

ارزیابی کارایی شبکه عصبی چند لایه MLP-ANN با الگوریتم آموزش PSO در مدل سازی سری زمانی محتوای الکترون کلی لایه یونسفر

میر رضا غفاری رزین^{۱*}، بهزاد وثوقی^۲

^۱دکتری مهندسی ژئودزی - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
rghaffari@mail.kntu.ac.ir

^۲دانشیار دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
vosoghi@kntu.ac.ir

(تاریخ دریافت بهمن ۱۳۹۴، تاریخ تصویب اردیبهشت ۱۳۹۶)

چکیده

در این مقاله از یک شبکه عصبی مصنوعی (ANN) ۳ لایه با ۱۸ نورون در لایه مخفی جهت مدل سازی سری زمانی تغییرات محتوای الکترون کلی (TEC) لایه یونسفر در منطقه ایران استفاده شده است. مشاهدات ۳۶ ایستگاه GPS در ۱۱ روز متوالی (روز ۲۲۰ GPS الی روز ۲۳۰ GPS) از سال ۲۰۱۲ جهت مدل سازی بکار گرفته شده است. جهت سرعت بخشیدن به مرحله آموزش و نیز بالا بردن دقت و صحت نتایج از الگوریتم آموزش بهینه سازی انبوه ذرات (PSO) استفاده شده است. اعتبارسنجی نتایج حاصل از روش با مشاهدات سیستم تعیین موقعیت جهانی (GPS) انجام گرفته است. همچنین نتایج بدست آمده از شبکه عصبی در پنج ایستگاه آزمون با نتایج حاصل از مدل مرجع بین المللی ۲۰۱۲ (IRI-2012) و روش درونیابی کریجینگ فراگیر مورد مقایسه قرار گرفته است. آنالیز نتایج بدست آمده حاکی از سرعت بالای الگوریتم آموزش PSO در همگرایی به جواب بهینه می باشد. جهت ارزیابی خطای مدل شبکه عصبی از شاخص dvTEC که از اختلاف مابین TEC حاصل از اندازه گیری های GPS و TEC حاصل از مدل محاسبه می گردد، استفاده شده است. کمینه این شاخص در ۱۱ روز مورد مطالعه برای سه مدل شبکه عصبی، IRI-2012 و کریجینگ فراگیر بترتیب برابر با ۰/۵۵، ۱/۵۷ و ۰/۷۰ TECU و بیشینه آن بترتیب برابر با ۵/۴۵، ۷/۱۶ و ۵/۵۱ TECU محاسبه شده است. نتایج حاصل از این مقاله حاکی از آن است که مدل شبکه عصبی مصنوعی با الگوریتم آموزش PSO از دقت و صحت لازم جهت پیش بینی تغییرات زمان-مکان لایه یونسفر برخوردار می باشد.

واژگان کلیدی: شبکه عصبی مصنوعی، PSO، TEC، GPS، یونسفر، کریجینگ

* نویسنده رابط

۱- مقدمه

از سال ۱۹۹۰ میلادی اندازه‌گیری‌های سیستم‌های ماهواره‌ای ناوبری جهانی^۱ (GNSS) به عنوان یک ابزار موثر و باارزش جهت مطالعه خصوصیات فیزیکی و نیز تغییرات زمان-مکان لایه یونسفر مورد استفاده قرار گرفته است [۲، ۳، ۴]. توسعه و ارزیابی یک مدل قابل اعتماد که بتواند تمامی ویژگی‌های فیزیکی این لایه را نشان دهد، هنوز به عنوان یک چالش جدی در علوم فضایی مطرح می‌باشد. بدلیل ماهیت غیرخطی رفتار یونسفر و نیز عوامل موجود موثر بر آن، این چالش از اهمیت فوق العاده‌ای برخوردار است. الکترون‌های موجود در یونسفر تاثیر بسزایی بر انتشار امواج الکترومغناطیسی عبوری از آن دارند. این تاثیر، حوزه‌های تحقیقاتی وسیع و گسترده‌ای را در مورد این لایه از جو همانند سیستم‌های مشاهداتی زمین-فضا^۲، سیستم‌های ارتباطی^۳، هواشناسی فضایی^۴ و ایجاد کرده است [۳]. سیگنال‌های سیستم تعیین موقعیت جهانی^۵ (GPS) نیز متاثر از خاصیت الکتریکی یونسفر می‌باشند.

بدلیل ماهیت خاص و نیز ویژگی‌های فیزیکی، چگالی الکترونی در یونسفر دارای تغییرات زمانی-مکانی^۶ است. این تغییرات می‌تواند ناشی از تغییرات روزانه^۷، تغییرات فصلی^۸، آنومالی‌های مختلف موجود و یا دوره فعالیت‌های خورشیدی^۹ باشد [۲]. وجود فرکانس‌های مختلف در رفتار چگالی الکترونی در یونسفر منجر به اثرات بسیار زیان‌باری در سیستم‌های ارتباطی شده است. جهت پی بردن به ماهیت فعالیت‌های یونسفری و نحوه تاثیر آنها در سایر سیستم‌ها، می‌بایستی تغییرات زمان-مکان آن بصورت دقیق مورد مطالعه قرار گیرد.

کمیتی که با استفاده از آن می‌توان چگونگی فعالیت‌های یونسفری و نیز تغییرات زمان-مکان چگالی الکترونی در این لایه از جو را مورد مطالعه قرار داد، محتوای الکترون کلی (TEC) می‌باشد. در حقیقت TEC

تعداد کل الکترون‌های آزاد در مسیر مابین ماهواره تا گیرنده در ستونی بمساحت ضلع یک متر مربع است [۵]. واحد اندازه‌گیری TEC، TECU بوده و یک TECU معادل 10^{16} (ele./m²) می‌باشد. این کمیت را می‌توان از روی اندازه‌گیری‌های فاز و کد بدست آمده از سیستم تعیین موقعیت جهانی بدست آورد.

بدلیل توزیع مکانی نامناسب گیرنده‌های GPS و نیز تعداد محدود آنها و همچنین وجود ناپیوستگی مشاهداتی در حوزه زمان، مقادیر چگالی الکترونی و TEC بدست آمده از اندازه‌گیری‌های GPS دارای محدودیت زمان-مکان خواهند بود. جهت محاسبه و تعیین مقدار TEC در مناطقی که دارای مشاهده نبوده و یا توزیع ایستگاهی مناسب وجود ندارد، در این حالت مقدار TEC بدست آمده از اندازه‌گیری‌های GPS می‌بایستی با یک روش مناسب، درون‌یابی^{۱۰} و یا برون‌یابی^{۱۱} شوند. در نتیجه مقادیر TEC محاسبه شده و نیز مقادیر TEC برآورد شده، می‌توانند به عنوان مدلی جهت بررسی رفتار چگالی الکترونی یونسفر در زمان و مکان مورد استفاده قرار گیرند.

تاکنون تلاش‌های بسیار زیادی جهت درون‌یابی و یا برون‌یابی چگالی الکترونی یونسفر و کمیت TEC در مناطقی که مشاهده کافی و یا مناسب موجود نیست، صورت گرفته است. بطور مثال می‌توان به روش‌های کریجینگ^{۱۲}، چندجمله‌ای^{۱۳}، هارمونیک‌های کروی^{۱۴}، درون‌یابی به کمک توابع اسپیلاین^{۱۵} اشاره نمود [۶، ۷، ۸، ۹]. از این روش‌ها به کرات جهت تهیه و مدل‌سازی منطقه‌ای و جهانی مقدار TEC و چگالی الکترونی استفاده شده است.

وجود آنومالی‌های مختلف و نیز تاثیر سایر پدیده‌ها در رفتار یونسفر، مدل‌سازی تحلیلی این لایه از جو را بسیار دشوار کرده است. بنظر می‌رسد ارائه مدل تحلیلی که بتواند تمامی ویژگی‌های موثر موجود بر رفتار یونسفر را در برگیرد کاری سخت و دشوار خواهد بود. بنابراین استفاده از سیستم‌هایی که در عین سادگی و کارآمد بودن، بتواند پردازش‌های موازی^{۱۶} را برای سیستم‌هایی با رفتار

^۱ Global Navigation Satellite System^۲ Space-based observation systems^۳ Communication systems^۴ Space weather^۵ Global Positioning System^۶ Temporal and spatial variations^۷ Diurnal Variation^۸ Seasonal Variations^۹ Solar cycle variations^{۱۰} Interpolation^{۱۱} Extrapolation^{۱۲} Kriging^{۱۳} Polynomial^{۱۴} Spherical Harmonics^{۱۵} Spline Functions^{۱۶} Parallel Processing

امروزه کاربرد الگوریتم‌های جستجوگر تکاملی برای آموزش شبکه‌های عصبی به جای روش‌های آموزشی مرسوم، مورد توجه محققان قرار گرفته است. به همین علت در این مقاله، استفاده از الگوریتم بهینه‌سازی انبوه ذرات^۳ (PSO) جهت آموزش شبکه عصبی مورد استفاده قرار گرفته است [۱۲]. این الگوریتم قادر است که با یک روش غیرقطعی در فضای جواب‌ها، جوابی نزدیک به بهترین جواب را با سرعت و دقتی بالا پیدا نماید. الگوریتم PSO الهام گرفته از رفتار اجتماعی برخی گونه‌های جانوری است. از جمله مزایای این الگوریتم نسبت به الگوریتم‌های تکاملی تدریجی نظیر الگوریتم ژنتیک (GA)^۴ می‌توان به پیاده‌سازی آسان، پارامترهای کم الگوریتم و همچنین سرعت همگرایی بالای آن اشاره کرد.

هدف کلی این مقاله مدل‌سازی تغییرات زمانی محتوای الکترون کلی لایه یونسفر در ایران با استفاده از شبکه‌های عصبی مصنوعی می‌باشد. جهت دست یافتن به این هدف و نیز افزایش سرعت آموزش شبکه عصبی و نیز بالا بردن دقت و صحت نتایج حاصل از آن، از الگوریتم آموزش PSO استفاده می‌شود. نتایج حاصل از روش پیشنهادی این مقاله با مشاهدات GPS، خروجی‌های مدل مرجع بین‌المللی ۲۰۱۲ (IRI-2012) و روش کریجینگ فراگیر مورد مقایسه قرار گرفته است.

۲- محاسبه STEC (مشاهدات ورودی)

در این بخش جهت بدست آوردن مشاهدات STEC از ترکیب خطی هندسه آزاد^۵ مشاهدات GPS استفاده می‌شود. خطاهای فاصله هندسی، خطای ساعت و تاخیر تروپوسفری مستقل از فرکانس بوده و به کمک این ترکیب خطی بصورت کامل حذف خواهند شد. ترکیب خطی هندسه آزاد مشاهدات GPS را می‌توان بصورت روابط زیر نوشت [۵]:

$$P_4 = P_1 - P_2 = I_1 - I_2 + b_r^P + b_s^P + \varepsilon_{12}^P \quad (1)$$

$$\Phi_4 = \Phi_1 - \Phi_2 = I_1 - I_2 + \lambda_1 N_1 - \lambda_1 N_2 + b_r^\Phi + b_s^\Phi + \varepsilon_{12}^\Phi \quad (2)$$

غیرخطی و پیچیده همانند لایه یونسفر انجام دهد کاملاً احساس می‌شود. شبکه‌های عصبی مصنوعی بعلاوه ماهیت غیرخطی و نیز بدلیل سرعت عمل و آسانی در پردازش، از اقبال بسیار زیادی در زمینه مدل‌سازی و برآورد پدیده‌هایی همانند رفتار لایه یونسفر برخوردار شده‌اند.

در شبکه‌های عصبی دستیابی به نتایج مطلوب تنها زمانی ممکن بوده است که منبع غنی داده‌ها با مشاهدات فراوان در اختیار باشد و زمانی که با داده‌های اندک (همانند مساله مدل‌سازی سری زمانی محتوای الکترونی یونسفر) برای آموزش شبکه مواجه بوده‌ایم، کارایی بالایی نداشته که این نقص، کاربردهای شبکه عصبی را بشدت محدود می‌کند. هدف از آموزش شبکه‌های عصبی، یافتن اندازه وزن‌ها و بایاس‌ها به نحوی است که خطای داده‌های آموزش را به حداقل ممکن برساند. لذا آموزش شبکه‌های عصبی را می‌توان در بردارنده یک مسأله بهینه‌سازی^۱ دانست که هدف از آن بهینه‌سازی ضرایب وزنی و بایاس‌ها جهت دستیابی به حداقل خطای آموزش می‌باشد [۱۰]. در روش‌های مرسوم جهت آموزش شبکه‌های عصبی از الگوریتم پس انتشار^۲ و دیگر روش‌های گرادیانی استفاده می‌شود. این روش‌ها در مواردی که شکل تابع غیرخطی و پیچیده باشد، ضعف و ناکارآمدی خود را نشان می‌دهند. در الگوریتم پس انتشار در هر مرحله مقدار خروجی محاسبه شده جدید، با مقدار واقعی مقایسه شده و با توجه به خطای بدست آمده به اصلاح وزن‌ها و بایاس‌های شبکه پرداخته می‌شود. به نحوی که در انتهای هر تکرار اندازه خطای حاصله کمتر از میزان بدست آمده در تکرار قبلی باشد. اساس این کمینه‌سازی، حرکت بر روی بردار گرادیان تابع مربعات خطای شبکه می‌باشد که این بردار نیز به نوبه خود بوسیله مشتق‌گیری زنجیره‌ای از تابع خطا نسبت به تک تک پارامترهای شبکه بدست می‌آید [۱۱]. اگر چه استفاده از الگوریتم پس انتشار در این سال‌ها برای آموزش شبکه‌های عصبی بسیار رواج یافته است، اما استفاده از این روش در برخی موارد منجر به بروز مشکلاتی می‌گردد. این موانع شامل سرعت پایین همگرایی در روند آموزش و همگرایی زودرس در کمینه‌های محلی می‌باشد.

^۳ Particle Swarm Optimization

^۴ Genetic Algorithm

^۵ Geometry-Free

^۱ Optimization

^۲ Back-propagation

در روابط (۱) و (۲) I_1 و I_2 تاخیر یونسفری بروی فرکانس‌های L_1 و L_2 ، λ_1 و λ_2 طول موج، N_1 و N_2 ابهام فاز موج حامل، b_r^P و b_s^P بایاس داخل فرکانسی گیرنده و ماهواره برای مشاهدات کد، b_r^Φ و b_s^Φ بایاس داخل فرکانسی گیرنده و ماهواره برای مشاهدات فاز، ε_{12}^P ترکیب نویز مشاهدات و اثر چند مسیری روی مشاهدات کد و ε_{12}^Φ ترکیب نویز مشاهدات و اثر چند مسیری روی مشاهدات فاز می‌باشند. تاخیر یونسفری بروی هر دو فرکانس با مقدار STEC دارای رابطه زیر می‌باشد:

$$I_p = \pm \frac{40.3}{f^2} STEC \quad (3)$$

با جایگزاری رابطه (۳) در رابطه (۱) و انجام محاسبات لازم خواهیم داشت:

$$P_4 = 40.3 \left(\frac{f_2^2 - f_1^2}{f_1^2 f_2^2} \right) STEC + b_r^P + b_s^P + \varepsilon_{12}^P \quad (4)$$

با مرتب‌سازی رابطه (۴) می‌توان نوشت:

$$STEC_p = \frac{P_4}{\beta} = STEC + B_r^P + B_s^P + \varepsilon_{p4} \quad (5)$$

در رابطه (۵) B_r^P مقدار بایاس داخل فرکانسی گیرنده برای مشاهدات کد برحسب واحد TECU، B_s^P مقدار بایاس داخل فرکانسی ماهواره برای مشاهدات کد برحسب واحد TECU و ε_{p4} ترکیب نویز مشاهدات و اثر چند مسیری روی مشاهدات کد برحسب واحد TECU می‌باشند. همچنین در رابطه (۵) مقدار β بصورت زیر محاسبه می‌شود:

$$\beta = 40.3 \left(\frac{f_2^2 - f_1^2}{f_1^2 f_2^2} \right) \quad (6)$$

با استفاده از مشاهدات فاز موج حامل و همانند روش بالا می‌توان مقدار STEC نسبی را بصورت زیر بدست آورد:

$$STEC_\Phi = \frac{\Phi_4}{\beta} = -STEC + N_{arc} + B_r^\Phi + B_s^\Phi + \varepsilon_{\Phi 4} \quad (7)$$

در رابطه (۷) B_r^Φ مقدار بایاس داخل فرکانسی گیرنده برای مشاهدات کد برحسب واحد TECU، B_s^Φ مقدار بایاس داخل فرکانسی ماهواره برای مشاهدات کد برحسب واحد TECU و ε_{p4} ترکیب نویز مشاهدات و اثر چند مسیری روی مشاهدات فاز برحسب واحد TECU، N_{arc} بایاس در مشاهدات یونسفری بسبب ابهام فاز موجود در مشاهدات فاز می‌باشند که با رابطه زیر محاسبه می‌شود:

$$N_{arc} = \frac{\lambda_1 N_1}{\beta} - \frac{\lambda_2 N_2}{\beta} \quad (8)$$

در تمامی روابط بالا مقادیر بایاس داخل فرکانسی ماهواره از تولیدات شبکه جهانی IGS و بایاس‌های مربوط به گیرنده‌ها از پیش‌پردازش‌های مشاهدات ایستگاه‌های GPS بدست آمده است.

۲-۱- مشاهدات STEC نرم شده


مشاهدات شبه فاصله معمولاً دارای نویز بالایی بوده و متأثر از اثر چند مسیری است. در نتیجه مقدار STEC حاصل از این مشاهدات دارای نویز زیادی هستند. با استفاده از آنتن‌های خاص همانند چک-رینگ^۱ و یا گیرنده‌هایی با تکنولوژی‌های پیشرفته امروزی می‌توان مقدار اثر چند مسیری را تا حد امکان کاهش داد. بایستی توجه داشت که با استفاده از مشاهدات فاز موج حامل می‌توان مقدار نویز و اثر چند مسیری را از مشاهدات STEC حاصل از مشاهدات کد کاهش داده و به یک مقدار نسبی دقیقی از STEC دست یافت. مشاهدات STEC حاصل از اندازه‌گیری‌های فاز موج حامل دقیق‌تر از مشاهدات STEC حاصل از مشاهدات کد 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^۲ مقدار STEC با همدیگر ترکیب نمود [۱۳]. در این تقریب مقادیر STEC حاصل از

^۱ Choke-ring

^۲ Smoothing

۳- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی روشی تقریباً جدید برای تقریب توابع و پیش‌بینی حالت آینده سیستم‌های مختلف می‌باشند. این شبکه‌ها برای حالتی که بین ورودی و خروجی سیستم روابط غیرخطی برقرار است، به نتایج قابل قبول منتج می‌شوند و از این رو در بسیاری از حوزه‌های علمی مورد استفاده قرار می‌گیرند. شبکه‌های عصبی نسبت به روش‌های رایج همانند کمترین مربعات دارای سرعت عمل و دقت بالاتری بوده و حساسیت آنها نسبت به نویزها بسیار پایین‌تر است [۱]. شبکه‌های عصبی مصنوعی با پردازش روی داده‌های تجربی، قانون نهفته در آنها را کشف کرده و به داخل ساختار شبکه انتقال می‌دهند. هر شبکه عصبی از تعدادی گره که همان نورون‌ها هستند و وزن‌های ارتباطی که گره‌ها را به هم وصل می‌کنند، تشکیل شده است. داده‌های ورودی در وزن متناظرشان ضرب می‌شوند و مجموع آنها به نورون‌ها وارد می‌گردند. هر نورون دارای یک تابع فعال‌سازی می‌باشد. این مقدار ورودی از تابع فعال‌سازی عبور کرده و مقدار خروجی نورون را مشخص می‌کند [۱۴]. تعداد نورون‌ها و لایه‌های شبکه عصبی متناسب با مسئله مورد نظر و با روش سعی و خطا به دست می‌آید. یک شبکه عصبی شامل اجزای سازنده لایه‌ها و وزن‌ها می‌باشد. رفتار شبکه نیز وابسته به ارتباط بین اعضا است. شکل (۱) ساختار یک شبکه عصبی با لایه‌های ورودی، پنهان و خروجی را نشان می‌دهد.



شکل ۱- ساختار یک شبکه عصبی چندلایه

۳-۱- آموزش شبکه‌های عصبی مصنوعی

هدف از آموزش شبکه‌های عصبی، یافتن اندازه وزن‌ها و بایاس‌ها به نحوی است که خطای داده‌های آموزش را به

مشاهدات فاز در کمان‌های پیوسته^۱ توسط مقادیر میانگین مشاهدات STEC حاصل از اندازه‌گیری‌های کد تعدیل می‌شوند. مقدار میانگین برای هر کمان پیوسته بصورت زیر محاسبه می‌شود:

$$\langle STEC_p + STEC_\phi \rangle = \frac{1}{N} \sum_{i=1}^N (STEC_p + STEC_\phi)_i \quad (9)$$

در رابطه (۹) N نشاندهنده تعداد اندازه‌گیری‌های پیوسته برای کمان مورد نظر بوده و $\langle \cdot \rangle$ بیانگر مقدار میانگین می‌باشد. با فرض اینکه مقادیر بایاس داخل فرکانسی ثابت بوده و با جایگزاری روابط (۵) و (۷) در رابطه (۹) می‌توان نوشت:

$$\langle STEC_p + STEC_\phi \rangle = (B_r^p + B_s^p + B_r^\phi + B_s^\phi) + \frac{1}{N} \sum_{i=1}^N (N_{arc} + \varepsilon_{p4}) \quad (10)$$

با تفاضل رابطه (۷) از رابطه (۱۰) جملات مربوط به ابهام فاز حذف شده و مقدار STEC نرم شده بصورت زیر حاصل می‌شود:

$$STEC_{smoothed} = \langle STEC_p + STEC_\phi \rangle - STEC_\phi = STEC + (B_r^p + B_s^p) + \varepsilon_{p4} \quad (11)$$

جهت بدست آوردن مقدار محتوای الکترون کلی یونسفر در راستای زنیت می‌توان از تابع تصویر بصورت زیر استفاده کرد:

$$VTEC = M \times STEC_{smoothed} \quad (12)$$

که خواهیم داشت:

$$M = \sin(elev) \quad (13)$$

در رابطه (۱۳) $elev$ زاویه ارتفاعی ماهواره می‌باشد. مقادیر بدست آمده از رابطه (۱۲) در هر ایستگاه شبکه به عنوان خروجی در نظر گرفته می‌شود. پس از مدل‌سازی مقدار محتوای الکترون کلی لایه یونسفر با شبکه عصبی مصنوعی، می‌توان مقدار VTEC را در هر نقطه‌ای خارج از نقاط اصلی شبکه و نیز در نقاطی نزدیک به محدوده شبکه بصورت تابعی از زمان برآورد نمود.

^۱ Continues arc

حداقل ممکن برساند. لذا آموزش شبکه‌های عصبی را می‌توان در بردارنده یک مسئله بهینه‌سازی^۱ دانست که هدف از آن بهینه‌سازی ضرایب وزنی و بایاس‌ها جهت دستیابی به حداقل خطای آموزش می‌باشد. دلیل معایب موجود در الگوریتم آموزش پس انتشار خطا از جمله سرعت پایین همگرایی در روند آموزش و همگرایی زودرس در کمینه‌های محلی در این مقاله از الگوریتم PSO جهت آموزش شبکه عصبی استفاده شده است.

۳-۲- الگوریتم آموزش PSO

هر ذره در الگوریتم PSO از سه بردار d بعدی تشکیل شده است که d بعد فضای جستجو می‌باشد. برای ذره i ام این سه بردار عبارتند از: x^i موقعیت فعلی ذره، v^i سرعت حرکت ذره و $x^{i,best}$ بهترین موقعیتی که ذره تا به حال تجربه کرده است. $x^{i,best}$ مجموعه‌ای از مختصات است که موقعیت فعلی ذره را نمایش می‌دهد. در هر مرحله‌ای که الگوریتم تکرار می‌شود، x^i به عنوان یک جواب برای مساله محاسبه می‌شود. اگر این موقعیت بهتر از جواب‌های پیشین باشد در $x^{i,best}$ ذخیره می‌شود. f^i مقدار تابع هدف در x^i و $f^{i,best}$ مقدار تابع هدف در $x^{i,best}$ است که هر دو از عناصر تشکیل دهنده هر ذره به حساب می‌آیند. در هر تکرار x^i و v^i جدیدی بدست می‌آیند و منظور از اجرای الگوریتم، بهتر کردن $x^{i,best}$ است. بهترین موقعیتی که بوسیله همه ذرات پیدا شده است بصورت $x^{g,best}$ نشان داده می‌شود که با مقایسه مقادیر $f^{i,best}$ به ازای همه ذرات و از میان $x^{i,best}$ ها انتخاب می‌شود. مقدار تابع هدف در $x^{g,best}$ بصورت $f^{g,best}$ نشان داده می‌شود. اگر تعداد ذرات موجود در جمعیت n باشد آنگاه می‌توان روابط زیر را نوشت:

$$x^{i,best}[t] = \arg \min_{\tau \leq t} f(x^i[\tau]) = \arg \min \{f(x^i[t]), f(x^{i,best}[t-1])\} \quad (14)$$

$$f^{i,best}[t] = f(x^{i,best}[t]) = \min_{\tau \leq t} f^i[\tau] = \min \{f^i[t], f^{i,best}[t-1]\} \quad (15)$$

$$x^{g,best}[t] = \arg \min_{i=1, \dots, n} f(x^{i,best}[t]) \quad (16)$$


$$f^{g,best}[t] = f(x^{g,best}[t]) = \min_{t=1, \dots, n} f^{i,best}[t] \quad (17)$$

در مرحله ابتدایی الگوریتم، ذرات با موقعیت‌ها و سرعت‌های تصادفی ایجاد می‌شوند. در طی اجرای الگوریتم، موقعیت و سرعت هر ذره در مرحله $t+1$ ام از الگوریتم، از روی اطلاعات مرحله قبلی ساخته می‌شوند. اگر z_j مولفه z ام از بردار z باشد، آنگاه روابطی که سرعت و موقعیت ذرات را تغییر می‌دهند، عبارتند از:

$$v_j^i[t+1] = wv_j^i[t] + c_1r_1(x_j^{i,best}[t] - x_j^i[t]) + c_2r_2(x_j^{g,best}[t] - x_j^i[t]) \quad (18)$$

$$x_j^i[t+1] = x_j^i[t] + v_j^i[t+1] \quad (19)$$

در این روابط w ضریب اینرسی، r_1 و r_2 اعدادی تصادفی در بازه $[0,1]$ با توزیع یکنواخت و همچنین c_1 و c_2 ضرایب یادگیری هستند. r_1 و r_2 باعث می‌شوند که نوعی گوناگونی در جواب‌ها بوجود بیاید و به این نحو جستجوی کاملی روی فضا انجام پذیرد. c_1 ضریب یادگیری مربوط به تجارب شخصی هر ذره است و در مقابل c_2 ضریب یادگیری مربوط به تجارب کل جمع می‌باشد. شکل (۲) مراحل کلی انجام الگوریتم آموزش PSO را نشان می‌دهد.



شکل ۲- مراحل الگوریتم PSO

از معادله (۱۸) می‌توان به این نتیجه رسید که هر ذره به هنگام حرکت الف) جهت حرکت قبلی خود، ب) بهترین موقعیتی را که در آن قرار داشته است و پ) بهترین موقعیتی را که بوسیله کل جمع تجربه شده است، در نظر می‌گیرد. ضریب اینرسی w بروی همگرایی الگوریتم PSO تاثیر مستقیم دارد. در واقع می‌توان بواسطه

^۱ Optimization

تعیین بایاس‌ها ($Z(x)$). این دو مرحله بصورت رابطه زیر نمایش داده می‌شوند:

$$Y(x) = f(x) + Z(x) \quad (20)$$

در رابطه (۲۰) $f(x)$ تابع رگرسیون و $Z(x)$ پردازش‌های آماری با در نظر گرفتن میانگین صفر و واریانس σ^2 و نیز ماتریس همبستگی^{۱۱} Ψ می‌باشند. بسته به نوع تابع رگرسیون انتخاب شده درون‌یابی کریجینگ را می‌توان تقسیم‌بندی کرد. اگر تابع رگرسیون بصورت یک چندجمله‌ای چند متغیره^{۱۲} تعریف گردد آنرا کریژینگ فراگیر می‌نامند. در این حالت می‌توان نوشت:

$$f(x) = \sum_{i=1}^p \alpha_i b_i(x) \quad (21)$$

در رابطه (۲۱) $b_i(x)$ توابع پایه و $\alpha = (\alpha_1, \dots, \alpha_p)$ نشان‌دهنده ضرایب می‌باشند. در نظر بگیریم که نمونه‌ای به طول n بصورت $X = (x^1, \dots, x^n)$ و مقادیر خروجی مربوط به هر نمونه بصورت $Y = (y^1, \dots, y^n)$ باشند. در این صورت ماتریس مدل با ابعاد $n \times p$ بصورت زیر می‌تواند تعریف گردد:

$$F = \begin{pmatrix} b_1(x^1) & \dots & b_p(x^1) \\ \vdots & \ddots & \vdots \\ b_1(x^n) & \dots & b_p(x^n) \end{pmatrix} \quad (22)$$

برای نمونه ارائه شده ماتریس همبستگی را می‌توان بصورت زیر در نظر گرفت:

$$\Psi = \begin{pmatrix} \psi(x^1, x^1) & \dots & \psi(x^1, x^n) \\ \vdots & \ddots & \vdots \\ \psi(x^n, x^1) & \dots & \psi(x^n, x^n) \end{pmatrix} \quad (23)$$

که در رابطه (۳۱-۳) $\psi(x^n, x^n)$ تابع کوورلیشن می‌باشد. نتیجتاً میانگین و واریانس پیش‌بینی شده توسط درون‌یابی کریجینگ برای هر نقطه بصورت زیر محاسبه می‌شود:

$$\mu(x) = M\alpha + r(x) \times \Psi^{-1} \times (y - F\alpha) \quad (23)$$

^{۱۱} Correlation Matrix
^{۱۲} multivariate polynomial

ضریب اینرسی، تاثیر سرعت‌های گذشته را بر سرعت‌های زمان حال کنترل نمود. می‌توان برای برقراری موازنه بهتر میان جستجوی سراسری^۱ و جستجوی محلی^۲ مقدار w را تغییر داد. مقدار زیاد برای w باعث می‌شود که ذرات موجود در الگوریتم، به جستجوی مناطق جدیدتر روی بیاورند و یک جستجوی سراسری را انجام دهند. در مقابل یک مقدار کم برای w باعث می‌شود که ذرات در منطقه محدودی بمانند و در واقع یک جستجوی محلی را انجام دهند. جستجوی محلی برای دقیق‌تر کردن جواب‌های فعلی مناسب است و جستجوی سراسری برای یافتن جواب‌های بهتری که به احتمال در جاهای ناشناخته از فضای جستجو وجود دارند بکار می‌رود.

۴- کریجینگ فراگیر

یکی از تکنیک‌های بسیار مناسب و پیشرفته برای تحلیل فضایی^۳ و توزیع منطقه‌ای داده‌های مکانی استفاده از روش کریجینگ می‌باشد. کریجینگ یک روش درون‌یابی بهینه^۴ است که متغیرهای استفاده شده در آن تصادفی هستند و از تابع هندسی مشخصی تبعیت نمی‌کنند. بدلیل ویژگی خاصی که این روش دارد در مباحث درون‌یابی مربوط به علوم زمین بصورت گسترده‌ای مورد استفاده قرار می‌گیرد. این روش در دهه شصت میلادی توسط مهندس فرانسوی جرج ماترون مورد استفاده قرار گرفت. البته قبل از وی (دهه پنجاه میلادی) دین کریژ کارهای عملی ساده‌ای را با این روش انجام داده بود. درون‌یابی بروش کریجینگ را می‌توان در چهار حالت کریجینگ معمولی^۵، کریجینگ فراگیر^۶، کریجینگ قطعه‌ای^۷ و کوکریجینگ^۸ انجام داد.

درون‌یابی کریجینگ از دو مرحله تشکیل شده است: مرحله اول ساختن تابع رگرسیون^۹ با استفاده از داده‌های ورودی ($f(x)$) و مرحله دوم پردازش‌های آماری^{۱۰} جهت

^۱ Global Search
^۲ Local Search
^۳ Spatial Analysis
^۴ Optimal Interpolation Method
^۵ Ordinary Kriging
^۶ Universal Kriging
^۷ Blok Kriging
^۸ Cokriging
^۹ Regression Function
^{۱۰} Statistical Process

۳۰ ایستگاه جهت آموزش^۱، ۱ ایستگاه جهت ارزیابی^۲ و ۵ ایستگاه جهت آزمون^۳ نتایج روش بکار گرفته شده‌اند. اندازه‌گیری‌های ایستگاه‌های آزمون در مرحله آموزش شبکه عصبی بکار نرفته است. در بازه‌های زمانی ۳۰ دقیقه (نیم ساعت) مشاهدات VTEC از اندازه‌گیری‌های ایستگاه‌های GPS، مطابق با الگوریتم مورد اشاره در بخش دوم محاسبه شده است. پایگاه داده مشاهداتی برابر با ۳۶۰۰۰ داده VTEC بعنوان خروجی شبکه عصبی و نیز مقادیر طول و عرض جغرافیایی، ساعت و روز مشاهده نیز به عنوان ۴ پارامتر ورودی جهت آموزش مورد استفاده قرار گرفته‌اند. رابطه زیر نشان‌دهنده ارتباط مابین ورودی و خروجی شبکه عصبی مورد استفاده می‌باشد:

$$VTEC_{NN} = f(lat \quad lon \quad Hr \quad d) \quad (25)$$

در این مقاله جهت ارزیابی نتایج شبکه عصبی مصنوعی در برآورد مقدار VTEC از مفهوم شاخص dVTEC استفاده شده است. این شاخص بصورت زیر تعریف می‌شود:

$$dVTEC = |VTEC_M - VTEC_{GPS}| \quad (26)$$


که در رابطه (۲۶) $VTEC_M$ مقدار بدست آمده از مدل‌ها در نقاط آزمون و $VTEC_{GPS}$ مقدار محاسبه شده از اندازه‌گیری‌های GPS در نقاط آزمون می‌باشند. جهت انتخاب ساختار بهینه شبکه و نیز ارزیابی کارایی، دقت و سرعت همگرایی الگوریتم PSO مقادیر میانگین مربع خطا (MSE) برای مراحل آزمون و آموزش محاسبه شده است. نتیجه این ارزیابی در جدول (۱) آورده شده است. بکمک نتایج این جدول بوضوح می‌توان مشاهده نمود که در تعداد تکرار ثابت (مقدار تکرار ۱۴۶ براساس سعی و خطا بدست آمده است) و برای ساختارهای متفاوت از شبکه عصبی مصنوعی، ساختار ۱-۱۸-۴ دارای کمترین مقدار خطا در مراحل آموزش و آزمون بوده است.

$$s^2(x) = \sigma \left(1 - r(x) \Psi^{-1} r(x)^T + \frac{(1 - F^T \Psi^{-1} r(x)^T)}{F^T \Psi^{-1} F} \right) \quad (24)$$

در روابط بالا $M = (b_1(x), b_2(x), \dots, b_p(x))$ ماتریس مدل در نقطه مجهول مورد نظر، $\alpha = (F^T \Psi^{-1} F)^{-1} F^T \Psi^{-1} y$ بردار ضرایب مربوط به تابع رگرسیون و $r(x) = (\psi(x, x^1), \dots, \psi(x, x^n))$ بردار همبستگی مابین نقاط نمونه و نقطه مجهول می‌باشند.

۵- آنالیز نتایج


جهت بررسی و ارزیابی دقت الگوریتم آموزش PSO در پیش‌بینی تغییرات زمان-مکان مقدار محتوای الکترون کلی یونسفر، از مشاهدات ۳۶ ایستگاه GPS موجود در منطقه ایران استفاده شده است. اندازه‌گیری‌های استفاده شده مربوط به ماه آگوست سال ۲۰۱۲ می‌باشند. ۱۱ روز از سال ۲۰۱۲ (۲۲۰ الی ۲۳۰) جهت آنالیز روش بکار گرفته شده است. چگونگی پراکندگی این ایستگاه‌ها در شکل (۳) نشان داده شده است. در این شکل ستاره‌های مشکی نشانگر ایستگاه‌های مورد استفاده در مدل‌سازی و دایره‌های قرمز بیانگر ایستگاه‌های آزمون می‌باشند. ایستگاه‌های آزمون عبارتند از Tabz (۳۷/۸۶ و ۴۶/۳۴)، Tehn (۵۱/۳۳ و ۳۵/۵۱)، Mshn (۳۶/۱۵ و ۵۹/۴۷)، Zabl (۳۰/۶۷ و ۶۱/۷۱) و Bebn (۳۰/۴۳ و ۵۰/۲۱).



شکل ۳- چگونگی توزیع مکانی ایستگاه‌های مورد استفاده در این مقاله

ایستگاه‌های مورد استفاده در این تحقیق به سه بخش تقسیم‌بندی شده‌اند. از ۳۶ ایستگاه GPS موجود، مشاهدات

^۱ Train
^۲ Validation
^۳ Test



شکل ۴- تغییرات مقادیر شاخص dVTEC حاصل در ۵ ایستگاه آزمون
 برترتیب از بالا ایستگاه آزمون Bebn و Zabl, Mash, Tehn, Tabz

براساس مقایسه های صورت گرفته در شکل (۴) و
 نتایج بدست آمده برای شاخص dVTEC در ۵ ایستگاه

جدول ۱- مقایسه مقادیر خطای موجود در مرحله آموزش و آزمون
 برای ساختارهای مختلف شبکه عصبی مصنوعی ۳ لایه با الگوریتم
 آموزش PSO

تعداد تکرار	MSE برای مرحله آزمون (TECU)	MSE برای مرحله آموزش (TECU)	ساختار شبکه	ردیف
۱۴۶	۲/۰۸۹	۲/۴۲۶	۴-۱۶-۱	۱
۱۴۶	۱/۶۴۸	۱/۹۵۲	۴-۱۷-۱	۲
۱۴۶	۱/۴۶۹	۱/۸۵۲	۴-۱۸-۱	۳
۱۴۶	۱/۷۵۹	۲/۱۷۹	۴-۱۹-۱	۴
۱۴۶	۲/۲۳۶	۲/۶۵۸	۴-۲۰-۱	۵


در جدول (۲) نیز مقادیر خطای مراحل آموزش و
 آزمون برای تعداد دوره های متفاوت در ساختار ۴-۱۸-۱
 آورده شده است.

جدول ۲- مقایسه تعداد تکرار و مقادیر خطای موجود در مرحله
 آموزش و آزمون برای ساختار ۴-۱۸-۱ با الگوریتم آموزش PSO

تعداد تکرار	MSE برای مرحله آزمون (TECU)	MSE برای مرحله آموزش (TECU)	ساختار شبکه	ردیف
۵۰	۲/۱۶۹	۲/۳۶۹	۴-۱۸-۱	۱
۸۰	۲/۱۲۳	۲/۴۵۶	۴-۱۸-۱	۲
۱۴۶	۱/۴۶۹	۱/۸۵۲	۴-۱۸-۱	۳
۱۰۹	۱/۸۵۲	۲/۳۵۷	۴-۱۸-۱	۴
۱۲۰	۲/۱۵۷	۲/۳۵۹	۴-۱۸-۱	۵

با استفاده از شبکه عصبی مصنوعی و الگوریتم آموزش
 PSO مقادیر VTEC برای ۵ ایستگاه آزمون در طول ۲۴
 ساعت پیش بینی شده است. این مقایسه برای ۱۱ روز
 مختلف (۲۲۰ الی ۲۳۰) از سال ۲۰۱۲ انجام گرفته است.
 همچنین مقادیر بدست آمده با مقادیر VTEC حاصل از
 اندازه گیری های GPS به عنوان مرجع، مدل مرجع
 بین المللی ۲۰۱۲ و روش کریجینگ فراگیر مورد مقایسه
 قرار گرفته است. در مقایسه های صورت گرفته متوسط
 مقدار dVTEC برای ۲۴ ساعت از هر روز محاسبه شده و
 در نمودارها قرار گرفته است.

دو مدل ANN-PSO و کریجینگ از دقت‌های بالاتری نسبت به مدل IRI-2012 برخوردارند. همچنین این نتایج حاکی از برتری نسبی مدل ANN-PSO نسبت به مدل کریجینگ می‌باشد. جهت بررسی صحت نتایج حاصل مقدار ضریب همبستگی هر سه مدل ANN-PSO، IRI-2012 و کریجینگ با مشاهدات TEC بدست آمده از GPS مورد مقایسه قرار گرفته است. این مقایسه در شکل (۵) نشان داده شده است. در این شکل خط مربوط به بهترین برازش نیز آورده شده است.




شکل ۵- نمایش بهترین مقدار رگرسیون بدست آمده برای مقادیر TEC محاسبه شده از GPS در مقابل نتایج حاصل از مدل‌های ANN-PSO، IRI-2012 و کریجینگ

با توجه به شکل (۵) مقادیر ضریب همبستگی برای حالت GPS و ANN-PSO برابر 0.9331 ، برای حالت

آزمون در نظر گرفته شده می‌توان موارد زیر را مورد بررسی قرار داد:

- در ایستگاه آزمون Tabz کمترین و بیشترین مقدار dVTEC برای روش ANN-PSO بترتیب برابر با $0.55/4.69$ و $0.79/4.84$ TECU بدست آمده است. برای روش کریجینگ فراگیر کمترین و بیشترین مقدار dVTEC بترتیب برابر با $0.79/4.84$ و $1.55/6.79$ TECU بدست آمده است. مدل IRI-2012 این مقادیر بترتیب برابر با $1.55/6.79$ TECU محاسبه شده است.
 - در ایستگاه آزمون Tehn کمترین و بیشترین مقدار dVTEC برای روش ANN-PSO بترتیب برابر با $0.97/4.97$ و $0.70/4.83$ TECU بدست آمده است. برای روش کریجینگ فراگیر کمترین و بیشترین مقدار dVTEC بترتیب برابر با $0.70/4.83$ و $2.17/5.72$ TECU محاسبه شده است.
 - در ایستگاه آزمون Mash کمترین و بیشترین مقدار dVTEC برای روش ANN-PSO بترتیب برابر با $0.68/5.45$ و $0.86/5.19$ TECU بدست آمده است. برای روش کریجینگ فراگیر کمترین و بیشترین مقدار dVTEC بترتیب برابر با $0.86/5.19$ و $2.59/7.16$ TECU محاسبه شده است.
 - در ایستگاه آزمون Zabl کمترین و بیشترین مقدار dVTEC برای روش ANN-PSO بترتیب برابر با $1.23/5.33$ و $0.05/5.21$ TECU بدست آمده است. برای روش کریجینگ فراگیر کمترین و بیشترین مقدار dVTEC بترتیب برابر با $0.05/5.21$ و $2.47/6.60$ TECU محاسبه شده است.
 - در ایستگاه آزمون Bebn کمترین و بیشترین مقدار dVTEC برای روش ANN-PSO بترتیب برابر با $0.75/4.21$ و $0.84/3.14$ TECU بدست آمده است. برای روش کریجینگ فراگیر کمترین و بیشترین مقدار dVTEC بترتیب برابر با $0.84/3.14$ و $2.47/5.64$ TECU محاسبه شده است.
- نتایج بدست آمده از آنالیز انجام گرفته با استفاده از شاخص dVTEC در پنج ایستگاه آزمون نشان می‌دهد که




شکل ۶- تغییران مقادیر محتوای الکترون کلی در ۵ ایستگاه آزمون Zabl, Mash, Tehn, Tabz برای ۱۱ روز متوالی و ۲۴ ساعت از شبانه روز

با توجه به نتایج حاصل از شکل (۶) بوضوح قابل مشاهده است که بیشینه مقدار محتوای الکترون کلی در ساعات مابین ۱۰ الی ۱۲ در طول روز رخ می‌دهد. نتایج حاصل همچنین بیانگر این موضوع است که با استفاده از مدل ANN-PSO براحتی می‌توان مقدار محتوای الکترون کلی را در هر موقعیت و زمان ممکن در داخل شبکه مورد نظر محاسبه نمود.

۵- نتیجه‌گیری

شبکه عصبی مصنوعی یک سامانه پردازشی داده‌ها است که از مغز انسان ایده گرفته و پردازش داده‌ها را به عهده پردازنده‌های کوچک و بسیار زیادی سپرده که به صورت شبکه‌ای به هم پیوسته و موازی با یکدیگر رفتار می‌کنند تا یک مسئله را حل نمایند. بدلیل ماهیت خاص این نوع از شبکه‌ها، از آنها جهت مدل‌سازی پدیده‌هایی با رفتار غیرخطی استفاده می‌شود. بهمین جهت در این مقاله از یک شبکه عصبی مصنوعی سه لایه با ۱۸ نورون در لایه مخفی جهت مدل‌سازی سری زمانی تغییرات محتوای

GPS و کریجینگ برابر ۰/۹۲۷۲ و برای حالت GPS و IRI-2012 برابر با ۰/۸۶۱۶ بدست آمده است. نتایج بیانگر این موضوع است که مقادیر TEC بدست آمده از مدل ANN-PSO دارای همبستگی زیادی با مشاهدات TEC بدست آمده از GPS دارند. پس از ارزیابی دقت و صحت مدل ANN-PSO در ایستگاه‌های آزمون، می‌توان سری زمانی تغییرات مقدار محتوای الکترون کلی را برای هر پنج ایستگاه، در ۲۴ ساعت شبانه‌روز و ۱۱ روز متوالی مدل‌سازی کرد. نتیجه این آنالیز در شکل (۶) نمایش داده شده است.



الکترون کلی لایه یونسفر در ایران استفاده شد. داده‌های ۳۶ ایستگاه از شبکه مبنای ژئودینامیک ایران جهت محاسبه مشاهدات ورودی شبکه عصبی بکار گرفته شدند. این داده‌ها مربوط به ۱۱ روز از سال ۲۰۱۲ ماه آگوست بودند. عموماً جهت آموزش شبکه‌های عصبی از الگوریتم پس انتشار خطا استفاده می‌شود. منتها بدلیل معایب موجود در این الگوریتم از جمله سرعت همگرایی پایین و نیز گیر افتادن در کمینه‌های محلی از الگوریتم آموزش بهینه‌سازی انبوه ذرات (PSO) استفاده می‌شود. آنالیزهای انجام گرفته در این مقاله نشان داد که با بهره‌گیری از الگوریتم آموزش PSO نه تنها زمان همگرا شدن به جواب بهینه کاهش می‌یابد بلکه دقت و صحت نتایج نیز افزایش پیدا می‌کند.

نتایج حاصل از شبکه عصبی مصنوعی با نتایج حاصل از مدل مرجع جهانی ۲۰۱۲ و نیز روش کریجینگ فراگیر مورد مقایسه قرار گرفت. در تمامی مقایسه‌های انجام گرفته مشاهدات VTEC بدست آمده از GPS به عنوان مشاهده مرجع مورد استفاده قرار گرفت. در اکثر

مقایسه‌های صورت گرفته خروجی بدست آمده از شبکه عصبی از مقدار خطای کمتری نسبت به مدل مرجع جهانی و روش کریجینگ فراگیر برخوردار بوده است. میانگین شاخص dVTEC بدست آمده برای شبکه عصبی مصنوعی با الگوریتم آموزش PSO در ۱۱ روز متوالی از سال ۲۰۱۲ برابر ۲/۳۴ TECU بوده است. این مقدار برای مدل مرجع جهانی ۲۰۱۲ برابر ۵/۸۹ TECU و برای روش کریجینگ فراگیر برابر ۲/۷۸ TECU بدست آمده است. مقایسه صورت گرفته در مورد ضریب همبستگی نیز حاکی از برتری روش شبکه عصبی مصنوعی در برآورد مقدار TEC بوده است. مهم‌ترین مزیت شبکه‌های عصبی مصنوعی یادگیری شبکه، پردازش موازی، سرعت و انعطاف‌پذیری در محاسبات است. اگر تعداد مشاهدات مورد استفاده در آموزش شبکه عصبی از مقدار معینی کمتر باشد، ممکن است در این مواقع شبکه عصبی نتایج نامطمئنی به‌دست دهد که این امر می‌تواند از معایب مدل‌سازی با شبکه‌های عصبی باشد.

مراجع

- [1] M.R. Ghaffari Razin, A. Mohammadzadeh. Regional Ionosphere Modeling Using Artificial Neural Networks and Polynomial Fitting Over Iran. JGST. 2015; 4 (3):51-60
- [2] Komjathy, A., (1997), Global ionospheric total electron content mapping using the Global Positioning System, Ph.D. thesis, Dep. of Geod. and Geomatics Eng., Univ. of New Brunswick, Fredericton, New Brunswick, Canada.
- [3] Schaer, S., (1999), Mapping and predicting the Earth's Ionosphere Using the Global Positioning System, PhD thesis, Astronomical Institute, University of Berne, Berne Switzerland.
- [4] Ghaffari Razin, M.R., (2015), Development and analysis of 3D ionosphere modeling using base functions and GPS data over Iran. Acta Geod Geophys, DOI 10.1007/s40328-015-0113-9 Volume 51, Issue 1, pp 95-111.
- [5] Seeber. G. , (2003), satellite Geodesy: Foundations. Methods and Applications, Walter de Gruyter. Berlin and New York, 53.
- [6] Wielgosz, P., D. Brzezinska, and I. Kashani, (2003), Regional ionosphere mapping with Kriging and multiquadratic method, J. Global Pos. Syst., 2, 48–55.
- [7] Ghaffari Razin, M.R., Voosoghi, B., (2016), Regional ionosphere modeling using spherical cap harmonics and empirical orthogonal functions over Iran. Acta Geod Geophys, DOI 10.1007/s40328-016-0162-8.
- [8] Orus, R., (2005), Improvement of global ionospheric VTEC maps by using Kriging interpolation technique, J. Atmos. Sol. Terr. Phys., 67, 1598–1609.
- [9] Sayin, I., F. Arikan, and O. Arikan, (2008), Regional TEC mapping with random field priors and Kriging, Radio Sci., 43, RS5012, doi: 10.1029/2007RS003786.
- [10] Ghaffari Razin, M.R., Voosoghi, B., Mohammadzadeh, A., (2015), Efficiency of artificial neural networks in map of total electron content over Iran. Acta Geod Geophys, DOI 10.1007/s4038-015-0143-3.
- [11] Haykin. S, (1994), Neural Networks, a comprehensive Foundation, Macmillan College Publishing Company, New York.
- [12] Ghaffari Razin, M.R., Voosoghi, B., (2016), Modeling of ionosphere time series using wavelet neural networks (case study: N-W of Iran), Advances in Space Research. doi: <http://dx.doi.org/10.1016/j.asr.2016.04.006>.

- [13] Ciralo, L., Azpilicueta, F., Brunini, C., Meza, A., Radicella, SM., (2007), Calibration errors on experimental slant total electron content (TEC) determined with GPS. J Geod 81(2):111–120. doi: 10.1007/s00190-006-0093-1.
- [14] Ghaffari Razin M.R, Voosoghi B, (2016), 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 (2016) 21–30.