



دانشگاه صنعتی شاهرود

دوره ۱۲، شماره ۱، سال ۱۴۰۵، صفحات ۱۲ - ۱

شناسه دیجیتال (DOI): 10.22044/JRAG.2025.16085.1370

محاسبه مدل سرعت و حل مسئله وارون لرزه‌ای با استفاده از شبکه‌های عصبی آگاه از فیزیک مسئله

آرمان نجفی^۱؛ امین روشندل کاهو^{۲*} و مهرداد سلیمانی منفرد^۳

۱- دانشجوی کارشناسی ارشد اکتشاف معدن؛ دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود، شاهرود، ایران.

۲- دانشیار؛ دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود، شاهرود، ایران.

۳- دانشیار؛ دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود، شاهرود، ایران.

دریافت مقاله: ۱۴۰۴/۰۱/۲۹؛ پذیرش مقاله: ۱۴۰۴/۰۶/۱۶

* نویسنده مسئول مکاتبات: roshandel@shahroodut.ac.ir

واژگان کلیدی

شبکه‌های عصبی آگاه از فیزیک
مسئله وارون لرزه‌ای
یادگیری عمیق

چکیده

روش‌های سنتی عددی و مبتنی بر گزاردیان در حل مسائل وارون لرزه‌ای با چالش‌هایی مانند نیاز به مدل اولیه سرعت و خطر به دام افتادن در کمینه‌های محلی مواجه‌اند. در این پژوهش، شبکه‌های عصبی آگاه از فیزیک مسئله (PINN) برای حل معادله موج آکوستیک دو بعدی و وارون‌سازی شکل موج کامل به کار گرفته شده‌اند. در سال‌های اخیر، یادگیری عمیق تحولات چشمگیری در علوم مختلف، به‌ویژه در علوم زمین و لرزه‌شناسی، ایجاد کرده است. روش‌های مبتنی بر شبکه‌های عصبی مصنوعی معمولاً صرفاً بر داده‌های موجود تکیه دارند و نقش دانش علمی در فرآیند آموزش را نادیده می‌گیرند. در این راستا، شبکه‌های عصبی آگاه از فیزیک مسئله به عنوان رویکردی نوین معرفی شده‌اند که با ترکیب دانش علمی و یادگیری ماشین، چالش‌های روش‌های متداول را تا حد زیادی برطرف می‌کنند. از جمله مزایای این روش کاهش وابستگی به حجم بالای داده‌های آموزشی و بهبود قابلیت تفسیر مدل‌های یادگیری عمیق است. در این پژوهش، از شبکه‌های عصبی آگاه از فیزیک مسئله برای حل معادله موج آکوستیک دو بعدی و وارون‌سازی شکل موج کامل استفاده شده است. مدل سرعت حاصل، با خروجی شبکه‌های عصبی ناآگاه از فیزیک مقایسه شده تا میزان دقت و کارایی روش پیشنهادی مورد ارزیابی قرار گیرد. نتایج این پژوهش نشان می‌دهد که استفاده از شبکه‌های عصبی آگاه از فیزیک مسئله، ضمن کاهش این چالش‌ها، عملکرد بهتری نسبت به روش‌های عددی کلاسیک و شبکه‌های عصبی ناآگاه از فیزیک دارد. این روش با بهره‌گیری از دانش فیزیکی ضمن کاهش وابستگی به داده‌های برچسب‌گذاری شده، دقت و قابلیت اطمینان مدل‌های وارون‌سازی لرزه‌ای را بهبود می‌بخشد.

۱- مقدمه

وارون‌سازی لرزه‌ای راهی برای تصویرسازی داده‌های لرزه‌ای و مدل‌سازی ساختارهای زیر سطح زمین با استفاده از اندازه‌گیری‌های لرزه‌ای است. این مدل زیر سطحی را می‌توان با حل یک مسئله وارون با استفاده از داده‌های لرزه‌ای بدست آورد (Wang et al., 2018). تصویرسازی لرزه‌ای مرحله آخر یک فرآیند طولانی و پیچیده پردازش داده است که هدف آن تصویرکردن مناسب پدیده‌های زیرسطحی است که به کمک آن می‌توان پدیده‌های زیر زمین را تفسیر کرد. هدف اصلی تصویرسازی لرزه‌ای بدست آوردن اطلاعات از ساختارهای زمین شناسی زیرسطحی به شکل یک تصویر لرزه‌ای است که می‌تواند یک ابزار ارزشمند برای تفسیر لرزه‌ای و قسمت مهمی از الگوریتم‌های وارون‌سازی لرزه‌ای باشد. شبیه‌سازی امواج لرزه‌ای در بسیاری از کاربردهای دنیای واقعی از مدل‌سازی زلزله تا انجام اکتشافات لرزه‌ای کاربرد دارد (Robin., 2010). در سال‌های اخیر شاهد پیشرفت‌های بسیاری در حوزه هوش مصنوعی و یادگیری ماشین بوده‌ایم که این پیشرفت‌ها همراه با افزایش حجم داده‌ها و بهبود سیستم‌های محاسباتی بوده است (Moseley et al., 2020). عامل اصلی که سبب می‌شود در یادگیری ماشین دچار مشکل یا محدودیت نشویم، ساخت پایگاه داده بزرگ و دقیق برای آموزش شبکه‌های عصبی است که فرآیندی پرهزینه و زمان‌بر است (Kingma and Ba., 2014). تحقیقات بسیاری برای بهبود الگوریتم‌های آموزشی و در نتیجه بالا بردن کیفیت فرآیند آموزش در حوزه یادگیری ماشین انجام شده است (Rashednia and Pourghaz., 2021). به عنوان مثال از یادگیری ماشین برای تشخیص بیماری گیاهان با استفاده از آنالیز تصاویر برگ و ساقه آن‌ها استفاده شد (Rezaei et al., 2024). در واقع الگوریتم‌های مدرن یادگیری عمیق در حال حاضر تقریباً در هر زمینه‌ای از علوم مورد استفاده قرار گرفته است. با وجود همه این پیشرفت‌ها می‌توان گفت بزرگترین چالش یادگیری ماشین جعبه سیاه بودن آن در نحوه نمایش و استدلال آن در مورد روش حل مسئله و ضعف آن در تعمیم‌پذیری است، بدین‌شکل که معمولاً این شبکه‌ها در خارج از داده‌های آموزشی خطای بالایی دارند (Karimipouli and Tahmasebi., 2020). یادگیری مدل‌های تعمیم‌پذیر که بتواند خارج از داده‌های آموزشی هم عملکرد خوبی داشته باشد یک چالش مهم در زمینه یادگیری ماشین است (Moseley et al., 2023). استفاده از یادگیری ماشین و شبکه‌های عصبی در ژئوفیزیک هم سابقه طولانی دارد (Yang and Ma., 2019). مطالعات انجام شده با استفاده از روش‌های یادگیری عمیق در مسائل وارون لرزه‌ای بیشتر مربوط به تخمین و ساخت مدل سرعت و حل مشکل فرکانس‌های پایین بوده است. داده‌های مورد استفاده در این تحقیقات معمولاً داده‌های دو بعدی مصنوعی است (Adler et al., 2021). فقدان اطلاعات فرکانس پایین و مدل اولیه مناسب به شکل جدی روی موفقیت وارون‌سازی لرزه‌ای اثر می‌گذارد. مطالعات بسیاری از یادگیری عمیق برای برون‌یابی فرکانس‌های پایین از دست رفته و کمک به کاهش مشکل پرش چرخه استفاده کردند (Hu et al., 2021). سان و دمانت، (Sun and Demant., 2021)

برای رفع مشکل فرکانس‌های پایین در وارون‌سازی شکل موج کامل از شبکه عصبی کانولوشنی استفاده کردند. این شبکه قابلیت برون‌یابی فرکانس‌های پایین از دست رفته را داشت. در بعضی مطالعات دیگر هم از شبکه‌های عصبی از پیش آموزش دیده برای هم‌گرایی بهتر استفاده شد (Kazei et al., 2021).

با وجود همه این پیشرفت‌ها، در زمینه امواج و داده‌های لرزه‌ای به دلیل کمبود داده‌های دقیق و همچنین نادیده گرفتن دانش علمی خود از مسئله چالش‌های زیادی وجود دارد. زمانی که برای حل مسئله‌ای از یادگیری ماشین استفاده می‌کنیم در واقع دانش علمی خود نسبت به مسئله را کنار می‌گذاریم. در چند سال اخیر حوزه جدیدی به نام یادگیری ماشین علمی معرفی شد که در واقع این امکان را به ما می‌دهد تا دانش خود از مسئله را وارد فرآیند حل مسئله کنیم (Rackauckas and Abdelrehim., 2024). هدف یادگیری ماشین علمی ترکیب دانش علمی موجود از مسئله با یادگیری ماشین است. مبنای شکل‌گیری این حوزه رسیدن به روش قوی‌تر برای تحقیقات علمی است (Cao et al., 2024). تحقیقات بسیاری در زمینه یادگیری ماشین علمی انجام شده که از مهم‌ترین آن‌ها می‌توان به علوم مرتبط با زمین (Lin et al., 2023) مکانیک سیالات (Haghighat et al., 2021) و کشاورزی (Adombi., 2024) اشاره کرد.

در سال ۲۰۱۹ روش جدیدی به نام شبکه‌های عصبی آگاه از فیزیک مسئله (Physics-Informed Neural Network (PINN معرفی شد و در مواردی که از معادله فیزیکی حاکم بر مسئله آگاه هستیم می‌تواند مورد استفاده قرار گیرد (Raissi et al., 2019). PINN در واقع قوانین فیزیکی شناخته شده را به عنوان یک پارامتر در تابع هزینه اضافه می‌کنند. معادلات دیفرانسیل و قوانین فیزیک حاکم بر مسئله در تابع هزینه برای جریمه کردن فرآیند یادگیری شبکه دخالت دارند. این شبکه‌ها توانایی این را دارند که راه‌حلی را آموزش ببینند که خارج از داده‌های مرزی مورد استفاده برای آموزش آن‌ها است (Zhu et al., 2024). PINN یک رویکرد جدید برای حل مسائل مربوط به معادلات دیفرانسیل ارائه می‌دهند و اخیراً در بسیاری از حوزه‌های مختلف محبوب شده‌اند (Jaberizideh et al., 2023). اسمیت و همکاران (Smith et al., 2021) از یک PINN برای حل مسئله پیشرو و پیش بینی زمان سیر امواج در یک محیط ناهمگن سه بعدی استفاده کردند. کریم پولی و طهماسبی (Karimipouli and Tahmasebi., 2020) از یک PINN برای حل معادله موج وابسته به زمان یک بعدی در محیطی با سرعت ثابت استفاده کردند و نشان دادند که این شبکه‌ها هم‌زمان قادر به حل مسئله وارون و پیشرو هستند. رشت بهشتی و همکاران (Rasht-Behesht et al., 2022) از این شبکه‌ها برای تخمین مدل سرعت در محیط دو بعدی ناهمگن با چند منبع لرزه‌ای استفاده کردند. سونگ و همکاران (Song et al., 2021) از یک شبکه آموزش داده شده با اطلاعات فیزیکی مسئله برای شبیه‌سازی امواج لرزه‌ای در محیط‌های آکوستیک دوبعدی و سه‌بعدی با استفاده از میدان موج پراکنده در حوزه فرکانس استفاده کردند. رن و همکاران (Ren et al., 2022) نشان دادند که می‌توان از طریق تجزیه دامنه زمانی، کارایی محاسباتی PINN را برای مدل‌سازی امواج لرزه‌ای افزایش داد. ژانگ و

$$x^i = \sigma(w^i x^{i-1} + b^i). \quad i \in [1, n + 1] \quad (1)$$

مقدار w^i وزن و b^i مقدار بایاس را نشان می‌دهد. n تعداد لایه‌های پنهان و \square تابع فعال‌سازی را نشان می‌دهد. در شبکه‌های عصبی، لایه‌های پنهان نقش اساسی در استخراج ویژگی‌های پیچیده و مدل‌سازی روابط غیرخطی میان داده‌های ورودی و خروجی ایفا می‌کنند. در فرآیند وارون‌سازی لرزهای، این لایه‌ها به مدل امکان می‌دهند تا ساختارهای زیرسطحی زمین را با دقت بالاتری بازسازی کند، داده‌های مشاهده‌ای را به اطلاعات فیزیکی تبدیل کرده و وابستگی‌های پیچیده میان میدان موج و مدل سرعت را تشخیص دهد. انتخاب تعداد لایه‌های پنهان باید متناسب با پیچیدگی مسئله انجام شود. در مدل‌های ساده با تغییرات کم در سرعت، استفاده از تعداد محدود لایه‌های پنهان کفایت می‌کند، زیرا روابط میان داده‌های ورودی و خروجی نسبتاً خطی هستند. اما در محیط‌های پیچیده با لایه‌بندی نامنظم و تغییرات شدید سرعت، افزایش تعداد لایه‌های پنهان ضروری است تا بتوان الگوهای پیچیده‌تر را یاد گرفت و همگرایی شبکه عصبی را بهبود بخشید.

تابع فعال‌سازی یکی از بخش‌های کلیدی در شبکه‌های عصبی است که غیرخطی بودن را به مدل اضافه می‌کند و باعث می‌شود شبکه بتواند الگوهای پیچیده را یاد بگیرد. بدون وجود تابع فعال‌سازی، شبکه عصبی مانند یک مدل خطی ساده عمل می‌کند که قدرت یادگیری آن بسیار محدود خواهد بود. در شکل ۱ معماری PINN استفاده شده برای حل مسئله وارون نمایش داده شده است. ورودی شبکه یک نقطه دلخواه در زمان و مکان x, t است و خروجی شبکه تقریبی از راه‌حل میدان موج در این نقطه است. در حل معادله موج، توزیع سرعت یکی از مؤلفه‌های اساسی است که تأثیر مستقیم بر انتشار امواج لرزهای دارد. در این پژوهش، این پارامتر به‌عنوان بخشی از ساختار PINN وارد شده و نقش تعیین‌کننده‌ای در تابع هزینه ایفا می‌کند. ورودی شبکه عصبی شامل مختصات مکانی و زمانی بوده، و در فرآیند آموزش مدل، توزیع سرعت به‌عنوان یک متغیر کلیدی در تابع هزینه لحاظ شده است. این پارامتر به‌طور خاص در بخش دوم تابع هزینه ظاهر می‌شود، جایی که مدل به‌گونه‌ای بهینه‌سازی می‌شود که پیش‌بینی‌های آن با معادله موج آکوستیک سازگار باشد.

همکاران "(Zhang et al., 2023)" از این شبکه‌ها برای تخمین مدل سرعت و چگالی بر اساس معادلات موج آکوستیک بهره بردند. پاکروان "(Pakravan., 2004)"، از یک PINN برای حل معادله موج و وارون‌سازی پارامترهای معادله موج مانند سرعت موج در محیط الاستیک و ویسکوالاستیک استفاده کرد.

با وجود پیشرفت‌های چشمگیر در یادگیری ماشین، به‌ویژه در حوزه ژئوفیزیک، همچنان چالش‌هایی نظیر وابستگی به داده‌های حجیم، انتخاب مدل اولیه سرعت، و کمینه‌های محلی در وارون‌سازی لرزهای وجود دارد. در این پژوهش، یک مدل نوین مبتنی بر PINN برای وارون‌سازی لرزهای ارائه شده است که با بهره‌گیری از دانش فیزیکی، محدودیت‌های روش‌های سنتی عددی و مبتنی بر گرادینان را برطرف می‌کند. برخلاف رویکردهای کلاسیک که وابسته به انتخاب دقیق مدل اولیه سرعت هستند و ممکن است در کمینه‌های محلی گرفتار شوند، مدل پیشنهادی با تلفیق معادله موج آکوستیک در تابع هزینه، دقت بالاتری در تخمین پارامترهای مدل فراهم می‌آورد. علاوه بر این، روش مورد استفاده بدون نیاز به مش‌بندی، فرآیند حل معادله موج را بهینه‌سازی کرده و زمان پردازش را نسبت به رویکردهای سنتی کاهش داده است. در مقایسه با شبکه‌های عصبی ساده، این مدل نشان داده است که اضافه کردن قوانین فیزیکی به تابع هزینه، نه تنها دقت پیش‌بینی مدل سرعت را افزایش می‌دهد، بلکه قابلیت تعمیم‌پذیری آن را حتی خارج از داده‌های آموزشی بهبود می‌بخشد. این پژوهش با به‌کارگیری یک ساختار دوگانه برای حل همزمان مسئله پیشرو و وارون، فرآیند یادگیری شبکه عصبی را شفاف‌تر ساخته و به درک بهتر مکانیسم وارون‌سازی کمک کرده است. این رویکرد نوین، مسیری جدید در وارون‌سازی لرزهای با استفاده از یادگیری عمیق و هوش مصنوعی ایجاد می‌کند و می‌تواند به عنوان یک جایگزین کارآمد برای مدل‌سازی ساختارهای زیرسطحی زمین مورد استفاده قرار گیرد.

۲- روش پژوهش

یکی از رایج‌ترین روش‌ها برای حل معادله موج، استفاده از روش تفاضل محدود است "(Leng et al., 2019)". برای پیاده‌سازی روش تفاضل محدود نیاز به گسسته‌سازی معادله موج داریم و استفاده از فرآیند مش‌بندی می‌تواند از نظر محاسباتی بسیار پرهزینه باشد "(Moseley et al., 2020)".

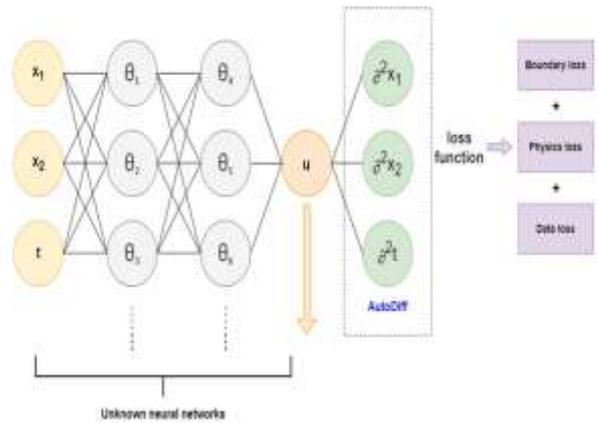
PINN نیاز به مش‌بندی‌های زمانبر ندارند و روشی بدون مش محسوب می‌شوند. به‌طور PINN شامل دو قسمت آگاه از فیزیک مسئله و قسمت ناآگاه از فیزیک مسئله می‌شوند. برای قسمت ناآگاه از فیزیک مسئله از شبکه‌های عصبی پیشخور کاملاً متصل استفاده می‌شود که شامل مختصات زمانی و مکانی در لایه ورودی و چند لایه مخفی و یک لایه خروجی می‌شود. ارتباط بین لایه‌ها در رابطه شماره (۱) نشان داده شده است که x^{i-1} و x^i ویژگی‌های ورودی و خروجی در هر لایه را نشان می‌دهند. x^i نشان‌دهنده خروجی لایه (i) و x^{i-1} نشان‌دهنده ورودی لایه قبلی $(i-1)$ است.

$$\mathcal{L}(\theta) = \frac{\lambda_1}{N_b} \sum_{i=1}^{N_b} \|u_{obs}(x_i, t_i) - \hat{u}(x_i, t_i; \theta)\|^2 \quad (4)$$

$$+ \frac{\lambda_2}{N_p} \sum_{j=1}^{N_p} \left\| \left[\nabla^2 - \frac{1}{g^2} \frac{\partial^2}{\partial t^2} \right] \hat{u}(x_j, t_j; \theta) \right\|$$

که θ پارامتر قابل آموزش شبکه، \mathcal{V} مدل سرعت و $u_{obs}(x_i, t_i)$ مجموعه داده‌های مشاهده‌ای ما با استفاده از مدل‌سازی تفاضل محدود هستند. خروجی شبکه عصبی با $\hat{u}(x_i, t_i)$ نمایش داده شده است. λ یک فرآیند پارامتر برای برقراری تعادل بین عبارات تابع هزینه است. عبارت اول راه حل PINN را با مدل‌سازی تفاضل محدود در تعدادی از گام‌های زمانی مقایسه می‌کند. عبارت دوم اعمال محدودیت فیزیک مسئله است که تلاش می‌کند تا اطمینان حاصل کند که راه حل آموخته شده توسط شبکه عصبی از معادله موج که در مسئله اضافه کردیم تبعیت می‌کند. اگر مقدار بدست آمده برای تابع هزینه از حد تعیین شده بیشتر باشد مجدد فرآیند حدس اولیه مدل سرعت انجام می‌شود و این فرآیند تا جایی ادامه پیدا می‌کند که به جواب ایده‌آل برسیم. در این پژوهش، مدل اولیه سرعت به صورت تخمینی و با استفاده از PINN تعیین می‌شود. برخلاف روش‌های سنتی که به یک مدل اولیه دقیق وابسته هستند، در اینجا شبکه عصبی از معادله موج برای بهبود تخمین اولیه سرعت استفاده می‌کند. در فرآیند آموزش، مقدار اولیه سرعت به عنوان یک پارامتر قابل تنظیم در تابع هزینه وارد می‌شود. به این فرآیند بهینه سازی گفته می‌شود که ما از بهینه‌ساز آدام برای این مسئله بهره بردیم. بهینه‌سازی آدام یکی از الگوریتم‌های پرکاربرد برای بهینه‌سازی مدل‌های یادگیری ماشین است که ترکیبی از دو روش گرادینان نزولی با مومنتوم و تخمین میانگین متحرک انطباقی را ارائه می‌دهد. این روش به دلیل سرعت همگرایی بالا و انعطاف‌پذیری، در بسیاری از مسائل یادگیری عمیق به کار گرفته می‌شود. در این پژوهش، آدام برای بهینه‌سازی پارامترهای مدل سرعت در PINN استفاده شده است. این الگوریتم باعث اصلاح تدریجی مقدار سرعت و بهبود همگرایی شبکه می‌شود و کمک می‌کند تا مدل با کمینه‌های محلی مواجه نشود و به جواب بهینه برسد.

مسائل وارون ارتباط نزدیکی با مدل‌سازی پیشرو دارند. در وارون‌سازی لرزه‌ای ما به دنبال یافتن بهترین مدل سرعت هستیم که حل مسئله پیشرو در آن بتواند بیشترین شباهت را به داده‌های مشاهده‌ای موجود داشته باشد. یکی از تفاوت‌های اصلی بین حل مسئله وارون و پیشرو در تعریف مدل سرعت است. در مدل‌سازی پیشرو مقدار سرعت یا \mathcal{V} به عنوان پارامتر معلوم به تابع هزینه اضافه می‌شود و در واقع معادله موج در مدل سرعت با استفاده از PINN حل می‌شود. در حل مسئله وارون مقدار سرعت به عنوان یک پارامتر مجهول در مسئله تعریف می‌شود که شبکه عصبی می‌خواهد مقدار آن را تخمین بزند. در مسئله پیشرو خروجی شبکه عصبی فقط میدان موج لرزه‌ای \hat{u} است و در مسئله وارون علاوه بر میدان موج لرزه‌ای، مدل سرعت هم بدست می‌آید. در واقع در فرآیند آموزش PINN، وارون‌سازی سرعت و پیش بینی جابه‌جایی میدان لرزه‌ای به طور هم‌زمان انجام می‌شود. در حل مسئله وارون از دو شبکه عصبی مجزا که خروجی شبکه اول میدان موج لرزه‌ای و شبکه دوم مدل سرعت است استفاده می‌کنیم. دلیل استفاده از دو شبکه عصبی، افزایش سرعت همگرایی است. در مدل پیشنهادی، دو



شکل ۱: PINN یک تقریب عملکردی پیوسته از راه حل را ارائه می‌دهند. در واقع ورودی شبکه یک نقطه دلخواه در مکان و زمان است. سمت چپ تصویر شبکه عصبی ناآگاه از فیزیک مسئله و سمت راست تابع هزینه و قسمت آگاه از فیزیک مسئله قابل مشاهده است.

دانش فیزیکی که قرار است به ما در حل مسئله پیشرو و وارون و استفاده از یادگیری عمیق کمک کند، معادله موج آکوستیک دو بعدی است که در رابطه شماره (۲) نمایش داده شده است:

$$\rho \nabla \cdot \left(\frac{1}{\rho} \nabla u \right) - \frac{1}{g^2} \frac{\partial^2 u}{\partial t^2} = -\rho \frac{\partial^2 f}{\partial t^2} \quad (2)$$

که در رابطه (۲) $u(x, t)$ میدان موج یا فشار امواج لرزه‌ای را نشان می‌دهد. $f(x)$ قدرت منبع لرزه‌ای، \mathcal{V} سرعت محیط و ρ چگالی محیط مورد بررسی است (Long et al., 2013). در صورت ناچیز بودن عبارت منبع نقطه‌ای (که در مرکز مدل سرعت قرار دارد) $f(x)$ و با فرض ثابت بودن چگالی محیط رابطه شماره (۳) بدست می‌آید:

$$\nabla^2 u - \frac{1}{g^2} \frac{\partial^2 u}{\partial t^2} = 0 \quad (3)$$

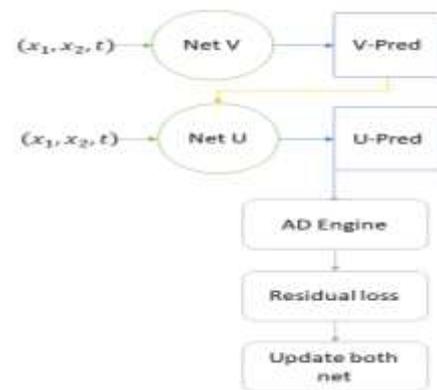
حل رابطه (۳) با استفاده از PINN می‌تواند امواج لرزه‌ای تولید شده از یک منبع نقطه‌ای را در یک مدل سرعت شبیه‌سازی کند. حل مسئله پیشرو یا شبیه‌سازی میدان موج شامل حل رابطه (۳) با توجه به محدودیت‌های مرزی و داشتن سرعت موج در یک محیط محاسباتی است. ورودی شبکه عصبی مختصات فضا و زمانی است و خروجی آن راه‌حل میدان موج تخمینی در آن مختصات است. معادله موج و مدل سرعت ورودی به طور مستقیم در تابع هزینه هنگام آموزش شبکه استفاده می‌شود. اصلی‌ترین قسمت از ساختار PINN تشکیل تابع هزینه است، جایی که دانش فیزیکی موجود از مسئله که در این پژوهش معادله موج است به طور مستقیم در تابع هزینه هنگام آموزش شبکه استفاده می‌شود. تابع هزینه شامل دو بخش اختلاف داده مشاهده‌ای و داده محاسباتی حاصل از مدل و فیزیک مسئله (رابطه شماره ۳) است که در رابطه شماره (۴) نشان داده شده است. ورودی شبکه عصبی مختصات مکان و زمان (x_1, x_2, t) است و خروجی شبکه عصبی مدل سرعت و تخمینی از میدان موج در آن مختصات است.

شکل ۳: مدل‌های مختلف سرعت برای بررسی عملکرد PINN. الف) مدل سرعت با دو لایه افقی. ب) مدل سرعت با پنج لایه افقی.

در حل مسئله پیشرو برای بررسی عملکرد روش مورد استفاده و در مسئله وارون برای تشکیل تابع هزینه و رسیدن به مدل نهایی سرعت نیاز به داده مشاهده‌ای است. در این پژوهش از کد مدل‌سازی تفاضل محدود که دقت بالایی دارد به عنوان دیتا مشاهده‌ای و اعمال شرایط مرزی مسئله استفاده شد (Komatitsch and Martin., 2007). برای هر دو مدل سرعت از یک شبکه عصبی کاملاً متصل پیشخور با سه لایه مخفی استفاده شد. تابع فعال‌سازی \tanh برای پردازش داده‌های لرزه‌ای انتخاب شد زیرا خروجی آن متقارن، گرادیان‌ها پایدار و مناسب برای یادگیری عمیق و مدل‌سازی امواج است. در گام بعدی از مشتق‌گیری خودکار برای محاسبه گرادیان‌های استفاده شد. از گرادیان‌ها در این پژوهش در فرآیند بهینه‌سازی تابع هزینه و اصلاح مدل سرعت استفاده شد. در فرآیند آموزش شبکه گرادیان تابع هزینه نسبت به پارامترهای شبکه محاسبه می‌شود تا مدل به سمت مقدار بهینه حرکت کند. این گرادیان‌ها تعیین می‌کنند که چطور وزن‌ها و بایاس‌ها در لایه‌های پنهان به‌روزرسانی شوند. برای مسئله بهینه‌سازی از الگوریتم نزول گرادیان تصادفی بهره بردیم. در نهایت اندازه دسته‌ها هم ۶۰۰ نمونه در نظر گرفته شد. اندازه دسته‌ها در شبکه عصبی مشخص می‌کند که در هر مرحله آموزش، چند نمونه داده به‌طور همزمان پردازش شود. اندازه دسته با توجه به ابعاد شبکه و پیچیدگی مدل سرعت، انتخاب شده تا شبکه تعادل بین سرعت پردازش و پایداری مدل را حفظ کند. بازه زمانی برای انتشار موج ۰.۵ ثانیه و مدل چگالی ثابت $2200 \frac{kg}{m}$ در نظر گرفته شد. در تمامی مدل‌ها از منبع نقطه‌ای با موجک ریکر و فرکانس ۲۰ هرتز در مرکز مدل سرعت استفاده کردیم. برای رسیدن به دقت بالا از ۶۰ مرحله زمانی برای آموزش شبکه و مقایسه داده محاسبه‌ای و مشاهده‌ای استفاده شد.

اولین مطالعه ما بررسی توانایی PINN برای یک مدل سرعت با دو لایه افقی است که منبع لرزه‌ای در مرکز مدل قرار دارد. پیش‌بینی‌ها برای حل مسئله پیشرو و حل مسئله وارون که هدف یافتن شبیه‌ترین مدل سرعت به واقعیت زمین است، در شکل ۴ نشان داده شده است. بررسی و مقایسه حل مسئله پیشرو و مدل سرعت نهایی در پنج مقطع زمانی نمایش داده شده است. ستون سمت چپ حل مسئله پیشرو با استفاده از شبکه عصبی آگاه از فیزیک مسئله را نشان می‌دهد. ستون دوم و سوم، داده مشاهده‌ای و اختلاف بین حل مسئله پیشرو و داده مشاهده‌ای را نشان می‌دهد. ستون سمت راست پیش‌بینی مدل سرعت توسط PINN را نشان می‌دهد که بعد از ۱۱۴۰۰ بار تکرار بدست آمده است. سطرهای اول تا پنجم به ترتیب گام‌های زمانی انتشار موج را نشان می‌دهد.

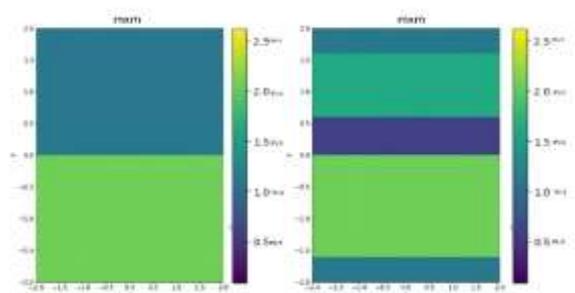
شبکه عصبی به صورت وابسته و هماهنگ آموزش داده می‌شوند. ساختار کلی در شکل ۲ نمایش داده شده است. ابتدا مختصات مکانی و زمانی (x_1, x_2, t) به هر دو شبکه داده می‌شود. شبکه Net V مقدار سرعت را پیش‌بینی می‌کند و آن را به عنوان ورودی به شبکه Net U منتقل می‌سازد. سپس شبکه Net U میدان موج را بر اساس مدل سرعت و مختصات مکانی و زمانی تولید می‌کند. از طریق مشتق‌گیری خودکار (AD) مشتقات موردنیاز برای محاسبه باقی‌مانده معادله موج استخراج شده و تابع هزینه نهایی تشکیل می‌گردد. گرادیان این تابع هزینه به صورت مشترک به هر دو شبکه منتقل شده و با استفاده از الگوریتم آدام به‌روزرسانی انجام می‌شود. این ساختار سبب می‌شود که آموزش مدل سرعت و میدان موج به صورت همزمان انجام شده و از اطلاعات فیزیکی درونی سیستم بهره‌برداری شود.

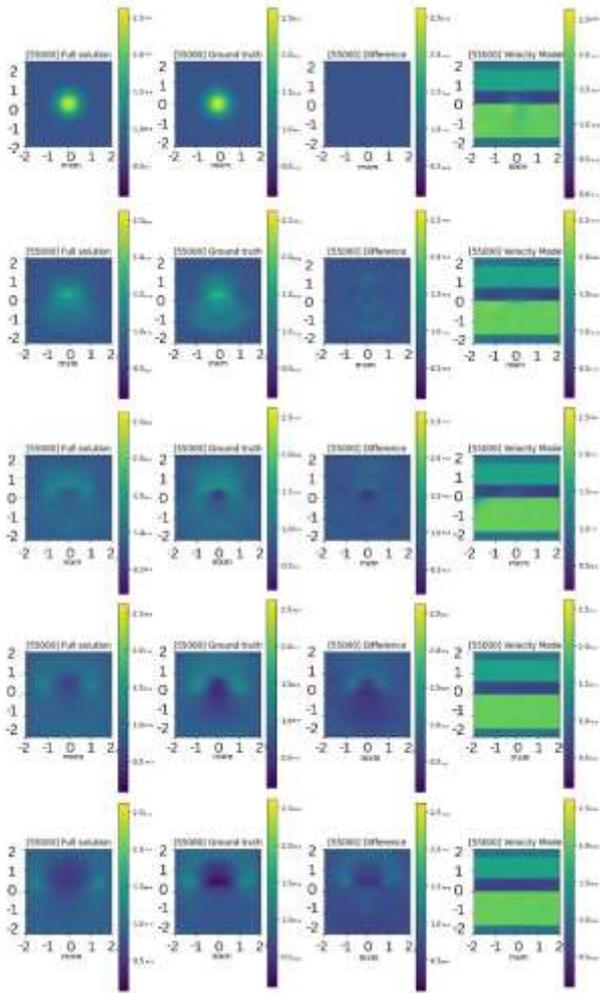


شکل ۲: دیاگرام جریان داده در ساختار دوشبکه‌ای PINN شامل شبکه‌ی مدل سرعت (Net V) و شبکه‌ی میدان موج (Net U) را نشان می‌دهد. ابتدا سرعت پیش‌بینی‌شده توسط Net V به عنوان ورودی به Net U منتقل می‌شود. سپس میدان موج با استفاده از خروجی هر دو شبکه پیش‌بینی شده و با بهره‌گیری از مشتق‌گیری خودکار (AD Engine)، باقی‌مانده معادله موج محاسبه شده و پارامترهای هر دو شبکه به صورت همزمان به‌روزرسانی می‌شوند.

۳- داده‌ها و اطلاعات

عملکرد روش پیشنهادی در دو مدل سرعت لایه ای که هر لایه سرعت متفاوتی دارد، بررسی می‌شود که در شکل ۳ نشان داده شده است.

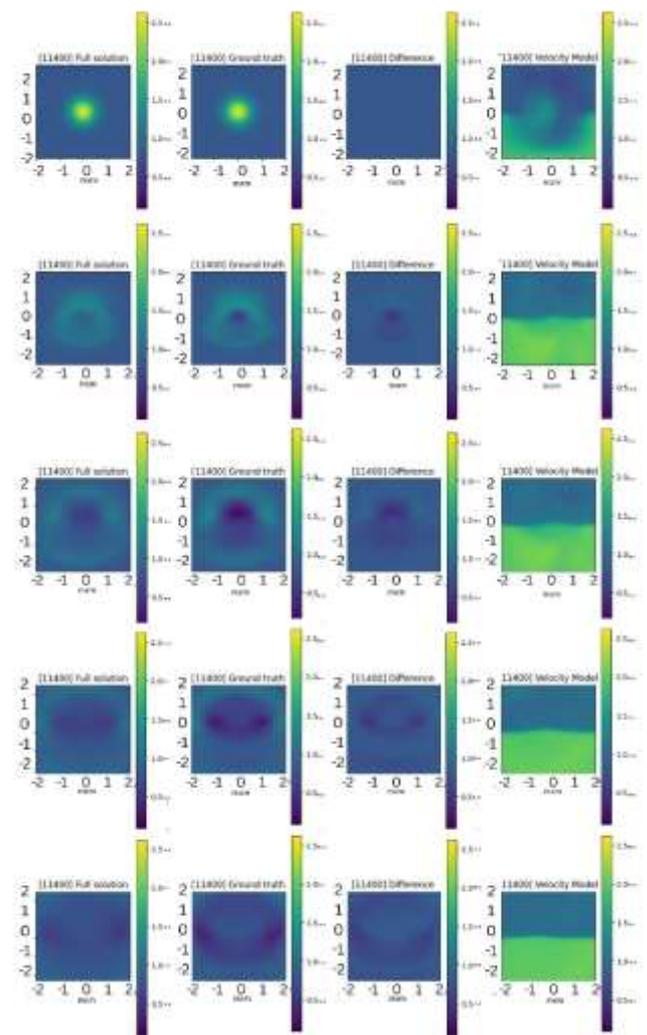




شکل ۵: حل مسئله پیشرو و وارون برای مدل سرعت با پنج لایه افقی توسط PINN. ستون سمت چپ حل مسئله پیشرو توسط شبکه عصبی آگاه از فیزیک مسئله، ستون دوم و سوم، داده مشاهده‌ای و اختلاف بین حل مسئله پیشرو و داده مشاهده‌ای را نشان می‌دهد. ستون سمت راست پیش بینی مدل سرعت توسط PINN را نشان می‌دهد. سطر اول ($t = 0$ s) یا اولین گام بررسی بعد از انتشار موج را نمایش می‌دهد. سطر دوم ($t = 0.1$ s) یا 0.1 ثانیه بعد از انتشار موج را نشان می‌دهد. سطر سوم ($t = 0.2$ s)، سطر چهارم ($t = 0.3$ s) و سطر پنجم ($t = 0.4$ s) به ترتیب زمان‌های بعد از انتشار موج را نشان می‌دهند.

به منظور شفاف‌سازی کامل فرآیند آموزش، مشخصات دقیق معماری شبکه‌های به کار رفته و پارامترهای آموزشی مربوطه در جدول ۱ ارائه شده است. این جدول شامل اطلاعاتی نظیر تعداد نرون‌های هر لایه، تعداد کل پارامترها، نرخ یادگیری، الگوریتم بهینه‌سازی، اندازه دسته آموزشی، زمان آموزش، و نوع سخت‌افزار مورد استفاده است. همچنین در این مطالعه، از طرح توقف زودهنگام استفاده نشده است. هدف اصلی، مشاهده کامل روند همگرایی و تحلیل عملکرد مدل تا تعداد مشخصی از تکرارها بوده است. توقف زودهنگام می‌توانست موجب قطع زودهنگام آموزش و کاهش شفافیت روند خطا شود.

جدول ۱: مشخصات کامل شبکه‌های PINN استفاده شده در آموزش

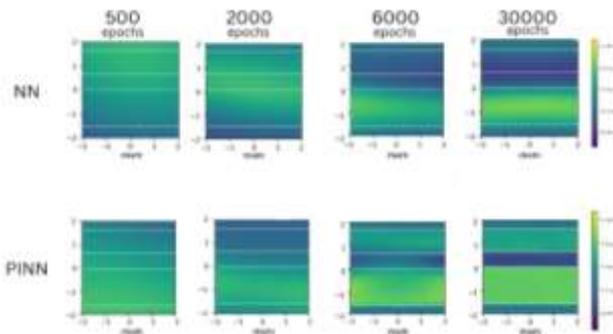


شکل ۴: حل مسئله پیشرو و وارون برای مدل سرعت با دو لایه افقی توسط PINN. ستون سمت چپ حل مسئله پیشرو توسط شبکه عصبی آگاه از فیزیک مسئله، ستون دوم و سوم، داده مشاهده‌ای و اختلاف بین حل مسئله پیشرو و داده مشاهده‌ای را نشان می‌دهد. ستون سمت راست پیش بینی مدل سرعت توسط PINN را نشان می‌دهد. سطر اول ($t = 0$ s) یا اولین گام بررسی بعد از انتشار موج را نمایش می‌دهد. سطر دوم ($t = 0.1$ s) یا 0.1 ثانیه بعد از انتشار موج را نشان می‌دهد. سطر سوم ($t = 0.2$ s)، سطر چهارم ($t = 0.3$ s) و سطر پنجم ($t = 0.4$ s) به ترتیب زمان‌های بعد از انتشار موج را نشان می‌دهند.

محیط بعدی مورد مطالعه ما یک مدل سرعت با پنج لایه افقی با ضخامت‌های مختلف است که برای شبیه‌سازی توسط PINN مورد دشواری محسوب می‌شود. در واقع میدان موج زمانی که در محیط منتشر می‌شود و به لایه‌های مختلف سرعت برخورد می‌کند فشرده و منبسط می‌شود. پیش‌بینی‌های PINN پس از آموزش و 55000 تکرار برای حل مسئله پیشرو و وارون در شکل ۵ نمایش داده شده است. در این مدل برای اجرای کامل و رسیدن به مدل سرعت بهینه حدود 70 ساعت زمان صرف شد که از یک واحد پردازنده گرافیکی 2080 و رم 128 گیگابایت استفاده شد.

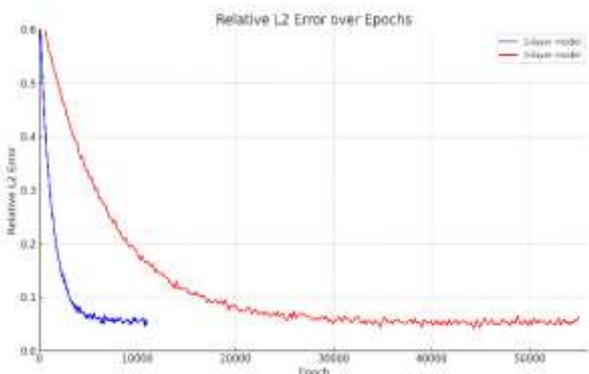
مدل	PINN - دو لایه افقی	PINN - پنج لایه افقی
-----	---------------------	----------------------

مسئله وارون لرزه‌ای می‌تواند دقت پیش‌بینی را تا حد زیادی افزایش دهد.



شکل ۷: حل مسئله وارون لرزه‌ای و مدل‌های سرعت بدست آمده با شبکه عصبی ساده و PINN با تکرارهای مختلف در مدل سرعت با پنج لایه افقی.

به منظور ارزیابی عددی عملکرد مدل‌های PINN، دو معیار مهم برای تحلیل دقت آموزش در نظر گرفته شده‌اند که شامل خطای نسبی L2 برای میدان موج و میانگین مربعات خطا (RMSE) برای مدل سرعت است. به صورت میانگین اختلاف نسبی بین میدان موج پیش‌بینی شده توسط PINN و میدان موج مرجع حاصل از مدل‌سازی تفاضل محدود روی کل دامنه تعریف می‌شود. این خطا به طور خاص روند همگرایی مدل را در طول تکرارهای آموزشی نمایش می‌دهد. شکل ۸ روند کاهش خطای نسبی L2 را برای مدل‌های دو لایه و پنج لایه افقی را نشان می‌دهد.

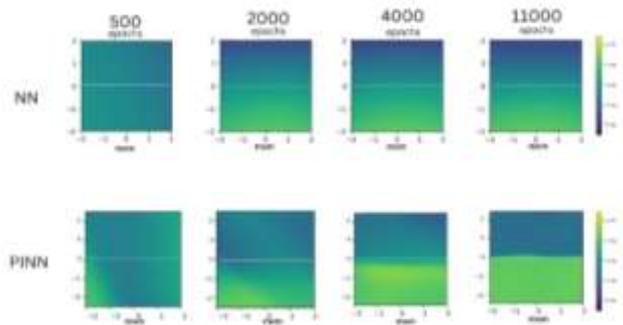


شکل ۸: نمودار خطای نسبی میدان موج (Relative L2 Error) در طول تکرارهای آموزشی برای دو معماری مختلف PINN. مدل ۲ لایه با سرعت بیشتری به مقدار کمینه خطا در تکرار ۱۱۰۰۰ می‌رسد، در حالی که مدل ۵ لایه در تکرار ۵۵۰۰۰ همگرا می‌شود. روند یادگیری با افت ناگهانی اولیه و کاهش تدریجی در ادامه همراه است.

از سوی دیگر، برای ارزیابی دقت بازسازی مدل سرعت، از خطای RMSE میان مدل سرعت واقعی و بازسازی شده استفاده شده است. نتایج کمی برای این دو معیار در جدول ۲ خلاصه شده است. مشاهده می‌شود که مقادیر خطای میدان موج و مدل سرعت در هر دو مدل به صورت

ADAM	ADAM	الگوریتم بهینه‌سازی
۲۰۰	۲۰۰	تعداد نرون در هر لایه
۱۶۱۶۰۱	۴۱۰۰۱	تعداد کل پارامترها
tanh	tanh	تابع فعال‌سازی
۰,۰۰۰۵	۰,۰۰۱	نرخ یادگیری
۶۰۰	۶۰۰	اندازه دسته
۵۵۰۰۰	۱۱۴۰۰	تعداد تکرار (epoch)
۴,۶ ثانیه	۴ ثانیه	میانگین زمان هر epoch
حدود ۷۰ ساعت	حدود ۱۲ ساعت	زمان کل آموزش
GPU RTX 2080, RAM 128GB	GPU RTX 2080, RAM 128GB	سخت افزار

یکی از مزایای استفاده از PINN نسبت به شبکه‌های عصبی ساده، تعمیم‌پذیری مدل نهایی بدست آمده است که شبکه‌های عصبی آگاه از فیزیک مسئله به دلیل وجود دانش فیزیکی در محدوده خارج از داده‌های آموزشی هم می‌توانند عملکرد مناسبی داشته باشند. یکی دیگر از چالش‌های مهم در حوزه یادگیری ماشین، نیاز به پایگاه داده گسترده و دقیق برای آموزش شبکه‌های عصبی است. با این حال، در شبکه‌های عصبی آگاه از فیزیک، حضور معادلات حاکم بر مسئله می‌تواند تا حد زیادی این چالش را برطرف کند. به طور کلی PINN با بهره‌گیری از اصول علمی و فیزیکی، نیاز به داده‌های حجیم و پیچیده را کاهش داده و به نتایج قابل اطمینان‌تر و جامع‌تری دست می‌یابند. برای درک بهتر این تفاوت‌ها مدل‌های سرعت بدست آمده با دانش فیزیکی در تکرارهای مختلف با مدل‌های سرعت بدست آمده با شبکه عصبی بدون دانش فیزیکی در مدل سرعت با دو لایه افقی مقایسه شد که در شکل ۶ نشان داده شده است.



شکل ۶: حل مسئله وارون لرزه‌ای و مدل‌های سرعت بدست آمده با شبکه عصبی ساده (NN) و PINN با تکرارهای مختلف در مدل سرعت با دو لایه افقی.

PINN نسبت به شبکه‌های عصبی ساده در حل مسئله وارون لرزه‌ای در مسائلی که داده‌های آموزشی محدودی وجود دارد، برتری قابل ملاحظه‌ای دارند. برای مدل سرعت با پنج لایه افقی هم که در شکل ۷ نشان داده شده است، این مقایسه انجام شد و با توجه به نتایج بدست آمده می‌توان به این نتیجه رسید که استفاده از دانش فیزیکی برای حل

۴- بحث

در این پژوهش عملکرد PINN برای حل معادله موج آکوستیک دو بعدی در دو مدل سرعت لایه‌ای و همچنین حل مسئله وارون (بدست آوردن مدل سرعت) بررسی شد. پیدا کردن مدل سرعت یا حل مسئله وارون با استفاده از شبکه‌های عصبی آگاه از فیزیک در مقایسه با روش‌های سنتی یا مبتنی بر گرادیان عملکرد بهتری ارائه می‌کند. یکی از برتری‌های PINN، حساس نبودن به انتخاب مدل اولیه سرعت است. در روش‌های سنتی اگر مدل سرعت اولیه دقیق انتخاب نشود احتمال گیر افتادن در کمینه‌های محلی بسیار بالا است. یکی دیگر از مزیت‌های PINN بدون مش بودن آن‌ها است که در مقایسه با روش‌های سنتی عددی از نظر زمان پردازش عملکرد به مراتب بهتری دارند.

در گام بعدی مدل‌های سرعت بدست آمده از روش PINN با مدل‌های بدست آمده از شبکه عصبی ساده یا بدون دانش فیزیکی در تکرارهای مختلف مقایسه شد و نشان دهنده این موضوع بود که با اضافه کردن معادله موج به تابع هزینه دقت پیش‌بینی‌ها بالاتر می‌رود. در واقع PINN در مقایسه با شبکه‌های عصبی ساده در جایی که از فیزیک مسئله آگاه هستیم و محدودیت در حجم داده‌های دقیق مورد نیاز برای آموزش وجود دارد، عملکرد بهتری دارند. پژوهش‌های بسیاری با استفاده از انواع شبکه‌های عصبی برای حل مسئله وارون و پیش‌رو لرزه‌ای انجام شده است که در تمامی آن‌ها چالش اصلی ساخت پایگاه داده بزرگ برای یادگیری بهتر شبکه عصبی است "(Araya-Polo et al., 2018)". در این پژوهش با اضافه کردن فیزیک مسئله به تابع هزینه، بدون پایگاه داده بزرگ یا نیاز به داده‌های برچسب‌گذاری شده، شبکه همگرا و مدل سرعت دقیق بدست آمد. برتری دیگر PINN نسبت به شبکه‌های عصبی ساده مسئله تعمیم پذیری پاسخ، خارج از محدوده داده‌های آموزشی است. در واقع PINN به دلیل داشتن اطلاعات فیزیک مسئله این توانایی را دارند که میدان موج را در مکان‌های دورتر از میدان موج اولیه شبیه‌سازی و پیش‌بینی کنند.

یکی از نکات مثبت این پژوهش کیفیت بالای پیش‌بینی‌های مدل نهایی سرعت است که به طور دقیق توانسته مرز لایه‌های افقی با ضخامت و سرعت‌های مختلف را تشخیص دهد و علت آن طراحی دقیق لایه‌های شبکه عصبی و بهره بردن از گام‌های زمانی متعدد برای مقایسه داده‌های مشاهده‌ای و داده‌های محاسبه‌ای است. این مقایسه در زمان‌های مختلف با فواصل کم باعث بالا رفتن هزینه‌های محاسباتی می‌شود اما کمک بسیار زیادی برای تشخیص دقیق مرزهای لایه‌های مختلف سرعت و مکان‌های دور از منبع لرزه‌ای می‌کند. یکی دیگر از نکات مثبت این پژوهش نمایش همزمان حل مسئله پیش‌رو و وارون لرزه‌ای در تکرارهای مختلف است که باعث شد فرآیند رسیدن به مدل سرعت نهایی قابل فهم باشد و مقداری از جعبه سیاه بودن شبکه‌های عصبی را کم کند و فرآیند رسیدن به جواب را توضیح دهد.

۵- نتیجه‌گیری

در این پژوهش، یک مدل وارون‌سازی لرزه‌ای مبتنی بر PINN ارائه شد که بدون نیاز به مدل اولیه دقیق توانست با دقت بالا ساختار زیرسطحی را

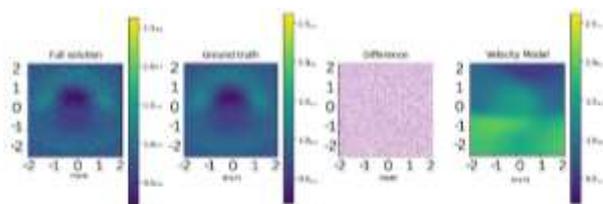
هم‌راستا کاهش یافته‌اند، که نشان‌دهنده آموزش همزمان موفق هر دو مؤلفه در چارچوب PINN است.

جدول ۲: مقایسه عملکرد مدل‌های PINN دو لایه و پنج لایه بر اساس خطای نسبی میدان موج و خطای RMSE مدل سرعت

نوع شبکه	ساختار	تعداد تکرار	L2 خطای نسبی میدان موج	RMSE خطای مدل سرعت
Simple NN	دو لایه افقی	۱۱۴۰۰	۰,۲۱	۰,۱۹
Simple NN	پنج لایه افقی	۵۵۰۰۰	۰,۱۴	۰,۱۲
PINN	دو لایه افقی	۱۱۴۰۰	۰,۰۵۵	۰,۰۵۳
PINN	پنج لایه افقی	۵۵۰۰۰	۰,۰۶۳	۰,۰۶

نتایج جدول ۲ نشان می‌دهد که شبکه دو لایه با تکرار کمتر به دقت قابل توجهی دست یافته و خطای نسبی L2 و RMSE هر دو کاهش یافته‌اند. مدل پنج لایه، به تکرارهای بیشتری برای همگرایی نیاز داشته، ولی در نهایت به دقت مشابهی دست یافته است. اختلاف ناچیز میان مقادیر L2 و RMSE به دلیل ارتباط ساختاری میان مدل سرعت و میدان موج در معادله موج است. در نهایت در مقایسه با شبکه عصبی ساده (بدون درک فیزیکی)، مدل PINN عملکرد به مراتب دقیق‌تری در تفکیک لایه‌ها و بازسازی ساختار سرعت از خود نشان داد.

به منظور ارزیابی استحکام مدل پیشنهادی در مواجهه با داده‌های دارای نویز، یک آزمایش حساسیت طراحی شد که در آن نویز گوسی سفید با نسبت سیگنال به نویز (SNR) برابر با ۲۰ دسی‌بل به داده‌های مصنوعی مدل با دو لایه افقی افزوده گردید. نتایج حاصل، که در شکل ۹ ارائه شده‌اند، نشان می‌دهند که مدل PINN با وجود حضور نویز، همچنان به همگرایی مناسب دست یافته و توانایی بازسازی دقیق حل معادله و استخراج ساختار مدل سرعت را حفظ کرده است.



شکل ۹: بررسی عملکرد مدل PINN در شرایط نویزی با SNR=20dB. از چپ به راست: میدان فشار بازسازی‌شده، داده‌ی مصنوعی (Ground truth)، تفاوت بین پیش‌بینی و داده‌ی واقعی، و مدل سرعت بازیابی‌شده.

در مقایسه با حالت بدون نویز، مقدار خطای نسبی L2 برای مدل دو لایه از مقدار ۰,۰۵۵ به حدود ۰,۰۷۴ افزایش یافت. این افزایش جزئی در خطا نشان می‌دهد که مدل در برابر نویز متوسط مقاوم بوده و کیفیت بازیابی اطلاعات حتی در شرایط نویزی نیز قابل قبول باقی مانده است. عمده تغییرات خطا در نواحی مرزی مشاهده می‌شود، اما الگوی کلی بازیابی همچنان دقیق است.

- Karimpouli, S., and Tahmasebi, P. (2020). Physics informed machine learning: Seismic wave equation. *Geosci. Front.*, 11, 1993-2001. doi: 10.1016/j.gsf.2020.06.009
- Kazei, V., Ovcharenko, O., Plotnitskii, P., Peter, D., Zhang, X., and Alkhalifah, T. (2021). Mapping full seismic waveforms to vertical velocity profiles by deep learning. *Geophysics*, 86(1), 50-61. doi:10.1190/geo2020-0219.1
- Kingma, D.P., and Ba, J. (2014). Adam: A Method for Stochastic Optimization. *ArXiv Prepr. ArXiv* 1412.6980. Retrieved from <https://arxiv.org/abs/1412.6980>
- Komatitsch, D., and Martin, R. (2007). An unsplit convolutional perfectly matched layer improved at grazing incidence for the seismic wave equation. *Geophysics*, 72(5), SM155-SM167. doi:10.1190/1.2757586
- Leng, K., Nissen-Meyer, T., van Driel, M., Hosseini, K., and Al-Attar, D. (2019). AxiSEM3D: broad-band seismic wave fields in 3-D global earth models with undulating discontinuities. *Geophys. J. Int.*, 217(3), 2125-2146. doi:10.1093/gji/ggz067
- Lin, Y., Theiler, J., and Wohlberg, B. (2023). Physics-guided data-driven seismic inversion: Recent progress and future opportunities in full-waveform inversion. *IEEE Signal Process. Mag.*, 40(1), 115-133. doi:10.1109/MSP.2023.1234567
- Long, G., Zhao, Y., and Zou, J. (2013). A temporal fourth order scheme for the restored acoustic wave equations. *Geophysical Journal International*, 194(3), 1473-1485. ISSN 1365-246X. doi:10.1093/gji/ggt155
- Moseley, B., Markham, A., and Nissen-Meyer, T. (2020). Solving the wave equation with physics-informed deep learning. *ArXiv*. Retrieved from <https://arxiv.org/abs/2004.07525>
- Moseley, B., Markham, A., and Nissen-Meyer, T. (2023). Finite basis physics-informed neural networks (FBPINNs): a scalable domain decomposition approach for solving differential equations. *Advances in Computational Mathematics*, 49(4). doi:10.1007/s10444-023-10065-9
- Pakravan, A. (2024). One-Dimensional Elastic and Viscoelastic Full-Waveform Inversion in Heterogeneous Media using Physics-Informed Neural Networks. *IEEE Access*. doi:10.1109/ACCESS.2024.3402240
- Rackauckas, C. V., and Abdelrehim, A. (2024). Scientific machine learning (sciml) surrogates for industry, part 1: The guiding questions. *OSF Preprints*. doi:10.31219/osf.io/p95zn
- 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. doi: 10.1016/j.jcp.2018.10.045
- Rashednia, R., and Pourghaz, M. (2021). Deep learning surrogate interacting Markov chain Monte Carlo based full wave inversion scheme for properties of materials

تخمین بزند. نتایج نشان داد که این روش می‌تواند زمان پردازش را کاهش داده و مشکلات روش‌های سنتی، مانند نیاز به مش‌بندی و حساسیت به انتخاب مدل اولیه سرعت را برطرف کند. شبکه‌های عصبی عمیق با اطلاعات فیزیکی قادر به حل معادله موج و تعمیم پاسخ در خارج از محدوده آموزشی خود با اضافه کردن محدودیت‌های فیزیک مسئله به طور مستقیم به تابع هزینه هستند. بررسی مدل‌های سرعت چندلایه نشان داد که PINN در تشخیص ناپیوستگی‌های سرعت عملکرد مناسبی دارد و وابستگی به داده‌های حجیم را کم می‌کند. با وجود موفقیت‌های این مدل، چندین محدودیت در پژوهش قابل بررسی است. مدل ارائه‌شده روی داده‌های مصنوعی آزمایش شده و نیاز به اعتبارسنجی در داده‌های واقعی دارد. همچنین، باید عملکرد آن در محیط‌های زمین‌شناسی پیچیده‌تر ارزیابی شود. علاوه بر این، محدودیت‌هایی در تشخیص لایه‌های نازک وجود دارد که در مطالعات آینده می‌توان با تنظیم دقیق معماری شبکه بهبود داد. این پژوهش نشان می‌دهد که ادغام قوانین فیزیکی در یادگیری ماشین می‌تواند مسیر جدیدی برای وارون‌سازی لرزه‌ای باز کند. کارهای آینده می‌تواند شامل حل معادله موج سه بعدی در محیط‌های پیچیده‌تر و استفاده از شبکه‌های عصبی مختلف مانند خودرمنگار و ترکیب آن‌ها با ساختار PINN باشد.

۶- منابع

- Adler, A., Araya-Polo, M., and Poggio, T. (2021). Deep learning for seismic inverse problems: Toward the acceleration of geophysical analysis workflows. *IEEE Signal Processing Magazine*, 38, 89-119. DOI: 10.1109/MSP.2020.3037429
- Adombi, A.V.D.P. (2024). A new causal physics-informed deep learning architecture to improve model performance in groundwater level simulation. *Zenodo*. doi: 10.5281/zenodo.1234567
- Araya-Polo, M., Jennings, J., Adler, A., and Dahlke, T. (2018). Deep-learning tomography. *The Leading Edge*, 37(1), 58-66. doi: 10.1190/tle37010058.1
- Cao, W., Song, J., and Zhang, W. (2024). A solver for subsonic flow around air foils based on physics-informed neural networks and mesh transformation. *Physics of Fluids*, 36(2). doi: 10.1063/5.0062475
- Haghighat, E., Raissi, M., Moure, A., Gomez, H., and Juanes, R. (2021). A physics-informed deep learning framework for inversion and surrogate modeling in solid mechanics. *Comput. Methods Appl. Mech. Eng.*, 379, 113741. doi: 10.1016/j.cma.2021.113741
- Hu, W., Jin, Y., Wu, X., and Chen, J. (2021). Progressive transfer learning for low-frequency data prediction in full waveform inversion. *Geophysics*, 86(1), 1-82. doi:10.1190/geo2020-0186.1
- JaberiZideh, M., Chatterjee, P., and Srivastava, A. K. (2023). Physics-informed machine learning for data anomaly detection, classification, localization, and mitigation: A review, challenges, and path forward. *IEEE Access*. doi:10.1109/ACCESS.2023.1234567

- quantification. *Journal of Sound and Vibration*. doi: 10.1016/j.jsv.2020.115694
- Rasht-Behesht, M., Huber, C., Shukla, K., and Karniadakis, G.E. (2022). Physics-Informed Neural Networks (PINNs) for wave propagation and full waveform inversions. *JGR Solid Earth*, 127, e2021JB023120. doi:10.1029/2021JB023120
- Ren, P., Rau, C., Sun, H., and Liu, Y. (2022). SeismicNet: Physics-informed neural networks for seismic wave modeling in semi-infinite domain. *ArXiv*. doi:10.48550/arXiv.2210.14044
- Rezaei, M., Diepeveen, D., Laga, H., Jones, M.G.K., and Sohel, F. (2024). Plant disease recognition in a low data scenario using few-shot learning. *Computers and Electronics in Agriculture*, 219, 108812. doi: 10.1016/j.compag.2024.108812
- Robein, E. (2010). *Seismic imaging: a review of the techniques, their principles, merits and limitations*. EAGE Publications.
- Smith, J., Azizzadenesheli, K., and Ross, Z.E. (2021). EikoNet: Solving the Eikonal Equation with Deep Neural Networks. *IEEE Transactions on Geoscience and Remote Sensing*, 59(12), 10685-10696. doi:10.1109/TGRS.2020.3039165
- Song, C., Alkhalifah, T., and Waheed, U. B. (2021). Solving the frequency-domain acoustic VTI wave equation using physics-informed neural networks. *Geophysical Journal International*, 225(2), 846-859. doi:10.1093/gji/ggab010
- Sun, H., and Demanet, L. (2020). Extrapolated full-waveform inversion with deep learning. *GEOPHYSICS*, 85, R275-R288. doi:10.1190/geo2019-0150.1
- Wang, J., Meng, X., Liu, H., Zheng, W., and Liu, Y. (2018). Full waveform inversion based on the ensemble Kalman filter method using uniform sampling without replacement. *Science Bulletin*. doi: 10.1016/j.scib.2018.08.027
- Wu, Y., Lin, Y., and Zhou, Z. (2018). Inversionet: Accurate and efficient seismic-waveform inversion with convolutional neural networks. *SEG Technical Program Expanded Abstracts 2018*, Society of Exploration Geophysicists, 2096-2100. doi:10.1190/segam2018-2996590.1
- Zhang, Y., Zhu, X., and Gao, J. (2023). Seismic inversion based on acoustic wave equations using physics informed neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 61. doi:10.1109/TGRS.2023.3236973
- Zhu, S.P., Wang, L., Luo, C., Correia, J.A.F.O., Jesus, A.M.P.D., and Berto, F. (2024). Physics-informed machine learning and its structural integrity applications: State of the art. *Philos. Trans. R. Soc. A*, 381, 20220406. doi:10.1098/rsta.2022.0406