

证据理论融合量子神经网络的短期负荷预测

李鹏¹, 颜艳², 郑武军¹, 贾健夫³, 白波²

(1. 浙江省衢州市开化县供电局, 浙江 衢州 324300; 2. 东北电力大学电气工程学院, 吉林 吉林 132012;
3. 吉林省电网培训中心, 吉林 吉林 132012)

摘要: 提出一种用于电力系统短期负荷预测的量子神经网络方法。量子神经网络模型作为单一预测模型对负荷进行预测。利用神经网络, 非线性回归模型对预测的历史误差和预测时点的外界影响因素进行分析建模, 建立每个模型的可信度评价模型。采用证据理论对每个模型的可信度进行分析评价和合成, 确立最终的模型组合预测权值。通过该权值对相应的预测结果进行加权求和得到最终的预测结果。实例表明, 该方法能提高预测的精度, 是有效可行的。

关键词: 负荷预测; 量子神经网络; D-S 证据理论

Short-term load forecasting based on quantum neural network by evidential theory

LI Peng¹, YAN Yan², ZHENG Wu-jun¹, JIA Jian-fu³, BAI Bo²

(1. Zhejiang Quzhou Power Supply Bureau, Quzhou 324300, China;
2. School of Electrical Engineering, Northeast Dianli University, Jilin 132012, China;
3. Jilin Power Grid Training Center, Jilin 132012, China)

Abstract: A quantum neural networks (QNN) method for short-term load forecasting of power system is proposed. The models from QNN forecast the short-term load as single model. The artificial neural networks (ANN) and non-linear regression forecast are selected to evaluate the credit of forecasting results of the above models, with historical forecasting errors and environmental influence. The credit is combined to calculate the weights with Dempster-Shafer(D-S) evidential theory. The final forecasting is obtained by the weighted forecasting. The real experiment shows the accuracy of the method based on D-S evidential theory is improved.

Key words: load forecasting; quantum neural network; D-S evidential theory

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2010)16-0049-05

0 引言

短期负荷预测是电力系统一项非常重要的工作, 日负荷和周负荷预测为短期负荷预测的周期, 分别用于安排日调度计划和周调度计划。为了准确和快速地预测短期电力负荷, 人们已做了大量的工作, 提出了很多成功的算法和预测模型, 并在电力系统的实际应用中取得了很大的进展^[1-3]。然而, 负荷特性随着预测时刻的变化而不断改变, 单一的预测模型不可能始终保持较高的预测精度, 如何随着时间和影响因素的变化选择精度较高的预测模型, 是迫切需要解决的问题。组合预测方法建立多种不同的预测模型进行预测, 然后通过对各种模型的预测结果进行一定的加权求和得到最终的预测结果。其优点是可以通过不同的模型来考虑不同的影响因素, 从不同的角度进行建模预测, 能够充分利用信

息。但是组合预测模型的难点在于如何确定其组合权值^[4-6]。

本文针对传统的神经网络的缺陷, 把量子计算融入神经网络^[7-9], 改进神经网络的性能, 然后把此模型用于负荷预测。通过多个不同的模型从不同角度, 利用预测时点的环境信息来评价单一电价预测模型在该点的可信度, 然后利用证据理论数据融合原理对单一模型的可信度进行综合处理, 得到组合权值; 最后根据这些组合权值和单一模型的负荷预测值来进行负荷组合预测^[9-10]。

1 组合预测结构及原理

本文的组合预测系统结构如图1。

首先选择单一预测模型, 进行数据预处理, 得到预测前一天的一些负荷数据, 将处理后的数据分为训练数据集和预测样本集; 然后将数据样本送入

量子神经网络模型和非线性回归预测模型中间，得到了单一预测模型的误差，它和当时外界环境因素的特征向量一起输入神经网络模型中进行可信度的

训练，最终得到每个单一模型的可信度；最后通过D-S证据理论融合单一预测模型，得到每个单一模型的权值，得到最终负荷预测值。

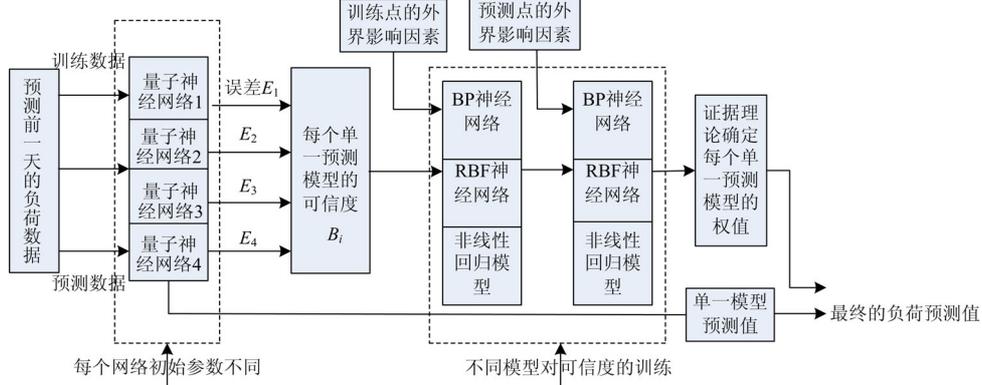


图1 组合预测系统结构图

Fig.1 Combined forecasting system structure

2 基于证据理论的组合负荷预测

2.1 单一预测模型的选取

组合模型预测的效果不仅取决于组合权值的选择，更依赖于单一模型预测的精度。因此选择好预测模型是组合预测的第一步。本文选取量子神经网络模型和非线性回归预测模型作为单一预测模型，就是基于预测的精度而考虑，以下简单介绍量子神经网络模型。

2.1.1 量子理论

在量子理论中^[10-11]，一个量子位的状态可以表示为：

$$|\Psi\rangle = a_0|0\rangle + a_1|1\rangle \quad (1)$$

其中： a_0 和 a_1 为任意复数且满足归一化要求 $|a_1|^2 + |a_0|^2 = 1$ ， $|a_1|^2$ 和 $|a_0|^2$ 分别表示该量子位坍缩到 $|1\rangle$ 和 $|0\rangle$ 的概率。把量子态坍缩到 $|1\rangle$ 的概率作为虚部，量子位坍缩到 $|0\rangle$ 的概率作为实部，用复数形式表示为：

$$f(\theta) = \cos(\theta) + j\sin(\theta) \quad (2)$$

其中， $|0\rangle$ 的概率幅对应实部的平方； $|1\rangle$ 的概率幅对应虚部的平方； j 是虚数单位； θ 是相位角，不同的相位角对应不同的量子态。

量子门是物理实现量子计算的基础，量子门代表了量子计算，它包含量子计算的特点。根据式(2)构成最基本的通用量子门组的两类量子门可表示为：

一位相移门：

$$f(\theta_1 + \theta_2) = f(\theta_1)f(\theta_2) = e^{j(\theta_1 + \theta_2)} \quad (3)$$

两位受控非门：

$$f[(\pi/2)k - \theta] = \begin{cases} \sin\theta + j\cos\theta, & k=1 \\ \cos\theta - j\sin\theta, & k=0 \end{cases} \quad (4)$$

其中： k 是控制变量，当 $k=1$ 时量子态发生反转； $k=0$ 时不反转；不同的 θ 对应于不同的量子态，两类量子门通过改变 θ 值实现对量子态的演化和变换。

在量子计算中，最后经过量子测量即量子坍缩，把一个量子态以概率幅的方式变换成经典信息(一个确定的值)。 $|\Psi\rangle$ 以概率 $|a_0|^2$ 作为量子0态的量子测量， $|\Psi\rangle$ 以概率 $|a_1|^2$ 作为量子1态的量子测量。

2.1.2 量子神经网络

量子神经网络的模型如图2。

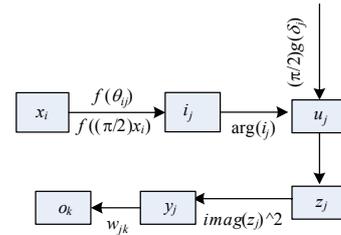


图2 量子神经网络模型

Fig.2 Quantum neural network model

图2参数处理过程说明如下：

$$o_k^t = g\left(\sum_{j=1}^m y_j^t w_{jk} - \theta_k\right) \quad (5)$$

$$y_j^t = \text{imag}(z_j)^2 \quad (6)$$

$$z_j^t = f(u_j^t) \quad (7)$$

$$u_j^t = (\pi/2)g(\delta_j) - \arg(i_j^t) \quad (8)$$

$$i_j^t = \sum_{i=1}^n f(\theta_{ij}) * f((\pi/2)x_i^t) \quad (9)$$

(1) x_i^t 为第 t 样本的相应实数输入。 y_j^t 为第 t 个样本的隐层量子测量输出, o_k^t 为第 t 个样本的最终输出。此模型的特点是复数表示形式, 应用量子门进行计算, 把实数输入 x 转化为量子态, 输出的 y 是经过量子测量的实数值。网络模型表示有 n 个输入神经元, m 个隐层神经元, l 个输出神经元, 因此 i 取 1 到 n , j 取 1 到 m , k 取 1 到 l 。 x_i^t 表示的是第 t 个样本的第 i 个实向量, 它是实际特征数值的归一化后的值; θ_{ij} 表示的是输入第 i 神经元到隐层第 j 神经元的量子相位变换参数; δ_j 表示的是隐层量子转动参数; w_{jk} 表示隐层第 j 个神经元到输出层第 k 个神经元的权值; θ_k 是表示输出的第 k 个神经元的阈值; o_k^t 表示的是第 t 个样本的第 k 个的网络输出。

(2) 此文中 θ 是相位变量; δ 是相位控制因子; θ 与 δ 是两个控制量子神经元的参数; 函数表示 $f(\theta) = \cos(\theta) + i \sin(\theta)$ 。 $f(\bullet)$ 是量子态表示形式。 $g(\bullet)$ 函数是非线性 sigmoid 函数, 表示为 $g(\delta) = 1/(1 + \exp(-\delta))$, 它和量子门一起构成了量子神经元的激活函数。此函数能把收集到的信息转换到 0~1 的范围内。根据式 (2) 此模型的量子输出测量是采用量子态 1 的概率幅, 量子态 1 的概率幅对应的是复数虚部的平方, 因此最终的表示即 y_j 取用的是 z_j 的虚部的平方。量子神经网络的内部参数调整方法采用梯度下降法, 在此不加详细介绍。此模型能降低预测误差, 本文就是采用此模型作为单一预测模型。各个量子神经网络的隐层数和初始权值是不同的, 这样它们预测的精度也是不同的, 篇幅有限不详细介绍。

2.2 可信度的训练

在利用训练数据对单一负荷预测模型进行训练后, 每个模型都会产生训练误差。根据训练误差 E_i , 可以确定每个模型在任一个时点相应的可信度 B_i 。而 $E_i = (\hat{y}_i - y_i)/y_i$ 。 i 从 1 到 4, \hat{y}_i 为预测的负荷值, y_i 为实际的负荷值。模型在该点的可信度 B_i 就可以表示为 E_i 的函数。

$$B_i = (1/(|E_i| + 0.01)) / (\sum_{j=1}^4 (1/(|E_j| + 0.01))) \quad (10)$$

这里每个误差绝对值加上 0.01 只是为了消除

E_i 为 0 的极端情况。

然后将 B_i 作为目标输出, 该时点的外界影响因素 (日期类型, 该时点的最高温度, 最低温度, 具体的时间点值) 作为模型输入, 采用 BP 神经网络, RBF 神经网络, 非线性回归模型作为模型进行可信度训练。在模型建立以后, 输入目标时点的外界影响因素变量就可以得到可信度 B_i 的预测值。可以通过折算使每个单一预测模型的可信度之和等于 1。通过折算后的可信度就可以作为一个证据体, 进行下列的 D-S 证据合成。

2.3 D-S 证据组合

首先用三种模型对每个单一量子神经网络预测模型的可信度进行了训练, 然后将结果折算到每个模型中, 得到三个证据体。对于不同证据体, 用 D-S 合成法则, 计算出这些证据联合作用下的信度函数和似真度函数, 然后将最终的判定概率作为最终的组合权值^[12-13]。

D-S 法则如下: m_1 和 m_2 分别是同一识别框架 Θ 上基于不同证据的两个基本可信度分配函数, 对应的基本命题分别为 A_1, A_2, \dots, A_m 和 B_1, B_2, \dots, B_n , 那么, 由两个不同证据的基本信度函数 m_1, m_2 合成的基本信度分配法则为:

$$m(A) = \begin{cases} \frac{\sum_{A_i \cap B_j = A} m_1(A_i) \bullet m_2(B_j)}{k} \\ 0 \end{cases} \quad (11)$$

其中, $k = \sum_{A_i \cap B_j \neq \Phi} m_1(A_i) \bullet m_2(B_j)$ 。多个证据结合的计算可用两个证据结合的计算递推得到。如果有 n 个证据体则 $m = ((m_1 \oplus m_2) \oplus \dots \oplus m_n)$ 。

2.4 最终负荷的预测

利用已训练好的量子网络预测模型, 对负荷做出初步的预测; 然后利用 D-S 合成法则计算的最终组合权值对初步的负荷预测进行加权求和, 就得到了最终的负荷预测值。

3 算法在负荷预测中的应用

将此算法用于电力系统的短期负荷预测中。在此预测中, 把样本集分为训练样本集和测试样本集, 每对训练样本的输入特征量由负荷、温度、日期类型的数据组成, 输出特征向量为负荷值。具体操作如下: 提取哈尔滨地区 2000 年 3 月 1 号到 14 号每天整数点的有功负荷值, 并进行归一化处理; 再分别取 2 号到 15 号的最高温度和最低温度两个特征量值, 此类数据采用温度梯度法进行归一化处理; 对

2 号到 15 号的日期类型的提取, 如周一取 0.1, 周二取 0.2, 依此类推, 不必再考虑周末和工作日的区别。这样每对样本就有 27 个归一化的输入向量, 即输入神经元为 27 个。用 2 号到 15 号哈尔滨地区对应的整数点的有功负荷作为训练网络期望输出。不同量子神经网络的隐层个数取值不一样, 初始权值及其量子系数都用 rand 函数随机取值。所以每个单一预测模型的预测结果是完全不一样的, 取 3 月 16 号到 30 号 14 天的数据作为测试数据以检验网络的泛化能力。通过 Matlab 仿真结果如图 3 所示。

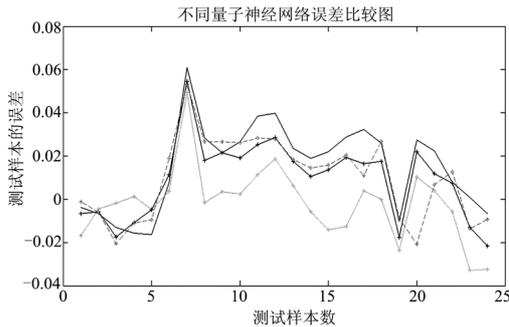


图3 不同量子神经网络误差曲线对比

Fig.3 Comparison of precision curves of different QNN

当量子神经网络的隐层和初始权值取值不同, 误差有很大的变化; 相同的模型不同的输入样本结果也完全不一样。所以用证据理论合成是很有必要的。

计算出每个单一模型的预测误差, 将根据式(10)就可以知道每个单一预测模型的可信度函数, 然后根据证据理论融合得出相应的权值系数。对量子神经网络模型的组合预测权值计算进行说明。以量子神经网络模型 1 为例。根据式(11), 计算其证据体为: 权值 $W=0.23907 \times 0.2268 \times 0.23628 / K$, 而 $K=(0.23907 \times 0.22685 \times 0.23628 + 0.24115 \times 0.22764 \times 0.21948 + 0.28456 \times 0.27239 \times 0.26129 + 0.23522 \times 0.27313 \times 0.28296)$ 。证据理论融合如表 1。

表 1 D-S 理论对单一模型的可信度的融合

Tab.1 Reliabilities of the single short-load forecasting models with D-S

单一预测模型	证据体 BP 网络	证据体 RBF 网络	证据体非线性回归	证据理论融合结果
量子网络 1	0.239 0	0.226 85	0.236 28	0.202 45
量子网络 2	0.241 1	0.227 64	0.219 48	0.190 36
量子网络 3	0.241 1	0.272 39	0.261 29	0.319 98
量子网络 4	0.235 5	0.273 13	0.282 96	0.287 21

表 1 是单一模型可信度的融合结果, 可以看出不同的证据体对单一预测模型结果的可信度是不同的, 例如证据体 RBF 网络认为量子网络 4 的可信度最大, 但是证据体 BP 网络却不认为量子网络 4 的可信度不是最大的。通过证据理论融合结果可以看出量子网络 3 的可信度最高, 量子网络 4 次之, 融合结果即相应的每个单一模型的权重, 通过加权平均得到预测的结果。

用实际的负荷来校验证据理论组合预测的精度, 并与单一预测模型的精度做比较。图 4 是 3 月 17 号整时点的误差曲线比较图。

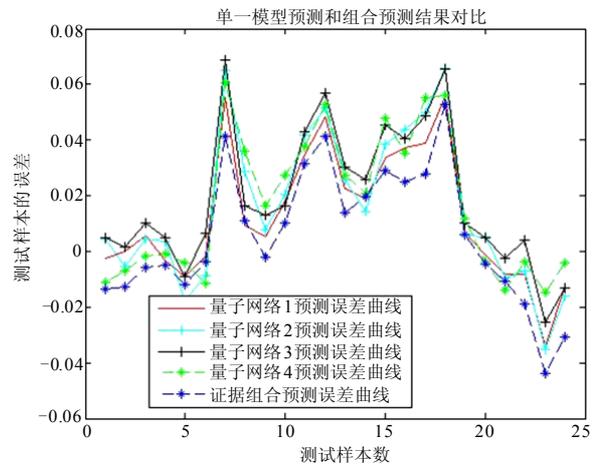


图 4 单一模型预测和组合预测结果对比

Fig.4 Comparison between the combined forecasting and single model forecasting method

由图 4 可以看出, 证据理论融合的负荷预测具有更好的精度, 但是证据理论的组合预测受到单一预测的极大影响, 误差曲线图走势和单一模型预测极其相似, 因此提高组合预测精度的前提条件就是单一预测模型的高精度, 这也是本文选择量子神经网络做组合预测单一模型的唯一原因。

4 结论

本文用量子理论改进了神经网络, 用该网络作为单一的预测模型, 预测短期负荷, 克服了传统神经网络的一些固有缺陷, 提高了预测精度; 用 BP 网络和 RBF 网络, 非线性回归模型训练了单一预测网络的可信度; 并用证据理论融合了这三种证据体的可信度, 得到了每个单一预测网络的权值, 最后得到了理想的负荷预测精度。实例表明该方法是切实可行的, 这也为负荷预测提供了一种参考方案。

参考文献

[1] 牛东晓, 曹树华, 等. 电力负荷预测技术及其应用[M]. 北京: 中国电力出版社, 1998.

- [2] 马继涛, 李军, 董元方, 等. 基于BP神经网络数学模型的短期负荷预测研究[J]. 长春理工大学学报, 2007, 30 (2): 111-114.
MA Ji-tao, LI Jun, DONG Yuan-fang, et al. Research of short term load forecasting based on mathematical model of BP neural network [J]. Journal of Changchun University of Science and Technology, 2007, 30 (2): 111-114.
- [3] 倪明, 单渊达. 证据理论及其应用[J]. 电力系统自动化, 1996, 20 (3): 76-80.
NI Ming, SHAN Yuan-da. Evidential theory and its applications[J]. Automation of Electric Power Systems, 1996, 20 (3): 76-80.
- [4] 倪明, 高晓萍, 单渊达. 证据理论在中期负荷预测中的应用[J]. 中国电机工程学报, 1997, 17(3): 199-203.
NI Ming, GAO Xiao-ping, SHAN Yuan-da. Application of evidential theory in middle-term load forecasting[J]. Proceedings of the CSEE, 1997, 17 (3): 199-203
- [5] 任峰, 李伟, 丁超. 基于灰色-周期外延组合模型的电力负荷预测[J]. 电网技术, 2007, 31 (24): 52-54.
REN Feng, LI Wei, DING Chao. Load forecasting based on gray-periodic extensional combinatorial model[J]. Power System Technology, 2007, 31 (24): 52-54.
- [6] 解光军. 量子神经计算[J]. 合肥工业大学学报, 2002, 25 (3): 355-359.
XIE Guang-jun. On quantum neural computation[J]. Journal of Hefei University of Technology, 2002, 25(3): 355-359.
- [7] 吕强, 俞金寿. 量子神经元结构设计及其应用[J]. 控制与决策, 2007, 22 (9): 355-359.
Lü Qiang, YU Jin-shou. Structure design of quantum neural unit and its application[J]. Control and Decision, 2007, 22 (9): 355-359.
- [8] 解光军, 范海秋. 一种量子神经计算网络模型[J]. 复旦大学学报, 2004, 43 (5): 700-703.
XIE Guang-jun. One quantum neural model[J]. Journal of Fudan University, 2004, 43 (5): 700-703.
- [9] 高在村. 基于量子门神经网络的车牌字符识别[J]. 计算机工程, 2008, 34 (23): 227-229.
GAO Zai-cun. License plate character recognition based on neural network with quantum gate[J]. Computer Engineering, 2008, 34 (23): 227-229.
- [10] 刘刚, 黄剑华, 刘学仁. 基于改进型BP神经网络的短期电力负荷预测[J]. 电气应用, 2005, 24 (12): 46-49.
LIU Gang, HUANG Jian-hua, LIU Xue-ren. Short-term load forecasting based on improved BP neural network [J]. Electricity Application, 2005, 24 (12): 46-49.
- [11] 孙奇, 杨伟. D-S证据理论融合改进BP网络的短期负荷预测研究[J]. 继电器, 2007, 35 (7): 61-65.
SUN Qi, YANG Wei. Research on load forecasting of fusion between D-S evidential theory improved BP network[J]. Relay, 2007, 35 (7): 61-65.
- [12] 曾鸣, 冯义, 刘达. 基于证据理论的多模型组合电价预测[J]. 中国电机工程学报, 2008, 28 (16): 84-88.
ZENG Ming, FENG Yi, LIU Da. Electricity price forecasting based on multi-models combined by evidential theory[J]. Proceedings of the CSEE, 2008, 28 (16): 84-88.

收稿日期: 2009-09-19; 修回日期: 2009-11-02

作者简介:

李鹏(1982-), 男, 本科, 工程师, 主要研究方向为电力系统应用研究;

颜艳(1984-), 女, 硕士研究生, 主要研究方向为配电自动化. E-mail: yanyan6284@yahoo.com.cn

(上接第 48 页 continued from page 48)

- [10] 路鸣, 保铮. 改善 MUSIC 空间谱估计分辨率的后处理算法[J]. 电子学报, 1990, 18 (4): 57-62.
LU Ming, BAO Zheng. Post-processing for resolution improvement of the MUSIC algorithm[J]. Acta Electronica Sinica, 1990, 18 (4): 57-62.
- [11] 王波, 杨洪耕. 基于 AR 谱估计和插值 FFT 的间谐波检测方法[J]. 继电器, 2006, 34 (4): 49-52.
WANG Bo, YANG Hong-geng. A method for interharmonic measurement based on AR model spectral estimation and interpolation FFT algorithm[J]. Relay, 2006, 34 (4): 49-52.
- [12] Petre Stoica, LI Hong-bin, LI Jian. Amplitude estimation

of sinusoidal signals: survey, new result, and an application[J]. IEEE Transactions on Signal Processing, 2000, 48(2).

收稿日期: 2009-09-21; 修回日期: 2010-04-22

作者简介:

季宇(1982-), 男, 博士, 研究方向为现代信号处理在电力系统中的应用; E-mail: anxiso@sina.com

孙云莲(1962-), 女, 博导, 研究方向为现代信号处理在电力系统中的应用, 电能质量分析与控制;

梁进祥(1983-), 男, 硕士, 研究方向为无线传感器网络技术在智能电网中的应用。