پانزدهمین سمینار احتمال و فرآیندهای تصادفی
۸ و ۹ شهریور ۱۴۰۴
دانشگاه کردستان
15th Seminar On Probability and Stochastic Processes
August 30-31, 2025
University of Kurdistan
انجمن آمار ایران

مدل‌سازی فرایندهای سری‌زمانی شبکه عصبی بیزی برای شناسایی پیش‌زلزله با ناهنجاری‌های یونوسفری زلزله خاش

محدثه کیکاوسی [۱]، فاطمه حسینی، امید کریمی

گروه آمار، دانشگاه سمنان

چکیده: فرایندهای سری‌زمانی حافظه بلند و کوتاه مدت برای مدل‌کردن داده‌های وابسته به گذشته به کار می‌روند که قادرند اطلاعات مربوط به زمان‌های گذشته را برای مدت طولانی حفظ کنند. با بهره‌گیری از شبکه‌های عصبی و روش‌های بیزی می‌توان روند زمانی ناهنجاری‌های یونوسفری را شناسایی و تحلیل کرد. تحلیل ناهنجاری‌های یونوسفری به شناسایی وقوع زمین‌لرزه‌ها با استفاده از پس‌لرزه‌ها کمک می‌کند. در این مقاله، مدل‌های حافظه بلندمدت با روش‌های کلاسیک و بیزی برای تحلیل و پیش‌بینی روندهای زمانی ناهنجاری‌های مربوط به زلزله خاش سال ۱۳۹۲ به کار گرفته می‌شوند. نتایج حاصل نشان می‌دهند که مدل پیشنهادی توانایی مناسبی در شناسایی الگوهای پنهان یونوسفری پیش از زمین‌لرزه دارند و می‌توان از آن‌ها به‌عنوان ابزاری کارآمد در تحلیل پیش‌نشانگرهای لرزه‌ای بهره گرفت.

واژه‌های کلیدی: فرآیندهای زمانی، شبکه‌های عصبی بیزی، حافظه طولانی کوتاه مدت، زمین‌لرزه خاش.

کد موضوع‌بندی ریاضی (۲۰۲۰): 62J12، 62H11، 65K10.

۱ مقدمه

پیش‌بینی زلزله همواره یکی از چالش‌های مهم در علوم زمین بوده است. در سال‌های اخیر، استفاده از تحلیل تغییرات محتوای الکترونی کل[۱] (TEC) به عنوان یکی از روش‌های نوین برای شناسایی پیش‌نشانگرهای زلزله مورد توجه قرار گرفته است. پژوهش‌های متعددی نشان داده‌اند که بلایای طبیعی می‌توانند از طریق سازوکارها و شدت‌های مختلف، لایه یونوسفر[۲] را دچار اختلال کنند (چن و همکاران ، ۲۰۲۰؛ فری‌شَه و همکاران ، ۲۰۲۴). با توجه به پیچیدگی رفتار زمین، استفاده از شبکه‌های عصبی با مدل‌سازی عدم قطعیت می‌تواند بینش عمیق‌تری در تحلیل این ناهنجاری‌ها ارائه دهد. در این مقاله، با استفاده از داده‌های TEC استخراج‌شده از فایل‌های یونکس[۳] و

[۱] سخنران، mohadeseh-keykavosi@semnan.ac.ir

[1] Total Electron Content
[2] Ionosphere
[3] IONEX

به‌کارگیری مدل‌های حافظه کوتاه و بلند مدت[۴] (LSTM) و LSTM بیزی[۵] (سقیب و همکاران ، ۲۰۲۴) به تحلیل ناهنجاری‌های یونوسفری پیش از وقوع زلزله شهر خاش در استان سیستان و بلوچستان پرداخته‌ایم. این زلزله ۲۷ فروردین ۱۳۹۲ با بزرگای حدود ۷/۵ رخ داده است. یکی از اهداف مهم، بررسی پیش‌بینی روند زمانی داده‌های TEC در بازه زمانی پیش از زلزله و ارزیابی هم‌زمانی ناهنجاری‌های شناسایی‌شده با زمان وقوع این زلزله می‌باشد.

۲ مدل‌های LSTM کلاسیک و بیزی

برای مدل‌کردن روند زمانی داده‌های TEC، از دو مدل شبکه عصبی بازگشتی LSTM کلاسیک و بیزی برای شناسایی ناهنجاری‌های احتمالی پیش از زلزله استفاده می‌شود. مدل LSTM کلاسیک یکی از انواع شبکه‌های عصبی بازگشتی است که برای مدل‌سازی داده‌های سری زمانی و وابسته به گذشته طراحی شده است. این مدل با استفاده از ساختار حافظه‌ای ویژه، قادر است اطلاعات مربوط به زمان‌های گذشته را برای مدت طولانی‌تری حفظ کند و از آن‌ها در یادگیری وابستگی‌های زمانی پیچیده بهره گیرد. در مدل‌های LSTM ، چهار مؤلفه‌ی وضعیت سلول و دروازه ورودی[۶] و دروازه فراموشی[۷] و دروازه خروجی[۸] وجود دارد که نقش کلیدی در پردازش و حفظ اطلاعات ایفا می‌کنند. هر یک از این اجزا وظیفه‌ای خاص را بر عهده دارند و با همکاری یکدیگر، توانایی مدل در یادگیری و حفظ اطلاعات بلندمدت را بهبود می‌بخشند. برای درک بهتر عملکرد این مدل، فرض کنید در زمان t، ورودی X_t، بردار وزن‌ها $W_t = [W_f, W_i, W_c, W_o]$ و بردار اریبی‌ها $b_t = [b_f, b_i, b_c, b_o]$ وجود دارد. خروجی مدل در این زمان نیز O_t خواهد بود. دروازهٔ فراموشی به صورت $f_t = \sigma(W_f \cdot [O_{t-1}, X_t] + b_f)$ است که در آن، f_t خروجی دروازهٔ فراموشی در زمان t است. تابع σ نشان‌دهندهٔ تابع فعال‌سازی سیگموید[۹] است که خروجی را در محدودهٔ بین ۰ تا ۱ قرار می‌دهد. O_{t-1} خروجی مدل در زمان قبلی $(t-1)$ است. همچنین، W_f وزن‌های مرتبط با دروازهٔ فراموشی و b_f اریبی این دروازه است. دروازهٔ فراموشی با استفاده از این مکانیزم، تصمیم می‌گیرد که چه میزان از اطلاعات قبلی در وضعیت سلول حفظ شود. اگر f_t بزرگتر از ۰/۵ باشد، اطلاعات قبلی در حالت سلولی حفظ می‌شود؛ در غیر این صورت، اطلاعات فراموش می‌شود. این فرایند به مدل LSTM اجازه می‌دهد تا به صورت انتخابی و هوشمندانه، اطلاعات مهم را نگه داشته و اطلاعات غیرضروری را حذف کند، که این امر در پردازش توالی‌های زمانی و یادگیری الگوها بسیار حیاتی است.

دروازه ورودی در مدل LSTM به‌صورت $i_t = \sigma(W_i \cdot [O_{t-1}, X_t] + b_i)$ محاسبه می‌شود. که در آن، i_t خروجی دروازه ورودی در زمان t است و نشان می‌دهد چه اطلاعاتی از ورودی جدید باید وارد وضعیت سلول شود. وضعیت سلول پیشنهادی در مدل LSTM به صورت $\tilde{C}_t = \tanh(W_c \cdot [O_{t-1}, X_t] + b_c)$ تعریف می شود که در آن، $\tilde{C}_t$ مقدار پیشنهادی برای به‌روزرسانی وضعیت سلول در زمان t است. تابع tanh به عنوان تابع فعال‌سازی استفاده می‌شود و خروجی آن در محدوده‌ی بین ۱- و ۱+ قرار می‌گیرد. W_c وزن‌های مرتبط با وضعیت سلول پیشنهادی و b_c بایاس ان است. سپس وضعیت سلول به صورت $C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t$ به‌روزرسانی می‌شود. که در آن، C_t وضعیت سلول در زمان t است که با ترکیب اطلاعات قبلی و اطلاعات جدید به‌دست می‌آید. دروازه خروجی مدل LSTM به صورت $h_t = \sigma(W_o \cdot [O_{t-1}, X_t] + b_o)$ به دست می‌آید که در آن، h_t سیگنال خروجی دروازه خروجی در زمان t است که مقداری بین ۰ و ۱ اختیار می‌کند. پس از محاسبه‌ی h_t، خروجی نهایی مدل در زمان t (O_t) با استفاده از وضعیت

[4] Long Short-Term Memory
[5] Bayesian LSTM
[6] Input Gate
[7] Forget Gate
[8] Output Gate
[9] Sigmoid

سلول به‌روزرسانی‌شده (C_t) و سیگنال خروجی دروازه خروجی به صورت $O_t = h_t \cdot \tanh(C_t)$ به دست می‌آید. در این مقاله، مدل LSTM پایه‌ای به‌کار گرفته شده است که شامل یک لایه LSTM با تعداد مشخصی واحد حافظه و یک لایه خروجی چگالی است. این مدل به‌صورت کلاسیک و قطعی آموزش داده می‌شود؛ به این معنا که در مرحله‌ی آموزش، از تکنیک دراپ آوت[10] برای جلوگیری از بیش‌برازش استفاده می‌شود، اما در مرحله آزمون، دراپ آوت غیرفعال می‌گردد. در نتیجه، مدل تنها یک مقدار مشخص و قطعی برای TEC در هر زمان پیش‌بینی می‌کند. این مدل توانایی مناسبی در یادگیری الگوهای زمانی TEC دارد، اما به‌دلیل ماهیت قطعی خود، امکان سنجش عدم قطعیت پیش‌بینی‌ها را فراهم نمی‌کند. به همین دلیل، در ادامه از رهیافت بیزی برای بهبود مدل LSTM بهره گرفته می‌شود تا علاوه بر پیش‌بینی، ارزیابی میزان اطمینان مدل نیز امکان‌پذیر باشد.

در ادامه مؤلفه‌های، W_t و b_t را با استفاده از رهیافت بیزی بهینه می‌کنیم. در مدل‌های LSTM ، وزن‌ها (W_t) و اریبی‌ها (b_t) با استفاده از توزیع‌های پیشین مدل‌سازی می‌شوند. این رهیافت عدم قطعیت‌ها را در پارامترها در نظر می‌گیرد و برازش‌ها را بهینه می‌کند. وزن‌ها و اریبی‌ها دارای توزیع نرمال به صورت $W_t \sim \mathcal{N}(\mu_0, \sigma^2)$ و $b_t \sim \mathcal{N}(\mu_0, \sigma^2)$ است که در آن، μ_0 میانگین اولیه‌ی پیشین است که انتظار اولیه برای مقدار وزن‌ها و اریبی‌ها را نشان می‌دهد و σ^2 واریانس پیشین است که میزان عدم قطعیت در پارامترها را مشخص می‌کند. در مدل LSTM ، تنظیم اریبی برای بهینه‌سازی عملکرد مدل بسیار مهم است. همچنین، برای بهبود توانایی تعمیم‌پذیری مدل و جلوگیری از بیش‌برازش، از تکنیک دراپ آوت استفاده می‌شود. برای افزایش اعتمادپذیری مدل و لحاظکردن عدم قطعیت در پیش‌بینی‌ها، از ساختار بیزی در قالب شبکه عصبی LSTM استفاده می‌شود. در این ساختار، با بهره‌گیری از روش‌های مونت کارلویی[11] ، لایه‌های دراپ آوت نه‌تنها در زمان آموزش بلکه در مرحله‌ی آزمون نیز فعال باقی می‌مانند. نمونه‌های تصادفی مونت کارلویی امکان برآورد توزیع پسین را فراهم می‌سازد. با نمونه‌گیری چندباره از مدل، می‌توان میانگین پیش‌بینی‌ها و انحراف معیار آن‌ها را محاسبه کرد. تابع زیان در مدل LSTM به‌صورت $\mathcal{O}_t^{\text{dropout}} = \frac{1}{N}\sum_{i=1}^{N}\mathcal{L}(y_i, O_t) + \lambda \sum_{j=1}^{L}\left(\|W_t\|^2 + \|b_t\|^2\right)$ تعریف می‌شود، که شامل دو بخش است. بخش اول، میانگین خطای پیش‌بینی را محاسبه می‌کند، که با استفاده از تابع $\mathcal{L}$ اختلاف بین مقادیر واقعی (y_i) و پیش‌بینی‌های مدل (O_t) را اندازه‌گیری می‌کند. بخش دوم، یک عبارت تنظیم‌گر[12] است که با مجموع مربعات وزن‌ها (W) و اریبی‌ها (b) و ضرب آن در پارامتر λ از بیش‌برازش جلوگیری می‌کند.

طبق هستی و همکاران (۲۰۰۹)، برآوردگر ماکسیمم درست‌نمایی برای وزن‌ها (W_t) با بیهنه کردن تابع زیان به‌دست می‌آید. این رویکرد تعادلی مناسب بین دقت پیش‌بینی و جلوگیری از بیش‌برازش برقرار می‌کند و به بهبود عملکرد و تعمیم‌پذیری مدل کمک می‌نماید.

در رهیافت بیزی امکان به دست آوردن توزیع احتمالی مشاهدات پیش‌بینی‌شده را فراهم می‌کند. تابع درست‌نمایی به‌صورت زیر تعریف می‌شود:

$$p(y \mid X, W, \sigma^2) \propto \frac{1}{\sqrt[n/2]{\sigma^2}} e^{-\frac{1}{2\sigma^2}\left((y-XW)^T(y-XW)\right)}.$$

این فرمول احتمال اینکه بردار خروجی y از داده‌های ورودی X و پارامترهای مدل W تولید شده باشد را نشان می‌دهد. که در آن، $(y-XW)^T(y-XW)$ مجموع مربعات خطاها (SSE)[13] است که اختلاف بین مقادیر واقعی y و مقادیر پیش‌بینی‌شده XW را اندازه‌گیری می‌کند. در مدل بیزی، از توزیع پیشین مزدوج برای پارامترها استفاده می‌شود. توزیع پیشین به‌صورت $p(W, \sigma^2) = p(\sigma^2)\, p(W \mid \sigma^2)$ می‌باشد. درآن صورت توزیع پسین به‌صورت $p(W, \sigma^2 \mid y, X) \propto p(y \mid X, W, \sigma^2)\, p(W \mid \sigma^2)\, p(\sigma^2)$

[10] Dropout
[11] Monte Carlo Dropout
[12] Regularization
[13] sum squares errors

تعریف می‌شود. توزیع پسین پارامترهای مدل به‌صورت

$$p(W,\sigma^2 \mid y,X) \propto \frac{1}{\sqrt[n/2]{\sigma^2}} e^{-\frac{1}{2\sigma^2}(y-XW)^T(y-XW)} \times (\sigma^2)^{-(n-v)/2} e^{-\frac{1}{2\sigma^2}(W-\mu_0)^T\Lambda_0(W-\mu_0)} \times (\sigma^2)^{-(\alpha_0-1)} e^{-\frac{b_0}{\sigma^2}}$$

به دست می‌آید. که در آن $(\sigma^2)^{-(n-v)/2} e^{-\frac{1}{2\sigma^2}(W-\mu_0)^T\Lambda_0(W-\mu_0)}$ توزیع پیشین وزن‌ها را با میانگین μ_0 و ماتریس دقت Λ_0 مشخص می‌کند و $(\sigma^2)^{-(\alpha_0-1)} e^{-\frac{b_0}{\sigma^2}}$ توزیع پیشین واریانس را با پارامترهای α_0 و β_0 مدل‌سازی می‌کند. ماتریس ریج $\Lambda_0 = cI$ نقشی کلیدی در تنظیم مدل و حل مشکل چندخطی‌بودن دارد. با اضافه کردن این ماتریس به X^TX، ماتریس معکوس‌پذیر شده و از بیش‌برازش جلوگیری می‌کند. پارامتر c شدت تنظیم را کنترل می‌کند؛ هرچه c بزرگتر باشد، تأثیر پیشین قوی‌تر است. میانگین پسین μ_n با فرمول $\mu_n = (X^TX + \Lambda_0)^{-1}(X^Ty\hat{w} + \Lambda_0\mu_0)$ محاسبه می‌شود که ترکیبی از اطلاعات داده‌ها و باورهای پیشین است. به‌روزرسانی پارامترهای بیزی شامل محاسبه $\Lambda_n = X^TX + \Lambda_0$ و $a_n = a_0 + \frac{n}{2}$ است. همچنین، W_t با فرمول $W_t = W_0 + \frac{1}{2}(y^Ty + \mu_0^T\Lambda_0\mu_0 - \mu_n^T\Lambda_n\mu_n)$ به‌روزرسانی می‌شود. بنابراین توزیع پیشگویی نهایی به‌صورت

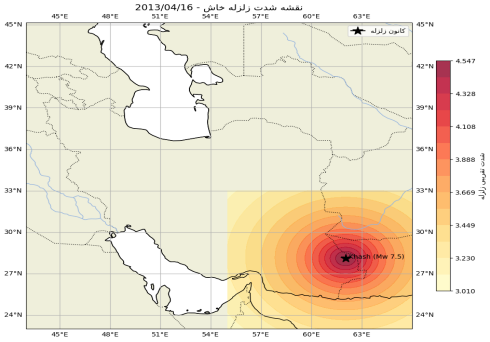
$$p(y \mid m) = \frac{p(m) \times p(y \mid X,W,\sigma,m)}{p(W,\sigma \mid y,X,m)}$$

محاسبه می‌شود. این فرمول بر اساس قانون بیز، توزیع پیشگویی $p(y \mid m)$ را به عنوان نسبت درست‌نمایی $p(y \mid X,W,\sigma,m)$ و توزیع پیشین $p(m)$ به توزیع پسین پارامترها $p(W,\sigma \mid y,X,m)$ محاسبه می‌کند. پیش‌بینی نهایی دارای توزیع نرمال است که نه تنها یک مقدار نقطه‌ای، بلکه یک بازه اطمینان برای مقدار خروجی ارائه می‌دهد. این بازه اطمینان، عدم قطعیت‌های موجود در برآورد پارامترها و نویز مدل را در نظر می‌گیرد و به کاربر امکان می‌دهد تا درک بهتری از محدوده احتمالی مقادیر پیش‌بینی‌شده داشته باشد. در نتیجه، LSTM بیزی نه‌تنها پیش‌بینی عددی ارائه می‌دهد، بلکه بازه‌ی اطمینان برای آن پیش‌بینی را نیز مشخص می‌کند. این ویژگی برای تحلیل پیش‌نشانگرهای زلزله که با عدم قطعیت‌های طبیعی همراه‌اند، اهمیت ویژه‌ای دارد.

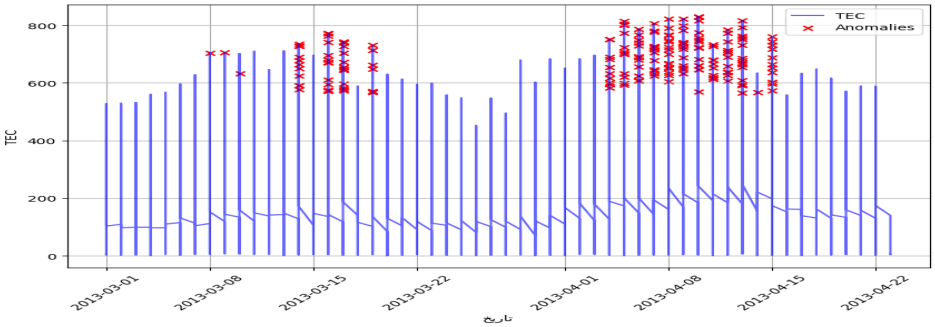
۳ تحلیل داده‌های زلزله خاش

برای مطالعه موردی، زلزله خاش در تاریخ ۲۷ فروردین ۱۳۹۲ انتخاب شد. پس از استخراج داده‌ها، به‌منظور تحلیل دقیق‌تر و شناسایی ناهنجاری‌ها، شاخص نمره‌گذاری استاندارد[۱۴] به صورت $Z_i = \frac{x_i - \mu}{\sigma}$ برای هر روز محاسبه شد، که در آن x_i مقدار TEC در زمان مشخص، μمیانگین و σ انحراف معیار مقادیر TEC در یک بازه‌ی زمانی مرجع است. شکل ۱ موقعیت و شدت زلزله خاش را روی نقشه کشور ایران نشان می‌دهد، این زلزله با بزرگای ۷/۵ در عمق حدود ۹۲ کیلومتری زمین به وقوع پیوست. دلیل انتخاب این زلزله، قدرت بالا، گستره تأثیر قابل توجه و ثبت دقیق آن در منابع بین‌المللی بوده است که امکان بررسی ناهنجاری‌های یونوسفری پیش از رخداد را با دقت و وضوح بیشتری فراهم می‌سازد. شکل ۲ روند تغییرات TEC را در بازه زمانی بین ابتدای مارس تا اواخر آوریل ۲۰۱۳ برای ایستگاه خاش نمایش می‌دهد. در این بازه زمانی، دو دوره‌ی پرتراکم از ناهنجاری‌ها به وضوح قابل مشاهده هستند: دوره اول: از حدود ۸ مارس تا ۱۶ مارس، که در آن تعداد قابل توجهی از مقادیر TEC از روند معمول خود فراتر رفته‌اند. دوره دوم: از حدود ۵ آوریل تا ۱۵ آوریل، که در این بازه نیز مقادیر TEC دارای پراکندگی زیاد و رفتار غیرعادی بوده‌اند. این رفتار ناهنجار ممکن است با

[14] Z-score



شکل ۱: نقشه شدت زلزله خاش



شکل ۲: نمودار TEC با نقاط ناهنجاری: مقادیر TEC با استفاده از خطوط نمایش داده شده‌اند و نقاط ناهنجار استاندارد شده با علامت ستاره مشخص شده‌اند.

پیش‌نشانگرهای ژئوفیزیکی یا ژئومغناطیسی زلزله‌ها مرتبط باشد و می‌تواند به عنوان هشدار اولیه مورد استفاده قرار می‌گیرد.

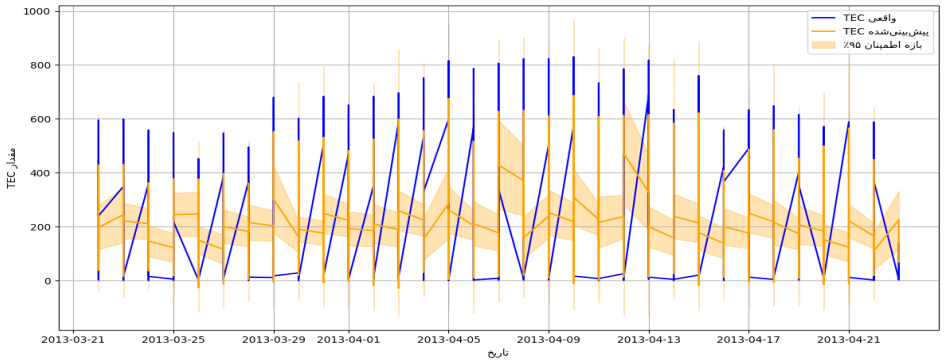
در ادامه، مدل‌های LSTM کلاسیک و بیزی روی داده‌ها اجرا و مورد ارزیابی قرار گرفت. هدف اصلی، بررسی دقت پیش‌بینی این دو مدل، ارزیابی ناهنجاری‌های احتمالی در داده‌ها پیش از رخداد زلزله و تحلیل عدم قطعیت در پیش‌بینی‌ها است. برای این منظور داده‌ها به دو بخش آموزش[۱۵] (۸۰٪) و آزمون[۱۶] (۲۰٪) تفکیک شدند. هر دو مدل روی بازه زمانی پیش از زلزله آموزش داده شدند و عملکرد آن‌ها در بازه نزدیک به وقوع زلزله (تقریباً ۴۶ روز قبل تا ۷ روز بعد از زلزله) مورد ارزیابی قرار گرفتند. معیارهای میانگین قدرمطلق خطا (MAE)[۱۷] و ریشه میانگین مربعات خطا (RMSE)[۱۸] و نرمال میانگین قدرمطلق خطا (NMAE)[۱۹] و نرمال ریشه میانگین مربعات خطا (NRMSE)[۲۰] برای ارزیابی دقت این مدل‌های به‌صورت $\text{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i - y_i)^2}$، $\text{MAE} = \frac{1}{n}\sum_{i=1}^{n}|\hat{y}_i - y_i|$، $\text{NMAE} = \frac{\text{MAE}}{\max(y_i)-\min(y_i)}$، $\text{NRMSE} = \frac{\text{RMSE}}{\max(y_i)-\min(y_i)}$ محاسبه شده‌اند، که در آن y_i داده‌های واقعی TEC و $\hat{y}_i$ مقدار پیشگویی آن است. نتایج ارزیابی مدل‌های LSTM کلاسیک و بیزی روی داده‌های خاش در جدول ۱ خلاصه شده است. نتایج جدول ۱ نشان می‌دهد که مدل LSTM قادر است تغییرات TEC را با خطای نسبتاً کنترل‌شده‌ای پیش‌بینی نماید، به‌ویژه آن‌که مقدار NMAE کمتر از ۰/۲ بوده که نشان‌دهنده پیش‌بینی قابل قبول در مقیاس تغییرات طبیعی داده‌هاست.

[15] Train
[16] Test
[17] Mean Absolute Error
[18] Root Mean Squared Error
[19] Normal Mean Absolute Error
[20] Normal Root Mean Squared Error

جدول ۱: خلاصه نتایج دو مدل LSTM کلاسیک و بیزی

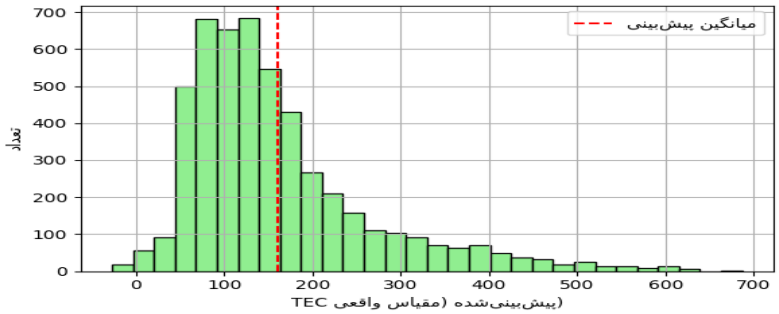
معیار	LSTM کلاسیک	LSTM بیزی
MAE	۱۳۵/۷۰	۱۳۵/۱۶
RMSE	۱۸۷/۵۰	۱۷۵/۱۷
NMAE	۰/۱۶۳۷	۰/۱۶۳۰
NRMSE	۰/۲۲۶۲	۰/۲۱۱۳

همان‌گونه که مشاهده می‌شود، هرچند دقت کلی مدل LSTM بیزی نسبت به LSTM تفاوت زیادی ندارد، اما مقدار RMSE کاهش یافته است که بیانگر کاهش اثر نمونه‌های دارای خطای بالا در مدل بیزی است.



شکل ۳: نمودار پیش‌بینی سری زمانی TEC با مدل $LSTM$ بیزی

در شکل ۳، علاوه بر مقایسه مقدار واقعی با مقدار پیش‌بینی‌شده، بازه اطمینان ۹۵٪ نیز نمایش داده شده است. مدل LSTM بیزی نه تنها پیش‌بینی را انجام می‌دهد، بلکه عدم قطعیت آن را نیز نشان می‌دهد. عرض بازه‌های اطمینان در حوالی روزهای پیش از زلزله افزایش می‌یابد، که می‌تواند نشانه‌ای از افزایش عدم اطمینان مدل و احتمال بروز ناهنجاری باشد. این ویژگی روش‌های بیزی برای تحلیل پیش‌نشانگرهای زلزله بسیار کاربردی است، زیرا به جای پیش‌بینی قطعی، بازه‌ای از پیش‌بینی‌ها ارائه می‌دهد. شکل ۴ توزیع میانگین پیش‌بینی‌ها توسط مدل بیزی را نمایش می‌دهد.توزیع به‌صورت نامتقارن و حول مقدار میانگین متمرکز



شکل ۴: نمودار هیستوگرام پیشبینی مدل $LSTM$ بیزی

است، اما نسبت به هیستوگرام LSTM، پراکندگی کمتری دارد که باعث دقت پیشگویی در مدل بیزی است. این نامتقارنی می‌تواند

بازتاب‌دهنده ناپایداری یا تنش در لایه یونوسفر باشد. مدل LSTM بیزی دقت نسبتا بالاتری در پیش‌بینی دارد و مهم‌تر از آن، با ارائه بازه اطمینان، قدرت تحلیل ناهنجاری‌های ساختاری در داده را فراهم می‌آورد. به‌ویژه در نواحی زمانی پیش از زلزله، افزایش عرض بازه اطمینان می‌تواند به عنوان شاخصی برای شناسایی ناهنجاری در لایه یونوسفر در نظر گرفته شود.

بحث و نتیجه‌گیری

در این مقاله با استفاده از مدل سری‌زمانی LSTM کلاسیک و بیزی با شاخص نمره‌گذاری استاندارد، ناهنجاری‌های احتمالی در داده‌های TEC استخراج‌شده از فایل‌های یونکس شناسایی گردید. این ناهنجاری‌ها عمدتاً به‌صورت خوشه‌ای و در بازه‌های زمانی مشخصی پیش از وقوع برخی زلزله‌ها ظاهر شدند که می‌توانند به‌عنوان نشانه‌هایی از پیش‌نشانگرهای یونوسفری تفسیر شوند. در ادامه، به‌منظور بررسی و مدل‌کردن رفتار زمانی این ناهنجاری‌ها، از دو مدل یادگیری عمیق شامل LSTM کلاسیک و LSTM بیزی با مرزهای عدم‌قطعیت استفاده شد. نتایج این مدل‌ها نشان داد که مدل بیزی علاوه بر ارائه دقت قابل‌قبول، قابلیت نمایش عدم‌قطعیت پیش‌بینی‌ها را نیز داراست که در تحلیل داده‌های حساس و پرنوسان مانند TEC بسیار ارزشمند است. با توجه به این یافته‌ها، پیشنهاد می‌شود در مطالعات آتی مدل‌های پیشرفته‌تر بیزی، گراف‌پایه به‌کار گرفته شود تا همبستگی دقیق‌تری بین ناهنجاری‌های TEC مشخص گردد و گامی مؤثر در راستای توسعه سامانه‌های هشدار زلزله برداشته شود.

مراجع

Chen J., Zhang X., Ren X., Zhang J., Freeshah M., Zhao Z. (2020), Ionospheric disturbances detected during a typhoon based on GNSS phase observations: A case study for typhoon Mangkhut over Hong Kong, *Adv. Space Res.*, **66**, 1743–1753.

Freeshah M., Adil M.A., Sentürk E., Zhang X., Ren X., Liu H., Osama N. (2024a), A cyclone formation, eastward plume drag, ionhydration process, and the consequent ionospheric changes following the 2022 Hunga Tonga-Hunga Ha'apai volcanic eruption, *Advances in Space Research*, **73** (5), 2457–2470.

Hastie, T., Tibshirani, R., Friedman, J. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer.

Saqib, M., Sentürk, E., Adil, M.A., Freeshah, M. (2024). Seismo-ionospheric precursory detection using hybrid Bayesian-LSTM network model with uncertainty-boundaries and anomaly-intensity. *Advances in Space Research*, 74, 1828–1842.

Bayesian Neural Network Temporal Processes Modeling for Earthquake Precursors Identification Using Ionospheric Anomalies of Khash Earthquake”

Mohadeseh Keykavosi, Fatemeh Hoseini, Omid Karimi

Department of statistics, Semnan University

Abstract: Long-short term memory time series processes are employed to model past-dependent data, capable of retaining information from past times for extended periods. By leveraging neural networks and Bayesian methods, the temporal trends of ionospheric anomalies can be identified and analyzed. The analysis of ionospheric anomalies aids in detecting earthquake occurrences using aftershocks. In this paper, long-term memory models, both classical and Bayesian, are utilized to analyze and predict the temporal trends of anomalies related to the 2013 Khash earthquake. The results demonstrate that the proposed model has a suitable capability in identifying hidden ionospheric patterns before earthquakes and can be used as an effective tool in analyzing seismic precursors.

Keywords: Temporal Processes, Bayesian Neural Networks, Long- Short term Memory, Khash Earthquake.
Mathematics Subject Classification (2020): 62J12، 62H11، 65K10.
