



## فیلتر پخش ناهمسانگرد بهینه شده توسط شبکه استنتاج عصبی - فازی تطبیق پذیر و کاربرد آن در تضعیف نوفه تصادفی در داده‌های لرزه‌ای

روح اله کیمیایی<sup>۱</sup>، حمیدرضا سیاهکوهی<sup>۲</sup>، علیرضا حاجیان<sup>۳\*</sup> و احمد کلهر<sup>۴</sup>

۱- دانشجوی دکتری، دانشکده علوم پایه، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران

۲- استاد، مؤسسه ژئوفیزیک، دانشگاه تهران

۳- استادیار، گروه فیزیک، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران

۴- استادیار، دانشکده مهندسی برق، دانشگاه تهران

دریافت مقاله: ۱۳۹۶/۰۲/۰۳؛ پذیرش مقاله: ۱۳۹۶/۰۴/۳۰

\* نویسنده مسئول مکاتبات: [dralirezahajian@gmail.com](mailto:dralirezahajian@gmail.com)

### چکیده

فیلتر پخش ناهمسانگرد می‌تواند به عنوان یک روش کارآمد سطح نوفه تصادفی را در بسیاری از داده‌های کاهش دهد، هرچند در استفاده از این فیلتر برای داده‌های لرزه‌ای با سطح نوفه بالا، باید جانب احتیاط را در مورد ظهور رویدادهای غیرواقعی در مقطع رعایت نمود. در این مقاله، به عنوان یک راه‌حل به منظور مقابله با این مسئله، با معرفی یک چهارچوب هوشمند خودکار، خروجی بهینه فیلتر، برای هر نقطه از داده‌های ورودی، از طریق شبکه استنتاج عصبی - فازی تطبیق پذیر استخراج می‌شود. آموزش شبکه عصبی - فازی، با استفاده از خروجی فیلتر پخش ناهمسانگرد و نیز خوشه‌بندی فازی و توسط الگوریتم C-Mean تعیین می‌گردد. آزمایش‌های انجام شده در این تحقیق نشان می‌دهد که در مقام مقایسه با فیلتر پخش ناهمسانگرد مرسوم، روش ارائه شده به صورت محسوس، در دستیابی به مقاطع مصنوعی با نسبت سیگنال به نوفه بالاتر، حداکثر به میزان ۳۲٪ عملکرد فیلتر پخش ناهمسانگرد را ارتقا داده است. در داده‌های حقیقی نیز، علاوه بر تضعیف نوفه‌های مقطع، نسبت به حفظ رویدادهای همدوس مقطع، دقیق‌تر عمل کرده است.

### واژگان کلیدی

تضعیف نوفه تصادفی  
فیلتر پخش ناهمسانگرد  
شبکه استنتاج عصبی - فازی تطبیق پذیر  
خوشه‌بندی فازی

## ۱- مقدمه

ثابت نوفه در برداشت داده‌های لرزه‌ای بازتابی، یک موضوع غیر قابل اجتناب است و وابسته به نوع و میزان نوفه رکورد شده، مراحل پردازش و تفسیر داده‌های لرزه‌ای متأثر از این پدیده خواهند بود. نوفه تصادفی لرزه‌ای نیز، که بنا بر تعریف، رابطه فازی مشخصی در اطلاعات متناظر با آن در ردلرزه‌های مجاور وجود ندارد؛ در شمول همین قاعده است و حضور آن در داده‌ها، تأثیر بسزایی در کاهش امکان ردگیری رویدادها در داده‌های برداشت شده دارد (Sheriff, 1997). اگر چه سطح نوفه تصادفی، پس از برابراش داده‌ها به شدت کاهش می‌یابد؛ اما همچنان، وابسته به فولد برداشت داده‌ها، می‌توان حضور نوفه تصادفی را در دورافت‌های بزرگ و زمان رسیدهای بزرگ‌تر، احساس نمود (Broadhead, 2008).

به فراخور ویژگی‌های ساختاری رویدادهای لرزه‌ای در مقطع و نیز سطح نوفه تصادفی رکورد شده، متخصص پردازش داده‌ها می‌تواند با به کارگیری روش‌های متعدد مرسوم، اقدام به تضعیف نوفه‌های تصادفی نماید؛ اما با توجه به این‌که یکی از اولویت‌های اصلی مراحل پردازش، حفظ اطلاعات مربوط به رویدادهای بازتابی است، عملکرد روش‌های به کار گرفته شده، معمولاً به نوعی، مقید به قید مذکور می‌باشند. بعضی از متداول‌ترین روش‌های مرسوم به منظور تضعیف نوفه عبارتند از: فیلتر میان‌گذر فرکانسی (Nikolic, 1975; Stein and Bartley, 1983)، فیلترهای مبتنی بر میانه‌گیری از داده‌ها (Al-Yahya, 1991)، روش‌های مبتنی بر واهمامیخت داده‌ها (Kaboodin and Javaherian, 2010) و فیلترهای اعمال شده در بستر تبدیل‌های فرکانسی و زمان فرکانسی (Neelamani et al., 2008; Lin et al., 2014).

هدف این تحقیق، حصول به روش خودکاری جهت تضعیف نوفه تصادفی بر اساس فیلتر پخش ناهمسانگرد است؛ که بتواند علاوه بر داشتن عملکرد مناسب در تضعیف نوفه، رویدادهای بازتابی موجود در مقطع (به صورت عام، رویدادهای همدوس) را حفظ نماید. با توجه به این نکته که یکی از نقاط ضعف این فیلتر، مبهم سازی و ایجاد رویدادهای غیرواقعی در خروجی است؛ راه‌حلی برای رفع این مشکل ارائه شده است. نخست، پس از مرور اجزای مفاهیم شبکه استنتاج عصبی- فازی تطبیق‌پذیر، انفیس (ANFIS)، خوشه‌بندی فازی و فیلتر پخش ناهمسانگرد، روش ارائه شده به تفصیل تبیین و پس از آن، نتیجه آزمایش‌های ارائه و بررسی شده است.

## ۲- تئوری و روش

### ۲-۱- معماری انفیس

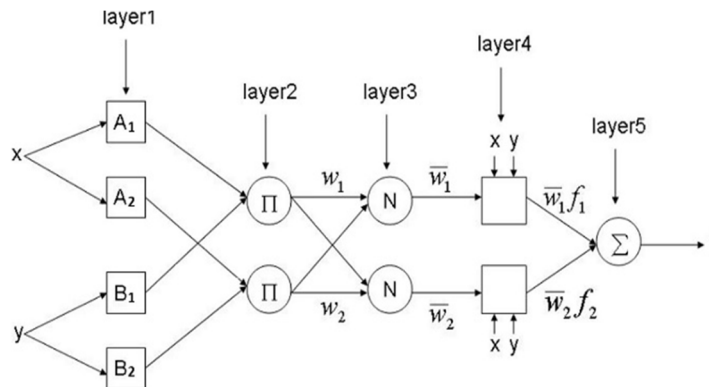
به رغم قابلیت‌های غیرقابل چشم‌پوشی فیلتر پخش ناهمسانگرد، ادبیات مربوط به آن در پردازش داده‌های لرزه‌ای چندان مسبوق به سابقه نیست. بدری و همکاران (Baddari et al., 2011) و شکفته زوارم و همکاران (۱۳۹۴) هر دو با افزایش قابلیت فیلتر پخش در حفظ اطلاعات لبه‌ها (پیوستگی رویدادها و عدم ایجاد رویدادهای کاذب)، از فیلتر پخش به منظور تضعیف نوفه تصادفی در مقاطع مصنوعی و حقیقی استفاده کرده‌اند.

در سال‌های اخیر، روش‌های ارائه شده در بستر محاسبات نرم، توانسته‌اند پاسخگوی بعضی از نیازهای مطالعات ژئوفیزیک باشند (Baan and Jutten, 2000; Aminzadeh and Groot, 2004; Hajian et al., 2012). البته در مطالعات لرزه‌ای نفوذ این روش‌ها بیشتر متمرکز در بخش دسته‌بندی و تفسیر اطلاعات است و متأسفانه بهره حوزه پردازش داده‌ها از روش‌های مبتنی بر هوش مصنوعی چندان زیاد نبوده است و برخی از این تحقیقات در ادامه آمده است.

زانگ و همکاران (Zhang et al., 2010) با استفاده از یک شبکه با معماری پس انتشار (back propagation) و معرفی یک

قانون شماره دو: اگر  $x$  برابر با  $A_2$  باشد و  $y$  نیز برابر با  $B_2$  باشد، آنگاه  $(f_2 = p_2x + q_2y + r_2)$ .

قانون شماره یک: اگر  $x$  برابر با  $A_1$  باشد و  $y$  نیز برابر با  $B_1$  باشد، آنگاه  $(f_1 = p_1x + q_1y + r_1)$ .



شکل ۱: معماری شبکه انفیس با دو قاعده فازی (Jang, 1993).

فیلتر گاوسی استفاده می‌شوند؛ که به مرور و در هر مرحله، از تغییرات سریع در داده‌های ورودی کاسته و سعی در ارائه یک داده بدون نوفه می‌کنند. در خلال فرآیند پخش ناهمسانگرد، با توجه به جهت گرادیان داده‌های محلی در همسایگی هر نقطه از داده‌ها، خروجی فیلتر در مسیر تغییرات اصلی داده‌ها، ارائه می‌شود (Perona and Malik, 1987). بر همین اساس، پارامتری به نام ضریب پخش تعریف می‌شود؛ که می‌تواند نشان‌دهنده شدت تغییرات در نواحی مختلف باشد و با استناد به این ضریب می‌تواند فرآیند تضعیف نوفه را هموارتر سازد. این ضریب که اغلب به صورت ناهمسانگرد و غیرخطی در نظر گرفته می‌شود (Weeratunga and Kamath, 2003)، سنگ بنای ارائه فیلتر پخش ناهمسانگرد است.

معادله پخش برای تصویر  $I(x,y)$  به صورت زیر ارائه می‌شود (Weickert, 1998):

$$\frac{\partial I(x,y,t)}{\partial t} = \frac{\partial^2 I(x,y,t)}{\partial x^2} + \frac{\partial^2 I(x,y,t)}{\partial y^2} \quad (5)$$

حال اگر یک فیلتر گوسی با انحراف معیار  $\sigma$  را به صورت زیر تعریف شود:

$$G_\sigma(x,y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{|x|^2 + |y|^2}{2\sigma^2}\right) \quad (6)$$

در این صورت کانولوشن  $I$  و  $G_\sigma$  برابر خواهد بود با:

$$(G_\sigma * I)(x) = \int G_\sigma(x - \alpha)I(\alpha)d\alpha \quad (7)$$

$$(G_\sigma * I)(y) = \int G_\sigma(y - \beta)I(\beta)d\beta$$

و در حوزه فرکانس، با اعمال تبدیل فوریه،  $\mathcal{F}$  خواهیم داشت:

در این صورت، عملیات انجام شده در هر لایه بدین شرح خواهد بود: در لایه اول، ورودی‌ها، با توجه به توابع عضویت، مقداردهی می‌شوند:

$$O_{1,i} = \mu A_i(x), \quad \text{for } i=1,2 \quad (1)$$

$$O_{1,i} = \mu B_i(x), \quad \text{for } i=3,4$$

در لایه دوم، قوانین اگر-آنگاه ساخته می‌شوند:

$$O_{2,i} = w_i = \mu A_i(x)\mu B_i(y), \quad i=1,2 \quad (2)$$

خروجی لایه دوم، در لایه سوم نرمالایزه می‌شود و سپس در لایه چهارم، نتیجه به دست آمده وزن دهی می‌شود:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i=1,2 \quad (3)$$

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i)$$

درنهایت، خروجی شبکه، به صورت زیر در لایه پنجم به دست خواهد آمد:

$$O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (4)$$

آموزش در این سیستم به این معنی خواهد بود که با توجه به داده آموزش که در واقع زوج‌های ورودی و خروجی شبکه انفیس هستند، توابع عضویت فازی به گونه‌ای تنظیم گردند که به ازای هر ورودی، خروجی مناسب، با خطای قابل قبول، ارائه شود.

## ۲-۲- فیلتر پخش ناهمسانگرد

فیلتر پخش ناهمسانگرد (Anisotropic Diffusion Filtering, ADF)، تلاش می‌کند ضمن حذف نوفه از داده ورودی، تغییرات ماهوی زیادی در داده ورودی ایجاد نکند. در این فیلتر، یک توالی از داده‌های پردازش شده توسط

مورد اقبال محققان نبوده است. خواننده محترم می‌تواند به عنوان نمونه به تحقیقات (Yang et al. 2015; Sun et al. 2016) مراجعه نماید.

### ۲-۳- الگوریتم خوشه‌بندی C-Mean

نخستین الگوریتم C-Mean در سال 1973 ارائه شد و ارائه‌دهندگان آن موفق به ارائه یک خوشه‌بندی دقیق شدند (Duda and Hart, 1973). از آنجا که برخی داده‌ها در این خوشه‌بندی به خوشه‌های متعدد وابستگی و نزدیکی داشتند و امکان قرار دادن آن‌ها در یک خوشه وجود نداشت، دان (Dunn, 1974) نسخه فازی الگوریتم (Fuzzy C-Mean Clusternig, FCM) را ارائه نمود. الگوریتم مذکور، بارها مورد بازبینی قرار گرفت؛ تا در نهایت نسخه نهایی الگوریتم با معرفی m به عنوان مبهم ساز (fuzzifier) توسط بزک (Bezdek, 1981) معرفی شد. الگوریتم حاصل ابرهای کروی از نقاط را در یک فضای p بعدی شناسایی می‌کند. این خوشه‌ها به طور مفروض، تقریباً هم اندازه هستند. هر خوشه با مرکزش نمایش داده می‌شود. این نحوه نمایش خوشه‌ها، مدل یا نمونه نیز نامیده می‌شود؛ زیرا اغلب به عنوان نماینده همه داده‌های تخصیص داده شده به خوشه انگاشته می‌شود. به عنوان یک رابطه برای فاصله‌سنجی، فاصله اقلیدسی بین یک نقطه و یک نمونه مورد استفاده قرار می‌گیرد (در تحقیقات متفاوتی، سایر روابط فاصله سنجی نیز به کار رفته است). در انتخاب مرکز خوشه، همان‌گونه که از اسم الگوریتم پیداست، مقدار میانگین مورد استفاده قرار می‌گیرد.

مشکلی که در ارتباط با این الگوریتم مطرح است، این است که الگوریتم نمی‌تواند خوشه‌هایی با شکل‌ها و اندازه‌ها و چگالی‌های متفاوت را شناسایی کند. برای شناسایی شکل‌های دیگر به جای ماتریس همایی، در تعیین فاصله، می‌توان از ماتریس‌های دیگر بهره گرفت. به عنوان مثال، ماتریس قطری برای تشخیص خوشه‌های بیضوی به کار برده می‌شود. از مزایای این الگوریتم سهولت آن است؛ که منجر به کاهش زمان محاسبات می‌شود. در عمل، با تکرارهای کمی می‌توان به حل قابل قبولی نهایتاً رسید.

مشابه الگوریتم C میانگین (C-Means) کلاسیک، در این الگوریتم نیز تعداد خوشه‌ها، C، از قبل مشخص شده است. تابع هدفی که برای این الگوریتم تعریف شده است به صورت زیر است (Bezdek, 1981):

$$J = \sum_{i=1}^C \sum_{j=1}^n u_{ik}^m d_{ik}^2 = \sum_{i=1}^C \sum_{j=1}^n u_{ik}^m \|x_k - v_i\|^2 \quad (13)$$

$$, 1 < m < \infty$$

در رابطه ۱۳، m یک عدد حقیقی بزرگ‌تر از یک است؛ که در بیشتر موارد برای آن عدد دو انتخاب می‌شود.  $X_k$  نمونه k ام است و  $V_i$  نماینده یا مرکز خوشه i ام است.  $U_{ik}$  میزان تعلق نمونه i ام در خوشه k ام را نشان می‌دهد. d نیز، میزان تشابه (فاصله) نمونه با (از)

$$(\mathcal{F} I)(\omega) = \int I(x) \exp(-i(\omega, x)) dx \quad (8)$$

$$(\mathcal{F} I)(\omega) = \int I(y) \exp(-i(\omega, y)) dy$$

در نتیجه برای کانولوشن تابع گاوسی و داده ورودی، در حوزه فرکانس، خواهیم داشت:

$$(\mathcal{F}(G_\sigma * I))(\omega) = (\mathcal{F}G_\sigma)(\omega) \cdot (\mathcal{F} I)(\omega) \quad (9)$$

و از آنجایی که تبدیل فوریه یک تابع گاوسی، خود نیز یک تابع گاوسی است؛ در نتیجه کانولوشن اعمال شده در حوزه فوریه، مانند یک فیلتر یکنواخت پایین گذر عمل کرده (Weickert, 1998) و مؤلفه‌های متناظر با فرکانس بالاتر را تضعیف می‌کند.

با این توضیحات، برای دستیابی به فیلتر پاشش ناهمسانگرد، در معادله (۵) به ازای  $t = \frac{\sigma^2}{2}$  و  $t_0 = 0$  (Nadernejad and Hassanpour, 2007):

$$\frac{\partial I(x, y, t)}{\partial t} = \nabla \cdot \{r(x, y, t) \nabla I(x, y, t)\} \quad (10)$$

$$I(x, y, 0) = I_0(x, y)$$

r در معادله فوق، ضریب پخش یا انتشار است که اگر مستقل از سه پارامتر x، y و t باشد، معادله پخش توصیف شده را اصطلاحاً یک معادله پخش همسانگرد و در غیر این صورت ناهمسانگرد می‌گویند. یکی از متداول‌ترین معادلات ارائه شده به منظور محاسبه ضریب پخش، معادله ارائه شده توسط پرونا و ملک (Perona and Malik, 1987) است:

$$r(x, y, t) = \frac{1}{1 + \frac{|\nabla I|^2}{k^2}} \quad (11)$$

در معادله فوق، k، ضریب بازگشتی نامیده می‌شود و مقدار آن که تأثیر زیادی در حفظ لبه‌ها و نیز میزان هموارسازی داده ورودی دارد؛ بین ۵ تا ۱۰۰ انتخاب می‌شود. با توجه به ضریب انتشار تعریف شده در معادله (۱۱) خواهیم داشت (Nadernejad and hassanpour, 2007):

$$I(x, y, t + \Delta t) = I(x, y, t) + \Delta t(d_N r_N + d_S r_S + d_W r_W + d_E r_E) \quad (12)$$

$d_i$  ها و  $r_i$  ها، به ترتیب، نمایانگر گرادیان‌ها و نیز ضرایب انتشار محاسبه شده در چهار جهت اصلی و در همسایگی‌های هر نقطه از داده ورودی هستند. البته می‌توان به غیر از چهار جهت اصلی، با تعیین همسایگی بزرگ‌تر، در سایر جهات نیز اقدام به محاسبه گرادیان‌ها و نیز ضرایب تصویر نمود. ویکرت (Weickert, 1998 & 2002) تأثیر مثبت همسایگی  $5 \times 5$  را در تضعیف نوفه تصادفی از منظر حفظ ساختار و لبه‌های داده‌ها بررسی نمود.

در مقام مقایسه با سایر روش‌های تضعیف نوفه، ADF، چندان

داده‌ها (به عنوان مثال، ۵٪ از داده‌های ورودی) محاسبه می‌شود. در مورد درصد مناسب داده‌های آموزشی، لازم به ذکر است که بنا بر آزمایش‌های انجام شده، مقدار مورد اشاره، عملکردی مناسبی در خروجی روش داشته است. بعد از این مرحله، مقدار انحراف معیار خروجی فیلترهای یاد شده، برای هر نقطه محاسبه می‌شود. انحراف معیار ذکر شده، به عنوان نشانگری از میزان تعلق هر نقطه به فضای نوفه (و یا رویدادهای همدوس) در نظر گرفته می‌شود. این استدلال بر این فرض استوار است که خصوصیات آماری یک نقطه متناظر با نوفه، از یک نقطه متناظر با یک رویداد همدوس متفاوت است (Fani and Hashemi, 2011) و از لحاظ آماری، این تفاوت در پراکندگی اعداد محاسبه شده برای هر نقطه با تنظیمات متفاوت فیلتر نمایان می‌شود. بازچینی مقادیر متناظر به تمام نقاط انتخاب شده، بر اساس مقدار انحراف معیار محاسبه شده، می‌تواند نقاطی با بیشترین احتمال تعلق به فضای نوفه و رویدادهای همدوس را از همدیگر جدا کند. خوشبختانه هنگام استفاده از شبکه‌های عصبی، نیازی به دانستن روابط ریاضی و تحلیلی بین این اعداد نمی‌باشد و شبکه عصبی می‌تواند حتی با یک معماری ساده، این روابط را شبیه‌سازی کند. برای نقاطی که میزان تعلق آن‌ها به فضای رویدادهای همدوس بیشتر بوده است، خروجی مناسب شبکه مقداری است که با توجه به اندازه انحراف معیار، میانگین وزن‌داری از مقدار خود نقطه و اعداد محاسبه شده به عنوان فیلتر پخش ناهمسانگرد است.

برای نقاط با احتمال تعلق بالاتر به فضای نوفه (نقاطی که میزان انحراف معیار آن‌ها بالاتر از سایر نقاط است)، با توجه به محدودیت‌های گفته شده برای فیلتر ADF و احتمال ایجاد رویدادهای غیرواقعی و هموارسازی لبه‌ها، استناد به خروجی‌های مقادیر ADF به تنهایی کارساز نیست. به همین دلیل، برای این نقاط، با استفاده از خصوصیات آماری مانند میانگین، میانه، اکسترمم و ... که در همسایگی هر نقطه محاسبه شده‌اند، می‌توان ساختار داده‌ها را استخراج نمود. این ساختار می‌تواند در یک بستر نرمالایز شده به حد بالایی و پایینی داده‌های ورودی، به عنوان یک خروجی مطلوب در نظر گرفته شود. ضرورت استفاده از ساختار مذکور در هنگامی که نسبت سیگنال به نوفه پایین باشد، به راحتی احساس می‌شود. به عنوان خروجی مناسب برای نقاطی که شدیداً تحت تأثیر وجود نوفه تصادفی قرار داشته‌اند، به روش مشابه، از میانگین وزن‌دار مجموعه‌ای استفاده می‌شود؛ که در این جا، خروجی خوشه‌بندی فازی نیز به آن مجموعه اضافه شده است و با افزایش تعلق نقطه به فضای نوفه، وزن مربوط به خروجی FCM افزایش می‌یابد. در هر حالت، ورودی شبکه، خروجی‌های فیلتر ADF با تنظیمات مختلف به همراه مقدار اصلی مقطع است. پس از آماده شدن جفت ورودی-خروجی‌ها، شبکه ANFIS آموزش داده شده و سپس با محاسبه فیلتر ADF با تنظیمات قبلی، شبکه آموزش دیده بر روی کل داده‌ها تعمیم داده می‌شود. خروجی این تعمیم دهی، مقطع فیلتر

مرکز خوشه است؛ که می‌توان از هر تابعی که بیانگر تشابه نمونه و مرکز خوشه باشد، به منظور محاسبه این متغیر استفاده کرد. از روی  $U_{ik}$ ، می‌توان یک ماتریس  $U$  تعریف کرد؛ که دارای  $C$  سطر و  $n$  ستون است و مؤلفه‌های آن هر مقداری بین صفر تا یک را می‌توانند اختیار کنند (مقدار توابع عضویت همواره بین این دو عدد قرار می‌گیرند). اگر تمامی مؤلفه‌های ماتریس  $U$  به صورت صفر و یا یک باشند، الگوریتم مشابه  $C$  میانگین کلاسیک خواهد بود. با این‌که مؤلفه‌های ماتریس  $U$  می‌توانند هر مقداری بین صفر تا یک را اختیار کنند؛ اما مجموع مؤلفه‌های هر یک از ستون‌ها باید برابر یک باشد و بنابراین خواهیم داشت:

$$\sum_{i=1}^C u_{ik} = 1, \quad k = 1, \dots, n \quad (14)$$

معنای این شرط این است که مجموع تعلق هر نمونه به  $C$  خوشه باید برابر یک باشد. با استفاده از شرط فوق و کمینه کردن تابع هدف خواهیم داشت:

$$u_{ik} = \frac{1}{\sum_{j=1}^C \left( \frac{d_{ik}}{d_{jk}} \right)^{\frac{2}{m-1}}} \quad (15)$$

$v_{ik} = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m}$   
از این رو، حلقه تکرار الگوریتم هنگامی متوقف می‌شود که شرط زیر برقرار شود (Bezdek, 1981):

$$\max_{ij} \{ |u_{ij}^{k+1} - u_{ij}^k| \} < \varepsilon \quad (16)$$

در اینجا،  $\varepsilon$  شرط اتمام حلقه را تأمین می‌کند و می‌تواند بین صفر و یک باشد و این فرایند همیشه درنهایت به سمت یک کمینه محلی مقعر خواهد شد؛ که این موضوع از نقاط قوت الگوریتم FCM است (Bezdek, 1981).

بر اساس آنچه گفته شد، مراحل الگوریتم  $C$  میانگین بدین صورت است که پس از مقداردهی اولیه برای  $C$ ،  $m$  و  $U_0$ ، خوشه‌های اولیه تخمین زده می‌شوند. پس از آن، مراکز خوشه‌ها،  $v_i$  محاسبه شده و سپس ماتریس تعلق از روی خوشه‌های محاسبه شده استخراج می‌شوند. در این صورت اگر  $\|U^{t+1} - U^t\| \leq \varepsilon$ ، الگوریتم خاتمه می‌یابد و در غیر این صورت موقعیت مراکز خوشه‌ها تغییر می‌یابد.

حساسیت به نوفه و زمان محاسباتی زیاد، از جمله نقاط ضعف این الگوریتم هستند؛ که البته با توجه به حسن بزرگ بدون نظارت بودن این الگوریتم، اشکالات مذکور نمی‌توانند مانع از به کارگیری آن باشند. هرچند تلاش‌های مثبتی برای رفع این مشکلات نیز انجام شده است (Wang, 2006).

## ۲-۴- روش پیشنهادی

در روش ارائه شده در این تحقیق و در اولین قدم، فیلتر پخش ناهمسانگرد، با تنظیمات متفاوت (به عنوان مثال با ضرایب بازگشتی مختلف از ۵ تا ۸۰ با گام‌های افزایشی ۵ تایی) برای درصدی از

کیمیایی و همکاران، فیلتر پخش ناهمسانگرد بهینه شده توسط شبکه استنتاج عصبی- فازی تطبیق پذیر و کاربرد آن در تضعیف نوفه تصادفی در ...، صفحات ۴۴۰-۴۲۹. در شکل ۲، بیانگر عملکرد ضعیف تر فیلتر AOADF، در سطح نوفه پایین تر و عملکرد قوی تر آن در سطوح نوفه بالاتر، است. به عنوان یک ابزار کمی، با توجه به در دسترس بودن مقطع بدون نوفه در آزمایش‌های مبتنی بر داده‌های مصنوعی، از شاخص PSNR (Peak Signal to Noise Ratio) به صورت زیر استفاده شده است:

$$PSNR = 10 \log \left( \frac{\text{Max}(\text{In})^2}{\text{Mean Squared Error}(\text{Ref}, \text{In})} \right) \quad (17)$$

در این رابطه، In، مقطع حاوی نوفه و یا فیلتر شده و Ref، مقطع بدون نوفه است. در شکل ۲، PSNR محاسبه شده برای هر مقطع ارائه شده است. همان‌گونه که مشاهده می‌شود، در بالاترین سطح، عملکرد AOADF، ۳۲ درصد بیشتر از ADF است؛ که مربوط به زمانی است که واریانس نوفه برابر چهار بوده است.

در شکل ۴، ردیف ۷۵ام داده‌های بدون نوفه، حاوی نوفه و فیلتر شده مربوط به مقاطع شکل ۲ آمده است. همان‌گونه که مشاهده می‌شود، سری زمانی مربوط به خروجی روش ارائه شده، نزدیکی بیشتری با داده‌های اصلی به خصوص در سطوح نوفه بالاتر داشته است. به منظور دستیابی به یکی معیار کمی دیگر، از میانگین مربعات خطای محاسبه شده بین مقادیر واقعی و فیلتر شده، استفاده شده است. خروجی این محاسبات در جدول ۱ آمده است. چنانچه مشاهده می‌شود، سطح نوفه پایین (شکل ۴a)، عملکرد روش ADF با اختلاف اندک، مناسب‌تر بوده است؛ اما با افزایش سطح نوفه، به وضوح عملکرد روش ارائه شده، بهتر شده است.

نه تنها مقایسه بصری نتایج شکل‌های d۶ و e۶ نشان از برتری روش ارائه شده در حذف رویدادهای تصادفی موجود در مقطع دارد؛ بلکه تفاضل خروجی مقطع حاوی نوفه از مقطع فیلتر شده نیز نشان می‌دهد، سطح نوفه بیشتری در روش ارائه شده، شناسایی و حذف شده است. این در حالی است که شکل ۶c رویدادهای همدوس در مقام مقایسه با شکل b۶ به وضوح قابلیت پیگیری بیشتری پیدا کرده و تقویت شده‌اند.

شده توسط AOADF (ANFIS Optimized Antistrophic Diffusion Filtering) خواهد بود.

### ۳- آزمایش‌ها

به منظور ارزیابی صحیح و قابل اتکا، روش ارائه شده بر روی داده‌های مصنوعی و حقیقی اعمال شده و نتیجه با خروجی فیلتر پخش ناهمسانگرد مرسوم مقایسه شده است.


اولین داده مورد استفاده یک داده پس از برانبارش مصنوعی است که متناظر با یک توالی شیب‌دار از لایه‌هاست که در آن شکستگی‌های شیب‌داری نیز اعمال شده است (شکل ۲a). سه سطح متفاوت از نوفه گاوسی، با میانگین متناظر با میانگین داده‌های ورودی و واریانس‌هایی برابر با یک (شکل ۲b)، دو (شکل ۲c) و چهار (شکل ۲h)، به داده اصلی و بدون نوفه اضافه شده است. برای این مقطع مصنوعی (و نیز سایر مقاطع مورد استفاده در این تحقیق)، پنج درصد از کل داده ورودی، به عنوان داده آموزشی شبکه انفیس، استفاده شده؛ که این مقدار به صورت تصادفی از بین کل نقاط مقطع انتخاب شده است. فیلتر ADF با پانزده مقدار متفاوت برای ضرایب بازگشتی محاسبه شده و مقدار انحراف از معیار این پانزده خروجی، به عنوان معیار تفکیک نقاط با بیشترین احتمال تعلق به فضای نوفه و رویدادهای همدوس در نظر گرفته شده است. معادله (۱۱) به عنوان معادله انتشار ADF استفاده شده و از آنجایی که هدف اصلی تحقیق، دستیابی به یک چهارچوب بهینه‌سازی برای فیلتر ADF است؛ تأثیر این انتخاب در روند آزمایش‌ها بررسی نشد.

در شکل ۳ نمایشی از انحراف معیارهای محاسبه شده برای پنج درصد از داده‌های شکل ۲b ارائه شده است. فرآیند خوشه‌بندی فازی داده‌های آموزشی با استفاده از مقدار اکسترمم داده‌ها، در پنجره‌هایی با طول هفت نمونه، برای هر نقطه و همسایگی سه در سه آن انجام شده است.


مقایسه بصری و کیفی خروجی فیلترهای ADF و AOADF

جدول ۱: میانگین مربعات خطای محاسبه شده بین داده اصلی و فیلتر شده در شکل ۴.


واریانس نوفه	$\sigma_n^2 = 1$	$\sigma_n^2 = 2$	$\sigma_n^2 = 4$
ADF	MSE=0.2849	MSE=0.6239	MSE=1.2458
AOADF	MSE=0.3019	MSE=0.3216	MSE=0.6322



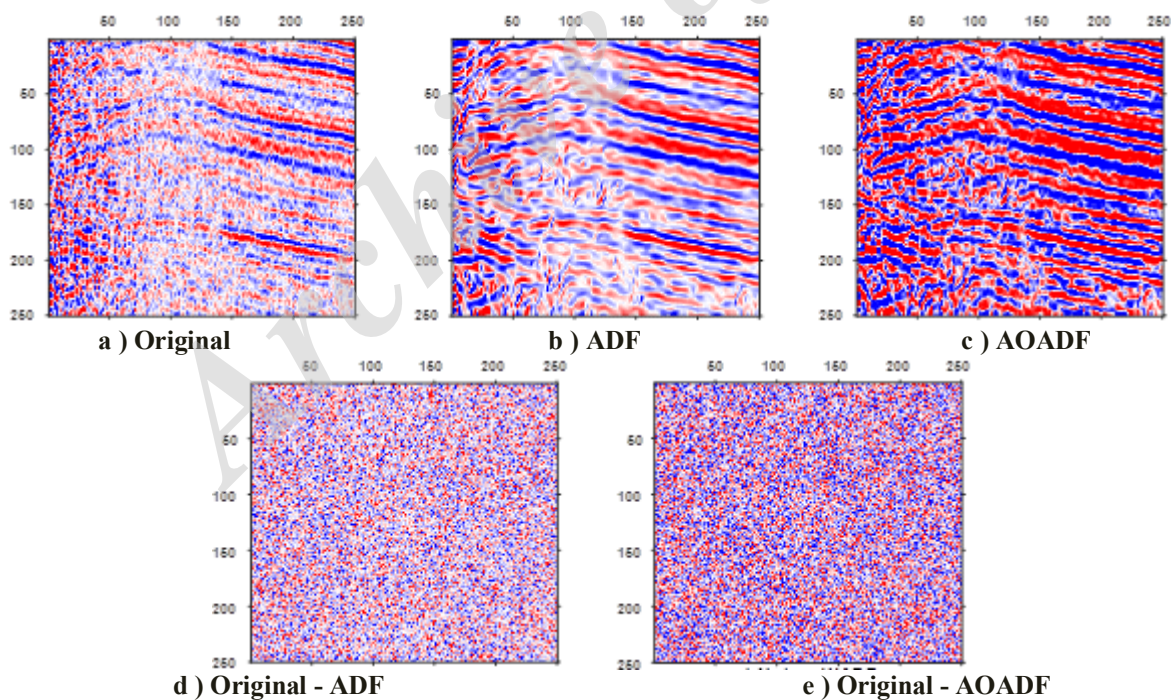
شکل ۲: یک داده پس از انبارش مصنوعی با رویدادها و شکستگی‌های شیب‌دار (a)، داده‌های حاوی نوفه و خروجی فیلترهای ADF و AOADF (b تا j). شاخص PSNR محاسبه شده بین داده اصلی بدون نوفه و داده‌های حاوی نوفه و فیلتر شده، در زیر هر مقطع آمده است. مربع سمت راست در هر شکل مربوط به قسمتی است که داده ورودی (شکل‌های ۲-b، ۲-e و ۲-h) بدون نوفه بوده و مربع سمت چپ مربوط به قسمتی است که داده ورودی تنها متشکل از نوفه بوده و رویدادهای همدوس در این قسمت وجود نداشته‌اند.



شکل ۳: میزان انحراف معیار محاسبه شده برای خروجی ۱۵ فیلتر ADF محاسبه شده برای پنج درصد از داده‌های شکل ۲-b. مستطیل سبز، نشانگر نقاطی است که بیشترین احتمال تعلق به فضای رویدادهای همدوس را داشته‌اند و مستطیل بنفش، متناظر با نقاطی است که احتمال تعلق آنها به فضای رویدادهای تصادفی بیشتر است.

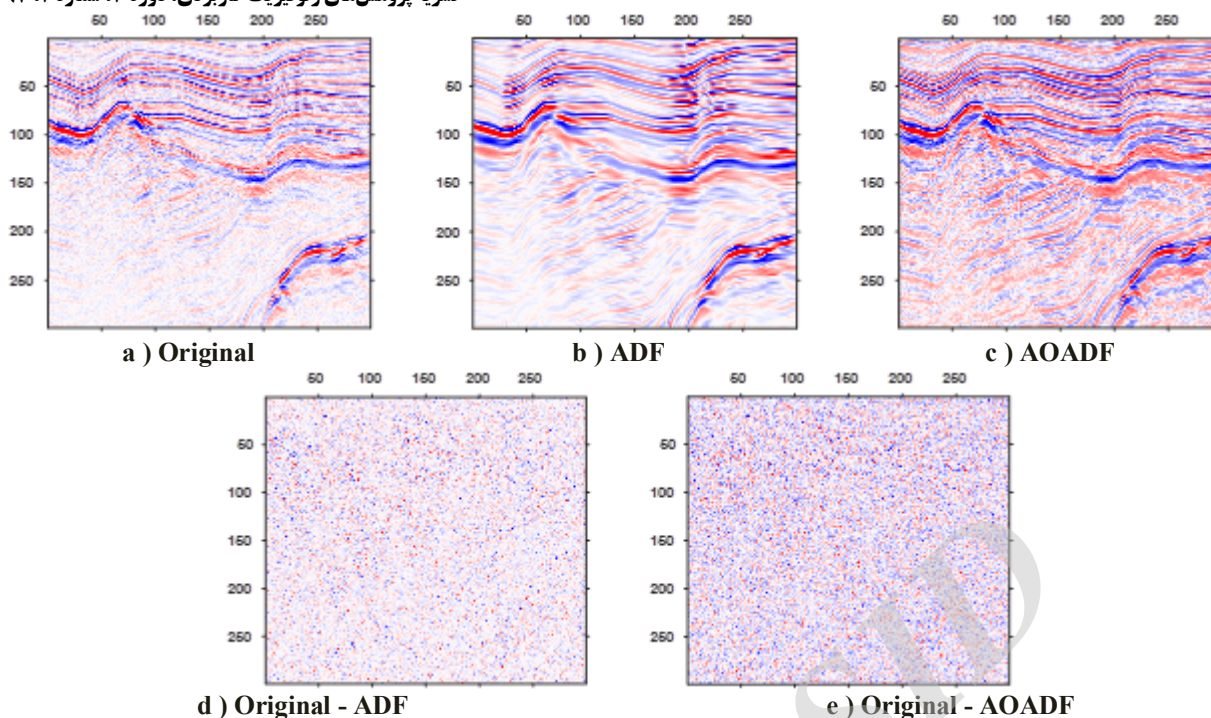


شکل ۴: ردیف ۱۷۵ داده‌های اصلی بدون نوفه، حاوی نوفه و خروجی فیلتر شده در شکل ۲- در حالتی که داده اصلی با نوفه گاوسی با واریانس یک (a)، دو (b) و چهار (c) جمع شده است.



شکل ۵: قسمتی از یک مقطع دورافت مشترک بازچینی شده (رکوردها در یکی از مناطق جنوب ایران) به همراه مقاطع فیلتر شده و تفاضل آنها از مقطع اولیه.





شکل ۶: قسمتی از یک مقطع پس از برانبارش دریایی (رکورد شده در یکی مخازن دریایی مربوط به سواحل غربی آمریکا) به همراه مقاطع فیلتر شده و تفاضل آنها از مقطع اولیه.

ناهماسنگرد غیرخطی تانسوری. مجله پژوهش‌های ژئوفیزیک کاربردی، ۱ (۲)، ۱۰۵-۱۱۸.

Al-Yahya, K., 1991, Application of the partial Karhunen-Loeve transform to suppress random noise in seismic sections, *Geophysical Prospecting*, 39, 77-93.

Aminzadeh, F. and Groot, P.D., 2004, Soft Computing for qualitative and quantitative seismic object and reservoir property prediction, Part 1., *Neural Network Applications*, 22, 9-54.

Baan, M.V.D. and Jutten, C., 2000, Neural networks in geophysical applications. *Geophysics*, 65 (4), 1031-1047.

Baddari, K., Ferahtia, J., Aifa, T. and Djarfour, N., 2011, Seismic noise attenuation by means of an anisotropic non-linear diffusion filter, *Computers and Geoscience*, 37 (4), 456-463.

Bezdek, J.C., 1981, *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York.

Broadhead, M., 2008, The impact of random noise on seismic wavelet estimation, *The Leading Edge*, 27 (2), 226-230.

Djarfour, N., Aifa, T., Baddari, K., Mihoubi, A. and Ferahtia, J., 2008, Application of feedback connection artificial neural network to seismic data filtering, *C. R. Geoscience*, 340, 335-344.


#### ۴- نتیجه‌گیری

با توجه به نتایج آزمایش‌های بر روی داده‌های مصنوعی پس از برانبارش و نیز داده‌های دورافت مشترک و پس از برانبارش حقیقی، مشاهده شد که استفاده از الگوریتم‌های قدرتمند انجیس و نیز خوشه‌بندی فازی در بهینه‌سازی فیلتر پخش ناهمسانگرد، می‌تواند ضمن قدرت بخشی به عملکرد فیلتر در حوزه تضعیف نوفه تصادفی، از ایجاد رویدادهای غیرواقعی در مقطع لرزه‌ای تا حد زیادی اجتناب کند. مقایسه خروجی روش در داده‌های مصنوعی نشان داد که در سطح نوفه پایین، عملکرد دو فیلتر قابل مقایسه با یکدیگر است؛ هرچند عملکرد فیلتر ADF به مقدار جزئی بالاتر از AOADF بوده است. در سطوح نوفه بالاتر، روش پیشنهادی به مراتب قوی‌تر عمل کرده است. افزایش PSNR در این مقاطع، در بالاترین سطح نوفه، ۳۲ درصد از فیلتر مرسوم بالاتر بوده است. در داده‌های حقیقی به کار رفته نیز، عملکرد روش پیشنهادی در ارتقای قابلیت رهگیری رویدادهای هم‌دوس به صورت محسوس بالاتر از ADF مرسوم بوده است. امتیاز مذکور، در کنار این برتری است که میزان رویدادهای غیرواقعی ایجاد شده نیز، در خروجی ناشی از اعمال روش پیشنهادی، بسیار کمتر بوده است.

#### ۵- منابع

شکفته زوارم، م.، روش‌دندل کاهو، ا. و گرایلو، ه.، ۱۳۹۵، تضعیف نوفه تصادفی در داده‌های لرزه‌ای بازتابی با استفاده از فیلتر انتشار

- IEEE Computer Society Workshop on Computer Vision, pp. 16-22.
- Sheriff, R.E., 1997, Seismic resolution a key element, AAPG Explorer, 18 (10), 44-51.
- Stein, R. and Bartley, N., 1983, Continuously time-variable recursive digital band-pass filters for seismic signal processing, Geophysics, 48, 702-712.
- Sun, C., Chengyu, S. and Xiaolei, E., 2016, A combined denoising method based on Curvelet transform and anisotropic diffusion filtering, Acta Petrolei Sinica, 37 (4), 490-498.
- Takagi, T. and Sugeno, M., 1985, Fuzzy identification of systems and its applications to modeling and control, IEEE Trans, Systems, Man, and Cybernetics, 15, 116-132.
- Wang, Z.Y., 2006, Fuzzy Clustering in the Analysis of Fourier Transform Infrared Spectra for Cancer Diagnosis, Ph.D Thesis, School of Computer Science and Information Technology, University of Nottingham.
- Weeratunga, S.K. and Kamath, C., 2003, A comparison of PDE-based non-linear anisotropic diffusion techniques for image denoising, Image Processing: Algorithms and Systems II, SPIE Electronic Imaging, Santa Clara, USA.
- Weickert, J. and Scharr, H., 2002, A Scheme for Coherence-Enhancing Diffusion Filtering with Optimized Rotation Invariance, Journal of Visual Communication and Image Representation, 13 (1), 103-118.
- Weickert, J., 1998, Anisotropic diffusion in image processing, Teuber Verlag, Stuttgart.
- Yang, Q., Wu, G. and Zhao, X., 2015, Application of 3D anisotropic diffusion filter in seismic data processing, Progress in Geophysics, 30 (5), 2287-2292.
- Zhang, Y., Tian, X., Deng, X. and Cao, Y., 2010, Seismic denoising based on modified BP neural network, 6<sup>th</sup> International Conference on Natural Computation, 4, 1825-1829.
- Duda, R. and Hart, P., 1973, Pattern Classification and Scene Analysis, John Wiley & Sons.
- Dunn, J.C., 1974, A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well Separated Clusters, Journ. Cybern., 3, 95-104.
- Fani, R. and Hashemi, H., 2011, Random noise attenuation by application of GK clustering on relevant seismic attributes, 124<sup>th</sup> SEG Conference, Tokyo, Japan.
- Hajian, A., Zomorrodian, H. and Styles, P., 2012, Simultaneous estimation of shape factor and depth of subsurface cavities from residual gravity anomalies using feed-forward back propagation neural networks, Acta Geophysica, 60 (4), 1043-1075.
- Jang, J.S.R., 1993, ANFIS: Adaptive-Neural-Based Fuzzy Inference System, IEEE Transactions on Systems, Man and Cybernetics, 23 (3), 665-685.
- Kaboodin, A. and Javaherian, A., 2010, Random noise reduction by F-X deconvolution, Journal of the earth, 5, 61-68.
- Kimiaefar, R., Siahkoohi, H.R., Hajian, A.R. and Kalhor, A., 2016, Seismic Random Noise Attenuation Using Artificial Neural Network and Wavelet Packet Analysis, Arabian Journal of Geosciences, 9 (3).
- Lin, H., Li, Y., Yang, B., Ma, H. and Zhang, C., 2014, Seismic random noise elimination by adaptive time-frequency peak filtering. IEEE Geosciences and Remote Sensing Letters, 11(1), 337-341.
- Nadernejad, E. and Hassanpour, H., 2007, Evaluating diffusion-based image de-noising techniques, Proc. Int. Conf. on Intelligent & Advance Systems ICIAS, Kuala Lumpur, Malaysia, pp. 565-570.
- Neelamani, R., Baumstein, A.I., Gillard, D.G., Hadidi, M.T. and Soroka, W.I., 2008, Coherent and random noise attenuation using the curvelet transform, The Leading Edge, 27, 240-248.
- Nikolic, Z., 1975, A recursive time-varying band-pass filter, Geophysics, 40, 520-526.
- Perona, P. and Malik, J., 1987, Scale-space and edge detection using anisotropic diffusion, Proc. of



## Anisotropic diffusion filter modified by adaptive neuro-fuzzy interference system (ANFIS) and its application to random noise attenuation in seismic data

Roohollah Kimiaee<sup>1</sup>, Hamid Reza Siahkoohi<sup>2</sup>, Alireza Hajian<sup>3\*</sup> and Ahmad Kalhor<sup>4</sup>

1- Ph.D. Candidate, Islamic Azad University, Science and Research Branch, Tehran, Iran

2- Professor, Institute of Geophysics, University of Tehran, Tehran, Iran

3- Assistant Professor, Department of Physics, Najafabad Branch, Islamic Azad University, Najafabad, Iran

4- Assistant Professor, University of Tehran, Tehran, Iran

Received: 23 April 2017; Accepted: 21 July 2017

\* Corresponding author: dralirezahajian@gmail.com

### Keywords

Anisotropic Diffusion  
ANFIS  
Random Noise Attenuation  
Seismic  
Fuzzy C-Mean Clustering

### Extended Abstract

#### Summary

Anisotropic diffusion filtering (ADF) is widely used as an efficient method in random noise attenuation problems, and various modifications to its original version have been proposed. The main reason could be the thought that ADF preserves edge features with acceptable performance beside noise attenuation procedure. In seismic data processing, however, it should be noticed that using ADF could cause severe changes (artifacts) in the zones that are highly

contaminated with random noise. In this paper, the optimum value is derived, by introducing an automatic framework based on two artificial intelligence (AI) algorithms, adaptive neuro-fuzzy inferences (ANFIS) and fuzzy c-mean clustering (FCM). The neuro-fuzzy network is trained using original data, successive ADF values are calculated for each data point, and FCM output is obtained in a weighted averaging manner adapted with estimated noise level. The trained network is, then, generalized to all data, and thus, the ANFIS optimized version of ADF, called here AOADF, is achieved. Comparison of the results of the ADF and AOADF experiments reveals that in synthetic common mid-point (CMP) gathers, the proposed method improves peak signal to noise ratio (PSNR) value, 40% higher than ADF (in the best case) and in real CMP and common offset sorted gathers, the performance of AOADF is considerably higher than ADF, in terms of random noise attenuation without adding unwanted artifacts and preserving continuity of coherence components.

### Introduction

As an inevitable phenomenon in seismic data acquisition, random noise affects the processing and interpretation results of seismic reflection data. Although it is expected that random noise decreases dramatically by increasing the stack fold, observation of random noise at far offsets and later arrivals, especially in relatively deep acquisitions, could be considered as a common case.

This paper intends to enhance the signal to noise ratio (SNR) of the seismic reflection data by attenuating background random noise and preserving reflection data, utilizing powerful potential of the ANFIS and FCM in model discrimination and the ability of ADF in random noise attenuation. The proposed method mainly seeks to improve the ability of ADF in the zones when the input data is highly contaminated with random noise, and thus, ADF output usually severely cause unwanted artifacts. Achieving latter goal is mainly based on increasing the weight of FCM output value, in the averaging scheme designed for optimum output calculation.

### Methodology and Approaches

In the interior of a segment in the input data, the nonlinear isotropic diffusion behaves almost like the linear diffusion filter, but one should consider that at edges, diffusion is inhibited. Therefore, noise at edges cannot be eliminated successfully by the mentioned process. As a solution to this problem, anisotropic models do not only take into account the modulus of the edge detector, but also its direction.

ANFIS, as a neural-fuzzy system, combines the learning capabilities of neural networks with the functionality of fuzzy inference system.

FCM is a robust method for analysis of data and construction of models, more natural than hard clustering, in almost all problems. Data on the boundaries between several classes are not forced to fully belong to one of the classes, but rather

are assigned membership degrees between 0 and 1 indicating their partial membership. In the method adapted in this research, at the very first stage, ADF with some different diffusion coefficients (5 to 80) are calculated for a small part of input data. At the next step, the standard deviations of ADF values are compared to each other. The point with higher standard deviation could be considered as noise related data point and vice versa. Hence, sorting, and then, selecting the first, let us say five percent of data, could relatively promise that we have selected one percent of dataset, which are less likely to be masked by random noise. Using the set of selected data and a weighted average of initial ADF values, original values of input data and output of FCM analysis, the training pairs for ANFIS network will be constructed. The AOADF output will be automatically achieved by generalizing the trained network to all data.

### **Results and Conclusions**

Although ADF is a strong method for random noise attenuation in many problems, in seismic data processing, ADF could cause artifacts in the zones that are highly contaminated with random noise. In this research, as the comparison of the results of AOADF and ADF on synthetic and real seismic datasets indicates, the AOADF method considerably performs better in random noise attenuation and in preserving the continuity of the coherence events without adding significant artifacts.

---

Archive of SID