doi: 10.11720/wtyht.2026.0124
李智超, 刘国昌, 卢嘉赫, 等. 基于地震属性变尺度分解与分级融合的断裂识别方法及应用[J]. 物探与化探, 2026, 50(5): 912-925. https://doi.org/10.11720/wtyht.2026.0124
Li Z C, Liu G C, Lu J H, et al. A method for fault identification based on the varying-scale decomposition and hierarchical fusion of seismic attributes and its application[J]. Geophysical and Geochemical Exploration, 2026, 50(5): 912-925. https://doi.org/10.11720/wtyht.2026.0124

# 基于地震属性变尺度分解与分级融合的断裂识别方法及应用

李智超[1,2,3], 刘国昌[1,2,3], 卢嘉赫[1,2,3], 沈家浩[1,2,3], 吴启斌[1,2,3], 板琦[1,2,3], 王昊天[1,2,3]

(1. 中国石油大学(北京)地球物理学院, 北京 102249; 2. 油气资源与工程全国重点实验室, 北京 102249; 3. CNPC 物探重点实验室, 北京 102249)

**摘 要:** 断控型储层是非常规油气勘探开发的重要目标, 不同尺度断裂的精确识别直接影响储层产能与开发效益。地震属性是断裂预测的常用手段, 但单一属性难以同时突显多尺度断裂特征。为此, 本文提出一种基于地震属性变尺度分解与分级融合的断裂识别方法。首先, 提取多种优选的断裂检测属性, 利用基于滚动引导滤波的多尺度分解算法, 分离不同尺度断裂响应与噪声分量。其次, 针对小、中、大尺度断裂分别构建融合模型: 采用高斯加权的绝对值最大化规则实现小尺度属性自适应加权融合, 增强微弱断裂响应; 利用结合加权局部能量与基于八邻域的改进拉普拉斯算子方法完成中尺度属性融合, 突出中尺度断裂展布; 借助栈式稀疏自编码器对大尺度属性进行深度非线性融合, 实现大尺度断裂构造的精细刻画。最后, 集成多尺度融合结果, 形成综合断裂表征属性。模拟数据与实际地震资料测试均表明, 本文方法有效规避了传统属性融合算法存在的特征冗余与信息丢失问题, 微小断裂识别分辨率提升, 大尺度断裂边界更清晰、抗噪性更强, 为复杂断控型储层的精准预测提供了可靠技术支撑。

**关键词:** 断裂识别; 地震属性融合; 多尺度断裂; 分级融合; 变尺度分解

**中图分类号:** P631.4; P31 **文献标识码:** A **文章编号:** 1000-8918(2026)05-0912-14

## 0 引言

断裂是致密砂岩、碳酸盐岩、页岩等非常规油气储层的重要储集空间与渗流通道, 断裂发育密度、空间展布及连通性直接决定储层物性与油气富集规律。因此, 完成断裂的精确识别与多尺度刻画, 是复杂油气藏评价、有利区优选的关键前提, 也是油气地球物理领域的重点研究课题。地下天然断裂具备多尺度共生、非均匀分布、地震响应微弱的特征, 不同尺度断裂地震响应差异显著, 地震表征信息相互叠加干扰。单一地震属性与固定尺度分析难以全面刻画多尺度断裂响应, 易造成断裂漏识别、误识别。

地震属性分析是叠后地震数据断裂识别的核心技术[1-3], 可分为波形动力学属性与构造几何形态属性两类。其中, 相干体、方差体、蚂蚁体等属性多用于表征宏观断裂、断裂发育特征[4-5]; 倾角、曲率等几何属性侧重刻画地层形变引发的断裂异常[6-7]。但单一地震属性表征维度有限, 缺乏断裂密度定量表征物理机制; 同时多属性存在信息冗余、多解性突出等问题[8], 传统单尺度、单属性分析方法抗干扰能力弱, 无法满足复杂断裂储层精细化勘探需求。

为弥补单属性识别缺陷, 多属性融合技术成为断裂精细预测的主流方法, 可通过信息互补降低解释多解性[9-10]。国内外学者依托数理统计方法构建了多种融合技术体系。毕俊凤[11] 通过差异化加权算法实现多属性融合, 提升断裂异常识别清晰度。Guo 等[12]、Fu 等[13] 利用主成分分析法(principal com-

**收稿日期:** 2026-06-04; **修回日期:** 2026-07-31
**基金项目:** 国家自然科学基金项目(42374130)
**第一作者:** 李智超(2000-), 男, 博士, 主要研究方向为储层预测及地震反演。Email: 2023310419@student.cup.edu.cn

ponent analysis, PCA)完成高维属性降维, 精简冗余数据、优化运算效率。陈俊等[14]结合 RGB-IHS 变换与傅里叶滤波算法, 压制随机噪声, 有效提高断裂识别精度。谢成芳等[15]将 Contourlet 变换应用于地震属性处理, 依托其多分辨特性挖掘细微断裂响应信息。曹磊等[16]针对火山岩储层地震响应特征, 优选核心地震属性, 采用分级融合方法精准刻画火山通道边界, 验证了变换域融合技术的实用性。

基于图像信号处理方法的传统融合方法虽能优化识别效果, 但存在明显短板: 该类方法高度依赖人工经验, 模型自适应能力差, 在复杂工区泛化性能不足; 且难以挖掘属性间非线性关联, 对高维冗余数据处理能力有限, 无法适配多尺度非均匀断裂识别要求。

人工智能技术的应用突破了传统融合算法瓶颈[17], 神经网络凭借优异的非线性映射、自适应特征提取能力, 成为地震属性融合领域的研究热点。国内学者早期围绕基础神经网络开展算法优化研究: 曹琳昱等[18]将粒子群算法与 BP 神经网络结合, 改善了传统网络易陷入局部最优的缺陷, 但该方法对复杂储层适配性较差; 李全忠等[19]引入脉冲耦合神经网络(pulse coupled neural network, PCNN), 依靠其非线性处理优势自适应求解融合系数, 实现多属性智能融合; 李婷婷等[20]融合主成分降维与竞争神经网络优势, 构建了属性智能聚类融合模型。在多类型属性分级融合研究方面, Nayar[21]提出改进拉普拉斯能量方法, 奠定了多尺度分解融合基础; 屈小波等[22]将 SML 算法引入多聚焦图像融合, 优化高频系数融合规则以提升融合质量; Yin 等[23]进一步改进 SML 算法, 构建八邻域加权计算模式, 完善了多尺度融合评价体系。依托多尺度分级融合理论, 薄昕等[24]融合拉普拉斯金字塔与 PCNN 算法, 强化小尺度断裂精细提取能力; 汤韦等[25]结合剪切波变换优化算法, 完整捕获多尺度断裂轮廓与细节特征; 赵军等[26]依托前馈神经网络, 结合测井约束实现工区断裂系统精细刻画。除常规神经网络外, 深度学习算法在断裂识别中迭代发展, Gui 等[27]利用改进 U-Net++网络, 实现岩溶、断裂的差异化精准预测。无监督自编码器(auto-encoder, AE)算法凭借深层特征挖掘优势被广泛应用, Qian 等[28]采用深度自编码器提取地震隐含特征, 突破传统属性表征局限; Li 等[29]提出共享自编码器结构, 强化多源属性耦合关联; 周单等[30]基于堆叠稀疏自编码器优化模型, 有效提升大尺度断裂刻画精度, 但该算法参数调试难度高, 难以识别微弱、微小断裂。

针对现有地震属性融合方法存在的尺度处理单一、多尺度断裂表征能力不足、多尺度断裂能量表征有误等问题, 本文构建了一套基于地震属性变尺度分解与分级融合的断裂识别方法, 依托滚动引导滤波(rolling guidance filtering, RGF)变尺度分解算法精准分离不同量级的断裂有效响应与噪声分量; 在此基础上, 针对小、中、大尺度断裂的响应特征差异, 分别采用高斯加权的绝对值最大化规则(Gaussian-weighted absolute value maximization, GAVM)、结合加权局部能量与基于八邻域的改进拉普拉斯算子方法(weighted local energy-weighted sum of eight-neighborhood-based modified Laplacian, WLE-WSEML)、栈式稀疏自编码器(stacked sparse autoencoder, SSAE)实现分层差异化特征融合与信号增强, 充分保留多尺度断裂的有效信息, 压制随机噪声与特征冗余。模拟数据与实际地震资料验证结果表明, 本文方法可为复杂非均匀断裂型储层的全尺度精细刻画与高效勘探开发提供新的技术支撑。

## 1　方法原理

### 1.1　地震属性优选分析

在进行地震属性变尺度分解与多类型属性分级融合之前, 需要通过理论分析方法及专家经验总结从若干种地震属性优选出对断裂地震响应最为敏感的地震属性, 被优选的地震属性需要具有明确物理意义的同时保证各自的数据独立性。本文优选方差体、曲率、蚂蚁追踪 3 类对断裂响应敏感且物理意义明确的地震属性, 作为变尺度分解与分级融合的输入。方差体通过对若干组两两相邻的地震道数据进行方差分析, 从而对其地震信号差异程度进行表征, 稳定地突出地质构造中的断裂与横向非均匀性特征, 侧重大尺度断裂与不连续性识别。曲率通过拟合地震反射面的局部二次曲面, 量化地层曲面弯曲, 精准刻画构造形态与断裂分布, 对中小尺度断裂与地层弯曲敏感。蚂蚁追踪通过模拟蚂蚁释放、感知“信息素”的正反馈机制, 在三维地震数据体中自动识别、追踪并连接断裂等不连续界面, 用于检测小尺度断裂。优选的 3 种地震属性对不同尺度断裂检测能力有所不同, 为了能够更加清晰地刻画断裂展布情况, 以 3 种地震属性为输入, 利用变尺度分解与多类型属性分级融合获得断裂预测的最优结果。

### 1.2　地震属性标准化

在对不同量纲、不同数值量级、不同物理意义的多种地震属性输入算法模型之前, 需要通过归一

化, 对地震属性的值域范围进行标准化处理以消除量纲差异, 使多属性具备可比性、可叠加性[31]。极差标准化处理公式如下所示:

$$\boldsymbol{x}^{*}=\frac{\boldsymbol{x}-\min(\boldsymbol{x})}{\max(\boldsymbol{x})-\min(\boldsymbol{x})}, \tag{1}$$

式中: $\boldsymbol{x}^{*}$为标准化后地震属性数据; $\boldsymbol{x}$为标准化前地震属性数据。

### 1.3 基于 RGF 的地震属性变尺度分解

滚动引导滤波器 (rolling guidance filter, RGF) 是由 Zhang 等[32]、Hattori 等[33] 提出的一种具有尺度感知能力的局部边缘保持滤波器, 其主要由平滑小尺度图像结构的高斯滤波和基于联合双边滤波的迭代边缘恢复两部分构成, 结构如图 1 所示。因此, RGF 能够在平滑掉小尺度结构的同时, 保留大尺度结构的边缘细节信息。高斯滤波是一种经典的线性平滑滤波算法, 通过调节滤波器的标准差参数, 可以控制消除结构的尺度大小。高斯滤波公式如下。

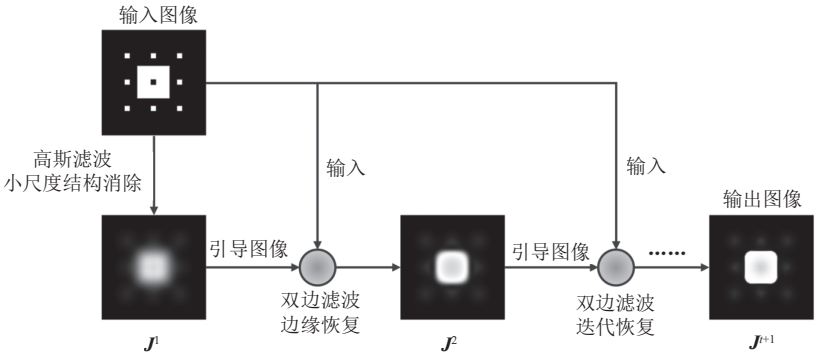



**图 1 滚动引导滤波器示意**

**Fig. 1 Schematic of the rolling guidance filter**

$$\boldsymbol{G}(p)=\frac{\sum\limits_{q\in N(p)}\exp\left(-\dfrac{\|\boldsymbol{p}-\boldsymbol{q}\|^{2}}{2\sigma_{s}^{2}}\right)\cdot\boldsymbol{I}(q)}{\sum\limits_{q\in N(p)}\exp\left(-\dfrac{\|\boldsymbol{p}-\boldsymbol{q}\|^{2}}{2\sigma_{s}^{2}}\right)}, \tag{2}$$

其中: $\boldsymbol{I}$和$\boldsymbol{G}$分别为输入和输出图像; $\boldsymbol{p}$和$\boldsymbol{q}$表示像素点的索引; $N(p)$表示像素$p$的相邻像素点; $\sigma_s$为控制高斯结构尺度的标准差参数。

经过高斯滤波步骤后, 利用联合双边滤波对模糊掉的大尺度结构边缘进行迭代恢复。将高斯滤波得到的图像$\boldsymbol{G}$作为联合双边滤波的原始引导图$\boldsymbol{J}^{1}$, 然后通过多次迭代, 逐步恢复不同尺度的边缘信息。在每次迭代中处理的引导图来自上一次迭代的输出图像$\boldsymbol{J}^{t}$。该过程的表达式为:

$$\boldsymbol{J}^{t+1}(p)=\frac{\sum\limits_{q\in N(p)}\exp\left(-\dfrac{\|\boldsymbol{p}-\boldsymbol{q}\|^{2}}{2\sigma_{s}^{2}}-\dfrac{J^{t}(p)-J^{t}(q)}{2\sigma_{r}^{2}}\right)-I(q)}{\sum\limits_{q\in N(p)}\exp\left(-\dfrac{\|\boldsymbol{p}-\boldsymbol{q}\|^{2}}{2\sigma_{s}^{2}}-\dfrac{J^{t}(p)-J^{2}(q)}{2\sigma_{r}^{2}}\right)}, \tag{3}$$

式中: $\boldsymbol{J}^{t+1}(p)$是第$t$次迭代的结果; $\sigma_s$和$\sigma_r$分别控制空间权重和距离权重。

为了实现空间上混叠的多尺度地震属性结构分离, 本文采用相邻 RGF 结果相减法来提取不同尺度的地震属性信息, 流程如图 2 所示。对原始地震属性$\boldsymbol{S}^{0}$进行 RGF 处理得到$\boldsymbol{S}^{1}$, 该结果消除了$\boldsymbol{S}^{0}$中的小尺度结构, 并保留了大尺度结构的边缘, 用$\boldsymbol{S}^{0}$减$\boldsymbol{S}^{1}$可得到地震属性中的细节信息$\boldsymbol{D}^{1}$。重复上述过程, 可得不同尺度的细节信息以及最终平滑化的大尺度结构$\boldsymbol{B}$, 计算公式如下所示:

$$\boldsymbol{D}^{i}=\boldsymbol{S}^{i-1}-\boldsymbol{S}^{i}, \tag{4}$$

式中: $\boldsymbol{S}^{i}=RGF(\boldsymbol{S}^{i-1},\sigma_{s},\sigma_{r})$; $RGF(\cdot)$表示 RGF 滤波; $i$表示分解的尺度级别。

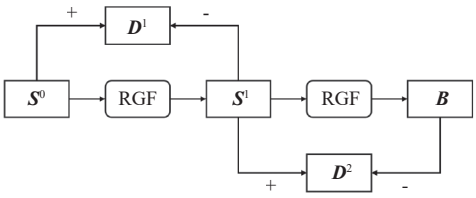



**图 2 基于 RGF 的地震属性多尺度分解流程**

**Fig. 2 Workflow of multi-scale decomposition of seismic attributes based on the RGF**

最终, 分尺度融合的地震属性可以通过如下方程重建:

$$\boldsymbol{S}_{F}=\sum_{i=1}^{N}\boldsymbol{D}_{F}^{i}+\boldsymbol{B}_{F}, \tag{5}$$

式中: $\boldsymbol{S}_F$为多尺度融合得到的最终地震属性; $\boldsymbol{D}_F^i$为融合后的第$i$级地震属性细节; $\boldsymbol{B}_F$表示融合后的大尺度地震属性。

### 1.4 基于高斯加权的绝对值最大化规则的小尺度属性融合

不同的地震属性具有独立的物理含义, 因此它

们在形态结构和强度上存在很大差异。传统基于图像分解的融合方法通常对高频分量和低频分量采用简单的融合规则, 这类方法缺乏针对性, 难以有效匹配不同尺度信息的特征。因此, 有必要针对不同尺度层设计相应的融合策略, 以更好地结合地震属性在不同尺度上的互补信息。

根据本文所使用的方法, 分解后的地震属性依据尺度落入 3 个层级: 小尺度层 $\boldsymbol{D}^1$、中尺度层 $\boldsymbol{D}^2$、大尺度层 $\boldsymbol{B}$。小尺度层包含地震属性中最细微的碎片状分布信息, 针对此特点, 采用 GAVM 融合规则, 以保留原始数据中更多的突出细节特征[34]。GAVM 的计算公式如下:

$$\boldsymbol{D}_F^1 = \sum_{k=1}^{3} \boldsymbol{G}(\boldsymbol{W}_k, \sigma_0) \cdot \boldsymbol{D}_k^1, \tag{6}$$

式中: $k$表示输入地震属性的类别; $\boldsymbol{G}(\boldsymbol{W}_k, \sigma_0)$表示加权系数矩阵 $\boldsymbol{W}_k$的高斯平滑; 高斯核标准差为 $\sigma_0$, 以减少噪声的干扰, 通常默认设置为 2。$\boldsymbol{W}_k$的计算公式如下:

$$\boldsymbol{W}_k = \begin{cases} 1, \boldsymbol{D}_k^1 = \max\{\boldsymbol{D}_1^1, \boldsymbol{D}_2^1, \boldsymbol{D}_3^1\}, \\ 0, \text{其他}。 \end{cases} \tag{7}$$

### 1.5　结合加权局部能量与基于八邻域的改进拉普拉斯算子方法的中尺度属性融合

中尺度地震属性相比于碎片状的小尺度地震属性具有更加明显的结构化特征, 其尺度介于小尺度和大尺度之间, 既包含原始地震属性的细节、边缘, 又反映部分结构信息。因此, 采用 WLE 和 WSEML 相结合的方法, 对中尺度地震属性进行充分融合, 其中 WLE 用于度量输入的结构信息, WSEML 用于度量输入的细节信息。WLE 的计算公式如下所示:

$$\boldsymbol{WLE}_k(i,j) = \sum_{m=-r}^{r}\sum_{n=-r}^{r} \boldsymbol{W}(m+r+1, n+r+1) \cdot \boldsymbol{D}_k^2(i+m, j+n)^2, \tag{8}$$

式中: $k$是地震属性类别; $\boldsymbol{D}_k^2(i,j)$表示中尺度层在 $(i,j)$位置上的值; $\boldsymbol{W}$是 $(2r+1)\times(2r+1)$的权重矩阵, $\boldsymbol{W}$中每个元素的值根据 $2^{2r-d}$公式计算; $r$代表矩阵 $\boldsymbol{W}$的半径; $d$表示相应元素到矩阵中心的 $L_1$范数距离。例如, 当 $r$为 1 时, 归一化矩阵 $\boldsymbol{W}$可表示为 $(1/16)\begin{pmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{pmatrix}$。

基于八邻域的改进拉普拉斯算子(eight-neighborhood-based modified Laplacian, EML)考虑了对角系数的影响, 因此可以充分利用邻域的信息。WSEML 是 EML 的加权表示方法, 其公式为:

$$\boldsymbol{WSEML}_k(i,j) = \sum_{m=-r}^{r}\sum_{n=-r}^{r} \boldsymbol{W}(m+r+1, n+r+1) \cdot \boldsymbol{EML}_k(i+m, j+n), \tag{9}$$

$$\begin{aligned} \boldsymbol{EML}_k(i,j) = {} & \left|2\boldsymbol{D}_k^2(i,j) - \boldsymbol{D}_k^2(i-1,j) - \boldsymbol{D}_k^2(i+1,j)\right| + \\ & \left|2\boldsymbol{D}_k^2(i,j) - \boldsymbol{D}_k^2(i,j-1) - \boldsymbol{D}_k^2(i,j+1)\right| + \\ & \frac{1}{\sqrt{2}}\left|2\boldsymbol{D}_k^2(i,j) - \boldsymbol{D}_k^2(i-1,j-1) - \boldsymbol{D}_k^2(i+1,j+1)\right| + \\ & \frac{1}{\sqrt{2}}\left|2\boldsymbol{D}_k^2(i,j) - \boldsymbol{D}_k^2(i-1,j+1) - \boldsymbol{D}_k^2(i+1,j-1)\right|。 \end{aligned} \tag{10}$$

根据 WLE 和 WSEML 的计算结果, 设计相应的融合规则, 得到融合后的中尺度地震属性, 融合规则的表达式为:

$$\begin{aligned} & \boldsymbol{D}_F^2(i,j) = \boldsymbol{D}_k^2(i,j), \\ & \text{if } \boldsymbol{WLE}_k(i,j) \cdot \boldsymbol{WSEML}_k(i,j) = \max_{1\leqslant l\leqslant 3} \boldsymbol{WLE}_l(i,j) \cdot \boldsymbol{WSEML}_l(i,j)。 \end{aligned} \tag{11}$$

### 1.6　基于栈式稀疏自编码器的大尺度属性融合

经过多轮 RGF 迭代滤波输出的结果代表大尺度结构的能量信息, 而大尺度层的融合方法对地震属性融合的质量起到至关重要的作用。传统的融合方法通常基于简单的加权平均规则, 其线性融合的本质导致其无法捕捉不同属性之间的非线性关系, 易造成有效信息的损失。栈式稀疏自编码器(stack sparse auto encoders, SSAE)是一种先进的深度无监督学习模型, 该模型能够实现高维数据的低维鲁棒表示, 充分挖掘输入数据之间的非线性关系, 在多模态数据融合任务中表现出色[35]。

SSAE 的基本结构单元为自编码器(autoencoder, AE), 其结构如图 3 所示, 包含输入层、隐藏层(瓶颈层)、输出层。将输入映射到隐藏层的过程称为编码, 将隐藏层映射回原输入的过程称为解码, 其表达式分别为:

$$\begin{aligned} h(x) &= \boldsymbol{\sigma}(\boldsymbol{W}_e x + b_e), \\ Y &= \boldsymbol{\sigma}(\boldsymbol{W}_d h(x) + b_d)。 \end{aligned} \tag{12}$$

式中: $\boldsymbol{W}_e$、$\boldsymbol{W}_d$分别为编码器、解码器网络权重参数; $b_e$、$b_d$分别为编码器、解码器网络偏置项; $\boldsymbol{\sigma}(\cdot)$为 sigmoid 激活函数, $\boldsymbol{\sigma}(x) = (1+\mathrm{e}^{-x})^{-1}$。

AE 以输入与输出之间的重构误差平方和作为优化目标, 其数学表达式为:

$$(\boldsymbol{W}^*, b^*) = \underset{\boldsymbol{W},b}{\operatorname{argmin}} \frac{1}{2}\sum_{i=1}^{m}\sum_{j=1}^{n}[y(i,j) - x(i,j)]^2, \tag{13}$$

式中: $x(i,j)$为输入样本; $y(i,j)$为模型输出。

利用梯度下降法更新网络的参数, 以此实现模型的无监督训练, 第 $l$层权重参数与偏置项更新的数学表达为:

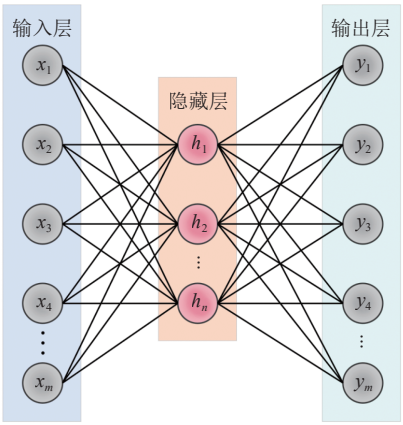



**图 3　自编码器构造示意**

**Fig. 3　Architecture of the autoencoder**

$$w^l(i,j)=w^l(i,j)-\eta\frac{\partial\mathcal{L}}{\partial w^l(i,j)}b^l(j)=b^l(j)-\eta\frac{\partial\mathcal{L}}{\partial b^l(j)},\tag{14}$$

式中：$\eta$为学习率；$\mathcal{L}$为损失函数，$\mathcal{L}=\frac{1}{2}\sum_{i=1}^{m}\sum_{j=1}^{n}[y(i,j)-x(i,j)]^2$；$w(i,j)$为第$i$个输入神经元与第$j$个输出神经元之间的权重系数；$b(j)$为第$j$个输出神经元的偏置项。

不同于单独的 AE，SSAE 通过整合“堆栈”和“稀疏性”两个核心策略，改善了传统 AE 可能陷入“恒等映射”——即网络简单地记忆输入的问题，提高了模型对复杂数据的降维表征能力。SSAE 的对称网络结构如图 4 所示（图中透明单元为稀疏单元），包括输入层、多层隐藏层、瓶颈层、多层隐藏层、输出层。通过多层堆叠，模型将复杂数据分解为越来越抽象的特征，逐步过渡到结构模式。同时，引入 KL 散度作为稀疏性惩罚，限制每个隐藏层中激活神经元的数量。该策略迫使网络具有高度选择性，仅捕获数据中最显著、信息量最大的底层结构，避免自编码器只是简单地将输入复制到输出，而没有学习有效信息。KL 散度的表达式为：

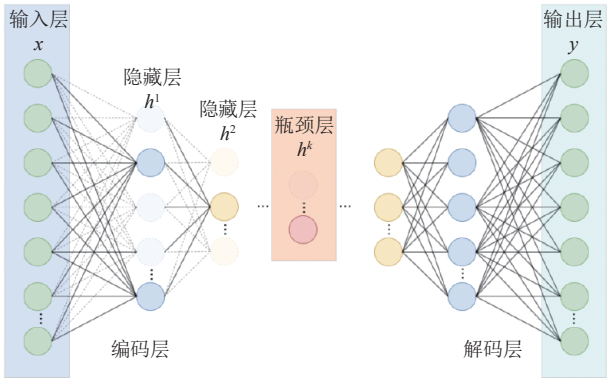



**图 4　栈式稀疏自编码器构造示意**

**Fig. 4　Architecture of the stacked sparse autoencoder**

$$\mathrm{KL}\left(\overline{p}\middle|\tilde{p}_j\right)=\overline{p}\log\frac{\overline{p}}{\tilde{p}_j}+(1-p)\log\frac{1-\overline{p}}{1-\tilde{p}_j},\tag{15}$$

式中：$\overline{p}$为期望平均稀疏激活度参数；$\tilde{p}_j=\frac{1}{m}\sum_{i=1}^{m}h_j(x^i)$，$h_j(x^i)$为输入是$x^i$时隐含层神经元$j$的激活值。

SSAE 损失函数的数学公式为：

$$\mathcal{L}_{SSAE}=\mathcal{L}+\beta\sum_{j=1}^{s}\mathrm{KL}\left(\overline{p}\middle|\tilde{p}_j\right),\tag{16}$$

式中：$s$为隐含层神经元个数；$\beta$为控制稀疏性惩罚因子的权重。

本文采用神经元个数依次为 128-32-8-1-8-32-128 隐藏层结构的 SSAE 模型，输入多种大尺度地震属性，利用早停法“微调”迭代 36 轮至收敛后，提取 SSAE 瓶颈层神经元的值作为属性融合结果，并通过极差归一化将 SSAE 属性融合结果的值域映射回原值域，最终获得大尺度层$B$的输出结果。

### 1.7　地震属性变尺度分解与融合实现流程

结合上述理论算法，本文主要按照如下步骤开展实验：地震属性优选及预处理、地震属性多尺度分解、分级融合、地震属性还原重构。本文方法整体流程如图 5 所示，具体说明如下。

1）地震属性优选及预处理：根据本文利用地震属性识别断裂的目标需要，挑选出方差体属性、曲率属性、蚂蚁体属性 3 类对断裂响应突出的地震属性用于属性融合实验，并分别进行极差标准化处理，将各属性值域映射到[0,255]区间内，以消除量纲对属性融合效果的影响。

2）地震属性多尺度分解：分别对每一种地震属性应用 2 轮 RGF 得到最终的大尺度层，代表属性的结构信息，并通过提取相邻 RGF 结果之间的残差得到小尺度层、中尺度层，表示属性的细节信息。

3）多类型属性分级融合：由于不同尺度层数据分布特征不同，分别使用 3 种不同的融合规则对地震属性进行多尺度融合。针对小尺度层，采用 GAVM 融合算法，以保留最突出的细节特征并压制噪点干扰。在使用 GAVM 时，需设置高斯核标准差$\sigma_0$的大小，以控制权重系数的平滑程度。针对中尺度层，采用 WLE-WSEML 融合规则，该方法可以较好地平衡原始属性的能量和细节信息，在应用时要求人工设置权重矩阵的半径$r$，该参数决定融合的平滑程度。针对大尺度层，利用 SSAE 模型，充分挖掘隐藏在不同属性之间的复杂非线性关系，实现大尺度结构信息的融合。在部署 SSAE 模型时，需根据训练效果调整网络各层神经元个数、稀疏激活度参数、稀疏性惩罚因子权重、迭代次数等超参数。

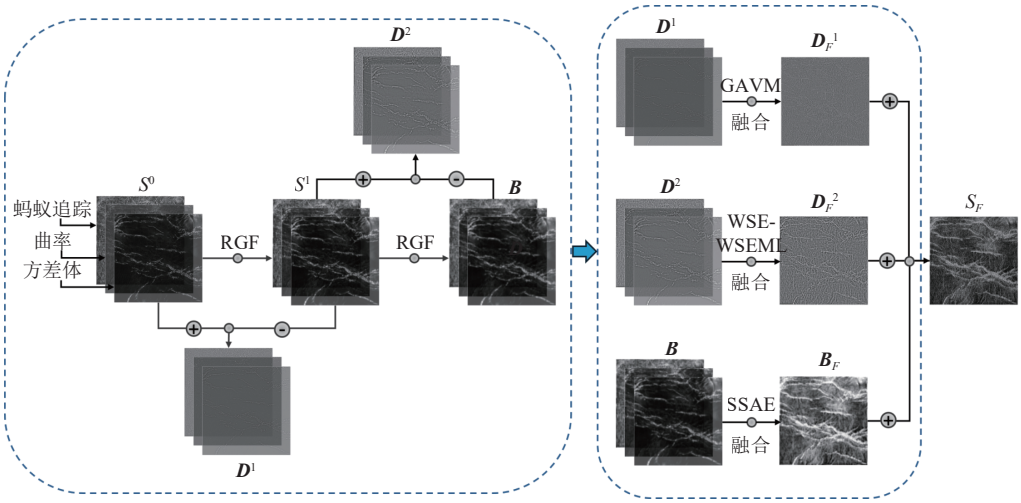



**图 5　基于地震属性变尺度分解与分级融合的断裂识别流程**

**Fig. 5　Workflow of fault detection based on variable-scale decomposition and hierarchical fusion of seismic attributes**

4)地震属性还原重构: 将多尺度融合后的多层地震属性进行线性加和, 最终得到还原重构的融合地震属性。

### 1.8　小波变换地震属性融合

小波变换(wavelet transform, WT)通过多分辨率分析, 将信号逐级分解为低频近似分量和高频细节分量。通过设计相应规则, 分别对不同类别输入的低频系数和高频系数进行融合, 最后对融合后的子带进行逆小波变换重构, 得到的结果在保留多源输入主体结构的同时突出细节信息[36-37]。WT 地震属性融合的流程如下:

1)通过式(1)对输入进行标准化处理, 得到消除量纲差异的样本, 保护数据间的相关性。

2)利用 Mallat 算法对每类输入分别逐层进行二维小波分解, 每层得到低频近似以及水平、垂直、对角 3 个方向的高频细节。除初次分解外, 每次分解仅对低频子带进行卷积与下采样操作:

$$\begin{aligned}&\boldsymbol{A}^{\boldsymbol{0}}=\boldsymbol{I},\\&\boldsymbol{A}^{j+1}=\boldsymbol{H}_x*\boldsymbol{H}_y*\boldsymbol{A}^j,\\&\boldsymbol{D}_{\boldsymbol{h}}^{j+1}=\boldsymbol{H}_x*\boldsymbol{G}_y*\boldsymbol{A}^j,\\&\boldsymbol{D}_{\boldsymbol{v}}^{j+1}=\boldsymbol{G}_x*\boldsymbol{H}_y*\boldsymbol{A}^j,\\&\boldsymbol{D}_{\boldsymbol{d}}^{j+1}=\boldsymbol{G}_x*\boldsymbol{G}_y*\boldsymbol{A}^j。\end{aligned}\tag{17}$$

式中: $\boldsymbol{I}$为二维输入; $j$表示分解层数; $\boldsymbol{A}$为低频系数; $\boldsymbol{D}_{\boldsymbol{h}}$、$\boldsymbol{D}_{\boldsymbol{v}}$、$\boldsymbol{D}_{\boldsymbol{d}}$分别为垂直、水平、对角方向的高频系数; $\boldsymbol{H}_x$、$\boldsymbol{H}_y$、$\boldsymbol{G}_x$、$\boldsymbol{G}_y$分别为不同方向的小波滤波器。

3)通过取平均法对最后一层低频系数进行融合:

$$F(\boldsymbol{A})=\frac{1}{n}\sum\boldsymbol{A}_i,\tag{18}$$

式中: $F$为融合函数; $i$表示原始输入的类别。

4)利用绝对值最大化准则分别对每层不同方向的高频系数进行融合:

$$\begin{aligned}&F(\boldsymbol{D}_{\boldsymbol{h}}^{\boldsymbol{j}})=\max(|\boldsymbol{D}_{\boldsymbol{ih}}^{\boldsymbol{j}}|),\\&F(\boldsymbol{D}_{\boldsymbol{v}}^{\boldsymbol{j}})=\max(|\boldsymbol{D}_{\boldsymbol{iv}}^{\boldsymbol{j}}|),\\&F(\boldsymbol{D}_{\boldsymbol{d}}^{\boldsymbol{j}})=\max(|\boldsymbol{D}_{\boldsymbol{id}}^{\boldsymbol{j}}|)。\end{aligned}\tag{19}$$

5)对融合后的各频段子带进行逆小波变换, 即步骤 1)的反卷积上采样操作, 最终得到重构的多属性融合结果。

### 1.9　主成分分析地震属性融合

主成分分析(principal component analysis,PCA)是一种经典的线性降维算法, 该方法通过正交变换, 将高维且可能存在相关性的原始变量, 重新组合成一组线性无关的新变量, 并按方差大小降序排列[38]。因此, 可以利用 PCA 对多类型地震属性进行融合, 保留主要信息结构并消除冗余分量。PCA 地震属性融合的算法流程及原理如下。

1)通过式(1)对输入进行标准化处理, 得到消除量纲差异的样本矩阵$\boldsymbol{X}$。

2)计算标准化样本矩阵的协方差矩阵$\boldsymbol{C}$:

$$\boldsymbol{C}=\frac{1}{n-1}\boldsymbol{X}(\boldsymbol{X})^{\mathrm{T}},\tag{20}$$

式中: $n$ 表示输入变量的个数。

3)对协方差矩阵$\boldsymbol{C}$进行特征值分解, 得到由特征值构成的对角阵$\boldsymbol{D}$和由特征向量构成的矩阵$\boldsymbol{V}$:

$$[\boldsymbol{D},\boldsymbol{V}]=\mathrm{eig}(\boldsymbol{C}),\tag{21}$$

式中: eig(·)表示特征值分解运算。

4)重建降维后的样本:

$$\boldsymbol{T}=\boldsymbol{X}\boldsymbol{W},\tag{22}$$

式中: $\boldsymbol{T}$表示降维后的样本矩阵; $\boldsymbol{W}$表示投影矩阵, 由前 $k$ 个最大特征值对应的特征向量组成, $k$ 的值取决于特征值累积贡献度, 即前 $k$ 个主成分分量的方差和占总方差的比例大于 85% 时, 选取前 $k$ 个特征向量。

5)计算前 $k$ 个主成分分量的欧几里得范数，该范数值即为多维输入经过 PCA 融合后的结果：

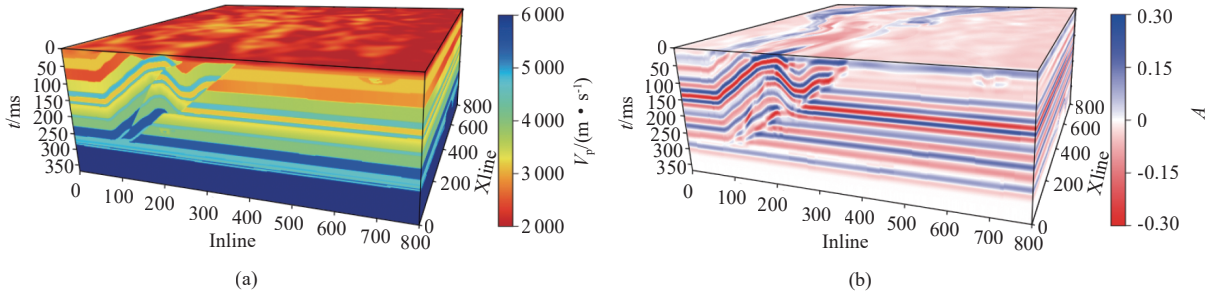
$$s=\sqrt{\sum_{i=1}^{k}l_i^2}, \tag{23}$$

式中：$l_i$表示主成分分量值。

## 2　模型验证

为了验证变尺度分解与多类型属性分级融合方法对于复杂断层模型断裂预测的适用性，本研究采用 SEG/EAGE 3D 推覆体模型来进行效果测试。如图 6a 所示，3D 推覆体模型规格为 800×800×187，时间采样间隔为 2 ms。以主频为 25 Hz 的雷克子波进行褶积模型正演，所得地震正演结果如图 6b 所示。生成三维合成记录的方差体、曲率、蚂蚁追踪属性，如图 7 所示。

图 8a~d 分别为 3D 推覆体模型正演结果、方差体、曲率、蚂蚁追踪属性三维数据体在 212 ms 的时间切片。对 3 种断裂检测属性应用变尺度分解与分级融合方法、SSAE 方法、小波变换方法、PCA 方法分别进行融合，并取各方法融合结果在 212 ms 的时间切片，图 8e~h 分别为变尺度分解与分级融合方法、SSAE 方法、小波变换方法、PCA 方法融合结果。从图 8 可以看出，PCA 融合结果对推覆断层的刻画效果最差；小波变换融合结果与 SSAE 融合结果均可以刻画模型中断层和曲流河的响应，但刻画结果较为模糊，断层边界不清晰，连续性较差；变尺度分解与分级融合结果刻画断层和曲流河时响应清晰，成像分辨率高，断裂识别连续程度高，识别结果

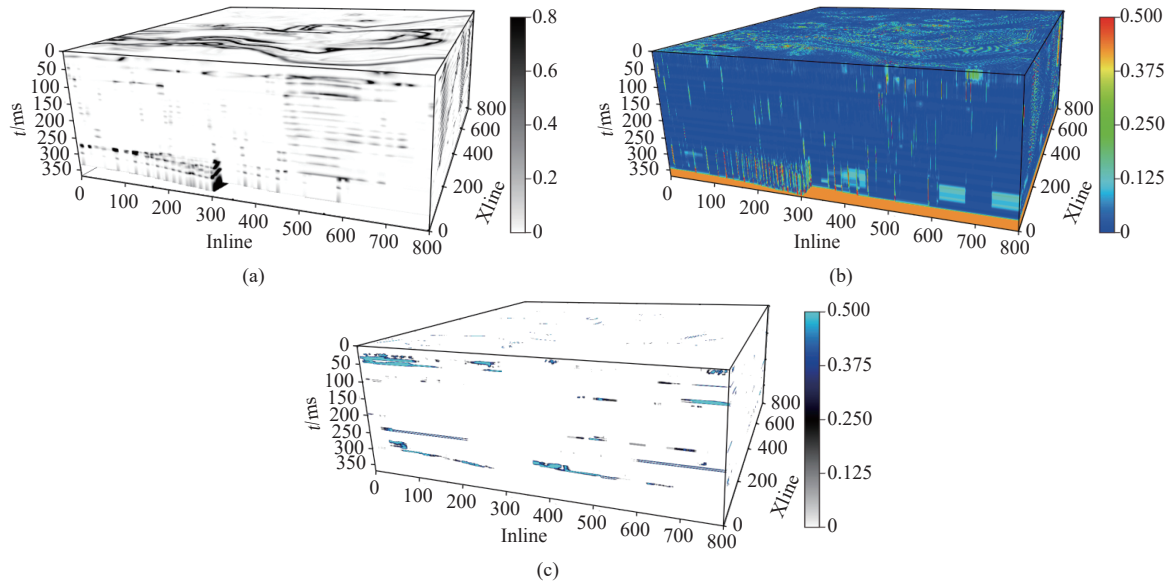



a—3D 推覆体模型；b—25 Hz 雷克子波地震正演结果

a—3D nappe model; b—seismic forward modeling result with a 25 Hz Ricker wavelet

**图 6　基于地震属性变尺度分解与分级融合的断裂识别流程**

**Fig. 6　Flowchart of fault identification based on variable-scale decomposition and hierarchical fusion of seismic attributes**

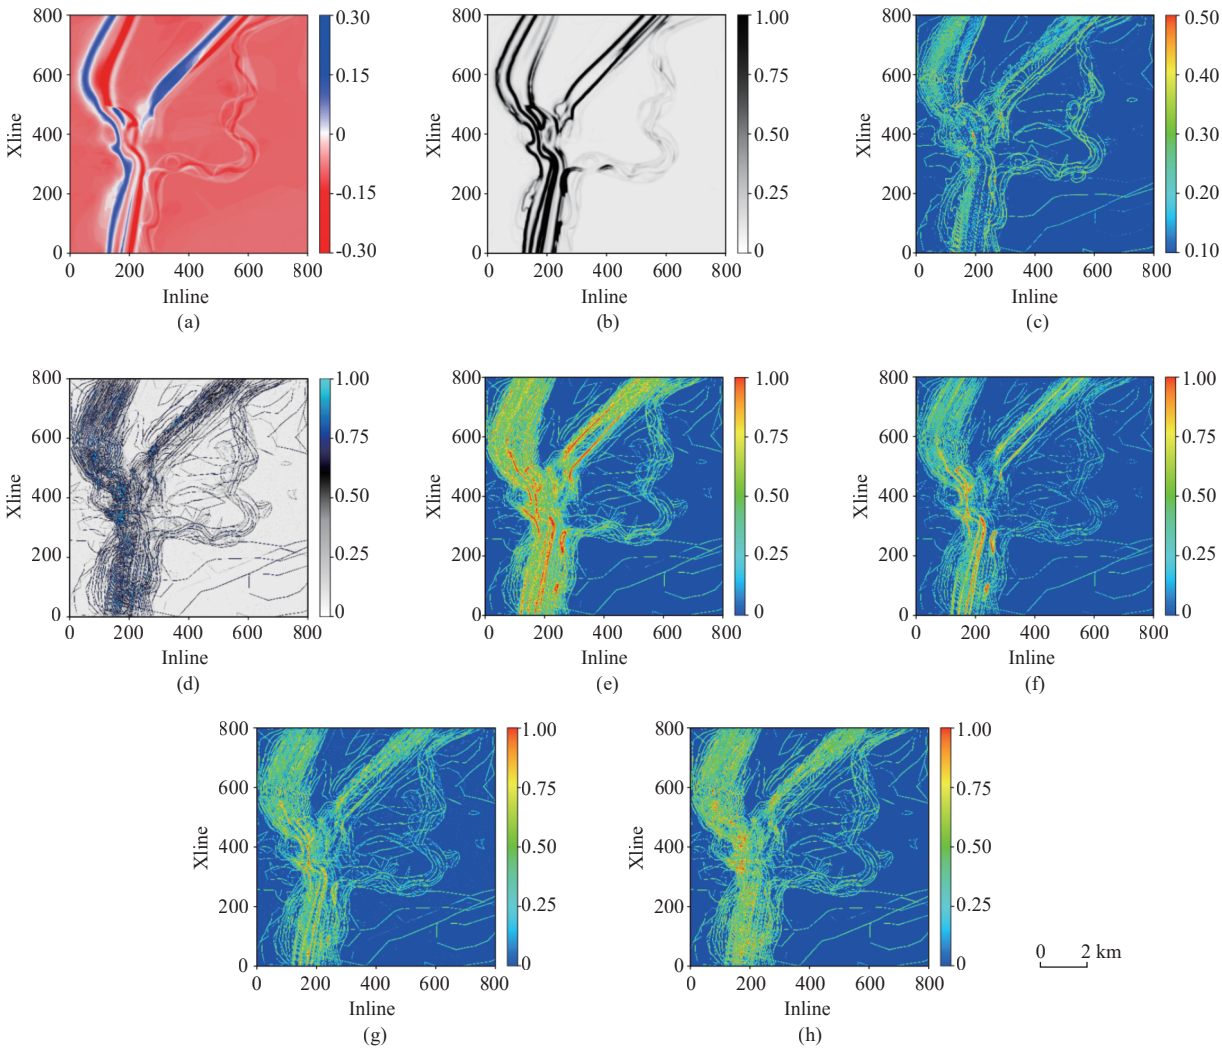



a—方差体；b—曲率；c—蚂蚁追踪

a—varianc; b—curvature; c—ant tracking

**图 7　3D 推覆体模型断裂检测地震属性三维数据体**

**Fig. 7　3D seismic attribute volumes for fault detection in the 3D thrust-nappe model**




a—3D 推覆体模型正演结果; b—方差体; c—曲率; d—蚂蚁追踪; e—变尺度分解与分级融合方法; f—SSAE 方法; g—小波变换方法; h—PCA 方法

a—forward modeling; b—variance; c—curvature; d—ant tracking; e—variable-scale decomposition and hierarchical fusion method; f—SSAE method; g—wavelet transform method; h—PCA method

**图 8　3D 推覆体模型正演、断裂检测属性、各方法多属性融合结果时间切片**

**Fig. 8　Time slices of the forward modeling result, fault detection attributes, and multi-attribute fusion results using different methods for the 3D thrust-nappe model**

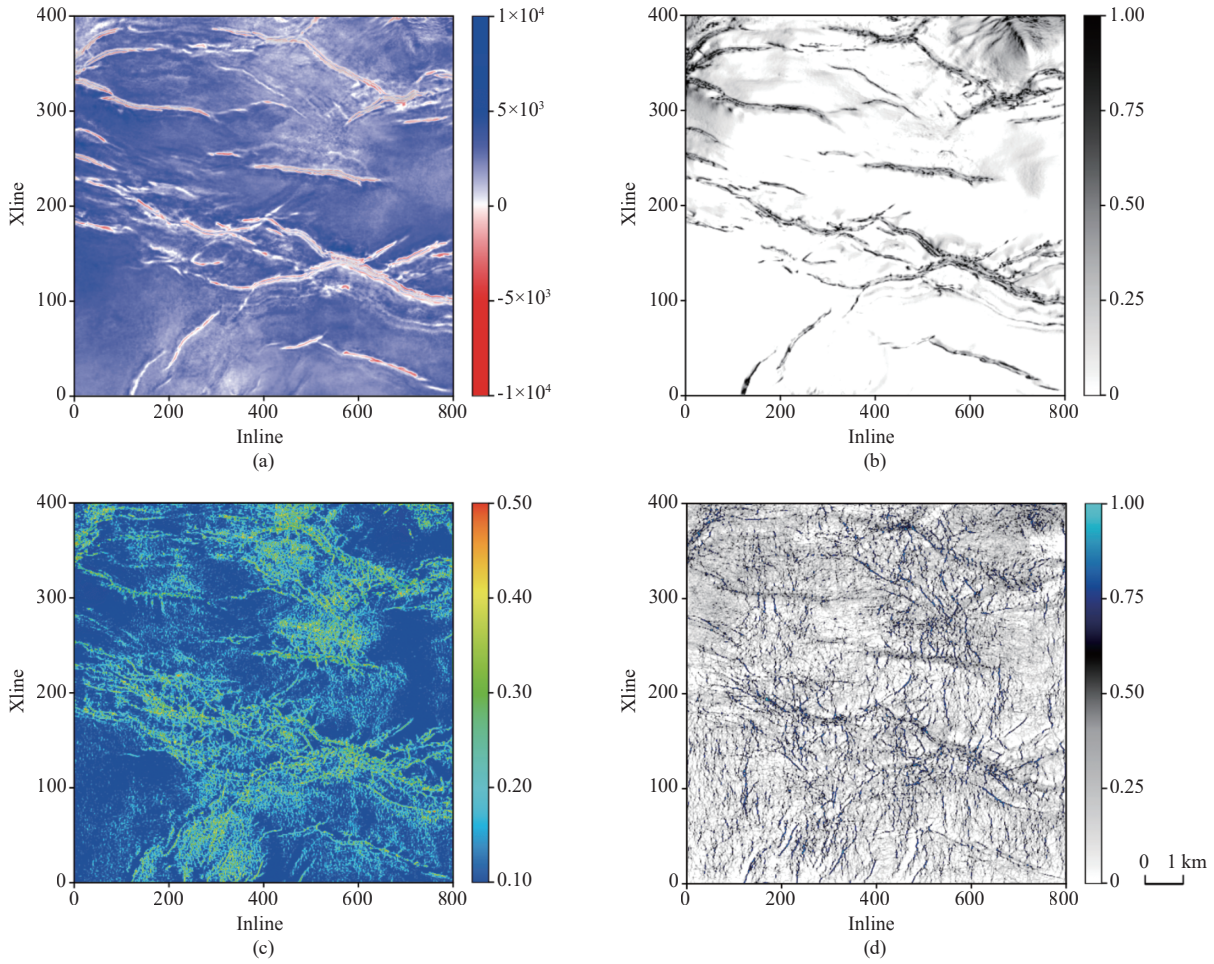
更符合实际地质模型。因此, 变尺度分解与分级融合方法能够有效地、全面地实现复杂断层模型正演地震记录多属性数据融合及断裂预测。

## 3　实例应用

将变尺度分解与分级融合算法应用于渤海湾盆地 B 研究区域, 以分析该方法的可行性与实用性。研究区域地震数据范围内共计线号 800 道, 道号 400 道, 面元为 12.5 m×25 m, 地震数据采样率为 2 ms, 研究区域存在构造转换带, 发育多尺度断裂, 非均质性较强, 不同性质断裂彼此转换交切。基于 B 研究区域叠后地震数据生成方差、曲率、蚂蚁追踪 3 种断裂检测属性并提取沿目的层的地震属性切片, 作为后续输入数据以分析不同断裂属性融合后检测效果。

图 9 为沿目标层系提取的原始地震资料及标准化处理后 3 种断裂检测地震属性切片, 方差体、曲率、蚂蚁追踪 3 种属性对 B 研究区域目标层段断裂检测呈现出不同结果, 3 种属性对针对不同尺度的断裂识别具有特定优势。将 3 种断裂检测属性输入 4 种多属性融合方法获得融合结果进行比对分析。

图 10 为不同方法对图 9 中 3 种断裂检测属性进行融合所得结果对比, 图 10a 为应用变尺度分解与分级融合所得结果, 图 10b 为应用 SSAE 方法融合所得结果, 图 10c 为应用小波变换方法融合所得结果, 图 10d 为应用 PCA 方法融合所得结果, 4 种方法输入数据相同并对结果进行对比分析。4 种方法均




a—原始地震资料; b—方差体; c—曲率; d—蚂蚁追踪

a—raw seismic data; b—variance; c—curvature; d—ant tracking

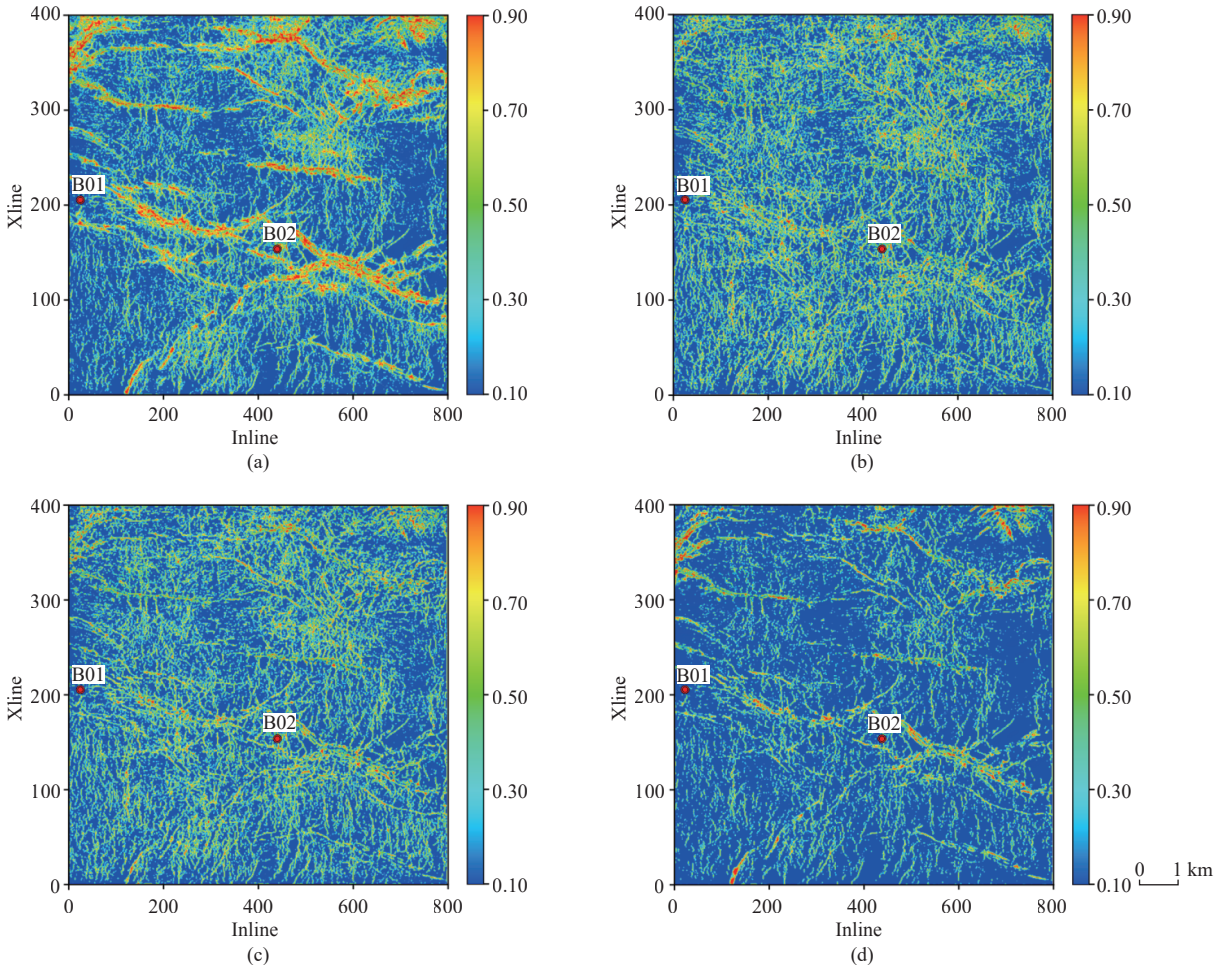
**图 9　目标层原始地震资料及标准化断裂检测地震属性沿层切片**

**Fig. 9　Horizon slices of the raw seismic data and normalized fault detection seismic attributes for the target layer**

能够实现断裂检测地震属性的融合，但 PCA 方法融合结果相较于其他 3 种呈现出更低的表征效果，并且存在过多的细节缺失。小波变换方法融合结果将 3 种地震属性识别的断裂信息较好的融合，表征了断裂信息，但是融合结果杂乱离散，并未对不同尺度断裂表征信息进行分级处理，导致各级尺度信息过度模糊，较大尺度数据对小尺度数据存在遮挡掩盖。SSAE 方法融合结果相较于小波变换方法有所完善，该方法对表征断裂冗余信息进行了处理与消除，将不同尺度信息边界刻画得更加清晰的同时保留了更多小尺度断裂信息，但不足的是牺牲了表征大尺度断裂时的准确性，丢弃了部分低频信息及能量，降低了中、大尺度断裂的连续性。变尺度分解与分级融合放大融合结果相较于其他方法具有明显的优势，各尺度断裂信息采用特定的方法进行融合，因此最终融合结果在保留了各级别尺度的断裂信息及能量的同时，消除了各级信息中分散的能量信息，保证了各尺度断裂识别时能量稳定、轮廓清晰、表征连续，同时横向分辨率更高。

图 11 为方差体、曲率、蚂蚁追踪、本文提出方法的大、中、小尺度分解结果沿层切片，明显的，本文应用的方法可以将方差体(图 11a)、曲率(图 11b)、蚂蚁追踪(图 11c)属性进行多个尺度有效分解，获得多尺度分量并全面地提取出不同尺度的断裂信息，以用于后续的分级融合。同时，本文提出方法(图 11d)的各个尺度分量能够对方差体、曲率、蚂蚁追踪的各个尺度分量综合表征，得到识别能力更准确、能量对比更清晰的各尺度分量。

以 B01 井与 B02 为例，B01 井所处区域在 4 种方法融合结果中均处在断裂较不发育、距离大尺度断裂较远位置，钻井生产验证，B01 井试油结果较差。B02 井目标所在区域在相干体属性中断裂表征模糊，而根据变尺度分解与分级融合结果分析，认为该井所处区域断裂发育密集，经钻井验证，B02 井试油获工业油流，与本文方法预测结果高度吻合，验证了方法的实用性与可靠性。




a—变尺度分解与分级融合方法; b—SSAE 方法; c—小波变换方法; d—PCA 方法

a—variable-scale decomposition and hierarchical fusion method; b—SSAE method; c—wavelet transform method; d—PCA method

**图 10　不同方法多属性融合识别断裂结果对比**

**Fig. 10　Comparison of multi-attribute fusion results for fault identification using different methods**

## 4　讨论

蚂蚁追踪属性受参数影响显著, 断裂空间展布极为复杂, 断裂倾角、走向、倾向等信息均会对断裂识别造成影响, 为了更加全面、准确地表征断裂展布, 后续工作中我们将优化蚂蚁追踪属性的参数设置, 以保证该方法在复杂环境下能够更加精确。

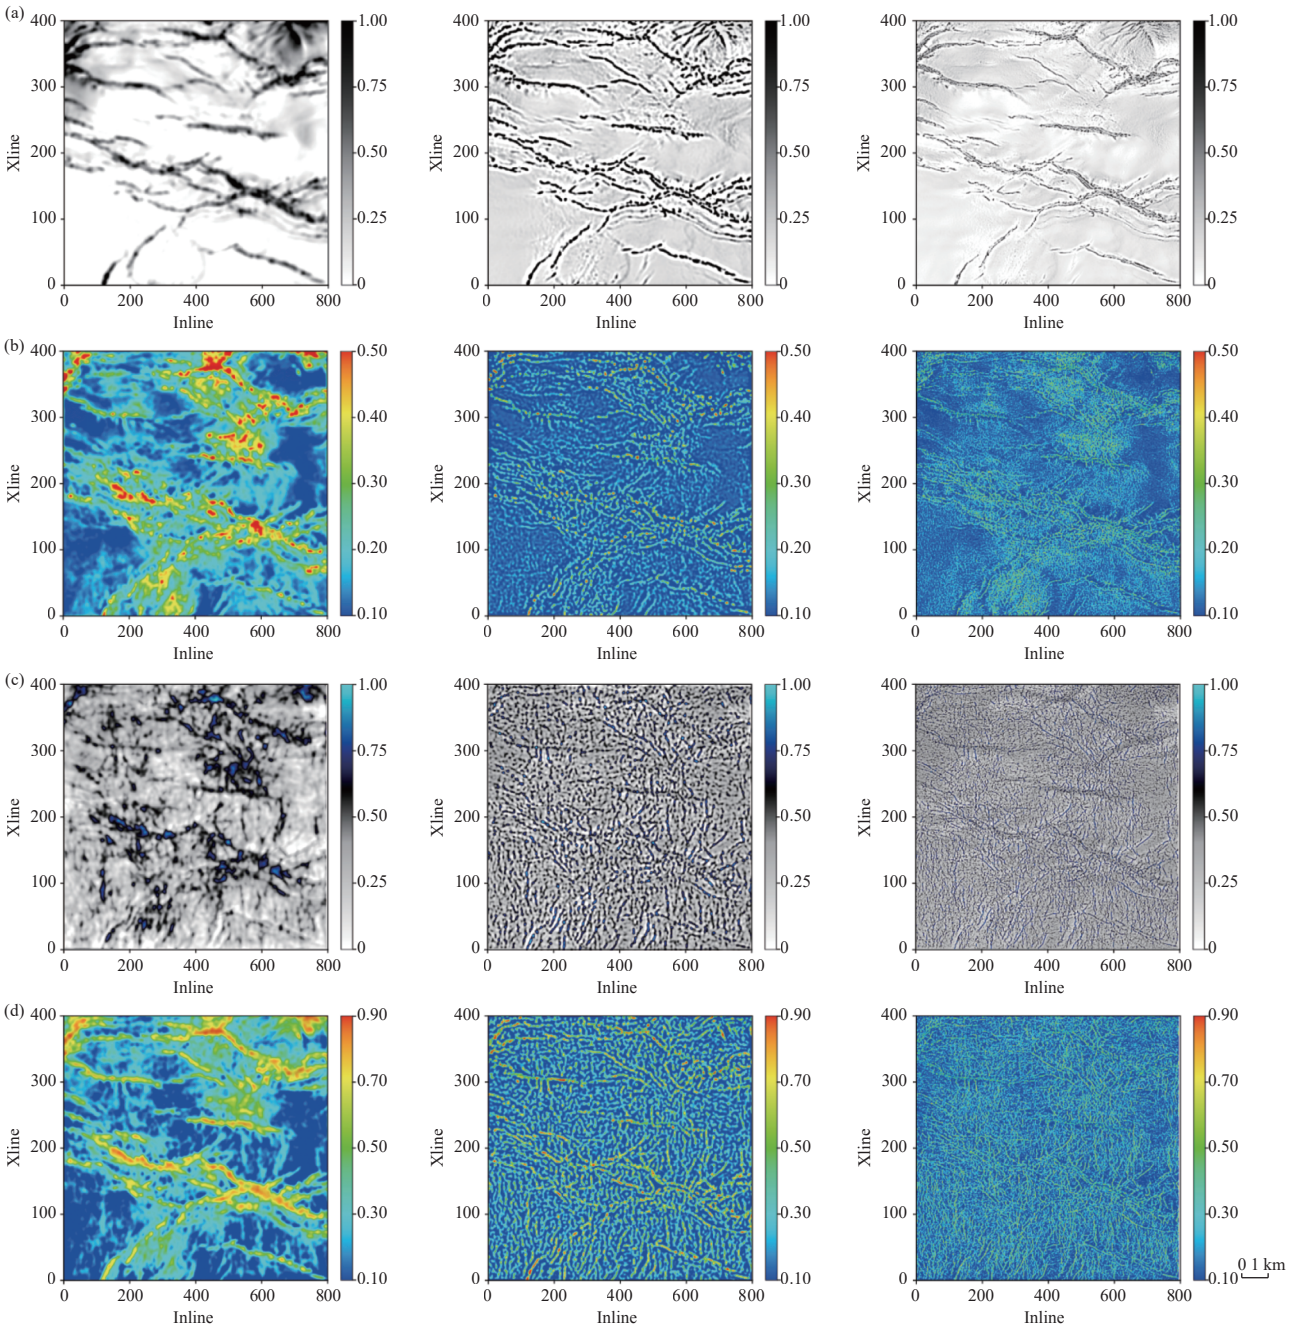
此外, 变尺度分解与分级融合方法由于需要对输入数据进行多尺度分解后, 再对不同尺度利用不同网络进行融合最终获得融合结果, 因此该方法计算量较普通方法更大。测试分析表明在进行变尺度分解时, 输入数据的分解层数不应过多, 过多的层数会导致计算量激增的同时破坏更多本应保留的断裂细节信息。

最后, 在实际应用中应根据研究区域的地质特点, 结合地质专家的认识优选不同的地震属性, 本研究中优选出的属性适用于 B 研究区域, 依实际情况的优选属性能够更加有效地提高断裂解释的准确性。

## 5　结论

本文提出了一种地震属性变尺度分解与分级融合方法用于断裂识别, 该方法利用基于 RGF 的变尺度分解分离出地震属性中不同尺度的断裂信息, 在针对不同尺度断裂响应采用 GAVM 算法、WLE-WSEML 算法、SSAE 算法完成分级融合及重构, 得到高分辨率、兼顾多尺度的断裂识别结果。

将该方法应用于 3D 推覆体模型、B 研究区域实际地震数据, 结果表明, 该方法对不同断裂识别属性的融合效果在能量保留、多尺度断裂刻画能力方面更优越, 横向分辨率高, 相较于其他融合方法(SSAE 方法、小波变换方法、PCA 方法), 该方法有效规避了传统算法的特征冗余与信息丢失问题, 微小断裂识别分辨率提升、大尺度断裂边界刻画更清晰, 抗噪稳定性更强。本文方法为复杂断裂储层多尺度精细




a—方差体; b—曲率; c—蚂蚁追踪; d—本文提出方法

a—variable-scale decomposition and hierarchical fusion method; b—SSAE method; c—wavelet transform method; d—PCA method

**图 11　方差体、曲率、蚂蚁追踪、本文提出方法的大(左)、中(中)、小尺度(右)分解结果沿层切片**

**Fig. 11　Horizon slices of the large (left), medium (middle), and small-scale (right) decomposition results for variance, curvature, ant tracking, and the proposed method**

刻画与高效勘探开发提供了新思路与技术支撑。

## 参考文献(References):

[1]　刘振峰, 曲寿利, 孙建国, 等. 地震裂缝预测技术研究进展 [J]. 石油物探, 2012, 51(2): 191−198.
Liu Z F, Qu S L, Sun J G, et al. Progress of seismic fracture characterization technology[J]. Geophysical Prospecting for Petroleum, 2012, 51(2): 191−198.

[2]　梁志强. 不同尺度裂缝的叠后地震预测技术研究 [J]. 石油物探, 2019, 58(5): 766−772.
Liang Z Q. Poststack seismic prediction techniques for fractures of different scales[J]. Geophysical Prospecting for Petroleum, 2019, 58(5): 766−772.

[3]　李丛, 张栋, 袁青松, 等. 基于多窗口级联属性交互分析的裂缝识别方法及应用 [J]. 地球物理学进展, 2025, 40(3): 1142−1151.
Li C, Zhang D, Yuan Q S, et al. Fracture identification method and application based on multi-window cascade attribute interaction

analysis[J]. Progress in Geophysics, 2025, 40(3): 1142−1151.

[4] Bahorich M, Farmer S. 3-D seismic discontinuity for faults and stratigraphic features: The coherence cube[J]. The Leading Edge, 1995, 14(10): 1053−1058.

[5] 汪勇, 陈学国, 王月蕾, 等. 叠后多属性分析在哈山西石炭系火山岩裂缝预测中的应用研究 [J]. 地球物理学进展, 2014, 29(4): 1772−1779.
Wang Y, Chen X G, Wang Y L, et al. Application of multiple post-stack seismic attributes in the prediction of Carboniferous fracture in west Hashan[J]. Progress in Geophysics, 2014, 29(4): 1772−1779.

[6] Chopra S, Marfurt K. Curvature attribute applications to 3D surface seismic data[J]. The Leading Edge, 2007, 26(4): 404−414.

[7] 王雷, 陈海清, 陈国文, 等. 应用曲率属性预测裂缝发育带及其产状 [J]. 石油地球物理勘探, 2010, 45(6): 885−889.
Wang L, Chen H Q, Chen G W, et al. Application of curvature attributes in predicting fracture-developed zone and its orientation[J]. Oil Geophysical Prospecting, 2010, 45(6): 885−889.

[8] 吕丙南, 陈学华, 吴昊杰, 等. 复杂碳酸盐岩缝洞型储层的地震精细预测方法 [J]. 石油物探, 2024, 63(2): 426−436.
Lyu B N, Chen X H, Wu H J, et al. A fine seismic prediction method for complex carbonate fractured-vuggy reservoirs[J]. Geophysical Prospecting for Petroleum, 2024, 63(2): 426−436.

[9] 陈芊澍, 文晓涛, 何健, 等. 基于极限学习机的裂缝带预测 [J]. 石油物探, 2021, 60(1): 149−156, 174.
Chen Q S, Wen X T, He J, et al. Prediction of a fracture zone using an extreme learning machine[J]. Geophysical Prospecting for Petroleum, 2021, 60(1): 149−156, 174.

[10] 陈秋旭, 曹俊兴, 苏照东, 等. 基于 OVT 域地震数据的多尺度裂缝预测方法及应用 [J]. 地球物理学进展, 2023, 38(3): 1084−1094.
Chen Q X, Cao J X, Su Z D, et al. Multi-scale fracture prediction method based on OVT domain seismic data[J]. Progress in Geophysics, 2023, 38(3): 1084−1094.

[11] 毕俊凤. 地震多属性加权融合显示技术在宣汉-达县地区的应用 [J]. 油气地质与采收率, 2008, 15(2): 75−77.
Bi J F. Application of multi-seismic attribute syncretized technique with weighted algorithm in Xuanhan-Daxian area[J]. Petroleum Geology and Recovery Efficiency, 2008, 15(2): 75−77.

[12] Guo H, Marfurt K J, Liu J L. Principal component spectral analysis[J]. Geophysics, 2009, 74(4): P35−P43.

[13] Fu D T, Sullivan E C, Marfurt K J. Rock property- and seismic-attribute analysis of a chert reservoir in the Devonian Thirty-one Formation, west Texas, U. S. A[J]. Geophysics, 2006, 71(5): B151−B158.

[14] 陈俊, 程金星. 基于 RGB-IHS 变换的地震属性融合方法 [J]. 石油天然气学报, 2014, 36(11): 69−73.
Chen J, Cheng J X. Seismic attribute fusion method based on RGB-IHS transform[J]. Journal of Oil and Gas Technology, 2014, 36(11): 69−73.

[15] 谢成芳, 彭真明, 周晶晶, 等. 基于 Contourlet 变换的地震多属性融合方法 [J]. 石油地球物理勘探, 2014, 49(4): 739−744, 5-6.
Xie C F, Peng Z M, Zhou J J, et al. Seismic multi-attribute fusion based on Contourlet transform[J]. Oil Geophysical Prospecting, 2014, 49(4): 739−744, 5-6.

[16] 曹磊, 蔡峰. 基于地震属性融合技术的火山通道识别研究 [J]. 地球物理学进展, 2021, 36(2): 559−564.
Cao L, Cai F. Recognition research of volcanic conduit based on seismic attribute fusion technology[J]. Progress in Geophysics, 2021, 36(2): 559−564.

[17] 王志勇, 刘国昌, 王梓旭, 等. 基于振幅一致性残差卷积编码—解码器的不规则缺失数据重建 [J]. 吉林大学学报: 地球科学版, 2025, 55(4): 1336−1350.
Wang Z Y, Liu G C, Wang Z X, et al. Reconstruction of irregular missing data based on amplitude consistency residual convolutional encoder-decoder[J]. Journal of Jilin University: Earth Science Edition, 2025, 55(4): 1336−1350.

[18] 曹琳昱, 朱仕军, 周强. 基于粒子群优化的 BP 网络在地震属性融合技术中的应用 [J]. 石油与天然气地质, 2010, 31(5): 685−688.
Cao L Y, Zhu S J, Zhou Q. Application of particle swarm optimization based BP neural network to multi-attribute fusion techniques[J]. Oil & Gas Geology, 2010, 31(5): 685−688.

[19] 李全忠, 彭真明, 周晶晶, 等. 基于脉冲耦合神经网络的地震多属性融合方法 [J]. 石油地球物理勘探, 2014, 49(2): 316−321, 221.
Li Q Z, Peng Z M, Zhou J J, et al. Seismic multi-attribute fusion based on pulse coupled neural networks[J]. Oil Geophysical Prospecting, 2014, 49(2): 316−321, 221.

[20] 李婷婷, 王钊, 马世忠, 等. 地震属性融合方法综述 [J]. 地球物理学进展, 2015, 30(1): 378−385.
Li T T, Wang Z, Ma S Z, et al. Summary of seismic attributes fusion method[J]. Progress in Geophysics, 2015, 30(1): 378−385.

[21] Nayar S K, Nakagawa Y. Shape from focus[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1994, 16(8): 824−831.

[22] 屈小波, 闫敬文, 杨贵德. 改进拉普拉斯能量和的尖锐频率局部化 Contourlet 域多聚焦图像融合方法 [J]. 光学精密工程, 2009, 17(5): 1203−1212.
Qu X B, Yan J W, Yang G D. Multifocus image fusion method of sharp frequency localized Contourlet transform domain based on sum-modified-Laplacian[J]. Optics and Precision Engineering, 2009, 17(5): 1203−1212.

[23] Yin M, Liu X N, Liu Y, et al. Medical image fusion with parameter-adaptive pulse coupled neural network in nonsubsampled shearlet transform domain[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(1): 49−64.

[24] 薄昕, 徐旺林, 陈小宏, 等. 基于局部熵的 LP-PCNN 多属性融合裂缝预测方法 [J]. 石油物探, 2022, 61(5): 821−829.
Bo X, Xu W L, Chen X H, et al. LP-PCNN multi-attribute fusion fracture prediction method based on local entropy[J]. Geophysical Prospecting for Petroleum, 2022, 61(5): 821−829.

[25] 汤韦, 李景叶, 王建花, 等. 基于非下采样剪切波变换—参数自适应脉冲耦合神经网络的属性融合裂缝预测方法 [J]. 石油地球物理勘探, 2022, 57(1): 52−61.
Tang W, Li J Y, Wang J H, et al. Attribute fusion method based on

NSST-PAPCNN for fracture prediction[J]. Oil Geophysical Prospecting, 2022, 57(1): 52−61.

[26] 赵军, 冉琦, 朱博华, 等. 基于前馈神经网络井控多属性融合的断裂识别方法 [J]. 物探与化探, 2024, 48(4): 1045−1053.
Zhao J, Ran Q, Zhu B H, et al. A method for identifying faults based on well-controlled multi-attribute fusion using a feedforward neural network[J]. Geophysical and Geochemical Exploration, 2024, 48(4): 1045−1053.

[27] Gui Z P, Zhang J H, Zhang Y T, et al. Characterization of fault-karst reservoirs based on deep learning and attribute fusion[J]. Acta Geophysica, 2025, 73(2): 1335−1347.

[28] Qian F, Yin M, Liu X Y, et al. Unsupervised seismic facies analysis via deep convolutional autoencoders[J]. Geophysics, 2018, 83(3): A39−A43.

[29] Li K H, Zong J J, Fei Y F, et al. Simultaneous seismic deep attribute extraction and attribute fusion[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5906410.

[30] 周单, 钟晗. 基于 SSAE 的地震属性融合技术 [J]. 地球物理学进展, 2024, 39(2): 647−660.
Zhou S, Zhong H. Seismic attribute fusion technology based on SSAE[J]. Progress in Geophysics, 2024, 39(2): 647−660.

[31] 印兴耀, 周静毅. 地震属性优化方法综述 [J]. 石油地球物理勘探, 2005, 40(4): 482−489.
Yin X Y, Zhou J Y. Summary of optimum methods of seismic attributes[J]. Oil Geophysical Prospecting, 2005, 40(4): 482−489.

[32] Zhang Q, Shen X Y, Xu L, et al. Rolling guidance filter[G]//Computer vision–ECCV 2014. Cham: Springer International Publishing, 2014: 815-830.

[33] Hattori T, Inoue K, Hara K. Rolling guidance filter as a clustering algorithm[J]. IEICE Transactions on Information and Systems, 2021, E104-D(10): 1576-1579.

[34] Gong X Q, Hou Z Y, Wan Y T, et al. Multispectral and SAR image fusion for multiscale decomposition based on least squares optimization rolling guidance filtering[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5401920.

[35] 商宏涛, 施国良. 基于 SSAE 深度学习特征表示的高光谱遥感图像分类方法 [J]. 计算机测量与控制, 2018, 26(10): 291−294.
Shang H T, Shi G L. Hyperspectral remote sensing image classification method based on SSAE deep learning feature representation[J]. Computer Measurement & Control, 2018, 26(10): 291−294.

[36] 张永升, 黄超, 刘军, 等. 地震信号倒谱分解技术及其在超深层碳酸盐岩储层烃类检测中的应用 [J]. 物探与化探, 2024, 48(6): 1618-1625.
Zhang Y S, Huang C, Liu J, et al. Cepstrum decomposition of seismic signals and its application in hydrocarbon detection of ultra-deep carbonate reservoirs[J]. Geophysical and Geochemical Exploration, 2024, 48(6): 1618-1625.

[37] 张刚, 王俊辉, 惠鑫, 等. 基于小波变换与 CMT 架构融合的地层智能划分与对比研究 [J]. 测井技术, 2025, 49(6): 879−889.
Zhang G, Wang J H, Hui X, et al. Research on intelligent stratigraphic division and correlation with integrated wavelet transform and CMT architecture[J]. Well Logging Technology, 2025, 49(6): 879−889.

[38] 王飞文, 孙五斌, 郑明丹. 融合主成分分析与曲率特征的点云去噪方法研究 [J]. 测绘与空间地理信息, 2024, 47(11): 182−185.
Wang F W, Sun W B, Zheng M D. Research on point cloud denoising method combining principal component analysis and curvature characteristics[J]. Geomatics & Spatial Information Technology, 2024, 47(11): 182−185.

# A method for fault identification based on the varying-scale decomposition and hierarchical fusion of seismic attributes and its application

LI Zhi-Chao [1, 2, 3], LIU Guo-Chang [1, 2, 3], LU Jia-He [1, 2, 3], SHEN Jia-Hao [1, 2, 3], WU Qi-Bin [1, 2, 3], BAN Qi [1, 2, 3], WANG Hao-Tian [1, 2, 3]

(1. *College of Geophysics, China University of Petroleum (Beijing), Beijing* 102249, *China*; 2. *State Key Laboratory of Petroleum Resources and Engineering, Beijing* 102249, *China*; 3. *Key Laboratory of Geophysical Exploration ,CNPC, Beijing* 102249, *China*)

**Abstract:** Fault-controlled reservoirs represent important targets for the exploration and exploitation of unconventional hydrocarbons. Accurately identifying multi-scale faults directly determines the reservoir productivity and economic benefits. Although seismic attributes are commonly used for fault prediction, a single attribute struggles to characterize multi-scale faults simultaneously. To address this challenge, this study proposes a novel method for fault identification based on varying-scale decomposition and hierarchical fusion of seismic attributes. First, multiple optimized seismic attributes for fault identification are extracted, and multi-scale fault responses are separated from noise components using a multi-scale decomposition algorithm based on the rolling guidance filter (RGF). Then, distinct fusion models tailored to small-, medium-, and large-scale faults are established. Specifically, a Gaussian-weighted absolute value maximization (GAVM) rule is adopted to achieve adaptive weighted fusion of small-scale attributes, thus enhancing weak fault responses. The weighted local energy is combined with a weighted sum of eight-neighborhood-based modified Laplacian (WLE-WSEML) for medium-scale attribute fusion, thereby highlighting the spatial distribution of medium-scale faults. A stacked sparse autoencoder (SSAE) is used to conduct deep non-linear fusion of large-scale attributes, achieving fine-scale characterization of large-scale fault structures. Finally,

multi-scale fusion results are integrated to form comprehensive attributes for fault characterization. Tests on synthetic and field seismic data demonstrate that the proposed method in this study can effectively overcome the issues of feature redundancy and information loss inherent in traditional attribute fusion algorithms. The proposed method significantly improves the resolution of minor- and small-scale faults and yields clearer boundaries and enhanced noise-resistant performance for large-scale faults. Therefore, this study provides reliable technical support for accurate prediction of complex fault-controlled reservoirs.

**Key words:** fault identification; seismic attribute fusion; multi-scale fault; hierarchical fusion; variable-scale decomposition

（本文编辑: 叶佩）