

基于多重影响因素的神经网络中短期用电量预测模型

吴 豫, 苗福丰, 董 智

国网河南省电力公司, 河南 郑州

收稿日期: 2021年12月3日; 录用日期: 2022年2月28日; 发布日期: 2022年3月4日

摘 要

当前, 电网规划建设由满足电力负荷平衡需求到电量平衡需求转变。新形势下需要探索和拓展考虑多重影响的因素的电量预测方法。本文在电量影响因素分析基础上, 采用BP神经网络、RBF神经网络两种不同的预测模型和方法, 将用电量和主要影响因素作为输入条件, 构建、训练电量预测模型, 最后以某区域电量为实例, 验证模型方法的准确性和实用性, 助力电力负荷平衡向电量平衡转变。

关键词

电量平衡, 神经网络, 电量预测, 相关分析, 精准规划

A Neural Network Mid-Term and Short-Term Electricity Consumption Forecast Model Based on Multiple Influencing Factors

Yu Wu, Fufeng Miao, Zhi Dong

State Grid Henan Electric Power Company, Zhengzhou Henan

Received: Dec. 3rd, 2021; accepted: Feb. 28th, 2022; published: Mar. 4th, 2022

Abstract

At present, the planning and construction of power grids have shifted from satisfying the demand for electric load balancing to the demand for electric power balancing. Under the new situation, it is necessary to explore and expand electricity forecasting methods that consider multiple influencing factors. Based on the analysis of power influencing factors, this paper adopts two different

prediction models and methods of BP neural network and RBF neural network. The power consumption and main influencing factors are used as input conditions to construct and train the power prediction model. Finally, the power consumption in a certain area As an example, it verifies the accuracy and practicability of the model method, and facilitates the transition from power load balance to power balance.

Keywords

Power Balance, Neural Network, Power Prediction, Related Analysis, Precise Planning

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

当前,我国经济进入精细化、高质量发展的新阶段,电网规划建设也要求由满足电力负荷平衡需求到电量平衡需求转变[1] [2]。用电量的影响因素较多,国内外学者也从不同方面对电量预测方法进行了研究。文献[3]基于回归分析法和指数平滑法,提出计及经济因素的月度用电量预测方法;文献[4] [5] [6]采用回归分析和 X-12-ARIMA 模型,对季节和气候变化对月度电量进行预测模型构建;文献[7] [8]针对春节期间负荷和电量最小值差异,分别对负荷和电量按照 2 段建模分析;文献[9]针对计量装置在线路故障情况下存在缺失电量问题,采用强鲁棒性的随机森林方法对故障区间用电量进行滚动预测。

以上文献从不同方面考虑了电量回归预测分析方法,影响因素多有局限性。随着新形势的发展变化,需要探索和拓展考虑多重影响的因素的电量预测方法。神经网络预测方法[10] [11] [12]是所有预测方法中最接近人工智能的,它能够模拟人脑活动,以其独特的自我学习和自动适应能力,实现对知识优化和智能化处理,在预测精度、所需训练样本、处理影响因素等方面,比其他预测方法更具优势。

本文首先采用相关系数分析法,分析影响电量的主要因素,并将主要影响因素和电量等多元素,作为输入条件,采用神经网络中两种不同的预测模型和方法,从不同角度,构建、训练电量预测模型,并以某区域电量为实例,验证模型方法的准确性和实用性,提高电量预测的精度,助力电力负荷平衡向电量平衡转变。

2. 用电量主要影响因素分析

2.1. 相关性分析方法

采用相关性分析,对用电量和影响因素进行两两指标量化相关系数分析。相关性判别原则,如表 1 所示。

Table 1. Relevance discrimination principle

表 1. 相关性判别原则

序号	相关系数	相关性
1	$ r = 0$	完全不相关
2	$0 < r < 0.3$	基本不相关

Continued

3	$0.3 \leq r < 0.5$	低度相关
4	$0.5 \leq r < 0.8$	显著相关
5	$0.8 \leq r < 1$	高度相关
6	$ r = 1$	完全相关

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

式中, n ——指标样本数据的个数;

x 和 y ——两个比较指标的平均值。

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (2)$$

2.2. 影响因素相关性分析

2.2.1. 与产业和能源消耗的相关性

用统计分析软件 SPSS, 对某城市 A 《统计年鉴》近 10 年中, 全社会用电量对国民经济、工业总产值、万元国内生产总值能耗等数据的相关性分析, 结果如表 2 所示。

Table 2. Pearson correlation analysis of electricity consumption in the whole society in the past 10 years (unit: 100 million yuan, 10,000 tons of standard coal, ton of standard coal/10,000 yuan)

表 2. 近 10 年全社会用电量的 Pearson 相关性分析(单位: 亿元, 万吨标煤, 吨标煤/万元)

	第一产业	第二产业	第三产业	能源消费总量	GDP (现价)	GDP 能耗
Pearson 相关性	0.979**	0.994**	0.984**	0.996**	0.992**	-0.994**
显著性(双侧)	0.000	0.000	0.000	0.000	0.000	0.000
N	10	10	10	10	10	10

**在 0.01 水平(双侧)上显著相关。

*在 0.05 水平(双侧)上显著相关。

从表 2 可以看出, 近 10 年全社会用电量对以上数据分析的相关系数, 均在 0.9 以上, 具有高度相关性。

2.2.2. 与气象因素的相关性

同理, 用统计分析软件 SPSS, 对 A 城市历史年某 1 年 365 天中, 分析全社会日用电量与气象因素相关数据的相关性分析, 结果如表 3 所示。

从表 3 可以看出, 电量与最高气温、最低气温、平均气温, 低度相关, 与平均气压显著负相关; 与降水量、最大风速、最大风向、日照时长、平均相对湿度等, 基本不相关。即气象因素中, 仅气温为用电量影响因子。

Table 3. Pearson correlation analysis of daily electricity consumption

表 3. 日用电量 Pearson 相关性分析

	平均气 压(hpa)	平均气 温(°C)	最高气 温(°C)	最低气 温(°C)	降水量 (mm)	最大风 速(m/s)	最大风 速风向 (null)	日照时 长(h)	平均相 对湿度 (%)
Pearson 相关性	-0.211**	0.315**	0.390**	0.320**	0.087	-0.050	-0.070	0.010	0.057
显著性(双侧)	0.000	0.000	0.000	0.000	0.097	0.341	0.182	0.849	0.276
N	365	365	365	365	365	365	365	365	365

**在 0.01 水平(双侧)上显著相关。

*在 0.05 水平(双侧)上显著相关。

图 1 为某城市近年用电量与各月平均气温的散点图，以及对应的二次拟合曲线。从图中明显看出，气温在高于 25 度，以及低于 5 度时，对用电量产生重要影响。




Figure 1. Scattered fitting diagram of the relationship between electricity consumption and temperature

图 1. 用电量与气温关系散点拟合图

2.2.3. 与节假日的相关性

对于中短期电量预测来说，节假日也是一个重要影响因素。特别是春节、“五一”、“十一”这三个假日，对当月用电量产生较大影响。三大假期中，由于春节是中国农历假期，故单独列出其所在阳历日期，以期分析对应影响关系。

春节是中国人民传统的节日，很多大型工厂停产放假，影响了第二产业的用电量，进而对全社会用电量产生巨大影响。表 4 为 2011~2020 年春节对应日期表。图 2 为 A 城市 2011~2020 年月度全社会用电量趋势图。

从图 2 看出，全社会用电量呈明显的周期性和规律性。形状如同“宝盖头”。峰值为每年的夏季高峰负荷，低谷为每年的春节假期。也从侧面进一步佐证，夏季高温对城市月度电量的影响程度。

Table 4. 2011~2020 Electricity consumption and spring festival date correspondence table

表 4. 2011~2020 年用电量与春节日期对应表

年份	2011 年	2012 年	2013 年	2014 年	2015 年
春节日期	2 月 3 日	1 月 23 日	2 月 10 日	1 月 31 日	2 月 19 日
年份	2016 年	2017 年	2018 年	2019 年	2020 年
春节日期	2 月 8 日	1 月 28 日	2 月 16 日	2 月 5 日	1 月 25 日




Figure 2. Trend map of monthly electricity consumption of the whole society in City A from 2011 to 2020
图 2. A 市 2011~2020 年月度全社会用电量走向图

3. 神经网络模型

3.1. BP 神经网络模型

3.1.1. BP 模型简介

BP (Back Propagation)神经网络, 具有多层神经元输入、单层神经元输出, 信号前馈、误差后馈的神经网络。通过神经元多次迭代学习和训练, 使得预测输出不断逼近期望值, 是多变量预测算法模型中应用最广泛的模型之一, 结构如图 3 所示。




Figure 3. Schematic diagram of BP neural network
图 3. BP 神经网络示意图

3.1.2. BP 神经网络预测模拟训练

1) 数据标准化

先对数据进行标准化处理, 将最小值定为 0, 最大值定为 1, 中间值用下列公式计算:

$$x_s = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3)$$

x_{\max}, x_{\min} 分别为训练样本的最大和最小值。

2) 模拟训练

由于每月总用电量与时间的关系复杂, 并非简单的线性关系, 还应考虑以前几个月用电量情况, 因此, 利用前一部分月份的用电量作为输入, 后一部分月份的用电量作为输出, 用以检验预测结果, 依次类推。

3.1.3. BP 神经网络预测流程

应用 BP 神经网络预测模型, 预测月度用电量的流程如下:

首先收集月度用电量，对数据作归一化处理；
 将数据分为训练样本和检验样本两部分，分别为输入训练数据和输出校验数据。通过多次训练，达到预测所需要的精度，即可停止训练；
 将训练好的模型结果保存，作为可供选择应用的全社会用电量预测模型，如图 4 所示。

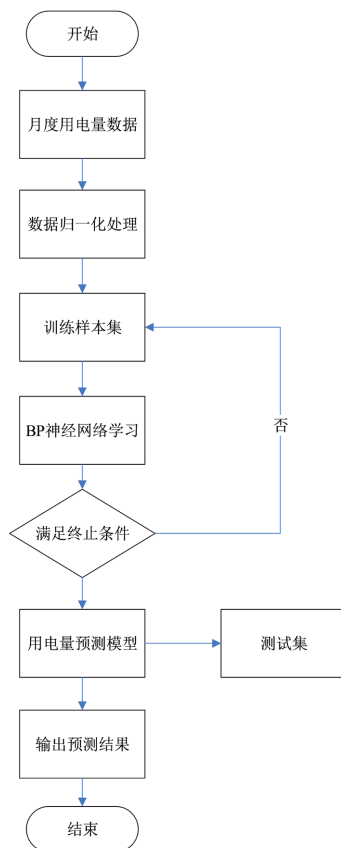


Figure 4. BP neural network prediction flowchart
 图 4. BP 神经网络预测流程图

3.2. RBF 神经网络模型

3.2.1. RBF 神经网络简介

RBF (Radical Basic Function)神经网络，利用多维空间插值技术，能够逼近任意非线性函数。它具有结构、训练简洁、学习收敛速度快，较 BP 神经网络更具优越性，其结构如图 5 所示。




Figure 5. Schematic diagram of RBF neural network structure
 图 5. RBF 神经网络结构示意图

3.2.2. RBF 神经网络预测模拟训练

近年来，RBF 神经网络以唯一最佳逼近点的优势，在预测领域的应用越来越广泛。

为保证训练的充分有效性，RBF 神经网络学习训练时，一般隐含层为输入层变量个数的 2 倍以上，且样本数据不宜小于 20 个。

根据相关遵循原则，设置好各层的参数，进行模拟训练，直到满足误差要求为止。

3.2.3. RBF 神经网络预测流程

应用 RBF 神经网络预测模型，预测月度用电量的流程如下：

首先收集月度用电量，对数据作归一化处理；

将数据分为训练样本和检验样本两部分，分别为输入训练数据和输出校验数据。通过多次训练，达到预测所需要的精度，即可停止训练；

将训练好的模型结果保存，作为可供使用的全社会用电量预测模型，如图 6 所示。

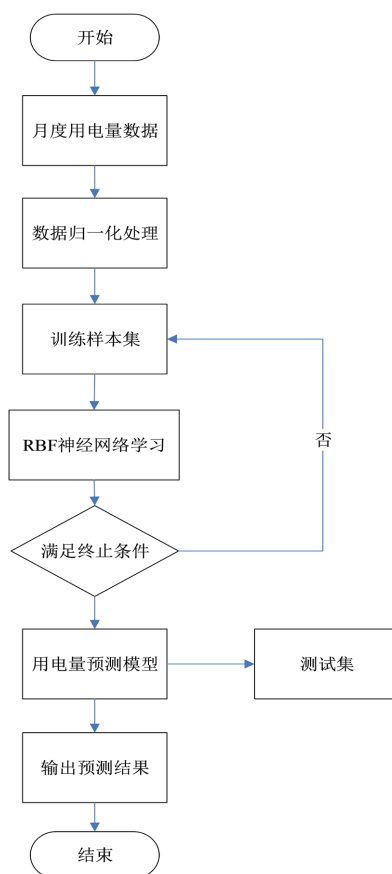


Figure 6. RBF neural network prediction flowchart

图 6. RBF 神经网络预测流程图

4. 算例分析

4.1. 实例概况

本文收集某地区 A 市 2018~2020 年电网用电量，采用以上 2 种神经网络预测模型进行月度电量预测，并与其它方法的预测结果进行校核。

4.2. BP 神经网络预测用电量

4.2.1. 训练

以 A 市 2018.1~2020.12 全社会用电量作为训练样本。将所有数据样本分成两组,其中,2018.1~2020.6 共 30 个样本作为训练组,2020.7~2020.12 共 6 个样本作为检验组。训练过程如表 5 所示。

Table 5. 2018.1~2020.6 Electricity consumption standardized value table

表 5. 2018.1~2020.6 用电量标准化值表

时间	全社会用电量	X 标准化的值	时间	全社会用电量 (万千瓦时)	X 标准化的值
2018 年 1 月	23,065.4	0.6036	2019 年 4 月	23,812.2	0.6511
2018 年 2 月	13,580.5	0	2019 年 5 月	23,852.2	0.6537
2018 年 3 月	22,472.1	0.5659	2019 年 6 月	23,899.5	0.6567
2018 年 4 月	22,297.75	0.5548	2019 年 7 月	27,593.3	0.8918
2018 年 5 月	22,926.85	0.5948	2019 年 8 月	27,939.15	0.9138
2018 年 6 月	23,151.8	0.6091	2019 年 9 月	24,036.6	0.6654
2018 年 7 月	29,293.85	1	2019 年 10 月	23,924.15	0.6583
2018 年 8 月	28,895.65	0.9747	2019 年 11 月	24,411.65	0.6893
2018 年 9 月	24,229.9	0.6777	2019 年 12 月	25,425.2	0.7538
2018 年 10 月	22,003.8	0.5361	2020 年 1 月	25,703.85	0.7715
2018 年 11 月	23,475.05	0.6297	2020 年 2 月	15,798.1	0.1411
2018 年 12 月	24,304.45	0.6825	2020 年 3 月	23,999.95	0.6631
2019 年 1 月	22,002.05	0.5359	2020 年 4 月	24,741.5	0.7103
2019 年 2 月	16,545	0.1887	2020 年 5 月	24,211.35	0.6765
2019 年 3 月	24,948.35	0.7235	2020 年 6 月	24,916.5	0.7214

4.2.2. 预测结果与分析

通过 BP 神经网络模型 600 次训练后,在满足误差精度要求下, BP 神经网络预测结果,如表 6 所示。

Table 6. BP neural network prediction results

表 6. BP 神经网络预测结果

时间	全社会用电量 (万千瓦时)	BP 神经网络预测值 (万千瓦时)	相对误差 (万千瓦时)	绝对误差
2020 年 7 月	27031.15	27022.9	-8.25	0.00%
2020 年 8 月	28271.95	28176.25	-95.7	-0.30%
2020 年 9 月	24103.1	24248.4	145.3	0.60%
2020 年 10 月	22616.85	22699.5	82.65	0.40%

Continued

2020年11月	25505.2	25576.45	71.25	0.30%
2020年12月	25633.4	25710.55	77.15	0.30%

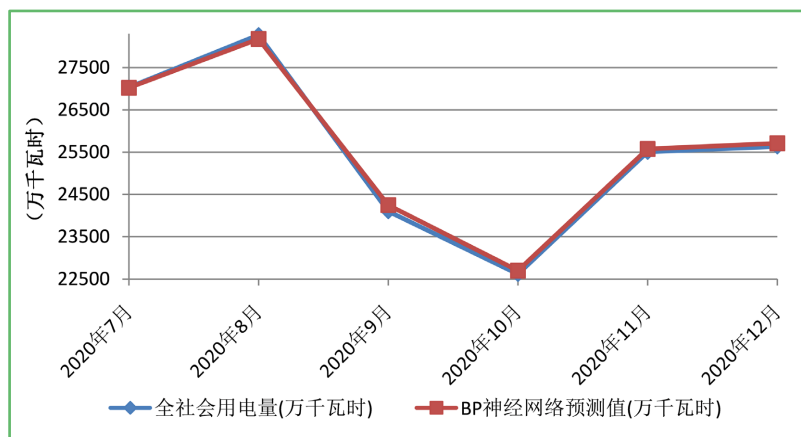


Figure 7. BP neural network prediction result fitting graph
图 7. BP 神经网络预测结果拟合图

预测值与实际值之间存在一定误差，原因分析如下：

- 1) 网络模型尚需更多的学习样本，且随着训练样本的增多，预测精度会更高。
- 2) 实际数据难免有统计误差，势必造成预测的误差。

经过检验，把 24 个月的用电量作为对第 25 个月的预测输入值，可以进一步提高预测精度。

4.3. RBF 神经网络预测用电量

采用 RBF 神经网络模型进行模拟训练，训练后的预测结果，如表 7 所示。

Table 7. RBF neural network prediction results
表 7. RBF 神经网络预测结果

时间	全社会用电量 (万千瓦时)	RBF 神经网络预测 值(万千瓦时)	相对误差 (万千瓦时)	绝对误差
2020年7月	27,031.15	27,249.15	218	0.8%
2020年8月	28,271.95	28,518.5	246.55	0.9%
2020年9月	24,103.1	24,132	28.9	0.1%
2020年10月	22,616.85	22,724.55	107.7	0.5%
2020年11月	25,505.2	25,538	32.8	0.1%
2020年12月	25,633.4	25,794.9	161.5	0.6%

从图 8、表 7 可以看出，隐含层神经元参数设置为 12 的情况下，预测结果和实际值高度拟合，具有高精度预测结果。




Figure 8. RBF neural network prediction result fitting graph
图 8. RBF 神经网络预测结果拟合图

4.4. 气象因素拟合预测用电量

按照考虑气象因素的回归模型算法，同样对上文中 A 市历史用电量进行拟合预测，预测结果如表 8、图 9 所示。

Table 8. Forecast results based on meteorological factors
表 8. 基于气象因素预测结果

时间	全社会用电量(万千瓦时)	最高温度(°C)	平均温度(°C)	最低温度(°C)	基于气温的预测值(万千瓦时)	绝对误差
2020年7月	27,031.15	32.9	29.15	25.4	30,962.25	14.50%
2020年8月	28,271.95	30.7	27.65	24.6	29,938.3	5.90%
2020年9月	24,103.1	27.9	24.95	22	26,947.6	11.80%
2020年10月	22,616.85	25	20.7	16.4	25,976.5	14.90%
2020年11月	25,505.2	19.3	15.55	11.8	26,091.25	2.30%
2020年12月	25,633.4	11.4	6.9	2.4	27,484.1	7.20%




Figure 9. Fitting diagram of prediction results of electricity consumption in the whole society based on temperature
图 9. 基于气温的全社会用电量预测结果拟合图

从图 9 可以看出, 基于气温的全社会用电量预测结果, 较为接近实际全社会用电量曲线, 有一定的拟合度, 预测结果结合本文影响因素中季节、假日等, 还可以进一步精度拟合修正。

4.5. 几种预测结果对比分析

为验证本文所提 BP 神经网络、RBF 神经网络模型方法的有效性, 将以上算例中三种方法预测结果及误差进行综合对比, 如表 9 所示。

Table 9. Comparative analysis of three prediction results

表 9. 三种预测结果对比分析

时间	全社会用电量	BP 神经网络		RBF 神经网络		基于气温预测	
		预测值	绝对误差	预测值	绝对误差	预测值	绝对误差
2020 年 7 月	27,031.15	27,022.9	0.00%	27,249.15	0.80%	30,962.25	14.50%
2020 年 8 月	28,271.95	28,176.25	-0.30%	28,518.5	0.90%	29,938.3	5.90%
2020 年 9 月	24,103.1	24,248.4	0.60%	24,132	0.10%	26,947.6	11.80%
2020 年 10 月	22,616.85	22,699.5	0.40%	22,724.55	0.50%	25,976.5	14.90%
2020 年 11 月	25,505.2	25,576.45	0.30%	25,538	0.10%	26,091.25	2.30%
2020 年 12 月	25,633.4	25,710.55	0.30%	25,794.9	0.60%	27,484.1	7.20%
平均误差		0.22%		0.50%		9.43%	

从表 9 可以看出, BP 神经网络模型、RBF 神经网络模型、基于气温预测模型, 三种预测模型方法的结果平均误差, 分别为 0.22%、0.50%、9.43%, 验证了本文所提出的 2 种神经网络预测模型预测结果, 均在 1% 的误差范围内, 具有较高的预测精度。

5. 结语

本文采用相关系数分析法, 分析出产业和能源消耗、气温、节假日等都是影响电量的重要因素。

采用 BP 神经网络和 RBF 神经网络, 通过对模型构建和训练, 其中, BP 神经网络电量预测平均误差为 0.22%; RBF 神经网络电量预测平均误差为 0.5%; 采用基于气象因素的拟合预测方法, 平均误差为 9.43%。

算例分析结果表明, 神经网络预测模型方法预测结果和实际值高度拟合, 具有较高的预测精度。

参考文献

- [1] 马杰, 李秋燕, 丁岩, 等. 含高渗透率可再生能源的配电网灵活性评价指标体系及计算方法[J]. 电力系统及其自动化学报, 2020, 32(9): 99-104, 112.
- [2] 孙可, 裴传逊, 翁秉宇. 转型发展形势下城市电网发展协调性评价[J]. 电气工程, 2020, 8(3): 98-108. <https://doi.org/10.12677/JEE.2020.83012>
- [3] 徐久益, 李自明, 姚剑峰, 等. 计及经济因素的混合模型电量预测研究[J]. 四川电力技术, 44(1): 83-88.
- [4] 张强, 王毅, 李鼎睿, 等. 基于 X-12-ARIMA 季节分解与年度电量校正的月度电量预测[J]. 电力建设, 2017, 38(1): 76-83.
- [5] 马瑞, 彭舟, 蒋诗谣, 等. 季节划分下产业用电量关联分析及预测[J]. 中国电力, 2015, 48(7): 82-88.
- [6] 魏晓川, 王新刚. 基于气象大数据的城市电力负荷预测[J]. 电测与仪表, 2021, 58(2): 90-95.
- [7] 潘良军, 王楷, 赵宏炎, 等. 基于春节影响时期分析的中期负荷智能预测[J]. 智慧电力, 2020, 48(9): 75-80, 117.

- [8] 杨俊义, 周琪, 赵宏大, 等. 春节假期对江苏电网负荷及电量影响研究[J]. 电力需求侧管理, 2015, 17(6): 19-22.
- [9] 陈广开, 陈书弘, 潘炜, 等. 基于随机森林滚动预测的电量追补算法[J]. 陕西电力, 2018, 46(12): 45-49, 104.
- [10] 岳中义. 基于神经网络的中短期电量预测模型研究[J]. 电力设备, 2018(26): 171-179.
- [11] 邓雪凝. 基于灰色关联度的 BP 神经网络模型短期用电量预测[J]. 电子技术与软件工程, 2020, 174(4): 215-217.
- [12] 崔佳豪, 毕利. 基于混合神经网络的光伏电量预测模型的研究[J]. 电力系统保护与控制, 2021, 49(13): 142-149.