

بیست و سومین همایش انجمن زمین‌شناسی ایران ۲۰ و ۲۱ آبانماه ۱۳۹۹ The 23rd Symposium of Geological Society of Iran 10-11 November, 2020

تشخیص تخلخل در تصاویر سی تی اسکن مغزه با استفاده از شبکه عصبی پیچشی، مطالعه موردی در یکی از مخازن کربناته در بخش مرکزی خلیج فارس

عادل‌ه جمالیان، وحید توکلی

دانشجوی دکتری دانشکده زمین شناسی دانشگاه تهران، دانشیار دانشکده زمین شناسی دانشگاه تهران


چکیده

چکیده : تصاویر سی‌تی‌اسکن مغزه از مهم‌ترین داده‌های رقومی مطالعه مخزن هیدروکربنی هستند. بنابراین استفاده و توسعه الگوریتم‌های مختلف شبکه های عصبی پیچشی (Convolutional Neural Network: CNN) یکی از مهم‌ترین روش‌های یادگیری است که در آن چندین لایه یادگیری آموزش داده می‌شود. در میان این الگوریتم‌ها، شبکه‌های عصبی پیچشی عمیق از دقت بالاتری برخوردار هستند. شبکه‌های پیچشی برای یادگیری برای کارهای مربوط به تصویر و بینایی رایانه مهم هستند. شبکه های پیچشی خاصیت "عدم تغییر فضایی" دارند، به این معنی که آن‌ها یاد می‌گیرند ویژگی‌های تصویر را در هر نقطه از تصویر شما تشخیص دهند. در این مطالعه، تصاویر سی‌تی‌اسکن- سازند کنگان به سن تریاس در بخش مرکزی خلیج فارس ایران با استفاده از CNNطبقه‌بندی و به دو گروه متخلخل و فاقد تخلخل تقسیم شدند. در مجموع ۴۰۹۰ تصویر از ۱۲۳ متر مغزه در بخش مرکزی خلیج فارس استفاده شده است. استفاده از ویژگی‌های مبتنی بر CNNبرای تشخیص تخلخل بررسی شد. سه مرحله اصلی جهت رسیدن به نتیجه نهایی انجام شد. پردازش اولیه تصاویر، استخراج ویژگی‌ها و طبقه‌بندی توسط شبکه از قبل آموزش دیده شده موبایل نت (MobileNetبرای استخراج این ویژگی بدون افزایش داده‌ها استفاده شده است. برای تجزیه و تحلیل عملکرد طبقه‌بندی مجموعه داده‌ها، تعداد تکرار (دوره) و ۷ اندازه دسته تصاویر ۳۲ بود. میزان خطای داده های آزمون ۰.۲ و برای داده های آموزش ۳.۶ است. مقدار دقت برای داده های آموزش ۹۸.۳٪ و برای داده های آزمون ۷۷.۶۲٪ است. نتایج حاصل از توسعه این روش به عنوان روش شناسایی تخلخل در تعداد زیاد تصاویر و همچنین مدل پایه‌ای برای ارزیابی ناهمگنی مخازن هیدروکربنی مورد استفاده قرار خواهد گرفت.


مقدمه

مقدمه : امروزه یادگیری عمیق به حوزه مطالعاتی بسیار جذابی در رشته‌های مختلف علوم نظیر کامپیوتر، دارو و درمان، امور اقتصادی و غیره تبدیل شده است (۱-۱۶). یادگیری عمیق زیرمجموعه‌ای از هوش مصنوعی و یادگیری ماشین است که به عنوان یک زبان ساده که توسط تکنیک‌های یادگیری ماشین آموخته می‌شود، تعریف می‌شود (۱۸). هدف از یادگیری عمیق انجام کارهای دشوار و وقت‌گیر به جای انسان و همچنین استفاده از مهندسی ویژگی است. از ویژگی‌های مهم یادگیری عمیق، توانایی یادگیری خودکار ویژگی‌ها، دقت بالا در نتایج، قدرت تعمیم بالا و شناسایی داده‌های جدید و پشتیبانی گسترده از سخت‌افزار و نرم‌افزار است (۱۷). از کاربردهای یادگیری عمیق می‌توان به ترجمه خودکار، ربات‌های سخنگو، اتومبیل‌های بدون سرنشین اشاره نمود و جالب‌ترین کاربرد آن در پردازش تصویر است. بر خلاف شبکه‌های عصبی رایج که با شناسایی ویژگی‌های تصویر، اجزای آن را از هم متمایز می‌کنند، در روش یادگیری عمیق، تعداد زیادی عکس به رایانه داده می‌شود و بدون تعریف ویژگی‌ها، رایانه چندین لایه ایجاد می‌کند و الگوهایی را می‌آموزد تا ویژگی‌ها و اجزای مختلف تصاویر را شناسایی و اندازه‌گیری کند. از یادگیری عمیق به طور گسترده‌ای در کارهای مختلف بینایی رایانه مانند طبقه‌بندی تصویر و تشخیص اشیاء استفاده شده است. یادگیری عمیق یک الگوریتم یادگیری ماشین مبتنی بر یک شبکه عصبی است که می‌تواند به عنوان یادگیری تحت نظارت ، یادگیری نیمه-نظارت‌شده یا یادگیری بدون نظارت استفاده شود. شبکه یادگیری عمیق از چندین لایه برای استخراج ویژگی‌ها از داده‌های ورودی استفاده می‌کند و پس از آن عملیاتی نظیر طبقه‌بندی، برازش و یا سایر عملیات را بر روی ویژگی‌های استخراج شده انجام می‌دهد. یادگیری عمیق در زمینه‌های مختلف علمی مانند بینایی ماشین، تشخیص گفتار، تفکیک منبع صوتی و بسیاری از زمینه‌های دیگر کاربرد دارد (۲، ۱۸).

الگوریتم‌های یادگیری عمیق که ویژگی‌های قابل تشخیص یا غیرقابل تشخیص را در سلسله مراتبی از داده‌ها یاد می‌گیرند، می‌توانند در علوم زمین برای تجزیه و تحلیل مقدار قابل توجهی از اطلاعات استفاده شوند. تصاویر سی‌تی‌اسکن از مقطع مغزه‌ها، به عنوان داده‌هایی که انعکاسی از شرایط داخل زمین را نمایان می‌سازند، به هدف ثبت اطلاعات استخراج شده از تصویر در مقیاس چاه در منطقه مورد مطالعه اهمیت دارند. بسته به نوع اطلاعات می‌توان ویژگی‌های مبتنی بر شیء یا ساختار را از تصاویر استخراج نمود. روش‌های یادگیری عمیق مورد استفاده در تشخیص هدف به سه دسته‌ی اصلی شامل روش‌های نظارت‌شده، نیمه-نظارت‌شده و نظارت نشده تقسیم می‌شوند. در زمین‌شناسی ، ران و همکاران (۱۹) نشان دادند که تجزیه و تحلیل تصویر با استفاده از شبکه عصبی پیچشی عمیق برای شناسایی انواع سنگ از تصاویر گرفته شده در این زمینه قابل استفاده است. ژانگ و همکاران (۲۰) مدل‌های یادگیری عمیق بر روی تصاویر ساختار زمین شناسی برای طبقه بندی استفاده کردند. چنگ و ونهوی (۲۱) تصاویر سنگ را با ضریب اطمینان بالا بر اساس شبکه عصبی پیچشی طبقه بندی کردند. واضح است که این توانایی استثنایی در یادگیری و حل مشکلات پیچیده‌تر، به کامپیوترهایی با قدرت محاسبات بالا احتیاج دارد، اما انجام تحلیل داده‌ها با حجم کم توسط رایانه‌های معمولی نیز امکان‌پذیر است. این مقاله بر روی محبوب‌ترین مدل و کاربرد یادگیری عمیق در بینایی ماشین یعنی شبکه عصبی پیچشی تمرکز دارد. پردازش تصویر با کمک زبان پایتون (Python، در تصاویر سی‌تی‌اسکن مغزه به منظور شناسایی تصاویر حاوی تخلخل از تصاویر بدون تخلخل استفاده می‌شود. تجزیه و تحلیل رخسار، محیط‌های رسوبی و تغییرات دیانزتری این سازند قبلاً توسط محققان مختلف (۲۲، ۲۳، ۲۴، ۲۵) بررسی شده است. برخی از نویسندگان ناهمگنی مخزن را نیز مورد توجه قرار داده‌اند (۲۳، ۲۵). تصاویر سی‌تی‌اسکن مغزه تا کنون برای ارزیابی ناهمگنی در سازند



شکل ۱: تصاویر سی‌تی‌اسکن حاوی تخلخل. نقاط تیره در تصویر نشان‌دهنده حفرات هستند. قطر هر تصویر ۱۰ سانتی‌متر است.




شکل ۲: تصاویر سی‌تی‌اسکن از مقاطع ماتریکس (بدون تخلخل). تصاویر متخلخل نیستند. رگه‌های شکستگی و لکه‌های سیمانی‌شده در برخی از تصاویر که با رنگ روشن قابل شناسایی هستند، پراکنده شده‌اند.

بیست و سومین همایش انجمن زمین‌شناسی ایران ۲۰ و ۲۱ آبانماه ۱۳۹۹

The 23rd Symposium of Geological Society of Iran 10-11 November, 2020


مواد و روش کار

مواد و روش کار : در این تحقیق از یک پایگاه داده شامل مجموعه‌ای از تصاویر سی‌تی‌اسکن از ۱۲۳ متر مغزه از سازند کنگان به سن تریاس از یک چاه در بخش مرکزی خلیج فارس تهیه شده است. تعداد ۴۰۹۰ تصویر با فاصله متوسط یک اینچ تهیه شده است. هر یک از تصاویر نمای مقطعی از مغزه را نشان می‌دهند. همه تصاویر در مقیاس خاکستری هستند و به دو دسته حاوی تخلخل و صرفاً ماتریکس (بدون تخلخل) تقسیم شدند. وضوح هر تصویر ۵۱۲ * ۵۱۲ پیکسل است. تصاویر انتخاب شده از هر دسته در شکل‌های سمت راست و چپ با مقیاس کوچک نشان داده شده است. شبکه CNNبه عنوان یک روش یادگیری عمیق برای طبقه بندی تصویر مورد استفاده قرار می‌گیرد. بنابراین داده‌ها برای آموزش و آزمایش به یک شبکه عصبی پیچشی وارد می‌شوند. به این منظور، تمام پردازش‌ها درمحیط کولب انجام شد. کولب بستری است که امکان دسترسی به نوت بوک ژوپیتر را که دارای کد پایتون است فراهم می‌کند و امکان اتصال به GPUهای قدرتمند برای تسریع در عملیات یادگیری ماشین را دارد.



بحث

داده ها به صورت عدد اعشاری کوتاه ذخیره می‌شوند و مقدار هر پیکسل به صورت رقمی بین ۰ تا ۲۵۵ است. سپس ماتریس‌های با ابعاد صحیح نیز به فرمت اعداد اعشاری کوتاه تبدیل می‌شوند. سپس میانگین مجموعه داده‌ها بر روی ویژگی‌های (تصویری) مختلف محاسبه شده و از داده‌های آموزش و آزمون کم شده و بر ۲۵۵ تقسیم می‌شود تا داده‌ها را بین ۰ و ۱ قرار دهد. شبکه‌ی پیش‌آموزش‌دیده‌ی موبایل‌نت برای تصاویر رنگی استفاده می‌شود، در نتیجه تصاویر سی‌تی‌اسکن استفاده شده در مطالعه حاضر توسط نرم‌افزار فوتوشاپ رنگ شده و حاشیه تصاویر نیز بریده شد. در نهایت تنها مقاطع دایره‌ای تصاویر مورد بررسی قرار گرفت. در این مقاله از شبکه پیش‌آموزش‌دیده‌ی موبایل‌نت برای استخراج ویژگی بدون افزایش تعداد داده‌ها استفاده شد. معماری این شبکه بر روی پایگاه داده تصویری نت آموزش دیده است. برای طبقه‌بندی ویژگی‌ها از تابع برازش چندکلاسه استفاده شد. امتیاز کلاس‌ها به عنوان لگاریتم احتمال غیرطبیعی در نظر گرفته می‌شود. هرچه امتیاز یک کلاس بیشتر باشد، احتمال مشابهت آن با تصویر ورودی بیشتر است. با توجه به تابع تعریف شده امتیاز بالاتر یک کلاس معادل با احتمال مشابهت بیشتر است. سپس تابع هزینه محاسبه می‌شود. هر چه مقدار بیشتری از تابع هزینه به دست آید، در نتیجه مقدار وزن قابل قبول نخواهد بود. سپس تابع حداقل هزینه محاسبه و از تابع توسط روش تخمین تحلیلی مشتق گرفته می‌شود. الگوریتم پس انتشار این محاسبات را به صورت خودکار انجام می‌دهد. این الگوریتم مقدار شیب را در هر نقطه تخمین می‌زند. برای تجزیه و تحلیل عملکرد طبقه‌بندی تصاویر بر روی یک پایگاه داده، تعداد تکرارها ۲ مرتبه و اندازه هر دسته ۱ است. در مجموع، ۸۰ درصد تصاویر برای آموزش و تصاویر باقیمانده برای آزمایش در نظر گرفته شدند. یادگیری عمیق می‌تواند سطوح انتزاعی از تصویر را نمایش دهد و آن‌ها را از درجه پایین به بالا ترکیب نماید. شکل ۴ چارچوب کلی یادگیری عمیق را برای تجزیه و تحلیل تصاویر مغزه نمایش می‌دهد. نمودار شامل سه بخش اصلی است: داده‌های ورودی، لایه‌های مخفی و داده خروجی مورد انتظار. یکی از الگوریتم‌های اصلی کاربردی در یادگیری عمیق شبکه عصبی پیچشی است.



شکل ۴: تصویر شماتیکی از معماری یک شبکه عصبی پیچشی با لایه‌های متحرک (pooling layer) و کاملاً متصل (fully connected layer). عصبی پیچشی پیشنهادی دارای دو لایه است.


یکی از مسائل اصلی در حوزه بینایی ماشین این است که کدام سیستم بینایی می‌تواند ویژگی‌ها را درست‌تر تشخیص دهد. شبکه عصبی پیچشی یکی از معماری‌های یادگیری عمیق است که در حوزه بینایی رایانه و ارائه مدل‌های قدرتمند برای شناسایی و طبقه‌بندی تصاویر به کار می‌رود. می توان از شبکه عصبی پیچشی برای یادگیری و تفسیر ویژگی‌های تصویر استفاده کرد. ایندولیا و همکاران (۲۶) منبع جامعی برای درک این شبکه ارائه داده‌اند. مجموعه داده‌های مورد استفاده در این تحقیق به ۸۰ درصد برای آزمون تقسیم شدند. مسئله پیش روی این تحقیق یعنی تشخیص تخلخل از تصاویر دو بعدی سی‌تی‌اسکن برای اولین بار توسط یک شبکه یادگیری عمیق در دست بررسی بوده و هیچ مدل از پیش آموزش‌دیده‌ای برای آموزش سیستم وجود نداشت. ایده اصلی شبکه عصبی پیچشی استخراج ویژگی از تصاویر ورودی است. سپس با کاهش وضوح ویژگی‌های استخراج شده، تصویر در برابر نویز، جابه‌جایی، انتقال و چرخش مقاوم خواهد شد. به نظر می رسد استخراج یک ویژگی از تصویر قبل از لایه پیچشی یا کانولوشن برای هر نقشه ویژگی، بهتر از استخراج ویژگی‌های نقشه‌های ویژگی، لایه خروجی می‌شود. بعد از این مراحل، آخرین لایه توسط یک یا چند لایه مخفی به خروجی متصل می‌شود. عملکردهای فعال‌سازی تمام سلول‌های عصبی در همه لایه‌ها سیگمئوئید است. مجموعه داده‌های مربوط به این تحقیق برای اولین بار در حوزه اعمال شبکه یادگیری عمیق توسط نویسندگان تهیه و مدل شبکه عصبی پیچشی بر آن اعمال شده است. بنابراین از آن‌جایی که مجموعه داده مشابهی برای استفاده از مدل و پیش‌آموزش آن در دسترس نبود، دقت مدل با سایر مدل‌ها قابل مقایسه نیست. در روش پیشنهادی، تمام پردازش‌ها در گوگل کولب انجام شد. استفاده از معماری از قبل آموزش دیده‌ی موبایل‌نت برای استخراج ویژگی‌ها منجر به روش پیشنهادی برای انجام طبقه‌بندی دقیق‌تر شده است. دقت این مدل ۷۷.۶۲٪ است. منحنی‌های خطا و دقت مدل پیشنهادی ما در حین آموزش در شکل ۵ و ۶ قابل مشاهده است. هرچه منحنی افت کمتری داشته باشد، درنتیجه مدل ارائه شده بهتر است. مقدار ضرر با توجه به آموزش و آزمون محاسبه می‌شود و تفسیر آن این است که مدل ارائه شده چقدر برای این دو مجموعه کارایی دارد. بر خلاف دقت، مقدار خطا به درصد نیست. مقدار خطا معادل مجموع خطاهایی است که برای هر مثال در مجموعه‌های آموزش یا اعتبارسنجی ایجاد شده است. مقدار دقت اطلاعات آموزش ما به ۹۸.۳ درصد رسید، اما دقت اطلاعات آزمون پس از ۵ دوره تکرار به حدود ۷۷.۶۲ درصد رسید و پس از آن تغییری نکرد. برای پیش‌پردازش داده‌ها، ماتریس‌هایی از نوع عدد صحیح به فرمت اعداد اعشاری کوتاه تبدیل شدند. سپس مقدار میانگین در ویژگی‌های مختلف محاسبه شد و در نهایت میانگین محاسبه شده از داده های آموزش و آزمون کم شد. مجموعه داده‌ها به دو دسته با کلاس (با تخلخل و بدون تخلخل) تقسیم شدند. با استفاده از فرایند رمزگذاری وان-هات ، هر یک از این دو کلاس به یک بردار دودویی تبدیل شده‌اند که اولین جزء آن یک و جزء دیگر آن صفر است. به عنوان مثال، در کلاس ۰ و ۱ به صورت (۰، ۱) و (۱، ۰) نشان داده می‌شوند. با توجه به اینکه با تعداد کمی از داده (۴۰۹۰ تصویر) و با ابزارهایی مانند تقویت داده و حذف تصادفی، نمی‌توان به دقت بسیار بالایی دست یافت، بنابراین برای یادگیری نیاز به استفاده از شبکه‌های از پیش آموزش دیده مانند موبایل نت داریم. برای استفاده از شبکه‌های از قبل آموزش دیده دو روش وجود دارد: روش افزایش داده (تقویت داده) و بدون افزایش داده. روش تقویت داده بسیار کند است، زیرا هر بار که نیاز به گرفتن عکس از یک حلقه پیچشی عمیق است به تعداد زیادی پردازش نیاز است. روش استخراج ویژگی بدون افزایش داده‌ها روشی سریع است که در این مقاله استفاده می‌شود. مجموعه داده تحقیق حاضر متشکل از ۴۰۹۰ تصویر است که برای آموزش به صورت جداگانه در اختیار شبکه پیچشی قرار گرفت. سپس هر یک از تصاویر به یک بردار ویژگی تبدیل شدند. وضوح تصاویر به بزرگی ۵۱۲ * ۵۱۲ * ۳ بود که هر یک از آن‌ها به بردارهای بزرگ تبدیل شدند. لازم به ذکر است که این ویژگی‌ها توسط شبکه مبتنی کانولوشن با همان شبکه پیچشی استخراج شدند. سپس مجموعه داده به ماتریسی از تصاویر و بردارها تبدیل شده، کلاس مربوط به ویژگی اختصاص داده شده و پس از آن روند آموزش آغاز شد.




نتیجه گیری

برای طبقه بندی ویژگی‌ها از طبقه بندی سافت-مکس استفاده شد. در این مرحله با توجه به رتبه‌بندی کلاس‌ها، وزن‌های قابل قبول یا غیرقابل قبول (((که امتیازات از آن‌ها محاسبه شده است، باید به دست آید. هرچه درجه یا رتبه کلاسی بیشتر باشد، یعنی کلاس احتمالاً مشابه همان تصویر ورودی می‌باشد. پس از این مرحله حداقل تابع ژئان با الگوریتم پس‌انتشار محاسبه شد.

برای تجزیه و تحلیل عملکرد طبقه‌بندی مجموعه داده‌ها، تعداد تکرار (دوره) و ۷ اندازه دسته تصاویر ۳۲ بود. میزان میان دقت و خطا برای مجموعه داده ارائه شده است (شکل‌های ۵ و ۶). در شکل ۵ میزان خطای داده برای داده های آزمون ۰.۲ و برای داده های آموزش ۳.۶ است. در شکل ۶، مقدار دقت برای داده های آموزش ۹۸.۳٪ و برای داده های آزمون ۷۷.۶۲٪ است.



شکل ۵: منحنی خطا (Loss)داده‌های آموزش. مدل کم‌برازش (Underfit)نشان می‌دهد که خطای آموزش کاهش پیدا کرده و در بخش پایانی نمودار نیز همچنان کاهش می‌یابد.



شکل ۶: منحنی دقت در داده‌های آموزش. استفاده از تصاویر بیشتر در مجموعه آموزش باعث شد که الگوریتم بایاس به حداقل برسد.

نتیجه‌گیری

یادگیری عمیق با کمک الگوریتم‌های شبکه‌ی عصبی مصنوعی که از مغز انسان الهام گرفته شده است از مجموعه‌ای بزرگ از داده‌ها یاد می‌گیرد از بین همه برنامه های کاربردی یادگیری عمیق، بینایی ماشین یکی از محبوب‌ترین آن‌هاست. شبکه عصبی پیچشی یکی از بهترین ابزارهای موجود برای بینایی ماشین است.در این تحقیق شبکه عصبی پیچشی به عنوان یک روش خوب برای شناسایی و طبقه بندی تصاویر اصلی سی تی اسکن عمل نمود. در مجموع ۴۰۹۰ تصویر ورودی در دو کلاس آموزش و آزمون به شبکه دو لایه پیچشی داده شد. پس از استفاده از الگوریتم، نتایج نشان داد که شبکه توانست تصاویر متخلخل و ماتریس را با دقت ۷۷.۶۲٪ جدا کند. در مطالعات آینده، با هدف بهبود نتایج طبقه بندی و جلوگیری از حالت بیش‌برازش ((Overfitting، تعداد و تنوع تصاویر در پایگاه داده باید افزایش یابد. در این راستا بهتر است از پایگاه داده‌های از پیش‌آموزش دیده دیگری استفاده نمود تا توانایی طبقه بندی داده‌های مختلف افزایش یابد.

منابع

- [1] Bakker, I.D.: Python Deep Learning Cookbook: Over 75 practical recipes on neural network modeling, reinforcement learning, and transfer learning using Python. Packt Publishing (2017).
- [2] Ciresan, D., Giusti, A., Schmidhuber, J.: Deep neural networks segment neuronal membranes in electron microscopy images. In NIPS (2012).
- [3] Clement Farabet, L. Couprie, N. and LeCun, Y.: Learning hierarchical features for scene labeling. PAMI, 35(8) (2013).
- [4] Deng, L. and Yu, D.: Deep Learning: Methods and Applications. Foundations and Trends in Signal Processing: 7: 3–4, 197–387 (2014).
- [5] Girshick, R., Donahue, J., Darrell, T. and Malik, J.: Rich feature hierarchies for accurate object detection and semantic segmentation. CoRR abs/1311.2524 (2014).
- [6] Glassner, A.: Deep Learning, Vol. 2: From Basics to Practice, Amazon Digital Services LLC (2018).
- [7] Krizhevsky, A., Sutskever, I. and Hinton, G. E.: Imagenet classification with deep convolutional neural networks. NIPS. 1097–1101 (2012).
- [8] LeCun, Y., Bengio, Y. and Hinton, G.: Deep learning. Nature volume, 521, 436–444 (2015).
- [9] Liangpei, Z., Zhang, L. and Du, B.: Deep learning for remote sensing data: A technical tutorial on the state of the art. IEEE Geoscience and Remote Sensing Magazine 4.2: 22–40 (2016).
- [10] Ouyang, W., Wang, X., Zeng, X., Qiu, S., Luo, P., Tian, Y., Li, H., Yang, S., Wang, Z., Loy, C.: DeepID-net: Deformable deep convolutional neural networks for object detection. CVPR (2015).
- [11] Ouyang, W., Wang, X., Zhang, C. and Yang, X.: Factors in finetuning deep model for object detection with long-tail. In CVPR (2016).
- [12] Razavian, S., Azizpour, H., Sullivan, J. and Carlsson, S.: CNN features off-the-shelf: an astounding baseline for recognition. arXiv preprint arXiv:1403.6382 (2014).
- [13] Ren, S., He, K., Girshick, R. and Sun, J.: Faster r-cnn: Towards real-time object detection with region proposal networks. NIPS, arXiv: 1506.01497v3 (2015).
- [14] Simonyan K., and Zisserman, A.: Very deep convolutional networks for large-scale image recognition. CoRR abs/1409.1556 (2014).
- [15] Skansi, S.: Introduction to Deep Learning: From Logical Calculus to Artificial Intelligence (Undergraduate Topics in Computer Science), Springer (2018).
- [16] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A.: Going deeper with convolutions. CVPR. In: Proceedings of the IEEE conference on computer vision and pattern recognition (2015).
- [17] Goodfellow, I., Bengio, Y. and Courville, A.: Deep Learning, the MIT Press, Cambridge (2016).
- [18] Chollet, F.: Deep Learning with Python. Manning Publications Co (2018).
- [19] Ran, X., Xui, L., Zhang, Y., Liu, Z., Sang, X. and He, J.: Rock Classification from Field Image Patches Analyzed Using a Deep Convolutional Neural Network. Mathematics, 7, 755, doi:10.3390/math7080755 (2019).
- [20] Zhang, Y., Wang, G., Li, M. and Han, Sh.: Automated Classification Analysis of Geological Structures Based on Images Data and Deep Learning Model. Applied Sciences, doi: 10.3390/app8122493 (2018).
- [21] Cheng, G. and Wenhui, G.: Rock images classification by using deep convolution neural network. IOP Conf. Series: Journal of Physics: Conf. Series 887 doi:10.1088/1742-6596/887/1/012089 (2017).
- [22] Abdolmaleki, J., Tavakoli, V., Asadi-Eskandar, A.: Sedimentological and diagenetic controls on reservoir properties in the Permian–Triassic successions of western Persian Gulf, southern Iran. J. Petrol. Sci. Eng. 141, 90–113 (2016).
- [23] Nazari, M.H., Tavakoli, V., Rahimpour-Bonab, H., Sharifi-Yazdi, M.: Investigation of factors influencing geological heterogeneity in tight gas carbonates, Permian reservoir of the Persian Gulf. Journal of Petroleum Science and Engineering, 183, no. 106341 (2019).
- [24] Nazemi, M., Tavakoli, V., Rahimpour-Bonab, H., Hosseini, M., Sharifi-Yazdi, M.: The effect of carbonate reservoir heterogeneity on Archie's exponents (a and m), an example from Kangan and Dalan gas formations in the central Persian Gulf. Journal of Natural Gas Science and Engineering, 59, 297–308 (2018).
- [25] Rahimpour-Bonab, H.: A procedure for appraisal of a hydrocarbon reservoir continuity and quantification of its heterogeneity. Journal of Petroleum Science and Engineering, 58, 1–12 (2007).
- [26] Indolia, S., Goswami, A.K., Mishra, S.P. and Asops, P.: Conceptual Understanding of Convolutional Neural Network-A Deep Learning Approach. Procedia Computer Science, 132, 679–688 (2018).