

doi:10.3799/dqkx.2013.114

基于贝叶斯网络的地震相分类

顾元¹, 朱培民¹, 荣辉², 曾凡平³, 海洋⁴

1. 中国地质大学地球物理与空间信息学院, 湖北武汉 430074

2. 中国地质大学资源学院, 湖北武汉 430074

3. 东方地球物理公司研究院大港分院, 天津 300280

4. 中铁一院甘肃铁道综合工程勘察院有限公司物探工程新技术研究所, 甘肃兰州 730000

摘要: 为了解决传统多地震属性的地震相分类方法中“难以引入先验信息用以指导分类, 难以给出地震相分类结果可靠程度的定量估计, 且各分类参数的权值较难确定”这3个问题, 提出了一种新的基于贝叶斯网络的地震相分类方法。该分类方法有效地融合了先验信息和训练样本的分布特征, 对提取的多种地震属性进行智能分析, 以概率推理的方式得到各地震相类别的概率值, 并根据概率分布估计分类结果的可靠程度。详述了贝叶斯网络用于地震相分类的原理与方法, 并结合理论地震数据, 验证了该方法的可行性和正确性。

关键词: 贝叶斯网络; 地震属性; 数据挖掘。

中图分类号: P631.4

文章编号: 1000-2383(2013)05-1143-10

收稿日期: 2012-11-13

Seismic Facies Classification Based on Bayesian Networks

GU Yuan¹, ZHU Pei-min¹, RONG Hui², ZENG Fan-ping³, HAI Yang⁴1. *Institute of Geophysics and Geomatics, China University of Geosciences, Wuhan 430074, China*2. *Faculty of Earth Resource, China University of Geosciences, Wuhan 430074, China*3. *Dagang Branch of GRI, BGP Inc., CNPC, Tianjin 300280, China*4. *Geophysical Research Institute of Gansu Integrated Engineering Investigation of Railway, Lanzhou 730000, China*

Abstract: There are three challenging issues in traditional seismic facies classification based on seismic attributes. Firstly, it is difficult to introduce priori-information into the processing of classification to enhance the result of seismic facies classification. Secondly, it is difficult to quantitatively evaluate reliability of the result for seismic facies classification. Thirdly, it is difficult to determine the weights of all parameters of Bayesian networks in classification. In order to solve the above-mentioned problems, this paper proposes a new approach of seismic facies classification based on Bayesian networks, which effectively combines the priori-information and probability distribution of the training samples to construct a reasonable classification model, and deduce the probability for each of seismic facies. According to the probability distribution of each seismic facies, we could estimate the reliability of the classification results in a quantitative manner. The principles and workflow are presented in detail for applying Bayesian networks to seismic facies classification. The numerical experiment proves that this method is correct and feasible.

Key words: Bayesian networks; seismic facies classification; seismic attribute; data mining.

地震数据被用于油气藏勘探, 要求在目标地区钻井前, 利用各种有效信息来提高储层预测的准确性, 其中地震相识别就是储层预测的基础工作之一。地震相是指有一定分布范围的地震反射单元, 具体地说, 是反射单元内各种岩相的地震波的综合响应。

划分地震相, 并通过井的标定, 可以建立起地震相与地质体的对应关系, 进行区域地层解释、确定沉积体系、预测有利生油区和储集相带。但是, 人工进行地震相解释, 其工作量巨大, 解释效率低, 而且存在解释结果受人为因素影响较大等缺点。

基金项目: 国家自然科学基金(Nos.41174049, 91014002); “973”深部煤炭资源综合地质评价理论与方法研究(No.2006CB202202)。

作者简介: 顾元(1983—), 男, 博士生, 主要从事地震数据处理、层析成像、数值模拟及决策分析方面的研究。E-mail: guy15@163.com

目前多借助多种地震属性的分析技术来进行地震相的划分,可以较大幅度地提高地震相解释的效率(朱红涛等,2011,2013).然而,多地震属性的地震相识别是一个多因素的综合分类问题(Dumay and Fournier, 1988; Saggaf *et al.*, 2003; John *et al.*, 2008),由于要面对类别众多的地震属性,解释的工作量仍然很大.鉴于地震属性与目标地质体之间复杂的关系,目前尚无法找到地震属性与地质体间一一对应的联系,且对不同地震相、不同的沉积环境,最有效和最具代表性的地震属性是不同的,因此地震属性解释同样存在某种程度的多解性.目前,已发展出一些地震属性智能化的解释技术(如聚类、主因素分析、降维和神经网络等方法)来解决这个问题.它们均克服了过去主要依靠人工完成多属性地震相分类的缺点,通过综合分析多种地震属性与不同类别地震相之间的相关性,建立起地震相类别与各种地震属性值的对应关系,对地震相进行分类,大大提高了地震相分类的准确性和效率(Dumay and Fournier, 1988; Saggaf *et al.*, 2003; de Matos *et al.*, 2007; John *et al.*, 2008).但这些方法仍然有 3 个主要问题未能解决:(1)评价地震相分类结果的可信度或可靠性比较困难;(2)在地震相分类过程中无法利用有价值的先验信息以指导分类并提高分类结果的准确性;(3)各分类参数的权值较难确定.

为解决以上 3 个问题,本文提出了基于贝叶斯网络的地震相分类方法.该方法通过多种地震属性的智能分析,得到地震相的分类结果及可靠性的定量评价.其优点是可将先验信息引入分类的过程中,有效地利用先验信息和训练样本的分布特征指导分类,以概率推理的方式得到各地震相类别的概率值,从而估计出分类结果的可靠程度,因此可有效地解决过去的多属性地震相分类方法所面临的问题.本文以露头剖面所构建的地质模型为例,说明了地震相识别过程中的建模、学习和分类的步骤,并且验证了该方法的可行性和正确性.

1 贝叶斯网络地震相分类原理及流程

1.1 贝叶斯网络分类原理

贝叶斯网络是近年来发展较快的、应用于数据挖掘的智能决策模型.目前贝叶斯网络已有比较成功的应用,如资源评价(Porwal *et al.*, 2006)、医疗诊断(Heckerman, 1990)、金融分析(Sun and Shenoy, 2007)以及军事目标识别(Langley, 1993)等.

贝叶斯网络是应用概率来表示变量间依赖关系的有向无环图,由网络结构和网络参数确定(Korb and Nicholson, 2004; Neapolitan, 2004).网络结构由代表变量的结点及连接这些结点的有向边构成,其中有向边表示了变量间的因果关系.网络参数由关于变量间因果关系的一系列条件概率表组成,且这些条件概率表列出了每个结点相对于其父结点的所有条件概率.

贝叶斯网络分类的理论基础是贝叶斯定理,形式如下:

$$P(C | X) = \frac{P(X | C)P(C)}{P(X)}, \quad (1)$$

式中: $X = (X_1, X_2, X_3, \dots, X_n)$ 为随机变量集合,代表已知样本及其属性;随机变量为推理或待分类的结果类别变量, C 的可能取值为 $c_1, c_2, c_3, \dots$, 或 c_m . $P(C)$ 和 $P(C | X)$ 分别为分类结果类别 C 的先验概率和后验概率, $P(C)$ 是对过去经验总结或统计得到的 C 的概率分布, $P(X | C)$ 是 C 的似然度,是待分类样本数据集关于类别 C 的概率统计结果.

基于贝叶斯网络分类的流程是:

(1)定义变量.根据研究中用于分类的属性参数定义变量,包括代表参与分类的各个属性参数的变量和代表最终分类结果的类别变量.例如,在贝叶斯网络地震相分类中定义的变量包括地震相类别变量和代表参与分类的地震属性的变量.由于各个属性参数的数值大小及值域范围不同,且考虑到基于离散变量的贝叶斯网络在算法上比较容易实现,可对各属性参数按照一定的规则进行离散化及标准化处理.

(2)网络训练.包括网络结构训练和网络参数训练.通过对训练样本的学习,得到贝叶斯网络分类模型的网络结构和网络参数;根据贝叶斯网络训练算法的不同,网络训练前可仅定义变量,而不定义变量间的关系(有向边),网络结构和网络参数完全由网络训练算法得到;也可根据先验信息中变量之间的关系,构建初始网络模型,提高网络训练的准确度(Korb and Nicholson, 2004).

(3)数据的分类.以训练后的贝叶斯网络分类模型为基础,查询对应变量的网络参数,通过公式(1)可计算出待分类样本对应各个类别的后验概率值 $P(C | X)$, 即当指标参数取值为 $X = (X_1, X_2, \dots, X_n) = (x_1, x_2, \dots, x_n)$ 时,地震相类别 $C = c_j$ 的概率.概率值最大的类别即被认为是与传统方法分类结果相同的定性的分类结果.例如,若 C 的类别数为




图1 示例中的条件概率表的分布特征

Fig.1 The distribution of conditional probability in two instances

2,取值分别为 c_1 或 c_2 .当

$$P(C=c_1 | X_i=x_i) > P(C=c_2 | X_i=x_i)$$

时,样本被定为 c_1 类.当

$$P(C=c_1 | X_i=x_i) < P(C=c_2 | X_i=x_i)$$

时,样本被定为 c_2 类(Neapolitan, 2004).

设 $X=(X_1, \dots, X_n)$, 且各变量相互独立时,则公式(1)可简化为:

$$P(C | X_1, \dots, X_n) \propto P(C) \prod_{i=1}^n P(X_i | C). \quad (2)$$

由上式可以看出后验概率 $P(C | X_1, \dots, X_n)$ 为 C 的先验概率与每个变量对应的条件概率值的乘积.其中先验概率 $P(C)$ 根据过去的分类经验总结的 C 为各个类别的概率;条件概率分布 $P(X_i | C)$ ($i=1, \dots, n$) 是通过对训练样本的学习得到的,反映了训练样本中各个属性参数与分类类别的相关性.

贝叶斯网络分类具备以下 3 个重要的特性(Korb and Nicholson, 2004; Neapolitan, 2004): (1)分类结果为各类别的概率值,给出了评价结果的可信度或可靠性; (2)将先验信息引入到贝叶斯网络的训练过程中,降低了对训练数据样本分布的过度依赖,避免了对于学习数据过度拟合的情况发生; (3)各个评价参数的权值是通过对于样本数据的学习自动获得的,有较高的智能性.

下面以一个示例来说明贝叶斯网络分类的 3 个重要特征在分类过程中的意义与重要性.假设有一个贝叶斯网络分类问题,包含先验信息的概率分布 $P(C)$ 和从样本数据中训练得到的两个属性参数的条件概率分布 $P(X_1 | C)$ 和 $P(X_2 | C)$, 根据公

式(2)求得后验信息的概率分布 $P(C | X_1, X_2)$, 即分类的结果.取概率值最大的类别作为评价的类别结果,这等同于传统的聚类、主因素分析、降维和神经网络等方法的评价结果.当分类结果的概率分布为非均匀分布时,分类结果的可信度高.例如,当先验信息、属性参数和分类结果如图 1a 到图 1d 时,虽然 $P(C)$ 、 $P(X_1 | C)$ 和 $P(X_2 | C)$ 中概率最高类别分别为 3、4 和 2,但是 $P(C | X_1, X_2)$ 的最高概率仍然为类别 3.这是因为 $P(X_1 | C)$ 和 $P(X_2 | C)$ 的概率分布相比于 $P(C)$,更接近均匀分布,因此先验信息的权重高于其他两个属性参数.依据公式(2),计算结果 $P(C | X_1, X_2)$ 的最高概率的类别与先验概率分布 $P(C)$ 相同.这说明,如果能够将正确的先验信息输入贝叶斯网络分类模型中指导分类,即使训练数据的质量很差,甚至有错误,仍然能得到正确的结果.

再看另外一种情况.当先验信息、属性参数和分类结果如图 1e~1h 时,属性参数 X_1 与 C 的相关性,比属性参数 X_2 与 C 的相关性更高,条件概率 $P(X_1 | C)$ 权重高于先验信息和另外一个属性参数,因此计算结果 $P(C | X_1, X_2)$ 的最高概率的类别与 $P(X_1 | C)$ 相同.这说明,当多个属性参数同时参与分类时,贝叶斯网络分类模型在训练的过程中统计各属性参数与分类结果的相关性,自动给定各属性参数设置权值.

以上两种情况,由于计算结果图 1d 和 图 1h, $P(C | X_1, X_2)$ 中类别 3 的概率值均超过了 0.50, 高于类别 4 的概率值 0.25, 因此将概率值最高的类别 3 作为分类的结果.由于类别 3 的概率远高于其他类别的概率值,将其定为类别 3 的可信度是较高




图 2 基于贝叶斯网络的地震相分类流程

Fig.2 Workflow chart of seismic facies classification based on Bayesian Networks

的.如果类别 3 与类别 4 的概率值相差不大,则可同时将类别 3 或类别 4 作为分类结果.

1.2 地震相分类思想及流程

基于贝叶斯网络的地震相分类的基本思想是:有效地融合关于地震相的先验信息和典型地震相训练样本的分布特征,构建出合理的地震相分类模型,以概率推理的方式得到地震相各类别的概率值,并根据概率分布估计出地震相分类结果的可靠程度.依据上述思想,作者设计的地震相贝叶斯网络分类算法如图 2 所示.地震相分类所需要的数据包括:先验信息,用于训练的样本数据(地震属性)和待分类的实例数据(地震属性).分类目标是将地震相划分到不同的类别,其具体工作步骤如下:

(1)提取地震属性;(2)对地震属性数据作预处理;(3)建立初始贝叶斯网络模型,设置先验信息;(4)输入学习样本,对网络进行训练;(5)将训练后的分类模型用于地震相的分类.

2 方法实现与测试

由于露头可以提供真实的、可与地下情况对比的

沉积地质信息、岩石物性参数等,从而能确定岩性、岩石物性和沉积相的关系,为地震相的分类和预测提供一个可靠的验证基础(Grammer *et al.*, 2004).因此,本文以塔里木西北部巴楚一间房组生物礁滩露头剖面所构建的地震模型为例,说明贝叶斯地震相网络分类流程中的建模、学习和分类的过程、地震相分类所涉及的各种算法,验证方法的可行性.

2.1 地质建模

焦养泉等(2011)和 Jiao *et al.*(2012)根据巴楚一间房组的台缘生物礁—滩沉积体系的典型露头的野外调查结果(图 3),以生物礁为中心,将剖面中的 5 种成因相归纳为生物礁、生物滩和台缘背景沉积等 3 种成因相的组合.为了建立地质模型,在该剖面上共采集了 25 个岩石样本,并在实验室中测量了岩石的纵波速度与密度等物性(曾凡平等, 2009),测量结果如表 1 所示.取各成因相的纵波速度均值和密度均值计算对应的纵波波阻抗值.对比各成因相的纵波波阻抗值,可看出内滩最低、外滩和礁基次之、礁核最高,而台地介于礁核和外滩之间.

2.2 地震模型

基于露头写实以及地质解释结果,并根据上述测量数据,建立了地震波阻抗模型,运用褶积的方法计算出了对应的合成地震记录,用以验证及测试本文所提出的地震相分类方法(图 4).为了方便,试验省去了时深转换的环节,直接建立了时间域的地震波阻抗模型.波阻抗模型大小为 200×300 的网格,深度间隔为 1 ms,CDP 间隔为 10 m.对应的合成地震记录采用主频为 30 Hz 的雷克子波,并加入了 5%的高斯随机噪声.

2.3 地震属性

笔者根据地震属性对地质体反应的敏感性和符合率较大的原则,选择了 8 种地震属性作为地震相分类的基础数据,包括:瞬时振幅、瞬时频率、均方根振幅、平均绝对振幅、绝对距离、欧式距离、互相关距离和相似系数.图 5 是根据图 4b 计算出的地震属性结果.

2.4 分类模型的构建及训练

由于没有类似的研究成果作参照,无法通过前人的研究成果设定地震相分类贝叶斯网络的先验信息(初始网络结构和网络参数).因此,在网络结构训练前,仅定义了网络节点,将其作为初始网络结构,而在网络参数学习前,将各节点参数的条件概率分布表均设定为均匀分布,作为贝叶斯网络参数学习的初始网络参数.




图 3 塔里木一间房组生物礁滩露头剖面(据焦养泉等, 2011)

Fig.3 Reef outcrop of Bachu Yijianfang Formation in northwest Tarim

a.剖面照片;b.剖面写实

表 1 岩石物性测量结果

Table 1 Results of petrophysical measurement

成因相组合	成因相	纵波波速(m/s)		密度(kg/m ³)	
		均值	标准差	均值	标准差
生物礁	礁核	4 771	734.7(±15.4%)	2 690	24.2(±0.9%)
	礁基	3 057	596.1(±19.5%)	2 627	63.0(±2.4%)
生物滩	内滩	2 221	417.5(±18.8%)	2 595	67.5(±2.6%)
	外滩	3 054	910.1(±29.8%)	2 616	65.4(±2.5%)
台缘背景沉积	台地	4 374	852.9(±19.5%)	2 613	78.4(±3%)
下伏地层		5 500	—	2 700	—

表 2 列出了本研究中用于地震相分类所定义的变量名。

由于礁基、内滩和外滩的波阻抗差异小,在地震上较难区别,因此在实验中将礁核和礁基合并为生物礁,把内滩和外滩合并为生物滩.为了区分台缘背景沉积中的单层内部的随机噪声和层序界面对应的

地震相,实验中将台地分为内部均匀沉积和层序界面两类地震相.因此,以礁核、生物滩和台缘背景沉积这 3 种成因相组合为最小划分单元,试验将地震相的类别数最终确定为 4 个:1 类为生物礁,2 类为生物滩,3 类为台地 1—内部均匀沉积和 4 类为层序界面.由于各种地震属性的数值大小及值域范围都




图 4 波阻抗模型及合成地震记录

Fig.4 Impedance model and synthetic seismic data

a.波阻抗模型;b.地震模型(加入 5%的高斯随机噪声)




图 5 地震属性

Fig.5 Seismic attributes computed from Fig.4(b)

a.绝对平均振幅;b.均方根振幅;c.瞬时振幅;d.瞬时频率;e.绝对距离;f.欧氏距离;g.互相关距离;h.相似系数

表 2 贝叶斯网络节点定义

Table 2 The categories of nodes in Bayesian networks

变量名	分类结果	瞬时振幅	瞬时频率	均方根振幅	平均绝对振幅	绝对距离	欧式距离	互相关	相似系数
编号	①	②	③	④	⑤	⑥	⑦	⑧	⑨

不同,考虑到基于离散变量的贝叶斯网络算法容易实现,故在样本数据输入评价模型之前,均对其进行离散化处理.本次试验的离散化规则为:根据地震属性的值域范围分成 5 个区间,按照其数值从大到




图 6 训练样本的提取
Fig.6 Training samples

a.波阻抗模型;b.绝对平均振幅;c.均方根振幅;d.瞬时振幅;e.瞬时频率;f.绝对距离;g.欧氏距离;h.互相关距离;i.相似系数




图 7 结构学习后的贝叶斯网络结构

Fig.7 The results of Bayesian networks structure learning

①地震相;②瞬时振幅;③瞬时频率;④均方根振幅;⑤绝对平均振幅;⑥绝对距离;⑦欧式距离;⑧互相关距离;⑨相关系数

小的规则将其编号(1(大)~5(小)).

选择模型中的部分典型区域(如图 6 的白框内)按照所属的沉积相类别编号,逐一提取对应区域的各地震属性值,并对其进行整理,最后将结果用于贝叶斯网络的结构训练和参数训练.贝叶斯网络的训练采用了 K2 算法 (Cooper and Herskovits, 1992),该算法将同时完成结构和参数训练.结构训练的结果如图 7 所示.

2.5 地震相分类

将整个模型的地震属性输入到训练后的地震相分类模型中,应用贝叶斯网络的推理算法可得到地




图 8 地震相分类结果

Fig.8 Results of the seismic facies classification

a.地震相分类类别结果;b.1类(生物礁)地震相的预测概率;c.2类(生物滩)地震相的预测概率;d.3类(台地1—内部均匀沉积)地震相的预测概率;e.4类(层序界面)地震相的预测概率

震相的分类结果(图 8).本文所选用的评价方法为全局联合树推理算法(Pearl, 1986).图 8a 为地震相分类的类别结果,分别显示了各类地震相的分布范围,与地质模型(图 3,图 4)相比,其整体分类结果较好.其中 1 类(生物礁)和 2 类(生物滩)的地震相分布与地质模型总体比较吻合,3 类(台地 1—内部均匀沉积)和 4 类(层序界面)的分布范围也较准确.图 8b~8e 分别为 1 类(生物礁)、2 类(生物滩)、3 类(台地 1—内部均匀沉积)和 4 类(层序界面)地震相的概率值分布图.但是,还要注意到图 8a 中白色框的部分与地质模型(图 3,图 4)存在着较大的差距,这可能是由于 1 类(生物礁)太小或者由于周围生物滩的影响,地震波对于部分生物礁相的响应不好造成的.

对比地震模型(图 4)、地震属性(图 5)和地震相分类结果(图 8),以及各地震相的概率分布图发现,虽然图 5a~5c,5g 和 5h 中地震属性较好的反映了地震相的分布形态,中强幅值与礁滩的分布也较吻合,但是也有如图 5d~5f 成为了地震属性进行地震相分类的干扰因素.这是因为图 5d~5f 所表示的地震属性对剖面中沉积相的变化不敏感所致(所得各

类别概率值接近于均匀分布).

若在地震相分类前进行属性优选,剔除如图 5d~5f 对分类结果具有负面影响的地震属性,按照 2.4 节所述方法,重新对地震相分类模型进行训练,得到的分类结果如图 9 所示.与图 8 的分类结果相比,分类结果的精度有了提高.但是在未进行属性优选的情况下,本研究所得到的地震相分类结果(图 8)并没有受到太大的负面影响,依然得到了准确性较高的地震相分类结果.究其原因,就是在网络参数的训练过程中,由于地震属性与分类的不相关性,造成该地震属性的分类概率值接近于均匀分布,自动降低了不利于地震相解释的地震属性对于地震相分类结果的负面影响,且不需要任何人工的干预(参见 2.1 节).

3 结论

本文提出的基于贝叶斯网络的地震相分类方法,并以巴楚一间房组台缘生物礁—滩沉积体系的典型露头剖面所构建的地质模型为例,描述了地震




图 9 地震属性优选后的地震相分类结果

Fig.9 Results of the seismic facies classification after seismic attributes optimization
a.地震相分类类别结果;b.1 类(生物礁)地震相的预测概率;c.2 类(生物滩)地震相的预测概率;d.3 类(台地 1—内部均匀沉积)地震相的预测概率;e.4 类(层序界面)地震相的预测概率

相识别过程中贝叶斯网络的建模、学习和分类的步骤,并且验证了该方法的可行性和正确性.

与现有的确定性地震相分类方法比较,具有一定的优势:(1)经过实例数据的测试,证明本文所建立的地震相分类方法是可靠的,为地震相分类研究提供了一种新的、更加有效的方法;(2)以概率分布的形式输出分类的结果,原则上将概率值最大的类别作为待分类样本所属的类别,分类结果的概率分布即是分类的可靠性评价;(3)通过引入先验信息,降低了对训练数据样本分布的过度依赖,并且提高了分类结果的准确性;(4)该方法在没有人工干预的情况下,通过对样本数据的学习,智能地完成了各地震属性权值设定;当某些地震属性结果对地震相分类不利时,该方法可自动降低其对分类结果的负面影响;在地震相分类过程中,由于不需要人工干预,因而更客观可靠.

由于时间有限及其他方面的原因,本文提出的地震相分类方法仅对理想地震数据进行了应用,对于实际数据的应用效果还需要进一步的验证和深入研究.

致谢:本研究得到了中国地质大学(武汉)资源

学院焦养泉教授的指导和帮助.文章中的地震相分类程序调用了贝叶斯网络 Matlab 工具箱(Bayes Net Toolbox),该工具箱为加拿大英属哥伦比亚大学 Murphy 教授的研究成果,作者在此一并致谢.

References

Cooper, G. F., Herskovits, E., 1992. A Bayesian Method for the Induction of Probabilistic Networks from Data. *Machine Learning*, 9(4): 309—347.

de Matos, M.C., Osorio, P.L.M., Johann, P.R.S., 2007. Unsupervised Seismic Facies Analysis Using Wavelet Transform and Self-organizing Maps. *Geophysics*, 72(1): 9—21. doi:10.1190/1.2392789

Dumay, J., Fournier, F., 1988. Multivariate Statistical Analyses Applied to Seismic Facies Recognition. *Geophysics*, 53(9): 1151—1159. doi:10.1190/1.1442554

Grammer, G.M., Harris, P.M., Eberli G.P., 2004. Integration of Outcrop and Modern Analogs in Reservoir Modeling. *AAPG Memoir*, 80: 1—22.

Heckerman, D., 1990. Probabilistic Similarity Networks. *Networks*, 20(5): 607—636. doi:10.1002/net.3230200508

Jiao, Y.Q., Rong, H., Wang, R., et al., 2011. Reservoir Depo-

- sitional System Analysis of Ordovician Carbonate Platform Margin in Yijianfang Outcrops of Western Tarim Basin, *Acta Petrologica Sinica*, (1): 285—296 (in Chinese with English abstract).
- Jiao, Y. Q., Wu, L. Q., Rong, H., et al., 2012. Paleocology of the Ordovician Reef-Shoal Depositional System in the Yijianfang Outcrop of the Bachu Area, West Tarim Basin, *Journal of Earth Science*, 23(4): 408—420.
- John, A., Lake, L., Torres-Verdin, C., et al., 2008. Seismic Facies Identification and Classification Using Simple Statistics, *SPE Reservoir Evaluation & Engineering*, 11(6): 984—990, doi:10.2118/96577-PA
- Korb, K. B., Nicholson, A. E., 2004. Bayesian Artificial Intelligence. CRC Press, Boca Raton, 28.
- Langley, P., 1993. Induction of Recursive Bayesian Classifiers, *Machine Learning*, 667: 153—164, doi: 10.1007/3—540—56602—3_134
- Neapolitan, R. E., 2004. Learning Bayesian Networks, Pearson Prentice Hall, Upper Saddle River, New Jersey, 13—15.
- Pearl, J., 1986. Fusion, Propagation, and Structuring in Belief Networks, *Artificial Intelligence*, 29(3): 241—288, doi:10.1016/0004—3702(86)90072—X
- Porwal, A., Carranza, E. J. M., Hale, M., et al., 2006. Bayesian Network Classifiers for Mineral Potential Mapping, *Computers & Geosciences*, 32(1): 1—16, doi: 10.16/j.cageo.2005.03.018
- Saggaf, M., Toksoz, M., Marhoon, M., 2003. Seismic Facies Classification and Identification by Competitive Neural Networks, *Geophysics*, 68(6): 1984—1999, doi: 10.1190/1.1635052
- Sun, L. L., Shenoy, P. P., 2007. Using Bayesian Networks for Bankruptcy Prediction: Some Methodological Issues, *European Journal of Operational Research*, 180(2): 738—753, doi:10.1016/j.ejor.2006.04.019
- Zeng, F. P., Zhu, P. M., Jiao, Y. Q., et al., 2009. Relationship Between Sedimentary System and Acoustic Velocity of Rocks from Marine Strata in Keping-Bachu Area, *Acta Sedimentologica Sinica*, 27(2): 312—318 (in Chinese with English abstract).
- Zhu, H. T., Yang, X. H., Zhou, X. H., et al., 2011. High Resolution Three-Dimensional Facies Architecture Delineation Using Sequence Stratigraphy, Seismic Sedimentology: Example from Dongying Formation in BZ3-1 Block of Western Slope of Bozhong Sag, Bohai Bay Basin, *Earth Science—Journal of China University of Geosciences*, 36(6): 1073—1084 (in Chinese with English abstract).
- Zhu, H. T., Yang, X. H., Zhou, X. H., et al., 2013. Sediment Transport Pathway Characteristics of Continental Lacustrine Basins Based on 3-D Seismic Data: An Example from Dongying Formation of Western Slope of Bozhong Sag, *Earth Science—Journal of China University of Geosciences*, 38(1): 121—129 (in Chinese with English abstract).

附中文参考文献

- 焦养泉, 荣辉, 王瑞, 等, 2011. 塔里木盆地西部一间房露头区奥陶系台缘储层沉积体系分析. 岩石学报, (1): 285—296.
- 曾凡平, 朱培民, 焦养泉, 等, 2009. 柯坪—巴楚露头区海相地层声波速度与沉积体系的关系. 沉积学报, 27(2): 312—318.
- 朱红涛, 杨香华, 周心怀, 等, 2011. 基于层序地层学和地震沉积学的高精度三维沉积体系: 以渤中凹陷西斜坡 BZ3-1 区块东营组为例. 地球科学——中国地质大学学报, 36(6): 1073—1084.
- 朱红涛, 杨香华, 周心怀, 等, 2013. 基于地震资料的陆相湖盆物源通道特征分析: 以渤中凹陷西斜坡东营组为例. 地球科学——中国地质大学学报, 38(6): 1073—1084.