

کاربرد شبکه عصبی موجک با الگوریتم آموزش بهینه‌سازی انبوه ذرات در مدل‌سازی تغییرات زمانی محتوای الکترون کلی یون‌سپهر

میررضا غفاری رزین^۱

بهزاد وثوقی^۲

تاریخ دریافت مقاله: ۹۷/۰۹/۱۵

تاریخ پذیرش مقاله: ۹۸/۰۹/۱۰

چکیده

در این مقاله از ترکیب شبکه‌های عصبی موجک (WNNs) به همراه الگوریتم آموزش بهینه‌سازی انبوه ذرات (PSO) جهت مدل‌سازی تغییرات زمانی محتوای الکترون کلی (TEC) یون‌سپهر در منطقه ایران استفاده شده است. چهار ترکیب از تعداد مشاهدات ورودی مختلف جهت تست روش، مورد ارزیابی قرار گرفته است. تعداد مشاهدات ورودی انتخاب شده جهت آموزش شبکه عصبی موجک با الگوریتم PSO به ترتیب ۲۵، ۲۰، ۱۵ و ۱۰ ایستگاه از شبکه مبنای ژئودینامیک ایران (IPGN) می‌باشند. در هر چهار حالت تعداد پنج ایستگاه با توزیع مناسب در گستره جغرافیایی ایران به عنوان ایستگاه‌های آزمون در نظر گرفته شده‌اند. شاخص‌های آماری خطای نسبی، خطای مطلق و ضریب همبستگی جهت ارزیابی مدل شبکه عصبی موجک مورد استفاده قرار گرفته است. نتایج حاصل از مدل پیشنهادی این مقاله با TEC حاصل از مشاهدات GPS به عنوان مرجع اصلی و مدل جهانی یون‌سپهر ۲۰۱۶ (IRI-۲۰۱۶) مقایسه شده است. میانگین خطای نسبی محاسبه شده در ۵ ایستگاه آزمون برای شبکه عصبی موجک با ۲۵ ایستگاه آموزش برابر با ۱۳/۴۳٪، با ۲۰ ایستگاه آموزش برابر با ۱۳/۷۳٪، با ۱۵ ایستگاه آموزش برابر با ۱۵/۰۵٪ و با ۱۰ ایستگاه آموزش برابر با ۲۸/۱۷٪ تعیین شده است. همچنین میانگین مقادیر ضریب همبستگی محاسبه شده در پنج ایستگاه آزمون برای شبکه عصبی موجک با ۲۵ ایستگاه آموزش برابر با ۰/۹۷۶۸، با ۲۰ ایستگاه آموزش برابر با ۰/۹۵۴۵، با ۱۵ ایستگاه آموزش برابر با ۰/۹۳۷۶ و با ۱۰ ایستگاه آموزش برابر با ۰/۷۵۶۹ محاسبه شده است. نتایج این مقاله نشان می‌دهد که مدل شبکه عصبی موجک با الگوریتم آموزش PSO یک مدل قابل اعتماد جهت پیش‌بینی تغییرات زمانی یون‌سپهر در منطقه ایران است. این مدل می‌تواند یک جایگزین بسیار مطمئن برای مدل مرجع جهانی یون‌سپهر در ایران باشد.

واژه‌های کلیدی: TEC، شبکه عصبی موجک، الگوریتم PSO، GPS.

۱- استادیار، گروه مهندسی نقشه‌برداری، دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک (نویسنده مسئول) mr.ghafari@arakut.ac.ir

۲- دانشیار، گروه مهندسی ژئودزی، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی vosoghi@kntu.ac.ir

۱- مقدمه

یون‌سپهری و نیز تغییرات زمانی-مکانی چگالی الکترونی در این لایه از جو را مورد مطالعه قرار داد، محتوای الکترون کلی می‌باشد. در حقیقت TEC تعداد کل الکترون‌های آزاد در مسیر مابین ماهواره تا گیرنده در ستونی به مساحت ضلع یک متر مربع است. واحد اندازه‌گیری TEC، TECU بوده و یک TECU معادل 10^{16} (ele/m²) می‌باشد (سیبر، ۲۰۰۳). این کمیت را می‌توان از روی اندازه‌گیری‌های فاز و کد بدست آمده از سیستم تعیین موقعیت جهانی بدست آورد.

به دلیل توزیع مکانی نامناسب گیرنده‌های GPS و نیز تعداد محدود آنها و همچنین وجود ناپوستگی 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 برون‌یابی شوند (غفاری رزین و وثوقی، ۲۰۱۶). در نتیجه مقادیر TEC محاسبه 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 برون‌یابی TEC در مناطقی که مشاهده کافی و یا مناسب موجود نیست، صورت گرفته است. بطور مثال می‌توان به روش‌های کریژینگ، چندجمله‌ای، هارمونیک‌های کروی، درون‌یابی به کمک توابع اسپیلاین و مدل شبکه‌های عصبی مصنوعی اشاره نمود (اوروس، ۲۰۰۵؛ ولگوسز و همکاران، ۲۰۰۳؛ مون، ۲۰۰۴؛ سین و همکاران، ۲۰۰۸؛ یلماز و همکاران، ۲۰۰۹؛ غفاری رزین و وثوقی، ۲۰۱۶؛ میروکا و همکاران، ۲۰۱۱). از این روش‌ها به کرات جهت تهیه و مدل‌سازی منطقه‌ای و جهانی مقدار TEC استفاده شده است.

در دو دهه اخیر تلاش‌های اندکی در راستای استفاده از روش شبکه‌های عصبی مصنوعی (ANN) جهت مدل‌سازی TEC صورت گرفته است (کاندر، ۱۹۹۸). سابقه استفاده از قابلیت و کارایی شبکه‌های عصبی مصنوعی در مباحث

توسعه مدل‌های قابل اعتماد برای برآورد و پیش‌بینی تغییرات محتوای الکترون کلی (TEC) در لایه یون‌سپهر هنوز به عنوان یک چالش واقعی برای ژئودزین‌ها و ژئوفیزیک‌ها مطرح است. این امر تا حدی به دلیل رفتار غیرخطی پارامترهای فیزیکی و ژئوفیزیکی مؤثر در تغییرات TEC و همچنین وجود مشکل در اندازه‌گیری دقیق برخی از این پارامترها می‌باشد (عامریان و همکاران، ۲۰۱۰). علاوه بر این، تغییرات این پارامترها در حوزه زمان نیز پیچیدگی مسئله مدل‌سازی یون‌سپهر را بیشتر می‌کند. همچنین تابش تشعشعات خورشیدی در رفتار این لایه از جو اثر گذار است. با توجه به ساختار چندلایه یون‌سپهر، امواج الکترومغناطیسی گذرنده از این لایه‌ها تحت تأثیر خاصیت پاشندگی یون‌سپهر قرار می‌گیرند. به همین جهت مدل‌سازی این لایه از جو دارای اهمیت فوق‌العاده‌ای است. الکترون‌های موجود در یون‌سپهر تأثیر بسزایی بر انتشار امواج الکترومغناطیسی عبوری از آن دارند. این تأثیر، حوزه‌های تحقیقاتی وسیع و گسترده‌ای را در مورد این لایه از جو همانند سیستم‌های مشاهداتی زمین - فضا، سیستم‌های ارتباطی، هواشناسی فضایی و ... ایجاد کرده است (غفاری رزین، ۲۰۱۵؛ غفاری رزین و وثوقی، ۲۰۱۶). سیگنال‌های سیستم تعیین موقعیت جهانی (GPS) نیز متأثر از خاصیت الکتریکی یون‌سپهر می‌باشند. بدلیل ماهیت خاص و نیز ویژگی‌های فیزیکی و ژئوفیزیکی، کمیت TEC دارای تغییرات زمانی-مکانی است. این تغییرات می‌تواند ناشی از تغییرات روزانه، تغییرات فصلی، آنومالی‌های مختلف موجود و یا دوره فعالیت‌های خورشیدی باشد (غفاری رزین و وثوقی، ۲۰۱۶). 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 تأثیر آنها در سایر سیستم‌ها، می‌بایست تغییرات زمانی-مکانی آن بصورت دقیق مورد مطالعه قرار گیرد. کمیتی که با استفاده از آن می‌توان چگونگی فعالیت‌های

مورد استفاده جهت آموزش شبکه عصبی موجک است. نتایج حاصل از روش پیشنهادی این مقاله با مشاهدات GPS و همچنین با خروجی‌های مدل مرجع بین‌المللی ۲۰۱۶ (IRI-۲۰۱۶) مورد مقایسه قرار گرفته است.

۲- شبکه‌های عصبی موجک

شبکه‌های عصبی مصنوعی (ANNs) به عنوان یک تقریب کننده جامع شناخته می‌شوند. این شبکه‌ها دارای ویژگی‌های خود یادگیری و تطبیق با شرایط مسئله هستند (هایکین، ۱۹۹۴). با ترکیب ویژگی‌های محلی‌سازی موجک‌ها و همچنین شبکه‌های عصبی استاندارد، شبکه‌های عصبی موجک (WNNs) به عنوان یک روش ریاضی جدید جهت مدل‌سازی و پیش‌بینی رفتار پدیده‌های مختلف بوجود آمده است. کاربرد موجک در شبکه عصبی موجکی بعنوان تابع فعالیت، اخیراً بعنوان یک روش جایگزین در شبکه‌های عصبی به کار برده می‌شود. در شبکه‌های عصبی موجکی موقعیت و مقیاس موجک‌ها علاوه بر وزن‌ها بهینه‌سازی می‌شوند. در اصل شبکه عصبی موجکی به شبکه عصبی با استفاده از موجک اشاره دارد. در این نوع از شبکه‌ها تعیین ساختار شبکه و همچنین نوع الگوریتم مورد استفاده جهت آموزش از اهمیت ویژه‌ای برخوردار است (چن، ۲۰۰۰). معمولاً در شبکه‌های عصبی موجک پارامتر خروجی از طریق رابطه (۱) محاسبه می‌شود:

(۱)

$$g_{\lambda}(\mathbf{x}; \mathbf{w}) = \hat{y}(\mathbf{x}) = \omega_{\lambda+1} + \sum_{j=1}^{\lambda} \omega_j \cdot \Psi_j(\mathbf{x}) + \sum_{i=1}^m \omega_i \cdot x$$

در این رابطه \mathbf{x} نشان‌دهنده بردار مشاهدات ورودی، $\Psi_j(\mathbf{x})$ موجک چند متغیره که می‌تواند با استفاده از ضرب تسسوری m تابع پایه موجک واحد محاسبه گردد، λ بیانگر تعداد نورون‌های لایه پنهان و ω وزن مربوط به شبکه می‌باشند. موجک چند متغیره را می‌توان با استفاده از رابطه (۲) محاسبه نمود:

$$\Psi_j(\mathbf{x}) = \prod_{i=1}^m \psi(z_j) \quad (۲)$$

ژئودزی و ژئودینامیکی به چند سال اخیر برمی‌گردد. لئوناردو و ساتوس در سال ۲۰۰۷ یک شبکه عصبی سه لایه را جهت تعیین مقدار چگالی الکترونی گسترش دادند (لئوناردو و ساتوس، ۲۰۰۷). تولونای و همکاران در سال ۲۰۰۷ با اندک تغییراتی در شبکه عصبی گسترش داده شده توسط لئوناردو و همکاران (اضافه نمودن مقادیر مؤثر در تغییرات چگالی الکترونی بصورت روزانه) مقدار TEC را برای یک شبکه محلی در زمان‌های مختلف تخمین زدند (تولونای و همکاران، ۲۰۰۶). رودریگو و لئوناردو در سال ۲۰۰۷ از یک روش درون‌یابی بر مبنای شبکه‌های عصبی مصنوعی جهت برآورد چگالی الکترونی یون‌سپهر استفاده نمودند (رودریگو و لئوناردو، ۲۰۰۷). هابارولما و همکاران در سال‌های ۲۰۰۷ و ۲۰۰۹ ایده استفاده از یک ایستگاه مرکزی جهت آموزش شبکه عصبی و تخمین مقادیر TEC در منطقه آفریقای جنوبی را ارائه نمودند (هابارولما و همکاران، ۲۰۰۷ و ۲۰۰۹). یلماز و همکاران در سال ۲۰۰۹ از شبکه‌های عصبی با توابع پایه شعاعی جهت مدل‌سازی و تخمین مقدار TEC در کشور ترکیه استفاده نمودند (یلماز و همکاران، ۲۰۰۹). غفاری رزین و همکاران از یک شبکه عصبی پرسپترون سه لایه جهت درون‌یابی مقدار TEC بصورت مسطحاتی استفاده کردند (غفاری رزین و همکاران، ۲۰۱۵).

هدف کلی این مقاله مدل‌سازی تغییرات زمانی محتوای الکترون کلی لایه یون‌سپهر در ایران با استفاده از شبکه‌های عصبی موجک (WNNs) 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 بهینه‌سازی انبوه ذرات (PSO) استفاده می‌شود. چهار سناریو مختلف از داده‌های ورودی جهت ارزیابی مدل مورد نظر بررسی شده است. در این سناریوها، تعداد مشاهدات ورودی مدل کاهش پیدا کرده تا اینکه بتوان دقت، صحت و سرعت مدل پیشنهادی را مورد ارزیابی قرار داد. در حقیقت نوآوری اصلی این مقاله در نوع ترکیب دو روش شبکه عصبی موجک با الگوریتم PSO و همچنین نوع مشاهدات

شود. برخلاف الگوریتم پس انتشار، PSO یک الگوریتم جستجوگر سراسری است که می‌تواند وزن‌های اولیه را بهینه نموده و همچنین ساختار مناسب برای شبکه را معرفی نماید. الگوریتم PSO بدلیل عدم استفاده از بردار شیب در کمینه‌های محلی گیر نمی‌افتد. معادلات مورد استفاده در این الگوریتم به صورت روابط (۷) و (۸) در نظر گرفته می‌شوند:

(۷)

$$v_i^{t+1} = w \times v_i^t + c_1 \times rand \times (pbest_i - x_i^t) + c_2 \times rand \times (gbest - x_i^t)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (۸)$$

در روابط بالا w نشان‌دهنده وزن اولیه، v_i^t سرعت ذره i در تکرار t ، c_1 و c_2 بیانگر ضرایب شتاب ذره، x_i^t موقعیت کنونی ذره i در تکرار t و $gbest$ نشان‌دهنده بهترین موقعیت ذره می‌باشند. در هر تکرار، سرعت ذرات توسط رابطه (۷) محاسبه می‌شوند. پس از آن، مکان ذرات توسط معادله (۸) بدست می‌آید.

۴- مشاهدات STEC

گیرنده‌های دو فرکانسه GPS مشاهدات کد و فاز موج حامل را در باند L و با فرکانس‌های L_1 و L_2 در اختیار می‌گذارند. دقت مشاهدات فاز موج حامل نسبت به مشاهدات کد بالاتر می‌باشد. با وجود این مقدار TEC که از مشاهدات فاز موج حامل محاسبه می‌شود به مقادیر ابهام فاز موجود در آن وابسته است. همچنین مقادیر TEC بدست آمده از مشاهدات فاز موج حامل دارای دقت بالاتری نسبت به مقادیر بدست آمده از مشاهدات کد است. به همین دلیل استفاده از الگوریتمی که بتواند مقادیر ابهام فاز را از مشاهدات TEC بدست آمده از اندازه‌گیری‌های فاز موج حامل حذف کند امری اجتناب‌ناپذیر است. در این مقاله از یک الگوریتم نرم‌سازی جهت تعیین مشاهدات STEC استفاده شده است (کیرالوو و همکاران، ۲۰۰۷). مقادیر STEC مشاهداتی بصورت رابطه (۹) می‌باشد:

(۹)

$$STEC = (\bar{P}_4 - br - bs - \langle \epsilon_p \rangle_{arc} + \epsilon_L) \frac{f_1^2 f_2^2}{40.3(f_2^2 - f_1^2)}$$

در رابطه (۲) z موجک مادر بوده و می‌تواند از رابطه

(۳) محاسبه شود:

$$z_{ij} = \frac{x_i - \omega_{(\xi)ij}}{\omega_{(\xi)ij}} \quad (۳)$$

در رابطه بالا $i = 1, \dots, m$, $j = 1, \dots, \lambda + 1$

پارامتر انتقال و $\omega_{(\xi)ij}$ پارامتر مقیاس می‌باشند. انتخاب موجک مادر بستگی به کاربرد آن دارد. در این مقاله از موجک Mexican hat به عنوان موجک مادر استفاده شده است. دلیل این انتخاب بعلت کارایی آن در تحقیقات انجام شده قبلی است (ژانگ و بنونیست، ۱۹۹۲). شکل کلی این موجک بصورت رابطه (۴) می‌باشد:

$$\psi(z_{ij}) = (1 - z_{ij}^2) e^{-\frac{1}{2}z_{ij}^2} \quad (۴)$$

جهت بهینه‌سازی و انتخاب پارامترهای انتقال و مقیاس راه‌حل‌های متفاوتی وجود دارد. در این مقاله از دو رابطه (۵) و (۶) جهت انتخاب این پارامترها استفاده شده است (ژانگ و بنونیست، ۱۹۹۲):

$$\omega_{(\xi)ij} = 0.5(N_i + M_i) \quad (۵)$$

$$\omega_{(\xi)ij} = 0.2(M_i - N_i) \quad (۶)$$

در روابط بالا N_i و M_i نشان‌دهنده کمترین و بیشترین مقدار ورودی هستند.

۳- الگوریتم بهینه‌سازی انبوه ذرات (PSO)

متداول‌ترین الگوریتم آموزش در شبکه‌های عصبی، الگوریتم آموزش پس انتشار خطا (BP) است که مبتنی بر حرکت بروی بردار شیب می‌باشد. این الگوریتم براحتی در کمینه‌های محلی گیر می‌افتد. به همین جهت الگوریتم پس انتشار خطا جهت یافتن راه حل بهینه و جواب سراسری مسئله ناکارآمد است. همچنین، سرعت همگرایی به راه حل بهینه در این الگوریتم بسیار پایین می‌باشد (مارس و همکاران، ۱۹۹۷). از دیگر مسائل کلیدی در این الگوریتم می‌توان وابستگی به وزن‌های اولیه و نیز نرخ آموزش شبکه را عنوان نمود. این نقاط ضعف می‌تواند با استفاده از الگوریتم‌های تکاملی همانند الگوریتم بهینه‌سازی انبوه ذرات برطرف

مورد بررسی قرار گرفته است. در این ترکیبات تعداد مشاهدات ورودی بتدریج کاهش پیدا کرده و مقادیر خطا در ایستگاه‌های آزمون محاسبه می‌شوند. با مقایسه صورت گرفته می‌توان ارزیابی نمود که شبکه عصبی موجک با الگوریتم آموزش PSO تا چه حد می‌تواند در مدل‌سازی و پیش‌بینی رفتار یون‌سپهر مدل موفق باشد. تعداد مشاهدات ورودی انتخاب شده جهت آموزش شبکه عصبی موجک با الگوریتم PSO به ترتیب ۲۵، ۲۰، ۱۵ و ۱۰ ایستگاه از شبکه مبنای ژئودینامیک ایران (IPGN) می‌باشند. با استفاده از الگوریتم نرم‌سازی ارائه شده در بخش ۴ مشاهدات STEC از اندازه‌گیری‌های ایستگاه‌های GPS محاسبه شده و مقادیر VTEC تعیین می‌شوند. جهت ارزیابی روش پیشنهادی سه شاخص ضریب همبستگی، خطای نسبی و خطای مطلق مورد استفاده قرار می‌گیرند. سپس در هر ترکیب تعداد مشاهدات ورودی کاهش پیدا کرده و مدل مجدداً مورد ارزیابی قرار می‌گیرد. جدول (۱) مشخصات ترکیبات متفاوت مورد ارزیابی در این مقاله را نشان می‌دهد.

جدول ۱: مشخصات مشاهدات مورد استفاده در ترکیبات متفاوت مورد ارزیابی

تعداد مشاهدات در پایگاه داده	تعداد ایستگاه‌های آزمون	تعداد ایستگاه‌های آموزش	ترکیبات مشاهدات
۳۰۰	۵	۲۵	۱
۲۴۰	۵	۲۰	۲
۱۸۰	۵	۱۵	۳
۱۲۰	۵	۱۰	۴

خورشید و فعالیت‌های وابسته به آن نقش اصلی و اساسی را در دینامیک فضا ایفا می‌کنند. به همین جهت فعالیت بالای خورشیدی باعث بوجود آمدن تغییرات عمده و اساسی در چگالی الکترونی یون‌سپهر خواهد شد.

شاخص فعالیت‌های خورشیدی برای روز ۲۲۴ از سایت (<http://www.spaceweatherlive.com>) دانلود شده که نگاره (۱) نشان‌دهنده چگونگی تغییرات این شاخص می‌باشد. در نمودار فوق، مقادیر کمتر از ۴ ($Kp < 4$) با رنگ سبز، مقادیر

در این رابطه \tilde{P}_4 مشاهده یون‌سپهری نرم شده با استفاده از مشاهدات یون‌سپهری فاز موج حامل، br و bs به ترتیب مقادیر بایاس داخل فرکانسی برای گیرنده و ماهواره می‌باشند. در رابطه (۹) STEC مقدار محتوای الکترون کلی در راستای مایل است. جهت بدست آوردن مقدار محتوای الکترون یون‌سپهر در راستای زنیت می‌توان از تابع تصویر بصورت رابطه (۱۰) استفاده نمود:

$$VTEC = M \times STEC \quad (10)$$

که خواهیم داشت:

$$M = \sin(elev) \quad (11)$$

در رابطه (۱۱) $elev$ زاویه ارتفاعی ماهواره می‌باشد.

۵- ارزیابی خطا

در این مقاله جهت ارزیابی نتایج شبکه عصبی موجک در برآورد مقدار VTEC از دو مفهوم خطای نسبی و خطای مطلق استفاده شده است. خطای مطلق بصورت رابطه (۱۲) تعریف می‌شود:

$$Absolute(Error) = |VTEC_{WNN} - VTEC_{GPS}| \quad (12)$$

که در رابطه (۱۲) $VTEC_{WNN}$ مقدار برآورد شده از شبکه عصبی موجک در نقاط آزمون و $VTEC_{GPS}$ مقدار بدست آمده از مشاهدات GPS می‌باشند. خطای نسبی نیز بصورت رابطه (۱۳) تعریف می‌شود:


$$Relative(Error) = \frac{|VTEC_{WNN} - VTEC_{GPS}|}{VTEC_{GPS}} \times 100 \quad (13)$$

۶- نتایج عددی

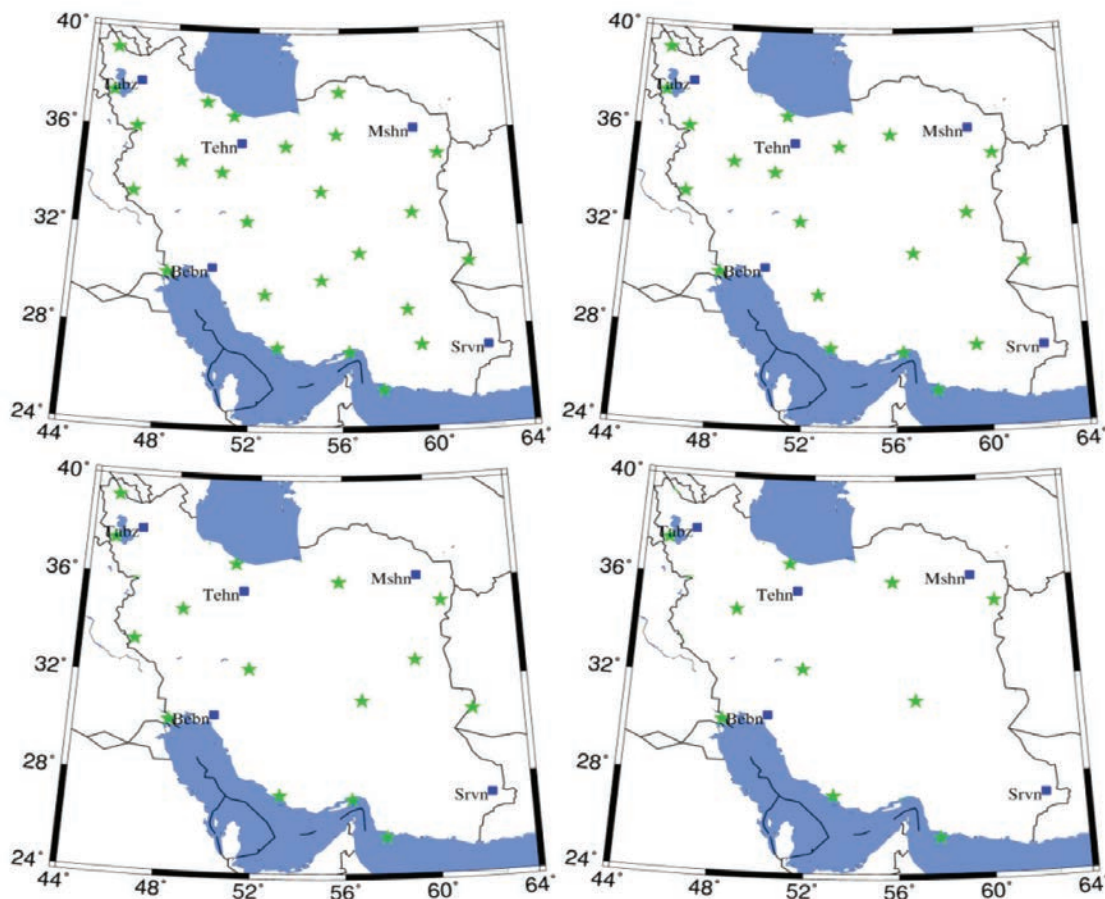
جهت ارزیابی شبکه عصبی موجک با الگوریتم آموزش PSO در مدل‌سازی و پیش‌بینی تغییرات زمان - مکان TEC در منطقه ایران، از مشاهدات ۳۷ ایستگاه شبکه ژئودینامیک در مورخه ۲۰۱۲/۰۸/۱۱ (روز ۲۲۴) استفاده شده است. از ۳۷ ایستگاه مورد نظر، ۵ ایستگاه به عنوان ایستگاه‌های آزمون، ۲ ایستگاه جهت ارزیابی شبکه عصبی موجک و مابقی ایستگاه‌ها جهت آموزش شبکه استفاده می‌شوند. چهار ترکیب متفاوت از مشاهدات ورودی در این مقاله

Kp index for August 2012

According to the finalized Kp-index of GFZ Potsdam



نگاره ۱: چگونگی تغییرات شاخص
 فعالیت‌های خورشیدی (Kp) در ماه
 آگوست سال ۲۰۱۲
 مأخذ: برگرفته شده از سایت
 (<http://www.spaceweatherlive.com>)



نگاره ۲. چگونگی پراکنندگی مکانی ایستگاه‌های GPS مورد استفاده در چهار ترکیب مورد مطالعه، ستاره‌ها ایستگاه‌های مورد استفاده در آموزش و مربع‌ها ایستگاه‌های آزمون می‌باشند، ۲۵ ایستگاه آموزش (بالا سمت چپ)، ۲۰ ایستگاه آموزش (بالا سمت راست)، ۱۵ ایستگاه آموزش (پایین سمت چپ)، ۱۰ ایستگاه آموزش (پایین سمت راست).

نیز ترسیم شده است.

با توجه به نگاره (۳) مقادیر ضریب همبستگی برای حالت GPS و IRI برابر ۰/۸۸۴۵ و برای حالت GPS و WNN با ۲۵ ایستگاه آموزش برابر ۰/۹۷۶۸، با ۲۰ ایستگاه آموزش برابر با ۰/۹۳۷۶، با ۱۵ ایستگاه آموزش برابر با ۰/۹۵۴۵، با ۱۰ ایستگاه آموزش برابر با ۰/۷۵۶۹ بدست آمده است. نتایج بیانگر این موضوع است که مقادیر TEC بدست آمده از مدل WNN دارای همبستگی زیادی با مشاهدات TEC بدست آمده از GPS می‌باشند. تنها در حالت ۱۰ ایستگاه آموزش مقدار ضریب همبستگی از مقدار مدل IRI ۲۰۱۶ کمتر شده است. یعنی با تعداد ۱۵ ایستگاه آموزش به راحتی می‌توان دقتی بالاتر از مدل IRI ۲۰۱۶ در منطقه ایران بدست آورد. همچنین میانگین مقادیر خطای نسبی و مطلق در ۵ ایستگاه آزمون محاسبه شده و در جدول ۲ ارائه شده است. نتایج این جدول برای هر چهار ترکیب از مشاهدات است. با توجه به نتایج حاصل در جدول ۲، خطای نسبی و مطلق مدل مرجع جهانی ۲۰۱۶ در سه ترکیب ۲۵، ۲۰ و ۱۵ ایستگاه آموزش نسبت به شبکه عصبی موجک بیشتر می‌باشد. این امر دور از انتظار نبود، زیرا که مدل مرجع جهانی تنها از یک ایستگاه اندازه‌گیری مستقیم یونسپهر در ایران استفاده می‌کند و در نتیجه مقادیر ارائه شده توسط این مدل دارای خطای زیادی در منطقه ایران می‌باشند. تنها در ترکیب چهارم که شبکه عصبی موجک از ۱۰ ایستگاه آموزش استفاده می‌کند مدل مرجع جهانی ۲۰۱۶ تا حدودی نسبت به مدل پیشنهادی از خطای کمتری برخوردار است. همچنین نتایج حاصل در جدول ۲ نشان‌دهنده این موضوع

مساوی یا نزدیک به ۴ با رنگ زرد ($Kp < 4$) و مقادیر بیشتر از ۴ با رنگ قرمز نشان داده شده است. با توجه به نتایج بدست آمده از نگاره (۱) می‌توان به وضوح مشاهده نمود که روز ۱۱ از ماه آگوست سال ۲۰۱۲ جزء روزهای با فعالیت خورشیدی پایین می‌باشد. به همین جهت در مشاهدات ورودی شبکه عصبی موجک مورد استفاده در این مقاله، شاخص فعالیت‌های خورشیدی به عنوان مشاهده ورودی مورد استفاده قرار نگرفته است.

۱-۶- ترکیبات مورد استفاده و چگونگی پراکندگی ایستگاه‌ها

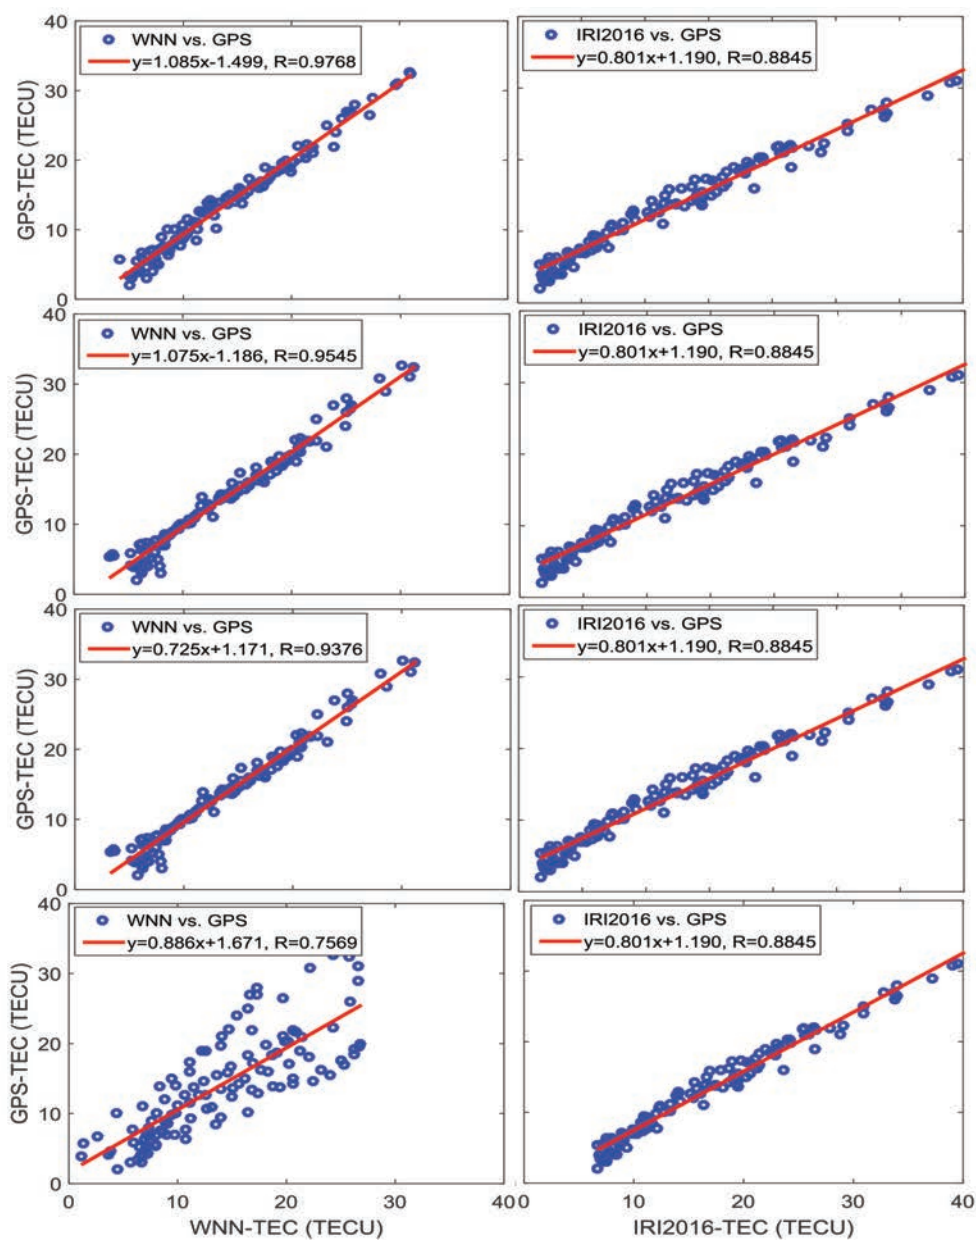
بر اساس آنچه که توضیح داده شد چهار ترکیب متفاوت از مشاهدات جهت بررسی روش پیشنهادی این مقاله مورد استفاده قرار گرفته است. در این چهار ترکیب، ابتدا ۲۵ ایستگاه جهت آموزش WNN مورد استفاده واقع شده و سپس به ترتیب مقدار ایستگاه‌های آموزش به ۲۰، ۱۵ و ۱۰ ایستگاه کاهش یافته است. نگاره (۲) چگونگی پراکندگی ایستگاه‌های آموزش را نشان می‌دهد. در هر چهار حالت ۵ ایستگاه به عنوان ایستگاه‌های آزمون انتخاب شده‌اند.

۲-۶- ارزیابی مقدار خطا در نقاط آزمون

جهت بررسی صحت نتایج حاصل از مدل مرجع جهانی ۲۰۱۶ و مدل شبکه عصبی موجک، تمامی نتایج با مشاهدات TEC بدست آمده از GPS مورد مقایسه قرار گرفته است. این مقایسه در نگاره (۳) برای هر چهار ترکیب نشان داده شده است. در تمامی اشکال خط مربوط به بهترین برازش

جدول ۲. مقایسه میانگین مقادیر خطای نسبی و خطای مطلق در ۵ ایستگاه آزمون و برای هر چهار ترکیب مختلف.

سناریو	تعداد مشاهدات	میانگین خطای مطلق (TECU)		میانگین خطای نسبی (%)	
		GPS-WNN	GPS-IRI	GPS-WNN	GPS-IRI
۱	۳۰۰	۰/۴۵	۳/۲۲	۱۳/۴۳	۲۶/۲۳
۲	۲۴۰	۰/۹۳	۳/۲۲	۱۳/۷۳	۲۶/۲۳
۳	۱۸۰	۱/۱۵	۳/۲۲	۱۵/۰۵	۲۶/۲۳
۴	۱۲۰	۳/۳۴	۳/۲۲	۲۸/۱۷	۲۶/۲۳



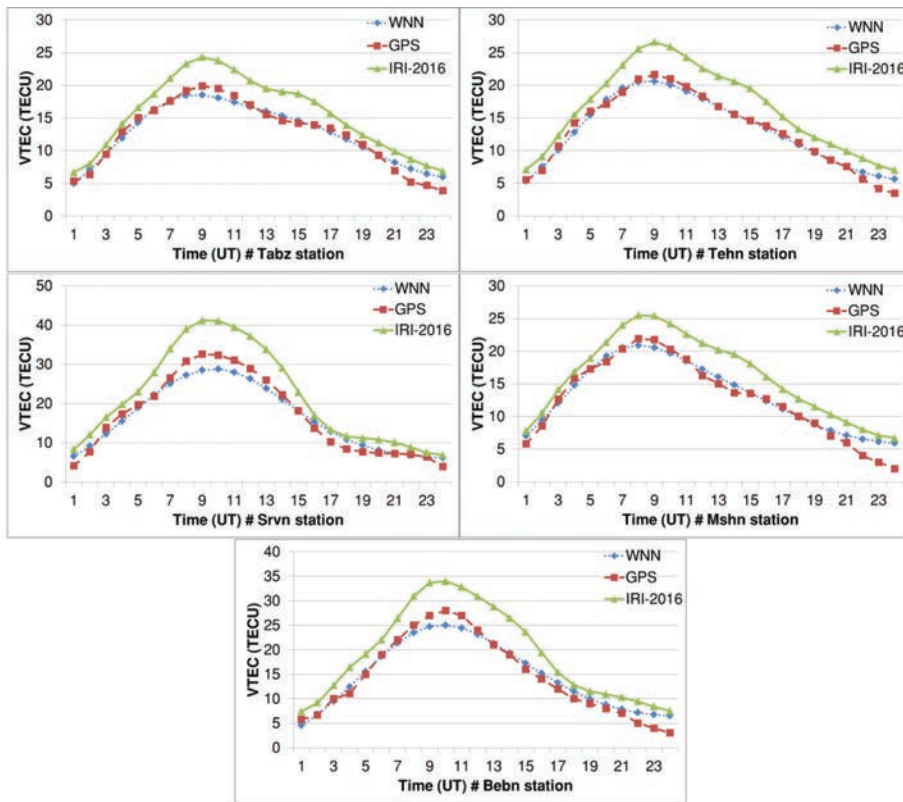
نگاره ۳: نمایش بهترین مقدار رگرسیون بدست آمده برای مقادیر TEC و بدست آمده از WNN در مقابل مشاهدات GPS به عنوان مرجع، ستون سمت راست برای مدل IRI2016 و ستون سمت چپ شکل اول (۲۵) ایستگاه)، شکل دوم (۲۰) ایستگاه)، شکل سوم (۱۵) ایستگاه) و شکل چهارم (۱۰) ایستگاه).

است که با کاهش مشاهدات در شبکه عصبی موجک، مقادیر خطای نسبی و مطلق افزایش پیدا کرده است. (IRI-2016) مورد مقایسه قرار گرفته است. نتیجه این مقایسه در نگاره‌های (۴)، (۵)، (۶) و (۷) برای هر چهار ایستگاه آزمون نشان داده شده است. مقایسه انجام گرفته در نگاره (۴) بیانگر این موضوع است که نتایج حاصل از شبکه عصبی موجک در ایستگاه‌های آزمون به نتایج حاصل از اندازه‌گیری‌های GPS بسیار نزدیک است. نگاره (۵) مقایسه صورت گرفته مابین مدل‌های شبکه عصبی موجک و IRI2016 را با TEC حاصل از GPS نمایش می‌دهد. در این مقایسه پایگاه داده برای شبکه عصبی موجک

است که با کاهش مشاهدات در شبکه عصبی موجک، مقادیر خطای نسبی و مطلق افزایش پیدا کرده است.

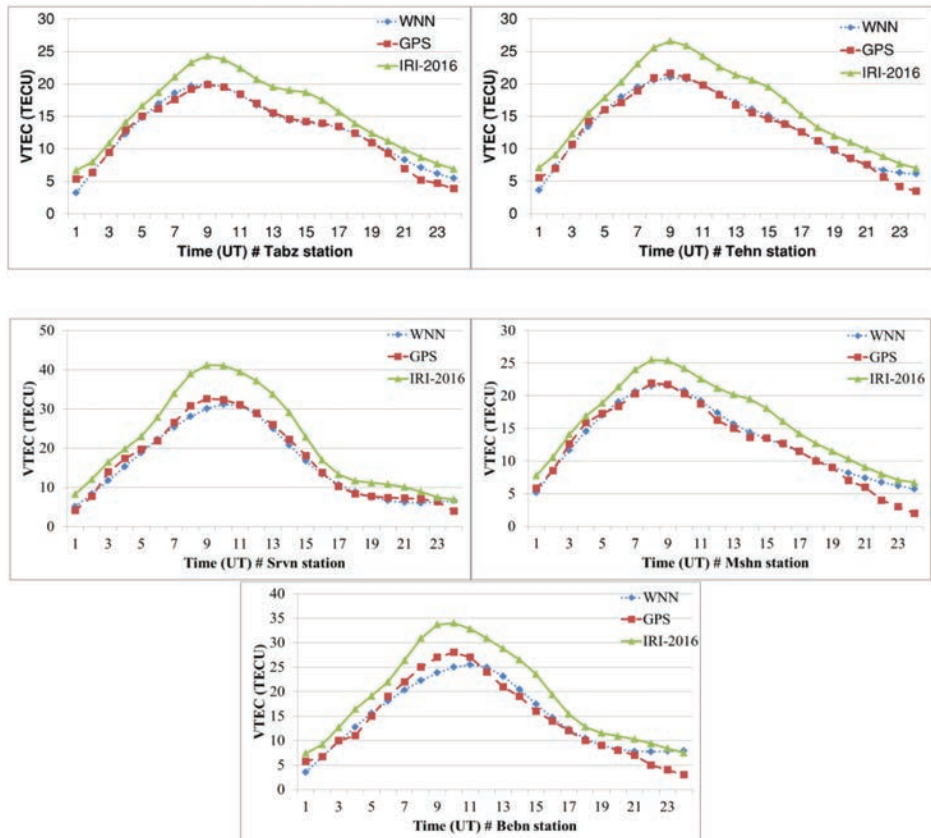
۳-۶- ترسیم سری زمانی روزانه TEC حاصل از مدل WNN با استفاده از شبکه عصبی مصنوعی موجک و الگوریتم آموزش PSO مقادیر VTEC برای ۵ ایستگاه آزمون انتخاب شده در طول ۲۴ ساعت پیش‌بینی شده است. همچنین مقادیر بدست آمده با مقادیر VTEC حاصل از اندازه‌گیری‌های GPS به عنوان مرجع و نیز مدل مرجع بین‌المللی ۲۰۱۶

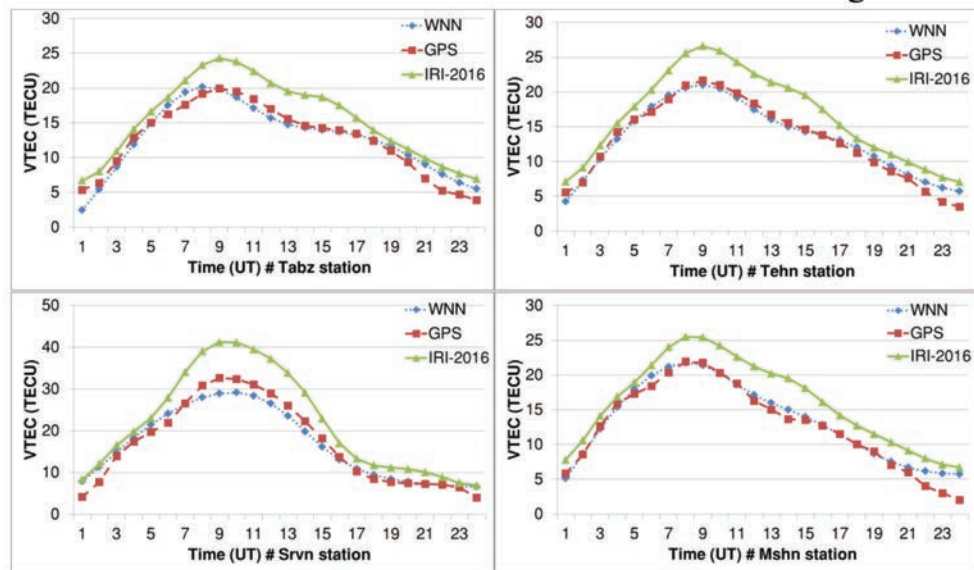
فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (سیر)
 کاربرد شبکه عصبی موجک با الگوریتم آموزش بهینه‌سازی ... / ۱۵




نگاره ۴: مقایسه مقادیر VTEC برآورد شده در ۵ ایستگاه آزمون با مقادیر VTEC حاصل از GPS و مدل مرجع جهانی ۲۰۱۶ با تعداد ۲۵ ایستگاه آزمون

نگاره ۵: مقایسه مقادیر VTEC برآورد شده در ۵ ایستگاه آزمون با مقادیر VTEC حاصل از GPS و مدل مرجع جهانی ۲۰۱۶ با تعداد ۲۰ ایستگاه آزمون





نگاره ۶: مقایسه مقادیر VTEC برآورد شده در ۵ ایستگاه آزمون با مقادیر VTEC حاصل از GPS و مدل مرجع جهانی ۲۰۱۶ با تعداد ۱۵ ایستگاه آزمون




تعداد مشاهدات به ۱۲۰ مشاهده در پایگاه داده، در برخی از ایستگاه‌های آزمون (ایستگاه‌های تبریز، بهبهان و سراوان) دقت نتایج حاصل از مدل شبکه عصبی موجک تا حدودی کاهش پیدا کرده است. بررسی‌های بیشتر نشان می‌دهد که در نزدیکی ایستگاه‌های آزمون تهران و مشهد، ایستگاه‌های آموزش بیشتری نسبت به بقیه ایستگاه‌های آزمون وجود دارد. همین امر می‌تواند دلیلی بر پایین آمدن دقت پیش‌بینی تغییرات VTEC در سایر ایستگاه‌های آزمون شود.

۷- نتیجه‌گیری

در این مقاله از یک شبکه عصبی موجک (WNNs) جهت مدل‌سازی تغییرات زمانی محتوای الکترون کلی (TEC) لایه یونسفر در ایران استفاده شد. داده‌های ۳۷ ایستگاه از شبکه مبنای ژئودینامیک ایران جهت محاسبه مشاهدات ورودی شبکه عصبی موجک بکار گرفته شدند.

دارای ۲۰ ایستگاه آموزش است.

براساس نتایج حاصل از نگاره (۵) مقادیر TEC حاصل از شبکه عصبی موجک به مقادیر TEC حاصل از GPS بسیار نزدیک است. نتایج حاصل از مدل IRI2016 نسبت به مدل WNN و GPS دارای خطای بیشتری می‌باشد. نگاره (۶) مقایسه صورت گرفته برای ترکیب ۱۵ ایستگاه آموزش را نمایش می‌دهد. مقادیر VTEC در این مجموعه نیز در ۵ ایستگاه آزمون به وسیله شبکه عصبی موجک پیش‌بینی شده و با مقادیر VTEC حاصل از مشاهدات GPS و مدل مرجع جهانی ۲۰۱۶ مقایسه شده است. نتایج حاصل در نگاره (۶) مجدداً بیان می‌کند که مدل مرجع جهانی یونسفر ۲۰۱۶ در مقایسه با مدل شبکه عصبی موجک از دقت کمتری برخوردار است. نگاره (۷) مقایسه صورت گرفته برای ترکیب ۱۵ ایستگاه آموزش را نمایش می‌دهد. بررسی نتایج در نگاره (۷) نشان می‌دهد که با کاهش



نگاره ۷: مقایسه مقادیر VTEC برآورد شده در ۵ ایستگاه آزمون با مقادیر VTEC حاصل از GPS و مدل مرجع جهانی ۲۰۱۶ با تعداد ۱۰ ایستگاه آزمون

پیدا می‌کند. این کاهش تا تعداد ۱۸۰ مشاهده مشهود نبوده ولی با تعداد ۱۲۰ مشاهده خطای نسبی و مطلق تا دو برابر افزایش پیدا کرد. بایستی به این نکته اشاره نمود که حتی با تعداد ۱۲۰ مشاهده (۱۰ ایستگاه جهت آموزش)، باز هم نتایج مدل شبکه عصبی موجک با نتایج حاصل از GPS تا حدودی مطابقت دارد. البته در این حالت مقدار خطا نسبت به حالت‌های قبل بیشتر شده است. همچنین در بررسی‌های به عمل آمده در این مقاله این نتیجه بدست آمد که با وجود ایستگاه‌های GPS در اطراف نقطه آزمون، نتایج حاصل از دقت بالاتری برخوردار خواهد بود.

نتایج این مقاله نشان داد که مدل شبکه عصبی موجک با الگوریتم آموزش PSO یک مدل قابل اعتماد جهت پیش‌بینی تغییرات زمانی یون‌سپهر در منطقه ایران می‌باشد. این مدل می‌تواند یک جایگزین بسیار مطمئن برای مدل مرجع جهانی یون‌سپهر در ایران باشد.

این داده‌ها مربوط به روز ۱۱ از ماه آگوست سال ۲۰۱۲ بودند. عموماً جهت آموزش شبکه‌های عصبی، از الگوریتم پس‌انتشار خطا استفاده می‌شود. منتها بدلیل معایب موجود در این الگوریتم از جمله سرعت همگرایی پایین و نیز گیر افتادن در مینیم‌های محلی، در این مقاله از الگوریتم آموزش بهینه‌سازی انبوه ذرات (PSO) استفاده شد.

جهت مدل‌سازی محتوای الکترون کلی ۴ ترکیب از مشاهدات مورد ارزیابی قرار گرفت. تعداد ۲۵، ۲۰، ۱۵ و ۱۰ ایستگاه جهت آموزش شبکه عصبی موجک مورد استفاده قرار گرفتند. تعداد مشاهدات در پایگاه داده به ترتیب برابر با ۳۰۰، ۲۴۰، ۱۸۰ و ۱۲۰ مشاهده (طول و عرض جغرافیایی، زمان مشاهده) در نظر گرفته شدند. نتایج آنالیزهای انجام گرفته نشان‌دهنده این موضوع بود که با کاهش تعداد مشاهدات در پایگاه داده، خطای مطلق و خطای نسبی افزایش پیدا کرده و ضریب همبستگی کاهش

to South African GPS TEC modelling. *Adv. Space Res.*, 43(11), 1711–1720. doi:10.1016/j.asr.2008.08.020, 2009.

13. Hirooka, S., K. Hattori, and T. Takeda 2011, Numerical validations of neural-network-based ionospheric tomography for disturbed ionospheric conditions and sparse data, *Radio Sci.*, 46, RS0F05, doi: 10.1029/2011RS004760.

14. Haykin. S. 1994, *Neural Networks, a comprehensive Foundation*, Macmillan College Publishing Company, New York, 1994.

15. Leandro, R.F., Santos, M.C., 2007, A neural network approach for regional vertical total electron content modelling. *Stud. Geophys.Geod.* 51 (2), 279–292.

16. Mars, P., J.R. Chen, and R. Nambiar. 1996, *Learning Algorithms: Theory and Applications in Signal Processing, Control and Communications*, CRC Press, Boca Raton, Florida, 1996.

17. 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.

18. Orus, R., 2005, Improvement of global ionospheric VTEC maps by using Kriging interpolation technique, *J. Atmos. Sol. Terr. Phys.*, 67, 1598–1609.

19. Rodrigo F Leandro., 2007, A New Technique to TEC Regional Modeling using a Neural Network. Geodetic Research Laboratory, Department of Geodesy and Geomatics Engineering, University of New Brunswick, Fredericton, Canada.

20. Sayin, I., F. Arıkan, and O. Arıkan, 2008, Regional TEC mapping with random field priors and Kriging, *Radio Sci.*, 43, RS5012, doi: 10.1029/2007RS003786.

21. Seeber, G., 2003, *satellite Geodesy: Foundations. Methods and Applications*, Walter de Gruyter. Berlin and New York, 531.

22. Tulunay, E., Senalp, E.T., Radicella, S.M., Tulunay, Y., 2006, Forecasting total electron content maps by neural network technique. *Radio Sci.* 41, doi:10.1029/2005RS003285.

23. Wielgosz, P., D. Brzezinska, and I. Kashani, 2003, Regional ionosphere mapping with Kriging and multiquadratic method, *J. Global Pos. Syst.*, 2, 48–55.

24. Yilmaz, A., K. E. Akdogan, and M. Gurun, 2009, Regional TEC mapping using neural networks, *Radio Sci.*, 44, RS3007, doi:10.1029/2008RS004049.

25. Zhang, Q., Benveniste, A., 1992, *Wavelet Networks*. *IEEE Trans. Neural Networks* 3 (6) 889–898.

منابع و مأخذ

1. Amerian, Y., Hossainali, M., Voosoghi, B., Ghaffari Razin, M. R., 2010, Tomographic Reconstruction of the Ionospheric Electron Density in term of Wavelets. *International Journal of Aerospace science and Technologie*
2. Cander, R. Artificial neural network applications in ionospheric studies, *Annali di Geofisica*, Vol.5-6, 757-766, 1998.
3. Chen, Y.h., 2000, evolving wavelet neural networks for system identification. *Proceeding of International Conference on Electrical Engineering*, 2000, pp. 279–282.
4. Ciralo, L., Azpilicueta, F., Brunini, C., Meza, A., Radicella, S.M., 2007, Calibration errors on experimental Slant Total Electron Content (TEC) determined with GPS. *Journal of Geodesy* 81 (2), 111–120.
5. Ghaffari Razin, M.R., 2015a, Development and analysis of 3D ionosphere modeling using base functions and GPS data over Iran. *ActaGeodGeophys*, DOI 10.1007/s40328-015-0113-9 Volume 51, Issue 1 ,pp 95-111.
6. Ghaffari Razin., M.R., Voosoghi, B., 2016a, Regional ionosphere modeling using spherical cap harmonics and empirical orthogonal functions over Iran. *ActaGeodGeophys*, DOI 10.1007/s40328-016-0162-8.
7. Ghaffari Razin, M.R., Voosoghi, B., 2016b, Regional application of multi-layer artificial neural networks in 3-D ionosphere tomography. *Advances in Space Research*, <http://dx.doi.org/10.1016/j.asr.2016.04.029>.
8. Ghaffari Razin, M. R., Voosoghi, B., Mohammadzadeh, A., 2015b, Efficiency of artificial neural networks in map of total electron content over Iran. *ActaGeodGeophys*, DOI 10.1007/s40328-015-0143-3.
9. Ghaffari Razin, M.R., Voosoghi, B., 2016c, 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>.
10. Ghaffari Razin, M.R., Voosoghi, B., 2016d, 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.
11. Habarulema, J.B., McKinnell, L.A., Cilliers, P.J., 2007, Prediction of Global Positioning System total electron content using neural networks over South Africa. *J. Atmos. Sol. Terr. Phys.* 69 (15), 1842–1850.
12. Habarulema, J.B., McKinnell, L.-A., Cilliers, P.J., Opperman, B.D.L. 2009, Application of neural networks