

ترکیب روش‌های یادگیری عمیق برای پیش‌بینی درخشش‌های یونسفری با استفاده از شبکه ایستگاه‌های دائمی GNSS در آمریکای جنوبی

علیرضا عتباتی^۱، ایرج جزیریان^{۲*}، محمد مهدی علیزاده الیزئی^۲

۱- دانشجوی دکتری ژئودزی، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

۲- استادیار گروه ژئودزی، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ دریافت مقاله: ۱۴۰۳/۰۲/۰۴ تاریخ پذیرش مقاله: ۱۴۰۳/۰۵/۱۳

چکیده

اغتشاشات پلاسمای یونسفری که اغلب ناشی از فعالیت‌های خورشیدی و میدان‌های مغناطیسی بین سیاره‌ای هستند، سبب ایجاد تغییراتی نامنظم در چگالی الکترونی یونسفر شده که منجر به رخداد درخشش‌های یونسفری می‌شوند. درخشش‌های یونسفری باعث بروز نوسانات شدید در شدت و فاز سیگنال‌های رادیویی شده که می‌توانند بر دقت سیستم‌های ناوبری ماهواره‌ای تأثیر بگذارند. این پدیده به‌صورت نامنظم رخ می‌دهد و درصد رخداد این پدیده در محدوده‌هایی با عرض جغرافیایی پایین و در نزدیکی آنامولی استوایی، به نسبت بالاتر از مناطق با عرض متوسط و بالا است. در این پژوهش از ترکیبی از روش‌های شبکه‌های یادگیری عمیق و استفاده از روش تابع زبان هوپر با دخالت دادن وزن مشاهدات، برای پیش‌بینی مکانی-زمانی درخشش‌های یونسفری به صورت نزدیک به آنی استفاده شده است. در این پژوهش از روش *ConvGRU* که حاصل از ترکیب یک شبکه واحد بازگشتی دروازه‌ای (*GRU*) با یک مدل کانولوشن، به‌عنوان یک روش پیش‌بینی مکانی-زمانی برای مجموعه داده‌های درخشش یونسفری استفاده شده است. برای این منظور، از داده‌های مشاهداتی ۱۲۱ ایستگاه زمینی *GNSS*، در محدوده عرض جغرافیایی ۱۵ درجه شمالی تا ۵۵ درجه جنوبی و محدوده طول جغرافیایی ۲۷۰ درجه تا ۳۳۰ درجه شرقی در محدوده آنامولی استوایی و در سراسر آمریکای جنوبی، برای ماه‌های ژانویه، مارس و جولای سال‌های ۲۰۱۵ (سالی با فعالیت خورشیدی بالا) و ۲۰۲۰ (سالی با فعالیت خورشیدی پایین) استفاده شده است. این انتخاب، ارزیابی دقت مدل پیشنهادی را در طیفی متنوع از سناریوهای ژئومغناطیسی به نمایش می‌گذارد. مدل طراحی شده توانایی پیش‌بینی درخشش‌های یونسفری را با متوسط دقت حدوداً ۷۵٪ برای سال ۲۰۱۵ و ۸۰٪ برای سال ۲۰۲۰ را به‌صورت منطقه‌ای دارد. این مطالعه نشان می‌دهد که با استفاده از تکنیک‌های پیشرفته یادگیری ماشین، می‌توان اغتشاشات یونسفری را با دقت بالا پیش‌بینی کرد که می‌تواند برای یک سیستم هشدار نزدیک به آنی برای کاربران سیستم‌های ناوبری جهت بهبود دقت مشاهدات مناسب باشد.

کلیدواژه‌ها: سیستم تعیین موقعیت جهانی (*GNSS*)، اغتشاشات یونسفری، یادگیری عمیق، واحد بازگشتی مبتنی بر کانولوشن، تابع زبان هوپر، درخشش یونسفری دامنه (*S4*).

* نویسنده مکاتبه‌کننده: تهران، خیابان ولیعصر، بالاتر از میرداماد، پلاک ۱۳۴۶، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده مهندسی نقشه‌برداری.

تلفن: ۰۲۱-۸۸۸۷۷۰۷۰

۱- مقدمه

ایجاد اغتشاشات پلاسمای یونسفر^۱ می‌تواند منجر به ایجاد پدیده‌ای به نام درخشش یونسفری^۲ گردد که می‌تواند تأثیرات زیادی بر سیگنال‌های رادیویی که از یونسفر عبور می‌کند بگذارد. این فعالیت می‌تواند بر عملکرد سیستم‌های ناوبری ماهواره‌ای و ارتباطات رادیویی تأثیرات بسزایی داشته باشد. این اختلالات در سیگنال‌های رادیویی باند L سبب ایجاد اختلالاتی در دامنه و فاز سیگنال شده که به آن درخشش یونسفری فاز و دامنه می‌گویند. درخشش یونسفری دامنه با نوسانات شدید در شدت سیگنال با استفاده از پارامتر نسبت سیگنال به نویز (C/N_0) محاسبه شده و درخشش یونسفری فاز را می‌توان با استفاده از میزان نوسانات در فاز حامل سیگنال اندازه‌گیری نمود [۱]. رفتارسنجی اغتشاشات یونسفری^۳ به دلیل تنوع مکانی-زمانی و پیچیدگی‌های لایه‌های یونسفر و ماهیت فعالیت‌های خورشیدی و میدان مغناطیسی بین سیاره‌ای^۴ (IMF) است که به عنوان عوامل اصلی ایجاد اغتشاشات یونسفری در عرض‌های جغرافیایی متفاوت عمل می‌کنند. عرض‌های جغرافیایی پایین به دلیل ارتباط مستقیم آن‌ها با باد خورشیدی^۵ و اختلالات مغناطیسی کره، مناطق چالش برانگیز ویژه‌ای هستند [۲]. یکی از عوامل ایجاد درخشش‌های یونسفری رخداد پدیده‌ای به نام جوشش‌های پلاسمای استوایی^۶ (EPB) است که نوعی از اغتشاشات بزرگ‌مقیاس یونسفری در راستای میدان مغناطیسی هستند که سبب کاهش چگالی پلاسمای یونسفری می‌شود که در نواحی پایین‌تر لایه F در حوالی مناطق نزدیک به استوا ایجاد می‌گردد. میدان مغناطیسی زمین تأثیر بسزایی

در رخداد این پدیده دارد. دلیل ایجاد این اغتشاشات و انکسار در امواج رادیویی به علت ساختار و قاعده پلاسمای یونسفری است [۳]. رخداد این پدیده بیشتر در محدوده با آنامولی ۲۰-۱۵ درجه از استوا اتفاق می‌افتد که به آن آنامولی یونسفری استوایی^۸ گفته می‌شود. این محدوده که در مناطقی با عرض جغرافیایی پایین واقع شده است، دارای میزان چگالی الکترونی بالاتری است [۴]. جوشش‌های پلاسمای نیرویی به اندازه بردار $E \times B$ حرکتی رو به بالا داشته، که این بردار از یک دوقطبی الکترونی ایجاد شده در این ناحیه نشأت می‌گیرد سپس پس از رسیدن به بالاترین میزان ارتفاع، این لایه در دو سوی شمالی و جنوبی استوا شروع به گسترش یافتن کرده و سبب ایجاد آنامولی یونسفری استوایی به اندازه ۱۵ درجه از استوا به سمت جنوب و شمال مدار استوایی می‌گردد. پلاسمای ضعیف شده^۹ با پلاسمای متراکم شده‌ای که در آنامولی یونسفری استوایی موجود است سبب ایجاد یک گرادیان قدرتمند در ساختار یونسفری می‌شود. این فرآیند سبب رخداد بی‌نظمی‌های شدید در این منطقه شده که منجر به افزایش درخشش یونسفری در آنامولی یونسفری استوایی می‌شود [۵].

در مناطق نزدیک به آنامولی یونسفری استوایی در حوالی غروب خورشید، میزان سرعت حرکت عمودی لایه‌های یونسفری افزایش یافته که در پی آن سبب افزایش ارتفاع لایه F ($Spread-F$) و در پی آن باعث افزایش گرادیان لایه‌های پایین‌تر یونسفر شده و در نتیجه آن میزان جوشش‌های پلاسمای استوایی افزایش پیدا می‌کنند. از عوامل مؤثر بر $Spread-F$ می‌توان از عواملی همچون چرخه‌های خورشیدی، تغییرات فصل و نیز وابستگی به زمان محلی، نام برد. علاوه احتمال رخداد $Spread-F$ به شدت وابسته به عرض جغرافیایی منطقه می‌باشد. مناطقی با عرض‌های

¹ Ionospheric Plasma Irregularities² Ionospheric Scintillations³ Ionospheric Irregularities⁴ Interplanetary Magnetic Field⁵ Solar Wind⁶ Magnetospheric Disturbances⁷ Equatorial Plasma Bubbles⁸ Equatorial Ionospheric Anomaly⁹ Depleted Plasma

اندازه‌گیری‌های فاز حامل و به تبع آن نرم کردن مشاهدات کد می‌توان نویز حاصل را کاهش داد. زمانی که نرم کردن کدها به تناوب دچار قطع و یا قفل شدن روی ماهواره به دلیل درخشش یونسفری شود می‌تواند سبب ایجاد خطا در اندازه‌گیری فاز حامل شده به سبب آن خطای چندمسیری^۴ محلی ایجاد شده که در پی آن نویزهای حرارتی مشاهدات می‌تواند ۱۰-۳ برابر حالت عادی شوند. علاوه بر این درخشش‌های یونسفری می‌تواند سبب افزایش اغتشاشات بالای فرکانسی در اندازه‌گیری فاز شده که مانع از کاهش نویز گردد [۱۰]. در طول دو دهه گذشته، محققین استفاده گسترده‌ای از مشاهدات سیستم ناوبری ماهواره‌ای جهانی^۵ (GNSS) در محاسبه پارامترهایی همچون درخشش یونسفری دامنه و فاز و همچنین پارامترهای دیگری همچون نرخ تغییرات چگالی الکترونی برای پیش‌بینی درخشش‌های یونسفری کرده‌اند. به‌طور مثال، رزنده و همکاران (۲۰۱۰) با استفاده از روش درخت تصمیم‌گیر^۶ و به‌کارگیری بیشترین مشاهدات درخشش یونسفری در بازه‌های یک و نیم‌ساعته برای هر شبانه‌روز مدلی برای پیش‌بینی رخداد اغتشاشات یونسفری ارائه کردند که قادر به پیش‌بینی درخشش‌های شدید یونسفری در بازه‌های مشاهداتی است [۱۱]. عتباتی و همکاران (۲۰۲۰) یک روش پیش‌بینی درخشش یونسفری روزانه را با استفاده از ترکیب یک مدل پراسپرتون چندلایه با روش الگوریتم ژنتیک برای مشاهدات تک ایستگاه ارائه دادند [۱۲ و ۱۳]. مدل‌سازی با استفاده از روش یادگیری عمیق^۷ در کارهای گذشته برای مدل‌سازی مکانی و زمانی مقادیر پارامترهای یونسفری همچون محتوای کلی الکترونی (TEC) و یا نرخ تغییرات TEC استفاده شده است. لیو و همکاران (۲۰۲۱) در یک مطالعه یک الگوریتم یادگیری ماشین حافظه کوتاه‌مدت کانولوشنال

جغرافیایی پایین به‌طور معمول $Spread-F$ بیشتر در طول شب و نزدیک به غروب آفتاب و در محدوده اطراف نقاط اعتدالین رخ می‌دهد [۶]. اغتشاشات یونسفری رخ داده در محدوده لایه F گسترش یافته در محدود نزدیک به استوا یکی از عوامل اصلی رخداد درخشش‌های یونسفری است که به آن اغتشاشات لایه F گسترش یافته استوایی^۱ (ESF) گفته می‌شود. دلیل اصلی رخداد این اغتشاشات فرآیندی ناپایدار به نام رالف-تیلور^۲ بوده که حاصل از سرعت حرکت عمودی لایه‌های یونسفری و افزایش گرادیان لایه‌های یونسفر در محدوده آنامولی استوایی است. یکی از مهم‌ترین نتایج فرآیند ناپایدار RT ، افزایش سرعت پلاسمای عمودی لایه F در محدوده استوایی است که تحت تأثیر میدان الکتریکی منطقه‌ای پس‌زمینه در استوا مغناطیسی است [۷]. در حوالی غروب آفتاب، با افزایش میدان الکتریکی منطقه‌ای قبل از برگشت^۳ (PRE) مشاهده می‌شود که شرایط مناسبی را برای رشد فرآیند ناپایدار RT ایجاد می‌کند [۸]. اثرات اغتشاشات یونسفری بر سیگنال‌های رادیویی را می‌توان به سه دسته کلی تقسیم‌بندی نمود. در ابتدا این پدیده قادر است که میزان کمیت و کیفیت اندازه‌گیری گیرنده را کاهش داد و می‌تواند در اندازه‌گیری‌های ایستگاه‌های دائمی GNSS تأثیر گذارد و علاوه بر آن این پدیده قادر به آن است که در اندازه‌گیری‌های ماهواره‌ای که بر مبنای ارتباط میان ماهواره‌ها با یکدیگر است تأثیر گذاشته و سبب قطع ارتباط میان-ماهواره‌ای به‌خصوص در ماهواره‌های کوتاه پرواز شود [۹]. اغتشاشات یونسفری می‌تواند سبب از دست دادن سیگنال ارسالی شده و یا سبب افزایش میزان نویز در مقادیر باقی‌مانده شود. قطع سیگنال بر توانایی گیرنده برای نرم کردن اندازه‌گیری‌ها و کاهش نویز مؤثر است. با استفاده از

^۴ Multi Path^۵ Global Navigation Satellite System (GNSS)^۶ Decision Tree^۷ Deep Learning^۱ Equatorial Spread-F^۲ Rayleigh-Taylor^۳ Pre-reversal Enhancement Electric Field

عصبی بازگشتی^۵ (*RNN*) برای پردازش داده‌های سری یا دنباله‌دار مفید هستند و در آن‌ها هر نورون یا واحد پردازشی قادر به حفظ حالت داخلی^۶ یا همان حافظه به‌منظور حفظ اطلاعات مرتبط با ورودی قبلی است [۱۷]. شبکه‌های حافظه کوتاه‌مدت طولانی^۷ (*LSTM*) نوعی از شبکه‌های عصبی بازگشتی هستند. یک شبکه عصبی بازگشتی سنتی از نظر تئوری باید قادر به تولید دنباله‌هایی با هر پیچیدگی باشد اما در عمل مشاهده می‌شود که این شبکه در ذخیره‌سازی اطلاعات مرتبط با ورودی‌های گذشته برای بازه‌های زمانی طولانی مشکلاتی دارد. حافظه طولانی کوتاه‌مدت یا به‌اختصار *LSTM* یک معماری شبکه عصبی بازگشتی است که برای ذخیره‌سازی و دسترسی بهتر به اطلاعات نسبت به نسخه سنتی آن طراحی شده است [۱۸]. شبکه‌های واحد بازگشتی دروازه‌ای^۸ (*GRU*) عموماً به‌عنوان نسخه ای تغییر یافته از *LSTM* در نظر گرفته می‌شود چرا که هر دو این معماری‌ها از طراحی مشابهی بهره می‌برند. این شبکه از دو دروازه به نام‌های دروازه بازنشانی^۹ و دروازه به‌روزرسانی^{۱۰} استفاده می‌کند. معماری یک سلول *GRU* بسیار شبیه به سلول یک شبکه بازگشتی ساده است. به کمک این دو قابلیت جدید، شبکه عصبی *GRU* به راحتی می‌تواند نسبت به ذخیره‌سازی و یا فیلتر کردن اطلاعات از گام‌های زمانی قبلی اقدام کرده و از دنباله‌های طولانی که شبکه عصبی بازگشتی سنتی در مواجه با آن با مشکلات عدیده‌ای مواجه بود بهره‌برداری کند و کاستی‌های شبکه عصبی بازگشتی سنتی را مرتفع سازد [۱۹].

شی و همکاران (۲۰۱۵) یک ترکیبی از یک شبکه *LSTM* را با یک مدل کانولوشنال^{۱۱} بنام *ConvLSTM*

مبتنی بر تصویر را برای پیش‌بینی اغتشاشات یونسفری زمان در زمان رخداد طوفان ژئومغناطیسی در عرض‌های جغرافیایی بالا ارائه می‌کند که می‌تواند یک پیش‌بینی کوتاه‌مدت را به صورت مکانی-زمانی با استفاده از روش‌های یادگیری عمیق ارائه دهد [۱۴].

پیش‌بینی درخشش یونسفری با استفاده از مدل‌های ریاضی همچون یادگیری عمیق که بتوانند مدل‌سازی و پیش‌بینی این پدیده را به صورت دوبعدی برای یک سری زمانی انجام دهند، از آن جهت ارزشمند است که تاکنون راه‌حلی قطعی برای مدل‌سازی این پدیده با استفاده از روش‌های عددی ارائه نشده است، لذا برای پیش‌بینی این گونه پدیده‌ها می‌تواند کارگشا باشد. یادگیری عمیق زیرشاخه‌ای از یادگیری ماشین است که از لایه‌های متعدد تبدیلات خطی به‌منظور پردازش سیگنال‌های مشاهداتی مانند تصاویر دوبعدی یا سیگنال‌های تک‌بعدی استفاده می‌کند [۱۵]. منظور از یادگیری عمیق در بیشتر مواقع در واقع در بیشتر مواقع همان شبکه عصبی عمیق است. واژه عمیق در بحث شبکه عصبی عمیق می‌تواند ناشی از وجود عمق در تمامی ابعاد شبکه عصبی با توجه به روش قابل‌استفاده در مبحث یادگیری عمیق باشد. عمیق در یادگیری عمیق به عمق لایه‌ها در یک شبکه عصبی اشاره دارد. شبکه‌های عصبی کانولوشن^۲ (*CNN*) تا حد بسیار زیادی شبیه شبکه‌های عصبی مصنوعی^۳ هستند. این نوع شبکه‌ها متشکل از نورون‌هایی با وزن‌ها و بایاس-های قابل یادگیری و تنظیم هستند. هر نورون تعدادی ورودی دریافت کرده و سپس حاصل ضرب وزن‌ها در ورودی‌ها را محاسبه کرده و در انتها با استفاده از یک تابع تبدیل^۴ (فعال‌ساز) غیرخطی نتیجه‌ای را ارائه دهد [۱۶].

نوع دیگری از شبکه‌های عصبی عمیق یعنی شبکه‌های

⁵ Recurrent Neural Network

⁶ Internal State

⁷ Long-Short Term Memory

⁸ Gated Recurrent Unit

⁹ Reset Gate

¹⁰ Update Gate

¹¹ Convolutional

¹ Deep Neural Network

² Convolutional Neural Network

³ Artificial Neural Network

⁴ Transfer Function

همین بخش به معرفی روش استفاده شده برای تابع استفاده از تابع ضرر در روند محاسبات پرداخته می‌شود. در بخش نتایج ابتدا به معرفی منطقه مورد مطالعه و سپس نتایج عددی حاصل شده از روش پیش‌بینی اغتشاشات یونسفری به صورت نزدیک به آنی ارائه خواهد شد و در آخرین بخش با استفاده از روش‌های آماری به ارزیابی نتایج در شناسایی انواع درخشش‌های یونسفری پرداخته می‌شود.

۲- داده‌ها و متغیرهای مورد استفاده

یکی از رایج‌ترین روش‌های شناسایی اغتشاشات یونسفری استفاده از مشاهدات گیرنده‌های ایستگاه‌های دائمی GNSS است که برای تشخیص درخشش یونسفری و رفتار و علل ایجاد آن می‌توان از مشاهداتی همچون نرخ تغییرات پارامتر درخشش یونسفری دامنه بهره گرفت [۲۲]. برای شناسایی درخشش‌های یونسفری می‌توان از مشاهدات $S4$ که به پارامتر درخشش یونسفری دامنه نیز شناخته می‌شود، جهت شناسایی درخشش یونسفری بر سیگنال ارسالی استفاده کرد. این پارامتر مهم‌ترین مؤلفه برای شناسایی درخشش‌های یونسفری مخصوصاً در محدوده‌های نزدیک به استوا است. پارامتر $S4$ با نام درخشش یونسفری دامنه یاد می‌شود که حاصل از مشاهده $C/N0$ فایل مشاهدات خام گیرنده GNSS بوده و جهت شناسایی درخشش‌های یونسفری که نوعی از اغتشاشات یونسفری هستند، مورد استفاده قرار می‌گیرد [۲۳]. مشاهده $C/N0$ حاصل از فایل مشاهداتی گیرنده به صورت پارامتر $S1$ و $S2$ در هر دو باند فرکانسی $L1$ و $L2$ است که از فایل مشاهدات قابل برداشت است. در محاسبه پارامتر $S4$ ابتدا به کمک پارامتر $C/N0$ ، میزان نرخ سیگنال به نویز ($S/N0$) را محاسبه نموده که در رابطه (۱) نمایش داده شده است و پس از آن با دیترند^۲ کردن مقادیر محاسبه شده، مقادیر $S/N0$

برای داده‌های مکانی-زمانی پیشنهاد کردند [۲۰]. در این روش یک شبکه عصبی کانولوشنال را با یک شبکه عصبی تکراری ترکیب کردند و توانستند به دقت خوبی برای پیش‌بینی بارندگی با استفاده از تصاویر رادار دست یابند. یکی از مزایای $ConvLSTM$ نسبت به روش CNN و $LSTM$ در این است که می‌توان همزمان شبکه را با استفاده از همبستگی میان زمان و مکان داده‌ها آموزش داد. با این حال، $ConvLSTM$ پارامترهای بسیار زیادی دارد و به راحتی می‌تواند داده‌ها را تحت الشعاع قرار دهد. با توجه به این مشکل، می‌توان از روش $ConvGRU$ به عنوان یک روش پیش‌بینی مکانی-زمانی چندمرحله‌ای که با استفاده از یک استراتژی پیش‌بینی چندمرحله‌ای برای چندین تانسور ورودی و خروجی بهره گرفت [۲۱].

در این پژوهش از یک روش ترکیبی از شبکه‌های یادگیری عمیق برای یک پیش‌بینی مکانی-زمانی برای یک سری زمانی استفاده شده است. استفاده از روش $ConvGRU$ برای مجموعه داده‌هایی همچون پارامتر درخشش یونسفری ($S4$) که داده‌هایی به نسبت زیاد را به صورت مکانی و زمانی برای آموزش شبکه و سپس پیش‌بینی پارامتر مشاهداتی استفاده می‌کنند، به نسبت سایر روش‌ها مناسب‌تر است. از این رو مدل‌سازی و پیش‌بینی اغتشاشات یونسفری همچون درخشش‌های یونسفری می‌تواند سبب کاهش میزان تأثیرات خطاهای یونسفری در مشاهدات سامانه‌های ماهواره‌ای ناوبری جهانی (GNSS) و در نتیجه سبب افزایش میزان دقت در کارکرد ارتباطات ماهواره‌ای و ناوبری گردد. در این مقاله ابتدا به معرفی پارامترهای درخشش یونسفری حاصل از مشاهدات GNSS جهت تشخیص اغتشاشات یونسفری خواهیم پرداخت. سپس در بخش روش تحقیق به معرفی مدل طراحی شده $ConvGRU$ برای پیش‌بینی درخشش یونسفری که قابلیت مدل‌سازی دوبعدی اغتشاشات یونسفری برای یک بازه زمانی بلندمدت و همچنین پیش‌بینی مکانی-زمانی اغتشاشات یونسفری را خواهد داشت، پرداخته خواهد شد. در

¹ Amplitude Ionospheric Scintillation

² Detrend

دیترنده را در رابطه (۲) محاسبه می‌کنیم [۲۴].

$$S / N_0 = 10^{0.1(C/N_0)} \quad \text{رابطه (۱)}$$

$$SI_{\text{detrended}}^{S/N_0} = \frac{(S / N_0)_k}{\sum_{i=1}^{60 \times f_s} \frac{(S / N_0)_{k-i}}{60 \times f_s}} \quad \text{رابطه (۲)}$$

در رابطه (۲)، f_s بیانگر نرخ مشاهدات گیرنده GNSS است. سپس با توجه به روابط (۱) و (۲)، مقادیر $S4$ طبق رابطه (۳) محاسبه می‌شود:

$$S4 = \sqrt{\frac{\langle (SI_{\text{detrended}}^{S/N_0})^2 \rangle - \langle SI_{\text{detrended}}^{S/N_0} \rangle^2}{\langle SI_{\text{detrended}}^{S/N_0} \rangle^2}}$$

با استفاده از رابطه (۳) می‌توان دید که $S4$ با توجه به نوع محاسبه آن که حاصل از انحراف معیار مقادیر شدت سیگنال به نویز دیترنده شده برای یک بازه زمانی است، لذا واحدی برای معرفی آن وجود ندارد. مقادیر $S4$ برای فواصل زمانی از چند ثانیه تا چندین ساعت با توجه به نیاز کاربر استفاده می‌شود. در این پژوهش از مشاهدات مجموعه‌ای از ایستگاه‌های زمینی با نرخ مشاهداتی سی‌ثانیه‌ای برای محاسبه پارامتر $S4$ با گام زمانی پنج‌دقیقه‌ای استفاده شده است. می‌توان با استفاده از پارامتر $S4$ نوع درخشش یونسفری رخ داده را به صورت رابطه (۴) محاسبه نمود [۲۵]:

رابطه (۴)

$$S4 = \begin{cases} S4 < 0.2 & \text{No Scintillation} \\ 0.2 \leq S4 < 0.4 & \text{Weak Scintillation} \\ 0.4 \leq S4 < 0.6 & \text{Medium Scintillation} \\ 0.6 \leq S4 & \text{Strong Scintillation} \end{cases}$$

با استفاده از رابطه (۴) می‌توان دید که $S4$ را می‌توان با توجه به حد آستانه‌های تعریف شده به چهار حالت تقسیم‌بندی نمود. زمانی که مقدار $S4$ کمتر از ۰٫۲ است و درخشش یونسفری اتفاق نیافتاده است، زمانی که مقدار $S4$ بین ۰٫۲ تا ۰٫۴ است که در این حالت شاهد درخشش‌های یونسفری ضعیف هستیم، زمانی که

$S4$ در محدوده ۰٫۴ تا ۰٫۶ است که شاهد درخشش‌های یونسفری متوسط هستیم و زمانی که مقدار $S4$ بیشتر از ۰٫۶ است که شاهد درخشش‌های یونسفری شدید خواهیم بود. با استفاده از این طبقه‌بندی می‌توان رفتار درخشش‌های یونسفری را بر اساس مقدار پارامتر $S4$ محاسبه و ارزیابی نمود.

۳- روش تحقیق

در این بخش به توضیح روش پیشنهادی برای مدل‌سازی و سپس پیش‌بینی اغتشاشات یونسفری به صورت مکانی-زمانی^۱ خواهیم پرداخت. 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 تأثیر کمتری نسبت به داده‌های آلوده به نویز قرار گرفته و قابلیت استفاده از داده‌های آلوده به نویزی برای مقادیر زیادی از مشاهدات را داراست [۲۶]. یادگیری عمیق زیرشاخه‌ای از یادگیری ماشین است که از لایه‌های متعدد تبدیلات خطی به منظور پردازش سیگنال‌های مشاهداتی مانند تصاویر دوبعدی استفاده می‌کند. منظور از یادگیری عمیق در بیشتر مواقع درواقع شبکه عصبی عمیق است. واژه عمیق در بحث شبکه عصبی عمیق می‌تواند ناشی از وجود عمق در تمامی ابعاد شبکه عصبی با توجه به روش قابل استفاده در مبحث یادگیری عمیق باشد. عمیق در یادگیری عمیق به عمق لایه‌ها در یک شبکه عصبی اشاره دارد. یک شبکه عصبی متشکل از بیش از سه لایه، که شامل ورودی‌ها، لایه‌های پنهان و خروجی‌ها هم می‌شود، را می‌توان یک الگوریتم یادگیری عمیق دانست [۲۷]. شبکه‌های عصبی بازگشتی (RNN) نسل بعدی شبکه‌های عصبی بود. شبکه‌های عصبی بازگشتی برای پردازش یک سری داده هستند و در آن‌ها هر سلول پردازشی قادر به حفظ

^۱ Spatio-Temporal

افزایش خطای انباشت گرادیان و یا خطای ناپدید شدن گرادیان را رفع کرده، زمان پردازش طولانی و برازش بیش‌ازحد ناشی از توالی‌های طولانی *RNN*‌های سنتی را برطرف نموده و توانایی بهینه‌سازی محلی و نیز توانایی تعمیم شبکه را بهبود می‌بخشد [۲۸]. شبکه‌های عصبی واحد بازگشتی دروازه‌ای مبتنی بر کانولوشن (*ConvGRU*) در مقایسه با شبکه‌های *GRU* توانایی یادگیری قوی‌تری برای یک سری زمانی از داده‌های دوبعدی دارند. ساختار درونی شبکه‌های *LSTM* و *GRU* یک روند تقریباً کاملاً متصل‌را اتخاذ می‌کنند که سبب مشکلاتی در خصوص تکرار و توالی اطلاعات‌را به همراه خواهد داشت و این ارتباط همبستگی مکانی میان پیکسل‌های محلی در داده‌های دوبعدی را برای سری‌های زمانی نادیده می‌گیرد. ساختار *ConvGRU* تنها نمی‌تواند روابط زمانی مانند *GRU* ایجاد کند، بلکه ویژگی‌های فضایی محلی را همانند شبکه‌های کانولوشن عمیق را نیز ایجاد می‌کند. شبکه‌های *ConvGRU* ایده ارتباط میان روش کاملاً متصل در *GRU* را با استفاده از ساختارهای کانولوشن گسترش و تغییر می‌دهد. به‌گونه‌ای که در این روش عملیات ضرب نقطه‌ای در شبکه‌های *GRU* را با عملیات کانولوشن جایگزین می‌نماید. ساختار داخلی شبکه‌های *ConvGRU* مبتنی بر ورودی و عناصر خروجی تانسورهای سه‌بعدی هستند که الگوهای مکانی را برای سری‌های زمانی در خود حفظ می‌کنند که بزرگ‌ترین ویژگی و مزیت این نوع شبکه‌ها هستند [۲۹]. این پژوهش از روش ترکیب شبکه‌های *GRU* مبتنی بر کانولوشن (*ConvGRU*) برای پیش‌بینی درخشش‌های یونسفری استفاده می‌کند. در ادامه به توضیح شبکه‌های *ConvGRU* خواهیم پرداخت.

حالت داخلی^۱ یا همان حافظه به جهت حفظ اطلاعات مرتبط با ورودی قبلی می‌باشد که در کاربردهای مرتبط با داده‌های سری زمانی اهمیت اساسی پیدا می‌کند. این ویژگی به شبکه کمک می‌کند تا قادر به فهم و کشف ارتباط میان داده‌ها در سری‌های طولانی باشد. در شبکه‌های عصبی بازگشتی یک عملیات برای تمام المان‌های یک سری داده انجام می‌گیرید و خروجی آن وابسته به ورودی فعلی و عملیات‌های قبلی می‌باشد. این رفتار با تکرار یک خروجی از شبکه در زمان t با ورودی شبکه در زمان $t+1$ انجام می‌گیرد که در آن خروجی‌هایی از مرحله قبل با مقادیر ورودی در مرحله جدید ترکیب می‌شوند. این چرخه‌ها اجازه وجود اطلاعات از یک گام زمانی به گام زمانی بعدی را میسر می‌کنند و به عبارت دیگر این شبکه با حلقه‌ای در درون خود قادر است اطلاعات را در حین خواندن ورودی از نوروها منتقل کند [۱۷].

شبکه عصبی بازگشتی سنتی نمی‌تواند در طول آموزش وابستگی طولانی‌مدت را به دلیل افزایش خطای انباشت گرادیان و یا خطای ناپدید شدن گرادیان به‌خوبی مدیریت کند، از این رو شبکه‌هایی همچون *LSTM* و *GRU* ابداع شدند که با استفاده از دروازه‌های متعدد میزان این نوع خطا را برای سری‌های زمانی طولانی کاهش دهند. همان‌طور که میدانیم انباشت گرادیان برعکس ناپدید شدن گرادیان است و زمانی است که گرادیان به بزرگ‌تر شدن ادامه می‌دهد که باعث به‌روزرسانی‌های پی‌درپی وزن‌ها می‌شود و منجر به واگرایی گرادیان نزولی می‌شود. شبکه‌های *GRU* در مقایسه با شبکه‌های *LSTM* عملکردی مشابه ولی مدل ساده‌تری دارند که می‌توانند رفتارهای شبکه *LSTM* را با زمان همگرایی آموزشی سریع‌تر حفظ کنند. شبکه‌های *GRU* الگوهای *RNN* را برای کشف وابستگی‌های ذاتی برای داده‌های دنباله‌ای را به ارث می‌برد ولی درعین حال می‌توانند مشکلات ناشی از

^۲ Fully Connected^۳ Redundancy Problems^۱ Internal State

۳-۱- واحد بازگشتی دروازه‌ای مبتنی بر

کانولوشن ConvGRU

شبکه‌های ConvGRU که به آن‌ها شبکه‌های واحد بازگشتی دروازه‌ای مبتنی کانولوشن گفته می‌شود نسبت به شبکه‌های GRU توانایی یادگیری قوی‌تری دارند. ساختار شبکه‌های ConvGRU علاوه بر توانایی یادگیری برای یک سری زمانی برای داده‌های یک دنباله، قادر است که ویژگی‌های مکانی داده‌های دوبعدی ورودی را همانند شبکه‌های CNN مدل نموده و سپس در پیش‌بینی خود استفاده نماید لذا نسبت به شبکه‌های GRU توانایی یادگیری بالاتری دارند. ساختار درونی شبکه‌های LSTM و GRU یک رویکرد تقریباً کاملاً متصل را اتخاذ نموده که مشکلات زیادی را در مورد انباشت اطلاعات به همراه دارد و بعلاوه این نوع شبکه‌ها ارتباط همبستگی مکانی میان پیکسل‌های مجاور در داده‌های دوبعدی را نادیده می‌گیرد. ایده استفاده از شبکه‌های ConvGRU حالت اتصال کامل در شبکه‌های GRU را به ساختار کانولوشن تغییر داده و عملیات ضرب نقطه‌ای را در شبکه با عملیات کانولوشن جایگزین می‌کند. در ساختار شبکه‌های ConvGRU تمامی ورودی و خروجی‌ها تانسورهای سه‌بعدی هستند که اطلاعات و ویژگی‌های مکانی را در یک سری زمانی در بردارند. با دارا بودن ویژگی حافظه در شبکه GRU، ConvGRU نیز می‌تواند روند مکانی توالی‌های تصاویر ورودی را در یک بازه زمانی طولانی مدت مدت حفظ کرده و نیز می‌تواند از انتقال مؤثر اطلاعات ویژگی در یک بازه زمانی طولانی‌تر اطمینان حاصل نماید و دقت نتایج پیش‌بینی مکانی-زمانی خود را بهبود بخشد. معادلات اصلی ConvGRU در روابط (۵) تا (۱۰) به صورت زیر آورده شده است:

$$z_t = \sigma(W_{xz} * X_t + W_{hz} * h_{t-1} + b_z) \quad \text{رابطه (۵)}$$

$$r_t = \sigma(W_{xr} * X_t + W_{hr} * h_{t-1} + b_r) \quad \text{رابطه (۶)}$$

$$\hat{h}_t = f(W_{xh} * X_t + r_t \circ (W_{hh} * h_{t-1}) + b_h) \quad \text{رابطه (۷)}$$

$$h_t = (1 - z_t) \circ \hat{h}_t + z_t \circ h_{t-1} \quad \text{رابطه (۸)}$$

$$X_t \in \mathbb{R}^{C_t \times H \times W} \quad \text{رابطه (۹)}$$

$$\hat{h}_t \in \mathbb{R}^{C_h \times H \times W} \quad \text{رابطه (۱۰)}$$

در روابط (۵) تا (۱۰)، پارامتر r_t معرف دروازه بازنشانی، z_t دروازه به‌روزرسانی، $\hat{h}_t$ سلول حافظه کنونی^۱، h_t سلول حافظه نهایی^۲، h_{t-1} میزان خروجی حالت برای لایه پنهانی قبلی است. در این روابط، بایاس‌ها با پارامتر b ، وزن‌های ماتریسی با W و داده ورودی با X_t نمایش داده شده‌اند. در روابط مذکور، $\circ$ نماد ضرب درایه‌ای^۳، $*$ نماد ضرب کانولوشن و σ نشان‌دهنده تابع سیگموئید است. تابع فعال‌ساز مورد استفاده برای این شبکه تابع ReLU خواهد بود. با توجه به معادلات بالا می‌توان گفت که دروازه به‌روزرسانی (z_t) درگاهی است که مشخص می‌کند در یک گام زمانی معادلات بر مبنای استفاده از حالت قبلی آن سلول باشد (h_{t-1}) یا ورودی سلول (X_t) و یا ترکیبی از هر دوی آن‌ها مورد استفاده قرار گیرد. با کمک این روش شبکه قادر خواهد بود در سری زمانی‌های طولانی به راحتی یک حالت از چندین گام زمانی قبل را در چند گام زمانی بعدی تأثیر دهد و یا به عبارت دیگر شبکه قادر است تا المان‌هایی را از گذشته در حافظه خود نگه داشته و از آن استفاده نماید. قابلیت به‌روزرسانی اضافه شده در GRU به نسبت شبکه عصبی بازگشتی سنتی دو فایده خواهد داشت؛ اولاً هر سلول می‌تواند یک ویژگی خاص را در جریان ورودی خود برای گام‌های زمانی بعدی به یاد داشته باشد و ویژگی‌ای که توسط دروازه به‌روزرسانی مهم تلقی شود می‌تواند بدون تکرارهای مجدد حفظ شود. ثانیاً شبکه

^۱ Current Memory Cell

^۲ Final Memory Cell

^۳ Hadamard Product

یکی دیگر از توابع زیان میانگین قدر مطلق خطا^۴ (MAE) است. این تابع زیان، به‌مانند MSE از فاصله بین مقدار پیش‌بینی و واقعی به عنوان معیار استفاده کرده ولی جهت این تفاضل را در نظر نمی‌گیرد. بنابراین MAE میانگین قدر مطلق تفاضل بین مقدار پیش‌بینی و واقعی را محاسبه می‌کند. شیوه محاسبه MAE در رابطه (۱۲) آورده شده است.

$$L_{MAE} = \frac{1}{n} \sum_{i=1}^n w_i \cdot |y_i - \hat{y}_i| \quad \text{رابطه (۱۲)}$$

البته مسلم است که هر دو تابع زیان MAE و MSE زمانی که برآورد با مقدار واقعی برابر باشد، حداقل مقدار (صفر) خواهند بود. اگر از تابع زیان MSE جذر گرفته شود، تابع زیان دیگری به نام ریشه میانگین مربعات خطا^۵ ($RMSE$) ساخته می‌شود. اگر مقدار پیش‌بینی به مقدار واقعی نزدیک باشد MSE میزان خطا را منقبض می‌کند و در خطا فشردگی به وجود می‌آورد. از آنجایی که در محاسبه زیان MSE از مربع خطا استفاده می‌شود، اگر میزان خطا بزرگ‌تر از یک باشد، مقدار MSE بزرگ می‌شود. در صورت وجود داده‌های نویزی خطا افزایش یافته و تابع زیان MSE ، خطا را بسیار بزرگ‌تر نشان می‌دهد. بنابراین به نظر می‌رسد که داده‌های نویزی در محاسبه MSE تأثیر بیشتری در کاهش دقت آموزش نسبت به MAE دارند. می‌توان گفت تابع زیان MAE نسبت به وجود داده‌های پرت^۶ مقاوم‌تر است بنابراین هنگامی که داده‌های پرت یا دورافتاده در مشاهدات وجود دارد، استفاده از تابع زیان MAE می‌تواند کارایی مدل را بالا ببرد. از سویی دیگر، هنگام استفاده از MAE ، مقدار گرادیان تابع زیان، برای مقدارهای کوچک خطا نیز بزرگ است. این وضعیت برای الگوریتم‌های یادگیری ماشین مناسب نیست. برای حل این مشکل بهتر است از «نرخ یادگیری پویا»^۷

توانایی جدیدی در مسیرهای میانبری ایجاد می‌کند که چندین گام زمانی را پشت سر می‌گذارد. این میانبرها به همین صورت به خطای تولیدی اجازه می‌دهد تا بدون آنکه خیلی سریع محو شود به راحتی در فاز پس انتشار منتقل گردد و این‌طور معضلات مرتبط با گرادیان‌های محو شونده کاهش میابد [۱۹]. با استفاده از دروازه بازنشانی شبکه می‌تواند معین کند چه مقدار از اطلاعات گذشته در گام فعلی مورد نیاز نیست و باید فراموش شود و نیز در گام فعلی چه میزان از اطلاعات گام قبل مورد استفاده قرار گیرد. هر بار که یک ورودی جدید در قالب یک تانسور وارد شبکه می‌شود، دروازه بازنشانی مجدد کنترل خواهد کرد که آیا حالت قبلی مورد استفاده قرار گیرد یا خیر و دروازه به‌روزرسانی میزان استفاده از داده‌های ورودی جدید را در h_t کنترل می‌کند. با توجه به اینکه ورودی این شبکه‌ها یک تانسور است؛ مقادیر H و W ارتفاع و عرض و مقادیر C_i و C_h نیز به ترتیب اندازه کانال تانسورهای حالت و ورودی خواهند بود.

۳-۲- تابع زیان

تابع زیان، معیاری برای سنجش مناسب بودن مدل از نظر قابلیت و توانایی در پیش‌بینی مقدارهای جدید است. زمانی که یک مدل یادگیری ماشین را آموزش^۱ می‌دهیم، هدف پیدا کردن نقطه‌ای است که تابع زیان در آن کمینه می‌شود. یکی از روش‌های معمول برای پیدا کردن کمینه تابع زیان، استفاده از مشتق و الگوریتم گرادیان نزولی^۲ است. یکی از معمول‌ترین توابع زیان در تحلیل رگرسیونی، میانگین مربعات خطا^۳ (MSE) نامیده می‌شود. این تابع زیان، میانگین مربعات فاصله بین مقدار پیش‌بینی و واقعی را محاسبه می‌کند. شیوه و نحوه محاسبه آن در رابطه (۱۱) دیده می‌شود:

$$L_{MSE} = \frac{1}{n} \sum_{i=1}^n w_i \cdot (y_i - \hat{y}_i)^2 \quad \text{رابطه (۱۱)}$$

^۴ Mean Absolute Error

^۵ Root Means Square Error

^۶ Outlier

^۷ Dynamic Learning Rate

^۱ Train

^۲ Gradient Descent

^۳ Means Square Error

استفاده شود که هنگام نزدیک شدن به نقطه کمینه، مقدارش کاهش می‌یابد. ولی گرادیان تابع زیان MSE ، زمانی که مقدار خطا، بزرگ باشد، زیاد و هنگامی که خطا کم شود، کاهش خواهد یافت. اگر داده‌های نویزی، بیانگر مقدارهای غیرمعمول بوده و باید حتماً برای مدل‌سازی شناسایی شوند، استفاده از تابع زیان MSE می‌تواند مفید باشد. ولی اگر داده‌های نویزی، حاصل مشاهدات اشتباه باشد، بهتر است از MAE استفاده کنیم تا اثر آن‌ها را در برآورد پارامترهای مدل از بین ببریم. توابع زیان MAE نسبت به داده‌های نویزی مقاوم‌تر بوده ولی مشتق آن‌ها پیوسته نیست. در نتیجه برای پیدا کردن کمینه به‌راحتی از روش‌های مشتق‌گیری نمی‌توان استفاده کرد. در مقابل توابع زیان MSE نسبت به داده‌های نویزی دقیق نبوده ولی محاسبات مربوط به پیدا کردن نقاط کمینه آن ساده‌تر است و به کمک روش‌های تحلیلی محاسبه می‌شوند. برای این منظور می‌توان از ترکیبی از دو روش MAE و MSE برای حل مشکل این دوگانگی بهره گرفت. استفاده از تابع زیان هوبر^۱ یا میانگین خطای قدر مطلق هموار شده^۲ در این تحقیق مورد استفاده قرار گرفته است. تابع زیان هوبر نسبت به MSE کمتر تحت تأثیر داده‌های پرت است و همچنین، برعکس تابع زیان MAE ، مشتق‌پذیر بوده و کمینه‌سازی آن به‌راحتی امکان‌پذیر است و مطابق با رابطه (۱۳) محاسبه می‌شود:

رابطه (۱۳)

$$L_{\delta} = \begin{cases} w_i \cdot \frac{1}{2} (y_i - \hat{y}_i)^2 & |y_i - \hat{y}_i| \leq \delta \\ w_i \cdot (\delta |y_i - \hat{y}_i| - \frac{1}{2} \delta^2) & |y_i - \hat{y}_i| > \delta \end{cases}$$

در نگاه اول، شاید این تابع، همان MSE به نظر برسد ولی با دقت بیشتر، متوجه می‌شویم که با کوچک بودن خطا یا فاصله بین y و $\hat{y}$ از مقدار δ تابع زیان شبیه

تابع زیان MSE است و در غیر اینصورت شبیه تابع زیان MAE خواهد شد. در نتیجه همان‌طور که مشخص است، شکل تابع زیان هوبر برحسب مقدار δ تغییر می‌کند. اگر $\delta \sim 0$ (به سمت صفر نزدیک شود) تابع زیان هوبر به تابع زیان MSE نزدیک می‌شود. در صورتی که $\delta \sim \infty$ (مقدار آن بزرگ باشد) این تابع زیان، تبدیل به تابع زیان MAE خواهد شد. یکی از مشکلات عمده، هنگام استفاده از تابع زیان MAE در یادگیری شبکه عصبی، بزرگ بودن مشتق است که ممکن است باعث شود، کمینه مقدار تابع زیان در پایان مراحل یادگیری به‌وسیله الگوریتم گرادیان کاهشی حاصل نشود. در عوض، استفاده از تابع زیان هوبر باعث می‌شود، زمانی که میزان خطا کاهش می‌یابد، مشتق کاهش یافته و دسترسی به کمینه مقدار تابع زیان هوبر میسر شود. بنابراین تابع زیان هوبر از مزایای هر دو تابع زیان MSE و MAE بهره برده است. به این ترتیب این تابع زیان، زمانی که داده‌های پرت وجود داشته باشد، اثر آن‌ها را در محاسبات کم می‌کند و زمانی که خطا کاهش یابد، امکان کمینه‌سازی تابع زیان هوبر به‌راحتی امکان‌پذیر است. از آنجایی که مقدارهای مختلف δ شکل تابع زیان را تغییر می‌دهد، انتخاب مقدار مناسب برای آن کاری حساس و مشکل است. زیرا انتخاب مقدار بزرگ برای آن، تابع زیان را برای بیشتر مواقع MSE در نظر گرفته و انتخاب مقدار کوچک باعث استفاده از تابع زیان MAE برای بیشتر مشاهدات می‌شود. برای اطمینان از اینکه این مقادیر تابع زیان به‌طور مؤثر با داده‌های مشاهداتی مطابقت داشته باشند، ما مقادیر w_i را به عنوان یک تابع وزنی برای پارامترهای درخشش یونسفری در معادلات خود وارد کرده‌ایم. استفاده از مقادیر w_i به‌طور مشابه در مطالعات دیگر برای افزایش عملکرد پیش‌بینی مورد استفاده قرار گرفته است [۱۴]. این مقادیر w_i ، به‌ویژه برای مقادیر حد آستانه $S4$ اعمال شده، بر اساس طبقه‌بندی مقادیر درخشش یونسفری بر اساس $S4$ و با استفاده از یک روش نوآورانه به صورت رابطه (۱۴) برای طبقه‌بندی مقادیر وزن‌ها

^۱ Huber Loss Function

^۲ Smooth Mean Absolute Error

درخشش‌های یونسفری در منطقه مورد مطالعه ایجاد شده است. شکل (۱) ساختار مدل رمزنگار-رمزگشا را برای مدل‌سازی و پیش‌بینی درخشش‌های یونسفری نمایش می‌دهد. در بخش رمزنگار، شبکه ویژگی‌های تصویر را از ابعاد بالا به پایین آموزش می‌دهد به گونه‌ای که پس از ورودی داده‌ها، لایه کانولوشنال برای کاهش ابعاد ویژگی تانسور و واحد ConvGRU برای یادگیری ویژگی‌های متوالی تانسور عمل می‌کند و در ادامه ماتریس میانی تشکیل می‌شود. سپس ماتریس میانی به بخش رمزگشا وارد می‌شود. ماتریس میانی ابتدا به لایه Deconvolution منتقل شده و با استفاده از آن ابعاد تصویر افزایش پیدا می‌کند و پس از آن در لایه ConvGRU ویژگی‌های تصویر آموزش دیده و پس از دو لایه به مقادیر آموزش دیده شده به ابعاد اصلی تانسور ورودی تبدیل خواهند شد. در این مدل تابع ضرر^۵ به طور مداوم در طول فرآیند آموزش به هنگام شده به طوری که مقدار تابع هزینه به طور مداوم در روند آموزش کاهش می‌یابد. در مرحله رمزنگار ابعاد تانسور ویژگی به تدریج کاهش یافته و تعداد کانال‌های شبکه و به تبع ویژگی‌های استخراج شده به تدریج افزایش می‌یابد. در بخش رمزگشا به تدریج ابعاد ماتریس داده‌ها از پایین به بالا و تعداد کانال‌ها کاهش پیدا می‌کند تا در نهایت ابعاد تانسور خروجی با تانسور ورودی برابر گردد. یک الگوریتم یادگیری ماشین، پارامترهای مدل را به طور مکرر بر اساس ارزیابی یک تابع ضرر به روز می‌کند.

استفاده خواهد شد:

رابطه (۱۴)

$$w_i = \begin{cases} 0.25 & S4 < 0.2 \\ 0.50 & 0.2 \leq S4 < 0.4 \\ 0.75 & 0.4 \leq S4 < 0.6 \\ 1.00 & 0.6 \leq S4 \end{cases}$$

در مطالعه ما، روشی که برای تعیین مقادیر حد آستانه برای متغیر w_i ، عمدتاً از رویکردی که در تحقیقات گذشته استفاده شده است الهام گرفته شده است [۱۴]. اهمیت این رویکرد در توانایی آن در وزن دادن به تابع زیان به این دلیل است که مدل را قادر می‌سازد تا به صورت پویا با داده‌های مشاهداتی تنظیم شود. این امر به ویژه در مواردی که با افزایش ناگهانی مقادیر مشاهداتی کار برای پیش‌بینی سخت می‌شود برای مدل بسیار مهم است و در نتیجه دقت پیش‌بینی مدل را افزایش می‌دهد.

۳-۳- ساختار مدل ارائه شده

با توجه به پژوهش‌های پیشین در خصوص مدل‌سازی و پیش‌بینی با استفاده از روش ConvGRU، بایستی یک ساختار رمزنگار-پیش‌بینی برای پیش‌بینی مکانی-زمانی درخشش‌های یونسفری به صورت چند ورودی^۱ و چند خروجی^۲ ارائه نمود. مدل ارائه شده در این مقاله شامل دو بخش رمزنگار و پیش‌بینی^۳ است. بخش رمزنگار از دو نوع لایه که شامل ConvGRU و لایه Convolution است، تشکیل شده است. بخش پیش‌بینی نیز از دو نوع لایه ConvGRU و دکانولوشن^۴ تشکیل می‌شود. با توجه به مقادیر ورودی شبکه و بر اساس پژوهش‌های پیشین انجام گرفته در این زمینه [۲۰، ۲۱، ۳۰ و ۳۱] از یک مدل رمزنگار-پیش‌بینی با سه لایه بر اساس روش ConvGRU برای آموزش داده‌های ورودی برای ایجاد یک مدل پیش‌بینی مکانی-زمانی برای مقادیر


¹ Multi Input Layers

² Multi Output Layers

³ Encoder- Forecaster

⁴ Deconvolution


⁵ Loss Function



شکل ۱: ساختار رمزگذار-پیش‌بینی کننده به کار گرفته شده در مدل پیشنهادی برای پیش‌بینی درختش‌های یونسفری

و یک‌لایه ConvGRU است. هدف Forecaster بازسازی و طرح نقشه S4 در گام بعدی بر اساس داده‌های کدگذاری شده از گام‌های قبلی است. خروجی‌های لایه‌های ConvGRU در رمزگذار، که شامل حالت‌های مخفی و سلولی هستند، به عنوان ورودی برای لایه‌های مربوطه در Forecaster عمل می‌کنند. این مدل، همان‌طور که در شکل (۲) نشان داده شده است، یک ساختار شبکه جامع را برای مدل‌سازی مؤثر و پیش‌بینی پارامتر درختش‌های یونسفری ارائه می‌دهد. این مدل به‌طور خاص پیش‌بینی مقادیر درختش‌های یونسفری را در آمریکای جنوبی مورد مطالعه قرار می‌دهد. انتقال از لایه‌های کانولوشنال، ConvGRU و Deconvolution (به تفصیل در شکل (۱)) منجر به ماتریس‌های خروجی با شماره، ارتفاع و عرض فیلتر خاص می‌شود که در مجاورت بلوک‌های مربوطه در شکل (۲) نشان داده شده است.

طراحی معماری الگوریتم از چهار جزء مجزا تشکیل شده است: ماژول ورودی، رمزگذار، رمزگشا (پیش‌بینی کننده) و ماژول خروجی. نقشه‌های ورودی و خروجی، به‌طور خاص بر روی پارامتر S4 تمرکز دارند که در محدوده آمریکای جنوبی برداشت شده‌اند و به صورت گریدهایی به‌طور یکسان در ارتفاع ۷۰ واحد و عرض ۵۰ واحد منظم شده‌اند. این داده‌های ورودی شامل دنباله‌ای از ۱۲ نقشه S4 متوالی است که از طریق یک سری از سه بلوک رمزگذار پردازش می‌شوند. رمزگذارها تعداد فیلترهای فزاینده را به ترتیب ۱۶، ۳۲ و ۶۴ برای هر بلوک به کار می‌گیرند. در هر یک از این بلوک‌ها، یک لایه کانولوشن با یک لایه ConvGRU جفت می‌شود که لایه ابتدایی نمونه‌برداری‌ها را در سطوح پایین تسهیل می‌کند و دومی به استخراج ویژگی‌های مکانی-زمانی اختصاص دارد. این چیدمان در بخش Forecaster منعکس می‌شود، که همچنین دارای سه بلوک است که هر یک شامل یک لایه Deconvolution



شکل ۲: ساختار مدل مبتنی بر روش ConvGRU برای پیش‌بینی منطقه‌ای درخشش‌های یونسفری در منطقه آمریکای جنوبی

می‌کند. با این دیدگاه از موارد پیشین و بینش‌های به‌دست‌آمده از آزمایشات اولیه، ما به این نتیجه رسیده‌ایم که استفاده از روش جدید امکان پیش‌بینی نزدیک به آنی برای درخشش‌های یونسفری به صورت منطقه‌ای همچون منطقه آمریکای جنوبی، که به دلیل نزدیکی به EIA بسیار است، را میسر می‌سازد. در این مطالعه، با استفاده از روش ConvGRU و استفاده از روش تابع زیان هوبر با دخالت دادن وزن‌های مشاهدات پارامتر $S4$ ، هدف ما دستیابی به یک پیش‌بینی نزدیک به آنی برای مقادیر پارامتر درخشش یونسفری به صورت منطقه‌ای است.

۴- نتایج تحقیق


هدف این تحقیق پیش‌بینی نزدیک به آنی درخشش‌های یونسفری با استفاده از داده‌های مشاهداتی $S4$ در گام‌های زمانی متوالی به عنوان داده‌های ورودی و هدف پیش‌بینی اپک بعدی مشاهداتی با استفاده از روشی بر مبنای ConvGRU است. با توجه به توضیحات گفته‌شده در بخش مقدمه، میدانیم که مناطقی در محدوده‌های نزدیک به آنومالی استوایی یونسفری مناطقی بسیار مستعد جهت رخداد

در این پژوهش از رویکرد چند به یک برای ارتباط مقادیر ورودی با خروجی مدل استفاده شده است. در نتیجه، با استفاده از ۱۲ گام مشاهدات $S4$ به عنوان داده‌های ورودی، یک گام آینده پیش‌بینی می‌شود که نشان‌دهنده یک پیش‌بینی به صورت نزدیک به آنی است. منطق پشت این تصمیم از این واقعیت ناشی می‌شود که علیرغم توانایی مدل برای مدیریت دوره‌های بیشتر، تا شش دوره، نتایج به‌دست‌آمده در آزمایش‌های اولیه و بررسی پروژه‌ها در زمینه پیش‌بینی اغتشاشات یونسفری نشان‌دهنده کاهش قابل توجه دقت پیش‌بینی با افزایش دوره‌های پیش‌بینی است و این کاهش را در برخی از مطالعات می‌توان به‌طور واضح مشاهده کرد، همچون تحقیق لیو و همکاران، که در این تحقیق می‌توان به‌راحتی مشاهده کرد که در گام‌های بعدی از پیش‌بینی‌شده، مقادیر دقت پیش‌بینی به‌طور قابل توجهی کاهش یافته است [۱۴]. حتی در مواردی که شدت اختلالات ژئومغناطیسی شدید است، دقت کمتر از ده درصد شده و ارزش پیش‌بینی را عملاً ناچیز

^۱ Many-to-One

بر این، این مطالعه با استفاده از مشاهدات در دو سال ۲۰۱۵ و ۲۰۲۰ می‌تواند تأثیرات چرخه خورشیدی یازده ساله را بر شرایط یونسفر بررسی نماید. شایان ذکر است، سال ۲۰۱۵ سالی با افزایش فعالیت خورشیدی بود، درحالی‌که سال ۲۰۲۰ فعالیت خورشیدی نسبتاً کمتری را تجربه کرد. هدف اصلی این مقاله پیش‌بینی درخشش‌های یونسفری در شرایط مختلف ژئومغناطیسی است. برای این منظور ماه‌های ژانویه، مارس و جولای در سال‌های ۲۰۱۵ و ۲۰۲۰ انتخاب شدند. این انتخاب ارزیابی دقت مدل پیشنهادی را در طیفی متنوع از سناریوهای ژئومغناطیسی به نمایش می‌گذارد. در این بخش ابتدا به ارزیابی جامع مقادیر پارامترهای ژئومغناطیسی در این بازه‌های زمانی مورد استفاده در این پژوهش خواهیم پرداخت، سپس به ارائه نتایج عددی و تحلیلی پیش‌بینی‌های درخشش یونسفری پرداخته می‌شود و در آخرین گام به ارزیابی نتایج پیش‌بینی‌های انجام شده پرداخته خواهد شد.

پدیده‌های اغتشاشات یونسفری همچون درخشش‌های یونسفری است لذا برای این پژوهش، درمجموع ۱۲۱ ایستگاه زمینی GNSS، در محدوده عرض جغرافیایی ۱۵ درجه شمالی تا ۵۵ درجه جنوبی و محدوده طول جغرافیایی ۲۷۰ درجه تا ۳۳۰ درجه شرقی در سراسر آمریکای جنوبی، در محدوده‌ای در مجاورت ناحیه EIA، به کار گرفته شده است. توزیع مکانی این ایستگاه‌ها در شکل (۳) نمایش داده شده است که در گستره‌ای از شمال آمریکای جنوبی تا جنوب آمریکای جنوبی که محدوده‌هایی مستعد جهت رخداد اغتشاشات یونسفری است، مشاهده می‌شود. تغییرات زمانی پدیده‌های یونسفری در طول یک سال را می‌توان به سه مرحله فصلی مجزا انقلاب تابستانی، انقلاب زمستانی و اعتدالین تقسیم‌بندی نمود. در این مطالعه، یک رویکرد سیستماتیک برای انتخاب یک ماه به عنوان نماینده‌ای از هر فصل برای انجام مدل‌سازی و تحلیل پیش‌بینی پدیده‌های اغتشاشات یونسفری اتخاذ شده است. علاوه



شکل ۳: (الف) توزیع جغرافیایی ایستگاه‌های GNSS در محدوده آمریکای جنوبی، (ب) مشاهدات S4 در امتداد مسیر IPP در ساعت (UT) ۱۴:۰۰ در ۱۵ ژانویه ۲۰۱۵ و (ج) یک نمونه نقشه S4 که از طریق درون‌یابی با استفاده از روش کریجینگ

بازه‌های زمانی خاص است. می‌توان رفتار فعالیت‌های ژئومغناطیسی و تأثیرات زمانی آن‌ها را بر پدیده‌های

۴-۱- فعالیت‌های ژئومغناطیسی


این مطالعه نیاز به تجزیه و تحلیل رفتار درخشش‌های یونسفری در بازه‌های زمانی مختلف دارد که مستلزم ارزیابی جامع مقادیر پارامترهای ژئومغناطیسی در این

در این ماه مقدار میانگین مقادیر پارامتر K_p ۲/۴۶ بوده که بالاترین میزان در محدوده مشاهداتی این پژوهش است. بالاترین مقادیر K_p پس از آن در روزهای ابتدایی ژانویه ۲۰۱۵ با ثبت نزدیک به ۷ برای پارامتر K_p به ثبت رسیده است که مقدار میانگین K_p در ژانویه ۲۰۱۵ برابر با ۱/۹۶ بوده که بالاتر از جولای همان سال با ۱/۷۱ است. در سال ۲۰۲۰ با کاهش فعالیت‌های ژئومغناطیسی می‌توان دید که مارس بازمی‌باز هم بالاترین میانگین را در میان ماه‌های ۲۰۲۰ دارد و با روندی شبیه ۲۰۱۵ پس از مارس به ترتیب ژانویه و جولای قرار دارند. شاخص Dst یک شاخص برای نشان دادن میزان فعالیت‌های ژئومغناطیسی است که از مجموعه‌ای از مشاهدات ژئومغناطیسی در نزدیکی استوا و در راستای افقی محاسبه می‌شود که حاصل از اندازه‌گیری شدت میزان الکتورجت استوایی^۷ است. مقادیر Dst را می‌توان از وبسایت دانشگاه کیوتو برداشت نمود. با استفاده از شکل (۴) برای مقادیر Dst می‌توان دید که در بازه‌هایی که شاهد افزایش و یا کاهش مقادیر K_p بوده‌ایم، مقادیر Dst نیز روندی مشابه در پیش گرفتند. بیشترین میزان Dst در میانه‌های مارس اتفاق افتاده است که همانطور که مشخص است یک طوفان ژئومغناطیسی در این بازه مشاهداتی رخ داده است که سبب افزایش میانگین ماهانه مقادیر Dst به ۲۷/۷۵- شده است، در صورتیکه ماه ژانویه میانگینی در حدود ۲۰/۵۶- را در سال ۲۰۱۵ از خود به ثبت رسانده است. در سال ۲۰۲۰ هم ماه مارس بالاترین مقدار را در میانگین مقادیر Dst از خود به نمایش گذاشته است؛ در حالیکه در این سال مقادیر مشاهداتی Dst برای جولای از ژانویه بیشتر بوده و برابر با ۴/۷۳- بوده است.

یونسفری در طول سال به سه فصل از قبیل انقلاب تابستانی^۱، انقلاب زمستانی^۲ و اعتدالی^۳ تقسیم‌بندی نمود. ماه‌های همچون ژانویه، فوریه، نوامبر و دسامبر به عنوان ماه‌های انقلاب زمستانی، ماه‌هایی مانند می، ژوئن، جولای و آگوست به عنوان ماه‌های انقلاب تابستانی و ماه‌هایی همچون مارس، آوریل، سپتامبر و اکتبر نیز به عنوان ماه‌های اعتدالین تقسیم‌بندی نمود. لذا در این پژوهش سعی شده است از هر کدام از فصل‌ها یک ماه انتخاب‌شده و مدل‌سازی و پیش‌بینی برای آن‌ها انجام‌گرفته شود [۱۲]. برای این منظور از مجموعه‌ای از پارامترهای ژئومغناطیسی همچون شاخص ژئومغناطیسی بین‌المللی K_p ، شار خورشیدی^۴، شاخص Dst ^۵ و تعداد لکه‌های خورشیدی^۶ در شکل (۴) برای توصیف شدت فعالیت‌های مغناطیسی استفاده شده است. با نگاهی به پژوهش‌های گذشته می‌توان دید که این پارامترها را به عنوان مؤلفه‌های ژئومغناطیسی مؤثر بر رخداد درخشش‌های یونسفری استفاده کرده‌اند، از این رو در این پژوهش نیز از این مؤلفه‌ها به جهت توصیف فعالیت‌های ژئومغناطیسی در بازه‌های زمانی مدل‌سازی استفاده شده است [۳۲ و ۳۳].

شاخص ژئومغناطیسی بین‌المللی K_p را می‌توان به عنوان یکی از پارامترهای اصلی جهت توصیف فعالیت‌های ژئومغناطیسی به کار گرفت [۳۳]. مقادیر K_p را می‌توان از وبسایت دانشگاه کیوتو به نشانی wdc.kugi.kyoto-u.ac.jp دریافت نمود. در شکل (۴) می‌توان دید که مقادیر K_p در بازه‌های ژانویه و مارس ۲۰۱۵ بالاترین مقدار خود را در بازه مشاهداتی داشته‌اند؛ می‌تواند دید که بالاترین مقدار K_p نزدیک به ۸ بوده که در نیمه مارس ۲۰۱۵ به ثبت رسیده است و

^۱ Summer Solstice^۲ Winter Solstice^۳ Equinox^۴ Auroral Electrojet^۵ Disturbance storm time index^۶ Sunspot number^۷ Equatorial Electrojet



شکل ۴: مقادیر پارامترهای ژئومغناطیسی مؤثر بر رخداد درخشش‌های یونسفری؛ تصاویر (الف) تا (ج): شاخص Dst ، تصاویر (د) تا (و): شار خورشیدی ($F10.7$)، تصاویر (ز) تا (ت): شاخص ژئومغناطیسی Kp و تصاویر (ی) تا (ل): تعداد لکه‌های خورشیدی (SSN) در طول ماه‌های ژانویه، مارس و جولای سال ۲۰۱۵ (نمودارهای قرمز) و سال ۲۰۲۰ (نمودارهای آبی)

۲۰۲۰ اما همچون سایر مولفه‌ها می‌توان دید که مقدار لکه‌های خورشیدی نیز با کاهشی چشمگیر همراه بوده است. در ۲۰۲۰ بیشترین تعداد لکه‌های خورشیدی در ماه‌های جولای و ژانویه رخ داده است که روندی مشابه با روند شار خورشیدی دارد.

۴-۲- نتایج عددی و تحلیلی پیش‌بینی‌های درخشش یونسفری

مشاهدات حاصل از ایستگاه‌های GNSS داده‌های مشاهداتی را در گام‌های زمانی^۲ ۱۵ و ۳۰ ثانیه در اختیار کاربران قرار داده‌اند. برای کاهش خطاهای ردیابی مانند چند مسیری، زاویه قطع ارتفاع ماهواره‌ای^۳ مقدار ۲۰ درجه انتخاب شد. در این تحقیق، پارامترها بر روی ۴۵۰ کیلومتر تنظیم شده‌اند، زیرا این ارتفاع به دلیل قرارگیری لایه F2 بیشترین میزان اغتشاشات یونسفری را تجربه می‌کند و منبع بسیاری از اغتشاشات یونسفری است [۳۶]. شکل (۳-الف) پراکندگی جغرافیایی ایستگاه‌های GNSS در آمریکای جنوبی را با کمبود قابل‌توجه در منطقه مرکزی برزیل نشان می‌دهد. برای کاهش محدودیت‌های ناشی از توزیع ناهموار ایستگاه، الگوریتم کریجینگ^۴ برای درون‌یابی مؤثر داده‌ها در این مطالعه پیاده‌سازی شده است. برای نشان دادن توزیع مکانی درخشش‌های یونسفری در محدوده آمریکای جنوبی، نقشه‌های S4 دوبعدی با ابعاد ۵۰ در ۷۰ ایجاد شده است. این نقشه‌ها با میانگین‌گیری تمام مقادیر مشاهداتی S4 در هر IPP مشاهداتی موجود در یک گرید به ابعاد ۱ × ۱، در یک بازه زمانی ۵ دقیقه‌ای گردآوری شده است. شکل (۳-ب) نمونه‌ای از مقادیر نقشه خام مشاهدات S4 در هر IPP را نشان می‌دهد که با استفاده از این مقادیر و با کمک روش درون‌یابی کریجینگ برای مقداردهی به تمامی گریدهای این تنسور دوبعدی حاصل از مشاهدات S4

مؤلفه F10.7 نشان‌دهنده شار خورشیدی اندازه‌گیری شده برای طول‌موج ۱۰/۷ سانتی‌متر است که برای محاسبه میزان فعالیت‌های خورشیدی مورد استفاده قرار می‌گیرد [۳۴]. مقادیر مؤلفه F10.7 را می‌توان از وب‌سایت ngdc.noaa.gov دریافت نمود. در این مؤلفه می‌توان دید که مقادیر F10.7 در ماه ژانویه به نسبت مارس مقادیر بالاتری را در سال ۲۰۱۵ به ثبت رسانده‌اند. میانگین مقادیر F10.7 در ژانویه ۲۰۱۵ برابر با ۱۳۷/۳۲ و در مارس همان سال برابر با ۱۲۶/۲۹ است. در سال ۲۰۲۰ اما می‌توان دید که این روند تکرار شده است و ژانویه با میانگین ۷۲/۲۳ بالاتر از مارس با ۷۰/۱۲ و جولای با ۶۹/۵۷ قرار دارد ولی در این سال اختلاف میان مقادیر میانگین مؤلفه F10.7 به شدت کاهش پیدا کرده است؛ به گونه‌ای که اختلاف میان بالاترین و پایین‌ترین ماه یعنی ژانویه و جولای به حدود ۳ واحد رسیده است که نشان از افت فعالیت‌های خورشیدی نسبت به سال ۲۰۱۵ دارد و نشان می‌دهد در سال‌هایی که فعالیت‌هایی خورشیدی کمتر است اختلاف میان فصول مختلف نیز کاهش میابد.

یکی از مؤلفه‌های دیگر مؤثر بر درخشش یونسفری تعداد لکه‌های خورشیدی است. لکه‌های خورشیدی به‌طور مستقیم با میدان مغناطیسی خورشید مرتبط بوده و داده‌های به‌دست‌آمده از این پارامتر بیانگر این موضوع بوده که میدان مغناطیسی ایجاد شده در اطراف لکه‌های خورشیدی هزاران بار قوی‌تر از میدان مغناطیسی زمین است [۳۵]. تعداد لکه‌های خورشیدی توسط پارامتری به نام عدد ولف اندازه‌گیری و به صورت روزانه منتشر می‌شود. این شاخص نشان می‌دهد که بالاترین میزان لکه‌های خورشیدی ثبت‌شده در بازه مشاهداتی در ژانویه ۲۰۱۵ رخ داده است که برابر با ۱۵۳ است و میانگین ژانویه ۲۰۱۵ نیز در تعداد لکه‌های خورشیدی برابر با ۹۳/۶۵ است که از این نظر بالاتر از مارس و جولای همان سال قرار دارد. در سال

² Interval

³ Satellite Elevation Cutoff Angle

⁴ Kriging Algorithm

¹ Wolf Number

مشاهداتی استفاده شده است که نشان دهنده تعداد مشاهداتی با مقادیر $S4$ بیشتر از 0.2 است که نشان دهنده رخداد پدیده درخشش یونسفری در آن بازه زمانی است. با توجه به مقادیر جدول (۱)، مشاهده می شود که بالاترین درصد درخشش یونسفری که در سال 2015 (حداکثر فعالیت خورشیدی) رخ داده است که مقادیری بیشتر از سال 2020 (حداقل فعالیت خورشیدی) را ثبت کرده است. مقادیر مشاهدات $S4$ برای ماه های ژانویه، مارس و جولای نشان می دهد که درصد وقوع درخشش یونسفری در سال 2015 در ماه ژانویه بیشتر از ماه های مارس و جولای است و در سال 2020 درصد رخداد درخشش یونسفری برای محدوده آمریکای جنوبی در ماه جولای مقادیری بیشتر از دو ماه دیگر را ثبت کرده است ولی می توان دید که درصد رخداد درخشش یونسفری در هر سه ماه مشاهداتی سال 2020 بسیار نزدیک به هم به ثبت رسیده است که دلیل آن کاهش فعالیت های ژئومغناطیسی خورشید در این سال است. با توجه به مقادیر به دست آمده از مدل سازی در جدول (۱)، می توان دریافت که دقت مدل سازی در سال 2015 در جولای بالاتر از ماه های ژانویه و مارس همان سال است. مؤلفه های جدول (۱) نشان می دهد که ژانویه 2015 پایین دقت را در میان تمامی بازه های مشاهداتی این تحقیق از خود به نمایش گذاشته است، به طور مثال می توان دید که مقدار CC و $RMSE$ برای بازه مدل سازی ژانویه 2015 به ترتیب برابر با 0.83 و 0.14 است و میانگین خطاها برای بازه مدل سازی این دوره 0.26 ثبت شده است. این افت پارامترهای دقت را می توان ناشی از افزایش فعالیت های ژئومغناطیسی در این دوره مشاهداتی قلمداد نمود. در سال 2020 اما بالاترین دقت مدل سازی را می توان در ماه ژانویه دید که نسبت به ماه های مارس و جولای عملکرد بهتری را به ثبت رسانیده است که نشان دیگری از تأثیر فعالیت های ژئومغناطیسی بر رخداد درخشش های یونسفری است.

استفاده شده است و در نتیجه می توان نقشه مشاهدات $S4$ درون یابی شده را برای هر اپک مشاهداتی مانند نقشه موجود در شکل (۳-ج) نمایش داد. ابعاد این نقشه $S4$ درون یابی شده از تنسور دوبعدی در ابعاد 70 گرید در ارتفاع (عرض جغرافیایی) و 50 گرید در عرض (طول جغرافیایی)، با اندازه شبکه 1×1 درجه تشکیل شده است. این تکنیک درون یابی برای نقشه های دوبعدی $S4$ خام به دست آمده از داده های GNSS مشاهداتی در ژانویه، مارس و جولای 2015 (حداکثر فعالیت خورشیدی) و 2020 (حداقل فعالیت خورشیدی) اعمال شده است. با استفاده از این مجموعه داده ها به عنوان داده ورودی می توان مقادیر مشاهداتی $S4$ را برای هر کدام از این تنسورهای مشاهداتی در سه بخش مجزا جهت انجام مدل سازی با استفاده از روش $ConvGRU$ به نام های: بخش آموزش (70%) از کل داده ها، شامل 1 تا 22 ژانویه / مارس / جولای، اعتبار سنجی (20%) از کل داده ها، پوشش 23 تا 28 ژانویه / مارس / جولای، و آزمایش (10%) از کل داده ها، شامل 29 تا 31 ژانویه / مارس / جولای) تقسیم بندی نمود. در مرحله اول، نتایج مدل سازی $S4$ توسط $ConvGRU$ را برای بازه مدل سازی با مشاهدات این داده ها در همان بازه زمانی مقایسه کردیم. در این پژوهش ما از پارامترهای میانگین خطا^۳ (ME)، ریشه میانگین مربعات خطا^۴ ($RMSE$) و ضریب همبستگی پیرسون^۵ (CC) برای کمی سازی عملکرد مدل سازی و پیش بینی روش یادگیری ماشین ارائه شده استفاده می کنیم. جدول (۱) مقادیر این پارامترها را برای مقادیر $S4$ برای بازه های مدل سازی (مراحل آموزش و اعتبارسنجی) و پیش بینی (آزمایش) نشان می دهد. علاوه بر این از درصد رخداد درخشش های یونسفری در طول دوره

¹ Train² Validation³ Mean Error⁴ Root Mean Squared Error⁵ Pearson correction coefficient

جدول ۱: مقادیر حاصل از میانگین پارامترهای ژئومغناطیسی مؤثر بر درخشش‌های یونسفری، متوسط مقادیر پارامتر درخشش یونسفری ($S4$) و درصد رخداد درخشش یونسفری ($S4 > 0.2$) و مقادیر پارامترهای ارزیابی دقت مدل‌سازی و پیش‌بینی درخشش‌های یونسفری در محدوده آمریکای جنوبی برای ماه‌های ژانویه، مارس و جولای سال‌های ۲۰۱۵ و ۲۰۲۰


پارامترها	۲۰۱۵			۲۰۲۰		
	ژانویه	مارس	جولای	ژانویه	مارس	جولای
وضعیت پارامترهای ژئومغناطیسی	Kp میانگین	۹۶/۱	۴۶/۲	۱/۷۱	۱/۰۲	۱/۳۴
	Dst میانگین	-۲۰/۵۶	-۲۷/۷۵	-۱۹/۴۳	-۳/۶۳	-۵/۷۶
	SSN میانگین	۹۳/۶۵	۵۴/۱۵	۶۵/۷۸	۶/۱۸	۱/۸۴
	$F10.7$ میانگین	۱۳۷/۳۲	۱۲۶/۲۹	۱۰۶/۹۱	۷۲/۲۳	۷۰/۱۲
وضعیت درخشش‌های یونسفری	$S4$ میانگین	۰/۱۵۲	۰/۱۴۸	۰/۱۴۳	۰/۱۳۰	۰/۱۲۸
	درصد رخداد $Scintillation (S4 > 0.2)$	٪۱۹/۳۲	٪۱۷/۴۶	٪۱۷/۰۹	٪۱۰/۵۵	٪۱۱/۴۴
	CC	۰/۸۳	۰/۸۶	۰/۸۷	۰/۹۲	۰/۹۱
	$RMSE$	۰/۰۱۴	۰/۰۱۴	۰/۰۱۳	۰/۰۰۹	۰/۰۱۰
مدلسازی $ConvGRU - L_{\delta}$	ME	۰/۰۲۶	۰/۰۲۵	۰/۰۲۴	۰/۰۱۸	۰/۰۱۹
	CC	۰/۷۳	۰/۷۵	۰/۷۶	۰/۸۱	۰/۷۹
	$RMSE$	۰/۰۴۲	۰/۰۳۸	۰/۰۳۲	۰/۰۱۹	۰/۰۲۲
	ME	۰/۰۰۷	۰/۰۰۶	۰/۰۰۵	۰/۰۰۴	۰/۰۰۴

شکل (۵) مقادیر $S4$ را برای ۲۹ام ژانویه در سال‌های ۲۰۱۵ و ۲۰۲۰ نمایش می‌دهد که با استفاده از اطلاعات جدول (۱) می‌توان دریافت که ژانویه ۲۰۱۵ بالاترین درصد رخداد درخشش یونسفری و ژانویه ۲۰۲۰ کمترین درصد رخداد درخشش‌های یونسفری را ثبت کرده‌اند. در ژانویه ۲۰۱۵ متوسط مقدار CC برابر با ۰/۷۳ و متوسط $RMSE$ برابر با ۰/۰۴۲ محاسبه شده است که پایین‌ترین دقت را در میان مقادیر پیش‌بینی شده در این شش بازه مشاهداتی را ثبت کرده است. این را می‌توان در شکل (۵) و در رفتار مقادیر پیش‌بینی شده مخصوصاً در بازه طلوع آفتاب دید که مدل نتوانسته است به خوبی تمامی درخشش‌های یونسفری را ثبت کند و در عرض جغرافیایی نزدیک به استوا و در نزدیکی طول ۷۰ درجه غربی یک درخشش یونسفری رخ داده است ولی مدل تنها بخش کوچکی را به عنوان رخداد درخشش یونسفری پیش‌بینی کرده است. این اتفاق در بازه‌های ظهر و طلوع نیز با شدتی

در گام دوم، با استفاده از داده‌های مدل‌سازی شده برای یک بازه زمانی سه‌روزه در هر ماه با استفاده از روش $ConvGRU$ مورد استفاده در این پژوهش یک پیش‌بینی برای بازه زمانی سه‌روزه شامل ۲۹ام، ۳۰ام و ۳۱ام هر ماه انجام گرفته است. نتایج این بازه‌های پیش‌بینی برای سه روز در هر کدام از ماه‌ها در شکل‌های (۵) تا (۷) آورده شده است. در این شکل‌ها سعی شده است تا بازه‌های زمانی‌ای که در آن تغییرات یونسفری بیشتری در مدت یک شبانه‌روز اتفاق می‌افتد انتخاب شود. برای این منظور مقادیر مشاهداتی و پیش‌بینی شده توسط روش $ConvGRU$ پارامتر $S4$ را برای هر روز را در سه بازه زمانی هنگام طلوع خورشید، هنگام ظهر و هنگام غروب آفتاب نمایش داده شده است. در تمامی این شکل‌ها می‌توان دید که در میزان درخشش‌های یونسفری در سال‌های ۲۰۱۵ و ۲۰۲۰ تفاوت بسیاری با یکدیگر داشته‌اند که ناشی از تفاوت فعالیت‌های ژئومغناطیسی میان این دو سال است.

از خود به نمایش گذاشته است به طوری که متوسط مقدار CC برابر با ۰/۸۱ و متوسط $RMSE$ برابر با ۰/۱۹ محاسبه شده است که بالاترین دقت را در میان بازه‌های مشاهداتی از خود به نمایش گذاشته است. می‌توان این افزایش دقت را با مقایسه میان نقشه‌های $S4$ در سال‌های ۲۰۱۵ و ۲۰۲۰ به راحتی مشاهده کرد. می‌توان دید که در سال ۲۰۲۰ با کاهش فعالیت ژئومغناطیسی و کاهش درخشش‌های یونسفری میزان دقت پیش‌بینی نیز افزایش پیدا کرده است.


کمتر اتفاق افتاده است. با این حال می‌توان دید که در این بازه‌های مشاهداتی متوسط همبستگی در حدود ۰/۷ بوده است و مدل توانسته روند رخداد درخشش‌های یونسفری در بازه‌های مشخص شده شناسایی کند. در ژانویه ۲۰۱۵ اما اوضاع بسیار متفاوت است و در این بازه زمانی مقدار پارامترهای دقت پیش‌بینی بهترین عملکرد خود را در میان بازه‌های مشاهداتی سال‌های ۲۰۱۵ و ۲۰۲۰ ثبت کرده است. در ژانویه ۲۰۲۰ می‌توان دید که مدل عملکرد بسیار خوبی



شکل ۵: مقادیر $S4$ مشاهداتی و پیش‌بینی شده برای محدوده آمریکای جنوبی در روز ۱۲م ژانویه در سه بازه زمانی هنگام طلوع خورشید (Sunrise)، هنگام ظهر (Noon) و هنگام غروب آفتاب (Sunset). ستون اول و دوم به ترتیب مقادیر مشاهداتی و پیش‌بینی شده $S4$ برای سال ۲۰۱۵ و ستون‌های سوم و چهارم مقادیر ترتیب مقادیر مشاهداتی و پیش‌بینی شده $S4$ برای سال ۲۰۲۰

عملکرد بهتری را نسبت به ژانویه داشته است به صورتیکه متوسط مقدار CC برابر با ۰,۷۵ و متوسط $RMSE$ برابر با ۰,۳۸ محاسبه شده است. با استفاده از شکل (۶) می‌توان دید که اغتشاشات یونسفری مارس سال ۲۰۱۵ در بازه طلوع آفتاب به نسبت دو بازه زمانی دیگر بالاتر بوده است و مدل نیز توانسته است رخداد درخشش یونسفری را در محدوده آنامولی استوایی به‌درستی پیش‌بینی کند.

در شکل (۶) روز ۳۰ام ماه مارس، ماه دوم پیش‌بینی برای سال‌های ۲۰۱۵ و ۲۰۲۰ نمایش داده شده است. با استفاده از اطلاعات جدول (۱) و شکل (۶) می‌توان دید در ماه مارس در هر دو سال مشاهداتی از لحاظ درصد رخداد درخشش یونسفری و فعالیت‌های ژئومغناطیسی در میانه قرار دارد؛ با این تفاوت که در سال ۲۰۱۵ به نسبت ۲۰۲۰ درخشش‌های یونسفری بیشتری مشاهده شده است. با استفاده از پارامترهای دقت می‌توان دید که پیش‌بینی برای مارس ۲۰۱۵




شکل ۶: مقادیر $S4$ مشاهداتی و پیش‌بینی‌شده برای محدوده آمریکای جنوبی در روز ۳۰ام مارس در سه بازه زمانی هنگام طلوع خورشید (Sunrise)، هنگام ظهر (Noon) و هنگام غروب آفتاب (Sunset). ستون اول و دوم به ترتیب مقادیر مشاهداتی و پیش‌بینی‌شده $S4$ برای سال ۲۰۱۵ و ستون‌های سوم و چهارم مقادیر ترتیب مقادیر مشاهداتی و پیش‌بینی‌شده $S4$ برای سال ۲۰۲۰

بازه زمانی طلوع می‌توان اغتشاشات یونسفری را در محدوده‌ای کوچک در نزدیک آنامولی استوایی شاهد بود. در بازه زمانی طلوع نیز می‌توان دید که *ConvGRU* توانسته است رخداد درخشش یونسفری را در محدوده نزدیک به استوا پیش‌بینی کند.

در شکل (۷) می‌توان مقادیر *S4*‌های مشاهداتی و پیش‌بینی‌شده را برای روز ۳۱ام ماه جولای برای سال‌های ۲۰۱۵ و ۲۰۲۰ دید که همانند دو شکل قبلی برای سه بازه زمانی طلوع، ظهر و غروب خورشید ترسیم شده‌اند.

بر طبق شکل (۶)، در بازه‌های ظهر و طلوع نیز مدل توانسته است رخداد اغتشاشات یونسفری را در بازه مکانی پیش‌بینی کند و در کل نیز مقدار متوسط خطای پیش‌بینی نسبت به ماه ژانویه کاهش داشته و برابر با ۰/۰۶ محاسبه شده است. در سال ۲۰۲۰ هم با کاهش مقادیر اغتشاشات یونسفری دقت پیش‌بینی انجام شده افزایش پیدا کرده است به گونه‌ای که مقادیر متوسط مقدار *CC* برابر با ۰/۷۹ و متوسط *RMSE* برابر با ۰/۰۲۲ شده است. در ۳۰ام مارس نیز در شکل (۶) می‌توان دید که در بازه‌های زمانی طلوع و ظهر شاهد کمترین میزان اغتشاشات یونسفری هستیم و تنها در



شکل ۷: مقادیر *S4* مشاهداتی و پیش‌بینی‌شده برای محدوده آمریکای جنوبی در روز ۳۱ام جولای در سه بازه زمانی هنگام طلوع خورشید (*Sunrise*)، هنگام ظهر (*Noon*) و هنگام غروب آفتاب (*Sunset*). ستون اول و دوم به ترتیب مقادیر مشاهداتی و پیش‌بینی‌شده *S4* برای سال ۲۰۱۵ و ستون‌های سوم و چهارم مقادیر ترتیب مقادیر مشاهداتی و پیش‌بینی‌شده *S4* برای سال ۲۰۲۰

مقادیر کمتری را به ثبت رسانده‌اند که به دلیل افزایش فعالیت‌های ژئومغناطیسی و به تبع آن افزایش اغتشاشات یونسفری است. پارامتر CC برای جولای ۲۰۲۰ برابر با ۰/۷۹ را ثبت کرده است که از ژانویه کمتر و برابر با CC مارس است ولی مقدار $RMSE$ ثبت شده در جولای ۲۰۲۰ برابر با ۰/۲۴ است که بیشترین مقدار ثبت شده در مارس ۲۰۲۰ است.

۴-۳- ارزیابی نتایج

در بخش ارزیابی نتایج این پژوهش، بررسی عملکرد مدل پیشنهادی $ConvGRU$ در پیش‌بینی اغتشاشات یونسفری انجام می‌گیرد که به صورت یک مسئله طبقه‌بندی بر اساس روش‌های آماری مورد تحلیل قرار می‌گیرد. عملکرد این مدل‌ها از طریق تقسیم‌بندی درخشش‌های یونسفری به چهار سطح مشخص، بر اساس مقادیر شاخص $S4$ که شدت رخداد درخشش یونسفری را نشان می‌دهد، سنجیده می‌شود. این سطوح به ترتیب عبارت‌اند از: عدم رخداد درخشش یونسفری، درخشش یونسفری ضعیف، درخشش یونسفری متوسط و درخشش یونسفری قوی. معیارهای طبقه‌بندی بر اساس مقادیر $S4$ در نقاط عطف ۰/۲، ۰/۴ و ۰/۶ تعریف شده‌اند که برچسب یک به رکوردهایی که این آستانه‌ها را رد می‌کنند و برچسب صفر به سایرین اختصاص می‌یابد. برای ارزیابی دقت و اعتماد پیش‌بینی‌های این مدل‌ها، متغیرهای آماری متعددی شامل نرخ هشدار کاذب (FAR)، شاخص موفقیت بحرانی^۱ (CSI)، احتمال تشخیص^۲ (POD) و امتیاز مهارت واقعی^۳ (TSS) به کار گرفته شده‌اند. پارامتر FAR نسبت موارد مثبت کاذب به کل موارد منفی واقعی را اندازه‌گیری می‌کند و به صورت تعداد موارد مثبت کاذب تقسیم بر مجموع موارد مثبت کاذب و

با توجه به دو ستون اول شکل (۷) و اطلاعات جدول (۱) می‌توان دید که ماه جولای نسبت به دو ماه دیگر سال ۲۰۱۵ دوره‌ای با اغتشاشات یونسفری کمتر را تجربه کرده است. این روند کاهشی را می‌توان با مقایسه جولای ۲۰۱۵ در شکل (۷) با ژانویه و مارس ۲۰۱۵ شکل‌های (۵) و (۶) مشاهده کرد که در جولای ۲۰۱۵ در سه بازه زمانی طلوع، ظهر و غروب خورشید مقادیر $S4$ مشاهداتی و پیش‌بینی شده مقادیر کمتری را نسبت به دو ماه دیگر دارد که نشان‌دهنده انطباق مشاهدات با اطلاعات جدول (۱) هستند. با استفاده از اطلاعات جدول (۱) می‌توان دید که پارامترهای دقت پیش‌بینی برای جولای ۲۰۱۵ نسبت به دو ماه دیگر بهتر است. در این ماه مقدار متوسط CC برای مقادیر پیش‌بینی شده برابر با ۰/۷۶ و متوسط مقدار $RMSE$ برابر با ۰/۳۲ است که به نسبت دو ماه دیگر آمار بهتری از خود ثبت کرده است. در جولای ۲۰۱۵ می‌توان دید که در هر بازه زمانی طلوع، ظهر و غروب خورشید بیشترین میزان رخداد درخشش یونسفری در محدوده نزدیک به آنامولی استوایی رخداد است و مقادیر پیش‌بینی شده نیز توانسته‌اند این بازه مکانی را به خوبی شناسایی کرده و رخداد درخشش‌های یونسفری را پیش‌بینی کنند. می‌توان دید که در این ماه نیز سال ۲۰۲۰ مقدار رخداد اغتشاشات یونسفری به شدت کاهش پیدا می‌کند. در جولای ۲۰۲۰ می‌توان رخداد درخشش‌های یونسفری را بیشتر در بازه طلوع آفتاب و در محدوده نزدیک به آنامولی استوایی مشاهده کرد و مدل نیز توانسته است رخداد این اغتشاشات رو پیش‌بینی کند. مشاهدات جولای ۲۰۲۰ اما نشان از بالاتر بودن میزان اغتشاشات یونسفری در این بازه زمانی نسبت به دو ماه دیگر سال ۲۰۲۰ دارد. این را می‌توان با مقایسه میان شکل‌های ژانویه و مارس ۲۰۲۰ با مقادیر جولای ۲۰۲۰ مشاهده نمود که در هر سه بازه زمانی و مخصوصاً در بازه طلوع آفتاب شاهد یک روند افزایشی نسبت به دو ماه دیگر هستیم. پارامترهای دقت در جولای ۲۰۲۰ نسبت به ژانویه و مارس ۲۰۲۰

¹ False Alarm Rate (FAR)

² Critical Success Index (CSI)

³ Probability of Detection (POD)

⁴ True Skill Score (TSS)

⁵ False Positives (FP)

عملی برخوردار است. TSS در بازه ۱- تا ۱ قرار دارد، که ۱ نشان دهنده مهارت کامل، ۰ نشان دهنده عدم مهارت (معادل با شانس تصادفی) و ۱- نشان دهنده کامل ناهماهنگی است. جدول (۲)، تحلیل مقایسه‌ای دقیقی از شاخص‌های عملکرد مدل پیشنهادی $ConvGRU-L\delta$ را که بر روی داده‌های پیش‌بینی شده اعمال شده‌اند، ارائه می‌دهد. این جدول، امتیازهای مهارت را برای ماه‌های ژانویه، مارس و جولای طی سال‌های ۲۰۱۵ و ۲۰۲۰ فراهم می‌کند و شرایط مختلف اغتشاشات یونسفری را در بر می‌گیرد. این بررسی دقیق به فهم بهتر اثربخشی هر یک از مدل‌ها تحت شرایط زمانی و محیطی متفاوت کمک می‌کند، و دقت پیش‌بینی‌های آن‌ها در دوره‌های پراکندگی یونسفری را مورد تأکید قرار می‌دهد.

جهت ارزیابی مدل پیشنهادی از پارامترهای آماری مانند (FAR) ، (CSI) ، (POD) و (TSS) استفاده شده است تا بتوان دقت کارایی مدل را در دوره‌هایی با سطوح مختلف فعالیت خورشیدی در ماه‌های ژانویه، مارس و جولای سال‌های ۲۰۱۵ و ۲۰۲۰ به‌طور جامع ارزیابی نمود. نتایج حاصل از این تحلیل نشان می‌دهد که مدل $ConvGRU$ در تمامی شاخص‌ها در سال ۲۰۲۰ با کاهش میزان فعالیت‌های خورشیدی عملکرد بهتری از خود نشان داده است. در ژانویه ۲۰۱۵، FAR به ۰/۳۷ رسید و این میزان در ژانویه ۲۰۲۰ به ۰/۲۱ کاهش یافته است، که کاهش تعداد پیش‌بینی‌های نادرست رویدادهای پراکندگی را نمایان می‌سازد. کاهش در FAR در ماه‌های دیگر نیز مشاهده شده است که می‌توان کاهش مقادیر FAR از ۲۰۱۵ تا ۲۰۲۰ در ماه‌های مارس و جولای را نیز مشاهده نمود. شاخص CSI ، که دقت پیش‌بینی‌ها را در رابطه با رخداد‌های واقعی پراکندگی ارزیابی می‌کند، از ۰/۴۰ در ژانویه ۲۰۱۵ به ۰/۶۱ در ژانویه ۲۰۲۰ افزایش یافت. این بهبود در دقت پیش‌بینی در ماه‌های مارس و جولای نیز مشاهده شده است. در مورد POD ، بهبود قابل توجهی از ۰/۵۵ در ژانویه ۲۰۱۵ به ۰/۷۶ در ژانویه ۲۰۲۰

منفی واقعی^۱ محاسبه می‌شود. شاخص CSI ، که به‌عنوان امتیاز تهدید آشناخته می‌شود، دقت پیش‌بینی‌ها را با در نظر گرفتن هم برخورد‌ها (مثبت‌های واقعی^۲) و هم دور زدن‌ها (منفی‌های کاذب^۳) به‌علاوه هشدارهای کاذب (مثبت‌های کاذب) ارزیابی می‌کند. شاخص POD توانایی مدل را در تشخیص صحیح موارد مثبت واقعی ارزیابی می‌کند، که به‌صورت نسبت مثبت‌های واقعی به مجموع مثبت‌های واقعی و منفی‌های کاذب محاسبه می‌شود. شاخص TSS نرخ برخورد^۴ و نرخ هشدار کاذب (FAR) را مقایسه می‌کند تا توانایی مدل را در تمایز بین کلاس‌های مثبت و منفی فراتر از شانس تصادفی ارزیابی کند. FAR ، CSI ، POD و TSS بر طبق روابط (۱۵) تا (۱۸) محاسبه می‌شوند:

$$FAR = \frac{FP}{TP + FP} \quad \text{رابطه (۱۵)}$$

$$CSI = \frac{TP}{TP + FP + FN} \quad \text{رابطه (۱۶)}$$

$$POD = \frac{TP}{TP + FN} \quad \text{رابطه (۱۷)}$$

$$TSS = \frac{TP}{TP + FN} - \frac{FP}{FP + TN} \quad \text{رابطه (۱۸)}$$

در این قسمت، TP ، TN ، FP و FN به ترتیب تعداد موارد مثبت واقعی، منفی واقعی، مثبت کاذب و منفی کاذب را نمایان می‌سازند. نرخ هشدار کاذب (FAR) پایین، کمتر بودن تعداد پیش‌بینی‌های نادرست پراکندگی در زمان‌های بدون پراکندگی را نشان می‌دهد، که بیانگر دقت بالاتر مدل است. شاخص CSI منفی‌های واقعی را در نظر نمی‌گیرد و صرفاً بر مواردی که به‌عنوان رویدادها پیش‌بینی شده‌اند، متمرکز می‌شود. مقادیر بالای شاخص POD نشان دهنده تشخیص مؤثر رویدادهای پراکندگی است، که از اهمیت بالایی برای تضمین قابلیت اطمینان در کاربردهای

¹ True Negatives (TN)

² Threat Score

³ True Positives (TP)

⁴ False Negatives (FN)

⁵ Hit Rate

مشاهده‌شده است، که نشان‌دهنده حساسیت افزایش‌یافته مدل در تشخیص رویدادهای پراکندگی واقعی است، که برای اطمینان از قابلیت اطمینان عملیاتی در کاربردهای واقعی حیاتی است. قابلیت تشخیص بهبودیافته مدل نیز در ماه‌های مارس و جولای ۲۰۲۰ مشهود است. درنهایت، TSS ، که توانایی مدل را در تمیز دادن بین شرایط پراکندگی و

عدم پراکندگی اندازه‌گیری می‌کند، از ۰/۴۹ در ژانویه ۲۰۱۵ به ۰/۶۹ در ژانویه ۲۰۲۰ پیشرفت کرده است. این پیشرفت در TSS در سراسر دوره‌ها، قدرت تمیز دهنده افزایش‌یافته مدل را نمایان می‌سازد که برای پیش‌بینی‌های قابل‌اعتماد شرایط یونسفری بسیار مهم است.

جدول ۲: عملکرد پیش‌بینی مدل $ConvGRU-L_{\delta}$ با استفاده از پارامترهای آماری مانند نرخ هشدار کاذب (FAR)، شاخص موفقیت بحرانی (CSI)، احتمال تشخیص (POD)، و امتیاز مهارت واقعی (TSS) در آمریکای جنوبی در ژانویه و مارس ۲۰۱۵ و ۲۰۲۰

پارامترها	۲۰۱۵			۲۰۲۰		
	ژانویه	مارس	جولای	ژانویه	مارس	جولای
$ConvGRU - L_{\delta}$	FAR	۰/۳۷	۰/۳۵	۰/۳۲	۰/۲۳	۰/۱۸
	CSI	۰/۴۰	۰/۴۲	۰/۴۷	۰/۶۳	۰/۶۶
	POD	۰/۵۵	۰/۵۷	۰/۵۸	۰/۷۷	۰/۷۹
	TSS	۰/۴۹	۰/۵۱	۰/۵۴	۰/۷۰	۰/۷۲

۵- نتیجه‌گیری و پیشنهادات

این پژوهش باهدف شناسایی، مدل‌سازی و پیش‌بینی اغتشاشات یونسفری به روش مکانی-زمانی با استفاده از روش‌های پیشرفته یادگیری ماشین انجام شده است. با توجه به نتایج به‌دست‌آمده، درخشش‌های یونسفری می‌توانند تأثیرات قابل‌توجهی بر دقت و قابلیت اطمینان سیگنال‌های $GNSS$ داشته باشند، به‌خصوص در مناطق نزدیک به آنامولی یونسفری استوایی که شدت این پدیده‌ها بیشتر است. در این تحقیق از روش شبکه‌های عصبی بازگشتی دروازه‌ای مبتنی بر کانولوشن به دلیل توانایی‌های منحصربه‌فرد خود در پردازش داده‌های سری زمانی و همچنین توانایی بالا در شناسایی ویژگی‌های مکانی از داده‌های دوبعدی، برای مدل‌سازی و پیش‌بینی درخشش‌های یونسفری استفاده شده است. مدل پیشنهادی در این تحقیق شامل دو بخش رمزنگار و پیش‌بینی است که از تکنیک‌های $ConvGRU$ و لایه‌های کانولوشن و دیکانولوشن بهره گرفته است تا قابلیت‌های یادگیری مکانی-زمانی را بهبود بخشد. این

روش توانایی بالایی در کاهش ابعاد و استخراج ویژگی‌های مهم داده‌های یونسفری از طریق پردازش‌های مکانی و زمانی نشان داده است. از جنبه‌های دیگر این پژوهش، استفاده از توابع زیان هوبر که با پارامترهای درخشش یونسفری وزن‌دهی می‌شوند، به عنوان رویکرد نوآورانه این تحقیق مورد توجه قرار گرفت. تابع زیان هوبر با توانایی ترکیب ویژگی‌های مثبت هر دو تابع زیان MSE و MAE ، به افزایش قابلیت‌های پیش‌بینی مدل کمک کرد. این تابع در شرایط خاص توانست اثر داده‌های پرت را کاهش دهد و دقت مدل را در حالت‌های با خطای کم بهبود بخشد. این مدل به‌خوبی توانسته است از داده‌های موجود از ۱۲۱ ایستگاه $GNSS$ ، که در محدوده‌های جغرافیایی مختلف در آمریکای جنوبی پراکنده‌اند، برای تخمین زمانی و مکانی درخشش‌های یونسفری استفاده کند. تجزیه و تحلیل‌ها نشان داد که تغییرات چرخه خورشیدی و شرایط ژئومغناطیسی در سال‌های مختلف (۲۰۱۵ و ۲۰۲۰) تأثیر قابل‌توجهی بر شدت و تواتر

درخشش‌های یونسفری داشته‌اند. یافته‌های تحقیق حاکی از آن است که مدل *ConvGRU* با دقت بالایی توانسته است در زمان‌های کوتاه، وضعیت یونسفر را با توجه به داده‌های ورودی پیش‌بینی کند. این امر بیانگر کارایی بالای مدل در درک پیچیدگی‌های مکانی-زمانی درخشش‌های یونسفری است. تحلیل نتایج نشان می‌دهد که مدل به خوبی می‌تواند در شرایط مختلف ژئومغناطیسی و با در نظر گرفتن تغییرات فعالیت خورشیدی عملکرد قابل قبولی داشته باشد. این موضوع خصوصاً در داده‌های مربوط به سال ۲۰۱۵ که فعالیت خورشیدی در حداکثر بوده است، بیشتر مشهود است. مدل در پیش‌بینی درخشش‌های یونسفری در سال ۲۰۲۰ با فعالیت خورشیدی کمتر، دقت بیشتری نشان داده است که این ممکن است به دلیل کاهش پارامترهای ژئومغناطیسی و کمتر بودن اغتشاشات یونسفری باشد.

تجزیه و تحلیل جامع پیش‌بینی‌های پراکندگی یونسفری با استفاده از پیکربندی‌های مدل *ConvGRU* در طی دوره‌های متفاوت فعالیت خورشیدی در سال‌های ۲۰۱۵ (حداکثر فعالیت خورشیدی) و ۲۰۲۰ (حداقل فعالیت خورشیدی)، درک عمیق‌تری از چگونگی تأثیر فعالیت خورشید بر توانایی‌های پیش‌بینی در پراکندگی‌های یونسفری را فراهم می‌آورد. نرخ هشدار کاذب (*FAR*) در تمام مدل‌ها نشان‌دهنده کاهش مشخصی از ۲۰۱۵ به ۲۰۲۰ است. این کاهش، به‌ویژه در ماه‌های با فعالیت یونسفری کمتر، دقت افزایش یافته مدل را در پرهیز از هشدارهای کاذب با کاهش چرخه خورشیدی منعکس می‌کند. شاخص *FAR* پایین در ۲۰۲۰، توانایی افزایش یافته در تشخیص رویدادهای غیرمترقبه را نشان می‌دهد، که برای کاهش ناکارآمدی‌های عملیاتی در کاربردهای واقعی بسیار حیاتی است. بهبودهای شاخص *CSI* از ۲۰۱۵ به ۲۰۲۰ تکامل دقت پیش‌بینی کلی مدل‌ها را نشان می‌دهد. افزایش سالانه *CSI* در ماه‌های ژانویه و مارس، علی‌رغم تنوع جوی، همسویی بهبودیافته مدل‌ها با رفتار واقعی

یونسفر را می‌رساند، که احتمالاً به دلیل بهبود آموزش و بهینه‌سازی پارامترهای مدل در نتیجه کاهش فعالیت‌های ژئومغناطیسی است. افزایش مقادیر *POD* از ۲۰۱۵ به ۲۰۲۰، قابلیت‌های تشخیص قوی پیش‌بینی حاصل از این مدل را برجسته می‌کند. نرخ‌های تشخیص بهبودیافته برای اطمینان از ضبط و در نظر گرفتن تأثیرات رخداد اغتشاشات یونسفری، به‌ویژه در سیستم‌های ناوبری و ارتباطات که به شرایط یونسفری وابسته هستند، حیاتی است. مقادیر *TSS* بالاتر در سال ۲۰۲۰، توانایی پیچیده مدل پیشنهادی را برای تفکیک دقیق بین شرایط پراکندگی و عدم پراکندگی نمایان می‌کند. پیشرفت تدریجی در *TSS* طی سال‌ها، قدرت تمیزدهی افزایش یافته مدل‌ها را نشان می‌دهد که برای پیش‌بینی‌های قابل اعتماد یونسفری ضروری است. این تحلیل نشان می‌دهد که عملکرد مدل‌ها نه تنها با فعالیت خورشیدی بلکه به صورت فصلی نیز متفاوت است. عملکرد بهتر در ماه جولای در هر دو سال ممکن است به دلیل شرایط ژئوفیزیکی و خورشیدی پایدارتر که محیطی سازگار برای پیش‌بینی‌های مدل فراهم می‌کند، نسبت داده شود. در مقابل، تغییرپذیری مشاهده شده در مارس ممکن است به اختلالات یونسفری مرتبط با اعتدالین که به دلیل طبیعت پویای آن‌ها به سختی قابل مدل‌سازی است، مرتبط باشد. سال ۲۰۱۵ فعالیت یونسفری بیشتری به دلیل حداکثر خورشیدی نشان داد، که منجر به بروز پراکندگی‌های بیشتری شد که دقت مدل را به چالش می‌کشد. در مقابل، شرایط خورشیدی آرام‌تر در سال ۲۰۲۰ به دستاوردهای مدل پایدارتر و نرخ خطای پایین‌تر منجر شد، که تأثیر سطوح فعالیت خورشیدی بر موفقیت پیش‌بینی را تقویت می‌کند. در نهایت، با توجه به پیچیدگی‌های موجود و تأثیر گسترده اغتشاشات یونسفری بر سیستم‌های مختلف، تداوم تحقیقات در این زمینه و توسعه فناوری‌های نوین برای شناسایی و کنترل این پدیده‌ها از اهمیت بالایی برخوردار است. افزایش تعداد

نشان‌دهنده پیشرفت قابل‌توجهی در توانایی ما برای مدیریت تأثیرات آب‌وهوای فضا بر فناوری‌های زمینی است. این مدل‌ها می‌توانند در کاهش خطرات مرتبط با تغییرپذیری یونسفر مفید باشند و همچنین از عملکرد مداوم، ایمن و کارآمد سیستم‌های ناوبری و ارتباطی مبتنی بر ماهواره پشتیبانی کنند.

ایستگاه‌های دائمی و به‌کارگیری تکنولوژی‌های پیشرفته تحلیلی می‌تواند در بهبود عملکرد سیستم‌های ناوبری و ارتباطات تأثیر مثبتی داشته باشد و به کاهش خطرات احتمالی در این زمینه‌ها کمک نماید. درنهایت باید گفت که مدل‌سازی پیش‌بینی اغتشاشات یونسفری با استفاده از ترکیبی از الگوریتم‌های یادگیری عمیق

مراجع

- [1] X. Pi, B. A. Iijima, and W. Lu, "Effects of ionospheric scintillation on GNSS - based positioning," *Navigation: Journal of The Institute of Navigation*, vol. 64, no. 1, pp. 3-22, 2017.
- [2] Li, G., Ning, B., Otsuka, Y., Abdu, M.A., Abadi, P., Liu, Z., Spogli, L. and Wan, W., "Challenges to equatorial plasma bubble and ionospheric scintillation short-term forecasting and future aspects in east and southeast Asia," *Surveys in Geophysics*, vol. 42, pp. 201-238, 2021.
- [3] M. C. Kelley, *The Earth's ionosphere: plasma physics and electrodynamics*. Academic press, 2009.
- [4] E. V. Appleton, "The anomalous equatorial belt in the F2-layer," *Journal of Atmospheric and terrestrial Physics*, vol. 5, no. 1-6, pp. 348-351, 1954, doi: 10.1016/0021-9169(54)90054-9.
- [5] A. Atabati, I. Jazireeyan, M. Alizadeh, M. Pirooznia, J. Flury, H. Schuh, and B. Soja, "Analyzing the Ionospheric Irregularities Caused by the September 2017 Geomagnetic Storm Using Ground-Based GNSS, Swarm, and FORMOSAT-3/COSMIC Data near the Equatorial Ionization Anomaly in East Africa," *Remote Sensing*, vol. 15, no. 24, p. 5762, 2023.
- [6] A. Atabati, I. Jazireeyan, M. M. Alizadeh, A. Pourmina, and A. Malekzadeh, "Investigation of the effects of geomagnetic storms on ionospheric irregularities using the combination of ground-based GNSS and SWARM satellites data," *Engineering Journal of Geospatial Information Technology*, vol. 10, no. 3, pp. 1-27, 2023.
- [7] B. Fejer, L. Scherliess, and E. de Paula, "Effects of the vertical plasma drift velocity on the generation and evolution of equatorial spread F," *J Geophys. Res.* 104, 19859-19869," ed, 1999.
- [8] M. Abdu, J. Bittencourt, and I. Batista, "Magnetic declination control of the equatorial F region dynamo electric field development and spread F," *Journal of Geophysical Research: Space Physics*, vol. 86, no. A13, pp. 11443-11446, 1981.
- [9] T. E. Humphreys, M. L. Psiaki, and P. M. Kintner, "Modeling the effects of ionospheric scintillation on GPS carrier phase tracking," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 46, no. 4, pp. 1624-1637, 2010.
- [10] R. Tiwari, H. Strangeways, and S. Skone, "Modeling the effects of ionospheric scintillation on GPS carrier phase tracking using high rate TEC data," in *Proceedings of the 26th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2013)*, 2013, pp. 2480-2488.
- [11] L. F. C. Rezende, E. R. de Paula, S. Stephany, I. J. Kantor, M. T. A. H. Muella, P. M. de Siqueira, and K. S. Correa, "Survey and prediction of the ionospheric scintillation using data mining techniques," *Space Weather*, vol. 8, no. 6, pp. n/a-n/a, 2010, doi: 10.1029/2009sw000532.
- [12] A. Atabati, M. Alizadeh, H. Schuh, and L.-C. Tsai, "Ionospheric scintillation prediction on s4 and rot parameters using artificial neural network and genetic algorithm," *Remote Sensing*, vol. 13, no.

- 11, p. 2092, 2021.
- [13] A. R. Atabati and M. M. Alizadeh, "Combining Neural Network with Genetic Algorithm for prediction of S4 Parameter using GPS measurement," (in eng), *Journal of Geospatial Information Technology, Research* vol. 7, no. 3, pp. 57-77, 2019, doi: 10.29252/jgit.7.3.57.
- [14] L. Liu, Y. J. Morton, and Y. Liu, "Machine Learning Prediction of Storm - Time High - Latitude Ionospheric Irregularities From GNSS - Derived ROTI Maps," *Geophysical Research Letters*, vol. 48, no. 20, p. e2021GL095561, 2021.
- [15] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [16] N. Kalchbrenner, E. Grefenstette, and P. Blunsom, "A convolutional neural network for modelling sentences," *arXiv preprint arXiv:1404.2188*, 2014.
- [17] D. Mandic and J. Chambers, *Recurrent neural networks for prediction: learning algorithms, architectures and stability*. Wiley, 2001.
- [18] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, no. 8, pp. 1735-1780, 1997.
- [19] R. Dey, Salem, F., "Gate-variants of gated recurrent unit (GRU) neural networks," in *2017 IEEE 60th international midwest symposium on circuits and systems (MWSCAS)*, 2017: IEEE, pp. 1597-1600.
- [20] X. Shi, Z. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong, and W.-c. Woo, "Convolutional LSTM network: A machine learning approach for precipitation nowcasting," *Advances in neural information processing systems*, vol. 28, 2015.
- [21] X. Shi, Z. Gao, L. Lausen, H. Wang, D.-Y. Yeung, W.-k. Wong, and W.-c. Woo, "Deep learning for precipitation nowcasting: A benchmark and a new model," *Advances in neural information processing systems*, vol. 30, 2017.
- [22] E. R. de Paula, de Oliveira, Cesar BA, Caton, Ronald G, Negreti, Patricia M, Batista, Inez S, Martinon, André RF, Neto, Acácio C, Abdu, Mangalathayil A, Monico, João FG, Sousasantos, Jonas, "Ionospheric irregularity behavior during the September 6-10, 2017 magnetic storm over Brazilian equatorial-low latitudes," *Earth, Planets and Space*, vol. 71, no. 1, p. 42, 2019.
- [23] A. Van Dierendonck, Klobuchar, J., Hua, Q., "Ionospheric scintillation monitoring using commercial single frequency C/A code receivers," in *proceedings of ION GPS*, 1993, vol. 93, pp. 1333-1342.
- [24] J. Juan, Aragon-Angel, A., Sanz, J., González-Casado, G., Rovira-Garcia, A., "A method for scintillation characterization using geodetic receivers operating at 1 Hz," *Journal of Geodesy*, vol. 91, no. 11, pp. 1383-1397, 2017.
- [25] B. Xiong, W. X. WAN, B. Q. NING, H. Yuan, and G. Z. LI, "A Comparison and Analysis of the S4 Index, C/N and Roti over Sanya," *Chinese Journal of Geophysics*, vol. 50, no. 6, pp. 1414-1424, 2007.
- [26] S. Haykin, *Neural Networks and Learning Machines* New Jersey: Pearson Prentice Hall, 2008.
- [27] Pouyanfar, S., Sadiq, S., Yan, Y., Tian, H., Tao, Y., Reyes, M.P., Shyu, M.L., Chen, S.C. and Iyengar, S.S., "A survey on deep learning: Algorithms, techniques, and applications," *ACM Computing Surveys (CSUR)*, vol. 51, no. 5, pp. 1-36, 2018.
- [28] D. Zhang and M. R. Kabuka, "Combining weather condition data to predict traffic flow: a GRU - based deep learning approach," *IET Intelligent Transport Systems*, vol. 12, no. 7, pp. 578-585, 2018.
- [29] G. Dai, C. Ma, and X. Xu, "Short-term traffic flow prediction method for urban road sections based on space-time analysis and GRU," *IEEE Access*, vol. 7, pp. 143025-143035, 2019.
- [30] C. Gu and H. Li, "Review on deep learning

- research and applications in wind and wave energy," *Energies*, vol. 15, no. 4, p. 1510, 2022.
- [31] Y. Sun, H. Zhang, S. Hu, J. Shi, J. Geng, and Y. Su, "ConvGRU-RMWP: A Regional Multi-Step Model for Wave Height Prediction," *Mathematics*, vol. 11, no. 9, p. 2013, 2023.
- [32] A. Atabati, Alizadeh, M., Schuh, H. and L. C. Tsai, "Ionospheric scintillation prediction on s4 and rot parameters using artificial neural network and genetic algorithm," *Remote Sensing*, vol. 13, no. 11, p. 2092, 2021.
- [33] B. Zolesi, Cander, Ljiljana R, "The General Structure of the Ionosphere," in *Ionospheric Prediction and Forecasting: Springer*, 2014, pp. 11-48.
- [34] E. R. De Paula, 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, doi: 10.1016/S0273-1177(03)00048-6.
- [35] J. Wilkinson, *New Eyes on the Sun: A Guide to Satellite Images and Amateur Observation* (Springer Science & Business Media). 2012.
- [36] F. Arikan, Erol, CB, Arikan, O, "Regularized estimation of vertical total electron content from GPS data for a desired time period," *Radio Science*, vol. 39, no. 6, pp. 1-10, 2004.



Prediction of Ionospheric Scintillation with a Combination of Deep Learning Algorithms Using GNSS Ground-Based Network across South America

Alireza Atabati ¹, Iraj Jazireeyan ^{2*}, Mohammad Mahdi Alizadeh Elizeie ²

1- PhD Student of Geodesy, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran

2- Assistant Professor of Geodesy, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran

Abstract

Ionospheric plasma disturbances, often caused by solar activity and interplanetary magnetic fields, lead to irregular variations in the electron density of the ionosphere, which result in ionospheric scintillations. The Ionospheric scintillations cause significant fluctuations in the intensity and phase of radio signals that can potentially impact the accuracy of the satellite-based navigation systems. This phenomenon occurs irregularly, and its occurrence rate at low latitudes and near the equatorial anomaly is higher than mid and high latitudes. This study employs a combination of the deep learning network methods and the Huber loss function with observation weighting to predict the spatiotemporal behavior of the ionospheric scintillations in near-real-time. Specifically, the ConvGRU method, which combines a GRU network with a convolutional model, is used for spatiotemporal prediction of the ionospheric scintillation datasets. The data obtained from 121 ground-based GNSS stations, within the latitude range of 15°N to 55°S and longitude range of 270°E to 330°E across the equatorial anomaly region in South America in January, March, and July of the years 2015 (a year of high solar activity) and 2020 (a year of low solar activity) have been utilized. This selection demonstrates the accuracy of the proposed model across a diverse spectrum of geomagnetic scenarios. The designed model achieves regional prediction accuracy of approximately 75% for 2015 and 80% for 2020. This study illustrates that the advanced machine learning techniques can accurately predict the ionospheric scintillations, which can be used near-real-time warning systems to enhance the precision of the observations for the navigation system users.

Key words: Global Navigation Satellite System (GNSS); Ionospheric Irregularities; Deep Learning Algorithms, Convolutional Gated Recurrent Unit (ConvGRU), Huber Loss Function, Amplitude Ionospheric Scintillation (S4).