



شبکه‌های عصبی مصنوعی در مدل سازی یونوسفر

صالح مافی^۱، یزدان عامریان^{۲*}

^۱دانش آموخته دانشکده مهندسی نقشه برداری دانشگاه صنعتی خواجه نصیرالدین طوسی
^۲استادیار دانشکده مهندسی نقشه برداری دانشگاه صنعتی خواجه نصیرالدین طوسی

چکیده :

در این مقاله از یک شبکه عصبی مصنوعی بازگشتی ۲ لایه با ۲۵ نورون در لایه مخفی جهت مدل سازی مقدار محتوای الکترونی لایه یونوسفر (TEC) استفاده شده است. به طور کلی برای مدل سازی TEC^۱ به شبکه عصبی پیشرفته ای نیاز داریم زیرا مقدار TEC تابعی از طول ژئودتیک، عرض ژئودتیک و زمان می باشد. در این جا منظور از زمان ساعت خاصی از روز است هر چند که این پارامتر می تواند به یک روز خاص از ایام سال هم اطلاق شود. علاوه بر این به دلیل تغییرات مقدار TEC نسبت به طول و عرض ژئودتیک بررسی این مسئله در حالت جهانی بسیار پیچیده است از این رو محدوده تغییرات طول و عرض به صورت محلی در نقاط شبکه اطراف ایران در نظر گرفته شده است. داده مورد استفاده مدل تک لایه TEC است که در تاریخ ۸ آوریل ۲۰۱۴ توسط سرویس بین المللی IGS منتشر شده است. تعداد نورون های لایه مخفی به صورت تجربی و به روش سعی و خطا و با در نظر گرفتن مینیمم خطای نسبی برای نتایج به دست آمده است که جدول آن را در بخش معرفی شبکه عصبی ملاحظه می کنید.

واژه‌های کلیدی : شبکه های عصبی مصنوعی^۱، تابع فعال سازی^۱، محتوای الکترونی یونوسفر، پس انتشار خطا^۱، GPS



۱- مقدمه

به طور کلی تمامی اندازه گیری های میدانی با خطا همراه هستند. این خطاها به دلایل مختلف و از منابع خطای مختلف ناشی می شوند. در یک تقسیم بندی کلی خطاها را به سه دسته خطاهای^۱ فاحش، خطاهای سیستماتیک^۲ و خطاهای تصادفی^۳ طبقه بندی می کنند. خطاهای فاحش یا اشتباهات باید قبل از انجام هر گونه عملیات محاسباتی از مجموعه مشاهدات حذف شوند. خطاهای سیستماتیک هم به دلیل رفتار منظم آن ها قابل مدلسازی هستند. بنابراین تنها خطاهایی که بر روی مشاهدات باقی می ماند، خطاهای تصادفی هستند که رفتار آن ها را نمی توان مدل کرد. مقدار این خطاها با روش های آماری مانند روش کمترین مربعات تعدیل می شوند. از آن جایی که مشاهدات GPS در یک محیط فیزیکی به انجام می رسند بنابراین اندازه گیری های انجام شده در این سیستم نیز عاری از این گونه خطاها نیستند [۹]. خطای تروپوسفری، شکست امواج در لایه یونوسفر، خطاهای ساعت ماهواره و گیرنده و خطای چند مسیری شدن از جمله منابع خطای مهم در این سیستم به شمار می آیند. در این مقاله به بررسی ویژگی های لایه یونوسفر و تاثیرات آن بر سیگنال های GPS می پردازیم.

بعد از حذف اثر SA^۴ در حال حاضر خطای یونوسفری بزرگ ترین منبع خطا در تعیین موقعیت و ناوبری با GPS به شمار می آید. لایه یونوسفر از دو جهت بر سیگنال های GPS تاثیر می گذارد. اول این که به دلیل وجود الکترون های آزاد در این لایه میدان های الکتریکی و مغناطیسی سیگنال های GPS تحت تاثیر قرار گرفته و مسیر آن ها منحرف می شود. ثانياً به دلیل داشتن یک محیط مادی سرعت انتشار امواج در این لایه کاهش می یابد که به آن تاخیر یونوسفری می گویند. مقدار خطای یونوسفری به شدت متغییر است و به فاکتورهای مختلفی مانند زمان روز، عرض ژئودتیک، فعالیت های خورشیدی و تغییرات فصلی بستگی دارد [۱، ۲، ۳]. مقدار این خطا با مقدار محتویات الکترونی (TEC) لایه یونوسفر متناسب است. TEC به صورت تعداد الکترون های آزاد در ستونی با سطح مقطع یک متر مربع در مسیر حرکت سیگنال در لایه یونوسفر تعریف می شود. این پارامتر، عددی است که به مسیر مایل سیگنال در راستای زینت محلی مرتبط است و تابعی از زاویه ارتفاعی ماهواره می باشد. در ژئودزی ماهواره ای از گیرنده های مختلفی برای دریافت امواج GPS استفاده می شود. این گیرنده ها به سه دسته گیرنده های تک فرکانسه، دو فرکانسه و چند فرکانسه تقسیم می شوند. در گیرنده های تک فرکانسه به دلیل این که از یک نوع فرکانس استفاده می شود، منابع خطای مختلف به ویژه خطای یونوسفری به شدت در تعیین موقعیت با این گیرنده ها تاثیر گذارند. از این رو برای رسیدن به دقت های تعیین موقعیت مناسب با این گیرنده ها باید تاثیر هر کدام از این منابع را به کمک روش های ریاضی و تجربی مدل کرده و تاثیر آن ها را از روی اندازه گیری ها حذف و یا کاهش دهیم. اما در گیرنده های دو یا چند فرکانسه به دلیل استفاده از فرکانس های مختلف تاثیر هر یک از این منابع خطا با ترکیب مختلف مشاهدات مدلسازی می شوند [۴، ۳]. بنابراین برای حذف و یا کاهش منابع خطای سیستماتیک بر روی مشاهدات یک گیرنده تک فرکانسه نیاز به مدل های ریاضی داریم. در این مدل ها مقدار خطا به صورت تابعی از پارامترهای فیزیکی لایه مورد نظر محاسبه می شود. برای مثال برای محاسبه اثر یونوسفری در یک ایستگاه لازم است که رفتار TEC را در آن ایستگاه بدانیم [۵، ۴، ۳]. در این مقاله هدف اصلی برآورد مقدار TEC با استفاده از یک شبکه عصبی مصنوعی است. شبکه عصبی که در این جا استفاده شده است یک شبکه عصبی جریان مستقیم است که به صورت پس انتشار وزن ها و بایاس های خود را به هنگام سازی می کند. در بخش ۲ توضیح مختصری درباره محاسبه TEC از مشاهدات گیرنده های دو فرکانسه ارائه می شود، بخش ۳ به معرفی شبکه های عصبی مصنوعی و کاربردهای آن ها اختصاص داده شده است و در نهایت در بخش ۴ هم به آنالیز و تحلیل نتایج حاصل از شبکه عصبی و دقت آن می پردازیم.

¹ -blunders

² -systematic errors

³ -random errors

⁴ -Selective Availability



۲- محاسبه TEC از مشاهدات گیرنده های دو فرکانسه

گیرنده های دو فرکانسه GPS مشاهدات کد و فاز موج حامل ($P_i, \Phi_i (i = 1, 2)$) را در باند L و با فرکانس های $L_1 (1575.42MHz)$ و $L_2 (1227.60MHz)$ دریافت می کنند. مدل ریاضی این مشاهدات که ویژگی های هندسی و فیزیکی فضای اندازه گیری را در بردارند عبارتست از [۲]:

فرکانس L_1 :

$$P_1 = \rho + c(dt - dT) + d_{orb} + d_{trop} + I + b_{P_1} - B_{P_1} + d_{mult/P_1} + \varepsilon(P_1) \quad (1)$$

$$\Phi_1 = \rho + c(dt - dT) + \lambda_1 N_1 + d_{orb} + d_{trop} - I + b_{\Phi_1} - B_{\Phi_1} + d_{mult/\Phi_1} + \varepsilon(\Phi_1) \quad (2)$$

فرکانس L_2 :

$$P_2 = \rho + c(dt - dT) + d_{orb} + d_{trop} + \gamma I + b_{P_2} - B_{P_2} + d_{mult/P_2} + \varepsilon(P_2) \quad (3)$$

$$\Phi_2 = \rho + c(dt - dT) + \lambda_2 N_2 + d_{orb} + d_{trop} - \gamma I + b_{\Phi_2} - B_{\Phi_2} + d_{mult/\Phi_2} + \varepsilon(\Phi_2) \quad (4)$$

که در آن:

$$I = 40.3 \frac{TEC}{f_i^2} \quad (5)$$

ρ فاصله هندسی میان گیرنده و ماهواره، c سرعت نور در خلاء بر حسب m/s ، dt خطای ساعت ماهواره نسبت به زمان GPS، dT خطای ساعت گیرنده نسبت به زمان GPS، d_{orb} خطای مدار ماهواره بر حسب متر، λ_i طول موج سیگنال L_i بر حسب متر، N_i ابهام فاز، d_{trop} تاخیر تروپوسفری به متر، I پارامتر تاخیر یونسفری، d_{mult} اثر خطای چند مسیری به متر، b_{P_i} و b_{Φ_i} تاخیر ابزاری ماهواره روی فرکانس های L_1 و L_2 ، B_{P_i} و B_{Φ_i} تاخیر ابزاری گیرنده روی فرکانس های L_1 و L_2 به متر، $f_1 = 1575.42MHz$ ، $f_2 = 1227.60MHz$ و بالاخره ε نویز اندازه گیری ها بر حسب متر می باشد. با استفاده از مشاهدات فاز موج حامل در هر دو فرکانس L_1 و L_2 می توان کمیت TEC را به صورت زیر محاسبه کرد [۱۰]:

$$TEC_\phi = \frac{f_1^2 [(\lambda_1 \Phi_1 - \lambda_2 \Phi_2) - (\lambda_1 N_1 - \lambda_2 N_2) - b_i - b^P]}{40.3(\gamma - 1)} \quad (6)$$

که در این رابطه:

$$\gamma = \left(\frac{f_1}{f_2}\right)^2 = \left(\frac{77}{60}\right)^2 \quad (7)$$



همان گونه که مشاهده می شود با استفاده از فرکانس های دریافت شده توسط گیرنده های دو فرکانسه می توان مقدار TEC را به کمک آن ها محاسبه کرد. برای به دست آوردن مقدار محتوای الکترونی یونوسفر در راستای زینت می توان از تابع تصویر استفاده کرد [۲]:

$$VTEC = M \times TEC_{SM,N} \quad (8)$$

که در این رابطه M تابع تصویر است که به صورت زیر محاسبه می شود:

$$M = \frac{1}{\sin(elev)} \quad (9)$$

که در رابطه ۹، $elev$ زاویه ارتفاعی ماهواره می باشد.

این روابط بیان می کنند که مقدار TEC همواره در تعیین موقعیت به صورت یک منبع خطای سیستماتیک رفتار می کند. مقادیر طول و عرض ژئودتیک به همراه زمان روز پارامترهای ورودی به شبکه عصبی هستند و مقادیر VTEC محاسبه شده از رابطه ۸ به عنوان خروجی شبکه در نظر گرفته می شوند. پس از مدلسازی می توانیم مقدار VTEC را در هر موقعیت و زمان دلخواهی در محدود منطقه تعریف شده، پیش بینی کنیم.

۳- شبکه های عصبی مصنوعی

توسعه و پیشرفت شبکه های عصبی مصنوعی تقریباً ۵۰ سال پیش با هدف مدلسازی نحوه یادگیری مغز انسان شروع شد و پیشرفت های سریع در محاسبات رقومی تحولات چشمگیری را در این رشته علمی به وجود آوردند.

شبکه های عصبی اساساً سیستم های پردازش اطلاعات هستند که بر اساس فرضیات زیر توسعه داده شده اند:

۱. پردازش اطلاعات در یک سری عناصر ساده ای به نام نورون صورت می گیرد.
 ۲. سیگنال ها بین نورون ها و از طریق مسیرهای ارتباطی (سیناپس ها) عبور داده می شوند.
 ۳. هر سیناپس دارای یک وزن مربوط به خود است که در یک شبکه عصبی، سیگنال عبوری در آن ضرب می شود.
 ۴. هر نورون از یک تابع فعالسازی (که معمولاً غیر خطی است) برای محاسبه پاسخ سیگنال ورودی استفاده می کند.
- یک شبکه عصبی به وسیله (۱) الگوی ارتباط بین نورون هایش (که معماری (architecture) آن نامیده می شود)، (۲) روش تعیین وزن ها در ارتباطات (که آموزش (algorithm training, learning) نامیده می شود) و (۳) تابع فعالسازی آن مشخص می شود [۶].

یک شبکه عصبی شامل تعداد زیادی از عناصر ساده پردازشی می باشد که نورون (neuron)، واحد (unit)، سلول (cell) یا نود (node) نامیده می شود. هر نورون به وسیله خطوط ارتباطی مستقیمی که هر کدام دارای وزن مشخصی هستند به سایر نورون ها مرتبط می شود [۶، ۷، ۸]. وزن ها اطلاعاتی را نمایش می دهند که باید برای هر شبکه استفاده شوند تا یک مسئله را حل کنند. شبکه های عصبی می توانند در طیف وسیعی از مسائل مانند ذخیره سازی و بازیابی داده ها یا الگوها، طبقه بندی الگوها، ایجاد نقشه های عمومی از الگوهای ورودی به الگوهای خروجی، دسته بندی الگوهای مشابه و پیدا کردن راه حل هایی برای بهینه سازی مسائل دارای قید، مورد استفاده قرار گیرند [۶].



هر نورون دارای یک وضعیت داخلی است که به آن فعالسازی یا سطح فعالیت نورون گفته می‌شود و تابعی از ورودی‌هایی است که آن نورون دریافت کرده است. به عنوان مثال، یک نورون فعالسازی خودش را به صورت یک سیگنال به سایر نورون‌ها ارسال می‌کند. در این جا لازم است که ذکر کنیم یک نورون در هر لحظه می‌تواند تنها یک سیگنال را ارسال کند، هرچند که آن سیگنال می‌تواند به سمت چندین نورون دیگر منتشر شود. اطلاعات ورودی برای هر لایه از طریق وزن‌های معرفی شده در یک پروسه سرشکنی تکراری محاسبه می‌شوند که به این مرحله، فرآیند آموزش^۵ شبکه عصبی گفته می‌شود. پس از مرحله فوق اطلاعات نهایی با کمک توابع فعالسازی برای لایه خروجی تولید می‌شوند.

۳-۱- تنظیم وزن‌ها و آموزش شبکه

علاوه بر معماری، روش تعیین مقادیر وزن‌ها (آموزش) یک وجه تمایز مهم بین شبکه‌های عصبی مختلف است که در این مقاله روش‌های آموزش نظارت شده^۶ و نظارت نشده^۷ را به طور خلاصه توضیح می‌دهیم. در روش نظارت شده، آموزش شبکه به وسیله معرفی دسته‌ای از بردارها یا الگوهای آموزشی انجام می‌شود که هر کدام از این بردارها به بردار خروجی تارگت مربوط می‌شوند. سپس وزن‌ها و بایاس‌های شبکه بر اساس یک الگوریتم یادگیری تنظیم می‌شوند. در روش نظارت شده معرفی داده‌های ورودی به شبکه عصبی به دو روش امکان پذیر است: ۱- روش ارائه یکجا^۸ و ۲- روش ارائه الگو^۹ [۱۱، ۱۲]. به عنوان مثال در شبکه‌های عصبی چند لایه پرسپترون از روش ارائه الگو به دلیل سرعت در پردازش و راحتی انجام محاسبات استفاده می‌شود. به منظور آموزش شبکه و اصلاح وزن‌ها تا رسیدن به یک خطای معنادار، روش‌های بسیار زیادی وجود دارد. یکی از معروف‌ترین و در عین حال ساده‌ترین این روش‌ها، الگوریتم پس انتشار خطا^{۱۰} می‌باشد. الگوریتم پس انتشار خطا در دو مرحله شبکه را آموزش می‌دهد. مرحله اول به صورت پیش رو^{۱۱} انجام می‌گیرد یعنی زمانی که داده‌های ورودی از لایه ورودی به سمت لایه خروجی حرکت می‌کنند. در این مرحله خروجی‌های به دست آمده از شبکه با داده‌های برچسب دار مقایسه شده و میزان خطا تعیین می‌گردد. مرحله بعد به صورت پس رو^{۱۲} انجام می‌گیرد. در این مرحله خطاها از لایه خروجی به سمت لایه ورودی حرکت داده می‌شوند و مجدداً وزن‌های ورودی تعدیل می‌شوند. این دو مرحله آنقدر تکرار می‌گردند تا این که شبکه به آستانه خطای مورد انتظار برای خروجی‌های نهایی برسد [۱۱، ۱۲، ۱۳]. یک شبکه عصبی آموزش دیده که یک مجموعه از بردارهای ورودی را به یک مجموعه متناظر از بردارهای خروجی نسبت می‌دهد یک حافظه رابط نامیده می‌شود؛ اگر بردار خروجی تارگت متفاوت از بردار ورودی باشد، در آن صورت شبکه مورد نظر را یک حافظه غیر رابط می‌نامند. بعد از آموزش، یک حافظه رابط می‌تواند الگوی ذخیره شده هنگام دریافت بردار ورودی را فراخوانی کند تا بردار خروجی متناظر به بردار ورودی را محاسبه کند. در آموزش نظارت نشده، شبکه عصبی بردارهای ورودی را با یکدیگر بدون استفاده از داده‌های آموزشی دسته بندی می‌کند. این روش اصطلاحاً به یادگیری ماشینی معروف است که وظیفه آن پیدا کردن تابعی است که ساختار مخفی داده‌های طبقه بندی نشده را بیان کند. در شکل ۱ نحوه عملکرد شبکه عصبی مورد استفاده را ملاحظه می‌کنید.

⁵ -Training Process

⁶ -supervised training

⁷ -unsupervised training

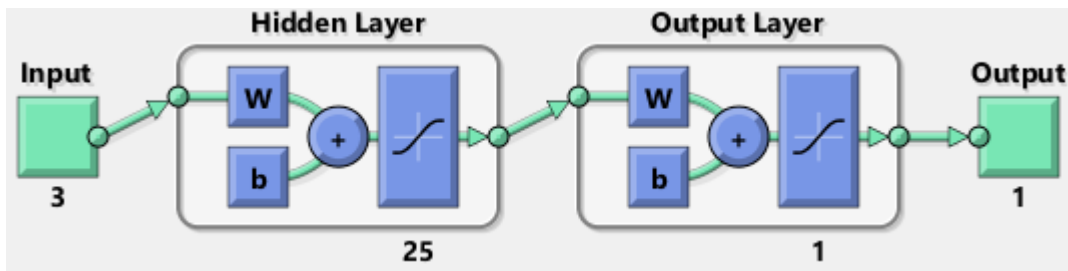
⁸ -Batch mode

⁹ -Pattern mode

¹⁰ -Error back propagation

¹¹ -Feed-forward

¹² -Feed-backward



شکل ۱: یک شبکه عصبی مصنوعی دو لایه یا یک لایه مخفی و تعداد ۲۵ نورون در آن لایه. این تصویر از واسط گرافیکی نرم افزار MATLAB گرفته شده است.

به سادگی از شکل (۱) می توان نتیجه گرفت که خروجی های نورون های لایه ورودی، ورودی نورون های لایه مخفی هستند و به همین ترتیب خروجی نورون های لایه مخفی به عنوان ورودی لایه خروجی در نظر گرفته می شوند. به عنوان مثال مقدار سیگنال منتشر شده از نورون لایه output در شکل ۱، از طریق رابطه زیر محاسبه می شود:


$$y_k = \varphi \left(\sum_{k=1}^l w_k \varphi \left(\sum_{i=1}^m (x_i \times w_{ki}) + b_k \right) + w_0 \right) \quad (10)$$

در این رابطه y_k نورون خروجی، φ تابع فعالسازی نورون، m تعداد نورون های لایه مخفی، x_i نشان دهنده پاسخ i -امین نورون لایه مخفی، w_{ki} وزن سیناپس بین نورن لایه مخفی و k -امین نورن لایه خروجی و b_k و w_0 هم به ترتیب بردارهای بایاس نورون های لایه مخفی و لایه خروجی هستند. تابع فعالسازی هم دارای انواع مختلفی است که معروف ترین آن ها توابع سیگموئید، سیگموئید دوقطبی و تانژانت هیپربولیک هستند. در زیر توضیح مختصری درباره انواع توابع فعالسازی ارائه می شود.

۳-۲- انواع توابع فعالسازی


۱. تابع همانی: از این تابع بیشتر برای دریافت داده ها در بخش ورودی شبکه عصبی استفاده می شود. معادله و شکل این تابع به صورت زیر است [۶]:

$$\forall x \in R \quad f(x) = x \quad (11)$$



شکل ۲: تابع همانی

۲. تابع پله ای: شبکه های تک لایه اغلب برای تبدیل ورودی های شبکه به مقادیر باینری و یا مقادیر ثابت ۱ و ۰- از یک تابع پله ای استفاده می کنند. در توابع پله ای از یک حد آستانه استفاده می شود که مقدار آن به کاربرد مورد نظر بستگی دارد [۶]. تابع پله ای باینری به تابع حد آستانه یا تابع هویساید نیز معروف است. از این توابع برای ساخت نورون هایی استفاده می شود که در تصمیمات طبقه بندی نقش دارند.




شکل ۳: تابع پله ای باینری

۳. توابع سیگموئید (منحنی های S شکل)، تابع لجستیک و تانژانت هیپربولیک مهم ترین و رایج ترین نوع توابع فعالسازی هستند. این توابع در شبکه های عصبی استفاده می شوند که با روش انتشار بازگشتی آموزش دیده اند دلیل این امر ارتباط ساده ای است که بین مقدار و مشتق این توابع در یک نقطه وجود دارد که باعث می شود بار محاسباتی در طول فرآیند آموزش کاهش یابد. تابع لجستیک، یک تابع سیگموئید با بردی از ۰ تا ۱ است که اغلب در شبکه هایی استفاده می شود که مقادیر خروجی مورد نظر یا باینری هستند و در بازه بین ۰ تا ۱ قرار می گیرند. جهت تاکید بر محدوده برد تابع، تابع لجستیک را سیگموئید باینری می نامیم که به آن تابع سیگموئید لجستیک نیز گفته می شود [۶]. این تابع در شکل ۴ به ازای دو مقدار از پارامتر σ نشان داده شده است.

$$f(x) = \frac{1}{1 + \exp(-\sigma x)}$$

$$f'(x) = \sigma f(x)[1 - f(x)].$$

شکل ۴: سیگموئید باینری. پارامترهای شیب $\sigma=1$ و $\sigma=3$


تابع سیگموئید می تواند با داشتن هر بردی که برای یک مسئله داده شده است، مقیاس گذاری شود. رایج ترین محدوده برای برد یک تابع سیگموئید از -۱ تا ۱ است؛ ما این تابع سیگموئید را سیگموئید دو قطبی می نامیم. این تابع در شکل ۵ به ازای $\sigma = 1$ نشان داده شده است.

سیگموئید دو قطبی: اگر $f(x)$ یک تابع لجستیک باشد در آن صورت برد این تابع در بازه ی ۰ تا ۱ قرار می گیرد. برای آن که برد تابع را به محدوده ی -۱ تا ۱ گسترش دهیم تابع $g(x)$ را به صورت زیر تعریف می کنیم.



$$g(x) = 2f(x) - 1 = \frac{2}{1 + \exp(-\sigma x)} - 1 = \frac{1 - \exp(-\sigma x)}{1 + \exp(-\sigma x)}$$

$$g'(x) = \frac{\sigma}{2} [1 + g(x)][1 - g(x)].$$



شکل ۵: تابع سیگموئید دو قطبی

سیگموئید دو قطبی رابطه نزدیکی با تانژانت هیپربولیک دارد که از آن نیز اغلب زمانی که محدوده خروجی مورد نظر در بازه -1 تا 1 باشد به عنوان تابع فعالسازی استفاده می شود. ارتباط بین این دو تابع را به ازای $\sigma=1$ نشان می دهیم [۶].

داریم:

$$g(x) = \frac{1 - \exp(-x)}{1 + \exp(-x)} \quad (12)$$

تابع تانژانت هیپربولیک نیز به صورت زیر است:

$$\tanh(x) = h(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} = \frac{1 - \exp(-2x)}{1 + \exp(-2x)} = g(2x). \quad (13)$$

از طریق رابطه به دست آمده ارتباط بین تابع سیگموئید دو قطبی و تابع تانژانت هیپربولیک به دست می آید. مشتق تابع تانژانت هیپربولیک به صورت زیر است.

$$h'(x) = [1 + h(x)][1 - h(x)]. \quad (14)$$

همانطور که ملاحظه می شود ارتباط ساده ای بین مقدار تابع و مقدار مشتق تابع در یک نقطه وجود دارد که این امر بار محاسباتی را در شبکه های عصبی به شدت کاهش می دهد.

۴- آنالیز نتایج

بر اساس آمار و اطلاعات بیشترین عرض ژئودتیک ایران مربوط به مرکز استان آذربایجان شرقی (۳۸.۰۵۲۴۶۷۵) و کمترین آن مربوط به مرکز استان هرمزگان (۲۷.۱۸۳۳۳۳۳) است. همچنین بیشترین طول ژئودتیک مربوط به استان سیستان و بلوچستان (۶۰.۸۵۳۶۴۷۰) و کمترین آن مربوط به استان آذربایجان غربی (۴۵.۴۶۵۴۸۷) است.



شبکه جهانی که توسط سرویس بین‌المللی IGS برای نمایش مقدار TEC طراحی شده است، از عرض‌های ۸۷.۵- تا ۸۷.۵ و طول‌های ۱۸۰- تا ۱۸۰ را در بر می‌گیرد. فاصله بین رئوس شبکه در راستای تغییرات عرضی ۲.۵ درجه و در راستای تغییرات طولی ۵ درجه است. از این رو با توجه به مقادیر ماکزیمم و مینیمم طول و عرض ژئودتیک ایران، به منظور تعریف یک شبکه محلی از بازه‌های طولی و عرضی زیر استفاده می‌کنیم.

$$\varphi_{min} = 25; \quad \varphi_{max} = 40; \quad \lambda_{min} = 45; \quad \lambda_{max} = 65$$

۴-۱- تعیین پارامترهای بهینه شبکه عصبی مصنوعی

برای آموزش شبکه عصبی ابتدا پارامترهای شبکه را به صورت دلخواه انتخاب می‌کنیم. تعداد لایه‌های مخفی شبکه عصبی را با توجه به این که مدل‌سازی به صورت محلی صورت می‌گیرد، برابر ۱ در نظر می‌گیریم. تعداد نورون‌های موجود در لایه مخفی، نرخ یادگیری شبکه، تابع فعال‌سازی لایه مخفی و تابع انتقال لایه خروجی با سعی و خطا مشخص می‌شوند. جدول ۱ روش تعیین پارامترهای بهینه برای آموزش شبکه عصبی را نشان می‌دهد. لازم به ذکر است که تمامی این مراحل به صورت تجربی انجام شده‌اند.

جدول ۱: پارامترهای شبکه عصبی در طی آموزش‌های مختلف

Name of network	Number of layers	Number of neurons in hidden layer	Learning rate	Activation function of hidden layer	Activation function of output layer	Training time	RMSE
Network 1	۲	۱۵	۰.۰۰۱	LOGSIG	PURELIN	۰.۲،۴،۶،۸،۱۰،۱۲،۱۴،۱۶،۱۸	TECU۳.۲۶۰
Network 2	۲	۱۲	۰.۰۰۱	LOGSIG	PURELIN	۰.۲،۴،۶،۸،۱۰،۱۲،۱۴،۱۶،۱۸	TECU۲.۵۷۳
Network 3	۲	۱۵	۰.۰۱	LOGSIG	PURELIN	۰.۲،۴،۶،۸،۱۰،۱۲،۱۴،۱۶،۱۸	TECU۳.۲۷۲
Network 4	۲	۲۵	۰.۰۱	LOGSIG	PURELIN	۰.۲،۴،۶،۸،۱۰،۱۲،۱۴،۱۶،۱۸	TECU۳.۷۶۷
Network 5	۲	۱۵	۰.۰۰۱	TANSIG	PURELIN	۰.۲،۴،۶،۸،۱۰،۱۲،۱۴،۱۶،۱۸	TECU۳.۸۱۲
Network 6	۲	۲۰	۰.۰۰۱	LOGSIG	PURELIN	۰.۲،۴،۶،۸،۱۰،۱۲،۱۴،۱۶،۱۸	TECU۰.۹۵۸

در جدول ۱ توابع PURELIN، LOGSIG و TANSIG به ترتیب توابع همانی، لجستیک و تانژانت هیپربولیک می‌باشند. به طور کلی برای تعیین پارامترهای بهینه یک شبکه عصبی قاعده و قانون کلی وجود ندارد. تنها یک سری قوانین تجربی برای آموزش بهینه یک شبکه عصبی مطرح شده است. به عنوان مثال به صورت تجربی ثابت شده است که اگر برای لایه‌های مخفی از تابع تانژانت هیپربولیک و برای لایه خروجی از تابع همانی استفاده کنیم سرعت یادگیری شبکه عصبی افزایش می‌یابد. تابع فعال‌سازی یک شبکه عصبی پارامتر مهمی است و در دقت نهایی شبکه به شدت تاثیر گذار است. برای محاسبه دقت یک شبکه آموزش دیده به داده‌های تست نیازمندیم. داده‌های تست داده‌هایی هستند که همانند داده‌های آموزشی دارای ورودی و خروجی‌اند. با توجه به این که شبکه از قبل آموزش دیده است (وزن‌ها و بایاس‌های شبکه محاسبه شده‌اند)، می‌توانیم ورودی‌های آزمایشی را به شبکه عصبی معرفی کنیم که در نهایت شبکه به کمک وزن‌ها و بایاس‌های محاسبه شده یک بردار خروجی تولید می‌کند. با مقایسه خروجی‌های تولید شده با خروجی‌های آزمایشی که از قبل به شبکه معرفی کرده بودیم، بردار خطای شبکه به صورت جداگانه محاسبه می‌شود. در نهایت به کمک این بردار و با استفاده از رابطه ۱۵ مقدار RMSE محاسبه می‌شود.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}} \quad (15)$$

پس از آموزش شبکه و رسیدن به خطای میانگین کمتر از ۱ TECU جهت ارزیابی نحوه عملکرد شبکه عصبی داده‌های زیر را جهت پیش‌بینی به شبکه معرفی می‌کنیم.

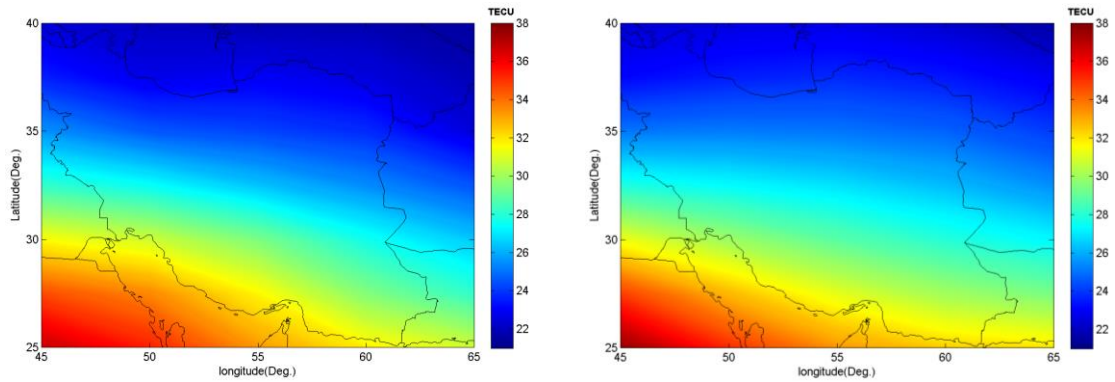


خروجی های TEC محاسبه شده توسط شبکه عصبی در ساعت های ۲۰ و ۲۲ و مقایسه آن ها با مقادیر منتشر شده توسط سرویس IGS. در جدول ۲ این مقایسه را به صورت عددی ملاحظه می کنید.

جدول ۲: مقایسه مقدار TEC پیش بینی شده و محاسبه شده در ساعت های ۲۰ و ۲۲

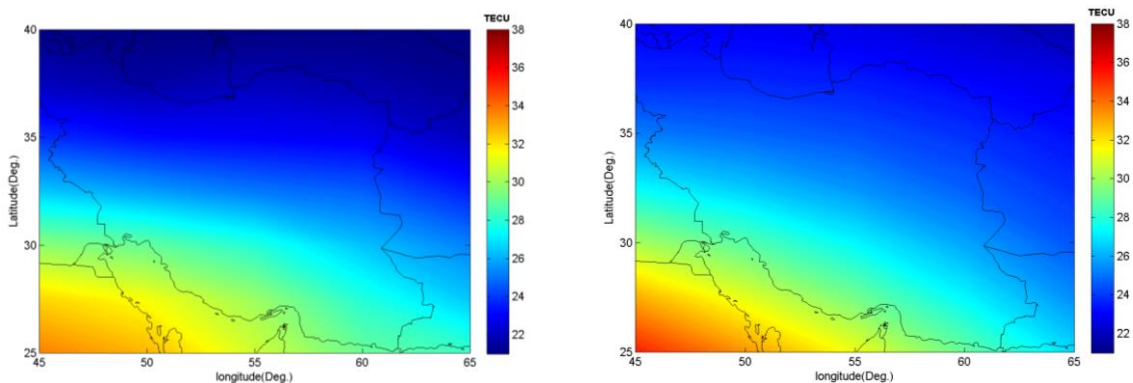
Geodetic Latitude	Geodetic Longitude	IGS TEC (Time:20)	NN TEC (Time:20)	Delta TEC (Time:20)	IGS TEC (Time:22)	NN TEC (Time:22)	Delta TEC (Time:22)
۴۰	۴۵	۲۲.۴	۲۲.۴۸۸	۰.۰۸۸	۲۳.۰	۲۱.۰۹۰	-۱.۹۱
۴۰	۵۰	۲۲.۶	۲۲.۰۴۰	-۰.۵۶	۲۲.۹	۲۰.۹۴۰	-۱.۹۶
۴۰	۵۵	۲۲.۷	۲۱.۸۱۸	-۰.۸۸۲	۲۲.۷	۲۰.۹۷۷	-۱.۷۲۳
۴۰	۶۰	۲۲.۳	۲۱.۸۰۷	-۰.۴۹۳	۲۲.۲	۲۱.۰۴۳	-۱.۱۵۷
۴۰	۶۵	۲۱.۶	۲۱.۵۱۲	-۰.۰۸۸	۲۱.۷	۲۰.۸۴۷	-۰.۸۵۳
۳۷.۵	۴۵	۲۳.۲	۲۳.۵۹۸	۰.۳۹۸	۲۳.۷	۲۲.۰۱۱	-۱.۶۸۹
۳۷.۵	۵۰	۲۳.۶	۲۲.۷۶۴	-۰.۸۳۶	۲۳.۷	۲۱.۵۸۷	-۲.۱۱۳
۳۷.۵	۵۵	۲۳.۸	۲۲.۹۶۷	-۰.۸۳۳	۲۳.۵	۲۱.۹۶۵	-۱.۵۳۵
۳۷.۵	۶۰	۲۳.۵	۲۲.۵۹۵	-۰.۹۰۵	۲۳.۱	۲۱.۶۹۳	-۱.۴۰۷
۳۷.۵	۶۵	۲۲.۹	۲۱.۹۳۲	-۰.۹۶۸	۲۲.۷	۲۱.۳۲۸	-۱.۳۷۲
۳۵	۴۵	۲۵.۱	۲۵.۵۸۷	۰.۴۸۷	۲۵.۲	۲۳.۸۹۴	-۱.۳۰۶
۳۵	۵۰	۲۵.۲	۲۴.۵۸۴	-۰.۶۱۶	۲۴.۸	۲۳.۲۶۵	-۱.۵۳۵
۳۵	۵۵	۲۵.۱	۲۴.۲۵۳	-۰.۸۴۷	۲۴.۴	۲۳.۰۶۸	-۱.۳۳۲
۳۵	۶۰	۲۴.۸	۲۳.۸۳۹	-۰.۹۶۱	۲۳.۹	۲۲.۸۶۴	-۱.۰۳۶
۳۵	۶۵	۲۴.۱	۲۲.۵۴۹	-۱.۵۵۱	۲۳.۳	۲۲.۰۱۳	-۱.۲۸۷
۳۲.۵	۴۵	۲۷.۹	۲۸.۲۲۲	۰.۳۲۲	۲۷.۴	۲۶.۴۹۷	-۰.۹۰۳
۳۲.۵	۵۰	۲۷.۴	۲۷.۴۸۱	۰.۰۸۱	۲۶.۵	۲۵.۷۹۵	-۰.۷۰۵
۳۲.۵	۵۵	۲۶.۹	۲۶.۴۰۲	-۰.۴۹۸	۲۵.۶	۲۵.۱۴۰	-۰.۴۶
۳۲.۵	۶۰	۲۶.۳	۲۵.۴۸۰	-۰.۸۲	۲۴.۷	۲۴.۷۱۹	۰.۰۱۹
۳۲.۵	۶۵	۲۵.۵	۲۴.۵۰۴	-۰.۹۹۶	۲۳.۹	۲۳.۵۹۱	-۰.۳۰۹

در جدول ۲ نمونه هایی از TEC های پیش بینی شده توسط شبکه عصبی برای زمان های ۲۰ و ۲۲ و TEC های محاسبه شده توسط شبکه IGS آورده شده است. به کمک این مقادیر می توانیم مقدار عملکرد شبکه را در زمان های مختلف اندازه گیری کنیم. به طور کلی مقدار خطای میانگین (RMSE) برای تخمین های ساعت ۲۰ برابر 0.7233 TECU و برای ساعت ۲۲ برابر 1.1449 TECU است. مقدار کل میانگین خطا هم همانگونه که در جدول ۱ بیان شد برابر 0.9576 TECU است. در شکل های (۶) و (۷) این مقایسه ها را به صورت تصویری ملاحظه می کنید.



شکل ۶: TEC محاسبه شده توسط IGS (تصویر راست) و TEC پیش بینی شده توسط شبکه عصبی (تصویر چپ) در ساعت

۲۰



شکل ۷: TEC محاسبه شده توسط IGS (تصویر راست) و TEC پیش بینی شده توسط شبکه عصبی (تصویر چپ) در ساعت

۲۲

۵- نتیجه گیری

همان گونه که در بخش ۳ بیان شد، شبکه های عصبی در واقع مدل های ریاضی پردازش اطلاعات هستند. استفاده از این شبکه ها به نوع مسئله تعریف شده بستگی دارد. داده هایی که در این تحقیق مورد استفاده قرار گرفتند، داده های محلی بودند و شبکه عصبی که از آن برای پیش بینی TEC استفاده شد یک شبکه جریان مستقیم با یک لایه مخفی بود. تعداد نورون ها، نرخ یادگیری شبکه و سایر پارامترهای آن به صورت تجربی و با روش سعی و خطا تعریف شدند.

از شبکه های عصبی می توان برای پیش بینی های پیچیده تر نیز استفاده کرد. به عنوان مثال اگر بخواهیم رفتار TEC را به صورت جهانی بررسی کنیم، به شبکه عصبی پیشرفته تری نیاز داریم. معمولا برای پیش بینی های پیچیده تر، نوع شبکه عصبی را تغییر نمی دهند بلکه تعداد لایه های مخفی، نورون های موجود در هر لایه و نرخ یادگیری شبکه را مورد ارزیابی قرار می دهند. آموزش شبکه هایی که دارای چند لایه مخفی هستند بسیار پیچیده تر از شبکه هایی است که از یک لایه مخفی تشکیل شده اند. بنابراین برای افزایش سرعت پیش بینی لازم است که تا حد ممکن از تعریف شبکه های پیچیده صرف نظر کنیم.

به کمک شبکه عصبی می توان رفتار TEC را در بازه های زمانی چند روزه و یا حتی بازه های ماهیانه پیش بینی کرد. علاوه بر این می توانیم به روشی دیگر پارامترهای تاثیر گذار در رفتار TEC مانند طول و عرض ژئودتیک، میل و بعد خورشید، تاثیرات طوفان های ژئومغناطیسی و طوفان های خورشیدی را به کمک شبکه های ساده تر پیش بینی کنیم و در نهایت به کمک توابع ریاضی ارتباط آن ها را با TEC مدل کنیم.



RMSE های محاسبه شده برای ساعت های مختلف بیان می کنند که شبکه عصبی در پیش بینی TEC در ساعت ۲۰ نسبت به ساعت ۲۲ عملکرد بهتری داشته است. دلیل این امر را باید در رفتار متناوب TEC در ساعات مختلف روز جستجو کرد. رفتار TEC در ساعات ۰، ۲ و ۴ رفتاری نامنظم است. اما با طلوع خورشید و افزایش تدریجی شدت تشعشعات خورشیدی مقدار TEC شروع به افزایش می کند به گونه ای که در ساعت ۱۶ بعدازظهر به وقت گرینویچ به ماکزیمم مقدار خود می رسد. از ساعت ۱۶ به بعد TEC به تدریج شروع به کاهش می کند و در ساعات آینده شاهد افت نسبی آن خواهیم بود. از آن جایی که این افزایش و کاهش با آهنگ یکنواختی انجام نمی گیرد بنابراین برای پیش بینی دقیق TEC توسط شبکه عصبی باید یک دوره تناوب از تغییرات آن را به شبکه معرفی کنیم، در غیر این صورت مقادیر پیش بینی شده مقادیر مناسبی نخواهند بود.

مراجع

- [1] Gao Y Liao Z Liu Z (2002) Ionosphere Modeling Using Carrier Smoothed Ionosphere Observations from a Regional GPS Network. *Geomatica*, Vol. 56, No.2, pp. 97-106
- [2] Seeber G: *Satellite Geodesy (1993) , "Foundations, Methods and Application,"* Walter de Gruyter, Berlin and New -York, 531
- [3] Amerian Y Hossainali M Voosoghi B Ghaffari M R (2010) Tomographic Reconstruction of the Ionospheric Electron Density in term of Wavelets. *International Journal of Aerospace science and Technologie*
- [4] Feltens J Dow M (1996) ROUTINE PRODUCTION OF IONOSPHERE TEC MAPS AT ESOC – FIRST RESULTS
- [5] Komjathy, A. and Langley, R. B., (1996): An Assessment of Predicted and Measured Ionospheric Total Electron Content Using a Regional GPS Network. *Proceedings of the National Technical Meeting of the Institute of Navigation*, pp. 615 – 624.
- [6] Fausett, L., 1991. *Fundamentals of Neural Networks*, Chap1, 1-19
- [7] Fausett, L., 1991. *Fundamentals of Neural Networks*, Chap1, 27-28
- [8] Howard, D., and Beale, M., 1996. *Neural Network Toolbox, Neuron Model and Network Architectures*, 2-2(36)
- [9] Aly M. El-naggar., 2013. Artificial neural network as a model for ionospheric TEC map to serve the single frequency receiver. 25 May 2013
- [10] Zhizhao liu (2004) Ionospheric Tomographic Modeling, UCGE Reports, Number 20198, University of CALGARY,
- [11] Mars, P., J.R. Chen, R. Nambiar (1996): *Learning Algorithms: Theory and Applications in Signal Processing, Control and Communications*, CRC Press, Boca Raton, Florida.
- [12] Cander. R (1998): Artificial neural network applications in ionospheric studies, *Annali di Geofisica*, Vol.5 – 6,
- [13] Zaletnyik, P (2002). COORDINATE TRANSFORMATION WITH NEURAL NETWORKS AND WITH POLYNOMIALS IN HUNGARY, Budapest University of Technology and Economics.