

摘要

随着电气化铁路的不断发展，这给人们的出行提供了巨大便利的同时，也带来了一系列问题。牵引负荷的峰值功率不仅会加剧负序、电压波动等电能质量问题，还会使系统对牵引变压器的容量要求变大，从而增加系统的日常运营成本。此外，机车在处于制动工况时产生的制动能量若未被及时回收，不仅会造成资源的浪费，还会注入电网对其造成冲击。因此，实现减小牵引负荷峰值功率与回收再生制动能量的双重应用，是提高系统运行效益的有效方法。为了得到更好的双重应用效果，本文在电气化铁路系统中引入超级电容储能，提出了一种基于 AC-MPC 的储能系统控制策略，并使用实测牵引负荷数据验证其有效性。本文主要研究内容如下：

为提高控制结果的精确性，本文在所提控制策略中加入负荷预测环节。为得到更加精确的牵引负荷预测结果，本文首先对牵引负荷数据特性进行分析，根据数据特性，选用 DWT 模型对牵引负荷进行数据分解，以此降低预测数据的复杂程度。针对 DWT 模型中的母小波函数的选取以及分解层数的选择，本文从原理分析与实验验证两个方面进行论证，并进行择优选取。再根据不同序列的频率差异，选用 TCN 模型预测中、低频序列；选用 SVR 模型预测高频序列，并使用 PSO 优化模型中的关键参数，使得 SVR 模型具有更高的预测精度。最后在 python 的 Keras 框架下验证了所提出的预测模型的有效性。

在对牵引负荷预测方法改进后的基础上，本文对目前双重应用下的储能控制策略进行分析，指出了其中依然存在的两个问题。第一点是系统运行时可能出现的储能“死区时间”问题，第二点是预测误差对控制结果影响较大的问题。针对问题一，我们采用实时修正 SOC 的方法。为了得到更好的修正效果，本文在修正过程中引入了滚动优化与预测控制的思想。减小了修正过程的计算量，避免了因为修正而引起新的负荷峰值的问题；针对问题二，在对预测模型进行改进之后，我们还可以在每次滚动优化过程加入滚动预测过程。通过减小预测时间尺度的方式来减小预测结果的误差，从而减小预测误差对控制结果造成的影响。经实测数据实验表明，本文所提控制策略能够有效地解决上述中存在的两个问题，保证了双重应用的效果并提高了系统运行的经济性。

关键词：电气化铁路；牵引负荷预测；计算智能模型；模型预测控制；双重应用

Abstract

With the continuous development of electrified railways, while bringing many conveniences to people, it also brings a series of problems. The peak power of the traction load will not only cause power quality problems such as negative sequence and voltage fluctuations, but also increase the capacity requirements of the system on the traction transformer. In addition, if the braking energy generated by the locomotive in the braking condition is not recovered in time, it will not only cause a waste of resources, but will also cause an impact on the grid when injected into the power grid. Solving the problem of recovery and utilization of regenerative braking energy and excessive peak power also has an important impact on the economic benefits of railways. Focusing on these two issues, this paper introduces the dual application of super capacitor energy storage to the traction load in the electrified railway system to reduce the maximum demand of the traction load and increase the capacity utilization rate of the electrified railway traction transformer, so as to improve the economic benefits of the railway sector. the goal of. Based on a large number of related literatures, this paper conducts an in-depth study on the control strategy of energy storage devices, and proposes a dual-application control strategy for electrified railway energy storage systems, which achieves load peak elimination and regenerative braking energy recovery. The main research contents and innovations of this article are as follows:

In order to improve the accuracy of the control results, the proposed control strategy in this paper incorporates a load prediction link. Therefore, the traction load prediction technique is first investigated. To overcome the shortcomings of existing traction load prediction methods, this paper first analyzes the traction load data characteristics. To reduce the difficulty of prediction, the DWT model is first used to decompose the traction load data. The selection of the mother wavelet function and the number of decomposition layers in the DWT model are demonstrated from both principle analysis and experimental validation, and are selected on the basis of merit. Then, according to the frequency difference of different sequences, the TCN model is chosen to predict medium and low frequency sequences; the SVR model is chosen to predict high frequency sequences, and the key parameters in the model are optimized using PSO to make the SVR model have higher prediction accuracy. Finally, the

effectiveness of the proposed prediction model is verified in the Keras framework of python.

Based on the improved traction load prediction method, this paper analyzes the current energy storage control strategy under dual application and points out two problems that still exist in it. The first problem is the possible "dead time" of energy storage during system operation, and the second problem is the influence of prediction error on control results. To address problem 1, we use a real-time SOC correction method. In order to get a better correction effect, we introduce the idea of rolling optimization and predictive control in the correction process. This reduces the computation of the correction process and avoids the problem of new load peaks caused by the correction. For problem two, after improving the prediction model, we can also add a rolling prediction process to each rolling optimization process. By reducing the prediction time scale to reduce the error of the prediction results, thus reducing the impact of the prediction error on the control results. The experimental data show that the proposed control strategy can effectively solve the above two problems, ensure the effect of dual application and improve the economy of system operation.

Keywords: Electrified Railway; Traction load forecast; Computational Intelligence Model; Model predictive control; Dual application

全文英文缩写与中文含义对照表

缩略语	英文全称	中文全称
SC	Super Capacitor Storage	超级电容储能
ESD	Energy Storage Device	储能装置
SOC	State of Charge	荷电状态
PSO	Particle Swarm Optimization	粒子群优化算法
CNN	Convolutional Neural Network	卷积神经网络
RNN	Recurrent Neural Network	循环神经网络
LSTM	Long Short-Term Memory	长短期记忆神经网络
TCN	Temporal Convolutional Network	时间卷积神经网络
SVR	Support Vector Regression	支持向量回归
RMSE	Root Mean Square Error	均方根误差
MAE	Mean Absolute Error	平均绝对误差
MPC	Model Prediction Control	模型预测控制

目录

摘要.....	I
Abstract.....	II
全文英文缩写与中文含义对照表.....	IV
第 1 章 绪论.....	1
1.1 研究背景及意义.....	1
1.2 国内外研究现状.....	3
1.2.1 电气化铁路储能技术及其控制策略研究现状.....	3
1.2.2 电气化铁路牵引负荷预测研究现状.....	5
1.2.3 计算智能技术的研究与应用现状.....	7
1.3 本文研究内容及创新点.....	7
1.3.1 本文研究内容.....	7
1.3.2 本文创新点.....	9
第 2 章 牵引供电系统与储能系统基本原理.....	10
2.1 牵引供电系统结构及负荷特性.....	10
2.1.1 牵引供电系统.....	10
2.1.2 牵引负荷特性.....	11
2.2 储能装置运行的基本原理.....	11
2.3 电气化铁路上的储能系统拓扑结构及工作原理.....	14
2.4 本章小结.....	17
第 3 章 基于 DWT-TCN-PSO_SVR 的组合预测模型.....	18
3.1 常规预测模型及问题分析.....	18
3.2 基于 DWT-TCN-PSO_SVR 的组合预测模型.....	19
3.2.1 组合预测模型流程.....	19
3.2.1 离散小波变换 (DWT)	20
3.2.2 时间卷积网络 (TCN)	22
3.2.3 支持向量回归 (SVR)	24
3.3 案例研究.....	25
3.3.1 案例介绍与评价指标.....	25
3.3.2 模型参数优化.....	26
3.3.3 预测过程及分析.....	30
3.4 本章小结.....	36
第 4 章 基于 AC-MPC 的储能系统双重应用控制策略	37

4.1 储能“死区时间”问题机理分析	37
4.1.1 常规控制策略模型.....	37
4.1.2 储能“死区时间”问题介绍	39
4.1.3 储能“死区时间”问题原理分析	42
4.2 基于 AC-MPC 的控制策略	43
4.2.1 模型预测控制思想.....	43
4.2.2 总体控制流程.....	45
4.2.3 储能出力自适应修正方法.....	49
4.3 案例研究.....	51
4.3.1 案例说明与参数介绍.....	51
4.3.2 减小预测误差对控制结果的影响分析.....	52
4.3.3 解决储能“死区时间”问题分析	55
4.4 控制方法的有效性验证.....	58
4.4.1 对其他时间段负荷的敏感性.....	58
4.4.2 控制方法的实时性分析.....	59
4.4 本章小结.....	60
第 5 章 总结与展望.....	61
5.1 本文总结.....	61
5.2 后期工作展望.....	62
参考文献.....	63
致谢.....	66
个人简历、攻读硕士学位期间取得的研究成果与参与的科研项目	67

第 1 章 绪论

1.1 研究背景及意义

随着铁路相关技术的不断发展与能源结构的重大变革,我国已正式向现代化铁路迈进。2007 年,我国正式实现动车组的开通,这标志着我国电气化铁路的由弱变强。至 2012 年底,我国已具有世界最长的铁路总营运里程。2017 年,复兴号时速 350 公里的商业运营更是向世界展示了中国速度。我国电气化铁路在这短短的几十年里迅速发展,纵横交错的高铁网与电气化铁路网为人们的出行与经济的发展提供了巨大的便利与可靠的支撑^[1,2]。

图 1-1 所示为我国近几年的铁路运营里程统计,由图可知,我国电气化铁路里程数在不断增加,伴随着的是我国经济的稳定快速的的增长,而经济的快速稳定增长又反过来带动了电气化铁路的发展。铁路作为社会经济的重要支柱和国家经济的大动脉,在我国的投资建设任务中也占据着重要的地位。我国计划在 2025 年之前,完成铁路总长 17.5 万 km 的建设任务与高铁线路总长 3.8 万 km 的建设任务。其目标是使铁路更多融入未发展地区,服务于更多人口,优化铁路网布局,提高铁路运行效益并降低资源损耗。值得注意的是,随着电气化铁路如此大规模的发展,其带来的一系列问题所造成的影响也会愈发加大。如何更好地解决这些问题也更加值得我们重视。除此之外,由于电气化铁路运营的经济性会对国民经济产生巨大影响,因此我们在研究解决相关问题的技术时,不仅要考虑到牵引供电系统的稳定安全运行,也需注重其运行的经济性^[3]。




图 1-1 2014-2019 中国铁路运营里程统计

电气化铁路作为我国最大的单体负荷，其总用电量占全国的 1%-1.5%，因此其总运营成本的大部分为电费成本。随着新建线路的快速增加，铁路公司在电费方面的支出也在不断增长，因此亟需对电气化铁路相关技术进行研究，以实现电气化铁路的经济稳定运行。一般而言，在牵引供电系统中电费计价方式分为两个部分，包括电度电费计价部分与需量电费计价部分。其中需量电费计价部分与牵引变压器的容量直接相关^[4,5]。而牵引变压器设定容量的最小值是由牵引负荷的最大峰值功率所决定。但由实测牵引负荷数据可知，牵引负荷的峰值功率通常出现频率低且持续时间短，所以目前我国大多数牵引变压器都出现容量冗余、利用率低的情况。根据目前的一项调查可知，我国大多数牵引变压器有效使用容量仅占总容量的 5%~40%^[6,7]。综上所述，若牵引负荷最大峰值过大，这不仅会直接增加铁路部门的需量电费支出，还会造成牵引变压器额定容量过大、实际利用率低的情况，从而加大了铁路部门的初始投资成本。因此，我们有必要针对牵引负荷的峰值功率进行研究，若能有效地消除牵引负荷峰值功率，无疑能够有效地提高电气化铁路运行的经济性；除此之外，列车行驶在制动工况时，会产生一部分的再生制动能量，若是产生的这部分能量未被及时回收，不仅会造成资源的浪费，还会注入电网从而对电网造成冲击。若是能够及时地对这部分再生制动能量进行回收，在合适的时机提供给牵引供电系统，这不仅可以减少铁路部门的电度电费支出，也可以响应国家提倡的节能减排的主题。综上所述，减小牵引负荷峰值功率与对再生制动能量及时回收利用是提高铁路部门经济效益的关键点。

为了实现牵引负荷峰值功率消除与再生制动能量回收利用的双重应用，人们提出了许多解决方案，如使用铁路功率调节器(Railway Static Power Conditioner, RPC)来解决对两供电臂进行功率转移可以在一定程度上对此进行解决^[3,8]。此外，随着储能装置(Energy Storage Device, ESD)相关技术的逐步成熟。根据其能够对能量进行存储以及二次分配的特性，已经在电力系统中发挥出了巨大作用^[9-12]。因此，可以考虑将 ESD 应用于牵引供电系统，并与 RPC 装置相结合，利用 ESD 的实时能量存储与二次分配的特性和 RPC 的功率转移的特性，可以进一步减小系统对两者的容量要求，从而进一步减小系统的投资成本。目前，储能在电力系统中的应用主要集中在参与系统调峰和配合发电设备调频两种场景。储能的运行控制策略相关研究仍处于初级阶段，主要集中在根据单一信号，如调度指令、系统的频率变化等，优化储能设备的动作时机和充分利用储能的放电深度。但如何根据电池容量、充放电倍率和 SOC 上下限值解决电池参与调峰的动作时机和动作深度问题，是储能参与电网调峰控制的难点。值得注意的是，若将 ESD 应用于牵引供电系统中，由于牵引负荷具有随机波动性较强和波动幅值较大的特性^[13]，这会给储能装置的控制带来了挑战。一方面，负荷的随机波动使得控制系统

需要有快速的响应能力；另一方面，较大的负荷波动幅度会造成较大的负荷峰值功率，这对控制系统的大信号稳定性提出了更高的要求^[14]。因此，为了提高控制系统的效果，我们考虑在控制策略中加入负荷预测环节，根据负荷预测数据提前调整控制系统参数，从而提高控制系统的适应性和控制效果^[15]。

1.2 国内外研究现状

1.2.1 电气化铁路储能技术及其控制策略研究现状

1. 储能技术研究现状

对电力系统而言，储能的功能就是直接或间接地提供调节能力，消除电力供应和需求之间的差异，保证系统灵活性。在传统电力系统中，化石能源、水能、核能等一次能源都是有形实体，易于存储，储能主要配置在一次能源侧，如煤场、油罐、水库等。发电机组依托这些储能设施为系统提供调节能力，功率调节能力为最大负荷的 60%~70%，能量调节能力为全年用电量的 3% -5%。然而，随着能源清洁转型不断深入，风电、光伏等波动新能源发电装机占比不断提高，常规调节能力逐步减少，需要引入新型储能作为调节能力来源，电储能将成为高比例清洁能源系统中重要的储能形式，在电力系统发、输配、用各环节可广泛应用。目前的储能方式可以分为以下三类。不同类型储能技术的原理不同，技术经济特性各异，在电力系统中的应用情况也有明显区别^[16]。

（一）机械储能

机械储能方面，我国使用较多的抽水储能技术已发展较为成熟，其使用寿命长(超过 50 年)，电能转换效率较高(约 75%)，装机规模可达吉瓦级，持续放电时间一般为 6~12h，但抽水蓄能对地址选取要求较高，并且建设一座抽水蓄能站的建设周期也比较长。传统的压缩空气储能技术成熟，使用生命周期长，缺点是转换效率低；依托地下天然洞穴储气，储能规模可达数十小时，但选址要求较高；飞轮储能具有功率密度高(5kW/kg)、设备体积小、转换效率高(超过 90%)的特点，但缺乏持续放电能力(分钟级)，属于功率型储能技术，其能量成本为 1.5 万~1.8 万美元/kWh。近年来，由于机械储能原理简单可靠，不少机构开始探索混凝土块等新型固体重力储能^[17]。

（二）电化学储能

电化学储能方面，锂离子电池具有转换效率高的特点(90%~95%)，但循环寿命(约 4000 次)仍有待提高，且存在消防安全隐患，能量成本 300~400 美元/kWh^[18]。铅电池安全可靠，但能量密度低，循环次数(1000~2000 次)和使用寿命(3~5 年)有限，能量成本 100~250 美元/kWh。液流电池原理安全可靠，能量成本 500~550

美元/kWh，但存在能量转化率低的情况。近年来，科研机构和技术厂商不断探寻新材料、新体系的电化学电池技术，包括液态金属电池等，力求获得储能密度大、安全性好、原材料易得和循环寿命长的新型电池。

（三）电磁储能

电磁储能方面，超级电容储能（Super Capacitor Storage, SC）的功率密度高（7~10kW/kg），循环次数多（10万次），但单体容量小，是典型的功率型储能技术，功率成本7-10美元/kW。理论上，SC具有较长的使用寿命和无限的充放电次数且无需维护，此外超级电容的生产过程对环境较为友好。由于这些优良特性，SC常常被用作交通设施中功率密度型储能装置首选^[19,20]。

2.牵引负荷双重应用的储能控制策略研究现状

目前电气化铁路中存在的牵引变压器容量利用率低、牵引负荷峰值冲击和再生制动能量利用率低等问题引起了相关学者关注^[21,22]。针对这些问题，相关学者提出了各种解决方法。文献[23]提出在两供电臂中加入RPC装置，平衡两供电臂负荷，这在一定程度缓解了负荷峰值冲击和再生制动能量回收的问题。文献[24]提出了一种基于超级电容的铁路功率调节器(SC-RPC)，此装置可以实现完全回收利用再生制动能量，还能在负荷峰值处协助电网提供能量，实现了更好的牵引负荷峰值消除和再生制动能量回收的双重应用。

在SC-RPC中，如何协调电网、储能系统与列车之间的能量流动，实现牵引负荷的双重应用，就显得尤为重要^[25]。为此，有学者针对上述协调控制策略进行了大量研究。这些研究主要可以分为两类，第一类是基于规则的控制策略，该策略主要是根据提前设定的规则，根据采集到的数据实时地对牵引负荷进行双重应用。文献[26]根据历史典型工作日数据，确定了日内的削峰线和填谷线，以此作为牵引负荷实时双重应用的依据，并采用恒功率法得到了牵引负荷双重应用后的负荷分布曲线。第二类是基于全局优化的控制策略，该策略主要是根据调度日的负荷预测曲线，以系统运行成本最低为目标制定日前优化调度计划^[27,28]。文献[29]基于常规日前负荷优化调度，深入考虑日内的负荷的峰谷特性，并基于此特性制定了充电、放电、平衡三种调度模型，得到了理想的双重应用效果。

上述研究在牵引负荷双重应用控制策略方面均取得了一定的研究成果，但也还存在一些尚未解决的问题或值得改进的地方。问题一是目前已有的研究均未考虑当储能装置容量较小或者某时间段内存在连续峰值负荷时，如何尽可能保证储能能量能够完成负荷削峰工作^[30]。问题二是基于规则的控制策略是根据历史负荷制定规则^{[31][32]}，而牵引负荷具有很强的不确定性，这可能会导致这种方法在不同的场景下存在适用性差的问题^[33]；基于全局优化的方法采用对负荷数据进行预测的方式解决了这个问题^[34]，但此类方法一般默认负荷预测曲线较为精确^[25]，

很少考虑预测误差对控制结果带来的影响；上述两个问题都会对最终的双重应用效果产生影响，进而影响到系统运行的经济性。

针对已有的研究均未考虑当储能装置容量较小或者某时间段内存在连续峰值负荷时，如何尽可能保证储能能量能够完成负荷削峰工作的问题。已有学者对此做出研究，并提出了基于荷电状态值（State of Charge, SOC）区间划分方法的储能控制策略。这种控制策略的主要思想是针对常规的控制策略均为单点控制策略，即在对某个时刻进行控制时，无法考虑此时刻充放电会对未来时刻产生的影响，也无法考虑到未来时刻对此时刻充放电的需求。而当前储能装置的荷电状态（SOC）是根据当前时刻之前，所有储能进行充放电的累积的结果。因此，当前时刻的储能出力大小对未来时刻储能装置的 SOC 存在影响。若当前时刻储能出力过多，未来某些时刻储能 SOC 便会低于下限值，从而出现过充过放的情况。因此相关学者在得到负荷预测数据的基础上，提出了一种基于 SOC 区间划分的控制策略。这种策略能够考虑到当前储能处理对未来时刻所造成的影响，从而合理调节当前时刻的储能出力，减少过充过放的现象发生。但这种方法只能考虑到当前时刻对未来时刻的影响，却不能考虑到未来时刻对当前时刻的要求，这会使得储能的实时 SOC 修正变得很局促，只能以较小的功率进行 SOC 修正，不能得到理想的控制效果^[35]。因此，引入预测控制来预知此时刻负荷修正会对未来时刻储能 SOC 造成的影响是解决问题的有效方法。但值得注意的是预测控制过程中可能会出现负荷预测数据的误差较大，从而使得控制结果的精度不高的情况。因此，如何对牵引负荷预测模型进行改进，提高预测结果的精度，是解决此问题的另一关键。

1.2.2 电气化铁路牵引负荷预测研究现状

由于牵引负荷的随机波动性较强，传统基于统计学的预测模型不能较好地把握数据间的变化规律，因此得到的预测结果的精度不够高。目前牵引负荷预测模型主要可以分为以下两类：第一种是基于牵引供电计算的仿真预测模型，第二种是建立历史负荷数据特征库进行数据拟合的预测模型。

在基于牵引供电计算的仿真预测模型方面，[36]建立机车组实时负荷计算模型，包括对机车组进行详细的受力分析，在受力分析中详细考虑当前机车当前工况以及机车所处位置，机车位置是根据列车运行图所得到。而后对动车组进行有功功率计算求解得到所需结果；文献[37]和文献[38]在文献[36]的基础上，建立了全天的牵引负荷动态模型，但在不同列车工况下使用的同一个功率因数，且未考虑谐波之间互相作用产生的影响，所以模型的精确性有所欠缺。文献[39]结合实时的线路情况对列车进行了工况区分，以此构建了动态负荷计算模型，使预测模

型的精确性有所提升。文献[15]对大量的实测数据进行分析，基于牵引负荷的动态特性，应用概率统计方法，以此建立牵引负荷不同工况下的负荷模型^[40]。并结合行车运行图所能够提供的行车次、时间等信息，得到负荷预测结果。这种预测模型的优点如下：一是能够获取到的参数种类较多，包括有功功率、无功功率、功率因素等；二是预测得到的负荷数据准确度较高。但缺点也不可忽视，其一是模型建立难度大，包括诸多数据，如发车时间表、线路具体状况等；二是计算复杂，需要对机车进行受力分析并结合当前机车运行情况计算实时功率。三是模型适应能力差，对于不同的线路，需要重新建立模型。

建立历史负荷数据特征库进行数据拟合的预测模型方面，文献[41]使用数理统计的思想对牵引负荷进行剖析，得到牵引网上的馈线电流的分布特征，建立起牵引负荷特征库，而后应用了蒙特卡洛抽样法得到预测负荷。文献[41]根据工况差异将牵引负荷区分为再生工况与牵引工况，对其进行特征分析后使用模型 C 均值聚类法将牵引负荷进行分类。而后使用判别分析法找到匹配的概率模型，得到预测负荷结果。文献[42]对牵引负荷的特征量进行了改进，在文献[41]的基础上增加了偏度系数作为主要的特征量，并增加了负荷分类类别数目，提高了负荷分类的精确度，从而提高了最终预测结果的精度。文献[43]对聚类模型进行改进，使用高斯混合模型得到牵引负荷的聚类结果，并利用神经网络在面对海量数据时表现出的优异性能将其应用于模型特征库的匹配工作。取得了良好的应用效果。这种方法更加适用于牵引负荷的长期预测，应用于线路相关设备定容。若是用于超短期预测领域，缺点较为明显。一是过程较为复杂，负荷特征提取工作难度较大。二是预测精度达不到使用要求。

为了更好地完成牵引负荷的双重应用工作，这对预测模型的性能提出了挑战。第一点在于预测模型的建立不能过于复杂；第二在于预测模型的预测精度足够高。目前传统的预测方法在各自的领域中都得到令人满意的预测效果，但也都存在自身的局限性。因此我们需要找到一种模型建立更加简单、预测结果精度更高的预测模型。

铁路牵引负荷与风电负荷和太阳能负荷又有所不同。牵引负荷数据存在很多 0 值，导致牵引负荷的波动幅度很大，这使得一些方法在其他负荷预测领域作用效果较好，但在牵引负荷预测领域的作用效果有待提升。因此，分析牵引负荷的数据分布特征和各种预测模型的优缺点，找到更加合适的预测方法是非常重要的。文献[44]提出了基于长短期记忆 (Long Short-Term Memory, LSTM) 的预测模型，有效地避免了模型建立的复杂性。预测工作量减少。由于单一神经网络有其自身的局限性，研究人员开始尝试将单一神经网络与其他算法相结合，并取得了一些成果。文献[45]提出了一种结合卷积神经网络(Convolutional Neural Network, CNN)

和时间卷积网络(Temporal Convolutional Network, TCN)的组合预测方法,该方法在实际数据集中表现出良好的性能。

1.2.3 计算智能技术的研究与应用现状

随着新兴学科和应用理论的兴起,一些预测方法在诸如太阳能和风电预测领域取得了成功,包括遗传算法(GA)、支持向量回归、神经网络和组合预测在内的几种算法在风速、风电和其他负荷预测领域内得到了很好的应用。

文献[46]提出了一种基于分形插值的负荷预测方法,使预测结果的误差减少了。基于分形插值的负荷预测;文献[47]提出在预测中加入注意机制,突出输入的有效特征;文献[48]考虑了电能和能源载体之间的耦合和依赖,使用 Levenberg-Marquardt (LM) 方法对深度信念网络(Deep Belief Network, DBN)网络参数进行优化校准; [49]在预测中考虑了风功率因子的影响,使用核密度估计方法,获得了更精确的预测区间。在文献[50]中,由于数据的高度非线性性质,神经模糊技术被应用于分形数据。它被用来检测基于分形维度的影响风速的最重要变量;在文献[51]中,设计并调整了自适应神经模糊推理系统(ANFIS),以根据风电场的涡轮机数量来估计风电场的效率;这些方法根据自身预测过程中面临的困难,对预测模型进行改进,提高了最终的预测精度。此外,利用波形分解来降低牵引负荷的复杂性是提高预测精度的有效方法。文献[52]利用经验模式分解(Empirical Mode Decomposition, EMD)对数据进行分解,然后选择 DBN 对分解后的数据进行预测,得到了理想的结果。文献[53]利用离散小波分解(Discrete Wavelet Transformation, DWT)对数据进行分解,然后根据分解得到的子序列的特征,选择 ARIMA 和 BNN 模型对子序列进行预测,分别得到了理想的预测结果。

铁路牵引负荷与风电负荷和太阳能负荷又有所不同。牵引负荷数据存在很多零值,导致牵引负荷的波动幅度很大,这使得一些方法在其他负荷预测领域作用效果较好,但在牵引负荷预测领域的作用效果有待提升。因此,分析牵引负荷的数据分布特征和各种预测模型的优缺点,找到更加合适的预测方法十分重要。

1.3 本文研究内容及创新点

1.3.1 本文研究内容

本文围绕目前牵引负荷中负荷峰值消除与再生制动能量回收的双重应用中,储能装置的控制策略展开了研究。首先对常规控制策略进行了分析,指出了目前控制策略存在的两个问题。一是如何保证在储能装置尽可能小的情况下完成牵引负荷的双重应用工作;二是如何减小预测误差从而控制策略的控制精度。而后针

对这两个问题展开了更详细的分析,先是提出了一种基于计算智能技术的预牵引负荷预测模型,能够得到更加精确的预测结果;而后综合考虑了系统运行的经济性与双重应用的效果,设计了一种新型的储能控制策略。各章节具体工作如下:

第 1 章对电气化铁路相关背景和本文所做工作的意义进行了阐述,对电气化铁路中储能装置的控制策略进行了现状分析,对当前牵引负荷预测领域内常用的预测模型进行了介绍与优缺点分析,对基于计算智能技术的预测模型进行了介绍,包括它们在其他符合领域的应用现状。可以更好地从整体上把握全文。

第 2 章首先介绍了牵引供电系统的相关结构,并分析得到牵引负荷具有随机波动性强、随机幅值较大的特性。接着介绍了 ESD 运行在不同工况下,双向 DC/DC 变换器的工作状态。最后在含 SC-RPC 的系统拓扑结构图中,分析了系统在对不同 ESD 工作状态下的能量流向图,为制定双重应用下储能系统控制策略提供了指引。

第 3 章针对牵引力负荷具有较强的随机波动,难以预测的问题,采用 DWT (离散小波变换)方法对牵引力负荷进行分解,得到单一波动频率的子序列。利用子序列进行预测可以得到比直接预测原始数据更准确的结果。针对负荷峰值难以预测的问题,本文采用 haar 函数作为小波分解的基础函数。分解得到的子系列峰值比传统方法中使用的 dbn 基函数得到的峰值更平滑,从而提高了预测结果的准确性。本文采用 SVR 模型对牵引负荷的高频子序列进行预测,SVR 模型能够考虑样本拟合误差和模型的复杂性,具有较好的泛化能力,与神经网络方法可能带来的过拟合和泛化能力差的问题相比,提高了预测结果的准确性和稳定性。利用中国某牵引供电站的实测数据进行的实验结果表明,本文提出的 DWT-TCN-PSO_SVR 组合预测方法与几种最先进的牵引负荷预测模型相比具有更高的预测精度。

第 4 章中指出了常规控制策略在牵引负荷双重应用下可能出现的储能“死区时间”问题与预测误差造成控制结果偏差较大的问题。本章对储能“死区时间”问题进行机理分析,旨在不增大储能容量的前提下对此问题进行解决。因此,本章结合模型预测控制方法中的滚动优化与预测控制的思想,提出了一种基于储能荷电状态自适应修正的模型预测控制策略。策略中包含的预测控制思想,能够预知后续时刻储能 SOC 对当前时刻的储能系统的充放电功率要求,与当前时刻储能系统充放电功率对后续时刻的储能 SOC 的影响,能够保证每次储能出力修正的精确性,针对储能“死区时间”问题进行较好地解决;滚动优化能够减小每次修正对全局带来的影响,减小计算的复杂程度。此外,滚动优化环节中的滚动预测通过以减小预测时间尺度的方式来减小预测误差,从而减小预测误差对控制结果的影响,能够针对预测误差造成控制结果偏差较大的问题进行较好地解决。经实测

数据实验表明，本文所提控制策略能够有效地解决上述中存在的两个问题，保证了双重应用的效果并提高了系统运行的经济性。

第五章是对全文的总结与展望。

1.3.2 本文创新点

本文的亮点与创新如下：

第一，提出了一种新的牵引负荷组合预测方法，此方法具有更高的预测精度。在此方法中使用 DWT 模型对牵引负荷进行分解，以降低预测数据的复杂度，并对 DWT 中母小波函数的选取与分解层数进行择优论证。而后使用 TCN 模型与 SVR 模型分别预测低、中频子序列和高频子序列。此外，SVR 模型中关键参数是使用 PSO 寻优得到。

第二，指出常规控制策略在双重应用下可能出现的储能“死区时间”问题与预测误差造成控制结果偏差较大的问题。在对问题进行深度剖析后，根据问题的产生本质，提出了一种基于 AC-MPC 的储能系统双重应用控制策略。策略中包含的预测控制思想能够保证功率修正的精确性，可以较好地解决储能“死区时间”问题；滚动优化能够减小每次修正对全局带来的影响，减小计算的复杂程度。此外，滚动优化环节中的滚动预测通过以减小预测时间尺度的方式来减小预测误差，从而较好地解决预测误差过大而造成控制结果偏差较大的问题。

第 2 章 牵引供电系统与储能系统基本原理

2.1 牵引供电系统结构及负荷特性

2.1.1 牵引供电系统

牵引供电系统包括供电电源到受电机车这个途径中，所以电力所经过的电力装置的总称，其主要构成模块是变电所与供电网。

其中变电所的主要任务是将电网电压变换成机车适用电压，并通过馈电线输送到接触网上。机车在需要取电时，升起受电弓便能从此处获得所需电能。供电网中的主要构成元素包括接触网、馈线、回流线和钢轨。系统的结构如图 2-1 所示。

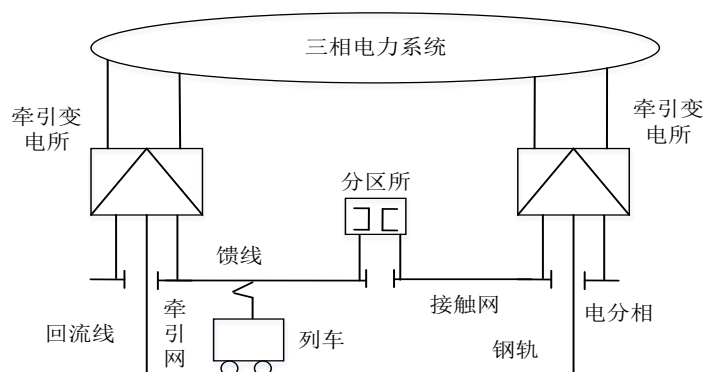


图 2-1 牵引供电系统组成

牵引变压器是变电所的核心元件。其接线方式、容量会直接影响变电站的主接线形式以及变电站的室内布置面积，对整个牵引变电站的运行产生经济上的影响。如图 2-2 是常用的三种牵引变压器的接线方式，它们的特点如表 2-1 所示。本文所研究的电气化铁路牵引供电系统是基于 V/v 接线方式的牵引变压器。

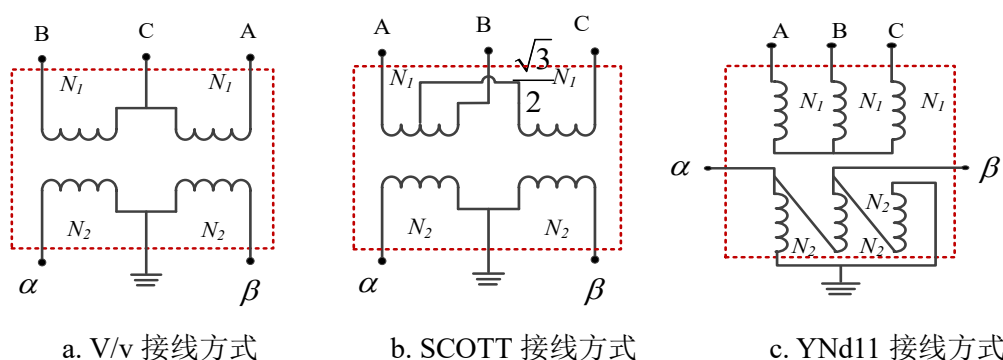


图 2-2 三种常用牵引变压器

表 2-1 三种接线方式比较

接线方式	单相	V/v	YNd11	平衡
结构	简单	简单	结构	结构
容积利用率	高	低	低	较高
优点	容量利用率可达 100%，主接线简单，占地面积小，投资少	主接线较简单，投资少，负序比简单少，可双边供电	低压侧保持三相，有利于供应牵引变电所连续供电	阻抗匹配系数取值灵活，变压器的设计更加方便
缺点	负序电流较大，对接触网不能双边供电	一个变压器故障，有倒闸过程，存在短暂停电	变压器容量不能充分利用，结构较单相复杂	需要考虑减小电磁力，环流等问题
适用条件	电力系统容量较大场合	单供电臂容量较小场所	山区单线牵引负荷不平衡场所	大运量、高密度，电网薄弱场所

2.1.2 牵引负荷特性

牵引负荷是指在供电范围内，由牵引网提供给所有机车正常运行的电能。由于电力机车的运行会受到很多因素的影响，如线路状况、天气影响、列车临时停运等情况。对其进行分析，总结出数据的分布和预测的难度，对后续预测方法的选择有很大帮助。牵引负荷具有以下特点：

1) 牵引负荷具有很强的随机波动性。当列车加速、减速或遇到弯道、坡道、支路等路况时，会引起牵引负荷的波动。因为影响因素很多，而且这些因素是随机的，所以牵引力负荷也有很强的随机波动。

2) 空载情况和负荷突然变化频繁。当供电范围内没有列车通过时，牵引负荷的值为 0，而一旦有列车通过。牵引负荷会立即跳到 10 兆瓦或更高。往往在空载现象之后，会出现负荷的急剧变化。

基于牵引负荷的上述特点，有必要采用信号分解的方法对原始牵引负荷进行分解，以降低原始牵引负荷的复杂性。因此，使用 DWT 对原始牵引力负荷进行预处理是一个不错的选择。上述分析也证实了在实际数据分析层面上，将 DWT 引入组合模型的可行性。

2.2 储能装置运行的基本原理

前文已经对目前常用的三种储能类型进行了分析，由于 SC 具有响应速度快，可频繁充放电的优势，可以较好地响应负荷峰值消除与再生制动能量回收的需求响应。因此本文选用超级电容作为储能装置。

为避免储能装置在充放电时端口电压的大幅度波动对设备产生的影响，我们在储能装置与外界电路系统中增加一个双向 DC/DC 变换器。此装置可以及时响应指令需求，调节功率的双向流动，还能维持直流输出电压的稳定。本文所用 DC/DC 变换器结构如图 2-3 所示，储能装置的充放电分别对应双向 DC/DC 变换器的升压模式与降压模式，两种模式具体分析如下：




图 2-3 双向 DC/DC 变换器结构图

(1) 升压模式

当电路处于升压模式时， V_o 大于 V_1 ，其中 S_1 处于关断状态，电路如图 2-4 所示。




图 2-4 升压模式电路

当开关管 S_2 处于导通状态时，电能流向如图 2-5(a)所示，电路存在如下表达式。

$$V_1 = L \frac{di_L}{dt} = L \frac{\Delta i_{L_{on}}}{T_{on}} \quad (2-1)$$

式中， V_1 为输入端电压， L 为电感值， i_L 为电感电流， T_{on} 为一个开关周期内的导通时间， $\Delta i_{L_{on}}$ 为导通时间电感电流的增加量。




图 2-5 升压模式下的电流向图

当开关管 S_2 处于关断状态时，电流向如图 2-5(b)所示，此时电路存在以下关系式。

$$V_1 - V_0 = L \frac{di_L}{dt} = L \frac{\Delta i_{Loff}}{T_{off}} \quad (2-2)$$

结合占空比表达式 $D = T_{on} / T$ 可以得到：

$$V_0 = \frac{V_1}{1-D} \quad (2-3)$$

(2) 降压模式

在该模式下， V_0 小于 V_1 ， S_2 处于截止状态，电路如图 2-6 所示。




图 2-6 降压模式电路

当 S_1 处于导通状态时，电路的电流向如图 2-7(a)，存在式 (2-4) 所示的关系。

$$V_1 - V_0 = L \frac{di_L}{dt} = L \frac{\Delta i_{ton}}{T_{on}} \quad (2-4)$$




图 2-7 降压模式电能流向图

当 S_1 关断时，电能流向如图 2-7 (b) 所示，此时电路存在以下关系。

$$-V_0 = L \frac{di_L}{dt} = L \frac{\Delta i_{Loff}}{T_{off}} \quad (2-5)$$

结合占空比表达式 $D = T_{on} / T$ 可以得到：

$$V_o = DV_1 \quad (2-6)$$

2.3 电气化铁路上的储能系统拓扑结构及工作原理




图 2-8 含储能装置的电气化铁路拓扑

本文使用的牵引供电系统结构如图 2-8 所示，SC 通过供电臂接入牵引供电系统中，该系统的 RPC 的直流母线上并联 SC。RPC 装置连接在两供电臂中间，

作用是进行两供电臂之间的功率转移。当两臂负载出现峰值负荷时，超级电容可以放出能量从而避免两臂出现负荷峰值；当两臂出现再生制动能量时，通过控制超级电容充电来达到吸收再生制动能量的目的。

根据拓扑结构图可知，原始牵引负荷功率 $P(t)$ 为治理后的牵引负荷功率 $P_G(t)$ 和 SC 的放电功率 $P_{sc}(t)$ 相加得到。三者平衡表达式如(2-7)所示：

$$P(t)=P_G(t)+P_{sc}(t) \quad (2-7)$$

其中， t 为任意时刻。记 $P_{sc}(t) < 0$ 为储能充电， $P_{sc}(t) > 0$ 为储能放电。

储能装置的剩余能量 $E(t)$ 满足以下关：

$$E(t)=E(t-\Delta t)-P_{sc}(t)\cdot\Delta t \quad (2-8)$$

式中， $\eta = \begin{cases} \eta_c, P_{sc}(t) < 0 \\ \eta_d, P_{sc}(t) > 0 \end{cases}$ ，其中， Δt 为时间间隔长度。

$P_{sc}(t)$ 的约束条件如式（2-9）所示，其中 P_e 为 SC 的额定功率。

$$-P_e \leq P_{sc}(t) \leq P_e \quad (2-9)$$

SC 的荷电状态表达式如（2-10）所示：

$$SOC(t)=\frac{E(t)}{E_e}\times 100\% \quad (2-10)$$

$SOC(t)$ 应满足以下约束条件

$$SOC_{\min} \leq SOC(t) \leq SOC_{\max} \quad (2-11)$$

储能系统的工作状态主要取决于对应时刻的牵引负荷功率，如图 2-9 所示，牵引负荷可以划分为 3 个区间，大于 P_h 的牵引负荷功率被称为峰值负荷，其中 P_h 为削峰线功率，可以由使用优化算法求解系统最优运行经济性而得到^[26,29]。小于 0 的牵引负荷功率为再生制动负荷。介于 P_h 与 0 之间的负荷为常规负荷。根据牵引负荷所属类型不同，可将 SC 分为以下三种状态。

1) 放电削峰状态

当牵引负荷位于峰值负荷区间时，此时牵引负荷的功率较大，因此储能装置会放出能量协助电网给机车供电，以此达到消除电网上的峰值负荷的目的。其工作原理如图 2-10 所示。

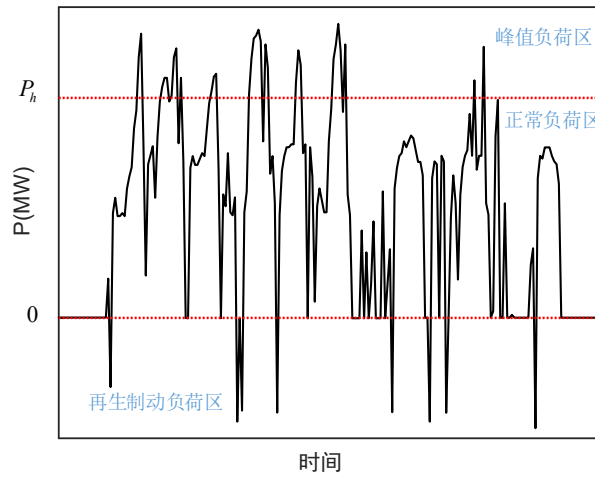


图 2-9 牵引负荷区间划分




图 2-10 削峰放电模式原理图




图 2-11 填谷充电模式原理图

2) 吸收再生制动能量充电状态

当牵引负荷位于再生制动负荷区间时，此时的再生制动能量若不被及时使用利用，不仅会造成能量的浪费，还会注入到电网而影响电网的电能质量。因此储能装置会吸收这部分再生制动能量，等待牵引负荷位于峰值负荷区间时而放出。

其工作原理如图 2-10 所示。

3) 静置状态

当牵引负荷位于正常负荷区间时，储能装置为空闲状态。

2.4 本章小结

本章首先介绍了牵引供电系统的相关结构，并分析得到牵引负荷具有随机波动性强、随机幅值较大的特性。接着介绍了 ESD 运行在不同工况下，双向 DC/DC 变换器的工作状态。最后在含 SC-RPC 的系统拓扑结构图中，分析了系统在对应不同 ESD 工作状态下的能量流向图，为制定双重应用下储能系统控制策略提供了指引。

第3章 基于 DWT-TCN-PSO_SVR 的组合预测模型

3.1 常规预测模型及问题分析

目前牵引负荷预测主要用于牵引供电系统的规划,这对预测结果的精度并要求并不严格,一般采用传统的基于统计学的预测方法。该方法的具体流程图如图 3-1 所示,可以看出,该方法主要存在以下两个问题:

问题 1 是预测工作量很大,影响后续控制的实时性。由图 3-1 可见,该过程可以分为 3 步。步骤 1 是进行特征提取,需要采集大量的列车相关数据,然后提取这些数据的特征,但这一步的数据采集工作量与特征提取的计算量都比较大。步骤 2 是根据提取的特征建立牵引负荷概率模型库,然后提取实测牵引负荷数据特征,这会使得每一次预测都要提取实时数据的特征,使预测所需的时间变得较长,从而会影响后续控制的实时性。

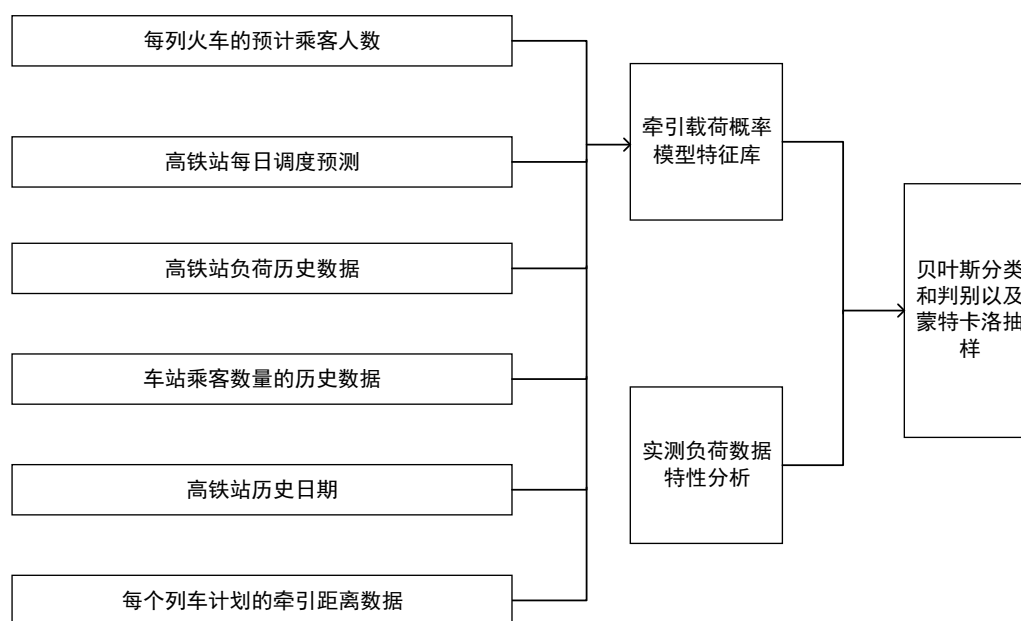


图 3-1 基于统计学的预测方法流程图

问题 2 是预测结果精度不高,影响最终的控制效果。步骤 3 中使用了基于统计学的的数据抽样法,首先在调度控制云平台中确定随机模型,选择模型参数;然后根据随机模型,依次生成相应的估计值,并在所建立的概率分布图中找到每个分段周期内相应的模拟负荷值。最后尽可能多地重复第二个步骤,获得足够多个个高速铁路牵引负载模拟,可以将其转换为目标时间的负载值分布。而牵引负荷在局部上具有随机波动性强,波动频繁且变化幅值大的特点。抽样法往往只能把

握住数据的大致走向，而不能得到精确的预测数据。

3.2 基于 DWT-TCN-PSO_SVR 的组合预测模型

3.2.1 组合预测模型流程

本文设计了一种基于 DWT-TCN-PSO_SVR 的预测方法。针对预测过程中计算量大的问题，本文选用基于机器学习的 TCN 预测模型和 SVR 预测模型。只需将历史负荷数据输入预测模型中，模型会自动对这些输入的数据进行训练和学习，并且根据实测负荷数据也能很快得到预测结果，不需要对实测数据做特征提取工作，保证了后续控制的实时性。也避免了对历史负荷之外的大量数据进行特征提取，极大地减小了预测计算量；针对预测结果精度不高的问题，本文使用 DWT 将波动混杂、难以预测的牵引负荷分解成 3 种波动频率单一、易于预测的子序列，然后根据不同类子序列的特点，选用了 TCN 模型预测低频和中频类子序列，选用 SVR 模型预测高频类子序列。这样就发挥了不同预测模型的优点，使得各个子序列都能得到理想的预测结果。接下来还使用了 PSO 算法对 SVR 模型中的关键参数进行了优化，进一步提升了预测结果的精确性。本文所提方法具体流程如图 3-2 所示，主要可以分为 3 步：




图 3-2 组合预测模型流程图

步骤 1:使用小波分解将牵引负荷分解成低频、中频和高频子序列。首先使用小波分解将波动混杂、难以预测的牵引负荷分解成 6 个波动频率单一、易于预测的子序列。我们将频率最高的两个子序列归为高频类,这类子序列具有随机波动性强、波动频率高的特点,代表了牵引负荷中随机性较强的局部特征;将频率最低的两个子序列归为低频类,这类子序列具有周期性较强、波动性较弱的点,代表了牵引负荷周期性较强的整体变化趋势;将频率居中的两个子序列归为中频类,这类子序列具有一定的周期性,代表了牵引负荷比较具体的变化趋势。接下来便是针对不同类序列分别预测。

步骤 2: 使用 TCN 模型预测低频类和中频类子序列,使用 SVR 模型预测高频类子序列。针对低频和中频子序列,由于 TCN(时间卷积网络)模型中加入了因果卷积和膨胀卷积,使得 TCN 模型在能够处理时序预测任务并拥有一个较大的感受野,能够使用更多的历史信息。并且,在很多序列问题的预测实验中,展现了比大多数的预测方法更加优异的性能。因此,对随机波动性较弱、波动周期性较强的低频和中频子序列使用 TCN 的方法进行预测可以很快地得到非常精确的预测结果;针对高频子序列,由于 SVR(支持向量回归)是基于结构风险最小化准则,数据训练方式是将问题转化为二次凸规划问题,拥有很好的泛化能力,很适用于小样本、非线性强的数据集。因此,对于随机波动性强、波动频率高的高频子序列使用 SVR 的方法进行预测。

步骤 3: 参数优化和结果求和。使用 PSO 算法对此方法中需要优化的参数进行优化,并对各个子序列的预测结果求和,得到最终的牵引负荷预测结果。

通过以上步骤就能充分利用了不同预测模型的优点,得到了更加精确的预测结果。另外,此方法只需将牵引负荷数据输入预测模型就能得到相应的预测结果,这就避免了预测过程中大量的数据采集和特征提取的工作,极大减小了预测的工作量。

3.2.1 离散小波变换 (DWT)

小波变换是一种新型时频分析方法,是傅里叶分析思想方法的拓展,在信号处理方面取得了很好的应用。小波变换通过对母小波进行伸缩、平移构成一个 $L^2(R)$ 标准正交基,使得尺度空间与小波空间相互正交,通过改变尺度的大小,就可以得到原始序列不同时间尺度下的变化特征。

以母小波为基的积分连续小波变换:

$$(W_{\psi} f)(a, b) = |a|^{-\frac{1}{2}} \int f(x) \overline{\psi\left(\frac{x-b}{a}\right)} dx, f(x) \in L^2 R \quad (3-1)$$

其中， a 为尺度因子，表示与频率相关的伸缩， b 为时间平移因子。由于牵引负荷的时间序列是离散的，所以要对连续的小波函数进行离散化处理：

$$(W_{\psi}f)(a,b) = \langle f(t), \psi_{a,b}(t) \rangle \quad (3-2)$$

将 a 、 b 离散化，令 $a = 2^{-j}$ ， $b = 2^{-j}k$ ， $j, k \in Z$ ，可得离散小波变换：

$$(DW_{\psi}f)(j,k) = \langle f(t), \psi_{j,k}(t) \rangle \quad (3-3)$$

其中， $\psi_{j,k}(t) = 2^{\frac{j}{2}} \psi(2^j t - k)$ ， $j, k \in Z$ 。

基于 Meyer 小波函数的启发，Mallat 提出了分辨率分析的概念，从数学分析的角度解释了小波变换的概念，并提出了一种快速计算小波变化的算法。相关公式如下：

信号在小波空间的展开为：

$$f(t) = \sum_{j \in Z} f_{W_j} = \sum_{j \in Z} \sum_{k \in Z} \langle f(t), \psi_{j,k}(t) \rangle \psi_{j,k}(t) \quad (3-4)$$

对公式(3-4)引入多分辨率分析概念可得：

$$f(t) = \sum_{k \in Z} \langle f(t), \phi_{j,k}(t) \rangle + \sum_{j \leq j' < J} \sum_{k \in Z} \langle f(t), \psi_{j',k}(t) \rangle \psi_{j',k}(t) \quad (3-5)$$

之后对其进行 $(J - j)$ 次小波分解，将每次分解的尺度系数和小波系数记为：

$$\begin{cases} c_{j,k} = \langle f, \phi_{j,k} \rangle \\ d_{j,k} = \langle f, \psi_{j,k} \rangle \end{cases} \quad (3-6)$$

可以知道：

$$\phi_{j,k} = \sum_n \langle \phi_{j,k}, \phi_{j+1,n} \rangle \phi_{j+1,n} \quad (3-7)$$

$$\begin{aligned} \langle \phi_{j,k}, \phi_{j+1,n} \rangle &= \frac{2^j}{\sqrt{2}} \int_{-\infty}^{+\infty} \overline{\phi(2^j t - k)} \phi(2^{j+1} t - n) dt \\ &= \frac{1}{\sqrt{2}} \int_{-\infty}^{+\infty} \overline{\phi(t')} \phi(2t' + 2k - n) dt \end{aligned} \quad (3-8)$$

因为

$$h_k = \langle \varphi(t), \varphi(2t-k) \rangle = \frac{2^j}{\sqrt{2}} \int_{-\infty}^{+\infty} \varphi(t) \overline{\varphi(2t-k)} dt \quad (3-9)$$

故

$$\langle \varphi_{j,k}(t), \varphi_{j+1,n}(t) \rangle = \frac{1}{\sqrt{2}} h_{n-2k} \quad (3-10)$$

代入得

$$\varphi_{j,k} = \frac{1}{\sqrt{2}} \sum_n h_{n-2k} \varphi_{j+1,n} = \frac{1}{\sqrt{2}} \sum_{n'} h_{n'} \varphi_{j+1,n'+2k} \quad (3-11)$$

可以很快得到尺度系数:

$$c_{j,k} = \frac{1}{\sqrt{2}} \sum_{n \in \mathbb{Z}} h_n c_{j+1,n+2k} \quad (3-12)$$

相应得到小波系数:

$$d_{j,k} = \frac{1}{\sqrt{2}} \sum_{n \in \mathbb{Z}} g_n c_{j+1,n+2k} \quad (3-13)$$

3.2.2 时间卷积网络 (TCN)

TCN 是一种优秀的基于深度学习的预测方法,它是在 CNN 的结构上改进而来。CNN 普遍运用于图像处理领域,为了让 CNN 在时间序列预测上发挥作用,一些学者结合时序预测的要求和特点,对 CNN 的结构进行了改进,得到了在时序预测上作用效果优秀的 TCN。

相较于 CNN,TCN 主要在以下三个方面做出了改进:

1.使用因果卷积。时序预测要求对 T_n 的预测只能通过 T_n 时刻之前的输入 T_1 到 T_{n-1} 来判别,如图 3-3 所示,因果卷积通过限制卷积窗口滑动可以做到对于给定输入序列 $x_1, \dots, x_t, \dots, x_{t+n}$,预测 $y_1, \dots, y_t, \dots, y_{t+n}$ 。但是在预测 y_t 时,只能使用已经得到的序列 x_1, \dots, x_t ,而不能使用 x_{t+1}, x_{t+2}, \dots 。




图 3-3 因果卷积结构




图 3-4 空洞卷积结构

2.使用空洞卷积。空洞卷积结构如图 3-4 所示,在使用因果卷积时,较大的

感受野是构建长期记忆所必需的,为了增加感受野,隐藏层数量也会相应地增加,过多的隐藏层也会导致计算速度变慢。因此,在因果卷积里注入空洞,以此来增加感受野,降低计算量,使结果更加精确,在因果卷积中注入空洞后的结构如图 3-5 所示。




图 3-5 因果卷积中加入空洞卷积

3.增加残差网络。残差网络是由多个残差模块构成,单个残差模块如图 3-6 所示。残差模块是训练深层网络的有效方法,它可以将下一层提取的特征信息传递给上一层以增加结果的准确率,其结构如图 3-7 所示。

TCN 的主要思想为:将因果卷积和空洞卷积融合为一个标准卷积层,然后与恒等映射一起封装成一个残差模块,多个残差模块的连接形成了深度网络。




图 3-6 残差模块图

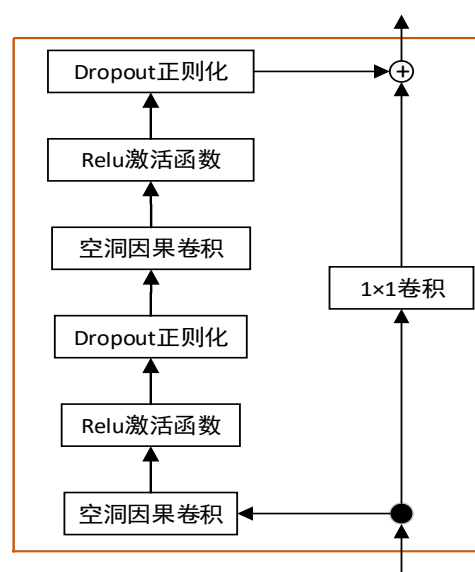


图 3-7 TCN 的标准残差模块

3.2.3 支持向量回归 (SVR)

在 SVM 模型中, 输出函数为-1 或 1, 而在 SVR 中输出函数可以为任意实数。因此, 通过引入不敏感函数 ε , 就可以将分类问题转化为回归问题。如图所示, SVR 的基本思路为: 给定训练样本集 $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$, 使其经过回归模型训练得到输出函数 $f(x)$ 。




图 3-8 ε 不敏感损失带与 SVR 模型

$$f(x) = \langle w, x \rangle + b \quad (3-14)$$

当 $|f(x_i) - y_i| > \varepsilon$ 时, 引入松弛变量 ξ_i, ξ_i^* , 回归问题转化为优化问题:

$$\min_{w, \xi_i, \xi_i^*} \frac{1}{2} \|w\|^2 + C \sum_i^l (\xi_i + \xi_i^*),$$

$$s.t. \begin{cases} y_i - f(x_i) \leq \varepsilon + \xi_i \\ f(x_i) - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, i = 1, 2, \dots, N \end{cases} \quad (3-15)$$

其中, C 为惩罚因子。

为求解式(3-15)的优化问题, 引入拉格朗日函数:

$$L(w, b, \xi, \alpha) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) - \sum_{i=1}^l (n_i \xi_i + n_i^* \xi_i^*) - \sum_{i=1}^l \alpha_i (\varepsilon + \xi_i - y_i + f(x_i)) - \sum_{i=1}^l \alpha_i^* (\varepsilon + \xi_i^* - y_i + f(x_i)) \quad (3-16)$$

根据拉格朗日对偶性可得:

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i \quad (3-17)$$

因此， $f(x) = \langle w, x \rangle + b$ 可以转换为：

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b \quad (3-18)$$

为了将支持向量机分类和回归模型推广到非线性问题中，引入径向基核函数，把低维特征向量映射到高维空间中进行线性拟合。径向基核函数为：

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (3-19)$$

引入核函数变换，回归模型变为：

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) k(x_i, x) + b \quad (3-20)$$

3.3 案例研究

3.3.1 案例介绍与评价指标

本文的实验数据来自于一个牵引供电臂 3 天内的牵引负荷数据的分布。利用第 3.2 节构建的预测模型对其进行预测，展示各部分的预测效果图，并将不同部分的预测结果与实际结果进行比较，证明预测模型设计的合理性。最后，用得到的结果与常用的 LSTM 和 SVR 预测方法的预测结果进行比较。

由于原始数据集包含大量的零数据，不能使用相对误差指标。因此，本文选择了两种不同的绝对误差作为评价指标。平均绝对误差（MAE）和均方根误差（RMSE），分别如式（3-21）和式（3-22）所示^[44,45]。其中 MAE 可以衡量预测结模型的性能，反映出预测结果的精确性，MAE 越低，代表预测模型的性能越高，预测结果的精度也就越高；RMSE 可以衡量预测模型的稳定性，可以反映预测误差的分布均匀情况。RMSE 越低，代表预测模型的稳定性越高，预测结果的误差分布越均匀，不会出现在个别时刻预测误差过大的情况。

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i^* - y_i| \quad (3-21)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i^* - y_i)^2} \quad (3-22)$$

其中, y_i^* 和 y_i 分别代表预测值和真实值, N 代表数据总个数。

3.3.2 模型参数优化

(一) DWT 中母小波函数的选取

DWT 被用来分解牵引负荷序列, 复杂的序列被分解成几个不同频率的子序列。

对于小波函数的选择, 目前还没有公认的、统一的选择原则。本文选择 haar 函数作为小波基函数, 并从原理分析和实验验证两方面进行论证。

本文的目的是将具有无序波动的原始负荷分解成若干个具有单一波动频率的子序列, 以便于后续选择有针对性的预测模型来分别预测这些子序列。对小波基函数的要求主要有两个。

- 1). 由于牵引负荷数据是离散点的组合, 要求小波基函数支持离散小波变换。
- 2). 分解后的子序列需要易于预测, 并能获得更准确的预测结果。根据小波基函数需要满足的两个要求, 本文从以下两个方面进行了选择

①原理分析.

一些常用的母小波函数和它们各自的特征如表 3-1 所示。

表 3-1 不同母小波函数的特征

	Haar	Daubechies	Coiflets	Symlets	Morlet	Mexican Hat
表现形式	haar	db N	Coif N	Sym N	morl	mexh
举例	haar	db3	Coif3	Sym2	morl	mexh
正交性	Yes	Yes	Yes	Yes	No	No
双正交性	Yes	Yes	Yes	Yes	No	No
紧支撑性	Yes	Yes	Yes	Yes	No	No
支撑长度	1	2N-1	6N-1	2N-1	有限长度	有限长度
消失矩阶数	1	N	2N	N	\	\

从表 3-1 可以看出, Morlet 和 Mexican Hat 小波基函数不支持离散小波变换, 所以不在考虑范围之内, 依此类推。其余四个小波基函数 Haar、db N、Coif N 和 Sym N 的主要区别在于支持长度和消失矩阶数不同。理论上, 支持长度越长, 消失矩阶数越高, 分解后的信号就越平滑, 但这也使子序列的负荷峰值更加明显, 而负荷峰值往往是负荷预测工作中出现较大误差的位置。其中, haar 函数的支撑

长度和消失矩阶数最小，分解后的子序列的负荷峰更加平滑，预测结果会更高。因此，本文选择 haar 函数作为小波基础函数。

②实验验证。

本文选择了大多数研究中常用的 haar 函数和 dbN(db3)函数进行验证比较。图 3-9 是 haar 函数的 d3 序列的预测结果，图 3-10 是 db3 函数的 d3 序列的预测结果。可以看出，通过 db3 分解得到的 d3 序列的负荷峰值比较明显，在负载峰值处的预测精度比较低。因此证实了选择 haar 函数作为小波基础函数的合理性。




图 3-9 使用 haar 母小波函数下的 d3 子序列的预测结果




图 3-10 使用 db3 母小波函数下的 d3 子序列的预测结果

(二) DWT 中分解子序列数目

对于分解子序列的数量，本文选择了不同的数值进行预测，预测精度如表 3-2 所示。从表 3-2 的数据可以看出，当子序列数为 6 和 7 时，两个误差指标很小，而且非常接近。这是由于被分解的第六个子序列 a5 的波动性已经很小，其预测

的准确性已经很高。子序列 a5 及其预测结果如图 3-13(a)所示，可以看出，预测值已经极为精确。为了简化预测模型，没有必要对 a5 子序列进行进一步分解。因此，本文共分解为 6 个不同频率的子序列，其结果如图 3-11 所示。

表 3-2 不同子序列分解层数的误差指标

Number of subsequences	MAE	RMSE
3	0.1235	0.2143
4	0.1045	0.1829
5	0.0904	0.1202
6	0.0803	0.1059
7	0.0795	0.0934




图 3-11 使用 DWT 模型对负荷进行分解所得结果

(三) SVR 模型中核函数的选取

在 SVR 模型中，不同参数的选取会对预测结果产生很大的影响，因此我们在构建 SVR 模型时，必须针对参数进行优化选取。参数主要包括核函数、核函数的宽度参数 γ 和惩罚因子 C 等。

核函数是 SVR 模型的核心参数之一，引入核函数，可以将输入空间的非线性问题，通过非线性映射，转化为高维空间的线性问题。目前常见的核函数有以下四种：

①sigmoid 核函数: $K(x_i, x_j) = \tanh(\gamma \langle x_i, x_j \rangle + r)$ 。

②多项式核函数: $K(x_i, x_j) = \tanh(\gamma \langle x_i, x_j \rangle + r)^d$ 。

③线性核函数: $K(x_i, x_j) = \langle x_i, x_j \rangle$ 。

④径向基(RBF)核函数: $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$ 。

其中, d 、 r 、 γ 均是核函数中的重要参数, 目前预测工作中, SVR 核函数选取的理论依据较少。主要根据经验与关键参数个数来选择。从参数个数来看, sigmoid 核函数与多项式核函数均有两个参数, 这会增加预测模型的复杂度; 线性核函数只能处理线性映射, 而径向基核函数可以处理非线性映射。线性核函数也可以看作是径向基核函数的一种特类。牵引负荷数据具有较强的非线性特征, 因此, 在负荷预测工作中, 我们一般将径向基核函数作为首选。

(四) SVR 模型中 C 与 γ 的选取

C 和 γ 的主要作用在于协调统一机器学习风险理论中的经验风险和结构风险, 对模型的预测精度与过拟合能力进行协调配合。选取合适的惩罚因子 C 和宽度参数 γ , 能够提升模型的预测精度与泛化能力。

PSO 算法作为高效、简洁的寻优算法, 在多种场景下均表现出优异的效果。本文使用 PSO 算法对 SVR 模型中的 C 和 γ 进行优化选取。优化算法流程如图 3-12 所示。




图 3-12 SVR 模型参数优化流程图

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/966151004101010034>