

A Review of Application of Machine Learning in Wireline Logging Formation Evaluation

Tianwei Yang¹, Qi Wang¹, Yongzhen Liu¹, Yu Wan^{1,2*}, Xin Nie^{1,2}

¹College of Geophysics and Petroleum Resources, Yangtze University, Wuhan Hubei

²Key Laboratory of Exploration Technologies for Oil and Gas Resources (Yangtze University), Wuhan Hubei
Email: *313343078@qq.com

Received: Mar. 5th, 2020; accepted: Apr. 8th, 2020; published: Jun. 15th, 2020

Abstract

With the development of logging technology, the logging data is getting bigger, and the traditional method can't solve the big data problems of multiple logging data. Machine learning is an important subject in artificial intelligence. The way of its various research results is to automatically extract features from massive data. It can perfect application in well logging interpretation. This paper summarizes the machine learning method and its application in geophysical logging formation evaluation, and puts forward the prospect.

Keywords

Deep Learning, Machine Learning, Geophysical Logging, Lithology Identification, Reservoir Evaluation

*通信作者。

机器学习在测井地层评价中的应用综述

杨添微¹, 王 啟¹, 刘永震¹, 万 宇^{1,2*}, 聂 昕^{1,2}

¹长江大学地球物理与石油资源学院, 湖北 武汉

²长江大学油气资源与勘探技术教育部重点实验室, 湖北 武汉

Email: *313343078@qq.com

收稿日期: 2020年3月5日; 录用日期: 2020年4月8日; 发布日期: 2020年6月15日

摘 要

随着测井技术的发展, 测井数据量越来越大, 传统方法在解决多种测井数据综合形成的大数据问题时遇到了困难。机器学习是人工智能领域的一个重要学科, 其多种研究成果的途径是从海量数据中自动提取特征, 并通过逐层特征变化进而解决复杂的分类或预测问题, 可以完美应用在数据类型较多的测井解释中。本文对机器学习方法及其在地球物理测井评价中的应用进行归纳总结, 并提出了展望。

关键词

深度学习, 机器学习, 地球物理测井, 岩性识别, 储层评价

Copyright © 2020 by author(s), Yangtze University and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

机器学习在人工智能领域具有相当大的影响, 其深度学习是构建分层模型结构[1], 对输入数据从底层到高层逐级进行提取并建立对应关系。就实际贡献而言, 深度学习也许是近十年来机器学习领域最成功的课题。Geoffrey Hinton [2]因提出训练深度神经网络的方法, 使深度学习因其强大的表现数据内部结构的能力获得了各领域学者们的广泛关注, 自 2012 年深度学习成功应用于图像识别和语音识别以来, 各领域的学者便一直在积极扩展深度学习的应用范围和影响力, 目前正成为资源勘查领域的一个非常吸引人的技术。

神经网络技术具有求解问题时的强抗干扰能力和非线性映射能力, 为测井解释的发展开拓了一个新的研究思路。与传统的测井解释方法相比, 神经网络技术的独特优势体现在: 不需要建立具体的解释模型和具体的计算公式; 不需要对大量的参数进行选取; 不需要太多的专家经验[3]。深度学习是在神经网络的基础上使其层数更加深入, 它可以从海量数据中自动提取特征, 并通过逐层特征变化进而解决复杂的分类或预测问题。因此, 为了解决复杂的储层解释问题, 机器学习在地球物理测井中的应用必将越来越多。

随着测井技术的发展, 测井方法越来越多、精度越来越高、数据量越来越大。每一条测井曲线对地层岩性信息都有相应的响应, 如果同时解释多条测井曲线, 就需要同时解决复杂的多维度非线性问题和

多种测井数据综合形成的大数据的问题[4] [5]，这是传统的交会图法等方法无法解决的。作为智能算法，机器学习具有从大量数据中自动提取特征，并通过逐层特征变化解决复杂的分类或预测问题的特点，其在测井领域已经有了应用。对机器学习在测井中的应用进行调研并总结分析，可为测井智能解释奠定基础。

2. 机器学习的概述

机器学习是一门多领域交叉学科，涉及概率论、统计学、逼近论、凸分析、算法复杂度理论等多门学科。机器学习的方法有很多，包括神经网络法、支持向量机算法、决策树算法等[6]，机器学习理论主要是设计和分析一些让计算机可以自动“学习”的算法。机器学习算法是一类从数据中自动分析获得规律，并利用规律对未知数据进行预测的算法。因为学习算法中涉及了大量的统计学理论，机器学习与统计推断学联系尤为密切，也被称为统计学习理论。算法设计方面，机器学习理论关注可以实现的，行之有效的学习算法。很多推论问题属于无程序可循难度，所以部分的机器学习研究是开发容易处理的近似算法。

其分为两个阶段：浅层学习和深度学习。在 20 世纪 80 年代末期，发明了人工神经网络的反向传播算法(BP 算法) [7]。该算法可以让一个人工神经网络模型从大量训练样本中学习统计规律，并利用此规律对未知的事件做出预测。但是此时的神经网络模型隐层层数过浅，所以也被称为浅层学习。在 2006 年，Hinton 和他的学生 Salakhutdinov 在学术刊物《Science》上发表了一篇文章[8]，该文章提出了深度学习的概念。这篇文章主要提出了对于很多隐层的人工神经网络具有良好的特征学习能力，可以学习得到更精准的数据特征，更有利于数据分类，这里提到的神经网络模型就已经是多隐层层数的了，所以可以被称为深度学习。

机器学习已经有了十分广泛的应用，例如：数据挖掘、计算机视觉、自然语言处理、生物特征识别、搜索引擎、医学诊断、检测信用卡欺诈、证券市场分析、DNA 序列测序、语音和手写识别、战略游戏和机器人运用[8] [9] [10]。

3. 机器学习在测井地层评价中的应用

尽管浅层学习时期发明的 BP 算法可以使人工神经网络模型从大量训练样本中学习统计规律，并利用此规律对未知事件做出预测，但是这些模型的结构隐层节点层数极少，不能满足测井的需要。深度学习的本质是通过构建含有很多隐层节点的机器学习模型，使用大量的数据进行训练，来学习更多更有用的特征，从而提高分类或预测的精准度。所以，是用深度模型的方法，对样本进行特征学习。

3.1. 机器学习在测井岩性识别中的应用

岩性识别是储层含油气性评价、油藏描述等方面的重要内容之一，是求解油气储层各种参数的基础。与其它岩性识别方法(如取岩心)相比，利用测井资料识别岩性速度快、费用低，也正因此才被广泛采用。常规的利用测井资料识别地层岩性的方法主要有交会图法[11] [12]、统计学方法[13]以及成像测井[14]，但是传统识别方法精度低、效率慢并且人为因素影响大，而成像测井价格昂贵，不利于广泛实际应用，因此研究出一种高精度自动识别岩性的方法对于测井数据解释具有重要的意义。神经网络、决策树和支持向量机在测井岩性识别领域具有良好的应用前景。

神经网络(Artificial Neural Network, ANN)是由大量处理单元(神经元)互相连接组成的大规模、非线性、自适应动力学系统[15]。信息由输入层到输出层不断传递，中间神经元根据某种准则不断调整对接收到的相应信号的处理方式，最终使输出层得到想要的信息[16]。目前，在测井岩性识别中实际效果好且应用最广泛的有 2 种神经网络模型：误差反传神经网络(BPNN)、径向基函数神经网络(RBFNN)。BPNN 是一种全局逼近神经网络，在训练过程中误差逐层向输入层逆向传播，对网络中出现的所有权值和阈值进行修正，RBFNN 是一种局部逼近网络，对于每个训练样本，它只需要对少量的权值和阈值进行修正，另

外 RBFNN 通过径向基函数将低维空间中非线性可分的问题映射到高维空间,使其在高维空间中线性可分。BPNN 与 RBFNN 两者功能相近,可以互相替代,但理论上后者结构简单、收敛速度快,能够逼近任意非线性函数,相比 BPNN 更适用于测井岩性识别[17]。

决策树(Decision Tree, DT)是一个类似流程图的树状结构,可以从一组无规则、无次序的分类样本中推理出分类规则。DT 通过根节点到叶节点的顺序对样本进行分类,其中每个节点代表一个因变量,每个分支代表它所连接的上节点在其自变量上的可能取值。分类时采取自顶向下的递归方式,在内部节点进行因变量的比较,并根据不同的因变量值判断从该节点向下的分支,在树的叶节点得到结论即因变量 y ,整个过程都是以新节点为根的子树上的重复[18]。DT 的建立由建树和剪枝组成[19],所有 DT 算法都遵循这 2 个阶段,所产生的算法有 C5.0, CART, QUEST 和 CHAID,差异只在于测量指标不同,如在建树过程中如何确定首先使用哪个自变量和自变量取值作为拆分点。其中, C5.0 算法与其他算法相比,通常不需要很长的训练次数,而且面对数据缺失和数据量大的问题时稳健性明显高于其他算法[6],这在测井岩性识别时优势明显。

支持向量机(Support Vector Machine, SVM)建立在统计学理论和结构风险最小原理基础上,在学习精度和学习能力之间寻求最佳折中,可最大化模型的预测能力,是一项功能强大的分类和回归技术[20]。对于线性不可分问题, SVM 的主要原理是:用核函数将样本映射到高维特征空间,在高维特征空间中构造最优分割面,避免了在原空间中进行非线性曲面分割的计算,样本通过核函数映射到高维空间,增加了线性分割概率。但对某些情况仍然无法实现线性分割,如数据有噪声。SVM 则允许样本点在一定程度上偏离最优分割面,样本点 x_i 允许偏离最优分割面的量称为松弛变量 ξ_i 。因此,实现最优分类需调节松弛变量,使其达到最优[21][22]。与调节松弛变量相比,核函数的选择才是影响分类效果的关键,包括线性核函数、多项式核函数、RBF 核函数和 Sigmoid 核函数,而核函数的选择没有唯一确定的准则,在测井岩性识别中需要根据实际情况进行尝试和比较[21][23]。

前人对进行岩性识别主要使用的是 BP 神经网络:侯俊胜和王颖(1999)对煤气层测井资料进行了定量解释识别[24],卢新卫和金章东(1999)对胜利油田某测井岩性进行识别[25],范训礼等(1999)对塔里木油田 TZ4 测井的岩性进行了识别[26],他们用的都是 BP 神经网络手段,而且相同的是识别结果准确率均不高。蔡磊和程国建等人(2010)采用极限学习机的方法对测井岩性进行识别[27]。在蔡磊(2010)的文章中使用了机器学习的支持向量机方法。在这次验证中,蔡磊的研究对象选择了自然伽玛,深感应电阻率,中子-密度孔隙度差,平均中子-密度孔隙度,光电效应这 5 条测井曲线,选取了 10 口井中的 6 口作为训练集 3150 个样本,2 口作为验证集 421 个样本,2 口作为测试集 431 个样本。最终结果显示岩性识别正确率如表 1。识别结果较好,表明了基于支持向量机的机器学习算法也能在岩性识别中发挥很好的作用。

Table 1. Results of lithology identification of Cai Lei *et al.* (2010) [28]

表 1. 蔡磊等(2010)岩性识别结果表[28]

岩性编号	岩性名称	样本总数	SVM 正确样本数	正确率%	ELM 正确样本数	正确率%
1	陆相砂岩	8	8	100	8	100
2	陆相粗砂岩	21	20	95.24	20	95.24
3	陆相细砂岩	22	18	81.82	19	86.36
4	海相粉砂岩和页岩	13	12	92.31	12	92.31
5	泥岩	30	28	93.33	27	90
6	泥粒灰岩	67	52	77.61	53	79.1
7	白云岩	34	31	91.18	29	85.29
8	泥粒灰岩-粒屑灰岩	56	52	87.5	50	87.5
9	叶状-藻状积岩	32	30	93.75	31	96.88

安鹏和曹丹平(2018)基于深度学习对测井岩性识别进行了研究[28],构建了一个包含多个隐层的深度神经网络模型(图 1),其中激励函数采用的是 ReLU 函数,神经网络优化算法采用的是 Adagrad 算法,并且在原始输出层和最终输出层之间添加了 softmax 层将神经网络输出转变成一个概率分布。

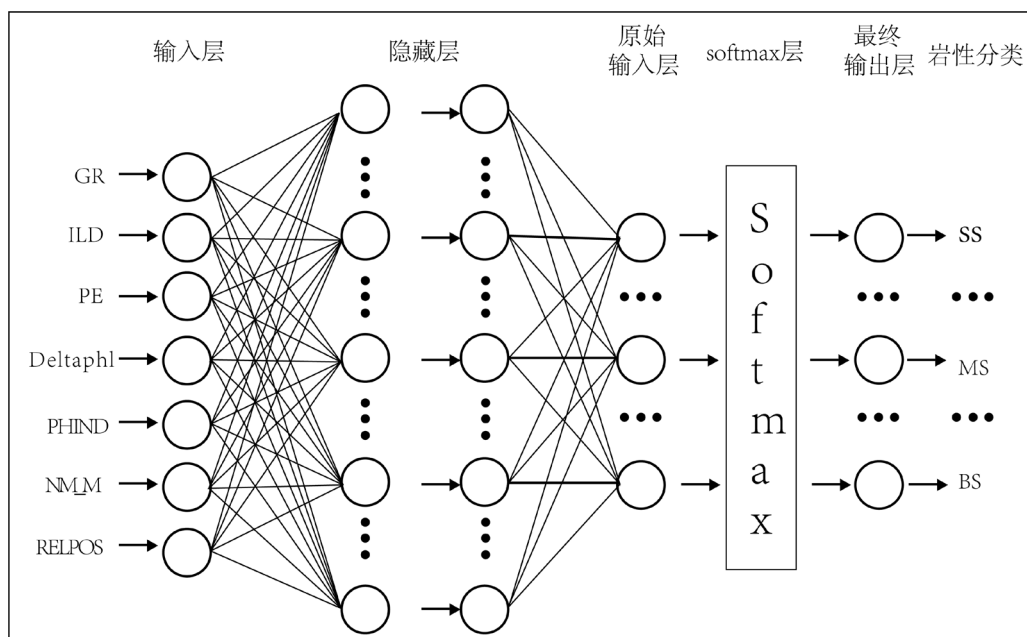


Figure 1. Deep neural network constructed by An and Cao (2018) [28]

图 1. 安鹏和曹丹平(2018)构建的深度神经网络[28]

深度神经网络使用前馈传播(Forward propagation)将训练数据输入到网络中,逐层训练至输出层,得到本次的样本数据的预测估计值,然后将预测估计值带入交叉熵损失函数计算误差,然后使用反向传播算法获得每一个神经元的误差值。接着使用基于梯度的 Adagrad 优化算法,首先根据代价函数计算模型的每一个参数的梯度,根据梯度计算“惩罚值”,调整模型参数,使预测结果向优化目标(即岩性标签)接近。

3.2. 机器学习在测井孔隙度预测中的应用

储层孔隙度的准确计算对估算石油、天然气等资源的储量具有极大的影响。如果要计算孔隙度,要先从储层测井曲线的特征出发,对测井资料进行综合分析[29]。对于砂泥岩剖面,有体积模型法、基于岩心分析资料拟合法等[30]。对于碳酸盐岩储层,借助核磁测井、电成像等测井方法对储层空间类型进行孔隙度求解[31] [32]。但有些地区缺少核磁测井、电成像测井等资料,又由于碳酸盐岩储层非均质性强[33] [34],孔隙度与测井曲线并无确定的线性关系,所以在复杂岩性的碳酸盐岩储层中,要利用 BP 神经网络的非线性的映射能力进行储层孔隙度的预测[35]。用神经网络法来解释孔隙度,就是通过给训练样本进行学习得到一种解释模型,用该模型对未知井进行孔隙度预测[36] [37] [38],网络的输出层单元只有实测的孔隙度。王娜娜等[39]改进了传统的 BP 算法,改进后的 BP 算法收敛速度快,图 2 为王娜娜所用 BP 网络计算孔隙度的模型。

周雪晴等[38]利用邻域粗糙集选取孔隙度敏感曲线,并将磷虾觅食算法和 BP 神经网络相结合,建立了最终神经网络孔隙度预测模型。在实验中,周雪晴等人得到的不同隐含层数目的误差的比较,如表 2。




Figure 2. BP network porosity calculation model by Wang *et al.* (2008) [38]

图2. 王娜娜等(2008)计算孔隙度的BP网络孔隙度模型[38]

Table 2. Comparison of errors of different hidden layers by Zhou *et al.* (2017) [39]

表2. 周雪晴等(2017)部分不同隐含层数目的误差的比较[39]

隐层层数	结点数/个	SEE	R	最大迭代次数	训练时间/s
1	4	22.75	0.67	111	1
1	5	22.51	0.69	232	3
1	6	21.07	0.72	374	5
1	7	21.19	0.72	630	8
2	4、4	21.60	0.70	592	9
2	4、3	21.21	0.73	1397	21
2	4、2	22.85	0.69	1250	18
2	5、4	20.65	0.75	596	9
3	3、2、4	22.95	0.69	1000	50
3	3、3、3	22.23	0.70	1000	56
3	4、3、2	22.11	0.71	1000	58
3	5、5、2	22.19	0.74	1000	41

周雪晴等(2017)选用不同的训练函数,为效果较好的部分训练函数结果。选取训练效果最好的训练函数 *trainlm* 为最终孔隙度模型训练函数。最终对资料进行处理,结果如图3所示。

3.3. 机器学习在测井渗透率预测中的应用

反映储层非均质性最直接的参数是就渗透率,使用常规方法解释的渗透率精度一直较低[40] [41]。神经网络是深度学习中的一种模型,人工神经网络具有结构、神经元传递函数及学习算法3个属性[42] [43],在实际应用中,大多采用的是BP网络,由于渗透率的影响因素较多,不确定性、非结构化现象严重,因此,适用BP网络方法预测砂岩储层的渗透率。

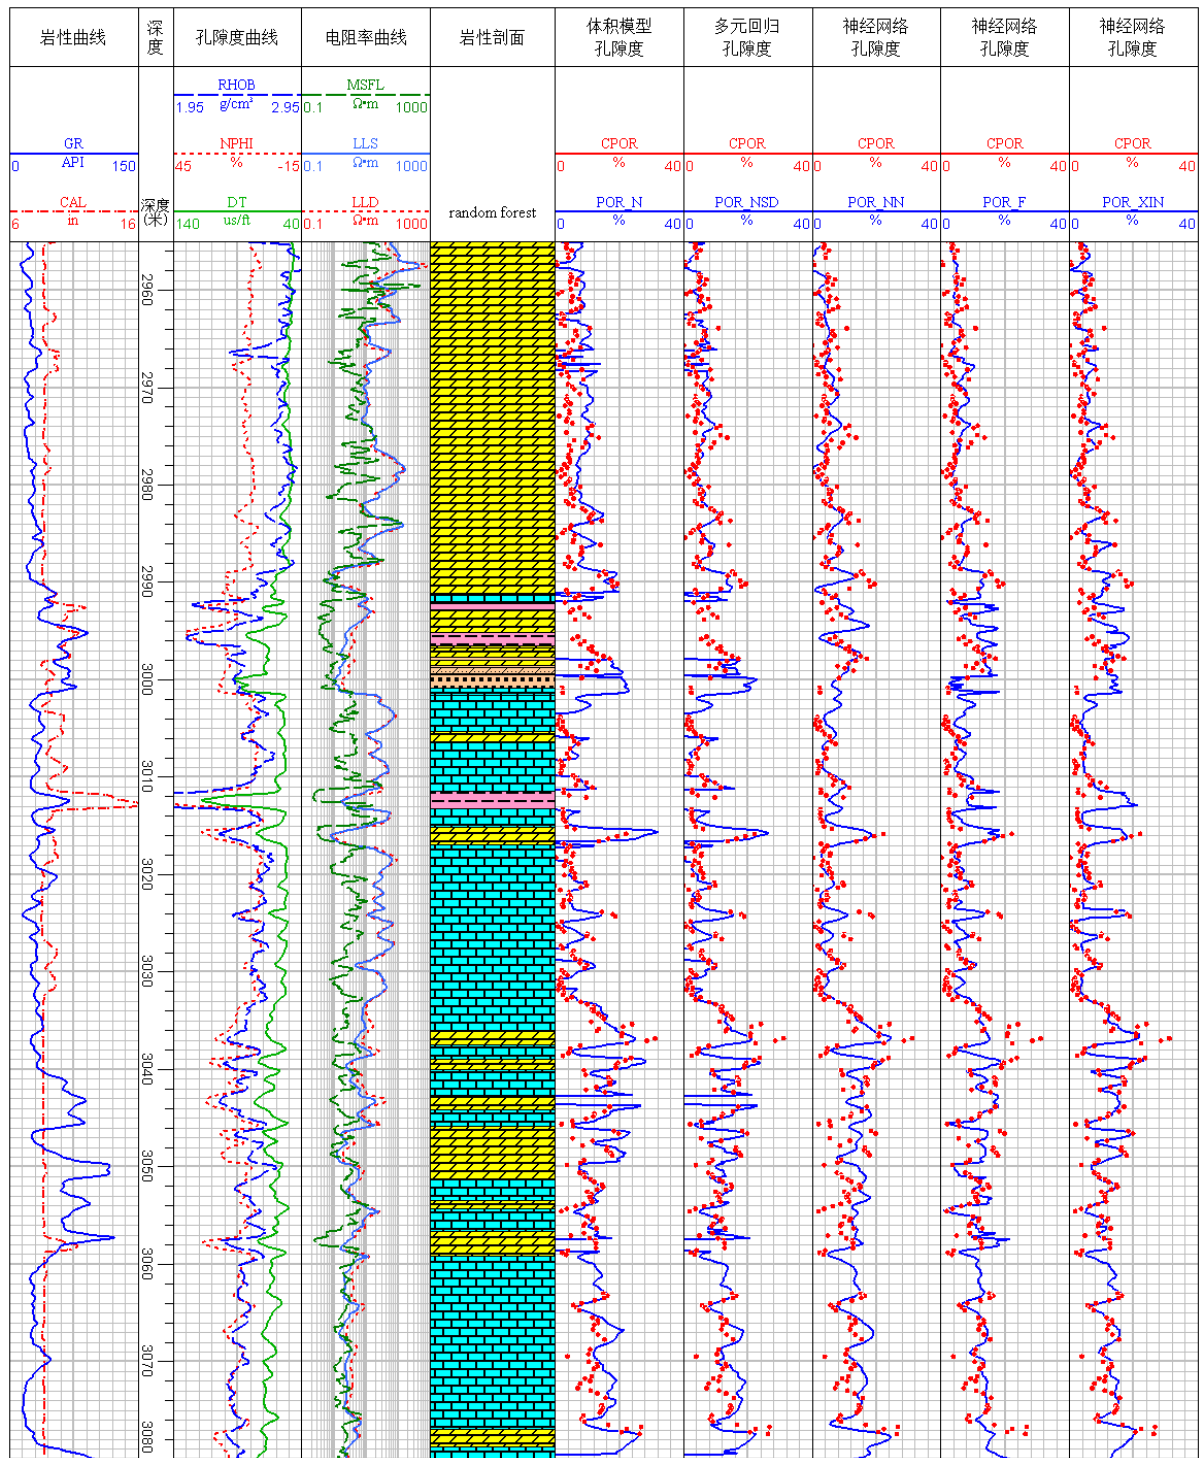


Figure 3. Comparison of different porosity prediction methods by Zhou Xueqing *et al.* (2017) [39]

图 3. 周雪晴等(2017)不同孔隙度预测方法对比[39]

李继安(2010)以十红滩铀矿床为例实验的神经网络在渗透率预测的应用[44], 李继安选择用测井资料向量组成训练模式对, 由多个训练模式对组成学习样本集, 建立对应实际地层情况的测井信息, 形成输入样本, 并以此对其他钻孔进行渗透率的预测。在建立渗透率预测的神经网络模型时, 李继安等人采用

了三层网络模型，理论已证明：“一个三层网络能以任何精度近似任何连续函数” [45]。起构造的神经网络结构如图 4 所示。最终预测结果见表 3。绝对误差小于 0.2 的为合格结果，总体合格率为 58.30%，效果较好。




Figure 4. The permeability prediction neural network constructed by Li Ji'an (2010) [45]
 图 4. 李继安(2010)构造的渗透率预测神经网络[45]

Table 3. Comparison of predicted permeability and measured permeability in Shihongtan area by Li Ji'an (2010) [45]
 表 3. 李继安(2010)十红滩地区预测渗透率与实测渗透率对比表[45]

序号	实测渗透率 (m/d)	预测渗透率 (m/d)	绝对误差	结果	序号	实测渗透率 (m/d)	预测渗透率 (m/d)	绝对误差	结果
1	0.0067	0.0079	0.181	合格	7	0.0168	0.0206	0.225	不合格
2	0.0082	0.0089	0.091	合格	8	0.1005	0.0837	-0.167	合格
3	0.0095	0.0148	0.554	不合格	9	0.2110	0.1545	-0.268	不合格
4	0.0114	0.0096	-0.154	合格	10	0.3016	0.3954	0.311	不合格
5	0.0088	0.0067	-0.234	不合格	11	0.3865	0.3231	-0.164	合格
6	0.0083	0.0099	0.188	合格	12	0.2764	0.3032	0.097	合格

3.4. 机器学习 AdaBoost.M2 算法在砂砾岩流体识别中的应用[46]

流体识别是测井评价的重要环节。在某些储层情况下，流体很难准确识别，如图 5 所示，该地区利用密度与电阻率难以识别流体。因而，选取反映储层岩性、物性、流体性质的 SP、GR (伽马)、RT、AC (声波时差)、CNL、(补偿中子)、DEN (密度)等六种测井资料，运用机器学习算法，提取反映流体的信息，多参数结合实现砂砾岩中的流体识别。

首先在关键井中，根据核磁共振、录井油气显示、试油等结果选取多个井段的储层样本，综合考虑岩性、孔隙结构、地层水矿化度等因素选取上述六种测井资料作为输入，建立研究区干层、水层、油水同层、油层识别模型。

建模前，对输入参数做归-化处理消除量纲的影响。图 6 为不同流体类型测井数据归-化后的平行坐标系，从左到右分别为 DEN、CNL、GR、AC、SP、RT 测井类型。每一个样本为一条曲线，不同颜色的曲线代表不同类型的流体。从图中可以看出，不同类型流体测井响应特征不同，同一种流体各测井响应特征也不完全一致。因此，采用单一测井曲线无法对复杂储层流体类型进行划分，需要多个测井参数进行学习分类获得学习模型，识别油水层。




Figure 5. Resistivity-density crossplot of the study area

图 5. 研究区电阻率 - 密度交会图

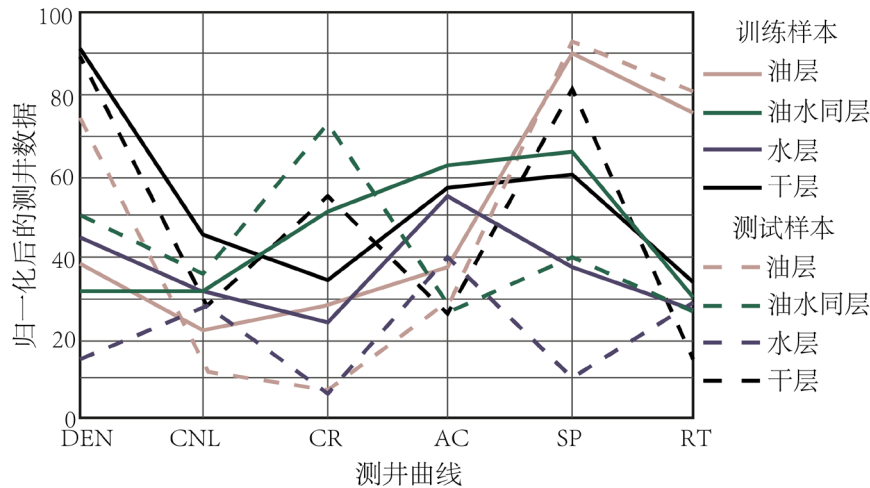


Figure 6. Parameter parallel coordinate system after normalization

图 6. 归一化后的参数平行坐标系

3.5. 机器学习在重建三维多孔介质建模中的应用[47]

岩石物理是测井评价的基础。数字岩心作为一种新的手段,可以弥补常规岩石物理实验的不足。Lukas Mosser 等开发了利用一类无监督机器学习方法生成对抗网络(GAN)进行三维数字岩心建模的方法。生成对抗网络由两个可区分的函数组成:鉴别器 D 和生成器 G。鉴别器 D 接收“真实”数据集的样本数据和生成器 G 从隐藏的潜在空间 Z 中创建的“伪”样本 $G(z)$ (潜在空间 Z 由独立的实际随机变量组成,通常是正态或均匀分布的,表示发生器 G 的随机输入)。然后生成器 G 将潜在空间 Z 中的随机变量映射到空间中生成图像。GAN 的训练流程如图 7 所示。

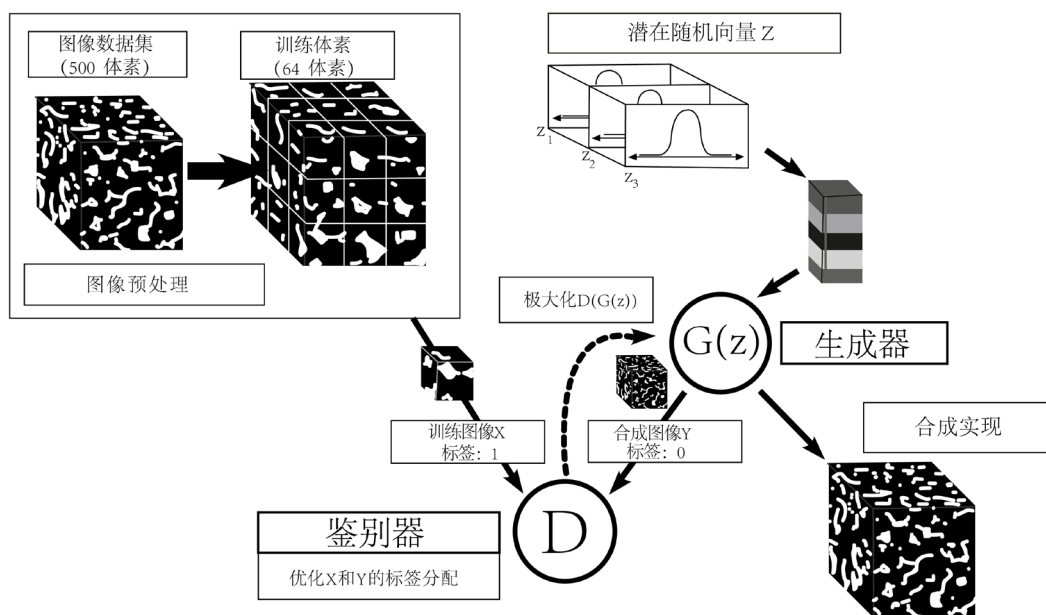


Figure 7. GAN training process
图 7. 生成对抗网络(GAN)训练流程

4. 结论与展望

在测井解释中，机器学习覆盖范围极广。调研发现深度学习技术运用在岩性识别、孔隙度渗透率预测中，不仅极大地提高了工作的效率，而且识别的准确率也相当高。现有的机器学习应用直观的体现了机器学习技术在测井中的发展。随着计算机人工智能等快速发展，机器学习在大量数据预测，数据处理过程中具有显著优势，并且在很大程度上也会带动测井仪器朝着高精度高维度高分辨率方向发展。

近年来，机器学习在图像分类方面前景广阔，况且电成像技术在测井剖面解释中直观的展现了地下地质情况，因此将机器学习应用到电成像裂缝识别中意义重大。深度信念网络(机器学习中的一种)也可以引入煤田测井数据处理中。相信在不远的将来，机器学习会在更多的地球物理勘探手段中实现更深入的应用。

基金项目

长江大学大学生创新创业训练计划项目(2018038)，国家自然科学基金项目(41504094)。

参考文献

- [1] 余凯, 贾磊, 陈雨强, 徐伟. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799-1804.
- [2] Hinton, G.E., Osindero, S. and Te, Y. (2006) A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, **18**, 1527-1554. <https://doi.org/10.1162/neco.2006.18.7.1527>
- [3] 童凯军, 单钰铭, 王道串, 等. 基于毛管压力曲线的储层渗透率估算模型——以塔里木盆地上泥盆统某砂岩组为例[J]. 石油与天然气地质, 2008, 29(6): 812-818.
- [4] 尉中良, 邹长春. 地球物理测井[M]. 北京: 地质出版社, 2005.
- [5] 李娜, 李新胜, 许登才, 等. 灰色系统理论在国外油田储层精细评价中的应用[J]. 西北地质, 2007, 40(4): 75-80.
- [6] 李政宏, 刘永福, 张立强, 赵海涛, 陈曦, 李昊东. 数据挖掘方法在测井岩性识别中的应用[J]. 断块油气田, 2019, 26(6): 713-718.
- [7] Rumelhart, D.E., Hinton, G.E. and Williams, R.J. (2007) Learning Representations by Back-Propagating Errors. In:

- Neurocomputing: Foundations of Research*, MIT Press, Cambridge, 533-536. <https://doi.org/10.1038/323533a0>
- [8] Hinton, G.E. and Salakhutdinov, R.R. (2006) Reducing the Dimensionality of Data with Neural Networks. *Science*, **313**, 504-507. <https://doi.org/10.1126/science.1127647>
- [9] Lecun, Y., Boser, B., Denker, J.S., et al. (2014) Back Propagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, **1**, 541-551. <https://doi.org/10.1162/neco.1989.1.4.541>
- [10] Dahl, G.E., Yu, D., Deng, L., et al. (2012) Context-Dependent Pre-Trained Deep Neural Networks for Large-Vocabulary Speech Recognition. *IEEE Transactions on Audio Speech & Language Processing*, **20**, 30-42. <https://doi.org/10.1109/TASL.2011.2134090>
- [11] 范宜仁, 黄隆基. 交会图技术在火山岩岩性与裂缝识别中的应用[J]. 测井技术, 1999, 23(1): 53-56.
- [12] 陶宏根, 曾日辉, 赵小青, 等. 海拉尔盆地火山碎屑岩测井响应与应用[J]. 地球物理学报, 2011, 54(2): 534-544.
- [13] 田玉昆, 周辉, 袁三一. 基于马尔科夫随机场的岩性识别方法[J]. 地球物理学报, 2013, 56(4): 1360-1368.
- [14] 杨礼节. 成测井技术研究现状及应用[J]. 中国石油和化工标准与质量, 2016, 36(12): 113-114.
- [15] Lin, Y.P., Wu, T.Z., Sheng, X.F., et al. (2013) Artificial Neural Networks Identification of Lithology-Types in Complex Carbonate from Well Logs, Block K, in Uzbekistan. *Advanced Materials Research*, **756-759**, 2396-2400. <https://doi.org/10.4028/www.scientific.net/AMR.756-759.2396>
- [16] Wang, K. and Zhang, L. (2008) Predicting Formation Lithology from Log Data by Using a Neural Network. *Petroleum Science*, **5**, 242-246. <https://doi.org/10.1007/s12182-008-0038-9>
- [17] Wen, H., Xie, W., Pei, J., et al. (2016) An Incremental Learning Algorithm for the Hybrid RBF-BP Network Classifier. *EURASIP Journal on Advances in Signal Processing*, **2016**, 57. <https://doi.org/10.1186/s13634-016-0357-8>
- [18] 石广仁. 地学数据挖掘与知识发现[M]. 北京: 石油工业出版社, 2012: 87-91.
- [19] 李洪奇, 谭锋奇, 许长福, 等. 基于决策树方法的砾岩油藏岩性识别[J]. 测井技术, 2010, 34(1): 16-21.
- [20] Al-Anazi, A. and Gates, I.D. (2010) A Support Vector Machine Algorithm to Classify Lithofacies and Model Permeability in Heterogeneous Reservoirs. *Engineering Geology*, **114**, 267-277. <https://doi.org/10.1016/j.enggeo.2010.05.005>
- [21] Elangovan, M., Sugumaran, V., Ramachandran, K.I., et al. (2011) Effect of SVM Kernel Functions on Classification of Vibration Signals of a Single Point Cutting Tool. *Expert Systems with Application*, **38**, 15202-15207. <https://doi.org/10.1016/j.eswa.2011.05.081>
- [22] 牟丹, 王祝文, 黄玉龙, 等. 基于最小二乘支持向量机测井识别火山岩类型: 以辽河盆地中基性火山岩为例[J]. 吉林大学学报(地球科学版), 2015, 45(2): 639-648.
- [23] 朱怡翔, 石广仁. 火山岩岩性的支持向量机识别[J]. 石油学报, 2013, 34(2): 312-322.
- [24] 侯俊胜, 王颖. 神经网络方法在煤气层测井资料解释中的应用[J]. 地质与勘探, 1999, 35(3): 41-45.
- [25] 卢新卫, 金章东. 前馈神经网络的岩性识别方法[J]. 石油与天然气地质, 1999, 1(20): 82-85.
- [26] 范训礼, 戴航, 张新家, 等. 神经网络在岩性识别中的应用[J]. 测井技术, 1999, 23(1): 50-52.
- [27] 蔡磊, 程国建, 潘华贤. 极限学习机在岩性识别中的应用[J]. 计算机工程与设计, 2010, 31(9): 2010-2012.
- [28] 安鹏, 曹丹平. 基于深度学习的测井岩性识别方法研究与应用[J]. 地球物理学进展, 2018, 124(9): 3-98.
- [29] 刘畅, 张琴, 庞国印, 等. 致密砂岩储层孔隙度定量预测——以鄂尔多斯盆地姬塬地区长 8 油层组为例[J]. 岩性油气藏, 2013, 23(5): 70-75.
- [30] 王洪辉, 黎鹏, 段新国. 四川盆地须家河组低孔致密砂岩孔隙度测井解释研究[J]. 成都理工大学学报(自然科学版), 2009, 36(3): 249-252.
- [31] 谭茂金, 赵文杰. 用核磁共振测井资料评价碳酸盐岩等复杂岩性储集层[J]. 地球物理学进展, 2006, 21(2): 489-493.
- [32] 崔晓朵, 王伟, 曹刚, 等. 墨西哥 EPC 区碳酸盐岩储层裂缝特征和非均质性研究[J]. 海洋地质前沿, 2011, 27(1): 38-41.
- [33] 赵军龙, 巩泽文, 李甘, 等. 碳酸盐岩裂缝性储层测井识别及评价技术综述与展望[J]. 地球物理学进展, 2012, 27(2): 537-547.
- [34] 李晓辉, 周彦峰, 缙艳红, 等. 电成像测井孔隙度分析技术及其在碳酸盐岩储层产能预测中的应用[J]. 吉林大学学报(地球科学版), 2012, 42(4): 928-934.
- [35] 连承波, 李汉林, 渠芳, 等. 基于测井资料的 BP 神经网络模型在孔隙度定量预测中的应用[J]. 天然气地球科学, 2006, 17(3): 382-384.

- [36] 陈蓉, 王峰. 基于 MATLAB 的 BP 神经网络在储层物性预测中的应用[J]. 测井技术, 2009, 33(1): 75-78.
- [37] 李操, 王继春. 神经网络方法在储层孔隙度预测中的应用[J]. 内蒙古石油化工, 2007(12): 372-373 + 376.
- [38] 王娜娜, 张国英, 王明君. 改进的 BP 神经网络在石油测井解释中的应用[J]. 北京石油化工学院学报, 2008, 16(1): 17-20.
- [39] 周雪晴, 张占松, 张超谟, 等. 粗糙集-磷虾觅食神经网络在孔隙度预测中的应用[J]. 中国科技论文, 2017, 12(9): 990-998.
- [40] 贾文玉, 闫安宇, 田素月. 渗透率的理论计算方法[J]. 测井技术, 2000, 24(3): 216-219.
- [41] 刘向君, 夏泉, 赵正文. 砂泥岩地层渗透率预测通用计算模型[J]. 西南石油学院学报, 1999, 21(1): 10-12.
- [42] 王科俊, 王克成. 神经网络建模、预报与控制[M]. 哈尔滨: 工业大学出版社, 1996: 1-8.
- [43] 丛爽. 面向 MATLAB 工具箱的神经网络理论与应用[M]. 北京: 中国科学技术大学出版社, 1998: 11.
- [44] 李继安. 人工智能神经网络在岩性识别、孔隙度和渗透率预测中的应用——以十红滩铀矿床为例[J]. 西北地质, 2010, 43(2): 32-37.
- [45] 黄德双. 基于 PCA 的概率神经网络模式分类方法[J]. 北京理工大学学报, 1996(1): 69-74.
- [46] 陈钢花, 梁莎莎, 等. 机器学习 AdaBoost. M2 算法在砂砾岩流体识别中的应用[J]. 石油地球物理勘探, 2019, 54(6): 1357-1362 + 1177.
- [47] Mosser, L., Dubrule, O. and Blunt, M.J. (2008) Reconstruction of Three-Dimensional Porous Media Using Generative Adversarial Neural Networks. *Physical Review E*, **96**, Article ID: 043309.
<https://doi.org/10.1103/PhysRevE.96.043309>