

基于自组织映射神经网络的市场清算电价预测

曾次玲¹, 张步涵¹, 谢培元²

(1. 华中科技大学电气与电子工程学院, 湖北 武汉 430074; 2. 湖南省电力调度通信中心, 湖南 长沙 410007)

摘要: 市场清算电价预测是电力市场中交易决策的基础。人工神经网络是电价预测较为理想的方法,但依然存在一些问题,如样本训练有时需要很长时间,存在收敛问题,特别是当样本特征量不明显的时候,这种现象更为突出。针对这一问题,利用自组织映射的聚类特性将历史数据进行特征分类和筛选处理,处理后形成的新数据用于训练三层BP神经网络,仿真结果表明,经过这种数据处理后,网络的收敛速度得到了显著提高,且预测效果良好。

关键词: 电力市场; 电价预测; BP神经网络; 自组织映射神经网络

中图分类号: TM73; F123.9 **文献标识码:** A **文章编号:** 1003-4897(2005)13-0039-05

0 引言

人工智能方法在电力负荷预测等很多方面得到了广泛的应用,并取得了很好的成果。因电价预测与负荷预测存在一些相似之处^[1],近年来它在电价预测方面的应用也有不少论文发表,如应用最广的神经网络预测电价^[2~8]。预测的基本思路主要是利用历史的负荷和清算电价数据来预测未来电价。但预测效果并不理想,特别是在节假日和高峰负荷时段,预测误差非常大。主要存在两方面的原因:神经网络方法建网无现成规律,样本训练有时需要很长时间,存在收敛问题,特别是当样本特征量不明显的时候。市场中参与者对电价的操纵行为很难捕捉,缺乏数据支持。

针对以上的第一个问题,本文利用自组织映射的聚类特性将历史数据进行筛选和分类处理,处理后形成的新数据用于训练三层BP神经网络,仿真结果表明,经过处理后的网络的训练速度得到了显著提高,且预测效果良好。对第二个问题,我们将在另文中详细阐述其解决方法。

1 自组织映射神经网络模型与算法

所谓自组织现象是指:人脑在许多区域是有组织的,不同的区域的作用各不相同,不同的感官输入被传递给不同位置的脑细胞群,并且这种神经元所具有的特性并不是完全来自生物遗传,而是在很大程度上依赖于后天的学习过程。基于生物神经元这一特性,芬兰学者 Kohonen 于 1982 年提出了自组织映射网络或称为自组织特征映射网络 (Self-organizing Map, SOM)。

1.1 自组织映射网络模型

自组织映射网络模型具备这样的特点:输入节点和输出神经元的连接权值互联;在输出神经元之间进行竞争选择,输出神经元之间存在侧抑制。从功能上来说,它能够将单个神经元的变化规则 and 一层神经元的群体变化规则联系在一起。

从网络结构上来说,自组织映射网络的最大特点是神经元被放置在一维、二维或更高维的网格节点上。图 1 所示为使用最为普遍的二维网络模型。该模型包含输入输出两层,而不包含隐含层。在输入层中有 N 个输入节点,其中任一输入节点用 j 表示。输入层接受输入向量 $X = [x_1, x_2, \dots, x_N]^T$ 。从空间的角度看,该输入空间是 N 维的,输入节点通过权值 w_{ij} ($i=1, 2, \dots, M; j=1, 2, \dots, N$) 和网络的 M 个神经元相连。将权值根据相连的神经元划分为 M 个权向量,任一权值向量为 $W_i = [w_{i1}, w_{i2}, \dots, w_{iN}]^T$ ($i=1, 2, \dots, M$)。在输出层分布着网络的 M 个神经元,其中任一神经元用 i 表示,其输入为 $u_i = \sum_{j=1}^N w_{ij}x_j$, 输出为 $v_i = f(u_i)$, 其中 f 为神经元激励函数,一般取为线性函数。

值得注意的是,神经元分布在二维的网格上。从某种意义上说,二维的网格就是自组织映射的输出空间。而自组织映射网络正是通过引入网格,在神经元之间建立了拓扑关系,神经元之间的联系是由它们在网格上的相互位置所决定的,并且这种联系模拟了人脑中的神经元之间的侧抑制功能,是网络实现竞争的基础。这种对侧抑制的模拟通过定义一个获胜神经元的拓扑邻域来实现。

1.2 自组织映射学习算法

自组织映射学习算法属于无监督竞争学习算

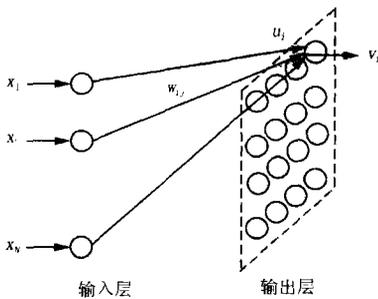


图 1 具有二维网格的自组织映射网络模型

Fig 1 SOM network with grid of two dimensions grid

法。自组织映射网络可以将任一维数的输入模式以拓扑有序的方式变换到一维或是二维的离散空间上,这种变换称为特征映射,表示为:输入空间 H 输出空间 A 。其中,输入空间 H 是输入向量的集合,其维数等于输入向量的维数;输出空间 A 在二维网格的自组织映射中是二维的平面。

自组织映射学习算法包含:竞争、合作和更新三个过程^[9]。

1) 竞争过程中,确定输出最大的神经元为获胜神经元。由于神经元的激励函数为线性函数,神经元的输出最大取决于其输入 $u_i = \sum_{j=1}^N w_{ij}x_j$, 即输入向量 $X = [x_1, x_2, \dots, x_N]^T$ 和权值向量 $W_i = [w_{i1}, w_{i2}, \dots, w_{iN}]^T$ ($i = 1, 2, \dots, M$) 的内积。而该内积在输入向量和权值向量均为归一化向量时,等价于输入向量和权值向量的欧氏距离最小。所以当输入向量为 X 且第 c 个神经元获胜时,满足条件:

$$X - W_c = \min_i X - W_i, \quad i = 1, 2, \dots, M \quad (1)$$

其中: \cdot 表示求输入向量 X 和权值向量 W_i 的欧氏距离。

2) 在合作过程中,确定获胜神经元的加强中心。拓扑邻域的中心就是在竞争过程中得到的获胜神经元,在邻域范围内的神经元称为兴奋神经元,即加强中心。在此,可采用简单的正方形的邻域形状。邻域在网格上表现如图 2。

当邻域半径为 0 时,邻域仅仅包含获胜神经元;而半径为 1 时,邻域包含除了获胜神经元之外的 8 个邻近神经元。当半径增大时,邻域依此规律放大。在此将拓扑邻域记为 $N_c(n)$, 同时也表示在第 n 次迭代时,拓扑邻域的半径。它的值随着迭代次数的增加而变化,其更改采用式 (2):

$$N_c(n) = NT(N_c(0)(1 - n/N)), \quad n = 0, 1, 2, \dots, N \quad (2)$$

其中: $N_c(0)$ 表示初始的拓扑邻域半径; N 为总的迭代次数, $NT()$ 表示取整数。

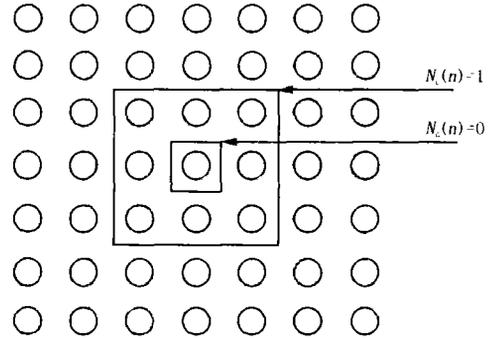


图 2 二维网格上的拓扑邻域

Fig 2 Neighboring area of topology in two dimensions grid

可以看出,拓扑邻域随着迭代次数的增加是不断收缩的。在网格上具体表现如图 3, 其中 $N_c(k_1)$ 、 $N_c(k_2)$ 和 $N_c(k_3)$ 代表当迭代次数为 k_1 、 k_2 和 k_3 ($k_1 < k_2 < k_3$) 时获胜神经元的拓扑邻域。

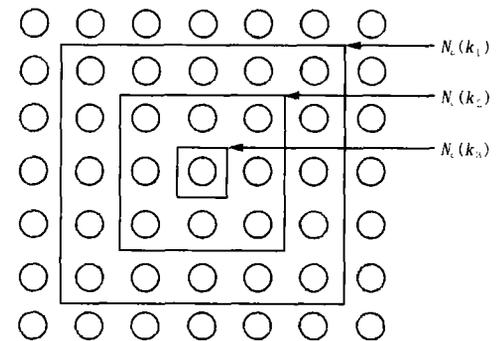


图 3 二维网格上邻域的变化情况

Fig 3 Movement of neighboring area in two dimensions grid

3) 在更新过程中,采用 Hebb 学习规则的改变形式,对网格上获胜神经元拓扑邻域内的神经元进行权值向量的更新。

$$W_j(n+1) = W_j(n) + \eta(n)(X - W_j(n)), \quad n = 0, 1, 2, \dots, N \quad (3)$$

其中: $\eta(n)$ 为学习速度 ($0 < \eta(n) < 1$), 随迭代次数的增加而减小,变化的规则可以采用式 (4):

$$\eta(n) = \eta(0) \left(1 - \frac{n}{N}\right), \quad n = 0, 1, 2, \dots, N \quad (4)$$

式中: N 为总迭代步数; $\eta(0)$ 为初始学习速率。

自组织映射学习算法的具体步骤如下。

第一步 设置变量和参数:

$X(n) = [x_1(n), x_2(n), \dots, x_N(n)]^T$ 为输入向量,或称为训练样本。

$W_i(n) = [w_{i1}(n), w_{i2}(n), \dots, w_{iN}(n)]^T$ 为权值向量, $i = 1, 2, \dots, M$ 。

设置迭代总次数为 N 。

第二步 初始化:将权值向量 w_i 用小的随机值进行初始化;设置初始学习速率 $\eta(0)$;对权值向量初始值 $w_i(0)$ 和所有的输入向量 x 进行归一化处理。

$$X = \frac{X}{\|X\|} \quad (5)$$

$$w_i(0) = \frac{w_i(0)}{\|w_i(0)\|} \quad (6)$$

其中: $w_i(0) = \sum_{j=1}^N [w_{ij}(0)]^2$, $X = \sum_{j=1}^N (x_j)^2$, 分别是权值向量和输入向量的欧氏范数。

第三步 采用:从输入空间中选取训练样本 x 。

第四步 近似匹配:根据式(1),通过欧氏距离最小的标准来选取获胜神经元 c ,从而实现了神经元的竞争过程。

第五步 更新:对获胜神经元拓扑邻域内的兴奋神经元,参照式(3),以 Hebb 学习规则更新神经元的权值向量,从而实现了神经元的合作和更新过程。

第六步 根据式(4)和式(2)更新学习速率 $\eta(n)$ 和拓扑邻域 $N_c(n)$ 并对学习后的权值重新进行归一化处理:

$$w_i(n+1) = \frac{w_i(n+1)}{\|w_i(n+1)\|} \quad (7)$$

第七步 判断迭代次数 n 是否超过 N , 如果 $n > N$ 就转到第三步, 否则结束迭代过程。

网络经过以上学习训练后,如果训练充分且算法收敛,则自组织映射网络具有特征映射能力,具有以下几个重要功能:

1) 对输入空间的近似。自组织映射算法的基本目标是寻找较小的原型集来存储一个大的输入集,而这些原型集能够提供对输入空间的良好近似。从分类角度说,自组织映射通过寻找最优参考向量集合来对输入模式进行分类。在此这个原型集就是自组织网络的权值向量,因此特征映射提供了对输入空间的良好近似。

2) 拓扑排序。由自组织映射算法得出的特征映射是拓扑有序的,输出层上神经元的位置相应于输入模式的特别特征和区域。拓扑排序是网络采用的权值改变规则的直接结果。在学习规则的作用下,获胜神经元及其附近神经元的权值向量不断趋向于输入向量。

3) 密度匹配。特征映射反映了输入分布的统

计特征的变化:在输入空间中那些样本以高概率产生的区域在输出空间中被映射到大的区域,因此也就比低概率产生样本的区域具有更好的解。

4) 特征选择。对于来自非线性分布的输入空间的数据,自组织映射可以选择最好的特征集合来近似潜在的分布。在这点上,特征映射具有独特的提取非线性数据的内在特征的功能。

2 电价预测模型

电力市场中电价主要受系统负荷和发电成本(燃料价格)的影响,因此,电价随着负荷的变动而发生相应变化,又由于受到其他多种因素(策略性投标、系统运行状态的不同以及市场外机组调度的不确定性等因素)的影响而具有不定性和波动性。由文献[1]可知:市场清算电价具有明显周期变化的特点,如:一天内的电价变化和一周内的电价变化曲线具有明显的周期性,而且与负荷的涨落基本一致;在一天中的高峰负荷时段,电价波动较大,容易出现尖峰电价。基于以上分析可知,系统的历史清算电价和负荷是最能反映未来电价走势的因素,也是电力市场中最容易获得的信息,本文后续章节主要利用这两方面的数据进行电价预测,市场参与者的行为以及电力系统本身的状况对电价预测的影响将在另文中详述。

2.1 电价预测 BP模型

根据以上分析,在预测下一日市场清算电价 $p(d, t)$ (即神经网络的输出点)的神经网络的输入点的选择中,将考虑以下因素(其中: d 表示日历日; t 表示时段):

1) 历史 MCP:预测时段前一时段的电价 $p(d, t-1)$;预测时段所在日前一日同一时段的电价 $p(d-1, t)$;预测时段所在日前一星期同一时段的电价 $p(d-7, t)$ 。

2) 系统负荷:预测时段所在日的系统实际负荷 $L(d, t)$ (可通过短期负荷预测得到,或对市场公布的预测负荷修正后得到);预测时段前一时段的负荷 $L(d, t-1)$;预测时段所在日前一日同一时段的负荷 $L(d-1, t)$;预测时段所在日前一星期同一时段的负荷 $L(d-7, t)$ 。

考虑以上输入因素,BP神经网络预测模型的结构如图4所示。

2.2 基于 SOM的数据处理过程

电价预测的数据纷繁复杂,要在大量数据中找出有用的样本数据是很不容易的,本节首先利用自

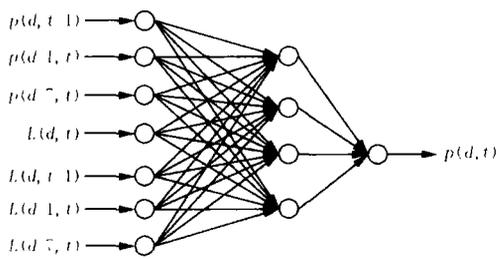


图 4 BP神经网络预测模型结构图

Fig 4 Structure of BP neural network model

组织映射网络具有的特征映射能力,对数据进行特征分类处理,形成新的数据子集,然后再用新的数据训练第三章中提出的BP神经网络。采用澳大利亚昆士兰州电力市场2002年1月20日~2002年12月10日的实际运行数据作为训练数据。预测和数据处理流程图如图5所示。

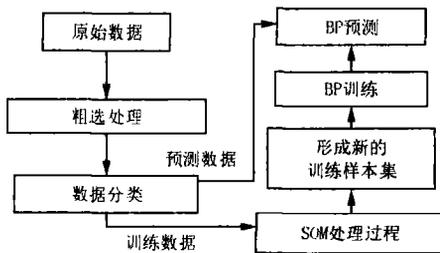


图 5 电价预测流程图

Fig 5 Flow chart of electricity price forecasting

3 仿真分析

采用上述模型对澳大利亚昆士兰州电力市场2002年12月12日(星期六)的清算电价进行预测,预测结果显示:

1) 直接采用BP神经网络预测相对误差达10%以上的时段数为8个时段,而采用SOM进行数据处理后神经网络预测相对误差达10%以上的时段数只有2个时段,可见预测偏差大的时段减少了很多。

2) 在直接采用BP神经网络预测时有5个时段不能很好地收敛,采用SOM处理后的神经网络只有一个时段存在收敛性的问题。

3) 采用SOM处理后的神经网络大大提高了收敛的速度,速度提高了大约55%。

4) 平均百分比误差:直接采用BP神经网络预测时为1.860%;采用SOM处理后为0.94%。

图6给出了采用SOM处理后的BP神经网络与单独采用BP神经网络预测时市场清算电价的预测值和实际值。图6中“price1”是经SOM数据处理后

的预测结果,“price2”是仅用BP神经网络的预测结果。

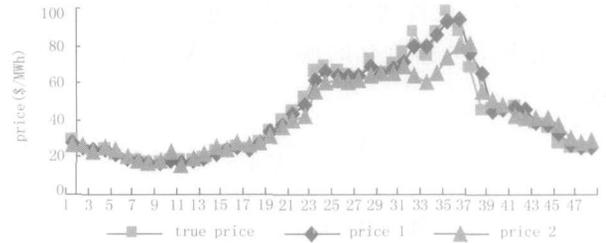


图 6 SOM处理前后的预测结果比较

Fig 6 Comparison of forecasting results based on single BP and SOM-BP

从图6中可以看出,在负荷低谷,不用SOM进行数据处理,BP神经网络的预测结果与实际值相差不大,预测误差小。而在负荷高峰时段,不用SOM进行数据处理,BP神经网络的预测结果与实际值相差很大,预测误差非常大;而采用SOM进行数据处理后,预测误差相对减小了,但在有些点仍然存在比较大的误差,这主要是由于模型中没有考虑市场中的一些人为因素以及电力系统当时的运行状态而造成的。

4 结论

本文基于SOM神经网络的自组织特征,对样本数据进行特征分类与筛选,经处理后的数据再用于BP神经网络进行训练,预测模型简单。对澳大利亚昆士兰州电力市场2002年12月12日的电价进行了预测,预测结果显示使用SOM数据处理后的BP网络的预测效果更加令人满意。但还存在一些问题:一个是对训练参数中的特殊值处理,对预测精度有很大影响;另外,作为无监督学习网络,SOM不能利用导师信号是其缺点。同时对周末的市场清算电价的预测在某些点会出现较大的误差。如何改进模型,在模型中反映出市场参与者对电价的操纵行为以及电力系统的运行状态,提高高峰负荷和节假日电价的预测精度,是下一步的主要工作。

参考文献:

- [1] 周佃民,赖菲,刘亚安,等. 电力系统负荷预测与电价预测[J]. 继电器, 2000, 28(10): 31-33.
ZHOU Dian-min, LAI Fei, LU Ya-an, et al. Electric Power System Load Forecast and Electricity Price Forecast [J]. Relay, 2000, 28(10): 31-33.
- [2] Szkuta B R, Sanabria L A, Dillon T S. Electric Price

- Short-term Forecasting Using Artificial Neural Networks [J]. IEEE Trans on Power Systems, 1999, 14 (3): 851-857.
- [3] GAO Feng, GUAN Xiao-hong, CAO Xi-ren, et al Forecasting Power Market Clearing Price and Quantity Using a Neural Network Method [A]. Proceedings of the IEEE Conference on Power Engineering Society Summer Meeting Washington (USA): 2000. 2183-2188.
- [4] 杨莉, 邱家驹, 江道灼. 基于 BP 网络的下一交易日无约束市场清算电价预测模型 [J]. 电力系统自动化, 2001, 25 (19): 11-14.
- YANG Li, QIU Jia-ju, JIANG Dao-zhuo. BP Based Day-ahead Unconstrained Market Clearing Price Forecasting Model [J]. Automation of Electric Power Systems, 2001, 25 (19): 11-14.
- [5] 黄日星, 康重庆, 夏清. 电力市场中边际电价预测 [J]. 电力系统自动化, 2000, 24 (22): 9-12.
- HUANG Ri-xing, KANG Chong-qing, XIA Qing. Marginal Price Forecasting in Electricity Market [J]. Automation of Electric Power Systems, 2000, 24 (22): 9-12.
- [6] 刘正国, 付祥明, 高伏英, 等. 基于神经网络的浙江发电市场清算电价预测方法 [J]. 电力系统自动化, 2002, 26 (9): 49-52.
- LIU Zheng-guo, FU Xiang-ming, GAO Fu-ying, et al Forecasting Market Clearing Price in Zhejiang Generation Market Using Neural Network [J]. Automation of Electric Power Systems, 2002, 26 (9): 49-52.
- [7] KM Chyang-il, YU In-keun, Song Y H. Prediction of System Marginal Price of Electricity Using Wavelet Transform Analysis [J]. Energy Conversion and Management, 2002, 43 (14): 1839-1851.
- [8] 魏平, 李均利, 陈刚. MCP 预测技术在浙江电力市场中的应用 [J]. 继电器, 2004, 32 (11): 58-61.
- WEI Ping, LI Jun-li, CHEN Gang. Application of MCP Forecasting Method in Zhejiang Electricity Market [J]. Relay, 2004, 32 (11): 58-61.
- [9] Kohonen T. The Self-organizing Map [J]. Proceedings of the IEEE, 1990, 78 (9): 1464-1480.

收稿日期: 2004-10-21; 修回日期: 2005-03-02

作者简介:

曾次玲 (1976 -), 女, 博士研究生, 主要从事电力系统分析和电力市场方面的研究; E-mail: ling-yuan@263.net

张步涵 (1950 -), 男, 教授, 主要从事电力系统分析和电力市场方面的研究;

谢培元 (1975 -), 男, 硕士, 主要从事电力系统调度运行和电力市场方面的研究。

Forecasting market clearing price using self-organizing map neural network

ZENG Ci-ling¹, ZHANG Bu-han¹, XIE Pei-yuan²

(1. Huazhong University of Science and Technology, Wuhan 430074, China; 2. Hunan Electric Power Dispatch & Communication Center, Changsha 410007, China)

Abstract: Forecasting the market-clearing price (MCP) is the most essential task for any decision-making in electricity market. Artificial neural network (ANN) is a preferable forecasting method. However, there still exist some theoretic shortcomings in ANN method, such as the time-consuming sample training and convergence problem. Especially when the characteristic of sample is hard to capture, those phenomena will be more explicit. To solve the problem, based on the characteristic of self-organizing and clustering of self-organizing map (SOM), this paper proposes a method to deal with the sample dataset of the BP model, which can perform a data analysis, and then form a new training dataset. By using the BP network on the new dataset analyzed by SOM for the prediction, the efficiency is advanced remarkably and the prediction is satisfactory.

Key words: power market; price forecasting; BP network; self-organizing map

(上接第 33 页 continued from page 33)

Abstract: The distribution systems are important components owe to connecting high voltage power transmission systems to consumers in electric power system. To improve the framework of distribution systems and the reliability and economic value, this paper presents the allocating method of branch switches in distribution system based on the principle of capacity moment. In addition, experimental results show that the method is effective. It is important for constructing of solid distribution systems and the enhancing of the level of reliable and economic operation in whole power systems.

Key words: power system; capacity moment; distribution system; branch switch