

Determination of the Additional Secondary Factor (ASF) of the ground-based navigation system (LPS) based on deep learning network

Arman Saberi¹, Nemat Allah Ghahremani^{*2}, Saeid Nasrollahi³, Mohammad Ali Keyvanrad⁴

1- Ph.D. Candidate of control engineering, Faculty of electrical and computer engineering, Malek Ashtar University of Technology, Tehran, Iran.
Email: arman.saberi@mut.ac.ir

2- (*Corresponding author) Associate professor of control engineering, Faculty of electrical and computer engineering, Malek Ashtar University of Technology, Tehran, Iran..Email: ghahremani@mut.ac.ir

3-Assistant professor of control engineering, Faculty of electrical and computer engineering, Malek Ashtar University of Technology, Tehran, Iran.
Email: nasrollahi@mut.ac.ir

4-Assistant professor of control engineering, Faculty of electrical and computer engineering, Malek Ashtar University of Technology, Tehran, Iran.
Email: keyvanrad@mut.ac.ir

Article Info

Date of receive:

2025/01/28

Date of last review:

2025/03/09

Date of accept:

2025/05/09

Date of online publication:

2025/05/09

Keywords:

Additional Secondary Factor,
Loran navigation system, positioning,
Deep learning network,
Time difference error,
Finite-difference time-domain method

Extended Abstract

Introduction

The Loran terrestrial navigation system is recognized as one of the key systems for providing precise positioning services and improving navigation performance on a global scale. These systems transmit low-frequency (LF) electromagnetic waves to deliver highly accurate timing signals to ground users, enabling access to high-precision positioning data. However, the performance of these systems is significantly influenced by environmental and geographical factors, including land cover, elevation, surface temperature, humidity, electrical conductivity, and thermal conductivity. These factors can introduce an additional secondary factor (ASF) error, causing changes in the path and intensity of electromagnetic waves, which consequently reduce the accuracy and reliability of signals. The importance of analyzing these factors and developing models to mitigate their effects is particularly critical in areas with diverse geographical characteristics. Additionally, the complexity of environmental factors such as topographical and climatic variations necessitates advanced methods for modeling and analyzing their impacts. In this context, combining numerical methods with deep learning has emerged as an effective solution to reduce errors arising from these factors and improve the performance of terrestrial navigation systems.

Materials & Methods

1. Numerical Modeling Using the FDTD Method

The finite-difference time-domain (FDTD) method is a powerful numerical approach for simulating electromagnetic wave propagation under various environmental conditions. ... ► **Page 28**

How to Cite:

Saberi, A. Ghahremani, N. Nasrollahi, S. Keyvanrad, M.A. (2025). Determination of the Additional Secondary Factor (ASF) of the ground-based navigation system (LPS) based on deep learning network. Scientific-Research Quarterly Geographical Data (SEPEHR). 34(135), 27-55.

By discretizing Maxwell's equations, this method effectively models the interaction between electromagnetic waves and complex environmental features. In this study, the research area includes 17 distinct land cover classes such as dense forests, water bodies, and arid regions, enabling a comprehensive analysis of the environmental influences on ASF values. This modeling enhances our understanding of the interaction between electromagnetic waves and environmental conditions, paving the way for more accurate solutions to reduce errors stemming from these influences.

2. Integration of Meteorological Data

One of the main challenges in this study was the limited availability of meteorological data from weather stations. To address this issue, data from nine weather stations in the study area were integrated with MODIS (Moderate Resolution Imaging Spectroradiometer) satellite imagery. Satellite data, with its extensive spatial coverage and high temporal resolution, provides more accurate inputs for predicting environmental parameter changes. Variables such as temperature, humidity, and air pressure were processed and combined to enhance the quality of the model inputs. This data integration not only increased spatial and temporal resolution but also improved the accuracy of ASF predictions.

3. Deep Learning Using LSTM Networks

Long short-term memory (LSTM) networks, a type of advanced deep learning model, are particularly well-suited for analyzing sequential data. In this study, LSTM networks were employed to predict the spatiotemporal distribution of meteorological parameters. These networks, by identifying long-term temporal dependencies in the data, significantly improved the accuracy of ASF predictions. The integration of inputs derived from the FDTD method and meteorological information provided a robust framework for analyzing the nonlinear relationships among environmental variables.

Results and Discussion

Key Findings

1- Impact of Land Cover: The results revealed that areas with dense vegetation and high electrical and thermal conductivity exhibited higher ASF values. This can be attributed to the significant influence of these land covers on the absorption and reflection of electromagnetic

waves. Conversely, arid regions with low conductivity showed lower ASF values.

2- Impact of Elevation: Higher elevations were associated with increased ASF values. This increase is due to variations in atmospheric pressure and temperature at these elevations, which affect the path and intensity of electromagnetic waves.

3- Meteorological Relationships: The findings demonstrated a direct relationship between temperature, humidity, and ASF values. Warmer and more humid conditions amplified ASF errors, while cooler and drier conditions reduced these errors.

4- Temporal Variations: ASF values exhibited daily and seasonal variations, influenced by fluctuations in temperature and humidity over time. These variations necessitate periodic adjustments to maintain the accuracy of navigation systems.

Integration of Numerical Modeling and Deep Learning

The results of this study demonstrated that combining the FDTD method with LSTM-based deep learning models provides an effective approach for mitigating ASF errors. The FDTD method accurately simulated complex environmental conditions, while the LSTM model identified long-term temporal patterns. This combination significantly enhanced the reliability of terrestrial navigation systems and reduced errors arising from environmental conditions.

Conclusion


This study successfully integrated numerical modeling and deep learning to address the challenges associated with ASF errors in terrestrial navigation systems. The findings clearly highlighted the importance of considering environmental factors such as elevation, land cover, and meteorological conditions in improving the accuracy and performance of these systems. The proposed combined approach not only ensures the reduction of errors due to environmental conditions but also lays a foundation for future research in navigation and geospatial analyses.



صفحات ۵۵ - ۲۷

فصلنامه علمی - پژوهشی

اطلاعات جغرافیایی (سپهر) دوره ۳۴، شماره ۱۳۵، پاییز ۱۴۰۴



مقاله پژوهشی

<https://doi.org/10.22131/sepehr.2025.2049922.3118>

تعیین فاکتور ثانویه اضافی سامانه ناوبری زمین پایه LPS

بر مبنای شبکه یادگیری عمیق

آرمان صابری^۱، نعمت‌الله قهرمانی^{۲*}، سعید نصراللهی^۳، محمدعلی کیوان‌راد^۴

۱- دانشجوی دکتری برق-کنترل، گروه کنترل، دانشکده برق و کامپیوتر دانشگاه صنعتی مالک اشتر، تهران، ایران arman.saberi@mut.ac.ir

۲- (*نویسنده مسئول) دانشیار گروه کنترل، دانشکده برق و کامپیوتر دانشگاه صنعتی مالک اشتر، تهران، ایران ghahremani@mut.ac.ir

۳- استادیار گروه کنترل، دانشکده برق و کامپیوتر دانشگاه صنعتی مالک اشتر، تهران، ایران nasrollahi@mut.ac.ir

۴- استادیار گروه هوش مصنوعی، دانشکده برق و کامپیوتر دانشگاه صنعتی مالک اشتر، تهران، ایران keyvanrad@mut.ac.ir

چکیده

سامانه‌های ناوبری زمین پایه لورن به دلیل تأثیرپذیری از عوامل محیطی مانند ارتفاع، پوشش اراضی، هدایت الکتریکی، رسانش حرارتی، دما و رطوبت، با چالش‌های مهمی در دقت و پایداری مواجه هستند. این عوامل با تأثیر بر مسیر و شدت امواج الکترومغناطیسی، خطای فاکتور ثانویه اضافی را ایجاد می‌کنند که منجر به انحراف سیگنال می‌شود. در این مقاله، از روش تفاضل محدود در حوزه زمان برای محاسبه مقادیر فاکتور ثانویه اضافی در منطقه مطالعاتی شمال غرب ایران و در ۱۷ کلاس مختلف پوشش اراضی استفاده شد. از آنجا که داده‌های هواشناسی محدود به نه ایستگاه با مختصات معلوم بودند، برای پیش‌بینی پارامترهای جوّی کل منطقه، از تصاویر ماهواره‌ای مادیس بهره گرفته شد. مدل‌های یادگیری عمیق شبکه عصبی بازگشتی حافظه طولانی کوتاه‌مدت برای مدل‌سازی دقیق‌تر توزیع مکانی-زمانی دما به کار رفتند و توزیع دما در شبانه‌روز و نقاط مختلف منطقه مطالعاتی را با دقت بالایی پیش‌بینی کردند. یافته‌ها نشان داد که ارتفاعات بالا، زمین‌های با رسانایی الکتریکی و حرارتی بالا و پوشش‌های گیاهی متراکم، منجر به افزایش مقادیر فاکتور ثانویه اضافی می‌شوند. در مقابل، مناطق خشک و کم‌رسانا مقادیر کمتری از این خطا را تولید می‌کنند. براساس نتایج حاصله، ترکیب داده‌های ایستگاه‌های هواشناسی و تصاویر ماهواره‌ای، دقت قابل توجهی در تحلیل و پیش‌بینی تغییرات فاکتور ثانویه اضافی فراهم کرده است. علاوه بر این، تحلیل نتایج نشان داد که ارتباط مستقیمی میان دما و سایر پارامترهای هواشناسی با مقدار فاکتور ثانویه اضافی وجود دارد. پژوهش حاضر با ترکیب روش‌های عددی و یادگیری عمیق، راهکاری جامع برای تحلیل دقیق اثرات محیطی و جغرافیایی بر سامانه‌ی ناوبری زمین پایه ارائه داده و امکان بهبود دقت و کارایی این سامانه‌ها را در شرایط پیچیده جغرافیایی و جوّی فراهم می‌کند.

اطلاعات مقاله

تاریخ دریافت:

۱۴۰۳/۱۱/۰۹

تاریخ آخرین بازنگری:

۱۴۰۳/۱۲/۱۹

تاریخ پذیرش:

۱۴۰۴/۰۲/۱۹

تاریخ انتشار:

۱۴۰۴/۰۲/۱۹

واژه‌های کلیدی:

فاکتور ثانویه اضافی؛

سامانه ناوبری لورن؛

تعیین موقعیت؛

شبکه یادگیری عمیق؛

خطای اختلاف زمانی؛

معادلات تفاضل محدود

حوزه زمان

استناد به این مقاله:


صابری، آ؛ قهرمانی، ن؛ نصراللهی، س؛ کیوان راد، م.ع (۱۴۰۴) تعیین فاکتور ثانویه اضافی سامانه ناوبری زمین پایه LPS بر مبنای شبکه یادگیری عمیق؛ فصلنامه علمی پژوهشی اطلاعات جغرافیایی (سپهر)، ۳۴(۱۳۵): ۵۵ - ۲۷.

۱- مقدمه

همان‌طور که پیش‌تر بیان شد، سامانه تعیین موقعیت و ناوبری لورن زمین‌پایه است یعنی سیگنال‌ها را به‌صورت زمینی ارسال می‌کند. عواملی چون تغییرات جو، توپوگرافی سطح زمین، جنس عوارض، تداخل الکترومغناطیسی، کروی بودن زمین و همچنین رسانایی الکتریکی سطح زمین روی سیگنال ارسالی تأثیر گذاشته و باعث ایجاد تأخیر در دریافت آن می‌شوند. مهم‌ترین عامل این تأخیر، فاکتور ثانویه اضافی^۳ است که باعث کاهش دقت تعیین موقعیت و ناوبری می‌شود. خطای فاکتور ثانویه اضافی به‌دلیل تغییر سرعت امواج الکترومغناطیسی به‌وجود می‌آید؛ تغییر سرعت نیز به این دلیل است که انتشار سیگنال رادیویی در مناطق مختلف زمین با پوشش‌ها، ارتفاعات و خواص دی‌الکتریک متفاوت است. این عوامل باعث به‌وجود آمدن تأخیر در دریافت سیگنال و ایجاد تغییر فاز می‌شود (User handbook, 1992). این تغییر فاز ایجادشده به‌راحتی قابل پیش‌بینی و اندازه‌گیری نیست و خود نیز تابع عوامل متغیر زیادی همچون ارتفاع منطقه، تغییرات آب‌وهوایی، پوشش سطح زمین منطقه و... است. به منظور افزایش دقت سامانه لورن، محاسبه و حذف این تأخیر برای افزایش بهره‌وری مورد نیاز است. در خصوص پیشینه تحقیق ابتدا ذکر نکاتی به شرح زیر لازم است:

فاکتور ثانویه اضافی به دو بخش مکانی^۴ و زمانی^۵ تقسیم می‌شود. بخش مکانی همان مقدار ثابت ASF است که به موقعیت مکانی شامل توپوگرافی و رسانایی مسیر انتشار سیگنال وابسته هست. بخش زمانی شامل مقادیر متغیرهای وابسته با زمان است که این متغیرها عبارتند از دما، رطوبت، فشار هوا، مسیر انتشار سیگنال و شرایط آب و هوایی (بارانی، برفی و غیره). پژوهش‌های انجام‌گرفته درباره ASF به دو دسته تقسیم می‌شوند: پژوهش‌هایی که با استفاده از الگوریتم‌ها و تکنیک‌های محاسباتی به

سامانه ناوبری رادیویی زمین‌پایه لورن^۱ یک سامانه ناوبری با برد بلند است که برای پایداری انتشار امواج رادیویی از فرکانس ۱۰۰ کیلوهرتز استفاده می‌شود (پایمی‌فرد و گروه نویسندگان، ۱۳۸۹). فرستنده‌های این سامانه روی سطح زمین قرار دارند و گیرنده‌های آن می‌توانند با دریافت سیگنال‌های ارسالی از ایستگاه‌های فرستنده، موقعیت خود را به‌دست آورند. این سامانه از زنجیره‌ای شامل یک ایستگاه فرستنده اصلی و دو یا بیشتر ایستگاه فرستنده ثانویه که چند صد کیلومتر از هم فاصله دارند تشکیل شده است. نحوه موقعیت‌یابی به این صورت است که ایستگاه اصلی و ایستگاه‌های ثانویه پالس‌های رادیویی را در فواصل زمانی مشخص ارسال می‌کنند و گیرنده‌های این سامانه اختلاف زمانی^۲ بین ارسال و دریافت این پالس‌ها را محاسبه می‌نمایند. هر اختلاف زمانی محاسبه‌شده بر روی یک منحنی هذلولی قرار می‌گیرد و موقعیت کاربر از تلاقی دو منحنی هذلولوی و یا دو رویه هذلولوی‌گون تعیین می‌شود (Johler, J.R, 1956) که در نگاره ۱ نحوه موقعیت‌یابی توسط کاربر سامانه نمایش داده شده است.



نگاره ۱: تعیین موقعیت با یک فرستنده اصلی و دو فرستنده ثانوی

3- Additional Secondary Phase Factor (ASF)

4- Spatial

5- Temporal

1- Long Rang Navigation

2- Time Differences

بودن سامانه ناوبری لورن برای سامانه‌های ناوبری در کاربردهای هوایی مورد ارزیابی قرار گرفت (Lest et al 2000). در پژوهشی مشابه، به منظور محاسبه مقدار ASF با تلفیق سامانه‌های GPS / LORAN⁴ و ارسال تصحیحات سامانه ناوبری جهانی از طریق سامانه لورن، در تعیین موقعیت و ناوبری بررسی شده است (Lee et al 2003). در ادامه اندازه‌گیری میدانی ASF در رشته‌کوه‌های راکی کانادا انجام شده است و سه عامل خطای ناوبری سامانه لورن یعنی فاکتور اولیه، فاکتور ثانویه و فاکتور ثانویه اضافی محاسبه شد (Fang et al 2020). همچنین سه روش مختلف برای تخمین فاکتور ثانویه اضافی ارائه شده که مهم‌ترین آن‌ها استفاده از روش گوس مارکو مرتبه اول است. در پژوهشی دیگر، روش دامنه برد ارائه شده که مقدار سرعت انتشار را با استفاده از داده‌های سامانه فضایی جهانی و سامانه ناوبری لورن محاسبه می‌کند (Fang et al 2020). در ادامه به مرور پژوهش‌هایی می‌پردازیم که مبتنی بر پیش‌بینی سرعت انتشار با استفاده از شبکه عصبی هوشمند هستند.

در پژوهشی، تأخیر سرعت انتشار در پنج متغیر آب و هوایی شامل دما، رطوبت، فشار بخار، میدان دید و سرعت باد در بازه زمانی نوامبر تا دسامبر ۲۰۱۶ بررسی و مورد تجزیه و تحلیل قرار گرفت و از معماری MLP⁴ با یک لایه مخفی در شبکه عصبی استفاده شد. نتایج نشان می‌دهد که همبستگی بالایی بین تأخیر زمان انتشار و وضعیت آب و هوا وجود دارد. همچنین همبستگی خطی مثبتی بین تأخیر زمان انتشار و دما برقرار است و همبستگی بالا ولی منفی بین تأخیر زمان انتشار و رطوبت وجود دارد و رفتار مشابهی در تأخیر زمان انتشار در مواجهه با تغییرات فشار بخار و میدان دید مشاهده شده است. همچنین، در این مرجع نشان داده شده که سرعت باد ارتباطی با تغییر زمان انتشار ندارد (Yang et al 2019). در مطالعه‌ای دیگر ارتباط بین تغییرات آب و هوایی در طول روز و مقدار تأخیر زمان انتشار مورد تجزیه و تحلیل قرار گرفته و تأخیر انتشار در

تخمین سرعت انتشار پرداخته‌اند و پژوهش‌هایی که مبتنی بر پیش‌بینی سرعت انتشار با استفاده از هوش مصنوعی و شبکه عصبی هستند. ما در این پژوهش ابتدا مروری بر مطالعاتی که با استفاده از الگوریتم‌ها و تکنیک‌های محاسباتی به تخمین سرعت انتشار پرداخته‌اند داریم. سپس به مطالعاتی می‌پردازیم که مبتنی بر پیش‌بینی سرعت انتشار با استفاده از شبکه عصبی هستند.

اولین بار در سال ۱۹۵۶ سرعت انتشار موج در محیط‌های مختلف بررسی شده است (Johler et al, 1956). سپس در کتاب راهنمای کاربر سامانه زمین پایه لورن که در سال ۱۹۹۲ تهیه شده، روش میلینگتون مورد ارزیابی قرار گرفته است. این روش تنها تأثیر رسانش زمین را در تخمین سرعت انتشار در نظر می‌گیرد و تأثیر تغییرات شدت میدان که به واسطه عبور سیگنال از ارتفاعات رخ می‌دهد را نادیده می‌گیرد. این روش فرض می‌کند مسیر انتشار، تک پرتویی است و جزئیات سطح نادیده گرفته شده و تنها قله‌ها را در نظر گرفته‌اند. در پژوهشی دیگری الگوریتم معادله انتگرالی مطرح شده و هر دو عامل رسانش زمین و ناهمواری برای تعیین تأخیر انتشار مدنظر قرار گرفته است (Paterson et al 1998). سپس به بررسی اینکه آیا با استفاده از سامانه‌های فضایی جهانی^۱ می‌توان فاکتور ثانویه اضافی سامانه ناوبری زمین پایه را محاسبه کرد، پرداخته شده است. نتایجی که از این بررسی به دست آمده این است که با تلفیق دو سامانه ناوبری و با استفاده از فیلتر کالمن، می‌توان خطای ثانویه اضافی را بصورت حدودی تخمین زد. در مطالعات مشابهی مدل‌سازی تأخیرهای فاز در مناطق کوهستانی شمال غربی اروپا با استفاده از روش معادله انتگرالی صورت گرفت و در مطالعه‌ای دیگر سه عامل خطای فاکتور اولیه^۲، فاکتور ثانویه^۳ و فاکتور ثانویه اضافی در محیط‌های مختلف بررسی شد (wiliyams et al, 2000). در پژوهشی دیگر امکان مکمل و پشتیبان

1- Global Navigation Satellite System

2- Primary Phase Factor

3- Secondary Phase Factor

4- Long Range Navigation

5- Multi-Layer Perceptron Neural Network

کاهش تأثیرات منفی این عوامل بر دقت ناوبری کمک کند. در نهایت، توسعه سیستم‌های ترکیبی که از چندین منبع ناوبری به طور همزمان استفاده می‌کنند، می‌تواند به افزایش پایداری و دقت کمک کند. به عنوان مثال، ترکیب داده‌های سامانه‌های ناوبری زمینی و ماهواره‌ای می‌تواند به کاهش خطاهای ناوبری منجر شود. اخیراً، استفاده از مدل‌های یادگیری عمیق برای تحلیل داده‌های پیچیده و بهبود دقت پیش‌بینی‌ها نیز به عنوان یک رویکرد نوین مطرح شده است. به علاوه، توسعه حسگرهای جدید و فناوری‌های مرتبط با اینترنت اشیاء^۴ می‌تواند به جمع‌آوری داده‌های دقیق‌تر و لحظه‌ای کمک کند، که این داده‌ها می‌توانند در بهبود مدل‌های پیش‌بینی و کاهش خطاهای ناوبری مؤثر باشند. در ادامه همین بخش به تعریف مسئله و در بخش دوم به معرفی منطقه مطالعاتی و روش تحقیق خواهیم پرداخت. در بخش سوم مدل‌سازی و داده‌های مورد استفاده بیان می‌شود. در بخش چهارم فرمولاسیون ساختارهای شبکه عصبی بازگشتی حافظه طولانی کوتاه‌مدت^۵ و روش تفاضل محدود در حوزه زمان^۶، به منظور پیش‌بینی و تحلیل فاکتور ثانویه اضافی ارائه می‌شود، در بخش پنجم، شبیه‌سازی مورد ارزیابی قرار می‌گیرد. در بخش ششم، تحلیل و ارزیابی نتایج به دست آمده بیان می‌شود. و در بخش هفتم نتیجه‌گیری و پیشنهادات ارائه خواهد شد.

برای طرح مسئله پژوهش حاضر باید اذعان داشت که؛ سامانه‌های ناوبری زمین‌پایه لورن به دلیل تأثیرپذیری از عوامل محیطی نظیر ارتفاع، پوشش اراضی و شرایط جو^۷، با چالش‌های قابل توجهی در دقت و پایداری مواجه هستند. این عوامل می‌توانند منجر به ایجاد اختلالات و انحرافات در سیگنال‌های ناوبری شوند که به عنوان فاکتور ثانویه اضافی ASF شناخته می‌شوند. وجود این اختلالات موجب کاهش دقت و اعتمادپذیری سامانه‌های ناوبری می‌شود و می‌تواند تأثیرات منفی بر کاربردهای حیاتی مانند

فاصله ۹۲ کیلومتری در طی ۱۰۴ روز متوالی اندازه‌گیری شد. نتایج استخراجی بیانگر این بود که پارامترهای محیطی نظیر تغییرات دما و بارش اثر چشم‌گیری بر روی مقدار ASF می‌گذارند (Hongjuan et al 2017). در مطالعه دیگری متغیرهای آب و هوایی در طول مسیر انتشار برای چند نقطه مختلف محاسبه شد. به این صورت که طی ۹۹۲ کیلومتر، شش نقطه با فواصل یکسان انتخاب و شبکه‌های عصبی مختلف تست و بررسی شده‌اند. نتیجه نشان داد که مدل شبکه عصبی به دلیل در نظر گرفتن نقاط میانی بیشتری در حفاصل فرستنده تا گیرنده عملکرد بهتری داشته است (Pu et al 2021). پژوهشی دیگر با هدف استفاده از روش شبکه عصبی BPNN^۱ به همراه الگوریتم ژنتیک برای تخمین مقدار ASF انجام شد. همچنین ایده تصحیح ASF با استفاده از شبکه عصبی و یادگیری انتقالی برای آموزش مقادیر تئوری به دست آمده با استفاده از روش معادله انتگرالی را ارائه داده‌اند؛ بنابراین ورودی‌های شبکه عصبی، طول و عرض جغرافیایی و ارتفاع گیرنده در نقاط مختلف هر ناحیه در نظر گرفته شد و روش‌های شبکه عصبی BPNN، RBFNN^۲ و GRNN^۳ مورد استفاده قرار گرفتند (Yang et al 2021).

در سال‌های اخیر، پیشرفت‌های زیادی در زمینه بهبود دقت سامانه‌های ناوبری زمین‌پایه مانند لورن صورت گرفته است. به عنوان مثال، تحقیقات نشان می‌دهد که استفاده از الگوریتم‌های پیشرفته تصحیح خطا و مدل‌سازی دقیق‌تر تأثیرات محیطی، می‌تواند به کاهش تأخیرات و افزایش دقت کمک کند. استفاده از داده‌های سنجش از دور و اطلاعات ماهواره‌ای برای مدل‌سازی بهتر توپوگرافی و پوشش سطح زمین، یکی از این روش‌ها است. علاوه بر این، فناوری‌های جدید در حوزه پردازش سیگنال و هوش مصنوعی نیز به بهبود عملکرد سامانه‌های ناوبری کمک کرده‌اند. استفاده از یادگیری ماشین برای تحلیل داده‌های تاریخی و پیش‌بینی تغییرات جو^۷ و محیطی می‌تواند به

4- Internet of Things

5- Long Short Terem Memory

6- Finite-Difference Time-Domain

1- Back Propagation Neural Network

2- Radid Basis Function Nevral Network

3- Generalized Regression Neural Network

۲-۱- منطقه مطالعاتی

منطقه مطالعاتی این پژوهش شمال غرب ایران است که در نگاره ۲ مکان ایستگاه‌ها و در جدول ۱ مختصات دقیق آن‌ها نمایش داده شده است. انتخاب این منطقه به دلایل تنوع بالای پوشش اراضی، تغییرات قابل توجه در عوارض زمین‌شناختی و وجود شبکه ایستگاه‌های دائمی سامانه‌های ناوبری فضاپایه جهانی بوده است. این منطقه شامل سه ایستگاه پلدشت، تبریز و ارومیه می‌شود که از شبکه ایستگاه‌های دائمی GNSS شمال غرب کشور انتخاب شده‌اند. در این پژوهش از ساختار زنجیره سه‌گره‌ای^۲ استفاده شده است، به‌طوری که ایستگاه ارومیه به‌عنوان ایستگاه اصلی^۳ و ایستگاه‌های پلدشت و تبریز به‌عنوان ایستگاه‌های ثانویه^۴ در نظر گرفته شده‌اند. در این ساختار، ایستگاه اصلی سیگنال مرجع را ارسال می‌کند و ایستگاه‌های ثانویه سیگنال‌های اصلاحی را به گیرنده منتقل می‌کنند. این روش امکان تحلیل دقیق‌تر تأثیر عوامل محیطی بر انتشار امواج و عملکرد سامانه ناوبری را فراهم می‌نماید. گیرنده با مقایسه زمان دریافت سیگنال از هر سه ایستگاه، تأخیر زمانی و در نتیجه اثرات عوامل محیطی مانند دما، رطوبت، پوشش اراضی و ارتفاع را بر مقدار فاکتور ثانویه اضافی ASF محاسبه می‌کند. انتخاب این منطقه و ساختار زنجیره سه‌گره‌ای به دلیل موقعیت جغرافیایی استراتژیک و قابلیت پوشش متنوعی از شرایط محیطی و جغرافیایی صورت گرفته است که امکان مطالعه و ارزیابی دقیق اثرات پارامترهای مختلف محیطی را فراهم می‌کند. نتایج شبیه‌سازی و تحلیل‌ها نشان داد که این روش می‌تواند با دقت بالایی تغییرات ناشی از عوامل محیطی را بر سامانه‌های ناوبری زمین‌پایه مدل‌سازی کند.

حمل و نقل هوایی، دریایی و زمینی داشته باشد. با وجود پیشرفت‌های انجام‌شده، هنوز شکاف‌های قابل توجهی در درک نحوه تأثیرگذاری این عوامل محیطی بر ASF وجود دارد. مدل‌های موجود اغلب قادر به پیش‌بینی دقیق این تأثیرات، به‌ویژه در شرایط پیچیده و متغیر محیطی نیستند. پژوهش‌ها نشان داده‌اند که عوامل محیطی مانند ارتفاع، پوشش اراضی و شرایط جوّی تأثیرات چشمگیری بر مقدار ASF دارند. برای مثال، ارتفاعات باعث تغییر در مسیر انتشار امواج و افزایش انعکاس و انکسار می‌شوند. همچنین، پوشش اراضی متنوع نظیر جنگل‌ها، شهرها و زمین‌های کشاورزی می‌توانند با ایجاد موانع مختلف، تغییرات قابل توجهی در مسیر امواج و در نتیجه در مقدار ASF ایجاد کنند. شرایط جوّی مانند رطوبت، فشار هوا و دما نیز نقش کلیدی در تغییر مقدار ASF دارند. برای نمونه، رطوبت بالا می‌تواند با افزایش جذب امواج، قدرت سیگنال‌ها را کاهش دهد. برای حل این چالش‌ها و بهبود دقت محاسبات ASF، در این پژوهش از ترکیبی از داده‌ها و روش‌های پیشرفته استفاده شده است.

۲-۲- داده‌ها و روش تحقیق

داده‌های مورد استفاده در پژوهش حاضر شامل مدل رقومی ارتفاعی^۱ با دقت ۱۰ متری، نقشه‌های پوشش اراضی دقیق، داده‌های ماهواره‌ای و اطلاعات ایستگاه‌های هواشناسی هستند. همچنین، روش معادلات تفاضل محدود در حوزه زمان برای شبیه‌سازی دقیق امواج الکترومغناطیسی به کار گرفته شده است. این روش امکان بررسی اثرات مختلف انتشار موج مانند انعکاس، انکسار، تحریک امواج سطحی و پس‌پراکندگی را فراهم می‌کند. علاوه بر این، از مدل یادگیری عمیق شبکه عصبی بازگشتی با حافظه طولانی کوتاه‌مدت برای تحلیل داده‌های محیطی و پیش‌بینی تأثیر این عوامل بر مقدار ASF استفاده شده است.

2- Three-Node Chain

3- Primary Station

4- Secondary Stations

1- Digital Elevation Model

اعمال می‌شوند. این ویژگی باعث می‌شود که مدل بتواند رفتار واقعی امواج الکترومغناطیسی را در محیط‌های پیچیده بازتاب دهد. این رویکرد عددی، امکان تحلیل دقیق‌تر تأثیرات محیطی را فراهم می‌کند و به بهبود پیش‌بینی‌ها و افزایش دقت سامانه‌های ناوبری در شرایط محیطی پیچیده، مانند مناطق کوهستانی یا زمین‌های با رسانایی متغیر، کمک می‌کند. نتایج شبیه‌سازی با روش FDTD نشان داده‌اند که این روش می‌تواند با دقت بیشتری اثرات ناهمواری زمین و تغییرات جوی را بر مقدار ASF پیش‌بینی کند، که این امر در مقایسه با محاسبات تحلیلی، تطابق بیشتری با داده‌های مشاهده شده دارد.



نگاره ۲: منطقه مطالعاتی

۲-۲- ارتباط فاکتور ثانویه اضافی با شرایط محیطی،

هواشناسی و ارتفاع

این پژوهش با استفاده از روش محاسباتی تفاضل محدود در حوزه زمان FDTD و الگوریتم هوش مصنوعی شبکه عصبی بازگشتی حافظه طولانی کوتاه‌مدت LSTM، تأثیر عوامل محیطی و جوی بر مقدار فاکتور ثانویه اضافی ASF را به صورت جامع بررسی کرده است. هدف اصلی این تحقیق، توسعه مدل‌ها و الگوریتم‌هایی است که بتواند با دقت بالاتری اثر عواملی مانند ارتفاع، پوشش اراضی و شرایط جوی را بر میزان ASF پیش‌بینی کنند. این پژوهش بر مبنای تحلیل اثرات ناهمواری‌های زمین، رسانایی و شرایط جوی مانند دما، رطوبت و فشار هوا انجام شده است. نتایج این تحلیل می‌تواند نقشی کلیدی در کاهش خطاهای سیگنال و افزایش اعتمادپذیری سامانه‌های ناوبری زمین‌پایه ایفا کند. علاوه بر این، یافته‌های مقاله امکان بهبود دقت و پایداری سامانه را در شرایط محیطی پیچیده و متغیر فراهم می‌آورد. در ادامه، تمامی این عوامل به تفصیل مورد بررسی و ارزیابی قرار خواهند گرفت.

جدول ۱: طول و عرض جغرافیایی ایستگاه‌های فرستنده سه‌گره‌ای

نام ایستگاه	عرض جغرافیایی	طول جغرافیایی
پلدشت (PLDT)	۵۱/۶۰۴۷	۳۹ ۱۹ ۴۱/۲۲۹۸
تبریز (TBRIZ)	۱۹/۸۶۱۴	۳۸ ۶ ۴۷/۵۴۴۵
ارومیه (URMH)	۳۴/۴۰۷۰	۳۷ ۳۴ ۴۲/۷۳۴۸۷

در محاسبات ساده، مقدار ASF بر اساس اختلاف زمانی دریافت سیگنال از دو ایستگاه فرستنده توسط گیرنده به صورت رابطه (۱) تعریف می‌شود.


$$\text{ASF} = \text{TOF}_m - \text{TOF}_e \quad \text{رابطه (۱)}$$

در این رابطه، TOF_m زمان دریافت سیگنال در شرایط واقعی^۱ و TOF_e زمان دریافت سیگنال در شرایط ایده‌آل^۲ (بدون مانع) است. با این حال، پژوهش حاضر از روش پیشرفته FDTD استفاده کرده است که به جای مقایسه ساده زمانی، اثرات پیچیده ناهمواری زمین، پوشش اراضی و شرایط جوی را مستقیماً در شبیه‌سازی‌های عددی لحاظ می‌کند. در روش FDTD، پارامترهایی مانند رسانایی زمین، ارتفاع، و شرایط جوی مستقیماً در شبیه‌سازی انتشار موج

1- Time Differences Real

2- Time Differences Measure

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (...)
تعیین فاکتور ثانویه اضافی سامانه ناوبری زمین پایه LPS بر مبنای ... / ۳۵



نگاره ۳: روند نمای پژوهش

۳- مدل سازی
نگاره ۳ نمایش داده شده است شناسایی و بررسی شدند. از جمله این عوامل می توان به پوشش اراضی منطقه مطالعاتی برای محاسبه فاکتور ثانویه اضافی، ابتدا عوامل مؤثر بر خطای این فاکتور با استفاده از روندنمای پژوهش که در و مدل رقومی ارتفاعی اشاره کرد که از مهم ترین دلایل

در این پژوهش، نقشه‌های پوشش اراضی کشور با استفاده از تکنیک‌های یادگیری عمیق و در یک فرایند بهینه استخراج شده‌اند. داده‌های آموزشی این نقشه‌ها از نقشه‌های پوشش اراضی موجود تهیه شده و در ۱۵ کلاس مختلف طبق جدول ۲ و نگاره ۴ دسته‌بندی شده‌اند. این نقشه‌ها امکان شناسایی و تحلیل دقیق‌تر تغییرات و ویژگی‌های مختلف پوشش زمین را فراهم می‌کنند. همچنین، استفاده از این داده‌ها در مدل‌سازی فاکتور ثانویه اضافی تأثیرات پوشش زمین بر انتشار امواج الکترومغناطیسی را با دقت بالاتری نشان می‌دهد.

جدول ۲: سیستم طبقه‌بندی پوشش و کاربری زمین با استفاده از داده‌های سنجش از دور

کد کلاس	نام کلاس
۱	جنگل متراکم
۲	جنگل نیمه متراکم و کم تراکم
۳	مرتع متراکم
۴	مرتع نیمه متراکم و کم تراکم
۵	زراعت آبی
۶	زراعت دیم
۷	زراعت آیش
۸	باغات
۱۱	اراضی شور و نم‌زار (پهنه‌های نمکی)
۱۳	اراضی فاقد پوشش
۱۴	پهنه‌های ماسه‌ای و شن‌زار
۱۵	آب‌های دائمی
۱۶	آب‌های فصلی
۱۹	تالاب با پوشش گیاهی
۲۰	تالاب بدون پوشش گیاهی
۲۲	برف و یخ
۲۳	مناطق ساخته شده

ایجاد خطاهای مکانی در دریافت سیگنال به شمار می‌روند. سپس، تأثیر این عوامل بر مقدار ASF با بهره‌گیری از روش معادلات تفاضل محدود در حوزه زمان محاسبه شد. به‌منظور افزایش دقت محاسبات، پارامترهای هواشناسی مانند دما، فشار، و رطوبت به مدل اضافه شدند تا زمان رسیدن سیگنال با دقت بیشتری تعیین شود. در این مدل‌سازی، تحلیل‌های زمانی و مکانی به‌صورت جامع انجام شده و تأثیر هر یک از پارامترها بر نتایج مدل بررسی شده است. این تحلیل‌ها نقشی کلیدی در کاهش خطاهای ناشی از شرایط محیطی و جغرافیایی ایفا کرده و در نهایت به افزایش دقت و قابلیت اطمینان مدل منجر می‌شوند.

در ادامه، نتایج مدل‌سازی و تحلیل تأثیر عوامل محیطی و جوی بر مقدار ASF به تفصیل ارائه خواهد شد.

۳-۱- پوشش اراضی

پوشش زمین به هر نوع پوشش فیزیکی و بیولوژیکی موجود در سطح زمین، شامل آب، پوشش گیاهی، زمین بایر، تالاب‌ها، یخ و برف، و سازه‌های مصنوعی گفته می‌شود (علیخواه اصل و ناصری، ۱۳۹۶). در این پژوهش، طبقه‌بندی کلاس‌های پوشش اراضی بر اساس استاندارد سازمان خواربار و کشاورزی^۱ و سامانه طبقه‌بندی پوشش اراضی سازمان زمین‌شناسی ایالات متحده^۲ انجام شده است (Di Gregorio et al., 2005). نقشه‌هایی که این ویژگی‌ها را در سطح زمین نمایش می‌دهند، به‌عنوان نقشه‌های پوشش اراضی شناخته می‌شوند؛ اگرچه اصطلاحات "پوشش زمین" و "کاربری زمین" اغلب به‌جای یکدیگر به‌کار می‌روند، اما طبق تعریف بین‌المللی، "پوشش زمین" به ویژگی‌های فیزیکی مشاهده‌شده سطح زمین اشاره دارد که توسط عوامل طبیعی مانند پوشش گیاهی، آب و سطوح غیرقابل نفوذ یا سازه‌های مصنوعی پوشیده شده است (کاظمی و همکاران، ۱۳۹۰).


1- Food and Agriculture Organization-

2- USGS-LCCS

امکان تحلیل دقیق‌تر و معتبرتر انتشار امواج زمینی توسط ایستگاه‌های فرستنده سامانه لورن را فراهم می‌کند. دقت بالای این مدل به ما اجازه می‌دهد جزئیات بیشتری از عوارض زمین را در محاسبات لحاظ کرده و رفتار امواج الکترومغناطیسی را در حضور ناهمواری‌ها و عوارض پیچیده سطح زمین به‌طور دقیق بررسی کنیم. استفاده از این مدل رقومی دقیق به تولید نتایج علمی معتبرتر و کاهش خطاهای ناشی از ناهمواری‌های زمین کمک کرده است.

۳-۳- داده‌های هواشناسی

ایستگاه‌های هواشناسی در سراسر جهان پارامترهای مختلف جوّی را اندازه‌گیری و ثبت می‌کنند. مراکز متعددی برای دریافت این داده‌ها وجود دارند که از جمله آن‌ها می‌توان به مرکز تحلیل و توزیع اطلاعات اقلیمی^۴، مرکز داده دانشگاه وایومینگ^۵، مرکز هواشناسی Weather Underground و مرکز هواشناسی ملی آمریکا اشاره کرد. در این پژوهش، داده‌های مورد نیاز از مرکز هواشناسی دانشگاه وایومینگ دریافت و برای پیاده‌سازی اولیه مدل استفاده شده است. داده‌های این مرکز شامل اندازه‌گیری‌های دقیق پارامترهای هواشناسی از جمله دمای هوا، رطوبت نسبی، دمای خاک، رطوبت خاک، فشار سطحی و سایر پارامترهای سطحی است که در بازه‌های زمانی یک‌ساعته جمع‌آوری و ثبت شده‌اند. این داده‌ها بین سال‌های ۲۰۱۷ تا ۲۰۲۳ از نه ایستگاه هواشناسی در منطقه مطالعاتی گردآوری شده‌اند. برای آموزش الگوریتم یادگیری عمیق شبکه عصبی بازگشتی با حافظه کوتاه‌مدت طولانی LSTM، ۱۷۹۰۰ نمونه اندازه‌گیری آماده‌سازی و استفاده شده است. در این پژوهش، شش ایستگاه هواشناسی برای مدل‌سازی و سه ایستگاه برای ارزیابی عملکرد مدل به‌کار گرفته شدند. اطلاعات دقیق ایستگاه‌ها، از جمله مختصات و مکان آن‌ها، در جدول ۳ و نگاره ۵ ارائه شده است. استفاده از این داده‌ها به ما امکان داد تا تأثیر پارامترهای جوّی بر رفتار امواج و



نگاره ۴: نقشه پوشش و کاربری زمین با استفاده از داده‌های سنجش از دور

۳-۲- مدل رقومی

مدل‌های رقومی زمین^۱ (توپوگرافی سطح زمین) از مهم‌ترین داده‌های مورد استفاده در علوم ژئوماتیک و تحلیل‌های زمین‌شناسی هستند. این مدل‌ها نقش کلیدی در اصلاحات هندسی و رادیومتری داده‌های ماهواره‌ای ایفا می‌کنند و به داده‌های ارتفاعی مانند DSM^۲ مدل سطح دیجیتال و DTM^۳ مدل زمین دیجیتال نیاز دارند (Crespi et al., 2008). مدل‌های جهانی DSM با وضوح پایین و متوسط، مانند SRTM30 و SRTMDSM برای ایالات متحده و SRTM90 در سراسر جهان، به‌صورت رایگان و به‌آسانی در دسترس هستند (Martha et al., 2010). با این حال، این مدل‌ها اغلب فاقد وضوح بالا و جزئیات کافی برای کاربردهای مهندسی و محیطی هستند. حتی در مواردی که مدل‌های با وضوح بالا در دسترس باشند، دقت آن‌ها برای تحلیل‌های دقیق همیشه کافی نیست. این محدودیت‌ها می‌تواند تأثیر منفی بر صحت نتایج تحلیل‌های زمین‌شناسی و انتشار امواج داشته باشند. در این پژوهش، از یک مدل رقومی زمین با دقت ۱۰ متر استفاده شده است. این مدل

1- Digital Elevation Model

2- Digital Surface Model

3- Digital Terrain Model

4- National Oceanic and Atmospheric Administration

5- University of Wyoming

جدول ۳: لیست ایستگاه‌های انتخابی برای مدل‌سازی و ارزیابی مدل

مدل‌سازی / ارزیابی	مرکز	کد	ارتفاع	طول جغرافیایی	عرض جغرافیایی
مدل‌سازی	اردبیل	OITL	۱۳۱۶m	۴۸/۴۲E	۳۸/۳۳N
مدل‌سازی	قزوین	OIIK	۱۲۷۸m	۵۰/۰۰E	۳۶/۲۵N
مدل‌سازی	تهران	OIII	۱۱۹۱m	۵۱/۳۵E	۳۵/۶۸N
مدل‌سازی	تبریز	OITT	۱۳۶۱m	۴۶/۲۸E	۳۸/۰۸N
مدل‌سازی	سهند	OITM	۱۳۴۰m	۴۶/۱۵E	۳۷/۳۵N
مدل‌سازی	خوی	OITK	۱۱۰۷m	۴۴/۹۷E	۳۸/۵۵N
ارزیابی	نخجوان	UBBN	۸۷۳m	۴۵/۴۵E	۳۹/۱۸N
ارزیابی	ارومیه	OITR	۱۲۹۷m	۴۵/۰۸E	۳۷/۵۳N
ارزیابی	زنجان	OITZ	۱۶۶۳m	۴۸/۳۷E	۳۶/۷۷N



نگاره ۵: ایستگاه‌های انتخابی برای مدل‌سازی و ارزیابی مدل

گیاهی تفاضلی بهنجار شده^۲، آب قابل بارش جو^۳ (MYD₀₅) و (MOD₀₅)، شاخص پایداری هوا (MYD₀₇ و MOD₀₇)، از سنجنده مادیس^۴ مستقر بر سکوه‌های ترا و آکوا هستند. داده‌های مورد استفاده از وب‌سایت مادیس دریافت شده

فاکتور ثانویه اضافی ASF را با دقت بالاتری بررسی کنیم.

۳-۴- داده‌های مورد استفاده ماهواره‌ای

در این پژوهش، از داده‌های ماهواره‌ای متنوعی برای استخراج و تحلیل پارامترهای جوّی و پوشش زمین استفاده شده است. این داده‌ها شامل دمای سطح زمین^۱، شاخص

2- Normalized Difference Vegetation Index

3- Total Precipitable Water

4- MODIS

1- Land Surface Temperature

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (س)

تعیین فاکتور ثانویه اضافی سامانه ناوبری زمین پایه LPS بر مبنای ... / ۳۹

$$T_{air} = 0.75 \times LST + 1.21 \times TPW - 0.06 \times LI + 6.98 \times NDVI - 3.47$$

رابطه (۲)

در این پژوهش، علاوه بر استفاده از این مدل، نقشه دقیق پوشش اراضی و مدل رقومی ارتفاعی DEM منطقه مطالعاتی برای بهبود پیش‌بینی دما به کار گرفته شده است. این ترکیب باعث کاهش خطاهای مدل در مقایسه با روش‌های پیشین شده است. همچنین، برای تحلیل و پیش‌بینی دقیق‌تر، از الگوریتم‌های یادگیری عمیق مانند شبکه‌های عصبی بازگشتی LSTM استفاده شده است. این الگوریتم‌ها عملکرد بهینه‌تری در پیش‌بینی پارامترهای جوّی ارائه می‌دهند و نشان‌دهنده دقت و قابلیت بالای مدل نسبت به روش‌های سنتی هستند.

۳-۵- ارتباط بین پارامترهای استخراجی از تصاویر

ماهواره‌ای و دمای هوا

برای مشخص کردن ارتباط یک پارامتر با دمای هوا، نمودار پراکنش هر پارامتر ترسیم و مورد بحث قرار می‌گیرد. قابل ذکر است که داده‌های استفاده شده همان داده‌های مورد استفاده در مدل‌سازی دمای هوا هستند و این نمودارها برای تعداد ۲۰۰۰ داده ترسیم شده‌اند.

۳-۵-۱- بررسی ارتباط دمای سطح زمین با دمای هوا

دمای سطح زمین یکی از پارامترهای کلیدی و تأثیرگذار بر دمای هوا است که به ویژگی‌هایی مانند نوع پوشش سطح، رطوبت، ویژگی‌های ساختاری و شیمیایی سطح، ضریب گسیل و شرایط جوّی وابسته است (H. Kerr, 1992). این پارامتر به دلیل ناهمگنی بالای سطح زمین (مانند خاک، پوشش گیاهی و توپولوژی) به سرعت نسبت به زمان و مکان تغییر می‌کند (Z. Wan et al., 2023). تحلیل نمودار پراکنش نشان می‌دهد که دمای سطح زمین و دمای هوا ارتباطی بسیار قوی با یکدیگر دارند، به‌طوری که ضریب تعیین (R^2) این دو پارامتر برابر با ۰/۹۴ محاسبه شده که در نگراره ۶ قابل ملاحظه است. این یافته، اهمیت دمای

و پس از انجام تصحیحات رادیومتریکی و هندسی، و در صورت لزوم زمین مرجع کردن، آماده‌سازی شده‌اند.


یکی از دلایل اصلی استفاده از داده‌های ماهواره‌ای در این پژوهش، محدودیت داده‌های ایستگاه‌های هواشناسی است. داده‌های ایستگاه‌ها تنها به محل دقیق هر ایستگاه مربوط می‌شوند و امکان پوشش کامل منطقه مطالعاتی را فراهم نمی‌کنند. از سوی دیگر، داده‌های ماهواره‌ای به دلیل توانایی پوشش گسترده و ارائه اطلاعات زمانی-مکانی دقیق، این محدودیت را برطرف می‌کنند (Khesali & Mobasheri, 2019).

با استفاده از این داده‌ها، می‌توان پارامترهایی مانند دما، رطوبت و سایر شرایط جوّی را در تمامی نقاط منطقه مطالعاتی برآورد کرد. علاوه بر این، داده‌های ماهواره‌ای نقش کلیدی در بهبود دقت مدل‌سازی جوّی و کاهش خطاهای مرتبط با پارامترهای محیطی داشته‌اند (Khesali & Mobasheri, 2020). این داده‌ها، همراه با الگوریتم‌های پیشرفته مانند LSTM، دقت پیش‌بینی‌ها را به‌طور قابل توجهی افزایش داده و امکان تحلیل بهتر تغییرات جوّی و پوشش زمین را فراهم کرده‌اند.

۳-۴-۱- مدل استخراج دمای هوا از تصاویر

در این پژوهش، برای تخمین دمای هوا از تصاویر سنجنده MODIS، از مدلی بهره گرفته شده است که توانایی محاسبه دمای هوا را در محدوده‌های وسیع و به‌صورت مستقل از داده‌های ایستگاه‌های هواشناسی دارد. این مدل، که مبنای آن استفاده از محصولات سنجنده مادیس و ضرایب تجربی مرتبط است، در سال ۲۰۱۸ توسط مباحثی و خصالی توسعه داده شده و با دقت ۲/۳۳ درجه سانتی‌گراد و ضریب همبستگی ۰/۹۴ ارائه شده است (Khesali & Mobasheri, 2018).

در این مدل، دمای سطح زمین LST، آب قابل بارش جو TPW، شاخص پایداری جو LI و شاخص بهنجار شده پوشش گیاهی NDVI به‌عنوان متغیرهای کلیدی استفاده شده‌اند که همگی از فرآورده‌های سنجنده MODIS استخراج می‌شوند. رابطه اصلی این مدل به‌صورت رابطه (۲) است.



نگاره ۷: نمودار پراکندگی NDVI نسبت به دمای هوا


۳-۵-۳- آب قابل بارش کلی و ارتباط آن با دمای هوا
آب قابل بارش کلی به مجموع بخار آب موجود در ستونی از جو که قابلیت بارش دارد اطلاق می‌شود. این ستون عمودی از سطح زمین شروع شده و تا نقطه پایانی بخار آب در جو ادامه می‌یابد (Kaufman and Gao, 2000). تحقیقات پیشین نشان داده‌اند که رابطه خطی و تجربی معناداری میان آب قابل بارش کلی و فشار جزئی بخار آب وجود دارد (Yang and Qiu, 1996) همچنین، مباحثی و خصالی در سال ۲۰۲۳ یک رابطه لگاریتمی بین این دو پارامتر به صورت رابطه (۳) ارائه کرده‌اند.

$$VP = 1.13 \times \ln[(TPW) + 0.91] \quad \text{رابطه (۳)}$$

در این پژوهش، با استفاده از داده‌های سنجنده مادیس، مقدار آب قابل بارش استخراج و با داده‌های فشار بخار آب ایستگاه‌های هواشناسی ترکیب شده است. سپس، با بهره‌گیری از رابطه (۳)، فشار بخار آب در تمامی منطقه مطالعاتی مدل‌سازی شده است. تحلیل نمودار پراکنش آب قابل بارش کلی و دمای هوا نشان می‌دهد که این دو پارامتر ارتباط قابل توجهی با یکدیگر دارند و ضریب تعیین برابر با ۰/۷۳ محاسبه شده که در نگاره ۸ نمایش داده شده‌اند. این یافته‌ها بیانگر نقش مهم TPW در پیش‌بینی دمای هوا و تأثیر آن بر دینامیک‌های جوّی است.



دستاوردهای این پژوهش شامل توسعه مدل‌های دقیق‌تر برای پیش‌بینی دمای هوا در شرایط اقلیمی منطقه و بهبود درک از فرآیندهای جوّی محلی با استفاده از داده‌های سنجنده مادیس و داده‌های ایستگاه‌های زمینی است.

سطح زمین را در مدل‌سازی دمای هوا نشان می‌دهد و تأکید می‌کند که داده‌های ماهواره‌ای MODIS، با ارائه اطلاعات زمانی-مکانی دقیق، ابزاری مؤثر برای این منظور هستند. دستاوردهای این تحقیق شامل بهبود دقت پیش‌بینی‌ها، کاهش خطاها با استفاده از تکنیک‌های پیشرفته یادگیری عمیق، و ارائه مدل‌هایی دقیق‌تر برای تحلیل دمای هوا بر اساس تغییرات زمانی و مکانی دمای سطح زمین است.



نگاره ۶: نمودار پراکندگی دمای سطح زمین مستخرج از تصاویر ماهواره‌ای نسبت به دمای هوا

۳-۵-۲- بررسی ارتباط شاخص گیاهی NDVI با دمای هوا
شاخص گیاهی تفاضلی بهنجار شده یکی از معروف‌ترین و کاربردی‌ترین شاخص‌های گیاهی است که تراکم پوشش گیاهی را نشان می‌دهد. مقادیر NDVI کمتر از ۰/۰۵ برای خاک‌های لخت، ۰/۰۵ تا ۰/۱ برای مناطق گیاهی تنک، ۰/۱ تا ۰/۵ برای پوشش‌های گیاهی معمولی و بالای ۰/۵ برای مناطق با تراکم بالای گیاهی تعریف می‌شود، در حالی که آب، برف و یخ مقادیر منفی NDVI دارند (Jackson et al., 1991). با تحلیل نمودار پراکنش NDVI و دمای هوا (نگاره ۷)، مشاهده شد که همبستگی قابل توجهی میان این دو پارامتر وجود ندارد و ضریب تعیین R^2 آن‌ها برابر با ۰/۲۸ است. این نتایج نشان می‌دهد که شاخص NDVI به تنهایی نمی‌تواند پیش‌بینی دقیقی از دمای هوا ارائه دهد. با این حال، یافته‌های پژوهش شامل شناسایی محدودیت‌های NDVI در پیش‌بینی دما و پیشنهاد استفاده از روش‌های ترکیبی با دیگر شاخص‌های گیاهی و پارامترهای محیطی برای بهبود دقت مدل‌سازی دما است.



نگاره ۹: نمودار پراکندگی شاخص پایداری نسبت به دمای هوا

نگاره ۸: نمودار پراکندگی فشار بخار آب نسبت به دمای هوا

۳-۵-۵- تأثیر ارتفاع و شرایط توپوگرافی بر دمای هوا
دمای سطح زمین تحت تأثیر عوامل مختلفی از جمله شرایط توپوگرافی، میزان انرژی دریافتی، شرایط اقلیمی و موقعیت جغرافیایی منطقه قرار دارد. تغییر هر یک از این پارامترها می‌تواند به تغییرات قابل توجهی در دمای سطح منجر شود. شرایط توپوگرافی شامل ارتفاع، شیب و جهت شیب از عوامل کلیدی هستند که بر دمای سطح زمین اثر می‌گذارند. به طور کلی، مناطق با ارتفاع بالاتر نسبت به مناطق کم‌ارتفاع‌تر از میانگین دمای پایین‌تری برخوردارند. همچنین، تفاوت دما در جهت‌های مختلف شیب زمین به دلیل میزان دریافت انرژی خورشیدی می‌تواند قابل توجه باشد. مطالعات این پژوهش نشان داده است که ارتفاع و دمای هوا ارتباط زیادی با یکدیگر دارند. تحلیل نمودار پراکنش نگاره ۱۰ بیانگر ضریب تعیین ۰/۸۰ میان این دو پارامتر است که تأثیر قوی ارتفاع بر دمای هوا را نشان می‌دهد. دستاوردهای این تحقیق شامل درک بهتر از تأثیرات جغرافیایی و توپوگرافی بر دمای هوا، و همچنین توسعه ابزارهای جدید برای پیش‌بینی تغییرات دمایی در مناطق مختلف هستند. این نتایج می‌توانند به بهبود مدیریت اقلیمی و محیط‌زیستی و طراحی مدل‌های دقیق‌تر پیش‌بینی دما کمک کنند.

۳-۵-۴- شاخص پایداری جو و ارتباط آن با دمای هوا
پایداری جو از عوامل کلیدی در تحلیل دینامیک‌های جوی است و به عواملی نظیر گرمایش یا سرمایش تابشی محلی، فرارفت توده‌های هوا و صعود یا نزول بی‌دررویی گستره هوا وابسته است. میزان این پارامتر با استفاده از شاخص LI^۱ اندازه‌گیری می‌شود که اختلاف بین دمای بسته هوای در حال صعود و دمای محیط در ارتفاع ۵۰۰ میلی‌بار را نشان می‌دهد (J.G. Galway, 1965). این شاخص با استفاده از پروفایل رطوبت و دمای استخراج شده از داده‌های سنجنده MODIS قابل محاسبه است. بر اساس این شاخص، مقادیر مثبت LI نشان‌دهنده پایداری جو و مقادیر منفی آن نشان‌دهنده ناپایداری جوی است:

$LI > 6$ هوا کاملاً پایدار، $1 < LI \leq 6$ تقریباً پایدار، $0 < LI \leq -2$ تقریباً ناپایدار، $-6 < LI \leq -2$ ناپایداری کم با احتمال طوفان، $LI \leq -6$ کاملاً ناپایدار با احتمال طوفان شدید. در بررسی نمودار پراکنش شاخص LI و دمای هوا همانطور که در نگاره ۹ نشان داده شده است، این شاخص برخلاف سایر پارامترها، ارتباط معکوسی با دمای هوا دارد. ضریب تعیین R^2 این رابطه برابر با ۰/۵۱ است که نشان‌دهنده تأثیر منفی پایداری جو بر افزایش دمای هوا است. دستاوردهای این پژوهش شامل توانایی پیش‌بینی دقیق‌تر ناپایداری‌های جوی و احتمال وقوع طوفان‌ها با استفاده از داده‌های ماهواره‌ای و تحلیل شاخص LI است. این نتایج می‌توانند به بهبود مدیریت بحران‌های آب‌وهوایی و طراحی سامانه‌های هشدار زودهنگام کمک کنند.


یکی از چالش‌های اصلی این روش، بازتاب‌های مصنوعی در مرزهای شبکه است که برای حل آن از لایه جاذب PML استفاده شد. در این مطالعه، میدان‌های الکتریکی و مغناطیسی برای ۱۷ کلاس مختلف پوشش زمین، شامل جنگل‌ها، زراعت، مراتع، تالاب‌ها و مناطق ساخته‌شده، برآورد شدند. ضرایب هدایت الکتریکی و حرارتی بر اساس نوع پوشش استخراج و در شبیه‌سازی اعمال شدند (جدول ۴). نتایج نشان داد که پوشش‌های با رسانایی الکتریکی و حرارتی بالا، مانند آب‌های دائمی و مناطق ساخته‌شده، تأثیر بسزایی در کاهش مقدار ASF دارند، در حالی که زمین‌های بدون پوشش یا آیش با خاصیت حرارتی و رسانایی کم، موجب افزایش مقادیر ASF می‌شوند. این یافته‌ها با مطالعات پیشین همخوانی داشته و بیانگر دقت بالای روش FDTD در تحلیل اثرات محیطی بر انتشار امواج الکترومغناطیسی است.

۴- فرمولاسیون ساختارهای LSTM و FDTD در پیش‌بینی و تحلیل ASF

در این پژوهش، برای تحلیل و پیش‌بینی دقیق فاکتور ثانویه اضافی ASF، از دو ساختار فرمولاسیون متفاوت و مکمل استفاده شده است که عبارتند از مدل یادگیری عمیق LSTM و روش محاسباتی FDTD که هر یک از این ساختارها به‌صورت مستقل و همزمان برای تحلیل و شبیه‌سازی به کار گرفته شده‌اند.

۴-۱- ساختار LSTM

شبکه عصبی بازگشتی حافظه طولانی کوتاه‌مدت، یکی از معماری‌های پیشرفته شبکه عصبی است که به‌طور ویژه برای یادگیری وابستگی‌های زمانی بلندمدت طراحی شده است. برخلاف RNN‌های معمولی، LSTM با استفاده از ساختار خاص خود از مشکل ناپدید شدن گرادیان^۱ جلوگیری می‌کند و امکان یادگیری روابط پیچیده در داده‌های سری زمانی را فراهم می‌آورد. یک واحد LSTM



نگاره ۱۰: نمودار پراکندگی ارتفاع نسبت به دمای هوا سطح زمین

۳-۶- روش معادلات تفاضل محدود حوزه زمان

این روش یکی از کارآمدترین روش‌های عددی برای تحلیل مسائل الکترومغناطیسی است که با گسسته‌سازی معادلات ماکسول در فضا و زمان، میدان‌های الکتریکی و مغناطیسی را به‌طور مستقیم شبیه‌سازی می‌کند. این روش که توسط K.S. Yee در سال ۱۹۶۶ معرفی شد، از شبکه Yee برای گسسته‌سازی معادلات استفاده می‌کند و مقادیر میدان‌ها در نقاط مختلف شبکه را به‌صورت متناوب به‌روزرسانی می‌کند. در این پژوهش، گام‌های فضایی بر اساس یک‌بیستم طول موج و گام زمانی بر مبنای شرط پایداری کورانت انتخاب شدند تا دقت شبیه‌سازی تضمین شود. به‌روزرسانی میدان‌های الکتریکی و مغناطیسی با استفاده از معادلات گسسته انجام شد.

به‌روزرسانی میدان مغناطیسی (H_y):

$$H_y(i, t + \Delta t) = H_y(i, t) + \left(\frac{\Delta t}{\mu_0 + \Delta x} \right) (E_z(i+1, t) - E_z(i, t))$$

رابطه (۴)

به‌روزرسانی میدان الکتریکی (E_z):

$$E_z(i, t + \Delta t) = E_z(i, t) + \left(\frac{\Delta t}{\epsilon_0 + \Delta x} \right) (H_y(i, t) - H_y(i-1, t))$$

رابطه (۵)

در روابط (۴) و (۵) $E_z(i, t)$ میدان الکتریکی در نقطه i و در زمان t ، $H_y(i, t)$ میدان مغناطیسی در نقطه i و زمان t ، Δt گام زمانی، Δx فاصله ایستگاه‌ها، μ_0 نفوذپذیری مغناطیسی خلاء و ϵ_0 گذردهی الکتریکی خلاء هستند.

1- Recurrent Neural Network

2- vanishing gradient

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (مجله)

تعیین فاکتور ثانویه اضافی سامانه ناوبری زمین پایه LPS بر مبنای ... / ۴۳

جدول ۴: فهرست کلاس‌های پوشش زمین به همراه ضرایب

کد کلاس	نام کلاس	هدایت الکتریکی (S/m)	هدایت حرارتی (W/mK)	بررسی
۱	جنگل متراکم	۸	۵۰	جنگل متراکم رسانایی متوسط و خاصیت حرارتی بالا دارد.
۲	جنگل نیمه متراکم و کم تراکم	۶	۳۰	کاهش پوشش باعث کاهش ضریب حرارتی و رسانایی شده است.
۳	مرتع متراکم	۱۰	۴۰	مراتع رسانایی بیشتری دارند.
۴	مرتع نیمه متراکم و کم تراکم	۸	۲۵	کاهش تراکم باعث کاهش ضریب حرارتی شده است.
۵	زراعت آبی	۱۲	۶۰	زراعت آبی دارای رسانایی و خاصیت حرارتی بالایی است.
۶	زراعت دیم	۶	۱۵	زراعت دیم رسانایی و خاصیت حرارتی کمتری دارد.
۷	زراعت آیش	۵	۱۰	زمین‌های آیش خاصیت حرارتی و رسانایی بسیار کمتری دارند.
۸	باغات	۱۰	۳۵	باغات مشابه زراعت آبی اما با رسانایی و حرارت کمتر.
۱۱	اراضی شور و نمک‌زار	۴	۵	رسانایی پایین و خاصیت حرارتی کم.
۱۳	اراضی فاقد پوشش	۳	۳	زمین‌های بدون پوشش خاصیت حرارتی و رسانایی کمی دارند.
۱۴	پهنه‌های ماسه‌ای و شن‌زار	۵	۳	رسانایی بیشتر از اراضی فاقد پوشش، اما خاصیت حرارتی کم است.
۱۵	آب‌های دائمی	۲۰	۱۰۰	رسانایی و خاصیت حرارتی بسیار بالا.
۱۶	آب‌های فصلی	۱۵	۸۰	کمتر از آب‌های دائمی.
۱۹	تالاب با پوشش گیاهی	۸	۵۰	مشابه جنگل‌ها به دلیل پوشش گیاهی.
۲۰	تالاب بدون پوشش گیاهی	۶	۳۰	رسانایی و خاصیت حرارتی کمتر به دلیل نبود پوشش گیاهی.
۲۲	برف و یخ	۱۲	۷۰	رسانایی متوسط و خاصیت حرارتی بالا به دلیل رطوبت.
۲۳	مناطق ساخته شده	۱۵	۹۰	رسانایی و خاصیت حرارتی بسیار بالا به دلیل مواد ساختمانی

شامل چهار گیت اصلی است که با استفاده از توابع سیگما (σ) و تانژانت هایپربولیک (tanh) عملیات پردازش را انجام می‌دهند.

• گیت اول که به آن forget information نیز گفته می‌شود؛ این گیت مشخص می‌کند که چه میزان از اطلاعات لایه قبلی به لایه فعلی انتقال پیدا کند.

$$i_t = \sigma(W_i \cdot [h_{t-1} \cdot x_t] + b_i) \quad \text{رابطه (۷)}$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1} \cdot x_t] + b_c) \quad \text{رابطه (۸)}$$

$$f_t = \sigma(w_f \cdot [h_{t-1} \cdot x_t] + b_f) \quad \text{رابطه (۶)}$$

در فرمول شماره (۶) x_t : ورودی در زمان t ، و h_{t-1} : خروجی زمان قبلی و w_f, b_f : وزن‌ها و بایاس مربوط به گیت فراموشی هستند.

• گیت لایه سوم که به آن Update cell state گفته می‌شود. در این لایه بعد از تعیین خروجی‌ها به روزرسانی انجام می‌گیرد.

حذف داده‌های پرت^۱ پاکسازی شدند. پس از آن، داده‌ها به دنباله‌های سری زمانی با ۲۴ گام زمانی تبدیل شده و با روش Min-Max نرمال‌سازی شدند. در نهایت، داده‌ها به دو بخش ۸۰٪ برای آموزش و ۲۰٪ برای تست تقسیم شدند. فرایند آموزش مدل با استفاده از الگوریتم بهینه‌سازی Adam انجام شد. تنظیمات یادگیری شامل نرخ اولیه یادگیری ۰/۰۰۵، تعداد ۵۰۰ اپوک، و اندازه دسته‌ای ۳۵۰ بودند. علاوه بر این، از مکانیسم کاهش نرخ یادگیری در صورت عدم بهبود مدل استفاده شد. مدل بر روی پردازنده گرافیکی^۲ آموزش داده شد که موجب کاهش زمان محاسباتی شد. عملکرد مدل با استفاده از معیارهایی نظیر خطای میانگین مربعات^۳، خطای میانگین مطلق^۴، میانگین مربعات خطا^۵، ضریب همبستگی^۶ و ضریب تعیین^۷ مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل توانست به دقت قابل توجهی در پیش‌بینی دما دست یابد. همچنین، خروجی مدل با داده‌های واقعی مقایسه و نمودارهای ارزیابی ترسیم شدند که حاکی از هماهنگی مناسب بین مقادیر پیش‌بینی‌شده و واقعی در هر ایستگاه هواشناسی بود. این مدل با ترکیب روش‌های عددی و یادگیری عمیق، قابلیت تعمیم‌پذیری بالایی را نشان داده و می‌تواند به‌عنوان رویکردی کارآمد برای تحلیل سری‌های زمانی محیطی و جوی مورد استفاده قرار گیرد. مقایسه دقت مدل LSTM با سایر مدل‌های یادگیری ماشین نشان داد که LSTM دقت بالاتری در پیش‌بینی توزیع دما دارد و قادر است الگوهای غیرخطی و پیچیده را بهتر از سایر روش‌ها شناسایی کند (Graves et al., 2013). به‌ویژه، توانایی این مدل در یادگیری روابط بلندمدت و تحلیل روندهای دمایی باعث کاهش خطای پیش‌بینی و افزایش دقت محاسباتی شد. این یافته‌ها با مطالعات پیشین (Bai et al., 2018; Zaytar & Amrani, 2016) سازگار هستند.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad \text{رابطه (۹)}$$

• گیت لایه چهارم که به آن create output گفته می‌شود. در این گیت خروجی نهایی ساخته می‌شود

$$o_t = \sigma(W_0[h_{t-1}, x_t] + b_0) \quad \text{رابطه (۱۰)}$$

$$h_t = o_t * \tan h(C_t) \quad \text{رابطه (۱۱)}$$

۴-۲- پیاده‌سازی مدل LSTM برای پیش‌بینی دمای هوا

مدل پیاده‌سازی‌شده در این مقاله یک معماری یادگیری عمیق مبتنی بر شبکه عصبی حافظه طولانی کوتاه‌مدت است که به‌صورت اختصاصی برای تحلیل سری‌های زمانی و پیش‌بینی دمای هوا طراحی شده است. این معماری شامل سه لایه LSTM، سه لایه Batch Normalization و دو لایه Fully Connected (Dense) است. در این مدل، لایه‌های شبکه عصبی حافظه طولانی کوتاه‌مدت نقش اصلی را در استخراج وابستگی‌های زمانی بلندمدت و کوتاه‌مدت از داده‌های ورودی ایفا می‌کنند. لایه اول LSTM با ۲۵۶ واحد حافظه، داده‌های ورودی را پردازش کرده و خروجی خود را به لایه دوم LSTM منتقل می‌کند. لایه دوم نیز با تعداد واحدهای مشابه، الگوهای پیچیده‌تری را استخراج کرده و به‌عنوان ورودی لایه سوم LSTM استفاده می‌کند. لایه Fully Connected پس از این مراحل، داده‌ها را به فضای ویژگی‌های فشرده‌تری انتقال داده و در نهایت لایه خروجی، مقدار دمای پیش‌بینی‌شده را تولید می‌کند. لایه‌های Batch Normalization نیز به‌منظور افزایش سرعت همگرایی و بهبود پایداری مدل، بین لایه‌های LSTM و Fully Connected قرار گرفته‌اند.

برای آموزش مدل، داده‌ها از فایل ورودی بارگذاری و پیش‌پردازش شدند. این داده‌ها شامل ویژگی‌هایی همچون ارتفاع، کلاس پوشش زمین، دما، فشار، سرعت باد و رطوبت بودند که به همراه تاریخ و زمان جمع‌آوری شدند. به‌منظور کاهش تأثیر مقادیر ناهنجار، داده‌ها از طریق روش

1- Outlier Removal

2- Graphics Processing Unit

3- Mean Squared Error

4- Mean Absolute Error

5- Root Mean Squared Error

6- Correlation Coefficient

7- Coefficient of Determination

۴-۳- استفاده از داده‌های سنجش از راه دور برای

پیش‌بینی دما

با توجه به محدودیت داده‌های ایستگاه‌های هواشناسی که تنها در نقاط مشخصی از منطقه مطالعاتی در دسترس هستند و نیاز به داده‌های هواشناسی در کل منطقه مطالعاتی وجود دارد، استفاده از روش‌های پیشرفته با دقت بالا برای پیش‌بینی دما ضروری است. اندازه‌گیری میدانی دمای سطح زمین به دلیل محدودیت‌های مکانی و هزینه‌های بالا، تنها در مقیاس‌های کوچک عملی است. در مقابل، تصاویر ماهواره‌ای با پوشش مکانی گسترده و دقت زمانی بالا، ابزاری کارآمد برای تخمین پارامترهای جوی در مناطق وسیع به شمار می‌روند.


در این مقاله، مدل یادگیری عمیق LSTM که در بخش قبل آموزش داده شد، برای پیش‌بینی دمای هوای کل منطقه مطالعاتی مورد استفاده قرار گرفت. این مدل، با بهره‌گیری از داده‌های سنجنده مادیس^۱ از ماهواره‌های آکوا و ترا، که داده‌هایی با دقت مکانی یک کیلومتر و برای گذرهای روزانه و شبانه ارائه می‌دهند، به همراه داده‌های ایستگاه‌های هواشناسی، توانست توزیع مکانی-زمانی دما را با دقت بالایی پیش‌بینی کند. مدل LSTM با شناسایی وابستگی‌های زمانی بلندمدت و کوتاه‌مدت در داده‌ها، عملکرد قابل‌توجهی در پیش‌بینی دما داشت. نتایج نشان داد که مدل ارائه‌شده عملکرد بسیار مطلوبی در پیش‌بینی دما داشته است. شاخص‌های ارزیابی مانند ضریب همبستگی، ضریب تعیین، خطای میانگین مربعات و خطای میانگین مطلق که در جدول ۵ ارائه شده‌اند، نشان‌دهنده دقت بالای مدل هستند.

نمودار پراکندگی ارائه‌شده در نگاره ۱۱، همبستگی قوی میان مقادیر پیش‌بینی‌شده و واقعی دما را به‌وضوح نمایش می‌دهد. همچنین، نگاره ۱۲ تغییرات دمای هوای پیش‌بینی‌شده توسط مدل را در مقایسه با مقادیر واقعی در بازه‌های زمانی مختلف نشان می‌دهد. این نمودارها بیانگر

توانایی مدل در پیش‌بینی نوسانات دما و کاهش خطاهای پیش‌بینی به حداقل ممکن هستند. این روش، با ترکیب داده‌های ایستگاهی و تصاویر ماهواره‌ای، توانسته است دقت و جامعیت پیش‌بینی دمای هوا را به‌طور قابل‌توجهی بهبود بخشد. مقایسه نتایج این تحقیق با روش‌های پیشین نشان‌دهنده کاهش خطاها و بهبود چشمگیر دقت پیش‌بینی‌ها است. دستاوردهای کلیدی این پژوهش شامل بهبود چشمگیر دقت پیش‌بینی دما، کاهش خطاهای مدل و اثبات اثربخشی الگوریتم شبکه عصبی LSTM در تحلیل داده‌های پیچیده محیطی و سری‌های زمانی است.

جدول ۵: نتایج ارزیابی شبکه یادگیری عمیق

شاخص‌های ارزیابی	نتایج ارزیابی
ضریب همبستگی	۰/۹۴
ضریب تعیین	۰/۶۹
خطای میانگین مربعات	۴/۰۹۶۱
خطای میانگین مطلق	۱/۴۳۷۲
میانگین مربعات خطا	۲/۰۲۳۹



نگاره ۱۱: نمودار محاسبه ضریب همبستگی

طول موج باشد. مقدار $\lambda/20$ به عنوان یک استاندارد عملی پذیرفته شده که در آن نوسانات موج به طور مناسب مدل سازی می شوند.

• نمایش بهتر تغییرات موج: این انتخاب تضمین می کند که در هر چرخه موج، تعداد کافی نقاط محاسباتی وجود داشته باشد (حداقل ۲۰ نقطه در طول موج).

• توازن بین دقت و هزینه محاسباتی: کاهش بیش از حد گام فضایی باعث افزایش تعداد نقاط شبکه و زمان محاسبات می شود، در حالی که گام های بزرگ تر ممکن است باعث از دست رفتن جزئیات موج شوند. مقدار $\lambda/20$ یک تعادل مناسب بین دقت و کارایی ارائه می دهد.

گام زمانی (dt) بر اساس شرط پایداری کورانت^۲ تعیین شده است این ضریب نشان دهنده گام فضایی در راستای شعاعی (r) است. شرط پایداری کورانت برای یک شبکه دوبعدی FDTD به صورت رابطه (۱۲) تعریف می شود.


$$dt = \frac{dr}{\sqrt{2}c} 0.9 \quad \text{رابطه (۱۲)}$$

dr : گام فضایی در راستای شعاعی و c : سرعت نور هستند. این شرط به این دلیل تعریف می شود که سرعت انتشار موج در شبیه سازی FDTD نباید از سرعت انتشار در دنیای واقعی (سرعت نور C) فراتر رود. شرط پایداری کورانت تضمین می کند که موج به درستی در شبکه محاسباتی منتقل شود و از بروز ناپایداری های عددی جلوگیری می کند. ضریب 0.9 برای افزایش حاشیه اطمینان استفاده می شود.

• ضریب dr/c نشان دهنده حداکثر زمانی است که یک موج می تواند بدون عبور از بیش از یک سلول شبکه در یک گام زمانی طی کند.

• مقدار $\sqrt{2}$ به دلیل ماهیت دوبعدی شبکه استفاده می شود. این مقدار حاصل از ترکیب راستاهای r و z در یک سلول محاسباتی است.

ابعاد شبکه (300×480) است و بر اساس موارد زیر انتخاب



نگاره ۱۲: وضعیت دمای هوای برآورد شده توسط شبکه عصبی آموزش دیده در مقابل دمای هوای واقعی

۴-۴- ساختار FDTD

در این پژوهش، برای تحلیل و شبیه سازی مسائل مربوط به انتشار امواج الکترومغناطیسی در محیط های مختلف، از روش تفاضل محدود در حوزه زمان استفاده شده است. این روش به دلایل دقت بالا، انعطاف پذیری، و توانایی مدل سازی میدان های الکتریکی و مغناطیسی در فضای گسسته، انتخاب شده و برخلاف مدل های تجربی مانند روش میلینگتون^۱، قادر است تأثیرات توپوگرافی، شرایط محیطی و تغییرات زمانی را در نظر بگیرد (Johler et al., 1956; Paterson et al., 1998). همچنین در مطالعات اخیر (Yang et al., 2021; Pu et al., 2021)، ترکیب روش های یادگیری عمیق مانند LSTM با مدل سازی عددی توصیه شده است. به همین دلیل، در پژوهش حاضر روش FDTD برای مدل سازی انتشار فیزیکی امواج و LSTM برای تحلیل وابستگی های زمانی و محیطی مورد استفاده قرار گرفته اند.

۴-۴-۱- گام زمانی و گام مکانی

گام فضایی به صورت $\lambda/20$ (یک بیستم طول موج) تعیین شده است. این انتخاب به دلایل زیر انجام شده است:

• دقت شبیه سازی: برای جلوگیری از ناپایداری عددی و حفظ دقت محاسبات، گام فضایی باید کوچک تر از

که در آن $\sigma(i)$ ضریب میرایی در سلول i از لایه PML است $Pml_{thickness}$ ضخامت لایه جاذب PML بر حسب تعداد سلول‌ها است که این مقدار تعیین می‌کند چه تعداد از سلول‌های مرزی به عنوان ناحیه جاذب امواج در نظر گرفته شوند. همچنین این رابطه تضمین می‌کند که موج به طور کامل در لایه جاذب مستهلک شود.

انتخاب گام‌های فضایی و زمانی، ابعاد شبکه و شرایط مرزی با دقت بالا بر اساس اصول روش FDTD، با هدف دستیابی به نتایج دقیق و پایدار انجام شده است. معادلات ماکسول، با گسسته‌سازی مناسب، امکان مدل‌سازی انتشار امواج الکترومغناطیسی را با دقت بالا فراهم می‌آورند. لایه جاذب PML نیز به طور مؤثری از بازتاب امواج جلوگیری می‌کند و باعث بهبود دقت مدل‌سازی می‌شود.

۵- شبیه‌سازی

در این بخش، فرآیند شبیه‌سازی و تحلیل نتایج مرتبط با محاسبه و برآورد مقادیر فاکتور ثانویه اضافی در ایستگاه‌های مطالعاتی و کل منطقه بررسی شده‌اند. این شبیه‌سازی با هدف درک بهتر اثرات محیطی بر انتشار امواج الکترومغناطیسی و ارائه روشی دقیق برای پیش‌بینی مقادیر ASF انجام شده است. برای این منظور، دو رویکرد مکمل مورد استفاده قرار گرفته‌اند.

رویکرد اول شبیه‌سازی بر اساس داده‌های ایستگاه‌های هواشناسی است؛ که در این روش، داده‌های ایستگاه‌های منتخب منطقه مورد مطالعه که شامل پارامترهای جوی و محیطی مختلف هستند، به عنوان ورودی مدل استفاده شدند. مقادیر ASF با استفاده از روش معادلات تفاضل محدود حوزه زمان FDTD در بازه زمانی مشخصی محاسبه شدند. این رویکرد دقت بالایی در تحلیل و پیش‌بینی مقادیر ASF در نقاط خاص ایستگاه‌ها ارائه کرد و با نتایج مقالات مشابه تطابق نشان داد.

رویکرد دوم شبیه‌سازی کل منطقه مطالعاتی است که در این رویکرد، برای دستیابی به توزیع دقیق دما و پارامترهای

شده است:

وسعت ناحیه مورد مطالعه: تعداد نقاط در راستاهای r و z بر اساس مقیاس فیزیکی منطقه مورد مطالعه و نیاز به دقت کافی برای تحلیل مشخص شده است.

حاشیه کافی برای شرایط مرزی: شبکه طوری طراحی شده که مرزهای لایه جاذب PML فضای کافی برای جذب انرژی موج بدون تداخل با منطقه اصلی شبیه‌سازی داشته باشند.

بهینه‌سازی محاسباتی: تعداد نقاط شبکه با در نظر گرفتن محدودیت‌های محاسباتی (حافظه و زمان پردازش) تنظیم شده است.

۴-۲- شرایط مرزی و لایه جاذب (PML)

شرایط مرزی: در شبکه FDTD، برای جلوگیری از بازتاب امواج از مرزهای شبکه که می‌تواند نتایج را مخدوش کند، از شرایط مرزی جاذب استفاده شده است. لایه جاذب کامل PML یکی از کارآمدترین روش‌ها برای جذب امواج است. لایه PML در حاشیه‌های شبکه قرار می‌گیرد و امواج برخوردکننده را به تدریج میرایی می‌کند. این لایه با ضریب میرایی σ مدل‌سازی شده که مقدار آن به صورت نمایی با فاصله از مرز تغییر می‌کند.

فرمول اعمال میرایی:

$$E_z = E_z \times H \quad \text{رابطه (۱۳)}$$

$$e_r^{-\sigma \cdot dt} = H_r \times H \quad \text{رابطه (۱۴)}$$

$$e_z^{-\sigma \cdot dt} = H_z \times e^{-\sigma \cdot dt} \quad \text{رابطه (۱۵)}$$

که در آن مؤلفه میدان الکتریکی در راستای z ، H_r مؤلفه میدان مغناطیسی در راستای r و H_z مؤلفه میدان مغناطیسی در راستای z و dt گام زمانی شبیه‌سازی هستند.

ضریب میرایی در هر نقطه براساس رابطه (۱۶) محاسبه شده است:

$$\sigma(i) = \left(\frac{\log(1+pml_{thickness})}{5} \times \frac{pml_{thickness}-i}{pml_{thickness}} \right)^2 \quad \text{رابطه (۱۶)}$$

مدل‌سازی‌های مشابه برجسته کرده است، همخوانی دارد. ایستگاه ارومیه تغییرات نوسانی شدیدی را طی بازه زمانی شبیه‌سازی نشان داد که می‌تواند به دلیل توپوگرافی پیچیده منطقه و پوشش اراضی متنوع باشد. مشابه این یافته، در تحقیق (Kaufman and Gao 2000) نیز تأثیر ناهمگنی زمین در مقادیر پارامترهای جوّی و انتشار امواج نشان داده شده است. در ایستگاه قزوین، افزایش قابل توجهی در اواخر فوریه مشاهده شد که به نظر می‌رسد از ترکیب تغییرات دما و سرعت باد ناشی شده باشد؛ این مشاهدات مشابه مطالعاتی است که به تغییرات رطوبت و باد به‌عنوان عوامل کلیدی در انتشار امواج اشاره کرده‌اند. ایستگاه اردبیل مقادیر بسیار بالای ASF را در اوایل مارس ۲۰۲۱ ثبت کرد، که ممکن است به تعاملات خاص امواج الکترومغناطیسی با توپوگرافی منطقه نسبت داده شود. این موضوع در مقاله (Wan et al 2023) نیز به وضوح بیان شده است که تغییرات توپوگرافی می‌تواند باعث بازتاب و تغییر مسیر امواج شود. در ایستگاه زنجان، به جز افزایش ناگهانی اوایل ژانویه که ممکن است به تغییرات فشار بخار مرتبط باشد، مقادیر ASF نسبتاً پایدار بودند؛ این ثبات در شرایط مشابه با آنچه در مقاله (Jackson et al, 1991) برای مناطق با توپوگرافی ساده‌تر ارائه شده، تطابق دارد. ایستگاه سهند با مقادیر کم ASF، نشان‌دهنده پایداری جوی در این منطقه است که با نتایج پژوهش (Galway 1965) که بر تأثیر مستقیم پایداری جو بر مقادیر امواج تأکید دارد، همخوانی دارد.

ایستگاه قزوین پراکندگی مقادیر ASF را طی بازه شبیه‌سازی نشان داد که بیانگر اثر عوامل جوّی متغیر مانند فشار و رطوبت است و مشابه نتایج تحقیق (Anderson et al, 2008) است. در ایستگاه نخجوان، تغییرات ASF عمدتاً در زمان‌هایی با تغییرات شدید دما و دید افقی مشاهده شد؛ این نتیجه در مقایسه با تحقیق (Townshend 1994) که نقش دید افقی در تغییرات امواج را توضیح می‌دهد، قابل تحلیل است. در نهایت، ایستگاه تبریز پایداری در مقادیر ASF را نشان داد که احتمالاً ناشی از همگنی شرایط


هواشناسی در کل منطقه مطالعاتی، از تصاویر ماهواره‌ای سنجنده مادیس MODIS استفاده شده است. این تصاویر که شامل گذرهای روزانه و شبانه از دو سنجنده ترا و آکوا هستند، داده‌هایی با دقت مکانی بالا (۱ کیلومتر) ارائه می‌دهند. با استفاده از این داده‌ها و ترکیب آن‌ها با مدل‌های عددی، پارامترهایی نظیر دمای سطح زمین، آب قابل بارش، شاخص پایداری هوا و شاخص پوشش گیاهی NDVI استخراج شدند. این پارامترها به‌عنوان ورودی مدل معادلات تفاضل محدود حوزه زمان FDTD به‌کار گرفته شدند تا توزیع مکانی مقادیر فاکتور ثانویه اضافی ASF در کل منطقه تخمین زده شود.

استفاده از تصاویر ماهواره‌ای، امکان پوشش کامل منطقه مطالعاتی را فراهم کرد و از محدودیت داده‌های نقطه‌ای ایستگاه‌های هواشناسی فراتر رفت. نتایج شبیه‌سازی نشان داد که توزیع ASF به شدت تحت تأثیر عوامل محیطی از جمله نوع پوشش زمین، رطوبت و توپوگرافی است. این یافته‌ها، دقت مدل را در تحلیل رفتار انتشار امواج در شرایط محیطی مختلف تأیید کرده و با نتایج مطالعات مشابه سازگار است. که نتایج آن در قسمت بعد به تفصیل شرح داده می‌شود.

۵-۱- نتایج شبیه‌سازی بر اساس داده‌های ایستگاه‌های

هواشناسی با مدل‌سازی FDTD

در شبیه‌سازی اول، مقدار فاکتور ثانویه اضافی ASF برای بازه زمانی ۲۲ دسامبر ۲۰۲۰ تا ۲۲ مارس ۲۰۲۱ در ژئو ایستگاه مختلف منطقه مطالعاتی با استفاده از روش تفاضل زمان حوزه محدود FDTD محاسبه شد. نتایج این شبیه‌سازی که در نگاره ۱۳ نمایش داده شده است نشان داد که مقدار ASF به شدت تحت تأثیر ترکیبی از عوامل محیطی و جوّی، از جمله دما، رطوبت نسبی، سرعت باد، و ارتفاع قرار دارد. ایستگاه تهران در اوایل مارس ۲۰۲۱ بیشترین مقدار ASF را نشان داد که احتمالاً به افزایش سرعت باد و کاهش دید افقی نسبت داده می‌شود. این یافته‌ها با نتایج تحقیق (Mobasheri et al 2018) که تأثیر سرعت باد و رطوبت را در




نگاره ۱۳: نمودار محاسبه مقدار ASF در هر ایستگاه: الف: ایستگاه تهران، ب: ایستگاه خوی، پ: ایستگاه قزوین، ت: ایستگاه اردبیل، ث: ایستگاه ارومیه، ج: ایستگاه زنجان، چ: ایستگاه سهند، ح: ایستگاه تبریز

جوئی و توپوگرافی منطقه است و با نتایج تحقیق (Crespi et al. 2008) در مورد تأثیر ناچیز تغییرات جوئی در مناطق با شرایط یکنواخت مطابقت دارد. این تحلیل‌ها اهمیت ترکیب داده‌های جوئی، توپوگرافی، و مدل‌سازی دقیق را در پیش‌بینی دقیق مقادیر ASF برجسته کرده و نشان می‌دهند که نتایج تحقیق حاضر در راستای یافته‌های تحقیقات پیشین

بر این، زراعت آبی، به دلیل رطوبت بالا و رسانایی مناسب، مقادیر متوسطی را نشان داد، در حالی که زراعت دیم به دلیل خشکی نسبی، مقدار کمتری از ASF را ارائه کرد. این تفاوت‌ها، ارتباط تنگاتنگ میان رطوبت خاک، نوع پوشش و رفتار انتشار امواج را تأیید می‌کند، همان‌طور که در تحقیقات Yang and Qiu, 1996 نیز مطرح شده است.

در مقایسه با نتایج شبیه‌سازی براساس داده‌های ایستگاه‌های هواشناسی، که توزیع ASF در ایستگاه‌های منتخب را تحلیل می‌کرد، مشخص شد که ایستگاه‌های واقع در مناطق با پوشش جنگلی متراکم یا تالاب‌ها، مقادیر بالاتری از ASF را نشان می‌دهند. به عنوان مثال، تالاب با پوشش گیاهی نتایج مشابهی با یافته‌های مقالات Kaufman and Gao, 2000 ارائه می‌دهد که نقش کلیدی پوشش گیاهی و رطوبت را در افزایش مقدار ASF برجسته کرده است.

در نهایت، این نتایج نشان می‌دهند که روش FDTD با ترکیب داده‌های محیطی متنوع و تحلیل اثرات آن‌ها، ابزاری قدرتمند برای بررسی و پیش‌بینی مقادیر ASF در محیط‌های مختلف فراهم کرده است. این روش امکان تحلیل دقیق تأثیرات فیزیکی و جغرافیایی را بر انتشار امواج الکترومغناطیسی فراهم کرده و نتایج حاصل با مطالعات پیشین همخوانی کاملی دارد.



نگاره ۱۴: نقشه مقدار ASF برای کل منطقه مطالعاتی


است و در برخی موارد جزئیات بیشتری از تأثیرات عوامل محیطی ارائه می‌دهد.

۲-۵- تحلیل نتایج شبیه‌سازی ASF برای کلاس‌های مختلف پوشش زمین

در این بخش، نتایج شبیه‌سازی که در نگاره شماره ۱۴ نمایش داده شده است، نقشه مقدار ASF برای کل منطقه مطالعاتی را ارائه می‌دهد و نگاره شماره ۱۵ به تفکیک، مقدار ASF برای هر نوع پوشش زمین را نمایش می‌دهد. در این پژوهش، بیش از ۶۵۰,۰۰۰ نقطه داده با فواصل مکانی یک کیلومتر و مشخصات فیزیکی و محیطی منحصر به فرد مانند ارتفاع، دما، نوع پوشش، مختصات دقیق و مقادیر LST برای شبیه‌سازی مورد استفاده قرار گرفت. نتایج نشان داد که مقادیر ASF به شدت وابسته به نوع پوشش زمین و ویژگی‌های فیزیکی و شیمیایی هر کلاس است. یکی از یافته‌های برجسته این پژوهش، مقدار بالای ASF در کلاس "آب‌های دائمی" است. این کلاس، به دلیل هدایت الکتریکی (20 S/m) و حرارتی بالا (100 W/mK)، مقدار ASF معادل ۱/۱۲ را نشان داد. در نگاه اول، این مقدار ممکن است با تعریف ASF که نشان‌دهنده تأخیر زمانی سیگنال به دلیل تعامل با محیط است، متضاد به نظر برسد. اما باید توجه داشت که محیط‌های آبی به دلیل رسانایی بالا، تعامل شدیدی با امواج الکترومغناطیسی دارند و این تعامل می‌تواند بازتاب‌های قابل توجهی ایجاد کند که منجر به تأخیر در سیگنال و در نتیجه افزایش مقدار ASF می‌شود. این رفتار با یافته‌های مطالعات (Anderson et al., 2008, Wan et al., 2023) که تأثیر رسانایی بالای محیط‌های آبی بر انتشار امواج را تأیید کرده‌اند، همخوانی دارد. در مقابل، کلاس‌هایی مانند اراضی فاقد پوشش و اراضی شور و نم‌کزار به دلیل هدایت الکتریکی و حرارتی پایین، مقادیر کمتری از ASF را نشان دادند. این نتایج با تحقیقات خصلی و مباحثی در سال ۲۰۲۳ که کاهش خاصیت بازتاب و پراکندگی امواج در مناطق خشک را نشان داده است، مطابقت دارد. علاوه

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (سج)

تعیین فاکتور ثانویه اضافی سامانه ناوبری زمین پایه LPS بر مبنای ... / ۵۱



نگاره ۱۵ نمودار محاسبه مقدار ASF در هر کلاس: الف: کلاس جنگل متراکم، ب: کلاس جنگل نیمه متراکم و کم متراکم، پ: مرتع متراکم ت: مرتع نیمه متراکم و کم تراکم، ث: زراعت آبی ج: زراعت دیم ج: زراعت آیش ح: باغات خ: اراضی شور د: اراضی فاقد پوشش ذ: پهنه‌های ماسه ای ر: آب‌های دائمی ز: آب‌های فصلی ژ: تالاب با پوشش گیاهی س: تالاب بدون پوشش گیاهی ش: برف ویخ ص: مناطق ساخته شده

۶- ارزیابی نتایج

نتایج حاصل از این پژوهش نشان‌دهنده دقت و کارایی روش‌های ترکیبی عددی و داده‌محور در تحلیل و برآورد مقادیر فاکتور ثانویه اضافی در سامانه‌های ناوبری زمین‌پایه لورن است. شبیه‌سازی‌های انجام‌شده با استفاده از روش تفاضل محدود در حوزه زمان FDTD و تحلیل داده‌های ماهواره‌ای مادیس، توزیع مکانی دقیق و جزئیات بالایی از مقادیر ASF را در کل منطقه مطالعاتی ارائه کردند. این یافته‌ها با مطالعات پیشین همخوانی دارند و تأیید می‌کنند که بهره‌گیری از داده‌های توپوگرافی، ویژگی‌های فیزیکی زمین، دمای سطح، و پارامترهای هواشناسی تأثیر به‌سزایی در بهبود دقت مدل‌سازی انتشار امواج دارد. نتایج نشان داد که پوشش زمین، هدایت الکتریکی، رسانش حرارتی، و دما از عوامل کلیدی تأثیرگذار بر توزیع مقادیر ASF هستند. کلاس‌هایی مانند "زراعت آبی" و "مناطق ساخته‌شده" به دلیل ویژگی‌های رسانایی بالا، مقادیر بیشتری از ASF را نشان دادند. در مقابل، کلاس‌هایی مانند "اراضی فاقد پوشش" و "شنزارها"، که هدایت‌پذیری و رسانش حرارتی پایینی دارند، مقادیر کمتری را تولید کردند. همچنین نتایج دیگر این پژوهش درباره تأثیر ارتفاع، رسانایی زمین و پوشش گیاهی مترام بر مقدار ASF نشان داد که: در مناطق مرتفع، مقدار ASF کاهش می‌یابد که این نتیجه مطابق با مطالعات (Paterson et al., 1998; Williams et al., 2000) است که نشان داده‌اند افزایش ارتفاع باعث کاهش اثرات جذب و پراش امواج رادیویی می‌شود؛ و در زمین‌های با رسانایی بالا، مقدار فاکتور ثانویه اضافی کمتر است که این نتیجه با مطالعات (Johler et al., 1956; Williams et al., 2000) همخوانی دارد که تأیید کرده‌اند سطوح با رسانایی بالا امواج را بهتر انتقال می‌دهند و بازتاب کمتری ایجاد می‌کنند و در نهایت در مناطق دارای پوشش گیاهی مترام، مقدار ASF کمتر است که مطابق با پژوهش (Graves et al., 2013; Bai et al., 2018) نشان می‌دهد که پوشش گیاهی باعث افزایش جذب امواج و کاهش مقدار ASF می‌شود.

یکی دیگر از دستاوردهای مهم این پژوهش، نقش ارتفاع در تغییرات مقادیر ASF است. نتایج نشان داد که ارتفاعات بالاتر به دلیل کاهش هدایت‌پذیری زمین و تغییر در شرایط جو، معمولاً با مقادیر بیشتری از ASF همراه هستند. این موضوع با یافته‌های مطالعات قبلی، تطابق دارد که بیانگر تأثیر مهم ارتفاع در رفتار انتشار امواج الکترومغناطیسی است. بررسی مقایسه‌ای با مقالات و پژوهش‌های پیشین نشان داد که ترکیب روش‌های عددی و یادگیری عمیق در این پژوهش، توانسته است میزان خطا را کاهش دهد و دقت پیش‌بینی‌ها را بهبود بخشد. استفاده از داده‌های ایستگاهی و تصاویر ماهواره‌ای، امکان برآورد دقیق‌تری از دما و هدایت‌پذیری زمین را فراهم کرد. نقشه‌های توزیع ASF، با پوشش بیش از ۶۵۰,۰۰۰ نقطه با فاصله یک کیلومتر، دقت بالا و تطابق خوبی با داده‌های واقعی منطقه نشان دادند. این ارزیابی‌ها، علاوه بر تأیید کارآمدی روش‌های ارائه‌شده، نشان‌دهنده پتانسیل بالای آن‌ها برای تحلیل و بهبود سامانه‌های ناوبری زمین‌پایه در شرایط مختلف محیطی هستند.

۷- نتیجه‌گیری و پیشنهادات

این پژوهش با هدف تحلیل عوامل مؤثر بر فاکتور ثانویه اضافی ASF در سامانه‌های ناوبری زمین‌پایه، ترکیبی از روش‌های عددی پیشرفته و الگوریتم‌های یادگیری عمیق را به کار گرفت. استفاده از مدل یادگیری عمیق شبکه عصبی بازگشتی حافظه طولانی کوتاه‌مدت LSTM به‌منظور پیش‌بینی دقیق دمای هوا در کل منطقه مطالعاتی و روش تفاضل محدود در حوزه زمان FDTD برای شبیه‌سازی انتشار امواج الکترومغناطیسی، امکان تحلیل دقیق و جامع اثرات پارامترهای محیطی و جو را فراهم آورد. نتایج نشان داد که عواملی نظیر ارتفاع، رسانایی الکتریکی و حرارتی، پوشش اراضی، دما، رطوبت و نوع زمین تأثیرات چشمگیری بر مقدار ASF دارند. تحلیل‌ها نشان دادند که افزایش ارتفاع، به دلیل کاهش رسانایی زمین و تغییرات

و داده‌های راداری در کنار تحلیل تغییرات مکانی-زمانی ASF می‌تواند به دقت بیشتر پیش‌بینی‌ها کمک کند.

تشکر و سپاسگزاری

پژوهشگران مراتب تشکر خود را از سازمان جغرافیایی، برای در اختیار قرار دادن داده‌های ارتفاعی با دقت ۱۰ متر و نقشه پوشش اراضی ابراز می‌نمایند.

تعارض منافع

در این پژوهش، حامی مالی و تعارض منافع وجود ندارد.

References

1. Ali, S., & Smith, K. A. (2006). On learning algorithm selection for classification. *Applied Soft Computing*, 6(2), 119–138. <https://doi.org/10.1016/j.asoc.2005.02.002>
2. Ali-Khah-Asal, M., & Naseri, D. (2017). Assessment of land cover change trends in the Khair Gota watershed using remote sensing methods. *Journal of Environmental Science and Technology*, 19
3. Anderson, M. C., et al. (2008). A thermal-based remote sensing technique for routine mapping of land-surface carbon, water, and energy fluxes from field to regional scales. *Remote Sensing of Environment*, 112(12), 4227–4241. <https://doi.org/10.1016/j.rse.2008.07.009>
4. Anismov, O. (2001). Prediction pattern of near surface air temperature using empirical data. *Climatic Change*, 50:297–315.
5. Bai, S., Kolter, J. Z., & Koltun, V. (2018). "An empirical evaluation of generic convolutional and recurrent networks for sequence modeling." *arXiv preprint arXiv:1803.01271*.
6. Bannayan, M., & Hoogenboom, G. (2008). Daily weather sequence prediction realization using the non-parametric nearest neighbor re-sampling technique. *Int. J. Climatol.*, 28(10), 1357–1368.
7. Bannayan, M., & Hoogenboom, G. (2008). Weather Analogue: A tool for lead time simulation of daily weather data based on modified K-nearest-neighbor approach. *Environmental Modeling and Software*, 23, 703–713.
8. Bhutiyani, M. R., Kale, V. S., & Pawar, N. J. (2007). Long-term trends in maximum, minimum and mean annual air

در شرایط جوّی، منجر به افزایش مقادیر ASF می‌شود. این امر ناشی از تغییر مسیر انتشار و کاهش انعکاس امواج در ارتفاعات است، که یافته‌های تحقیقاتی و سایر مطالعات مرتبط را تأیید می‌کند. همچنین، تأثیر نوع پوشش اراضی در پژوهش حاضر، به‌وضوح مشخص شد؛ زمین‌های با پوشش گیاهی متراکم یا زراعت آبی به دلیل هدایت الکتریکی و حرارتی بالا مقادیر بیشتری از ASF را نشان دادند، در حالی که مناطق خشک یا فاقد پوشش گیاهی، به دلیل هدایت‌پذیری پایین، مقادیر کمتری را ارائه دادند. رفتار خاص آب دریا به دلیل رسانایی الکتریکی بالای آن، مقدار ASF را تقریباً ثابت و یکنواخت حفظ کرد، که این ویژگی اهمیت در نظر گرفتن محیط‌های آبی در تحلیل‌های مرتبط را برجسته می‌کند. ترکیب داده‌های ایستگاه‌های هواشناسی با تصاویر ماهواره‌ای و بهره‌گیری از الگوریتم‌های یادگیری عمیق، دقت پیش‌بینی دما و تحلیل ASF را بهبود بخشید. از سوی دیگر، مدل‌های عددی مبتنی بر روش FDTD توانایی تحلیل انتشار امواج در شرایط مختلف جغرافیایی و محیطی را فراهم کرده و امکان ارائه تحلیل‌های دقیق‌تر در مقایسه با مدل‌های سنتی را مهیا کردند. این پژوهش نشان داد که ترکیب روش‌های عددی و یادگیری عمیق، ابزاری قدرتمند و مؤثر برای تحلیل دقیق اثرات محیطی بر سامانه‌های ناوبری زمین‌پایه است. یافته‌های این مطالعه نه تنها می‌توانند به بهبود دقت و عملکرد سامانه‌های ناوبری کمک کنند، بلکه افق‌های جدیدی برای تحقیقات آینده در زمینه تحلیل اثرات محیطی و جوّی بر امواج الکترومغناطیسی گشودند. با توجه به نتایج این پژوهش، پیشنهاد می‌شود در تحقیقات آینده بر بهبود یکپارچه‌سازی GNSS و LPS متمرکز شوند تا دقت و قابلیت اطمینان سیستم‌های ناوبری افزایش یابد. در ضمن برآورد آبی و تصحیح خطای ASF از طریق مدل‌های یادگیری عمیق مانند Transformers، Attention Mechanisms و شبکه‌های ترکیبی LSTM-CNN می‌تواند موجب بهینه‌سازی عملکرد سامانه زمین پایه لورن شود. همچنین، استفاده از داده‌های ماهواره‌ای با وضوح بالا

Symposium on Advances in Science and Technology.

20. Khesali, E., & Mobasheri, M. R. (2019). Prediction of areas at risk of frost using the NEAT model. *Scientific-Research Quarterly of Geographical Data (SEPEHR)*, 28(111), 41–52.

21. Khesali, E., & Mobasheri, M. R. (2020). A method in near surface estimation of air temperature (NEAT) in times following the satellite passing time using MODIS images. *Advances in Space Research*, 65(10), 2339–2347.

22. Khesali, E., & Mobasheri, M. R. (2023). Near Surface Air Temperature Estimation Through Parametrization of Modis Products. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 10, 405-410.

23. Last, J. D., Williams, P., Peterson, B., & Dyksta, K. (2000, November). Propagation of Loran-C signals in irregular terrain: Modeling and measurements Part 1: Modeling. In *29th Annual Convention and Technical Symposium, International Loran Association*, Washington DC, Washington USA (pp. 13–15).

24. Li, X. R., Zhu, Y., Wang, J., & Han, C. (2003). Optimal linear estimation fusion I. Unified fusion rules. *IEEE Transactions on Information Theory*, 49(9), 2192–2208.

25. Li, Z.-L., Tang, B.-H., Wu, H., Ren, H., Yan, G., Wan, Z., & others. (2013). Satellite-derived land surface temperature: Current status and perspectives. *Remote Sensing of Environment*, 131, 14–37. <https://doi.org/10.1016/j.rse.2012.12.008>

26. Li, Z. L., et al. (2018). "Satellite-derived land surface temperature: Current status and perspectives." *Remote Sensing of Environment*.

27. Lomme, J. P., & Guillioni, L. (2004). A simple model for minimum crop temperature forecasting during nocturnal cooling. *Agricultural and Forest Meteorology*, 123(1–2), 55–68.

28. Lo, S., Enge, P., Boyce, L., Peterson, B., Gunther, T., Wenzel, B., & Carroll, K. (2002, September). The Loran integrity performance panel. In *Proceedings of the 15th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GPS 2002)* (pp. 1002–1012).

29. Lo, S., Leatham, M., Offermans, G., Gunther, G. T., Peterson, B., Johnson, G., & Enge, P. (2009). Defining primary, secondary, additional secondary factors for RTCM minimum performance specification. *Research & Radionavigation*.

temperatures across the Northwestern Himalaya during the twentieth century. *Climatic Change*, 85:159–177.

9. Bolstad, P. V., Swift, L., Collins, F., & Regniere, J. (1998). Measured and predicted air temperatures at basin to regional scales in the southern Appalachian Mountains. *Agricultural and Forest Meteorology*, 91:161–176.

10. Crespi, M., De Vendictis, L., Poli, D., Wolff, K., Colosimo, G., Gruen, A., & Volpe, F. (2008). Radiometric quality and DSM generation analysis of Cartosat-1 stereo imagery.

11. Fang, T. H., Kim, Y., Park, S. G., Seo, K., & Park, S. H. (2020). GPS and eLoran integrated navigation for marine applications using augmented measurement equation based on range domain. *International Journal of Control, Automation and Systems*, 18(9), 234–2359.

12. Galway, J. G. (1956). The lifted index as a predictor of latent instability. *Bulletin of the American Meteorological Society*, 37, 528–529. <https://doi.org/10.1175/1520-0477-37.10.528>

13. Gao, B.-C., & Kaufman, Y. J. (2000). The MODIS near-IR water vapor algorithm. Product ID: MOD05 -Total Precipitable Water. NASA MODIS Technical Report Series.

14. Hongjuan, Y., Lili, W., Yurong, P., & Xiaoli, X. (2017, October). Analysis of diurnal variation on long-wave ground wave propagation delay. In *2017 Sixth Asia-Pacific Conference on Antennas and Propagation (APCAP)* (pp. 1–3). IEEE.

15. Jingmei, Y., & Jinhuan, Q. (1996). The empirical expressions of the relation between precipitable water and ground water vapor pressure for some areas in China. *Scientia Atmospherica Sinica*, 5.

16. Johler, J. R. (1956). Phase of the low frequency ground wave (Vel 573). US Department of Commerce, National Bureau of Standards.

17. Kazemi, M. Y., Mahdavi, Y., & Other Authors. (2011). Estimation of land cover and land use changes using remote sensing techniques and geographic information system

18. Kerr, Y. H., Lagouarde, J. P., & Imbernon, J. (1992). Accurate land surface temperature retrieval from AVHRR data with use of an improved split window algorithm. *Remote Sensing of Environment*, 41(2–3), 197–209. [https://doi.org/10.1016/0034-4257\(92\)90063-P](https://doi.org/10.1016/0034-4257(92)90063-P)

19. Khesali, E., & Mobasheri, M. R. (2018). Air temperature image production at different times from a satellite pass time using weather stations data. 13th

39. Pu, Y. Zheng, X. Wang, D. & Xi, X. (2021). Accuracy improvement model for predicting propagation delay of Loran-C signal over a long distance. *IEEE Antennas and Wireless Propagation Letters*, 20(4), 582-586.
40. Rosenthal, W., et al. (2017). "Air temperature estimation using MODIS LST and surface emissivity." *Journal of Climate Science*.
41. Townshend, J. R. G., Justice, C., Skole, D., Malingreau, J. P., Cihlar, J., Teillet, P., & others. (1994). The 1 km resolution global data set: Needs of the International Geosphere Biosphere Programme. *International Journal of Remote Sensing*, 15(17), 3417-3441. <https://doi.org/10.1080/01431169408954395>
42. Tzanis, A. (2017). "Electromagnetic wave propagation in complex environments." *Geophysical Journal International*, 182(2), 469-487.
43. Wang, J., et al. (2019). "Deep learning for daily temperature forecasting: Feasibility and challenges." *Advances in Atmospheric Sciences*, 36(4), 390-405.
44. Wang, L. L. Liang, Z. C. Pu, Y. R. & Xi, X. L. (2021). Method for Loran-C Additional Secondary Factor Correction Based on Neural Network and Transfer Learning. *IEEE Antennas and Wireless Propagation Letters*, 21(2), 332-336.
45. Wang, Y. Wang, W. & Luo, R. (2021). Research on Loran-C ASF Correction Method Based on GA-BP Neural Network. In *China Satellite Navigation Conference (CSNC 2021) Proceedings* (pp. 487-495). Springer, Singapore.
46. Williams, P. & Last, D. (2000), Mapping the ASF of the Northwest European Loran -C System. *The Journal of Navigation*, 53(2), 225-235.
47. Zhou, L. Xu, X. Zhang, J. & Pu, Y. (2013). A new method for Lon-CASF calculation over irregular terrain. *IEEE Transactions on Aerospace and Electronic System*, 49(3), 1738-1744.
30. Loran, C. (1992). User Handbook. US Department of Transportation, US Coast Guard, Commandant Publication P16562.5.
31. Martha, T. R., Kerle, N., van Westen, C. J., Jetten, V., & Vinod Kumar, K. (2010). Effect of sun elevation angle on DSMs derived from Cartosat-1 data. *Photogrammetric Engineering and Remote Sensing*, 76, 429-438.
32. Meng, B., Xi, X. L., & Li, J. (2009, July). ASF seasonal correction of Loran-C based on artificial neural network. In *Proceedings of the IEEE 2009 National Aerospace & Electronics Conference (NAECON)* (pp. 304-307). IEEE.
33. Mohsen, F., & Authors Group. (2009). Introduction to the positioning of Malek Ashtar University of Technology.
- 34- Moran, M. S., & Jackson, R. D. (1991). Assessing the spatial distribution of evapotranspiration using remotely sensed inputs. *Journal of Environmental Quality*, 20(4), 725-737. <https://doi.org/10.2134/jeq1991.00472425002000040022x>
35. Nandakumar, R., Amitabh Chamy, M. P. T., Kopparthi, S. S. S., Paswan, G., Prakash, S., & Singh, S. (2008). Synthesis of investigations under ISPRS-ISRO Cartosat-1 scientific assessment programme primarily for DSM generation. http://www.isprs.org/proceedings/XXXVII/congress/1_pdf/218.pdf
36. Paterson, B., Hartnett, R., Bruckner, D., Hetherington, R., & Fiedlers, R. (1998). Integrated GPS/Loran: Structures and issues. *Navigation*, 45(3), 183-193.
37. Peterson, B. B., Lo, S., & Enge, P. (2008, September). Integrating Loran and GNSS for safety of life applications. In *Proceedings of the Institute of Navigation GNSS Conference*, Savannah, GA.
38. Pu, Y., Yang, H. J., Wang, L. L., Zhao, Y. C., Luo, R., & Xi, X. L. (2019). Analysis and modeling of temporal variation properties for LF ground-wave propagation delay. *IEEE Antennas and Wireless Propagation Letters*, 18(4), 641-645.

COPYRIGHTS

©2025 by the authors. Published by National Geographical Organization. This article is an open access article distributed under the terms and conditions of the Creative Commons [Attribution-NoDerivs 4.0 International \(CC BY-ND 4.0\)](https://creativecommons.org/licenses/by-nd/4.0/)





پروہشگاہ علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی