



Efficiency of the Least Squares Support Vector Regression in local modeling of the ionosphere Total Electron Content and comparison with other models

Tania Mansour Fallah¹, Behzad Voosoghi², and Seyyed Reza Ghaffari-Razin^{3*}

1. M.Sc. Student, Faculty of Geodesy & Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran
2. Professor, Faculty of Geodesy & Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran
3. Associate Professor, Department of Surveying Engineering, Arak University of Technology, Arak, Iran

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

ABSTRACT

In this paper, the aim is to use the least squares support vector regression (LS-SVR) for spatio-temporal modeling of the ionospheric total electron content (TEC). In this model, simple linear equations are used to solve the system of equations. As a result, the complexity of the computational algorithm is reduced and the speed of convergence and the accuracy of the results are increased. In order to do this, the observations of 15 GPS stations in the north-west of Iran have been used in the period from 193 to 228 at 2012. Comparing the results of the new model with support vector regression (SVR), artificial neural network (ANN), adaptive neuro-fuzzy inference system (ANFIS), Kriging model, GIM and international reference ionosphere 2016 (IRI2016) as well as TEC obtained from GPS. The accuracy of all models has been evaluated and interpreted at interior and exterior control stations. The analyzes performed show that the averaged root mean square error (RMSE) of ANN, ANFIS, SVR, LS-SVR, Kriging, GIM and IRI2016 models in two interior control stations are 3.91, 2.73, 1.27, 1.04, 2.70, 3.02 and 6.93 TECU, respectively. Also, the averaged relative error of the models in two interior control stations was calculated as 15.98%, 9.39%, 7.85%, 6.09%, 11.60%, 12.54% and 26.56%, respectively. Analysis of the PPP method shows an improvement of 50 mm in the coordinate components using the LS-SVR model. The results of this paper show that the LS-SVR model can be considered as an alternative to global and empirical models of the ionosphere in the study area. The LS-SVR model is a high-precision local ionosphere model.

Keywords: Ionosphere, TEC, GPS, Northwest of Iran, machine learning, LS-SVR

1. Introduction

The ionosphere is one of the layers of the earth's atmosphere that has destructive effects on electromagnetic waves. In order to investigate these effects, the total electron content (TEC) of the ionosphere is studied. Usually, TEC is measured along the line of sight from the satellite to the receiver on the

ground [1]. Therefore, due to the limitation of the number of ground stations, there will be discontinuity of observations in space and time domain for TEC. To overcome this problem, the value of TEC can be interpolated or extrapolated. So far, there have been various methods for this. Machine learning models are relatively new methods that have been used in various



COPYRIGHTS

© 2024 by the authors. Published by Aerospace Research Institute. This article is an open access article distributed under the terms and conditions of [the Creative Commons Attribution 4.0 International \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)

How to cite this article:

T. Mansour Fallah, B. Voosoghi, and S. R. Ghaffari-Razin " Efficiency of the Least Squares Support Vector Regression in Local Modeling of the Ionosphere Total Electron Content and Comparison with other Models," *Journal of Space Science and Technology*, vol.17, no. 1, pp. 21-36, 2024 (in Persian).

fields of geodesy. In this paper, the aim is to use the Least Squares Support Vector Regression (LS-SVR) model for spatio-temporal modeling of TEC. In this model, simple linear equations are used to solve the system of equations. As a result, the complexity of the computational algorithm is reduced and as a result, the speed of convergence and the accuracy of the results are increased.

2. Materials and Methods

Support vector machine is a kind of efficient learning system based on the theory of constrained optimization. In this model, the principle of structural error minimization is used and leads to a general optimal solution. In this model, dual programming is used to solve the equations [2]. Therefore, solving problems in large dimensions greatly increases the computational cost. To solve this problem, Sukens et al. 2002 proposed the least squares support vector regression (LS-SVR) method [3]. In this model, simple linear equations are used to solve a problem, which effectively reduces the complexity of the algorithm. However, a prerequisite for SVR to achieve better results is to find three suitable user-defined parameters. In LS-SVR, there are only two user-defined parameters. These user-defined parameters play a key role in building a highly accurate regression model with good generalization performance. The LS-SVR model is actually a reformulation of the SVR model. LS-SVR algorithm can identify higher stability and learn faster than SVR.

3. Results and Discussion

In this paper, the aim is to use the least squares support vector regression (LS-SVR) for spatio-temporal modeling of the ionospheric total electron content (TEC). In this model, simple linear equations are used to solve the system of equations. As a result, the complexity of the computational algorithm is reduced and as a result, the speed of convergence and the accuracy of the results are increased. In order to do this, the observations of 15 GPS stations in the north-west of Iran have been used in the period from 193 to 228 at 2012. Comparing the results of the new model with support vector regression (SVR), artificial neural network (ANN), adaptive neuro-fuzzy inference system (ANFIS), Kriging model, GIM and international reference ionosphere 2016 (IRI2016) as well as TEC obtained from GPS. The accuracy of all models has been evaluated and interpreted at interior and exterior control stations. The analyzes performed show that the averaged RMSE of ANN, ANFIS, SVR, LS-SVR, Kriging, GIM and IRI2016 models in two interior control stations are 3.91, 2.73, 1.27, 1.04, 2.70, 3.02 and 6.93 TECU, respectively. Also, the averaged relative error of the models in two interior control stations was calculated as 15.98, 9.39, 7.85, 6.09, 11.60, 12.54

and 26.56%, respectively. Analysis of the PPP method shows an improvement of 50 mm in the coordinate components using the LS-SVR model. The results of this paper show that the LS-SVR model can be considered as an alternative to global and empirical models of the ionosphere in the study area. The LS-SVR model is a high-precision local ionosphere model.

4. Conclusion

Error analysis in interior control stations showed that the LS-SVR model has higher accuracy in estimating the spatio-temporal variations of vertical total electron content (VTEC) than other models. Also, the results of the analyzes showed that the error of the machine learning models was higher in the KLBR control station respect to the TABZ control station. The reason for this was that the TABZ station was surrounded by training stations. The analysis of the results of the control stations outside the studied network showed that the accuracy of the LS-SVR model is higher than other models. The error of the LS-SVR model at TEHN exterior control station is higher than ARUC. In other words, the error of machine learning models increases when move away from the GPS network territory. Also, if the observations of exterior control stations are used in the training step, the error of the models will be less. Also, the time series analysis of VTEC predicted with the new model showed that this model has the ability to predict the VTEC value with an error of about 1.89 TECU. The results of this paper showed that the LS-SVR model has a very high capability in modeling and predicting spatio-temporal variations in VTEC. The analyzes showed that the accuracy of this model is very high in the territory of the GPS network. By moving away from the GPS network territory, the accuracy of the model decreases. But the accuracy of the new model in the exterior control stations is higher than the GIM and IRI2016 models. This model is a local ionosphere model and has high accuracy and computational speed.

5. Reference

- [1] G. Seeber, "Satellite geodesy: foundations, methods, and applications". Walter de Gruyter, New York, p. 53, <https://doi.org/10.1515/9783110200089>.
- [2] V. Vapnik, S. Golowich, A.J. Smola, "Support vector method for function approximation, regression estimation, and signal processing". *Adv. Neural Info. Process. Syst.* 9, 281–287.
- [3] J. Suykens, T. Van Gestel, J. De Brabanter, B. De Moor, J. Vandewalle, "Least squares Support Vector Machines". <https://doi.org/10.1142/5089>.



ارزیابی کارایی مدل کمترین مربعات رگرسیون بردار پشتیبان در مدل‌سازی محلی محتوای الکترون کلی یونسfer و مقایسه آن با سایر مدل‌ها

تانيا منصورفلاح^۱، بهزاد وثوقی^۲ و سیدرضا غفاری‌رزین^{۳*}

۱- دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

۲- دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

۳- گروه مهندسی عمران و نقشه‌برداری، دانشگاه صنعتی اراک، اراک، ایران

*ایمیل نویسنده مخاطب: mr.ghafari@arakut.ac.ir

در این مقاله هدف استفاده از مدل کمترین مربعات رگرسیون بردار پشتیبان (*LS-SVR*) جهت مدل‌سازی مکانی-زمانی مقدار محتوای الکترون کلی یونسfer (*TEC*) است. جهت انجام این کار، از مشاهدات ۱۵ ایستگاه *GPS* موجود در منطقه شمال غرب ایران در بازه زمانی روزهای ۱۹۳ الی ۲۲۸ از سال ۲۰۱۲ استفاده شده است. مقایسه نتایج مدل جدید با مدل‌های رگرسیون بردار پشتیبان (*SVR*)، مدل شبکه عصبی مصنوعی (*ANN*)، مدل استنتاج عصبی-فازی سازکار (*ANFIS*)، مدل کریجینگ، مدل *GIM*، مدل تحریبی بین‌المللی مرجع یونسfer ۲۰۱۶ (*IRI2016*) و همچنین مقادیر *TEC* حاصل از *GPS* به عنوان مشاهده مرجع انجام می‌گیرد. دقت همه مدل‌ها در ایستگاه‌های کنترل داخلی و خارجی ارزیابی و تفسیر شده است. آنالیزهای انجام‌گرفته نشان می‌دهد که میانگین مدل‌های *RMSE* *LS-SVR* *SVR* *ANFIS* *ANN* *GIM* *Kriging* *TECU* و *IRI2016* در دو ایستگاه کنترل داخلی به ترتیب برابر با ۳/۹۱، ۳/۹۳، ۲/۷۳، ۲/۷۰، ۱/۰۴، ۱/۰۴، ۱/۲۷ و ۶/۹۳ بوده است. تجزیه و تحلیل روش *PPP* بهبود ۵ میلی‌متری در مؤلفه‌های مختصات با استفاده از مدل *LS-SVR* را نشان می‌دهد. نتایج این مقاله نشان می‌دهد که مدل *LS-SVR* را می‌توان به عنوان جایگزینی برای مدل‌های جهانی و تحریبی یونسfer در منطقه مورد مطالعه در نظر گرفت. مدل *LS-SVR* یک مدل یونسfer محلی با دقت بالا محسوب می‌شود.

واژه‌های کلیدی: یونسfer، *GPS*، *TEC*، *LS-SVR*، *ML*، *GIM*، *IRI*

علائم و اختصارات

مقدمه

لایه یونسfer^۳ قسمتی از جو زمین است که تحت تأثیر تشعشعات پر انرژی خورشیدی قرار گرفته و مواد گازی شکل موجود در آن طی فرآیند یونیزاسیون به مجموعه‌ای از یون‌های مثبت و الکترون‌های آزاد تبدیل شده است. به مواد شکل گرفته در این مجموعه، پلاسمما

GPS	سامانه تعیین موقعیت جهانی
TEC	محتوای الکترونی کلی
ML	روش‌های یادگیری ماشین
GIM	مدل یونسfer جهانی
IRI	یونسfer مرجع جهانی

۱. دانشجوی کارشناسی ارشد (نویسنده مخاطب)

۲. استاد

تکاملی (EC) است [۱۰]. از سال ۱۹۹۳، با پیشرفت فناوری رایانه، بسیاری از الگوریتم‌های جدید و ترکیبی، مانند سیستم استنتاج عصبی فازی (ANFIS) در ML توسعه یافته‌اند. در دهه‌های اخیر از روش‌های یادگیری ماشین در مدل‌سازی یونسfer و تربویونسfer فراوان استفاده شده و نتایج قابل قبولی ارائه شده است [۱۱-۲۰].

مدل‌های نهایی GIM معمولاً تا ۱۴ روز پس از جمع‌آوری داده ایستگاه‌های دائمی IGS در سراسر جهان در اختیار کاربران قرار داده می‌شود تا برای تعیین موقعیت مورد استفاده قرار گیرند. این تأخیر زمانی برای کاربردهای آنی تعیین موقعیت با استفاده از GPS مناسب نیست. از طرف دیگر مدل‌های پیش‌بینی GIM نیز اخیراً گسترش یافته‌اند، اما دقت این مدل‌ها به اندازه مدل‌های نهایی نمی‌باشد. از آنجایی که از ایستگاه‌های با پوشش جهانی در تهیه این مدل‌ها استفاده می‌شود، نمی‌توان انتظار داشت که تعییرات با فرکانس بالای زمانی که می‌تواند دارای الگوی متفاوتی در مکان‌های مختلف باشد، در این مدل‌ها بازتاب داده شود. مدل تجربی یونسfer از سوی دیگر، دارای دقت مناسبی در پیش‌بینی یونسfer نیست و نمی‌توان برای کاربردهای دقیق آنی از آن استفاده کرد. با توجه به اینکه تعییرات زمانی-مکانی یونسfer بسیار نامنظم است، می‌بایست از یک روش جدید با دقت و صحت بالاتر برای بازیابی این تعییرات استفاده نمود.

ماشین بردار پشتیبانی (SVM) یک نوع سیستم یادگیری نظارت شده است که برای مسائل طبقه‌بندی به کار می‌رود به طوری که کمترین خطا در طبقه‌بندی داده‌ها رخ دهد. این روش بر مبنای تئوری یادگیری آماری استوار است که از اصل کمینه‌سازی خطای ساختاری بهره می‌جوید و موجب یک جواب بهینه کلی می‌شود. این الگوریتم بعدها برای کار با مسائل رگرسیون یا تخمین داده‌ها توسعه یافت. الگوریتم جدید رگرسیون بردار پشتیبانی (SVR) نامیده شد [۲۱]. با این حال، روش رگرسیون بردار پشتیبان دارای معایی است. سرعت همگرایی به جواب بهینه در این مدل در تعداد زیاد مشاهدات ورودی بهشت کاهش پیدا کرده و الگوریتم کند عمل می‌کند. همچنین در صورت عدم توزیع مناسب ایستگاه‌ها، دقت این مدل بهشت کاهش می‌یابد. برای غلبه بر این محدودیت‌ها، در این مقاله ایده استفاده از مدل کمترین مربعات رگرسیون بردار پشتیبان (LS-SVR) ارائه می‌شود. مدل LS-SVR از معادلات خطی ساده برای حل سیستم معادلات استفاده می‌کند. درنتیجه، پیچیدگی الگوریتم محاسباتی کاهش می‌یابد. علاوه بر این، سرعت همگرایی و دقت نتایج افزایش خواهد داشت.

هدف اصلی این مقاله این است که مدل‌سازی زمانی-مکانی یونسfer به کمک مدل کمترین مربعات رگرسیون بردار پشتیبان و با استفاده

گفته می‌شود. محدوده ارتفاعی پوشش داده شده توسط لایه یونسfer متغیر است اما معمولاً از ارتفاع ۶۰ کیلومتری تا ۱۰۰۰ کیلومتری از سطح زمین را پوشش می‌دهد. این محدوده ارتفاعی بستر بسیاری از فعالیت‌های ارتباطی و هوافضا بوده و همچنین بر خصوصیات آب و هوا بی‌زمین نظری دما، رعد و برق و بارش تاثیرگذار است. تاثیر محاذای الکترونی لایه یونسfer بر سیگنال‌های سامانه تعیین موقعیت جهانی^۴ (GPS)، استفاده از مشاهدات این سیستم را به روشن مؤثر و کارآمد در تعیین زمانی-مکانی محاذای الکترونی کلی^۵ (TEC) و چگالی الکترونی یونسfer^۶ (IED) تبدیل کرده است. با توجه به این که TEC حاصل از مشاهدات GPS در راستای خط دید گیرنده و ماهواره به دست می‌آید، جهت تعیین مقدار TEC در تمامی نقاط لازم است که از یک روش مدل‌سازی ریاضی استفاده شود.

توسعه مدل‌های قابل اعتماد برای برآورد و پیش‌بینی تعییرات چگالی الکترونی در لایه یونسfer هنوز به عنوان یک چالش جدی برای ژئودزین‌ها و داشمندان علوم فضایی مطرح است. این امر تا حدی به دلیل رفتار غیرخطی پارامترهای فیزیکی و ژئوفیزیکی مؤثر در تعییرات چگالی الکترونی و همچنین وجود مشکل در اندازه‌گیری دقیق برخی از این پارامترها می‌باشد. علاوه بر این، تعییرات این پارامترها در حوزه زمان نیز پیچیدگی مسئله مدل‌سازی یونسfer را بیشتر می‌کند. تابش تشعشعات خورشیدی منبع دیگری است که در رفتار این لایه از جو بسیار تاثیرگذار است. با توجه به ساختار چندلایه یونسfer، امواج الکترومغناطیسی گزرنده از این لایه‌ها تحت تأثیر خاصیت پاشندگی^۷ قرار می‌گیرند. به همین جهت مدل‌سازی این لایه از جو دارای اهمیت فوق العاده‌ای است.

تاكتون تلاش‌های بسیار زیادی جهت درون‌یابی و یا برونویابی TEC در مناطقی که مشاهده کافی و یا مناسب موجود نیست، صورت گرفته است. به طور مثال می‌توان به روش‌های کربیجنگ [۱]، چندجمله‌ای، هارمونیک‌های کروی [۲]، هامونیک‌های کلاه کروی [۳]، درون‌یابی به کمک توابع اسپیلان و موجک [۴]، مدل‌سازی با توابع اسپلین [۵-۷]، توابع اتورگرسیون و اتوکوواریانس [۸]، درون‌یابی با روش المان‌های محدود C^۱ [۹] اشاره کرد. از این روش‌ها به کرات جهت تهیه و مدل‌سازی منطقه‌ای و جهانی مقدار TEC استفاده شده است. در سالیان اخیر مدل‌سازی و پیش‌بینی کمیت TEC توسط محققان و با روش‌هایی که دارای سرعت محاسباتی و دقت بالایی باشند مورد توجه قرار گرفته است. یکی از شاخه‌هایی که توانسته در زمینه تخمین و مدل‌سازی قابلیت‌های خوبی از خود نشان دهد روش‌های یادگیری ماشین^۸ (ML) هستند. یادگیری ماشین شامل سیستم استنتاج فازی (FIS)، شبکه‌های عصبی مصنوعی (ANN)، الگوریتم ژنتیک (GA)، ماشین‌های بردار پشتیبان (SVMs) و ارتباطات

9. Machine learning

10. Support vector machine

11. Support vector regression

12. Least-square support vector regression

5. Global Positioning System

6. Total Electron Content

7. Ionosphere Electron Density

8. Dispersive

مشاهدات در طول موج L2 از مشاهدات طول موج L1 به ترکیب عاری از هندسه برای مشاهده کد و فاز می‌رسیم که عبارت‌اند از [۲۴]:

$$\begin{aligned} P_{4,r}^s &= 40.3 \left(\frac{f_2^2 - f_1^2}{f_1^2 f_2^2} \right) STEC_r^s + c \left(\tau_{L1}^s - \tau_{L2}^s + \tau_{L1,r} - \tau_{L2,r} \right) \\ L_{4,r}^s &= -40.3 \left(\frac{f_2^2 - f_1^2}{f_1^2 f_2^2} \right) STEC_r^s + (T_{L1}^s - T_{L2}^s + T_{L1,r} - T_{L2,r}) + \lambda_1 N_1 - \lambda_2 N_2 \end{aligned} \quad (1)$$

همان‌طور که در روابط (۱) و (۲) ملاحظه می‌شود برای محاسبه STEC با استفاده از مشاهدات ترکیب عاری از هندسه از مشاهدات کد، نیاز به معلوم بودن بایاس‌های ناشی از فرکانس برای گیرنده و ماهواره می‌باشد و برای استفاده از مشاهدات فاز بهمنظور محاسبه STEC نیز پارامترهای مجهول ایهام فاز می‌بایست پارامترهای بایاس وابسته به فرکانس گیرنده و ماهواره تعیین شده باشد. ترم‌های مربوط به بایاس وابسته به فرکانس برای گیرنده و ماهواره برای مشاهده کد به صورت زیر خلاصه می‌شوند:

$$\tau_{L1}^s - \tau_{L2}^s = bs \quad (3)$$

$$\tau_{L1,r} - \tau_{L2,r} = br \quad (4)$$

$$T_{L1,r} - T_{L2,r} = Br \quad (5)$$

$$T_{L1}^s - T_{L2}^s = Bs \quad (6)$$

به پارامترهای bs و br به ترتیب بایاس تفاضلی کد^{۱۹} (DCB) برای ماهواره s و گیرنده r و به پارامترهای Bs و Br به ترتیب بایاس تفاضلی فاز برای ماهواره s و گیرنده r گفته می‌شود. مقدار bs برای کلیه ماهواره‌های GPS از سوی سرویس IGS در فایل‌های مدل جهانی GIM در اختیار قرار می‌گیرند. مقادیر DCB گیرنده‌ها در مرحله پیش‌پردازش مشاهدات و در نرم‌افزار یونولوب^{۲۰} محاسبه شده است.

کمترین مربuat ماشین بردار پشتیبان

ماشین بردار پشتیبان نوعی سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی محدود است. در این مدل از اصل استقرای کمینه‌سازی خطای ساختاری استفاده و به یک جواب بهینه کلی منجر می‌شود. در این مدل برای حل معادلات از برنامه‌ریزی دوگانه^{۲۱} استفاده می‌شود [۲۵]: بنابراین، حل مسائل در ابعاد بزرگ با استفاده از مدل یادشده، هزینه محاسباتی را بهشدت افزایش می‌دهد. برای رفع این مشکل، سوکتز و همکاران [۲۶]، روش کمترین مربuat رگرسیون بردار پشتیبان (LS-SVR) را ارائه کردند. در این مدل از معادلات خطی ساده برای حل مسائل استفاده می‌شود که به طور مؤثری پیچیدگی

از مشاهدات چندین ایستگاه GPS منطقه شمال غرب ایران صورت گرفته و دقت آن در پیش‌بینی تغییرات روزانه، ماهیانه و فصلی TEC مورد ارزیابی و تحلیل قرار گیرد. همچنین اثر استفاده از این مدل سازی در دقت تعیین موقعیت مطلق نیز مورد بررسی قرار خواهد گرفت. در حقیقت نوآوری اصلی این مقاله در استفاده توأم متغیرهای مکانی، زمانی، خورشیدی و ژئومغناطیسی در مرحله مدل سازی و ارزیابی نتایج در حالت‌های مختلف می‌باشد. همچنین مدل سازی و پیش‌بینی مقدار TEC روزانه از دیگر نوآوری‌های این مقاله است. جهت نشان دادن دقت و صحت بالاتر مدل جدید ارائه شده و همچنین بهمود اتفاق افتاده در مدل سازی، نتایج با مدل‌های شبکه عصبی مصنوعی^{۱۲} (ANN)، مدل استنتاج عصبی-فازی سازکار^{۱۳} (ANFIS)، مدل SVR^{۱۴}، مدل کریجینگ^{۱۵} و GIM^{۱۶} و مدل تجربی IRI2016 در ایستگاه‌های کنترل داخلی و خارجی مقایسه و ارزیابی می‌شود.

روش تحقیق

در این بخش در مورد تئوری ریاضی مدل کمترین مربuat رگرسیون بردار پشتیبان (LS-SVR)، مدل کریجینگ و مدل GIM بحث و بررسی خواهد شد. با توجه به اینکه مدل‌های ANN، ANFIS، SVR و IRI2016 به کرات در تحقیقات مشابه مورد استفاده قرار گرفته است، درنتیجه جهت آشنایی با تئوری ریاضی این مدل‌ها، خوانندگان محترم می‌توانند به مراجع [۲۲، ۲۳] مراجعه نمایند.

استخراج مشاهدات TEC دقیق

سیگنال‌های GPS دو مشاهده اصلی تحت عنوان شبکه‌فاصله کد و فاز موج دریافتی را در اختیار می‌گذارند. واحد شبکه‌فاصله کد به متر است که فاصله میان گیرنده تا ماهواره را در خود اندازه‌گیری کرده است. به جهت متأثر بودن این مشاهده از سیاری از منابع خطأ، مشاهده کد به شبکه‌فاصله شناخته می‌شود. مشاهده فاز موج حامل بر حسب سیکل^{۱۵} اندازه‌گیری می‌شود و از آنجایی که نسبت به مشاهده کد از طول موج کوتاه‌تری برخوردار است با دقت یک‌صدم سیکل قابل اندازه‌گیری می‌باشد. گیرنده GPS فاز موج حامل را اندازه‌گیری می‌کند اما تعداد سیکل‌های کامل طی شده توسط موج که به پارامتر ایهام فاز^{۱۶} معروف است مجھول بوده و قابل اندازه‌گیری نیست. ابهام فاز با تشکیل ترکیب تفاضلی دوگانه مشاهدات و استفاده از روش‌های پردازش مختلف نظری ترکیب ملبورن-ووبنا^{۱۷}، ترکیب طول موج بلند^{۱۸} و به کار گیری مدل‌های یونسfer جهانی نظری GIM می‌تواند تعیین گردد. از کم کردن

18. Melbourne-Wubbena
19. Wide-lane
20. Differential Code Bias
21. Ionolab software
22. Dual programming

13. Artificial neural network
14. Adaptive neuro-fuzzy inference system model
15. Kriging
16. Cycle
17. Phase ambiguity

در رابطه (۱۲) $K(\mathbf{x}, \mathbf{x}_n)$ تابع کرنل نامیده می‌شود که مطابق با رابطه (۱۳) به عنوان تابعی با ایجاد ضرب داخلی در فضای ویژگی معرفی می‌شود:

$$K(\mathbf{x}, \mathbf{x}_n) = \langle \varphi(\mathbf{x}), \varphi(\mathbf{x}_n) \rangle \quad (13)$$

تابع کرنل خطی، چندجمله‌ای و شعاعی را می‌توان در رابطه (۱۲) مورد استفاده قرار داد که از بین آن‌ها، کرنل شعاعی بیشترین سرعت و کمترین خطای را دارد.

مدل کریجینگ

کریجینگ یکی از مناسب‌ترین و پیشرفته‌ترین تکنیک‌های تحلیل داده‌های مکانی است. کریجینگ یک روش درون‌بایی بهینه است که در آن متغیرها تصادفی هستند و تابع هندسی خاصی را دنبال نمی‌کنند. این روش در دهه ۷۰ میلادی توسط مهندس فرانسوی ماترون (۱۹۷۱) مورد استفاده قرار گرفت [۲۷]. کریجینگ یک برآورده‌گر بی‌طرفانه با کمترین واریانس تخمین است. شرط بی‌طرفانه در سایر روش‌های تخمین مانند فاصله معکوس و محدود فاصله معکوس نیز اعمال می‌شود، اما ویژگی کریجینگ این است که ضرایب مجھول را به‌گونه‌ای تعیین می‌کند که واریانس تخمین‌ها نیز حداقل باشد [۲۸]. کریجینگ بر اساس میانگین‌ها ثابت برای داده‌ها و خطاهای تصادفی و با مستوی مکانی به شرح زیر است:

$$Z(x_0) = \mu(x_0) + \varepsilon(x_0) \quad (14)$$

که در آن $Z(x_0)$ متغیر مورد نظر، (x_0) روند قطعی و $\varepsilon(x_0)$ خطای همبستگی است [۲۹]. در الگوریتم معمولی کریجینگ، معادله (۱۴) را می‌توان به صورت زیر ارائه نمود:

$$Z(x_0) = \mu(x_0) + \sum_{i=1}^n \lambda_i [z(x_i) - \mu(x_i)] \quad (15)$$

که در آن n تعداد نقاط نمونه مورد استفاده برای تخمین است، λ_i وزنی است که به نقطه نمونه برداری شده (x_i) اختصاص داده شده است، $\sum_{i=1}^n \lambda_i = 1$ یک شرط است [۳۰]. کریجینگ یکی از مناسب‌ترین

روش‌های درون‌بایی مکانی است زمانی که فاصله همبستگی مکانی یا سوگیری جهتی در داده‌ها مشخص باشد. بایستی اشاره شود که در این مقاله از مدل کریجینگ معمولی استفاده شده است. در این روش برای بیان تعییرات مکانی از پراش نگار استفاده می‌شود و خطای مقادیر پیش‌بینی شده را با توجه به توزیع فضایی داده‌های پیش‌بینی شده، کمینه می‌کند. روش عمومی محاسبه کریجینگ بر اساس معادله زیر می‌باشد:

$$Z_0^1 = \sum_{i=1}^N w_i z_i \quad (16)$$

الگوریتم را کاهش می‌دهد. با این حال، پیش‌نیاز SVR برای دستیابی به نتایج بهتر، یافتن سه پارامتر مناسب تعریف شده توسط کاربر است. در LS-SVR، تنها دو پارامتر تعریف شده توسط کاربر وجود دارد. این پارامترهای تعریف شده توسط کاربر نقش کلیدی در ساخت یک مدل رگرسیون بسیار دقیق با عملکرد تعییم χ^2 خوب دارند.

مدل LS-SVR در حقیقت فرمول بندی مجدد مدل SVR است. الگوریتم LS-SVR می‌تواند پایداری بالاتر را مشخص کند و با سرعت بیشتری نسبت به SVR آموزش بینند. می‌توان مدل رگرسیون LS-SVR را با حل مسئله بهینه‌سازی زیر به دست آورد:

$$\frac{\gamma}{2} \sum_{n=1}^N e_n^2 + \frac{1}{2} \|\mathbf{w}\|^2 \quad (17)$$

محدودیت:

$$y_i = \mathbf{w}^T \Phi(x_i) + b + e_i \quad (18)$$

در روابط بالا، γ پارامتر تنظیم‌کننده بخش خطای $\Phi(x_i)$ در مدل SVR، e_i خطای داده‌های آموزش، b ترسیم غیرخطی ورودی‌ها در فضای ویژگی با ابعاد زیاد، پارامترهای w و b به ترتیب مقادیر وزن و بایانس تابع رگرسیون هستند. تابع لاگرانژ برای حل مسئله بهینه‌سازی (۱۷) به صورت زیر ساخته می‌شود:

$$L(\mathbf{w}, \mathbf{b}, e; a) = \frac{\gamma}{2} \sum_{n=1}^N e_n^2 + \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{n=1}^N a_n \{ \mathbf{w}^T \varphi(\mathbf{x}) + \mathbf{b} - 1 + e_n \} \quad (19)$$

که در آن a_n بیانگر ضرب لاگرانژی است. شرایط مرتبه اول را می‌توان به صورت زیر در نظر گرفت:

$$\frac{\partial L(\mathbf{w}, \mathbf{b}, e; a)}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{n=1}^N a_n \phi(\mathbf{x}_n) \quad (10)$$

$$\frac{\partial L(\mathbf{w}, \mathbf{b}, e; a)}{\partial \mathbf{b}} = 0 \Rightarrow \sum_{n=1}^N a_n = 0$$

$$\frac{\partial L(\mathbf{w}, \mathbf{b}, e; a)}{\partial e_n} = 0 \Rightarrow a_n = \gamma e_n \quad (11)$$

$$\frac{\partial L(\mathbf{w}, \mathbf{b}, e; a)}{\partial a_n} = 0 \Rightarrow \{ \mathbf{w}^T \varphi(\mathbf{x}) + \mathbf{b} \} = 1 - e_n$$

تابع رگرسیون پیش‌بینی مدل LS-SVR همانند مدل رگرسیون بردار پشتیبان است که با رابطه زیر مشخص می‌شود:

$$y(\mathbf{x}) = \sum_{n=1}^N a_n t_n K(\mathbf{x}, \mathbf{x}_n) + \mathbf{b} \quad (12)$$

نیز، مقادیر VTEC حاصل از مشاهدات GPS خواهد بود؛ بنابراین تابع زیر را می‌توان به عنوان رابطه مابین پارامترهای ورودی و خروجی مدل‌های یادگیری ماشین در نظر گرفت:

$$VTEC_{ANN\ ANFIS\ SVR\ LS-SVR} = f(Lat.\ Log.\ DOY\ Time\ KP\ DST\ F10.7) \quad (18)$$

تابع هدف^{۲۷} (تابع هزینه) تعريف شده برای همه مدل‌های یادگیری ماشین مورد استفاده در این مقاله، به صورت زیر می‌باشد:

$$C = \sum_{i=1}^N (VTEC_{GPS}^i - VTEC_{mod\ el}^i)^2 \quad (19)$$

در رابطه (۱۹) $VTEC_{GPS}$ بیانگر مقادیر حاصل از GPS، $VTEC_{mod\ el}$ نشان‌دهنده مقادیر حاصل از مدل‌های یادگیری ماشین و N تعداد نمونه‌های مورد آزمون را نشان می‌دهند.

شاخص‌های آماری

ارزیابی نتایج مدل‌های ANN، ANFIS، SVR و LS-SVR کریجینگ، IRI2016 و GIM در مدل سازی زمانی-مکانی محتوای GPS الکترون کلی یونسfer با استفاده از مقادیر VTEC حاصل از GPS به عنوان مشاهده مرتع انجام می‌گیرد. پارامترهای آماری خطای نسبی، ضریب همبستگی و همچنین RMSE جهت بررسی دقت و صحت مدل‌ها استفاده می‌شوند. این پارامترها با روابط زیر محاسبه می‌شوند:

$$Re(\%) = \frac{|VTEC_{mod\ el} - VTEC_{GPS}|}{VTEC_{GPS}} \times 100 \quad (20)$$

$$R = \frac{\sum_{i=1}^N (VTEC_{mod\ el}^i - \bar{VTEC}_i) \times (\bar{VTEC}_{GPS}^i - \bar{VTEC}_{GPS})}{\sqrt{\sum_{i=1}^N (VTEC_{mod\ el}^i - \bar{VTEC}_i)^2} \times \sqrt{\sum_{i=1}^N (\bar{VTEC}_{GPS}^i - \bar{VTEC}_{GPS})^2}} \quad (21)$$

در روابط بالا، $VTEC_{GPS}$ بیانگر مقدار حاصل از مشاهدات GPS (مشاهده مرتع) و $VTEC_{model}$ نشان‌دهنده مقدار مقدار حاصل از مدل‌ها می‌باشند. کمینه مقادیر خطای نسبی و RMSE صفر است. هرچقدر مقادیر این دو پارامتر به صفر نزدیک‌تر باشند، نشان‌دهنده دقت بالاتر مدل مورد نظر است. ضریب همبستگی بینگر 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 [۰, ۱] 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.

در این معادله Z_0^1 برابر با مقادیر برآورده شده، w_i برابر با وزن و z_i برابر با مقادیر نمونه است. وزن‌ها به درجه همبستگی بین نقاط نمونه و نقاط برآورده شده بستگی دارد و همیشه جمع آن‌ها برابر با یک است. برای محاسبه وزن از معادله ماتریسی استفاده می‌شود.

مدل GIM

نقشه‌های جهانی یونسfer (GIM-TEC) توسط IGS در یک بازه زمانی ۲ ساعته ارائه می‌شود. توابع هارمونیک کروی (SH) برای مدل سازی VTEC در یک چارچوب مرجع ژئومغناطیسی خورشیدی مطابق با معادله زیر استفاده می‌شود [۳۱]:

$$VTEC(\varphi, \lambda) = \sum_{n=0}^{n_{max}} \sum_{m=0}^n \tilde{P}_{mn} (\sin \varphi) (a_{nm} \cos(m\lambda) + b_{nm} \sin(m\lambda)) \quad (17)$$

در رابطه (۱۷) φ بیانگر عرض جغرافیایی ثابت خورشیدی نقطه نفوذ یونسfer^{۲۸} (IPP) است، λ طول جغرافیایی ثابت خورشیدی در نقطه IPP، n و m به ترتیب درجه و مرتبه مدل، \tilde{P}_{mn} تابع لزاندر نرمالیزه شده، a_{nm} و b_{nm} به ترتیب ضرایب مجھول و پارامترهای مدل GIM هستند. رزولوشن زمانی TEC محاسبه شده با مدل GIM ۲ ساعت است. با این حال، تحقیقات نشان داده است که تغییرات زمانی یونسfer دارای فرکانس کمتر از ۲ ساعت است. این تغییرات در طول دوره‌های فعالیت خورشیدی افزایش می‌یابد؛ بنابراین، در ک رفتار زمانی یونسfer نیاز به یک مدل با رزولوشن زمانی بالاتر دارد.

پارامترهای ورودی و خروجی در مدل‌های یادگیری ماشین

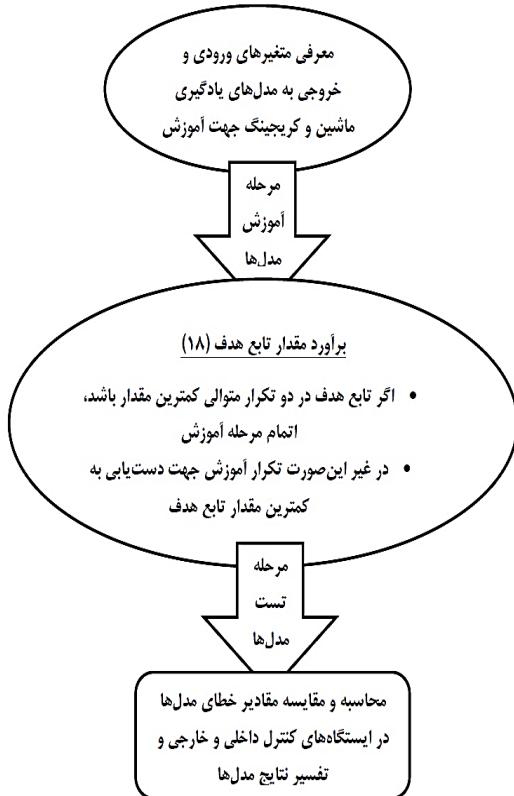
مدل‌های یادگیری ماشین بر اساس پارامترهای ورودی و پارامترهای خروجی متناظر با آن آموزش داده شده و سپس مطابق با تابع هدف در نظر گرفته شده برای مدل، مرحله آموزش آن‌ها به اتمام می‌رسد. در این مقاله برای چهار مدل ANN، ANFIS، SVR و LS-SVR مقایسه شده است. از هفت پارامتر طول و عرض جغرافیایی ایستگاه GPS، روز از سال^{۲۹} (DOY)، زمان به وقت جهانی^{۳۰} (UT)، پارامترهای ژئومغناطیسی و DST و KP^{۳۱} و F10.7^{۳۲} به عنوان بردار ورودی استفاده می‌شود. به عبارت دیگر هم پارامترهای وابسته به مکان (طول و عرض جغرافیایی)، پارامترهای وابسته به زمان (روز از سال و زمان به وقت جهانی) و پارامترهای فیزیکی (DST و KP) در آموزش مدل‌ها شرکت داده می‌شوند. خروجی متناظر با بردار ورودی

27. Universal time
28. Cost function

25. Ionospheric pierce point
26. Day of year

ایستگاه‌های مورد استفاده در این تحقیق، ۰/۹۷ TECU است. به عبارت دیگر، مقادیر VTEC ورودی به مدل‌های یادگیری ماشین و مدل کریجینگ خود دارای خطای ۰/۹۷ TECU هستند. فلوچارت چگونگی انجام مراحل آموزش و آزمون مدل‌های یادگیری ماشین و مدل کریجینگ در شکل (۲) نمایش داده است.

مطابق با فلوچارت ارائه شده در شکل (۲) فرآیند اعتبارسنجی مدل‌ها در ایستگاه‌های کنترل داخلی و خارجی انجام گرفته است. به این صورت که مقدار TEC دقیق حاصل از GPS در این ایستگاه‌ها مشخص می‌باشد. پس از مرحله آموزش مدل‌های یادگیری ماشین و مدل کریجینگ، متغیرهای ورودی به مدل‌ها معرفی شده و مقدار TEC با مدل‌های یادگیری ماشین و مدل کریجینگ برآورد می‌شود. این مقدار با مقدار دقیق حاصل از GPS مقایسه شده و خطای مدل‌ها در ایستگاه‌های کنترل داخلی و خارجی محاسبه و ارزیابی می‌شود.



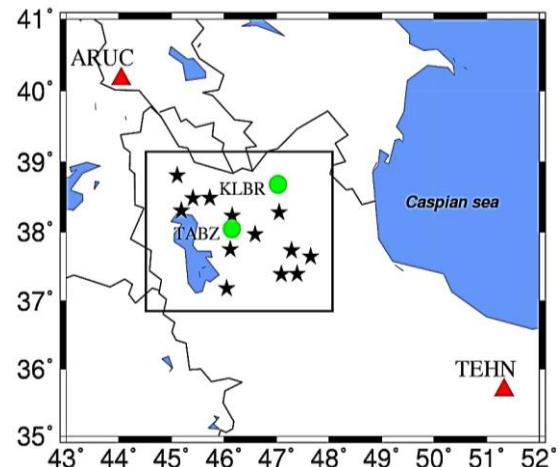
شکل ۲- فلوچارت چگونگی استفاده از مدل‌های ANN، ANFIS و SVR و کریجینگ جهت برآورد مقدار TEC و ارزیابی دقت آن‌ها.

نتایج عددی و بحث

در این بخش نتایج عددی و آنالیزهای انجام گرفته در مراحل آموزش و آزمون برای مدل‌های مختلف ارائه شده و نتایج حاصل، تفسیر می‌شوند.

منطقه مورد مطالعه و مشاهدات مورد استفاده

برای ارزیابی مدل LS-SVR از مشاهدات ۱۵ ایستگاه GPS در شمال غرب ایران استفاده شده است. مشاهدات در بازه زمانی ۱۹۳ تا ۳۶۲۲۸ (روز) در سال ۱۳۹۱ می‌باشد. کلیه فایل‌های راینکس^{۳۶} مربوط به ایستگاه‌های GPS از سازمان نقشه‌برداری کشور^{۳۹} (NCC) تهیه شده است. ارتفاع این ایستگاه‌ها از ۱۲۸۰ تا ۱۹۵۲ متر بالاتر از سطح متوسط دریا^{۳۰} (MSL) متغیر است. همچنین برای غلبه بر خطای چندمسیری از آتن چوک با زاویه ارتفاعی بالای ۱۵ درجه استفاده شده است. دلیل اصلی انتخاب این بازه زمانی برای ارزیابی مدل‌ها، در دسترس بودن مجموعه کاملی از مشاهدات ایستگاه‌های GPS است. لازم به ذکر است که از ۱۵ ایستگاه مورد استفاده، دو ایستگاه TABZ (38.04° N, 46.15° E) و KLBR (38.68° N, 47.03° E) به عنوان ایستگاه‌های کنترل داخلی^{۳۱} انتخاب شده‌اند. به منظور ارزیابی دقت مدل‌ها خارج از محدوده شبکه GPS مورد مطالعه، ایستگاه‌های ARUC (40.17° N, 44.05° E)^{۳۲} و TEHN (35.69° N, 51.33° E)^{۳۳} به عنوان ایستگاه‌های کنترل خارجی^{۳۴} انتخاب شده‌اند. شکل (۱) چگونگی توزیع ایستگاه‌های GPS (ستاره‌های سیاه)، ایستگاه‌های کنترل داخلی (دایره‌های سبز) و ایستگاه‌های کنترل خارجی (مثلث‌های قرمز) را نشان می‌دهد. همچنین در این شکل، مستطیل سیاه محدوده مدل‌سازی را نمایش می‌دهد.



شکل ۱- چگونگی توزیع مکانی ایستگاه‌های آموزش (ستاره‌های سیاه)، ایستگاه‌های کنترل داخلی (دایره‌های سبز) و ایستگاه‌های کنترل خارجی (مثلث‌های قرمز).

مطابق با الگوریتم ارائه شده در بخش استخراج مشاهدات TEC دقیق و با استفاده از نرم‌افزار IONOLAB مقادیر VTEC در روزهای ۱۹۳ تا ۳۶۲۲۸ می‌باشد و به عنوان خروجی مطلوب در مدل‌های یادگیری ماشین و مدل کریجینگ مورد استفاده قرار می‌گیرند. بایستی اشاره شود که انحراف معیار مقادیر VTEC محاسبه شده برای کلیه

32. Interior control stations

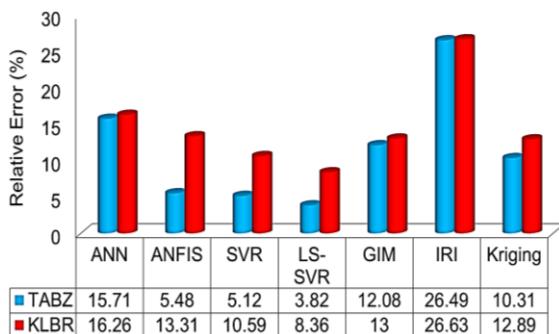
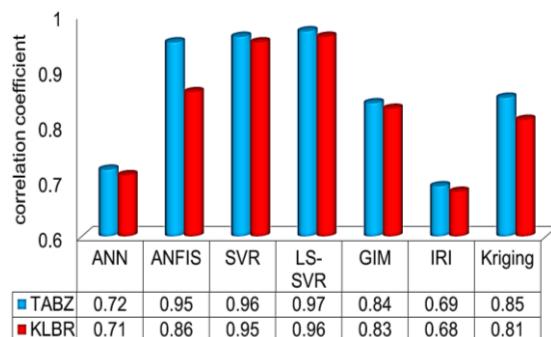
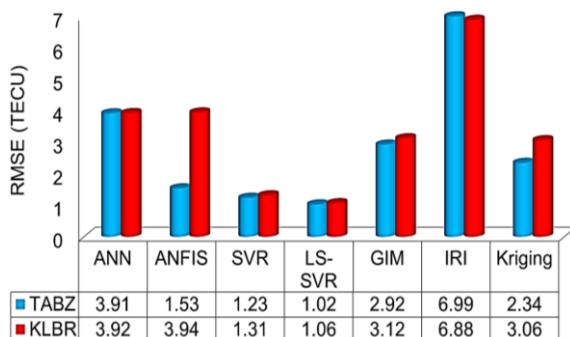
33. Exterior control stations

29. Rinex

30. National cartographic center

31. Mean sea level

کرد. در این مرحله با مدل های آموزش دیده، مقدار VTEC در ایستگاه های GPS- (GPS) VTEC مقایسه می شود. لازم به ذکر است که دو ایستگاه کنترل داخلی به گونه ای انتخاب شده اند که دقت مدل ها در شرایط متفاوت مورد ارزیابی قرار گیرد. به عبارت دیگر، ایستگاه کنترل TABZ از ایستگاه های آموزشی آموزشی احاطه شده است، اما ایستگاه KLBZ از ایستگاه های آموزشی دورتر است. همچنین از مشاهدات ایستگاه های کنترل داخلی در مرحله آموزش استفاده نمی شود. شکل (۳) مقادیر RMSE، ضریب همبستگی و خطای نسبی مدل های ANN، ANFIS، SVR، LS-SVR، GIM، Kriging، IRI2016 و GIM ذکر است در تمامی محاسبات و مقایسه ها، VTEC حاصل از GPS به عنوان مشاهده مرجع در نظر گرفته شده است.



شکل -۳- مقایسه میانگین خطای RMSE (TECU)، ضریب همبستگی و خطای نسبی (بر حسب درصد) در ایستگاه های کنترل داخلی TABZ و KLBZ برای مدل های LS-SVR، SVR، ANFIS، ANN، GIM و Kriging، IRI2016 در مرحله آزمون.

مرحله آموزش مدل های SVR، ANFIS، ANN و LS-SVR

در مرحله آموزش ساختار بهینه مدل ها مشخص می شود. بنابراین ساختاری بهینه است، که در آن خطای مدل حداقل شده و ضریب همبستگی بین خروجی مدل و خروجی واقعی، بالاترین مقدار را دارد. همچنین در تمامی مدل ها زمان همگرایی به جواب بهینه اندازه گیری می شود. اگر زمان همگرایی مدل به جواب بهینه کم باشد، مدل از سرعت محاسباتی بالاتری برخوردار است؛ بنابراین، سه پارامتر RMSE، ضریب همبستگی و زمان همگرایی برای مدل ها در مرحله آموزش مقایسه می شوند. برای مدل های ANN، ANFIS، SVR و LS-SVR، زمان، بردار ورودی شامل طول و عرض جغرافیایی ایستگاه GPS، DOY، زمان، F10.7 و DST و KP است. مقدار VTEC مربوط به بردار ورودی نیز به عنوان خروجی مدل ها در نظر گرفته می شود. پایگاه داده آموزش مدل ها شامل ۵۶۱۶ بردار ورودی و خروجی می باشد. جدول (۱) مقادیر RMSE، ضریب همبستگی و زمان همگرایی را در مرحله آموزش مدل های LS-SVR، SVR، ANFIS، ANN و Kriging نشان می دهد. لازم به ذکر است که در این مقایسه VTEC به دست آمده از GPS به عنوان مشاهده مرجع در نظر گرفته شده است. همچنین محاسبات تمامی مدل ها بر روی کامپیوتری با سخت افزار و نرم افزار یکسان انجام شده است.

جدول ۱- مقادیر RMSE (TECU)، ضریب همبستگی و زمان همگرایی (بر حسب ثانیه) در مرحله آموزش مدل های ANN، ANFIS، SVR، LS-SVR و SVR

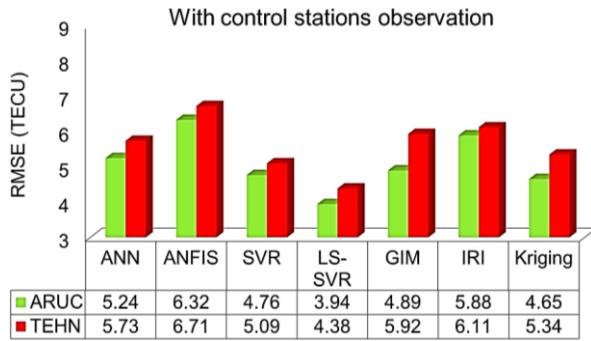
انواع مدل	RMSE (TECU) (بر حسب ثانیه)	ضریب همبستگی مرحله آموزش	زمان همگرایی به جواب بهینه (بر حسب ثانیه)
ANN مدل	۱/۸۲	۰/۹۳	۸۸
ANFIS مدل	۱/۵۲	۰/۹۵	۳۴۲
SVR مدل	۱/۲۸	۰/۹۷	۷۹
LS-SVR مدل	۰/۶۷	۰/۹۸	۱۹

با توجه به جدول (۱)، نتایج مرحله آموزش مدل LS-SVR در هر سه پارامتر بهتر از مدل های دیگر است. در این مدل داده ها بر اساس کرنل شعاعی و معادلات خطی ساده آموزش داده می شوند؛ اما در SVR و ANFIS وزن اولیه کاملاً تصادفی است و خوش بندی در جین آموزش و الگوریتم تکرار می شود. درنتیجه مدل LS-SVR از دقت بالاتر و زمان همگرایی کمتری نسبت به مدل های دیگر در مرحله آموزش برخوردار است.

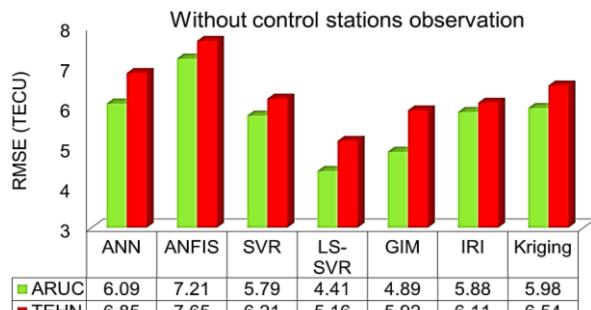
مرحله آزمون مدل های SVR، ANFIS، ANN و LS-SVR

پس از مرحله آموزش مدل های یادگیری ماشین و انتخاب ساختار بهینه برای مدل ها، حال می توان از این مدل ها برای برآورد مقدار VTEC استفاده

میانگین RMSE برای تمام روزها در این دو شکل نشان داده شده است. همچنین VTEC حاصل از GPS به عنوان مشاهده مرجع در نظر گرفته شده است.



(الف)



(ب)

شکل ۴- مقایسه میانگین RMSE (بر حسب TECU) در ۳۶ روز مورد بررسی برای مدل‌های ANN، ANFIS، SVR، کریجینگ، LS-SVR و GIM در دو ایستگاه کنترل خارجی در حالت استفاده از مشاهدات IRI2016 و GIM و عدم استفاده از مشاهدات در مرحله آموزش (شکل (الف) و عدم استفاده از مشاهدات در مرحله آموزش (شکل (ب)).

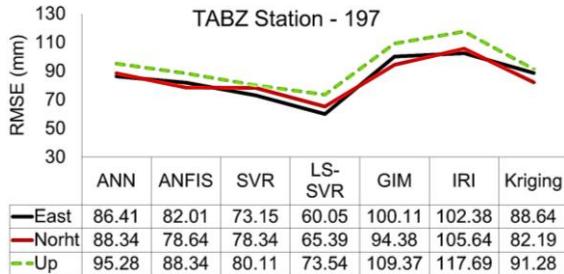
مقایسه نتایج دو سناریو در نظر گرفته شده برای ارزیابی ایستگاه‌های کنترل خارجی به وضوح نشان می‌دهد که تمام RMSE مدل‌های یادگیری ماشین در حالت استفاده از مشاهدات برای مرحله آموزش کمتر از حالت دیگر است؛ به عبارت دیگر، خطای RMSE زمانی کاهش می‌یابد، که از مشاهدات ایستگاه‌های کنترل در مرحله آموزش استفاده شود. در هر دو حالت ارزیابی شده RMSE، مدل LS_SVR در هر دو ایستگاه کنترل خارجی کمتر از مدل‌های دیگر است. شایان ذکر است که RMSE مدل‌های یادگیری ماشین در ایستگاه‌های کنترل خارجی تقریباً سه برابر RMSE این مدل‌ها در ایستگاه‌های کنترل داخلی است. این نشان می‌دهد که دقت مدل‌های ML در محدوده شبکه GPS بالاست. با دور شدن از محدوده شبکه، دقت مدل‌ها به شدت کاهش می‌یابد. نتایج شکل (۴) نشان می‌دهد که مدل ANFIS RMSE در هر دو حالت به شدت افزایش یافته است. قوانین اگر-آنگاه فازی مدل ANFIS در محدوده شبکه GPS دارای اعتبار هستند. با این حال، با دور

در شکل (۳) مقادیر شاخص‌های RMSE، خطای نسبی و ضریب همبستگی در بازه‌های زمانی دو ساعته و روزانه محاسبه شده و سپس، میانگین کل ۳۶ روز مورد بررسی، ارائه شده است. نتایج شکل (۳) نشان می‌دهد که در هر دو ایستگاه کنترل داخلی، مدل LS-SVR از GIM و خطا نسبی مدل‌های ANN، ANFIS، SVR، کریجینگ و LS-SVR بیشتر از ایستگاه KLBR است. مطابق شکل (۱)، ایستگاه کنترل TABZ توسط ایستگاه‌های آموزشی احاطه شده است. در نتیجه مشاهدات آموزشی بیشتری برای این ایستگاه در پایگاه داده وجود دارد.

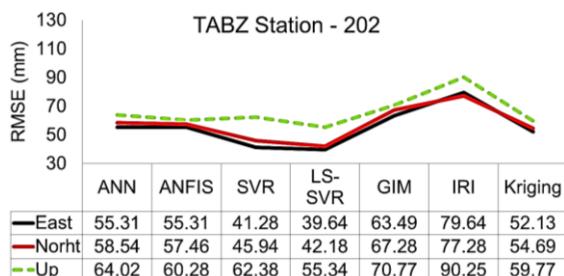
خطای مدل GIM در هر دو ایستگاه کنترل داخلی بیشتر از مدل‌های ANN، ANFIS، SVR، کریجینگ و LS-SVR بوده و کمتر از مدل GIM است. مدل ANN مبتتنی بر توابع هارمونیک کروی است. ضرایب این مدل با استفاده از مشاهدات ایستگاه‌های شبکه جهانی IGS برآورد می‌شوند؛ بنابراین، این یک مدل جهانی یونسferی است. در ایران به دلیل وجود تنها دو ایستگاه IGS، دقت TEC در هر توسط مدل GIM پایین است. خطای مدل تجربی IRI2016 در هر دو ایستگاه کنترل داخلی بیشتر از سایر مدل‌ها است. مدل IRI یک مدل پیش‌بینی یونسfer است. دقت این مدل به دقت مشاهدات ایستگاه‌های یونوسوند و ISR بستگی دارد. به دلیل عدم وجود ایستگاه‌های یونوسوند و ISR در ایران، دقت مدل IRI پایین است. نکته مهم دیگر در شکل (۳) این است که ضریب همبستگی VTEC حاصل از مدل GIM با GPS زیاد است ($R=0.84$). این نشان می‌دهد که GIM به درستی تعییرات زمانی و مکانی را در VTEC تشخیص می‌دهد؛ اما دقت مدل‌سازی محلی آن پایین است. میانگین خطای LS-SVR مدل‌های RMSE، SVR، ANFIS، ANN، کریجینگ، LS-SVR و IRI2016 در دو ایستگاه کنترل داخلی به ترتیب برابر با $6/93$ ، $3/91$ ، $2/73$ ، $2/70$ ، $1/04$ ، $1/22$ ، $6/93$ و $2/02$ TECU شده است؛ به عبارت دیگر در دو ایستگاه کنترل داخلی کمترین مقدار خطای مربوط به مدل‌های SVR و LS-SVR است.

برای تجزیه و تحلیل دقیق‌تر دقت مدل‌های یادگیری ماشین در مقایسه با مدل‌های جهانی، تجربی یونسfer و مدل کریجینگ، دو ایستگاه کنترل خارج از محدوده شبکه GPS در نظر گرفته شده است. هر دو ایستگاه جزء ایستگاه‌های شبکه جهانی IGS هستند. برای تحلیل خطای مدل‌ها دو سناریو در نظر گرفته شده است: آموزش مدل‌ها بدون استفاده از مشاهدات ایستگاه‌های کنترل خارجی و مجددآموزش مدل‌ها با استفاده از مشاهدات ایستگاه‌های کنترل خارجی. شکل (۴) نتایج این دو سناریو را نشان می‌دهد. لازم به ذکر است که

۱۹۷ دارای فعالیت خورشیدی و ژئومغناطیسی بالاتری نسبت به روز ۲۰۲ است.

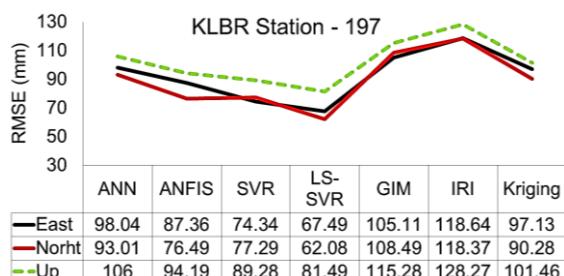


(الف)

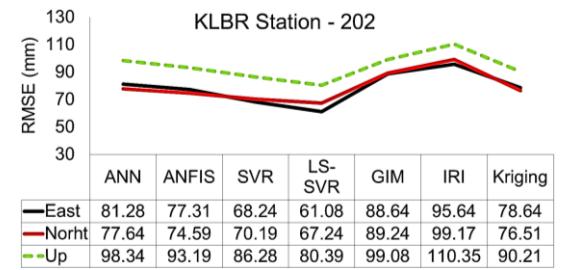


(ب)

شکل ۵- تجزیه و تحلیل خطای RMSE (بر حسب میلیمتر) در مؤلفه‌های مختصاتی ایستگاه کنترل داخلی TABZ برای مدل‌های ANN، ANFIS، SVR، LS-SVR، GIM و IRI2016 در روز ۱۹۷ و ۲۰۲ (شکل (الف) و (ب))



(الف)



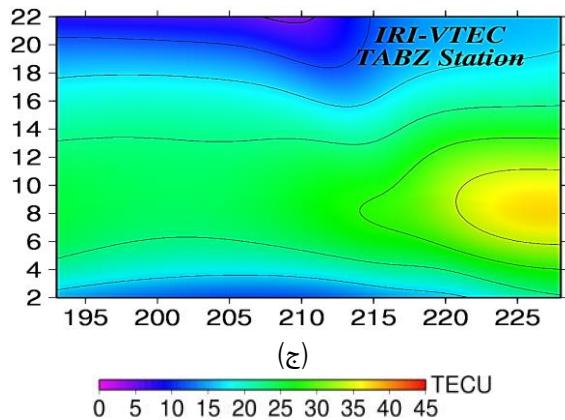
(ب)

شکل ۶- تجزیه و تحلیل خطای RMSE (بر حسب میلیمتر) در مؤلفه‌های مختصاتی ایستگاه کنترل داخلی KLBR برای مدل‌های ANN، ANFIS، SVR، LS-SVR، GIM و IRI2016 در روز ۱۹۷ و ۲۰۲ (شکل (الف) و (ب))

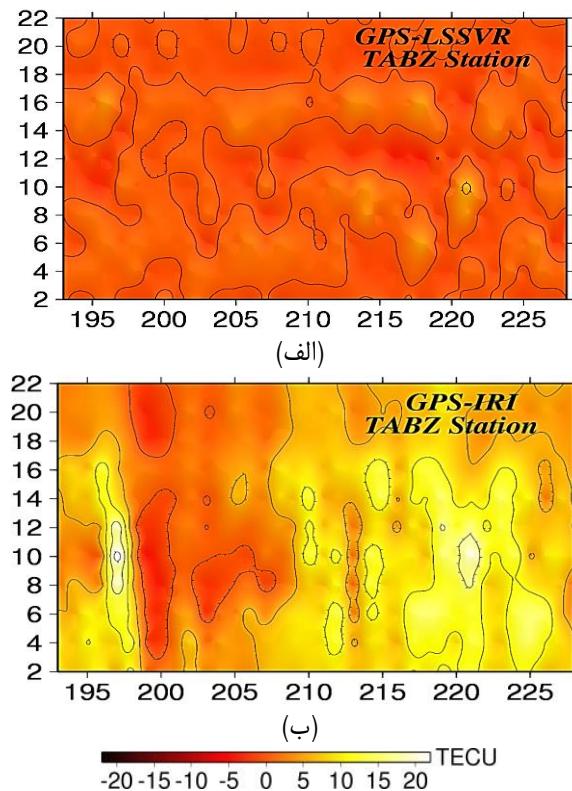
شندن از محدوده شبکه، اعتبار این قوانین بهشدت کاهش می‌یابد. این عامل باعث کاهش دقت مدل ANFIS در ایستگاه‌های کنترل خارجی شده است. لازم به ذکر است که دقت مدل LS-SVR در هر دو ایستگاه کنترل خارجی و در هر دو حالت بالاتر از مدل‌های GIM و IRI2016 می‌باشد. در مدل کریجینگ زمانی که مشاهدات ایستگاه‌ها در مرحله سرشکنی و برآورد ضرایب مدل استفاده شده، خطا کمتر از حالت بدون استفاده از مشاهدات ایستگاه‌های کنترل خارجی است. این مقایسه نشان می‌دهد مدل LS-SVR می‌تواند جایگزین مدل‌های جهانی و تجربی در خارج از محدوده شبکه GPS باشد.

یکی از کاربردهای اصلی مدل سازی دقیق VTEC استفاده از آن در تعیین موقعیت نقطه‌ای دقیق (PPP) با گیرندهای تک فرکانس است. معمولاً در یک گیرنده تک فرکانس، یک مدل یونسفری با دقت بالا برای تعیین موقعیت دقیق مورد نیاز است. روش PPP به عنوان یک رویکرد بهینه برای ارائه موقعیت ژئودتیک نقطه در حالت استاتیکی و کینماتیکی با استفاده از تمامی منظمه‌های ^{۳۳} تعیین موقعیت GNSS موجود است. برای تعیین موقعیت در حالت استاتیک و با استفاده از مشاهدات ۲۴ ساعته، روش PPP می‌تواند دقت‌های در سطح میلی‌متر را برای همه مؤلفه‌های مختصاتی (طول، عرض و ارتفاع) ارائه دهد. در این رویکرد، داده‌های تک فرکانس در حالت PPP پردازش می‌شوند، اگرچه همه ایستگاه‌های GPS در منطقه مورد مطالعه مشاهدات دو فرکانس را دریافت می‌کنند. هدف استفاده از داده‌های تک فرکانس تنها اعمال مدل‌های یونسفر برای اصلاح تأخیرهای یونسفری است، به جای استفاده از مشاهدات دو فرکانس که اثرات یونسفر را کلاً از بین می‌برد. از آنجایی که تأخیر یونسفری، خطای غالب در روش PPP با مشاهدات تک فرکانس است، نتایج آن را می‌توان به عنوان شاخصی برای ارزیابی دقت مطلق مدل‌های یونسفری استفاده کرد.

با استفاده از VTEC به دست آمده از مدل‌های یادگیری ماشین ارزیابی شده در این مقاله، انکسار یونسفری محاسبه شده و سپس مشاهدات راینکس ایستگاه‌های کنترل تصحیح می‌شود. مختصات دو ایستگاه کنترل داخلی با استفاده از مشاهدات تصحیح شده و نرم‌افزار برنیز برآورد می‌شوند. همچنین با حالت تفاضلی، مختصات حاصل از ایستگاه‌های کنترل، مجددًا تخمین زده می‌شود. مختصات دو روش (برآورد با برنیز و محاسبه از حالت تفاضلی) مقایسه شده و RMSE مدل‌ها، محاسبه می‌شوند. برای ارزیابی دقیق‌تر، نتایج RMSE مؤلفه‌های مختصاتی روزهای ۱۹۷ و ۲۰۲ که فعالیت‌های خورشیدی و ژئومغناطیسی متفاوتی دارند، در دو ایستگاه کنترل داخلی KLBR و TABZ نشان داده شده است. روز



شکل ۷- مقایسه GPS-VTEC (شکل االف)، LSSVR-VTEC (شکل ب) و TABZ (شکل ج) در ایستگاه کنترل داخلی IRI-VTEC محور افقی نشان دهنده روز از سال (DOY) و محور عمودی زمان به وقت جهانی (UT) را نشان می دهد.



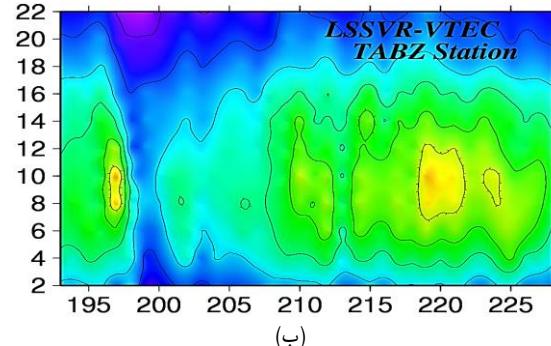
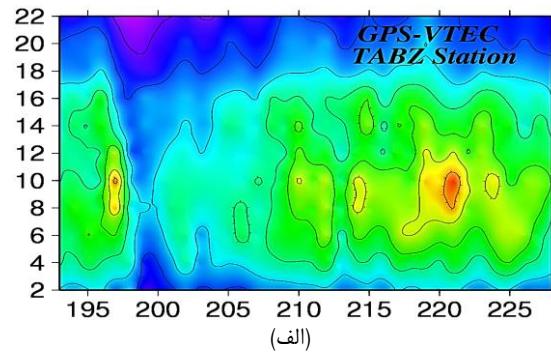
شکل ۸- تفاصل VTEC حاصل از GPS مدل VTEC با (شکل a) LS-SVR مدل VTEC حاصل از مدل IRI (شکل b) در ایستگاه کنترل داخلی TABZ، محور افقی نشان دهنده روز از سال (DOY) و محور عمودی زمان به وقت جهانی (UT) را نشان می دهد.

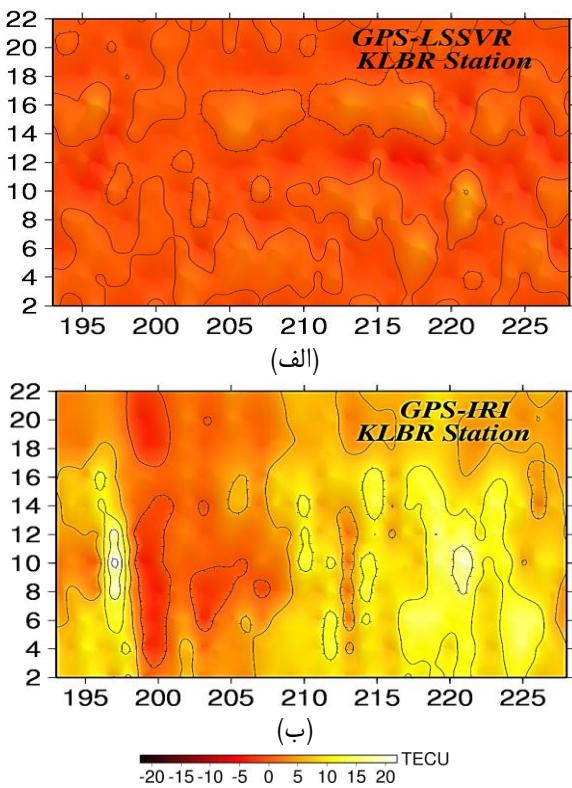
مقایسه GPS-VTEC و LS-SVR مدل VTEC حاصل از مدل تفاوتی در حدود ۰ تا ۴/۷۵ TECU را نشان می دهد؛ اما برای مدل IRI2016 تفاوت در حدود ۰ تا ۱۸/۵۰ TECU دیده می شود. این مقایسه نشان می دهد که مدل تجربی IRI2016 دقت محلی بسیار

دقیق ترین موقعیت با مدل های ANFIS، SVR، GIM و LS-SVR است. تحلیل RMSE مؤلفه های مختصاتی ایستگاه های کنترل LS-SVR و TABZ نشان می دهد که در هر دو ایستگاه، مدل LS-SVR دارای RMSE کمتری نسبت به سایر مدل های دیگر است. مقایسه نتایج دو ایستگاه کنترل داخلی نشان دهنده بهود ۱۰ تا ۵۴ میلی متری دقت تعیین موقعیت با استفاده از مدل LS-SVR نسبت به مدل های دیگر IRI2016 است. نتایج شکل های بالا نشان می دهد که برای مدل تجربی GIM و مدل جهانی LS-SVR در دو ایستگاه کنترل داخلی، خطای دقت تعیین موقعیت بهود چندانی نداشته است. نکته مهم دیگر این است که همه مدل ها در فعالیت خورشیدی و ژئومغناطیسی بالا، بیشتر از حالت فعالیت های پایین است.

مدل سازی مکانی-زمانی VTEC

پس از آموزش و تست مدل های ANFIS، SVR، GIM و LS-SVR، حال می توان با استفاده از مدل های آموزش دیده، تغییرات مکانی-زمانی VTEC را در محدوده شبکه GPS برآورد کرد. در مراحل آنالیز خطای مدل ها، مدل LS-SVR نسبت به مدل های دیگر خطای کمتری داشته است؛ بنابراین در این بخش VTEC حاصل از این مدل با GPS-VTEC و IRI-VTEC مقایسه شده است. شکل (۷) تا شکل (۱۰) نتایج این مقایسه را برای ایستگاه های کنترل داخلی TABZ و GPS-VTEC نشان می دهد. همچنین در دو شکل (۸) و (۹)، تفاصل GPS-VTEC و VTEC مدل های LS-SVR و IRI2016 را نشان داده است.





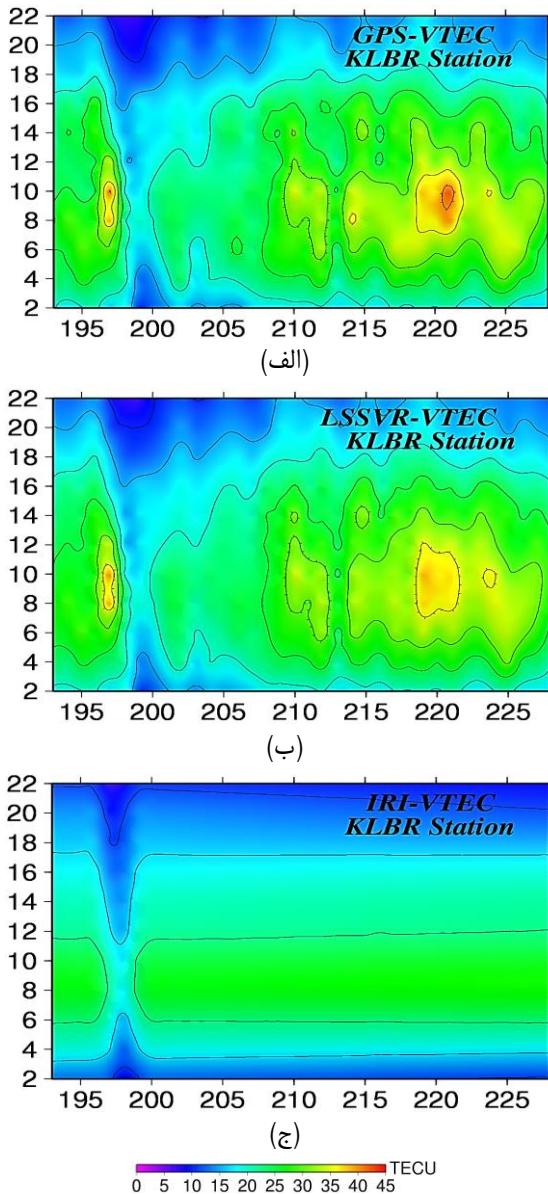
شکل ۱۰- تفاضل VTEC حاصل از GPS با مدل LS-SVR (شکل (الف)) و VTEC حاصل از مدل IRI (شکل (ب)) در ایستگاه کنترل داخلی KLBR، محور افقی نشان دهنده روز از سال (DOY) و محور عمودی زمان به وقت جهانی (UT) را نشان می‌دهد.

در ایستگاه کنترل KLBR، مدل LS-SVR تغییرات زمانی VTEC با GPS نشان می‌دهد؛ اما VTEC حاصل از مدل تجربی IRI2016 با GPS-VTEC در حدود ۰ تا ۲۰/۷۵ TECU تفاوت وجود دارد. همچنین نتایج ایستگاه کنترل KLBR نشان می‌دهد که مدل LS-SVR از قابلیت و دقت بسیار بالایی در نشان دادن تغییرات زمانی یونسfer در مدل سازی محلی برخوردار است.

VTEC پیش‌بینی زمانی

به منظور ارزیابی قابلیت مدل LS-SVR در برآورد مقدار VTEC، در این بخش سری‌های زمانی مورد تجزیه و تحلیل قرار گرفته است. در این مقاله از مشاهدات ۳۶ روزه در ۱۵ ایستگاه GPS برای ارزیابی و آنالیز خطای مدل‌ها استفاده شده است. برای تحلیل خطای مدل جدید در پیش‌بینی سری زمانی VTEC، از مشاهدات ۳۵ روز برای آموزش استفاده می‌شود و مقدار VTEC برای روز ۳۶ پیش‌بینی می‌شود. این ارزیابی در ایستگاه‌های کنترل داخلی TABZ و KLBR انجام می‌شود. در هر دو ایستگاه کنترل، مقدار VTEC با مدل

پایینی دارد. مدل LS-SVR تغییرات زمانی VTEC را مطابق با GPS-VTEC تخمین زده است (چگونگی تغییرات منحنی میزان‌ها در شکل (۷) این موضوع را نشان می‌دهد). بیشینه مقدار VTEC در روزهای ۲۱۹ تا ۲۲۳ و در بازه زمانی ۸ تا ۱۰ UT رخ داده است. مدل LS-SVR همچنین بیشینه تغییرات VTEC را مطابق با GPS حاصل از VTEC تجربی IRI2016 در روزهای ۲۲۵ تا ۲۲۸ مشاهده می‌شود. این تغییرات با GPS-VTEC سازگار نیستند.



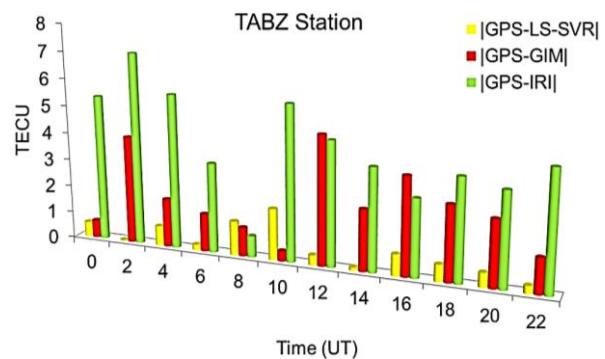
شکل ۹- مقایسه GPS-VTEC (شکل (الف)، (ب) و IRI-VTEC (شکل (ج)) در ایستگاه کنترل داخلی KLBR. محور افقی نشان دهنده روز از سال (DOY) و محور عمودی زمان به وقت جهانی (UT) را نشان می‌دهد.

نتیجه‌گیری و بحث

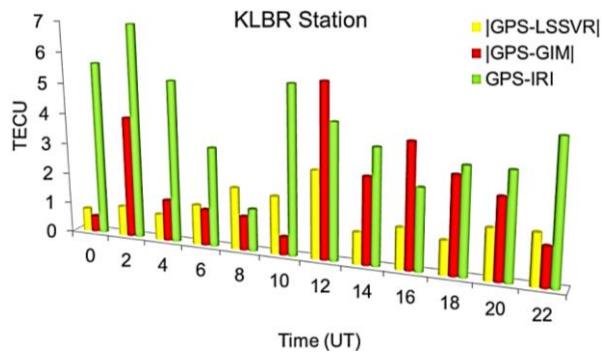
هدف از این مقاله مدل‌سازی و پیش‌بینی مکانی-زمانی مقدار محتوای الکترون کلی یونسفر (TEC) با استفاده از مدل کمترین مرباعات رگرسیون بردار پشتیبان (LS-SVR) بود. برای این منظور، مشاهدات ۱۵ ایستگاه GPS در شمال غرب ایران (شبکه محلی آذربایجان) در بازه زمانی روزهای ۱۹۳ تا ۲۲۸ در سال ۱۳۹۱ انتخاب شد. دلیل انتخاب این بازه زمانی برای تجزیه و تحلیل نتایج، در دسترس بودن مجموعه کاملی از مشاهدات GPS بود. از بین ۱۵ ایستگاه، ایستگاه‌های TABZ و KLBR به عنوان ایستگاه‌های کنترل داخلی انتخاب شدند. مشاهدات این ایستگاه‌ها از مرحله آموزش حذف شد. همچنین ایستگاه‌های ARUC و TEHN به عنوان ایستگاه‌های کنترل خارج از محدوده شبکه GPS انتخاب شدند. با استفاده از ۷ پارامتر ورودی طول و عرض جغرافیایی ایستگاه‌های GPS، روز از سال (DOY)، زمان به وقت جهانی (UT)، شاخص‌های ژئومغناطیسی DST و KP و شاخص فعالیت خورشیدی (F10.7) و همچنین پارامتر خروجی VTEC، مدل جدید آموزش داده شد. پس از مرحله آموزش، مقدار VTEC با استفاده از مدل LS-SVR برآورد شده و در ایستگاه‌های کنترل داخلی و خارجی ارزیابی گردید. همچنین تمامی نتایج به دست آمده با مدل‌های شبکه عصبی مصنوعی (ANN)، سیستم استنتاج عصبی-فازی سازگار (ANFIS)، رگرسیون برداری پشتیبان (SVR)، کریجینگ، RMSE و IRI2016 مقایسه شد. شاخص‌های آماری خطای نسبی، خطای مدل (dVTEC) و dTEC جهت ارزیابی دقت مدل‌ها مورد استفاده قرار گرفتند. همچنین تأثیر مدل‌سازی VTEC در تعیین موقعیت نقطه‌ای دقیق (PPP) مورد بررسی قرار گرفت. در ادامه و پس از ارزیابی دقت مدل‌ها، مقدار محتوای الکترون کلی در محدوده شبکه مورد مطالعه برآورد شده و با سایر مدل‌ها مقایسه شد.

بر اساس آنالیزهای انجام گرفته میانگین RMSE مدل‌های IRI2016، SVR، ANFIS، ANN، کریجینگ، LS-SVR و GIM در دو ایستگاه کنترل داخلی به ترتیب برابر با ۰/۲۵، ۰/۸۹، ۰/۲۷۲، ۰/۷۳، ۰/۹۱، ۰/۷۰، ۰/۳۰۲، ۰/۰۴ و ۰/۹۳ TECU بوده است. میانگین خطای نسبی مدل‌ها در دو ایستگاه کنترل داخلی به ترتیب برابر با ۰/۸۵، ۰/۳۹، ۰/۵۶ و ۰/۵۴ درصد محاسبه شد. تجزیه و تحلیل دقت خطای ایستگاه‌های کنترل داخلی نشان داد که مدل LS-SVR با بالاتری در برآورد تغییرات مکانی-زمانی VTEC نسبت به مدل‌های دیگر دارد. همچنین نتایج آنالیزها نشان داد که در ایستگاه کنترل داخلی KLBR خطای مدل‌های یادگیری ماشین بیشتر از ایستگاه کنترل داخلی TABZ بود. علت این امر احاطه بودن ایستگاه TABZ با ایستگاه‌های آموزش بود. تجزیه و تحلیل نتایج ایستگاه‌های کنترل

برآورد شده و سپس با VTEC به دست آمده از GPS و همچنین مدل‌های GIM و IRI2016 مقایسه می‌شود. شکل‌های (۱۱، ۱۲) قدر مطلق تفاضل مابین GPS-VTEC و VTEC حاصل از مدل‌های LS-SVR و IRI2016 GIM را در دو ایستگاه کنترل برای روز ۲۲۸ (روز ۳۶ از مشاهدات) نشان می‌دهد. لازم به ذکر است که به دلیل خطای زیاد سایر مدل‌ها نسبت به مدل LS-SVR، مقایسه فقط برای مدل جدید گرفته شده است.



شکل ۱۱- قدر مطلق تفاضل مابین GPS-VTEC و VTEC مدل‌های LS-SVR و IRI2016 GIM در ایستگاه کنترل داخلی TABZ برای روز ۲۲۸



شکل ۱۲- قدر مطلق تفاضل مابین GPS-VTEC و VTEC مدل‌های LS-SVR و IRI2016 GIM در ایستگاه کنترل داخلی KLBR برای روز ۲۲۸

مطابق با نتایج حاصل از شکل‌های (۱۱، ۱۲) در ایستگاه کنترل داخلی TABZ حداقل و حداقل اختلاف بین GPS-VTEC و LSSVR-VTEC به ترتیب ۰/۲۵ و ۰/۸۹ TECU می‌باشد. این مقادیر در ایستگاه کنترل KLBR به ترتیب ۰/۷۵ و ۰/۸۵ TECU می‌باشند. میانگین خطای مدل LS-SVR در ایستگاه‌های TABZ و KLBR شده است. به عبارت دیگر مدل جدید قابلیت پیش‌بینی سری زمانی VTEC را با دقت ۱/۰۲ TECU دارد. برای مدل‌های GIM و IRI2016، میانگین خطای دو ایستگاه کنترل به ترتیب ۰/۲۶ و ۰/۲۲ TECU است. نتایج نشان می‌دهد که مدل جدید ارائه شده در این مقاله از دقت بالایی در پیش‌بینی سری‌های زمانی یونسفر برخوردار است.

- Radio Science*, vol. 43, no. 05, pp. 1-14, 2008, doi: <https://doi.org/10.1029/2007RS003786>.
- [2] M.-R. G. Razin, "Development and analysis of 3D ionosphere modeling using base functions and GPS data over Iran," *Acta Geodaetica et Geophysica*, vol. 51, pp. 95-111, 2016.
- [3] M. R. G. Razin and B. Voosoghi, "Regional ionosphere modeling using spherical cap harmonics and empirical orthogonal functions over Iran," *Acta Geodaetica et Geophysica*, vol. 52, pp. 19-33, 2017, doi: <https://doi.org/10.1007/s40328-016-0162-8>.
- [4] Amerian, Y., Voosoghi, B., and Y. Amerian, B. Voosoghi, and M. M. Hossainali, "Regional ionosphere modeling in support of IRI and wavelet using GPS observations," *Acta Geophysica*, vol. 61, pp. 1246-1261, 2013.
- [5] H. Etemadfar and M. Mashhadi Hossainali, "Application of Slepian theory for improving the accuracy of SH-based global ionosphere models in the Arctic region," *Journal of Geophysical Research: Space Physics*, vol. 121, no. 3, pp. 2583-2594, 2016, doi: <https://doi.org/10.1002/2015JA021811>.
- [6] M. A. Sharifi and S. Farzaneh, "Regional TEC dynamic modeling based on Slepian functions," *Advances in Space Research*, vol. 56, no. 5, pp. 907-915, 2015, doi: <https://doi.org/10.1016/j.asr.2015.05.024>.
- [7] R. Mautz, J. Ping, K. Heki, B. Schaffrin, C. Shum, and L. Potts, "Efficient spatial and temporal representations of global ionosphere maps over Japan using B-spline wavelets," *Journal of Geodesy*, vol. 78, pp. 662-667, 2005, doi: <https://doi.org/10.1007/s00190-004-0432-z>.
- [8] P. Muhtarov, I. Kutiev, and L. Cander, "Geomagnetically correlated autoregression model for short-term prediction of ionospheric parameters," *Inverse Problems*, vol. 18, no. 1, p. 49, 2002, doi: 10.1088/0266-5611/18/1/304.
- [9] P. Nematipour, M. Raoofian-Naeeni, and M. R. G. Razin, "Regional application of C1 finite element interpolation method in modeling of ionosphere total electron content over Europe," *Advances in space research*, vol. 69, no. 3, pp. 1351-1365, 2022, doi: <https://doi.org/10.1016/j.asr.2021.11.030>.
- [10] H. Jang and E. Topal, "A review of soft computing technology applications in several mining problems," *Applied Soft Computing*, vol. 22, pp. 638-651, 2014, doi: <https://doi.org/10.1016/j.asoc.2014.05.019>.
- [11] L. R. Cander, R. Leitinger, and M. Levy, "Ionospheric models including the auroral environment," in *Workshop on Space Weather, Report WPP-155, Noordwijk, The Netherlands, European Space Agency (ISSN 1022-6656)*, 1999, pp. 135-142.
- [12] J. B. Habarulema, L. A. McKinnell, and B. D. Opperman, "Regional GPS TEC modeling; Attempted spatial and temporal extrapolation of TEC using neural networks," *Journal of geophysical research: space physics*, vol. 116, no. A4, 2011.

خارج از محدوده شبکه مورد مطالعه نشان داد که دقت مدل LS-SVR نسبت به سایر مدل‌ها بیشتر است. خطای مدل LS-SVR در ایستگاه کنترل خارجی TEHN بیشتر از ایستگاه ARUC است. به عبارت دیگر، با دور شدن از محدوده شبکه GPS، خطای مدل‌های یادگیری ماشین افزایش می‌یابد. همچنین اگر در مرحله آموزش از مشاهدات ایستگاه‌های کنترل خارجی استفاده شود، خطای مدل‌ها کمتر خواهد بود. همچنین تحلیل سری زمانی VTEC پیش‌بینی شده با مدل جدید ارائه شده در این مقاله نشان داد که این مدل توانایی پیش‌بینی مقدار VTEC با خطای در حدود ۱/۸۹ TECU را دارد.

در تحقیقات مشابه دیگری که در مورد مدل سازی TEC با مدل‌های یادگیری ماشین در سالیان اخیر انجام گرفته شده است مخصوصاً تحقیقات نظام‌زاده و همکاران [۲۳، ۱۴۰۲]، فیضی و همکاران، ۲۰۲۱؛ غفاری رزین و همکاران، ۲۰۲۲ به دقت‌های در حدود ۱ TECU دست یافته‌اند؛ اما با استیتی اشاره کرد که الگوریتم آموزش و همچنین مشاهدات مورد استفاده در این تحقیقات متفاوت از تحقیق حاضر بوده است. علی‌ایحال مقایسه نتایج حاصل از این مقاله با سه تحقیق اشاره شده در بالا نشان‌دهنده بهبود دقت مدل سازی با روش جدید LS-SVR نسبت به مدل‌های دیگر استفاده شده است. نتایج این مقاله نشان داد که مدل LS-SVR از قابلیت بسیار بالایی در مدل سازی و پیش‌بینی تعییرات مکانی-زمانی در VTEC برخوردار است. تجزیه و تحلیل‌ها نشان داد که دقت این مدل در محدوده شبکه GPS بسیار بالا است؛ اما با دور شدن از محدوده شبکه GPS، دقت مدل کاهش می‌یابد؛ اما دقت مدل جدید در ایستگاه‌های کنترل بیرونی بیشتر از مدل‌های GIM و IRI2016 است. این مدل یک مدل یونسfer محلی است و از دقت و سرعت محاسباتی بالایی برخوردار است.

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندها نشده است.

تشکر و قدردانی

نویسندها از سازمان نقشه‌برداری کشور (NCC) به جهت در اختیار گذاشتن داده‌های ایستگاه‌های شبکه محلی آذربایجان تشکر و قدردانی می‌کنند. همچنین از داوران محترم به سبب ارائه نکات بسیار ارزشمند علمی، قدردانی می‌شود.

مراجع

- [1] I. Sayin, F. Arikan, and O. Arikan, "Regional TEC mapping with random field priors and kriging,"

- [22] M.-R. Ghaffari Razin and S. Inyurt, "Spatiotemporal analysis of precipitable water vapor using ANFIS and comparison against voxel-based tomography and radiosonde," *GPS Solutions*, vol. 26, pp. 1-13, 2022, doi: <https://doi.org/10.1007/s10291-021-01184-1>.
- [23] D. Bilitza, L.-A. McKinnell, B. Reinisch, and T. Fuller-Rowell, "The international reference ionosphere today and in the future," *Journal of Geodesy*, vol. 85, pp. 909-920, 2011.
- [24] L. Ciraolo, F. Azpilicueta, C. Brunini, A. Meza, and S. M. Radicella, "Calibration errors on experimental slant total electron content (TEC) determined with GPS," *Journal of geodesy*, vol. 81, pp. 111-120, 2007, doi: <https://doi.org/10.1007/s00190-006-0093-1>.
- [25] C. Cortes and V. Vapnik, , "Support-vector networks," *Machine learning*, vol. 20, , pp. 273-297, 1995, doi: <https://doi.org/10.1007/BF00994018>.
- [26] J. Suykens, T. Van Gestel, J. De Brabanter, B. De Moor, J. Vandewalle, "Least squares Support Vector Machines". <https://doi.org/10.1142/5089>.
- [27] G. Matheron, "The theory of regionalized variables and its applications: Centre de Geostatistique," *Fontainebleau, France*, 1971.
- [28] V. R. Joseph, "Limit kriging," *Technometrics*, vol. 48, no. 4, pp. 458-466, 2006, doi: <https://doi.org/10.1198/004017006000000011>.
- [29] S. Erdogan, "Modelling the spatial distribution of DEM error with geographically weighted regression: An experimental study," *Computers & Geosciences*, vol. 36, no. 1, pp. 34-43, 2010, doi: <https://doi.org/10.1016/j.cageo.2009.06.005>.
- [30] J. Li and A. D. Heap, *A Review of Spatial Interpolation Methods for Environmental Scientists*. Geoscience Australia Canberra, 2008.
- [31] S. Schaer, and S. h. d. s. n. C. géodésique, *Mapping and predicting the Earth's ionosphere using the Global Positioning System*: Institut für Geodäsie und Photogrammetrie, Eidg. Technische Hochschule ..., 1999.
- [32] M. S. Nezamzadeh, B. Voosoghi, S. R. Ghaffari Razin, "Evaluation of the effect of solar and geomagnetic parameters in spatio-temporal modeling of ionosphere's total electron content using machine learning methods," *journal of the earth and space physisc*. Vol. 49, no. 1, pp. 153-169.
- [13] M. R. G. Razin, B. Voosoghi, and A. Mohammadzadeh, "Efficiency of artificial neural networks in map of total electron content over Iran," *Acta Geodaetica et Geophysica*, vol. 51, pp. 541-555, 2016, doi: 10.1007/s40328-015-0143-3.
- [14] A. Tebabal, S. Radicella, B. Damtie, Y. Migoya-Orue, M. Nigussie, and B. Nava, "Feed forward neural network based ionospheric model for the East African region," *Journal of atmospheric and solar-terrestrial physics*, vol. 191, p. 105052, 2019, doi: <https://doi.org/10.1016/j.jastp.2019.05.016>.
- [15] S. Inyurt and A. Sekertekin, "Modeling and predicting seasonal ionospheric variations in Turkey using artificial neural network (ANN)," *Astrophysics and Space Science*, vol. 364, no. 4, p. 62, 2019, doi: <https://doi.org/10.1007/s10509-019-3545-9>.
- [16] R. Feizi, B. Voosoghi, and M. R. G. Razin, "Regional modeling of the ionosphere using adaptive neuro-fuzzy inference system in Iran," *Advances in Space Research*, vol. 65, no. 11, pp. 2515-2528, 2020, doi: <https://doi.org/10.1016/j.asr.2020.02.027>.
- [17] C. Cesaroni, L. Spogli, A. Aragon-Angel, M. Fiocca, V. Dear, G. De Franceschi, and V. Romano, "Neural network based model for global Total Electron Content forecasting," *Journal of space weather and space climate*, vol. 10, p. 11, 2020, , doi: <https://doi.org/10.1051/swsc/2020013>.
- [18] L. Liu, S. Zou, Y. Yao, and Z. Wang, "Forecasting global ionospheric TEC using deep learning approach," *Space Weather*, vol. 18, no. 11, pp. e2020SW002501, 2020, doi: <https://doi.org/10.1029/2020SW002501>.
- [19] G. Xia, Y. Liu, T. Wei, Z. Wang, W. Huang, Z. Du, Z. Zhang, X. Wang, and C. Zhou, "Ionospheric TEC forecast model based on support vector machine with GPU acceleration in the China region," *Advances in Space Research*, vol. 68, no. 3, pp. 1377-1389, 2021, doi: <https://doi.org/10.1016/j.asr.2021.03.021>.
- [20] M. Adolfs, and M. M. Hoque, "A neural network-based TEC model capable of reproducing nighttime winter anomaly," *Remote Sensing*, vol. 13, no. 22, pp. 4559, 2021, doi: <https://doi.org/10.3390/rs13224559>.
- [21] A. J. Smola, and B. Schölkopf, "On a kernel-based method for pattern recognition, regression, approximation, and operator inversion," *Algorithmica*, vol. 22, pp. 211-231, 1998, doi: <https://doi.org/10.1007/PL00013831>.