

تحلیل شرایط آب و هوایی با یادگیری عمیق مبتنی بر انتخاب ویژگی با الگوریتم یادگیری کلاغ

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

۱- دانشجوی دکتری، دانشگاه آزاد اسلامی واحد بیرجند، بیرجند، ایران.

۲- استادیار، دانشگاه آزاد اسلامی واحد بیرجند، گروه کامپیوتر، بیرجند، ایران

۳- کارشناس ارشد پژوهشی، پژوهشکده اقلیم‌شناسی مشهد، ایران

چکیده


شبکه‌های عصبی یادگیری عمیق کاربردهای زیادی در موضوعات مختلف مانند پیش‌بینی، طبقه‌بندی و تشخیص الگو دارند. یکی از کاربردهای مهم شبکه‌های عصبی یادگیری عمیق، موضوع پیش‌بینی وضعیت آب و هوایی است. شبکه عصبی LSTM یک روش یادگیری عمیق است که می‌تواند برای تشخیص وضعیت آب و هوایی استفاده شود. در لایه اول شبکه یادگیری عمیق LSTM، از انتخاب ویژگی خودکار و در لایه آخر فاز طبقه‌بندی خودکار انجام می‌شود. در این مقاله برای کاهش دادن خطای پیش‌بینی و طبقه‌بندی شبکه یادگیری عمیق LSTM یک رویکرد دو مرحله‌ای برای بهبود این شبکه یادگیری عمیق ارائه می‌شود. در فاز اول از الگوریتم یادگیری کلاغ برای انتخاب ویژگی در لایه اول شبکه LSTM استفاده می‌شود تا یادگیری روی ویژگی‌های مهم متمرکز شود. ارزیابی‌ها نشان داد دقت روش پیشنهادی در پیش‌بینی وضعیت آب و هوایی برابر ۹۶.۹۲٪ است و این در حالی است که اگر برای پیش‌بینی از انتخاب ویژگی استفاده نشود و فقط از شبکه یادگیری عمیق استفاده شود آنگاه دقت روش پیشنهادی در حدود ۹۳.۲۱٪ است. ارزیابی‌ها نشان می‌دهد دقت روش پیشنهادی برای پیش‌بینی وضعیت آب و هوایی از روش LSTM و MLP بیشتر است.

کلید واژه‌ها: یادگیری عمیق، شبکه LSTM، الگوریتم یادگیری کلاغ، پیش‌بینی آب و هوا.

مقدمه

الگوریتم‌های فراابتکاری روش‌های حل مسئله‌ای است که از رویدادهای موجود در طبیعت و یا رفتار جانداران الگوبرداری شده است. در این الگوریتم‌ها شیوه‌های حل مسئله در جانداران مورد مدلسازی و الگوبرداری قرار گرفته شده است تا بتوان راه‌حلهای بهینه را استخراج نمود. مکانیزم بقا و روش یافتن غذا، شکار یا جفت در طبیعت و یا حتی فرآیندهای زیستی و فیزیکی می‌تواند برای مدلسازی الگوریتم‌های فراابتکاری مورد استفاده قرار گرفته شود. مزیت مهم الگوریتم‌های فراابتکاری در حل مسائل پیچیده و بهینه‌سازی در آن است که نیازی به اطلاعات گرادیان تابع هدف ندارند و به طور معمول جوابهای را ارائه می‌دهند که دارای دقت بالایی بوده و در بیشتر موارد اختلاف ناچیز با جواب واقعی دارند [۱]. یکی از روش‌های خلق الگوریتم‌های فراابتکاری مطالعه رفتار جانداران در بقا است و از جمله این روش‌ها می‌توان به شیوه بقای جاندارانی اشاره نمود که در طبیعت به صورت گروهی زندگی می‌کنند و یا رفتارهای اجتماعی دارند. امروزه بیشتر جانداران در طبیعت از رفتارهای اجتماعی و دسته جمعی برای افزایش شانس بقای خود استفاده می‌نمایند که از جمله این رفتارها می‌توان به مورچه‌ها اشاره نمود. رفتارهای گروهی در طبیعت به جانداران کمک می‌نمایند که بتوانند بر مشکلات غلبه نمایند و آنها با استفاده از قوانین تکامل و انتخاب طبیعی آموخته‌اند که در کنار هم بودن شانس آنها را برای بقا افزایش می‌دهد. الگوریتم‌های هوش دسته جمعی [۲] به نوعی از الگوریتم‌های فراابتکاری گفته می‌شود که از رفتار جاندارانی که زندگی گروهی و اجتماعی دارند الگوبرداری شده است و

در اینجا رفتار اجتماعی می‌تواند در شکار گروهی نمود پیدا نماید. نمونه رفتارهای شکار، الگوریتم بهینه‌سازی کفتار [۳ و ۴]، الگوریتم بهینه‌سازی وال [۵ و ۶] و الگوریتم گرگ بهینه‌سازی خاکستری [۷ و ۸] است و یا این رفتار در بقای جانداران و محافظت آنها بکار می‌رود که نمونه آن مکانیزم گرم کردن بدن توسط پنگوئن‌ها در الگوریتم بهینه‌سازی پنگوئن [۹] است و یا می‌توان الهام بخش آنها در گردآوری غذا باشد که نمونه آن در الگوریتم بهینه‌سازی سنجاب [۱۰] قابل مشاهده است. در برخی از گونه‌های هوش گروهی، از مکانیزم برقراری ارتباط به وسیله مواد شیمیایی و یا نور و حتی صدا استفاده می‌شود و هر کدام از این روش‌ها تاکنون مورد توجه پژوهشگران قرار گرفته شده است. یکی از الگوریتم‌های گروهی که از رفتار ارتباطی با مواد شیمیایی در بین جانداران وجود دارد، الگوریتم بهینه‌سازی پروانه [۱۱] است. در اینجا از مکانیزم انتشار فرومون بین گونه‌ها و حرکت به سمت منبع بیشتر فرومون برای یافتن جواب بهینه استفاده می‌شود. امروزه الگوریتم‌های فراابتکاری متنوعی برای حل مسائل بهینه‌سازی ارائه شده است که دارای رویکرد هوش گروهی است و بر اساس مکانیزم شکار الگوبرداری شده است که نمونه این الگوریتم‌ها الگوریتم بهینه‌سازی شاهین [۱۲ و ۱۳] و الگوریتم بهینه‌سازی اره ماهی [۱۴] است. الگوریتم‌های فراابتکاری بر اساس شیوه حل مسئله می‌تواند به دسته‌های مختلفی تقسیم بندی شوند که یک دسته‌بندی آن در پژوهش [۱۵]، در سال ۲۰۲۰ مطابق نمودار شکل (۱)، نمایش داده شده است و مشاهده می‌شود که الگوریتم‌های فراابتکاری به ۴ گروه و دسته مختلف بر اساس عملکرد خود تقسیم شده‌اند:



شکل ۱: دسته بندی الگوریتم‌های فراابتکاری به دسته‌های مختلف [۱۵]

روش‌های که برای پیش‌بینی وضعیت آب و هوایی استفاده می‌شود می‌توان به روش شبکه عصبی چند لایه [۱۸]، رگرسیون [۱۹]، شبکه عصبی کانولوشن [۲۰]، شبکه عصبی LSTM با مبتنی بر حافظه [۲۱] از جمله این روش‌ها است. یکی روش‌های مناسب برای پیش‌بینی استفاده از شبکه عصبی LSTM است که در پیش‌بینی بیماری کووید [۱۹] [۲۲]، پیش‌بینی بازار بورس [۲۳] و پیش‌بینی آب و هوایی [۲۴] از آن استفاده شده است. در این مقاله برای بهبود دقت شبکه LSTM از بهینه‌سازی ویژگی‌های مهم با استفاده از روش یادگیری در کلاخ‌ها استفاده شده است. این مقاله در چند بخش نگارش شده است. در ادامه شبکه یادگیری عمیق LSTM توضیح داده می‌شود و سپس روش پیشنهادی ارائه و فرموله می‌گردد و در ادامه نیز روش پیشنهادی پیاده‌سازی و مورد تجزیه و تحلیل قرار گرفته می‌شود. در نهایت و در انتهای مقاله نتایج مقاله ارائه و پیشنهادات آتی بیان می‌شود.

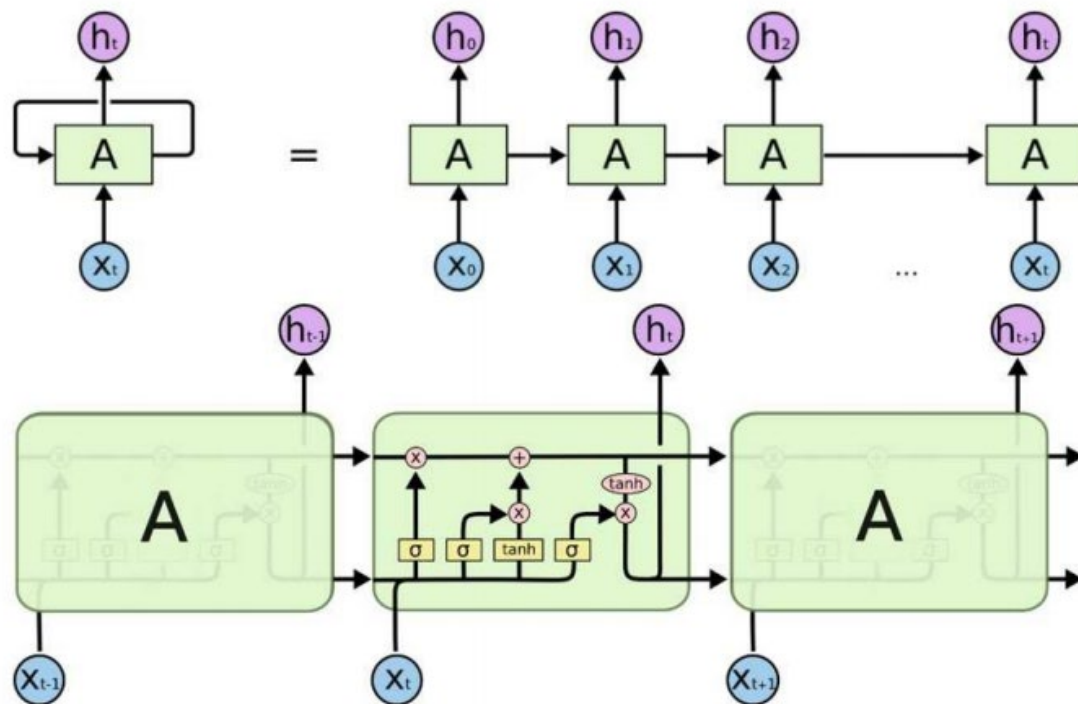
شبکه یادگیری LSTM

شبکه عصبی حافظه طولانی کوتاه مدت در واقع نوعی از شبکه‌های عصبی مکرر می‌باشند با این تفاوت یک ورودی از

مطابق این دسته‌بندی الگوریتم‌های فراابتکاری به دسته‌های تکاملی، دسته جمعی، الگوریتم‌های فیزیکی، رفتارهای مبتنی بر انسان تقسیم‌بندی می‌شوند. در رفتارهای تکاملی از بقاء و شایستگی مانند الگوریتم ژنتیک برای حل مسئله استفاده می‌شود و در رفتارهای گروهی از رفتار اجتماعی جانداران برای بقاء استفاده شده که نمونه آن رفتار مورچه‌ها است و در الگوریتم‌های مبتنی بر قواعد فیزیکی یک مکانیزم و قانون در طبیعت مانند گرانش به عنوان عامل حل مسئله در نظر گرفته می‌شود. الگوریتم‌های هوش گروهی دسته مهمی از الگوریتم‌های فراابتکاری است و در این الگوریتم‌ها یک راه-حل به تنهایی قادر نمی‌باشد که جواب بهینه را پیدا نماید و برای یافتن جواب بهینه نیاز به نوعی همکاری در بین اعضای جمعیت است. الگوریتم‌های فراابتکاری در زمینه‌های مختلف دارای کاربرد می‌باشند که یکی از آنها بهینه‌سازی پارامترهای یادگیری ماشین [۱۶] و یادگیری عمیق [۱۷] است. با بهینه‌سازی روش‌های یادگیری عمیق و یادگیری ماشین می‌توان از آنها به عنوان ابزارهای قدرتمند در پیش‌بینی و طبقه‌بندی استفاده نمود. یکی از کاربردهای یادگیری ماشین و یادگیری عمیق در پیش‌بینی وضعیت آب و هوایی است. از جمله

یادگیری کلاغ: در این گام موقعیت جدید کلاغ بر اساس یادگیری عمودی یا افقی تعیین می‌شود. شکل (۴) موقعیت کلاغ قبل و بعد از یادگیری را نشان می‌دهد.

وضعیت فعلی سیستم را نیز دارند. هر واحد شبکه LSTM بر خلاف شبکه RNN دارای دو ورودی است و واحدهای حافظه نیز مانند شکل (۲)، دارد [۲۵]. گرفته می‌شوند و بقیه کلاغ‌ها به عنوان کلاغ‌های نوجوان در نظر گرفته می‌شوند.



شکل ۲: تفاوت شبکه‌های عصبی LSTM و مکرر [۲۵]

سپردن تعیین می‌کند که چه میزان از وضعیت فعلی، توسط لایه گیت فراموشی بایستی فراموش شود و چه میزان از حافظه بایستی آزاد شود. شبکه LSTM با ظاهر پیچیده، شامل چند ایده جذاب و ساده است به گونه‌ای حافظه بلندمدت دارد و هم اطلاعات را می‌تواند به خاطر بیاورد و هم آنها را فراموش نماید از طرفی گیت‌های در این شبکه وجود دارد که جریان ورودی به خروجی را کنترل می‌کند و به طور کلی در این شبکه سه گیت با نام‌های گیت فراموشی، گیت ورودی و گیت خروجی وجود دارد. گیت فراموشی برای آن است که اطلاعات غیرضروری گذشته فراموش شود و در یادگیری استفاده نشود. گیت ورودی برای آن است که بررسی شود، اطلاعات به‌دست آمده از لحظه فعلی ارزش ذخیره در حافظه بلندمدت را دارند یا بهتر است آنها را فراموش کرد. گیت خروجی برای آن است که همه اطلاعات موجود در

در شبکه LSTM، به کمک تابع سیگموئید که به صورت عنصر به عنصر اعمال می‌شود، لایه‌های گیت ورودی، فراموشی و خروجی بردارهایی تولید می‌کنند که تمام درایه‌های آنها بین صفر و یک یا نزدیک به آن دو هستند. وقتی یکی از این لایه‌ها در بردار دیگری ضرب می‌شود، بدین شکل به عنوان یک فیلتر عمل می‌کند که فقط یک نسبت خاص از بردار را انتخاب می‌کند. دقیقاً به این دلیل است که این لایه‌ها گیت نامیده می‌شوند. حالت غیر متعارف زمانی است که تمامی مقادیر یک بردار یک هستند که تمام بردار عبور خواهد کرد، یا تمام آن برابر با صفر است که هیچ کدام عبور نخواهند کرد. گیت‌های فراموشی، ورودی و خروجی به شکل کاملاً مشابه محاسبه می‌شوند و فقط تنها پارامترها متفاوت می‌باشند. هر چند این پارامترها در تمامی گام‌های زمانی به اشتراک گذاشته می‌شوند. فراموش کردن به خاطر

صورت رابطه (۱) است که در آن W وزن و b بایاس است نمایش داد [۲۶].

$$i^t = \sigma(W^{ix}x^t + U^{ih}h^{t-1} + b^i) \quad ۱$$

در این رابطه، h^{t-1} و x^t را به عنوان ورودی در نظر گرفته می‌شود. لایه ورودی سلول، ورودی سلول جریان مشابه دروازه ورودی دارد و h^{t-1} و x^t را به عنوان ورودی دریافت می‌شوند. با این حال، از فعال سازی \tanh برای خرد کردن مقادیر ورودی در بازه ای بین -1 و 1 استفاده می‌شود و با l^t در معادله (۲) مشخص می‌شود [۲۶].

$$l^t = \tanh(w^{lx}x^t + U^{lh}h^{t-1} + b^l) \quad ۲$$

دروازه فراموشی واحدی با عملکرد سیگموئیدال تعیین می‌کند که کدام اطلاعات مربوط به مراحل قبلی سلول باید حفظ یا فراموش شود. دروازه f^t بر اساس ورودی، h^{t-1} و x^t مقادیری بین صفر و یک را در نظر می‌گیرد. در مرحله بعدی، f^t توسط یک تولید کننده Hadamard با حالت سلول قدیمی c^{t-1} داده می‌شود تا به حالت سلول جدید c^t به روز شود و برای این منظور از معادله رابطه (۳)، استفاده می‌شود. در این حالت، مقدار صفر به معنای بسته بودن دروازه است، بنابراین اطلاعات حالت سلول قدیمی c^{t-1} را کاملاً فراموش می‌کند، در حالی که مقادیر یک باعث می‌شود همه اطلاعات به یاد ماندنی شود. بنابراین، اگر اطلاعات قدیمی بی‌معنی تلقی شوند، دروازه فراموشی حق بازنشانی وضعیت سلول را دارد [۲۶].

$$f^t = \sigma(W^{fx}x^t + U^{fh}h^{t-1} + b^f) \quad ۳$$

حالت سلول، حافظه سلول را در مدت زمان طولانی تری ذخیره می‌کند. هر سلول یک واحد خطی متصل به طور خودکار دارد که به آن چرخ فلک ثابت خطا (CEC) گفته می‌شود. مکانیسم CEC تضمین می‌کند که یک شبکه LSTM از مشکل گرادیان ناپدید شده یا در حال انفجار رنج نمی‌برد. CEC توسط گیت فراموشی کار تنظیم می‌شود و همچنین می‌تواند توسط گیت فراموشی تنظیم شود. در زمان t ، حالت سلول فعلی c^t با حالت سلول قبلی c^{t-1} که توسط دروازه فراموشی و تولید کننده ورودی فعلی و ورودی سلول کنترل می‌شود، به روز می‌شود. به طور کلی، معادله (۴) به روز رسانی ترکیبی حالت سلول را توصیف می‌کند [۲۶].

$$c^t = f^t \cdot c^{t-1} + i^t \cdot l^t \quad ۴$$

حافظه فعلی C^t به خروجی ht منتقل نشود و گیت‌های مورد نظر مانند یک فیلتر عمل نموده و همواره خروجی‌شان بین صفر و یک است. مقادیر گیت‌ها همیشه در یک ورودی به صورت بولین یا درایه به درایه ضرب می‌شوند. هر گیت دو ورودی $ht-1$ و xt دارد و دو ورودی در دو لایه اتصال کامل با هم ضرب می‌شوند و بعد با هم جمع می‌شوند و در نهایت با تابع فعالیت سیگموئید دچار تغییر می‌شوند. یک تابع فعالیت کاربردی تانژانت هایپربولیک است اطلاعات را همواره بین بازه -1 و 1 قرار می‌دهد. به طور معمول شبکه LSTM، چهار برابر شبکه RNN هزینه محاسباتی دارد [۲۶].

شبکه‌های حافظه کوتاه مدت بلند در ده نود میلادی توسط هوکرایتر و اشمیدویر معرفی شدند. LSTM نوعی از شبکه‌های عصبی بازگشتی است که توانایی رفع نواقص ساختارهای بازگشتی را دارد که عملکرد خوبی ندارند. به عنوان مثال، هنگام مدیریت وابستگی‌های طولانی مدت، ضعف‌هایی در این حالت وجود دارد که شبکه LSTM آن را برطرف می‌نماید. علاوه بر این، LSTM از مشکل محو شدن یا زیاد شدن گرادیان جلوگیری می‌کنند. در سال ۱۹۹۹، LSTM با دروازه فراموشی شدنی معرفی شد که می‌تواند حافظه سلول را تنظیم کند. این امر LSTM اولیه را بهبود بخشید و به ساختار استاندارد شبکه‌های LSTM تبدیل شد. برخلاف شبکه‌های عصبی پیش‌خور عمیق، LSTM حاوی اتصالات بازخورد هستند. علاوه بر این، آن‌ها نه تنها می‌توانند نقاط داده‌ای واحد، مانند بردارها یا آرایه‌ها، بلکه توالی داده‌ها را پردازش کنند. در یک شبکه استاندارد LSTM، موجودیت اصلی واحد LSTM یا بلوک حافظه نامیده می‌شود. هر واحد از یک سلول، قسمت حافظه واحد و سه دروازه تشکیل شده است: یک دروازه ورودی، یک دروازه خروجی و یک دروازه فراموشی که به آن دروازه نگهدارنده نیز گفته می‌شود. دروازه ورودی، واحدی با عملکرد سیگموئیدی که جریان اطلاعات را به داخل سلول کنترل می‌کند. فعال‌سازی خود را از دو خروجی زمان قبلی h^{t-1} و ورودی x^t دریافت می‌کند. تحت تاثیر تابع سیگموئید، یک درگاه ورودی مقادیری بین صفر تا یک تولید می‌کند. صفر نشان می‌دهد که اطلاعات را به طور کامل مسدود می‌کند، در حالی که مقادیر یک اجازه عبور همه اطلاعات را می‌دهد. این معادله را می‌توان به

اطلاعات مجموعه داده نیاز است که مورد پیش پردازش و نرمالسازی قرار گرفته شود. منظور از نرمالسازی آن است که مقدار کران بالا و پایین همه ویژگی‌های مجموعه داده در یک محدود تعریف شود تا خطای یادگیری ماشین و شبکه عصبی مصنوعی در پیش بینی آب و هوا کمینه شود. در روش پیشنهادی برای نرمالیزه کردن مجموعه داده همه ویژگی‌ها را در محدوده $[L,U]$ نرمالیزه می‌نمایم. برای نرمالیزه کردن مجموعه داده می‌توان از رابطه (۷)، استفاده نمود.

$$X' = L + \frac{X - \min(X)}{\max(X) - \min(X) - U} (L - U) \quad (7)$$

در این حالت، X مقدار غیرنرمال شده یک ویژگی در مجموعه داده است و X' مقدار نرمال شده همان ویژگی است و بازه نرمالسازی هم محدوده $[L,U]$ است. در روش نرمالسازی مورد نظر، $\min(X)$ و $\max(X)$ به ترتیب مقدار کمینه و بیشینه هر ویژگی نظیر X است. در روش پیشنهادی، یک بردار ویژگی، دارای یک الگوی صفر و یک است و هر جا صفر باشد نشان دهنده این موضوع است که ویژگی مورد نظر انتخاب نشده است و هر جا برابر یک باشد آنگاه ویژگی مورد نظر انتخاب شده است. یک بردار ویژگی را می‌توان برای آموزش شبکه عصبی استفاده نمود و برای ارزیابی آن دو عامل ذیل مهم است و کمینه شدن این دو عامل نشان می‌دهد یک بردار ویژگی یا یک کلاغ تا چه اندازه دارای شایستگی است:

متوسط خطای پیش بینی توسط شبکه عصبی حداقل شود.

دروازه خروجی، واحدی با عملکرد سیگموئیدال می‌تواند جریان اطلاعات را از سلول کنترل کند. یک LSTM از مقادیر گیت خروجی در زمان t استفاده می‌کند و با o^t مشخص می‌شود و برای کنترل حالت سلول فعلی c^t که توسط یک تابع \tanh فعال می‌شود و برای به دست آوردن بردار خروجی نهایی h^t رابطه (۵) و (۶) وجود دارد [۲۶]:

$$o^t = \sigma(W^{ox}x^t + U^{oh}h^{t-1} + b^o) \quad (5)$$

$$h^t = o^t \cdot \tanh(c^t) \quad (6)$$

ساختار کلی شبکه عصبی یادگیری عمیق LSTM با تمامی واحدها به صورت شکل (۳) است.

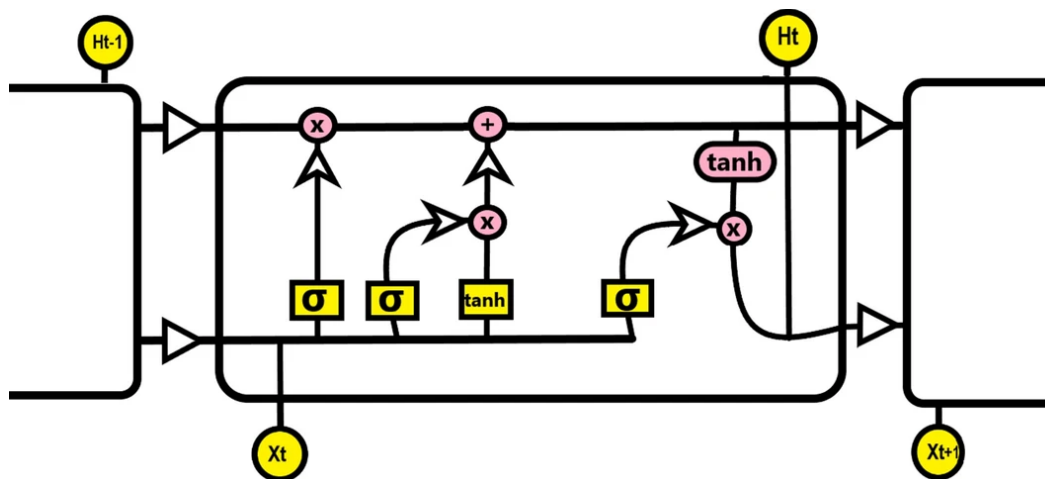
مدل پیشنهادی

در شکل (۴)، چارچوب روش پیشنهادی برای بهبود شبکه LSTM با استفاده از یادگیری کلاغ و الگوریتم جستجوی کلاغ در فاز انتخاب ویژگی و شبکه عصبی مصنوعی در فاز طبقه‌بندی نمونه‌ها نمایش داده شده است. در روش پیشنهادی برای بهبود شبکه LSTM، طبق چارچوب پیشنهادی سه فاز اصلی ذیل وجود دارد.

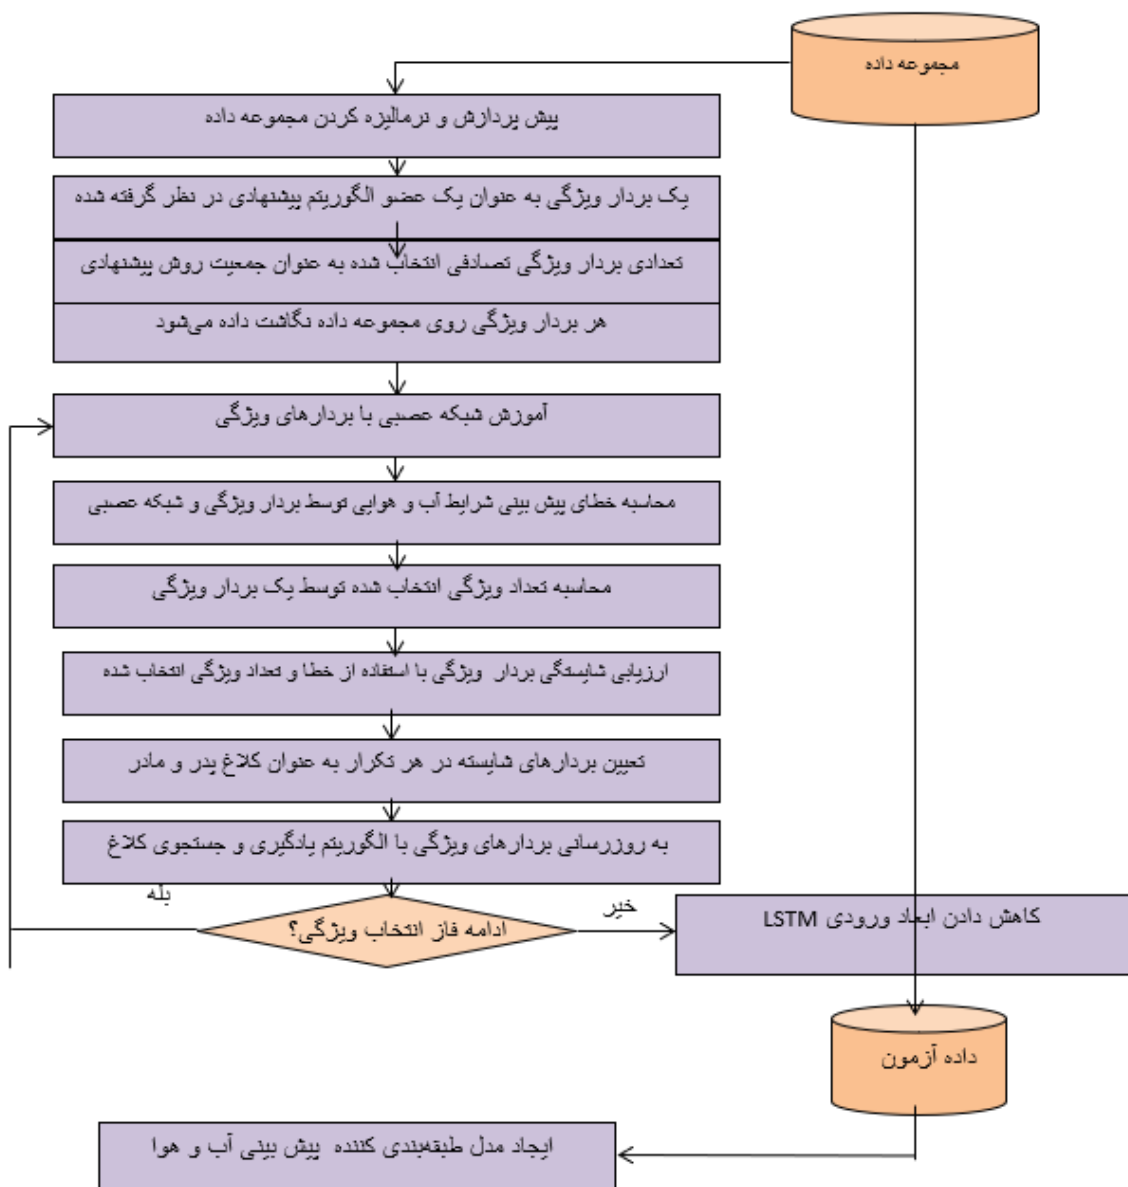
- بهبود الگوریتم یادگیری کلاغ با الگوریتم جستجوی کلاغ
- ارائه یک نسخه انتخاب ویژگی از الگوریتم ترکیبی یادگیری کلاغ و جستجوی کلاغ برای کاهش دادن تعداد ورودی طبقه‌بندی کننده مانند شبکه عصبی مصنوعی LSTM

- یادگیری و پیش بینی وضعیت آب و هوایی با شبکه LSTM

در روش پیشنهادی برای بهبود دقت LSTM از چارچوب فوق استفاده می‌شود و مراحل آن به شرح ذیل در ادامه ذکر می‌شود. در روش پیشنهادی در ابتدا



شکل ۳ ساختار شبکه‌های حافظه کوتاه مدت بلند



شکل ۵- هیستوگرام خطا به ازای داده‌های آموزشی و آزمایشی در ANFIS آموزش یافته با الگوریتم یادگیری کلاغ

VSLprob، احتمال انتخاب والدین توسط کلاغها برابر P1prob و احتمال یادگیری فردی و بر اساس تجربه برابر TaEprob فرض می‌شود. در روش پیشنهادی جمعیت کلاغها در یک ماتریس نگهداری می‌شود که مطابق رابطه (۱۱)، فرموله می‌شود.

$$Crows = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_d^1 \\ x_1^2 & x_2^2 & \dots & x_d^2 \\ \vdots & \vdots & \vdots & \vdots \\ x_1^N & x_2^N & \dots & x_d^N \end{bmatrix}$$

در این رابطه، هر سطر موقعیت یک کلاغ را نشان می‌دهد و در اینجا فرض بر آن است که هر راه‌حل دارای d بعد است. هر کلاغ نیاز دارد مطابق الگوریتم جستجوی کلاغ موقعیت بهینه‌ترین موقعیتی که در آن قرار داشته است را به خاطر بسپارد و از این جهت از رابطه (۱۲)، استفاده می‌شود.

$$Memory = \begin{bmatrix} m_1^1 & m_2^1 & \dots & m_d^1 \\ m_1^2 & m_2^2 & \dots & m_d^2 \\ \vdots & \vdots & \vdots & \vdots \\ m_1^N & m_2^N & \dots & m_d^N \end{bmatrix}$$

در این رابطه، هر سطر ماتریس حافظه نشان دهنده موقعیت بهینه یک ذره یا یک کلاغ است و در اینجا هر راه‌حل مانند x^i دارای d مولفه حافظه است که با m^i نمایش داده می‌شوند. در الگوریتم پیشنهادی فرض بر آن است که X_{ij} بردار راه‌حل i -ام در j -ام است و در تکرار اول این بردار و جمعیت تصادفی تولید می‌شوند که در رابطه (۱۳)، نمایش داده شده است.

$$X_{ij} = L + (U - L) \times U(0,1)$$

در این رابطه، $U(0,1)$ بردار تصادفی با مقدار بین صفر و یک است و از طرفی L و U به ترتیب محدوده پایین و بالایی مسئله است. شایستگی هر کلاغ با تابع هدف مشخص می‌شود و در اینجا دو راه‌حل شایسته اول به عنوان پدر و مادر جمعیت در نظر گرفته شده که به ترتیب با $X1$ و $X2$ نمایش داده می‌شود. اگر دو عضو جمعیت پدر و مادر باشند آنگاه $n-2$ کلاغ دیگر به عنوان راه‌حل‌های

تعداد ویژگی انتخاب شده توسط بردار ویژگی مورد نظر نیز کمینه شود.

می‌توان دو هدف مورد نظر را در یک هدف واحد مانند رابطه (۸)، فرموله نمود و این تابع هدف در بسیاری از پژوهش‌ها در پیش بینی مورد استفاده قرار گرفته شده است:

$$Cost = \alpha \cdot E + \beta \cdot \frac{\|f\|}{\|F\|} \quad ۸$$

در این رابطه، $\|f\|$ تعداد ویژگی‌های انتخاب شده در یک بردار ویژگی است و $\|F\|$ تعداد کل ویژگی‌های مجموعه داده است. در این رابطه، E متوسط خطای پیش بینی است و α و β دو عدد تصادفی بین صفر و یک بوده به گونه‌ای که مقدار β نیز برابر $1 - \alpha$ است. هر بردار ویژگی یا یک کلاغ در روش پیشنهادی که این تابع هدف را کمینه نماید به عنوان بردار ویژگی بهینه در پیش بینی در نظر گرفته می‌شود. در روش پیشنهادی شاخص خطای E را می‌توان مانند رابطه (۹)، فرموله نمود:

$$e = \frac{1}{n} \left(\sum_{i=1}^n (\tilde{o}_i - o_i)^2 \right) \quad ۹$$

در این رابطه، \tilde{o}_i و o_i به ترتیب شماره کلاس اصلی و تخمینی نمونه‌ها است و i شماره یک نمونه و n و e به ترتیب تعداد نمونه‌های بکار رفته است. در الگوریتم یادگیری کلاغ، یک راه‌حل به صورت X_i یا یک عضو الگوریتم یادگیری کلاغ تعریف می‌شود. هر راه‌حل را می‌توان در فضای مسئله در ابتدا تصادفی توزیع نمود و یک جمعیت از کلاغها مانند رابطه (۱۰)، ایجاد نمود.

$$Pop = \{X_1, X_2, X_3, \dots, X_N\} \quad ۱۰$$

در این رابطه، N تعداد جوابها و راه‌حل‌های مسئله است و هر راه‌حل در تعامل با سایر راه‌حل‌ها سعی در یافتن جواب بهینه دارد. در الگوریتم یادگیری کلاغ، اندازه جمعیت برابر n ، احتمال تقویت یادگیری در کلاغ برابر Rpprob، احتمال یادگیری اجتماعی در کلاغها برابر Slprob، احتمال یادگیری عمودی در کلاغها برابر

در این رابطه، RW برای آنکه بتوان مقدار پاداش را تعیین نمود نیاز است که ضرایب آلفا و بتا مانند رابطه (۱۷) و (۱۸) تنظیم شوند:

$$\alpha = |X_{ij}(t) - X_{ij}(t - 1)|$$

$$\beta = X_{ij}(t - 1) \times \exp(-lf \times r \times t \times \text{mean}(j))$$

برای محاسبه مقدار آلفا نیاز است که موقعیت فعلی و قبلی یک راه‌حل را از هم کم کرد. برای محاسبه β میانگین یک بعد نظیر j با $\text{mean}(j)$ محاسبه شده و r یک عدد تصادفی بین صفر و یک است و lf مقدار فاکتور یادگیری در کلاخ‌ها است که مطابق رابطه (۱۹)، فرموله می‌شود:

$$lf = lf_{min} + ((lf_{max} - lf_{min}) / Max_t) \times t$$

در این معادله، lf_{min} کمترین ضریب یادگیری در کلاخ‌ها و lf_{max} بیشترین ضریب یادگیری در جمعیت کلاخ‌ها است. در این رابطه، Max_t بیشترین شماره تکرار در الگوریتم پیشنهادی است. میزان پاداش به کلاخ-ها را می‌توان بر اساس معادله رابطه (۲۰)، فرموله نمود:

$$RW = \begin{cases} \beta - \alpha & \text{if } i < n/2 \\ r1 \times ((r2 \times \beta) - \alpha) & \text{otherwise} \end{cases}$$

بعد از ارایه پاداش به کلاخ‌ها می‌توان مکانیزم تقویت یادگیری را در الگوریتم یادگیری کلاخ اعمال نمود. تقویت یادگیری برای والدین در الگوریتم کلاخ استفاده می‌شود که رابطه (۲۱)، برای آن فرموله شده است.

$$X_{ij}(t)$$

$$= \begin{cases} X_{ij}(t - 1) - [X_{1j}(t - 1) + \exp(r1 \times \text{mean}(j) - X_{ij}(t - 1))] & i = 1 \\ X_{ij}(t - 1) - [r2 \times X_{1j}(t - 1) + \exp(r1 \times \text{mean}(j) - X_{ij}(t - 1))] & i = 2 \end{cases}$$

رابطه (۲۲)، استفاده می‌شود:

$$x^{i,iter+1} = x^{i,iter} + r_i \times fl^{i,iter} \times (m^{j,iter} - x^{i,iter})$$

در این رابطه، r_i یک عدد تصادفی در بازه $[0,1]$ است و از طرفی $fl^{i,iter}$ طول پرواز یا گام پروازی برای کلاخ شماره i در تکرار $iter$ است. در این رابطه، موقعیت فعلی یک کلاخ قبل از سرقت غذای سایر

عادی یا کلاخ‌های خواهر و برادر شناخته می‌شوند. در الگوریتم یادگیری کلاخ دو فاز یادگیری افقی و عمودی وجود دارد. یادگیری عمودی به یادگیری گفته می‌شود که کلاخ‌ها از پدر یا مادر دارند و یادگیری افقی نیز مرتبط با یادگیری کلاخ‌ها از برادران و خواهران خود است که این موضوع در رابطه (۱۴)، نمایش داده شده است.

$$X_{ij}(t) = X_{kj}(t - 1)$$

for Vertical - Learning: $k = 1$ or 2

for Horizontal - Learning: $3 \leq k \leq i - 1$

در این روابط، t شماره تکرار فعلی و $t - 1$ شماره تکرار قبلی الگوریتم یادگیری کلاخ است و k شماره یک عضو جمعیت الگوریتم کلاخ است که برای پدر و مادر k برابر ۱ یا ۲ است. در یادگیری افقی یک کلاخ نیاز است که یک کلاخ را تصادفی از جمعیت خواهر و برادران خود انتخاب نماید و سپس در راستای این کلاخ پرواز نماید. برای انتخاب خواهر یا برادر به صورت تصادفی از رابطه (۱۵)، استفاده می‌شود.

$$k = 3 + [\text{rand} \times (i - 3)] \ \& \ i \geq 3$$

در الگوریتم یادگیری کلاخ بعد از فرآیند یادگیری به برخی از اعضای جمعیت با دادن غذا می‌توان پاداش داد که مکانیزم پاداش مطابق رابطه (۱۶)، فرموله می‌شود. در الگوریتم یادگیری کلاخ احتمال دریافت پاداش برای کلاخ‌ها برابر Rpprob است:

$$X_{ij}(t) = X_{ij}(t) \pm RW$$

۲۱

در این رابطه، برای تقویت یادگیری روی کلاخ والد شماره یک یا $i=1$ که همان پدر است از رابطه اول استفاده می‌شود و برای تقویت یادگیری کلاخ والد دوم یا مادر از رابطه دوم استفاده می‌گردد. در الگوریتم پیشنهادی رفتار جستجوی کلاخ‌ها بعد از فاز یادگیری اعمال می‌شود. برای جستجوی غذا با مکانیزم سرقت از

شده است. یک شبکه عصبی مصنوعی دو لایه که در هر لایه آن ۲۰ نورون قرار دارد استفاده می‌شود. در پیاده‌سازی‌ها ۷۰٪ از نمونه‌ها از نوع آموزشی و ۳۰٪ دیگر از نوع آزمون است. اندازه جمعیت نیز برابر ۲۰ و تعداد تکرار الگوریتم بهینه‌سازی کلاغ نیز برابر ۵۰ است و هر آزمایش را ۳۰ مرتبه تکرار نموده و متوسط شاخص‌های مانند دقت و خطا را محاسبه نموده و با روش‌های مشابه در نهایت مورد مقایسه قرار خواهیم داد.

برای پیاده‌سازی شبکه عصبی LSTM از پارامترهای شکل (۵)، استفاده می‌شود. در روش پیشنهادی داده‌های مجموعه داده نرمالیزه شده و به عنوان ورودی روش پیشنهادی مورد استفاده قرار گرفته می‌شوند.

کلاغ‌ها برابر $x^{i,iter}$ و موقعیت جدید آن برابر $x^{i,iter+1}$ است.

پیاده‌سازی و تحلیل

برای پیاده‌سازی روش پیشنهادی از محیط برنامه‌نویسی متلب و جعبه ابزار شبکه عصبی مصنوعی استفاده می‌شود. در ادامه روش پیشنهادی در محیط متلب پیاده‌سازی شده و نتایج آزمایشات با روش‌های مشابه مورد مقایسه قرار خواهد گرفت.

پارامترهای پیاده‌سازی

برای پیاده‌سازی روش پیشنهادی از پارامترهای جدول (۱)، استفاده می‌شود. در جدول پارامترها، مقدار برخی از آنها بر اساس مقاله کلاغ تنظیم شده است و تعدادی دیگر از آنها مانند شبکه عصبی با آزمون و خطا محاسبه

جدول (۱): پارامترهای پیاده‌سازی روش پیشنهادی

Parameter	Value
No. of crows within a family	20
Maximum No. of Iterations	50
Reinforcement Probability	0.9
Social Learning Probability	0.99
Vertical Learning Probability	0.99
First Parent Selection Probability	0.95
Trial and Error Probability	0.3
lfmin	0.0005
lfmax	0.02
Layers of ANN	2
Hidden layer neurons	20

layers =

6×1 **Layer** array with layers:

- 1 'input1' Sequence Input Sequence input with 13 dimensions
- 2 'input2' LSTM LSTM with 100 hidden units
- 3 'input3' BiLSTM BiLSTM with 100 hidden units
- 4 'input11' Fully Connected 1 fully connected layer
- 5 " Fully Connected 1 fully connected layer
- 6 " Regression Output mean-squared-error

شکل ۵: پارامترهای پیاده‌سازی LSTM در روش پیشنهادی

شاخصهای ارزیابی

یکی از شاخص‌های مهم برای پیش‌بینی شرایط آب و هوایی شاخص متوسط مجذور خطای MSE است و به صورت رابطه (۲۳)، فرموله می‌گردد و از طرفی برای ارزیابی روش پیشنهادی می‌توان از شاخص‌های طبقه-بندی و پیش‌بینی دقت، یادآوری و صحت مانند رابطه (۲۴)، (۲۵) و (۲۶) استفاده نمود:

$$MSE = \frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{n}$$

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

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

$$Precision = \frac{TP}{(TP + FP)}$$

در این روابط، y_i برابر شماره کلاس یک نمونه نظیر نمونه i -ام از نظر وضعیت بارانی و عادی است و \bar{y}_i برابر شماره پیش‌بینی کلاس یک نمونه نظیر نمونه i -ام از نظر عادی و بارانی است و n برابر تعداد نمونه‌های ارزیابی بکار گرفته شده است. برای محاسبه دقت نیاز است که نمونه‌های صحیح مثبت (TP)، نمونه‌های غلط مثبت (FP)، نمونه‌های صحیح منفی (TN) و نمونه‌های غلط منفی (FN) محاسبه شوند.

تحلیل روش پیشنهادی


روش پیشنهادی برای پیش‌بینی شرایط آب و هوایی در نرم‌افزار متلب ۲۰۲۱ مورد پیاده‌سازی قرار گرفته شده است. یک شاخص مهم برای ارزیابی روش پیشنهادی تحلیل خطا در فاز انتخاب ویژگی و خطای یادگیری LSTM است. در نمودار شکل (۶) به ترتیب خطای پیش‌بینی در فاز انتخاب ویژگی در ترکیب با شبکه عصبی نمایش داده شده است و در شکل (۷)، نیز خروجی یادگیری عمیق LSTM در پیش‌بینی وضعیت آب و هوایی به تصویر کشیده شده است.

شاخص خطای RMSE که در خروجی‌ها مشاهده می‌شود در واقع مجذور خطای MSE است. در نمودار


شکل (۶)، تعداد تکرار در این آزمایش برابر ۱۰ نظر گرفته شده است و الگوریتم یادگیری کلاغ در ۱۰ تکرار در حال اجرا است و فاز انتخاب ویژگی توانسته در این آزمایش خطای پیش‌بینی وضعیت آب و هوایی را از ۰.۰۵۵ به حدود ۰.۰۳۳ کاهش دهد که به دلیل بهینه نمودن بردارهای ویژگی است. بردارهای ویژگی بهینه به عنوان ورودی یادگیری شبکه LSTM در نظر گرفته می‌شود و شبکه LSTM نیز آموزش داده می‌شود و این موضوع باعث شده است که خطای پیش‌بینی وضعیت آب و هوایی در حال کاهش باشد.

آزمایشات نشان می‌دهد خطای MSE روش پیشنهادی در تشخیص و پیش‌بینی شرایط آب و هوایی برابر ۰.۰۳۲۵ است و این در حالی است که شبکه عصبی چند لایه، شبکه عصبی بازگشتی و روش LSTM به ترتیب دارای خطای پیش‌بینی برابر ۰.۰۷۹۲، ۰.۰۹۰۳۵ و ۰.۰۸۹۲ است. آزمایشات نشان داد روش پیشنهادی در پیش‌بینی وضعیت آب و هوایی دارای دقتی برابر ۹۶.۹۲٪، یادآوری یا حساسیت برابر ۹۵.۸۲٪ و صحتی برابر ۹۶.۳۴٪ است. در جدول (۲)، شاخص‌های ارزیابی روش پیشنهادی برای پیش‌بینی شرایط آب و هوایی نشان داده شده است. در نمودار شکل (۸)، (۹)، (۱۰) و (۱۱) به ترتیب شاخص خطای پیش‌بینی، دقت، یادآوری یا حساسیت و صحت روش پیشنهادی با شبکه عصبی چند لایه، شبکه عصبی بازگشتی و روش LSTM مورد مقایسه قرار گرفته شده است.

تحلیل نمودار خطای پیش‌بینی نشان می‌دهد شاخص خطای پیش‌بینی در شبکه عصبی چند لایه، شبکه عصبی بازگشتی و روش LSTM و روش پیشنهادی به ترتیب ۰.۰۷۹، ۰.۰۹۰۴، ۰.۰۸۹ و ۰.۰۳۳ است و کمترین خطا مرتبط با روش پیشنهادی است و در مرتبه بعدی LSTM قرار دارد و بدترین روش نیز روش RBF است.




شکل ۶: کاهش یافتن خطای پیش بینی در فاز انتخاب ویژگی




شکل ۷: کاهش یافتن خطای پیش بینی در فاز طبقه بندی با LSTM

جدول ۲- متوسط شاخص‌های پیش‌بینی روش پیشنهادی

روش	MLP	RBF	LSTM	LSTMCrow
دقت	۹۱.۳۳	۸۸.۰۹	۹۳.۲۱	۹۶.۹۲
حساسیت	۹۰.۵۹	۸۷.۶۶	۹۲.۵۴	۹۵.۸۲
صحت	۹۰.۸۸	۸۶.۹۱	۹۲.۶۲	۹۶.۳۴
خطای پیش‌بینی	۰.۰۷۹۲	۰.۹۰۳۵	۰.۰۸۹۲	۰.۰۳۲۵



شکل ۸: مقایسه خطای MSE روش پیشنهادی با روش‌های پیش‌بینی



شکل ۹: مقایسه دقت روش پیشنهادی با روش‌های پیش‌بینی

۸۶.۹۱٪، ۹۲.۶۲٪ و ۹۶.۳۴٪ است. بهترین عملکرد در شاخص‌های خطا، دقت، حساسیت و صحت برای پیش بینی وضعیت آب و هوایی مرتبط با روش پیشنهادی است و بدترین عملکرد نیز مرتبط با شبکه RBF است.

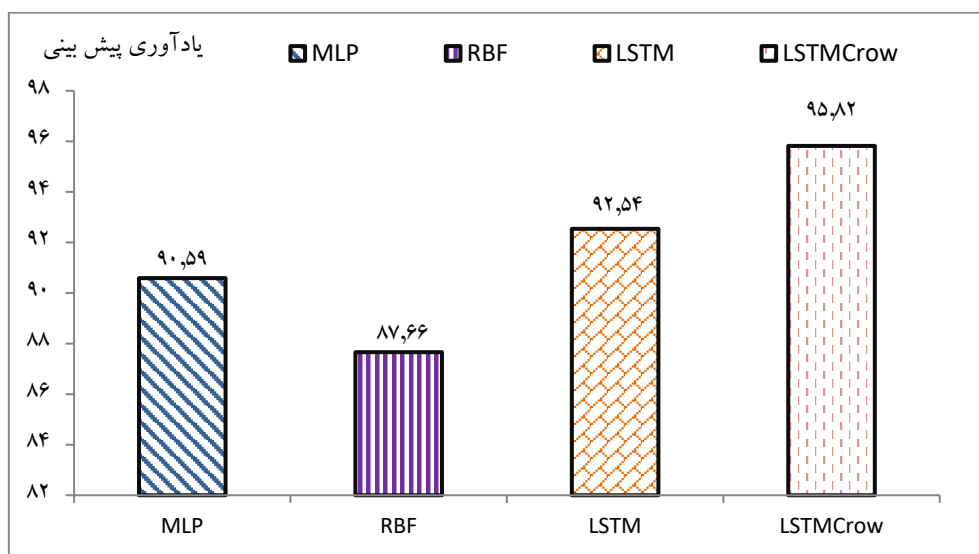
برای ارزیابی روش پیشنهادی برای پیش بینی وضعیت آب و هوایی، روش پیشنهادی در شاخص دقت با روشهای CNN، CNN+DT، CNN+SVM، MeteCNN مورد مقایسه قرار گرفته شده است [۲۶].

ارزیابی‌ها نشان می‌دهد دقت روش پیشنهادی برابر ۹۶.۹۲٪ است و دقت CNN، CNN+DT، CNN+SVM، MeteCNN به ترتیب برابر ۹۲٪، ۹۳٪، ۹۴٪ و ۹۲٪ است و روش پیشنهادی دارای دقت بیشتری در پیش بینی نسبت به روشهای CNN، CNN+DT، CNN+SVM، MeteCNN است.


تحلیل نمودار دقت نشان می‌دهد شبکه عصبی چند لایه، شبکه عصبی بازگشتی و روش LSTM و روش پیشنهادی دارای شاخص دقت به ترتیب برابر ۸۸.۰۹٪، ۹۱.۳۳٪، ۹۳.۲۱٪ و ۹۶.۹۲٪ است و در بین این روش‌ها بهترین عملکرد مرتبط با روش پیشنهادی و سپس روش LSTM و سپس روش MLP است.

شاخص یادآوری یا حساسیت برای پیش بینی شرایط آب و هوایی در شبکه عصبی چند لایه، شبکه عصبی بازگشتی و روش LSTM و روش پیشنهادی به ترتیب برابر ۹۰.۵۹٪، ۸۷.۶۶٪، ۹۲.۵۴٪ و ۹۵.۸۲٪ است و بهترین عملکرد نیز مرتبط با روش پیشنهادی است و بدترین عملکرد در این شاخص را نیز شبکه RBF دارد.


شاخص صحت برای پیش بینی وضعیت آب و هوایی در شبکه عصبی چند لایه، شبکه عصبی بازگشتی و روش LSTM و روش پیشنهادی به ترتیب برابر ۹۰.۸۸٪،



شکل ۱۰: مقایسه یادآوری روش پیشنهادی با روشهای پیش بینی



شکل ۱۱: مقایسه صحت روش پیشنهادی با روشهای پیش بینی



شکل ۱۲: مقایسه شاخص دقت روش پیشنهادی در پیش بینی آب و هوایی

شبکه را با ویژگی‌های مهم آموزش داد. در روش پیشنهادی برای افزایش دقت پیش بینی شبکه عصبی LSTM از انتخاب هوشمندانه ویژگی با استفاده از ترکیب الگوریتم یادگیری کلاغ و جستجوی کلاغ استفاده شده است. در روش پیشنهادی شبکه LSTM نقش پیش بینی روی ویژگی‌های مهم را دارد. آزمایشات نشان داد روش پیشنهادی برای پیش بینی وضعیت آب و هوایی دارای دقتی برابر ۹۶.۹۲٪،

نتیجه‌گیری

یکی از کاربردهای مهم یادگیری ماشین و یادگیری عمیق در پیش بینی رویدادها است. یکی از رویدادهای که پیش بینی آن برای بشر مهم است، پیش بینی وضعیت آب و هوایی است. شبکه LSTM یک روش یادگیری عمیق است که می‌توان به کمک آن شرایط آب و هوایی را پیش بینی نمود اما برای کاهش دادن خطای پیش بینی می‌توان ورودی‌های

- for Photovoltaic Energy Systems (pp. 421-438). Springer, Cham.
9. Dhiman, G., & Kumar, V. (2018). Emperor penguin optimizer: A bio-inspired algorithm for engineering problems. *Knowledge-Based Systems*, 159, 20-50.
 10. Wang, Y., & Du, T. (2020). A Multi-objective Improved Squirrel Search Algorithm based on Decomposition with External Population and Adaptive Weight Vectors Adjustment. *Physica A: Statistical Mechanics and its Applications*, 542, 123526.
 11. Arora, S., & Singh, S. (2019). Butterfly optimization algorithm: a novel approach for global optimization. *Soft Computing*, 23(3), 715-734.
 12. Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., & Chen, H. (2019). Harris hawks optimization: Algorithm and applications. *Future generation computer systems*, 97, 849-872.
 13. Kamboj, V. K., Nandi, A., Bhadoria, A., & Sehgal, S. (2020). An intensify Harris Hawks optimizer for numerical and engineering optimization problems. *Applied Soft Computing*, 89, 106018.
 14. Shadravan, S., Naji, H. R., & Bardsiri, V. K. (2019). The Sailfish Optimizer: A novel nature-inspired metaheuristic algorithm for solving constrained engineering optimization problems. *Engineering Applications of Artificial Intelligence*, 80, 20-34.
 15. Li, S., Chen, H., Wang, M., Heidari, A. A., & Mirjalili, S. (2020). Slime mould algorithm: A new method for stochastic optimization. *Future Generation Computer Systems*.
 16. 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.
 17. 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.
 18. Vuyyuru, V. A., Rao, G. A., & Murthy, Y. V. (2021). A novel weather prediction model using a hybrid mechanism based on MLP and VAE with fire-fly optimization algorithm. *Evolutionary Intelligence*, 14(2), 1173-1185.
 19. Sharapov, R. V. (2022, May). Using Linear Regression for Weather Prediction. In *2022 Wave Electronics and its Application in یادآوری یا حساسیت برابر ۹۵.۸۲٪ و صحتی برابر ۹۶.۳۴٪*. روش پیشنهادی دارای دقت بیشتری برای پیش بینی شرایط آب و هوایی نسبت به شبکه عصبی چند لایه، شبکه عصبی بازگشتی و روش LSTM است. از پیشنهادات ما برای پژوهش آینده استفاده از یادگیری عمیق مبتنی بر شبکه CNN و GAN است.

منابع

1. Karimzadeh Parizi, M., Keynia, F., & Khatibi Bardsiri, A. (2020). Woodpecker Mating Algorithm (WMA): a nature-inspired algorithm for solving optimization problems. *International Journal of Nonlinear Analysis and Applications*, 11(1), 137-157.
2. Xue, J., & Shen, B. (2020). A novel swarm intelligence optimization approach: sparrow search algorithm. *Systems Science & Control Engineering*, 8(1), 22-34.
3. Dhiman, G., & Kumar, V. (2019). Spotted hyena optimizer for solving complex and non-linear constrained engineering problems. In *Harmony search and nature inspired optimization algorithms* (pp. 857-867). Springer, Singapore.
4. Divya, S., Kiran, E. L., Rao, M. S., & Vemulapati, P. (2020). Prediction of Gene Selection Features Using Improved Multi-objective Spotted Hyena Optimization Algorithm. In *Data Communication and Networks* (pp. 59-67). Springer, Singapore.
5. Mirjalili, S., Mirjalili, S. M., Saremi, S., & Mirjalili, S. (2020). Whale optimization algorithm: theory, literature review, and application in designing photonic crystal filters. In *Nature-Inspired Optimizers* (pp. 219-238). Springer, Cham.
6. Elaziz, M. A., & Mirjalili, S. (2019). A hyper-heuristic for improving the initial population of whale optimization algorithm. *Knowledge-Based Systems*, 172, 42-63.
7. Faris, H., Aljarah, I., Al-Betar, M. A., & Mirjalili, S. (2018). Grey wolf optimizer: a review of recent variants and applications. *Neural computing and applications*, 30(2), 413-435.
8. Davoodkhani, F., Nowdeh, S. A., Abdelaziz, A. Y., Mansoori, S., Nasri, S., & Alijani, M. (2020). A New Hybrid Method Based on Gray Wolf Optimizer-Crow Search Algorithm for Maximum Power Point Tracking of Photovoltaic Energy System. In *Modern Maximum Power Point Tracking Techniques*

24. Tukymbekov, D., Saymbetov, A., Nurgaliyev, M., Kutybay, N., Dosymbetova, G., & Svanbayev, Y. (2021). Intelligent autonomous street lighting system based on weather forecast using LSTM. *Energy*, 231, 120902.
25. Fu, J., Chu, J., Guo, P., & Chen, Z. (2019). Condition monitoring of wind turbine gearbox bearing based on deep learning model. *Ieee Access*, 7, 57078-57087.
26. Sampaio, P. S., Almeida, A. S., & Brites, C. M. (2021). Use of artificial neural network model for rice quality prediction based on grain physical parameters. *Foods*, 10(12), 3016.
- Information and Telecommunication Systems (WECONF) (pp. 1-4). IEEE.
20. Yalçın, S. (2022). Weather parameters forecasting with time series using deep hybrid neural networks. *Concurrency and Computation: Practice and Experience*, e7141.
21. Suleman, M. A. R., & Shridevi, S. (2022). Short-term weather Forecasting using Spatial Feature Attention based LSTM model. *IEEE Access*.
22. Chandra, R., Jain, A., & Singh Chauhan, D. (2022). Deep learning via LSTM models for COVID-19 infection forecasting in India. *PloS one*, 17(1), e0262708.
23. Mehtab, S., & Sen, J. (2022). Analysis and forecasting of financial time series using CNN and LSTM-based deep learning models. In *Advances in Distributed Computing and Machine Learning* (pp. 405-423). Springer, Singapore.