

پیش‌بینی مکانی - زمانی بارش ماهانه با استفاده از شبکه‌ی باور عمیق (مورد مطالعاتی: منطقه شمال غرب ایران)

هاجر رحیمی^۱، مهدی فرنقی^{۲*}

^۱ دانشجوی کارشناسی ارشد سیستم‌های اطلاعات مکانی - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه

نصیرالدین طوسی

rahimi@email.kntu.ac.ir

^۲ استادیار دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی

farnaghi@kntu.ac.ir

(تاریخ دریافت آبان ۱۳۹۵، تاریخ تصویب بهمن ۱۳۹۵)

چکیده

در جهان امروز، توسعه‌ی سریع، همه‌جانبه و پایدار، هدف اصلی تمامی کشورها از جمله ایران می‌باشد. اصلی‌ترین محدودیت پیش روی توسعه‌ی پایدار، وضعیت اقلیمی و شرایط محیط زیستی کشورها است. از جمله‌ی مهم‌ترین محدودیت‌های اقلیمی در کشور ایران، بارش ناکافی همراه با پراکندگی نامناسب مکانی - زمانی است. هدف اصلی این تحقیق، پیش‌بینی ماهانه‌ی میزان بارش در منطقه‌ی شمال غربی ایران با استفاده از روش‌های یادگیری ماشین شبکه‌ی عصبی کم عمق و شبکه‌ی باور عمیق و همچنین تهیه‌ی نقشه‌ی پیش‌بینی توزیع مکانی - زمانی آن در منطقه‌ی مطالعاتی می‌باشد. در این تحقیق از داده‌های بارش به همراه سایر داده‌های محیطی و هواشناسی، از ابتدای سال ۱۹۵۱ تا پایان سال ۲۰۱۴ استفاده شده است. ارتفاع و مختصات ایستگاه‌های هواشناسی نیز به عنوان پارامتر توپوگرافی از مدل رقومی ارتفاعی بدست آمد. همچنین به منظور انجام پژوهشی جامع و افزایش دقت نتایج، از داده‌های بزرگ مقیاس اقلیمی در کنار سایر داده‌ها بهره برده شده است. وجود پارامترهای متنوع محیطی، توپوگرافی و اقلیمی اثر گذار بر پدیده‌ی بارش، سبب شده است که در این تحقیق با کلان داده‌های مکانی - زمانی مواجه باشیم. در این پژوهش ابتدا داده‌های مورد نیاز جمع‌آوری شد و بعد از آماده‌سازی در پایگاه داده‌ی غیر رابطه‌ای کاساندرای ذخیره‌سازی گردید. در گام بعدی دو شبکه‌ی عصبی کم عمق و شبکه‌ی باور عمیق پیاده‌سازی شد و آموزش، تست و پیش‌بینی با هر دو مدل صورت پذیرفت و نقشه‌ی پیش‌بینی توزیع مکانی - زمانی بارش هر دو شبکه برای دوازده ماه سال ۲۰۱۴ تهیه گردید. مقایسه‌ی مقدار بارش ماهانه‌ی به وقوع پیوسته با میزان بارش ماهانه‌ی پیش‌بینی شده توسط شبکه‌ی عصبی کم عمق و شبکه‌ی باور عمیق نشان داد که شبکه‌ی باور عمیق از توانایی بیشتری در مواجه با کلان داده‌های مکانی - زمانی و حل پیچیدگی‌های مساله‌ی پیش‌بینی بارش برخوردار است. همچنین در این تحقیق از معیارهای Accuracy، Precision، Recall و F1 score جهت ارزیابی عملکرد روش‌های پیشنهادی استفاده شد. نتایج نشان داد که مقادیر Accuracy برای شبکه‌ی عصبی کم عمق و شبکه‌ی باور عمیق به ترتیب برابر ۰/۶۷ و ۰/۷۱، مقادیر Precision به ترتیب ۰/۶۹ و ۰/۶۹، مقادیر Recall به ترتیب ۰/۷ و ۰/۸ و مقادیر F1 score به ترتیب ۰/۶۹ و ۰/۷۴ می‌باشد.

واژگان کلیدی: پیش‌بینی ماهانه‌ی بارش، سامانه‌ی اطلاعات مکانی، کلان داده، توزیع مکانی - زمانی، شبکه‌ی عصبی کم عمق، شبکه‌ی باور عمیق

* نویسنده رابط

۱- مقدمه

آب یکی از ارکان اصلی حیات بشری است، به طوری که زندگی بدون آن برای موجودات زنده به هیچ شکلی قابل تصور نمی‌باشد. به رغم اینکه بخش اعظم سطح زمین را آب پوشانده، تنها بخش اندکی از آن قابل استفاده است [۱]. کشور ایران، علاوه بر تمامی محدودیت‌های جهانی آب، دارای بارشی به میزان یک سوم میانگین جهانی است که بحران آب را به چالشی ملی بدل کرده است [۲]. توزیع مکانی آب در ایران به دلیل شرایط طبیعی بسیار ناهمگن است و توزیع زمانی نزولات جوی نیز به مانند توزیع مکانی، روند مشابهی را نشان می‌دهد [۳].

در برابر خشکسالی، پدیده‌ی سیل قرار دارد. مطابق آمار تهیه شده توسط سازمان ملل متحد، در میان بلایای طبیعی، سیل و طوفان بیشترین تلفات و خسارات را وارد آورده‌است، به گونه‌ای که تنها در یک دهه میزان خسارات ناشی از سیل و طوفان بالغ بر ۲۱ میلیارد دلار در مقابل ۱۸ میلیارد دلار خسارات ناشی از زلزله بوده است [۴]. در کشور ایران نیز در سال‌های گذشته حدود ۷۰٪ اعتبارات سالانه‌ی طرح کاهش اثرات بلایای طبیعی و ستاد حوادث غیر مترقبه صرف جبران خسارات ناشی از سیل شده است [۴].

ایران از جمله معدود کشورهایی است که به صورت هم زمان هم با پدیده‌ی خشکسالی و هم با پدیده‌ی بارش‌های سیل آسا، دست به گریبان است. این حقیقت، اهمیت پیش‌بینی بارش در کشور ایران را دو چندان می‌کند.

منطقه‌ی شمال غربی ایران که از لحاظ تقسیمات کشوری شامل استان‌های آذربایجان غربی، آذربایجان شرقی، اردبیل، زنجان، کردستان و همدان می‌باشد، یکی از مهم‌ترین مناطق کشور از لحاظ اقتصادی، اجتماعی و ژئوپولتیک است. کاهش یا افزایش بیش از حد نزولات جوی می‌تواند خسارات جبران ناپذیری به این منطقه وارد آورد. از این رو پیش‌بینی بلند مدت بارش به مثابه ابزاری قدرتمند، نقش مهمی در برنامه‌ریزی و مدیریت منابع آبی منطقه ایفا می‌کند.

هدف اصلی این پژوهش، پیش‌بینی ماهانه‌ی بارش در منطقه‌ی شمال غربی ایران بر پایه‌ی کلان داده‌های مکانی-زمانی و با استفاده از روش‌های یادگیری ماشین

شبکه‌ی عصبی کم عمق^۱ و شبکه‌ی باور عمیق^۲ می‌باشد. به این منظور ابتدا داده‌های محیطی و هواشناسی، اقلیمی و توپولوژیکی جمع‌آوری شد و بعد از آماده‌سازی، در پایگاه داده‌ی غیر رابطه‌ای کاساندریا ذخیره گردید. سپس یک شبکه‌ی عصبی مصنوعی کم‌عمق و یک شبکه‌ی مبتنی بر یادگیری عمیق در نظر گرفته شد. بعد از تنظیم و بهینه‌سازی ساختار و پارامترهای این دو شبکه، مراحل تست، آموزش و پیش‌بینی انجام شد و نقشه‌های پیش‌بینی بارش ماهانه برای سال ۲۰۱۴ تهیه گردید. در نهایت مقایسه‌ای بین عملکرد این دو شبکه صورت پذیرفت.

این مقاله در پنج فصل نگارش شده است. پس از مقدمه در فصل دوم، مروری بر مطالعات انجام شده در حوزه‌ی پیش‌بینی‌های آب و هوایی و به طور خاص پیش‌بینی بارش خواهیم داشت و نقش مکان و پارامترهای مکانی و همچنین سیستم اطلاعات مکانی در این تحقیقات بررسی خواهد شد. سپس در فصل سوم مفاهیم پایه‌ی مرتبط با کلان داده، شبکه عصبی مصنوعی و همچنین یادگیری عمیق و در نهایت روش‌های ارزیابی شبکه، توضیح داده خواهد شد. در فصل چهارم ضمن معرفی منطقه مورد مطالعه و داده‌های مورد استفاده در این تحقیق، نحوه پیاده‌سازی دو مدل مورد نظر در این پژوهش و همچنین نتایج پیش‌بینی‌های انجام شده تجزیه و تحلیل خواهد شد. در نهایت در فصل پنجم به جمع‌بندی مسائل مطرح شده در این تحقیق خواهیم پرداخت و پیشنهادهای جهت ادامه‌ی تحقیق آورده شده است.

۲- پیشینه تحقیق

روش‌های مختلفی جهت پیش‌بینی پارامترهای آب و هواشناسی وجود دارد. به طور کلی این روش‌ها را می‌توان به سه دسته‌ی سینوپتیک یا همدیدی^۳، عددی یا دینامیکی^۴ و آماری^۵ تقسیم نمود [۵-۷]. پیش‌بینی‌های همدیدی یا سینوپتیکی براساس تحلیل کارشناسان هواشناسی نسبت به نقشه‌های همدیدی جو انجام می‌گیرد. وجود تغییرپذیری در متغیرها، خطای انسانی و در نتیجه دقت پایین از مهم ترین چالش‌های پیش روی این نوع پیش‌بینی است [۷، ۸].

^۱ Shallow Neural Network

^۲ Deep Belief Network

^۳ Synoptic Weather Forecasting

^۴ Numerical Weather Prediction

^۵ Statistical Weather Forecast

روش دیگر، استفاده از پیش‌بینی‌های عددی یا دینامیکی است. قوانین فیزیکی از قبیل پایستگی انرژی، بر تغییرات جوی حاکم هستند. این قوانین برحسب یک سری روابط ریاضی بیان می‌شوند که هسته‌ی مرکزی پیش‌بینی‌های دینامیکی را تشکیل می‌دهند. به این روابط، معادلات پیش‌بینی گفته می‌شود [۹]. البته این مدل‌ها کامل نبوده و همگی دارای خطا می‌باشند. در صورتی که هدف، تنها پیش‌بینی وضعیت جوی در چند روز آینده باشد، روش‌های عددی می‌تواند مفید واقع شود. اما در صورتی که پیش‌بینی‌های بلند مدت مد نظر باشد، به علت خطای موجود در روش‌های عددی، نتایج از اعتبار کافی برخوردار نخواهند بود. همچنین روش‌های عددی مستلزم داشتن حجم انبوهی از داده‌ها و قدرت محاسباتی بالا است که عملاً کار با روش‌های عددی را بسیار مشکل می‌کند [۹].

جهت فائق آمدن بر مشکلات روش‌های ذکر شده، عمدتاً از روش‌های آماری به عنوان روش جایگزین استفاده می‌شود. این روش‌ها، در پیش‌بینی‌های بلند مدت و همچنین در مواجهه با کلان داده‌ها موفق عمل می‌کند. یکی از روش‌های متداول و پرکاربرد جهت پیش‌بینی پارامترهای آب و هوایی با بهره‌گیری از روش‌های آماری، استفاده از شبکه‌های عصبی می‌باشد [۱۰]. تاکنون مطالعات بسیاری در زمینه آب و هواشناسی و به طور خاص پیش‌بینی بارش و با محوریت شبکه‌های عصبی انجام شده است. برای نمونه ابوت و همکاران (۲۰۱۴) در تحقیقی به انتخاب ورودی و بهینه سازی آن به منظور پیش‌بینی بارش ماهانه در منطقه‌ی کوئینزلند استرالیا با کمک شبکه‌ی عصبی مصنوعی پرداختند و تلاش کردند که بین داده‌های بارش و دما ارتباط برقرار کنند [۱۱]. همچنین قلی زاده و همکاران (۲۰۰۹) در تحقیق خویش به پیش‌بینی بارش ماهانه‌ی استان تهران با استفاده از شبکه‌های عصبی مصنوعی پرداختند. در این پژوهش از داده‌های بارش ماهانه طی دوره ی آماری ۵۳ ساله (۲۰۰۳ - ۱۹۵۱) و شبکه ی عصبی مصنوعی جهت پیش‌بینی بارش بهره برده شد [۱۲].

در این بین، تحقیقاتی رابطه‌ی بارش با پارامترهای بزرگ مقیاس اقلیمی را بررسی کردند. برای نمونه، مکانیک و همکاران (۲۰۱۳) از رگرسیون چند متغیره و شبکه‌ی عصبی مصنوعی جهت پیش‌بینی بلند مدت بارش با استفاده از داده‌های بزرگ مقیاس اقلیمی در استان

ویکتوریا در جنوب شرق استرالیا بهره بردند. در این تحقیق ترکیب اثر دو پدیده‌ی انسو و دو قطبی اقیانوس هند بر میزان بارش ماهانه در ناحیه‌ی مورد مطالعه بررسی شد [۱۳]. در تحقیقی دیگر غیاث آبادی و همکاران (۲۰۱۳) به پیش‌بینی بارش جنوب دریاچه‌ی ارومیه با استفاده از شبکه‌ی عصبی مصنوعی بر اساس سیگنال‌های اقلیمی در طی دوره‌ی آماری ۱۹۷۰ تا ۲۰۰۷ پرداختند [۱۴].

بخشی از تحقیقات انجام شده در زمینه‌ی پیش‌بینی وضع آب و هوا به بررسی رابطه‌ی بارش با پارامترهای مکانی مربوط است. برای نمونه استور و همکاران (۱۹۷۲) ارتفاع، زاویه شیب دامنه، فاصله از قله کوه و جهت ناهمواری را در توزیع مکانی بارش، موثر دانست [۱۵]. لیناکره و همکاران (۱۹۹۲) در تحقیقی نشان دادند که هشتاد و هشت درصد تغییرات مکانی بارش از شکل زمین تبعیت می‌کند [۱۶]. همچنین مور و همکاران (۱۹۷۲) مختصات جغرافیایی نقاط را به عنوان عامل تاثیر گذار بر توزیع مکانی بارش معرفی کردند [۱۷]. لوک و همکاران (۲۰۰۰) اثر اطلاعات مکانی-زمانی بر پیش‌بینی کوتاه مدت بارش را بررسی کردند. در این پژوهش از داده‌های بارش ۱۶ ایستگاه با بازه‌ی زمانی ۱۵ دقیقه بین ژانویه‌ی ۱۹۹۱ تا سپتامبر ۱۹۹۶ استفاده شده است. ایشان نشان دادند که اگر تعداد بهینه‌ای از ورودی‌های مکانی به شبکه وارد شود و نیز شبکه تاخیر کمتری داشته باشد، شبکه‌ی عصبی بهترین دقت را خواهد داد [۱۸]. در پژوهشی دیگر محمودیان و همکاران (۲۰۱۴) به بررسی رابطه‌ی بارش با سه عامل زمین اقلیم ارتفاع، طول و عرض جغرافیایی پرداختند. آنها نشان دادند که به ترتیب طول جغرافیایی، عرض جغرافیایی و ارتفاع بیشترین تاثیر را بر پدیده‌ی بارش دارند [۱۹]. مسعودیان و همکاران (۱۹۹۶) رابطه ی مکانی بارش با ارتفاع در ایران را مورد بررسی قرار دادند. ایشان پیشنهاد دادند که جهت بررسی تغییرات مکانی بارش در منطقه‌ای به وسعت ایران، به جای ارتفاع، از طول و عرض جغرافیایی نقاط کمک گرفته شود [۲۰]. رضائی و همکاران (۲۰۰۲) نیز از یک مدل رگرسیونی پنج متغیره شامل ارتفاع، طول جغرافیایی، عرض جغرافیایی، فاصله از کوه و فاصله از دریا برای برآورد مقادیر بارش در حوضه‌ی آبریز قره سو استفاده کردند. نتایج این تحقیق نشان داد که سه عامل طول جغرافیایی، عرض جغرافیایی و ارتفاع از سطح دریا، بیشترین سهم را در پیش‌بینی بارش توسط مدل رگرسیونی در منطقه‌ی مورد مطالعه دارند [۲۱]. همچنین

۳-۱- کلان داده

کلان داده به حجم عظیمی از داده‌های ساختار یافته، نیمه ساختار یافته و بدون ساختار گفته می‌شود که پردازش آن‌ها با پایگاه داده‌های سنتی و روش‌های معمول امکان پذیر نمی‌باشد [۲۶]. با ورود به عصر اطلاعات و ارتباطات و تولید داده با دستگاه‌های مختلف دیجیتال از قبیل دوربین‌ها، تلفن‌های همراه، حسگرها، ایستگاه‌های هواشناسی و غیره، روزانه حجم عظیمی از داده‌ها تولید می‌شود که این خود مستلزم روش‌های نوین جمع‌آوری^۱، ذخیره‌سازی^۲، جست‌وجو^۳، به‌اشتراک‌گذاری^۴ و پردازش^۵ داده می‌باشد [۲۷]. به طور کلی در مقالات اولیه‌ی مرتبط با این حوزه، چالش‌های پیش‌روی کلان داده‌ها شامل سه بعد اصلی حجم، تنوع و نرخ تولید می‌باشد [۲۸] اما با گذشت زمان این چالش‌ها شکل کامل‌تری به خود گرفت و علاوه بر سه چالش گفته شده، صحت^۶، اعتبار^۷، نوسان^۸، نمایش^۹ و ارزش^{۱۰} را نیز شامل شد [۲۹].

در بحث مطالعات آب و هواشناسی و به طور خاص‌تر پیش‌بینی بارش، داده‌ها علاوه بر برخورداری از حجم زیاد، دارای نرخ تولید بالا و تنوع بسیاری نیز می‌باشند [۳۰، ۳۱]. به‌علاوه اکثر پارامترهای محیطی و توپولوژیکی تاثیرگذار بر بارش، اطلاعات مکانی هستند که در طول زمان دچار نوسان شده و تغییر می‌یابند. از این رو می‌توان نتیجه گرفت که در مبحث پیش‌بینی بلند مدت بارش، بحث کلان داده‌های مکانی-زمانی^{۱۱} مطرح می‌باشد [۳۱، ۳۲]. سیستم اطلاعات مکانی، به عنوان ابزاری قدرتمند، قادر است تا امکان بصری‌سازی، تصمیم‌سازی، تجزیه و تحلیل و مدل‌سازی پدیده‌ی بارش را به خوبی فراهم آورد و مدیریت این حجم عظیم از داده‌های مکانی را تسهیل نماید [۳۰].

۳-۲- پایگاه داده‌ی غیر رابطه‌ای

با مطرح شدن بحث کلان داده‌ها، پایگاه داده‌های سنتی‌تر رابطه‌ای^{۱۲}، دیگر جواب‌گوی نیاز حال حاضر

منتوق و همکاران (۲۰۱۳)، تغییرات اقلیمی در اردن را با استفاده از شبکه‌ی عصبی مصنوعی و GIS به منظور پیش‌بینی آب و هوا، بررسی کردند. در این تحقیق داده‌های متوسط دمای بیشینه‌ی سالانه، متوسط دمای کمینه سالانه و متوسط دمای سالانه بین سال‌های ۱۹۷۹ تا ۲۰۰۸ مورد آنالیز قرار گرفت و در نتیجه دما و بارش سال‌های ۲۰۰۹ تا ۲۰۱۸، پیش‌بینی شد. در نهایت نقشه‌ی پیش‌بینی را تهیه کردند [۲۲]. دیوداتو (۲۰۰۵) به بررسی رابطه‌ی بارش با پارامترهای توپوگرافیکی در ناحیه‌ای کوهستانی در جنوب ایتالیا پرداخت. ایشان در این تحقیق از سیستم اطلاعات جغرافیایی جهت درونیابی استفاده نمود [۲۳].

در این بین تحقیقات بسیار کمی با استفاده از یادگیری عمیق جهت پیش‌بینی پارامترهای آب و هوایی صورت گرفته است. برای نمونه لیو و همکاران (۲۰۱۴)، از یک تکنیک یادگیری عمیق به نام Stacked Auto Encoder جهت پیش‌بینی چهار پارامتر آب و هوایی دما، سرعت باد، فشار سطح متوسط دریاها و دمای نقطه‌ی شبنم با استفاده از کلان داده‌های هواشناسی در ۲۴ ساعته آینده پرداختند. نتایج، موفقیت روش‌های مبتنی بر یادگیری عمیق در پیش‌بینی پارامترهای آب و هواشناسی را نشان داد [۲۴]. در تحقیقی دیگر دالتو و همکاران (۲۰۱۴) به پیش‌بینی کوتاه مدت وزش باد با استفاده از دو شبکه‌ی عصبی عمیق و کم عمق پرداختند. در این تحقیق تلاش شد تا الگوریتمی جهت انتخاب پارامترهای ورودی بهینه معرفی شود. نتایج این تحقیق برتری شبکه‌ی عصبی عمیق را نشان داد [۲۵]. بر اساس اطلاعات نویسندگان، تا زمان نگارش این مقاله، پژوهشی به منظور پیش‌بینی پارامترهای آب و هواشناسی با استفاده از یادگیری عمیق، در ایران صورت نگرفته است.

۳- مواد و روش‌ها

در این بخش تلاش شده است تا مبانی نظری این تحقیق جهت درک هر چه بهتر مساله‌ی پیش‌بینی بلند مدت بارش و تهیه‌ی نقشه‌های پیش‌بینی، متناسب با توزیع مکانی-زمانی آن، تشریح شود. به این منظور ابتدا مبحث کلان داده‌ها و به طور خاص کلان داده‌های مکانی-زمانی ارائه شده است. سپس مبانی شبکه‌ی عصبی مصنوعی و یادگیری عمیق به عنوان روش‌های ماشینی پایه‌ی پیاده‌سازی شده، تشریح می‌گردد. در نهایت معیارهای ارزیابی دقت استفاده در این پژوهش تشریح می‌شود.

^۱ Capture

^۲ Storage

^۳ Search

^۴ Sharing

^۵ Analysis

^۶ Veracity

^۷ Validity

^۸ Volatility

^۹ Visualization


^{۱۰} Value

^{۱۱} Spatiotemporal Big Data

^{۱۲} Relational Database (SQL)

[۴۱]. تعداد لایه‌های پنهان و نورون‌های آن‌ها، متناسب با پیچیدگی‌های مساله تعیین می‌شود [۴۲]. ساز و کار عملکرد شبکه‌های عصبی مصنوعی به این صورت است که ابتدا بخشی از داده‌ها که به طور هم‌زمان شامل پارامترهای ورودی و خروجی‌شان می‌باشند، جهت آموزش، به شبکه خوانده می‌شوند. در این مرحله، وزن‌های شبکه به نحوی تعیین می‌گردند که خطا کمینه گردد. سپس بخش دیگری از داده‌ها که تنها پارامترهای ورودی را شامل می‌شوند، جهت ارزیابی دقت، به شبکه وارد می‌گردند. یکی از معروف‌ترین انواع شبکه‌ی عصبی مصنوعی، شبکه‌ی پرسپترون چند لایه می‌باشد [۱۰]. روش‌های مختلفی جهت آموزش این نوع شبکه‌ها وجود دارد که یکی از معروف‌ترین آن‌ها انتشار رو به عقب می‌باشد [۱۰]. در این روش پارامترهای ورودی بعد از عبور از لایه (یا لایه‌های) میانی وارد لایه‌ی خروجی می‌شوند.

در این لایه مقدار پیش‌بینی شده با مقدار واقعی مقایسه می‌شود و در نتیجه میزان خطا بدست می‌آید. سپس با حرکتی رو به عقب در شبکه، خطای محاسبه شده سرشکن می‌گردد [۱۰]. در این تحقیق از شبکه‌ی پرسپترون چند لایه با شیوه‌ی آموزش انتشار رو عقب، جهت مدل‌سازی بارش استفاده می‌شود.



شکل ۱- ساختار شبکه‌ی عصبی پرسپترون چند لایه [۱۰]

۴-۳- یادگیری عمیق

یادگیری عمیق یک نگرش جدید به ایده‌ی شبکه‌های عصبی می‌باشد. در واقع یادگیری عمیق مجموعه الگوریتم‌هایی است که در تلاش‌اند تا مفاهیم انتزاعی و پیچیده را در سطوح و لایه‌های مختلف مدل کنند [۴۳-۴۹]. ایده‌ی اصلی شبکه‌های مبتنی بر یادگیری عمیق، نزدیک شدن هر چه بیشتر یادگیری ماشین به یکی از اهداف اصلی‌اش که همان هوش مصنوعی است، می‌باشد. در سال‌های اخیر پیشرفت‌های زیادی در حوزه یادگیری عمیق صورت گرفته که سبب ایجاد

نبودند. در چنین شرایطی بود که پایگاه داده‌های غیر رابطه‌ای^۱ برای غلبه بر محدودیت‌ها و مشکلات نوع رابطه‌ای به‌وجود آمد [۳۳]. از جمله مزیت‌های نوع غیر رابطه‌ای، می‌توان به امکان ذخیره‌سازی کلان داده‌ها، مقیاس پذیری^۲، عدم نیاز به وجود مدل داده‌ای^۳ ثابت، وجود تکنیک پیشرفته در ذخیره‌سازی داده، ارزان‌تر بودن سرورها و هزینه نگهداری کمتر اشاره کرد [۳۴].

از آن جایی که در این تحقیق بحث کلان داده‌های مکانی- زمانی مطرح می‌باشد، انتخاب یک پایگاه داده‌ی غیر رابطه‌ای، ضروری به نظر می‌رسد. از میان تمامی پایگاه داده‌های غیر رابطه‌ای موجود، پایگاه داده‌ی کاساندریا جهت ذخیره‌سازی داده‌های این تحقیق انتخاب شد. کاساندریا ابتدا در سال ۲۰۰۸ توسط شرکت فیس‌بوک توسعه داده شد اما بعدها در سال ۲۰۱۰ به عنوان یک پروژه‌ی متن باز در اختیار بنیاد آپاچی قرار گرفت. از جمله مزیت‌های کاساندریا که آن را به یک پایگاه داده پیش رو در میان سایر پایگاه داده‌های غیر رابطه‌ای بدل کرده، می‌توان به منبع باز بودن این پایگاه داده^۴، بهره‌گیری از معماری Peer 2 Peer، دسترسی بالا^۵، تحمل‌پذیری خطا^۶، ثبات مناسب^۷ و ستون‌گرایی^۸ اشاره کرد [۳۵] [۳۶] [۳۷].

این معماری درونی بسیار قوی^۹، سبب شد تا در این تحقیق از پایگاه داده‌ی کاساندریا جهت ذخیره‌سازی کلان داده‌های مکانی- زمانی مرتبط با بارش استفاده شود.

۳-۳- شبکه‌ی عصبی مصنوعی

شبکه‌ی عصبی مصنوعی یک روش محاسباتی است که از سیستم‌های عصبی زیستی الهام گرفته شده است [۳۸]. و کارایی خود را در حل مسائل پیچیده نشان داده است [۳۹]. اساس این شبکه، استخراج ویژگی‌ها و روابط ذاتی بین داده‌ها و تعمیم آن‌ها در شرایط دیگر می‌باشد [۴۰]. این شبکه معمولاً از سه بخش اصلی لایه‌ی ورودی، لایه (یا لایه‌های) پنهان و لایه‌ی خروجی تشکیل شده است

^۱ Non Relational Database (NoSQL)

^۲ Elastic Scalability

^۳ Schema

^۴ Open Source

^۵ High Availability

^۶ Fault Tolerance

^۷ Tunable Consistency

^۸ Column Oriented

^۹ Robust Architecture

۳-۵- طبقه‌بندی معیارهای ارزیابی دقت

در این پژوهش از تکنیک طبقه‌بندی و تخمین کلاس /احتمالی^۷ جهت بیان نتایج استفاده شد. در این روش تلاش بر آن است تا بارش ماهانه‌ی سال ۲۰۱۴ و کلاسی که به آن تعلق می‌گیرد پیش‌بینی شود. در این حالت کلاس‌ها مستقل از هم می‌باشند. در شیوه‌ی طبقه‌بندی و تخمین کلاس احتمالی، از چهار معیار 'Recall'، 'Accuracy'، 'Precision' و 'F1 score' جهت بیان دقت نتایج استفاده می‌شود [۵۳]. پیش از پرداختن به هر یک از این پارامترها، ضروری است تا با دو مفهوم ماتریس درهم‌ریختگی^۸ و جدول درهم‌ریختگی^۹ آشنا شویم.

ماتریس درهم‌ریختگی یا خطا، به ماتریسی اطلاق می‌شود که عملکرد و دقت مدل‌ها را در پیش‌بینی کلاس مورد نظر نشان می‌دهد. در این ماتریس سطرها نشان دهنده‌ی تعداد پیش‌بینی شده، و ستون‌ها تعداد واقعی نمونه‌های هر کلاس را نشان می‌دهند [۵۴]. به تعداد کلاس‌های موجود در ماتریس درهم‌ریختگی، جدول در-هم‌ریختگی وجود دارد. در هر جدول درهم‌ریختگی، کلاس مربوطه مثبت فرض می‌شود. در حقیقت جدول درهم‌ریختگی به جدولی ۲×۲ اطلاق می‌شود که هدف آن نمایش تعداد «درست مثبت» یا همان TP (تعداد کلاس مثبتی که به درستی پیش‌بینی شده است)، «درست منفی» یا همان TN (تعداد کلاس‌های منفی که به درستی پیش‌بینی شده است)، «غلط مثبت» یا همان FP (تعداد کلاس‌های منفی که به اشتباه مثبت پیش‌بینی شده است) و «غلط منفی» یا همان FN (تعداد کلاس مثبتی که به اشتباه منفی پیش‌بینی شده است) می‌باشد [۵۳-۵۷]. با کمک این چهار پارامتر، می‌توان معیارهای دقت مورد استفاده در این تحقیق را محاسبه نمود.

معیار Accuracy که نشان دهنده‌ی میزان نمونه‌هایی است که مدل در پیش‌بینی آن‌ها موفق عمل کرده است، به صورت زیر محاسبه می‌شود [۵۸].

$$ACC = \frac{\text{مشاهداتی که به درستی پیش‌بینی شده}}{\text{تعداد کل مشاهدات}} \quad (۱)$$


$$= \frac{TP + TN}{TP + FN + TN + FP}$$

^۷ Classification and class probability estimation

^۸ Confusion matrix

^۹ Table of confusion

روش‌های گوناگونی در این حوزه گشته است. شبکه‌ی باور عمیق یکی از قدرتمندترین الگوریتم‌های یادگیری عمیق است که در سال ۲۰۰۶ توسط هینتون ارائه شده است. در نگاه اول دو شبکه‌ی باور عمیق و پرسپترون چند لایه^۱ از لحاظ ساختار شبکه یکسان به نظر می‌آیند. این در حالی است که شبکه‌های باور عمیق از چند لایه ماشین بولتزمن محدود شده^۲ (RBM) ساخته شده‌اند [۵۰]. در واقع یک ماشین بولتزمن نوع خاصی از میدان‌های تصادفی مارکوف هستند که از شبکه‌های متقارن با واحدهای تصادفی باینری تشکیل شده‌اند [۵۰]. این شبکه از یک لایه واحدهای مخفی و یک لایه واحدهای مشاهده‌پذیر تشکیل شده که اتصالات بین دو لایه کاملاً برقرار می‌باشد. این در حالی است که اتصالات بین واحدهای مخفی و بین واحدهای مشاهده‌پذیر کاملاً قطع است (شکل ۲) [۵۰]. همچنین علاوه بر تفاوت‌های ساختاری، دو شبکه‌ی باور عمیق و پرسپترون چند لایه از لحاظ شیوه‌ی آموزشی نیز کاملاً متفاوت می‌باشند. در مدل‌هایی نظیر پرسپترون چند لایه، آموزش با کمک شیوه‌ی انتشار رو به عقب^۳ صورت می‌گیرد در صورتی که استفاده از همین متد آموزشی در شبکه‌های باور عمیق، سبب ایجاد خطای "گرادیان محو شونده"^۴ می‌شود [۵۱]. شیوه‌ی آموزش در شبکه‌های باور عمیق به این صورت است که ابتدا اولین ماشین بولتزمن محدود شده آموزش می‌بیند. سپس لایه‌ی پنهان^۵ آن، نقش لایه‌ی قابل مشاهده‌ی^۶ دومین ماشین بولتزمن محدود شده را ایفا می‌کند و آموزش دومین ماشین بولتزمن محدود شده با استفاده از خروجی ماشین بولتزمن اول صورت می‌گیرد. این روند تا آموزش تک تک لایه‌های مدل تداوم می‌یابد [۵۲].



شکل ۲- ساختار شبکه‌ی باور عمیق [۵۲]

^۱ Multi Layer Perceptron

^۲ Restricted Boltzmann Machine

^۳ Backward Propagation of Errors

^۴ Vanishing Gradient


^۵ Hidden Layer

^۶ Visible Layer

بهینه می‌گردد. بعد از طی مراحل آموزش، تست و پیش‌بینی، نقشه‌ی بارش ماهانه‌ی سال ۲۰۱۴ مجدداً تهیه می‌گردد. در گام آخر نیز مقایسه‌ی بین نتایج حاصل از دو شبکه عصبی مصنوعی کم عمق و باور عمیق صورت می‌گیرد.

۴-۱- محدوده‌ی تحقیق

منطقه‌ی شمال غربی ایران که از لحاظ تقسیمات کشوری شامل استان‌های آذربایجان غربی، آذربایجان شرقی، اردبیل، زنجان، کردستان و همدان می‌شود، یکی از مهم‌ترین مناطق کشور از لحاظ اقتصادی، اجتماعی و ژئوپولیتیک می‌باشد. شکل (۳) منطقه‌ی مطالعاتی را نشان می‌دهد.



شکل ۳- منطقه‌ی مورد مطالعه

همچنین در جدول شماره‌ی (۱) اطلاعاتی از قبیل نام استان، موقعیت جغرافیایی، ارتفاع از سطح دریا، مساحت، جمعیت و تعداد شهرستان‌های منطقه‌ی مورد مطالعه ارائه شده است. این خطه از کشور دارای ویژگی‌ها و قابلیت‌های منحصر به فردی است که هر یک بازگو کننده‌ی اهمیت بارش و پیش‌بینی آن برای منطقه‌ی مورد مطالعه است. از جمله این قابلیت‌ها، می‌توان به وجود جنگل‌ها، رودخانه‌ها، دریاچه‌هایی چون ارومیه و رونق بسیار کشاورزی و دامپروری اشاره کرد.

معیار Precision بیان‌کننده آن است که چه میزان از پیش‌بینی‌های مثبت، درست می‌باشد. به عبارت دیگر، میزان دقت پیش‌بینی را با توجه به FP بیان می‌کند [۵۸].

$$PREC = \frac{TP}{TP + FP} \quad (2)$$

معیار Recall نشان‌دهنده آن است که چه میزان از کلاس مثبت، به درستی پیش‌بینی شده‌اند. به عبارت دیگر، میزان دقت پیش‌بینی را با توجه به FN بیان می‌کند [۵۸].

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

معیار F1 score در حقیقت میانگین وزنی Precision و Recall می‌باشد [۵۸].

$$F1 \text{ score} = \frac{2 (Recall \times Precision)}{(Recall + Precision)} \quad (4)$$

$$= \frac{2 TP}{2 TP + FN + FP}$$

۴- پیاده‌سازی و نتایج

در این قسمت از تحقیق ابتدا منطقه‌ی شمال غربی ایران به عنوان ناحیه‌ی مطالعاتی معرفی می‌شود. بعد از آن داده‌های مورد استفاده در این پژوهش معرفی خواهند شد. سپس یک شبکه‌ی عصبی مصنوعی کم‌عمق در نظر گرفته شده و اقدام به تنظیم و بهینه‌سازی پارامترهای آن می‌شود. بعد از بهینه‌سازی پارامترهای شبکه‌ی عصبی مصنوعی کم‌عمق، مرحله‌ی آموزش، تست و همچنین پیش‌بینی بارش ماهانه‌ی سال ۲۰۱۴ با کمک شبکه‌ی بهینه شده، انجام می‌شود و نقشه‌های پیش‌بینی تهیه می‌گردد. در گام بعدی به سراغ یک شبکه‌ی باور عمیق رفته و این بار پارامترهای آن تنظیم و

جدول ۱- مشخصات منطقه‌ی مورد مطالعه

نام استان	مرکز استان	موقعیت جغرافیایی استان		ارتفاع از سطح دریا (متر)	مساحت استان (کیلومتر مربع)	جمعیت استان	تعداد شهرستان‌ها
		عرض جغرافیایی	طول جغرافیایی				
آذربایجان شرقی	تبریز	N: 36°45'- 39°26'	E: 45°7'- 48°20'	۱۳۴۵	۴۵۴۹۰/۸۸	۳۷۲۴۶۲۰	۲۰
آذربایجان غربی	ارومیه	N: 35°58'- 39°46'	E: 44°3'- 47°23'	۱۳۶۳	۴۳۶۶۰	۳۰۸۰۵۷۶	۱۷
اردبیل	اردبیل	N: 37°9'- 39°42'	E: 47°15'- 48°56'	۱۳۳۸	۱۷۸۸۱	۱۲۴۸۴۸۸	۱۰
زنجان	زنجان	N: 35°25'- 37°15'	E: 47°1'- 49°52'	۱۶۳۸	۲۲۱۶۴	۱۰۱۵۷۳۴	۷
کردستان	سنندج	N: 34°44'- 36°30'	E: 45°31'- 48°16'	۱۴۶۳	۲۸۲۰۳	۱۴۹۳۶۴۵	۱۰
همدان	همدان	N: 33°59'- 35°48'	E: 47°34'- 49°36'	۱۷۴۱	۱۹۴۹۳	۱۷۵۸۲۶۸	۹

۴-۲- داده‌های ورودی

در این تحقیق از داده‌های محیطی و هواشناسی، داده‌های بزرگ مقیاس اقلیمی و همچنین داده‌های توپوگرافی به منظور پیش‌بینی ماهانه‌ی بارش، استفاده شده است. جدول (۲) جزئیات داده‌های ورودی را تشریح می‌نماید (جدول ۲).

جدول ۲- داده‌ها مورد استفاده در این تحقیق


	نام داده‌ی ورودی		نوع داده	بازه‌ی مورد بررسی		منبع تهیه داده
	فارسی	انگلیسی		پایان بازه	شروع بازه	
داده‌های محیطی و هواشناسی	بیشینه دمای هوا	Temp_Max	ماهانه	۲۰۱۴	۱۹۵۰	سازمان هواشناسی کشور
	کمینه دمای هوا	Temp_Min	ماهانه	۲۰۱۴	۱۹۵۰	
	میانگین دمای هوا	Temp_Mean	ماهانه	۲۰۱۴	۱۹۵۰	
	مجموع بارش	Precipitation	ماهانه	۲۰۱۴	۱۹۵۰	
	سمت و سرعت باد بیشینه	Wind_Max	ماهانه	۲۰۱۴	۱۹۵۰	
	میانگین سرعت باد	Wind_Mean	ماهانه	۲۰۱۴	۱۹۵۰	
شاخص‌های بزرگ مقیاس اقلیمی	نوسان قطب جنوبی	AO	ماهانه	۲۰۱۴	۱۹۵۰	اداره‌ی ملی اقیانوسی و جوی ایالات متحده آمریکا
	نوسان آتلانتیک شمالی	NAO	ماهانه	۲۰۱۴	۱۹۵۰	
	شاخص دمای سطح آب در اقیانوس آرام حاره‌ای	Nino1+2	ماهانه	۲۰۱۴	۱۹۵۰	
	شاخص دمای سطح آب در شرق اقیانوس آرام استوایی	Nino3	ماهانه	۲۰۱۴	۱۹۵۰	
	شاخص دمای سطح آب در شرق اقیانوس آرام حاره‌ای	Nino3.4	ماهانه	۲۰۱۴	۱۹۵۰	
	شاخص دمای سطح آب در اقیانوس آرام مرکزی	Nino4	ماهانه	۲۰۱۴	۱۹۵۰	
داده‌ها توپوگرافی	ارتفاع	Height	-	-	-	مدل رقومی زمین
	طول و عرض جغرافیایی	Longitude & Latitude	-	-	-	

این تحقیق از داده‌های ماهانه‌ی مربوط به پارامترهای فوق در بازه‌ی زمانی (۲۰۱۴-۱۹۵۱) استفاده شد. همچنین ارتفاع، طول و عرض جغرافیایی به عنوان داده‌ی توپوگرافی و تاثیرگذار بر بارش، از مدل رقومی ارتفاعی بدست آمد. در نهایت بعد از آماده‌سازی، داده‌ها در پایگاه داده‌ی غیر رابطه‌ای کاساندرای ذخیره‌گردید. در جدول (۲) لیستی از داده‌های جمع‌آوری شده در این تحقیق نمایش داده شده است.

۴-۳- مدل‌سازی بارش

در این بخش مدل‌سازی بارش با استفاده از دو شبکه‌ی عصبی مصنوعی کم‌عمق و شبکه‌ی باور عمیق، توضیح داده می‌شود. مراحل اصلی پیاده‌سازی در شکل (۴) نشان داده شده است.

شاخص‌های بزرگ مقیاس اقلیمی نیز از جمله عوامل تاثیر گذار بر میزان بارش می‌باشند. در واقع الگوهای اقلیمی حاصل روابط پیچیده و برهم‌کنش اقیانوس‌ها (آب کره)، کوهستان‌ها و خشکی‌ها (سنگ کره) و شرایط پایینی جو (هوا کره) می‌باشد. با وجود آنکه این الگوها در مکان‌های مشخصی اتفاق می‌افتند، اما دامنه اثرگذاری آن‌ها تا مکان‌های دور دست نیز گسترش یافته است. داده‌های بزرگ مقیاس اقلیمی از سایت اداره‌ی ملی اقیانوسی و جوی ایالات متحده آمریکا (NOAA) تهیه شده است. از بین تمامی پارامترهای بزرگ مقیاس اقلیمی، بر اساس تحقیقات صورت گرفته، پارامترهای AO، NAO، Nino1+2، Nino3، Nino3.4 و Nino4، بیشترین تاثیر را بر بارش منطقه‌ی شمال غربی ایران دارند. از این رو در



شکل ۴- (الف) ذخیره سازی داده در پایگاه داده. (ب) فرایند آموزش شبکه ی عصبی کم عمق (۱) و شبکه ی باور عمیق (۲). (ج) فرایند ارزیابی دقت و پیش بینی با هر دو مدل

۴-۳-۱- ساختار مدل پیش بینی

در راستای هدف پیش بینی بارش ماهانه ی سال ۲۰۱۴ با استفاده از دو مدل شبکه ی عصبی مصنوعی کم عمق و شبکه ی باور عمیق، یک مدل پیش بینی در نظر گرفته شد (شکل ۵). در این مدل، اطلاعات ماهانه ی مربوط به پارامترهای مجموع بارش ماهانه (p)، کمینه دما (T_{min})، بیشینه دما (T_{max}) و متوسط دما (T)، AO، NAO، Nino1+2، Nino3، Nino4 و Nino3.4، برای دوازده ماه پیش از ماه مورد پیش بینی، به عنوان پارامتر ورودی به هر دو شبکه داده می شود. همچنین مقدار بارش ماهانه، به عنوان پارامتر پیش بینی این مدل در نظر گرفته شد. از آنجایی که در این تحقیق از تکنیک طبقه بندی و تخمین کلاس احتمالی جهت بیان نتایج استفاده می شود، از شاخص درصد / بارش نرمال به عنوان تکنیک طبقه بندی بهره برده می شود [۵۹-۶۱]. در این شیوه می توان بارش را به پنج کلاس بارش بسیار کم (کمتر از ۸۰ درصد میانگین بارش)، بارش کم (بین ۸۰ تا ۹۰ درصد میانگین بارش)، بارش متوسط (بین ۹۰ تا ۱۱۰ درصد میانگین بارش)، بارش زیاد (بین ۱۱۰ تا ۱۲۰

درصد میانگین بارش)، بارش بسیار زیاد (بیش از ۱۲۰ درصد میانگین بارش) طبقه بندی کرد. لازم به ذکر است که در مرحله ی آموزش، مقدار محقق شده ی بارش به عنوان پارامتر خروجی به شبکه داده می شود. در این حالت بارش تنها تحت تاثیر پارامترهای فوق در دوازده ماه گذشته، پیش بینی خواهد شد و روند طی شده در سال های اخیر، در نظر گرفته نشده است. از این رو میانگین مقادیر ماهانه ی مربوط به ده سال گذشته ی تک تک این پارامترها به همراه میانگین ده ساله ی سرعت باد، برای ماه مورد پیش بینی به مدل داده می شود. در این صورت مدل علاوه بر تاثیر پذیری از روند کامل یک سال گذشته، از برآیند سال های پیش نیز متأثر خواهد بود. علاوه بر پارامترهای فوق، ارتفاع و مختصات بدست آماده از مدل رقومی زمین به عنوان داده ی توپولوژیکی به همراه شماره ی ماه به مدل داده می شود. در شکل (۵) مدل پیش بینی مورد استفاده در این پژوهش نشان داده شده است. در این مدل t و y به ترتیب بیانگر شماره ی ماه و سال مورد پیش بینی می باشد.

$$\begin{aligned}
P_t = & f(P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{t-5}, P_{t-6}, P_{t-7}, P_{t-8}, P_{t-9}, P_{t-10}, P_{t-11}, P_{t-12}, \frac{y-10}{y-1} \bar{P}_t, T_{t-1}, T_{t-2}, T_{t-3}, T_{t-4}, T_{t-5}, T_{t-6}, T_{t-7}, \dots \\
T_t = & T_{t-8}, T_{t-9}, T_{t-10}, T_{t-11}, T_{t-12}, \frac{y-10}{y-1} \bar{T}_t, T_{max,t-1}, T_{max,t-2}, T_{max,t-3}, T_{max,t-4}, T_{max,t-5}, T_{max,t-6}, T_{max,t-7}, T_{max,t-8}, \dots \\
T_{max,t} = & T_{max,t-9}, T_{max,t-10}, T_{max,t-11}, T_{max,t-12}, \frac{y-10}{y-1} \bar{T}_{max,t}, T_{min,t-1}, T_{min,t-2}, T_{min,t-3}, T_{min,t-4}, T_{min,t-5}, T_{min,t-6}, T_{min,t-7}, \dots \\
T_{min,t} = & T_{min,t-8}, T_{min,t-9}, T_{min,t-10}, T_{min,t-11}, T_{min,t-12}, \frac{y-10}{y-1} \bar{T}_{min,t}, \frac{y-10}{y-1} \bar{W}_t, e_{0,1}, AO_{t-1}, AO_{t-2}, AO_{t-3}, AO_{t-4}, AO_{t-5}, AO_{t-6}, AO_{t-7}, \dots \\
AO_t = & AO_{t-8}, AO_{t-10}, AO_{t-11}, AO_{t-12}, \frac{y-10}{y-1} AO_t, NAO_{t-1}, NAO_{t-2}, NAO_{t-3}, NAO_{t-4}, NAO_{t-5}, NAO_{t-6}, NAO_{t-7}, NAO_{t-8}, NAO_{t-10} \dots \\
NAO_t = & NAO_{t-11}, NAO_{t-12}, \frac{y-10}{y-1} NAO_t, Nino12_{t-1}, Nino12_{t-2}, Nino12_{t-3}, Nino12_{t-4}, Nino12_{t-5}, Nino12_{t-6}, Nino12_{t-7}, Nino12_{t-8}, \dots \\
Nino12_t = & Nino12_{t-10}, Nino12_{t-11}, \frac{y-10}{y-1} Nino12_t, Nino12_{t-12}, Nino3_{t-1}, Nino3_{t-2}, Nino3_{t-3}, Nino3_{t-4}, Nino3_{t-5}, Nino3_{t-6}, Nino3_{t-7}, \dots \\
Nino3_t = & Nino3_{t-8}, Nino3_{t-10}, Nino3_{t-11}, Nino3_{t-12}, \frac{y-10}{y-1} Nino3_t, Nino4_{t-1}, Nino4_{t-2}, Nino4_{t-3}, Nino4_{t-4}, Nino4_{t-5}, Nino4_{t-6}, Nino4_{t-7}, \dots \\
Nino4_t = & Nino4_{t-8}, Nino4_{t-10}, Nino4_{t-11}, Nino4_{t-12}, \frac{y-10}{y-1} Nino4_t, Nino34_{t-1}, Nino34_{t-2}, Nino34_{t-3}, Nino34_{t-4}, Nino34_{t-5}, Nino34_{t-6}, \dots \\
Nino34_t = & Nino34_{t-7}, Nino34_{t-8}, Nino34_{t-10}, Nino34_{t-11}, Nino34_{t-12}, \frac{y-10}{y-1} Nino34_t, X, Y, Z, t)
\end{aligned}$$

شکل ۵- مدل پیش‌بینی مورد استفاده در این پژوهش

۴-۳-۲- تنظیم و بهینه‌سازی ساختار و مولفه‌های شبکه

در ابتدا و پیش از انجام پیش‌بینی با دو شبکه‌ی عصبی مصنوعی پرسپترون چند لایه و شبکه‌ی باور عمیق، لازم است تا ساختار و مولفه‌های این دو شبکه تنظیم^۱ گردند. منظور از ساختار شبکه، تعداد لایه‌های پنهان و نورون‌هایشان می‌باشد. به این منظور، یک روال دو مرحله‌ای متشکل از چندین گام، مورد استفاده قرار می‌گیرد. در مرحله‌ی اول ضمن در نظر گرفتن یکسری مولفه‌های اولیه، بهترین ساختار شبکه بدست می‌آید. به این منظور ابتدا ساده‌ترین حالت ممکن که شبکه‌ای با یک لایه‌ی پنهان و یک نورون می‌باشد، در نظر گرفته می‌شود. سپس با افزایش تعداد نورون‌ها، تلاش می‌شود تا دقت مدل بهبود یابد. روند افزایش تعداد نورون‌ها، تا آن جایی که دیگر تغییری در دقت شبکه حاصل نشود، ادامه می‌یابد. بعد از آن یک لایه‌ی پنهان جدید متشکل از یک نورون، اضافه می‌شود. مجدداً تعداد نورون‌های لایه‌ی جدید به هدف بهبود شبکه افزایش می‌یابد. بعد از توقف روند بهبود دقت شبکه، مجدداً به لایه‌ی پنهان قبلی برگشته و متناسب با تغییرات ایجاد شده، تعداد نورون‌ها کم و زیاد می‌شود تا مقدار بهینه بدست آید. روند جابه‌جایی بین لایه‌ها تا زمانی که دیگر تغییری در نتایج حاصل نشود، ادامه می‌یابد.

^۱ tuning

بعد از توقف روند بهبود دقت شبکه، مجدداً لایه‌ای جدید به شبکه اضافه شده و همان روند قبلی تکرار می‌شود. بعد از آنکه این اطمینان حاصل گردید که شبکه‌ی مورد نظر از بهترین ساختار ممکن برخوردار است، مرحله‌ی دوم آغاز می‌شود. در این مرحله تلاش می‌شود تا بهترین مقادیر برای مولفه‌های شبکه‌ی طراحی شده، بدست آید. به این منظور چندین گام طی خواهد شد. در هر گام با ثابت نگه داشتن سایر مولفه‌ها، مولفه‌ی مورد نظر تنظیم می‌گردد. در ادامه این گام‌ها معرفی می‌شود. در گام اول، به سراغ تعیین تابع فعالیت می‌رویم. این تابع مجموعه‌ی ورودی‌های یک نورون را به یک خروجی واحد تبدیل می‌کند [۶۲]. در صورتی که تابع فعالیت متعلق به لایه (یا لایه‌های) میانی باشد، این خروجی به عنوان ورودی به لایه‌ی میانی بعدی داده خواهد شد. اما اگر تابع فعالیت مربوط به لایه‌ی پایانی باشد، خروجی آن، خروجی اصلی شبکه است. انواع مختلفی از تابع فعالیت وجود دارد که در حالت کلی به دو دسته‌ی تابع فعالیت مربوط به لایه (یا لایه‌های پنهان) و تابع فعالیت مربوط به لایه‌ی خروجی تقسیم می‌شود [۶۳]. در این تحقیق برای لایه‌های میانی سه تابع $\tanh$ ، sigmoid و برای لایه‌ی خروجی، دو تابع softmax و identity در نظر گرفته شده است [۶۳]. در شبکه‌های یادگیری عمیق، معمولاً از تابع فعالیت relu برای لایه‌های میانی استفاده می‌شود زیرا دو تابع دیگر سبب ایجاد خطای "گرادیان محو شونده" و در نتیجه سخت‌تر

در گام ششم، شیوه‌ی به‌هنگام کردن وزن‌ها تنظیم می‌شود. هدف از به‌هنگام‌سازی وزن‌ها، کاهش اختلاف بین مقدار واقعی و پیش‌بینی شده می‌باشد. تا به امروز روش‌های بسیاری به این منظور معرفی شده است از جمله ADADelta، NESTEROV، ADAM، ADAGRAD و RMSPROP. انتخاب یک روش درست می‌تواند سرعت یادگیری شبکه را افزایش دهد.

در گام هفتم، الگوریتم بهینه‌سازی شبکه تعیین می‌گردد. در واقع این الگوریتم نحوه‌ی به روز رسانی شبکه با توجه به میزان گرادیان را مشخص می‌کند. یکی از متداول‌ترین این الگوریتم‌ها gradient descent stochastic یا همان SGD می‌باشد. البته انواع دیگری از این الگوریتم مانند conjugate gradient و LBFGS نیز وجود دارد. در اکثر موارد از ترکیب SGD و روش به روز رسانی RMSPROP به عنوان یک پیش فرض بسیار خوب استفاده می‌شود.

۴-۳-۳- شبکه‌ی عصبی کم عمق

به منظور مدل‌سازی بارش با استفاده از شبکه‌ی عصبی کم عمق، یک شبکه‌ی پرسپترون چند لایه در قالب دو مرحله‌ی ذکر شده، تنظیم و بهینه گردید. جدول (۳) گام‌های طی شده جهت تنظیم و بهینه‌سازی ساختار و مولفه‌های شبکه را نشان می‌دهد.

ساختاری متشکل از یک لایه‌ی ورودی، سه لایه‌ی پنهان و یک لایه‌ی خروجی به عنوان ساختار بهینه تعیین گردید. این لایه‌ها به ترتیب از ۱۳۴، ۷، ۳، ۸ و ۵ نورون تشکیل شده اند. بعد از تعیین ساختار بهینه، مولفه‌های شبکه‌ی عصبی کم عمق متناسب با ساختار ایجاد شده، تنظیم گردید. در نهایت بعد از طی چندین گام، شبکه‌ای با تابع فعالیت relu در لایه‌های پنهان و softmax در لایه‌ی خروجی و نیز نرخ یادگیری $1e-1$ تنظیم گردید. همچنین تعداد تکرار ۲۸ به همراه روش وزن‌دهی اولیه XAVIER در لایه‌ی پنهان اول و NORMALIZATION در سایر لایه‌ها، مناسب تشخیص داده شد. در نهایت تابع به هنگام سازی RMSPROP، تابع هزینه MCXENT و الگوریتم بهینه‌سازی LBFGS به عنوان توابع و الگوریتم‌های مناسب انتخاب گردید.

با استفاده از نتایج پیش‌بینی حاصل شده توسط مدل شبکه‌ی عصبی کم‌عمیق، نقشه‌ی پیش‌بینی بارش ماهانه‌ی سال ۲۰۱۴ تهیه می‌گردد. نقشه‌ی پیش‌بینی بارش دوازده ماه در شکل (۶) نمایش داده شده است.

شدن یادگیری شبکه می‌شوند. همچنین با توجه به آن که مساله‌ی پیش رو از نوع طبقه‌بندی می‌باشد و نهایتاً با کلاس‌های مختلف سر و کار داریم، تابع فعالیت softmax برای لایه‌ی خروجی، مناسب تشخیص داده شد.

در گام دوم، اقدام به تغییر نرخ یادگیری شبکه عصبی کم عمق می‌شود. اگر مقدار کمی به نرخ یادگیری اختصاص داده شود، شبکه کند عمل خواهد کرد. در مقابل نرخ یادگیری زیاد، سبب ایجاد نوسان و ناپایداری در شبکه می‌گردد. معمولاً نرخ یادگیری در بازه‌ای بین $1e-1$ و $1e-6$ تغییر می‌کند.


در گام سوم، روش وزن‌دهی اولیه تغییر می‌یابد. روش‌های مختلفی جهت اختصاص وزن‌های اولیه و تصادفی به شبکه‌ی طراحی شده وجود دارد. از جمله XAVIER، UNIFORM، RELU، NORMALIZE و DISTRIBUTED. با انتخاب یک روش مناسب می‌توان دقت شبکه را افزایش داد.

در گام چهارم، تعداد تکرارها هدف تغییر و بهینه‌سازی قرار می‌گیرد. در حالت کلی، افزایش دفعات تکرار سبب بالا رفتن دقت شبکه می‌شود. علت این افزایش، بالاتر رفتن درجه‌ی آزادی شبکه و در نتیجه توانایی بیشتر آن در تشخیص نویزها و مثال‌های نادر است. در عین حال تکرار بیش از حد می‌تواند دقت پیش‌بینی را برخلاف دقت آموزش کاهش دهد. علت پدید آمدن چنین شرایطی را می‌تواند در مسئله‌ی Overfitting جست و جو کرد [۶۴]. در واقع با افزایش بیش از حد مراحل تکرار، شبکه شروع به حفظ کردن داده‌های آموزشی می‌کند که در نتیجه آن دقت آموزش بالاتر می‌رود. اما در عین حال شبکه در تشخیص نمونه‌های جدید و پیش‌بینی درست، موفق عمل نمی‌کند. به منظور تعیین مقدار بهینه، با گام‌هایی پنج تایی، اقدام به افزایش تعداد تکرارها می‌شود. این روند افزایشی تا آن جایی که دیگر بهبودی در دقت شبکه حاصل نشود، ادامه می‌یابد. سپس همسایگی آخرین تکرار بهینه‌ی بدست آمده به منظور یافتن مقدار بهینه‌ی نهایی، تا شعاع ۴ گام، ارزیابی می‌شود.

در گام پنجم، تابع هزینه تنظیم می‌شود. با کمک تابع هزینه می‌توان دریافت که کدام پاسخ به جواب بهینه نزدیک‌تر است. دو نوع تابع هزینه وجود دارد. MSE و MCXENT. تابع اول میانگین مربع خطاهاست که مناسب ارزیابی دقت در مسائلی است که خروجی مقدار حقیقی می‌باشد. اما تابع دوم در شرایطی که با طبقه‌بندی داده‌ها سر و کار داشته باشیم، کاربرد پیدا می‌کند. از آن جایی که مساله‌ی پیش رو از نوع طبقه‌بندی می‌باشد، همواره از تابع هزینه MCXENT استفاده می‌شود.

جدول ۳- مراحل طی شده جهت تنظیم و بهینه‌سازی شبکه‌ی عصبی کم‌عمق

نتایج (دقت پیش‌بینی)		الگوریتم بهینه سازی	تابع به‌هنگام- سازی	تابع هزینه	تعداد دوره	روش‌های وزن‌دهی اولیه	نرخ یادگیری	توابع فعالیت	تعداد نورون‌ها h ₁ ,...,h _n	تعداد لایه‌های پنهان	پارامترهای شبکه عصبی پرسپترون	
Acc	PREC	optimization algorithm	Updater	Loss Function	Iteration	Weight Initialization	Learning Rate	Activity Function	Neurons	Hidden Unit	نام انگلیسی	
۰/۲۱	۰/۲	SGD	RMSPROP	MCXENT	۵	XAVIER	1e-3	tanh	۱	۱	گام اول	مرحله- ی اول
۰/۱۹	۰/۲۱							softmax				
۰/۲۲	۰/۲۲							tanh				
۰/۲۵	۰/۲۷	SGD	RMSPROP	MCXENT	۵	XAVIER	1e-3	softmax	۳, ۲	۲	گام دوم	
۰/۲۷	۰/۲۵							tanh				
۰/۲۳	۰/۳۱							softmax				
۰/۳	۰/۲۶	SGD	RMSPROP	MCXENT	۵	XAVIER	1e-3	relu	۷, ۳, ۸	۳	گام اول	مرحله- ی دوم
۰/۲۵	۰/۳۱							softmax				
۰/۳۲	۰/۲۸							relu				
۰/۳۲	۰/۲۶	SGD	RMSPROP	MCXENT	۵	XAVIER	1e-1	softmax	۷, ۳, ۸	۳	گام دوم	
۰/۳	۰/۲۸							relu				
۰/۳۳	۰/۳							softmax				
۰/۳۷	۰/۳۳	SGD	RMSPROP	MCXENT	۲۸	XAVIER	1e-1	relu	۷, ۳, ۸	۳	گام چهارم	
۰/۳۲	۰/۳۲					NORMALIZATION		softmax				
۰/۳۲	۰/۳۲					XAVIER		softmax				
۰/۳۲	۰/۳۲	SGD	RMSPROP	MCXENT	۲۸	XAVIER	1e-1	relu	۷, ۳, ۸	۳	گام پنجم	
۰/۳۲	۰/۳۲					NORMALIZATION		softmax				
۰/۳۷	۰/۳۳					XAVIER		relu				
۰/۳۲	۰/۳۲	SGD	RMSPROP	MCXENT	۲۸	NORMALIZATION	1e-1	softmax	۷, ۳, ۸	۳	گام ششم	
۰/۳۲	۰/۳۲					XAVIER		relu				
۰/۶۷	۰/۶۹					LBFGS		RMSPROP				
۰/۶۷	۰/۶۹	NORMALIZATION	softmax									
۰/۶۷	۰/۶۹	NORMALIZATION	softmax									



شکل ۶- نقشه‌ی پیش‌بینی بارش ماهانه‌ی منطقه‌ی شمال غربی ایران در سال ۲۰۱۴ با استفاده از اطلاعات بدست آمده از مدل شبکه‌ی عصبی کم‌عمق

۴-۳-۴- شبکه‌ی باور عمیق

جهت مدل‌سازی بارش با استفاده از شبکه‌ی باور عمیق، ساختار و مولفه‌های شبکه متناسب با توضیحات ارائه‌شده، تنظیم و بهینه‌سازی گردید. به این منظور، چندین گام در قالب دو مرحله‌ی اصلی که در جدول (۴) قابل مشاهده می‌باشد، طی شد که در نتیجه‌ی آن، شبکه‌ای متشکل از ۴ ماشین بولتزمن محدود شده مناسب تشخیص داده شد.

این شبکه از لحاظ ظاهری مشابه یک شبکه‌ی پرسپترون با ۳ لایه‌ی پنهان است که به ترتیب دارای ۱۹، ۹ و ۱۹ نورون می‌باشد. بعد از تعیین یک ساختار بهینه،


نوبت به تنظیم مولفه‌های شبکه‌ی باور عمیق می‌رسد. در نهایت بعد از طی چندین گام، شبکه‌ای با تابع فعالیت relu در لایه‌های پنهان و softmax در لایه‌ی خروجی تنظیم گردید. همچنین تعداد تکرار ۱۰ به همراه روش وزن‌دهی اولیه Uniform و نیز نرخ یادگیری $1e-1$ مناسب تشخیص داده شد. و در نهایت تابع به هنگام سازی RMSPROP، تابع هزینه MCXENT و الگوریتم بهینه‌سازی SGD تعیین گردید. جدول (۴)، ساختار و مولفه‌های شبکه‌ی بهینه‌سازی شده و مقدار هر یک از معیارهای ارزیابی دقت شبکه را، نمایش می‌دهد.

جدول ۴- مراحل طی شده جهت تنظیم و بهینه‌سازی شبکه‌ی باور عمیق

پارامترهای شبکه باور عمیق		تعداد لایه‌های پنهان	تعداد نورون‌ها $h_1, \dots, h_n$	توابع فعالیت	نرخ یادگیری	روش‌های وزن‌دهی اولیه	تعداد دوره	تابع هزینه	تابع به‌هنگام‌سازی	الگوریتم بهینه‌سازی	نتایج (دقت پیش‌بینی)	
نام تکلیبی		Hidden Unit	Neurons	Activity Function	Learning Rate	Weight Initialization	Iteration	Loss Function	Updater	optimization algorithm	PREC	Acc Recall
مرحله اول	گام اول	۱	۳	relu	$1e-3$	XAVIER	۵	MCXENT	RMSPROP	SGD	۰/۲۹	۰/۲۶
				softmax							۰/۳۲	۰/۳۵
	گام دوم	۲	۳, ۳	relu	$1e-3$	XAVIER	۵	MCXENT	RMSPROP	SGD	۰/۱۵	۰/۲
				softmax							۰/۲۳	۰/۵۳
	گام سوم	۳	۱۹, ۹, ۱۹	relu	$1e-3$	XAVIER	۵	MCXENT	RMSPROP	SGD	۰/۱۶	۰/۲۶
				softmax							۰/۱۸	۰/۱۹
مرحله دوم	گام اول	۳	۱۹, ۹, ۱۹	relu	$1e-3$	XAVIER	۵	MCXENT	RMSPROP	SGD	۰/۱۶	۰/۲۶
				softmax							۰/۱۸	۰/۱۹
	گام دوم	۳	۱۹, ۹, ۱۹	relu	$1e-1$	XAVIER	۵	MCXENT	RMSPROP	SGD	۰/۳۵	۰/۱۸
				softmax							۰/۳۰	۰/۲۶
	گام سوم	۳	۱۹, ۹, ۱۹	relu	$1e-1$	UNIFORM	۵	MCXENT	RMSPROP	SGD	۰/۶۴	۰/۶۵
				softmax							۰/۶۹	۰/۷۶
	گام چهارم	۳	۱۹, ۹, ۱۹	relu	$1e-1$	UNIFORM	۱۰	MCXENT	RMSPROP	SGD	۰/۶۹	۰/۷۱
				softmax							۰/۷۴	۰/۸
	گام پنجم	۳	۱۹, ۹, ۱۹	relu	$1e-1$	UNIFORM	۱۰	MCXENT	RMSPROP	SGD	۰/۶۹	۰/۷۱
				softmax							۰/۷۴	۰/۸
	گام ششم	۳	۱۹, ۹, ۱۹	relu	$1e-1$	UNIFORM	۱۰	MCXENT	RMSPROP	SGD	۰/۶۹	۰/۷۱
				softmax							۰/۷۴	۰/۸
	گام هفتم	۳	۱۹, ۹, ۱۹	relu	$1e-1$	UNIFORM	۱۰	MCXENT	RMSPROP	SGD	۰/۶۹	۰/۷۱
				softmax							۰/۷۴	۰/۸

۲۰۱۴ تهیه می‌گردد. نقشه‌ی پیش‌بینی بارش دوازده ماه در شکل (۷) نمایش داده شده است.

با استفاده از نتایج پیش‌بینی حاصل شده توسط شبکه‌ی باور عمیق، نقشه‌ی پیش‌بینی بارش ماهانه‌ی سال



شکل ۷- نقشه‌ی پیش‌بینی بارش ماهانه‌ی منطقه‌ی شمال غربی ایران در سال ۲۰۱۴ با استفاده از اطلاعات بدست آمده از مدل شبکه‌ی باور عمیق

۴-۴- ارزیابی نتایج


جهت ارزیابی دقت دو شبکه‌ی عصبی کم عمق و شبکه‌ی باور عمیق، داده‌های سال ۱۹۵۱ تا ۲۰۱۳ به عنوان پارامتر ورودی به این دو شبکه داده شد (شکل ۵). به منظور بررسی نتایج این دو شبکه، یک مقایسه‌ی ماه به ماه و ایستگاه به ایستگاه بین مقادیر بارش به وقوع پیوسته و بارش پیش‌بینی شده توسط این دو مدل صورت گرفت (شکل ۸ و ۹). همان طور که از مقایسه‌ی شکل‌های (۸) و (۹) مشخص است، شبکه‌ی باور عمیق در مقایسه با شبکه‌ی عصبی کم عمق، از دقت بهتری در پیش‌بینی نتایج برخوردار است. داده‌های هواشناسی خصوصا داده‌های بارش، به صورت طبیعی دارای توزیع نامتوازن می‌باشند. به این معنی که

توزیع میزان بارش حول مقداری خاص، بیشتر از سایرین می‌باشد. همان طور که از شکل‌های (۸) و (۹) مشخص است، خط پیوسته نشان دهنده‌ی میزان بارش رخ داده در سطح منطقه‌ی مطالعاتی است. این خط نشان می‌دهد که بارش بیشتر ایستگاه‌ها، تقریباً در تمامی ماه‌های سال، مقداری کمتر از ۸۰ درصد میانگین بارش و یا بیش‌تر از ۱۲۰ درصد این میانگین را به خود اختصاص می‌دهد. از این رو انتظار میرفت که بارش پیش‌بینی شده نیز بیشتر در این دو کلاس واقع شود.

شبکه‌ی عصبی مصنوعی کم عمق تحت تاثیر الگوی غالب بارش در منطقه‌ی مطالعاتی، بارش تقریباً تمامی ایستگاه‌ها در ماه‌های فوریه، مارس، آوریل، می، جون، جولای، آگوست، سپتامبر و دسامبر را کمتر از ۸۰ درصد

در مقابل مشاهده می‌شود که شبکه‌ی باور عمیق با وجود الگوی غالب بارش در سطح منطقه‌ی مطالعاتی، توانسته است میزان بارش‌هایی با پراکندگی کمتر در این ناحیه را نیز به خوبی پیش‌بینی کند (شکل ۹). علت توانایی بیشتر این شبکه در پیش‌بینی الگوهای بارشی با پراکندگی کمتر و در نتیجه مدل‌سازی بهتر پیچیدگی‌های مساله را می‌توان در تعداد لایه‌های بیشتر و شیوه‌ی آموزش بهینه‌تر آن جست و جو کرد.


میانگین منطقه و بارش تمامی ایستگاه‌ها در ماه نوامبر را بیش از ۱۲۰ درصد میانگین بارش پیش‌بینی کرده است (شکل ۸). علت این پیش‌بینی ضعیف را می‌توان در تاثیر پذیری زیاد شبکه‌ی عصبی مصنوعی کم عمق از پارامتر پیش‌بینی یا همان بارش به وقوع پیوسته با پراکندگی بیشتر در مرحله‌ی آموزش و در نتیجه عدم توانایی این شبکه در پیش‌بینی سایر کلاس‌ها دانست.



شکل ۸- مقایسه ماه به ماه و ایستگاه به ایستگاه بارش به وقوع پیوسته و بارش پیش‌بینی شده توسط شبکه‌ی عصبی مصنوعی کم عمق

شبکه‌ی عصبی کم عمق (شکل ۳-۸)، شبکه‌ی باور عمیق، بارش بیشتر ایستگاه‌ها را در کلاس درست پیش‌بینی کرده است (شکل ۳-۹).

برای نمونه در ماه مارس، بارش به وقوع پیوسته‌ی بیشتر ایستگاه‌ها، در کلاس «چهار» قرار دارد. با وجود پیش‌بینی کلاس صفر برای تمامی ایستگاه‌ها توسط



شکل ۹- مقایسه ماه به ماه و ایستگاه به ایستگاه بارش به وقوع پیوسته و بارش پیش‌بینی شده توسط شبکه‌ی باور عمیق

شکل (۴-۹) مشاهده می‌شود که شبکه‌ی باور عمیق نوسانات به وقوع پیوسته در میزان بارش ایستگاه‌های منطقه‌ی مطالعاتی را به خوبی نشان داده است.

در ماه نوامبر نیز با وجود آنکه شبکه‌ی عصبی مصنوعی کم عمق، بارش تمامی ایستگاه‌ها در سطح منطقه‌ی مطالعاتی را به اشتباه در کلاس «چهار» پیش‌بینی کرده (شکل ۱۱-۸)، شبکه‌ی باور عمیق نوسانات بارشی منطقه را به شکل بهتری پیش‌بینی نموده است (شکل ۱۱-۹).

همچنین به منظور انجام یک ارزیابی کلی‌تر از دقت نتایج حاصل از دو شبکه، با کمک اطلاعات موجود از بارش و همچنین نقشه‌های پیش‌بینی، کلاس متعلق به میانگین میزان بارش ماهانه‌ی به وقوع پیوسته و همچنین بارش پیش‌بینی شده توسط دو مدل در سطح منطقه‌ی

همچنین در ماه دسامبر، با وجود نوسانات بسیار بارش در سطح منطقه، بارش پیش‌بینی شده توسط شبکه‌ی عصبی مصنوعی کم عمق، برای تمامی ایستگاه‌ها کلاس صفر می‌باشد (شکل ۱۲-۸). اما در شکل (۱۲-۹) مشاهده می‌شود که شبکه‌ی باور عمیق به خوبی نوسانات را پوشش داده است. در ماه فوریه نیز پیشرفت قابل قبولی در پیش‌بینی بارش منطقه توسط شبکه‌ی باور عمیق (شکل ۲-۹) در مقایسه با شبکه‌ی عصبی مصنوعی کم عمق (شکل ۲-۸) ملاحظه می‌شود. همچنین در پیش‌بینی بارش ایستگاه‌ها در ماه آپریل، شبکه‌ی باور عمیق عملکرد بهتری از خود نشان داده است. شبکه‌ی عصبی مصنوعی کم عمق بارش این ماه در تمامی ایستگاه‌ها را، با وجود نوسانات بسیار، تقریباً «صفر» پیش‌بینی کرده است (شکل ۴-۸). اما در

است. بر اساس اطلاعات استخراج شده از نقشه‌های وضع موجود، بیشترین میزان بارش در سطح منطقه، در دو ماه اسفند و فروردین و همچنین سه ماهه‌ی پاییز به وقوع می‌پیوندد که دقیقاً مطابق با واقعیت موجود می‌باشد.

مطالعاتی، محاسبه شد (جدول ۵). با کمک محاسبه‌ی میانگین، امکان انجام یک ارزیابی دقیق و سریع از مشاهدات حاصل از نقشه‌ها فراهم می‌گردد. همان طور که از جدول (۵) مشخص است، شبکه‌ی باور عمیق در ۱۰ ماه موفق به انجام پیش‌بینی صحیح و منطبق با واقعیت شده

جدول ۵- نتایج ارزیابی نقشه‌های وضعیت موجود و نقشه‌های پیش‌بینی حاصل از نتایج دو شبکه‌ی عصبی مصنوعی کم عمق و شبکه‌ی باور عمیق

مشخصات ماه مورد بررسی			برآیند میزان بارش به وقوع پیوسته در سطح منطقه مطالعاتی		برآیند میزان بارش پیش‌بینی شده با کمک شبکه عصبی مصنوعی کم عمق		برآیند میزان بارش پیش‌بینی شده با کمک شبکه باور عمیق	
شماره ماه (میلادی)	نام ماه		شماره کلاس	عنوان کلاس	شماره کلاس	عنوان کلاس	شماره کلاس	عنوان کلاس
	میلادی	خورشیدی						
۱	ژانویه	دی - بهمن	۱	بین ۸۰ تا ۹۰٪ میانگین بارش	۱	بین ۸۰ تا ۹۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش
۲	فوریه	بهمن - اسفند	۰	کمتر از ۸۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش
۳	مارس	اسفند - فروردین	۴	بیش از ۱۲۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش	۴	بیش از ۱۲۰٪ میانگین بارش
۴	آوریل	فروردین - اردیبهشت	۲	بین ۹۰ تا ۱۱۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش	۲	بین ۹۰ تا ۱۱۰٪ میانگین بارش
۵	می	اردیبهشت - خرداد	۲	بین ۹۰ تا ۱۱۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش
۶	جون	خرداد - تیر	۰	کمتر از ۸۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش
۷	جولای	تیر - مرداد	۰	کمتر از ۸۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش
۸	آگوست	مرداد - شهریور	۰	کمتر از ۸۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش
۹	سپتامبر	شهریور - مهر	۰	کمتر از ۸۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش
۱۰	اکتبر	مهر - آبان	۴	بیش از ۱۲۰٪ میانگین بارش	۴	بیش از ۱۲۰٪ میانگین بارش	۴	بیش از ۱۲۰٪ میانگین بارش
۱۱	نوامبر	آبان - آذر	۴	بیش از ۱۲۰٪ میانگین بارش	۴	بیش از ۱۲۰٪ میانگین بارش	۴	بیش از ۱۲۰٪ میانگین بارش
۱۲	دسامبر	آذر - دی	۲	بین ۹۰ تا ۱۱۰٪ میانگین بارش	۰	کمتر از ۸۰٪ میانگین بارش	۲	بین ۹۰ تا ۱۱۰٪ میانگین بارش

بهترین دقت می‌باشد. در جدول (۶) نتایج ارزیابی دقت دو شبکه نشان داده شده است. همان طور که از نتایج پیداست، شبکه‌ی باور عمیق در حل مساله‌ی پیش‌بینی بارش و نیز در مواجهه با کلان داده‌های مکانی- زمانی موفق‌تر عمل کرده است.

به علاوه، به منظور ارزیابی دقت نتایج حاصل از دو مدل شبکه‌ی عصبی کم‌عمق و شبکه‌ی باور عمیق، از چهار معیار Accuracy، Precision، Recall و F1 score جهت ارزیابی استفاده شد. هر یک از این معیارها مقادیری بین ۰ و ۱ را به خود اختصاص می‌دهند که عدد ۱ بیانگر

جدول ۶- نتایج ارزیابی شبکه‌های عصبی مصنوعی کم عمق و شبکه‌ی باور عمیق

روش	تعداد موارد درست پیش‌بینی شده	تعداد موارد اشتباه پیش‌بینی شده	Accuracy	Precision	Recall	F1 score
شبکه‌ی عصبی کم‌عمق	۵۶۷	۲۷۳	۰/۶۷	۰/۶۹	۰/۷	۰/۶۹
شبکه‌ی باور عمیق	۵۹۶	۲۴۴	۰/۷۱	۰/۶۹	۰/۸	۰/۷۴

هواشناسی، داده‌های بزرگ مقیاس اقلیمی و داده‌های توپولوژیکی جمع‌آوری شد. سپس ساختار و مولفه‌های شبکه‌ی عصبی مصنوعی کم عمق و شبکه‌ی باور عمیق مورد استفاده در این پژوهش، تنظیم و بهینه‌سازی گردید. سپس مراحل آموزش، تست و پیش‌بینی، با استفاده از هر از این شبکه صورت پذیرفت. سپس با استفاده از نتایج حاصل از این دو شبکه، نقشه‌های پیش‌بینی بارش ماهانه تهیه شد. جهت ارزیابی دقت دو شبکه‌ی عصبی مصنوعی کم عمق و شبکه‌ی باور عمیق، از چهار معیار Accuracy، Precision، Recall و F1 score بهره برده شد. نتایج

۵- جمع‌بندی و پیشنهادات

پیش‌بینی بلند مدت بارش، نقش مهمی در مدیریت منابع آبی کشور ایران ایفا می‌کند. با توجه به اینکه پدیده‌ی بارش تابع عوامل مختلفی می‌باشد، پیش‌بینی آن از پیچیدگی‌های بسیاری برخوردار است. در این تحقیق به منظور تهیه‌ی نقشه‌های توزیع مکانی- زمانی بارش ماهانه در منطقه‌ی شمال غربی ایران، از روش‌های یادگیری ماشین شبکه‌ی عصبی مصنوعی کم عمق و شبکه‌ی مبتنی بر یادگیری عمیق استفاده شد. به این منظور ابتدا داده‌های ماهانه‌ی مورد نیاز در سه دسته‌ی داده‌های محیطی و

بدست آمده نشان دهنده‌ی موفقیت شبکه‌های مبتنی بر یادگیری عمیق، در مواجهه با کلان داده‌های مکانی-زمانی، نسبت به شبکه‌های عصبی مصنوعی کم عمق می‌باشد. همچنین مقایسه‌ی مقدار بارش ماهانه‌ی به وقوع پیوسته‌ی با میزان بارش ماهانه‌ی پیش‌بینی شده توسط شبکه‌ی عصبی کم عمق و شبکه‌ی باور عمیق، برای هر یک از ایستگاه‌های منطقه‌ی مطالعاتی، نشان دهنده‌ی توانایی بیشتر شبکه‌ی باور عمیق در پیش‌بینی بارش ماهانه می‌باشد.

به عنوان کارهای آینده قصد داریم تا از الگوریتم‌های بهینه‌سازی جهت انتخاب پارامترهای ورودی بهینه و انتخاب موثرترین آن‌ها بهره‌بریم. پیش‌بینی می‌شود که استفاده از این الگوریتم، تاثیر بسزایی در بالا بردن دقت نتایج داشته باشد. همچنین از آن جایی که در مبحث

پیش‌بینی‌های آب و هوایی و از جمله پیش‌بینی بارش با کلان داده‌های مکانی-زمانی رو به رو هستیم، زمان پردازش طولانی می‌باشد. از این رو قصد داریم در پژوهش‌های بعدی به منظور کاهش زمان پردازش، از واحد پردازش گرافیکی (GPU) استفاده کنیم. همچنین همان طور که پیش‌تر نیز گفته شد، داده‌های هواشناسی خصوصاً بارش، به صورت طبیعی دارای توزیع نامتوازن می‌باشند. در علم داده، برای حل مشکل این نوع از داده‌ها، راه‌حلهایی پیش‌بینی شده است. یکی از اهداف تحقیقات بعدی می‌تواند حل مشکل داده‌های نامتوازن و بهبود دقت نتایج تمامی کلاس‌ها می‌باشد.

مراجع

- [1] Wescoat Jr, J.L. and G.F. White, Water for life: Water management and environmental policy. 2003: Cambridge University Press.
- [2] Foltz, R.C., Iran's water crisis: cultural, political, and ethical dimensions. Journal of Agricultural and Environmental Ethics, 2002. 15(4): p. 357-380.
- [3] Tabari, H. and P.H. Talaee, Temporal variability of precipitation over Iran: 1966–2005. Journal of Hydrology, 2011. 396(3): p. 313-320.
- [4] Karim Khodaei, A.S., Ebrahim Amiri, Kazem Shahroudi, Factors contributing to the intensification of floods and damages in Kahnouj, in The 1st Iranian National Conference on Applied Research in Water Resource. 2010: Kermanshah.
- [5] Lorenc, A.C., Analysis methods for numerical weather prediction. Quarterly Journal of the Royal Meteorological Society, 1986. 112(474): p. 1177-1194.
- [6] Wilks, D.S., Statistical methods in the atmospheric sciences. Vol. 100. 2011: Academic press.
- [7] Holtslag, A., E. De Bruijn, and H. Pan, A high resolution air mass transformation model for short-range weather forecasting. Monthly Weather Review, 1990. 118(8): p. 1561-1575.
- [8] Sutcliffe, R., Reviews of modern meteorology—6. Principles of synoptic weather forecasting. Quarterly Journal of the Royal Meteorological Society, 1952. 78(337): p. 291-320.
- [9] Robert, A., A stable numerical integration scheme for the primitive meteorological equations. Atmosphere-Ocean, 1981. 19(1): p. 35-46.
- [10] Gardner, M.W. and S. Dorling, Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. Atmospheric environment, 1998. 32(14): p. 2627-2636.
- [11] Abbot, J. and J. Marohasy, Input selection and optimisation for monthly rainfall forecasting in Queensland, Australia, using artificial neural networks. Atmospheric Research, 2014. 138: p. 166-178.
- [12] Mohammad Hosein gholizadeh, M.D., Monthly Rainfall Forecasting Using Artificial Neural Network. Physical Geography Research Quarterly, 2010. 71: p. 12.
- [13] Mekanik, F., et al., Multiple regression and Artificial Neural Network for long-term rainfall forecasting using large scale climate modes. Journal of Hydrology, 2013. 503: p. 11-21.
- [14] Fateme Ghas Abadi Farahani, E.F., Shokat Moghimi, Neda majidirad, Prediction of rainfall based on climatic signals with artificial neural network: South of Lake Oroomie, in National Hazard and Environmental Crises. 2013, Kharazmi University: Tehran. p. 9.
- [15] Storr, D. and H. Ferguson, The distribution of precipitation in some mountainous Canadian watersheds. IN: DISTRIBUTION OF PRECIPITATION IN MOUNTAINOUS AREAS, VOLUME II, 1973.
- [16] Linacre, E., Climate data and resources: a reference and guide. 1992: Psychology Press.

- [17] Whitmore, J., The variation of mean annual rainfall with altitude and locality in South Africa, as determined by multiple curvilinear regression analysis. IN: DISTRIBUTION OF PRECIPITATION IN MOUNTAINOUS AREAS, VOLUME I, 1973.
- [18] Luk, K., J. Ball, and A. Sharma, A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. *Journal of Hydrology*, 2000. 227(1): p. 56-65.
- [19] Alijani, P.M.B., Relationship between annually and seasonal precipitation with topographic parameters. *Journal of Applied Researches in Geographical Science*, 2014(13): p. 20.
- [20] Hassan Ali Ghayur, S.A.M., An Spatial Analysis of Elevation - Precipitation Models (Case Study; Iran). *Geographical Research*, 1996. 41(1019-4052): p. 20.
- [21] Majid Rezaei Banafsheh, A.R., Analysis and modeling of rainfall in the catchment area Gharehsou. *Human Sciences MODARES*, 2002. 6: p. 22.
- [22] Matouq, M., et al., The climate change implication on Jordan: A case study using GIS and Artificial Neural Networks for weather forecasting. *Journal of Taibah University for Science*, 2013. 7(2): p. 44-55.
- [23] DIODATO, N., THE INFLUENCE OF TOPOGRAPHIC CO-VARIABLES ON THE SPATIAL VARIABILITY OF PRECIPITATION OVER SMALL REGIONS OF COMPLEX TERRAIN. *INTERNATIONAL JOURNAL OF CLIMATOLOGY*, 2005. 25: p. 13.
- [24] Liu, J.N., et al. Deep Neural Network Based Feature Representation for Weather Forecasting. in *Proceedings on the International Conference on Artificial Intelligence (ICAI)*. 2014. The Steering Committee of The World Congress in Computer Science, Computer Engineering and Applied Computing (WorldComp).
- [25] Dalto, M., Deep neural networks for time series prediction with applications in ultra-short-term wind forecasting. *Rn (Θ1)*. 1: p. 2.
- [26] Sagiroglu, S. and D. Sinanc. Big data: A review. in *Collaboration Technologies and Systems (CTS)*, 2013 International Conference on. 2013. IEEE.
- [27] Manyika, J., et al., Big data: The next frontier for innovation, competition, and productivity. 2011.
- [28] Chen, C.P. and C.-Y. Zhang, Data-intensive applications, challenges, techniques and technologies: A survey on Big Data. *Information Sciences*, 2014. 275: p. 314-347.
- [29] Mai Abdrabo, M.E., Ghada Eltoweel, Sherif Barakat, Enhancing Big Data Value Using Knowledge Discovery Techniques. *I.J. Information Technology and Computer Science*, 2016. 8(8): p. 12.
- [30] Graham, M. and T. Shelton, Geography and the future of big data, big data and the future of geography. *Dialogues in Human Geography*, 2013. 3(3): p. 255-261.
- [31] Zaslavsky, A., C. Perera, and D. Georgakopoulos, Sensing as a service and big data. *arXiv preprint arXiv:1301.0159*, 2013.
- [32] Thornton, P.E., S.W. Running, and M.A. White, Generating surfaces of daily meteorological variables over large regions of complex terrain. *Journal of Hydrology*, 1997. 190(3): p. 214-251.
- [33] Moniruzzaman, A. and S.A. Hossain, Nosql database: New era of databases for big data analytics-classification, characteristics and comparison. *arXiv preprint arXiv:1307.0191*, 2013.
- [34] Han, J., et al. Survey on NoSQL database. in *Pervasive computing and applications (ICPCA)*, 2011 6th international conference on. 2011. IEEE.
- [35] Deka, G.C., A Survey of Cloud Database Systems. *IT Professional*, 2014. 16(2): p. 50-57.
- [36] Hewitt, E., *Cassandra: the definitive guide*. 2010: "O'Reilly Media, Inc."
- [37] Abramova, V. and J. Bernardino. NoSQL databases: MongoDB vs cassandra. in *Proceedings of the International C* Conference on Computer Science and Software Engineering*. 2013. ACM.
- [38] Hagan, M.T., et al., *Neural network design*. Vol. 20. 1996: PWS publishing company Boston.
- [39] Zeinab Ghaemi, M.F., Abbas Ali Mohammadi, An Online Approach for Spatio-Temporal Prediction of Air Pollution in Tehran using Support Vector Machine. *Journal of Geospatial Information Technology*, 2016. 3: p. 23.
- [40] Mao, J. and A.K. Jain, Artificial neural networks for feature extraction and multivariate data projection. *IEEE transactions on neural networks*, 1995. 6(2): p. 296-317.
- [41] Jain, A.K., J. Mao, and K.M. Mohiuddin, Artificial neural networks: A tutorial. *IEEE computer*, 1996. 29(3): p. 31-44.
- [42] Karsoliya, S., Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture. *International Journal of Engineering Trends and Technology*, 2012. 3(6): p. 713-717.

- [43] Goodfellow, I., Y. Bengio, and A. Courville, Deep learning. 2015, 2016.
- [44] Deng, L. and Y. Dong, Foundations and Trends® in Signal Processing. Signal Processing, 2014. 7: p. 3-4.
- [45] Bengio, Y., Learning deep architectures for AI. Foundations and trends® in Machine Learning, 2009. 2(1): p. 1-127.
- [46] Bengio, Y., A. Courville, and P. Vincent, Representation learning: A review and new perspectives. IEEE transactions on pattern analysis and machine intelligence, 2013. 35(8): p. 1798-1828.
- [47] Schmidhuber, J., Deep learning in neural networks: An overview. Neural Networks, 2015. 61: p. 85-117.
- [48] LeCun, Y., Y. Bengio, and G. Hinton, Deep learning. Nature, 2015. 521(7553): p. 436-444.
- [49] Arel, I., D.C. Rose, and T.P. Karnowski, Deep machine learning-a new frontier in artificial intelligence research [research frontier]. IEEE Computational Intelligence Magazine, 2010. 5(4): p. 13-18.
- [50] Keyvanrad, M.A. and M.M. Homayounpour, Deep Belief Network Training Improvement Using Elite Samples Minimizing Free Energy. International Journal of Pattern Recognition and Artificial Intelligence, 2015. 29(05): p. 1551006.
- [51] Glorot, X. and Y. Bengio. Understanding the difficulty of training deep feedforward neural networks. in Aistats. 2010.
- [52] Hinton, G.E., S. Osindero, and Y.-W. Teh, A fast learning algorithm for deep belief nets. Neural computation, 2006. 18(7): p. 1527-1554.
- [53] Batista, G.E., R.C. Prati, and M.C. Monard, A study of the behavior of several methods for balancing machine learning training data. ACM Sigkdd Explorations Newsletter, 2004. 6(1): p. 20-29.
- [54] He, H. and E.A. Garcia, Learning from imbalanced data. IEEE Transactions on knowledge and data engineering, 2009. 21(9): p. 1263-1284.
- [55] Fawcett, T., An introduction to ROC analysis. Pattern recognition letters, 2006. 27(8): p. 861-874.
- [56] Kubat, M. and S. Matwin. Addressing the curse of imbalanced training sets: one-sided selection. in ICML. 1997. Nashville, USA.
- [57] Maimon, O. and L. Rokach, Data mining and knowledge discovery handbook. Vol. 2. 2005: Springer.
- [58] Powers, D.M., Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. Journal of Machine Learning Technologies, 2011. 2(1): p. 26.
- [59] Farajzadeh, M., et al., Meteorological Drought Monitoring based on an efficient index, using Geostatistical analyst in Ghare Aghaj watershed_ Iran, in International Conference of water crisis. 2009: Zabol university.
- [60] Masoudi, M. and S. Hakimi, A new model for vulnerability assessment of drought in Iran using Percent of Normal Precipitation Index (PNPI). Iranian Journal of Science and Technology, 2014. 38(A4): p. 435.
- [61] Dariush Rahimi, S.M., Hamid Barghi, A Review of Drought Severity Using Percent Normal Precipitation Index (Case Study; Sistan Balouchestan). Geography and Environmental Planning, 2009. 20: p. 13.
- [62] Raschka, S. What is the role of the activation function in a neural network? 2015 [cited 2016 Feb 25].
- [63] Srihari, S., Artificial Neural Networks: Introduction. Buffalo. p. 27.
- [64] Reby, D., et al., Artificial neural networks as a classification method in the behavioural sciences. Behavioural processes, 1997. 40(1): p. 35-43.