

## بهبود تحلیل رخساره‌های لرزه‌ای با استفاده از نشانگر WTMLA و خوشه‌بندی‌های SOM و K-mean

سعید هادیلو<sup>۱\*</sup>، حمیدرضا سیاه‌کوهی<sup>۲</sup> و علی عدالت<sup>۳</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد ژئوفیزیک، گروه فیزیک زمین، مؤسسه ژئوفیزیک دانشگاه تهران، ایران

<sup>۲</sup> دانشیار، گروه فیزیک زمین، مؤسسه ژئوفیزیک دانشگاه تهران، ایران

<sup>۳</sup> مشاور، شرکت مشاوران تهران

(دریافت: ۸۸۳،۲۳، پذیرش نهایی: ۹۰/۱۱/۱۱)

### چکیده

تحلیل رخساره‌های لرزه‌ای بدون نظارت به‌منظور برآورد کردن خصوصیات مخزن با استفاده از ترکیب نشانگرهای لرزه‌ای در الگوریتم‌های شناسایی الگو، یکی از روش‌های بسیار مهم تفسیری است. بدون توجه به توانمندی روش به‌کاررفته در تحلیل رخساره‌های لرزه‌ای، دسته‌بندی داده‌ها در درون مخزن باید با دقت کامل صورت گیرد. با توجه به پیچیدگی‌های موجود در سامانه مخزن، سطح اطمینان از یک تفسیر، با توجه به دقت داده‌های لرزه‌ای و تجربه مفسر، می‌تواند متغیر باشد و هر خطایی در تفسیر، بدون شک منجر به اشتباه یا نتایج غلط در تفسیر لرزه‌ای شود. به‌خصوص وقتی از شکل ردلرزه، برای الگوریتم تحلیل رخساره‌ی لرزه‌ای استفاده کنیم. کم بودن دقت نشانگرهای قدیمی باعث می‌شد که رخساره‌های لرزه‌ای تولید شده به دلیل تغییرات سریع شکل موج لرزه‌ای در محدوده مخزن، نادرست و یا با دقت کم دسته‌بندی شوند. با توجه به متغیر بودن محتوای بسامدی با زمان در ردلرزه‌ها، تحلیل زمان-بسامد ردلرزه می‌تواند یک روش جدید و موثر برای تعیین ویژگی‌های مخزن باشد. در این تحقیق پیشنهاد می‌شود که از خصوصیات زمان-بسامد و به‌خصوص نشانگر خط بیشینه دامنه ضرایب تبدیل موجک (WTMLA) برای شناسایی تکینگی ردلرزه در محدوده مخزن استفاده شود. در این تحقیق از ابزار ریاضی نقشه‌های خودسازمان‌ده در حکم تحلیل‌گر رخساره لرزه‌ای بدون سرپرست برای خوشه‌بندی داده‌های مخزن استفاده شده است. نشانگر استفاده شده در این تحقیق به تعیین دقیق زمان رخداد لرزه‌ای حساس نیست در نتیجه می‌تواند دقت تحلیل رخساره لرزه‌ای را افزایش دهد. در این تحقیق روش پیشنهادی، روی داده‌های لرزه‌ای واقعی اعمال شده است.

واژه‌های کلیدی: تفسیر مقاطع لرزه‌ای، تحلیل رخساره لرزه‌ای، تحلیل زمان-بسامد، بازشناسایی الگوهای لرزه‌ای، نقشه‌های خودسازمان‌ده

## Improving seismic facies analysis using WTMLA attributes, self-organizing maps and K-mean clustering

Hadiloo, S.<sup>1</sup>, Siahkoohi, H. R.<sup>2</sup> and Edalat, A.<sup>3</sup>

<sup>1</sup> M.Sc Student of Geophysics, Institute of Geophysics, University of Tehran, Iran

<sup>2</sup> Associate Professor, Institute of Geophysics, University of Tehran, Iran

<sup>3</sup> Consultant, Tehran Energy Consultant Company, Iran

(Received: 13 Jun 2009, Accepted: 31 Jan 2012)

### Abstract

Reservoir models are initially generated from estimates of specific rock properties and maps of reservoir heterogeneity. Many types of information are used in reservoir model construction. One of the most important sources of information comes from wells,

including well logs and core samples. Unfortunately well log and core data are local measurements that may not reflect the reservoir behavior as a whole. In addition, well data are not available at the initial phases of exploration. In contrast to sparse well data, 3D seismic data cover large areas. Seismic attributes extracted from 3D seismic data can provide information for the construction of reservoir models. Seismic facies analysis can be accomplished through the use of pattern recognition techniques. When the geological information is incomplete or nonexistent, seismic facies analysis can be done using unsupervised learning techniques. One of the most promising mathematical techniques of unsupervised learning is the Kohonen's Self Organizing Map (SOM) (Kohonen, 2001).

In this paper we use the SOM and time-frequency analysis to characterize reservoirs. Since variations in frequency content are sensitive to subtle changes in reflective information. In this context, we show that the wavelet transform modulus maxima line amplitudes (WTMMLA) that extracted from continuous wavelet transforms (CWT) can be applied to detect singularities. These singularities are analyzed and clustered by SOM.

The SOM networks map points of input space to points in an output space while preserving the topology. Topology preservation means that points which are close in the input space should also be close in the output space (map). Normally, the input space is of high dimension while the output is two-dimensional. The seismic attributes, can be represented by vectors in the space  $R^n$ ,  $x = [x_1, x_2, \dots, x_n]$ . We assume that the map has  $P$  elements; therefore, there will exist  $P$  prototype vectors  $m_i$ ,  $m_i = [m_{i1}, \dots, m_{in}]$ ,  $i = 1, 2, \dots, P$ , where  $n$  is the dimension of the input vector. After the SOM training, prototype vectors represent the input data set of seismic attributes, the distances between  $x$  and all the prototype vectors are computed. The map unit with the smallest distance  $m_b$  to the input vector  $x$  is called the best matching unit (BMU) and is computed by,  $\|x - m_b\| = \min \{\|x - m_i\|\}$ . The prototype vector corresponding to the BMU and their neighbors are moved towards the input winner vector in the input space. Since one of the main objectives of this work was the identification of data clusters, we displayed the distances between the neighbor prototype vectors to identify similarities among the vector prototypes. We used the U-matrix (Ultsch, 1993), to represent these distances. After the SOM learning, the U-matrix was generated by computing, for each SOM prototype vector, the distance between the neighbor prototype vectors and their average.

For estimation of the number of existing seismic facies in the data, we used a K-means partitive clustering algorithm. We clustered the prototype vectors instead of the original data. In this manner, large data sets formed by the SOM prototype vectors can be indirectly grouped. Results showed that the proposed method not only provides a better understanding about the group formations, but it is also computationally efficient. Another benefit of this methodology is noise reduction because the prototype vectors represent local averages of the original data without any loss of resolution. To automate the classification process, we used the Davies and Bouldin (1979) index (DBI) as means of evaluating the results of the K-means partitioning.

Transitions, or irregular structures, present in any kind of signals carry information related to its physical phenomena (Mallat, 1999). Besides the horizon locations, the identified transition characterization in the interpretation is associated with geological processes. In this way, a possible transition classification could be linked to the seismic facies. Detection of transitions or singularities in signals is based on simple mathematical concepts. The signal inflection points are associated with the first-derivative extremes which correspond to the second-derivative zero crossings. For the signal inflection-point positions, using the CWT local peak locations, a wavelet should be chosen as the first-derivative of the smoothing function  $\theta(x)$ . One of the wavelet functions that fulfill this

requirement is the first-derivative of the Gaussian function, called the Gauss wavelet. We can extract scalogram's local peaks coincide from the signal inflection points. It can be proven that these lines, which are called WTMLA, can be used to characterize the signal irregularity. The signal irregularities can be characterized mathematically through the WTMLA and Hölder exponent (Mallat, 1999). The exponent can be obtained from the slope estimation of the curve created by the  $\log_2$  of the WTMLA coefficients divided by the  $\log_2$  of the scales. In This study we used WTMLA as a direct seismic attribute. We calculated CWT coefficients and WTMLA for sixteen seismic data samples around the picked reservoir horizon. The extracted WTMLA can show the possible heterogeneity and singularity within the reservoir. We used these attribute as input vector for the SOM step and obtained the  $U_{matrix}$ . The K-mean and DBI estimate the number of seismic facies. Utilizing of CWT to locate events in time through the identification of signal singularities also proved to be useful as an appropriate tool for detection of seismic events. Therefore this method proved to be less sensitive to interpretation errors. The performance of the method was tested on Kangan formation at one of the Iranian oil fields.

**Key words:** Signal processing, Seismic facies analysis, Time-frequency analysis, Seismic pattern recognition, Self organizing maps

## ۱ مقدمه

کند. هنگامی که داده‌های چاه وجود ندارد و یا تعداد آنها کم است، مفسر باید با استفاده از الگوریتم‌های بدون ناظر، یعنی بدون استفاده از داده‌های چاه به تحلیل خصوصیات مخزن پردازد. الگوریتم‌های زیادی برای این منظور وجود دارد. یکی از موفق‌ترین آنها نقشه‌های خودسازمانده (SOM, self-organizing maps) کوهن (کوهن، ۱۹۹۰) است که محققان زیادی برای خوشه‌بندی انواع داده‌ها آن را مورد استفاده قرار داده‌اند (ماتوس و همکاران، ۲۰۰۳a و ۲۰۰۳b).

در این تحقیق ابتدا مروری کوتاه بر مبانی نظری نقشه‌های خودسازمانده خواهیم داشت و سپس به معرفی نشانگری به نام خطوط بیشینه ضرایب تبدیل موجک (WTMMLA, wavelet transform modulus maxima line amplitudes) خواهیم پرداخت. این نشانگر با استفاده از بیشینه ضرایب تبدیل موجک در مقیاس‌های متفاوت به دست می‌آید و نوع تکینگی (singularity) سری زمانی را در زمان‌های مشخص، تعیین می‌کند. سپس با استفاده از این نشانگر (attribute) و با استفاده از

مدل یک مخزن از برآورد خصوصیات سنگ‌های مخزن و به نقشه در آوردن ناهمگنی‌های مخزن قابل دستیابی است. برآورد خصوصیات سنگ مخزن از قبیل، تخلخل، تاثیرپذیری، نوع مایع درون سنگ و سنگ‌شناسی، یک اصل برای اکتشاف، توسعه و گسترش حوضه نفتی است. از انواع گوناگونی از اطلاعات برای مدل کردن مخزن استفاده می‌شود که از جمله مهم‌ترین این اطلاعات، اطلاعات به دست آمده از داده‌های چاه، نمونه‌های مغزه‌ها، و اطلاعات لرزه‌ای است. به علت محدود بودن تعداد چاه‌ها و کم بودن قدرت تفکیک افقی این داده‌ها، نمی‌توان فقط با تکیه بر اطلاعات چاه‌ها به بررسی مخازن پرداخت. از طرفی باید در نظر گرفت که در مراحل اولیه اکتشاف ممکن است تعداد چاه‌ها کم باشد و یا چاهی وجود نداشته باشد. در مقابل، داده‌های لرزه‌ای سه‌بعدی با گستردگی مناسب روی مخزن، اطلاعات جامع و کاملی از کل محدوده مخزن به دست می‌دهد. این اطلاعات را می‌توان با داده‌های چاه واسنجی (کالیبره) کرد تا مفسر بتواند به نسبت خوبی، رفتار و خصوصیات مخزن را تعیین

خود در ارتباط هستند و این ارتباط، اغلب به صورت شش گوشه یا هگزاگونال (hexagonal) (هر نرون با شش نرون اطراف خود) و یا مستطیلی (rectangular) (هر نرون با چهار نرون اطراف خود) است.

برای تعیین مقادیر بردارهای وزن اولیه دو راه وجود دارد: اول اینکه این مقادیر کاملاً به صورت تصادفی انتخاب شوند و روش دیگر اینکه این مقادیر با استفاده از دو ویژه مقدار بزرگ (two largest eigenvectors) ماتریس داده‌های ورودی تعیین شوند (کوهنن، ۲۰۰۱). روش اول به این خاطر که بردارهای وزن ممکن است کاملاً با داده‌های ورودی متفاوت و یا از آنها دور باشند، چندان مورد استفاده قرار نمی‌گیرد. چون در این حالت، شبکه به زمان زیادی برای آموزش نیاز دارد و حتی ممکن است نتواند به درستی داده‌های ورودی را نمایندگی کند. روش دوم از آنجاکه مقادیر بردار وزن خود را با توجه به ویژه مقادیر بزرگ و بردارهای ویژه ماتریس ورودی تعیین می‌کند، تا حدودی به داده‌های ورودی نزدیک خواهد بود و این سبب می‌شود که آموزش (learning) شبکه سریع و با دقت بیشتری صورت گیرد. بعد از تعیین بردارهای وزن اولیه نرون‌ها، بردارهای ورودی (نشانگرهای لرزه‌ای) را به شبکه اعمال می‌کنند. در هر مرحله یکی از بردارهای ورودی را به صورت تصادفی انتخاب می‌کنند و فاصله بردار ورودی با همه بردارهای وزن محاسبه می‌شود. نرونی که کمترین فاصله را با بردار ورودی داشته باشد در حکم نرون برنده تعیین و با استفاده از رابطه زیر به سمت بردار ورودی سوق داده می‌شود.

$$m_i(t+1) = m_i(t) + \lambda(t)h_{bi}(t)[x - m_i(t)] \quad (1)$$

این روند در تکرارهای متمادی برای همه بردارهای ورودی صورت می‌گیرد. در هر مرحله نرون برنده و همسایگی‌های آن نرون به سمت بردار ورودی سوق داده

نقشه‌های خودسازمان‌ده به دسته‌بندی داده‌های لرزه‌ای محدوده مخزن می‌پردازیم. استفاده از نشانگر این امکان را می‌دهد که خوشه‌بندی ناحیه مخزن زیاد به دقت تعیین رخداد لرزه‌ای یا افق حساس نباشد و این امکان خطا در خوشه‌بندی را تا حد بسیار زیادی کاهش می‌دهد (ماتوس و همکاران، ۲۰۰۷).

## ۲ نقشه‌های خودسازمان‌ده

نقشه‌های خودسازمان‌ده (SOM) ابزار خوشه‌بندی‌اند و می‌توانند داده‌های با ابعاد بزرگ را به صورت دو بُعدی نمایش دهند. در این نمایش SOM نظم توپولوژیکی داده‌ها در ابعاد بزرگ را در دو بُعد نیز حفظ می‌کند. به‌طور کلی اگر داده‌هایی در فضای ورودی به یکدیگر نزدیک باشند، در نقشه حاصل شده از SOM نیز نزدیک به یکدیگر باقی می‌مانند. به همین دلیل نقشه‌های خودسازمان‌ده می‌توانند فضای ورودی با ابعاد بزرگ را در یک نقشه دو بُعدی، با حفظ ساختار توپولوژیکی داده‌های ورودی به دست دهند. با استفاده از این ویژگی خصوصیات گوناگون گروه‌های موجود در داده‌های ورودی، در نقشه حاصل نشان داده می‌شود (تر و همکاران، ۲۰۰۱).

شبکه‌های خودسازمان‌ده از خانواده شبکه‌های رقابتی‌اند. این شبکه‌ها از دو لایه تشکیل می‌شوند. لایه اول شامل داده‌های ورودی به شبکه است. بُعد (dimension) داده‌های ورودی با توجه به تعداد نشانگرهای لرزه‌ای تعیین می‌شود. لایه دوم شامل نرون‌هایی است که در یک شبکه دو بُعدی قرار گرفته‌اند و بعد از آموزش شبکه، داده‌های ورودی را نمایندگی می‌کنند. لایه دوم (خروجی شبکه) دارای بردار اولیه (vector prototype) به صورت بردار ورودی  $m_i = [m_{i1}, \dots, m_{in}]$ ،  $i=1, 2, \dots, p$  است. تعداد بُعد بردار ورودی (تعداد نشانگر لرزه‌ای) با  $n$  نشان داده شده است. در لایه خروجی همه نرون‌ها با نرون‌های همسایگی

### ۳ خوشه‌بندی با استفاده از SOM و K-mean

با اعمال نشانگرهای لرزه‌ای به شبکه، ماتریس  $U$  به دست می‌آید. این ماتریس گروه‌های ذاتی درون داده‌های لرزه‌ای را با استفاده از رنگ‌های یکسان نشان می‌دهد و جدایش این گروه‌ها نیز با استفاده از رنگی که برای نمایش فاصله بیشتر وجود دارد نمایندگی می‌شود. تعیین تعداد رخصاره‌های لرزه‌ای در تحلیل رخصاره‌ی لرزه‌ای به روش تجربی صورت می‌گیرد (جوهان و همکاران، ۲۰۰۱). در اینجا پیشنهاد می‌شود که برای مشخص کردن تعداد رخصاره‌های لرزه‌ای از یک روش خوشه‌بندی مانند k-mean استفاده شود. استفاده از این روش احتمال خطا در تعیین تعداد خوشه مناسب و تعیین مرز خوشه‌ها را کاهش می‌دهد. در حقیقت با استفاده از این روش تعداد خوشه‌ها را در درون ماتریس  $U$  به صورت خودکار پیدا می‌کنیم. در این کار ما به جای خوشه‌بندی داده‌های اصلی به خوشه‌بندی بردارهای اولیه حاصل از SOM می‌پردازیم. این کار باعث کم شدن حساسیت نرم‌افزار به نوفه درون داده‌ها می‌شود، چون بردارهای اولیه، یک میانگین محلی از داده‌های ورودی هستند و از طرف دیگر زمان محاسبات را تا حد قابل ملاحظه‌ای کاهش می‌دهند (وستانو و الهونیمی، ۲۰۰۰). از آنجا که اطلاعی از تعداد خوشه‌های موجود در داده در دست نیست، خوشه‌بندی با تعداد متفاوت خوشه صورت می‌گیرد و سپس بهترین تعداد با الگوریتمی که در ادامه می‌آید انتخاب می‌شود. بهترین خوشه‌بندی آن خوشه‌بندی است که در آن فاصله اعضای خوشه از مرکز خوشه و دیگر اعضا کمینه و فاصله‌شان از اعضای دیگر خوشه‌ها بیشینه باشد. برای تعیین بهترین تعداد خوشه‌ها دیویس و بولدین در ۱۹۷۹ اندیسی را معرفی کردند، به طوری که این اندیس برای خوشه‌بندی بهینه، کمترین مقدار را به خود می‌گیرد.

می‌شود. با ادامه این روند مقادیر وزن همه نرون‌ها تغییر می‌کند و هر کدام به دسته‌ای از بردارهای ورودی نزدیک می‌شوند. در رابطه بالا  $\lambda(t)$  نرخ یادگیری (Learning rate) است. این مقدار با افزایش تعداد تکرار کاهش می‌یابد. کاهش نرخ یادگیری موجب می‌شود که بعد از آموزش نسبی شبکه، مقادیر وزن با نرخ کوچک‌تری تغییر یابند و بهترین جواب حاصل شود. همسایگی نیز با افزایش تعداد تکرار با توجه به فرمول  $h_{bi}(t)$  اندازه همسایگی برای نرون برنده است. اندازه همسایگی نیز با افزایش تعداد تکرار با توجه به فرمول پایین کاهش می‌یابد.

$$h_{bi}(t) = e^{-\left(\|r_b - r_i\|^2 / 2\sigma^2(t)\right)} \quad (2)$$

$r_i, r_b$  مکان نرون‌ها در شبکه را نشان می‌دهند و  $\sigma^2(t)$  پهنای همسایگی را تعیین می‌کند. بعد از آموزش شبکه هر نرون مقداری را به دست می‌آورد که هر کدام بخشی از بردار ورودی را با حفظ نظم آنها نمایندگی می‌کند. از آنجا که خروجی شبکه SOM دو بُعدی است، این توان به مفسر داده می‌شود که بتواند دسته‌بندی موجود در داده‌ها را تعیین کند. برای این کار ماتریسی تشکیل می‌شود که در آن درایه‌ها، فاصله هر نرون با همسایگی‌های خودش است. این ماتریس نرون‌های که نزدیک به یکدیگر و یا نرون‌هایی که مقادیر وزنشان با همسایگی‌هایشان بیشتر است با رنگ‌های متفاوت نشان می‌دهد. این نمایش از نرون‌ها، دسته‌بندی موجود در داده‌های ورودی را تا حدودی نشان می‌دهد. این ماتریس را ماتریس  $U$  (آلتسچ، ۱۹۹۳) می‌نامند. در ماتریس  $U$  گروه‌های شبیه به هم با رنگ‌های یکسان نشان داده می‌شوند. این ماتریس نمایش دو بُعدی از بردارهای ورودی است و می‌تواند گروه‌های ذاتی موجود در داده‌های ورودی را نمایش دهد.

اندیس دیویس و بولدین با رابطه زیر محاسبه می‌شود (دیویس و بولدین، ۱۹۷۹).

$$DBI = \frac{1}{P} \sum_{k=1}^P \max_{l \neq k} \left\{ \frac{S_k + S_l}{d_{kl}} \right\} \quad (3)$$

$d_{kl}$  فاصله بین مراکز دو خوشه متفاوت،  $S_k$  میانگین فاصله داده‌های ورودی از مرکز خوشه  $k$  و  $P$  تعداد خوشه‌ها است. با مشخص شدن تعداد خوشه‌های بهینه می‌توان به صورت خودکار، تعداد خوشه‌های موجود در داده‌های اصلی را تعیین کرد. با محاسبه اندیس دیویس و بولدین برای تعداد متفاوتی از خوشه‌ها، کوچک‌ترین اندیس به دست آمده، بهترین خوشه‌بندی را نشان می‌دهد، که در آن داده‌های درون هر خوشه نزدیک‌ترین فاصله را از یکدیگر و مراکز خوشه دارند و نسبت به مراکز دیگر خوشه‌ها بیشترین فاصله را دارند. در حقیقت با استفاده از این کار می‌توانیم به صورت خودکار و بدون ناظر، تعداد خوشه‌های موجود در داده‌ها را به صورت غیر مستقیم تشخیص دهیم.

#### ۴ تعیین تکینگی با استفاده از تبدیل موجک

برای رده‌بندی داده‌های لرزه‌ای در محدوده مخزن، به نشانگر لرزه‌ای نیاز است که به تغییرات جزئی سیگنال در آن محدوده حساس باشد. بی‌نظمی‌ها و نقاط گذار (transitions) موجود در سیگنال، بیانگر اطلاعاتی از پدیده فیزیکی به وجود آورنده آنها است (مالات، ۱۹۹۹). تفسیر لرزه‌ای در حقیقت شناخت دقیق بازتاب‌های لرزه‌ای است که با موجک لرزه‌ای هموار شده‌اند. افزون بر شناخت محل بازتابنده نیاز است که نوع و ویژگی‌های آن بازتابند که نماینده خصوصیات زمین‌شناسی لایه‌ها است شناخته و تفسیر شود. بررسی خصوصیات این بازتابنده‌ها می‌تواند تحلیلی از رخساره‌های لرزه‌ای بازتابنده به دست دهد. تعیین نوع

گذار یا تکینگی در جایی که بازتابنده وجود دارد، با استفاده از یک مفهوم ساده ریاضی قابل تعیین است. نقاط عطف یا تکینگی یک سیگنال، همان نقاط بیشینه مشتق اول و صفرهای مشتق دوم آن هستند (کانی، ۱۹۸۶). از آنجا که تبدیل موجک، همامیخت (convolution) سیگنال لرزه‌ای با یک تابع موجک است، اگر این موجک مشتق درجه اول و یا دوم تابع هموارساز  $\theta(x)$  باشد، آن‌گاه حاصل همامیخت سیگنال با تابع موجک می‌تواند بیانگر نوع تکینگی نقاط متفاوت و نقاط عطف سیگنال باشد (مالات، ۱۹۹۹). حال اگر این تابع موجک با مقیاس‌های متفاوت، با سیگنال لرزه‌ای همامیخت شود و نقاط بیشینه و یا صفر تعیین شوند، در حقیقت توانسته‌ایم به صورت چندمقیاسی به تحلیل سیگنال لرزه‌ای و نقاط تکینگی آن پردازیم.

تابع هموارساز تابع گاوسی و مشتق اول آن موجکی است که به طور کامل می‌تواند انواع تکینگی سری زمانی و سیگنال لرزه‌ای را تعیین کند (مالات، ۱۹۹۹). در شکل ۱ یک سری زمانی با استفاده از تبدیل موجک پیوسته در مقیاس‌های متفاوت تجزیه شده است. همان‌طور که دیده می‌شود، توالی نقاط بیشینه ضرایب تبدیل موجک پیوسته در مقیاس‌های متفاوت با نقاط عطف و نقاطی که در آن بی‌نظمی دیده شده، در سری زمانی منطبق‌اند. خطوطی که این نقاط بیشینه را به یکدیگر متصل می‌کنند خطوط بیشینه ضرایب تبدیل موجک نام دارند. دامنه این خطوط با نام دامنه خطوط بیشینه ضرایب تبدیل موجک WTMMMLA برای تعیین تکینگی سیگنال لرزه‌ای در محل نمونه‌ای مورد نظر به دست آمده است، به کار می‌رود (مالات و وانگ، ۱۹۹۲).

بی‌نظمی سیگنال و تکینگی با استفاده از توان لپزچتر (Lipschitz exponent) نیز قابل بررسی است (مالات، ۱۹۹۹). این توان با نام توان هولدر (Hölder exponent) نیز شناخته می‌شود (مالات، ۱۹۹۹). توان هولدر با استفاده

محاسبه می‌شود و درحکم نشانگر لرزه‌ای در محدوده مخزن به کار می‌رود.

در این مرحله تعداد ۱۶ نمونه از سیگنال‌های لرزه‌ای، در محدوده افق انتخاب و این داده‌ها درحکم ورودی به نرم‌افزار داده می‌شود. بعد از به دست آمدن نشانگر، این نشانگرها درحکم ورودی به شبکه SOM داده می‌شود و در نهایت تعداد خوشه‌ها با استفاده از ضریب DBI به دست می‌آید. بعد از انتخاب بهترین تعداد خوشه، همه داده‌های ورودی، در خوشه نزدیک به خود قرار می‌گیرند. در این مرحله هر خوشه با رنگ مشخصی معرفی می‌شود، بنابراین ما می‌توانیم افق موردنظر را با توجه به دسته‌های تعیین شده ببینیم. از آنجا که ضرایب بیشینه تبدیل موجک به تغییرات سیگنال که در اثر تغییرات سنگ‌شناسی لایه‌ها به وجود آمده است، حساس است می‌توان افق مورد بررسی را با توجه به نوع سنگ‌شناسی آن دسته‌بندی کرد. در اینجا با استفاده از الگوریتم معرفی شده در این تحقیق به بررسی و تحلیل نقشه رخساره لرزه‌ای افق کنگان می‌پردازیم. در تحقیق حاضر ضرایب بیشینه تبدیل موجک به دو روش به دست می‌آید. ابتدا با استفاده از تبدیل موجک پیوسته نشانگر WTMMLA را به دست می‌آوریم و سپس نقشه رخساره لرزه‌ای را برای افق کنگان با استفاده از این نشانگر به دست می‌آوریم.

محدوده مورد بررسی افق کنگان در یکی از میادین نفتی است که تا کنون در آن سه چاه حفر شده است. موقعیت چاه‌ها و نقشه خطوط لرزه‌نگاری برداشت شده، در شکل ۲ نشان داده شده است. نقشه رخساره لرزه‌ای مربوط به افق کنگان به دست آمده از تبدیل موجک پیوسته در شکل ۳ نشان داده شده است. همان‌گونه که در شکل دیده می‌شود، الگوریتم معرفی شده تعداد سه خوشه را برای افق کنگان تعیین می‌کند. در شکل ۳ همچنین محل چاه‌ها روی نقشه رخساره لرزه‌ای به دست آمده، آورده شده است.

از شیب منحنی لگاریتم دوم WTMMLA برحسب لگاریتم دوم مقیاس به دست می‌آید، رابطه (۴).

$$\log_2 |wf(u,s)| \leq \log_2 A + \left(\alpha + \frac{1}{2}\right) \log_2 s \quad (4)$$







در رابطه بالا A ضریب ثابت،  $\alpha$  (آلفا) توان هولدر و S مقیاس تبدیل موجک است. باید توجه داشت که خط WTMML از مخروط تاثیرپذیری فراتر نرود (شکل ۱- و). ساختار این مخروط با توجه به نوع تابع موجک انتخابی و مقیاس تعیین می‌شود. توان لیزچیتز نوع تکنیکی سیگنال را در نقاطی که ضرایب تبدیل موجک بیشینه می‌شود به دست می‌دهد. در شکل ۲ توان لیزچیتز برای نمونه ۶۴ محاسبه و برابر صفر به دست آمده است که با ناپیوستگی که در آن نمونه در سری زمانی دیده می‌شود، منطبق است (مالات، ۱۹۹۹). همان‌طور که گفته شد توان لیزچیتز یا هولدر از بیشینه دامنه ضرایب تبدیل موجک به دست می‌آید. در این تحقیق از این دامنه‌ها درحکم نشانگر لرزه‌ای در محدوده مخزن استفاده می‌کنیم تا بتوانیم افق لرزه‌ای موردنظر را دسته‌بندی کنیم.

## ۵ کاربرد روش برای تحلیل رخساره‌های لرزه‌ای در افق‌های لرزه‌ای

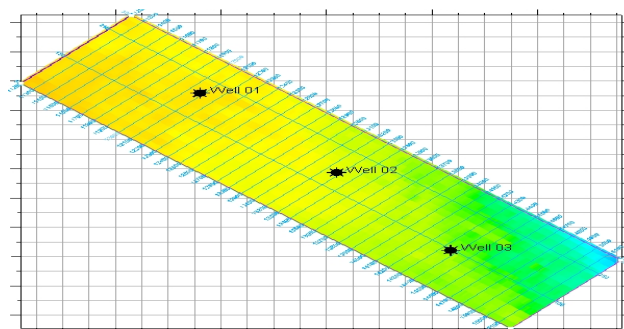
از آنجا که توان هولدر برای همه نمونه‌هایی که دارای تغییرات هستند مقدار می‌گیرد، از این توان می‌شود درحکم نشانگر لحظه‌ای (لینر و اسمیت، ۲۰۰۴) در محدوده مخزن استفاده کرد. در این تحقیق به جای استفاده از توان هولدر از عامل به وجود آورنده این توان برای تعیین نوع تکنیکی، تغییرات سیگنال لرزه‌ای، خوشه‌بندی و تحلیل رخساره لرزه‌ای استفاده می‌کنیم. برای این کار ابتدا محدوده‌ای از مقطع لرزه‌ای که قرار است تحلیل رخساره‌ای در آن صورت گیرد انتخاب می‌شود. سپس برای این محدوده ضرایب بیشینه تبدیل موجک

این چاه‌ها در اختیار باشد می‌توان نوع و خصوصیات مربوط به خوشه‌ها را تعیین کرد. براساس نتایج خوشه‌بندی، چاه شماره دو به لحاظ خصوصیات موج لرزه‌ای در محدوده گذار بین خوشه‌های دوم و سوم قرار گرفته است و این بیانگر وجود تغییراتی در شرایط سازند کنگان است.

به طوری که در شکل ۳ دیده می‌شود، افق کنگان بیشتر از نوع خوشه دوم و سوم است. با توجه به نقشه رخساره لرزه‌ای به دست آمده، ملاحظه می‌شود که محدوده سرخ‌رنگ که چاه شماره ۳ در آن قرار گرفته است بخش اعظمی از این افق را تشکیل می‌دهد و چاه شماره ۱ نیز در محدوده خوشه‌ی سوم قرار گرفته است. اگر اطلاعاتی از

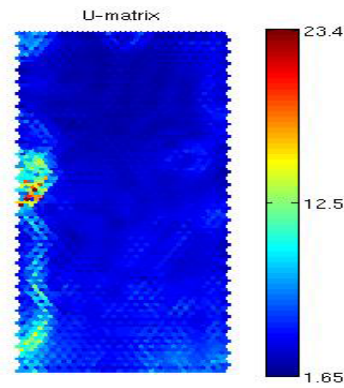


شکل ۱. سیگنال آزمایشی، (الف) سری زمانی، (ب) تبدیل موجک با مقیاس‌های متفاوت، (ج) WTMMMLA، (د) منحنی WTMMMLA برحسب مقیاس، (ه) منحنی لگاریتم دوم WTMMMLA برحسب مقیاس و به دست آوردن توان هولدر و (و) مخروط تاثیرپذیری. (ماتوس و همکاران، ۲۰۰۷).

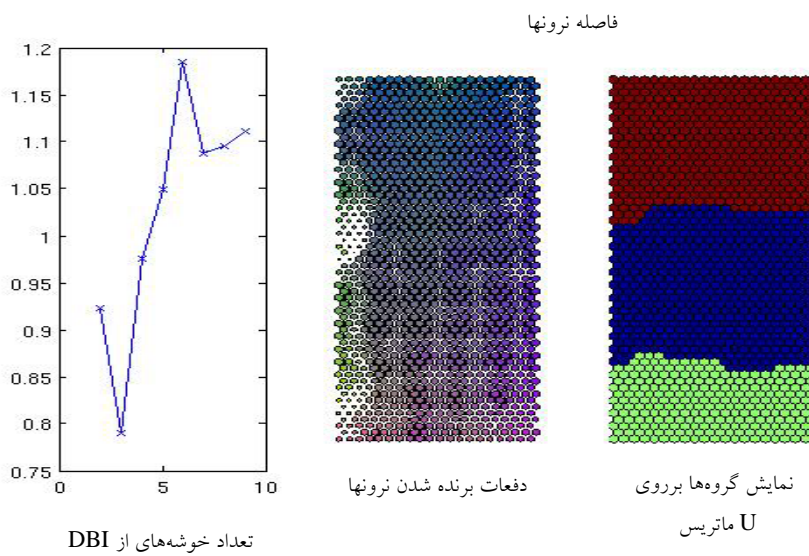


شکل ۲. نقشه خطوط لرزه‌نگاری و محل چاه‌های حفر شده.

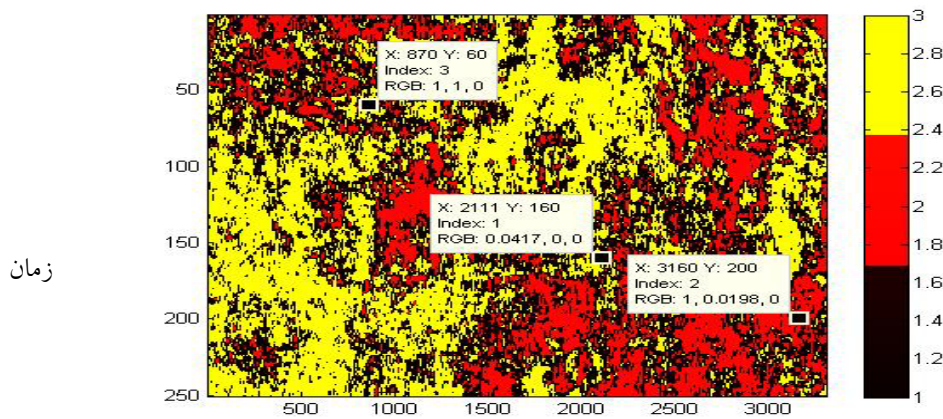




(الف)




(ب)

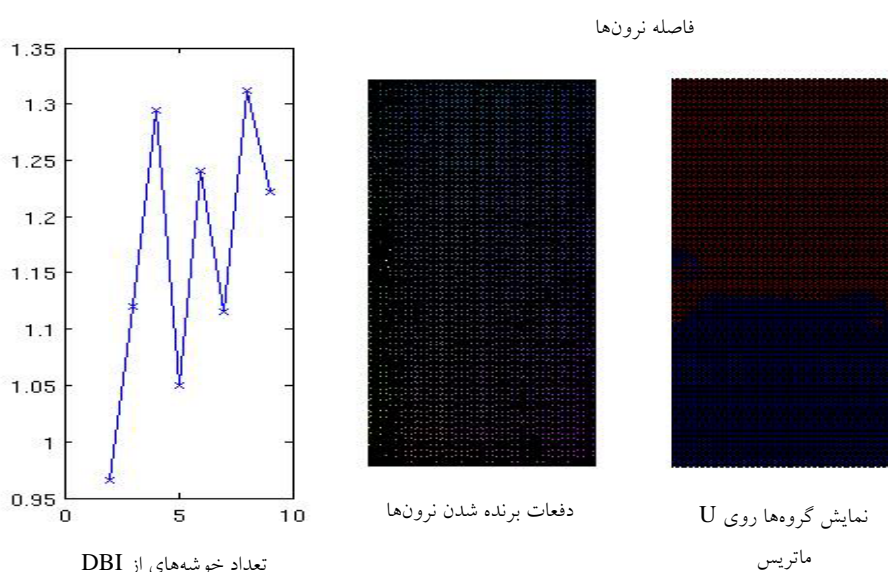


(ج)

شکل ۳. خوشه‌بندی داده‌های لرزه‌ای واقعی برای افق کنگان با استفاده از WTMMLA به‌دست آمده از تبدیل موجک پیوسته و با استفاده از شبکه SOM. (الف) آموزش شبکه و به‌دست آوردن ماتریس U. (ب) تعیین تعداد خوشه‌های موجود درون داده‌ها با استفاده از ضریب DBI و (ج) نقشه رخساره لرزه‌ای افق کنگان.

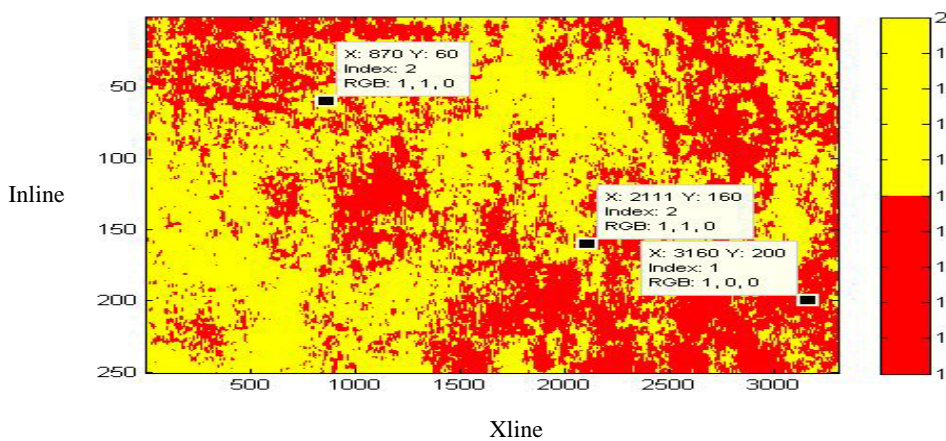


(الف)



تعداد خوشه‌های از DBI

(ب)



(ج)

**شکل ۴:** خوشه‌بندی داده‌های لرزه‌ای واقعی برای افق کنگان با استفاده از WTMMMLA به‌دست آمده از تبدیل موجک گسسته، بدون کاهش نمونه و با استفاده از شبکه SOM، (الف) آموزش شبکه و به‌دست آوردن ماتریس U، (ب) تعیین تعداد خوشه‌های موجود درون داده‌ها با استفاده از ضریب DBI و (ج) نقشه رخساره لرزه‌ای افق کنگان.

بهینه‌ترین تعداد خوشه مطرح شد. این روش به دلیل آزمودن تعداد متفاوتی خوشه‌بندی و سپس پیدا کردن بهترین تعداد خوشه با استفاده از داده‌های لرزه‌ای، کاملاً برحسب تغییرات موجود در ردلرزه‌ها کار می‌کند و دید اولیه مناسبی از مخزن، قبل از حفاری چاه‌های متعدد، به دست می‌دهد.

معمولاً در مواردی که نسبت سیگنال به نوفه کم باشد نمی‌توان رخدادهای لرزه‌ای را به درستی دنبال کرد و در نتیجه، تفسیر به‌خاطر امکان اشتباه در تعیین رخداد لرزه‌ای، منجر به نتایج نادرستی از لرزه‌نگاری خواهد شد. در این تحقیق نشانگر ضرایب بیشینه تبدیل موجک WTMMMLA معرفی شد، این نشانگر به دلیل اینکه خود تعیین کننده رویداد است، این توان را دارد که بتواند رخداد لرزه‌ای را پیدا کند و مشکل کم بودن دقت تعیین رخداد لرزه‌ای را از بین ببرد. در ضمن، روشن شد که استفاده از این نشانگر فقط نیازمند انتخاب تقریبی رخداد لرزه‌ای است، سپس نشانگر می‌تواند محل دقیق رخداد را تعیین و از آن قسمت برای خوشه‌بندی استفاده کند.

#### تشکر و قدردانی

نویسندگان این مقاله از شرکت نفت و گاز پارس به خاطر اجازه استفاده از داده‌های لرزه‌ای و حمایت مالی از جانب آن شرکت تشکر می‌کنند.

#### منابع

- Canny, J., 1986, A computational approach to edge detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, **36**, 961-1005
- Davies, D. L., and Bouldin, D. W., 1979, A cluster separation measure, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-1, 2 224-227.
- Johann, P. R. S., Castro, D. D., and Barroso, A. S., 2001, Reservoir geophysics: Seismic pattern recognition applied to ultra-deepwater oilfield in Campos basin, offshore Brazil, SPE Latin America and Caribbean Petroleum Engineering

در مرحله بعد، نشانگر WTMMMLA با استفاده از تبدیل موجک گسسته بدون کاهش نمونه محاسبه می‌شود. این بار نیز ضرایب بیشینه تبدیل موجک درحکم ورودی به الگوریتم داده می‌شود و نقشه رخصاره لرزه‌ای به دست می‌آید. همان‌گونه که دیده می‌شود، با استفاده از نشانگر حاصل از تبدیل موجک گسسته، بدون کاهش نمونه نیز نتایجی مانند حالت قبل به دست می‌آید (شکل ۴). تنها تفاوت آنها در خوشه‌ای است که در مرحله قبل درحکم منطقه گذر بین دو خوشه اصلی معرفی شد. همان‌گونه که از مقایسه این دو نقشه رخصاره لرزه‌ای به دست می‌آید، دیده می‌شود که هر دوی آنها توانسته‌اند دو خوشه اصلی این سازند را نشان دهند و تقریباً در اکثر نقاط در نوع خوشه مشترک هستند و نقشه یکسانی را نیز نمایش می‌دهند.

معمولاً این نوع بررسی بدون ناظر، بیشتر در مراحل ابتدایی اکتشافی مورد استفاده قرار می‌گیرد و می‌تواند دیدی مناسب از مخزن فراهم کند. در صورت وجود چاه در محدوده مورد بررسی، این اطلاعات کمک می‌کند که ویژگی‌های زمین‌شناختی خوشه‌های موجود در افق را تعیین کنیم و با مشخص شدن این ویژگی‌ها محل مناسب حفاری‌های بعدی پیشنهاد شود.

#### ۶ نتیجه‌گیری

در این تحقیق نقشه‌های خودسازمانده SOM برای خوشه‌بندی اولیه نشان داد که این شبکه توان بالایی در خوشه‌بندی داده‌ها هنگامی که نسبت سیگنال به نوفه کوچک است، دارد. از طرف دیگر چون شبکه SOM یک میانگین محلی از داده‌های لرزه‌ای عرضه شده به دست می‌دهد، روشن شد که از خوشه‌بندی مقادیر وزن حاصل از نقشه‌های خودسازمانده، با استفاده از خوشه‌بندی  $k$ -mean می‌توان حساسیت خوشه‌بندی به نوفه را کاهش داد. در این تحقیق کارایی ضریب DBI برای تعیین

Conference.

- Kohonen, T., 1990, The self-organizing map. Proceedings of the IEEE, **78**(9), 1464-1480.
- Kohonen, T., 2001, Self-organizing maps, 3rd ed. Springer-Verlag.
- Liner, C., and Smythe, j., 2004, SPICE: A new general seismic attribute, 74<sup>th</sup> Annual International Meeting, SEG, Expanded Abstracts, 433-436.
- Mallat, S., 1999, A wavelet tour of signal processing: Academic Press Inc.
- Mallat, S. and Hwang, W. L., 1992, Singularity detection and processing with wavelets, IEEE Trans. Info. Theory, **38**(2), 617-643.
- Matos, M. C., Osorio, P. L. M., and Johann, P. R. S., 2003a, Using wavelet transform and self-organizing maps for seismic reservoir characterization of a deep-water field, Campos basin, offshore Brazil, 65th Annual Conference and Exhibition, EAGE, Extended Abstracts, B29.
- Matos, M. C., Osorio, P. L. M., and Johann, P. R. S., 2003b, Unsupervised seismic reservoir characterization using wavelet transform and self-organizing maps of a deep-water field, Campos basin, offshore Brazil, 73rd Annual International Meeting, SEG, Expanded Abstracts, 1458-1461.
- Matos, M. C., Osorio, P. L. M., and Johann, P. R. S., 2007, Unsupervised seismic facies analysis using wavelet transform and self-organizing maps: GEOPHYSICS, **72**, 9-21
- Taner, M. T., Walls, J. D., Smith, M., Taylor, G., Carr, M. B., and Dumas, D., 2001, Reservoir characterization by calibration of self-organized map clusters, 71st Annual International Meeting, SEG, Expanded Abstracts, **20**, 1522-1525.
- Ultsch, A., 1993, Knowledge extraction from self-organizing neural networks, in Opitz et al., eds., Information and Classification: Springer-Verlag.
- Vesanto, J. and Alhoniemi, E., 2000, Clustering of the self-organizing 12 map, IEEE Transactions on Neural Networks, **11**, 586-600.