

基于再生神经网络的断层面模型重构

施云惠^{1),2)} 阮秋琦²⁾

¹⁾(北京工业大学计算机学院,北京 100022) ²⁾(北京交通大学信息科学研究所,北京 100044)

摘要 为了提高勘探精度及采油效率,需要更深入地了解地质构造,因此断层面模型的重构有着重要的意义,为此提出了基于再生神经网络的断层面重构方法。再生核源于不同学科分支,目前已成为函数逼近的重要工具。将再生核与神经网络有机地结合起来,提出一种新型的神经网络——再生核神经网络,且将网络的训练归结为求解线性方程组问题,为了建立既具有足够精度又能表现系统行为的简单模型,考虑线性方程组的稀疏解是必要的,稀疏解就是具有大量零元素的近似解。虽然稀疏解整体误差较小,但可能在一些点上的误差较大,为此提出对稀疏解的误差修正方法。将再生核神经网络应用于大庆地区的断层面模型重构,实验结果表明,本文重构的断层面与传统方法重构的断层面相比,更符合大庆地区的地质情况。

关键词 再生核 断层面重构 稀疏解

中图分类号: TP391 **文献标识码**: A **文章编号**: 1006-8961(2005)06-0721-04

Reconstruction of Fault Surface Models Based on Reproducing Kernel Neural Network

SHI Yun-hui^{1),2)}, RUAN Qiu-qi²⁾

¹⁾(College of Computer Science, Beijing University of Technology, Beijing 100022)

²⁾(Institute of Information Science, Beijing Jiaotong University, Beijing 100044)

Abstract In order to improve the accuracy of prospecting and efficiency of oil extraction, it is necessary to understand the geological construction deeply. Therefore, the reconstruction of fault surface models is highly important. A method for fault surface models reconstruction is proposed in this paper. Reproducing kernel developed in different disciplines has become an important tool in functional approximation. By combining the reproducing kernel and neural network, a new kind of neural networks, i. e. the reproducing kernel neural network (RKNN) has been initiated. Besides, learning of the network is converted into seeking the solution of the linear equations system. It is essential to consider the sparse solution so as to construct a simple model with sufficient accuracy and represent the system behavior. The sparse solution is an approximating solution with a large part of components as zero. Although the over all error is small, errors of some points may be very big. The error correction of the sparse solution is also discussed. The reconstruction of fault surface models based on the reproducing kernel neural network is implemented in Daqing, and the experimental results show that the reconstructed fault surfaces based on the method presented in this paper is more suitable for the geological situation in Daqing compared with traditional method.

Keywords reproducing kernel, fault surface reconstruction, sparse solution

1 引言

由于多年开采,我国的石油工业开采成本逐年增高。为了提高勘探精度、采油效率,需要更深入地了解地质构造,因此,地质构造的重构有着重要的意义。

地壳每时每刻都在不断地变化和发展,当地球上某地区受到外力作用时,该地区的岩石通常会发生位移和变形,除发生褶皱变动外,还伴有断裂和错位现象,并且沿着断裂面,两侧岩石发生明显位移,形成断层。岩层发生相对位移时,总是沿着一个破碎面进行的,这个岩石断裂错开的面称为断层面^[1]。断层面

收稿日期:2003-09-12;改回日期:2004-12-30

第一作者简介:施云惠(1966~),女,副教授。2002年于哈尔滨工业大学获导航、制导与控制专业博士学位,现为北京交通大学信息科学研究所在职博士后。主要研究方向为图像处理、视频编码。已发表论文10篇。E-mail:syhzmbj@bjut.edu.cn

可以是平坦的,也可以是波形起伏的,可以是直立的,也可以是倾斜的。大庆地区的断层面基本是平整的、连续的、倾斜的,即使有起伏也不会是明显的起伏,因此所重构的断层面必须与实际相符合。

以往确定钻井位置,基本是依据测井资料综合解释,测井资料综合解释就是按照预定的地质任务,选择合适的测井方法组成测井系列,根据有关的地质、钻井及油田开发等方面的资料对得到的一系列曲线、数据进行综合分析、计算,以研究油田油层划分、对比,对油、水、气进行研究、评价。测井资料综合解释在大庆油田的实际应用中取得到了一定成效,然而油田的构造特点和油气藏类型、油田各个时代地层的分布等特性是极其复杂的,仅仅依靠测井资料综合解释是不够的,需要更全面直观地了解地质构造,为了精确地确定打井位置,提高采油效率,断层面的重构是有着重要的意义的。

再生核源于不同的数学分支,直到 20 世纪 50 年代, Aronszajn 提出再生核的一般理论,再生核理论才逐步成熟起来,再生核已成为函数逼近的重要工具^[2]。本文将再生核与神经网络^[3-5]有机地结合起来,构造了一种新型的神经网络——再生核神经网络,并将网络的训练归结为求解线性方程组,为了建立既具有足够精度又能表现系统行为的简单模型,考虑线性方程组解的稀疏性是必要的,为此提出一种稀疏解算法,稀疏解就是具有大量零元素的近似解,这样使得不降低模型精度的前提下,得到简单的神经网络模型,稀疏解的误差分布是不均匀的,进而又提出了一种降低最大误差方法对稀疏解进行修正,最后将再生核神经网络应用于断层面的重构。

2 再生核神经网络及其训练算法

再生核空间 W 定义如下:

$$W = W(\Omega) = \{u(x, y) \mid u(x, y) \text{ 是 } \Omega = [a, b] \times [c, d] \text{ 的全连续函数, } \frac{\partial u}{\partial x}, \frac{\partial u}{\partial y}, \frac{\partial^2 u}{\partial x \partial y} \in L^2(\Omega)\}$$

其中, W 空间的内积和范数为

$$(u, v) = \iint_a^b \int_c^d \left[u(x, y)v(x, y) + \frac{\partial u}{\partial x} \frac{\partial v}{\partial x} + \frac{\partial u}{\partial y} \frac{\partial v}{\partial y} + \frac{\partial^2 u}{\partial x \partial y} \frac{\partial^2 v}{\partial x \partial y} \right] dx dy \quad (1)$$

$$\|u\|^2 = (u, u)_w \quad (2)$$

这里 $u, v \in W$ 。

W 空间的再生核为

$$R(s, z, x, y) = K(s, x)K(z, y)$$

其中, $K(s, x) = \frac{1}{2 \sinh(b-a)} [\cosh(s+x-a-b) + \cosh(|s-x|+a-b)]$ 。若 $\{x_j, y_j\}_{j=1}^{\infty}$ 是 Ω 上稠密的互异点集, 定义 $\varphi_j(x, y) = R(x_j, y_j, x, y)$, 则 $\{\varphi_j\}_{j=1}^{\infty}$ 是线性无关的, 且 $\{\varphi_j\}_{j=1}^{\infty}$ 是 W 空间的完全系。对 $\{\varphi_j\}_{j=1}^{\infty}$ 进行 Schmidt 正交化得到 $\{\varphi_j^*\}_{j=1}^{\infty}$, 那么 $\{\varphi_j^*\}_{j=1}^{\infty}$ 是 W 空间的标准正交基。对于 $f \in W$ 有如下展开:

$$f = \sum_{j=1}^{\infty} (f, \varphi_j^*) \varphi_j^* \quad (3)$$

由于 $\{\varphi_j^*\}_{j=1}^{\infty}$ 是由 $\{\varphi_j\}_{j=1}^{\infty}$ 经正交化得到的, φ_j^* 是 $\{\varphi_j\}_{j=1}^{\infty}$ 的线性组合。又根据式(3), 构造再生核神经网络如下:

$$\hat{f}^*(x, y) = \sum_{j=1}^m u_j \varphi_j(x, y) \quad (4)$$

将输入样本 $(\bar{x}_1, \bar{y}_1), (\bar{x}_2, \bar{y}_2), \dots, (\bar{x}_p, \bar{y}_p)$ 和输出样本 $\bar{z}_1, \bar{z}_2, \dots, \bar{z}_p$ 代入式(4), 得到如下方程

$$\bar{z}_i = \sum_{j=1}^m u_j \varphi_j(\bar{x}_i, \bar{y}_i) \quad i = 1, \dots, p \quad (5)$$

不妨将上式记为

$$Au = b \quad (6)$$

其中, $m \gg p$, $\varphi_j(x, y) = R(x_j, y_j, x, y)$, 以下将介绍选取集合 $\{(x_j, y_j)_{j=1}^m\}$ 的方法。首先确定区域 $[a, b] \times [c, d]$, 取 $a = \min_{1 \leq i \leq p} \{\bar{x}_i\}$, $b = \max_{1 \leq i \leq p} \{\bar{x}_i\}$, $c = \min_{1 \leq i \leq p} \{\bar{y}_i\}$, $d = \max_{1 \leq i \leq p} \{\bar{y}_i\}$, 即用矩形区域 $[a, b] \times [c, d]$ 将断层面的区域包围, 然后将区域 $[a, b] \times [c, d]$ 等距剖分生成 400 个点, 构成点集 $\{(x_j, y_j)\}_{j=1}^{400}$, 定义 $\{(x_j, y_j)\}_{j=1}^m = \{(x_j, y_j)\}_{j=1}^{400} \cup \{(\bar{x}_i, \bar{y}_i)\}_{i=1}^p$, 其中, $m = p + 400$ 。 $\{(x_j, y_j)_{j=1}^m\}$ 包含输入样本的目的是为了提高网络的收敛速度。

这样就将再生核神经网络的训练问题归结为求解线性方程组的解, 首先用投影算法给出方程的稀疏解 u , (即解 u 中的非零分量的个数少, 并且具有尽可能高的逼近精度, 其中 s 为维数), u , 虽然可使总体误差较小, 但可能使个别点的误差过大, 为此提出一种降低最大误差的直接修正法, 即对稀疏解进行修正。

(1) 投影过程

用投影算法给出方程组的稀疏解, 首先将 A 的各列 A_j 进行标准化: $\bar{A}_j = A_j / \|A_j\|$, 在 \bar{A}_j 中选取与 b 角度最小的向量, 不妨设为 a_1 , 然后将 b 在 a_1 上投

影,设投影余量 $\mathbf{b}_R^{(1)} = \mathbf{b}$,

$$\mathbf{b}_R^{(2)} = \mathbf{b}_R^{(1)} - (\mathbf{a}_1, \mathbf{b}) \mathbf{a}_1 \quad (7)$$

在 \bar{A}_j 中选取与剩余向量 $R\mathbf{b}^{(2)}$ 角度最小的向量 \mathbf{a}_2 ,

$$\mathbf{b}_R^{(3)} = \mathbf{b}_R^{(2)} - (\mathbf{a}_2, R\mathbf{b}^{(2)}) \mathbf{a}_2 \quad (8)$$

在 \bar{A}_j 中选取与剩余向量 $\mathbf{b}_R^{(3)}$ 角度最小的向量 \mathbf{a}_3 , 这样进行下去, 于是得到迭代公式:

$$\mathbf{b}_R^{(i+1)} = \mathbf{b}_R^{(i)} - (\mathbf{a}_i, R\mathbf{b}^{(i)}) \mathbf{a}_i \quad (9)$$

显然, $R\mathbf{b}^{(i+1)} \perp \mathbf{a}_i$ 。

$$\|\mathbf{b}_R^{(i+1)}\| = \|\mathbf{b}_R^{(i)}\| - |(\mathbf{a}_i, R\mathbf{b}^{(i)})| \quad (10)$$

$$\|\mathbf{b}_R^{(i+1)}\| = \|\mathbf{b}_R^{(i)}\| \sin(\theta_i), 0 \leq \theta_i \leq \pi/2 \quad (11)$$

$$\|\mathbf{b}_R^{(i+1)}\| < \|\mathbf{b}_R^{(i)}\| \quad (12)$$

由此可见, 迭代产生的余量所构成的序列按范数单调下降。这样投影进行下去, 直到 $\|\mathbf{b}_R^{(i)}\| < \varepsilon$, 得到了一个稀疏的近似解 \mathbf{u}_s , 其中, \mathbf{u}_s 是 \mathbf{u} 的非零分量组成的 s 维向量, 相当于方程

$$\mathbf{A}_s \mathbf{u}_s = \mathbf{b} \quad (13)$$

的近似解。

2.2 修正过程

为了便于叙述, 不妨将式(13)看成

$$\mathbf{A} \mathbf{x} = \mathbf{b} \quad (14)$$

$\mathbf{A} = (a_{ij})_{nm}$, $\mathbf{A}^{(i)}$ 表示 \mathbf{A} 的第 i 行向量, $\mathbf{b} = [b_1, b_2, \dots, b_m]$, $\mathbf{x} = [x_1, x_2, \dots, x_n]$, 记

$$r_i(\mathbf{x}) = (\mathbf{A}^{(i)}, \mathbf{x}) - b_i \quad (15)$$

$$d_i^{(0)} = |r_i(\mathbf{x}^{(0)})|, i = 1, 2, \dots, m \quad (16)$$

其中, $\mathbf{x}^{(0)}$ 是初始解, 我们的目的在于降低最大误差 $\max_i \{d_i^{(0)}\}$ 。直接修正法是: 首先对初始解 $\mathbf{x}^{(0)}$ 直接修正, 降低 $\max_i \{d_i^{(0)}\}$, 得到一个新解 $\mathbf{x}^{(1)}$, 再对 $\mathbf{x}^{(1)}$ 直接修正, 降低 $\max_i \{d_i^{(1)}\}$, 得到一个新解 $\mathbf{x}^{(2)}$, 这样继续下去, 直到误差不再下降为止。算法推导如下:

$$d_k^{(0)} = \max_i \{d_i^{(0)}\} \quad (17)$$

记 $\mathbf{x}^{(1)} = \mathbf{x}^{(0)} + \Delta \mathbf{x}$, 其中, $\Delta \mathbf{x}$ 为修正量, 为了降低 $d_k^{(0)}$, 关键是如何选取 $\Delta \mathbf{x}$, 为此首先给出一个定理。

定理 1 按如下条件

$$(1) \operatorname{sgn}(\mathbf{A}^{(k)}, \Delta \mathbf{x}) = -\operatorname{sgn} r_k(\mathbf{x}^{(0)})$$

$$(2) |(\mathbf{A}^{(k)}, \Delta \mathbf{x})| \leq d_k^{(0)}$$

$$(3) |(\mathbf{A}^{(i)}, \Delta \mathbf{x})| \leq d_k^{(0)} - d_i^{(0)}, i \neq k$$

选取修正量 $\Delta \mathbf{x}$, 而以 $\mathbf{x}^{(1)} = \mathbf{x}^{(0)} + \Delta \mathbf{x}$ 作为方程组的新解时, 能使

$$d_i^{(1)} < d_k^{(0)}, i = 1, 2, \dots, m \quad (18)$$

证明

$$d_i^{(1)} = |r_i(\mathbf{x}^{(1)})| = |(\mathbf{A}^{(i)}, \mathbf{x}^{(1)}) - b_i|$$

$$= |(\mathbf{A}^{(i)}, \mathbf{x}^{(0)} + \Delta \mathbf{x}) - b_i| \quad (19)$$

即

$$d_i^{(1)} = |r_i(\mathbf{x}^{(0)}) + (\mathbf{A}^{(i)}, \Delta \mathbf{x})| \quad (20)$$

显然当 $i = k$ 时, 只要 $\Delta \mathbf{x}$ 满足条件 1、2 就有

$$d_k^{(1)} < d_k^{(0)} \quad (21)$$

当 $i \neq k$ 时, 只要 $\Delta \mathbf{x}$ 满足条件 3, 就有

$$d_i^{(1)} < d_k^{(0)} \quad (22)$$

证明完毕。

修正过程的最关键问题是如何确定 $\Delta \mathbf{x}$, 因为 $\mathbf{A}^{(k)} \neq \mathbf{0}$, 不妨设 $a_{kj} \neq 0$, 则令 $\Delta \mathbf{x} = \delta \mathbf{e}_j$, 其中, \mathbf{e}_j 是第 j 个分量为 1 的 n 维单位向量。 δ 为修正系数, 这样

$$d_i^{(1)} = |r_i(\mathbf{x}^{(0)}) + \delta a_{ij}|, i = 1, 2, \dots, m \quad (23)$$

定理 1 中的 3 个条件可转化为关于 δ 的 3 个条件, 即

$$(1) \operatorname{sgn}(\delta a_{kj}) = -\operatorname{sgn} r_k(\mathbf{x}^{(0)})$$

$$(2) |\delta a_{kj}| \leq d_k^{(0)}$$

$$(3) \delta a_{kj} \leq d_k^{(0)} - d_i^{(0)}, i \neq k$$

由于确定了 a_{kj} , a_{kj} 的绝对值和符号就是已知的, 根据转化后的条件 1 可确定 δ 的符号, 根据转化后的条件 2、3 确定 δ 的绝对值, 即选择满足转化后的条件 2、3 的 δ 绝对值的最小值。从而选定一个 $\Delta \mathbf{x}$, 得到方程组的一组新解 $\mathbf{x}^{(1)}$, 这样, 就得到了一个解序列 $\mathbf{x}^{(0)}, \mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(k)}, \dots$, 每次修正都使最大误差下降, 最大误差的个数增多, 但只要最大误差点的个数不超过 n , 上述修正过程就可以继续下去。实际编程中, 设置一个最大修正次数 $\maxtime = 100$ 来控制迭代次数, 用稀疏解 \mathbf{u}_s 作为修正过程的初值, 具体的修正过程如下:

将 \mathbf{u}_s 作为下面迭代的初始解 \mathbf{x}

$$time = 1, \maxtime, time++$$

$$\{d_i = |r_i(\mathbf{x})|\}$$

$$d_k = \max_i \{d_i\}$$

选取 a_{kj} , 确定 δ 的绝对值和 δ 的符号

$$\mathbf{x} = \mathbf{x} + \delta \mathbf{e}_j$$

3 断层面重构

数据源于大庆油田测井资料, 大庆地区的断层面基本是平整的、连续的、倾斜的, 没有明显的起伏, 因此所重构的断层面必须与大庆地区的断层面实际相符合。为了验证本文方法的有效性, 给出了比较算法, 即对于大庆油田同一断层面, 应用本文方法和传统方法分别进行重构。

我们知道,断层面的重构就是根据从测井资料中获取的断层面上断点的信息,将断层面构造出来,断点是 3 维散列数据: $P_i = (\bar{x}_i, \bar{y}_i, \bar{z}_i)$ ($i = 1, 2, \dots, M$), M 表示数据点的个数), (\bar{x}_i, \bar{y}_i) ($i = 1, 2, \dots, M$) 是不规则分布的。断层面的重构就是基于 3 维散列数据曲面构造的问题。基于 3 维散列数据传统的曲面构造通常采用样条插值,样条插值需要对数据分布区域进行矩形剖分,使得数据点尽量落在剖分的网格线上,由于断层面数据分布区域 (\bar{x}_i, \bar{y}_i) ($i = 1, 2, \dots, M$) 是不规则的,这就给样条插值的实施带来

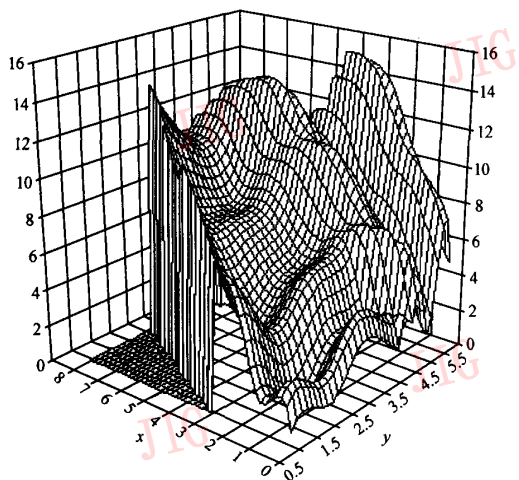


图 1 基于样条插值的断层面重构

Fig. 1 The fault surface reconstruction based on spline interpolation

了困难,显然,应用样条插值算法对于同样的数据,不同剖分得到的曲面形状相差很大。图 1 是利用样条插值对断层面重构的结果(单位为 100s),很显然重构的断层面出现了明显的凹凸现象,曲面的趋势与实际不符。图 2 是基于再生神经网络的断层面重构结果(单位为 100m),这种方法不仅摆脱了由数据不规则分布引起的数据分布区域剖分的问题,而且重构的断层面是平整的、连续的、倾斜的,没有明显的凹凸现象,与大庆地区的地质情况相符合。




图 2 基于再生神经网络的断层面重构

Fig. 2 The fault surface reconstruction based on the reproducing kernel neural network

4 结 论

本文提出了再生神经网络,并给出了相应的训练算法:稀疏解算法,稀疏解使得在满足精度的前提下,得到简单的神经网络模型,稀疏解的误差在边界断点处比其他断点处大,对稀疏解的修正降低了边界断点处的误差,使得断点处的误差均匀分布,与传统的相比,用本文提出的方法对断层面重构,得到断层面与地质情况相符合。此外,本文提出的断层面模型重构的算法本质上是 3 维不规则区域散列数据的曲面重构,传统 3 维不规则区域散列数据的曲面重构方法需要进行区域剖分,而不同的剖分规则,产生不同的曲面,本文算法不需要区域剖分,为曲面重构提供了一个崭新的手段。

参考文献 (References)

- 1 Zeng Wen-chong. Well logging evaluation technique for oil gas preservation reservoir[M]. Beijing:Petroleum Industry Press, 1991: 20 ~ 40. [增文冲. 油气藏储集层测井评价技术[M]. 北京:石油工业出版社,1991:20 ~ 40.]
- 2 Wen Song-long, Cui Ming-gen. On the best operator interpolation in W [J]. *Mathematica Numerica Sinica*, 1997, 19(2): 177 ~ 184. [文松龙, 崔明根. W 空间最佳插值逼近算子[J]. 计算数学, 1997, 19(2): 177 ~ 184.]
- 3 Shin Suzuki. Constructive function-approximation by three artificial neural[J]. *Neural Networks*, 1998, 11: 1049 ~ 1058.
- 4 Ning Qian. On the momentum term in gradient descent learning algorithms[J]. *Neural Networks*, 1999, 12: 145 ~ 151.
- 5 Gomm J B, Yu D L. Selecting radial basis function network centers with recursive orthogonal least squares training [J]. *IEEE Transactions on Neural Networks*, 2000, 11(2): 306 ~ 313.