

基于量子衍生布谷鸟的脊波过程神经网络及TOC预测

刘志刚^{1†}, 许少华², 李盼池¹, 肖佃师³

(1. 东北石油大学 计算机与信息技术学院, 黑龙江 大庆 163318; 2. 山东科技大学 信息科学与工程学院,
山东 青岛 266590; 3. 中国石油大学(华东) 非常规油气与新能源研究院, 山东 青岛 266580)

摘要: 为提高总有机碳含量(TOC)的预测精度,针对测井曲线的时变、奇异性特征,选用脊波函数作为过程神经元的激励函数,提出一种连续脊波过程神经元网络。模型训练方面首先给出基于正交基展开的梯度下降法;其次为提高模型训练收敛能力,提出一种沿Bloch球面纬线实施莱维飞行的量子衍生布谷鸟算法,并用于模型参数优化;最后将训练好的脊波过程神经网络应用于泥页岩TOC预测,通过相关性选取对TOC响应敏感的测井曲线作为模型特征输入。实验对比结果表明,该方法的预测精度较高,较其他过程神经网络提高7个百分点。

关键词: 脊波函数; 过程神经网络; 量子布谷鸟; 网络训练; TOC预测

中图分类号: TP183

文献标志码: A

Ridgelet process neural networks based on quantum-inspired cuckoo search and application for TOC prediction

LIU Zhi-gang^{1†}, XU Shao-hua², LI Pan-chi¹, XIAO Dian-shi³

(1. School of Computer and Information Technology, Northeast Petroleum University; Daqing 163318, China; 2. College of Information Science and Engineering, Shandong University of Science and Technology, Qingdao 266590, China; 3. Institute of Unconventional Oil & Gas and New Energy, China University of Petroleum, Qingdao 266580)

Abstract: To enhance the prediction accuracy of total organic carbon(TOC), and according to time-varying, singularity feature of logging curve, the ridgelet transform function is used as the activation function for process neuron and a continuous ridgelet process neural network is proposed. Firstly, the gradient descent method based on orthogonal basis expansion is proposed. Then, in order to improve the training convergence ability, a quantum-inspired cuckoo search algorithm is proposed and applied to model training, in which, the individual's Lévy flight follows the latitude on the Bloch sphere. Finally, the trained ridgelet process neural network is applied to shale TOC prediction. Some logging curves which have sensitive response to TOC are selected as the model feature inputs by the correlation analysis. Through the comparison with other process neural networks, the experimental result shows that the TOC prediction accuracy increases about 7 percent.

Keywords: ridgelet function; process neural network; quantum cuckoo search; network training; TOC prediction

0 引言

近年来,以页岩油气为重点的非常规资源已成为世界能源焦点,总有机碳含量(TOC)是用来反映页岩油气富集程度的重要参数^[1]。利用 $\Delta \log R$ 法进行TOC预测时,需要人工选定基线,推广受到限制。文献[2-4]根据常规测井资料,利用人工神经网络(ANN)进行了TOC预测的积极探索,取得一定的效果,但预测精度偏低。主要原因在于:1)基于测井资料的TOC预测主要依据的是反映地层物理性质随深度变化的多条测井曲线形态、幅值特征及其组合关系,因此建

立地质区域TOC与测井响应曲线之间对应关系的判别模型时,保持连续测井曲线的过程形态完整以及客观地提取是提高TOC预测精度的关键,在本质上属于连续过程信号的建模问题,而ANN受同步瞬时输入限制,无法体现测井连续信号的TOC时间累积效应,导致预测精度较低;2)测井曲线受地层变化影响,振幅、频率突变频繁,数据中存在大量的奇异点,具有超平面奇异特性,从数学角度看,ANN受激励函数限制,难以完成这种复杂奇异性信号的非线性映射。

神经元的聚合机制和激励函数对模型的逼近能

收稿日期: 2016-04-29; 修回日期: 2016-08-17。

基金项目: 国家自然科学基金项目(61170132, 41330313); 黑龙江省自然科学基金项目(F2015021)。

作者简介: 刘志刚(1979—), 男, 副教授, 博士生, 从事神经网络、量子衍生进化算法的研究; 许少华(1962—), 男, 教授, 博士生导师, 从事过程神经网络等研究。

[†]通讯作者. E-mail: dqpilzg@163.com

力有重要影响。过程神经元网络(PNN)通过在神经元内部增加对时间的积分算子,实现连续输入信号的处理,逼近精度较高,近年来人们相继提出了量子^[5]、离散^[6]、多聚合^[7]、半监督^[8]等PNN模型,主要用于无突变、较为平稳的时变过程信号处理。但对于复杂奇异性时变信号处理,若满足精度要求,则需要增加隐层节点数或隐层数,导致网络规模较大、存在冗余,模型稳定性和泛化能力受到影响^[9]。近年来,脊波变换作为一种多尺度几何分析工具,引起广泛关注。它将小波分析的优点延伸到高维空间,在尺度、位置基础上,增加对高维数据的方向描述,有效处理数据直线和超平面奇异性,完成对空间不均匀性函数的逼近。在生理学上,更符合人类视觉系统,即根据目标方向信息寻找最少的神经元进行信息表示。目前,脊波变换已逐渐应用于图像处理^[10-11]、函数逼近^[12-13]等问题中。

鉴于此,本文为提高TOC预测精度,提出一种脊波过程神经元网络(RPNN),将脊波函数作为过程神经元激励函数,处理测井曲线奇异性复杂的信号时,通过不断调节位置、尺度、方向3个参数。同时,内部的时空聚合算子可以处理测井曲线的连续过程信号映射,不易丢失细节,二者结合提高TOC预测精度。在学习算法方面,首先给出梯度下降学习算法,该方法简单,但训练收敛性略低。为解决该问题,将模型训练转换为优化问题,因RPNN学习参数较多,提出一种量子衍生布谷鸟搜索算法(QCS)。最后以A区B井的TOC预测为例,验证所提出方法的有效性。实验结果表明,所提出方法的TOC预测精度有一定提高,当电阻率与TOC相关性较弱时,QCS-RPNN的TOC预测精度较传统的 $\Delta \log R$ 法提高16%左右,较其他过程神经网络提高7%。

1 脊波变换

设 $\psi : R^d \rightarrow R \in S(R)$ 为Schwartz空间, $\hat{\psi}(\xi)$ 为 ψ 的傅里叶变换,如果函数 $\psi : R^d \rightarrow R$ 满足下列约束条件,则称函数 ψ 为容许函数:

$$K_\psi = \int \frac{|\hat{\psi}(\xi)|^2}{|\xi|^d} d\xi < \infty. \quad (1)$$

由 ψ 产生的脊函数 ψ_r 定义为脊波,有

$$\psi_r = \psi((ux - b)/a), \quad (2)$$

其中 a, b, c 分别为脊波的尺度、位置、方向。参数空间定义为

$$\Gamma = \{\gamma = (a, u, b), a > 0, u \in S^{d-1}, \|u\| = 1\}. \quad (3)$$

Γ 中的度量定义为

$$\mu(d\gamma) = \frac{\sigma_d d_a d_u db}{a^{d+1}}.$$

其中: σ_d 为 d 维空间中的单位球 S^{d-1} 的表面面积, d_u 为球 S^{d-1} 上的一致概率度量。

若给定一个双变量函数 $f(x) = L^1 \cap L^2(R^2)$,则 $f(x)$ 的连续脊波变换定义为

$$R_f(a, b, \theta) = \int_{R^2} \psi_{a,b,\theta}(x) f(x) dx, \quad (4)$$

其中

$$\psi_{a,b,\theta}(x) = a^{1/2} \psi((\cos \theta)x_1 + (\sin \theta)x_2 - b/a).$$

2 脊波过程神经网络RPNN

脊波过程神经元除对输入信号进行时空聚合外,同时进行方向、尺度和位置的变换。记输入函数为 $X(t) = \{x_1(t), x_2(t), \dots, x_n(t)\}$,输入到隐层的连接权函数为 $W(t) = \{w_1(t), w_2(t), \dots, w_n(t)\}$, ψ 为脊波函数,则单隐层单输出RPNN如图1所示。

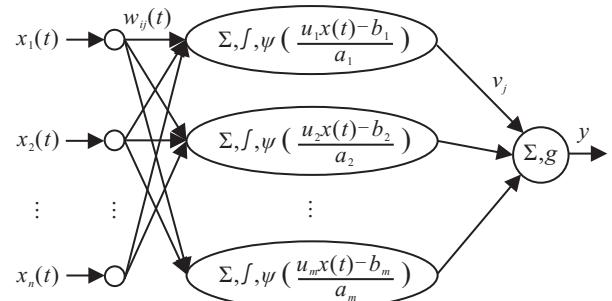


图1 脊波过程神经元网络

RPNN的输出与输入间的关系为

$$y = g\left(\sum_{j=1}^m v_j \psi\left(\left(u_j \int_0^T \sum_{i=1}^n \omega_{ij}(t) x_i(t) dt - b_j\right) / a_j\right)\right). \quad (5)$$

其中: $\psi(\cdot)$ 为脊波函数, $w_{ij}(t)x_i(t)$ 为第*i*个输入 $x_i(t)$ 与权值 $w_{ij}(t)$ 的内积。

在输入函数空间 $C[0, T]$ 中选取一组正交基函数 $b_1(t), b_2(t), \dots, b_L(t)$,对于输入函数和权函数,在满足拟合精度的条件下进行展开,有

$$x_i(t) = \sum_{l=1}^L c_i^{(l)} b_l(t), \quad w_{ij}(t) = \sum_{k=1}^L w_{ij}^{(k)} b_k(t). \quad (6)$$

根据标准正交基的特性,式(6)可整理为

$$y = g\left(\sum_{j=1}^m v_j \psi\left(\frac{u_j \sum_{i=1}^n \sum_{l=1}^L w_{ij}^{(l)} c_i^{(l)} - b_j}{a_j}\right)\right). \quad (7)$$

设*K*个样本为 $(x_{k1}(t), x_{k2}(t), \dots, x_{kn}(t), d_k)$,

其中 $k = 1, 2, \dots, K$, 则模型的误差函数定义为

$$E = \frac{1}{2} \sum_{s=1}^K (y_k - d_k)^2 = \frac{1}{2} \sum_{s=1}^K \left(g \left(\sum_{j=1}^m v_j \psi \left(\frac{u_j \sum_{i=1}^n \sum_{l=1}^L w_{ij}^{(l)} c_{is}^{(l)} - b_j}{a_j} \right) \right) - d_k \right)^2. \quad (8)$$

3 学习算法

3.1 梯度下降学习算法

RPNN 的学习参数有权函数基展开系数 $w_{ij}^{(l)}$ 、隐层输出权值 v_j 、尺度参数 a_j 、位置参数 b_j 、方向参数 u_j . 根据梯度下降修正各个参数如下:

$$\begin{cases} w_{ij}^l = w_{ij}^l - \alpha(y - d) \left(\sum_{j=1}^m v_j \psi'(\sigma) \right) \sum_{i=1}^n \frac{u_j c_i^l}{a_j}, \\ v_j = v_j - \beta(y - d) \psi(\sigma), \\ a_j = a_j - \lambda(y - d) \left(\sum_{j=1}^m v_j \psi'(\sigma) \left(-\frac{u_j w_{ij} c_i^l}{a_j^2} \right) \right), \\ b_j = b_j - \eta(y - d) \left(\sum_{j=1}^m v_j \psi'(\sigma) \left(-\frac{1}{a_j} \right) \right), \\ u_j = u_j - \gamma(y - d) \left(\sum_{j=1}^m v_j \psi'(\sigma) \left(-\frac{w_{ij} c_i^l}{a_j} \right) \right), \end{cases} \quad (9)$$

其中 $\alpha, \beta, \lambda, \eta, \gamma$ 为学习速率. 具体步骤如下.

Step 1: 设定模型训练误差精度 ε 、最大学习次数 Max_I、当前累计学习次数 Curr_I.

Step 2: 选取一组正交基函数 $b_1(t), b_2(t), \dots, b_L(t)$, 对于输入函数, 按照一定精度进行展开.

Step 3: 随机初始化参数 $w_{ij}^{(l)}, v_j, a_j, b_j, u_j, i = 1, 2, \dots, n, j = 1, 2, \dots, m, l = 1, 2, \dots, L$.

Step 4: 按式(8)计算误差, 若 $E < \varepsilon$ 或 $Curr_I > Max_I$, 则转 Step 6, 否则执行下一步.

Step 5: 计算梯度, 修正各个参数, $Curr_I + 1 \rightarrow Curr_I$, 转至 Step 4.

Step 6: 模型学习结束.

3.2 量子布谷鸟优化学习算法

梯度下降法存在对初值敏感、易陷入局部最小等不足, 导致训练收敛性较差. 布谷鸟搜索算法是一种元启发优化算法^[14], 算法参数较少、易于实现. 并且性能接近或略高于粒子群、差分进化和人工蜂群算法^[15], 但对于 RPNN 训练这种高维优化问题, 与其他算法类似, CS 算法易陷入局部最小.

为提高 CS 算法的优化能力和 RPNN 训练收敛性, 提出一种量子衍生布谷鸟算法 QCS, 个体采用 Bloch 球面坐标^[16]描述的量子比特编码, 通过量子旋

转门完成个体进化, 使用莱维飞行确定旋转门的幅角. 为保持种群多样性, 按照变异概率对个体实施量子非门变异.

引理 1^[16] 对于全局最优解中的每一维分量, 在 Bloch 球上有无数个点坐标表示的量子比特与之对应.

定理 1 Bloch 球面坐标编码的量子个体, 在沿 Bloch 球面搜索过程中, 仅需调整转角 θ , 实施纬线搜索即可找到最优解. Bloch 球面纬线搜索示意图如图 2 所示.

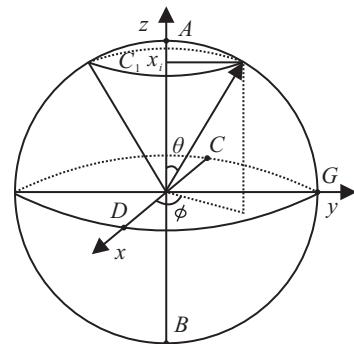


图 2 Bloch 球面纬线搜索示意图

证明 记全局最优解 $X = (X_1, X_2, \dots, X_D)$ 从问题解空间 Ω 映射到 $I^D = [-1, 1]^D$ 后为 $p = (x_1, x_2, \dots, x_D)$. 设当前最优解中的某一维 x_i 对应的 Bloch 球的转角分别为 θ_i 和 ϕ_i , 此时以 $\sin \theta_i$ 为半径, 在 Bloch 球面上做垂直于 z 轴的纬线圆周 C_1 , 其上任意一点坐标为 $(\cos \phi \sin \theta_i, \sin \phi \sin \theta_i, \cos \theta_i)$, 并且 C_1 所有点的 z 坐标都为 x_i .

根据引理 1, 圆周 C_1 上有无数个坐标对应的量子比特与 x_i 对应, 因此沿 Bloch 球作纬线搜索即可完成最优解寻优, 并且最优解 x_i 仅与 θ_i 大小有关, 与 ϕ 无关, ϕ 可增加量子比特多样性. \square

使用 QCS 算法优化 RPNN 的步骤如下.

Step 1: 种群初始化, 设种群规模 M , 最大代数 G 、误差精度 ε 、当前迭代次数 t 、转角 θ 和 ϕ 的初值.

Step 2: 对 RPNN 的模型参数 $w_{ij}^{(l)}, v_j, a_j, b_j, u_j$, 用 Bloch 球面坐标描述量子比特表示, 实施三链结构染色体编码如下:

$$p_i = \begin{bmatrix} \cos \phi_{i1} \sin \theta_{i1} & \cdots & \cos \phi_{iD} \sin \theta_{iD} \\ \sin \phi_{i1} \sin \theta_{i1} & \cdots & \sin \phi_{iD} \sin \theta_{iD} \\ \cos \theta_{i1} & \cdots & \cos \theta_{iD} \end{bmatrix}. \quad (10)$$

其中: $\theta_{ij} = 2\pi \times r, \phi_{ij} = \pi \times r, r \in (0, 1)$ 为随机数, $D = nmL + 3m$. 每条个体包含 3 条基因链, 占据遍历空间中的 3 个位置.

Step 3: 解空间变换. 记个体 p_i 上第 j 个量子位的问题空间为 $[a_j, b_j]$, 则变换后的 3 个可行解为

$$\begin{aligned}
 X_i^j &= \\
 &\frac{b_j(1 + \cos \phi_{ij} \sin \theta_{ij}) + a_j(1 - \cos \phi_{ij} \sin \theta_{ij})}{2}, \\
 Y_i^j &= \\
 &\frac{b_j(1 + \sin \phi_{ij} \sin \theta_{ij}) + a_j(1 - \sin \phi_{ij} \sin \theta_{ij})}{2}, \\
 Z_i^j &= \\
 &\frac{b_j(1 + \cos \theta_{ij}) + a_j(1 - \cos \theta_{ij})}{2}. \quad (11)
 \end{aligned}$$

Step 4: 对每条个体按式(8)倒数分别计算适应度,三链中最大适应度为当前染色体适应度,并记录当代种群最优解,更新全局最优解。

Step 5: 采用量子旋转门^[16]改变每条个体量子相位,向当代种群最优解靠近,更新后的个体为

$$U \begin{bmatrix} \cos \phi_{ij} \sin \theta_{ij} \\ \sin \phi_{ij} \sin \theta_{ij} \\ \cos \theta_{ij} \end{bmatrix} = \begin{bmatrix} \cos(\phi_{ij} + \Delta\phi_{ij}) \sin(\theta_{ij} + \Delta\theta_{ij}) \\ \sin(\phi_{ij} + \Delta\phi_{ij}) \sin(\theta_{ij} + \Delta\theta_{ij}) \\ \cos(\theta_{ij} + \Delta\theta_{ij}) \end{bmatrix}. \quad (12)$$

其中量子旋转门幅角计算使用莱维飞行策略,且根据定理1,QCS 算法按 Bloch 球面纬线搜索时,对于最优解某一维分量 x_i ,只要确定 θ_i 的变化即可。则量子旋转门幅角为

$$\begin{cases} \Delta\theta_{ij}(t+1) = \alpha_0 \frac{\eta \times \mu}{|v|^{1/\beta}} (\theta_{ij}(t) - \theta_{best,j}(t)), \\ \Delta\phi_{ij}(t+1) = \text{rand}(0, 1) \Delta\theta_{ij}(t+1). \end{cases} \quad (13)$$

其中: u, v 服从正态分布, $\beta = 1.5$ 。

Step 6: 根据变异概率 p_m 和随机数 $r_i \in [0, 1]$, 循环判断 $r_i < p_m$, 条件成立则个体被选中。对选中个体再随机选择 $\lceil n/2 \rceil$ 个量子位,通过幅角变换完成变异如下:

$$\Delta\phi = \pi/2 - 2\phi, \Delta\theta = \pi/2 - 2\theta. \quad (14)$$

Step 7: 返回 Step 3 循环计算,直到达到最大进化代数或者满足小于误差精度,训练结束。

4 TOC 预测实例

本部分以 A 区 B 井为例,测井资料包括自然电位 SP、自然伽马 GR、深侧向电阻率 RLLD、密度 DEN、补偿中子 CNL、声波时差 AC。实验对比包括训练和预测两方面,对比模型有:本文所提出的基于梯度下降的脊波过程神经网络 BP-RPNN、基于量子衍生布谷鸟的脊波过程神经网络 QCS-RPNN、正交基展开 PNN(OBPNN)^[5]、用于 TOC 预测的普通 BP 神经网络 BP-ANN^[3]。此外,为说明神经网络预测 TOC 的适用性,与传统 $\Delta \log R$ 法也进行了对比。

4.1 数据样本选取

利用神经网络预测 TOC,测井曲线的选择很重要,首先利用相关性选取对 TOC 变化较为敏感的测井曲线,通过相关性交互图分析,DEN、CNL 和 AC 与 TOC 的相关系数分别为 0.565 2、0.570 6、0.443 9,高于 SP、GR 和 RLLD 与 TOC 的相关性,因此选择 DEN、CNL、AC 作为特征输入。实验共选取 180 组样本,其中 135 组为训练样本,其余 45 组为测试样本。由于每条测井曲线量纲不同,在输入前对每条测井曲线进行归一化。

4.2 仿真实验

根据试探法,确定模型的拓扑结构为 3-7-1,最大迭代步数 MaxGen = 8 000,误差精度 $\varepsilon = 0.005$ 。3 种过程神经网络 QCS-RPNN、BP-RPNN、OBPNN 的正交基函数选用勒让德基函数,基函数项数 $L = 9$ 。此外,OBPNN 和 BP-RPNN 的学习速度 $\alpha = \beta = \gamma = 0.3$, $\lambda = \eta = 0.1$ 。针对 135 组训练样本,4 种神经网络方法各独立进行 20 次实验,对结果数据进行统计,表 1 为训练和预测情况对比。

由表 1 可见,在训练方面:由于梯度下降训练方法的不足,使得 BP-RPNN 与 OBPNN 的训练收敛性较差,20 次模型训练中仅有 50%~60% 的收敛。采用 QCS 算法优化方式的 QCS-RPNN 训练收敛性得到明显提高,达 80% 左右。在预测方面: $\Delta \log R$ 法假定声波和孔隙变化仅由 TOC 引起,与 B 井实际地质情况不

表 1 模型的训练和预测情况对比

模型	训练结果				预测结果			
	最小步数	平均步数	平均时间/s	收敛次数	相关系数	平均绝对误差	平均相对误差	均方根误差
$\Delta \log R$	—	—	—	—	0.737 1	1.680 0	0.275 0	1.282 0
BP-ANN	3 459	4 136	24.492 4	8	0.781 9	1.117 2	0.174 1	1.481 6
OBPNN	5 628	6 134	89.453 8	11	0.829 7	1.012 8	0.164 5	1.324 6
BP-RPNN	6 253	6 772	97.692 5	12	0.845 6	1.004 3	0.148 2	1.039 6
QCS-RPNN	3 804	4 215	164.830 4	17	0.899 9	0.808 4	0.100 7	0.001 1

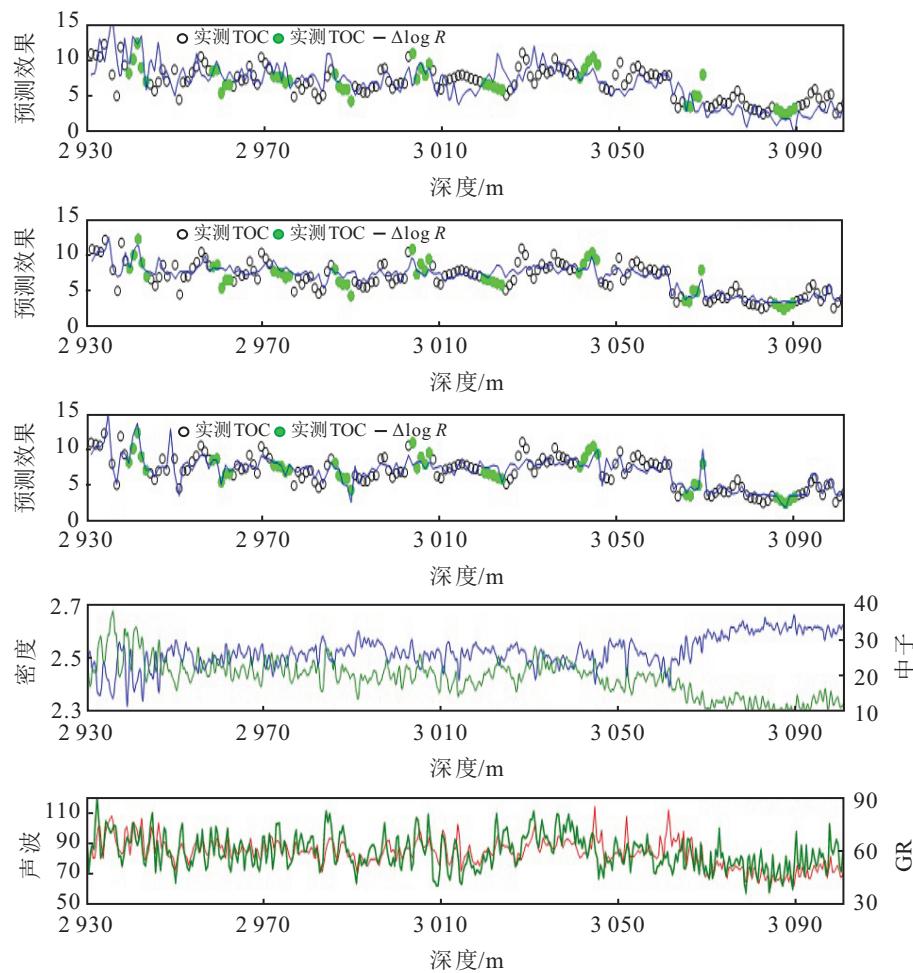


图 3 3 种方法的 TOC 预测效果对比

符(RLLD 与 TOC 的相关系数仅为 0.0192), TOC 预测精度低于 4 种神经网络方法。同时, QCS-RPNN 利用内部时空聚合算子和脊波函数,能够更为有效地处理连续过程、奇异性测井信号,TOC 预测效果最为理想,相关系数比传统的 $\Delta \log R$ 法提高了 16% 左右,比 OBPNN 提高约 7%。图 3 为 QCS-RPNN、OBPNN、 $\Delta \log R$ 预测 TOC 的情况对比,在垂直纵向分布上,QCS-RPNN 更好地体现了 TOC 的整体变化趋势。

4.3 实验分析

4.3.1 TOC 预测精度分析

$\Delta \log R$ 法是假定 TOC 与电阻率、声波之间为线性关系,但 B 井经岩心 TOC 相关性分析发现其电阻率与 TOC 相关性较差, $\Delta \log R$ 法的测井响应线性假定与实际不符,导致预测精度偏低。此时,TOC 与测井曲线之间应属于一种非线性映射关系,选择与其相关性较高的多条测井曲线作为神经网络的特征参数,考虑了多种测井方法对 TOC 的综合响应,因此精度要优于 $\Delta \log R$ 法。

根据测井曲线预测 TOC 属于复杂非线性映射过程,而普通神经网络只能处理同步瞬时输入,无法体

现测井曲线这种连续过程输入信号的时间累积效应,导致 TOC 预测精度偏低。过程神经网络内部具有时空聚合算子,可完成连续测井信号和 TOC 的数据映射,对于测井曲线内部形态特征提取更为准确,减小过程信号映射时的细节丢失。

QCS-RPNN 和 BP-RPNN 中均采用脊波函数作为激励函数,通过调节位置、尺度、方向参数,利用多组脊函数不断叠加,能有效处理测井曲线数据中的直线和超平面奇异性,而 OBPNN 的激励函数为具有全局特性的 Sigmoid 函数,仅对平稳的时变信号有较好的适应性,测井曲线为非平稳的时变信号,此时 OBPNN 具有不适用性。

QCS-RPNN 中通过量子旋转门和量子非门的协同作用完成参数优化,利用莱维飞行计算幅角,易跳出局部极值,可精确捕捉到测井曲线和 TOC 之间的非线性映射关系。BP-RPNN 的梯度下降法训练过程对初值敏感,易陷入局部最小,训练的 RPNN 模型参数很难达到最优,此外初值选取的不合适还易引起模型训练过程的振荡,因此 BP-RPNN 的逼近效率要低于 QCS-RPNN。

4.3.2 学习能力分析

OBPNN、BP-RPNN 和 QCS-RPNN 在训练时需要对测井曲线离散数据进行拟合、函数正交基展开等操作,计算量较大,因此训练时间均长于BP-ANN。其中QCS-RPNN最为耗时,主要由种群进化方式引起。QCS每次迭代时,对多组可行解进行更新变异,而OBPNN和BP-RPNN的梯度下降法只计算一组可行解,所以QCS-RPNN单步计算量要大于OBPNN和SSDPNN,学习时间最长。但QCS-RPNN训练收敛性最高,原因在于QCS算法的量子染色体具有三链结构,扩大了对解空间的搜索范围,同时Bloch球面坐标使得最优解的数量得到了扩充。此外,个体向目标比值逼近时,采用多次短距离探索和偶尔长距离行走的幅角旋转模式,易跳出局部极值。

综上理论分析,QCS-RPNN的逼近效率和训练收敛能力高于BP-RPNN和OBPNN,但学习算法的计算效率最低,较为耗时。根据无免费午餐定理(NFL),QCS-RPNN是通过牺牲计算效率来换取逼近效率的提高。但根据常规测井资料预测TOC属于离线问题,QCS-RPNN训练较为耗时,但并不影响实际应用。

5 结 论

本文为提高TOC预测精度,减小测井曲线信号随深度变化的时间累积误差,提出了一种脊波过程神经网络模型。针对测井曲线的奇异性,内部激励函数使用脊波变换,利用尺度、位置、方向参数的调节,通过脊函数的叠加提高模型非线性映射的逼近效率。在学习算法方面,将RPNN的训练转化为函数优化问题,提出一种量子布谷鸟搜索算法,个体沿Bloch球面纬线搜索,使用量子旋转门更新个体,借助莱维飞行计算旋转门幅角大小。经过对比分析,当电阻率与TOC的线性关系不明显时,QCS-RPNN的TOC预测精度比 $\Delta \log R$ 法提高16%,对泥页岩的TOC预测问题有一定的适用性。

参考文献(References)

- [1] 郝建飞,周灿灿,李霞.页岩气地球物理测井评价综述[J].地球物理学进展,2012,27(4): 1624-1632.
(Hao J F, Zhou C C, Li X. Summary of shale gas evaluation applying geophysical logging[J]. Progress in Geophysics, 2012, 27(4): 1624-1632.)
- [2] Khoshnoodkia M, Mohseni H, Rahmani O, et al. TOC determination of gadvan gor-mation in south pars gas field, using artificial intelligent systems and geochemical data[J]. J of Petroleum Science and Engineering, 2011, 78(1): 119-130.
- [3] Tan M J, Liu Q, Zhang S Y. A dynamic adaptive radial basis function approach for total organic carbon content prediction in organic shale[J]. Geophysics, 2013, 78(6): 445-459.
- [4] Ouafeul S A, Aliouane L. Shale gas reservoirs characterization using neural network[J]. Energy Procedia, 2014, 59: 16-21.
- [5] Li P C, Wang H Y, Dai Q. Quantum process neural networks model algorithm and applications[J]. Acta Physica Sinica, 2012, 61(16): 1-8.
- [6] 李盼池,施光尧.基于数值积分的离散过程神经网络算法及应用[J].系统工程理论与实践,2013,33(12): 3216-3222.
(Li P C, Shi G Y. Numerical integration-based discrete process neural networks algorithm and applications[J]. System Engineering—Theory & Practice, 2013, 33(12): 3216-3222.)
- [7] 肖红,许少华,李盼池.基于数值积分的多聚合过程神经网络算法[J].信息与控制,2013,42(5): 608-612.
(Xiao H, Xu S H, Li P C. Multi-aggregation process neural networks algorithm based on numerical integration[J]. Information and Control, 2013, 42(5): 608-612.)
- [8] 王兵,许少华.基于半监督竞争学习过程神经网络的抽油机故障诊断[J].信息与控制,2014,43(2): 235-240.
(Wang B, Xu S H. Fault diagnosis of pumping unit based on semisupervised competitive learning process neural network[J]. Information and Control, 2014, 43(2): 235-240.)
- [9] He X G, Xu S H. Process neural networks[M]. Hangzhou: Zhejiang University Press, 2009: 52-53.
- [10] Li H A. Image edge detection based on complex ridgelet transform[J]. J of Information & Computational Science, 2015, 12(1): 31-39.
- [11] Saudagar A K J, Syed A S. Image compression approach with ridgelet transformation using modified neuro modeling for biomedical images[J]. Neural Computing & Applications, 2014, 24(7/8): 1725-1734.
- [12] Martias C. On the subexponentiality of the ridgelet transform[J]. Comptes Rendus Mathematique, 2014, 352(12): 1029-1031.
- [13] Yang S, Wang M, Jiao L. Approximation of functions with spatial inhomogeneity based on true orthoridgelet neural network[J]. Applied Soft Computing, 2011, 11(2): 2444-2451.
- [14] Yang X S, Deb S. Cuckoo search via levy flights[C]. Proc of the World Congress on Nature & Biologically Inspired Computing. Coimbatore: IEEE, 2009: 210-214.
- [15] Yang X S, Deb S. Multi-objective cuckoo search for design optimization[J]. Computers & Operations Research, 2013, 40(6): 1616-1624.
- [16] Li P C, Li S Y. Quantuminspired evolutionary algorithm for continuous spaces optimization based on bloch coordinates of qubits[J]. Neurocomputing, 2008, 72(1-3): 581-591.

(责任编辑:郑晓蕾)