

مدل سازی و درونیابی محتوای الکترونی کلی یون سپهر به کمک شبکه عصبی مصنوعی و مشاهدات GPS

میررضا غفاری رزین*^۱ و بهزاد وثوقی^۲

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

۲. دانشیار، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

(دریافت: ۹۳/۱۲/۲۵، پذیرش نهایی: ۹۴/۱۱/۱۱)

چکیده

سیگنال‌های سامانه موقعیت‌یاب جهانی (GPS) اطلاعات بارزشی را از ساختار فیزیکی یون‌سپهر در اختیار می‌گذارند. با کمک این مشاهدات می‌توان مقدار محتوای الکترونی کلی (TEC) را برای هر مسیر دید مابین گیرنده و ماهواره به‌دست آورد. در این مقاله اندازه‌گیری‌های به‌دست آمده از ۲۲ ایستگاه موجود در شمال غرب ایران ($36^{\circ} < \varphi < 40^{\circ}$ ، $44^{\circ} < \lambda < 48^{\circ}$) به‌منظور تعیین مقدار محتوای الکترونی کلی در راستای قائم (VTEC) استفاده شده است. به‌علت کمبود مشاهدات و توزیع مکانی نامناسب ایستگاه‌ها، به‌منظور برآورد زمانی مکانی مقدار VTEC در سایر نقاط، دو مدل شبکه عصبی مصنوعی ۳ لایه (MLP-ANN) و شبکه عصبی با تابع‌های پایه شعاعی (RBFNN) براساس الگوریتم پس‌انتشار خطا (BPA) به‌کار گرفته شده است. ۳ ایستگاه آزمون با توزیع مناسب به‌منظور ارزیابی صحت نتایج انتخاب شده است. کمینه خطای نسبی در نقاط آزمون برای شبکه عصبی مصنوعی ۳ لایه ۱/۴۰٪ و برای شبکه عصبی با تابع‌های پایه شعاعی ۱/۸٪ محاسبه شده است. محاسبه خطاهای نسبی کم و همچنین تحلیل صورت گرفته، بیانگر قابلیت مطلوب روش‌های GPS+MLP-ANN و GPS+RBFNN در مقایسه با روش‌های متعارف درونیابی در نشان دادن تغییرات زمانی مکانی یون‌سپهر است.

واژه‌های کلیدی: یون‌سپهر، شبکه عصبی چندلایه، شبکه عصبی با تابع‌های پایه شعاعی، GPS، IGS.

۱. مقدمه

جهانی (GPS) نیز متأثر از خاصیت الکتریکی یون‌سپهر هستند. با استفاده از دو بسامد متفاوت در سامانه موقعیت‌یاب جهانی خاصیت‌های فیزیکی لایه یون‌سپهر را می‌توان مورد بررسی قرار داد. با کمک دو بسامد، تعداد الکترون‌های آزاد لایه یون‌سپهر در راستای گیرنده تا ماهواره محاسبه می‌شود (سیبر، ۲۰۰۳). کمیتی که با این روش محاسبه می‌شود محتوای الکترونی یون‌سپهر در راستای مایل (STEC) نام دارد. جهت موقعیت‌یاب با گیرنده‌های تک‌بسامدی، می‌باید اثر لایه یون‌سپهر از روی سیگنال‌های عبوری از آن برداشته شود. این مرحله در موقعیت‌یاب به مدل‌سازی یون‌سپهر معروف است.

به‌علت ماهیت خاص و نیز ویژگی‌های فیزیکی، چگالی الکترونی در یون‌سپهر دارای تغییرات

در سال‌های اخیر آگاهی از چگونگی توزیع چگالی الکترونی یون‌سپهر به‌مثابه چالشی مهم، در حوزه‌های علمی و عملی مورد توجه محققان و دانشمندان بسیاری قرار گرفته است. گسترش و ارزیابی مدلی قابل اعتماد که بتواند همه ویژگی‌های فیزیکی این لایه را نشان دهد، هنوز چالشی جدی در علوم فضایی است. به‌علت ماهیت غیرخطی رفتار یون‌سپهر و نیز عوامل موجود موثر بر آن، این چالش اهمیت فوق‌العاده‌ای دارد.

الکترون‌های موجود در یون‌سپهر تأثیری بسزا بر انتشار امواج الکترومغناطیسی عبوری از آن دارند. این تأثیر، حوزه‌های تحقیقاتی وسیع و گسترده‌ای را در مورد این لایه از جو همانند سامانه‌های مشاهداتی زمین‌فضا، سامانه‌های ارتباطی و هواشناسی فضایی ایجاد کرده است (شایبر، ۱۹۹۹). سیگنال‌های سامانه موقعیت‌یاب

زمانی مکانی است. این تغییرات ممکن است ناشی از تغییرات روزانه، تغییرات فصلی، بی‌هنجاری‌های گوناگون موجود و یا دوره‌ فعالیت‌های خورشیدی باشد (کومجانی، ۱۹۹۷). وجود بسامدهای گوناگون در رفتار چگالی الکترونی در یونسپهر منجر به اثرات بسیار زیان‌باری در سامانه‌های ارتباطی شده است. به‌منظور پی‌بردن به ماهیت فعالیت‌های یونسپهری و نحوه‌ تاثیر آنها در سایر سامانه‌ها، می‌باید تغییرات زمانی مکانی آن به‌صورت دقیق مورد بررسی قرار گیرد.

کمیتی که با استفاده از آن می‌توان چگونگی فعالیت‌های یونسپهری و نیز تغییرات زمانی مکانی چگالی الکترونی در این لایه از جو را مورد بررسی قرار داد، محتوای الکترونی کلی (TEC) است. TEC انتگرال خطی چگالی الکترونی در مسیر مابین ماهواره تا گیرنده است (سیبر، ۲۰۰۳). واحد اندازه‌گیری TEC، TECU بوده و یک TECU معادل 10^{16} (ele/m²) است. این کمیت را می‌توان از روی اندازه‌گیری‌های فاز و گد به‌دست آمده از سامانه موقعیت‌یاب جهانی به‌دست آورد. یونسپهر به‌علت خاصیت پراکندگی باعث تاخیر و تقدم در سیگنال‌های عبوری از آن می‌شود.

به‌علت توزیع مکانی نامناسب گیرنده‌های GPS و نیز تعداد محدود آنها، مقادیر TEC به‌دست آمده از اندازه‌گیری‌های GPS دارای محدودیت مکانی خواهند بود. به‌منظور محاسبه و تعیین مقدار TEC در مناطقی که دارای مشاهده نیستند و یا توزیع ایستگاهی مناسبی ندارند، در این حالت مقدار TEC به‌دست آمده از اندازه‌گیری‌های GPS می‌باید با روشی مناسب، درون‌یابی و یا برون‌یابی شوند (یلماز و همکاران، ۲۰۰۹؛ غفاری رزین و همکاران، ۲۰۱۵؛ غفاری رزین و وثوقی، ۲۰۱۶). در نتیجه مقادیر TEC محاسبه شده و نیز مقادیر TEC برآورد شده را می‌توان درحکم مدلی برای بررسی رفتار چگالی الکترونی یونسپهر در مکان و زمان مورد استفاده قرار داد.

تاکنون تلاش‌های بسیار زیادی برای درون‌یابی و یا

برون‌یابی چگالی الکترونی یونسپهر در مناطقی که مشاهده کافی و یا مناسب موجود نیست، صورت گرفته است. برای مثال می‌توان به روش‌های کریژینگ، چندجمله‌ای، هماهنگ‌های کروی، درون‌یابی به‌کمک تابع‌های اسپیلاین اشاره کرد (اوروس، ۲۰۰۵؛ ولگوسز و همکاران، ۲۰۰۳؛ مون، ۲۰۰۴؛ سین و همکاران، ۲۰۰۸). از این روش‌ها به‌کرات به‌منظور تهیه و مدل‌سازی منطقه‌ای و جهانی مقدار TEC استفاده شده است.

در سالیان اخیر استفاده از روش‌هایی که نسبت به روش‌های قبلی سرعت عمل و دقت بیشتری داشته باشند مورد توجه محققان قرار گرفته است. یکی از شاخه‌هایی که توانسته در این عرصه قابلیت‌های خود را آشکار ساخته است مبحث مدل‌سازی و برآورد هوشمند با استفاده از شبکه‌های عصبی مصنوعی است (کونوی و همکاران، ۱۹۹۸؛ غفاری رزین و وثوقی، ۲۰۱۶). شبکه‌های عصبی مصنوعی چندلایه (MLP-ANN) به رات در حوزه‌های علوم دیگر به‌منظور تقریب و برآورد مورد استفاده قرار گرفته است (سیمپسون، ۱۹۹۰؛ سارما و ماهدو، ۲۰۰۵؛ غفاری رزین و وثوقی، ۲۰۱۶). نتایج به‌دست آمده از این تحقیقات بیانگر این موضوع است که شبکه‌های عصبی درحکم یک تقریب‌کننده جهانی قابلیت اعتماد بیشتری دارند.

در چندین سال اخیر تلاش‌های اندکی در راستای استفاده از این روش برای مدل‌سازی منطقه‌ای TEC صورت گرفته است. استفاده از قابلیت و کارایی شبکه‌های عصبی مصنوعی در مباحث ژئودزی و ژئودینامیکی به چند سال اخیر بر می‌گردد. هراندز و همکاران (۱۹۹۷) از یک شبکه عصبی بسیار ساده با تنها دو ورودی به‌منظور مدل‌سازی و برآورد مقدار TEC استفاده کردند. مکنیل (۲۰۰۲) یک شبکه عصبی دو لایه را به‌منظور محاسبه مقدار TEC مورد ارزیابی قرار دادند. ژینوس و همکاران (۲۰۰۳) از تبدیل فارادی و نیز شبکه عصبی دو لایه برای برآورد مقدار TEC در راستای قائم (VTEC) استفاده کردند. لئوناردو و

رزین و مشهدی حسینی، ۱۳۸۸ و ۱۳۹۰). با توجه به این مشکل، به‌دست آوردن مقدار TEC و برآورد آن برای سایر نقاط، این‌گونه از مدل‌سازی‌ها دارای معایب و ایرادهایی از جمله کاهش دقت نتایج خواهند بود. مورد دیگر در این نوع از مدل‌سازی‌ها، در نظر نگرفتن شرایط فیزیکی موثر در رفتارهای یون‌سپهر همانند دوره فعالیت‌های خورشیدی و فعالیت‌های مغناطیسی است. این دو عامل می‌تواند باعث کاهش دقت نتایج حاصل برای مقدار TEC شوند.

به‌علت وجود چنین مشکلاتی در عرضه یک مدل تحلیلی برای برآورد زمانی مکانی مقدار TEC، ایده استفاده از روش‌هایی که بتواند با سرعت و دقت زیاد، مقدار TEC را برآورد کند و نیز به آسانی قابل اجرا باشد مطرح شد. شبکه‌های عصبی مصنوعی به‌علت ماهیت غیرخطی و نیز به‌علت سرعت عمل و آسانی در پردازش، در زمینه مدل‌سازی و برآورد مقدار TEC مورد استقبال فراوان قرار دارند. البته شبکه‌های عصبی مصنوعی تنوع بسیار زیادی دارند و می‌توان از انواع ساختارهای گوناگون موجود در این شبکه‌ها به‌منظور مدل‌سازی و برآورد استفاده کرد. دو نوع پرکاربرد و در عین حال دقیق این نوع از شبکه‌ها که می‌توان آنها را در مدل‌سازی و برآورد مقدار TEC مورد استفاده قرار داد، در این مقاله مورد بررسی و ارزیابی کامل قرار گرفته است. شبکه‌های عصبی مصنوعی چندلایه و شبکه‌های عصبی مصنوعی با تابع‌های پایه شعاعی، دو مدل مورد استفاده در این مقاله هستند. به‌منظور پردازش‌های لازم، از اندازه‌گیری‌های به‌دست آمده از ۲۲ ایستگاه موجود در منطقه شمال‌غرب ایران (آذربایجان) استفاده شده است. این اندازه‌گیری‌ها به‌گونه‌ای انتخاب شده است که زلزله به‌وقوع پیوسته در منطقه آذربایجان در ۱۳۹۱ در داخل بازه زمانی مشاهدات این تحقیق قرار گیرد. همچنین ۴ پارامتر بسیار مهم دوره فعالیت خورشیدی، چگونگی فعالیت‌های مغناطیسی، روز و ساعت در کنار موقعیت جغرافیایی دُبعدی به‌منزله پارامترهای کلیدی

سانتوس (۲۰۰۷) یک شبکه عصبی سه‌لایه را به‌منظور تعیین مقدار چگالی الکترونی گسترش دادند. تولونای و همکاران (۲۰۰۶) با اندک تغییراتی در شبکه عصبی گسترش داده شده لئوناردو و همکاران (اضافه کردن مقادیر موثر در تغییرات چگالی الکترونی به‌صورت روزانه) مقدار TEC را برای یک شبکه محلی در زمان‌های متفاوت برآورد کردند. رودریگو و لئوناردو (۲۰۰۷) از یک روش درونی‌یابی بر مبنای شبکه‌های عصبی مصنوعی به‌منظور برآورد چگالی الکترونی یون‌سپهر استفاده کردند. هابارولما و همکاران (۲۰۰۷) ایده استفاده از یک ایستگاه مرکزی به‌منظور آموزش شبکه عصبی و برآورد مقادیر TEC در منطقه افریقای جنوبی را عرضه کردند. یلماز و همکاران (۲۰۰۹) از شبکه‌های عصبی با تابع‌های پایه شعاعی برای مدل‌سازی و برآورد مقدار TEC در کشور ترکیه استفاده کردند.

در داخل کشور در زمینه استفاده از شبکه‌های عصبی مصنوعی در برآورد مقدار TEC تحقیقات بسیار اندکی صورت گرفته است. غفاری رزین و محمدزاده (۱۳۹۳) از ایده شبکه‌های عصبی سه‌لایه به‌همراه اطلاعات اضافی در مرحله آموزش شبکه، به‌منظور مدل‌سازی و برآورد مقادیر VTEC در نقاط گوناگون شبکه ژئودینامیک کشور ایران استفاده کردند. به‌علت کمبود منابع اطلاعاتی کافی و کارهای تحقیقاتی صورت گرفته در زمینه مدل‌سازی و برآورد مقدار TEC در داخل کشور، در این مقاله هدف عرضه دو الگوریتم متفاوت از شبکه عصبی مصنوعی به‌منظور برآورد مقدار VTEC در منطقه ایران است.

تاکنون تلاش‌های بسیار زیادی به‌منظور عرضه مدل تحلیلی که نشان‌دهنده ارتباط بین موقعیت و مقدار TEC در آن موقعیت باشد، صورت گرفته است (عامریان و همکاران، ۲۰۱۰ و ۲۰۱۳؛ غفاری رزین، ۲۰۱۵). به‌علت کمبود مشاهدات ورودی و گاهی به‌علت ماهیت این نوع از مدل‌سازی‌ها، مسئله مدل‌سازی تحلیلی یون‌سپهر یک مسئله وارون بدووضع محسوب می‌شود (غفاری

همچنین در معادله (۳) مقادیر آریبی داخل بسامدی برای ماهواره‌ها با کمک رابطه‌های (۶) و (۷) به دست می‌آید:

$$bs = c(\tau_{p1}^s - \tau_{p2}^s) \quad (6)$$

$$Bs = c(T_{L1}^s - T_{L2}^s)$$

با جمع کردن معادله‌های (۱) و (۳) خواهیم داشت:

$$P_4 + \Phi_4 = \lambda_1 N_1 - \lambda_2 N_2 + \quad (7)$$

$$Br + Bs + br + bs + \varepsilon_p$$

مقادیر پارامترهای ابهام فاز N_1 و N_2 برای مشاهدات پیوسته بدون جهش فاز، ثابت در نظر گرفته می‌شوند. خواهیم داشت:

$$\langle P_4 + \Phi_4 \rangle_{arc} = \frac{1}{n} \sum_{i=1}^n (P_4 + \Phi_4)_i = \quad (8)$$

$$\langle \lambda_1 N_1 - \lambda_2 N_2 \rangle_{arc} + Br + Bs + br + bs + \langle \varepsilon_p \rangle_{arc}$$

در رابطه (۸) تعداد اندازه‌گیری‌های پیوسته در هر دو بسامد است. با کم کردن معادله (۴) از معادله (۸) خواهیم داشت:

$$\bar{P}_4 = \langle P_4 + \Phi_4 \rangle_{arc} - \Phi_4 \approx I_1 \quad (9)$$

$$-I_2 + br + bs + \langle \varepsilon_p \rangle_{arc} - \varepsilon_L$$

در رابطه (۹) مشاهده یون‌سپهری نرم شده با استفاده از مشاهدات یون‌سپهری فاز موج حامل است. تاخیر یون‌سپهری با رابطه (۱۰) به بسامدها مرتبط می‌شود:

$$I_i = \frac{40.3}{f_i^2} STEC \quad (10)$$

با وارد کردن معادله (۱۰) در معادله (۹) می‌توان مقدار محتوای الکترونی کلی در راستای مایل را به دست آورد:

$$STEC = \left(\bar{P}_4 - br - bs - \langle \varepsilon_p \rangle_{arc} + \varepsilon_L \right) \quad (11)$$

$$\frac{f_1^2 f_2^2}{40.3(f_2^2 - f_1^2)}$$

در رابطه (۱۱) مقدار محتوای الکترونی کلی در راستای مایل است که درحکم خروجی مطلوب در آموزش شبکه‌های عصبی مورد استفاده قرار خواهد گرفت. به‌منظور به‌دست آوردن مقدار محتوای الکترونی کلی یون‌سپهر در راستای قائم می‌توان از تابع تصویر به‌صورت رابطه (۱۲) استفاده کرد:

$$VTEC = M \times STEC \quad (12)$$

که خواهیم داشت:

$$M = \frac{1}{\sin(elev)} \quad (13)$$

در رابطه (۱۳) $elev$ زاویه ارتفاعی ماهواره است.

مهم در آموزش هر دو شبکه عصبی مورد استفاده قرار گرفته است. به‌منظور مقایسه نتایج به‌دست آمده از روش‌های فوق و بررسی صحت و دقت این روش‌ها در برآورد مقدار TEC، از نتایج به‌دست آمده از شبکه جهانی IGS استفاده شده است. در بخش دوم این مقاله معادله‌های پایه و اساسی برای به‌دست آوردن مشاهدات موردنیاز TEC در شبکه، مورد بررسی قرار می‌گیرد. در بخش سوم در مورد شبکه عصبی، نحوه آموزش و چگونگی تغییر وزن‌ها صحبت خواهد شد. در بخش چهارم نتایج عملی کار عرضه می‌شود و سرانجام در بخش پنجم در مورد معایب و مزیت‌ها و نیز پیشنهادات برای کارهای آینده صحبت خواهد شد.

۲. معادله‌های پایه و اساسی

گیرنده‌های دو بسامدی GPS مشاهدات کُند و فاز موج حامل $(P_i, \Phi_i, (i=1,2))$ را در باند L و با بسامدهای $L_1(1575.42MHz)$ و $L_2(1227.60MHz)$ در اختیار می‌گذارند. با استفاده از مقادیر مشاهدات کُند و فاز در هر دو بسامد خواهیم داشت (عامریان و همکاران، ۲۰۱۳):

$$P_1 = P_1 - P_2 = I_1 - I_2 + \quad (1)$$

$$c(\tau_{p1}^s - \tau_{p2}^s) + c(\tau_{p1}^s - \tau_{p2}^s) + \varepsilon_p$$

$$P_4 = 40.3 STEC \left(\frac{f_2^2 - f_1^2}{f_1 f_2} \right) \quad (2)$$

$$+ br + bs + \varepsilon_p$$

$$\Phi_4 = \Phi_1 - \Phi_2 = \quad (3)$$

$$I_2 - I_1 + \lambda_1 N_1 - \lambda_2 N_2 +$$

$$c(T_{L1}^s - T_{L2}^s) + c(T_{L1}^s - T_{L2}^s) + \varepsilon_L$$

$$\Phi_4 = -40.3 STEC \left(\frac{f_2^2 - f_1^2}{f_1 f_2} \right) + \quad (4)$$

$$\lambda_1 N_1 - \lambda_2 N_2 + Br + Bs + \varepsilon_L$$

که در رابطه‌های بالا داریم: c سرعت نور در خلاء برحسب $T^r, \tau^r, T^s, \tau^s, m/s$ مقادیر وابسته به بسامد که به آریبی داخل بسامدی برای کُند و فاز معروف‌اند، λ_i طول موج سیگنال L_i برحسب متر، N_i ابهام فاز، I_i پارامتر تاخیر یون‌سپهری و بالاخره ε نوبه اندازه‌گیری‌ها برحسب متر است. در معادله (۱) مقادیر آریبی داخل بسامدی برای گیرنده به‌صورت رابطه (۵) تعریف می‌شود:

$$br = c(\tau_{p1}^r - \tau_{p2}^r) \quad (5)$$

$$Br = c(T_{L1}^r - T_{L2}^r)$$

که در رابطه (۱۴) y_k نورون خروجی، ϕ تابع فعال سازی نورون، m تعداد پارامترهای ورودی شبکه، x_i نشان دهنده پارامتر μ ورودی، w_{ki} وزن هر نورون و b_k آریبی پارامترهای ورودی است. تابع فعال سازی را می توان به صورت تابع سیگموئید (رابطه ۱۵) تعریف کرد (لئوناردو و همکاران، ۲۰۰۷):

$$\phi(x) = \frac{1}{1+e^{-x}} \quad (15)$$

مسئله مهم در شبکه های عصبی مصنوعی چندلایه تعداد نورون های لایه های متفاوت است. در مورد لایه های ورودی و خروجی تعداد نورون ها براساس تعداد پارامترهای ورودی و خروجی مسئله تعیین می شود. تعداد نورون های لایه مخفی در شبکه چندلایه معمولاً براساس سعی و خطا و نیز در نظر گرفتن مقدار خطای ایجاد شده در پارامترهای خروجی به دست می آید.

۳.۱. شبکه عصبی با تابع های پایه شعاعی


شبکه های عصبی با تابع های پایه شعاعی نوع خاصی از شبکه های عصبی هستند که بر پایه نظریه های درون یابی شکل گرفته اند. به علت ماهیت خاص این نوع از شبکه های عصبی، محققان بسیاری به صورت متداول از این نوع شبکه عصبی به منزله جایگزین شبکه های عصبی چندلایه استفاده کرده اند (مودی و دارکن، ۱۹۹۸). این نوع از شبکه های عصبی به منظور تقریب تابع ها و طبقه بندی از قابلیت بسیار زیادی دارند. این امر به علت توپولوژی و سرعت یادگیری سریع این نوع از شبکه های عصبی است (پاول، ۱۹۸۷). شکل ۲ ساختار یک شبکه عصبی با تابع های پایه شعاعی را نشان می دهد.

۳. شبکه عصبی پرسپترون چندلایه
شبکه عصبی، سامانه پردازش اطلاعات است که از تعداد زیادی از عنصرهای پردازش ساده تر که به مثابه عصب های مصنوعی شناخته می شوند، تشکیل یافته است. هر شبکه عصبی از تعدادی گره که همان نورون ها هستند و وزن های ارتباطی که گره ها را به هم وصل می کنند، تشکیل شده است (سیمپسون، ۱۹۹۰؛ هایکین، ۱۹۹۴). داده های ورودی در وزن متناظرشان ضرب می شوند و مجموع آنها به نورون ها وارد می شود. هر نورون دارای یک تابع فعال سازی است. این مقدار ورودی از تابع فعال سازی عبور می کند و مقدار خروجی نورون را مشخص می سازد. تعداد نورون ها و لایه های شبکه عصبی متناسب با مسئله مورد نظر و با روش سعی و خطا به دست می آید.


یکی از ساده ترین و در عین حال کارآمدترین چیدمان های پیشنهادی برای استفاده در مدل سازی عصب های واقعی مدل پرسپترون چندلایه است که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل یافته است (سیمپسون، ۱۹۹۰؛ هایکین، ۱۹۹۴). در این ساختار، همه نورون های یک لایه به همه نورون های لایه بعد متصل اند. این چیدمان در اصطلاح یک شبکه با اتصال های کامل را تشکیل می دهد. شکل ۱ ساختار یک شبکه عصبی با لایه های ورودی، پنهان و خروجی را نشان می دهد.

هر نورون در لایه ورودی براساس تابع زیر پردازش را روی پارامترهای ورودی شبکه عصبی عملی می سازد (لئوناردو و همکاران، ۲۰۰۷):

$$y_k = \phi \left(\sum_{i=1}^l w_{ki} \phi \left(\sum_{i=1}^m x_i \times w_{ki} \right) + b_k \right) + w_0 \quad (14)$$



شکل ۱. ساختار شبکه عصبی چندلایه



شکل ۲. ساختار یک شبکه عصبی با تابع‌های پایه شعاعی

$$\phi_j(x) = \exp\left(-\frac{\|x - u_j\|^2}{2\sigma_j^2}\right) \quad (17)$$

در رابطه (۱۷)، $x \in R^d$ بردار ورودی، $u_j \in R^d$ و σ_j به ترتیب مقدار مرکز و پارامتر پهنای تابع پایه هستند. آموزش این نوع شبکه‌ها نیز نیازمند داده‌های برچسب‌دار است. در واقع زمانی شبکه از لحاظ وزن و آریبی به مقدار بهینه خواهد رسید که مقدار خطای موجود به کمترین میزان برسد. به همین منظور در هر دو روش شبکه‌های عصبی مصنوعی چندلایه و شبکه‌های عصبی با تابع‌های پایه شعاعی از الگوریتم پس‌انتشار خطا برای آموزش استفاده می‌شود.

۲.۳. الگوریتم پس‌انتشار خطا

این الگوریتم که در ۱۹۸۶ روملهارت و مک‌کلیلاند پیشنهاد کردند، در شبکه‌های عصبی پیش‌سو مورد استفاده قرار می‌گیرد. پیش‌سو بودن به این معنا است که نورون‌های مصنوعی در لایه‌های متوالی قرار گرفته‌اند و خروجی خود را رو به جلو می‌فرستند. واژه پس‌انتشار نیز به معنای این است که خطاها به سمت عقب در شبکه تغذیه می‌شوند تا وزن‌ها را اصلاح کنند و پس از آن، مجدداً ورودی مسیر پیش‌سوی خود تا خروجی را تکرار کند (مارس و همکاران، ۱۹۹۶).

روش پس‌انتشار خطا از روش‌های باسرپرست است به این مفهوم که نمونه‌های ورودی برچسب خورده‌اند و خروجی مورد انتظار هریک از آنها از پیش دانسته است (سوزیل و همکاران، ۱۹۹۷). لذا خروجی شبکه با این خروجی‌های ایدئال مقایسه و خطای شبکه محاسبه می‌شود. در این الگوریتم ابتدا فرض بر این است که

با توجه به شکل ۲ می‌توان پی‌برد که این نوع شبکه‌های عصبی نیز از سه لایه تشکیل شده‌اند. لایه ورودی با دریافت یک بردار درحکم ورودی و انتشار نتایج به لایه میانی، خروجی را در لایه آخر به وجود می‌آورد. لایه میانی از نورون‌هایی تشکیل یافته است که از تابع‌های پایه شعاعی استفاده می‌کنند. شبکه‌های عصبی با تابع‌های پایه شعاعی نسبت به شبکه‌های عصبی چندلایه مزیت‌های زیر را دارند:

۱. قابلیت تقریب فراگیر انواع گوناگون تابع‌ها را دارند.
۲. برآورد پارامترها نسبت به شبکه‌های عصبی چندلایه به نسبت ساده‌تر است.

۳. امکان عرضه تفسیرهای فیزیکی درخصوص پارامترهای آن وجود دارد.

خروجی نورون i ام در لایه خروجی را می‌توان با استفاده از تابع زیر (رابطه ۱۶) محاسبه کرد (یلماز و همکاران، ۲۰۰۹):

$$y_i = \sum_{j=1}^q w_{ij} \phi_j(x) + w_0 \quad (16)$$

در رابطه (۱۶) q تعداد نورون‌ها در لایه مخفی، w_{ij} وزن بین نورون j ام در لایه مخفی و نورون i ام در لایه خروجی و w_0 نشان‌دهنده مقادیر آریبی هستند. $\phi(\cdot)$ تابع پایه‌ای است که انتقال غیرخطی بین لایه ورودی با لایه خروجی را عملی می‌سازد. این تابع در واقع نقشی شبیه تابع‌های فعالیت در شبکه‌های عصبی چندلایه دارد. رایج‌ترین نوع تابع پایه در این نوع از شبکه‌های عصبی، تابع گاوسی است (بیشوپ، ۲۰۰۵؛ ینگ و همکاران، ۲۰۱۰). این تابع معمولاً به صورت رابطه (۱۷) تعریف می‌شود:

در عرضه تکی داده‌ها، خطر کمینه‌های محلی منتفی است. در الگوریتم پسانتشار خطا، تابع تحریک هر عصب به صورت جمع وزن‌دار ورودی‌های مربوط به آن عصب در نظر گرفته می‌شود. بدین ترتیب با فرض اینکه w وزن‌های متناظر بین لایه ورودی و لایه بعد باشد می‌توان نوشت:

$$A_j(x, w) = \sum_{i=0}^n x_i w_{ji} \quad (18)$$

به وضوح می‌توان دید که تابع تحریک عصب فقط به ورودی و وزن‌های متناظر بستگی دارد. با فرض این که تابع خروجی، سیگموئید باشد می‌توان خروجی عصب O_j را به صورت رابطه (۱۹) نوشت:

$$O_j(x, w) = \text{sgm}(A_j(x, w)) = \frac{1}{1 + e^{-A_j(x, w)}} \quad (19)$$

با دقت در رابطه (۱۹) درمی‌یابیم که خروجی فقط به مقدار تابع تحریک بستگی دارد که به نوبه خود به ورودی و وزن‌ها مرتبط می‌شود. لذا برای تغییر خروجی باید وزن‌ها تغییر کنند. آنچنان که پیش از این نیز بیان شد، هدف فرایند آموزش، رسیدن به خروجی مطلوب است. بدین ترتیب ابتدا باید تابع خطای هر نرون را تعریف کنیم. این خطا از اختلاف خروجی واقعی شبکه و خروجی موردانتظار به صورت رابطه (۲۰) به دست می‌آید:

$$E_j(x, w, d_j) = (O_j(x, w) - d_j)^2 \quad (20)$$

انتخاب مربع تفاضل بین خروجی واقعی (O_j) و خروجی مطلوب (d_j) از چندین جنبه قابل بحث است، نخست با استفاده از توان دوم، مقدار خطا همواره مثبت خواهد بود. دوم اگر اختلاف بین خروجی واقعی و مطلوب زیاد باشد، توان دوم منجر به بزرگ‌تر شدن این عدد می‌شود و برعکس اگر اختلاف بین خروجی واقعی و مطلوب کم باشد توان دوم منجر به کوچک‌تر شدن آن می‌شود. بر این اساس می‌توان خطای کلی شبکه را به صورت مجموع خطای تک‌تک عصب‌های لایه خروجی نوشت. لذا داریم:

$$E(x, w, d) = \sum_j E_j(x, w, d_j) = \sum_j (O_j(x, w) - d_j)^2 \quad (21)$$

وزن‌های شبکه تصادفی انتخاب شده‌اند. در هر گام خروجی شبکه محاسبه می‌شود و برحسب میزان اختلاف آن با خروجی مطلوب، وزن‌ها تصحیح می‌شوند تا در نهایت، این خطا کمینه شود. در الگوریتم پسانتشار خطا، تابع تحریک هر عصب به صورت جمع وزن‌دار ورودی‌های مربوط به آن عصب در نظر گرفته می‌شود.

با توجه به اینکه شبکه عصبی، مدل ساده شده اعصاب بدن است، درست به مانند آنها قابلیت یادگیری دارد. به عبارت دیگر، شبکه با استفاده از اطلاعاتی که از ورودی و به واسطه سرپرست خود دریافت می‌کند، قادر به فراگیری روند موجود در الگوها است (سوزیل و همکاران، ۱۹۹۷). لذا به طور مشابه با انسان، روند یادگیری در شبکه عصبی نیز از مدل‌های انسانی الهام گرفته است. بدین صورت که مثال‌های بسیاری را به دفعات باید به شبکه عرضه کرد تا بتواند با تغییر وزن‌های شبکه، خروجی موردنظر را دنبال کند. عرضه نمونه داده‌های ورودی به شبکه عصبی به دو روش امکان پذیر است:

۱. روش عرضه یک‌جا: در این روش، همه نمونه‌ها به شبکه عرضه می‌شود و در آخر، خطای شبکه نسبت به کل نمونه‌ها محاسبه می‌شود و وزن‌ها براساس آن خطا تغییر می‌کند. در مرحله بعد، دوباره همه داده‌ها به شبکه عرضه می‌شود و روند فوق نظیر به نظیر صورت می‌پذیرد تا در نهایت خطا به سطح قابل قبولی برسد (صیادی، ۱۳۸۷). مسلماً این روش پیچیده و زمان‌بر است و نیاز به حافظه زیادی دارد. همچنین امکان گیر کردن الگوریتم در کمینه‌های محلی وجود دارد.

۲. روش عرضه الگو: در این روش، در هر بار نمونه‌ها به صورت تک‌تک به شبکه داده می‌شود و خطای متناظر با همان داده بلافاصله محاسبه می‌شود و براساس آن، وزن‌های شبکه تغییر می‌کند. سپس نمونه بعدی به شبکه عرضه می‌شود و روند مشابه بالا صورت می‌پذیرد (صیادی، ۱۳۸۷). چون در این روش، در هر گام اصلاح وزن‌ها براساس هر نمونه صورت می‌گیرد، الگوریتم همگرایی خوبی دارد و با توجه به ماهیت تصادفی موجود

میزان اصلاح وزن‌ها در هر گام T باید مشتق خطا را برحسب وزن‌ها به دست آوریم. بدین منظور با استفاده از قاعده زنجیره‌ای می‌توان نوشت:

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial O_j} \times \frac{\partial O_j}{\partial w_{ji}} \quad (24)$$

با توجه به رابطه (۲۱) می‌توان نوشت:

$$\frac{\partial E}{\partial O_j} = 2(O_j - d_j) \quad (25)$$

همچنین با استفاده مجدد از قاعده زنجیره‌ای و با توجه به رابطه‌های (۱۸) و (۱۹) می‌توان نوشت:

$$\frac{\partial O_j}{\partial w_{ji}} = \frac{\partial O_j}{\partial A_j} \times \frac{\partial A_j}{\partial w_{ji}} = (O_j(1 - O_j)) \times x_i \quad (26)$$

در رابطه (۲۶) برای محاسبه با توجه به رابطه (۱۸) و با استناد به خاصیت زیر برای تابع سیگموئید می‌توان مشتق تابع سیگموئید را برحسب خود تابع نوشت:

$$\frac{d}{dx} \text{sgm}(x) = \frac{d}{dx} \left(\frac{1}{1 + e^{-x}} \right) =$$

$$\frac{e^{-x}}{(1 + e^{-x})^2} = (1 - \text{sgm}(x)) \text{sgm}(x)$$

با قرار دادن (۲۵) و (۲۶) در رابطه (۲۴) خواهیم داشت:

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial O_j} \times \frac{\partial O_j}{\partial w_{ji}} =$$

$$2(O_j - d_j) \times O_j \times (1 - O_j) \times x_i \quad (28)$$

اکنون با جایگزینی (۲۸) در (۲۳) رابطه نهایی میزان اصلاح وزن‌ها در هر گام از الگوریتم پسانتشار خطا به صورت رابطه (۲۹) به دست می‌آید:

$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} =$$

$$-2\eta(O_j - d_j) \times O_j \times (1 - O_j) \times x_i$$

از رابطه (۲۹) در اصلاح وزن‌های یک شبکه عصبی دو لایه که فقط یک دسته وزن دارد می‌توان استفاده کرد. با فرض وجود لایه پنهان باید دو دسته وزن در هر گام از اجرای الگوریتم پسانتشار خطا، اصلاح شوند: وزن‌های اتصال‌های لایه ورودی به لایه پنهان (v) و وزن‌های اتصال‌های لایه پنهان به لایه خروجی (w). در این حالت، خطا علاوه بر وابستگی به وزن‌های اتصال‌های لایه پنهان، به لایه خروجی یا همان w_{ji} به وزن‌های v_{ji} نیز وابسته است. بار دیگر با استفاده از ایده گرادیان شیب می‌توان نوشت:

حال باید به بررسی ارتباط خطا با ورودی‌ها، وزن‌ها و خروجی‌ها پردازیم. برای این کار روش‌های متفاوتی وجود دارد که برخی از مهم‌ترین آنها عبارت‌اند از:

۱. روش گرادیان شیب
۲. روش نیوتن
۳. روش اندازه حرکت
۴. روش آنتروپی متقابل
۵. روش لوونبرگ

روش گرادیان شیب به علت اینکه ساده‌ترین و درعین حال پُرکاربردترین روش است، بیشتر از سایر روش‌ها مورد استفاده واقع می‌شود (صیادی، ۱۳۸۷). در روش گرادیان شیب، ابتدا یک تابع هزینه درجه دوم تعریف می‌شود که عبارت است از:

$$J(w) = \frac{1}{N} \sum_{i=1}^N J(w, i) = \quad (22)$$

$$\frac{1}{N} \sum_{i=1}^N \left(\frac{1}{2} \sum_{j=1}^{L_0} (O_j - d_j)^2 \right)$$

که در رابطه (۲۲) L_0 بُعد خروجی (تعداد نورون‌های لایه خروجی) است. هدف نهایی الگوریتم پسانتشار خطا، کمینه کردن این تابع هزینه است. براساس روش گرادیان شیب، با توجه به درجه دوم و مثبت بودن تابع هزینه، فرض می‌شود این تابع رفتاری سهموی دارد. لذا برای رسیدن به کمینه کلی آن باید در خلاف جهت شیب تابع حرکت کنیم. بنابراین با فرض اینکه وزن‌ها در ابتدای کار به صورت تصادفی انتخاب شده باشند، باید شیب تابع خطا را نسبت به وزن‌ها محاسبه کرد و در جهت خلاف آن، وزن‌ها را تغییر داد. این روند را تا آنجا ادامه می‌دهیم که به کمینه کلی یا یک خطای قابل قبول برسیم. بنابراین میزان تغییر وزن‌ها در هر گام عبارت است از:

$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} \quad (23)$$

که در آن، η ثابت اصلاح وزن‌ها است و از سوی کاربر انتخاب می‌شود. این ثابت، نرخ همگرایی الگوریتم را تعیین می‌کند. لذا به وضوح هرچه مقدار این ثابت بیشتر باشد، میزان تغییرات در هر گام بیشتر خواهد بود و برعکس. طبق رابطه (۲۳) به منظور یافتن

مشخص می‌کند. در مورد تعداد نورون‌های لایه میانی، مبنای خاصی وجود ندارد و معمولاً با سعی و خطا به‌نحوی انتخاب می‌شود که شبکه جواب معقولی در اختیار بگذارد. باید دقت داشت که اگر شبکه خیلی پیچیده باشد، دقیقاً رفتار الگوهای ورودی را یاد خواهد گرفت و لذا اگر ورودی نسبت به داده‌های آموزشی تغییر کند، شبکه به‌راحتی قادر به دنبال کردن آن نخواهد بود. در این حالت در اصطلاح گفته می‌شود که شبکه عصبی قابلیت تعمیم ندارد. این چنین شبکه‌هایی را Over-loaded networks (سرریز) می‌نامند (صیادی، ۱۳۸۷).

قدم بعدی در شبیه‌سازی، انتخاب نوع تابع خروجی نورون است که در شبکه‌های چندلایه که با الگوریتم پس‌انتشار خطا کار می‌کنند، عمدتاً از تابع سیگموئید استفاده می‌شود. علت این امر مشتق‌گیری ساده و ارتباط مستقیم مشتق تابع با خود تابع است. پیش از شروع شبیه‌سازی، باید داده‌های ورودی را به دو گروه تقسیم کرد:

۱. داده‌های آموزش: این داده‌ها از میان داده‌های برچسب‌دار و به‌منظور آموزش شبکه به کار می‌روند. عمدتاً از میان کل داده‌ها شصت تا هفتاد درصد آنها را (به‌طور تصادفی یا با یک پیش‌فرض) به‌منزله داده‌های آموزش انتخاب می‌کنند. پس از آنکه شبکه با این داده‌ها آموزش دید، وزن‌ها مقدار نهایی خود را یافته‌اند به‌نحوی که شبکه برای داده‌های آموزش، کمترین خطا را به‌دست می‌دهد.

۲. داده‌های آزمون: پس از آنکه شبکه با داده‌های آموزش تا رسیدن به حداقل خطا آموزش یافت، بقیه داده‌ها (سی تا چهل درصد) که در آموزش نقشی نداشته‌اند در حکم ورودی به شبکه داده می‌شوند و پاسخ شبکه با پاسخ مطلوب (برچسب آنها) مقایسه و بدین ترتیب بازدهی شبکه آموزش دیده محک زده می‌شود.

شایان ذکر است که اگر تعداد نمونه‌های آموزش

$$\Delta v_{ik} = -\eta \frac{\partial E}{\partial v_{ik}} = -\eta \frac{\partial E}{\partial x_i} \times \frac{\partial x_i}{\partial v_{ik}} = \quad (30)$$

$$-\eta \frac{\partial E}{\partial x_i} \times (x_i(1-x_i)v_{ik})$$

همچنین با توجه به اینکه در حالتی که شبکه عصبی دارای سه لایه است، ورودی لایه خروجی در حقیقت خروجی لایه پنهان است، و رابطه (۲۸) به‌صورت رابطه (۳۱) تغییر می‌یابد:

$$\frac{\partial E}{\partial w_{ji}} = -2(O_j - d_j) \times O_j \times (1 - O_j) w_{ji} \quad (31)$$

اگر شبکه عصبی دارای تعداد لایه‌های بیشتری باشد، با استفاده از روندی مشابه با روند بالا می‌توان میزان اصلاح وزن‌های هر لایه را به‌دست آورد. در عمل می‌توان نشان داد که یک شبکه عصبی با سه لایه می‌تواند بازدهی مشابه با شبکه‌های با لایه‌های بیشتر داشته باشد، بنابراین از آنجا که افزایش تعداد لایه‌ها، الگوریتم یادگیری را پیچیده‌تر می‌کند، مرسوم است که از شبکه‌های عصبی با سه لایه (ورودی، پنهان و خروجی) استفاده شود.

۳.۳. روند اجرای شبکه‌ها

به‌منظور شبیه‌سازی یک مسئله با استفاده از شبکه‌های عصبی به روش با سرپرست (با فرض در اختیار داشتن داده‌های برچسب‌دار) اولین کار انتخاب ابعاد شبکه است. با توجه به بحث پیشین، انتخاب تعداد لایه‌ها محدود به سه لایه می‌شود. در لایه ورودی باید به تعداد بُعدهای هر الگوی ورودی، نورون قرار دهیم. بنابراین، اندازه لایه ورودی را بعد داده‌های ورودی تعیین می‌کند. در لایه خروجی نیز به‌وضوح باید به تعداد رده‌ها، نورون داشته باشیم. در حالت ایدئال، با آمدن ورودی مربوط به یک رده انتظار داریم نورون مربوط به آن رده مقدار ۱ و بقیه نورون‌ها مقدار ۰ را به خود بگیرند. اما در عمل با توجه به تابع سیگموئید مورد استفاده، مقدار خروجی شبکه، عددی بین صفر و یک است. لذا در حالت عملی، نورونی از لایه خروجی که در اصطلاح بیش از بقیه روشن شده باشد (مقدار آن بزرگ‌تر از بقیه باشد) رده مربوط به آن داده را

ورودی شبکه عصبی طول، عرض، مقادیر دوره فعالیت‌های خورشیدی، مقدار فعالیت‌های مغناطیسی، ساعت و مقادیر VTEC در حکم پارامترهای خروجی در نظر گرفته می‌شوند. در نتیجه می‌توان تابع زیر را به مثابه رابطه ریاضی بین ورودی‌ها و خروجی‌های شبکه عصبی بیان کرد:

$$T_{NN} \equiv f(lat \ lon \ SA \ MA \ Hr) \quad (۳۴)$$

در رابطه (۳۴) مقدار T_{NN} مقدار VTEC برآورد شده به کمک شبکه عصبی، Lat و Lon مقادیر عرض و طول جغرافیایی، SA مقدار دوره فعالیت خورشیدی، MA مقدار فعالیت‌های مغناطیسی و Hr زمان مربوط به اندازه گیری است.

معمولاً در شبکه‌های عصبی به منظور به دست آوردن بهینه‌ترین ساختار شبکه، داده‌های ورودی را به سه دسته مجزا از هم تقسیم می‌کنند: مجموعه آموزش، مجموعه آزمون و مجموعه ارزیابی. مجموعه آموزش صرفاً به منظور آموزش شبکه و تعیین وزن نورون‌ها به کار برده می‌شود. در این مقاله برای ارزیابی نتایج شبکه عصبی مصنوعی در برآورد مقدار VTEC از سه مفهوم خطای نسبی، خطای مطلق و جذر خطای مربعی میانگین استفاده شده است. خطای مطلق به صورت رابطه (۳۵) تعریف می‌شود (کاندر، ۱۹۹۸):

$$Absolute(Error) = |VTEC_e - VTEC_k| \quad (۳۵)$$

که در آن، $VTEC_k$ مقدار مشخص در نقاط آزمون و $VTEC_e$ مقدار برآورد شده از شبکه عصبی در نقاط آزمون هستند. خطای نسبی نیز به صورت رابطه (۳۶) تعریف می‌شود:

$$Relative(Error) = \frac{|VTEC_e - VTEC_k|}{VTEC_k} \times 100 \quad (۳۶)$$

همچنین جذر خطای مربعی میانگین به صورت رابطه (۳۷) تعریف می‌شود:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (y_i^{Actual} - y_i^{Predict})^2} \quad (۳۷)$$

که در آن، y_i^{Actual} نشان‌دهنده مقادیر خروجی واقعی و $y_i^{Predict}$ بیانگر خروجی‌های شبکه عصبی هستند.

به حد کافی زیاد باشد، استفاده از روش عرضه الگو جواب‌های بهتری می‌دهد اما در کاربردهایی که تعداد نمونه‌های برچسب‌دار آموزش کم باشند، هر دو روش عرضه الگو و عرضه یک‌جا به جوابی یکسان منجر خواهند شد. همچنین باید توجه داشت که در اولین گام اجرای الگوریتم، وزن همه لایه‌ها به طور تصادفی انتخاب می‌شود و در هر گام با استفاده از روش پس‌انتشار خطا، وزن‌ها تصحیح می‌شود. اشاره به این نکته حائز اهمیت است که پس از آنکه همه نمونه‌ها یک‌بار به شبکه عرضه شد، در نوبت بعدی (اپوک بعد) ابتدا داده‌های آموزشی به طور تصادفی بر زده شوند. این کار به‌ویژه سبب می‌شود که شبکه عصبی به‌ازای نمونه‌های خاص آربی نشود و همچنین از گیر کردن در کمینه‌های محلی جلوگیری می‌کند (صیادی، ۱۳۸۷). پس از اجرای الگوریتم تصحیح وزن‌ها تا رسیدن به کمینه خطای کلی، چندین معیار برای توقف الگوریتم پیشنهاد می‌شود که مهم‌ترین آنها عبارت‌اند از:

۱. اگر خطا (تابع هزینه) که قرار است کمینه شود، از یک سطح آستانه کمتر شود، می‌توان پذیرفت که شبکه با خطای قابل قبولی آموزش دیده است. این شرط چنین بیان می‌شود:

$$J(w) < \varepsilon_0 \quad (۳۲)$$

۲. اگر میزان تغییرات خطا در طی دو گام متوالی کمتر از یک سطح آستانه باشد یا به عبارت دیگر روند کاهش خطا با سرعت کند صورت گیرد، می‌توان چنین برداشت کرد که به حوالی کمینه کلی رسیده‌ایم. لذا در این حالت نیز تصمیم به توقف الگوریتم آموزش گرفته می‌شود. بیان ریاضی این شرط نیز چنین است:

$$|\nabla_w J(w)| < \varepsilon_0 \quad (۳۳)$$

۳.۴. بررسی خطا در شبکه عصبی

در این مقاله از آموزش به روش پس‌انتشار خطا به منظور برآورد VTEC در شبکه استفاده شده است. پارامترهای

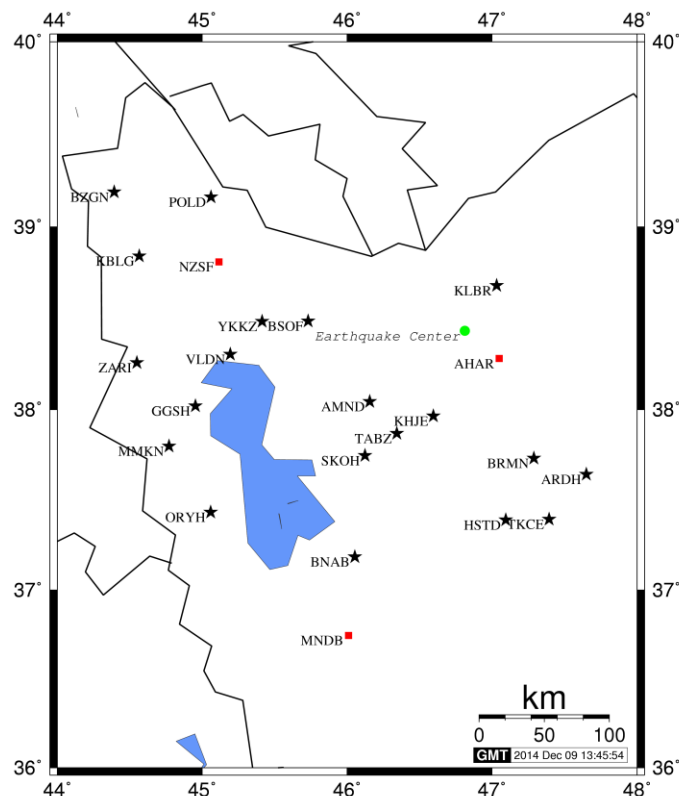
۴. پردازش مشاهدات

تحقیقات ژئودینامیک در ایران از ۱۳۷۷ به‌منظور پایش تغییرات پوسته زمین و حرکات زمین‌ساختی مربوط به آن آغاز شده است. در این راستا شبکه دائمی ژئودینامیک سراسری در ۱۳۸۳ به‌منظور بررسی سازوکارهای حرکات گسل‌های ایران طراحی و به‌تدریج اجرا شد. در حال حاضر این شبکه دارای ۱۲۰ ایستگاه دائمی GPS است. به‌منظور آزمون و ارزیابی روش‌های پیشنهاد شده در این مقاله در برآورد مقدار VTEC و نیز به‌منظور بررسی اینکه روش فوق تا چه حد می‌تواند در مناطقی که تعداد ایستگاه‌های GPS و در نتیجه تعداد مشاهدات ورودی کم بوده است، جوابگو باشد و بتواند با دقت زیاد ویژگی‌های فیزیکی یون‌سپهر را نمایش دهد، از تعداد ۲۲ ایستگاه موجود در شمال‌غرب ایران (آذربایجان) استفاده شده است. این محدوده در عرض جغرافیایی $36^{\circ}N \leq \varphi \leq 40^{\circ}N$ و طول جغرافیایی $44^{\circ}E \leq \varphi \leq 48^{\circ}E$ قرار گرفته است. شکل ۳ چگونگی توزیع مکانی ۲۲ ایستگاه از شبکه آذربایجان را نشان می‌دهد. در این شکل ایستگاه‌های مورد استفاده برای آموزش، سه ایستگاه برای آزمون نتایج و نیز محل جغرافیایی وقوع زلزله نشان داده شده است.

مشاهدات مورد استفاده در این مقاله مربوط به ۲۱ روز از ماه اوت سال ۲۰۱۲ (مرداد ۱۳۹۱) است. علت انتخاب این بازه زمانی برای مشاهدات، وقوع زمین‌لرزه در تاریخ ۲۰۱۲/۰۸/۱۱ (۲۱ مرداد ۱۳۹۱) در منطقه اهر-ورزقان است. لازم به ذکر است که هدف اصلی این مقاله ارزیابی کارایی دو روش شبکه عصبی مصنوعی چندلایه و شبکه عصبی مصنوعی با تابع‌های پایه شعاعی در درون‌یابی تغییرات زمانی مکانی VTEC در منطقه آذربایجان است. انتخاب بازه زمانی فوق بیشتر بدین علت است که بتوان در تحقیقات آینده از نتایج به‌دست آمده در این مقاله به‌منظور ارزیابی چگونگی تاثیر پدیده‌های ژئودینامیکی همانند زلزله در مقدار چگالی الکترونی یون‌سپهر استفاده کرد.

ذکر این نکته نیز ضروری است که می‌توان از مدل‌های مرجع جهانی یون‌سپهر (IRI2012) و یا خروجی‌های به‌دست آمده از شبکه جهانی IGS به‌منظور تعیین مقدار VTEC استفاده کرد. باید توجه داشت که مدل مرجع جهانی یون‌سپهر از اندازه‌گیری‌های مستقیم یون‌سپهر (یونوسوند) برای تعیین مقدار VTEC و چگالی الکترونی یون‌سپهر استفاده می‌کند. با توجه به اینکه در منطقه ایران فقط یک ایستگاه اندازه‌گیری مستقیم یون‌سپهر موجود است، این نوع مدل‌ها در مناطقی همانند ایران از روش‌های گوناگون درون‌یابی استفاده می‌کنند و این امر باعث کاهش دقت نتایج عرضه شده می‌شود. در مورد خروجی‌های شبکه جهانی IGS نیز به‌علت وجود صرفاً یک ایستگاه در ایران، باز هم استفاده از روش‌های درون‌یابی اجتناب‌ناپذیر است. بنا به علت‌های فوق و نیز ضعف مدل‌های مرجع و جهانی، لزوم عرضه مدلی که بتواند نقاط ضعف این مدل‌ها را جبران کند و در عین حال محلی، سریع، دقیق و در دسترس باشد، کاملاً احساس می‌شود. به‌همین خاطر در این مقاله از داده‌های ایستگاه‌های GPS به همراه الگوریتم شبکه‌های عصبی به‌منظور برآورد مقدار VTEC در نقاط گوناگون استفاده شده است.

داده‌های GPS به‌کار رفته در این مقاله طوری انتخاب شده است که ۱۰ روز آن مربوط به قبل از زلزله و ۱۰ روز دیگر مربوط به بعد از زلزله هستند. این انتخاب به این علت صورت گرفته است که بتوان تغییرات زمانی مکانی مقدار VTEC را در روز وقوع زلزله با کمک شبکه عصبی برآورد کرد. از ۲۲ ایستگاه GPS انتخاب شده در منطقه آذربایجان، ۱۹ ایستگاه به‌منظور آموزش و ۳ ایستگاه برای آزمون نتایج هستند. این سه ایستگاه آزمون به‌گونه‌ای انتخاب شده است که از محل ایستگاه‌های به‌کار رفته در مرحله آموزش دور باشند. این عامل باعث خواهد شد تا بتوان ارزیابی موثرتری در مورد کارایی هر یک از شبکه‌های عصبی مصنوعی در برآورد مقدار VTEC را عملی ساخت.



شکل ۳. چگونگی توزیع مکانی ۲۲ ایستگاه مورد استفاده در این تحقیق (ستاره‌ها نشان‌دهنده ایستگاه‌های مورد استفاده در آموزش شبکه، مربع‌ها نشان‌دهنده ایستگاه‌های مورد استفاده در آزمون و دایره نشان‌دهنده مرکز زمین‌لرزه هستند).

نتایج مربوط به ایستگاه آزمون اهر آورده شده است. با توجه به نتایج به دست آمده در جدول ۱ می‌توان دریافت که بیشینه خطای نسبی به دست آمده از شبکه عصبی مصنوعی سه‌لایه ۴/۸۰ درصد و کمینه خطای نسبی ۰/۶۱ درصد است.

با توجه به نتایج به دست آمده در جدول ۲ می‌توان دریافت که بیشینه خطای نسبی به دست آمده از شبکه عصبی مصنوعی با تابع‌های پایه شعاعی ۵/۴۱ درصد و کمینه خطای نسبی ۰/۲۵ درصد است. همچنین به منظور ارزیابی صحت نتایج به دست آمده از مدل شبکه‌های عصبی در محدوده خارج از ایستگاه‌های مورد استفاده در آموزش، در فواصل مشخصی مقدار VTEC از دو مدل شبکه عصبی مصنوعی چندلایه و شبکه عصبی با تابع‌های پایه شعاعی مورد محاسبه قرار گرفته و با نتایج حاصل از GPS مقایسه شده است. نتیجه این ارزیابی در شکل ۴ نشان داده شده است.

به منظور محاسبه مقادیر VTEC ورودی به شبکه‌های عصبی با استفاده از الگوریتم اشاره شده در بخش دوم، بازه‌های زمانی یک ساعته استفاده شده است. در واقع برای هر یک ساعت از اندازه‌گیری‌های فاز و گد گیرنده‌های GPS، یک مقدار VTEC محاسبه شده است. در این حالت تعداد کل مشاهدات VTEC حاصل از ایستگاه‌های GPS برای آموزش شبکه عصبی ۳۶۵۱۶۳ عدد در ۲۰ روز داده است. درحقیقت هدف ما در این مقاله استفاده از داده‌های ۲۰ روز گیرنده‌های GPS منطقه آذربایجان (۱۰ روز قبل و ۱۰ روز بعد از زلزله) به منظور مدل‌سازی رفتار یونسپهر توسط شبکه عصبی و سپس استفاده از این مدل برای برآورد تغییرات زمانی مکانی VTEC در روز زلزله است.

جدول‌های ۱ و ۲ مقادیر خطاهای نسبی و مطلق به دست آمده از دو شبکه عصبی مصنوعی و شبکه عصبی با تابع‌های پایه برای روز وقوع زلزله در ایستگاه آزمون اهر را نشان می‌دهند. لازم به ذکر است که برای اختصار، فقط

جدول ۱. مقادیر VTEC به‌دست آمده از GPS و VTEC برآورد شده با شبکه عصبی مصنوعی سه‌لایه به همراه خطاهای مطلق و نسبی در ایستگاه آزمون

اهر (یازدهم اوت ۲۰۱۲)

Time (LT)	VTEC (GPS)	VTEC (MLP-ANN)	Relative Error (%)	Absolute Error (TECU)
۲	۲۸/۸۹۴۶	۲۷/۷۹۱۳	۳/۸۲	۱/۱۰
۴	۲۹/۶۸۹۷	۲۸/۲۶۴۹	۴/۸۰	۱/۴۲
۶	۲۹/۹۰۳۵	۲۹/۱۲۶۱	۲/۶۰	۰/۷۸
۸	۳۰/۱۲۳۶	۲۹/۷۸۸۸	۱/۱۱	۰/۳۳
۱۰	۳۰/۳۵۹۱	۲۹/۹۴۹۱	۱/۳۵	۰/۴۱
۱۲	۳۰/۸۴۹۷	۳۰/۰۵۹۵	۲/۵۶	۰/۷۹
۱۴	۳۱/۳۳۴۷	۳۱/۸۸۰۱	۱/۷۴	۰/۵۵
۱۶	۳۱/۱۱۴۷	۳۱/۳۰۴۲	۰/۶۱	۰/۱۹
۱۸	۲۹/۵۹۸۴	۲۸/۷۷۵۳	۲/۷۸	۰/۸۲
۲۰	۲۸/۹۶۴۱	۲۸/۶۹۵۱	۰/۹۳	۰/۲۷
۲۲	۲۸/۰۱۹۵	۲۷/۵۱۹۷	۱/۷۸	۰/۵۰

جدول ۲. مقادیر VTEC به‌دست آمده از GPS و VTEC برآورد شده با شبکه عصبی مصنوعی با تابع‌های پایه شعاعی به همراه خطاهای مطلق و نسبی در

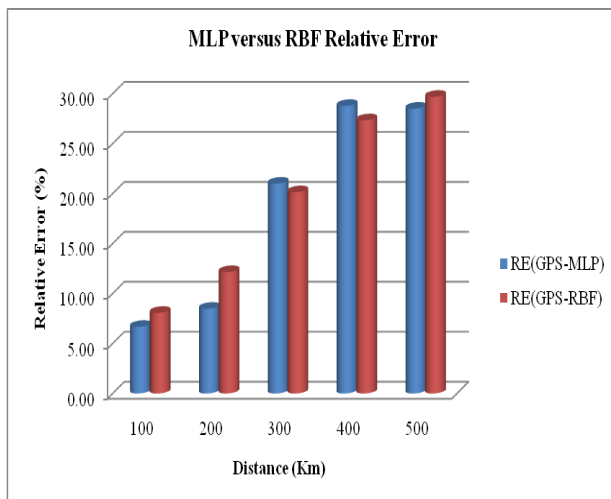
ایستگاه آزمون اهر (یازدهم اوت ۲۰۱۲)

Time (LT)	VTEC (GPS)	VTEC (RBFNN)	Relative Error (%)	Absolute Error (TECU)
۲	۲۸/۸۹۴۶	۲۷/۳۳۱۸	۵/۴۱	۱/۵۶
۴	۲۹/۶۸۹۷	۲۸/۴۲۸۷	۴/۲۵	۱/۲۶
۶	۲۹/۹۰۳۵	۲۹/۰۵۷۹	۲/۸۳	۰/۸۵
۸	۳۰/۱۲۳۶	۲۹/۲۰۹۷	۳/۰۳	۰/۹۱
۱۰	۳۰/۳۵۹۱	۲۹/۶۱۸۹	۲/۴۴	۰/۷۴
۱۲	۳۰/۸۴۹۷	۲۹/۹۷۶۱	۲/۸۳	۰/۸۷
۱۴	۳۱/۳۳۴۷	۳۱/۲۵۶۱	۰/۲۵	۰/۰۸
۱۶	۳۱/۱۱۴۷	۳۰/۸۹۱۶	۰/۷۲	۰/۲۲
۱۸	۲۹/۵۹۸۴	۲۹/۰۱۶۴	۱/۹۷	۰/۵۸
۲۰	۲۸/۹۶۴۱	۲۸/۶۳۹۷	۱/۱۲	۰/۳۲
۲۲	۲۸/۰۱۹۵	۲۷/۴۱۳۵	۲/۱۶	۰/۶۱


برای این ایستگاه می‌تواند قابل تفسیر باشد.

شکل‌های ۵ و ۶ نشان‌دهنده تغییرات زمانی مقدار VTEC به‌دست آمده از دو مدل شبکه عصبی در موقعیت جغرافیایی زمین‌لرزه است. با توجه به هر دو شکل می‌توان دریافت که در زمان‌های نزدیک به زلزله و پس از آن تغییرات محسوسی در مقدار VTEC دیده می‌شود. این زمان‌ها در هر دو شکل با رنگ‌های متفاوتی نشان داده شده است. مقدار این تغییرات حدود ۱/۶ TECU در هر دو مدل شبکه عصبی سه‌لایه و شبکه عصبی با تابع‌های پایه شعاعی است.

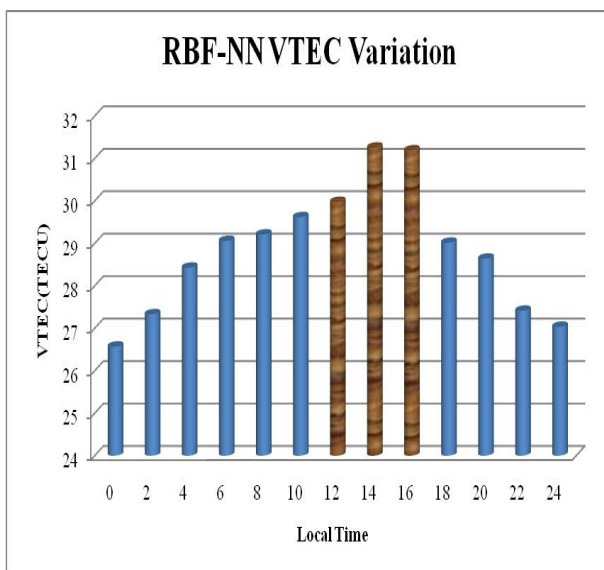
با توجه به نتایج حاصل از شکل ۴ می‌توان به‌وضوح مشاهده کرد که مقادیر خطای نسبی برای هر دو مدل شبکه عصبی با افزایش فاصله نقطه موردنظر از محدوده ایستگاه‌های مورد استفاده در مرحله آموزش، افزایش می‌یابد. البته بررسی این موضوع مربوط به مباحث برون‌یابی به کمک شبکه‌های عصبی مصنوعی است و در این مقاله به این موضوع پرداخته نشده است. علت مطرح کردن این موضوع در این قسمت، آن است که ایستگاه آزمون میاندوآب، خارج از محدوده ایستگاه‌های مورد استفاده در مرحله آموزش است و نتایج به‌دست آمده




شکل ۴. چگونگی تغییرات خطای نسبی برای روش‌های شبکه عصبی چندلایه و شبکه عصبی مصنوعی با تابع‌های پایه شعاعی نسبت به فاصله از محدوده ایستگاه‌های مورد استفاده در آموزش شبکه



شکل ۵. چگونگی تغییرات زمانی مقدار VTEC در موقعیت جغرافیایی مرکز زمین لرزه به دست آمده از شبکه عصبی مصنوعی سه لایه (یازدهم اوت ۲۰۱۲)




شکل ۶. چگونگی تغییرات زمانی مقدار VTEC در موقعیت جغرافیایی مرکز زمین لرزه به دست آمده از شبکه عصبی مصنوعی با تابع‌های پایه شعاعی (یازدهم اوت ۲۰۱۲)




شکل ۷. مقایسه چگونگی تغییرات زمانی مقدار VTEC در موقعیت

جغرافیایی ایستگاه آزمون اهر؛ به‌دست آمده از GPS. شبکه عصبی مصنوعی سه‌لایه و شبکه عصبی با تابع‌های پایه شعاعی (یازدهم اوت ۲۰۱۲)



شکل ۸. مقایسه چگونگی تغییرات زمانی مقدار VTEC در موقعیت

جغرافیایی ایستگاه آزمون سلماس؛ به‌دست آمده از GPS. شبکه عصبی مصنوعی سه‌لایه و شبکه عصبی با تابع‌های پایه شعاعی (یازدهم اوت ۲۰۱۲)



شکل ۹. مقایسه چگونگی تغییرات زمانی مقدار VTEC در موقعیت

جغرافیایی ایستگاه آزمون میاندوآب؛ به‌دست آمده از GPS. شبکه عصبی مصنوعی سه‌لایه و شبکه عصبی با تابع‌های پایه شعاعی (یازدهم اوت ۲۰۱۲)

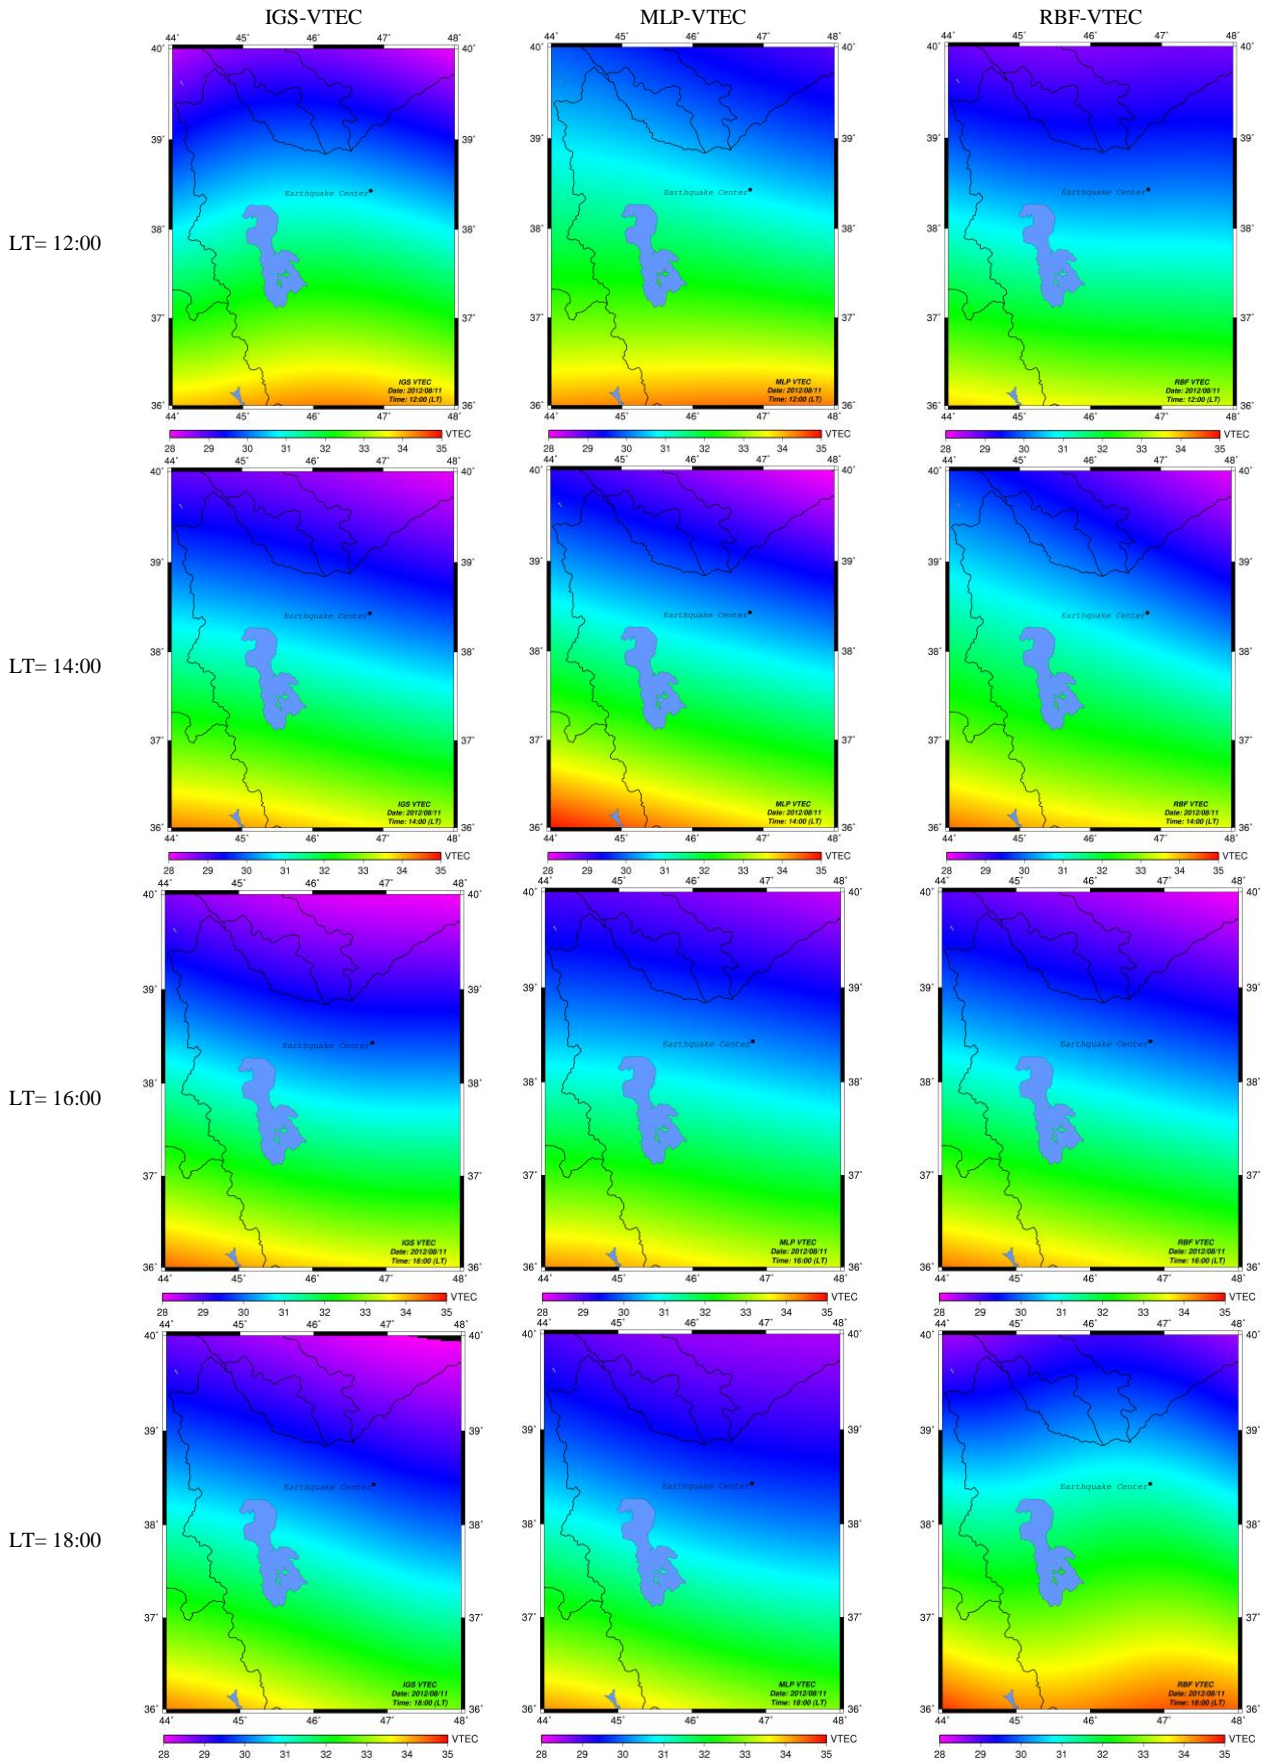
لازم به یادآوری است که با توجه به نتایج جدول‌های ۱ و ۲ و مقادیر خطای نسبی و مطلق محاسبه شده برای هر دو مدل، اظهارنظر در مورد اینکه مقدار تغییرات $1/6$ TECU مربوط به اثرات زلزله بوده است و خطاهای مربوط به مدل‌ها در آن دخالتی ندارد، نیازمند تحقیقات و بررسی‌های بیشتری است و همان‌طور که در بالا گفته شده، تمرکز اصلی این مقاله بر بررسی کارایی شبکه‌های عصبی مصنوعی در برآورد تغییرات زمانی مکانی یون‌سپهر است، نه بررسی اثر پدیده‌های ژئودینامیکی در تغییرات TEC.

شکل‌های ۷، ۸ و ۹ تغییرات زمانی (۲۴ ساعته)

مقدار VTEC را در محل ایستگاه‌های آزمون نشان می‌دهند. در هر سه شکل مقدار VTEC حاصل از GPS با مقادیر VTEC برآورد شده با شبکه عصبی مصنوعی سه‌لایه و نیز شبکه عصبی با تابع‌های پایه شعاعی مقایسه شده است.

با توجه به نتیجه به‌دست آمده از شکل ۷ می‌توان به این نکته اشاره کرد که مقادیر VTEC حاصل از شبکه عصبی سه‌لایه تا حدودی دقیق‌تر از مقادیر VTEC حاصل از شبکه عصبی با تابع‌های پایه شعاعی هستند.

مهم‌ترین نتیجه حاصل از سه شکل ۷، ۸ و ۹ این است که شبکه عصبی قابلیت بسیار زیادی در برآورد تغییرات زمانی یون‌سپهر دارد. پس از ارزیابی صحت نتایج به‌دست آمده از شبکه‌های عصبی مصنوعی، مقادیر VTEC در محدوده طول و عرض جغرافیایی شبکه مورد بررسی در چهار زمان ۱۲، ۱۴، ۱۶ و ۱۸ برآورد شده است. همچنین این مقادیر با نتایج حاصل از خروجی‌های شبکه جهانی IGS نیز مقایسه شده است. شکل ۱۰ نشان‌دهنده این نتایج است. با توجه به نتایج به‌دست آمده در این شکل می‌توان به‌وضوح مشاهده کرد که محتوای الکترونی کلی لایه یون‌سپهر دارای تغییرات زمانی و مکانی است.



شکل ۱۰. مقایسه چگونگی تغییرات زمانی مکانی مقدار VTEC در محدوده جغرافیایی شبکه مورد بررسی؛ به دست آمده از IGS، شبکه عصبی مصنوعی

سه لایه و شبکه عصبی با تابع های پایه شعاعی در زمان های ۱۲، ۱۴، ۱۶ و ۱۸ به وقت محلی (پازدهم اوت ۲۰۱۲)

۵. نتیجه‌گیری

زیادی دارند. از دیگر قابلیت‌های این مدل آن است که می‌توان از آن در مناطق با تعداد مشاهدات کم (تعداد ایستگاه‌های کم GPS در منطقه) در برآورد مقدار محتوای الکترونی کلی در جو بالای شبکه استفاده کرد. این مدل در مقایسه با مدل‌های توموگرافی و نیز مدل‌های مرجع جهانی یون‌سپهر و خروجی‌های شبکه جهانی IGS سرعت محاسباتی بیشتری دارد و همچنین تعداد محاسبات صورت گرفته در این روش به مراتب کمتر از روش‌های متداول دیگر است. البته باید به این نکته اشاره کرد که در صورت نبود داده‌های کافی در مرحله آموزش، ممکن است شبکه به نتایج نامطمئنی برسد. وجود مسئله برازش بیش از حد را نیز از جمله معایب این روش‌ها می‌توان در نظر گرفت. همچنین نبود عرضه مدلی تحلیلی براساس متغیرهای موردنظر، از دیگر نقاط ضعف مدل‌سازی با شبکه‌های عصبی مصنوعی است.

مراجع

- صیادی، ا.، ۱۳۸۷، آشنایی مقدماتی با شبکه‌های عصبی مصنوعی، دانشگاه صنعتی شریف.
- غفاری رزین، م. ر. و محمدزاده، ع.، ۱۳۹۳، مدل‌سازی منطقه‌ای TEC با استفاده از شبکه‌های عصبی مصنوعی و مدل چند جمله‌ای در ایران، م. علمی-پژوهشی علوم و فنون نقشه‌برداری، ۴(۳)، ۵۱-۶۰.
- غفاری رزین، م. ر. و مشهدی حسینعلی، م.، ۱۳۸۸، تعیین دانسیته الکترونی لایه یون‌سپهر در منطقه ایران با استفاده از تکنیک توموگرافی براساس مشاهدات GPS ایران سراسری، نشریه فناوری اطلاعات مکانی، شماره اول، ۱۲-۲۶.
- غفاری رزین، م. ر. و مشهدی حسینعلی، م.، ۱۳۹۰، مدل‌سازی ۳ بعدی تغییرات چگالی الکترونی یون‌سپهر در سه فصل مختلف با استفاده از مشاهدات GPS شبکه ژئودینامیک ایران، فصلنامه علمی-پژوهشی علوم و فناوری فضایی، ۴(۱ و ۲)، ۱۲-۱.
- Amerian, Y., Mashhadi Hossainali, M.,

در این مقاله از روش‌های شبکه عصبی مصنوعی چندلایه و شبکه عصبی مصنوعی با تابع‌های پایه شعاعی به همراه مشاهدات ۲۲ ایستگاه GPS موجود در منطقه آذربایجان، به منظور مدل‌سازی و درون‌یابی مقدار محتوای الکترونی کلی یون‌سپهر در راستای قائم استفاده شد. به علت اینکه هدف اصلی در این مقاله ارزیابی کارایی دو مدل شبکه عصبی چندلایه و شبکه عصبی با تابع‌های پایه شعاعی در برآورد زمانی مکانی مقدار VTEC بود، از داده‌های ۲۱ روز ماه اوت ۲۰۱۲ (مرداد ۱۳۹۱) در مدل‌سازی و آموزش شبکه‌های عصبی استفاده شد. مقادیر VTEC به دست آمده در محل ایستگاه‌های شبکه در بازه‌های زمانی یک‌ساعته در طول ۲۰ روز درحکم خروجی مطلوب شبکه‌های عصبی است و مقادیر طول و عرض جغرافیایی هر ایستگاه، ساعت مشاهده، شاخص فعالیت خورشیدی در آن روز و نیز شاخص فعالیت‌های مغناطیسی به منزله مقادیر ورودی برای مدل‌ها در نظر گرفته می‌شوند.

در آموزش هر دو مدل شبکه عصبی از روش پس‌انتشار خطا استفاده شده است. در هر دو روش معیار جذر خطای مربعی میانگین (RMSE) به منزله معیار توقف تکرار در نظر گرفته شد. همچنین تعداد نوروهای لایه پنهان در هر دو روش براساس آزمون و خطا و با در نظر گرفتن کمینه شدن مقدار RMSE تعیین شد. میانگین خطای نسبی تولید شده در نقطه آزمون هر دو مدل شبکه عصبی مصنوعی سه لایه ۱/۴۰ درصد و میانگین خطای نسبی به دست آمده از شبکه عصبی با تابع‌های پایه شعاعی ۱/۸۸ درصد محاسبه شد. نتایج هر دو مدل نشان‌دهنده قابلیت بسیار زیاد آنها در نشان دادن تغییرات زمانی مکانی یون‌سپهر است.

به منظور ارزیابی نتایج به دست آمده از این دو مدل، از خروجی‌های مدل جهانی IGS نیز استفاده شد. مقایسه صورت گرفته نشان‌دهنده این موضوع بود که مدل‌های شبکه عصبی در بیان رفتار فیزیکی یون‌سپهر قابلیت

Voosoghi, B. and Ghaffari Razin, M. R.,

- 2010, Tomographic reconstruction of the ionospheric electron density in term of wavelets, *Journal of Aerospace Science and Technology*, 7(1), 19-29.
- Amerian, Y., Hossainali, M. M. and Voosoghi, B., 2013, Regional improvement of IRI extracted ionospheric electron density by compactly supported base functions using GPS observations, *J. Atmos Sol Terr Phys.*, 92, 23-30, doi: 10.1016/j.jastp.2012.09.011.
- Bishop C M., 2005, *Neural Networks for Pattern Recognition*; Oxford University Press, New York, NY, 504p.
- Conway, A. J., Macpherson, K. P., Blacklaw, G. and Brown, J. C., 1998, A neural network prediction of solar cycle 23, *J. Geophys. Res.*, 103(A12), 29733-29742.
- Cander, R., 1998, Artificial neural network applications in ionospheric studies, *Annali di Geofisica*, 5-6.
- Ghaffari Razin, M. R., Voosoghi, B. and Mohammadzadeh, A., 2015, Efficiency of artificial neural networks in map of total electron content over Iran, *Acta Geod Geophys.*, doi: 10.1007/s40328-015-0143-3.
- Ghaffari Razin, M. R. and 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>.
- 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, 51(1), 95-111.
- Ghaffari Razin, M. R. and 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.
- Ghaffari Razin, M. R. and Voosoghi, B., 2016, 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>.
- Habarulema, J. B., McKinnell, L. A. and 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.
- Hernandez-Pajares, M., Juan, J. and Sanz, J., 1997, Neural network modelling of the ionospheric electron content at global scale using GPS, *Radio Sci.*, 32, 1081-1090.
- Haykin, S., 1994, *Neural Networks, a comprehensive Foundation*, Macmillan College Publishing Company, New York.
- 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.
- Leandro, R. F. and Santos, M. C., 2007, A neural network approach for regional vertical total electron content modelling, *Stud. Geophys. Geod.*, 51(2), 279-292.
- 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.
- Moody, J. and Darken, C., 1998, Fast learning in networks of locally-tuned processing units, *Neural Comput.*, 1(2), 281-294.
- McKinnell, L., 2002, A neural network based ionospheric model for the Bottomside electron density profile over Grahamstown South Africa, Ph.D. Thesis, Rhodes Université.
- Mars, P., Chen, J. R. and Nambiar, R., 1996, *Learning algorithms: theory and applications in signal processing, Control and Communications*, CRC Press, Boca Raton, Florida.
- Orus, R., 2005, Improvement of global ionospheric VTEC maps by using Kriging interpolation technique, *J. Atmos. Sol. Terr. Phys.*, 67, 1598-1609.
- Powell, M. J. D., 1987, Radial basis functions for multivariate interpolation: a review; in: *algorithms for approximation* (eds) Mason, J. and Cox, M., Clarendon Press, Oxford, 143-167.
- Rodrigo, F., Leandro, R. F., 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.
- Schaer, S., 1999, Mapping and predicting the Earth's ionosphere using the global positioning system, Ph.D. thesis, Astronomical Institute, University of Berne, Berne Switzerland.
- Seeber, G., 2003, *satellite geodesy: foundations. methods and applications*, Walter de Gruyter, Berlin and New York, 53.
- Svozil, D., KvasniEka, V. and Pospichal, J., 1997, Introduction to multi-layer feed-forward neural networks, *Chemometrics and Intelligent Laboratory Systems*, 39, 43-62.
- Sayin, I., Arikan, F. and Arikan, O., 2008, Regional TEC mapping with random field priors and Kriging, *Radio Sci.*, 43, RS5012, doi: 10.1029/2007RS003786.
- Sarma, A. and Mahdu, T., 2005, Modelling of foF2 using neural networks at an equatorial anomaly station. *Curr. Sci.*, 89(7), 1245-1247.
- Simpson, P. K., 1990, *Artificial neural systems:*

- foundations, paradigms, applications, and implementations, Pergamon Press, New York.
- Tulunay, E., Senalp, E. T., Radicella, S. M. and Tulunay, Y., 2006, Forecasting total electron content maps by neural network technique., Radio Sci. 41, doi: 10.1029/2005RS003285.
- Xenos, T. D., Kouris, S. S. and Casimiro, A., 2003, Time-dependent prediction degradation assessment of neural-networks-based TEC forecasting models, Nonlinear Proc. Geophys., 10, 585-587.
- Wielgosz, P., Brzezinska, D. and Kashani, I., 2003, Regional ionosphere mapping with Kriging and multiquadratic method, J. Global Pos. Syst., 2, 48-55.
- Yilmaz, A., Akdogan, K. E. and Gurun, M., 2009, Regional TEC mapping using neural networks, Radio Sci., 44, RS3007, doi: 10.1029/2008RS004049.
- Yeung, D. S., Cloete, I., Shi, D. and Ng, W. W. Y., 2010, Sensitivity analysis for neural networks; Springer-Verlag, Berlin Heidelberg, 86p.