

文章编号:1009-9603(2019)05-0073-06

DOI:10.13673/j.cnki.cn37-1359/te.2019.05.009

# 基于卷积门控循环单元网络的储层参数预测方法

宋辉<sup>1,2</sup>,陈伟<sup>1,2,3</sup>,李谋杰<sup>1,2,3</sup>,王浩懿<sup>4</sup>

(1.油气资源与勘探技术教育部重点实验室 长江大学,湖北 武汉 430100; 2.长江大学 地球物理与石油资源学院,湖北 武汉 430100; 3.非常规油气湖北省协同创新中心 长江大学,湖北 武汉 430100; 4.太原理工大学 材料科学与工程学院,山西 太原 030024)

**摘要:**储层参数是储层评价的一项重要内容。针对传统储层预测方法难以摆脱线性方程的束缚及预测精度不高的问题,将卷积神经网络与门控循环单元网络相结合,提出了卷积门控循环单元网络模型。该模型不仅具备卷积神经网络局部感知的特性,还具备门控循环单元网络长期记忆的功能,从而具有表达数据时空特征的能力。基于某井区A井已知井段测井资料建立卷积门控循环单元网络孔隙度预测模型,预测该井区未知深度段的孔隙度,并提出变学习率训练方法。实验证明,与单一的卷积神经网络模型、门控循环单元网络模型相比,卷积门控循环单元网络模型能够更有效地提取数据特征,预测精度更高,可为储层参数的预测提供新的思路。

**关键词:**储层参数预测;孔隙度;深度学习;卷积神经网络;循环神经网络;门控循环单元网络

中图分类号:TE122.2

文献标识码:A

## A method to predict reservoir parameters based on convolutional neural network-gated recurrent unit(CNN-GRU)

SONG Hui<sup>1,2</sup>, CHEN Wei<sup>1,2,3</sup>, LI Moujie<sup>1,2,3</sup>, WANG Haoyi<sup>4</sup>

(1.Key Laboratory of Exploration Technologies for Oil and Gas Resources, Ministry of Education, Yangtze University, Wuhan City, Hubei Province, 430100, China; 2.Institute of Geophysics and Petroleum Resources, Yangtze University, Wuhan City, Hubei Province, 430100, China; 3.Hubei Cooperative Innovation Center of Unconventional Oil and Gas, Yangtze University, Wuhan City, Hubei Province, 430100, China; 4.School of Materials Science and Engineering, Taiyuan University of Technology, Taiyuan City, Shanxi Province, 030024, China)

**Abstract:** Reservoir parameters are important for reservoir evaluation. Aiming at the difficulties of the traditional reservoir parameters prediction method to get rid of the constraint of a linear equation and the low prediction accuracy, a model combined with convolutional neural network (CNN) and gated recurrent unit (GRU) is proposed. The model not only has the local perception characteristics of CNN but also has the long-term memory function of GRU, thus having the ability to express the spatio-temporal features of data. The CNN-GRU porosity prediction model is established based on the well logging data of Well A to predict the porosity of unknown depth segment in this well area, and to further propose a variable learning rate training method. Compared with CNN or GRU models, experimental results show that CNN-GRU model can extract data features more effectively and can improve the reservoir parameters prediction accuracy, which provides a new idea to predict reservoir parameters.

**Key words:** reservoir parameter prediction; porosity; deep learning; convolutional neural network; recurrent neural network; gated recurrent unit

收稿日期:2019-06-08。

作者简介:宋辉(1996—),男,山东济宁人,在读硕士研究生,从事深度学习与储层预测研究。联系电话:17771444311, E-mail:201400567@yangtzeu.edu.cn。

通信作者:陈伟(1985—),男,湖北监利人,博士,副教授。联系电话:13125041733, E-mail:chenwei2014@yangtzeu.edu.cn。

基金项目:国家自然科学基金项目“基于经验模态分解的自由表面多次波衰减方法研究”(41804140),湖北省教育厅指导性项目“基于地震数据结构的高分辨率油藏识别方法研究”(B2018556),油气资源与勘探技术教育部重点实验室(长江大学)“地球物理信息探测方法与技术”(PI2018-02)。

储层参数通常由测井资料确定,传统的测井资料解释基于储层均质性假设建立测井解释方程,难以摆脱线性方程的束缚。随着非常规油气成为目前勘探开发的主体,储层预测的目标介质发生了很大变化,具有明显的非均质、各向异性特征<sup>[1]</sup>,常规测井储层预测技术难以满足勘探领域的要求。如今发展的机器学习技术可以很好地解决测井解释中的非线性映射问题<sup>[2]</sup>。

用于储层预测的机器学习算法主要有支持向量机<sup>[3-8]</sup>、随机森林<sup>[9]</sup>、极端梯度提升<sup>[10]</sup>和人工神经网络<sup>[11-16]</sup>等。深度学习是机器学习的一个分支,其概念源于对人工神经网络的研究。相对于传统的浅层学习,深度学习通过构建具有很多隐层的机器模型结构,实现复杂函数逼近和逐层特征变换,从而提升预测或分类的准确性。目前深度学习已广泛应用于计算机视觉、自然语言处理、语音识别等领域。

深度学习包括很多流行的模型,如卷积神经网络(CNN)和循环神经网络(RNN)。段友祥等借鉴CNN在图像处理上的应用,在卷积模型中将测井参数调整为二维数据,更好地提取了储层特征<sup>[17]</sup>。林年添等将CNN应用于地震储层预测,取得较好的预测结果<sup>[18-19]</sup>。无论是CNN,还是全连接神经网络(DNN),其前提假设均为:前一个输入和后一个输入是完全没有关系的。但是,某些任务需要能够更好地处理序列的信息,即有些场景输入的数据与后面输入的数据是有关系的,或者说后面的数据跟前面的数据是有关联的。而长短期记忆网络(LSTM)与门控循环单元网络(GRU)能够考虑历史输入对当前输入的影响,因此非常适合处理序列数据。张东晓等将LSTM应用于测井曲线生成,该方法准确性高且成本低<sup>[20]</sup>。安鹏等将其应用于孔隙度与泥质含量预测,取得了比DNN更优的结果<sup>[21]</sup>。

以上研究结果表明,基于深度学习的储层预测比传统方法有更好的预测结果。储层预测实质上属于序列预测问题,因此在测井数据提取特征中,既要考虑不同特征参数之间空间上的联系,还要考虑测井参数随深度的变化。为此,提出将CNN与GRU相结合,选取对孔隙度较为敏感的声波、密度、补偿中子、自然伽马4种测井参数作为模型输入,从而进行孔隙度预测。同时为证明该模型对于孔隙度预测的有效性,利用CNN-GRU模型对某井区A井未知深度的孔隙度进行预测,并与CNN和GRU模型预测的结果进行比较,证实CNN-GRU模型的有效性。

# 1 深度学习理论

CNN与RNN是深度学习的2种特性不同的模型。CNN具有参数共享、稀疏连接的特性,因此擅长提取数据的空间特征。RNN具有记忆的特性,能以很高的效率处理序列数据任务。在某些情况下,一个任务的完成需要多种模型共同发挥作用,CNN与RNN有时也结合使用<sup>[22]</sup>。但RNN存在着梯度消失的问题,难以记忆长距离的信息。门控算法是RNN应对梯度消失的重要方法,而GRU是门控算法的代表。因此,本次基于CNN与GRU进行孔隙度预测。

## 1.1 卷积神经网络

CNN是一种特殊的网络结构,在计算机视觉领域广泛应用。CNN包含卷积层与池化层2种特殊的提取结构。卷积层能够提取前一层的特征并得到特征图,由于每个特征图的神经元能够共享权重参数,减少了网络各层的连接,同时也降低了过拟合的风险;池化层也称为下采样,可以看作一种特殊的卷积过程,主要用于特征降维、压缩数据以及减少参数的数量。

卷积是CNN中非常重要的操作,不同维度的卷积可以解决不同的问题。用一维卷积处理测井资料,提取的是测井参数在邻近时间步长上的变化;用二维卷积处理测井资料,可以用于提取不同测井参数之间的关系。研究使用二维卷积提取不同测井参数之间的关系,其处理步骤包括:①借用图像识别的处理,将测井资料表征为时间步长×特征参数的矩阵。②用二维卷积提取特征。选用的特征参数包括声波、密度、补偿中子和自然伽马,其原理如图1所示,卷积核长度为1×4,点乘表1中每一行的值,从上到下依次进行,如果输入的时间步长为5,则5×4个数据经过这一层卷积后被压缩为5个数据,如果需要保持原来尺寸,则需要通过填充0操作。

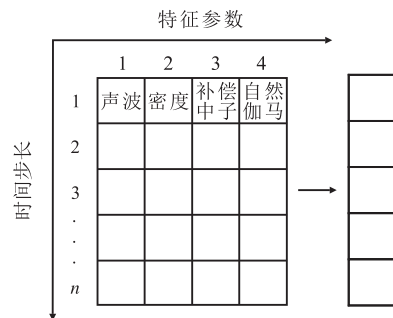


图1 二维卷积提取测井数据不同特征参数示意  
Fig.1 Schematic of different characteristic parameters extraction of logging data by two-dimensional convolution

### 1.2 门控循环单元网络

RNN是当前深度学习热潮中最重要的技术之一。一个典型的RNN结构包括输入层、隐藏层和输出层。由图2可知,RNN的特殊之处在于隐藏层为循环体结构,也就是说RNN每一时刻都在执行同样的操作,只不过是输入数据不同而已。该结构使得RNN当前时刻的计算会结合历史的输入信息,有助于处理序列相关的任务。但RNN只能记忆短期的历史输入信息,无法有效解决长期记忆的问题。




图2 RNN模型

Fig.2 Schematic of RNN model

为克服长期记忆问题,提出LSTM<sup>[23]</sup>。LSTM的核心思想在于细胞状态和各种门结构。细胞状态携带网络不同时刻的记忆信息,而输入门、遗忘门和输出门能够控制细胞状态遗忘或记忆某些信息。GRU是LSTM的一种非常流行的变体,在很多任务中能够达到与LSTM相当的表现,同时具有更简洁的模型结构,减少模型训练的参数,增强模型防止过拟合的能力,并且提高模型的收敛速度。GRU对LSTM做了2个大的改动:①将单元状态与输出合并为隐藏状态,依靠隐藏状态来传输信息。②将输入门、遗忘门和输出门更改为更新门和重置门。

GRU模型隐藏层结构包含更新门激活向量( $z_t$ )、重置门激活向量( $r_t$ )、候选状态向量( $\tilde{h}_t$ )、隐藏状态向量( $h_t$ )及上一时刻的隐藏状态向量( $h_{t-1}$ )(图3)。




图3 GRU模型隐藏层结构

Fig.3 Hidden layer structure of GRU model

更新门同时决定着丢弃旧信息的内容和添加新信息的内容,其表达式为:

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z) \quad (1)$$

重置门决定着忘记历史信息,其表达式

为:

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \quad (2)$$

候选状态主要是包含当前时刻输入的信息,相当于记忆了当前时刻的状态,其表达式为:

$$\tilde{h}_t = \tanh(W_h[h_{t-1} \otimes r_t, x_t] + b_h) \quad (3)$$

隐藏状态决定当前时刻需要输出的信息,其表达式为:

$$h_t = (1 - z_t) \otimes h_{t-1} + z_t \otimes \tilde{h}_t \quad (4)$$

## 2 模型构建

CNN与GRU模型是深度学习非常流行的算法,具有不同的特性。CNN模型具有局部感知的特性,而GRU模型具有长期记忆的功能,更适合解决时序问题。为此,将CNN与GRU相结合,设计CNN-GRU模型进行孔隙度预测,该模型具有表达数据时空特征的能力,模型预测框架如图4所示。在数据输送到网络模型之前,首先需要对数据进行预处理,即划分数数据集与数据归一化,然后将预处理后的数据输送到网络模型中进行训练及测试。另外,CNN-GRU模型隐藏层由单层CNN与GRU构成。在CNN层设置8个 $1 \times 4$ 的卷积核,在GRU层设置4个神经单元。同时,考虑到如果时间步长太短,模型可以利用的信息太少会影响预测精度,而时间步长太长,则会增加模型计算的负担,因此,在本次实验中,将时间步长设置为6。选择TensorFlow框架来实现模型,TensorFlow具备高质量的元框架,如Keras,Keras作为TensorFlow的高级应用程序编程接口,封装了很多TensorFlow的代码,使得代码模块化,非常简便,但缺少灵活性。因此,本次模型建模部分主要由Keras完成,其余部分由TensorFlow完成,充分利用两者的优势。




图4 CNN-GRU模型预测框架

Fig.4 Prediction framework of CNN-GRU model

为避免模型出现过拟合现象,提高模型的泛化能力,在损失函数中加入L2正则化项。最终将模型损失函数定义为:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N \| \hat{y}_\theta(x_i) - y_i \|_2^2 + \frac{\lambda}{N} \sum_{i=1}^N \theta^2 \quad (5)$$

模型使用RMSProp优化器来更新网络参数,以最小化损失函数,其表达式更新为:

$$s = \beta s + (1 - \beta) g^2 \tag{6}$$

$$\theta = \theta - \frac{\eta}{\sqrt{s + \epsilon}} \otimes g \tag{7}$$

学习率是深度学习中一个非常重要的超参数。学习率太大,网络无法收敛到全局最小值,而是在全局最小值附近“徘徊”;学习率太小,网络收敛需要极长的时间。因此,调整好学习率是训练出好模型的关键要素之一。设置变学习率训练方法为:

$$\eta = \begin{cases} 0.01 & (epoch \leq r1) \\ 0.001 & (r1 < epoch \leq r2) \\ 0.0001 & (r2 < epoch) \end{cases} \tag{8}$$

(8)式中,r1与r2将训练阶段分为训练前期、训练中期和训练后期。(8)式表明训练前期使用较大的学习率以加速网络收敛,然后以较小的学习率过渡到训练后期,最后设置更小的学习率,以保证训练的稳定性。

### 3 实例与分析

为证明所设计模型的有效性,利用某井区的A井数据进行验证。在A井中选择井深为6 650~6 813 m的1 080组测井数据作为训练集,井深为6 813~6 868 m的360组测井数据作为测试集。训练集是为了训练网络参数,而测试集则用来测验模型的性能。为加速训练及提高模型预测的精度,对数据进行归一化处理,归一化公式为:

$$Y = \frac{X - X_{min}}{X_{max} - X_{min}} \tag{9}$$

经过多次实验,将CNN-GRU模型中r1,r2分别设置为50,200;将CNN模型中r1,r2分别设置为100,400;将GRU模型中r1,r2分别设置为100,500。为检验3种模型的预测效果,将训练好的模型分别在测试集上进行测试。

从图5可以看出,3种深度学习模型均实现了很




图5 3种深度学习模型孔隙度预测结果

Fig.5 Porosity prediction results based on three different deep learning models

好的预测结果,证明深度学习能有效地提取测井数据之间的非线性化特征,为储层预测提供了一种有效的新技术。为评价3种模型性能,采用均方差和相关系数(R)作为评价标准(表1)。从表1可知,CNN-GRU模型对均方差和相关系数的预测结果比单一的GRU模型和CNN模型更优,这说明充分利用数据的时空特征可以取得更好的预测效果,证明

CNN-GRU模型的有效性。

从CNN-GRU模型在测试集上的交会结果(图6)可以看出,CNN-GRU模型预测的孔隙度与实际孔隙度具有较高的相关性,其相关系数达0.9118。

为证明所设置变学习率训练方法的有效性,将设置的学习率与固定学习率0.01,0.001和0.0001分别迭代1 000次。由图7可知,当学习率为0.01

表1 3种深度学习模型预测结果评价  
Table1 Evaluation of prediction results based on three different deep learning models

模型	均方差( $10^{-5}$ )	相关系数
CNN	9.630	0.900 5
GRU	9.410	0.901 7
CNN-GRU	8.479	0.911 8




图6 CNN-GRU模型在测试集上的交会结果  
Fig.6 Cross plot on test set based on CNN-GRU model




图7 不同学习率对模型收敛的影响

Fig.7 Effect of different learning rates on model convergence

时,训练前期网络收敛快,训练后期网络难以收敛;当学习率为0.000 1时,网络收敛缓慢。因此,以固定学习率训练网络模型存在着收敛震荡或收敛很慢的问题。这证明所提出的学习率设置方式,既可在训练前期加速网络收敛,又可在训练后期使网络平稳收敛到一个较小的值。由不同学习率对模型预测结果的影响(图8)可知,所提出的变学习率训练方法能够得到更好的预测精度。

## 4 结束语

随着勘探领域的变化,储层介质由均质地层转向非均质地层,传统的储层预测方法难以估计出非均质地层的孔隙度。深度学习是机器学习的一个分支,已被广泛应用于各个领域。CNN与GRU是2种特性不同的深度学习模型,CNN模型适合提取不




图8 不同学习率对模型预测结果的影响

Fig.8 Effect of different learning rates on model prediction results

同测井参数之间的非线性关系,GRU模型适合提取测井参数在时间维度上的变化,2种模型均取得了不错的储层参数预测结果。本次结合2种模型的优势,设计了CNN-GRU模型。该模型能够充分提取测井数据的时空特征,预测精度优于单一的模型。调整好学习率是训练出好模型的关键要素之一,所提出的变学习率训练方法,既可以加速网络收敛,又可以提高模型的预测精度。

### 符号解释

$n$ ——时间步长; $x_t$ —— $t$ 时刻的输入; $y_t$ —— $t$ 时刻的输出; $h_t$ —— $t$ 时刻的隐藏状态向量; $r_t$ ——重置门激活向量; $\sigma$ ——Sigmoid函数; $z_t$ ——更新门激活向量; $\tilde{h}_t$ —— $t$ 时刻的候选状态向量; $\tanh$ —— $\tanh$ 函数; $W_z$ ——更新门权重矩阵; $b_z$ ——更新门偏置值; $W_r$ ——重置门权重矩阵; $b_r$ ——重置门偏置值; $W_h$ ——候选状态的权重矩阵; $b_h$ ——候选状态的偏置值; $x_n$ ——第 $n$ 个输入值; $\hat{y}_n$ ——第 $n$ 个输出值; $L(\theta)$ ——模型损失函数; $\theta$ ——模型中的权重矩阵与偏置值; $N$ ——样本数量; $i$ ——样本序号, $i=1,2,3,\dots,N$ ; $y_\theta(x_i)$ ——输入值为 $x_i$ 时的预测值; $x_i$ ——输入值; $y_i$ ——实际值; $\lambda$ ——正则化系数,取值为 $10^{-5}$ ; $s$ ——累积平方梯度; $\beta$ ——动量系数; $g$ ——梯度; $\eta$ ——学习率; $\varepsilon$ ——用于维持数值稳定的常数,取值为 $10^{-8}$ ; $epoch$ ——迭代次数; $r_1$ ——训练前期与训练中期的界限值; $r_2$ ——训练中期与训练后期的界限值; $Y$ ——测井数据归一化后的值; $X$ ——测井数据。

### 参考文献

[1] 甘利灯,张昕,王晓钧,等.从勘探领域变化看地震储层预测技术现状和发展趋势[J].石油地球物理勘探,2018,53(1):214-225.  
GAN Lideng, ZHANG Xin, WANG Yaojun, et al. Current status and development trends of seismic reservoir prediction viewed from the exploration industry [J]. Oil Geophysical Prospecting, 2018, 53(1): 214-225.

- [2] 刘全稳. 测井神经网络技术综述[J]. 石油地球物理勘探, 1996, 31(增刊1): 64-69.  
LIU Quanwen. Survey of logging neural network technology[J]. Oil Geophysical Prospecting, 1996, 31(Supplement 1): 64-69.
- [3] 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.
- [4] 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): 1 494-1 503.
- [5] 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.
- [6] ZHAO B, ZHOU H, LI X, et al. Water saturation estimation using Support Vector Machine [J]. SEG Technical Program Expanded Abstracts, 2006, 25(1): 1 693-1 697.
- [7] 张向君, 张晔. 基于支持向量机的交互检验储层预测[J]. 石油物探, 2018, 57(4): 597-600.  
ZHANG Xiangjun, ZHANG Ye. Reservoir prediction through cross-validation based on support vector machine [J]. Geophysical Prospecting for Petroleum, 2018, 57(4): 597-600.
- [8] 林年添, 付超, 张栋, 等. 无监督与监督学习下的含油气储层预测[J]. 石油物探, 2018, 57(4): 601-610.  
LIN Niantian, FU Chao, ZHANG Dong, et al. Supervised learning and unsupervised learning for hydrocarbon prediction using multi-wave seismic data [J]. Geophysical Prospecting for Petroleum, 2018, 57(4): 601-610.
- [9] 宋建国, 杨璐, 高强山, 等. 强容噪性随机森林算法在地震储层预测中的应用[J]. 石油地球物理勘探, 2018, 53(5): 954-960.  
SONG Jianguo, YANG Lu, GAO Qiangshan, et al. Strong tolerance random forest algorithm in seismic reservoir prediction [J]. Oil Geophysical Prospecting, 2018, 53(5): 954-960.
- [10] 闫星宇, 顾汉明, 肖逸飞, 等. XGBoost算法在致密砂岩气储层测井解释中的应用[J]. 石油地球物理勘探, 2019, 54(2): 447-455.  
YAN Xingyu, GU Hanming, XIAO Yifei, et al. XGBoost algorithm applied in the interpretation of tight-sand gas reservoir on well logging data [J]. Oil Geophysical Prospecting, 2019, 54(2): 447-455.
- [11] 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 Rong, WANG Feng. Application of MATLAB-based of BP neural network in reservoir parameters prediction [J]. Well Logging Technology, 2009, 33(1): 75-78.
- [12] 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 Yingtao, YUAN Xiaoyu, LIU Di, et al. Research on the application of BP neural network in wells log interpretation [J]. West-China Exploration Engineering, 2013, 25(3): 45-48.
- [13] 张向君, 管叶君, 崔凤林, 等. 双重神经网络预测储层及油气[J]. 石油地球物理勘探, 1997, 32(5): 717-723.  
ZHANG Xiangjun, GUAN Yejun, CUI Fenglin, et al. Predicting a reservoir and the hydrocarbon resources by dual neural network [J]. Oil Geophysical Prospecting, 1997, 32(5): 717-723.
- [14] 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 Xingpeng. Application of similarity-genetic neural network to reservoir parameters prediction [J]. Well Logging Technology, 2012, 36(3): 267-271.
- [15] 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]. 计算机工程应用, 2014, 50(10): 52-56.  
PAN Shaowei, LIANG Hongjun, LI Liang, et al. Dynamic prediction on reservoir parameter by improved PSO-BP neural network [J]. Computer Engineering & Applications, 2014, 50(10): 52-56.
- [16] 赵约翰. 基于地质模型监督的灰质泥岩发育区砂岩储层预测方法[J]. 油气地质与采收率, 2018, 25(4): 46-53.  
ZHAO Yuehan. A prediction method of sandstone reservoir in limy mudstone developmental area based on the geological model constraint [J]. Petroleum Geology and Recovery Efficiency, 2018, 25(4): 46-53.
- [17] 段友祥, 李根田, 孙歧峰. 卷积神经网络在储层预测中的应用研究[J]. 通信学报, 2016, 37(Z1): 1-9.  
DUAN Yongxiang, LI Gentian, SUN Qifeng. Research on convolutional neural network for reservoir parameter prediction [J]. Journal on Communications, 2016, 37(Z1): 1-9.
- [18] 林年添, 张栋, 张凯, 等. 地震油气储层的小样本卷积神经网络学习与预测[J]. 地球物理学报, 2018, 61(10): 4 110-4 125.  
LIN Niantian, ZHANG Dong, ZHANG Kai, et al. Predicting distribution of hydrocarbon reservoirs with seismic data based on learning of the small-sample convolution neural network [J]. Chinese Journal of Geophysics, 2018, 61(10): 4 110-4 125.
- [19] 张繁昌, 刘汉卿, 钮学民, 等. 褶积神经网络高分辨率地震反演[J]. 石油地球物理勘探, 2014, 49(6): 1 165-1 169.  
ZHANG Fanchang, LIU Hanqing, NIU Xuemin, et al. High resolution seismic inversion by convolutional neural network [J]. Oil Geophysical Prospecting, 2014, 49(6): 1 165-1 169.
- [20] 张东晓, 陈云天, 孟晋. 基于循环神经网络的测井曲线生成方法[J]. 石油勘探与开发, 2018, 45(4): 598-607.  
ZHANG Dongxiao, CHEN Yuntian, MENG Jin. Synthetic well logs generation via Recurrent Neural Networks [J]. Petroleum Exploration and Development, 2018, 45(4): 598-607.
- [21] 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, 33(3): 1 029-1 034.  
AN Peng, CAO Danping. Research and application of logging lithology identification based on deep learning [J]. Progress in Geophysics, 2018, 33(3): 1 029-1 034.
- [22] ZUO H, FAN H, BLASCH E, et al. Combining convolutional and recurrent neural networks for human skin detection [J]. IEEE Signal Processing Letters, 2017, 24(3): 289-293.
- [23] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1 735-1 780.