

معرفی روشی کم هزینه و خودکار در تولید انبوه داده مخزنی برای آموزش الگوریتم یادگیری عمیق با استفاده از شبیه سازی متوالی مستقیم

حمید ثابتی^{۱*}؛ وحید هنربخش^۲

۱- استادیار؛ گروه مهندسی معدن، دانشگاه صنعتی بیرجند

۲- دانشجوی دکتری لرزه شناسی؛ دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران

دریافت مقاله: ۱۴۰۱/۰۴/۲۴؛ پذیرش مقاله: ۱۴۰۱/۱۲/۰۷

* نویسنده مسئول مکاتبات: sabeti@birjandut.ac.ir

چکیده

موفقیت های اخیر در روش های وارون سازی شکل موج کامل مبتنی بر داده، منجر به رشد سریع تقاضا برای مجموعه داده های قابل دسترس به منظور استفاده در این مسائل شده است. کمبود مجموعه داده آموزشی به تعداد لازم و نزدیک به مدل های واقعی زیرسطحی برای آموزش شبکه های عصبی عمیق، یکی از کاستی های این روش ها در کاربردهایی ژئوفیزیکی است. برای حل این مشکل، در این مقاله، چارچوبی با استفاده از یک روش شبیه سازی زمین آماری برای تولید پایگاه داده آموزشی، استفاده شده است. ایده اصلی در این مقاله، استفاده از داده های چاه استخراج شده از مدل های مختلف و به تعداد دلخواه و قرارگیری در الگوریتم شبیه سازی متوالی مستقیم و شبیه سازی متوالی مستقیم توأمان است. در این روش، برای بدست آوردن مدل های سرعت یا مخزنی قابل استفاده برای شبکه عمیق، از آماره های اولیه (میانگین و واریانس) که از داده های چاه بدست می آید، در مراحل شبیه سازی استفاده می شود. همچنین با استفاده از الگوریتم شبیه سازی متوالی مستقیم توأمان و به کارگیری تصویر ثانویه (تصویر مدل اصلی با درصد های متفاوت همبستگی) تولید مدل های با پیوستگی بیشتر ارائه شده است. استفاده از درصد های مختلف همبستگی تصویر ثانویه منجر به تولید مدل های متنوع زمین شناسی شده است. در این مقاله، مثال های گوناگونی از مدل های سرعت معروف، انتخاب و چارچوب ارائه شده بر روی آنها اعمال گردیده است. اگرچه محدودیتی در استفاده از ضرایب همبستگی متنوع وجود ندارد، به عنوان نمونه، ضرایب همبستگی ۳۰، ۵۰ و ۷۰ درصد برای استفاده از تصویر ثانویه در تولید داده آموزشی استفاده شده است. نتایج، نشان دهنده تولید پایگاه آموزشی با مدل های مرتبط با ساختارهای زمین شناسی متنوع است.

واژگان کلیدی

شبیه سازی متوالی مستقیم
یادگیری عمیق
مدل سرعت
زمین آمار
تصویر ثانویه

۱- مقدمه

توصیف دقیق و کارآمد زمین‌شناسی زیرسطحی یکی از موضوعات در ژئوفیزیک به منظور کاربردهای مختلف می‌باشد. تاکنون روش‌های مختلف و مرسوم برای این منظور استفاده شده است، مانند تصویرسازی لرزه‌ای و روش‌های زمین‌آماري.

یکی از موضوعات مهم که در چند سال اخیر در زمینه بینایی ماشین و پردازش تصویر مورد توجه و استفاده قرار گرفته روش‌های یادگیری ماشین و به طور ویژه روش‌های یادگیری عمیق می‌باشد (Lecun et al., 2015).

روش یادگیری عمیق به صورت ویژه در سالهای اخیر به طور گسترده در حوزه‌های مختلف ژئوفیزیک مانند پردازش داده‌های لرزه‌ای شامل درون‌یابی، تصویرسازی، حذف نوفه و بدست آوردن پارامترهای مخزن مورد استفاده قرار گرفته است (Siwei et al., 2019; Kaur et al., 2021; Hermann et al., 2019; Siahkoohi et al., 2021). یکی از روش‌های دارای قدرت تفکیک بالا برای بدست آوردن مدل سرعتی روش وارن‌سازی شکل موج کامل می‌باشد (Virieux and Operto, 2009; Aghamiry et al., 2019). این روش به صورت تکراری از یک مدل اولیه شروع می‌شود و خروجی آن مدل سرعتی با رزولیشن بالاست. برای حل برخی از مشکلات این روش مانند وابستگی به مدل سرعت اولیه، بد وضع بودن و پرش دوره، روش‌های ارائه شده است. یکی از روش‌های که چند سال اخیر برای برطرف کردن مشکلات روش وارن‌سازی شکل موج کامل مورد توجه قرار گرفته روش‌های یادگیری عمیق است (Arya-Polo et al., 2018). روش‌های یادگیری عمیق در زمینه وارن‌سازی شکل موج کامل، خود به سه دسته تقسیم می‌شود: ۱- روش‌های کدگذار-کدگشا (Yang and Ma, 2019; WU and Lin, 2019)، ۲- روش‌های یادگیری Low-Wavenumber (Fang et al., 2020) و ۳- روش شبکه عصبی حاوی اطلاعات فیزیکی مسئله (Ren et al., PINN 2020).

در روش کدگذار-کدگشا، عملگر وارن به طور مستقیم در فرایند یادگیری قرار می‌گیرد. در حالی که در روش دوم یادگیری عدد موج پایین از داده توسط روش‌های تکراری متداول در وارن‌سازی جبهه موج استفاده می‌شود. در روش آخر که تقریباً از دو روش بالا جدیدتر است اطلاعات در مورد فیزیک مسئله (معادله موج) استفاده می‌شود.

در اکثر روش‌های یادگیری عمیق که به صورت با نظارت انجام می‌شود، برای آموزش بهتر شبکه و بدست آوردن خروجی با قدرت تفکیک مناسب تعداد زیاد داده آموزشی مورد نیاز است.

همان طور که در بالا بیان شد، یکی از روش‌های مورد استفاده در به دست آوردن مدل سرعتی، استفاده از ساختار کدگذار-کدگشا می‌باشد که در بسیاری از مقالات از این روش استفاده شده است (Li et al., 2020; Mao et al., 2019). یکی از مشکلات این نوع از شبکه‌ها که به صورت با نظارت آموزش داده می‌شوند، تولید تعداد زیاد و نزدیک به واقعیت مدل

سرعتی برای آموزش شبکه است. تاکنون روش‌هایی برای تولید داده زیاد و واقعی ارائه شده‌اند که شامل ۱- روش‌های تولید داده به صورت تصادفی، ۲- روش‌های زمین‌آماري و ۳- روش‌های یادگیری عمیق هستند. سوال اصلی این است که چگونه مدل‌های سرعتی زیر سطحی تولید شود که در بردارنده ویژگی‌های واقعی زمین شناسی برای آموزش شبکه باشد.

در روش اول، الگوریتم‌های تولید مدل تصادفی معمولاً برای یک کار خاص طراحی می‌شوند و ممکن است انواع عمومی مدل‌های زیرسطحی تصادفی مانند مدل‌های لایه ای یا مدل‌های دارای گنبد نمکی را تولید کنند. به این معنی که مدل‌های زیرسطحی به‌دست‌آمده از دیدگاه متخصصان، واقعی به نظر نمی‌رسند (مانند لایه‌بندی، گسل‌ها، روندها و غیره) (Ovcharenko et al., 2019).

در روش دوم، از روش‌های زمین‌آماري برای تولید مدل واقعی استفاده می‌شود. این روش‌ها خود به دو روش چند نقطه و دو نقطه تقسیم می‌شود. برای مثال، از روش زمین‌آماري چند نقطه بر پایه تصویر آموزشی برای شبیه‌سازی استفاده شده است (Rezaee et al., 2015). همچنین با استفاده از ترکیب روش‌های زمین‌آمار چند نقطه و شبکه‌های GAN برای تولید مدل واقعی استفاده گردیده است (Laloy et al., 2019). در این مقاله، از روش شبیه‌سازی متوالی مستقیم و شبیه‌سازی متوالی مستقیم توأمان و با استفاده از مفهوم تصویر ثانویه، مدل‌های سرعت نزدیک به واقعی تولید شده است.

در روش سوم، از روش‌های یادگیری عمیق برای تولید در مدل واقعی استفاده شده است (Laloy et al., 2019; Shihang et al., 2021).

روش انتقال ساختار (Johnson et al., 2016)، به دسته‌ای از الگوریتم‌ها اطلاق می‌شود که شکل‌های دیجیتال یا ویدئوها را به منظور اتخاذ ظاهر یا سبک بصری تصویر دیگر دستکاری می‌کنند. واقع گرایی ادراکی شکل‌های تولید شده مصنوعی، یکی از نتایج مطلوب در حوزه بینایی کامپیوتر است. از این الگوریتم‌ها با استفاده از شبکه‌های عصبی عمیق به منظور تبدیل تصویر مشخص برای تولید داده نسبتاً واقعی استفاده شده است (Ovcharenko et al., 2019). در این روش با درنظر گرفتن مدل‌های سرعت به عنوان سبک تصویر، مشخصات زمین شناسی همان ساختار با محتوای تصویری دیگر ادغام می‌شود. بنابراین این مسئله شبیه تولید عکس واقعی است. یکی از مشکلات این روش هزینه محاسبات بالای آن است که برای کاهش هزینه محاسباتی پژوهش‌هایی انجام شده است (Feng et al., 2021).

در این مقاله، از یک روش ساده و سریع به منظور تولید پایگاه داده آموزشی استفاده شده است. این روش براساس شبیه‌سازی زمین‌آماري در مدل‌سازی مخازن استفاده می‌شود. در اینجا، از روش شبیه‌سازی متوالی مستقیم و با استفاده از مفهوم تصویر ثانویه، مدل‌های سرعت متنوع تولید شده است.

۲- روش شناسی

روش ها و الگوریتم های مختلفی برای شبیه سازی زمین آماری وجود دارد که همه آنها حول الگوریتم شبیه سازی متوالی گوسی (Deutch and Journal, 1992) گسترش یافته اند. فرض گوسی بودن توزیع احتمالی اولیه در این الگوریتم ها با انجام یک تبدیل گوسی روی داده اولیه انجام می شود. در حالی که توزیع داده ها می تواند دارای چولگی مثبت و منفی و یا چند مدی باشد و از این رو بازتولید تابع توزیع احتمالی اولیه یا هیستوگرام، بعد از تبدیل گوسی ممکن است دشوار باشد (Tran et al., 2001). لازم به یادآوری است که برای رسیدن به مدل های مخزنی قابل اطمینان، ضروری است که آماره های اولیه (میانگین و واریانس) که از داده های چاهنگاری به دست آمده اند در مدل های شبیه سازی شده بازتولید گردند. استفاده از روش شبیه سازی متوالی مستقیم توسعه داده شده توسط سوارس (۲۰۰۱) به دلیل امتیاز ویژه آن در عدم فرض گوسی بودن برای تابع توزیع احتمالی اولیه به دست آمده از داده های چاهنگاری است. مراحل محاسباتی الگوریتم شبیه سازی متوالی مستقیم به شرح زیر است (Soares, 2001):

- ۱- تعیین مسیر تصادفی در کل شبکه شبیه سازی
- ۲- انتخاب سلول x_u که قرار است شبیه سازی شود
- ۳- تخمین میانگین محلی $z(x_u)^*$ و واریانس $\sigma_{sk}^2(x_u)$ با استفاده از تخمین کریجینگ که به داده های تجربی و داده شبیه سازی شده قبلی مقید شده است.
- ۴- تعیین بازه تابع توزیع $F_z(z)$ که قرار است نمونه برداری شود.
- ۵- تولید عددی مانند p از توزیع یکنواخت بین صفر و یک
- ۶- تولید یک مقدار y^s از تابع توزیع گوسی $G(y(x_u)^*, \sigma_{sk}^2(x_u))$ به صورت زیر:

$$y^s = G^{-1}(y(x_u)^*, \sigma_{sk}^2(x_u), p)$$
- ۷- تولید مقدار شبیه سازی شده به صورت زیر:

$$z^s(x_u) = \varphi^{-1}(y^s)$$
 که در آن φ^{-1} تبدیل معکوس گوسی است.
- ۸- تکرار مراحل فوق تا زمانی که همه سلول ها شبیه سازی شوند.

توجه شود که تابع توزیع گوسی فقط برای نمونه برداری از تابع توزیع تجمعی استفاده می شود و نیازی به فرض گوسی بودن تابع توزیع تجمعی اولیه نیست. برای تولید مقدار شبیه سازی در الگوریتم رایج از تابع توزیع تجمعی کلی استفاده می شود (Soares, 2001). این بدان معنی است که در کل شبکه شبیه سازی احتمال ظهور یک مقدار شبیه سازی شده یکسان است. از طرف دیگر، یک مدل پیوستگی فضایی مشابه برای کل شبکه در نظر گرفته می شود. این امر موجب ساده سازی الگوریتم و در نتیجه سرعت بالای اجرای آن خواهد شد اما در بعضی شرایط ممکن است با واقعیت منطبق نباشد. این موضوع خصوصاً در شرایطی که تغییرات پارامتر مورد مطالعه در یک راستا بسیار بیشتر از راستاهای دیگر

نشریه پژوهش های ژئوفیزیک کاربردی، دوره ۱۰، شماره ۲، ۱۴۰۳.

است، ایجاد مشکل می کند. به عنوان مثال در شرایطی که لایه ها زیرسطحی تقریباً افقی یا با شیب کم هستند، بیشترین تغییرات متغیر مورد نظر تنها در جهت قائم وجود دارد و تغییرات جانبی خفیف است. در این شرایط، استفاده از تابع توزیع تجمعی کلی برای شبیه سازی نقاطی که از نظر موقعیت فضایی در قسمت های مختلفی قرار دارند، ممکن است موجب تولید مقادیر شبیه سازی نادرست گردد.

در این پژوهش، چارچوب مشخصی برای تولید پایگاه داده به صورت خودکار در محیط برنامه نویسی MATLAB مطابق شکل ۱ ارائه شده است. همانطور که در این شکل مشخص است، اولین مرحله اول انتخاب پنجره مناسب برای استخراج مقاطع مختلف از مدل اولیه است. انتخاب داده های چاه های مصنوعی به تعداد دلخواه از مقاطع انتخاب شده دومین مرحله مهم این فلوچارت را تشکیل می دهد. انتخاب تصادفی داده های چاه باید به گونه ای باشد که توزیع فضایی مناسب داشته باشد. این کار توسط اندازه گیری فاصله چاه ها به صورت خودکار در آمده است. در صورت تایید، سپس، ورود داده های چاه به الگوریتم شبیه سازی صورت گرفته و مدل های آموزشی تولید بر اساس شبیه سازی ساده یا شبیه سازی توأمان انجام می شود. با انتخاب پارامترهای مختلف می تواند داده های آموزشی انبوه را تولید نمود. در این مقاله، به عنوان نمونه، استفاده از شش مدل سرعت معروف (شکل ۲) برای تولید داده های آموزشی مورد استفاده قرار گرفته و نتایج آن در قسمت بعد آورده شده است.

۳- شبیه سازی عددی و نتایج


به منظور شبیه سازی و تولید مدل های مناسب، از شش مدل سرعت معروف که در اکثر مقالات به آنها پرداخته می شود، استفاده شد (شکل ۲). برای تنوع کافی در مدل های سرعت و به منظور شبیه سازی و استفاده به عنوان داده آموزشی، بخش هایی از این مدل های سرعت جدا شده و از بین این مدل ها، آنهایی را که از نظر زمین شناسی دارای مفهوم هستند انتخاب شده است. سپس این مدل ها، به عنوان ورودی مرحله شبیه سازی به رفته است. در این مقاله، ابعاد هر مدل را ۱۰۰ در ۱۵۰ سلول است. این ابعاد برای تنوع در ساختار زمین شناسی در مدل های ذکر شده انتخاب شده و محدودیتی در تغییر ابعاد براساس نظر متخصص وجود ندارد. سپس از روش شبیه سازی متوالی مستقیم و شبیه سازی متوالی مستقیم توأمان برای تولید مدل های مناسب برای آموزش شبکه های عصبی عمیق استفاده شده است.

مطابق فلوچارت شکل ۱، ابتدا از هر مدل ۴، ۶ و ۸ چاه به صورت تصادفی استخراج شده و با استفاده از روش شبیه سازی متوالی مستقیم، تولید داده انجام گردید که در شکل های ۳ تا ۱۴ (الف-ت) برخی از خروجی های شبیه سازی آورده شده است. این روش می تواند برای مدل هایی که دارای گنبدنمکی یا گسل باشد تا حد مطلوبی کارآمد باشد. در شکل های ۴، ۷، ۱۰ و ۱۲، مدل سازی بر روی مدل های سرعت دارای گنبدنمکی انجام شده است که نتایج، هنگامی که از تصویر ثانویه استفاده شده مطلوب تر است. همچنین در شکل ۶ مدل سرعت دارای گسل، شبیه سازی شده است. همانطور که مشخص است هنگامی که از تصویر


ثانویه استفاده می‌شود قابلیت مدل کردن گسل‌ها وجود دارد. با استفاده از این روش، تعداد خروجی‌های شبیه‌سازی می‌تواند به هر تعداد دلخواه باشد که در ضمن با هم تفاوت دارند (جلوگیری از بیش برآزش در آموزش شبکه عمیق) و این یکی از مزایای این روش برای تولید داده آموزشی است. همچنین در این مقاله، از روش شبیه‌سازی مستقیم توأمان برای تولید داده با کیفیت و نزدیک به مدل‌های واقعی استفاده شده است. به این صورت که بخشی از ورودی به عنوان تصویر ثانویه در فرآیند شبیه‌سازی در کنار داده‌های چاه استفاده شده است. در این مقاله، به عنوان نمونه، از ضرایب همبستگی ۳۰، ۵۰ و ۷۰ درصد برای شبیه‌سازی توأمان استفاده شده است (شکل‌های ۳ تا ۱۴، ستون‌های ب-ت). استفاده از ضرایب همبستگی مختلف می‌تواند منجر به تولید حجم داده آموزشی بیشتر گردد. اما ضرایب همبستگی بالاتر از ۹۰ درصد می‌تواند تغییرپذیری داده‌ها را کاهش دهد و می‌بایست با احتیاط بیشتری استفاده شود. استفاده از تصویر ثانویه در فرآیند شبیه‌سازی برای تولید مدل سرعت به دو منظور می‌باشد: اول اینکه با این روش نیز مدل سرعت برای آموزش شبکه‌های عمیق به تعداد دلخواه تولید می‌شود و محدودیتی ایجاد نمی‌شود و دوم اینکه استفاده از تصویر ثانویه همان طور که اشاره شد، باعث می‌شود کیفیت بهتری از مدل سرعت با جزئیات بیشتر ارائه گردد. مزیت دیگر این روش این است که از ضرایب همبستگی مختلف برای تولید بدون محدودیت مدل‌های سرعت یا مخزنی می‌توان استفاده نمود. این به معنای تولید به تعداد زیاد از مدل سرعت یا مخزنی برای ایجاد یک پایگاه داده برای آموزش شبکه‌های عصبی عمیق در پژوهش‌های مختلف است.

۴- نتیجه‌گیری و پیشنهاد


در این مقاله، روشی ساده و کم هزینه برای تولید نامحدود داده آموزشی با استفاده از روش شبیه‌سازی مستقیم و شبیه‌سازی مستقیم توأمان ارائه گردید. همچنین در این مقاله، نشان داده شد که استفاده از تصویر ثانویه در تولید مدل‌های دارای پیچیدگی بیشتر نقش موثری دارد اما برای مدل‌های لایه ای افقی روش‌های شبیه‌سازی مستقیم و شبیه‌سازی مستقیم توأمان نتایج تقریباً یکسانی خواهند داشت. از این روش می‌توان برای تولید مدل‌های مناسب با کاربرد در تعیین مدل‌های سرعت و مدل‌های مخزنی برای آموزش شبکه‌های عصبی عمیق از جزئیات کم تا جزئیات زیاد استفاده کرد. همچنین پیشنهاد می‌شود که از مدل‌های تولید شده توسط چارچوب ارائه شده در این مقاله، برای تخمین پارامترهای مخزنی مانند امیدانس صوتی، تخلخل و اشباع در مطالعات آتی استفاده شود. پیشنهاد بعدی، خودکارسازی تعیین پارامترهای واربیوگرام با استفاده از روش‌های هوش مصنوعی و تولید مدل‌های آموزشی با دقت بیشتر است.




شکل ۱: فلوچارت ارائه شده برای تولید پایگاه داده آموزشی




شکل ۲: مدل‌های سرعت مصنوعی




شكل ۳: نتايج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت BP با ساختار لایه‌ای




شكل ۴: نتايج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت BP با توده غير لایه‌ای




شکل ۵: نتایج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت HESS




شکل ۶: نتایج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت HESS دارای ساختار گسل




شکل ۷: نتایج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت Marmousi دارای ساختار ناپیوستگی




شکل ۸: نتایج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت Marmousi دارای ساختار لایه‌ای




شکل ۹: نتایج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت Pluto دارای ساختار لایه‌ای شیب‌دار




شکل ۱۰: نتایج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت Pluto دارای ناپیوستگی




شکل ۱۱: نتایج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت SEGsalt



شکل ۱۲: نتایج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت SEGsalt دارای ناپیوستگی



شکل ۱۳: نتایج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت SIGSBEE2B



شکل ۱۴: نتایج حاصل از شبیه‌سازی متوالی مستقیم و شبیه‌سازی توأمان بر روی مدل سرعت SIGSBEE2B بدون قطع شدگی لایه‌ها

۵- منابع

- Siahkoohi, A., Rizzuti, G. and Herrmann, F. J., Deep bayesian inference for seismic imaging with tasks. arXiv preprint arXiv:2110.04825, 2021.
- Siwei Yu, Jianwei Ma, and Wenlong Wang, 2019, Deep learning for denoising deep learning for denoising. *Geophysics*, 84(6):V333–V350.
- Shihang Feng, Youzuo Lin, and Brendt Wohlberg, 2021, Multiscale data-driven seismic full-waveform inversion with field data study. *IEEE Transactions on Geoscience and Remote Sensing*, pp. 1–14.
- Soares, A., 2001, Direct Sequential Simulation and Cosimulation, *Mathematical Geology*, 33, 911-926.
- Tran, T.T., Deutsch, C.V. and Xie, Y., 2001, Direct Geostatistical Simulation With Multiscale Well, Seismic, and Production Data, SPE Annual Technical Conference and Exhibition, Vol. SPE Paper Number 71323. Society of Petroleum Engineers.
- Virieux, J., and Operto, S., 2009, An overview of full-waveform inversion in exploration geophysics. *Geophysics*, 74(6). <https://doi.org/10.1190/1.3238367>
- Wu, Y. and Lin, Y., 2019, InversionNet: An Efficient and Accurate Data-Driven Full Waveform Inversion. *IEEE Transactions on Computational Imaging*, 6, 419–433.
- Yang, F. and Ma, J., 2019, Deep-learning inversion: A next-generation seismic velocity model building method. *Geophysics*, 84(4), R583–R599.
- Aghamiry, H. S., Gholami, A., and Operto, S., 2019, Implementing bound constraints and total-variation regularization in extended full-waveform inversion with the alternating direction method of multiplier: Application to large contrast media. *Geophysical Journal International*, 218(2), 855–872.
- Araya-Polo, M., Jennings, J., Adler, A. and Dahlke, T., 2018, Deep-learning tomography. *Leading Edge*, 37(1), 58–66.
- Deutsch, C.V. and Journel, A.G., 1992, *GSLIB: Geostatistical software library and user's guide*, Oxford Univ Press, New York. 340.
- Fang, J., Zhou, H., Elita Li, Y., Zhang, Q., Wang, L., Sun, P. and Zhang, J., 2020, Data-driven low-frequency signal recovery using deep-learning predictions in full-waveform inversion. *Geophysics*, 85(6), A37–A43.
- Herrmann, F. J., A. Siahkoohi, and G. Rizzuti. Learned imaging with constraints and uncertainty quantification. In *Neural Information Processing Systems (NeurIPS)*, 2019, Deep Inverse Workshop.
- Johnson, J., Alahi, A. and Fei-Fei, L., 2016, Perceptual losses for real-time style transfer and super-resolution, *European conference on computer vision*. Springer, pp. 694–711.
- Kaur, H., Pham, N., & Fomel, S., 2021, Seismic data interpolation using deep learning with generative adversarial networks. *Geophysical Prospecting*, 69(2), 307–326.
- Laloy, E., Linde, N., Ruffino, C., Hraut, R., Gasso, G. and Jacques, D., 2019, Gradientbased deterministic inversion of geophysical data with generative adversarial networks: Is it feasible? *Computers & Geosciences*, 133, 104333.
- Lecun, Y., Bengio, Y., & Hinton, G., 2015, Deep learning. *Nature*, 521(7553), 436–444.
- Li, S., Liu, B., Ren, Y., Chen, Y., Yang, S., Wang, Y. and Jiang, P. (2020, Deep-Learning Inversion of Seismic Data. *IEEE Transactions on Geoscience and Remote Sensing*, 58(3), 2135–2149.
- Mao, B., Han, L. G., Feng, Q. and Yin, Y. C. (2019). Subsurface velocity inversion from deep learning-based data assimilation. *Journal of Applied Geophysics*, 167, 172–179.
- Ovcharenko, O. V., Kazei, D. P. and Alkhalifah, T., 2019, Style transfer for generation of realistically textured subsurface models: 89th Annual International Meeting, SEG, Expanded Abstracts, doi: 10.1190/segam2019-3216349.1.
- Ren, Y., Xu, X., Yang, S., Nie, L. and Chen, Y., 2020, A Physics-Based Neural-Network Way to Perform Seismic Full Waveform Inversion. *IEEE Access*, 8, 112266–112277.
- Rezaee, H., D. Marcotte, P. Tahmasebi, and Saucier, A., 2015, Multiple-point geostatistical simulation using enriched pattern databases, *Stochastic Environ. Res. Risk Assess.*, 29(3), 893–913