



مدل سازی سری زمانی محتوای الکترون کلی لایه یونسپهر به کمک شبکه عصبی چند لایه با الگوریتم آموزش MLP-ANN

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

۱- دانشجوی دکتری ژئودزی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

۲- دانشیار گروه ژئودزی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

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 یونسپهر در منطقه ایران استفاده شده است. مشاهدات ۳۷ ایستگاه GPS در ۵ روز متوالی (۲۲۴، ۲۲۳، ۲۲۲، ۲۲۶، ۲۲۵) از سال ۲۰۱۲ تا ۲۰۱۴ 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 با نتایج حاصل از مدل مرجع بین المللی IRI-2012 (IRI-2012) و نیز شبکه جهانی IGS 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 مدل شبکه عصبی از شاخص های آماری خطای نسبی و خطای مطلق استفاده شده است. کمینه خطای نسبی محاسبه شده برای شبکه عصبی مصنوعی ۰/۴۵ درصد و بیشینه آن ۱۶/۸۵ درصد می باشد. همچنین کمینه و بیشینه خطای مطلق ۰/۰۶ و ۳/۹۶ TECU بدست آمده 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 یونسپهر را برخوردار می باشد.

واژه های کلیدی: شبکه عصبی مصنوعی، GPS، TEC، PSO، یونسپهر

۱- مقدمه

از سال ۱۹۹۰ میلادی اندازه‌گیری‌های سیستم‌های ماهواره‌ای ناوبری جهانی (GNSS) به عنوان یک ابزار موثر و بالرزش جهت مطالعه خصوصیات فیزیکی و نیز تغییرات زمان-مکان لایه یون‌سپهر مورد استفاده قرار گرفته است [۱، ۲ و ۳]. 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 یون‌سپهر و نیز عوامل موجود موثر بر آن، این چالش از اهمیت فوق العاده‌ای برخوردار است. الکترون‌های موجود در یون‌سپهر 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^۱، سیستم‌های ارتباطی^۲، هواشناسی فضایی^۳ و ... ایجاد کرده است [۴]. سیگنال‌های سیستم تعیین موقعیت جهانی (GPS) نیز متأثر از خاصیت الکتریکی یون‌سپهر می‌باشند. بدلیل ماهیت خاص و نیز ویژگی‌های فیزیکی، چگالی الکترونی در یون‌سپهر دارای تغییرات زمانی-مکانی است. این تغییرات می‌تواند ناشی از تغییرات روزانه^۴، تغییرات فصلی^۵، آنومالی‌های مختلف موجود و یا دوره فعالیت‌های خورشیدی^۶ باشد [۵]. وجود فرکانس‌های مختلف در رفتار چگالی الکترونی در یون‌سپهر منجر به اثرات بسیار زیان‌باری در سیستم‌های ارتباطی شده است. جهت پی بردن به ماهیت فعالیت‌های یون‌سپهری 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 یون‌سپهری و نیز تغییرات زمان-مکان چگالی الکترونی در این لایه از جو را مورد مطالعه قرار داد، محتوای کلی الکtron (TEC) می‌باشد. در حقیقت TEC تعداد کل الکترون‌های آزاد در مسیر مابین ماهواره تا گیرنده در ستونی بمساحت ضلع یک متر مربع است [۶]. 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 به دست 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 زمانی-مکانی 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 و یا برونویابی شوند. در نتیجه مقادیر TEC محاسبه شده و نیز مقادیر TEC برآورد شده، می‌توانند به عنوان مدلی جهت بررسی رفتار چگالی الکترونی یون‌سپهر در زمان و مکان مورد استفاده قرار گیرند. تاکنون تلاش‌های بسیار زیادی جهت درون‌یابی و یا برونویابی چگالی الکترونی یون‌سپهر و کمیت TEC در مناطقی که مشاهده کافی و یا مناسب موجود نیست، صورت گرفته است. بطور مثال می‌توان به روش‌های کریثینگ^۷، چندجمله‌ای^۸، هارمونیک‌های کروی^۹، درون‌یابی درون‌یابی به کمک توابع اسپیلانین^{۱۰} اشاره نمود [۷، ۸، ۹ و ۱۰]. 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 یون‌سپهر، مدل‌سازی تحلیلی این لایه از جو را بسیار دشوار کرده است. بنظر می‌رسد ارائه مدل تحلیلی که بتواند تمامی ویژگی‌های موثر موجود بر رفتار یون‌سپهر را در برگیرد کاری سخت و دشوار خواهد بود.

¹ space-based observation systems

² Communication systems

³ Space weather

⁴ Diurnal Variation

⁵ Seasonal Variations

⁶ Solar cycle variations

⁷ Kriging

⁸ Polynomial

⁹ Spherical Harmonics

¹⁰ Spline Functions

بنابراین استفاده از سیستم‌هایی که در عین سادگی و کارآمد بودن، بتواند پردازش‌های موازی^۱ را برای سیستم‌هایی با رفتار غیر خطی و پیچیده همانند لایه یون‌سپهر انجام دهد کاملاً احساس می‌شود. شبکه‌های عصبی مصنوعی به عنوان ماهیت غیرخطی و نیز بدلیل سرعت عمل و آسانی در پردازش، از اقبال بسیار زیادی در زمینه مدل‌سازی و برآوردهای پدیده‌هایی همانند رفتار لایه یون‌سپهر 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 یون‌سپهر) برای آموزش شبکه مواجه بوده‌ایم، کارایی بالای 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 مسئله بهینه‌سازی^۲ دانست که هدف از آن بهینه‌سازی ضرایب وزنی و بایاس‌ها جهت دست‌یابی به حداقل خطای آموزش می‌باشد [۱۱]. در روش‌های مرسوم جهت آموزش شبکه‌های عصبی از الگوریتم پس انتشار^۳ و دیگر روش‌های گرادیانی استفاده می‌شود. این روش‌ها 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 حاصله کمتر از میزان اصلاح وزن‌ها و بایاس‌های شبکه پرداخته می‌شود. به نحوی که در انتهای هر تکرار اندازه خطای حاصله کمتر از میزان بهدست 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 خطای نسبت به تک تک پارامترهای شبکه بهدست می‌آید [۱۲]. 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. 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^۴ (PSO) جهت آموزش شبکه عصبی مورد استفاده قرار گرفته است [۱۳]. این الگوریتم قادر است که با یک روش غیر قطعی در فضای جواب‌ها، جوابی نزدیک به بهترین جواب را با سرعت و دقیقی 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) 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 یون‌سپهر در ایران با استفاده از شبکه‌های عصبی مصنوعی می‌باشد. جهت دست‌یافتن 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 و همچنین با خروجی‌های مدل مرجع بین‌المللی IRI-2012 (۲۰۱۲) و شبکه جهانی IGS مورد مقایسه قرار گرفته است.

۲- محاسبه STEC (مشاهده 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 ترопوسفری مستقل از فرکانس بوده و به کمک این ترکیب خطی

¹ Parallel Processing

² optimization

³ Back-propagation

⁴ Particle Swarm Optimization

⁵ Geometry-Free

به صورت کامل حذف خواهد شد. مشاهدات شبیه فاصله معمولاً دارای نویز بالایی بوده و متأثر از اثر چند مسیری می‌باشند. در نتیجه مقدار STEC حاصل از این مشاهدات دارای نویز زیادی هستند. با استفاده از آنتن‌های خاص همانند کوک-رینگ^۱ و یا گیرندهایی با تکنولوژی‌های پیشرفته امروزی می‌توان مقدار اثر چند مسیری را تا حد امکان کاهش داد [۱۴].

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 بهره برداری 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 [۱۴]. در این صورت مقدار STEC نرم شده با دقت بالا به صورت رابطه زیر خواهد بود:

$$\begin{aligned} STEC_{smoothed} &= \langle STEC_P + STEC_\Phi \rangle - STEC_\Phi \\ &= STEC + (B_r^P + B_s^P) + \varepsilon_{P4} \end{aligned} \quad \text{رابطه (۱)}$$

در رابطه (۱) STECP مقدار محتوای الکترونی کلی بدست آمده از مشاهدات کد، $STEC\Phi$ مقدار محتوای الکترونی کلی بدست آمده از مشاهدات فاز، $\langle \cdot \rangle$ بیانگر مقدار میانگین، B_r^P مقدار بایاس داخل فرکانسی گیرنده برای مشاهدات کد، B_s^P مقدار بایاس داخل فرکانسی ماهواره برای مشاهدات کد بر حسب واحد TECU و ε_{P4} نویز مشاهدات می‌باشند. جهت بدست آوردن مقدار محتوای الکترون یون سپهر در راستای زنیت می‌توان ازتابع تصویر به صورت زیر استفاده کرد:

$$VTEC = M \times STEC_{smoothed} \quad \text{رابطه (۲)}$$

که خواهیم داشت:

$$M = \frac{1}{\sin(elev)} \quad \text{رابطه (۳)}$$

در رابطه (۳) $elev$ زاویه ارتفاعی ماهواره می‌باشد. مقادیر بدست آمده از رابطه (۲) در هر ایستگاه شبکه به عنوان خروجی در نظر گرفته می‌شود. پس از مدل‌سازی مقدار محتوای الکترونی لایه یون‌سپهر با شبکه عصبی مصنوعی، می‌توان مقدار VTEC را در هر نقطه‌ای خارج از نقاط اصلی شبکه و نیز در نقاطی نزدیک به محدوده شبکه به صورت مکانی برآورد کرد.

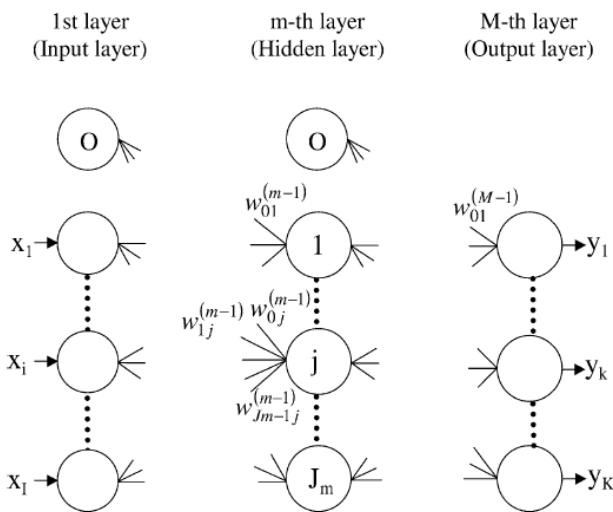
۳- شبکه‌های عصبی مصنوعی

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

¹ choke-ring

² smoothing

بسیار پایین‌تر است [۱۵]. 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 متناظر شان ضرب می‌شوند و مجموع آنها به نورون‌ها وارد می‌گردند. هر نورون دارای یکتابع فعال‌سازی می‌باشد. این مقدار ورودی از تابع فعال‌سازی عبور کرده و مقدار خروجی نورون را مشخص می‌کند [۱۶]. 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 اعضاء است. شکل (۱) ساختار یک شبکه عصبی با لایه‌های ورودی، پنهان و خروجی را نشان می‌دهد.



شکل ۱: ساختار یک شبکه عصبی چندلایه.

۱-۳- آموزش شبکه‌های عصبی مصنوعی

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 مسئله بهینه‌سازی دانست که هدف از آن بهینه‌سازی ضرایب وزنی و بایاس‌ها جهت دست‌بایانی به حداقل خطای آموزش می‌باشد. بدلیل معایب موجود در الگوریتم آموزش پس انتشار خطای 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.

۲-۳- الگوریتم آموزش PSO

هر ذره در الگوریتم PSO از سه بردار d بعدی تشکیل شده است که d بعد فضای جستجو می‌باشد. برای ذره \mathbf{z} ام این سه بردار عبارتنداز: 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 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_{gbest} نشان داده می‌شود که با مقایسه مقادیر $f_{i,best}$ به ازای همه ذرات و از میان $x_{i,best}$ انتخاب می‌شود. مقدار تابع هدف در x_{gbest} بصورت f_{gbest} نشان داده می‌شود. اگر تعداد ذرات موجود در جمعیت n باشد آنگاه می‌توان رابطه‌های زیر را نوشت:

$$x^{i,best}[t] = \arg \min_{\tau \leq t} f(x^i[\tau]) = \arg \min \{f(x^i[t]), f(x^{i,best}[t-1])\} \quad (4)$$

$$f^{i,best}[t] = f(x^{i,best}[t]) = \min_{\tau \leq t} f^i[\tau] = \min \{f^i[t], f^{i,best}[t-1]\} \quad (5)$$

$$x^{gbest}[t] = \arg \min_{i=1,\dots,n} f(x^{i,best}[t]) \quad (6)$$

$$f^{gbest}[t] = f(x^{gbest}[t]) = \min_{t=1,\dots,n} f^{i,best}[t] \quad (7)$$

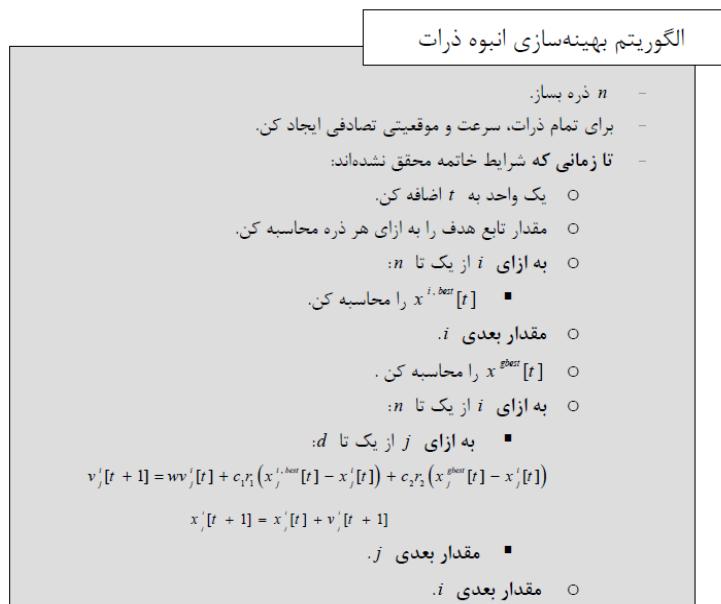
در مرحله ابتدایی الگوریتم، ذرات با موقعیت‌ها و سرعت‌های تصادفی ایجاد می‌شوند. در طی اجرای الگوریتم، موقعیت و سرعت هر ذره در مرحله $t+1$ از مرحله t از روی اطلاعات مرحله قبلی ساخته می‌شوند. اگر z_j مولفه z از بردار z باشد، آنگاه روابطی که سرعت و موقعیت ذرات را تغییر می‌دهند، عبارتنداز:

$$v_j^i[t+1] = w v_j^i[t] + c_1 r_1 (x_j^{i,best}[t] - x_j^i[t]) + c_2 r_2 (x_j^{gbest}[t] - x_j^i[t]) \quad (8)$$

$$x_j^i[t+1] = x_j^i[t] + v_j^i[t+1] \quad (9)$$

در این رابطه‌ها w ضریب اینرسی، c_1 و c_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. از معادله (8) 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 بر روی همگرایی الگوریتم PSO تأثیر مستقیم دارد. در واقع می‌توان بواسطه ضریب اینرسی، تأثیر سرعت‌های گذشته را بر سرعت‌های زمان حال کنترل نمود. می‌توان برای برقراری موازنۀ بهتر میان جستجوی سراسری¹ و جستجوی محلی² مقدار w را تغییر داد.

¹ Global Search
² Local Search

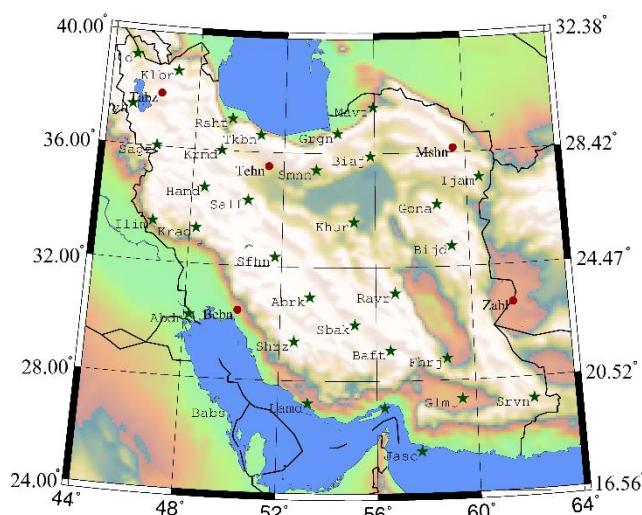


شکل ۲: مراحل الگوریتم PSO

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 سرتاسری برای یافتن جواب‌های بهتری که به احتمال در جاهای ناشناخته از فضای جستجو وجود دارند به کار می‌رود.

۴- آنالیز نتایج

جهت بررسی و ارزیابی دقت الگوریتم آموزش PSO در پیش‌بینی تغییرات زمان-مکان مقدار محتوای الکترون کلی یون سپهر، از مشاهدات ۳۷ ایستگاه GPS موجود در منطقه ایران استفاده شده است. اندازه‌گیریهای استفاده شده مربوط به ماه آگوست سال ۲۰۱۲ می‌باشند. ۵ روز از سال ۲۰۱۲ (۲۰۱۲، ۲۲۴، ۲۲۳، ۲۲۲ و ۲۲۶) جهت آنالیز روش بکار گرفته شده است. چگونگی پراکندگی این ایستگاه‌ها در شکل (۳) نشان داده شده است.



شکل ۳: چگونگی توزیع مکانی ایستگاه‌های مورد استفاده در این مقاله، ستاره‌های مشکی نشان‌گر ایستگاه‌های مورد استفاده در مدل‌سازی و دایره‌های قرمز بیان‌گر ایستگاه آزمون تهران می‌باشند.

ایستگاه‌های مورد استفاده در این تحقیق به سه بخش تقسیم‌بندی شده‌اند. از ۳۷ ایستگاه GPS موجود، مشاهدات ۳۰ ایستگاه جهت آموزش^۱، ۲ ایستگاه جهت ارزیابی^۲ و ۵ ایستگاه جهت آزمون^۳ نتایج روش بکار گرفته شده‌اند. اندازه‌گیری‌های ایستگاه‌های آزمون در مرحله آموزش شبکه عصبی به کار نرفته است. در بازه‌های زمانی ۳۰ دقیقه مشاهدات VTEC از اندازه‌گیری‌های ایستگاه‌های GPS، مطابق با الگوریتم مورد اشاره در بخش دوم محاسبه شده است. پایگاه داده مشاهداتی برابر با ۷۲۰۰ 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:

$$VTEC_{NN} = f(lat \ lon \ Hr \ d) \quad (10)$$

در این مقاله جهت ارزیابی نتایج شبکه عصبی مصنوعی در برآورد مقدار VTEC از دو مفهوم خطای نسبی و خطای مطلق استفاده شده است. خطای مطلق بصورت زیر تعریف می‌شود:

$$Absolute(Error) = |VTEC_{NN} - VTEC_{GPS}| \quad (11)$$

که در رابطه (11) VTEC_{NN} مقدار مشخص در نقاط آزمون و VTEC_{GPS} مقدار برآورده شده از شبکه عصبی در نقاط آزمون می‌باشند. خطای نسبی نیز بصورت زیر تعریف می‌شود:

$$Relative(Error) = \frac{|VTEC_{NN} - VTEC_{GPS}|}{VTEC_{GPS}} \times 100 \quad (12)$$

جهت انتخاب ساختار بهینه شبکه و نیز ارزیابی کارائی، دقت و سرعت همگرایی الگوریتم PSO مقادیر میانگین مربع خطای (MSE) برای مراحل آزمون و آموزش محاسبه شده است. نتیجه این ارزیابی در جدول (۱) آورده شده است.

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

ردیف	ساختار شبکه	MSE برای مرحله آموزش (TECU)	MSE برای مرحله آزمون (TECU)	تعداد تکرار
۱	۴-۱۶-۱	۲/۰۱۳	۱/۹۷۲	۳۴۱
۲	۴-۱۷-۱	۱/۸۷۹	۱/۴۶۵	۳۴۱
۳	۴-۱۸-۱	۱/۷۶۴	۱/۲۴۷	۳۴۱
۴	۴-۱۹-۱	۱/۸۳۷	۱/۵۶۹	۳۴۱
۵	۴-۲۰-۱	۲/۱۷۶	۲/۰۹۷	۳۴۱

به کمک نتایج این جدول به‌وضوح می‌توان مشاهده نمود که در تعداد تکرار ثابت (مقدار تکرار ۳۴۱ براساس سعی و خطای بدست آمده است) و برای ساختارهای متفاوت از شبکه عصبی مصنوعی، ساختار ۴-۱۸-۱ نیز مقادیر خطای مراحل آموزش و آزمون برای تعداد دورهای متفاوت در ساختار ۴-۱۸-۱ آورده شده است.

¹ train

² validation

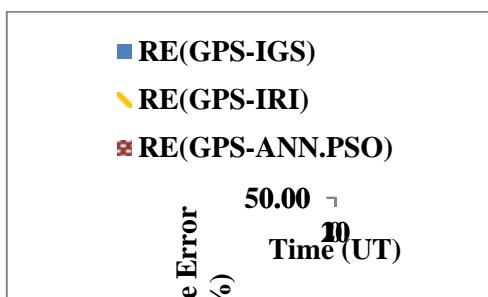
³ test

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

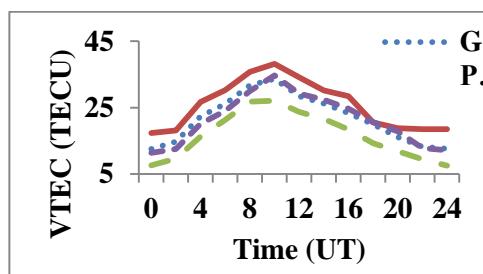
ردیف	ساختار شبکه	MSE برای مرحله آموزش (TECU)	MSE برای مرحله آزمون (TECU)	تعداد تکرار
۱	۴-۱۸-۱	۲/۲۸۹	۲/۰۷۴	۳۱۰
۲	۴-۱۸-۱	۲/۰۶۷	۱/۹۷۲	۳۲۰
۳	۴-۱۸-۱	۱/۷۶۴	۱/۲۴۷	۳۴۱
۴	۴-۱۸-۱	۱/۹۷۲	۱/۷۶۴	۳۵۰
۵	۴-۱۸-۱	۲/۰۳۹	۱/۸۳۷	۳۶۰

با استفاده از شبکه عصبی مصنوعی و الگوریتم آموزش VTEC مقادیر PSO برای ایستگاه آزمون تهران در طول ۲۴ ساعت پیش بینی شده است. این مقایسه برای ۵ روز مختلف (۲۲۲، ۲۲۳، ۲۲۴، ۲۲۵، ۲۲۶) از سال ۲۰۱۲ انجام گرفته است. همچنین مقادیر بدست آمده با مقادیر VTEC حاصل از اندازه گیریهای GPS به عنوان مرجع و نیز مدل مرجع بین المللی IRI-2012 (۲۰۱۲) مورد مقایسه قرار گرفته است. نتیجه این مقایسه در شکل (۴) نشان داده شده است. همچنین در این شکل مقادیر خطای نسبی محاسبه شده برای الگوریتم PSO، مدل مرجع جهانی ۲۰۱۲ و خروجیهای شبکه جهانی IGS با نتایج بدست آمده از GPS به عنوان مرجع آورده شده است.

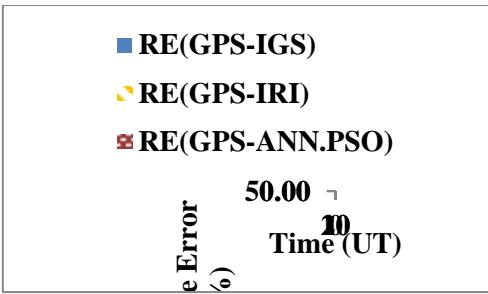
با استفاده از نتایج شکل (۴) و نیز مقادیر خطاهای نسبی محاسبه شده می‌توان به دقت الگوریتم آموزش PSO در شبکه عصبی مصنوعی پی برد. در روز ۲۲۲ کمینه خطای نسبی محاسبه شده برای شبکه عصبی با الگوریتم آموزش PSO با در نظر گرفتن مشاهده GPS به عنوان مرجع برابر ۲/۷۸ درصد و بیشینه آن ۱۵/۲۴ درصد بدست آمده است. برای روز ۲۲۳ کمینه خطای نسبی محاسبه شده برابر ۰/۶۲ درصد و بیشینه آن ۱۴/۳۵ درصد محاسبه شده است. این مقادیر برای روز ۲۲۴ بترتیب برابر با ۰/۸۷ و ۱۳/۱۶ درصد و بیشینه آن ۲۲۵ کمینه خطای نسبی ۰/۴۵ درصد و بیشینه آن ۱۶/۸۵ درصد شده است. همچنین برای روز ۲۲۶ این مقادیر بترتیب برابر با ۰/۵۲ و ۸/۸۵ درصد محاسبه شده است. همچنین با توجه به نتایج بدست آمده در شکل ۴ می‌توان بوضوح مشاهده کرد که اختلاف نسبتاً زیادی مابین خروجیهای شبکه جهانی IGS و مقادیر TEC تولید شده با GPS وجود دارد. این امر بدليل وجود تنها یک ایستگاه اندازه گیری IGS در منطقه ایران می‌باشد. شکل (۵) مقادیر خطای مطلق محاسبه شده برای ۵ روز مختلف در ایستگاه آزمون تهران را نشان می‌دهد. براساس نتایج حاصل از این شکل می‌توان بوضوح مشاهده نمود که خروجیهای IGS در منطقه ایران از خطای مطلق بالایی برخوردار می‌باشند که امر مجدداً دال بر عدم وجود ایستگاههای کافی از شبکه جهانی IGS در کشور ایران می‌باشد. با توجه به این شکل بیشترین مقدار خطای مطلق به دست آمده برای خروجیهای IGS در مقایسه با مشاهدات GPS مربوط به روز ۲۲۶ و برابر ۱/۰۱ TECU و کمترین مقدار آن مربوط به روز ۲۲۴ و برابر ۰/۴ TECU می‌باشد.



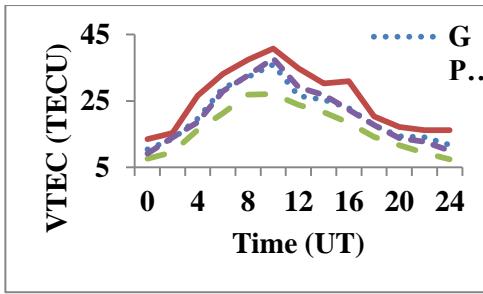
الف) مقایسه VTEC و خطای نسبی بدست آمده از شبکه عصبی، GPS، مدل مرجع جهانی ۲۰۱۲ و خروجی IGS برای روز ۲۲۲



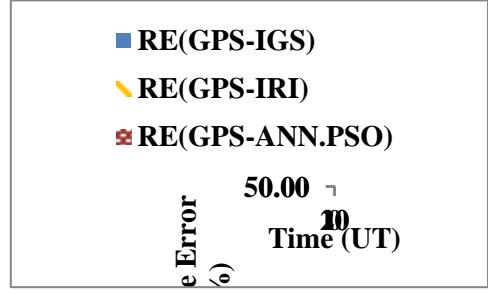
الف) مقایسه VTEC و خطای نسبی بدست آمده از شبکه عصبی، GPS، مدل مرجع جهانی ۲۰۱۲ و خروجی IGS برای روز ۲۲۲



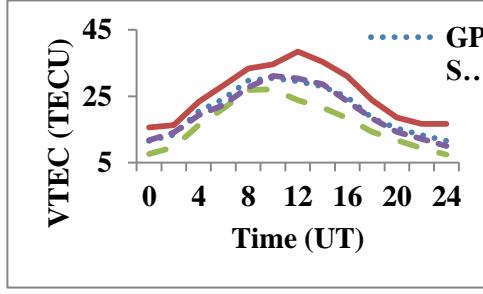
ب) مقایسه VTEC و خطای نسبی بدست آمده از شبکه عصبی، GPS، مدل مرجع جهانی ۲۰۱۲ و خروجی IGS برای روز ۲۲۳



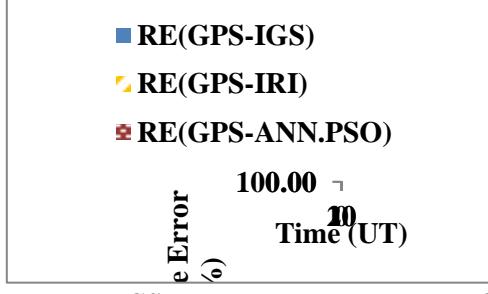
ب) مقایسه VTEC و خطای نسبی بدست آمده از شبکه عصبی، GPS، مدل مرجع جهانی ۲۰۱۲ و خروجی IGS برای روز ۲۲۳



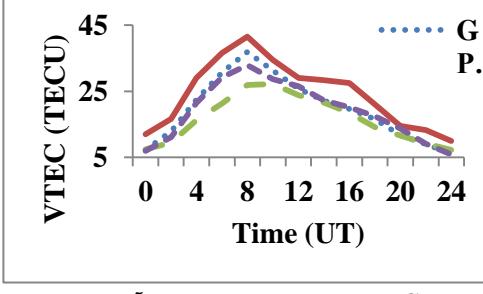
ج) مقایسه VTEC و خطای نسبی بدست آمده از شبکه عصبی، GPS، مدل مرجع جهانی ۲۰۱۲ و خروجی IGS برای روز ۲۲۴



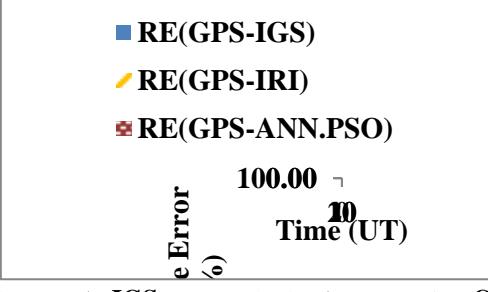
ج) مقایسه VTEC و خطای نسبی بدست آمده از شبکه عصبی، GPS، مدل مرجع جهانی ۲۰۱۲ و خروجی IGS برای روز ۲۲۴



د) مقایسه VTEC و خطای نسبی بدست آمده از شبکه عصبی، GPS، مدل مرجع جهانی ۲۰۱۲ و خروجی IGS برای روز ۲۲۵

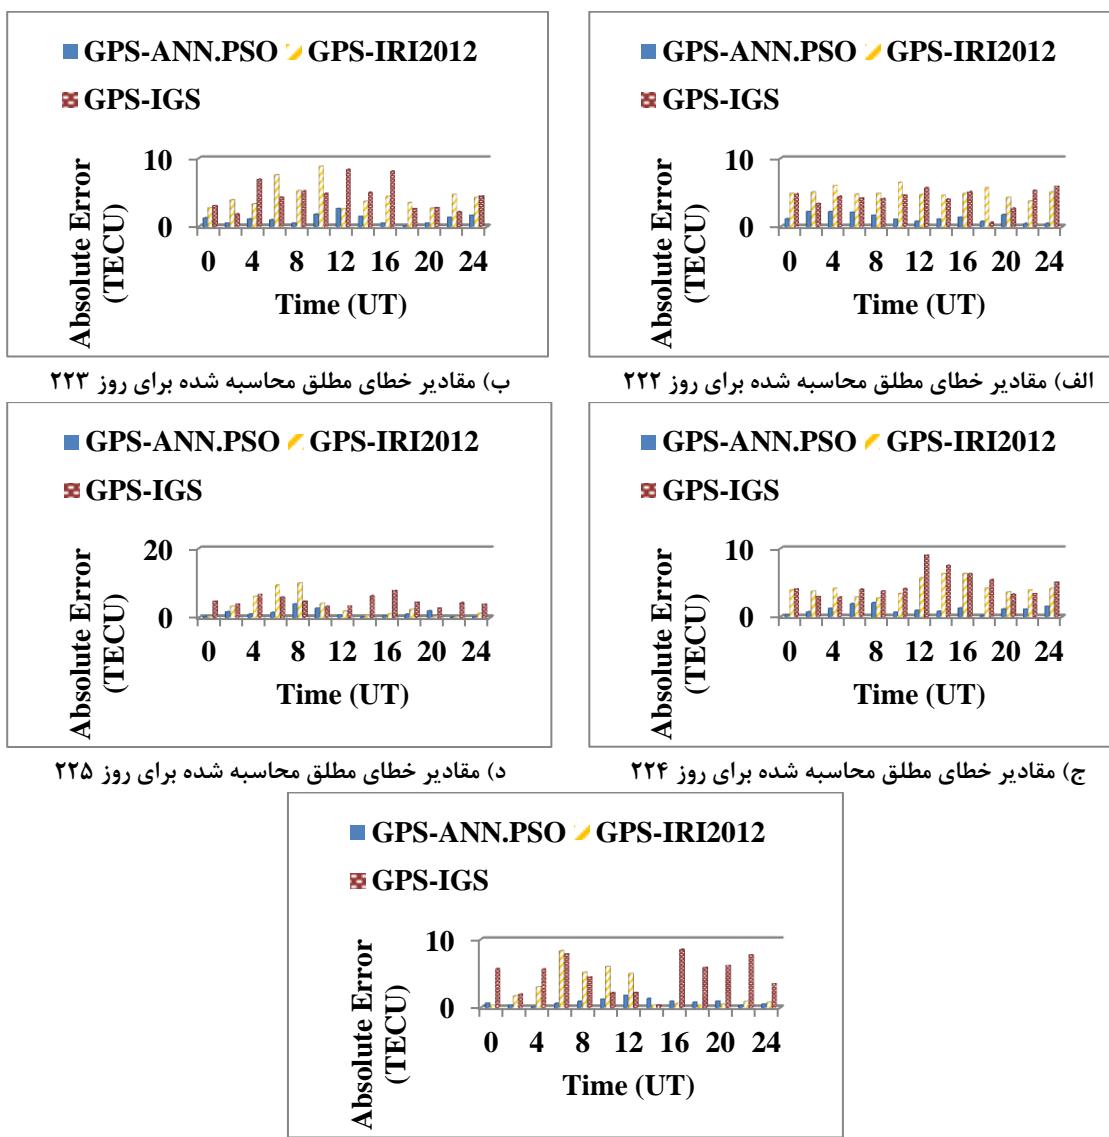


د) مقایسه VTEC و خطای نسبی بدست آمده از شبکه عصبی، GPS، مدل مرجع جهانی ۲۰۱۲ و خروجی IGS برای روز ۲۲۵



د) مقایسه VTEC و خطای نسبی بدست آمده از شبکه عصبی، GPS، مدل مرجع جهانی ۲۰۱۲ و خروجی IGS برای روز ۲۲۶

شکل ۴: مقایسه مقادیر VTEC و خطای نسبی بدست آمده از شبکه عصبی، GPS، مدل مرجع جهانی ۲۰۱۲ و خروجی IGS برای روز ۲۲۶ (۲۲۶، ۲۲۵، ۲۲۴، ۲۲۳، ۲۲۲) از ماه آگوست سال ۲۰۱۲ برای ایستگاه آزمون تهران



ب) مقادیر خطای مطلق محاسبه شده برای روز ۲۲۳

الف) مقادیر خطای مطلق محاسبه شده برای روز ۲۲۲

د) مقادیر خطای مطلق محاسبه شده برای روز ۲۲۵

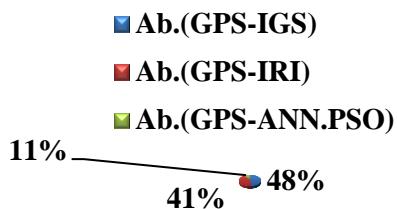
ج) مقادیر خطای مطلق محاسبه شده برای روز ۲۲۴

۵) مقادیر خطای مطلق محاسبه شده برای روز ۲۲۶

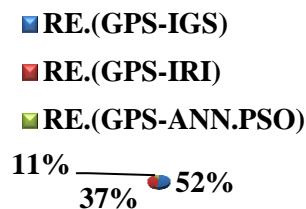
شکل ۵. مقایسه مقادیر خطای مطلق بدست آمده برای شبکه عصبی مصنوعی با الگوریتم آموزش PSO و IGS. خروجیهای GPS به عنوان مرجع در ۵ روز از سال ۲۰۱۲ برای ایستگاه آزمون تهران مدل مرجع جهانی با اندازه گیریهای آزمون تهران

میانگین مقادیر خطاهای نسبی و مطلق برای ۵ روز از سال ۲۰۱۲ در ایستگاه آزمون تهران محاسبه شده و نتیجه این ارزیابی در شکل (۶) نشان داده شده است. با توجه به این شکل می توان به این نکته اشاره کرد که مدل شبکه عصبی مصنوعی همراه با الگوریتم آموزش PSO در برآورد تغییرات زمانی مقدار محتوای الکترون کلی لایه یون سپهر از دقت و صحت بالاتری نسبت به مدلها مرجع بین المللی و خروجیهای شبکه جهانی IGS در منطقه ایران برخوردار است.

Average Absolute Error in 5 Days at 2012



Average Ralative Error in 5 Days at 2012



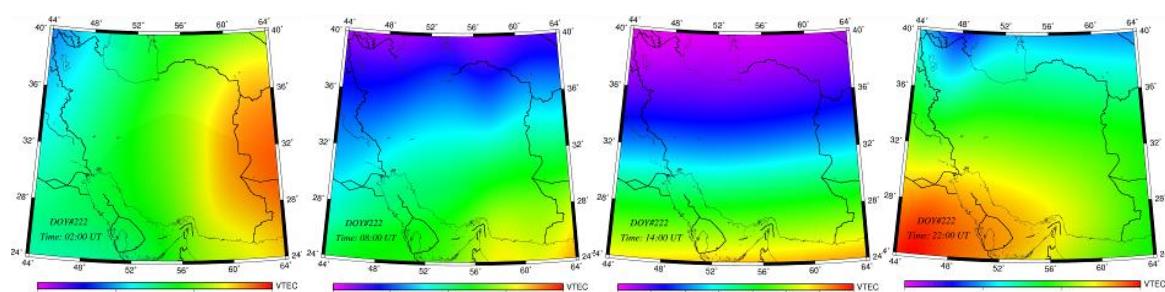
ب

الف

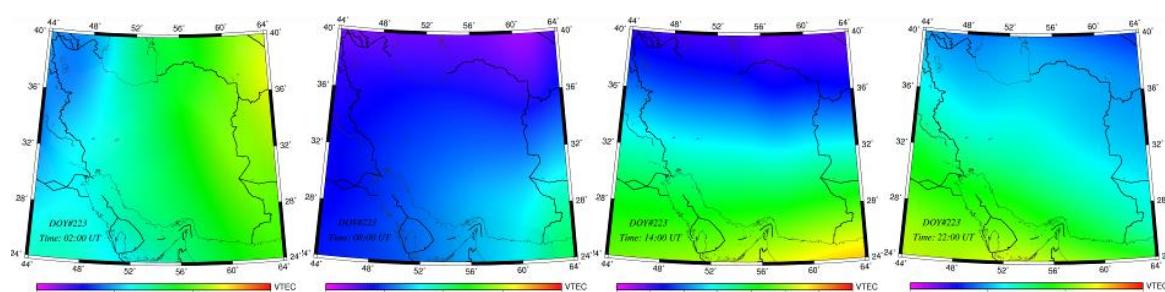
شکل ۶: مقادیر میانگین خطاهای نسبی و مطلق برای ۵ روز از ماه آگوست سال ۲۰۱۲ در ایستگاه آزمون تهران پس از ارزیابی دقت و صحت مدل شبکه عصبی مصنوعی در برآورد مقدار VTEC در ایستگاه‌های آزمون، می‌توان مقدار آن را برای هر نقطه دلخواه دیگر و برای هر زمان محاسبه نمود. شکل (۷) تغییرات مقدار VTEC را به صورت مسطحه‌ای برای منطقه ایران نشان می‌دهد. این محاسبه برای چهار زمان ۲، ۸، ۱۴ و ۲۲ بوقت جهانی نشان داده شده است.

با توجه به نتایج به دست آمده از شکل (۷) می‌توان به این نکته پی‌برد که یون‌سپهر دارای تغییرات زمانی و مکانی می‌باشد و مدل شبکه عصبی دارای قابلیت نشان دادن این تغییرات است.

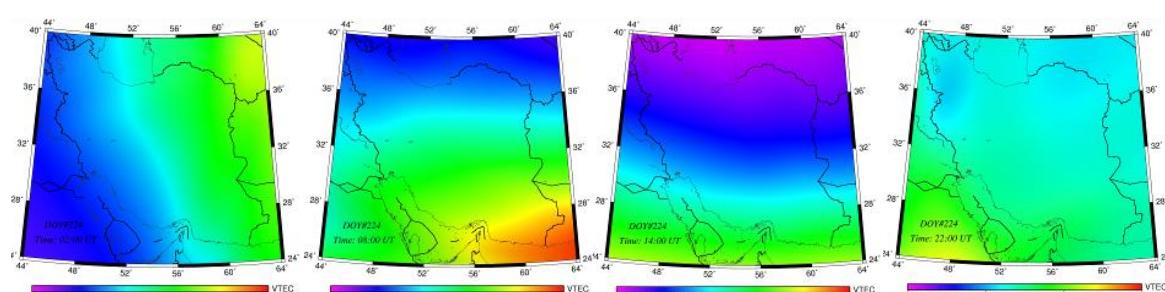
UT=02:00 UT=08:00 UT=14:00 UT=22:00



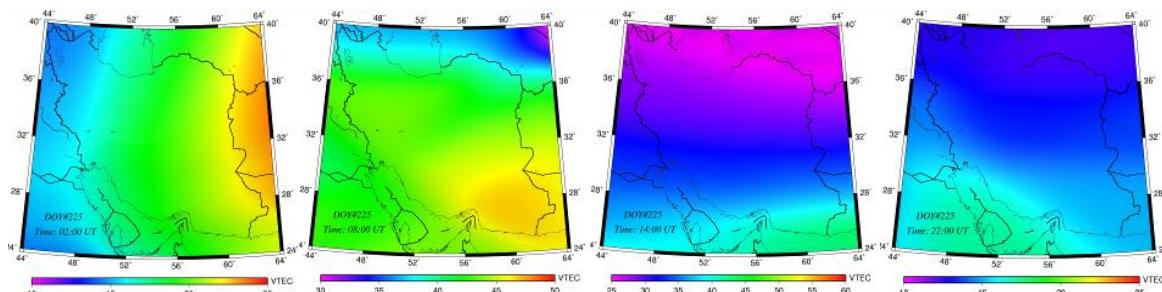
الف) تغییرات مسطحه‌ای VTEC بدست آمده از مدل شبکه‌های عصبی مصنوعی در چهار زمان ۲، ۸، ۱۴ و ۲۲ برای روز ۲۲۲



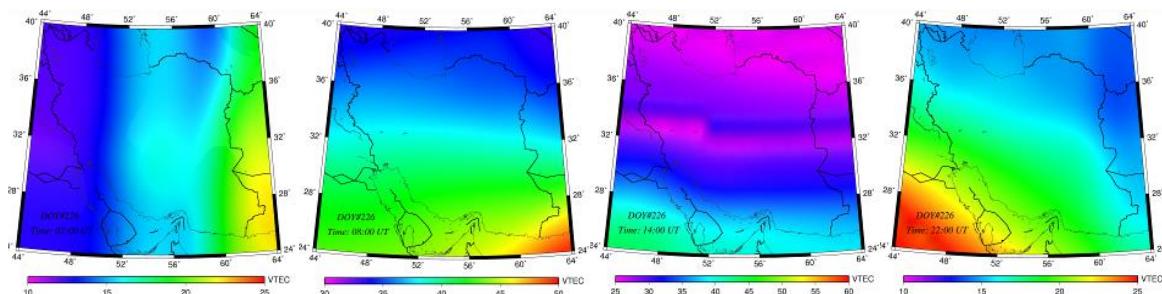
ب) تغییرات مسطحه‌ای VTEC بدست آمده از مدل شبکه‌های عصبی مصنوعی در چهار زمان ۲، ۸، ۱۴ و ۲۲ برای روز ۲۲۳



ج) تغییرات مسطحه‌ای VTEC بدست آمده از مدل شبکه‌های عصبی مصنوعی در چهار زمان ۲، ۸، ۱۴ و ۲۲ برای روز ۲۲۴



د) تغییرات مسطحاتی VTEC بدست آمده از مدل شبکه های عصبی مصنوعی در چهار زمان ۲، ۸، ۱۴ و ۲۲ برای روز ۲۲۵



r) تغییرات مسطحاتی VTEC بدست آمده از مدل شبکه های عصبی مصنوعی در چهار زمان ۲، ۸، ۱۴ و ۲۲ برای روز ۲۲۶

شکل ۷: تغییرات مسطحاتی مقدار VTEC بدست آمده از مدل شبکه های عصبی مصنوعی با الگوریتم آموزش PSO در چهار زمان ۲، ۸، ۱۴ و ۲۲ بوقت جهانی برای ۴ روز از ماه آگوست سال ۲۰۱۲

۵- نتیجه گیری

شبکه عصبی مصنوعی یک سامانه پردازشی داده ها است که از مغز انسان ایده گرفته و پردازش داده ها را به عهده پردازنده های کوچک و بسیار زیادی سپرده که به صورت شبکه ای به هم پیوسته و موازی با یکدیگر رفتار می کنند تا یک مسئله را حل نمایند. بدلیل ماهیت خاص این نوع از شبکه ها، از آنها جهت مدلسازی پدیده هایی با رفتار غیرخطی استفاده می شود. بهمین جهت در این مقاله از یک شبکه عصبی مصنوعی سه لایه با ۱۸ نورون در لایه مخفی جهت مدلسازی سری زمانی تغییرات محتوای الکترون کلی لایه یون سپهر در ایران استفاده شد. داده های ۳۷ ایستگاه از شبکه مبنای ژئودینامیک ایران جهت محاسبه مشاهدات ورودی شبکه عصبی بکار گرفته شدند. این داده ها مربوط به ۵ روز از سال ۲۰۱۲ ماه آگوست بودند. عموماً جهت آموزش شبکه های عصبی از الگوریتم پس انتشار خطاب استفاده می شود. منتها بدلیل معايب موجود در این الگوریتم از جمله سرعت همگرايی پايان و نيز گير افتادن در مينيم های محلی از الگوریتم آموزش بهينه سازی انبوه ذرات (PSO) استفاده شد. آناليز های انجام گرفته در اين مقاله نشان داد که با بهره گيري از الگوریتم آموزش PSO نه تنها زمان همگرا شدن به جواب بهينه کاهش می يابد بلکه دقت و صحت نتایج نيز افزایش پيدا می کند. نتایج حاصل از شبکه عصبی مصنوعی با نتایج حاصل از مدل مرجع جهانی ۲۰۱۲ و نيز خروجيهای شبکه جهانی IGS مورد مقاييسه قرار گرفت. در تمامي مقاييسه های انجام گرفته مشاهدات VTEC بدست آمده از GPS به عنوان مشاهده مرتع مورد استفاده قرار گرفت. در اكثرا مقاييسه های صورت گرفته خروجي به دست آمده از شبکه عصبی از مقدار خطابي كمتری نسبت به مدل مرجع جهانی و خروجي IGS برخوردار بوده است. ميانگين خطابي نسبی بدست آمده برای شبکه عصبی مصنوعی با الگوریتم آموزش PSO در ۵ روز متوالي از سال ۲۰۱۲ برابر ۵/۷۸ درصد بوده است. اين مقدار برای مدل مرجع جهانی ۲۰۱۲ برابر ۱۹/۳۲ درصد و برای خروجي های شبکه جهانی IGS برابر ۲۷/۵۰ درصد بدست آمده است. مقاييسه صورت گرفته در مورد خطابي مطلق نيز حاكي از برتری روش شبکه عصبی مصنوعی در برآورد مقدار VTEC بوده است. نتایج نشان دهنده اين موضوع است که شبکه عصبی تا ۹۴ درصد قابلیت مدلسازی و پيش بینی تغیيرات زمانی محتوای الکترون کلی یون سپهر را دارد.

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 موقع شبکه عصبی نتایج نامطمئنی به دست دهد که این امر می‌تواند از معايب مدل‌سازی با شبکه‌های عصبی باشد.

مراجع

- [1] احمدی، م.، و موسوی، س.، م.، ۱۳۹۱، حل دقیق معادلات موقعیت در گیرنده‌های GPS با استفاده از شبکه‌های عصبی: مجله علمی و پژوهشی رایانش نرم و فناوری اطلاعات، ۱ (۲۶-۳۹).
- [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] Schaeer, S., 1999, Mapping and predicting the Earth's Ionosphere Using the Global Positioning System, PhD thesis, Astronomical Institute, University of Berne, Berne Switzerland.
- [4] Meggs, R., 2005, Mapping of ionospheric total electron content using global navigation satellite systems, Ph.D. thesis, University of Bath, Bath, UK.
- [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] Moon, Y., 2004, Evaluation of 2-dimensional ionosphere models for national and regional GPS networks in Canada, Master's thesis, Univ. of Calgary, Calgary, Alberta, Canada.
- [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] Mars, P., J.R. Chen, R. Nambiar, 1996, Learning Algorithms: Theory and Applications in Signal Processing, Control and Communications, CRC Press, Boca Raton, Florida.
- [11] Haykin. S, 1994, Neural Networks, a comprehensive Foundation, Macmillan College Publishing Company, New York.
- [12] Chen, Y., Yang, B., & Dong, J., 2006, Time-series prediction using a local linear wavelet neural wavelet. Neuro computing, 69, 449–465.
- [13] Ciraolo, 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] Beale, M. H., Hagan, M. T., and Demuth, H. B., 2010, Neural Network Toolbox 7 User's Guide: The MathWorks Inc., Natick, MA, 951 pp.