

## شناسایی بافت‌های لرزه‌ای در حوزه زمان-بسامد

جلیل ناصری<sup>۱</sup> و حمیدرضا سیاهکوهی<sup>\*۲</sup>

<sup>۱</sup> کارشناس ارشد زئوفیزیک، شرکت Eni  
<sup>۲</sup> دانشیار، گروه فیزیک زمین، مؤسسه زئوفیزیک دانشگاه تهران، ایران  
 (دریافت: ۸۶/۱۰/۸، پذیرش نهایی: ۷۶/۲۸)

### چکیده

هدف از این تحقیق شناسایی تغییر بافت‌های لرزه‌ای با استفاده از تبدیل زمان-بسامد (مقیاس) سیگنال‌های لرزه‌ای است. شناسایی گستره بافت‌های لرزه‌ای می‌تواند در تفسیر داده‌های لرزه‌ای کمک شایانی در تهیه مدل‌های زمین‌شناسی داشته باشد. تبدیل موجک که تصویری از سیگنال در مقیاس‌های گوناگون را عرضه می‌کند در شناسایی بافت‌های لرزه‌ای می‌تواند مفید باشد. انتخاب مناسب تابع موجک در شناسایی نحوه تغییر خواص سیگنال لرزه‌ای (که در اینجا ناشی از تغییر در بافت لرزه‌ای است) در امتداد خط لرزه‌نگاری و در یک بازه زمانی مشخص، نقش بسزایی دارد. بیشینه و کمینه دامنه ضرایب موجک به دست آمده از تجزیه سیگنال با به کارگیری تبدیل موجک گسسته پایا (بدون کاهش تعداد نمونه)، منطبق بر نقاط عطف در دو سوی رویداد لرزه‌ای موردنظر است. در این تحقیق این بیشینه و کمینه‌ها در حکم نشانگرهایی (Seismic attribute) به کار می‌روند که می‌توانند تغییرات بافت لرزه‌ای (Seismic texture) را نمایان سازند.

برای تعیین گستره تغییرات و دسته‌بندی نشانگرهایی به دست آمده در حوزه زمان-بسامد، از ابزار ریاضی بنام ماشین پایه‌برداری استفاده شده است. ماشین پایه‌برداری برخلاف روش‌های مرسوم دیگر (مانند شبکه عصبی) که سعی در کمینه ساختن خطای آموزش دارند، این روش سعی در کمینه کردن حد بالایی خطای تعمیم برای بیشینه‌سازی حاشیه بین صفحه جدایش چندبعدی و داده‌ها دارد (اسکالکوپ و همکاران، ۱۹۹۶). ما از ماشین پایه‌برداری برای دسته‌بندی نشانگرهایی به دست آمده از تبدیل موجک استفاده کردیم که احتمال می‌رود بافت لرزه‌ای در آنها تغییر کرده باشد.

واژه‌های کلیدی: تبدیل موجک، تفسیر مقاطع لرزه‌ای، تحلیل بافت‌های لرزه‌ای، SVM دسته بندی بروش

## Seismic texture recognition in time-frequency domain

Naseri, J.<sup>1</sup> and Siahkoohi, H. R.<sup>2</sup>

<sup>1</sup> M. Sc. in Geophysics, Earth Physics Department, Institute of Geophysics, University of Tehran, Iran  
<sup>2</sup> Associate Professor, Earth Physics Department, Institute of Geophysics, University of Tehran, Iran

(Received: 1 Sep 2007, Accepted: 20 Oct 2010)

### Abstract

In seismic exploration studies different types of techniques are used to recognize seismic features in terms of their temporal and spatial spectra. Variations in frequency content are sensitive to subtle changes in reflection information (Castro de matos et al., 2003). In this study the joint time-frequency analysis is used for seismic texture recognition.

Discrete wavelet transform (DWT) without decimation is implemented to identify the seismic trace singularities in each geologically oriented segment along a seismic line within a time window. The DWT involves a decimation operation and a down sampling by a factor of two. This process causes DWT not to be invariant to displacement in time and applicable for detecting and characterizing the singularities. To obtain an invariant

DWT, the down sampling operation is removed from the process. DWT without decimation, known as wavelet a trous, is a signal convolution with filter bank coefficients with  $(2^j - 1)$  zeros inserted between the samples (Matos, 2007).

The mathematical concepts are the basis of detection of singularities in signals. The signal inflection points are associated with the first derivative extremes. A differentiable smoothing function  $\theta(x)$ , with integral equal to one, is defined, which converges to zero when  $x$  tends to  $\pm\infty$ . Since the integral of  $\psi^\alpha x = d\theta(x)/dx$  and  $\psi^\alpha x = d\theta^2(x)/dx^2$  are zero in the interval of  $-\infty \leq x \leq \infty$  they can be considered as a wavelet. In this way, the WT of a signal  $f(x)$ , in the scale  $s$ , can be obtained by convolving the signal with a scaled wavelet;  $W_s^a f(x) = f * \Psi_s^a(x)$ ,  $W_s^b f(x) = f * \Psi_s^b(x)$ . If the wavelets are substituted by the derivatives of smoothing function into the last equations, they change to;  $W_s^a f(x) = s \frac{d}{dx} (f * \theta_s)(x)$ ,  $W_s^b f(x) = s^2 \frac{d^2}{dx^2} (f * \theta_s)(x)$ . Hence, the wavelet transforms  $W_s^a f(x)$  and  $W_s^b f(x)$  are the first and second derivatives of the signal. The local extremes of  $W_s^a f(x)$  and zeros of  $W_s^b f(x)$  correspond to the inflection points of  $f * \theta_s(x)$ . The local changes in the seismic event manifest themselves as changes in the extremes, which are the minimum and maximum amplitudes of each decomposition level of seismic traces derived by DWT without decimation. Hence lateral changes to seismic reflections are characterized by the extremes.

The extremes obtained from decomposition are used as seismic attributes and classified to define the seismic texture variation. A support vector machine (SVM), a learning machine based on statistical learning theory (Vapnik, 1995), is used to classify the attributes. The concept of SVM is based on finding an optimal separating hyperplane, which could be derived either in the input space or in a more generalized feature space.

SVM uses the structural risk minimization principle to construct decision rules that generalize well (Burges, 1998). The SRM method is based on the fact that the test error rate is bounded by the sum of the training error rate and a term which depends on the VC dimension of the learning machine, and generalized by minimizing the summation. For a linear hyperplane the decision function is;  $f(x) = \text{sgn}(w \cdot x + b)$ . The VC dimension can be controlled by controlling the norm of the weight vector  $w$ . Giving training data  $(x_1, y_1), \dots, (x_l, y_l)$ ,  $x_i \in R^N$ ,  $y_i \in \{\pm 1\}$ , a separating hyperplane which

generalized well can be found by  $\min_{w,b,\xi} \frac{1}{2} w^T w + C \sum_{i=1}^l \xi_i$  subject to  $y_i((w^T \Phi(x_i)) + b) \geq 1 - \xi_i$ ,  $\xi_i \geq 0$ ,  $i = 1, \dots, l$ .

The method can be generalized to a nonlinear decision surface by mapping the input nonlinearly into some high dimension space, and finding the separating hyperplane in the space. This is achieved by using different types of kernel functions,  $K(x_i, x_j) = \Phi(x_i)^T \Phi(x_j)$ , instead of ordinary scalar product  $(x \cdot y)$ . Consequently, the generalized decision function for a nonlinear input will be;

$$f(x) = \text{sgn} \left( \sum_{i=1}^l \alpha_i y_i \Phi(x_i)^T \Phi(x) + b \right).$$

Classification can be performed in several dimensions using two or more attributes derived from decompositions. In this instance two attributes are used as inputs for the SVM classifier and the hyperplane separates the regions where the seismic reflections are changing. The hyperplane was constructed by half of the selected training data, and then its accuracy was cross checked by the other half. Finally, all test data is used as input to the classifier. For instance, the seismic textures are classified into two types within a time window of a phantom horizon on a 2D seismic section. The color code of green and white indicate different seismic textures on the color band.

**Key words:** wavelet transform, seismic interpretation, texture analysis, SVM classification

## ۱ مقدمه

دسته‌بندی ردلرزه‌ها در تفسیر داده‌های لرزه‌ای به کار روند، نشان داده است (مارفورت و کرلین، ۲۰۰۱؛ گراب و والدن، ۱۹۹۷).

چون تغییر محتوای بسامدی متأثر از تغییرهای کوچک مقیاس ویژگی‌های کشسانی در محیط انتشار است، در این تحقیق از تبدیل موجک در حکم ابزاری برای شناسایی این تغییرها استفاده شده است. هدف در اینجا به دست آوردن نشانگرهایی است که بتوانند تغییرهای بافت لرزه‌ای را در ردلرزه‌ها تعیین کنند.

در ادامه تحقیق از ابزار ریاضی دیگری به نام ماشین پایه‌برداری (Support Vector Machine (SVM)) استفاده می‌شود تا نشانگرهای به دست آمده از تبدیل موجک را براساس تغییرات آنها دسته‌بندی کنیم. این دسته‌بندی گستره تغییرهای بافت لرزه‌ای را نتیجه می‌دهد. نشانگرها را می‌توان به تعداد دسته‌های موردنیاز که شناسه‌ای برای بافت‌های گوناگون باشند دسته‌بندی کرد. ماشین پایه‌برداری را وینیک (1995) و محققان دیگر، براساس نگرش‌های جدید یادگیری آماری به طور جدی در حدود یک دهه گذشته بنا نهاده‌اند. این شیوه از یادگیری آماری با ترسیم کردن داده‌ها به فضایی با بعد بالاتر، یادگیری خطی را عملی می‌سازد. برخلاف روش‌های مرسوم دیگر (مانند شبکه عصبی) که سعی در کمینه کردن خطای آموختش دارند، ماشین پایه‌برداری

ردلرزه‌ها نمایشی از سری بازتاب لایه‌های زیرین زمین با باند بسامدی محدودتر از واقعیت است. این امر به خاطر همامیخت موجک لرزه‌ای (با باند بسامدی محدود) با سری زمانی ضرایب بازتاب است. ضرایب زیر سطح زمین به واسطه لایه‌بندی‌ها، گسل‌ها، درزهای و مانند آن، ناهمگونی زیادی دارد و این امر باعث می‌شود که مدل‌های به دست آمده از بررسی‌های لرزه‌ای به نوعی وابسته به مقیاس باشند. پس در بررسی داده‌های لرزه‌ای از جنبه مقیاس آنها نمی‌توان چشم‌پوشی کرد، به ویژه آنکه وابستگی داده‌های لرزه‌ای به مقیاس به بیانی با بسامد غالب موجک هم ارتباط دارد.

سیگال‌های لرزه‌ای نشانگر تغییر در مقاومت صوتی (Acoustic impedance) لایه‌ها هستند و می‌توان گفت که شکل موج امواج بازتابی متأثر از تغییر رخساره‌های زمین‌شناسی بین واحدهای چینه‌ای است (کاریلات و همکاران، ۲۰۰۳).

روش طیف توان در تحلیل‌های حوزه بسامد برای تفسیر داده‌های لرزه‌ای و تعیین لایه‌های نازک به کار گرفته شده است. اما طیف توان چگونگی تغییر محتوای بسامدی با زمان را آشکار نمی‌سازد. الگوریتم‌های زمان-بسامد را می‌توان برای تعیین این ویژگی مورد استفاده قرار داد. در این راستا تبدیل موجک گسسته قابلیت خود را برای تهیه نشانگرهای لرزه‌ای که می‌توانند برای تعیین ویژگی‌ها و

و با قرار دادن مشتق‌های تابع هموارساز در رابطه‌های ۳ به دست خواهد آمد:

$$\begin{aligned} W_s^a f(x) &= s \frac{d}{dx} (f * \theta_s)(x) , \\ W_s^b f(x) &= s^r \frac{d^r}{dx^r} (f * \theta_s)(x) \end{aligned} \quad (4)$$

مشاهده می‌شود که تبدیل‌های موجک  $W_s^a f(x)$  و  $W_s^b f(x)$  در مقیاس  $s$  به ترتیب مشتق اول و دوم سیگنال است. بنابراین حدّهای محلی  $W_s^a f(x)$  مربوط به صفرهای  $W_s^b f(x)$  است که منطبق بر نقاط عطف  $f * \theta_s(x)$  هستند. برای تعیین موقعیت نقطه‌های عطف، با استفاده از موقعیت بیشینه‌های محلی تبدیل موجک، لازم است که موجک به صورت مشتق اول تابع  $\theta(x)$  انتخاب شود.

تبدیل موجک پیوسته خانواده‌ایی از تابع‌ها را مورد استفاده قرار می‌دهد که به طور پیوسته با مقیاس  $s$  تغییر می‌کنند و با پارامتر  $u$  جایه‌جا می‌شوند. تبدیل موجک پیوسته دارای افروزی (Redundancy) است و خیلی کاربردی نیست و این ویژگی از نقاط صعف آن به شمار می‌آید (پانچماکمار، ۲۰۰۳). راه حل برای حذف این ضعف استفاده از تبدیل موجک گستته است که در آن عامل‌های مقیاس و جایه‌جایی بر پایه شبکه گستته زمان-مقیاس ارزیابی می‌شوند و منجر به یک سری گستته از تابع‌های پایه پیوسته می‌شود.

الگوریتم تبدیل موجک گستته بدون کاهش تعداد نمونه، موجک اتروس (wavelet a trous) یا تبدیل موجک پایا نامیده می‌شود. این نوع از تبدیل موجک گستته عبارت است از هماییخت سیگنال با ضرایب فیلترهایی که در آنها به تعداد  $(-1)^j$  صفر بین ضرایب فیلتر وارد شده است (کاسترودوماتوس و همکاران ۲۰۰۳). این امر موجب اتروس نامیده شدن آن شده که در زبان فرانسوی به معنی موجک سوراخدار یا

سعی در کمینه کردن حد بالایی خطای تعییم برای بیشینه‌سازی حاشیه بین صفحه جداش چندبعدی و داده‌ها دارد. ماشین پایه‌برداری حتی به فضای با بعد بالا تحت اصول کمینه‌سازی خطای تجربی که در بسیاری از شبکه‌های عصبی به کار گرفته می‌شود، تعییم داده شده است.

## ۲ تبدیل موجک

هنگامی که یک خانواده از تابع موجک انتخاب شود، تبدیل موجک پیوسته،  $W$ ، تابع  $f(t) \in L^2(\mathbb{R})$  در زمان  $t$  و مقیاس  $s$  به صورت زیر تعیین می‌شود (کیزر، ۱۹۹۴)

$$Wf(u, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} f(t) \Psi^* \left( \frac{t-u}{s} \right) dt = f * \bar{\Psi}_s(u) \quad (1)$$

نقطه‌های عطف یک سیگنال مربوط به حدود مشتق اول است که منطبق بر صفرهای مشتق دوم است. تابع  $\theta(x)$  زا که دوبار مشتق‌پذیر و سطح زیر انتگرال آن مساوی با یک است و با رفتن  $X$  به سمت بی‌نهایت به صفر همگرا می‌شود، انتخاب می‌کنیم. مشتق اول و دوم این تابع را می‌توان به شکل زیر بیان کرد

$$\Psi^a(x) = \frac{d\theta(x)}{dx} , \quad \Psi^b(x) = \frac{d\theta^r(x)}{dx^r} \quad (2)$$

از آنجا که انتگرال‌های  $(x)^a \Psi^a$  و  $(x)^b \Psi^b$  در بازه  $x < -\infty$  صفر است، پس این توابع می‌توانند در حکم تابع موجک در نظر گرفته شوند. تبدیل موجک پیوسته تابع  $f(x)$  در مقیاس  $s$  را می‌توان با هماییخت کردن آن با موجک مقیاس شده به دست آورد. تبدیل موجک پیوسته  $f(x)$  با استفاده از دو موجک تعیین شده در رابطه ۲ بدین شکل است

$$\begin{aligned} W_s^a f(x) &= f * \Psi_s^a(x) , \\ W_s^b f(x) &= f * \Psi_s^b(x) \end{aligned} \quad (3)$$

$f \rightarrow \{ +I, -I \}$  با استفاده از داده‌های آموزشی ورودی-خروجی  $(x_1, y_1), \dots, (x_l, y_l)$  دارد.

به طوری که  $f$ ، براساس همان توزیع احتمال  $P(x, y)$  را در آموزش داده‌ها، الگوهای پیش‌بینی نشده  $(x, y)$  را به درستی طبقه‌بندی کند. ساده‌ترین حالت، داده‌های خطی تفکیک‌پذیر با یک صفحه بدون خطای خطا است. اما در مواردی که داده‌های آموزشی با یک صفحه بدون خطای خطا نمی‌توانند جدا شوند، هدف ساخت صفحه‌ای خواهد بود که کمترین خطای خطا را ایجاد کند. به عبارتی دیگر صفحه‌های جدایش زیادی می‌توان ترسیم کرد اما یکی از آنها بیشترین جدایش را ایجاد می‌کند. نقاط  $x$  که روی صفحه جدایش قرار دارند در رابطه زیر صدق می‌کنند

$$\{x \in F : (w \cdot x) + b = 0\} \quad (6)$$

با توجه به اینکه  $x$  در یکی از دو رده قرار داشته باشد این رابطه به یک نامساوی منجر می‌شود

$$y_i(w \cdot x_i + b) - 1 \geq 0 \quad \forall i \quad (7)$$

در این رابطه‌ها بردار  $w$  عمود بر صفحه است و  $\|w\|$  فاصله عمود از صفحه تا مبدأ و  $\|w\|$  نُرم اقلیدسی  $w$  است. با مقایس دار کردن  $w$  و  $b$  در صفحه جدایش، صفحه‌های گذرنده از نزدیک‌ترین نقطه‌ها به صفحه جدایش به دست می‌آید (شکل ۱).

$$H_1: (w^T x_i) + b = +1 , \quad (8)$$

$$H_2: (w^T x_i) + b = -1$$

فاصله بین این دو صفحه،  $2/\|w\| = 2/\sqrt{w^T w}$  حاشیه جدایش خوانده می‌شود (برگس، ۱۹۹۸). با کمینه ساختن عبارت  $w^T w/2$  بیشینه مقدار فاصله به دست می‌آید

$$\max 2/\|w\| \equiv \min w^T w/2$$

به شرط آنکه

$$y_i((w^T x_i) + b) \geq 1 \quad i = 1, \dots, l \quad (9)$$

صفردار است. یکی از محدودیت‌هایی که این روش ایجاد می‌کند آن است که طول سیگنال باید بر  $\mathcal{Z}$  بخش‌پذیر باشد و  $\mathcal{Z}$  بیشینه سطح تجزیه است.

### ۳ ماشین پایه‌برداری

عمولاً فرایند دسته‌بندی داده‌ها شامل آموزش و آزمایش نمونه‌هایی از داده‌ها است. هر نمونه در سری آموزش شامل یک مقدار هدف و چندین نشانگر است. هدف روش ماشین پایه‌برداری ساختن مدلی است که در آن مقدار هدف برای سری آزمایشی از نمونه‌ها فقط با استفاده از نشانگرهای آنها پیش‌بینی می‌شود.

توانایی تعمیم برای این ماشین یادگیری بر مبنای فاکتورهایی است که در نظریه کمینه‌سازی خطر ساختاری برای کنترل امکان تعمیم فرایندهای یادگیری توصیف شده است. این محدوده کنترل را می‌توان به صورت زیر نوشت

$$R(\alpha) \leq R_{emp}(\alpha) + \Phi(h) \quad (5)$$

که در آن  $R(\alpha)$  محدوده،  $\alpha$  شاخصی برای محدوده،  $R_{emp}$  تابع خطر تجربی،  $\Phi(h)$  بازه اعتماد و  $h$  تعداد بُعدهای ساختار ماشین است.

دو راه موثر برای کمینه ساختن سمت راست این نامساوی وجود دارد. شبکه‌های عصبی اولین جمله را کمینه می‌کنند که موجب آن می‌شود تا جورشدنگی بیش از اندازه ایجاد شود. ماشین‌های پایه‌برداری، برای جلوگیری از جورشدنگی بیش از اندازه، مقدار خطر تجربی را ثابت نگه می‌دارند و بازه اعتماد را کمینه می‌کنند. بدین ترتیب می‌توان با کمینه ساختن این نسبت در مقایسه با بیشینه کردن حاشیه، کنترل بهتری روی تعمیم داشت.

ماشین پایه‌برداری برای شناسایی الگو بر مبنای نظریه یادگیری آماری، سعی برآورد کردن تابع

سوی صفحه گزینش قرار دارد. صفحه گزینش صفحه‌ای در بین  $H_1$  و  $H_2$  و موازی با آنها است. سپس برچسب رده مناسب به آن آرایه داده می‌شود.تابع گزینش به صورت زیر بیان می‌شود

$$f(x) = \text{sgn}(w \cdot x + b) = \text{sgn} \left( \sum_{i=1}^l \alpha_i y_i (x \cdot x_i) + b \right) \quad (11)$$

که  $x$  داده‌های آزمایش،  $w$  متغیرها و  $b$  ضریب هم‌گذار صفحه است.

داده‌ها همیشه به صورت خطی قابل جدایش نیستند. در مواردی که داده‌ها خواه جدایش‌پذیر و خواه جدایش‌ناپذیر غیرخطی هستند، می‌توانند در فضاهای دیگر جدایش‌پذیر خطی باشند (مولر و همکاران، ۲۰۰۱). در چنین مواردی ساختار صفحه جدایش خطی در فضای بعد زیاد صورت می‌گیرد. از این‌رو، بردارهای آموزشی  $x_i$  با تابع  $\Phi$  به فضاهای با بعد زیادتر (که ممکن است بین‌نهایت باشد) ترسیم می‌شوند به طوری که

$$\Phi(x) = (\Phi_1(x), \Phi_2(x), \dots) \quad (12)$$

سپس ماشین پایه‌برداری یک صفحه جدایش خطی را با بیشینه حاشیه پیدا می‌کند. بنابراین مسئله به شکل استاندارد زیر بیان می‌شود (ورگلت، ۱۹۹۷)

$$\min_{w, b, \xi} \frac{1}{2} w^T w + C \sum_{i=1}^l \xi_i \quad (13)$$

مشروط بر اینکه

$$y_i ((w^T \Phi(x_i)) + b) \geq 1 - \xi_i \quad (14)$$

$$\xi_i \geq 0 \quad i = 1, \dots, l$$

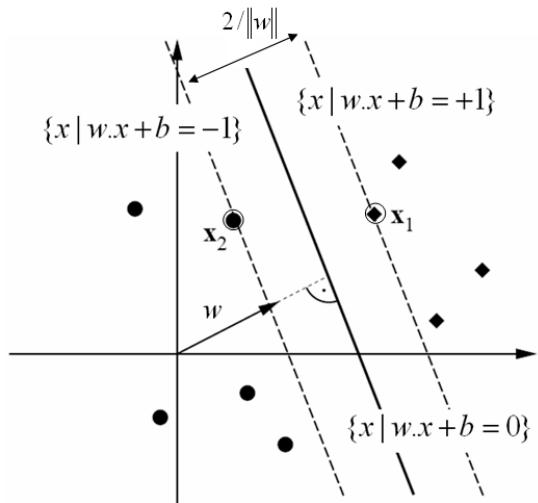
و تابع گزینش برای سری داده‌های غیرخطی به صورت زیر معرفی می‌شود

$$f(x) = \text{sgn} \left( \sum_{i=1}^l \alpha_i y_i \Phi(x_i)^T \Phi(x) + b \right) \quad (15)$$

نقاطه‌های آموزشی که نامساوی (۹) را برآورده می‌سازند و روی یکی از صفحه‌های جدایش  $H_1$  یا  $H_2$  قرار دارند، و همچنین حذف کردن آنها، نتیجه را تغییر می‌دهد، بردارهای پایه (Support Vector) نامیده می‌شوند. این بردارهای در شکل یک با دایره‌های اضافه مشخص شده‌اند.

برای حل مسئله بالا از لاغرانژین استفاده می‌شود. ضریب‌های مثبت لاغرانژ  $\alpha_i$ ،  $i = 1, \dots, l$ ، برای هریک از محدوده‌های نامساوی در رابطه ۹ معرفی می‌شود (گران، ۲۰۰۲).

$$L(w, b, \alpha) \equiv \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i (y_i (w \cdot x_i) + b) \quad (10)$$



شکل ۱. صفحه جدایش و حاشیه جدایش بین صفحه‌های گذرنده موازی با آن از نزدیکترین نقطه‌ها؛ نقطه‌های دارای دایره‌های اضافه، بردارهای پایه هستند.

سپس لاغرانژین، نسبت به  $b$  و  $w$  کمینه می‌شود، در همین حال احتیاج است که مشتق‌های  $L$  نسبت به  $\alpha_i$  میرا شود و همه مشروط بر این است که  $\alpha_i \geq 0$  باشد. هنگامی که ماشین پایه‌برداری آموزش داده شد به آسانی می‌تواند مشخص کند که آرایه آزمایشی  $x$  در کدام

شکل ۳ یک نمونه ردلرزه در بازه زمانی گزیده شده و تجزیه آن در چهار مقیاس از جزئیات و برآوردها را نمایش می‌دهد. خطهای بیشینه ضریب تبدیل موجک مقدارهای بیشینه و کمینه دامنه‌های هر سطح از جزئیات را به هم وصل کرده است و در حکم نشانگر لرزه‌ای برای ویژگی‌های سیگنال در این بررسی به کار می‌روند (مالات، ۱۹۹۹). این کمینه و بیشینه‌ها منطبق بر نقاط عطف پدیده‌ها روی ردلرزه و متاثر از تغییر پدیده‌ها روی ردلرزه‌ها در اثر تغییرهای رخساره‌ای است (واپنار و همکاران، ۲۰۰۵). کمینه و بیشینه مقدار دامنه‌ها در دو سطح اول و دوم از تجزیه ردلرزه‌ها به جزئیات کاملاً قابل تشخیص است و از آنها در حکم نشانگرهای لرزه‌ای استفاده شده است (ناصری، ۱۳۸۶).

شکل ۴ نمایش ماتریسی تجزیه ردلرزه‌ها با استفاده از تبدیل موجک گسسته را نشان می‌دهد. نخستین و دومین سطح از تجزیه‌ها تغییر جانی پدیده‌های بازتابی را به خوبی نمایان می‌سازد که حاصل تغییر بافت لرزه‌ای است. برای آنکه بتوان موقعیت و گستره تغییرهای بافت لرزه‌ای را شناسایی کرد نیاز است که نشانگرهای به دست آمده از تبدیل موجک دسته‌بندی شوند. از این‌رو داده‌ها به آرایش مناسبی برای ورود به ماشین‌های پایه‌برداری انتقال یافتدند. در این دسته‌بندی نشانگرهای در موقعیت تغییرهای بافت لرزه‌ای دارای گُد صفر و در دیگر موقعیت‌ها گُد یک هستند.

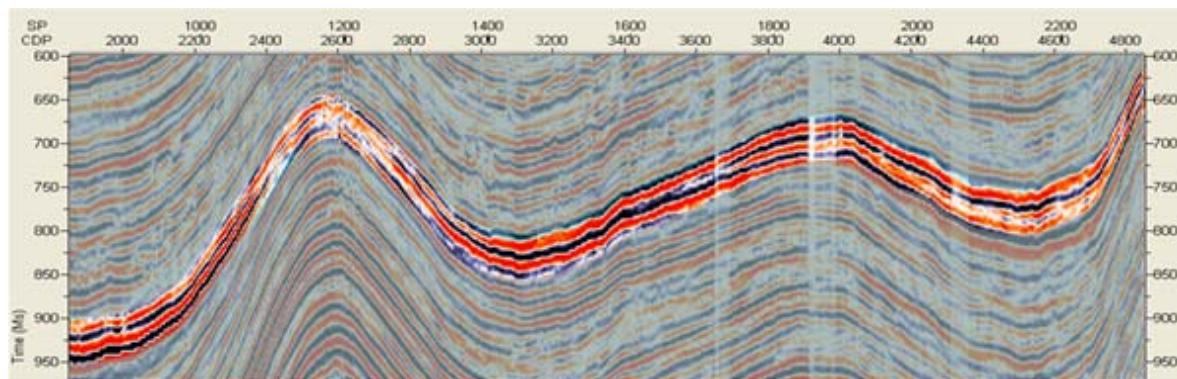
که  $\Phi(x)$  تابع ترسیم به بعد زیاد،  $x_i$  مولفه سری آموزشی،  $x$  نقطه مورد آزمایش است. به جای تعیین تابع ترسیم  $\Phi$ ، ضرب داخلی " $\Phi(x_i)^T \Phi(x)$ " تعیین می‌شود که عبارت از ضرب Feature (Space) است و به صورت یک هسته (کرنل) نمایش داده می‌شود

$$K(x_i, x_j) = \Phi(x_i)^T \Phi(x_j) \quad (16)$$

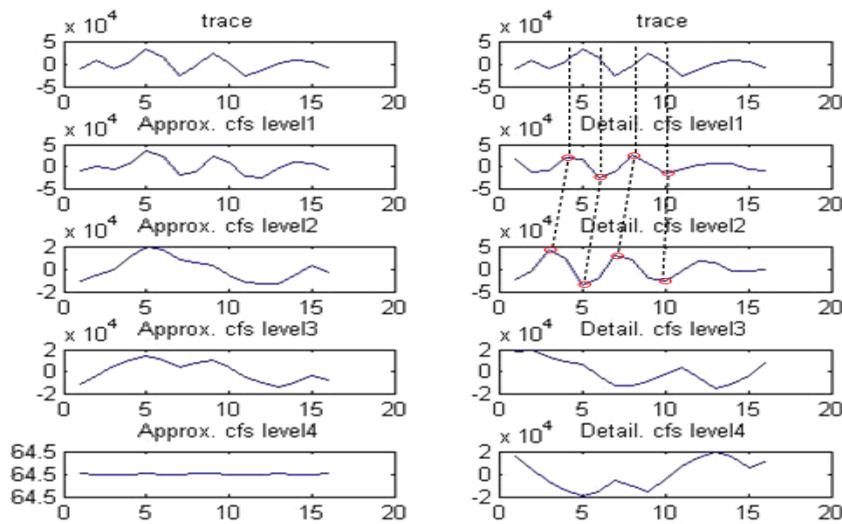
که از آن به نام ترفند هسته یاد می‌شود. ترفند هسته در ماشین‌های یادگیری روشی است برای تبدیل دسته‌بندی کننده‌های خطی به غیرخطی، که مشاهده‌های اصلی را به فضای بُعد زیاد ترسیم می‌کند. به طوری که دسته‌بندی خطی در این فضای جدید معادل دسته‌بندی غیرخطی در فضای اصلی است.

#### ۴ به کارگیری روش روی داده‌های لرزه‌ای

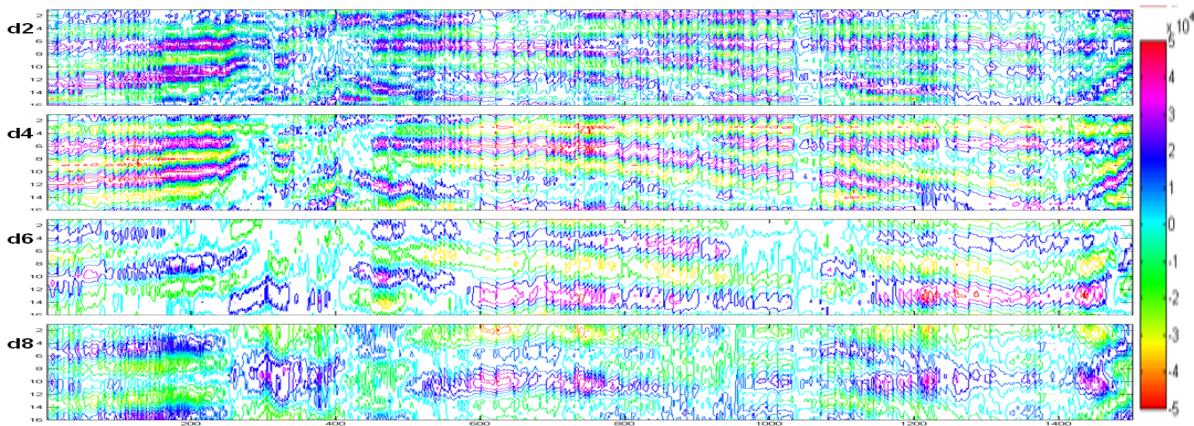
در مقطع لرزه‌ای نشان داده شده در شکل ۲ یک بازه زمانی در امتداد رویداد بازتابی موردنظر به منزله افق موردنظر انتخاب می‌شود (در شکل نسبت به بقیه قسمت‌ها پُررنگ‌تر است). طول این بازه ۶۴ میلی ثانیه و در بردارنده ۱۶ نمونه با فاصله زمانی ۴ میلی ثانیه است. تبدیل موجک گسسته پایا برای ردلرزه‌های موجود در بازه انتخابی از مقطع تا چهار مقیاس محاسبه می‌شود.



شکل ۲. مقطع لرزه‌ای و بازه دلخواه ۱۶ نمونه‌ای که به صورت پُررنگ روی مقطع مشاهده می‌شود.



شکل ۳. بازه زمانی انتخاب شده از ردیلزه (نخستین ردیف) و تجزیه آن در چهار مقیاس به جزئیات (ستون چپ) و به برآوردها (ستون راست). شایان ذکر است که جزئیات و برآوردها دو خروجی تبدیل موجک گستته به ورودی است. خطچین‌ها نشانگر بیشینه و کمینه ضرایب تبدیل موجک هستند که در حکم نشانگر لرزه‌ای به کار رفته‌اند.

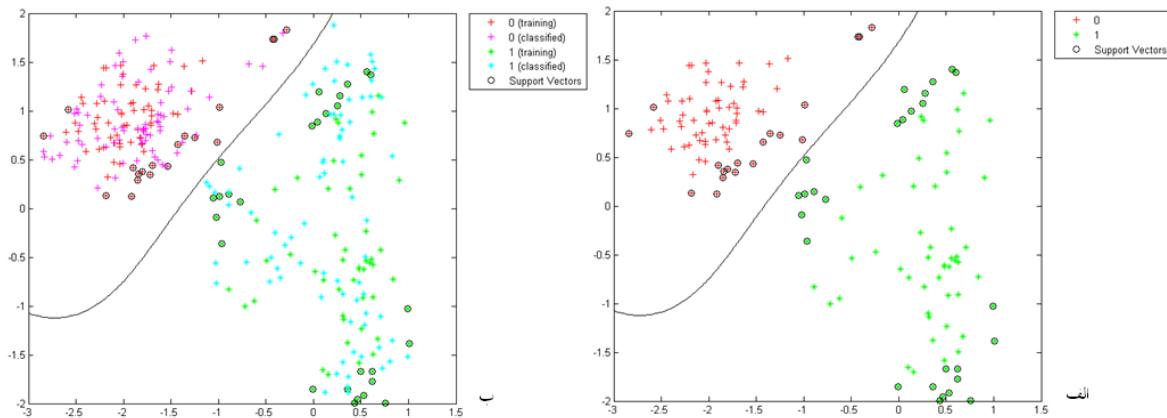


شکل ۴. نمایش ماتریس تجزیه ردیلزه‌ها در بازه انتخاب شده با استفاده از تبدیل موجک.

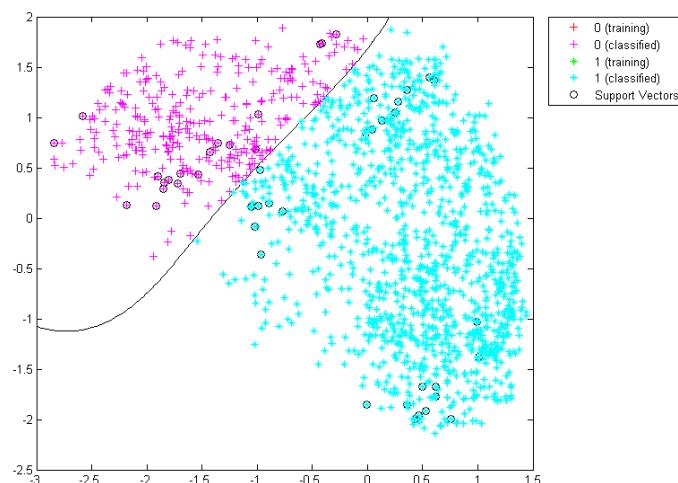
مریبوط به قسمت‌های از مقطع لرزه‌ای است که بافت لرزه‌ای تغییر می‌کند و در مقابل، محیط نشان داده شده با یک مریبوط به بخش‌های بدون تغییر در بافت است.

نمایش این دو دسته در امتداد مقطع لرزه‌ای می‌تواند ناحیه‌هایی از مقطع را نشان دهد که تغییرهای بافت لرزه‌ای وجود دارد. در محدوده CDP ۳۴۰۰ تا ۳۶۵۰ و همچنین ۲۳۵۰ تا ۲۷۵۰ تغییرهای بافت لرزه‌ای شناسایی شده است (شکل ۷).

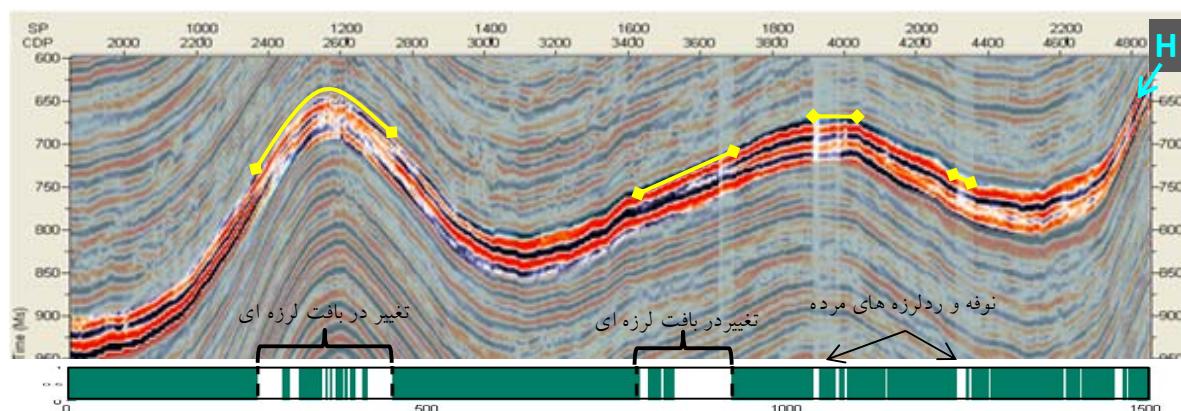
تعداد ۳۰۰ جفت داده آموزشی از حالت‌های متفاوت بافت لرزه‌ای از دامنه‌های بیشینه و کمینه سطح دوم تجزیه انتخاب و به دو بخش ۱۵۰ جفتی تقسیم شد. سپس آموزش با استفاده از هسته تابع پایه شعاعی روی یک بخش صورت گرفت (شکل ۵\_الف) و با بخشی دیگر درستی این آموزش تایید شد (شکل ۵\_ب). سپس داده‌های آزمایشی که عبارت از دامنه‌های به دست آمده از همه ردیلزه‌ها است، با استفاده از این صفحه جدایش دسته‌بندی شد (شکل ۶). محیط نشان داده شده با صفر



شکل ۵. بردارهای پایه که صفحه جدایش را بنا نهاده‌اند و با دایرهای مشکی نمایان شده‌اند، دو محیط متفاوت بافت لرزه‌ای را از هم جدا کرده‌اند. الف- آموزش با ۱۵۰ جفت نمونه نخست و ساخت صفحه جدایش، ب- تایید درستی آموزش با ۱۵۰ جفت نمونه دوم با دسته‌بندی شدن درست داده‌ها.



شکل ۶. دسته‌بندی شدن نشانگرهای لرزه‌ای با صفحه جدایش.



شکل ۷. نوار دو رنگ سبز و سفید به دست آمده از دسته‌بندی است. رنگ سفید بیانگر موقعیت تغییرهای بافت لرزه‌ای است. برهم‌نهی موقعیت برخی نوارهای باریک سفید با ردلرزه‌های دارای نوفه نیز آشکار است.

بافت لرزه‌ای تغییر می‌کند. تغییر بافت لرزه‌ای می‌تواند متاثر از تغییر رخسارهای زمین‌شناسی باشد.

#### منابع

- ناصری، ج.، ۱۳۸۶، تحلیل بافت‌های لرزه‌ای با استفاده از تبدیل موجک، پایان‌نامه کارشناسی ارشد، دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران.
- Burges, C. J. C., 1998, A tutorial on support vector machines for pattern recognition: Kluwer Academic Publishers.
- Carrillat, A., Randen, T., Sonnenland, L. and Elvebakk, G., 2003, 3D Texture attributes aid seismic facies classification: Offshore, February.
- Castro de Matos, M., Léo Manassi, O. P. and Schroeder, P. R., 2003, Unsupervised seismic facies analysis using wavelet transform and self-organizing maps: Military Institute of Engineering–Brazilian Army.
- Gran, F., 2002, Pattern recognition using SVM: Mathematikcentrum LTH.
- Grubb, H. J. and Walden, A. T., 1997, Characterizing seismic time series using the discrete wavelet transform: Geophysical Prospecting, **45**, 183-205.
- Kaiser, G., 1994, A friendly guide to wavelets: Birkhauser.
- Mallat, S., 1999, A wavelet tour of signal processing: Academic Press.
- Marfurt, K. J., Kirlin, R. L., 2001, Narrow-band spectral analysis and thin-bed tuning: Geophysics, **66**, 1274-1283.
- Muller, K., Sebastian, M., Gunnar, R., Koji, T. and Bernhard, S., 2001, An Introduction to kernel-based learning algorithms, IEEE Transaction on Neural Network, **12**(2).
- Panchamkumar, S., 2003, Complex wavelet transform and their application: Department of Electronic and Electrical Engineering, University of Strathclyde.
- Scholkopf, B., Burges, C. and Vapnik, V., 1996, Incorporating invariances in support vector learning machine: Computer Science, **1112**.
- Vapnik, V., 1995, The Nature of Statistical Learning Theory. Springer-Verlag.

در مقایسه با مقطع لرزه‌ای در افق بررسی شده دیده می‌شود که در فاصله CDP ۳۴۰۰ تا ۳۶۵۰ لایه زیرین در افق موردنظر نازک و ناپدید می‌شود. همچنین در فاصله CDP ۲۳۵۰ تا ۲۷۵۰ خود افق مورد بررسی نازک شده و در قسمتی از آن ناپدید می‌شود. این پدیده‌ها می‌توانند بیانگر ناپیوستگی از دید زمین‌شناسی باشد. مکان‌های پراکنده دیگری نیز به صورت تغییر بافت لرزه‌ای مشخص شده است که درست نیست. این مکان‌ها در بیشتر موارد منطبق بر ردلرزه‌های مرده یا دارای نوفه بسیار زیاد هستند. به دلیل دسته‌بندی نشانگرها به دو بخش، نوفه‌ها هم به متزله تغییر در بافت لرزه‌ای نمایان شده‌اند اما با بیشتر کردن تعداد دسته‌ها می‌توان ردلرزه‌های مرده و نوفه‌ها را نیز از دیگر تغییرها در بافت لرزه‌ای جدا ساخت.

#### ۵ نتیجه‌گیری

نشانگرها به دست آمده از تبدیل موجک گسته بدون کاهش نمونه توانایی خوبی در نشان دادن تغییر ویژگی‌های بازتابی و گذردهی موج دارند. این نشانگرها کمینه و یکی‌نیمه مقدارهای به دست آمده از تجزیه ردلرزه‌ها به جزیات، و منطبق بر نقطه‌های عطف ردلرزه‌ها هستند. برای تعیین موقعیت نقطه‌های عطف ردلرزه‌ها با استفاده از موقعیت پیک‌های محلی تبدیل موجک، لازم است که موجک به صورت مشتق اول تابع متقارن  $\theta(x)$  انتخاب شود.

برای نمایش تغییر بافت‌های لرزه‌ای، نشانگرها لرزه‌ای دسته‌بندی می‌شوند. برای این دسته‌بندی ماشین پایه‌برداری با یک هسته مناسب مانند هسته پابه شعاعی انتخاب می‌شود. دسته‌بندی نشانگرها منجر به جدایش بخش‌هایی از مقطع لرزه‌ای در پنجره انتخابی می‌شود که

Vorgelegt, V., 1997, Support vector learning:

Technischen Universität Berlin.

Wapenaar, K., Ranajit, G., Toxopeus, G. and

Fokkema, J., 2005, The wavelet transform as a  
tool for geophysical data integration:  
Integrated Computer-Aided Engineering.