

基于 PCA 与改进 BP 神经网络相结合的 电网中长期负荷预测

贺 远,翟丹丹,苏贵敏
(国网河南省电力公司济源供电公司,河南 济源 454650)

摘 要:本文在标准反向传播神经网络的基础上,提出一种结合主成分分析法和改进的误差反向传播神经网络的方法来对电网中长期的电力负荷进行预测。首先利用主成分分析法对电力负荷的影响因素进行特征提取,有效地降低数据样本的维度,消除数据的冗余和线性信息,保留主要成分作为模型的输入数据。然后在标准的神经网络的反向传播环节中引入动量项和陡度因子。两种方法的结合有效地解决了网络收敛速度慢和容易陷入局部最小值的问题。将此方法应用于济源市的中长期电力负荷预测,实验结果表明,基于主成分分析法与改进的反向传播神经网络相结合的方法比常用的标准的反向传播神经网络、基于多变量的时间序列网络及时间序列网络具有更高的计算效率和预测精度,证明提出的预测模型在电力负荷预测中是有效的。

关键词:中长期负荷预测;主成分分析法;反向传播神经网络;收敛速度;预测精度

文章编号:2096-4633(2019)05-0074-07 **中图分类号:**TM715 **文献标志码:**B

电力系统负荷预测是电力系统经济调度中的一项重要内容,是能量管理系统(EMS)的一个重要模块。负荷预测按时间类型可以分为中长期负荷预测、短期负荷预测和超短期负荷预测。济源地区的电力系统负荷按占比主要可以分为城市民用负荷、商业负荷、农村负荷、工业负荷以及其他负荷等,如表 1 所示。不同类型的负荷具有不同的特点和规律。城市居民负荷带有明显的季节性特点,度夏和度冬负荷偏高,春秋季节负荷平稳,并且逐年攀升。农村生产负荷往往受天气、季节、湿度等自然因素比较大,而工业负荷在所有负荷中占比最大,而且与商业负荷受环境因素比较小,趋于恒定^[1]。提高电网的中长期负荷预测水平,不仅有助于提高用电工作科学有效的管理水平,更好地安排电网最优运行方式和相关设备的检修工作计划,而且有助于节约不能再生资源,降低发电成本,增加电力带来的社会和经济效益。

由于电力负荷带有明显的时变特点以及不可控因素,所以电力负荷预测是一个典型的非线性问题^[2]。为了能够取得准确的负荷预测结果,最需要解决的问题是建立最佳的电力负荷预测的数学模型。传统的负荷预测模型种类繁多,但其中效果最好的是人工神经网络。它通过对历史数据强大的自主学习和自适应能力,从而训练出预测指标与负荷

预测结果之间的映射关系,无限逼近实际问题,十分适用于电力负荷预测。

表 1 2017 年济源地区负荷分类及平均占比
Tab. 1 Load classification and average proportion of Jiyuan area in 2017

负荷类型	年平均负荷/MW	占比/%
工业生产负荷	555	78.9
城市民用负荷	77	11
商业负荷	35	5
农村生产负荷	21	3
其他负荷	15	2.1
合 计	703	100

现实中影响电力负荷的因素种类繁多,由于这些影响因素之间存在着冗余、共线性及不可量化的信息,直接将这些信息作为负荷预测模型输入量,会导致模型的输入维数偏多,使网络结构变得复杂、泛化能力降低,在对济源市用电负荷做中长期负荷预测时需要往年的历史数据作为模型的训练样本,由于这些数据量庞大,势必会导致预测模型的收敛速度下降,甚至导致预测结果无法得到最优结果。针对其收敛速度慢和容易陷入局部极小值的缺陷,本文首先运用 PCA 法对数据进行预处理^[3],然后再结合本文中改进的 BP 神经网络算法对济源市电网的

中长期电力负荷进行快速、更精确预测。

1 主成分分析法(principle component analysis, PCA)

PCA 基本思想是通过变量的相关系数矩阵内部结构的研究,找出具有代表性的少数几个变量来描述整个变量体系的相关关系^[4]。在数学的角度,PCA 方法属于降维处理技术^[5]。PCA 具体处理过程如下:

(1) 设 $X_{(m \times n)}$ 表示 m 个样本的 n 个变量的原始数据矩阵,对其进行标准化处理后得到新的矩阵:

$$Y = (y_{ij})_{m \times n} (j = 1, 2, \dots, p) \quad (1)$$

其中:

$$y_{ij} = \frac{x_{ij} - \bar{x}_j}{\frac{1}{m-1} \sum_{i=1}^m (x_{ij} - \bar{x}_j)} \quad (2)$$

$$\bar{x}_j = \frac{1}{m} \sum_{i=1}^m x_{ij} \quad (3)$$

(2) 建立经过标准化处理后的 n 个因素的相关系统矩阵 R :

$$R = (r_{ij})_{n \times n} \quad (4)$$

$$r_{ij} = \frac{\sum_{k=1}^m (x_{kj} - \bar{x}_j)(x_{ki} - \bar{x}_i)}{\sqrt{\sum_{k=1}^m (x_{kj} - \bar{x}_j)^2 \sum_{k=1}^m (x_{ki} - \bar{x}_i)^2}} \quad (5)$$

(3) 计算新矩阵 R 的特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$ 及其各自对应的特征向量 $\mu_1, \mu_2, \dots, \mu_n$, 并将特征值按从大到小的顺序排列。

(4) 分别计算每个特征值的贡献率 e_i 和累计贡献率 E_i , 具体计算公式如下:

$$e_i = \frac{\lambda_i}{\sum_{i=1}^n \lambda_i} \quad (6)$$

$$E_i = \sum_{j=1}^i \lambda_j / \sum_{i=1}^n \lambda_i \quad (7)$$

(5) 结合上述公式,计算表示各成分与变量之间相关系数的主成分载荷矩阵 z_i 。

$$z_i = \sum_{j=1}^m \sum_{i=1}^n \mu_{ij} y_{ij} \quad (8)$$

2 标准 BP 神经网络算法

2.1 标准 BP 神经网络的定义及特点

标准 BP 神经网络是基于误差反向传播算法(back propagation, 简称 BP 算法)的多层前向神经网络,一般包含三层网络:输入层、隐含层和输出层,每

一层都是由众多神经元组成,相同层的神经元之间没有任何连接,但是相邻层则完全互互相连接,图 1 所示为包含了一个隐含层的网络结构。BP 网络的神经元采用的传递函数一般为 Sigmoid 型可微函数,所以在实际应用中能够实现输入和输出间的任意非线性映射,被广泛应用在信号处理、语音识别等领域。网络主要包括两个传播过程,即正向传播和反向传播组成的误差修正型学习算法^[6]。




图 1 标准 BP 神经网络结构

Fig. 1 Standard BP neural network structure

$$f(x) = \frac{1}{1 + e^{-x}} \quad (9)$$

输入信号在响应函数的作用下,按照梯度下降的原则依次通过隐含层和输出层,不断修正各层的对应权值,直至网络收敛。如果在输出层无法得到期望输出,则误差信号反向传播,修改神经元之间的连接权值。通过这样反复的过程,最终使网络收敛。BP 网络是一个高度非线性函数求全局最优的过程^[7]。

2.2 标准 BP 神经网络的实现步骤

标准的 BP 神经网络一般包括以下主要步骤:

- (1) 确定网络结构:确定输入、输出层节点数以及隐含层数目和隐层节点数,选取较小的初始值 w_{ij} 、 w_{jk} 和 θ_j 、 γ_k , 以保证每个神经元的输入为一个较小的数值,这样能够保证网络工作在传递函数的激活区。在隐层节点相对较多的情况下,单隐层的前馈网络有可能逼近连续的函数,而过多的隐层节点又会导致“过拟合现象”和“过度参数化”的问题,即神经网络的权值系数个数大大超过训练样本总数,造成其推广能力较差。因此一般通过试选的方法来确定隐层节点的数目,视模型的误差情况进行调整;
- (2) 给定训练样本的输入输出集合,根据训练样本,分别计算各隐含层和输出层神经元的输出;
- (3) 计算输出值与期望输出之间的误差,如果

超出预定的允许误差范围,则需对网络各神经元的连接权值和阈值进行合理的调整,对整个网络进行改进;

(4)重复步骤(2),直至网络误差负荷要求为止。

2.3 标准 BP 神经网络的缺陷

虽然标准 BP 神经网络在解决非线性问题时,可以拟合出最逼近实际问题的非线性函数^[8],但是在应用中却存在这不可忽视的缺陷和不足,总结如下:

(1)BP 算法的目标函数非常繁琐复杂,基于梯度下降法使 BP 算法计算效率低效且必然出现“锯齿形现象”;

(2)BP 算法在求解复杂非线性函数的全局极值时,采用的是分段搜索局部最优值的方式,这导致算法容易陷入局部极值,最终使训练失败;

(3)BP 算法在数据训练阶段,训练样本的输入数据对算法的非线性函数逼近能力有很大的影响,不仅影响训练速度,而且降低函数的准确性。因此如何选取适合的学习训练数据是一个不可忽视的问题;

(4)BP 算法的初始权值及阈值一般是随机分配的,因此不合适的取值会对网络性能造成影响,使网络结构收敛速度变慢,预测误差变大;

(5)BP 算法的预测能力受训练能力的影响,两者成强正相关的关系。但达到一定程度后,预测能力会随着训练能力提高而出现下降,即所谓的“过拟合”现象,即便为网络提供再多的训练数据,也无法反映出样本的内部规律。

3 基于 PCA 与改进的 BP 神经网络算法

本文针对标准 BP 算法的不足,为加快算法的训练速度,避免陷入局部最优值,并提高算法的有效性,在样本训练阶段引入了动量项和陡度因子的算法,同时结合 PCA 算法的数据降维优势,极大地解决了传统算法样本数据量大和乱的问题,提高计算效率和有效性。

改进算法的大致思路为:首先通过 PCA 算法对输入数据进行降维处理,提取有效数据作为模型的训练数据并输入 BP 网络中。然后在误差反向传播阶段,当神经元输出进入了转移函数的饱和区时动量项引入陡度因子,使模型的误差函数迅速脱离平坦区,不断修正权值,直至网络误差达到最小并输出

最佳期望值。基于 PCA 与改进的 BP 网络算法的主要执行步骤如下:

(1)数据初始化。将训练样本进行归一化处理,映射至 $[0,1]$ 之间。

(2)筛选主要数据。对样本数据进行主成分分析,计算各成分的贡献率,根据贡献率大小筛选出 N 个主要成分,并作为模型的输入数据。

(3)确定权值、阈值和全局误差 E 。根据(2)中 N 个主要成分确定模型的结构,并为每一个连接权值 w_{ij} 、 w_{jk} 、阈值 θ_j 、 γ_k ,赋予 $(-1,1)$ 区间内任一随机值。模型的全局误差 E 设为 0;

(4)分别计算隐含层和输出层的输出;

(5)分别计算隐含层和输出层的误差。

(6)修正权值和阈值。当反向传播过程中,在连接权值调整中加入动量项,若神经元输出进入了转移函数的饱和区域时,则在原函数中引入陡度因子,使之脱离平坦区。通过此方式修正输入层和隐含层、隐含层和输出层的权值和阈值;

(7)通过重复步骤(4)~(6)的过程不断修正各层神经元的权值,直至误差收敛;

(8)结束学习。当网络误差精度 $E_{\min} >$ 全局误差 E 时,则判定网络收敛,满足精度要求,结束学习。

基于 PCA 与改进 BP 网络相结合的算法如流程图 2 所示。




图 2 基于 PCA 与改进 BP 网络相结合算法流程图

Fig. 2 Flowchart based on combination of PCA and improved BP network

4 实例分析

4.1 电力负荷预测及检验的原始数据

本文提取济源地区 2016 年至 2017 年的全社会系统负荷作为原始数据样本,同时也是基于 PCA 与改进 BP 网络结合算法的训练数据,以 2018 年 7 月的电力负荷作为测试值。首先运用标准三层结构的多输入多输出 BP 网络模型进行负荷预测,将原始

数据作为训练样本,采集周期为 3 个小时,输入层为 4 380 个神经元,对应着 2016 年和 2017 年 730 天每隔 3 小时的负荷数据,输出层为预测月份的负荷数据,即 2018 年 7 月的全社会电力负荷,共 $31 \times 24 \div 3 = 248$ 个神经元。经过多次试验确定隐含层节点数为 5000 时的模型训练精度较高。仿真预测结果与实际负荷值对比如图 3 所示。实验仿真环境:Windows7 系统、8G 内存、i5 处理器、MATLAB2013。




图3 标准 BP 网络预测负荷与实际负荷对比

Fig. 3 Comparison of predictive load and actual load of standard BP network

4.2 改进算法的实验仿真

在相同的仿真环境、样本数据和输出层节点数下,运用基于 PCA 与改进后的 BP 网络相结合的方

法对 2018 年 7 月份的系统负荷进行预测。首先对样本进行主成分分析,得到如表 2 所示的各主成分的贡献率。

表 2 PCA 的特征值及贡献率

Tab. 2 PCA eigenvalue and contribution rate

主成分	特征值	方差贡献率/%	累计贡献率/%
1	13. 378 9	51. 457 2	51. 457 2
2	4. 857 9	18. 684 1	70. 141 4
3	2. 828 7	10. 879 6	81. 021 0
4	1. 138 5	4. 378 7	85. 399 8
5	1. 015 2	3. 962 0	89. 361 8
6	0. 638 3	2. 455 3	91. 817 1
7	0. 457 5	1. 825 1	93. 642 2
8	0. 361 3	1. 423 6	95. 065 8
...	...	...	...
27	0. 000 3	0. 001 2	100. 000 0

由表 2 可以看出,前 6 个主成分的累计贡献率达到了 91.82%,根据累计贡献率达到 90% 以上的最少的 N 个特征值作为主成分的原则,这里取前 6 个主成分代替原来 27 个与电力负荷有关的变量。这 6 个变量基本上可以反映出所有原变量包含的绝大部分信息,并且它们之间互不相关,从而消除了

27 个变量的冗余、共线性信息,从而达到了降维的效果。将处理过的数据作为改进后的 BP 神经网络的输入数据,仿真表明这使得网络结构变得简洁,而且运算速度加快。由此可得预测结果与实际负荷对比如图 4 所示。




图 4 基于 PCA 与改进 BP 网络相结合的预测负荷与实际负荷对比

Fig. 4 Comparison between predictive load and actual load based on PCA combined with improved BP network

4.3 负荷预测的误差计算

电力负荷预测的任何模型不可能考虑到所有的影响因素,那些被忽略的、较小的因素不可避免会与实际负荷预测产生误差。合理的计算和分析误差能够不断提升负荷预测的精度,进而为预测模型的不断优化提供更有价值的依据。本文采用标准误差法对预测值的误差进行计算,标准误差采用的是对误差的平方和求平均数的方法,同时考虑了训练数据及预测数据,能够解决正负误差相加相互抵消的问题,是一种常用的误差计算方法^[9]。具体计算公式为:

$$S_Y = \sqrt{\frac{\sum (Y_i - \hat{Y}_i)^2}{n - m}} \quad (10)$$

式中, S_Y 为预测的标准误差, Y_i 为第 i 个实际负荷值, $\hat{Y}_i$ 为第 i 个预测负荷值, n 为历史负荷样本数据, m 为自由度,即变量个数,包括自由变量和因变量的个数。

4.4 实验结果分析

在相同的三层网络结构和数据样本下,分别用

标准 BP 网络和 PCA 与改进 BP 网络结合的算法来预测济源市 2018 年 7 月的全社会系统负荷,预测的指标对比如表 3 所示。由表 3 可以看出,基于 PCA 和改进 BP 神经网络相结合的模型运行时间仅为 558 秒,由于在数据处理阶段 PCA 有效地降低了电力负荷预测数据的空间维数,消除了各种影响因素的冗余、共线性信息,只保留了原始变量中的主要成分,因而极大提高了网络的训练时间,运算时间比标准 BP 网络提高了 3.3 倍,比 CAR 模型提高了 2.3 倍,比 ARIMA 模型提高了 1.8 倍。误差反向传播阶段引入的动量项和陡度因子,使误差函数能够及时脱离饱和区,避免陷入局部最小值,从而提高了预测精度,平均误差由 5.44% 降低至 1.21%,降低了 4.5 倍,与 CAR 模型相比降低 8.1 倍,与 ARIMA 模型相比降低了 9.4 倍。由图 3 和图 4 对比可以看出,基于 PCA 和改进 BP 神经网络模型的预测数据与实际电力负荷数据的整体拟合度要高于标准 BP 网络的预测值。所以综上所述,我们可以判定本文中提到的算法整体预测效果要明显优于标准的 BP 神经网络。

表3 两种算法的指标对比

Tab.3 Comparison of indicators of the two algorithms

算 法	网络结构	迭代次数	运行时间	平均误差/%
标准 BP 网络	3 层	262 662	1 842 秒(30 分 42 秒)	5.44
CAR	—	—	1 291 秒(21 分 31 秒)	9.82
ARIMA	—	—	1 025 秒(17 分 05 秒)	11.36
PCA—改进 BP 网络	3 层	152 843	558 秒(9 分 18 秒)	1.21

5 结束语

本文针对济源市地区电力负荷影响因素众多而难以准确预测的特点,采用基于 PCA 和改进 BP 神经网络相结合的模型,首先利用 PCA 算法有效地降低了训练样本和预测数据的维度,消除了冗余和线性信息,筛选出对模型最有价值的数据信息^[10-12]。然后在标准 BP 网络的误差修正环节引入了动量项和陡度因子,加快了模型的学习效率,避免模型陷入局部最小值。实验仿真结果表明,利用主成分分析对影响电力负荷的变量数据进行预处理,有效地减少网络的输入维度,极大的简化了模型的结构,改进后的模型比标准 BP 模型具有更快的计算效率和更高的预测精度,这对于电力部门和供电系统的最优运行和调度规划的制定都有着重要的社会意义和经济意义^[13-18]。

参考文献:

[1] 蒋玮,黄丽雨,祁晖,等. 基于分布式图计算的台区负荷预测技术研究[J]. 中国电机工程学报,2018,38(12):3419-3430+1.

JIANG Wei, HUANG Lili, Qi Hui, et al. Research on load forecasting technology of transformer areas based on distributed graph computing[J]. Proceedings of the CSEE,2018,38(12):3419-3430+1.

[2] 杨斌,杨永军,张亚,等. 基于主成分分析与神经网络复合模型的汽轮机排汽焓计算[J]. 中国电力,2018,51(01):126-132.

YANG Bin, YANG Yongjun, ZHANG Ya, et al. The calculation of turbine exhaust enthalpy based on the hybrid model of the principal component analysis and the BP neural network[J]. Electric Power, 2018,51(01):126-132.

[3] 刘晓菲,商立群. 非线性主成分分析和 RBF 神经网络的电力系统负荷预测[J]. 电网与清洁能源,2016,32(01):47-52.

LIU Xiaofei, SHANG Liqun. Nonlinear principal component analysis and RBF neural network for power system load forecasting [J]. Power System and Clean Energy,2016,32(01):47-52.

[4] 张智晟,于道林. 考虑需求响应综合影响因素的 RBF-NN 短期负荷预测模型[J]. 中国电机工程学报,2018,38(06):1631-1638+1899.

ZHANG Zhisheng, YU Daolin. RBF-NN based short-term load forecasting model considering comprehensive factors affecting demand response[J]. Proceedings of the CSEE,2018,38(06):1631-1638+1899.

[5] 苏学能,刘天琪,曹鸿谦,等. 基于 Hadoop 架构的多重分布式 BP 神经网络的短期负荷预测方法[J]. 中国电机工程学报,2017,37(17):4966-4973+5216.

SU Xueneng, LIUTianqi, CAO Hongqian, et al. A multiple distributed BP neural networks approach for short-term load forecasting based on Hadoop framework [J]. Proceedings of the CSEE,2017,37(17):4966-4973+5216.

[6] 刘俊,王旭,郝旭东,等. 基于多维气象数据和 PCA-BP 神经网络的光伏发电功率预测[J]. 电网与清洁能源,2017,33(01):122-129.

LIU Jun, WANG Xu, HAO Xudong, et al. photovoltaic power forecasting based on multidimensional meteorological data and PCA-BP neural network [J]. Power System and Clean Energy, 2017,33(01):122-129.

[7] 秦欢,门业堃,于钊,等. 基于隐马尔科夫和主成分分析的电网数据词典构建[J]. 电力大数据,2019,11(01):16-21.

QIN Huan, MEN Yekun, YU Zhao, et al. The construction of grid data dictionary based on HMM and PCA[J]. Power Systems and Big Data. 2019,11(01):16-21.

[8] 王鸿玺,李飞,李翀,等. 基于大数据分析的混沌神经网络模型在负荷预测中的应用[J]. 电力大数据,2017,20(08):1-5+40.

WANG Hongxi, LI Fei, LI Chong, et al. Application of chaotic neural network model in load forecasting based on big data analysis [J]. Power Systems and Big Data,2017,20(08):1-5+40.

[9] DONGXIAO NIU, JIANJUN WANG, JINPENG LIU. Knowledge mining collaborative DESVM correction method in short-term load forecasting [J]. Journal of Central South University of Technology,2011,18(04):1211-1216.

[10] 李重春,祝安琪,王烁罡,等. 电力大数据下的短期电力负荷预测[J]. 电力大数据,2019,22(01):66-70.

LI Chongchun, ZHU Anqi, WANG Shuogang, et al. Short-term power load forecasting under power big data [J]. Power Systems

- and Big Data, 2019, 22(01):66–70.
- [11] 孔繁钢, 刘强, 王冀星, 等. 基于改进 BP 神经网络算法的岸电电源智能输出控制的研究[J]. 电网与清洁能源, 2017, 33(02):64–67+74.
KONG Fangang, LIU Qiang, WANG Jixing, et al. Intelligent output control of shore power supply based on improved BP neural network algorithm[J]. Power System and Clean Energy, 2017, 33(02):64–67+74.
- [12] 詹长杰, 周步祥. 基于 PCA-SVM 模型的中长期电力负荷预测[J]. 电测与仪表, 2015, 52(09):6–10+40.
ZHAN Changjie, ZHOU Buxiang. The medium and long term power load forecasting model based on PCA-SVM[J]. Electrical Measurement & Instrumentation, 2015, 52(09):6–10+40.
- [13] 张凌云, 肖惠仁, 吴俊豪, 等. 电力系统负荷预测综述[J]. 电力大数据, 2018, 21(01):52–56.
ZHANG Lingyun, XIAO Hui ren, WU Junhao, et al. Review of power system load forecasting[J]. Power Systems and Big Data, 2018, 21(01):52–56.
- [14] 郑海雁, 王成亮. 基于用电大数据的中长期负荷预测研究[J]. 电测与仪表, 2018, 55(13):74–77.
ZHENG Haiyan, WANG Chengliang. Research of medium-long term load forecasting based on electricity big data[J]. Electrical Measurement & Instrumentation. 2018, 55(13):74–77.
- [15] RONGBIN QI, HUA MEI, CHAO CHEN, et al. A fast MPC algorithm for reducing computation burden of MIMO[J]. Chinese Journal of Chemical Engineering, 2015, 23(12):2087–2091.
- [16] 夏博, 杨超, 李冲. 电力系统短期负荷预测方法研究综述[J]. 电力大数据, 2018, 21(07):22–28.
XIA Bo, YANG Chao, LI Chong. Review of the short-term load forecasting methods of electric power system[J]. Power Systems and Big Data, 2018, 21(07):22–28.
- [17] YUNLUO YU, WEI LI, DEREN SHENG, JIANHONG CHEN. A hybrid short-term load forecasting method based on improved ensemble empirical mode decomposition and back propagation neural network[J]. Journal of Zhejiang University-Science A (Applied Physics & Engineering), 2016, 17(02):101–114.
- [18] 黄宇腾, 韩翊, 赖尚栋. 深度神经网络在配电网公变短期负荷预测中的应用研究[J]. 浙江电力, 2018, 37(05):1–6.
HUANG Yuteng, HAN Yi, LAI Shangdong. Application of deep neural network in short-term load prediction of public transformer of power distribution network[J]. Zhejiang Electric Power, 2018, 37(05):1–6.

收稿日期: 2019–02–05

作者简介:



贺 远(1989), 男, 硕士研究生, 工程师, 主要从事电力调度及监控工作。

(本文责任编辑: 范 斌)

Medium and long-term load forecasting of power grid based on PCA combined with improved BP neural network

HE Yuan, ZHAI Dandan, SU Guimin

(Jiyuan Power Supply Company of State Grid Henan Electric Power Company, Jiyuan 454650 Henan, China)

Abstract: Based on the standard back propagation neural network, this paper proposes a method combining principal component analysis and improved error back propagation neural network to predict the long-term power load of the power grid. Firstly, principal component analysis is used to extract the factors affecting the power load, effectively reduce the dimension of the data sample, eliminate the redundancy and linear information of the data, and retain the main components as the input data of the model. The momentum term and the steepness factor are then introduced in the back propagation of the standard neural network. The combination of the two methods effectively solves the problem of slow network convergence and easy to fall into local minimum. The method is applied to the medium and long term power load forecasting in Jiyuan City, the experimental results show that the method based on principal component analysis combined with improved back-propagation neural network is more common than the standard back-propagation neural network, multivariate-based time series network and time series network have higher computational efficiency and prediction accuracy, which proves that the proposed prediction model is effective in power load forecasting.

Key words: medium and long term load forecasting; principle component analysis; back propagation neural network; convergence speed; prediction accuracy