

واهمامیخت لرزه‌های کور دوبعدی از طریق شبکه عصبی همامیختی

فاطمه خالویی^{۱*}، حجت حق‌شناس لاری^۲ و پروین رزاقی^۳

^۱ دانشجوی کارشناسی ارشد لرزه‌شناسی، دانشکده علوم زمین، دانشگاه تحصیلات تکمیلی علوم پایه زنجان، زنجان، ایران

^۲ استادیار، دانشکده علوم زمین، دانشگاه تحصیلات تکمیلی علوم پایه زنجان، زنجان، ایران

^۳ استادیار، دانشکده فناوری اطلاعات و علوم رایانه، دانشگاه تحصیلات تکمیلی علوم پایه زنجان، زنجان، ایران

(دریافت: ۱۴۰۳/۰۵/۲۳، پذیرش: ۱۴۰۳/۰۸/۰۱)

چکیده

برای افزایش وضوح داده‌های لرزه‌نگاری باید اثر موجک لرزه‌ای را از روی داده‌های لرزه‌ای حذف نمود. این کار با استفاده از عملگر واهمامیخت در مرحله پردازش داده‌های لرزه‌ای انجام می‌گیرد. عموماً، واهمامیخت داده‌های لرزه‌ای به صورت تک‌کاناله و چندکاناله بر روی داده‌ها اعمال می‌شود. ویژگی روش واهمامیخت چندکاناله، در نظر گرفتن ارتباط بین رخدادها در داده است. واهمامیخت را می‌توان به دو روش غیرکور و کور اعمال کرد. در روش‌های واهمامیخت کور، موجک چشمه مشخص نیست و باید آن را هنگام انجام واهمامیخت تخمین زد. در روش‌های مرسوم واهمامیخت، عموماً از روش‌های بهینه‌سازی و وارون‌سازی استفاده می‌شود. برای به دست آوردن پاسخ صحیح در این روش‌ها، نیاز است تا پارامترهای منظم‌سازی به صورت صحیح انتخاب شوند. این کار برای داده‌های بزرگ‌مقیاس بسیار دشوار و زمان‌بر است و عموماً، نیاز است تا کاربر برای تعیین این پارامترها در حل مسئله دخالت داشته باشد. از این رو باید یک روش خودکار برای این کار معرفی شود. روش‌های یادگیری عمیق برای این بردن این چالش معرفی شده‌اند تا به صورت خودکار ارتباط بین داده‌های ورودی و داده‌های خروجی را یافته، بدون نیاز به تعیین پارامترها برای هر داده، نیاز به دخالت انسان را به حداقل برسانند. در این مقاله یک روش واهمامیخت کور دوبعدی بر اساس یکی از روش‌های یادگیری عمیق معرفی خواهد شد تا واهمامیخت به صورت کاملاً خودکار و با کمترین نیاز به تعیین پارامترهای بهینه‌سازی و تخمین موجک، به صورت چندکاناله انجام شود. برای این کار از شبکه عصبی همامیختی دوبعدی استفاده می‌گردد. به علاوه با مثال‌های مصنوعی و واقعی نشان خواهیم داد که برای آموزش این روش استفاده از داده‌های با ساختار ساده کفایت می‌کند و نیازی نیست تا داده‌ها کاملاً شبیه به داده‌های ورودی مسئله باشند. در این مثال‌ها نشان می‌دهیم که این روش برای انجام واهمامیخت کور دوبعدی به خصوص در حضور نوفه از عملکرد مطلوبی برخوردار است.

کلمه‌های کلیدی: واهمامیخت کور، شبکه عصبی همامیختی، عملگر دوبعدی

۱ مقدمه

هدف از انجام لرزه‌نگاری بازتابی، آشکارسازی ساختار و خواص لایه‌های زیرسطحی زمین است. با استفاده از این روش می‌توانیم ساختارهای داخلی زیرسطحی، به‌ویژه ساختارهای زمین‌شناسی مانند لایه‌ها، کانال‌ها، تله‌ها و گسل‌ها را به تصویر درآورده و آن‌ها را بررسی کنیم. تصاویر لرزه‌ای به‌عنوان ابزاری برای مکان‌یابی ذخایر معدنی و منابع انرژی مانند هیدروکربن‌ها اهمیت بالایی دارند (شریف و گلدارت، ۱۹۸۳؛ ایلماز، ۲۰۰۱). به‌علاوه، از روش‌های لرزه‌نگاری برای به‌دست‌آوردن اطلاعات زمین‌شناسی به‌منظور انجام مطالعات مهندسی، مطالعات مربوط به انرژی زمین‌گرمایی، ارزیابی خطرات سونامی، مکان‌یابی فعالیت‌های زیرزمینی برای اهداف امنیتی مانند تشخیص تونل (گوربوز و همکاران، ۲۰۰۶) استفاده می‌شود. به‌منظور ثبت داده‌های لرزه‌نگاری، یک سیگنال صوتی با طول‌موج کوتاه به نام موجک در زمین منتشر می‌شود. این موجک پس از بازتابش از لایه‌های درون زمین توسط آرایه‌ای از گیرنده‌ها ثبت می‌گردد. پس از این مرحله داده‌های به‌دست‌آمده به داده‌های لرزه‌ای چندبُعدی تبدیل شده و در مراحل بعد پردازش می‌شوند (شریف و گلدارت، ۱۹۸۳). موجک ارسال‌شده به درون زمین دارای محدودیت فرکانسی بوده و از این‌رو باعث کاهش وضوح داده‌های لرزه‌ای برداشت‌شده خواهد شد. از این‌رو یکی از مراحل مهم پردازشی، اعمال واهمامیخت به‌منظور حذف اثر موجک از روی داده‌ها و افزایش پهنای فرکانسی داده‌های لرزه‌ای است.

تابه‌حال روش‌های زیادی برای انجام واهمامیخت معرفی شده است (ویگنیز، ۱۹۸۷؛ تیلور و همکاران، ۱۹۷۹، ریل و برخوت، ۱۹۸۵؛ نگوین و کاستاگنا، ۲۰۱۰؛ ژنگ و کاستاگنا، ۲۰۱۱؛ غلامی و ساکی، ۲۰۱۲). در تمامی این روش‌ها فرض می‌شود که داده‌های لرزه‌ای از ردلرزه‌هایی تشکیل شده‌اند که از واهمامیخت یک موجک لرزه‌ای با

سری بازتابش زمین به‌دست‌آمده و مقداری نوفه تصادفی به آن افزوده شده است. این نگرش به داده‌های لرزه‌نگاری را مدل واهمامیخت زمین گویند. از آنجایی که عمدتاً فرض بر این است که سری بازتابش زمین تُنک است، به‌منظور بازیابی این سری‌های زمانی از روی داده‌های لرزه‌نگاری در برخی از این روش‌های واهمامیخت، از نُرم l_1 برای افزایش تُنکی این ردلرزه‌ها استفاده می‌شود (نگوین و کاستاگنا، ۲۰۱۰؛ غلامی و ساکی، ۲۰۱۲).

به‌علاوه، به‌منظور در نظر گرفتن رابطه بین سری‌های زمانی، گاه فرض می‌شود که این داده‌ها با داده‌های همسایه خود دارای همبستگی هستند. از این‌رو برخی از روش‌های واهمامیخت، داده‌های لرزه‌ای را به‌صورت چندبُعدی در نظر می‌گیرند (آیدیر و گوسارد، ۱۹۹۳؛ مندل و همکاران، ۱۹۸۱، کارسن و تکست، ۱۹۹۸؛ هیمر و همکاران، ۲۰۰۷؛ هیمر و کوهن، ۲۰۰۸ و ۲۰۰۹؛ رَم و همکاران، ۲۰۱۰؛ غلامی و ساکی، ۲۰۱۳). این کار کمک می‌کند تا در زمان بازیابی سری بازتابش لرزه‌ای، اطلاعات مکانی بین داده‌ها نیز توسط عملگر واهمامیخت در نظر گرفته شود؛ بنابراین پیوستگی افقی وقایع لرزه‌ای نیز در این روش‌ها حفظ می‌گردد و از طرفی تضعیف نوفه‌های تصادفی در آن‌ها افزایش می‌یابد (غلامی و ساکی، ۲۰۱۳). در این روش‌های واهمامیخت گاه فرض می‌شود که موجک چشمه از قبل معلوم نیست و برای انجام واهمامیخت از روش‌های واهمامیخت کور استفاده می‌کنند (هیمر و همکاران، ۲۰۰۷؛ غلامی و ساکی، ۲۰۱۳).

از سوی دیگر، در برخی روش‌های واهمامیخت فرض می‌شود موجک در طول مسیر خود درون زمین ثابت بوده و تغییری نمی‌کند (رابینسون، ۱۹۸۵؛ ساکی و همکاران، ۱۹۹۴). با این‌حال این فرض چندان با واقعیت سازگاری ندارد. یک موجک لرزه‌ای از زمان تولید توسط چشمه تا زمان ثبت آن توسط گیرنده دستخوش تغییراتی در فرکانس، فاز و دامنه می‌شود. از این‌رو، استفاده از این فرض

معتبر برای درک زمین‌شناسی در حوزه زمان به‌خصوص در مواجهه با داده‌های بزرگ‌مقیاس به‌کار آید. بین و همکاران (۲۰۲۴) یک روش مبتنی بر یادگیری ماشین خودنظارت‌شده (self-supervised) برای واهمایخت کور پیشنهاد کرده‌اند که بدون نیاز به مویک معین به انجام واهمایخت مبادرت می‌ورزد.

از روش‌های یادگیری عمیق در زمینه انجام واهمایخت لرزه‌ای نیز استفاده شده است. به‌عنوان مثال پرگ و همکاران (۲۰۲۰) از شبکه عصبی بازگشتی (RNN) به منظور واهمایخت دوبعدی داده‌های لرزه‌ای استفاده کرده‌اند. در روش معرفی شده توسط آن‌ها سعی شده تا با استفاده از شبکه عصبی بازگشتی همبستگی زمانی داده‌های لرزه‌ای حفظ گردد. چای و همکاران (۲۰۲۱) سعی کرده‌اند تا با استفاده از شبکه عصبی همایختی (CNN) به‌صورت دوبعدی، واهمایخت مویک چشمه را انجام دهند. در روش آن‌ها سعی شده تا وابستگی مکانی و زمانی هر نقطه از سری ضرایب بازتاب با نقاط اطراف آن حفظ شود. چن و همکاران (۲۰۲۳) از روش یادگیری عمیق نیمه نظارت‌شده (semi-supervised) استفاده کرده‌اند تا تغییرات مویک چشمه را درون زمین در نظر بگیرند. در روش آن‌ها مویک چشمه و ضرایب بازتاب به‌صورت همزمان تخمین زده می‌شوند. از این‌رو، روش آن‌ها جزو روش‌های واهمایخت ناپایای کور دسته‌بندی می‌شود.

در این مقاله، به معرفی یک روش واهمایخت لرزه‌ای کور با استفاده از شبکه عصبی همایختی (CNN) دوبعدی پرداخته خواهد شد. روش معرفی شده در مقاله می‌تواند علاوه بر در نظر گرفتن وابستگی افقی و عمودی سری‌های بازتاب و با کمترین اطلاعات اولیه از مویک چشمه، ضرایب بازتاب را تخمین بزند. به همین دلیل یک روش واهمایخت کور دوبعدی محسوب می‌گردد. به‌علاوه، در این روش نیازی نیست تا کاربر برای انجام واهمایخت بر روی هر داده، پارامترهای مربوط به آن را به‌صورت مجزا

با واقعیت چندان سازگار نیست. روش‌های واهمایخت ناپایای داده‌های لرزه‌ای برای حل این ایراد معرفی شده‌اند (هارگارو و کالورت، ۱۹۹۱؛ مارگارو و همکاران، ۲۰۱۱؛ ون در بن، ۲۰۱۲؛ حق‌شناس‌لاری و غلامی، ۲۰۱۹؛ لی و لیو، ۲۰۲۲؛ سان و همکاران، ۲۰۲۴).

بیشتر روش‌های واهمایخت از روش‌های وارون‌سازی برای حل مسئله تُنک‌سازی استفاده می‌کنند. از طرفی روش‌های وارون‌سازی نیازمند تخمین دقیق تعداد زیادی پارامتر منظم‌سازی برای حل این‌گونه مسائل هستند. انجام این تخمین‌ها به‌خصوص برای داده‌های بزرگ‌مقیاس لرزه‌ای می‌تواند زمان‌بر بوده و یا تخمین آن‌ها با خطای بالایی همراه باشد. در سال‌های اخیر استفاده از روش‌های یادگیری ماشین و یادگیری عمیق در لرزه‌نگاری توانسته تا حدودی این نگرانی را برطرف نماید. از این روش‌ها در زمینه‌های مختلف پردازش و تفسیر داده‌های لرزه‌نگاری استفاده شده است. به‌عنوان مثال از این روش‌ها به‌منظور تخمین و انتخاب سرعت برون راند نرمال (NMO) (فیش و کوسوما، ۲۰۰۵)، انتخاب سرعت برانبارش لرزه‌ای (بیسواس و همکاران، ۲۰۱۸)، ساختن مدل سرعت لرزه‌ای از روی داده‌های لرزه‌نگاری (لی و همکاران، ۲۰۱۹) و یافتن گسل (آرای-پولو و همکاران، ۲۰۱۷) استفاده شده است.

به‌علاوه، در سال‌های اخیر روش‌های پردازشی و تفسیری جدیدی با استفاده از روش‌های یادگیری ماشین معرفی شده‌اند. پریژف و استینسیلیو (۲۰۱۸) وارون‌سازی کلاسیک لرزه‌ای را با الگوریتم‌های یادگیری ماشین برای پیش‌بینی ویژگی‌های مخزن مقایسه کرده و پیشنهاد می‌کنند که روش‌های غیرخطی یادگیری ماشین ممکن است در محیط‌های زمین‌شناسی پیچیده دقت بیشتری داشته باشند. راسل (۲۰۱۹) مقایسه‌ای بین وارون‌سازی زمین‌شناسی و رویکردهای یادگیری ماشین انجام داده است و نشان می‌دهد که یادگیری ماشین می‌تواند به‌عنوان یک جایگزین

که در این رابطه (*) نشانگر عملگر همایخت زمانی است. البته باید تاکید کرد که در واقعیت استفاده از این مدل برای کل داده‌های لرزه‌نگاری صحیح نیست چرا که داده‌های لرزه‌نگاری در طول مسیر خود درون زمین دستخوش تغییراتی در دامنه، فرکانس و فاز می‌شوند. از این رو، باید تاکید کرد که این مدل همایخت فقط برای قسمت کوچکی از داده‌های لرزه‌ای صادق است و برای داده‌های بزرگ‌تر باید از مدل‌های دیگری مانند مدل واهمایخت ناپایای زمین استفاده نمود (مارگارو و همکاران، ۲۰۱۱). با این حال در تمام این مقاله فرض می‌شود که موجک چشمه در داده‌های مورد بررسی تغییری نداشته است. در صورتی که موجک چشمه (W) معلوم باشد، می‌توان با استفاده از رابطه زیر، واهمایخت داده‌های لرزه‌ای را برای به دست آوردن ضرایب بازتاب (r) انجام داد (غلامی و ساکی، ۲۰۱۳).

$$\arg \min_{\mathbf{r}} \{ \|\mathbf{s} - \mathbf{w} * \mathbf{r}\|_2^2 + \lambda_1^2 \|\nabla_x \mathbf{r}\|_1 + \lambda_2^2 \|\nabla_t \mathbf{r}\|_1 \} \quad (2)$$

در رابطه (۲) $\|\cdot\|_1$ نشان‌دهنده نُرم یک و $\|\cdot\|_2$ نشان‌دهنده نُرم دو، ∇_i برای $i \in x, t$ مشتق مرتبه اول در جهت‌های مکانی و زمانی و λ_1 و λ_2 ضرایب لاگرانژ هستند. برای حل این رابطه می‌توان از روش برگمن دوبخشی (گلدستین و اوشر، ۲۰۰۹) استفاده نمود. می‌توان برای به دست آوردن موجک چشمه از رابطه (۳) استفاده کرد.

$$\arg \min_{\mathbf{r}} \{ \|\mathbf{s} - \mathbf{r} * \mathbf{w}\|_2^2 \} \quad (3)$$

در این رابطه موجک چشمه از واهمایخت مقطع ضرایب بازتاب (r) و مقطع داده‌ها (s) به دست می‌آید.

۲-۲ شبکه عصبی CNN

شبکه عصبی همایختی (CNN) نوعی شبکه عصبی است که عموماً به منظور پردازش داده‌هایی که به صورت یک شبکه قابل نمایش هستند، مانند تصاویر، استفاده می‌شود. این شبکه از قشر بینایی حیوانات الهام گرفته شده است (هابل و

تعیین نماید و یک بار آموزش مدل برای این کار کافی است. از این رو، استفاده از این روش به روش‌های واهمایخت مرسوم پیشنهاد می‌شود. برای بررسی توانایی این روش، ابتدا این روش بر روی یک داده مصنوعی دوبعدی اعمال می‌شود. به منظور بررسی عملکرد روش در لبه گسلش‌ها، در این داده‌ها چند گسله در نظر گرفته شده است. سپس توانایی روش برای اعمال بر روی داده‌های آلوده به نوفه تصادفی بررسی شده است. در نهایت نیز از داده‌های لرزه‌نگاری دوبعدی واقعی برای بررسی عملکرد این روش استفاده می‌شود. در تمامی این آزمایش‌ها نشان داده خواهد شد که یکی از نقاط قوت این روش علاوه بر کاهش نیاز به تعیین پارامترهای منظم‌سازی، استفاده از داده‌های با ساختار ساده برای آموزش مدل معرفی شده برای داده‌های پیچیده است.

۲ روش پژوهش

در این بخش به معرفی روش واهمایخت کور دوبعدی مبتنی بر یادگیری عمیق پرداخته خواهد شد. از این رو، ابتدا مدل همایخت زمین توضیح داده می‌شود و یک روش مرسوم واهمایخت برای مقایسه با روش واهمایخت معرفی شده در این مقاله معرفی خواهد شد و پس از آن در مورد شبکه عصبی همایختی به صورت مختصر صحبت می‌گردد. در انتها نیز مدل واهمایخت کور دوبعدی بر اساس شبکه عصبی همایختی و لایه‌های مورد استفاده در این مدل ارائه خواهد شد.

۱-۲ مدل همایخت زمین

مدل همایخت مرسوم زمین بیان می‌کند که داده‌های لرزه‌نگاری $(s(t,x))$ از همایخت سری بازتابش زمین $(r(t,x))$ با موجک چشمه $(W(t))$ به همراه مقداری نوفه تصادفی $(n(t,x))$ ایجاد شده‌اند:

$$s(t,x) = W(t) * r(t,x) + n(t,x) \quad (1)$$

معماری CNN پیشنهادی به منظور اعمال روش واهمایخت کور دوبعدی در جدول (۱) نمایش داده شده است. برای به دست آوردن پاسخی مناسب برای انجام واهمایخت کور باید این شبکه با داده‌های مناسب آموزش داده شود. داده‌هایی که برای آموزش این شبکه به کار می‌روند با استفاده از واهمایخت یک موجک تخمین زده شده و یک مقطع دوبعدی ضرایب بازتاب ساخته می‌شوند.

به دنبال هر کدام از لایه‌های همایختی در جدول ۱ یک لایه نرمال‌کننده (Batch Normalization) و به عنوان تابع فعال‌سازی (Activation function) از تانزانت هایپربولیک $(\tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x}))$ استفاده شده است. دلیل استفاده از این تابع، توانایی آن در بازیابی اعداد به صورت منفی به صورت همزمان است که مشخصه داده‌های لرزه‌نگاری است. از این رو استفاده از این تابع نسبت به توابع فعال‌سازی مانند تابع واحد یک‌سوسودهی خطی (Rectified Linear Unit) (ReLU) که فقط توانایی بازیابی قسمت مثبت داده‌های ورودی را دارند، ارجحیت دارد. وظیفه لایه نرمال‌کننده، نرمال کردن خروجی لایه قبلی با کم کردن میانگین آن از کل اعداد و تقسیم باقیمانده به انحراف معیار داده‌ها است.

متأسفانه در بیشتر برداشت‌های لرزه‌نگاری امکان ثبت موجک چشمه وجود ندارد. این رخداد به خصوص در داده‌های لرزه‌نگاری مربوط به خشکی بیشتر اتفاق می‌افتد. از این رو، تخمین موجک اولیه برای این گونه داده‌ها یا با

ویسل، ۱۹۶۸) و به گونه‌ای طراحی شده که بتواند به صورت سلسله‌مراتبی، خصوصیات یک الگو در مکان را از کم به زیاد به صورت خودکار یاد بگیرد. شبکه عصبی همایختی یک ساختار ریاضی است که از سه نوع لایه تشکیل شده است: لایه همایخت، لایه ادغام و لایه‌های کاملاً متصل (یاماشیتا و همکاران، ۲۰۱۸). لایه همایخت ورودی را با فیلترهای همایخت ترکیب می‌کند تا نقشه ویژگی‌های تغییر یافته را ایجاد کند. عموماً این شبکه به صورت یک تابع ψ به صورت زیر نوشته می‌شود:

$$y = \psi(x, w, b) \quad (4)$$

در این رابطه y داده پیش‌بینی شده، x داده‌های ورودی، w ماتریس وزن‌دهی و b بردار بایاس است. CNN شبکه‌ای است که در آن تمامی لایه‌های پنهان آن همایختی است. در این شبکه مقادیر w و b در هر تکرار به روز می‌شود و این کار تا زمان کمینه شدن تابع هزینه ادامه می‌یابد. در این روند، پارامترهای قابل آموزش با انتشار رو به عقب (backpropagating) خطاها در لایه‌ها اصلاح می‌گردند. این کار با استفاده از یک الگوریتم بهینه‌سازی انجام می‌گیرد (راملهارت و همکاران، ۱۹۸۶). در این مقاله از الگوریتم آدام (کینگما و با، ۲۰۱۴) برای این کار استفاده می‌شود.

۲-۳ واهمایخت کور دوبعدی با استفاده از روش CNN

جدول ۱. معماری شبکه برای انجام واهمایخت کور دوبعدی برای یک داده با اندازه ۶۴ نمونه مکانی و ۱۲۸ نمونه زمانی. رنگ سبز نشان‌دهنده لایه همایختی، رنگ خردلی نشان‌دهنده تابع نرمال‌کننده (Batch Normalization) و رنگ آبی نشان‌دهنده تابع تانزانت هایپربولیک است.

لایه	۱	۲	۳	۴	۵
اندازه فیلتر	۲۵۶	۲۵۶	۲۵۶	۱۲۸	۱
اندازه هسته	۵	۱	۱	۱	۱
	Batch Normalization	Batch Normalization	Batch Normalization	Batch Normalization	Batch Normalization
	tanh	tanh	tanh	tanh	tanh

آموزش مدل معرفی شده در این مقاله استفاده نمود. خلاصه مراحل ساخت داده‌ها به صورت یک الگوریتم در شکل ۱ نشان داده شده است.

در شکل ۱ می‌توان هر مقطع لرزه‌ای با خصوصیات متفاوت مانند گسله و یا لایه‌های افقی و شیب‌دار با دامنه‌های متفاوت را ساخت و از آن استفاده نمود. در قسمت بعد، با نمایش چند مثال توانایی روش معرفی شده را در انجام واهمامیخت کور نمایش خواهیم داد.

۳ اندازه‌گیری، مشاهده و محاسبه

در این قسمت چند داده مصنوعی و واقعی برای نمایش توانایی روش معرفی شده در قسمت قبل مورد استفاده قرار می‌گیرد. در قسمت داده‌های مصنوعی، سطوح مختلفی از نوفه تصادفی گوسی به داده افزوده می‌شود تا بتوان توانایی روش را در حضور نوفه‌های تصادفی بررسی نمود. به علاوه در این قسمت از داده‌هایی به همراه گسله استفاده شده تا بتوان عملکرد روش را در لبه گسله‌ها مطالعه کرد.

۱-۳ داده‌های مصنوعی

شکل ۲-آ یک مقطع ضرایب بازتاب با چهار گسله را نمایش می‌دهد. فاصله نمونه‌برداری در این شکل چهار میلی‌ثانیه است. این چهار گسله به منظور بررسی عملکرد روش در مرز آن‌ها قرار داده شده است. شکل ۲-ب از همامیخت شکل ۲-آ با یک موجک ریکر با فرکانس قله ۲۵ هرتز و فاز صفر درجه حاصل شده است. شکل ۲-پ مقطع ضرایب بازتاب به دست آمده از واهمامیخت کور معرفی شده در این مقاله محاسبه شده است. شکل ۲-ت تفاضل شکل ۲-آ و شکل ۲-پ را نشان می‌دهد. همان‌طور که در این شکل ملاحظه می‌شود میزان باقیمانده در مرز گسله‌ها بیشتر از باقی قسمت‌ها است. به علاوه مقداری باقیمانده در باقی قسمت‌ها نیز دیده می‌شود.

استفاده از روش‌های آماری و یا با استفاده از تطابق داده‌های چاه با داده‌های لرزه‌نگاری انجام می‌گیرد (کوی و مارگارو، ۲۰۱۴). در این مقاله برای تخمین موجک، از طیف دامنه خودهمبستگی (autocorrelation) ردلرزه‌ها استفاده می‌شود. کوی و مارگارو (۲۰۱۴) نشان داده‌اند که طیف دامنه موجک $|w(f)|$ با طیف دامنه خودهمبستگی ردلرزه‌ها $|s(f)|^2$ از رابطه زیر پیروی می‌کند:

$$|s(f)|^2 = \alpha |w(f)|^2 \quad (5)$$

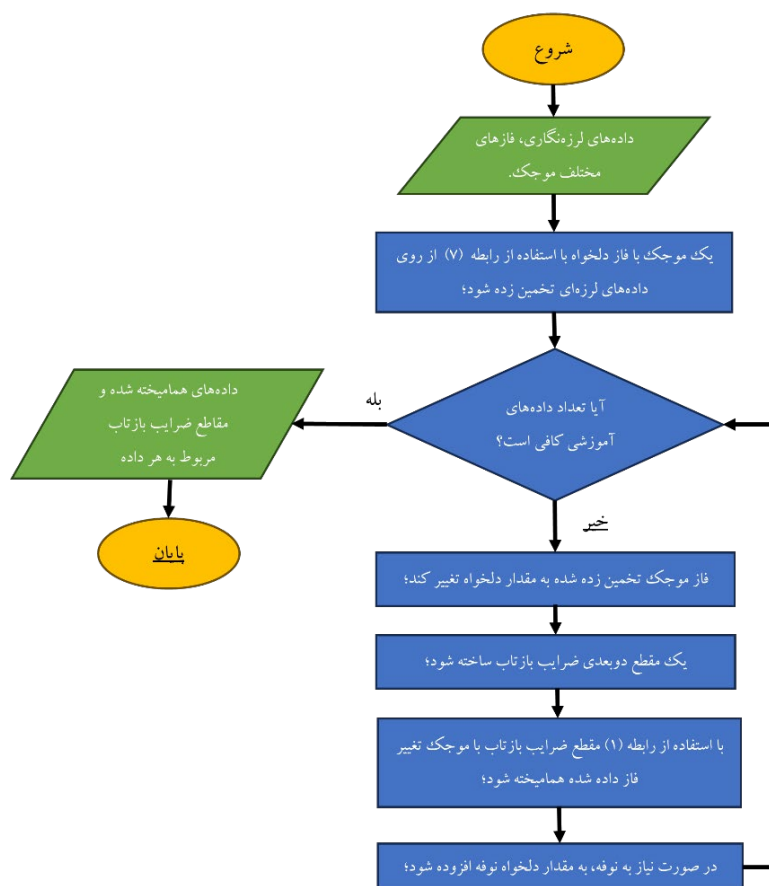
در رابطه بالا $|\cdot|$ علامت قدرمطلق است. از این رو می‌توان با به دست آوردن طیف دامنه یک ردلرزه، ضریبی (α) از طیف دامنه موجک را به دست آورد. برای تعیین موجک می‌توان هر فازی (φ) را برای موجک در نظر گرفت. با این حال برای داده‌های واقعی منطقی‌تر آن است که فاز موجک چشمه را کمینه فرض کنیم و با استفاده از رابطه زیر فاز کمینه ($\varphi_{min}(f)$) آن را محاسبه می‌نماییم (مارگارو، ۲۰۱۳):

$$\varphi_{min}(f) = \text{Hilbert}(\ln(|w(f)|)) \quad (6)$$

در این رابطه $\text{Hilbert}()$ تبدیل هیلبرت و $\ln(x)$ لگاریتم طبیعی مقدار x است. از این رو، می‌توان موجک با فاز دلخواه به صورت زیر تخمین زد:

$$w(f) = |w(f)|e^{i\varphi(f)} \quad (7)$$

که در آن e^a تابع نمایی است. موجک به دست آمده از رابطه بالا بسیار نزدیک به موجک چشمه خواهد بود. با این حال این روش نمی‌تواند دقیقاً همان موجک چشمه را تخمین بزند. از این رو نتایج واهمامیخت مطلوب نخواهد بود. از آنجایی که طیف دامنه موجک حاصل از روی طیف دامنه ردلرزه‌ها ایجاد شده، می‌توان فرض کرد که طیف دامنه موجک صحیح است و رابطه (۵) برقرار است. با این حال فاز موجک را می‌توان با استفاده از رابطه بالا تغییر داد به گونه‌ای که چندین موجک با فاز کمینه، چندین موجک آمیخته فاز و چندین موجک با فاز بیشینه به دست آورد و از آن‌ها برای ساخت داده‌های لرزه‌ای مصنوعی به منظور



شکل ۱. روندنمای ساخت داده‌های مصنوعی به منظور آموزش مدل واهمامیخت کور دوبعدی با استفاده از CNN.

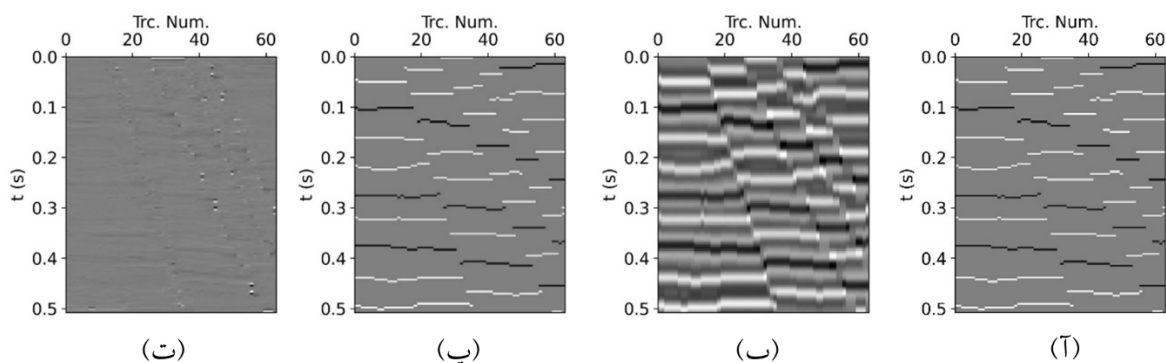
داده‌شده در شکل ۱ استفاده شده است. برای این کار فاز موجک مورد استفاده برای هر مقطع بین صفر تا ۳۰ درجه متغیر در نظر گرفته شده و فرکانس قله موجک‌های مورد استفاده بین ۱۷ تا ۲۵ هرتز به صورت کاملاً تصادفی تغییر می‌کند. به علاوه، نوبه‌های گوسی تصادفی با میانگین صفر و انحراف معیار متغیر بین ۰/۰۰۵ تا ۰/۲۱ به داده‌ها افزوده شده است. شکل ۴، چهار مقطع ضرایب بازتاب (بالا) و داده‌های مربوط به هر کدام (پایین) را نمایش می‌دهد. در این شکل ملاحظه می‌شود که علاوه بر فرکانس موجک‌های به کار رفته و انحراف معیار نوبه تصادفی در این داده‌ها، تعداد لایه‌ها، دامنه لایه‌ها، محل قرارگیری آن‌ها و تعداد گسله مورد استفاده در آن‌ها نیز با داده شکل ۲ متفاوت است. این نشان می‌دهد که استفاده از داده‌های ساده

شکل ۳-آ برای مقایسه موجک استفاده شده برای ساخت داده (خط آبی)، موجک اولیه تخمین زده شده با استفاده از روش توضیح داده شده در شکل ۱ (خط چین نارنجی) و موجک حاصل از واهمامیخت مقطع به دست آمده در شکل ۲-پ و داده‌های شکل ۲-ب (نقاط مشکی)، نمایش داده شده است. طیف دامنه و طیف فاز این موجک‌ها به ترتیب در شکل ۳-ب و شکل ۳-پ رسم شده‌اند. همان‌طور که ملاحظه می‌شود با وجود این که موجک تخمین زده شده اولیه کمی با موجک اصلی تفاوت دارد، موجک حاصل از واهمامیخت بسیار به موجک اصلی شبیه است.


به منظور آموزش شبکه معرفی شده در جدول ۱، ۵۰۰ داده آموزشی ساخته شده با استفاده از روش توضیح

حضور نوفه تصادفی را به خوبی نمایش می‌دهد. به منظور مقایسه بهتر پاسخ روش معرفی شده در این مقاله با روش‌های مرسوم، روش واهمامیخت رابطه (۲) (رجوع شود به مقاله غلامی و ساکی (۲۰۱۳)) استفاده شده است تا داده‌های بدون نوفه در شکل-ب و آلوده به نوفه در ۵-ب با موجک اصلی که این داده‌ها از روی آن ساخته شده‌اند (موجک آبی‌رنگ در ۱-آ) واهمامیخت شوند. از این رو، این واهمامیخت یک واهمامیخت کور نیست و صرفاً به منظور مقایسه نتایج آن با نتایج به دست آمده از روش معرفی شده در این مقاله استفاده قرار گرفته است. برای این کار $\lambda_1, \lambda_2 = 0.01$ در نظر گرفته شده است و باقی پارامترهای الگوریتم برای هر دو شکل یکسان در نظر گرفته شده است. نتایج این مقایسه در شکل ۶ نمایش داده شده است.

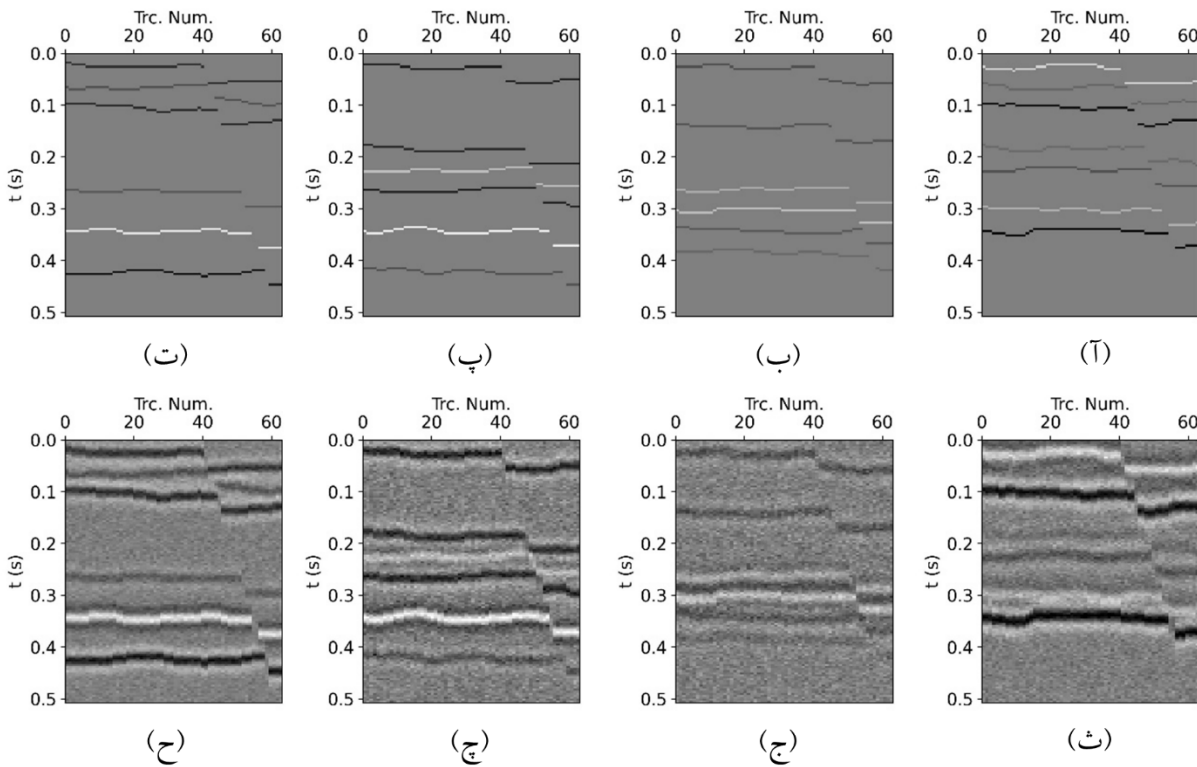
برای آموزش روش معرفی شده در جدول ۱ کافی است و نیازی نیست داده‌های پیچیده برای این کار استفاده شود. شکل ۵ عملکرد روش معرفی شده را برای واهمامیخت داده‌های آلوده به نوفه نمایش می‌دهد. ۵-آ یک مقطع ضرایب بازتاب دارای چهار گسله و ۵-ب داده‌های مربوط به آن را نمایش می‌دهند. فرکانس قله موجک ریکر برای این داده‌ها ۲۵ هرتز است. این داده‌ها توسط نوفه‌های گوسی تصادفی با میانگین صفر و انحراف معیار 0.21 آلوده شده‌اند. ۵-پ مقطع بازتابش حاصل از واهمامیخت کور معرفی شده در این مقاله را نمایش می‌دهد. با مقایسه این شکل و نتایج به دست آمده در شکل ۲-پ می‌توان دید که افزایش نوفه باعث کاهش توان روش در بازیابی ضرایب بازتاب شده است. ۵-ت از تفاضل ۵-آ با ۵-پ به دست آمده است. این شکل نیز کاهش توانایی روش در



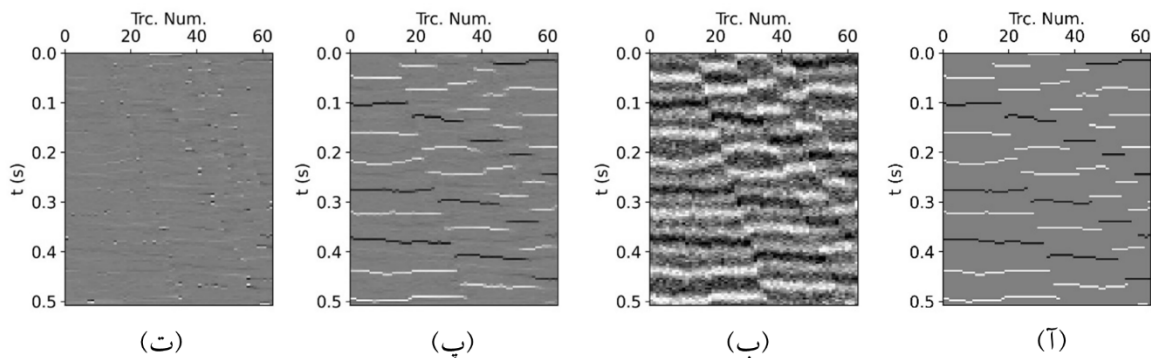
شکل ۲. آ) یک مقطع از ضرایب بازتاب. ب) مقطع (آ) که با یک موجک ریکر با فرکانس قله ۲۵ هرتز هم‌میخته شده است. پ) مقطع پس از اعمال واهمامیخت کور توسط روش معرفی شده در مقاله. ت) تفاضل مقاطع (ب) و (آ).



شکل ۳. آ) خط آبی: موجک ریکر با فرکانس قله ۲۵ هرتز که با استفاده از آن شکل ۲-ب ساخته شده است. خط چین نارنجی: موجک اولیه تخمین زده شده با روش معرفی شده در شکل ۱، نقاط مشکی: موجک حاصل از واهمامیخت شکل ۲-ب و شکل ۲-پ با روش این مقاله. ب) طیف دامنه موجک‌ها و پ) طیف فاز آن‌ها.



شکل ۴. آ، ب، پ، ت) چهار مقطع بازتابش از ۵۰۰ مقطعی که برای آموزش شبکه معرفی شده در جدول ۱ از آن‌ها استفاده شده است. ث) داده به‌دست آمده از مقطع بازتابش (آ) همایخته شده با موجکی با فرکانس ۱۹ هرتز و فاز ۱۸ درجه و آلوده به نوفه گوسی تصادفی با انحراف معیار ۰/۰۹۳. ج) داده به‌دست آمده از مقطع بازتابش (ب) همایخته شده با موجکی با فرکانس ۲۱ هرتز و فاز ۱۴ درجه و آلوده به نوفه گوسی تصادفی با انحراف معیار ۰/۱۰۹. چ) داده به‌دست آمده از مقطع بازتابش (پ) همایخته شده با موجکی با فرکانس ۲۳ هرتز و فاز ۲۷ درجه و آلوده به نوفه گوسی تصادفی با انحراف معیار ۰/۱۱۳. ح) داده به‌دست آمده از مقطع بازتابش (ت) همایخته شده با موجکی با فرکانس ۲۳ هرتز و فاز ۳ درجه و آلوده به نوفه گوسی تصادفی با انحراف معیار ۰/۰۷۱. همان‌طور که ملاحظه می‌شود میزان نوفه، تعداد گسله، تعداد لایه‌ها، دامنه‌ها و محل قرارگیری هر لایه در این داده‌های آموزشی با داده شکل ۲ متفاوت هستند.

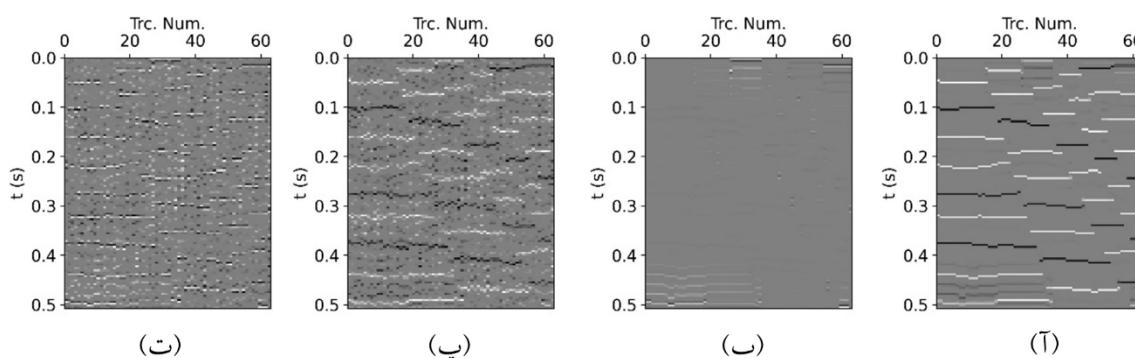


شکل ۵. آ) یک مقطع از ضرایب بازتاب. ب) مقطع (آ) که با یک موجک ریکر با فرکانس قله ۲۵ هرتز همایخته شده است و با نوفه‌های گوسی تصادفی با میانگین صفر و انحراف معیار ۰/۲۱ آلوده شده است. پ) مقطع (ب) پس از اعمال واهمایخت کور توسط روش معرفی شده در مقاله. ت) تفاضل مقطع (پ) و (آ).

شکل‌ها پیدا است، این روش به‌خصوص در لبه‌های داده عملکرد خوبی نداشته است. میانگین مربع خطای (MSE) به‌دست آمده برای این داده برابر با ۰/۰۰۳ است که بیشتر از

شکل ۶-آ و شکل ۶-ب به ترتیب نتیجه واهمایخت شکل ۲-ب از موجک اصلی و تفاضل آن با مقطع ضرایب اصلی در شکل ۲-آ را نمایش می‌دهند. همان‌طور که از روی این

که قطعاً می‌توان با تغییر پارامترهای λ_1 و λ_2 در رابطه (۲) به نتایج بهتری دست یافت. با این حال، این کار نیازمند آزمون و خطای بسیاری برای این داده خواهد بود. در صورتی که در روش واهمامیخت معرفی شده در این مقاله، فقط یک بار نیاز است تا فرآیندهای شبکه عصبی تعیین شوند و پس از آموزش شبکه نیازی نیست هر بار برای هر داده مجزا این کار تکرار گردد. و این یکی از محاسن روش واهمامیخت مبتنی بر شبکه عصبی واهمامیخت است.




شکل ۶. (آ) یک مقطع از ضرایب بازتاب. (ب) مقطع (آ) که با یک موجک ریکر با فرکانس قله ۲۵ هرتز همایخته شده است و با نوفه‌های گوسی تصادفی با میانگین صفر و انحراف معیار ۰/۲۱ آلوده شده است. (پ) مقطع (ب) پس از اعمال واهمامیخت کور توسط روش معرفی شده در مقاله. (ت) تفاضل مقطع (پ) و (آ).


نمودار شکل ۸ رسم شده است. در این شکل تاثیر سطح نوفه تصادفی با انحراف معیارهای متفاوت بر میزان میانگین مربع خطا (MSE) برای داده شکل ۲ رسم شده است تا پایداری روش را در برابر نوفه نمایش دهد. میانگین مربع خطا با استفاده از رابطه $MSE = \|R - R_{obtained}\|^2 / N$ که در آن R ضرایب بازتاب اصلی، $R_{obtained}$ ضرایب بازتاب به دست آمده و N تعداد ضرایب است، به دست آمده است. همان‌طور که ملاحظه می‌شود، با افزایش میزان نوفه، MSE افزایش داشته است و این به معنای آن است که کیفیت نتایج به دست آمده از این روش واهمامیخت با افزایش نوفه کاهش می‌یابد.

این مقدار برای شکل ۲-پ یعنی ۰/۰۰۲۷ است (شکل ۸). با این حال عملکرد روش برای باقی قسمت‌های مقطع به خصوص لبه گسله‌ها خوب بوده است. ۶-پ و ۶-ت نتیجه اعمال واهمامیخت رابطه (۲) را بر روی داده ۵-ب و تفاضل آن‌ها را نمایش می‌دهند. همان‌طور که ملاحظه می‌شود وجود نوفه باعث شده عملکرد روش بسیار کاهش یابد. میانگین مربع خطای (MSE) به دست آمده برای این داده برابر با ۰/۰۳۵ است که بسیار بیشتر از این مقدار برای شکل ۵-پ یعنی ۰/۰۰۴۵ است (شکل ۸). البته باید افزود

در شکل ۷-آ موجک استفاده شده برای ساخت داده (خط آبی)، موجک اولیه تخمین زده شده با استفاده از روش توضیح داده شده در شکل ۱ (خط چین نارنجی) و موجک حاصل از واهمامیخت مقطع به دست آمده در شکل ۵-پ و داده‌های شکل ۵-ب (نقاط مشکی)، نمایش داده شده است. طیف دامنه و طیف فاز این موجک‌ها به ترتیب در شکل ۷-ب و شکل ۷-پ رسم شده است. همان‌طور که ملاحظه می‌شود با افزایش نوفه موجک تخمین زده شده با واهمامیخت کمی با موجک اصلی متفاوت است. با این حال این تفاوت زیاد نیست. برای مقایسه بهتر میزان تاثیر نوفه گوسی تصادفی بر روی توانایی و پایداری روش واهمامیخت کور معرفی شده در مقاله،



شکل ۷. (آ) خط آبی: موجک ریکر با فرکانس قله ۲۵ هرتز که با استفاده از آن شکل ۵-ب ساخته شده است. خط چین نارنجی: موجک اولیه تخمین زده شده با روش معرفی شده در شکل ۱، نقاط مشکی: موجک حاصل از واهمایخت شکل ۵-ب و شکل ۵-پ با استفاده از روش این مقاله. (ب) طیف دامنه موجک‌ها و (پ) طیف فاز آنها.



شکل ۸. میزان تغییر MSE (محور عمودی) با افزودن نوفه‌های گوسی با میانگین صفر و انحراف معیارهای متفاوت (محور افقی) به منظور بررسی پایداری روش در برابر نوفه تصادفی.

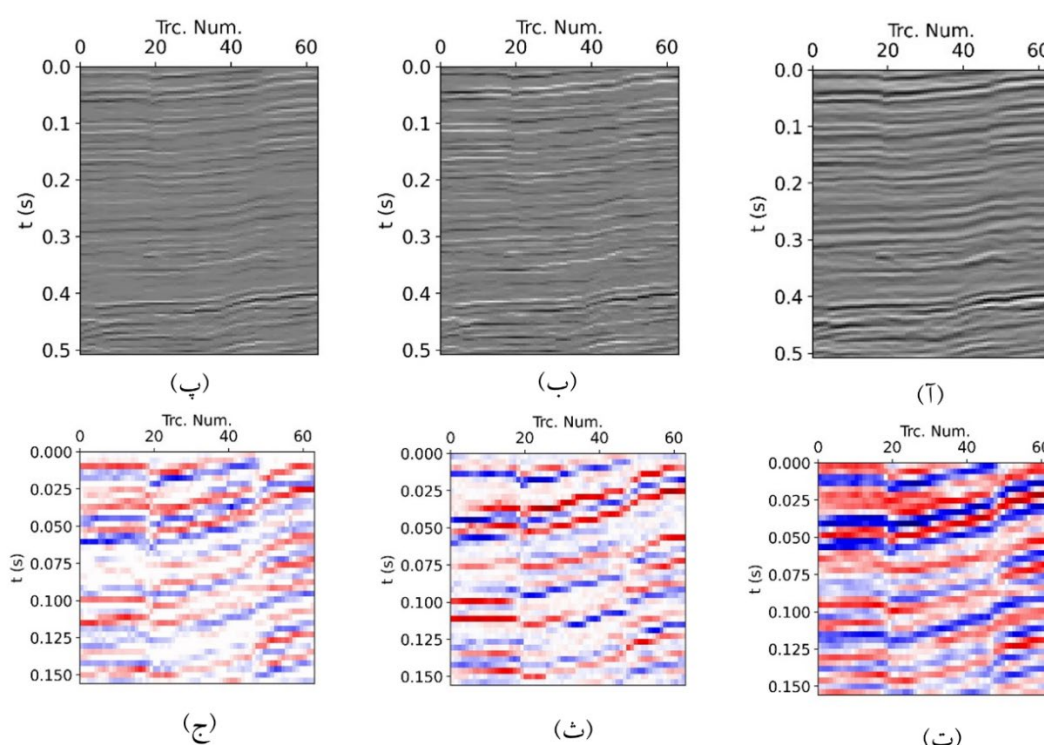
۳-۲ داده واقعی

در شکل ۱۰-آ موجک به دست آمده از واهمایخت شکل ۹-آ و شکل ۹-ب با خط چین سیاه رنگ نمایش داده شده است. برای مقایسه بهتر، موجک تخمین زده شده اولیه با خط آبی رنگ در این شکل نمایش داده شده است. موجک حاصل از واهمایخت در این شکل با استفاده از رابطه (۳) به دست آمده است. ملاحظه می شود که موجک به دست آمده به موجک تخمین زده شده اولیه شباهت نزدیکی دارد اما با آن یکسان نیست. برای مقایسه بهتر طیف دامنه و فاز این موجک‌ها به ترتیب در شکل ۱۰-ب و شکل ۱۰-پ نمایش داده شده اند. همان طور که از روی این شکل‌ها پیدا است، طیف دامنه دو موجک به یکدیگر


شکل ۹-آ قسمتی از یک داده واقعی را نمایش می دهد که در میانه آن دو گسله قرار دارند. شکل ۹-ب مقطع ضرایب بازتاب به دست آمده از روش واهمایخت کور چندکاناله مبتنی بر CNN را نشان می دهد. از آنجایی که مقطع ضرایب بازتاب برای مقایسه روش معرفی شده در این مقاله برای داده واقعی در دسترس نبود، با استفاده از رابطه (۲)، این مقطع به دست آمده و برای مقایسه بهتر در شکل ۹-پ نمایش داده شده است. برای انجام واهمایخت در این شکل از موجک تخمین زده شده اولیه استفاده شده است. به منظور مقایسه بهتر، مقطع بزرگ نمایی شده مربوط به هر شکل در زیر آنها نمایش داده شده است (شکل ۹-ت، شکل ۹-ث، شکل ۹-ج).

مقاله (شکل ۹-ب) بیشتر از مقطع بازتابی است که از واهمامیخت موجک اولیه از داده اصلی (شکل ۹-پ) به دست آمده است؛ بنابراین می توان نتیجه گرفت که مقطع واهمامیخت شکل ۹-ب تُنک تر از شکل ۹-پ است و این نشان می دهد روش واهمامیخت کور چندکاناله عملکردی بهتر از روش مربوط به رابطه (۲) داشته است. البته اگر اطلاعات اولیه بهتری از موجک چشمه داشتیم، شاید نتیجه برای روش واهمامیخت رابطه (۲) بهتر می شد.

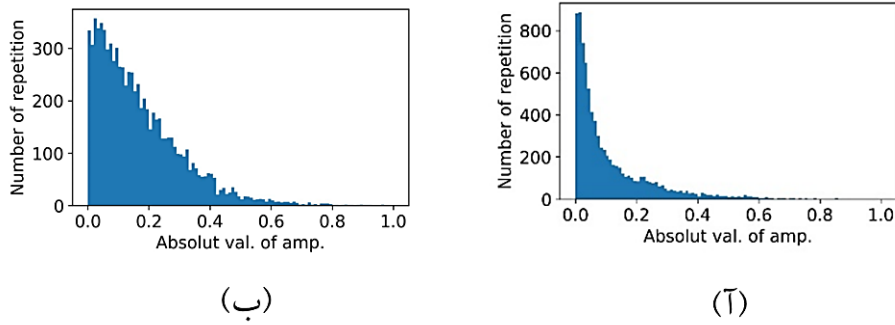
نزدیک هستند. با این حال، طیف فاز دو موجک به خصوص در فرکانس های بالاتر متفاوت هستند. برای مقایسه بهتر شکل ۹-ب و شکل ۹-پ نمودار هیستوگرام قدرمطلق دامنه های آن ها در شکل ۱۱ نشان داده شده است. شکل ۱۱-آ مربوط به شکل ۹-ب و شکل ۱۱-ب مربوط به شکل ۹-پ است. از مقایسه این دو نمودار می توان فهمید که تعداد تکرار دامنه های صفر و یا نزدیک به صفر در مقطع به دست آمده از روش واهمامیخت این



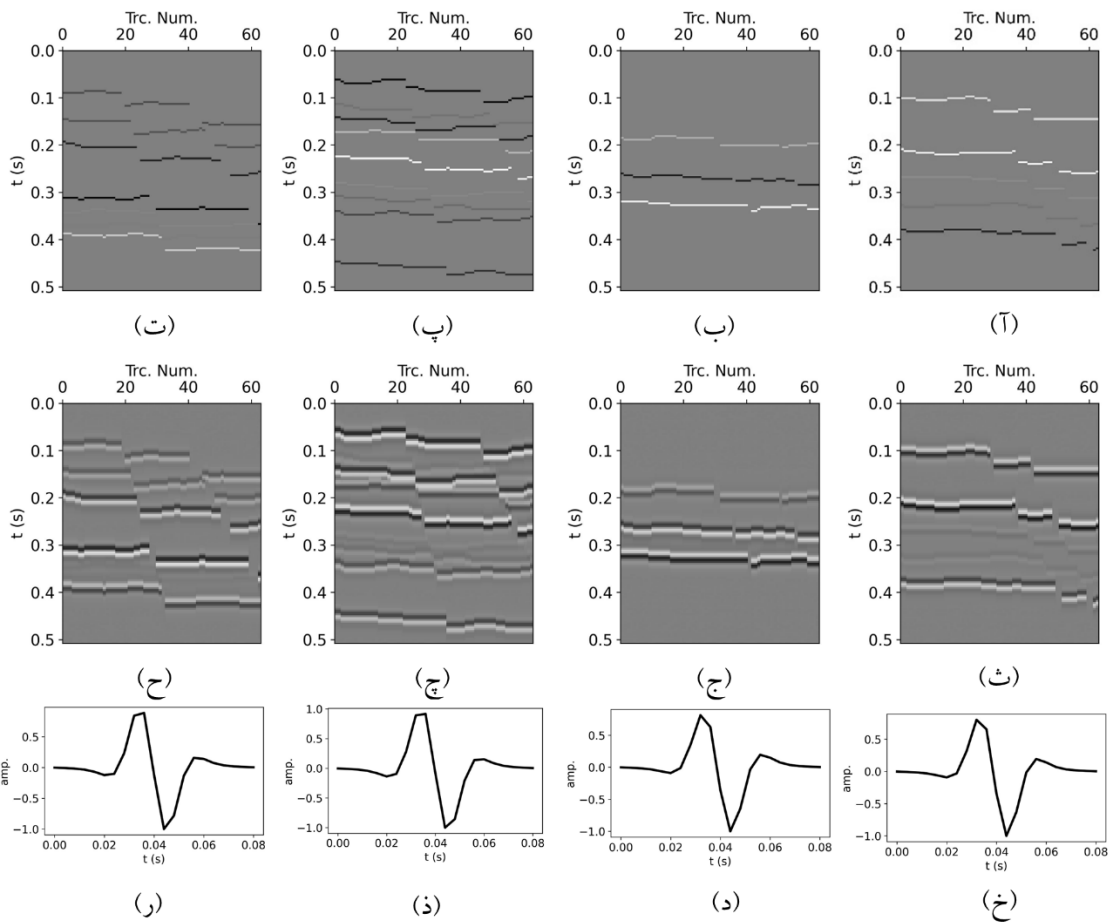
شکل ۹. (آ) مقطع پس از برانبارش از یک داده واقعی. (ب) مقطع (آ) پس از واهمامیخت توسط روش واهمامیخت کور چندکاناله بر اساس CNN. (پ) مقطع (آ) پس از واهمامیخت توسط روش واهمامیخت تُنک کور چندکاناله رابطه (۲). (ت) مقطع (آ) پس از بزرگنمایی. (ث) مقطع (ب) پس از بزرگنمایی. (ج) مقطع (پ) پس از بزرگنمایی.



شکل ۱۰. (آ) خط آبی: موجک تخمین زده شده اولیه و خط چین سیاه رنگ موجک به دست آمده پس از انجام واهمامیخت کور مبتنی بر CNN. (ب) طیف دامنه مربوط به هر موجک. (ج) طیف فاز مربوط به هر موجک.



شکل ۱۱. آ) نمودار هیستوگرام تعداد تکرار قدرمطلق دامنه‌های موجود در مقطع واهمامیخته شده توسط روش واهمامیخت کور مبتنی بر CNN در شکل ۹-ب. ب) نمودار هیستوگرام تعداد تکرار قدرمطلق دامنه‌های موجود در مقطع واهمامیخته شده با روش واهمامیخت تُنک رابطه (۲) در شکل ۹-پ.



شکل ۱۲. آ، ب، پ، ت) چهار مقطع بازتاب از ۲۰۰۰ مقطعی که برای آموزش شبکه معرفی شده در جدول ۱ از آن‌ها استفاده شده است. ث) داده به‌دست آمده از مقطع بازتابش (آ) همامیخته شده با موجکی با فرکانس ۳۵ هرتز و تغییر فاز ۱۰۷ درجه نمایش داده شده در قسمت (خ). ج) داده به‌دست آمده از مقطع بازتابش (ب) همامیخته شده با موجکی با فرکانس ۳۴ هرتز و فاز ۱۰۸ درجه نمایش داده شده در قسمت (د). ج) داده به‌دست آمده از مقطع بازتابش (پ) همامیخته شده با موجکی با فرکانس ۳۳ هرتز و فاز ۹۳ درجه نمایش داده شده در قسمت (ذ). ح) داده به‌دست آمده از مقطع بازتابش (ت) همامیخته شده با موجکی با فرکانس ۳۵ هرتز و فاز ۹۵ درجه نمایش داده شده در قسمت (ر). همان‌طور که ملاحظه می‌شود شیب گسله‌ها، تعداد لایه‌ها، دامنه‌ها و محل قرارگیری هر لایه در این داده‌های آموزشی با داده شکل ۹ متفاوت هستند.

مدل، اعمال واهمامیخت برای داده‌های مقاله در کسری از یک ثانیه انجام شده است. دوم، تخمین موجک و در نظر گرفتن تمامی موجک‌های محتمل در ساخت داده‌های آموزشی اهمیت بالایی دارد. بر همگان روشن است که اگر داده‌های آموزشی با موجک‌های اشتباه آموزش داده شوند ضرایب بازتاب نیز اشتباه به دست خواهند آمد. از این رو نیاز است تا آموزش این روش با داده‌های کافی و موجک‌هایی در یک بازه صحیح انجام پذیرد. سوم، در این مقاله فرض شده که موجک چشمه درون زمین تغییری نمی‌کند. این فرض در واقعیت صحیح نیست و روش معرفی شده در این مقاله فقط برای قسمت کوچکی از داده‌های لرزه‌نگاری که در آن موجک بدون تغییر است، قابل اعمال خواهد بود. در کارهای بعدی فرض ناپایا بودن موجک نیز برای این کار در نظر گرفته خواهد شد؛ و در نهایت نیاز است تا توضیحاتی در مورد نحوه انتخاب فرآپارامترها (Hyperparameters) افزوده شود. این پارامترها شامل نوع و تعداد لایه‌ها، طول هسته و تعداد فیلتر در هر لایه، تعداد تکرار و نرخ یادگیری (Learning Rate) می‌شوند. انتخاب این پارامترها بسیار زمان‌بر بوده و نیاز به آزمون و خطای بسیاری است. هیچ راه‌حل قطعی برای تعیین این پارامترها وجود ندارد. استفاده از نشانگرهایی مانند تابع زیان (Loss Functions) و نیز معیارهای دقت (Accuracy metrics) مناسب می‌تواند در تصمیم‌گیری بهتر در مورد انتخاب این فرآپارامترها کمک کند. در این مقاله از MSE به عنوان تابع زیان و از دقت باینری (دودویی) (Binary Accuracy) به عنوان معیار دقت استفاده شده است.

۵ نتیجه‌گیری

در این مقاله یک روش واهمامیخت کور دوبعدی بر اساس شبکه عصبی همایختی معرفی گردید. به علاوه، یک الگوریتم کارآمد برای ساخت داده‌های مصنوعی به منظور آموزش شبکه عصبی به کار گرفته شده است. نشان دادیم که

برای آموزش شبکه معرفی شده در مقاله، فاز و فرکانس موجک آبی‌رنگ در شکل ۹-ت با استفاده از جدول ۱ تغییر داده شده است و ۲۰۰۰ داده آموزشی با استفاده از مقاطع ضرایب بازتاب مختلف تولید شده است. برای ساخت داده‌های آموزشی بازه فرکانسی بین ۳۰ تا ۴۰ هرتز و بازه فاز موجک بین ۶۰ تا ۱۲۰ درجه متغیر است. شکل ۱۲ چهار مقطع متفاوت ضرایب بازتاب (سطر بالا) را به همراه داده‌های مربوط به هر کدام (سطر وسط) و موجک مورد استفاده برای آن داده (سطر پایین) نمایش می‌دهد. همان‌طور که ملاحظه می‌شود علاوه بر فاز و فرکانس موجک چشمه، شیب گسله‌ها، محل قرارگیری آن‌ها، تعداد لایه‌ها، دامنه‌ها و محل قرارگیری هر لایه در این داده‌های آموزشی با داده واقعی متفاوت هستند. این داده‌ها به خوبی نشان می‌دهند که با تعداد کافی داده‌های با ساختار ساده می‌توان شبکه معرفی شده در این مقاله را به خوبی آموزش داد و پاسخ خوبی گرفت.

۴ بحث

برای روش واهمامیخت معرفی شده در این مقاله ذکر چند نکته الزامی است. اول اینکه برای آموزش شبکه عصبی معرفی شده مانند دیگر مسائل شبکه‌های عصبی، باید به اندازه کافی داده با در نظر گرفتن متغیرهای مسئله بکار برد. این کار می‌تواند زمان‌بر باشد و به سخت‌افزار بسیار قدرتمندی برای انجام آن احتیاج است. آموزش داده‌های این مقاله با استفاده از یک لپ‌تاپ با پردازنده Core i7 و کارت گرافیک NVIDIA GeForce RTX 3050 با استفاده از کتابخانه‌های Tensor Flow و Keras انجام شده است. از این رو، امکان استفاده از داده‌های بزرگ مقیاس با تغییر پارامترهای زیاد با سخت‌افزار ذکر شده در این مقاله میسر نبود. باید اضافه کنیم که آموزش مدل به صورت تقریبی برای داده‌های مصنوعی ۲۴ ساعت و برای داده‌های واقعی ۴۶ ساعت به طول انجامیده است؛ اما پس از آموزش

- of outliers. *IEEE Transactions on Geoscience and Remote Sensing*, 50(10), 4105–4116.
- Gholami, A., & Sacchi, M.D. (2013). Fast 3D blind seismic deconvolution via constrained total variation and GCV. *SIAM Journal on Imaging Sciences*, 6(4), 2350–2369.
- Goldstein, T., & Osher, S. (2009). The Split Bregman Method for L1-Regularized Problems. *SIAM Journal on Imaging Sciences*, 2, 323–343.
- Gurbuz, A.C., McClellan, J.H., Scott, W.R., & Larson, G.D. (2006). Seismic tunnel imaging and Detection. *2006 International Conference on Image Processing*, 3229–3232.
- Haghshenas Lari, H., & Gholami A. (2019). Nonstationary blind deconvolution of seismic records. *Geophysics*, 84, V1-V9.
- Hargreaves, N. D., & Calvert, A. J. (1991). Inverse q filtering by Fourier transform. *Geophysics*, 56, 519–527.
- Heimer, A., & Cohen, I. (2008). Multichannel blind seismic deconvolution using dynamic programming. *Signal Processing*, 88(4), 1839–1851.
- Heimer, A., & Cohen, I. (2009). Multichannel seismic deconvolution using Markov-Bernoulli Random Field modeling. *IEEE Transactions on Geoscience and Remote Sensing*, 47(7), 2047–2058.
- Heimer, A., Cohen, I., & Vassiliou, A. (2007). Dynamic programming for multichannel blind seismic deconvolution. *SEG Technical Program Expanded Abstracts*, 1845–1849.
- Hubel, D.H., & Wiesel, T.N. (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of Physiology*, 195, 215–243.
- Idier, J., & Goussard, Y. (1993). Multichannel seismic deconvolution. *IEEE Transactions on Geoscience and Remote Sensing*, 31(5), 961–979.
- Kaarsen, K., & Taxt, T. (1998). Multichannel blind deconvolution of seismic signals. *Geophysics*, 63(6), 2093–2107.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Mendel, J., Kormylo, J., Aminzadeh, F., Lee, J., & Habibi-Ashrafi, F. (1981). A novel approach to seismic signal processing and modeling. *Geophysics*, 46, 1398–1414.
- Li, C., & Liu, G. (2022). Warped mapping-based blind deconvolution for resolution improvement. *Geophysical Prospecting*, 70(4), 677–701.
- برای اعمال این روش واهمایخت، تنها کافی است که یک تخمین اولیه از موجک لرزه‌ای با استفاده از طیف فرکانسی داده‌های لرزه‌ای انجام شود. از آنجایی که این تخمین اولیه با موجک چشمه فاصله دارد، با در نظر گرفتن حالت‌های مختلف فرکانس و فاز و با تغییر این مقادیر، موجک‌های مختلفی تولید شد. از همایخت این موجک‌ها با مقاطع دوبعدی ضرایب بازتاب، داده‌هایی برای آموزش شبکه تولید شد و نشان داده شد که می‌توان از داده‌های آموزشی با ساختار ساده به‌منظور واهمایخت داده‌های پیچیده استفاده کرد. در نهایت توانایی روش معرفی شده با استفاده از داده‌های مصنوعی و واقعی مورد بررسی قرار گرفت و در این داده‌ها نشان داده شد که این روش در حضور نوفه و در لبه گسله‌ها عملکرد خوبی از خود به نمایش می‌گذارد و اثرات ناخواسته کمی را بر روی مقطع واهمایخت شده برجای خواهد گذاشت.

منابع

- Araya-Polo, M., Dahlke, T., Frogner, C., Zhang, C., Poggio, T., & Hohl, D. (2017). Automated fault detection without seismic processing. *The Leading Edge*, 36(3), 208–214.
- Biswas, R., Vassiliou, A., Stromberg, R., & Sen, M.K. (2018). Stacking velocity estimation using recurrent neural network. *SEG Technical Program Expanded Abstracts 2018*, 2241–2245.
- Chai, X., Tang, G., Lin, K., Yan, Z., Gu, H., Peng, R., Sun, X., & Cao, W. (2021). Deep learning for multitrace sparse-spike deconvolution. *Geophysics*, 86(3), V207-V218.
- Chen, H., Sacchi, M. D., Haghshenas Lari, H., Gao, J., & Jiang, X. (2023). Nonstationary seismic reflectivity inversion based on prior-engaged semisupervised deep learning method. *Geophysics*, 88(1), WA115-WA128.
- Cui, T., & Margrave, G. F. (2014). Seismic wavelet estimation. *CREWES Research Report*.
- Fish, B.C., & Kusuma, T. (2005). A neural network approach to automate velocity picking. *SEG Technical Program Expanded Abstracts 1994*, 185–188.
- Gholami, A., & Sacchi, M.D. (2012). A fast and automatic sparse deconvolution in the presence

- Li, S., Liu, B., Ren, Y., Chen, Y., Yang, S., Wang, Y., & Jiang, P. (2011). Deep Learning Inversion of Seismic Data. *CoRR abs/1901.07733*.
<http://arxiv.org/abs/1901.07733>
- Nguyen, T., & Castagna, J. (2010). High resolution seismic reflectivity inversion. *Journal of Seismic Exploration*, 19(4), 303–320.
- Margrave, G., Lamoureux, M.P., & Henley, D. (2011). Gabor deconvolution: estimating reflectivity by nonstationary deconvolution of seismic data. *Geophysics*, 76(3), W15–W30.
- Margrave, G. F. (2013). Methods of seismic data processing – *Geophysics 517/557 Course Notes*. The Department of Geoscience, University of Calgary.
- Pereg, D., Cohen, I., & Vassiliou, A. A. (2020). Sparse seismic deconvolution via recurrent neural network. *Journal of Applied Geophysics*, 175, 103979.
<https://doi.org/10.1016/j.jappgeo.2020.103979>
- Priezzhev, I., & Stanislav, E. (2018). Application of machine learning algorithms using seismic data and well logs to predict reservoir properties. *80th EAGE Conference and Exhibition 2018*.
- Ram, I., Cohen, I., & Raz, S. (2010). Multichannel deconvolution of seismic signals using statistical MCMC methods. *IEEE Transactions on Signal Processing*, 58(5), 2757–2769.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323, 533–536.
- Riel, P.V., & Berkhout, A.J. (1985). Resolution in seismic trace inversion by parameter estimation. *Geophysics*, 50, 1440–1455.
- Robinson, E. A. (1985). Seismic time-invariant convolutional model. *Geophysics*, 50, 2742–2751.
- Russell, B. (2019). Machine learning and geophysical inversion—A numerical study. *The Leading Edge*, 38(7), 512–519.
- Sacchi, M. D., Velis D. R., & Comínguez A. H. (1994). Minimum entropy deconvolution with frequency-domain constraints. *Geophysics*, 59, 938–945.
- Sherif, R., & Geldart, L. (1983). *Exploration Seismology* (2nd ed.). UK: Cambridge University Press.
- Sun, Y., Cao, S., Chen, S., & Su, Y. (2024). Blind spectral inversion of seismic data. *Geophysical Prospecting*.
- Taylor, H.L., Banks, S.C., & McCoy, J.F. (1979). Deconvolution with the ‘1 norm. *Geophysics*, 44, 39–52.
- van der Baan, M. (2008). Time-varying wavelet estimation and deconvolution by kurtosis maximization. *Geophysics*, 73, V11–V18.
- Wiggins, R. (1978). Minimum entropy deconvolution. *Geoexploration*, 16, 21–35.
- Yamashita, R., Nishio, M., Do, R.K.G., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9, 611–629.
<https://doi.org/10.1007/s13244-018-0639-9>
- Yilmaz, Ö. (2001). *Seismic Data Analysis*. Tulsa: Society of Exploration Geophysicists.
- Yin, X., Xu, W., Yang, Z., & Wu, B. (2024). Seismic Blind Deconvolution Based on Self-Supervised Machine Learning. *Applied Sciences*.
- Zhang, R., & Castagna, J. (2011). Seismic sparse-layer reflectivity inversion using basis pursuit decomposition. *Geophysics*, 76(6), 147–158.

Seismic 2D blind deconvolution via convolutional neural network

Fatemeh Khaloui^{1*}, Hojjat Haghshenas Lari² and Parvin Razzaghi³

¹ M.Sc. Student of Seismology, Institute for Advanced Studies in Basic Sciences (IASBS), Zanjan, Iran

² Assistant Professor, Institute for Advanced Studies in Basic Sciences (IASBS), Zanjan, Iran

³ Assistant Professor, Department of Computer Science and Information Technology, Institute for Advanced Studies in Basic Sciences (IASBS), Zanjan, Iran

(Received: 13 August 2024, Accepted: 22 October 2024)

Summary

The convolutional model of the earth proposes that seismic data results from the combination of reflectivity and a source wavelet along with some random noise. As a result, enhancing seismic data resolution involves mitigating the impact of the seismic wavelet, an essential task in seismic data processing. Deconvolution of seismic data is a method utilized for this purpose, ultimately improving the interpretation of seismic sections by enhancing data resolution and bandwidth. This process can be applied to both single and multichannel seismic data. In single-channel deconvolution, it is assumed that multidimensional seismic data is a weighted combination of one-dimensional traces, and deconvolution is applied to each trace independently. On the other hand, multichannel deconvolution takes into account the time and spatial correlation between seismic channels, making it more advantageous compared to single-channel deconvolution methods. Deconvolution can be performed in nonblind or blind manners. In the case of nonblind deconvolution, information about the source wavelet is available. This type of deconvolution relies on recorded source wavelets or estimated wavelets obtained from sources such as well logs. Conversely, due to the often unavailability of precise information about seismic wavelets, blind deconvolution techniques are utilized to estimate the wavelets before or during the deconvolution process. Traditional seismic deconvolution methods commonly utilize optimization techniques to solve this issue, often heavily dependent on the accuracy of the optimization parameters and requiring human intervention for decision-making. To address these challenges, deep learning methods have been proposed. These methods automatically determine the parameters and reduce the need for human-computer interaction. In this paper, a deep learning-based deconvolution method is proposed for applying multichannel semi-blind deconvolution to two-dimensional (2D) post-stack seismic data sets. This approach employs 2D convolutional neural networks (CNNs) to generate high-resolution reflectivity images from seismic sections. CNN is a network where some of the hidden layers are convolutional, and the convolution layer combines the inputs as feature maps with convolution filters to form transformed feature maps. The trainable parameters are adjusted through backpropagation of errors using advanced optimization algorithms. We used the advantages of this network and proposed a CNN-based multichannel semi-blind deconvolution method. The method is referred to as semi-blind since it requires a wavelet estimation as the initial step to produce training data, but does not demand precise wavelet information, as a rough estimation suffices to achieve good results. The effectiveness of this proposed method has been confirmed using both synthetic and real seismic data examples incorporating complex structures and varying signal-to-noise ratios. The experiments have demonstrated that the method can effectively handle diverse scenarios, highlighting a significant improvement in data deconvolution results through training with simple synthetic data.

Keywords: Blind deconvolution, CNN, 2D operator

*Corresponding author:

fatemeh.khalouei@iasbs.ac.ir