای شبکه، ستون سوم مقدار برچسب زمانی است که تعداد داده ورودی به شبکه را نشان می‌دهد و دو ستون آخر مربوط به خطاهای گزارش شده در نمونه‌های آموزشی و آزمون هستند.

جدول ۲.۴: نتایج حاصل از پیش‌بینی شاخص‌ها در مرحله اول آزمایش

<i>Index – Name</i>	<i>BestEpochs</i>	<i>Time – Stamp</i>	<i>Train – RMSE</i>	<i>Test – RMSE</i>
<i>NDVI</i>	200	1	0.05	0.06
<i>SAVI</i>	200	1	0.03	0.15
<i>RVI</i>	200	1	0.3	0.36

همانطور که می‌بینیم شاخص‌ها با میزان خطای محسوسی پیش‌بینی شده‌اند. در این مرحله با انجام آزمایش‌های مختلف مشاهده شد که با افزایش تعداد نمونه‌های آموزشی میزان خطا کاهش می‌یافت لذا در مرحله دوم از کار اقدام به استخراج نمونه‌های جدید در ناحیه شرق شاهرود انجام شد و تعداد نمونه‌ها به ۳۸۰ مورد افزایش یافت. در ناحیه شمال یک فریم و در ناحیه شرق چهار فریم از هر عکس استخراج شد. پس از آماده سازی نمونه‌ها داده‌ها مورد ارزیابی قرار گرفتند. نتایج حاصل از پیش‌بینی تغییرات شاخص‌ها در جدول ۳.۴ قابل مشاهده است. ورودی شبکه در این حالت نیز داده در فصل سال قبل و خروجی، داده فصل مشابه در سال بعد است. همانطور که مشاهده می‌شود میزان خطا کاهش یافته است، اما شاخص *RVI* نسبت به دو شاخص دیگر دارای خطای بیشتری است. با انجام آزمایش‌های متعدد از نظر

جدول ۳.۴: نتایج حاصل از پیش‌بینی شاخص‌ها در مرحله دوم آزمایش

<i>Index – Name</i>	<i>BestEpochs</i>	<i>Time – Stamp</i>	<i>Train – RMSE</i>	<i>Test – RMSE</i>
<i>NDVI</i>	200	1	0.03	0.04
<i>SAVI</i>	200	1	0.03	0.05
<i>RVI</i>	200	1	0.1	0.15

تعداد تکرارهای شبکه و همچنین برچسب زمانی‌های متفاوت نتایج جدیدتر و بهتری برای این شاخص حاصل شد. با دادن تعداد ورودی‌های بیشتر به شبکه میزان خطای شبکه کاهش می‌یافت.

در این مرحله برچسب زمانی به ۶ تغییر یافت و ورودی شبکه، داده‌ها در پنج سال گذشته و خروجی، داده فصل مشابه در سال آینده می‌باشد. در این مرحله شبکه با دریافت ورودی‌های بیشتر بهتر قادر به پیش‌بینی آینده است. در نهایت بهترین نتیجه برای هر سه شاخص حاصل گشت که نتایج نهایی در ادامه همراه با نمودار پیش‌بینی گزارش می‌شود. جدول ۴.۴ نتایج خطای حاصل از پیش‌بینی هر دو دسته داده آموزش و آزمون برای شاخص *NDVI* با برچسب زمانی و تکرارهای متفاوت می‌باشد. که با توجه به نتایج به دست آمده تعداد برچسب زمانی برابر با ۶ و تعداد تکرار برابر با ۳۰۰ نتایج مناسبی را ارائه می‌دهند. نمودار حاصل از پیش‌بینی مقادیر آموزش و آزمون شاخص *NDVI* در شکل ۱.۴ نشان داده شده است.


محور افقی این تصویر مربوط به زمان و محور عمودی مربوط به مقادیر شاخص می‌باشند. این شاخص برای نواحی انتخاب شده از تصاویر مقادیری بین ۰.۰۶ تا ۰.۲ را داراست، همانطور که پیشتر توضیح داده شد مقادیر این شاخص در بازه (۱+۱) قرار دارند. لازم به ذکر است که مقدار نشان داده شده در نمودار میزان میانگین شاخص در هر ناحیه است. مقدار میانگین شاخص در هر ناحیه نشان می‌دهد که پوشش گیاهی این نواحی از ضعیف تا متوسط است. تغییرات این شاخص از سال ۲۰۰۰ تا ۲۰۱۸ در نمودار پیداست و در برخی موارد تغییرات ناگهانی نیز مشاهده می‌شود. شبکه در پیش‌بینی تغییرات این شاخص موفق بوده است و با میزان خطای بسیار پایینی آن را پیش‌بینی می‌کند.

جدول ۴.۴: نتایج نهایی حاصل از پیش‌بینی شاخص *NDVI*

<i>Index – Name</i>	<i>Epochs</i>	<i>Time – Stamp</i>	<i>Train – RMSE</i>	<i>Test – RMSE</i>
<i>NDVI</i>	1	100	0.03	0.04
	1	200	0.03	0.04
	1	300	0.03	0.04
	6	100	0.03	0.04
	6	200	0.03	0.031
	6	300	0.02	0.03

جدول ۵.۴ نتایج خطای حاصل از پیش‌بینی هر دو دسته داده آموزش و آزمون برای شاخص *SAVI* با برچسب زمانی‌ها و تکرارهای متفاوت می‌باشد.

با توجه به اطلاعات به دست آمده که در جدول قابل مشاهده است. مقادیر *TimeStamp* برابر با ۵ و *Epoch* برابر با ۳۰۰ بهترین نتیجه را به دست می‌دهند. شکل ۲.۴ نمودار حاصل از پیش‌بینی این مقادیر روی داده‌های آموزش و آزمون را نشان می‌دهد. این شاخص در نواحی مد نظر مقادیری بین ۰.۰۵ تا ۰.۲۵ را نشان می‌دهد. مقادیر استاندارد این شاخص نیز در بازه (۱+۱) قرار دارند. مقادیر نشان داده شده در نمودار نشان دهنده میانگین پیکسل‌های




شکل ۱.۴: مقادیر پیش‌بینی شده برای دو دسته آموزش و آزمون شاخص *NDVI*

جدول ۵.۴: نتایج نهایی حاصل از پیش‌بینی شاخص *SAVI*


<i>Index – Name</i>	<i>Epoch</i>	<i>Time – Stamp</i>	<i>Train – RMSE</i>	<i>Test – RMSE</i>
<i>SAVI</i>	1	100	0.04	0.05
	1	200	0.04	0.05
	1	300	0.03	0.04
	6	100	0.03	0.04
	6	200	0.02	0.03
	6	300	0.01	0.02

موجود در هر ناحیه است. مقدار این شاخص در نواحی انتخاب شده نشان دهنده پوشش گیاهی ضعیف تا متوسط است و در طول زمان تغییراتی در آن مشاهده می‌شود، و در برخی مواقع تغییرات ناگهانی نیز قابل مشاهده است. شبکه در پیش‌بینی این شاخص با دقت خوبی موفق بوده است و با میزان خطای پایین آن را پیش‌بینی می‌کند. رفتار شبکه در برابر این شاخص همانند رفتار با شاخص *NDVI* می‌باشد.

جدول ۶.۴ نتایج خطای حاصل از پیش‌بینی هر دو دسته داده آموزش و آزمون برای شاخص *RVI* با برچسب زمانی‌ها و تکرارهای متفاوت می‌باشد.



شکل ۲.۴: مقادیر پیش‌بینی شده برای دو دسته آموزش و آزمون شاخص SAVI



شکل ۳.۴: مقادیر پیش‌بینی شده برای دو دسته آموزش و آزمون شاخص RVI

جدول ۶.۴: نتایج نهایی حاصل از پیش‌بینی شاخص *RVI*

<i>Index – Name</i>	<i>Epoch</i>	<i>Time – Stamp</i>	<i>Train – RMSE</i>	<i>Test – RMSE</i>
<i>RVI</i>	1	100	0.06	0.07
	1	200	0.06	0.07
	1	300	0.05	0.07
	6	100	0.05	0.06
	6	200	0.06	0.07
	6	300	0.05	0.06

با توجه به اطلاعات به دست آمده که در جدول ۶.۴ قابل مشاهده است. مقادیر برچسب زمانی برابر با ۶ و تکرار برابر با ۳۰۰ بهترین نتیجه را به دست می‌دهند. شکل ۳.۴ نمودار حاصل از پیش‌بینی این مقادیر روی داده‌های آموزش و آزمون را نشان می‌دهد. مقادیر این شاخص برای نواحی مد نظر از ۰.۸ تا ۱.۸ تغییر می‌کند. مقدار استاندارد این شاخص از صفر تا مقادیر بالای مثبت است. هر چه مقدار مثبت این شاخص بیشتر باشد، پوشش گیاهی در آن ناحیه متراکم‌تر است. مقادیر به دست آمده برای این شاخص نشان‌دهنده میزان متوسط پوشش گیاهی در این نواحی است و در مقایسه با دو شاخص قبلی میزان پوشش گیاهی و تغییرات آن را بهتر نشان می‌دهد.

شبکه در پیش‌بینی مقادیر آینده به خوبی آموزش می‌بیند و مقادیر را با خطای کم پیش‌بینی می‌کند. در شرایط ثابت و مشابه دو شاخص قبلی مقدار خطای این شاخص در حدود ۰.۲ بود. با انجام آزمایش‌های مختلف روی ورودی‌های شبکه مشخص شد که ترتیب ورودی‌ها در میزان یادگیری شبکه موثر است، به طوریکه در مواردی که ورودی شبکه فصل‌های پیشین فصلی است که قصد پیش‌بینی آن را داریم، شبکه در پیش‌بینی موفق‌تر است و با میزان خطای کمتری عمل پیش‌بینی را انجام می‌دهد.

۴.۴ مقایسه نتایج با مطالعات مرتبط اخیر

در این فصل مقادیر شاخص‌های پوشش گیاهی مورد ارزیابی قرار گرفتند، همانطور که نشان داده شد مقادیر دو شاخص *NDVI* و *SAVI* و تغییرات آن‌ها به هم شبیه است و رفتار شبکه نیز در آموزش و پیش‌بینی این مقادیر تقریباً یکسان است. مقدار و تغییرات شاخص *RVI* با دو شاخص دیگر تفاوت دارد و به طور بهتری میزان پوشش گیاهی و تغییرات را در نواحی مد نظر نشان می‌دهد.

عوامل موثر در پیش‌بینی دقیق‌تر به سه مورد تقسیم می‌شوند، مقدار برچسب زمانی، آزمایش ترتیب ورودی‌های مختلف به شبکه و تعداد تکرارهای شبکه. هر چه میزان برچسب زمانی افزایش می‌یابد، از میزان خطا کاسته می‌شود و در واقع شبکه با مشاهده مقادیر قبلی بیشتری، بهتر قادر به پیش‌بینی است. همچنین با آزمایش ترتیب‌های مختلف ورودی به شبکه، مشاهده می‌شود که در مواقعی که مقادیر ورودی برچسب زمانی داده شده به شبکه مربوط به ماه‌ها و فصول مشابه باشد، پیش‌بینی آینده بهتر و با دقت بیشتری انجام خواهد گرفت. مقدار تکرار در دقت بسیار موثر است، به طوریکه در تکرارهای بالاتر دقت پیش‌بینی افزایش می‌یابد و داده‌ها بهتر و با میزان خطای کمتری پیش‌بینی می‌شوند.

نتایج حاصل از این مطالعه در مقایسه با کارهای اخیر مشابه، نشان دهنده بهبود در پیش‌بینی است. در سال ۱۳۹۶ در مطالعه‌ای [۱۲] با استفاده از مدل مارکوف مقادیر شاخص پوشش گیاهی برای شهر بجنورد در استان خراسان شمالی پیش‌بینی شده است که میزان دقت مدل در مقایسه با مطالعه حاضر با استفاده از یادگیری عمیق پایین‌تر است. میزان دقت مدل مارکوف در حد ۸۰ درصد بیان شده است و میزان دقت مطالعه کنونی ما بیش از ۹۹ درصد است. در برخی مطالعات نیز با دریافت تصاویر لندست و در دست داشتن نرم‌افزارهای سنجش از دور مانند *ENVI*، اقدام به مشاهده و تحلیل تغییرات شاخص‌های پوشش گیاهی شده است. در این دسته مطالعات تغییرات سالیانه مورد ارزیابی و مقایسه قرار گرفته و با تحلیل تغییرات در سال‌های پشت سر هم اقدام به پیش‌بینی تغییرات مشابه در سال‌های آینده شده است. این دسته تحقیقات بر مبنای مقایسه و تحلیل آماری هستند که به درستی تغییرات آینده را پیش‌بینی نمی‌کنند [۱۳]. لذا استفاده از شبکه‌های عمیق در پژوهش کنونی، بسیار موثر است و عملیات پیش‌بینی را با دقت بیش از ۹۹ درصد انجام می‌دهد. در سال ۲۰۱۸ تحقیقی در کشور هند در منطقه جزیره نیکوبار با پوشش گیاهی متراکم انجام شده است که در آن از تصاویر سری زمانی *MODIS* استفاده می‌شود. الگوریتم به کار برده شده در این تحقیق نیز الگوریتم شبکه حافظه طولانی کوتاه-مدت است، اما داده‌ها از نوع سری زمانی *MODIS* با بازه هفت روزه می‌باشند. این داده‌ها دارای تغییرات زیادی در سال‌های متوالی نیستند و ناحیه مورد مطالعه پوشش گیاهی همیشه متراکمی دارد که با نواحی خشک و پوشش گیاهی متوسط بسیار متفاوت هستند. نتایج این تحقیق نیز دقت بالای شبکه عصبی عمیق را نشان می‌دهد [۵۷].

فصل ۵

نتیجه‌گیری و کارهای آینده

۱.۵ مقدمه

در این پایان‌نامه با دریافت تصاویر ماهواره‌ای مربوط به سال‌های ۲۰۰۰ تا ۲۰۱۸ از هر سال ۴ عکس به طوریکه تمام فصول سال تحت پوشش باشند، شاخص‌های پوشش گیاهی که مناسب ناحیه بودند استخراج شده و به صورت داده سری زمانی درآمدند. این داده‌ها با عنوان نمونه به شبکه حافظه طولانی کوتاه-مدت داده شدند و پس از جداسازی نمونه‌های آموزش و آزمون، عملیات آموزش و کامپایل مدل انجام شد. داده‌های سری زمانی جهت پیش‌بینی به دو دسته داده‌های آموزش و آزمون تقسیم شدند و با برچسب زمانی‌های متفاوت، همچنین تکرارهای متفاوت عمل پیش‌بینی انجام شد. نتایج به دست آمده طی چندین آزمایش با به دست آوردن خطای $RMSE$ کمتر از ۰.۰۵ به دست آمد. این نتایج نشان از قابلیت بالای شبکه در آموزش و پیش‌بینی داده‌های با تغییرات مناسب را دارد.

۲.۵ مشکلات و محدودیت‌های موجود

در انجام کار محدودیت‌هایی از جمله در دسترس نبودن داده به اندازه کافی وجود داشت. چرا که داده‌های موجود در سایت *USGS* اغلب دارای درصد ابر بالایی بودند و استفاده از آن‌ها منجر به پر کردن پیکسل‌های دارای ابر با داده‌های پیکسل معادل در سال قبل می‌شد.

که خود از کیفیت و درستی داده می‌کاهید، لذا از تصاویری استفاده شد که درصد ابر حداقل داشته باشند و درصد ابر برای دریافت داده‌های پژوهش حاضر برابر با ۱۰ درصد است. هر چه تعداد نمونه‌های آموزشی بیشتر باشد الگوریتم بهتر کار کرده و جواب بهتری گرفته می‌شود، همچنین تغییرات موجود در داده نیز برای بالا بردن کیفیت کار حائز اهمیت است. در انجام این پژوهش نواحی مختلف مورد بررسی قرار گرفتند و الگوریتم با داده‌های از نواحی مختلف آزمایش شده است و در نهایت ناحیه با بیشترین تغییرات پوشش گیاهی در نظر گرفته شده است. عملکرد الگوریتم در مقابل داده‌های با تغییرات کم تا زیاد مورد بررسی قرار گرفته است. در تمامی آزمایش‌ها عملکرد الگوریتم نسبت به الگوریتم‌های دیگر از جمله مدل مارکوف یا شبکه‌های عصبی بازگشتی بهتر بوده و دقت بالاتری از خود نشان داده است.

۳.۵ کارهای آینده

نتایج این مطالعه با استفاده از داده‌های ماهواره لندست با تصحیحات لازم انجام شد. نواحی جدا شده از تصاویر نواحی با پوشش گیاهی متوسط هستند که تغییرات پوشش گیاهی در آن‌ها بدون دخالت انسانی است. با توجه به عملکرد شبکه در این تحقیق و داده استفاده شده در آن، پیش‌بینی می‌شود که با داشتن داده‌های بیشتر از ناحیه یا نواحی که دارای تغییرات پوشش گیاهی بیشتری نسبت به این ناحیه باشند و همچنین استفاده از ویژگی‌های دیگری علاوه بر شاخص‌های پوشش گیاهی، نتایج بهتر و جدیدتری به دست آید. برای مثال اضافه کردن داده‌هایی مانند دما یا میزان بارش سالیانه و فصلی به داده‌های شاخص با تغییرات زیاد سبب آموزش بهتر شبکه می‌شود. همچنین استفاده از داده‌های سری زمانی با فاصله زمانی کم سبب آموزش بهتر شبکه و دریافت نتایج بهتر خواهد شد.

مراجع

- [۱] کاظمی نیا ع، (۱۳۹۶) ” کاربرد سنجش از دور در بررسی پوشش گیاهی ”، نشریه علمی- ترویجی مهندسی نقشه برداری و اطلاعات مکانی، شماره ۱، دوره نهم، ص ۳۶
- [۲] ممبئی م و عسگری ح، (۱۳۹۷) ” کاربرد سنجش از دور در بررسی پوشش گیاهی ”، فصلنامه علمی- پژوهشی اطلاعات جغرافیایی، شماره ۱۰۵، دوره ۲۷، ص ۲
- [۳] شمسی پور ع، حیدری س، و باقری ک، (۱۳۹۶) ” کاربرد سنجش از دور در بررسی پوشش گیاهی ”، پژوهش های جغرافیای برنامه ریز شهری، شماره ۳، دوره ۵، ص ۳
- [۴] فاطمی ب و رضایی ی، (۱۳۹۱) ” مبانی سنجش از دور ”، انتشارات آزاده، شماره ۳، دوره ۵، ص ۶
- [۵] کاظمی نیا ع، (۱۳۹۶) ” کاربرد سنجش از دور و GIS در بررسی پوشش گیاهی ”، نشریه علمی- ترویجی مهندسی نقشه برداری و اطلاعات مکانی، شماره ۱، دوره ۹، ص ۳
- [۶] کریمیان آ و جعفرزاده ن، (۱۳۸۵) ” کاربرد سنجش از دور در پایش منابع آب ”، اولین همایش ملی بهره برداری در بخش آب و فاضلاب، شماره ۳، دوره ۹، ص ۴
- [۷] اطمیابی س و جارگانی م، (۱۳۹۷) ” شکارسازی تغییرات کاربری اراضی با استفاده از داده های سنجش از دور ”، کنفرانس عمران، معماری و شهرسازی کشورهای جهان اسلام، شماره ۱، دوره ۲، ص ۲۵۰
- [۸] میجانی ن، حمزه س و کریمی م، (۱۳۹۸) ” کمی سازی تاثیر پارامترهای سطحی و شرایط اقلیمی بر دمای سطح زمین با استفاده از داده های انعکاسی و حرارتی سنجش از دور ”، فصلنامه سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی، شماره ۱، دوره ۱۰، ص ۵
- [۹] ناطقی س، حنوحه گرا، احسانی ا و بذرافشان ا، (۱۳۹۵) ” بررسی تغییرات پوشش گیاهی بر اساس شاخص های گیاهی با استفاده از سنجش از دور ”، فصلنامه علمی- پژوهش تحقیقات مرتع و بیابان ایران، شماره ۴، دوره ۱۰، ص ۷۷۸

- [۱۰] میرموسوی ح، بابایی غ و کریمی س، (۱۳۸۹) ”برآورد سطح پوشش گیاهی با استفاده از شاخص‌های مختلف تصاویر ماهواره‌ای در حوضه قشلاق- سنندج NDVI و مقایسه آنها با شاخص جهانی”، **فصلنامه علمی- پژوهش تحقیقات مرتع و بیابان ایران**، شماره ۷، دوره ۴۹، ص ۷۲
- [۱۱] امینی ج، (۱۳۸۸) ”پردازش کامپیوتری تصاویر سنجش از دور”، جلد اول چاپ دوم، موسسه چاپ و انتشارات دانشگاه تهران
- [۱۲] پرور ز و شایسته ک، (۱۳۸۹) ’پیش بینی روند تغییرات و توسعه شهری با استفاده از تصاویر ماهواره‌ای چندزمانه و سیستم‌اطلاعات جغرافیایی‘، **محیط شناسی**، شماره ۳، دوره ۴۳، ص ۵۲۷-۵۱۳
- [۱۳] جوادزین ا و دماوندی ع، (۱۳۹۷) ’ بررسی تغییرات شاخص‌های $NDVI$ ، $NDMI$ و $NDSI$ در دو مقطع سی ساله با استفاده از تصاویر ماهواره لندست ‘، **دومین کنفرانس بین‌المللی پژوهش‌های کاربردی در علوم کشاورزی، منابع طبیعی و محیط زیست**، شماره ۲، دوره ۴۸، ص ۱۵
- [۱۴] فرمانبر م، (۱۳۹۶)، پایان‌نامه ارشد: ”یک معماری برای پردازش داده‌های کلان سنجش از دور براساس پردازش خوشه‌ای“، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شاهرود
- [15] Kussul, N., Lavreniuk, M., Skakun, S. and Shelestov (2017), ” A Deep learning classification of land cover and crop types using remote sensing data” **IEEE Geoscience and Remote Sensing Letters**, pp 778-782
- [16] Ranganath R.N., Jayaraman V. and Roy P.S. (2007), ” Remote Sensing Applicatio: An Overview” **National Remote Sensing Agency, Hyderabad**, 500, 037, pp 5
- [17] Hasmadi M., Pakhriazad H. and Shahrin M. (2017), ” Evaluating supervised and unsupervised techniques for land cover mapping using remote sensing data” **Geografia-Malaysian Journal of Society and Space**, 5, 1, pp 1
- [18] Rawat J. and Kumar M. (2015), ” Monitoring land use/cover change using remote sensing and GIS techniques: A case study of Hawalbagh block, district Almora, Uttarakhand, India” **The Egyptian Journal of Remote Sensing and Space Science**, 18,1, pp 77-94
- [19] Galmier D. and Lacot R. (1970), ”Photo interpretation, with examples of its usefulness” **Photogrammetria**, 25,4, pp 139-146

-
-
- [20] Thompson M. M. and Mikhail E. (1976), "Automation in photogrammetry: Recent developments and applications" **Photogrammetria**, 32,4, pp 111-145
- [21] Colwell R. N. and Mikhail E. (1970), "The photo interpretation picture in 1960" **Photogrammetria**, 25, 4, pp 139-146
- [22] Haack B. N. and Mikhail E. (1982), "Landsat: A tool for development," World Development" **Photogrammetria**, 10, 10, pp 899-909
- [23] Liu P. and Mikhail E. (2015), "A survey of remote-sensing big data" **Frontiers in Environmental Science**, 3, 45, p. 45
- [24] Masek J. G., Hayes D. J., Hughes M. J., Healey S. P. and Turner D. P. (2015), "The role of remote sensing in process-scaling studies of managed forest ecosystems" **Forest Ecology and Management**, 355, 45, pp. 129-123
- [25] Campbell J. B., Hayes D. J. and Wynne R.H. (2011), "Introduction to remote sensing" **Guilford Press**, 35, 45, p. 2
- [26] Tsang L. , Kong J. A. and Shine R. T. (1985), "Theory of microwave remote sensing" **Guilford Press**, 35, 45, p. 3
- [27] Jensen J. R and Lulla K. (1987), "Introductory digital image processing: a remote sensing perspective" **Guilford Press**, 35, 45, p. 4
- [28] Seelan S. K., Laguetta S., Casady G. M. and Seielstad G. A. (2003), "Remote sensing applications for precision agriculture: A learning community approach" **Remote Sensing of Environment**, 88, 2, pp. 157-169
- [29] Chen M., Mao S., and Liu Y. (2014), "Big data: A survey" **Mobile Networks and Applications**, 19, 2, pp. 171-209
- [30] Khan N., (2014), "Big data: survey, technologies, opportunities, and challenges" **The Scientific World Journal**, 20, 14, p. 35
- [31] Wu H. and Zhao-Liang L. (2009), "Scale issues in remote sensing: A review on analysis, processing and modeling" **Sensors**, 9, 3, pp. 1768-1793
- [32] Keogh E. and Mueen A. (2011), "Curse of dimensionality" in **Encyclopedia of Machine Learning: Springer**, 20, 11, pp. 257-258

- [33] Zahangir Alom M. D., Taha T.M., and Yakopcic C., Westberg S., Sidike P., Nasrin M.S, Hasan M., Van Essen B. C., Awwal A. S. and Asari V. K. (2019), "A State-of-the-Art Survey on Deep Learning Theory and Architectures"
- [34] Liu W., Wang Z., Liu X., Zeng N., Liu Y. and Alsaadi F. E. (2017), "A Survey of Deep Neural Network Architectures and Their Applications" **the National Natural Science Foundation of China under Grants**, 20, 11, pp. 1-2
- [35] Das K. and Behera R. N. (2017), "A Survey on Machine Learning: Concept, Algorithms and Applications " **International Journal of Innovative Research in Computer and Communication Engineering**, 5, 2, pp. 1-2
- [36] Mitchell T. M. (2017), "**Machine Learning**", Vol. 1, University Press, UK. 1, pp. 273
- [37] Kotsiantis S. B. (2007), " Supervised Machine Learning: A Review of Classification Techniques " **Informatica**, 31, 2, pp. 249-268
- [38] Sathya R. and Abraham A. (2013), " Comparison of Supervised and Unsupervised Learning Algorithms for Pattern Classification " **International Journal of Advanced Research in Artificial Intelligence**, 31, 2, pp. 1-3
- [39] Kaelbling L. P., Littman M. L. and Moor A. W. (1996), " Reinforcement Learning: A Survey " **Journal of Artificial Intelligence Research**, 4, 2, pp. 237-285
- [40] Kaelbling L. P., Littman M. L. and Moor A. W. (2018), " Survey In Artificial Neural Networks In Myocardial Infarction " **International Journal of Advanced Engineering and Research Development**, 5, 3, pp. 1-5
- [41] Pouyanfar S., Sadiq S., Yan Y., Tian H., Tao Y., and Reyes P. M. (2018), " A survey on deep learning: Algorithms, techniques, and applications " **ACM Computing Surveys**, 51, 5, pp. 1-5
- [42] Turner D. P., Cohen W. B., Kennedy R. E., Fassnacht K. S. and Briggs J. M. (1999), "Relationships between leaf area index and Landsat TM spectral vegetation indices across three temperate zone sites " **Remote sensing of environment**, 70, 1, pp. 52-68

-
-
- [43] Gong P. (2013), "Finer resolution observation and monitoring of global land cover: first mapping results with Landsat TM and ETM+ data" **International Journal of Remote Sensing**, 34, 7, pp. 2607-2654
 - [44] Mack B., Leinenkugel P., Kuenzer C. and Dech S. (2017), "A semi-automated approach for the generation of a new land use and land cover product for Germany based on Landsat time-series and Lucas in-situ data" **Remote Sensing Letters**, 8, 3, pp. 244-253
 - [45] Ahmad W., Jupp L. and Nunez S. (1999), "Land cover mapping in a rugged terrain area using Landsat MSS data" **International Journal of Remote Sensing**, 13, 4, pp. 673-683
 - [46] Reinhold A. and Wolff G. (1970), "Methods of representing the results of photo interpretation" **Photogrammetria**, 25, 5, pp. 201-207
 - [47] Chander G., Markham B. L. and Helder D. L. (2009), "Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors" **Remote sensing of environment**, 113, 5, pp. 893-903
 - [48] Phiri D. and Morgenroth J. L. (2009), "Developments in Landsat land cover classification methods: A review" **Remote Sensing**, 9, 9, p. 967
 - [49] Hochreiter S. (1997), "Long Short-Term Memory " **Neural Computation**, 9, 8, pp. 1735-1780
 - [50] Stepchenko A. (2016), " Ndvi index forecasting using a layer recurrent neural network coupled with stepwise regression and the pca". **The 5th International Virtual Scientific Conference on Informatics and Management Sciences**, 7, 8, pp. 130–135
 - [51] Stepchenko A., and Chizhov, J. (2015), " Applying markov chains for NDVI time series forecasting of latvian regions". **Information Technology and Management Science**, 5, 6, pp. 57–61
 - [52] Foody G. M. (2006), "Pattern recognition and classification of remotely sensed images by artificial neural networks". **Ecological informatics Springer, Berlin**, 5, 6, pp. 459–477

-
- [53] Wagh V. M., Panaskar D. B., Muley A. A., Mukate S. V., Lolage Y. P., and Aamalawar M. L. (2016), "Prediction of groundwater suitability for irrigation using artificial neural network model: a case study of Nanded tehsil, Maharashtra, India Model". **Modeling Earth Systems and Environment**, 4, 6, p. 2
- [54] Gamboa J. C. B. (2017), "Deep Learning for Time-Series Analysis". **arXiv preprint arXiv:1701.01887**, 4, 6, p. 12
- [55] Das M. and Ghosh S.K. (2016)," Deep-step: A deep learning approach for spatiotemporal prediction of remote sensing data". **IEEE Geoscience and Remote Sensing Letters**, 4, 8, pp. 1984-1988
- [56] Das M. and Ghosh (2017)," Measuring Moran's I in a Cost-Efficient Manner to Describe a Land-Cover Change Pattern in Large-Scale Remote Sensing Imagery". **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing** , 2, 3, pp. 2631-2639
- [57] Reddy D. S. and Prasad P. R. C. (2018),"Prediction of vegetation dynamics using NDVI time series data and LSTM". **Modeling Earth Systems and Environment**, 6, 4, pp. 409-419
- [58] RuBwurm M. and Korner M. (2017),"Multitemporal land cover classification with long shortterm memory neural networks" **International archives of the photogrammetry, remote sensing and spatial information sciences**, 4, 5, p. 42
- [59] Wang S., Yang B., Yang Q., Lu, L., Wang X., and Peng Y. (2016), "Temporal trends and spatial variability of vegetation phenology over the northern hemisphere during 1982-2012". **International PLoS One**, 11, 6, p. 157
- [60] Adedeji O. H., Tope-Ajayi O. O., and Abegunde O. L. (2015), Assessing and Predicting Changes in the Status of Gambari Forest Reserve, Nigeria Using Remote Sensing and GIS Techniques". **International of Geographic Information System**, 7,3, pp. 301-318
- [61] Xue J., and Su B. (2017), "Significant remote sensing vegetation indices: a review of developments and applications". **International Journal of Sensors**, 5, 6, p. 8

-
-
- [62] Petitjean F., Inglada, J., and Gancarski P. (2014), "Assessing the quality of temporal high-resolution classifications with low-resolution satellite image time series". **International Journal of Remote Sensing**, 4, 9, pp. 2693–2712
- [63] Haas E. M., Bartholome E., and Combal B. (2009), "Time series analysis of optical remote sensing data for the mapping of temporary surface water bodies in sub-Saharan western Africa". **International Journal of Hydrology**, 7, 8, pp. 52–63
- [64] Calera A., Martínez, C., and Melia J. (2001), "A procedure for obtaining green plant cover: relation to NDVI in a case study for barley". **International International Journal of Remote Sensing**, 4, 5, pp. 3357-3362
- [65] Cohen W. B., Maersperger T. K., Gower, S. T., and Turner D. P. (2003), "An improved strategy for regression of biophysical variables and Land sat ETM+ Data". **International Remote Sensing of Environment**, pp. 561-571
- [66] Gurgel H. C., and Ferreira N. J. (2003), "Annual and Interannual Variability of NDVI in Brazil and its Connections with Climate". **International Journal of Remote Sensing**, pp. 3595–3609
- [67] Liang E. Y., Shao X. M., and He, J. C. (2005), "Relationships between tree growth and NDVI of grassland in the semiarid grassland of north China". **International Journal of Remote Sensing**, pp. 2901–2908
- [68] Hosseini S. Z., Kappas M., and Propastin P. (2011), "Estimating Relationship between Vegetation Dynamic and Precipitation in Central Iran". **Toledo. Spain**, p. 8
- [69] Hadian F., Hosseini SZ. (1393), " Seyyed Hassani M. Monitoring vegetation changes in Kermanshah, using NOVAA and AVHRR satellite imagery and rainfall data". **Journal of Applied Ecology**, pp. 46-62
- [70] Arsanjani J. J., Helbich M., Kainz W. and Darvishi Boloorani A. (2013), "Integration of regression, Markov chain and cellular automata models to simulate urban expansion". **International Journal of Applied Earth Observation and Geo information**, pp. 265-275
- [71] Jabbari S, Khajeh Aldin SJ, Jafari R, Soltani S (1394), "Investigating the percentage of changes in vegetation cover in pastures in Isfahan, Semirom, using satellite imagery". **Journal of Applied Ecology**; pp. 27-80

-
- [72] Mansuri S., Sepehri A., Farrokhzadeh B. (1394), "Evaluating drought impact on vegetation in pastures in Golestan, using MODIS satellite imagery". **Faculty of Rangeland, Watershed Management, Fisheries and Environment**, p. 7
- [73] Yin G., Hu Z., Chen X. and Tiyyip T. (2016), "Vegetation dynamics and its response to climate change in Central Asia". **Journal of Arid Land**, pp. 375-388
- [74] Chen Z., Jiang W. G., Tang Z. H. and Jia K. (2016), "Spatial-Temporal Pattern of Vegetation Index Change and the Relationship to Land Surface Temperature in Zoige". **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, pp. 849-852
- [75] Zhu Z., Piao S., Myneni R. B., Huang M., Zeng Z., Canadell J. G. and Cao C. (2016), "Greening of the Earth and its drivers". **Nature climate change**, 85, 5, pp. 791-795
- [76] Gers F. and Schmidhuber J. (2000), "Recurrent nets that time and count " **Proceedings of the IEEE-INNS-ENNS International** , 80, 3, pp. 1-5
- [77] Phiri D. and Morgenroth J. (2017), "Developments in Landsat land cover classification methods: A review " **Remote Sensing**
- [78] Haack B.N. (1982), "Landsat: A tool for development " **World Development** , 10, 10, pp. 899-909
- [79] Young N.E., Anderson R.S., Chignell S.M. and Vorster A.G. (2017), "A survival guide to Landsat preprocessing " **Ecology** , 98, 4, pp. 920-932
- [80] Graves A.E. (2012), "Supervised sequence labelling with recurrent neural networks " **Springer** , 385, 5, pp. 1-56

Aabstract

Remote sensing means receiving information without direct contact with the surface, which requires magnetic field. The data of this technology is spatio-temporal. Understanding and analyzing the changes in vegetation cover is very important in several aspects including understanding climate changes, ecological balance and planning necessary conservation measures. The concept of neural networks has gained much significance in the analysis of vegetation dynamics using remote sensing satellite data. In the current study, an attempt is made to predict the vegetation dynamics using Landsat-5, 7, 8 data for the Shahrood city using the Long Short Term Memory (LSTM) network. The dataset consists of Landsat images from 2000 to 2018 with 4 Images from each season. The extracted indices are NDVI, SAVI, RVI from vegetation indexes. In this study, after the atmospheric correction, the desired indices are extracted and time series are constructed. Then prediction is performed using deep learning algorithm. To check the reliability of the experiment we have finalized two different regions for investigation. To measure the accuracy of the LSTM network, root mean square error is calculated. To measure the accuracy of the LSTM network, root mean square error is calculated. The trends of the NDVI, SAVI and RVI series are well adapted by the network and it is able to predict the future Index values with good accuracy maintaining RMSE= 0.02 for NDVI, RMSE=0.03 for SAVI and RMSE=0.05 for RVI without providing any supplementary data. By adopting the proposed method, prediction of vegetation changes can be done with more than 99 percent accuracy. In previous studies, using Markov model and logistic regression for prediction of vegetation changes using Landsat satellite data, an accuracy of up to 80 percent is reported.

Key Words: Deep Learning, Vegetation Index, SpatioTemporal, Time series



Faculty Of Computer Engineering

MSc Thesis in Artificial Intelligence

SpatioTemporal Prediction Of Remote Sensing Data Using Deep Learning

By: Elham Zanganeh

Supervisors:

Dr. Hoda Mashayekhi

Dr. Saeideh Ferdosi

Advisor:

Dr. Saeid Gharachelo

Sep 2019