

## مدل‌سازی و پیش‌بینی سری زمانی محتوای الکترون کلی یونوسفر با استفاده از روش

### ماشین بردار پشتیبان در سال‌های ۲۰۰۷ الی ۲۰۱۸

سید رضا غفاری رزین\*<sup>۱</sup> و نوید هوشنگی<sup>۱</sup>

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

(دریافت: ۱۴۰۰/۴/۲۱، پذیرش نهایی: ۱۴۰۰/۱۰/۲۰)

#### چکیده

یونوسفر یکی از لایه‌های جو زمین است که به علت خاصیت الکتریکی، ممکن است اثرات مخرب و زیان‌باری را روی امواج الکترومغناطیسی عبوری از آن داشته باشد. جهت بررسی این اثرات، مقدار محتوای الکترونی کلی (TEC) یونوسفر مورد مطالعه و بررسی قرار می‌گیرد. در این مقاله سری زمانی یونوسفر با استفاده از سه مدل شبکه‌های عصبی مصنوعی (ANNs)، سیستم استنتاج عصبی-فازی سازگار (ANFIS) و ماشین بردار پشتیبان (SVM) مدل‌سازی شده و سپس پیش‌بینی می‌شود. جهت انجام این تحقیق از مشاهدات ایستگاه GNSS تهران (۳۵/۶۹N، ۵۱/۳۳E) که یکی از ایستگاه‌های شبکه جهانی IGS است، در سال‌های ۲۰۰۷ الی ۲۰۱۸ استفاده شده است. پارامترهای سال (year)، روز از سال (DOY)، ساعت (time)، شاخص فعالیت‌های خورشیدی (F10.7) و شاخص‌های فعالیت‌های ژئومغناطیسی (Kp and DST) به عنوان ورودی هر سه مدل در نظر گرفته شده و خروجی، مقدار TEC خواهد بود. برای مرحله آزمون دقت هر سه مدل، مشاهدات دو سال ۲۰۱۴ و ۲۰۱۸ از مرحله آموزش کنار گذاشته شده‌اند. دلیل انتخاب این دو سال، بررسی دقت مدل‌ها در زمان فعالیت‌های شدید خورشیدی (۲۰۱۴) و فعالیت‌های آرام خورشیدی (۲۰۱۸) است. نتایج حاصل از هر سه مدل با TEC حاصل از مدل مرجع بین‌المللی یونوسفر ۲۰۱۶ (IRI2016) و همچنین خروجی‌های شبکه جهانی IGS مقایسه شده است. همچنین از شاخص‌های آماری ضریب همبستگی، خطای نسبی و جذر خطای مربعی میانگین (RMSE) جهت بررسی دقت و صحت سه مدل استفاده شد. کمینه RMSE محاسبه شده برای مدل SVM، ۳/۱۱ TECU به دست آمده که در مقایسه با سایر مدل‌ها، از دقت بالاتری در مدل‌سازی و پیش‌بینی سری زمانی TEC یونوسفر در دوره فعالیت‌های آرام و شدید خورشیدی برخوردار است.

واژه‌های کلیدی: یونوسفر، TEC، GPS، شبکه عصبی، ANFIS، SVM

#### ۱. مقدمه

اندازه‌گیری‌ها، استفاده از مشاهدات این شبکه‌ها جهت مطالعه لایه یونوسفر امکان‌پذیر شده است. با استفاده از مشاهدات گیرنده‌های دو فرکانسه می‌توان مقدار محتوای الکترونی یونوسفر در راستای مایل (STEC) را محاسبه کرد. این پارامتر مجموع الکترون‌های آزاد در یک استوانه به مقطع یک مترمربع مابین ماهواره و گیرنده زمینی بوده و واحد آن الکترون بر مترمربع (ele/m<sup>2</sup>) می‌باشد. اگر TEC در امتداد قائم (راستای زینت) باشد، VTEC نامیده می‌شود. معمولاً TEC برحسب TECU که برابر ele/m<sup>2</sup> ۱۰<sup>۱۶</sup> است، بیان می‌شود (سیبر، ۲۰۰۳).

پس برداشتن اثر SA (Selective Availability) از روی سیستم تعیین موقعیت جهانی، انکسار یونوسفری به عنوان

یونوسفر لایه‌ای از جو زمین است که از ارتفاع ۶۰ کیلومتری تا ارتفاع ۱۵۰۰ کیلومتری گسترش پیدا کرده است. آگاهی از چگونگی توزیع چگالی الکترونی در لایه یونوسفر برای مطالعات علمی و کاربردهای عملی مانند تحقیقات فضایی، حرکت ماهواره‌ها از داخل آن، ارتباطات رادیویی و تعیین موقعیت با گیرنده‌های تک فرکانسه بسیار مهم و ضروری می‌باشد. اندازه‌گیری‌های سیستم‌های ناوبری ماهواره‌ای (GNSS) همانند سیستم تعیین موقعیت جهانی (GPS) به عنوان یک ابزار مؤثر و با ارزش جهت مطالعه و بررسی ویژگی‌های فیزیکی لایه یونوسفر شناخته شده‌اند. به دلیل گستره مکانی بسیار زیاد شبکه‌های ماهواره‌ای و نیز در دسترس بودن دائم

مهم‌ترین منبع خطا در انتشار امواج می‌باشد. این خطا متناسب با مقدار محتوای الکترونی یونوسفر است. مقدار محتوای الکترونی نشان‌دهنده تعداد الکترون‌های آزاد در مسیر مابین گیرنده تا ماهواره می‌باشد. زمانی که بتوان مقدار TEC را به صورت دقیق به دست آورد امکان محاسبه تأخیر یونوسفری بروی سیگنال‌های GPS به واسطه انکسار یونوسفری فراهم می‌شود. در گیرنده‌های تک‌فرکانسه جهت حذف مقدار انکسار یونوسفری باید مقادیر TEC مشخص باشد. این مقدار را می‌توان از طریق مدل‌های یونوسفری موجود محاسبه کرد. برخی از این مدل‌ها دارای پوشش جهانی بوده و برخی دیگر به صورت منطقه‌ای تعریف می‌شوند (عامریان و همکاران، ۲۰۱۰). به طور معمول مدل‌های منطقه‌ای به دلیل وجود ایستگاه‌های متراکم‌تر از دقت و صحت بالاتری برخوردار هستند.

سرویس بین‌المللی سیستم‌های ماهواره‌ای ناوبری جهانی (IGS) از سال ۱۹۹۸ در قالب گروه کاری یونوسفر شروع به انتشار روزانه نقشه‌های جهانی یونوسفری از کمیت TEC محاسبه شده از اطلاعات GPS به عنوان یکی از محصولات IGS کرده است (شاییر، ۱۹۹۹). این نقشه‌ها در ابتدا به صورت هفتگی ارائه می‌شدند که با افزایش سرعت محاسباتی سیستم‌های کامپیوتری، در حال حاضر هر ۲ ساعت یک‌بار و با قدرت تفکیک مکانی ۵ درجه در طول و ۲/۵ درجه در عرض جغرافیایی در فرمت استاندارد IONEX منتشر می‌شوند. از سایر مدل‌های جهانی مربوط به یونوسفر می‌توان به مدل مرجع بین‌المللی یونوسفر (IRI) و همچنین مدل NeQuick اشاره کرد که به مدل‌های تجربی معروف‌اند (بلیتیرا و راینیش، ۲۰۰۸؛ ناوا و همکاران، ۲۰۰۸). هر دو مدل اطلاعات بسیار باارزشی را در مورد یونوسفر و تغییرات آن در اختیار استفاده‌کنندگان قرار می‌دهند. منبع اصلی داده‌های مشاهداتی برای هر دو مدل (IRI و NeQuick) شامل شبکه سراسری از ایستگاه‌های یونوسوند (۴۲۳ ایستگاه در کل دنیا) و دستگاه ISR (۹ ایستگاه در کل دنیا) در جهان می‌باشند.

تحقیقات بسیار گسترده و وسیعی در کل دنیا و مخصوصاً کشور ایران جهت ارائه یک مدل محلی دقیق و صحیح برای بررسی پارامتر TEC و همچنین مدل‌سازی سری زمانی آن ارائه شده است. لیو و گائو (۲۰۰۳) با استفاده از مدل‌سازی به روش هارمونیک‌های کروی (SH) سری زمانی TEC را مورد مطالعه قرار دادند. نتایج کار ایشان به درجه و مرتبه هارمونیک‌های کروی وابسته است. یلماز و همکاران (۲۰۰۹) از شبکه‌های عصبی با توابع پایه شعاعی جهت مدل‌سازی و تخمین مقدار TEC در کشور ترکیه استفاده کردند. عامریان و همکاران (۲۰۱۳) با استفاده از توابع اسپیلاین مقدار TEC را برای منطقه ایران مدل‌سازی کردند. در این پژوهش روش پایدارسازی LSQR جهت حل مدل و برآورد ضرایب یونوسفری مورد استفاده قرار گرفت. آخوندزاده (۲۰۱۴) قابلیت شبکه‌های عصبی مصنوعی (ANNs) را جهت تشخیص آنومالی‌های موجود در یونوسفر قبل از زمین‌لرزه‌های بزرگ مورد مطالعه و بررسی قرار داد. شریفی و فرزانه (۲۰۱۵) و اعتمادفرد و حسینعلی (۲۰۱۶) با استفاده از تئوری اسلپین به مدل‌سازی TEC در منطقه آمریکا و قطب شمال پرداختند. غفاری رزین و وثوقی (۲۰۱۷) از ایده شبکه‌های عصبی ۳ لایه با استفاده از الگوریتم آموزش پس انتشار خطا (BP)، جهت مدل‌سازی و تخمین مقادیر VTEC در نقاط مختلف شبکه ژئودینامیک کشور ایران استفاده کردند. عبدی و همکاران (۲۰۱۶ و ۲۰۱۸) با استفاده از تلفیق مشاهدات GPS و ارتفاع‌سنجی ماهواره‌ای به بررسی رفتار یونوسفر در منطقه ایران و مناطق دریایی پرداختند. نتایج تحقیق ایشان حاکی از بهبود دقت مدل یونوسفری ارائه شده نسبت به مدل GIM در منطقه ایران است. سبزه‌ای و همکاران (۲۰۱۸) از قابلیت‌های شبکه‌های عصبی مصنوعی چندلایه جهت مدل‌سازی TEC برای گیرنده‌های تک‌فرکانسه در منطقه ایران بهره بردند. تبابال و همکاران (۲۰۱۹) از یک شبکه عصبی پیش‌رو جهت مدل‌سازی مقدار TEC در منطقه آفریقای جنوبی استفاده کردند. غفاری رزین و مرادی (۲۰۲۰) با استفاده از تلفیق

SVM در سال‌های ۲۰۱۴ و ۲۰۱۸ با نتایج حاصل از مدل مرجع بین‌المللی یونوسفر ۲۰۱۶ (IRI2016) و همچنین TEC حاصل از شبکه جهانی IGS مقایسه و تفسیر می‌شوند. همچنین دقت هر سه مدل در تعیین موقعیت نقطه‌ای دقیق (PPP) نیز مورد مطالعه و بررسی قرار می‌گیرد.

## ۲. محاسبه مشاهدات TEC دقیق

در این بخش جهت به‌دست آوردن مشاهدات STEC از ترکیب خطی هندسه آزاد مشاهدات GPS استفاده می‌شود. خطاهای فاصله هندسی، خطای ساعت و تأخیر تروپوسفری مستقل از فرکانس بوده و به‌کمک این ترکیب خطی به‌صورت کامل حذف خواهند شد. ترکیب خطی هندسه آزاد مشاهدات GPS را می‌توان به‌صورت روابط زیر نوشت (کلوسبرگ و تیونیس، ۱۹۹۸):

$$P_4 = 40.3 \left( \frac{f_2^2 - f_1^2}{f_1^2 f_2^2} \right) STEC + b_r^p + b_s^p + \varepsilon_{12}^p \quad (1)$$

با مرتب‌سازی رابطه (۱) می‌توان نوشت:

$$STEC_p = \frac{P_4}{\beta} = STEC + B_r^p + B_s^p + \varepsilon_{p4} \quad (2)$$

در رابطه (۲)،  $B_r^p$  مقدار بایاس داخل فرکانس گیرنده برای مشاهدات کد برحسب واحد TECU،  $B_s^p$  مقدار بایاس داخل فرکانسی ماهواره برای مشاهدات کد برحسب واحد TECU و  $\varepsilon_{p4}$  ترکیب نویز مشاهدات و اثر چند مسیری روی مشاهدات کد برحسب واحد TECU می‌باشند. با استفاده از مشاهدات فاز موج حامل می‌توان مقدار STEC نسبی را به‌صورت زیر به دست آورد:

$$STEC_\Phi = \frac{\Phi_4}{\beta} = -STEC + N_{arc} + B_r^\Phi + B_s^\Phi + \varepsilon_{\Phi 4} \quad (3)$$

در رابطه (۳)،  $B_r^\Phi$  مقدار بایاس داخل فرکانسی گیرنده برای مشاهدات کد برحسب واحد TECU،  $B_s^\Phi$  مقدار بایاس داخل فرکانسی ماهواره برای مشاهدات کد

سیستم استنتاج عصبی-فازی سازگار (ANFIS) و روش تجزیه به مؤلفه‌های اصلی (PCA) جهت برآورد سری زمانی TEC در منطقه ایران استفاده کردند. فیضی و همکاران (۲۰۲۰) از قابلیت روش ANFIS جهت مدلسازی سری زمانی TEC با مشاهدات کوتاه مدت و در بازه فعالیت‌های آرام ژئومغناطیسی پرداختند. غفاری رزین و مرادی (۲۰۲۱) از مدل شبکه‌های عصبی موجک (WNN) جهت مدلسازی و پیش‌بینی سری زمانی TEC در ایستگاه تهران استفاده کردند.

مطالعات انجام گرفته در زمینه مدلسازی یونوسفر در منطقه ایران نشان داده است که مدل‌های جهانی همانند مدل یونوسفری شبکه جهانی IGS (GIM) و همچنین مدل‌های تجربی همانند مدل‌های IRI2016 و NeQuick دارای دقت پایینی در این منطقه هستند. عمده‌ترین دلیل ارائه شده برای پایین بودن دقت این مدل‌ها، نبود مشاهدات کافی در منطقه ایران است. به‌همین دلیل، در این مقاله ایده استفاده از روش‌های مبتنی بر یادگیری جهت تولید یک مدل محلی یونوسفر با استفاده از مشاهدات ایستگاه‌های GNSS ارائه شده است؛ بنابراین هدف اصلی و اساسی این مقاله استفاده از سه مدل شبکه‌های عصبی مصنوعی، سیستم استنتاج عصبی-فازی سازگار و مدل ماشین بردار پشتیبان (SVM) جهت مدلسازی و پیش‌بینی سری زمانی تغییرات TEC یونوسفر در ایستگاه GNSS تهران است. نوآوری اصلی این مقاله در دو بخش است: نخست این که مدل ماشین بردار پشتیبان برای اولین بار در ایران جهت مدلسازی و پیش‌بینی سری زمانی یونوسفر با مشاهدات بلندمدت TEC مورد استفاده قرار می‌گیرد. دوم این که دقت و صحت هر سه مدل علاوه بر شرایط آرام خورشیدی، در شرایط طوفان‌های شدید خورشیدی هم مورد مطالعه و بررسی قرار می‌گیرد. جهت بررسی دقت مدل‌های مورد نظر، از شاخص‌های آماری خطای نسبی، ضریب همبستگی و جذر خطای مربعی میانگین (RMSE) استفاده می‌شود. کلیه نتایج به‌دست آمده از مدل‌های ANN، ANFIS و

برای محاسبه مقدار محتوای الکترون کلی قائم از تابع تصویر (۷) می‌توان استفاده کرد:

$$VTEC = M \times STEC_{smoothed} \quad (۷)$$

$$M(ele) = \left[ 1 - \left( \frac{R \cos(ele)}{R+h} \right)^2 \right]^{\frac{1}{2}} \quad (۸)$$

در روابط (۷) و (۸) تابع تصویر،  $ele$  زاویه ارتفاعی ماهواره،  $R$  شعاع کره زمین و  $h$  ارتفاع مدل تک‌لایه یونوسفری (۴۵۰ کیلومتر) است. زاویه ارتفاعی با استفاده از فاصله هندسی ماهواره و گیرنده و با فایل‌های افریز ماهواره محاسبه می‌شود. مقادیر VTEC حاصل از رابطه (۷) به‌عنوان خروجی هر سه مدل ANN، ANFIS و SVM در نظر گرفته می‌شوند. همچنین ۵ پارامتر سال ( $year$ )، روز از سال ( $DOY$ )، ساعت ( $time$ )، شاخص فعالیت‌های خورشیدی ( $F10.7$ ) و شاخص فعالیت‌های ژئومغناطیسی ( $Kp$ ) به‌عنوان بردار ورودی هر سه مدل خواهند بود.

### ۳. شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی روش‌های محاسباتی و ابزار ریاضی برای پردازش داده‌ها هستند. این شبکه‌ها از سیستم عصبی الهام گرفته‌اند و مانند مغز به پردازش داده‌ها می‌پردازند. شبکه عصبی مصنوعی مبتنی بر واحدهای متصل و غیرخطی به نام نورون است که کوچک‌ترین واحد پردازشگر اطلاعات بوده و اساس عملکرد شبکه عصبی را تشکیل می‌دهند (سیمپسون، ۱۹۹۰؛ هایکین، ۱۹۹۴). یک نورون یا یک سلول عصبی در واقع یک تابع با  $n$  ورودی و یک خروجی است که رابطه ورودی-خروجی نورون همانند رابطه ۹ خواهد بود (لئوناردو و سانتوس، ۲۰۰۷):

$$y = h \left( \sum_{j=1}^n (w_j x_j + w_0) \right) \quad (۹)$$

در رابطه (۹)  $h$  نشان‌دهنده تابع فعالیت،  $w_j$  بیانگر وزن هر

برحسب واحد TECU و  $\varepsilon_{p4}$  ترکیب نوین مشاهدات و اثر چند مسیری روی مشاهدات فاز برحسب واحد TECU،  $N_{arc}$  بایاس در مشاهدات یونوسفری به دلیل ابهام فاز موجود در مشاهدات فاز می‌باشند. مشاهدات STEC حاصل از اندازه‌گیری‌های فاز موج حامل ( $STEC_{\phi}$ ) دقیق‌تر از مشاهدات STEC حاصل از مشاهدات کد ( $STEC_p$ ) می‌باشند. مشکل اصلی مشاهدات STEC حاصل از مشاهدات فاز در وجود دو مقدار ابهام فاز در اندازه‌گیری‌های فاز موج حامل می‌باشد. جهت بهره‌برداری از مزیت دقت بالای مشاهدات STEC حاصل از اندازه‌گیری‌های فاز موج حامل و نیز مزیت عدم وجود مقدار ابهام فاز در مشاهدات STEC حاصل از اندازه‌گیری‌های کد، می‌توان مشاهدات حاصل از دو مجموعه را جهت نرم‌سازی مقدار STEC با همدیگر ترکیب کرد (کیرالوو و همکاران، ۲۰۰۷). در این تقریب مقادیر STEC حاصل از مشاهدات فاز در کمان‌های پیوسته توسط مقادیر میانگین مشاهدات STEC حاصل از اندازه‌گیری‌های کد تعدیل می‌شوند. مقدار میانگین برای هر کمان پیوسته به‌صورت زیر محاسبه می‌شود:

$$\langle STEC_p + STEC_{\phi} \rangle = \frac{1}{N} \sum_{i=1}^N (STEC_p + STEC_{\phi}) \quad (۴)$$

در رابطه (۴)،  $N$  نشان‌دهنده تعداد اندازه‌گیری‌های پیوسته برای کمان مورد نظر بوده و  $\langle \cdot \rangle$  بیانگر مقدار میانگین است. با فرض این که مقادیر بایاس داخل فرکانسی ثابت بوده و با جای‌گذاری روابط (۲) و (۳) در رابطه (۴) می‌توان نوشت:

$$\langle STEC_p + STEC_{\phi} \rangle = (B_r^p + B_s^p + B_r^{\phi} + B_s^{\phi}) + \frac{1}{N} \sum_{i=1}^N (N_{arc} + \varepsilon_{p4}) \quad (۵)$$

با تفاضل رابطه (۳) از رابطه (۵) جملات مربوط به ابهام فاز حذف شده و مقدار STEC نرم شده به‌صورت زیر حاصل می‌شود:

$$STEC_{smoothed} = \langle STEC_p + STEC_{\phi} \rangle - STEC_{\phi} = STEC + (B_r^p + B_s^p) + \varepsilon_{p4} \quad (۶)$$

(FRB) گفته می‌شود. مراحل استدلال (عملیات نتیجه‌گیری بر روی قواعد اگر-آنگاه فازی) با استفاده از یک سیستم استنتاج فازی انجام می‌شود. معمول‌ترین نوع سیستم استنتاج فازی که قابلیت قرارگیری در یک شبکه تطبیقی را دارا است، سیستم فازی تاکاگی-سوگنو است که خروجی آن یک رابطه خطی است و پارامترهای آن را می‌توان با ترکیب روش‌های حداقل مربعات خطا و انتشار خطا به عقب بر اساس کاهش گرادبان برآورد کرد (تاکاگی و سوگنو، ۱۹۸۵). برای سادگی کار فرض می‌شود که FIS مورد بررسی از دو ورودی  $y$  و  $x$  و یک خروجی  $f$  تشکیل شده و همچنین پایگاه قانون در آن شامل دو قانون اگر-آنگاه است. قوانین موجود در این سیستم عبارت‌اند از (جنگ، ۱۹۹۳):

$$\text{IF } x = A_1 \text{ AND } y = B_1, \quad (12)$$

$$\text{Then } f_1 = p_1 + q_1 + r_1$$

$$\text{IF } x = A_2 \text{ AND } y = B_2, \quad (13)$$

$$\text{Then } f_2 = p_2 + q_2 + r_2$$

که در آن  $A_1$  و  $A_2$  توابع عضویت برای ورودی  $x$  و  $B_1$  و  $B_2$  توابع عضویت برای ورودی  $y$  و در نهایت  $p_1, q_1, r_1$  و  $p_2, q_2, r_2$  پارامترهای تابع خروجی هستند. همانند سیستم‌های فازی، ساختار ANFIS نیز از دو بخش تشکیل شده است. بخش نخست مقدم و بخش دوم تالی (استنتاج-نتیجه) نامیده می‌شود که این دو بخش توسط قواعد فازی در فرم یک شبکه به یکدیگر متصل می‌شوند. برای شبکه ANFIS می‌توان ۵ لایه را به صورت زیر در نظر گرفت:

لایه اول: نقاط موجود در این لایه به پارامترهای یک تابع تطبیق می‌یابند. خروجی هر نقطه، یک مقدار درجه عضویت می‌باشد که توسط ورودی‌های توابع عضویت داده شده‌اند. به عنوان مثال توابع عضویت می‌توانند به صورت تابع عضویت گوسی باشند:

$$\mu_{A_i}(x) = \exp\left[-\left(\frac{x - c_i}{2a_i}\right)^2\right] \quad (14)$$

نورون،  $x_j$  نشان‌دهنده بردار ورودی و  $w_0$  وزن‌های اولیه شبکه را نشان می‌دهند. یکی از مناسب‌ترین توابع فعال‌سازی تابع سیگموئید می‌باشد که به صورت تابع ریاضی زیر تعریف می‌شود:

$$f(z) = \frac{1}{(1 + e^{-z})} \quad (10)$$

که در رابطه (۱۰)،  $z$  اطلاعات ورودی نورون و  $f(z) \in [0,1]$  می‌باشند. جهت آموزش شبکه عصبی، الگوریتم‌های آموزش متفاوتی وجود دارد. در این مقاله، از الگوریتم آموزش پس‌انتشار خطا (BP) استفاده می‌شود (مارس و همکاران، ۱۹۹۶). در این الگوریتم خروجی شبکه عصبی با خروجی مطلوب مقایسه شده و بر اساس تابع هدف، مقدار خطا محاسبه می‌شود. اگر مقدار خطا در حد دقت مطلوب نباشد، بر اساس مشتق تابع هدف، وزن‌های مربوط به نورون‌ها تصحیح شده و مجدداً خروجی محاسبه می‌شود. این مراحل تا مادامی که مقدار خطا (تابع هدف) به کمترین میزان خود برسد، ادامه می‌یابد. تابع هدف مورد استفاده در این مقاله به صورت زیر است:


$$E = \sum_j (TEC_{GPS} - TEC_{model})^2 \quad (11)$$

در رابطه (۱۱)،  $TEC_{GPS}$  خروجی مطلوب و  $TEC_{model}$  خروجی حاصل از سه مدل  $ANN$ ،  $ANFIS$  و  $SVM$  می‌باشند.

#### ۴. سیستم استنتاج عصبی-فازی سازگار (ANFIS)

سیستم‌های استنتاج فازی (FIS) می‌توانند رفتار یک پدیده یا فرآیند را صرفاً در قالب استفاده از قواعد توصیفی و تجربی بدون نیاز به شناخت مدل دقیق تحلیلی فرمول‌بندی کنند. حتی سیستم‌های استنتاج فازی برخلاف مدل‌های رگرسیون و شبکه‌های عصبی مصنوعی بدون نیاز به داده‌های فرآیند نیز می‌توانند برای شبیه‌سازی رفتار یک فرآیند استفاده شوند. سیستم استنتاج فازی ابزار فرموله کردن یک فرآیند به کمک قواعد اگر-آنگاه فازی است. به مجموعه این قواعد فازی پایگاه قواعد فازی

(واپسینک، ۱۹۷۹). در ساده‌ترین فرم آن یعنی حالت خطی،  $SVM$  عبارت است از یک ابر صفحه که مجموعه نمونه‌های مثبت و منفی را با حداکثر فاصله از هم جدا کرده است. ماشین بردار پشتیبان یک مدل تقریباً جدید برای دسته‌بندی فضای مشاهدات بوده و البته دارای ساختار مشابهی همانند شبکه‌های عصبی مصنوعی است. شکل ۱ ساختار ساده‌ای از یک مدل  $SVM$  را نمایش می‌دهد.



شکل ۱. ساختار یک شبکه  $SVM$  با مشاهدات ورودی، توابع کرنل و مشاهده خروجی.

در یک فضای  $n$  بعدی،  $SVM$  با استفاده از ابر صفحه‌ها جداکننده، فضای مشاهدات ورودی را به دسته‌های مختلف افراز می‌کند. به منظور انتخاب بهترین ابر صفحه، ریسک‌پذیری دقت در  $SVM$  مورد توجه قرار می‌گیرد. به عبارت دیگر، جداکننده‌ای مناسب است که بیشترین فاصله را از هر دو دسته از داده‌ها داشته باشد. یعنی سبب شود بیشترین حاشیه ریسک ایجاد شود (ناحیه بین دو ابر صفحه، حاشیه گفته می‌شود). این حالت به داشتن ماکزیمم حاشیه تعبیر می‌شود (یگانه و همکاران، ۲۰۱۲). معمولاً ماشین بردار پشتیبان را می‌توان در دو حالت خطی و غیرخطی مورد بررسی قرار داد. معمولاً در حالتی که داده‌ها به سادگی از هم تفکیک نمی‌شوند، یک تفکیک کننده خطی نمی‌تواند مؤثر باشد. فرض کنید که مجموعه مشاهدات آموزش به صورت زیر در نظر گرفته شوند:

$$D = \{(x_1, y_1), \dots, (x_N, y_N)\} \quad (20)$$

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x), \quad i=1,2 \\ O_{1,i} &= \mu_{B_{i-2}}(y), \quad i=3,4 \end{aligned} \quad (15)$$

در روابط (۱۴) و (۱۵)  $\mu_{A_i}$  و  $\mu_{B_i}$  درجات توابع عضویت برای مجموعه‌های  $A_i$  و  $B_i$  بوده و  $(a_i, b_i, c_i)$  پارامترهای هستند که می‌توانند شکل تابع عضویت را تغییر دهند. پارامترهای موجود در این لایه پارامترهای فرض در نظر گرفته می‌شوند.

لایه دوم: تمام نقاط موجود در این لایه نقاط ثابت می‌باشند. گره خروجی، نتیجه ضرب سیگنال‌های ورودی می‌باشد و این خروجی توسط گره بعدی دریافت می‌شود. در لایه دوم عملگر  $T$ -norm مانند عملگر  $and$  و یا ضرب برای به دست آوردن خروجی استفاده می‌شود:

$$O_{2i} = w_i = \mu_{A_i}(x) \times \mu_{B_i}(x), \quad i=1,2 \quad (16)$$

لایه سوم: همانند لایه دوم، تمام گره‌ها در این لایه ثابت می‌باشند. این لایه نقش نرمال کننده را دارد و وزن هر گره بر مجموع وزن‌های گره‌ها تقسیم می‌شود:

$$O_{3i} = \bar{w}_i = \frac{w_i}{\sum_j w_j} \quad (17)$$

لایه چهارم: تمام نقاط موجود در این لایه گره‌ی تطبیقی برای یک خروجی با تابع گره زیر می‌باشند:

$$O_{4i} = \bar{w}_i f = (p_i x + q_i x + r_i) f \quad (18)$$

لایه پنجم: تک نقطه موجود در این لایه یک گره غیر تطبیقی و ثابت می‌باشد. در این لایه نتیجه کلی با جمع کردن همه سیگنال‌های ورودی از لایه‌های قبل محاسبه می‌شود. دایره مربوط به این لایه با علامت مجموع برچسب گذاری شده است.

$$(19)$$

$$O_{5i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

۵. ماشین بردار پشتیبان ( $SVM$ )

در ۱۹۷۹ ماشین بردار پشتیبان توسط واپسینک ارائه شد

زمانی یونوسفر با استفاده از مدل مرجع بین‌المللی یونوسفر IGS ۲۰۱۶ (IRI-TEC) و خروجی‌های شبکه جهانی (GIM-TEC) انجام می‌گیرد. پارامترهای آماری خطای نسبی، ضریب همبستگی و همچنین RMSE جهت بررسی دقت و صحت مدل مورد نظر استفاده می‌شوند. این پارامترهای آماری با روابط زیر محاسبه می‌شوند:

$$Re.(%) = \frac{|VTEC_{model} - VTEC_{GPS}|}{VTEC_{GPS}} \times 100 \quad (26)$$

$$R = \frac{\sum_{i=1}^N (VTEC_{model}^i - \overline{VTEC}_i) \times (VTEC_{GPS}^i - \overline{VTEC}_{GPS}^i)}{\sqrt{\sum_{i=1}^N (VTEC_{model}^i - \overline{VTEC}_i)^2 \times \sum_{i=1}^N (VTEC_{GPS}^i - \overline{VTEC}_{GPS}^i)^2}} \quad (27)$$

$$RMSE = \sqrt{\frac{1}{M} \sum_{m=1}^M (VTEC_{model}^m - VTEC_{GPS}^m)^2} \quad (28)$$

در روابط بالا،  $VTEC_{GPS}$  بیانگر مقدار حاصل از مشاهدات GPS و  $VTEC_{model}$  نشان‌دهنده مقدار حاصل از مدل‌های ANN، ANFIS، SVM، IRI2016 و GIM می‌باشند.

#### ۷. مشاهدات مورد استفاده

مشاهدات مورد استفاده در این تحقیق، مشاهدات مربوط به ایستگاه GNSS تهران (۳۵/۶۹N، ۵۱/۳۳E) در بازه زمانی مابین سال‌های ۲۰۰۷ الی ۲۰۱۸ می‌باشد. تمامی مشاهدات از وب‌سایت شبکه جهانی IGS به آدرس <ftp://cddis.gsfc.nasa.gov/pub/gps/data/daily/> دانلود شده است. پس از دانلود مشاهدات، با استفاده از الگوریتم ارائه شده در بخش ۲ مقدار STEC دقیق و متعاقب آن مقدار VTEC دقیق به‌عنوان خروجی مطلوب هر سه مدل محاسبه می‌شوند (مقادیر VTEC استخراج شده مربوط به موقعیت ایستگاه تهران است). بایاس داخل فرکانسی برای ماهواره‌ها از شبکه جهانی IGS استخراج شده و برای گیرنده‌ها، در مرحله پردازش اولیه با نرم‌افزار برنیز محاسبه شده است. بازه زمانی مورد استفاده جهت محاسبه VTEC دقیق با الگوریتم بخش دوم به صورت ۳۰ دقیقه‌ای بوده

در رابطه بالا  $x$  بردار مشاهدات با بعد  $d$  و  $y$  بردار خروجی به صورت یک بعدی می‌باشد. با توجه به این که نمونه‌های موجود به صورت خطی قابل تفکیک نیستند، آنها با استفاده از تابع تصویر غیرخطی  $\phi(x)$  به فضایی با ابعاد بالاتر افزار می‌شوند. در نتیجه مسئله بهینه‌سازی زیر را می‌توان به صورت زیر نوشت (ژانگ و همکاران، ۲۰۱۹):

$$f(x) = \omega \phi(x) + b \quad (21)$$

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^N (\xi_i^+ + \xi_i^-) \quad (22)$$

معادله بهینه‌سازی بالا منوط به معادله زیر خواهد بود:

$$\begin{cases} -\varepsilon - \xi_i^+ \leq y_i - \omega \phi(x_i) - b \leq \varepsilon + \xi_i^- \\ \xi_i^+ \geq 0 \\ \xi_i^- \geq 0 \end{cases} \quad (23)$$

در روابط بالا،  $\omega$  بردار عمود بر ابر صفحه،  $\|\cdot\|$  نرم دو ماتریس،  $\xi_i^+$  و  $\xi_i^-$  کران‌های پایین و بالای متغیر مثبت کاهش،  $C$  بیانگر فاکتور جریمه و  $\varepsilon$  سطح خطای مجاز برای تابع می‌باشند. ابعاد بردار  $\omega$  و تابع  $\phi(x)$  بر اساس تابع کرنل مشخص می‌شوند. با اضافه کردن ضرب لاگرانژ، مسئله بهینه‌سازی (۲۲) به مسئله دوگانه زیر تبدیل می‌شود:

$$f(x) = \sum_{i=1}^{n_{SV}} (a_i^- - a_i^+) K(x_i, x) + b \quad (24)$$


$$\begin{aligned} K(x_i, x) &= \langle \phi(x_i), \phi(x) \rangle \\ &= \exp(-\gamma \|x - x_i\|^2) \end{aligned} \quad (25)$$

در روابط (۲۴) و (۲۵)،  $n_{SV}$  نشان‌دهنده تعداد بردارهای پشتیبان،  $a_i^+$  و  $a_i^-$  ضرایب لاگرانژی،  $K(x_i, x)$  بیانگر تابع کرنل و  $\gamma$  پارامتر کرنل را نمایش می‌دهد. در این مقاله از تابع کرنل شعاعی به جهت تطابق بیشتر با مشاهدات ورودی، محاسبات سریع‌تر و خطای کمتر، استفاده شده است.

#### ۶. ارزیابی مدل‌های مورد استفاده

ارزیابی مدل‌های پیشنهادی این مقاله در پیش‌بینی رفتار

خورشیدی بالا و سال ۲۰۱۸ دارای فعالیت خورشیدی پایین است.



شکل ۲. چگونگی تغییر شاخص فعالیت خورشیدی F10.7 در بازه زمانی سال‌های ۲۰۰۷ الی ۲۰۱۸.

در ادامه آنالیزهای صورت گرفته برای مشاهدات مربوط به بازه زمانی ۲۰۰۷ الی ۲۰۱۸ مورد بررسی قرار می‌گیرد.

#### ۷-۱. آنالیز دقت و صحت مدل‌های ANN، ANFIS، SVM، IRI2016 و GIM

در این قسمت جهت بررسی و ارزیابی کارایی مدل‌های ANN، ANFIS و SVM در پیش‌بینی سری زمانی یونوسفر در شرایط طوفان‌های شدید خورشیدی و شرایط آرام، هر سه مدل با مشاهدات موجود آموزش داده می‌شوند (مشاهدات سال‌های ۲۰۱۴ و ۲۰۱۸ در مرحله آموزش مورد استفاده قرار نمی‌گیرند). سپس از مدل‌های آموزش دیده استفاده شده و مقدار TEC برای سال‌های ۲۰۱۴ و ۲۰۱۸ پیش‌بینی می‌شود. برای مرحله آموزش سه پارامتر RMSE، زمان همگرایی به جواب بهینه و ضریب همبستگی برای هر سه مدل مورد مقایسه قرار گرفته است. جدول ۱، نتایج حاصل برای مرحله آموزش را نشان می‌دهد. در مرحله آموزش، TEC حاصل از GPS به‌عنوان مشاهده مرجع در نظر گرفته شده است.


جدول ۱. مقایسه مقدار RMSE، زمان همگرایی به جواب بهینه و ضریب همبستگی در مرحله آموزش برای سه مدل ANN، ANFIS و SVM.

مدل	مقدار RMSE برای مرحله آموزش (TECU)	زمان همگرایی به جواب بهینه (ثانیه)	ضریب همبستگی (R) مرحله آموزش
ANN	۵/۱۱۸	۴۸۲	۰/۸۳
ANFIS	۴/۴۶۳	۵۵۶	۰/۸۵
SVM	۳/۳۸۲	۶۲۱	۰/۸۷

است. به‌عبارت‌دیگر برای هر ۳۰ دقیقه، یک مقدار VTEC دقیق از مشاهدات GPS ایستگاه محاسبه شده است (از TEC‌های ۳۰ ثانیه‌ای به‌دست آمده در هر ۳۰ دقیقه میانگین‌گیری شده است). مشاهدات ورودی به سه مدل ANN، ANFIS و SVM شامل سال (Year)، شاخص‌های فعالیت‌های ژئومغناطیسی ( $Kp$  and  $DST$ )، شاخص فعالیت‌های خورشیدی ( $F10.7$ )، روز از سال ( $DOY$ ) و ساعت در روز ( $HR$ ) هستند. پارامتر  $F10.7$  نشان‌دهنده شار خورشیدی است که در حال حاضر یکی از بهترین شاخص‌های فعالیت خورشیدی بوده و از ۵۰ سال گذشته در حال اندازه‌گیری می‌باشد. پارامتر  $Kp$  بیانگر شاخص فعالیت‌های ژئومغناطیسی بوده و در دو حالت آرام ( $Kp < 4$ ) و فعالیت شدید ( $Kp > 4$ ) دسته‌بندی می‌شود. شاخص  $Dst$  به‌طور گسترده‌ای به‌عنوان شاخص فعالیت ژئومغناطیسی استفاده می‌شود. به‌عنوان مثال، انواع طوفان بر اساس بزرگی شاخص  $Dst$  تعریف شده است: طوفان جزئی ( $-30nT > DST > -50nT$ )، طوفان متوسط ( $-50nT > DST > -100nT$ )، طوفان بزرگ و شدید ( $DST < -100nT$ ). مجموعه مشاهدات مورد استفاده شامل مشاهدات سال‌های ۲۰۰۷ الی ۲۰۱۸ ایستگاه تهران است که از این ۱۲ سال مشاهده، مشاهدات دو سال ۲۰۱۴ (فعالیت خورشیدی شدید) و ۲۰۱۸ (فعالیت آرام خورشیدی) جهت انجام تست و تعیین خطای مدل‌ها، کنار گذاشته شده‌اند. بایستی اشاره شود که مشاهدات سال‌های ۲۰۱۴ و ۲۰۱۸ در مرحله آموزش استفاده نمی‌شود. شکل ۲ چگونگی تغییرات شاخص فعالیت خورشیدی را در بازه زمانی سال‌های ۲۰۰۷ الی ۲۰۱۸ نمایش می‌دهد. کاملاً از این شکل مشخص است که سال ۲۰۱۴ دارای فعالیت




۱۲ ماه در دو سال ۲۰۱۴ و ۲۰۱۸ در اشکال نمایش داده شده است.



شکل ۳. نمودار تغییرات خطای نسبی حاصل از مدل‌های ANN، ANFIS، SVM، IRI2016 و GIM در سال‌های ۲۰۱۴ و ۲۰۱۸.

بر اساس نتایج حاصل از شکل ۳ کمترین مقدار خطای نسبی برای مدل SVM در سال ۲۰۱۸ به دست آمده و بیشترین مقدار خطا، برای مدل IRI2016 در سال ۲۰۱۴ حاصل شده است. همچنین، خطای نسبی تمامی مدل‌ها در سال ۲۰۱۴ بیشتر از خطای نسبی آنها در سال ۲۰۱۸ است. به عبارت دیگر، تمامی مدل‌ها در سال ۲۰۱۴ که فعالیت‌های خورشیدی بالاست، خطای بیشتری دارند. چنین حالتی، در خطای RMSE نیز دیده می‌شود. ماکزیمم مقدار RMSE در سال ۲۰۱۴ برای مدل IRI2016 دیده می‌شود؛ در صورتی که کمترین مقدار RMSE برای مدل SVM و در سال ۲۰۱۸ محاسبه شده است.



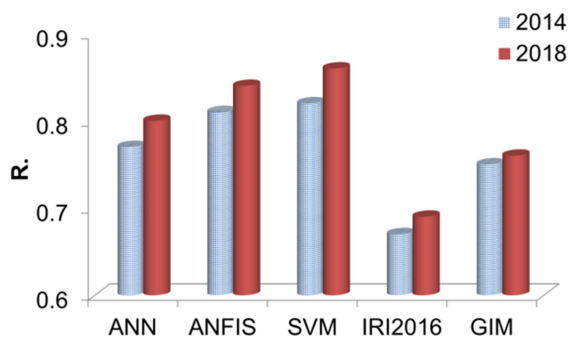
شکل ۴. نمودار تغییرات خطای RMSE حاصل از مدل‌های ANN، ANFIS، SVM، IRI2016 و GIM در سال‌های ۲۰۱۴ و ۲۰۱۸.

مقادیر RMSE به دست آمده برای مدل‌های ANN،

بر اساس نتایج حاصل از جدول ۱ مقدار RMSE مدل SVM در مرحله آموزش کمتر از دو مدل ANN و ANFIS است. به عبارت دیگر، ساختار مدل SVM با مشاهدات ورودی و خروجی سازگاری بیشتری داشته است. اما زمان همگرایی به جواب بهینه برای مدل ANN کمتر از دو مدل دیگر است. به عبارت دیگر مدل ANN سریع‌تر از مدل‌های ANFIS و SVM به جواب بهینه همگرا شده است. ساختار مدل ANFIS ترکیبی از مدل شبکه عصبی مصنوعی و مدل فازی است. به عبارت دیگر جهت دستیابی به جواب بهینه در مدل ANFIS، می‌بایستی قواعد اگر-آنگاه فازی در لایه‌های مختلف به همراه وزن‌های اولیه، بهینه شوند. همین امر باعث افزایش زمان همگرایی به جواب بهینه در مدل ANFIS می‌شود. در مدل SVM مهم‌ترین مرحله، برآورد بهینه پارامترهای توابع کرنل است. دستیابی به مقدار بهینه این پارامترها، باعث افزایش زمان همگرایی به جواب بهینه و همچنین پیچیدگی محاسباتی در مدل SVM می‌شود. مخصوصاً زمانی که تعداد مشاهدات ورودی خیلی زیاد باشد، تعیین بهینه پارامترهای توابع کرنل در مدل SVM زمان‌بر خواهد بود. برای پارامتر ضریب همبستگی، مدل SVM از ضریب همبستگی بالاتری نسبت به دو مدل دیگر برخوردار است. به عبارت دیگر، مدل SVM تغییرات موجود در سری زمانی TEC را با دقت بالاتری شناسایی کرده است.

پس از مرحله آموزش هر سه مدل، مقدار TEC برای سال‌های ۲۰۱۴ (فعالیت خورشیدی شدید) و ۲۰۱۸ (فعالیت آرام خورشیدی) پیش‌بینی شده و با مقدار TEC حاصل از GPS، مدل IRI2016 و GIM مقایسه شده است. در این مرحله نیز، شاخص‌های آماری خطای نسبی، RMSE و ضریب همبستگی برای تمامی مدل‌ها (ANN، ANFIS، SVM، IRI2016 و GIM) محاسبه و ارزیابی می‌شوند. شکل‌های ۳، ۴ و ۵، مقایسه‌های صورت گرفته برای سه شاخص را نشان می‌دهند. بایستی اشاره شود که در این اشکال، TEC حاصل از GPS به عنوان مرجع در نظر گرفته شده است. همچنین به جهت اختصار، میانگین

مقادیر واقعی کمیت مورد بررسی است.




شکل ۵. نمودار تغییرات ضریب همبستگی حاصل از مدل‌های ANN، ANFIS، SVM، IRI2016 و GIM در سال‌های ۲۰۱۴ و ۲۰۱۸.

مقادیر ضریب همبستگی مدل‌های ANN، ANFIS، SVM، IRI2016 و GIM در سال ۲۰۱۴ به ترتیب برابر با ۰/۷۷، ۰/۸۱، ۰/۸۲، ۰/۶۷ و ۰/۷۵ به دست آمده است. آنالیز ضریب همبستگی نشان می‌دهد که مدل SVM تغییرات سری زمانی TEC را با دقت بالاتری شناسایی کرده است.


نوع دیگر آنالیز انجام گرفته در این مقاله جهت ارزیابی دقت مدل‌های ارائه شده، استفاده از روش تعیین موقعیت نقطه‌ای دقیق (PPP) است. با استفاده از سه مدل ANN، ANFIS و SVM مقدار TEC در روزهای مشخصی از سال‌های ۲۰۱۴ و ۲۰۱۸ مدل‌سازی شده و سپس آنکسار یونوسفری محاسبه می‌شود. با استفاده از آنکسار به دست آمده، مشاهدات آن روز تصحیح شده و با کمک مشاهدات تصحیح شده، مختصات ایستگاه به روش PPP برآورد می‌شود؛ همچنین مختصات دقیق ایستگاه با استفاده از نرم‌افزار برنیز نیز برآورد شده و با مختصات به دست آمده از PPP مقایسه می‌شوند. با توجه به این که آنالیز خطای مدل‌ها برای مشاهدات سال‌های ۲۰۱۴ و ۲۰۱۸ انجام گرفته، جهت اختصار تنها نتایج روز ۶۱ از سال ۲۰۱۴ و روز ۳۲۰ از سال ۲۰۱۸ در شکل ۶ نمایش داده شده است. در روز ۶۱ فعالیت خورشیدی ماکزیمم ( $F_{10.7}=159/5$ ) و در روز ۳۲۰ فعالیت خورشیدی مینیمم ( $F_{10.7}=43/3$ ) می‌باشد.

ANFIS، SVM، IRI2016 و GIM در سال ۲۰۱۴ به ترتیب برابر با ۴/۳۱، ۳/۸۷، ۳/۱۱، ۸/۶۸ و ۴/۰۵ TECU به دست آمده است. عمده‌ترین عامل تولید خطا در نتایج مدل ANN و ANFIS می‌تواند مربوط به مرحله آموزش و انتخاب ساختار بهینه باشد. آموزش هر دو مدل با استفاده از روش پس‌انتشار خطا صورت گرفته است. این روش مبتنی بر مشتق تابع هدف (رابطه ۱۱) بوده و وزن‌های شبکه بر اساس آن تنظیم می‌شود. عدم تنظیم صحیح وزن‌های شبکه باعث تولید خطا در نتایج مدل‌های ANN و ANFIS می‌شود. برای مدل SVM، مهم‌ترین مرحله تعیین توابع کرنل و پارامترهای این توابع هست. با توجه به این که این توابع با فیزیک رفتار یونوسفر تطابق بیشتری دارند، در نتیجه خطای حاصل از این مدل نسبت به مدل‌های ANN و ANFIS کمتر است. عمده‌ترین منبع مشاهداتی برای مدل تجربی IRI2016 اندازه‌گیری‌های به دست آمده از ایستگاه‌های یونوسوند است. در ایران تنها یک ایستگاه یونوسوند وجود دارد و مشاهدات آن ایستگاه هم به طور پیوسته و منظم نیست (به دلیل خرابی و نقص فنی). بنابراین این مدل در منطقه ایران دارای خطای زیادی خواهد بود. مدل GIM در منطقه ایران تنها از مشاهدات دو ایستگاه تهران و همدان جهت برآورد مقدار TEC استفاده می‌کند. این مدل با استفاده از روابط هارمونیک‌های کروی و برآورد ضرایب آنها، مقدار TEC را مدل‌سازی می‌کند. به عبارت دیگر جهت برآورد ضرایب هارمونیک‌های کروی از مشاهدات کلیه ایستگاه‌های شبکه جهانی IGS استفاده می‌شود. این عامل باعث می‌شود که مدل GIM یک مدل جهانی یونوسفر محسوب شود؛ در نتیجه دقت این مدل در نشان دادن تغییرات محلی یونوسفر پایین خواهد بود.

شکل ۵، نتایج مقایسه مابین ضریب همبستگی مدل‌های مورد بررسی در سال‌های ۲۰۱۴ و ۲۰۱۸ را نشان می‌دهد. هر چقدر مقدار ضریب همبستگی به عدد یک نزدیک‌تر باشد نشان‌دهنده همبستگی بالاتر خروجی‌های مدل با



(ب)



(الف)

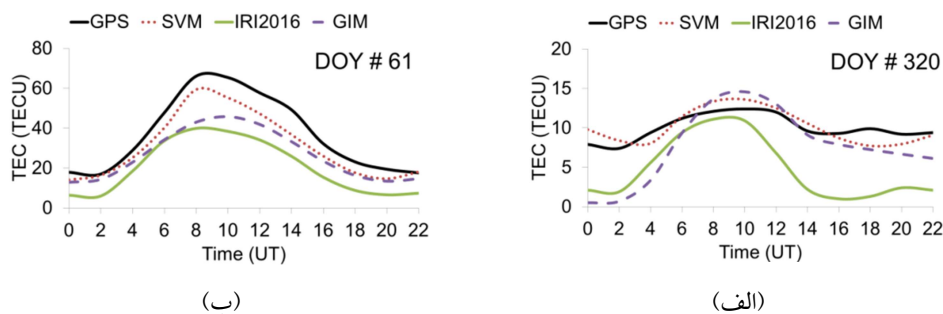
شکل ۶. مقایسه مقادیر RMSE مؤلفه‌های مختصاتی ایستگاه تهران حاصل از مدل‌های ANN, ANFIS, SVM, IRI2016 و GIM در روزهای ۳۲۰ از سال ۲۰۱۸ (الف) و روز ۶۱ از سال ۲۰۱۴ (ب).

مدل SVM که دقیق‌تر از سایر مدل‌هاست، در دوره فعالیت‌های شدید خورشیدی (سال ۲۰۱۴) بهبودی در حدود ۹ الی ۱۵ میلی‌متر در مؤلفه‌های مختصاتی نسبت به مدل‌های IRI2016 و GIM دیده می‌شود.

۷-۲. آنالیز سری زمانی TEC حاصل از مدل‌های

ANN, ANFIS و SVM در سال‌های ۲۰۱۴ و ۲۰۱۸ پس از آنالیز دقت مدل‌های ANN, ANFIS, SVM, IRI2016 و GIM در سال‌های ۲۰۱۴ و ۲۰۱۸، حال می‌توان سری زمانی حاصل از این مدل‌ها را در روزهای مختلف ترسیم و مقایسه کرد. با توجه به این که آنالیزهای انجام گرفته نشان داد که دقت مدل SVM از دو مدل ANFIS و ANN بالاتر است، در این قسمت سری زمانی این دو مدل ترسیم نشده است. همچنین جهت اختصار، سری زمانی روزانه TEC برای دو روز ۳۲۰ از سال ۲۰۱۸ (فعالیت خورشیدی پایین) و ۶۱ از سال ۲۰۱۴ (فعالیت خورشیدی بالا) نمایش داده شده است. شکل ۷ مقایسه سری زمانی روزانه TEC حاصل از مدل‌های SVM, IRI2016 و GIM را با TEC حاصل از GPS به‌عنوان مرجع، نشان می‌دهد.

مطابق با نتایج حاصل از شکل ۶، مقادیر RMSE مؤلفه‌های مختصاتی ایستگاه تهران در سال ۲۰۱۴ در تمامی مدل‌ها بیشتر از سال ۲۰۱۸ است. به عبارت دیگر تمامی مدل‌ها در فعالیت‌های خورشیدی بالا دارای خطای زیادی در برآورد مقدار TEC هستند. اما، مقایسه مابین نتایج مدل‌ها در سال ۲۰۱۴ نشان می‌دهد که در هر سه مؤلفه، خطای مدل SVM کمتر از مدل‌های دیگر است. نکته مهم دیگر از شکل ۶ این است که مقادیر RMSE سه مدل ANN, ANFIS و GIM در هر دو سال ۲۰۱۴ و ۲۰۱۸ کمتر از مدل‌های IRI2016 هستند. در هر سه مدل ANN, ANFIS و GIM پارامتر  $F10.7$  جزو پارامترهای ورودی مدل در نظر گرفته شده است. در نتیجه اثر فعالیت‌های خورشیدی در خروجی این سه مدل، وجود دارد. اما در مدل GIM این اثر در پارامترهای مدل دیده نمی‌شود. برای مدل تجربی IRI2016 اثر فعالیت‌های خورشیدی در ورودی‌های مدل در نظر گرفته شده است اما با توجه به این که این مدل بیشتر از مشاهدات ایستگاه‌های یونسوند برای پیش‌بینی مقدار TEC استفاده می‌کند و در منطقه ایران تنها یک ایستگاه وجود دارد، در نتیجه دقت آن به شدت پایین آمده است. با استفاده از

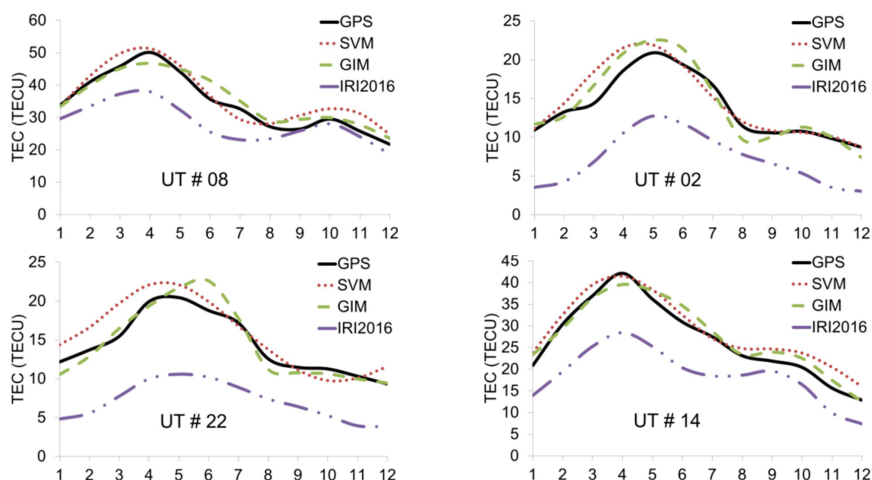


شکل ۷. مقایسه سری زمانی روزانه TEC حاصل از GPS و مدل‌های SVM، IRI2016 و GIM در روزهای ۳۲۰ از سال ۲۰۱۸ (الف) و روز ۶۱ از سال ۲۰۱۴ (ب).

بالا، دقت پایین‌تری دارند. اما مدل SVM نسبت به دو مدل IRI2016 و GIM در دوره فعالیت‌های خورشیدی دقیق‌تر عمل کرده است. بر اساس شکل ۷، پیک مقدار TEC در ساعات ۸ الی ۱۰ UT مشاهده می‌شود و هر سه مدل این پیک را به درستی نشان داده‌اند.

نوع دیگر مقایسه صورت گرفته مربوط به تغییرات ساعتی TEC در کلیه ماه‌های سال ۲۰۱۴ (فعالیت خورشیدی بالا) است. بر این اساس تغییرات TEC به اختصار در زمان‌های ۲، ۸، ۱۴ و ۲۲ به وقت جهانی توسط سه مدل SVM، GIM و IRI2016 پیش‌بینی شده و با مقادیر TEC حاصل از GPS در این زمان‌ها مقایسه شده است. شکل ۸ نتایج حاصل از این مقایسه را نمایش می‌دهد. لازم به ذکر است که میانگین ماهیانه TEC محاسبه شده و در نمودارها ترسیم شده است. در این نمودارها، محور افقی بیانگر ماه‌های سال ۲۰۱۴ است.

بر اساس شکل ۷ و در روز ۳۲۰ از سال ۲۰۱۸ که فعالیت خورشیدی پایین است، سری زمانی TEC حاصل از مدل SVM به سری زمانی TEC حاصل از GPS بسیار نزدیک است. تفاوت مابین این دو سری زمانی از ۰ تا ۱/۷۵ TECU است. اما برای سری‌های زمانی روزانه مدل‌های IRI2016 و GIM تفاوتی در حدود ۰ الی ۸/۶ TECU وجود دارد. مدل GIM در برخی از ساعات مقدار خطای کمتری داشته است اما مدل IRI2016 تقریباً در همه ساعات شبانه‌روز در برآورد سری زمانی TEC دارای خطای زیادی است. در روز ۶۱ از سال ۲۰۱۴ که فعالیت خورشیدی بالاست، تفاوت سری زمانی مدل SVM با GPS در حدود ۰ الی ۹/۶۸ TECU شده است. این تفاوت برای مدل‌های GIM و IRI2016 چیزی در حدود ۲ الی ۲۶ TECU شده است. نتایج مقایسه انجام گرفته در شکل ۷ نشان می‌دهد که هر سه مدل در فعالیت‌های خورشیدی



شکل ۸. پروفیل تغییرات ساعتی TEC حاصل از مدل‌های SVM، IRI2016، GIM و مقایسه آن با TEC حاصل از GPS در زمان‌های ۲، ۸، ۱۴ و ۲۲ UT در کلیه ماه‌های سال ۲۰۱۴.

(*Kp and DST*) در نظر گرفته شدند. خروجی هم پارامتر TEC بوده است. هر سه مدل با روش پس انتشار خطا آموزش داده شده و سپس مقدار TEC برای سال‌های ۲۰۱۴ و ۲۰۱۸ برآورد شدند. با استفاده از شاخص‌های آماری خطای نسبی، ضریب همبستگی و RMSE دقت هر سه مدل مورد ارزیابی قرار گرفت. همچنین نتایج حاصل با مدل‌های IRI2016 و GIM نیز مقایسه شد.

در مرحله تست سال ۲۰۱۴، مقدار RMSE مدل‌های ANN، ANFIS، SVM، GIM و IRI2016 به ترتیب برابر با ۴/۰۵، ۳/۸۷، ۳/۱۱، ۴/۳۱ و ۸/۶۸ TECU حاصل شد. همچنین مقدار خطای نسبی نیز برای ۵ مدل فوق به ترتیب برابر با ۱۷/۵۲، ۱۵/۳۶، ۱۴/۲۸، ۱۷/۳۶ و ۳۳/۰۹ درصد به دست آمد. نتایج به دست آمده در سال ۲۰۱۴ (فعالیت خورشیدی بالا) نشان داد که مدل SVM نسبت به چهار مدل دیگر از دقت بالاتری در پیش‌بینی سری زمانی TEC یونوسفر برخوردار است. همچنین مدل IRI2016 به دلیل نداشتن مشاهدات کافی از یونوسفر در منطقه ایران، دارای دقت بسیار پایینی است. آنالیز سال ۲۰۱۸ نیز نشان داد که مدل SVM دارای دقت بالاتری نسبت به بقیه مدل‌ها در منطقه ایران است. آنالیز دقت مدل‌ها به روش PPP نیز نشان داد که در دوره فعالیت‌های شدید خورشیدی و با استفاده از مدل SVM، بهبودی به اندازه ۹ الی ۱۵ میلی‌متر نسبت به مدل‌های GIM و IRI2016 در مؤلفه‌های مختصاتی ایستگاه به وجود می‌آید.

نتایج حاصل از این مقاله نشان داد که مدل SVM دارای دقت و قابلیت بسیار بالایی در مدلسازی و پیش‌بینی سری زمانی TEC یونوسفر است. این مدل در دوره فعالیت‌های شدید خورشیدی نیز نسبت به مدل‌های GIM و IRI2016 که مدل‌های متداول یونوسفری در جهان هستند، از دقت بالاتری برخوردار است. با توجه به این که مدل‌های جهانی در منطقه ایران، عمدتاً به دلیل نبود مشاهدات کافی از دقت قابل‌قبولی برخوردار نیستند، در نتیجه می‌توان از مدل SVM ارائه شده در این مقاله به عنوان یک مدل محلی یونوسفر با دقت بالا استفاده کرد. با استفاده از این مدل

مطابق با نتایج حاصل از شکل ۸ تغییرات ماهیانه و همچنین ساعتی TEC برای هر سه مدل به وضوح مشاهده می‌شود. تفاوت فاحشی در حدود ۱ تا ۱۳/۷۰ TECU مابین مدل IRI2016 و TEC حاصل از GPS دیده می‌شود. مقدار TEC حاصل از مدل SVM تفاوتی در حدود ۰ تا ۴/۸۶ TEC نسبت به TEC حاصل از GPS دارد. مقایسه پروفیل‌های ترسیم شده برای چهار زمان مختلف نشان می‌دهد که پیشینه مقدار TEC در زمان ۸ UT ( $LT=UT+3.30 h$ ) است. همچنین پیشینه مقدار TEC در بازه زمانی ماه‌های آوریل تا ژوئن دیده می‌شود. در این ماه‌ها و در منطقه ایران تابش‌های خورشیدی افزایش پیدا کرده و در نتیجه بر فعالیت یونوسفر افزوده می‌شود.

#### ۸. نتیجه‌گیری و پیشنهادات

در این مقاله ایده استفاده از روش‌های مبتنی بر یادگیری جهت مدلسازی و پیش‌بینی سری زمانی TEC یونوسفر ارائه شد. با استفاده از مدل‌های ANN، ANFIS، SVM و مشاهدات بلندمدت ایستگاه GNSS تهران که یکی از ایستگاه‌های شبکه جهانی IGS است، جهت ارزیابی و آنالیز سه مدل استفاده شد. بایستی اشاره شود که استفاده از مدل SVM جهت آنالیز سری زمانی یونوسفر برای اولین بار در ایران و این مقاله ارائه شده است. همچنین دلیل استفاده از مشاهدات ایستگاه تهران، در دسترس بودن مجموعه کامل مشاهدات به صورت رایگان و در بستر اینترنت است. مشاهدات سال‌های ۲۰۰۷ الی ۲۰۱۸ از وبسایت شبکه جهانی IGS دانلود شده و سپس بر اساس الگوریتم بخش ۲، مقادیر TEC دقیق محاسبه شده است. با توجه به این که هدف این مقاله ارزیابی هر سه مدل در دوره فعالیت‌های آرام و شدید خورشیدی بود، مشاهدات دو سال ۲۰۱۴ (فعالیت خورشیدی بالا) و ۲۰۱۸ (فعالیت آرام خورشیدی) از مجموعه مشاهدات آموزش کنار گذاشته شدند. بایستی اشاره شود که ورودی هر سه مدل ۵ پارامتر سال، روز از سال، ساعت در روز، شاخص فعالیت خورشیدی (*F10.7*) و شاخص‌های فعالیت ژئومغناطیسی

دقیق آنومالی‌ها و اغتشاشات موجود در یونوسفر بهره برد.

### تشکر و قدردانی

نویسندگان مقاله از داوران محترم به دلیل ارائه نکات بسیار ارزنده و علمی تشکر و قدردانی می‌کنند. همچنین، از شبکه جهانی IGS به دلیل در اختیار قرار دادن رایگان مشاهدات ایستگاه تهران، تشکر و قدردانی می‌شود.

### مراجع

- Abdi, N., Azmoodeh Ardalan, A. R. and Karimi, R., 2016, Evaluation of Iran Ionosphere Model Based on GPS Data Processing, *JGST*, 5 (4), 37-47.
- Abdi, N., Azmoodeh Ardalan, A. R. and Karimi, R., 2018, Combination of GPS and Satellite Altimetry Observations for Local Ionosphere Modeling Over Iran, *JGST*, 7(3), 109-125.
- Akhoondzadeh, M., 2014, Investigation of GPS-TEC measurements using ANN method indicating seismo-273 ionospheric anomalies around the time of the Chile (Mw = 8.2) earthquake of 01 April 2014, *Advance in space research*, 54(9), 1768-1772.
- Amerian, Y., Mashhadi Hossainali, M., Voosoghi, B. and Ghaffari Razin, M. R., 2010, Tomographic reconstruction of the ionospheric electron density in term of wavelets, *Journal of Aerospace Science and Technology*, 7(1), 19–29.
- Amerian, Y., Voosoghi, B. and Mashhadi Hossainali, M., 2013, Regional Ionosphere Modeling in Support of IRI and Wavelet Using GPS Observations, *Acta Geophysica*, 61(5), 1246-1261, DOI: 10.2478/s11600-013-0121-5.
- Bilitza, D. and Reinisch, B. W., 2008, International Reference Ionosphere 2007: Improvements and new parameters, *Advances in Space Research*, 2018, 42 (2008), 599–609.
- Ciraolo, L., Azpilicueta, F., Brunini, C., Meza, A. and Radicella, S. M., 2007, Calibration errors on experimental slant total electron content (TEC) determined with GPS, *J Geod.*, 2007, 81(2), 111–120. doi: 10.1007/s00190-006-0093-1.
- Etemadfard, H. and Hossainali, M. M., 2016, Application of Slepian Theory for Improving the Accuracy of Global Ionosphere Models in the Arctic Region, *J. Geophys. Res. Space Physics*, 121(3), 2583-2594.
- Feizi, R., Voosoghi, B. and Ghaffari Razin, M. R., 2020, Regional modeling of the ionosphere using adaptive neuro-fuzzy inference system in Iran. *Advances in Space Research* 65(2020), 2515–2528.
- Ghaffari Razin, M. R. and Voosoghi, B., 2017, Wavelet neural networks using particle swarm optimization training in modeling regional ionospheric total electron content, *Journal of Atmospheric and Solar–Terrestrial Physics*, <http://dx.doi.org/10.1016/j.jastp.2016.09.005>, 149 (2017), 21–30.
- Ghaffari Razin, M. R. and Moradi, A. R., 2020, Temporal extrapolation of TEC using WNN during 2007–2018 and comparison against GIM, IRI2016 and Kriging, *Advances in Space Research*, <https://doi.org/10.1016/j.asr.2020.11.033>.
- Haykin, S., 1994, *Neural Networks, a comprehensive Foundation*, Macmillan College Publishing Company, New York, 1994.
- Jang, J.-S. R., 1993, ANFIS: adaptive-network-based fuzzy inference system, *IEEE Transactions on Systems, Man and Cybernetics*, 23(3), 665–685.
- Kleusberg, A. and Teunissen, P. J. G., 1998, *GPS for geodesy*, Springer, 1998.
- Liu, Z. and Gao, Y., 2003, Ionospheric TEC predictions over a local area GPS reference network, *GPS Solutions*, 8(1), 23–29.
- Leandro, R. F. and Santos, M. C., 2007, A neural network approach for regional vertical total electron content modeling, *Stud. Geophys. Geod.*, 51(2), 279-292.
- Mars, P., Chen, J. R. and Nambiar, R., 1996, *Learning Algorithms: Theory and Applications in Signal Processing, Control and Communications*, CRC Press, Boca Raton, Florida, 1996.
- Nava, B., Coisson, P. and Radicella, S. M., 2008, A new version of the NeQuick ionosphere electron density model, *Journal of Atmospheric and Solar-Terrestrial Physics*, 2008, [doi:10.1016/j.jastp.2008.01.015](https://doi.org/10.1016/j.jastp.2008.01.015).
- Sabzehee, F., Farzaneh, S., Sharifi, M. A. and Akhoondzadeh, M., 2018, TEC Regional Modeling and prediction using ANN method and single frequency receiver over IRAN, *ANNALS OF GEOPHYSICS*, 61(1).
- Schaer, S., 1999, *Mapping and Predicting the Earths Ionosphere Using the Global Positioning System*, PhD dissertation, Astronomical Institute,

- University of Berne, Switzerland, 205.
- Seeber, G., 2003, *Satellite Geodesy, Foundations, Methods and Application*”, Walter de Gruyter, Berlin and New York, 531.
- Sharifi, M. A. and Farzaneh, S., 2015, Regional TEC dynamic modeling based on Slepian functions, *Advances in Space Research*, 56 (5), 907-915.
- Simpson, P. K., 1990, *Artificial neural systems: foundations, paradigms, applications, and implementations*, Pergamon Press, New York, 1990.
- Takagi, T. and Sugeno, M., 1985, Fuzzy identification of systems and its applications to modeling and control, *IEEE Transactions on Systems, Man and Cybernetics*, 15(1), 116-132.
- Tebabal, A., Radicella, S. M., Damtie, B., Migoya-Orue, B., Nigussie, M. and Nava, B., 2019, Feed forward neural network based ionospheric model for the East African region, *Journal of Atmospheric and Solar–Terrestrial Physics*, 2019, 191(105052).
- Vapnik, V., 1995, *Nature of statistical learning theory*”, Springer, New York.
- Yeganeh, B., Motlagh, MSP, Rashidi, Y., Kamalan, H., 2012, Prediction of CO concentrations based on a hybrid Partial Least Square and Support Vector Machine model, *Atmos Environ*, 55:357–365.
- Yilmaz, A., Akdogan, K. E. and Gurun, M., 2009, Regional TEC mapping using neural networks, *Radio Sci*, 2009, 44 (3), 1-16, doi:10.1029/2008RS004049.
- Zhang, Z., Pan, S., Gao, C., Zhao, T. and Gao, W., 2019, Support Vector Machine for Regional Ionospheric Delay Modeling, *Sensors*, 2019, 19, 2947; doi:10.3390/s19132947.

## Modeling and prediction of the ionospheric total electron content time series using support vector machine in 2007-2018

Ghaffari Razin, S. R.<sup>1\*</sup> and Hooshangi, N.<sup>2</sup>

1. Assistant Professor, Department of Geomatics, Faculty of Geoscience Engineering, Arak University of Technology, Arak, Iran

(Received: 12 July 2021, Accepted: 10 Jan 2022)

### Summary

The ionosphere is a layer of the Earth's atmosphere that extends from an altitude of 60 km to an altitude of 1,500 km. Knowledge of electron density distribution in the ionosphere is very important and necessary for scientific studies and practical applications. Observations of global navigation satellite system (GNSS) such as the global positioning system (GPS) are recognized as an effective and valuable tool for studying the properties of the ionosphere. Studies on ionosphere modeling in the Iranian region have shown that the global ionosphere maps (GIM) model as well as empirical models such as IRI2016 and NeQuick have low accuracy in this region. The main reason for the low accuracy of these models is the lack of sufficient observations in the Iranian region. For this reason, this paper presents the idea of using learning-based methods to generate a local ionosphere model using observations of GNSS stations. Therefore, the main purpose of this paper is to use three models of artificial neural networks (ANNs), adaptive neuro-fuzzy inference system (ANFIS) and support vector machine (SVM) to model and predict the time series of ionospheric TEC variations in Tehran GNSS station.

An adaptive neuro-fuzzy inference system (ANFIS) is a kind of ANN that is based on Takagi–Sugeno fuzzy inference system. The technique was developed in the early 1990s (Jang, 1993). Since it integrates both neural networks and fuzzy logic principles, it has potential to capture the benefits of both in a single framework. Its inference system corresponds to a set of fuzzy IF–THEN rules that have learning capability to approximate nonlinear functions. Hence, ANFIS is considered to be a universal estimator. ANFIS architecture consists of five layers: fuzzy layer, product layer, normalized layer, defuzzy layer, and total output layer.

In machine learning, support-vector machines (SVM) are supervised learning models with associated learning algorithms that analyze data used for classification and regression analysis. More formally, a SVM constructs a hyperplane or set of hyperplanes in a high- or infinite-dimensional space, which can be used for classification, regression, or other tasks like outliers detection (Vapnik, 1995). In SVM method, using nonlinear functions  $\phi(x)$ , the input vector ( $x$ ) is depicted from N-dimensional space to M-dimensional space ( $M>N$ ). The number of hidden units ( $M$ ) is equal to the number of support vectors that are the learning data points, closest to the separating hyperplane.

The results of this paper show that the SVM has a very high accuracy and capability in modeling and predicting the ionosphere TEC time series. This model has a higher accuracy in the period of severe solar activity than GIM and IRI2016 models, which are the traditional ionospheric models in the world. Due to the fact that global models in the region of Iran do not have acceptable accuracy due to lack of sufficient observations, therefore, the SVM can be used as a local ionosphere model with high accuracy. Using this model, the TEC value can be predicted with high accuracy for different times and during periods of severe solar activity. This model can be used in studies related to the physics of the ionosphere as well as its temporal variations.

**Keywords:** Ionosphere, TEC, GPS, Neural Network, ANFIS, SVM.

---

\* Corresponding author:

mr.ghafari@arakut.ac.ir