

مدل سازی سری های زمانی تغییرات محتوای الکترون کلی یونسفر با بکارگیری روش عددی سیستم استنتاج عصبی-فازی سازگار مطالعه خاص: ایستگاه دائمی GPS تهران

رسول فیضی^۱، بهزاد وثوقی^۲، میر رضا غفاری رزین^{۳*}

^۱ دانشجوی کارشناسی ارشد ژئودزی - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
rasoul.feizi72@email.kntu.ac.ir

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

^۳ استادیار گروه مهندسی عمران و نقشه برداری - دانشگاه صنعتی اراک
mr.ghafari@arakut.ac.ir

(تاریخ دریافت تیر ۱۳۹۷، تاریخ تصویب دی ۱۳۹۷)

چکیده

به دلیل خاصیت پاشندگی لایه یونسفر و اثر مخرب آن بر روی امواج عبوری، مدل سازی و پیش بینی رفتار این لایه از جو یکی از کاربردی ترین موضوعات مورد بحث در ژئودزی و مطالعات فضایی است. پارامتری که با استفاده از آن خصوصیات فیزیکی لایه یونسفر مورد مطالعه و بررسی قرار می گیرد، مقدار محتوای الکترون کلی (TEC) نامیده می شود. جهت مدل سازی پارامتر TEC روش های زیادی ارائه شده است که نیازمند عملیات محاسباتی زیاد بوده و در برخی مواقع از دقت کافی برای مدل سازی یونسفر برخوردار نیستند. در این مقاله از سیستم استنتاج عصبی-فازی سازگار (ANFIS) جهت پیش بینی تغییرات زمانی پارامتر TEC برای یک روز آینده استفاده شده است. یک سیستم استنتاج عصبی-فازی سازگار نوعی شبکه عصبی مصنوعی (ANN) است که براساس سیستم فازی تاکاگی-سوگنو (Takagi-Sugeno) می باشد. از آنجایی که این سیستم، شبکه های عصبی و مفاهیم منطق فازی را یکی می کند، می تواند از امکانات هر دو آنها در یک قاب بهره مند گردد. سیستم سازگار آن مطابق با مجموعه قوانین فازی اگر-آنگاه است که قابلیت یادگیری برای تقریب زدن توابع غیرخطی را دارا می باشد. در این مقاله مشاهدات ایستگاه دائمی GPS تهران با موقعیت ($51^{\circ}19'48''E, 35^{\circ}42'00''N$) در سه ماه (می، آوریل و دسامبر) مختلف از سال های (۲۰۱۱ و ۲۰۱۵) جهت آموزش شبکه ANFIS مورد استفاده قرار گرفته و پیش بینی برای روزهای (۳۰، ۳، ۶) در ماه های (می، دسامبر و آوریل) انجام گرفته است. این مشاهدات بگونه ای انتخاب شده است تا فعالیت های خورشیدی زیاد، متوسط و کم را شامل باشد. برای تعیین تاخیرهای زمانی بهینه جهت آموزش شبکه ANFIS طراحی شده از الگوریتم ژنتیک بهره گرفته شده است. جهت ارزیابی نتایج حاصل از سیستم استنتاج عصبی-فازی سازگار، مقادیر TEC حاصل از این سیستم با مقادیر TEC حاصل از شبکه عصبی مصنوعی (ANN) با الگوریتم آموزش لونیگ-مارکوارت، TEC حاصل از سیستم تعیین موقعیت جهانی GPS و همچنین TEC حاصل از مدل مرجع جهانی یونسفر IRI 2016 مورد مقایسه قرار گرفته است. میزان کمیت جذر خطای مربعی میانگین (RMSE) برای اختلاف بین مقادیر TEC پیش بینی شده توسط شبکه ANFIS و TEC حاصل از مشاهدات GPS در بیشترین حالت $4/6$ TECU و در کمترین حالت $2/1$ TECU بدست آمده است. مقدار RMSE برای شبکه عصبی مصنوعی در مقایسه با GPS در بیشترین و کمترین حالت بترتیب برابر با $5/06$ و $2/6$ TECU محاسبه شده است. در مدل مرجع جهانی یونسفر IRI2016 بیشترین و کمترین مقدار RMSE بترتیب برابر با $5/8$ و $4/3$ TECU تعیین شده است. نتایج حاصل نمایش دهنده قابلیت بالای شبکه ANFIS در مدل سازی سری زمانی یونسفر را دارد.

واژگان کلیدی: یونسفر، TEC، منطق فازی، GPS، شبکه عصبی، ANFIS

* نویسنده رابط

۱- مقدمه

جهانی مقدار TEC و چگالی الکترونی استفاده شده است. مدل سازی و پیش بینی کمیت TEC توسط محققان و با روش های مختلف مورد مطالعه قرار گرفته است. از جمله این روش ها می توان به روش های توابع Autocovariance، Autoregression و همچنین ARMA^{۱۰} اشاره کرد [۸]. این روش ها اغلب برای مدل های خطی کاربرد دارند. در حالی که رفتار پارامتر TEC یونسفر بصورت غیرخطی است. همچنین مدل های پیش بینی یونسفری با استفاده از شبکه های عصبی مصنوعی^{۱۱} توسعه یافته اند که جهت مدل سازی و آموزش نیازمند داده های ورودی بسیار زیادی هستند [۹].

منطق فازی^{۱۲} اولین بار در پی تنظیم نظریه مجموعه های فازی به وسیله پروفیسور لطفی زاده در صحنه محاسبات نو ظاهر شد. واژه fuzzy به معنای غیردقیق، ناواضح و مبهم (شناور) است [۱۰]. منطق فازی بیش از بیست سال پس از ۱۹۶۵ از درگاه دانشگاه ها به بیرون راه نیافت زیرا کمتر کسی معنای آنرا درک کرده بود. در اواسط دهه ۸۰ میلادی قرن گذشته صنعتگران ژاپنی معنا و ارزش صنعتی این علم را دریافته و منطق فازی را به کار گرفتند. اولین پروژه آنها طرح هدایت و کنترل تمام خودکار قطار زیرزمینی شهر سندای بود که توسط شرکت هیتاچی برنامه ریزی و ساخته شد. نتیجه این طرح موفق و چشم گیر ژاپنی ها به طور ساده اینگونه خلاصه می شود: آغاز حرکت نامحسوس (تکان های ضربه ای) قطار، شتاب گرفتن نامحسوس، ترمز و ایستادن نامحسوس و صرفه جویی در مصرف برق. از این پس منطق فازی بسیار سریع در تکنولوژی دستگاه های صوتی و تصویری ژاپنی ها راه یافت (از جمله نلر زیدن تصویر فیلم دیجیتال ضمن لرزیدن دست فیلم بردار). اروپایی ها بسیار دیر، یعنی در اواسط دهه ۱۹۹۰ میلادی، پس از خوابیدن موج بحث های علمی در رابطه با منطق فازی، استفاده صنعتی از آن را آغاز کردند.

مطالعات گسترده در این مورد نشان داد که سیستم های فازی برای سیستم های غیرخطی و پیچیده با استفاده از طراحی رول^{۱۳} یا قوانین اگر - آنگاه فازی پاسخ بهتری ارائه می دهند. تکنیک استنتاج فازی تاکاگی -

مشاهدات سیستم های ماهواره ای و ناوبری جهانی^۱ (GNSS) مانند هر مشاهده دیگری دستخوش خطاهای تصادفی و سیستماتیک، مانند خطاهای مداری، خطای ساعت، انکسار تروپوسفر، انکسار یونسفر و غیره می باشند. سیگنال های سیستم تعیین موقعیت جهانی^۲ (GPS) نیز متأثر از خاصیت الکتریکی یونسفر هستند. با استفاده از دو فرکانس متفاوت در سیستم تعیین موقعیت جهانی می توان خواص فیزیکی لایه یونسفر را مورد بررسی قرار داد. با کمک دو فرکانس می توان تعداد الکترون های آزاد لایه یونسفر را در ستونی به مساحت ضلع یک متر مربع در راستای گیرنده تا ماهواره بدست آورد. کمیتی که از این روش محاسبه می شود محتوای الکترون کلی یونسفر در راستای مایل^۳ (STEC) نامیده می شود [۱]. این کمیت را می توان با استفاده از توابع نگاشت به محتوای الکترون کلی در راستای قائم^۴ (VTEC) تبدیل نمود. درحقیقت TEC مجموع تعداد الکترون ها در مسیر مابین ماهواره تا گیرنده در یک سطح مقطع به اندازه یک متر مربع است که واحد آن TECU می باشد. این کمیت را می توان از روی اندازه گیری های فاز و کد بدست آمده از سیستم تعیین موقعیت جهانی بدست آورد. جهت تعیین موقعیت با گیرنده های تک فرکانسه، می بایستی اثر لایه یونسفر از روی سیگنال های عبوری از آن برداشته شود. این مرحله در تعیین موقعیت به مدل سازی یونسفر^۵ معروف است.

تاکنون تلاش های بسیار زیادی جهت درون یابی و یا برون یابی چگالی الکترونی یونسفر و کمیت TEC در مناطقی که مشاهده کافی و یا مناسب موجود نیست، صورت گرفته است. بطور مثال می توان به روش های کریجینگ^۶، چندجمله ای^۷، هارمونیک های کروی^۸، درون یابی به کمک توابع اسپیلاین^۹، اسلپین، موجک و شبکه عصبی مصنوعی اشاره نمود [۲، ۳، ۴، ۵، ۶، ۷]. از این روش ها به کرات جهت تهیه و مدل سازی منطقه ای و

^۱ Global Navigation Satellite Systems

^۲ Global Positioning system

^۳ Slant Total Electron Content

^۴ Vertical Electron Content

^۵ Ionosphere modeling

^۶ Kriging

^۷ Polynomial

^۸ Spherical Harmonics

^۹ Spline Functions

^{۱۰} Auto Regressive Multiple

^{۱۱} Artificial neural networks

^{۱۲} fuzzy logic

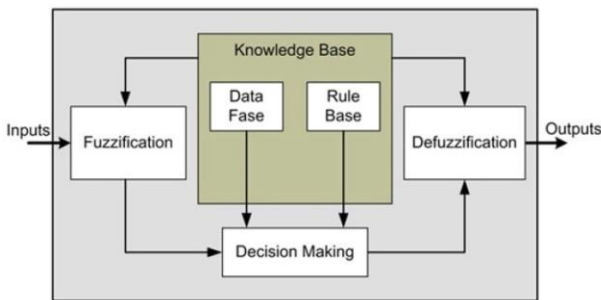
^{۱۳} Rule

مربوط به بازه فعالیت‌های خورشیدی متوسط و مشاهدات ماه (دسامبر) مربوط به بازه فعالیت‌های خورشیدی کم هستند.

جهت بررسی دقت و صحت مدل ارائه شده، نتایج حاصل از این مقاله با نتایج حاصل از مدل شبکه عصبی مصنوعی با الگوریتم آموزش لونیگ-مارکوآرت، مقادیر TEC به دست آمده از مدل مرجع جهانی یونسفری^۴ IRI 2016 و TEC های حاصل از مشاهدات GPS مورد ارزیابی قرار گرفته است.

۲- سیستم استنتاج فازی (FIS)

مراحل استدلال (عملیات نتیجه‌گیری بر روی قواعد اگر-آنگاه فازی) با استفاده از یک سیستم استنتاج فازی انجام می‌شود. در شکل (۱) یک نمونه از ساختار FIS نمایش داده شده است.



شکل ۱- ساختار یک شبکه FIS در حالت کلی

یک FIS براساس پنج بخش اصلی زیر تعریف می‌شود:

- ۱- پایگاه قواعد: شامل تعدادی از قواعد فازی "اگر-آنگاه" می‌باشد.
- ۲- پایگاه داده: توابع عضویت مجموعه‌های فازی که در قواعد فازی مورد استفاده قرار گرفته‌اند در این بخش تعریف می‌شود.
- ۳- بخش تصمیم‌گیری: این بخش عملیات استنتاج را بر روی قواعد فازی اعمال می‌کند.
- ۴- بخش فازی‌سازی^۵: در این بخش ورودی‌هایی که کریسپ^۶ هستند به درجاتی تبدیل می‌شوند که با مقادیر زبانی منطبق می‌باشند.

سوگنو^۱ برای محاسبه تاخیرهای زمانی یونسفر توسط آکیلماز و ارسلان در سال (۲۰۰۸) مورد استفاده قرار گرفت. آنها یک سیستم استنتاج فازی-عصبی سازگار^۲ (ANFIS) برای پیش‌بینی TEC ارائه نمودند که از الگوریتم یادگیری تطبیقی برای بهینه کردن پارامترهای فازی استفاده می‌کرد [۱۱]. با این حال ساختار مناسب روش بهینه‌سازی یک فاکتور مهم برای انتخاب متغیرها و کاهش تعداد رول‌ها و مجموعه‌های فازی است. رتنام و همکارانش در سال (۲۰۱۷) با استفاده از الگوریتم بهینه‌سازی کاهش شیب^۳ سری زمانی تغییرات TEC را مورد مطالعه قرار دادند [۱۲]. در الگوریتم کاهش شیب، ضریب یادگیری توسط کاربر انتخاب می‌شود و همچنین این الگوریتم سرعت انجام محاسبات پایینی دارد که اینها از نقاط ضعف الگوریتم مذکور می‌باشد. یاکوبو و همکاران در سال (۲۰۱۷) سیستم استنتاج عصبی-فازی سازگار را برای پیش‌بینی مکانی مقدار VTEC در کشور چین مورد استفاده قرار دادند [۱۳]. در این مقاله از سیستم استنتاج عصبی-فازی سازگار در پیش‌بینی سری زمانی VTEC برای یک روز آینده مورد استفاده قرار گرفته است. در طراحی سیستم‌های فازی، انتخاب تعداد قواعد مناسب بسیار مهم است، چرا که انتخاب تعداد زیاد قواعد باعث پیچیده‌تر شدن سیستم فازی شده که ممکن است برای مسئله ضروری نباشد و از طرفی انتخاب تعداد قواعد کم ممکن است سیستم فازی ضعیفی را بوجود بیاورد و هدف مورد نظر را تامین نکند.

هدف اصلی این مقاله طراحی یک سیستم استنتاج عصبی-فازی سازگار است که تعداد قواعد را براساس زوج‌های ورودی و خروجی تعیین کند. ایده اساسی این روش گروه‌بندی زوج‌های ورودی و خروجی در خوشه‌های مختلف و استفاده از یک قاعده برای هر خوشه می‌باشد. سپس از این سیستم فازی طراحی شده جهت مدل‌سازی و پیش‌بینی سری زمانی تغییرات TEC در ایستگاه GPS تهران استفاده می‌شود. مشاهدات مورد استفاده در این مقاله مربوط به ماه‌های (می)، (آوریل) و (دسامبر) از سال‌های (۲۰۱۵ و ۲۰۱۱) می‌باشند. مشاهدات ماه (می) مربوط به بازه فعالیت‌های خورشیدی بالا، ماه (آوریل)

^۴ International Reference Ionosphere

^۵ Fuzzation

^۶ Crisp

^۱ Takagi-Sugeno fuzzy inference

^۲ Adaptive Neuro Fuzzy Inference System

^۳ Gradient descends

$$y = h \left(\sum_{j=1}^n (w_j x_j + w_0) \right) \quad (1)$$

در رابطه (۱۰) h نشان دهنده تابع فعالیت، w_j بیانگر وزن هر نورون، x_j نشان دهنده بردار ورودی و w_0 وزن های اولیه شبکه را نشان می دهند. معمولاً الگوریتم های آموزشی یک شبکه عصبی به مشتق توابع فعالیت نیاز دارند، از این رو است که معمولاً از توابع مشتق پذیر استفاده می شود:

$$\begin{cases} h(x) = \frac{a}{1 + e^{-x}} \\ h(x) = a \frac{e^{kx} - 1}{e^{kx} + 1} \end{cases} \Rightarrow x = \sum_{j=1}^n (w_j x_j + w_0) \quad (2)$$

۳-۱- آموزش شبکه های عصبی مصنوعی

در شبکه های عصبی دستیابی به نتایج مطلوب تنها زمانی ممکن بوده است که منبع غنی داده ها با مشاهدات فراوان در اختیار باشد و زمانی که با داده های اندک برای آموزش شبکه مواجه بوده ایم، کارایی بالایی نداشته که این نقص، کاربردهای شبکه عصبی (پرسپترون و موجک) را بشدت محدود می کند. هدف از آموزش شبکه های عصبی، یافتن اندازه وزن ها و بایاس ها به نحوی است که خطای داده های آموزش را به حداقل ممکن برساند. لذا آموزش شبکه های عصبی را می توان در بردارنده یک مسأله بهینه سازی^۷ دانست که هدف از آن بهینه سازی ضرایب وزنی و بایاس ها جهت دستیابی به حداقل خطای آموزش می باشد.

۳-۲- آموزش بروش لوبنبرگ-مارکوآرت^۸

الگوریتم لوبنبرگ-مارکوآرت تعمیمی از الگوریتم گوس نیوتون بوده که برای افزایش سرعت همگرایی بهینه سازی مرتبه دوم توابع هزینه^۹ بدون محاسبه ماتریس هسین است و وقتی ضریب μ بزرگ باشد این الگوریتم به روش گرادیان نزولی بسیار نزدیک می شود.

روند الگوریتم بدین صورت است که در الگوریتم مقدار μ را کوچک انتخاب می کند. اگر در یک گام آموزشی مقدار تابع هزینه کاهش نیابد، این ضریب در یک پارامتر ν

۵- بخش نافازی سازی^۱: نتایج فازی به نتایج کریسپ غیرفازی تبدیل می شود.

سیستم های استنتاجی مختلفی برای انجام تصمیم گیری فازی ارائه شده است که پرکاربردترین آنها قواعد اگر-آنگاه فازی تاکاگی-سوگنو^۲ می باشد. در این سیستم خروجی هر قاعده یک ترکیب خطی از متغیرهای ورودی می باشد که با یک مقدار ثابتی جمع می شوند و خروجی نهایی، میانگین وزن دار خروجی تمام قواعد می باشد [۱۴].

۳- شبکه های عصبی مصنوعی (ANNs)

شبکه های عصبی مصنوعی یا به زبان ساده تر شبکه های عصبی، سیستم ها و روش های محاسباتی نوینی برای یادگیری ماشینی، نمایش دانش و در انتها اعمال دانش به دست آمده در جهت بیش بینی پاسخ های خروجی از سامانه های پیچیده اند. ایده اصلی این گونه شبکه ها الهام گرفته از شیوه کارکرد سیستم عصبی زیستی، برای پردازش داده ها و اطلاعات به منظور یادگیری و ایجاد دانش قرار دارد. عنصر کلیدی این ایده، ایجاد ساختارهایی جدید برای سامانه پردازش اطلاعات است. این سیستم از شمار زیادی عناصر پردازشی فوق العاده بهم پیوسته با نام نورون^۳ تشکیل شده که برای حل یک مسأله با هم هماهنگ عمل می کنند و توسط سیناپس ها (ارتباطات الکترومغناطیسی) اطلاعات را منتقل می کنند. وزن یا میزان ارتباط بین نورون ها در یک شبکه تعیین کننده تمایز مابین شبکه های عصبی می باشد. ساختار هر شبکه عصبی از سه لایه ورودی^۴، پنهان^۵ و خروجی^۶ تشکیل یافته است. براساس ماهیت مساله مورد نظر، شبکه عصبی می تواند از تعداد لایه های پنهان بیشتری تشکیل شود [۱۵]. هر کدام از این لایه ها دارای تعداد نورون های متفاوتی هستند. یک نورون یا یک سلول عصبی در واقع یک تابع با n ورودی و یک خروجی است که رابطه ورودی-خروجی نورون بفرم زیر خواهد بود:

۱ De-Fuzzation
۲ Takagi-Sugeno
۳ Neuron
۴ Input
۵ Hidden
۶ Output

۷ Optimization
۸ Levenberg-Marquardt
۹ Cost function

برای سادگی کار فرض می‌شود که FIS مورد بررسی از دو ورودی x و y و یک خروجی f تشکیل شده و همچنین پایگاه قانون در آن شامل دو قانون اگر- آنگاه است. قوانین موجود در این سیستم عبارت اند از:

$$\begin{aligned} &IF \quad x = A_1 \quad AND \quad y = B_1, \\ &Then \quad f_1 = p_1 + q_1 + r_1 \end{aligned} \quad (3)$$

$$\begin{aligned} &IF \quad x = A_2 \quad AND \quad y = B_2, \\ &Then \quad f_2 = p_2 + q_2 + r_2 \end{aligned} \quad (4)$$

که در آن A_1 و A_2 توابع عضویت برای ورودی x و B_1 و B_2 توابع عضویت برای ورودی y و در نهایت p_1, q_1, r_1 و p_2, q_2, r_2 پارامترهای تابع خروجی هستند. همانند سیستم‌های فازی، ساختار ANFIS نیز از دو بخش تشکیل شده است. بخش نخست مقدم و بخش دوم تالی (استنتاج - نتیجه) نامیده می‌شود که این دو بخش توسط قواعد فازی در فرم یک شبکه به یکدیگر متصل می‌شوند.

با توجه به شکل (۲) لایه‌های اول و چهارم شامل نقاط تطبیقی می‌باشند به طوری که در طی فرآیند آموزش قابل تغییر بوده و سایر لایه‌ها شامل نقاط ثابت می‌باشند. لایه‌های موجود را می‌توان به صورت زیر تعریف کرد:

لایه اول: نقاط موجود در این لایه به پارامترهای یک تابع تطبیق می‌یابند. خروجی هر نقطه، یک مقدار درجه عضویت می‌باشد که توسط ورودی‌های توابع عضویت داده شده‌اند. به عنوان مثال توابع عضویت می‌توانند توابع عضویت گوسی رابطه (۵)، تابع عضویت زنگوله‌ای رابطه (۶) و یا دیگر توابع عضویت می‌توانند باشند:

$$\mu_{A_i}(x) = \exp \left[- \left(\frac{x - c_i}{2a_i} \right)^2 \right] \quad (5)$$

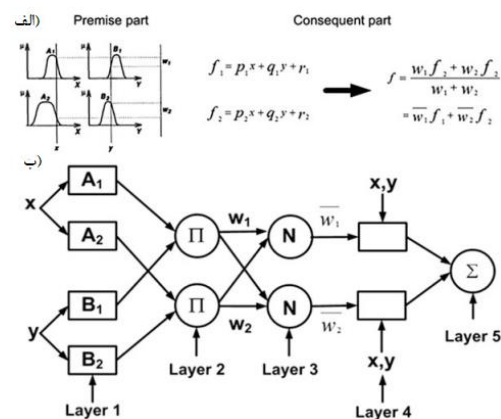
$$\mu_{A_i}(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b}} \quad (6)$$

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x), \quad i = 1, 2 \\ O_{1,i} &= \mu_{B_{i-2}}(y), \quad i = 3, 4 \end{aligned} \quad (7)$$

ضرب شده و مجدداً گام آموزشی تکرار می‌شود. این عمل تا زمانی که تابع هزینه کاهش یابد ادامه پیدا خواهد کرد. بدین ترتیب با رشد ضریب ν الگوریتم مانند گرادیان نزولی عمل می‌کند. اگر میزان کاهش تابع هزینه بسیار کم باشد می‌توان با تقسیم کردن μ بر ν مجدداً گام آموزشی را اجرا کرد تا سرعت کاهش تابع هزینه افزایش پیدا کند. با این تغییر الگوریتم به روش گوس نیوتون نزدیک می‌شود. روش آموزش مورد استفاده در این مقاله برای شبکه عصبی مصنوعی الگوریتم لوبنبرگ-مارکوآرت می‌باشد.

۴- سیستم استنتاج عصبی-فازی سازگار (ANFIS)

منطق فازی این توانایی را دارد که اطلاعات کیفی انسانی را به اطلاعات کمی تحلیلی تبدیل کند. با این حال این روش زمان زیادی را برای تعدیل کردن توابع عضویت^۱ مجموعه‌های فازی صرف می‌کند. بر خلاف منطق فازی، الگوریتم ANN توانایی زیادی در آموزش شبکه دارد و می‌تواند در زمان کمتری با محیط مسئله مورد نظر منطبق شود. بنابراین می‌توان از ANN برای تعدیل اتوماتیک توابع عضویت مجموعه‌های فازی استفاده کرد تا میزان خطا در تعیین قوانین منطق فازی کاهش یابد [۱۶]. ساختار ANFIS یک شبکه تطبیق یافته می‌باشد که از روش نظارت شده در آموزش الگوریتم استفاده می‌کند که تابعی شبیه به سیستم استنتاج فازی تاکاگی-سوگنو دارد. در شکل (۲) مکانیسم استنتاج فازی تاکاگی-سوگنو و ساختار شبکه ANFIS نشان داده شده است [۱۷].



شکل ۲- سیستم استنتاج فازی اگر-آنگاه تاکاگی-سوگنو و مکانیسم منطق فازی. (ب) ساختار ANFIS

^۱ Membership functions

پارامترهای فرض می‌باشند در حالی که لایه چهارم شامل پارامترهای خطی نتیجه می‌باشند. برای به روز کردن و سازگار کردن این پارامترها نیاز به فرآیند آموزش با استفاده از داده‌های آموزشی و الگوریتم گرادیان نزولی می‌باشد که هر دو گروه از پارامترها را آموزش می‌دهد تا در نهایت با محیط مسئله سازگار شوند. برای آموزش شبکه از یک نوع آموزش ترکیبی که توسط Jang ارائه شده است استفاده می‌شود [۱۷]. علت استفاده از این الگوریتم به این دلیل است که الگوریتم‌های بازگشتی که برای آموزش پارامترهای موجود در شبکه‌های عصبی مصنوعی استفاده می‌شود، دارای مشکلاتی بوده و مخصوصاً دارای نرخ همگرایی پایین می‌باشند و احتمال افتادن در کمینه‌های محلی در این روش‌ها بالا می‌باشد.

الگوریتم آموزش هیبرید از دو بخش به نام‌های مسیر رفت^۲ و مسیر برگشت^۳ تشکیل شده‌اند. در مرحله مسیر رفت، پارامترهای فرض مسئله (لایه اول) باید ثابت در نظر گرفته شوند. یک روش برآورد کننده کم‌ترین مربعات بازگشتی (RLSE)^۴ برای بهتر کردن پارامترهای نتیجه موجود در لایه چهارم مورد استفاده قرار می‌گیرد. از آنجا که پارامترهای تالی یا نتیجه، خطی می‌باشند، روش RLSE می‌تواند برای سرعت بخشیدن به نرخ همگرایی در فرآیند آموزش ترکیبی مورد استفاده قرار گیرند. در ادامه فرآیند، بعد از به دست آوردن پارامترهای بخش تالی، داده‌های ورودی به ورودی شبکه تطبیقی بازگشت داده می‌شوند و خروجی تولید شده با خروجی حقیقی مورد مقایسه قرار می‌گیرند.

در مرحله اجرای مسیر برگشت، پارامترهای تالی باید به صورت ثابت در نظر گرفته شوند. خطای به دست آمده از مقایسه بین خروجی حاصل شده با خروجی حقیقی بر روی لایه اول پخش می‌گردد. به طور هم زمان پارامترهای فرض یا مقدمه در لایه اول با استفاده از گرادیان نزولی یا انتشار بازگشتی به روز می‌شوند. با استفاده از آموزش ترکیبی که RLSE و گرادیان ترکیبی را ترکیب می‌کند، می‌توان مطمئن بود که نرخ همگرایی سرعت بالایی دارد زیرا که این روش می‌تواند ابعاد فضای جستجو را در روش

در این روابط $\mu_{Bi,2}$ و μ_{Ai} درجات توابع عضویت برای مجموعه‌های A_i و B_i می‌باشند و پارامترهای (a_i, b_i, c_i) تابع عضویت می‌باشند که می‌توانند شکل تابع عضویت را تغییر دهند. پارامترهای موجود در این لایه پارامترهای فرض در نظر گرفته می‌شوند.

لایه دوم: تمام نقاط موجود در این لایه نقاط ثابت می‌باشند. گره خروجی، نتیجه ضرب سیگنال‌های ورودی می‌باشد و این خروجی توسط گره بعدی دریافت می‌شود. در لایه دوم عملگر T-norm مانند عملگر and و یا ضرب برای به دست آوردن خروجی استفاده می‌شود:

$$o_{2i} = w_i = \mu_{Ai}(x) \times \mu_{Bi}(x) \quad , \quad i=1,2 \quad (8)$$

لایه سوم: همانند لایه دوم، تمام گره‌ها در این لایه ثابت می‌باشند. این لایه نقش نرمال کننده را دارد و وزن هر گره بر مجموع وزن‌های گره‌ها تقسیم می‌شود:

$$o_{3i} = \bar{w}_i = \frac{w_i}{\sum_j w_j} \quad (9)$$

لایه چهارم: تمام نقاط موجود در این لایه گرهی تطبیقی برای یک خروجی با تابع گره زیر می‌باشند:

$$o_{4i} = \bar{w}_i f = (p_i x + q_i x + r_i) f \quad (10)$$

لایه پنجم: تک نقطه موجود در این لایه یک گره غیرتطبیقی و ثابت می‌باشد. در این لایه نتیجه کلی با جمع کردن همه سیگنال‌های ورودی از لایه‌های قبل محاسبه می‌شود. دایره مربوط به این لایه با علامت مجموع برچسب گذاری شده است.

$$o_{5i} = \sum \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (11)$$

۴-۱- الگوریتم آموزش هیبرید^۱

در ساختار شبکه ANFIS معرفی شده، لایه‌های اول و چهارم شامل پارامترهایی هستند که می‌توانند در طول مدت زمان الگوریتم تعدیل شوند. لایه اول شامل

^۲ Forward Path

^۳ Backward Path

^۴ Recursive Least Square Estimator

^۱ Hybrid Learning Algorithm

ابهام فاز، ε_L و ε_P به ترتیب ترکیب نویز مشاهدات و اثر چند مسیری روی مشاهدات کد و ترکیب نویز مشاهدات و اثر چند مسیری روی مشاهدات فاز می‌باشند. با در نظر گرفتن رابطه (۱۷) خواهیم داشت:

$$\begin{cases} \beta = 40.3 \left(\frac{f_2^2 - f_1^2}{f_1^2 f_2^2} \right) \\ N_{arc} = \frac{\lambda_1 N_1}{\beta} - \frac{\lambda_2 N_2}{\beta} \end{cases} \quad (17)$$

$$STEC_P = \frac{P_4}{\beta} = STEC + B_r^P + B_s^P + \varepsilon_{P4} \quad (18)$$

$$STEC_\Phi = \frac{\Phi_4}{\beta} = STEC + N_{arc} + B_r^\Phi + B_s^\Phi + \varepsilon_{\Phi4} \quad (19)$$

مشاهدات STEC حاصل از اندازه‌گیری‌های فاز موج حامل دقیق‌تر از مشاهدات STEC حاصل از مشاهدات می‌باشند. مشکل اصلی مشاهدات STEC حاصل از مشاهدات فاز در وجود دو مقدار ابهام فاز در اندازه‌گیری‌های فاز موج حامل می‌باشد. جهت بهره‌مندی از مزیت دقت بالای مشاهدات STEC حاصل از اندازه‌گیری‌های فاز موج حامل و نیز مزیت عدم وجود ابهام فاز در مشاهدات STEC حاصل از اندازه‌گیری‌های کد، می‌توان مشاهدات حاصل از دو مجموعه را جهت نرم‌سازی^۴ مقدار STEC با همدیگر ترکیب نمود [۱۹]. در این تقریب مقادیر STEC حاصل از مشاهدات فاز در کمان‌های پیوسته^۵ توسط مقادیر میانگین مشاهدات STEC حاصل از اندازه‌گیری‌های کد تعدیل می‌شوند. مقادیر میانگین برای هر کمان پیوسته بصورت زیر محاسبه می‌شود:

$$\langle STEC_P + STEC_\Phi \rangle = \frac{1}{N} \sum_{i=1}^N (STEC_P + STEC_\Phi)_i \quad (20)$$

در رابطه (۲۰)، N نشان‌دهنده تعداد اندازه‌گیری‌های پیوسته برای کمان مورد نظر می‌باشد. بنابراین مقدار STEC نرم شده بصورت رابطه (۲۱) حاصل می‌شود:

$$\begin{aligned} STEC_{smoothed} &= \langle STEC_P + STEC_\Phi \rangle - STEC_\Phi \\ &= STEC + B_u^P + B_m^P + \varepsilon_{P4} \end{aligned} \quad (21)$$

اصلی پس انتشاری^۱ کاهش دهد. هر مرحله از آموزش ترکیبی یک اپوک نامیده می‌شود. در این مقاله از این الگوریتم جهت آموزش شبکه ANFIS استفاده شده است.

۵- محاسبه TEC با استفاده از گیرنده‌های دو فرکانسه

برای بدست آوردن STEC، از ترکیب خطی عاری از هندسه^۲ مشاهدات GPS استفاده می‌شود. خطای ساعت و تاخیر تروپوسفری مستقل از فرکانس بوده و به کمک این ترکیب خطی حذف خواهند شد. ترکیب خطی عاری از هندسه را می‌توان به صورت روابط (۱۲) و (۱۵) نوشت [۱۸].

$$\begin{aligned} P_{4,u}^m &= P_{1,u}^m - P_{2,u}^m = d_{ion1,u}^m - d_{ion2,u}^m \\ &+ c(\tau_{P1}^m + \tau_{P2}^m) + c(\tau_{P1,u} + \tau_{P2,u}) + \varepsilon_P \end{aligned} \quad (12)$$

$$d_{ion1,u}^m - d_{ion2,u}^m = 40.3 \left(\frac{f_2^2 - f_1^2}{f_1^2 f_2^2} \right) STEC \quad (13)$$

$$P_{4,u}^m = 40.3 \left(\frac{f_2^2 - f_1^2}{f_1^2 f_2^2} \right) STEC + b_s^P + b_r^P + \varepsilon_P \quad (14)$$

$$\begin{aligned} \Phi_{4,u}^m &= \Phi_{1,u}^m - \Phi_{2,u}^m = d_{ion2,u}^m - d_{ion1,u}^m + \lambda_1 N_1 \\ &- \lambda_2 N_2 + c(T_{L1}^m + T_{L2}^m) + c(T_{L1,u} + T_{L2,u}) + \varepsilon_L \end{aligned} \quad (15)$$


$$\begin{aligned} \Phi_{4,u}^m &= -40.3 \left(\frac{f_2^2 - f_1^2}{f_1^2 f_2^2} \right) STEC + \lambda_1 N_1 \\ &- \lambda_2 N_2 + B_s^P + B_r^P + \varepsilon_L \end{aligned} \quad (16)$$

در این روابط u اندیس مربوط به گیرنده و m اندیس مربوط به ماهواره، d_{ion2} و d_{ion1} تاخیر یونسفری بر روی فرکانس‌های L_2 و L_1 ، $b_r^P = c(\tau_{P1} + \tau_{P2})$ ، $b_s^P = c(\tau_{P1}^m + \tau_{P2}^m)$ و ماهواره برای مشاهدات شبه فاصله کد، ترتیب بایاس تداخل فرکانسی گیرنده و ماهواره برای مشاهدات فاز موج حامل، λ_1 و λ_2 طول موج، N_1 و N_2

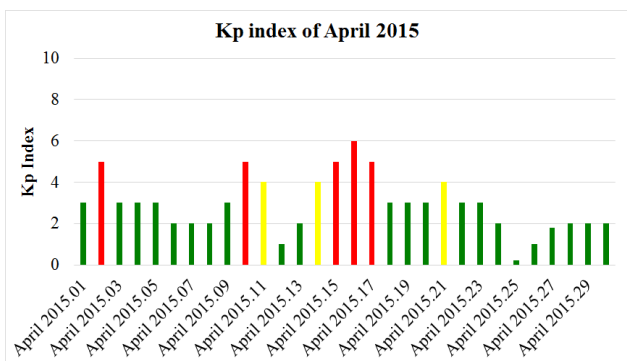
۴ Smoothing
۵ Continues arc

۱ Back propagation
۲ Geometry free
۳ Receiver inter frequency bias


داده و برای یک ماه ۸۶۴۰ مقدار TEC به دست آمده است که انتخاب ماه های مورد مطالعه بر اساس ضریب فعالیت های خورشیدی صورت گرفته است. چگونگی تغییرات شاخص فعالیت های خورشیدی^۲ (Kp) May 2015 با میانگین ضریب Kp index ۳/۸۰، بعنوان شرایط ناآرام فعالیت های خورشیدی، April 2015 با میانگین ضریب Kp index ۲/۹، بعنوان شرایط متوسط فعالیت های خورشیدی و December 2011 با میانگین Kp index ۱/۹ بعنوان شرایط آرام فعالیت های خورشیدی که به ترتیب در اشکال (۴)، (۵) و (۶) نمایش داده شده اند، جهت انجام آنالیزها در نظر گرفته شده است.



شکل ۴- ضریب Kp index برای ماه می سال ۲۰۱۵



شکل ۵- ضریب Kp index برای ماه آوریل سال ۲۰۱۵



شکل ۶- ضریب Kp index برای ماه دسامبر سال ۲۰۱۱

جهت بدست آوردن مقدار محتوای الکترون کلی قائم از تابع نگاشت رابطه (۲۳) استفاده خواهیم کرد.

$$VTEC = M \times STEC_{smoothed} \quad (22)$$


$$M = \left[1 - \left(\frac{R \cos(ele)}{R+h} \right)^2 \right]^{-1/2} \quad (23)$$

در رابطه (۲۳)، M تابع نگاشت، ele زاویه ارتفاعی ماهواره، R شعاع کره زمین و h ارتفاع لایه یونسفری می باشد [۱۹].

در این مقاله VTEC حاصل از نرم افزار IONOLAB^۱ به صورت سری زمانی ایستگاه تهران، به عنوان داده های آموزش شبکه در زمان های مختلف مورد استفاده قرار گرفته است [۲۰، ۲۱، ۲۲].

۶- نتایج عددی و آنالیزها

مشاهدات TEC ایستگاه GPS دائمی تهران در موقعیت (35.70N , 51.33E) برای آنالیز روش پیشنهادی مورد استفاده قرار گرفته است. شکل (۳) موقعیت ایستگاه مورد مطالعه را نمایش می دهد.



شکل ۳- موقعیت ایستگاه GPS تهران (ستاره ها موقعیت ایستگاه های مربوط به شبکه ژئودینامیک ایران و دایره قرمز رنگ ایستگاه مورد مطالعه)

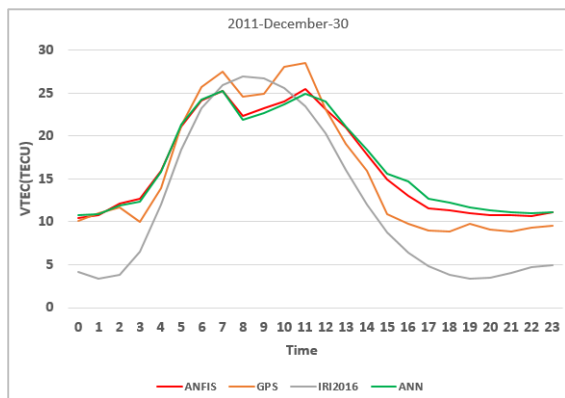
سری زمانی TEC ایستگاه تهران از طریق نرم افزار IONOLABTEC^۲، بدین صورت که در هر پروفیل ۲۴ ساعته و با نرخ نمونه برداری ۵ دقیقه، برای یک روز ۲۸۸

^۲ <https://www.spaceweatherlive.com/en/archive>

^۱ <http://www.ionolab.org/>

به ماه های با فعالیت خورشیدی زیاد، فعالیت خورشیدی متوسط و فعالیت خورشیدی کم انجام شده است. نتایج حاصل نشان دهنده این است که در ماههایی با فعالیت کم و فعالیت متوسط یک تقریب مناسبی از TEC را شاهد هستیم ولی ماههایی که مربوط به فعالیت خورشیدی شدید می باشند مقدار TEC را تحت تاثیر قرار داده و از کارایی شبکه می کاهد. مقدار جذر خطای مربعی میانگین (RMSE^۲) بین مقادیر پیش بینی شده توسط شبکه ANFIS و شبکه عصبی مصنوعی با مقادیر اندازه گیری شده از مشاهدات سیستم GPS و همچنین TEC حاصل از مدل مرجع جهانی یونسفری IRI 2016 محاسبه گردیده و معیار ارزیابی دقت پیش بینی قرار گرفته است.

اشکال (۷)، (۸) و (۹) به ترتیب نمودارهای پیش بینی مربوط به روز سی ام ماه دسامبر ۲۰۱۱، سوم می ۲۰۱۵ و ششم آوریل ۲۰۱۵ را نمایش می دهد. در این نمودارها پیش بینی حاصل از شبکه ANFIS با رنگ قرمز، پیش بینی حاصل از شبکه عصبی مصنوعی با رنگ سبز و TEC محاسبه شده با استفاده از مشاهدات GPS با رنگ نارنجی و همچنین TEC حاصل از مدل IRI با رنگ خاکستری نمایش داده شده است.



شکل ۷- مقایسه مقدار محتوای الکترون کلی قائم محاسبه شده با شبکه ANFIS، شبکه عصبی مصنوعی و مشاهدات GPS و مدل IRI برای روز ۳۰ ماه دسامبر ۲۰۱۱

سری زمانی $X = \{VTEC(t), t = 1, 2, 3, \dots, n\}$ که مقدار محتوای الکترون کلی در زمان t و n تعداد کل داده های سری زمانی است. در این مطالعه از داده های مربوط به ۳۰ روز جهت آموزش و آزمون استفاده شده است بگونه ای که ۸۰ درصد داده ها (داده های ۲۴ روز) بعنوان آموزش و ۲۰ درصد داده ها (داده های ۶ روز) برای آزمون نتایج استفاده شده است. جهت آموزش سیستم استنتاج عصبی-فازی سازگار تاخیرهای زمانی^۱ بهینه به عنوان ورودی شبکه معرفی شده اند. برای شبکه چهار ورودی طبق رابطه (۲۴) و یک خروجی در نظر گرفته شده است:

$$\begin{aligned} \{r(t-288), r(t-1615), r(t-1290), r(t-672)\} &\rightarrow \text{Inputs} \\ r(t) &\rightarrow \text{Targets} \\ r(t+288) &\rightarrow \text{Outputs} \end{aligned} \quad (24)$$

پس از اینکه داده ها را تا قبل از روز پیش بینی برای شبکه معرفی کردیم، شبکه ANFIS قادر خواهد بود مقدار TEC را برای یک روز آینده پیش بینی کند، در واقع افق پیش بینی مورد نظر در این مقاله یک روز می باشد. پیش بینی TEC همچنین با استفاده از شبکه عصبی مصنوعی با الگوریتم آموزش لونبرگ-مارکوارت نیز برای داده های موجود صورت گرفته است تا بتوان مقایسه علمی درستی در مورد دقت و صحت نتایج حال از شبکه ANFIS ارائه داد. ساختار شبکه مورد استفاده برای ANFIS در جدول (۱) بیان شده است.

جدول ۱- پارامترهای مختلف و مقادیر مورد استفاده جهت آموزش ANFIS

ANFIS Parameter type	Value
MF Type	Gauss
Number of MFs	12
Number of Rules	3
Number of Iterations	100
Output function	Linear
Optimization Method	Hybrid
Classification	“genfis 2” matlab routine
Radius of influence	0.6

۶-۱- نتایج پیش بینی TEC با استفاده از ANFIS و شبکه عصبی مصنوعی

در این مقاله پیش بینی TEC برای روزهای ششم آوریل ۲۰۱۵، سوم می ۲۰۱۵ و سی ام دسامبر ۲۰۱۱ که مربوط


^۲ Root Mean Square Error

^۱ Delays


با توجه به شکل (۱۰) و با مقایسه RMSE محاسبه شده بین مقادیر پیش‌بینی شده توسط شبکه ANFIS، شبکه عصبی مصنوعی و مدل مرجع جهانی IRI 2016 با مقادیر حاصل از اندازه‌گیری‌های مشاهدات سیستم GPS، برآورد حاصل از روش ANFIS، از نظر دقت پیش‌بینی برای روزهای با فعالیت خورشیدی شدید، متوسط و آرام، نسبت به روش شبکه عصبی مصنوعی و مدل IRI برتری دارد و همچنین این روش از نظر انجام عملیات محاسباتی از روش شبکه عصبی مصنوعی بهتر می‌باشد.

۷- نتیجه‌گیری

در این مقاله از شبکه‌های عصبی مصنوعی و همچنین مدل استنتاج فازی-عصبی سازگار جهت پیش‌بینی و برآورد مقدار محتوای الکترون کلی قائم لایه یونسفر برای یک روز آینده استفاده شد. نتایج بدست آمده از این تحقیق نشان می‌دهد که در پیش‌بینی مقدار TEC، شبکه ANFIS یک سیستم دقیق و سریع می‌باشد. با توجه به RMSE محاسبه شده بین مدل مرجع جهانی IRI 2016، نتایج حاصل از شبکه ANFIS و نتایج حاصل از شبکه عصبی مصنوعی با میزان TEC اندازه‌گیری شده از مشاهدات GPS در هر سه روز مورد مطالعه، پیش‌بینی شبکه ANFIS نسبت به شبکه عصبی مصنوعی و مدل IRI با دارا بودن کمترین مقدار RMSE در هر سه بازه مورد مطالعه، از نظر دقت و عملیات محاسباتی برتری دارد. در روزهای سوم می ۲۰۱۵ و ۳۰ دسامبر ۲۰۱۱ مقدار RMSE برای شبکه ANFIS، ۳/۷ TECU و ۲/۱ TECU برآورد شده درحالی‌که این مقدار برای روز ششم آوریل ۲۰۱۵ برابر ۴/۶ در واحد TECU محاسبه شده است. در روزهای سوم می ۲۰۱۵ و ۳۰ دسامبر ۲۰۱۱ مقدار RMSE برای شبکه عصبی مصنوعی با الگوریتم آموزش لونیگ-مارکوات ۴/۰۶ و ۲/۶ TECU و برای روز ششم آوریل ۲۰۱۵ برابر ۵/۰۶ در واحد TECU برآورد شده است. همچنین مقدار RMSE بین TEC حاصل از مدل مرجع جهانی یونسفری IRI و مقادیر TEC دقیق حاصل از اندازه‌گیری‌های سیستم GPS برای روزهای سوم می ۲۰۱۵ و ۳۰ دسامبر ۲۰۱۱ برابر ۴/۳۲ و ۴/۳۷ TECU و برای روز ششم آوریل ۲۰۱۵ برابر ۵/۸۸ در واحد TECU برآورد شده است. با توجه به نتایج بدست آمده




شکل ۸- مقایسه مقدار محتوای الکترون کلی قائم محاسبه شده با شبکه ANFIS، شبکه عصبی مصنوعی و مشاهدات GPS برای روز ۳ ماه می ۲۰۱۵



شکل ۹- مقایسه مقدار محتوای الکترون کلی قائم محاسبه شده با شبکه ANFIS، شبکه عصبی مصنوعی و مشاهدات GPS برای روز ۶ ماه آوریل ۲۰۱۵

همچنین شکل (۱۰) مقدار RMSE محاسبه شده بین TEC پیش‌بینی شده توسط شبکه ANFIS، شبکه عصبی مصنوعی و TEC بدست آمده از مدل IRI 2016 را برای سه بازه زمانی مورد مطالعه، نمایش می‌دهد. در این شکل، نمودار آبی رنگ مربوط به شبکه ANFIS، نمودار نارنجی رنگ مربوط به مدل IRI و RMSE مربوط به شبکه عصبی مصنوعی با نمودار خاکستری رنگ نمایش داده شده است.



شکل ۱۰- مقایسه (RMSE) محاسبه شده مابین مقدار محتوای الکترون کلی قائم داده‌های آموزش و آزمون با مقادیر TEC محاسبه شده از مشاهدات GPS در ماه‌های با فعالیت‌های خورشیدی متفاوت

استفاده نمود، علاوه بر این می‌توان از الگوریتم‌های بهینه‌سازی دیگری مانند الگوریتم مورچگان، الگوریتم بهینه‌سازی انبوه ذرات، الگوریتم تکاملی تفاضلی برای بهبود سیستم استنتاج عصبی- فازی اولیه استفاده کرده و نتایج را مورد بررسی و مقایسه قرار داد.

شبکه عصبی - فازی سازگار کارایی و سرعت عمل بهتری نسبت به شبکه عصبی مصنوعی و مدل جهانی IRI داشته است. همچنین به عنوان پیشنهاد، در مطالعات بعدی می‌توان از همین سیستم جهت مدل‌سازی مکانی در ایستگاه‌های یک شبکه و یا در نقاط نفوذ یونسفری (IPP)

مراجع

- [1] Seeber. G., (2003). "Satellite Geodesy: Foundations. Methods and Applications". Walter de Gruyter. Berlin and New York, 531.
- [2] Sayin, I., Arikan, F., Arikan, O. (2008). "Regional TEC mapping with random field priors and kriging". Radio Sci. 2008, 43, 441-448.
- [3] Aghayani-pour, K. and Hakemifar, J. (2008), "Theoretical and Experimental Study of the Strength of Piezoelectric Structures Under Pressure Forces," Proc. of the 1st Conference on Dynamics of Advanced Structures, Mechanics Research Center, Isfahan, pp. 23-25, (in Persian).
- [4] Mautz, R., Ping, J., Heki, K., Schaffrin, B., Shum, C.K., Potts, L. (2005). "Efficient spatial and temporal representations of global ionosphere maps over Japan using B-spline wavelets". J. Geod. 78 (11-12), 660-667, 2005.
- [5] Ghaffari Razin, M.R., Voosoghi, B., (2016)." Modeling of ionosphere time series using wavelet neural networks (case study: N-W of Iran)". Advances in Space Research. doi: <http://dx.doi.org/10.1016/j.asr.2016.04.006>.
- [6] Sharifi, M.A. and Farzaneh, S., (2015). "Regional TEC dynamic modeling based on Slepian functions". Advances in Space Research, Vol.56, No.5, pp.907-915.
- [7] Amerian, Y., Voosoghi, B. and Hossainali, M.M., (2013). "Regional ionosphere modeling in support of IRI and wavelet using GPS observations". Acta Geophysica, Vol.61, No.5, pp.1246-1261.
- [8] Muhtarov, P., Kutiev, I., & Cander, L. (2002). "Geomagnetically correlated autoregression model for short-term prediction of ionospheric parameters". Inverse Problems. Vol.18, No.1, pp. 49-65.
- [9] Ghaffari Razin, M. R., Voosoghi, B., & Mohammadzadeh, A. (2016). "Efficiency of artificial neural networks in map of total electron content over Iran". Acta Geodaetica et Geophysica, Vol.51, No.3, pp. 541-555.
- [10] Zadeh, L. A. (1996). "Fuzzy sets". Information and control. Vol.8, pp. 338-353.
- [11] Akyilmaz, O., & Arslan, N. (2008). "An experiment of predicting Total Electron Content (TEC) by fuzzy inference systems". Earth, planets and space, Vol.60, No.9, pp.967-972.
- [12] Ratnam, D. V., Vindhya, G., & Dabbakuti, J. K. (2017)." Ionospheric forecasting model using fuzzy logic-based gradient descent method". Geodesy and Geodynamics, Vol. 8, No.5, pp.305-310.
- [13] Yakubu, I., Ziggah, Y. Y., & Asafo-Agyei, D. (2017). "Appraisal of ANN and ANFIS for Predicting Vertical Total Electron Content (VTEC) in the Ionosphere for GPS Observations". Ghana Mining Journal, Vol. 17, No.2, pp. 12-16.
- [14] Suparta, W., & Alhasa, K. M. (2015). "Modeling of zenith path delay over Antarctica using an adaptive neuro fuzzy inference system technique". Expert systems with applications, Vol.42, No.3, pp.1050-1064.
- [15] Schalkoff, R. J. (1997). "Artificial neural networks". Vol. 1. New York: McGraw-Hill.
- [16] T. Takagi, M. Sugeno. (1985). "Fuzzy identification of systems and its applications to modeling and control". IEEE Transactions on Systems, Man and Cybernetics vol. 15, No. 1, 1985, pp. 116-132.
- [17] Jang, J. S. (1993). "ANFIS: adaptive-network-based fuzzy inference system". IEEE transactions on systems, man, and cybernetics, Vol. 23, No.3, pp.665-685.
- [18] Leick, A., Rapoport, L., & Tatarnikov, D. (2015). "GPS satellite surveying". John Wiley & Sons.
- [19] Ciraolo, 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, Vol.81, No. 2, pp. 111-120.
- [20] Nayir, H., Arikan, F., Arikan, O., & Erol, C. B. (2007). "Total electron content estimation with Reg-Est". Journal of Geophysical Research: Space Physics, Vol. 112, No. A11.
- [21] Arikan, F., Nayir, H., Sezen, U., & Arikan, O. (2008)." Estimation of single station interfrequency receiver bias using GPS-TEC". Radio Science, Vol. 43, No.4.
- [22] Sezen, U., Arikan, F., Arikan, O., Ugurlu, O., & Sadeghimorad, A. (2013)." Online, automatic, near-real time estimation of GPS-TEC: IONOLAB-TEC". Space Weather, Vol. 11, No. 5, pp. 297-305.