

# 文本复制检测报告单(全文标明引文)

№:ADBD2021R\_2021072315351220210723154732311182882693

检测时间:2021-07-23 15:47:32

检测文献: 002

作者: 养方式

检测范围: 中国学术期刊网络出版总库

中国博士学位论文全文数据库/中国优秀硕士学位论文全文数据库

中国重要会议论文全文数据库

中国重要报纸全文数据库

中国专利全文数据库

图书资源

优先出版文献库

学术论文联合比数据库

互联网资源(包含贴吧等论坛资源)

英文数据库(涵盖期刊、博硕、会议的英文数据以及德国Springer、英国Taylor&Francis 期刊数据库等)

港澳台学术文献库

互联网文档资源

源代码库

CNKI大成编客-原创作品库

个人比数据库

时间范围: 1900-01-01至2021-07-23

## 检测结果

去除本人文献复制比: 32.4%

跨语言检测结果: 0%

去除引用文献复制比: 32.4%

总文字复制比: 32.4%

单篇最大文字复制比: 23.7% (基于BP神经网络的短期电力负荷预测的研究)

重复字数: [9078]

总段落数: [3]

总字数: [28061]

疑似段落数: [3]

单篇最大重复字数: [6646]

前部重合字数: [117]

疑似段落最大重合字数: [4244]

后部重合字数: [8961]

疑似段落最小重合字数: [1167]



指 标: ☒ 疑似剽窃观点 ☒ 疑似剽窃文字表述 ☐ 疑似整体剽窃 ☐ 过度引用

表 格: 0

公 式: 没有公式

疑似文字的图片: 0

脚注与尾注: 0

12.2%(1167) 12.2%(1167) 002\_第1部分 (总9593字)

36.2%(3667) 36.2%(3667) 002\_第2部分 (总10131字)

50.9%(4244) 50.9%(4244) 002\_第3部分 (总8337字)



(注释: 无问题部分 文字复制部分 引用部分)

疑似剽窃观点 (8)

002\_第1部分

- 如果在预测过程中选择了多种预测方法, 那么最后就要分别对其预测结果进行误差分析, 然后评价到底哪个方法更好, 更能达到我们想要的结果; 当然也可以使用一种我们认为比较好的预测方法, 在其预测过程中, 可能会使用到不同的算法等问题, 这样最后我们就可以对经过不同算法之后的预测结果进行分析, 然后得出最优的预测算法。

002\_第2部分

- 年的负荷曲线, 可以看出, 每年的负荷变化基本上是相似的, 每年负荷最高峰和最低谷基本一致, 每年的夏季是年负荷高峰期, 因为炎热的夏季气温升高, 会引起空调等制冷设备的投入, 使得负荷升高, 这个时段基本上都在 7、8 月份。
- 如图 3-3 所示, 描述的是 A 市 2019 年 6 月、7 月和 8 月负荷的变化曲线, 从图中曲线可以看出, 每个月每个周的负荷的变化趋势是一致的, 虽然具体到

同类型日的负荷量不同，但是这里的周期性只表示每周的负荷变化趋势。

3. 进一步的分析，可以看出，每天的日负荷最大值出现在白天，而最小负荷出现在夜里，因为，白天人们都活动或者工作，负荷量大，而夜里，人们都已经休息，很显然负荷就小。

- 002\_第3部分
1. 可以看出，训练达到我们所期望的误差范围即 0.001 时所需要的训练步数是 500。
  2. 可以看出在训练到 46 步的时候，网络就训练到了我们所要求的误差范围。
  3. 对于隐含层节点数的选取同样要进行试凑，从表 4-5 中可以看出选取 28 个节点是最为合适的。
  4. 算法预测效果最佳，本文选取该算法对 BP 神经网络进行优化计算。

1. 002_第1部分		总字数：9593
相似文献列表		
去除本人文献复制比：12.2%(1167)      文字复制比：12.2%(1167)      疑似剽窃观点：(1)		
1	用于购供售一体化管理系统的短期电力负荷预测 - 《学术论文联合比对库》- 2015-05-30	9.1% (876) 是否引证：否
2	基于BP神经网络的短期电力负荷预测的研究 隋惠惠(导师：王宏) - 《哈尔滨工业大学硕士论文》- 2015-06-01	9.1% (874) 是否引证：否
3	13S053069-隋惠惠-王宏 隋惠惠 - 《学术论文联合比对库》- 2015-06-11	9.0% (864) 是否引证：否
4	2436800_电源与电机研究_电力电子大师兄 电源与电机研究 - 《学术论文联合比对库》- 2015-06-04	9.0% (864) 是否引证：否
5	3_吴云_基于改进灰色关联与蝙蝠优化神经网络的短期负荷预测 吴云 - 《学术论文联合比对库》- 2019-03-20	2.1% (198) 是否引证：否
6	基于小波神经网络的电力系统短期负荷预测模型研究 祖哲;毕贵红;刘力;郝娟; - 《计算机技术与发展》- 2012-10-10	0.7% (70) 是否引证：否
7	考虑可靠性的混编公交车计划编制研究 范毓琳(导师：姚恩建) - 《北京交通大学硕士论文》- 2020-06-30	0.6% (62) 是否引证：否
8	基于BP人工神经网络的电力短期负荷预测 曲薇薇(导师：段玉波) - 《东北石油大学硕士论文》- 2011-03-26	0.4% (35) 是否引证：否
9	基于PSO-BP神经网络的DOA估计方法 孟非;王旭; - 《电讯技术》- 2012-05-20	0.3% (30) 是否引证：否

原文内容

专业硕士学位论文基于神经网络的电力负荷预测研究  
2021 年 8 月  
中图分类号：×××× 学校代码：×××  
UDC：××× 密级：公开  
专业硕士学位论文基于神经网络的电力负荷预测研究  
硕士研究生：□□□  
导师：□□□(副)教授企业导师：□□□高工  
申请学位：工程硕士  
专业领域：电气工程培养方式：在职  
所在学院：电气与电子工程学院  
答辩日期：2021 年 8 月  
授予学位单位：华北电力大学I  
摘要

电力负荷预测是电力管理中的主要内容，直接影响到整个电力系统的运行状况与稳定状况，而电力负荷预测精度与电力部门的经济和管理效益有很大关系。随着我国社会发展，用户对电量的需求以及电能质量的要求也在不断增加，导致电力负荷预测困难。因此在这样的背景下本文基于我国电力负荷需求实际情况进行分析，  
构建 BP 神经网络模型，利用该模型对电力负荷情况进行预测。但是在传统方式下BP 神经网络又存在收敛速度慢、易陷入局部极小、易波动等问题，因此对传统 BP 神经网络进行改进十分有必要。

本研究首先对电力负荷预测情况进行分析，了解电力负荷预测的特点以及预测流程，然后对神经网络进行分析，通过对 BP 神经网络结构、算法等相关问题进行探讨，构建基于 BP 神经网络的电力负荷预测模型。但是笔者结合以往研究成果和应用经验可知标准 BP 神经网络存在一定的问题，导致预测精度低，因此笔者在标准 BP 神经网络的基础上进行了改进，并分析三种优化算法对 BP 神经网络模型应用效果的影响。经过对比发现 L-M 算法在 A 市电力负荷预测计算精度高，因此利用该算法进

行预测，分析 7 月份电力负荷情况，验证改进 BP 神经网络电力负荷模型的可行性。

关键词：神经网络；电力负荷；预测模型；预测精度

II

Abstract

Power load forecasting is the main content of power management, which directly affects the operation and stability of the whole power system, and the accuracy of power load forecasting has a great relationship with the economic and management benefits of the power sector. With the social development of our country, the demand of users for electricity and the demand of power quality are also increasing, which leads to the difficulty of power load forecasting. Therefore, in this context, based on the actual situation of China's power load demand, this paper analyzes the construction of BP neural network model, using the model to predict the power load. However, in the traditional BP neural network, the convergence speed is slow, easy to fall into local minimum, easy to fluctuate and other problems, so it is very necessary to improve the traditional BP neural network.

This study first analyzes the situation of power load prediction, to understand the characteristics of power load prediction and the process of prediction, and then analyzes the neural network, through the BP neural network structure, algorithm and other related issues are discussed, to build a BP neural network based on the power load prediction model. However, the author combined previous research results and application experience to know that the standard BP neural network has some problems, resulting in low prediction accuracy. Therefore, the author made improvements on the basis of the standard BP neural network, and analyzed the influence of three optimization algorithms on the application effect of the BP neural network model. Through comparison, it is found that L-M algorithm has A high accuracy in power load prediction in A city. Therefore, this algorithm is used to forecast, analyze the power load in July, and verify the feasibility of improving the BP neural network power load model.

Key words: Neural network; Power load; Prediction model; Prediction accuracy

III

目录

摘要

.....	I
Abstract .....	II
目录 .....	III
第 1 章绪论 .....	
.....	1
1.1 研究背景和意义 .....	
.....	1
1.2 国内外研究现状 .....	
.....	1
1.2.1 国内研究现状 .....	
.....	1
1.2.2 国外研究现状 .....	
.....	3
1.3 论文主要研究内容 .....	
.....	4
第 2 章电力负荷预测理论分析 .....	
.....	5
2.1 电力负荷预测 .....	

2.2 电力负荷预测步骤	5
2.3 BP 神经网络介绍	5
2.3.1 BP 神经网络概念及原理	6
2.3.2 BP 神经网络结构	7
2.3.3 BP 神经网络的学习算法	8
2.3 本章小结	11
第 3 章基于神经网络电力负荷预测模型的建立	12
3.1 模型建立	12
3.1.1 模型数据处理	12
3.1.2 网络拓扑结构	12
3.2 A 市电力负荷基本情况	14
3.3 实例分析	15
3.4 本章小结	17
第 4 章基于改进 BP 神经网络的电力负荷预测研究	19
4.1 标准 BP 网络的优缺点	19
4.2 BP 算法的改进	20
4.3 实例分析	21
4.3.1 基于自适应 BP 算法的负荷预测	21
4.3.2 基于弹性梯度 BP 算法的负荷预测	24
4.3.3 基于 L-M 法的 BP 算法的负荷预测	
IV	
4.3.4 三种优化算法负荷预测结果对比	28
4.3.5 基于 L-M 法的负荷预测	

.....	29
4.5 本章小结	
.....	31
结论	
.....	33
参考文献	
.....	34
攻读硕士学位期间发表的论文及其它成果	
.....	37
致谢	
.....	38
作者简介	
.....	1

## 第 1 章绪论

1.1 研究背景和意义电力行业是关系我国国民经济命脉的一项支柱型行业，能够带动我国经济发展。电力行业发展的稳定性直接决定了我国国家安全和省会的稳定，因此保证电力稳定至关重要。尤其是在最近几年的发展中不管是生产还是生活都离不开电力，客户对电网运行质量提出了更高要求。在现代电网中如何对电力负荷进行准确预测就成为关键性问题[1]。准确实现电力负荷预测能够为电网电能调度提供具体方案，也能够起到节省能源，实现可持续发展目的。因此如何保证电力负荷预测准确性已经成为当前亟待解决的一大问题。

为了深入分析电网中电力负荷，了解电网内负荷变化状态就要求在电力负荷预测时能够对多种不同类型的电力类型进行分析，了解用户对电力负荷需求状况，这样才能够更好的预测电力负荷，除此之外在电力负荷预测时还需要采取合适的技术和预测方式，比如说神经网络预测等，通过这些科学技术和方法能够保证电力负荷预测的精度和预测的准确度。在电力负荷预测时还需要充分的考虑到气象数据等对负荷模型的影响，因此本文在进行研究时通过对电力负荷预测现状进行分析，然后将神经网络应用到电力负荷预测中，通过神经网络高精度计算优势从而有效提高预测的精度，这样能够对电力系统运行提供理论依据，保证整个系统能够处于正常运行状态下，因此对电力负荷预测研究十分有必要。

### 1.2 国内外研究现状

1.2.1 国内研究现状国内在电力负荷预测方面主要是根据不同的网络搭建不同负荷预测模型，然后利用计算方法的优势彰显出负荷预测的精度。而且国内在研究时侧重于神经网络模型，并将该模型与遗传算法、粒子群算法等多种方式解决神经网络易波动、误差大、

精度低等问题。通过对改进神经网络模型进行分析，验证方案的优越性和可行性。

(1) 关于 BP 神经网络模型构建的研究李文认为人工神经网络的出现能够对电力系统中的负荷情况进行准确预测，从而为电力保障奠定基础，因此其在进行研究时通过 Elman 神经网络进行分析，然后将该神经网络应用到电力负荷中，最后利用 MatLab 软件对基于 Elman 神经网络的电力负荷模型进行仿真测试。经过测试发现 Elman 神经网络能够在电力系统预测中起到良好效果[3]。罗育辉等人认为电力负荷存在随机性大、稳定性差、预测难度大等问题，针对这一问题提出了基于最大偏差相似性的 BP 神经网络预测模型。在该模型中首先会根据最大偏差相似的原则提出负荷数据特征，然后确定预测日的相似日，然后对这些相似日的历史负荷数据进行提取，利用 BP 神经网络的作用对历史 2

负荷数据进行训练。经过实验验证发现所提出的改进 BP 神经网络模型在实际的应用过程中能够具有良好的预测精度，并且在进行样本数据训练时所花费的时间比较短，但是其所起到的实效性却非常强[4]。王家兰等人提出了基于 RBF 神经网络的电力负荷模型，通过对该模型中的历史参数进行负荷相似排列，这样可以有效降低预测误差。同时还以误差为对象进行分析，提出抑制波动策略[5]。李琛等人以北京夏季为对象，对该区域在 2006 年到 2017 年之间的气象资料以及电力负荷参数进行分析和整理，发现在该区域内气象因素也是影响北京电力负荷情况的一个主要因素，

因此在该影响因素下建立 BP 神经网络。将网络计算的预测值与北京地区实际的电力负荷值进行对比分析，发现其所提出的模型预测精度高，预测效果佳，可以在实际负荷预测中应用[6]。陈卓等人认为电力负荷预测能够提高电力系统运行稳定性，

因此其在进行研究时提出了长短期记忆功能的神经网络模型，在该模型中能够对电力系统中的长短期电力负荷情况进行预测。与传统预测模型相比，本文所构建的模型应用效果更佳，其在实际应用时所预测的结果与传统模型所测量的结果更接近实际值，因此可以说其所搭建的模型精度更好[7]。

#### (2) 关于 BP 神经网络算法优化的研究

一是粒子群算法在 BP 神经网络算法优化中的应用。胡亚超等人认为电力负荷存在非线性、冗余度大等特点，如果采用传统负荷预测方式很难起到良好预测效果。

因此其在进行研究时首先利用主成分分析法对历史数据进行筛选，选择合适的历史参数作为样本输入到径向基函数神经网络中。然后对样本数据进行训练和检验。接着利用粒子群算法进行优化计算。最后根据某地区 2016 年的电力负荷参数为基础进行神经网络电力负荷预测模型研究。经过研究发现在电力负荷预测中采用径向基函数神经网络和粒子群优化算法之后预测精度有明显提升[8]。

二是 L-M 算法在 BP 神经网络算法优化中的应用。陈亚等人通过对电力负荷情况进行分析，并提出基于 BP 神经网络和 Elman 神经网络两种不同的电力负荷预测方式。其在进行研究时认为利用附加动量法能够很好的对 BP 神经网络模型中所应用



到的数据进行分析,优化神经网络计算结果,大大提高模型计算的收敛速度,而采用 L-M 算法的作用则可以有效解决 Elman 神经网络模型易陷入局部极值问题。

最后进行仿真验证。经过验证发现经过改进之后的模型可以起到良好预测效果,而且改进 Elman 神经网络模型要比 BP 神经网络模型预测精度更高,而且收敛的速度也更快一些,因此 Elman 神经网络模型可以在动态变化的系统中进行应用[9]。

三是遗传算法在 BP 神经网络算法优化中的应用。杨蕊等人通过对电力负荷变化情况进行分析发现其存在随机性等特点,因此其在标准 BP 神经网络预测模型的基础上提出了相似日优化算法。通过对相似日的气象因素、时间因素、距离因素等多个不同的影响因素进行分析和研究,搭建 BP 神经网络模型,并利用遗传算法对 3

网络模型进行计算。通过遗传算法能够快速的计算出模型中权值和阈值大小。经过仿真测试可知该预测方式具有良好的预测精度和稳定性,能够保证预测效果[10]。王帅哲等人认为对短期电力负荷预测能够有效降低发电成本。因此通过对区域内的电力负荷情况进行研究和分析,然后搭建标准 BP 神经网络。为了提高网络精度,分别采用遗传算法和模拟退火算法两种不同的算法进行优化计算。在两种算法下都可以起到良好预测结果[11]。

四是自适应算法在 BP 神经网络算法优化中的应用。袁小凯等人在传统神经网络的基础上提出了随机抽样方式,在该方式下能够对多组数据进行训练的处理形成一个完整的神经网络,然后输出结果。为了保证神经网络的计算精度,还采用自适应算法的作用缩小误差。经过仿真测试表明该方法能够有效减小误差[12]。

从国内在电力负荷预测研究方面成果可以发现神经网络电力负荷预测模型具有良好的测量精度,将其与传统模型进行对比分析可知预测精度要高很多。虽然预测精度有很大提升,但是在实际应用过程中还很容易陷入局部极小问题、波动问题、

预测精度低等问题中,最终影响到预测精度。目前国内学者大都是对计算方法进行选择,比如说遗传算法、粒子群算法等。而本文研究时就以此我基础,通过利用 L-M

算法对 BP 神经网络进行改进,从而提高 BP 神经网络的预测精度。

1.2.2 国外研究现状国外对电力负荷预测方面研究起步较早,在上世纪的五六十年代中就开始利用神经网络进行气候预测,但是由于当时神经网络研究还处于初级阶段,应用并不是很广泛。直到八十年代神经网络中的隐含层连接权问题才得以解决,并在多个领域中进行推广应用,并逐渐在电力领域中发挥重要作用。

(1) 关于 BP 神经网络模型构建的研究Jahan 等人通过对不同类型的电力负荷预测技术进行分析,研究这些技术在应用时所存在的问题。经过整理分析发现最为常见的电力负荷预测技术有:人工神经网络、支持向量回归、决策树、线性回归和模糊集。而且其在研究时还针对电力负荷预测的概念进行了明确的分析和界定[13]。Sideratos 等人针对市场能源变化提出了周前负荷预测模型。首先可以利用三次交叉的方式对径向基函数神经网络进行训练,然后将最佳训练结果应用到神经网络中进行处理,转换为思维数据集。接着利用卷积神经网络对数据集进行处理。最后得到输出结果。在该模型中能够对未来七天内的电力负荷情况进行预测[14]。Saviozzi 等人提出了基于人工神经网络的预测模型,并将该模型应用到实际的电网中。经过应用发现人工神经网络模型能够有效解决电力负荷需求不确定性问题,实现资源的最佳配置[15]。Motepe 等人利用混合人工智能和深度学习技术构建了电力负荷预测模型,并在南非配电网中进行应用。在该模型中能够利用模糊逻辑分析法对电网数据进行分析

和预测,采集数据参数,然后 4 进行电力负荷需求预测[16]。

(2) 关于 BP 神经网络算法优化的研究在算法优化中主要是通过一定的计算方法,并将该算法应用到神经网络计算中,优化计算结果。De 等人开发了人工神经网络和模糊逻辑相结合的电力负荷预测模型,在该模型中能够对神经网络中的参数等进行调整和优化,改变传统电力负荷预测方式下的不足之处,从而制定出弹性电力生产计划[17]。López 等人提出了基于自适应和神经网络相结合的电力负荷预测模型,并将该模型投入到西班牙电力负荷预测中。经过实际应用分析可知模型能够根据历史参数预测出未来 9 天的电力需求,而且可以将误差控制在合理范围内[18]。Talaat 等人构建了基于中短期的电力负荷预测模型,利用该模型能够对每日、每时的电力负荷情况进行预测。在预测模型中能够利用前馈神经网络和 grasshopper 优化算法的作用进行模型处理,从而提高负荷预测模型精度。经过实验测试可知该模型能够将精度控制在-0.006 到 0.006 误差范围内[19]。Afrasiabi 等人利用卷积神经网络和门控回归单元相结合的方式进行电力负荷预测,并将历史负荷参数输入到模型中进行处理,输出数据集,接着利用自适应核密度估计方法进行计算,提取其中的概率特征。与此同时其在研究时还将所提出的预测模型与其他算法进行对比,突出方案的优势[20]。

1.3 论文主要研究内容笔者在进行研究时主要的研究内容包括以下几方面:

(1) 总结国内外研究成果,分析研究内容,寻找本文研究切入点,然后确定本文研究内容。通过文献资料分析掌握国内外对电力负荷预测的概念以及 BP 神经网络基本算法。

(2) 对 BP 神经网络进行分析,了解其基本的原理、网络结构、算法等相关研究,然后在此基础上构建基于 BP 神经网络的电力负荷模型。阐述在 BP 神经网络下数据处理、建立模型过程,并通过实际的 A 市案例对 BP 神经网络负荷预测性能进行测试。

(3) 对 BP 神经网络进行分析,提出其应用的优缺点,然后提出改进 BP 神经网络负荷预测模型,并对模型三种改进算法进行分别计算、对比,得到最佳的改进算法,然后将改进算法应用到 BP 神经网络中,然后以 A 市实际算例中进行验证,确定模型可行性。 5

第 2 章电力负荷预测理论分析  
2.1 电力负荷预测电力负荷预测主要的对象就是电网中的电力状况,因此在开展电力负荷预测之前需要清晰的定位电力负荷,明确电力负荷的概念。从本质上来说电力负荷就是在整个电力系统运行中所需要的所有负荷之和,是所有用电设备所需要的总负荷。电力负荷是用户用电设备在使用过程中所有电能的需求量,也是发电厂的发电厂经过输电线路的作用为用户所提供的电力负荷。

电力负荷预测就是根据用户需求、电力系统运行情况,然后综合考虑多种不同因素对电力系统中的电能参数进行预测的过程。电力负荷预测需要了解电网以往运行参数,并且选择合理且有效的预测方法建立长期且有效的预测应用模型,利用该模型的作用能够对某一区域或者是某一个时间段的用电情况进行准确判断,以便为电能生产提供支持[21-23]。

根据当前在电力负荷预测方面的研究成果分析,主要集中在长期、中期和短期三方面负荷预测研究,通过负荷预测能够能

够有效指挥电能生产，实现电力资源的优化配置。本文则主要是对短期电力负荷预测进行探究。

2.2 电力负荷预测步骤要想做好电力负荷预测工作，就先知道负荷预测步骤是怎样的，不能一味的盲目的去干。具体步骤如下：

(1) 确定想要预测的地区及时间问题。在预测之前，首先需要确定自己想要预测负荷的时间长短即长、中、短还是超短期乃至负荷所在的地点。只有先确定我们想预测负荷期限，才能有目的的去搜集历史数据，不至于搜集过多导致繁琐，也不至于搜集过少导致预测不准。

(2) 收集获取可靠历史信息。历史信息包括历史负荷数据以及我们所要用到的气象因素比如每天气温还有天气状况等信息，搜集可靠的数据是准确预测的一个关键，数据不准确，预测也就不会达到预期的效果。历史负荷数据我们可以通过有关电力部门获取。

(3) 对历史信息进行分析并处理。这一步在负荷预测当中也是必不可少的，因为即使我们从电力部门获得了数据，这些数据也会因为各种原因比如采集设备或者人为因素而存在缺陷比如缺失或者误差。因此搜集到数据之后，一定要对所有的数据进行分析并且进行一定的处理，我们称之为预处理，这样才能保证所用数据的完整性以及准确性，才能在后期的预测工作中达到我们要求的预测精度，显然这一点是及其重要的。

(4) 确立合适的预测方法并建立预测模型。电力负荷进行预测的方法有很多，因此我们可以有很多种选择，但是每种方法有他们的优缺点，我们要根据具体的情况具体分析用哪一种方法更合适。在实际操作中，也可以选用多种方法来进行预测，最后再行比较，然后选择出最佳的预测方法。

(5) 对预测结果进行误差分析并评价。如果在预测过程中选择了多种预测方法，那么最后就要分别对其预测结果进行误差分析，然后评价到底哪个方法更好，更能达到我们想要的结果；当然也可以使用一种我们认为比较好的预测方法，在其预测过程中，可能会使用到不同的算法等问题，这样最后我们就可以对经过不同算法之后的预测结果进行分析，然后得出最优的预测算法。本文就是应用了一种方法即 BP 神经网络预测法，并且应用了多种算法，最后对其分析，得到最佳算法。

以上对负荷预测的基本步骤做了一个简单描述，图 2-1 更简洁的展示了负荷预测的步骤。  
开始收集历史数据历史数据处理建立负荷预测模型模型参数估计预测误差分析优化算法输出预测值结束图 2-1 负荷预测基本步骤

2.3 BP 神经网络介绍

2.3.1 BP 神经网络概念及原理BP 神经网络是以反向传播学习为机理，最终达到计算结果要求的一种网络，因此神经网络又被称为反向传播神经网络。利用 BP 神经网络进行计算之前首先需要从网络模型中选取样本数据。通过网络中的自学习功能对选取的数据样本进行训练。当训练结果达到要求之后结束训练任务。根据训练过程设置网络的权值和阈值最终得到精确输出结果。利用神经网络进行计算之后所得数据与期望值数据之间相差不大，这就说明网络模型具有良好计算精度，此时之后利用该网络进行数据分析

和计算时还能够具有良好的非线性特性、容错能力强等优势，因此被广泛的应用到各领域[27-28]。7  
BP 神经网络在应用时主要是通过通过对实际值和预测值之间的误差为信号，然后实现数据反向传输控制，通过对神经网络中的权值和阈值进行调整，得到与预测值相差不大的实际输出值，从而结束训练，这是神经网络在进行非线性数据参数处理时的基本原理。与其他数据处理方式相比，BP 神经网络计算过程较为简单，不需要具体的模型，而且训练样本数据所呈现的规律也不需要明确，只要所得到的输出值能够在误差允许范围内即可。利用 BP 神经网络中的数据规律可以通过对网络调整参数来体现。

2.3.2 BP 神经网络结构BP 神经网络是一个多层网络结构，其中最为常见的是三层结构，示意图如图 2-2 所示。

输入层隐含层输出层输出结果信号修改权值阈值修改权值阈值图 2-2 BP 神经网络结构在多层 BP 神经网络中第一层是 BP 神经网络中的输入层，在该层次中可以将样本的数据输入到模型中。最后一层则是 BP 神经网络中的输出层，在该层次中会将经过模型之后的计算结果输出。其余的层次均为 BP 神经网络的隐含层。由于 BP 神经网络最少是三层结构，因此隐含层至少有一个，对于多层神经网络而言，隐含层的数量可以是多个。在同一个层次上不同的神经元之间没有连接，而不同层次上的每一个神经元都会与上下层之间的每一个神经元之间进行连接，从而实现数据计算。

BP 神经网络的训练过程，主要包含以下两个步骤：  
一号正向传播过程。在该过程中主要是以输入信号为主要传播对象。此时需要将所需要训练的进行训练的样本数据作为输入数据，输入到输入层中，然后信号经过输入层进入到隐含层中进行数据计算，经过计算之后将结果传递给输出层，并对输出层的输出结果进行对比。如果经过对比之后所得到的实际结果与预期结果之间的误差非常大，不符合要求，此时就需要以误差值作为对象反向传播。二是反向传播过程。  
在该过程中主要是以误差值作为主要的传递信号，此时需要将经过计算之后的误差值输入到输入层中，然后对各层之间的权值进行调整，使得输出层的误差不断减小，最终达到要求，训练过程结束。

指 标
疑似剽窃观点
1. 如果在预测过程中选择了多种预测方法，那么最后就要分别对其预测结果进行误差分析，然后评价到底哪个方法更好，更能达到我们想要的结果；当然也可以使用一种我们认为比较好的预测方法，在其预测过程中，可能会使用到不同的算法等问题，这样最后我们就可以对经过不同算法之后的预测结果进行分析，然后得出最优的预测算法。



1. BP neural network, the convergence speed is slow, easy to fall into local minimum,
2. 负荷预测步骤要想做好电力负荷预测工作,就要先知道负荷预测步骤是怎样的,不能一味的盲目的去干。
3. 在预测之前,首先需要确定自己想要预测负荷的时间长短即长、中、短还是超短期乃至负荷所在的地点。只有先确定我们想预测负荷期限,才能有目的的去搜集历史数据,不至于搜集过多导致繁琐,也不至于搜集过少导致预测不准。
4. 历史信息包括历史负荷数据以及我们所要用到的气象因素比如每天气温还有天气状况等信息,搜集可靠的数据是准确预测的一个关键,数据不准确,预测也就不会达到预期的效果。历史负荷数据我们可以通过有关电力部门获取。
5. 这一步在负荷预测当中也是必不可少的,因为即使我们从电力部门获得了数据,这些数据也会因为各种原因比如采集设备或者人为因素而存在缺陷比如缺失或者误差。因此搜集到数据之后,一定要对所有的数据进行分析并且进行一定的处理,我们称之为预处理,这样才能保证所用数据的完整性以及准确性,才能在后期的预测工作中达到我们要求的预测精度,显然这一点是及其重要的。
6. 电力负荷进行预测的方法有很多, 6 因此我们可以有很多种的选择,但是每种方法有他们的优缺点,我们要根据具体的情况具体分析用哪一种方法更合适。在实际操作中,也可以选用多种方法来进行预测,最后再进行比较,然后选择出最佳的预测方法。
7. 本文就是应用了一种方法即 BP 神经网络预测法,并且应用了多种算法,最后对其分析,得到最佳算法。以上对负荷预测的基本步骤做了一个简单描述,图 2-1 更简洁的展示了负荷预测的步骤。

## 2. 002\_第2部分

总字数: 10131

## 相似文献列表

去除本人文献复制比: 36.2%(3667)

文字复制比: 36.2%(3667)

疑似剽窃观点: (3)

1	基于BP神经网络的短期电力负荷预测的研究 隋惠惠(导师:王宏) - 《哈尔滨工业大学硕士论文》- 2015-06-01	23.7% (2402) 是否引证: 否
2	12602466_李灿_基于改进BP神经网络的负荷预测问题研究 李灿 - 《学术论文联合比对库》- 2018-05-02	20.7% (2095) 是否引证: 否
3	13S053069-隋惠惠-王宏 隋惠惠 - 《学术论文联合比对库》- 2015-06-11	17.3% (1748) 是否引证: 否
4	2436800_电源与电机研究_电力电子大师兄 电源与电机研究 - 《学术论文联合比对库》- 2015-06-04	17.3% (1748) 是否引证: 否
5	用于购供售一体化管理系统的短期电力负荷预测 - 《学术论文联合比对库》- 2015-05-30	17.1% (1734) 是否引证: 否
6	李灿-论文最终版0625 - 《学术论文联合比对库》- 2018-06-27	14.9% (1510) 是否引证: 否
7	基于改进BP神经网络的负荷预测问题研究 李灿(导师:姚李孝) - 《西安理工大学硕士论文》- 2018-06-30	14.8% (1498) 是否引证: 否
8	1525416377981_李灿_基于改进BP神经网络的负荷预测问题研究 李灿 - 《学术论文联合比对库》- 2018-05-04	13.5% (1370) 是否引证: 否
9	01212502458530074_高李陈_新能源与建筑用电节能 高李陈 - 《学术论文联合比对库》- 2017-03-20	6.1% (617) 是否引证: 否
10	3-刘杰 刘杰 - 《学术论文联合比对库》- 2019-11-05	5.3% (539) 是否引证: 否
11	毛罗陆林_基于平衡成本分析的风电分段价值发现研究 毛罗陆林 - 《学术论文联合比对库》- 2017-03-29	4.3% (440) 是否引证: 否
12	基于SOM和BP神经网络的配电网台区低电压预测 肖林煌 - 《学术论文联合比对库》- 2019-04-17	4.3% (438) 是否引证: 否
13	杨丹丹-149910002-电力电子与电力传动 杨丹丹 - 《学术论文联合比对库》- 2017-02-26	4.1% (417) 是否引证: 否
14	10_21410182_程宇也 程宇也 - 《学术论文联合比对库》- 2017-03-02	2.1% (216) 是否引证: 否
15	王政-142419017-基于广义回归神经网络的短期电力负荷预测模型 王政 - 《学术论文联合比对库》- 2017-03-18	1.3% (136) 是否引证: 否
16	王政-142419017-基于广义回归神经网络的短期电力负荷预测模型 - 查重版	1.3% (136)



	王政 - 《学术论文联合比对库》 - 2017-03-17	是否引证：否
17	供配电需求侧智能监控系统研究 占潮(导师：徐惠勇;周军利) - 《中国地质大学(北京)硕士论文》 - 2016-05-01	0.7% (72) 是否引证：否
18	2104130017占潮 - 《学术论文联合比对库》 - 2016-06-12	0.7% (72) 是否引证：否
19	12254664_李帅 李帅 - 《学术论文联合比对库》 - 2018-04-16	0.6% (65) 是否引证：否
20	区域农业水土资源系统风险特征及其对种植结构的影响效应研究 李帅(导师：刘东) - 《东北农业大学硕士论文》 - 2018-06-01	0.6% (65) 是否引证：否

原文内容

在进行迭代训练计算时可以不断的提高 BP 神经网络模型的计算精度[29-30]。

2.3.3 BP 神经网络的学习算法对于一个三层结构的 BP 神经网络而言，加入在该网络的输入层所输入的信号向量表达式为  $x = (x_1, x_2, \dots, x_n)^T$ ，假设此时向量中存在以下参数：  $0 < x_i \leq 1$ ，这样在 BP 神经网络中隐含层的神经元个数就会存在一个临界值；然后设定 BP 神经网络的输出向量的表达式为  $y = (y_1, y_2, \dots, y_m)^T$ ，隐含层向量的表达式为  $z = (z_1, z_2, \dots, z_n)^T$ ，设定向量中存在以下参数：  $0 < y_j \leq 1$ ，这样在 BP 神经网络中输出层的神经元个数就会存在一个临界值；假设在 BP 神经网络中输出层预期的输出向量为  $y$ ，输入层向量为  $x$ ，隐含层向量为  $z$ ，则神经网络中各层的权值表达式为：

输入层与隐含层之间的权值表达式为  $w_{kj}$ ，在隐含层中的神经元  $k$  处所对应的权值向量表达式为  $w_k = (w_{k1}, w_{k2}, \dots, w_{kn})^T$ 。BP 神经网络中隐含层与输出层之间所设置的权值向量的表达式为  $v_{mj}$ ，在隐含层中的神经元  $j$  处所对应的权值向量表达式为  $v_j = (v_{j1}, v_{j2}, \dots, v_{jm})^T$ 。这样在整个 BP 神经网络中存在：

输入层中存在以下表达式：

$$f_{netk} = \sum_{j=1}^n w_{kj} x_j \quad (2-1)$$

隐含层中存在以下表达式：

$$y_j = f_{netj} = \sum_{k=1}^n v_{jk} z_k \quad (2-2)$$

输出层中存在以下表达式：

$$f_{netm} = \sum_{j=1}^n v_{mj} y_j \quad (2-3)$$

在以上的计算公式中  $f(x)$  所代表的是神经网络的变换函数具体函数的计算表达式为：

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2-4)$$

此时将函数进行转变，转变为双曲线正切函数，具体的表达式为：

$$f(x) = \frac{e^x - 1}{e^x + 1} \quad (2-5)$$

此时就可以得到具体的三层 BP 神经网络模型为：

$$y = \sum_{m=1}^M v_{mj} f(\sum_{k=1}^N v_{jk} f(\sum_{i=1}^N w_{ki} x_i)) \quad (2-6)$$

$f_{net\ k\ l}$

$ef_x$

$e$

$L_{(2-7)}$

在该模型中期望值计算表达式为： $21\ 1(\ )(\ )\ 2\ 2$

$l$

$k\ k$

$k\ l$

$E\ d\ o\ d\ o\quad(2-8)$

如果在神经网络中  $E$  可以拓展到隐含层中，此时则存在： $2\ 2\ 0\ 1\ 1(\ )(\ )\ 2\ 2$

$l\ l\ m$

$k\ k\ jk\ j$

$k\ l\ k\ l\ j$

$E\ d\ f_{net\ d\ f\ w\ y}\quad(2-9)$

然后误差拓展到输入层则有： $2\ 2\ 0\ 0\ 0\ 1\ 1(\ )(\ )\ 2\ 2$

$l\ m\ l\ m\ n$

$k\ jk\ j\ k\ jk\ ij\ i$

$k\ l\ j\ k\ l\ j\ i$

$E\ d\ f\ w\ f_{net\ d\ f\ w\ f\ v\ x}\quad(2-10)$

从以上的计算公式中可以了解到在 BP 神经网络中在输入层所输入的误差与各层之间权值大小有关，因此可以通过调整权值减小模型误差。根据权值与误差之间的偏导数关系进行分析，两者之间呈正比关系，即：

$0, 1, 2, \dots, 1, 2, \dots, j$

$k$

$jk$

$Ew\ j\ l\ k\ l$

$w$

$L\ L\quad(2-11)$

$0, 1, 2, \dots, 1, 2, \dots, j$

$k$

$jk$

$Ev\ i\ n\ j\ m$

$w$

$L\ L\quad(2-12)$

在以上公式中  $\alpha$  是一个比例系数，如果该参数取值时在 0-1 之间，其符号为负说明梯度在变化。

对于输出层来说，可以在以上公式的基础上进行变化，具体如下：

$k$

$jk$

$jk\ k\ jk$

$E\ E_{netw}$

$w_{net\ w}\quad(2-13)$

$j$

$ij$

$ij\ j\ jk$

$E\ E_{netv}$

$v_{net\ w}\quad(2-14)$

为了保证各层之间的独立性，防止出现影响，因此在 BP 网络中需要在每层都设置一个单独的网络误差符号，具体如下：

$o$

$k$

$k$

$E$

$net\quad(2-15)\ 10$

$y$

$j$

$j$

$E$

$net\quad(2-16)$

在 BP 神经网络中的权值调整公式为：

$o$

$jk\ k\ j$

$$w_{y_j} \quad (2-17)$$

$y_{ij}$   
 $v_{x_j}$  (2-18)  
 此时利用以上的误差信号 $o_k$  和 $y_j$  就可以计算出各层之间的权值调整量。其中输入层误差信号计算表达式为：  
 $( )_o$

$$k$$

$$k_k$$

$$k_k k_k$$

$$E_{o_k} E_{f_{net}}$$

$$net_o \quad net_y \quad (2-19)$$

隐含层误差信号计算表达式为：

$$( )_{y_j}$$

$$j$$

$$j_j j_j$$

$$E_{y_j} E_{f_{net}}$$

$$net_y \quad net_y \quad (2-20)$$

以输入层为例，就可以得到网络模型的误差梯度，其具体的表达式为：

$$( )_k$$

$$k$$

$$k$$

$$E_{d_o}$$

$$o \quad (2-21)$$

以隐含层为例网络模型的误差梯度具体的表达式为：  $( ) ( )$

$$l$$

$$k_k k_k j_k$$

$$j_k l$$

$$E_{d_o} f_{net_w}$$

$$y \quad (2-22)$$

此时就可以得到：

$$( ) (1)_k$$

$$k_k k_k$$

$$k$$

$$E_{d_o} o_o$$

$$o \quad (2-23) \quad ( ) ( ) ( ) ( ) (1)$$

$$l \quad l$$

$$o$$

$$k_k k_k j_k j_k j_k j_j$$

$$j_k l k l$$

$$E_{d_o} f_{net_w} f_{net_w} y_y$$

$$y \quad (2-24)$$

从以上的分析中可以了解到在 BP 神经网络中隐含层所产生的误差值与各层输出偏导数之间呈现象关系，这就意味着改变神经网络只能的权值就可以达到调整输出误差的目的。因此对于 BP 神经网络权值调整计算公式为：

$$( ) (1)_o j$$

$$k_k j_k k_k k_k j$$

$$w_{y_d} o_o o_y \quad (2-25) \quad 1 ( ) (1)$$

$$l$$

$$y_o$$

$$ij_j i_k j_k j_j i$$

$$k$$

$$v_{x_j} w_{y_j} y_x \quad (2-26)$$

对于一个 3 层网络结构的 BP 神经网络而言，假设其具有  $h$  个隐含层结构，具体的节点编号为1

2  $n$   
 $1, 1, \dots, 1$ ，此时各节点之间的输出变量则为1

2  $n_y, y, \dots, y$ ，权值矩阵

为1

2  $nW, W, \dots, W$ ，这样就可以得到在网络中各层之间的权值调整表达式： 11

输出层权值调整表达式为：

$$1 \quad 1 ( ) (1) \quad 0, 1, 2, \dots, 1, 2, \dots, h \quad h \quad h \quad h_j$$

$$k_k j_k k_k k_k j$$

$w_{j d o o y j m k l} \quad L L \quad (2-27)$   
 隐含层权值调整表达式为:  $1 \ 1 \ 1 \ 1 \ ( ) \ (1) \ 0, 1, 2, \ , \ 1, 2, \ ,$   
 $l$   
 $h \ h \ h \ o \ h \ h \ h \ h$   
 $i j \ j \ i \ k \ j k \ i \ i \ i$   
 $k$   
 $w \ j \ w \ y \ y \ j \ i \ m \ j \ m$   
 $L L \quad (2-28)$

从以上计算公式中可以逐步计算出每一层权值调整函数，而且函数大小取决于学习效率因子、本层次输出的误差信号和本层输入信号量。

### 2.3 本章小结

本章节在进行研究时首先对电力负荷的概念以及预测步骤进行分析，然后对BP神经网络进行介绍，分析BP神经网络的基本结构以及学习算法，为下文基于搭建BP神经网络模型奠定基础。12

## 第3章基于神经网络电力负荷预测模型的建立

### 3.1 模型建立

3.1.1 模型数据处理建立预测模型需要做的第一步就是对历史负荷数据以及所要用到的温度和气象等因素的信息进行收集、整理、分析，确定建立网络的训练样本和目标样本，并对其进行归一化或量化处理，然后建立训练网络并进行训练。

(1) 数据预处理基于负荷的周期性，对于那些因为一些因素而导致丢失的数据，本文采用前一天或者后一天在此刻的数据来代替。

(2) 数据归一化及量化处理BP网络神经元的激励函数一般选取S型函数，这样做的目的是为了加快网络的收敛速度。而误差函数又是S型函数，如果样本数据不进行处理直接用，输入值很大，会导致过饱和现象，影响训练。因此，要对数据进行归一化处理。经过处理之前所的参数量纲一致，以便后期进行计算。假设经过归一化处理后数据存在最大值和最小值，此时所有的数据都会成为[0, 1]区间的常数。本文中建立BP网络所采用的激励函数为指数型S函数logsig，因此需要将样本负荷数据转化到(0, 1)之间，

公式如下：

$$\frac{\min}{\max \min} \frac{n}{P \ PP} \quad (3-1)$$

$$\frac{\min}{\max \min} \frac{n}{T \ TT} \quad (3-2)$$

式中：

$\max$   
P 历史输入数据中的最大值；m

$\min$   
P 历史输入数据中的最小值；m

$\max$   
T 目标样本数据中的最大值；m

$\min$   
T 目标样本数据中的最小值；nP 归一化处理后的数据矩阵；

$\min$   
T 归

一化后的目标矩阵；P 经过预处理后的输入历史电力负荷训练样本矩阵；T 经过预处理后的目标负荷样本矩阵。

归一化之后的数据进行训练得出的结果还需要进行反归一化为负荷值，反归一

化公式如下：

$$\frac{\max \min}{\min} \frac{n}{T \ TY \ T} \quad (3-3)$$

### 3.1.2 网络拓扑结构

(1) 输入及输出层节点数的选取输入层和输出层节点的数目要根据具体选取的样本的情况而定，本文选取一天13当中每隔1小时取样一次的电力负荷数据，即一天24组负荷值。首先用前一天的24组历史负荷数据，这样输入层的节点数取24。而目标输出是当天的每隔一小时的24个负荷值，因此输出节点数为24个。



(2) 隐含层层数的确定本文采用单层隐含层的 BP 网络，虽然增加隐含层的层数对网络训练的信息处理能力有所提高，但同时也使网络变得繁琐复杂，对网络的性能上以及训练速度上都有一定的影响。

(3) 隐含层节点数的确定隐含层节点数的选取一般都是进行试凑，通过在网络训练中选取不同的节点数分析比较最后得出的预测结果误差，然后确定选取多少个节点合适。利用试错法确定隐含层节点数的步骤为：首先利用  $\ln n m a$  公式对节点数进行计算。BP 神经网络有  $m$  个输出层节点， $n$  个输入层节点， $\ln$  个隐层节点， $a$  所代表的是一个自然常数，该参数在 1 到 10 之间取值。其次依次隐含层节点数，通过结果误差确定节点数。

(4) 初始值在初始值选取时如果取值过大，这样整个网络的学习和训练过程会非常的慢，甚至还有可能出现不学习、不训练的问题，因此在进行初始值选取时尽量保证权值和阈值取值小一些。根据现有研究成果可知 BP 神经网络在初始值选取时一般会在

-1 到 1 之间取一个非 0 的小数。

(5) 学习速率的选取学习速率参数选取的大小能够对网络权值的设置和调整产生影响。假如说在一个 BP 神经网络中其在权值初始化设置时所选取的参数比较大，此时学习速率就比较低，与此同时神经网络的学习时间会不断延长。这样在低学习速率下神经网络

的收敛速度会不断减慢，具有明显的稳定性。反之如果在 BP 神经网络中权值过小，

BP 神经网络所呈现出的学习速率就比较的大，网络在短时间内就可以完成学习任务，但是此时对于整个 BP 神经网络而言其稳定性较差。因此学习速率与权值之间有很大关系，在进行学习速率选取时往往会通过权值调整而改变参数值[31]。通常学习速率选取在 0.01-0.8 之间，本文将取 0.1。

基于以上分析就可以建立本文电力负荷预测所使用的三层 BP 神经网络模型，

据图如图 3-1 所示。 14

输入层隐含层输出层 . . . 1 2 24 . . . 1 2 24 . . .

图 3-1 电力负荷预测模型经过以上几步的完成，BP 神经网络的建立问题基本解决，为后期对历史负荷的训练以及对未来负荷的预测做好准备。

3.2 A 市电力负荷基本情况如图 3-2 所示，描绘了 A 市 2015 年到 2019 年的负荷曲线，可以看出，每年的负荷变化基本上是相似的，每年负荷最高峰和最低谷基本一致，每年的夏季是年负荷高峰期，因为炎热的夏季气温升高，会引起空调等制冷设备的投入，使得负荷升高，这个时段基本上都在 7、8 月份。而到了冬季，对于 A 市来说采用的是燃烧取暖，不需要电能供暖，所以 A 市冬季电力负荷就不会出现明显的增高。

图 3-2 负荷年周期变化曲线电力负荷的周周期性是指电力负荷的变化在以周为单位来分析时，其变化的趋势是相似的。如图 3-3 所示，描述的是 A 市 2019 年 6 月、7 月和 8 月负荷的变化曲线，从图中曲线可以看出，每个月每个周的负荷的变化趋势是一致的，虽然具体到

同类型日的负荷量不同，但是这里的周期性只表示每周的负荷变化趋势。并且能进一步分析得出，一周当中工作日用电量明显比休息日高，这是由于处于工作日时， 15

工业负荷为主要负荷的原因，而休息日，工厂基本上处于休息阶段，此时居民生活负荷占很大一部分，而且明显比工作日低，但是总体而言，每周的负荷变化趋势是类似的，体现了负荷的周周期性。而且在周六日为休息日负荷会有所下降。

图 3-3 负荷月周期变化趋势电力负荷的日周期性是指负荷在连续几天甚至在每一天的变化情况都是类似的。如图 3-4 所示，为 A 市 2019 年 7 月 1 日的负荷变化曲线，从中便可以很明显的看出日负荷的变化规律也是一样的。进一步的分析，可以看出，每天的日负荷最大值出现在白天，而最小负荷出现在夜里，因为，白天人们都活动或者工作，负荷量大，而夜里，人们都已经休息，很显然负荷就小。

图 3-4 负荷日周期变化趋势

3.3 实例分析应用以上 BP 算法建立负荷预测模型，并以 A 市 2020 年 6 月份负荷为例，对 6 月 23 日负荷进行预测。建立的模型中选取的最大训练步数为 10000，学习速率选取

0.1，目标误差选取 0.001。然后进行训练并预测。通过对网络进行训练，得到网络误差训练曲线，如图 3-5 所示，从图中可以看出，采用标准 BP 算法时，最后训练的网络误差不仅达不到所设定的目标误差，而且已经训练到所设定的最大训练步 16

数，可见本文所提出 BP 算法的预测性能太差图 3-5 网络误差训练曲线经过预测训练最后得出的 6 月 23 日的实际的 24 小时负荷值与预测出的 24 小时负荷进行对比，如图 3-6 所示，预测的效果也很不好，误差很大。对误差进一步分析，如图 3-7 所示，也能看出误差非常大。

图 3-6 网络输出对比曲线 17

图 3-7 误差曲线如表 3-3 所示，是用 BP 算法进行预测后所得到的 6 月 23 日的实际负荷与预测负荷的对比，可以得出，最大的相对误差是 25.3%，最小的相对误差是 1.05%，平均相对误差为 7.5%。而电力部门要求短期电力负荷预测精度为 3%，显然误差太大。

表 3-3 网络输出误差对比分析时刻

(h)

实际负荷

(MW)

预测负荷

(MW)

相对误差 (%)

时刻

(h)

实际负荷

(MW)

## 预测负荷

(MW)

相对误差 (%) 1 7528.7 8502.7 -12.94 2 7143.5 6908.0 3.30 3 6914.2 6752.8 2.33 4 6714.3 6026.4 10.25 5

6559.2 6201.1 5.46 6 6420.7 5628.6 12.34 7 6377.3 6721.1 -5.39 8 6571.6 6944.1 -5.67 9 8456.2 8001.3 5.38 10

10603.2 11625.3 -9.64 11 11210.4 11328.6 -1.05 12 11426.4 11654.8 -2.00 13 10091.2 11307.1 -12.05 14 9623.4

10829.6 -12.53 15 10983.4 11980.4 -9.08 16 11229.7 11428.7 -1.77 17 11389.4 10840.1 4.82 18 11269.3 11053.2

1.92 19 9896.2 10869.5 -9.84 20 10547.4 9812.3 6.97 21 10688.2 11003.4 -2.95 22 10506.3 11073.8 -5.40 23 9858.2

10836.3 -9.92 24 8870.3 11114.6 25.30

3.4 本章小结本章节通过对 BP 神经网络进行分析,了解该网络的结构等相关内容,搭建标准 BP 神经网络模型。最后利用 A 市电力负荷实际情况分析,验证模型计算效果。

本文通过对 A 市 6 月电力负荷实际情况进行分析,预测 6 月 23 日电力负荷情况。

经过实验验证发现利用以上所介绍的 BP 神经网络进行分析所得到的预测误差比较 18

大,均误差在 7.5%,而电力部门要求误差在 3%以内,这是由于以上预测所采用的是标准 BP 神经网络,其在实际应用时虽然可以起到预测效果,但是由于多种因素影响,导致预测精度误差大。 19

### 第 4 章基于改进 BP 神经网络的电力负荷预测研究

4.1 标准 BP 网络的优缺点标准 BP 神经网络的应用能够为数据处理带来巨大便利,总结其在应用时的优点主要有:

(1) 与传统方式下的计算方法相比,利用标准 BP 神经网络所构建的数学模型不需要明确、具体化,只需要能够对所计算的对象的变化规律或者是输出和输入之间的关系利用语言描述出来就可以。然后利用训练样本的作用对网络进行计算,从而将实际复杂问题简单化。

(2) 与其他数学模型相比,标准 BP 神经网络具有明显的储存优势,能够将样本数据训练后的结果进行记忆,以便后期进行应用。而且标准 BP 神经网络还能够通过对训练数据和训练结果进行分析得到误差值进行储存,并且对误差变化情况分析确定输入和输出之间的映射关系,通过映射关系进行未来数据的预测和变化趋势推测。

(3) 标准 BP 神经网络具有自学习功能。在该功能下标准 BP 神经网络能够适当的调整网络模型中的权值和阈值,从而将神经网络模型计算效果误差控制在允许范围内。

除了以上所列举的 BP 神经网络应用优势以外,标准 BP 神经网络在应用时还具有计算量小等多种不同优势,因此被广泛的应用到各种系统中进行计算。

就目前国内外相关研究成果可知 BP 神经网络模型应用非常广泛,而且所起到的应用效果也非常明显,但是由于 BP 神经网络具有非线性等复杂性能,导致其在实际应用时仍然存在计算问题,影响到最终预测值:

虽然 BP 神经网络具有巨大的优势,但是其在应用时仍然存在缺点:

(1) 训练速度慢。标准 BP 神经网络在应用时首先会对样本数据进行训练,但是为了保证训练结果标准 BP 神经网络在训练时会降低学习速率,这样可以有效的降低网络计算误差,避免神经网络计算出现振荡现象。但是由于学习速率取值较小,

在初始应用时下降速度非常快,误差较大。随着训练的推进,误差在不断降低,此时误差的绝对权值就更小,导致模型修正速度不断减慢,导致训练速度变慢[40]。

(2) 易陷入误差局部极小。标准 BP 神经网络经常会应用到一些复杂且非线性网络计算中,从而解决复杂性问题。此时在 BP 神经网络的作用下所得到的误差值是一个曲面取值,同时存在多个不同的极小点。由于极小点分布在曲面的不同位置,

利用 BP 神经网络进行训练时训练结果就有可能陷入到误差局部极小问题下,导致最终的训练结果不理想,无法达到预期计算效果。 20

4.2 BP 算法的改进为了更好的对 BP 神经网络进行改进,本文拟打算利用三种不同的算法进行分析,选择合适的算法,从而对 BP 神经网络进行计算。

(1) 自适应 BP 算法标准 BP 算法通常请况下选择的学习速率值是固定的,一般取值在 0.01-0.8 之间,至于为何所取数值要如此之小,其主要原因在于只有相对较小的学习率,对参数的修正才不会产生发散或者振荡问题,但这一取值也不可以过小,若太小,会导致修正参数太小则影响网络速度,效率过低。可但也有相异的训练阶段所选择的学习速率值不等。比如,在训练初期可以选择设置稍微大一些的学习速率值,使得收敛速度加快,当即将到达最低的误差点时,为了减慢学习的速度同时也要避免过度振动校正现象。因此,需要通过对算法做更进一步的改进来避免该问题产生,可在训练过程中对学习速率进行调整,以满足网路需要,优化训练过程。

在调整学习率这一方面,是判断网络训练结果出来后的调整值是否能使偏差降低,如果偏差比上一个偏差小,那么以便尽快到达目标误差可以基于原先的学习速

率增加速率,反之,则说明误差修正的太快,以致于错过了最小的误差点,此时就

需要逐渐对学习速率进行缩小。

以下为能够使学习速率自动调整的表达式:  $1.05 \left( \frac{E(k)}{E(k-1)} \right)^{-1} \left( \frac{E(k)}{E(k-1)} \right)^{-1} 0.7 \left( \frac{E(k)}{E(k-1)} \right)^{-1} 1.04 \left( \frac{E(k)}{E(k-1)} \right)^{-1}$

$E(k)$  代表的是第 k 步的误差平方和

$E(k-1)$  代表的是第 k-1 步的误差平方和

其他 (4-1)

其中: (k) 代表的是第 k 步的学习速率; E(k) 代表的是第 k 步的误差平方和。

在运用自适应 BP 算法展开相关预测时,对于初始学习速率值大小的确认不需从很小的值开始试凑,可以选取任意值。

(2) 弹性梯度下降法

一般情况来说, S 型 BP 神经网络的激励函数是控制输出值在一定区间内,如 S 型对数函数其输出值的取值范围要控制在区间[0,1]之间,当输出值接近 0 或 1 时,

斜率趋近于 0。在这种状况下再进行网络训练,由于修正权值和阈值与误差导数和学习率之间有直接关系,是二者之积,所以,无论输入值是大还是小都有几率使得修复是难以进行。

为了解决这个问题，在对 BP 算法权值和阈值校正时，把标准 BP 算法的梯度变化的权重和阈值设置为独立的调整值，而网络参数调整的范围由自主调整值确定其大小，调整方向是由误差权重阈值或偏导数决定。这个独立的调整值不是恒定值，训练进行时，如果在连续的两个训练符号校正后得到的偏导数都是一样的，则认为 21 调整量较小，需要增加调整值，反之，则需要减少调整值。所以与标准算法以及自适应算法相比较，弹性 BP 算法收敛速度更快一些且过程不繁琐。在更多的工程实践中，弹性梯度下降法的结果是较为合理的。

(3) L-M 算法 L-M 方法其实就是针对标准算法在初始训练状态的快速下降的优势还有拟牛顿法可以在靠近最小误差时寻找最优的搜索方向同时不产生振荡的优点，最终将这两者进行组合。

LM 算法比拟牛顿法效率更高，拟合度更好。这是由于它不需要通过不同的公式来逼近  $(k)H$ ，它通常由一阶导数来逼近。在 L-M 方法， $(k)H$  近似为：

$$(k) TH J J (4-2)$$

于是 L-M 法的调整公式为：

$$\begin{bmatrix} \Delta w_k \\ \Delta b_k \end{bmatrix} = - (J^T J)^{-1} J^T E w \quad (4-3)$$

其中：

$(J^T)E w$  代表的是梯度； $J$  代表的是雅克比矩阵，该矩阵通常是由误差函数对参数的一阶偏导数构成的； $kw$  代表的是 BP 网络的权值； $\Delta$  代表的是 BP 网络依照训练程度进行自适应调整的值。

指 标
<p>疑似剽窃观点</p> <ol style="list-style-type: none"> <li>年的负荷曲线，可以看出，每年的负荷变化基本上是相似的，每年负荷最高峰和最低谷基本一致，每年的夏季是年负荷高峰期，因为炎热的夏季气温升高，会引起空调等制冷设备的投入，使得负荷升高，这个时段基本上都在 7、8 月份。</li> <li>如图 3-3 所示，描述的是 A 市 2019 年 6 月、7 月和 8 月负荷的变化曲线，从图中曲线可以看出，每个月每个周的负荷的变化趋势是一致的，虽然具体到同类型日的负荷量不同，但是这里的周期性只表示每周的负荷变化趋势。</li> <li>进一步的分析，可以看出，每天的日负荷最大值出现在白天，而最小负荷出现在夜里，因为，白天人们都活动或者工作，负荷量大，而夜里，人们都已经休息，很显然负荷就小。</li> </ol>
<p>疑似剽窃文字表述</p> <ol style="list-style-type: none"> <li>基于神经网络电力负荷预测模型的建立 <ol style="list-style-type: none"> <li>模型建立 <ol style="list-style-type: none"> <li>模型数据处理建立预测模型需要做的第一步就是对历史负荷数据以及所要用到的温度和气象等因素的信息进行收集、整理、分析，确定建立网络的训练样本和目标样本，并对其进行归一化或量化处理，然后建立训练网络并进行训练。</li> </ol> </li> <li>误差函数又是 S 型函数，如果样本数据不进行处理直接用，输入值很大，会导致过饱和现象，影响训练。因此，要对数据进行归一化处理。</li> <li>首先用前一天的 24 组历史负荷数据，这样输入层的节点数取 24。而目标输出是当天的每隔一小时的 24 个负荷值，因此输出节点数为 24 个。</li> <li>经过以上几步的完成，BP 神经网络的建立问题基本解决，为后期对历史负荷的训练以及对未来负荷的预测做好准备。</li> </ol> </li> <li>3.2 A 市电力负荷 <ol style="list-style-type: none"> <li>取暖，不需要电能供暖，所以 A 市冬季电力负荷就不会出现明显的增高。</li> </ol> </li> <li>图 3-2 负荷年周期变化曲线电力负荷的周周期性是指电力负荷并且能进一步分析得出，一周当中工作日用电量明显比休息日高，这是由于处于工作日时，15 工业负荷为主要负荷的原因，而休息日，工厂基本上处于休息阶段，此时居民生活负荷占很大一部分，而且明显比工作日低，但是总体而言，每周的负荷变化趋势是类似的，体现了负荷的周周期性。</li> <li>电力负荷的日周期性是指负荷在连续几天甚至在每一天的变化情况都是类似的。如图 3-4 所示，为</li> <li>负荷进行预测。建立的模型中选取的最大训练步数为 10000，学习速率选取 0.1，目标误差选取 0.001。然后进行训练并预测。通过对网络进行训练，得到网络误差训练曲线，如图 3-5 所示，从图中可以看出，采用标准 BP 算法时，最后训练的网络误差不仅达不到所设定的目标误差，而且已经训练到所设定的最大训练步 16 数，可见本文所提出 BP 算法的预测性能太差图 3-5 网络误差训练曲线经过预测训练最后得出的 6 月 23 日的实际的 24 小时负荷值与预测出的 24 小时负荷进行对比，如图 3-6 所示，预测的效果也很不好，误差很大。对误差进一步分析，如图 3-7 所示，也能看出误差非常大。</li> <li>图 3-6 网络输出对比曲线 17</li> </ol>



图 3-7 误差曲线如表 3-3 所示,是用 BP 算法进行预测后所得到的 6 月 23 日的实际负荷与预测负荷的对比,可以得出,最大的相对误差是 25.3%,最小的相对误差是 1.05%,平均相对误差为 7.5%。而电力部门要求短期电力负荷预测精度为 3%,显然误差太大。

9. 可但也有相异的训练阶段所选择的学习速率值不等。比如,在训练初期可以选择设置稍微大一些的学习速率值,使得收敛速度加快,当即将到达最低的误差点时,为了减慢学习的速度同时也要避免过度振动校正现象。因此,需要通过对算法做更进一步的改进来避免该问题产生,可在训练过程中对学习速率进行调整,以满足网路需要,优化训练过程。在调整学习率这一方面,是判断网络训练结果出来后的调整值是否能使偏差降低,如果偏差比上一个偏差小,那么以便尽快到达目标误差可以基于原先的学习速率增加速率,反之,则说明误差修正的太快,以致于错过了最小的误差点,此时就需要逐渐对学习速率进行缩小。
10. 在运用自适应 BP 算法展开相关预测时,对于初始学习速率值大小的确认不需从很小的值开始试凑,可以选取任意值。
11. 在这种状况下再进行网络训练,由于修正权值和阈值与误差导数和学习率之间有直接关系,是二者之积,所以,无论输入值是大还是小都有几率使得修复是难以进行。  
为了解决这个问题,在对 BP 算法权值和阈值校正时,把标准 BP 算法的梯度变化的权重和阈值设置为独立的调整值,而网络参数调整的范围由自主调整值确定其大小,调整方向是由误差权重阈值或偏导数决定。这个独立的调整值不是恒定值,  
训练进行时,如果在连续的两个训练符号校正后得到的偏导数都是一样的,则认为 21  
调整量较小,需要增加调整值,反之,则需要减少调整值。所以与标准算法以及自适应算法相比较,弹性 BP 算法收敛速度更快一些且过程不繁琐。在更多的工程实践中,弹性梯度下降法的结果是较为合理的。

3. 002_第3部分		总字数: 8337
相似文献列表		
去除本人文献复制比: 50.9%(4244)      文字复制比: 50.9%(4244)      疑似剽窃观点: (4)		
1	<u>基于BP神经网络的短期电力负荷预测的研究</u> 隋惠惠(导师:王宏) - 《哈尔滨工业大学硕士论文》 - 2015-06-01	40.4% (3370) 是否引证: 否
2	<u>用于购供售一体化管理系统的短期电力负荷预测</u> - 《学术论文联合比对库》 - 2015-05-30	39.9% (3330) 是否引证: 否
3	13S053069-隋惠惠-王宏 隋惠惠 - 《学术论文联合比对库》 - 2015-06-11	39.6% (3300) 是否引证: 否
4	2436800_电源与电机研究_电力电子大师兄 电源与电机研究 - 《学术论文联合比对库》 - 2015-06-04	39.4% (3283) 是否引证: 否
5	12602466_李灿_基于改进BP神经网络的负荷预测问题研究 李灿 - 《学术论文联合比对库》 - 2018-05-02	30.7% (2558) 是否引证: 否
6	<u>肾癌手术病人住院周期的影响因素研究及预测分析</u> 梁栋(导师:江志斌) - 《上海交通大学硕士论文》 - 2017-02-01	21.2% (1770) 是否引证: 否
7	梁栋_肾癌手术病人住院周期的影响因素研究及预测分析 梁栋 - 《学术论文联合比对库》 - 2016-12-16	19.6% (1631) 是否引证: 否
8	<u>基于SOM和BP神经网络的配电网台区低电压预测</u> 肖林煌 - 《学术论文联合比对库》 - 2019-04-17	17.7% (1474) 是否引证: 否
9	201320301158_李木华_电气工程 李木华 - 《学术论文联合比对库》 - 2017-12-12	16.0% (1337) 是否引证: 否
10	13-02-2徐海粟-现场研磨性的BP神经网络预测方法研究 - 《学术论文联合比对库》 - 2016-04-25	14.3% (1196) 是否引证: 否
11	201320301158李木华(检测版) - 《学术论文联合比对库》 - 2017-10-19	14.0% (1168) 是否引证: 否
12	01212502458530074_高李陈_新能源与建筑用电节能 高李陈 - 《学术论文联合比对库》 - 2017-03-20	10.8% (902) 是否引证: 否
13	<u>基于改进神经网络的配电网低电压预测研究</u> 肖林煌 - 《学术论文联合比对库》 - 2019-04-18	9.5% (791) 是否引证: 否
14	<u>基于改进BP神经网络的负荷预测问题研究</u> 李灿(导师:姚李孝) - 《西安理工大学硕士论文》 - 2018-06-30	8.6% (718) 是否引证: 否
15	02000_1140209416_梁栋 梁栋 - 《学术论文联合比对库》 - 2016-12-19	8.1% (678) 是否引证: 否
16	梁栋_肾癌手术病人住院周期的影响因素研究及预测分析 梁栋 - 《学术论文联合比对库》 - 2016-12-17	8.1% (678) 是否引证: 否



17	<u>基于支持向量机的短期电力负荷预测方法研究及应用</u> 马鸿芳(导师: 王惠中;马世雄) - 《兰州理工大学硕士论文》 - 2018-03-29	3.2% (267) 是否引证: 否
18	电气工程与信息工程学院+143085207040+马鸿芳 马鸿芳 - 《学术论文联合比对库》 - 2018-06-04	3.2% (267) 是否引证: 否
19	4_马鸿芳_基于支持向量机的短期电力负荷预测方法研究及应用 马鸿芳 - 《学术论文联合比对库》 - 2018-05-31	3.2% (267) 是否引证: 否

**m** 代表的是 BP 网络可依照训练程度自行调整的值,

4.3 实例分析下面以 A 市 2020 年 6 月 1 日到 6 月 21 日的电力负荷值以及目标当天的温度(最大值、最小值以及平均值)、天气情况以及日期类型的归一化及量化值作为输入样本,

4.3.1 基于自适应 BP 算法的负荷预测采用自适应 BP 算法,即用 `traingdx` 训练函数对网络进行训练,它是通过自适应性的调整学习速率来避免人为对其选择不合适的问题。训练过程中如果修正后的

通过试错的方法来选取隐含层的节点的个数，通过观察最后网络训练得到的误差以及所需要的训练步数而寻找最佳的隐含层节点数目。如表 4-1 所示，为当隐含层采用不同节点数时网络训练所得的平均误差以及达到误差的训练步数。通过表 22

表 4-1 网络训练平均误差和步数与隐含层节点数的关系

最终经过学习训练，得到预测结果，如图 4-1 所示，为用自适应 BP 算法 6 月 23 日进行预测所得出的网络误差训练曲线。可以看出，训练达到我们所期望的误差范围即 0.001 时所需要的训练步数是 500。

如图 4-3 所示为训练后得到的预测负荷结果与期望负荷输出之间的误差曲线,

但是只靠图形并不能看出真正的误差是否在我们要求范围内，后面对实际预测输出值进行分析。 23

小时负荷的一个比较, 可以看到进行对比分析之后相对误差中最大为 8.36%, 最小为 0.15%, 最后得出平均相对误差为 2.54%。电力部门规定在进行短期预测时误差在 3% 以内即符合要求, 很显然, 此方法符合要求。

## 实际负荷

(MW)

(h)

## 预测负荷

0.2 6951.2 -5.98 6 6420.7 6817.6 -6.19 7 6377.3 6420.3 -0.67 8 6571.6 6767.4 -2.98 9 8456.2 8420.4 0.53 10

0.24 19 9896.2 9920.1 -0.25 20 10547.4 10422.3 1.19 21 10688.2 10668.2 0.19 22 10506.3 10627.5 -1.15 23 9858.2  
9872.6 -0.15 24 8870.3 9055.2 -2.09

表 4-3 网络训练平均误差和步数与隐含层节点数的关系节点数 10 15 20 21 22 23 24 25 30

平均误差 0.0317 0.0306 0.0293 0.0276 0.0263 0.0255 0.0257 0.0262 0.0255

步数 185 89 75 85 54 46 47 51 63

如图 4-4 所示是用弹性 BP 算法对 A 市 6 月 23 日负荷进行训练预测所得到的网络误差训练过程图。可以看出在训练到 46 步的时候，网络就训练到了我们所要求的误差范围。

图 4-4 网络误差训练曲线如图 4-5 所示，为采用弹性 BP 算法训练后得到的 A 市 6 月 23 日预测负荷与当 25

地当日实际采集负荷的对比曲线。如图 4-6 所示为采用弹性 BP 算法训练后得到的预测负荷结果与期望负荷输出之间的误差曲线。

图 4-5 预测输出对比曲线图 4-6 网络误差曲线如表 4-4 所示，是通过弹性 BP 算法进行预测最终得到的 A 市 6 月 23 日预测当天 24 小时负荷值与实际 24 小时负荷值的一个比较，可以看到通过对比分析之后相对误差中最大为 8.04%，最小为 0.06%，最后得出平均相对误差为 2.48%。可以看出，虽然就平均误差而言，比用自适应 BP 算法的小，但是预测结果相对不稳定。

表 4-4 网络输出误差对比分析时刻

(h)

实际负荷

(MW)

预测负荷

(MW)

相对误差 (%)

时刻

(h)

实际负荷

(MW)

预测负荷

(MW)

相对误差 (%) 1 7528.7 7713.2 -2.45 2 7143.5 7425.1 -3.94 26 3 6914.2 7470.2 -8.04 4 6714.3 7161.2 -6.66 5 6559.2 7002.1 -6.75 6 6420.7 6601.2 -2.81 7 6377.3 6463.5 -1.35 8 6571.6 6850.4 -4.24 9 8456.2 8701.7 -2.90 10 10603.2 10464.3 1.31 11 11210.4 11445.4 -2.10 12 11426.4 11629.3 -1.78 13 10091.2 10142.9 -0.51 14 9623.4 9807.9 -1.92 15 10983.4 11048.1 -0.59 16 11229.7 11363.7 -1.19 17 11389.4 11480.4 -0.80 18 11269.3 11407.1 -1.22 19 9896.2 9792.4 1.05 20 10547.4 10772.5 -2.13 21 10688.2 11100.4 -3.86 22 10506.3 10512.7 -0.06 23 9858.2 10042.4 -1.87 24 8870.3 8864.5 0.07

4.3.3 基于 L-M 法的 BP 算法的负荷预测采用 L-M 算法，也就是调用 trainlm 训练函数对网络进行训练。对于隐含层节点数的选取同样要进行试凑，从表 4-5 中可以看出选取 28 个节点是最为合适的。

表 4-5 网络训练平均误差和步数与隐含层节点数的关系节点数 20 22 24 25 26 27 28 29 30

平均误差 0.0343 0.0288 0.0203 0.0235 0.0201 0.0221 0.0146 0.0168 0.0167

步数 6 7 7 11 5 8 6 9 10

图 4-7 是采用 L-M 算法对负荷进行预测得到的误差训练过程曲线，可以看出，利用 L-M 法时，训练到第 6 步的时候，误差就已经达到了我们所要求的误差范围，训练速度明显比前两种方法要好很多。

图 4-7 网络误差训练曲线如图 4-8 所示，为采用 L-M 算法训练后得到预测负荷与当日实际采集负荷的对比曲线。如图 4-9 为误差曲线。 27

图 4-8 预测输出对比曲线图 4-9 网络误差曲线如表 4-6 所示，经过分析可以得出相对误差中最大为 3.95%，最小为 0.01%，

最后得出平均相对误差值 1.33%。符合短期电力负荷预测的误差要求。

表 4-6 网络输出误差对比分析时刻

(h)

实际负荷

(MW)

预测负荷

(MW)

相对误差 (%)

时刻

(h)

实际负荷

(MW)

预测负荷

(MW)

相对误差 (%) 1 7528.7 7672.5 -1.91 2 7143.5 7275.4 -1.85 3 6914.2 7025.7 -1.61 4 6714.3 6737.9 -0.35 5 6559.2 6507.2 0.79 6 6420.7 6350.4 1.09 7 6377.3 6160.4 3.40 8 6571.6 6311.9 3.95 9 8456.2 8352.6 1.23 10 10603.2 10451.4 1.43 11 11210.4 11205.4 0.04 12 11426.4 11565.2 -1.21 13 10091.2 10064.3 0.27 14 9623.4 9686.2 -0.65 15 10983.4 11023.4 -0.36 16 11229.7 11392.1 -1.45 17 11389.4 11479.2 -0.79 18 11269.3 11454.2 -1.64 19

9896.2 9814.3 0.83 20 10547.4 10412.5 1.28 21 10688.2 10689.4 -0.01 22 10506.3 10573.2 -0.64 23 9858.2 10140.3 -2.86 24 8870.3 8964.2 -1.06

4.3.4 三种优化算法负荷预测结果对比对上面所用到的三种改进的 BP 算法所预测的结果进行总结比较，如表 4-7 所示，可以很明显的看出 L-M 算法进行预测所得的平均相对误差最小，而且所用的训练步数是最少的，也就是说训练的速度最快。因此，三种改进的算法里面，L-M 算法是最为理想的改进算法。

表 4-7 三种改进算法训练对比分析时刻 (h)	自适应算法	弹性 BP 算法	L-M 算法
最小相对误差	0.15%	0.06%	0.01%
最大相对误差	8.36%	8.04%	3.95%
平均相对误差	2.54%	2.48%	1.33%
训练步数	500	46	6

如图 4-10 所示为三种算法预测出的效果对比，从图中能够看出，采用 L-M 法的预测效果相对其他算法效果是好的。如图 4-11 所示，为三种算法预测的误差对比分析，很明显，也能看出采用 L-M 法预测的误差最小。

图 4-10 三种改进算法训练输出对比 29  
图 4-11 三种改进算法训练误差曲线对比

4.3.5 基于 L-M 法的负荷预测以上对 A 市 6 月 23 日的 24 小时负荷值进行了预测，采用 L-M 算法的预测效果是最理想的。查阅日历可知 2020 年 6 月 23 日为工作日，因此下一步利用 L-M 法对 6 月 27 日即休息日的负荷进行预测。预测建模中同样目标误差选取 0.001。

对于隐含层节点数的选择仍然采取试凑的方式，通过多次的训练，得出预测结果。如图 4-12 所示，为采用 L-M 法对 6 月 27 日预测出的 24 小时负荷值与实际值的输出对比曲线。如图 4-13 所示为训练后得到的预测负荷结果与期望负荷输出之间的误差曲线。

图 4-12 预测输出对比曲线 30

图 4-13 网络误差曲线如表 4-8 所示，是通过 L-M 算法进行预测最终得到的 A 市 6 月 27 日的预测当天 24 小时负荷值与实际 24 小时负荷值的一个比较，经过分析可以得出相对误差中最大为 3.78%，最小为 0.06%，最后得出平均相对误差为 1.42%。符合短期电力负荷预测的误差要求。

表 4-8 6 月 27 日网络输出误差对比分析时刻

(h)	
实际负荷 (MW)	
预测负荷 (MW)	
相对误差 (%)	
时刻 (h)	
实际负荷 (MW)	
预测负荷 (MW)	
相对误差 (%)	1 8286.3 8599.7 -3.78 2 7861.4 8014.1 -1.94 3 7861.4 8013.9 -1.94 4 7272.1 7453.3 -2.49 5 7043.7 7128.9 -1.21 6 6841.2 6872.1 -0.45 7 6673.2 6962.1 -2.49 8 6793.3 6935.2 -3.93 9 8279.4 8513.4 -2.83 10 10194.3 10403.5 -2.05 11 10929.4 11028.6 -0.91 12 11217.3 11247.6 -0.27 13 10029.4 10110.7 -0.81 14 9686.4 9691.6 -0.06 15 10991.5 11187.3 -1.78 16 11139.8 11293.1 -1.38 17 11172.4 11093.1 0.71 18 10921.4 10784.7 1.25 19 9598.2 9622.1 -0.25 20 10047.3 9977.8 0.69 21 10197.5 10126.5 0.70 22 10202.4 10136.9 0.64 23 9838.4 9815.1 0.24 24 9168.3 9015.2 1.67

以上对 A 市的预测仅仅局限在一个月的某一天工作日和休息日的预测上，下面同样以 A 市负荷为例，采用改进 BP 神经网络预测模型，并应用 L-M 算法对 2020

整个 7 月份负荷进行预测。以 A 市 2020 年 6 月的负荷及气象历史数据信息作为训练样本，对深圳市 7 月份的每日的 24 小时点的负荷进行预测。预测算法同样采用对比分析出的效果最好的一种改进 BP 算法——L-M 法。如图 4-14 所示为 7 月 1 日 31

至 7 月 30 日的预测出的负荷与实际负荷的对比曲线图。

图 4-14 7 月份负荷预测曲线如表 4-9 所示为对 7 月每天负荷预测的平均相对误差的对比，通过比较发现，考本文所提出模型及算法预测精度很高，符合电力部门要求。

表 4-9 7 月网络输出误差对比分析日期误差 (%) 日期误差 (%) 日期 误差 (%)

7 月 1 日	1.95%	7 月 11 日	1.23%	7 月 21 日	1.36%
7 月 2 日	1.93%	7 月 12 日	1.06%	7 月 22 日	1.2%
7 月 3 日	1.65%	7 月 13 日	1.43%	7 月 23 日	0.89%
7 月 4 日	1.27%	7 月 14 日	1.32%	7 月 24 日	1.32%
7 月 5 日	1.62%	7 月 15 日	0.81%	7 月 25 日	1.24%
7 月 6 日	1.13%	7 月 16 日	1.85%	7 月 26 日	1.33%
7 月 7 日	1.58%	7 月 17 日	1.4%	7 月 27 日	1.32%
7 月 8 日	1.48%	7 月 18 日	1.93%	7 月 28 日	0.88%
7 月 9 日	1.98%	7 月 19 日	0.95%	7 月 29 日	1.71%
7 月 10 日	1.27%	7 月 20 日	1.37%	7 月 30 日	1.04%

4.5 本章小结本章利用所建立的 BP 神经网络模型以 A 市负荷为例进行实例分析,对电力负荷做出预测,应用了三种对标准 BP 算法的改进算法即自适应算法、弹性 BP 算法以及 L-M 法分别对 A 市 6 月 23 日的负荷进行预测并对预测结果进行对比分析,

通过实例验证, L-M 法是预测效果最佳的一种改进算法。除此之外还针对 6 月 27

日休息日进行预测, 1.32%也可以起到预测结果, 因此采用 L-M 法对 BP 神经网络进行改进可以起到良好预测效果。最后利用 6 月份数据对 7 月份电力负荷进行预测,

预测结果与实际结果误差不大, 预测精度高。 32 33

结论电力负荷预测是我国现代电网建设的必然要求, 通过对电力负荷预测能够合理安排电能生产计划。由于电力负荷预测影响因素较多, 很难采用统一的方案对电力负荷进行预测。因此本文在进行研究时通过对 A 县实际情况进行分析, 结合当前电力负荷变化趋势, 然后进行负荷预测模型计算。同时为了提高负荷模型预测精度还提出了基于 BP 神经网络的计算方法, 通过对标准 BP 神经网络进行分析, 提出改进 BP 神经网络算法, 并将该算法应用到 A 县中进行负荷预测。总结本文研究成果如下:

(1) 通过对对电力负荷预测概念及流程进行分析, 然后从理论角度对 BP 神经网络的结构以及算法流程进行分析, 为本文研究奠定理论基础。

(2) 结合研究理论搭建 BP 神经网络模型, 确定神经网络各层节点数以及相关参数的计算方式和取值, 构建本文所应用的三层神经网络模型,

(3) 以 A 市电力负荷为对象进行年负荷、月负荷、日负荷情况进行分析, 发现 A 市的电力负荷存在规律性变化, 因此证明可以采取有效方法进行负荷预测。

(4) 经过实际应用验证分析发现 BP 神经网络下计算平均误差为 7.5%, 误差相对比较大, 无法满足电力部门所要求的 3%以内范围, 预测精度无法达到要求。

这是由于 BP 神经网络的拟合性差, 性能不稳定, 极易陷入局部极值。

(5) 针对上述问题提出了改进 BP 神经网络预测模型, 在该模型中主要是通过

优化算法对 BP 神经网络进行改进, 提高预测精度。本文选用自适应、弹性梯度和 L-M 算法进行对比分析, 三者的平均相对误差分别为: 2.54%、2.48%、1.33%, 训练步数分别为 500 次、46 次和 6 次。由此可见 L-M 算法预测效果最佳, 本文选取该算法对 BP 神经网络进行优化计算。

(6) 利用改进模型对 A 市的工作日以及非工作日电力负荷情况进行预测, 其中平均相对误差分别为: 1.33%、1.42%。最后以 6 月历史数据对 7 月电力负荷进行预测, 误差仍可控制在 2%以内。

虽然本文研究已经完成, 所提出的改进 BP 神经网络模型应用效果也良好, 但是囿于本人研究能力限制以及影响因素不确定性, 实际应用中还需要不断完善。比如说在本次的研究中只是以日和月为单位进行分析, 是否能够将该模型应用到年度生产计划应用中尚未可知。而且本文在研究时还未涉及到根据气候的变化进行负荷调整等, 这些都是在以后需要完善之处, 还需要在以后研究中进行深入挖掘和分析。 34

参考文献

- [1] 李国庆, 刘钊, 金国彬, 等. 基于随机分布式嵌入框架及 BP 神经网络的超短期电力负荷预测[J]. 电网技术, 2020, 435(02):53-61.
- [2] 张淑清, 杨振宁, 张立国, 等. 基于弹性网降维及花授粉算法优化 BP 神经网络的短期电力负荷预测[J]. 仪器仪表学报, 2019, 40(07):50-57.
- [3] 李文. 基于 Elman 神经网络算法的电力负荷预测模型研究[J]. 赤峰学院学报(自然科学版), 2017(21):43-45.
- [4] 罗育辉, 蔡延光, 戚远航, 等. 基于最大偏差相似性准则的 BP 神经网络短期电力负荷预测算法[J]. 计算机应用研究, 2019, 36(11):75-79.
- [5] 王家兰, WANG, Jia-lan, 等. 基于 RBF 神经网络的电力负荷预测研究[J]. 西安文理学院学报(自然科学版), 2017, 06(06):45-48.
- [6] 李琛, 郭文利, 吴进, 等. 基于 BP 神经网络的北京夏季日最大电力负荷预测方法[J]. Climatic and Environmental Research, 2019, 24(01):137-144.
- [7] 陈卓, 孙龙祥. 基于深度学习 LSTM 网络的短期电力负荷预测方法[J]. 电子技术, 2018, 047(001):39-41.
- [8] 胡亚超, 刘超, 陈勇, 等. 基于主成份分析法的神经网络电力负荷预测[J]. 自动化技术与应用, 2019, 038(007):90-93.
- [9] 陈亚, 李萍. 基于神经网络的短期电力负荷预测仿真研究[J]. 电气技术, 2017(1):26-29.
- [10] 杨蕊, 张程, 李飞, 等. 一种短期电力负荷预测方法 [J]. 软件, 2017(03):14-19.
- [11] 王帅哲, 王金梅, 王永奇, 等. 基于改进遗传算法的 BP 神经网络短期电力负荷预测[J]. 国外电子测量技术, 2019, 38(01):15-18.
- [12] 袁小凯, 李果, 许爱东, 等. 基于改进增强型神经网络的短期电力负荷预测 [J]. 计算机与数字工程, 2020, v. 48;No. 364(02):227-232+237.
- [13] Jahan I S, Snasel V, Misak S. Intelligent Systems for Power Load Forecasting: A Study Review[J]. Energies, 2020, 3(13):1234-1238.
- [14] Sideratos G, Ikonomopoulos A, Hatziargyriou N D. A novel fuzzy-based ensemble model for load forecasting using hybrid deep neural networks[J]. Electric Power Systems Research, 2020(178):112-139.
- [15] Saviozzi M, Massucco S, Silvestro F. Implementation of advanced functionalities for Distribution Management Systems: Load forecasting and modeling through Artificial Neural Networks ensembles[J]. Electric Power Systems Research, 2019, 167(2):230-239. 35
- [16] Motepe S, Hasan A N, Stopforth R. Improving Load Forecasting Process for



- a Power Distribution Network Using Hybrid AI and Deep Learning Algorithms[J]. IEEE Access, 2019(7):1-1.
- [17] De Miranda S T , Abaide A , Sperandio M , et al. Application of artificial neural networks and fuzzy logic to long-term load forecast considering the price elasticity of electricity demand[J]. Energy, 2020, 1(78):106-114.
- [18] López, Miguel, Valero S , Rodriguez A , et al. New online load forecasting system for the Spanish Transport System Operator[J]. Electric Power Systems Research, 2018, 154(1):401-412.
- [19] Talaat M , Farahat M A , Mansour N , et al. Load forecasting based on grasshopper optimization and a multilayer feed-forward neural network using regressive approach[J]. Energy, 2020, 196(2):117087.1-117087.12.
- [20] Afrasiabi M , Mohammadi M , Rastegar M , et al. Probabilistic deep neural network price forecasting based on residential load and wind speed predictions[J]. Renewable Power Generation, IET, 2019, 13(11):1840-1848.
- [21] Zhao B , Liang Y , Gao X , et al. Short-Term Load Forecasting Based on RBF Neural Network[J]. Journal of Physics Conference Series, 2018, (1069):121-126.
- [22] 袁德强, 赵贝贝, 王亚琳, 等. 基于 BP 神经网络的安阳县电力负荷预测[J]. 安阳师范学院学报, 2020, 124(02):114-116.
- [23] Zhou Z , Wu G , Zhang X . Short-term Load Forecasting Model Based on IBFO-BILSTM[J]. IOP Conference Series: Earth and Environmental Science, 2020, 440(3):39-49.
- [24] 庄世杰、於志勇、郭文忠、黄昉苑. 基于 Zoneout 的跨尺度循环神经网络及其在短期电力负荷预测中的应用[J]. 计算机科学, 2020, 47(09):111-115.
- [25] Zhao W , Liu X , Li C , et al. Short-term Load Forecasting of PowerSystem Based on Improved Feedforward Neural Network[J]. Journal of Physics: Conference Series, 2020, 1549(5):52-56.
- [26] 赵会茹, 赵一航, 郭森. 基于互补集合经验模态分解和长短期记忆神经网络的短期电力负荷预测[J]. 中国电力, 2020, 53(06):52-59.
- [27] 马天男, 王超, 彭丽霖, 等. 计及需求响应和深度结构多任务学习的电力系统短期负荷预测[J]. 电测与仪表, 2019, 56(16):11-15.
- [28] B K X A , A H Y , B G H , et al. Short-term power load forecasting based on Elman neural network with particle swarm optimization[J]. Neurocomputing, 2019, 24(02):114-126.
- [29] Chen P , Cheng H , Yao Y , et al. Research on Medium-Long Term Power Load Forecasting Method Based on Load Decomposition and Big Data Technology[C]// 2018 International Conference on Smart Grid and Electrical Automation (ICSGEA). IEEE 36 Computer Society, 2018.
- [30] 罗宁, 高华, 贺墨琳. 基于神经网络的电力负荷预测方法研究[J]. 自动化与仪器仪表, 2020, 3(06):52-59.
- [31] Zang H , Cheng L , Ding T , et al. Hybrid method for short-term photovoltaic power forecasting based on deep convolutional neural network[J]. IET Generation, Transmission & Distribution, 2018, 14(2):123-143.
- [32] Tang X , Dai Y , Wang T , et al. Short-term power load forecasting based on multi-layer bidirectional recurrent neural network[J]. Generation, Transmission & Distribution, IET, 2019, 13(17):3847-3854.
- [33] 肖伸平, 张卫卫. 基于改进的遗传算法优化 BP 神经网络的电力负荷预测[J]. 电子测试, 2020(22):252-259.
- [34] Qing X , Chao Z , Shuangshuang Z , et al. Research on short-term power load forecasting method based on machine learning[J]. Electrical Measurement & Instrumentation, 2019, 1(2):164-176.
- [35] Xu-Dong Z , Zhong-Wen Q , Si-Qi S , et al. The Power Load Forecasting Algorithm Based on LSTM and LGBM[J]. Systems Engineering, 2019, 2(2):106-119.
- [36] 王成武, 郭松林, 王伟. 改进粒子群优化 RBF 神经网络在短期电力负荷预测上的研究[J]. 电子测试, 2020, 3(02):512-519.
- [37] Tianmeng L , Lijie W , Ai M A , et al. Power system load forecasting based on clustering analysis and neural network[J]. Journal of Beijing Information Science & Technology University, 2018, 12(3):108-116.
- [38] 王瑞, 逯静, 孙忆枫, 等. 一种基于相似日和 RBF 神经网络的短期电力负荷预测方法:, 2020, 3(01):151-159.
- [39] Xu F Y , Cun X , Yan M , et al. Power Market Load Forecasting on Neural Network With Beneficial Correlated Regularization[J]. IEEE Transactions on Industrial Informatics, 2018(1):5050-5059.
- [40] 易礼秋. 基于 BP 和 SOM 神经网络相结合的电力负荷预测研究[J]. 科技创新与应用, 2020, 320(28):29-30+33. 37

致谢

指 标																																																																																										
疑似剽窃观点																																																																																										
<div>1. 可以看出，训练达到我们所期望的误差范围即 0.001 时所需要的训练步数是 500。</div> <div>2. 可以看出在训练到 46 步的时候，网络就训练到了我们所要求的误差范围。</div> <div>3. 对于隐含层节点数的选取同样要进行试凑，从表 4-5 中可以看出选取 28 个节点是最为合适的。</div> <div>4. 算法预测效果最佳，本文选取该算法对 BP 神经网络进行优化计算。</div>																																																																																										
疑似剽窃文字表述																																																																																										
<div>1. 代表的是 BP 网络可依照训练程度自行调整的值，在训练起步时，可将 m 值设置的较大，这样可以在一定程度上所获得的效果等同于梯度下降法；而随着训练的逐步进行，误差开始逐渐接近最小值，在无限接近极小点时，m 值会逐渐减小，直至为 0，这种情况下网络的修正方向就是拟牛顿法的修正方向，所以与其他方法相比较，L-M 法更为高效。</div> <div>2. 在以下网络建模中，目标误差都取 0.001。</div> <div>4.3.1 基于自适应 BP 算法的负荷预测采用自适应 BP 算法，即用 traingdx 训练函数对网络进行训练，它是通过自适应性的调整学习速率来避免人为对其选择不合适的问题。训练过程中如果修正后的权值对误差减小有益，那么就可以在此学习速率的基础上增加一个量；否则就减小一个量。</div> <div>通过试错的方法来选取隐含层的节点的个数，通过观察最后网络训练得到的误差以及所需要的训练步数而寻找最佳的隐含层节点数目。如表 4-1 所示，为当隐含层采用不同节点数时网络训练所得的平均误差以及达到误差的训练步数。通过表 22</div> <div>4-1 很明显看出当取隐含层节点数为 30 时误差是最小的，而且所需要的训练步数也是相对来说比较合适的，因此选择 30 个隐含层节点。</div> <div>表 4-1 网络训练平均误差和步数与隐含层节点数的关系</div> <table><tr><th>节点数</th><td>20</td><td>25</td><td>26</td><td>29</td><td>30</td><td>31</td><td>32</td><td>33</td><td>34</td></tr><tr><th>平均误差</th><td>0.0285</td><td>0.0273</td><td>0.0284</td><td>0.0269</td><td>0.0258</td><td>0.0261</td><td>0.0259</td><td>0.0261</td><td>0.0257</td></tr><tr><th>步数</th><td>425</td><td>427</td><td>512</td><td>452</td><td>500</td><td>524</td><td>597</td><td>614</td><td>712</td></tr></table> <div>最终经过学习训练，得到预测结果，如图 4-1 所示，为用自适应 BP 算法 6 月 23 日进行预测所得出的网络误差训练曲线。</div> <div>3. 图 4-1 网络误差训练曲线如图 4-2 所示为采用自适应 BP 算法训练后得到的 A 市 6 月 23 日预测负荷与当日实际采集负荷的对比曲线。</div> <div>如图 4-3 所示为训练后得到的预测负荷结果与期望负荷输出之间的误差曲线，但是只靠图形并不能看出真正的误差是否在我们要求范围内，后面对实际预测输出值进行分析。</div> <div>23 图 4-2 预测输出对比曲线图 4-3 网络误差曲线如表 4-2 所示，为通过自适应 BP 算法进行预测得到预测 24 小时负荷与实际 24</div> <div>小时负荷的一个比较，可以看到进行对比分析之后相对误差中最大为 8.36%，最小为 0.15%，最后得出平均相对误差为 2.54%。电力部门规定在进行短期预测时误差在 3%以内即符合要求，很显然，此方法符合要求。</div> <div>4. 如表 4-3 所示为用弹性 BP 算法进行训练时隐含层在选取不同节点数时得到的平均误差以及达到误差所需要的训练步数，从表中数据分析得出，隐含层在选取 23 个节点时，是最合适的。</div> <div>表 4-3 网络训练平均误差和步数与隐含层节点数的关系</div> <table><tr><th>节点数</th><td>10</td><td>15</td><td>20</td><td>21</td><td>22</td><td>23</td><td>24</td><td>25</td><td>30</td></tr><tr><th>平均误差</th><td>0.0317</td><td>0.0306</td><td>0.0293</td><td>0.0276</td><td>0.0263</td><td>0.0255</td><td>0.0257</td><td>0.0262</td><td>0.0255</td></tr><tr><th>步数</th><td>185</td><td>89</td><td>75</td><td>85</td><td>54</td><td>46</td><td>47</td><td>51</td><td>63</td></tr></table> <div>如图 4-4 所示是用弹性 BP 算法对 A 市 6 月 23 日负荷进行训练预测所得到的网络误差训练过程图。</div> <div>5. 图 4-4 网络误差训练曲线如图 4-5 所示，为采用弹性 BP 算法训练后得到的 A 市 6 月 23 日预测负荷与当日实际采集负荷的对比曲线。如图 4-6 所示为采用弹性 BP 算法训练后得到的预测负荷结果与期望负荷输出之间的误差曲线。</div> <div>图 4-5 预测输出对比曲线图 4-6 网络误差曲线如表 4-4 所示，是通过弹性 BP 算法进行预测最终得到的 A 市 6 月 23 日预测当天 24 小时负荷值与实际 24 小时负荷值的一个比较，可以看到通过对比分析之后相对误差中最大为 8.04%，最小为 0.06%，最后得出平均相对误差为 2.48%。可以看出，虽然就平均误差而言，比用自适应 BP 算法的小，但是预测结果相对不稳定。</div> <div>6. 表 4-5 网络训练平均误差和步数与隐含层节点数的关系</div> <table><tr><th>节点数</th><td>20</td><td>22</td><td>24</td><td>25</td><td>26</td><td>27</td><td>28</td><td>29</td><td>30</td></tr><tr><th>平均误差</th><td>0.0343</td><td>0.0288</td><td>0.0203</td><td>0.0235</td><td>0.0201</td><td>0.0221</td><td>0.0146</td><td>0.0168</td><td>0.0167</td></tr><tr><th>步数</th><td>6</td><td>7</td><td>7</td><td>11</td><td>5</td><td>8</td><td>6</td><td>9</td><td>10</td></tr></table> <div>图 4-7 是采用 L-M 算法对负荷进行预测得到的误差训练过程曲线，可以看出，利用 L-M 法时，训练到第 6 步的时候，误差就已经达到了我们所要求的误差范围，训练速度明显比前两种方法要好很多。</div> <div>图 4-7 网络误差训练曲线如图 4-8 所示，为采用 L-M 算法训练后得到预测负荷与当日实际采集负荷的对比曲线。如</div>	节点数	20	25	26	29	30	31	32	33	34	平均误差	0.0285	0.0273	0.0284	0.0269	0.0258	0.0261	0.0259	0.0261	0.0257	步数	425	427	512	452	500	524	597	614	712	节点数	10	15	20	21	22	23	24	25	30	平均误差	0.0317	0.0306	0.0293	0.0276	0.0263	0.0255	0.0257	0.0262	0.0255	步数	185	89	75	85	54	46	47	51	63	节点数	20	22	24	25	26	27	28	29	30	平均误差	0.0343	0.0288	0.0203	0.0235	0.0201	0.0221	0.0146	0.0168	0.0167	步数	6	7	7	11	5	8	6	9	10
节点数	20	25	26	29	30	31	32	33	34																																																																																	
平均误差	0.0285	0.0273	0.0284	0.0269	0.0258	0.0261	0.0259	0.0261	0.0257																																																																																	
步数	425	427	512	452	500	524	597	614	712																																																																																	
节点数	10	15	20	21	22	23	24	25	30																																																																																	
平均误差	0.0317	0.0306	0.0293	0.0276	0.0263	0.0255	0.0257	0.0262	0.0255																																																																																	
步数	185	89	75	85	54	46	47	51	63																																																																																	
节点数	20	22	24	25	26	27	28	29	30																																																																																	
平均误差	0.0343	0.0288	0.0203	0.0235	0.0201	0.0221	0.0146	0.0168	0.0167																																																																																	
步数	6	7	7	11	5	8	6	9	10																																																																																	

图 4-9 为误差曲线。

7. 网络误差曲线如表 4-6 所示, 经过分析可以得出相对误差中最大为 3.95%, 最小为 0.01%, 最后得出平均相对误差值 1.33%。符合短期电力负荷预测的误差要求。
8. 如图 4-11 所示, 为三种算法预测的误差对比分析, 很明显, 也能看出采用 L-M 法预测的误差最小。  
图 4-10 三种改进算法训练输出对比  
图 4-11 三种改进算法训练误差曲线对比
- 4.3.5 基于 L-M 法的负荷预测以上对
9. 法对 6 月 27 日即休息日的负荷进行预测。预测建模中同样目标误差选取 0.001。  
对于隐含层节点数的选择仍然采取试凑的方式, 通过多次的训练, 得出预测结果。如图 4-12 所示, 为采用 L-M 法对 6 月 27 日预测出的 24 小时负荷值与实际值的输出对比曲线。如图 4-13 所示为训练后得到的预测负荷结果与期望负荷输出之间的误差曲线。  
图 4-12 预测输出对比曲线
10. 日的预测当天 24 小时负荷值与实际 24 小时负荷值的一个比较, 经过分析可以得出相对误差中最大为 3.78%, 最小为 0.06%, 最后得出平均相对误差为 1.42%。符合短期电力负荷预测的误差要求。
11. 月的负荷及气象历史数据信息作为训练样本, 对深圳市 7 月份的每日的 24 小时点的负荷进行预测。预测算法同样采用对比分析出的效果最好的一种改进 BP 算法——L-M 法。如图

说明: 1. 总文字复制比: 被检测论文总重合字数在总字数中所占的比例

2. 去除引用文献复制比: 去除系统识别为引用的文献后, 计算出来的重合字数在总字数中所占的比例

3. 去除本人文献复制比: 去除作者本人文献后, 计算出来的重合字数在总字数中所占的比例

4. 单篇最大文字复制比: 被检测文献与所有相似文献比对后, 重合字数占总字数的比例最大的那一篇文献的文字复制比

5. 指标是由系统根据《学术论文不端行为的界定标准》自动生成的

6. 红色文字表示文字复制部分; 绿色文字表示引用部分; 棕灰色文字表示作者本人文献部分

7. 本报告单仅对您所选择比对资源范围内检测结果负责



✉ [amlc@cnki.net](mailto:amlc@cnki.net)

🌐 <http://check.cnki.net/>

👤 <http://e.weibo.com/u/3194559873/>