

Original Research Paper

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 Seyed Reza Ghaffari-Razin^{3*}

1, 2. Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran

3. Department of Surveying Engineering, Arak University of Technology, Arak, Iran

ARTICLE INFO**Article History:**

Received 15 July 2023

Revised 19 September 2023

Accepted 19 September 2023

Available Online 10 December 2023

Keywords:

Ionosphere

TEC

GPS

Machine learning

LS-SVR

ABSTRACT

In this paper, we aim to employ the least squares support vector regression (LS-SVR) for the spatio-temporal modeling of the ionospheric total electron content (TEC). This model utilizes simple linear equations to solve the system of equations, thereby reducing the computational complexity and enhancing both the speed of convergence and the accuracy of the results. We utilized observations from 15 GPS stations in north-western Iran from day 193 to day 228 in 2012. The results of the LS-SVR model were compared with those of support vector regression (SVR), artificial neural networks (ANN), adaptive neuro-fuzzy inference system (ANFIS), Kriging model, global ionospheric maps (GIM), and the International Reference Ionosphere 2016 (IRI2016) as well as TEC values obtained from GPS. The accuracy of all models was evaluated and interpreted at interior and exterior control stations. The analyses indicate that the average root mean square error (RMSE) for the ANN, ANFIS, SVR, LS-SVR, Kriging, GIM, and IRI2016 models at two interior control stations are 3.91, 2.73, 1.27, 1.04, 2.70, 3.02, and 6.93 TECU, respectively. Furthermore, the average relative errors of these models at the same control stations were calculated as 15.98%, 9.39%, 7.85%, 6.09%, 11.60%, 12.54%, and 26.56%, respectively. Analysis of the precise point positioning (PPP) method demonstrated an improvement of 50 mm in the coordinate components using the LS-SVR model. The results of this study demonstrate that the LS-SVR model can serve as a viable alternative to global and empirical models of the ionosphere in the studied area. The LS-SVR model provides a high-precision local ionosphere model.

*Corresponding Author's E-mail: mr.ghafari@arakut.ac.ir**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), <https://doi.org/10.22034/jsst.2024.1454>.**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/).

ارزیابی کارایی مدل کمترین مربعات رگرسیون بردار پشتیبان در مدل سازی محلی محتوای الکترون کلی یونسفر و مقایسه آن با سایر مدل ها

تائیا منصورفلاح^۱، بهزاد وثوقی^۲، و سیدرضا غفاری رزین^{۳*}

۱- دانشجوی کارشناسی ارشد، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

۲- استاد، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

۳- استادیار، گروه مهندسی عمران و نقشه برداری، دانشگاه صنعتی اراک، اراک، ایران

چکیده

اطلاعات مقاله

در این مقاله، هدف استفاده از مدل کمترین مربعات رگرسیون بردار پشتیبان (LS-SVR) جهت مدل سازی مکانی-زمانی مقدار محتوای الکترون کلی یونسفر (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 مدل های رگرسیون بردار پشتیبان (SVR)، مدل شبکه عصبی مصنوعی (ANN)، مدل استنتاج عصبی-فازی سازگار (ANFIS)، مدل کریجینگ، مدل GIM، مدل تجربی بین المللی مرجع یونسفر ۲۰۱۶ (IRI2016) و همچنین مقادیر TEC حاصل از GPS به عنوان مشاهده مرجع انجام می گیرد. دقت همه مدل ها در ایستگاه های کنترل داخلی و خارجی ارزیابی و تفسیر شده است. آنالیزهای انجام گرفته نشان می دهد که میانگین RMSE مدل های ANN، ANFIS، SVR، LS-SVR، Kriging، TECU ۶/۹۳ و GIM در دو ایستگاه کنترل داخلی به ترتیب برابر با ۳/۹۱، ۲/۷۳، ۱/۲۷، ۱/۰۴، ۲/۷۰، ۳/۰۲ و ۳/۰۲ بوده است. تجزیه و تحلیل روش PPP بهبود ۵۰ میلی متری در مؤلفه های مختصات با استفاده از مدل LS-SVR را نشان می دهد. نتایج این مقاله نشان می دهد که مدل LS-SVR را می توان به عنوان جایگزینی برای مدل های جهانی و تجربی یونسفر در منطقه مورد مطالعه در نظر گرفت. مدل LS-SVR یک مدل یونسفر محلی با دقت بالا محسوب می شود.

تاریخچه مقاله:

دریافت ۲۴ تیر ۱۴۰۲

بازنگری ۲۸ شهریور ۱۴۰۲

پذیرش ۲۸ شهریور ۱۴۰۲

اولین انتشار ۱۹ آذر ۱۴۰۲

واژه های کلیدی:

یونسفر

TEC

GPS

یادگیری ماشین

LS-SVR

*پست الکترونیکی نویسنده مسئول: mr.ghafari@arakut.ac.ir

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), <https://doi.org/10.22034/jsst.2024.1454>.



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/).



علائم و اختصارات

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

مقدمه

لایه یونسفر^۱ قسمتی از جو زمین است که تحت تأثیر تشعشعات پرنرژی 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، پلاسما گفته می‌شود. محدوده ارتفاعی پوشش داده شده توسط لایه یونسفر 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 هوایی زمین نظیر دما، رعد و برق و بارش تأثیرگذار است. تأثیر محتوای الکترونی لایه یونسفر بر سیگنال‌های سامانه تعیین موقعیت جهانی^۲ (GPS)، استفاده از مشاهدات این سیستم را به روشی مؤثر و کارآمد در تعیین زمانی-مکانی محتوای الکترونی کلی^۳ (TEC) و چگالی الکترونی یونسفر^۴ (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 تغییرات چگالی الکترونی در لایه یونسفر هنوز به‌عنوان یک چالش جدی برای ژئودزین‌ها و دانشمندان علوم فضایی مطرح است. این امر تا حدی به دلیل رفتار غیرخطی پارامترهای فیزیکی و ژئوفیزیکی مؤثر در تغییرات چگالی الکترونی و همچنین وجود مشکل در اندازه‌گیری دقیق برخی از این پارامترها می‌باشد. علاوه بر این، تغییرات این پارامترها در حوزه زمان نیز پیچیدگی مسئله مدل‌سازی یونسفر را بیشتر می‌کند. تابش تشعشعات خورشیدی منبع دیگری است که در رفتار این لایه از جو بسیار تأثیرگذار است. با توجه به ساختار چندلایه یونسفر، امواج الکترومغناطیسی گذرنده از این لایه‌ها تحت تأثیر خاصیت پاشندگی^۵ قرار می‌گیرند. به همین جهت مدل‌سازی این لایه از جو دارای اهمیت فوق‌العاده‌ای است.

تاکنون تلاش‌های بسیار زیادی جهت درون‌یابی و یا برون‌یابی TEC در مناطقی که مشاهده کافی و یا مناسب موجود نیست، صورت گرفته است. به‌طور مثال می‌توان به روش‌های کریجینگ [۱]، چندجمله‌ای، هارمونیک‌های کروی [۲]، هامونیک‌های کلاه کروی [۳]، درون‌یابی به کمک توابع اسپیلاین و موجک [۴]، مدل‌سازی با توابع اسلپین [۵-۷]، توابع اتورگرسیون و اتوکووارانس [۸]، درون‌یابی با روش المان‌های محدود^۱ C^۱ [۹] اشاره کرد. از این روش‌ها به‌کرات 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^۶ (ML) هستند. یادگیری ماشین شامل سیستم استنتاج فازی (FIS)، شبکه‌های عصبی مصنوعی (ANN)، الگوریتم ژنتیک (GA)، ماشین‌های بردار پشتیبان (SVMs) و ارتباطات تکاملی (EC) است [۱۰]. از سال ۱۹۹۳، با پیشرفت فناوری رایانه، بسیاری از الگوریتم‌های جدید و ترکیبی، مانند سیستم استنتاج عصبی فازی تطبیقی (ANFIS) در ML توسعه یافته‌اند. در دهه‌های اخیر از روش‌های یادگیری ماشین در مدل‌سازی یونسفر و تروپوسفر فراوان استفاده شده و نتایج قابل قبولی ارائه شده است [۲۰-۱۱].

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 تغییرات با فرکانس بالای زمانی که می‌تواند دارای الگوی متفاوتی در مکان‌های مختلف باشد، در این مدل‌ها بازتاب داده شود. مدل تجربی یونسفری IRI از سوی دیگر، دارای دقت مناسبی در پیش‌بینی یونسفر نیست و نمی‌توان برای کاربردهای دقیق آنی از آن استفاده کرد. با توجه به اینکه تغییرات زمانی-مکانی یونسفر بسیار نامنظم است، می‌بایست از یک روش جدید با دقت و صحت بالاتر برای بازیابی این تغییرات استفاده نمود. ماشین بردار پشتیبان^۷ (SVM) یک نوع سیستم یادگیری نظارت‌شده است که برای مسائل طبقه‌بندی به‌کار می‌رود به‌طوری که کمترین خطا در طبقه‌بندی داده‌ها رخ دهد. این روش بر مبنای تئوری یادگیری آماری استوار است که از اصل کمینه‌سازی خطای ساختاری بهره

5. Dispersive
6. Machine Learning
7. Support Vector Machine

1. Ionosphere
2. Global Positioning System
3. Total Electron Content
4. Ionosphere Electron Density

استخراج مشاهدات TEC دقیق

سیگنال‌های GPS دو مشاهده اصلی تحت عنوان شبه‌فاصله کد و فاز موج دریافتی را در اختیار می‌گذارند. واحد شبه‌فاصله کد به متر است که فاصله میان گیرنده تا ماهواره را در خود اندازه‌گیری کرده است. به جهت متأثر بودن این مشاهده از بسیاری از منابع خطا، مشاهده کد به شبه‌فاصله شناخته می‌شود. مشاهده فاز موج حامل برحسب سیکل^۶ اندازه‌گیری می‌شود و از آنجایی که نسبت به مشاهده کد از طول موج کوتاه‌تری برخوردار است با دقت یک‌صدم سیکل قابل‌اندازه‌گیری می‌باشد. گیرنده GPS فاز موج حامل را اندازه‌گیری می‌کند اما تعداد سیکل‌های کامل طی شده توسط موج که به پارامتر ابهام فاز^۷ معروف است مجهول بوده و قابل‌اندازه‌گیری نیست. ابهام فاز با تشکیل ترکیب تفاضلی دوگانه مشاهدات و استفاده از روش‌های پردازش مختلف نظیر ترکیب ملبورن-ووبنا^۸، ترکیب طول موج بلند^۹ و به‌کارگیری مدل‌های یونسفری جهانی نظیر GIM می‌تواند تعیین گردد. از کم کردن 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]:

$$P_{L,r}^s = 40.3 \left(\frac{f_2^2 - f_1^2}{f_1^2 f_2^2} \right) STEC_r^s + c (\tau_{L1}^s - \tau_{L2}^s + \tau_{L1,r} - \tau_{L2,r}) \quad (۱)$$

$$L_{L,r}^s = -40.3 \left(\frac{f_2^2 - f_1^2}{f_1^2 f_2^2} \right) STEC_r^s + (T_{L1}^s - T_{L2}^s + T_{L1,r} - T_{L2,r}) + \lambda_1 N_1 - \lambda_2 N_2 \quad (۲)$$

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 ابهام 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 به‌صورت زیر خلاصه می‌شوند:

$$\tau_{L1}^s - \tau_{L2}^s = bs \quad (۳)$$

$$\tau_{L1,r} - \tau_{L2,r} = br \quad (۴)$$

$$T_{L1,r} - T_{L2,r} = Br \quad (۵)$$

$$T_{L1}^s - T_{L2}^s = Bs \quad (۶)$$

به پارامترهای bs و br به ترتیب بایاس تفاضلی کد^{۱۰} (DCB) برای ماهواره s و گیرنده r و به پارامترهای Br و Bs به ترتیب بایاس تفاضلی

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 پشتیبان^۱ (SVR) نامیده شد [۲۱]. با این حال، روش رگرسیون بردار پشتیبان دارای معایبی است. سرعت همگرایی به جواب بهینه در این مدل در تعداد زیاد مشاهدات ورودی به شدت کاهش پیدا کرده و الگوریتم کند عمل می‌کند. همچنین در صورت عدم توزیع مناسب ایستگاه‌ها، دقت این مدل به شدت کاهش می‌یابد. برای غلبه بر این محدودیت‌ها، در این مقاله ایده استفاده از مدل کمترین مربعات رگرسیون بردار پشتیبان^۲ (LS-SVR) ارائه می‌شود. مدل LS-SVR از معادلات خطی ساده برای حل سیستم معادلات استفاده می‌کند. در نتیجه، 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 یونسفر به کمک مدل کمترین مربعات رگرسیون بردار پشتیبان و با استفاده 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 مدل‌سازی در دقت تعیین موقعیت مطلق نیز مورد بررسی قرار خواهد گرفت. در حقیقت نوآوری اصلی این مقاله در استفاده توأمان متغیرهای مکانی، زمانی، خورشیدی و ژئومغناطیسی در مرحله مدل‌سازی و ارزیابی نتایج در حالت‌های مختلف می‌باشد. همچنین مدل‌سازی و پیش‌بینی مقدار TEC روزانه از دیگر نوآوری‌های این مقاله است. جهت نشان دادن دقت و صحت بالاتر مدل جدید ارائه شده و همچنین بهبود اتفاق افتاده در مدل‌سازی، نتایج با مدل‌های شبکه عصبی مصنوعی^۳ (ANN)، مدل استنتاج عصبی-فازی سازگار^۴ (ANFIS)، SVR، مدل کریجینگ^۵، GIM 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 مربعات 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، در نتیجه جهت آشنایی با تئوری ریاضی این مدل‌ها، خوانندگان محترم می‌توانند به مراجع [۲۲، ۲۳] مراجعه نمایند.

6. Cycle
7. Phase Ambiguity
8. Melbourne-Wubbena
9. Wide-Lane
10. Differential Code Bias

1. Support Vector Regression
2. Least-Square Support Vector Regression
3. Artificial Neural Network
4. Adaptive Neuro-Fuzzy Inference System Model
5. Kriging

$$L(\mathbf{w}, \mathbf{b}, e; a) = \frac{\gamma}{2} \sum_{n=1}^N e_n^2 + \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{n=1}^N a_n \{ \mathbf{w}^T \phi(\mathbf{x}) + \mathbf{b} - 1 + e_n \} \quad (9)$$

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

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

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

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

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

تابع رگرسیون پیش بینی مدل LS-SVR همانند مدل رگرسیون بردار پشتیبان است که با رابطه زیر مشخص می شود:

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

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

$$K(\mathbf{x}, x_n) = \langle \phi(\mathbf{x}), \phi(x_n) \rangle \quad (13)$$

توابع کرنل خطی، چندجمله ای و شعاعی را می توان در رابطه (۱۲) مورد استفاده قرار داد که از بین آن ها، کرنل شعاعی بیشترین سرعت و کمترین خطا را داراست.

مدل کریجینگ

کریجینگ یکی از مناسب ترین و پیشرفته ترین تکنیک های تحلیل داده های مکانی است. کریجینگ یک روش درون یابی بهینه است که در آن متغیرها تصادفی هستند و تابع هندسی خاصی را دنبال نمی کنند. این روش در دهه شصت توسط مهندس فرانسوی ماترون (۱۹۷۱) مورد استفاده قرار گرفت [۲۷]. کریجینگ یک برآوردگر بی طرفانه با کمترین واریانس تخمین است. شرط بی طرفانه در سایر روش های تخمین مانند فاصله معکوس و مجذور فاصله معکوس نیز اعمال می شود، اما ویژگی کریجینگ این است که ضرایب مجهول را به گونه ای تعیین می کند که واریانس تخمین ها نیز حداقل باشد [۲۸]. کریجینگ بر اساس میانگین μ ثابت برای داده ها و خطاهای تصادفی ε با وابستگی مکانی به شرح زیر است:

فاز برای ماهواره s و گیرنده r گفته می شود. مقدار bs برای کلیه ماهواره های GPS از سوی سرویس IGS در فایل های مدل جهانی GIM در اختیار قرار می گیرند. مقادیر DCB گیرنده ها در مرحله پیش پردازش مشاهدات و در نرم افزار یونولب محاسبه شده است.

کمترین مربعات ماشین بردار پشتیبان

ماشین بردار پشتیبان نوعی سیستم یادگیری کارآمد بر مبنای تئوری بهینه سازی مقید است. در این مدل از اصل استقرای کمینه سازی خطای ساختاری استفاده و به یک جواب بهینه کلی منجر می شود. در این مدل برای حل معادلات از برنامه ریزی دوگانه^۲ استفاده می شود [۲۵]؛ بنابراین، حل مسائل در ابعاد بزرگ با استفاده از مدل یاد شده، هزینه محاسباتی را به شدت افزایش می دهد. برای رفع این مشکل، سوکنز و همکاران [۲۶]، روش کمترین مربعات رگرسیون بردار پشتیبان (LS-SVR) را ارائه کردند. در این مدل از معادلات خطی ساده برای حل مسائل استفاده می شود که به طور مؤثری پیچیدگی الگوریتم را کاهش می دهد. با این حال، پیش نیاز 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 تعمیم^۳ خوب دارند. مدل LS-SVR در حقیقت فرمول بندی مجدد مدل SVR است. الگوریتم LS-SVR می تواند پایداری بالاتر را مشخص کند و با سرعت بیشتری نسبت به SVR آموزش ببیند. می توان مدل رگرسیون LS-SVR را با حل مسئله بهینه سازی زیر به دست آورد:

$$\frac{\gamma}{2} \sum_{n=1}^N e_n^2 + \frac{1}{2} \|\mathbf{w}\|^2 \quad (7)$$

با محدودیت:

$$y_i = \mathbf{w}^T \cdot \Phi(x_i) + \mathbf{b} + e_i \quad (8)$$

$$i = 1, 2, \dots, N$$

در روابط بالا، γ پارامتر تنظیم کننده بخش خطا (مشابه پارامتر C در مدل SVR)، e_i خطای داده های آموزش، $\Phi(x_i)$ ترسیم غیرخطی ورودی ها در فضای ویژگی با ابعاد زیاد، پارامترهای \mathbf{w} و \mathbf{b} به ترتیب مقادیر وزن و بایاس تابع رگرسیون هستند. تابع لاگرانژ برای حل مسئله بهینه سازی (۷) به صورت زیر ساخته می شود:

ساعت است. با این حال، تحقیقات نشان داده است که تغییرات زمانی یونسفر دارای فرکانس کمتر از ۲ ساعت است. این تغییرات در طول دوره‌های فعالیت خورشیدی افزایش می‌یابد؛ بنابراین، درک رفتار زمانی یونسفر 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 SVR، ANFIS، ANN و LS-SVR از هفت پارامتر طول و عرض جغرافیایی ایستگاه GPS، روز از سال^۳ (DOY)، زمان به وقت جهانی^۴ (UT)، پارامترهای ژئومغناطیسی KP و DST، همچنین پارامتر مرتبط با شاخص فعالیت‌های خورشیدی یعنی شار خورشیدی یا F10.7 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 (KP، DST و F10.7) در آموزش مدل‌ها شرکت داده می‌شوند. خروجی متناظر با بردار ورودی 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^۵ (تابع هزینه) تعریف شده برای همه مدل‌های یادگیری ماشین مورد استفاده در این مقاله، به صورت زیر می‌باشد:

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

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

شاخص‌های آماری

ارزیابی نتایج مدل‌های ANN، ANFIS، SVR، LS-SVR، کریجینگ، IRI2016 و GIM در مدل‌سازی زمانی-مکانی محتوای الکترون کلی

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

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

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

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 درون‌یابی 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^۱ استفاده شده است. در این روش برای بیان تغییرات 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:

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

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

مدل GIM

نقشه‌های جهانی یونسفر (GIM-TEC) توسط IGS در یک بازه زمانی ۲ ساعته ارائه می‌شود. توابع هارمونیک کروی (SH) برای مدل‌سازی 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 ژئومغناطیسی نقطه نفوذ یونسفری^۲ (IPP) است، λ طول جغرافیایی ثابت خورشیدی در نقطه IPP، n و m به ترتیب درجه و مرتبه مدل، \tilde{P}_{mn} تابع لژاندر نرمالیزه شده، a_{nm} و b_{nm} به ترتیب ضرایب مجهول و پارامترهای مدل GIM هستند. رزولوشن زمانی TEC محاسبه شده با مدل GIM، ۲

4. Universal Time
5. Cost Function

1. Ordinary Kriging
2. Ionospheric Pierce Point
3. Day of Year

(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).

Fig. 1. The spatial distribution of training stations (black stars), internal control stations (green circles) and external control stations (red triangles).

مطابق با الگوریتم ارائه شده در بخش استخراج مشاهدات TEC دقیق و با استفاده از نرم‌افزار IONOLAB مقادیر VTEC در روزهای ۱۹۳ الی ۲۲۸ محاسبه شده و به‌عنوان 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 ایستگاه‌های مورد استفاده در این تحقیق، $0.97/TECU$ است. به عبارت دیگر، مقادیر VTEC ورودی به مدل‌های یادگیری ماشین و مدل کریجینگ خود دارای خطای $0.97/TECU$ هستند. فلوجارت چگونگی انجام مراحل آموزش و آزمون مدل‌های یادگیری ماشین و مدل کریجینگ در شکل (۲) نمایش داده شده است.

مطابق با فلوجارت 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.

یونسفر با استفاده از مقادیر VTEC حاصل از GPS به‌عنوان مشاهده مرجع 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:

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

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

$$RMSE = \sqrt{\frac{1}{M} \sum_{m=1}^M (VTEC_{model}^m - VTEC_{GPS}^m)^2} \quad (22)$$

در روابط بالا، $VTEC_{GPS}$ بیانگر مقدار حاصل از مشاهدات GPS (مشاهده مرجع) و $VTEC_{model}$ نشان‌دهنده مقدار حاصل از مدل‌ها می‌باشند. کمینه مقادیر خطای نسبی و RMSE صفر است. هرچه قدر 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.

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 ۲۲۸ (۳۶ روز) در سال ۱۳۹۱ می‌باشد. کلیه فایل‌های راینکس^۱ مربوط به ایستگاه‌های GPS از سازمان نقشه‌برداری کشور^۲ (NCC) تهیه شده است. ارتفاع این ایستگاه‌ها از ۱۲۸۰ تا ۱۹۵۲ متر بالاتر از سطح متوسط دریا^۳ (MSL) متغیر است. همچنین برای غلبه بر خطای چند مسیری از آنتن 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) به‌عنوان ایستگاه‌های کنترل داخلی^۴ انتخاب شده‌اند. به‌منظور ارزیابی دقت مدل‌ها خارج از محدوده شبکه GPS مورد مطالعه، ایستگاه‌های ARUC (40.17° N, 44.05° E) و TEHN (35.69° N, 51.33° E) به‌عنوان ایستگاه‌های کنترل خارجی^۵ انتخاب شده‌اند. شکل (۱) چگونگی توزیع ایستگاه‌های GPS

4. Interior Control Stations
5. Exterior Control Stations

1. Rinex
2. National Cartographic Center
3. Mean Sea Level

مربوط به بردار ورودی نیز به‌عنوان خروجی مدل‌ها در نظر گرفته می‌شود. پایگاه داده آموزش مدل‌ها شامل ۵۶۱۶ بردار ورودی و خروجی می‌باشد. جدول (۱) مقادیر RMSE، ضریب همبستگی و زمان همگرایی را در مرحله آموزش مدل‌های ANN، ANFIS، SVR و LS-SVR نشان می‌دهد. لازم به ذکر است که در این مقایسه VTEC به‌دست آمده از GPS به‌عنوان مشاهده مرجع در نظر گرفته شده است. همچنین محاسبات تمامی مدل‌ها بر روی کامپیوتری با سخت‌افزار و نرم‌افزار یکسان انجام شده است.

جدول ۱- مقادیر RMSE (TECU)، ضریب همبستگی و زمان همگرایی (برحسب ثانیه) در مرحله آموزش مدل‌های ANN، ANFIS، SVR و LS-SVR.

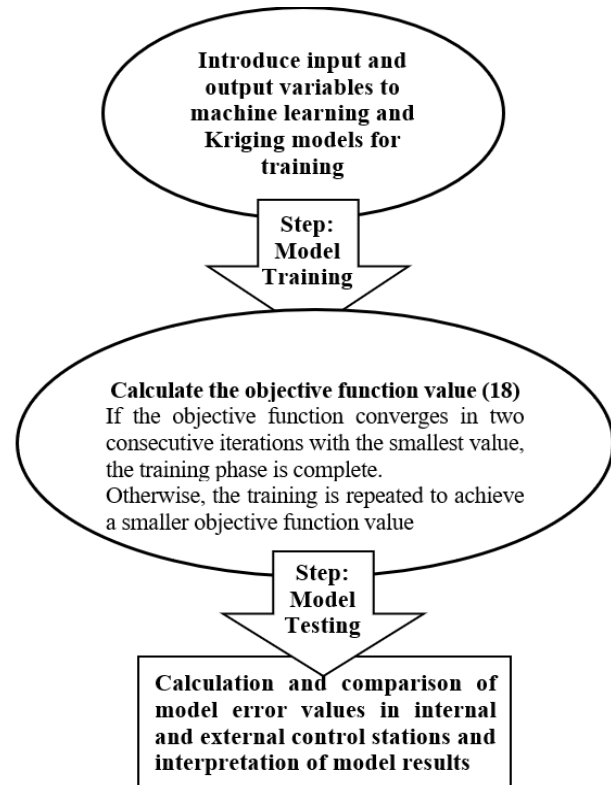
Table 1. RMSE (TECU) values, correlation coefficients, and convergence time (in seconds) in the training phase of ANN, ANFIS, SVR, and LS-SVR models.

Models	RMSE Error (TECU)	Training Correlation Coefficient	Convergence Time (in seconds)
Model ANN	1.82	0.93	88
Model ANFIS	1.52	0.95	342
Model SVR	1.28	0.97	79
Model LS-SVR	0.67	0.98	19

با توجه به جدول (۱)، نتایج مرحله آموزش مدل LS-SVR در هر سه پارامتر بهتر از مدل‌های دیگر است. در این مدل داده‌ها بر اساس کرنل شعاعی و معادلات خطی ساده آموزش داده می‌شوند؛ اما در ANN، ANFIS و SVR وزن اولیه کاملاً تصادفی است و خوشه‌بندی در حین آموزش و الگوریتم تکرار انجام می‌شود. در نتیجه مدل LS-SVR از دقت بالاتر و زمان همگرایی کمتری نسبت به مدل‌های دیگر در مرحله آموزش برخوردار است.

مرحله آزمون مدل‌های ANN، ANFIS، SVR و LS-SVR، کریجینگ، GIM و IRI2016

پس از مرحله آموزش مدل‌های یادگیری ماشین و انتخاب ساختار بهینه برای مدل‌ها، حال می‌توان از این مدل‌ها برای برآورد مقدار VTEC استفاده کرد. در این مرحله با مدل‌های آموزش دیده، مقدار VTEC در ایستگاه‌های کنترل داخلی برآورد و با مقدار VTEC به‌دست آمده از GPS (-GPS) مقایسه می‌شود. لازم به ذکر است که دو ایستگاه کنترل داخلی به‌گونه‌ای انتخاب شده‌اند که دقت مدل‌ها در شرایط متفاوت مورد ارزیابی قرار گیرد. به عبارت دیگر، ایستگاه کنترل TABZ توسط ایستگاه‌های آموزشی احاطه شده است، اما ایستگاه KLBR از ایستگاه‌های آموزشی



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

Fig. 2. Flowchart of how to use ANN, ANFIS, SVR, LS-SVR and Kriging models to estimate TEC value and evaluate their accuracy.

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.

مرحله آموزش مدل‌های ANN، ANFIS، SVR و LS-SVR




در مرحله آموزش ساختار بهینه مدل‌ها مشخص می‌شود. 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 مدل‌ها زمان همگرایی به جواب بهینه اندازه‌گیری می‌شود. 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 همه مدل‌ها در مرحله آموزش مقایسه می‌شوند. برای مدل‌های ANN، ANFIS، SVR و LS-SVR، بردار ورودی شامل طول و عرض جغرافیایی ایستگاه GPS، DOY، زمان، KP، DST و F10.7 است. مقدار VTEC

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 دقت بالاتری نسبت به سایر مدل‌ها برخوردار است. همچنین خطای RMSE و خطای نسبی مدل‌های ANN، ANFIS، SVR، کریجینگ و LS-SVR در ایستگاه KLBR بیشتر از ایستگاه TABZ 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 ANN است. مدل GIM مبتنی بر توابع هارمونیک کروی است. ضرایب این مدل با استفاده از مشاهدات ایستگاه‌های شبکه جهانی IGS برآورد می‌شوند؛ بنابراین، این یک مدل جهانی یونسفری است. در ایران به دلیل وجود تنها دو ایستگاه IGS، دقت TEC ارائه شده 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 یونسفر است. دقت این مدل به دقت مشاهدات ایستگاه‌های یونسفر و ISR بستگی دارد. به دلیل عدم وجود ایستگاه‌های یونسفر 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 تغییرات زمانی و مکانی را در VTEC تشخیص می‌دهد؛ اما دقت مدل‌سازی محلی آن پایین است. میانگین خطای RMSE مدل‌های ANN، ANFIS، SVR، کریجینگ، LS-SVR، GIM و IRI2016 در دو ایستگاه کنترل داخلی به ترتیب برابر با $۱/۲۷$ ، $۲/۷۳$ ، $۳/۹۱$ ، $۱/۲۷$ ، $۲/۷۰$ ، $۱/۰۴$ ، $۳/۰۲$ و $۶/۹۳$ TECU شده است؛ به عبارت دیگر در دو ایستگاه کنترل داخلی کمترین مقدار خطا مربوط به مدل‌های SVR و LS-SVR است.

برای تجزیه و تحلیل دقیق‌تر دقت مدل‌های یادگیری ماشین در مقایسه با مدل‌های جهانی، تجربی یونسفر و مدل کریجینگ، دو ایستگاه کنترل خارج از محدود 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 مجدداً آموزش مدل‌ها با استفاده از مشاهدات ایستگاه‌های کنترل خارجی. شکل (۴) نتایج این دو سناریو را نشان می‌دهد. لازم به ذکر است که میانگین RMSE برای تمام روزها در این دو شکل نشان داده شده است. همچنین VTEC حاصل از GPS به‌عنوان مشاهده مرجع در نظر گرفته شده است.

دورتر است. همچنین از مشاهدات ایستگاه‌های کنترل داخلی در مرحله آموزش استفاده نمی‌شود. شکل (۳) مقادیر RMSE، ضریب همبستگی و خطای نسبی مدل‌های ANN، ANFIS، SVR، LS-SVR، کریجینگ، GIM و IRI2016 را در دو ایستگاه کنترل داخلی نشان می‌دهد. لازم به ذکر است در تمامی محاسبات و مقایسه‌ها، VTEC حاصل از GPS به‌عنوان مشاهده مرجع در نظر گرفته شده است.




شکل ۳- مقایسه میانگین خطای RMSE (TECU)، ضریب همبستگی و خطای نسبی (بر حسب درصد) در ایستگاه‌های کنترل داخلی TABZ و KLBR برای مدل‌های ANN، ANFIS، SVR، LS-SVR، کریجینگ، GIM و IRI2016 در مرحله آزمون.

Fig. 3. Comparison of average RMSE error (TECU), correlation coefficient and relative error (in percent) in indoor control stations TABZ and KLBR for ANN, ANFIS, SVR, LS-SVR, Kriging, GIM and IRI2016 models in the test stage.


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 RMSE مدل ANFIS 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 شدن از محدوده شبکه، اعتبار این قوانین به شدت 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 مدل‌سازی دقیق VTEC استفاده از آن در تعیین موقعیت نقطه‌ای دقیق (PPP) با گیرنده‌های تک فرکانس است. معمولاً در یک گیرنده تک فرکانس، یک مدل یونسفری با دقت بالا برای تعیین موقعیت دقیق مورد نیاز است. روش PPP به‌عنوان یک رویکرد بهینه برای ارائه موقعیت ژئودتیک نقطه در حالت استاتیکی و کینماتیکی با استفاده از تمامی منظومه‌های تعیین موقعیت GNSS^۱ 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 فرکانسه را دریافت می‌کنند. هدف استفاده از داده‌های تک فرکانس تنها اعمال مدل‌های یونسفر برای اصلاح تأخیرهای یونسفری است، به‌جای استفاده از مشاهدات دو فرکانس که اثرات یونسفری را کلاً از بین می‌برد. از آنجایی که تأخیر یونسفری، خطای غالب در روش PPP با مشاهدات تک فرکانس است، نتایج آن را می‌توان به‌عنوان شاخصی برای ارزیابی دقت مطلق مدل‌های یونسفری استفاده کرد.

با استفاده از VTEC به‌دست 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 دقیق ایستگاه‌های کنترل، مجدداً تخمین زده می‌شود. مختصات حاصل از 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



(A)

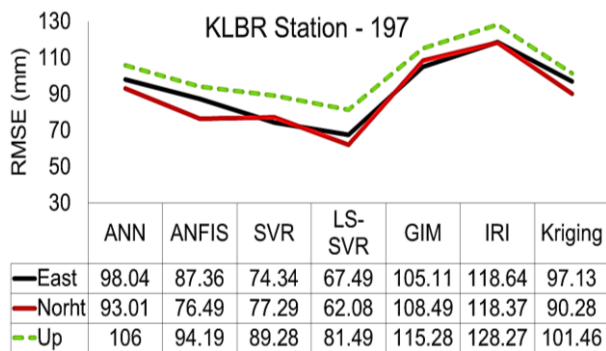


(B)


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

Fig. 4. Comparison of average RMSE (in terms of TECU) in the 36 days investigated for ANN, ANFIS, SVR, Kriging, LS-SVR, GIM and IRI2016 models in two external control stations in the mode of using the observations of these stations in the training phase (Figure A) and Not using observations in the training phase (Figure B).

مقایسه نتایج دو سناریو در نظر گرفته شده برای ارزیابی ایستگاه‌های کنترل خارجی به وضوح نشان می‌دهد که RMSE تمام مدل‌های یادگیری ماشین در حالت استفاده از مشاهدات برای مرحله آموزش کمتر از حالت دیگر است؛ به عبارت دیگر، خطای RMSE مدل‌ها 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



(A)



(B)


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

Fig. 6. RMSE error analysis (in mm) in coordinate components of KLBR indoor control station for ANN, ANFIS, SVR, Kriging, LS-SVR, GIM and IRI2016 models on day 197 (Figure a) and day 202 (Figure b).


مدل‌سازی مکانی-زمانی VTEC

پس از آموزش و تست مدل‌های ANN، ANFIS، SVR، کریجینگ و LS-SVR، حال می‌توان با استفاده از مدل‌های آموزش‌دیده، تغییرات مکانی-زمانی VTEC را در محدوده شبکه GPS برآورد کرد. در مراحل آنالیز خطای مدل‌ها، مدل LS-SVR نسبت به مدل‌های 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 ایستگاه‌های کنترل داخلی TABZ و KLBR نشان می‌دهد. همچنین در دو شکل (۸) و (۱۰)، تفاضل GPS-VTEC و VTEC مدل‌های LS-SVR و IRI2016 نشان داده شده است.

ژئومغناطیسی متفاوتی دارند، در دو ایستگاه کنترل داخلی TABZ و KLBR در شکل‌های (۵، ۶) نشان داده شده است. روز ۱۹۷ دارای فعالیت خورشیدی و ژئومغناطیسی بالاتری نسبت به روز ۲۰۲ است.



(A)



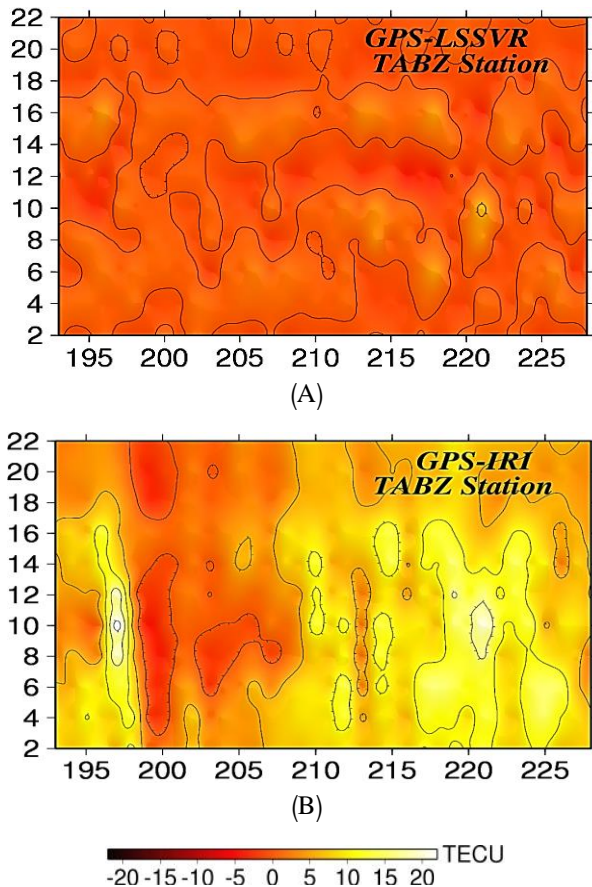
(B)

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

Fig. 5. Analysis of RMSE error (in mm) in coordinate components of TABZ indoor control station for ANN, ANFIS, SVR, Kriging, LS-SVR, GIM and IRI2016 models on day 197 (Figure a) and day 202 (Figure b).

دقت تعیین موقعیت با مدل‌های ANN، ANFIS، SVR، کریجینگ، LS-SVR، GIM و IRI2016 در ایستگاه کنترل TABZ بالاتر از KLBR است. تحلیل RMSE مؤلفه‌های مختصاتی ایستگاه‌های کنترل TABZ و KLBR نشان می‌دهد که در هر دو ایستگاه، مدل LS-SVR دارای RMSE کمتری نسبت به سایر مدل‌های دیگر است. مقایسه نتایج دو ایستگاه کنترل داخلی نشان دهنده بهبود ۱۰ تا ۵۴ میلی‌متری دقت تعیین موقعیت با استفاده از مدل LS-SVR نسبت به مدل‌های دیگر است. نتایج شکل‌های بالا نشان می‌دهد که برای مدل تجربی IRI2016 و مدل جهانی GIM در دو ایستگاه کنترل داخلی، خطای دقت تعیین موقعیت بهبود چندانی نداشته است. نکته مهم دیگر این است که RMSE همه مدل‌ها در فعالیت خورشیدی و ژئومغناطیسی بالا، بیشتر از حالت فعالیت‌های پایین است.


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 VTEC حاصل از GPS نشان می‌دهد. با این حال، برای مدل تجربی IRI2016، یک بیشینه VTEC در روزهای ۲۲۵ تا ۲۲۸ مشاهده می‌شود. این تغییرات با GPS-VTEC سازگار نیستند.



شکل ۸- تفاضل VTEC حاصل از GPS با VTEC مدل LS-SVR (شکل الف) و VTEC حاصل از مدل IRI (شکل ب) در ایستگاه کنترل داخلی TABZ، محور افقی نشان‌دهنده روز از سال (DOY) است و محور عمودی زمان به وقت جهانی (UT) را نشان می‌دهد.

Fig. 8. Difference of VTEC from GPS with VTEC from LS-SVR model (Figure a) and VTEC from IRI model (Figure b) at indoor control station TABZ, the horizontal axis represents the day of the year (DOY) and the vertical axis is the Universal Time (UT) is showing.


در ایستگاه کنترل KLBR، مدل LS-SVR تغییرات زمانی VTEC را مطابق با VTEC حاصل از 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 یونسفر در مدل‌سازی محلی برخوردار است.



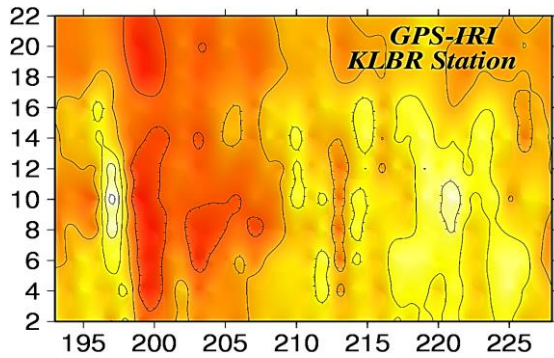
شکل ۷- مقایسه GPS-VTEC (شکل الف)، LSSVR-VTEC (شکل ب) و IRI-VTEC (شکل ج) در ایستگاه کنترل داخلی TABZ، محور افقی نشان‌دهنده روز از سال (DOY) است و محور عمودی زمان به وقت جهانی (UT) را نشان می‌دهد.

Fig. 7. Comparison of GPS-VTEC (Figure A), LSSVR-VTEC (Figure B) and IRI-VTEC (Figure C) at TABZ indoor control station. The horizontal axis represents the day of the year (DOY) and the vertical axis represents the time in Universal Time (UT).

مقایسه GPS-VTEC و VTEC حاصل از مدل LS-SVR تفاوتی در حدود ۰ تا ۴/۷۵ TECU را نشان می‌دهد؛ اما برای مدل IRI2016 تفاوت در حدود ۰ تا ۱۷/۵۰ TECU دیده می‌شود. این مقایسه نشان می‌دهد که مدل تجربی IRI2016 دقت محلی بسیار 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



(A)



(B)




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


Fig. 10. Difference of VTEC from GPS with VTEC from LS-SVR model (Figure a) and VTEC from IRI model (Figure b) at indoor control station KLBR, horizontal axis represents day of year (DOY) and vertical axis is Universal Time (UT) is showing.

پیش‌بینی زمانی VTEC


به‌منظور 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 LS-SVR برآورد شده و سپس با VTEC به‌دست آمده از GPS و همچنین مدل‌های GIM و IRI2016 مقایسه می‌شود. شکل‌های (۱۱، ۱۲) قدر مطلق تفاضل مابین GPS-




(A)



(B)



(C)



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

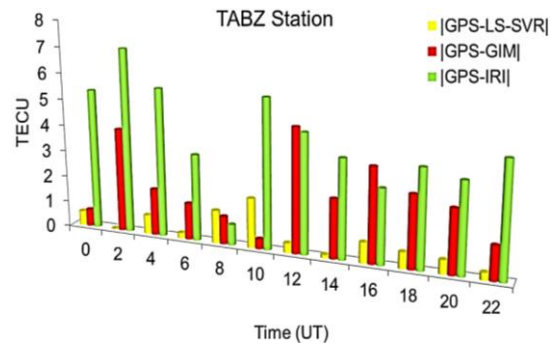
Fig. 9. Comparison of GPS-VTEC (Figure A), LSSVR-VTEC (Figure B) and IRI-VTEC (Figure C) at the indoor control station KLBR. The horizontal axis represents the day of the year (DOY) and the vertical axis represents the time in Universal Time (UT).

نتیجه‌گیری و بحث

هدف از این مقاله مدل‌سازی و پیش‌بینی مکانی-زمانی مقدار محتوای الکترون کلی یونسفر (TEC) با استفاده از مدل کمترین مربعات 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 به‌عنوان ایستگاه‌های کنترل داخلی انتخاب شدند. مشاهدات این ایستگاه‌ها از مرحله آموزش حذف شد. همچنین ایستگاه‌های ARUC و TEHN به‌عنوان 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 KP و DST، 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 به‌دست‌آمده با مدل‌های شبکه عصبی مصنوعی (ANN)، سیستم استنتاج عصبی-فازی سازگار (ANFIS)، رگرسیون برداری پشتیبان (SVR)، کریجینگ، GIM و IRI2016 مقایسه شد. شاخص‌های آماری خطای نسبی، خطای RMSE، ضریب همبستگی و dVTEC 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 ANN، ANFIS، SVR، کریجینگ، LS-SVR، GIM و IRI2016 در دو ایستگاه کنترل داخلی به ترتیب برابر با ۳/۹۱، ۲/۷۳، ۱/۲۷، ۲/۷۰، ۱/۰۴، ۳/۰۲ و ۶/۹۳ TECU بوده است. میانگین خطای نسبی مدل‌ها در دو ایستگاه کنترل داخلی به ترتیب برابر با ۱۵/۹۸، ۹/۳۹، ۷/۸۵، ۱۱/۶۰، ۶/۰۹، ۱۲/۵۴ و ۲۶/۵۶ درصد محاسبه شد. تجزیه و تحلیل خطا در ایستگاه‌های کنترل داخلی نشان داد که مدل LS-SVR دقت 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

VTEC و حاصل از مدل‌های LS-SVR، GIM و IRI2016 را در دو ایستگاه کنترل برای روز ۲۲۸ (روز ۳۶ام 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. مطابق با نتایج حاصل از شکل‌های (۱۱، ۱۲) در ایستگاه کنترل داخلی TABZ حداقل و حداکثر اختلاف بین GPS-VTEC و LSSVR-VTEC به ترتیب ۱/۸۹ و ۰/۲۵ TECU می‌باشد. این مقادیر در ایستگاه کنترل KLBR به ترتیب ۲/۸۵ و ۰/۷۵ TECU محاسبه می‌شوند. میانگین خطای مدل LS-SVR در ایستگاه‌های کنترل داخلی TABZ و KLBR ۱/۰۲ TECU 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 خطا در دو ایستگاه کنترل به ترتیب ۲/۲۶ و ۴/۲۲ TECU است. نتایج نشان می‌دهد که مدل جدید ارائه شده در این مقاله از دقت بالایی در پیش‌بینی سری‌های زمانی یونسفر برخوردار است.



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

Fig. 11. Absolute value of difference between GPS-VTEC and VTEC of LS-SVR, GIM and IRI2016 models at TABZ indoor control station for day 228.



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

Fig. 12. The absolute value of the difference between GPS-VTEC and VTEC of LS-SVR, GIM and IRI2016 models at the indoor control station KLBR for day 228.

مراجع

- [1] I. Sayin, F. Arikan, and O. Arikan, "Regional TEC mapping with random field priors and Kriging," *Radio Science*, vol. 43, no. 5, 2008, Art. no. RS5012, <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, <https://doi.org/10.1007/s40328-015-0113-9>.
- [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, <https://doi.org/10.1007/s40328-016-0162-8>.
- [4] 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, <https://doi.org/10.2478/s11600-013-0121-5>.
- [5] H. Etemadfard 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, <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, <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, <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, 2002, Art. no. 49, <https://doi.org/10.1088/0266-5611/18/1/304>.
- [9] P. Nematipour, M. Raofian-Naeni, and M. R. G. Razin, "Regional application of C^1 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, <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, <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

بود. علت این امر احاطه بودن ایستگاه TABZ با ایستگاه‌های آموزش بود. تجزیه و تحلیل نتایج ایستگاه‌های کنترل 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 خطایی در حدود ۱/۸۹ TECU را دارد.

در تحقیقات مشابه دیگری که در مورد مدل‌سازی TEC با مدل‌های یادگیری ماشین در سالیان اخیر انجام گرفته شده است مخصوصاً تحقیقات نظام‌زاده و همکاران [۳۲]، ۱۴۰۲؛ فیضی و همکاران، ۲۰۲۱؛ غفاری رزین و همکاران، ۲۰۲۲ به دقت‌هایی در حدود ۱ TECU دست یافته‌اند؛ اما بایستی 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 مدل‌سازی 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 مدل‌سازی و پیش‌بینی تغییرات 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 یونسفر محلی است و از دقت و سرعت محاسباتی بالایی برخوردار است.

تشکر و قدردانی

نویسندگان 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.

تعارض منافع

هیچگونه تعارض منافع توسط نویسندگان بیان نشده است.

- Algorithmica*, vol. 22, pp. 211-231, 1998, <https://doi.org/10.1007/PL00013831>.
- [22] M. R. G. Razin and S. Inyurt, "Spatiotemporal analysis of precipitable water vapor using ANFIS and comparison against voxel-based tomography and radiosonde," *GPS Solutions*, vol. 26, 2022, Art. no. 1, <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, <https://doi.org/10.1007/s00190-010-0427-x>.
- [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, <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, <https://doi.org/10.1007/BF00994018>.
- [26] J. A. K. Suykens, T. Van Gestel, J. De Brabanter, B. De Moor, and J. Vandewalle, *Least Squares Support Vector Machines*, Singapore: World Scientific, 2002, <https://doi.org/10.1142/5089>.
- [27] G. Matheron, *The Theory of Regionalized Variables and Its Applications*, France: École National Supérieure Des Mines, 1971.
- [28] V. R. Joseph, "Limit Kriging," *Technometrics*, vol. 48, no. 4, pp. 458-466, 2006, <https://doi.org/10.1198/004017006000000011>.
- [29] S. Erdoğan, "Modelling the spatial distribution of DEM error with geographically weighted regression: An experimental study," *Computers & Geosciences*, vol. 36, no. 1, pp. 34-43, 2010, <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*, Canberra, Australia: Geoscience Australia, 2008.
- [31] S. Schaer, *Mapping and Predicting the Earth's Ionosphere Using the Global Positioning System*, Zürich: Institut für Geodäsie und Photogrammetrie, 1999.
- [32] M. S. Nezamzadeh, B. Voosoghi, and 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 Physics*, vol. 49, no. 1, pp. 153-169, 2023, (in Persian), <https://doi.org/10.22059/jesphys.2023.339441.1007405>.
- Workshop on Space Weather*, WPP-155, European Space Agency, Noordwijk, the Netherlands, 1999, pp. 135-142.
- [12] J. B. Habarulema, L. A. McKinnell, and B. D. L. 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, Art. no. A04314, <https://doi.org/10.1029/2010JA016269>.
- [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, <https://doi.org/10.1007/s40328-015-0143-3>.
- [14] A. Tebabal, S. M. Radicella, B. Dantie, 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, 2019, Art. no. 105052, <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, 2019, Art. no. 62, <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, <https://doi.org/10.1016/j.asr.2020.02.027>.
- [17] C. Cesaroni *et al.*, "Neural network-based model for global Total Electron Content forecasting," *Journal of Space Weather and Space Climate*, vol. 10, 2020, Art. no. 11, <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, 2020, Art. no. e2020SW002501, <https://doi.org/10.1029/2020SW002501>.
- [19] G. Xia *et al.*, "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, <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, 2021, Art. no. 4559, <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,"