

基于改进 DFNN的短期电价预测新方法

敖磊¹,刘旭东²,吴耀武¹,熊信银¹

(1. 华中科技大学电力系, 湖北 武汉 430074; 2. 湖北省宜昌供电公司, 湖北 宜昌 443003)

摘要: 提出了一种改进的动态模糊神经网络 DFNN (Dynamic Fuzzy Neural Network)的短期电价预测方法。首先对采集到的信息进行特征提取,然后利用模糊粗糙集理论中的信息熵进行属性简化、去掉冗余信息,最后用得到的属性作为动态模糊神经网络 (DFNN)的输入进行训练预测。在模糊神经网络内部引入递归环节,构成了动态模糊神经网络,并采用具有全局寻优能力的遗传算法来训练网络,克服了单纯 BP算法易陷入局部最优解的困境。最后以美国加州电力市场公布的 2000年数据进行了模型训练和预测,结果表明该方法所建立的预测模型具有较高的预测精度。

关键词: 出清电价; 短期电价预测; 动态模糊神经网络 (DFNN)

中图分类号: TM715 **文献标识码:** A **文章编号:** 1003-4897(2006)06-0034-05

0 引言

随着全球电力市场化^[1]大趋势的到来,电力行业逐渐由垄断经营走向竞争,这与国际上电力工业解除政府管制 (deregulation)引入竞争机制的改革浪潮相辉映。这一发展趋势开始于南美和欧洲,目前已经席卷美国。这一变革对电力工业的传统运营模式带来了深刻的影响。在新的模式下建立了区域性的统一电力交易市场,通过市场的拍卖过程确定各相互竞争的电力企业的发电量。我国目前已经有部分省份开始了电力系统市场化运行的试点工作^[2]。

出清电价 (Market Clearing Price)是电力市场中反映电力商品短期供求关系的重要数据。从系统购电方来看,MCP构成了它的单位购电成本,MCP的预测使自身的动态成本控制成为可能;从发电方来看,MCP是它的产品价格,其利润依赖于准确把握短期市场走向,把握市场的关键是对 MCP的准确预测。因此,电价预测就成为电力市场中急待研究和解决的课题。

1 出清电价预测方法概述

最近几年已有一些学者提出了一些适用于电价预测的方法。文 [3]对时间序列法作了比较详细的介绍并将此方法应用于实际算例。文献 [4]提出利用人工神经网络对输入量和输出量之间的非线性关系的强映射能力来建立系统边际电价的预测模型,分别建立了多个 3层和 4层反向传播 (BP)神经网络模型,并以英国 1995年的边际电价数据进行模型的训练和测试,得到的两种模型的预测值的平均绝

对误差较大,与实用化仍有一定距离。文献 [5]提出基于 BP神经网络预测下一交易日系统电价,该神经网络分为两部分:一部分用来预测规律性强的基本系统电价;另一部分用来预测下一交易日与当日同一时段系统电价的差值,两部分神经网络之和即为下一交易日预测时段的系统电价值,但该文献并未给出具体模型和预测精度。

本文将模糊逻辑系统技术与神经网络相结合构成模糊神经网络系统,利用神经网络调整模糊逻辑推理系统的隶属度函数和调整推理规则,利用模糊推理规则的形式构造前向传播结构,从而可以充分发挥各自的特点,实现相互补充。此外,普通的神经网络不具备反馈结构而使应用范围仅限于静态问题,对动态问题控制无效。而实际的短期出清电价预测中,过程的变量是时间的函数,具有动态特性,需要具有动态特性的预测技术。因此,本文在模糊神经网络内部引入递归环节,构成了动态模糊神经网络 DFNN (Dynamic Fuzzy Neural Network),并采用具有全局寻优能力的遗传算法来训练网络,克服了单纯 BP算法易陷入局部最优解的困境。文中把 DFNN与常用 BP及 FUZZY方法进行了比较,仿真结果表明 DFNN在网络结构、学习速度及处理动态问题等方面显示了其优势。

另一方面,模型输入变量的选择对于预测结果的精度影响也很大,这也是短期电价预测系统建模的关键问题,现有文献 [6,7]一般根据经验来选择输入变量,无法体现各输入变量对于输出值影响的重要性程度。为此,本文引入粗糙集 RS (Rough Set)理论中的信息熵计算方法来选择与待预测量相

关性大的参数作为动态模糊神经网络系统 (DFNN) 的输入,充分保证了模型输入参数的合理性,有效地减少了模型的计算工作量,提高了模型的预测精度。

2 粗糙集 (RS)理论和遗传算法简介

2.1 粗糙集 (RS)理论

RS是波兰科学家 Zdzislaw Pawak在 20世纪 80年代初提出的,其特点是不需要预先给定某些属性的数量描述,直接从给定问题的描述集合出发,通过不可分辨关系和不可分辨类确定给定问题的近似域,从而找出该问题中的内在规律,而该理论中的信息熵反映了知识的不确定程度。

在此用 U 表示论域,属性集中的条件属性集合记为 C ,决策属性集合记为 D 。 R_C 、 R_D 分别表示 U 上基于条件属性集合 C 、决策属性集合 D 的等价关系。信息熵就是粗糙集理论中对知识不确定性进行度量的一种指标。其相关概念如下:

定义 1: R_C 在 U 上的子集的概率分布为

$$P([X]) = \frac{|[X]|}{|U|} \quad (1)$$

式中: $[X] \in U/R_C$ 表示 U 的等价类; $|[X]|$ 表示集合 $[X]$ 的“势”,在此可用 $[X]$ 所含元素个数表示。

定义 2: 令

$$H(R_C) = - \sum_{[X]} P([X]) \log P([X]) \quad (2)$$

称 $H(R_C)$ 为知识 R_C 的信息熵。

定义 3:

$$H\left(\frac{R_D}{R_C}\right) = - \sum_{[X]} P([X]) \sum_{[Y]} P\left(\frac{[Y]}{[X]}\right) \log P\left(\frac{[Y]}{[X]}\right) \quad (3)$$

式中: $[Y] \in U/R_D$; $P\left(\frac{[Y]}{[X]}\right) = \frac{|[Y] \cap [X]|}{|[X]|}$; 称 $H\left(\frac{R_D}{R_C}\right)$ 为知识 R_D 相对于知识 R_C 的条件熵。

定义 4: 令

$$I(c_i, D) = [H\left(\frac{R_D}{R_C - c_i}\right) - H\left(\frac{R_D}{R_C}\right)] / H\left(\frac{R_D}{R_C}\right) \quad (4)$$

则称 $I(c_i, D)$ 为属性 c_i 关于决策属性 D 的重要程度,该值越大说明在条件属性 C 中属性 c_i 对决策属性 D 越重要、两者的相关性越大。若 $I(c_i, D) = 0$, 则属性 c_i 是多余的,可从条件属性集合中去掉,属性集 C 简化为 $C - \{c_i\}$ 。

2.2 遗传算法简介

遗传算法 GA (Genetic Algorithm) 是一种基于进化论的全局优化搜索算法。它具有简单、通用和适于并行处理的特点,其应用范围十分广泛。用 GA 优化

求解问题一般包括以下步骤: 对给定的优化问题,设置目标函数; 设置待优化参数的变化区间; 对待优化参数进行二进制 (或实数) 编码; 随机产生初始种群; 计算种群中每个个体的适应度,并进行评价; 对待优化参数父代个体进行交叉; 对待优化参数子代个体进行变异; 回到 ~ 反复进行迭代,直到满足特定指标或一定遗传代数为止。

3 基于 RS 和 GA 的动态模糊神经网络 (DFNN) 短期电价预测模型

3.1 模型输入参数的确定

可以用上面介绍的信息熵方法对 DFNN 输入参数进行选择,具体步骤如下: (1) 建立关系数据表模型。将各个可能的输入参数视为条件属性,则条件属性集合为 $C = \{c_1, c_2, \dots, c_m\}$; 将待预测电价 y 视为决策属性,则决策属性集合为 $D = \{y\}$ 。

(2) 属性值特征化确定等价关系。为了能从观测数据中分析出知识间的依赖性和属性的重要性,需要利用属性对论域进行分类,而分类的基础是属性值特征化,即对每个属性的属性值进行离散化处理,属性值特征化后便可建立知识系统。

(3) 输入参数的确定。由式 (4) 计算属性集 C 中各属性关于待预测指标 y 的重要程度,删除输入属性集 C 中 $I(c_i, D) = 0$ 的第 i 个属性,将其余的属性依照 $I(c_i, D)$ 值的大小排列,设置重要性阈值 t_0 ,取大于阈值的属性为 DFNN 的输入参数。

3.2 DFNN 结构

模糊神经网络^[8]是利用神经网络调整模糊逻辑推理系统的隶属度函数和调整推理规则,利用模糊推理规则的形式构造前向传播结构 (即将经验融入到神经网络初始结构和权值的选择上),从而可以充分发挥各自的特点,实现相互补充。现存的神经模糊网络的主要缺点是大都不具备反馈结构而使应用范围限于静态问题,对暂态问题控制无效。对于实际的生产过程来说,对象常常具有动态特性,过程的变量是时间的函数,因此,研究具有动态特性的模糊神经网络具有更为实际的意义。本文在模糊神经网络内部引入递归环节,构成了动态模糊神经网络 (DFNN),并采用具有全局寻优能力的遗传算法来训练网络。DFNN 的各个参数具有明确的物理意义,可以根据上节计算出的输入参数及对应的出清电价历史数据对 DFNN 网络进行有导师学习,完成模糊系统的参数辨识任务,它是一个动态映射网络,比普通模糊神经网络 (FNN) 更适于描述动态系统。

动态模糊神经网络的拓扑结构动态模糊神经网络的拓扑结构如图 1 所示,它由 5 部分组成:输入层 L_1 ;模糊化层 L_2 ;规则层 L_3 ;归一化层 L_4 和输出层 L_5 。在第二层 L_2 引入了递归神经元,由于递归神经元有内部反馈连接,可以捕获系统的动态响应,能简化网络模型。以下的描述中, u_i^s 表示第 s 层的第 i 个节点的输入, O_i^s 表示第 s 层的第 i 个节点的输出, s 为网络的层数。

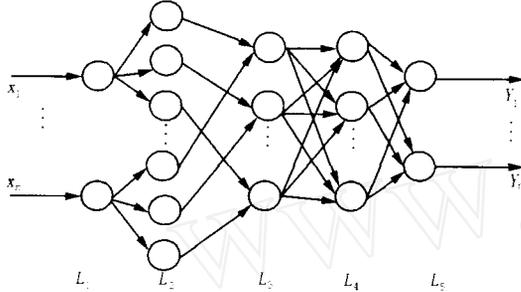


图 1 DFNN 的网络结构图

Fig 1 Structure of DFNN

第一层为输入层 L_1 :各个节点直接与输入向量各分量 x_i 相连,并将各输入值 $X = [x_1, x_2, \dots, x_n]^T$ 传到下一层, T 为转置, n 为输入变量的个数。

$$O_i^1 = u_i^1 \quad (i = 1, 2, \dots, n) \quad (5)$$

第二层为模糊化加递归层 L_2 :每个节点代表一个语言变量值,如负大、零、正小等。它计算各输入分量属于各语言变量值模糊集合的隶属度函数(采用高斯函数)。

$$O_{ij}^2 = \exp \left\{ - \frac{(u_{ij}^2 - c_{ij})^2}{(\sigma_{ij})^2} \right\} \quad (6)$$

$$(i = 1, 2, \dots, n; j = 1, 2, \dots, m_i)$$

其中: m_i 为 x_i 的模糊分割数; c_{ij} 和 σ_{ij} 分别表示隶属函数的中心和宽度;此层第 k 时刻的输入 $u_{ij}^2(k) = O_i^1(k) + O_{ij}^2(k-1)$, σ_{ij} 表示递归单元的连接权值。此层中 $O_{ij}^2(k-1)$ 记录了网络 $k-1$ 时刻的信息,因而可实现动态映射。

第三层为规则层 L_3 :每个节点代表一条模糊规则,用来匹配模糊规则的前件,完成模糊与操作计算出每条规则的适用度。

$$O_i^3 = \prod_j u_{ij}^3 \quad (7)$$

$$(i = 1, 2, \dots, m; j = 1, 2, \dots, n)$$

第四层为归一化层 L_4 :节点与第三层相同,实现归一化运算。

$$O_j^4 = u_j^4 / \sum_i u_i^4 \quad (8)$$

第五层为输出层 L_5 :实现清晰化计算,得到输出值 y_o 。

$$y_j = O_j^5 = \sum_i u_i^5 w_{ij}^5$$

($j = 1, 2, \dots, r$); r 为输出量个数; w_{ij}^5 为 L_5 的权值)

3.3 用 GA 训练模型参数

参数训练可以有很多方法,最常用的 BP 算法的训练时间较长,且易陷入局部极小值。因此采用遗传算法与 BP 算法相结合的方法来调整参数。遗传算法 GA (Genetic Algorithms),模拟自然界“物竞天择,适者生存”的进化过程,在问题空间进行全面并行的、随机的搜索优化,使种群朝全局最优的方向收敛。但由于 GA 在整个解空间内进行搜索,因此搜索速度比较慢,通过结合 BP 算法可克服此不足。具体方法为先用遗传算法对初始参数进行优化,找到准最优解,再用 BP 算法加快最后的收敛速度。此动态模糊神经网络中,若其模糊分割数是确定的,则需要学习的参数为最后一层的权值 w_{ij} ,第二层隶属函数的中心 c_{ij} 和宽度 σ_{ij} 以及递归连接权值 σ_{ij} 。定义目标函数:

$$J = \frac{1}{2} \sum_i (y_{di} - y_i)^2 \quad (9)$$

其中: r 为输出量的个数, y_{di} 和 y_i 分别为期望输出和实际输出,DFNN 的学习目标为使 J 最小。训练过程如下,首先运用遗传算法训练网络:

(1) 编码和译码。采用遗传算法对神经网络的参数进行训练,首先必须对参数进行相应的编码,同样在求每个个体的适应值时,必须将每个个体转化成相应的网络参数。然后计算出网络的输出,并通过性能指标对其进行评估,取得相应的适应值。这里采用简单的编码方式,即将网络的所有参数按一定的顺序排列在一起,每个参数是长度为 L 的二进制数。表示方法为:若参数的变化范围为 $[a_{\min}, a_{\max}]$,用 L 位二进制数 b 来表示,则二者之间的关系为 $a = a_{\min} + \frac{b}{2^L - 1} (a_{\max} - a_{\min})$ 。

(2) 确定适应度函数。适应度函数的确定方法很多,本文采用目标函数的倒数作为适应度函数 $F = 1/J$ 。

(3) 选择继承。评价种群的各个个体,对适应度为 F_i 的个体赋予其选择概率 P_i ,其中 $P_i = F_i / \sum_j F_j$,实际训练中一般将适应度最大的个体直

接遗传给下一代。

(4)交叉。对网络以概率值 P_c 进行单点交叉操作。首先对群体中的个体进行两两随机配对。若种群大小为 M ,则最多共有 $M/2$ 对相互配对的个体组。然后对每一对相互配对的个体,随机设置某一基因座之后的位置为交叉点,依设定的交叉概率 P_c 在其交叉点处相互交换两个个体的部分染色体,从而产生出新个体。

(5)变异。以变异概率 P_m 随机地改变个体染色体基因,产生新个体。

在遗传算法中,初始种群的大小 M ,交叉概率值 P_c 和变异概率 P_m 的选择对遗传算法的性能有很大的影响,一般选取 P_c 为 0.5 ~ 1.0, P_m 为 0.005 ~ 0.1。其具体数值需经过反复实验确定。

当优化个体的适应度和种群的适应值的平均值不再有意义地增加时,采用 BP算法来训练网络,使其快速收敛。

$$\text{令 } \delta_i^5 = -\frac{\partial}{\partial O_i^5} = y_{di} - y_i \quad (10)$$

其中 $E = J = \frac{1}{2} \sum_i^r (y_{di} - y_i)^2$,因此权值 w_{ij} 有

$$\frac{\partial}{\partial w_{ij}} = \frac{\partial}{\partial O_i^5} \frac{\partial O_i^5}{\partial w_{ij}} \quad (11)$$

$$- \delta_i^5 u_j^5 = - (y_{di} - y_i) O_i^4$$

再计算

$$\delta_j^4 = -\frac{\partial}{\partial O_j^4} = -\sum_{i=1}^r \frac{\partial}{\partial O_i^5} \frac{\partial O_i^5}{\partial O_j^4} = \sum_{i=1}^r \delta_i^5 w_{ij} \quad (12)$$

δ_j^3 和 δ_i^2 的计算依次类推。

最后可得出参数调整的学习算法为 (其中, $\eta > 0$ 为学习率)

$$w_{ij}(k+1) = w_{ij}(k) - \frac{\partial}{\partial w_{ij}} \quad (13)$$

$$i = 1, 2, \dots, n; \quad j = 1, 2, \dots, m$$

$c_{ij}(k+1)$ 、 $w_{ij}(k+1)$ 和 $w_{ij}(k+1)$ 的计算依次类推。

4 算例分析

用本文方法对美国加州电力市场^[9] 2000年1月第一个星期的出清电价进行了预测,并与常用BP算法及常用FUZZY算法的预测结果进行对比。

图2、图3分别为2000年6月2日(工作日)、6月3日(周末)的实际电价和预测电价的对比图。

从图2、3可以看出,在对周末的电价预测方面,由于采用了特殊工作日处理方法,预测准确度和一

般工作日没有很大的区别。

表2中列出了使用本文方法和直接使用BP神经网络得出的2000年6月2日的预测误差的对比,从表中可以看出本文的预测方法对市场出清电价的预测具有较高的精度。

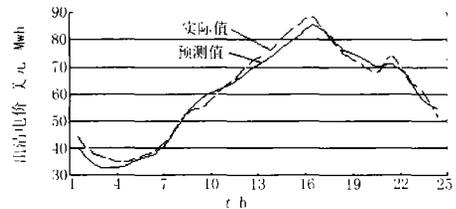


图2 工作日出清电价曲线

Fig 2 Curve of MCPs on workday

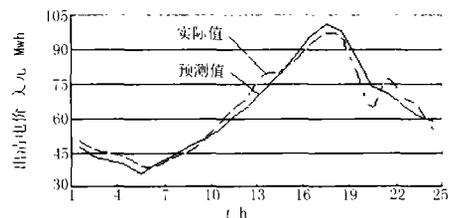


图3 休息日出清电价曲线

Fig 3 Curve of MCPs on weekend

表2 预测结果误差对比

Tab 2 Comparison of forecasting value and error (%)

时段	本文方法	FUZZY方法	BP神经网络
1	8.95	9.85	10.98
2	9.99	10.98	11.25
3	8.86	11.26	10.85
4	5.00	9.27	8.37
5	4.06	7.67	7.41
6	3.61	5.98	6.56
7	5.54	8.02	7.74
8	4.61	7.99	7.25
9	5.93	9.21	8.39
10	6.32	12.08	10.88
11	5.91	11.26	11.28
12	6.87	10.43	8.01

由表2可见,本文方法的预测精度明显高于常用的BP及FUZZY方法,原因在于:BP算法只是通过权值的联结笼统地给出了输入输出的非线性映射关系,常用的FUZZY方法中不论是对模糊规则还是隶属度函数的选取都过分依赖专家的主观意见,而本文的DNN系统不仅以信息熵的计算给出了合理的输入参数,而且是通过实际数据的学习客观地确定了系统的参数,真实地反映了输入变量与预测量之间的关系,在意义表达上较常用的BP及FUZZY方法更为准确。

5 结论

通过以上对实例的分析可以得出以下结论:

(1)粗糙集理论是一种处理具有模糊、不精确或不完全信息的分类问题的新型数学方法。它可以将输入信息的空间维数简化而模糊神经网络则不能,而且当输入的信息量较大时,模糊神经网络DFNN的拓扑结构不但复杂而且训练时间也很长。因此,将粗糙集理论和模糊神经网络结合起来,能发挥各自的优点相互补充,协同处理。

(2)运用粗糙集理论中的信息熵来选择与待预测测量相关性大的参数作为模糊神经网络DFNN的输入,充分保证了模型输入参数的合理性,有效地减少了系统计算的工作量,加快了网络的响应速度,同时也提高了模型的预测精度。

(3)动态模糊神经网络DFNN含有递归环节,具有动态映射,适宜处理动态问题,并且利用了GA全局寻优,并行搜索和随机操作的特点,避免了陷入局部最优。

另外值得一提的是,当今各国学者提出的预测短期出清电价的方法基本上都是建立在“动力学特性”的基础之上的,当电力市场处于完全竞争状态时的预测电价比较准确,但是当出现不完全竞争时,预测值与实际值都会相去甚远。怎样运用电力市场中“博弈均衡特性”来有效地避免上述现象将成为以后研究的重点。

参考文献:

- [1] 于尔铿. 电力市场[M]. 北京:中国电力出版社, 1998
YU Er-keng Electric Market[M]. Beijing: China Electric Power Press, 1998.
- [2] Gao F, Guan X H. Forecasting Power Market Clearing Price Using Neural Networks[A]. Proceeding of the 3rd World Congress on Intelligence Control and Automation. China: 2000.

- [3] Francisco N J, Javier C, et al. Forecasting Nextday Electricity Prices by Time Series Models[J]. IEEE Trans on Power Systems, 2002.
- [4] Wang A, Ramsay B. Prediction of System Marginal Price in the UK Power Pool Using Neural Networks[A]. Proceedings of IEEE International Conference. 1997. 2116-2120.
- [5] 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价格预测模型[J]. 电力系统自动化, 2001, 25(19): 11-14.
YANG Li, QIU Jia-jun, JIANG Dao-zhuo. BPN Based Day-Unconstrained Market Clearing Price Forecasting Model[J]. Automation of Electric Power Systems, 2001, 25(19): 11-14.
- [6] Disomtietwat P, Dagli C H. Simple Ensemble-averaging Model based on Generalized Regression Neural Network in Financial Forecasting Problems[A]. Adaptive Systems for Signal Processing, Communications, and Control Symposium, IEEE. 2000. 1-4.
- [7] Lyer A, Fung C C, Gedeon T A. Fuzzy-neural Approach to Electricity Load and Spot-price Forecasting in a Deregulated Electricity Market[A]. TENCON Conference on Convergent Technologies for Asia-Pacific Region. 2003. 15-17.
- [8] 赵庆波,周原冰,郭蓉,等. 模糊神经网络在电力系统边际电价预测中的应用[J]. 电网技术, 2004, 28(7): 45-48.
ZHAO Qing-bo, ZHOU Yuan-bing, GUO Rong, et al. Application of Fuzzy Neural Network in Power System Marginal Price Forecasting[J]. Power System Technology, 2004, 28(7): 45-48.
- [9] California Electricity Market Data [EB/OL]. Available: <http://www.ucei.berkeley.edu/>.

收稿日期: 2005-07-22; 修回日期: 2005-08-15

作者简介:

敖磊(1981-),男,硕士,研究方向为电力系统电价预测、电力市场理论及电力系统规划;E-mail: ao_jeff@163.com

刘旭东(1966-),男,工程师,研究方向为电力系统运行分析与规划、电力系统可靠性;

吴耀武(1963-),男,副教授,研究方向为最优化技术在电力系统中的应用、电力系统运行分析、电力系统规划及电力系统谐波分析;

熊信银(1945-),男,教授,从事最优化理论在电力系统中的应用、电力系统运行分析、电力系统规划等方面的研究工作。

A new approach to short-term price forecasting based on improved DFNN

AO Lei¹, LU Xu-dong², WU Yao-wu¹, XDNG Xin-yin¹

(1. Huazhong University of Science and Technology, Wuhan 430074, China;

2. Yichang Power Supply Company, Yichang 443003, China)

Abstract: An approach of improved dynamic fuzzy neural network for power system short-term price forecasting is proposed. Firstly, the fuzzy-rough set theory is applied to find relevant factors to the price among varied factors, then the dynamic fuzzy neural network (DFNN) model is trained using historical daily price and load data selected before performing the final forecast. The DFNN is constructed by introducing recursion segment in the fuzzy neural network, and the network is trained using the genetic algorithm and BP algorithm to avoid being trapped in the local convergence. With the established model, the day-ahead Market Clearing Prices (MCPs) of California Electricity Market are successfully forecasted. The analysis of the obtained forecasting results show that the presented method possesses better convergence and more accuracy.

Key words: market clearing price; short-term price forecasting; DFNN