

ادغام داده‌های سنجش‌ازدوری و هواشناسی جهت پیش‌بینی زمانی سیلاب با استفاده از الگوریتم یادگیری عمیق

فاطمه حسین‌زاده^۱، حمید عبادی^۲، عباس کیانی^{۳*}

۱- دانشجوی کارشناس ارشد، گروه فتوگرامتری و سنجش‌ازدور، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

۲- استاد گروه فتوگرامتری و سنجش‌ازدور، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

۳- استادیار دانشکده مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل

تاریخ دریافت مقاله: ۱۳۹۹/۰۹/۲۲ تاریخ پذیرش مقاله: ۱۴۰۰/۰۳/۱۸

چکیده

پیش‌بینی دقیق سیلاب نیازی اساسی جهت کاهش خطرات آن می‌باشد ولی به دلیل ساختار پیچیده سیلاب و جریان رودخانه، عملاً پیش‌بینی دقیق طغیان و تخلیه رودخانه مسأله‌ای دشوار است. شبکه‌های عصبی مصنوعی مانند شبکه‌های عصبی مکرر، عملکرد بسیار خوبی در داده‌های سری زمانی دارند. در سال‌های اخیر استفاده از شبکه‌های حافظه طولانی کوتاه مدت به دلیل رفع معایب شبکه‌های عصبی مکرر توجه زیادی را به خود جلب کرده است. در این مطالعه سعی بر پیش‌بینی دبی روزانه ایستگاه آق‌قلا در استان گلستان تا سه روز آینده، با استفاده از شبکه حافظه طولانی کوتاه مدت شده است. این شبکه به دلیل ساختار ویژه و توانایی یادگیری وابستگی‌های طولانی مدت، جهت پیش‌بینی‌های سری زمانی بسیار مناسب می‌باشد. از طرفی شبکه مورد نظر شبکه‌ای پایدار و شامل حداکثر پارامترهای پیش‌فرض بوده که این امر نشان‌گر قابلیت استفاده از آن برای دیگر مناطق می‌باشد. همچنین این الگوریتم توانایی استفاده از توپوگرافی و داده‌های دبی سایر ایستگاه‌های منطقه را دارد. جهت پیش‌بینی دبی در ایستگاه هدف چندین ترکیب داده؛ داده‌های دبی ایستگاه آق‌قلا به صورت تنها و به همراه ایستگاه‌های بالادست آن، مدل ارتفاعی شهرستان آق‌قلا و استان گلستان، به عنوان ورودی شبکه استفاده شده‌اند. در ادامه یافته‌های مطالعه حاضر با شبکه‌های رگرسیون ساده، رگرسیون ماشین بردار پشتیبان و شبکه عصبی مکرر ساده مقایسه گردید. نتایج حاکی از برتری شبکه حافظه طولانی کوتاه مدت، با مقادیر پارامتر نش-ساتکلیف بالای ۰.۹۱، نسبت به سایر شبکه‌ها می‌باشد. در مطالعات بعدی سعی بر استفاده از سایر داده‌های تاثیرگذار بر وقوع سیلاب و همچنین توسعه شبکه مورد استفاده به شبکه‌ای کاملاً خودکار می‌باشد.

کلید واژه‌ها: پیش‌بینی سیل، سنجش‌ازدور، دبی، یادگیری عمیق، *LSTM*.

* نویسنده مکاتبه کننده: گروه نقشه‌برداری، دانشکده مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل، خیابان شریعتی، بابل، مازندران.

۱- مقدمه

پدیده سیل از جمله بلایای طبیعی پررخداد در کشور محسوب می‌گردد که در طی سال‌های اخیر با دخالت عوامل انسانی، تعداد و میزان آن شدت پیدا کرده است. پیش‌بینی دقیق سیل یک نیاز اساسی جهت کاهش خطر بروز سیل است که برای مدیریت سیستم‌های منابع آب از اهمیت ویژه‌ای برخوردار می‌باشد. با این حال پیش‌بینی دقیق تخلیه رودخانه به دلیل پیچیده بودن تجزیه و تحلیل سیل و غیرخطی بودن روند جریان رودخانه مسئله‌ای دشوار است [۱].

در حال حاضر دو روش جهت پیش‌بینی سیلاب وجود دارد [۱]. روش اول که به طور گسترده مورد استفاده قرار می‌گیرد روند جریان آب را شبیه‌سازی می‌کند. این روش‌ها معمولاً به حجم زیادی از داده‌ها مانند داده‌های توپوگرافی، تصاویر هوایی و ماهواره‌ای با قدرت تفکیک مکانی مناسب نیاز دارند که همیشه در دسترس نیستند و یا دسترسی به آن‌ها مشکل است. اشکال دیگر این مدل‌ها این است که به جریان‌های مناطق بالاتر توجه نمی‌کنند [۲ و ۳]. روش دوم روش‌های مبتنی بر داده است. این روش‌ها مانند شبکه‌های یادگیری عمیق رابطه آماری بین داده‌های ورودی و خروجی را شناسایی و به پیش‌بینی متغیر مورد نظر می‌پردازد. این روش برخلاف رویکرد پیشین مشکل دسترسی به تعداد متنوعی از داده‌ها مانند داده‌های توپوگرافی و یا تصاویر با قدرت تفکیک مکانی بالا را ندارد [۴ و ۵].

یکی از مدل‌های مناسب جهت پیش‌بینی سری‌های زمانی، شبکه‌های عصبی^۱ بوده‌اند. تحقیقات زیادی در خصوص پیش‌بینی مولفه‌های هیدرولوژیکی با استفاده از شبکه‌های عصبی مصنوعی انجام شده است [۶ و ۷]. با این وجود نواقص آن‌ها در مواجهه با کارهای پیچیده با ابعاد و واریانس بالا مشخص شد. یادگیری

عمیق متشکل از چندین لایه پردازش جهت یادگیری با چندین سطح می‌باشد که اکنون برای غلبه بر مشکلات پیش‌رو به وجود آمده‌است. از مزایای شبکه‌های یادگیری عمیق، عملکرد خوب آن‌ها در داده‌های سری‌زمانی است [۸]. در سال ۱۳۹۵ مطالعه‌ای توسط رحیمی و همکاران در خصوص پیش‌بینی زمانی و مکانی بارش ماهانه در شمال غرب ایران با استفاده از داده‌های بارش روزانه طی ۶۳ سال، از سال ۱۹۵۱ الی سال ۲۰۱۴ انجام گردید. جهت این امر از دو روش شبکه عصبی کم‌عمق و شبکه باور عمیق^۲ استفاده شده‌است. در نهایت مشخص شده‌است که شبکه باور عمیق در هنگام مواجهه با کلان داده‌های مکانی و زمانی و حل پیچیدگی‌های مسئله پیش‌بینی بارش ماهانه از توانایی بیشتری برخوردار می‌باشد [۹].

حافظه طولانی کوتاه مدت (*LSTM*)^۳ نوع خاصی از شبکه‌های عصبی مکرر می‌باشد که توسط هوچرپرتر و اشمیتدور در سال ۱۹۹۷ جهت غلبه بر ضعف شبکه عصبی مکرر سنتی معرفی شده‌است [۱۰]. در سال ۲۰۱۸ با استفاده از داده‌های روزانه ۷ عامل، به پیش‌بینی سطح آب دریاچه دونگتینگ چین پرداخته شده‌است. این تحقیق با استفاده از شبکه‌های *LSTM* و ماشین بردار پشتیبان^۴ انجام شد. داده‌های سال‌های ۲۰۰۳ الی ۲۰۱۲ جهت آموزش و سال‌های ۲۰۱۱ الی ۲۰۱۳ جهت ارزیابی شبکه تقسیم شده‌اند. با ارزیابی شبکه توسط مقادیر خطای جذر میانگین مربعات^۵ و ضریب تعیین به برتری *LSTM* نسبت به ماشین بردار پشتیبان پی برده شده‌است [۱۱]. در همین سال در چین جهت شبیه‌سازی بارش رواناب با استفاده از داده‌های ۱۵ ایستگاه در طی ۴۲ سال به مقایسه شبکه‌های عصبی مصنوعی و *LSTM* پرداخته شده‌است. به طور کلی هر دو این شبکه‌ها جهت مدل‌سازی بارش

^۴ Support vector machine

^۵ Root Mean Square Error

^۱ Artificial Neural Network

^۲ Deep belief network

^۳ Long Short Term Memory

استفاده قادر به استفاده از توپوگرافی منطقه و داده‌های دبی در ایستگاه‌های بالادست، به دلیل بررسی تاثیر نوسانات این ایستگاه‌ها بر ایستگاه هدف علاوه بر داده‌های دبی در ایستگاه هدف می‌باشد. جهت این امر از داده‌های دبی مربوط به ۳۰ سال، مدل ارتفاعی منطقه و الگوریتم *LSTM* استفاده شده‌است. همچنین با توجه به آزمایشات صورت گرفته در خصوص آنالیز حساسیت، این شبکه از پایداری و استحکام بالایی برخوردار می‌باشد. در پایان، عملکرد شبکه موردنظر با شبکه‌های عصبی مصنوعی مکرر ساده، رگرسیون خطی و رگرسیون ماشین‌بردار پشتیبان مقایسه گردید. نتایج این مطالعه نشان داده‌است که شبکه *LSTM* برای پیش‌بینی سیلاب منطقه‌ای که ایستگاه هیدرومتری فعال حداقل از یک دهه اخیر داشته باشد می‌تواند نتایج قابل قبولی ارائه دهد.

۲- مواد و روش‌ها

استان گلستان از مناطق سیل‌خیز کشور ایران است. طی سال‌های اخیر چندین سیل مخرب در این استان رخ داده که موجب تلفات انسانی و خسارات اقتصادی فراوان و جبران‌ناپذیری گردیده‌است. این امر اهمیت مطالعه حاضر را تایید می‌کند. جهت این کار، بنا به عملکرد مناسب شبکه‌های عصبی مصنوعی مانند شبکه‌های عصبی مکرر در داده‌های سری زمانی، از این شبکه‌ها استفاده خواهد شد.

۲-۱- داده و منطقه مورد مطالعه

رودخانه گرگان‌رود یکی از مهم‌ترین شاخه‌های سیل‌خیز این استان است. جهت جریان آب این رودخانه از شرق به غرب می‌باشد. این رودخانه از رشته‌کوه البرز سرچشمه گرفته و به دریای خزر می‌ریزد. شهرستان آق‌قلا واقع در استان گلستان، در طرفین رودخانه گرگان‌رود و در ۱۸ کیلومتری شمال شهر گرگان با عرض جغرافیایی $36^{\circ}58'$ و طول جغرافیایی $54^{\circ}16'$ قرار گرفته‌است.


در شکل (۱) موقعیت جغرافیایی منطقه مورد مطالعه، ایستگاه آق‌قلا به همراه ایستگاه‌های بالادست آن نشان داده شده‌است. با توجه به آمار دریافتی از سازمان مدیریت

رواناب مناسب‌اند، با این حال شبکه *LSTM* دقیق‌تر و پایدارتر از شبکه مصنوعی ساده می‌باشد [۱۲]. در سال ۲۰۱۹ مطالعه‌ای بر روی رودخانه‌ای در شمال‌غربی ویتنام انجام شد. در این مطالعه که به پیش‌بینی دبی ایستگاه هوآبین با استفاده از شبکه *LSTM* پرداخته شده از داده‌های ۲۴ ساله ایستگاه هدف و ۷ ایستگاه بالادست آن استفاده کرده‌است. این مطالعه در حداکثر ۱۰۰۰۰۰ دوره تکرار، به پیش‌بینی یک، دو و سه روزه دبی موردنظر با دقت بسیار بالا دست‌یافت [۱]. در مطالعه‌ای مشابه، مقایسه‌ای بین سه شبکه *LSTM*، واحد عود مکرر و شبکه مصنوعی ساده جهت پیش‌بینی رواناب با استفاده از داده‌های ایستگاه هدف در جنوب چین و سه ایستگاه بالادست آن طی ۱۴ سال انجام شده‌است. نتیجه حاصل شده در این مطالعه این بود که شبکه *LSTM* با یک لایه نتیجه بهتری نسبت به چند لایه دارد. علاوه بر این نتیجه اصلی این مطالعه این بود که *LSTM* و واحد عود مکرر بدون گام زمانی بهینه، کمی بهتر از شبکه مصنوعی ساده عمل می‌کنند ولی با گام زمانی بهینه، شبکه مصنوعی ساده نتیجه کمی بهتر دارد [۱۳]. در مطالعات داخل کشور می‌توان تنها به یک مورد اشاره نمود. در سال ۱۳۹۹ مطالعه‌ای در خصوص پیش‌بینی دبی ماهانه رودخانه کارون توسط احمدی و همکاران انجام شده‌است. در این مطالعه از طریق ۲۰۴ داده ماهانه دبی به آموزش شبکه *LSTM* پرداخته شده‌است. گرچه شبکه به کار برده شده دارای دقت مناسبی بوده ولی بنا به مطالعات صورت گرفته در خصوص شبکه‌های *LSTM* به نظر می‌رسد این شبکه دارای استحکام کافی نمی‌باشد [۱۴].

در مطالعه حاضر به بررسی سیلاب‌های متعدد رخ داده بر ایستگاه آق‌قلا و ایستگاه‌های بالادست آن پرداخته و دبی ایستگاه آق‌قلا، به دلیل رابطه بسیار نزدیک با وقوع سیلاب، برای یک تا سه روز آتی با دقت و سرعت اجرای مناسب پیش‌بینی شده‌است. با توجه به بررسی‌های صورت گرفته در خصوص سری زمانی، شبکه‌های *LSTM* از کارایی ویژه‌ای برخوردار هستند. شبکه مورد

در جدول (۱) مشخصات تعدادی از ایستگاه‌های بالادست شهرستان آق‌قلا آورده شده‌است. در مطالعه حاضر تاثیر این ایستگاه‌ها بر ایستگاه هدف بررسی خواهد شد.

منابع آب کشور، در خصوص سیلاب‌های رخ داده در شهرستان آق‌قلا، این منطقه دارای چندین مورد سیل در چند دهه اخیر بوده‌است. بر روی گرگان‌رود چندین ایستگاه هیدرومتری وجود دارد.



شکل ۱: منطقه جغرافیایی مورد مطالعه همراه با موقعیت ایستگاه‌های هیدرومتری واقع بر گرگان‌رود

جدول ۱: مشخصات ایستگاه‌های هیدرومتری واقع بر گرگان‌رود

ردیف	نام ایستگاه	کد ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع (متر)
۱	آق‌قلا	۱۲-۰۳۷	۵۴,۴۶۶۷	۳۷,۰۱۶۶	-۱۲
۲	سد گرگان	۱۲-۰۲۵	۵۴,۷۳۳۳	۳۷,۲	۱۲
۳	قزاقلی	۱۲-۰۲۳	۵۵,۰۱۶۷	۳۷,۲۳۳۳	۳۰
۴	گنبد	۱۲-۰۱۱	۵۵,۱۵	۳۷,۲۶۶۶	۳۶
۵	تمرگران	۱۲-۰۰۵	۵۵,۵	۳۷,۴۸۳۳	۱۳۲

داده می‌باشد که توانایی حل مشکلات از طریق نوروها را دارد [۱۵]. سرعت یادگیری پایین در لایه‌های اولیه همراه با کاهش دقت مدل، از دلایل اصلی مشکل گرادیان ناپدید شده^۱ است که از معایب آموزش شبکه‌های عصبی مصنوعی با الگوریتم پس‌انتشار می‌باشد [۱۶]. علاوه‌براین مدل شبکه عصبی مصنوعی سنتی هنگام حل مسئله داده‌های پی‌درپی مانند سری زمانی یا تکمیل جمله محدودیت اساسی دارد [۱۷]. برای حل مشکلات فوق‌الذکر شبکه عصبی مکرر معرفی شده‌است. شبکه‌های عصبی مکرر برای اولین بار در دهه ۱۹۸۰ توسعه یافتند [۱۸]. در طی فرایند آموزش یک

۲-۲-۲- مبانی تئوری تحقیق

شبکه‌های عصبی مصنوعی، از مدل‌های مناسب در پیش‌بینی سری‌های زمانی می‌باشند. با این وجود معایب آن‌ها در مواجهه با کارهای پیچیده مشخص شده‌است. شبکه LSTM نوع خاصی از شبکه‌های عصبی مصنوعی می‌باشد که جهت غلبه بر معایب شبکه‌های پیشین معرفی شده‌است. در ادامه به شرح هر یک از این شبکه‌ها پرداخته می‌شود.

۲-۲-۱- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یک سیستم محاسباتی مبتنی بر

^۱ Vanishing gradient

وزن می‌دهد.

$$i_t = \sigma(W_i [Y_{t-1}, X_t] + b_i) \quad \text{رابطه (۲)}$$

$$N_t = \tanh(W_n [Y_{t-1}, X_t] + b_n) \quad \text{رابطه (۳)}$$

$$C_t = C_{t-1} f_t + N_t i_t \quad \text{رابطه (۴)}$$

در روابط (۲)، (۳) و (۴) C_t و C_{t-1} حالت سلول در زمان t و $t-1$ ، همچنین b و W به ترتیب بایاس و وزن حالت سلول هستند. در مرحله آخر مطابق روابط (۵) و (۶) مقادیر خروجی (Y_t) که یک نسخه فیلتر شده براساس وضعیت سلول خروجی است، تولید می‌شود. در روابط (۵) و (۶) متغیرهای b_0 و W_0 به ترتیب بایاس و وزن دروازه خروجی هستند.

$$O_t = \sigma(W_o [Y_{t-1}, X_t] + b_o) \quad \text{رابطه (۵)}$$

$$Y_t = O_t + \tanh(C_t) \quad \text{رابطه (۶)}$$

۲-۲-۳- معیارهای ارزیابی مدل

جهت ارزیابی عملکرد مدل‌های پیش‌بینی در زمینه‌های هیدرولوژی اغلب از کارایی نش-ساتکلیف (NSE^f) و خطای میانگین مربعات استفاده می‌شود. با استفاده از معیار NSE توانایی پیش‌بینی مدل بر اساس اختلاف متغیرهای پیش‌بینی شده از مقدار میانگین آن‌ها (رابطه (۷)) و معیار خطای میانگین مربعات نیز برای ارزیابی مدل از جذر اختلاف مقادیر پیش‌بینی و مشاهده شده (رابطه (۸)) بررسی می‌شود [۱].

$$NSE = \left(1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2} \right) \quad \text{رابطه (۷)}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad \text{رابطه (۸)}$$

در روابط (۷) و (۸)، O_i مقادیر مشاهده شده، \bar{O}_i مقادیر میانگین مشاهده، P_i پیش‌بینی شده و n تعداد کل مشاهدات می‌باشند. مقدار NSE در بازه $[-\infty, 1]$ و

شبکه عصبی مکرر از یک الگوریتم پس‌انتشار^۱ برای محاسبه گرادیان‌ها و تنظیم ماتریس‌های وزنی استفاده می‌شود؛ بنابراین معمولاً از آن به عنوان پس‌انتشار در طول زمان^۲ یاد می‌شود. در این شبکه‌ها به دلیل انباشت گرادیان خطا در طی فرایند به‌روزرسانی شبکه ناپایدار می‌گردد [۱۹].

۲-۲-۲- شبکه عصبی حافظه کوتاه مدت

$LSTM$ تکامل یافته شبکه عصبی مکرر است که در سال ۱۹۹۷ جهت حل مشکلات شبکه‌های مکرر معرفی شد [۱۰]. این شبکه‌ها قادر به یادگیری وابستگی‌های طولانی مدت هستند. واحد $LSTM$ در زمان معین با عبور داده‌های ورودی از لایه‌های سیگموئید^۳ و تانژانت هایپربولیک^۴ و با اعمال بایاس و افزودن و مقیاس‌گذاری اطلاعات، به تولید حافظه به‌روز شده و حالت مخفی واحد $LSTM$ در زمان بعدی می‌پردازد. اولین قدم برای ساخت این شبکه مطابق رابطه (۱) شناسایی و حذف اطلاعات غیرضروری است. عملگر سیگموئید تعیین می‌کند که کدام قسمت از خروجی قدیمی باید از بین برود. به این دروازه، دروازه فراموشی^۵ (f_t) گفته می‌شود.

$$f_t = \sigma(W_f [Y_{t-1}, X_t] + b_f) \quad \text{رابطه (۱)}$$

در رابطه (۱)، σ ، W_f ، b_f به ترتیب تابع سیگموئید، ماتریس وزن و بایاس دروازه فراموشی می‌باشند. مرحله بعد تصمیم‌گیری و ذخیره اطلاعات از ورودی جدید (X_t) در حالت سلول و همچنین به‌روزرسانی حالت سلول است. این مرحله مطابق روابط (۲)، (۳) و (۴) شامل دو بخش، لایه سیگموئید و لایه تانژانت هایپربولیک است. ابتدا توسط لایه سیگموئید تصمیم گرفته می‌شود که آیا اطلاعات جدید باید به‌روز شوند یا نادیده گرفته شوند و سپس تابع تانژانت هایپربولیک به مقادیر عبور داده‌شده با توجه به میزان اهمیت آن‌ها

^۴ \tanh

^۵ Forget gate

^۶ Nash Sutcliffe Efficiency

^۱ Feed back

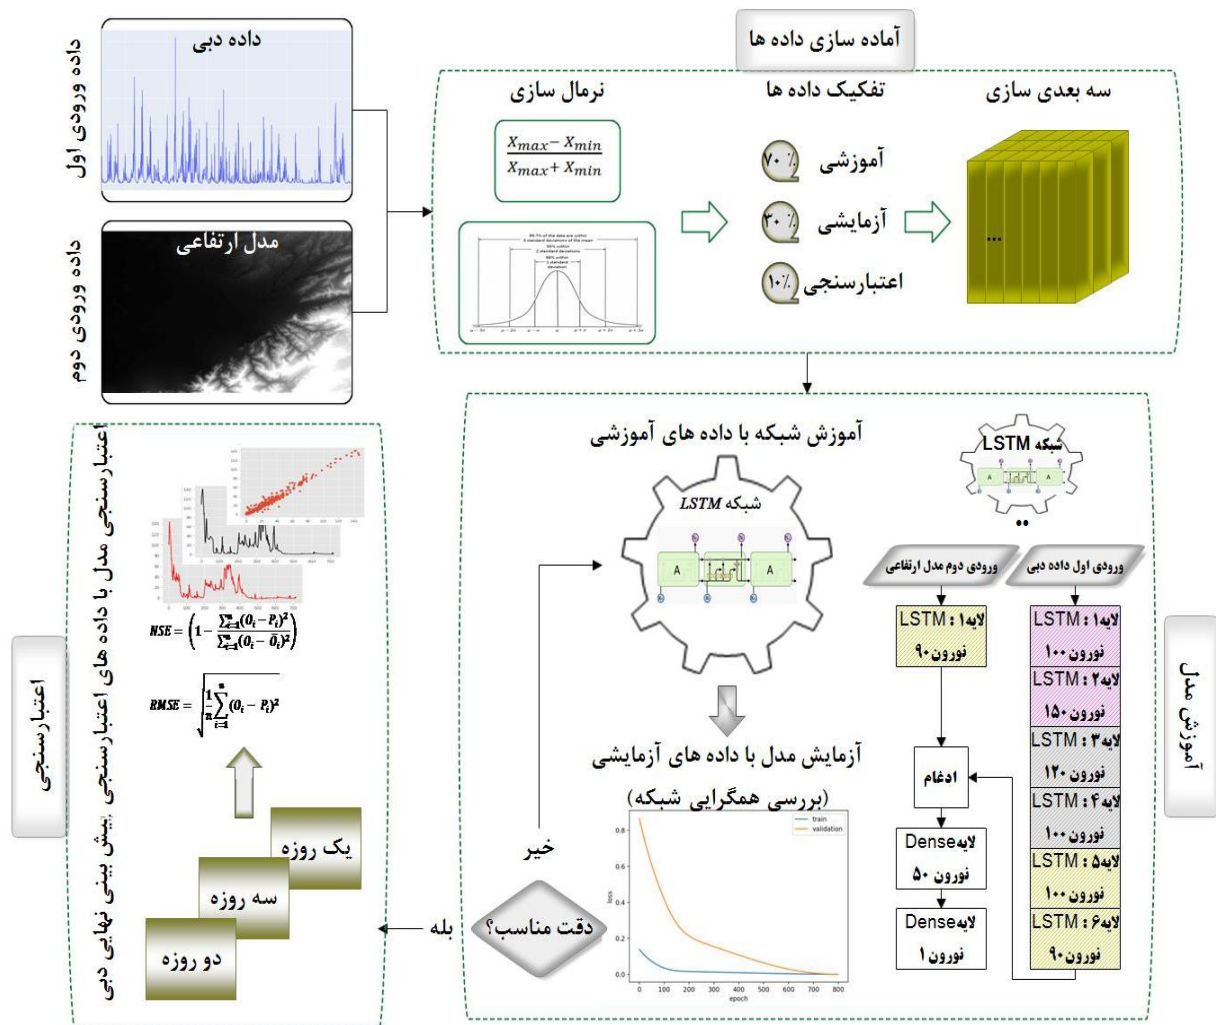
^۲ BackPropagation Through Time (BPTT)

^۳ Sigmoid

خطای میانگین مربعات در بازه [0,1] می‌باشد. بر این اساس اگر NSE به عدد یک و خطای میانگین مربعات به

۳- روش پیشنهادی

روند کلی انجام کار در شکل (۲) آورده شده است.




شکل ۲: روند نمای تحقیق

۳-۱- آماده سازی داده ها

در این مرحله ابتدا داده‌های هر ایستگاه به بازه صفر تا یک نرمال می‌گردند. سپس داده‌ها به سه دسته آموزشی (جهت آموزش شبکه)، آزمایشی (جهت آزمایش شبکه) و اعتبارسنجی (جهت برآورد دقت نهایی شبکه) تقسیم می‌شوند. در تحقیق پیش‌رو داده‌های مربوط به سال

۱۳۶۲ الی ۱۳۸۳ به عنوان داده آموزشی، سال ۱۳۸۴ الی ۱۳۹۰ به عنوان داده آزمایشی و سال‌های ۱۳۹۱ و ۱۳۹۲ به عنوان داده اعتبارسنجی تقسیم‌بندی شده‌اند. در شکل (۳) مجموع داده‌های دبی ایستگاه هدف، به تفکیک دسته‌های آموزشی، آزمایشی و اعتبارسنجی مشاهده می‌شود.



شکل ۳: داده‌های دبی ایستگاه آق‌قلا از سال ۱۳۶۲ الی ۱۳۹۲

لایه‌های *LSTM* یک لایه تراکم^۴ با تعداد یک نرون، جهت پیش‌بینی کلاس هدف ایجاد و سپس با تعریف تابع بهینه‌ساز و تابع هزینه مدل همگردانی^۵ می‌شود. در شکل نمای کلی از شبکه مورد استفاده در این مطالعه نشان داده شده‌است. در این شبکه از ۲، ۴ و ۶ لایه *LSTM* استفاده شده‌است. تعداد مشخص نرون برای هر لایه انتخاب و نتایج آن‌ها با یکدیگر مقایسه شده‌است. سپس یک لایه تراکم با تابع فعال‌سازی تانژانت هایپربولیک و واحد برابر ۱، به دلیل پیش‌بینی یک کلاس استفاده شده‌است. در نهایت مدل با استفاده از تابع بهینه‌ساز آدام^۶ با نرخ آموزش ۰/۰۰۱ و تابع هزینه خطای میانگین مربعات همگردانی گردید. قابل ذکر است نرخ آموزش استفاده شده برای تابع بهینه‌ساز آدام، مقداری پیش‌فرض می‌باشد [۲۰، ۲۱]. پس از ساخت شبکه *LSTM*، داده‌های آموزشی سه‌بعدی شده که شامل داده‌های دبی ایستگاه آق‌قلا و ایستگاه‌های بالادست و مدل ارتفاعی منطقه هستند در چند دسته وارد شبکه شده و نتایج تاثیر هر کدام مورد ارزیابی قرار می‌گیرد. تعداد دوره‌های اجرای شبکه بر روی حداکثر ۱۰۰۰ دوره تنظیم شده‌است ولی اگر طی ۵۰ دوره‌ی متوالی مقدار خطای میانگین مربعات در دسته داده‌های آزمایشی حداقل نشود، اجرای شبکه متوقف شده و بهترین وزن‌ها جهت پیش‌بینی نهایی بر روی داده‌های اعتبارسنجی در حافظه شبکه ثبت خواهند شد.

جهت ورود داده‌ها به شبکه *LSTM* بایستی بخش ورودی ساختاری سه بعدی پیدا کند. ساختار سه بعدی شامل اندازه دسته^۱، گام‌های زمانی و تعداد ویژگی‌ها در یک توالی می‌باشد. دسته دیگر از داده که در این مطالعه مورد استفاده قرار گرفته‌است، داده ارتفاعی می‌باشد. مدل ارتفاعی نیز همانند داده‌های دبی ابتدا نرمال سپس به سه دسته؛ آموزشی، ارزیابی و اعتبارسنجی تقسیم شده‌است. جهت استفاده از مدل رقومی زمین در این ناحیه از داده‌های رایگان پالسار^۲ مربوط به تاریخ ۸ ژانویه ۲۰۱۱ استفاده شده‌است. این داده‌ها با قدرت ۱۲/۵ متر در سایت آلاسکا^۳ از سال ۲۰۰۶ الی ۲۰۱۱، موجودند. در مطالعه حاضر همان‌طور که در شکل (مشخص می‌باشد از دو مدل ارتفاعی با اندازه‌های متفاوت استفاده شده‌است:

الف) مدل ارتفاعی شامل تمامی ۵ ایستگاه ذکر شده در بخش (۰)

ب) شامل تنها ایستگاه آق‌قلا.

در حالت (الف)، ارتفاع منطقه بین ۴۵- الی ۲۲۲۵ متر و در حالت (ب)، بین ۳۵- الی ۵۶ متر بوده است.

۳-۲- آموزش شبکه (تولید مدل)

شبکه می‌تواند شامل یک یا چند لایه *LSTM* باشد که در هر کدام تعدادی نرون قرار گرفته‌است. نرون‌های هر لایه پس از دریافت داده‌ها و اعمال پردازش‌های لازم آن‌ها را به لایه‌های بعد منتقل می‌کنند. پس از ایجاد

^۴ Dense


^۵ Compile

^۶ Adam

^۱ Batch size

^۲ PALSAR

^۳ ALASKA

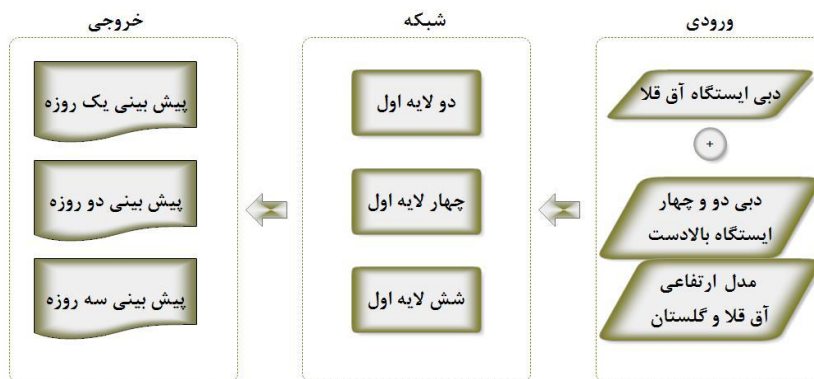


شکل ۴: مدل رقومی ارتفاعی به همراه موقعیت ایستگاه‌ها


۳-۳- اعتبارسنجی

در شکل (۵) جزئیات آزمایشات انجام شده آورده شده است. به طور کلی ۹ مجموعه داده، از قبیل؛ (۱) دبی ایستگاه آق قلا به صورت منفرد، (۲) دبی ایستگاه آق قلا به همراه دو ایستگاه بالادست، (۳) دبی ایستگاه آق قلا به همراه چهار ایستگاه بالادست، (۴) دبی ایستگاه آق قلا به همراه مدل ارتفاعی شهرستان آق قلا، (۵) دبی ایستگاه آق قلا به همراه دو ایستگاه بالادست و مدل ارتفاعی شهرستان آق قلا، (۶) دبی ایستگاه آق قلا به همراه چهار ایستگاه بالادست و مدل ارتفاعی شهرستان

آق قلا، (۷) دبی ایستگاه آق قلا به همراه مدل ارتفاعی استان گلستان، (۸) دبی ایستگاه آق قلا به همراه دو ایستگاه بالادست و مدل ارتفاعی استان گلستان، (۹) دبی ایستگاه آق قلا به همراه چهار ایستگاه بالادست و مدل ارتفاعی استان گلستان مورد بررسی قرار گرفته‌اند. در نهایت شبکه مورد نظر به پیش‌بینی یک تا سه روزه دبی ایستگاه هدف پرداخته است. با توجه به شکل (۶)، شبکه مورد نظر با استفاده از داده‌های ۱۰ روز به پیش‌بینی دبی یک، دو و یا سه روز آتی پرداخته است.



شکل ۵: نمای کلی از داده‌های مورد استفاده، تعداد لایه‌ها و پیش‌بینی‌های حاصل شده



شکل ۶: نحوه عملکرد پنجره‌ای با اندازه ۱۰ جهت پیش‌بینی دبی

۴- نتایج

ایستگاه هدف، طی ۲۰ و ۷ سال، به ترتیب مورد آموزش و آزمایش قرار گرفت. در جدول (۲)، مقادیر NSE و خطای میانگین مربعات برای مجموعه داده‌های اعتبارسنجی به همراه تعداد گام‌ها و زمان سپری شده در واحد ثانیه، در هر یک از تعداد لایه‌های شبکه برای هر کدام از مجموعه داده‌ها آورده شده‌است. در ادامه جهت سهولت در درک و فهم و تفسیر بهتر، در شکل (۷) مقادیر اعتبارسنجی و بهترین نمونه‌های پیش‌بینی شده در روش منفرد در فرم نمایش بصری مجزا به صورت تفکیک سال و فصل ارائه شده‌است.

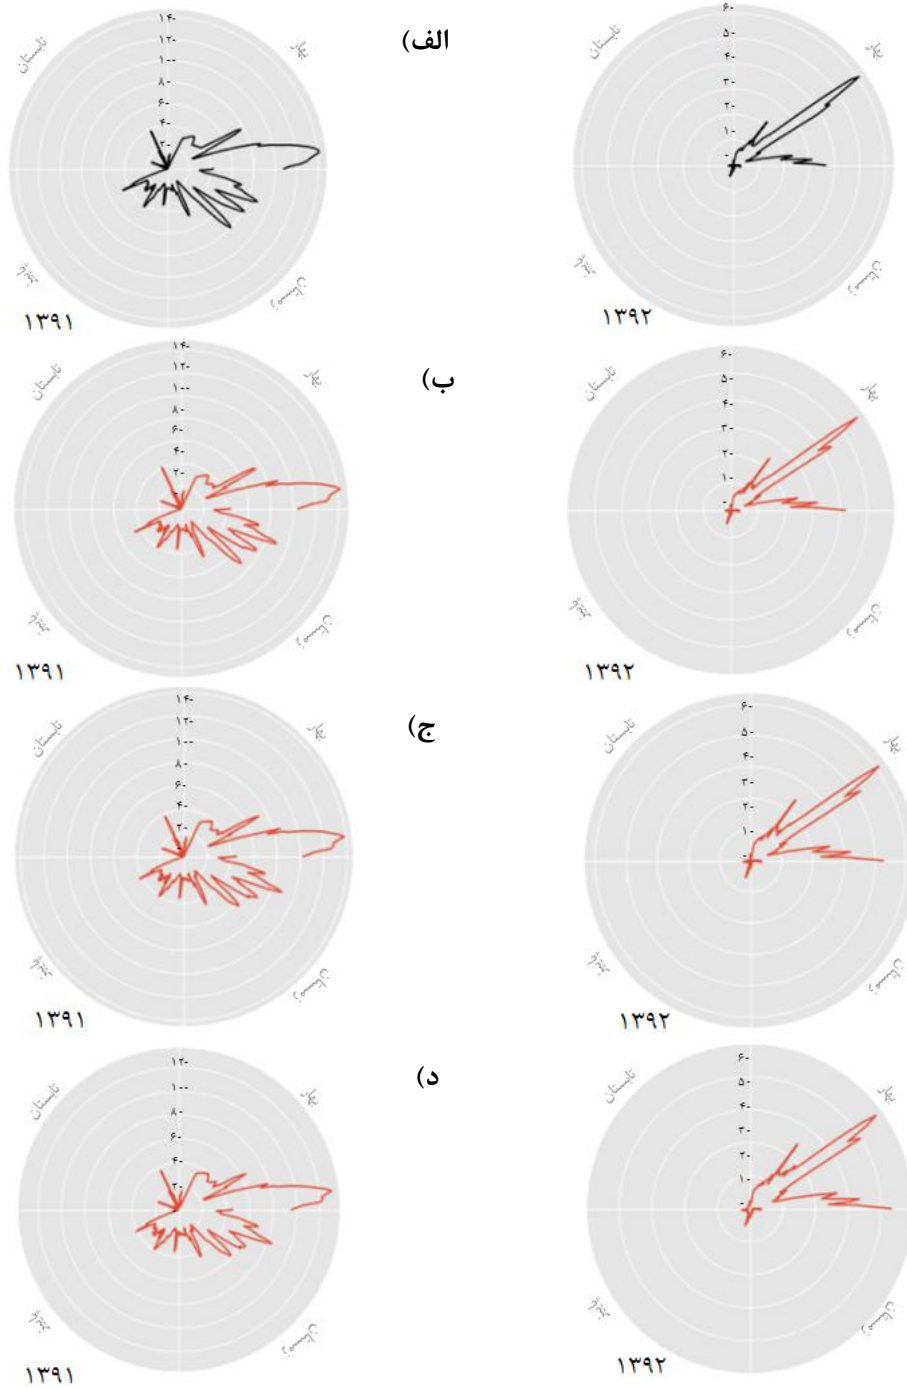
شبکه‌های آموزش دیده توسط داده‌های جداگانه و مستقل دبی سال ۱۳۹۱ و ۱۳۹۲ مورد اعتبارسنجی قرار گرفتند. برای هر یک از موارد شکل (۵) مقادیر NSE و خطای میانگین مربعات محاسبه شده‌است. جهت بررسی نتایج اعتبارسنجی در دو دسته، بررسی‌های منفرد و بررسی‌های دارای همبستگی بیان خواهند شد.

۴-۱- بررسی‌های منفرد

در مرحله اول شبکه تنها با استفاده از مدل‌های ارتفاعی شهرستان آق‌قلا و استان گلستان و داده‌های دبی روزانه

جدول ۲: مقادیر NSE و خطای میانگین مربعات پیش‌بینی داده‌های ارزیابی در روش منفرد، با استفاده از سه گروه داده؛ دبی روزانه ایستگاه هدف به صورت مجزا و به همراه مدل ارتفاعی شهرستان آق‌قلا و استان گلستان

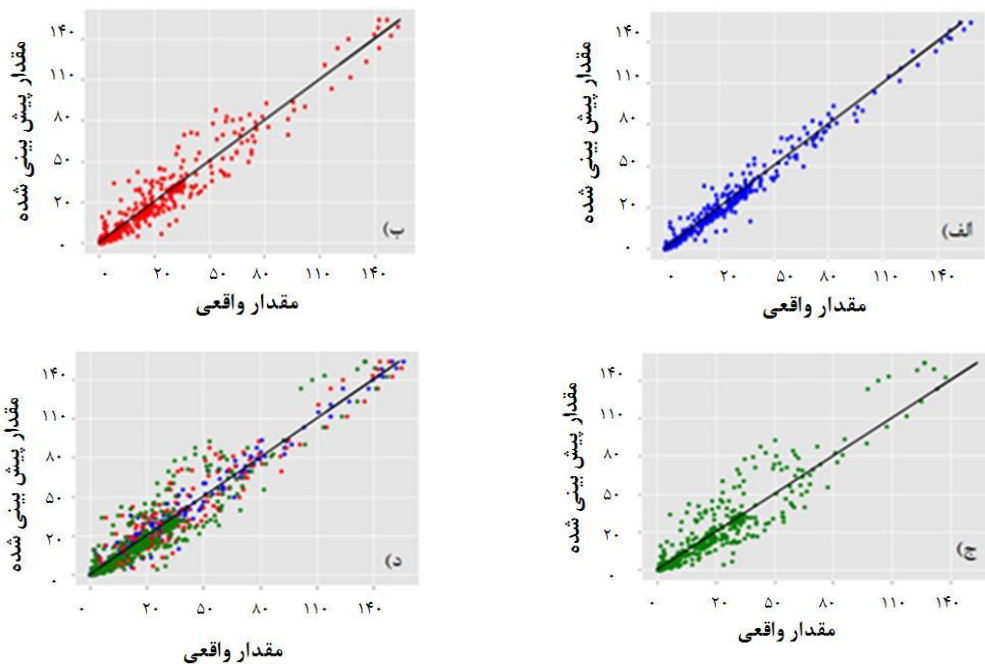
پیش‌بینی		یک روزه		دو روزه		سه روزه		داده
لايه	زمان (ثانیه)	$RMSE$	NSE	دوره	زمان (ثانیه)	$RMSE$	NSE	
۲	۱۹۴	۰٫۹۸۲	۰٫۰۱۳	۱۷۰	۱۵۶	۰٫۰۲۲	۰٫۹۴۴	دبی هدف
۴	۲۴۹	۰٫۹۸۰	۰٫۰۱۳	۱۴۵	۱۸۹	۰٫۰۲۳	۰٫۹۴۰	
۶	۳۲۲	۰٫۹۸۱	۰٫۰۱۳	۱۳۷	۲۷۷	۰٫۰۲۳	۰٫۹۴۱	
۲	۳۰۶	۰٫۹۸۱	۰٫۰۱۳	۱۷۲	۱۷۳	۰٫۰۲۳	۰٫۹۳۹	دبی هدف + مدل ارتفاعی
۴	۴۷۹	۰٫۹۸۱	۰٫۰۱۳	۱۹۱	۲۰۰	۰٫۰۲۴	۰٫۹۳۳	
۶	۳۰۵	۰٫۹۸۰	۰٫۰۱۳	۱۰۷	۳۴۶	۰٫۰۲۴	۰٫۹۳۷	
۲	۵۰۲	۰٫۹۸۰	۰٫۰۱۳	۲۱۵	۲۴۷	۰٫۰۲۲	۰٫۹۴۲	دبی هدف + مدل ارتفاعی گلستان
۴	۵۳۶	۰٫۹۸۱	۰٫۰۱۳	۱۹۰	۳۳۶	۰٫۰۲۲	۰٫۹۴۲	
۶	۳۸۲	۰٫۹۸۱	۰٫۰۱۳	۱۰۹	۳۱۵	۰٫۰۲۲	۰٫۹۴۲	



شکل ۷: بررسی بهترین پیش‌بینی‌های دبی ایستگاه هدف به تفکیک سال و فصل در روش منفرد، الف) مقادیر واقعی دبی جهت اعتبارسنجی، ب) پیش‌بینی یک روزه، ج) پیش‌بینی دو روزه، د) پیش‌بینی سه روزه

مربوط به پیش‌بینی یک، دو، سه روزه به همراه تطبیق آن‌ها می‌باشد.

به منظور مقایسه‌ای بهتر بین مقادیر واقعی و بهترین مقادیر پیش‌بینی شده، نمودار پراکنش آن‌ها در شکل (۸) آورده شده است. این شکل شامل چهار نمودار



شکل ۸: نمودار پراکنش مربوط به روش منفرد، پیش‌بینی الف) یک روزه، ب) دو روزه، ج) سه روزه و د) تطبیق نمودارها


در جدول (۳) مقادیر NSE و خطای میانگین مربعات برای مجموعه داده‌های اعتبارسنجی به همراه تعداد گام‌ها و زمان سپری شده در واحد ثانیه در هر یک از تعداد لایه‌های شبکه برای هر کدام از مجموعه داده‌ها آورده شده‌است.

۴-۲- بررسی‌های همراه با همبستگی

در روش دوم در شبکه مورد نظر با استفاده از مدل‌های ارتفاعی شهرستان آق‌قلا و استان گلستان و داده‌های ایستگاه هدف و ایستگاه‌های بالادست آن به پیش‌بینی دبی تا سه روز آتی پرداخته می‌شود.

در شکل (۹) مقدار همبستگی هر یک از ایستگاه‌های واقع بر گرگان‌رود و بالادست ایستگاه آق‌قلا مشاهده می‌شود. در این مطالعه از دو ترکیب این ایستگاه‌ها:

- ۱- ایستگاه‌های آق‌قلا، تمرگران، گنبد، به عنوان ترکیب داده‌ها با همبستگی کم و ۲- تمامی ایستگاه‌ها، آق‌قلا، سدگران، قزاقلی، تمرگران، گنبد، به عنوان ترکیب داده‌ها با همبستگی زیاد استفاده می‌شود.



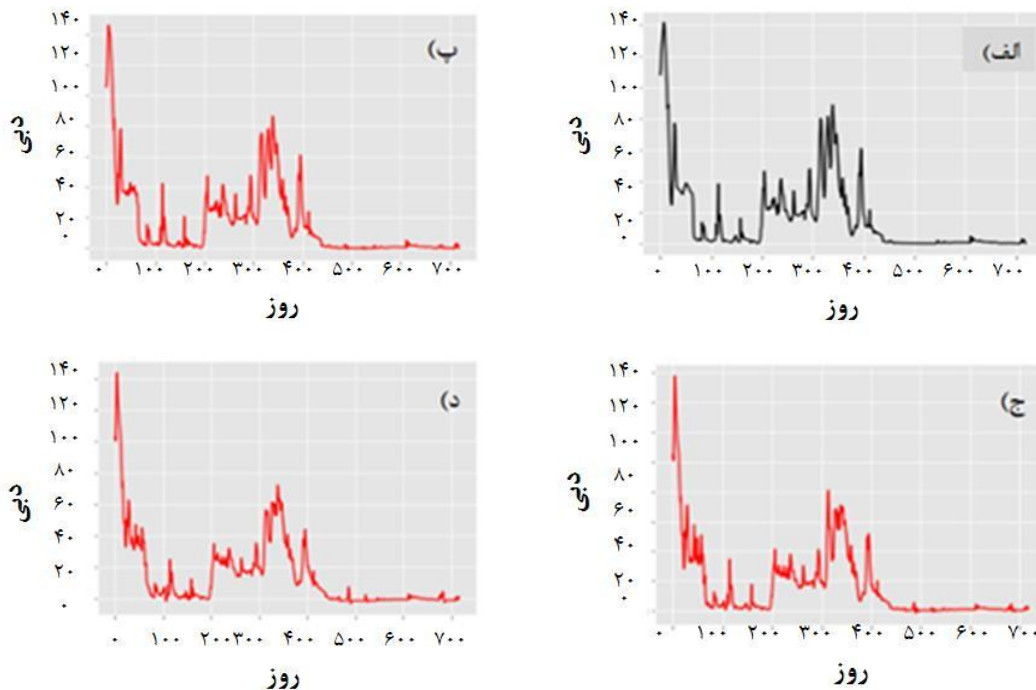
شکل ۹: نمودار رابطه و همبستگی ایستگاه آق قلا با ایستگاه‌های بالادست

جدول ۳: مقادیر NSE و خطای میانگین مربعات پیش‌بینی داده‌های اعتبارسنجی در روش همراه با همبستگی با استفاده از شش گروه داده

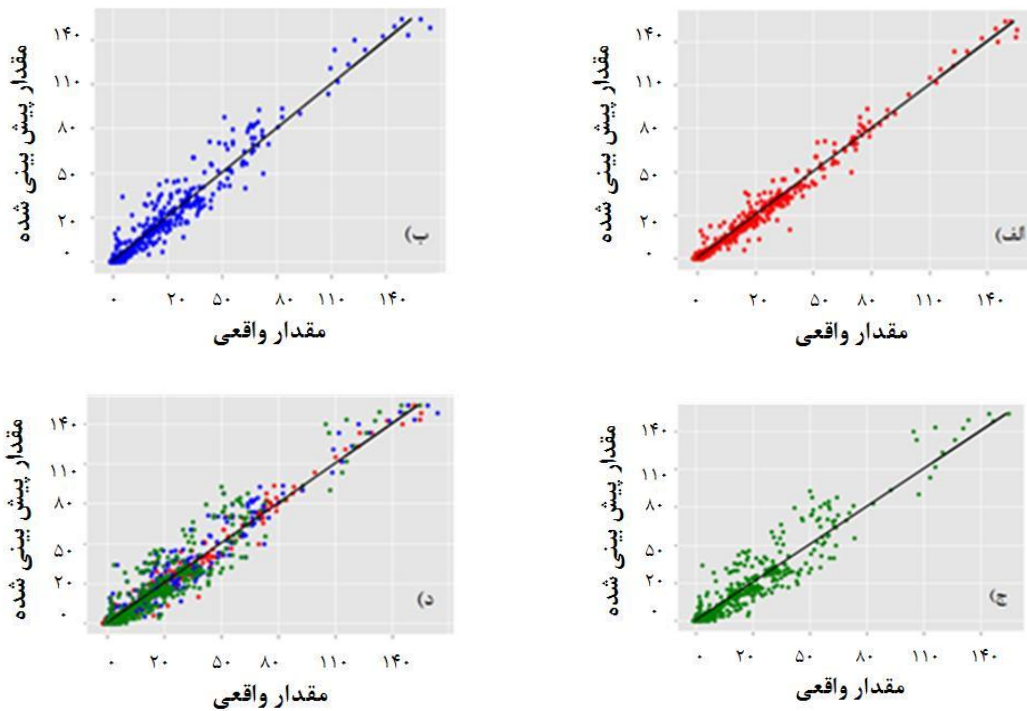
سه روزه		دو روزه		یک روزه		پیش‌بینی							
$RMSE$	NSE	گام	زمان (ثانیه)	$RMSE$	NSE	گام	زمان (ثانیه)	$RMSE$	NSE	گام	زمان (ثانیه)	لايه	داده
0.031	0.891	132	144	0.022	0.946	68	78	0.014	0.978	60	71	2	دبی هدف + 2 ایستگاه
0.033	0.874	117	199	0.022	0.943	93	157	0.014	0.977	79	137	4	
0.030	0.893	107	247	0.025	0.930	103	235	0.013	0.980	109	249	6	
0.027	0.915	74	136	0.022	0.943	68	123	0.013	0.981	79	166	2	دبی هدف + 2 ایستگاه + مدل ارتفاعی آق قلا
0.027	0.912	76	192	0.021	0.949	76	183	0.013	0.980	64	182	4	
0.029	0.902	92	287	0.021	0.948	77	241	0.013	0.982	67	242	6	
0.028	0.908	71	163	0.024	0.936	135	323	0.013	0.981	55	128	2	دبی هدف + 2 ایستگاه + مدل ارتفاعی گلستان
0.031	0.885	122	341	0.026	0.923	142	407	0.014	0.978	114	338	4	
0.028	0.906	95	333	0.023	0.938	109	385	0.014	0.979	79	284	6	
0.038	0.834	78	122	0.031	0.888	89	101	0.017	0.967	93	103	2	دبی هدف + 4 ایستگاه
0.038	0.833	79	181	0.030	0.897	80	139	0.018	0.962	83	142	4	
0.037	0.843	104	319	0.030	0.900	70	166	0.017	0.969	74	170	6	
0.037	0.837	104	190	0.032	0.885	73	129	0.017	0.967	90	186	2	دبی هدف + 4 ایستگاه + مدل ارتفاعی آق قلا
0.038	0.826	90	235	0.030	0.898	99	241	0.018	0.962	90	264	4	
0.038	0.828	70	235	0.030	0.897	82	250	0.016	0.972	73	271	6	
0.039	0.825	82	193	0.029	0.903	77	180	0.019	0.960	98	236	2	دبی هدف + 4 ایستگاه + مدل ارتفاعی گلستان
0.040	0.813	92	273	0.031	0.888	88	256	0.018	0.964	84	249	4	
0.037	0.836	78	267	0.031	0.889	87	316	0.017	0.966	103	374	6	

به منظور مقایسه‌ای بهتر بین مقادیر واقعی و بهترین مقادیر پیش‌بینی شده، نمودار پراکنش آن‌ها در شکل (۱۱) آورده شده‌است.

در شکل (۱۰) مقادیر اعتبارسنجی و بهترین نمونه‌های پیش‌بینی شده در روش همراه با همبستگی نشان داده شده‌است.



شکل ۱۰: بررسی بهترین پیش‌بینی‌های دبی ایستگاه هدف، در روش همراه با همبستگی، (الف) مقادیر واقعی دبی جهت اعتبارسنجی، (ب) پیش‌بینی یک روزه، (ج) پیش‌بینی دو روزه، (د) پیش‌بینی سه روزه



شکل ۱۱: نمودار پراکنش روش همراه با هم‌بستگی، پیش‌بینی الف) یک روزه، ب) دو روزه، ج) سه روزه و د) تطبیق نمودارها

۳-۴- آنالیز حساسیت

در این بخش جهت اثبات استحکام شبکه برای بهترین نتایج حاصل شده مربوط به پیش‌بینی‌های یک، دو و

سه روزه آزمایشات یک بار دیگر تکرار شده‌اند. مقدار زمان اجرا شبکه در واحد ثانیه، تعداد گام‌ها و مقادیر معیارهای ارزیابی مربوط هر یک از موارد در جدول (۴) آورده شده‌است.

جدول ۴: مقادیر *NSE* و خطای میانگین مربعات در بهترین حالات اتفاق افتاده در روش‌های پیشین در آزمایشات آنالیز حساسیت

پیش‌بینی روز	منفرد					همراه با وابستگی				
	داده	لایه	زمان (S)	گام	<i>NSE</i>	داده	لایه	زمان (S)	گام	<i>NSE</i>
روزه ۱	دبی هدف	۲	۲۲۰	۱۰۷	۰٫۹۸۱	دبی هدف+ ۲ ایستگاه+ مدل ارتفاعی آق‌قلا	۶	۲۰۰	۶۵	۰٫۹۸۱
	دبی هدف	۲	۲۸۹	۱۱۷	۰٫۹۴۵	دبی هدف+ ۲ ایستگاه+ مدل ارتفاعی آق‌قلا	۴	۱۵۵	۷۰	۰٫۹۵۰
	دبی هدف	۶	۲۹۰	۱۰۵	۰٫۸۹۰	دبی هدف+ ۲ ایستگاه+ مدل ارتفاعی آق‌قلا	۲	۱۲۷	۷۲	۰٫۹۱۱

ناچیز دقت شبکه نیز شده‌است. با آزمایش تعداد نورن‌های مختلف، این نتیجه حاصل گردید که با بالارفتن تعداد نورن‌ها دقت شبکه بالا رفته و پس از یک مقدار مشخص بی تاثیر می‌شود. بنابراین تعداد متوسط نورن‌ها در لایه اول در نظر گرفته، با افزایش لایه‌ها بر تعداد نورن‌ها نیز افزوده شده و سپس در لایه‌های نهایی تعداد آن‌ها دوباره به حالت اولیه برگشته‌است. در مرحله بعد با آزمایش توابع بهینه‌ساز مختلف مانند اس جی دی^۲ و آدام این نتیجه حاصل گردید که مانند سایر تحقیقات انجام شده در این حیطه، تابع بهینه‌ساز آدام مناسب بوده‌است [۱ و ۲۲]. همان‌طور که در بخش نتایج بیان شده، در روش منفرد استفاده از مدل ارتفاعی شهرستان آق‌قلا نتیجه بهتری نسبت به مدل ارتفاعی استان گلستان حاصل کرده‌است. البته این امر ممکن است به دلیل رزولوشن مکانی پایین مدل ارتفاعی مورد استفاده و نوع منطقه باشد. از طرف دیگر در روش همراه با وابستگی، استفاده از داده‌های دو ایستگاه بالادست ایستگاه آق‌قلا، یعنی ایستگاه‌های گنبد با ارتفاع ۳۶ متر و میزان همبستگی ۰٫۵ با ایستگاه هدف و تمرگران با ارتفاع ۱۳۲ متر و میزان همبستگی ۰٫۲ با ایستگاه هدف نتیجه بهتری را نسبت به استفاده از تمامی ایستگاه‌ها حاصل کرده‌است. این اختلاف، به خصوص با افزایش تعداد روزهای مورد پیش‌بینی کاملاً مشهود بوده‌است. در پایان نتایج شبکه *LSTM* با شبکه مکرر ساده، رگرسیون ساده و رگرسیون ماشین بردار پشتیبان مقایسه شده‌است. همانند نتایجی که توسط آپایدین و همکاران (۲۰۲۰) به‌دست آمد دقت *LSTM* بیشتر از شبکه مکرر ساده بوده ولی سرعت شبکه مکرر ساده بالاتر می‌باشد [۲۳]. مطابق آنچه توسط لیانگ و همکاران (۲۰۱۸) بیان شد دقت شبکه *LSTM* بالاتر از شبکه رگرسیون ماشین بردار پشتیبان می‌باشد [۱۱].

۴-۴- مقایسه

برای اطمینان از کارایی شبکه *LSTM* نتایج آن با شبکه‌های عصبی مکرر ساده، رگرسیون ساده^۱ و رگرسیون ماشین بردار پشتیبان^۲ مقایسه گردیده‌است. در جدول (۵) نتایج حاصل از شبکه مکرر ساده آورده شده‌است. در جدول (۶) با استفاده از شبکه رگرسیون ساده، رگرسیون ماشین بردار پشتیبان و سه گروه داده؛ به پیش‌بینی‌های دبی ایستگاه هدف تا سه روز آتی پرداخته شده و نتایج آن‌ها برای نمونه‌های اعتبارسنجی آورده شده‌است. قابل ذکر است پارامترهای بهینه برای این شبکه، کرنل *rbf* دارای گاما ۰٫۱ و c برابر ۱ در نظر گرفته شد.

۵- بحث و تحلیل نتایج

در مطالعه حاضر با استفاده از داده‌های دبی ایستگاه هدف و ایستگاه‌های بالادست، مدل ارتفاعی منطقه و با استفاده از روش یادگیری عمیق به پیش‌بینی دبی در یک الی سه روز آتی پرداخته شده‌است. شبکه حاضر با ۲، ۴ و ۶ لایه و با استفاده از معیارهای *NSE* و خطای میانگین مربعات بررسی شده‌است. ارزیابی نتایج نشان‌دهنده کارایی نتایج بوده، درعین حال با افزایش تعداد روزهای مورد پیش‌بینی مقادیر دقت‌ها سیرنزولی داشته‌اند. به عبارتی دقت پیش‌بینی یک روزه بالاتر از پیش‌بینی دو روزه و دقت پیش‌بینی دو روزه بیشتر از دقت پیش‌بینی سه روزه می‌باشد.

جهت ارزیابی بیشتر شبکه مورد نظر چند عامل مانند تعداد لایه‌ها، تعداد نورن‌ها و تابع بهینه‌ساز بررسی شده‌اند. در آزمایش تاثیر تعداد لایه‌های به‌کار برده شده، برخلاف آنچه که توسط کائو و همکاران بیان شده افزایش تعداد لایه‌ها تاثیر منفی بر نتایج شبکه‌ی *LSTM* نداشته‌است [۲۱]. در واقع افزایش تعداد لایه‌ها با تغییرات بسیار جزئی همراه بوده و گاهی باعث افزایش

^۳ *sgd*

^۱ *Linear regression*

^۲ *support vector regression*

جدول ۵: نتایج حاصل از پیش‌بینی‌های یک الی سه روزه برای داده‌های اعتبارسنجی جهت قیاس روش پیشنهادی و شبکه RNN ساده

RNN وابسته ۲				RNN وابسته ۱				RNN منفرد				پیش‌بینی	
RMSE	NSE	گام	زمان (S)	RMSE	NSE	گام	زمان (S)	RMSE	NSE	گام	زمان (S)	لايه	روز
۰/۰۱۷	۰/۹۶۶	۱۴ ۴	۲۱۷	۰/۰۱۳	۰/۹۸۰	۶۷	۱۰۳	۰/۰۱۴	۰/۹۷۶	۱۰۳	۱۵۲	۲	
۰/۰۱۶	۰/۹۷۰	۱۰ ۱	۲۳۰	۰/۰۱۴	۰/۹۷۷	۹۴	۲۱۴	۰/۰۱۳	۰/۹۸۰	۲۵۱	۵۶۵	۴	دبی هدف
۰/۰۱۸	۰/۹۶۲	۹۵	۲۸۴	۰/۰۱۴	۰/۹۷۸	۱۰ ۳	۳۱۳	۰/۰۱۴	۰/۹۷۹	۱۱۸	۳۶۰	۶	
۰/۰۱۶	۰/۹۶۹	۷۴	۱۱۳	۰/۰۱۳	۰/۹۸۱	۸۴	۱۲۸	۰/۰۱۴	۰/۹۷۸	۶۲	۹۳	۲	دبی هدف
۰/۰۱۸	۰/۹۶۲	۹۳	۱۹۰	۰/۰۱۴	۰/۹۷۹	۸۳	۱۷۱	۰/۰۱۶	۰/۹۷۱	۶۷	۱۴۰	۴	+ مدل
۰/۰۲۰	۰/۹۵۶	۶۲	۱۶۰	۰/۰۱۵	۰/۹۷۴	۹۲	۲۳۴	۰/۰۱۵	۰/۹۷۵	۷۰	۱۷۹	۶	ارتفاعی آق‌قلا
۰/۰۲۰	۰/۹۵۵	۱۳ .	۲۲۰	۰/۰۱۴	۰/۹۷۷	۷۰	۱۲۳	۰/۰۱۴	۰/۹۷۷	۱۰۵	۱۰۸	۲	دبی هدف
۰/۰۲۰	۰/۹۵۴	۱۰ ۴	۲۳۳	۰/۰۱۶	۰/۹۷۰	۸۷	۱۹۵	۰/۰۱۵	۰/۹۷۳	۸۱	۱۸۰	۴	+ مدل ارتفاعی
۰/۰۱۸	۰/۹۶۲	۱۰ ۹	۲۹۱	۰/۰۱۴	۰/۹۷۹	۶۵	۱۷۹	۰/۰۱۵	۰/۹۷۴	۱۸۱	۴۹۱	۶	گلستان
۰/۰۳۱	۰/۸۸۹	۹۹	۹۵	۰/۰۲۶	۰/۹۲۱	۵۳	۵۴	۰/۰۲۵	۰/۹۳۰	۹۳	۹۸	۲	
۰/۰۳۰	۰/۸۹۳	۷۱	۱۰۲	۰/۰۲۴	۰/۹۳۲	۱۷ ۱	۲۴۵	۰/۰۲۵	۰/۹۳۱	۶۳	۹۷	۴	دبی هدف
۰/۰۳۲	۰/۸۸۶	۱۶ ۷	۳۰۹	۰/۰۲۴	۰/۹۳۲	۶۸	۱۳۰	۰/۰۲۵	۰/۹۳۰	۹۵	۱۸۹	۶	
۰/۰۳۲	۰/۸۸۳	۶۳	۹۴	۰/۰۲۵	۰/۹۳۰	۵۴	۸۴	۰/۰۲۴	۰/۹۳۵	۱۱۵	۱۷۶	۲	دبی هدف
۰/۰۳۳	۰/۸۷۸	۶۴	۱۳۰	۰/۰۲۳	۰/۹۴۰	۷۹	۱۶۰	۰/۰۲۵	۰/۹۲۹	۶۳	۱۳۴	۴	+ مدل
۰/۰۳۵	۰/۸۶۲	۸۸	۲۲۸	۰/۰۲۷	۰/۹۱۹	۱۶ ۲	۴۱۲	۰/۰۲۷	۰/۹۱۷	۷۴	۱۸۷	۶	ارتفاعی آق‌قلا
۰/۰۳۶	۰/۸۵۱	۸۳	۱۴۶	۰/۰۳۰	۰/۸۹۸	۱۰ ۸	۱۸۶	۰/۰۲۷	۰/۹۱۶	۱۵۳	۲۶۵	۲	دبی هدف + مدل
۰/۰۳۱	۰/۸۸۹	۷۷	۱۷۶	۰/۰۲۵	۰/۹۲۸	۶۷	۱۵۳	۰/۰۲۶	۰/۹۲۵	۷۱	۱۶۱	۴	ارتفاعی
۰/۰۳۲	۰/۸۸۳	۷۳	۲۰۵	۰/۰۲۵	۰/۹۳۰	۷۴	۲۰۵	۰/۰۲۷	۰/۹۱۸	۱۱۱	۱۳۴	۶	گلستان
۰/۰۴۴	۰/۷۷۲	۹۰	۹۰	۰/۰۲۸	۰/۹۰۵	۱۰ ۵	۱۰۲	۰/۰۳۳	۰/۸۷۴	۷۸	۷۷	۲	
۰/۰۳۴	۰/۸۶۲	۵۴	۸۱	۰/۰۳۳	۰/۸۷۵	۶۲	۹۳	۰/۰۳۲	۰/۸۷۷	۱۰۶	۱۴۹	۴	دبی هدف
۰/۰۴۱	۰/۷۹۹	۱۶ .	۳۱۰	۰/۰۳۲	۰/۸۸۲	۵۴	۱۰۳	۰/۰۳۴	۰/۸۶۸	۱۲۳	۲۲۷	۶	
۰/۰۳۷	۰/۸۳۷	۱۱ ۹	۱۸۷	۰/۰۲۸	۰/۹۰۸	۸۰	۱۲۴	۰/۰۳۵	۰/۸۵۴	۶۸	۱۰۶	۲	دبی هدف + مدل

یک

دو

سه

۰٫۰۳۹	۰٫۸۱۷	۶۶	۱۳۴	۰٫۰۳۴	۰٫۸۶۲	۱۱	۲۳۷	۰٫۰۳۳	۰٫۸۷۱	۷۳	۱۴۸	۴	ارتفاعی آق‌قلا
۰٫۰۴۱	۰٫۷۹۹	۶۸	۱۷۶	۰٫۰۳۳	۰٫۸۷۰	۷۵	۱۹۶	۰٫۰۳۴	۰٫۸۶۶	۷۲	۱۹۰	۶	
۰٫۰۴۰	۰٫۸۱۲	۸۰	۱۴۳	۰٫۰۳۰	۰٫۸۹۷	۵۹	۱۰۴	۰٫۰۳۲	۰٫۸۷۵	۸۴	۱۵۳	۲	دبی هدف
۰٫۰۳۹	۰٫۸۱۸	۹۶	۲۲۴	۰٫۰۳۴	۰٫۸۶۲	۱۰	۲۴۱	۰٫۰۳۴	۰٫۸۶۰	۹۷	۲۱۸	۴	+ مدل ارتفاعی
۰٫۰۴۶	۰٫۷۵۴	۱۱	۳۱۱	۰٫۰۳۱	۰٫۸۸۸	۸۱	۲۲۷	۰٫۰۳۴	۰٫۸۶۰	۶۵	۱۷۷	۶	گلستان

جدول ۶: نتایج حاصل از پیش‌بینی‌های یک الی سه روزه داده‌های اعتبارسنجی

پیش‌بینی		رگرسیون ساده		رگرسیون ماشین بردار پشتیبان	
روز	داده	<i>NSE</i>	<i>RMSE</i>	<i>NSE</i>	<i>RMSE</i>
	دبی هدف	۰٫۹۷۹	۰٫۰۱۴	۰٫۹۷۶	۰٫۰۱۵
یک روزه	دبی هدف + ۲ ایستگاه	۰٫۹۸۰	۰٫۰۱۳	۰٫۹۷۹	۰٫۰۱۴
	دبی هدف + ۴ ایستگاه	۰٫۹۶۹	۰٫۰۱۷	۰٫۹۶۴	۰٫۰۱۸
	دبی هدف	۰٫۹۳۱	۰٫۰۲۴	۰٫۹۲۵	۰٫۰۲۵
دو روزه	دبی هدف + ۲ ایستگاه	۰٫۹۳۷	۰٫۰۲۳	۰٫۹۳۵	۰٫۰۲۴
	دبی هدف + ۴ ایستگاه	۰٫۸۹۵	۰٫۰۳۰	۰٫۸۹۰	۰٫۰۳۱
	دبی هدف	۰٫۸۷۴	۰٫۰۳۳	۰٫۸۶۸	۰٫۰۳۴
سه روزه	دبی هدف + ۲ ایستگاه	۰٫۸۸۹	۰٫۰۳۱	۰٫۸۸۱	۰٫۰۳۲
	دبی هدف + ۴ ایستگاه	۰٫۸۲۸	۰٫۰۳۸	۰٫۸۱۸	۰٫۰۳۹

۶- نتیجه‌گیری

پیش‌بینی دقیق سیل نیازی اساسی جهت کاهش خطرات آن می‌باشد، با این حال پیش‌بینی دقیق تخلیه رودخانه به دلیل پیچیده بودن تجزیه و تحلیل سیل و غیرخطی بودن روند جریان رودخانه مسئله‌ای دشوار است. شبکه‌های عصبی مصنوعی به خصوص شبکه‌های یادگیری عمیق عملکرد بسیار خوبی در مواجهه با مسائل پیچیده و غیرخطی دارند. شبکه *LSTM* نوعی از شبکه‌های عصبی مکرر است، که جهت رفع معایب آن‌ها به وجود آمد. این شبکه به دلیل ساختار ویژه‌ای که دارد در مسائل مربوط به سری زمانی، نتایج بسیار مناسبی را حاصل کرده‌است. از این رو در این مطالعه سعی بر پیش‌بینی دبی ایستگاه آق‌قلا واقع در استان گلستان با

استفاده از شبکه *LSTM* شده‌است. در این روش چندین ترکیب داده؛ داده‌های دبی ایستگاه آق‌قلا به صورت تنها و به همراه ایستگاه‌های بالادست آن، مدل ارتفاعی شهرستان آق‌قلا و استان گلستان، به عنوان ورودی شبکه استفاده شده‌اند. در نهایت به پیش‌بینی یک، دو و سه روزه دبی ایستگاه هدف منجر شد. ارزیابی این شبکه با استفاده از معیارهای *NSE* و خطای میانگین مربعات، با مقدار *NSE* بالاتر از ۰٫۹۱ و خطای میانگین مربعات کمتر از ۰٫۰۳، نشان‌دهنده قابل قبول بودن نتایج می‌باشد.

جهت ساخت شبکه مورد نظر چند عامل مانند تعداد لایه‌ها، تعداد نورون‌ها و تابع بهینه‌ساز بررسی شده‌اند. در آزمایش تاثیر تعداد لایه‌های به کار برده‌شده، نتایج

نتایج نشان دادند که به طور کلی شبکه *LSTM* به کار برده شده در مطالعه حاضر دارای بیشترین دقت بوده است.

یافته‌های این مطالعه گزینه‌ای مناسب جهت پیش‌بینی سیلاب شهرستان آق‌قلا، که دارای آمار وقوع سیلاب‌های زیاد در چند دهه اخیر بوده، می‌باشد. این شبکه به دلیل استحکام بالا، برای پیش‌بینی سیلاب هر منطقه‌ای که ایستگاه هیدرومتری فعال حداقل از یک دهه اخیر داشته باشد می‌تواند نتایج قابل قبولی ارائه دهد. همچنین روش مورد نظر، قابلیت پیاده‌سازی با توجه به شرایط مختلف اقلیمی و کمبود منابع داده (مانند تصاویر پهپاد) در کشور را دارا می‌باشد. با توجه به محدودیت‌های دسترسی به داده‌ها (داده‌های ارتفاعی با قدرت تفکیک بالا و سایر داده‌های مرتبط) در ارتباط با بلایای طبیعی در کشور که در این پژوهش به رغم مراجعات متعدد به سازمان‌ها و ارگان‌های مسئول در نهایت و در فاز اجرایی داده‌ی مناسب در اختیار قرار نگرفت، به‌کارگیری روش‌هایی که بتوانند با استفاده از داده‌های موجود (داده‌های ماهواره‌ای رایگان و ایستگاه هیدرومتری فعال) نتایج مناسبی را کسب نمایند، از اهمیت بسزایی در مدیریت بحران برخوردار است. علاوه‌براین، با توجه به بررسی‌های صورت گرفته توسط مولف، چنین مطالعه‌ای با این استحکام در داخل کشور انجام نشده است. جهت دستیابی به نتیجه‌ای بهتر، در مطالعات بعدی سعی بر استفاده از سایر داده‌های تاثیرگذار بر وقوع سیلاب، مانند بارندگی و استفاده از تصاویر ماهواره‌ای و مدل ارتفاعی با رزولوشن مکانی بیشتر می‌باشد. از طرف دیگر، توسعه مدل مورد استفاده به مدلی کاملاً خودکار، باعث سرعت بالاتر و کارایی بیشتر آن خواهد شد.

نشان داده‌اند که افزایش تعداد لایه‌ها تاثیر زیادی بر دقت حاصل نداشته است. با آزمایش تعداد نورن‌های مختلف این نتیجه حاصل شد که تعداد آن‌ها بر عملکرد شبکه موثر بوده و تعداد بسیار کم و یا بسیار زیاد آن باعث کاهش دقت می‌شود. در مرحله بعد با آزمایش توابع بهینه‌ساز مختلف، این نتیجه حاصل گردید که تابع بهینه‌ساز آدام تابعی مناسب در این زمینه بوده است.

در این مطالعه، پیش‌بینی دبی ایستگاه هدف در سه روز آتی انجام شده است. نتایج نشان دهنده کاهش دقت با افزایش روزها بوده‌اند. به‌طور کلی نتایج در دو بخش منفرد و دارای همبستگی ارائه شده است. در روش منفرد تنها از دبی ایستگاه هدف و مدل ارتفاعی استفاده شده، در صورتی که در روش دارای همبستگی از دبی ایستگاه‌های بالادست ایستگاه هدف نیز استفاده شده است. در بهترین حالات پیش‌بینی شده در این دو روش، مشخص شده است که در پیش‌بینی یک روزه، تفاوتی بین نتایج روش منفرد و دارای همبستگی وجود ندارد ولی با افزایش تعداد روزها این اختلاف بیشتر شده و روش دارای همبستگی دقت بالاتری را ارائه داده است. برای هر یک از پیش‌بینی‌های یک الی سه روزه بالاترین مقادیر *NSE*، در روش منفرد، بدون استفاده از مدل ارتفاعی و در روش دارای همبستگی، با استفاده از مدل ارتفاعی آق‌قلا رخ داده است. البته دلیل این امر ممکن است، نوع منطقه (اختلاف ارتفاعی کم) و رزولوشن مکانی پایین مدل ارتفاعی باشد. از طرف دیگر در روش همراه با وابستگی استفاده از داده‌های دو ایستگاه که همبستگی کمتر داشتند نتیجه بهتری را نسبت به استفاده تمامی ایستگاه‌ها حاصل کرده‌اند. در پایان، نتایج شبکه *LSTM* با شبکه مکرر ساده، رگرسیون ساده و رگرسیون ماشین بردار پشتیبان مقایسه شده است.

مراجع

[1] X.-H. Le, H. V. Ho, G. Lee, and S. Jung, "Application of long short-term memory (LSTM) neural network for flood

forecasting," *Water*, vol. 11, p. 1387, 2019.

[2] J. F. Rosser, D. Leibovici, and M. Jackson, "(2017) Rapid flood inundation mapping

- using social media, remote sensing and topographic data. *Natural Hazards*. ISSN 1573-0840".
- [3] J. Teng, J. Vaze, D. Dutta, and S. Marvanek, "Rapid inundation modelling in large floodplains using LiDAR DEM," *Water Resources Management*, vol. 29, pp. 2619-2636, 2015.
- [4] S. Ebadi aghdam, M. Saghebian, "Flood risk zoning using GIS and hierarchical analysis process (Case study: Sarandchai watershed)", *Proceedings of the Second Conference on Tactics of Architecture, Urban Planning, Civil Engineering and Geography in Sustainable Development*, 2019.
- [5] R. P. Deshmukh and A. Ghatol, "Short term flood forecasting using recurrent neural networks a comparative study," *International Journal of Engineering and Technology*, vol. 2, p. 430, 2010.
- [6] J. Alcazar, A. Palau, and C. Vega-Garci, "A neural net model for environmental flow estimation at the Ebro River Basin, Spain," *Journal of hydrology*, vol. 349, pp. 44-55, 2008.
- [7] M. Tayyab, J. Zhou, X. Zeng, and R. Adnan, "Discharge forecasting by applying artificial neural networks at the Jinsha river basin, China," *European Scientific Journal*, vol. 12, pp. 108-127, 2016.
- [8] Z. Han, J. Zhao, H. Leung, K. F. Ma, and W. Wang, "A review of deep learning models for time series prediction," *IEEE Sensors Journal*, 2019.
- [9] M. Farnaghi, H. Rahimi, "Spatio-Temporal Prediction of Monthly Rainfall using Deep Neural Network: A Case Study in North-west Iran", *Journal of Geomatics Ecience and Technology*, 2017
- [10] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, pp. 1735-1780, 1997.
- [11] C. Liang, H. Li, M. Lei, and Q. Du, "Dongting lake water level forecast and its relationship with the three gorges dam based on a long short-term memory network," *Water*, vol. 10, p. 1389, 2018.
- [12] C. Hu ,Q. Wu, H. Li, S. Jian, N. Li, and Z. Lou, "Deep learning with a long short-term memory networks approach for rainfall-runoff simulation," *Water*, vol. 10, p. 1543, 2018.
- [13] S. Gao, Y. Huang, S. Zhang, J. Han, G. Wang, M. Zhang, et al., "Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation," *Journal of Hydrology*, vol. 589, p. 125188, 2020.
- [14] P. Ahmadi, H. Arefi, N. Kardan, "Modeling the discharge of Karun River Using a New Method Based on the Joint LSTM and GRU Neural Networks," , *Eco Hydrology*, 7, 2020.
- [15] A. Kiani, F. FarnoodAhmadi, H. Ebadi, "Developing an interpretation system for high-resolution remotely sensed images based on hybrid decision-making process in a multi-scale manner," *Journal of the Indian Society of Remote Sensing* vol. 48, pp. 197-214, 2019.
- [16] Y. Bengio, P. Simard, and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," *IEEE transactions on neural networks*, vol. 5, pp. 157-166, 1994.
- [17] R. S. Govindaraju, "Artificial neural networks in hydrology. II: hydrologic applications," *Journal of Hydrologic Engineering*, vol. 5, pp. ۲۰۰ , ۱۳۷-۱۲۴ .
- [18] P. J. Werbos, "Generalization of backpropagation with application to a recurrent gas market model," *Neural networks*, vol. 1, pp. 339-356, 1988.
- [19] S. Hochreiter, "The vanishing gradient

problem during learning recurrent neural nets and problem solutions," *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, vol. 6, pp. 107-116, 1998.

- [20] J. Sanyal and X. Lu, "Application of remote sensing in flood management with special reference to monsoon Asia: a review", *Natural Hazards*, vol. 33, pp. 283-301, 2004.
- [21] C. Cao, P. Xu, Y. Wang, J. Chen, L. Zheng, and C. Niu, "Flash flood hazard susceptibility mapping using frequency ratio and statistical index methods in coalmine subsidence areas," *Sustainability*, vol. 8, p. 948, 2016.
- [22] Y. Sudriani, I. Ridwansyah, and H. A. Rustini, "Long short term memory (LSTM) recurrent neural network (RNN) for discharge level prediction and forecast in Cimandiri river, Indonesia," in *IOP Conference Series: Earth and Environmental Science*, 2019, p. 012037.
- [23] H. Apaydin, H. Feizi, M. T. Sattari, M. S. Colak, S. Shamshirband, and K.-W. Chau, "Comparative Analysis of Recurrent Neural Network Architectures for Reservoir Inflow Forecasting," *Water*, vol. 12, p. 1500, 2020.



Integration of remote sensing and meteorological data to predict flooding time using deep learning algorithm

Fatameh Hoseynzadeh¹, Hamid Ebadi², Abbas Kiani^{3}*

1- Master's degree, Department of remote sensing and photogrammetry, K.N.Toosi University of Technology

2- Professor in Geomatics Engineering Faculty, K.N.Toosi University of Technology

3- Assistant Professor, Faculty of Civil Engineering, Babol Noshirvani University of Technology

Abstract

Accurate flood forecasting is a vital need to reduce its risks. Due to the complicated structure of flood and river flow, it is somehow difficult to predict the exact time of flooding. Artificial neural networks, such as frequent neural networks, offer good performance in time series data. In recent years, the use of Long Short Term Memory networks has attracted a lot of attention due to the shortcomings of the frequent neural networks. In this study, it is tried to predict the daily discharge of the Aqqala station in Golestan province, for the next three days, using Long Short Term Memory network. This network is very suitable for time series predictions, due to its special structure and ability to learn long-term dependencies. On the other hand, the desired network is stable and contains the maximum default parameters, which indicates its usability for other regions. Furthermore, this algorithm has the ability to use topography and flow data from other stations in the region. To predict the discharge at the target station, several data combinations; the discharge data of Aqqala station alone and together with its upstream stations, the elevation model of Aqqala city and Golestan province were used as network inputs. The present research findings were compared with simple regression network, support vector machine-regression, and frequent neural network. The results show that Long Short Term Memory network is superior to other networks with Nash-Sutcliffe Efficiency values above 91%. In future studies, authors are going to use other influential data on flood occurrence as well as the development of the applied network into fully automated network.

Key words: flood forecasting, remote sensing, discharge forecasting, deep learning, LSTM.