

ترکیب شبکه عصبی با الگوریتم ژنتیک جهت پیش‌بینی درخشش یونسفری با استفاده از پارامتر S4 و مشاهدات سیستم تعیین موقعیت جهانی

علیرضا عتباتی^۱، محمدمهدی علیزاده الیزئی^{۲*}

۱- دانشجوی کارشناسی ارشد ژئودزی دانشکده نقشه‌برداری دانشگاه صنعتی خواجه نصیرالدین طوسی

۲- استادیار دانشکده نقشه‌برداری دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ دریافت مقاله: ۱۳۹۷/۱۰/۰۸ تاریخ پذیرش مقاله: ۱۳۹۷/۱۱/۱۳

چکیده

جوشش‌های پلاسمای یونسفری معمولاً سبب ایجاد تغییراتی نامنظم در چگالی الکترونی یونسفر می‌شوند. این تغییرات در فاز سیگنال ارسالی از ماهواره تأثیر گذاشته و در نهایت مجموعه‌ای از این تغییرات در لایه یونسفر سبب ایجاد پدیده‌ای به نام درخشش یونسفری می‌شود. این پدیده به صورت نامنظم رخ می‌دهد و درصد رخداد آن در نواحی با عرض جغرافیایی پایین نسبت به مناطق با عرض جغرافیایی متوسط و بالا بیشتر است. در نواحی استوایی احتمال وقوع این پدیده معمولاً پس از غروب خورشید افزایش می‌یابد که می‌توان اغتشاشات پلاسما را به‌عنوان یکی از عوامل وقوع این پدیده در این بازه زمانی دانست. پژوهش حاضر پیرامون مدل‌سازی و در نهایت پیش‌بینی درخشش یونسفری با استفاده از پارامترهای فیزیکی مرتبط با این پدیده می‌باشد. مدل‌سازی انجام شده در این پژوهش با استفاده از روش شبکه عصبی و ترکیب آن با الگوریتم ژنتیک که نوعی الگوریتم جهت برآورد مینیمم مطلق برای وزن‌های شبکه عصبی می‌باشد و نتایج حاصل از آن نسبت به مدل‌سازی با شبکه‌های عصبی که تنها متمرکز بر روش‌های کمترین مربعات می‌باشند، دقیق‌تر است. این مدل‌سازی برای محدوده عرض‌های جغرافیایی پایین و منطقه نزدیک به استوا انجام گرفته و به این منظور ایستگاه‌های مشاهداتی گوام (GUAM) متعلق به سرویس IGS واقع در کشور گوام و با طول ۱۴۴.۸۶۸۳ و عرض جغرافیایی ۱۳.۵۸۹۳ می‌باشد، انتخاب شده است که درخشش یونسفری در این محدوده با میزان ۲۰ درجه اختلاف نسبت به استوا، پدیده‌ای غالب است. این مدل‌سازی برای ماه ژوئن سال ۲۰۱۷ انجام گرفته و به‌واسطه آن یک پیش‌بینی عددی به کمک داده‌های فیزیکی یونسفر برای روز اول ماه جولای سال ۲۰۱۷ که روز بعد از این مدل‌سازی است، انجام گرفته است. مدل طراحی شده در این پژوهش توانایی پیش‌بینی روزانه برای پدیده درخشش یونسفری در منطقه مورد مطالعه را با دقتی در حدود ۷۸ درصد داراست.

کلیدواژه‌ها: شبکه عصبی، الگوریتم ژنتیک، درخشش یونسفری.

* نویسنده مکاتبه کننده: تهران - خیابان ولیعصر - بالاتر از میرداماد - پلاک ۱۳۴۶ - دانشگاه صنعتی خواجه نصیرالدین طوسی - دانشکده مهندسی ژئودزی و ژئوماتیک

تلفن: ۰۲۱۸۸۸۷۷۰۷۰-۱

Email: alizadeh@kntu.ac.ir

۱- مقدمه

درخشش یونسفری یکی از پدیده های رایج یونسفری است که باعث ایجاد اثرات تخریبی بر سیگنال های رادیویی مانند سیگنال ارسالی از ماهواره های سیستم تعیین موقعیت جهانی (GNSS) می شود. درخشش یونسفری می تواند با ایجاد اختلالاتی، منجر به تغییر در اندازه گیری فاصله میان ماهواره و گیرنده شده که می تواند با اثرگذاری بر فاز و دامنه سیگنال ارسالی، سبب ایجاد تغییرات زیاد در مشاهدات گیرنده شود [۱]. پدیده درخشش یونسفری قابلیت تاثیرگذاری بر دامنه و فاز موج حامل سیگنال ارسالی را داراست. به بیان دیگر می توان گفت که درخشش یونسفری دامنه قادر است نوساناتی در شدت سیگنال ارسالی ماهواره ایجاد کرده و باعث افزایش میزان نسبت سیگنال به نویز (SNR) در موج ارسالی از سوی ماهواره شود. به علاوه این پدیده قادر است نوساناتی شدید را در فاز موج حامل ارسالی از ماهواره ایجاد کند [۲].

یکی از پدیده های شاخص در یونسفر که سبب ایجاد اغتشاشات در دامنه و فاز امواج رادیویی می شود پدیده ای به نام درخشش یونسفری^۱ است. تاثیرات خورشید بر روی یونسفر زمین تاثیر بسزایی در رخداد این پدیده داشته که می توان گفت که در بیشتر مواقع دلیل ایجاد این اغتشاشات، انعکاس در امواج رادیویی و همچنین ساختار پلاسمای یونسفر^۲ است [۳]. این پدیده بیشتر در محدوده با ۲۰-۱۵ درجه از استوا رخ می دهد که به آن آنامولی یونسفری استوایی^۳ اطلاق می شود که این محدوده در مناطقی با عرض جغرافیایی پایین^۴ قرار داشته و دارای میزان چگالی الکترونی بالاتری نسبت به سایر مناطق است [۴]. در منطقه آنامولی یونسفری استوایی در حوالی غروب خورشید

میزان سرعت حرکت عمودی لایه های یونسفری^۵ افزایش یافته و به تبع آن سبب افزایش ارتفاع لایه F می شود؛ در این هنگام میزان گرادیان لایه های پایینی یونسفر افزایش یافته و به سبب آن میزان جوش های پلاسما یونسفری^۶ نیز افزایش می یابد. این افزایش به دلیل فرآیندی ناپایدار به نام Rayleigh-Taylor رخ می دهد و منجر به ایجاد اغتشاشات در یونسفر می شود [۳]. جوش های پلاسمای یونسفری با نیرویی به اندازه بردار $E \times B$ رو به بالا حرکت می کند که این نیرو تولید شده از یک دوقطبی الکترونی ایجاد می شود که پس از رسیدن به بالاترین حد ارتفاعی خود در دو طرف و به دو سوی شمالی و جنوبی استوا گسترش یافته که دلیل ایجاد آنامولی یونسفری استوایی به اندازه ۱۵ درجه از استوا به سمت جنوب و شمال مدار استوایی می شود [۵]. پلاسمای ضعیف شده^۷ که در فرآیند جوشش شرکت نموده با پلاسمای متراکم شده و واکنش داده نشده ای که در یونسفر استوایی تولید شده، ترکیب می شود که سبب ایجاد یک گرادیان قوی در ساختار یونسفری می شود که این فرآیند سبب رخداد بی نظمی های شدید در این منطقه شده که منجر به افزایش درخشش یونسفری در مناطق استوایی یونسفر می شود [۶]. درخشش های یونسفری در این ناحیه بیشتر از نواحی استوایی است، علاوه بر این میزان دوره های خورشیدی نیز باعث افزایش شدت این پدیده در مناطق استوایی می شود [۱].

درخشش یونسفری می تواند باعث ایجاد اختلالاتی شود که سبب تغییر در اندازه گیری فاصله میان ماهواره و گیرنده شده و نیز می تواند با اثرگذاری بر فاز و دامنه سیگنال ارسالی باعث ایجاد تغییرات زیاد در مشاهدات گیرنده گردد. پدیده درخشش یونسفری قابلیت تاثیرگذاری بر دامنه و فاز موج حامل سیگنال ارسالی را

^۱ Ionospheric Scintillation^۲ Ionospheric Plasma^۳ Equatorial Ionospheric Anomaly^۴ Low Latitudes^۵ Vertical Drift Velocity^۶ Ionospheric Plasma Bubbles^۷ Depleted Plasma

در مشاهدات سیستم‌های ماهواره‌ای ناوبری جهانی^۳ (GNSS) و در نتیجه سبب افزایش میزان دقت در کارکرد ارتباطات ماهواره‌ای و ناوبری شود [۸]. تاکنون مدل‌هایی تجربی جهت تخمین میزان درخشش یونسفری دامنه و فاز به چاپ رسیده است [۹-۱۱]. تاکنون راه‌حلی قطعی برای مدل‌سازی این پدیده با استفاده از روش‌های عددی ارائه نشده است، لذا برای مدل‌سازی اینگونه پدیده‌ها روش‌های بر مبنای ریاضی با استفاده از پارامترهای تجربی می‌تواند کارگشا باشد. در برخی از مدل‌های تجربی از پارامترهایی همچون طول و عرض جغرافیایی، فصل و زمان برداشت مشاهدات به‌عنوان ورودی استفاده شده است، این در حالی است پدیده درخشش یونسفری علاوه بر پارامترهای مکانی از پارامترهای فیزیکی یونسفری نیز تاثیر می‌پذیرد [۸]. داس و همکاران درصد رخداد درخشش یونسفری را برای یک دوره یازده ساله به‌صورتی مدل‌سازی کردند که برای هر روز عددی را به‌عنوان میانگین درخشش یونسفری همان روز و به‌عنوان ورودی مدل محاسبه کرده‌اند [۱۲]. در این مدل‌سازی از شبکه عصبی استفاده شده است و پارامترهایی نظیر شار خورشیدی، شماره ماه و نیز ساعت رخداد را نیز به‌عنوان ورودی‌های دیگر مدل در نظر گرفته‌اند و بر این اساس، مدلی برای درخشش یونسفری ابداع کردند. نکته‌ای که می‌توان درخصوص این مدل‌سازی گفت این است که به دلیل بزرگی بازه زمانی انتخاب شده در احتساب درخشش‌های یونسفری به صورت روزانه و نیز عدم استفاده از پارامترهای تاثیرگذار فیزیکی دیگر در این مدل‌سازی، نمی‌توان انتظار دقتی بالا برای پیش‌بینی پدیده درخشش‌های یونسفری از این مدل داشت. رزنده، دی پائولا و همکاران با استفاده از روش یادگیری ماشین و از طریق روش درخت تصمیم‌گیر و استفاده از بیشترین مشاهدات میزان درخشش یونسفری

داراست به بیان دیگر می‌توان گفت که درخشش یونسفری دامنه قادر است نوساناتی در شدت سیگنال ارسالی ماهواره ایجاد کرده و باعث افزایش میزان نسبت سیگنال به نویز (SNR) در موج ارسالی از سوی ماهواره گردد. بعلاوه این پدیده قادر است نوساناتی شدید را در فاز موج حامل ارسالی از ماهواره ایجاد کند [۲]. درخشش یونسفری دامنه می‌تواند سبب کاهش سطح سیگنال ارسالی از ماهواره تا حد آستانه قفل گیرنده شده و یا در مواقع درخشش‌های شدید یونسفری می‌تواند باعث محو شدن سیگنال^۱ ارسالی از ماهواره شود. در زمان درخشش یونسفری این پدیده می‌تواند با ایجاد بی‌نظمی‌هایی در ضریب شکست محیط، باعث انحراف سیگنال در جهات تصادفی حول محور اصلی انتشار آن شود. در مسیر انتشار موج این تغییرات کوچک فاصله سبب ایجاد تداخل در درون سیگنال شده و نتیجه آن تضعیف و تقویت متناوب سیگنال در امتداد محور انتشار آن است. تاثیر درخشش‌های یونسفری بر فاز موج حامل می‌تواند سبب ایجاد جهش فاز و قطع سیگنال گیرنده و از دست دادن داده مورد نظر شود. درخشش یونسفری فاز می‌تواند یک شیفت فرکانسی در سیگنال ایجاد کند و سبب افزایش میزان پهنای باندهای که باعث قفل شدن فاز گیرنده شود، می‌گردد و نیز سبب کاهش دقت توانایی گیرنده برای اتصال و قفل به سیگنال ارسالی از ماهواره می‌شود [۱]. این فرآیند سبب افزایش میزان پارامتر تفکیک هندسی دقیق^۲ (GDOP) و در نتیجه باعث افزایش میزان خطا در تعیین موقعیت مکان گیرنده شده و نتیجه آن سبب کاهش توانایی گیرنده در دریافت و ردیابی سیگنال ارسالی می‌شود [۷].

مدل‌سازی و پیش‌بینی درخشش یونسفری می‌تواند سبب کاهش میزان تاثیرات خطای درخشش یونسفری

^۳ Global Navigation Satellite Systems

^۱ Deep Signal Fades

^۲ Geometrical Dilution of Precision

ایستگاه ساو خوزه کامپوس^۱ در بازه های یک و نیم ساعته در محدوده ساعتی ۲۰:۰۰ تا ۲۴:۰۰ برای چهار روز مشاهداتی در مدت زمان ۲۵ تا ۲۹ دسامبر ۲۰۰۱ مدلی برای پیش بینی رخداد درخشش یونسفری ابداع کردند [۱۳]. در این مدل از داده های ژئوفیزیکی همچون شار خورشیدی، پارامتر فعالیت مغناطیسی، سرعت رانش پلاسما عمودی^۲ و میزان درخشش یونسفری دامنه^۳ استفاده شده است. نتایج این تحقیق مقادیری قابل قبول برای این پدیده می باشد اما به این دلیل که تنها قادر به پیش بینی درخشش های شدید یونسفری و نیز محدود به بازه محدودی از یک روز بود، نمی توان به صورت عملیاتی از آن استفاده نمود.

در پژوهشی اندرسون و همکاران یک مدل برای پیش بینی درخشش های یونسفری بر مبنای تغییرات ارتفاعی یونسفر برای بالاترین میزان ارتفاع لایه F2 ارائه دادند؛ زیرا که معتقد بودند این پارامتر بیشترین تاثیر را در ایجاد اغتشاشات جوشش های پلاسما یونسفری دارد؛ لذا این پارامتر را برای پیش بینی پدیده درخشش یونسفری به کار گرفته اند [۱۴]. از این پارامتر جهت پیش بینی رخداد درخشش های یونسفری به سه حالت: درخشش یونسفری شدید، بدون درخشش یونسفری و با احتمال درخشش یونسفری در بازه زمانی ۱۸:۳۰ تا ۱۹:۳۰ در منطقه ای به نام پروویان^۴ استفاده شده است. ایراد این روش در آن است که از دیگر پارامترهای فیزیکی مرتبط با درخشش یونسفری بهره نبرده و پیش بینی خود را تنها محدود به پارامتر تغییرات ارتفاعی لایه F2 کرده است.

در پژوهشی دیگر دلیما و همکاران [۱۵] یک مدل برای بیان ارتباط و همبستگی درخشش یونسفری با داده های فیزیکی یونسفر و نیز داده های مرتبط با خورشید با استفاده از روش درخت تصمیم گیر ابداع

کردند [۱۵]. در این مدل سازی از پارامترهایی فیزیکی نظیر شار خورشیدی، میزان فعالیت های ژئومغناطیسی، ارتفاع لایه F2، سرعت ارتفاعی این لایه و نیز پارامتر درخشش یونسفری دامنه به صورت میانگین یک و نیم ساعته بهره برده اند. محدوده زمانی داده های درخشش یونسفری مورد استفاده بیشتر از داده های استفاده شده در مقاله رزنده و همکاران می باشد [۱۳]. به علاوه در پژوهش مذکور از درخشش های یونسفری ضعیف و متوسط نیز در محدوده زمانی ۱۸:۳۰ تا ۲۲:۰۰ برای یک بازه زمانی ۳۸ روزه استفاده شده است. آنالیز پیدا کردن همبستگی و ارتباط میان داده های مرتبط با درخشش یونسفری در روش مورد استفاده در این تحقیق به دلیل استفاده از بازه زمانی ۳۸ روزه دارای دقتی بالاتر نسبت به تحقیقات گذشته است.

استفاده از روش شبکه عصبی برای مدل هایی که داده های زیادی را برای مدل سازی و یا پیش بینی پارامتری محدود استفاده می کنند، نسبت به سایر روش های مدل سازی مناسب تر است [۶]. در این پژوهش سعی شده از روش شبکه های عصبی و تلفیق آن با الگوریتم ژنتیک برای وزن دهی بهینه و نیز آموزش مقدماتی داده ها برای مدل سازی و در نهایت پیش بینی درخشش های یونسفری استفاده شود. از روش شبکه عصبی برای مدل سازی و پیش بینی پدیده درخشش های یونسفری نیز استفاده شده است که در بالا به برخی از این تحقیقات اشاره شد. روش شبکه عصبی روشی ریاضی است که برای مدل سازی و پیش بینی مسائل غیرخطی نظیر پارامترهای یونسفری که مدل سازی آن بر مبنای مدلی قطعی و فیزیکی بسیار مشکل و یا غیرممکن به نظر می آید، دارای کارایی بالاتری نسبت به سایر روش های مدل سازی ریاضی است [۱۶]. علاوه بر این روش شبکه عصبی برای مدل سازی و پیش بینی داده های حاوی نویز که دارای تغییراتی زیاد در مدت زمان کم می باشند همچون پارامتر درخشش یونسفری دامنه، میتواند روشی مناسب تلقی شود [۶].

¹ São José dos Campos

² Vertical plasma Drift Velocity

³ Amplitude Scintillation

⁴ Peruvian

۳- داده‌ها و متغیرهای مورد استفاده

در این پژوهش از پارامترهای موثر بر فیزیک یونسفر که می‌تواند سبب ایجاد پدیده درخشش یونسفری شود به‌عنوان ورودی و از پارامتر S_4 که معیاری برای سنجش درخشش یونسفری است به‌عنوان خروجی شبکه عصبی تلفیق شده با الگوریتم ژنتیک استفاده شده است. که در ذیل به تفصیل به آن پرداخته خواهد شد.

۳-۱- پارامتر S_4

در این پژوهش برای سنجش میزان درخشش یونسفری از پارامتری به نام S_4 استفاده شده است که میزان آن برابر است با انحراف معیار^۲ شدت سیگنال مشاهده شده در هر اپک از گیرنده که با میزان میانگین سیگنال مشاهداتی گیرنده در یک گام زمانی مشخص نرمالیز^۳ می‌شود و از رابطه (۱) بدست می‌آید:

$$S_4 = \frac{\sqrt{\langle I^2 \rangle - \langle I \rangle^2}}{\langle I \rangle} \quad \text{رابطه (۱)}$$

در رابطه (۱) I نشان‌دهنده شدت سیگنال^۴ ارسالی از ماهواره بوده و $\langle I \rangle$ مقدار امید ریاضی پارامتر I بوده که در فایل مشاهداتی از ماهواره برابر با میانگین پارامتر S_1 و S_2 که نشان‌دهنده میزان شدت سیگنال به نویز موج ارسالی در هر دو فرکانس $L1$ و $L2$ از ماهواره می‌باشد [۱۷]. پارامتر S_4 بنا به نوع تعریف آن که حاصل از انحراف معیار مقادیری در یک بازه زمانی می‌باشد، لذا واحدی برای نمایش آن وجود ندارد. S_4 برای بازه‌های زمانی از چند ثانیه تا چند ساعت بنا به نوع نیاز مدل استفاده می‌شود. در این پژوهش از متوسط مقادیر S_4 مشاهداتی برای یک بازه زمانی پنج دقیقه‌ای برای محاسبه S_4 مشاهداتی استفاده شده است. در این خصوص می‌توان مقادیر متوسط محاسباتی $S_4 \leq 0.2$ برای بازه پنج دقیقه را به‌عنوان

در این پژوهش ابتدا منطقه مطالعاتی و نیز پایگاه داده مورد استفاده در مدلسازی پارامتر S_4 که می‌توان از آن برای تاثیر درخشش یونسفری بر دامنه موج ارسالی استفاده نمود و نیز پارامترهای فیزیکی یونسفری و خورشیدی استفاده شده به‌طور کامل توضیح داده خواهد شد و میزان تاثیر هر یک از این پارامترها بر درخشش یونسفری مشخص نشان داده خواهد شد. پس از آن در خصوص روش تحقیق این پژوهش همچون شبکه عصبی، الگوریتم ژنتیک و ترکیب شبکه عصبی با الگوریتم ژنتیک و همچنین میزان تاثیرگذاری آن بر نتایج حاصل توضیحاتی آورده شده و سپس نتایج حاصل از این روش در منطقه مورد مطالعه بررسی شده و میزان دقت مدلسازی و پیش‌بینی در بازه زمانی مذکور در بخش نتایج به تفصیل آورده شده است.

۲- منطقه مورد مطالعه

داده‌های مربوط به مدلسازی و پیش‌بینی درخشش‌های یونسفری مورد استفاده در این پژوهش شامل مشاهداتی با گام‌های زمانی یکسان‌سازی شده جهت استفاده به‌عنوان داده ورودی و داده هدف^۱ در شبکه عصبی می‌باشد.

برای این منظور داده‌های S_4 از مشاهدات GNSS ایستگاه گوام GUAM که در کشور گوام و در شهر Dededo و با طول جغرافیایی ۱۴۴،۸۶۸۳ و عرض جغرافیایی ۱۳،۵۸۹۳ واقع گردیده، استفاده شده است. این ایستگاه که در ارتفاع ۲۰۱،۹۲۲ متری از سطح دریا بوده و از گیرنده JAVAD TRE_G3TH DELTA و آنتن ASH701945B_M استفاده می‌نماید. داده‌های RINEX دریافت شده از این ایستگاه با نرخ مشاهداتی ۳۰ ثانیه از سایت IGS به نشانی <ftp://cddis.gsfc.nasa.gov> قابل برداشت می‌باشد.

^۲ Standard deviation


^۳ Normalize

^۴ Signal Intensity


^۱ Target Data

مدت ۲۴ ساعت و در روز دهم ماه ژوئن سال ۲۰۱۷ است.

رخداد درخشش یونسفری قلمداد نمود [۱۶]. شکل شماره (۲) نمایش دهنده متوسط مقادیر S_4 مشاهداتی برای موج $L1$ برای بازه پنج دقیقه‌ای در



شکل ۱: ایستگاه GUAM واقع در کشور گوام



شکل ۲: پارامتر S_4 مشاهداتی برای روز دهم ماه ژوئن سال ۲۰۱۷

پدیده درخشش یونسفری بایستی از پارامترهای دیگری همچون شار خورشیدی و پارامتر آن $F10.7$ ، تعداد لکه‌های خورشیدی^۱ و شاخص ژئومغناطیسی بین‌المللی Kp نیز بهره برد.

در بین این پارامترها، دو پارامتر بیشترین ارتفاع لایه F_2 و سرعت ارتفاعی لایه F_2 به صورت مستقیم بر روی لایه F_2 که محیط اصلی ایجاد پدیده درخشش

۳-۲- پارامترهای فیزیکی موثر بر درخشش یونسفری


در این پژوهش از پارامترهای موثر بر فیزیک یونسفر که می‌تواند سبب ایجاد پدیده درخشش یونسفری شود به‌عنوان ورودی‌های شبکه عصبی تلفیق شده با الگوریتم ژنتیک استفاده شده است. پارامترهایی نظیر بیشترین ارتفاع لایه F_2 (HmF_2) برحسب کیلومتر و سرعت عمودی لایه F_2 (vdF) بر حسب کیلومتر بر ثانیه و همچنین علاوه بر این دو پارامتر، برای مدل‌سازی

^۱ Sunspot Number

$$\gamma = \frac{\Delta n}{n} \left(\frac{E}{B} + \frac{g}{V_{in}} \right) - \beta \quad \text{رابطه (۲)}$$

که در این رابطه B بیانگر شدت میدان مغناطیسی زمین، g نشان دهنده میزان گرانش زمین و β نشان دهنده نرخ بازسازی یون‌ها در یونسفر است. این پارامترها سبب ایجاد شرایط و یا عواملی هستند که باعث افزایش نرخ رشد بی‌ثباتی در یونسفر می‌شوند [۳]. در شکل شماره ۳ نمایش بیشترین ارتفاع دانسیته الکترونی در لایه $F2$ برای روز دهم ماه ژوئن سال ۲۰۱۷ آورده شده است.

یونسفری است، تاثیرگذار هستند [۱۵]. در حقیقت نرخ رشد ناپایداری پلاسما که به‌نوعی می‌تواند باعث ایجاد درخشش‌های یونسفری شود به عواملی همچون: فرکانس برخورد یون‌های خنثی (V_{in}) که سبب تأثیر بر تغییرات ارتفاعی لایه $F2$ می‌شود، شدت میدان الکتریکی (E) که در زمان غروب خورشید دچار تغییرات به‌نسبت زیادی می‌شود و سبب افزایش میزان سرعت ارتفاعی لایه $F2$ شده و همچنین گرادیان چگالی الکترونی Δn در لایه $F2$ وابسته است. میزان نرخ رشد ناپایداری‌های پلاسما را می‌توان به صورت زیر نمایش داد [۳]:



شکل ۳: میزان بیشترین ارتفاع دانسیته الکترونی در لایه $F2$ برحسب کیلومتر برای روز ۱۰ ژوئن سال ۲۰۱۷


$$vdF = \frac{\Delta hF}{\Delta t} \quad \text{رابطه (۳)}$$

که در رابطه (۳) ΔhF برابر با اختلاف ارتفاع در دو اپک متوالی مشاهداتی در این پژوهش، vdF برابر با سرعت عمودی لایه $F2$ که بر حسب کیلومتر بر ثانیه می‌باشد و Δt نیز برابر با بازه زمانی مشاهداتی است که در این پژوهش برابر با پنج دقیقه می‌باشد. در شکل ۴ مقادیر سرعت عمودی لایه $F2$ برای روز دهم ژوئن سال ۲۰۱۷ برای بازه پنج دقیقه‌ای به نمایش در آمده است.

در این پژوهش پارامتر بیشترین ارتفاع دانسیته الکترونی در لایه $F2$ ($HmF2$) و سرعت عمودی لایه $F2$ (vdF) مربوط به ایستگاه یونسند^۱ گوام با طول جغرافیایی ۱۴۴٫۸۶۰ و عرض جغرافیایی ۱۳٫۶۲ با گام زمانی مشاهداتی پانزده دقیقه و در فرکانس‌های ۴ تا ۸ مگاهرتز استفاده شده است. اطلاعات مربوط به این ایستگاه را از سایت NOAA^۲ می‌توان دریافت نمود. میزان سرعت عمودی لایه $F2$ را می‌توان با محاسبه میزان تغییرات لایه $F2$ نسبت به بازه زمانی اندازه‌گیری مدنظر به‌صورت رابطه (۳) محاسبه نمود.

^۱ Ionosonde Portable Sounder

^۲ <https://www.ngdc.noaa.gov/stp/IONO>



شکل ۴: سرعت عمودی لایه F2 بر حسب واحد کیلومتر بر ثانیه (KM/S) برای روز ۱۰ ژوئن سال ۲۰۱۷

سوی جو زمین ارسال می‌شود [۲۰]. تعداد لکه‌های خورشیدی توسط پارامتری به نام عدد ولف^۳ اندازه‌گیری شده و به صورت روزانه از طریق موسسه *National Geophysical Data Center* منتشر می‌شود [۱۹].

یکی دیگر از فاکتورهای موثر بر درخشش یونسفری میزان فعالیت ژئومغناطیسی زمین می‌باشد. شاخص ژئومغناطیسی بین‌المللی K_p پارامتری جهت اندازه‌گیری میزان فعالیت‌های ژئومغناطیسی زمین است. اندیس K_p خود میانگین نجومی اندیس K است. اندیس K خود حاصل مشاهده مولفه‌های نظیر H^5 , D^6 و Z^7 در طول هشت بازه زمانی سه ساعته برای یک روز می‌باشند. از اندیس K_p می‌توان برای ارزیابی روزهایی که به لحاظ ژئومغناطیسی دارای اختلال هستند و یا برای روزهای آرام استفاده نمود [۱۹]. مقادیر پایین‌تر از ۳ برای این پارامتر نشان‌دهنده وضعیت آرام از لحاظ ژئومغناطیسی است؛ در حالی که افزایش این پارامتر سبب افزایش اغتشاشات و نیز افزایش درصد رخداد درخشش یونسفری می‌شود [۲۱]. مقادیر K_p -index به

پارامتر $F10.7$ نشان دهنده شار خورشیدی اندازه‌گیری شده در طول موج ۱۰/۷ سانتی متر است که برای تعیین میزان فعالیت خورشیدی مورد استفاده قرار می‌گیرد [۱۸]. درخشش‌های یونسفری شدید در بازه‌های زمانی رخ می‌دهد که فعالیت‌های خورشید در آن دوره در بیشترین میزان خود قرار دارد و یا در بازه‌های زمانی که میزان فعالیت‌های خورشید کم است درخشش‌های یونسفری مشاهده شده مقادیری کمتر دارند که این عامل نشان از ارتباط بالا میان فعالیت‌های خورشیدی و میزان رخداد درخشش‌های یونسفری دارد [۱۵]. این مقادیر از سایت *National Geophysical Data Center*^۱ دریافت شده است.

تعداد لکه‌های خورشیدی پارامتر دیگری که در مدل‌سازی از آن استفاده شده است. لکه‌های خورشیدی به طور مستقیم با میدان مغناطیسی خورشید ارتباط دارند. داده‌های بدست آمده بیانگر آن است که میدان مغناطیسی ایجاد شده در اطراف لکه‌های خورشیدی هزاران بار قوی‌تر از میدان مغناطیسی زمین است [۱۹]. با افزایش تعداد لکه‌های خورشیدی شدت میدان مغناطیسی زمین افزایش یافته و در اثر آن حجم عظیمی از انرژی به صورت شارهای خورشیدی^۲ به

^۳ Wolf Number

^۴ <https://www.ngdc.noaa.gov/>

^۵ مولفه افقی میدان ژئومغناطیسی زمین

^۶ و نصف النهار جغرافیایی H زاویه بین مولفه

^۷ مولفه قائم میدان ژئومغناطیسی زمین

^۱ <https://www.ngdc.noaa.gov/>

^۲ Solar Flare

می‌رسند وارد فرایندی به نام پس انتشار^۲ شده و با مقایسه میزان خطا و محاسبه میزان تاثیر هر کدام از ورودی‌ها در تمام لایه‌ها، شروع به اصلاح وزن‌های مقدماتی کرده که شرط توقف آن رسیدن به کمترین میزان خطا میان داده خروجی مدل و داده هدف که به صورت ورودی به مدل داده شده است، خواهد بود [۲۴]. در شکل (۶) ساختار یک شبکه عصبی با دولایه میانی آورده شده است.

۴-۲- الگوریتم ژنتیک

الگوریتم ژنتیک یک الگوریتم جستجوی عددی است که بر مبنای نظریه بقای داروین طرح‌ریزی شده است [۲۵]. رابطه میان علم ژنتیک و الگوریتم ژنتیک را می‌توان این گونه در نظر گرفت که ژن‌ها به عنوان کمیت و متغیر مساله به صورت رشته‌ای در درون کروموزوم‌ها قرار گرفته‌اند که متغیرهای اصلی مساله ما هستند. شاخصی به نام جمعیت به مفهوم مجموعه‌ای از کروموزوم‌های یک نسل، مفهوم پراهمیت دیگر این الگوریتم است. وقتی یک مسئله بهینه‌سازی را حل می‌کنیم هدف یافتن بهترین جواب از میان تمامی جوابهای ممکن است. در واقع جستجو برای جواب به معنای جستجو برای پیدا کردن مینیمم در فضای کلی مساله است [۲۶]. این الگوریتم به صورت تصادفی جمعیتی از جواب‌های اولیه می‌سازد و سپس این جواب‌ها به حالت باینری زنجیره‌های صفر و یک تبدیل شده که به آن کروموزوم می‌گویند. کروموزوم‌های با شایستگی بیشتر با استفاده از یک روند تصادفی به عنوان والدین انتخاب شده و در تولید مثل شرکت می‌کنند و فرزندان تولید می‌شوند. فرزندان که از والدینشان شایسته‌تر هستند در جمعیت جدید جای والدین را خواهند گرفت. بدین ترتیب، روند تکامل تا رسیدن به بهینه سراسری یا شایسته‌ترین کروموزوم در تکامل یافته‌ترین جمعیت ادامه خواهد یافت. البته باید

صورت روزانه و نیز به صورت بازه زمانی سه ساعته منتشر می‌شود و از سایت دانشگاه کیوتو^۱ قابل برداشت است. مقادیر حاصل از شاخص K_p در بازه‌های سه ساعته برای دهم ماه ژوئن سال ۲۰۱۷ در شکل (۵) آورده شده است.

۴- مبنای نظری تحقیق

این مقاله از روش شبکه‌های عصبی و تلفیق آن با الگوریتم ژنتیک برای وزن‌دهی بهینه و نیز آموزش مقدماتی داده‌ها برای مدلسازی و در نهایت پیش‌بینی درخشش‌های یونسفری استفاده کرده است. در ذیل به تفصیل به موضوع شبکه‌های عصبی و ترکیب آن با الگوریتم ژنتیک خواهیم پرداخت.

۴-۱- شبکه‌های عصبی

شبکه عصبی یکی از روش‌های یادگیری ماشین است که می‌تواند برای مدلسازی و یا پیش‌بینی پارامترهای خطی و غیرخطی مورد استفاده قرار گیرد که می‌توان برای مدلسازی و یا پیش‌بینی پارامترهای یونسفر نیز از این روش بهره برد. این روش تحت تاثیر کمتری نسبت به داده‌های آلوده به نویز قرار گرفته و قابلیت استفاده از داده‌های آلوده به نویزی برای مقادیر زیادی از مشاهدات را داراست [۲۲]. شبکه‌های عصبی با پردازش مشاهدات وارد شده به عنوان داده‌های تجربی، ارتباط میان آنها و یا قانون نهفته در آنها را کشف نموده و به داخل شبکه انتقال می‌دهند. هر شبکه عصبی از تعدادی گره که همان نورون‌ها هستند و وزن‌های ارتباطی که گره‌ها را به هم متصل می‌کنند، تشکیل شده است [۲۳]. داده‌های ورودی در وزن‌های متناظرشان ضرب می‌شوند و مجموع آنها به نورون‌ها وارد می‌شوند. هر نورون دارای یک تابع انتقال می‌باشد که این مقدار ورودی از تابع انتقال عبور کرده و مقدار خروجی نورون را مشخص می‌کند. سپس مقادیر حاصله از نورون‌ها که با ترکیب در یکدیگر به جوابی اولیه


² Back Propagation

¹ Kyoto University, <http://wdc.kugi.kyoto-u.ac.jp/kp/>


روی استخر تولید مثل اعمال خواهد شد. سپس در فرایند جهش با ایجاد تغییرات تصادفی در ژن‌ها سبب می‌شود که کروموزوم‌ها دچار تفاوت و پراکندگی ژنتیکی شده و محدوده وسیع‌تری از فضای جستجو برای یک جمعیت به منظور یافتن کروموزوم‌های شایسته‌تر مورد بررسی قرار گیرد. در واقع بهره‌گیری از فضای جستجوی عددی وسیع‌تر در این روش، وجه تمایز آشکار میان این روش و روش‌های حاصل از تکرار همچون کمترین مربعات است. پس از گذشت مدت زمانی از اجرای الگوریتم ژنتیک، کروموزوم‌ها به سمت یک پاسخ بهینه همگرا می‌شوند که در این مرحله اجرای الگوریتم ژنتیک متوقف شده و آن کروموزوم به عنوان پاسخ بهینه مسأله انتخاب می‌شود. البته می‌بایست به این نکته اشاره نمود که میزان صحت و دقت همگرایی به انتخاب بهینه پارامترهای الگوریتم وابسته است [۲۸].

یک معیار برای توقف الگوریتم و جمعیت تکامل یافته نهایی در نظر گرفته شود [۲۷]. کروموزوم‌ها در هر نسل به عنوان ورودی تابع هدف وارد الگوریتم می‌شوند و این همان تابع اصلی است که به دنبال مینیمم مطلق آن هستیم. کروموزوم‌های موجود در هر نسل، جمعیت الگوریتم می‌باشند. این کروموزوم‌ها در واقع همان جواب‌های اصلی مسأله بوده که در هر نسل با توجه به تغییر در ژن‌های آن تغییر می‌کنند. سپس در فرایند مقیاس‌بندی بهترین وزن به هر کدام از کروموزوم‌ها نسبت داده می‌شود. سپس در فرایند انتخاب کروموزوم‌های شایسته‌تر، با یک روند تصادفی در یک جمعیت انتخاب شده و با یکدیگر ترکیب شده و کروموزوم‌ها یا جواب‌های جدیدتر را تولید می‌کنند [۲۸].

سپس جمعیتی از کروموزوم‌های شایسته جهت انجام تولید مثل انتخاب شده و عملگر ترکیب با یک نرخ ترکیب مشخص با هدف تولید رشته‌های باینری بهتر بر



شکل ۵: شاخص ژئومغناطیسی بین‌المللی Kp index سه ساعته برای دهم ماه ژوئن سال ۲۰۱۷



شکل ۶: ساختار شبکه عصبی با دو لایه میانی [۲۵]

دارد که با جهش به جوابی مطلوب که مینیمم مطلق تابع هدف است، برسد و شرط پایان الگوریتم ژنتیک نیز رسیدن به حدنصاب تعیین میزان اختلاف در کروموزوم‌های ابتدایی با کروموزوم‌های بهینه است [۳۱]. در واقع استفاده از یک روش تکراری در آموزش شبکه‌های عصبی سبب افزایش دقت در فرایند پیدا کردن مینیمم نسبی برای تابع مورد تعریف بوده و علاوه بر آن آزمون‌های اطمینان از جواب‌های حاصل از الگوریتم ژنتیک است [۲۷]. ترکیب الگوریتم ژنتیک با شبکه‌های عصبی می‌تواند دقتی به مراتب بالاتر از الگوریتم ژنتیک و دقتی بالاتر از شبکه‌های عصبی ارائه کند. علاوه بر این باعث کاهش زمان پردازش مورد نیاز در شبکه عصبی شده زیرا شبکه می‌تواند با کمترین میزان پردازش به دقت مورد نظر رسیده و فرایند را پایان دهد [۳۲].

روش کار در شبکه‌های عصبی ترکیب شده با الگوریتم ژنتیک به طور خلاصه عبارت است از [۳۱]:

(۱) طراحی شبکه : شامل وارد کردن داده‌های ورودی شبکه ، تعداد لایه‌های میانی ، تعداد نورون‌های لایه میانی ، انتخاب نوع تابع انتقال، انتخاب نوع روش برای آموزش شبکه مانند لونیبرگ-مارکوات و که در بخش پیاده‌سازی و نتایج به پیاده‌سازی این مدل در این پژوهش خواهیم پرداخت.

(۲) پیدا کردن بهترین وزن‌های اولیه به کمک الگوریتم ژنتیک : در شبکه‌های عصبی وزن‌های اولیه به صورت تصادفی داده می‌شود در حالی که استفاده از ژنتیک باعث می‌شود این وزن‌ها به صورت مینیمم مطلق (در صورت پردازش کامل الگوریتم) به عنوان وزن اولیه وارد شبکه عصبی شود. روش آموزش وزن‌های اولیه توسط این روش به این صورت خواهد بود که یک تابع هدف برای مینیمم‌سازی وزن‌ها تعریف شده و مقایسه وزن‌های هر دور با دور بعد از پردازش که بر مبنای کمترین اختلاف میان آنهاست به دست می‌آید. در این برنامه ابتدا شبکه عصبی تعریف شده با ورودی‌ها و تعداد نورون‌ها و خروجی‌ها به برنامه داده شده و سپس

۵- روش تحقیق

در این پژوهش از ترکیب الگوریتم ژنتیک با شبکه عصبی برای بهینه نمودن وزن‌های اولیه استفاده شده است. شبکه عصبی برای مدل‌سازی داده‌های آلوده به نویز و همچنین تعداد بالایی از مشاهدات مناسب به نسبت روش‌های دیگر مناسب ارزیابی می‌شود که می‌تواند برای مدل‌سازی مقادیر S_4 که پارامتری جهت پیدا کردن پدیده درخشش یونسفری است، استفاده شود [۶]. با استفاده از روش‌های جستجوی عددی همچون الگوریتم ژنتیک، می‌توان مقادیر وزن‌های ابتدایی شبکه را که تأثیر بسزایی در دقت مدل‌سازی خواهند داشت بهینه نمود. در ادامه به توضیح در خصوص تلفیق شبکه عصبی با الگوریتم ژنتیک پرداخته خواهد شد و سپس در خصوص ساختار شبکه استفاده شده در این پژوهش مطالبی آورده خواهد شد.

۵-۱- ترکیب روش الگوریتم ژنتیک با شبکه

عصبی برای آموزش وزن‌های اولیه شبکه

در آموزش شبکه عصبی از روش‌های تکراری همچون لونیبرگ-مارکوات^۱ که نوعی روش کمترین مربعات درجه دوم است استفاده می‌شود [۲۹]. این روش‌ها در کنار نقاط قوت متعددی که دارند دارای نقطه ضعفی بزرگ همچون پیدا کردن مینیمم‌های محلی به عنوان جواب بهینه مسأله هستند که این در حالی است که روش‌هایی همچون ژنتیک توانایی محاسبه مینیمم مطلق را در صورت تعریف بهینه اجزای الگوریتم ژنتیک دارند [۲۹]. مزایای ترکیب این دو روش و استفاده از الگوریتم ژنتیک برای آموزش ابتدایی وزن‌ها و پیدا کردن وزن‌های اولیه این است که الگوریتم ژنتیک عیب بزرگ روش‌های تکراری در آموزش وزن‌های شبکه عصبی را می‌پوشاند [۳۰]. شبکه عصبی هم به کمک روش‌های تکراری سعی در بهینه کردن جوابی دارد که از ژنتیک استخراج شده زیرا روش ژنتیک توانایی آن را

^۱ Levenberg-Marquard

وزن‌های تصادفی ابتدایی را به آن وارد کرده و سپس الگوریتم ژنتیک را تعریف نموده و بازه و میزان نسل‌های آن را مشخص می‌کنیم. این وزن‌ها در هر دور توسط الگوریتم محاسبه شده و میزان مربع خطا^۱ در هر دور محاسبه شده و در هر دور جواب‌ها بهینه می‌شود تا به جوابی مطلوب که مینیمم مطلق تابع هدف است، برسیم. شرط پایان الگوریتم ژنتیک نیز رسیدن به آن حدنصاب برای میزان اختلاف در کروموزوم‌های ابتدایی با کروموزوم‌های بهینه است [۳۱].

۳) آموزش شبکه: شبکه با وزن‌های حاصل از ژنتیک آموزش داده می‌شود و سپس با روش لونبرگ-مارکوات که نوعی روش کمترین مربعات است، دوباره آموزش داده می‌شود که این عمل احتمال دستیابی به وزن‌های بهینه را برای این نوع شبکه عصبی افزایش می‌دهد. این روش از آن جهت اهمیت پیدا می‌کند که آزمونی برای اطمینان از درستی جواب حاصله از الگوریتم ژنتیک می‌باشد [۳۱].

۶- پیاده‌سازی و نتایج

برای انجام مدل‌سازی یک شبکه عصبی تلفیق شده با الگوریتم ژنتیک که از دو لایه تشکیل شده است که لایه ابتدایی آن دارای پنج نرون بوده که شامل داده‌های ورودی شبکه است و لایه انتهایی آن نیز شامل یک نرون بوده که خروجی حاصل از این مدل می‌باشد که در ادامه به آن‌ها اشاره خواهد شد. تابع انتقال میان نرون‌ها در شبکه عصبی طراحی شده از نوع توابع سیگموئید^۲ است که از وزن‌های تعیین شده از الگوریتم ژنتیک به عنوان وزن اولیه مورد نیاز شبکه استفاده می‌نماید. در شبکه طراحی شده پنج نوع داده به عنوان داده‌های ورودی وارد شبکه می‌کنیم که شامل بیشترین ارتفاع دانسیته الکترونی لایه $F2$ ، سرعت ارتفاعی لایه $F2$ ، پارامتر شار خورشیدی ($F10.7$)، تعداد لکه‌های خورشیدی و شاخص ژئومغناطیسی بین‌المللی Kp

¹ Mean Squared Error


² Sigmoid

می‌باشد که به صورت نرمالیز شده وارد شبکه می‌شود. از آنجا که وزن‌های شبکه عصبی در بازه صفر و یک هستند، لذا برای رسیدن به بهترین مقادیر برای شبکه بهتر است که داده‌های ورودی و هدف شبکه عصبی در بازه‌ای میان صفر و یک وارد معادلات شوند که با استفاده از الگوریتم ژنتیک که در قسمت قبل به تفصیل به آن پرداخته شده است سبب بهینه نمودن وزن‌های ابتدایی شبکه طراحی شده خواهند شد. در سوی دیگر میزان تاثیر درخشش یونسفری بر دامنه فاز سیگنال ارسالی که می‌توان آن را با پارامتر $S4$ بیان نمود که میزان حداقل زاویه برداشت آن 20° درجه در نظر گرفته شده است را به عنوان داده هدف و به صورت نرمالیزه شده وارد شبکه می‌کنیم. به شبکه عصبی طراحی شده مجموعه‌ای از داده‌ها تحت عنوان وزن‌های اولیه وارد می‌شود که در این پژوهش این وزن‌ها با آموزش ابتدایی در الگوریتم ژنتیک وارد شبکه شده‌اند. نوع ورودی داده‌ها و شماتیک شبکه عصبی به کارگرفته شده در شکل (۷) آورده شده است.


نتایج حاصل از مدل‌سازی انجام گرفته با استفاده از یک شبکه عصبی دو لایه شبکه عصبی و ترکیب آن با الگوریتم ژنتیک برای داده‌های $S4$ با بازه زمانی پنج دقیقه‌ای که بازه‌ای متعارف است [۳۳] به صورت 24 ساعته و برای یک دوره سی روزه برای ماه ژوئن سال 2017 برای مدل‌سازی اولیه شبکه عصبی در نظر گرفته شده که نشانگر کاربرد مدل‌سازی سی‌روزه برای این پدیده می‌باشد. داده‌های ورودی برای شبکه عصبی طراحی شده شامل 8640 گام زمانی است که شامل بیشترین ارتفاع لایه $F2$ ($HmF2$) برحسب کیلومتر، سرعت عمودی لایه $F2$ (vdF) برحسب کیلومتر بر ثانیه، شار خورشیدی و پارامتر آن $F10.7$ ، تعداد لکه‌های خورشیدی و شاخص ژئومغناطیسی بین‌المللی Kp که در بخش سوم به تفصیل به آن‌ها پرداخته شد، برای بازه‌های پنج دقیقه‌ای برای 30 روز می‌باشد. داده‌های ورودی شبکه عصبی که داده‌های فیزیکی موثر بر درخشش یونسفری می‌باشد، بایستی با داده $S4$ که

استفاده جهت آموزش، ارزیابی و اعتبارسنجی شبکه و همچنین برای کل داده‌های شرکت‌کننده در شبکه عصبی دولا به تلفیق شده با الگوریتم ژنتیک که بخش‌های اصلی در فرآیند مدل‌سازی شبکه عصبی می‌باشند و نیز پارامترهایی به جهت برآورد دقت مدل‌سازی برای شبکه عصبی هستند، در شکل (۸) نمایش داده شده است.

داده هدف است، هم‌زمان‌سازی شوند. لذا می‌توان با استفاده از روش‌های درونیابی همچون استفاده از *B-spline* این داده‌ها را درونیابی نمود. این داده‌ها به عنوان داده‌های ورودی در کنار داده هدف که پارامترهای مشاهده شده *S4* هستند، به شبکه طراحی شده اعمال می‌شوند؛ سپس شبکه با استفاده از این داده‌ها وارد فرایند آموزش ترکیب شده و در شبکه عصبی تلفیق شده با الگوریتم ژنتیک مدل‌سازی می‌شوند. میزان آنالیز همبستگی در سه بخش برای داده‌های مورد




شکل ۷: شبکه عصبی طراحی شده برای مدل‌سازی و پیش‌بینی شبکه مقادیر میانگین *S4* مشاهداتی



شکل ۸: مقایسه میزان آنالیز همبستگی برای قسمت آموزش، ارزیابی و اعتبارسنجی در شبکه عصبی دولا به تلفیق شده با الگوریتم ژنتیک

برای کل شبکه برابر است با ۰/۸۸۱۶ که میزانی قابل قبول برای اطمینان از دقت شبکه و مدلسازی انجام شده می‌باشد. مقادیر حاصل از مدلسازی با استفاده از این شبکه با استفاده از پارامترهای فیزیکی ذکر شده جهت مدلسازی برای پارامتر S_4 در بازه زمانی سی روزه برای ماه ژوئن سال ۲۰۱۷ در شکل (۹) نمایش داده شده است.



شکل ۹: مقادیر S_4 مدلسازی شده برای ماه ژوئن سال ۲۰۱۷ با استفاده از شبکه عصبی تلفیق شده با الگوریتم ژنتیک


نشان دادن دقت مدل می‌باشد. مقادیر مدلسازی شده نیز برای S_4 دارای میانگینی برابر با ۰/۱۹۲۵ و انحراف معیاری برابر با ۰/۰۴۱۴ هستند. در شکل (۱۱) آنالیز همبستگی میان مدلسازی انجام شده توسط شبکه عصبی تلفیق شده با الگوریتم ژنتیک و مقادیر مشاهداتی برای ماه ژوئن سال ۲۰۱۷ به نمایش در آمده است.

همان‌گونه که در شکل (۸) مشاهده شده است میزان ضریب همبستگی برای داده‌های مدلسازی شده با استفاده از شبکه عصبی تلفیق شده با الگوریتم ژنتیک برای شبکه عصبی طراحی شده آورده شده است که میزان آن برای داده‌های آموزش شبکه برابر ۰/۹۰۱۶، برای داده‌های ارزیابی شبکه ۰/۸۳۹۲ و برای داده‌های اعتبارسنجی برابر با ۰/۸۲۵۳ می‌باشد. مقدار این پارامتر


سپس نتایج حاصل از مدلسازی شبکه عصبی برای بازه یک ماهه برای داده S_4 با میزان اصلی این داده در همان بازه زمانی مقایسه شده و برای سنجش میزان دقت، مدل حاصل را با پارامترهای همچون انحراف جذر میانگین مربعات ($RMSE$) برای سنجش میزان خطاها و نیز از پارامتر همبستگی برای محاسبه آنالیز همبستگی و میزان رگرسیون استفاده می‌کنیم.

مقادیر مشاهداتی برای S_4 با میانگین ۰/۱۹۲۶ و دارای انحراف معیاری برابر با ۰/۰۴۹۱ هستند. برای مدلسازی یک ماهه برای ماه ژوئن سال ۲۰۱۷ میزان $RMSE$ به دست آمده برابر با ۰/۰۱۳۵ می‌باشد که نشان‌دهنده دقت مدلسازی است؛ همچنین میزان پارامتر همبستگی داده‌های مدلسازی شده و داده‌های واقعی برابر با ۰/۸۸۱۹ می‌باشد که پارامترهایی جهت

^۱ Root Mean Square Error




شکل ۱۰: مقایسه میان $S4$ مدلسازی شده با رنگ آب و $S4$ مشاهداتی با رنگ قرمز برای ماه ژوئن سال ۲۰۱۷



شکل ۱۱: نمایش آنالیز همبستگی میان مدلسازی انجام شده توسط شبکه عصبی تلفیق شده با الگوریتم ژنتیک و مقادیر مشاهداتی برای ماه ژوئن سال ۲۰۱۷

میزان بردار باقیمانده برای این بازه زمانی سی‌روزه آورده شده است. میانگین میزان قدرمطلق باقی‌مانده‌ها برای این ماه برابر 0.0122 و بیشترین میزان آن 0.0926 می‌باشد که نشان‌دهنده عملکرد مدلسازی انجام گرفته می‌باشد.


علاوه بر این می‌توان با رسم بردار قدرمطلق باقیمانده‌ها میان مدلسازی انجام گرفته و داده‌های مشاهداتی مدل که در شکل (۱۲) نمایش داده شده است، پارامتری دیگر نیز جهت ارزیابی مدل آموزش دیده توسط شبکه عصبی و ترکیب آن با الگوریتم ژنتیک نشان داد. این



شکل ۱۲: بردار باقی‌مانده‌ها برای مقایسه میان مقادیر اصلی و مقادیر مدلسازی شده برای پارامتر S_4 برای ماه ژوئن سال ۲۰۱۷

داده و کاربر تصحیحات لازم به جهت مقابله با این اختلالات در مشاهدات خود را به عمل آورد. برای این منظور داده‌های مربوط به پارامترهای فیزیکی مربوط به پدیده درخشش یونسفری آن روز را به‌عنوان داده‌های ورودی وارد مدل کرده و سپس با کمک مدل آموزش دیده، داده‌ها برای روز مورد نظر، پیش‌بینی می‌شود. در این پژوهش میزان پارامتر S_4 برای روز اول ماه جولای سال ۲۰۱۷ پیش‌بینی شده است. در شکل (۱۳) میزان S_4 حاصل از مدل‌سازی نمایش داده شده است.

در گام آخر روز ابتدایی ماه بعد (روز ۳۰+۱ برای ماه‌های سی‌روزه و روز ۳۱+۱ برای ماه‌های سی و یک‌روزه) که در آن مدل‌سازی انجام شده، روز ابتدایی ماه جولای سال ۲۰۱۷ است که ماهی سی‌روزه بوده که به کمک مدل حاصل از شبکه عصبی و تلفیق آن با الگوریتم ژنتیک پیش‌بینی می‌شود که می‌تواند به کاربران سیستم‌های تعیین موقعیت جهانی به منظور برداشت و استفاده از مشاهدات در بازه‌های زمانی مناسب از لحاظ رخداد پدیده درخشش یونسفری اطلاع




شکل ۱۳: مقادیر S_4 پیش‌بینی شده برای اولین روز ماه جولای سال ۲۰۱۷ با استفاده از شبکه عصبی تلفیق شده با الگوریتم ژنتیک

برای سنجش میزان خطاها و پارامتر R -Square برای محاسبه میزان رگرسیون استفاده می‌کنیم. میزان

برای سنجش میزان دقت پیش‌بینی انجام شده با مقادیر واقعی در همان بازه زمانی، از پارامتر $RMSE$

۲۰۱۷ را می‌توان در شکل شماره (۱۴) مشاهده نمود.


داده‌های پیش‌بینی و نیز میزان داده‌های مشاهده شده S_4 برای بازه زمانی ۲۴ ساعته در روز اول جولای سال



شکل ۱۴: مقایسه میان S_4 پیش‌بینی شده با رنگ آب و S_4 مشاهداتی با رنگ قرمز برای روز اول ماه جولای سال ۲۰۱۷

شده به‌عنوان رخداد درخشش یونسفری قلمداد نمود [۱۶]. شکل (۱۵) میزان آنالیز همبستگی میان پیش‌بینی انجام شده توسط شبکه عصبی تلفیق شده با الگوریتم ژنتیک و مقادیر مشاهداتی برای روز اول ماه جولای سال ۲۰۱۷ را نمایش داده است.


برای این پیش‌بینی که برای روز اول ماه جولای سال ۲۰۱۷ انجام گرفته است میزان $RMSE$ به دست برابر با ۰/۰۱۷۸ می‌باشد و پارامتر R -Square بدست آمده برای مدل برابر با ۰/۷۷۸۳ می‌باشد. در این بازه زمانی مقادیر حاصل برای پارامتر S_4 مشاهده شده را می‌توان بنا به پژوهشی که پیشتر در این زمینه انجام



شکل ۱۵: نمایش آنالیز همبستگی میان پیش‌بینی انجام شده توسط شبکه عصبی تلفیق شده با الگوریتم ژنتیک و مقادیر مشاهداتی برای روز اول ماه جولای سال ۲۰۱۷

باقی‌مانده‌ها برای این روز برابر ۰/۰۱۱۴ و بیشترین میزان آن ۰/۱۱۷۹ می‌باشد که نشان از عملکردی خوب برای پیش‌بینی انجام گرفته می‌باشد.


شکل (۱۶) نشان‌دهنده میزان اختلاف میان مقادیر مشاهداتی و مقادیر پیش‌بین شده برای روز اول ماه جولای سال ۲۰۱۷ را نشان می‌دهد. میانگین بردار



شکل ۱۶: بردار باقی‌مانده‌ها برای مقایسه میان مقادیر اصلی و مقادیر پیش‌بینی شده برای پارامتر S_4 برای روز اول ماه جولای سال ۲۰۱۷

کمیت بر روی مقدار عددی کمیت) استفاده شده که در شکل (۱۷) نمایش داده شده است. میانگین خطای نسبی برای بازه زمانی یک روزه برای روز اول ماه جولای سال ۲۰۱۷ برابر با ۰/۳۴۴ و میانگین این مقادیر نیز برابر با ۰/۰۸۷۵ است که بیانگر عملکردی قابل قبول برای پیش‌بینی انجام گرفته می‌باشد.

همان‌طور که از شکل‌های (۱۵ و ۱۶) مشخص است در اکثر مواقع پیش‌بینی انجام شده توسط شبکه عصبی و ترکیب آن با الگوریتم ژنتیک توانسته است رفتاری شبیه با مشاهده را دنبال نماید. در این راستا برای نمایش بهتر اختلاف میان مقادیر مشاهداتی و مقادیر پیش‌بینی شده از مقدار خطای نسبی (مقدار خطای



شکل ۱۷: مقدار قدر مطلق خطای نسبی برای مقایسه میان مقادیر اصلی و مقادیر پیش‌بینی شده پارامتر S_4 برای روز اول ماه جولای سال ۲۰۱۷

شهر Dededo با طول جغرافیایی ۱۴۴,۸۶۸۳ و عرض جغرافیایی ۱۳,۵۸۹۳ مطالعه و بررسی صورت گرفته است. همچنین از داده‌های ایستگاه یونسند گوام نیز برای دریافت اطلاعات فیزیکی یونسفر استفاده شده

۷- نتیجه‌گیری و پیشنهادات

این تحقیق درخصوص پیش‌بینی درخشش یونسفری برای ایستگاه گوام GUAM واقع در کشور گوام و در

فیزیکی یونسفر و با استفاده از شبکه عصبی و تلفیق آن با الگوریتم ژنتیک انجام گرفته است. در پیش‌بینی انجام شده، روز ابتدایی ماه جولای سال ۲۰۱۷ به کمک مدل حاصل از شبکه عصبی و تلفیق آن با الگوریتم ژنتیک پیش‌بینی شده است که می‌تواند به کاربران سیستم‌های تعیین موقعیت جهانی به‌منظور برداشت و استفاده از مشاهدات در بازه‌های زمانی مناسب از لحاظ رخداد پدیده درخشش یونسفری اطلاع داده و کاربر تصحیحات را برای تعیین مختصات و فعالیت‌های مرتبط با اتمسفر، به جهت مقابله با این دسته اختلالات در مشاهدات خود اعمال نماید. برای بررسی میزان دقت این پیش‌بینی می‌توان به پارامتر آنالیز همبستگی R -Square داده‌های پیش‌بینی شده با داده‌های مشاهداتی به میزان ۰/۷۷۸۳ و نیز پارامتر $RMSE$ داده‌های پیش‌بینی شده به مقدار ۰/۰۱۷۸ اشاره نمود. علاوه بر این دو پارامتر، میانگین بردار باقی‌مانده‌ها میان مقادیر پیش‌بینی شده و مقادیر مشاهداتی نیز برابر با ۰/۰۱۱۴ می‌باشد که بیانگر دقتی قابل قبول برای پیش‌بینی پدیده‌ی درخشش یونسفری می‌باشد. از این مدل‌سازی می‌توان برای پیش‌بینی پدیده درخشش یونسفری جهت کاهش خطای این پدیده در مشاهدات برای کاربران عادی جهت افزایش دقت تعیین موقعیت و همچنین اصلاح مشاهدات در ایستگاه‌های مشاهدات ماهواره‌ای بهره برد.

است. این ناحیه در منطقه کمربند مغناطیسی استوایی قرار داشته که دارای بیشترین میزان درصد رخداد پدیده درخشش یونسفری نسبت به مناطق با عرض‌های جغرافیایی بالا و متوسط می‌باشد. در این پژوهش از پنج نوع داده فیزیکی یونسفری و یا تاثیرگذار بر یونسفر که منشأ برخی از آنها خورشید می‌باشد به‌عنوان داده‌های اولیه در شبکه عصبی تلفیق شده با الگوریتم ژنتیک برای مدل‌سازی و سپس پیش‌بینی وقوع میزان درخشش یونسفری با استفاده از پارامتر $S4$ برای مدت یک روز بعد از دوره مدل‌سازی شده، استفاده شده است. از دیگر ویژگی‌های این پژوهش می‌توان به استفاده از داده‌های پارامتر $S4$ نام برد که به دلیل نوع ساختار، ذاتی نویزی دارند؛ لذا تغییرات شدید در مقادیر آن در بازه‌های زمانی کوتاه مدت امری اجتناب‌ناپذیر بوده و مدل‌سازی این نوع داده‌ها امری به نسبت دشوار به نظر می‌رسد ولی استفاده از روش شبکه‌های عصبی و نیز تلفیق آن با الگوریتم ژنتیک توانسته با ایجاد انعطاف در مدل‌سازی این دسته داده، این امر را تا حدودی ممکن نماید. این داده‌ها به صورت روزانه در یک ماه سی روزه و با نرخ برداشت پنج دقیقه‌ای برای داده‌های $S4$ مشاهداتی برای موج $L1$ محاسبه شده است. مدل‌سازی این داده‌ها با استفاده از شبکه عصبی و تلفیق آن با الگوریتم ژنتیک در یک بازه زمانی یک ماهه برای ماه ژوئن در سال ۲۰۱۷ انجام گرفته است. بر اساس این مدل یک پیش‌بینی یک روزه (۲۴ ساعته) برای پارامتر $S4$ با بکارگیری داده‌های

مراجع

- [1] de Paula, E., Rodrigues, FS, Iyer, KN, Kantor, IJ, Abdu, MA, Kintner, PM, Ledvina, BM, Kil, H, Equatorial anomaly effects on GPS scintillations in Brazil. *Advances in Space Research*, 2003. 31(3): p. 749-754.
- [2] Xu, R., Liu, Z., Li, M., Morton, Y., Chen, W., An Analysis of Low-Latitude Ionospheric Scintillation and Its Effects on Precise Point Positioning. *Journal of Global Positioning Systems*, 2012. 11(1): p. 22-32.
- [3] Abdu, M.A., Outstanding problems in the equatorial ionosphere-thermosphere electrodynamics relevant to spread F. *Journal of Atmospheric and Solar-Terrestrial Physics*, 2001. 63(9): p. 869-884.
- [4] Appleton, E.V., The anomalous equatorial belt in the F2-layer. *Journal of Atmospheric and terrestrial Physics*, 1954. 5(1-6): p. 348-351.

- [5] Sultan, P.J., Linear theory and modeling of the Rayleigh-Taylor instability leading to the occurrence of equatorial spreadF. *Journal of Geophysical Research: Space Physics*, 1996. 101(A12): p. 26875-26891.
- [6] de lima, G., Stephany, S., de Paula, E., Batista, I., Abdu, M.A., Prediction of the level of ionospheric scintillation at equatorial latitudes in Brazil using a neural network. *Space Weather*, 2015. 13(8): p. 446-457.
- [7] Sridhar, M., Venkata Ratnam, D., Padma Raju, K., Sai Praharsha, D., Saathvika, K., Ionospheric scintillation forecasting model based on NN-PSO technique. *Astrophysics and Space Science*, 2017. 362.
- [8] Basu, S., Groves, K., Basu, S., Sultan, P., Ionospheric scintillation: A Tutorial. *J. Atmos. Sol.-Terr. Phys.*, 2002.
- [9] Béniguel, Y., Adam, J.P., Jakowski, N., Noack, T., Wilken, V., Valette, J. J., Cueto, M., Bourdillon, A., Lassudrie-Duchesne, P., Arbesser-Rastburg, B., Analysis of scintillation recorded during the PRIS measurement campaign. *Radio Science*, 2009. 44(1): p. 1-11.
- [10] Forte, B., Radicella, S.M., Comparison of ionospheric scintillation models with experimental data for satellite navigation applications. *Annals of Geophysics*, 2005.
- [11] Secan, J., Bussey, R., Fremouw, E., Basu, S., An improved model of equatorial scintillation. *Radio Science*, 1995. 30(3): p. 607-617.
- [12] Das, A., Gupta, A., Ray, S., Characteristics of L-band (1.5GHz) and VHF (244MHz) amplitude scintillations recorded at Kolkata during 1996-2006 and development of models for the occurrence probability of scintillations using neural network. *Journal of Atmospheric and Solar-Terrestrial Physics*, 2010. 72(9-10): p. 685-704.
- [13] Rezende, L., de Paula, E., Stephany, S., Kantor, I., Muella, M., de Siqueira, P., Correa, K., Survey and prediction of the ionospheric scintillation using data mining techniques. *Space Weather*, 2010. 8(6): p. 1-10.
- [14] Anderson, D., Morton, Y., Jiao, Y., Redmon, R., Day-fo-day Monitoring of the Comparisons Between UHF Scintillation Forecasts and GNSS Observations. 2013.
- [15] de Lima, G., Stephany, S., de Paula, E., Batista, I., Abdu, M.A., Rezende, L., Aquino, M., Dutra, A., Correlation analysis between the occurrence of ionospheric scintillation at the magnetic equator and at the southern peak of the Equatorial Ionization Anomaly. *Space Weather* : (۶)۱۲. ۲۰۱۴. p. 406-416.
- [16] Taabu, S., D'ujanga, FM, Ssenyonga, T., Prediction of ionospheric scintillation using neural network over East African region during ascending phase of sunspot cycle 24. *Advances in Space Research*, 2016. 57(7): p. 1570-1584.
- [17] Van Dierendonck, A.a.Q.H., Measuring ionospheric scintillation effects from GPS signals. *Proceedings of the 57th Annual Meeting of the Institute of Navigation.*, 2001.
- [18] de Paula, E.R., F. S. Rodrigues, K. N. Iyer, I. J. Kantor, M. A. Abdu, P. M. Kintner, B. M. Ledvina, and H. Kintner Equatorial anomaly effects on GPS scintillations in Brazil. 2003.
- [19] Zolesi, B., Cander, L. R., The General Structure of the Ionosphere, in *Ionospheric Prediction and Forecasting*. 2014, Springer. p. 11-48.
- [20] Wilkinson, J., *New Eyes on the Sun: A Guide to Satellite Images and Amateur Observation*. Springer Science & Business Media. 2012.
- [21] Aquino, M.H.O., Waugh, S., Dodson, A., Moore, T., Skone, S., GPS based Ionospheric Scintillation Monitoring. Technical Report, Institute of Engineering Surveying and Space Geodesy, 2004.
- [22] Haykin, S., *Neural Networks and Learning Machines* 2008, New Jersey: Pearson Prentice Hall.
- [23] Beale, R., Jackson, T., *Neural Computing-an introduction*. 1990, London: CRC Press.
- [24] Norgaard, P.M., *The Neural Network Based System Identification Toolbox*. Technical Report, Department of Automation, Technical University of Denmark, 1997.
- [25] Alireza, M., *Genetic algorithm and its applications*. 2014, Tehran: Naghos.

- [26] Schaffer, J.D., Whitley, D., Eshelman, L. J. *Combinations of genetic algorithms and neural networks: A survey of the state of the art.* in *Combinations of Genetic Algorithms and Neural Networks*, 1992., COGANN-92. International Workshop on. 1992. IEEE.
- [27] Alonso, M.A., Fernando Desantes, Jos M. Hernandez, Leonor Hernandez, Vicente Molt, Germn, *Combining Neural Networks and Genetic Algorithms to Predict and Reduce Diesel Engine Emissions.* *IEEE Transactions on Evolutionary Computation*, 2007. 11(1): p. 46-55.
- [28] Davis, D.J.M.a.L., *Training Feedforward Neural Networks Using Genetic Algorithms.* 2005.
- [29] Montana, D.J., *Neural Network Weight Selection Using Genetic Algorithms.* 2008.
- [30] Montana, D.J., Davis, L. *Training Feedforward Neural Networks Using Genetic Algorithms.* in *IJCAI*. 1989.
- [31] Cook, D.F., Ragsdale, C. T. ,Major, R.L., *Combining a neural network with a genetic algorithm for process parameter optimization.* *Engineering applications of artificial intelligence*, 2000. 13(4): p. 391-396.
- [32] Ashour, M.A., AlZahby, S.A, Abdalla, M.I. . *Training Feed Forward Neural Network Using Genetic Algorithm to Predict Mean Temperature.* *IJRRAS*, 2016. 29: p. 19-26.
- [33] Yang, Z., Liu, Z., *Correlation between ROTI and Ionospheric Scintillation Indices using Hong Kong low-latitude GPS data.* *GPS solutions*, 2016. 20(4): p. 815-824.



Combining Neural Network with Genetic Algorithm for prediction of S4 Parameter using GPS measurement

Ali Reza Atabati ¹, Mohammad Mahdi Alizadeh ^{2*}

1- Ms.c student of Geodesy in Department of Geomatics, College of Geodesy & Geomatics Engineering, K.N. Toosi University of Technology

2- Assistant professor in Department of Geomatics, College of Geodesy & Geomatics Engineering, K.N. Toosi University of Technology

Abstract

The ionospheric plasma bubbles cause unpredictable changes in the ionospheric electron density. These variations in the ionospheric layer can cause a phenomenon known as the ionospheric scintillation. Ionospheric scintillation could affect the phase and amplitude of the radio signals traveling through this medium. This phenomenon occurs frequently around the magnetic equator and in low latitudes, mid as well as high latitude regions. Ionospheric scintillation is a very complex phenomenon to be modeled. Patterns of ionospheric scintillation occurrence are depended on spatial and temporal ionospheric variabilities. Neural Network (NN) is a data-dependent method, that its performance improves with the sample size. According to the advantages of NN for large datasets and noisy data, the NN model has been implemented for predicting the occurrences of amplitude scintillations. In this paper, the GA technique was considered to obtain primary weights in the NN model in order to identify appropriate S4 values for GUAM GPS station in Guam country (latitude: 144.8683, Longitude:13.5893). The modeling was carried out for the whole month of June 2017, while this model along with ionospheric physical data was used for predicting ionospheric scintillation at the first day of July 2017, the day after the modeling. The designed model has the ability to predict daily ionospheric scintillation with the accuracy of about 78%.

Key words: Neural Networks, Genetic Algorithm, Ionospheric Scintillation.