

بهینه‌سازی شبکه عصبی کانولوشن با الگوریتم حشره آبسوار در پیش‌بینی

وضعیت آب و هوایی

حمیدرضا غفاری^۱، شراره ملبوسی^{۲*}، سمیرا شهرکی^۳

۱- استادیار، دانشگاه آزاد اسلامی واحد فردوس، گروه کامپیوتر، فردوس

۲- دانشجوی دکتری، دانشگاه آزاد اسلامی واحد فردوس، فردوس

۳- دانشجوی دکتری، دانشگاه آزاد اسلامی واحد بیرجند، بیرجند

چکیده

یکی از موضوعات مهم و کاربردی در دنیای امروز، پیش‌بینی وضعیت آب و هوایی است. پیش‌بینی وضعیت آب و هوایی باعث می‌شود تا زیان و خسارات شرایط بحرانی آب و هوایی کاهش داده شود. پیش‌بینی وضعیت آب و هوایی می‌تواند در کاربردهای مانند کشاورزی و حمل و نقل هوایی موثر باشد. برای پیش‌بینی وضعیت آب و هوایی نیاز است که اطلاعات محیطی برای یک دوره مشخص گردآوری شود و سپس این اطلاعات به عنوان ورودی یک سیستم پیش‌بینی استفاده شود. برای پیش‌بینی وضعیت آب و هوایی در بیشتر مطالعات از روشهای رگرسیون استفاده شده است. یکی از روشهای که می‌توان برای یادگیری و پیش‌بینی آب و هوایی از آن استفاده نمود، شبکه‌های یادگیری عمیق و از جمله شبکه عصبی کانولوشن می‌باشد. یکی از چالش‌های مهم شبکه عصبی کانولوشن آن است که انتخاب ویژگی را غیر هوشمندانه و با استفاده از تعدادی عملیات کانولوشن انجام می‌دهد. در این مقاله برای بهبود دادن دقت پیش‌بینی شرایط آب و هوایی توسط شبکه عصبی کانولوشن، یک روش هوش‌گروهی ارائه شده است. در روش پیشنهادی در لایه اول به جای آنکه از عملیات کانولوشن برای انتخاب ویژگی استفاده شود از ترکیب شبکه عصبی چند لایه و الگوریتم حشره آبسوار برای انتخاب ویژگی استفاده می‌شود. انتخاب هوشمندانه ویژگی در لایه اول شبکه کانولوشن، دقت آن را در پیش‌بینی وضعیت آب و هوایی افزایش می‌دهد. ارزیابی‌ها با استفاده از مجموعه داده‌های مرتبط با شرایط آب و هوایی نشان می‌دهد روش پیشنهادی دارای دقت و حساسیتی به ترتیب برابر ۹۶.۳۲٪ و ۹۶.۱۴٪ در پیش‌بینی آب و هوا است. روش پیشنهادی نسبت به شبکه یادگیری عمیق CNN، توانسته دقت پیش‌بینی را در حدود ۸.۳۵٪ افزایش دهد.

کلیدواژه‌ها: پیش‌بینی آب و هوا، شبکه عصبی کانولوشن، انتخاب ویژگی، الگوریتم حشره آبسوار

مقدمه

توسعه، حرکت و روند تحلیل آب و هوای همرفتی شدید را کاوش و ردیابی کنیم [۲].

یک روش برای پیش بینی وضعیت آب و هوایی استفاده از سیستم های هوش مصنوعی^۲ است. سیستم های هوش مصنوعی به کمک مکانیزم یادگیری هوشمندانه ای که دارند می توانند تا حد دقیقی شرایط آب و هوایی را پیش بینی نمایند. امروزه یادگیری ماشین^۳ [۳] و یادگیری عمیق^۴ [۴] به عنوان دو زیر مجموعه از سیستم های هوش مصنوعی در نظر گرفته می شوند و کاربرد زیادی در پیش بینی وضعیت آب و هوایی دارند. به عنوان مهمترین شاخه یادگیری ماشین، یادگیری عمیق در سال های اخیر به سرعت توسعه یافته و در زمینه های مختلف به کار گرفته شده است. یادگیری عمیق توجه گسترده بسیاری از پژوهشگران بخصوص در حوزه های پیش بینی را به خود جلب کرده است و استفاده از این روشها سابقه توسعه طولانی دارد. امروزه، یادگیری عمیق به طور فزاینده ای تکامل پیدا کرده است.

مفهوم یادگیری عمیق اولین بار در سال ۲۰۰۶ توسط هینتون^۵ و همکاران از دانشگاه تورنتو ارائه شد. اصل یادگیری عمیق شبیه به فعالیت مغز است و به رایانه اجازه می دهد تا بر اساس داده ها و اطلاعاتی که قبلاً دیده است آموزش یابد. یادگیری عمیق یک چارچوب ریاضی برای یادگیری بازنمایی از داده ها است و بر یادگیری از سطوح متوالی^۶ تاکید دارد. این نمایش های سلسله مراتبی تقریباً همیشه از طریق مدل های شبکه عصبی آموخته می شوند. یادگیری در شبکه های عصبی به معنای یافتن مجموعه ای از مقادیر وزن برای تمام لایه های شبکه عصبی^۷ است تا شبکه بتواند به طور دقیق با هر ورودی نمونه با هدف خود مطابقت داشته باشد. در بیشتر موارد از تابع هزینه یا زیان برای اندازه گیری کیفیت خروجی شبکه استفاده می شود و کمینه شدن آن مطلوب است. ورودی تابع هزینه مقدار پیش بینی شده شبکه و مقدار هدف واقعی است و سپس مقدار فاصله محاسبه می شود. از این مقدار فاصله

شرایط آب و هوایی یک موضوع جالب و پیچیده است و از طرفی بسیار متغیر و به عنوان مثال، یک دقیقه آسمان صاف است و دقیقه دیگر ابرهای تیره و بادهای شدید می تواند وضعیت آب و هوایی را تغییر دهد. با تغییر آب و هوا و وقوع طوفان، عابران پیاده در ایستادن مشکل دارند، درختان قطع می شوند و ساختمان های ساده یک طبقه حتی به آوار تبدیل می شوند. بین سال های ۲۰۰۰ تا ۲۰۲۰، تعداد تجمعی بلایا در سراسر جهان به ۱۳۳۴۵ رسید و بیش از ۱.۵ میلیون نفر جان خود را از دست دادند که بیشتر آنها پدیده های جوی بوده است [۱]. هنگامی که شرایط آب و هوای شدید رخ می دهد، بارندگی های شدید کوتاه مدت، رعد و برق، طوفان، گردباد، تگرگ و غیره می تواند به وقوع بپیوندد و اینها همه پدیده های آب و هوایی فاجعه بار هستند. وضعیت آب و هوایی دارای ویژگی های متعدد و ناگهانی و محلی می باشند و می توانند بسیار متغیر باشند. در حال حاضر روش موثری برای تضعیف مصنوعی و پیشگیری از عواقب شرایط آب و هوایی مخرب وجود ندارد، بنابراین پیشگیری باید در اولویت قرار گیرد و ترکیبی از پیشگیری و نجات معمولاً راهکار هوشمند برای اثرات مخرب شرایط آب و هوایی مخاطره آمیز است. تحقیقات نظری در مورد سیستم آب و هوایی هوای همرفتی شدید و بهبود سطح پیش بینی آب و هوای همرفتی شدید بسیار مهم است. با پیشرفت علم و فناوری، رادار و ماهواره ژئوسنکرون^۱ به تدریج در حوزه هواشناسی جدید برای شناسایی و پایش تغییرات آب و هوا اعمال می شوند. امروزه ایستگاه های هواشناسی مختلف از رادار هواشناسی برای پیش بینی وقوع آب و هوای شدید همرفتی و نظارت بر فعالیت های آن استفاده می کنند. از طریق تجزیه و تحلیل تصاویر ابرهای ماهواره ای که به طور مداوم توسط ماهواره های هواشناسی گرفته می شود، می توانیم وقوع،

1 Meteorological satellites

2 Artificial intelligence systems

3 Machine learning

4 Deep learning

5 Hinton

6 Hierarchical representations

7 Neural network

مروری بر پیشینه تحقیق

مطالعه پدیده‌های آب و هوایی به عنوان روشی برای پیش بینی تغییرات آب و هوا از یونان باستان آغاز شده است. ارسطو در کار خود کوشید تا پدیده‌های جوی را به شیوه‌ای فلسفی و نظری توضیح دهد. با این حال، اولین ابزار آب و هوا در پایان قرن شانزدهم اختراع شد. به عنوان نمونه دماسنج در اواخر سال ۱۶۰۰، فشارسنج در سال ۱۶۴۳، و رطوبت‌سنج (برای اندازه‌گیری رطوبت) در اواخر دهه ۱۷۰۰ معرفی شده است. با توسعه ابزارهای بیشتر، اندازه‌گیری آب و هوا دقیق تر و قابل اعتمادتر شد. اختراع تلگراف در سال ۱۸۴۳ امکان انتقال مشاهدات آب و هوا را فراهم کرد. یکی دیگر از جهش‌های بزرگ دیگر در سال ۱۹۵۰ با استفاده از رایانه برای حل معادلات پیچیده ریاضی که رفتار جوی و استفاده از رادارهای داپلر را توصیف می‌کند، انجام شد، که توانایی مشاهده در طوفان‌های شدید رعد و برق و آشکار کردن پدیده‌های رخ داده در داخل را فراهم کرده است [۹]. در یک سری کنفرانس‌های بین‌المللی هواشناسی (شروع در سال ۱۸۷۳)، دستورالعمل‌هایی در مورد جمع‌آوری داده‌های هواشناسی صادر شد که شامل اندازه‌گیری‌ها و همچنین تبادل داده‌ها بین خدمات هواشناسی بود. دستورالعمل‌های اضافی برای تجزیه و تحلیل، پیش‌بینی و ایجاد نقشه این داده‌ها صادر شد. سازمان بین‌المللی هواشناسی در سال ۱۸۷۸ با هدف اصلی بهبود سازمان بین‌المللی هواشناسی ملی تأسیس شد و در سال ۱۹۵۰ به سازمان جهانی هواشناسی تغییر نام داد. استفاده از داده‌های اندازه‌گیری شده و همچنین دستورالعمل‌های جمع‌آوری آن‌ها بر عهده سازمان جهانی هواشناسی^{۱۳} است و طی سال‌ها روش‌ها و سیستم‌های رصد مختلفی مانند هوایی، دریایی، هواپیمابر و زمینی مجهز شده است. سازمان جهانی هواشناسی همچنین علاقه‌مند به سیستم‌هایی است که قادر به بازیابی داده‌های هواشناسی و همچنین مشاهدات محیطی به طور خودکار توسط ایستگاه‌های هواشناسی خودکار^{۱۴} و

به عنوان یک سیگنال بازخورد برای تنظیم دقیق مقدار وزن برای کاهش مثال فعلی استفاده می‌شود. این تنظیم توسط یک برنامه بهینه‌سازی انجام می‌شود که به اصطلاح الگوریتم پس انتشار^۸ را پیاده‌سازی می‌کند و این الگوریتم اصلی یادگیری عمیق است [۲]. یکی از کاربردهای مهم یادگیری عمیق، استفاده از این روش در پیش‌بینی وضعیت آب و هوایی است. از جمله روش‌های که برای پیش‌بینی وضعیت آب و هوایی استفاده شده می‌توان به شبکه‌های عصبی کانولوشن^۹ [۵]، شبکه‌های حافظه محور^{۱۰} [۶]، شبکه‌های عصبی مبتنی بر تئوری بازی^{۱۱} [۷] و شبکه‌های عصبی بازگشتی^{۱۲} [۸] اشاره نمود. یکی از روش‌های کاربردی برای پیش‌بینی شرایط آب و هوایی استفاده از تکنیک یادگیری عمیق شبکه عصبی کانولوشن است. این روش با وجود کاربردهای گسترده در پیش‌بینی دارای چالش‌های است که یکی از آنها انتخاب غیرهوشمندانه ویژگی است. انتخاب ویژگی در این روش یادگیری ماشین با استفاده از عملیات آماری و ضرب کانولوشن ماتریس‌ها و ماسک‌ها انجام می‌شود. یک چالش دیگر این روش آن است که وزن‌های بکار رفته در این شبکه لزوماً بهینه انتخاب نمی‌شوند. برای رفع این چالش‌ها و برای افزایش دقت شبکه عصبی کانولوشن در این مقاله از هوش گروهی استفاده می‌شود. هدف این مقاله ارائه یک سیستم پیش‌بینی وضعیت آب و هوایی بر اساس شبکه عصبی کانولوشن بهینه شده با هوش گروهی است تا خطای پیش‌بینی کاهش داده شود. این مقاله در چند بخش تهیه و تدوین شده است به گونه‌ای که در ادامه در مورد پیشینه تحقیق مطالبی ارائه می‌شود و سپس در بخش سوم روش پیشنهادی ارائه می‌شود. در بخش چهارم مقاله نیز تجزیه و تحلیل روش پیشنهادی ارائه می‌شود و در نهایت در بخش پنجم نیز نتیجه‌گیری و پیشنهادات آتی ارائه می‌شود.

8 Backpropagation algorithm

9 Convolutional neural network

10 Long short-term memory (LSTM)

11 Generative adversarial network (GAN)

12 Recurrent neural network (RNN)

13 World Meteorological Organization (WMO)

14 Automatic Weather Stations (AWS)


علاوه بر این، سازمان جهانی هواشناسی به دسته‌های فوق‌الذکر ایستگاه‌های هواشناسی خودکار، نوع دیگری از ایستگاه‌های هواشناسی را با عنوان ایستگاه هواشناسی خودکار و کم هزینه (AWS-LC) شناسایی می‌کند. از ویژگی‌های این نوع ایستگاه‌ها می‌توان به هزینه کم استفاده و خرید و همچنین مصرف برق کم، قابلیت انتقال اطلاعات به صورت بلادرنگ در نهایت اندازه کوچک و فشرده آنها اشاره کرد. با این حال، به دلیل جهت گیری بازار مصرف کننده و استفاده از الکترونیک و حسگرهای تولید شده توسط فروشندگان بدون تجربه گسترده در اندازه گیری‌های هواشناسی، کیفیت داده‌های جمع آوری شده به سرعت ناشناخته می‌شود و ایستگاه‌های AWS-LC در حال حاضر استاندارد نشده اند [۹]. در شکل (۱)، یک سیستم گردآوری اطلاعات آب و هوایی پیشرفته که دارای انواع حسگرها از جمله دوربین‌ها، پنلهای خورشیدی، رطوبت سنج و دماسنج است نمایش داده شده است. این حسگرها و اشیاء هوشمند در واقع یک ایستگاه آب و هوایی کوچک اما هوشمند را برای گردآوری اطلاعات و ارسال آنها به ایستگاه پایه انجام می‌دهد. این نوع ایستگاه هواشناسی برای مکان یابی و انتخاب ابزار اندازه گیری فردی بهینه شده است [۱۰].

مطالعات نشان می‌دهد که ویژگی‌ها و فاکتورهای پیش بینی نیز باید به درستی انتخاب و به عنوان ورودی پیش بینی در نظر گرفته شوند. تعدادی از فاکتورهای مهم در پیش بینی وضعیت آب و هوایی در یادگیری ماشین در نمودار شکل (۲)، نشان داده شده است.


جمع آوری داده‌ها از یک شبکه از طریق کانال‌های ارتباطی مختلف هستند. پیاده سازی، نصب و راه اندازی ایستگاه‌های هواشناسی خودکار وظیفه‌ای است که به صورت تحلیلی در انتشارات و دستورالعمل‌های سازمان جهانی هواشناسی توضیح داده شده است [۹].

ایستگاه‌های هواشناسی خودکار توسط سازمان جهانی هواشناسی به عنوان یک ایستگاه هواشناسی که مشاهدات در آن انجام می‌شود و به طور خودکار مخابره می‌شود، تعریف می‌شود. یک ایستگاه‌های هواشناسی خودکار به منظور افزایش تعداد و قابلیت اطمینان مشاهدات سطحی استفاده می‌شود. طبق سازمان جهانی هواشناسی، چهار دسته ایستگاه‌های هواشناسی خودکار به شرح ذیل وجود دارد [۹].

- ۱- ایستگاه‌های هواشناسی خودکار سبک برای اندازه گیری چند متغیر (بارش و/یا دمای هوا).
 - ۲- ایستگاه‌های هواشناسی خودکار پایه برای اندازه گیری اندازه گیری‌های اولیه هواشناسی (دمای هوا، رطوبت نسبی، سرعت و جهت باد، بارش و فشار اتمسفر).
 - ۳- ایستگاه‌های هواشناسی خودکار توسعه یافته که تابش خورشیدی، مدت زمان تابش آفتاب، دمای خاک و تبخیر را نیز اندازه گیری می‌کند.
 - ۴- ایستگاه‌های هواشناسی خودکار با اتوماسیون مشاهدات بصری (ارتفاع پایه ابر و آب و هوای فعلی).
- همه دسته‌ها قابلیت ثبت داده‌ها با استفاده از گردآوری کننده اختصاصی و همچنین امکان انتقال داده‌ها با استفاده از روش‌های مختلف را فراهم می‌کنند.



شکل ۱: ساختار AWS-LC یک پیشرفته در گردآوری اطلاعات آب و هوایی [۱۰]



شکل ۲: فاکتورهای مهم در پیش‌بینی وضعیت آب و هوایی در مطالعات مرور شده [۱۱]

عملکرد سیستم، داده‌های آب و هوایی پیش‌بینی شده را با اندازه‌گیری‌های واقعی سنسور از اداره حفاظت محیط زیست و اداره هواشناسی مرکزی ایستگاه رصد مقایسه می‌شود تا دقت پیش‌بینی مورد ارزیابی قرار گرفته شود. نتایج آزمایشات نشان می‌دهد که سیستم پیشنهادی دارای عملکرد قابل اطمینان در نظارت بر آب و هوا و پیش‌بینی خوب برای پیش‌بینی آب و هوا یک روزه از طریق مدل‌های آموزش دیده است.

در پژوهش [۱۴]، یک راه حل با پیچیدگی اندک برای پیش‌بینی وضعیت آب و هوایی در زمان واقعی با حسگرهای تعبیه شده و رگرسیون ارائه دادند. این سیستم متشکل از یک ایستگاه هواشناسی تجاری است که با یک ماژول پردازش داده صنعتی IOT-edge ادغام شده است که جهت و پیش‌بینی سرعت باد را بدون نیاز به اتصال به اینترنت محاسبه می‌کند. الگوریتم یادگیری ماشین رگرسیون به گونه‌ای انتخاب شد که به کمترین مقدار منابع (حافظه، CPU) نیاز داشته باشد و بتواند در یک میکروکنترلر اجرا شود. الگوریتم زیر شرایط و مشخصات خاصی طراحی و کدگذاری شده است. این سیستم بر روی داده‌های آب و هوایی واقعی جمع‌آوری شده از ایستگاه‌های آب و هوایی ساکن و در طول یک سفر آزمایشی آزمایش شده است. کارایی سیستم با معیارهای مختلف خطا ثابت شده است.

در پژوهش [۱۵]، یک الگوریتم جدید یادگیری ماشین برای پیش‌بینی عددی سنسورهای محیط نزدیک زمین پیشنهاد دادند. مدل پیشنهادی جدید با ترکیب یک رمزگذار خودکار انباشته و یک شبکه حافظه بلند مدت و کوتاه مدت پیش‌بینی

برای تشخیص و پیش‌بینی وضعیت آب و هوایی تاکنون مطالعات مختلفی ارائه شده است که بیشتر آنها بر پایه یادگیری ماشین و یادگیری عمیق است که در ادامه تعدادی از آنها مرور می‌شود.

در پژوهش [۱۲]، پیش‌بینی آب و هوا بر اساس اینترنت اشیا با استفاده از شبکه عصبی مصنوعی را پیشنهاد دادند. توپولوژی پیشنهادی یک نظارت آب و هوایی مبتنی بر اینترنت اشیا را با استفاده از شبکه عصبی مصنوعی برای پیش‌بینی فرموله کرد. هدف اصلی این سیستم توپولوژی طراحی شده، نظارت بر پارامترهای آب و هوا مانند دما/رطوبت/فشار/بارندگی و غیره است. اینترنت اشیا برای جمع‌آوری داده‌ها از حسگرها سازماندهی شده و از طریق شبکه Wi-Fi ارتباط برقرار می‌کند. شبکه عصبی برای پیش‌بینی آب و هوا طراحی شده است. تجزیه و تحلیل ثابت می‌کند که معماری پیشنهادی کارایی بهتری در پیش‌بینی آب و هوا نسبت به روش‌های معمولی نشان می‌دهد اما چالش مهم آن عدم بهینه‌سازی وزن و بایاس بکار رفته در شبکه عصبی مصنوعی برای کاهش دادن خطای پیش‌بینی است.

در پژوهش [۱۳]، نظارت و پیش‌بینی آب و هوا در زمان واقعی با استفاده از اتوبوس‌های شهری و یادگیری ماشین را پیشنهاد دادند. در مرحله اول، با توجه به داده‌های سنسور هوا، مدل حافظه کوتاه مدت (LSTM) و مدل پرسپترون چند لایه (MLP) آموزش داده می‌شوند و با استفاده از داده‌های دما، رطوبت و فشار هوا محیط آزمایش، تأیید می‌شوند. در مرحله دوم، مدل یادگیری آموزش دیده برای پیش‌بینی سری زمانی اطلاعات آب و هوا استفاده می‌شود. به منظور ارزیابی

استفاده شود و می تواند بر روی یک رایانه شخصی مستقل اجرا شود.

در پژوهش [۱۸]، یک روش یادگیری عمیق برای پیش بینی بارندگی و وضعیت آب و هوایی ارائه دادند. امروزه از مدل‌های آب و هوایی برای ارزیابی تأثیر تغییرات آب و هوایی بر خطر سیل و وقوع بارش شدید مورد استفاده قرار می‌گیرند. برای بهبود پیش بینی بارش با وضوح بالا در این پژوهش از روش یادگیری عمیق با استفاده از داده های ورودی از یک محصول تجزیه و تحلیل مجدد استفاده شده است. که با خروجی مدل آب و هوا قابل مقایسه است. آنها برای پیش بینی یک مدل رمزگذار رمزگشایی که دارای یک مکانیسم توجه دو بعدی جدید بین لایه های پیوسته متقابل-تکراری است تا به طور موثر فرایندهای آب و هوایی فضایی-زمانی چند مقیاس را مدل سازی کند.

۳- روش پیشنهادی

یک از کاربردهای مهم شبکه عصبی کانولوشن، پیش بینی وضعیت آب و هوایی است و در این حالت ورودی های یادگیری تحویل لایه کانولوشن می شود و سپس توسط لایه های بعدی پردازش می شود تا در نهایت خروجی پیش بینی تولید می شود. چالش های مهم شبکه عصبی کانولوشن برای پیش بینی وضعیت آب و هوایی آن است که این شبکه یادگیری را روی ویژگی های انجام می دهد که با عملیات کانولوشن انجام می دهد. انتخاب ویژگی که توسط شبکه عصبی کانولوشن انجام می شود به شیوه محاسبات ضرب ماتریس ها در عملیات کانولوشن است و هوشمندی بالایی ندارد. در این پژوهش برای آنکه دقت شبکه عصبی کانولوشن افزایش داده شود انتخاب ویژگی در لایه اول آن به الگوریتم هوش گروهي حشره آبسوار داده می شود که دارای دقت بالایی است. الگوریتم های تکاملی از اولین روش های فراالبتکاری توسعه یافته بودند و این روش ها بیشتر بر اساس رقابت و بقاء عمل می کنند. در این روش ها مانند الگوریتم ژنتیک، هر راه حل که دارای شایستگی بیشتری باشد آنگاه دارای شانس بیشتری برای بقاء می باشد. در روش های مبتنی بر رویداد های فیزیکی مانند الگوریتم جستجوی گرانشی هر راه حل بر اساس قوانین فیزیکی کدگذاری و برای حل مسئله استفاده می شود. در روشهای مبتنی بر رفتار انسان یک

می شود. رمزگذار خودکار انباشته ویژگی ها را به حداکثر می رساند و افزودنی را از داده های حسگر ایستگاه هواشناسی هدف حذف می کند و ویژگی های زمانی را با استفاده از یک شبکه حافظه بلند مدت و کوتاه مدت از داده های سنسور استخراج می کند. مدل جدید پیشنهادی عملکرد پیش بینی و قابلیت تعمیم را در چهار مکان مشاهده در عرض های جغرافیایی مختلف قطب جنوب شرقی (شامل حداکثر قطب جنوب و منطقه ساحلی) ارزیابی می کند. عملکرد پنج شبکه یادگیری عمیق از طریق پنج معیار ارزیابی مقایسه می شود و شکل بیهینه ترکیب ورودی مورد بحث قرار می گیرد. نتایج نشان می دهد که قابلیت پیش بینی مدل از سایر مدلها بهتر عمل می کند. این روش جدیدی برای پیش بینی کوتاه مدت هواشناسی در یک منطقه کوچک داخلی قطب جنوب ارائه می دهد.

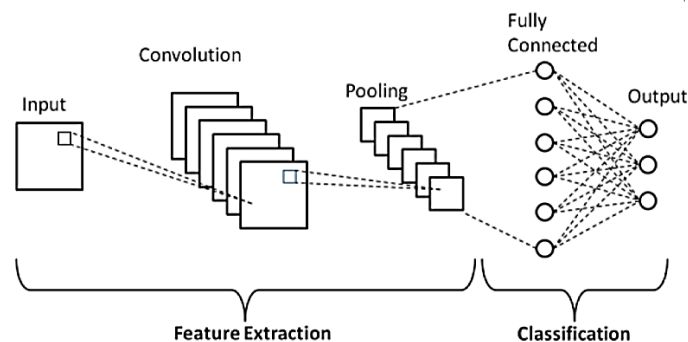
در پژوهش [۱۶]، یک روش آماری و یادگیری ماشین برای پیش بینی آب و هوایی ارائه دادند. مجموعه ای از مدل‌های یادگیری ماشین، شامل رگرسیون، درخت تصمیم گیری و روشهای یادگیری عمیق برای برآورد دمای سطح دریا توسعه داده شد. داده های آموزشی شامل اطلاعات دریافتی از ماهواره و داده های جوی است. مدل ها از نظر دقت و پیچیدگی محاسباتی مورد ارزیابی قرار گرفتند. مهارت های پیش بینی در برابر مشاهدات و یک مدل مدرن و مبتنی بر فیزیک از مرکز اروپایی پیش بینی آب و هوای متوسط ارزیابی شد. نتایج نشان داد که با ترکیب مهندسی ویژگی های خودکار با رویکردهای یادگیری ماشین، می توان دقت پیش بینی را افزایش دهد. آزمایشات آنها نشان داد که رویکردهای مبتنی بر یادگیری ماشین می تواند به عنوان ابزارهای پیش بینی قابل حمل برای متغیرهای آب و هوایی استفاده شود.

در پژوهش [۱۷]، یک شبکه عصبی برای پیش بینی موثر آب و هوا با استفاده از داده های سری زمانی از ایستگاه هواشناسی محلی ارائه دادند. نتایج تجربی حاصل از آزمایشات نشان می دهد که مدل پیشنهادی با استفاده از شبکه عصبی کانولوشن پیش بینی بهتری را در مقایسه با شبکه عصبی مصنوعی LSTM و سایر روشهای کلاسیک یادگیری ماشین ارائه می دهد. مدل پیشنهادی آنها می تواند به عنوان یک ابزار پیش بینی آب و هوای محلی کارآمد برای جامعه کاربران

انتقال^{۱۵} یا تغییرناپذیر با فضا^{۱۶} هم یاد می‌شود. این نامگذاری بر مبنای ساختار این شبکه است. در یادگیری عمیق، CNN ها رایج ترین شبکه‌هایی هستند که برای طبقه بندی تصاویر استفاده می‌شوند. CNN ها از سیستم بینایی انسان پیشنهاد شده توسط فوکوشیما و همکاران الهام گرفته شده است. آنها رویکردهای پیشرفته‌ای برای تشخیص الگو، تشخیص اشیا و بسیاری از کاربردهای تصویر دیگر هستند. CNN ها بسیار متفاوت از سایر الگوریتم‌های تشخیص الگو هستند زیرا CNN ها استخراج ویژگی و طبقه بندی را ترکیب می‌کنند. شکل (۳)، نمونه‌ای از یک نمایش شمایلی ساده از یک CNN پایه را نشان می‌دهد. این شبکه ساده از پنج لایه مختلف تشکیل شده است که عبارتند از یک لایه ورودی، یک لایه کانولوشن، یک لایه ادغام، یک لایه کاملاً متصل و یک لایه خروجی است. این لایه‌ها به دو بخش ذیل تقسیم می‌شوند:

۱- استخراج ویژگی^{۱۷}

۲- طبقه بندی^{۱۸}



شکل ۳: ساختار شبکه عصبی کانولوشن با اجزای آن [۱۹]

کانولوشن در هم می‌پیچد. در مرحله بعد، لایه ادغام اندازه تصویر را کاهش می‌دهد در حالی که سعی می‌کند اطلاعات موجود را حفظ کند. خروجی‌های استخراج ویژگی به عنوان نقشه‌های ویژگی شناخته می‌شوند. این طبقه بندی ویژگی‌های استخراج شده را در لایه کاملاً متصل ترکیب می‌کند. در نهایت، یک نورون خروجی برای هر دسته شی

الگوریتم تلاش دارد تا یک رویداد آموزشی، فرهنگی، اقتصادی و مرتبط با انسان را برای حل مسئله استفاده نماید. مزیت این روش‌ها در آن است که هوشمندی بالایی دارند اما مدلسازی این روش‌ها سخت و دشوار است. رفتارهای هوش گروهی از رفتار هوشمند و گروهی جانداران برای بقاء استفاده می‌شود. در این الگوریتم ها تعدادی راه حل وجود دارد که با مشارکت هم سعی در یافتن جواب بهینه دارند. در اینجا هر راه حل که شایستگی بیشتری دارد نقش بیشتری در هدایت جمعیت به سمت جواب بهینه دارد. در این بخش روش پیشنهادی برای بهبود شبکه عصبی کانولوشن با استفاده از هوش گروهی حشرات آب سوار ارایه و معرفی می‌شود.

۱-۳- شبکه عصبی کانولوشن

شبکه عصبی پیچشی، رده ای از شبکه های عصبی ژرف هستند که معمولاً برای انجام تحلیل های تصویری یا گفتاری در یادگیری ماشین استفاده می‌شوند. شبکه های عصبی پیچشی به منظور کمینه کردن پیش پردازش‌ها از گونه ای از پرسپترونهای چند لایه استفاده می‌کنند. به جای شبکه پیچشی گاهی از این شبکه ها با نام شبکه های عصبی تغییرناپذیر با

استخراج ویژگی از یک لایه ورودی، یک لایه کانولوشن و یک لایه ادغام تشکیل شده است در حالی که طبقه بندی شامل یک لایه کاملاً متصل و یک لایه خروجی است. لایه ورودی یک اندازه ثابت برای تصاویر ورودی مشخص می‌کند که در صورت نیاز اندازه آن تغییر می‌کند. سپس تصویر با چندین هسته آموخته شده با استفاده از وزن‌های مشترک توسط لایه

15 Shift invariout


16 Space invariout

17 Feature extraction

18 Classification

۳-۲- الگوریتم حشره آبسوار

یکی از رفتارهای جالب هوش گروهی که اخیراً ارائه شده است، رفتار الگوریتم حشره آبسوار^{۲۳} است. در این الگوریتم رفتارهای نظیر غذا یابی و جفت-گیری برای یافتن جواب بهینه و جستجوی فضای مسئله مورد استفاده قرار گرفته می-شود. در شکل (۴)، رفتار جفت-گیری و فرار از جفت-گیری در حشرات آبسوار را نشان می-دهد.



شکل ۴: یک نمونه از رفتار هوش گروهی بر اساس جفت گیری و فرار [۲۱]

به روزرسانی شده و شرط دوم برای بهینه-سازی بردارهای وزن و بایاس شبکه عصبی است تا با تکرار الگوریتم موفق به یافتن بردار وزن و بایاس بهینه شویم .

۱- تجزیه و تحلیل ورودی-های و پیش پردازش نمونه-های آب و هوایی

۲- نرمالسازی نمونه-های پیش بینی

۳- تقسیم داده-ها به نمونه آموزشی و آزمون

۴- انتخاب ویژگی برای بهینه-سازی ورودی شبکه عصبی مصنوعی کانولوشن

۵- بهینه-سازی وزن و بایاس بکار رفته در شبکه عصبی کانولوشن با الگوریتم حشره آبسوار

۶- ایجاد یک مدل پیش بینی توسط شبکه عصبی مصنوعی بهبود یافته برای پیش بینی وضعیت آب و هوایی

۷- ارزیابی روش پیشنهادی برای پیش بینی وضعیت آب و هوایی با استفاده از مدل آموزش دیده و توسط داده-ها و نمونه-های آزمون

در لایه خروجی وجود دارد. در این شبکه خروجی قسمت طبقه بندی، نتیجه طبقه بندی داده-ها است. یک معماری CNN از چندین لایه متوالی به شرح ذیل تشکیل شده است:

۱- یک لایه ورودی دو بعدی^{۱۹}

۲- یک لایه کانولوشن^{۲۰}

۳- یک لایه حداکثر تجمعی^{۲۱}

۴- یک لایه کاملاً متصل^{۲۲}

با توجه به شکل فوق، راه-حل نر یا غیر بهینه به راه-حل بهینه یا ماده نزدیک شده و در صورت جفت-گیری نوعی جستجوی محلی را انجام داده و در صورت فرار نر از ماده نوعی جستجوی سراسری برای یافتن جواب بهینه انجام می-شود. الگوریتم-های هوش گروهی به دلیل آنکه فضای مسئله را موازی و به کمک تعداد زیادی راه-حل مورد جستجو قرار می-دهند توانایی بالایی در فرار از بهینه-های محلی دارند و می-توانند به موازات هم فضای مسئله را برای یافتن جوابهای بهینه جستجو نمایند .

۳-۳- چارچوب پیشنهادی

در شکل (۵)، چارچوب روش پیشنهادی برای پیش بینی وضعیت آب و هوایی نمایش داده شده است. با توجه به چارچوب روش پیشنهادی، فازهای ذیل وجود دارد. در فلوجارت پیشنهادی دو شرط وجود دارد و شرط اول برای انتخاب ویژگی است تا مطمئن شویم که همه بردارهای ویژگی

19 Two-dimensional input laye

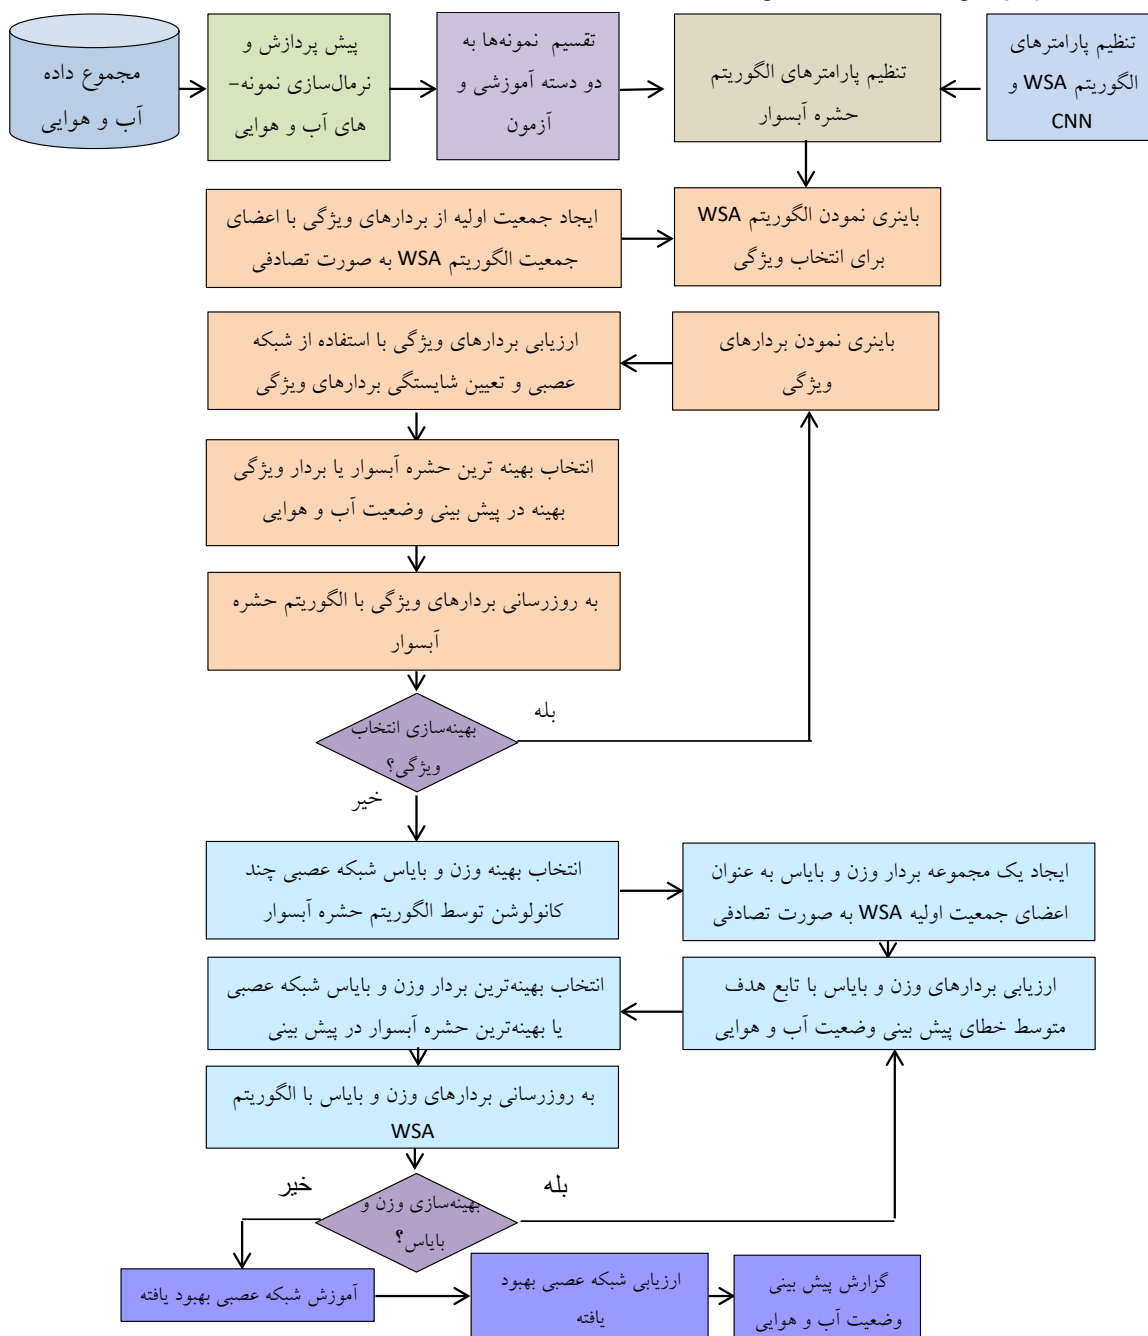
20 Convolutional layer

21 Max-pooling layer

22 Fully connected layer

23 Water strider algorithm

۸- ارزیابی مدل پیشنهادی با استفاده از نمونه-هاب آزمون و تحلیل روش پیشنهادی با شاخص‌های مانند دقت، صحت و حساسیت در پیش‌بینی وضعیت آب و هوایی



شکل ۵: چارچوب روش پیشنهادی برای پیش‌بینی وضعیت آب و هوایی

۳-۴- نرمالسازی و پیش‌پردازش

مهمترین بخش پیش‌پردازش را می‌توان فاز نرمالسازی ۲۴ در نظر گرفت. نرمالسازی به فرآیندی گفته می‌شود که باعث می‌شود مقادیر تغییرات ویژگی‌ها یکسان شود. به عبارت بهتر

در بیشتر موارد ستون‌ها یا ویژگی‌های مجموعه داده دارای کران پایین و بالای متفاوتی می‌باشند و این موضوع دقت یادگیری ماشین را کاهش می‌دهد. فرض کنید مجموعه داده نرمال شده در بازه $[a, b]$ مورد نرمالسازی قرار گرفته شود.

مجموعه داده است و $|m|$ تعداد ویژگی های انتخاب شده و بکار گرفته شده در بردار ویژگی X_i است. در اینجا دو وزن w_1 و w_2 وجود دارد که اهمیت دو عامل خطا و کاهش ابعاد را نشان می دهد. مطابق رابطه (۵)، مجموعه این دو بردار برابر یک است و w_1 را می توان تصادفی بین صفر و یک انتخاب نمود و بر اساس آن مقدار w_2 را محاسبه نمود.

$$w_1 + w_2 = 1 \quad ۵$$

با توجه به رابطه (۵) می توان تابع هدف را مانند رابطه (۶)، بازنویسی نمود:

$$Cost(X_i) = w_1 Error(X_i) + (1 - w_1) \frac{|n|}{|m|} \quad ۶$$

در این معادله، $Error(X_i)$ برابر خطای پیش بینی وضعیت آب و هوایی توسط بردار ویژگی یا حشره آبسوار X_i است و طبق رابطه (۷)، محاسبه می شود:

$$Error(X_i) = \frac{\sum_{i=1}^{total} (Class_i^{real} - Class_i^{est})^2}{total} \quad ۷$$

در اینجا $Class_i^{real}$ شماره کلاس واقعی از نظر نوع وضعیت آب و هوایی برای نمونه i و $Class_i^{est}$ مقدار پیش بینی آن است. در اینجا، $total$ تعداد نمونه های آب و هوایی برای ارزیابی است و $Error(X_i)$ خطای پیش بینی وضعیت آب و هوایی به ازای یک بردار ویژگی است. می توان معادلات را تجمیع نمود و تابع هدف مناسب را مانند معادله (۸)، بازنویسی نمود:

هر بردار ویژگی که بتواند این تابع هدف را کمینه نماید به

$$Cost(X_i) = w_1 \frac{\sum_{i=1}^{total} (Class_i^{real} - Class_i^{est})^2}{total} + (1 - w_1) \frac{|n|}{|m|} \quad ۸$$

عنوان بردار ویژگی بهینه برای پیش بینی وضعیت آب و هوایی در نظر گرفته می شود و به عنوان موقعیت طعمه در الگوریتم حشره آبسوار در نظر گرفته می شود.

۴- تجزیه و تحلیل روش پیشنهادی

در روش پیشنهادی برای تجزیه و تحلیل در محیط پیاده سازی متلب مورد ارزیابی قرار گرفته می شود. برای ارزیابی از

برای نرمالیزه نمودن یک ویژگی با مقدار f از رابطه (۱)، استفاده می شود و f' مقدار نرمال شده ویژگی f است.

$$f' = \frac{f - \min}{\max - \min} (b - a) + a \quad ۱$$

در این رابطه، \max و \min به ترتیب کمینه و بیشینه یک ویژگی نظیر f در نظر گرفته می شود و می توان بازه نرمال سازی را بین صفر و یک در نظر گرفت و نرمال سازی مطابق رابطه (۲)، انجام می شود:

$$f' = \frac{f - \min}{\max - \min} \quad ۲$$

نرمال سازی باعث می شود تا دامنه تغییرات همه ویژگی های مرتبط با پیش بینی وضعیت آب و هوایی یکسان شود و دقت یادگیری ماشین با نرمال سازی افزایش پیدا می کند. برای انتخاب ویژگی انجام فرآیند نرمال سازی روی داده ها مهم و حیاتی است و باعث می شود تا ویژگی های مهم انتخاب شود.

۳-۵- بهینه سازی شبکه عصبی کانولوشن

در روش پیشنهادی مطابق معادله رابطه (۳)، یک جمعیت از بردارهای ویژگی به عنوان جمعیت الگوریتم حشره آبسوار در نظر گرفته می شود و هر سطر این ماتریس یک بردار ویژگی یا یک حشره آبسوار است. در این معادله هر ستون یک ویژگی مرتبط با مجموعه داده است که در اینجا فرض شده d بعد دارد:

$$F = \begin{bmatrix} (X_{11}, X_{12}, X_{13}, \dots, X_{1d}) \Rightarrow X_1 \\ (X_{21}, X_{22}, X_{23}, \dots, X_{2d}) \Rightarrow X_2 \\ (X_{31}, X_{32}, X_{33}, \dots, X_{3d}) \Rightarrow X_3 \\ \vdots \\ (X_{n1}, X_{n2}, X_{n3}, \dots, X_{nd}) \Rightarrow X_n \end{bmatrix} \quad ۳$$

در روش پیشنهادی یک بردار ویژگی یا حشره آبسوار i -ام با $(X_{i1}, X_{i2}, X_{i3}, \dots, X_{id}) \Rightarrow X_i$ نمایش داده می شود. هر بردار ویژگی نظیر X_i در واقع ورودی های شبکه عصبی را تعیین می کند. و هر بردار ویژگی یا حشره آبسوار برای ارزیابی نیاز به یک تابع هدف دارد که یکی از آنها که در بیشتر مطالعات استفاده می شود در معادله (۴)، فرموله شده است:

$$Cost(X_i) = w_1 Error(X_i) + w_2 \frac{|n|}{|m|} \quad ۴$$


در این رابطه، $Error(X_i)$ خطای پیش بینی وضعیت آب و هوایی توسط بردار ویژگی X_i است. $|n|$ تعداد ویژگی های

نمونه آب و هوایی است و از طرفی N تعداد نمونه‌های مورد استفاده در ارزیابی است. برای ارزیابی و پیش‌بینی وضعیت آب و هوایی در روش پیشنهادی می‌توان شاخص‌های مانند دقت و حساسیت استفاده نمود که ضابطه آنها در رابطه (۱۱) و (۱۲) بیان شده است:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad 11$$

$$Sensitivity = \frac{TP}{TP + FN} \quad 12$$

برای ارزیابی روش پیشنهادی بر اساس شاخص‌های دقت^{۲۵} و حساسیت^{۲۶} در پیش‌بینی وضعیت آب و هوایی از شمارش نمونه‌های صحیح مثبت (TP)، نمونه‌های غلط مثبت (FP)، نمونه‌های صحیح منفی (TN)، و نمونه‌های غلط منفی (FN) استفاده می‌گردد. در نمودار شکل (۷)، متوسط شاخص خطای RMSE در پیش‌بینی وضعیت آب و هوایی توسط روش پیشنهادی ارایه شده است. در این نمودار اندازه جمعیت الگوریتم حشره آب سوار متغیر در نظر گرفته شده است تا تاثیر آن مشخص شود.



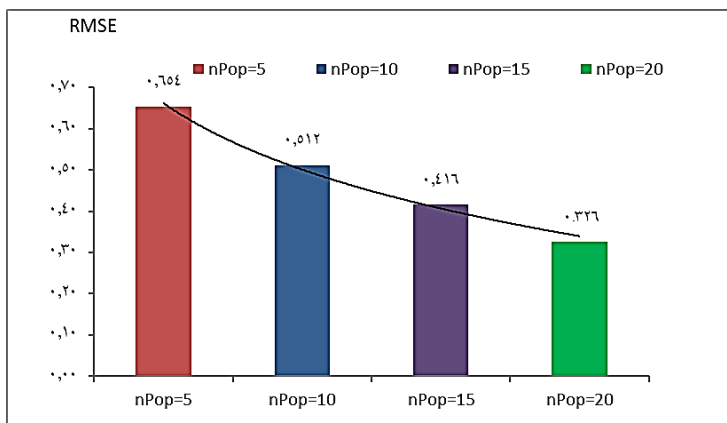
شکل ۶: مقدار تابع هدف در فاز انتخاب ویژگی

نرم‌فزار متلب ۲۰۲۱ استفاده می‌شود. در روش پیشنهادی از داده‌های مرتبط با سازمان هواشناسی ایران استفاده می‌شود و این داده‌ها دو وضعیت بارش و حالت عادی را در نظر می‌گیرند. در آزمایشات از ۷۰٪ از این داده‌ها به عنوان داده آموزشی و از ۳۰٪ دیگر داده‌ها به عنوان داده آزمون استفاده می‌شود. در روش پیشنهادی از شبکه عصبی کانولوشن با کرنل‌های ۳ در ۳ استفاده می‌شود و از طرفی تعداد بردارهای ویژگی به ترتیب برابر ۵، ۱۰، ۱۵ و ۲۰ در نظر گرفته شده و تعداد تکرار نیز برابر ۳۰ تنظیم شده و تعداد آزمایشات برابر ۲۵ عدد می‌باشد. در نمودار شکل (۶)، مقدار تابع هدف بر حسب تکرار الگوریتم پیشنهادی نمایش داده شده است. ارزیابی‌ها نشان می‌دهد مقدار تابع هدف بر حسب تکرار الگوریتم پیشنهادی در پیش‌بینی وضعیت آب و هوایی در حال کاهش است. کاهش یافتن تابع هدف به دلیل آن است که همزمان خطای پیش‌بینی وضعیت آب و هوایی و تعداد ویژگی انتخاب شده در حال کاهش است زیرا تابع هدف از این دو عامل ساخته شده است. برای ارزیابی روش پیشنهادی می‌توان از متوسط خطای پیش‌بینی وضعیت آب و هوایی استفاده نمود که در اینجا دو شاخص مهم پیش‌بینی نظیر MSE و RMSE وجود دارند که به ترتیب در روابط (۹) و (۱۰)، ارایه شده‌اند:

$$mse = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad 9$$

$$rmse = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad 10$$


در این رابطه‌ها، y_i شماره کلاس واقعی یک نمونه آب و هوایی از نظر عادی یا دارای بارش است و \hat{y}_i نیز شماره کلاس تخمین زده شده توسط روش پیشنهادی از وضعیت



شکل ۷: شاخص RMSE روش پیشنهادی برای پیش بینی وضعیت آب و هوایی بر اساس اندازه جمعیت بردار ویژگی

به ۰.۳۲۶ کاهش داشته است و این کاهش در حدود ۵۰.۱۵٪ است. در نمودار شکل (۸)، خطای پیش بینی وضعیت آب و هوایی با روشهای یادگیری ماشین مانند ماشین بردار پشتیبان، درخت تصمیم-گیری و رگرسیون خطی مقایسه شده است.

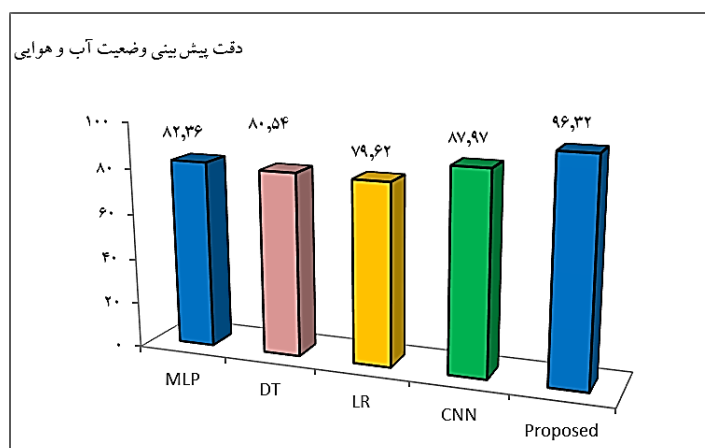
تجزیه و تحلیل روش پیشنهادی نشان می-دهد شاخص خطای پیش بینی RMSE به ازای جمعیت برابر ۵، ۱۰، ۱۵ و ۲۰ به ترتیب برابر ۰.۶۵۴، ۰.۵۱۲، ۰.۴۱۶ و ۰.۳۲۶ است. با افزایش جمعیت بردارهای ویژگی خطای پیش بینی از ۰.۶۵۴



شکل ۸: مقایسه شاخص RMSE روش پیشنهادی برای پیش بینی وضعیت آب و هوایی با روشهای یادگیری ماشین

استفاده نمود. آزمایشات نشان می-دهد روش پیشنهادی دارای دقت و حساسیتی به ترتیب برابر ۹۶.۳۲٪ و ۹۶.۱۴٪ در پیش بینی آب و هوا است. در نمودار شکل (۹) و (۱۰) به ترتیب متوسط شاخص دقت و حساسیت روش پیشنهادی با شبکه عصبی چند لایه، درخت تصمیم-گیری، رگرسیون لجستیک و شبکه عصبی کانولوشن برای پیش بینی وضعیت آب و هوایی مورد مقایسه قرار گرفته شده است.

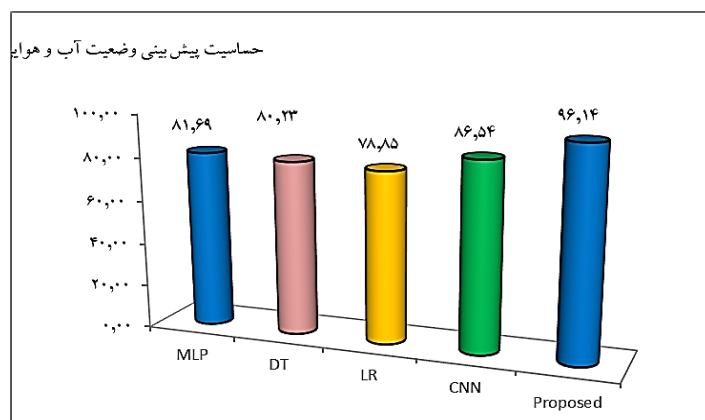
ارزیابی-ها نشان داد خطای پیش بینی روش پیشنهادی با جمعیت ۱۰ برابر ۰.۵۱۲ است و این در حالی است که خطای پیش بینی وضعیت آب و هوایی در روش ماشین بردار پشتیبان، درخت تصمیم-گیری و رگرسیون خطی به ترتیب برابر ۰.۸۷۸، ۱.۰۳۳ و ۰.۸۶۶ است و روش پیشنهادی دارای خطای کمتری نسبت به این روشها است. برای ارزیابی روش پیشنهادی می-توان از شاخص-های مانند دقت و حساسیت



شکل ۹: مقایسه دقت پیش‌بینی وضعیت آب و هوایی

دارای دقت بیشتری است. با توجه به نمودار حساسیت می‌توان گفت که حساسیت روش شبکه عصبی مصنوعی، درخت تصمیم‌گیری، رگرسیون لجستیک و شبکه عصبی کانولوشن برای پیش‌بینی وضعیت آب و هوایی به ترتیب برابر ۸۱.۶۹٪، ۸۰.۲۳٪، ۷۸.۸۵٪، ۸۶.۵۴٪ است و روش پیشنهادی نسبت به این روش‌ها دقت بیشتری در پیش‌بینی دارد.

تجزیه و تحلیل و آزمایشات نشان می‌دهد روش پیشنهادی در پیش‌بینی وضعیت آب و هوایی دارای دقتی برابر ۹۶.۳۲٪ است و این در حالی است که دقت روش شبکه عصبی مصنوعی، درخت تصمیم‌گیری، رگرسیون لجستیک و شبکه عصبی کانولوشن به ترتیب برابر ۸۲.۳۶٪، ۸۰.۵۴٪، ۷۹.۶۲٪ و ۸۷.۹۷٪ است. به عبارت بهتر روش پیشنهادی نسبت به روش‌های مورد مقایسه در پیش‌بینی وضعیت آب و هوایی



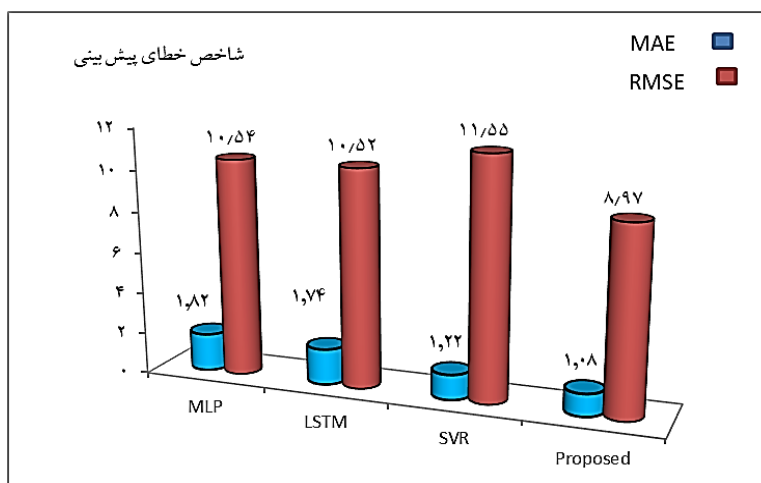
شکل ۱۰: مقایسه حساسیت پیش‌بینی وضعیت آب و هوایی

آب و هوایی با سه روش شبکه عصبی چند لایه^{۲۷}، شبکه یادگیری عمیق مبتنی بر حافظه^{۲۸} و رگرسیون بردار پشتیبان^{۲۹} مورد مقایسه قرار گرفته شده است. در نمودار شکل (۱۱)، نیز روش پیشنهادی با روشهای مورد نظر مورد مقایسه قرار گرفته شده و مورد تحلیل قرار گرفته شده است.

ارزیابی‌ها نشان می‌دهد روش پیشنهادی نسبت به شبکه یادگیری عمیق CNN، توانسته دقت پیش‌بینی را در حدود ۸.۳۵٪ افزایش دهد. در اینجا برای تکمیل آزمایشات روش پیشنهادی با نتایج مقاله [۲۲] که در سال ۲۰۲۱ ارایه شده است مورد مقایسه قرار گرفته می‌شود. در جدول (۱)، شاخص MAE و MSE روش پیشنهادی در خطای پیش‌بینی وضعیت

جدول (۱): مقایسه شاخص MAE و MSE در پیش بینی وضعیت آب و هوایی با روشهای مشابه

روش	MAE	MSE
MLP	۱.۸۲	۱۰.۵۴
LSTM	۱.۷۴	۱۰.۵۲
SVR	۱.۲۲	۱۱.۵۵
Proposed method	۱.۰۸	۸.۹۷



شکل ۱۱: مقایسه شاخص MAE و MSE در پیش بینی وضعیت آب و هوایی

در ابتدا انتخاب ویژگی با الگوریتم حشره آبسوار انجام شده و سپس در ادامه ویژگی‌های مهم مرتبط با شرایط آب و هوایی تحویل شبکه عصبی کانولوشن می‌شود تا بتوان شرایط آب و هوایی را پیش بینی نمود. ارزیابی‌ها نشان داد روش پیشنهادی در پیش بینی وضعیت آب و هوایی دارای خطای کمتری نسبت به ماشین بردار پشتیبان، درخت تصمیم‌گیری و رگرسیون خطی است. ارزیابی‌ها نشان می‌دهد که روش پیشنهادی در شاخص دقت و حساسیت برای پیش بینی وضعیت آب و هوایی از شبکه عصبی مصنوعی، درخت تصمیم‌گیری، رگرسیون لجستیک و شبکه عصبی کانولوشن دقیق‌تر است. در پژوهش آتی تلاش می‌شود چند کلاس به جای دو کلاس برای شرایط آب و هوایی در نظر گرفته شود و خروجی طبقه‌بندی کننده مبتنی بر رای‌گیری اکثریت باشد.

منابع:

1. Xu, Y. Characteristics and Psychological Response in the Post-disaster Era. Logist. Chin. Gov. 2020, 68–69 .

با توجه به آزمایشات انجام شده شاخص MAE و MSE در پیش بینی وضعیت آب و هوایی در روش پیشنهادی به ترتیب برابر ۱.۰۸ و ۸.۹۷ است و خطای روش پیشنهادی در پیش بینی وضعیت آب و هوایی از روشهای شبکه عصبی چند لایه، شبکه یادگیری عمیق مبتنی بر حافظه و رگرسیون بردار پشتیبان کمتر است.

۵- نتیجه گیری و پیشنهادات آتی

امروزه پیش بینی وضعیت آب و هوایی یک موضوع تحقیقاتی مهم است و باعث شده است تا بسیاری از پژوهشگران به سمت این موضوع هدایت شوند. پیش بینی وضعیت آب و هوایی بر اساس متغیرهای محیطی در دوره‌های قبلی و فعلی باعث می‌شود تا از وقوع آسیب‌های حوادثی مانند سیل کاسته شود. امروزه از پیش بینی هواشناسی برای کاربردهای مانند کشاورزی و برنامه‌ریزی سفرها استفاده می‌شود. یکی از روش‌های پیش بینی وضعیت آب و هوایی استفاده از روشهای یادگیری ماشین و یادگیری عمیق مانند شبکه عصبی کانولوشن است. در این مقاله برای پیش بینی وضعیت آب و هوایی از یک مدل دو لایه استفاده شده است.

13. Huang, Z. Q., Chen, Y. C., & Wen, C. Y. (2020). Real-time weather monitoring and prediction using city buses and machine learning. *Sensors*, 20(18), 5173.
14. Karvelis, P., Mazzei, D., Biviano, M., & Stylios, C. (2020). PortWeather: A lightweight onboard solution for real-time weather prediction. *Sensors*, 20(11), 3181.
15. Wang, Y., Dou, Y., Yang, W., Guo, J., Chang, X., Ding, M., & Tang, X. (2021). A New Machine Learning Algorithm for Numerical Prediction of Near-Earth Environment Sensors along the Inland of East Antarctica. *Sensors*, 21(3), 755.
16. Wolff, S., O'Donncha, F., & Chen, B. (2020). Statistical and machine learning ensemble modelling to forecast sea surface temperature. *Journal of Marine Systems*, 208, 103347.
17. Hewage, P., Behera, A., Trovati, M., Pereira, E., Ghahremani, M., Palmieri, F., & Liu, Y. (2020). Temporal convolutional neural (TCN) network for an effective weather forecasting using time-series data from the local weather station. *Soft Computing*, 24(21), 16453-16482.
18. Adewoyin, R. A., Dueben, P., Watson, P., He, Y., & Dutta, R. (2021). TRU-NET: a deep learning approach to high resolution prediction of rainfall. *Machine Learning*, 1-28.
19. Phung, V. H., & Rhee, E. J. (2019). A high-accuracy model average ensemble of convolutional neural networks for classification of cloud image patches on small datasets. *Applied Sciences*, 9(21), 4500.
20. Kaveh, A., & Eslamlou, A. D. (2020, June). Water strider algorithm: A new metaheuristic and applications. In *Structures* (Vol. 25, pp. 520-541). Elsevier.
21. Kaveh, A., Rahmani, P., & Dadras Eslamlou, A. (2021). Guided water strider algorithm for structural damage detection using incomplete modal data. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 1-18.
22. Bączkiewicz, A., Wątróbski, J., Sałabun, W., & Kołodziejczyk, J. (2021). An ANN Model Trained on Regional Data in the Prediction of Particular Weather Conditions. *Applied Sciences*, 11(11), 4757.
2. Fang, W., Xue, Q., Shen, L., & Sheng, V. S. (2021). Survey on the application of deep learning in extreme weather prediction. *Atmosphere*, 12(6), 661.
3. Jiang, Z., Yang, S., Liu, Z., Xu, Y., Xiong, Y., Qi, S., ... & Xu, T. (2022). Coupling machine learning and weather forecast to predict farmland flood disaster: A case study in Yangtze River basin. *Environmental Modelling & Software*, 105436.
4. Gao, Y., Miyata, S., & Akashi, Y. (2022). Multi-step solar irradiation prediction based on weather forecast and generative deep learning model. *Renewable Energy*, 188, 637-650.
5. Li, W., Pan, B., Xia, J., & Duan, Q. (2022). Convolutional neural network-based statistical post-processing of ensemble precipitation forecasts. *Journal of Hydrology*, 605, 127301.
6. Suleman, M. A. R., & Shridevi, S. (2022). Short-term weather Forecasting using Spatial Feature Attention based LSTM model. *IEEE Access*.
7. Brecht, R., & Bihlo, A. (2022). Computing the ensemble spread from deterministic weather predictions using conditional generative adversarial networks. *arXiv preprint arXiv:2205.09182*.
8. Chandrayan, S. S., Singh, K., & Bhoi, A. K. (2022). Atmospheric Weather Fluctuation Prediction Using Machine Learning. In *Cognitive Informatics and Soft Computing* (pp. 431-443). Springer, Singapore.
9. Ioannou, K., Karampatzakis, D., Amanatidis, P., Aggelopoulos, V., & Karmiris, I. (2021). Low-Cost Automatic Weather Stations in the Internet of Things. *Information*, 12(4), 146.
10. Noh, I., Doh, H. W., Kim, S. O., Kim, S. H., Shin, S., & Lee, S. J. (2021). Machine Learning-Based Hourly Frost-Prediction System Optimized for Orchards Using Automatic Weather Station and Digital Camera Image Data. *Atmosphere*, 12(7), 846.
11. Fathi, M., Haghi Kashani, M., Jameii, S. M., & Mahdipour, E. (2021). Big data analytics in weather forecasting: A systematic review. *Archives of Computational Methods in Engineering*, 1-29.
12. Rani, S. S., Janet, J., Ramya, K. C., & Gomathy, V. (2020, December). IoT based climate prediction using ANN for green networking. In *IOP Conference Series: Materials Science and Engineering* (Vol. 993, No. 1, p. 012090). IOP Publishing.