

分类号: \_\_\_\_\_

密 级: \_\_\_\_\_

UDC: \_\_\_\_\_

单位代码: 10078

# 华北水利水电大学专业硕士学位论文

基于 WT-QPIO-BP 的短期电力负荷预测

Short-term Power load forecasting based on WT-QPIO-BP

研 究 生 姓 名: 白苏赫

指 导 教 师: 朱雪凌 唐耀华

专 业 领 域: 电气工程

所 在 学 院: 电力学院

2022 年 03 月

# 独立完成与诚信声明

本人郑重声明：所提交的学位论文，是本人在指导教师的指导下，独立进行研究工作所取得的研究成果并撰写完成的。没有剽窃、抄袭等违反学术道德、学术规范的侵权行为。文中除已经标注引用的内容外，本学位论文中不包含其他人或集体已经发表或撰写过的研究成果，也不包含为获得华北水利水电大学或其它教育机构的学位或证书所使用过的材料。对本文的研究做出重要贡献的个人和集体，均已在文中作了明确的说明并表示了谢意。本人完全意识到本声明的法律后果由本人承担。

学位论文作者签名：白书新      保证人（导师）签名：朱厚波

签字日期：2022.5.31      签字日期：2022.5.31

# 学位论文版权使用授权书

本人完全了解华北水利水电大学有关保管、使用学位论文的规定。特授权华北水利水电大学可以将学位论文的全部或部分内 容公开和编入有关数据库提供检索，并采用影印、缩印或扫描等复制手段复制、保存、汇编以供查阅和借阅。同意学校向国家有关部门或机构送交论文原件或复印件和电子文档。（涉密的学位论文在解密后应遵守此规定）

学位论文作者签名：白书新      导师签名：朱厚波

签字日期：2022.5.31      签字日期：2022.5.31

已按照答辩委员会意见进行修改

## 基于 WT-QPIO-BP 的短期电力负荷预测

### 摘要

短期电力负荷预测是电力系统安全和经济发展规划的重要组成部分，对电网调度优化、机组启停、国民经济都有着重要的影响，本文对短期电力负荷预测工作进行研究。

首先，分析国内外负荷预测技术的研究现状，介绍短期负荷预测的基本原理，通过对抚顺市电力日负荷特性、周负荷特性、季节负荷特性分析确定影响电力负荷的因素。

其次，在电力负荷预测模型方面，本文选取处理非线性数据能力较强的 BP 神经网络作为负荷预测的基本模型。针对 BP 神经网络容易陷入局部最优的问题，选取寻优速度较快的粒子群算法 (PSO) 和寻优能力较强的鸽群算法 (PIO) 优化 BP 神经网络的权值和阈值，并利用 PSO-BP 模型和 PIO-BP 模型对抚顺市电力负荷进行预测。仿真表明，PIO-BP 模型的预测结果更精确，验证 PIO 算法对 BP 神经网络有较好的优化效果。

再次，为解决鸽群算法寻优后期种群多样性减少的问题，本文融入量子信息理论。利用量子编码鸽群，扩展鸽群搜索空间，提升算法的全局寻优性能。并将改进后的基于量子鸽群算法 (QPIO) 与 BP 神经网络混合构建预测模型，利用 QPIO-BP 神经网络对抚顺市电力负荷进行预测，并通过仿真对比 QPIO-BP 和 PIO-BP 的预测效果，验证量子编码方法对 PIO 算法有较好的优化效果。

最后，针对原始电力负荷数据非线性的特点，将小波分解 (WT) 技术应用到数据处理中。通过 WT 分解技术将原始电力负荷序列分解为多个子序列，再结合 QPIO-BP 预测模型分别对各个子序列进行预测，然后将预测结果重构。通过仿真，WT-QPIO-BP 模型有效地提高了预测精度。

**关键词：**短期电力负荷预测；BP 神经网络；鸽群算法；量子信息；WT 技术

# SHORT-TERM POWER LOAD FORECASTING BASED ON WT-QPIO-BP

## ABSTRACT

Short-term power load forecasting is an important part of power system security and economic development planning, and it has an important impact on grid scheduling optimization, unit start-stop, and national economy. This thesis studies short-term power load forecasting.

Firstly, the research status of load forecasting technology at home and abroad is analyzed, the basic principle of short-term load forecasting is introduced, and the factors affecting power load are determined by analyzing the daily load characteristics, weekly load characteristics and seasonal load characteristics of Fushun City.

In the aspect of power load forecasting model, this thesis selects BP neural network with strong ability to deal with nonlinear data as the basic model of load forecasting. Aiming at the problem that the BP neural network is easy to fall into the local optimum, the particle swarm algorithm (PSO) with faster optimization speed and the pigeon swarm algorithm (PIO) with strong optimization ability are selected to optimize the weights and thresholds of the BP neural network, and the PSO-BP model and the PIO-BP model are used to forecast the electricity load in Fushun City. The simulation shows that the prediction results of the PIO-BP model are more accurate, and it is verified that the PIO algorithm has a better optimization effect on the BP neural network.

Thirdly, in order to solve the problem of the reduction of population diversity in the later stage of optimization of pigeon swarm algorithm, this paper integrates quantum information theory. Using quantum coding pigeons to expand the search space of pigeons and improve the global optimization performance of the algorithm. The improved prediction model based on Quantum Pigeon Swarm Algorithm (QPIO) and BP neural network is mixed to build a prediction model, and the QPIO-BP neural network is used to predict the power load in Fushun City, and the prediction effect of QPIO-BP and PIO-BP is compared through simulation. , to

verify that the quantum coding method has a better optimization effect on the PIO algorithm.

According to the nonlinear characteristics of the original power load data, the wavelet decomposition (WT) technology is applied to the data processing. The original power load sequence is decomposed into multiple sub-sequences by WT decomposition technology, and then combined with the QPIO-BP prediction model to predict each sub-sequence, and then the prediction results are reconstructed. Through simulation, the WT-QPIO-BP model effectively improves the prediction accuracy.

**KEY WORDS:** Short-term power load forecasting; BP neural network; Pigeon swarm algorithm; Quantum information; WT

# 目 录

摘 要.....	I
ABSTRACT.....	III
1 绪论.....	1
1.1 课题研究的背景和意义.....	1
1.2 短期负荷预测研究现状.....	2
1.2.1 传统预测方法.....	2
1.2.2 现代预测方法.....	4
1.3 本文主要研究内容.....	5
2 负荷预测基本理论和抚顺市电力负荷特性.....	7
2.1 电力负荷预测的基本理论.....	7
2.1.1 电力负荷的构成.....	7
2.1.2 电力负荷预测分类.....	7
2.1.3 电力负荷预测特点.....	8
2.2 电力负荷预测的评价指标.....	9
2.2.1 电力负荷预测误差产生原因.....	9
2.2.2 电力负荷预测误差评价指标.....	9
2.3 短期电力负荷预测的基本步骤.....	10
2.4 抚顺市负荷预测相关情况.....	11
2.4.1 抚顺市情况简介.....	11
2.4.2 抚顺市电网现状.....	12
2.4.3 2021 年抚顺市电力负荷指标完成情况.....	12
2.4.4 抚顺市负荷变化规律.....	12
2.5 本章小结.....	16
3 基于 PIO-BP 神经网络的短期电力负荷预测.....	17
3.1 BP 神经网络.....	17
3.1.1 BP 神经网络模型.....	17
3.1.2 BP 神经网络的训练.....	18
3.2 BP 神经网络短期负荷预测.....	20
3.2.1 BP 神经网络模型设计.....	20
3.2.2 基于 BP 神经网络的短期负荷预测.....	21
3.3 智能群算法.....	23

3.3.1 智能群算法研究背景 .....	23
3.3.2 粒子群算法 .....	24
3.3.3 鸽群算法 .....	25
3.4 鸽群算子模型 .....	26
3.5 PIO-BP 神经网络模型 .....	29
3.5.1 PIO-BP 神经网络模型分析 .....	29
3.5.2 PIO-BP 神经网络模型流程 .....	29
3.6 智能群算法优化 BP 短期负荷预测 .....	30
3.6.1 基于 PSO-BP 短期负荷预测 .....	30
3.6.2 基于 PIO-BP 短期负荷预测 .....	31
3.6.3 PSO-BP 与 PIO-BP 的对比 .....	33
3.6.4 PIO-BP 与其它预测模型的对比 .....	34
3.7 本章小结 .....	35
4 基于小波分解法的 QPIO-BP 短期电力负荷预测 .....	37
4.1.量子信息 .....	37
4.1.1 量子比特 .....	37
4.1.2 量子旋转门 .....	39
4.2 基于量子改进鸽群算法流程 .....	39
4.2.1 产生原始鸽群 .....	39
4.2.2 解空间变换 .....	40
4.2.3 鸽子状态的更新 .....	40
4.2.4 QPIO 算法过程 .....	41
4.3 基于 QPIO-BP 的短期负荷预测 .....	41
4.4 基于 WT-QPIO-BP 电力负荷预测 .....	43
4.4.1 小波分解原理 .....	43
4.4.2 基于 WT 的电力负荷数据分解 .....	44
4.4.3 基于 WT-QPIO-BP 的负荷预测流程 .....	45
4.5 基于 WT-QPIO-BP 的短期负荷预测 .....	46
4.6 本章小结 .....	49
5 结论与展望 .....	51
5.1 结论 .....	51
5.2 展望 .....	52
攻读学位期间参加的科研项目及发表的学术论文 .....	53

目录

---

致谢.....	55
参考文献.....	57

# 1 绪论

## 1.1 课题研究的背景和意义

电力行业作为我国国民经济中重要的基础性产业，始终以平稳高效的运行服务于国家能源战略大局，服务于国家与地方经济和社会高质量发展，在国家能源与经济发展战略中占据着十分关键的地位。面对社会经济高质量发展的新局面，我们要着眼于电力供需问题，满足人民群众的幸福美好生活与国家经济的高速发展对充足、可靠能源的需求<sup>[1]</sup>。目前我国用电需求结构已经从原有的架构转变，呈现出用电峰谷间差距增大、尖峰负荷数值飙升但持续时间短暂、平均负荷率相对降低等用电负荷新问题、新趋势、新常态。2021年9月中下旬以来，引发众多关注的、范围涵盖多省的“拉闸限电”问题，值得我们对于电源结构等问题进行更加深入的思考<sup>[2]</sup>。我们要准确、清晰地认识目前电源结构所存在的问题，甚至从其本身延伸到当前电力系统所存在的全部问题，就必须遵从能源转型的趋势和逻辑角度，用双维度、双思想去思考、研究电力的能源结构解决方案<sup>[3]</sup>。

“十四五”时期，我国电力工业想要如期实现加快绿色智慧转型、构建高质量发展格局的预期目标，就必须进一步优化电力结构<sup>[4]</sup>。现如今，伴随着城镇化比例越来越高，电网形态呈现多元化的发展态势，这就要求今后一段时间内，电力系统要认真践行电力为人民服务的宗旨，全力服务于区域经济协调、乡村振兴等国家重大战略实施，着力解决好电网发展不平衡不充分的问题。为确保电力系统的安全、稳定、高效运行，电力负荷预测已成为目前电力系统的常态化工作<sup>[5]</sup>。

电力负荷预测是在充分考虑历史负荷、对电力系统运行存在影响的电价因素、气象数据、社会事件等多重参考因素的条件下，在满足一定精度的要求下，对未来特定时段内的负荷数值做出合理、准确的预测。电力负荷预测按照时间尺度可以划分为长期负荷预测(Long-term load forecasting, LTLF)、中期负荷预测(Medium-term load forecasting, MTLF)、短期负荷预测(Short-term load forecasting, STLF)和超短期负荷预测(Very short-term load forecasting, VSTLF)四种类型<sup>[6]</sup>。其中短期负荷预测是对电力负荷未来几小时或者几天时间间隔内的数据预测。由于时间尺度较短，所以短期负荷预测相比于其他时间间隔的预测所需要的精度要求更高。由于电力负荷数据具有非线性增长、波动性较大等特征，传统方法难以对电力负荷进行准确的预测<sup>[7]</sup>，近几年来大量智能算法被应用到负荷预测中<sup>[8,9]</sup>。

辽宁省作为新中国工业摇篮，经济一直在稳步发展，也在追求转型。2021年辽宁省发电量为2147亿千瓦时，同比增长4.7%。抚顺市是辽宁省重要工业基地，非常重视基础设施的建设。目前，清源抽水蓄能电站这一工程正在抚顺市内建造，整个工程的投资额是109亿元，电站总装机容量是1800兆瓦，机组台数是6台，规划年发电量30亿千瓦时，抽水电量40亿千瓦时。电站预计会在2023年投入使用，将并入辽宁电

网完善东北地区电网电源结构。

综上，由于抚顺市经济的发展以及电网结构的更新，为服务于抚顺市经济调度，保证电网平稳高效地运行、合理安排电网内部的机组启停、实现的电力调度优化，本文利用抚顺市 2021 年负荷数据进行短期负荷预测。

## 1.2 短期负荷预测研究现状

上世纪 70 年代，电力系统负荷预测成为国内外研究热点。Box-Jenkins 提出了时间序列方法为现代电力负荷预测奠定了基础。电力负荷是具有连续性和数值性的序列，时间序列法就是利用其连续性，得出负荷的变化规律实现预测。20 世纪 80 年代，我国展开了对电力负荷预测模型的研究。在当时电力短缺的情况下，我国存在限电、停电等情况，造成了历史负荷数据短缺的情况，曾朝晖等基于平稳随机过程中的自回归动平均模型（ARMA），对原始数据进行了处理，初步提高了电力负荷预测精度<sup>[10]</sup>。在 20 世纪 90 年代出现了人工智能技术，国内外学者将人工智能应用到负荷预测中，使得电力规划事业有了迅速的发展<sup>[11]</sup>。这些方法不需要对数据结构和相关的知识有相关的了解，也不需要识别复杂的系统来构造过程的数学模型<sup>[12]</sup>。总结现有的预测方法，大致可以分成两类：传统预测方法和现代预测方法。其中传统的预测方法主要有相似日法、回归分析法、趋势外推法、卡尔曼滤波法、指数平滑法灰色预测和时间序列法等。传统的预测方法经过多年的研究应用，已经建立比较成熟的理论体系，但是在处理非线性的负荷数据时预测效果并不理想<sup>[13]</sup>。为改善传统预测方法的局限性，基于智能算法的现代预测方法被陆续提出：支持向量机法、小波分析方法、混沌理论、模糊预测方法和组合模型预测方法等。

### 1.2.1 传统预测方法

#### （1）趋势外推法

趋势外推法是根据过去事物的规律推测未来事物的一类方法的总称。趋势外推法的原理是：对于事物过去发展产生影响的因素，在一定程度上也影响着事物未来的发展，且事物的发展不会发生突变。所以趋势外推法所预测的变化规律一般是递进式，而不会是跳跃式。由于电力负荷的变化具有一定的规律性，在找到其变化趋势后，就可以利用趋势外推法来进行负荷预测。文献[14]将历史的负荷数据通过数学模型进行拟合，拟合成一条负荷曲线。按照该曲线反映的负荷变化趋势对未来的负荷进行预测。

趋势外推法采用线性模型、生长曲线、指数曲线等数学模型来表达事物随时间变化，属于一种模型预测法。被应用在实际负荷预测时，一般采用简单的数学模型来拟合数据点。

#### （2）灰色预测法

人们把未知的信息看作是黑色，把已知的信息看成是白色，用灰色来表达只了解一部分的、难以精确表达的信息，这就是灰色理论。灰色理论可以从已知的条件中获

取有价值的信息，用来研究由于缺少信息的不确定性问题、不确定性系统。灰色预测以灰色理论为基础，利用灰色预测法进行负荷预测时，不需要全部的原始负荷数据，而且可以把杂乱无章的负荷数据处理成规律性或线性数据，得到光滑离散的函数，再进行预测研究。文献[15]运用傅里叶函数处理预测值和原始数据之间的误差。修正后叠加到预测值上，修正了预测值与实际数据之间的误差。文献[16]在传统GM(1, 1)模型基础上，引入马尔可夫方法，利用残差的预测值来对预测负荷数据进行修正，以此来改进预测模型；文献[17]在传统GM(1, 1)模型的基础上建立了含几个变量的GM(1, n)模型并改变参数的赋值方法，建立新的灰色预测模型解决了传统GM(1, 1)模型仅适用于单一变量的问题。

灰色预测法具有模型简单，并且所需要原始数据量少等优点；但是GM(1, 1)处理大量数据时精度较差、无法完成影响因素过多的预测工作。

### (3) 时间序列法

时间序列法是数理统计中的方法，常用于研究事物的发展规律。时间序列法的研究对象是变化的动态数据，通过分析总结出动态数据随时间的变化规律，构建合适的数学模型，在已知过去值和当前值对未来值进行预测的方法。在用时间序列法进行负荷预测时，负荷被看作是一组随时间变化的数列，根据负荷随时间变化的趋势来搭建合适的模型。然而时间序列法对于影响电力负荷预测的因素没有考虑全面，在对波动性较大的负荷进行预测时误差较大。文献[18]提出将时间序列和BP神经网络相结合进行预测，首先利用时间序列法进行预测，然后用BP神经网络对时间序列法预测输出结果的误差进行预测和修正；文献[19]对于受季节性因素影响较大的数据进行研究，为改进原有模型，调整影响因素顺序，按照自回归项、移动平均项、差分项、季节性项排序，达到提高预测精度的效果。文献[20]对移动平均法和时间序列法赋予不同的权重，将两种预测模型组合，提高了原有预测模型的精度。

### (4) 回归分析法

回归分析法用于电力负荷研究时，将负荷原始数据看成自变量，影响电力负荷因素看成因变量，通过分析自变量和因变量之间的关系，建立预测模型完成预测。由于原始的负荷数据是杂乱的，利用回归分析法进行预测时，需要找到合适的非线性模型。在完成数据量庞大的预测任务时任务量较大。文献[21]提出一种改进后的模糊回归分析算法。

按照不同预测任务下，两种方法的侧重程度，赋予可调的权重值给两种算法，让两种算法很好的结合。文献[22]利用小波分解法对负荷序列进行分解，分解成四部分，分别利用回归分析法进行预测，得到预测结果后，把四部分重构组合，得到最终的预测值；文献[23]采用偏最小二乘回归法获取电力负荷与各影响因素的关系方程，考虑到经济发展期间的不同场景，调整不同场景下的参数，建立了多个宏观和微观结合的负荷预测模型。

### (5) 相似日法

相似日法用于电力负荷预测时，需要找到与待预测日气温、季节、日期类型等因素相似的日期。然后根据待预测日的负荷属性进行参数修正，得到待预测日的负荷值。相似度计算公式参数原本需要人工赋值，为解决参数多维优化文献[24]运用果蝇算法训练结果赋值给相似度计算公式，明显提高了预测的准确度；文献[25]对相似日负荷预测产生的误差进行预测，根据相似日负荷预测产生的误差调整原预测模型预测参数，有效地提高预测准确度。文献[26]利用改进的聚类分析算法得到所要预测曲线的相似集与特征曲线，再利用相似集内负荷曲线的进行预测。相对于传统的相似日法，预测精度大大提高。

## 1.2.2 现代预测方法

### (1) 专家系统方法

所谓专家系统，就是把专家解决特定问题所用的专业知识存放在知识库中，然后利用知识库像专家一样解决各种复杂的问题<sup>[27]</sup>。它的实质是一种强大的人工智能程序，可以模拟、复制专家的脑力劳动进行工作，甚至有时候工作效果会超过专家的脑力工作效果。文献[28]提出一种集成蚁群优化、遗传算法的智能负荷预测专家系统，改善了专家系统运行速度慢、过分依赖经验等缺点。文献[29]提出一种改进的模糊专家系统，增加了传统专家系统的透明性、灵活性以及启发性。

### (2) 支持向量机法

支持向量机 SVM (Support Vector Machines, SVM) 的基本思想是在高维空间中解决低维空间的问题，关键在于如何在高维空间建立函数以及如何完成低维到高维的映射。凸二次规划问题是支持向量机算法的本质，任何问题通过映射处理后都会回到该本质下解决问题<sup>[30]</sup>。SVM 的优点之一是对样本规模要求较小，样本数量的大小对 SVM 参数的影响比较小。支持向量机的参数有核函数以及误差惩罚参数，把 SVM 应用在负荷预测时，任何参数选取的偏差都会严重影响负荷预测的结果。为提高 SVM 参数选取的精准性，文献[31]利用灰狼算法对 SVM 的参数进行寻优，加快了 SVM 的收敛速度。文献[32]分别用网格搜索法、粒子群优化算法、遗传算法对 SVM 进行优化，改善了其计算速度较慢的缺点。

### (3) 模糊预测法

对于电力负荷呈现非线性和不确定性，几乎不可能建立精确的数学模型来描述其动态过程。模糊系统的优点之一在于其不需建立模型，它模拟专家的推理和判断方式对负荷进行预测<sup>[33]</sup>。模糊系统是用来描述知识的，对于我们不知道的隐形知识，可以通过其输入和输出建立模糊系统<sup>[34]</sup>。实际的电力负荷预测中，存在很多模糊现象，采用模糊预测的方法，可以很快将这些模糊现象定性。

### (4) 人工神经网络法

人工神经网络 (ANN) 是一种可以模拟人类大脑思考过程的数学工具<sup>[35]</sup>。20 世纪 80 年代末，人工神经网络首次应用于负荷预测，由于 ANN 良好的数据分类和拟合的能

力,非线性、多变量建模成为可能。人工神经网络解决了人工智能在非结构化信息方面、处理直觉方面的缺点,使负荷预测进一步发展<sup>[36]</sup>。目前应用比较广泛的 ANN 有:自组织映射神经网络(SOM)、感知器神经网络(PNN)、反向传递神经网络(BP)等。ANN 目前已经被用在各个领域。文献[37]用改进后的遗传算法优化 BP 神经网络,使得 BP 神经网络初始的权值和阈值达到了更好的标准,并考虑天气和日期等因素,用优化后的神经网络模型预测了地铁客流量。文献[38]将新闻情感倾向值与股票关键指标进行融合,并通过权重的方式组合 BP 神经网络和时间序列模型,建立了一种可以考虑财经新闻情感倾向值的股票收盘价格预测方法。文献[39]将 PNN 神经网络和遗传算法相结合进行变压器的故障诊断,提高了诊断的正确率。

传统的预测方法普遍运用数学模型,其所构建的模型比较简单,计算较快。但是普遍依赖于历史数据,在数据量较小的情况下达不到预测标准;稳定较低,在有突发情况发生造成负荷突变的情况下,预测误差增大;对于负荷影响比较大的因素无法完全考虑,预测精度偏低。

现代预测方法智能性较好,可以充分考虑电力负荷的影响因素。但是现代预测模型的参数选择比较重要,一旦参数选择失误,模型达不到预期预测效果;且现代预测模型计算量较大,在处理负荷数据时所需时间较长。

### 1.3 本文主要研究内容

本文以电力负荷短期预测为研究对象,以抚顺市 2021 年负荷数据为例,考虑温度等影响电力负荷的因素,建立以 BP 神经网络为基础的短期负荷预测模型。研究内容以 BP 神经网络的优化算法以及电力负荷数据重构为重点,本文主要内容如下:

第一章:阐述了本文研究内容的背景,其次叙述了短期负荷预测的研究现状,详细介绍了目前应用于短期负荷预测的方法。

第二章:详细介绍了短期负荷预测的基本理论,包括电力负荷的构成、电力负荷预测的特点;说明了电力负荷预测的基本步骤以及电力负荷预测误差产生的原因和误差评价指标。结合抚顺市日负荷特性、周负荷特性以及季节负荷特性确定影响电力负荷的主要因素。

第三章:介绍了 BP 神经网络的结构和训练过程,针对 BP 神经网络的缺点提出优化算法进行改进。对比提出的智能群算法,选择搜索效率高,搜索精准的鸽群算法对 BP 神经网络进行优化。

第四章:针对上文提出的鸽群优化算法(PIO)后期种群规模减小容易陷入局部最优的缺点,利用量子编码鸽群可以扩展搜索的遍历性的优点对鸽群算法进行改进,提出基于量子的鸽群算法(QPIO),并对 BP 神经网络进行改进(QPIO-BP)。为进一步提高模型精确度,利用小波分解技术(WT)对电力负荷原始数据进行处理,结合 QPIO-BP 神经网络模型对负荷数据进行预测分析。

第五章：结论与展望。本文总结了根据抚顺市电力负荷特性选出负荷预测模型的详细步骤，介绍了每一步涉及到的负荷预测模型的预测效果。分别从选取影响电力负荷因素方面、所选用预测模型方面、负荷数据处理方面提出改进意见。

## 2 负荷预测基本理论和抚顺市电力负荷特性

### 2.1 电力负荷预测的基本理论

#### 2.1.1 电力负荷的构成

电力系统承担着为千家万户、企业单位、事业单位输送电能的责任。电力系统负荷一般可以按如下分类进行划分：城市民用、商业、农业、工业和其他，不同的电力负荷有着不一样的周期特性。

城市的民用负荷主要来自于居民的日常生活。随着经济的发展，民用负荷有着年年增加的趋势。由于空调、电暖器等设备耗电较大，所以居民用电有着明显季节性波动的特点。民用负荷和居民自家经济水平也有一定的关系，电价上涨时，经济条件较好的家庭不会考虑价格问题而改变用电量，而经济水平一般的家庭会根据电价转移用电时间段。

商业负荷主要来自于大型商场、宾馆、餐饮店等等。商业用户的种类比较丰富，但是其特性差别不大，主要是照明、空调设备、以及动力用电设备消耗负荷<sup>[40]</sup>。一般商业负荷用量小于工业负荷，但是其商业照明负荷占据着用电高峰。

工业负荷分为轻工业和重工业，城市中工业用电需求量较大，占国家最大的耗电比例<sup>[41]</sup>。抚顺市是辽宁省重要工业基地，石化产业占工业用电负荷的大部分，而石化产业属于重工业，不宜调整生产方式，和季节性关系不大，所以抚顺市工业负荷大概恒定。

农业负荷是指在农村地区用于农村工业、农副产品加工的电力负荷。农村负荷受到气候、地理位置等自然条件影响比较大，一般在傍晚和清晨有用电小高峰。相比于城市地区，农村地区用电负荷受经济、人口因素影响较大，目前国家鼓励乡村振兴背景下，我国农村地区快速发展，用电量将呈持续上涨趋势，所以我国农业负荷将更新其特性<sup>[42]</sup>。

综上所述，影响电力负荷特性的原因众多：地区的经济水平、电价、气候情况以及国家政策等对负荷都有一定的影响。所以在进行负荷预测时，需要多方面考虑建立精准的预测模型。

#### 2.1.2 电力负荷预测分类

##### (1) 按行业分类

按照用电所处的行业可以把电力负荷预测分为：农业用电预测、工业用电预测、居民用电预测等。其中农业用电量受季节和降雨量影响很大，在春季播种和秋季收获的时节农业用电量增加显著，而降雨量影响着农业的灌溉和排水；工业用电负荷在城市总用电量占有较大的比重，一般不会发生突变，受到温度、天气、降雨量等气候因

素的影响较小；居民用电量受温度影响较大，随着社会经济发展，越来越多的家庭使用空调、电暖器等现代化设备，所以居民用电呈上涨趋势。

### （2）按预测对象分类

可以根据相关单位的负荷预测要求，把预测对象分为：母线预测、网供预测、平均负载预测、最高负载预测等类别。

### （3）按时间分类

负荷预测按照时间尺度大小分为以下四类。

①长期负荷预测：对未来 3~5 年的负荷预测。长期负荷预测的结果一般用来规划国家电网未来发电安排，与国民经济的发展、人口变动、地理条件改变等不确定因素密切相关，所以这一类负荷预测难度很大。

②中期负荷预测：指对未来 1 个月~一年内的负荷预测。中期负荷预测一般用来制定火电站燃料变化、水电站抽水调度、机组检修和扩建电网等，对预测精度有一定的要求。

③短期负荷预测：未来几天或几小时负荷预测。短期负荷预测通常用来在实际工程中制定日调度计划。

④超短期负荷预测：为将来每小时、每分钟的负荷预测。超短期负荷预测一般用来预测很短时间内的负荷变化，在发电机发电功率控制上应用广泛，由于其可以反映超短时间内用电的改变，为调度人员实时控制发电量提供了方便。

## 2.1.3 电力负荷预测特点

电力负荷预测把对电力负荷原始数据以及影响电力负荷的相关数据通过特定的程序、方式、模型等结合起来并加以分析。目的在于得出电力负荷的变化规律来预测未来的电力负荷。但由于环境因素、社会因素、人为因素等，使得负荷预测有不确定性、条件性、多方案性等特点。

### （1）不确定性

负荷的变化虽然有一定的规律可循，但是电力负荷的变化受到多方面因素的影响。在进行电力负荷预测时，人们往往通过以往的规律来进行预估。但是有一部分不确定因素很难预见，比如突发的事件、天气骤变、电力系统故障等，都会对预测产生影响，所以电力负荷预测有着一定的不确定性。

### （2）条件性

电力负荷预测的整个预测工作会受到预测模型、特定外界条件、历史负荷等相关因素的影响，很多因素难以估计，所以需要假设一些条件来预测未来时刻的电力负荷值。

### （3）多方案性

从数据角度考虑，电力负荷本身是非线性数据，没有确定的规律；从对负荷影响因素角度考虑，影响因素选择的不同、各个因素权重不同以及突发事件的发生都将导

致预测结果不唯一。所以在选择负荷预测方案时，需要尽可能的考虑全面，提出多种方案对比，保证预测的精确性。

## 2.2 电力负荷预测的评价指标

### 2.2.1 电力负荷预测误差产生原因

通常情况下，我们在进行负荷预测时，为保证效率会忽略对电力负荷影响相对薄弱的因素，仅选择诸如气象等对电力负荷影响较强的因素。这种选择影响因素的方法尽管可以较好地满足简单系统对精度的要求，但是在更为复杂的电力系统中，由于其负荷波动的规律性尚不明确，且在预期模型中所考虑的因素并不详细，导致负荷预测结果往往与实际值之间存在着较大的差异。然而实际上，在建模过程中不论忽视了怎样的薄弱因素，都会不可避免地出现误差。

由于电力负荷预测往往是在采集得到的原始数据的基础上进行的，负荷预测的精度通常取决于历史数据资料的完整性和有效性。因此收集足够全面的数据资料是进行负荷预测的首要任务。在实际情况下，尽管综合考虑了各种因素的影响，通过绝对严谨的资料收集途径对资料进行收集，由于非人为因素的不可控，我们仍然无法保证所收集数据的完整无误，且数据自身缺损的信息是真实存在的，我们只能尽量高度还原历史资料数据的完整性。由于历史数据信息无法达到绝对的准确完整，因此负荷预测模型无论怎样训练和学习也不能准确地获得系统的真实规律，进而出现不可避免的误差。

在生活中有很多的突发事件，这些无法预知的事件也会给负荷预测带来影响，从而引起误差。例如，电网事故可能导致大规模停电，计划外的电厂停机以及大规模停电，突发事件等电力行业中不可预测或未知的随机事件，都会对负荷有影响。这些随机事件的影响在进行负荷预测时无法做到提前修正，导致难以避免的误差。

### 2.2.2 电力负荷预测误差评价指标

由于电力负荷预测不确定性、多方案性等特点，对电力负荷进行预测时，不可避免地出现一定地误差。如何客观地评价误差、根据误差及时调整模型的精度是负荷预测工作中重要的部分。

为对负荷预测模型精度有更深一步分析，本文选用几种常用的误差评价指标：

(1) 平均绝对百分比误差 (MAPE)：

$$MAPE = \frac{1}{w} \sum_{i=1}^w \left| \frac{y_i - \tilde{y}_i}{y_i} \right| \quad (2.1)$$

(2) 均方根误差 (RMSE)：

$$RMSE = \sqrt{\frac{\sum_{i=1}^w (y_i - \tilde{y}_i)^2}{w}} \quad (2.2)$$

(3) 平均绝对误差 (MAE) :

$$MAE = \frac{1}{w} \sum_{i=1}^w |y_i - \tilde{y}_i| \quad (2.3)$$

式中,  $w$  为预测样本数,  $y_i$  为实际值,  $\tilde{y}_i$  为真实值。

MAPE 是平均绝对百分比误差, 表示预测值照比真实值偏离的平均程度。MAPE 越小说明误差越小, 模型精度越好。

RMSE 是均方根误差, 表示样本预测值和真实值之差的平均期望值。一般用来衡量样本误差的波动情况。

MAE 是平均绝对误差, 表示所有样本预测值和真实值之间偏差绝对值的平均值, 和所要预测的负荷值是同一单位。由于误差被绝对值化, MAE 不会出现正负相抵消的情况, 可以更好的反应实际的误差情况。

## 2.3 短期电力负荷预测的基本步骤

### (1) 制定相关计划

不同的地区电网对负荷预测的要求并不统一, 同一地方电网在不同时期对负荷预测要求也不同。在对具体地区进行负荷预测工作之前, 应该详细了解当地电网实际需求, 充分考虑不同场景调整预测方案, 制定全面的负荷预测计划。

### (2) 确定影响负荷因素

短期电力负荷预测受多种外界因素影响, 如: 日期类型、气象因素、经济因素以及突发事件因素等。在开始预测工作前, 应结合当地电网所提供的负荷数据, 进行负荷特性分析, 确定对负荷影响较大的因素。为减少不必要的工作量, 应该剔除对负荷没有影响或者影响很小的因素。

### (3) 收集并处理历史资料

历史数据的收集是短期电力负荷预测工作中重要的部分。数据的收集应该尽可能全面, 主要包括电力负荷数据、天气数据、温度数据、湿度数据、降雨量数据等。其中电力负荷数据是最基础最重要的部分。收集到历史数据后, 可以利用制作图表等辅助手段观察历史数据, 对数据中的异常点进行处理, 保证历史数据的准确性, 降低由于数据处理不当给负荷预测工作带来的影响。

### (4) 建立预测模型

同一历史数据集, 利用不同的模型进行预测输出的结果不同。为确保所选模型的优越性, 可以通过对比几种模型的预测效果进行模型的选择。构建负荷预测模型时, 不仅要考虑电力负荷的影响因素, 还要考虑各影响因素所占比重, 来完成模型参数的

初始化。

#### (5) 训练网络

将收集到的历史数据集划分为测试集、训练集。通过对训练集数据进行预测反复调整网络参数，提高模型泛化能力。

#### (6) 输出预测结果与模型分析

运用调整好的预测模型进行电力负荷预测，得到模型输出值，将输出值和数据真实值进行比对。通过输出值和真实值之间的误差对所选模型性能进行评估。如果误差较小且满足地区电网要求，则所建立的预测模型可以被实际运用。

负荷预测的程序框图如下：

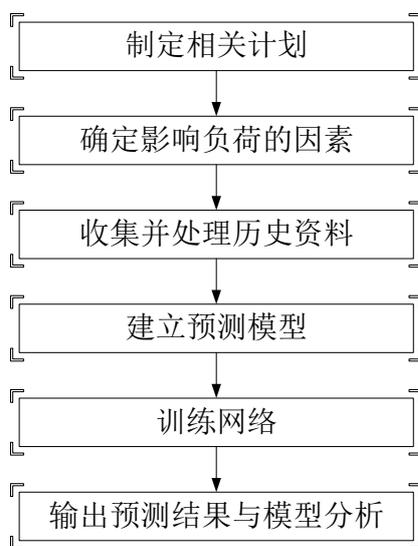


图 2-1 短期负荷预测流程图

Figure 2-1 Flow chart of short-term load forecasting

## 2.4 抚顺市负荷预测相关情况

对于某一城市进行短期负荷预测之前，应该结合当地经济水平、气候情况、产业特色和居民生活方式等背景分析负荷特性。

### 2.4.1 抚顺市情况简介

抚顺地处长白山西南延续支脉，南北两侧夹山地势。城市地理面积 11271 平方千米，人口 186.1 万，行政区划涵盖 4 区、3 县以及 2 个省级开发区。市区坐落于浑河河谷冲击平原之上，呈东西走向，长三十余千米，南北宽仅六至八公里。美丽的浑河自东向西贯穿整个市区，与其支流以及两个露天煤矿共同将市区分割为南部矿区、望花、东洲、河北、河南、章党和六大区域。抚顺市已经构成分散布局的城市格局：以河南、河北为主体，东洲、望花为两翼，南部矿区、章党共存。抚顺天然的地理优势与丰富自然资源，使其成为辽宁重要水源保护地，我国重要的能源、原材料老工业基地，城

市经济以煤矿、石化为主要经济产业。

## 2.4.2 抚顺市电网现状

抚顺电网通过蒲抚一、二线及抚程一、二线与辽宁 500 千伏主网相连。220 千伏通过顺灯线与辽阳电网相连；通过抚石一、二线及抚徐线与本溪电网相连；热友一、二线沈东分线与沈阳电网相连。目前已经形成北部以 220 千伏辽宁东方电厂、中电投抚顺热电厂为电源支撑点，南部以 500 千伏抚顺变及抚矿中机热电厂为电源支撑点的环网结构。

抚顺市电源规模：截至 2021 年 11 月，220 千伏公用电厂 5 家，总装机容量为 240 万千瓦；66 千伏及以下公用电厂 8 家，总装机容量为 16.43 万千瓦；企业自备电厂 3 家，总装机容量为 36 万千瓦。地区电网 0.6 万千瓦及以上发电厂 16 座，总装机容量 292.43 万千瓦。2021 年地区电厂发电量 78.42 亿千瓦时，上网电量 57.89 亿千瓦时。

抚顺市电网规模：截至 2021 年 11 月，地区电网共有 500 千伏变电站 1 座，变电容量 150 万千伏安，500 千伏输电线路 4 条，线路 309.1 千米；220 千伏公用变电站 14 座，变电容量 495 万千伏安，220 千伏输电线路 55 条，线路 1358.32 千米；66 千伏（含 35 千伏，下同）公用变电站 97 座，变电容量 455.5 万千伏安，66 千伏（含 35 千伏）输电线路 154 条，线路 2033.99 千米。

## 2.4.3 2021 年抚顺市电力负荷指标完成情况

全社会用电量：103.22 亿千瓦时，同比增长 1.81%，占全省全社会用电量的 4.43%，增长率排名全省第 9 位；工业用电量：78.01 亿千瓦时，同比增长 0.3%，占全省工业用电量的 4.84%；售电量：81.07 亿千瓦时，同比增长 3.83%，电量排名全省第 9 位，增长率排名全省第 13 位；售电收入：49.73 亿元，同比降低 1.6%；全口径售电平均单价：551.68 元/千千瓦时，同比下降 2.54 元/千千瓦时；市场占有率：90.34%；全社会最大负荷：164 万千瓦，同比增长 7.19%；全口径最大负荷：137 万千瓦，同比持平 4.58%；网供最大负荷：133 万千瓦，同比持平 3.1；综合线损率：2.48%；同比降低 0.17 个百分点；城网供电可靠 99.9475%；综合电压合格率 99.996%；农网供电可靠率 99.7396%；综合电压合格率 99.881%；

## 2.4.4 抚顺市负荷变化规律

在电力系统中，我们称一日内用电负荷高峰为峰荷、用电低谷为谷荷。下面根据抚顺市日负荷曲线、周负荷曲线、季节负荷曲线趋势，分析负荷特性，以便于建立预测模型，为抚顺市负荷预测提供有效服务。

### （1）日负荷特性

日负荷特性是指以一天内负荷波动所体现出的规律性。本文选取抚顺市 2021 年 3 月 11 日为典型工作日、3 月 13 日为典型休息日、10 月 1 日为典型节假日进行负荷特性

分析，每间隔 1 小时，读取一个负荷数据点。即，每天 24 个负荷数据点，日负荷曲线如图 2-2、2-3、2-4 所示。

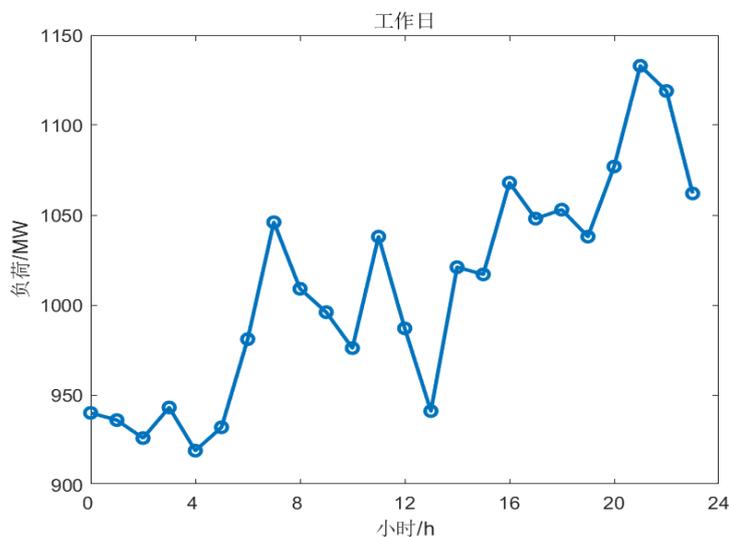


图 2-2 抚顺市典型工作日负荷曲线

Fig. 2-2 Typical working day load curve in Fushun

有图 2-2 可知，抚顺市的工作日用电峰荷大约出现在夜间 22 点左右。这种现象是由于抚顺市是重工业城市，在工作日工厂几乎 24 小时持续运转，工业负荷几乎不变。所以，用电高峰期出现的时间点主要取决于居民用电量大小。大概在傍晚 19 点后，居民用电负荷开始上升，22 点后居民陆续开始休息，居民用电负荷开始下降。抚顺市工作日谷荷大约出现在凌晨 2:00-4:00，该时间段居民几乎不进行工作、娱乐等活动。

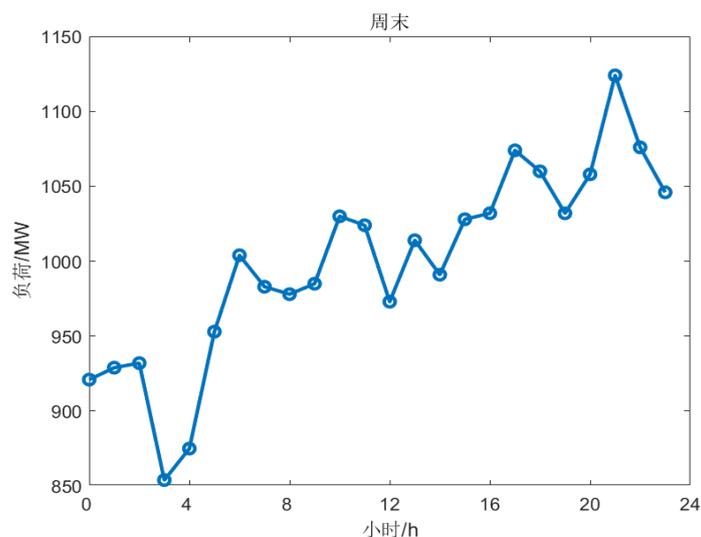


图 2-3 抚顺市典型休息日负荷曲线

Fig. 2-3 Typical rest day load curve in Fushun

对比图 2-2 和图 2-3 可知，抚顺市工作日和周末用电负荷大致相同，并且用电高峰大约都发生在夜间 21-23 点。这是由于东北地区人员消费水平不高，夜间娱乐场所较少，所以由于客观条件的限制，即使是周末，抚顺人民的作息时间和在工作日作息时间几乎相同。工作日和周末用电负荷的区别在于，工作日午间用电负荷明显下降，这是由于人们往往需要午休来调整状态，所以工作日午间用电量明显减少。

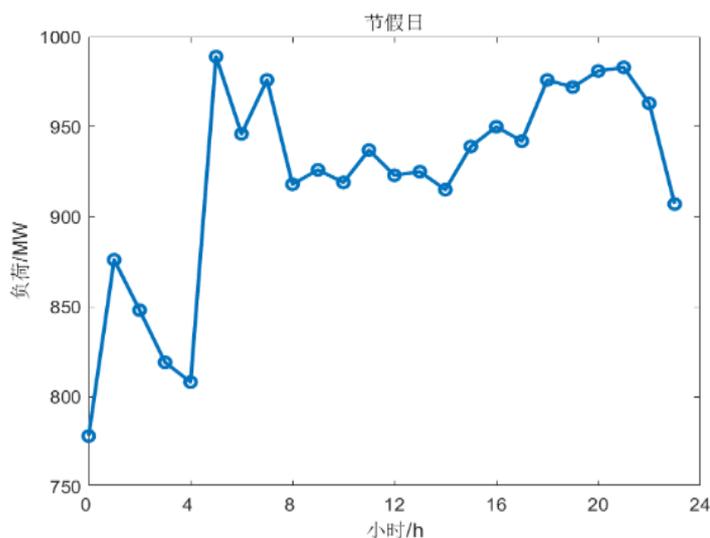


图 2-4 抚顺市典型节假日负荷曲线

Fig. 2-4 Typical holiday load curve in Fushun

由图 2-4 可知，节假日期间居民早起外出，所以用电负荷大约从凌晨 4 点开始大幅度增加；大概在上午 8 点，居民完成出行准备后，用电负荷开始下降；8 点到下午 16 点，用电负荷比较平稳；16 点之后用电负荷开始增加，到 22 点左右居民陆续休息时下降。相比于工作日，节假日峰荷用电量的整体用电负荷明显较小，这是由于节假日工厂休息的缘故。

### (2) 周负荷特性

选取抚顺市 2021 年 6 月 7 日到 6 月 13 日负荷数据，其中 6 月 7 日到 6 月 11 日是周一到周五，6 月 12 日到 6 月 13 日是周六和周日。每天每小时采集一次数据，一天 24 个负荷点，绘制的曲线如图 2-5 所示。

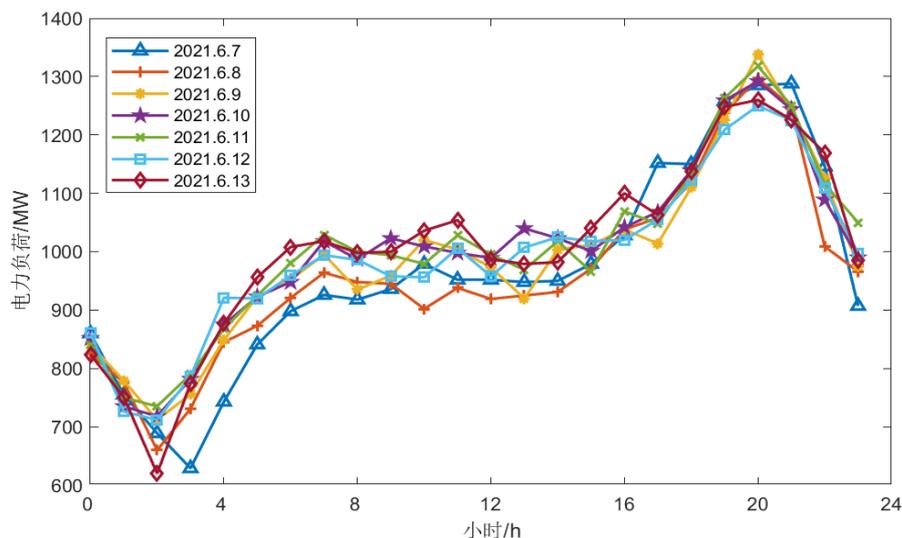


图 2-5 抚顺市一周负荷曲线

Fig. 2-5 one week load curve of Fushun

由图 2-5 可知，每周每天内负荷变化规律具有相似性，无论是工作日还是休息日，峰荷一般出现在 21-23 点。由于东北地区经济不发达，周末一般不需要加班，周六居民在进行休息调整，周日居民进行娱乐活动，一周内基本上周日用电负荷最大；一周内负荷峰值出现在周五夜晚，进行放松娱乐的时间；一周内谷荷出现在周一凌晨，居民都在休息迎来新一周的工作任务。

### (3) 季节负荷特性

选取抚顺市 2021 年 3 月 20 日、2021 年 7 月 15 日、2021 年 9 月 15 日、2021 年 12 月 15 日分别作为春、夏、秋、冬典型日进行负荷特性研究。每天每小时采集一次数据，每天 24 点负荷数据绘制曲线如图 2-6 所示。

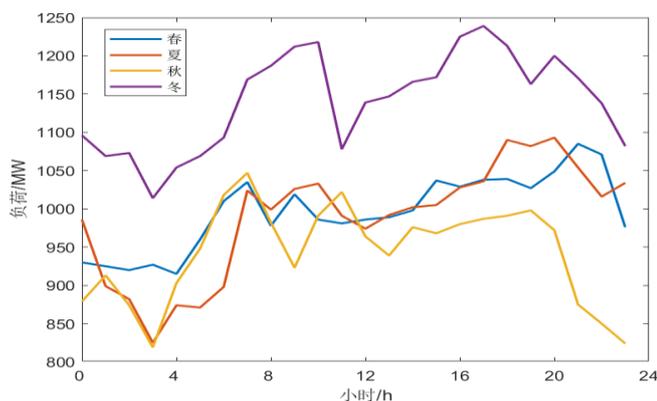


图 2-6 抚顺市各季节典型负荷曲线

Fig. 2-6 Typical load curve of each season in Fushun area

通过季节性因素研究地区负荷变化规律时，温度条件是不可忽略的因素。抚顺市春季、夏季、秋季的温度差别不大，但冬季十分寒冷，需要大量的负荷用于供暖。如图所示，通过对比其他三个季节的负荷曲线，可以推测供暖负荷大约占总负荷的 25%。在东北地区，由于秋季、冬季太阳下山时间会提前、天黑较早，所以人们入睡休息时间会相对提前，用电峰荷时间提前到 20 点之前，相比于其他三个季节有明显提前。

## 2.5 本章小结

本章介绍了负荷预测基本理论，具体介绍了电力负荷的构成以及电力负荷预测流程和预测误差分析。结合抚顺电网的负荷现状，分析了抚顺市电力负荷特性，初步确定影响抚顺市电力负荷的因素，为构建负荷预测模型提供基础。

### 3 基于 PIO-BP 神经网络的短期电力负荷预测

保证负荷预测精度对保证电力系统安全稳定运行尤为重要。BP 神经网络（Back Propagation, BP）是一种非线性系统，可以很好完成负荷预测。但由于其特殊的“梯度下降”训练方法，BP 神经网络存在待改善的缺点，因此，本章引入具有结果最优性、快速收敛性等明显优势的鸽群优化算法对其进行改进，并利用改进后的 BP 神经网络进行负荷预测。

#### 3.1 BP 神经网络

##### 3.1.1 BP 神经网络模型

BP 神经网络的结构如图 3-1 所示，负责接收外界给予信息的第一层为神经网络的输入层；负责输出处理过的信息的最后一层为输出层；在输入层和输出层中间还有若干个隐含层负责传递信息并完成信息的变换。

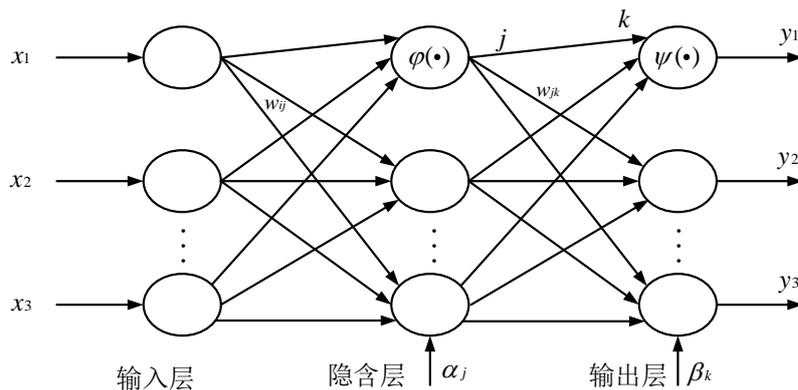


图 3-1 BP 神经网络结构

Fig. 3-1 BP neural network structure

假设在输入层有  $i$  个输入节点，隐含层有  $j$  个节点，输出层一共有  $k$  个输出节点。

式中  $\alpha_j$  和  $\beta_k$  分别代表隐含层第  $j$  节点和输出层第  $k$  节点的阈值。 $\varphi(\cdot)$  和  $\psi(\cdot)$  分别是隐含层和输出层的激活函数。

$w_{ij}$  为输入层和隐含层之间的权重，即：

$$W_{ij} = \begin{bmatrix} W_{11} & W_{21} & \cdots & W_{1j} \\ W_{21} & W_{22} & \cdots & W_{2j} \\ \vdots & \vdots & \vdots & \vdots \\ W_{i1} & W_{i2} & \cdots & W_{ij} \end{bmatrix} \quad (3.1)$$

$w_{jk}$  为隐含层和输出层之间的权重，即：

$$W_{jk} = \begin{bmatrix} W_{11} & W_{21} & \cdots & W_{1k} \\ W_{21} & W_{22} & \cdots & W_{2k} \\ \vdots & \vdots & \vdots & \vdots \\ W_{j1} & W_{j2} & \cdots & W_{jk} \end{bmatrix} \quad (3.2)$$

### 3.1.2 BP 神经网络的训练

BP 神经网络的训练过程由输入信息的正向传播和误差信号的反向传递两个部分组成。

#### (1) BP 神经网络的正向传播

BP 神经网络的正向传播就是将输入信号由输入层开始逐层传播到输出层，最终输出结果的过程。

隐含层第  $j$  个输入  $net(j)$  和输出  $G_j$  为：

$$net(j) = \sum_j^n w_{ij} \cdot x_i + \alpha_j \quad (3.3)$$

$$G_j = \phi \left( \sum_{i=1}^n w_{ij} + \alpha_j \right) \quad (3.4)$$

输出层第  $k$  个输入  $net(k)$  和输出  $G_k$  为：

$$net(k) = \sum_{j=1}^m w_{jk} \cdot G_j + \beta_k = \sum_{j=1}^m \phi \left( \sum_{i=1}^n w_{ij} + \alpha_j \right) + \beta_k \quad (3.5)$$

$$y_k = \phi[net(k)] = \phi \left[ \sum_{j=1}^m w_{jk} \cdot \phi \left( \sum_{i=1}^n w_{ij} + \alpha_j \right) + \beta_k \right] \quad (3.6)$$

#### (2) BP 神经网络的反向传播

BP 神经网络通过训练误差来调整输入层、隐含层的权重和阈值，这个调整的过程一般依据梯度下降法。误差反向传播的过程就是利用梯度下降法的原理，利用损失函数分别对权重和偏置求偏导数，也就是梯度向量。可以把梯度向量理解成斜率，梯度增加的地方是斜率大的地方，也就是训练误差增加快的地方；而梯度小的地方就是斜率小的方向，向着斜率小的地方寻找，更容易找到训练误差的最小值。

设定有  $n$  个数据集，那么可以用  $t_p^n = (t_1^n, t_2^n, \dots, t_p^n)$  来表示第  $n$  个数据集的期望输出。当实际输出  $y_k^n$  与期望输出  $t_k^n$  不符时，BP 神经网络进入到误差反向传播阶段。考虑到输入层、隐含层节点的误差无法通过输出信息直接获取，因此，反向传播法把输出层节点的预测误差通过计算后反向传递给隐含层节点；隐含层节点通过计算误差后再传递给输入

层。 $\gamma$  为梯度下降的学习率，也就是反向传播中梯度下降的步长。

全局误差函数的表达为：

$$E_g = \frac{1}{2} \sum_{n=1}^n \sum_{k=1}^k (t_k^n - y_k^n)^2 \quad (3.7)$$

输出层连接权值更新为：

$$\Delta w_{jk} = -\gamma \frac{\partial E}{\partial w_{jk}} = -\gamma \frac{\partial E}{\partial net(k)} \cdot \frac{\partial net(k)}{\partial w_{jk}} = -\gamma \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial net(k)} \cdot \frac{\partial net(k)}{\partial w_{jk}} \quad (3.8)$$

将输出层误差定义为  $\varepsilon_k$ ：

$$\varepsilon_k = -\frac{\partial E}{\partial net(k)} = -\frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial net(k)} \quad (3.9)$$

$$\frac{\partial E}{\partial y_k} = -\sum_{n=1}^n \sum_{k=1}^k (t_k^n - y_k^n) \quad (3.10)$$

$$\frac{\partial y_k}{\partial net(k)} = \psi'[net(k)], \quad \frac{\partial net(k)}{\partial w_{jk}} = G_j \quad (3.11)$$

则输出层权值更新为：

$$\Delta w_{jk} = \gamma \sum_{n=1}^n \sum_{k=1}^k (t_k^n - y_k^n) \cdot \psi'[net(k)] \cdot G_j \quad (3.12)$$

输出层阈值更新过程：

$$\Delta \beta = -\gamma \frac{\partial E}{\partial \beta_k} = -\gamma \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial net(k)} \cdot \frac{\partial net(k)}{\partial \beta_k}, \quad \frac{\partial net(k)}{\partial \beta_k} = 1 \quad (3.13)$$

则输出层阈值更新为：

$$\Delta \beta = \gamma \sum_{n=1}^n \sum_{k=1}^k (t_k^n - y_k^n) \cdot \psi'[net(k)] \quad (3.14)$$

输入层权值更新过程：

$$\Delta w_{jk} = -\gamma \frac{\partial E}{\partial w_{jk}} = -\gamma \frac{\partial E}{\partial net(k)} \cdot \frac{\partial net(k)}{\partial w_{ij}} = -\gamma \frac{\partial E}{\partial G_j} \cdot \frac{\partial G_j}{\partial net(j)} \cdot \frac{\partial net(j)}{\partial w_{ij}} \quad (3.15)$$

定义隐含层误差为  $\varepsilon_j$ ：

$$\varepsilon_j = -\frac{\partial E}{\partial net(j)} = -\frac{\partial E}{\partial G_j} \cdot \frac{\partial G_j}{\partial net(j)} \quad (3.16)$$

$$\frac{\partial G_j}{\partial net(j)} = \varphi' net(k), \quad \frac{\partial net(j)}{\partial w_{ij}} = x_i \quad (3.17)$$

输入层权值更新为:

$$\Delta w_{ij} = \sum_{n=1}^n \sum_{k=1}^k (t_k^n - y_k^n) \cdot \psi' [net(k)] \cdot w_{jk} \cdot \varphi' [net(k)] \cdot x_i \quad (3.18)$$

隐含层阈值更新过程:

$$\Delta \alpha_j = -\gamma \frac{\partial E}{\partial \alpha_j} = -\frac{\partial E}{\partial G_j} \cdot \frac{\partial G_j}{\partial net(j)} \cdot \frac{\partial net(j)}{\partial \alpha_j}, \quad \frac{\partial net(j)}{\partial \alpha_j} = 1 \quad (3.19)$$

隐含层阈值更新为:

$$\Delta \alpha_j = \gamma \sum_{n=1}^n \sum_{k=1}^k (t_k^n - y_k^n) \cdot \psi' [net(k)] \cdot w_{jk} \cdot \varphi' [net(k)] \quad (3.20)$$

### (3) BP 神经网络的训练流程

BP 神经网络的权值和阈值两个参数在信号正向传播和误差反向传递的过程中不断更新。所谓训练 BP 神经网络的过程, 就是让网络参数不断更新的过程。以此, 让网络模型更为精确, 输出的预测效果更接近真实值。

①网络初始化: 按照经验给予网络隐含层、输出层赋予权值阈值。设定网络最小训练误差和最大学习次数;

②选取样本: 选取数据样本并设置训练集样本、测试集样本;

③隐含层、输出层计算: 输入信号, 通过神经网络计算隐含层和输出层各神经元的输入和输出;

④求偏导数: 利用神经网络输出值与真实数据值计算误差函数。计算误差函数对输出层神经元的偏导数、计算误差函数对隐含层神经元的偏导数;

⑤修正权值: 利用输出层各神经元的偏导数和隐含层各神经元的输出来修正隐含层链接权值; 利用隐含层各神经元的偏导数和输入层各神经元的输出修正输入层链接权值;

⑥计算全局误差: 运行修正过的 BP 神经网络模型, 输出模型的误差。

## 3.2 BP 神经网络短期负荷预测

### 3.2.1 BP 神经网络模型设计

#### (1) BP 神经网络输入向量、输出向量的设计

本文的预测目标是抚顺市 2021 年 12 月 31 日全天的整点负荷值。

本文选择 2021 年每天的整点负荷数据作为部分输入向量; 由于气象因素对电力负荷影响较大, 选用预测日当日最高温度 $^{\circ}\text{C}$ 、最低温度 $^{\circ}\text{C}$ 、平均温度 $^{\circ}\text{C}$ 、降雨量、相对

湿度 5 个气象指数作为另一部分输入向量。

综上，BP 神经网络有 29 个输入节点，24 个输出节点。

### (2) BP 神经网络的隐含层设计

隐含层的层数选取过多会影响网络处理数据的速度，按照经验来说，大部分单隐含层神经网络就可以解决预测问题。实际上，Robert Hecht-Nielsen 证明了对于单隐含层的 BP 神经网络可以逼近任何一个闭区间的连续函数。

综上，本文选用一个隐含层的 BP 神经网络模型。

隐含层节点的选取分为两步：

#### ① 由经验公式求取隐含层个数大概范围：

$$j = \sqrt{i+k} + a \quad (3.21)$$

式中， $i$  为输入神经元数， $k$  为输出神经元数， $a$  为 [1, 10] 之间的常数， $j$  为隐含层节点数。确定隐含层节点数大概在 8~17 之间。

#### ② 采用试错法

BP 神经网络模型由公式 (3.21) 计算得出的最小隐含层节点数开始运行，模型按照依次增加一个隐含层节点个数运行，直到运行至：按照经验公式计算出最大隐含层节点个数的网络，运行结束。对比各隐含层节点数网络的误差，选取出最合适的隐含层节点数。

表 3-1 隐含层神经元节点对应均方误差

Table 3-1 corresponding mean square error of hidden layer neuron nodes

隐含层神经元节点数	训练次数	均方误差
8	1000	12.73
9	1000	12.69
10	1000	13.12
11	1000	12.33
12	1000	12.80
13	1000	12.26
14	1000	12.88
15	1000	12.06
16	1000	12.81
17	1000	11.70

由表 3-1 可得，BP 神经网络隐含层节点数为 17 时，模型预测误差最小。

综上，文本所设计的 BP 神经网络有输入层节点数为 29、输出层节点数为 24、隐含层节点数为 17。

### 3.2.2 基于 BP 神经网络的短期负荷预测

建立 BP 神经网络模型进行短期负荷预测。设定网络训练次数为 1000，学习速率为

0.01，训练目标最小误差为0.000001。通过Matlab建模与分析，得到抚顺市12月31日24个时间点的预测曲线与真实曲线的对比图：

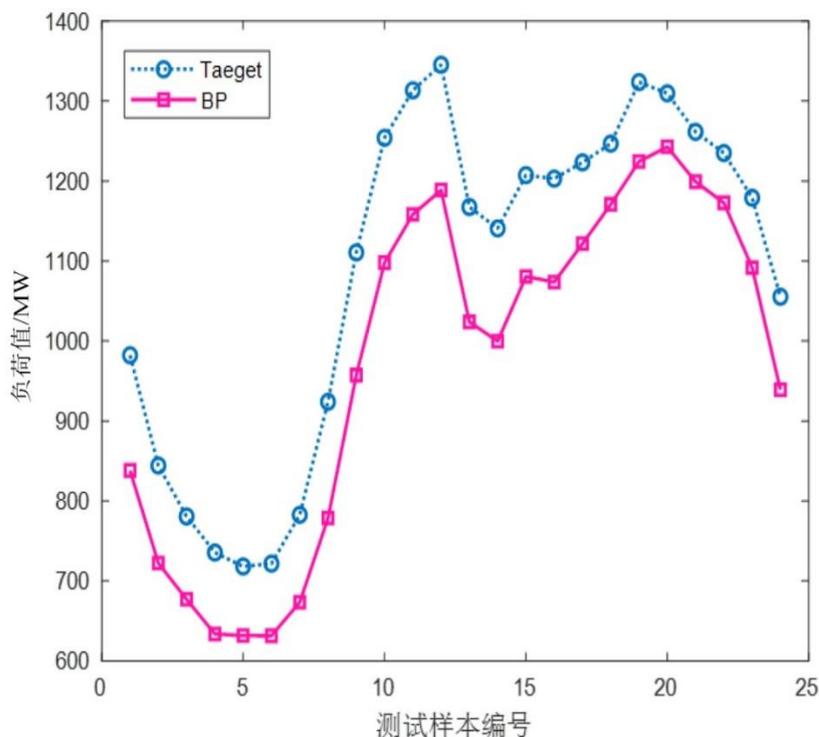


图 3-2 BP 神经网络预测结果图

Fig. 3-2 prediction results of BP neural network

图 3-2 中，蓝色的线为真实值、粉红色的线为 BP 神经网络输出的预测值。虽然图中的两条曲线大致走势相同，但是图中两条曲线没有重合的部分，BP 神经网络的负荷预测结果和真实负荷值差别较大，通过分析得出，传统的 BP 神经网络有待优化。

为了能更直观地分析 BP 神经网络的预测效果，表 3-2 列出了 BP 神经网络的负荷预测值。

表 3-2 BP 神经网络预测结果

Table 3-2 prediction results of BP neural network

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	982.14	838.10	14.66%	13	1167.50	1088.741	12.31%
2	844.24	722.21	14.45%	14	1140.72	1060.576	12.36%
3	780.58	676.88	13.28%	15	1207.31	1135.265	10.49%
4	735.49	633.62	13.85%	16	1202.97	1140.619	10.75%
5	718.01	631.65	12.03%	17	1223.27	1177.362	8.31%

(续表 3-2)

6	721.60	631.44	12.49%	18	1246.74	1238.751	6.08%
7	782.59	673.16	13.98%	19	1323.62	1300.859	7.49%
8	923.91	778.56	15.73%	20	1309.59	1298.158	5.11%
9	1110.57	957.28	13.80%	21	1261.43	1257.195	4.95%
10	1253.99	1097.87	12.45%	22	1234.96	1228.337	5.04%
11	1313.37	1158.28	11.80%	23	1179.02	1132.269	7.40%
12	1345.32	838.10	11.65%	24	1055.30	980.071	11.03%

电力行业对负荷预测的精度有一定的要求，要求短期负荷预测的相对误差小于 3%。由表 3-2 可知，BP 神经网络模型的最大相对误差为 15.73%，相对误差的平均值为 10.90%，最小相对误差为 4.97%；只有 7 个输出节点的相对误差没有超过 10%，并且各节点的相对误差数值相差较大，说明传统的 BP 神经网络预测的波动性较大。

由于 BP 神经网络按照梯度下降的方式调整自身参数，调整到某一梯度向量为零的时候 BP 神经网络很可能就停止训练，这样 BP 神经网络的误差函数就会陷入局部最小值、而不是全局最小值，从而导致网络没有较好的训练效果。考虑到 BP 神经网络初始参数的选择尤为重要，初始参数选择的不同，有可能使 BP 神经网络收敛于不同的局部最小值。针对 BP 神经网络这一缺点，本文将利用优化算法对其进行改进。

### 3.3 智能群算法

#### 3.3.1 智能群算法研究背景

智能群算法从本质来说是基于生物行为所研究出的算法。智能群算法模仿了生物群体之间相互传递信息、合作寻找食物等行为，体现了生物种群之间不断进化、不断优化特点。目前，国内外学者提出大量的智能群算法，如蚁群算法、粒子群算法、免疫算法、遗传算法等。

近 20 年来，科学家们根据观察动物的群体行为创造了许多方法、技术和工具。自然界中动物生存有着群体行为，例如：鸟儿和鱼儿总是成群地游、大雁的飞行有领头雁、蚂蚁靠着触角传递信号等，通过观察各种动物群体之间的交流、群体间的合作方式以及生存方式等进化过程提出了各种群智能算法。

20 世纪 70 年代，Holland 团队从遗传学的思想中得到了启发并结合自然界中适者生存优胜劣汰的机制提出了遗传算法 (Genetic Algorithms, 简称 GA)。1991 年，Dorigo 等通过观察蚂蚁成群寻找食物的过程提出了蚁群优化算法 (ant colony optimization, 简称 ACO)<sup>[43]</sup>。蚂蚁在寻找食物行进的过程中会保留所需要记录的路径等信息，并把保留的信息和其他蚂蚁分享，蚁群会自发向信息信号高的地方移动。但是

蚁群算法收敛速度较慢,容易陷入局部最优。1995年,美国学者 Kennedy、Eberhart 通过研究自然界中鸟类飞行、鸟和鸟之间互相交流信息并根据得到的信息进行飞行方向改变的群体性现象提出了粒子群优化算法(particle swarm optimization, 简称 PSO)<sup>[44]</sup>,在解决大部分的优化问题中,PSO 算法优化速度较快、寻优比较精准,所以是应用较为广泛的。但是和其他智能群算法一样,PSO 算法仍具有容易陷入局部最优的缺点。2003年,李晓磊博士通过对鱼儿在保证自身安全和躲避外界危害,在游动的过程中会自然聚集成群的行为进行研究,首次提出了人工鱼群算法<sup>[45]</sup>(Artificial Fish Swarm Algorithm, 简称 AFSA)。

鸽子可以感知地磁场的磁感应,并且具有一定的记忆环境能力。基于鸽子这种特征,国内外学者开始对鸽群优化模型进行研究。在研究鸽子如何进行自主归巢的过程中受到启发,2014年段海滨等首次提出了一种基于鸽子归巢行为的新型群体智能优化算法——鸽群优化(pigeon inspired optimization, PIO)算法<sup>[46]</sup>。Whiten 提出太阳对鸽子的导航能力有一定的影响,所以太阳也是鸽子的导航工具。2017年 Bolaji 等提出二进制编码的鸽群算法,解决多维背包求解问题<sup>[47]</sup>,同年段海滨等为全球卫星集中检测精度不高的问题,提出了集中检测方案的改进鸽群算法<sup>[48]</sup>。

在我国国内,段海滨教授对鸽群算法的研究有很大的突破<sup>[49]</sup>,目前。鸽群算法已经应用在求解高维复杂函数<sup>[50]</sup>、图像分割<sup>[51]</sup>、机器人路径规划<sup>[52]</sup>、控制参数优化等领域并解决了实际工程中复杂优化的问题。

通过对智能群算法的学习,比较各种群智能算法的优缺点,本文选用计算简单、优化速度快的粒子群算法和鸽群算法对 BP 神经网络进行优化。

### 3.3.2 粒子群算法

粒子群算法(Particle Swarm Optimization, PSO)模拟的是鸟群觅食的过程。一个多维空间内,鸟群共同寻找一块食物。没有一只鸟知道食物的具体位置,但是鸟群可以得知自己距离食物的位置,鸟群找到目前距离食物最近的鸟,并搜寻当前距食物最近的鸟的周围<sup>[53]</sup>。这样,所有的鸟都会聚集在食物周围。

PSO 算法中,将所有的鸟比作“粒子”,所有的粒子都只有速度和位置两个属性。其中,位置代表移动的方向,速度代表移动的快慢。每一次迭代过程中,粒子根据群体中所有粒子的最优位置以及自身找到的最优位置来更新自己的参数。粒子当前的位置和速度叠加就是粒子下一次飞行的位置。

粒子群算法的数学模型描述如下: $N$  是此群中粒子的总数, $v_i$  是粒子的速度; $rand()$  是介于(0, 1)之间的随机数; $x_i$  是粒子的当前位置; $c_1$  和  $c_2$  是学习因子,通常  $c_1=c_2=2$ 。

则有如下关系式:

$$v_{id}^{k+1} = wv_{id}^k + c_1 \times \text{rand}(0,1) \times (pbest - x_{id}^k) + c_2 \times \text{rand}(0,1) \times (gbest - x_{id}^k) \quad (3.22)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^k \quad (3.23)$$

$x_{id}^k$  和  $v_{id}^k$  分别是分别表示第  $i$  个粒子的位置和速度，其中  $k$  表示当前迭代次数； $d$  表示维度； $w$  被称为惯性因子，且  $w$  为非负数； $c_1$  和  $c_2$  为学习因子，用来调节学习的步长， $c_1$  表示每个粒子的个体学习能力， $c_2$  表示粒子的社会学习能力； $pbest$  表示个体最优解； $gbest$  表示全局最优解。

粒子群算法的程序框图如下：

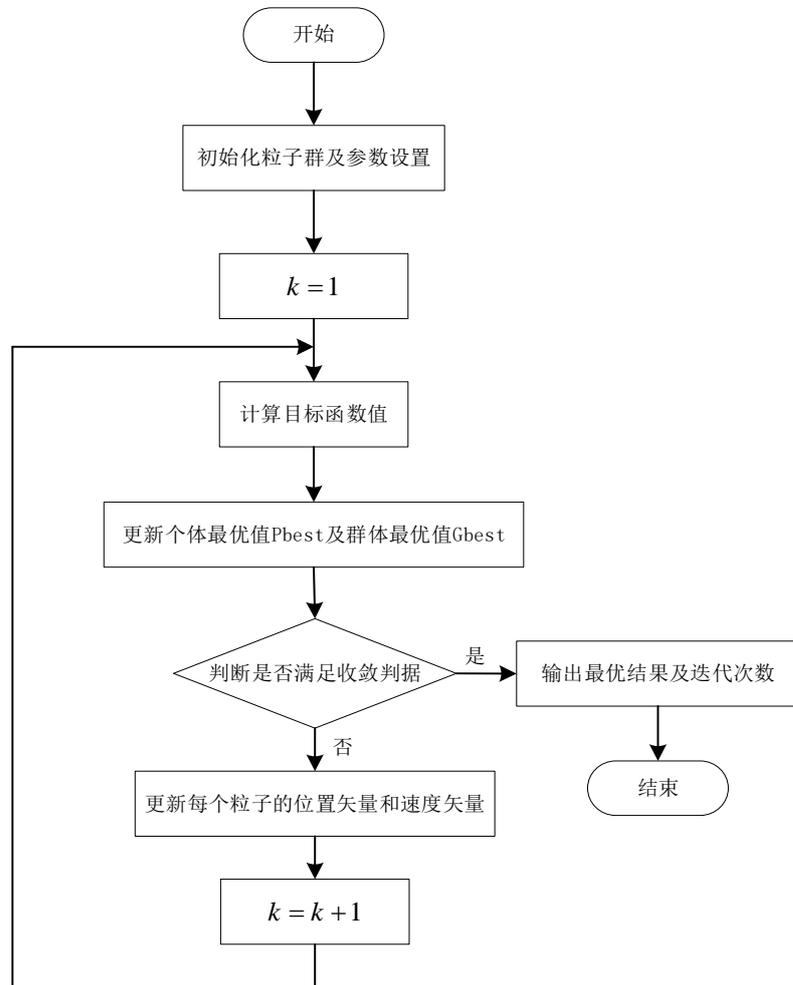


图 3-3 粒子群算法程序框图

Fig. 3-3 program block diagram of particle swarm optimization algorithm

### 3.3.3 鸽群算法

鸽子具有其他家禽类没有的生活习性。鸽子的作息比较规律，一般在白天活跃，

白天进行饮食饮水飞行等活动，夜晚休息。但是经过训练的鸽子，如果在白天没有完成飞行任务或者没有到达栖息地，夜晚会继续飞行。鸽子对自己的栖息地比较依赖，即使把鸽子放到千里以外的地方，鸽子也会努力飞回到“家”，而且是竭尽全力地飞，不到万不得已，鸽子不会更换栖息地。甚至飞行过程中，不会在陌生的地方休息或逗留。

鸽子的记忆力很强，对生存的条件环境、所食的饲料以及特定的呼叫信号均能产生一定的习惯。鸽子可以很快与经常照顾它的人熟悉亲近。记忆力强这一特性，也帮助了鸽子飞行顺利归巢<sup>[54]</sup>。

鸽子依靠什么做到远距离精准归巢，引起了国内外学者的兴趣。目前的研究成果看鸽子首先通过地磁场判断大概方位，再根据地形熟悉的建筑物判断方向，最终到达目的地<sup>[55]</sup>。

#### (1) 地磁对鸽群归巢的影响

经国外学者研究得出，磁场对于鸽子飞行的影响贯穿整个飞行的过程。

现代学者通过大量动物学实验发现，动物群行动受磁场影响的原因并不是类似动物身体里装个指南针这样简单，因为鸟类的磁感应并不是对准南北极方向，而是检测地平线和磁感应角度的罗盘形式。鸟类可以感测到自身所在位置的磁感应强度，以地磁场自西向东逐渐增强的东半球为例，在飞行过程中，鸽子感受到某地的磁感应强度大于“栖息地”，就会“认识”到自己处在栖息地以东的位置，在接下来的飞行中，鸽子会向西飞行以调整方向<sup>[56]</sup>。根据大量生物学研究报告标明，鸟类的身体上存在一个磁感应系统，德国学者 Wiltschko 证明了这些结构在鸽子航行中发挥了重要的作用<sup>[57]</sup>。

#### (2) 太阳对鸽群归巢的影响

威廉·基顿 (William·Keeton) 利用信鸽研究了数十年的鸟类迁徙问题。曾在实验中让鸽子带磁铁飞行，实验结果发现，阴天天气下，即使是对目的地比较熟悉的鸽子也会迷失方向，但是晴天却不会。所以鸽子的飞行不光受到磁场的影响。Whiten 通过实验证明鸽子能够区分基地和释放点太阳之间的高度差异<sup>[58]</sup>，德国学者 Wiltschko 等通过实验总结出鸽子在归巢的前期过程中，是将太阳的高度和磁感应信息结合来判断方向的<sup>[59]</sup>，所以太阳也是鸽子的一种导航工具。

#### (3) 地形对鸽群归巢的影响

一般来说，不认为视觉是动物群寻找目的地的导航工具，但是经过研究发现，和鸽子栖息地相似的地形会影响鸽子的判断，导致鸽子偏航。如果在放飞鸽子之前，给鸽子一定的时间熟悉地形，则会加快鸽子到达目的地的过程。所以地形对鸽群归巢有一定的影响。

### 3.4 鸽群算子模型

在鸽群算子模型中，用虚拟鸽子模拟鸽子归巢的过程。分别给鸽子的位置和速度

赋予一个初始值，每只鸽子代表了一个  $D$  维空间的解，通过不断地迭代过程更新速度和位置，最终获得最优解。

(1) 地图和指南针算子：

$$X_i = [x_{i1}, x_{i2}, \dots, x_{iD}] \quad (3.24)$$

$$V_i = [v_{i1}, v_{i2}, \dots, v_{iD}] \quad (3.25)$$

式中  $i=1, 2, \dots, N$ ； $x_i$  为鸽子的位置； $v_i$  为各自的速度。

每只鸽子的位置和速度依据式 (3.26)、(3.27) 进行更新，如下：

$$V_i^{Nc} = V_i^{Nc-1} e^{-R \times Nc} + \text{rand}(X_{gbest} - X_i^{Nc-1}) \quad (3.26)$$

$$X_i^{Nc} = X_i^{Nc-1} + V_i^{Nc} \quad (3.27)$$

式中： $Nc$  是目前迭代次数； $R$  是地图和指南针因数； $\text{rand}$  是随机数，取值范围在 0~1； $X_{gbest}$  是在  $Nc-1$  次迭代后，所有鸽子的最优位置。

当循环次数达到设定的地磁导航次数以后，鸽子进入地标导航阶段。

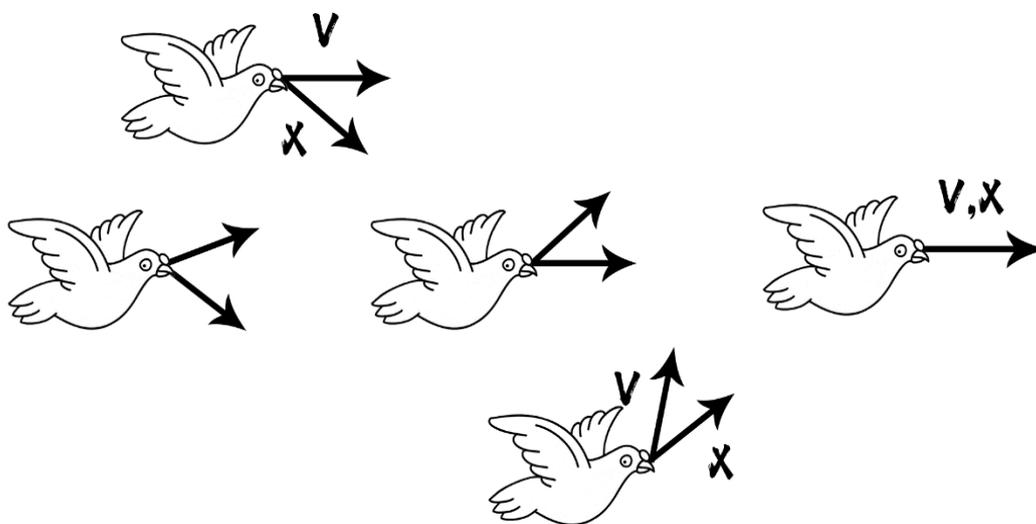


图 3-4 地图和指南针算子模型

Fig. 3-4 map operator model

(2) 地标算子

在归巢的后期阶段，鸽子会依赖于附近的地标判断飞行方向。如果鸽子对鸽群所在地地标并不熟悉，则会跟随熟悉地形的鸽子进行飞行；当鸽子找到熟悉的建筑物等标志性地标时，鸽子会根据自身的经验飞行。

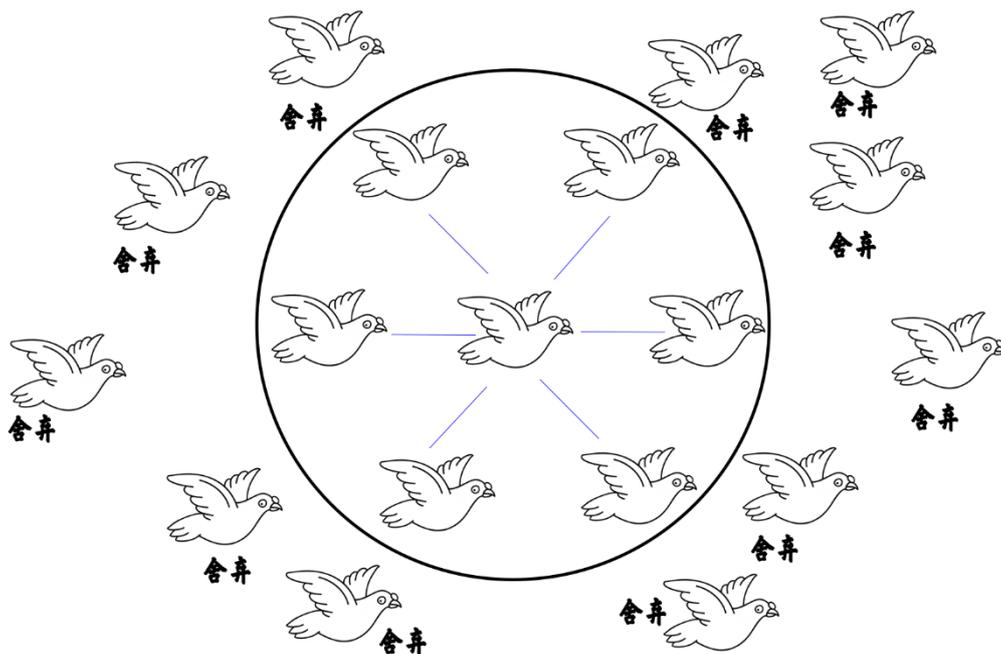


图 3-5 地标算子模型

Fig. 3-5 map operator model

$X_{center}^{Nc-1}$  为第  $Nc-1$  代所有各自的中心位置， $F(X_i^{Nc-1})$  为适应度函数，假如每一只鸽子都可以到达目的地，将有如下公式：

$$X_{center}^{Nc-1} = \frac{\sum_{i=1}^{N^{Nc-1}} X_i^{Nc-1} F(X_i^{Nc-1})}{N^{Nc-1} \sum_{i=1}^{N^{Nc-1}} F(X_i^{Nc-1})} \quad (3.28)$$

在地标模型中， $N^{Nc}$  代表每一次迭代后鸽群的数量，由于不熟悉地形的鸽子无法分辨方向，没有寻找鸽巢的能力，如式 (3.29) 所示，在地标模型中，每一次迭代淘汰一半鸽子的数量。

$$N^{Nc} = \frac{N^{Nc-1}}{2} \quad (3.29)$$

式中， $N^{Nc}$  代表每一次迭代后鸽群的数量

$$X_i = X_i^{Nc-1} + rand(X_{center}^{Nc-1} - X_i^{Nc-1}) \quad (3.30)$$

式中， $X_i$  为鸽子更新后的位置，当迭代循环到达最大迭代次数后，地表算子也停止工作。

### 3.5 PIO-BP 神经网络模型

#### 3.5.1 PIO-BP 神经网络模型分析

PIO 算法中每只鸽子代表  $D$  维空间的一个解，解的优劣性根据适应度函数决定。

其中鸽群的适应度函数  $F(X_i^{Nc-1})$  对应为：

$$F(X_i^{Nc-1}) = \begin{cases} \frac{1}{fitness(X_i^{Nc-1}) + \varepsilon}, \dots \text{针对最大化问题} \\ fitness(X_i^{Nc-1}), \dots \text{针对最小化问题} \end{cases} \quad (3.31)$$

不同的优化目标对应不同的适应度函数。本文利用 PIO 优化 BP 神经网络，可选取 BP 神经网络的预测误差为鸽群的适应度，鸽群寻找鸽巢的过程就是寻找 BP 神经网络的预测误差最小点的过程，此时最优鸽子的位置就是 BP 神经网络的初始参数。

#### 3.5.2 PIO-BP 神经网络模型流程

PIO 算法优化 BP 神经网络具体工作流程框图结果如图 3-6 所示：

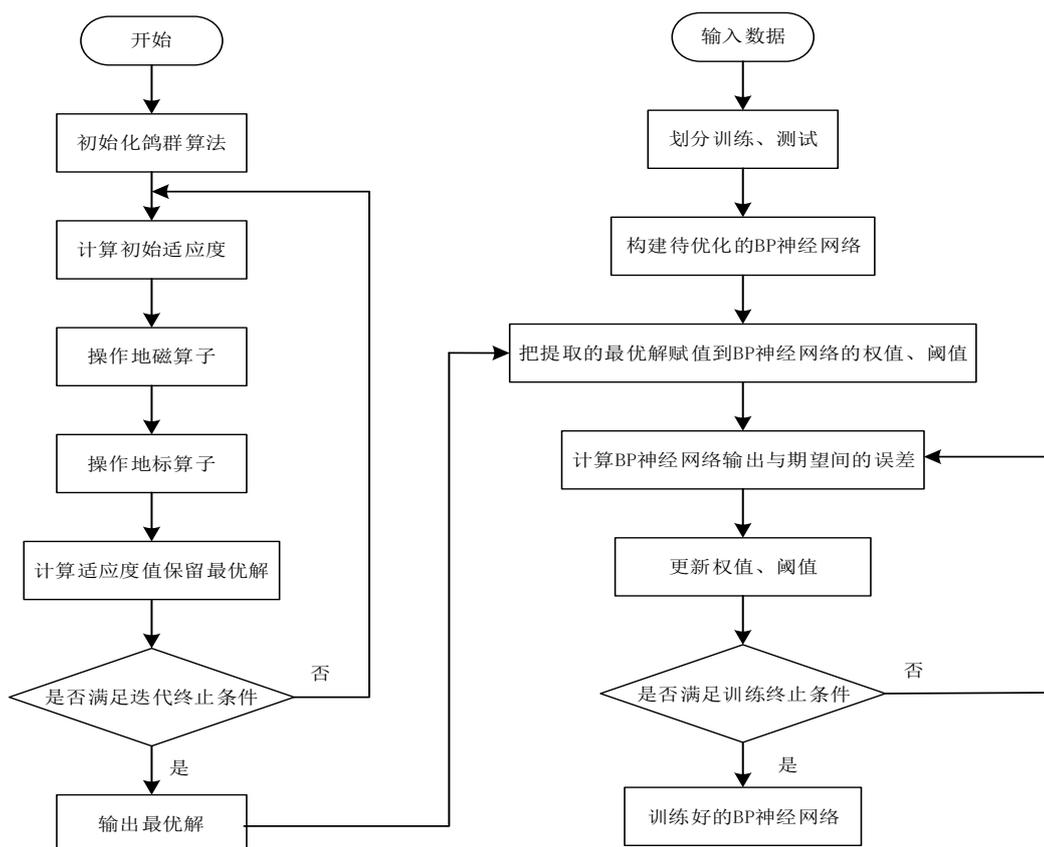


图 3-6 PIO-BP 流程图

Fig. 3-6 PIO-BP flow chart

利用鸽群算法优化 BP 神经网络步骤如图 3-6 所示：

- (1) 随机初始化鸽群，设置种群大小、变量维度、地磁导航次数和地标导航次数；
- (2) 通过计算所有种群的适应度数值，选择初始适应度值最优的鸽子进行记录；
- (3) 依次进入地磁导航、地标导航模式，更新鸽群位置，计算适应度值，保留最优解；
- (4) 判断 PIO 算法是否满足迭代终止条件，如果满足则停止迭代，将最优解赋值给 BP 神经网络的初始权值和阈值；
- (5) 对 BP 神经网络进行训练，计算 BP 神经网络输出和期望输出间的误差，更新权值和阈值；
- (6) 判断是否满足 BP 神经网络训练终止条件，如果满足输出预测结果。

### 3.6 智能群算法优化 BP 短期负荷预测

本节用 PSO 算法和 PIO 算法分别对 BP 神经网络进行优化，利用优化后的神经网络模型对抚顺市 2021 年 12 月 31 日 24 小时的负荷值进行预测，并通过对比 PSO-BP 和 PIO-BP 模型的预测精度，验证 PIO-BP 神经网络的预测效果。

#### 3.6.1 基于 PSO-BP 短期负荷预测

建立 PSO-BP 神经网络模型进行短期负荷预测。其中粒子种群规模设置为 40； $c_1$  学习因子设置为 2.8； $c_2$  学习因子设置为 1.3；最大迭代次数为 100。通过 Matlab 建模仿真，得到抚顺市 12 月 31 日 24 个时间点的预测曲线与真实曲线对比图。

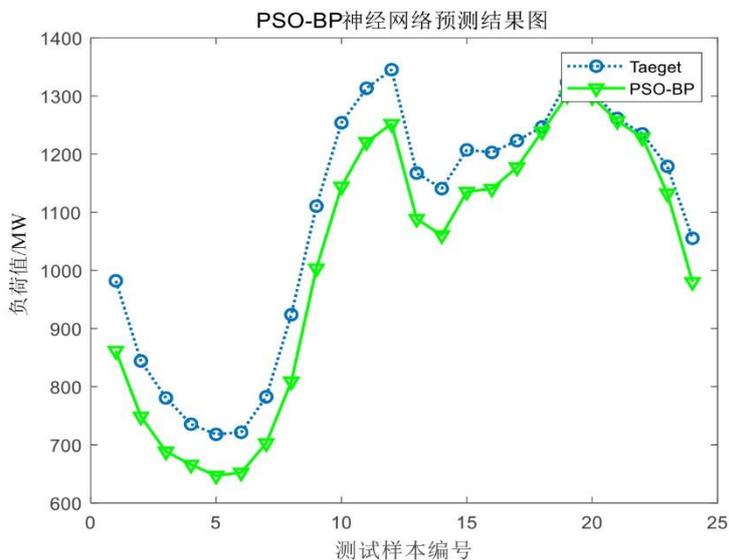


图 3-7 PSO-BP 神经网络预测结果图

Fig. 3-7 PSO-BP neural network prediction results

图 3-7 中，蓝色的线为真实值，绿色的线为 PSO-BP 神经网络输出的预测值。可以明显的看出，两条折线只有少部分重合的部分。PSO-BP 神经网络的负荷预测结果和真

实负荷值仍有一定差别。

为了能更直观地分析 PSO-BP 神经网络的预测效果，表 3-3 列出了 PSO-BP 神经网络的负荷预测值。

表 3-3 PSO-BP 神经网络的负荷预测值  
3-3 BP neural network prediction results

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	982.14	861.73	12.26%	13	1167.50	1088.74	6.74%
2	844.24	748.73	11.31%	14	1140.72	1060.57	7.03%
3	780.58	688.44	11.80%	15	1207.31	1135.26	5.97%
4	735.49	665.94	9.45%	16	1202.97	1140.62	5.18%
5	718.01	646.88	9.91%	17	1223.27	1177.36	3.75%
6	721.60	652.38	9.59%	18	1246.74	1238.75	0.06%
7	782.59	702.81	10.19%	19	1323.62	1300.86	1.72%
8	923.91	808.99	12.43%	20	1309.59	1298.16	0.87%
9	1110.57	1003.52	9.64%	21	1261.43	1257.19	0.34%
10	1253.99	1144.35	8.74%	22	1234.96	1228.34	0.54%
11	1313.37	1220.90	7.04%	23	1179.02	1132.27	3.96%
12	1345.32	1252.05	6.93%	24	1055.30	980.07	7.13%

由表 3-3 可知，PSO-BP 神经网络模型的最大相对误差为 12.44%，相对误差的平均值为 6.80%，最小相对误差为 0.34%；预测相对误差超过 10% 的输出节点有 5 个、小于 1% 的输出节点有 4 个；各输出节点的相对误差数值相差仍较大，说明 PSO-BP 神经网络模型的稳定性较低。

对比 PSO-BP 神经网络和 BP 神经网络预测效果，平均相对误差提高了 4%。通过 PSO 优化 BP 神经网络，可以有效地提高 BP 神经网络的预测精度。

### 3.6.2 基于 PIO-BP 短期负荷预测

建立 PIO-BP 神经网络模型进行短期负荷预测。其中鸽子种群规模设置为 10；地磁导航次数设置为 35；地标导航次数设置为 15；大迭代次数为 500；地磁因数为 0.3。通过 Matlab 建模与分析，得到抚顺市 12 月 31 日 24 个时间点的预测曲线与真实曲线对比图。

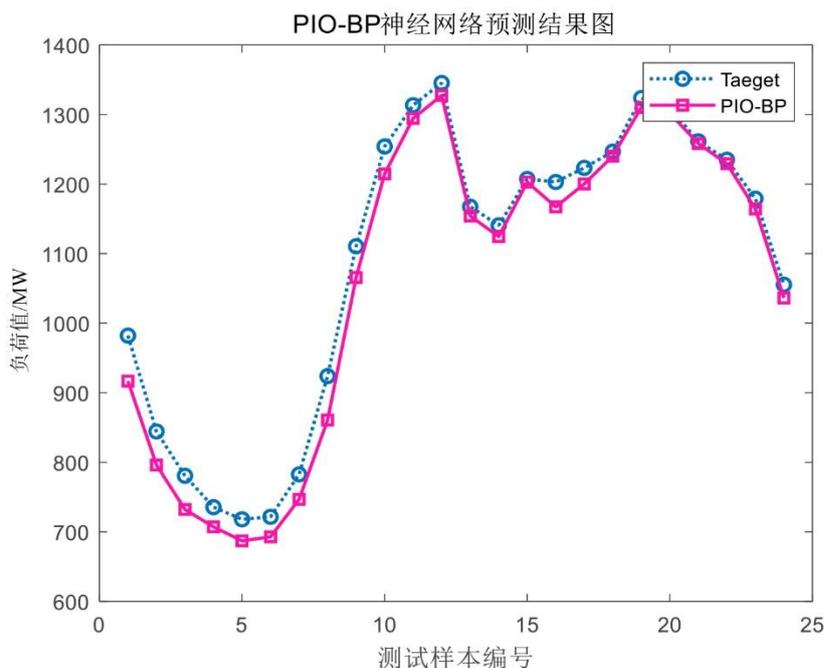


图 3-8 PIO-BP 神经网络预测结果图

Fig. 3-8 PIO-BP neural network prediction results

图 3-8 中，蓝色的线为真实值，粉色的线为 PIO-BP 神经网络输出的预测值。可以明显的看出，两条曲线比较贴近，在中午 11 点-14 点、夜晚 18 点-22 点，曲线的拟合程度较高；凌晨 0 点-早 7 点间曲线的拟合程度较低。说明 PIO 优化后的 BP 神经网络预测效果有了明显的提升，但稳定性仍有待加强。

为了能更直观地分析 PIO-BP 神经网络的预测效果，表 3-4 列出了 PIO-BP 神经网络的负荷预测值，以及预测值和真实值之间的相对误差。

表 3-4 PIO-BP 神经网络预测结果

Table 3-4 Prediction results of PIO-BP neural network

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	982.14	916.74	6.66%	13	1167.50	1154.12	1.14%
2	844.24	796.01	5.71%	14	1140.72	1124.46	1.42%
3	780.58	732.15	6.2%	15	1207.31	1202.87	0.03%
4	735.49	707.13	3.85%	16	1202.97	1167.21	2.97%
5	718.01	687.08	4.31%	17	1223.27	1200.23	1.88%
6	721.60	692.78	3.99%	18	1246.74	1240.23	0.05%
7	782.59	746.63	4.59%	19	1323.62	1310.24	1.01%
8	923.91	860.74	6.83%	20	1309.59	1301.67	0.06%
9	1110.57	1065.72	4.04%	21	1261.43	1258.24	0.25%
10	1253.99	1214.57	3.14%	22	1234.96	1229.24	0.04%
11	1313.37	1294.45	1.44%	23	1179.02	1164.21	1.26%
12	1345.32	1327.38	1.33%	24	1055.30	1036.23	1.81%

由表 3-4 可知, PIO-BP 神经网络模型的最大相对误差为 6.83%, 相对误差的平均值为 2.74%, 最小相对误差为 0.25%; 预测相对误差没有超过 10% 的输出节点, 小于 1% 的输出节点有 5 个; 各输出节点的相对误差数值相差较小; 对比 PIO-BP 神经网络和 BP 神经网络预测效果, 平均相对误差提高了 8%。说明 PIO-BP 神经网络模型的稳定性较好。

### 3.6.3 PSO-BP 与 PIO-BP 的对比

为了更清晰地观察 BP 神经网络、PSO-BP 神经网络、PIO-BP 神经网络三种模型进行短期负荷预测时的精度与效果, 下面将三种神经网络预测曲线与真实曲线进行对比。

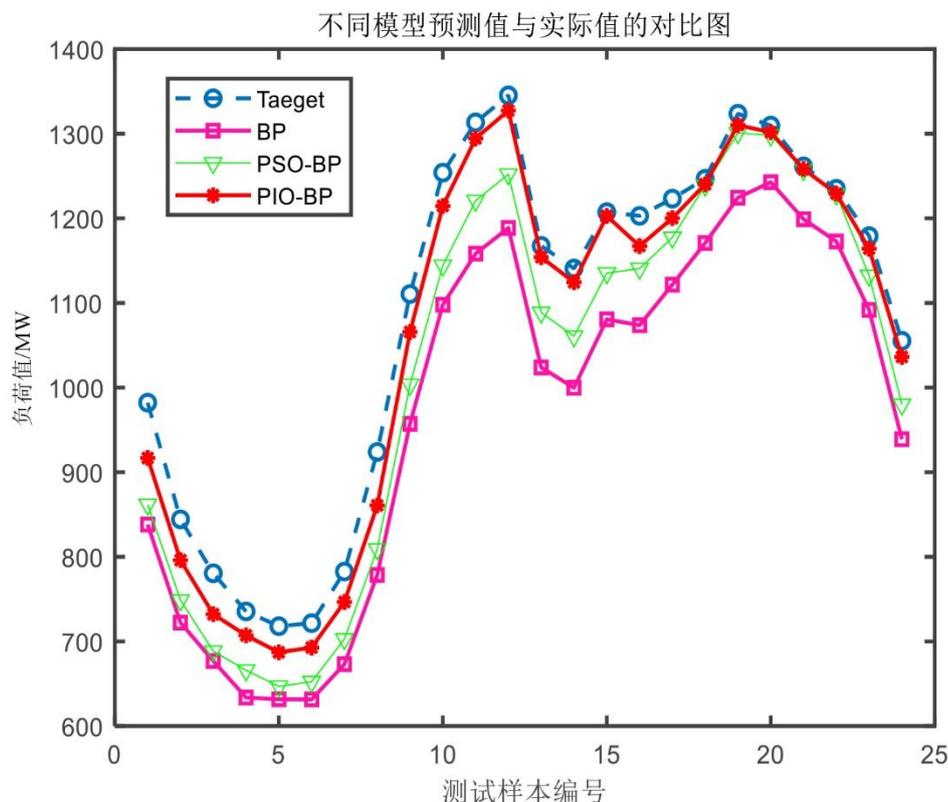


图 3-9 三种模型预测对比图

Fig. 3-9 Comparison of three models

如图 3-9 可知, 三种模型的预测曲线都和实际负荷曲线一样呈现出了相似的趋势, 其中蓝色线代表的实际负荷曲线与红色线代表的 PIO-BP 预测负荷曲线的拟合程度较高; 而且 PIO-BP 模型预测的负荷曲线整体靠近实际负荷曲线, 虽然波谷处的预测效果有待改进, 但整体的拟合程度是三种模型当中最高的。

为了进一步比较几种神经网络模型的预测精度, 表 3-5 给出几种神经网络预测的误差指标。

表 3-5 三种预测模型性能比较

Table 3-5 Performance comparison of three prediction models

	BP	PSO-BP	PIO-BP
MAE (MW)	84.03	57.88	26.41
RMS (MW)	88.07	56.25	31.78
MAPE (%)	10.90%	6.80%	2.74%

由表 3-5 可知，PIO-BP 神经网络模型的误差指标最小，而 BP 神经网络和 PSO-BP 误差较大，效果不理想，说明 PIO-BP 神经网络预测模型有很好的预测效果。综上，利用 PIO 优越的寻优性能，搜寻最优解后对 BP 神经网络初始的权值和阈值进行赋值，可以有效地提高 BP 神经网络的预测精度。

### 3.6.4 PIO-BP 与其它预测模型的对比

为了证明 PIO-BP 模型的预测的精准性，本文不仅建立了 PIO-BP 预测模型，还建立了 LSSVM 模型、ELM 模型以及小波神经网络三种常用的负荷预测模型用做对比分析。运用以上模型分别对抚顺市 2021 年 12 月 31 日 24 小时的负荷值进行预测四种预测模型的预测结果和真实负荷数据曲线对比如图所示。

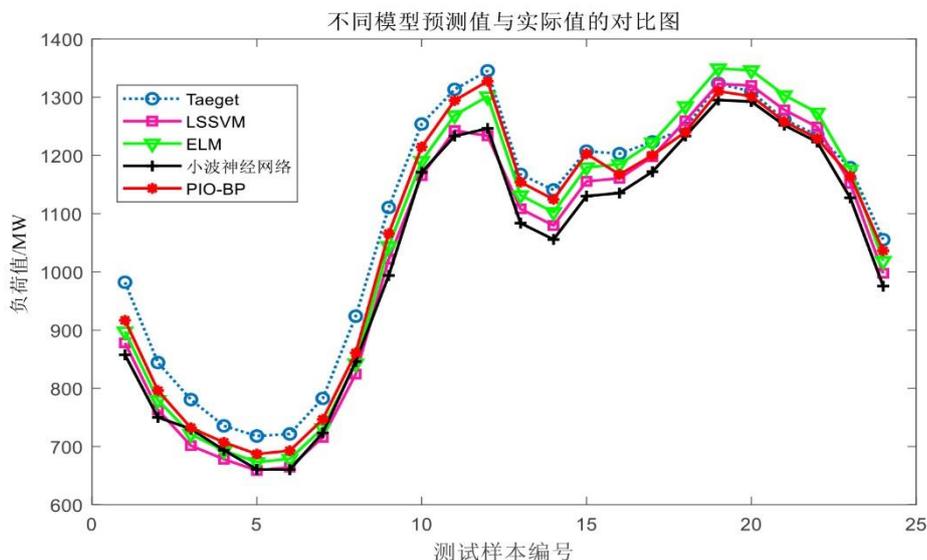


图 3-10 四种模型预测对比图

Fig. 3-10 Comparison of four models

从图 3-10 中可以看出，无论是哪条曲线都和蓝色曲线代表的真实负荷数据曲线有着一定的相似度。其中，粉色代表的 LSSVM 模型和绿色代表的 ELM 模型的拟合度较差，在谷荷处，预测数值低于谷荷、在峰荷处，预测数值高于峰荷。黑色曲线代表的小波神经网络预测曲线始终低于真实负荷曲线，说明小波神经网络模型的的预测数值

始终偏低。红色代表的 PIO-BP 神经网络预测曲线和蓝色代表的真实负荷数据曲线始终拟合度较高，在晚 18 点到 23 点区间和蓝色曲线几乎重合在一起，且红线在蓝线波动的幅度较小，说明了 PIO-BP 模型的稳定度较高。

为了进一步比较几种负荷预测模型的预测精度，表 3-6 给出几种预测模型的误差指标。

表 3-6 四种预测模型性能比较

Table3-6 Performance comparison of four prediction models

	PIO-BP	LSSVM	ELM	WNN
MAE (MW)	26.41	55.9678	42.94	63.43
RMSE (MW)	31.78	64.0455	47.37	70.71
MAPE (%)	2.74%	5.49%	3.13%	7.23%

由表 3-6 可得，PIO-BP 神经网络模型的平均相对误差、平均绝对误差、均方根误差是四种模型中最小的。数值为 2.74%、26.41MW、31.78MW。

综上，PIO-BP 的预测效果相对其他预测模型效果较好，说明 PIO 算法有效地优化了 BP 神经网络。

### 3.7 本章小结

本章首先对传统的 BP 神经网络进行了介绍，并运用 BP 神经网络预测一天中 24 个小时的电力负荷数据，观察预测结果和 BP 神经网络自身的学习算法相结合分析，说明了 BP 神经网络的缺点，由此引出了优化算法。

对鸽群优化算法的原理以及鸽群算法优化 BP 神经网络的流程进行了说明，然后对同一天中 24 个小时的电力负荷数据进行预测。通过对比 PIO-BP 模型和 PSO-BP 模型以及 BP 模型的预测结果，说明 PIO 算法属于群智能算法中比较优越的优化算法。

利用其他几种基础预测算法对同一天 24 小时的负荷数据进行预测，并对比 PIO-BP 模型和 LSSVM 模型、ELM 模型、WNN 模型的预测效果，进一步验证了本章提出的 PIO-BP 神经网络模型有效地提高了负荷预测精确度。



## 4 基于小波分解法的 QPIO-BP 短期电力负荷预测

为了改善鸽群算法寻优后期种群多样性下降、个体趋于统一化，容易陷入局部最优的缺点，本章提出利用量子编码鸽群。融入量子信息理论，扩大了鸽群搜索空间，提升鸽群算法的全局寻优能力。为了进一步提高预测模型的精度，本章提出利用小波变换实现负荷数据的分解与重构来降低负荷数据的复杂度。

### 4.1. 量子信息

量子信息是信息科学和量子力学的交叉学科，量子信息跟可控核聚变、人工智能并列属于有潜力改变世界的战略性科技，是中国处于世界领跑地位的科技领域之一。随着我国对量子操纵能力的进步，量子信息学科兴起。目前量子信息分为量子通信、量子计算、量子精密测量等分支学科，应用在国家各种领域。

量子中的量，可以被理解成可数的；量子中的子，可以是物质层面上不可分割的粒子。如果一个事物存在最小的不可分割的基本单元，我们就说它是“量子化”的，并把最小单元称为量子。量子一般代表了微观粒子，利用微观粒子的状态表示的信息称为量子信息。

量子信息的基本存储单位是量子比特<sup>[60]</sup>，一个量子比特的状态是一个二维复数空间的向量<sup>[61]</sup>。一个量子比特可以由 $|0\rangle$ 和 $|1\rangle$ 的任意叠加态表达，但是在经典信息中，二进制存储单元状态仅有 0 和 1 两种状态。

#### 4.1.1 量子比特

##### (1) 单量子比特

通常采用 0 和 1 二进制数表示经典信息。通常称它们为比特，所有的信息都可以被分解成比特。在量子计算中，采用 $|0\rangle$ 和 $|1\rangle$ 表示微观粒子的两种基本状态，称它们为量子比特，单量子比特的任意状态都可以表示为这两个基本状态的线性组合表示。称“ $|\ \rangle$ ”为狄拉克 (Dirac) 记号。

在经典信息中，二进制存储单元状态仅有 0 和 1 两种状态；但是在量子信息中，一个量子比特可以由 $|0\rangle$ 和 $|1\rangle$ 的任意叠加态表达：

$$|\varphi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (4.1)$$

式中， $\alpha$ 为 $|0\rangle$ 的概率幅； $\beta$ 为 $|1\rangle$ 的概率幅； $\alpha$ 和 $\beta$ 均为复数。

即量子态 $|\varphi\rangle$ 因测量导致 $|\alpha|^2$ 的概率坍缩到 $|0\rangle$ ，或者以 $|\beta|^2$ 的概率坍缩到 $|1\rangle$ ，且满足：

$$|\alpha|^2 + |\beta|^2 = 1 \quad (4.2)$$

量子态 $|\varphi\rangle$ 是二维复向量空间中的单位向量。由公式 (4.2)，可将 $|\varphi\rangle = \alpha|0\rangle + \beta|1\rangle$ 改写成：

$$|\varphi\rangle = \cos\frac{\theta}{2}|0\rangle + e^{i\varphi}\sin\frac{\theta}{2}|1\rangle \quad (4.3)$$

式中， $\cos\frac{\theta}{2}$ 和 $e^{i\varphi}\sin\frac{\theta}{2}$ 是复数； $|\cos\frac{\theta}{2}|^2$ 表示量子位处于 $|0\rangle$ 的概率， $\cos\frac{\theta}{2}$ 为 $|0\rangle$ 的概率幅； $|e^{i\varphi}\sin\frac{\theta}{2}|^2$ 表示量子位处于 $|1\rangle$ 的概率， $e^{i\varphi}\sin\frac{\theta}{2}$ 为 $|1\rangle$ 的概率幅。

则：

$$|\cos\frac{\theta}{2}|^2 + |e^{i\varphi}\sin\frac{\theta}{2}|^2 = 1 \quad (4.4)$$

式 (4.3) 定义了一个球体三维坐标点 $|\varphi\rangle$ ，示意图如图 4-1。

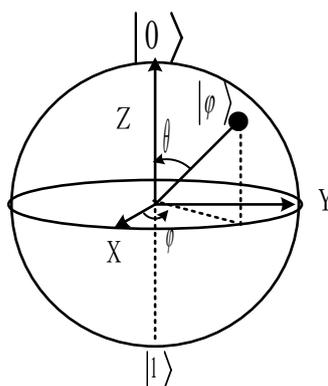


图 4-1 量子比特的 Bloch 球面表示

Figure 4-1 Bloch spherical representation of a qubit

我们把这个球称为 Bloch 球，这个球是量子比特可视化的有效方法。

## (2) 多量子比特

考虑  $n$  量子比特系统，该系统有  $2^n$  个形如  $|x_1x_2\cdots x_n\rangle$  的基本状态，其量子状态由  $2^n$  个概率幅所确定。类似于单量子比特， $n$  量子比特也可以处于  $2^n$  个基本状态的叠加态之中，即：

$$|\varphi\rangle = \sum_{x \in \{0,1\}^n} a_x |x\rangle \quad (4.5)$$

其中  $a_x$  成为基本状态  $|x\rangle$  的概率幅，且满足

$$\sum_{x \in \{0,1\}^n} |a_x|^2 = 1 \quad (4.6)$$

例如, 当  $n=3$  时

$$|\varphi\rangle = a_{000}|000\rangle + a_{001}|001\rangle + a_{010}|010\rangle + a_{011}|011\rangle \\ + a_{100}|100\rangle + a_{101}|101\rangle + a_{110}|110\rangle + a_{111}|111\rangle \quad (4.7)$$

其中概率幅满足

$$|a_{000}|^2 + |a_{001}|^2 + |a_{010}|^2 + |a_{011}|^2 + |a_{100}|^2 + |a_{101}|^2 + |a_{110}|^2 + |a_{111}|^2 = 1 \quad (4.8)$$

#### 4.1.2 量子旋转门

在量子计算中, 为了实现某种逻辑交换, 经常需要通过量子比特进行一系列的酉变换。对量子比特进行处理的逻辑门为量子门<sup>[62]</sup>。其中, 比较重要且经常使用的单比特量子门是量子旋转门<sup>[63]</sup>, 其矩阵表示:

$$|\varphi'\rangle = R|\varphi\rangle = \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix} \begin{bmatrix} \cos\varphi \\ \sin\varphi \end{bmatrix} = \begin{bmatrix} \cos(\varphi+\theta) \\ \sin(\varphi+\theta) \end{bmatrix} \quad (4.9)$$

如公式 (4-9) 所示, 该量子旋转门只改变量子位的相位, 而不改变量子的长度。

## 4.2 基于量子改进鸽群算法流程

由于鸽群在飞行过程中不断交流信息, 导致鸽群的飞行方向越来越一致。在地标导航时期, 每一次迭代都淘汰一半的鸽子, 这限制了鸽子的飞行范围, 也就是限制解的搜索范围空间<sup>[64]</sup>, 所以鸽群算法容易在局部最优解范围搜索。为了改善鸽群算法容易陷入局部最优的缺点, 可以通过扩大鸽子种群数量, 但是这种办法加大了计算量; 也可以通过削弱鸽子跟随领头鸽的行为增加个体多样性, 也就是减少对全局最优解的搜索, 但是这种办法容易降低迭代精度, 甚至得到发散的结果<sup>[65]</sup>。

为解决上述问题, 本文提出一种基于量子改进的鸽群算法 (Quantum Pigeon-Inspired Optimization, QPIO), 利用一种实数编码的量子表达方式编码鸽群, 并利用量子旋转门, 更新量子表达, 提高鸽群算法的优化效率。

### 4.2.1 产生原始鸽群

在 QPIO 算法中, 鸽子所在的当前位置对应优化问题的近似解。设鸽群中有  $m$  只鸽子, 随机分布在  $n$  维单位空间  $\tilde{\Omega} = [-1,1]^n$  中, 每只鸽子携带一组 ( $n$  个) 量子比特, 其概率幅表示鸽子当前位置。

在 QPIO 中, 把量子比特的两个概率幅都视为代表鸽子当前位置的信息。因此, 每只鸽子占据  $\tilde{\Omega}$  中两个位置, 考虑到种群初始化时编码的随机性, 设鸽子  $i$  携带的一组量子比特为:

$$P_i = \left[ \begin{array}{c} \cos(\theta_{i1}) \cos(\theta_{i2}) \cdots \cos(\theta_{in}) \\ \sin(\theta_{i1}) \sin(\theta_{i2}) \cdots \sin(\theta_{in}) \end{array} \right] \quad (4.10)$$

式中： $\theta_{ij} = 2\pi \times rnd$ ； $rnd$  为 (0,1) 之间的随机数； $i = 1, 2, \dots, m$ ； $j = 1, 2, \dots, n$  其中， $m$  是种群规模； $n$  是空间维数。由此可见，种群中每只鸽子占据  $\tilde{\Omega}$  空间中如下两个位置，它们分别对应量子态  $|0\rangle$  和  $|1\rangle$  的概率幅为：

$$\begin{aligned} P_{ic} &= (\cos(\theta_{i1}), \cos(\theta_{i2}), \dots, \cos(\theta_{in})) \\ P_{is} &= (\sin(\theta_{i1}), \sin(\theta_{i2}), \dots, \sin(\theta_{in})) \end{aligned} \quad (4.11)$$

式中： $P_{ic}$  为余弦位置， $P_{is}$  为正弦位置。

通过量子比特编码之后的鸽群在种群规模不变的时候，可使搜索空间加倍，从而加快了搜索范围。在 QPIO 中，鸽子所在的当前位置，对应优化问题的近似解。在当前鸽群占据的所有位置中，将适应度最好的位置定义成最优位置，将占据该位置的鸽子定义成最优鸽子。设鸽群中最优鸽子携带的量子比特上体现其最优位置的概率幅为  $\cos(\theta_1), \cos(\theta_2), \dots, \cos(\theta_n)$ 。

则当某只鸽子携带的量子比特相位旋转到  $\frac{\pi}{2} - \theta_1, \frac{\pi}{2} - \theta_2, \dots, \frac{\pi}{2} - \theta_n$  时，该鸽子携带的量子比特的正弦概率幅，对应最优解。

#### 4.2.2 解空间变换

在 QPIO 中，由于鸽子的遍历空间每维均为  $[-1, 1]$ ，为计算鸽子目前位置的优劣性，需要进行解空间变换，将每个粒子占据的 2 个位置由单位空间  $\tilde{\Omega} = [-1, 1]^n$  映射到优化问题的解空间。量子位的每个概率幅对应解空间的一个优化变量。记鸽子  $P_j$  的第  $i$  个量子位为  $[\alpha_i^j, \beta_i^j]^T$ ，则相应的解空间变量为

$$X_{ic}^j = \frac{1}{2} [b_i(1 + \alpha_i^j) + \alpha_i(1 - \alpha_i^j)] \quad X_{is}^j = \frac{1}{2} [b_i(1 + \beta_i^j) + \alpha_i(1 - \beta_i^j)] \quad (4.12)$$

因此，每个鸽子对应优化问题的两个解：量子态  $|0\rangle$  的概率幅  $\alpha_i^j$  对应  $X_{ic}^j$ ，量子态  $|1\rangle$  的概率幅  $\beta_i^j$  对应于  $X_{is}^j$ ，其中  $i = 1, 2, \dots, m$ ； $j = 1, 2, \dots, n$ 。

#### 4.2.3 鸽子状态的更新

在 QPIO 算法中，鸽子位置的移动由量子旋转门实现。因此，普通的 PIO 中鸽子移动速度的更新转换为量子旋转门转角的更新，鸽子位置的更新转换为每只鸽子量子位概率幅更新。

$$P_{ij} = (\cos(\theta_{ij1}), \cos(\theta_{ij2}), \dots, \cos(\theta_{ijn})) \quad (4.13)$$

整个种群目前搜索到的最优位置为：

$$P_g = (\cos(\theta_{g1}), \cos(\theta_{g2}), \dots, \cos(\theta_{gn})) \quad (4.14)$$

基于以上假设，鸽子状态更新规则可如下描述：

(1) 鸽子 $P_i$ 上量子位幅角增量的更新

$$\Delta\theta_{ij}^{N_c} = \Delta\theta_{ij}^{N_c-1} \times e^{-R \times N_c} + rand(\Delta\theta_g) \quad (4.15)$$

$$\Delta\theta_g = \begin{cases} 2\pi + \theta_{gj} - \theta_{ij} & (\theta_{gj} - \theta_{ij} < -\pi) \\ \theta_{gj} - \theta_{ij} & (-\pi \leq \theta_{gj} - \theta_{ij} \leq \pi) \\ \theta_{gj} - \theta_{ij} - 2\pi & (\theta_{gj} - \theta_{ij} > \pi) \end{cases} \quad (4.16)$$

(2) 基于量子旋转门的量子位概率幅更新

$$\begin{bmatrix} \cos(\theta_{ij}(N_c+1)) \\ \sin(\theta_{ij}(N_c+1)) \end{bmatrix} \begin{bmatrix} \cos(\Delta\theta_{ij}(N_c+1)) & -\sin(\Delta\theta_{ij}(N_c+1)) \\ \sin(\Delta\theta_{ij}(N_c+1)) & \cos(\Delta\theta_{ij}(N_c+1)) \end{bmatrix} \begin{bmatrix} \cos(\theta_{ij}(N_c)) \\ \sin(\theta_{ij}(N_c)) \end{bmatrix} = \begin{bmatrix} \cos(\theta_{ij}(N_c)) + \Delta\theta_{ij}(N_c+1) \\ \sin(\theta_{ij}(N_c)) + \Delta\theta_{ij}(N_c+1) \end{bmatrix} \quad (4.17)$$

式中： $i=1,2,\dots,m$ ； $j=1,2,\dots,n$ 。

鸽子 $P_i$ 更新后的两个新位置分别为：

$$\begin{aligned} \tilde{P}_{ic} &= (\cos(\theta_{i1}) + \Delta\theta_{ij}(N_c+1), \dots, \cos(\theta_{im}(N_c) + \Delta\theta_{im}(N_c+1))) \\ \tilde{P}_{is} &= (\sin(\theta_{i1}(N_c) + \Delta\theta_{i1}(N_c+1)), \dots, \sin(\theta_{im}(N_c) + \Delta\theta_{im}(N_c+1))) \end{aligned} \quad (4.18)$$

由此可见，量子旋转门通过改变描述鸽子位置的量子位相位，实现了两个位置的同时移动。利用量子旋转门完成鸽群速度与位置更新，使个体始终向最优方向翻转。因此 QPIO 算法可以快速的找到最优解。

#### 4.2.4 QPIO 算法过程

QPIO 算法的实现步骤可概括如下：

- (1) 鸽群初始化。根据公式 (4.10) 生成鸽子位置组成的初始种群。
- (2) 根据公式 (4.12) 进行解空间变换，计算每只鸽子的适应度。全局最优位置优于到目前为止搜索到的全局最优位置，则用目前全局最优位置替换。
- (3) 根据公式 (4-15)，(4-18) 实现鸽子状态更新。
- (4) 返回步骤(2)循环计算，直到鸽群完成地磁和地标导航的全部次数或满足收敛条件后停止。

### 4.3 基于 QPIO-BP 的短期负荷预测

建立 QPIO-BP 神经网络模型进行短期负荷预测，通过 Matlab 建模与分析，得到抚顺市 12 月 31 日 24 个时间点的预测曲线与真实负荷曲线对比图 4-2。

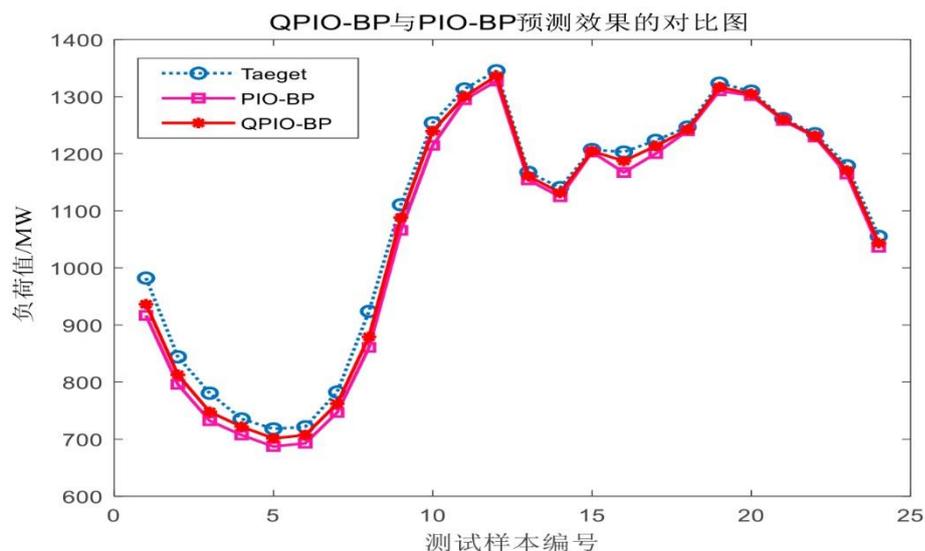


图 4-2 QPIO-BP 与 PIO-BP 预测效果对比图

Fig. 4-2 Comparison of prediction effects between QPIO-BP and PIO-BP

蓝色的线为真实值、粉色的线为 PIO-BP 神经网络输出的预测值、红色的线为 QPIO-BP 预测的输出值。可以明显的看出，QPIO-BP 曲线和真实负荷数据曲线比较贴近，在中午 12 点-14 点、夜晚 19 点-23 点，两条曲线几乎重合。说明 QPIO-BP 预测精度对比 PIO-BP 模型有了进一步提升。

为了能更直观地分析 QPIO-BP 神经网络的预测效果，表 4-1 列出了 QPIO-BP 神经网络的负荷预测值，以及预测值和真实值之间的相对误差。表 4-2 列出了 PIO-BP 和 QPIO-BP 的预测效果对比。

表 4-1 QPIO-BP 神经网络预测结果

Table 4-1 Prediction results of QPIO-BP neural network

时刻	实际负荷	预测负荷	相对误差	时刻	实际负荷	预测负荷	相对误差
h	MW	MW	%	h	MW	MW	%
1	982.14	936.38	4.66%	13	1167.5	1160.89	0.57%
2	844.24	812.90	3.71%	14	1140.72	1131.67	0.79%
3	780.58	747.76	4.20%	15	1207.31	1204.44	0.24%
4	735.49	721.84	1.86%	16	1202.97	1187.23	1.31%
5	718.01	701.45	2.31%	17	1223.27	1213.56	0.79%
6	721.6	707.22	1.99%	18	1246.74	1242.34	0.35%
7	782.59	762.28	2.60%	19	1323.62	1316.72	0.52%
8	923.91	879.21	4.84%	20	1309.59	1304.78	0.37%
9	1110.57	1087.93	2.04%	21	1261.43	1259.87	0.12%
10	1253.99	1239.65	1.14%	22	1234.96	1231.23	0.30%
11	1313.37	1300.35	0.99%	23	1179.02	1170.56	0.72%
12	1345.32	1336.23	0.68%	24	1055.3	1043.47	1.12%

由表 4-1 可知, QPIO-BP 神经网络模型的最大相对误差为 4.84%, 相对误差的平均值为 1.59%, 最小相对误差为 0.12%; 预测相对误差均小于 5%; 对比 QPIO-BP 神经网络和 PIO-BP 神经网络预测效果, 平均相对误差降低了 1.15%。为了进一步比较两种神经网络模型的预测精度, 表 4-2 给出两种神经网络预测的误差指标。

表 4-2 两种预测模型性能比较  
Table 4-2 Performance comparison of two prediction models

	MAE (MW)	RMSE (MW)	MAPE (%)
PIO-BP	26.41	31.78	2.74%
QPIO-BP	15.18	19.36	1.59%

由表 4-2 可知, QPIO-BP 神经网络比 PIO-BP 神经网络 MAE 降低了 11.23MW, RMSE 降低了 12.42MW, MAPE 降低了 1.15%。综上, QPIO-BP 有很好的预测效果, 说明基于量子位概率幅编码 PIO 算法, 破解了 PIO 容易陷入局部最优解的缺点。

#### 4.4 基于 WT-QPIO-BP 电力负荷预测

电力负荷数据具有较强的随机性、波动性和周期性, 时间相关性较高, 具有非线性。为提高预测精度, 在进行电力负荷预测之前可以先用信号分解技术对负荷数据进行分解。目前变分模态分解 (Variational Mode Decomposition, VMD)<sup>[66]</sup>、局部均值分解 (Local Mean Decomposition, LMD)<sup>[67]</sup>、经验模态分解 (Empirical Mode Decomposition, EMD)<sup>[68]</sup>等信号处理技术已经被广泛应用在各个领域。VMD 具有边界效应和突发信号的局限性, 并且适用在较长信号分解的情况; LMD 的端点效应轻, 但是该方法的稳定性和滑动跨度有关, 而滑动跨度需要靠经验来选择, 不易操作; EMD 算法缺点明显, 容易出现过包络、模态混叠以及欠包络的现象。小波分解 (Wavelet Transform, WT) 近年来应用广泛, 它不仅可以检测突变信号, 还具有良好的时频局部性和灵活性。

##### 4.4.1 小波分解原理

在处理时间序列信号时, 可以运用小波分解 (Wavelet Transform, WT) 方法来处理电力负荷数据。小波分解运用 Daubenchies 的小波基替换传统的傅里叶变换的基函数, 能够实现时间序列信号的时域以及频域信息的提取, 增强了信号的特征能力。通过将时间序列信号分解成低频信号与高频信号, 解决了分析非平稳信号困难等问题。

小波分解的数学定义如下: 设任意函数  $g(t), \psi(t)$  是平方可积函数, 满足

$$\int_{-\infty}^{+\infty} |g(t)|^2 dt < \infty \quad (4.19)$$

其傅里叶变换为  $\hat{\psi}(\bar{\omega})$ ，当  $\hat{\psi}(\omega)$  满足允许条件：

$$C_{\psi} = \int_{\mathbb{R}} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty \quad (4.20)$$

此时称  $\psi(t)$  为一个基本小波或母小波。则连续小波变换定义为：

$$W_g(a, b) = \int_{-\infty}^{+\infty} g(t) \psi\left(\frac{t-b}{a}\right) dt \quad a \neq 0 \quad (4.21)$$

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (4.22)$$

其中  $a$  为尺度因子、 $b$  为时移变量。小波变换的重构公式为：

$$g(t) = C_{\psi}^{-1} \int_{-\infty}^{+\infty} W_g(a, b) \psi_{a,b}(t) \frac{dp}{|p|^2} \quad (4.23)$$

使用 Daubechies 作为小波基，它是离散正交小波， $a$  和  $b$  的离散化公式分别取作  $a = a_0^j$  和  $b = ka_0^j b_0$ ，对应的离散小波  $\psi_{j,k}(t)$  可表示为：

$$\psi_{j,k}(t) = a_0^{-\frac{j}{2}} \psi(a_0^{-j} t - kb_0) \quad (4.24)$$

随后使用 Mallat 算法，实现了一种基于四种基本滤波器（分解低通、分解高通、重构低通和重构高通滤波器）的快速分解和重构的 DWT 算法。得到分解后各数据对应的低频信号序列和高频信号序列。可表示为：

$$\begin{cases} A_j = A_{j+1} h_1 \\ D_j = D_{j+1} l_1 \end{cases} \quad j = 0, 1, \dots, n-1 \quad (4.25)$$

$h_1$  和  $l_1$  分别为低通滤波系数和高通滤波系数； $n$  为小波分解层数。Mallat 重构算法为：

$$A_j = A_{j+1} h_2 + D_{j+1} l_2 \quad (4.26)$$

$h_2$  和  $l_2$  分别为  $h_1$  和  $l_1$  的共轭转置矩阵。

#### 4.4.2 基于 WT 的电力负荷数据分解

本文将气象数据序列和电力负荷数据序列分解为一组子序列。其中包含着数据序列的近似子序列  $A_1$  到  $A_n$ ， $D_1$  到  $D_4$  的详细子序列。经过 Matlab 的仿真处理，可以将时间序列信号分解成具有不同时间和不同频率分辨率的低频信号和高频信号。图 4-3 是抚顺市 2021 年 12 月负荷原始数据经过分解后的各频段分量。其中， $A_4$  是原始数据经过小

波分解后的近似子序列， $D_1$ 、 $D_2$ 、 $D_3$ 、 $D_4$  分别为原始数据各层分解的细节子序列。

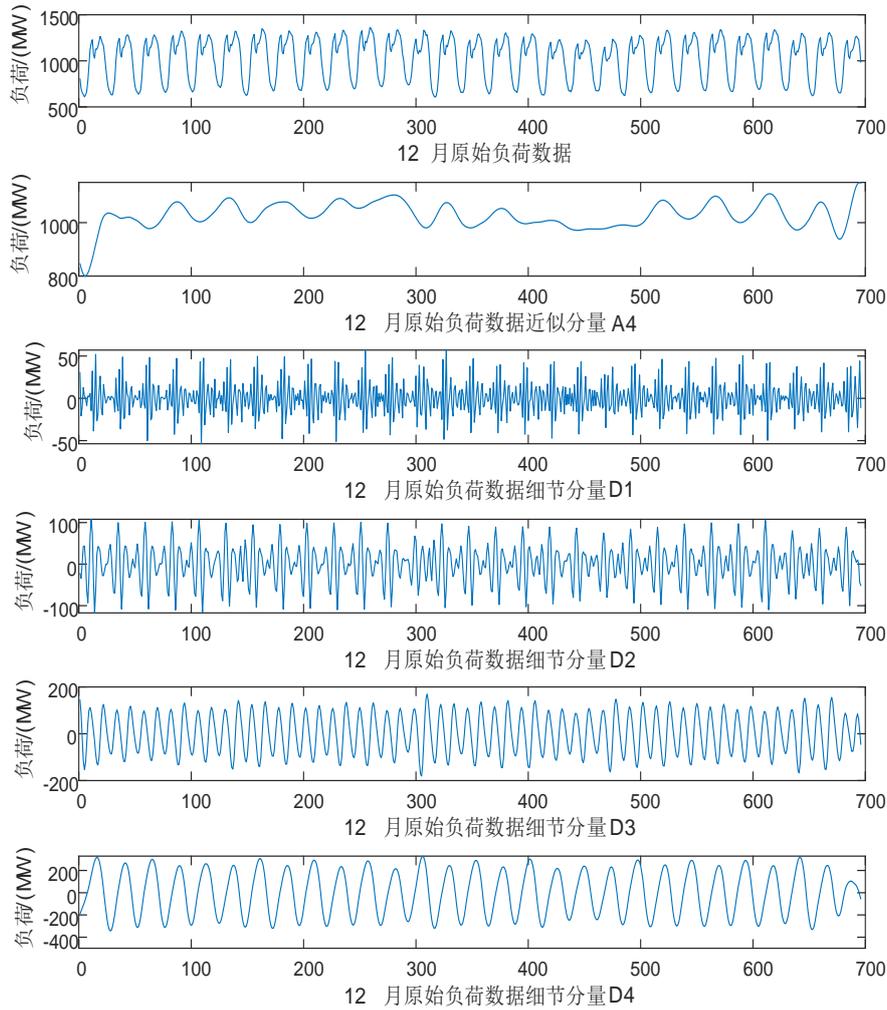


图 4-3 12 月份原始负荷数据各细节分量

Fig. 4-3 Detailed components of raw load data in December

从图 4-3 可以看出，小波分解将原始电力负荷数据分解成 5 个变换幅度大小不一样的子序列。其中近似分量 A4 的平均幅度较大，变换平缓，能反应 12 月份电力负荷数据整体趋势；细节分量 D1 和细节分量 D2 的平均振幅较小，变换急促并且所含噪声分量比较多，有明显的变换规律但周期性短，波动性强，是影响负荷预测的主要因素；细节分量 D3 和细节分量 D4 的周期变换规律较好，能很好的反应 12 月份负荷数据的主要变化趋势。

#### 4.4.3 基于 WT-QPIO-BP 的负荷预测流程

在利用气象数据和实际电力负荷数据对 QPIO-BP 预测模型进行训练时，先对电力负荷数据进行小波分解，将其分解为一个近似分量 A4 和四个细节分量 D1-D4；随后将这五部分内容输入到 QPIO-BP 预测模型中进行预测；最后对这五部分内容对应的预测结果进行小波重构，得到最终的电力负荷预测结果。其具体流程如图 4-4 所示：

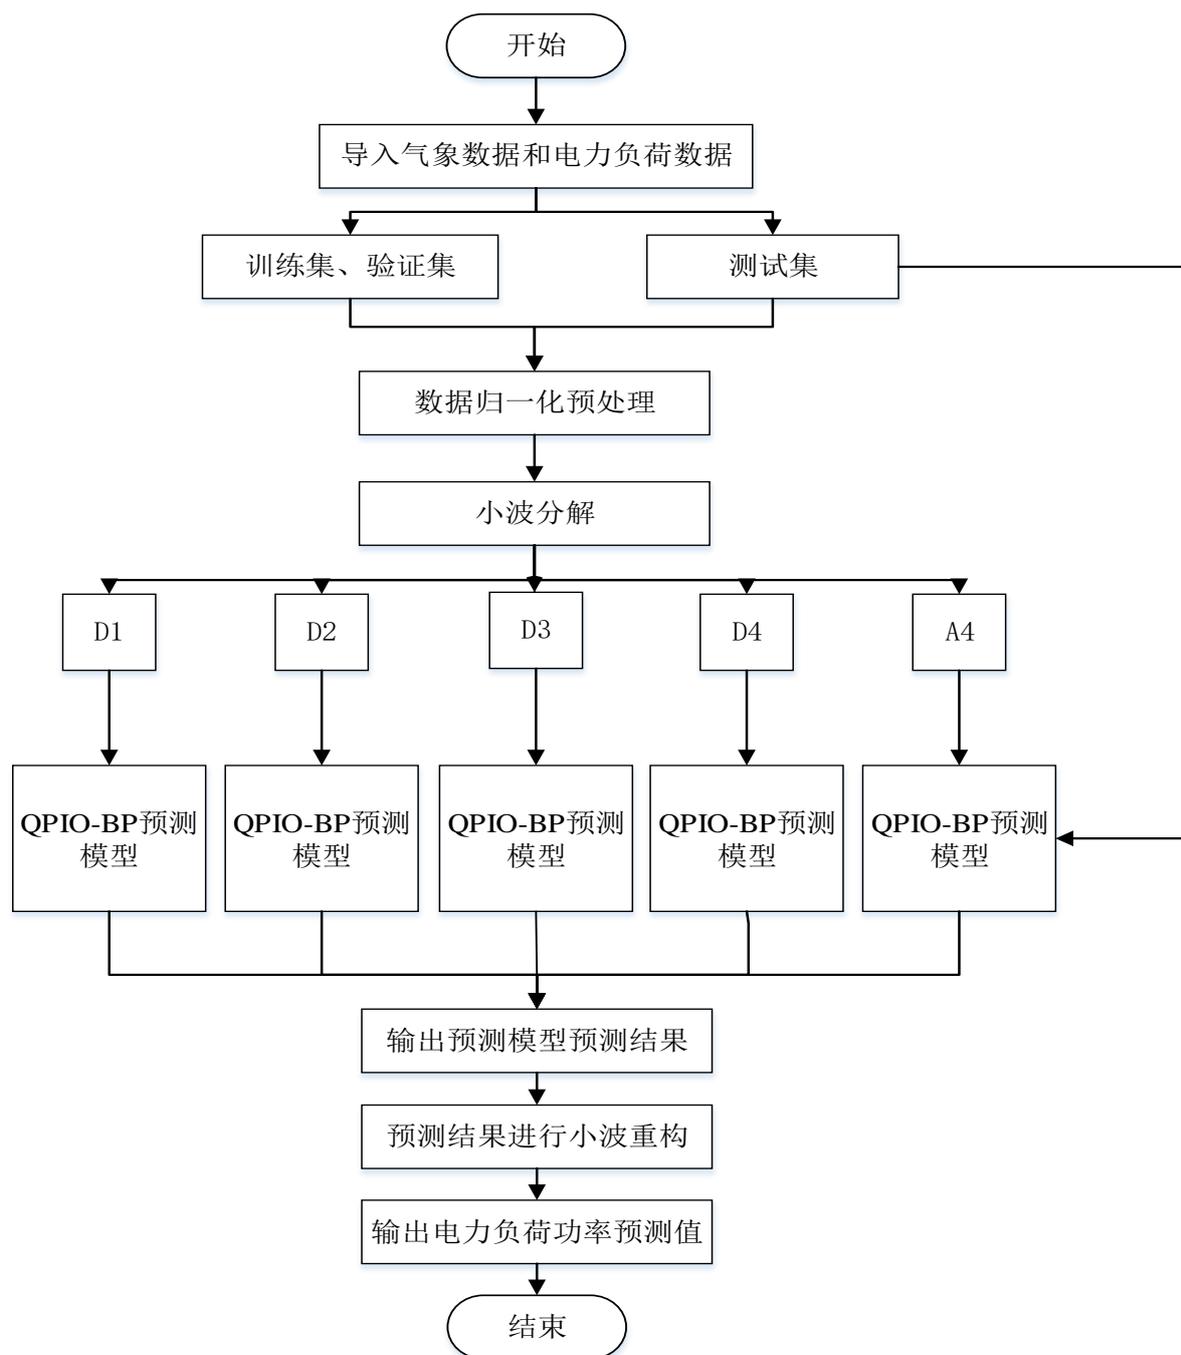


图 4-4 WT-QPIO-BP 的短期负荷预测流程

Fig. 4-4 Short-term load forecasting process of WT-QPIO-BP

#### 4.5 基于 WT-QPIO-BP 的短期负荷预测

本次仿真数据同样来自 2021 年抚顺市电力负荷数据。提取 2021 年 12 月抚顺市电力负荷以及对应的气象数据，气象数据为每日最高温度、最低温度、平均温度、降雨量、相对湿度；负荷数据为每小时进行的一个采样，每天共 24 个采样点。

运用 WT-QPIO-BP 神经网络模型对 2021 年 12 月电力负荷进行预测，同样以 12 月 31 日预测结果为例进行分析，WT-QPIO-BP 预测结果如下图 4-5:

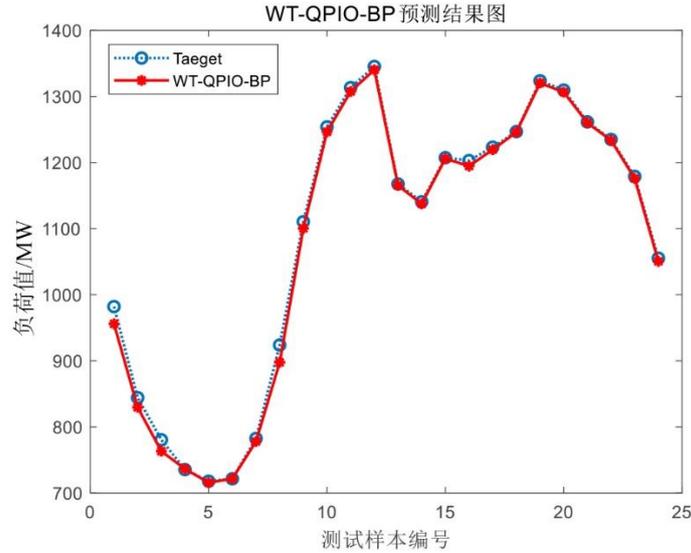


图 4-5 WT-QPIO-BP 预测结果图

Fig. 4-5 Prediction result of WT-QPIO-BP

如图所示，红色的曲线为 WT-QPIO-BP 预测结果，蓝色的曲线为真实负荷数据，两条曲线的拟合度较高，在峰荷和谷荷处的预测数值都明显相近。为进一步分析 WT-QPIO-BP 预测效果，表 4-3 列出了 WT-QPIO-BP 神经网络的负荷预测值，以及预测值和真实值之间的相对误差。

表 4-3 WT-QPIO-BP 神经网络预测结果

Table 4-3 WT-QPIO-BP neural network prediction results

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	982.14	956.02	2.66%	13	1167.50	1165.27	0.19%
2	844.24	829.78	1.71%	14	1140.72	1137.56	0.27%
3	780.58	763.37	2.20%	15	1207.31	1205.94	0.13%
4	735.49	736.55	0.14%	16	1202.97	1194.61	0.69%
5	718.01	715.81	0.3%	17	1223.27	1219.48	0.31%
6	721.60	721.65	0.006%	18	1246.74	1245.87	0.07%
7	782.59	777.94	0.59%	19	1323.62	1320.34	0.24%
8	923.91	897.69	2.84%	20	1309.59	1306.49	0.23%
9	1110.57	1100.34	0.9%	21	1261.43	1260.01	0.11%
10	1253.99	1246.46	0.6%	22	1234.96	1233.57	0.11%
11	1313.37	1307.49	0.44%	23	1179.02	1175.83	0.27%
12	1345.32	1340.23	0.37%	24	1055.30	1050.46	0.46%

由表 4-3 可知，WT-QPIO-BP 神经网络模型的最大相对误差为 2.84%，相对误差的平均值为 0.66%，最小相对误差为 0.01%；预测相对误差普遍小于 1%；说明 WT-QPIO-BP 神经网络模型的精确性和稳定性较好。

为了进一步验证 WT-QPIO-BP 神经网络模型的预测优越性，对比真实负荷曲线和 QPIO-BP 预测负荷曲线以及 WT-QPIO-BP 预测负荷曲线，如图 4-6 所示。

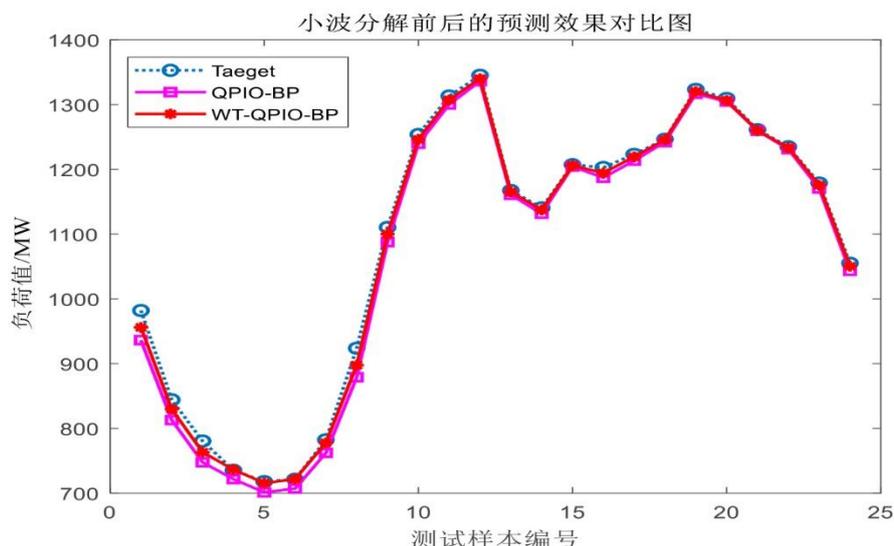


图 4-6 两种模型负荷预测曲线

Fig. 4-6 Load forecast curves of two models

由图 4-6 可以看出，无论是红色的 WT-QPIO-BP 曲线还是粉色的 QPIO-BP 曲线都和蓝色的真实负荷曲线有一定的拟合度。WT-QPIO-BP 曲线在早 5 点-晚 24 点都和真实数据曲线几乎重合；QPIO-BP 的预测曲线与真实负荷曲线的贴合度较差，在谷峰时刻预测效果不好。对比 QPIO-BP 预测模型，WT-QPIO-BP 预测模型在谷荷时刻负荷值的预测有了明显的改善。

为了进一步比较 WT-QPIO-BP 模型和 QPIO-BP 模型的预测精度，表 4-4 给出两种神经网络预测的误差指标。

表 4-4 两种预测模型性能比较

Table 4-4 Performance comparison of two prediction models

两种预测模型性能比较		
	QPIO-BP	WT-QPIO-BP
MAE (MW)	15.18	6.57
RMSE (MW)	19.36	9.75
MAPE (%)	1.59%	0.66%

由表 4-4 可知, WT-QPIO-BP 神经网络对比 QPIO-BP 神经网络 MAE 降低了 8.61MW, RMSE 降低了 9.61MW, MAPE 降低了 0.93%。综上可以说明, 利用 WT 技术对负荷数据进行分解再预测可以提高预测精度。

### 4.6 本章小结

本章首先介绍了量子信息相关知识, 利用量子编码鸽群, 提出一种 QPIO 优化算法; 利用 QPIO 优化算法优化 BP 神经网络, 将基于 QPIO-BP 神经网络进行短期负荷预测后与 PIO-BP 神经网络预测结果进行对比。为进一步提高模型精度, 本文引入了 WT 技术对电力负荷原始数据进行分解, 然后对 WT-QPIO-BP 模型负荷预测流程进行阐述, 并通过仿真与 QPIO-BP 预测效果进行对比, 结果证明了 WT-QPIO-BP 预测精度最好。



## 5 结论与展望

### 5.1 结论

短期负荷预测作为调度中心制定发电计划的依据，对电力系统的运行、控制和计划都有着非常重要的影响。本文以 2021 年抚顺市负荷数据为例进行短期负荷预测。利用 QPIO 算法优化传统 BP 神经网络模型后与小波分解技术 (WT) 相结合，提出了一种基于 WT-QPIO-BP 的短期电力负荷预测模型。并通过 Matlab 仿真对比，验证了该模型精准的预测效果，本文的主要工作如下：

(1) 介绍了短期负荷预测的相关内容，包括电力负荷的构成与分类、电力负荷的特点、电力负荷预测产生误差的原因以及误差指标、电力负荷预测的步骤。

(2) 介绍了抚顺市基本情况，概括介绍了抚顺市地理位置以及主要产业；详细介绍了抚顺市电网现状以及 2021 年抚顺市电力负荷指标完成情况。利用抚顺市 2021 年负荷数据对负荷特性进行分析，分析了抚顺市日负荷特性、周负荷特性以及季节负荷特性，确定影响抚顺市电力负荷的主要因素。

(3) 详细介绍了 BP 神经网络的结构以及训练流程，基于 BP 神经网络对抚顺市 2021 年 12 月 31 日电力负荷进行预测。分析预测结果，针对 BP 神经网络容易陷入局部最优的缺点，引出 PIO 优化算法。利用搜索效率高，搜索精准的 PIO 算法对 BP 神经网络进行优化，基于 PIO-BP 神经网络模型对抚顺市同一天电力负荷进行预测，仿真对比了 PIO-BP 神经网络和 BP 神经网络预测效果，验证 PIO 算法对 BP 神经网络有较好的优化效果。为体现 PIO-BP 模型的优越性，本文对比 PIO-BP 模型与 LSSVM 模型、ELM 模型、WNN 模型的预测效果，进一步验证了 PIO-BP 神经网络模型拥有较高的预测精度。

(4) 针对 PIO 算法后期由于种群规模减小，容易陷入局部最优的缺点。利用量子编码鸽群，可以扩展鸽群搜索空间的优点，对 PIO 算法进行改进，并将改进后的 QPIO 算法与 BP 神经网络混合构建预测模型。基于 QPIO-BP 神经网络对抚顺市同一天电力负荷进行预测，仿真对比 QPIO-BP 神经网络和 PIO-BP 神经网络预测效果，结果表明 QPIO-BP 预测的 MAPE 照比 PIO-BP 预测的 MAPE 下降 1.15%。

(5) 针对原始电力负荷数据非平稳、非线性的特点，引入小波分解 (WT) 技术。利用 WT 技术将原始电力负荷数据分解成 5 个子序列，再结合 QPIO-BP 对 5 个子序列进行预测。仿真验证 WT-QPIO-BP 的预测效果，结果表明 WT-QPIO-BP 预测的 MAPE 照比 QPIO-BP 预测的 MAPE 下降 0.93%，证明本文提出的短期电力负荷预测模型精度较高。

## 5.2 展望

随着近些年电网的发展越来越智能和多元化，对电力负荷产生影响的因素越来越多。为了保证较高的电力负荷预测精度，需要对算法模型进行全面深入地研究

本文提出的 WT-QPIO-BP 预测模型在进行负荷预测时，既有较高的预测精度，但作者的科研水平有限，所提模型还存在着一定的不足，仍然存在很多工作需要完善。

(1) 本文所构建的模型只考虑了气象因素，没有考虑经济因素。在日后的研究中，可以尝试考虑电价因素构建模型，使预测效果精度更高。

(2) 目前，鸽群优化算法已经应用在国家各个领域，对于鸽群算法后期容易陷入局部最优的缺点，学者们也提出了许多不同的改进方法。例如：添加“临近鸽子”的协作机制、将柯西扰动引入基本鸽群优化算法、在鸽群算法中引入学习因子，加强前后两阶段学习因子的相互交流等方法都对鸽群算法有了进一步的改善。在今后的学习中，可以尝试用不同的方法改进鸽群算法后，再进一步优化 BP 神经网络模型，提高预测精度。

(3) 本文利用小波分解法处理电力负荷原始数据，考虑到 WT 技术存在自适应性较差的缺点。在日后的研究中可以考虑利用不同信号处理技术对电力负荷进行预处理。

## 攻读学位期间参加的科研项目及发表的学术论文

### 发表论文情况:

1. 白苏赫,张铭飞,李丁,彭丹阳.基于鸽群优化 BP 神经网络的短期电力负荷预测方法研究[J].信息与电脑(理论版),2021,33(19):47-49.



## 致 谢

鲜衣怒马少年时，不负韶华行且知。行文至此，意味着我的学生生涯即将落幕，何其幸运，在华水度过大学和研究生生涯，度过我一生的黄金时代，回首八年光阴，如烟火，满眼繁华，目之所及，皆是回忆。一篇论文写不完我三年的努力，我的青春也不会就此结束。

一朝沐杏雨，一朝念吾师。成为朱雪凌老师的学生是我研究生生涯好运的开始。身教大于言传，感谢恩师用生命影响了我的生命；感谢朱老师的善良和宽容，帮助我成为了懂得体谅的大人；感谢朱老师一丝不苟的学术态度教会我认真做事、踏实求学；感谢朱老师的全心栽培和悉心呵护，给了我坦然面对未来的底气。感激之情，溢于言表，言辞有尽，师恩难忘。

世事如烟去，恩情存如血。感谢我的家人，博学的爷爷、慈祥的奶奶、美丽的母亲、幽默的父亲、可爱的妹妹。特别感谢爷爷奶奶二十多年悉心培养以及对我学业的支持，让我可以在前进的道路上摒弃一切挂碍无畏前进。求学之旅结束之际，深感遗憾自己没能成为让家人骄傲的小孩，庆幸普通的自己拥有世界上最无私的爱。

感恩作为兼职辅导员的四年时光，让我的生命更有厚度。感谢陪伴过我的15级、16级、17级和18级全体同学，是可爱的你们让我从一身戾气的小姑娘成为温柔知性的大姐姐。如果离别之际的祝愿更容易实现，除了道出前程似锦，一路顺风，彼此珍重之类俗气真诚的祝愿，我更希望能未来可以再有机会看看你们，看我用心照顾的孩子们成为大人之后的模样。聚是一团火，散是满天星。天南海北，再相逢依旧如故。

平生感知己，芳草寸悠悠。感谢我的师门同学，三年以来包容我的懒惰、原谅的我笨拙，无论是科研方面还是生活方面都照顾着我，从来没人埋怨做事拖大家后腿的我；感谢我的好姐妹，和你们共同经历的每件事都值得纪念一生；感谢我实验室的好兄弟们，在我写作论文最困难的时期给予我陪伴和肯定；感谢五湖四海的好朋友们，你们的关心和爱是我勇往直前的底气。山水一程，三生有幸。愿有前程可奔赴，亦有岁月可回首。

路漫漫其修远兮，吾将上下而求索。感谢平凡又努力发光的自己，感谢深夜哭湿枕头又乐观面对的自己，感谢黑暗时刻积极寻找终点的自己。愿此去，心怀坦荡，身怀赤诚，在这个复杂迷人的世界，做最可爱勇敢的女孩子。

最后，愿我们伟大的祖国繁荣昌盛，兴旺发达！



## 参考文献

- [1] 李晶, 李淼. 分析电力在中国经济社会发展中的地位及作用[J]. 现代经济信息, 2018, (19): 341.
- [2] 余娜. 新能源主体地位凸显电力系统待重构[N]. 中国工业报, 2021-12-01.
- [3] 朱彤. 能源转型中我国电力能源的结构、问题与趋势[J]. 经济导刊, 2020, (06): 48-53.
- [4] 白玫. “十四五”时期电力工业高质量发展的方向与路径[J]. 价格理论与实践, 2020, (08): 4-10+44.
- [5] V E S, Shin C, Cho Y. Efficient energy consumption prediction model for a data analytic-enabled industry building in a smart city[J]. Building Research and Information, 2021, 49 (1): 127-143.
- [6] Chen K, Chen K, Wang Q, et al. Short-Term Load Forecasting with Deep Residual Networks[J]. IEEE Transactions on Smart Grid, 2019, 10(4): 3943-3952.
- [7] 李廷顺, 王伟, 刘泽三. 考虑不确定区间的电力负荷 GELM-WNN 预测方法[J]. 计算机工程, 2019, 45(07): 315-320.
- [8] CHAO H-C, LIN F, PAN J-S, et al. Power Load Forecasting Based on VMD and Attention-LSTM; proceedings of the Proceedings of the 3rd International Conference on Data Science and Information Technology, F, 2020 [C].
- [9] SON M, MOON J, JUNG S, et al. A short-term load forecasting scheme based on auto-encoder and random forest; proceedings of the International Conference on Applied Physics, System Science and Computers, F, 2018 [C]. Springer.
- [10] 曾朝晖, 姚宏亮, 陈晓方, 等. 一种基于小波变化的 ARMA-LSTM 的时间序列混合预测方法[C]. 中国山西太原: 第 32 届中国过程控制会议(CPCC2021), 2021. 1561.
- [11] JIANG D. Study on short-term load forecasting method based on the PSO and SVM model [J]. International Journal of Control and Automation, 2015, 8(8): 181-8.
- [12] 蔡百灵. 基于改进猫群神经网络的短期负荷预测研究[D]. [硕士学位论文]. 北京: 中国地质大学(北京), 2021.
- [13] 张彦宇, 肖茜. 国内外关于电力系统负荷预测的研究现状分析[J]. 山东工业技术, 2016, (11): 215+208.
- [14] 谢辉煌, 郑荣进, 黄晓生. 趋势外推法在连江县电力负荷预测中的应用[J]. 电气时代, 2017, (06): 78-80.
- [15] 李长庆. 基于灰色理论的电力系统中长期负荷预测研究[D]. [硕士学位论文]. 上海: 上海工程技术大学, 2020.
- [16] 金鑫. 基于灰色理论的短期电力负荷预测系统设计与实现[D]. [硕士学位论文]. 杭州: 浙江工业大学, 2016.
- [17] 陈磊, 张青云, 向晓, 等. 改进灰色预测模型在电力负荷预测中的应用[J]. 河北电力技

- 术, 2021, 40(06): 27-30.
- [18] 张超. 基于时间序列法超短期负荷预测改进方法的研究[D]. [硕士学位论文]. 锦州: 辽宁工业大学, 2015.
- [19] VMS Ardila, JN Maciel, JJG Ledesma Fuzzy Time Series Methods Applied to (In) Direct Short-Term Photovoltaic Power Forecasting[C]. *Energies*, 2022, 15(3), 845.
- [20] 王飞燕. 基于误差修正时间序列模型的短期电力需求预测分析[J]. *甘肃科技*, 2016, 32(19): 46-47+24.
- [21] 冯虓. 基于改进模糊回归分析法的负荷预测[J]. *黑龙江电力*, 2010, 32(04): 258-261.
- [22] 闫冬梅, 任丽莉, 康冰. 基于小波回归分析法的短期负荷预测模型研究[J]. *长春师范学院学报(自然科学版)*, 2010, 29(04): 20-24.
- [23] 王雁凌, 吴梦凯. 经济新常态下基于偏最小二乘回归的中长期负荷预测模型[J]. *电力自动化设备*, 2018, 38(03): 133-139.
- [24] 陈弘川, 蔡旭, 孙国歧, 等. 基于智能优化方法的相似日短期负荷预测[J]. *电力系统保护与控制*, 2021, 49(13): 121-127.
- [25] 张春雷, 李炎. 一种改进的相似日负荷预测方法[J]. *电气应用*, 2015, 34(S1): 161-163.
- [26] 郭威. 改进相似日的频域分解短期负荷预测[J]. *科技资讯*, 2013, (19): 102-103.
- [27] 张东平. 安全评估中的专家系统法及应用研究[J]. *重庆大学学报(社会科学版)*, 2010, 16(06): 40-43.
- [28] Ghanbari A, Abbasian-Naghneh S, Hadavandi E. An intelligent load forecasting expert system by integration of ant colony optimization, genetic algorithms and fuzzy logic[C]. *Computational Intelligence and Data Mining (CIDM): Symposium Series on Computational Intelligence*, 2011, 246-251.
- [29] 张爱英. 改进的模糊专家系统及其在医疗诊断领域的应用研究[D]. [硕士学位论文]. 杭州: 浙江理工大学, 2014.
- [30] 廖庆陵. 基于智能算法优化的支持向量机负荷预测研究[D]. [硕士学位论文]. 淄博: 山东理工大学, 2021.
- [31] 杨晓敏. 改进灰狼算法优化支持向量机的网络流量预测[J]. *电子测量与仪器学报*, 2021, 35(03): 211-217.
- [32] 刘也. 基于小波神经网络与支持向量机的供热负荷预测方法研究[D]. [硕士学位论文]. 吉林: 东北电力大学, 2020.
- [33] 张昊, 吴捷, 郁滨. 电力负荷的模糊预测方法[J]. *电力系统自动化*, 1997, (12): 11-14+20.
- [34] 朱学锋, 韩荣阁, 杨若红. 基于模糊预测系统的观测数据野值剔除方法[J]. *系统工程与电子技术*, 2006, (03): 478-482.
- [35] 代宇艳. 基于结构改进循环神经网络的短期电力负荷预测[D]. [硕士学位论文]. 重庆: 重庆邮电大学, 2020.
- [36] 孔繁宁. 基于神经网络的大连地区短期电力负荷预测[D]. [硕士学位论文]. 大连: 大连

- 理工大学, 2013.
- [37] 肖明亮. 基于改进 BP 神经网络的地铁客流预测研究[D]. [硕士学位论文]. 南昌: 南昌大学, 2021.
- [38] 赵翰林. 基于 ARIMA-BP 神经网络与情感分析的股票价格预测方法研究[D]. [硕士学位论文]. 沈阳: 沈阳工业大学, 2021.
- [39] 高杰. 基于优化 PNN 网络的变压器故障诊断研究[D]. [硕士学位论文]. 淮南: 安徽理工大学, 2018.
- [40] 程云祥, 张海静, 梁雅洁, 等. 计及负荷分类及其需求响应的电力现货市场研究[J]. 电气技术与经济, 2022, (01): 75-78.
- [41] 邓莎. 计及用电行为特征的负荷数据分类方法研究[D]. [硕士学位论文]. 沈阳: 沈阳工业大学, 2021.
- [42] 熊宁, 肖异瑶, 姚志刚, 等. 基于农村发展模式分析的中长期负荷预测方法[J]. 电力系统及其自动化学报, 2021, 33(03): 94-101.
- [43] Colomi A. Distributed optimization by ant colonies[C]. Proc of the First European Conference on Artificial Life, 1991. 134-142.
- [44] Eberhart R, Kennedy J. A new optimizer using particle swarm theory[C]. Mhs95 Sixth International Symposium on Micro Machine & Human Science, 2002. 39-43.
- [45] 李晓磊. 一种新型的智能优化方法-人工鱼群算法[D]. [博士学位论文]. 杭州: 浙江大学, 2003.
- [46] Duan H B, Qiao P X. Pigeon-inspired optimization: a new swarm intelligence optimizer for air robot path planning[J]. International Journal of Intelligent Computing & Cybernetics, 2008, 7(1): 24-37.
- [47] Bolaji A L, Babatunde B S, Shola P B. Adaptation of binary pigeon-inspired algorithm for solving multidimensional knapsack problem[M]. Soft Computing: Theories and Applications. Springer, Singapore, 2018: 743-751.
- [48] ZHANG, Tianjie, DUAN, et al. A modified consensus algorithm for multi-UAV formations based on pigeon-inspired optimization with a slow diving strategy[J]. CAAI Transactions on Intelligent Systems, 2017, 12(4): 12.
- [49] 段海滨, 叶飞. 鸽群优化算法研究进展[J]. 北京工业大学学报, 2017, 43(01): 1-7.
- [50] 姬小波, 金景峰, 李献锋. 改进鸽群算法求解高维复杂函数[J]. 信息与电脑(理论版), 2020, 32(24): 44-47.
- [51] 胡春鹤, 王依帆, 朱书豪, 等. 基于鸽群优化算法的图像分割方法研究[J]. 郑州大学学报(工学版), 2019, 40(04): 42-47.
- [52] 刘昂, 蒋近, 徐克锋. 改进蚁群和鸽群算法的机器人路径规划[J]. 计算机应用, 2020, 40(11): 3366-3372.
- [53] 潘自超. 基于粒子群优化神经网络的三相逆变器故障诊断研究[D]. [硕士学位论文].

- 吉林: 吉林大学, 2021.
- [54] 陈忠华, 刘博, 郭瑞, 等. 基于改进鸽群算法的光伏阵列 MPPT 方法[J]. 电力系统及其自动化学报, 2021, 33(08): 32-40.
- [55] 王瑞, 肖冰松. 基于改进鸽群优化和马尔可夫链的多无人机协同搜索方法[J]. 工程科学学报, 2019, 41(10): 1342-1350.
- [56] 贺静澜, 万贵钧, 张明, , 等. 生物地磁响应研究进展[J]. 生物化学与生物物理进展, 2018, 45(07): 689-704.
- [57] Schiffner I, Wiltschko R. Temporal fluctuations of the geomagnetic field affect pigeons' entire homing flight[J]. Journal of Comparative Physiology A: Neuroethology, Sensory, Neural, and Behavioral Physiology, 2011, 197(7): 765-772.
- [58] Whiten A. Operant Study of Sun Altitude and Pigeon Navigation[J]. Nature, 1972, 237(5355): 405-406.
- [59] Wiltschko R, Wiltschko W. Clock-shift experiments with homing pigeons: a compromise between solar and magnetic information?[J]. Behavioral Ecology and Sociobiology, 2001, 49(5): 393-400.和上边没对齐
- [60] 王帅, 郭月凯, 屈少辉, et al. 基于量子遗传算法的作战油料调运优化[J]. 舰船电子工程, 2021, 41(10): 121-125.
- [61] 侯通. 基于量子编程对量子非定域性及其相关应用的研究[D]. [硕士学位论文]. 廊坊: 华北科技学院, 2021.
- [62] 甄然, 王攀, 武晓晶, et al. 基于量子遗传算法的无人机冲突解脱方法[J]. 科学技术与工程, 2020, 20(17): 6963-6969.
- [63] 王攀. 基于改进量子遗传算法的无人机冲突解脱方法研究[D]. [硕士学位论文]. 石家庄: 河北科技大学, 2020.
- [64] 周凌子, 王道波, 汪浩. 基于合作行为的改进鸽群算法[C]. 中国上海: 2020 中国自动化大会(CAC2020), 2020. 116-121.
- [65] 张倩. 粒子群算法的一种改进算法[J]. 大理大学学报, 2019, 4(12): 12-17.
- [66] 章迎宾. 基于 VMD-HSBSO-ELM 的短期电力负荷预测研究[D]. [硕士学位论文]. 南昌: 南昌大学, 2021.
- [67] 张亚丽, 胡伯轩, 李莎莎, 等. 基于相似日搜索的改进 LMD 与 ESN 相结合的短期电力负荷预测模型[J]. 郑州大学学报(理学版), 2017, 49(02): 121-127.
- [68] 刘丹丹. 基于经验模态分解的时间序列预测方法[J]. 上海电力大学学报, 2021, 37(03): 231-234+252.