

# 卷积神经网络在储层预测中的应用研究

段友祥, 李根田, 孙歧峰

(中国石油大学(华东)计算机与通信工程学院, 山东 青岛 266580)

**摘 要:** 神经网络作为人工智能的分支, 在模式识别、分类预测等方面已成功地解决了许多现代计算机难以解决的实际问题。然而随着人工智能的发展, 神经网络的自主性特征学习功能越来越重要, 神经网络虽然表现出了良好的智能特性, 但不能自主地学习特征。近年来, 深度学习逐渐崛起, 围绕深度神经网络的研究也越来越多, 但其在地质储层参数预测领域的研究还很少。提出了一种应用卷积神经网络对地质储层参数进行预测的方法, 该方法不仅能对储层参数进行精确预测, 而且可以得到储层特征集。实验证明, 卷积神经网络可以应用于地质储层参数预测, 且预测精度较高, 同时卷积神经网络的卷积特征为储层地质建模与测井资料解释提供了重要的支持。

**关键词:** 神经网络; 深度学习; 卷积神经网络; 储层预测; 储层特征

中图分类号: TP391

文献标识码: A

## Research on convolutional neural network for reservoir parameter prediction

DUAN You-xiang, LI Gen-tian, SUN Qi-feng

(College of Computer and Communication Engineering, China University of Petroleum (East China), Qingdao 266580, China)

**Abstract:** As the branch of artificial intelligence, artificial neural network solved many difficult practical problems in pattern recognition and classification prediction field successfully. However, they cannot learn the feature from networks. In recent years, deep learning becomes more and more advanced, but the research on the field of geological reservoir parameter prediction is still rare. A method to predict reservoir parameters by convolutional neural network was presented, which can not only predict reservoir parameters accurately, but also get features of the geological reservoir. The study established the convolutional neural network model. Results show that the convolutional neural network can be used for reservoir parameter prediction, and get high prediction precision. Moreover, convolutional features from convolutional neural network provided important support for geological modeling and logging interpretation.

**Key words:** artificial neural network, deep learning, convolutional neural network, reservoir prediction, reservoir feature

### 1 引言

地质储层参数(孔渗饱等参数)在地质建模中起着至关重要的作用, 储层参数往往是通过井资料来获得。然而在很多情况下, 钻井取心仅限于某些层段, 不能获取整个工区内的储层参数。因此, 地质学家通常通过建立经验公式的方法来预测未知地区的储层参数。常规的通过经验公式或简化地质条件建立模型计算储层参数, 对于解决一般地质储

层问题往往能取得较好的结果, 而对于解决复杂地质问题, 二者都有很大的局限和缺陷。人工智能特别是神经网络技术的发展为地质储层参数预测带来了新的途径。

无论国内还是国外, 很多学者在这个方面进行了深入研究, 提出了一些神经网络方法进行储层参数预测。陈蓉等<sup>[1]</sup>利用 BP 神经网络进行了储层的孔隙度和渗透率预测, 并在 Matlab 平台上实现。Hamidi 等<sup>[2]</sup>同样利用 BP 神经网络预测了油气

收稿日期: 2016-09-01

通信作者: 李根田, ligentian@163.com

基金项目: 国家科技重大专项基金资助项目(No.211ZX05006)

**Foundation Item:** The National Science and Technology Major Project(No.211ZX05006)

藏的孔隙度，实际效果显著。李映涛等<sup>[3]</sup>利用 BP 神经网络进行了储层的孔隙度预测，并进行了实际应用。董兴朋<sup>[4]</sup>将遗传算法与 BP 算法结合，并进行了储层的孔隙度和渗透率预测，该方法优化了神经网络结构，避免了 BP 算法陷入局部极小值的缺点。潘少伟等<sup>[5]</sup>利用改进的 PSO-BP 神经网络对储层参数动态预测，提高 BP 神经网络的收敛速度和泛化能力。近年，径向基网络和支持向量回归方法在储层预测中的应用也越来越广泛。Baneshi 等<sup>[6]</sup>采用优化传播 RBF 网络建立储层的孔隙度预测模型，并达到了预期的效果。Wu 等<sup>[7]</sup>提出了一种基于可训练的径向基函数的 RBF 网络，并进行了储层的敏感性预测，其预测精度高于运用简单的径向基函数的 RBF 网络。Na'imi 等<sup>[8]</sup>利用地震数据和支持向量回归的方法进行了储层孔隙度和含水饱和度的预测。同时 Al-Anazi<sup>[9,10]</sup>和 Mollajan 等<sup>[11]</sup>提出了一些高效的支持向量回归的储层预测方法。

人工神经网络虽然表现出了良好的智能特性，但是它不能自主地学习特征。近年来，随着深度学习的发展，具有自主性特征学习功能的深度神经网络越来越受到关注。卷积神经网络深度学习方法在图像识别<sup>[12]</sup>和声音分析<sup>[13]</sup>等领域取得了一些成果，然而在储层预测领域的应用研究很少。本文提出了应用卷积神经网络模型对地质储层参数进行预测的方法，并通过实验进行了验证。

## 2 卷积神经网络原理

卷积神经网络<sup>[14]</sup>(CNN, convolutional neural network)是近年发展起来，并引起广泛重视的一种高效模式识别方法，已经成为众多科学领域的研究热点之一，特别是在语音分析和图像识别领域。由于该网络避免了复杂前期预处理，可以直接输入原始信息，同时它的权值共享网络结构更类似于生物神经网络，大大降低了网络模型的复杂度，因而得到了更为广泛的应用。

卷积神经网络的基本结构包括 2 种特殊的神经元层<sup>[12]</sup>，其一为卷积层，每个神经元的输入与前一层的局部相连，并提取该局部的特征；其二是池化层，用来求局部敏感性与二次特征提取的计算层。卷积神经网络结构如图 1 所示，整个网络由输入层、一对或多对交替相连的卷积层和池化层、全连接层以及输出层组成。以图像识别为例，卷积神经网络过程：输入层通过 3 个卷积核进行卷积得到卷积层  $C_1$ ，卷积后产生 3 个特征图，然后每个特征图中每 4 个像素再进行池化，得到 3 个池化层  $S_1$ 。同样， $S_1$  层再经过特定组合的 9 个多层卷积核进行卷积得到 9 个  $C_2$  层，经过池化生成 9 个  $S_2$  层。最终，这些像素值被光栅化，连接成一个向量输入到传统的神经网络，即通过一个全连接层得到输出。在卷积层和池化层中有若干个特征图，每个特征图都与其前一层特征图相连接。卷积神经网络的主要优点有：

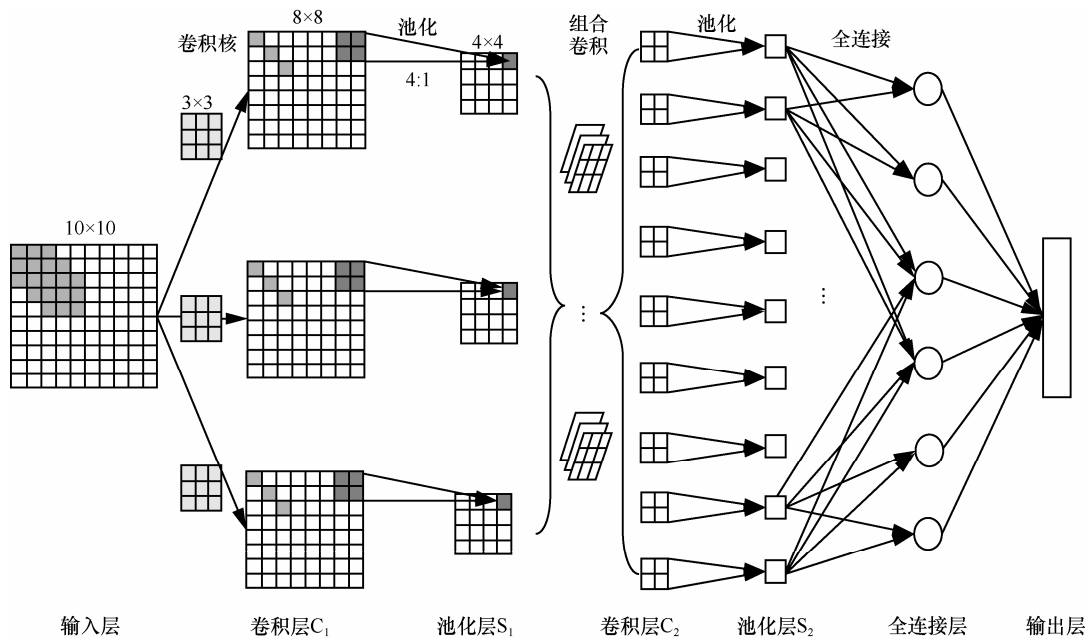


图 1 卷积神经网络结构

1) 卷积层通过训练数据进行特征学习,所以在卷积神经网络中,避免了显式地特征抽取,而是隐式地从训练数据中进行特征学习;2) 每一个卷积层都紧跟着一个二次提取的池化层,这种特有的 2 次特征提取结构减小了特征分辨率,减少了需要优化的参数数目;3) 同一层面上的神经元权值相同,减少了网络自由参数的个数,降低了网络规模。

### 2.1 卷积与池化

卷积是一种重要的数学运算。一般的认知是从局部到全局的,局部的统计特性与其他部分是存在关系的<sup>[15]</sup>,所以这种统计特征可以用卷积的形式表示。卷积层,又叫特征提取层,它是由前一层的特征图与一个可学习的核进行卷积后,加偏置再经过激活函数得到的输出结果组成。因此该层的每个神经元输入与前一层的局部感受也相连,通过卷积核提取该局部的特征,一旦该局部特征被提取后,它与其他特征间的位置关系也随之确定下来。卷积与池化过程如图 2 所示,前一层的特征图经过卷积后形成卷积层的特征图  $j$ ,且卷积层的每个特征图  $j$  可能与前一层多个特征图连接,卷积计算如式(1)所示。

$$x_j^{(l)} = \sum_{i \in N_j} a_i^{(l-1)} k_{ij}^{(l)} + b_c^{(l)} \quad (1)$$

$$a_j^{(l)} = f(x_j^{(l)})$$

其中,  $l$  表示层数,  $k$  为卷积核,每个特征图可与前一层多个特征图连接,  $N_j$  表示输入特征图的一个选择集合,可以选择所有的输入特征或者选择特定组合的输入特征,  $b_c$  表示附加偏置。

池化是为了对不同位置的特征进行统计一种方法,这种方法可以通过采样的方式对卷积层进行更低分辨率的统计表示<sup>[12]</sup>。常用的方法有平均池化 (mean-pooling)、最大池化 (max-pooling)、最小池化 (min-pooling) 和随机池化 (random-pooling)。池化层,又叫采样层或特征映射层,该层是由卷积层经过池化加偏置再经过激活函数得到的,如图 2 所示。这种池化的方法对卷积的特征图进行了二次采样,大大减小了特征分辨率,降低了网络规模。

卷积层的特征图经过池化得到池化层的特征图  $j$ ,池化特征图与卷积特征图为同一层面,且池化参数共享,池化计算如式(2)。

$$x_j^{(l)} = w_j^{(l)} \text{pooling}(a_j^{(l-1)}) + b_s^{(l)} \quad (2)$$

$$a_j^{(l)} = f(x_j^{(l)})$$

其中,  $l$  表示层数, pooling 为池化操作,  $w$  为池化权值,  $b_s$  表示附加偏置。

### 2.2 反向传播

对于 BP 来说,要想求得  $l$  层的每个神经元对应的权值更新,就需要先求  $l$  层的每一个神经节点的误差灵敏度  $\delta$ 。每一个卷积层  $l$ ,后面可以跟一个池化层  $l+1$ ,也可以跟一个全连接层。如果是全连接层,误差灵敏度可由 BP 算法得到;如果是池化层,灵敏度计算如式(3)。

$$\delta_j^{(l)} = \frac{\partial J}{\partial x_j^{(l)}} = w_j^{(l+1)} (f'(x_j^{(l)}) \circ \text{unp}(\delta_j^{(l+1)})) \quad (3)$$

其中,  $l$  表示层数,  $w$  为池化层的权值,  $f'$  为池化层激活函数导数, unp 为反池化操作,对于不同的池化方法,其计算方法对应不同。

得到卷积层的误差灵敏度后,用以更新卷积核  $k$  和偏置  $b_c$ ,因此更新参数的卷积核梯度和偏置梯度如式(4)。

$$\frac{\partial J}{\partial k_{ij}^{(l)}} = \sum_{M,N} \delta_j^{(l)} p_i^{(l-1)} \quad (4)$$

$$\frac{\partial J}{\partial b_c^{(l)}} = \sum_{M,N} \delta_j^{(l)}$$

其中,  $\delta_j^{(l)}$  表示卷积层的误差灵敏度,  $p_i^{(l-1)}$  是  $a_i^{(l-1)}$  在卷积的时候与卷积核  $k_{ij}^{(l)}$  逐个元素相乘的像素值,  $M, N$  代表像素的位置信息。

同样,每一个池化层  $l$ ,后面可以跟一个卷积层  $l+1$ ,也可以跟一个全连接层。如果是全连接层,误差灵敏度可由 BP 算法得到;如果是卷积层,则池化层的误差灵敏度计算如式(5)。

$$\delta_j^{(l)} = \frac{\partial J}{\partial x_j^{(l)}} = \text{conv}(\delta_j^{(l+1)}, k_j^{(l+1)}) \circ f'(x_j^{(l)}) \quad (5)$$

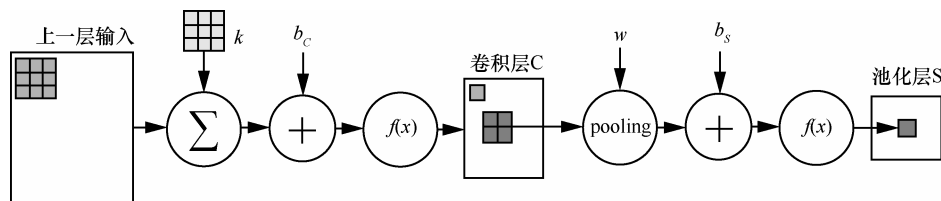


图 2 卷积与池化过程

其中,  $l$  表示层数,  $k$  为卷积核参数,  $f'$  为卷积层激活函数导数, conv 表示反卷积操作。

通过得到的误差灵敏度用作更新池化层权值  $w$  和偏置  $b_s$ , 因此池化层  $l$  对应的权值梯度和偏置梯度如式(6)。

$$\frac{\partial J}{\partial w_j^{(l)}} = \sum_{M,N} \delta_j^{(l)} pooling_i^{(l-1)} \quad (6)$$

$$\frac{\partial J}{\partial b_s^{(l)}} = \sum_{M,N} \delta_j^{(l)}$$

其中,  $\delta_j^{(l)}$  表示池化层的误差灵敏度,  $pooling_i^{(l-1)}$  是  $a_i^{l-1}$  在池化时的像素值,  $M, N$  代表像素的位置信息。

### 3 储层预测深度学习模型与仿真实现

#### 3.1 卷积模型的建立

地质储层参数预测问题与大多数的分类预测问题类似, 本质都是通过监督学习的方法训练模型来预测未知数据。然而, 地质储层参数区别于一般的图像文字等数据, 其储层特征不容易用深度学习的方法表达。本文将输入输出数据模拟成像素点, 利用卷积神经网络良好的特征学习能力自主训练储层特征, 并分析比较了池化过程在地质储层参数预测中的作用, 发现池化对于目标识别领域的图像检测、声音识别等具有某种程度的平移不变特征, 而在地质储层参数预测中基本不存在此类特征。同时由于输入参数较少, 池化所起的减小特征分辨率的优点也相对影响较小。基于此设计了 2 种卷积神经网络模型, 一种是单层卷积神经网络模型, 一种是双层卷积神经网络模型。

单层卷积神经网络模型包含 3 层, 分别为像素输入层、卷积特征层和传统神经网络输出层, 如图 3

所示。输入层为声波、密度、中子和自然伽马 4 种测井参数组成的  $2 \times 2$  像素点。卷积特征层中设置 4 个  $2 \times 2$  参数的卷积核  $k$  以及偏置  $b$ , 激活函数选择 Sigmoid 函数。卷积作用是为了提取 4 种输入参数分别对最终输出孔隙度影响度的特征, 并通过 4 个卷积核来表现。传统输出层将特征层的 4 个特征作为输入, 设置权值和偏置, 最终得到一个输出。

双层卷积神经网络模型包含 4 层, 分别为像素输入层、2 对卷积特征层和传统输出层, 如图 4 所示。输入层设置成  $4 \times 4$  的像素点, 将声波、密度、中子和自然伽马 4 种测井参数随机分配到  $4 \times 4$  的像素内。第一层卷积设置 4 个  $3 \times 3$  参数的卷积核以及偏置, 第二层卷积设置 6 个  $4 \times 2 \times 2$  参数的卷积核及偏置, 激活函数都选择 sigmoid 函数。第一层卷积的作用是为了提取 4 种随机参数分别与孔隙度关系的特征, 并通过 4 个卷积核来表现。第二层卷积的作用是为了提取 4 种输入特征之间的组合特征, 并通过 6 个组合卷积核来实现。传统输出层中将组合特征作为输入, 设置权值和偏置, 最终得到一个输出。

#### 3.2 仿真实现

实验选择了 Matlab 平台进行仿真实现, 并选择了与孔隙度 (NPHI) 相关的声波 (DT)、密度 (ZDEN)、中子 (CNCF) 和自然伽马 (GR) 四种测井数据, 经过主成分分析发现声波、密度、中子和自然伽马与孔隙度不具有相关性。因此网络模型的输入参数为声波、密度、中子和自然伽马, 输出参数为孔隙度。

实验首先用带标签的数据进行训练, 然后用训练得到的卷积模型进行参数预测。卷积网络参数初始化时, 偏置初始化为 0, 卷积核与权值初始化参

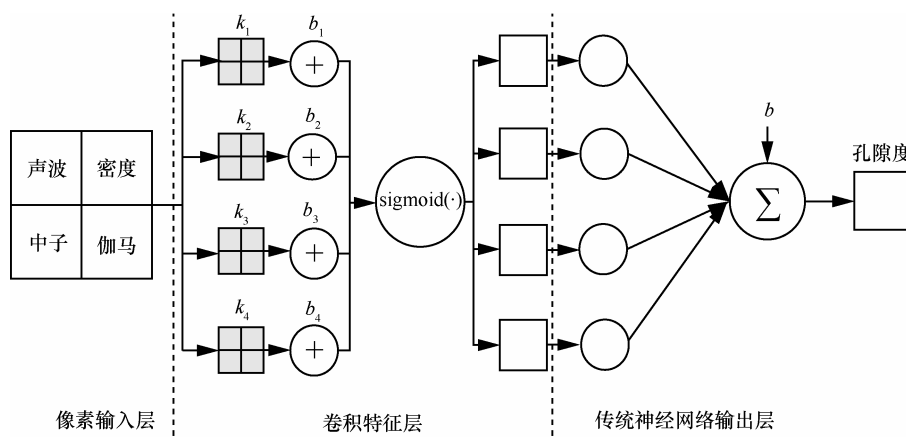


图 3 单层卷积神经网络结构

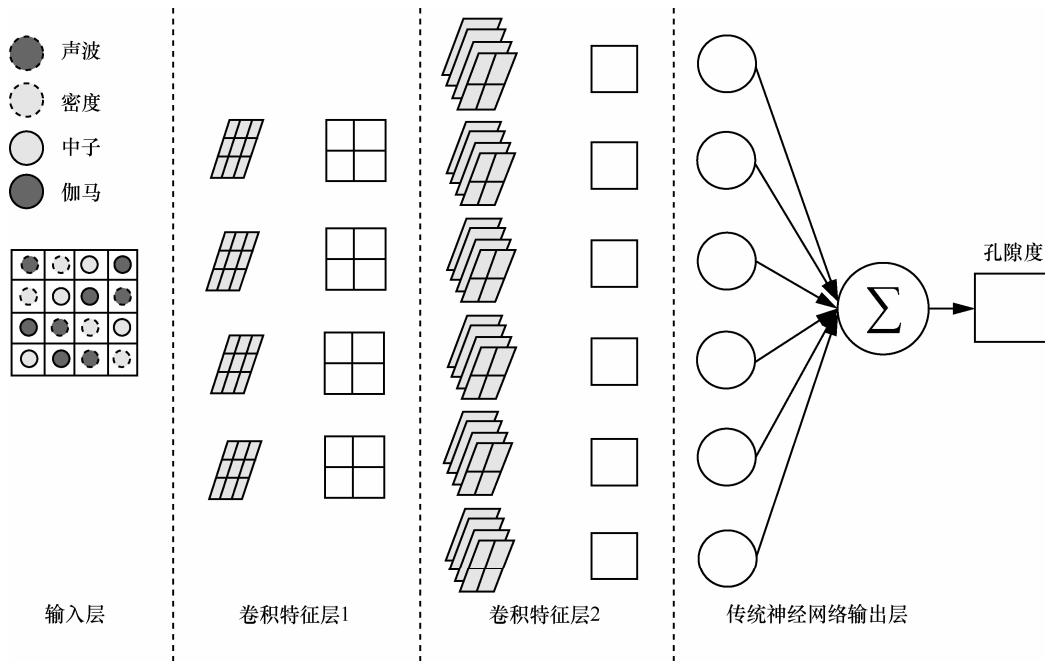


图 4 双层卷积神经网络结构

考 Glorot 与 Bengio 提出的方法<sup>[16]</sup>。初始化值如式(7)和式(8)。网络训练采用批量训练的方法，每 5 组样本进行一次训练，所有样本总共训练 100 次。

$$k_{ij} = rand(size(k) - 0.5) \times 2 \times \sqrt{\frac{6}{H_i + H_{i+1}}} \quad (7)$$

$$w = \frac{rand(-1,1)}{\sqrt{\frac{6}{H_i + H_{i+1}}}} \quad (8)$$

其中， $rand(\cdot)$  为随机函数， $size(\cdot)$  为卷积核大小的开平方， $H_i$  为输入神经元个数， $H_{i+1}$  为输出神经元个数。

#### 4 实验结果与分析

实验使用了某区块两口油井的测井数据，分别编号为 1 号井和 2 号井，用 2 种卷积神经网络模型做

了 4 组实验，实验数据的描述如表 1 所示。

前 2 组实验利用 2 种卷积神经网络模型分别预测同一口井的孔隙度参数。首先用 1 号井深度范围为 2 500~3 000 m 的 500 组数据训练网络，建立预测模型，然后再利用预测模型预测 1 号井深度范围 3 000~4 000 m 的孔隙度参数。图 5 和图 6 分别为单层卷积神经网络和双层卷积神经网络的预测值与实际值的比较结果。

后 2 组实验利用 2 种卷积神经网络模型分别预测邻井的孔隙度参数。首先用 1 号井深度范围为 2 500~3 500 m 的 1 000 组数据训练网络，建立预测模型，然后再利用预测模型预测 2 号井深度范围 2 500~3 500 m 的孔隙度参数。图 7 和图 8 分别为单层卷积神经网络和双层卷积神经网络的预测值与实际值的比较结果。

实际孔隙度与预测孔隙度比较结果采用均方差 ( $MSE$ ) 和相关系数 ( $R$ ) 来表示。比较数据见表 2。

表 1 实验数据描述

序号	训练数据	预测数据	网络模型	描述
1	1 号井, 500 组井深范围	1 号井, 1 000 组井深范围	单层卷积	2 种卷积神经网络模型预测同井数据
2	(2 500~3 000 m)	(3 000~4 000 m)	双层卷积	
3	1 号井, 1 000 组井深范围	2 号井, 1 000 组井深范围	单层卷积	2 种卷积神经网络模型预测邻井数据
4	(2 500~3 500 m)	(2 500~2 500 m)	双层卷积	

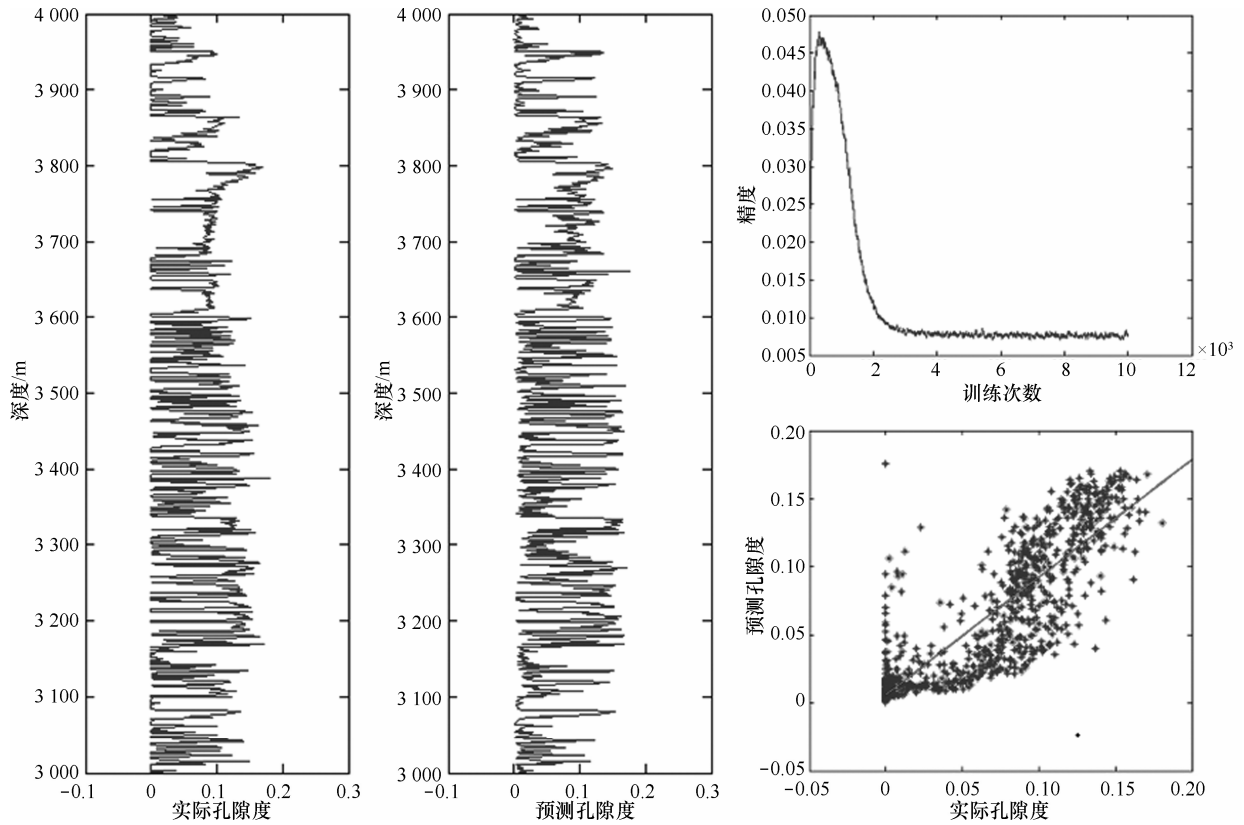


图 5 单层卷积神经网络预测同井数据

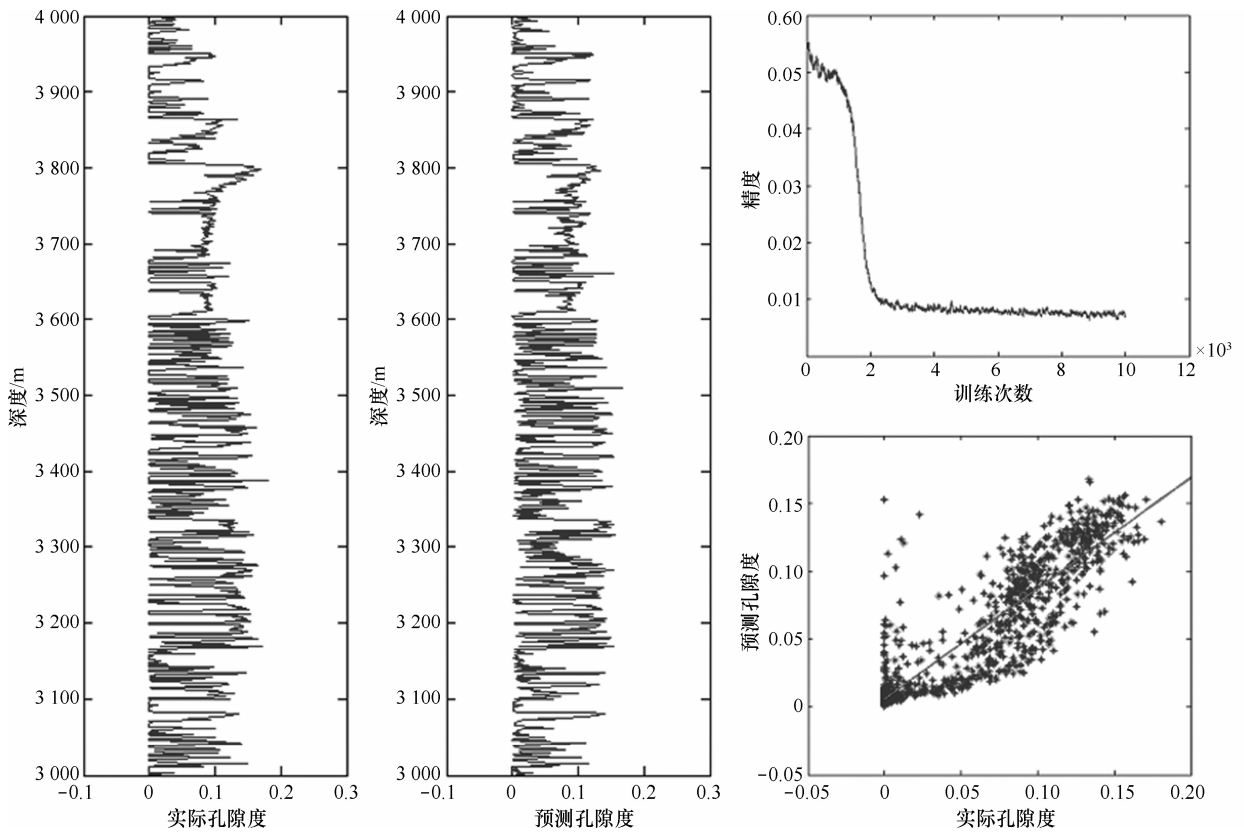


图 6 双层卷积神经网络预测同井数据

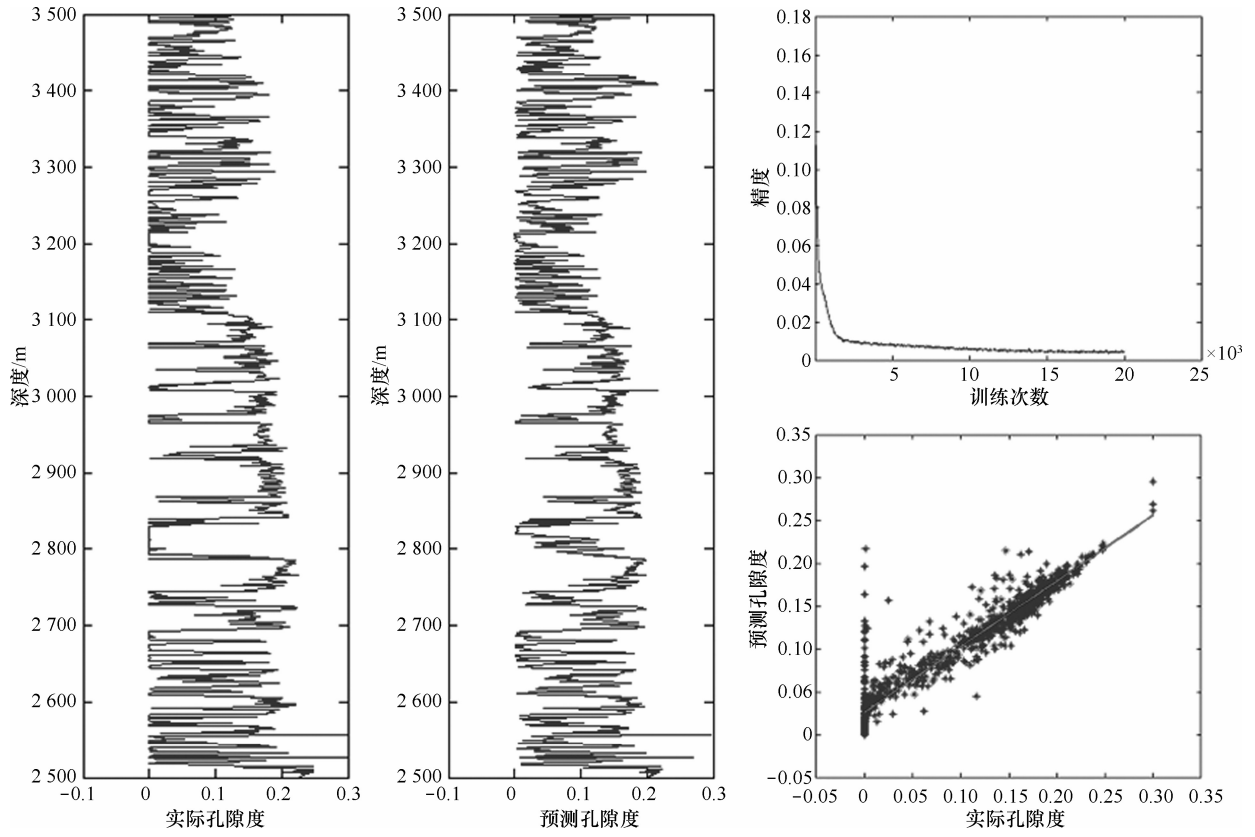


图7 单层卷积神经网络预测邻井数据

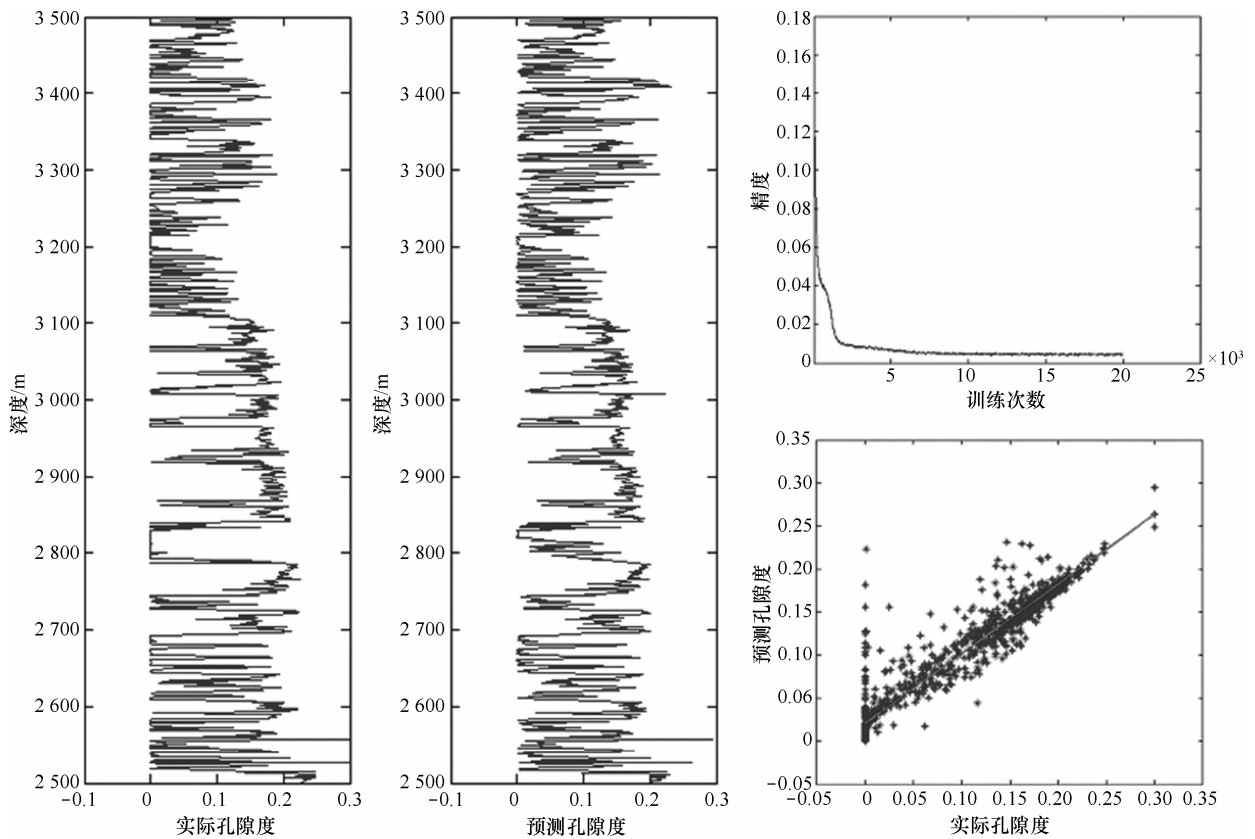


图8 双层卷积神经网络预测邻井数据

表 2 预测值与真实值均方差 (MSE) 和相关系数 (R)

序号	均方差(MSE)	相关系数(R)
1	0.000 721 08	0.870 0
2	0.000 604 38	0.890 7
3	0.000 794 26	0.946 0
4	0.000 761 23	0.942 8

通过数据分析与比较,用卷积神经网络预测地质储层参数能达到较高预测精度。从预测结果看,卷积神经网络在预测同井数据的不同深度段时的预测精度较低,而预测邻井数据的同一深度段时的预测精度

较高;同时,二次卷积的网络模型比一次卷积的网络模型预测精度稍高。造成预测同井数据不同深度段时的预测精度低的原因是随着深度的不同储层特征发生改变。图 9 和图 10 为用卷积神经网络预测邻井数据时的卷积特征,双层卷积神经网络较单层卷积神经网络训练获得的卷积特征更多,通过卷积核体现出的储层特征为储层地质建模与测井资料解释提供了重要的支持。实验表明,卷积神经网络不仅可以应用于地质储层参数预测,而且卷积神经网络预测模型可以自主地学习特征,避免了人工神经网络人为的特征提取,表现出了良好的智能特性。

$k_1$		$k_2$		$k_3$		$k_4$	
-0.552 9	-1.876 4	-0.315 2	-1.351 2	8.478 4	-1.772 9	0.057 4	-2.212 4
1.875 1	0.795 1	2.094 3	0.132 9	1.462 6	-0.190 9	2.621 9	0.665 3

图 9 单层卷积神经网络 4 个卷积核参数

$k_1^1$	-0.204 5	-0.161 7	1.187 5	$k_2^1$	-0.087 8	0.370 4	-1.163 6	
	-0.476 2	1.217 7	0.211 5		-1.282 5	0.076 6	2.755 4	
	1.415 2	-0.054 3	-0.724 9		2.979 7	-1.281 2	-0.284 3	
$k_3^1$	0.588 1	-0.571 2	-7.751 7	$k_4^1$	0.881 4	-0.515 1	-0.774 4	
	-0.112 1	0.566 9	-0.618 9		-1.005 9	0.709 9	-1.719 7	
	-1.289 7	-1.530 5	0.654 1		-2.476 0	-0.854 0	0.315 0	
$k_1^2$	0.731 0	0.655 2	2.141 0	0.185 8	-0.549 8	-0.400 7	-1.751 3	-0.354 8
	0.422 8	0.801 4	-1.748 4	0.990 2	-1.399 3	-0.072 8	-1.320 6	-0.912 1
$k_2^2$	-0.554 9	-1.324 4	-2.093 3	0.194 4	1.012 0	0.977 6	2.191 3	0.090 5
	-0.516 5	0.702 0	1.601 6	-0.861 9	1.983 9	1.016 5	1.612 0	0.960 2
$k_3^2$	-0.388 9	-0.052 7	-0.219 9	-0.112 3	-0.084 6	0.023 8	0.240 0	-0.172 1
	-0.105 1	-0.356 8	0.274 4	-0.239 8	0.030 1	0.123 5	0.298 4	0.394 7
$k_4^2$	0.004 9	-0.378 8	0.516 5	-0.776 2	0.716 8	0.204 2	-0.001 7	-0.046 2
	-0.024 1	-0.482 1	-0.823 7	0.265 1	-0.128 9	-0.019 4	0.395 0	-0.008 8
$k_5^2$	-0.194 4	-0.113 1	-0.520 1	0.192 2	-0.167 7	-0.415 0	0.198 5	-0.269 0
	-0.046 1	-0.215 9	0.236 8	-0.280 4	0.165 8	-0.016 8	0.007 3	0.245 5
$k_6^2$	0.555 8	-0.494 9	-0.233 8	-0.588 7	0.795 9	0.946 0	0.296 0	0.062 2
	-1.229 9	-1.142 1	-1.860 8	0.459 7	0.704 9	-0.066 7	0.852 7	-0.607 5

图 10 双层卷积神经网络 10 个卷积核参数

## 5 结束语

深度学习作为一种前沿的人工智能技术已经受到各个领域的关注, 围绕深度神经网络的研究也越来越多, 然而深度学习在储层预测中的应用研究很少。本文深入研究了神经网络的基本原理, 发现其特征学习能力能更好地解决地质储层参数预测本身的问题。同时, 借鉴卷积神经网络在图像识别和声音分析领域的应用技术, 将其应用于地质储层参数预测。本文提出了 2 种卷积神经网络模型, 单层卷积模型和双层卷积模型, 分别用于训练和预测储层孔隙度, 并用 Matlab 平台仿真实现。在卷积模型实现中将储层参数像素化, 以便更好地表达储层特征。实验证明, 卷积神经网络可用于地质储层参数预测问题, 且预测精度较高, 同时双层卷积神经网络不仅可以达到较好的预测效果, 而且通过卷积得到更多的卷积特征, 其为储层地质建模与测井资料解释提供了重要的支持。

### 参考文献:

- [1] 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.  
CHEN R, WANG F. Application of MATLAB-based of BP neural network in reservoir parameters prediction[J]. Well Logging Technology, 2009, 33(1): 75-78.
- [2] HAMIDI H, RAFATI R. Prediction of oil reservoir porosity based on BP-ANN[C]// Innovation Management and Technology Research (ICIMTR), 2012 International Conference. IEEE, 2012: 241-246.
- [3] 李映涛, 袁晓宇, 刘迪, 等. BP 神经网络在测井解释中的应用研究[J]. 西部探矿工程, 2013, 25(3): 45-48.  
LI Y T, YUAN X Y, LIU D, et al. Research on the application of BP neural network in wells log interpretation[J]. West-china Exploration Engineering, 2013.
- [4] 董兴朋. 相似度-遗传神经网络在储层物性预测中的应用[J]. 测井技术, 2012, 36(3): 267-271.  
DONG X P. Application of similarity-genetic neural network to reservoir parameters prediction[J]. Well Logging Technology, 2012.
- [5] 潘少伟, 梁鸿军, 李良, 等. 改进 PSO-BP 神经网络对储层参数的动态预测研究[J]. 计算机工程与应用, 2014, 50(10): 52-56.  
PAN S, LIANG H, LI L, et al. Dynamic prediction on reservoir parameter by improved PSO-BP neural network[J]. Computer Engineering & Applications, 2014, 50(10): 52-56.
- [6] BANESHI M, BEHZADIJO M, ROSTAMI M, et al. Using well logs to predict a multimin porosity model by optimized spread rbf networks[J]. Energy Sources, Part A: Recovery, Utilization, and Environmental Effects, 2015, 37(22): 2443-2450.
- [7] WU X J, JIANG G C, WANG X J, et al. Prediction of reservoir sensitivity using RBF neural network with trainable radial basis function[J]. Neural Computing & Applications, 2013, 22(5): 947-953.
- [8] NA'IMI S R, SHADIZADEH S R, RIAHI M A, et al. Estimation of reservoir porosity and water saturation based on seismic attributes using support vector regression approach[J]. Journal of Applied Geophysics, 2014, 107: 93-101.
- [9] AL-ANAZI A F, GATES I D. Support vector regression for porosity prediction in a heterogeneous reservoir: a comparative study[J]. Computers & Geosciences, 2010, 36(12): 1494-1503.
- [10] AL-ANAZI A F, GATES I D. Support vector regression to predict porosity and permeability: effect of sample size[J]. Computers & Geosciences, 2012, 39(2): 64-76.
- [11] MOLLAHAN A. Estimation of reservoir water saturation using support vector regression in an Iranian carbonate reservoir[C]// American Rock Mechanics Association. 2013.
- [12] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25(2): 2012.
- [13] DENG L, LI J, HUANG J T, et al. Recent advances in deep learning for speech research at microsoft[C]//2013: 8604-8608.
- [14] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [15] 李飞腾. 卷积神经网络及其应用[D]. 大连理工大学, 2014.  
LI F T. Convolutional neural network and its applications[D]. Dalian University of Technology, 2014
- [16] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks[J]. Journal of Machine Learning Research, 2010, 9: 249-256.

### 作者简介:



段友祥 (1964-), 男, 山东东营人, 博士, 中国石油大学 (华东) 教授、硕士生导师, 主要研究方向为网络与服务计算、计算机技术在油气领域的应用等。



李根田 (1992-), 男, 山东东营人, 中国石油大学 (华东) 硕士生, 主要研究方向为计算机可视化、机器学习和三维地质建模。



孙歧峰 (1976-), 男, 山东莘县人, 博士, 中国石油大学 (华东) 讲师, 主要研究方向为计算机技术在油气领域的应用等。