

برآورد پارامترهای مدل فیزیکی پیش‌بینی چگالی الکترونی یونسفر با استفاده از شبکه عصبی مصنوعی

محمد مهدی کاکنج^۱، یزدان عامریان^{۲*}، هانی محبوبی^۳

^۱ دانشجوی کارشناسی ارشد ژئودزی - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه‌نصیرالدین طوسی
m.kakanj@email.kntu.ac.ir

^۲ دانشیار دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه‌نصیرالدین طوسی
amerian@kntu.ac.ir

^۳ استادیار دانشکده مهندسی عمران، آب و محیط زیست - دانشگاه شهید بهشتی
h_mahbuby@sbu.ac.ir

(دریافت: مرداد ۱۴۰۳، تصویب: شهریور ۱۴۰۳)

چکیده

یونسفر به عنوان لایه بالایی اتمسفر زمین حاوی یون‌ها و الکترون‌های آزاد است که تأثیر زیادی بر انتقال سیگنال‌های رادیویی و ماهواره‌ای دارد. تصحیح مشاهدات سیستم‌های ماهواره‌ای ماهواره‌ای جهانی (GNSS) جهت افزایش دقت تعیین موقعیت، بهبود طراحی و عملکرد سیستم‌های ارتباطات رادیویی، تصحیح تأثیرات یونسفر برای ارتقاء دقت داده‌های راداری، درک بهتر تغییرات جوی و فضایی بر اثر طوفان‌های خورشیدی و فعالیت‌های ژئومغناطیسی، از جمله مواردی است که اهمیت پیش‌بینی چگالی الکترونی یونسفر (IED) را دو چندان کرده‌است. پیش‌بینی چگالی الکترونی یونسفر به نسبت محتوای کلی الکترونی (TEC) مزیت بیشتری دارد؛ چراکه اطلاعات دقیق‌تری در خصوص توزیع الکترون‌ها در ارتفاعات مختلف یونسفر فراهم می‌نماید. هدف از این پژوهش پیش‌بینی چگالی الکترونی یونسفر با استفاده از پیش‌بینی پارامترهای معادله پیوستگی با بکارگیری شبکه عصبی مصنوعی (ANN) است. این مطالعه به پیش‌بینی چگالی الکترونی یونسفر برای روز ۱۲۹ سال ۲۰۱۶ در محدوده ایران می‌پردازد که در سه فاز کلی انجام شده‌است. ابتدا با استفاده از چگالی الکترونی یونسفر دریافت شده از مرجع بین‌المللی یونسفر (IRI) و یک فرآیند رگرسیون خطی مقید و محاسبه شار تابشی خورشید بر روی نقاط شبکه‌ای با فواصل ۰/۵ درجه، پارامترهای معادله پیوستگی محاسبه می‌گردد. این مقادیر به عنوان داده‌های هدف به شبکه عصبی مصنوعی معرفی تا در کنار داده‌های ورودی مربوط به روزهای ۱۲۳ تا ۱۲۸ ام سال ۲۰۱۶، یک شبکه عصبی پیشخور آموزش داده شود. در فاز سوم پارامترهای پیش‌بینی شده توسط شبکه عصبی مصنوعی در معادله دیفرانسیل پیوستگی قرار گرفته و پیش‌بینی چگالی الکترونی یونسفر انجام می‌گردد. با ارزیابی نتایج، مقدار متوسط RMS اختلاف چگالی الکترونی یونسفر پیش‌بینی شده و چگالی الکترونی یونسفر IRI در روز ۱۲۹ ام برای بازه زمانی یک ساعته برابر $10^{10} \times 2.3733$ ، دو ساعته $10^{10} \times 5.1694$ و سه ساعته $10^{11} \times 1.0943$ الکترون بر مترمکعب بوده‌است.

واژگان کلیدی: معادله پیوستگی یونسفر، شبکه عصبی مصنوعی، چگالی الکترونی یونسفر، محتوای کلی الکترونی، IRI

۱- مقدمه

مطالعات یونسفر از اهمیت بسیار برخوردار است چراکه تأثیرات گسترده‌ای بر روی ارتباطات و ناوبری دارد. از جمله جنبه‌های کلیدی اهمیت یونسفر می‌توان به ارتباطات رادیویی برد بلند، سیستم‌های ماهواره‌ای ناوبری جهانی^۱ (GNSS)، مطالعات تغییرات جوی و فضایی و تحقیقات فیزیک پایه مربوط به پلاسما و هواشناسی فضایی اشاره نمود. چگالی الکترونی یونسفر^۲ می‌تواند باعث تأخیر زمانی و تغییر مسیر سیگنال‌های GNSS شود. پیش‌بینی‌های دقیق یونسفری به تصحیح این خطاها و افزایش دقت تعیین موقعیت کمک می‌کنند. از طرفی با استفاده از مدل‌های پیش‌بینی چگالی الکترونی، دقت تعیین موقعیت ماهواره‌ای بهبود می‌یابد که برای کاربردهایی مانند نقشه‌برداری، ناوبری هواپیماها و کشتی‌ها بسیار حیاتی است [۱۵].

یونسفر یک محیط حساس به تغییرات فعالیت‌های خورشیدی و ژئومغناطیسی است. پیش‌بینی‌های یونسفری به تحلیل و مدیریت اثرات این فعالیت‌ها بر سیستم‌های ارتباطی و ناوبری کمک می‌کنند. پیش‌بینی‌های یونسفری به بهبود ارتباطات رادیویی با فرکانس بالا^۳ (HF) که برای ارتباطات برد بلند استفاده می‌شود، کمک می‌کنند. این پیش‌بینی‌ها در تعیین بهترین فرکانس‌ها و زمان‌های ارسال سیگنال جهت انعکاس از یونسفر نقش اساسی دارند. تغییرات در چگالی الکترونی یونسفر می‌تواند منجر به تداخلات در ارتباطات رادیویی شود. پیش‌بینی این تغییرات به کاهش تأثیرات منفی و بهبود کیفیت ارتباطات کمک می‌کند [۱۳]. به طور کلی، پیش‌بینی‌های یونسفری نقش حیاتی در بهبود عملکرد و دقت سیستم‌های ناوبری، ارتباطات، مطالعات جوی و فضایی و سامانه‌های راداری دارند. این پیش‌بینی‌ها به کاهش خطاها، بهبود دقت و افزایش کارایی این سیستم‌ها کمک می‌کنند.

هابارولما و همکاران مدلی جهانی را برای محاسبه چگالی الکترونی یونسفر در سه بعد و در زمان وقوع طوفان‌های خورشیدی با استفاده از شبکه عصبی مصنوعی توسعه دادند [۶]. در این پژوهش از داده‌های اختفای رادیویی^۴ و یونوسوند^۵ مربوط به سال‌های ۲۰۰۶ الی ۲۰۲۱ و ۲۰۰۰ تا ۲۰۲۰ و همچنین از مقادیر شاخص طوفان ژئومغناطیسی

Kp استفاده شده است. نتایج این پژوهش در مقایسه با مدل IRI 2020، بهبودی تا حدود ۵۰ درصد در محاسبه شاخص f0F2 در طول زمان طوفان ژئومغناطیسی از ۳ تا ۶ نوامبر ۲۰۲۱ و ۲۳ تا ۲۵ مارس ۲۰۲۳ بر روی مناطق میلستون هیل (42.6°N, 71.5°W) و ترومسو (69.6°N, 19.2°E) و برای منطقه جیکارمارکا (11.8°S, 77.2°W) بهبودی تا حدودی ۲۰ درصد در دوره ۷ تا ۱۰ سپتامبر ۲۰۱۷ را نشان می‌دهد.

لیو و همکاران از ترکیب روش‌های المان محدود در حوزه فرکانس^۶ (FDFEM) و هوش مصنوعی برای پیش‌بینی چگالی الکترونی در لایه پایین یونسفر استفاده نمودند [۸]. در این روش که FDFEM-AI شناخته می‌شود؛ یک مجموعه داده با استفاده از FDFEM جهت آموزش و تست شبکه عصبی ایجاد می‌گردد. شبکه عصبی بهبود یافته (بهینه سازی وزن ها، آستانه ها، و تعداد نورون) المان^۷ (ENN) رابطه بین چگالی الکترونی یونسفر و دامنه/فاز موج‌های فرکانس بسیار پایین (VLF) در لایه‌های مختلف یونسفر را پیش‌بینی می‌نماید. به منظور بهینه‌سازی چگالی الکترونی در ارتفاعات مختلف و زوایای خورشیدی مختلف الگوریتم ژنتیک با ENN ترکیب می‌شود. نتایج نشان دهنده تطبیق مناسب بین پیش‌بینی‌ها و مشاهدات واقعی می‌باشد که نشان از موثر بودن روش مورد استفاده دارد.

دوتا و کوهن در سال ۲۰۲۳ مدل‌سازی چگالی الکترونی یونسفر در سطح بالایی یونسفر را با استفاده از پیش‌بینی‌های شبکه عصبی و مدل تجربی را توسعه دادند [۴]. آنها از یک مدل بهبودیافته یادگیری ماشین به ویژه شبکه عصبی مصنوعی چند لایه با ۹ نورون برای پیش‌بینی چگالی الکترونی در بالای یونسفر استفاده نمودند. ورودی‌های شبکه عصبی شامل زمان جهانی، عرض و طول جغرافیایی، ارتفاع و شاخص‌های خورشیدی و مغناطیسی F10.7 و Ap برای ۵ روز بوده است. نتایج بدست آمده با مدل مرجع بین المللی یونسفر IRI و مدل تجربی یونسفر قطب شمال کانادا (E-CHAIM) مقایسه شد. نتایج حاصل از پیش‌بینی شبکه عصبی در عرض‌های جغرافیایی میانی عملکرد بهتری را نشان می‌دهد و خطای مطلق کمتری را نسبت به IRI به ویژه در موارد با شاخص مغناطیسی (Kp) بالا را داشته است. همچنین

۵ Ionosonde

۶ Frequency-Domain Finite Element Method

۷ Elman Neural Network

۱ Global navigation satellite system

۲ Ionospheric Electron Density (IED)

۳ High Frequency

۴ Radio Occultation

این مدل بیش از ۵۰ درصد کاهش در خطای نسبی نسبت به مدل E-CHAIM در شرایط با اختلال زیاد یونسفر داشته‌است.

هوانگ و همکاران با بکارگیری شبکه عصبی بازگشتی^۱ (RNN) به مدل‌سازی چگالی الکترونی جهانی زمین با در نظر گرفتن تکامل زمانی پرداختند [۱۷]. در این مدل از داده‌های چگالی الکترونی چندساله از ماهواره Van Allen Probes استفاده شد. این ماهواره در مگنتوسفر داخلی زمین قرار دارد. داده‌ها شامل موقعیت ماهواره، زمان محلی مغناطیسی، عرض جغرافیایی مغناطیسی و چگالی الکترونی کل و شاخص‌های ژئومغناطیسی SML، Hp30، و SYM-H برای نمایش وضعیت مگنتوسفری بوده‌است. رزولوشن زمانی داده‌های ژئومغناطیسی، ۱۰ دقیقه و برای مدت زمان ۲۰۰ ساعت و موقعیت ماهواره با رزولوشن زمانی ۱ دقیقه برای مدت ۲۷۰ دقیقه بوده‌است. نتایج این تحقیق نشان می‌دهد که شبکه‌های عصبی بازگشتی می‌توانند برای مدل‌سازی پدیده‌های پیچیده مانند چگالی الکترونی در مگنتوسفر زمین بسیار موثر واقع شوند.

قلی‌پور پیش‌بینی محتوی الکترونی کلی یونسفر بر پایه ترکیب فیلتر کالمن و شبکه‌های عصبی مصنوعی با استفاده از مشاهدات سیستم تعیین موقعیت جهانی را ارائه دادند [۵]. در این پژوهش اختلاف بین مقادیر حاصل از پیش‌بینی و همچنین مقادیر TEC حاصل از مدل تجربی IRI همراه با مقادیر دقیق TEC حاصل از مشاهدات گیرنده دو فرکانسه GPS محاسبه گردید. نتایج حاصل نشان می‌دهد که دقت پیش‌بینی در شرایط مختلف خورشیدی تا بازه زمانی سه ساعت بهتر از مدل IRI می‌باشد اما با افزایش فاصله زمانی پیش‌بینی به سمت دقت مدل IRI میل کرده و به مرور کاهش می‌یابد.

به عنوان آخرین تلاش‌ها در ایران در زمینه پیش‌بینی یونسفر، محبوبی داده‌گواری^۲ منطقه‌ای چگالی الکترونی حاصل از مشاهدات GPS بر روی مدل فیزیکی یونسفر برای منطقه ایران را ارائه داد [۱۰]. در پژوهش مذکور یک مدل منطقه‌ای با در نظر گرفتن امکان کمبود داده را توسعه داده و خروجی آن به عنوان ورودی در فرآیند پیش‌بینی یونسفر استفاده گردید. شبکه آنالیز تولید شده توسط مدل منطقه‌ای داده‌گواری شده در منطقه ایران به عنوان شرایط اولیه لازم

جهت انتگرال‌گیری به معادله پیوستگی معرفی شد. در فرآیند پیش‌بینی نیز از تکنیک کمترین مربعات مقید استفاده شده‌است. پیش‌بینی‌ها در همان روزی که مدل منطقه‌ای داده‌گواری شده ساخته شده‌است، در گام‌های ده دقیقه‌ای به مدت حداکثر سه ساعت انجام شده و با مقادیر آنالیز معلوم در همان روز راستی‌آزمایی گردید. براساس نتایج بدست آمده با افزایش بازه زمانی پیش‌بینی، دقت کاهش می‌یابد و پیش‌بینی‌های یک ساعته و دو ساعته میزان همبستگی بیشتری با مقادیر آنالیز دارند.

۲- روش تحقیق

در پژوهش پیش رو، از معادله پیوستگی^۳ یونسفر برای پیش‌بینی چگالی الکترونی استفاده می‌شود. معادله پیوستگی توصیف‌گر تکامل زمانی و مکانی چگالی الکترونی ذرات در یک سیال یا پلاسما است. این معادله براساس بقای تعداد یا جرم ذرات عمل کرده و تغییرات چگالی الکترونی را در اثر فرایندهای مختلفی مانند تولید یون (یونش) و از بین رفتن الکترون‌ها (بازترکیب) و انتقال و جابجایی (در راستای افقی) آنها را بررسی می‌کند. هر سه پدیده ذکر شده در چهارچوب زمان و مکان مؤثر در میزان چگالی الکترونی هستند.

اما این معادله دارای یکسری پارامتر است که برآورد بهینه این پارامترها چالش ابتدایی تحقیق است. برای این منظور، ابتدا مقادیر چگالی الکترونی یونسفر روی شبکه نقاط سه بعدی از مدل IRI دریافت شده‌است. سپس با استفاده از مقادیر نقاط شبکه‌ای دریافت شده در دو لحظه متوالی، پارامترهای معادله پیوستگی به کمک یک فرآیند رگرسیون خطی مقید با استفاده از الگوریتم نقطه درونی تخمین زده می‌شود. فواصل نقاط شبکه‌ای ۵/۰ درجه در جهات طول و عرض انتخاب شده‌است. همچنین گام‌های زمانی ۱۰ دقیقه در نظر گرفته شده که شروع آن از ساعت صفر روز ۱۲۳ سال ۲۰۱۶ بوده و پایان آن ساعت ۲۳:۵۰ روز ۱۲۸ ام سال ۲۰۱۶ می‌باشد. علت انتخاب این بازه زمانی جهت برآورد ضرایب آن است که همه گونه فعالیت‌های ژئومغناطیسی و یونسفری در این بازه وجود دارد. ارتفاع در نظر گرفته شده برای یونسفر از ۱۰۰ تا ۲۰۰۰ کیلومتری سطح زمین و اختلاف ارتفاع نقاط

۳ Continuity Equation

۱ Recurrent Neural Networks

۲ Assimilation

شبکه‌ای سه بعدی از هم ۵۰ کیلومتر می‌باشد. در نهایت پیش‌بینی چگالی الکترونی یونسفر برای روز ۱۲۹ام انجام گرفته‌است.

رابطه (۱) معادله پیوستگی تغییرات زمانی ماده یونیزه شده در یک حجم واحد را بیان می‌کند. در واقع این معادله فعالیت‌های فتوشیمیایی در یونسفر را که منجر به تولید یون و ناپدید شدن الکترون می‌شود و همچنین پدیده انتقال الکترون را در نظر گرفته و توصیف می‌کند [۳].

$$\frac{\partial p_i}{\partial t} + \text{div} (p_i v_i) = Q_i - M_i \quad (1)$$

در رابطه فوق Q_i نرخ تولید یون و M_i نرخ ناپدید شدن را در واحد حجم بیان می‌کنند. p_i نشان دهنده چگالی نوع i ام یون در پلاسمای یونسفر است. یونسفر به لحاظ بار الکتریکی خنثی محسوب می‌گردد چراکه تعداد الکترون‌هایی که در این محیط تولید می‌شوند و یا از بین می‌روند برابر است با تعداد یون‌های مثبتی که تولید می‌شوند یا از بین می‌روند. جمله $\text{div} (p_i v_i)$ بیانگر تغییرات چگالی گونه یونی i ام با عمل انتقال است. $p_i v_i$ شار بار الکتریکی یا چگالی جریان الکتریکی را نشان می‌دهد. معادله پیوستگی یک معادله دیفرانسیل با مشتقات جزئی غیرخطی بوده که در صورت عدم ساده‌سازی تنها روش حل آن راه حل‌های عددی است. در صورت ساده‌سازی به صورت یک معادله دیفرانسیل معمولی در آمده و به صورت تحلیلی حل می‌گردد. حل معادله پیوستگی در طول روز متفاوت از حل آن در شب انجام می‌پذیرد. در شب فرض می‌شود که تولید الکترون نداشته و $Q = 0$ است. همچنین در لایه‌های پایینی یونسفر انتقال الکترون به علت اصطکاک لایه صورت نمی‌پذیرد.

نرخ تولید متوسط الکترون توسط گازهای یونسفر با میزان شار تابشی دریافتی از خورشید در صفحه افق ارتباط مستقیم دارد.


$$\bar{Q} = \beta_1 I \quad (2)$$

$\bar{Q}$ نرخ تولید متوسط الکترون و I بیانگر میزان شار تابشی دریافتی از خورشید در صفحه افق است.

$$I = I' \cos \chi \quad (3)$$

I' میزان شار دریافتی از خورشید در صفحه عمود بر مسیر تابش و χ زاویه زینتی تابش خورشیدی را نسبت به لایه‌های یونسفر نمایش می‌دهد (شکل ۱). این زاویه را می‌توان بر حسب عرض ژئودتیک نقطه ϕ زاویه میل خورشید δ و زاویه ساعتی خورشید h_s (که تابعی از زمان محلی است)، بدین صورت بازنویسی کرد [۱۴].

$$\cos \chi = \sin \phi \sin \delta + \cos \phi \cos \delta \cos h_s \quad (4)$$



شکل ۱- ثابت خورشیدی، شار تابش خورشیدی در صفحه افق، زاویه اوج تابش خورشیدی و انحراف خورشید [۱۰]

دما، رطوبت، گردوغبار و بخار آب، اثری بر روی شار تابشی خورشید بر یونسفر ندارند، می‌توان شار تابشی خورشید در صفحه عمود بر مسیر تابش I' را که در رابطه فوق بیان شد، ثابت فرض نمود.

نرخ از بین رفتن الکترون بستگی زیادی به ارتفاع یونسفر دارد. این نرخ در ارتفاع‌های پایین‌تر مضربی از چگالی الکترونی است و در ارتفاع‌های بالاتر تابعی درجه ۲ از چگالی الکترونی است. لذا می‌توان این تغییرات را به صورت زیر در نظر گرفت [۱۴]:

$$M = \beta_2 \rho_e^2 + \beta_3 \rho_e \quad (5)$$

اگر در فرایند محاسبات پیش‌بینی، میزان گام‌های زمانی خیلی کوچک فرض شود، به علت پایداری میدان مغناطیسی و الکتریکی پلاسما می‌توان فرآیند انتقال یا $\text{div} (p_i v_i)$ را نیز به صورت یک مقدار اسکالر ثابت β_4 در نظر گرفت. به دلیل آنکه میزان اصطکاک در لایه‌های مختلف متفاوت است لذا مقدار ثابت β_4 در این لایه‌ها نیز متفاوت است. قطر و ابعاد ذرات در یونسفر و دمای بارهای الکتریکی بر مقدار ضریب β_3 اثر می‌گذارد.

به علت ناچیز بودن مقدار چگالی الکترونی لایه D از پیش‌بینی آن صرف‌نظر شده و ۴ ثابت $(\beta_1, \beta_2, \beta_3, \beta_4)$ را در لایه های E (۱۰۰ تا ۲۰۰ کیلومتر)، F1 (۲۵۰ تا ۳۰۰ کیلومتر)، F2 (۳۵۰ تا ۶۰۰ کیلومتر) و بالاتر از F2 (۶۵۰ تا ۲۰۰۰ کیلومتر)، مقادیر متفاوت در نظر گرفته اما مقادیر آنها را در طول یک لایه ثابت فرض می‌نماییم.

در نهایت با صرف نظر کردن از جمله دیورژانس و استفاده از تقریب تفاضلی پیشرو^۱ برای مشتق زمانی، معادله پیوستگی برای هر کدام از ۴ ناحیه مذکور در دو اپک متوالی به صورت زیر بازنویسی می‌گردد:

(۶)

$$\frac{\rho_e(\lambda_{i,j}, \phi_{i,j}, h_k, t_0) - \rho_e(\lambda_{i,j}, \phi_{i,j}, h_k, t_0 - 1)}{\Delta t} = \beta_1 I(\lambda_{i,j}, \phi_{i,j}, h_k, t_0 - 1) - \beta_2 \rho_e(\lambda_{i,j}, \phi_{i,j}, h_k, t_0 - 1) - \beta_3 \rho_e(\lambda_{i,j}, \phi_{i,j}, h_k, t_0 - 1) - \beta_4$$

هر یک از نواحی ۴ مجهول در روز و ۳ مجهول در شب خواهد داشت. چراکه β_1 در شب صفر است. لذا می‌توان با استفاده از یک رگرسیون خطی مقید ضرایب را محاسبه نمود.

جدول ۱ - پارامترهای ورودی به شبکه عصبی

No.	Paremters	Unit
1	Altitude (hight)	kilometer
2	Longitude	Degree
3	Latitude	Degree
4	Time (UT)	Hour
5	Local Time /24	Hour of Day
6	Doy	Day of Year
7	Solar Radiation Flux	W / m ²
8	Kp index	Unitless
9	Ap index	Unitless
10	F10.7 (Daily)	MHz
11	Sunspot Number	Unitless
12	f0F2	MHz
13	NmF2	el / m ⁻³
14	hmF2	kilometer
15	Electron Tepmerature	Kelvin
16	Ne	el / m ⁻³

ضرایب محاسبه شده با رگرسیون به عنوان مقادیر هدف در مقابل دیگر پارامترهای ورودی که در جدول ۱ بیان شده، در شبکه عصبی مصنوعی استفاده می‌شوند. پارامترهای فوق از مرجع بین المللی یونسفر (۱۳ پارامتر) و مرکز تحقیقات علوم زمین آلمان^۲ (GFZ) (۳ پارامتر) برای آموزش شبکه عصبی مصنوعی به کار گرفته شده‌است (جدول ۱). در نهایت پس از ارزیابی و تست شبکه عصبی هر کدام با ۱۵ درصد از داده‌های ورودی، پیش‌بینی ضرایب مدل معادله پیوستگی در گام‌های زمانی بعدی یا همان روز ۱۲۹ ام سال ۲۰۱۶ انجام گردید.

Altitude, Longitude و Latitude موقعیت مکانی شبکه ایجاد شده و منطقه مورد مطالعه را نشان می‌دهند. همچنین باتوجه به اهمیت زمان در مطالعه یونسفر و متغیر بودن پارامترها در طول روز و زمان محلی و زمان سالیانه از سه پارامتر زمان UT و Local و Doy (Day of Year) استفاده گردید.

Solar Radiation Flux یا شار تابش خورشیدی به میزان انرژی خورشید که به یک سطح عمود بر اشعه خورشید در واحد زمان می‌رسد، اطلاق می‌گردد. واحد آن وات بر مترمربع بوده و مقدار آن در طول روز متغیر است. سرعت تولید یون یا الکترون آزاد به مقدار این پارامتر در طول روز بستگی دارد [۹]. Kp Index یک معیار جهانی برای نشان دادن شدت فعالیت‌های ژئومغناطیسی است. این شاخص که مقداری بین صفر تا ۹ دارد، در طول فواصل زمانی سه ساعته و توسط رصدخانه‌هایی در سراسر جهان اندازه‌گیری می‌شود (شکل ۲). مقدار بالاتر این پارامتر نشان دهنده فعالیت بیشتر ژئومغناطیسی است [۱۱]. فعالیت‌های ژئومغناطیسی شدید می‌تواند باعث اختلال در سیستم‌های مخابراتی و ناوبری مانند GPS و تاثیر منفی بر روی عملکرد آنها داشته باشد.

Ap Index دومین شاخص ژئومغناطیسی مورد استفاده در این پژوهش است که درواقع تصویر کلی‌تر از شدت و تغییرات روزانه فعالیت‌های ژئومغناطیسی را نشان می‌دهد. این شاخص برای تحلیل و مطالعات طولانی و دوره‌ای مناسب است.

^۲ The GFZ German Research Centre for Geosciences is the national research centre for Earth sciences in Germany.

^۱ Forward Difference Approximation

Electron Temperature دمای الکترون در ارتفاع و موقعیت مشخص شده آن و Ne نیز مقدار چگالی الکترونی می‌باشند.

۲-۱- رگرسیون خطی مقید با الگوریتم نقطه درونی

بهینه‌سازی^۱ یک فرآیند محاسباتی است که هدف آن یافتن بهترین پاسخ برای یک معادله تحت شرایط و محدودیت‌های خاص است. لذا در مسائل بهینه‌سازی یک هدف مشخص می‌گردد که دستیابی به آن هدف بستگی به متغیرهای^۲ (مجهولات) مسئله و قیود^۳ مربوط به آنها دارد. متغیرها همان مجهولاتی هستند که مقید می‌باشند.

$$\begin{cases} f(x) \rightarrow \min / \max \\ g(x) \leq 0 \\ h(x) = 0 \end{cases} \quad (7)$$


x بردار متغیرهاست و $f(x)$ همان تابع هدف محدب است که باید بهینه گردد. $g(x)$ و $h(x)$ توابع قیدی و محدب هستند که شرایط مسئله را تعریف می‌کنند. رگرسیون خطی مقید^۴ یک مسئله بهینه‌سازی است که در آن هدف، یافتن ضرایب ابر صفحه^۵ است که تابع هزینه را با رعایت برخی قیود، به حداقل برساند. الگوریتم نقطه درونی یکی از روش‌های مؤثر برای حل این نوع مسائل بهینه‌سازی است. فرض می‌گردد مسئله بهینه‌سازی محدب به فرم زیر داده شده‌است:

$$\begin{aligned} & \text{minimize } f(x) \\ & \text{subject to } g_i(x) \leq 0, \quad i = 1, \dots, m \end{aligned} \quad (8)$$

که در اینجا $f(x)$ یک تابع محدب و $g_i(x)$ توابع محدب قیود می‌باشند. برای حل مسئله در الگوریتم نقطه درونی از تابع مانع لگاریتمی استفاده می‌گردد.

$$P(x) = -\sum_{i=1}^m \log(-g_i(x)) \quad (9)$$

این تابع مانع به طوری طراحی شده‌است که وقتی x به مرز ناحیه مجاز نزدیک می‌شود (به عبارت دیگر $g_i(x)$ نزدیک



شکل ۲- مقدار شاخص Kp برای روز ۱۲۹ سال ۲۰۱۶

(<https://www.spaceweatherlive.com>)

F10.7 که جهت نشان دادن مقدار تابش رادیویی خورشید در طول موج ۱۰/۷ سانتی‌متر به صورت روزانه توسط رصدخانه‌های زمینی اندازه‌گیری و گزارش می‌گردد. این شاخص نشان‌دهنده فعالیت بالای خورشیدی است. مقادیر بالای این شاخص بر کیفیت و قابلیت اطمینان سیستم‌های مخابراتی و ناوبری اثر منفی گذاشته و باعث تداخل و افت کیفیت سیگنال‌ها گردد.

Sunspot Number معیاری است برای اندازه‌گیری فعالیت‌های خورشیدی که اشاره به تعداد لکه‌های سیاه روی سطح خورشید دارد. این لکه‌ها در نتیجه فعالیت‌های مغناطیسی خورشید ایجاد شده‌اند. لکه‌های خورشیدی ناشی از فوران‌های خورشیدی باعث تغییرات در جریان‌های الکتریکی و میدان‌های مغناطیسی در یونسفر می‌شود. به همین ترتیب بر سیگنال‌های عبوری از یونسفر (به خصوص در فرکانس‌های بالا) تأثیر دارد.

f0F2 یا فرکانس بحرانی لایه F2 از مهمترین پارامترها در مطالعات یونسفر است. لایه F2 یونسفر همانند یک فیلتر طبیعی برای امواج رادیویی عمل می‌کند. فرکانس بحرانی لایه F2 بیشترین فرکانس قابل عبور از لایه F2 برای رسیدن به فضا است بدون آنکه توسط این لایه بازتاب یابد. این پارامتر برای طراحی سیستم‌های ارتباطی ماهواره‌ای و رادارها نقش بسیار مهمی دارد.

NmF2 و hmF2 به ترتیب حداکثر چگالی الکترونی لایه F2 و ارتفاع مربوط به حداکثر چگالی الکترونی لایه F2 یونسفر می‌باشند.

۴ Constrained Linear Regression

۵ Hyper Plane

۱ Optimization

۲ Variables

۳ Constrains

به صفر می‌گردد) مقدار تابع به سمت بی‌نهایت میل کرده و بدین ترتیب از نقض قیود جلوگیری می‌شود. با استفاده از تابع مانع مسئله بهینه سازی باقیود نامساوی به یک مسئله بدون قید تبدیل می‌شود:

$$\text{minimize } f(x) + \frac{1}{t}P(x) \quad (10)$$

که در آن t به عنوان یک پارامتر مثبت تعیین می‌کند که تابع مانع چقدر بر مسئله اثر می‌گذارد. ابتدا با انتخاب x_0 به عنوان نقطه شروع که در داخل ناحیه مجاز است و مقدار اولیه $t=t_0$ محاسبات آغاز می‌گردد. در هر تکرار مسئله بدون قید، به روش نیوتن حل شده و تابع هدف مینیمم می‌گردد. مقدار t افزایش پیدا کرده که در نتیجه آن تقریب بهبود پیدا می‌کند:

$$t \rightarrow \mu t, \mu > 1 \quad (11)$$

μ یک مقدار ثابت می‌باشد. حل مسئله در صورت همگرایی یا رسیدن به تعداد تکرارهای مشخص متوقف می‌گردد. این روش برای مسائل بهینه سازی محدب بزرگ مقیاس بسیار موثر می‌باشد [۲].

۲-۲- شبکه عصبی مصنوعی پیشخور^۱

شبکه عصبی مصنوعی یک مدل محاسباتی الهام گرفته از ساختار و عملکرد مغز انسان است. آنها از واحدهای پردازشی به نام نورون تشکیل شده که به یکدیگر متصل هستند که امکان پردازش، یادگیری الگوها و انتقال اطلاعات را دارند. شبکه عصبی مصنوعی می‌توانند از طریف فرایندی به نام یادگیری ماشین^۲ آموزش ببینند. در این فرآیند به شبکه عصبی، حجم زیادی از اطلاعات داده می‌شود و شبکه به طور خودکار یاد می‌گیرد که روابط و الگوی موجود بین داده‌ها را کشف کند.

۲-۲-۱- اجزای اصلی یک شبکه عصبی مصنوعی

• **نورون‌ها:** که واحدهای پردازشی اولیه شبکه هستند. آنها ورودی‌هایی را دریافت و آنها را با استفاده از یک تابع فعال‌ساز پردازش و خروجی را تولید می‌کنند.

نورون‌ها درون لایه‌ها به صورت لایه ورودی، لایه پنهان و لایه خروجی سازماندهی می‌شوند.

• **اتصالات:** که وظیفه آنها اتصال بین نورون‌ها است. هر اتصال دارای یک وزن بوده که قدرت سیگنال منتقل شده بین دو نورون را تعیین می‌کند.

• **توابع فعال‌ساز:**^۳ که تعیین کننده پاسخ هر نورون به ورودی‌ها می‌باشد. از رایج‌ترین توابع فعال‌ساز می‌توان موارد زیر را نام برد:

$$f(x) = x \quad \text{تابع خطی} \quad (12)$$

$$u_c(x) = \begin{cases} 0 & x < c \\ 1 & x > c \end{cases} \quad \text{تابع پله‌ای} \quad (13)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad \text{تابع تانژانت هایپربولیک} \quad (14)$$

$$S(x) = \frac{1}{1 + e^{-x}} \quad \text{تابع سیگموئید} \quad (15)$$

$$f(x) = \begin{cases} 0 & x < 0 \\ x & x \geq 0 \end{cases} \quad \text{ReLU تابع} \quad (16)$$

$$f(x) = \begin{cases} x & x \geq 0 \\ ax & x < 0 \end{cases} \quad \text{Leaky ReLU تابع} \quad (17)$$

$$S(x) = \frac{x}{1 + e^{-x}} \quad \text{Swish تابع} \quad (18)$$

شبکه عصبی پیشخور از رایج‌ترین شبکه‌های عصبی مصنوعی است که در آن اتصالات بین نورون‌ها فقط در یک جهت، از لایه ورودی به لایه خروجی جریان داشته و هیچ حلقه‌ای در آن وجود ندارد. هر شبکه عصبی می‌تواند چندین لایه پنهان داشته باشد که هر نورون آن به تمامی نورون‌های لایه قبلی و لایه بعدی متصل است. آموزش شبکه عصبی پیشخور از الگوریتم پس انتشار خطا^۴ (BP) استفاده می‌کند که شامل مراحل زیر است:

• **انتشار رو به جلو (Forward Propagation):** ورودی‌ها از طریق شبکه جریان می‌یابند و خروجی محاسبه می‌شود.


^۳ Activation Function

^۴ Backpropagation

^۱ FeedForward Neural Network

^۲ Machine Learning

در بخش ۲-۲، مقادیر مربوط به روز ۱۲۹ به شبکه عصبی پیشخور آموزش دیده وارد و به ازای هر لایه برای یک گام زمانی، ۴ پارامتر معادله پیوستگی پیش بینی می‌شود. با قراردادن چهار پارامتر در معادله (۱۵) برای هر نقطه شبکه‌ای با حل این معادله دیفرانسیلی به روش رانگ-کوتا^۱ مرتبه چهارم، مقادیر چگالی الکترونی یونسفر در گام زمانی بعدی پیش بینی می‌شوند [۱۲].



شکل ۴ - نمودار فرآیند کلی محاسبات

روش رانگ-کوتا مرتبه چهارم یکی از محبوب‌ترین و پرکاربردترین روش‌های عددی برای حل معادلات دیفرانسیل معمولی (ODE) است. این روش به دلیل دقت بالا و پایداری مناسب، در بسیاری از مسائل مهندسی و علوم کاربردی استفاده می‌شود. در این روش بر اساس تقریب مشتق با استفاده از ترکیب خطی وزن‌دار از شیب‌های تابع در نقاط مختلف در یک بازه کوچک است. این فرایند به صورت تکراری برای پیش‌بینی مقدار تابع در گام بعدی انجام می‌شود.

مزیت اصلی روش رانگ-کوتا مرتبه چهارم، دقت بالای آن در مقایسه با روش‌های ساده‌تر مانند روش اویلر^۲ است. البته، پیچیدگی محاسباتی آن نیز بیشتر است.

• **محاسبه خطا (Error Calculation):** تفاوت بین خروجی پیش بینی شده و خروجی واقعی محاسبه می‌گردد.

$$Error = y_{true} - y_{pred} \quad (19)$$


• **انتشار به عقب (Backward Propagation):** خطا به عقب در شبکه انتشار می‌یابد و گرادیان‌ها محاسبه می‌شوند.

• **به‌روزرسانی وزن‌ها (Weight Update):** وزن‌ها با استفاده از روش گرادیان نزولی اصلاح می‌گردند.

$$w_{i+1} = w_i - \eta \frac{\partial Error}{\partial w_i} \quad (20)$$

که در آن η نرخ یادگیری (Learning Rate) و w_i وزن اولیه و w_{i+1} وزن ثانویه است.

در این پژوهش از شبکه عصبی پیشخور با یک لایه ورودی شامل ۱۶ نورون، دو لایه پنهان با ۳۲ و ۱۶ نورون و لایه خروجی با ۴ نورون استفاده شده است (شکل ۳). الگوریتم آموزشی Levenberg-Marquardt است که معروف‌ترین الگوریتم بین روش‌های مبتنی بر ناحیه اطمینان (Trust region) می‌باشد. مزیت این الگوریتم سرعت، دقت و قابلیت اطمینان بیشتر به جهت عدم گیرافتادن در مینیمم‌های محلی است [۱].



شکل ۳ - نمودار شبکه عصبی پیشخور بکاررفته در این پژوهش

۲-۳- پیش‌بینی با معادله پیوستگی

پس از آموزش شبکه با داده‌های مربوط به روزهای ۱۲۳ تا ۱۲۸ ام ماه می سال ۲۰۱۶ و باتوجه به فرضیات ارائه شده

^۲ Euler

^۱ Runge-Kutta

۳- ارزیابی و راست آزمایی

۳-۱- چگالی الکترونی یونسفر (Ne)

اشکال شماره ۵ و ۶ مقادیر چگالی الکترونی حاصل از شبکه IRI و مقدار پیش‌بینی و وابستگی این دو مقدار برای اپک‌های زمانی 0:00 UT و 11:00 UT نمایش داده شده‌اند. سه شکل اول مربوط به پیش‌بینی ۱ ساعته، سه شکل دوم پیش‌بینی ۲ ساعته و سه شکل سوم مربوط به پیش‌بینی ۳ ساعته در اپک زمانی مورد نظر می‌باشد. در اپک زمانی 0:10 UT ضریب همبستگی در یک ساعته ۰/۹۸، دو ساعته ۰/۸۹ و سه ساعته ۰/۷۸ بوده که نشان‌دهنده همبستگی بسیار قوی بین مقادیر پیش‌بینی شده و مقادیر IRI در یک ساعت است.

$$Y^{n+1} = Y^n + \left(\frac{\Delta h}{6}\right)(\lambda_1 + 2\lambda_2 + 2\lambda_3 + \lambda_4)$$


$$\lambda_1 = f(h_n, Y^n)$$

$$\lambda_2 = f\left(h_n + \frac{\Delta h}{2}, Y^n + \frac{\Delta t}{2} \lambda_1\right) \quad (21)$$


$$\lambda_3 = f\left(h_n + \frac{\Delta h}{2}, Y^n + \frac{\Delta h}{2} \lambda_2\right)$$

$$\lambda_4 = f(h_n + \Delta h, Y^n + \Delta h \lambda_3)$$

Y^n تقریب عددی جواب در گام n ام، Δh اندازه گام و ضرایب $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ شیب تقریبی در نقاط مختلف واقع در بازه $[h_n, h_n + \Delta h]$ می‌باشند. طرح کلی و فرآیند محاسبات در پژوهش پیش رو به صورت شکل ۴ خواهد بود.




شکل شماره ۵ - چگالی الکترونی حاصل از IRI، چگالی الکترونی پیش‌بینی و وابستگی بین آنها در اپک زمانی 0:10 UT در فواصل زمانی یک ساعته (سطر اول)، دو ساعته (سطر دوم) و سه ساعته (سطر سوم)



شکل شماره ۶- چگالی الکترونی حاصل از IRI، چگالی الکترونی پیش‌بینی و وابستگی بین آنها در اپک زمانی 11:10 UT در فواصل زمانی یک ساعته (سطر اول)، دو ساعته (سطر دوم) و سه ساعته (سطر سوم)


در شکل ۷ مقدار RMS اختلاف بین چگالی الکترونی پیش‌بینی و IRI در فواصل زمانی ۲۰، ۳۰ و ۴۰ دقیقه و در شکل ۸ در فواصل زمانی ۱، ۲ و ۳ ساعته نمایش داده شده‌اند.



شکل ۸- مقدار RMS اختلاف چگالی الکترونی پیش‌بینی و IRI در فواصل زمانی ۱، ۲ و ۳ ساعت

میانگین RMS اختلاف بین چگالی الکترونی پیش‌بینی و IRI در کل دوره پژوهش در فواصل زمانی مشخص، در جدول ۲ آورده شده‌است.

اما همانطوری که انتظار داشتیم به مرور این مقدار کاهش پیدا می‌کند که نشان دهنده کمتر شدن دقت پیش‌بینی‌ها است (شکل ۵). همین نکته در اپک زمانی 11:10 UT نیز برقرار بوده‌است. ضریب همبستگی در یک ساعت ۰/۹۹، دو ساعته ۰/۹۸ و سه ساعته ۰/۹۷ برقرار بوده‌است و مقادیر بهتری از اپک زمانی 0:10 UT دارند (شکل ۶).



شکل ۷- مقدار RMS اختلاف چگالی الکترونی پیش‌بینی و IRI در فواصل زمانی ۲۰، ۳۰ و ۴۰ دقیقه

جدول ۲- میانگین RMS اختلاف چگالی الکترونی پیش‌بینی و IRI


ردیف	مدت زمان پیش‌بینی	میانگین RMS
۱	۱۰ دقیقه	4.6946e+09
۲	۲۰ دقیقه	9.4761e+09
۳	۳۰ دقیقه	1.4270e+10
۴	۴۰ دقیقه	1.9000e+10
۵	۱ ساعت	2.3733e+10
۶	۲ ساعت	5.1694e+10
۷	۳ ساعت	1.0943e+11

(۲۲) انجام و با مقادیر این پارامتر که از IRI دریافت شده‌است، راستی‌آزمایی گردید [۳، ۱۰].


$$f0F2 \approx 9 \times \sqrt{Ne_{\max}} \quad (22)$$

در رابطه فوق که یک رابطه تقریبی است، $Ne_{\max}$ بیشترین چگالی الکترونی که معمولاً در لایه F2 اتفاق می‌افتد. این مقادیر برای کل محدوده مورد مطالعه (ایران) محاسبه شده‌است.

در اشکال ۹ و ۱۰ پیش‌بینی مقادیر $f0F2$ در اپک‌های 0:00 UT و 11:00 UT و مقدار RMS حاصل از اختلاف مقادیر پیش‌بینی و مقادیر دریافت شده از IRI را که در مدت زمان ۳ ساعت و در فواصل زمانی ۱۰ دقیقه انجام شده‌است، نشان می‌دهد.



شکل شماره ۱۰- مقادیر دریافتی از IRI (بالا)، مقادیر $f0F2$ پیش‌بینی (وسط) و مقادیر RMS اختلاف مقادیر $f0F2$ آنها (پایین) در اپک زمانی 11:00 UT در مدت زمان سه ساعت با فواصل ۱۰ دقیقه‌ای




شکل شماره ۹- مقادیر دریافتی از IRI (بالا)، مقادیر $f0F2$ پیش‌بینی (وسط)، و مقادیر RMS اختلاف مقادیر $f0F2$ آنها (پایین) در اپک زمانی 00:00 UT در مدت زمان سه ساعت با فواصل ۱۰ دقیقه‌ای


۳-۲- فرکانس بحرانی لایه F2 ($f0F2$)

هم‌زمان با انجام پیش‌بینی چگالی الکترونی یونسفر، پیش‌بینی مقدار پارامتر $f0F2$ با استفاده از مدل چپمن (رابطه

همچنین مقادیر RMS اختلاف f0F2 پیش بینی و IRI در فواصل زمانی ۱ ساعت، ۲ ساعت و ۳ ساعت در شکل ۱۱ و برای فواصل زمانی ۲۰ دقیقه، ۳۰ دقیقه و ۴۰ دقیقه در شکل ۱۲ نمایش داده شده‌اند.



شکل ۱۱- مقدار RMS اختلاف f0F2 پیش بینی و IRI در فواصل زمانی ۱، ۲ و ۳ ساعت



شکل ۱۲- مقدار RMS اختلاف f0F2 پیش بینی و IRI در فواصل زمانی ۲۰، ۳۰ و ۴۰ دقیقه

۴- نتیجه گیری و پیشنهادات

با توجه به پاشنده^۱ بودن محیط یونسفر نسبت به امواج الکترومغناطیس و اثر آن بر روی ارتباطات رادیویی، شناخت هرچه بیشتر این محیط مورد توجه پژوهشگران بسیاری در این حوزه قرار گرفته‌است. این پاشندگی ارتباط بسیار زیادی با میزان چگالی الکترونی موجود در لایه‌های مختلف یونسفر که مقدار آن در اثر فعالیت‌های خورشیدی و تغییرات ژئومغناطیسی زمین دچار تغییر می‌شود؛ دارد. از این میان پارامترهای فیزیکی متعددی جهت مطالعه با رویکردهای مختلف مدل سازی یونسفر، تعریف شده و به کار رفته‌است. مدل سازی فیزیکی یونسفر به دلیل سختی و پیچیدگی‌هایی که دارد کمتر مورد توجه پژوهشگران قرار گرفته‌است.

در منطقه مورد مطالعه (ایران) یک شبکه سه بعدی ساخته شد و داده‌های مدل مرجع بین المللی یونسفر (IRI) برای روزهای ۱۲۳ تا ۱۲۸ با فواصل زمانی ۱۰ دقیقه دریافت گردید.

ناحیه یونسفر به ۴ لایه از لحاظ ارتفاعی تقسیم شد و در هر لایه پارامترهای موثر بر معادله پیوستگی با استفاده از کمترین مربعات مقید و با حل به شیوه نقطه درونی محاسبه گردید. پارامترهای محاسبه شده به عنوان مقادیر هدف در آموزش شبکه عصبی استفاده شد. در این پژوهش از ۱۶ پارامترهای فیزیکی یونسفر به عنوان داده ورودی جهت آموزش شبکه عصبی مصنوعی استفاده گردید.

نهایتاً با استفاده از شبکه عصبی آموزش دیده برای پیش بینی پارامترهای معادله پیوستگی در هر لایه یونسفر و برای گام زمانی بعدی استفاده شد. پارامترهای پیش بینی شده در معادله پیوستگی قرار گرفته و سپس چگالی الکترونی نقاط شبکه‌ای برای گام زمانی بعدی از حل معادله دیفرانسیل وابسته به زمان به شیوه رانگ-کوتا پیش بینی شد.

براساس مقادیر شاخص Kp Index (شکل ۲) بالاترین میزان فعالیت‌های ژئومغناطیسی یونسفر در روز پیش بینی، ۶/۳۳ و کمترین آن ۴/۶۷ بوده‌است. درواقع برای روز ۱۲۹ فعالیت‌های نسبتاً شدید ژئومغناطیسی به نسبت دیگر روزهای سال ۲۰۱۶ ثبت شده‌است. این موضوع یکی از چالش‌های این پژوهش در دستیابی به دقت مناسب نتایج بوده‌است. با مقایسه و بررسی نمودارهای همبستگی بین مشاهدات چگالی الکترونی IRI و چگالی الکترونی حاصل از پیش بینی در ساعت ۱۱:۱۰ مقادیر ضریب همبستگی بالاتری به نسبت ساعت ۰:۱۰ (شکل ۵) حاصل شده‌است. این نتیجه برای زمانی است که Kp index کمترین مقدار (ساعت ۹ الی ۱۲) خود را داشته‌است. از طرفی در نمودارهای RMS اختلاف مشاهدات IRI و پیش بینی چگالی الکترونی (شکل‌های ۷ و ۸) کمترین میزان RMS در همین زمان بدست آمده‌است. با انجام پیش بینی در گام‌های زمانی بعدی و فاصله گرفتن از مبدأ زمان پیش بینی‌ها همانطور که انتظار می‌رفت مجدداً دقت مقادیر RMS مجدداً افزایش داشته‌است. RMS اختلاف مقادیر پیش بینی چگالی الکترونی و داده‌های شبکه آنالیز در پژوهش محبوبی در سال ۲۰۲۲ که با استفاده از داده‌های یک مدل منطقه‌ای داده‌گواری شده که به عنوان شرایط اولیه به معادله پیوستگی داده شده‌است، برای پیش بینی‌های یک ساعته، دوساعته و سه ساعته به ترتیب 1.0×10^{-1} ، 0.8×10^{-1} و 0.33×10^{-1} می‌باشد

^۱ Dispersive

[۱۰]. این نتایج در مقایسه با نتایج بدست‌آمده از این پژوهش مقادیر بهتری است.

دقت بالاتر پیش‌بینی چگالی الکترونی حاصل از یک شبکه داده‌گواری شده ناشی از دقیق‌تر بودن مقادیر چگالی الکترونی وارد شده به محاسبات است. هدف اصلی داده‌گواری این است که با ترکیب داده‌های واقعی با نتایج مدل‌های عددی، یک تخمین بهتر و دقیق‌تر از وضعیت کمیت مورد مطالعه را نتیجه دهد.

برهمن اساس اگر پارامترهای ورودی با دقت بالا اندازه‌گیری یا محاسبه شده باشند، شبکه عصبی مصنوعی نیز قادر خواهد بود الگوهای صحیح‌تری از داده‌ها بیاموزد و در نتیجه پیش‌بینی‌های بهتری انجام دهد. از سوی دیگر در صورت وجود خطا، نویز در شبکه یا عدم دقت داده‌های ورودی، ممکن است شبکه عصبی مصنوعی نتواند الگوهای دقیق را استخراج کرده و دچار عدم همگرایی یا همگرایی به یک جواب غیربهینه شود. در نهایت این موضوع می‌تواند باعث کاهش دقت نهایی پیش‌بینی‌ها، عدم درک صحیح اثرات پارامترهای فیزیکی مختلف و افزایش زمان لازم برای آموزش مدل شود.

مراجع

با توجه به حجم بسیار بالای داده‌های مورد استفاده و پیچیدگی‌های مدل‌سازی فیزیکی یونسفر، می‌توان اظهارداشت دقت و مقادیر بدست آمده تا حدود زیادی انتظارات را برآورده نموده‌است.

به جهت افزایش دقت، انتخاب فواصل زمانی مناسب‌تر داده‌ها با توجه به پایداری یونسفر در فواصل زمانی کم، باعث کاهش حجم محاسبات خواهد شد. از طرفی برخی ساده‌سازی‌ها در حل معادله پیوستگی باعث عملکرد مناسب مدل در پیش‌بینی چگالی الکترونی یونسفر در لایه‌های مختلف خواهد شد.

همچنین می‌توان با بهره‌گیری از روش‌های یادگیری عمیق در شبکه‌های عصبی مصنوعی که توان بیشتری برای آموزش بهتر با داده‌های با حجم بالا را دارند، نسبت به دستیابی به دقت بیشتر در پیش‌بینی چگالی الکترونی یونسفر اقدام نمود و از نتایج آن برای محاسبه محتوای الکترونی کل قائم در تعیین موقعیت‌های آبی و نزدیک به آبی استفاده نمود.

- [1] Ali, F., Hou, Y., & Feng, X. (2023). Backpropagation of Levenberg–Marquardt artificial neural networks for reverse roll coating process in the bath of Sisko fluid. *The European Physical Journal Plus*, 138(10), 944. doi: <https://doi.org/10.1140/epjp/s13360-023-04579-w>
- [2] Boyd, S., & Vandenberghe, L. (2004). *Convex Optimization*. Cambridge: Cambridge University Press
- [3] Chapman, S. (1931). The absorption and dissociative or ionizing effect of monochromatic radiation in an atmosphere on a rotating earth part II. Grazing incidence. *Proceedings of the Physical Society*, 43(5), 483. doi: <https://doi.org/10.1088/0959-5309/43/5/302>
- [4] Dutta, S., & Cohen, M. B. (2023). Topside Electron Density Modeling Using Neural Network and Empirical Model Predictions. *Space Weather*, 21(12), e2023SW003501. Doi: <https://doi.org/10.1029/2023SW003501>
- [5] Gholipour, N. (2019). Ionosphere total electron content prediction based on Kalman filter and artificial neural networks hybrid approach using GPS observations. (M.Sc. Thesis in Geomatics Engineering-Geodesy). K. N. Toosi University of Technology
- [6] Habarulema, J. B., Okoh, D., Burešová, D., Rabiú, B., Scipión, D., Häggström, I., . . . Milla, M. A. (2024). A storm-time global electron density reconstruction model in three-dimensions based on artificial neural networks. *Advances in Space Research*. doi: <https://doi.org/10.1016/j.asr.2024.02.014>
- [7] Huang, S., Li, W., Shen, X.-C., Ma, Q., Chu, X., Ma, D., . . . Goldstein, J. (2022). Application of Recurrent Neural Network to Modeling Earth's Global Electron Density. *Journal of Geophysical Research: Space Physics*, 127(9), e2022JA030695. doi: <https://doi.org/10.1029/2022JA030695>
- [8] Liu, B., Wang, M., Zhang, S., Wang, X., Nemati, S., Li, H., . . . Xu, J. (2024). Inversion of the Electron Density in the Lower Ionosphere Using Artificial Intelligence. *IEEE Antennas and Wireless Propagation Letters*, 23(5), 1618-1622. doi: <https://doi.org/10.1109/LAWP.2024.3364089>
- [9] Li, J., Huang, D., Wang, Y., Zhao, Y., & Hassan, A. (2020). A new model for total electron content based on ionospheric continuity equation. *Advances in Space Research*, 66(4), 911-931. doi: <https://doi.org/10.1016/j.asr.2020.04.048>

- [10] Mahbuby, H. (2022). Regional Assimilation of GPS-Derived Ionospheric Electron Densities into the Physical Model of Ionosphere. (Doctor of Philosophy (Ph.D.) in Geodesy). K. N .Toosi University of Technology
- [11] Matzka, J., Stolle, C., Yamazaki, Y., Bronkalla, O., & Morschhauser, A. (2021). The Geomagnetic Kp Index and Derived Indices of Geomagnetic Activity. Space Weather, 19(5), e2020SW002641. doi:<https://doi.org/10.1029/2020SW002641>
- [12] Morton, K. W., & Mayers, D. F. (2005). Numerical solution of partial differential equations: an introduction: Cambridge university press.
- [13] Norsuzila, Y. a., Mardina, A., & Mahamod, I. (2010). GPS Total Electron Content (TEC) Prediction at Ionosphere Layer over the Equatorial Region. In J. B. Christos (Ed.), Trends in Telecommunications Technologies (pp. Ch. 23). Rijeka: IntechOpen.
- [14] Prölss, G. (2004). Physics of the Earth's Space Environment: An Introduction: Springer Berlin Heidelberg
- [15] Zolesi, B., & Cander, L. R. (2014). Ionospheric Models for Prediction and Forecasting. In Ionospheric Prediction and Forecasting (pp. 101-121). Berlin, Heidelberg: Springer Berlin Heidelberg.