

Full Waveform Inversion Using a Physics-based Recurrent Neural Network

Saadat, M.¹  | Hashemi, H.¹  | Nabi-Bidhendi, M.¹ 

1. Department of Earth Physics, Institute of Geophysics, University of Tehran, Tehran, Iran.

Corresponding Author E-mail: mnbhendi@ut.ac.ir

(Received: 8 Feb 2025, Revised: 15 Feb 2025, Accepted: 29 April 2025, Published online: 20 Sep 2025)

Summary

Full-waveform inversion (FWI) is an advanced technique used to estimate the elastic properties of subsurface environment based on the seismic data. This method incorporates all available information from the amplitude, phase, and frequency of seismic waves, also referred to as the full-waveform. By considering the full waveform, FWI reconstructs the high-resolution models, which play a significant role in seismic imaging and are crucial for accurate subsurface characterization. However, achieving such high-resolution models comes with its own set of challenges, including the need for extensive computational power, long processing times, high dependency to the initial model, and stability and non-uniqueness problems which can sometimes limit the accuracy of the inversion process.

Considering the area of machine learning (ML) and deep learning (DL) which have been revolutionized in the recent years, researchers have increasingly concentrated on these methods to improve the efficiency and accuracy of FWI. Wavefield simulation in time domain is intrinsically recursive, so that wavefield in a certain point on time axis depends on the past history of the propagation. Considering this specification, we propose a deep recurrent neural network (RNN) block, corresponding to wave equation which can be used for forward modeling. In this approach, the velocity model of the medium is proportional to a learnable weight matrix in one of the deep network layers. The proposed method operates in an iterative scheme in which the deep learning block is used to predict seismic data. The difference between the predicted data and the observed seismic data is then computed at each iteration, and the gradient of the loss function with respect to the learnable parameters is calculated. This gradient is then used to update the model, effectively refining the velocity model to better match the observed seismic data. This process continues until the model converges to a solution that best fits the observations. One of the most important advantages of the proposed method is to increase the calculation speed. By leveraging the parallel computing capabilities of Graphics Processing Units (GPUs) and by mapping different seismic sources onto the mini-batch property of the deep recurrent neural network, the computation time is decreased by a factor hundreds of times.

The proposed algorithm was applied to the Marmousi model, both for synthetic data simulation and for full-waveform inversion. The results showed that the method was capable of accurately reconstructing the subsurface velocity model. The algorithm was assessed using quantitative metrics including L1 norm, L2 norm, Peak signal to noise Ratio (PSNR), and Structural Similarity Index Measure (SSIM), demonstrating a high degree of accuracy in model reconstruction. Conventional optimization methods which are commonly used in training of deep learning methods including Stochastic Gradient Descent Method (SGDM), RMSProp, and Adaptive Momentum (ADAM), were also applied to this problem. Among them, ADAM showed the best performance in terms of fitting the model to the observed data and its power in searching the model space. This optimization technique helped ensure that the inversion process converged more quickly and accurately. So that, SSIM between reconstructed and true models increased from 0.73 for Gradient Descent method (which is conventional optimization algorithm in FWI) to 0.77 for ADAM.

Keywords: Inversion, Full Waveform, Deep Learning, Physics based, Recurrent Neural Network.

Cite this article: Saadat, M., Hashemi, H., & Nabi-Bidhendi, M. (2025). Full Waveform Inversion Using a Physics-based Recurrent Neural Network. *Journal of the Earth and Space Physics*, 51(2), 325- 338. DOI: <http://doi.org/10.22059/jesphys.2025.390086.1007668>

E-mail: (1) mahdi.saadat@ut.ac.ir | hashemy@ut.ac.ir



© Authors Retain the Copyright and Full Publishing Rights.

Publisher: University of Tehran Press.

DOI: <http://doi.org/10.22059/jesphys.2025.390086.1007668>

Print ISSN: 2538-371X
Online ISSN: 2538-3906

وارون‌سازی شکل موج کامل با استفاده از یک شبکه عصبی بازگشتی مبتنی بر فیزیک مسئله

مهدی سعادت^۱ | حسین هاشمی^۱ | مجید نبی بیدهندی^۱✉

۱. گروه فیزیک زمین، مؤسسه ژئوفیزیک، دانشگاه تهران، تهران، ایران.

رایانامه نویسنده مسئول: mnbhendi@ut.ac.ir

(دریافت: ۱۴۰۳/۱۱/۲۰، بازنگری: ۱۴۰۳/۱۱/۲۷، پذیرش نهایی: ۱۴۰۴/۲/۹، انتشار آنلاین: ۱۴۰۴/۶/۲۹)

چکیده

وارون‌سازی شکل موج کامل روشی برای تخمین خواص الاستیک محیط است که همه اطلاعات موجود در داده‌های لرزه‌ای، شامل اطلاعات دامنه، فاز و فرکانس، را برای تخمین مدل‌هایی با قدرت تفکیک بالا به کار می‌گیرد. این روش در تصویرسازی صحیح لرزه‌ای اهمیت ویژه‌ای دارد، اما با چالش‌هایی چون نیاز به زمان و توان محاسباتی بالا و وابستگی به مدل اولیه مواجه است. پژوهشگران متعددی سعی در استفاده از روش‌های یادگیری عمیق برای غلبه بر چالش‌های مسئله وارون‌سازی شکل موج کامل داشته‌اند. این مقاله نیز یک بلوک یادگیری عمیق بازگشتی مبتنی بر معادله موج ارائه می‌دهد که سرعت محیط با ماتریس وزنی یکی از لایه‌های آن، مرتبط است. در فرایندی تکراری، از این بلوک برای پیش‌بینی داده لرزه‌ای استفاده می‌شود و سپس با مقایسه با داده مشاهده‌ای، تابع خطا و گرادین آن محاسبه و وزن‌های شبکه، شامل مدل سرعتی، به‌روزرسانی می‌شود. مزیت این روش، سرعت بالای محاسبات است، چراکه استفاده همزمان از واحد پردازش گرافیکی و شبیه‌سازی دسته‌ای و موازی چشمه‌های مختلف موجب تسریع چند صد برابری فرایند می‌شود. الگوریتم پیشنهادی بر مدل مارموزی برای شبیه‌سازی داده‌های مصنوعی و وارون‌سازی شکل موج کامل اعمال شد. همچنین، روش‌های بهینه‌سازی مرسوم در یادگیری عمیق مورد ارزیابی قرار گرفتند که از این بین روش مونتوم انطباقی بهترین عملکرد را از خود نشان داد، به‌طوری‌که شاخص شباهت ساختاری مابین مدل صحیح و مدل بازسازی‌شده، از 0.73 برای روش سریع‌ترین شیب، که روش متداول بهینه‌سازی در مسئله وارون‌سازی شکل موج است، به 0.77 برای روش مونتوم انطباقی افزایش یافته است.

واژه‌های کلیدی: وارون‌سازی، شکل موج کامل، یادگیری عمیق، مبتنی بر فیزیک، شبکه عصبی بازگشتی.

۱. مقدمه

ریاضیاتی ضابطه‌مندی بین ورودی و خروجی وجود ندارد، این روش‌ها یک انتخاب مناسب برای یادگیری یک ارتباط تجربی بین جفت‌های ورودی و خروجی می‌باشند. اما در برخی از مسائل رگرسیون، روابط و مدل‌های ریاضیاتی و فیزیکی ضابطه‌مندی بین داده‌ها برقرار است. در چنین شرایطی استفاده از روش‌های کاملاً مبتنی بر داده این مزیت را دارد که از دشواری کار با مدل‌های پیچیده ریاضیاتی می‌کاهد در حالی که برای به‌دست آوردن یک تابع نگاشت تعمیم‌پذیر برای چنین مسائل پیچیده‌ای به حجم بسیار زیادی از داده‌های متنوع نیاز داریم که حجم و زمان محاسبات را به‌طور فزاینده‌ای افزایش می‌دهد. یک راهکار جایگزین برای نیل به یک تابع نگاشت تعمیم‌پذیر در مسائل

روش‌های یادگیری عمیق که زیر مجموعه روش‌های یادگیری ماشین هستند، بدلیل قابلیت یادگیری فرایندهای پیچیده و از طرفی پیشرفت‌های محاسبات موازی، اخیراً به‌شکل ویژه‌ای مورد توجه قرار گرفته‌اند (آگارول، ۲۰۲۳). در بخش‌های مختلف حوزه ژئوفیزیک و لرزه‌نگاری اعم از پردازش (سعادت و همکاران، ۲۰۲۴a)، تفسیر (سعادت و همکاران، ۲۰۲۲)، و وارون‌سازی داده‌های لرزه‌ای (بیسواس و همکاران، ۲۰۱۹) نیز این روش‌ها مکرراً استفاده شده‌اند.

مسائلی که با استفاده از یادگیری عمیق مورد بررسی قرار می‌گیرند، عمدتاً به مسائل دسته‌بندی و رگرسیون تقسیم می‌شوند. در مسائل دسته‌بندی از آنجا که معمولاً رابطه

استناد: سعادت، مهدی؛ هاشمی، حسین و نبی بیدهندی، مجید (۱۴۰۴). وارون‌سازی شکل موج کامل با استفاده از یک شبکه عصبی بازگشتی مبتنی بر فیزیک مسئله، مجله فیزیک

زمین و فضا، ۵۱(۲)، ۳۲۵-۳۳۸. DOI: <http://doi.org/10.22059/jesphys.2025.390086.1007668>

رایانامه: (۱) hashemy@ut.ac.ir | mahdi.saadat@ut.ac.ir



ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <http://doi.org/10.22059/jesphys.2025.390086.1007668>

پردازش بزرگی است. از آنجا که پهنای باند فرکانسی داده لرزه‌ای محدود است، مدل اولیه باید حاوی طول موج‌های بلند مدل سرعتی باشد زیرا اطلاعات هم‌ارز آنها در داده لرزه‌ای وجود ندارد. یک راهکار مؤثر برای همگراشدن فرایند بهینه‌سازی، به کارگرفتن روش وارون‌سازی شکل موج کامل چند مقیاسی است که در آن ابتدا فرکانس‌های پایین داده، برای بازسازی طول موج‌های بلند مدل استفاده می‌شوند و رفته‌رفته جزئیات به مدل اضافه می‌شود (بونیا سیریوات و همکاران، ۲۰۰۹).

در سال‌های اخیر تلاش‌های زیادی برای استفاده از روش‌های یادگیری عمیق برای حل چالش‌های مسئله ساخت مدل سرعتی و وارون‌سازی شکل موج کامل صورت گرفته است. محققین متعددی از روش‌های کاملاً مبتنی بر داده (Data-Driven) برای تخمین مستقیم اپراتور وارون استفاده کرده‌اند (آریپلو و همکاران، ۲۰۱۸؛ وو و لین، ۲۰۱۹؛ ینگ و ما، ۲۰۱۸؛ لی و همکاران، ۲۰۱۹؛ ژنگ و لین، ۲۰۲۰؛ سعادت و همکاران، ۲۰۲۴b). هدف بلند پروازانه این روش‌ها تخمین مستقیم مدل سرعتی از داده لرزه‌ای بدون در نظر گرفتن فیزیک مسئله می‌باشد که موفقیت‌های محدودی در این زمینه نیز به دست آمده است اما تا دستیابی به یک مدل تعمیم‌پذیر قابل استفاده برای محیط‌های مختلف هنوز فاصله دارد. چرا که این روش‌ها عمدتاً با استفاده از داده‌ها و مدل‌های مصنوعی بسیار ساده آموزش دیده‌اند و سپس بر مدل‌های ساده‌ای از همان مجموعه داده آزمایش شده‌اند (هاشمی و همکاران، ۲۰۲۱).

در یک تلاش واقع‌گرایانه‌تر پژوهشگران متعددی از روش‌های مبتنی بر فیزیک (Physics-Driven) برای حل مسئله وارون‌سازی شکل موج کامل به وسیله روش‌های یادگیری عمیق استفاده کرده‌اند (رن و همکاران، ۲۰۲۰؛ سانگ و الخلیفه، ۲۰۲۰؛ سان و الخلیفه، ۲۰۲۲؛ ده‌ارو و سن، ۲۰۲۲). در این دیدگاه، معادله موج در تابع خطای شبکه عصبی استفاده می‌شود تا علاوه بر تخمین مدل، شبکه قادر به برازش به داده مشاهده‌ای نیز باشد و مسئله تخمین مدل سرعتی در چارچوب یادگیری عمیق به صورت غیر نظارتی

رگرسیون، دخالت دادن فیزیک مسئله در فرایند یادگیری می‌باشد (کارنیاداکیس و همکاران، ۲۰۲۱).

وارون‌سازی شکل موج کامل (FWI) یک روش ساخت مدل سرعتی با قدرت تفکیک بالا از داده لرزه‌ای می‌باشد که با چالش‌های متعددی مواجه است (ویریوکس و اپرتو، ۲۰۰۹). محاسبه چنین مدل سرعتی دقیقی در دستیابی به یک تصویر صحیح از بازتابنده‌های زیرسطحی و مهاجرت درست پدیده‌ها بسیار کمک‌کننده است (شوستر، ۲۰۱۷). برای حصول یک مدل سرعتی دقیق باید به چالش‌های متعددی که مسئله وارون‌سازی شکل موج کامل با آن روبه‌رو است، غلبه کرد. از جمله این چالش‌ها می‌توان به حجم بالای محاسبات و زمانبر بودن آن، وابستگی شدید به مدل اولیه و ساخت مدل اولیه و مشکل پایداری و غیریکتایی مسئله وارون اشاره کرد. یک راهکار برای حل مسئله پایداری و غیریکتایی استفاده از تکنیک منظم‌سازی به منظور به کارگیری اطلاعات چاه برای مقید ساختن مسئله و هدایت آن به سمت پاسخ صحیح می‌باشد. درحالی‌که ریشه زمانبر بودن و محاسبات زیاد این روش در حل تفاضل متناهی (Finite Difference) معادله موج می‌باشد که برای کاهش آن می‌توان از محاسبات موازی برای شبیه‌سازی میدان موج استفاده کرد. فرایند وارون‌سازی شکل موج یک فرایند تکراری است که در هر تکرار میدان موج پیشرو و میدان موج پسرو در محیط مدل محاسبه شده و مدل بروز می‌شود. زمان لازم برای انجام این محاسبات وابسته به ابعاد مدل، تعداد پله‌های زمانی شبیه‌سازی، تعداد چشمه‌ها، تعداد تکرارهای فرایند، نحوه پیاده‌سازی (شبیه‌سازی موازی یا سری) و سخت‌افزار مورد استفاده است، به طوری که برای یک مدل دوبعدی، محاسبات هر تکرار از چند دقیقه تا چند ساعت زمان می‌برد، میزان حافظه لازم از مرتبه چند ده گیگابایت بوده و محاسبات با استفاده از پردازنده‌های چند هسته‌ای یا واحد پردازش گرافیکی معمولی امکان‌پذیر است. در مدل سه بعدی هر تکرار از چند ساعت تا چند روز طول می‌کشد و حافظه لازم از مرتبه چند صد گیگابایت است. به خاطر حجم عظیم داده‌ها و مدل، وارون‌سازی شکل موج سه بعدی نیازمند پردازنده‌های خوشه‌ای و منابع

حل شود.

در این مقاله یک شبکه عصبی بازگشتی عمیق (RNN) متناظر با معادله موج آکوستیک ارائه شده است که با دریافت ورودی‌های لازم، برداشت‌های چشمه مشترک را در لایه خروجی به کاربر می‌دهد. مدل سرعتی که وزن یکی از لایه‌های این شبکه عصبی می‌باشد، این قابلیت را دارد که در فرایند پس انتشار یادگیری شود. این فرایند به صورت تکراری ادامه می‌یابد تا داده مشاهده شده، توسط داده پیش‌بینی شده به وسیله شبکه، کاملاً برازش داده شود. در ادامه مبانی نظری مربوط به این بلوک شبکه عصبی بازگشتی مبتنی بر فیزیک انتشار امواج تبیین شده است و روش پیشنهادی بر داده مصنوعی مربوط به مدل مارموزی اعمال شده است. مطابق با معیارهای کمی به کار گرفته شده، این روش قادر به تخمین مدل سرعتی با دقت بالایی بوده است.

۲. روش پژوهش

فیزیک انتشار امواج مکانیکی در یک محیط الاستیک از قانون هوک تعمیم یافته و معادله حرکت تبعیت می‌کند. اگر محیط مورد نظر را به صورت کاملاً همسانگرد در نظر بگیریم، معادله موج را می‌توان به شکل رابطه (۱) نوشت:

$$\rho \frac{\partial^2 \mathbf{I}}{\partial t^2} = (\lambda + \mu) \nabla \Delta + \mu \nabla^2 \mathbf{I}, \quad (1)$$

در این رابطه $\mathbf{I}$ بردار حرکت، λ و μ ضرایب لامه، ρ چگالی، و Δ تغییر حجم جزئی می‌باشد (آکی و ریچارد، ۲۰۰۲). از آنجا که بیشتر چشمه‌های لرزه‌ای تنها امواج تراکمی تولید می‌کنند و در برداشت‌های دریایی، لایه آب مانع از انتشار امواج برشی می‌شود، استفاده از معادله موج آکوستیک (رابطه ۲) در شبیه‌سازی میدان موج رایج است. اگرچه این تقریب قادر به مدل‌سازی امواج تبدیل شده و تغییرات دامنه با دورافت نیست (الخلیفه، ۲۰۱۶)، اما شکل ساده‌تر این معادله موجب کاهش بار محاسباتی و زمان شبیه‌سازی می‌شود که استفاده از آن را در محیط‌های زمین‌شناسی نسبتاً ساده توجیه‌پذیر می‌سازد.

$$\frac{\partial^2 \mathbf{P}}{\partial t^2} = v^2 \nabla^2 \mathbf{P} + f(t, \mathbf{x}), \quad (2)$$

در این رابطه $\mathbf{P}$ میدان فشار، v سرعت انتشار و f جمله مربوط

به چشمه موج می‌باشد. متداول‌ترین رهیافت برای حل عددی این رابطه استفاده از تقریب تفاضل محدود است که لازمه آن گسسته‌سازی و شبکه‌بندی محیط می‌باشد (دابلین، ۱۹۸۶). تقریب تفاضل محدود رابطه (۲) به شکل زیر می‌باشد:

$$\mathbf{P}_{i,j}^{n+1} - (2 + v_{i,j}^2 \alpha^2 \nabla^2) \mathbf{P}_{i,j}^n + \mathbf{P}_{i,j}^{n-1} = f_{i,j}^n, \alpha^2 = \frac{\Delta t^2}{\Delta x^2}, \quad (3)$$

در این رابطه i ، j و n به ترتیب شمارنده‌های محورهای x ، z و زمان، Δx ، Δt اندازه پله زمانی و اندازه سلول شبکه و ∇^2 اپراتور لاپلاسین گسسته می‌باشد.

در هر پله زمانی از شبیه‌سازی انتشار موج با استفاده از روش تفاضل محدود، میدان جابه‌جایی یا فشار محیط الاستیک محاسبه می‌شود که مقدار آن وابسته به میدان موج در دو پله زمانی اخیر، مدل سرعت و توزیع زمانی و مکانی منبع تولید موج می‌باشد. از آنجا که معادله موج یک معادله مشتقات جزئی می‌باشد، شرایط مرزی و شرایط اولیه آن نیز بایستی تعیین شود. در رابطه با شرایط اولیه، معمولاً شرایط اولیه صفر در نظر گرفته می‌شود و برای شرایط مرزی، وابسته به مرز مدنظر ممکن است شرایط مرزی جاذب یا سطح آزاد مورد استفاده قرار گیرد. معمولاً سطح فوقانی مدل که سطح بین سنگ و هوا یا آب و هوا است را سطح آزاد و سطوح جانبی و زیرین مدل را سطح جاذب در نظر می‌گیرند تا از بازتاب‌های ناخواسته این سطوح به درون مدل جلوگیری شود. در اینجا از شرایط مرزی جاذب لایه اسفنجی استفاده شده است (ونگ و کین، ۱۹۹۷).

در وارون‌سازی شکل موج کامل، هدف ساخت یک مدل سرعت است که داده مشاهده‌ای را برازش کند. لذا تابع هدف به صورت نرم دوم اختلاف بین داده مشاهده‌ای ($\mathbf{d}_{\text{obs}}$) و داده پیش‌بینی شده به وسیله اپراتور مدل‌سازی پیشرو ($\mathbf{d}_{\text{pre}}$) تعریف می‌شود که طی فرایند وارون‌سازی بایستی کمینه شود:

$$\mathbf{C}(\mathbf{m}) = \|\mathbf{d}_{\text{obs}} - \mathbf{d}_{\text{pre}}\|_2^2 = \Delta \mathbf{d}^\dagger \Delta \mathbf{d}, \quad (4)$$

چون $\mathbf{C}$ یک تابع غیرخطی است، می‌توان با استفاده از بسط تیلور آن را حول مدل اولیه ($\mathbf{m}_0$) تخمین زده و به صورت تکراری به حداقل رساند (تارانتولا، ۱۹۸۴؛ آستر، ۲۰۱۸؛

دقیق یا تحلیلی محاسبه می شود اما در مسائل پیچیده مثل وارون سازی شکل موج استفاده از تقریب عددی توصیه می شود (شوستر، ۲۰۱۷).

حل عددی معادله موج را می توان در چارچوب یادگیری عمیق و با طراحی یک شبکه عمیق بازگشتی (RNN) انجام داد. به این منظور در این مقاله یک بلوک بازگشتی عمیق مطابق با شکل ۲ پیشنهاد شده است که این شبکه هم ارز معادله موج گسسته سازی شده در رابطه (۳) است. این بلوک بازگشتی در لایه ورودی خود میدان موج در پله زمانی کنونی ($P_{i,j}^n$) و پله زمانی قبلی ($P_{i,j}^{n-1}$) را دریافت می کند. لایه بعد از آن، عملگر ضرب هادامارد (Hadamard) است که وزن تک فیلتر این لایه (M) مطابق با شرایط مرزی جاذب لایه اسفنجی (Sponge Layer) در نظر گرفته شده است و بازتاب های ناخواسته کناره های مدل را تضعیف می کند. این عملگر روی هر دو میدان موج ورودی عمل می کند سپس، میدان موج کنونی ($P_{i,j}^n$) که تحت عملگر شرایط مرزی جاذب قرار گرفته هم به عنوان میدان موج پیشین در پله زمانی بعد در نظر گرفته می شود، و همین طور از طریق یک شاخه دیگر وارد یک لایه کانولوشنی می شود تا فیلتر لاپلاسی گسسته (∇^2) روی آن عمل کرده و سپس در لایه ضرب هادامارد دوم که ماتریس وزن آن برابر با توان دوم حاصلضرب مدل سرعت در نسبت پله زمانی به اندازه گرید فضایی ($A = (V\alpha)^2$) است، وارد می شود. در آخر، خروجی این لایه و میدان موج پیشین که عملگر شرایط مرزی جاذب روی آن عمل کرده بود، به همراه جمله منبع (w) مجموع گیری شده تا میدان موج در پله زمانی پسین محاسبه شود. این میدان موج خود به عنوان میدان موج کنونی در پله زمانی بعدی در نظر گرفته شده و این فرایند به صورت بازگشتی انجام شده تا به حداکثر تعداد پله های زمانی تعریف (t_{max}) شده برسد. لازم به ذکر است که در هر پله زمانی یک اپراتور نمونه گیری (D) تعبیه شده که در محل گیرنده ها (G)، میدان موج را ثبت و در برداشت چشمه مشترک ضبط می کند. قسمت RNN در شکل ۲ مراحل محاسبات این شبکه عصبی هم ارز معادله موج را نشان می دهد. مانند رابطه (۲)، این شبکه عصبی بازگشتی

ویریوکس و اپرتو، ۲۰۰۹). در مسائل وارون غیرخطی معمولاً از روش های نیوتنی برای حل مسئله استفاده می شود که لازمه آن محاسبه وارون ماتریس هسین (Hessian) می باشد که در این مسئله محاسبه آن بسیار زمانبر بوده و حافظه زیادی می طلبد لذا معمولاً از روش های شبه نیوتونی یا گرادینان برای حل آن استفاده می شود (ویریوکس و اپرتو ۲۰۰۹؛ شوستر، ۲۰۱۷). گرادینان تابع هدف (رابطه ۴) در تکرار نام به صورت زیر تعریف می شود:

$$\nabla C_m^{(i)} = 2m(x)^{(i)} \sum_t \Delta r(x,t)^{(i)} P(x,t)^{(i)},$$

$$\Delta r = L^\dagger \Delta d, \quad (5)$$

در اینجا، $L^\dagger$ اپرتور الحاقی معادله موج است که بر تریس های باقی مانده (Δd) اعمال می شود و میدان موج پسرو (Δr) را محاسبه می کند. سپس گرادینان تابع خطا نسبت به پارامترهای مدل در هر تکرار، با استفاده از همبستگی متقابل در تأخیر صفر بین میدان موج پیشرو ($P(x,t)$) و میدان موج پسرو محاسبه می شود. در اصل میدان موج پسرو از مهاجرت زمان معکوس (RTM) اختلاف تریس های پیش بینی شده و تریس های واقعی حاصل می شود (شوستر، ۲۰۱۷). شکل ۱ طرحواره انجام وارون سازی شکل موج کامل را به تصویر کشیده است. مطابق با این طرحواره داده های ورودی برای فرایند وارون سازی شکل موج کامل شامل مدل اولیه، موجک چشمه و هندسه برداشت هستند که در شبیه سازی میدان موج پیشرو استفاده می شوند و سپس ردلرزه حاصل از اختلاف بین ردلرزه های محاسبه شده و ردلرزه های واقعی (ورودی چهارم به فرایند) در جهت عکس زمانی در مدل سرعتی منتشر شده و گرادینان تابع خطا نسبت به مدل به دست می آید. در روش سریع ترین شیب (GD)، گرادینان محاسبه شده به وسیله یک طول گام (α) مقیاس شده و مطابق با رابطه (۶) برای به روز رسانی مدل استفاده می شود:

$$m^{(i+1)} = m^{(i)} - \alpha \nabla C_m^{(i)}, \quad (6)$$

در این رابطه، m^i مدل در تکرار نام، m^{i+1} مدل بروز شده، $\nabla C_m^{(i)}$ گرادینان مدل در تکرار نام، و α طول گام می باشد. طول گام در مسائلی که پیچیدگی کمتری دارند به صورت

محاسبه هر دو میدان موج در شبکه بازگشتی، گرادیان تابع خطا نسبت به پارامترهای مدل از طریق معادله (۵) محاسبه می‌شود.

در اصل، انجام وارون‌سازی شکل موج با استفاده از این بلوک بازگشتی مبتنی بر فیزیک هم‌ارز وارون‌سازی شکل موج کامل معمولی است که در چارچوب یادگیری عمیق بازنویسی شده است و از مزیت سرعت محاسباتی چند صد برابری در این قالب بهره می‌برد. در وارون‌سازی شکل موج معمولی برای به‌روزرسانی مدل، از روش تندترین شیب (رابطه ۶) استفاده می‌شود که روند همگرایی را کند و میزان محاسبات را تشدید می‌کند. روش‌های شبه نیوتونی برای جبران این نقیصه از تاریخچه گرادیان در تکرارهای قبل برای تخمین وارون ماتریس هسین و تسریع روند همگرایی استفاده می‌کنند (شوستر، ۲۰۱۷). یک دسته از روش‌های بهینه‌سازی که طرفداران زیادی در آموزش شبکه‌های عصبی پیدا کرده‌اند روش‌های مبتنی بر مومنتوم هستند. این روش‌ها نیز از تاریخچه گرادیان برای محاسبه یک جهت میانگین استفاده می‌کنند که با کاهش حرکت‌های زیگزآگی، با سرعت بیشتری به سمت نقطه مینیمم تابع خطا حرکت می‌کند و قابلیت فرار از نقاط بهینه محلی را دارند (آگاروال، ۲۰۲۳). رابطه به‌روزرسانی در روش سریع‌ترین شیب تصادفی (SGDM) به‌صورت زیر است:

$$\mathbf{u}^{(i)} = \beta \mathbf{u}^{(i-1)} - \alpha \nabla \mathbf{C}_m^{(i)}, \quad (7)$$

$$\mathbf{m}^{(i+1)} = \mathbf{m}^{(i)} + \mathbf{u}^{(i)}, \quad (8)$$

در این رابطه $\mathbf{u}$ بردار مومنتوم، β پارامتر مومنتوم و سایر جملات مطابق با رابطه (۶) می‌باشند. در روش RMSProp برخلاف روش‌های مبتنی بر مومنتوم نرخ یادگیری برای هر پارامتر متغیر در نظر گرفته می‌شود. به این صورت که از میانگین نمایی مربع مقادیر گرادیان در تکرارهای متوالی برای بهنجارسازی مقدار گرادیان هر پارامتر استفاده می‌شود. این روش با پیش پردازش گرادیان از نوسان الگوریتم حول پارامترهای با حساسیت بالا جلوگیری می‌کند:

$$\mathbf{w}^{(i)} = \rho \mathbf{w}^{(i-1)} + (1 - \rho) (\nabla \mathbf{C}_m^{(i)})^2, \quad (9)$$

مبتنی بر فیزیک مسئله، با استفاده از تقریب عددی تفاضل محدود، معادله موج را برای مدل سرعتی (V) حل کرده و در مسئله وارون‌سازی شکل موج می‌تواند به‌عنوان اپراتور مدل‌سازی پیشرو مورد استفاده قرار گیرد. برای مدل سرعتی که در لایه ضرب هادامارد دوم مشخص شده است، می‌توان محاسبات مربوط به چشمه‌های مختلف را به‌صورت دسته‌ای (Mini-Batch) اجرا کرد و به‌صورت موازی محاسبات چندین شات را انجام داد. انجام موازی محاسبات شات‌های مختلف و استفاده از محاسبات مبتنی بر واحد پردازش گرافیکی باعث تسریع چندین صد برابری این فرایند می‌شود.

پیکان‌های زرد رنگ در شکل ۲ مرتبط با مدل‌سازی پیشرو معادله موج بوده و پیکان‌های قرمز رنگ مرتبط با وارون‌سازی معادله موج می‌باشند. برخی قسمت‌ها در مدل‌سازی پیشرو و وارون مشترک هستند که در این شکل با پیکان‌های مشکی رنگ مشخص شده‌اند. در وارون‌سازی شکل موج، هدف تخمین مدل سرعتی زیرسطحی با استفاده از داده مشاهده شده در سطح زمین می‌باشد. به این منظور و برای شروع محاسبات نیازمند یک مدل اولیه سرعت هستیم که این مدل را می‌توان به‌صورت دستی به شبکه بازگشتی خوراند یا خروجی یک شبکه از پیش آموزش دیده دیگر (مثلاً یک شبکه کانولوشنی یا کاملاً متصل) را به آن داد. مانند دیگر شبکه‌های عصبی، برای این که پاسخ شبکه عصبی بازگشتی ($\mathbf{d}_{pre}$) به پاسخ درست ($\mathbf{d}_{obs}$) برازش داده شود، بایستی وزن‌های شبکه عصبی بازگشتی (مدل سرعتی) طی یک فرایند تکراری بهینه شوند. به این منظور اختلاف بین پیش‌بینی شبکه و خروجی صحیح در شبکه عصبی به عقب منتشر شده، و میزان انحرافات وزن‌های شبکه عصبی محاسبه و اعمال می‌شود. از آنجا که معادله موج آکوستیک خودالحاقی (self-adjoint) است، از همین ساختار می‌توان برای پس انتشار (Back-Propagation) تریس‌های باقی‌مانده استفاده کرد. تنها تفاوت با مدل‌سازی پیشرو در موجک چشمه (که تریس‌های باقی‌مانده در محل گیرنده‌ها است) و جهت انتشار در زمان (که از انتها به ابتدا است) قرار دارد. پس از

به‌طور همزمان منتفع شود. برای این روش نیز بردار $\mathbf{w}$ از رابطه (۹) محاسبه می‌شود و سپس بردار مومنتوم ($\mathbf{u}$) و به‌روزرسانی به‌ترتیب مطابق با روابط زیر انجام می‌شود:

$$\mathbf{u}^{(i)} = \rho_u \mathbf{u}^{(i-1)} - (1 - \rho_u) \nabla \mathbf{C}_m^{(i)}, \quad (11)$$


$$\mathbf{m}^{(i+1)} = \mathbf{m}^{(i)} - \frac{\alpha^{(i)}}{\sqrt{\mathbf{w}^{(i)} + \epsilon}} \mathbf{u}^{(i)}, \quad (12)$$

در روابط ρ_u فاکتور کاهش جمله مومنتوم بوده و نرخ یادگیری ($\alpha^{(i)}$) الگوریتم به‌صورت انطباقی محاسبه می‌شود:


$$\alpha^{(i)} = \alpha \left(\frac{\sqrt{1 - \rho_f^{(i)}}}{1 - \rho_f^{(i)}} \right). \quad (13)$$

$$\mathbf{m}^{(i+1)} = \mathbf{m}^{(i)} - \frac{\alpha}{\sqrt{\mathbf{w}^{(i)} + \epsilon}} \nabla \mathbf{C}_m^{(i)}, \quad (10)$$

در این روابط $\mathbf{w}$ در محاسبه طول گام متغیر استفاده می‌شود، ρ فاکتور کاهش (decay factor) می‌باشد که عددی در بازه ۰ تا ۱ است، و ϵ یک مقدار کوچک (از مرتبه 10^{-8}) است که از ناپایداری الگوریتم جلوگیری می‌کند. روش مومنتوم انطباقی (ADAM) مثل روش RMSProp از بهنجارسازی سیگنال به‌نویز بهره می‌برد، و همچنین جهت به‌روزرسانی را مطابق با میانگین نمایی مرتبه اول گرادینان در نظر می‌گیرد تا از مزیت روش‌های مبتنی بر مومنتوم نیز



شکل ۱. طرحواره وارون‌سازی شکل موج کامل.



شکل ۲. شبکه عصبی بازگشتی هم‌ارز معادله موج که برای مدل‌سازی پیشرو انتشار موج و وارون‌سازی شکل موج کامل مورد استفاده قرار گرفته است.

۳. نتایج

به‌وسیله گیرنده‌ها ثبت شده است. پله زمانی برای شبیه‌سازی برابر با ۰/۵ میلی ثانیه و فاصله نمونه برداری در ورداهاست‌های چشمه مشترک ۴ میلی ثانیه می‌باشد. شکل (۳-ب) میدان موج موجود در محیط را برای چشمه هشتم در زمان‌های مختلف به تصویر می‌کشد و شکل (۳-پ) ورداهاست‌های چشمه مشترک ۱۵ چشمه را نشان می‌دهد. در مرحله بعد، از روش پیشنهادی برای وارون‌سازی داده مصنوعی و بازسازی مدل سرعتی استفاده شده است. مدل اولیه به کار رفته در فرایند وارون‌سازی با استفاده از عملکرد یک فیلتر گوسی دو بعدی پهن بر مدل اصلی به‌دست آمد که منجر به ایجاد مدل اولیه کاملاً همواری شده است (شکل ۴-ب)، که فقط حاوی اطلاعات طول‌موج‌های بسیار بلند مدل سرعتی است و بازسازی ساختارهای با رزولوشن بالاتر به‌عهده روش پیشنهادی قرار داده شده است. علاوه‌بر روش سریع‌ترین شیب (GD)، از روش‌های سریع‌ترین شیب تصادفی (SGDM)، روش RMSProp، و روش ADAM برای به‌روزرسانی مدل در خلال فرایند وارون‌سازی استفاده شده است که به‌ترتیب در شکل‌های (۴-پ)، (۴-ت)، (۴-ث) و (۴-ج) قابل مشاهده هستند. در شکل (۴-چ) نیز نگاره‌های سرعت مدل‌های مختلف در محل چاه (که به‌وسیله یک خط قائم مشکی روی مدل‌ها مشخص شده

برای شبیه‌سازی انتشار موج و تولید داده مصنوعی با استفاده از بلوک یادگیری عمیق بازگشتی مبتنی بر فیزیک، از مدل مارموزی (شکل ۳-الف) استفاده شده است که یک مدل پیچیده زمین‌شناسی دو بُعدی با تغییرات شدید سرعت در جهت قائم و جانبی است و به‌طور متداول برای تعیین کارایی روش‌های تصویرسازی عمقی و وارون‌سازی سرعت استفاده شده است، به‌طوری‌که به یک مدل استاندارد در این زمینه تبدیل شده است (ورستیچ، ۱۹۹۴). این مدل بر اساس ۱۶۰ افق و گسل‌های تفسیر شده از یک مقطع لرزه‌ای در حوزه کوانزا (Cuanza) در آنگولا ساخته شده است. مدل واقعی به‌ترتیب طول و عمقی برابر با ۹۲۰۰ و ۳۰۰۰ متر با اندازه سلول ۴ متر دارد. در اینجا، ابعاد شبکه‌بندی مدل ۳۰۱۱۵۰× با فاصله شبکه‌بندی ۱۰ متر در نظر گرفته شده است که ۱۵ چشمه با فاصله ۲۰۰ متر و برای هر چشمه یک آرایه ثابت شامل ۱۵۰ گیرنده با فاصله ۲۰ متر در سطح مدل فرض شده است. در این آزمایش انتشار موج از ۱۵ چشمه از نظر محاسباتی به‌صورت همزمان و با استفاده از محاسبات مبتنی بر واحد پردازش گرافیکی (GPU) اجرا شده است. موجک ریکر ۱۵ هرتز طی این آزمایشات در محیط منتشر شده و مدت‌زمان ۱/۲ ثانیه داده

بیشینه سیگنال به نوفه (PSNR) و شاخص شباهت ساختاری (SSIM) استفاده شده است که نتایج آن در جدول ۱ قابل مشاهده است. در این جدول هر سطر مقدار معیارهای متفاوت را برای یک روش مشخص می کند و هر ستون مقدار یک معیار را برای روش های مختلف نشان می دهد که بهترین مقدار آن به شکل پررنگ برجسته شده است. روابط ریاضیاتی این معیارهای کمی به صورت زیر است:

$$L_1 = \frac{1}{XY} \sum_{x,y} |\mathbf{m}_1 - \mathbf{m}_2|, \quad (14)$$

$$L_2 = \frac{1}{XY} \sqrt{\sum_{x,y} (\mathbf{m}_1 - \mathbf{m}_2)^2}, \quad (15)$$


$$SSIM = \frac{1}{n} \sum_{i=1}^n \left(1 - \left(\frac{(2\mu_{m1}\mu_{m2} + c_1)(2\sigma_{m1m2} + c_2)}{(\mu_{m1}^2 + \mu_{m2}^2 + c_1)(\sigma_{m1}^2 + \sigma_{m2}^2 + c_2)} \right) \right), \quad (16)$$

$$PSNR = 20 \log_{10} \left(\frac{PV}{L_2(\mathbf{m}_1, \mathbf{m}_2)} \right), \quad (17)$$


در این روابط $\mathbf{m}_1$ و $\mathbf{m}_2$ به ترتیب نشان دهنده مدل صحیح و مدل محاسبه شده هستند. x و y شمارنده سلول های محور افقی و عمقی شبکه مدل هستند که مقدارشان به ترتیب از ۱ تا X و Y تغییر می کند. در شاخص شباهت ساختاری، مقادیر μ_{m1} ، μ_{m2} ، σ_{m1} ، σ_{m2} ، σ_{m1m2} ، c_1 و c_2 به ترتیب نشان دهنده میانگین محلی تصویر صحیح و محاسبه شده، واریانس محلی تصویر صحیح و محاسبه شده، کواریانس بین دو تصویر محلی و دو ثابت قابل تنظیم هستند. در نسبت بیشینه سیگنال به نوفه نیز PV نشان دهند مقدار بیشینه سیگنال (Peak Value) است.

است) با نگاره صحیح سرعت مقایسه شده اند. شکل (۵-الف) روند تغییرات لگاریتم تابع خطا در فرایند وارون سازی شکل موج کامل را برای روش های مختلف به تصویر کشیده است. این نمودار نشان دهنده قدرت هر روش در برازش به داده مشاهده ای می باشد. در شکل (۵-ب) نیز فاصله مدل به دست آمده از روش های مختلف نسبت به مدل اولیه در هر تکرار محاسبه شده است که نشان دهنده بزرگی طول گام انتخاب شده در هر روش بوده و میزان انحرافات مدل در هر تکرار را به صورت تجمعی نشان می دهد.


از ارزیابی کیفی نگاره های سرعت بازسازی شده در محل چاه و مقایسه آنها با نگاره صحیح مشخص است که تا عمق حدود ۱۰۰۰ متری، روش ADAM دقت بیشتری نسبت به سایر روش ها در بازسازی جزئیات و تعیین ریز لایه های مدل سرعتی داشته است و مرز بین لایه ها به شکل دقیق تری محاسبه شده اند. در اعماق بیشتر نیز، این روش تغییرات مدل سرعت نسبت به مدل اولیه را بهتر از سایر روش ها بازسازی کرده است اما بنظر می رسد طول گام انطباقی این روش در این اعماق بیش از حد لازم بوده است که احتمالاً با افزایش تعداد تکرارها متناسب با مدل صحیح می شود. برای ارزیابی کمی عملکرد روش های پیشنهادی نیز از معیارها مختلف از جمله نرم اول اختلاف مدل وارون شده و مدل صحیح، نرم مرتبه دوم اختلاف مدل وارون شده و مدل صحیح، نسبت




(ب)




(الف)




شکل ۳. الف) مدل سرعتی مارموزی ۲، ب) میدان موج ثبت شده در محیط در زمان های مختلف برای چشمه هشتم، و پ) برداشت های چشمه مشترک ثبت شده توسط گیرنده های چیده شده در سطح مدل.



شکل ۴. الف) مدل مارموزی (مدل صحیح) که برای محاسبه دیتای مصنوعی به منظور استفاده در فرایند وارون سازی به وسیله شبکه عصبی عمیق بازگشتی مبتنی بر فیزیک مسئله به کار رفته است؛ ب) مدل اولیه متناظر با آن که در سایر روش های وارون سازی مورد استفاده قرار گرفته است. مدل حاصل از وارون سازی با روش های سریع ترین شیب، سریع ترین شیب تصادفی، RMSProp و ADAM به ترتیب در قسمت های (پ)، (ت)، (ث) و (ج) نمایش داده شده است. مسیر چاه روی مدل های مختلف به وسیله یک خط قائم مشکی و نگاره های سرعت در محل چاه با رنگ سفید بر روی مدل ها نشان داده شده است. در قسمت (ج) نگاره های سرعت حاصله از روش های مختلف با یکدیگر و با نگاره سرعت صحیح مقایسه شده اند.



(الف)



(ب)

شکل ۵. الف) مقایسه نمودار همگرایی فرایند وارون‌سازی شکل موج کامل با استفاده از شبکه عصبی عمیق بازگشتی مبتنی بر فیزیک مسئله با روش‌های سریع‌ترین شیب (GD)، سریع‌ترین شیب تصادفی (SGDM)، RMSProp و ADAM برای مدل مارموزی؛ ب) میزان فاصله مدل به‌دست آمده از روش‌های مختلف نسبت به مدل اولیه، در هر تکرار از فرایند وارون‌سازی.

جدول ۱. مقایسه مدل بازسازی‌شده با استفاده از روش‌های مختلف پهنه‌سازی و مدل صحیح توسط معیارهای استاندارد برای مدل مارموزی.

روش / معیار	SSIM	PSNR	L2	L1
روش GD	۰/۷۳	۲۱/۵۹	۵۸۸/۹۹	۲۳۹/۸۷
روش SGDM	۰/۷۳	۲۱/۶	۵۸۸/۰۱	۲۴۳/۵۳
روش RMSProp	۰/۷	۲۰/۷۴	۶۴۹/۲۶	۲۷۳/۲۴
روش ADAM	۰/۷۶	۱۹/۲۴	۷۷۱/۶۷	۲۷۹/۹۶

۴. بحث

معادله موج شامل محاسبات ماتریسی بزرگ مقیاسی است که استفاده از محاسبات موازی مبتنی بر واحدهای پردازش گرافیکی همه‌منظوره (GPGPU) تا میزان زیادی این مشکل را برطرف می‌کند. علاوه بر موازی‌سازی محاسبات ماتریسی می‌توان شبیه‌سازی مربوط به چشمه‌های مختلف را به‌صورت دسته‌ای انجام داد. در بلوک یادگیری عمیق بازگشتی پیشنهاد شده در این مقاله از هردوی این روش‌ها

وارون‌سازی شکل موج کامل علی‌رغم این که منجر به یک مدل سرعتی با رزولوشن بالا می‌شود، در سال‌های گذشته به‌ندرت به‌منظور تصویرسازی زیر سطحی مورد استفاده قرار می‌گرفت. یک علت برای عدم استفاده از آن نیاز به توان محاسباتی بالا و زمان طولانی محاسبات بوده است که ریشه در حل عددی معادله موج دارد. حل تفاضل محدود

برای تسریع محاسبات استفاده شده است به طوری که میدان موج چشمه‌های مختلف روی کانال‌های شبکه عصبی عمیق نگاشته شده‌اند. البته از آنجا که میزان حافظه واحدهای پردازش گرافیکی محدود می‌باشد، اندازه دسته (Mini-Batch)، از یک مقدار مشخص نمی‌تواند تجاوز کند. مقایسه زمان محاسبات این روش با محاسبات متداول که با استفاده از واحدهای پردازش مرکزی (CPU) انجام می‌شود، کاملاً وابسته به نحوه پیاده‌سازی و سخت افزارهای به کار گرفته شده است. اما در قیاس شبیه‌سازی همزمان دسته‌ای با شبیه‌سازی سری چشمه‌های مختلف، می‌توان گفت که زمان محاسبات با اندازه دسته مقیاس می‌شود. به عنوان مثال در نتایج مرتبط با مدل مارموزی ارائه شده در قسمت قبل، یک تکرار کامل وارون‌سازی شکل موج که شامل شبیه‌سازی پیشرو و پسروی میدان موج برای ۱۵ چشمه و به روزرسانی مدل است، با استفاده از واحد پردازش گرافیکی از نوع NVIDIA Quadro RTX 6000 نسبت به محاسبه با یک واحد پردازش مرکزی (CPU) ۲۴ هسته‌ای با سرعت کلاک ۳.۴۷ GHz حدود ۱۳ برابر سریع‌تر بوده است. باید توجه داشت که این نسبت برای حالتی است که همه ۱۵ چشمه برای CPU و GPU به صورت همزمان و موازی شبیه‌سازی شده‌اند و در صورتی که شبیه‌سازی‌های مبتنی بر CPU سری باشد این عدد به ۱۹۵ مرتبه محاسبات سریع‌تر برای روش پیشنهادی می‌رسد.

موضوع دیگری که در اینجا مورد بررسی قرار می‌دهیم، عملکرد روش‌های بهینه‌سازی مختلف در فرایند وارون‌سازی است. از میان معیارهای کمی استفاده شده در جدول ۱ که برای سنجش نحوه عملکرد این روش‌ها به کار گرفته شده‌اند، نرم‌های مرتبه اول و دوم از مجموع خطای هر پیکسل از مدل بازسازی شده نسبت به مدل صحیح به دست می‌آیند. اگرچه مقادیر کمتر این معیارها بیانگر دقت بیشتر در مدل بازسازی شده است، اما باید توجه داشت که این معیارها درکی نسبت به شباهت شکل ساختارها ارائه نمی‌دهند و تنها تفاوتشان در این است که نرم‌های مراتب بالاتر وزن بیشتری به خطاهای بیشتر می‌دهند. معیار بیشینه نسبت سیگنال به نوفه (PSNR) نیز ارتباط نزدیکی با

نرم مرتبه دوم دارد و میزان سیگنال به نوفه را بر حسب دسی‌بل برای مقدار اوج مقدار سیگنال بیان می‌کند، لذا روش SGDM که در جدول ۱ با معیار L_2 کمترین خطا را نشان می‌دهد، بیشترین مقدار PSNR را نیز دارد. معیار SSIM علاوه بر مقدار هر پیکسل به ساختمان محلی حول هر سلول نیز حساسیت دارد و برای سنجیدن شباهت دو تصویر به شکل متداول مورد استفاده قرار می‌گیرد. طبق این معیار روش ADAM بهترین عملکرد را در بازسازی ساختارهای محلی و تخمین سرعت داشته است. همچنین شکل (۵-الف) که لگاریتم تابع خطای روش‌های مختلف را بر حسب شماره تکرار نشان می‌دهد، بیانگر عملکرد بسیار بهتر روش ADAM در کاهش تابع خطا و برازش به داده مشاهده‌ای است. شکل (۵-ب) نیز نمایانگر قدرت هر روش در تغییر مدل اولیه و جستجوی فضای مدل برای نیل به مدل بهینه است که از این جهت نیز عملکرد روش ADAM سرآمد بوده است.

۵. نتیجه‌گیری

در این مقاله، یک بلوک یادگیری عمیق بازگشتی هم‌ارز معادله موج پیشنهاد شده است که در آن از لایه‌های متداول در شبکه عصبی عمیق مانند لایه کانولوشن، لایه ضرب هادامارد و لایه تجمیع استفاده شده است. با این حال تنها لایه‌ای که قابلیت آموزش را در این شبکه عصبی عمیق دارد، لایه ضرب هاداماردی است که وزن آن متناسب با سرعت مدل می‌باشد. لذا می‌توان در یک فرایند آموزش غیرنظارتی وزن‌های این لایه را طوری بروز کرد که داده پیش‌بینی شده به داده واقعی برازش داده شود. این فرایند که هم‌ارز وارون‌سازی شکل موج کامل است، به خاطر استفاده محاسبات مبتنی بر GPU چند صد برابر سریع‌تر نسبت به وارون‌سازی شکل موج معمولی است و قابلیت پیاده‌سازی روش‌های بهینه‌سازی متداول در آموزش شبکه‌های عصبی عمیق مانند روش‌های مبتنی بر مونتوم را دارد. اثر بخشی این روش از طریق اعمال آن بر مدل مصنوعی مارموزی بررسی شد و معیارهای کمی متعددی توانایی الگوریتم پیشنهادی در بازسازی مدل سرعتی

بیشترین انحراف تجمعی مدل و بالاترین قابلیت در جستجوی فضای مدل را نیز داشته است؛ به‌طوری‌که تغییر روش بهینه‌سازی از سریع‌ترین شیب به ADMA باعث افزایش شاخص شباهت ساختاری از ۰/۷۳ به ۰/۷۷ شده است.

مراجع

Aggarwal, C. C. (2023). *Neural Networks and Deep Learning* (2nd ed.). Springer, Switzerland. <https://doi.org/10.1007/978-3-031-29642-0>

Aki, K., & Richards, P. G. (2002). *Quantitative seismology* (2nd ed.). Sausalito, CA: University Science Books.

Alkhalifah, T. (2016). *Full waveform inversion in an anisotropic world: Where are the parameters hiding?*. EAGE Publications. <https://doi.org/10.3997/9789462822023>.

Araya-Polo, M., Jennings, J., Adler, A., & Dahlke, T. (2018). Deep-learning tomography. *The Leading Edge*, 37(1), 58-66.

Aster, R. C., Borchers, B., & Thurber, C. H. (2018). *Parameter estimation and inverse problems* (3rd ed.). Amsterdam, Netherlands: Elsevier.

Biswas, R., Sen, M. K., Das, V., & Mukerji, T. (2019). Prestack and poststack inversion using a physics-guided convolutional neural network. *Interpretation*, 7(3), SE161-SE174.

Boonyasiriwat, C., Valasek, P., Routh, P., Cao, W., Schuster, G. T., & Macy, B. (2009). A multiscale method for time-domain waveform tomography, *Geophysics*, 74(6), WCC59-WCC68.

Dablain, M. A. (1986). The application of high-order differencing to the scalar wave equation. *Geophysics*, 51, 54-66. <http://dx.doi.org/10.1190/1.1442040>

Dhara, A., & Sen, M. K. (2022). Physics-guided deep autoencoder to overcome the need for a starting model for full-waveform inversion. *The Leading Edge*, 41(6), 375-381. <https://doi.org/10.1190/tle41060375.1>

Hashemi, H., Saadat, M., Bidhendi, M. N., & De Groot, P. (2021). Incorporating acquisition geometry in deep learning-based full waveform inversion. In *82nd EAGE Annual Conference & Exhibition*, 2021(1), 1-5. European Association of Geoscientists & Engineers.

Karniadakis, G. E., Kevrekidis, I. G., Lu, L., Perdikaris, P., Wang, S., & Yang, L. (2021). Physics-informed machine learning. *Nature Reviews Physics*, 3, 422-440.

را تأیید کردند. به‌منظور مقایسه عملکرد روش‌های بهینه‌سازی مختلف، سایر این روش‌ها در شرایط یکسان (موجک، هندسه برداشت و مدل اولیه یکسان) بر یک مجموعه داده اعمال شدند و مطابق با شاخص شباهت ساختاری مشخص شد که در مسئله وارون‌سازی شکل موج، روش ADAM در عین حال که بیشترین برآزش به داده و بالاترین نرخ کاهش خطا در فضای داده را دارد،

Li, S., Liu, B., Ren, Y., Chen, Y., Yang, S., & Wang, Y. (2019). Deep learning inversion of seismic data. *IEEE Transactions on Image Processing*, 58(3), 2135-2149. <https://doi.org/10.48550/arXiv.1901.07733>

Ren, Y., Xu, X., Yang, S., Nie, L., & Chen, Y. (2020). A physics-based neural network way to perform seismic full waveform inversion. *IEEE Access*, 8, 112266-112277. <https://doi.org/10.1109/ACCESS.2020.2997921>

Saadat, M., Fakhari, M. G., Shoar, B. H., Salehi, E., & Aghazade, K. (2024a). Deep Semantic Segmentation for Automated Seismic Velocity Analysis. In *85th EAGE Annual Conference & Exhibition*, 2024(1), European Association of Geoscientists & Engineers.

Saadat, M., Hashemi, H., & Nabi-Bidhendi, M. (2024b). Generalizable data driven full waveform inversion for complex structures and severe topographies. *Petroleum Science*, 21(6), 4025-4033.

Saadat, M., Salehi, E., Etminan, M., Yousefzadeh, A., & Nezamoleslami, H. (2022). Enhanced collapse feature extraction from high-resolution seismic data using convolutional neural network. Second EAGE Digitalization Conference and Exhibition, Vienna, Austria. <https://doi.org/10.3997/2214-4609.202239084>

Schuster, G. T. (2017). Seismic inversion investigations in geophysics no. 20. SEG. <https://doi.org/10.1190/1.9781560803423>

Song, C., & Alkhalifah, T. (2020). Wavefield reconstruction inversion via machine learned functions. SEG 2020, Houston. <https://doi.org/10.1190/segam2020-3427351.1>

Sun, B., & Alkhalifah, T. (2022). ML-misfit: A neural network formulation of the misfit function for full-waveform inversion. *Frontiers in Earth Science*, 10. <https://doi.org/10.3389/feart.2022.1011825>

Tarantola, A. (1984). Inversion of seismic reflection data in the acoustic approximation. *Geophysics*, 49(8). <https://doi.org/10.1190/1.1441754>

Versteeg, Roelof. (1994). The Marmousi experience: Velocity model determination on a

- synthetic complex data set. *The Leading Edge*, 13 (9), 927–936. doi:10.1190/1.1437051
- Virieux, J., & Operto, S. (2009). An overview of full waveform inversion in exploration geophysics. *Geophysics*, 74(6), WCC1–WCC26. <https://doi.org/10.1190/1.3238367>
- Wu, Y., & Lin, Y. (2019). InversionNet: A real time and accurate full waveform inversion with CNNs and continuous CRFs. *IEEE Transactions of Computational Imaging*. arXiv: 1811.0775v2. <https://doi.org/10.48550/arXiv.1811.0775>
- Yang, F., & Ma, J. (2018). Deep-learning inversion: A next-generation seismic velocity model building method. *Geophysics*, 84(4). <https://doi.org/10.1190/geo2018-0249.1>
- Zhang, Z., & Lin, Y. (2020). Data-driven seismic waveform inversion: A study on robustness and generalization. *IEEE Transactions on Geoscience and Remote Sensing*, 58(10), 6900–6913. <https://doi.org/10.1109/TGRS.2020.2977635>