

شناسایی و استخراج رخسارههای کانالی با استفاده از شبکه عصبی پرسپترون چند لایه با الگوریتم پسانتشار و فیلتر اتصال کوچکترین اجزای ساختاری

معصومه لطفى' و عبدالرحيم جواهريان'*

۱ – دانشجوی دکتری، دانشکده مهندسی نفت، دانشگاه صنعتی امیرکبیر ۲- استاد، دانشکده مهندسی نفت، دانشگاه صنعتی امیرکبیر، استاد بازنشسته، مؤسسه ژئوفیزیک، دانشگاه تهران

دریافت مقاله: ۱۳۹۹/۰۱/۰۲؛ پذیرش مقاله: ۱۳۹۹/۰۳/۲۹

* نویسنده مسئول مکاتبات: javaherian@aut.ac.ir

چکیدہ	واژگان کلیدی
رخسارههای کانالی از جمله پدیدههای چینهشناسی حائز اهمیت از منظر اکتشاف منابع هیدروکربنی هستند؛ که با توجه به عمق تدفین و محتویات سیال، ممکن است قابلیت مخزنی داشته باشند یا بهعنوان مخاطره حفاری لحاظ شوند. بنابراین مکانیابی دقیق آنها قبل از تعیین هدف و طراحی مسیر حفاری ضروری است. با توجه به حجم بالای دادههای لرزهای و افزایش روزافزون تعداد نشانگرها، ترکیب نشانگرهای لرزهای با الگوریتمهای محاسباتی متفاوت، جزئیات بالاتری از رویدادهای لرزهای بدست میدهد. در این مطالعه از روشی نیمهخودکار مبنیبر تلفیق نشانگرهای لرزهای بر اساس شبکه عصبی پرسپترون چندلایه با الگوریتم پسانتشار، به منظور شناسایی مرزهای کانالهای مدفون واقع در برشهای زمانی از مربعات عادی شده و درصد ردهبندی نادرست مجموعه آزمایشی و مجموعه آموزشی به کمترین مقدار خود، تصویر بهبود یافتهای از کانالهای موجود در دادههای لرزهای با تفکیک پذیری نسبتا بالا ارائه گردیده است. سپس نتایج حاصل از شناسایی مرز کانالها با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار با نتایج حاصل از شناسایی مرز کانالها با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتی دان د که با رسیدن خطای میانگین مرز کانالها با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار با نتایج حاصل از شناسایی مرز کانالها با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار با نتایج حاصل از روشهای تحلیل مرز کانالها با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار با نتایج حاصل از روشهای تحلیل مولفههای اصلی و X -میانگین و نیز ترکیب این دو روش بهصورت کمی و کیفی مقایسه شد. بررسیها نشان داد که طرحواره پیشنهادی ضمن تاثیرپذیری کمتر نسبت به نوفه پسزمینه، جزئیات دقیقتری از مرزهای کانالهای موجود در دادههای لرزهای ثبت نموده است. استخراج خودکار موقعیت فضایی کانال موجود در داده لرزهای کانالهای موجود در دادههای اتصال کوچکترین اجزای ساختاری، تصویر دقیقی از محدوده کانال مورد مطالعه ارائه داده است.	رخسارههای کانالی نشانگرهای لرزهای شبکه عصبی مصنوعی آموزش نظارتی و غیرنظارتی فیلتر اتصال کوچکترین اجزای ساختار

۱- مقدمه

گسترش لرزهنگاری سهبعدی امکان آشکارسازی و بررسی ریختشناسیهای زیرسطحی و تفسیر رویدادهای ساختمانی و چینهای را فراهم آورده است. کانالها از جمله مهمترین پدیدههای چینهشناسی هستند که در صورت اشباع بودن از سیال هیدروکربنی میتوانند از دیدگاه مخزنی اهمیت پیدا کنند. علاوه بر این، کانالهای مدفون در عمق کم، عملیات حفاری را با چالش مواجه می سازند. بنابراین مکان یابی دقیق آنها یکی از مراحل اصلی تفسیر دادههای لرزهای برای تعیین مسیر حفاری محسوب میشود. با گسترش فنآوری لرزهنگاری سه بعدی در دهه ۱۹۸۰، نشانگرهای متعددی از جمله نشانگرهای مرتبط با دامنه (Rijks and Jauffred, 1991)، همدوسی (Rijks and Jauffred, 1991) 1995)، فركانس (Brown, 2001) و انحنا (Roberts, 2001) به منظور تسهیل فرآیند تفسیر کانالها معرفی شدند. نشانگرهای لرزهای، ویژگیهایی از داده لرزهای هستند که اطلاعات مورد نیاز در خصوص دامنه، فاز، فرکانس، پیوستگی و ریختشناسی را برای شناسایی الگوهای زمین شناسی فراهم می آورند (Qi et al., 2016). در برش های زمانی، كانالها اغلب به صورت لبههایی با مولفههای فركانس بالا دیده می شوند؛ به گونهای که مقادیر شدت روشنایی در آنها بهطور قابل ملاحظهای تغییر مى كند (Karbalaali et al., 2017). نمايش كانالها به صورت فروافتادگیهای جزئی موجود در بازتابندهها در مقاطع لرزهای دو بعدی، تفسیر آنها را با چالش مواجه ساخته است. لذا شناسایی کانالها از برشهای زمانی موجود در دادههای لرزهای سه بعدی پیچیدگی کمتری به همراه دارد (Boustani et al., 2019a).

در سالهای اخیر، با الهام از روشهای پردازش تصویر تحقیقات وسیعی در خصوص شناسایی لبههای موجود در دادههای لرزهای ارائه گردید. (2011) Aqrawi and Boe از فیلتر سوبل اصلاح شده بر مبنای هدایت شیب (Dip-guided) به منظور شناسایی لبههای موجود در دادههای لرزهای استفاده نمودند. (2012) .song et al از گرادیان محلی یک تابع درجه سه، موسوم به تابع برازش سطحی^۱ به منظور طراحی یک نشانگر کارآمد در شناسایی ریز گسلهای موجود در دادههای لرزهای استفاده نمودند. (2013) .Mahdavi Basir et al اردیات محلی استفاده نمودند. (2013) .it انفیق نتایج حاصل فشانگر کارآمد در شناسایی ریز گسلهای موجود در دادههای لرزهای استفاده نمودند. (2013) .mahdavi Basir et al اردیات توسط ان الگوریتم بهینهسازی کلونی مورچگان^۲ با پارامترهای متعلق به یکی از شبکه عصبی مصنوعی، گسلهای موجود در داده لرزهای متعلق به یکی از میادین نفتی ایران را شناسایی کردند. (2014) ما تلفیق نتایج حاصل میادین نفتی ایران را شناسایی کردند. (2014) موجود در حجم لرزهای مورد مطالعه را برجسته نمودند. (2013) در (2015) با استفاده از نشانگرهای مبنیبر ماتریس همرویداد سطح

خاکستری ٔ رخساره های کانالی موجود در حوضه رسوبی وینا (Vienna) را شناسایی کردند. (Sadeghi et al. (2016) از ترکیب رنگی قرمز-سبز-آبی (RGB) حجمهای تک بسامد حاصل از تجزیه طیفی، برای تفسیر بهبود یافته کانالها استفاده نمودند. سپس نتایج حاصل از ترکیب رنگی روشهای تبدیل فوریه زمان کوتاه مجزا و تبدیل فوریه زمان کوتاه واهمامیختی را با یکدیگر مقایسه کردند. (Karbalaali et al. (2017) با استفاده از تبدیل شیرلت^۵ مخروط-سازگار با پشتیبانی فشرده، مرز کانالهای موجود در داده لرزهای را شناسایی نمودند. سپس نتایج روش پیشنهادی خود را با عملگرهای شناسایی لبه متداول همچون کنی و سوبل مقایسه کردند. (Boustani et al., 2019b) با ادغام تبدیل کرولت⁶ و گرادیان مورفولوژی^۷ تصویر بهبود یافتهای از کانالهای موجود در داده لرزهای ارائه نمودند. آنها ضمن استخراج بیشینه محلی ضرایب کرولت در هر زیرباند، با اعمال گرادیان مورفولوژی با استفاده از اجزاء ساختاری به طول ها و جهت های مختلف، مرزهای کانالی را شناسایی کردند. Noori et al. (2019) ووش برازش فرآيند گاوسی^{^۸} را به منظور شناسايی گسلهای موجود در داده لرزهای معرفی نمودند. آنها لبههای موجود در داده لرزهای را بهعنوان ناهنجاریهای عمومی در نظر گرفتند؛ که منجر به برهمریختگی رفتار نرمال بازتابندههای لرزهای میشوند.

هر نشانگر لرزمای در مقایسه با نشانگرهای دیگر، بر اساس الگوریتمهای محاسباتی مربوط به خود، جزئیات متفاوتی از پدیدههای لرزمای را به تصویر میکشد. به منظور تلفیق جزئیات ثبت شده در نشانگرهای مختلف روشهای گوناگونی شامل سیستمهای فازی، خوشهبندی و طبقهبندی نظارتی^۴ و غیرنظارتی^{۱۰} توسط شبکههای عصبی مصنوعی مورد توجه قرار گرفته است. مردان و همکاران (۱۳۹۴) از الگوریتمهای آموزش غیرنظارتی جهت شناسایی رخسارههای کانالی تنگه هرمز در خلیج فارس استفاده نمودند. آنها از روش تحلیل مولفههای اصلی^{۱۱} برای کاهش ابعاد مجموعه نشانگرهای لرزهای به فضای دو بعدی نستفاده نمودند. سپس توانایی دو الگوریتم k-میانگین^{۱۲} و نقشههای نرزهای مورد بررسی قرار دادند. (2017) از Song et al رزهای رازهای از خوشهبندی فازی c-میانگین به منظور شناسایی غیرنظارتی رخسارههای لرزهای استفاده نمودند. در این روش، قرارگیری نقاط با ویژگیهای مشابه در کلاسهای موجود منجر به کاهش اثر حضور نوفه در ناحیه ناپیوستگی

10 Unsupervised

¹ Surface fitting

² Ant colony optimization

³ Gray-level

⁴ Gray-level covariance matrix

⁵ Shearlet transform

⁶ Curvelet transform

⁷ Morphological gradient

⁸Gaussian process regression 9 Supervised

¹¹ Principal component analysis

¹² k-mean

¹³ Self-organized maps

می شود. (Li et al. (2018) تحلیل رابطه خاکستری و ماشین بردار پشتیبان (را به منظور شناسایی کانالهای موجود در داده لرزهای متعلق به میدان نفتی داکینگ (Daqing) واقع در چین، مورد مطالعه قرار دادند. سلطانی و همکاران (۱۳۹۷) از یک روش اصلاح شده مبنیبر تحلیل مولفههای اصلی برای برجسته ساختن گسلها و شکستگیهای موجود در دادههای لرزهای با نسبت نشانک به نوفه پایین استفاده نمودند. آنها ضمن کاهش ابعاد نشانگرهای لرزهای به فضای دوبعدی، مولفههای اصلی با درصد واريانس بالا را بهعنوان پاسخ بهينه الگوريتم ثبت نمودند. لطفي و جواهريان (۱۳۹۸) از شبكه عصبي مصنوعي چندلايه با الگوريتم پسانتشار^۲ برای شناسایی مرزهای کانالهای موجود در داده لرزهای متعلق به بلوک هلندی دریای شمال استفاده نموند. آنها ضمن پردازش پس از برانبارش داده لرزهای، با ایجاد یک ترکیب غیرخطی از مجموعه نشانگرهای لرزهای کارآمد در شناسایی کانالها تصویر بهبود یافتهای از کانالهای لرزهای ارائه نمودند. در این مطالعه، از شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار برای شناسایی مرز کانالها روی برشهای زمانی از دادههای لرزهنگاری مصنوعی و واقعی حاوی کانال استفاده شده است. سپس نتایج حاصل از طرحواره پیشنهادی به عنوان یک روش یادگیری نظارتی با نتایج حاصل از روشهای یادگیری غیرنظارتی مانند تحلیل مولفههای اصلی و خوشهبندی k-میانگین به صورت کمی و کیفی مقایسه گردید.

۲- روش تحقیق

در سالهای اخیر مطالعه نشانگرهای لرزهای در تجزیه و تحلیل ناپیوستگیهای مرتبط با ساختارهای زمین شناسی، توسعه یافته است. نشانگر لرزهای، ابزاری است جهت شناسایی بهتر پدیدههای زمینشناسی، تعیین ریختشناسی و رخسارههای موجود در دادههای لرزهای. نشانگرهای لرزهای اغلب با ترکیب دادههای لرزهای مجاور ردلرزهها امکان تفسیر کانالها، گسلها و نیز تشخیص محیطهای رسوبی و تغییر شکلهای ساختمانی را برای مفسر فراهم میکنند. نشانگرهای لرزهای بسیاری با هدف شناسایی خودکار کانالهای مدفون معرفی شدند. در جدول ۱ به طور مختصر به معرفی نشانگرهای لرزهای استفاده شده در این مطالعه و کاربرد آنها در تفسیر دادههای لرزهای پرداخته شده است. به منظور بهبود نتایج حاصل از مطالعه پدیدههای زمین شناسی، تلفیق نشانگرهای لرزهای بر اساس شبکه عصبی مصنوعی، منطق فازی، یادگیریهای نظارتی و غیر نظارتی مفید قلمداد می شود (Zhao et al., 2015). شبکه عصبی مصنوعی، مجموعهای از واحدهای پردازشی است؛ که در یک ساختمان منظم، پیکرهبندی شده اند. در یک شبکه عصبی، دادهها از طریق لایه ورودی به شبکه تزریق و به وسیله واحدهای پردازشی به خروجی مطلوب تبدیل می شوند. در ادامه به طور مختصر به بررسی شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پس انتشار

1 Support vector machine

نشریه پژوهشهای ژئوفیزیک کاربردی، دوره۶، شماره ۲، ۱۳۹۹.

به عنوان یک روش یادگیری نظارتی و تحلیل مولفههای اصلی و خوشهبندی k-میانگین به عنوان روشهای یادگیری غیرنظارتی پرداخته شده است.

۱–۲- شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار

شبکه عصبی مصنوعی پرسپترون چندلایه اغلب از سه لایه ورودی، میانی و خروجی تشکیل شده است. دادهها از طریق لایه ورودی به شبکه تزریق میشوند. در این میان وظیفه مهم لایههای میانی که تعداد آنها به شرایط و نوع مسأله بستگی دارد، برقراری ارتباط بین لایههای ورودی و خروجی است. شبکه عصبی مصنوعی با شبیه سازی رفتار نرون های زیستی و با بهره گیری از قابلیت یادگیری در حل مسائل پیچیده از اهميت بالايي برخوردار است (منهاج، ١٣٨١). الگوريتم پسانتشار از جمله معروفترین روشهای آموزش با سرپرست در شبکههای عصبی پرسپترون چندلایه است که در آن پس از معرفی مجموعه ورودی، ضرایب ارتباطی بین واحدهای لایههای ورودی، میانی و خروجی، بهطور تصادفي تعيين مي گردد. مجموعه ورودي به صورت يک مجموع وزن دار به یک تابع فعالسازی غیرخطی معرفی می شود. وظیفه تابع فعالسازی تغییر مقیاس مجموع برای دستیابی به پاسخ بهینه میباشد. در صورت ناسازگاری پاسخ شبکه با پاسخ پیشبینی شده، پارامترهای داخلی مانند ورودیها و وزن گرهها مجددا بررسی و مقیاس بندی می شوند. در الگوریتم پسانتشار، تعریف ریاضی نرونهای بیولوژیکی^۳ را میتوان بهصورت یک تابع فعالسازی، A، در نظر گرفت که به یک تابع وزنی، W، اعمال می-شود (Brouwer and Huck, 2011):

$$W(y) = \sum_{i=1}^{L} w_{i} y_{i},$$
(1)

$$A(W) = \frac{2}{1 + exp(-W)} - 1,$$
 (7)

که y بردار ورودی و w بردار وزن گرهها میباشد. لازم به ذکر است A یک تابع سیگموئیدی کرندار، پیوسته، مشتق پذیر و صعودی است که پاسخ نهایی را با مقادیر بین صفر و یک ثبت می-کند. در آموزش با سرپرست، پرسپترون چندلایه در یک مجموعه داده متشکل از الگوهای ورودی و خروجیهای مرتبط آموزش داده می شود.

3 Biological neurons

² Back-propagation algorithm

کاربرد	توصيف	نشانگر لرزهای
شناسایی لکههای روشن، کانالها و گسلها	برابر با مجموع مربعات دامنه یک نمونه ردلرزه در یک پنجره زمانی معین میباشد (Chopra and Marfurt, 2005).	انرژی
شناسایی گسلها، کانالها، حفرههای کارستی و برشهای فرسایشی	میزان انحراف سطح از صاف بودن که ارتباط مستقیمی با مشتق مرتبه دوم دارد (Chopra and Marfurt, 2007).	انحنا
شناسایی کانالها، بررسی احتمال حضور هیدروکربن و طبقهبندی رخسارهها	بیانگر میانگین حسابی طیف بسامد داده لرزهای میباشد (Tingdahl and de Rooij, 2005).	بسامد میانگین
شناسایی کانالها، لایههای نازک و آشفتگیهای لرزهای، بررسی احتمال حضور هیدروکربن	تحلیل زمان-بسامد پیوستهای از داده لرزهای ارائه میدهد (Ombu and Ulori, 2017).	تجزيه طيفي
شناسایی گسلها، لبههای گنبد نمکی، کانالها و تغییرات جانبی رخسارههای لرزهای	همبستگی جانبی موجود در شکل موج لرزهای در امتداد یک رویداد بازتابی را محاسبه میکند (Chehrazi et al., 2013).	تشابه
شناسایی گسلها، ناپیوستگیهای زاویهدار، برشها و چینهای مواج	برابر با مجموع مربعات شیب در راستای خط گیرنده و شیب در راستای خط چشمه میباشد (Chehrazi et al., 2013).	شيب قطبى
تشخیص لایههای سخت از نرم و شناسایی رویدادهای زمینشناسی متخلخل	از تلفیق دادههای لرزهنگاری و نمودارهای چاهپیمایی بر اساس مدلسازی معکوس بدست میآید (Berge et al., 2002).	مقاومت صوتى
شناسایی رخسارههای لرزهای، کانالها و حفرههای کارستی	مشخصههای بافتی داده لرزهای را بر اساس ماتریس ه _م رویداد سطح خاکستری استخراج میکند (Mohebian et al., 2018).	نشانگر بافتی
شناسایی گسلها، لبههای گنبد نمکی، کانالها و تغییرات جانبی رخسارههای لرزهای	شباهت بین ردلرزههای مجاور را با مقیاسی بین صفر و یک محاسبه میکند (Hashemi Gazar et al., 2011).	همدوسى

جدول ۱: نشانگرهای لرزهای متعارف ورودی شبکه عصبی

الگوریتم پسانتشار با تنظیم وزن گرهها، خطای بین خروجی پیش-بینی شده و خروجی واقعی را به حداقل مقدار خود می ساند. اگر مجموع مربعات سیگنال خطا (مجذور اختلاف مقادیر محاسبه شده ستادهها^۱ و خروجی واقعی) بیشتر از مقدار آستانه باشد، الگوریتم با بازگشت به عقب و تغییر ضرایب ارتباطی، محاسبات را تکرار می کند؛ در غیر اینصورت الگوریتم متوقف می گردد (Brouwer and Huck, 2011). میانگین مربعات خطا و ضرایب وزنی جدید در هر تکرار به ترتیب طبق روابط (۳) و (۴) محاسبه می شوند (Beale et al., 2010):

$$\mathbf{MSE} = \frac{1}{Q} \sum_{k=1}^{Q} e(k)^2 = \frac{1}{Q} \sum_{k=1}^{Q} (t(k) - a(k))^2, \qquad (\texttt{``})$$

$$W(k+1) = W(k) - \alpha \frac{\partial \mathbf{MSE}}{\partial W}, \qquad (f)$$

که Q تعداد زوج دادههای یادگیری، t خروجی مطلوب شبکه عصبی، a خروجی لایه میانی و α نرخ یادگیری شبکه عصبی می اشد. در شکل ۱ طرحواره یادگیری شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پس انتشار نشان داده شده است.

شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار، دامنه کاربردی وسیعی در زمینه پردازش تصاویر رقومی دارد. از آنجا که دادههای لرزهنگاری بهعنوان تصاویر زمانی از زیر سطح زمین برداشت میشوند، تمرکز بر روشهای مرتبط با پردازش تصویر میتواند امری موثر در پردازش و تفسیر دادههای لرزهنگاری در اکتشافات هیدروکربنی باشد.

به منظور شناسایی رویدادهای زمین شناسی خاص بهتر است از چند نشانگر لرزهای مختلف با الگوریتم محاسباتی متفاوت استفاده شود؛ چرا که یک پدیده خاص لزوما در همه نشانگرها ظاهر نمی شود. در این مطالعه، ضمن تلفیق غیرخطی نشانگرهای لرزهای بر مبنای شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار، خروجی مطلوبی تحت عنوان مكعب احتمال كانال نمايش داده مى شود. أموزش شبكه عصبی بر اساس مقادیر نشانگرهای لرزهای در مجموعه نقاط تفسیر شده توسط مفسر بر اساس نتایج خوشهبندی k-میانگین و مطالعه نشانگرهای لرزهای صورت می گیرد. مجموعه نشانگرهای لرزهای متعارف ورودی شامل انحنا، انرژی، بسامد میانگین، تشابه، تجزیه طیفی، شیب قطبی، ماتریس همرویداد سطح خاکستری، مقاومت صوتی، همدوسی و همدوسی بر مبنای ماتریس همرویداد خاکستری با پارامترهای بهینه ارائه شده در جدول ۲ میباشد. با نوسان اختلاف بین نتایج حاصل از شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار با خروجی واقعی و خطای طبقهبندی کمول یک مقدار کمینه ثابت، توقف فرآیند آموزش خروجي بهينه را ثبت ميكند.

2 Misclassification error

¹ Dependent variables



نشریه پژوهشهای ژئوفیزیک کاربردی، دوره۶، شماره ۲، ۱۳۹۹.

۲-۲- تحلیل مولفههای اصلی

تحلیل مولفههای اصلی، یک روش آماری است که با استفاده از یک تبدیل خطی دادهها را از فضای چند طیفی به فضای بردارهای ویژه تصویر می کند (Gonzalez et al., 2004). الگوریتم تحلیل مولفههای اصلی منجر به کاهش ابعاد مجموعه دادههایی می شود؛ که تعداد زیادی از متغیرهای آنها وابسته هستند. مولفه اول اصلی بدست آمده از تحلیل مولفههای اصلی، همبستگی بالایی با تصاویر چند طیفی اولیه دارد؛ در واقع مولفه اول اصلی اطلاعات مشترک بین باندهای طیفی می باشد (Gonzalez et al., 2004).

شکل ۱: طرحواره شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم
پسانتشار.

أنها	. به	مربوط	تنظيمات	عي و	مصنو	عصبى	شبكه	ورودى	متعارف	،ای	لرزد	ناي ا	نشانگره	۲:	دول	ج
------	------	-------	---------	------	------	------	------	-------	--------	-----	------	-------	---------	----	-----	---

تنظيمات	موقعيت جانبى	پنجره زمانی	نشانگر لرزهای
استفاده از فیلتر میانه بهعنوان ورودی	-	[-24,24]	انرژی
پیروی از مکعب هدایت شیب	اندازه گام در راستای مکان 3	-	انحناي بيشينه منفى
استفاده از تغییر دهنده هنینگ	-	[-24,24]	بسامد میانگین
استفاده از فیلتر میانه بهعنوان ورودی، فرکانس،های خروجی 30. 45 و 60 هرتز	-	[-24,24]	تجزيه طيفي
پیروی از مکعب هدایت شیب، ثبت تشابه کمینه بهعنوان خروجی	اندازه گام در راستای مکان 1 مقایسه تمامی ردلرزههای مجاور ردلرزه مرکزی	[-24,24]	تشابه
استفاده از مکعب هدایت شیب بهعنوان ورودی	-	-	شیب قطبی
استفاده از نمودار مقاومت صوتی نسبی بهعنوان ورودی، استفاده از روش میانگین گیری به منظور نمونه گیری مجدد	-	-	مقاومت صوتى
پیروی از مکعب هدایت شیب، ثبت تباین بافت لرزهای بهعنوان خروجی	اندازه گام در راستای مکان 3	[-12,12]	نشانگر بافتی
پیروی از مکعب هدایت شیب	اندازه گام در راستای مکان 1 مقایسه تمامی ردلرزههای مجاور ردلرزه مرکزی	[-24,24]	همدوسى
پیروی از مکعب هدایت شیب، استفاده از نشانگر بافتی بهعنوان ورودی	اندازه گام در راستای مکان 1 مقایسه تمامی ردلرزههای مجاور ردلرزه مرکزی	[-24,24]	همدوسی بر مبنای ماتریس همرویداد سطح خاکستری

داده ها نقش مولفه های اصلی را در نتیجه نهایی پررنگتر نمود. اگر (مود. اگر نمود. اگر $X = (X_1, X_2, ..., X_p)'$ $(\lambda_1 > \lambda_2 > ... > \lambda_p > 0$ که $0 = (\lambda_1, \lambda_2, ..., \lambda_p)'$ $(\lambda_1 > \lambda_2 > ... > \lambda_p > 0$ مقادیر ویژه $\lambda_1, \lambda_2, ..., \lambda_p$ باشد (به گونه ای که $0 = (\lambda_1 - \lambda_2, ..., \lambda_p)$ ($\lambda_1 > \lambda_2 > ... > \lambda_p > 0$ مقادیر ویژه مهای اصلی باشد (به گونه ای که $0 = (\lambda_1 - \lambda_2, ..., \lambda_p)$ $(\lambda_1 > \lambda_2 > ... > \lambda_p > 0$ می شوند (Pearson, 1901) $Y_1 = a_{11}X_1 + a_{21}X_2 + ... + a_{p1}X_p,$ $Y_2 = a_{12}X_1 + a_{22}X_2 + ... + a_{p2}X_p,$ \vdots $Y_p = a_{1p}X_1 + a_{2p}X_2 + ... + a_{pp}X_p,$ این روش ضمن محاسبه ماتریس هموردی مجموعه دادههای ورودی نرمال شده، تصویر دادهها را روی بردارهای ویژه متعامد به هم بررسی میکند. در سیستم مختصات جدید واریانس دادهها در جهات مختلف محاسبه میشود. اولین محور دستگاه مختصات جدید در راستای بزرگترین واریانس، دومین محور در راستای بزرگترین واریانس بعدی و به همین ترتیب آخرین محور در راستای کوچکترین واریانس قرار میگیرد. با تخصیص ضرایب بزرگتر به مولفههای موثرتر و تخصیص ضرایب کوچکتر به مولفههای کم اهمیتتر، میتوان ضمن کاهش ابعاد مجموعه

که ويژه عمود بر $\lambda_1, \lambda_2, ..., \lambda_p$ بردارهای يکه ويژه عمود بر $a_1, a_2, ..., a_n$ می
باشند. لازم به ذکر است که بین واریانس مولفههای اصلی رابطه برقرار است. بر این اساس، میتوان $Var(Y_1) \ge Var(Y_2) \ge \dots \ge Var(Y_n)$ در مطالعه نشانگرهای لرزهای نوفه تصادفی را با حذف مولفههای اصلی آخر تضعیف و رویدادهای لرزهای را با تقویت چند مولفه اصلی اول، با تفکیک پذیری بالاتری تصویر نمود. در شکل ۲ طرحواره اجرای این الگوریتم مشاهده می شود. مهم ترین کاربرد این روش، مطالعه نشانگرهای لرزهای چندگانه، شناسایی رویدادهای زمینشناسی، کاهش ابعاد دادههای لرزهای، تضعیف نوفه و کاهش افزونگی اطلاعات میباشد (Wu and Fomel, 2018). در این مطالعه، روش تحلیل مولفه های اصلی استاندارد به منظور بهبود نتایج شناسایی کانال مورد مطالعه، بر روی نشانگرهای لرزهای ایجاد شده اعمال گردید. از آنجا که از ۱۰ نشانگر لرزهای با پارامترهای بهینه ارائه شده در جدول ۲ برای شناسایی کانالها استفاده شده است، ماتریس ورودی الگوریتم تحلیل مولفههای اصلی ماتریسی ۱۰ بعدی میباشد. پس از محاسبه ماتریس هموردی ماتریس ورودی و مقادیر ویژه هر یک از ابعاد آن، مولفههای اصلی مطابق رابطه (۵) محاسبه شد. در این روش، بخش عمده اطلاعات موجود در باندهای ورودی، در اولین مولفه اصلی ثبت می شود. در پایان، به منظور نمایش جزئیات دقیق تری از رويداد كانالي مورد مطالعه، تركيب رنگي قرمز-سبز-آبي مولفههاي اصلي اول، دوم و سوم بهعنوان خروجی مطلوب ثبت گردید. لازم به ذکر است که مولفههای اول، دوم و سوم به ترتیب با رنگهای قرمز، سبز و آبی نمایش داده شده اند.



شکل ۲: طرحواره استخراج مولفههای اصلی مجموعه نشانگرهای لرزهای.

۲-۳- خوشەبندى k-ميانگين

الگوریتم k-میانگین (McQueen, 1967) یکی از پرکاربردترین الگوریتمهای خوشهبندی است که به منظور خوشهبندی دادههای عددی

طراحی شده است. این الگوریتم میتواند برای خوشهبندی رنگهای یک تصویر مورد استفاده قرار گیرد. چنانچه هر یک از پیکسلهای موجود در یک تصویر رنگی بهعنوان برداری متشکل از ویژگیهای رنگی آن پیکسل در نظر گرفته شود، روش k-میانگین این بردارهای رنگی را از روی مقادیر شباهت به k خوشه تقسیم میکند. هر خوشه دارای یک مرکز به نام میانگین میباشد و هر نمونه داده به یک خوشه نسبت داده میشود؛ به گونهای که آن داده کمترین فاصله را تا مرکز آن خوشه داشته باشد. در این الگوریتم ابتدا به تعداد خوشههای مورد نیاز، نقاطی بهصورت تصادفی مراکز تعریف شده، به یکی از این خوشهها نسبت داده میشود. در مراکز تعریف شده، به یکی از این خوشهها نسبت داده می مود. در محاسبه میشود (2015). این روند تا زمانی ادامه میابد؛ که مجموع مربع اختلاف از میانگین (واریانس) برای هر خوشه حداقل شود (Kriegel et al., 2017).

$$\arg\min_{S} \sum_{i=1}^{k} \sum_{\mathbf{x} \in S_{i}} \left\| \mathbf{x} - \boldsymbol{\mu}_{i} \right\|^{2} = \arg\min_{S} \sum_{i=1}^{k} \left| S_{i} \right| Var(S_{i}), \tag{9}$$

که x مجموعه پیکسلها، μ_i مرکز خوشه i ام و S_i خوشه i ام میباشد. لازم به ذکر است که این الگوریتم از معیار تابع فاصله اقلیدسی به منظور اندازه گیری تشابه بین نمونه دادهها و مراکز خوشهها استفاده میکند. در شکل ۳ طرحواره اجرای این الگوریتم قابل مشاهده است.



شکل ۳: طرحواره خوشهبندی رخسارههای لرزهای بر اساس الگوریتم هیانگین.

در این مطالعه، داده لرزهای به عنوان ورودی به الگوریتم خوشهبندی

k-میانگین با ۲ خوشه معرفی گردید. سپس به منظور بهبود نتایج حاصل از یادگیری غیرنظارتی، ترکیب رنگی مولفههای اصلی اول، دوم و سوم ورودی الگوریتم خوشهبندی k-میانگین قرار گرفت. در نهایت، نتیجه فرآیند پس از اجرای ۲ تکرار همگرا گردید. لازم به ذکر است که از معیار کالینسکی-هارباسز (Calinski-Harabasz) به منظور تعیین تعداد خوشههای بهینه استفاده شده است.

۳- مثالها

به منظور ارزیابی نحوه عملکرد شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار از یک داده لرزهنگاری مصنوعی و یک داده لرزهنگاری واقعی متعلق به بلوک هلندی دریای شمال حاوی کانال استفاده شده است. عملکرد روش مورد مطالعه در خصوص دادههای لرزهای مصنوعی و واقعی، در مقایسه با خوشهبندی k-میانگین و تحلیل مولفههای اصلی به صورت کمی و کیفی مورد بررسی قرار گرفت. در شکل ۴ طرحواره مراحل شناسایی مرز کانالها ارائه شده است.



شکل ۴: طرحواره مراحل شناسایی نیمهخودکار و استخراج پیکره کانالهای مدفون.

۳-۱- داده لرزهای مصنوعی

برای بررسی عملکرد طرحواره پیشنهادی بر داده مصنوعی، یک مدل زمین شناسی در بردارنده دو کانال سینوسی در نظر گرفته شد. سرعت لایه ها بین ۲۰۰۰ تا ۲۰۰۰ متر بر ثانیه متغیر است. چگالی مرتبط با هر لایه بر اساس سرعت آن لایه توسط رابطه گاردنر محاسبه شد. در ادامه ضمن همامیخت ضرایب بازتاب بدست آمده از مقاومت صوتی با موجک ریکر با فرکانس بیشینه ۳۰ هرتز، یک مدل مصنوعی حاوی کانال ایجاد شد. در شکل ۵-الف برش زمانی ۵۴۰ میلی ثانیه از داده لرزهای مصنوعی اولیه حاوی کانال بدون حضور نوفه قابل مشاهده است. در شکل ۵-ب موقعیت فضایی نقطه نمونههای تشکیل دهنده داده لرزهای مصنوعی اولیه می شود نقطه نمونههای تشکیل دهنده داده لرزهای مصنوعی اولیه در برش زمانی ۵۴۰ میلی ثانیه نشان داده شده است. همانطور که مشاهده می شود نقطه نمونههای تشکیل دهنده داده لرزهای مصنوعی اولیه در مرش زمانی ۵۴۰ میلی ثانیه به دو دسته تقسیم می شوند. مجموعه نقاط محتمل به کانال با رنگ زرد و مجموعه نقاط غیر کانالی با رنگ آبی نشان داده شده است.

در شکلهای ۶-الف-۶-د به ترتیب نتایج شبکه عصبی مصنوعی چندلایه با الگوریتم پسانتشار، مولفه اصلی اول حاصل از تحلیل مولفه های اصلی، خوشه بندی k-میانگین و ترکیب مولفه اصلی اول حاصل از تحلیل مولفههای اصلی و خوشهبندی k-میانگین دیده می شود. همانطور که مشاهده میشود، در غیاب نوفه تصادفی، هر چهار روش مورد مطالعه، با عملکرد مشابه در شناسایی کانالها موفق عمل کرده اند. در شکلهای ۷-الف و ۷-ب به ترتیب داده لرزهای مصنوعی حاوی کانال بدون حضور نوفه و داده لرزهای مصنوعی حاوی کانال با نسبت نشانک به نوفه ۲ بهصورت سه بعدی نمایش داده شده است. در شکلهای ۷-ج و ۷-د به ترتیب طیف دامنه دادههای نمایش داده شده در ۷-الف و ۷-ب قابل مشاهده است. همان طور که مشاهده می شود، حضور نوفه تصادفی باعث تضعیف فرکانس های موجود در محدوده لرزهنگاری و تقویت فرکانسهای خارج از محدوده لرزهنگاری شده است. از فیلتر گاوسی با انحراف معيار ۲ به منظور بهبود كيفيت داده لرزهاى مصنوعي استفاده شده است. در شکلهای ۸-الف و ۸-ب به ترتیب داده لرزهای مصنوعی اولیه و داده لرزهای مصنوعی بهبود یافته در عمود به خط ۴۳۰ همراه با حیطه فوریه دو بعدی آنها (شکلهای ۸-ب و ۸-د) قابل مشاهده است.

1 Crossline

لطفي و جواهريان، شناسايي و استخراج رخسارههاي كانالي با استفاده از شبكه عصبي پرسپترون چندلايه با الگوريتم پسانتشار و فيلتر ...، صفحات 307 -330.



شکل ۵: (الف) داده لرزهای مصنوعی اولیه حاوی کانال بدون حضور نوفه در برش زمانی ۵۴۰ میلی ثانیه، (ب) موقعیت فضایی نقطه نمونههای تشکیل دهنده داده لرزهای در برش زمانی ۵۴۰ میلی ثانیه حاوی کانال که به دو دسته تقسیم شده اند. مجموعه نقاط زرد رنگ معرف نقاط کانالی و مجموعه نقاط آبی رنگ معرف نقاط غیر کانالی میباشد.



شکل ۶: برش زمانی ۵۴۰ میلی ثانیه حاصل از اعمال روشهای یادگیری نظارتی و غیرنظارتی بر روی داده لرزهای مصنوعی حاوی کانال بدون حضور نوفه: (الف) نشانگر احتمال کانال حاصل از شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار، (ب) تحلیل مولفههای اصلی (مولفه اصلی اول)، (ج) خوشهبندی k-میانگین، (د) ترکیب روشهای تحلیل مولفههای اصلی و خوشهبندی k-میانگین.

در شکل ۹-الف داده لرزهای بهبود یافته در برش زمانی ۵۴۰ میلی ثانیه همراه با موقعیت فضایی نقطه نمونههای تشکیل دهنده آن (شکل ۹-ب) نشان داده شده است. در ادامه به منظور آموزش شبکه عصبی مصنوعی، لازم است نقطه نمونههای تشکیل دهنده داده لرزهای دستهبندی گردد. برای این منظور داده لرزهای مصنوعی بهبود یافته ورودی الگوریتم کالینسکی-هارباسز قرار گرفت. شاخص اعتبارسنجی

کالینسکی-هارباسز مطابق رابطه زیر از مقادیر پراکندگی بین خوشهای و مقادیر پراکندگی بین خوشهای و مقادیر پراکندگی درون خوشهای برای تعیین تعداد خوشههای بهینه در یک مجموعه داده استفاده می کند (Cengizler and Un, 2017):

$$CH_{k} = \frac{tr(\mathbf{B}_{k})/(k-1)}{tr(\mathbf{W}_{k})/(n-1)},$$
(Y)

که $tr(B_k)$ مجموع قطر ماتریس مجموع مربعات بین خوشهها،

مجموع قطر ماتریس مجموع مربعات درون خوشهای، k تعداد $tr(W_k)$ خوشهها و n تعداد مجموعه دادهها است. در شکل ۹-ج مقادیر محاسبه شده شاخص کالینسکی-هاراباسز برای ۲ تا ۱۰ خوشه در قالب یک نمودار ستونی نمایش داده شده است. مقادیر بزرگتر شاخص کالینسکی-هاراباسز نمایانگر خوشهبندی مناسب تر است. از این رو، تعداد خوشههای بهینه بر اساس شاخص کالینسکی-هاراباسز ۲ برآورد شده است. در شکل ۹-د نتایج حاصل از اعمال خوشهبندی k-میانگین با ۲ خوشه بهینه به داده لرزهای اولیه در برش زمانی ۵۴۰ میلی ثانیه همراه با موقعیت فضایی نقطه نمونههای تشکیل دهنده تصویر ناحیهبندی شده (شکل ۹-ه) نشان داده شده است. همان طور که از شکل پیداست، داده لرزهای به دو دسته نواحی محتمل به کانال و نواحی پسزمینه تقسیم میشود. در ادامه بر اساس نتایج حاصل از خوشهبندی بهینه و مطالعه نشانگرهای لرزهای، مجموعه نقاط آموزشی به شبکه عصبی مصنوعی معرفی شد. در شکلهای ۱۰-الف و ۱۰-ب برش زمانی ۵۴۰ میلیثانیه از داده لرزهای مصنوعی با نسبت نشانک به نوفه ۲، قبل و بعد از اعمال فیلتر گاوسی، قابل مشاهده است. در شکلهای ۱۰–ج-۱۰-و به ترتیب نتایج شبکه عصبی مصنوعی چندلایه با الگوریتم پسانتشار، مولفه اصلی اول حاصل از تحلیل مولفه های اصلی، خوشه بندی k-میانگین و ترکیب مولفه اصلی اول حاصل از تحلیل مولفههای اصلی و خوشهبندی k-میانگین دیده می شود. همان گونه که مشاهده می شود خوشه بندی k-میانگین به تنهایی عملکرد ضعیفتری از خود نشان داده است. ترکیب روشهای تحلیل مولفههای اصلی و خوشهبندی k-میانگین منجر به بهبود نتایج شناسایی لبه شده است. شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار در مقایسه با سایر روشها عملکرد مناسبی از خود نشان داده است. لازم به



ذکر است که ترکیب روشهای غیرنظارتی خوشهبندی k-میانگین و تحلیل مولفههای اصلی نتایجی نزدیک به نتایج شبکه عصبی مصنوعی پرسپترون چندلایه فراهم آورده است.

در شکلهای ۱۱–الف–۱۱–د مقایسه کمی طرحواره پیشنهادی و نتایج حاصل از تحلیل مولفههای اصلی و خوشهبندی k-میانگین و ترکیب آنها با استفاده از آزمایش دستهبندی دودویی شامل دقت (Precision)، حساسیت (Sensitivity)، ویژگی (Specificity) و معیار فیشر (-F cmasure) برای داده لرزهای مصنوعی بدون نوفه و داده لرزهای مصنوعی با نسبت نشانک به نوفه ۲ نشان داده شده است. همان گونه که در شکل پیداست طرحواره پیشنهادی در حضور نوفه نسبت به روشهای غیرنظارتی در شناسایی مکان دقیق لبهها و شناسایی کمتر نقاط غیر لبه بهعنوان لبه موفق تر بوده است. معیارهای شناسایی لبه مذکور مطابق زیر تعریف شده اند (Karbalaali et al., 2017):

$Precision = \frac{TP}{TP_{1}, TP_{2}},$	
(IP + FP) TP	
$Sensitivity = \frac{1}{(TP + FN)},$	
Specificity = $\frac{TN}{(TP + FN)}$,	(λ)
(17 ± 170)	
$r = measure = \frac{1}{\frac{1}{\frac{1}{\frac{1}{\frac{1}{\frac{1}{\frac{1}{\frac{1}$	

که FP، TN، TP و FN به ترتیب موارد مثبت حقیقی، موارد منفی حقیقی، موارد منفی حقیقی، موارد منفی کاذب در نتایج مربوط به شناسایی لبه میباشند.

lime (ms)

شکل ۷: (الف) مکعب داده لرزهای مصنوعی حاوی کانال بدون نوفه، (ب) مکعب داده لرزهای مصنوعی حاوی کانال با نسبت نشانک به نوفه ۲، (ج و د) طیف دامنه (الف و ب). حضور نوفه باعث تضعیف فرکانسهای محدوده لرزهنگاری و تقویت فرکانسهای خارج از محدوده لرزهنگاری شده است.

لطفي و جواهريان، شناسايي و استخراج رخسارههاي كانالي با استفاده از شبكه عصبي پرسپترون چندلايه با الكوريتم پسانتشار و فيلتر ...، صفحات 307-330.



شکل ۸: (الف) داده لرزهای مصنوعی در عمود به خط ۴۳۰، (ب) حیطه فوریه دو بعدی (الف)، (ج) فیلتر گاوسی در عمود به خط ۴۳۰، (د) حیطه فوریه دوبعدی (ج). به منظور بررسی نحوه عملکرد فیلتر گاوسی اعمالی، از تبدیل حیطه فوریه دو بعدی استفاده شده است. فیلتر گاوسی توانسته است نوفه پسزمینه موجود در داده لرزهای مورد مطالعه را تضعیف نماید.



نشریه پژوهشهای ژئوفیزیک کاربردی، دوره ، شماره ، ۱۳۹۹.



شکل ۹: (الف) داده لرزهای مصنوعی حاوی رویداد کانالی بهبود یافته در برش زمانی ۵۴۰ میلی ثانیه، (ب) موقعیت فضایی نقطه نمونههای تشکیل دهنده (الف)، (ج) مقادیر شاخص کالینسکی–هارباسز برای تعداد خوشههای ۲ تا ۱۰ با ورودی داده لرزهای مصنوعی با نسبت نشانک به نوفه ۲، (د) نتایج حاصل از ناحیهبندی تصویر لرزهای (الف) توسط الگوریتم خوشهبندی k–میانگین بر اساس تعداد خوشههای بهینه مشخص شده در (ب)، (ه) موقعیت فضایی نقطه نمونههای تشکیل دهنده (د). مجموعه نقاط به رنگ آبی تیره معرف نقاط کانالی و مجموعه نقاط به رنگ آبی روشن معرف نقاط غیر کانالی میباشد.



لطفي و جواهريان، شناسايي و استخراج رخسارههاي كانالي با استفاده از شبكه عصبي پرسپترون چندلايه با الگوريتم پسانتشار و فيلتر ...، صفحات 307 -330.



شکل ۱۰: برش زمانی ۵۴۰ میلیثانیه از (الف) داده لرزهای اولیه با نسبت نشانک به نوفه ۲، (ب) داده لرزهای پالایش شده توسط فیلتر گاوسی، (ج) نشانگر احتمال کانال حاصل از شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار، (د) تحلیل مولفههای اصلی (مولفه اصلی اول)، (ه) خوشهبندی k-میانگین، (و) ترکیب روشهای تحلیل مولفههای اصلی و خوشهبندی k-میانگین.



شکل ۱۱: مقایسه کمّی نتایج حاصل از روش شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار با نتایج حاصل از روشهای تحلیل مولفههای اصلی، k-میانگین و ترکیب آنها با استفاده از آزمایش دستهبندی دودویی برای داده لرزهای مصنوعی بدون نوفه و داده مصنوعی با نسبت سیگنال به نوفه ۲: (الف) دقت، (ب) حساسیت، (ج) ویژگی و (د) معیار فیشر.

۳-۲- داده لرزهای واقعی

برای بررسی عملکرد شبکه عصبی مصنوعی تحت نظارت با الگوریتم پسانتشار در شناسایی رخسارههای کانالی، از یک داده لرزهای سه بعدی استفاده شده است. داده لرزهای مورد مطالعه در سال ۱۹۸۷ به منظور

اکتشاف ذخایر هیدروکربنی متعلق به طبقات ژوراسیک فوقانی-کرتاسه پایینی از بلوک هلندی دریای شمال برداشت شده است. داده لرزهای توزیعی از زمان و مکان میباشد بطوری که بازه زمانی ۴ میلیثانیه و بازه مکانی ۲۵ متر (بهصورت خطوط چشمه و خطوط گیرنده) است. مساحت

ناحیه برداشت ۳۸۶/۹۳ کیلومتر مربع، محدوده خطوط چشمه ۱۰۰-۷۵۰، محدوده خطوط گیرنده ۳۰۰–۱۲۵۰ و طول رکورد زمانی ۱۸۴۸ میلی ثانیه می باشد. حجم کوچکی از داده لرزهای دربردارنده پدیده مورد نظر با محدوده خطوط چشمه ۴۰۰–۶۵۰، محدوده خطوط گیرنده ۱۰۰-۴۰۰ و محدوده زمانی ۱۲۰۰–۹۰۰ میلی ثانیه انتخاب شده است.

چارچوب ساختمانی حاکم بر دریای شمال عمدتا از زمین ساخت کششی حاصل از شکل گیری حوضه های کافتی نشأت گرفته است (Pegrum and Spencer, 1990). بلوک مورد مطالعه از نظر زمین شناسی عمدتا بالای فروافتاد گی مرکزی هلند، بهعنوان یک حوضه بزرگ کافتی کیمرین قرار گرفته است (De jager, 2007). در شکل ۱۲ تصویری از موقعیت جغرافیایی داده مورد مطالعه قابل مشاهده است.



شکل ۱۲: موقعیت جغرافیایی منطقه مورد مطالعه همراه با خطوط برداشت آن. محدوده بلوک مخزنی F3 با مستطیل قرمز مشخص شده است.

لایهبندی سیگموئیدی بزرگ مقیاس موجود در بخش فوقانی داده لرزهای متشکل از رسوبات یک سیستم رودخانهای-دلتایی است. در دوره زمانی پلیوسن شرایط دلتایی حاکم بر محیط رودخانهای و منطقه جزر و مدی، عملیات زهکشی از سپرهای بالتیک و فنواسکاندیناوی را به همراه داشته است (Sales, 1992). این چرخه از یک ساختار کلینوفرم (یک عارضه زیرآبی همانند شیب قاره اقیانوسها یا لایههای جلویی یک دلتا) کلاسیک پیشرونده به سمت حوضه تشکیل شده است. شواهد نشان

نشریه پژوهشهای ژئوفیزیک کاربردی، دوره ، شماره ، ۱۳۹۹.

میدهد که این بخش که شامل سازندهای گروه گچی، دریای شمال پایینی و دریای شمال میانی میباشد، از سه سکانس رده سوم تشکیل شده است. این سکانسها به دنبال شکل گیری یک سیستم بزرگ مقیاس رودخانهای-دلتایی حاکم بر شمال غربی اروپا در اواخر دوران سنوزوئیک، تشکیل شده اند. همزمان با آغاز شکل گیری این سیستم زهکشی در طول الیگوسن، سپر اسکاندیناوی در حال بالاآمدگی بوده است. بر اثر نفوذ بالای رسوبات ناشی از این بالاآمدگی در اواخر میوسن، یک تفاوت بار رسوبی در سراسر منطقه ایجاد شده است. در نتیجه، نمک مدفون پرمین ضمن حرکت به سمت افقهای فوقانی منجر به شکل گیری چندین ناپیوستگی محلی زیر خط گنبد نمکی شده است (Ishak et al., 2018). در شکل ۱۳ تصویری از ستون چینهشناسی مربوط به منطقه مورد مطالعه نمایش داده شده است.



شکل ۱۳: ستون چینهشناسی منطقه مورد مطالعه (Ishak et al., 2018)

در ابتدا یک مکعب هدایت شیب از داده لرزهای که دربردارنده شیب و آزیموت محلی رخدادهای لرزهای در هر نقطه نمونه است، تهیه گردید. سپس هموارسازی داده لرزهای با اعمال فیلتر میانه ⁽ صورت گرفت. فیلتر میانه ضمن پیروی از شیب رخدادهای لرزهای بر مبنای مکعب هدایت شیب با جایگزینی مقدار میانه دامنه ردلرزههای مجاور هر نقطه داده، نوفه تصادفی موجود در داده لرزهای را تضعیف میکند. در شکلهای ۱۴-الف

و ۱۴-ج به ترتیب داده لرزهای اولیه و داده لرزهای بهبود یافته در به خط^۱ ۳۳۰ همراه با حیطه فوریه دو بعدی آنها (شکلهای ۱۴-ب و ۱۴-د) قابل مشاهده است.

در ادامه به منظور شناسایی پدیده چینهشناسی مورد نظر و تمایز سیگنالهای لرزهای مربوط به آن از سیگنالهای نامطلوب، مجموعهای از نشانگرهای لرزهای متعارف کارآمد در شناسایی کانالها با پارامترهای بهینه شامل نشانگرهای انحنا، انرژی، بسامد میانگین، تجزیه طیفی، تشابه، شیب قطبی، ماتریس همرویداد سطح خاکستری، مقاومت صوتی، همدوسی و همدوسی بر مبنای ماتریس همرویداد سطح خاکستری به عنوان ورودی شبکه عصبی تهیه گردید. علاوه بر این، از نشانگر همدوسی بر مبنای ماتریس همرویداد سطح خاکستری به منظور بهبود نتایج شناسایی کانال استفاده گردید. در شکل ۱۵ داده لرزهای اولیه، داده لرزهای پردازش پس از برانبارش شده و برخی از نشانگرهای لرزهای ورودی شبکه عصبی از جمله مقاومت صوتی، همدوسی بر مبنای ماتریس همرویداد سطح خاکستری، تجزیه طیفی و شباهت در برش زمانی ۱۰۲۴ میلی ثانیه مشاهده می شود. نشانگر مقاومت صوتی (شکل ۱۵-ج) در مقایسه با سایر نشانگرهای لرزهای در شناسایی مرزهای کانال مورد مطالعه موفقیت کمتری داشته است. همدوسی بر مبنای ماتریس همرویداد سطح خاکستری (شکل ۱۵-د) در مقایسه با نشانگر تشابه (شکل ۱۵-و) ضمن تاثیرپذیری بیشتر از لبههای کاذب ناشی از حضور نوفه، مرزهای کانالی را با دقت بالاتری ثبت نموده است. نشانگر تجزیه طيفی (شکل ۱۵-ه) با نمایش ترکیب رنگی قرمز-سبز-آبی ضمن تاثیر پذیری کمتر از نوفه پسزمینه، لبههای مربوط به کانال مورد مطالعه را با دقت کمتری شناسایی کرده است. لازم به ذکر است که رنگ قرمز نماینده فرکانس ۳۰ هرتز، رنگ سبز نماینده فرکانس ۴۵ هرتز و رنگ آبی نماینده فرکانس ۶۰ هرتز میباشد.

در شکل ۱۶-الف داده لرزهای بهبود یافته با محتوای فرکانسی بالاتر از ۵۰ هرتز در برش زمانی ۱۰۲۴ میلی ثانیه همراه با موقعیت فضایی نقطه نمونههای تشکیل دهنده آن (شکل ۱۶–ب) نشان داده شده است. در ادامه به منظور تعیین تعداد کلاسهای موجود در داده لرزهای برای آموزش شبکه عصبی مصنوعی، لازم است نقطه نمونههای تشکیل دهنده داده لرزهای دستهبندی گردد. برای این منظور داده لرزهای مصنوعی بهبود یافته با محتوای فرکانسی بالاتر از ۵۰ هرتز که در آن رویدادهای لرزهای با وضوح بالاتری نمایش داده می شوند، ورودی الگوریتم کالینسکی-هارباسز (Calinski-Harabasz) قرار گرفت. در شکل ۱۶-چ مقادیر محاسبه شده شاخص کالینسکی-هاراباسز برای ۲ تا ۱۰ خوشه در قالب یک نمودار ستونی نمایش داده شده است. مقادیر بزرگتر شاخص کالینسکی-هارباسز نمایانگر خوشهبندی مناسب تر است. از این رو، تعداد خوشههای بهینه بر اساس شاخص کالینسکی-هاراباسز ۲ برآورد شده است. در شکل ۱۶–د نتایج حاصل از اعمال خوشهبندی ۲-میانگین با ۲

همانطور که از شکل پیداست داده لرزهای به دو دسته نواحی محتمل به کانال و نواحی پس زمینه تقسیم می شود. البته لازم به ذکر است که کلیه نقاطی که از نظر شدت روشنایی دامنه ای نزدیک به دامنه کانال های مدفون دارند، در دسته نواحی محتمل به کانال قرار می گیرند.

در ادامه ضمن بررسی نتایج حاصل از خوشهبندی بهینه و مطالعه نتایج حاصل از نشانگرهای لرزهای، دو دسته نقطه که مشخصه نواحی محتمل به رخسارههای کانالی و نواحی پسزمینه میباشند، توسط مفسر به منظور آموزش شبکه عصبی انتخاب شدند. برخی از نقاط تفسیر شده مشخصه نواحی محتمل به کانال و نیز نواحی غیر کانالی بر روی برش زمانی ۱۰۲۴ میلی ثانیه از مکعب داده لرزهای با محتوای فرکانسی بالاتر از ۵۰ هرتز در شکل ۱۷ نمایش داده شده است. سپس مجموعه نشانگرها و نقاط انتخاب شده بهعنوان ورودى به شبكه عصبى تحت نظارت معرفي گردید. در مرحله آموزش ۳۰٪ دادهها برای مجموعه آزمایشی (Test data) و ۷۰٪ باقیمانده برای مجموعه آموزشی (Train data) تقسیم شدند. زمانی که اختلاف بین نتایج برآورد شده توسط شبکه عصبی مصنوعی و خروجی واقعی و همچنین خطای طبقهبندی برای هر دو مجموعه به کمترین مقدار خود برسد، آموزش متوقف می شود. در شکل ۱۸ نمودارهای مربوط به خطای جذر میانگین مربعات و خطای طبقهبندی برای مجموعه آزمایشی و آموزشی و در نهایت مکعب احتمال خروجی نشان داده شده است که در آن احتمال وجود رخساره کانالی برای هر نمونه، مقداری بین صفر و یک دارد. خطای جذر میانگین مربعات بیانگر تفاوت میان مقدار پیش بینی شده توسط مدل و مقدار واقعی است؛ در حالی که خطای طبقهبندی یک پارامتر ساده کنترل کیفیت نشاندهنده درصد قرارگیری مجموعه آزمایشی و مجموعه آموزشی در كلاس نادرست مىباشد. همانطور كه مشاهده مى شود، هدف شناسايى شده در شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار، نسبت به نتایج حاصل از مطالعات تکنشانگری از پیوستگی بالاتری برخوردار است. ترکیب غیرخطی نشانگرهای لرزهای متعارف توسط شبکه عصبي مصنوعي پرسپترون چندلايه با الگوريتم پسانتشار، نوفه پسزمينه را تضعیف نموده و تمایز بین مرزهای کانالی و نمونههای اطراف را برجسته ساخته است.

خوشه بهینه به داده لرزهای اولیه با محتوای فرکانسی بالاتر از ۵۰ هرتز در برش زمانی ۱۰۲۴ میلی ثانیه همراه با موقعیت فضایی نقطه نمونههای تشکیل دهنده تصویر ناحیهبندی شده (شکل ۱۶–ه) نشان داده شده است.

¹ Inline



شکل ۱۴: (الف) داده لرزهای واقعی اولیه در به خط ۳۳۰، (ب) حیطه فوریه دو بعدی (الف)، (ج) داده لرزهای واقعی پردازش پس از برانبارش شده با اعمال فیلتر میانه آماری در به خط ۳۳۰، (د) حیطه فوریه دو بعدی (ج). به منظور بررسی نحوه عملکرد فیلتر میانه آماری اعمالی، از تبدیل حیطه فوریه دو بعدی استفاده شده است. فیلتر میانه آماری توانسته است نوفه پسزمینه موجود در داده لرزهای مورد مطالعه را تضعیف نماید. خطچین '*AA* نشان دهنده برش زمانی ۱۰۲۴ میلی ثانیه و خطچین سبز که بهصورت دایره **B** نشان داده شده است، بیان کننده کانال مورد مطالعه میباشد.

> در ادامه ضمن بررسی نتایج حاصل از خوشهبندی بهینه و مطالعه نتایج حاصل از نشانگرهای لرزهای، دو دسته نقطه که مشخصه نواحی محتمل به رخسارههای کانالی و نواحی پسزمینه میباشند، توسط مفسر به منظور آموزش شبکه عصبی انتخاب شدند. برخی از نقاط تفسیر شده مشخصه نواحی محتمل به کانال و نیز نواحی غیر کانالی بر روی برش زمانی ۱۰۲۴ میلی ثانیه از مکعب داده لرزهای با محتوای فرکانسی بالاتر از ۵۰ هرتز در شکل ۱۷ نمایش داده شده است. سپس مجموعه نشانگرها و نقاط انتخاب شده بهعنوان ورودى به شبكه عصبى تحت نظارت معرفي گردید. در مرحله آموزش ۳۰٪ دادهها برای مجموعه آزمایشی (Test data) و ۷۰٪ باقیمانده برای مجموعه آموزشی (Train data) تقسیم شدند. زمانی که اختلاف بین نتایج برآورد شده توسط شبکه عصبی مصنوعی و خروجی واقعی و همچنین خطای طبقهبندی برای هر دو مجموعه به کمترین مقدار خود برسد، آموزش متوقف می شود. در شکل ۱۸ نمودارهای مربوط به خطای جذر میانگین مربعات و خطای طبقهبندی برای مجموعه آزمایشی و آموزشی و در نهایت مکعب احتمال خروجی نشان داده شده است که در آن احتمال وجود رخساره کانالی برای هر نمونه، مقداری بین صفر و یک دارد. خطای جذر میانگین مربعات بیانگر تفاوت میان مقدار پیشبینی شده توسط مدل و مقدار واقعی است؛ در حالی که خطای طبقهبندی یک پارامتر ساده کنترل کیفیت نشاندهنده درصد قرارگیری مجموعه آزمایشی و مجموعه آموزشی در كلاس نادرست مىباشد. همان طور كه مشاهده مى شود، هدف شناسايى شده در شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار، نسبت به نتایج حاصل از مطالعات تکنشانگری از پیوستگی بالاتری برخوردار است. تركيب غيرخطي نشانگرهاي لرزهاي متعارف توسط شبكه

عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار، نوفه پسزمینه را تضعیف نموده و تمایز بین مرزهای کانالی و نمونههای اطراف را برجسته ساخته است.

سپس نتایج حاصل از شبکه عصبی مصنوعی پرسپترون چند لایه با نتایج حاصل از تحلیل مولفههای اصلی، خوشهبندی k-میانگین و ترکیب خوشهبندی k-میانگین و تحلیل مولفههای اصلی مقایسه گردید. در شکلهای ۱۹ و ۲۰ به ترتیب مقایسه کیفی و کمی مربوط به روش پیشنهادی با روشهای تحلیل مولفههای اصلی، خوشهبندی k-میانگین و ترکیب آنها ارائه شده است. لازم به ذکر است که مولفههای اصلی اول، دوم و سوم اجزای تشکیل دهنده نمایش رنگی قرمز-سبز-آبی میباشد. واضح است که روش پیشنهادی در مقایسه با سایر روشها در مکانیابی دقیق لبهها و شناسایی کمتر نقاط غیرلبه بهعنوان لبه موفق تر عمل کرده است.

در پایان، مکعب داده لرزهای ورودی فیلتر اتصال کوچکترین اجزای ساختاری^۱ قرار گرفته است. فیلتر اتصال کوچکترین اجزای ساختاری یکی از ابزارهای کاربردی جهت ایجاد پیکرههای زمین شناسی پیوسته بر اساس مقادیر دامنه در یک حجم لرزهای میباشد. اساس این فیلتر، اتصال کوچکترین اجزای ساختاری مجاور بر اساس آستانه از پیش تعریف شده است. شکل ۲۱ پیکره کانال استخراج شده توسط فیلتر اتصال کوچکترین اجزای ساختاری را به تصویر میکشد. نوار رنگی نمایش داده شده در تصویر نشان دهنده عمق پیکره کانالی استخراج شده در هر نقطه نمونه

¹ Voxel connectivity filter



شکل ۱۵: برش زمانی ۱۰۲۴ میلیثانیه از (الف) داده لرزهای واقعی اولیه، (ب) فیلتر میانه، (ج) مقاومت صوتی، (د) نشانگر همدوسی بر مبنای ماتریس همرویداد سطح خاکستری، (ه) نشانگر تجزیه طیفی با نمایش RGB (فرکانس ۳۰ هرتز به رنگ قرمز، فرکانس ۴۵ هرتز به رنگ سبز و فرکانس ۶۰ هرتز به رنگ آبی نشان داده شده است.)، (و) نشانگر شباهت. پیکانهای سفید شاخه اصلی کانال مورد مطالعه را نشان میدهند. پیکان سبز رنگ نشان دهنده .

نشریه پژوهشهای ژئوفیزیک کاربردی، دوره ، شماره ، ۱۳۹۹.



شکل ۱۶: (الف) داده لرزهای واقعی با محتوای فرکانسی بالاتر از ۵۰ هر تز در برش زمانی ۱۰۲۴ میلی ثانیه حاوی رویدادی کانالی، (ب) موقعیت فضایی نقطه نمونههای تشکیل دهنده (الف)، (ج) مقادیر شاخص کالینسکی–هارباسز برای تعداد خوشههای ۲ تا ۱۰ با ورودی داده لرزهای واقعی با محتوای فرکانسی بالاتر از ۵۰ هر تز، (د) نتایج حاصل از ناحیهبندی تصویر لرزهای (الف) توسط الگوریتم خوشهبندی k–میانگین بر اساس تعداد خوشههای بهینه مشخص شده در (ب)، (ه) موقعیت فضایی نقطه نمونههای تشکیل دهنده (د). مجموعه نقاط به رنگ آبی تیره معرف نقاط با دامنه نزدیک به دامنه کانالهای مدفون فده در (ب)، (ه) موقعیت فضایی نقطه نمونههای تشکیل دهنده (د). مجموعه نقاط به رنگ آبی تیره معرف نقاط با دامنه نزدیک به دامنه کانالهای مدفون

شکل ۱۷: برخی از نقاط تفسیر شده مشخصه نواحی محتمل به کانال و نواحی پسزمینه بر روی برش زمانی ۱۰۲۴ میلیثانیه از مکعب داده لرزهای با محتوای فرکانسی بالاتر از ۵۰ هرتز که بر اساس نتایج حاصل از خوشهبندی بهینه و مطالعه نشانگرهای لرزهای انتخاب شده اند. نقاط کانالی با رنگ سبز و نقاط پسزمینه با رنگ زرد مشخص شده است.

شکل ۱۸: (الف) نمونهای از خطای آموزشی (پنجره بالایی)، خطای آزمایشی (پنجره پایینی). (ب) برش زمانی ۱۰۲۴ میلیثانیه از نشانگر احتمال کانال حاصل از شبکه عصبی مصنوعی. نشانگر احتمال کانال توانسته ضمن تاثیرپذیری کمتر از نوفه پسزمینه، مرزهای کانالی را با دقت بالاتری شناسایی نماید. مرزهای کانالی شناسایی شده با پیکانهای سفید مشخص شده است. پیکان سبز رنگ نشان دهنده جهت شمال میباشد.

شکل ۱۹: برش زمانی ۱۰۲۴ میلیثانیه از (الف) نشانگر احتمال کانال حاصل از شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار، (ب) الگوریتم تحلیل مولفه اصلی (مولفه اصلی اول به رنگ قرمز، مولفه اصلی دوم به رنگ سبز و مولفه اصلی سوم به رنگ آبی نشان داده شده است.)، (ج) k-میانگین حاصل از داده لرزهای با محتوای فرکانسی بالاتر از ۵۰ هرتز، (د) k-میانگین حاصل از نتایج به دست آمده از تحلیل مولفه اصلی. مرزهای کانالی شناسایی شده با پیکانهای سفید مشخص شده است. پیکان سبز رنگ نشان دهنده جهت شمال میباشد.

شکل ۲۰: مقایسه کمّی نتایج حاصل از روش شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار با نتایج حاصل از روشهای تحلیل مولفههای اصلی، k-میانگین و ترکیب آنها با استفاده از آزمایش دستهبندی دودویی برای داده لرزهای واقعی (از چپ به راست: دقت، حساسیت، ویژگی و معیار

شکل ۲۱: پیکره کانال استخراج شده توسط فیلتر اتصال کوچکترین اجزای ساختاری. عمق هر یک از اجزای ساختاری بهصورت یک نوار رنگی نشان داده شده است.

۴- نتیجهگیری

فیلتر میانه با تضعیف نوفه تصادفی موجود در داده لرزهای و افزایش نسبت سیگنال به نوفه، پیوستگی رخدادها و کیفیت نشانگرهای لرزهای را ارتقاء داده است. خوشهبندی داده لرزهای بهبود یافته با محتوای فرکانسی بالاتر از ۵۰ هرتز توسط الگوریتم k-میانگین با تعداد خوشههای بهینه ۲ بر اساس معیار کالینسکی-هارباسز، در تعیین تعداد کلاسهای آموزشی شبكه عصبى مصنوعى و همچنين انتخاب نقاط آموزشي توسط مفسر عملكرد موثرى از خود نشان داده است. با رسيدن اختلاف بين نتايج برآورد شده با شبکه عصبی مصنوعی و خروجی واقعی و همچنین خطای مربوط به هر دو مجموعه به کمترین مقدار خود، تصویر بهبود یافتهای از کانالهای موجود در داده لرزهای ثبت گردید. در واقع مکعب احتمال كانال حاصل از شبكه عصبى پرسپترون چندلايه با الگوريتم پسانتشار ضمن به تصویر کشیدن مرزهای کانال موجود در داده لرزهای با وضوح و تفکیک پذیری بالا، اثر ناپیوستگیهای متأثر از حضور نوفه در روشهای تک نشانگری را کاهش داده است. کانال مدفون شناسایی شده توسط شبكه عصبى مصنوعى پرسپترون چندلايه با الگوريتم پسانتشار شباهت قابل ملاحظهای به مرزهای کانالی ثبت شده توسط نشانگر همدوسی بر مبنای ماتریس همرویداد سطح خاکستری دارد. البته لازم به ذکر است که مرزهای کانالی شناسایی شده توسط شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار در مقایسه با نتایج حاصل از همدوسی بر مبنای ماتریس همرویداد سطح خاکستری، ضمن تفکیک پذیری بالاتر تاثیر پذیری کمتری نسبت به نوفه پس زمینه داشته است.

نتایج حاصل از طرحواره پیشنهادی در دادههای لرزهای مصنوعی و واقعی حاوی کانال، بهصورت کمی و کیفی با نتایج حاصل از تحلیل

فيشر).

مولفههای اصلی، خوشهبندی k-میانگین و ترکیب آنها مقایسه شد. بررسیها نشان داد که شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم پسانتشار نسبت به سایر روشها، در مکانیابی دقیق لبهها و شناسایی کمتر نقاط غیر لبه بهعنوان لبه موثرتر عمل کرده است. لازم به ذکر است که ترکیب روشهای تحلیل مولفههای اصلی، خوشهبندی k-میانگین همانند روش شبکه عصبی پرسپترون چندلایه با الگوریتم پس-انتشار از دقت مناسبی برخوردار است. فیلتر اتصال کوچکترین اجزای ساختاری توانسته پیکره کانال مورد مطالعه را با دقت نسبتا بالایی استخراج نماید. کانال استخراج شده دارای الگوی مستقیم و مآندری با راستای شمال شرقی-جنوب غربی و شیب شمالی-جنوبی میباشد.

۵- منابع

- سلطانی، پ.، آقاجانی، ح. و سلیمانی منفرد، م.، ۱۳۹۷، افزایش دقت در تفسیر گسلها در مقطع لرزهای با کمک تحلیل مولفههای اصلی در نشانگرها برای تعیین شکستگیها در دشت گرگان، پژوهش های ژئوفیزیک کاربردی، مقالات آماده انتشار، ۱–۱۱.
- لطفی، م. و جواهریان، ع.، ۱۳۹۸، شناسایی و استخراج رخسارههای کانالی با استفاده از شبکه عصبی پرسپترون چندلایه با الگوریتم پسانتشار و فیلتر اتصال وکسلها، اولین همایش ملی پردازش سیگنال و تصویر در ژئوفیزیک کاربردی، دانشگاه صنعتی شاهرود، شاهرود، ایران، ۲۰ آذر ماه ۱۳۹۸، ۱–۵.
- مردان، ا.ح.، جواهریان، ع. و میرزاخانیان، م.، ۱۳۹۴، مقایسه روشهای یادگیری غیرنظارتی با تأکید بر تشخیص رخسارههای کانالی تنگه هرمز، پژوهشهای ژئوفیزیک کاربردی، ۱(۲)، ۹۰–۱۰۲.
- منهاج، م.ب.، ۱۳۸۱، مبانی شبکههای مصنوعی، جلد اول، انتشارات دانشگاه صنعتی امیرکبیر.
- Aqrawi, A.A. and Boe, T.H., 2011, Improved fault segmentation using dip guided and modified Sobel filter, In 81st Annual International Meeting, SEG, Expanded Abstracts, 999–1003.
- Bahorich M.S. and Farmer S.L. 1995, 3-D seismic discontinuity for faults and stratigraphic features: the coherence cube, The Leading Edge 14(10), 1053–1058.
- Beale, M.H., Hagan, M.T., and Demuth, H.B., 2010, Neural network toolbox, User's Guide, MathWorks, 2, 129-203.
- Berge, T.B., Aminzadeh, F., de Groot, P. and Oldenziel, T., 2002, Seismic inversion successfully predicts reservoir, porosity, and gas content in Ibhubesi Field, Orange Basin, South Africa, The Leading Edge, 21(4), 338-348.
- Boustani, B., Javaherian, A., Nabi-Bidhendi, M., Torabi, S. and Amindavar, H.R., 2019a, Channel boundary detection using a 3D morphological filter and adaptive ellipsoidal structuring element, Exploration Geophysics, 1-16.

نشریه پژوهشهای ژئوفیزیک کاربردی، دوره ، شماره ، ۱۳۹۹.

- Li, Z.D., Zhang, S.X., Xu, J.Z., Liu, Y.K. and Li, W., 2018, Improved modeling of channel prediction based on gray relational analysis and a support vector machine: a case study on the X pilot area in the Daqing oilfield in China, Journal of Geophysics and Engineering, 15(4), 1407-1418.
- Mahdavi Basir, H., Javaherian, A. and Tavakoli Yaraki, M., 2013, Multi-attribute ant-tracking and neural network for fault detection: a case study of an Iranian oilfield, Journal of Geophysics and Engineering, 10(1), 1-10.
- McQueen, J., 1967, Some methods for classification and analysis of multivariate observations, In L.M. Le Cam, and J. Neyman, eds., Proceedings of the Fifth Berkeley Symposium on Mathematics, Statistics, and Probability, University of California, Press, 281-297.
- Mohebian, R., Riahi, M.A. and Yousefi, O., 2018, Detection of channel by seismic texture analysis using Grey Level Co-occurrence Matrix based attributes, Journal of Geophysics and Engineering, 15(5), 1953-1962.
- Noori, M., Hassani, H., Javaherian, A., Amindavar, H. and Torabi, S., 2019, Automatic fault detection in seismic data using Gaussian process regression, Journal of Applied Geophysics, 163, 117-131.
- Ombu, R.E., and Ulori, O.O., 2017, A case study on horizon based stratigraphic channels delineation using fast Fourier transform and seismic attributes: implications for reservoir characterization, IOSR Journal of Applied Physics, 9(5), 18-28.
- Pearson, K., 1901. LIII. On lines and planes of closest fit to systems of points in space, The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science, 2(11), 559-572.
- Pegrum, R.M., and Spencer, A.M., 1990, Hydrocarbon plays in the northern North Sea, Geological Society, London, Special Publications, 50(1), 441-470.
- Qi, J., Lin, T., Zhao, T., Li, F. and Marfurt, K., 2016, Semisupervised multi-attribute seismic facies analysis, Interpretation, 4(1), SB91-SB106.
- Rijks E.J.H. and Jauffred J.C.E.M. 1991, Attribute extraction: an important application in any detailed 3D interpretation study, The Leading Edge 10(9), 11–19.
- Roberts, A. 2001, Curvature attributes and their application to 3D interpreted horizons, First Break, 19, 85–100.
- Sadeghi, M., Roshandel, K.A., Siahkoohi, H.R. and Nikoo, A., 2016. Detecting buried channels using linear least square RGB color stacking method based on deconvolutive short time Fourier transform, Iranian Journal of Geophysics, 9(5), 104-112.
- Sales, J.K., 1992, Uplift and subsidence do northwestern Europe: possible causes and influence on hydrocarbon productivity, Norsk Geologisk Tidsskrift, 72(3), 253-258.
- Song, C., Liu, Z., Cai, H., Wang, Y., Li, X. and Hu, G., 2017, Unsupervised seismic facies analysis with spatial constraints using regularized fuzzy cmeans, Journal of Geophysics and Engineering, 14(6), 1535-1543.

- Boustani, B., Javaherian, A., Nabi-Bidhendi, M., Torabi, S. and Amindavar, H.R.,2019b, Mapping channel edges in seismic data using curvelet transform and morphological filter, Journal of Applied Geophysics, 160, 57-68.
- Brouwer, F. and Huck, A., 2011, An integrated workflow to optimize discontinuity attributes for the imaging of faults, In 31st annual GCSSEPM Foundation Bob F.Perkins Research Conference, Hoston, Texas, United States, 31, 496-532.
- Brown, A.R., 2001, Understanding seismic attributes, Geophysics, 66(1), 47-48.
- Cengizler, C. and Un, M.K., 2017, Evaluation of Calinski-Harabasz criterion as fitness measure for genetic algorithm based segmentation of cervical cell nuclei, Journal of Advances in Mathematics and Computer Science, 22(6), 1-13.
- Chehrazi, A., Rahimpour-Bonab, H., and Rezaee, M.R., 2013, Seismic data conditioning and neural networkbased attribute selection for enhanced fault detection, Petroleum Geoscience, 19(2), 169-183.
- Chopra, S. and Marfurt, K.J., 2005, Seismic attributes—A historical perspective, Geophysics, 70(5), 3SO-28SO.
- Chopra, S. and Marfurt, K.J., 2007, Volumetric curvature attributes adding value to 3D seismic data interpretation, The Leading Edge, 26(7), 856-867.
- De Jager, J., 2007, Geological development, Geology of the Netherlands, 5-26.
- Di, H. and Gao, D., 2014, Gray-level transformation and Canny edge detection for 3D seismic discontinuity enhancement, Computers and Geosciences, 72, 192– 200.
- Eichkitz, C. G., Schreilechner, M. G., de Groot, P. and Amtmann, J., 2015, Mapping directional variations in seismic character using gray-level co-occurrence matrix-based attributes, Interpretation, February, T13-T23.
- Gonzalez, R.C., Woods, R.E. and Eddins, S.L., 2004, Digital Image Processing Using MATLAB, Pearson Education India.
- Hashemi Gazar, A., Javaherian, A. and Sabeti, H., 2011, Analysis of effective parameters for semblance-based coherency attributes to detect micro-faults and fractures, Journal of Seismic Exploration, 20, 23-44.
- Ishak, M.A., Islam, M., Shalaby, M.R. and Hasan, N., 2018. The application of seismic attributes and wheeler transformations for the geomorphological interpretation of stratigraphic surfaces: a case study of the F3 block, Dutch offshore sector, North Sea, Geosciences, 8(3), 1-21.
- Karbalaali, H., Javaherian, A., Dahlke, S. and Torabi, S., 2017, Channel boundary detection based on 2D shearlet transformation: An application to the seismic data in the South Caspian Sea, Journal of Applied Geophysics, 146, 67-79.
- Kriegel, H.P., Schubert, E. and Zimek, A., 2017, The (black) art of runtime evaluation: Are we comparing algorithms or implementations?, Knowledge and Information Systems, 52(2), 341-378.

لطفي و جواهريان، شناسايي و استخراج رخسارههاي كانالي با استفاده از شبكه عصبي پرسپترون چندلايه با الگوريتم پسانتشار و فيلتر ...، صفحات 30%-33%.

- Wu, X. and Fomel, S., 2018, Automatic fault interpretation with optimal surface voting, Geophysics, 83(5), O67-O82.
- Zhao, T., Jayaram, V., Roy, A. and Marfurt, K.J., 2015, A comparison of classification techniques for seismic facies recognition, Interpretation, 3(4), SAE29-SAE58.
- Song, J., Mu, X., Li, Z., Wang, C. and Sun, Y., 2012, A faults identification method using dip guided facet model edge detector, In SEG Technical Program Expanded Abstracts, 1-5.
- Tingdahl, K.M. and De Rooij, M., 2005, Semi-automatic detection of faults in 3D seismic data, Geophysical Prospecting, 53(4), 533-542.

(JRAG)

2020, VOL 6, No 2 (DOI): 10.22044/JRAG.2020.9478.1281

Identification of channel facies using a supervised, fully connected multi-layer perceptron neural network and voxel connectivity filter

Masoume Lotfi¹ and Abdolrahim Javaherian^{2*}

1. Ph.D. Student of Petroleum Engineering-Exploration, Department of Petroleum Engineering, Amirkabir University of Technology, Tehran, Iran.

2. Professor, Presently Department of Petroleum Engineering, Amirkabir University of Technology, Formerly Institute of Geophysics, University of Tehran, Tehran, Iran

Received: 21 March 2020; Accepted: 18 June 2020

Corresponding author: javaherian@aut.ac.ir

Keywords	Extended Abstract				
Channel facies	summary				
Seismic attributes	Channel facies that are the most common stratigraphic features, are important				
Artificial neural network	from the viewpoint of hydrocarbon exploration. Depending on burial depth				
Supervised and unsupervised	and fluid contents, they may be considered as potential reservoirs or drilling				
learning	hazards. Revealing the accurate location of channel facies is an essential step				
Voxel connectivity filter	needed for an optimum well path design and reservoir target. Seismic				
Channel facies	interpretations become difficult due to the increase of seismic data volume and				
Seismic attributes	a variety of seismic attributes. Integration of seismic attributes with different				
	computational algorithms based on artificial neural networks provides more				

details of seismic events. For an enhanced channel edge detection, we applied a fully connected multi-layer perceptron neural network with supervised training to both synthetic and real seismic data containing channels. We compared our results with unsupervised learning algorithms to evaluate the proposed algorithm. In both synthetic and real seismic data examples, the multi-layer perceptron neural network with back-propagation algorithm outperformed the unsupervised learning methods. We also investigated the noise sensitivity of the algorithms mentioned above for the case of synthetic data set. The voxel connectivity filter determined the accurate spatial location of the studied channel in the real seismic data.

Introduction

Feature extraction techniques like supervised and unsupervised learning methods are designed to have a pixel-based classification based on intensity. In a supervised learning model, the algorithm provides an answer key based on the labeled input data set. An unsupervised learning algorithm, in contrast, tries to extract features and patterns with no explicit instructions. In this study, we used a multi-layer perceptron neural network with back-propagation algorithm as an efficient classification method to determine channel facies in seismic data that can be locations of drilling hazards or potential reservoirs. A multi-layer perceptron neural network with back-propagation algorithm is a supervised learning technique approximating the non-linear relationship between the input and the output by adjusting the weights of nodes internally. Then, the results of the proposed method were compared with the ones derived from the unsupervised learning algorithms.

Methodology and Approaches

We used OpendTect software to study seismic attributes. The chosen attributes are acoustic impedance, average frequency, curvature, coherency, energy, gray-level covariance matrix, gray-level covariance-based coherency, polar dip, similarity, and spectral decomposition. After preparing the set of attributes, we applied supervised and unsupervised learning techniques on the attributes of the three-dimensional (3D) seismic data acquired over the F3 block, offshore Netherlands, using OpendTect and MATLAB software. We applied multi-layer perceptron neural network with back-propagation algorithm to integrate the seismic attributes with the optimum parameters to sharpen the channel boundaries and attenuate the random background noise. The principal component analysis was applied to reduce the dimension of the set of the seismic attributes to 2D to obtain an image containing more information than that of single attribute. Then, K-means algorithm was applied to the data with a reduced dimension to enhance the results of

2020, VOL 6, NO 2

classification by attenuating random noise. The results showed that the proposed method was superior to the principal component analysis and K-means methods. Finally, the voxel connectivity filter was applied on the seismic data to extract the seismic channel body.

Results and Conclusions

Channels occur as edges in seismic time slices; therefore, it is reasonable to use algorithms applicable in image processing for seismic channel detection. Channel edge candidates could be found clearly by integrating different seismic attributes with optimum parameters using artificial neural networks. We used multi-layer perceptron neural network with back-propagation algorithm to extract the channel edges from 3D seismic data. Nonlinear integration of seismic attributes suppressed the background noise and enhanced the difference between channel edges and their surroundings. We compared the results of the multi-layer perceptron neural network with back-propagation algorithm with those of unsupervised learning methods qualitatively and quantitatively. In both synthetic and real data examples, the proposed algorithm outperformed the principal component analysis and the K-means algorithms and also their combination. The voxel connectivity filter could accurately visualize the 3D nature of the detected channels based on the predefined amplitude threshold value.