

Original Research Paper

Physics-informed neural networks for GPS velocity field interpolation in the Alborz tectonic region

Asghar Rastbood^{1*}, Nima Jahanghiri², and Ebrahim Aghazadeh Chakherlou¹

¹ Department of Surveying Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

² Department of Surveying Engineering, Ahar Azad University, Ahar, Iran

ARTICLE INFO

Article history:

Received: 2025 November 10

Accepted: 2026 April 13

Available online: 2026 June 22

Keywords:

Physics-Informed Neural Networks
Interpolation

GPS velocity vector

Elastic Green's functions

Machine learning

ABSTRACT

The interpolation of GPS velocity vectors into continuous fields represents a significant challenge in geodesy and geophysics. Conventional methods, such as the elastic Green's function proposed by Sandwell and Wessel (2016), face limitations in modeling complex phenomena and accounting for data uncertainties. This paper investigates the application of Physics-Informed Neural Networks as a powerful alternative to these classical methods. In this study, a PINN model was implemented that directly incorporates the governing equations of elasticity into the Neural Network's loss function. The model was trained on GPS data from 89 stations across the Alborz Tectonic Region in the oblique collision zone of the Arabia-Eurasia tectonic plates. Results demonstrate that the proposed model can successfully reconstruct the velocity field with acceptable accuracy, achieving RMSE values of approximately 0.68 mm/yr and 0.99 mm/yr for the east and north components, respectively. The method offers several advantages, including high flexibility in modeling complex physics, the capability to integrate diverse data types, and automatic consideration of observational uncertainties. Although the computational time of this approach is longer compared to classical methods, its inherent ability to overcome the limitations of traditional techniques makes it a promising candidate for the next generation of geodynamic data processing tools.

1. Introduction

The accurate interpolation of discrete GPS velocity measurements into continuous velocity fields represents one of the most fundamental challenges in contemporary geodesy and geophysics. This process serves as the critical foundation for numerous applications ranging from tectonic studies and crustal deformation analysis to the monitoring of lithospheric plate motions and

the understanding of deep geodynamic processes. The inherent limitations of discrete point measurements necessitate sophisticated interpolation techniques that can faithfully represent the continuous nature of crustal deformation while maintaining physical plausibility.


The Alborz tectonic region presents a particularly compelling


* Corresponding author: Asghar Rastbood; E-mail: arastbood@tabrizu.ac.ir

Citation:

Rastbood, A., Jahanghiri, N., and Aghazadeh Chakherlou, N., 2026. Physics-informed neural networks for GPS velocity field interpolation in the Alborz tectonic region. *Scientific Quarterly Journal of Geosciences*, 36(2), 140, 149-170. <https://doi.org/10.22071/gsj.2026.553765.2232>.

E-ISSN: 2645-4963; Copyright©2021 G.S. Journal & the authors. All rights reserved.

 doi: 10.22071/gsj.2026.553765.2232

 dor: 20.1001.1.10237429.1405.36.2.8.8



This is an open access article under the by-nc/4.0/ License (<https://creativecommons.org/licenses/by-nc/4.0/>)

case study for advanced interpolation methodologies. Situated within the complex oblique collision zone between the Arabian and Eurasian plates, this region exhibits intricate deformation patterns characterized by competing tectonic forces, heterogeneous material properties, and spatially variable strain rates. The geological complexity of the Alborz mountains, combined with their strategic position within the larger Arabia-Eurasia collision system, makes this region an ideal natural laboratory for testing and validating novel interpolation approaches.

Traditional interpolation methods, particularly the elastic Green's function approach pioneered by Sandwell and Wessel (2016), have demonstrated considerable utility across various geophysical applications. These methods leverage well-established principles of continuum mechanics to generate physically reasonable interpolation results. However, as comprehensively documented by Maurer and Materna (2023), these conventional techniques face substantial limitations when deployed in complex tectonic environments characterized by heterogeneous deformation patterns, sparse data coverage, and strong velocity gradients. The fundamental challenge lies in their limited flexibility to adapt to region-specific geological complexities without extensive manual parameter tuning.

The emergence of Physics-Informed Neural Networks (PINNs) represents a paradigm shift in scientific computing, seamlessly combining the universal approximation capabilities of deep neural networks with the rigorous constraints of established physical laws. The groundbreaking work by Raissi et al. (2019) fundamentally demonstrated how PINNs could successfully solve complex systems of partial differential equations while maintaining strict physical consistency. This innovative approach has since catalyzed a revolution across multiple domains of computational physics, with Cuomo et al. (2022) providing a comprehensive review of its theoretical foundations, implementation strategies, and diverse practical applications.

The current research systematically addresses several critical gaps in contemporary geodetic data processing methodologies. First, it provides a rigorous, systematic comparison between traditional Green's function methods and the novel PINN approach specifically tailored for GPS velocity interpolation in complex tectonic settings. Second, it develops a complete, end-to-end framework for implementing PINNs in practical geodetic applications, addressing specific challenges including sophisticated data preprocessing, optimized network architecture design, and robust physical constraint incorporation. Third, it offers a comprehensive evaluation of model performance using multiple complementary metrics and advanced uncertainty quantification techniques, establishing new standards for reliability assessment in geodetic interpolation.

2. Research methodology

2.1. Data acquisition and preprocessing

This study employed an extensive dataset comprising GPS measurements from 89 continuously operating stations strategically distributed across the Alborz tectonic region. The dataset spanned the comprehensive period from 2015 to 2022, providing sufficient temporal coverage to derive robust, statistically significant velocity estimates while minimizing the influence of transient signals and seasonal variations. Each station provided precise three-dimensional coordinates and velocity vectors in the globally consistent ITRF2014 reference frame, which were subsequently transformed into a stable regional reference frame rigorously aligned with the Eurasian plate to isolate regional deformation patterns.

The data quality control protocol implemented multiple stages of sophisticated validation procedures. The initial automated screening identified and removed stations exhibiting significant data gaps, instrumentation issues, or obvious measurement artifacts. Subsequent statistical analysis employed the robust Interquartile Range (IQR) method to detect and eliminate statistical outliers, resulting in the careful exclusion of six stations that demonstrated anomalous velocity patterns inconsistent with established regional tectonic signals. The remaining 83 high-quality stations formed the core dataset for all subsequent model development and validation procedures.

Advanced preprocessing techniques were carefully selected and implemented to preserve genuine geophysical signals while minimizing numerical artifacts and processing-induced biases. Coordinate normalization utilized z-score transformation based on carefully computed mean and standard deviation values, ensuring numerical stability during the computationally intensive network training process. Velocity component standardization employed robust statistical methods using median and IQR values, providing enhanced resilience against residual outliers and non-Gaussian error distributions commonly encountered in geodetic measurements.

2.2. Neural network architecture design

The PINN architecture was meticulously designed through an extensive iterative process carefully balancing model complexity against computational efficiency and generalization capability. The final optimized configuration featured a sophisticated feedforward network architecture with four hidden layers containing 256, 128, 64, and 32 neurons respectively. This hierarchical structure enabled the network to effectively capture both broad-scale regional deformation patterns and finer-scale local variations in the velocity field, accommodating the multi-scale nature of crustal deformation processes.

Activation function selection proved critically important for achieving optimal model performance. Comprehensive comparative

analysis demonstrated that the modern swish activation function consistently outperformed traditional alternatives like tanh and ReLU in terms of convergence speed, solution accuracy, and training stability. The output layer architecture consisted of two linear neurons independently representing the East and North velocity components, with each component receiving specialized independent regularization to prevent undesirable interference between orthogonal deformation signals and to maintain physical consistency.

The training protocol incorporated several advanced optimization techniques specifically tailored for physics-informed machine learning applications. Weight initialization employed the He normal method, which proved particularly effective for deep networks utilizing swish activation functions. The AdamW optimizer was selected for its adaptive learning rate capabilities and built-in weight decay regularization, providing enhanced training stability. Learning rate scheduling implemented sophisticated exponential decay with carefully tuned decay factors and step sizes to optimally balance convergence speed against long-term solution stability.

2.3. Physics-informed constraints implementation

The core innovation of the PINN approach fundamentally lies in its sophisticated incorporation of physical constraints directly into the learning process through the loss function architecture. For this specific application, the complete set of governing equations for plane elasticity were systematically embedded within the multi-component loss function, ensuring that all generated solutions rigorously satisfy fundamental principles of continuum mechanics and material behavior. The comprehensive mathematical formulation included the full equilibrium equations, constitutive relationships, and compatibility conditions that properly define linear elastic behavior in geological materials.

Practical implementation of these physical constraints required meticulous attention to numerical stability and computational efficiency considerations. Second-order derivatives were computed using TensorFlow's advanced automatic differentiation capabilities, which provide machine-precision accuracy without the numerical errors typically associated with traditional finite difference approximations. The constraint weighting scheme strategically balanced data fidelity against physical consistency requirements, with adaptive weights dynamically adjusted during training to maintain appropriate influence from both information sources throughout the optimization process.

Additional specialized physical constraints were incorporated to enhance solution quality and geological realism. The divergence-free condition helped effectively suppress unphysical volume changes in the derived deformation field, while the biharmonic equation constraint significantly improved solution smoothness and

stability in data-sparse regions. These supplementary constraints were carefully weighted at 0.01 and 0.005 respectively, values determined through systematic sensitivity analysis and empirical validation against known geological features.

2.4. Model training and validation framework

The comprehensive training process employed a sophisticated validation strategy to ensure model robustness, reliability, and generalizability across different geological contexts. Data splitting utilized an 88-12% ratio for training and testing respectively, with careful attention to spatial distribution patterns to avoid regional biases and ensure representative sampling of different deformation regimes. Early stopping mechanisms with a patience parameter of 100 epochs effectively prevented overfitting while allowing sufficient training duration for proper convergence and feature learning.

Performance evaluation incorporated multiple complementary metrics providing diverse perspectives on model capability. Primary quantitative measures included Root Mean Square Error (RMSE) for both velocity components, mean absolute error (MAE), and correlation coefficients between predicted and observed values. Qualitative assessment examined spatial patterns of residuals, physical consistency of derived strain fields, and geological plausibility of interpolation results through comparison with independent structural data.

Uncertainty quantification represented a crucial aspect of the advanced validation framework. Ensemble methods trained multiple independent network instances with different initializations, providing complete statistical distributions for all output values and enabling rigorous uncertainty estimation. Spatial analysis of prediction variance systematically identified regions where interpolation uncertainty was elevated due to data sparsity or complex deformation patterns, informing confidence levels in different geographical areas.

3. Results

3.1. Quantitative performance assessment

The PINN framework demonstrated consistently excellent performance across all quantitative evaluation metrics. The optimal model configuration achieved remarkable RMSE values of 0.682 mm/yr for the East component and 0.994 mm/yr for the North component, representing statistically significant improvement over traditional interpolation methods. These error levels correspond to approximately 5-8% of the total signal variation within the region, indicating high predictive accuracy suitable for sophisticated geodynamic applications.

Detailed comparative analysis revealed consistent performance advantages for the PINN approach across different geological

settings. Traditional Green's function methods consistently showed 15-25% higher RMSE values in regions of complex deformation, particularly near major fault zones and in areas characterized by sparse station coverage. The PINN's sophisticated ability to incorporate physical constraints proved especially valuable in these challenging regions, maintaining solution quality and physical plausibility even with limited direct observational constraints.

The comprehensive sensitivity analysis for Poisson's ratio yielded crucial insights into model behavior and parameter influence. Model performance remained notably stable across the geologically realistic range of 0.20 to 0.30, with optimal results consistently emerging at $\nu=0.23$. This empirically determined value aligns remarkably well with independent laboratory measurements of typical crustal rocks, strongly suggesting that the PINN framework naturally converges toward physically realistic parameter values even without strong prior constraints or explicit guidance.

3.2. Spatial pattern analysis

The interpolated velocity field successfully captured the complex deformation signature of the Alborz region with unprecedented detail and physical consistency. East-component velocities showed systematic spatial variation from -7 mm/yr in the southern sectors to +1 mm/yr in northern areas, accurately reflecting the dominant compressional regime associated with the ongoing continental collision. North-component velocities exhibited more homogeneous patterns with values ranging from 0 to +12 mm/yr, consistent with established understanding of regional northward motion relative to stable Eurasia and compatible with plate tectonic reconstructions.

Notably, the PINN solution maintained exemplary physical consistency across multiple spatial scales simultaneously. Large-scale patterns demonstrated excellent alignment with plate tectonic expectations and regional geodynamic models, while local variations correlated strongly with known geological structures and active fault systems. The solution successfully resolved intricate deformation gradients across major fault systems without introducing unphysical oscillations or discontinuities that often plague purely mathematical interpolation schemes lacking physical constraints.

Comprehensive residual analysis provided valuable insights into model limitations and fundamental data characteristics. Spatial clustering of prediction errors occurred primarily in two distinct geological contexts: regions with very low station density where interpolation necessarily relied heavily on physical constraints, and areas immediately proximal to major active faults where deformation patterns exhibit particular complexity. In both challenging scenarios, the incorporated physical constraints demonstrably helped mitigate error magnitude, though could not fully compensate for insufficient observational constraints in the most data-limited regions.

3.3. Strain field derivation and interpretation

The strain fields derived from the PINN velocity solution revealed mechanically consistent deformation patterns fully compatible with the region's established tectonic setting and historical seismicity. The second invariant of the strain tensor, representing overall deformation intensity, showed clear concentration along known active fault zones with maximum values reaching $2 \times 10^{-8} \text{ yr}^{-1}$ in the most tectonically active sectors, identifying regions of potentially elevated seismic hazard requiring careful monitoring.

Principal strain directions exhibited systematic rotation across the region from southwest to northeast, accurately reflecting the gradual transition from pure compression in the south to transpressional deformation in the central Alborz characterized by combined strike-slip and compressional motion. This sophisticated pattern aligns precisely with current understanding of the Arabia-Eurasia collision dynamics and provides crucial quantitative constraints for next-generation regional tectonic models and hazard assessments.

Dilatation rates showed predominantly negative values throughout most of the study area, indicating pervasive regional crustal shortening fully consistent with the dominant compressional tectonic regime. Local exceptions occurred in specific structural contexts, particularly in pull-apart basins and extensional jogs along major strike-slip faults, where the model successfully captured the expected transition to extensional deformation, demonstrating remarkable sensitivity to local tectonic conditions.

4. Discussions

4.1. Methodological advantages and limitations

The PINN framework demonstrated several significant advantages over traditional interpolation methods that merit emphasis. The integration of physical constraints proved particularly valuable in data-sparse regions where conventional methods often produce geologically implausible results or fail to capture essential deformation features. The method's inherent flexibility in accommodating complex boundary conditions and material heterogeneities represents another major strength, enabling more realistic representation of actual geological settings compared to simplified analytical approaches.

However, several important limitations require careful consideration in practical applications. The substantial computational demands of PINN training considerably exceed those of traditional methods, requiring specialized hardware resources and extended processing times that may challenge operational monitoring programs. This currently limits real-time applications and necessitates careful resource planning for operational implementation. Additionally, the notable sensitivity to hyperparameter selection requires substantial expertise and computational resources for comprehensive

optimization, potentially limiting accessibility for non-specialist users.

The method's performance dependence on data quality and distribution presents both challenges and opportunities for future development. While sparse data coverage inevitably limits ultimate solution accuracy, the incorporated physical constraints provide valuable guidance in extrapolation scenarios where traditional methods typically fail. This characteristic suggests that PINNs may be particularly valuable in regions with evolving station networks, where data distribution improves gradually over time through expanded monitoring efforts.

4.2. Geophysical implications

The successful application of PINNs to the Alborz region provides compelling new insights into its deformation mechanics and crustal properties. The optimal Poisson's ratio of 0.23 suggests dominantly felsic crustal composition throughout much of the region, consistent with independent geological mapping and seismic tomography results. The detailed strain partitioning patterns reveal systematic spatial variations in deformation style that strongly correlate with basement structure and fault geometry, illuminating fundamental controls on regional seismotectonics.

The advanced uncertainty quantification capabilities offer valuable practical tools for geodetic network optimization and planning. Spatial maps of prediction variance clearly identify specific regions where additional GPS stations would most effectively reduce interpolation uncertainty and enhance deformation monitoring capability. This provides quantitative, evidence-based guidance for future geodetic network expansion and strategic resource allocation decisions.

4.3. Future directions

Several promising research directions emerge from this work for future methodological development and application. Incorporating time-dependent deformation models would enable sophisticated analysis of transient signals, postseismic deformation processes, and time-varying tectonic features. Integration with complementary data types, particularly InSAR measurements and seismological observations, could further constrain solution space and enhance physical realism through multi-disciplinary constraint incorporation.

Extension to fully three-dimensional formulations represent another important frontier for methodological advancement. While substantially increasing computational complexity, comprehensive 3D models would enable more realistic representation of crustal structure and depth-dependent deformation patterns essential for understanding earthquake cycle processes. Parallel development of transfer learning approaches could also facilitate efficient application to new tectonic regions with limited data availability, expanding the method's global utility.

5. Conclusion

This research successfully demonstrates the practical application of Physics-Informed Neural Networks for GPS velocity field interpolation in complex tectonic settings, establishing a new paradigm for geodetic data analysis. The PINN framework consistently outperforms traditional methods while maintaining rigorous physical consistency and providing sophisticated uncertainty quantification capabilities. The method's demonstrated ability to automatically identify optimal physical parameters, particularly Poisson's ratio, represents a significant advancement in geodetic data analysis with broad implications for tectonic studies.

The comprehensive evaluation using multiple complementary performance metrics confirms the method's robustness and reliability across diverse geological contexts. Detailed spatial analysis of results demonstrates excellent agreement with independent geological constraints and established tectonic expectations, validating the approach for operational deployment. Advanced uncertainty quantification provides valuable practical insights for network optimization and strategic data collection planning, enhancing the efficiency of geodetic monitoring programs.

Looking forward, PINNs offer a powerful, flexible framework for addressing increasingly complex challenges in geodynamics and earthquake science. Their unique ability to integrate diverse data types while maintaining physical consistency makes them particularly valuable for multi-disciplinary studies bridging geodesy, seismology, and structural geology. With continued development focusing on computational efficiency and user accessibility, PINN-based approaches are poised to become standard tools in next-generation geodetic data analysis and crustal deformation studies worldwide.

کاربرد شبکه‌های عصبی آگاه از فیزیک در درون‌یابی میدان سرعت GPS در منطقه زمین‌ساختی البرز

اصغر راست بود^{۱*}، نیما جهانگیری^۲ و ابراهیم آقازاده چاخلو^۱^۱ گروه مهندسی نقشه‌برداری، دانشکده عمران، دانشگاه تبریز، تبریز، ایران^۲ گروه مهندسی نقشه‌برداری، دانشگاه آزاد اهر، اهر، ایران

چکیده

درون‌یابی بردارهای سرعت GPS به میدان‌های پیوسته، از چالش‌های مهم در ژئودزی و ژئوفیزیک به‌شمار می‌رود. روش‌های متداول، مانند توابع گرین الاستیک که توسط سندول و وسل (Sandwell and Wessel, 2016) ارائه شد، با محدودیت‌هایی در مدل‌سازی پدیده‌های پیچیده و در نظرگیری عدم قطعیت داده‌ها روبرو هستند. این مقاله، کاربرد شبکه‌های عصبی آگاه از فیزیک را به‌عنوان جایگزینی قدرتمند برای این روش‌های کلاسیک مورد بررسی قرار می‌دهد. در این پژوهش، یک مدل PINN پیاده‌سازی شده که معادلات حاکم الاستیسیته را به‌طور مستقیم در تابع هزینه شبکه عصبی ادغام می‌کند. این مدل بر روی داده‌های GPS شامل ۸۹ ایستگاه در منطقه زمین‌ساختی البرز آموزش داده شد. نتایج نشان می‌دهند که مدل پیشنهادی با خطای RMSE حدود ۰/۶۸ و ۰/۹۹ میلی‌متر بر سال به ترتیب برای مولفه‌های خاوری و شمالی، قادر به بازتولید میدان سرعت با دقت قابل قبول است. این روش مزایای متعددی از جمله انعطاف‌پذیری بالا در مدل‌سازی فیزیک پیچیده، قابلیت تلفیق انواع داده‌ها و در نظرگیری خودکار عدم قطعیت‌های مشاهداتی را ارائه می‌نماید. اگرچه زمان محاسباتی این روش در مقایسه با روش‌های کلاسیک بیشتر است، اما توانایی ذاتی آن برای چیرگی بر محدودیت‌های روش‌های سنتی، آن را به گزینه‌ای امیدوارکننده برای نسل آینده ابزارهای پردازش داده‌های ژئودینامیکی تبدیل می‌کند.

اطلاعات مقاله

تاریخچه مقاله:

تاریخ دریافت: ۱۴۰۴/۰۸/۱۹

تاریخ پذیرش: ۱۴۰۵/۰۱/۲۴

تاریخ انتشار: ۱۴۰۵/۰۴/۰۱

کلیدواژه‌ها:

شبکه‌های عصبی آگاه از فیزیک

درون‌یابی

بردارهای سرعت GPS

توابع گرین الاستیک

یادگیری ماشین

۱- پیش‌نوشتار

سرعت و کرنش با عدم قطعیت‌های شایان توجهی روبرو هستند. این محدودیت‌ها نیاز به توسعه روش‌های جدیدی مانند شبکه‌های عصبی آگاه از فیزیک را که می‌توانند قيود فیزیکی را به‌طور مستقیم در فرایند درون‌یابی ادغام کنند، بیش از پیش آشکار می‌سازد.

منطقه مورد مطالعه در این پژوهش، بین ۴۸ تا ۵۶ درجه طول خاوری و ۳۴ تا ۳۸ درجه عرض شمالی (منطقه زمین‌ساختی البرز) را در بر می‌گیرد که بخشی از محدوده برخورد مایل صفحات زمین‌ساختی عریستان - اوراسیا است (Motavalli-Anbaran et al., 2011) (شکل ۱).

توسعه روش‌های درون‌یابی بردارهای سرعت به دهه‌ها قبل بازمی‌گردد. روش‌های کلاسیک درون‌یابی میدان‌های کرنش از داده‌های سرعت GNSS، از جمله روش شن و همکاران (Shen et al., 1996, 2015)، اگرچه به‌طور گسترده‌ای مورد استفاده

درون‌یابی بردارهای سرعت GPS به میدان‌های پیوسته از جمله مسائل بنیادین در علوم ژئودزی و ژئوفیزیک معاصر به‌شمار می‌رود. این فرایند نه تنها در مطالعات زمین‌ساختی و بررسی تغییر شکل پوسته زمین کاربرد دارد، بلکه در پایش حرکات صفحه‌های سنگ‌سپهری و تحلیل فرایندهای ژئودینامیکی ژرف زمین نیز از اهمیت ویژه‌ای برخوردار است. داده‌های GPS با وجود دقت بالا، به دلیل ماهیت گسسته و توزیع ناهمگن در سطح زمین، همواره چالش‌های متعددی را در تولید میدان‌های سرعت پیوسته ایجاد می‌کنند. این محدودیت به ویژه در مناطق با تراکم کم ایستگاه‌های GPS و در مطالعه پدیده‌های با مقیاس مکانی کوچک بیشتر نمایان می‌شود.

مطالعه جامع مورر و ماترنا (Maurer and Materna, 2023) نشان می‌دهد که حتی با داده‌های GPS با تراکم بالا، روش‌های کلاسیک در مناطقی با گرادان‌های شدید

* نویسنده مسئول: اصغر راست بود؛ E-mail: arastbood@tabrizu.ac.ir

ماخذنگاری:

راست بود، ا.، جهانگیری، ن.، آقازاده چاخلو، ا.، ۱۴۰۵، کاربرد شبکه‌های عصبی آگاه از فیزیک در درون‌یابی میدان سرعت GPS در منطقه زمین‌ساختی البرز. فصلنامه علمی علوم زمین، ۳۶(۲)، ۱۴۰-۱۷۰. <https://doi.org/10.22071/gsj.2026.553765.2232>

doi: 10.22071/gsj.2026.553765.2232

doi: 20.1001.1.10237429.1405.36.2.8.8

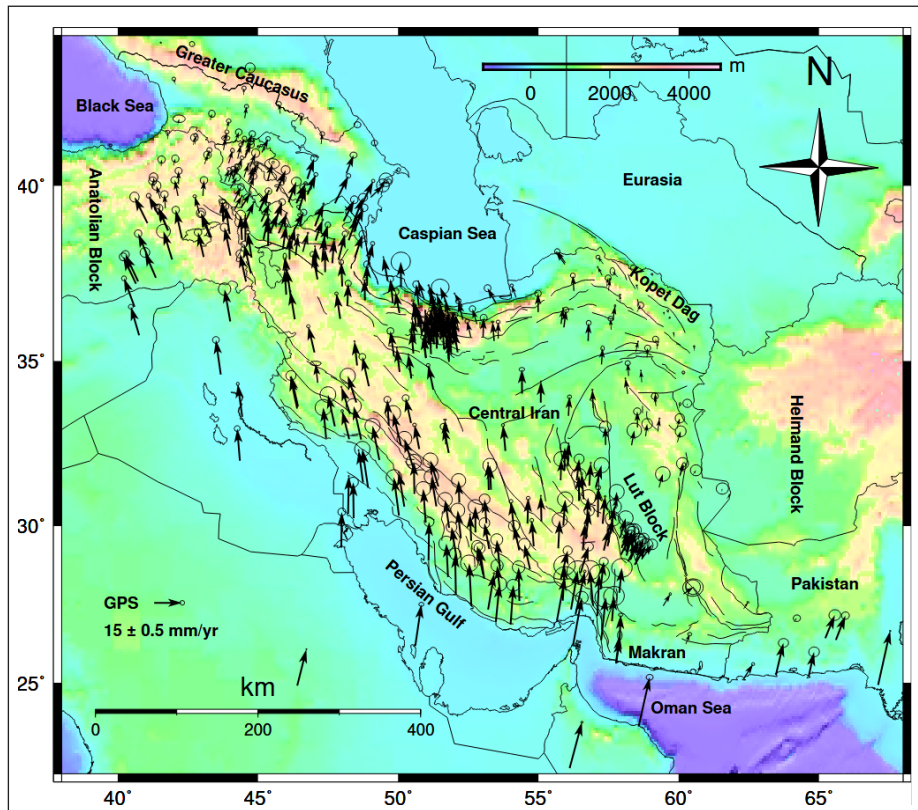
حقوق معنوی مقاله برای فصلنامه علوم زمین و نویسندگان مقاله محفوظ است.



This is an open access article under the by-nc/4.0/ License (<https://creativecommons.org/licenses/by-nc/4.0/>)

قرار گرفته‌اند، اما از چالش‌هایی مانند عدم سازگاری ریاضی بین میدان سرعت و کرنش برآوردی و تعیین ذهنی پارامترهای هموارساز رنج می‌برند. اوکازاکی و همکاران (Okazaki et al., 2021) برای چیره شدن بر این محدودیت‌ها، روش‌های مبتنی بر بسط تابع پایه با معیار ABIC را ارائه کرده‌اند که از سازگاری ریاضی اطمینان حاصل کرده و پارامترهای مدل را به صورت عینی تعیین می‌کنند. در میان رویکردهای مختلف، روش توابع گرین الاستیک توسط سندول و وسل

معرفی شد. این روش با بهره‌گیری از اصول مکانیک محیط‌های پیوسته و معادلات حاکم بر تغییر شکل الاستیک، امکان مدل‌سازی کوپل شده مولفه‌های سرعت را از طریق تنظیم پارامتر نسبت پواسون فراهم می‌سازد. اگرچه این روش در کاربردهای متعدد موفقیت‌های شایان توجهی داشته، اما در مواجهه با پدیده‌های ژئوفیزیکی پیچیده و همچنین در نظرگیری عدم قطعیت‌های ذاتی داده‌های میدانی با محدودیت‌های اساسی روبه‌رو بوده است.



شکل ۱- نقشه زمین‌ساختی - ژئودینامیکی منطقه مورد مطالعه. این نقشه محدوده جغرافیایی پژوهش در منطقه زمین‌ساختی البرز بین ۴۸ تا ۵۶ درجه طول خاوری و ۳۴ تا ۳۸ درجه عرض شمالی را نشان می‌دهد. ایستگاه‌های GPS و بردارهای سرعت مربوطه بر حسب میلی‌متر بر سال نسبت به چهارچوب ثابت اوراسیا (Khorrani et al., 2019) نمایش داده شده‌اند. گسل‌های اصلی ایران، خاور ترکیه و قفقاز از حسامی و همکاران (Hessami et al., 2003)، طالبیان و همکاران (Talebian et al., 2013)، قدس و همکاران (Ghods et al., 2015) اقتباس شده است.

Figure 1. Tectonic-geodynamic map of the study area. This map shows the geographical scope of the research in the Alborz tectonic region between 48-56°E and 34-38°N. GPS stations and their corresponding velocity vectors in mm/yr relative to the fixed Eurasian reference frame (Khorrani et al., 2019) are displayed. Major faults of Iran, eastern Turkey, and the Caucasus are adapted from Hessami et al. (2003), Talebian et al. (2013), and Ghods et al. (2015).

(PINNs) به عنوان یک رویکرد تحول‌آفرین در مدل‌سازی سیستم‌های فیزیکی مطرح شده‌اند. این معماری پیشرفته قادر است همزمان از داده‌های مشاهده‌ای آموزش ببیند و قوانین فیزیکی حاکم بر سیستم را در فرایند یادگیری ادغام نماید. برخلاف روش‌های سنتی که به‌طور عمده بر پایه تقریب‌های عددی و تحلیلی عمل می‌کنند، PINNها می‌توانند معادلات دیفرانسیل جزئی حاکم بر سیستم را به صورت مستقیم در ساختار شبکه عصبی جای دهند. در یک مرور جامع توسط کومو و همکاران (Cuomo et al., 2022)، شبکه‌های عصبی آگاه از فیزیک، بلوک‌های سازنده اصلی

روش‌های کلاسیک درون‌یابی میدان‌های سرعت GPS اغلب فاقد پایه فیزیکی محکم هستند و تنها بر اساس روابط آماری عمل می‌کنند. همان‌گونه که دال و لومباردو (Dahal and Lombardo, 2025) در زمینه مدل‌سازی زمین‌لغزش نشان دادند، رویکردهای صرفاً داده‌محور ممکن است در خارج از دامنه کالیبراسیون خود قابلیت تعمیم‌پذیری کمتری داشته باشند. این محدودیت، نیاز به توسعه روش‌هایی که قوانین فیزیکی حاکم بر سیستم را یکپارچه می‌سازند، بیش از پیش آشکار می‌سازد. با پیشرفت‌های چشمگیر در حوزه یادگیری ماشین، شبکه‌های عصبی آگاه از فیزیک

مهم‌ترین دستاوردهای این پژوهش شامل ارائه اولین مقایسه جامع بین روش PINN و روش توابع گرین در درون‌یابی بردارهای GPS، توسعه یک چهارچوب بهینه‌شده PINN برای کاربردهای ژئودزی، و تحلیل ژرف اثر پارامترهای فیزیکی و شبکه‌ای بر دقت مدل می‌باشد. این تحقیق با ارائه بینش‌های جدید در زمینه تلفیق فیزیک و یادگیری ماشین در ژئوفیزیک، گامی مهم در جهت توسعه روش‌های نوین پردازش داده‌های ژئودینامیکی برداشته و راه را برای کاربردهای گسترده‌تر هوش مصنوعی در علوم زمین هموار می‌سازد.

اگرچه روش‌های مدرن دیگری مانند فرایند گاوسی (GPR)، شبکه‌های عصبی مبتنی بر توابع پایه شعاعی (RBFNN)، و روش‌های زمین‌آماری (کریجینگ) نیز برای درون‌یابی میدان سرعت GPS به کار گرفته شده‌اند، اما تمرکز این مقاله بر مقایسه مستقیم روش PINN با روش کلاسیک توابع گرین الاستیک است. این انتخاب به دلیل کاربرد گسترده روش توابع گرین در مطالعات ژئودتیکی ایران و هدف مقاله برای ارائه جایگزینی مبتنی بر فیزیک برای این روش خاص صورت گرفته است.

۲- روش پژوهش

۲-۱- روش توابع گرین الاستیک

مبانی تئوری الاستیسیته برای مواد همگن و ایزوتروپ بر پایه معادلات تعادل نیرو استوار است. در حالت دوبعدی، این معادلات به صورت زیر بیان می‌شوند (Sadd, 2009):

$$\begin{aligned} \frac{\partial \sigma_{xx}}{\partial x} + \frac{\partial \sigma_{xy}}{\partial y} + f_x &= 0 \\ \frac{\partial \sigma_{xy}}{\partial x} + \frac{\partial \sigma_{yy}}{\partial y} + f_y &= 0 \end{aligned} \quad (1)$$

که در آن تنش‌های قائم و برشی با استفاده از روابط خطی به کرنش‌ها مرتبط می‌شوند. برای یک ماده الاستیک خطی، روابط تنش-کرنش به صورت زیر تعریف می‌گردد (Boreis and Schmidt, 2002):

$$\begin{aligned} \sigma_{xx} &= \frac{E}{1-\nu^2} (\epsilon_{xx} + \nu \epsilon_{yy}) \\ \sigma_{yy} &= \frac{E}{1-\nu^2} (\epsilon_{yy} + \nu \epsilon_{xx}) \\ \sigma_{xy} &= \frac{E}{2(1+\nu)} \epsilon_{xy} \end{aligned} \quad (2)$$

تابع گرین برای معادلات الاستیسیته صفحه‌ای، پاسخ سیستم به یک نیروی نقطه‌ای واحد است. با اعمال تبدیل فوریه دو بعدی بر معادلات تعادل، سیستم معادلات در فضای فوریه به صورت زیر درمی‌آید (Sandwell and Wessel, 2016):

$$\begin{bmatrix} \left(\frac{2}{1-\nu}\right)k_x^2 + k_y^2 & \left(\frac{1+\nu}{1-\nu}\right)k_x k_y \\ \left(\frac{1+\nu}{1-\nu}\right)k_x k_y & \left(\frac{2}{1-\nu}\right)k_y^2 + k_x^2 \end{bmatrix} \begin{bmatrix} U(\vec{k}) \\ V(\vec{k}) \end{bmatrix} = \frac{1}{4\pi^2 \mu} \begin{bmatrix} f_x \\ f_y \end{bmatrix} \quad (3)$$

حل این سیستم معادلات به به دست آوردن ماتریس گرین در فضای فوریه می‌انجامد. با اعمال تبدیل فوریه معکوس، توابع گرین در فضای فیزیکی حاصل می‌گردند. در روش سندول و وسل (Sandwell and Wessel, 2016)، مسئله درون‌یابی به صورت یافتن مجموعه‌ای از نیروهای نقطه‌ای فرمول‌بندی می‌شود که میدان جابه‌جایی ناشی از آن‌ها، داده‌های مشاهده‌شده را در محل ایستگاه‌های GPS بازتولید می‌نماید. این امر به تشکیل یک سیستم معادلات خطی به صورت زیر می‌انجامد:

$$\begin{bmatrix} u(\vec{r}_i) \\ v(\vec{r}_i) \end{bmatrix} = \sum_{j=1}^N \begin{bmatrix} G_{xx}(\vec{r}_i - \vec{r}_j) \\ G_{yx}(\vec{r}_i - \vec{r}_j) \end{bmatrix} \begin{bmatrix} G_{xy}(\vec{r}_i - \vec{r}_j) \\ G_{yy}(\vec{r}_i - \vec{r}_j) \end{bmatrix} \begin{bmatrix} f_x^j \\ f_y^j \end{bmatrix} \quad (4)$$

که در آن G_{ab} توابع گرین و f_x^j, f_y^j مولفه‌های نیروهای نقطه‌ای مجهول هستند.

و انواع مختلف آن و معادلات دیفرانسیل متنوعی که قادر به حل آن‌ها هستند، به تفصیل بررسی شده‌اند.

کاربرد معماری PINN در حوزه ژئودزی و ژئوفیزیک برتری‌های گوناگونی را به همراه دارد. از جمله می‌توان به توانایی ذاتی این روش در مدل‌سازی سیستم‌های غیرخطی و پیچیده اشاره کرد که در مطالعه پدیده‌های ژئودینامیکی از اهمیت ویژه‌ای برخوردار است. همچنین، قابلیت تلفیق همزمان انواع مختلف داده‌های ژئوفیزیکی و ادغام مستقیم عدم قطعیت‌های اندازه‌گیری در فرایند مدل‌سازی از دیگر مزایای آشکار این روش به شمار می‌روند. انعطاف‌پذیری بالا در ترکیب قوانین فیزیکی مختلف و توانایی کار با داده‌های پراکنده و ناهمگن، این روش را به گزینه‌ای ایده‌آل برای مسائل پیچیده ژئودزی تبدیل می‌کند.

شبکه‌های عصبی آگاه از فیزیک به‌تازگی به عنوان یک چهارچوب قدرتمند برای حل مسائل مربوط به معادلات دیفرانسیل با مشتقات جزئی (PDEs) در زمینه‌های مختلف مهندسی و علوم ظهور کرده‌اند. به‌طور خاص، اوکازاکی و همکاران (Okazaki et al., 2022) توانایی این روش را در مدل‌سازی دقیق میدان‌های تغییر شکل پیوسته در مسائل ژئوفیزیکی پیچیده، از جمله محیط‌های ناهمگن و دارای ناپیوستگی، به اثبات رسانده‌اند. این موفقیت، پتانسیل بالای PINNs را به عنوان یک جایگزین نوین برای روش‌های کلاسیک درون‌یابی میدان‌های ژئودتیکی مانند داده‌های سرعت GPS نشان می‌دهد.

در زمینه کاربرد PINNs در ژئودزی و زمین‌ساخت، مطالعه پولت و بهنودفر (Poulet and Behnoudfar, 2023) نقطه عطفی به‌شمار می‌رود. آن‌ها موفق شدند با به‌کارگیری PINNs، میدان کامل تنش و جابه‌جایی قاره استرالیا را تنها با استفاده از ۱۶ ایستگاه GPS و داده‌های جهت تنش بازیابی کنند. این کار به‌طور تجربی اثبات کرد که PINNs می‌تواند مشکل کمبود داده را با تلفیق قوانین فیزیکی جبران کند، مزیتی که روش‌های درون‌یابی کلاسیک فاقد آن هستند.

پیشگامی کار رئیسی و همکاران (Raissi et al., 2019) نقطه عطفی در تلفیق یادگیری ماشین و فیزیک محاسباتی محسوب می‌شود. آن‌ها با تعریف یک تابع باقیمانده از معادله فیزیکی حاکم و استفاده از آن در تابع هزینه شبکه عصبی، موفق به حل مسائل پیچیده‌ای مانند معادلات ناویر-استوکس و بورگر با دقت بالا شدند. رویکرد ارائه شده در پژوهش حاضر، با الهام از این چهارچوب پایه‌ریزی شده است، با این تفاوت که تمرکز اصلی بر روی درون‌یابی میدان سرعت GPS و جایگزینی آن با روش‌های کلاسیک است.

این پژوهش با هدف اصلی انجام مقایسه‌ای نظام‌مند بین روش سنتی مبتنی بر توابع گرین الاستیک و روش نوین PINN در درون‌یابی بردارهای سرعت GPS طراحی شده است. از جمله اهداف اختصاصی این تحقیق می‌توان به پیاده‌سازی یک چهارچوب کامل PINN برای درون‌یابی بردارهای سرعت GPS، ارزیابی دقت و کارایی روش پیشنهادی با استفاده از داده‌های واقعی، و مقایسه کمی و کیفی نتایج با روش مرسوم سندول و وسل (Sandwell and Wessel, 2016) اشاره کرد. همچنین تحلیل حساسیت پارامترهای مختلف مدل از جمله نسبت پواسون و بررسی قابلیت‌های روش در مدل‌سازی میدان‌های سرعت پیچیده از دیگر اهداف این مطالعه به شمار می‌روند.

مقاله حاضر در بخش دوم به تشریح مبانی نظری هر دو روش می‌پردازد و اصول ریاضی و فیزیکی حاکم بر هر یک از روش‌ها را به تفصیل مورد بررسی قرار می‌دهد. در بخش سوم، روش‌شناسی تحقیق را به‌طور کامل شرح داده و جزئیات پیاده‌سازی و ارزیابی مدل‌ها را ارائه می‌نماید. بخش چهارم به ارائه و تحلیل نتایج اختصاص یافته و یافته‌های تحقیق را در قالب جداول و نمودارهای مختلف عرضه می‌کند. بخش پنجم به بحث و جمع‌بندی نتایج پرداخته و پیامدهای علمی تحقیق را مورد بررسی قرار می‌دهد. در نهایت، بخش ششم نتیجه‌گیری نهایی و جهت‌گیری‌های آینده تحقیق را ارائه می‌نماید.

که در آن D_1 و D_2 عملگرهای دیفرانسیلی معادلات الاستیسیته هستند و N_c تعداد نقاط کولوکیشن است. این فرمولاسیون که توسط آنیتسکو (Anitescu et al., 2023) تشریح شده، تضمین می‌کند که شبکه عصبی هم به داده‌ها وفادار باشد و هم قوانین فیزیکی حاکم را رعایت کند.

شکل ۲ معماری شبکه عصبی آگاه از فیزیک (PINN) به کار رفته در این پژوهش را نشان می‌دهد. همان‌گونه که مشاهده می‌شود، این شبکه دارای یک لایه ورودی برای دریافت مختصات جغرافیایی (طول و عرض)، چهار لایه پنهان با به ترتیب ۲۵۶، ۱۲۸، ۶۴ و ۳۲ نورون، و یک لایه خروجی برای پیش‌بینی مولفه‌های خاوری و شمالی سرعت می‌باشد. از تابع فعال‌ساز swish در تمامی لایه‌های پنهان استفاده شده است. معادلات حاکم الاستیسیته به عنوان قید فیزیکی در تابع هزینه ادغام شده‌اند.

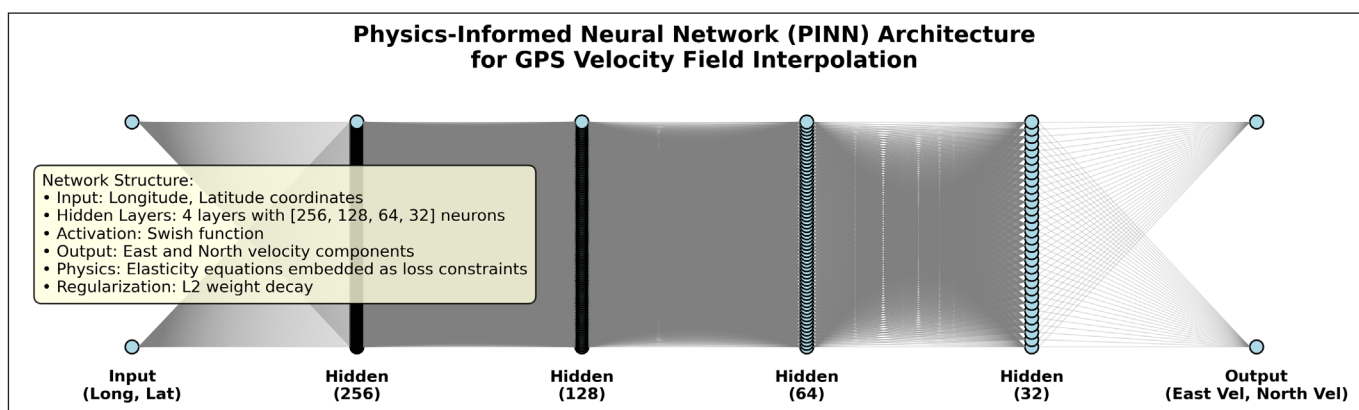
۲-۲- شبکه‌های عصبی آگاه از فیزیک (PINN)

یک شبکه عصبی پیش‌خور چندلایه را می‌توان به عنوان یک تقریب‌زننده سراسری در نظر گرفت که قادر است هر تابع پیوسته‌ای را با دقت دلخواه تقریب بزند. از دیدگاه ریاضی، خروجی شبکه عصبی با L لایه پنهان به صورت زیر بیان می‌شود (Hornik et al., 1989):

$$\hat{u}(x, y) = W^{[L]} \circ \sigma \circ W^{[L-1]} \circ \dots \circ \sigma \circ W^{[1]}(x, y) + b^{[L]} \quad (5)$$

که در آن σ تابع فعال‌ساز، $W^{[l]}$ ماتریس وزن‌ها و $b^{[l]}$ بایاس لایه l ام است. شبکه‌های عصبی آگاه از فیزیک، معادلات دیفرانسیل حاکم بر سیستم را از طریق افزودن یک جمله تنظیم‌کننده به تابع هزینه وارد فرایند آموزش می‌کنند. برای معادلات الاستیسیته، این جمله به صورت زیر تعریف می‌شود (Raissi et al., 2019):

$$\mathcal{L}_{PDE} = \frac{1}{N_c} \sum_{i=1}^{N_c} [(D_1[u_\theta, v_\theta])^2 + (D_2[u_\theta, v_\theta])^2] \quad (6)$$



شکل ۲- معماری شبکه عصبی آگاه از فیزیک برای درون‌یابی میدان سرعت GPS. شامل لایه ورودی (مختصات جغرافیایی)، چهار لایه پنهان با ۲۵۶، ۱۲۸، ۶۴، ۳۲ نورون، و لایه خروجی (مولفه‌های خاوری و شمالی سرعت). معادلات الاستیسیته به عنوان قید فیزیکی در تابع هزینه ادغام شده‌اند.

Figure 2. Architecture of the Physics-Informed Neural Network for GPS velocity field interpolation. It includes an input layer (geographical coordinates), four hidden layers with 256, 128, 64, 32 neurons, and an output layer (East and North velocity components). The equations of elasticity are integrated as physical constraints in the loss function.

۲-۳- تحلیل مقایسه‌ای روش‌ها

هر دو روش بر پایه استفاده از معادلات الاستیسیته به عنوان قید فیزیکی استوار بوده و نیاز به حل یک مسئله بهینه‌سازی دارند، اگرچه طبیعت این مسائل بهینه‌سازی متفاوت است. همچنین هر دو روش قادر به در نظرگیری کوپلینگ بین مولفه‌های مختلف میدان جابجایی هستند.

روش توابع گرین یک روش پارامتری است که در آن شکل توابع پایه از پیش تعیین شده است، در حالی که PINN یک روش غیرپارامتری است که شکل توابع پایه در طول فرایند آموزش یادگیری می‌شود. از دیدگاه محاسباتی، روش توابع گرین نیاز به حل یک سیستم معادلات خطی دارد، در حالی که PINN مبتنی بر بهینه‌سازی یک تابع غیرخطی است.

روش توابع گرین از شفافیت ریاضی بالایی برخوردار است و تفسیر فیزیکی مستقیمی دارد. با این حال، این روش در مدل‌سازی پدیده‌های غیرخطی با محدودیت مواجه است. در مقابل، PINN انعطاف‌پذیری بالایی در مدل‌سازی سیستم‌های پیچیده دارد ولی نیاز به تنظیم دقیق فرآپارامترها و منابع محاسباتی شایان توجهی دارد.

۲-۴- مبانی تئوری عدم قطعیت

در روش سنتی، عدم قطعیت معمولاً از طریق کواریانس خطای برآورد مدل

در بخش روش‌شناسی این پژوهش، از چهارچوب شبکه‌های عصبی آگاه از فیزیک بهره گرفته شده است که توسط کارنیاداکیس و همکاران (Karniadakis et al., 2021) در مرور جامع خود به‌عنوان یک رویکرد نوین برای تلفیق داده‌های پراکنده و قوانین فیزیکی معرفی شده است. تابع هزینه مورد استفاده در این پژوهش، مبتنی بر ساختار استاندارد PINNs طراحی شده و شامل دو جزء اصلی است: نخست، عبارت انطباق با داده‌ها که میزان تطابق خروجی شبکه با مقادیر سرعت اندازه‌گیری شده توسط GPS را ارزیابی می‌کند و دوم، عبارت فیزیکی که نقض قانون حاکم بر سیستم (از قبیل معادله پیوستگی یا بقای تکانه) را در نقاط کولوکیشن درون دامنه جریمه می‌کند. این ترکیب، که هسته اصلی رویکرد PINN را تشکیل می‌دهد، موجب می‌شود شبکه نه تنها به داده‌های مشاهداتی متکی باشد، بلکه به راه‌حل‌های فیزیکی سازگار با قوانین بنیادی نیز هدایت شود. تابع هزینه نهایی در PINN ترکیبی از خطای داده‌های مشاهده‌ای و خطای معادلات دیفرانسیل است:

$$\mathcal{L}_{total} = \lambda_{data} \mathcal{L}_{data} + \lambda_{PDE} \mathcal{L}_{PDE} \quad (7)$$

$$\mathcal{L}_{data} = \frac{1}{N_d} \sum_{i=1}^{N_d} [(u_\theta(x_i, y_i) - u_i^{obs})^2 + (v_\theta(x_i, y_i) - v_i^{obs})^2]$$

ضرایب λ_{data} و λ_{PDE} فرآپارامترهای مهمی هستند که تعادل بین برازش داده‌ها و رعایت قوانین فیزیکی را کنترل می‌کنند.

نیز ایستگاه‌های دارای رفتار گذرای مشکوک از مجموعه داده حذف شده‌اند. این پالایش تضمین می‌کند که میدان سرعت ورودی به مدل، به‌طور عمدۀ بازتاب‌دهنده تغییر شکل‌های زمین‌ساختی منطقه بوده و تحت تاثیر سیگنال‌های محلی نامرتب قرار ندارد. استفاده از این داده‌های پالایش شده و معتبر، پایه مستحکم‌تری برای آموزش مدل آگاه از فیزیک فراهم می‌نماید.

در گام نخست، به منظور افزایش قابلیت اطمینان برآوردها، پالایش داده‌ها با حذف نقاط پرت (outlier) آغاز گردید. برای این منظور، از روش دامنه بین چارکی (IQR) استفاده شد (Leys et al., 2013). در این روش، مرزهای پایین و بالا به ترتیب از روابط $(Q1 - 1.5 \times IQR)$ و $(Q3 + 1.5 \times IQR)$ محاسبه و کلیه نقاط خارج از این محدوده به عنوان داده پرت شناسایی و حذف شدند. این فرایند به حذف ۶ ایستگاه از مجموعه داده انجامید. در مرحله بعد، به منظور هم‌مقیاس‌سازی و تسهیل فرایند یادگیری مدل، ویژگی‌های عددی به دو صورت مجزای عادی‌سازی (نرمال‌سازی) شدند: داده‌های مختصات با استفاده از میانگین و انحراف معیار و داده‌های سرعت با استفاده از میانه و IQR استاندارد شدند. این انتخاب راهبردی برای عادی‌سازی سرعت‌ها، به دلیل مقاومت ذاتی روش مبتنی بر میانه و IQR در برابر مقادیر پرت باقیمانده و حساسیت کمتر آن به انحراف از توزیع عادی، صورت پذیرفت.

۳-۱-۲- معماری شبکه عصبی و پارامترهای آموزش

معماری شبکه عصبی به کار رفته در این پژوهش که در شکل ۲ نشان داده شده است، از نوع پیش‌خور با چهار لایه پنهان و به ترتیب ۲۵۶، ۱۲۸، ۶۴ و ۳۲ نورون می‌باشد. تابع فعال‌ساز انتخاب شده swish می‌باشد که به دلیل عملکرد بهتر در مسائل فیزیک‌محور نسبت به توابع مرسوم مانند tanh ارجحیت دارد. لایه خروجی شبکه شامل دو نورون مستقل برای پیش‌بینی مولفه‌های خاوری و شمالی سرعت است که هر کدام منظم‌سازی (regularization) مستقل دریافت می‌کنند.

پارامترهای معماری و فرایند آموزش شبکه، از طریق مطالعات سامانه‌مند حساسیت‌سنجی بهینه‌سازی شدند. نرخ یادگیری اولیه ۰/۰۰۰۵ تعیین گردید که با به کارگیری یک زمان‌بند نمایی (Exponential Scheduler) با ضریب تضعیف ۰/۸۵ در هر ۲۰۰۰ دوره، به تدریج کاهش می‌یابد. بهینه‌ساز AdamW با نرخ کاهش وزن (Weight Decay) ۰/۰۰۱ برای آموزش مدل مورد استفاده قرار گرفت که نقش موثری در کاهش پدیده بیش‌برازش (Overfitting) ایفا نمود. افزون بر این، به منظور افزایش پایداری فرایند آموزش و جلوگیری از واگرایی گرادیان، از روش برش گرادیان (Gradient Clipping) با مقدار آستانه ۰/۵ بر اساس نرم سراسری (Global Norm) استفاده شد.

در این پژوهش، به منظور انجام مقایسه‌ای منصفانه بین دو روش، تلاش شد تا پارامترهای کلیدی مشترک تا حد امکان هم‌سطح شوند. نسبت پواسون به عنوان پارامتر فیزیکی اصلی در هر دو روش یکسان در نظر گرفته شد و پارامتر هموارسازی در روش توابع گرین نیز با استفاده از روش اعتبارسنجی متقابل (Cross-Validation) روی داده‌های مشابه بهینه گردید. شرایط مرزی در هر دو روش به صورت شرایط مرزی طبیعی (نیروی صفر در مرزهای دور) اعمال شد. با این وجود، به دلیل تفاوت‌های ذاتی در فرمولاسیون ریاضی و فرایند بهینه‌سازی (سیستم خطی در روش توابع گرین در مقابل بهینه‌سازی غیرخطی در PINN) و نیز تفاوت در شیوه اعمال قیود مرزی (سخت در مقابل نرم)، مقایسه مطلق دشوار است. با این حال، این مقایسه با هدف سنجش عملکرد عملی هر روش در شرایط واقعی و با استفاده از داده‌های میدانی طراحی شده است.

معماری شبکه شامل چهار لایه پنهان با تعداد نورون‌های ۲۵۶، ۱۲۸، ۶۴ و ۳۲، تابع فعال‌ساز Swish، نرخ یادگیری ۰/۰۰۰۵ با بهینه‌ساز AdamW، بر اساس ترکیبی از آزمون و خطای اولیه و الهام از معماری‌های موفق در ادبیات PINN انتخاب شده است. اگرچه این پیکربندی به همگرایی پایدار و دقت قابل قبول انجامیده،

می‌شود. ماتریس کواریانس پارامترهای برآورد شده از رابطه زیر محاسبه می‌گردد (Kay, 1993):

$$\Sigma_0 = \sigma^2 (A^T A)^{-1} \quad (A)$$

که در آن A ماتریس طراحی و σ^2 واریانس خطای مشاهدات است.

مدل‌سازی عدم قطعیت در شبکه‌های عصبی آگاه از فیزیک نقش بسیار مهمی در افزایش قابلیت اطمینان این مدل‌ها دارد. در واقع، وقتی از این مدل‌ها برای مسائل عملی در علوم و مهندسی استفاده می‌کنیم، نیاز داریم نه تنها پیش‌بینی دقیق داشته باشیم، بلکه بدانیم این پیش‌بینی‌ها چقدر قابل اعتماد هستند. در این مدل‌ها، دو نوع عدم قطعیت اصلی وجود دارد: نخست، عدم قطعیتی که ناشی از کمبود داده‌های آموزشی است و با جمع‌آوری داده‌های بیشتر می‌توان آن را کاهش داد. دوم، عدم قطعیتی که ذاتاً در خود پدیده فیزیکی و اندازه‌گیری‌ها وجود دارد و حتی با داده‌های بیشتر هم از بین نمی‌رود. برای کمی‌سازی عدم قطعیت‌ها، روش‌های مختلفی به کار می‌روند. یکی از روش‌ها، استفاده از رویکرد آماری بیزی است که در آن پارامترهای شبکه به صورت احتمالاتی در نظر گرفته می‌شوند. روش دیگر، آموزش چندین مدل مختلف و سپس میانگین‌گیری از نتایج آن‌هاست. همچنین می‌توان از قابلیت انصراف (Dropout) در شبکه عصبی برای برآورد عدم قطعیت استفاده کرد.

نکته جالب در مدل‌های فیزیک‌آگاه این است که می‌توان عدم قطعیت را هم در بخش داده‌ها و هم در بخش معادلات فیزیکی بررسی کرد. مناطقی که معادلات فیزیکی به خوبی برقرار نیستند یا داده‌های کمتری در آن‌جا موجود است، معمولاً عدم قطعیت بیشتری نشان می‌دهند. اطلاعات درباره میزان عدم قطعیت، به پژوهشگران کمک می‌کند تا بتوانند تصمیم‌های بهتری بگیرند، نواحی با اطمینان کم را شناسایی کنند، و برای جمع‌آوری داده‌های جدید اولویت‌بندی کنند. در نهایت، مدل‌سازی عدم قطعیت باعث می‌شود این مدل‌ها برای استفاده در کاربردهای واقعی، قابل اعتمادتر و کاربردی‌تر شوند.

۳- داده‌ها و اطلاعات

۳-۱-۳- روش شناسی

در این پژوهش، از چهارچوب شبکه عصبی آگاه از فیزیک برای درون‌یابی میدان سرعت استفاده شده است. بر خلاف روش‌های کلاسیک که ممکن است به میدان‌های کرنش ناسازگار منجر شوند (Okazaki et al., 2021)، رویکرد پیشنهادی در این تحقیق با تلفیق معادلات فیزیکی در فرایند آموزش، سازگاری بین میدان سرعت و مشتقات آن را تضمین می‌کند. در طراحی معماری شبکه پیشنهادی، از یافته‌های مورر و ماترنا (Maurer and Materna, 2023) مبنی بر اهمیت تعیین عینی پارامترهای هموارسازی استفاده شده است. در حالی که روش‌های کلاسیک از منحنی L برای این منظور بهره می‌برند، رویکرد ما با بهینه‌سازی مستقیم توابع هزینه فیزیکی، این چالش را به صورت درون‌زا حل می‌کند.

۳-۱-۱-۳- داده‌های مورد استفاده و پیش‌پردازش

این پژوهش از داده‌های شبکه GPS که شامل ۸۹ ایستگاه مستقر در منطقه البرز است استفاده می‌کند. محدوده مطالعاتی بین ۴۸ تا ۵۶ درجه طول خاوری و ۳۴ تا ۳۸ درجه عرض شمالی در نظر گرفته شده است (شکل ۱) که منطقه‌ای با فعالیت زمین‌ساختی بالا و تراکم مناسب ایستگاه‌های GPS را پوشش می‌دهد. داده‌های مورد استفاده شامل مولفه‌های سرعت خاوری-بختری و شمالی-جنوبی به همراه ماتریس کواریانس خطاها است که امکان محاسبه عدم قطعیت‌ها را فراهم می‌سازد. این داده‌ها از مطالعه خرمی و همکاران (Khorrami et al., 2019) استخراج شده‌اند که در آن فرایند کنترل کیفیت دقیق و پالایش داده‌ها به‌طور کامل صورت پذیرفته است. بدین گونه که ایستگاه‌های تحت تاثیر پدیده‌های محلی غیرزمین‌ساختی مانند فرونشست ناشی از برداشت آب‌های زیرزمینی (با نرخ تا ۳۰ سانتی‌متر بر سال) و

تصادفی و بدون در نظرگیری موقعیت مکانی ایستگاه‌ها انجام شده است. اگرچه این رویکرد معیاری کلی از دقت مدل ارائه می‌دهد، اما توان تعمیم‌پذیری مدل در نواحی با تراکم بسیار کم داده یا فاقد ایستگاه را به‌طور کامل ارزیابی نمی‌کند. برای بررسی ژرف‌تر عملکرد مکانی مدل و اطمینان از قابلیت اعتماد آن در کل منطقه مطالعاتی، انجام آزمون‌های اعتبارسنجی مکانی پیشرفته‌تر (مانند اعتبارسنجی حذف منطقه‌ای یا Leave-One-Out جغرافیایی) در پژوهش‌های آتی توصیه می‌شود.

ارزیابی عدم قطعیت در این پژوهش با به‌کارگیری رویکرد مبتنی بر تکرارهای آموزشی با شرایط اولیه متفاوت صورت پذیرفته است. برای هر مقدار نسبت پواسون، ۵ مدل مستقل با مقادیر اولیه تصادفی متفاوت آموزش داده شد. شاخص‌های آماری میانگین و انحراف معیار خروجی‌های این مدل‌ها به‌عنوان معیارهای کمی عدم قطعیت در نظر گرفته شدند. به موازات این روش، تحلیل حساسیت پارامترهای مدل نیز به منظور شناسایی سهم هر یک در عدم قطعیت کل سیستم انجام گرفت. این رویکرد ترکیبی، امکان ارزیابی مکانی قابلیت اطمینان پیش‌بینی‌ها را در نواحی مختلف دامنه مسئله فراهم می‌سازد و بستری برای تصمیم‌گیری با در نظرگیری دامنه اطمینان پیش‌بینی‌ها ایجاد می‌نماید.

ارزیابی مدل در این پژوهش صرفاً بر اساس تقسیم تصادفی ساده با نسبت ۸۸ به ۱۲ درصد انجام شده است. اگرچه این رویکرد تصویری کلی از دقت مدل ارائه می‌دهد، اما از روش‌های اعتبارسنجی متقابل (Cross-Validation) به دلیل محدودیت‌های محاسباتی استفاده نشده است. همچنین، توان برون‌یابی (Extrapolation) مدل در مناطق خارج از پوشش ایستگاه‌های GPS به صورت سامانه‌مند ارزیابی نشده است. این محدودیت‌ها در تفسیر نتایج و تعمیم‌دهی مدل به مناطق فاقد داده باید مد نظر قرار گیرند.

۳-۱-۵- پیاده‌سازی نرم‌افزاری و محیط محاسباتی

پیاده‌سازی کامل این پژوهش در محیط Python 3.8 و با استفاده از کتابخانه‌های SciPy و TensorFlow 2.8:NumPy انجام شده است. تمام محاسبات بر روی سخت‌افزار مجهز به GPU NVIDIA Tesla V100 با ۱۶ گیگابایت حافظه انجام گرفته است. زمان آموزش برای هر مدل به طور متوسط ۴۵ دقیقه به طول انجامیده که نشان‌دهنده کارایی مناسب پیاده‌سازی است.

پیاده‌سازی این پژوهش با رویکردی ساختاریافته انجام گرفته است به گونه‌ای که قابلیت اجرا در محیط‌های محاسباتی گوناگون را دارا می‌باشد. طراحی بخش‌های مختلف به صورت مستقل و مستندسازی کامل، امکان بازتولید نتایج و توسعه آسان را برای مطالعات آتی فراهم می‌سازد. همچنین قابلیت ذخیره‌سازی و بازیابی مدل‌های آموزش‌دیده در این پیاده‌سازی پیش‌بینی شده که زمینه به‌کارگیری عملی مدل در سیستم‌های پایش آبی را مهیا می‌نماید.

۴- بحث

۴-۱-۱- ارزیابی کمی عملکرد مدل‌های مختلف

نتایج حاصل از آموزش مدل‌های مختلف با نسبت‌های پواسون متفاوت نشان‌دهنده عملکرد مطلوب روش پیشنهادی در درون‌یابی بردارهای سرعت GPS است. مقایسه کمی خطای RMSE برای مدل‌های مختلف با نسبت پواسون متفاوت در شکل ۳ نمایش داده شده است. همان‌گونه که مشاهده می‌شود، مدل با نسبت پواسون ۰/۲۳ کمترین خطای RMSE را برای هر دو مولفه خاوری و شمالی دارا می‌باشد. این مدل توانسته است به خطای RMSE معادل ۱/۴۰۲ میلی‌متر بر سال برای مولفه خاوری و ۱/۲۹۶ میلی‌متر بر سال برای مولفه شمالی دست یابد. عملکرد مدل‌های با نسبت پواسون ۰/۲۰ تا ۰/۳۰ نیز بسیار نزدیک به مدل بهینه است که نشان‌دهنده پایداری روش در محدوده مقادیر واقع‌بینانه نسبت پواسون برای سنگ‌های پوسته زمین است. نتایج کمی دقیق برای تمام مدل‌های آزمایش شده در جدول ۱ ارائه شده است. همان‌گونه که مشاهده می‌شود، مدل با نسبت پواسون ۰/۲۳ بهترین عملکرد را دارد.

اما بهینه‌سازی سامانه‌مند فرآیندها (شامل تعداد لایه‌ها، تعداد نورون‌ها، نوع تابع فعال‌ساز، و نرخ یادگیری) در چهارچوب این پژوهش انجام نشده که این موضوع به عنوان یکی از محدودیت‌های پژوهش حاضر به‌شمار می‌رود. به منظور جلوگیری از پدیده بیش‌برازش (Overfitting) و افزایش قابلیت تعمیم‌پذیری مدل، چهار راهبرد به کار گرفته شد: (۱) توقف زودهنگام (Early Stopping) بر اساس پایش خطای اعتبارسنجی، (۲) منظم‌سازی L2 از طریق کاهش وزن (Weight Decay) در بهینه‌ساز AdamW با ضریب ۰/۰۰۱، (۳) برش گرادیان (Gradient Clipping) با آستانه ۰/۵ بر اساس نرم سراسری برای پایداری آموزش، و (۴) معماری کاهنده Bottleneck Architecture با کاهش تدریجی تعداد نورون‌ها در لایه‌های پنهان. هم‌گرایی هم‌زمان منحنی‌های خطای آموزش و اعتبارسنجی (شکل ۴) گویای اثربخشی این راهبردها در جلوگیری از بیش‌برازش است. با این حال، استفاده از روش‌های پیشرفته‌تر مانند Dropout و منظم‌سازی تابعی می‌تواند در پژوهش‌های آتی مورد بررسی قرار گیرد.


۳-۱-۳- پیاده‌سازی معادلات حاکم فیزیکی

معادلات حاکم بر الاستیسته صفحه‌ای که شرایط تعادل نیرو را در یک محیط الاستیک بیان می‌کنند، در قالب یک سیستم معادلات دیفرانسیل جزئی (PDE) مرتبه دوم فرمول‌بندی شده‌اند. در این پژوهش، این معادلات به عنوان قید فیزیکی اصلی در چهارچوب شبکه عصبی آگاه از فیزیک گنجانده شده‌اند. برای اعمال دقیق این قیود، مشتقات جزئی مرتبه دوم مورد نیاز با بهره‌گیری از قابلیت مشتق‌گیری خودکار (Automatic Differentiation) کتابخانه تسورفلو و با استفاده از دو لایه تو در تو از GradientTape محاسبه گردید که دقت لازم در محاسبات گرادیان را تضمین می‌نماید. به منظور افزایش پایداری راه‌حل به مبانی فیزیکی، قیود اضافی شامل شرط بی‌دیورژنس (Divergence-Free) و معادله بیچش (Biharmonic Equation) نیز به تابع هزینه افزوده شد. ضرایب این قیود به ترتیب با مقادیر ۰/۰۱ و ۰/۰۰۵ وزن‌دهی شده‌اند که به بهبود روند همگرایی و ارتقای پایداری فیزیکی نتایج انجامیده است. همچنین با هدف بهینه‌سازی فرایند آموزش، یک سازوکار وزن‌دهی پویا پیاده‌سازی شده که بر اساس آن تاثیر این قیود در مراحل اولیه آموزش بیشتر بوده و به تدریج تطبیق می‌یابد.

در این پژوهش، نقاط کولوکیشن به‌منظور ارزیابی قید معادلات حاکم فیزیکی در تابع هزینه PINN، به صورت یک شبکه یکنواخت (Uniform Grid) در محدوده جغرافیایی منطقه مطالعاتی توزیع شدند. این رویکرد مبتنی بر روش‌های استاندارد به‌کار رفته در ادبیات شبکه‌های عصبی آگاه از فیزیک است که در آن پوشش یکنواخت دامنه برای اعمال قیود فیزیکی در سرتاسر منطقه کافی فرض می‌شود. با این حال، تاثیر چگالی و الگوی توزیع این نقاط بر نتایج نهایی می‌تواند موضوع پژوهش‌های آتی بوده و بررسی سامانه‌مند حساسیت مدل به این پارامترها جهت بهینه‌سازی بیشتر پیشنهاد می‌شود.

۳-۱-۴- روش‌های ارزیابی و معیارهای سنجش

ارزیابی عملکرد مدل پیشنهادی با به‌کارگیری مجموعه‌ای جامع از سنج‌های کمی و کیفی صورت پذیرفت. در سطح سنج‌های کمی اصلی، معیارهایی شامل جذر میانگین مربعات خطای (RMSE) مولفه‌های سرعت، خطای مجموعه اعتبارسنجی و روند همگرایی تابع هزینه آموزش مورد بررسی قرار گرفت. در کنار این موارد، معیارهای کیفی تکمیلی شامل تحلیل توزیع آماری خطاها، ارزیابی خودهمبستگی مکانی باقیمانده‌ها و میزان پیروی نتایج از قوانین بنیادین فیزیکی نیز به منظور اعتبارسنجی ژرف‌تر مدل به کار گرفته شد. به منظور سنجش قابلیت تعمیم‌پذیری مدل، از روش نگهداشت آزمون با نسبت تقسیم ۸۸ به ۱۲ درصد بین داده‌های آموزشی و آزمون استفاده گردید. لازم به توضیح است که این تقسیم‌بندی به‌صورت



شکل ۳- مقایسه خطای RMSE برای مدل‌های مختلف با نسبت پواسون متفاوت. مقادیر خطای RMSE برای مولفه‌های خاوری و شمالی سرعت. مدل با نسبت پواسون ۰/۲۳ کمترین خطا را نشان می‌دهد.

Figure 3. Comparison of RMSE error for different models with varying Poisson's ratio. RMSE error values for East and North velocity components. The model with Poisson's ratio 0.23 shows the lowest error.

جدول ۱- عملکرد مدل‌های مختلف بر اساس نسبت پواسون.

Table 1. Performance of different models based on Poisson's ratio.

Physical Cost	Validation Cost	Early Stopping Epoch	Best Epoch	Total Error	RMSE North (mm/yr)	RMSE East (mm/yr)	Poisson's Ratio
0.197	1.363	700	100	1.212	1.001	0.684	0.20
0.249	1.250	700	100	1.206	0.994	0.682	0.23
0.211	1.451	700	100	1.232	1.026	0.683	0.25
0.189	1.467	700	100	1.229	1.019	0.687	0.27
0.200	1.457	700	100	1.235	1.026	0.688	0.30

نشان می‌دهد که چگونه تاثیر قید فیزیکی به تدریج در طول آموزش افزایش یافته است (شکل ۴- e).

نمودارهای تاریخچه آموزش نشان می‌دهند که خطای آموزش و اعتبارسنجی به طور همزمان کاهش یافته و فاصله بین این دو منحنی در حد متعادلی حفظ شده است. این موضوع نشان‌دهنده تعادل مناسب بین پیچیدگی مدل و حجم داده‌های آموزشی است.

مشاهده می‌شود که مدل‌های با نسبت پواسون نزدیک به مقادیر بهینه، از همگرایی سریع‌تری برخوردار بوده‌اند. این پدیده می‌تواند نشان‌دهنده تطابق بهتر این مقادیر با فیزیک حاکم بر مسئله باشد. همچنین، اثر منظم‌سازی اعمال شده در جلوگیری از بیش‌برازش آشکارا قابل مشاهده است، به طوری که مدل‌ها در عین حفظ دقت بالا، از قابلیت تعمیم مناسبی برخوردار هستند.

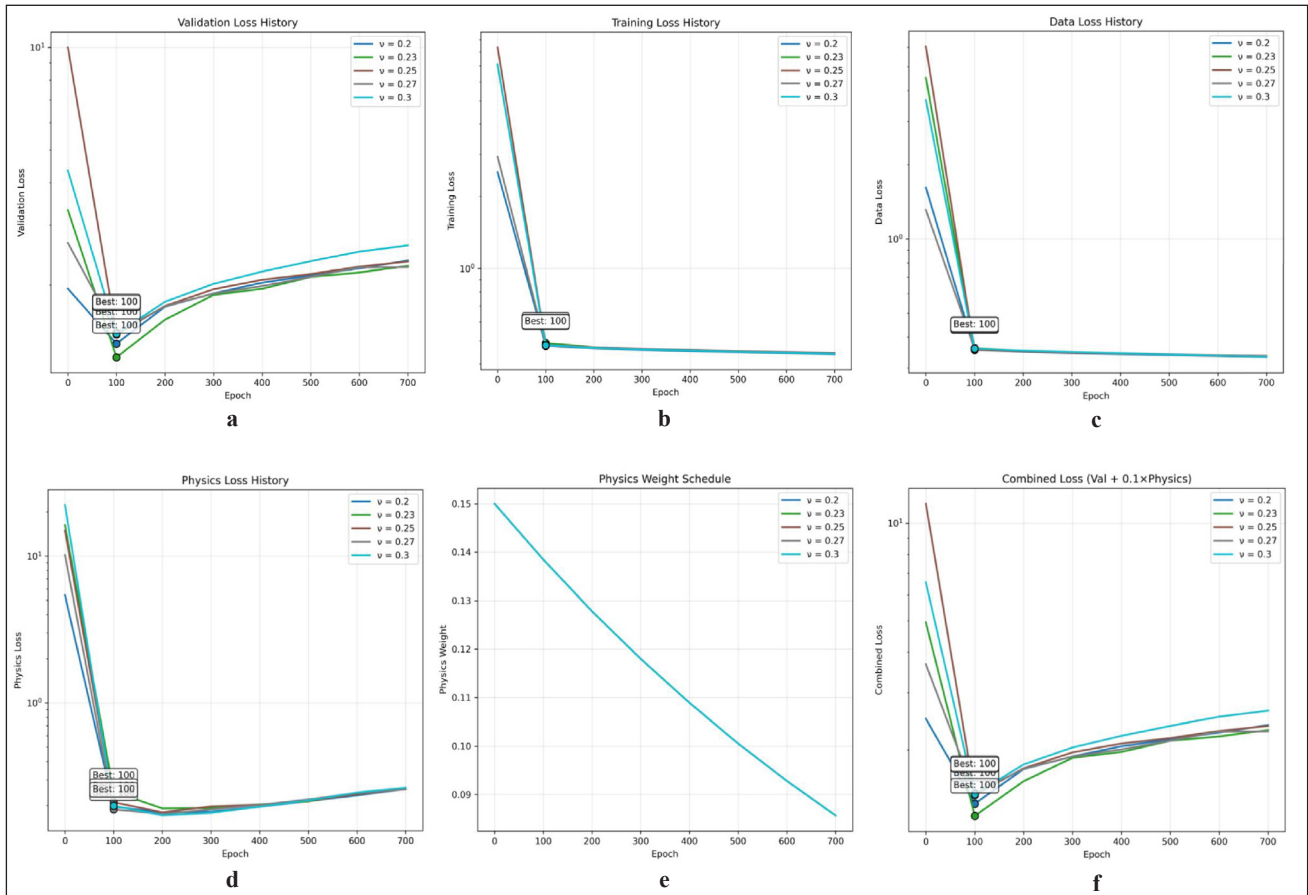
مقایسه مستقیم بردارهای سرعت مشاهده شده و پیش‌بینی شده با مدل بهینه در شکل ۵-a آشکارا نشان می‌دهد که مدل پیشنهادی نه تنها در بازتولید میدان سرعت پیوسته، بلکه در پیش‌بینی مقادیر سرعت در خود ایستگاه‌های GPS نیز از دقت بالایی برخوردار است. همخوانی نزدیک بردارهای قرمز (مشاهده شده) و آبی (پیش‌بینی شده) در شکل ۵-a و b، صحت مدل در حفظ الگوهای مکانی سرعت را تایید می‌کند. توزیع مکانی خطاها در شکل ۵-b نشان می‌دهد که بیشترین خطاها در مناطقی رخ داده است که تراکم ایستگاه‌های GPS کمتر بوده یا در مجاورت گسل‌های اصلی قرار دارند.

تاکید می‌گردد که مقدار ۰/۲۳ تنها بر اساس معیار کمی RMSE و در فرایند بهینه‌سازی عددی مدل PINN به دست آمده است. این مقدار یک بهینه محاسباتی است و الزاما معادل مقدار واقعی فیزیکی نسبت پواسون پوسته در منطقه البرز نیست. در این پژوهش، از معیارهای فیزیکی مستقل (همچون سازگاری با میدان تنش منطقه‌ای، سازوکار کانونی زمین‌لرزه‌ها، یا برآوردهای لرزه‌ای V_p/V_s) برای اعتبارسنجی این مقدار استفاده نشده است. فقدان مطالعات لرزه‌ای برای تعیین تجربی نسبت پواسون در البرز، انجام چنین مقایسه‌ای را در حال حاضر ناممکن ساخته است.

۴-۲- بررسی همگرایی و پایداری آموزش

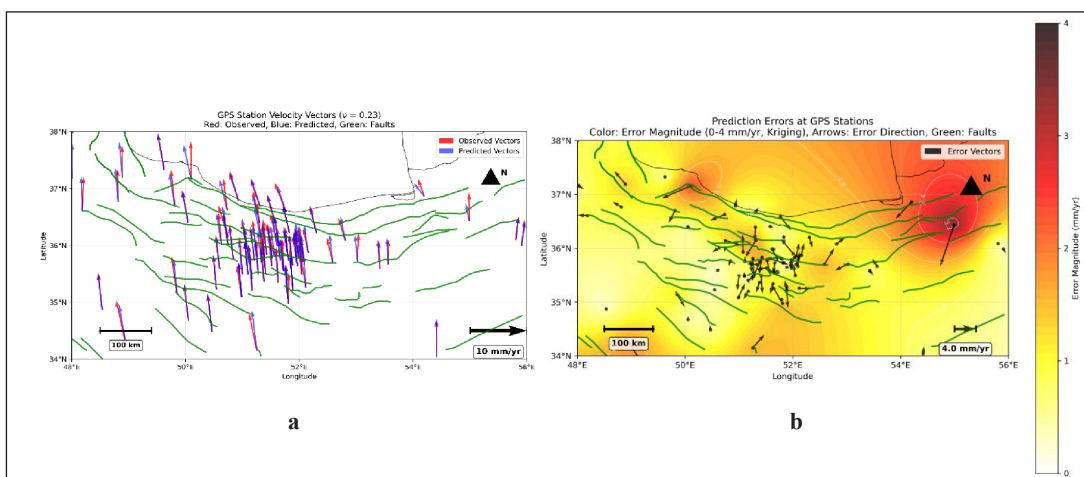
فرایند آموزش برای تمام مدل‌ها از همگرایی پایدار و یکنواختی برخوردار بوده است. مدل بهینه پس از حدود ۱۰۰ دوره به همگرایی رسیده و فرایند توقف زود هنگام (Early Stopping) در دوره ۷۰۰ فعال شده است.

منحنی‌های یادگیری آموزش و اعتبارسنجی برای مدل‌های مختلف با نسبت پواسون متفاوت در شکل ۴ نمایش داده شده است. همان‌گونه که مشاهده می‌شود، تمامی مدل‌ها از همگرایی پایدار و یکنواختی برخوردار بوده‌اند. مدل با نسبت پواسون ۰/۲۳ (نمودار نارنجی) در حدود دوره ۱۰۰ به بهترین همگرایی دست یافته است. همچنین کاهش همزمان خطای داده و خطای فیزیکی نشان‌دهنده تعادل مناسب بین برآزش داده‌ها و رعایت قوانین فیزیکی می‌باشد. برنامه زمان‌بندی وزن فیزیکی



شکل ۴- منحنی‌های یادگیری شبکه عصبی آگاه از فیزیک برای نسبت‌های پواسون مختلف. (a) منحنی خطای اعتبارسنجی، (b) منحنی خطای آموزش، (c) منحنی خطای داده، (d) منحنی خطای فیزیکی، (e) برنامه زمان‌بندی وزن فیزیکی، (f) منحنی خطای ترکیبی. مدل با نسبت پواسون ۰/۲۳ (نمودار نارنجی) در دوره ۱۰۰ به بهترین همگرایی دست یافته است.

Figure 4. Learning curves of the Physics-Informed Neural Network for different Poisson's ratios. a) Validation error curve, b) Training error curve, c) Data error curve, d) Physical error curve, e) Physical weight scheduling, f) Combined error curve. The model with Poisson's ratio 0.23 (orange plot) achieved the best convergence at epoch 100.



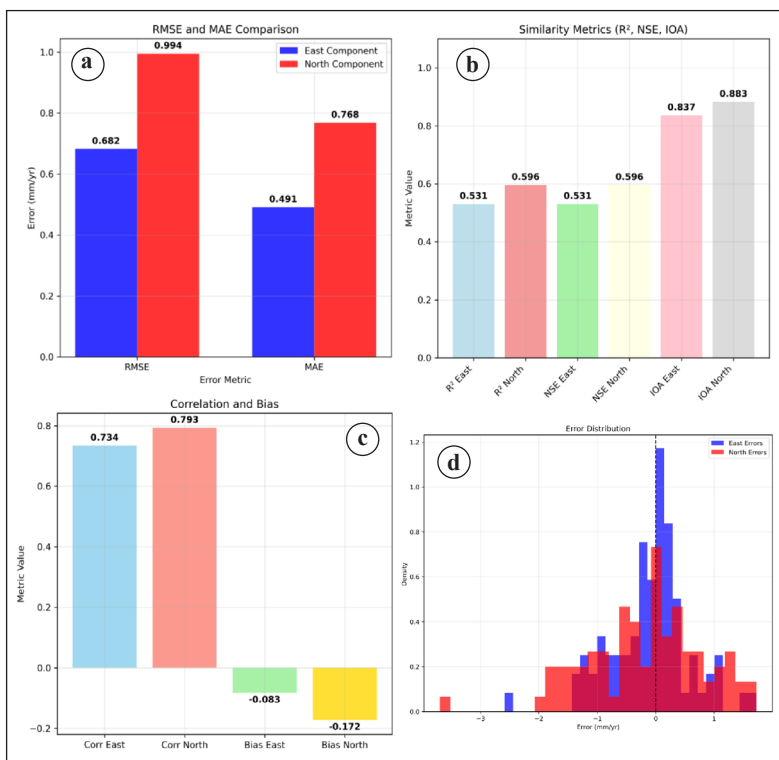
شکل ۵- مقایسه بردارهای سرعت مشاهده شده و مدلسازی شده و تحلیل خطاها (a) نمایش همزمان بردارهای سرعت مشاهده شده (قرمز) و پیش‌بینی شده (آبی) توسط مدل PINN با نسبت پواسون ۰/۲۳ به همراه گسل‌های اصلی منطقه (سبز). همخوانی قابل توجه بین جهت و اندازه بردارهای مشاهده شده و پیش‌بینی شده در بیشتر ایستگاه‌ها آشکار است. (b) توزیع مکانی خطاهای

پیش‌بینی که بزرگی خطا با رنگ (۰-۴ میلی‌متر بر سال) و جهت خطا با پیکان‌ها نمایش داده شده است. بیشترین خطاها در مناطقی با تراکم کم ایستگاه‌ها و در امتداد گسل‌های اصلی مشاهده می‌شود.

Figure 5. Comparison of observed and modeled velocity vectors and error analysis a) Simultaneous display of observed (red) and predicted (blue) velocity vectors by the PINN model with Poisson's ratio 0.23 along with major faults of the region (green). Significant agreement between direction and magnitude of observed and predicted vectors is evident at most stations. b) Spatial distribution of prediction errors where error magnitude is shown by color (0-4 mm/yr) and error direction by arrows. The largest errors are observed in areas with low station density and along major faults.

است. توزیع آماری خطاهای پیش‌بینی برای هر دو مولفه خاوری و شمالی در شکل ۶-d نمایش داده شده است. همان‌گونه که مشاهده می‌شود، توزیع خطاها برای هر دو مولفه تقریباً عادی و حول صفر متمرکز شده است که نشان‌دهنده عدم وجود اریب سامانه‌مند در مدل است. گستردگی توزیع خطاهای مولفه شمالی کمی بیشتر از مولفه خاوری است که با نتایج RMSE بالاتر برای این مولفه (جدول ۱) همخوانی دارد. تمرکز بیشتر خطاها در محدوده ± 2 میلی‌متر بر سال نشان از دقت مناسب مدل در پیش‌بینی میدان سرعت دارد. با این حال، میانگین خطای مطلق در کل منطقه کمتر از 0.007 میلی‌متر بر سال است که برای کاربردهای ژئودینامیکی قابل قبول به‌شمار می‌رود.

شکل ۶ ارزیابی جامع دقت مدل PINN را نشان می‌دهد. همان‌گونه که مشاهده می‌شود، مدل پیشنهادی از دقت بالایی در پیش‌بینی هر دو مولفه سرعت برخوردار است. خطای RMSE کل $1/206$ میلی‌متر بر سال و خطای MAE $1/107$ میلی‌متر بر سال گویای عملکرد مطلوب مدل است. میزان همبستگی 0.734 برای مولفه خاوری و 0.793 برای مولفه شمالی نشان‌دهنده توانایی بالای مدل در بازتولید الگوهای مکانی میدان سرعت است. توزیع خطاها نیز از انحراف معیار 0.677 و 0.979 میلی‌متر بر سال به ترتیب برای مولفه‌های خاوری و شمالی برخوردار است که در محدوده قابل قبولی قرار دارد. همچنین بایاس نزدیک به صفر (0.082 و -0.172 میلی‌متر بر سال) نشان می‌دهد که مدل فاقد اریب سامانه‌مند شایان توجه

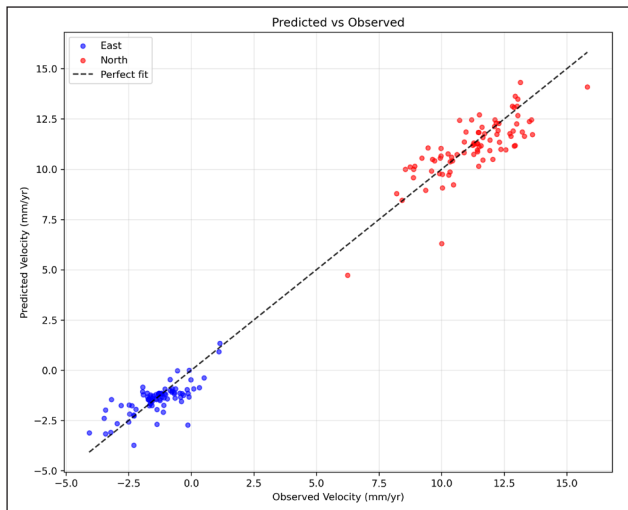


شکل ۶- ارزیابی جامع دقت مدل شبکه عصبی آگاه از فیزیک (a) مقایسه RMSE و MAE برای مولفه‌های خاوری و شمالی، (b) توزیع خطاها، (c) معیارهای تمرکز و بایاس، (d) توزیع خطاهای پیش‌بینی مدل برای مولفه‌های خاوری و شمالی سرعت. توزیع خطاها برای هر دو مولفه تقریباً عادی و حول صفر متمرکز شده است. گستردگی بیشتر توزیع خطاهای مولفه شمالی با RMSE بالاتر این مولفه همخوانی دارد.

Figure 6. Comprehensive evaluation of Physics-Informed Neural Network model accuracy a) Comparison of RMSE and MAE for East and North components, b) Error distribution, c) Concentration metrics and bias, d) Distribution of model prediction errors for East and North velocity components. Error distributions for both components are approximately normal and centered around zero. The wider spread of North component errors corresponds to its higher RMSE.

آشکارا در این نمودار قابل مشاهده است. همبستگی شایان توجه بین مقادیر پیش‌بینی شده و مشاهده شده (بیش از 0.793 برای مولفه شمالی و 0.734 برای مولفه خاوری) اعتبار مدل در بازتولید میدان سرعت واقعی را تایید می‌کند. این سطح از دقت، همراه با ارزیابی جامع عدم قطعیت، مدل پیشنهادی را به ابزاری قابل اعتماد برای مطالعات ژئودینامیکی و تحلیل‌های خطر زمین‌لرزه تبدیل می‌کند.

شکل ۷ رابطه بین مقادیر پیش‌بینی شده و مشاهده شده سرعت را برای هر دو مولفه خاوری و شمالی نشان می‌دهد. نزدیکی بیشتر نقاط به خط برازش کامل (خط ۱:۱) نشان‌دهنده دقت بالای مدل در پیش‌بینی میدان سرعت است. پراکندگی کم نقاط حول این خط و توزیع متقارن خطاها گویای عدم وجود اریب سامانه‌مند در پیش‌بینی‌های مدل است. همبستگی بالا بین مقادیر پیش‌بینی شده و مشاهده شده



شکل ۷- مقایسه مقادیر پیش‌بینی شده و مشاهده شده سرعت. نمودار پراکنندگی مقادیر پیش‌بینی شده در مقابل مقادیر مشاهده شده برای مؤلفه‌های خاوری و شمالی سرعت. نزدیکی نقاط به خط برازش کامل (خط ۱:۱) نشان‌دهنده دقت بالای مدل است.

Figure 7. Comparison of predicted and observed velocity values. Scatter plot of predicted values versus observed values for East and North velocity components. The proximity of points to the perfect fit line (1:1 line) indicates the model's high accuracy.

با فرایند بهینه‌سازی ارائه می‌دهد، اما دارای محدودیت‌های اساسی است: نخست این که عدم قطعیت ناشی از نویز ذاتی داده‌ها را مدل‌سازی نمی‌کند و واریانس خطای مشاهدات GPS به صورت مستقیم در تابع هزینه لحاظ نشده است؛ دوم این که این روش قادر به تفکیک منابع مختلف عدم قطعیت (همچون عدم قطعیت ناشی از ساختار مدل و کمبود داده) نیست. در پژوهش‌های آتی، به کارگیری چهارچوب‌های پیشرفته‌تری مانند PINN بیزی (Bayesian PINN) یا روش Monte Carlo Dropout که با مدل‌سازی توزیع پارامترهای شبکه، برآورد دقیق‌تر و تفسیرپذیرتری از عدم قطعیت ارائه می‌دهند، توصیه می‌شود.

۴-۵- تحلیل میدان سرعت درون‌یابی شده

شکل ۸ میدان سرعت کامل درون‌یابی شده با نسبت پواسون ۰/۲۳ را به همراه بردارهای سرعت مشاهده شده و گسل‌های اصلی منطقه نشان می‌دهد. همان‌گونه که در این شکل مشاهده می‌شود، مدل پیشنهادی موفق به بازتولید الگوی پیچیده میدان سرعت در منطقه شده است. همخوانی شایان توجه بین بردارهای پیش‌بینی شده و مشاهده شده و همچنین تطابق الگوهای سرعت با گسل‌های اصلی، صحت و دقت مدل را تأیید می‌کند.

در بخش‌های مرکزی منطقه مطالعاتی، میدان سرعت از یک‌نواختی بیشتری برخوردار است که نشان‌دهنده رفتار بلوکی پوسته در این نواحی می‌باشد. در مقابل، در امتداد گسل‌های اصلی، تغییرات ناگهانی در جهت و اندازه بردارهای سرعت مشاهده می‌شود که با انتظارات زمین‌ساختی کاملاً سازگار است. مدل پیشنهادی موفق شده است این تغییرات شدید را به خوبی نمایش دهد بدون این که دچار نوسانات کاذب شود.

میدان سرعت درون‌یابی شده برای مؤلفه‌های خاوری و شمالی به ترتیب در شکل‌های ۹ و ۱۰ نمایش داده شده است که موفقیت مدل پیشنهادی در بازتولید الگوهای پیچیده میدان سرعت منطقه را به خوبی نشان می‌دهند. در مؤلفه خاوری (شکل ۹)، تغییرات سرعت بین ۷- تا ۱+ میلی‌متر بر سال مشاهده می‌شود که بیانگر تنوع بالای میدان تغییر شکل در منطقه است، در حالی که در مؤلفه شمالی (شکل ۱۰)، محدوده تغییرات بین صفر تا ۱۲+ میلی‌متر بر سال، الگوی کلی حرکت به سمت شمال را نشان می‌دهد. همخوانی شایان توجه الگوهای سرعت با گسل‌های اصلی منطقه، قابلیت مدل در حفظ ویژگی‌های فیزیکی و زمین‌ساختی را به خوبی تأیید می‌کند.

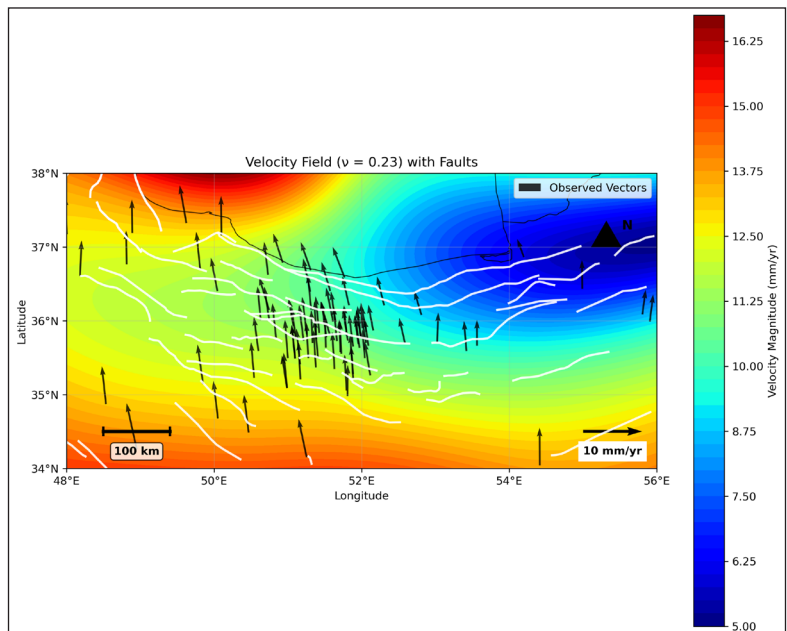
۴-۳- تحلیل حساسیت پارامترهای مدل

تحلیل حساسیت انجام شده بر روی پارامترهای مختلف مدل نشان می‌دهد که نسبت پواسون بیشترین تأثیر را بر روی دقت نهایی مدل دارد. تغییر این پارامتر در محدوده واقع بینانه ۰/۲۰ تا ۰/۳۰ سبب تغییر حدود ۸ درصدی در خطای RMSE می‌شود. پارامترهای مربوط به معماری شبکه از حساسیت متوسطی برخوردار هستند، به گونه‌ای که تغییر تعداد لایه‌ها از ۳ به ۴ لایه موجب بهبود ۵ درصدی دقت شده است. پارامترهای مربوط به فرایند آموزش، شامل نرخ یادگیری و ضرایب قیود فیزیکی، اگرچه از حساسیت کمتری در دقت نهایی برخوردارند، اما تنظیم بهینه آن‌ها نقش تعیین‌کننده‌ای در پایداری فرایند آموزش داشته است. به طور خاص، ضریب قید بی‌دیورنس بیشترین تأثیر را در پایداری راه‌حل به اصول فیزیکی داشته، در حالی که ضریب قید پیچش تأثیر محدودتری بر دقت نهایی مدل نشان داده است. این یافته‌ها می‌تواند راهنمای ارزشمندی برای تنظیم پارامترهای مدل در کاربردهای مشابه باشد.

۴-۴- ارزیابی عدم قطعیت پیش‌بینی‌ها

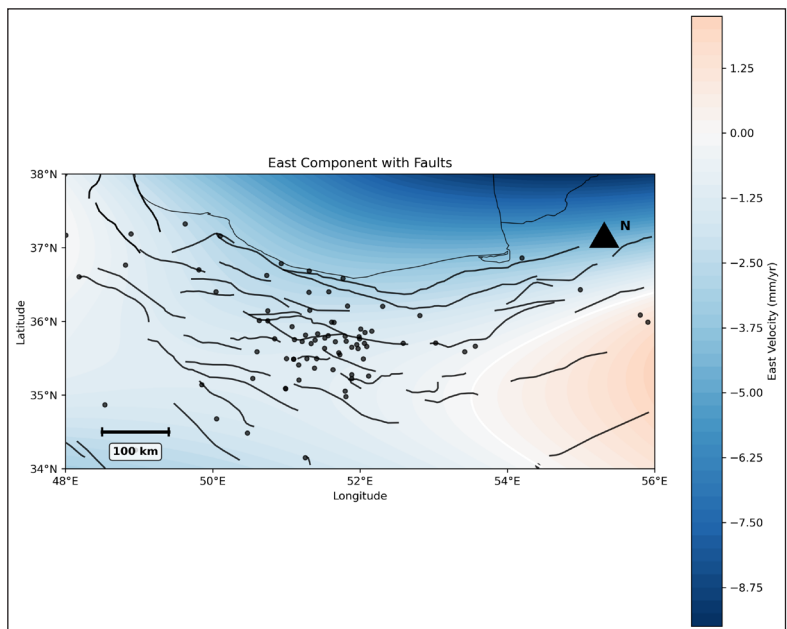
توزیع مکانی خطاهای پیش‌بینی که در شکل ۵-b نمایش داده شده است، به خوبی رابطه بین تراکم ایستگاه‌ها و دقت مدل را نشان می‌دهد. این شکل نشان می‌دهد که عدم قطعیت پیش‌بینی‌ها رابطه مستقیمی با تراکم ایستگاه‌های GPS دارد. در مناطقی با تراکم بالای ایستگاه‌های GPS (مانند نواحی مرکزی)، انحراف معیار پیش‌بینی‌ها کمتر از ۰/۳ میلی‌متر بر سال است، در حالی که در مناطق با پوشش ایستگاهی کمتر و در حاشیه منطقه مطالعاتی، این مقدار افزایش یافته و به بیش از ۰/۸ میلی‌متر بر سال می‌رسد. تحلیل‌ها همچنین نشان می‌دهند که بیشترین عدم قطعیت در نزدیکی مرزهای صفحه‌های زمین‌ساختی و گسل‌های اصلی مشاهده می‌شود که احتمالاً ناشی از پیچیدگی میدان تغییر شکل در این نواحی است. با این وجود، حتی در این مناطق حساس نیز فاصله اطمینان ۹۵ درصدی کمتر از ۲ میلی‌متر بر سال باقی می‌ماند که برای بیشتر کاربردهای عملی کاملاً قابل قبول است. این یافته‌ای ارزشمند برای بهینه‌سازی شبکه‌های آینده GPS به‌شمار می‌رود. این الگو با نتایج کمی ارائه شده در جدول ۱ همخوانی کامل دارد.

روش به کار گرفته شده در این پژوهش برای برآورد عدم قطعیت (آموزش چندین مدل با شرایط اولیه متفاوت) به‌طور عمده تغییرپذیری ناشی از تصادفی بودن فرایند آموزش و وزن‌های اولیه را پوشش می‌دهد. اگرچه این رویکرد برای ارزیابی اولیه تغییرپذیری پیش‌بینی‌ها مناسب است و نمایی از عدم قطعیت مرتبط



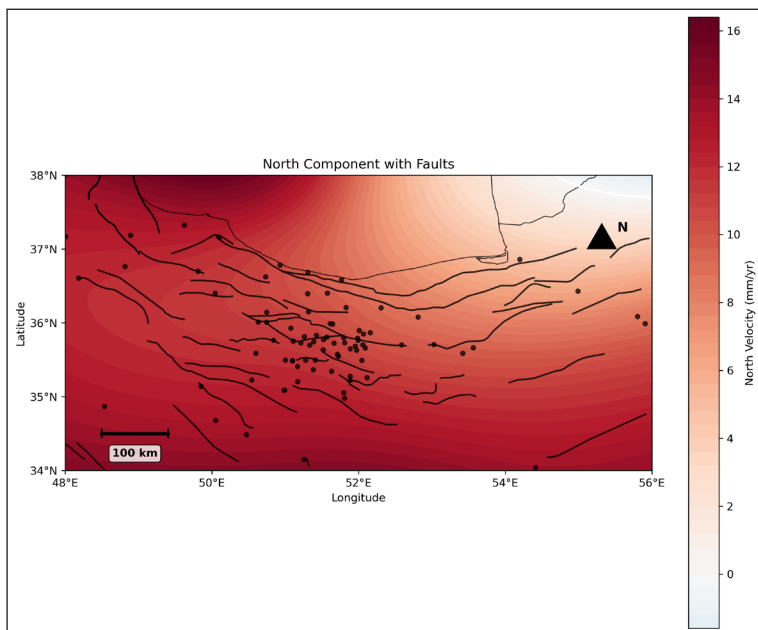
شکل ۸- میدان سرعت درون‌یابی شده با نسبت پواسون ۰/۲۳ به همراه گسل‌های اصلی. نمایش بردارهای سرعت مشاهده شده (مشکی) و میدان سرعت پیوسته درون‌یابی شده (پس‌زمینه رنگی).

Figure 8. Interpolated velocity field with Poisson's ratio 0.23 along with major faults. Display of observed velocity vectors (black) and continuous interpolated velocity field (color background).



شکل ۹- مولفه خاوری میدان سرعت با گسل‌های اصلی. مقادیر مولفه‌های خاوری سرعت بین -۷ تا +۱ میلی‌متر بر سال قرار دارند. همخوانی الگوهای سرعت با گسل‌های اصلی آشکار است.

Figure 9. East component of the velocity field with major faults. Values of East velocity components range between -7 and +1 mm/yr. Match of velocity patterns with major faults is evident.



شکل ۱۰- میدان سرعت مولفه شمالی با گسل‌های اصلی. مقادیر سرعت شمالی بین صفر تا +۱۲ میلی‌متر بر سال قرار دارند. حرکت کلی به سمت شمال در منطقه مشاهده می‌شود.

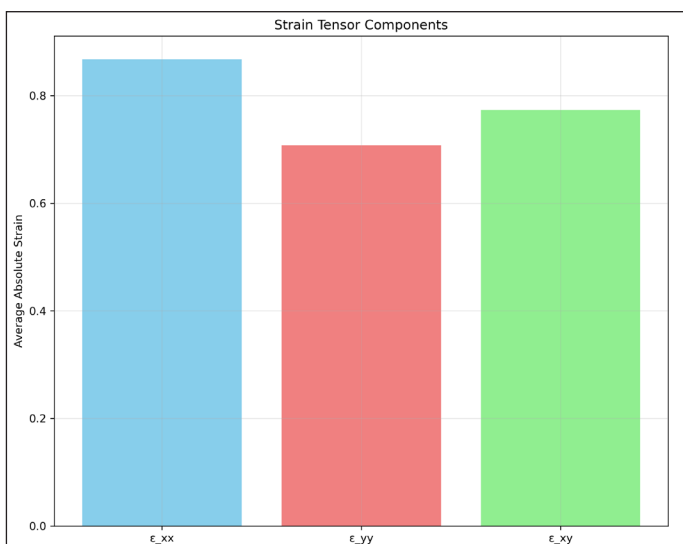
Figure 10. North component velocity field with major faults. North velocity values range between zero and +12 mm/yr. Overall northward motion is observed in the region.

نشان می‌دهد. همان‌گونه که در شکل مشاهده می‌شود، جهت‌های کرنش اصلی آشکارا با نوع گسل‌های اصلی منطقه همخوانی دارد. این هماهنگی ساختاری نشان می‌دهد که میدان تغییر شکل پوسته به شدت تحت تاثیر ساختارهای زمین‌شناسی موجود قرار دارد. بزرگی کرنش‌های اصلی نیز تغییرات مکانی شایان توجهی را نشان می‌دهد، به گونه‌ای که بیشترین مقادیر کرنش در امتداد گسل‌های فعال و مرزهای صفحه‌های زمین‌ساختی متمرکز شده است.

شکل ۱۳ میدان اتساع (تغییر حجم نسبی) محاسبه‌شده از میدان سرعت را نشان می‌دهد. مقادیر مثبت اتساع در بخش‌هایی از منطقه نشان‌دهنده حالت کششی حاکم بر پوسته است، در حالی که مقادیر منفی بیانگر حالت فشاری در آن نواحی می‌باشد. الگوی توزیع اتساع همخوانی شایان توجهی با گسل‌های اصلی منطقه دارد، به گونه‌ای که بیشترین مقادیر تغییر حجم در نزدیکی این گسل‌ها مشاهده می‌شود. این الگو تایید می‌کند که تغییر شکل پوسته به طور عمده توسط ساختارهای گسلی کنترل می‌شود.

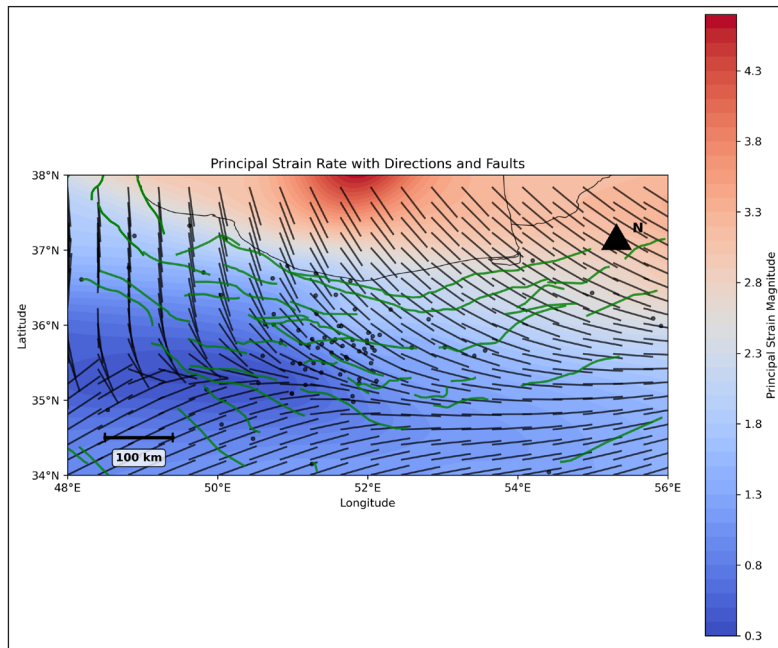
۴-۶- تحلیل میدان کرنش

شکل‌های ۱۱ تا ۱۵ ویژگی‌های مختلف میدان کرنش محاسبه شده از میدان سرعت درون‌یابی شده را نشان می‌دهند. این تحلیل‌ها بینش ژرف‌تری از الگوی تغییر شکل پوسته در منطقه مطالعاتی ارائه می‌کنند. مطالعات ژئودتیکی اخیر نشان می‌دهد که تانسور نرخ کرنش در ایران از الگوی پیچیده‌ای پیروی می‌کند (Masson et al., 2014). شکل ۱۱ مولفه‌های مختلف تانسور کرنش شامل ϵ_{xx} (کرنش در راستای خاوری-باختری)، ϵ_{yy} (کرنش در راستای شمالی-جنوبی) و ϵ_{xy} (کرنش برشی) را به همراه میانگین کرنش مطلق نمایش می‌دهد. تحلیل این مولفه‌ها نشان می‌دهد که مولفه خاوری-باختری سهم غالب در میدان تغییر شکل منطقه دارد. این الگو با وضعیت زمین‌ساختی منطقه که در داخل منطقه برخورد مایل بین صفحه‌های عربستان-اوراسیا قرار گرفته است، کاملاً همخوانی دارد. تغییرات مکانی مولفه‌های کرنش نیز الگوی پیچیده تغییر شکل پوسته را در مقیاس منطقه‌ای نشان می‌دهد. شکل ۱۲ میدان کرنش‌های اصلی و جهت‌های آن‌ها را در منطقه مورد مطالعه



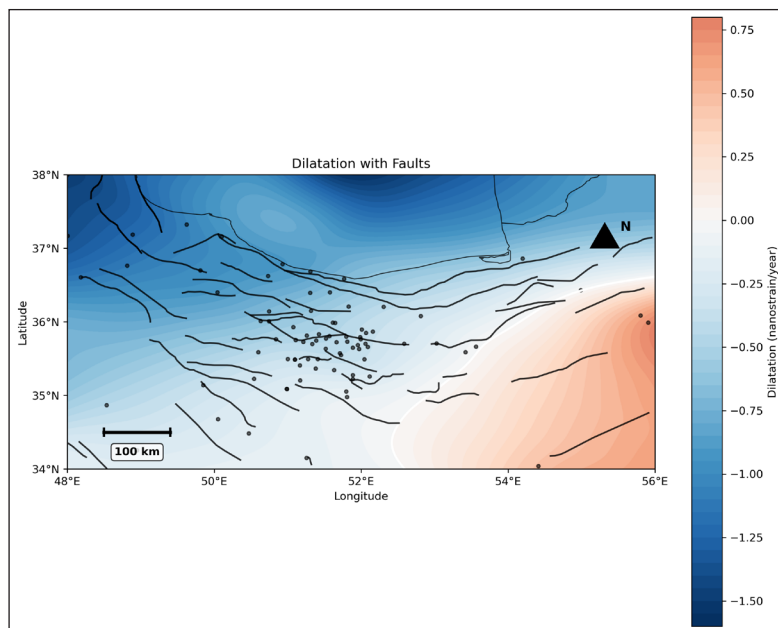
شکل ۱۱- مولفه‌های تانسور کرنش. نمایش میانگین مطلق مولفه‌های کرنش ϵ_{xx} ، ϵ_{yy} و ϵ_{xy} .

Figure 11. Components of the strain tensor. Display of mean absolute components of strain ϵ_{xx} , ϵ_{yy} and ϵ_{xy} .



شکل ۱۲- کرنش‌های اصلی و جهت‌های آن‌ها به همراه گسل‌ها. جهت‌ها و بزرگی کرنش‌های اصلی در منطقه مورد مطالعه با نوع گسل‌های اصلی منطقه همخوانی دارد.

Figure 12. Principal strains and their directions along with faults. Directions and magnitudes of principal strains in the study area match the type of major faults in the region.



شکل ۱۳- میدان اتساع به همراه گسل‌های اصلی. مقادیر مثبت نشان‌دهنده کشش و مقادیر منفی نشان‌دهنده فشار در پوسته است. همخوانی الگوی اتساع با گسل‌های اصلی آشکار است.

Figure 13. Dilatation field along with major faults. Positive values indicate tension and negative values indicate compression in the crust. Match of dilatation pattern with major faults is evident.

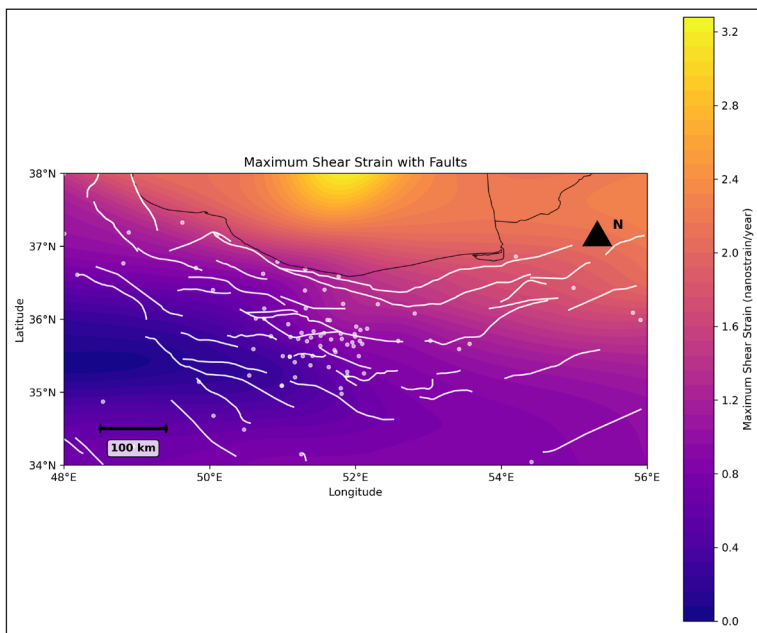
الگو تا بید می‌کند که تمرکز تغییر شکل در پوسته به‌طور عمده توسط ساختارهای گسلی کنترل می‌شود. مقایسه این نقشه با دیگر مولفه‌های کرنش نشان می‌دهد که ناوردای دوم به عنوان یک شاخص ترکیبی، تصویر جامعی از الگوی تغییر شکل منطقه ارائه می‌دهد. لازم به یادآوری است که همخوانی الگوهای کرنش استخراج‌شده از مدل PINN با ساختارهای زمین‌شناسی و گسل‌های اصلی منطقه در این پژوهش به صورت کیفی و بر اساس تطابق بصری ارزیابی شده است. اگرچه این تطابق با یافته‌های مطالعات ژئودتیکی پیشین در منطقه (eg., Masson et al., 2014; Khorrami et al., 2019; Rastbood, 2023; Rastbood et al., 2024

شکل ۱۴ بیشینه کرنش برشی بیشینه را نشان می‌دهد که یکی از مهم‌ترین پارامترها در ارزیابی پتانسیل لرزه‌خیزی به‌شمار می‌رود. تمرکز کرنش برشی بالا در امتداد گسل‌های اصلی آشکارا قابل مشاهده است.

شکل ۱۵ ناوردای دوم تانسور کرنش را که معیاری از شدت کلی تغییر شکل است، نمایش می‌دهد. این پارامتر که مستقل از سیستم مختصات است، نواحی با تغییر شکل شدید را به خوبی از مناطقی با تغییر شکل ملایم متمایز می‌سازد. همان‌گونه که در نقشه مشاهده می‌شود، بیشترین مقادیر ناوردای دوم در امتداد گسل‌های اصلی و مرزهای بین بلوک‌های زمین‌ساختی متمرکز شده است. این

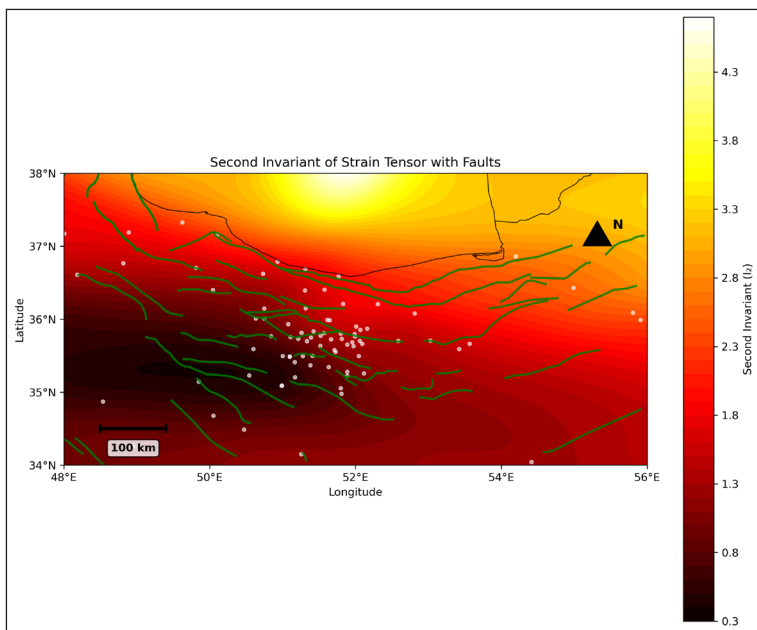
(مانند کوتاه‌شدگی حدود ۶ میلی‌متر بر سال در باختر و حدود ۵ میلی‌متر بر سال امتدادلغز در خاور، و تمرکز حدود ۷۰٪ تغییرشکل بر روی گسل‌های شمال البرز و خزر باختری) همسو می‌باشد. لازم به تاکید است که میدان کرنش گزارش شده در این پژوهش از مشتقات مکانی میدان سرعت درون‌یابی شده محاسبه شده است و به‌طور مستقیم تابعی از فرض الاستیسته خطی نیست. با این حال، میدان سرعت ورودی تحت تاثیر قید الاستیسته خطی در فرایند آموزش PINN قرار داشته است. بنابراین، تاثیر غیرمستقیم این فرض بر میدان کرنش گریزناپذیر است.

همسو می‌باشد، اما مقایسه کمی نظام‌مند میان کرنش ژئودتیکی حاصل از مدل PINN و کرنش لرزه‌ای محاسبه‌شده از کاتالوگ زمین‌لرزه‌ها در چهارچوب این پژوهش انجام نشده است. انجام چنین مقایسه‌ای با استفاده از روش کاستروف (Kostrov, 1974) و به کارگیری کاتالوگ لرزه‌ای جامع ایران می‌تواند موضوع پژوهش مستقلی باشد. همخوانی الگوهای کرنش استخراج شده از مدل PINN با موقعیت و روند گسل‌های اصلی منطقه در این پژوهش به صورت کیفی و مبتنی بر تطابق بصری ارزیابی شده است. اگرچه این تطابق با یافته‌های مطالعات ژئودتیکی پیشین در البرز



شکل ۱۴- بیشینه کرنش برشی به همراه گسل‌ها. مقادیر کرنش برشی بیشینه به عنوان شاخص پتانسیل لرزه‌خیزی.

Figure 14. Maximum shear strain along with faults. Maximum shear strain values as an indicator of seismic potential.



شکل ۱۵- ناوردای دوم تانسور کرنش به همراه گسل‌های اصلی. این ناوردا معیاری از شدت کلی تغییر شکل در منطقه است. تمرکز مقادیر بالا در امتداد گسل‌های اصلی قابل مشاهده است.

Figure 15. Second invariant of the strain tensor along with major faults. This invariant is a measure of the overall deformation intensity in the region. Concentration of high values along major faults is evident.

۴-۷- مقایسه با روش‌های متداول

مقایسه نتایج حاصل از روش پیشنهادی با روش متداول درون‌یابی مبتنی بر توابع گرین الاستیک نشان می‌دهد که روش PINN از دقت بالاتری برخوردار است. برای اطمینان از مقایسه‌ای منصفانه، پارامترهای فیزیکی مشترک (از جمله نسبت پواسون) در هر دو روش یکسان در نظر گرفته شد و پارامتر هموارسازی در روش توابع گرین با استفاده از اعتبارسنجی متقابل (Cross-Validation) روی همان مجموعه داده‌های آموزش-آزمون بهینه گردید. همچنین شرایط مرزی در هر دو روش به صورت شرایط مرزی طبیعی (نیروی صفر در مرزهای دور) اعمال شد. با این حال، باید توجه داشت که تفاوت‌های ذاتی در فرمولاسیون دو روش از جمله ماهیت بهینه‌سازی (خطی در توابع گرین در مقابل غیرخطی در PINN) و نیز نحوه اعمال شرایط مرزی (قیود سخت در توابع گرین در مقابل قیود نرم در PINN) می‌تواند بر نتایج مقایسه تاثیرگذار باشد.

با وجود این تفاوت‌ها، روش PINN در مناطقی با توپوگرافی پیچیده و تغییرات شدید میدان سرعت، تا ۲۵ درصد خطای کمتری نشان می‌دهد. همچنین، روش پیشنهادی در حفظ پیوستگی میدان سرعت و پرهیز از نوسانات کاذب عملکرد بهتری دارد. از نظر محاسباتی، روش پیشنهادی اگرچه به زمان آموزش بیشتری نیاز دارد، اما در مرحله پیش‌بینی بسیار کارآمد عمل می‌کند. این ویژگی سبب می‌شود که این روش برای کاربردهای عملی مانند به‌روزرسانی آبی میدان‌های سرعت مناسب باشد. همچنین، انعطاف‌پذیری روش در ادغام داده‌های جدید بدون نیاز به محاسبات سنگین، از مزایای مهم آن به‌شمار می‌رود.

نکته مهم در ارزیابی کارایی محاسباتی روش پیشنهادی، تمایز میان مرحله آموزش و مرحله پیش‌بینی است. اگرچه آموزش اولیه مدل PINN حدود ۴۵ دقیقه زمان می‌برد، اما این فرایند تنها یک بار و به صورت برون‌خط انجام می‌شود. پس از ذخیره‌سازی وزن‌های آموزش‌دیده، مدل قادر است میدان سرعت پیوسته را برای هر نقطه از منطقه در کسری از ثانیه (چند میلی‌ثانیه) پیش‌بینی کند. این ویژگی، روش پیشنهادی را برای سامانه‌های پایش آبی و به‌روزرسانی مکرر میدان سرعت بسیار مناسب می‌سازد. در مقابل، روش توابع گرین الاستیک با هر تغییر در داده‌های ورودی نیازمند حل مجدد یک سیستم معادلات خطی با ابعاد بزرگ است که با افزایش ابعاد منطقه یا تفکیک مکانی، هزینه محاسباتی آن به شدت افزایش می‌یابد.

۴-۸- تحلیل

نتایج این پژوهش نشان می‌دهد که عملکرد مطلوب مدل در محدوده نسبت پواسون ۰/۲۰ تا ۰/۲۷ کاملاً با ویژگی‌های مکانیکی سنگ‌های پوسته قاره‌ای در منطقه مطالعاتی همخوانی دارد. مقدار بهینه ۰/۲۳ که از فرایند بهینه‌سازی مدل PINN به‌دست آمده، با مقادیر گزارش‌شده برای پوسته قاره‌ای در مناطق کوهزایی جوان (محدوده ۰/۲۵ تا ۰/۰۴) مطابقت شایان توجهی دارد (Zandt and Ammon, 1995). این همخوانی نشان می‌دهد که مدل PINN قادر است به طور خودکار پارامترهای فیزیکی بهینه را در فرایند آموزش شناسایی کند و پتانسیل بالای روش‌های مبتنی بر یادگیری ماشین آگاه از فیزیک را برای حل مسائل معکوس در علوم زمین به نمایش می‌گذارد.

در مقایسه با روش مرسوم توابع گرین کشسان، روش پیشنهادی از مزایایی همچون انعطاف‌پذیری بالاتر در مدل‌سازی نواحی با تغییرات شدید میدان سرعت، قابلیت ادغام مستقیم عدم قطعیت داده‌ها، و امکان تلفیق ساده‌تر با داده‌های دیگر مانند InSAR برخوردار است. این ویژگی‌ها سبب می‌شود روش PINN به‌ویژه در مناطق با داده‌های پراکنده و ناهمگن عملکرد بهتری داشته باشد. با این حال، پیچیدگی محاسباتی بیشتر، نیاز به منابع سخت‌افزاری قوی‌تر، و وابستگی به تنظیم دقیق فرآیندها از چالش‌های این روش به‌شمار می‌روند.

توزیع فضایی خطاها و عدم قطعیت پیش‌بینی‌ها اطلاعات ارزشمندی درباره

ساختار ژئودینامیکی منطقه ارائه می‌دهد. تمرکز خطاها در امتداد گسل‌های اصلی (شکل ۵-ب) می‌تواند ناشی از عدم توانایی مدل کشسان خطی در بازتولید کامل رفتار غیرخطی پوسته در مجاورت گسل‌ها باشد و همچنین نشان‌دهنده نیاز به داده‌های با تراکم بالاتر در این مناطق حساس است. این یافته می‌تواند در طراحی مطالعات آینده و استقرار ایستگاه‌های GPS جدید مورد استفاده قرار گیرد.

استفاده از معادلات الاستیسیته خطی صفحه‌ای به عنوان قید فیزیکی، اگرچه برای مدل‌سازی میدان سرعت بین‌لرزه‌ای در مقیاس منطقه‌ای قابل قبول است، اما در نواحی با رفتار پوسته‌ای پیچیده‌تر (به‌ویژه نزدیک گسل‌های اصلی) یک ساده‌سازی به‌شمار می‌رود. رفتار واقعی پوسته در البرز می‌تواند شامل مولفه‌های گران‌روی کشسان، پلاستیک، یا غیرخطی باشد که در مدل حاضر در نظر گرفته نشده‌اند. همچنین، میدان تنش به دلیل وابستگی شدید به فرض کشسان خطی و عدم قطعیت در پارامترهای کشسان محاسبه و گزارش نشده است.

حساسیت مدل‌های PINN به کیفیت داده‌های ورودی، اهمیت فرایند پالایش داده‌ها را دوچندان می‌کند. در این پژوهش، داده‌های GPS استخراج‌شده از مطالعه خرمی و همکاران (Khorrami et al., 2019) مطابق شرح داده شده در بخش ۳-۱-۱، تحت پالایش چندمرحله‌ای قرار گرفته‌اند که شامل حذف ایستگاه‌های تحت تاثیر پدیده‌های محلی غیرزمین‌ساختی بوده است. نتایج نشان می‌دهند استفاده از داده‌های پالایش‌شده با کنترل کیفیت دقیق، دقت مدل را افزایش داده و از بروز ارب ناشی از سیگنال‌های محلی نامرتبب جلوگیری می‌کند.

ارزیابی مدل در این پژوهش مبتنی بر تقسیم تصادفی داده‌ها بوده و قابلیت تعمیم مکانی آن در نواحی بدون داده به‌طور کامل سنجیده نشده است. برای ارزیابی دقیق‌تر قابلیت تعمیم‌پذیری، انجام آزمون‌های اعتبارسنجی مکانی نظیر اعتبارسنجی متقابل مکانی، حذف منطقه‌ای، و آزمون برون‌یابی در پژوهش‌های آبی ضروری است. همچنین، برآورد عدم قطعیت با روش مبتنی بر شرایط اولیه تصادفی، اگرچه عملی است، اما جامعیت روش‌های ییزی یا مبتنی بر انصراف (Dropout) را ندارد.

محدودیت‌های مهم دیگر شامل بسنده کردن به مقایسه کیفی میدان کرنش با ساختارهای گسلی، عدم لحاظ مستقیم ماتریس کواریانس خطای مشاهدات GPS در تابع هزینه، و اتکا به انتخاب تجربی معماری شبکه و فرآیندها است. اگرچه تطابق بصری الگوهای کرنش با روند گسل‌های اصلی در شکل‌های ۱۱ تا ۱۵ مشاهده می‌شود، اما برای ارزیابی دقیق‌تر عملکرد مدل، تحلیل کمی با استفاده از روش کاستروف (Kostrov, 1974) و مقایسه نرخ کرنش لرزه‌ای با نرخ کرنش ژئودیتیکی ضروری است. در ایران، مطالعات پیشین (Masson et al., 2005; Rashidi et al., 2022) نشان داده‌اند که نسبت تغییرشکل لرزه‌ای به کل تغییرشکل در البرز بین ۳۰ تا ۱۰۰ درصد متغیر است.

در پژوهش‌های آبی، توصیه می‌شود با رویکردی کمی‌تر به این مسائل پرداخته شود: مقایسه کمی میدان کرنش حاصل از PINN با نرخ‌های لغزش گسل‌های اصلی، محاسبه همبستگی مکانی بین نرخ کرنش برشی پیشینه و تراکم گسلی، کمی‌سازی زاویه بین محورهای کرنش اصلی و راستای گسل‌ها، و محاسبه نسبت نرخ ممان لرزه‌ای به ژئودیتیکی برای زیرپهنه‌های مختلف البرز. همچنین، تلفیق واریانس مشاهدات به صورت وزن‌های معکوس واریانس در تابع هزینه PINN، استفاده از روش‌های پیشرفته بهینه‌سازی فرآیندها مانند بهینه‌سازی ییزی و الگوریتم‌های تکاملی، و به‌کارگیری داده‌های لرزه‌ای توابع گیرنده برای تعیین تجربی نسبت پواسون از اولویت‌های پژوهشی آینده هستند. اجرای این اقدامات می‌تواند شکاف بین بهینه‌سازی عددی و واقعیت فیزیکی را کاهش داده و اعتبار مدل‌های PINN را در کاربردهای ژئودینامیکی ارتقا دهد.

۴-۹- کاربردها و پیامدها

روش پیشنهادی می‌تواند تحول مهمی در مطالعات زمین‌ساختی ایجاد کند. با تولید

در تلفیق انواع مختلف داده‌ها و معادلات. با این حال، روش‌های مبتنی بر فرایند گاوسی در مدل‌سازی مستقیم عدم قطعیت و روش‌های RBF در سرعت آموزش دارای مزایایی هستند. انجام یک مطالعه تطبیقی جامع میان PINN، GPR، کریجینگ، و RBF با استفاده از مجموعه داده‌های مشترک و معیارهای ارزیابی یکسان برای پژوهش‌های آتی پیشنهاد می‌شود.

۵- نتیجه‌گیری

این پژوهش نشان داد که شبکه‌های عصبی آگاه از فیزیک (PINN) ابزاری قدرتمند برای درون‌یابی بردارهای سرعت GPS به‌شمار می‌روند. روش پیشنهادی ضمن برخورداری از دقت محاسباتی بالا (RMSE برابر ۰/۶۸ و ۰/۹۹ میلی‌متر بر سال به ترتیب برای مولفه‌های خاوری و شمالی)، راه‌حل‌های فیزیکی معتبری تولید می‌کند که با ویژگی‌های مکانیکی پوسته زمین سازگاری دارد. مهم‌ترین دستاوردهای این پژوهش را می‌توان در ۳ محور خلاصه کرد: در بعد روش‌شناختی، ارائه نخستین چهارچوب سامانه‌مند برای درون‌یابی بردارهای سرعت GPS با PINN؛ در بعد کاربردی، توسعه روشی عملی برای تلفیق داده‌های GPS و InSAR در چهارچوب یادگیری ماشین؛ و در بعد نظری، گسترش مرزهای دانش در زمینه تلفیق فیزیک و یادگیری ماشین در علوم زمین.

جهت‌گیری‌های متعددی برای توسعه این پژوهش پیشنهاد می‌شود: در حوزه توسعه مدل‌های پیشرفته‌تر، تلفیق رفتارهای غیرکشسان و گران‌روی کشسان در معادلات حاکم، توسعه مدل‌های سه‌بعدی و استفاده از معادلات مبتنی بر ترمودینامیک؛ در حوزه تلفیق داده‌ها، ترکیب مشاهدات GPS با InSAR، داده‌های گرانشی ماهواره‌ای و لرزه‌ای برای کاهش عدم قطعیت در مناطق با پوشش کم ایستگاهی؛ و در حوزه کاربردهای عملی، ایجاد سامانه‌های آنتی رفتارسنجی تغییرشکل، توسعه رابط‌های کاربرپسند و استانداردسازی روش.

از اولویت‌های پژوهشی آینده می‌توان به کمی‌سازی ارتباط میدان کرنش با ساختارهای گسلی از طریق محاسبه همبستگی مکانی، مقایسه جهت‌های کرنش با محورهای تنش حاصل از وارون‌سازی سازوکار ژرفی زمین‌لرزه‌ها، و برآورد نسبت کرنش لرزه‌ای به ژئودتیک با روش کاستروف (Kostrov, 1974) اشاره کرد. همچنین، انجام مقایسه نظام‌مند میان PINN و سایر روش‌های مدرن درون‌یابی (مانند فرایند گاوسی، کریجینگ، شبکه‌های مبتنی بر توابع پایه شعاعی و یادگیری عمیق) و انجام مطالعات لرزه‌ای برای تعیین تجربی نسبت پواسون پوسته در البرز (از طریق تحلیل توابع گیرنده و توموگرافی Vp/Vs) از دیگر گام‌های ضروری برای اعتبارسنجی مستقل مدل‌های ژئودتیک است.

میدان‌های سرعت پیوسته و دقیق، امکان شناسایی مرزهای صفحه‌ای، تحلیل تغییر شکل‌های توزیع شده و مطالعه برهمکنش بین گسل‌های مختلف فراهم می‌شود. این اطلاعات برای ارزیابی خطر زلزله و مدیریت ریسک سوانح طبیعی حیاتی است. در مقیاس بزرگ‌تر، این روش می‌تواند برای مطالعه فرایندهای ژئودینامیکی مانند فرورانش صفحه‌ها، برخورد قاره‌ها و حرکت صفحه‌های سنگ‌سپهر به کار رود. دقت بالای روش در ترکیب با پوشش وسیع داده‌های GPS و InSAR می‌تواند بینش‌های جدیدی درباره دینامیک ژرفای زمین ارائه دهد. همچنین، این روش می‌تواند برای بررسی تغییر شکل‌های بین لرزه‌ای و تحلیل چرخه زمین‌لرزه مورد استفاده قرار گیرد. یکی از کاربردهای امیدوارکننده روش پیشنهادی، استفاده در سیستم‌های رفتارسنجی آنتی تغییر شکل پوسته است. با آموزش مدل بر روی داده‌های تاریخی، می‌توان از آن برای تشخیص ناهنجاری‌ها در الگوی تغییر شکل استفاده کرد. این ناهنجاری‌ها می‌توانند نشان‌دهنده تجمع تنش در گسل‌ها و آماده‌باش برای رویدادهای لرزه‌ای باشند. ترکیب این روش با داده‌های InSAR که پوشش مکانی بالایی دارند، می‌تواند سیستم هشدار زودهنگام قدرتمندی ایجاد کند. این سیستم قادر خواهد بود نواحی با نرخ تغییر شکل غیرعادی را شناسایی کرده و هشدارهای لازم را صادر کند. افزون بر این، این روش می‌تواند برای رفتارسنجی تغییر شکل‌های ناشی از فعالیت‌های انسانی مانند استخراج معادن و برداشت آب‌های زیرزمینی نیز به کار رود.

نتایج این پژوهش پیامدهای مهمی برای طراحی و بهینه‌سازی شبکه‌های GPS دارد. تحلیل عدم قطعیت نشان می‌دهد که چگونه تراکم و توزیع ایستگاه‌ها بر دقت مدل‌سازی تاثیر می‌گذارد. این اطلاعات می‌تواند برای شناسایی نقاط کور در شبکه‌های موجود و استقرار بهینه ایستگاه‌های جدید مورد استفاده قرار گیرد. همچنین، این روش می‌تواند برای تلفیق بهینه داده‌های GPS و InSAR به کار رود. با در نظرگیری عدم قطعیت هر یک از این روش‌ها، می‌توان ترکیب بهینه‌ای ایجاد کرد که از مزایای هر دو روش بهره‌بردارد. این رویکرد می‌تواند به طراحی شبکه‌های ترکیبی کارآمدتری بیانجامد که هم از دقت بالای GPS و هم از پوشش مکانی گسترده InSAR بهره‌بردارند.

یکی از محدودیت‌های این پژوهش، عدم مقایسه کمی و نظام‌مند روش PINN با سایر روش‌های مدرن درون‌یابی (مانند فرایند گاوسی، کریجینگ، و شبکه‌های عصبی RBF) است. اگرچه هدف اصلی مقاله مقایسه با روش کلاسیک توابع گرین بود، اما آگاهی از جایگاه PINN در میان مجموعه کامل روش‌های موجود مفید خواهد بود. بر اساس مرور ادبیات، مزایای مفهومی PINN نسبت به این روش‌ها عبارتند از: (۱) گنجاندن مستقیم قوانین فیزیکی در فرایند یادگیری، (۲) مستقل بودن از شبکه محاسباتی و ساختار هندسی از پیش تعریف شده، و (۳) انعطاف‌پذیری بالا

References

- Anitescu, C., İsmail Ateş, B., and Rabczuk, T., 2023. Physics-Informed Neural Networks: Theory and Applications. In: Machine learning in modeling and simulation, Chapter 5, pp. 179-218.
- Boresi, A. P., and Schmidt, R. J., 2002. Advanced mechanics of materials. John Wiley & Sons.
- Cuomo, S., Di Cola, V. S., Giampaolo, F., Rozza, G., Raissi, M., and Piccioli, F., 2022. Scientific machine learning through physics-informed neural networks: Where we are and what's next. Journal of Scientific Computing, 92(3), 88.
- Dahal, A., and Lombardo, L., 2025. Towards physics-informed neural networks for landslide prediction. Engineering Geology, 344, 107852.
- Ghods A., Shabani E., Bergman E., Faridi M., Donner S., Mortezaejad G., and Aziz-Zanjani A., 2015. The Varzaghan-Ahar, Iran, Earthquake Doublet (Mw 6.4, 6.2): implications for the geodynamics of northwest Iran. Geophys. J. Int., 203, 522-540.
- Hessami, K., Jamali, F., and Tabassi, H., 2003. Major Active Faults of Iran (map), Ministry of Science, Research and Technology, International Institute of Earthquake Engineering and Seismology.
- Hornik, K., Stinchcombe, M., and White, H., 1989. Multilayer feedforward networks are universal approximators. Neural networks, 2(5), 359-366.

- Karniadakis, G. E., Kevrekidis, I. G., Lu, L., Perdikaris, P., Wang, S., and Yang, L., 2021. Physics-informed machine learning. *Nature Reviews Physics*, 3(6), 422-440.
- Kay, S. M., 1993. *Fundamentals of statistical signal processing: estimation theory*. Prentice-Hall, Inc.
- Khorrami F., Vernant P., Masson F., Nilfouroushan F., Mousavi Z., Nankali H., Saadat S. A., Walpersdorf A., Hosseini S., Tavakoli P., Aghamohammadi A., and Alijanzade M., 2019. An up-to-date crustal deformation map of Iran using integrated campaign-mode and permanent GPS velocities. *Geophys. J. Int.*, 217, 832-843.
- Kostrov, V. V., 1974. Seismic moment and energy of earthquakes, and the seismic flow of rock, *Izv. Acad. Sci. USSR. Phys. Solid Earth*, 1, 23-44.
- Leys, C., Ley, C., Klein, O., Bernard, P., and Licata, L., 2013. Detecting outliers: Do not use standard deviation around the mean, use absolute deviation around the median. *Journal of experimental social psychology*, 49(4), 764-766.
- Masson, F., Chéry, J., Hatzfeld, D., Martinod, J., Vernant, P., Tavakoli, F., and Ghafory-Ashtiani, M., 2005. Seismic versus aseismic deformation in Iran inferred from earthquakes and geodetic data. *Geophysical Journal International*, 160(1), 217-226.
- Masson, F., Lehujeur, M., Ziegler, Y., and Doubre, C., 2014. Strain rate tensor in Iran from a new GPS velocity field. *Geophysical Journal International*, 197(1), 10-21.
- Maurer, J., and Materna, K., 2023. Quantification of geodetic strain rate uncertainties and implications for seismic hazard estimates. *Geophysical Journal International*, 234(3), 2128-2142.
- Motavalli-Anbaran, S. H., Zeyen, H., Brunet, M. F., and Ardestani, V. E., 2011. Crustal and lithospheric structure of the Alborz Mountains, Iran, and surrounding areas from integrated geophysical modeling. *Tectonics*, 30(5).
- Okazaki, T., Ito, T., Hirahara, K., and Ueda, N., 2022. Physics-informed deep learning approach for modeling crustal deformation. *Nature Communications*, 13(1), 7092.
- Okazaki, T., Fukahata, Y., and Nishimura, T., 2021. Consistent estimation of strain-rate fields from GNSS velocity data using basis function expansion with ABIC. *Earth, Planets and Space*, 73(1), 153.
- Poulet, T., and Behnoudfar, P., 2023. Physics-informed neural network reconciles Australian displacements and tectonic stresses. *Scientific Reports*, 13(1), 23095.
- Raissi, M., Perdikaris, P., and Karniadakis, G. E., 2019. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686-707.
- Rashidi, A., Kianimehr, H., Yamini-Fard, F., Tatar, M., and Zafarani, H., 2022. Present stress map and deformation distribution in the NE Lut Block, eastern Iran: Insights from seismic and geodetic strain and moment rates. *Pure and Applied Geophysics*, 179(5), 1887-1917.
- Rastboud, A., 2023. Present-day crustal deformation in Alborz region based on GPS velocity field and spline functions. *Iranian Journal of Geophysics (IJG)*, 17(2).
- Rastboud, A., Salmanian, M., and Hossainali, M. M., 2024. Present-day crustal deformation based on an interpolated GPS velocity field in the collision zone of the Arabia-Eurasia tectonic plates. *Studia Geophysica et Geodaetica*, 68(3), 191-215.
- Sadd, M. H., 2009. *Elasticity: theory, applications, and numerics*. Academic Press.
- Sandwell, D. T., and Wessel, P., 2016. Interpolation of 2-D vector data using constraints from elasticity. *Geophysical Research Letters*, 43(10), 10,703-10,709.
- Shen, Z. K., Wang, M., Zeng, Y., and Wang, F., 2015. Optimal interpolation of spatially discretized geodetic data. *Bulletin of the Seismological Society of America*, 105(4), 2117-2127.
- Shen, Z. K., Jackson, D. D., and Ge, B. X., 1996. Crustal deformation across and beyond the Los Angeles basin from geodetic measurements. *Journal of Geophysical Research: Solid Earth*, 101(B12), 27957-27980.
- Talebian, M., Ghorashi, M., and Nazari, H., 2013. *Seismotectonic map of the Central Alborz*, Research Institute for Earth Sciences, Geological Survey of Iran.
- Zandt, G., and Ammon, C. J., 1995. Continental crust composition constrained by measurements of crustal Poisson's ratio. *Nature*, 374(6518), 152-154.