

# پیش‌بینی ضرایب تصحیح‌کننده چگالی اتمسفری با استفاده از شبکه‌های عصبی

سعید فرزانه<sup>۱</sup>

محمدعلی شریفی<sup>۲</sup>

امیر عبدالملکی<sup>۳</sup>

مسعود دهوری<sup>۴</sup>

تاریخ دریافت مقاله: ۱۴۰۰/۰۵/۲۶

تاریخ پذیرش مقاله: ۱۴۰۰/۰۸/۲۲

\*\*\*\*\*

## چکیده

امروزه ماهواره‌های مدار پایین نقش مهمی در جمع‌آوری مشاهدات مربوط به زمین و میدان گرانش حاکم بر آن ایفا می‌کنند. عوامل مختلفی بر دقت و صحت مشاهدات این ماهواره‌ها مؤثر هستند. از جمله این عوامل، اصطکاک اتمسفری وارد بر ماهواره‌ها است که حتی می‌تواند پس از مدتی کارایی آن‌ها را با چالش مواجه کند. به همین دلیل تلاش‌های گوناگونی در صدد مدل‌سازی و پیش‌بینی عوامل مؤثر بر این نیرو برآمده است. مدل‌های تجربی ارائه‌شده برای چگالی اتمسفری نمونه‌ای از این تلاش‌ها است. با گذشت زمان و پیدایش خطاهای موجود در مدل‌های تجربی، تلاش برای اصلاح آن‌ها آغاز شد چراکه به دلیل ساده‌سازی‌ها و محدودیت‌های مشاهداتی، این مدل‌ها همواره با خطا همراه هستند و مقدار خروجی آن‌ها با مقدار واقعی چگالی اتمسفر، تطابق کامل ندارد. از دیگر سو، با گسترش علوم، روش‌های جدیدی مانند هوش مصنوعی و شبکه‌های عصبی برای پیش‌بینی یک سری زمانی ارائه شده است که قابلیت یادگیری رفتار سیگنال بدون تشکیل یک مدل ریاضی پیچیده را دارند. در این تحقیق، از شبکه‌های عصبی با حافظه بلند-کوتاه مدت برای پیش‌بینی و اصلاح مدل‌های تجربی چگالی اتمسفری که مهم‌ترین عامل تعیین‌کننده‌ی میزان کشش اتمسفری است، استفاده شده است. این شبکه‌های عصبی از نوع شبکه‌های بازگشتی هستند و با حفظ وابستگی سیگنال در زمان می‌توانند دقت بهتری را برای پیش‌بینی سیگنال فراهم آورند. داده‌های مورد استفاده برای آموزش شبکه عصبی مربوط به ماهواره‌ی GRACE و در نیمه‌ی نخست سال ۲۰۱۴ بوده است. برای ارزیابی نتایج نیز با استفاده از ضریب اصطکاک خروجی حاصل از شبکه عصبی و همچنین ضریب اصطکاک مربوط به مدل‌های عددی، موقعیت ماهواره تعیین و با موقعیت واقعی مقایسه شده است. نتایج پیش‌بینی نشان می‌دهد که در حالت تک متغیره مقدار RMSE در حدود ۰/۰۵۴ و در حالت چند متغیره در حدود ۰/۰۳ است و همچنین شبکه‌ی عصبی قادر است مدار ماهواره GRACE را با RMSE در حدود ۰/۱۵ متر پیش‌بینی کند.

واژه‌های کلیدی: هوش مصنوعی، شبکه‌های عصبی، اصطکاک اتمسفری، مدل‌های تجربی چگالی اتمسفری، ماهواره‌های مدار پایین

\*\*\*\*\*

۱- استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران (نویسنده مسئول) farzaneh@ut.ac.ir

۲- دانشیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران sharifi@ut.ac.ir

۳- کارشناسی ارشد، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران amir.abdolmaleki@ut.ac.ir

۴- دانشجوی دکتری دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران masoud.dehvari@ut.ac.ir

## ۱- مقدمه

ماهواره‌ها در مدار خود تحت تأثیر نیروهای مختلفی هستند که می‌توانند آن را از مسیر تعیین شده منحرف کنند. شناخت این نیروها و اتخاذ اقدامات لازم، باعث افزایش دقت تعیین مدار ماهواره‌های موجود، تعیین بهتر طول عمر ماهواره‌ها و همچنین باعث افزایش دقت طراحی مدار پیش‌بینی شده در آینده می‌شود (Forootan et al, 2019). در مورد ماهواره‌های مدار پایین<sup>۱</sup>، با توجه به ارتفاع پایین این ماهواره‌ها (در حدود ۱۰۰۰ کیلومتر)، یکی از مهم‌ترین شتاب‌های اغتشاشی که به آن‌ها وارد می‌شود، شتاب کشش اتمسفری ناشی از اصطکاک اتمسفر با ماهواره است. مهم‌ترین عامل تعیین‌کننده‌ی میزان این اصطکاک، چگالی اتمسفر خنثی است. عوامل دیگری مانند مقدار فعالیت خورشیدی و همچنین میدان مغناطیسی زمین نیز می‌توانند بر چگالی اتمسفری مؤثر باشند (Forootan et al, 2019).

اثر این عوامل با ضرایبی تعیین می‌شود و از آن‌ها می‌توان برای برآورد بهتر چگالی اتمسفر استفاده کرد. با توجه به اهمیت این اصطکاک برای مأموریت‌های ماهواره‌ای، تلاش برای تعیین مقدار چگالی اتمسفر از دهه ۷۰ میلادی آغاز شد و حاصل آن ارائه‌ی مدل‌هایی بود که به صورت کلی در دودسته‌ی تجربی و فیزیکی طبقه‌بندی می‌شدند (Behlchaki et al, 2009). در اولین مدل‌های تجربی چگالی اتمسفر نظیر مدل Harris-Priester، چگالی، تنها وابسته به موقعیت بود (Harris et al, 1962). پس از آن با در دسترس قرار گرفتن اطلاعات TLE<sup>۲</sup> در دهه‌ی ۱۹۶۰، مدل‌های تجربی به شکل پیوسته بهبود یافتند به گونه‌ای که از آن‌ها در مأموریت‌های ماهواره‌ای و مطالعات خورشید-زمین استفاده می‌شد. به صورت عام، پارامترهای این مدل‌ها، ضرایب  $F_{10/7}$  و  $K_p$  هستند که بیان‌کننده‌ی مقدار فعالیت ژئومغناطیسی زمین و خورشید بوده و برای در نظر گرفتن تغییرات زمانی- مکانی چگالی به کار می‌روند. در نمونه‌های دیگری از مدل‌های تجربی، با وارد کردن پارامترهایی مانند طول و عرض و

زمان، مقدار چگالی اتمسفر به عنوان خروجی در دسترس قرار می‌گیرد. از جمله معروف‌ترین این مدل‌ها می‌توان به مدل NRLMSISE-00 (Picone et al, 2002) و یا Jacchia (Jacchia, 1971) اشاره کرد. به دلیل ساده‌سازی‌های مدل‌ها و محدودیت‌های مشاهداتی، بدیهی است که این مدل‌ها با خطا همراه بوده و مقدار خروجی آن‌ها با مقدار واقعی چگالی اتمسفر، تطابق کامل نداشته باشند.

بنابراین برای افزایش دقت این مدل‌ها نیاز به مشاهداتی از چگالی اتمسفر در ارتفاع ماهواره‌ها وجود دارد. یکی از روش‌هایی که می‌توان اطلاعاتی از چگالی اتمسفر در محدوده ماهواره‌های مدار پایین به دست آورد استفاده از داده‌های ماهواره‌های گرانی‌سنجی مانند CHAMP<sup>۳</sup> (Reigber et al, 2002)، GRACE<sup>۴</sup> (Tapley et al, 2004) و GOCE<sup>۵</sup> (Albertella et al, 2002) است.

ماهواره‌های گرانی‌سنجی مجهز به شتاب‌سنج‌های بسیار دقیقی برای اندازه‌گیری شتاب‌های غیر جاذبی که به آن‌ها وارد می‌شوند هستند. اگرچه از این اطلاعات در فرآیند تعیین میدان جاذبه، برای تمایز شتاب‌های غیر جاذبی از شتاب جاذبه زمین استفاده می‌شود، اما با توجه به این امر که شتاب کشش اتمسفر نیز در داده‌های شتاب‌سنج غیر جاذبی وجود دارد، می‌توان با استفاده از داده‌ها اطلاعات در مورد چگالی اتمسفر در مسیر حرکت ماهواره به دست آورد (Bruinsma et al, 2003; Sutton, 2008; Doornbos et al, 2009; Doornbos et al, 2013). اگر بتوان با استفاده از سری زمانی ضرایب اصطکاک اتمسفری ماهواره‌های گرانی‌سنجی، ضرایب چگالی اتمسفر را برای آینده و با دقت کافی پیش‌بینی کرد، می‌توان برآورد خوبی از میزان اصطکاک اتمسفر داشت. روش‌های گوناگونی برای تلفیق داده‌ها به منظور پیش‌بینی سری زمانی وجود دارد. به عنوان مثال در تحقیق‌هایی مانند (Codrescu et al, 2004; Minter et al, 2004; Matsuo et al, 2013; Codrescu et al, 2018) از فیلتر کالمن برای پیش‌بینی متغیرهای

3- CHALLENGING Minisatellite Payload

4- Gravity Recovery And Climate Experiment

5- Gravity field and steady-state Ocean Circulation Explorer

1- Low Earth orbit

2- Two Line Elements

این منظور از ضرایب بسط چگالی به هارمونیک‌های کروی حاصل از شتاب‌سنج ماهواره GRACE برای آموزش شبکه استفاده شده است و پس از به دست آوردن پارامترهای شبکه و پیش‌بینی ضرایب بسط چگالی، با استفاده از آن‌ها، مدار ماهواره GRACE تعیین شده و با مدار واقعی مورد مقایسه قرار می‌گیرد. علاوه بر این، برای پیش‌بینی‌های نزدیک‌تر به مقادیر واقعی، تنها به مقادیر تصحیح‌ها اتمسفری اکتفا نشده است؛ بلکه از سری‌های زمانی میزان فعالیت خورشیدی و میدان مغناطیسی زمین به منظور بهبود نتایج بهره گرفته شده و شبکه عصبی در دو حالت تک متغیره و چند متغیره توسعه داده شده است.

برای آموزش شبکه در حالت تک متغیره از داده‌های ضریب مرتبه صفر تصحیح چگالی اتمسفری در ۱۸۰ روز اول سال ۲۰۱۴ استفاده شده است. اما در حالت چند متغیره دو رویکرد مختلف در نظر گرفته شده است. در حالت اول برای پیش‌بینی ضریب مرتبه صفر، سایر ضرایب‌های بسط تصحیح چگالی اتمسفری تا درجه و مرتبه دوم در نظر گرفته شده‌اند. همچنین در حالت چند متغیره علاوه بر ضریب مرتبه صفر بسط تصحیح چگالی، از داده‌های ضرایب فعالیت ژئومغناطیسی و ضرایب فعالیت خورشیدی بهره گرفته شده است.

در بخش دوم این مقاله ابتدا توضیحی مختصر در مورد شبکه‌های عصبی مصنوعی ارائه شده است و سپس شبکه‌های عصبی با حافظه بلند - کوتاه مدت تشریح شده‌اند. پس از آن در بخش سوم نحوه به دست آوردن ضرایب چگالی اتمسفری با استفاده از مشاهدات ماهواره GRACE شرح داده می‌شود. در قسمت آخر نتایج پیش‌بینی تک‌متغیره و چندمتغیره تصحیح‌های داده‌های اتمسفری ارائه شده است. پس از آن با استفاده از نزدیک‌ترین مقادیر پیش‌بینی شده به مقادیر واقعی، مدار ماهواره GRACE ابتدا بدون اصطکاک اتمسفری، یکبار با در نظر گرفتن مدل تجربی اتمسفری، پس از آن با تصحیح مدل چگالی و در نهایت با تصحیح‌های پیش‌بینی شده تعیین می‌شود. برای درک بهتر نتایج، مدار

چگالی اتمسفر استفاده کردند. در این تحقیقات می‌توان به نتایج (Matsuo et al, 2013) اشاره نمود که نشان داده بودند می‌توان ضریب فعالیت‌های خورشیدی ( $F_{10.7}$ ) را با استفاده از داده‌های چگالی اتمسفری ماهواره‌های گرانی‌سنجی محاسبه نمود. اما این روش‌ها، نه تنها دربرگیرنده‌ی محاسبات سنگین و زمان‌بر هستند، بلکه دقت محدودی نیز در پیش‌بینی سری زمانی در بازه بلند-کوتاه مدت دارند. امروزه یکی از روش‌های پیش‌بینی سری‌های زمانی در علوم مختلف استفاده از شبکه‌های عصبی مصنوعی<sup>۱</sup> است (Zhang, 2003; Khashei et al, 2010). مزیت این روش سادگی آن در ایجاد ارتباط بین ورودی و خروجی به منظور پیش‌بینی سیگنال است. انواع مختلفی از شبکه‌های مصنوعی برای پیش‌بینی سیگنال‌ها وجود دارد ولی بی‌تردید جدیدترین و قدرتمندترین نوع این شبکه‌ها در بحث پیش‌بینی، شبکه‌های عصبی بازگشتی و به خصوص شبکه‌های حافظه بلند-کوتاه مدت (LSTM)<sup>۲</sup> هستند (Sak et al, 2014; Le et al, 2019).

در تحقیقی که توسط فروتن و همکاران (۲۰۱۸) انجام شده است، توانایی شبکه‌های عصبی بازگشتی مانند NARX (Non-linear Autoregressive with Exogenous Input) و NAR (Non-linear Autoregressive) برای پیش‌بینی ضریب مرتبه صفر تصحیح چگالی اتمسفری در بازه‌های ۷ و ۱۴ و ۳۰ و ۶۰ و ۹۰ روزه مورد ارزیابی قرار گرفته است. نتایج حاصل از این تحقیق نشان داد که بهترین بازه پیش‌بینی ۷ روزه و مقدار ضریب همبستگی برای NARX و همچنین NAR به ترتیب ۰/۸۹ و ۰/۹۴ به دست آمدند و با افزایش بازه پیش‌بینی مقدار ضریب همبستگی کاهش می‌یافت.

باتوجه به اهمیت در نظر گرفتن اصطکاک اتمسفری برای ماهواره‌ها و دقیق نبودن مدل‌های تجربی که بسیار مورد استفاده قرار می‌گیرند، در این نگارش سعی بر این است که با استفاده از شبکه‌های عصبی مصنوعی با حافظه بلند - کوتاه مدت، تصحیح‌های مدل‌های اتمسفری در بازه‌های کوتاه تا بلند مدت (۷ روز تا ۹۰ روز) پیش‌بینی شود. برای

1- Artificial Neural Network

2- Long Short-Term Memory

به ازای یک یا مجموعه‌ای از داده‌های ورودی است که بسته به نوع تابع فعال‌ساز می‌تواند مقادیر بین صفر و یک را داشته باشد. با توجه به کاربردهای گسترده‌ی شبکه‌های عصبی، انواع مختلفی از آن‌ها به وجود آمده‌اند. دو دسته‌ی اصلی شبکه‌های عصبی عبارتند از شبکه‌های پیش‌خور و شبکه‌های بازگشتی که در ادامه توضیح مختصری راجع به هرکدام ارائه شده است.

## ۲-۱- شبکه‌های عصبی پیش‌خور

شبکه‌های عصبی پیش‌خور وابستگی زمانی به مقادیر قبلی ورودی شبکه ندارند و مقدار خروجی شبکه در لحظه با توجه به ورودی‌های شبکه در همان لحظه و پارامترهای مدل به دست آمده برای شبکه عصبی محاسبه می‌شوند. تابعی که توسط یک شبکه عصبی پیش‌خور مدل می‌شود، یک بردار ورودی را به بردار خروجی نگاشت می‌کند. رابطه بین ورودی و خروجی را می‌توان به صورت رابطه (۱) نوشت:

$$y = f(x, \theta)$$

رابطه (۱)


که در آن  $\theta$  شامل پارامترهای ورودی شبکه عصبی و  $f$  نیز شامل پارامترهای وزن و بایاس است. بردار  $y$  نیز خروجی شبکه عصبی را مشخص می‌کند. در طی روند آموزش، هدف این است که پارامترهای مناسب برای وزن و بایاس به نحوی تعیین شوند که مدل، نگاشت  $y = f(x, \theta)$

دینامیکی تعیین شده در حالت‌های مختلف با مدار واقعی ماهواره مقایسه شده است.

## ۲-۲ شبکه‌های عصبی مصنوعی

در چند دهه اخیر، شبکه‌های عصبی در مقاصد علمی مختلفی به کار گرفته شده‌اند. به ویژه در چند سال اخیر و با توجه به پیشرفت‌های سخت‌افزاری در پردازش موازی و در دسترس بودن مجموعه داده‌های عظیم در زمینه‌های مختلف، بیش‌ازپیش بر محبوبیت این شبکه‌ها افزوده شده است. یک شبکه عصبی، متشکل از نورون‌هایی است که از طریق اتصالاتی به یکدیگر متصل هستند که اطلاعات از طریق آن‌ها جریان دارد. ارتباط بین این نورون‌ها، از طریق اتصالات وزن‌دار برقرار می‌شود. هنگامی که یک شبکه عصبی، آموزش می‌بیند، در واقع انتظار می‌رود که نورون‌ها، الگوهای خاص موجود در داده‌ها را یاد بگیرند (Senkal et al, 2012) در نگاره ۱ نمایی از یک شبکه عصبی مصنوعی ارائه شده است.

هر شبکه عصبی، از سه لایه‌ی کلی: ورودی، مخفی و خروجی تشکیل شده است. در هر شبکه عصبی اتصالاتی هست که خروجی یک نورون را به عنوان ورودی نورون مقصد منتقل می‌کند. وزن‌ها بیانگر میزان اهمیت ورودی‌های مختلف نسبت به یکدیگر هستند. همچنین در شبکه‌های عصبی تابع فعال‌ساز، تعیین‌کننده‌ی مقدار خروجی یک گره



نگاره ۱: نمایی از یک شبکه‌ی عصبی مصنوعی

به سمت عقب با شروع از لایه‌ی  $L$  ام به دست آورد. در هر لایه‌ی  $l$  مشتق جزئی نسبت به ماتریس وزن  $W^l$  را با استفاده از مؤلفه‌های گام قبلی به دست آورد. این به‌روزرسانی پارامترها تا زمانی که شبکه اصطلاحاً همگرا شود ادامه پیدا می‌کند. اما این نکته باید ذکر شود که از معایب روش گرادیان نزولی این است که هنگامی که تعداد لایه‌های مخفی شبکه افزایش یابند، چون این روش از الگوریتم بازگشتی برای آموزش شبکه استفاده می‌کند، ممکن است تعدادی از نورون‌ها در لایه‌های اولیه به‌خوبی آموزش نبینند و یا تعداد تکرارهای لازم برای آموزش شبکه افزایش یابد که این امر باعث افزایش زمان محاسبات خواهد شد.

## ۲-۲- شبکه‌های عصبی بازگشتی

شبکه‌های عصبی بازگشتی یکی از ساختارهای خاص شبکه‌های عصبی هستند که می‌توانند وابستگی‌های زمانی در داده‌های ورودی را ثبت کنند. این امر با در نظر گرفتن این که شبکه در هر گام زمانی، بازخوردی از گام قبلی دریافت می‌کند حاصل می‌شود (Le et al, 2019). همین مسئله شبکه‌های بازگشتی را برای مدل کردن دنباله‌های داده و سری‌های زمانی مناسب می‌سازد. یک شبکه عصبی بازگشتی چندلایه را می‌توان با افزودن پارامتر زمان به صورت رابطه (۵) و رابطه (۶) نوشت:

$$h_t^{(l)} = f^{(l)}(h_{t-1}^{(l-1)} W^l + h_{t-1}^{(l)} U^l + b^{(l)}) \quad \text{رابطه (۵)}$$

$$y_t = h_t^{(l)} = f^{(l)}(h_{t-1}^{(l-1)} W^l + b^{(l)}) \quad \text{رابطه (۶)}$$

در روابط (۵) و (۶) لایه‌ی اول در هر گام، ورودی برابر  $h_t^{(0)} = x_t$  دارد. همچنین وضعیت هر لایه با مقادیر از پیش تعیین شده  $h_0^{(l)} = h_{init}^{(l)}$  معلوم می‌شود. شبکه‌های عصبی بازگشتی هم می‌توانند با الگوریتم گرادیان نزولی و پس انتشار خطا در زمان و مشابه با اصول شبکه‌های پیش‌خور آموزش ببینند. یعنی مشتقات جزئی در هر گام زمانی محاسبه می‌شوند و برای به‌روزرسانی وزن‌ها مورد استفاده قرار می‌گیرند. آموزش یک شبکه‌ی بازگشتی با

را با کمترین خطا تقریب بزند. رابطه‌ی ریاضی نورون‌ها را می‌توان به صورت رابطه (۲) نوشت (Suparta et al, 2013):

$$o(x) = f(w^T x + b) \quad \text{رابطه (۲)}$$

که در آن  $x$  همان بردار ورودی است که در وزن  $w$  ضرب شده و با بردار بایاس  $b$  جمع می‌شود و حاصل این جمع به عنوان ورودی به تابع فعال‌ساز  $f$  داده می‌شود. یک شبکه‌ی عصبی چندلایه با لایه‌های  $l = 1, \dots, L$  که  $L$  بیانگر تعداد لایه‌های شبکه با لایه‌ی اولیه (ورودی)  $h^{(0)} = x$  را می‌توان با رابطه‌ی بازگشتی (۲) بیان کرد. بنابراین لایه‌ی آخر از رابطه (۳) به دست می‌آید:

$$h^{(l)} = f^{(l)}(h^{(l-1)} W^{(l)} + b^{(l)}) \quad \text{رابطه (۳)}$$

در رابطه‌ی (۳)، بردار وزن  $W^{(l)}$  و بردار بایاس  $b^{(l)}$  مربوط به لایه آخر هستند. در شبکه‌های عصبی پیش‌خور برای تقریب تابعی که خروجی مطلوب را می‌سازد، باید پارامترهای بهینه‌ی شبکه برآورد شوند. این امر یعنی تعیین پارامترهای بهینه برای وزن‌ها و بایاس، به وسیله الگوریتم گرادیان نزولی انجام می‌شود (Amari, 1993). برای محاسبه‌ی گرادیان‌ها نسبت به خطا یا تابع هزینه (تابع محاسبه‌گر فاصله بین خروجی مطلوب و خروجی شبکه که معمولاً از خطای مجذور میانگین MSE استفاده می‌شود) از مدل پس انتشار خطا استفاده می‌شود. برای یک تابع هزینه دلخواه  $J(\theta)$  که  $\theta$  پارامترهای مدل هستند، پس از انتشار خطا با گرادیان‌گیری، از تابع خطا نسبت به پارامترهای شبکه  $\nabla_{\theta} J(\theta)$  (مشتق‌گیری شده و به‌روزرسانی پارامترهای شبکه محاسبه می‌شود. با استفاده از قاعده‌ی زنجیری مشتقات جزئی نسبت به ماتریس وزن  $W^l$  لایه‌ی  $l$  ام را می‌توان به شکل رابطه (۴) نوشت:

$$\frac{\partial J}{\partial W^l} = \frac{\partial J}{\partial h^l} \left[ \prod_{k=1}^{l-1} \frac{\partial h^{k+1}}{\partial h^k} \right] \frac{\partial h^1}{\partial W^1} \quad \text{رابطه (۴)}$$

همان‌طور که در رابطه‌ی (۴) نشان داده شده است، می‌توان به‌روزرسانی پارامترهای شبکه را با انتشار گرادیان

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad \text{رابطه (۷)}$$

در رابطه (۷)  $\sigma$  بیانگر تابع فعال‌ساز سیگموئید است که رابطه‌ی آن به صورت رابطه (۸) است:

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad \text{رابطه (۸)}$$

در گام بعدی، مدل می‌تواند ضمن در نظر گرفتن خروجی مرحله قبلی ( $h_{t-1}$ )، اطلاعات خاصی از ورودی را توسط درگاه ورودی جمع‌آوری کند. پس از آن، یک لایه با تابع فعال‌ساز تانزانت هائپربولیک کاندیدهای جدید برای وضعیت سلول را به وجود می‌آورد. سپس با تلفیق این دو، به روزرسانی سلول انجام می‌شود. روابط مربوط به عملیات گفته شده در رابطه (۹) ارائه شده است:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad \text{رابطه (۹)}$$

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad \text{رابطه (۱۰)}$$

با داشتن این اطلاعات، حال می‌توان وضعیت سلول قدیمی یعنی  $C_{t-1}$  را به روزرسانی کرد. با ضرب خروجی درگاه فراموشی در وضعیت سلول قدیمی و افزودن حاصل ضرب اطلاعات درگاه ورودی در مقادیر کاندیدهای وضعیت سلول اخیر، میزان تغییر مطلوب برای وضعیت سلول به صورت رابطه (۱۱) محاسبه می‌شود:

$$C_t = f_t \times C_{t-1} + i_t \times C_t \quad \text{رابطه (۱۱)}$$

در نهایت، می‌توان خروجی سلول به صورت رابطه (۱۲) محاسبه می‌شود:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad \text{رابطه (۱۲)}$$

$$h_t = o_t \times \tanh(C_t) \quad \text{رابطه (۱۳)}$$

در نهایت باید ذکر نمود برای این که بتوان در یک شبکه عصبی بازگشتی، از مقادیر یک سیگنال برای آموزش شبکه و همچنین پیش‌بینی مقادیر سیگنال در آینده استفاده نمود، باید مقادیر سیگنال در کل مدت آموزش و همچنین پیش‌بینی گپ نداشته باشند و به عبارت فاصله زمانی تمامی

گرادینان نزولی، نیاز به پس انتشار خطا در کل شبکه با قاعده‌ی مشتق‌گیری زنجیره‌ای دارد. با تکرار این چرخه، به دلیل معماری پیچیده‌ی شبکه‌های عصبی بازگشتی گرادینان می‌تواند خیلی بزرگ یا خیلی کوچک شود. این ساختارها با مشکل واگرایی گرادینان روبه‌رو می‌شوند که این مسئله به یک چالش در شبکه‌های بازگشتی تبدیل شده است و باعث عدم فراگیری وابستگی‌های زمانی طولانی مدت سیگنال ورودی می‌شود (Le et al, 2019). بنابراین مدل‌سازی وابستگی‌های زمانی در دنباله‌های طولانی غیرممکن می‌شود.

### ۲-۳- شبکه‌های عصبی حافظه بلند - کوتاه مدت (LSTM)

این شبکه‌های عصبی توسط (Hochreiter et al, 1971) معرفی شدند. در این نوع از شبکه‌های عصبی بازگشتی، دروازه‌ای معرفی می‌شود که ایده‌ی اصلی پشت آن‌ها اضافه کردن مسیری در زمان بود که نمی‌تواند گرادینان واگرا داشته باشد. شبکه‌های LSTM دارای دروازه‌هایی هستند که مدل را قادر می‌سازد در مورد اینکه چه اطلاعاتی اندوخته و چه اطلاعاتی دور ریخته شوند تصمیم بگیرد. این ساختار باعث می‌شود که شبکه با مراحل زمانی مختلف داده‌ها درگیر باشد و در نتیجه هم‌وابستگی‌های زمانی کوتاه مدت، و هم بلند مدت موجود در داده‌ها را مدل‌سازی می‌کند. LSTM‌ها ساختار زنجیرواری دارند و مجهز به چهار لایه شده‌اند که به شکل خاصی با یکدیگر در ارتباط هستند (Le et al, 2019). هسته‌ی اصلی LSTM‌ها وضعیت سلول است که به شکل یک مسیر افقی در طول شبکه ادامه پیدا می‌کند. مکانیسم دروازه‌ای که بین اتصالات وزن‌دار لایه برقرار است و همچنین تابع فعال‌سازی سیگموئید که به صفر یا یک همگرا می‌شود را می‌توان به یک تصمیم‌گیری باینری تشبیه کرد که به دروازه‌های مختلف این اجازه را می‌دهد که وضعیت سلول را به روزرسانی کنند. به عنوان مثال دروازه‌ی فراموشی می‌تواند با صفر کردن مقدار خروجی، عملاً اطلاعات اضافی را دور بریزد. خروجی دروازه‌ی فراموشی که با  $f_t$  نشان داده می‌شود از رابطه (۷) به دست می‌آید:



و خورشید است. جابجایی زمین و خورشید علاوه بر به وجود آوردن تغییرات فصلی، با گرم و سرد کردن اتمسفر منجر به تغییر چگالی اتمسفر می‌شود (Forootan et al, 2019). رابطه‌ی چگالی اتمسفر و ارتفاع به صورت یک رابطه‌ی نمایی است که با افزایش ارتفاع، مقدار چگالی اتمسفر کاهش می‌یابد (Qian et al, 2012).

علاوه بر موارد گفته‌شده، تغییر در فعالیت‌های مغناطیسی زمین و خورشید، اثر مشخصی بر نحوه‌ی توزیع چگالی اتمسفر خنثی دارند که نمی‌توان یک رفتار مشخص در برای آن‌را در زمان‌های مختلف پیدا کرد. برای در نظر گرفتن تشعشعات خورشیدی، از ضرایب فعالیت خورشیدی استفاده می‌شود که متداول‌ترین آن‌ها، ضریب  $F_{10.7}$  است که بیانگر میزان انرژی خورشیدی ساطع‌شده با طول‌موج  $10.7$  سانتی‌متر است. از طرف دیگر، تغییر در فعالیت میدان مغناطیسی زمین، موجب تغییر در چگالی خنثی و غیر خنثی جو نیز می‌شوند. میزان این فعالیت با ضرایب  $K_p$  و  $A_p$  بیان می‌شود. مجموعه‌ی عوامل گفته‌شده، باعث می‌شود تا چگالی اتمسفر دستخوش تغییر باشد و تلاش برای یافتن این تغییرات آغاز گردد.

همان‌طور که اشاره شد، ماهواره‌های گرانی‌سنجی اخیر نظیر CHAMP، GRACE و GOCE به حسگر اندازه‌گیری شتاب‌های غیرجاذبی وارد بر ماهواره مجهز شده‌اند. از اطلاعات فراهم‌شده توسط این حسگرها می‌توان برای بهبود مدل‌های تجربی چگالی اتمسفر استفاده کرد. با استفاده از روابط (۱۳) و (۱۴) می‌توان نوشت:

$$\rho = \frac{2m(a_{obs} - a_{SRP} - a_{LRR})}{AC_c |v_{rel}|^2} \quad \text{رابطه (۱۶)}$$

باتوجه به اینکه برای محاسبه‌ی چگالی اتمسفر در رابطه (۱۵) از مشاهدات ماهواره‌ی GRACE استفاده شده است، این چگالی را با  $\rho_{GRACE}$  نمایش می‌دهند. همچنین چگالی که از مدل تجربی NRLMSISE-00 به دست می‌آید را با  $\rho_{model}$  نشان داده می‌شود. برای استفاده از اطلاعات ماهواره در بهبود چگالی مدل، آن را در ضریبی ضرب کرده

داده‌ها برابر باشد تا وابستگی زمانی سیگنال به‌خوبی توسط شبکه عصبی مدل گردد.

### ۳- چگالی اتمسفر و ضرایب تصحیح

مهم‌ترین شتاب وارد بر حرکت ماهواره، شتاب ناشی از جاذبه زمین است. اما علاوه بر آن، شتاب‌های دیگری نیز به ماهواره وارد می‌شوند که به آن‌ها شتاب‌های اغتشاشی گفته می‌شود. مهم‌ترین این شتاب‌ها، شتاب ناشی از تشعشعات خورشیدی، شتاب کشش اتمسفر، شتاب تشعشعات بازتابی از زمین و شتاب اغتشاشی ناشی از جسم سوم می‌باشند (Seeber, 2003). ماهواره‌ی GRACE مجهز به شتاب‌سنج‌هایی است که شتاب‌های غیرگرانشی را می‌توانند اندازه‌گیری کنند. بنابراین شتاب ثبت‌شده از این حسگر، به صورت رابطه (۱۴) در نظر گرفته می‌شود:

$$a_{obs} = a_{drag} + a_{SRP} + a_{LRR} \quad \text{رابطه (۱۴)}$$

شتاب تشعشعات خورشیدی ( $a_{SRP}$ ) ناشی از اثر امواج الکترومغناطیسی منتشرشده از خورشید به ماهواره‌ی در حال حرکت، و شتاب تشعشعات زمین ( $a_{LRR}$ )، به خاطر بازتاب این امواج از سطح زمین است. با محاسبه‌ی این دو شتاب و کسر آن‌ها از شتاب کل مشاهده‌شده توسط ماهواره، شتاب کشش اتمسفری ( $a_{drag}$ ) باقی می‌ماند. از طرفی، شتاب کشش اتمسفری را می‌توان توسط رابطه (۱۵) محاسبه کرد:

$$a_{drag} = \frac{1}{2} C_d \frac{A}{m} \rho |v_{rel}|^2 \quad \text{رابطه (۱۵)}$$

که در آن،  $p$  چگالی اتمسفر خنثی اطراف ماهواره، ضریب  $C_d$  نیرو،  $A$  تصویر مساحت ماهواره در جهت حرکت،  $m$  جرم ماهواره و  $v_{rel}$  سرعت ماهواره نسبت به اتمسفر است (Forootan et al, 2019). بنابراین همان‌طور که ملاحظه می‌شود، چگالی اتمسفر عاملی تعیین‌کننده در محاسبه‌ی میزان کشش اتمسفری وارد بر ماهواره است. چگالی جو زمین بنا به دلایل مختلفی تغییر می‌کند. یکی از اصلی‌ترین دلایل این تغییرات، تغییر موقعیت نسبی زمین



نگاره ۲: ضرایب  $C_{200}$  مربوط به ۱۸۰ روز نخست سال ۲۰۱۴

پس از پیش‌بینی ضرایب، مدار ماهواره GRACE یکبار بدون در نظر گرفتن کشش اتمسفری و به روش انتگرال شتاب با انتگرال‌گیر عددی ODE45 تعیین می‌شود. در گام دوم مدار با در نظر گرفتن شتاب کشش اتمسفری محاسبه می‌شود. اطلاعات موقعیت و سرعت ماهواره GRACE می‌توان از [https://podaac.jpl.nasa.gov/dataset/GRAC\\_LIB\\_GRAV\\_JPL\\_RL02](https://podaac.jpl.nasa.gov/dataset/GRAC_LIB_GRAV_JPL_RL02) دریافت نمود. پس از آن به جای استفاده از چگالی خالص مدل، چگالی تصحیح‌شده برای تعیین شتاب کشش اتمسفر مورد استفاده قرار می‌گیرد و به جای استفاده از ضرایب واقعی برای تصحیح چگالی اتمسفری مدل، از ضرایب پیش‌بینی‌شده با شبکه‌ی LSTM استفاده می‌شود و نتایج ارزیابی می‌شوند.

#### ۴-۱- طراحی شبکه LSTM

پیکربندی شبکه‌های عصبی، شامل تعیین تعداد لایه‌های شبکه، تعیین واحدهای LSTM، اندازه خوشه‌ها و مشخص کردن اندازه پنجره است. تعیین هرکدام از این پارامترها با توجه به نوع مسئله، به صورت تجربی و آزمون و خطا انجام می‌گیرد. در ادامه توضیح مختصری راجع به هر پارامتر و مقدار در نظر گرفته‌شده برای آن شرح داده شده است.

**تعداد لایه‌های شبکه:** لایه‌های شبکه شامل لایه ورودی، لایه مخفی شامل نورون‌های LSTM و لایه خروجی است. برای جلوگیری از بیش‌برازش (بایاس بیش‌ازحد شبکه به

که به شکل رابطه (۱۷) به دست می‌آید:

$$\bar{a} = \frac{P_{GRACE}}{P_{model}} \quad \text{رابطه (۱۷)}$$

این ضریب بدون واحد که به صورت ده‌ثانیه‌ای در زمان و مکان ماهواره محاسبه می‌شود را می‌توان به ضرایب هارمونیک‌های کروی در بازه روزانه بسط داد. یعنی این ضرایب تصحیح‌کننده مدل تجربی به شکل میانگین روزانه به دست می‌آیند و می‌توان برای این ضرایب نوشت:

$$\begin{cases} C_{nm} \\ S_{nm} \end{cases} = \iint_{\sigma} \bar{a} \bar{P}_{nm}(\cos \theta) \begin{pmatrix} \cos m\lambda \\ \sin m\lambda \end{pmatrix} d\sigma \quad \text{رابطه (۱۸)}$$

که در آن  $\bar{P}_{nm}$  چند جمله‌ای‌های نرمال لژاندر،  $\theta$  و  $\lambda$  عرض و طول محل و  $d\sigma$  المان سطح می‌باشند. این انتگرال به روش عددی و با محدود کردن درجه و مرتبه به ۱۰ حل شده و ضرایب هارمونیک‌های کروی بسط تصحیح‌های چگالی اتمسفری به دست می‌آیند (Forootan et al, 2019). با داشتن این ضرایب می‌توان تصحیح‌های چگالی مدل در محل مورد نظر را به صورت رابطه (۱۹) به دست آورد:

$$\bar{a}(\theta, \lambda) = \frac{1}{4\pi} \sum_{n=1}^{10} \sum_{m=0}^n \bar{P}_{nm}(\cos \theta) (C_{nm} \cos m\lambda + S_{nm} \sin m\lambda) \quad \text{رابطه (۱۹)}$$

#### ۴- نتایج

در این تحقیق برای آموزش شبکه LSTM در دو حالت تک متغیره و چند متغیره، از داده‌های سری زمانی ۱۸۰ روزه‌ی ضرایب نیروی اصطکاک مربوط به نیم سال اول ۲۰۱۴ حاصل از مشاهدات ماهواره‌ی GRACE استفاده شده است. پس از آن نیز با استفاده از پارامترهای به دست آمده برای شبکه، مقادیر ضرایب تصحیح نیروی چگالی اتمسفری پیش‌بینی و مورد ارزیابی قرار می‌گیرند. آنچه در این تحقیق با استفاده از شبکه‌ی عصبی پیش‌بینی شده است مهم‌ترین ضرایب بسط چگالی به هارمونیک‌های کروی یعنی  $C_{200}$  است. مقادیر این ضرایب مربوط به ۶ ماه نخست سال ۲۰۱۴ در نگاره ۲ آورده شده است.



و مقدار پیش‌بینی شده است:

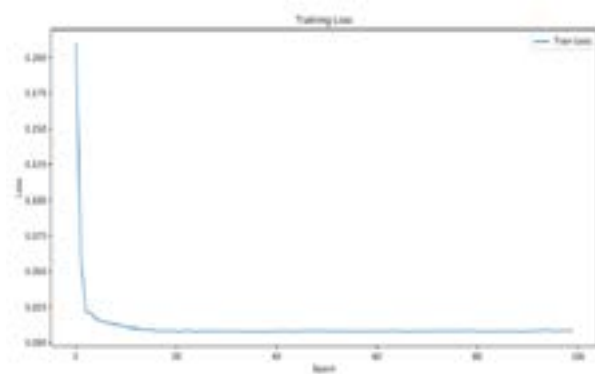
$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

رابطه (۲۰)

#### ۴-۲- پیش‌بینی ضرایب نیرو اصطکاک اتمسفری

##### به صورت تک‌متغیره

در ابتدا برای آماده کردن داده‌های جهت آموزش شبکه، عمل نرمال‌سازی بر روی ضرایب تصحیح نیروی چگالی (C<sub>00</sub>) مربوط به ۱۸۰ روز اول سال ۲۰۱۴ که برای آموزش شبکه در نظر گرفته شده‌اند انجام می‌گیرد. سپس با درصدهای در نظر گرفته شده برای آموزش و ارزیابی شبکه (۷۰ درصد برای آموزش و ۳۰ درصد برای ارزیابی شبکه (Forootan et al, 2019)) داده‌ها به دودسته‌ی: داده‌های آموزشی و داده‌ی ارزیابی به صورت تصادفی تقسیم می‌شوند. پس از آن با وارد کردن اولین مقدار از داده‌ی آزمودن در زمان t، شبکه مقدار t+1 را پیش‌بینی می‌کند. نگاره ۳ نمودار خطای شبکه را به ازای اپک‌های مختلف نشان می‌دهد.



نگاره ۳: نمودار خطای شبکه در روند آموزش به ازای اپک‌ها

پس از آموزش شبکه به صورت تک‌متغیره، از پارامترهای به‌دست آمده شبکه برای پیش‌بینی مقادیر ضرایب اصطکاک (C<sub>00</sub>) در بازه‌های ۷، ۱۴، ۳۰، ۶۰ و ۹۰ روزه استفاده می‌شود. در نگاره ۴ می‌توان مقایسه مقادیر پیش‌بینی شده با مقادیر واقعی را مشاهده نمود. همچنین مقدار RMSE برای تعداد

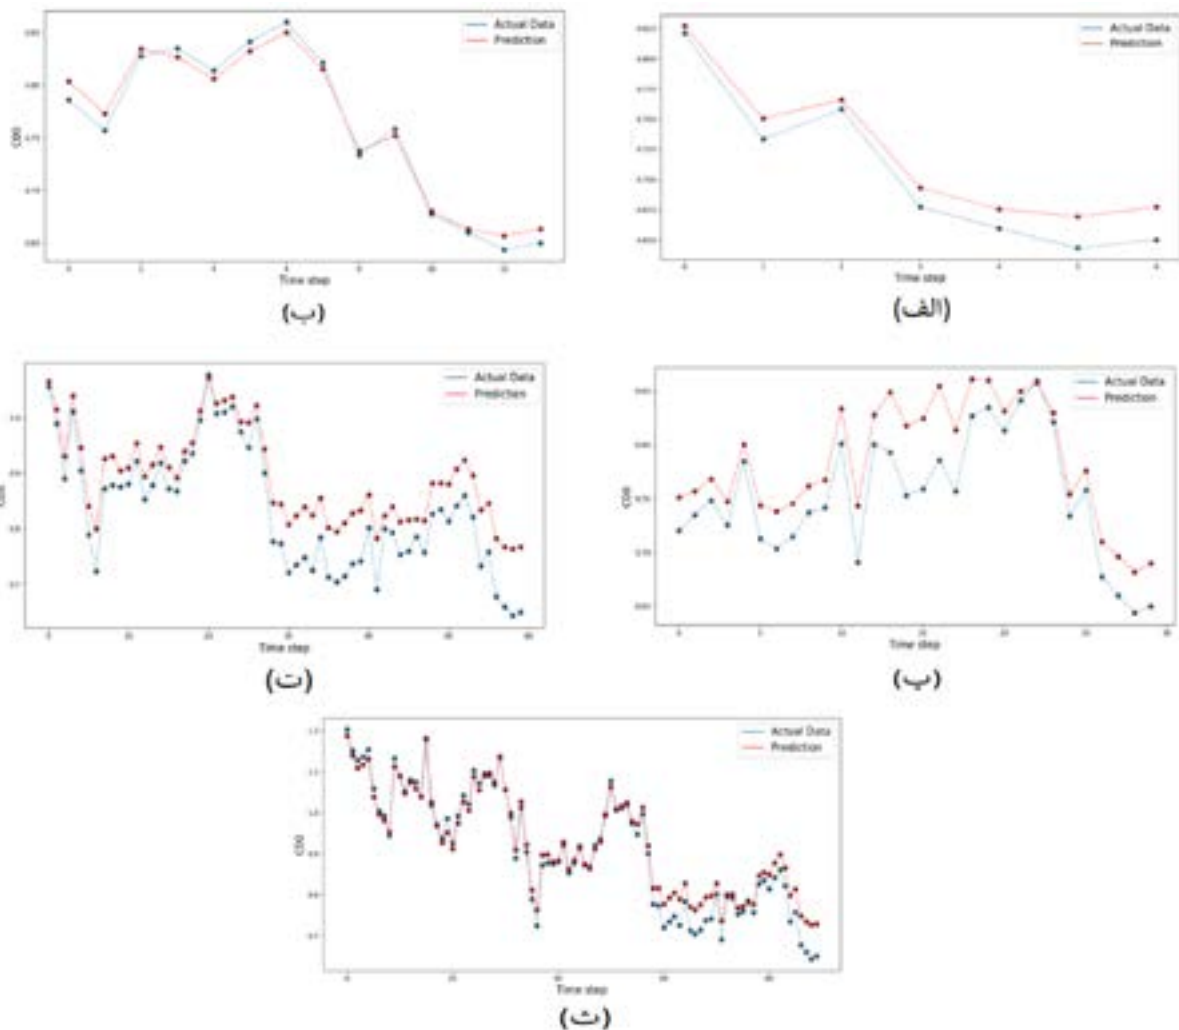
سمت داده‌های آموزش و در نتیجه عملکرد نامطلوب به ازای داده‌های مشاهده نشده‌ی آینده (روش‌های مختلفی در دسترس است. اما بهترین آن‌ها، غیرفعال کردن تعدادی از نورون‌ها به صورت تصادفی در هر بار تکرار آموزش است که نه تنها باعث جلوگیری از بیش‌برازش شبکه می‌شود، بلکه باعث می‌شود نورون‌های شبکه به صورت مستقل آموزش ببینند.

**واحدهای LSTM:** در شبکه LSTM، تعداد نورون‌های لایه مخفی برابر تعداد واحدهای LSTM است و تقریباً می‌توان آن‌ها را معادل تعداد ویژگی‌هایی که شبکه از داده‌های ورودی آموزش می‌بیند در نظر گرفت. بازه معمول برای این پارامتر بین ۱ تا ۵۰ در نظر گرفته می‌شود. اما به صورت تجربی مشخص شده که با افزایش این مقدار، علی‌رغم زمان‌بر شدن فرآیند یادگیری شبکه و همچنین در نظر گرفتن احتمال بیشتر بیش‌برازش، عملکرد آن به شدت بهبود می‌یابد.

**اندازه خوشه‌ها:** برابر تعداد داده‌هایی است که به شکل یک دسته وارد شبکه می‌شوند. مقدار این پارامتر ۱۰ در نظر گرفته شد. مزایای این کار جلوگیری از بیش‌برازش و افزایش سرعت و دقت آموزش است.

**تعداد اپک:** برای اپک مقادیر ۵۰، ۱۰۰، ۲۰۰، ۵۰۰ و ۱۰۰۰ انتخاب شد. اما همان‌طور که در نگاره ۳ و طبق خطای شبکه مشخص است، مقدار ۱۰۰ اپک بهینه و کافی است. **اندازه پنجره (Window Size):** پارامتری که با استفاده از آن می‌توان تعیین کرد که پیش‌بینی با در نظر گرفتن مقدار چند گام قبلی انجام شود. جهت به وجود آمدن امکان مقایسه در مراحل مختلف، مقدار آن برابر ۱ روز در نظر گرفته شد.

با وارد کردن داده‌های پیش‌پردازش شده به شبکه طراحی شده، امر آموزش شبکه انجام می‌گیرد. سپس با وارد کردن آخرین مقدار سری ضرایب نیرو به عنوان مقدار  $x_{t-1}$ ، مقدار  $x_t$  توسط شبکه پیش‌بینی می‌شود. معیار سنجش و مقایسه‌ی مقادیر پیش‌بینی شده با مقادیر واقعی، ریشه‌ی مجذور میانگین خطا (RMSE) است که رابطه‌ی آن به شکل رابطه (۲۰) است و در این رابطه  $\hat{y}_t$  مقدار واقعی




نگاره ۴: مقایسه مقادیر پیش‌بینی شده حالت تک متغیره و مقادیر واقعی ضرایب نیروی اصطکاک به ازای اپک‌های مختلف. خط آبی‌رنگ مقادیر واقعی و خط قرمز رنگ نیز مقادیر پیش‌بینی شده را نشان می‌دهد

همان‌طور که در نگاره ۴-ب و نگاره ۵ مشاهده می‌شود، در پیش‌بینی ضرایب اصطکاک به صورت تک متغیره، کمترین مقدار RMSE به ازای پیش‌بینی ۱۴ روزه به دست آمده است.

اپک‌های پیش‌بینی شده را می‌توان در نگاره ۵ مشاهده نمود.

#### ۴-۳- پیش‌بینی ضرایب نیرو اصطکاک اتمسفری به صورت چندمتغیره

شبکه‌های عصبی این قابلیت را دارند که فرآیند آموزش و تعیین پارامترهای به صورت چندمتغیره باشد، یعنی تعداد ورودی‌های شبکه برای آموزش بیش از یک متغیر باشد. برای آموزش شبکه به صورت چندمتغیره، دو حالت مختلف



نگاره ۵: مقدار خطای RMSE به ازای بازه‌های مختلف پیش‌بینی

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی ( )  
پیش‌بینی ضرایب تصحیح‌کننده چگالی اتمسفری با استفاده از ... / ۴۹


واقعی را می‌توان در نگاره ۶ مشاهده نمود. همان‌گونه که در نگاره ۶ مشاهده می‌شود، مقادیر RMSE نسبت به حالت تک متغیره بیشتر هستند و کمترین مقدار RMSE به ازای پیش‌بینی برای ۱۴ روز حاصل می‌گردد.

۴-۳-۲- در نظر گرفتن سری زمانی ضرایب چگالی اتمسفر (C<sub>00</sub>) به همراه فعالیت خورشیدی و ژئومغناطیسی زمین در این حالت، علاوه بر وارد کردن ضریب هارمونیک‌های کروی بسط تصحیح‌های چگالی اتمسفری (C<sub>00</sub>)، میزان فعالیت ژئومغناطیسی زمین نیز در نظر گرفته شد. مقدار این فعالیت را می‌توان با ضرایبی به نام F<sub>10</sub> و F<sub>7</sub> بیان کرد. این ضرایب به صورت ۳ ساعته اندازه‌گیری شده‌اند و در نهایت مجموع روزانه F<sub>7</sub> و میانگین F<sub>10</sub> یک سری زمانی روزانه را تشکیل می‌دهند. همچنین، ضریب فعالیت خورشیدی با طول موج ۱۰/۷ سانتی‌متر که با F<sub>10</sub>/7 نمایش داده می‌شود

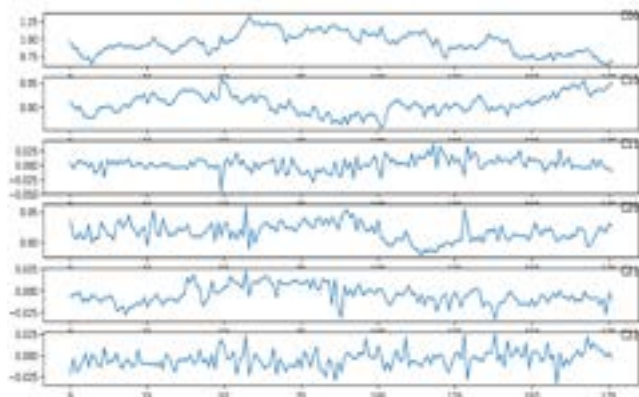
برای ورودی‌های شبکه در نظر گرفته شده است که در ادامه، نتایج مربوط به آن‌ها نشان داده شده است.

#### ۴-۳-۱- در نظر گرفتن سری زمانی ضرایب نیروی اصطکاک تا درجه دوم به عنوان ورودی شبکه عصبی

در گام نخست پیش‌بینی چندمتغیره، سری زمانی کامل بسط ضرایب تصحیح به هارمونیک‌های کروی در ۶ ماه ابتدایی سال ۲۰۱۴ تا درجه و مرتبه ۲ یعنی C<sub>00</sub>، C<sub>10</sub>، C<sub>11</sub>، C<sub>20</sub>، C<sub>21</sub> و C<sub>22</sub> برای آموزش شبکه مورد استفاده قرار گرفتند. نگاره ۷ مقادیر مشاهداتی مربوط به هر ضریب بسط اصطکاک اتمسفری را در ۶ ماه ابتدایی سال ۲۰۱۴ نشان می‌دهد. همانند حالت تک متغیره، پس از آموزش شبکه عصبی از آن برای پیش‌بینی مقادیر ضرایب اصطکاک در بازه‌های ۷، ۱۴، ۳۰، ۶۰ و ۹۰ روزه استفاده می‌شود. مقدار RMSE حاصل از مقایسه مقادیر پیش‌بینی شده با مقادیر

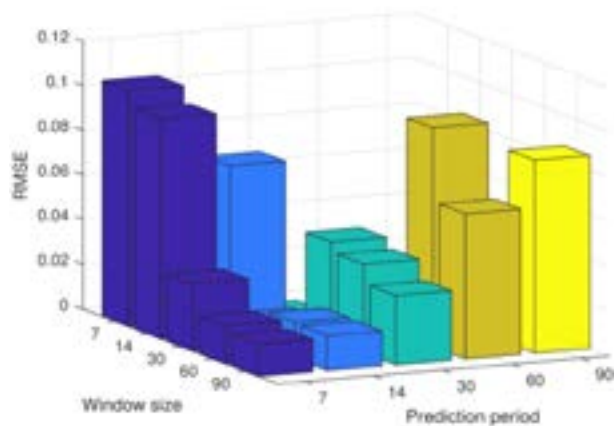


نگاره ۶: مقادیر RMSE به دست آمده از پیش‌بینی چندمتغیره ضرایب نیروی اصطکاک برای بازه‌های ۷، ۱۴، ۳۰، ۶۰ و ۹۰ روزه




نگاره ۷: مقادیر مشاهداتی C<sub>nm</sub> تا درجه و مرتبه ۲ مربوط به ۶ ماه ابتدایی سال ۲۰۱۴

صورت می‌پذیرد. این مسئله می‌تواند اثرات نامطلوبی را که داده‌های قدیمی ممکن است در تعیین پارامترهای شبکه داشته باشند حذف کند. با در نظر گرفتن حداقل اندازه پنجره به میزان تعداد روزهای پیش‌بینی، نتیجه آموزش و پیش‌بینی با ضرایب واقعی چگالی اتمسفری مقایسه شد که نتایج آن در نگاره ۱۰ ارائه شده است.



نگاره ۱۰: مقادیر RMSE به دست آمده در پیش‌بینی‌های با اندازه پنجره‌ی مختلف

نگاره ۸: مقادیر RMSE به دست آمده از پیش‌بینی چندمتغیره (ضرایب فعالیت ژئومغناطیسی و ضرایب فعالیت خورشیدی) ضرایب نیروی اصطکاک برای بازه‌های زمانی مختلف

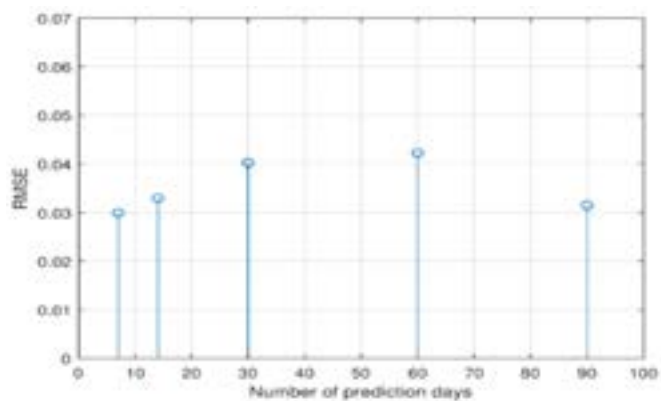


نیز برای بهبود فرآیند یادگیری و مدل‌سازی، وارد شبکه می‌گردد. در نگاره ۹ مقادیر سری زمانی هر یک از متغیرها که برای آموزش شبکه استفاده مورد استفاده قرار گرفته است نشان داده شده است.

مقدار RMSE حاصل از این مقادیر واقعی با مقادیر پیش‌بینی شده ضریب  $C_{00}$  مقایسه نیز در نگاره ۸ آورده شده است. طبق نتایج نگاره ۸، در این حالت مقدار RMSE نسبت به دو حالت قبلی کمتر است و همچنین کمترین مقدار RMSE مربوط به بازه زمانی ۷ روزه است.

#### ۴-۴- تغییر اندازه پنجره

یکی از تغییرات مهمی که می‌توان در ساختار شبکه عصبی با حافظه بلند - کوتاه مدت به منظور دسترسی به نتایج بهتر اعمال کرد، تغییر اندازه پنجره برای پیش‌بینی متغیرها است. در این حالت، کلیه داده‌های سری زمانی به صورت مستقیم، وارد روند آموزش شبکه نمی‌شوند؛ بلکه با وارد کردن تعداد کمتری ورودی، روند یادگیری شبکه



نگاره ۹: داده‌های سری زمانی  $C_{00}$ ، مجموع  $K_1$ ، میانگین  $A_1$  و میزان فعالیت خورشیدی ( $F_{10/7}$ ) مربوط به نیمه اول سال

**فصلنامه علمی - پژوهشی اطلاعات جغرافیایی ( ... )**  
پیش‌بینی ضرایب تصحیح‌کننده چگالی اتمسفری با استفاده از ... / ۵۱



اختلاف مدار تعیین‌شده‌ی فوق و سرعت آن، با مدار واقعی (داده‌های حسگر GPS ماهواره) در محورهای  $x$ ،  $y$  و  $z$  سیستم اینرشیا در نگاره ۱۱ آورده شده است. همان‌طور که در نگاره ۱۱ ملاحظه می‌شود، تصحیح مدل تجربی چگالی، موجب می‌شود مدار تعیین‌شده و به‌خصوص بردار سرعت تعیین‌شده به مقادیر واقعی خود بسیار نزدیک می‌شود. این بهبود از آن‌جایی حاصل شده که ضرب چگالی در ضریب تصحیح، باعث می‌شود مقدار واقعی چگالی در محاسبه شتاب کشش اتمسفری به‌کار رود و اثر این نیروی اغتشاشی به‌درستی وارد محاسبات شود.

در این مرحله، به‌جای استفاده از ضرایب تصحیح واقعی، از ضرایب پیش‌بینی‌شده با شبکه عصبی در بازه‌های ۷، ۱۴، ۳۰، ۶۰ و ۹۰ روزه با اندازه پنجره یک‌روزه برای تعیین مدار استفاده می‌شود و مدار تولیدشده توسط این ضرایب با مدار واقعی مقایسه می‌گردد که نتایج RMSE بردارهای موقعیت و سرعت در نگاره ۱۲ آورده شده است. با توجه به نگاره ۱۲-ب، ت، ج، خ، ز، می‌توان مشاهده نمود که به‌ازای افزایش زمان پیش‌بینی مقدار RMSE برای موقعیت ماهواره افزایش می‌یابد و کمترین مقدار RMSE مربوط به پیش‌بینی ۷ روزه و بیشترین مقدار آن مربوط به پیش‌بینی ۹۰ روزه است.

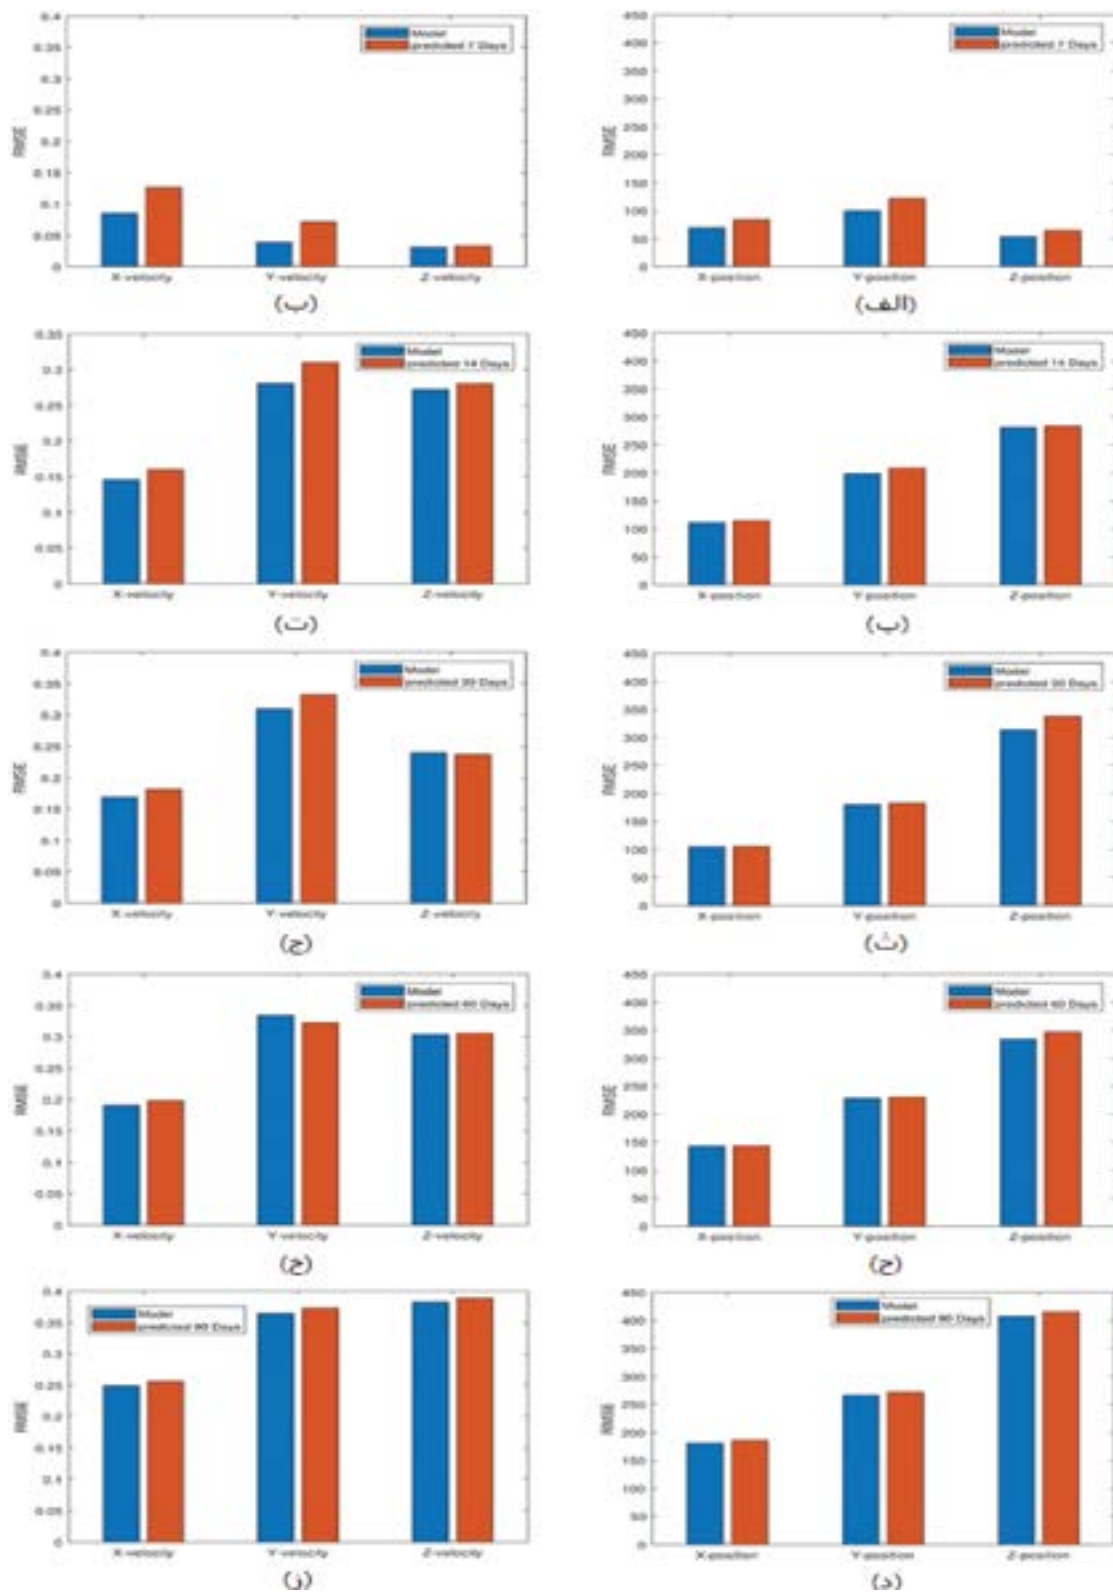
با توجه به مقادیر RMSE در نگاره ۱۰ و مقایسه آن‌ها با مقدار RMSE حالت‌های قبل در نگاره ۵ و ۷ و ۱۰، مشاهده می‌شود که در حالتی که برای پیش‌بینی‌های ۷، ۱۴ و ۳۰ روزه‌ی ضریب  $\rho_{00}$  از تغییر اندازه پنجره استفاده شود، پیش‌بینی‌ها، حتی از حالت شبکه‌ی آموزش‌دیده با سری زمانی کامل داده‌ها نیز بهتر می‌شود. با توجه به نگاره ۱۰، مشاهده می‌شود که بیشترین مقادیر RMSE مربوط به پنجره‌هایی با طول ۷ و ۱۴ روز است و با افزایش اندازه پنجره مقدار RMSE کاهش می‌یابد. همچنین کمترین مقدار RMSE مربوط به پیش‌بینی ۷ روزه با طول پنجره ۹۰ روی است.

**۴-۵- مقایسه مدار تعیین‌شده با مدار واقعی**

برای نشان‌دادن تأثیر تصحیح مدل‌های چگالی بر روی مدار ماهواره‌ها، ابتدا مدار ماهواره GRACE-A با در نظر گرفتن شتاب‌های اغتشاشی ذکرشده در رابطه (۱۳) و با استفاده از انتگرال‌گیر عددی ODE45 در نرم‌افزار MATLAB با تنظیم پارامتر خطای نسبی به میزان  $10^{-14}$  و خطای مطلق  $10^{-16}$  تعیین می‌شود. برای مقایسه، مدار ماهواره گریس بعد از ۶ ماه اول سال ۲۰۱۴ در بازه‌های ۷ و ۱۴ و ۳۰ و ۶۰ و ۹۰ روزه پیش‌بینی‌شده است و مقدار RMSE حاصل از



نگاره ۱۱: الف) مقدار RMSE حاصل از مقایسه موقعیت واقعی ماهواره گریس با مدل عددی و مقادیر پیش‌بینی‌شده. ب) مقدار RMSE حاصل از سرعت واقعی ماهواره گریس با مدل عددی و مقادیر پیش‌بینی‌شده. نمودارهای آبی‌رنگ مربوط به مدل عددی و نمودارهای قرمز رنگ مربوط به مقادیر پیش‌بینی‌شده هستند



نگاره ۱۲: مقدار RMSE حاصل از مقایسه مدار واقعی و مدار تعیین شده با تصحیح‌های پیش‌بینی‌شده در ایستگاه‌های زمانی در نظر گرفته‌شده. شکل‌های سمت راست مقادیر RMSE را برای موقعیت ماهواره و شکل‌های سمت چپ نیز مقادیر RMSE را برای سرعت ماهواره نشان می‌دهند.



از مدار واقعی در حالت پیش‌بینی ۷ روزه حاصل می‌گردد و پیش‌بینی ضریب اصطکاک اتمسفری با شبکه‌ی عصبی LSTM قادر است مدار ماهواره را با RMSE در حدود ۰/۱۵ متر نتیجه دهد.

#### ۶- منابع و مآخذ

- 1- Albertella, A., Migliaccio, F., Sansó, F. (2002). GOCE: The Earth gravity field by space gradiometry. Modern celestial mechanics: from theory to applications. Springer, 1-15.
- 2- Amari, S.-i. (1993). Backpropagation and stochastic gradient descent method. Neurocomputing 5, 185-96.
- 3- Belehaki, A., Stanislawski, I., Liliensten, J. (2009). An overview of ionosphere—Thermosphere models available for space weather purposes. Space science reviews 147, 271-313.
- 4- Bruinsma, S., Biancale, R. (2003). Total densities derived from accelerometer data. Journal of Spacecraft and Rockets 40, 230-6.
- 5- Codrescu, M., Fuller-Rowell, T., Minter, C. (2004). An ensemble-type Kalman filter for neutral thermospheric composition during geomagnetic storms. Space Weather 2.
- 6- Codrescu, S., Codrescu, M., Fedrizzi, M. (2018). An ensemble Kalman filter for the thermosphere-ionosphere. Space Weather 16, 57-68.
- 7- Doornbos, E., Bruinsma, S., Fritsche, B., et al. (2013). Air density and wind retrieval using GOCE data. ESA Living Planet Symposium. pp. 7.
- 8- Doornbos, E., Forster, M., Fritsche, B., et al. (2009). Air density models from multiple-satellite drag observations. DEOS/TU Delft Scientific Report 1.
- 9- Forootan, E., Didova, O., Kusche, J., Löcher, A. (2013). Comparisons of atmospheric data and reduction methods for the analysis of satellite gravimetry observations. Journal of Geophysical Research: Solid Earth 118, 2382-96.
- 10- Forootan, E., Farzaneh, S., Lück, C., Vielberg, K. (2019). Estimating and predicting corrections for empirical thermospheric models. Geophysical Journal

#### ۵- نتیجه‌گیری

این مطالعه با هدف بهبود و تصحیح مدل‌های تجربی چگالی اتمسفر با استفاده از شبکه‌های عصبی با حافظه بلند-کوتاه مدت (LSTM) از خانواده‌ی شبکه‌های عصبی بازگشتی انجام گرفته است. برای این هدف، از مشاهدات تصحیح‌های چگالی اتمسفر شتاب‌سنج ماهواره‌ی GRACE برای آموزش شبکه استفاده شده است و ضرایب تصحیح، با استفاده از میانگین روزانه‌ی داده‌های شتاب‌سنج ماهواره به‌دست آمده‌اند. شبکه‌ی LSTM نیز در دو حالت تک متغیره (آموزش فقط با استفاده از ضریب مرتبه‌ی صفر تصحیح نیروی چگالی اتمسفری) و چندمتغیره (آموزش با استفاده از ضرایب بسط تصحیح نیروی چگالی تا درجه و مرتبه دوم و همچنین آموزش با استفاده از ضریب مرتبه‌ی صفر تصحیح نیروی چگالی و همچنین ضرایب فعالیت ژئومغناطیسی و ضرایب فعالیت خورشیدی) توسعه داده شد. پس از آموزش شبکه عصبی LSTM، مقادیر ضرایب اصطکاک اتمسفری در بازه‌های ۷، ۱۴، ۳۰، ۶۰ و ۹۰ روزه پیش‌بینی و مقادیر به‌دست‌آمده با مقادیر واقعی پارامتر ضریب اصطکاک مقایسه گردیدند. نتایج نشان دادند که در حالت تک‌متغیره بهترین بازه پیش‌بینی ۱۴ روز است. همچنین در حالتی که از ضرایب بسط اصطکاک اتمسفری تا درجه و مرتبه‌ی دوم استفاده شود، بهترین بازه پیش‌بینی نیز ۱۴ روز است. اما در صورت استفاده از ضرایب فعالیت ژئومغناطیسی و ضرایب فعالیت خورشیدی در شبکه بهترین بازه‌ی پیش‌بینی ۷ روزه حاصل گردیده است. از مقایسه نتایج حالت تک‌متغیره با حالت چندمتغیره مشخص شده است که کمترین RMSE در حدود ۰/۰۳ مربوط به حالت چندمتغیره با به‌کارگیری ضرایب فعالیت ژئومغناطیسی و ضرایب فعالیت خورشیدی بوده است. همچنین در ادامه با استفاده از ضرایب چگالی اتمسفری پیش‌بینی‌شده توسط شبکه عصبی، تصحیح چگالی اتمسفری به‌شتاب ماهواره در هر لحظه اعمال شده و مدار ماهواره انتشار یافته و با مدار واقعی مقایسه گردیده است. نتایج این مقایسه نیز نشان دادند که کمترین اختلاف

- 24- Suparta, W., Alhasa, K.M. (2013). A comparison of ANFIS and MLP models for the prediction of precipitable water vapor. 2013 IEEE international conference on space science and communication (IconSpace). IEEE, pp. 243-8.
- 25- Sutton, E.K. (2008). Effects of solar disturbances on the thermosphere densities and winds from CHAMP and GRACE satellite accelerometer data. University of Colorado at Boulder.
- 26- Tapley, B.D., Bettadpur, S., Watkins, M., Reigber, C. (2004). The gravity recovery and climate experiment: Mission overview and early results. *Geophysical research letters* 31.
- 27- Zhang, G.P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing* 50, 159-75.
- International 218, 479-93.
- 11- Harris, I., Priester, W. (1962). Time-dependent structure of the upper atmosphere. *Journal of Atmospheric Sciences* 19, 286-301.
- 12- Hochreiter, S., Schmidhuber, J. (1971). Long short-term memory. *Neural computation* 9, 1735-80, 1997.
- 13- Jacchia, L.G. (1971). Revised static models of the thermosphere and exosphere with empirical temperature profiles. SAO special report 332.
- 14- Khashei, M., Bijari, M. (2010). An artificial neural network (p, d, q) model for timeseries forecasting. *Expert Systems with applications* 37, 479-89.
- 15- Le, X.-H., Ho, H.V., Lee, G., Jung, S. (2019). Application of long short-term memory (LSTM) neural network for flood forecasting. *Water* 11, 1387.
- 16- Matsuo, T., Lee, I.T., Anderson, J.L. (2013). Thermospheric mass density specification using an ensemble Kalman filter. *Journal of Geophysical Research: Space Physics* 118, 1339-50.
- 17- Minter, C., Fuller-Rowell, T., Codrescu, M. (2004). Estimating the state of the thermospheric composition using Kalman filtering. *Space Weather* 2.
- 18- Picone, J., Hedin, A., Drob, D.P., Aikin, A. (2002). NRLMSISE-00 empirical model of the atmosphere: Statistical comparisons and scientific issues. *Journal of Geophysical Research: Space Physics* 107, SIA 15-1-SIA-6.
- 19- Qian, L., Solomon, S.C. (2012). Thermospheric density: An overview of temporal and spatial variations. *Space science reviews* 168, 147-73.
- 20- Reigber, C., Lühr, H., Schwintzer, P. (2002). CHAMP mission status. *Advances in space research* 30, 129-34.
- 21- Sak, H., Senior, A.W., Beaufays, F. (2014). Long short-term memory recurrent neural network architectures for large scale acoustic modeling.
- 22- Seeber, G. (2003). *Satellite Geodesy, 2nd completely revised and extended edition*. Walter de Gruyter GmbH & Co. KG 10785, 303-4.
- 23- Şenkal, O., Yıldız, B.Y., Şahin, M., Pestemalçı, V. (2012). Precipitable water modelling using artificial neural network in Cukurova region. *Environmental monitoring and assessment* 184, 141-7.