

Spatio-temporal modeling and forecasting of precipitable water vapor using Long Short Term Memory neural network, case study: Tehran province

Forati, F.¹  | Voosoghi, B.¹  | Ghaffari-Razin, S. R.²  

1. Department of Geomatics Engineering, Geodesy & Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran.

2. Department of Surveying Engineering, Faculty of Geoscience Engineering, Arak University of Technology, Arak, Iran.

Corresponding Author E-mail: mr.ghafari@arakut.ac.ir

(Received: 18 May 2024, Revised: 19 Aug 2024, Accepted: 4 Jan 2025, Published online: 10 June 2025)

Summary

Precipitable water vapor (PWV) is one of the most important parameters in meteorological studies, which can be calculated using ground measurements such as radiosondes and radiometers, as well as indirect methods such as GPS observations. Due to the spatial limitations of meteorological stations, as well as observational discontinuities in the time domain, PWV modeling with new methods is of great importance. Various models have been developed to estimate the amount of water vapor (WV) and tropospheric refraction component. These models can be divided into two categories: empirical and analytical models. Among the analytical models, we can mention to the tomography method. Considering the spatial limitation of GPS and meteorological stations, as well as the discontinuity of observations in the time domain, modeling of PWV is very important. In order to overcome these limitations in PWV forecasting, the idea of using machine learning (ML) models has been proposed. In the first step, the zenith tropospheric delay (ZTD) is calculated with Gamit software. Then using the Saastamoinen empirical model as revised by Davis the value of zenith hydrostatic delay (ZHD) is calculated. By subtracting the amount of ZHD from ZTD, zenith wet delay (ZWD) is obtained at each GPS stations. Using the formula by Bavis, ZWD can be converted to PWV for any time. In this paper for the first time in Iran, the amount of PWV has been modeled and forecasted using the long short-term memory (LSTM) method. LSTM is one of the recurrent neural networks which is mostly used for time series purposes. The observations of Tehran GPS network in the 2021 and 2022 for the periods of 312 to 347 and 33 to 78 DOY have been used to evaluate the performance of the LSTM. It should be noted that the parameters of longitude, latitude and altitude, as well as day of year (DOY) and time (hour) are considered as inputs to LSTM model to estimate PWV. The results of this model are compared with the results of GRNN which is a type of radial basis function (RBF), GPT3 and Saastamoinen empirical models. Statistical indicators of root mean square error (RMSE) and correlation coefficient are used to check the accuracy of the models in control station. The RMSE for the control station of LSTM, GRNN, GPT3 and Saastamoinen models in 2021 is 0.5, 1.34, 7.12 and 7.65 mm, respectively. Also, the RMSE of three models for the control station in 2022 is 0.9, 1.19, 3.32 and 3.28 mm, respectively. The results show that the LSTM model has high accuracy to forecast the amount of PWV compared to GRNN and empirical models. As a result, the new model presented in this paper can be used as an alternative to empirical models in forecasting precipitable water vapor.

Keywords: Precipitable Water Vapor, GPS, LSTM, GRNN.

Cite this article: Forati, F., Voosoghi, B., & Ghaffari-Razin, S. R. (2025). Spatio-temporal modeling and forecasting of precipitable water vapor using Long Short Term Memory neural network, case study: Tehran province. *Journal of the Earth and Space Physics*, 51(1), 117-132. DOI: <http://doi.org/10.22059/jesphys.2025.375870.1007604>

E-mail: (1) fforati1999@gmail.com | vosoghi@kntu.ac.ir



Publisher: University of Tehran Press.
DOI: <http://doi.org/10.22059/jesphys.2025.375870.1007604>

Print ISSN: 2538-371X
Online ISSN: 2538-3906

پیش‌بینی مکانی-زمانی بخار آب قابل بارش با استفاده از شبکه عصبی حافظه کوتاه مدت طولانی (مطالعه موردی: استان تهران)

فاطمه فراتی^۱ | بهزاد وثوقی^۱ | سید رضا غفاری رزین^۲✉

۱. گروه مهندسی ژئودزی، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران.

۲. گروه مهندسی نقشه‌برداری، دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک، اراک، ایران.

رایانامه نویسنده مسئول: mr.ghafari@arakut.ac.ir

(دریافت: ۱۴۰۳/۲/۲۹، بازنگری: ۱۴۰۳/۵/۲۹، پذیرش نهایی: ۱۴۰۳/۱۰/۱۵، انتشار آنلاین: ۱۴۰۴/۳/۲۰)

چکیده

در این مقاله ایده استفاده از روش شبکه عصبی حافظه کوتاه مدت طولانی (LSTM) جهت مدل سازی و پیش‌بینی مکانی-زمانی مقدار بخار آب قابل بارش (PWV) به عنوان یک روش جدید ارائه شده است. مدل LSTM به دلیل ساختار خاص خود، قادر است اطلاعات مهم را در طول زمان حفظ و مشکلاتی مانند محو شدگی یا انفجار گرادیان را حل کند. این ویژگی‌ها باعث می‌شود که LSTM در پردازش داده‌های سری زمانی و مسائلی که نیاز به حفظ ترتیب زمانی دارند، بسیار کارآمد باشد. جهت ارزیابی مدل جدید، مشاهدات ۵ ایستگاه GPS شبکه تهران در سال ۲۰۲۱ برای بازه زمانی روزهای ۳۱۲ الی ۳۴۷ و در سال ۲۰۲۲ برای بازه زمانی روزهای ۳۳ الی ۷۸ مورد استفاده قرار گرفته است. از بین این ۵ ایستگاه GPS، ایستگاه هشتگرد که در فاصله بیشتری از سایر ایستگاه‌ها قرار دارد، به عنوان ایستگاه آزمون انتخاب شده است. در مرحله آزمون، نتایج حاصل از مدل LSTM با نتایج مدل شبکه عصبی رگرسیون عمومی (GRNN) و مدل‌های تجربی GPT3 و ساستاموین مقایسه شده است. شاخص‌های آماری جذر خطای مربعی میانگین (RMSE) و ضریب همبستگی برای بررسی دقت و صحت مدل‌ها استفاده می‌شوند. مقدار RMSE مدل‌های LSTM، GRNN، GPT3 و ساستاموین در سال ۲۰۲۱، به ترتیب ۰/۵ و ۱/۳۴ و ۷/۱۲ و ۷/۶۵ میلی متر است. در سال ۲۰۲۲ مقدار RMSE به ترتیب برابر با ۰/۹ و ۱/۱۹ و ۳/۳۲ و ۳/۲۸ میلی متر به دست آمده است. نتایج به دست آمده از این مقاله نشان می‌دهد که مدل LSTM در مقایسه با مدل GRNN و مدل‌های تجربی، از دقت و صحت بالایی در برآورد مقدار بخار آب قابل بارش برخوردار است. در نتیجه مدل جدید ارائه شده در این مقاله می‌تواند به عنوان جایگزین سایر مدل‌ها در پیش‌بینی بخار آب قابل بارش باشد.

واژه‌های کلیدی: بخار آب قابل بارش، GPS، LSTM، GRNN.

۱. مقدمه

با پیشرفت تکنولوژی و روی کار آمدن سامانه‌های ماهواره‌ای ناوبری جهانی (GNSS) و همچنین پیشرفت در زمینه‌های مطالعات علوم زمین و پیش‌بینی‌های هواشناسی، مطالعه بیشتر در مورد جو و پارامترهای آن اهمیت ویژه‌ای پیدا کرده و باعث پیدایش روش‌های مختلف جهت رسیدن به دقت بالاتری برای تخمین پارامترهای جو شده است. جو زمین را از لحاظ خاصیت الکتریکی معمولاً به دو بخش تروپوسفر و یونسفر تقسیم می‌کنند. تروپوسفر پایین‌ترین بخش جو زمین بوده و تا ارتفاع ۴۰ کیلومتری از سطح زمین گسترش می‌یابد. از لایه تروپوسفر تا ارتفاع ۱۰۰۰ کیلومتری از سطح زمین را یونسفر می‌گویند. یونسفر یک محیط پاشنده برای امواج

الکترومغناطیسی عبوری از آن بوده و انتشار امواج در این محیط به فرکانس بستگی دارد. اما در تروپوسفر انتشار امواج به فرکانس وابسته نیست، بنابراین یک محیط غیرپاشنده بوده و سیگنال‌های عبوری از آن تحت تأثیر پارامترهای دما، رطوبت، فشار و بخار آب هستند. تأخیر تروپوسفری در راستای زینت (ZTD) را می‌توان به دو مؤلفه خشک و تر تقسیم کرد. سهم بخش خشک ۹۰ درصد و سهم بخش تر ۱۰ درصد می‌باشد. با وجود این که بخش خشک سهم بیشتری در محاسبه تأخیر تروپوسفری دارد، اما مدل سازی بخش تر به دلیل تغییرات مکانی و زمانی زیاد فشار بخار آب، نقش به سزایی در برآورد خطای تروپوسفری دارد (سییر، ۲۰۰۳). با برآورد بخش تر، بخار آب

استناد: آقایی، مجتبی؛ احمدی گیوی، فرهنگ؛ محب‌الحجه، علیرضا و میرزائی، محمد (۱۴۰۴). نقش یاخته هادلی در گردش کلی جو و شکل گیری واپرخند جنب‌حاره‌ای بر روی جنوب غرب آسیا. مجله فیزیک زمین و فضا، ۵۱(۱)، ۱۱۷-۱۳۲. DOI: <http://doi.org/10.22059/jesphys.2024.371042.1007586>

رایانامه: (۱) mirzaeim@ut.ac.ir | amoheb@ut.ac.ir | man.mojtabaaghaie@ut.ac.ir

بهترین وسیله جهت به‌دست آوردن اطلاعات از چگونگی تغییرات بخار آب جو به‌صورت غیرمستقیم، استفاده از اندازه‌گیری‌های GNSS است. با استفاده از تکنیک‌های هواشناسی با GNSS می‌توان مشاهدات پیوسته و تقریباً آنی از مقدار بخار آب اطراف یک ایستگاه GNSS به‌دست آورد. لازم به‌ذکر است که در هنگام استفاده از هر یک از این تکنیک‌ها عوامل مختلفی چون هزینه، دقت، محدودیت عملیاتی، قدرت تفکیک مکانی و زمانی دخیل است.

تاکنون مدل‌های مختلفی جهت برآورد و پیش‌بینی مقدار بخار آب و مؤلفه ترانکسار تروپوسفری توسعه داده شده است. این مدل‌ها را می‌توان به دو دسته مدل‌های تجربی و مدل‌های تحلیلی تقسیم‌بندی کرد. از جمله مدل‌های تجربی ارائه‌شده برای محاسبه بخار آب و رطوبت مؤلفه تر می‌توان به مدل ساستاموین، مدل هافیلد، مدل ایفادیس و مدل برمن اشاره کرد (ساستاموین، ۱۹۷۳) از جمله مدل‌های تحلیلی می‌توان به مدل‌های توموگرافی اشاره کرد. در سالیان اخیر این مدل‌ها به‌دلیل قابلیت و دقت بسیار بالا در برآورد مقدار بخار آب و رطوبت در تروپوسفر، مورد توجه بسیاری قرار گرفته است.

رهم و بزی (۲۰۱۱) قیودی را که از طریق آنالیز جریان باد داده‌های رادیوسوند و مدل کامپس به‌دست آمده بود، جهت یکتا کردن جواب حاصل به دستگاه معادلات افزودند. ادوای و مشهدی حسینی (۲۰۱۴) با استفاده از روش ایستگاه‌های مرجع مجازی (VRS) انکسار تر تروپوسفر را با اندازه‌گیری‌های GPS در شمال غرب ایران مدل‌سازی کردند تا مشکل کمبود مرتبه را برطرف کنند. چن و لیو (۲۰۱۴) رویکردی را برای بهینه‌سازی توزیع المان‌های حجمی در هر دو حوزه تفکیک قائم و افقی پیشنهاد کردند. آنها از نمایه‌های رادیوسوندی برای بهینه‌سازی تفکیک ارتفاعی مدل توموگرافی و از روش تقاطع پرتو با سطح المان‌های حجمی برای بهینه‌سازی تفکیک افقی استفاده کردند. یی و همکاران (۲۰۱۶) پردازش توموگرافی بخار آب را در چند جنبه با کمک رادیوسوند و داده‌های COSMIC بهینه کردند. ویلقان و همکاران (۲۰۱۷) از مدل‌های عددی هواشناسی، مشاهدات ایستگاه‌های GNSS و مشاهدات زمینی هواشناسی استفاده و مسئله توموگرافی تروپوسفر را حل

قابل بارش (PWV) که یکی از پارامترهای مهم در مطالعات هواشناسی می‌باشد، قابل محاسبه است. با توجه به محدودیت مکانی ایستگاه‌های هواشناسی و GPS، همچنین ناپیوستگی مشاهداتی در حوزه زمان، مدل‌سازی مقادیر PWV بسیار حائز اهمیت است.

به کل بخار آب موجود در ستونی از جو که قابلیت بارش دارند بخار آب قابل بارش می‌گویند. بخار آب قابل بارش یک کمیت ارزشمند برای پیش‌بینی‌های آب‌وهوایی است. مقدار بخار آب موجود در جو عامل مهمی است که می‌تواند همراه با عوامل دیگر میزان بارندگی را تعیین کرده و رفتارهای دینامیکی طوفان‌ها در آینده را بررسی کند. پیش‌بینی آب‌وهوا به داشتن داده‌های دقیق بخار آب قابل بارش با پوشش زمانی و مکانی کافی در منطقه موردنظر بستگی دارد. افزایش در دسترس بودن داده‌های PWV پیش‌بینی‌های دقیق‌تری را تضمین می‌کند. به ویژه در مناطق آب‌وهوایی خشک با ارتفاع بالاتر که در آن فواصل زیادی بین مکان‌های اندازه‌گیری PWV وجود دارد، اهمیت اندازه‌گیری دقیق این پارامتر جوی کاملاً احساس می‌شود. به‌دست آوردن بخار آب با استفاده از اندازه‌گیری‌های مستقیم و دستگاه‌های اندازه‌گیری بخار آب کاری سخت و پر هزینه است. رادیوسوند و رادیومترها جهت اندازه‌گیری مستقیم بخار آب جو استفاده می‌شوند، اما استفاده از این دستگاه‌ها دارای مشکلات و محدودیت‌هایی خواهد بود. برای مثال هزینه نگهداری این دستگاه‌ها گران بوده و همچنین این دستگاه‌ها دارای پوشش ایستگاهی مناسبی نیستند. مشاهدات حاصل از بالون‌های هواشناسی رادیوسوندی، متراکم، یکنواخت و پیوسته نیستند. علاوه بر این اطلاعات رادیوسوندی به سرعت در اختیار کاربران قرار نمی‌گیرد، زیرا حدوداً یک ساعت زمان لازم است که بالون‌های رادیوسوندی به بالاترین ارتفاع تروپوسفر برسند. همچنین بررسی لحظه‌ای تغییرات زمانی و مکانی بخار آب از طریق رادیوسوندها وجود ندارد، زیرا بالون‌های رادیوسوندی تنها دو بار در روز پرتاب می‌شوند. بنابراین قدرت تفکیک زمانی مشاهدات بخار آب و نیز تراکم افقی اطلاعات کافی نیست. به‌علاوه تجهیزات رادیوسوندی گران قیمت هستند (موسوی و همکاران، ۱۳۸۶). با توجه به معایب روش‌های نامبرده،

کرده و انکسار کل تروپوسفر را محاسبه کردند. حاجی آقاجانی و عامریان (۲۰۱۷) از تکنیک ردیابی اشعه سه بعدی بر اساس معادلات آیکونال و داده‌های باز تحلیل ERA-Interim برای بازسازی مقدار بخار آب تروپوسفر در منطقه ایران استفاده کردند. بنویدس و همکاران (۲۰۱۸) جهت محاسبه بخار آب در مقیاس‌های محلی از روش توموگرافی استفاده کردند. آنها از مقادیر بخار آب نمایه‌های رادیوسوندی برای مقادیر اولیه روش توموگرافی استفاده کردند. ژو و همکاران (۲۰۱۹) از مشاهدات ایستگاه‌های خارج از محدوده توموگرافی برای افزایش دقت بازسازی تروپوسفر استفاده کردند. نتایج حاصل از روش پیشنهادی ایشان در بازسازی مقدار بخار آب جو بالای شبکه مورد بررسی، حاکی از دقت و صحت بالای آن بود. غفاری رزین و وثوقی (۲۰۲۰) از روش توموگرافی المان‌های حجمی به همراه شبکه‌های عصبی مصنوعی (ANN) جهت بازسازی مقدار انکسار تر تروپوسفر در منطقه شمال غرب ایران استفاده کردند. فروتن و همکاران (۲۰۲۱) برای مدل‌سازی تغییرات ارتفاعی از توابع هارمونیک کلاه کروی و برای مدل‌سازی عمودی از توابع متعامد تجربی مشتق گرفته از ERA5 استفاده کرده‌اند. حاجی آقاجانی و همکاران (۲۰۲۱) اثر استفاده از روش‌های توموگرافی تروپوسفری مبتنی بر عملکرد و مبتنی بر المان حجمی را بر دقت موقعیت‌یابی مطالعه کردند. ژانگ و همکاران (۲۰۲۱) یک مدل توموگرافی ترکیبی از GNSS و سنجش از دور را برای بهره‌برداری کامل از ارزش سیگنال‌های GNSS و اندازه‌گیری‌های سنجش از دوری توسعه دادند. نتایج آنها نشان داد که توموگرافی تروپوسفر GNSS-RS پتانسیل قابل توجهی برای بهبود بازسازی میدان‌های بخار آب جوی دارد. سرخابی و جمور (۲۰۲۴) با استفاده از مشاهدات ۵ ایستگاه دائمی GPS در منطقه ارسباران در شمال غرب ایران، میزان PWV را برای پیش‌بینی سیل اکتبر ۲۰۱۲، در این منطقه ارزیابی کردند. همچنین، توموگرافی بر روی ایستگاه‌های GPS انجام شده و با استفاده از روش تیخونوف برای مختصات عرض و ارتفاع برای سه روز متوالی، یعنی روز قبل از سیل، روز سیل و روز پس از سیل، ارزیابی شده

است. نتایج آنها نشان داد که مقادیر زیادی PWV در تروپوسفر، در روز قبل از سیل و به‌ویژه در روز سیل مشاهده شده است.

برآورد بخار آب قابل بارش و چگالی بخار آب با استفاده از روش توموگرافی دارای معایبی می‌باشد. ماتریس ضرایب در حل مسئله توموگرافی المان‌های حجمی کمبود مرتبه داشته و جهت از بین بردن آن می‌بایستی مقادیر اولیه از مقدار بخار آب در دسترس باشد. همچنین مقدار بخار آب داخل هر المان حجمی ثابت و بدون تغییر در نظر گرفته می‌شود، در صورتیکه این پارامتر دارای تغییرات زیاد مکانی و زمانی است (صادقی و همکاران، ۲۰۲۲). در این روش، تعداد مجهولات بسیار زیاد بوده و برآورد آنها از لحاظ محاسباتی کار دشواری است (حاجی آقاجانی و همکاران، ۲۰۲۰).

جهت غلبه بر محدودیت‌های روش‌های مستقیم و غیرمستقیم در برآورد بخار آب، ایده استفاده از مدل‌های مبتنی بر یادگیری ماشین (ML) و یادگیری عمیق (DL) جهت برآورد PWV مطرح شده است. روش‌های یادگیری ماشین دارای صحت و دقت بالا در محاسبات و پیچیدگی‌های محاسباتی کمتری هستند. ژین و درن (۲۰۰۵) از یک شبکه عصبی مصنوعی با ورودی‌های ماه، عرض جغرافیایی، ارتفاع و زاویه انکسار جهت مدل‌سازی مقدار PWV استفاده کردند. سلسوگلو (۲۰۲۰) از یک مدل شبکه عصبی به همراه پارامترهای هواشناسی، جهت برآورد مقدار تأخیر تر تروپوسفری استفاده کرد. سامخانیانی و همکاران (۲۰۲۱) از شبکه عصبی پرسپترون چندلایه (MLP) و شبکه عصبی خودبازگشتی غیرخطی با ورودی‌های خارجی (NARX) جهت پیش‌بینی بارش استفاده کردند. آنها از داده‌های GPS و هواشناسی در ایستگاه تهران در سال‌های ۲۰۰۷ تا ۲۰۱۰ برای آموزش مدل‌ها و از داده‌های سال ۲۰۱۱ برای اعتبارسنجی استفاده کردند. نتایج مطالعه آنها نشان داده است مدل NARX در مقایسه با مدل MLP و سیستم پیش‌بینی جهانی (GFS) عملکرد بهتری داشته است. غفاری رزین و اینیورت (۲۰۲۲) از سیستم استنتاج عصبی-فازی سازگار (ANFIS) جهت مدل‌سازی زمانی و مکانی بخار آب قابل بارش استفاده کردند. نتایج آنها توانایی و دقت بالای مدل پیشنهادشده را در تعیین

می‌شوند و باعث می‌شوند که وزن‌ها به‌طور غیرمنطقی تغییر کنند. این مسئله می‌تواند باعث ناپایداری و عدم همگرایی مدل شود. مدل LSTM به‌دلیل ساختار خاص خود، این مشکلات را تا حد زیادی حل کرده است. مدل LSTM با استفاده از سلول‌های حافظه و دروازه‌های ورودی، خروجی و فراموشی، می‌تواند اطلاعات مهم را در طول زمان حفظ و از محو شدگی یا انفجار گرادیان جلوگیری کند. این ویژگی‌ها باعث می‌شوند که مدل LSTM در پردازش داده‌های سری زمانی و مسائلی که نیاز به حفظ ترتیب زمانی دارند، بسیار کارآمد باشد.

بنابراین در این مقاله ایده استفاده از مدل LSTM جهت مدل‌سازی مکانی-زمانی و پیش‌بینی سری زمانی PWV برای اولین بار در ایران ارائه شده است. جهت ارزیابی صحت و دقت مدل جدید از مشاهدات شبکه GPS استان تهران برای دو بازه زمانی روزهای ۳۱۲ الی ۳۴۷ (۳۶ روز پیوسته) در سال ۲۰۲۱ و بازه زمانی روزهای ۳۳ الی ۷۸ (۴۶ روز پیوسته) در سال ۲۰۲۲ مورد استفاده قرار گرفته است. همچنین ایستگاه هشترگرد (HSHG) به‌عنوان ایستگاه آزمون در نظر گرفته شده است. ارزیابی کارایی مدل جدید، با استفاده از مقادیر PWV حاصل از مشاهدات ایستگاه GPS هشترگرد و همچنین توسط شاخص‌های آماری جذر خطای مربعی میانگین (RMSE) و ضریب همبستگی انجام می‌گیرد. بایستی اشاره شود که نتایج پیش‌بینی PWV توسط مدل LSTM با نتایج مدل شبکه عصبی GRNN و مدل‌های تجربی GPT3 و ساستاموین مقایسه می‌شوند.

۲. منطقه مورد مطالعه و مشاهدات استفاده شده

در این مقاله جهت ارزیابی دقت و صحت مدل‌های LSTM و GRNN در مدل‌سازی مکانی-زمانی بخار آب قابل بارش از مشاهدات ایستگاه‌های GPS استان تهران، برای دو بازه زمانی روزهای ۳۱۲ الی ۳۴۷ (۳۶ روز پیوسته) در سال ۲۰۲۱ و بازه زمانی روزهای ۳۳ الی ۷۸ (۴۶ روز پیوسته) در سال ۲۰۲۲ مورد استفاده قرار گرفته است. شبکه تهران شامل ۵ ایستگاه GPS می‌باشد که در هر دو بازه مورد مطالعه در سال‌های ۲۰۲۱ و ۲۰۲۲، از مشاهدات ۴ ایستگاه جهت

تغییرات زمانی و مکانی PWV تأیید کرد. غفاری رزین و وثوقی (۲۰۲۲) عملکرد مدل ماشین بردار پشتیبان (SVM) جهت برآورد و مدل‌سازی مقدار PWV در منطقه شمال غربی ایران را ارزیابی کردند. ایزانلو و همکاران (۲۰۲۳)، از روش‌های رگرسیون جنگل تصادفی (RFR) و رگرسیون تقویت گرادیان شدید (EGBR) برای مدل‌سازی PWV بهره گرفتند. بدین منظور، آنها از مشاهدات ایستگاه‌های GPS در ایران استفاده کردند. همچنین غفاری رزین و همکاران (۲۰۲۳) مدل کمترین مربعات رگرسیون بردار پشتیبان (LS-SVR) را جهت مدل‌سازی بخار آب قابل بارش در منطقه شمال غربی ایران ارائه داده و نتایج به‌دست آمده را با چندین مدل یادگیری ماشین مقایسه کردند. نتایج آنها نشان داده است که مدل LS-SVR در مقایسه با سایر مدل‌ها، از دقت بالاتری برخوردار است.

تاکنون از مدل‌های مختلفی همانند ANN، ANFIS، SVR و LS-SVR جهت مدل‌سازی مکانی زمانی بخار آب قابل بارش استفاده شده است. اما این مدل‌ها تنها برای بازه‌های زمانی کوتاه مدت مناسب هستند، زیرا در صورت استفاده از داده‌های مشاهداتی زیاد، این مدل‌ها دقت و سرعت همگرایی پایینی دارند. لذا استفاده از آنها برای مدل‌سازی و پیش‌بینی سری زمانی پیشنهاد نمی‌شود.

هدف این مقاله استفاده از شبکه عصبی حافظه کوتاه مدت طولانی (LSTM) برای مدل‌سازی و پیش‌بینی بخار آب قابل بارش در منطقه ایران است. مدل LSTM که زیر مجموعه شبکه عصبی بازگشتی (RNN) است، قادر به یادگیری وابستگی بلند مدت بین پارامترهای ورودی است. همچنین این مدل برای پیش‌بینی سری‌های زمانی قابل استفاده می‌باشد. مشکل محو شدگی گرادیان و انفجار گرادیان دو چالش اصلی در آموزش شبکه‌های عصبی عمیق هستند. محو شدگی گرادیان زمانی رخ می‌دهد که گرادیان‌ها در طول فرایند پس‌انتشار به تدریج کوچک می‌شوند. این مسئله باعث می‌شود که وزن‌های لایه‌های ابتدایی شبکه به‌درستی به‌روزرسانی نشوند و یادگیری مدل به کندی پیش برود یا حتی متوقف شود. انفجار گرادیان برعکس محو شدگی گرادیان است. در این حالت، گرادیان‌ها به‌شدت بزرگ

مقدار تأخیر ترزیتی (ZWD) حاصل خواهد شد:

$$ZWD = ZTD - ZHD \quad (2)$$

در مرحله سوم با استفاده از رابطه زیر مقادیر ZWD به مقادیر بخار آب قابل بارش (PWV) تبدیل می‌شوند:

$$PWV = \pi \times ZWD \quad (3)$$

که π از رابطه زیر قابل محاسبه است:

$$\pi = \left(10^{-6} \left(\frac{k_3}{T_m} + k_2' \right) \times R_v \times \rho_w \right)^{-1} \quad (4)$$

در رابطه فوق $R_v = 461.45 \text{ (JK/Kg.K)}$ ثابت گازها، $\rho_w = 1000 \text{ (Kg/m}^3\text{)}$ چگالی آب مایع، $K_2' = 17 \text{ (k/mbar)}$ و $k_3 = 3.7 \times 10^5 \text{ (k}^2\text{/mbar)}$ بیانگر ثوابت انکسار جوی است. در این مقاله جهت محاسبه T_m (میانگین وزنی دمای جو) از رابطه زیر استفاده شده است (صادقی و همکاران، ۲۰۱۴):


$$T_m = 75.39 + 0.7103 T_s \quad (5)$$

در رابطه فوق T_s بیانگر دمای سطحی منطقه مورد مطالعه می‌باشد. مقادیر PWV حاصل از رابطه (۳) به‌عنوان خروجی ایده‌آل مدل‌های LSTM و GRNN در نظر گرفته می‌شود. با توجه به محاسبات انجام شده، بردار کمیت PWV در سال ۲۰۲۱ برابر با $4320 \text{ (} 24 \times 36 \times 5 \text{)}$ و در سال ۲۰۲۲ برابر با $5520 \text{ (} 24 \times 36 \times 5 \text{)}$ می‌باشد. عدد ۵ بیانگر تعداد ایستگاه‌ها، اعداد ۳۶ و ۲۴ بیانگر تعداد روزهای موردبررسی و عدد ۲۴ بیانگر تعداد کمیت PWV در هر روز می‌باشد. لازم به‌ذکر است که در این مقاله بردار مشاهدات ورودی مدل‌های LSTM و GRNN شامل پارامترهای موقعیت ایستگاه‌های GPS یعنی طول جغرافیایی، عرض جغرافیایی و ارتفاع ایستگاه‌ها به‌علاوه پارامترهای روز از سال (DOY) و زمان بر حسب دقیقه می‌باشد. همچنین لازم به‌ذکر است که میانگین انحراف معیار برای مشاهدات PWV حاصل از نرم‌افزار گامیت، در سال‌های ۲۰۲۱ و ۲۰۲۲ به‌ترتیب برابر با 0.9 میلی‌متر و 0.7 میلی‌متر حاصل از مرحله سرشنکی می‌باشد.

۳. روش تحقیق

در این مقاله از روش شبکه‌عصبی حافظه کوتاه‌مدت طولانی جهت مدل‌سازی زمانی-مکانی بخار آب قابل

آموزش مدل LSTM استفاده شده است. جهت ارزیابی دقت مدل‌ها، ایستگاه هشترگرد (HSHG) با طول جغرافیایی $50/65$ درجه شرقی، عرض جغرافیایی $35/98$ درجه شمالی و ارتفاع $1287/17$ متر به‌عنوان ایستگاه آزمون در نظر گرفته شده است. چگونگی توزیع ایستگاه‌های GPS در شکل ۱ نشان داده شده است. دلیل استفاده از این ایستگاه‌ها جهت ارزیابی نتایج این تحقیق در دسترس بودن مشاهدات پیوسته و یکنواخت بوده است.



شکل ۱. چگونگی توزیع ایستگاه‌های آموزش (دایره‌های آبی) و ایستگاه آزمون (ستاره قرمز).

جهت استخراج مشاهدات PWV از اندازه‌گیری‌های GPS مشاهدات تأخیر ترزیتی تروپوسفر (ZTD) مورد نیاز است. بنابراین در مرحله اول مشاهدات ایستگاه‌های GPS توسط نرم‌افزار گامیت پردازش شده و مقادیر ZTD با قدرت تفکیک زمانی 300 ثانیه (15 دقیقه) محاسبه شده است. جهت مشاهده تغییرات زمانی PWV، از هر 12 مقدار ZTD میانگین گرفته شده و مقدار کمیت ZTD به‌صورت ساعتی برآورد شده است. در مرحله دوم مقدار تأخیر ترزیتی خشک (ZHD) با استفاده از مدل تجربی بهبود داده شده توسط دیویس و همکاران (۱۹۸۵) محاسبه می‌شود:

$$ZHD = \frac{0.0022768 \cdot p}{1 - 0.00266 \cdot \cos(2\varphi) - 0.28 \cdot 10^{-6} \times h_{ell}} \quad (1)$$

در رابطه فوق، p فشار هوای خشک در واحد میلی‌بار، φ و h_{ell} به‌ترتیب عرض جغرافیایی و ارتفاع اورتومتريک ایستگاه می‌باشند. اگر مقدار ZHD به‌دست آمده از رابطه (۱) از مقدار کلی تأخیر تروپوسفری (ZTD) کم شود،

به‌خاطر سپردن هستند. عملگر فراموشی دو ورودی دارد که یکی همان c_{t-1} است و دومین ورودی f_t می‌باشد. ورودی f_t قبل از اعمال از یک تابع سیگموئید می‌گذرد و این تابع سیگموئید باعث می‌شود که خروجی عددی بین ۰ تا ۱ شود. ورودی f_t را یک شبکه عصبی کوچک، با دو ورودی x_t و h_{t-1} تشکیل می‌دهد که وظیفه فراموشی بخشی از اطلاعات موجود در حافظه بلندمدت را دارد. به این شبکه عصبی، دروازه فراموشی گفته می‌شود. منظور از دروازه، یک دریچه یا پیچ قابل تنظیم است که به ما امکان کنترل می‌دهد. دروازه فراموشی یکی از ارکان مهم شبکه LSTM است و به شبکه LSTM این قابلیت را می‌دهد که بعضی از مؤلفه‌های موجود در c_{t-1} فراموش شوند. ساختار دروازه فراموشی بدین گونه می‌باشد که دو ورودی x_t و h_{t-1} از دو لایه با اتصالات کامل عبور می‌کنند و در نهایت با هم ترکیب می‌شوند و سپس از یک لایه سیگموئید می‌گذرند. معادله مرتبط با هر بلوک حافظه در ساختار LSTM به شرح زیر است (گریوس، ۲۰۱۳):

$$f_t = \sigma(w_{hf}h_{t-1} + w_{xf}x_t + b_{hf} + b_{xf}) \quad (6)$$

در معادله بالا w_{hf} و w_{xf} ماتریس وزن و b_{hf} و b_{xf} بردار بایاس دروازه فراموشی و $\sigma(\cdot)$ تابع سیگموئید هستند. در رابطه فوق اگر هر درایه از f_t به عدد یک نزدیک باشد، به این معناست که درایه متناظرش در c_{t-1} باید حفظ شود. اما اگر به صفر نزدیک باشد، یعنی این درایه از c_{t-1} باید حذف شود. در نهایت دو ورودی f_t و c_{t-1} به‌صورت زیر با هم ترکیب شده‌اند:


$$c_t = f_t * c_{t-1} \quad (7)$$

در معادله فوق علامت * بین دو متغیر f_t و c_{t-1} اشاره به ضرب درایه به درایه دو بردار ورودی دارد. بعد از گذر از عملگر $\otimes$ ، به عملگر $\oplus$ روی مسیر $c_{t-1}c_t$ خواهیم رسید. در زمان جاری پردازش‌هایی انجام گرفته و اکنون می‌بایستی آن اطلاعات به سلول حافظه سپرده شود. این اطلاعات با استفاده از یک شبکه عصبی محاسبه و همانند دروازه فراموشی شامل دو ورودی x_t و h_{t-1} است. این ورودی‌ها باید از دو لایه با وزن‌های w_{hg} و w_{ig} عبور کرده و در نهایت با هم جمع شوند. سپس این ورودی باید از یک تابع تانژانت

بارش استفاده شده است. لذا در این بخش تئوری ریاضی این روش توضیح داده می‌شود. از آنجایی که نتایج این مدل، با مدل‌های شبکه عصبی رگرسیون عمومی (GRNN) و مدل‌های تجربی GPT3 و ساستاموینن مقایسه می‌شود، در این بخش به تئوری ریاضی این مدل‌ها نیز اشاره خواهد شد.

۳-۱. شبکه عصبی حافظه کوتاه‌مدت طولانی

شبکه عصبی حافظه کوتاه‌مدت طولانی (LSTM)، زیرمجموعه شبکه‌های عصبی بازگشتی (RNN) است که به‌صورت زنجیره‌ای پشت سرهم قرار می‌گیرند و اولین بار توسط هوخرایتر و اشمیت‌هوبر (۱۹۹۷) معرفی شد. البته این مدل در سال‌های بعد توسط بسیاری از افراد بهبود داده شد. شبکه LSTM در طیف وسیعی از مسائل استفاده می‌شود اما بیشترین میزان استفاده از آن برای داده‌های سری زمانی می‌باشد. شبکه عصبی RNN مشکل وابستگی بلند مدت دارد، اما شبکه LSTM حافظه بلند مدت داشته و دقیقاً نقطه مقابل شبکه RNN می‌باشد. به عبارت دیگر، شبکه LSTM قادر به یادگیری وابستگی بلند مدت است. شکل ۲ معماری یک شبکه عصبی LSTM را نمایش می‌دهد.



شکل ۲. معماری شبکه عصبی LSTM.


در شکل ۲ مشاهده می‌شود که شبکه LSTM دو ورودی $(h_{t-1}$ و $c_{t-1})$ و دو خروجی $(h_t$ و $c_t)$ دارد که ورودی c_{t-1} مستقیماً به خروجی c_t متصل شده است. c مخفف Cell State است و یک مؤلفه کلیدی در LSTM می‌باشد. به Cell State حافظه بلند مدت هم گفته می‌شود. حافظه بلندمدت دارای دو خاصیت مهم و اساسی فراموش کردن و به‌خاطر سپردن اطلاعات می‌باشد. علامت‌های $\otimes$ و $\oplus$ روی خط $c_{t-1}c_t$ (شکل ۲)، به ترتیب مربوط به فراموش کردن و

در معادله فوق W_{ho} و W_{io} ماتریس وزن و b_{ho} و b_{io} بردار بایاس دروازه خروجی هستند. در نهایت، خروجی تولیدشده از دروازه خروجی o_t باید در خروجی تابع تانژانت هایپربولیک ضرب شود تا اطلاعاتی که نیاز است به خروجی h_t منتقل شود. رابطه ساخت خروجی نهایی به فرم زیر می باشد:

$$h_t = O_t * \tanh(c_t) \quad (12)$$

۳-۲. شبکه عصبی رگرسیون عمومی

شبکه عصبی رگرسیون عمومی (GRNN) حالت خاصی از شبکه عصبی توابع پایه شعاعی (RBF) است که بر مبنای یک روش آماری استاندارد، به نام رگرسیون کرنل بنا نهاده شده است. شبکه عصبی GRNN نخستین بار در سال ۱۹۹۱ توسط اسپیچ معرفی شد (اسپیچ، ۱۹۹۱). این شبکه شامل ۴ لایه ورودی، لایه الگو، لایه جمع کننده و لایه خروجی می باشد. شکل ۳ معماری شبکه عصبی رگرسیون تعمیم یافته را نشان می دهد.



شکل ۳. معماری شبکه عصبی رگرسیون تعمیم یافته.

شبکه عصبی GRNN نیاز به روش آموزش تکراری مانند روش الگوریتم پس انتشار خطا ندارد (چن و همکاران، ۱۹۹۱؛ سیگیزوخلو و آلپ، ۲۰۰۶). به علاوه سرعت آموزش این مدل بسیار بالا است و قادر به تقریب هر رابطه بین بردارهای ورودی و خروجی است و تابع را مستقیماً از مجموعه داده آموزشی تخمین می زند (یونان و همکاران، ۲۰۲۰). مزیت های شبکه GRNN باعث شده است تا از آن به عنوان ابزاری قدرتمند در مسائل تحلیل رگرسیون خطی استفاده شود. در شبکه GRNN لایه ورودی، اطلاعات را جمع آوری کرده و سپس به لایه الگو ارسال می کند. لازم

هایپربولیک عبور داده شود. خروجی g_t بین ۱- تا ۱ خواهد بود (با مقادیر بین ۱- تا ۱ می توان اثر بعضی مؤلفه های موجود در c_t را زیاد یا کم کرد). رابطه تشکیل خروجی g_t به صورت زیر می باشد (گریوس، ۲۰۱۳):

$$g_t = \tanh(w_{hg}h_{t-1} + w_{ig}x_t + b_{hg} + b_{ig}) \quad (8)$$

در خروجی g_t مقداری اطلاعات وجود دارد، اما شاید تمام این اطلاعات ارزش ذخیره سازی در حافظه بلندمدت را نداشته باشند. برای این کار کافی است از یک دروازه مشابه با ساختار دروازه فراموشی استفاده و بر سر راه خروجی g_t قرار داده شود. آنگاه به آسانی می توان تنظیم کرد که این خروجی چقدر ارزش دارد. به این دروازه جدید، دروازه ورودی گفته می شود. به عبارتی دروازه ورودی ارزیاب میزان ارزش اطلاعات موجود در g_t است. دروازه ورودی، ورود اطلاعات جدید به حافظه بلندمدت را بررسی می کند. مشابه دروازه فراموشی، ممکن است مقادیر موجود در بردار i_t نزدیک به صفر باشد، بنابراین اثر g_t را کم می کند. برعکس ممکن است مقادیر بردار i_t نزدیک به یک باشد، در این صورت g_t در حافظه بلند مدت ذخیره می شود. بردار i_t به صورت زیر تعریف می شود:

$$i_t = \sigma(w_{hi}h_{t-1} + w_{ii}x_t + b_{hi} + b_{ii}) \quad (9)$$

روابط خروجی نهایی (g'_t) و آپدیت c_t به فرم زیر می باشد:

$$g'_t = g_t * i_t$$

$$c_t = c_t + g'_t \quad (10)$$

تاکنون به این مسئله پرداخته شد که چگونه اطلاعاتی از گذشته را فراموش کرده و چگونه اطلاعاتی در بردار c_{t-1} ذخیره شود، اما هنوز هیچ مسیری روی خط $h_{t-1}h_t$ ساخته نشده است. کافی است خروجی c_t (آپدیت شده) از یک تانژانت هایپربولیک عبور داده شود، سپس به کمک یک دروازه دیگر، به نام دروازه خروجی آن بخش از اطلاعات را که مورد نیاز می باشد، به خروجی h_t متصل کرد. دروازه خروجی تعیین می کند چه اطلاعاتی از حافظه بلندمدت باید به خروجی منتقل شود. عملکرد دروازه خروجی دقیقاً مانند دروازه فراموشی و دروازه ورودی است. رابطه ریاضی دروازه خروجی به صورت زیر خواهد بود:

$$O_t = \sigma(w_{ho}h_{t-1} + w_{io}x_t + b_{ho} + b_{io}) \quad (11)$$

لایه خروجی منتقل شدند، خروجی مدل GRNN می‌تواند محاسبه شود. در این شبکه عصبی، تعداد نورون‌ها در لایه خروجی برابر با بعد بردار خروجی است (لی و همکاران، ۲۰۱۳).

۳-۳. مدل تجربی GPT3

مدل GPT3 یکی از مدل‌های تجربی است که با استفاده از آن پارامترهای هواشناسی قابل محاسبه هستند (لندسکرون و بوهم، ۲۰۱۸). پارامترهای ورودی مدل GPT3 شامل تاریخ ژولین اصلاح شده، طول جغرافیایی، عرض جغرافیایی و ارتفاع از بیضوی می‌باشد. پارامترهای خروجی مدل شامل ۹ پارامتر می‌باشد. از بین پارامترهای خروجی، از ۳ پارامتر فشار بخار آب (e)، ضریب کاهشی بخار آب (λ) و میانگین وزنی دمای جو (T_m) برای محاسبه تأخیر تر زینتی (ZWD) استفاده می‌شود (آسکنه و نوردیوس، ۱۹۸۷):

$$ZWD = 10^{-6} \left(k_2 + \frac{k_3}{T_m} \right) \times \frac{R_d}{(\lambda + 1)g_m} e \quad (16)$$

در رابطه فوق، $R_d = 287.0464 \text{ (J/K.Kg)}$ ثابت گازها برای بخش خشک و $g_m = 9.81 \text{ (m/s}^2\text{)}$ متوسط گرانش می‌باشد. ضریب کاهشی بخار آب (λ) یک کمیت بدون واحد است که به عرض جغرافیایی وابسته بوده و همچنین برای هر فصل مقدار متفاوتی برای آن در نظر گرفته شده است. در جدول زیر مقادیر مختلف λ آورده شده است (اسمیت، ۱۹۶۶):

به‌ذکر است که در شبکه عصبی GRNN تعداد نورون‌ها در لایه ورودی برابر با بُعد بردار ورودی می‌باشد. لایه الگو یک تبدیل غیرخطی از فضای ورودی به فضای الگو را دارا می‌باشد. نورون‌های لایه الگو قادر هستند تا رابطه بین نورون ورودی و پاسخ صحیح از لایه الگو، و تعداد نورون‌هایی که برابر با تعداد متغیرهای ورودی هستند را حفظ کنند. در نهایت خروجی لایه الگو، از لایه جمع‌کننده عبور می‌کند. این لایه تنها شامل دو نورون جمع‌کننده وزنی (نورون S) و نورون جمع‌کننده ساده (نورون D) می‌باشد. نورون S مجموع خروجی‌های وزنی لایه الگو را محاسبه می‌کند، درحالی‌که نورون D جمع خروجی‌های وزن نشده نورون‌های الگو را محاسبه می‌کند. روابط نورون S و نورون D در لایه جمع‌کننده به‌صورت زیر قابل تعریف می‌باشد:

$$S = \sum_{i=1}^N Y_i \exp \left(- \frac{(X-X_i)(X-X_i)^T}{2\sigma^2} \right) \quad (13)$$

$$D = \sum_{i=1}^N \exp \left(- \frac{(X-X_i)(X-X_i)^T}{2\sigma^2} \right) \quad (14)$$

در روابط فوق، Y_i وزنی است که نورون نام در لایه الگو را به لایه جمع متصل می‌کند و σ پارامتر هموارسازی است و مقدار بهینه آن از طریق آزمون و خطا مشخص می‌شود. برای یک بردار ورودی X ، خروجی GRNN از رابطه زیر قابل محاسبه است.

$$Y(X) = \frac{S}{D} = \frac{\sum_{i=1}^N Y_i \exp \left(\frac{(X-X_i)(X-X_i)^T}{2\sigma^2} \right)}{\sum_{i=1}^N \exp \left(\frac{(X-X_i)(X-X_i)^T}{2\sigma^2} \right)} \quad (15)$$

پس از این‌که نورون‌های جمع‌شده در لایه جمع‌کننده به

جدول ۱. مقادیر ضریب کاهشی بخار آب (λ) برای عرض‌های جغرافیایی و فصول مختلف.

میانگین سالیانه	فصل				عرض جغرافیایی (درجه شمالی)
	پاییز	تابستان	بهار	زمستان	
۲/۹۱	۲/۶۴	۲/۸۰	۲/۸۵	۳/۳۷	۱۰ - ۰
۲/۹۱	۲/۹۳	۲/۷۰	۳/۰۲	۲/۹۹	۲۰ - ۱۰
۳/۱۲	۲/۹۳	۲/۹۸	۳/۰۰	۳/۶۰	۳۰ - ۲۰
۳/۰۰	۲/۹۴	۲/۹۲	۳/۱۱	۳/۰۴	۴۰ - ۳۰
۲/۷۸	۲/۷۱	۲/۷۷	۲/۹۵	۲/۷۰	۵۰ - ۴۰
۲/۷۹	۲/۹۳	۲/۶۷	۳/۰۷	۲/۵۲	۶۰ - ۵۰
۲/۴۱	۲/۶۱	۲/۶۱	۲/۶۹	۱/۷۶	۷۰ - ۶۰
۲/۰۳	۲/۶۳	۲/۲۴	۱/۶۷	۱/۶۰	۸۰ - ۷۰
۱/۶۲	۲/۰۲	۱/۹۴	۱/۴۴	۱/۱۱	۹۰ - ۸۰
۲/۶۱	۲/۷۰	۲/۶۲	۲/۶۴	۲/۵۲	میانگین

مراحل آموزش و آزمون برای مدل‌های مختلف ارائه شده و نتایج حاصل تفسیر می‌شوند. میزان خطای مدل‌های LSTM، GRNN، و GPT3 و ساستاموین با استفاده از شاخص‌های آماری جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) ارزیابی می‌شوند. هر چقدر مقادیر شاخص آماری RMSE به صفر نزدیک‌تر باشد، مدل از دقت بالاتری برخوردار خواهد بود. شاخص ضریب همبستگی ابزاری جهت تعیین میزان رابطه و به‌علاوه نوع رابطه (مستقیم یا معکوس) یک متغیر کمی با متغیر کمی دیگر است. این ضریب عددی ما بین -۱ و ۱ می‌باشد. ضریب همبستگی مثبت بیانگر همبستگی مستقیم و ضریب همبستگی منفی نشان‌دهنده همبستگی معکوس می‌باشد و در صورت عدم رابطه بین دو متغیر، ضریب همبستگی برابر صفر می‌باشد. شاخص‌های نامبرده از طریق روابط زیر قابل محاسبه هستند:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (PWV_{model}^i - PWV_{GPS}^i)^2} \quad (19)$$

$$R = \frac{\sum_{i=1}^N (PWV_{model}^i - \overline{PWV_i}) (PWV_{GPS}^i - \overline{PWV_{GPS}^i})}{\sqrt{\sum_{i=1}^N (PWV_{model}^i - \overline{PWV_i})^2} \sqrt{\sum_{i=1}^N (PWV_{GPS}^i - \overline{PWV_{GPS}^i})^2}} \quad (20)$$

در روابط فوق، N تعداد نمونه‌های مورد بررسی را نشان می‌دهد. $\overline{PWV_{GPS}^i}$ میانگین PWV به‌دست آمده از GPS، PWV_{model}^i بخار آب قابل بارش به‌دست آمده از مدل و PWV_{GPS}^i بخار آب قابل بارش به‌دست آمده از GPS می‌باشند.

۴-۱. مرحله آموزش مدل‌های LSTM و GRNN

در مرحله آموزش مدل LSTM و GRNN از پارامترهای طول جغرافیایی، عرض جغرافیایی، ارتفاع ایستگاه‌ها به‌علاوه پارامترهای روز از سال (DOY) و زمان بر حسب دقیقه به‌عنوان ورودی استفاده شده است. برای هر بردار ورودی که شامل ۵ پارامتر نامبرده می‌شود، یک PWV به‌عنوان خروجی در نظر گرفته می‌شود. در مدل LSTM تعداد یونیت‌ها در لایه پنهان برابر با ۶۵ و تعداد تکرارها برابر ۳۵

با توجه به این که در این مقاله از دو مجموعه داده که یکی در فصل بهار و دیگری در فصل پاییز می‌باشد، استفاده شده و همچنین ایستگاه GPS تهران با توجه به جدول فوق، در محدوده عرض جغرافیایی ۳۰ - ۴۰ درجه قرار گرفته است، از مقادیر ۳/۱۱ در بهار و ۲/۹۴ در پاییز، برای پارامتر λ استفاده شده است. همچنین لازم به ذکر است که این پارامتر فاقد واحد است. یکی دیگر از پارامترهای موثر در محاسبه ZWD، پارامتر فشار بخار آب (e) است که به دلیل تغییرات مکانی و زمانی زیاد نمی‌توان برای آن یک مدل منحصر به فرد ارائه داد. در این مقاله جهت محاسبه فشار بخار آب از رابطه زیر استفاده شده است:

$$e = e_s \times \frac{r_h}{100} \quad (17)$$

در رابطه بالا r_h رطوبت نسبی بر حسب درصد است که از وب‌سایت ECMWF قابل دسترسی می‌باشد. کمیت e_s نیز فشار بخار آب اشباع شده می‌باشد. در نهایت با جای گذاری ZWD در رابطه (۳)، مقدار بخار آب قابل بارش (PWV) به‌دست می‌آید.

۳-۴. مدل تجربی ساستاموین

تأخیر ترزیتی حدود ۱۰ درصد تأخیر تروپوسفری را تشکیل می‌دهد. بخش تر به دلیل وابستگی آن به پارامتر بخار آب، تغییرات مکانی زمانی زیادی دارد. تأخیر ترزیتی با استفاده از مدل تجربی ساستاموین، برای عرض‌های جغرافیایی متوسط و شرایط نرمال جوی از رابطه زیر قابل محاسبه است (ساستاموین، ۱۹۷۵):

$$ZWD = 0.002277 \left(\frac{1255}{T_s} + 0.05 \right) e \quad (18)$$

در رابطه فوق، e فشار بخار آب در سطح زمین و T_s نشان‌دهنده دمای سطحی می‌باشد. پس از جای گذاری تأخیر ترزیتی از رابطه فوق در رابطه (۳)، مقدار بخار آب قابل بارش مدل‌سازی شده توسط مدل ساستاموین به‌دست می‌آید.

۴. نتایج عددی و بحث

در این بخش نتایج عددی و آنالیزهای انجام گرفته در

در جدول ۲، واضح است که مدل LSTM از دقت بالاتری نسبت به مدل GRNN برخوردار است. همچنین با توجه به این که تعداد روزهای مورد مطالعه در سال ۲۰۲۲ بیشتر از سال ۲۰۲۱ می‌باشد، خطای مدل LSTM در مرحله آموزش نیز بیشتر بوده و نیاز است تا پارامترهای مدل با دقت بیشتری تنظیم شود. لازم است ذکر شود با توجه به این که مدل GRNN در مقابل مدل LSTM نیاز به تنظیم پارامتر زیادی ندارد، دقت خوبی در فرایند آموزش داشته است.

۴-۲. مرحله آزمون مدل‌های LSTM، GRNN،

GPT3 و ساستاموین

پس از مرحله آموزش مدل‌های LSTM و GRNN برای هر دو بازه مورد مطالعه این پژوهش، بایستی مقادیر PWV برای داده‌های آزمون برآورد شده و سپس نتایج حاصل با نتایج مدل‌های تجربی GPT3 و ساستاموین مقایسه شود. در جدول‌های ۳ و ۴، به ترتیب شاخص‌های آماری محاسبه شده در برآورد مقدار PWV برای ایستگاه هشتگرد در سال‌های ۲۰۲۱ و ۲۰۲۲ آورده شده است. همچنین لازم به ذکر است که در مقایسه صورت گرفته، PWV حاصل از GPS به‌عنوان مبنا در نظر گرفته شده است.

در نظر گرفته شده است. تنظیم دقیق فرامترهای مدل LSTM، برای بهبود عملکرد مدل و دستیابی به نتایج دقیق‌تر امری ضروری می‌باشد (دانقیان و راست‌بود، ۲۰۲۴). در این مقاله، از روش جستجو شبکه‌ای (Grid Search)، فرامترهای مدل LSTM تنظیم شده است. تابع هزینه برای داده‌های آموزش و داده‌های ارزیابی در هر تکرار، با شاخص آماری میانگین مربعات خطا (MSE) کنترل شده است. تابع هزینه با گذر زمان روندی کاهشی را طی کرده است که این امر نشان دهنده بهبود عملکرد مدل در طول تکرارهای مرحله آموزش است. در مدل GRNN تعداد نورون‌ها در لایه الگو برابر با بعد بردار ورودی می‌باشد. در نهایت با استفاده از شاخص‌های آماری نظیر RMSE و ضریب همبستگی مقدار خطای مدل‌های LSTM و GRNN برای داده‌های آموزش در هر دو بازه زمانی ۳۶ روز در سال ۲۰۲۱ و ۴۶ روز در سال ۲۰۲۲ برای شبکه تهران بررسی می‌شود (جدول ۲).

لازم به ذکر است که مدل LSTM در نرم‌افزار پایتون و با استفاده از کتابخانه‌های Tensorflow و keras پیاده‌سازی شده؛ اما پردازش‌های صورت گرفته برای مدل GRNN، در نرم‌افزار متلب انجام شده است. با توجه به نتایج آورده شده

جدول ۲. شاخص‌های آماری (RMSE (mm) و ضریب همبستگی در مرحله آموزش مدل‌های LSTM و GRNN در هر دو بازه زمانی ۳۶ روز در سال ۲۰۲۱ و ۴۶ روز در سال ۲۰۲۲ برای شبکه تهران.

۴۶ روز در سال ۲۰۲۲		۳۶ روز در سال ۲۰۲۱		RMSE (mm)
مدل LSTM	مدل GRNN	مدل LSTM	مدل GRNN	
۱/۰۵	۱/۲۹	۰/۷	۱/۱۶	
۰/۹۷	۰/۹۵	۰/۹۷	۰/۹۵	ضریب همبستگی

جدول ۳. مقایسه شاخص‌های آماری (RMSE (mm) و ضریب همبستگی برای مدل‌های LSTM، GRNN، GPT3 و ساستاموین در مرحله آزمون برای ایستگاه هشتگرد در سال ۲۰۲۱.


سااستاموین	GPT3	GRNN	LSTM	RMSE (mm)
۷/۶۵	۷/۱۲	۱/۳۴	۰/۵	
۰/۴۷	۰/۴۷	۰/۹۴	۰/۹۹	ضریب همبستگی

جدول ۴. مقایسه شاخص‌های آماری (RMSE (mm) و ضریب همبستگی برای مدل‌های LSTM، GRNN، GPT3 و ساستاموینن در مرحله آزمون برای ایستگاه هشتگرد در سال ۲۰۲۲.


سااستاموینن	GPT3	GRNN	LSTM	
۳/۲۸	۳/۳۲	۱/۱۹	۰/۹	RMSE (mm)
۰/۴۶	۰/۴۶	۰/۹۳	۰/۹۸	ضریب همبستگی

روش‌های درون‌یابی این مدل‌ها دارای خطای نسبتاً زیادی هستند. نتایج جدول‌های ۳ و ۴ نشان می‌دهد که خطای مدل‌های تجربی GPT3 و ساستاموینن از خطای مدل LSTM و همین‌طور مدل GRNN بیشتر است. در شکل ۴ میزان همبستگی پارامترهای فشار، دما و رطوبت نسبی، با مقادیر واقعی و پیش‌بینی‌شده بخار آب قابل بارش توسط مدل‌های LSTM و GRNN برای داده‌های آزمون هر دو بازه زمانی سال ۲۰۲۱ و ۲۰۲۲ نشان داده شده است. همبستگی مقادیر واقعی و پیش‌بینی‌شده بخار آب قابل بارش توسط مدل LSTM برای داده‌های آزمون در هر دو بازه زمانی به ترتیب برابر با ۰/۹۸ و ۰/۹۹ می‌باشد. همچنین همبستگی مقادیر واقعی و پیش‌بینی‌شده بخار آب قابل بارش توسط مدل GRNN برای داده‌های آزمون در هر دو بازه زمانی به ترتیب برابر با ۰/۹۴ و ۰/۹۳ می‌باشد.

نتایج فوق نشان‌دهنده این است که مدل LSTM در مرحله آزمون نیز دقت بسیار بالایی در برآورد PWV برای ایستگاه هشتگرد در مقایسه با سایر مدل‌ها داشته است. با در نظر گرفتن مجموع خطای مقادیر PWV برآوردشده با نرم‌افزار گامیت، خطای مرحله آموزش و آزمون دو مدل LSTM و GRNN، تفاوت خطای RMSE حاصل از مدل‌های LSTM و GRNN در دو بازه زمانی سال‌های ۲۰۲۱ و ۲۰۲۲ با دو مدل GPT3 و ساستاموینن کاملاً معنادار بوده و در حقیقت نشان‌دهنده تفاوت مابین مدل‌ها و ماهیت آنها در مدل‌سازی مقدار PWV می‌باشد. مدل‌های تجربی از داده‌های هواشناسی برای تخمین مقدار PWV استفاده می‌کنند. پارامترهای این مدل‌ها در صورت نبود ایستگاه‌های هواشناسی با روش‌های درون‌یابی تخمین زده می‌شوند. از آنجایی که پارامترهای هواشناسی دارای تغییرات زمانی و مکانی زیادی هستند، لذا به دلیل استفاده از



(ب)





(الف)

شکل ۴. میزان همبستگی پارامترهای فشار (بر حسب هکتو پاسکال)، دما (بر حسب کلوین) و رطوبت نسبی (بر حسب درصد) با مقادیر واقعی و پیش‌بینی‌شده بخار آب قابل بارش (بر حسب میلی‌متر) توسط مدل‌های LSTM و GRNN برای ایستگاه آزمون در سال ۲۰۲۱ (الف) و در سال ۲۰۲۲ (ب).

می‌باشد.

۵. مدل‌سازی و برآورد سری زمانی بخار آب قابل بارش با توجه به تجزیه و تحلیل‌های انجام‌شده و بررسی دقت مدل‌ها، این نتیجه حاصل شد که مدل LSTM دقت بالاتری در مقایسه با سایر مدل‌ها دارد. بنابراین در شکل ۵ نتایج پیش‌بینی PWV توسط مدل‌های LSTM و GRNN برای بخش آزمون در سال‌های ۲۰۲۱ و ۲۰۲۲ آورده شده است. در این مقاله از داده‌های ۴ ایستگاه برای آموزش شبکه و همچنین ایستگاه هشتم در هر دو سال به عنوان ایستگاه آزمون استفاده شده است.

در شکل ۴ مشاهده می‌شود که در سال ۲۰۲۱ در مرحله آزمون، پارامتر رطوبت نسبی، بیشترین همبستگی را با مقدار ۰/۴۹ با مقادیر پیش‌بینی‌شده بخار آب قابل بارش توسط مدل LSTM و مقدار ۰/۵۴ با مقادیر پیش‌بینی‌شده بخار آب قابل بارش توسط مدل GRNN دارد. در سال ۲۰۲۲ در مرحله آزمون، پارامتر رطوبت نسبی با مقدار ۰/۴۲ بیشترین همبستگی را با مقادیر پیش‌بینی‌شده بخار آب قابل بارش توسط مدل LSTM و مقدار ۰/۴۳ با مقادیر پیش‌بینی‌شده بخار آب قابل بارش توسط مدل GRNN دارد. به علاوه کمترین میزان همبستگی در سال ۲۰۲۱ و ۲۰۲۲ بهار مربوط به پارامتر فشار



شکل ۵. پیش‌بینی بخار آب قابل بارش با استفاده از مدل‌های LSTM و GRNN در سال ۲۰۲۱ (الف) و در سال ۲۰۲۲ (ب).

LSTM برای ایستگاه هشتگرد در بازه‌های زمانی ذکر شده در سال‌های ۲۰۲۱ و ۲۰۲۲ مورد آزمایش قرار گرفت. سپس مقادیر PWV برآورد شده با نتایج مدل شبکه عصبی GRNN و مدل‌های تجربی GPT3 و ساستاموین مقایسه شد.

مقدار RMSE برای مدل‌های LSTM، GRNN، GPT3 و ساستاموین در سال ۲۰۲۱، به ترتیب ۰/۵ و ۱/۴۹ و ۷/۱۲ و ۷/۶۵ به دست آمد. همچنین ضریب همبستگی برای مدل‌های LSTM، GRNN، GPT3 و ساستاموین در سال ۲۰۲۱، به ترتیب برابر با ۰/۹۹ و ۰/۹۴ و ۰/۴۷ و ۰/۴۷ می‌باشد. مقدار RMSE مدل‌های LSTM، GRNN، GPT3 و ساستاموین در سال ۲۰۲۲، به ترتیب ۰/۹ و ۱/۳۵ و ۳/۳۲ و ۳/۲۸ حاصل شد. همچنین ضریب همبستگی برای مدل‌های LSTM، GRNN، GPT3 و ساستاموین در سال ۲۰۲۲، به ترتیب برابر با ۰/۹۸ و ۰/۹۳ و ۰/۴۶ و ۰/۴۶ می‌باشد. نتایج به دست آمده در این مقاله نشان داده است که مدل LSTM قابلیت بسیار بالایی در مدل‌سازی و پیش‌بینی زمانی-مکانی بخار آب قابل بارش در بازه‌های زمانی مورد مطالعه در سال‌های ۲۰۲۱ و ۲۰۲۲ در شبکه GPS تهران دارد. تعیین دقیق پارامتر PWV می‌تواند به مدیریت منابع آبی، از جمله سدها کمک کند. همچنین از نتایج این مقاله می‌توان برای تولید یک سیستم هشدار بارش آبی، در صورتی که داده‌های ایستگاه‌های GPS به صورت برخط در دسترس باشد، مورد استفاده قرار گیرد تا از وقوع رخدادهایی نظیر سیل جلوگیری شود. مدل LSTM می‌تواند به عنوان یک جایگزین بسیار خوب برای مدل‌های متداول موجود باشد. برای ادامه کار می‌توان تعداد ایستگاه‌های آموزش و روزهای مدل‌سازی را بیشتر کرده و مقایسه و ارزیابی دقیق‌تری انجام داد. همچنین می‌توان داده‌های ایستگاه‌های رادیوسوند را به عنوان مشاهده کمکی در مرحله آموزش وارد کرده و دقت مدل را بهبود داد. به علاوه می‌توان از روش‌های بهینه‌سازی با الگوریتم بایزین و الگوریتم‌های فرا ابتکاری، برای تنظیم دقیق‌تر فرامترهای مدل‌های استفاده شده در این مقاله استفاده کرد.

مطابق با شکل ۵ مشابهت زیادی در سری زمانی بخار آب قابل بارش پیش‌بینی شده با دو مدل LSTM و GRNN با PWV حاصل از GPS در هر دو بازه زمانی ارزیابی شده وجود دارد. در مرحله آزمون کمترین مقدار پیش‌بینی شده PWV توسط مدل LSTM در سال ۲۰۲۱ برابر با ۳/۴۷ میلی‌متر در روز ۳۴۵ ساعت ۱۳ و بیشترین مقدار PWV ۱۸/۲۹ میلی‌متر در روز ۳۲۶ ساعت ۲ می‌باشد. همین‌طور در سال ۲۰۲۲ کمترین مقدار پیش‌بینی شده برای PWV برابر با ۱/۶۱ میلی‌متر در روز ۶۳ ساعت ۱۴ و بیشترین مقدار پیش‌بینی شده ۱۵/۷۵ میلی‌متر است در روز ۷۰ ساعت ۵ می‌باشد.

۶. نتیجه‌گیری

هدف این مقاله استفاده از شبکه عصبی حافظه کوتاه مدت طولانی (LSTM) برای مدل‌سازی و پیش‌بینی سری زمانی بخار آب قابل بارش بود. مشاهدات ۵ ایستگاه GPS شبکه تهران در سال ۲۰۲۱ برای بازه زمانی ۳۱۲ الی ۳۴۷ و در سال ۲۰۲۲ برای بازه زمانی ۳۳ الی ۷۸ مورد استفاده قرار گرفتند. از بین ۵ ایستگاه GPS، ایستگاه هشتگرد که در فاصله بیشتری از سایر ایستگاه‌ها قرار دارد، به عنوان ایستگاه آزمون انتخاب شد. در مرحله اول مقدار تأخیر کلی تروپوسفر (ZTD) با استفاده از نرم‌افزار گامیت به دست آمد. رزولوشن زمانی تأخیر تروپوسفری ۳۰۰ ثانیه (۵ دقیقه) می‌باشد. سپس از هر ۱۲ مقدار ZTD میانگین‌گیری شده و کمیت ZTD به صورت ساعتی برآورد شد. در مرحله دوم مقدار تأخیر خشک زنیته (ZHD) با استفاده از مدل تجربی بهبود داده شده توسط دیویس محاسبه می‌شود. با تفاضل مقادیر ZHD از مقادیر ZTD، مقادیر تأخیر تر زنیته (ZWD) حاصل می‌شود. در مرحله سوم با ضرب مقادیر ZWD در پارامتر π ، مقادیر PWV قابل برآورد است. در ادامه با استفاده از پارامترهای ورودی طول و عرض جغرافیایی، ارتفاع ایستگاه‌ها، پارامتر روز از سال (DOY) و زمان بر حسب دقیقه مدل‌های LSTM و GRNN آموزش داده شده است. پس از مرحله آموزش، عملکرد مدل

تشکر و قدردانی

نویسندگان از داوران محترم به سبب ارائه نکات بسیار ارزشمند علمی، قدردانی می‌کنند.

مراجع

موسوی، ز.، خرمی، ف.، نانکلی، ح.، جموری، ی. (۱۳۸۶).

تعیین مقدار بخار آب موجود در اتمسفر با استفاده از

تخمین تأخیر تروپوسفری سیگنال‌های GPS در شبکه

ژئودینامیک سراسری ایران، همایش ژئوماتیک ۱۳۸۶.

Adavi, Z., & Mashhadi-Hossainali, M. (2014). 4D tomographic reconstruction of the tropospheric wet refractivity using the concept of virtual reference station, case study: northwest of Iran. *Meteorology and Atmospheric Physics*, 126, 193-205.

Askne, J., & Nordius, H. (1987). Estimation of tropospheric delay for microwaves from surface weather data. *Radio Science*, 22(3), 379-386.

Benevides, P., Catalao, J., Nico, G., & Miranda, P. (2018). 4D wet refractivity estimation in the atmosphere using GNSS tomography initialized by radiosonde and AIRS measurements: results from a 1-week intensive campaign. *GPS Solutions*, 91(2018), 22:91.

Chen, S., Cowan, C. F. N., & Grant, P. M. (1991). Orthogonal least squares learning algorithm for radial. *IEEE Trans. Neural Netw*, 2(2), 302-309.

Chen, B., & Liu, Z. (2014). Voxel-optimized regional water vapor tomography and comparison with radiosonde and numerical weather model. *Journal of Geodesy*, 88(7), 691-703.

Cigizoglu, H. K., & Alp, M. (2006). Generalized regression neural network in modelling river sediment yield. *Advances in Engineering Software*, 37(2), 63-68.

Daneghian, P., & Rastbood, A. (2024). GNSS-IR soil moisture estimation using deep learning with Bayesian optimization for hyperparameter tuning. *Journal of Geodetic Science*, 14(1), 20220172.

Davis, J.L., Herring, T.A., Shapiro, II., Rogers, E.E., & Elgered, G. (1985). Geodesy by radio interferometry: effects of atmospheric modeling errors on estimates of baseline length. *Radio Sci*, 20(6), 1593-1607.

Forootan, E., Dehvari, M., Farzaneh, S., & Sam Khaniani, A. (2021). A functional modelling approach for reconstructing 3 and 4 dimensional wet refractivity fields in the lower atmosphere using GNSS measurements. *Advances in Space Research*, 68(10), 4024-4038.

Ghaffari Razin, M.R., & Voosoghi, B. (2020). Estimation of tropospheric wet refractivity using tomography method and artificial neural networks in Iranian case study. *GPS Solutions*, 24(3), 1-14.

Ghaffari Razin, M.R., & Inyurt, S. (2022).

Spatiotemporal analysis of precipitable water vapor using ANFIS and comparison against voxel-based tomography and radiosonde. *GPS Solutions*, 26, 1, <https://doi.org/10.1007/s10291-021-01184-1>.

Ghaffari Razin, M.R., & Voosoghi, B. (2022). Modeling of precipitable water vapor from GPS observations using machine learning and tomography methods. *Advances in Space Research*, 69(7), 2671-2681. <https://doi.org/10.1016/j.asr.2022.01.003>.

Ghaffari-Razin, S. R., Majd, R. D., & Hooshangi, N. (2023). Regional modeling and forecasting of precipitable water vapor using least square support vector regression. *Advances in Space Research*, 71(11), 4725-4738.

Graves, A. (2013). Generating sequences with recurrent neural networks. arXiv preprint arXiv:1308.0850.

Haji Aghajany, S., & Amerian, Y. (2017). Three dimensional ray tracing technique for tropospheric water vapor tomography using GPS measurements. *Journal of Atmospheric and Solar-Terrestrial Physics*, 164 (2017), 81-88.

Haji Aghajany, S., Amerian, Y., & Verhagen, S. (2020). B-spline function-based approach for GPS tropospheric tomography. *GPS Solutions*, 24(3), 1-12.

Haji-Aghajany, S., Amerian, Y., Verhagen, S., Rohm, W., & Schuh, H. (2021). The effect of function-based and voxel-based tropospheric tomography techniques on the GNSS positioning accuracy. *Journal of Geodesy*, 95(78), 1-15. <https://doi.org/10.1007/s00190-021-01528-2>.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.

Izanlou, S., Amerian, Y., & Seyed Mousavi, S. M. (2023). GNSS-derived precipitable water vapor modeling using machine learning methods. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 10, 307-313.

Landskron, D., & Böhm, J. (2017). VMF3/GPT3: refined discrete and empirical troposphere mapping functions. *Journal of Geodesy*, 92(4), 349-360.

Li, H. Z., Guo, S., Li, C. J., & Sun, J. Q. (2013). A hybrid annual power load forecasting model based on generalized regression neural network

- with fruit fly optimization algorithm. *Knowledge-Based Systems*, 37, 378-387.
- Rohm, W., & Bosy, J. (2011). The verification of GNSS tropospheric tomography model in a mountainous area. *Adv. Space Res.*, 47(10), 1721-1730.
- Saastamoinen, J. (1973). Contributions to the theory of atmospheric refraction. Part II: refraction corrections in satellite geodesy. *Bull. Geod.*, (107), 13-34.
- Sadeghi, E., Hossainali, M., & Etemadfar, H. (2014). Determining precipitable water in the atmosphere of Iran based on GPS zenith tropospheric delays. *Annals of geophysics*, 57(4), 12-27.
- Sadeghi, E., Hossainali, M., & Safari, A. (2022). Development of a hybrid tomography model based on principal component analysis of the atmospheric dynamics and GPS tracking data. *GPS Solutions*, 26(77), 1-14.
- Sam Khaniani, A., Motieyan, H., & Mohammadi, A. (2021). Rainfall forecast based on GPS PWV together with meteorological parameters using neural network models. *Journal of Atmospheric and Solar-Terrestrial Physics*, 214(2021), 1-15.
- Seeber, G. (2003). *Satellite Geodesy, Foundations, Methods and Application*, Walter de Gruyter, Berlin and New York, 531.
- Selbesoglu, M. O. (2019). Prediction of tropospheric wet delay by an artificial neural network model based on meteorological and GNSS data. *Engineering Science and Technology, an International Journal*, 23(5), 967-972. DOI: 10.1016/j.jestch.2019.11.006.
- Smith, W. L. (1966). Note on the relationship between total precipitable water and surface dew point. *Journal of Applied Meteorology and Climatology*, 5(5), 726-727.
- Sorkhabi, O. M., & Djamour, Y. (2024). 4D modeling of precipitable water vapor to assess flood forecasting by using GPS signals. *Natural Hazards*, 120(1), 181-195.
- Specht, D. F. (1991). A general regression neural network. *IEEE Transactions on Neural Networks*, 2(6), 568-576.
- Wilgan, K., Hurter, F., Geiger, A., Rohm, W., & Bosy, J. (2017). Tropospheric refractivity and zenith path delays from least-squares collocation of meteorological and GNSS data. *Journal of Geodesy*, 91, 117-134.
- Xin, W., & Daren, L. (2005). Retrieval of Water Vapor Profiles with Radio Occultation Measurements Using an Artificial Neural Network. *Advances in atmospheric science*, 22(5), 759-764.
- Ye, S., Xia, P., & Cai, C. (2016). Optimization of GPS water vapor tomography technique with radiosonde and COSMIC historical data. *Ann. Geophys.*, 34, 789-799.
- Yuan, Q., Xu, H., Li, T., Shen, H., & Zhang, L. (2020). Estimating surface soil moisture from satellite observations using a generalized regression neural network trained on sparse ground-based measurements in the continental US. *J Hydrol*, 580(2020), 1-14.
- Zhang, W., Zhang, S., Ding, N., Holden, L., Wang, X., & Zheng, N. (2021). GNSS-RS Tomography: Retrieval of Tropospheric Water Vapor Fields Using GNSS and RS Observations. *IEEE Transactions on Geoscience and Remote Sensing*, (60), 1-13.
- Zhao, Q., Yao, Y., Cao, X., & Yao, W. (2019). Accuracy and reliability of tropospheric wet refractivity tomography with GPS, BDS, and GLONASS observations. *Advances in Space Research*, 63(9), 2836-2847.