




## Estimation of precipitable water vapor (PWV) using generalized regression neural network (GRNN) and comparison against tomography, ECMWF, Saastamoinen, GPT3 and ANN models

Ghaffari-Razin, S. R.<sup>1</sup>  | Davari Majd, R.<sup>2</sup>  | Hooshangi, N.<sup>3</sup> 

1. **Corresponding Author**, Department of Surveying Engineering, Faculty of Geoscience Engineering, Arak University of Technology, Arak, Iran. E-mail: [mr.ghafari@arakut.ac.ir](mailto:mr.ghafari@arakut.ac.ir)
2. Department of Surveying Engineering, Faculty of Civil Engineering, Islamic Azad University of Khoy, Khoy, Iran. E-mail: [rdavarymajd@trn.ui.ac.ir](mailto:rdavarymajd@trn.ui.ac.ir)
3. Department of Surveying Engineering, Faculty of Geoscience Engineering, Arak University of Technology, Arak, Iran. E-mail: [hooshangi@arakut.ac.ir](mailto:hooshangi@arakut.ac.ir)

(Received: 28 May 2022, Revised: 29 June 2022, Accepted: 4 Oct 2022, Published online: 14 June 2023)

### Summary

Precipitable water vapor (PWV) is a key parameter in meteorological studies and forecasting of atmospheric events such as rain and flood. Due to the spatial limitations of GPS and meteorological stations, as well as observational discontinuities in the time domain, PWV modeling is of great importance. Obtaining PWV using direct measurements and water vapor measuring devices is a difficult task. The best way to get information on PWV variations indirectly is to use GNSS measurements. The GNSS meteorological technique can provide continuous and almost instantaneous observations of the amount of PWV around a GNSS station. Research has shown that the accuracy of weather forecasts can be improved using GNSS-dependent techniques. Models based on GNSS observations for estimating PWV are known as tropospheric analytical models. The tomographic model is one of the most famous and widely used tropospheric models. There are limitations such as a large number of unknown parameters, rank deficiency of design matrix and the inevitability of using regularization methods, assuming the amount of water vapor inside each voxel is constant and also, the need for initial amounts of water vapor inside the voxels in the voxel-based tomography (VBT) method. Such limitations have led researchers to use machine learning methods to estimate the spatio-temporal variation of PWV. In this paper, the spatio-temporal modeling of PWV is suggested using the generalized regression neural network (GRNN) model. The GRNN model is a type of artificial neural network (ANN) that uses radial basis functions (RBF) as an activity function in the hidden layer. As a result, its accuracy is higher than the ANN model. Eight parameters of longitude, latitude and height of GPS station, day of year (DOY), time (min.), relative humidity (RH), temperature (T) and pressure (P) are considered as inputs of GRNN and ANN models and the PWVs corresponding to these eight parameters are the outputs. After the training step, to evaluate the GRNN and ANN models, the observations of two GPS networks are used. In the GPS network of north-west of Iran, observations of 23 GPS stations in the period of 300 to 314 (winter season) from 2011 have been used. For the central Alborz GPS network, observations of 11 stations at the period of 162 to 176 (summer season) in 2016 are also used. Results obtained from GRNN and ANN models in two interior control stations, one exterior control station (outside the GPS network territory) and also in Tabriz and Tehran radiosonde stations are compared and evaluated with the results of VBT, ECMWF, Saastamoinen and GPT3 models. The statistical parameters of root mean square error (RMSE), relative error and correlation coefficient (R) are used to evaluate the accuracy of the models. At the north-west GPS network, the averaged RMSE values of GRNN, ANN, VBT, ECMWF, Saastamoinen and GPT3 models in the two interior control stations are calculated as 2.14, 2.57, 3.32, 3.36, 6.31 and 4.35 mm, respectively. For the central Alborz GPS network, the averaged RMSE of two interior control stations are computed as 2.01, 2.42, 3.24, 3.26, 6.00 and 4.06 mm, respectively. For the exterior control station, the GRNN model has less error than the ANN, VBT and Saastamoinen models, but more than the ECMWF and GPT3 model. The results of this paper show that the GRNN model has a very high accuracy compared to other analytical and empirical models of the troposphere. This model has the ability to show the spatio-temporal variations of precipitable water vapor with high accuracy at the GPS network territory and; it can be considered as an alternative for the other analytical and empirical models.

**Keywords:** Precipitable water vapor GPS, troposphere, GRNN, ANN.

**Cite this article:** Ghaffari-Razin, S. R., Davari Majd, R., & Hooshangi, N. (2023). Estimation of precipitable water vapor (PWV) using generalized regression neural network (GRNN) and comparison against tomography, ECMWF, Saastamoinen, GPT3 and ANN models. *Journal of the Earth and Space Physics*, 49(1), 243-264. DOI: <http://doi.org/10.22059/jesphys.2022.342130.1007425>

# برآورد بخار آب قابل بارش (PWV) با استفاده از مدل شبکه عصبی رگرسیون عمومی (GRNN) و مقایسه آن با مدل‌های توموگرافی، ECMWF، ساستاموینن، GPT3 و ANN

سیدرضا غفاری رزین<sup>۱</sup> | رضا داوری مجد<sup>۲</sup> | نوید هوشنگی<sup>۳</sup>

۱. نویسنده مسئول، گروه مهندسی نقشه‌برداری، دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک، اراک، ایران. رایانامه: [mr.ghafari@arakut.ac.ir](mailto:mr.ghafari@arakut.ac.ir)

۲. گروه مهندسی نقشه‌برداری، دانشکده مهندسی عمران، دانشگاه آزاد اسلامی واحد خوی، خوی، ایران. رایانامه: [rdavarymajd@trn.ui.ac.ir](mailto:rdavarymajd@trn.ui.ac.ir)

۳. گروه مهندسی نقشه‌برداری، دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک، اراک، ایران. رایانامه: [hooshangi@arakut.ac.ir](mailto:hooshangi@arakut.ac.ir)

(دریافت: ۱۴۰۱/۳/۷، بازنگری: ۱۴۰۱/۴/۸، پذیرش نهایی: ۱۴۰۱/۷/۱۲، انتشار آنلاین: ۱۴۰۲/۳/۲۴)

## چکیده

در این مقاله مقدار بخار آب قابل بارش (PWV) با استفاده از مدل شبکه عصبی رگرسیون عمومی (GRNN) به صورت مکانی-زمانی مدل‌سازی و پیش‌بینی می‌شود. هشت پارامتر طول، عرض و ارتفاع جغرافیایی ایستگاه GPS، روز مشاهده (DOY)، زمان (min.)، رطوبت نسبی (RH)، دما (T) و فشار (P) به عنوان ورودی‌های مدل‌های GRNN و ANN در نظر گرفته شده و PWV متناظر با این هشت پارامتر، به عنوان خروجی هستند. جهت ارزیابی مدل‌های GRNN و ANN، از مشاهدات ایستگاه‌های شبکه شمال غرب ایران و شبکه البرز مرکزی استفاده شده است. در شبکه شمال غرب از مشاهدات ۲۳ ایستگاه GPS در بازه زمانی روزهای ۳۰۰ الی ۳۱۴ از سال ۲۰۱۱ (فصل زمستان) استفاده می‌شود. برای شبکه البرز مرکزی مشاهدات ۱۱ ایستگاه در بازه زمانی روزهای ۱۶۲ الی ۱۷۶ از سال ۲۰۱۶ (فصل تابستان) بکار گرفته شده است. نتایج حاصل از مدل‌های GRNN و ANN در دو ایستگاه کنترل داخلی، یک ایستگاه کنترل خارجی (خارج از محدوده شبکه GPS مورد مطالعه)، همچنین در ایستگاه رادیوسوند تبریز (۳۸/۰۸N، ۴۶/۲۸E) و رادیوسوند تهران (۳۵/۶۸N، ۵۱/۳۵E) با نتایج حاصل از مدل‌های توموگرافی آلمان‌های حجمی (VBT)، مدل ECMWF، ساستاموینن و GPT3 مقایسه و ارزیابی می‌شوند. پارامترهای آماری جذر خطای مربعی میانگین (RMSE)، خطای نسبی و ضریب همبستگی (R) برای بررسی دقت و صحت مدل‌ها استفاده می‌شوند. در شبکه شمال غرب و فصل زمستان، میانگین مقدار RMSE مدل‌های GRNN، ANN، VBT، ECMWF، ساستاموینن و GPT3 در دو ایستگاه کنترل داخلی به ترتیب برابر با ۲/۱۴، ۲/۵۷، ۳/۳۲، ۳/۶۳، ۳/۳۱، ۶/۳۵ میلی‌متر محاسبه شده است. همچنین، در شبکه البرز مرکزی و فصل تابستان، میانگین مقدار RMSE مدل‌ها به ترتیب برابر با ۲/۰۱، ۲/۴۲، ۳/۲۴، ۳/۲۶، ۶/۰۰ و ۴/۰۶ میلی‌متر حاصل شده است. در ایستگاه کنترل خارجی و در هر دو شبکه مورد بررسی، خطای مدل GRNN از مدل‌های ANN، VBT و ساستاموینن کمتر ولی از مدل‌های ECMWF و GPT3 بیشتر است. نتایج این مقاله نشان می‌دهد که مدل جدید GRNN از دقت و صحت بسیار بالایی در مقایسه با سایر مدل‌های تحلیلی و تجربی تروپوسفر در محدوده شبکه مورد مطالعه برخوردار است. این مدل قابلیت نشان دادن تغییرات زمانی-مکانی بخار آب قابل بارش را با دقت بالا داشته و می‌تواند جایگزین مدل‌های تحلیلی و تجربی دیگر شود.

واژه‌های کلیدی: بخار آب قابل بارش، GPS، تروپوسفر، GRNN، ANN.

## ۱. مقدمه

امواج تحت تأثیر قرار می‌گیرد. در نتیجه انتشار امواج در این لایه از جو به فرکانس امواج بستگی ندارد. تأخیر به وجود آمده در اثر لایه تروپوسفر را می‌توان به دو بخش هیدروستاتیکی (Dry) و تر (Wet) تقسیم‌بندی کرد. مؤلفه هیدروستاتیکی تأخیر تروپوسفری در اثر گازهای خشک موجود در این لایه حاصل می‌شود. در مقابل، مؤلفه تر انکسار تروپوسفری در اثر بخار آب موجود در لایه تروپوسفر به وجود می‌آید (سیبر، ۲۰۰۳).

از دید انتشار امواج رادیویی مربوط به سامانه ناوبری جهانی ماهواره‌ای (GNSS) در جو، جو زمین را می‌توان به دو بخش، تروپوسفر که تا ارتفاع حدود ۴۰ کیلومتری از سطح زمین است و یونوسفر که از بالای لایه تروپوسفر تا ارتفاع ۱۰۰۰ کیلومتری ادامه دارد، تقسیم کرد. در تروپوسفر انتشار امواج الکترومغناطیسی به غلظت بخار آب و دما وابسته است و امواج GNSS در آن پراکنده نمی‌شوند، اما در لایه یونوسفر به دلیل ذرات باردار این

استناد: غفاری رزین، سیدرضا؛ داوری مجد، رضا و هوشنگی، نوید (۱۴۰۲). برآورد بخار آب قابل بارش (PWV) با استفاده از مدل شبکه عصبی رگرسیون عمومی (GRNN) و مقایسه آن با مدل‌های توموگرافی، ECMWF، ساستاموینن، GPT3 و ANN. مجله فیزیک زمین و فضا، ۴۹(۱)، ۲۴۳-۲۶۴.

DOI: <http://doi.org/10.22059/jesphys.2022.342130.1007425>

استفاده از اندازه‌گیری‌های GNSS است. تکنیک هواشناسی با GNSS می‌تواند مشاهدات پیوسته و تقریباً آنی از مقدار بخار آب اطراف یک ایستگاه GNSS در اختیار قرار دهد. تحقیقات انجام گرفته نشان داده است که با استفاده از تکنیک‌های وابسته به GNSS می‌توان دقت پیش‌بینی‌های آب‌وهوایی را بهبود بخشید. مدل‌های مبتنی بر مشاهدات ایستگاه‌های GNSS جهت برآورد بخار آب قابل بارش به مدل‌های تحلیلی تروپوسفری معروف هستند. مدل توموگرافی از جمله معروف‌ترین و پرکاربردترین مدل‌های تروپوسفری است. در دو دهه اخیر از این روش به کرات جهت مدل‌سازی چگالی بخار آب و همچنین بخار آب قابل بارش استفاده شده است (فروتن و همکاران، ۲۰۲۱؛ سام خانیانی و همکاران، ۲۰۲۱؛ حاجی آقاجانی و همکاران، ۲۰۲۱؛ ژانگ و همکاران، ۲۰۲۱؛ یائو و همکاران، ۲۰۲۰؛ ژو و همکاران، ۲۰۲۰؛ غفاری رزین و وثوقی، ۲۰۲۰؛ ژو و همکاران، ۲۰۱۹؛ بنویدس و همکاران، ۲۰۱۸؛ حاجی آقاجانی و عامریان، ۲۰۱۷؛ سام خانیانی و همکاران، ۲۰۱۷؛ یی و همکاران، ۲۰۱۶؛ اداوی و حسینعلی، ۲۰۱۵؛ چن و لیو، ۲۰۱۴؛ رهم و بوسی، ۲۰۱۱). برآورد بخار آب قابل بارش و چگالی بخار آب با استفاده از روش توموگرافی دارای معایبی است. 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 صورتی که 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 معایب و مشکلات موجود در مدل‌های توموگرافی تروپوسفر، در سالیان اخیر، ایده استفاده از روش‌های یادگیری ماشین (ML) جهت برآورد چگالی بخار آب و همچنین بخار آب قابل بارش ارائه شده است.

بخار آب قابل بارش (PWV) یک پارامتر کلیدی در مطالعات آب و هواشناسی و پیش‌بینی رخداد‌های جوی نظیر باران و سیل می‌باشد. با توجه به محدودیت مکانی ایستگاه‌های GPS و هواشناسی، همچنین ناپیوستگی مشاهداتی در حوزه زمان، مدل‌سازی مقدار PWV از اهمیت زیادی برخوردار است. به دست آوردن بخار آب با استفاده از اندازه‌گیری‌های مستقیم و دستگاه‌های اندازه‌گیری بخار آب کاری سخت و پرهزینه است. رادیوسوند و رادیومترها جهت اندازه‌گیری مستقیم بخار آب جو استفاده می‌شوند، ولی 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. برای منطقه وسیعی همانند ایران که دارای تغییرات آب‌وهوایی بسیار متنوعی است تنها ۱۱ ایستگاه رادیوسوند فعال وجود دارد (غفاری رزین و وثوقی، ۲۰۲۲). سرویس بین‌المللی آب‌وهوا اطلاعات مربوط به چگونگی توزیع بخار آب را از طریق ماهواره و رادیوسوندهایی که دو بار در روز پرتاب می‌شوند به دست می‌آورد. مشاهداتی که به وسیله بالون‌های هواشناسی رادیوسوندی صورت می‌گیرد مناسب و کافی نیستند، زیرا مشاهدات حاصل از بالون‌هایی که پرتاب می‌شوند متراکم، یکنواخت و پیوسته نیستند. بعلاوه اطلاعات رادیوسوندی به سرعت در اختیار کاربران قرار نمی‌گیرد، زیرا حدود 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 حداکثر دو یا سه بار در روز پرتاب می‌شوند. بنابراین قدرت تفکیک زمانی مشاهدات بخار آب و نیز تراکم افقی اطلاعات نیز کافی نیست. به علاوه تجهیزات رادیوسوندی گران‌قیمت هستند (موسوی و همکاران، ۱۳۸۶).

بهترین وسیله جهت به دست آوردن اطلاعاتی از چگونگی تغییرات بخار آب جو به صورت غیرمستقیم،

رطوبت نسبی (RH)، دما (T) و فشار (P) به‌عنوان ورودی‌های مدل جدید GRNN در نظر گرفته شده و بر اساس این پارامترها، مدل‌سازی مکانی-زمانی بخار آب قابل بارش انجام می‌گیرد. ارزیابی دقت و صحت مدل جدید با استفاده از مشاهدات بخار آب قابل بارش سه ایستگاه GPS، ایستگاه رادیوسوند و همچنین با استفاده از شاخص‌های آماری جذر خطای مربعی میانگین (RMSE)، خطای نسبی و ضریب همبستگی انجام می‌گیرد. همچنین نتایج مدل GRNN با مدل‌های توموگرافی المان‌های حجمی (VBT)، مدل ECMWF، مدل تجربی ساستاموین، مدل استاندارد شبکه عصبی (ANN) و مدل GPT3 مقایسه می‌شوند. برای دو مدل GRNN و ANN آنالیز حساسیت نسبت به پارامترهای ورودی انجام گرفته و حساسیت بخار آب قابل بارش نسبت به این پارامترها، ارزیابی می‌شوند.

## ۲. منطقه مورد مطالعه و مشاهدات مورد استفاده

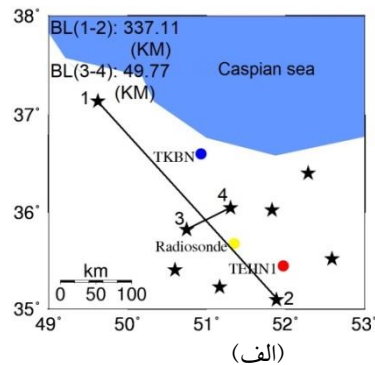

با توجه به در اختیار بودن مجموعه کاملی از مشاهدات ایستگاه‌های GPS، رادیوسوند و ایستگاه‌های هواشناسی در منطقه شمال غرب ایران و همچنین شبکه البرز مرکزی، مطالعه و ارزیابی مدل پیشنهادی مقاله در این دو ناحیه انجام گرفته است. در شبکه شمال غرب، مشاهدات ۲۳ ایستگاه GPS در سال ۲۰۱۱ و برای روزهای ۳۰۰ الی ۳۱۴ (فصل زمستان) استفاده شده است. برای شبکه البرز مرکزی، مشاهدات ۱۱ ایستگاه GPS در بازه زمانی روزهای ۱۶۲ الی ۱۷۶ (فصل تابستان) از سال ۲۰۱۶ بکار گرفته شده است. کلیه مشاهدات مورد نیاز از سازمان نقشه‌برداری کشور تهیه شده است (<https://www.ncc.gov.ir>). در شبکه شمال غرب، از ۲۳ ایستگاه موجود در منطقه، مشاهدات ۲۱ ایستگاه جهت آموزش مدل‌های GRNN و ANN استفاده می‌شوند. جهت ارزیابی دقت مدل‌ها، دو ایستگاه VLDN ( $38.30^0$  N,  $46.01^0$  E) MNDB و ( $36.74^0$  N,  $45.19^0$  E) به‌عنوان ایستگاه‌های کنترل داخلی در نظر گرفته شده و

حسن روش‌های ML در سرعت عمل و پایین بودن پیچیدگی محاسباتی، دقت و صحت بالا است. ژین و درن (۲۰۰۵) از یک شبکه عصبی مصنوعی (ANN) با ورودی‌های ماه، عرض جغرافیایی، ارتفاع و زاویه انکسار جهت مدل‌سازی مقدار PWV استفاده کردند. ژنگ و همکاران (۲۰۱۵) یک مدل ANN با الگوریتم آموزش پس انتشار خطا (BP) جهت مدل‌سازی مقدار تأخیر زینتی تروپوسفر (ZTD) را ارائه کردند. سلبسولگو (۲۰۱۹) یک مدل شبکه عصبی به همراه پارامترهای هواشناسی را جهت برآورد مقدار تأخیر تر تروپوسفری استفاده کرد. غفاری رزین و وثوقی (۲۰۲۲)، کارایی مدل ماشین بردار پشتیبان (SVM) را جهت مدل‌سازی و برآورد مقدار PWV در منطقه شمال غرب ایران ارزیابی کردند. غفاری رزین و اینیورت (۲۰۲۲) یک مدل جدید با استفاده از سیستم استنتاج عصبی-فازی سازگار (ANFIS) را جهت مدل‌سازی تغییرات زمانی و مکانی بخار آب قابل بارش ارائه کردند.

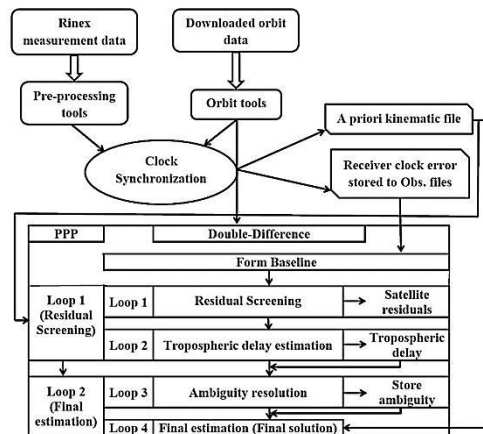
هدف اصلی و اساسی این مقاله استفاده از روش شبکه عصبی رگرسیون عمومی (GRNN) به‌عنوان یک مدل جدید برای برآورد تغییرات زمانی-مکانی مقدار بخار آب قابل بارش است. این شبکه عصبی به‌عنوان یک شبکه عصبی پیش‌بینی بر اساس نظریه رگرسیون غیرخطی، با تغییر ساختار شبکه‌های عصبی تابع شعاعی، دارای الگوریتم آموزش ساده و مستقیم است. ساختار این شبکه به گونه‌ای است که نیازی به یادگیری از طریق روش پس انتشار خطا از داده‌های آموزشی ندارد. آموزش و یادگیری سریع و همگرایی بهینه، از مزایای اصلی شبکه عصبی رگرسیون عمومی است. به‌عبارت‌دیگر یک شبکه عصبی رگرسیون عمومی می‌تواند از تجربه به‌درستی یاد گرفته و تنها با استفاده از بخش کوچکی از نمونه‌های آموزش مورد نیاز در مورد سایر مدل‌های یادگیری، فرآیند یادگیری را به اتمام برساند (ماسیکس و همکاران، ۲۰۱۵). هشت پارامتر طول، عرض و ارتفاع جغرافیایی ایستگاه GPS، روز مشاهده (DOY)، زمان (min.)،

از این ایستگاه‌ها (NZSF، TABZ، KLBR، BNAB)، ZARI، VLDN، SKOH) مجهز به سنجنده‌های دما، فشار و رطوبت هستند.

در مرحله اول، مشاهدات ایستگاه‌های GPS هر دو شبکه که در مرحله آموزش مدل‌های GRNN و ANN استفاده می‌شوند، در نرم‌افزار برنیز (داخ و همکاران، ۲۰۰۷) پردازش شده و مقدار تأخیر زینتی تروپوسفر (ZTD) در بازه‌های زمانی ۱۵ دقیقه‌ای (مشاهدات ۲۴ ساعته به فایل‌های مشاهداتی ۱۵ دقیقه‌ای تبدیل و هر ۱۵ دقیقه داده به‌طور مستقل مورد استفاده قرار گرفته است) حاصل می‌شوند. روند نمای پردازش مشاهدات و محاسبه تأخیر کل تروپوسفر با نرم‌افزار برنیز در شکل (۲) نمایش داده شده است.



شکل ۱. چگونگی پراکندگی ایستگاه‌های GPS (ستاره‌های سیاه)، ایستگاه‌های کنترل داخلی (دایره‌های قرمز و آبی رنگ)، ایستگاه کنترل خارجی (مثلث سبز رنگ) و ایستگاه‌های رادیوسوند تبریز و تهران (دایره زرد) مورد استفاده در این تحقیق به همراه بلندترین (۱-۲) و کوتاه‌ترین (۳-۴) طول بازه‌های پردازش شده در شبکه البرز مرکزی (الف) و شبکه شمال غرب (ب).



شکل ۲. روند نمای مراحل پردازش مشاهدات در نرم‌افزار برنیز و محاسبه مقدار تأخیر کل تروپوسفری.

جغرافیایی ایستگاه GPS، روز مشاهده (DOY)، زمان (min.)، رطوبت نسبی (RH)، دما (T) و فشار (P) به عنوان ورودی‌های دو مدل GRNN و ANN خواهند بود. به عبارت دیگر به عبارت دیگر پایگاه داده مشاهداتی جهت آموزش دو مدل GRNN و ANN در شبکه شمال غرب دارای ۳۰۲۴۰ و در شبکه البرز مرکزی دارای ۱۲۹۶۰ بردار ورودی است.

### ۳. روش شناسی

با توجه به اینکه هدف این مقاله ارائه یک روش جدید برای مدل‌سازی توأم مکانی-زمانی مقدار بخار آب قابل بارش با استفاده از مدل شبکه عصبی رگرسیون عمومی (GRNN) است، در نتیجه در ادامه مبانی ریاضی این روش توضیح داده می‌شود. همچنین با توجه به اینکه نتایج مدل جدید با مدل‌های شبکه عصبی مصنوعی استاندارد (ANN)، توموگرافی المان‌های حجمی (VBT)، مدل ECMWF، مدل تجربی ساستاموینس و GPT3 مقایسه و ارزیابی می‌شوند، تئوری ریاضی این روش‌ها نیز توضیح داده خواهند شد.

۳-۱. مدل شبکه عصبی رگرسیون عمومی (GRNN) شبکه عصبی رگرسیون عمومی (GRNN) نوعی از شبکه‌های عصبی توابع پایه شعاعی (RBNN) است که در سال ۱۹۹۱ توسط اسپیک ارائه شد (اسپیچ، ۱۹۹۱). این مدل برای رگرسیون، طبقه‌بندی و پیش‌بینی سیستم‌های دینامیک بسیار کارایی دارد. از نظر ساختاری، شبکه عصبی رگرسیون عمومی دارای ساختاری مشابه با شبکه عصبی تابع شعاعی با یک لایه اضافه از نوع خطی، قبل از خروجی است. نقش این لایه محاسبه یک رگرسیون از داده‌های طبقه قبل است. مدل GRNN مستقیماً هر تابع دلخواه مابین بردارهای ورودی و خروجی را در یک الگوریتم یادگیری یک طرفه به جای یک رویه تکراری مانند الگوریتم پس‌انتشار (BP) تقریب می‌کند (یووان و همکاران، ۲۰۲۰). تحقیقات انجام گرفته نشان داده است که مدل GRNN با دیتاهای ورودی بسیار زیاد، در مقایسه

در مرحله بعد، با استفاده از مدل تجربی ساستاموینس بهبود داده شده توسط دیویس و همکاران (۱۹۸۵)، مقدار تأخیر زینتی خشک (ZHD) برآورد 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،  $\varphi$  و  $h_{ell}$  به ترتیب عرض جغرافیایی و ارتفاع ایستگاه می‌باشند. اگر مقدار ZHD به دست آمده از رابطه (۱) از مقدار کلی تأخیر تروپوسفری (ZTD) کم شود، مقدار تأخیر تر زینتی (ZWD) حاصل خواهد شد. با استفاده از مقدار ZWD به دست آمده، می‌توان مقدار بخار آب قابل بارش را توسط رابطه زیر محاسبه کرد:

$$PWV = \prod(T_m) \times ZWD \quad (2)$$

در رابطه بالا خواهیم داشت:

$$\prod = \left( 10^{-6} \left( \frac{k_3}{T_m} + k_2' \right) \times R_v \times \rho \right)^{-1} \quad (3)$$

در رابطه (۳)،  $R_v = 461.45 (JK/gK)$  نشان‌دهنده ثابت گاز،  $K_2' = 17$ ،  $K_3 = 3.7 \times 10^5$  بیانگر ثابت انکسار جوی و  $\rho = 1000 (kg/m^3)$  معرف چگالی آب مایع است. در این مقاله رابطه زیر برای محاسبه پارامتر  $T_m$  مورد استفاده قرار گرفته است (صادقی و همکاران، ۲۰۱۴):

$$T_m = 75.39 + 0.7103T_0 \quad (4)$$

در رابطه (۴) دمای اولیه در محیط مورد بررسی است. بر اساس شکل (۱) و پردازش‌های انجام گرفته، تعداد  $21 \times 15 \times 96$  (۳۰۲۴۰) کمیت بخار آب قابل بارش (PWV) از ایستگاه‌های GPS شبکه شمال غرب و تعداد  $9 \times 15 \times 96$  (۱۲۹۶۰) کمیت بخار آب قابل بارش (PWV) از ایستگاه‌های GPS شبکه البرز مرکزی حاصل می‌شوند (۲۱ و ۹ بیانگر تعداد ایستگاه‌های GPS برای آموزش در دو شبکه، ۱۵ نشان‌دهنده تعداد روزهای مورد بررسی، ۹۶ بیانگر تعداد کمیت PWV در هر روز). متناظر با کمیت‌های PWV، هشت پارامتر طول، عرض و ارتفاع

$$K(X, X^i) = \exp\left(-\frac{D_i^2}{2\sigma^2}\right) \quad (8)$$

با انجام محاسبات مورد نیاز، تابع برآوردگر  $\hat{Y}(X)$  به صورت زیر حاصل خواهد شد:

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y^i K(X, X^i)}{\sum_{i=1}^n K(X, X^i)} \quad (9)$$

یک مدل GRNN شامل چهار لایه است (شکل ۳). لایه ورودی شامل  $p$  نورون است که بر اساس پارامترهای ورودی تعریف می شود. لایه الگو شامل  $n$  گره است که با نمونه های  $X$  فعال می شوند. در هر گره لایه الگو، از معادله (۷) جهت محاسبه  $D_i^2$  استفاده شده و سپس مقدار حاصل در رابطه (۸) بکار گرفته می شوند. خروجی لایه الگو به لایه جمع بندی ارسال می شوند.

در شکل (۳)  $R$  تعداد نورون های لایه ورودی بوده که با تعداد ویژگی های در نظر گرفته شده در مسئله برابر است. همچنین لایه تابع شعاعی دارای تعداد  $Q$  تابع شعاعی از نوع گوسین است. داده های ورودی به همراه ضرایب مربوطه به تابع شعاعی ارائه می شوند. بعد از محاسبه خروجی این لایه، مقادیر خروجی با در نظر گرفتن ضرایب دیگری به لایه خطی داده می شوند. در نهایت خروجی نهایی از ترکیب خطی خروجی های لایه خطی به دست می آید. خوشه بندی داده های آموزش ورودی در لایه شعاعی انجام می شود. از این رو، تعداد نورون ها در لایه شعاعی برابر با تعداد مجموعه داده های مورد استفاده برای آموزش است. لایه خطی همیشه از نورون اضافی در مقایسه با لایه خروجی بهره می گیرد. این نورون اضافی، تابع چگالی احتمال را محاسبه می کند، در حالی که نورون های باقیمانده برای محاسبه خروجی استفاده می شود (خسروی و همکاران، ۱۳۹۹؛ غریتلار و پرساد، ۲۰۱۸).

با سایر نسخه های شبکه عصبی، خطای بسیار پایینی دارد (کیم و همکاران، ۲۰۰۴). مدل GRNN بر پایه رگرسیون کرنلی است.

فرض کنید یک متغیر تصادفی اسکالر  $y$  به یک بردار متغیر تصادفی مستقل  $x$  وابسته است. با توجه به یک مجموعه آموزشی، محتمل ترین مقدار برای  $y$  تخمین زده می شود. مدل GRNN بر اساس تابع چگالی احتمال (PDF) و مجموعه آموزشی ایجاد می شود. از آنجایی که PDF از داده هایی بدون اطلاعات قبلی تولید می شود، در نتیجه مدل GRNN به عنوان یک مدل عمومی (ینیورسال) شناخته می شود. اگر  $f(X, Y)$  تابع چگالی احتمال مشترک متغیرهای  $x$  و  $y$  باشد، در این صورت امید ریاضی شرطی  $y$  در  $X$  به صورت زیر خواهد بود:


$$E(y|X) = \frac{\int_{-\infty}^{+\infty} y f(X, y) dy}{\int_{-\infty}^{+\infty} f(X, y) dy} \quad (5)$$

معمولاً تابع چگالی احتمال بر اساس نمونه هایی از مشاهدات  $X$  و  $y$  تولید می شود. فرض کنید که  $\hat{f}(X, Y)$  یک برآورد کننده تابع چگالی احتمال بر اساس متغیرهای تصادفی  $X$  و  $Y$  باشد. در این صورت خواهیم داشت:

$$\hat{f}(X, Y) = \frac{1}{(2\pi)^{\frac{p+1}{2\sigma^{p+1}}}} \frac{1}{n} \times \sum_{i=1}^n \exp\left[-\frac{(X - X^i)^T (X - X^i)}{2\sigma^2}\right] \exp\left[-\frac{(Y - Y^i)^2}{2\sigma^2}\right] \quad (6)$$

در رابطه (۶)،  $n$  تعداد مشاهدات نمونه،  $p$  بیانگر بعد بردار  $X$  و  $\sigma$  نشان دهنده پارامتر گسترش در مدل GRNN می باشد. تابع اسکالر  $D_i^2$  و کرنل گوسی به صورت در نظر گرفته می شوند:

$$D_i^2 = (X - X^i)^T (X - X^i) \quad (7)$$



شکل ۳. ساختار یک مدل GRNN و لایه‌های مختلف موجود در آن (خسروی و همکاران، ۱۳۹۹).

۲-۳. مدل شبکه عصبی استاندارد

(۱۹۹۴):

$$f(S_j) = \frac{1}{\left(1 + \exp\left(-\left(\sum_{i=1}^n w_{ij} \cdot x_i - \theta_j\right)\right)\right)} \quad (10)$$

$$j = 1, 2, \dots, H$$

در رابطه (۱۰)  $n$  بیانگر تعداد گره‌های ورودی،  $w_{ij}$  نشان‌دهنده وزن ارتباطی مابین گره‌های لایه ورودی و پنهان،  $\theta_j$  بیانگر بایاس موجود در لایه پنهان و  $x_i$  نشان‌دهنده ورودی است. خروجی در لایه آخر را می‌توان با استفاده از رابطه زیر محاسبه کرد:

$$y_k = \sum_{j=1}^H w_{kj} \cdot f(S_j) - \theta_k \quad (11)$$

$$k = 1, 2, \dots, O$$

در رابطه (۱۱)  $w_{kj}$  بیانگر وزن ارتباطی مابین زامین گره از لایه پنهان با  $k$  زامین گره از لایه خروجی و  $\theta_k$  بیانگر بایاس موجود در لایه خروجی است. خطای آموزش شبکه را با استفاده از رابطه زیر می‌توان محاسبه کرد:

$$E = \sum_{k=1}^q \frac{E_k}{(q * O)} \quad (12)$$


$$E_k = \sum_{i=1}^O (y_i^k - C_i^k)^2$$

در رابطه (۱۲)  $q$  بیانگر تعداد کل نمونه‌های مورد استفاده جهت آموزش و  $(y_i^k - C_i^k)$  نشان‌دهنده اختلاف مابین مقدار واقعی و خروجی شبکه هستند.

۳-۳. مدل تجربی GPT3

مدل GPT3 یک مدل تجربی تروپوسفر است که برای به دست آوردن پارامترهای هواشناسی توسعه داده شده است

یک شبکه عصبی مصنوعی ایده‌ای برای پردازش اطلاعات است که از سیستم عصبی-زیستی الهام گرفته و مانند مغز به پردازش اطلاعات می‌پردازد. عنصر کلیدی این ایده، ساختار جدید سیستم پردازش اطلاعات است. این سیستم از شمار زیادی عناصر پردازشی فوق‌العاده به هم پیوسته به نام نورون‌ها تشکیل شده که برای حل یک مسئله با هم هماهنگ عمل می‌کنند. یکی از معروف‌ترین ساختارهای شبکه‌های عصبی مصنوعی ساختار پرسپترون چندلایه (MLP) است که از یک لایه ورودی، یک یا چندلایه میانی (لایه پنهان) و یک لایه خروجی تشکیل یافته است. در نظر بگیرید که لایه ورودی دارای  $n$  گره، لایه پنهان دارای  $H$  گره و لایه خروجی دارای  $O$  گره به صورت شکل (۴) باشند.



شکل ۴. ساختار یک شبکه عصبی سه لایه (هایکین، ۱۹۹۴).

اگر در نظر بگیریم که تابع فعالیت لایه پنهان به صورت سیگموئید و تابع فعالیت لایه خروجی به صورت خطی باشند. بر اساس شکل (۳) خروجی زامین گره از لایه پنهان با رابطه زیر محاسبه می‌شود (هایکین،



قابل بارش مدل سازی شده توسط مدل تجربی ساستاموین حاصل می شود.

### ۳-۵. داده های باز تحلیل ERA-Interim

تحلیل دوباره یک سامانه برای تولید مجموعه ای از داده های اقلیمی، بازتحلیل نامیده می شود. داده های بازتحلیل یا تحلیل مجدد، با استفاده از یک سامانه ثابت و از نظر دینامیکی سازگار در داده گواری داده ها و مدل ها که در آن از همه داده های در دسترس مشاهداتی استفاده می شود، ایجاد می شوند (مرکز پیش بینی وضعیت آب و هوای اروپا، ۲۰۱۳). یکی از مؤلفه هایی که در این فرآیند تغییر می کند، داده های دیدبانی است. در واقع داده های بازتحلیل، تلفیقی از داده های دیدبانی به علاوه مدل سازی هستند. برای مناطقی که فاقد داده هستند یا شبکه ایستگاه ها تراکم کمی دارند از مدل سازی استفاده می شود. یکی از انواع داده های بازتحلیل، داده های ERA-Interim است. این داده ها ناشی از آخرین تحلیل دوباره جو است که سازمان پیش بینی وضعیت آب و هوای اروپا از ۱۹۷۹ آغاز کرده و تاکنون ادامه دارد (حاجی آقاجانی و وثوقی، ۱۳۹۵).

در نظر نگرفتن چرخه آب در جو و تطابق زمانی با دیگر داده ها، از جمله این مشکلات است. بدین منظور تعداد لایه های فشاری از ۲۳ به ۳۷ افزایش یافت. این داده ها مجموعه ای از پارامترهای هواشناسی از ژانویه ۱۹۷۹ تاکنون را در بر دارد. فاصله مکانی این داده ها ۰/۷۵ درجه و حدود ۷۰ کیلومتر است که کره زمین را به صورت شبکه های ۰/۷۵ × ۰/۷۵ درجه در برمی گیرد. این داده ها در برگیرنده عرض جغرافیایی ۸۹/۴۲۵ تا ۸۹/۴۲۵- درجه و طول جغرافیایی ۰ تا ۳۵۹/۲۵ درجه هستند. قدرت تفکیک زمانی این داده ها ۶ ساعت است و اطلاعات را در ساعت های ۶ صبح، ۱۲ ظهر، ۶ بعدازظهر و ۱۲ شب در بردارد. این داده ها حدود ۳۰۰ پارامتر از جمله فشار بخار آب، دما، فشار و مانند آن را در اختیار کاربران قرار می دهند (مرکز پیش بینی وضعیت آب و هوای اروپا،

لندسکرون و بوم، ۲۰۱۷). نسخه های مختلف این مدل به تدریج به صورت GPT، GPT2 و GPT3 توسعه داده شده اند. پارامترهای ورودی مدل GPT3 شامل تاریخ جولیان اصلاح شده (modified Julian date)، طول و عرض جغرافیایی و ارتفاع از بیضوی است. در حالی که پارامترهای خروجی شامل ۹ نوع پارامتر تروپوسفری است. از میان پارامترهای خروجی، میانگین وزنی دمای جو، فشار بخار آب و ضریب کاهش بخار آب عواملی هستند که برای محاسبه PWV استفاده می شوند. در این مطالعه، مقدار ZWD در هر نقطه شبکه با استفاده از مدل زیر محاسبه می شود (اسکنه و نوردیوس، ۱۹۸۷):

$$ZWD = 10^{-6} \left( k_2' + \frac{k_3}{T_m} \right) \times \frac{R_d}{(\lambda + 1)g_m} e \quad (13)$$

که در آن  $R_d$  یک ثابت گاز خاص،  $e$  و  $\lambda$  به ترتیب فشار بخار آب و ضریب کاهش بخار آب هستند،  $g_m$  متوسط گرانش است.

### ۳-۴. مدل تجربی ساستاموین

تاکنون مدل های تروپوسفری مختلفی جهت به دست آوردن اثر لایه تروپوسفر بر روی امواج عبوری از آن ارائه شده است. معمولاً پارامترهای هواشناسی مختلفی مانند: فشار، دما و رطوبت ورودی های این مدل ها هستند. مؤلفه ترانکسار تروپوسفری ۱۰ درصد تأخیر تروپوسفری را تشکیل می دهد. این بخش از تأخیر تروپوسفری به علت وابستگی آن به بخار آب، دارای تغییرات زیاد مکانی و زمانی است. مدل زینتی تأخیر ترانکسار تروپوسفری (ZWD) نوشته شده توسط ساستاموین برای عرض های جغرافیایی متوسط و شرایط نرمال به صورت زیر است (ساستاموین، ۱۹۷۳):

$$ZWD = 0.002277 \left( \frac{1255}{T_s} + 0.05 \right) e_s \quad (14)$$

در رابطه (۱۴)  $e_s$  فشار بخار آب در سطح زمین و  $T_s$  دما سطحی است. با جایگذاری مقدار تأخیر تر زینتی به دست آمده از رابطه (۱۴) در رابطه (۲)، مقدار بخار آب

با  $r$  سطر و  $n$  ستون است، همچنین  $m$  بردار مجهولات VWD در هر المان با مرتبه  $n$  است. درایه‌های ماتریس  $\mathbf{G}$  بر اساس طول سیگنال عبوری از المان حجمی ساخته می‌شوند. اگر المانی خالی باشد درایه متناظر آن در ماتریس، صفر خواهد بود؛ بنابراین، در این مقاله از روش بازسازی جبری هم‌زمان (SART) برای حل مسئله توموگرافی تروپوسفر به روش المان حجمی استفاده شده است (استر و همکاران، ۲۰۰۳). برآورد پارامترهای مجهول در روش SART با رابطه زیر صورت می‌گیرد:

$$m^{k+1} = m^k + \lambda \mathbf{V}^{-1} \mathbf{G}^T \mathbf{W}^{-1} (\mathbf{L} - \mathbf{G}m) \quad (18)$$

در رابطه (۱۸)  $m$  بردار مجهولات،  $\lambda$  پارامتر پایدارسازی و  $\mathbf{L}$  بردار مشاهدات هستند. در این رابطه  $\mathbf{V}$  و  $\mathbf{W}$  ماتریس‌هایی قطری می‌باشند. این دو ماتریس بر اساس روابط زیر محاسبه می‌شوند:

$$\text{Diag}(\mathbf{V}) = G_{i,+} = \sum_{j=1}^n G_{i,j} \quad (19)$$

$$\text{Diag}(\mathbf{W}) = G_{+,j} = \sum_{i=1}^r G_{i,j}$$

در این مقاله از روش منحنی  $L$  برای تعیین بهینه مقدار پارامتر پایدارسازی استفاده شده است (استر و همکاران، ۲۰۰۳). این روش یکی از ساده‌ترین روش‌های موجود برای انتخاب بهینه پارامتر پایدارسازی در یک مسئله گسسته معکوس ناپایدار است که در آن تغییرات نرم جواب پایدارسازی شده نسبت به تغییرات نرم بردار باقیمانده‌ها مورد بررسی قرار می‌گیرد. با برآورد پارامترهای مجهول در رابطه (۱۷) می‌توان مقدار WVD را محاسبه کرد. مجموع چگالی بخار آب حاصل از روش المان‌های حجمی در راستای زینت، مقدار بخار آب قابل بارش را به دست می‌دهد.

### ۳-۷. ارزیابی خطای مدل‌ها

ارزیابی‌های آماری مدل‌های GRNN، ANN، VBT، ECMWF، GPT3 و ساستاموینن با استفاده از

(۲۰۱۳). مقدار بخار آب قابل بارش (PWV) با استفاده از پارامترهای رطوبت نسبی، فشار و دما به کمک رابطه زیر محاسبه می‌شود:

$$PWV = \frac{1}{\rho_w g} \int_{P_s}^0 q(P) dP \quad (15)$$

در رابطه (۱۵)،  $\rho_w$  نشان‌دهنده چگالی آب ( $1000 \frac{kg}{m^3}$ )،  $g$  بیانگر شتاب ثقل در ایستگاه و  $q(P)$  نرخ بخار آب ( $\frac{g}{kg}$ ) می‌باشند.

### ۳-۶. مدل توموگرافی المان‌های حجمی

توموگرافی تروپوسفر با المان‌های حجمی یکی از روش‌های معمول و رایج در برآورد انکسار تر و مقدار بخار آب موجود در جو است. این روش به کرات و توسط محققین مختلف مورد استفاده قرار گرفته است (در مقدمه به برخی از این پژوهش‌ها اشاره شده است). به دلیل ناپایداری مسئله معکوس توموگرافی تروپوسفر که ذاتاً در اینجا مسئله‌ای از نوع فردهولم نوع اول است استفاده از روش‌های پایدارسازی برای رسیدن به جواب پایدار شده را اجتناب‌ناپذیر می‌کند (ادای و مشهدی حسینی، ۲۰۱۵؛ غفاری رزین، ۱۳۹۹). به دلیل استفاده از روش‌های پایدارسازی، پارامترهای برآورد شده دارای بایاس اریبی بوده و می‌بایستی مقدار این بایاس مورد بررسی قرار گیرد. مدل توموگرافی المان‌های حجمی تروپوسفر را می‌توان به صورت گسسته به صورت زیر نوشت (یائو و همکاران، ۲۰۱۹).

$$SWV^P = \sum_i^n d_i^P \rho_i \quad (16)$$

در (۱۶)،  $P$  شمارنده سیگنال‌ها،  $n$  تعداد المان‌ها در مدل توموگرافی،  $d_i^P$  مسافت طی شده توسط پرتو  $P$  در المان  $i$  و  $\rho_i$  چگالی بخار آب (WVD) در المان  $i$  است. معادله (۱۶) را می‌توان به شکل ماتریس نوشت:

$$\mathbf{L} = \mathbf{G}m \quad (17)$$

که در آن،  $\mathbf{L}$  بردار مشاهدات با مرتبه  $r$  است ( $r$  تعداد سیگنال‌های GPS است)،  $\mathbf{G}$  نشان‌دهنده ماتریس ضرب

جذر میانگین مربعات خطا (RMSE)، ضریب همبستگی و خطای نسبی انجام می‌شود. کمینه مقادیر خطای نسبی و RMSE صفر است. هر چقدر مقادیر این دو پارامتر به صفر نزدیک‌تر باشند، نشان‌دهنده دقت بالاتر مدل مورد نظر است. ضریب همبستگی بیانگر همبستگی موجود در دو متغیر مورد مقایسه است. به عبارت دیگر این شاخص تغییرات دو متغیر را نسبت به هم بیان می‌کند. مقدار این ضریب در بازه [0, 1] است. اگر ضریب همبستگی دو متغیر به یک نزدیک‌تر باشد نشان‌دهنده همبستگی بالای آن‌ها است. ضریب همبستگی صفر نشان‌دهنده عدم وجود همبستگی مابین دو متغیر است. این شاخص‌ها به صورت زیر تعریف می‌شوند:

۴-۱. آنالیز خطای مدل‌های ANN و GRNN در مرحله آموزش

در مرحله آموزش دو مدل ANN و GRNN هشت پارامتر طول، عرض و ارتفاع جغرافیایی ایستگاه GPS، روز مشاهده (DOY)، زمان (min.)، رطوبت نسبی (RH)، دما (T) و فشار (P) به عنوان ورودی در نظر گرفته می‌شوند. برای هر بردار ورودی، یک PWV متناظر با آن نیز به عنوان خروجی هدف، معرفی می‌شود؛ بنابراین هر دو مدل دارای ۸ پارامتر ورودی و ۱ پارامتر خروجی هستند؛ اما تعداد نورون‌های لایه الگو در مدل GRNN برابر با تعداد بردارهای مشاهداتی مورد استفاده برای آموزش است. در این لایه از تابع شعاعی از نوع گاوسی استفاده شده است. در مدل ANN تعداد نورون‌های لایه پنهان بر اساس کمینه خطای مدل در محل ایستگاه‌های رادیوسوند تبریز و تهران محاسبه شده است. بر اساس محاسبات انجام گرفته در مرحله آموزش، مدل ANN با تعداد ۸ نورون در لایه پنهان دارای کمترین خطا در مرحله آموزش است (ساختار بهینه برای مدل ANN به صورت ۸-۱۴-۱ می‌باشد. عدد ۸ نشان‌دهنده تعداد پارامترهای ورودی، عدد ۱۴ بیانگر تعداد نورون‌های لایه پنهان و عدد ۱ بیانگر خروجی است). در لایه پنهان مدل ANN از تابع فعال‌سازی سیگموئید استفاده شده است. جدول (۱) اطلاعات آماری حاصل از مرحله آموزش را برای دو مدل ANN و GRNN در هر دو شبکه مورد مطالعه نمایش می‌دهد.

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

$$R = \frac{\sum_{i=1}^N (PWV_{model}^i - \overline{PWV}_i) (PWV_{GPS}^i - \overline{PWV}_{GPS}^i)}{\sqrt{\sum_{i=1}^N (PWV_{model}^i - \overline{PWV}_i)^2} \sqrt{\sum_{i=1}^N (PWV_{GPS}^i - \overline{PWV}_{GPS}^i)^2}} \quad (21)$$

$$Re = \left( \frac{PWV_{model} - PWV_{GPS}}{PWV_{GPS}} \right) \times 100 \quad (22)$$

که در روابط بالا،  $\overline{PWV}$  مقدار میانگین PWV حاصل از GPS،  $PWV_{model}$  نشان‌دهنده بخار آب قابل بارش حاصل از مدل،  $PWV_{GPS}$  مقدار بخار آب قابل بارش به دست آمده از GPS و N تعداد نمونه‌های مورد بررسی هستند. لازم به ذکر است که برای ارزیابی دقیق‌تر، از روش تعیین موقعیت نقطه‌ای دقیق (PPP) در ایستگاه‌های کنترل داخلی و خارجی استفاده می‌شود. تأثیر مدل‌سازی بر روی مؤلفه‌های مختصات ایستگاه‌های کنترل ارزیابی می‌شوند.

#### ۴. آنالیز خطای مدل‌ها

ارزیابی و آنالیز خطای مدل‌های ANN، GRNN، VBT،


جدول ۱. مقایسه پارامترهای RMSE (mm)، ضریب همبستگی (R.) و زمان همگرایی به جواب بهینه (ثانیه) در مرحله آموزش مدل‌های ANN و GRNN در هر دو شبکه شمال غرب و البرز مرکزی.

| شبکه البرز مرکزی<br>(فصل تابستان) |          | شبکه شمال غرب<br>(فصل زمستان) |          |                                       |
|-----------------------------------|----------|-------------------------------|----------|---------------------------------------|
| مدل ANN                           | مدل GRNN | مدل ANN                       | مدل GRNN |                                       |
| ۲/۱۷                              | ۱/۳۱     | ۲/۸۳                          | ۱/۵۶     | RMSE (mm)                             |
| ۰/۹۱                              | ۰/۹۵     | ۰/۸۸                          | ۰/۹۳     | ضریب همبستگی (R.)                     |
| ۱۱۴                               | ۴۷۳      | ۱۹۸                           | ۶۸۹      | زمان همگرایی به جواب بهینه<br>(ثانیه) |

#### ۴-۲. آنالیز خطای مدل‌های ANN، GRNN، VBT،

ECMWF، GPT3 و ساستاموین در مرحله آزمون پس از مرحله آموزش دو مدل ANN و GRNN در دو شبکه شمال غرب و شبکه البرز مرکزی، حال می‌توان با مدل‌های آموزش دیده مقدار PWV را در محل ایستگاه‌های کنترل داخلی و خارجی و همچنین محل ایستگاه‌های رادیوسوند تبریز و رادیوسوند تهران برآورد کرده و با مقدار PWV حاصل از سایر مدل‌ها و همچنین بخار آب قابل بارش حاصل از GPS مقایسه کرد. شکل (۵) نتایج مقایسه انجام گرفته برای تمامی مدل‌ها در محل ایستگاه‌های کنترل داخلی و خارجی و برای دو شبکه مورد مطالعه را نمایش می‌دهد. بایستی اشاره شود که در مقایسه‌های صورت گرفته در این شکل، PWV حاصل از GPS به‌عنوان مبنا در نظر گرفته شده است. همچنین، مدل توموگرافی در نظر گرفته شده دارای تفکیک افقی ۴۵ کیلومتر، تفکیک زمانی یک ساعته و تفکیک ارتفاعی ۵۰۰ متر تا ارتفاع ۸ کیلومتری می‌باشد.

بایستی اشاره شود که هر دو مدل در یک سیستم کامپیوتری با سخت‌افزار و نرم‌افزار یکسان پردازش شده‌اند. بر اساس نتایج جدول (۱) مقدار خطای مدل GRNN در مرحله آموزش نسبت به مدل ANN در هر دو شبکه مورد مطالعه کمتر است. همچنین ضریب همبستگی مدل GRNN در مقایسه با مدل ANN بالاتر است. به عبارت دیگر مدل GRNN رفتار مکانی-زمانی موجود در داده‌های آموزشی را با دقت بالاتری نسبت به مدل ANN در هر دو شبکه مورد بررسی تشخیص داده است؛ اما با توجه به اینکه در مدل GRNN تعداد نورون‌های لایه الگو بسیار بیشتر از مدل ANN است در نتیجه زمان همگرایی به جواب بهینه در این مدل بالاتر از مدل ANN می‌باشد. همچنین بایستی اشاره شود که چون در شبکه البرز مرکزی تعداد ایستگاه‌های آموزش نسبت به شبکه شمال غرب کمتر است در نتیجه زمان همگرایی به جواب بهینه دو مدل GRNN و ANN پایین‌تر از شبکه شمال غرب حاصل شده است.



شکل ۵. مقایسه پارامترهای آماری RMSE (mm)، خطای نسبی (%) و ضریب همبستگی (R) برای مدل‌های ANN، GRNN، VBT، GPT3، Saas. و ECMWF در مرحله آزمون و برای شبکه البرز مرکزی (الف) و شبکه شمال غرب (ب).

بیشتری دارد. به عبارت دیگر در مرحله آموزش مدل‌های ANN و GRNN و در پایگاه داده، داده‌های آموزشی از این دو ایستگاه کنترل فاصله دارند. این عامل باعث کاهش دقت هر دو مدل در این دو ایستگاه کنترل نسبت به ایستگاه‌های کنترل VLDN و TEHN1 شده است؛ اما مقایسه نتایج شکل (۵) در دو ایستگاه کنترل MNDB و TKBN نشان می‌دهد که مدل GRNN از دقت بالاتری نسبت به ANN برخوردار است. به عبارت دیگر، مدل GRNN حتی با داده‌های آموزشی کمتر، دقت بالاتری

در هر دو شبکه مورد بررسی و در ایستگاه‌های کنترل داخلی (VLDN، MNDB، TKBN، TEHN1)، دقت مدل GRNN از ANN بیشتر است. استفاده از توابع پایه شعاعی در لایه الگو برای مدل GRNN باعث افزایش دقت شده است. نکته مهم در هر دو شبکه مورد بررسی و در هر دو مدل GRNN و ANN کاهش دقت در ایستگاه‌های کنترل داخلی MNDB و TKBN است. مطابق شکل (۱) و در هر دو شبکه، این دو ایستگاه کنترل داخلی از سایر ایستگاه‌های مورد استفاده در مرحله آموزش فاصله

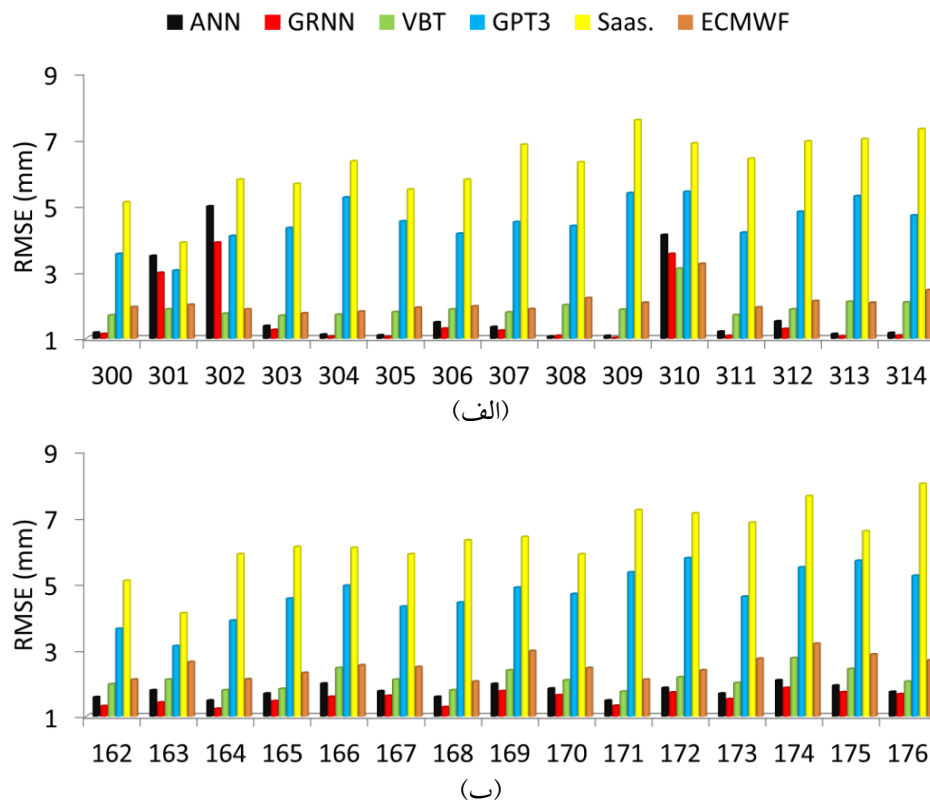
پایه شعاعی با استفاده از مشاهدات شبکه مورد مطالعه برآورد شده است. به عبارت دیگر، این پارامترها در محدوده شبکه GPS معتبر هستند. با دور شدن از محدوده شبکه GPS، اعتبار پارامترهای توابع پایه شعاعی از بین می‌رود و در نتیجه خطای مدل افزایش می‌یابد. به همین دلیل، در شبکه البرز مرکزی مقدار RMSE مدل GRNN نسبت به شبکه شمال غرب بیشتر شده است؛ زیرا فاصله ایستگاه کنترل خارجی ARUC از شبکه البرز مرکزی خیلی بیشتر از شبکه شمال غرب است.

با در نظر گرفتن مقادیر میانگین خطای نسبی در شکل (۵) و برای شبکه شمال غرب، مدل GRNN با دقت حدود ۸۷ درصد (۱۲/۳۱) درصد میانگین خطای نسبی مدل GRNN، ANN با دقت حدود ۸۶ درصد (۱۳/۴۰) درصد میانگین خطای نسبی مدل VBT و ANN است) با دقت حدود ۸۵ درصد (۱۴/۱۹) درصد میانگین خطای نسبی مدل توانایی مدل‌سازی PWV در موقعیت دو ایستگاه کنترل داخلی را دارند. برای شبکه البرز مرکزی، مدل GRNN با دقت حدود ۸۸ درصد (۱۲/۰۱) درصد میانگین خطای نسبی مدل GRNN، ANN با دقت حدود ۸۷ درصد (۱۳/۰۸) درصد میانگین خطای نسبی مدل VBT است) و VBT با دقت حدود ۸۵ درصد (۱۴/۲۰) درصد میانگین خطای نسبی مدل توانایی مدل‌سازی PWV در موقعیت دو ایستگاه کنترل داخلی را دارند. در ایستگاه‌های رادیوسوند تبریز و تهران، PWV حاصل از مدل‌های ANN، GRNN، VBT، ECMWF، ساستاموینن و GPT3 با PWV ایستگاه رادیوسوند مقایسه شده است. شکل (۶) خطای RMSE این مقایسه را در ۱۵ روز مورد مطالعه و برای هر دو شبکه مورد بررسی نشان می‌دهد. بایستی اشاره شود که PWV به‌دست‌آمده از ایستگاه رادیوسوند به‌عنوان مشاهده مرجع در نظر گرفته شده است.

نسبت به ANN دارد. نتایج شکل (۵) نشان می‌دهد که در هر دو شبکه مورد مطالعه و در ایستگاه‌های کنترل داخلی، RMSE مدل‌های GRNN و ANN کمتر از سایر مدل‌ها است.

به دلیل کمبود مرتبه ماتریس ضرایب در رابطه (۱۷) و استفاده از روش‌های پایدارسازی، بایاس در نتایج مدل VBT ایجاد می‌شود. همچنین تعیین اندازه بهینه المان‌های حجمی با در نظر گرفتن مقادیر اولیه بخار آب داخل هر المان و همچنین با فرض ثابت بودن بخار آب در داخل المان‌ها، از دیگر عوامل کاهش دقت نتایج مدل VBT می‌باشد. مدل‌های ECMWF، GPT3 و ساستاموینن از داده‌های هواشناسی برای تخمین مقدار PWV استفاده می‌کنند. در مدل‌های ECMWF و GPT3 از پارامترهای مختلفی وابسته به مکان و زمان برای برآورد پارامترهای هواشناسی استفاده می‌شود. در نتیجه دقت این مدل‌ها از مدل تجربی ساستاموینن بیشتر است. پارامترهای هواشناسی مورد استفاده در مدل‌های ECMWF، GPT3 و ساستاموینن معمولاً از ایستگاه‌های هواشناسی تعیین می‌شوند. این پارامترها در صورت نبود ایستگاه‌های هواشناسی، با روش‌های درونیابی تخمین زده می‌شوند. پارامترهای هواشناسی دارای تغییرات مکانی-زمانی زیادی هستند. خطای این پارامترها به دلیل استفاده از روش‌های درونیابی باعث ایجاد خطا در نتایج مدل‌های ECMWF، GPT3 و ساستاموینن می‌شود. نتایج شکل (۵) نیز نشان می‌دهد که RMSE این سه مدل در مقایسه با سایر مدل‌ها در دو ایستگاه کنترل داخلی و در هر دو شبکه مورد مطالعه بالاتر است.

در هر دو شبکه مورد مطالعه و در ایستگاه کنترل خارجی ARUC، RMSE مدل GRNN کمتر از مدل‌های ANN، VBT و ساستاموینن است، اما بیشتر از مدل‌های ECMWF و GPT3 است. در این مدل، پارامترهای توابع



شکل ۶. مقایسه RMSE (mm) حاصل برای مدل‌های ANN، GRNN، VBT، ECMWF، GPT3 و ساستاموین در ۱۵ روز مورد بررسی و در محل ایستگاه رادیوسوند تبریز (الف) و رادیوسوند تهران (ب).

میانگین خطای RMSE محاسبه شده در محل ایستگاه رادیوسوند تبریز برای مدل‌های ANN، GRNN، VBT، ECMWF، ساستاموین و GPT3 به ترتیب برابر با ۱/۸۲، ۱/۶۰، ۱/۹۳، ۲/۰۹، ۶/۲۲ و ۴/۵۱ میلی‌متر است. در ایستگاه رادیوسوند تهران، میانگین خطای RMSE محاسبه شده برای مدل‌های ANN، GRNN، VBT، ECMWF، ساستاموین و GPT3 به ترتیب برابر با ۱/۷۶، ۱/۵۴، ۲/۱۱، ۲/۵۱، ۶/۳۴ و ۴/۷۱ میلی‌متر شده است. با توجه به اینکه در ایستگاه رادیوسوند تهران مرحله کالیبراسیون قبل از پرتاب به صورت کامل انجام گرفته است، در نتیجه خطای مدل‌های ANN، GRNN و VBT نسبت به ایستگاه رادیوسوند تبریز کمتر شده است.

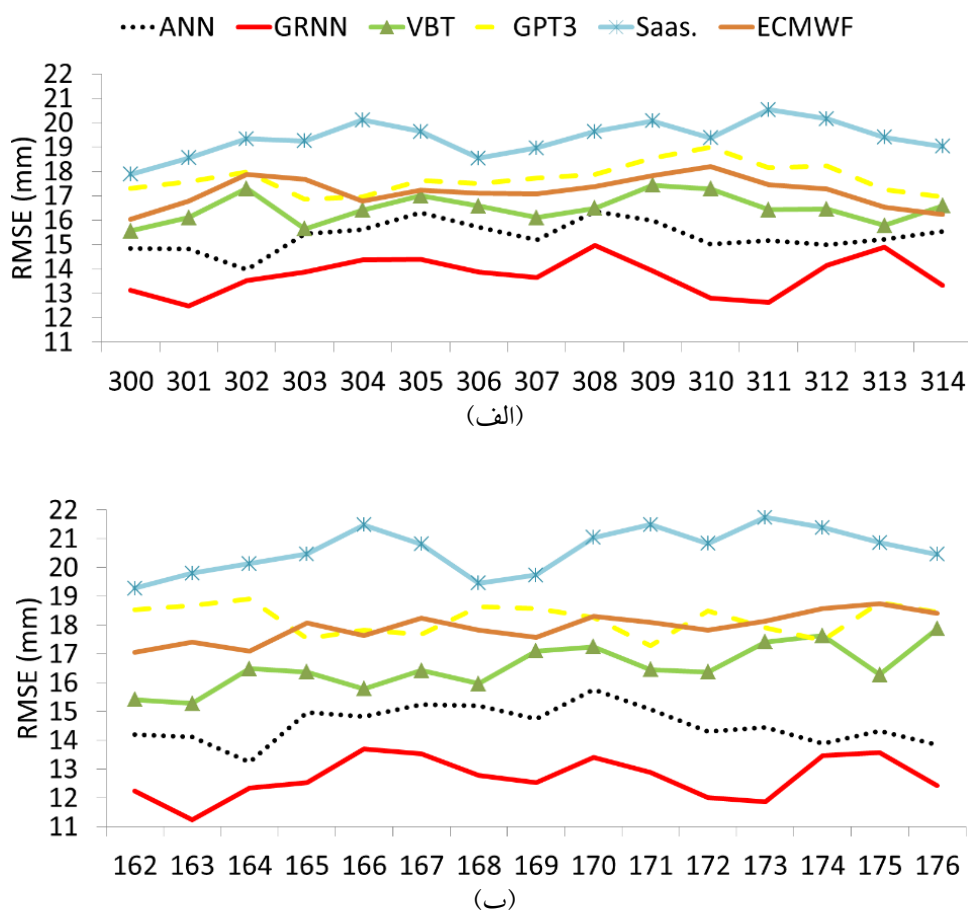
آنالیز دیگر انجام گرفته ارزیابی تأثیر مدل‌سازی PWV بر تعیین موقعیت به روش PPP است. در موقعیت ایستگاه‌های کنترل داخلی هر دو شبکه مورد مطالعه، مقادیر PWV با استفاده از مدل‌های مختلف برآورد شده و

با توجه به نتایج شکل (۶)، خطای RMSE مدل‌های ECMWF، ساستاموین و GPT3 ارزیابی شده در ۱۵ روز و در هر دو شبکه مورد مطالعه بیشتر از مدل‌های دیگر است. این سه مدل تجربی هستند و اگر پارامترهای هواشناسی با دقت بالا به این دو مدل معرفی نشوند، دقت آن‌ها پایین خواهد بود. مقایسه مدل‌های ANN، GRNN و VBT نیز نشان می‌دهد که مدل GRNN در هر دو شبکه مورد بررسی از دقت بالاتری نسبت به دو مدل دیگر برخوردار است. لازم به ذکر است که برای رادیوسوند مرحله کالیبراسیون قبل از پرتاب انجام می‌شود. در این مرحله، سنسورهای مختلف رادیوسوند کالیبره می‌شوند؛ بنابراین، اگر این مرحله به درستی انجام نشود، روی نتایج رادیوسوند تأثیرگذار خواهد بود. طبق گزارش حاصل از ایستگاه رادیوسوند تبریز، در روزهای ۳۰۱، ۳۰۲ و ۳۱۰ مرحله کالیبراسیون به صورت کامل انجام نگرفته است؛ بنابراین نتایج این سه روز برای مدل‌ها قابل اعتماد نیست.

سپس با استفاده از معادله (۲) به ZWD تبدیل می‌شوند. همچنین کمیت ZHD نیز با استفاده از رابطه (۱) محاسبه می‌شود. با جمع کمیت‌های ZHD، ZTD و ZWD به دست می‌آید. مشاهدات Rinex دو ایستگاه کنترل داخلی با استفاده از ZTD به دست آمده تصحیح می‌شوند. سپس مختصات دو ایستگاه کنترل داخلی با استفاده از مشاهدات تصحیح شده و تعیین موقعیت دقیق تک فرکانسه برآورد می‌شوند. همچنین مختصات دقیق ایستگاه‌های کنترل با استفاده از نرم‌افزار برنیز و روش PPP محاسبه می‌شود. این دو مختصات با همدیگر مقایسه شده و خطای RMSE میانگین برای ایستگاه‌های کنترل داخلی هر دو شبکه در

شکل (۷) ارائه شده است.

بر اساس نتایج حاصل از شکل (۷) خطای تعیین موقعیت با مدل GRNN در هر دو شبکه مورد مطالعه کمتر از مدل‌های دیگر است. همچنین، مدل‌های ساستاموینز، ECMWF و GPT3 در تعیین موقعیت خطای بالایی دارند. نتایج این سه مدل به مشاهدات هواشناسی بستگی دارد؛ بنابراین در صورت عدم معرفی دقیق پارامترهای هواشناسی به این سه مدل، خطای زیادی حاصل خواهد شد. با استفاده از مدل GRNN بهبودی به اندازه ۱ الی ۷/۵ میلی‌متر در خطای تعیین موقعیت نسبت به سایر مدل‌ها در هر دو شبکه حاصل می‌شود.



شکل ۷. خطای RMSE (mm) سه بعدی (میانگین RMSE سه مؤلفه مختصاتی) برای مدل‌های ANN، GRNN، VBT، ECMWF و GPT3 و ساستاموینز در ۱۵ روز مورد بررسی و به صورت میانگین برای دو ایستگاه کنترل داخلی در شبکه شمال غرب (الف) و دو ایستگاه کنترل داخلی در شبکه البرز مرکزی (ب).



پارامترهای ورودی در شبکه شمال غرب نشان می‌دهد. با توجه به نتایج مشابه در شبکه البرز مرکزی، نتایج این شبکه در این قسمت ارائه نشده است. در جدول (۲)، عدد ۵ نشان‌دهنده ۵ پارامتر اصلی عرض جغرافیایی، طول جغرافیایی، ارتفاع، DOY و زمان است.

تجزیه و تحلیل حساسیت مدل‌ها نشان می‌دهد که پارامترهای دما و فشار تأثیر تقریباً مشابهی بر PWV برآورد شده با دو مدل دارند؛ اما تأثیر پارامتر رطوبت نسبی در مدل‌سازی PWV بیشتر از دو پارامتر دیگر است. محاسبه ضریب همبستگی بین PWV با ۳ پارامتر دما، فشار و رطوبت نسبی نشان می‌دهد که مقدار این ضریب برای پارامتر رطوبت نسبی از دو پارامتر دیگر بیشتر است. ترکیب پارامترهای فشار و رطوبت نسبی با ۵ پارامتر دیگر، RMSE مدل‌ها را تا حد زیادی کاهش می‌دهد. به عبارت دیگر پارامترهای رطوبت نسبی، فشار و دما به ترتیب تأثیر بیشتری بر خروجی دو مدل ANN و GRNN دارند.

#### ۳-۴. آنالیز حساسیت مدل‌های ANN و GRNN نسبت به پارامترهای ورودی

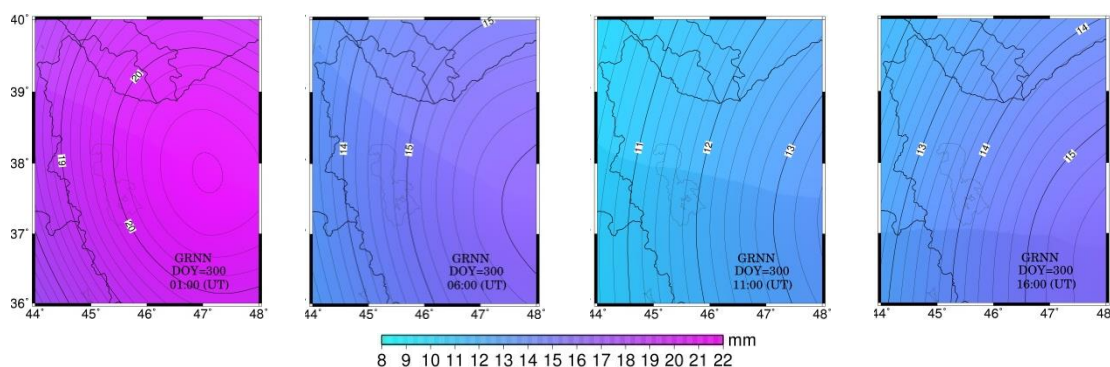
پس از ارزیابی دقت مدل‌های ANN و GRNN، حساسیت این دو مدل به پارامترهای ورودی مورد تجزیه و تحلیل قرار می‌گیرد. ۵ پارامتر اول عرض جغرافیایی ( $\varphi$ )، طول جغرافیایی ( $\lambda$ ) و ارتفاع (h) ایستگاه‌های GPS، DOY، زمان (min)، به عنوان پارامترهای ورودی اصلی مدل‌ها در نظر گرفته می‌شوند. طبق تحقیقات گسترده، PWV با این ۵ پارامتر ارتباط مستقیم دارد. به عبارت دیگر، تغییرات PWV به این ۵ پارامتر بستگی دارد (غفاری رزین و اینیورت، ۲۰۲۲). در نتیجه، حساسیت مدل جدید به پارامترهای دما (T)، فشار (P) و رطوبت نسبی (RH) تجزیه و تحلیل می‌شود. ترکیبات مختلفی از پارامترهای ورودی در موقعیت ایستگاه‌های کنترل داخلی در هر دو شبکه مورد مطالعه تجزیه و تحلیل شده و خطای دو مدل محاسبه شده است. جدول (۲) نتایج تجزیه و تحلیل حساسیت دو مدل ANN و GRNN را نسبت به

جدول ۲. آنالیز حساسیت مدل‌های ANN و GRNN نسبت به پارامترهای ورودی در دو ایستگاه کنترل داخلی.

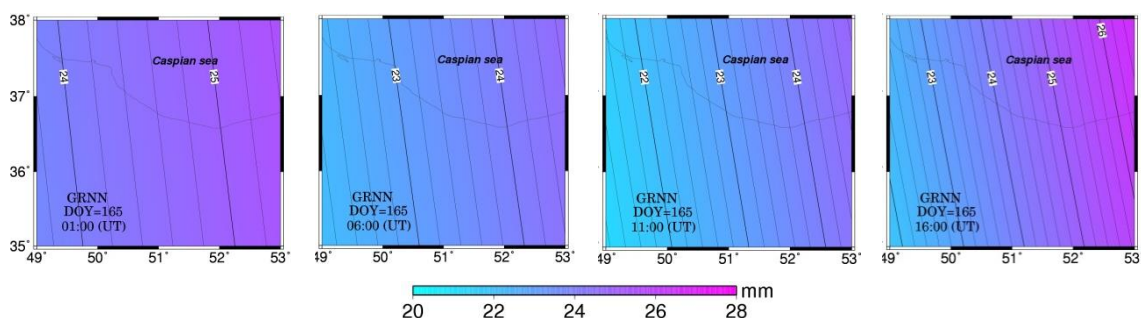
| ایستگاه کنترل داخلی<br>MNDB |         | ایستگاه کنترل داخلی<br>VLDN |         | ترکیبات پارامترهای مختلف                 |
|-----------------------------|---------|-----------------------------|---------|--|
| مدل GRNN                    | مدل ANN | مدل GRNN                    | مدل ANN |  |
| ۴/۰۹                        | ۴/۹۳    | ۳/۳۵                        | ۳/۸۹    | ۵ پارامتر اصلی                           |
| ۳/۷۹                        | ۴/۶۱    | ۳/۰۵                        | ۳/۵۲    | ۵ پارامتر اصلی + دما                     |
| ۳/۶۱                        | ۴/۵۰    | ۲/۹۸                        | ۳/۴۰    | ۵ پارامتر اصلی + فشار                    |
| ۳/۳۷                        | ۴/۱۱    | ۲/۵۶                        | ۳/۱۱    | ۵ پارامتر اصلی + رطوبت نسبی              |
| ۳/۱۲                        | ۳/۸۵    | ۲/۳۱                        | ۲/۹۹    | ۵ پارامتر اصلی + فشار + دما              |
| ۲/۵۱                        | ۳/۱۵    | ۱/۹۸                        | ۲/۴۵    | ۵ پارامتر اصلی + دما + رطوبت نسبی        |
| ۲/۴۰                        | ۲/۹۵    | ۱/۹۴                        | ۲/۳۶    | ۵ پارامتر اصلی + فشار + رطوبت نسبی       |
| ۲/۳۵                        | ۲/۸۳    | ۱/۹۳                        | ۲/۳۱    | ۵ پارامتر اصلی + فشار + دما + رطوبت نسبی |

۵. برآورد مکانی-زمانی بخار آب قابل بارش پس از تجزیه و تحلیل دقت مدل‌های ANN، GRNN، GPT3، VBT و ساستاموینن در ایستگاه رادیوسوند و ایستگاه‌های کنترل داخلی و خارجی، حال می‌توان از این مدل‌ها برای برآورد PWV در دو منطقه مورد مطالعه استفاده کرد. با توجه به آنالیزهای انجام گرفته مدل GRNN از همه مدل‌ها دقیق‌تر است؛ بنابراین، جهت اختصار تنها مقدار بخار آب قابل بارش به دست آمده با این مدل در اشکال (۸) و (۹) نمایش داده شده است. همچنین اشکال ترسیم شده مربوط به دو روز ۳۰۰ (شبکه شمال غرب) و ۱۶۵ (شبکه البرز مرکزی) و زمان‌های ۱، ۶، ۱۱ و ۱۶ به وقت جهانی می‌باشند. در اشکال (۸) و (۹)، منحنی‌ها نشان‌دهنده تغییرات PWV هستند. تغییرات افقی و وابسته به زمان در PWV به وضوح در نتایج این دو شکل قابل مشاهده است. مقدار PWV در

۰۱ و ۱۶ UTC بزرگ‌تر از زمان‌های دیگر است. نکته مهمی که در شکل مشاهده می‌شود این است که مقدار PWV از شمال غرب به شمال شرق در شبکه شمال غرب افزایش یافته است. این مورد در شبکه البرز مرکزی نیز قابل مشاهده است. به طور معمول ابرهای بارشی از شمال غرب (دریای مدیترانه و دریای سیاه) وارد ایران می‌شود. میزان بارندگی در مناطق کوهستانی ایران (شمال غرب) معمولاً بیشتر از شمال شرق است. مسیر افزایش مقادیر منحنی‌ها از شمال غرب به شمال شرق بوده و با شرایط اقلیمی واقعی منطقه سازگاری دارد. با تجزیه و تحلیل رطوبت نسبی و میزان PWV می‌توان به بحث بارش سطحی و وقوع سیل در یک منطقه پرداخت. نتایج اشکال (۸) و (۹) نشان می‌دهد که مدل GRNN از دقت و اطمینان بالایی برای تجزیه و تحلیل مقدار PWV برخوردار است.



شکل ۸. تغییرات زمانی-مکانی بخار آب قابل بارش برآورد شده توسط مدل GRNN در محدوده شبکه شمال غرب در روز ۳۰۰ و زمان‌های ۱، ۶، ۱۱ و ۱۶ به وقت جهانی.



شکل ۹. تغییرات زمانی-مکانی بخار آب قابل بارش برآورد شده توسط مدل GRNN در محدوده شبکه البرز مرکزی در روز ۱۶۵ و زمان‌های ۱، ۶، ۱۱ و ۱۶ به وقت جهانی.

## ۶. بحث و نتیجه گیری

هدف این مقاله مدل سازی و پیش بینی مقدار بخار آب قابل بارش (PWV) با استفاده از مدل شبکه عصبی رگرسیون عمومی (GRNN) بود. برای انجام این کار، اندازه گیری های دو شبکه شمال غرب و البرز مرکزی مورد آنالیز و بررسی قرار گرفت. در شبکه شمال غرب از مشاهدات ۲۳ ایستگاه GPS در بازه زمانی روزهای ۳۰۰ تا ۳۱۴ (فصل زمستان) در سال ۲۰۱۱ استفاده شد. همچنین در شبکه البرز مرکزی مشاهدات ۱۱ ایستگاه GPS در بازه زمانی روزهای ۱۶۲ الی ۱۷۶ (فصل تابستان) بکار گرفته شد. دلیل انتخاب این دو بازه زمانی برای تجزیه و تحلیل نتایج، در دسترس بودن مجموعه کاملی از مشاهدات ایستگاه های GPS، ایستگاه رادیوسوند و ایستگاه های هواشناسی بود. از بین ۲۳ ایستگاه شبکه شمال غرب، ایستگاه های MNDB و VLDN به عنوان ایستگاه های کنترل داخلی انتخاب شدند. در شبکه البرز مرکزی دو ایستگاه TEHN1 و TKBN به عنوان ایستگاه کنترل داخلی استفاده شدند. مشاهدات این ایستگاه ها از مرحله آموزش حذف شدند. همچنین ایستگاه ARUC به عنوان ایستگاه کنترل خارج از شبکه انتخاب شد. در مرحله اول، تأخیر زینتی تروپوسفر (ZTD) و تأخیر زینتی هیدروستاتیکی (ZHD) به ترتیب با نرم افزار برنیز و مدل تجربی ساستاموینن که توسط دیویس بازیینی شده است، محاسبه شد. در مرحله بعد ZHD از ZTD کم شده و تأخیر تر زینتی (ZWD) محاسبه شد. کمیت ZWD به دست آمده با استفاده از فرمول Bevis به مقدار PWV تبدیل شد. با استفاده از ۸ پارامتر ورودی عرض، طول و ارتفاع ایستگاه های GPS، DOY، زمان، رطوبت نسبی، دما و فشار و همچنین پارامتر خروجی PWV، مدل جدید آموزش داده شد. پس از مرحله آموزش، مقدار PWV با استفاده از مدل GRNN برآورد و در ایستگاه رادیوسوند تبریز، ایستگاه رادیوسوند تهران و همچنین ایستگاه های کنترل داخلی و یک ایستگاه خارجی مورد ارزیابی قرار گرفت. همچنین تمامی نتایج به دست آمده با مدل شبکه

عصبی مصنوعی (ANN)، توموگرافی المان های حجمی (VBT)، مدل ECMWF، مدل تجربی GPT3 و مدل تجربی ساستاموینن مقایسه شد.

میانگین ضریب همبستگی محاسبه شده برای مدل های ANN، GRNN، VBT، ECMWF، GPT3 و ساستاموینن در ایستگاه های کنترل داخلی شبکه شمال غرب به ترتیب ۰/۸۰، ۰/۸۲، ۰/۷۶، ۰/۷۳، ۰/۷۲ و ۰/۶۸ به دست آمد. همچنین میانگین RMSE مدل ها در دو ایستگاه کنترل داخلی این شبکه به ترتیب ۲/۵۷، ۲/۱۴، ۳/۳۲، ۳/۶۳، ۶/۳۱، ۴/۳۵ میلی متر حاصل شد. برای شبکه البرز مرکزی، میانگین ضریب همبستگی دو ایستگاه داخلی به ترتیب برابر با ۰/۸۱، ۰/۸۴، ۰/۷۷، ۰/۷۳، ۰/۷۳ و ۰/۶۹ حاصل شد. همچنین، میانگین RMSE مدل ها در ایستگاه های کنترل داخلی این شبکه به ترتیب برابر با ۲/۴۲، ۲/۰۱، ۳/۲۴، ۳/۲۶، ۴/۰۶ و ۶/۰۱ میلی متر به دست آمد. تجزیه و تحلیل خطا در ایستگاه های کنترل داخلی دو شبکه و ایستگاه های رادیوسوند تبریز و تهران نشان داد که مدل GRNN دقت بالاتری در برآورد تغییرات مکانی-زمانی PWV نسبت به مدل های دیگر دارد. تجزیه و تحلیل نتایج ایستگاه کنترل خارجی نشان داد که دقت مدل GRNN از مدل های ANN، VBT و ساستاموینن بیشتر است. خطای مدل GRNN در ایستگاه کنترل ARUC تقریباً ۲۵ الی ۵۰ درصد بیشتر از ایستگاه های کنترل داخلی در هر دو شبکه مورد مطالعه است. پارامترهای توابع پایه شعاعی در لایه الگو با استفاده از مشاهدات شبکه GPS بهینه می شوند. این پارامترها برای محدوده شبکه GPS مورد مطالعه، معتبر هستند. با دور شدن از محدوده شبکه، دقت این پارامترها تا حد زیادی کاهش می یابد. آنالیز حساسیت مدل های ANN و GRNN نشان داد که پارامترهای رطوبت نسبی، فشار و دما به ترتیب در اولویت قرار دارند.

نتایج این مطالعه نشان داد که مدل GRNN از قابلیت بسیار بالایی در مدل سازی و پیش بینی تغییرات مکانی-زمانی PWV در فصول زمستان و تابستان برخوردار است. تجزیه و تحلیل ها نشان داد که دقت این مدل در محدوده

موسوی، ز.، خرمی، ف.، نانکلی، ح.ر. و جموری، ی. (۱۳۸۶). تعیین مقدار بخار آب موجود در جو با استفاده از تخمین تأخیر وردسپهری سیگنال‌های جی‌پی‌اس در شبکه ژئودینامیک سراسری ایران، همایش ژئوماتیک ۱۳۸۶.

خسروی، م.، حسینی، ا. و قاسمی، ج. (۱۳۹۹). ارزیابی عملکرد منابع انسانی با رویکرد شبکه عصبی رگرسیون عمومی مورد مطالعه: اعضای هیات علمی. دو فصلنامه مطالعات برنامه‌ریزی آموزشی، ۹(۱۷)، ۲۰۲-۲۲۲.

غفاری رزین، س.ر. (۱۳۹۹). ارزیابی کارایی سامانه استنتاج عصبی-فازی سازگار در مدل‌سازی بخار آب مایل وردسپهر. مجله فیزیک زمین و فضا، ۴۷(۲)، ۲۵۷-۲۷۲.

- Aster, R., Borchers, B., & Thurber, C. (2003). *Parameter estimation and inverse problems*, Elsevier Academic Press, USA.
- Adavi, Z., & Mashhadi-Hossainali, M. (2015). 4D-tomographic reconstruction of water vapor using the hybrid regularization technique with application to the North West of Iran. *Advances in Space Research*, 55(7), 1845-1854.
- 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, 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.
- 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.
- Dach, R., Hugentobler, U., Fridez, P., & Meindl, M. (2007). Bernese GPS Software Version 5.0. Astronomical Institute, University of Bern, Bern.

شبکه GPS بسیار بالا است. نتایج این مقاله همچنین نشان داد که همبستگی بسیار بالایی بین تغییرات PWV و رطوبت نسبی وجود دارد. با تعیین دقیق PWV می‌توان میزان بارش سطحی را پیش‌بینی کرد. نتایج این مقاله می‌تواند برای تولید یک سیستم هشدار بارش سطحی آبی در صورتی که داده‌های ایستگاه GPS به صورت آنلاین در دسترس باشد، مورد استفاده قرار گیرد.

#### منابع

- حاجی آقاجانی، س. و وثوقی، ب. (۱۳۹۵). مقایسه داده‌های بازتحلیل ERA-Interim و حسگر MERIS در کاهش اثر لایه وردسپهر موجود در میدان‌های سرعت جابه‌جایی تداخل‌سنجی راداری. *مجله فیزیک زمین و فضا*، ۴۲(۳)، ۶۰۷-۶۱۸.
- European centre for Medium-Range Weather Forecasts (ECMWF) 2005, 2013, User Guide European center for Medium-Range Weather Forecasts (ECMWF), User Guide.
- Foorotan, 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. (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, 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. (2020). Estimation of tropospheric wet refractivity using tomography method and artificial neural networks in Iranian case study. *GPS Solutions* 24(3), 1-14.
- Ghritlahre, H., & Prasad, R. (2018). Investigation of thermal performance of unidirectional flow porous bed solar air heater using MLP, GRNN, and RBF models of ANN technique. *Thermal Science and Engineering Progress*. [doi:https://doi.org/10.1016/j.tsep.2018.04.006](https://doi.org/10.1016/j.tsep.2018.04.006).

- 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>.
- 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.
- Haykin, S. (1994). *Neural Networks, a comprehensive Foundation*, Macmillan College Publishing Company, New York, 1994.
- Kim, B., Lee, D.W., Park, K.Y., Choi, S.R., & Choi, S. (2004). Prediction of plasma etching using a randomized generalized regression neural network. *Vacuum*, 76(1), 37-43. <https://www.ncc.gov.ir>
- Landskron, D., & Böhm, J. (2017). VMF3/GPT3: refined discrete and empirical troposphere mapping functions. *Journal of Geodesy*, 92(4), 349-360.
- Masikos, M., Demestichas, K., Adamopoulou, E., & Theologou, M. (2015). Mesoscopic forecasting of vehicular consumption using neural networks. *Soft Computing*, 19(1), 145-156.
- Rohm, W., & Bosy, J. (2011). The verification of GNSS tropospheric tomography model in a mountainous area. *Adv. Space Res.*, 47(10), 1721-1730
- 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.
- Sam Khaniani, A., Azadi, M., & Zakeri, Z. (2017). Impact of Iranian permanent GPS network precipitable water estimates on numerical weather prediction. *Earth Observation and Geomatics Engineering*, 1(2), 100-111.
- 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.
- 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.
- Sadeghi, E., Hossainali, M., & Etemadfard, H. (2014). Determining precipitable water in the atmosphere of Iran based on GPS zenith tropospheric delays. *Annals of geophysics*, 57(4), 12-27.
- Saastamoinen, J. (1973). Contributions to the theory of atmospheric refraction. Part II: refraction corrections in satellite geodesy. *Bull. Geod.*, (107), 13-34.
- Specht, D. F. (1991). A general regression neural network. *IEEE Transactions on Neural Networks*, 2(6), 568-576.
- 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.
- Yao, Y., Liu, C., Xu, C., Tan, Y., & Fang, M. (2020). A Refined Tomographic Window for GNSS-Derived Water Vapor Tomography. *Remote Sens.* 12(18), 1-15. doi:10.3390/rs12182999.
- 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.
- Yao, Y., Xin, L., & Zhao, O. (2019). An improved pixel-based water vapor tomography model. *Ann. Geophys.*, (37), 89-100.
- 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., Du, Z., Yao, W., & Yao, Y. (2020). Hybrid precipitable water vapor fusion model in China. *Journal of Atmospheric and Solar-Terrestrial Physics*, 208(2020), 1-13. <https://doi.org/10.1016/j.jastp.2020.105387>.
- 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.
- Zheng, D., Hu, Y., Wang, W.S.J., & Zhu, M. C.

(2015). Research on regional zenith tropospheric delay based on neural network technology. *Survey Review*, 47(343), 286-295.