

分类号: TH122

密 级: 公开

学校代码: 10363

学 号: 2210120155



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目 塔式烘丝机烟丝干燥质量预测
与工艺参数优化研究

论 文 作 者 巫小燕

校 内 导 师 赵转哲（教授）

校 外 导 师 涂志健（高级工程师）

专业学位类别 机 械

研究方向（领域） 智能制造

论文提交日期: 2024 年 5 月 30 日

分类号：TH122

单位代码：10363

密 级：公开

学 号：2210120155

塔式烘丝机烟丝干燥质量预测与工艺参数优化研究

STUDY ON PREDICTION OF DRYING QUALITY AND
OPTIMIZATION OF PROCESS PARAMETERS OF TOBACCO IN
TOWER DRYER

学生姓名：巫小燕

指导教师：赵转哲（教授）

校外导师：涂志健（高级工程师）

专 业：机 械

研究方向：智能制造

论文答辩日期：2024 年 05 月 24 日

安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已明确注明和引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并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： 亚小燕

日期： 2024 年 05 月 30 日

安徽工程大学学位论文版权使用授权书

学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

本学位论文属于

保 密 ☐，在 ____ 年解密后适用本版权书。

不保密 ☒。

学位论文作者签名： 巫小燕

指导教师签名： 王 强

日期： 2024 年 05 月 30 日

日期： 2024 年 05 月 30 日

塔式烘丝机烟丝干燥质量预测与工艺参数优化研究

摘 要

塔式烘丝机是一种全自动化且封闭式新型气流式干燥设备，具有干燥速度快、生产效率高等优点，逐渐在国内烟草企业中得到了广泛应用。然而，在塔式烘丝机干燥过程中，烟丝干燥工艺参数的设置受主工艺气温、烟丝含水率等因素影响较大。面对复杂多变的烟丝来料特性，仅凭人工经验调控工艺参数很难精确适应现场来料特性的波动变化，无法保证烟丝干燥的出口质量。因此基于工艺参数建立高精度的预测模型，以应对不同来料特性的烟丝进行合理的参数调节，是推动烟草企业提高生产效率、降低生产成本，从而提升企业竞争力的关键。为此，本文的具体研究工作包括如下三点：

（1）选取影响烟丝干燥质量的关键工艺参数与数据预处理。针对影响烟丝干燥质量的关键工艺参数难以选取问题，考虑到烟丝干燥工艺参数具有高耦合性且烟丝干燥特性受多因素影响的原因，结合 Pearson 相关性分析和灰色关联分析共同选取了六个影响烟丝干燥质量的关键工艺参数，为后续烟丝干燥质量预测模型的建立和工艺参数优化研究提供数据支撑。

（2）建立基于改进神经网络的塔式烘丝机烟丝干燥质量预测模型。针对烟丝干燥质量指标难以准确预测问题，首先使用径向基函数神经网络（Radial Basis Function Neural Network, RBFNN）拟合多变量与烟丝出口含水率和温度的关系，获取满足需求的烟丝干燥质量预测模型；其次针对模

型预测精度较低问题，分别利用遗传算法和鹈鹕算法（Pelican Optimization Algorithm, POA）优化 RBF 神经网络的隐含层中心值、宽度以及隐含层到输出层的连接权值，以达到提高模型预测精度的目的；最后，三种模型的预测结果对比显示，基于 POA-RBF 神经网络的烟丝出口含水率模型的预测准确率为 0.9591，相较于另外两个模型更接近于 1 且误差最小，最终优选该模型为后续烟丝干燥质量多目标优化提供较为高精度的数据。

（3）对不同来料特性的烟丝进行工艺参数寻优，以满足不同委托方需求的标准烟丝出口水分和温度值。针对烟丝来料特性变化和不同烟丝干燥标准导致最优烟丝干燥工艺参数组合难以求解问题，提出了两阶段优化方法：一是采用改进 NSGA-II 算法进行烟丝干燥质量多目标优化，得到一组 Pareto 最优解集；二是引用多属性决策方法，得到唯一最优解，以达到获得最优烟丝干燥工艺参数组合的目的。优化结果表明，当烟丝出口含水率和温度目标值分别设定为 12.5% 和 56.0℃ 时，六个关键工艺参数值依次为 18.6%、31.8℃、37500 kg·h⁻¹、167.3℃、390 kg·h⁻¹ 和 164.8℃。所提的两阶段优化方法改善了目前塔式烘丝机烟丝干燥工艺参数的设置优化受个人经验限制的局限性，为精确控制干燥后烟丝含水率及温度、保持出口烟丝品质的稳定性提供了一种新的途径。

关键词：烟丝干燥质量，工艺参数优化，鹈鹕优化算法，RBF 神经网络，改进 NSGA-II 算法

STUDY ON PREDICTION OF DRYING QUALITY AND OPTIMIZATION OF PROCESS PARAMETERS OF TOBACCO IN TOWER DRYER

ABSTRACT

Tower drying machine is a new type of fully automated and closed air drying equipment, which has the advantages of fast drying speed and high production efficiency, and has been widely used in domestic tobacco enterprises. However, in the drying process of the tower drying machine, the setting of drying parameters is greatly affected by the main process temperature and water content of the tobacco. In the face of the complex and changeable characteristics of tobacco, it is difficult to adjust the process parameters by manual experience, and it is impossible to ensure the export quality of dried tobacco. Therefore, the establishment of a high-accuracy prediction model based on process parameters to adjust the parameters of different incoming tobacco is the key to promote tobacco enterprises to improve production efficiency and reduce production costs, so as to enhance their competitiveness. Therefore, the specific research work of this paper includes the following three points:

(1) The key process parameters and data preprocessing which affect the drying quality of cut tobacco were selected. In view of the difficulty in selecting key process parameters that affect the drying quality of cut tobacco, considering

that the drying process parameters of cut tobacco are highly coupled and the drying characteristics of cut tobacco are affected by multiple factors, six key process parameters that affect the drying quality of cut tobacco were selected together with Pearson correlation analysis and grey correlation analysis. It provides data support for the establishment of prediction model of dry quality of tobacco and optimization of process parameters.

(2) A prediction model of tobacco drying quality of tower dryer based on improved neural network was established. Aiming at the difficulty of accurate prediction of dry quality index of cut tobacco, this paper firstly used Radial Basis Function Neural Network (RBFNN) to fit the relationship between multi-variables and cut tobacco outlet moisture content and temperature, and obtained a prediction model of dry quality of cut tobacco that met the requirements. Secondly, to solve the problem of low prediction accuracy of the model, genetic Algorithm and Pelican Optimization Algorithm (POA) were used to optimize the central value and width of the hidden layer and the connection weight from the hidden layer to the output layer of the RBF neural network, so as to improve the prediction accuracy of the model. Finally, the comparison of the prediction results of the three models shows that the prediction accuracy of the tobacco outlet moisture content model based on POA-RBF neural network is 0.9591, which is closer to 1 and has the smallest error compared with the other two models. Finally, the model is selected to provide relatively high-precision data for the subsequent multi-objective optimization of tobacco drying quality.

(3)The process parameters of different incoming tobacco were optimized to meet the requirements of different clients. In order to solve the problem that the combination of optimal tobacco drying parameters is difficult to solve due to the change of raw material characteristics and different drying standards, a two-stage optimization method was proposed in this paper. First, the modified NSGA-II algorithm was used to optimize the drying quality of tobacco, and a set of Pareto optimal solution was obtained. The second is to use the multi-attribute decision method to obtain the unique optimal solution, so as to achieve the purpose of obtaining the optimal combination of tobacco drying process parameters. The optimization results showed that when the target water content and temperature of the cut tobacco outlet were set at 12.5% and 56.0°C respectively, the six key process parameters were 18.6%, 31.8°C, 37500 kg·h⁻¹, 167.3°C, 390 kg·h⁻¹ and 164.8°C respectively. The proposed two-stage optimization method improves the limitation that the setting and optimization of drying parameters in tower dryer is limited by personal experience, and provides a new way to accurately control the moisture content and temperature of dried tobacco and maintain the stability of exported tobacco quality.

KEY WORDS: tobacco export quality, process parameter optimization, pelican optimization algorithm, RBF neural network, improved NSGA-II algorithm

目录

摘 要	I
ABSTRACT	III
第 1 章 绪论	1
1.1 课题来源	1
1.2 研究背景及意义	1
1.3 国内外研究现状	2
1.3.1 烟丝干燥技术及设备研究现状	2
1.3.2 烟丝干燥质量预测研究现状	3
1.3.3 烟丝干燥工艺参数优化研究现状	5
1.4 主要研究内容与技术路线	6
第 2 章 数据预处理与关键工艺参数选取	9
2.1 烟丝干燥过程	9
2.1.1 烟丝干燥过程工艺描述	9
2.1.2 塔式烘丝机设备结构及工艺要求	10
2.2 数据采集	10
2.3 数据预处理	12
2.3.1 数据异常值处理	12
2.3.2 数据降噪处理	13
2.3.3 数据归一化处理	16
2.4 相关性分析选取关键工艺参数	17
2.4.1 Pearson 相关性分析	17
2.4.2 灰色关联分析	18
2.5 本章小结	21
第 3 章 基于改进神经网络的烟丝干燥质量预测	22
3.1 机器学习算法	22
3.1.1 RBF 神经网络算法	22
3.1.2 遗传算法优化 RBF 神经网络	26

3.1.3 鸚鵡算法优化 RBF 神经网络	28
3.2 烟丝干燥质量预测模型	30
3.2.1 基于 RBF 神经网络的烟丝干燥质量预测模型	30
3.2.2 基于 GA-RBF 神经网络的烟丝干燥质量预测模型	32
3.2.3 基于 POA-RBF 的烟丝干燥质量预测模型	33
3.3 烟丝干燥质量预测模型评价	35
3.4 本章小结	37
第 4 章 基于改进 NSGA-II 算法的烟丝干燥质量多目标优化	38
4.1 多目标优化方法	38
4.1.1 多目标优化简介	38
4.1.2 多目标优化流程	38
4.1.3 帕累托最优解集	39
4.2. 改进 NSGA-II 算法	40
4.2.1 NSGA-II 算法	40
4.2.2 改进 NSGA-II 算法	43
4.2.3 改进 NSGA-II 算法性能分析	46
4.3 两阶段优化	49
4.3.1 两阶段优化的框架	49
4.3.2 多属性决策	50
4.4 多目标优化模型的构建	51
4.4.1 选取决策变量	51
4.4.2 目标函数的构造	52
4.4.3 实验结果分析	53
4.5 本章小结	57
第 5 章 GUI 界面设计与实现	58
5.1 系统需求分析	58
5.1.1 总体功能需求分析	58
5.2 系统框架与开发软件介绍	59
5.2.1 系统框架设计	59
5.2.2 开发软件与软件平台	59

5.3 GUI 界面设计	59
5.3.1 用户登录界面	59
5.3.2 系统主界面	60
5.4 本章小结	63
第 6 章 总结与展望	64
6.1 总结	64
6.2 展望	65
参考文献	66
攻读学位期间发表的学术成果目录	72
致谢	73

第 1 章 绪论

1.1 课题来源

课题来源于安徽中烟工业有限责任公司芜湖卷烟厂的企业委托项目——《CTD 过程控制状态一致性机理分析及提升技术研究》。

1.2 研究背景及意义

烟丝干燥工艺作为烟叶制丝流程中的关键环节,对于产出优质烟丝具有不可或缺的作用。这一工序的核心目的在于通过烘丝机的干燥操作后,使烟丝达到预设的出口含水率和温度标准,从而确保烟丝品质符合规范要求^[1]。

合理的烟丝干燥工艺参数设置,不仅能够有效预防烟丝在后续存储过程中发生霉变,还为烟丝的长期保存和醇化提供了必要的条件。然而,经调研发现当前多数卷烟厂在设定烟丝干燥工艺参数时,主要依赖于操作人员的生产经验进行人工调整。由于烟丝干燥过程具有批次性的特点,工厂人员流动性较大且熟练工人数量相对较少。因此,针对来料特性不同的烟丝,工艺参数的调控过程常常会受到主观因素的显著影响,从而导致烟丝干燥质量的稳定性难以得到切实保障。在实际生产过程中,设备操作人员常常基于个人经验来初步设定烟丝干燥工艺参数值。然而,烟丝干燥过程本来就是一个极其复杂且非线性的系统,各因素之间的耦合关系紧密而复杂。即使是那些经验丰富的操作人员应对不同来料特性的烟丝时,也很难仅凭经验精准地调控干燥工艺参数。这种情况下,往往会有部分烟丝因干燥不充分或干燥过度而无法达到出口标准,进而需要进行二次处理,这不仅增加了产品的返工率,还影响了生产效率和成本控制^[2-3]。故在烟丝干燥过程中,面临的一个主要问题就是一致性问题,即烟丝干燥设备的工艺参数设置往往凭借的是人工经验,没有依据,进而导致工艺方案的决策也会存在因人而异的问题,从而无法确定合理准确的方案,这可能会导致烟丝加工质量不统一的现象^[4]。

为此,如果能够将设置参数的经验转为能够量化的指标,针对不同来料特性的烟丝时,使用合适的优化模型自适应地选择最理想的干燥工艺参数,将有助于解决一致性问题,同时对提高烟丝干燥生产的自动化程度、降低人工劳动强度以及提高烟丝干燥生产效率具有重要意义。

1.3 国内外研究现状

1.3.1 烟丝干燥技术及设备研究现状

干燥技术可以依据多种策略进行分类,从而能更全面地理解其应用方式和特点。首先,根据加热方式的不同,干燥技术可分为直接干燥和间接干燥两种类型。其次,依据物料干燥量的不同,可以将其划分为批量干燥和连续干燥。再者,颗粒运动的方式同样影响着干燥技术的分类,如滚筒干燥和流化床干燥等。最后,根据热输入类型的不同,可以将干燥技术分为微波干燥和气流干燥等^[5]。

目前烟草行业普遍采用的烟丝干燥设备包括流化床烘丝机、微波烘丝机、滚筒烘丝机和气流烘丝机等类型^[6-7],如图 1-1 所示^[8],这四种烘丝机在行业中均有广泛应用。其中,流化床烘丝机在干燥过程中可有效提升出口烟丝的填充值,但缺点是不能保证烟丝含水率的均匀性^[9]。微波干燥具有可改善烟丝品质以及较短的干燥时间等优势,但其受限于技术条件,目前难以实现大规模化的连续生产。滚筒烘丝机操作简单,适合连续生产,然而在干燥过程中,烟丝易受到机械力的影响,导致断裂等问题时有发生^[10-11]。相比之下,气流式烘丝机在干燥烟丝时表现出高填充度、高效率以及良好的干燥均匀性等优点^[12-13]。鉴于这些特性,当前烟草行业中使用较多的烟丝干燥装置为气流式烘丝机。




图 1-1 常见烘丝机示意图

1.3.2 烟丝干燥质量预测研究现状

评价烟丝干燥质量的指标一般是烟丝出口含水率和烟丝出口温度^[14]。在国内外学者的研究中,机器学习算法被广泛运用于烟丝干燥质量的预测中。这些算法通过建立控制变量与干燥质量指标之间的预测模型,使我们能够更深入地理解烟丝干燥质量各指标的波动情况。通过该方法,不仅可以评估烟丝干燥设备运行的稳定性,还能为设备操作者提供有力的决策支持。在此基础上,操作者可以根据实际情况灵活调整烟丝干燥工艺参数方案,以实现烟丝干燥设备的智能运行,从而进一步提升烟草行业的生产效率和质量水平。

目前,烟丝干燥设备智能运行中常用的是以下三种机器学习算法。

(1) 支持向量机

支持向量机(Support Vector Machines, SVM)模型^[15]以其独特的优势在烟丝干燥工艺数据处理中发挥着重要作用。该模型对异常值表现出不敏感性,这有助于我们更准确地抓住数据中的关键样本,同时剔除冗余样本,从而优化数据处理效果。此外,SVM模型还展现出较好的鲁棒性和泛化能力,能够在不同的数据集上保持稳定的性能,为烟丝干燥工艺参数的优化提供了有力的支持。魏甲欣^[16]等为提高烟丝结构检测的准确性,基于SVM构建了烟丝组分分类模型,所得模型的分类识别误差小于5%,具有较好的分类效果。谢鹏^[17]等针对气流式烘丝机设备故障预测准确率较低的问题,建立了基于SVM的预测模型,结果表明所提模型具有良好的预测效果。程志颖^[18]等利用粒子群算法(Particle Swarm Optimization, PSO)对最小二乘法支持向量机的核函数进行优化,将其应用于烟丝样品的近红外光谱建模,比较发现所提模型具有更好的预测效果。由此可见,采用支持向量机算法对烟丝干燥质量进行预测,不仅能够有效地拟合烟丝干燥工艺数据,更能精确预测烟丝干燥质量参数。

为了进一步提升模型的预测精度,支持向量机算法在进行烟丝干燥质量预测应用时,可结合遗传算法(Genetic Algorithm, GA)^[19-21]、PSO^[22-24]、迁移学习算法(Transfer Learning)、灰狼优化算法(Grey Wolf Optimizer, GWO)^[25]和海洋捕食者(Marine Predators Algorithm, MPA)^[26]等算法来优化其核函数。

(2) 集成学习

集成学习涵盖了多种算法,包括梯度提升树算法(Gradient Boosting Decision Tree, GBDT)、随机森林算法(Random Forest, RF)以及XGBoost算法等。集成学习算法在处理高维度数据时表现出色,能够有效应对复杂的数据结构,并提取出其中的关键信息,

对于烟丝干燥工艺参数限制性较小且算法的训练速度快,较适用于烟丝干燥系统复杂、耦合的工艺数据。王伟燕^[27]等利用随机森林算法构建烤烟叶片叶绿素含量预测模型,证明了其方法的可行性。卢沛临^[28]等为了选取影响片烟中片率的特征参数,建立了基于 RF 的回归模型,结果表明所提模型能够高效的预测出不同叶梗分离参数下的中片率。陶永峰^[29]等针对当前烟叶质量分析过程中容易出现信息损失的问题,结合 XGBoost 算法和成分特征分析,提出一种烟叶质量分级预测方法,结果表明,该方法具有较好的预测准确性。

综上,集成学习算法在提升烟丝干燥质量预测的准确性方面展现出了显著的优势,有效克服了单一模型存在的局限性。但是,该算法的内部机制相对复杂,需要不断地进行参数的修正操纵,以达到提升模型精度的目的。

(3) 神经网络

神经网络算法的灵感来源于动物神经网络的特征,具有显著的预测精度和广泛的应用领域等优点。鉴于这些特点,我们以现有的历史数据为基础,采用神经网络来训练模型,为解决生活中的复杂问题提供了切实可行的方案^[30-31]。在实际的工业应用领域,常用的神经网络算法有反向传播神经网络 (Back Propagation Neural Network, BPNN)^[32]、径向基函数神经网络 (Radial Basis Function Neural Network, RBFNN)^[33]、卷积神经网络 (Convolutional Neural Network, CNN)^[34]以及人工神经网络 (Artificial Neural Networks, ANN)^[35]等。杨浩等人^[36]为提高烟丝含水率的预测精度,提出了一种变学习率的 BP 神经网络方法,建立烟丝干燥质量预测模型,从而为后续烟丝干燥过程的优化提供了有力支持。为了测定初烤烟叶中的成分组成,许永^[37]等采用一种基于 BP 神经网络的控制方法,通过该方法对主流烟气中成分含量进行了精确预测。卓鸣等人^[38]对深入分析了影响成品烟丝质量的因素,通过构建预测模型来精准预测烟丝质量。针对烟丝干燥过程存在变量耦合度较强等难题,施艳美等人^[39]巧妙地将 BP 神经网络应用于回潮区参数的控制中。通过这一创新性的尝试,他们成功实现了对回潮区参数的精准调控,并取得了显著的效果。尽管 BP 神经网络在烟丝干燥质量预测方面展现出较好的效果,但其仍存在一些固有的局限性。具体来说, BP 神经网络在学习率与稳定性之间可能产生矛盾,这导致在训练过程中容易陷入局部最小值的情况,从而影响算法的性能,限制其在实际应用中的效能。

RBFNN 是一种能够高精度逼近非线性函数的神经网络,因其简单且高效的特性备受国内外学者的关注^[40]。Cheng^[41]等人建立了基于 RBFNN 的卷烟制丝工艺质量控制指

标预测模型,实现了对卷烟制丝最优工艺参数的准确预测,提高了卷烟制丝生产效率。李巧茹^[42]等人为提高短时交通流预测精度,对传统的 RBFNN 拟合参数进行了优化,从而实现了模型性能的有效提升。罗丹萍^[43]为保证烟叶复烤出口质量,提出了一种径向基神经网络融合粒子群优化算法的方法为烟叶复烤生产提供调控参数,研究表明,该方法能够有效地满足对烟叶质量预测的高精度要求。由此可知, RBFNN 具有非线性逼近能力,优化算法具有全局寻优能力,在实际应用中,结合优化算法对 RBFNN 进行参数优化,进而用于进行工艺参数预测,往往能够取得令人满意的预测效果。

综上所述,烟丝干燥质量预测对后续烟丝干燥工艺参数优化有着十分重要的作用,所以寻找到一种快速且准确的烟丝干燥质量预测算法是非常重要的。在现有的烟丝干燥预测算法中,神经网络预测法由于可以通过对样本的学习进行自动调节,从而相较于支持向量机和集成学习算法而言,具有更高的预测准确率和更快的运算速率。

1.3.3 烟丝干燥工艺参数优化研究现状

烟丝干燥过程是卷烟制丝最为关键的工序,需要通过优化工艺参数来达到满足不同委托方对来料特性不同烟丝的出口水分和温度值的要求。近年来,智能优化算法的研究层出不穷,在工程领域发挥着举足轻重的作用^[44]。在参数的组合优化中,智能优化算法能够轻松解决传统方法难以应对的复杂问题,特别是在处理典型的优化问题时,这些算法往往能够取得令人满意的效果^[45-46]。对于生活中常见的带有约束条件的多目标优化问题,智能优化算法同样表现出色,为解决这类问题提供了有效的途径^[47]。

当前,众多研究致力于在限制约束条件下探寻最理想的工艺参数方案,以达到满足产品质量的特定需求^[48-50]。在解决单目标优化问题时,常用的智能优化算法包括差分进化算法(Differential Evolution, DE)^[51]、GA^[52]以及 PSO^[53]等。张刘渲楠等^[54-56]针对传统参数优化方法无法考虑烘丝机全局工艺参数问题,提出了基于数据驱动的烘丝机工艺参数优化方法,实现了对干燥过程烟丝出口含水率的精确控制。

此外,在工程研究领域还存在着大量的多目标优化问题。与传统的单目标优化问题不同的是,多目标优化问题的最优解是由 Pareto 最优解集构成的^[57-60]。多目标优化算法起源于国外,主要分为两类:第一类为基于分解的多目标进化算法(Multi-objective Evolutionary Optimization, MOEA)。肖世隆等^[61]结合进化算法与数学规划方法,提出了一种基于分解的多目标进化算法。Zhang B 等^[62]为设计绿色调度问题的节能程序,提出了一种基于分解的多目标离散人工蜂群算法。Wan X 等^[63]针对动态重叠社区检测问题进行了深入的研究,采用了基于分解的多目标进化算法作为主要的优化工具。在这一过程

中，他们还巧妙地引入了动态优化技术和资源分配策略，以增强算法对动态环境变化的适应能力。通过这些方法，他们成功地获得了均匀分布的 Pareto 解集，为动态重叠社区检测问题提供了一种有效的解决方案。第二类为基于分配关系的多目标进化算法。该类中应用最为广泛的为 Deb 等^[64]在 2002 年提出的一种带有快速非支配排序和精英机制的多目标遗传算法（Non-dominated Sorting Genetic Algorithm II, NSGA-II）。高崇等^[65]着眼于配电网规划问题，将经济性和可靠性确立为优化的两个核心目标。基于这样的设定，他们提出了一个创新的交直流配电网规划模型，该模型以 NSGA-II 算法为基础，旨在实现配电网的经济高效与稳定可靠，为了验证所提模型的有效性，他们进一步通过具体算例进行了详尽的分析和验证，结果表明该模型在实际应用中具备显著的优化效果。周永长^[66]为优化润叶工艺方案，提出了改进的多目标优化算法，为后续复烤厂优化工艺流程、改良设备参数提供了重要的依据。在满足烟丝干燥质量要求的前提下，王浩^[67]进一步从成本的角度出发，对工艺参数方案进行了深入的探讨，运用多目标人工蜂群算法对工艺参数方案进行优化，旨在寻找出最合理的工艺方案。

上述研究均借助神经网络方法成功构建了工艺参数与产品质量之间的复杂映射关系。在此基础上，研究进一步采用了智能优化算法与预测模型相结合的策略，对目标函数进行了精准求解。此类方法不仅有效解决了复杂工艺机理模型难以建立的问题，而且为工业生产中的参数优化和质量控制提供了有力的技术支持。通过充分利用历史数据和先进的算法技术，这些研究为提升产品质量和工艺效率开辟了新的途径。

在当前烟丝干燥工艺中，由于不同客户对加工标准有着不同的需求，使得满足多样化烟丝出口需求标准成为一项挑战。尤其面对烟叶的动态来料特性变化，如何提出一种可持续性的解决方案成为了亟待解决的问题。

1.4 主要研究内容与技术路线

本文的主要研究内容是针对烟叶的动态来料特性，提出能够实现自适应推荐最佳工艺参数方案的方法。论文共分为 6 章，各章节研究内容安排如下，实施的技术路线如图 1-2 所示。

第 1 章详细介绍了课题的来源以及烟丝干燥过程的研究背景和研究意义，对国内外研究现状进行了分析和总结，通过对比不同研究方法的优劣，指出了当前研究中存在的不足之处。




图 1-2 论文的技术路线

第 2 章针对塔式烘丝机烟丝干燥工艺参数难以准确选取问题，结合 Pearson 相关性和灰色关联分析共同选取了影响烟丝干燥质量的关键工艺参数，从而降低后续神经网络的计算复杂度。

第 3 章针对塔式烘丝机烟丝干燥质量指标难以准确预测问题，分别利用遗传算法和鸸鹋算法优化 RBF 神经网络的隐含层中心值、宽度以及隐含层到输出层的连接权值，以达到提高模型预测精度的目的，实验结果表明，提出的基于 POA-RBF 神经网络的烟丝干燥质量模型有较高的预测精度。

第 4 章针对烟丝来料特性变化和不同烟丝干燥标准导致最优烟丝干燥工艺参数组合难以求解问题，本文以安徽省某烟厂的历史数据为基础，烟丝干燥质量预测与期望的差值作为优化目标，提出了两阶段优化方法：一是采用改进 NSGA-II 算法进行烟丝干燥质量多目标优化，得到一组 Pareto 最优解集；二是引用 FCM-GRP 相结合的多属性决策方法，得到唯一最优解，以达到获得最优烟丝干燥工艺参数组合的目的。

第 5 章对塔式烘丝机烟丝干燥质量预测和工艺参数优化系统进行了全面的开发，详细介绍了系统用到的硬件、软件以及技术架构；在深入分析了用户需求的基础上，设计了系统的功能模块和操作流程，确保系统能够满足用户的实际需求；对开发流程和结果进行了详尽的展示，以展现系统的完整性和实用性，最终实现了系统的相关功能。

第 6 章对全文的核心工作内容与取得的研究成果进行了全面而深入的总结，并针对论文中存在的不足之处进行了分析与反思，对后续将要展开的工作做出规划与展望。

第2章 数据预处理与关键工艺参数选取

在实际的烟丝干燥过程中,大量的历史生产数据信息不仅反映了企业采用的烘丝生产方式,更为烟丝干燥工艺参数的优化分析提供了丰富且有效的信息。数据预处理在将这些数字记录信息转化为有价值的生产信息过程中发挥了至关重要的作用。从后台系统获得的单纯的数字记录信息到有价值生产信息,数据预处理发挥了重要作用,经过预处理后的数据可对后续工艺参数优化过程提供具有针对性的基础数据,为优化工作提供坚实的数据支撑。

2.1 烟丝干燥过程

卷烟生产主要包括以下四个工序:(1)烟叶初烤,将收集到的成熟烟叶进行初步烤制,降低烟叶水分,使其最终呈现干焦状态。(2)打叶复烤,将叶、梗分离并进行二次水分调节,主要作用是防止烟叶霉变和利于后续储存。(3)烟叶配方,主要作用是改善烟叶的色泽和气味。(4)卷烟制丝,首先对烟叶进行切丝,然后进行水分回潮、处方配比、润叶处理以及烟丝干燥等制丝步骤。其主要目的是使烟丝出口质量(出口烟丝含水率和温度)满足生产要求,以进入下一步烟支卷制阶段^[68]。其流程如图 2-1 所示。



图 2-1 卷烟生产工序流程

2.1.1 烟丝干燥过程工艺描述

卷烟制丝工序,作为卷烟生产流程中的核心环节,发挥着至关重要的作用。它不仅是确保出口烟丝品质稳定的关键步骤,更是通过精确调控使得烟丝的出口含水率和温度均达到工艺规定的标准。此外,卷烟制丝工序还致力于保证出口烟丝具备理想的填充值和柔韧性,以满足卷烟生产的实际需求。在这一工序中,塔式烘丝机扮演着重要的角色,它的核心任务是通过高效且精确的烘干处理,确保出口烟丝质量符合后续卷烟生产要求。

塔式烘丝机烟丝干燥过程如图 2-2 所示,它主要由进料口的高频振槽、膨胀节、干燥塔身、切向落料器、燃烧炉以及主工艺风机等结构组成。物料首先经高频振槽进入膨胀节,经膨胀操作后进入干燥塔,然后再将干燥后的烟丝输送至气料分离器,物料随之从出料口处落下,最后热工艺气受离心式风机的影响,部分被排出设备,另外部分则重

新进入燃烧炉中，由此构成了一个烟丝干燥循环过程^[17]。




图 2-2 烟丝气流干燥过程原理图

2.1.2 塔式烘丝机设备结构及工艺要求

塔式烘丝机输送带和塔身的实物图如所图 2-3 所示。



图 2-3 塔式烘丝机实物图

烟丝干燥方式是由干燥塔内热风接触烟丝并对其进行加热处理，目的是使得烟丝出口质量满足某牌名卷烟生产工艺要求（一般控制烟丝出口含水率在 12.0%–14.0%范围内的某一特定值，烟丝出口温度在 55℃–75℃范围内的某一特定值），同时烟丝干燥过程还需提高烟丝的填充值，进而保证后续烟丝卷制为成品烟支的品质。

2.2 数据采集

塔式烘丝机烟丝干燥过程是一个极其复杂且精细的工艺过程，为确保数据采集的精准度，在烟丝干燥生产的各个测控点布置了相应的传感器，以实现数据的实时采集。部分现场采集点的布置情况如图 2-4 所示。这些实时采集的数据不仅为我们提供了丰富

的信息资源，更为烟丝干燥生产的自动参数调试提供了坚实的理论依据。



(a) 烟丝入口水分



(b) 烟丝出口水分

图 2-4 采集点分布

本文使用的数据是来自安徽省某烟厂 2023 年 10 月 10 日某一牌名烟支第 2 批次从监测设备中读取到的 1200 条数据，采样频率为 6s/次。塔式烘丝机烟丝干燥工艺过程中的各项参数如表 2-1 所示。

表 2-1 塔式烘丝机烟丝干燥工艺参数

代号	含义
A	烟丝入口水分/(%)
B	烟丝入口温度/(°C)
C	烟丝入口流量/(kg·h ⁻¹)
D	主工艺气质量流量/(kg·h ⁻¹)
E	主工艺气温度/(°C)
F	主风机转速/(r·min ⁻¹)
G	膨胀节风机转速/(r·min ⁻¹)
H	膨胀节工艺气质量流量(kg·h ⁻¹)
I	膨胀节工艺气体积流量(m ³ ·h ⁻¹)
J	膨胀节工艺气温度/(°C)
K	工艺蒸汽质量流量/(kg·h ⁻¹)
L	工艺蒸汽温度/(°C)
M	环境温度/(°C)
N	环境湿度/(%)

续表 2-1 塔式烘丝机烟丝干燥工艺参数

代号	含义
O	烟丝出口含水率/(%)
P	烟丝出口温度/(°C)

2.3 数据预处理

在实际塔式烘丝机烟丝干燥生产过程中,为了确保烟丝达到预期的干燥质量,需要提前对烘丝机实施预热处理。然而,当烟叶进入烘丝机的初期阶段,由于各种因素的作用,入口流量往往会出现不稳定的现象。此时传感器仍在持续采集数据,但这些数据实际上反映了非正常工作状态,因此其对于烟丝干燥质量的预测并无实际帮助。为了提升后续算法的准确性和可靠性,我们必须对采集到的数据进行异常值处理与降噪处理。这些非正常数据通常表现为偏离烘丝机正常工作状态的极值、缺失值等。此外,为了进一步增强算法的鲁棒性,还需对数据进行标准化处理,确保数据在统一的尺度上进行运算。

2.3.1 数据异常值处理

在烟丝干燥过程中,数据集中可能会出现偏离正常工作状态的值,这些值被称为异常值。为了提升数据的质量和可靠性,有必要对这些异常值进行专门的检测和处理。具体而言,烟丝干燥过程中可能存在异常值情况主要包括恒值异常和极值异常。

(1) 恒值异常

在烟丝干燥过程中,塔式烘丝机设备有时难免会遇到系统故障等问题。一旦这类情况发生,往往会导致采集到的数据出现偏差,特别是当大部分数据值显示为 0 时,就需要删除该条数据记录。

(2) 极值异常

在实际的烟丝干燥生产过程中,确保烟丝干燥质量处于适当的范围内是至关重要的。如本文选取的该系列烟丝干燥后的含水率应控制在 12.0%至 13.0%之间,温度则在 55°C至 70°C的范围内,以确保满足加工标准。若存在不符合这一标准的工艺参数值,则应予以删除。如图 2-5 所示,烟丝出口含水率和温度历史数据清晰地展示了部分不符合烟叶加工标准的值。针对这些不符合烟丝干燥标准范围的数据,采取删除处理的方式。同样的原则也适用于其他影响烟丝干燥质量的工艺参数,如烟丝入口流量、烟丝入口水分、主工艺气温度等。对于这些参数,我们也采用相同的方法进行处理,以确保数据的准确性和有效性,为后续的工艺优化和质量提升提供可靠依据。




图 2-5 烟丝干燥质量点线图

2.3.2 数据降噪处理

在烟丝干燥工艺数据的采集过程中,由于环境等多种因素的干扰,数据中常常会出现高低频噪声异常干扰的现象,这种现象的存在严重影响了数据的准确性和可靠性,因此,对采集的数据进行降噪处理显得尤为重要。传统的傅里叶变换在处理这种多噪声类型的数据时往往力不从心,难以取得理想的效果。为了更有效地消除烟丝干燥工艺数据中的异常干扰,选择采用小波降噪的方法^[69]。这种方法不仅具有较强的数据滤波能力,能够在很大程度上消除噪声的干扰,同时还能够较好地保持原有数据的特征,从而确保数据的完整性和真实性。小波变换的表达式如下。

$$W_f(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} X(t) \psi\left(\frac{t-b}{a}\right) dt \quad (2-1)$$

其中:伸缩因子用 a 表示;小波基函数表示为 $\psi(x)$; b 则为尺度因子。

小波逆变换如公式 (2-2) 所示。

$$f(t) = \frac{1}{c_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{1}{a^2} W_f(a,b) \psi\left(\frac{t-b}{a}\right) da db \quad (2-2)$$

式中, c_ψ 为小波因子。

小波降噪中常见的有硬阈值和软阈值两种处理方式,两者各有优势。两种阈值处理方法的公式如下^[70]。

硬阈值法:


$$\eta_H(\omega, \lambda) = \begin{cases} \omega, & |\omega| \geq \lambda \\ 0, & |\omega| < \lambda \end{cases} \quad (2-3)$$

软阈值法:


$$\eta_H(\omega, \lambda) = \begin{cases} \text{sgn}(\omega)(|\omega| - \lambda), & |\omega| \geq \lambda \\ 0, & |\omega| < \lambda \end{cases} \quad (2-4)$$

式中, η_H 为小波系数; ω 为小波分解系数, λ 为阈值。


在进行塔式烘丝机烟丝干燥工艺数据的降噪处理时,采用小波降噪的方法并选取了硬阈值处理方式。如图 2-6 所示,通过对比降噪前后的数据,可以明显观察到,小波降噪不仅有效地降低了噪声干扰,还最大程度的保留了原始数据的特征。此外,在实际应用中,该方法展现出了较短的处理时间,确保了数据处理的高效性。




(a) 烟丝入口水分




(b) 烟丝入口温度




(c) 烟丝入口流量




(d) 主风机转速




(e) 主工艺气质量流量




(f) 主工艺气温度




(g) 膨胀节风机转速



(h) 膨胀节工艺气质量流量



(i) 膨胀节工艺气流量



(j) 膨胀节工艺气温度




图 2-6 小波降噪前后烟丝干燥数据对比图

2.3.3 数据归一化处理

在分析不同指标时,结果可能由于指标间存在量纲和数量级上的显著差异而产生较大的误差。为了避免这种情况,确保分析的准确性,有必要对数据进行标准化处理。两种常用的标准化处理方式如下:

(1) Min-Max 标准化(即离差标准化)

Min-Max 标准化是通过线性变换手段对原始数据进行处理, 目的是将结果映射到 [0,1]之间。

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (2-5)$$

其中, x'_i 为 Min-Max 标准化后数据; $x_{\min}$ 是原始数据中的最小值; $x_{\max}$ 则是最大值。

(2) Z-score 标准化 (即标准差标准化)

当数据的最值未知或者出现离群值时, 便可用该方法进行标准化处理。公式如下:

$$x'_i = \frac{x_i - \mu}{\sigma} \quad (2-6)$$

其中, x'_i 表示 Z-score 标准化后数据; x_i 是原始数据; σ 则是原始数据的标准差; μ 是原始数据的均值。

基于采集的烟丝干燥工艺数据特征, 本文选用第一种方式对数据进行标准化处理。

当聚类算法结束或模型处理完毕后, 需使用反归一化处理将数据还原成原始数量级与量纲, 其公式如下:

$$x_i = x'_i (x_{\max} - x_{\min}) + x_{\min} \quad (2-7)$$

2.4 相关性分析选取关键工艺参数

塔式烘丝机烟丝干燥过程受高维工艺参数影响, 因此, 有必要提前研究工艺参数与烟丝干燥质量(烟丝出口含水率和温度)之间的关联性大小, 从而有效选取出影响烟丝干燥质量的关键工艺参数, 这对于降低后续神经网络的计算复杂度具有重要意义。

在进行相关性分析时, 可以运用多种方法来探究不同变量之间的关系。常用的相关性分析方法包括 Pearson 相关系数法、灰色关联分析以及 Spearman 相关系数法等。在本次研究中, 针对塔式烘丝机烟丝干燥的实际数据进行了深入分析, 最终结合 Pearson 相关系数法和灰色关联度方法对烟丝干燥数据进行相关性分析, 选取与烟丝干燥质量相关性较高的工艺参数。

2.4.1 Pearson 相关性分析

Pearson 相关系数法是相关性分析理论中的最常用的分析方法, 其计算公式如下:

$$r = \frac{N \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{N \sum x_i^2 - (\sum x_i)^2} \sqrt{N \sum y_i^2 - (\sum y_i)^2}} \quad (2-8)$$

其中, r 表示相关系数; N 为总样本数; x_i 和 y_i 为两个样本集合。

对塔式烘丝机烟丝干燥各项工艺参数进行 Pearson 相关性分析, 结果如图 2-7 所示。




图 2-7 烟丝干燥质量与各工艺参数 Pearson 相关性分析

由图 2-7 可知, 烟丝出口含水率与烟丝入口水分、烟丝入口温度、主工艺气质量流量、主工艺气温度、主风机转速、膨胀节风机转速、膨胀节工艺气质量流量、膨胀节工艺气体积流量、工艺蒸汽质量流量以及工艺蒸汽温度具有较高的相关性, 其相关系数绝对值均高于 0.8。烟丝出口温度与烟丝入口水分、烟丝入口温度、烟丝入口流量、主工艺气质量流量、主工艺气温度、工艺蒸汽质量流量以及工艺蒸汽温度具有较高的相关性, 其相关系数绝对值均高于 0.8。

因此, 通过对烟丝干燥各过程参数与烟丝干燥质量指标的 Pearson 相关性分析结果, 选取相关系数绝对值均大于 0.8 的工艺参数, 分别是烟丝入口水分、烟丝入口温度、主工艺气质量流量、主工艺气温度、工艺蒸汽质量流量以及工艺蒸汽温度, 初步将这些优选参数作为烟丝干燥质量预测模型的输入变量。

2.4.2 灰色关联分析

灰色关联分析, 作为灰色系统理论中的一项重要分析方法, 被广泛应用于度量复杂

系统中参考序列与比较序列间的关联性强度^[71]。在烟丝干燥工艺的实际操作中，各类工艺变量与烟丝干燥质量之间的相互作用是极为复杂且充满不确定性的。鉴于此，我们完全有理由将烟丝干燥过程视为一个典型的灰色系统。其中，工艺参数之间的关联程度并非一目了然，而是需要通过灰色关联分析等方法进行深入探究，以揭示其内在的关联机制，进而为优化烟丝干燥工艺提供有力的理论支持。灰色关联分析过程如下：

(1) 建立决策矩阵

在烟丝干燥过程中，参考序列为烟丝干燥质量指标（即烟丝出口含水率和温度），比较序列为不同的烟丝干燥工艺参数。其中，烟丝干燥质量指标集为 $X_0 = (M_a(1), M_a(2), \dots, M_a(n))^T$ ，工艺参数集为 $X = (X_1, X_2, \dots, X_n)$ 。初始决策矩阵如下所示：

$$Y = [y_{ij}] = \begin{bmatrix} \cdot & M_1 & \cdots & M_m \\ Q_1 & y_{11} & \cdots & y_{1m} \\ \vdots & \vdots & \vdots & \vdots \\ Q_n & y_{n1} & \cdots & y_{nm} \end{bmatrix} \quad (2-9)$$

(2) 计算灰色关联系数

灰色关联系数是用于衡量参考序列与比较序列之间关联程度大小的重要指标。其计算公式如下：

$$\xi_i(k) = \frac{\min_i \min_k |X_0(k) - X_i(k)| + \delta \max_i \max_k |X_0(k) - X_i(k)|}{|X_0(k) - X_i(k)| + \delta \max_i \max_k |X_0(k) - X_i(k)|} \quad (2-10)$$

(3) 计算综合评价度

假设塔式烘丝机干燥后烟丝出口含水率和温度对烟丝干燥的质量同等重要，因此，综合评价度定义如下：

$$\gamma_i = \frac{1}{m} \sum_{i=1}^m \xi_i(k) \quad m = 1, 2 \quad (2-11)$$

基于上述灰色关联系数的计算公式，得到的灰色关联度结果如表 2-2 和图 2-8 所示。

表 2-2 工艺参数灰色关联系数表

代号	工艺参数	关联系数
A	烟丝入口水分	0.90
B	烟丝入口温度	0.94
C	烟丝入口流量	0.71

续表 2-2 工艺参数灰色关联系数表

代号	工艺参数	关联系数
D	主工艺气质量流量	0.88
E	主工艺气温度	0.92
F	主风机转速	0.81
G	膨胀节风机转速	0.82
H	膨胀节工艺气质量流量	0.79
I	膨胀节工艺气体积流量	0.80
J	膨胀节工艺气温度	0.38
K	工艺蒸汽质量流量	0.91
L	工艺蒸汽温度	0.89
M	环境温度	0.58
N	环境湿度	0.46




图 2-8 烟丝干燥质量与各工艺参数灰色关联度图

通过观察表 2-2 和图 2-8 中烟丝干燥质量（烟丝出口含水率和温度）与各工艺参数之间的灰色关联度值，可以发现烟丝入口水分、烟丝入口温度、主工艺气质量流量、主工艺气温度、工艺蒸汽质量流量以及工艺蒸汽温度等参数与烟丝干燥质量之间的灰色关

联度值较高。经过比较,利用灰色关联分析优选出的关键工艺参数与上文通过 Pearson 相关性分析法所筛选出的参数呈现出高度的相似性。

根据以上分析,可获得影响塔式烘丝机烟丝干燥质量的六个关键工艺参数分别为烟丝入口水分、烟丝入口温度、主工艺气质量流量、主工艺气温度、工艺蒸汽质量流量以及工艺蒸汽温度。

2.5 本章小结

本章首先对塔式烘丝机烟丝干燥工艺流程进行了全面的描述,其次,对采集的安徽省某烟厂塔式烘丝机烟丝干燥生产的历史数据进行异常值处理和降噪处理。鉴于烟丝干燥工艺参数的高维性和高耦合性特点,本文综合运用 Pearson 相关性分析和灰色关联分析结果共同选取了烟丝入口水分、烟丝入口温度、主工艺气质量流量、主工艺气温度、工艺蒸汽质量流量以及工艺蒸汽温度六个影响烟丝干燥质量的关键工艺参数,为后续烟丝干燥质量预测模型的建立和工艺参数优化模型的建立提供数据支撑。

第3章 基于改进神经网络的烟丝干燥质量预测

烟丝出口含水率与温度，作为评价塔式烘丝机烟丝干燥质量的核心指标，其精确预测对于提升干燥效率、缩减生产成本以及优化干燥工艺参数至关重要。然而，目前对于烟丝干燥质量的预测缺乏对现场实际工艺数据的深入应用。实际上，烟丝干燥工艺过程中产生的数据蕴藏着丰富的设备运行信息以及物料温度流量等关键数据。深入挖掘这些数据，可以揭示各参数之间的内在联系和映射关系，对于建立更加精准、智能的预测模型具有重大意义。因此，本章提出一种基于改进 RBF 神经网络的塔式烘丝机烟丝干燥质量智能预测模型，这一模型能够充分利用历史烟丝干燥工艺数据，对烟丝干燥工艺参数的实时优化提供有力指导，从而进一步提升烟丝干燥过程的智能化水平。

3.1 机器学习算法

烟丝干燥质量预测，其本质在于以塔式烘丝机烟丝干燥过程中的关键工艺参数为自变量，而烟丝出口含水率及温度作为因变量，通过深入研究和筛选合适的算法，进而确立两者之间的精确映射关系。这一过程旨在最终构建一个高效且精准的烟丝干燥质量预测模型。为了提高烟丝出口含水率及温度的预测精度，本文利用机器学习算法结合塔式烘丝机烟丝干燥特点建立符合该设备的烟丝出口含水率及温度预测模型。在广泛调研了机器学习领域的多种预测算法后，选择 RBF 神经网络算法为基础建立烟丝干燥质量预测模型，将有效实现塔式烘丝机烟丝出口含水率及温度的精确预测。

3.1.1 RBF 神经网络算法

RBF 神经网络是在 1985 年由著名的 Powell 教授所提出的，在随后的数年里，经过学者们的不断研究与改进，逐渐发展出了一套相对完善的 RBF 神经网络体系。这种神经网络以其独特的三层简单结构在前馈型神经网络中脱颖而出。具体而言，其第一层为输入层，该层的输入节点数量取决于我们需要处理的输入变量的数量；紧接着是中间层，称之为隐含层，这一层主要由径向基函数构成，其功能是进行数据的非线性转换；而最后一层，即输出层，则是对输入数据进行响应并输出结果的关键层。

由于 RBF 神经网络具有结构简单、泛化能力强以及在处理复杂问题时展现出的强大非线性逼近能力，它在机器学习领域得到了广泛的应用。相较于另一种广泛使用的 BP 神经网络，RBF 神经网络在某些方面展现出了较大的优势，两种神经网络的性能对比如表 3-1 所示。

表 3-1 RBF 神经网络与 BP 神经网络性能对比

性能指标	BPNN	RBFNN
网络结构	网络结构之间的连接形式是权重连接，一旦网络结构确定将不能随意改变	网络结构只有三层，可根据实际需要，在模型训练阶段自主调整隐含层单元，直到满足需求
收敛速度	拓扑结构的复杂性较高，计算过程中收敛速度相对较慢	拓扑结构较为简单，在计算过程中收敛速度较快
利用率	解决实际问题时具有一定的局限性，利用率较低	可以根据不同问题的需求，自主调节神经元与节点个数，利用率较高

由表 3-1 可知，RBF 神经网络相较于 BP 神经网络，在某些方面展现出独特的优势。基于本文的实际需求，选择了 RBF 神经网络作为智能预测烟丝干燥质量的工具。图 3-1 展示了 RBF 神经网络的具体结构。主要包含以下内容：




图 3-1 RBF 神经网络的拓扑结构

(1) 确定径向基函数

径向基函数在 RBF 神经网络结构中有着至关重要的作用，因此，合理选择径向基函数十分重要，常用的径向基函数如下所示^[72-73]。

高斯函数：

$$g(x_k - c_i) = \exp\left(-\frac{1}{2\sigma_i^2} \|x_k - c_i\|^2\right) \quad (3-1)$$

反常 S 型函数：

$$R_k(x) = \frac{1}{1 + \exp\left(\frac{\|x_k - c_i\|^2}{\sigma_i^2}\right)} \quad (3-2)$$

逆多二次函数：

$$R_k(x) = \frac{1}{\sqrt{\|x_k - c_i\|^2 + \sigma_i^2}} \quad (3-3)$$

其中， x_k 为空间中随机一点； c_i 为一个中心点。

根据上式，本文 RBF 神经网络隐含层的径向基函数选用运用最为广泛的高斯函数，输出结果如式（3-4）所示。

$$Y_j = \sum_{i=1}^{\tau} \omega_{ij} \exp\left(-\frac{1}{2\sigma^2} \|x_k - c_i\|^2\right) \quad (3-4)$$

其中， c_i 表示隐含层第 i 个节点的中心； ω_{ij} 表示隐含层到输出层的连接权值。

（2）关键参数的确定

在 RBF 神经网络模型中，隐含层中心值 c_i 、宽度 σ 以及隐含层到输出层的连接权值 ω_{ij} 这三个参数对于神经网络的性能具有显著影响。三者中，隐含层中心的选取尤为关键，它直接关系到神经网络的整体性能。针对隐含层中心的确定，已经发展出多种有效的方法，主要有以下几种：

1) 随机选取中心法

在输入向量中随机选取隐含层的中心，通过这种方法选取的中心一般不会改变。但是，当原始数据中存在噪声或缺失值时，中心的选取过程可能变得复杂且容易出错。

2) 有监督选取中心

在优化 RBF 神经网络模型的过程中，采用梯度下降法来持续校正隐含层的中心，直至选择出符合特定要求的隐含层中心。这一优化过程本质上是非线性的，旨在通过迭代调整来提升神经网络的性能。现假设在计算过程中，输出层仅包含一个输出变量，隐含层的基函数选择高斯函数，具体计算公式如下，

$$S = \frac{1}{2} \sum_{n=1}^N e_n^2 \quad (3-5)$$

$$e_n = Y_n - y(x_n) \quad (3-6)$$

$$y(x_n) = \sum_{i=1}^{\tau} \omega_i \exp\left(-\frac{1}{2\sigma^2} \|x_n - c_i\|^2\right) \quad (3-7)$$

其中： $y(x_n)$ 表示神经网络的输出值； Y_n 为真实值， e_n 表示 $y(x_n)$ 和 Y_n 之间的差值；。

同时利用梯度下降法计算部分参数的值，公式如下：

$$\begin{cases} \frac{\partial S}{\partial e} = \sum_{n=1}^N e_n \\ \frac{\partial e}{\partial y} = -1 \end{cases} \quad (3-8)$$

由上式可得：

$$\frac{\partial S}{\partial y} = \frac{\partial S}{\partial e} \cdot \frac{\partial e}{\partial y} = -\sum_{n=1}^N e_n \quad (3-9)$$

采用这种方法可以对参数进行持续性的调整，但该过程较为复杂，可能会导致学习效率和时间成本相对较高。

3) 自组织法

自组织法主要包含自组织学习和监督学习两大核心内容。具体而言，自组织学习的核心目标是确定隐含层的中心值和宽度，监督学习则为了确定连接权值。步骤如下：

第一，随机选取 τ 个数据组成聚类中心 c_i 的起始数据， $c_i = 1, 2, \dots, \tau$ 。

第二，依据距离最近原则，将输入数据 x_k 全部分配给聚类中心 c_i 的数据集合 θ_i ，并且满足条件： $c_i = \min \|x_k - c_i\|$ 。

第三，计算更新的聚类中心，公式如下：

$$c_i = \frac{1}{m_i} \sum_{x_k \in \theta_i} x_k \quad (3-10)$$

其中， m_i 表示输出数据的数量。

不断计算上述步骤，直至最终确定出唯一聚类中心 c_i 。

第四，确定高斯函数作为径向基函数并计算宽度和权值，公式如下：

$$\sigma_i = \frac{c_{max}}{\sqrt{2\tau}} \quad (3-11)$$

$$\omega = \exp\left(\frac{\tau}{c_{max}^2} \|x_k - c_i\|^2\right) \quad (3-12)$$

其中, c_{max} 为两个中心的最远距离。

对比上述三种确定关键参数的方法, 最终选择自组织法来确定 RBF 神经网络隐含层的中心、宽度以及权值。

3.1.2 遗传算法优化 RBF 神经网络

遗传算法首次提出可追溯至 1962 年, 由美国密歇根大学的著名学者 John Holland 教授及其团队共同开创, 简称 GA^[74]。GA 优化 RBF 神经网络这一过程主要由三大部分构成: 首先是 RBF 神经网络拓扑结构确定, 其次是遗传算法的优化, 最后是 RBF 神经网络的预测应用^[75]。其中, RBF 神经网络的结构设计主要依赖于拟合函数的输入输出参数, 这些参数的选择直接决定了神经网络的基本形态。而 GA 优化 RBF 神经网络主要是优化其隐含层中心值 c_i 、宽度 σ 以及连接权值 ω_{ij} 。RBF 神经网络预测则是利用 GA 优选的最优个体对 RBF 神经网络的参数进行赋值, 经过训练后最终输出精确的预测模型。具体流程如图 3-2 所示。

由图 3-2 可知, 遗传算法优化神经网络主要包含以下几个部分。

(1) 种群初始化

种群的初始化是通过个体编码的方式实现的, 从而进行初始化操作。

(2) 适应度函数

个体的适应度值就是预测输出和期望输出之间的误差, 公式如下:

$$F = k \sum_{i=1}^n abs(y_i - o_i) \quad (3-13)$$

式中: n 为总的输出节点数; y_i 表示神经网络第 i 个节点的预测输出; o_i 表示第 i 个节点的期望输出; k 为系数。

(3) 选择操作

选择操作涉及从旧群体中根据特定概率进行择优选择, 进而构建出全新的群体。在这个过程中, 每个个体被选中的概率为 P_i , 可通过以下公式进行计算:

$$f_i = \frac{k}{F_i} \quad (3-14)$$

$$P_i = \frac{f_i}{\sum_{i=1}^n f_i} \quad (3-15)$$

其中，个体 i 的适应度值为 F_i ；个体数目为 n ； k 则为系数。




图 3-2 GA-RBF 神经网络算法流程图

(4) 交叉操作

交叉操作是通过对随机选择的两个个体遗传信息进行交换，从而产生更加优异的新个体。交叉操作的公式如下：

$$\begin{cases} a_{kj} = a_{kj}(1-b) + a_{lj}b \\ a_{lj} = a_{lj}(1-b) + a_{kj}b \end{cases} \quad (3-16)$$

式中， b 为 $[0,1]$ 之间的随机数； a_{kj} 表示第 k 个染色体的遗传信息， a_{lj} 表示第 l 个染色体的遗传信息。

(5) 变异操作

变异操作是随机选择种群中某个体并对其染色体上某些部位进行变异操作。变异操作公式如下：

$$a_{ij} = \begin{cases} a_{ij} + (a_{ij} - a_{max}) * f(g), & r > 0.5 \\ a_{ij} + (a_{min} - a_{ij}) * f(g), & r \leq 0.5 \end{cases} \quad (3-17)$$

$$f(g) = r \left(1 - \frac{g}{G_{max}} \right)^2 \quad (3-18)$$

其中, a_{max} 表示 a_{ij} 的上限; a_{min} 为 a_{ij} 的下限; G_{max} 表示最大进化次数; g 指的是当前迭代次数; r 表示[0,1]之间的随机数。

3.1.3 鹈鹕算法优化 RBF 神经网络

鹈鹕优化算法 (Pelican Optimization Algorithm, POA), 作为一种新兴的群智能算法, 由 Pavel Trojovský 等人于 2022 年提出, 该算法以鹈鹕独特的狩猎行为为蓝本, 对其在自然界中的捕食过程进行了深入的模拟^[76]。鹈鹕算法优化 RBF 神经网络的算法流程如图 3-3 所示。




图 3-3 POA-RBF 神经网络算法流程图

由图 3-3 算法流程图可知, 鹈鹕算法优化 RBF 神经网络主要包含以下几个部分且

POA 优化 RBF 神经网络的流程如下图所示。

(1) 初始种群产生

种群初始化公式如下：

$$X_{i,j} = l_j + rand \cdot (u_j - l_j) \quad (3-19)$$

式中： $X_{i,j}$ 表示第 i 个鸚鵡在第 j 维的位置， $rand$ 表示 $[0,1]$ 之间的随机数， u_j 和 l_j 分别是求解问题的上下限。

鸚鵡种群位置表示为以下矩阵 X ：

$$X = \begin{bmatrix} X_1 \\ \vdots \\ X_i \\ \vdots \\ X_N \end{bmatrix}_{N \times M} = \begin{bmatrix} X_{1,1} & \cdots & X_{1,j} & \cdots & X_{1,M} \\ \vdots & \cdots & \vdots & \cdots & \vdots \\ X_{i,1} & \cdots & X_{i,j} & \cdots & X_{i,M} \\ \vdots & \cdots & \vdots & \cdots & \vdots \\ X_{N,1} & \cdots & X_{N,j} & \cdots & X_{N,M} \end{bmatrix}_{N \times M} \quad (3-20)$$

(2) 初始化 RBF 神经网络模型参数。

(3) 利用 POA 对 RBF 神经网络进行优化，种群的目标函数为：

$$F = \begin{bmatrix} F_1 \\ \vdots \\ F_i \\ \vdots \\ F_N \end{bmatrix}_{N \times 1} = \begin{bmatrix} F(X_1) \\ \vdots \\ F(X_i) \\ \vdots \\ F(X_N) \end{bmatrix}_{N \times 1} \quad (3-21)$$

在优化过程中，依据鸚鵡觅食行为的特性，通过采用特定的位置更新公式来持续更新种群的位置直到预设的迭代次数结束。

(4) 探索阶段

$$x_{i,j}^{Pl} = \begin{cases} x_{i,j} + rand \cdot (p_j - I \cdot x_{i,j}), & F_p < F_i \\ x_{i,j} + rand \cdot (p_j - I \cdot x_{i,j}), & else \end{cases} \quad (3-22)$$

其中： $x_{i,j}^{Pl}$ 表示第 i 代 j 维更新后的位置， p_j 表示 j 维度的猎物位置， F_p 为猎物位置的适应度， I 随机取 1 或 2。

待探索结束后，新旧位置的适应度值比较如式 (3-23) 所示。

$$x_i = \begin{cases} x_i^{Pl}, & F_i^{Pl} < F_i \\ x_i, & else \end{cases} \quad (3-23)$$

其中： x_i^{Pl} 表示第 i 代的位置， F_i^{Pl} 为它的适应度。

(5) 开发阶段

$$x_{i,j}^{P2} = x_{i,j} + R \left(1 - \frac{t}{T} \right) \cdot (2 \cdot rand - 1) \cdot x_{i,j} \quad (3-24)$$

其中： $x_{i,j}^{P2}$ 表示第 i 代 j 维更新后的位置， R 是常数 0.2。

待开发结束后，将位置更新为适应度最小的位置。

$$x_i = \begin{cases} x_i^{P2}, & F_i^{P2} < F_i \\ x_i, & \text{else} \end{cases} \quad (3-25)$$

式中： x_i^{P2} 表示第 i 代位置， F_i^{P2} 为它的适应度。

(6) 根据最优种群即最优隐含层中心、宽度与权值参数构建 POA-RBF 模型。

3.2 烟丝干燥质量预测模型

结合塔式烘丝机的设备特征，依据第二章中选取的 6 个关键工艺参数构建烟丝干燥质量预测模型，旨在最大限度地提升烟丝出口含水率及温度预测结果的准确性。

3.2.1 基于 RBF 神经网络的烟丝干燥质量预测模型

基于 RBF 神经网络的烟丝干燥工艺质量预测模型主要包含两个核心步骤，其原理框图如图 3-4 所示，该图清晰地展示了模型构建的逻辑流程。






图 3-4 RBF 神经网络烟丝干燥质量预测模型原理框图

由图 3-4 可以清晰地看到整个预测流程的逻辑脉络。首先，在数据预处理阶段，采

用了小波降噪技术和标准化方法，对烟丝干燥工艺数据进行了精细处理。同时还进行了烟丝干燥质量相关性分析，分别利用了 Pearson 相关系数法和灰色关联分析法，筛选出了与烟丝干燥质量相关性较高的六个关键工艺参数，分别是烟丝入口水分、烟丝入口温度、主工艺气质量流量、主工艺气温度、工艺蒸汽质量流量以及工艺蒸汽温度。其次进行 RBF 神经网络预测工作，将先前通过相关性分析筛选出的 6 个关键工艺参数作为神经网络的输入变量，同时将烟丝出口含水率及温度预测结果作为输出变量。在数据集中 80% 的数据作为训集，20% 的数据作为测试集，通过网络训练最终输出烟丝干燥质量预测结果。其预测结果如图 3-5 所示。



(a) 烟丝出口含水率



(b) 烟丝出口温度

图 3-5 基于 RBF 神经网络的烟丝干燥质量预测结果

由图 3-5 的 RBF 神经网络烟丝干燥质量预测结果图可知，基于 RBF 神经网络算法的烟丝出口含水率预测模型的相对误差主要集中在 $[-0.25, 0.25]$ 的区间内，烟丝出口温度预测模型的相对误差主要集中在 $[-3, 3]$ 的区间内，

3.2.2 基于 GA-RBF 神经网络的烟丝干燥质量预测模型

在构建基于 RBF 神经网络的烟丝干燥质量预测模型的基础上,进一步探索了基于遗传算法优化 RBF 神经网络算法的干燥质量预测模型,这里将其简称为 GA-RBF 烟丝干燥质量预测模型。该模型主要由四大部分构成:数据预处理部分、参数设定及初始化部分、网络训练部分以及模型输出评价部分。这四个部分相互关联,共同构成了模型的完整框架。其原理框图如图 3-6 所示,该图清晰地展示了模型构建的逻辑流程。






图 3-6 GA-RBF 烟丝干燥质量预测模型原理框图

由图 3-6 可以清晰地看到模型的构建流程。首先,步骤 1 与基于 RBF 神经网络烟丝干燥质量预测模型相同,都是数据预处理部分。其次,步骤 2 对 RBF 神经网络和遗传算法进行初始化操作,遗传算法通过交叉和变异等操作来不断更新 RBF 神经网络的隐含层中心值 c_i 、宽度 σ 以及连接权值 ω_{ij} , 中心值 c_i 、宽度 σ 以及连接权值 ω_{ij} 从而优选出最优的权值并赋给 RBF 神经网络,在步骤 3 中将筛选出的 6 个关键工艺参数输入网络并进行模型训练,训练后输出烟丝出口含水率及温度预测值。最后步骤 4 则是模型评价与输出。其预测结果如图 3-7 所示。



(a) 烟丝出口含水率



(b) 烟丝出口温度

图 3-7 基于 GA-RBF 神经网络的烟丝干燥质量预测结果

由图 3-7 的 GA-RBF 烟丝干燥质量预测结果图可知, 基于 GA-RBF 神经网络算法的烟丝出口含水率预测模型的相对误差值主要集中在 $[-0.15, 0.15]$ 的区间内, 烟丝出口温度预测模型的相对误差值主要集中在 $[-2, 2]$ 的区间内,

3.2.3 基于 POA-RBF 的烟丝干燥质量预测模型

在构建基于 RBF 神经网络的烟丝干燥质量预测模型的基础上, 又引入了鹌鹑优化算法, 建立了一种基于鹌鹑优化算法优化 RBF 神经网络的烟丝干燥工艺性能预测模型, 这里简称其为 POA-RBF 烟丝干燥质量预测模型。该模型的设计旨在通过鹌鹑算法对 RBF 神经网络进行优化, 以提高预测精度和稳定性。基于 POA-RBF 烟丝干燥质量预测模型原理框图如图 3-8 所示。






图 3-8 POA-RBF 烟丝干燥质量预测模型原理框图

根据图 3-8 中的 POA-RBF 烟丝干燥质量预测原理框图可知，步骤与基于 GA-RBF 烟丝干燥质量预测模型的原理类似，区别在于步骤 2 中鹌鹑优化算法是通过不断选取较优种群位置来更新网络的隐含层中心值 c_i 、宽度 σ 以及隐含层到输出层的连接权值 ω_{ij} ，并将最优参数值赋给 RBF 神经网络。该模型预测结果如图 3-9 所示。



(a) 烟丝出口含水率



(b) 烟丝出口温度

图 3-9 基于 POA-RBF 算法的烟丝干燥质量预测结果


根据图 3-9 基于 POA-RBF 神经网络的烟丝干燥质量预测结果可以看出所得烟丝出口含水率及温度预测结果与实际结果比较接近, 相较于 RBF 以及 GA-RBF 神经网络预测的误差有所减小。基于 POA-RBF 神经网络的烟丝出口含水率预测模型的相对误差值主要集中在 $[-0.1, 0.1]$ 的区间内, 烟丝出口温度预测模型的相对误差值主要集中在 $[-1, 1]$ 的区间内, 整体误差值较小, 预测效果较好。

3.3 烟丝干燥质量预测模型评价


为了验证上述建立的基于 RBF、GA-RBF 以及 POA-RBF 三种烟丝干燥质量预测模型的效果, 选择安徽省某烟厂塔式烘丝机干燥的某批次烟丝进行效果评价分析, 数据来源于该塔式烘丝机某批次的烟丝干燥过程数据, 将不同的烟丝干燥质量模型预测结果进行对比分析, 对比结果如图 3-10 所示。

根据图 3-10 (a) 所展示的三种烟丝出口含水率预测模型的对比结果, 可以清晰地看到不同模型在预测性能上的差异。具体而言, 单一 RBF 神经网络模型预测的误差波动最为显著, 这表明其预测精度相对较低。相比之下, GA-RBF 模型在预测误差方面相较于 RBF 神经网络有了一定的提升, 显示出其在优化算法方面的优势。然而, 在这三种模型中, POA-RBF 模型的表现最为出色, 其预测误差波动最小且预测的烟丝出口含水率精度最高。根据图 3-10 (b) 所展示的三种烟丝出口温度预测模型的对比结果, 可知单一 RBF 神经网络模型预测的误差波动最大, 相比之下, GA-RBF 模型在预测误差方面相较于 RBF 神经网络有了一定的提升, 显示出其在优化算法方面的优势。然而, 在这三种模型中, POA-RBF 模型的表现最为出色, 其预测误差波动最小且预测的烟丝

出口温度精度也最高。



(a) 烟丝出口含水率



(b) 烟丝出口温度

图 3-10 不同烟丝干燥质量预测模型预测结果

为了能够定量描述烟丝干燥质量预测模型的性能，选取平均绝对误差（MAE）、均方根误差（RMSE）以及决定系数（ R^2 ）作为评价指标。其中 MAE 和 RMSE 为误差评价指标，其值越小证明模型预测精度越高，而决定系数 R^2 越接近 1，模型预测精度越高，计算公式如下所示：

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (3-26)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (3-27)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (3-28)$$

式中： $\hat{y}_i$ 为样本预测值； y_i 为样本实际值； $\bar{y}_i$ 为样本质量指标的均值。

根据上式计算，将得到的各评价指标结果整理成表 3-2 所示内容，以便更加清晰地展示和比较不同模型的预测性能。

表 3-2 不同烟丝干燥质量预测模型评价指标对比

评价指标	烟丝出口含水率			烟丝出口温度		
	RBF	GA-RBF	POA-RBF	RBF	GA-RBF	POA-RBF
MAE	0.0350	0.0322	0.0236	0.5787	0.4837	0.3765
RMSE	0.0508	0.0427	0.0341	0.8437	0.6526	0.5384
R ²	0.9089	0.9358	0.9591	0.8809	0.9288	0.9515

根据表 3-2 中的数据，我们可以明显看出，当烟丝出口含水率作为输出质量指标时，POA-RBF 模型的 RMSE 值为 0.0341，这一数值明显小于另外两个模型的对应值。此外，POA-RBF 模型的 R² 值为 0.9591，相较于另外两个模型，其值更接近于 1，表明该模型的拟合度更高。同样地，当烟丝出口温度作为输出质量指标时，POA-RBF 模型的 RMSE 为 0.5384，也低于另外两个模型的误差值，而其 R² 值为 0.9515，同样显示出更高的拟合度。因此，基于 POA-RBF 神经网络的烟丝干燥质量预测模型具有较高的预测精度和拟合度。鉴于这些优势，本文选择基于 POA-RBF 的烟丝干燥质量预测模型。

3.4 本章小结

本章首先对 RBF 神经网络、GA-RBF 神经网络以及 POA-RBF 神经网络的算法原理进行了详细的介绍。基于这三种算法，分别构建了对应的烟丝干燥质量预测模型。通过对这些模型的预测结果进行比较，发现 RBF 烟丝出口含水率预测模型误差值主要集中在[-0.25,0.25]之间，而相比之下，经过优化的 GA-RBF 和 POA-RBF 烟丝出口含水率预测模型的误差值分布更为集中，主要分布在[-0.1,0.1]的狭窄区间内。对比了三种烟丝干燥质量预测结果，基于 POA-RBF 神经网络的烟丝出口含水率模型的预测准确率为 0.9591，相较于另外两个模型更接近于 1。最终优选该模型为后续进行烟丝干燥质量多目标优化提供较为高精度的数据。

第 4 章 基于改进 NSGA-II 算法的烟丝干燥质量多目标优化

根据塔式烘丝机干燥烟丝的实际生产情况，烟丝干燥质量是以烟丝出口含水率和温度是否达到标准范围为衡量指标。这两个指标之间存在矛盾关系，即在一定范围内温度升高，水分会减小，因此想要得到合适的烟丝干燥方案，就要对其进行优化。对于烟丝干燥阶段来说，如果没有进一步条件，在企业的质量要求范围内，烟丝出口温度趋于较小值时，相应的主工艺气温度可以降低，工艺蒸汽质量流量可以减少，并且后续烟丝冷却时间可以减少，对于企业节能减排有所助益。为了在保证烟丝干燥质量符合标准范围的同时还可满足卷烟厂的经济性，不仅要保证烟丝出口含水率稳定在目标值附近，还要降低烟丝出口温度。本章主要是基于改进 NSGA-II 算法设计烟丝出口含水率和温度的多目标优化方案。

4.1 多目标优化方法

4.1.1 多目标优化简介

多目标优化问题是指多个子目标可以同时被求解，各个子目标之间不是互相独立的，而是互相限制的。经典的多目标优化求解往往只局限于单一目标，但这种方式明显没有考虑到多个目标间的约束联系，忽略了可能存在的最优解，从而不能获得真正的最优解。

现阶段，常用的多目标优化方法有 NSGA 算法、NSGA-II 算法、多目标粒子群算法（Multiple Objective Particle Swarm Optimization, MOPSO）等。

4.1.2 多目标优化流程

求解多目标优化问题可分为三个阶段，包括参数输入、约束条件确定以及目标函数明确。表示如下：

$$\begin{aligned} \min & F_j(X) \quad (j=1, 2, 3, \dots, m) \\ X &= [x_1, x_2, \dots, x_i, \dots, x_n]^T \\ \text{s.t.} & \begin{cases} a_i \leq x_i \leq b_i, (i=1, 2, 3, \dots, n) \\ G_j(X) \leq 0, (j=1, 2, 3, \dots, m) \\ H_j(X) = 0, (j=1, 2, 3, \dots, m) \end{cases} \end{aligned} \quad (4-1)$$

其中， X 表示输入参数； $a_i \leq x_i \leq b_i$ 、 $G_j(X)$ 和 $H_j(X)$ 指的是三类不同的约束条件； $F_j(X)$ 则是进行多目标优化的目标函数。

“输入参数”指的是算法的输入参数量，在本文中具体指影响塔式烘丝机烟丝干燥质量的六个关键工艺参数，分别是烟丝入口水分、烟丝入口温度、主工艺气质量流量、

主工艺气温度、工艺蒸汽质量流量以及工艺蒸汽温度。

“约束条件”表示的是各输入参数的约束条件，在本文中具体指六个关键工艺参数历史数值的上下限。

“目标函数”代表的是最终需要求解的多目标问题函数。

一般多目标优化过程如下：

(1) 计算全部目标函数的解集，并对解集内各个子解集进行全面比较，从而获取所需数目的非支配解，从而形成最优解集。

(2) 以较高层次的定性条件为决策手段，从最优化解集合中选择出最佳解。

4.1.3 帕累托最优解集

1893 年，意大利经济学家 Pareto 率先提出了著名的 Pareto 最优理论，此后便多个领域得到了广泛应用，特别是在处理多目标优化问题时，由于存在多个子目标且这些函数解之间往往呈现出复杂的支配与非支配关系。如图 4-1 所示：




图 4-1 Pareto 解的支配与非支配关系

以求取双目标函数的最小值为例，可以从图 4-1 (a) 中观察到 $F_1(p_1) < F_1(q_1)$ ，且 $F_2(p_1) < F_2(q_1)$ ，即称 p_1 支配 q_1 ；从图 4-1 (b) 中可以看出子目标函数 $F_1(p_2) > F_1(q_2)$ ，但同时 $F_2(p_2) < F_2(q_2)$ ，即 p_2 与 q_2 之间为非支配关系。由此可知，Pareto 最优解指的是 $\forall l = 1, 2, 3, \dots, m$ ，不存在 $x_k (k \in (1, 2, \dots, m))$ ，使得 $F_j(x_k) \leq F_j(x_l)$ ，且至少存在一个子目标函数 $F_i(x_k) \leq F_i(x_l)$ 不等式成立，则 x_l 为该多目标函数的一个 Pareto 最优解，所有最优解构成的解集称为 Pareto 最优解集。如图 4-2 所示， F_1 和 F_2 分别代表两个子目标函数，以双目标函数求取最小值为例，图中红点为 Pareto 最优解，所有红点构成的集合则称为

该双目标优化问题的 Pareto 最优解集。




图 4-2 Pareto 解集

4.2. 改进 NSGA-II 算法

4.2.1 NSGA-II 算法

NSGA-II 算法是 Deb 等人针对 NSGA 算法存在复杂程度高、容易陷入局部最优解等缺点进行的改进算法，其算法流程如图 4-3 所示。




图 4-3 NSGA-II 算法流程图

1、快速非支配排序

在 NSGA 算法中, 子目标函数的个数用 p 表示, 种群数量用 Q 表示, 对整个种群的个体进行非支配比较和排序, 即比较的次数为 $p*Q*Q$ 。如图 4-4 (a) 所示, 运算量巨大。而在 NSGA-II 算法中, 采用非支配分层分级排序方法, 比较次数为 $p*Q$ 。如图 4-4 (b) 所示, 大大降低了比较次数。




图 4-4 两种算法的非支配排序对比

2、拥挤度

拥挤度表示种群中指定点的密度。如图 4-5 所示, 其计算步骤如下:

- (1) 初始化种群中所有个体的拥挤度 d_{q_i} ;
- (2) 进行非支配排序;
- (3) 计算拥挤度 d_{q_i} , 如下式:

$$d_{q_i} = \sum_{j=1}^m |F_j^{q_{i+1}} - F_j^{q_{i-1}}| \quad (4-2)$$

式中 d_{q_i} 表示个体 q_i 的拥挤度, $F_j^{q_{i+1}}$ 和 $F_j^{q_{i-1}}$ 分别表示第 j 个子目标函数在 q_{i+1} 和 q_{i-1} 点的取值。

NSGA-II 算法是将拥挤度作为适应度函数, 在不断更新子代的过程中, 保留拥挤度大的解集。因此, 在解决多目标优化问题时, NSGA-II 算法不仅能够有效地寻找到最优解, 而且还能够确保解集的多样性, 从而使得 Pareto 最优解均匀分布。




图 4-5 拥挤度示意图

3、精英策略

精英策略的核心是通过对所有个体的对比,运用 NSGA-II 算法从筛选两代种群中的优势个体,从而实现对优秀个体的精准选择。根据图 4-6 可知,假设 N 为种群数量, Q_t 表示父代种群, P_t 代表子代种群。 Q_t 和 P_t 组合形成种群 R_t , 对种群 R_t 进行快速非支配排序得到 Z_1 、 Z_2 、 Z_3 等小种群, 当 Z_1 和 Z_2 的种群数量之和小于 N 时, 则直接将其带入 Q_{t+1} 中。若三个种群数量之和大于 N 时, 则把 Z_3 中的个体以拥挤度大小进行排序, 优先挑选拥挤度较大的个体放入到新子代种群 Q_{t+1} 中, 直到 Q_{t+1} 种群数量为 N 。




图 4-6 精英策略示意图

4.2.2 改进 NSGA-II 算法

改进 NSGA-II 算法是在原算法的种群初始化、父代选择、种群交叉以及种群变异四部分进行优化的。

(1) 种群初始化

NSGA-II 算法在初始化种群的时候采用的是随机生成，随机代表着不确定且随机生成的种群在整个空间上表现为不均匀，为消除随机初始化带来的不确定性和种群在空间上分布不均匀问题，由此引出新的初始化种群方式：佳点集生成种群。

佳点集^[77]最初是由华罗庚等提出，基本定义和构造为：假设 G_s 是 s 维的欧氏几何空间，那么 $r \in G_s$ ，则

$$P_n(k) = (r_1 k_1, r_2 k_2, \dots, r_t k_t), k = 1, 2, \dots, n \quad (4-3)$$

$$X_i^j = a_j + P_n(k)(b_j - a_j) \quad (4-4)$$

其中， n 表示样本数量， $P_n(k)$ 表示佳点集， r 指的是佳点，一般取 $r_i = \left\{ 2 \cos \left(\frac{2\pi i}{p} \right), 1 \leq i \leq t \right\}$ ，其中 p 是满足 $p \geq 2t + 3$ 的最小素数。

假设种群规模为 100 时，两种初始化种群方式生成的种群分布情况分别如图 4-7 所示。由图可知，佳点集生成的种群会比随机生成的种群分布更加均匀，因此佳点集初始化种群会提高种群的质量以及多样性，也避免后续交叉过程中搜索的限制，有利于避免发生局部最优的情况。




图 4-7 种群初始化方式比较

(2) 父代选择

传统的 NSGA-II 算法采用的是锦标赛选择方式。从选择方式看,优点是任何个体都有可能参与到竞争,一个适应值大的个体有可能作为多个父代的个体,可以保证父代选择公平,避免陷入局部最优。但同时锦标赛的选择方式也有存在缺点,从锦标赛的实现方式来看,父代近似于随机选择,其搜索能力得不到保证。为保证算法的收敛新且可以更好地逼近真实值。故选择基于线性排名的父代选择方式,其实现思路如下:

种群个体按照适应度值从小到大排序,在 NSGA-II 算法中是先对等级进行降序排列,再对拥挤距离进行升序排列。排名越高(适应度值越小),选择概率越高,然后按照选择的线性函数来分配个体的选择概率。

假设 x_1 为排名最高的个体, x_n 为排名最低的个体,个体 x_i 的选择概率为:

$$p_i = \frac{1}{N} \left(\eta^- + (\eta^+ - \eta^-)^{\frac{i-1}{N-1}} \right) \quad (4-5)$$

其中, $i=1,2,\dots,N$, η^+ 、 η^- 为一常数且 $0 \leq \eta^- \leq 1$ 。可添加指数项来随着代数的逐步推进调整 η^+ 、 η^- 的值。

(3) 种群交叉

多项式杂交方式所生成的个体结果,其本质可以视作是在某一特定区间内的随机变动值。然而,这种方式并不能保证子代个体一定优于其父代,会对算法的收敛速度产生不利影响,从而导致算法性能下降。为了改变这种情况,借鉴粒子群算法,提出了一种新的杂交方式——引导式杂交,使产生的个体尽可能的往好的方向进化。

选择两个个体作为父代进行杂交,两个个体之间存在基因上的差距,假如两者产生的后代形状表现为一半像父亲,一半像母亲,那么后代的基因应该从两个父代中各取一半。然而在实际的自然界中,这种现象很少发生,一般都是更像父亲或者更像母亲,这取决于子代的形状表现。借鉴粒子群算法中个体受到个体历史最优和种群最优的影响往最优的方向走的方式,具体的杂交方式如下:

假设 p_1 、 p_2 为父代个体,且 p_1 优于 p_2 (若等级一样,则按照拥挤距离判断); c_1 、 c_2 表示产生的后代个体。

$$\begin{aligned} cp &= p_1 - p_2 \\ zp &= \frac{p_1 + p_2}{2} \end{aligned} \quad (4-6)$$

式中， cp 表示两个父代之间的基因差别， zp 表示两个父代之间的基因共同点。

子代产生的进化方向如下：

$$\begin{aligned} vp_1 &= k \cdot cp + h_1 \cdot r_1 \cdot (p_1 - zp) + h_2 \cdot r_2 \cdot (p_2 - zp) \\ vp_2 &= k \cdot cp + h_1 \cdot r_3 \cdot (p_2 - zp) + h_2 \cdot r_4 \cdot (p_1 - zp) \end{aligned} \quad (4-7)$$

子代的生成：

$$\begin{aligned} c_1 &= p_1 + vp_1 \\ c_2 &= p_2 + vp_2 \end{aligned} \quad (4-8)$$

其中， k 、 h_1 、 h_2 为常数， r_1 、 r_2 、 r_3 、 r_4 为 $[0,1]$ 的随机数。

(4) 种群变异

多项式变异在进化算法中，其变异算子的作用与进化代数是构不成直接联系的，因此当进化到一定代数时，算法会缺乏局部搜索能力。为了关联起变异算子和进化代数，Michalewicz 提出了非均匀变异^[78]，这可扩大算法前期变异的范围，随着进化代数的增加，变异范围越来越小，从而增加算法的微调能力。

设 $x = (x_1, x_2, \dots, x_n)$ 为待变异个体，变异产生一个新基因 y ，首先随机生成一个整数 $k \in [1, n]$ ，然后对 x 的第 k 个基因进行变异。

$$y_k = \begin{cases} x_k + \Delta(t, u_k - x_k), & x \leq 0.5 \\ x_k - \Delta(t, u_k - x_k), & x > 0.5 \end{cases} \quad (4-9)$$

则产生的新个体为 $y = (x_1, x_2, \dots, x_k, \dots, x_n)$ 。

其中，随机数 $r \in [0,1]$ ， t 为当前进化代数，函数 $\Delta(t, z)$ 返回的是一个 $[0, z]$ 的值，并且随着 t 的增加，函数 $\Delta(t, z)$ 趋于 0 的概率增加。函数 $\Delta(t, z)$ 的特性使算法在前期具有较大的搜索范围，在后期可以进行小范围的调整。其中函数 $\Delta(t, z)$ 表示为：

$$\Delta(t, z) = z \cdot \left(1 - r(1 - t/T)^b\right) \quad (4-10)$$

上式中，随机数 $r \in [0,1]$ ， T 表示最大进化代数， b 是一个分均匀度的参数，一般取

值为 2 到 5。

综上所述，改进 NSGA-II 算法流程图如图 4-8 所示。




图 4-8 改进 NSGA-II 算法流程图

4.2.3 改进 NSGA-II 算法性能分析

(1) 测试函数

为了对改进 NSGA-II 算法进行深入的分析和评估，本文选取了 ZDT 系列中 4 个具有显著代表性的测试函数，这些测试函数的表达式和特性如下所式：

1) $m = 30$ ，Pareto 前沿特征为凸形、连续：

$$\text{ZDT1} \begin{cases} \min f_1(x) = x_1 \\ \min f_2(x) = g \left(1 - \sqrt{f_1 / g} \right) \\ g(x) = 1 + 9 \sum_{i=2}^m x_i / (m-1) \\ s.t. 0 \leq x_i \leq 1, i = 1, 2, \dots, 30 \end{cases} \quad (4-11)$$

2) $m = 30$, Pareto 前沿特征为凹形、连续:

$$\text{ZDT2} \begin{cases} \min f_1(x) = x_1 \\ \min f_2(x) = g \left(1 - (f_1 / g)^2 \right) \\ g(x) = 1 + 9 \sum_{i=2}^m x_i / (m-1) \\ s.t. 0 \leq x_i \leq 1, i = 1, 2, \dots, 30 \end{cases} \quad (4-12)$$

3) $m = 30$, Pareto 前沿特征为非连续:

$$\text{ZDT3} \begin{cases} \min f_1(x) = x_1 \\ \min f_2(x) = g \left(1 - \sqrt{(f_1 / g)} - (f_1 / g) \sin(10\pi f_1) \right) \\ g(x) = 1 + 9 \sum_{i=2}^m x_i / (m-1) \\ s.t. 0 \leq x_i \leq 1, i = 1, 2, \dots, 30 \end{cases} \quad (4-13)$$

4) $m = 10$, Pareto 前沿特征为凹形、非均匀:

$$\text{ZDT6} \begin{cases} \min f_1(x) = 1 - \exp(-4x_1) \sin^6(6\pi x_1) \\ \min f_2(x) = g \left(1 - (f_1 / g)^2 \right) \\ g(x) = 1 + 9 \left(\sum_{i=2}^m x_i / (m-1) \right)^{0.25} \\ s.t. 0 \leq x_i \leq 1, i = 1, 2, \dots, 10 \end{cases} \quad (4-14)$$

(2) 评价指标

为了进一步测试多目标算法的性能, 设置种群大小为 100, 最大迭代次数为 500, 变异率为 0.6, 交叉率为 0.8。同时采用世代距离 (Generational Distance, GD) 和分布指标 (Spread, SP) 来评价算法的收敛性和分布均匀性。

1) GD 指标

GD 指标是评价获得的解集与真实解集的重合度。首先求解最小归一化欧式距离, 公式如下:

$$d_i = \sum_{j=1}^{|P^*|} \min \sqrt{\sum_{m=1}^k \left(\frac{f_m(n_i) - f_m(p_j)}{f_m^{\max} - f_m^{\min}} \right)^2} \quad (4-15)$$

式中, 真实的 Pareto 最优解集表示为 $P^* = (p_1, p_2, \dots, p_{|P^*|})$; $N = (n_1, n_2, \dots, n_{|N|})$ 则表示

获得的 Pareto 最优解集; k 指的是目标函数的数量, $f_m^{\max}$ 、 $f_m^{\min}$ 分别表示第 m 个目标函

数的最大值和最小值。

$$GD(N) = \frac{\sum_{i=1}^{|N|} d_i}{|N|} \quad (4-16)$$

收敛性指标，即 GD 指标，该数值越小则表明解的收敛性越好。

2) SP 指标

SP 指标用于评价算法获得的解集分布均匀性，公式如下：

$$\begin{aligned} SP &= \sqrt{\frac{1}{|N|-1} \sum_{i=1}^{|N|} (\bar{d} - d_i)^2} \\ d_i &= \min_j \left\{ \sum_{m=1}^k \left| f_m(n_i) - f_m(n_j) \right| \right\} \\ n_i, n_j &\in N, i, j = 1, 2, \dots, |N| \\ \bar{d} &= \frac{1}{N} \sum_{i=1}^N d_i \end{aligned} \quad (4-17)$$

其中， k 指的是目标函数的数量， d_i 指的是第 i 个解与其相邻解之间的距离， $\bar{d}$ 表示所有解之间距离的平均值。

均匀性指标，即 SP 指标，该数值越小则表明算法解集分布的均匀性越好，

(2) 测试结果的对比和分析

鉴于随机性存在的可能，三种多目标优化算法均测试 30 次，得到的 ZDT 二维测试结果对比如图 4-9 至图 4-12 所示，并计算了 GD 指标与 SP 指标的均值，结果如表 4-1 和表 4-2 所示。




图 4-9 ZDT1 测试函数




图 4-10 ZDT2 测试函数




图 4-11 ZDT3 测试函数




图 4-12 ZDT6 测试函数

根据图 4-9 至图 4-12 可以看出,在 ZDT1、ZDT2、ZDT3 以及 ZDT6 中,改进 NSGA-II 算法得到的最优解较原 NSGA-II 算法更接近真实解,这表明改进 NSGA-II 算法的收敛性优于原 NSGA-II 算法;在 ZDT3 和 ZDT6 中,改进 NSGA-II 算法得到的解明显多于原 NSGA-II,这表明改进 NSGA-II 算法的全局搜索能力要优于原 NSGA-II 算法。

表 4-1 测试算法的 GD 指标

测试函数	NSGA-II	改进 NSGA-II
ZDT1	0.038437	0.002408
ZDT2	0.056815	0.001152
ZDT3	0.064275	0.006248
ZDT6	0.209660	0.001251

表 4-2 测试算法的 SP 指标

测试函数	NSGA-II	改进 NSGA-II
ZDT1	0.071426	0.056901
ZDT2	0.057859	0.050524
ZDT3	0.080185	0.053471
ZDT6	0.072476	0.062339

由表 4-1 和 4-2 可知,四个 ZDT 系列测试函数的 GD 指标和 SP 指标中,改进 NSGA-II 算法的值均为最小,这表明改进 NSGA-II 算法得到解的收敛性与均匀性均优于原 NSGA-II 算法,故改进 NSGA-II 算法在多目标寻优问题中具有更好的寻优能力。

4.3 两阶段优化

4.3.1 两阶段优化的框架

为确定唯一最优解,本章提出了一种新颖的两阶段多目标优化方法。该方法的实施分为两个阶段。阶段一进行多目标优化,运用改进 NSGA-II 算法来求解 Pareto 最优解集,从而得到一组优质的候选解;阶段二则专注于多属性决策分析,借助 FCM-GRP 方法进一步从 Pareto 最优解集中筛选出唯一的最优解。所提两阶段优化框架如下图所示。




图 4-13 两阶段优化框架

4.3.2 多属性决策

多属性决策的过程可由模糊 C-均值聚类（Fuzzy C-means, FCM）和灰色关联投影（Grey Relational Projection, GRP）两大环节构成。

（1）模糊 C-均值聚类

FCM 作为一种重要的聚类方法，在模糊聚类算法中得到了广泛的应用。其计算公式如下：

$$\begin{aligned} \min J(U, V, W) &= \sum_{i=1}^{N_d} \sum_{j=1}^{N_d} \mu_{ij}^m \|w_i - v_i\|^2 \\ \text{s.t. } \sum_{j=1}^{N_{cl}} \mu_{ij} &= 1 \end{aligned} \quad (4-18)$$

其中， J 表示损失函数； U 表示隶属度矩阵； V 表示聚类中心； W 为聚类的输入向量； μ_{ij} 为 x_i 属于 v_i 的隶属度； N_{cl} 表示聚类数量。

（2）灰色关联投影

GRP 是一种结合灰色关联理论和矢量投影原理的多属性决策方法，它有效提升决策方式的准确性和可靠性。在调度方案的决策过程中，GRP 通过对理想方案的投影如下：

$$Prj_l^{+(-)} = \sum_{i=1}^{Ng} Grc_{l,i}^{+(-)} \times \frac{r_i^2}{\sqrt{\sum_{i=1}^{Ng} (r_i)^2}} \quad (4-19)$$

式中， Ng 指的是方案的指标数量， $Grc_{l,i}$ 表示灰色关联系数， r_i 是指标的权重。

$$RP_l = \frac{Prj_l^+}{Prj_l^+ + Prj_l^-}, 0 \leq RP_l \leq 1 \quad (4-20)$$

其中, RP_i 表示相对投影。

综上所述, 多属性决策具体流程如图 4-14 所示。




图 4-14 两阶段优化求解流程

4.4 多目标优化模型的构建

4.4.1 选取决策变量

决策变量是人为可以调节的参数, 其取值范围通常限定在安全界限内。在本文实验数据中, 决策变量为经过相关性分析筛选出的烟丝入口水分、烟丝入口温度、主工艺气质量流量、主工艺气温度、工艺蒸汽质量流量以及工艺蒸汽温度六个影响烟丝干燥质量的关键工艺参数。同时需对决策变量进行约束, 参照安徽省某卷烟厂实际生产需求, 设定各决策变量的合理变化范围, 如下表 4-3 所示:

表 4-3 烟丝干燥工艺参数的约束范围值

参数	单位	下界	上界
烟丝入口水分	%	18.5	19.5
烟丝入口温度	°C	27	33
主工艺气质量流量	kg·h ⁻¹	37000	38000
主工艺气温度	°C	160	168
工艺蒸汽质量流量	kg·h ⁻¹	350	550
工艺蒸汽温度	°C	160	170

4.4.2 目标函数的构造

塔式烘丝机烟丝干燥优化的本质是通过调整烟丝干燥过程中的决策变量，来降低烟丝出口温度的同时保证烟丝出口含水率维持在目标值不变，这与常见的单目标优化问题有所不同，多目标优化问题是相对的，降低了烟丝出口温度的同时也会影响烟丝出口含水率，要构造出两个合理的目标函数，通过数学方法对这个多目标优化问题进行求解。本文中多目标优化的目标函数分别是烟丝出口含水率的预测值与期望的烟丝出口含水率差值最小，以及烟丝出口温度的预测值与期望的烟丝出口温度的差值最小。在选择目标函数时，选择烟丝出口温度的预测值与期望值作为目标函数，是因为烟丝出口温度的最小值有一定的限制，不能无限制的降低。根据适应度函数的计算要求和塔式烘丝机烟丝干燥实际运行中决策变量的变化范围，构造出的综合优化目标函数如下式（4-21）所示：

$$\begin{aligned}
 & \min \left(|f_1(x) - tar_1|, |f_2(x) - tar_2| \right) \\
 & \text{s.t.} \left\{ \begin{array}{l} f_1(x) = \sum_{i=1}^{n_1} (\omega_1 x + b_1) \\ f_2(x) = \sum_{i=1}^{n_2} (\omega_2 x + b_2) \\ x = [x_1, x_2, x_3, x_4, x_5, x_6] \\ 18.5 < x_1 < 19.5 \\ 27 < x_2 < 33 \\ 36500 < x_3 < 37500 \\ 160 < x_4 < 168 \\ 350 < x_5 < 550 \\ 160 < x_6 < 170 \end{array} \right. \quad (4-21)
 \end{aligned}$$

其中, tar_1 为烟丝出口含水率的期望值, tar_2 为烟丝出口温度的期望值, s.t. 为优化函数的约束条件, n_1 , n_2 分别表示烟丝出口含水率和烟丝出口温度模型的隐含层节点数, x 为建模所需的输入变量, $x_1, x_2, \dots, x_6$ 为决策变量。由于不同客户对烟叶加工要求标准不同, 目标函数的值会发生变化, 通过对目标函数中 tar_1 和 tar_2 的数值的调整, 可以得到不同的 Pareto 前沿最优解。

4.4.3 实验结果分析

多目标优化中, 选择烟丝出口含水率预测与期望的差值和烟丝出口温度的差值作为目标函数。NSGA-II 算法通过随机初始化种群, 采用模拟二进制交叉算子, 变异方式选择多项式变异, 交叉概率为 0.7, 变异概率为 0.2, 而改进 NSGA-II 算法则通过佳点集初始化种群, 变异方式选择非均匀变异, 交叉概率为 0.7, 变异概率为 0.2。

本文还利用常见的 MOPSO 作为 NSGA-II 和改进 NSGA-II 的对比算法, 为便于这三种优化算法进行对比分析, 迭代次数均设置为 200。在稳定工况下, 对三种算法施加一致的约束并求取 Pareto 最优解集, 为确保优化结果的准确性和可靠性, 分别进行了 10 次优化过程, 通过对这 10 次优化结果的综合分析, 选取平均值作为最终的优化结果, 优化结果如图 4-15 所示。




图 4-15 三种算法的 Pareto 最优解集对比

根据图 4-15 可以看出, 改进 NSGA-II 算法优化后的烟丝出口含水率差值保持在 0%-0.5% 区间, 对比原始烟丝出口含水率区间为 12%-13%, 差值为 0%~5%, 下降了 90%。

同时, 优化后的烟丝出口温度在标准范围内有了明显降低, 改进 NSGA-II 算法优化后的烟丝出口温度差值保持在 0°C - 4°C 区间, 对比原始烟丝出口温度区间为 55°C - 70°C , 差值为 0°C ~ 15°C , 下降了 73.3%。总的来说, 优化效果十分显著, 充分证明了所采取的优化策略的有效性和实用性。

鉴于这三种算法的收敛曲线较为接近, 为了能够更系统、深入地评估它们的优劣, 在对比优化结果的基础上, 还引入了多种类型评价指标, 对三种算法进行全面的分析。三种优化模型的性能对比如表 4-4 所示:

表 4-4 三种多目标优化算法的性能对比

参数	改进 NSGA-II	NSGA-II	MOPSO
烟丝出口含水率 (%)	12.60	12.70	12.73
烟丝出口温度 ($^{\circ}\text{C}$)	56.50	56.70	56.75
训练时间 (s)	424	468	556
优化个体数	27	26	23
GD	0.0605	0.0852	0.0919
SP	0.8044	0.9016	0.9868

(1) 对比三种算法的训练时间: MOPSO 算法所需的计算时间最长, 耗时为 556 秒, 另外两种算法的训练时间则较为接近, 其中改进 NSGA-II 算法的训练时间最短, 仅为 424 秒。这表明改进 NSGA-II 算法在收敛速度方面展现出显著优势。


(2) 对比三种算法的优化个体数量: 改进 NSGA-II 算法较另外两种算法在优化个体数量上略有优势, 最终优化得到了 27 个最优解。

(3) 对比三种算法的 GD 收敛性指标: 改进 NSGA-II 算法、NSGA-II 算法以及 MOPSO 算法的 GD 值分别为 0.0605、0.0852 和 0.0919, GD 收敛性指标的值越小表明该算法具有更好的收敛性, 由此可见改进 NSGA-II 算法具有更强的收敛性。


(4) 对比三种算法的 SP 均匀性指标: 改进 NSGA-II 算法的 SP 值为 0.8044, 在三种算法中最小, 而 SP 均匀性指标的值越小则表明其分布的越均匀。由此可见改进 NSGA-II 算法优化解集分布的最为均匀。

(5) 分析三种算法的稳定性:


分别将改进 NSGA-II、NSGA-II 以及 MOPSO 三种算法独立运行 10 次, 评估其运行的稳定性。三种算法获得的 Pareto 最优解集如图 4-16 所示。



(a) 改进 NSGA-II算法



(b) NSGA-II算法



(c) MOPSO 算法

图 4-16 三种算法的 Pareto 最优解集叠加图

由图 4-16 可知，改进 NSGA-II 算法在多次运行中展现出了极高的稳定性，其 10 条 Pareto 前沿紧密贴合，差距较小。相对而言，NSGA-II 算法也具备较好的稳定性，整体差异并不显著。然而，与这两种算法相比，MOPSO 算法的 Pareto 前沿呈现出多种不同的走向，特别是在第 5 次和第 7 次运行时，出现了明显的解集偏移现象。这很大程度上是因为算法陷入了局部最优解，导致其运行稳定性较差。因此，改进 NSGA-II 算法在稳定性方面表现最为出色，在三种算法中表现最优。

综上所述，在塔式烘丝机烟丝干燥质量多目标优化过程中，改进 NSGA-II 算法较另外两种算法相比，能更精确获得一组最佳烟丝干燥工艺参数，从而实现塔式烘丝机烟丝干燥系统的多目标优化。

经改进 NSGA-II 算法获得 Pareto 最优解集后，本文采用 FCM-GRP 的这一多属性决策方案，首先通过 FCM 将获得的解集进行有效聚类，再借助灰色关联投影的方法把最大理想度对应的烟丝出口含水率差值和烟丝出口温度差值作为最优解。如图 4-17 所示。




图 4-17 Pareto 最优解的聚类图像

由图 4-17 可知，Pareto 最优解集首先被 FCM 聚类成 3 组，再利用 GRP 提取最优解。如图中蓝点所示，该点烟丝出口含水率差值为 0.17%，即烟丝出口含水率为 12.67%，较优化前烟丝出口含水率差值为 5%下降了 96.6%，该点烟丝出口温度差值为 1.5℃，即烟丝出口温度为 56.5℃，较优化前烟丝出口温度差值为 15℃下降了 90%。图中最优解所对应的决策变量取值如表 4-5 所示，将这些决策变量的推荐值反馈给卷烟厂塔式烘丝机操作人员，这对于塔式烘丝机烟丝干燥过程具有十分重要的指导意义。

表 4-5 最优目标值对应的决策变量

参数	推荐值
烟丝入口水分 (%)	18.6
烟丝入口温度 (°C)	31.8
主工艺气质量流量 ($\text{kg}\cdot\text{h}^{-1}$)	37500
主工艺气温度 (°C)	167.3
工艺蒸汽质量流量 ($\text{kg}\cdot\text{h}^{-1}$)	390
工艺蒸汽温度 (°C)	164.8

4.5 本章小结

本章提出了一种创新性的两阶段多目标优化求解方法：一是采用改进 NSGA-II 算法进行烟丝干燥质量多目标优化，得到一组 Pareto 最优解集；二是引用 FCM-GRP 相结合的多属性决策方法，得到唯一最优解，以达到获得最优烟丝干燥工艺参数组合的目的。优化结果表明，当烟丝出口含水率和温度目标值分别设定为 12.5% 和 56.0°C 时，六个关键工艺参数值依次为 18.6%、31.8°C、37500 $\text{kg}\cdot\text{h}^{-1}$ 、167.3°C、390 $\text{kg}\cdot\text{h}^{-1}$ 和 164.8°C。所得的最优解对应的决策变量推荐值将为卷烟厂烟丝干燥设备高效运行提供重要的参考依据。

第 5 章 GUI 界面设计与实现

伴随着生产技术的持续进步，传统制造业正经历着升级与转型。在当前竞争日益加剧的市场环境下，硬件与软件的飞速发展共同推动了数字化与智能化的新趋势，成为企业追求发展的核心方向。因此，智能集成制造系统的设计与开发成为企业亟待解决的关键任务。鉴于此，本章致力于设计并开发一套专门用于塔式烘丝机烟丝干燥质量预测与工艺参数优化的系统，以进一步提升烟草行业的生产能力。

5.1 系统需求分析

5.1.1 总体功能需求分析

塔式烘丝机烟丝干燥质量预测与工艺参数优化系统的设计主要从以下两个方面进行考虑。一方面，能够准确预测烟丝干燥质量；另一方面也要能获取合理的干燥工艺参数方案。这样才能为塔式烘丝机烟丝干燥生产过程提供有效的帮助。

根据塔式烘丝机烟丝干燥过程所面临的的问题，本文设计的系统主要有要烟丝干燥数据读取、烟丝干燥质量预测和烟丝干燥工艺参数优化三个方面的功能。

（1）烟丝干燥数据读取

通常使用该系统的用户不止一人，所以需要对用户进行统一管理，为了防止非专业人员的不规范操作对系统软件以及烟丝干燥设备造成损坏，设置用户登录界面，只有身份验证成功后方能使用该系统。进入系统后，用户可以选择不同的烟丝干燥数据进行读取，在读入数据的同时，会显示烟丝干燥各过程数据以及对应的烟丝干燥质量指标数据，从而实现对烟丝干燥数据的全面展示。

（2）烟丝干燥质量预测

用户通过选取不同系列烟丝干燥数据集，可以查询到相应的烟丝干燥工艺参数方案的信息。此外，还可以使用系统中烟丝干燥质量预测功能，利用训练好的 POA-RBF 神经网络对烟丝干燥质量进行预测。

（3）烟丝干燥工艺参数优化

用户根据需求设定工艺参数的上下限范围，随后输入期望的烟丝出口含水率及温度目标值，基于第四章建立的多目标优化策略，可得到一组最佳的烟丝干燥工艺参数方案。

5.2 系统框架与开发软件介绍

5.2.1 系统框架设计

本系统的对象是塔式烘丝机的烟丝干燥数据，进行烟丝干燥质量预测以及工艺参数优化的重要步骤就是对烟丝干燥数据进行提取观察，选取影响烟丝干燥质量的关键影响因素，进而调用第三章建立的基于 POA-RBF 神经网络的预测模型，进行烟丝干燥质量的准确预测，最后利用第四章训练好的两阶段多目标优化模型对烟丝干燥工艺参数进行优化。塔式烘丝机烟丝干燥质量预测和工艺参数优化系统结构框架如图 5-1 所示。




图 5-1 系统结构框架

5.2.2 开发软件与软件平台

塔式烘丝机烟丝干燥质量预测与工艺参数优化 GUI 界面是基于 Windows10 系统进行开发的。在硬件配置方面，选用 Intel(R) Core(TM) i5-10400F CPU，其主频高达 2.90 GHz；在软件开发方面，采用 MATLAB 2021b 作为开发工具，用于代码的编译、调试以及结果测试，从而保证程序的高效性和稳定性。此外，采用 MATLAB 自带的 App Designer 设计工具，进行界面的可视化处理，从而提高用户的使用体验。

5.3 GUI 界面设计

5.3.1 用户登录界面

塔式烘丝机的烟丝干燥质量预测与工艺参数优化系统由用户登录界面以及烟丝干燥质量预测与工艺参数优化界面共同组成。设置了用户登录界面，只有用户身份验证成功后才能够使用。制作的塔式烘丝机的烟丝干燥质量预测与工艺参数优化系统登陆界面如图 5-2 所示。




图 5-2 用户登录界面

只有当用户输入正确的用户名以及密码后，才可以登录进入塔式烘丝机烟丝干燥质量预测与工艺参数优化系统主界面。登录界面设计流程如图 5-3 所示。




图 5-3 登录界面设计流程图

5.3.2 系统主界面

当用户成功登录后，可以直接进入塔式烘丝机烟丝干燥质量预测与工艺参数优化系统主界面。在这个界面主要分为三个部分，第一个部分是烟丝干燥数据读取，第二个部分是烟丝干燥质量的预测，第三个部分是工艺参数优化。塔式烘丝机烟丝干燥质量预测


与工艺参数优化系统主界面如图 5-4 所示。




图 5-4 系统主界面

第一部分为烟丝干燥数据读取部分，单击“数据输入”按钮，可自行读取不同系列烟支的烟丝干燥工艺过程数据。以安徽省某烟厂塔式烘丝机日常生产线上烟丝干燥数据为例，任意选取 2023 年 10 月 10 日某一牌名烟支从 PLC 中读取到的 1200 条数据进行读入。

第二部分为烟丝干燥质量预测部分，单击“开始训练”按钮，根据所选的烟丝干燥数据文件，系统会自动读取已经训练好的基于 POA-RBF 的烟丝干燥质量预测模型，从而进行训练和测试；单击“烟丝出口含水率”会自动出现训练集和测试集的烟丝出口含水率预测值与真实值的对比图，并且会根据预测结果计算出对应的 R^2 、MAE 以及 RMSE 等模型评价指标的值；单击“烟丝出口温度”同理，可以更直观、全面地显示出本文第三章所建烟丝干燥质量预测模型具有较高的预测精度，可以为后期烟丝干燥工艺参数优化提供数据支撑。此外，用户还可输入各特征值（即关键工艺参数），单击“预测”按钮，从而得到单次烟丝干燥质量指标的值。塔式烘丝机烟丝干燥质量预测界面如图 5-5 所示。



(a) 烟丝出口含水率预测



(b) 烟丝出口温度预测

烟丝干燥质量预测

特征值输入 19.0 27.5 36750 161 410 164

预测 12.66 58.02

(c) 单次烟丝干燥质量预测

图 5-5 烟丝干燥质量预测界面

最后一部分为干燥工艺参数优化部分，该模块的核心目的在于辅助用户确定最优的烟丝干燥工艺参数方案。如图 5-11 所示，首先输入关键烟丝干燥工艺参数的可调控区间，随后输入期望的烟丝出口含水率以及温度值，便可得到最理想的烟丝干燥工艺参数方案。

工艺参数优化

目标值输入 12.50 56.00

工艺参数方案 18.6 31.8 37500 167.3 390 164.8

图 5-6 烟丝干燥工艺参数优化界面

5.4 本章小结

本章利用 MATLAB 自带的 APP Designer 设计工具，对塔式烘丝机烟丝干燥质量预测与工艺参数优化系统进行设计，基于第三、四章提出的烟丝干燥质量预测与工艺参数优化模型，设计了一个塔式烘丝机烟丝干燥质量预测与工艺参数优化的 GUI 界面，实现了对塔式烘丝机历史烟丝干燥数据的读取、预测以及优化功能，并且将本文中所提出的网络模型更加直观地应用于实际生产中，具有较好的实际使用价值。

第 6 章 总结与展望

6.1 总结

在工业互联网领域,传感器的应用尤为广泛,它能够实时采集工业设备的工作信息,对设备的工作数据进行精准监测,从而为我们研究设备的工作规律提供了极大的便利。特别是在塔式烘丝机烟丝干燥生产过程中,如何有效利用传感器采集到的数据,对于推动工业生产的自动化研究、减轻人工调控设备的负担以及提升生产效率具有十分重要研究意义。本文主要工作总结如下:

(1) 实现了影响塔式烘丝机烟丝干燥质量的关键工艺参数选取。首先,针对采集的安徽省某烟厂塔式烘丝机烟丝干燥生产的历史数据存在异常值以及噪声干扰情况,利用小波降噪、归一化处理等方式对数据进行预处理。其次鉴于烟丝干燥工艺参数具有高维性和高耦合性的特点,结合 Pearson 相关性分析和灰色关联分析结果共同选取了烟丝入口水分、烟丝入口温度、主工艺气质量流量、主工艺气温度、工艺蒸汽质量流量以及工艺蒸汽温度六个对烟丝干燥质量具有显著影响的关键工艺参数,这些参数的选取不仅为后续烟丝干燥质量预测模型的建立提供了有力的数据支撑,同时也为工艺参数优化模型的构建奠定了坚实的基础。

(2) 实现了基于 POA-RBF 神经网络的塔式烘丝机烟丝干燥质量预测。针对塔式烘丝机烟丝干燥过程的机理模型难以建立且需要特定领域专家知识的问题,提出了一种基于鸚鵡算法优化径向基函数神经网络的方法,并将其应用于塔式烘丝机烟丝干燥质量预测。首先,采用 RBF 神经网络来建立烟丝干燥工艺参数与烟丝质量之间的映射关系;然后分别利用遗传算法和鸚鵡算法优化 RBF 神经网络,以进一步提高模型的预测精度;在此基础上,对比三种模型的预测结果,通过误差分析发现 GA-RBF 和 POA-RBF 烟丝干燥质量预测模型优于 RBF 烟丝干燥质量预测模型,并且基于 POA-RBF 的烟丝干燥质量模型的预测准确率最高且误差最小,最终优选出基于 POA-RBF 神经网络的烟丝干燥质量预测模型,为后续进行烟丝干燥质量多目标优化提供较为高精度的数据。

(3) 实现了基于 NSGA-II 算法的烟丝干燥质量多目标优化。首先,针对烟丝来料特性变化和不同烟丝干燥标准导致最优烟丝干燥工艺参数组合难以求解问题,对 NSGA-II 算法的种群初始化、父代选择、种群交叉以及种群变异四部分进行优化,得到改进 NSGA-II 算法,利用改进 NSGA-II 算法对烟丝干燥质量进行多目标优化;在此基础上,提出了一种创新的两阶段多目标优化求解方法,该方法将多目标优化阶段与多属

性决策阶段进行有机结合,建立 FCM-GRP 决策分析方法来求唯一最优解,旨在更加精准地解决多目标优化问题。优化结果表明,当烟丝出口含水率和温度目标值分别设定为 12.5%和 56.0℃时,六个关键工艺参数值依次为 18.6%、31.8℃、37500 kg·h⁻¹、167.3℃、390 kg·h⁻¹和 164.8℃。利用两阶段多目标优化策略最终得到最优解所对应的工艺参数方案,有助于卷烟厂实现更加绿色、高效的生产运营。

6.2 展望

目前,智能优化技术在工业生产方面已取得了诸多理论研究成果和丰富的应用实例。本文在深入剖析当前研究进展的基础上,结合优化算法在工业生产过程中的实际应用情况,对后续研究工作进行了如下展望:

(1) 在数据建模的过程中,神经网络因具备出色的非线性拟合能力而备受青睐。具体到塔式烘丝机烟丝干燥工艺中,为了深入理解工艺参数与烟丝干燥质量之间的复杂关系,本文采用了 RBF 神经网络进行学习。然而,烟丝干燥的实际过程涉及多个变量,并且这些变量之间的耦合关系相当紧密。为了进一步优化烟丝干燥的效果,后续的研究中应当结合与烟丝干燥时间紧密相关的机理模型,深入探讨如何精准控制不同工艺阶段的时间。通过这样的研究,我们期望能够实现烟丝干燥后品质的显著提升,从而确保最终产品的口感和品质达到最佳状态。

(2) 在塔式烘丝机烟丝干燥的过程中,生产数据呈现出动态变化的特性,且随着时间的推移而逐渐积累。这一过程中,烟丝干燥的工艺参数受到机器型号、环境条件和烟丝物理特性的多重影响,因此工况尤为复杂且多变。鉴于这种复杂性和动态性,利用神经网络和大数据技术来研究具有自适应和自学习能力的烟丝干燥工艺参数优化模型显得尤为重要。

(3) 本研究是仅仅针对塔式烘丝机烟丝干燥工艺参数进行的优化实验,其重点在于工艺参数的调整与优化,而尚未将工艺参数与加工能耗进行直接关联。鉴于这一局限性,未来的研究应当结合理论与实践,进一步拓展研究领域,引入与工艺能耗相关的多目标优化模型。通过深入探究工艺参数与能耗之间的关系,并对其进行精准调控,有望实现生产能耗降低和成本节约的目的。

参考文献

- [1] Zhu M, Wu K, Zhou Y, et al. Prediction of cooling moisture content after cut tobacco drying process based on a particle swarm optimization-extreme learning machine algorithm[J]. Mathematical Biosciences and Engineering, 2021, 18(3): 2496-2507.
- [2] Zong J, He X, Lin Z, et al. Effect of two drying methods on chemical transformations in flue-cured tobacco[J]. Drying Technology, 2022, 40(1):188-196.
- [3] 陈振业,林利明,雷嘉敏,等.基于智能控制技术在烟草设备中的应用分析[J].中国设备工程,2023(23):35-37.
- [4] 徐德龙,米强,付立伟,等.基于烟丝填充值提升的滚筒干燥工艺参数优化[J].轻工学报,2021,36(01):45-50.
- [5] Thamkaew, Grant, Ingegerd Sjöholm, et al. A review of drying methods for improving the quality of dried herbs[J]. Critical Reviews in Food Science and Nutrition , 2021,61(11):1763-1786.
- [6] 刘春山,陈思羽,肖世伟,等.稻谷变温均质干燥装置工艺优化与性能试验[J].农业机械学报,2023,54(S1):366-372.
- [7] 邵宁,翟鲁文,杨佳玫,等.不同烘丝方式对卷烟质量的影响研究进展[J].现代农业研究,2022,28(06):107-110.
- [8] 陈梅. 烟丝干燥特性及滚筒干燥机的试验研究[D].华中农业大学,2023.
- [9] Gu C, Zhao H, Xu B, et al. CFD-DEM simulation of distribution and agglomeration characteristics of bendable chain-like biomass particles in a fluidized bed reactor[J]. Fuel, 2023, 340: 127570.
- [10] 聂广军,刘文锋,周红审,等.滚筒内烟丝干燥过程的数值模拟[J].烟草科技,2022,55(12):80-87.
- [11] 付来强,郭亚强,郭志强,等.优化 SH626 型薄板烘丝机设备参数降低干头干尾[J].中国烟草学报,2022,28(01):39-43.
- [12] 罗旻晖,吴国忠,郭峰,等.CTD-1 气流烘丝机料头阶段燃烧炉温度控制系统的改进[J].烟草科技,2023,56(09):100-106.
- [13] 刘静远,李昕,刘杰,等.基于融合注意力时间卷积网络的烘丝出口含水率控制方法[J].烟草科技,2023,56(08):93-99.

- [14]Zhu M, Wu K, Zhou Y, et al. Prediction of cooling moisture content after cut tobacco drying process based on a particle swarm optimization-extreme learning machine algorithm[J]. Math. Biosci. Eng, 2021, 18: 2496-2507.
- [15]吴石,张勇,王宇鹏,等.基于双信号融合的主轴/刀柄结合面刚度退化程度预测[J/OL]. 中国机械工程:1-14[2024-04-03].
- [16]魏甲欣,李琪,马飞,等.基于图像识别的烟丝结构检测及烟丝组分分析[J].轻工学报,2022,37(03):82-87.
- [17]巫小燕,刘永明,谢鹏,等.基于支持向量机的CTD烟丝干燥设备故障预测研究[J].菏泽学院学报,2022,44(05):58-63.
- [18]程志颖,孔浩辉,张俊,等.粒子群算法结合支持向量机回归法用于近红外光谱建模[J].分析测试学报,2010,29(12):1215-1219.
- [19]乔守旭,钟文义,谭思超,等.基于PCA-GA-SVM的竖直下降两相流流型预测[J].核动力工程,2022,43(03):85-93.
- [20]杨浩,张通,阳苇丽,等.基于图像处理的雪茄烟叶晾制期间含水率预测模型比较[J].江苏农业学报,2023,39(09):1891-1900.
- [21]杜海娜,孟令峰,王松峰,等.基于机器学习的密集烘烤过程烟叶失水率预测模型对比[J].烟草科技,2022,55(09):81-88.
- [22]Huang W, Liu H, Zhang Y, et al. Railway dangerous goods transportation system risk identification: Comparisons among SVM, PSO-SVM, GA-SVM and GS-SVM [J]. Applied Soft Computing, 2021, 109: 107541.
- [23]刘浩,孟令峰,王松峰,等.基于机器视觉的烤烟鲜烟成熟度判别模型优选[J].中国农机化学报,2023,44(08):118-124.
- [24]李增盛,孟令峰,王松峰,等.基于图像处理的烟叶烘烤阶段判别模型优选[J].中国烟草学报,2022,28(02):65-76.
- [25]Zhou J, Huang S, Wang M, et al. Performance evaluation of hybrid GA-SVM and GWO-SVM models to predict earthquake-induced liquefaction potential of soil: a multi-dataset investigation[J]. Engineering with Computers, 2022:1-19.
- [26]Faramarzi A, Heidarinejad M, Mirjalili S, et al. Marine Predators Algorithm: A nature-inspired metaheuristic[J]. Expert systems with applications, 2020, 152: 113377.
- [27]王伟燕,冯文强,常乃杰,等.基于光谱预处理和机器学习算法的烤烟叶绿素含量预测

- [J].中国土壤与肥料,2023(03):194-201.
- [28]卢沛临,田青,李瑞东,等.基于随机森林算法的打叶工艺参数优化[J].安徽农业科学,2022,50(20):162-165.
- [29]陶永峰,钟琳,褚玮,等.基于 XGBoost 算法和成分特征的烟叶质量分级预测方法[J].作物研究,2023,37(06):627-633.
- [30]陈剑,许畅,徐庭亮.基于位错叠加法和改进概率神经网络的离心泵故障诊断方法[J].中国机械工程,2023,34(23):2854-2861.
- [31]邓新国,王磊,陈家瑞,等.结合核岭回归与多目标粒子群优化算法的激光焊接工艺参数预测[J].计算机集成制造系统,2021,27(11):3131-3137.
- [32]Liu Y, Jiang C, Lu C, et al. Increasing the accuracy of soil nutrient prediction by improving genetic algorithm backpropagation neural networks[J]. Symmetry, 2023, 15(1): 151.
- [33]Yin Z, Liu Q, Sun P, et al. Surface feature prediction for laser ablated 40Cr13 stainless steel based on extreme learning machine[J]. Materials, 2023, 16(2): 505.
- [34]Cao J, Wang J. Stock price forecasting model based on modified convolution neural network and financial time series analysis[J]. International Journal of Communication Systems, 2019, 32(12): e3987.
- [35]Esfe M H, Amoozadkhalili F, Toghraie D. Determining the optimal structure for accurate estimation of the dynamic viscosity of oil-based hybrid nanofluid containing MgO and MWCNTs nanoparticles using multilayer perceptron neural networks with Levenberg-Marquardt Algorithm[J]. Powder Technology, 2023, 415: 118085.
- [36]杨浩,张通,阳苇丽,等.基于图像处理的雪茄烟叶晾制期间含水率预测模型比较[J].江苏农业学报,2023,39(09):1891-1900.
- [37]许永,李超,杨乾栩,等.基于 BP 神经网络建立初烤烟叶主流烟气中氢氰酸释放量的预测模型[J].云南农业大学学报(自然科学),2018,33(01):72-78.
- [38]卓鸣,汪鹏,望开奎.基于 MIV-BP 神经网络的成品烟丝质量预测模型构建[J].食品与机械,2021,37(12):161-166+214.
- [39]施艳美. 基于 BP 神经网络在烟叶烤片机中回潮区的控制及应用[D].云南大学,2016.
- [40]Burghignoli L, Rossetti M, Centracchio F, et al. Adaptive RBF with hyperparameter optimisation for aeroacoustic applications[J]. International Journal of Aeroacoustics,

- 2022, 21(1-2): 22-42.
- [41]Cheng L, Wu X, Xie P, et al. Application of radial basis function neural network in optimization of process parameters of cigarette silk making[C]. Third International Conference on Artificial Intelligence, Virtual Reality, and Visualization (AIVRV 2023), 2023, 12923:543-549.
- [42]李巧茹,刘桂欣,陈亮,等.自适应BAS优化RBF神经网络的短时交通流预测[J].哈尔滨工业大学学报,2023,55(03):93-99.
- [43]罗丹萍. RBFNN 融合优化算法的烟叶复烤工艺参数优化研究[D].昆明理工大学,2023.
- [44]Ahmed M M Z, Touileb K, El-Sayed Seleman M M, et al. Bobbin tool friction stir welding of aluminum: parameters optimization using taguchi experimental design[J]. Materials, 2022, 15(8): 2771.
- [45]Park H S, Nguyen D S, Le-Hong T, et al. Machine learning-based optimization of process parameters in selective laser melting for biomedical applications[J]. Journal of Intelligent Manufacturing, 2022, 33(6): 1843-1858.
- [46]Zhang R, Tao J, Gao F. Temperature modeling in a coke furnace with an improved RNA-GA based RBF network[J]. Industrial & Engineering Chemistry Research, 2014, 53(8): 3236-3245.
- [47]王浩杰,王晓强,朱其萍,等.基于粒子群算法的超声滚挤压工艺参数多目标优化[J].塑性工程学报,2022,29(12):47-55.
- [48]Gunantara N. A review of multi-objective optimization: Methods and its applications[J]. Cogent Engineering, 2018, 5(1): 1502242.
- [49]赵钦,白清俊,聂坤堃,等.基于NSGA-III算法与TOPSIS决策下的区域水资源多目标优化配置[J].排灌机械工程学报,2022,40(12):1233-1240.
- [50]Liang X, Liu Y, Gu X, et al. Adaptive genetic algorithm based on individual similarity to solve multi-objective flexible job-shop scheduling problem[J]. IEEE Access, 2022, 10: 45748-45758.
- [51]Stanovov V, Akhmedova S, Vakhnin A, et al. Improving the quantum multi-swarm optimization with adaptive differential evolution for dynamic environments[J]. Algorithms, 2022, 15(5): 154.

- [52]Steklain A, Adames M, Ganacim F. Improving reflexive surfaces efficiency with genetic algorithms[J]. Journal of Instrumentation, 2023, 18(03): P03008.
- [53]Flori A, Oulhadj H, Siarry P. QUAntum particle swarm optimization: an auto-adaptive PSO for local and global optimization[J]. Computational Optimization and Applications, 2022, 82(2): 525-559.
- [54]张刘渲楠. 基于数据驱动的烘丝机工艺参数分析与优化[D].昆明理工大学,2019.
- [55]赵晓雷.基于 BP 神经网络与遗传算法的烘丝机干燥工艺参数优化[J].机械制造与自动化,2023,52(05):185-189.
- [56]Huang F, Deng N, Li Q, et al. Simulation of heat and mass transfer of cut tobacco in a batch rotary dryer by multi-objective optimization[J]. Contributions to Tobacco & Nicotine Research, 2020, 29(3):145-155.
- [57]郭秀萍,周玉莎.用多目标动态规划求解拆卸序列的 Pareto 最优前沿[J].系统管理学报,2023,32(06):1205-1212.
- [58]李文桦,明梦君,张涛,等.考虑全局和局部帕累托前沿的多模态多目标优化算法[J].自动化学报,2023,49(01):148-160.
- [59]吴功兴,阙凌燕,琚春华.基于帕累托前沿的双目标两阶段电网电压优化方法[J].系统科学与数学,2021,41(11):3207-3217.
- [60]蔡昕烨,马中雨,张峰,等.基于自适应分解的多任务协作型昂贵多目标优化算法[J].计算机学报,2021,44(09):1934-1948.
- [61]肖世隆,邹国平,安斯光.基于改进 MOEA/D 分解算法的天线阵优化设计[J].现代电子技术,2023,46(01):12-16.
- [62]Zhang B, Pan Q, Gao L, et al. A multiobjective evolutionary algorithm based on decomposition for hybrid flowshop green scheduling problem[J]. Computers & Industrial Engineering, 2019, 136: 325-344.
- [63]Wan X, Zuo X, Song F. Solving dynamic overlapping community detection problem by a multiobjective evolutionary algorithm based on decomposition[J]. Swarm and Evolutionary Computation, 2020, 54: 1-15.
- [64]Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE transactions on evolutionary computation, 2002, 6(2): 182-197.
- [65]高崇,王天霖,张俊潇,等.基于协同进化 NSGA-II的多目标交直流配电网规划方法[J].

- 电测与仪表,2023,60(08):133-137.
- [66]周永长,黄亚宇.打叶工艺参数的多目标建模与优化[J].农业装备与车辆工程,2021,59(11):56-59.
- [67]王浩. 基于 MOABC 的烟叶复烤干燥参数方案决策研究[D].昆明理工大学,2023.
- [68]陈安钢. 工业烟丝干燥过程建模与先进控制策略研究[D].东华大学,2022.
- [69]李琪,屈峰涛,何璟彬,等.基于 BAS-BP 的钻井机械钻速预测模型[J].西安石油大学学报(自然科学版),2021,36(06):89-95.
- [70]Halidou A, Mohamadou Y, Ari, et al. Review of wavelet denoising algorithms[J]. Multimedia Tools and Applications, 2023, 82(27), 41539-41569.
- [71]贺利军,李文锋,张煜.基于灰色综合关联分析的多目标优化方法[J].控制与决策,2020,35(05):1134-1142.
- [72]Krishnan P, Gopalakrishnan R, Nishanth R, et al. PSO-RBFNN based optimal PID controller and ANFIS based coupling for fruits drying system[J]. EAI Endorsed Transactions on Energy Web, 2021, 8(36).
- [73]Xu F, Liang X, Chen M, et al. Robust self-learning PID control of an aircraft anti-skid braking system[J]. Mathematics, 2022, 10(8): 1290.
- [74]Ning M, Guan J, Liu P, et al. GA-BP Air quality evaluation method based on fuzzy theory[J]. Computers, Materials & Continua, 2019, 58(1):215-227.
- [75]Tao J, Yu Z, Zhang R, et al. RBF neural network modeling approach using PCA based LM-GA optimization for coke furnace system[J]. Applied Soft Computing, 2021, 111: 107691.
- [76]Trojovský P, Dehghani M. Pelican optimization algorithm: A novel nature-inspired algorithm for engineering applications[J]. Sensors, 2022, 22(3): 855.
- [77]刘伟军,索英祁,姜兴宇,等.激光清洗过程低碳建模与工艺参数优化[J].机械工程学报,2023,59(07):276-294.
- [78]Chauhan S, Singh M, Aggarwal A, et al. Diversity driven multi-parent evolutionary algorithm with adaptive non-uniform mutation[J]. Journal of Experimental & Theoretical Artificial Intelligence, 2021, 33(5): 775-806.

攻读学位期间发表的学术成果目录

一、学术论文

- [1] 第一作者,基于支持向量机的 CTD 烟丝干燥设备故障预测研究[J].菏泽学院学报,2022,44(05):58-63.
- [2] 第一作者,Application of improved jellyfish search algorithm in rotate vector reducer fault diagnosis [J]. Electronic Research Archive, 2023, 31(8):4882-4906. (SCI 论文)
- [3] 第三作者,Rotate vector reducer fault diagnosis model based on EEMD-MPA-KELM [J]. Applied Sciences, 2023, 13(7): 4476. (SCI 论文)
- [4] 第二作者,Application of radial basis function neural network in optimization of process parameters of cigarette silk making[C]. Third International Conference on Artificial Intelligence, Virtual Reality, and Visualization (AIVRV 2023), 2023, 12923: 543-549.
- [5] 第一作者,基于自适应进化率的拓扑优化方法研究[J].安徽工程大学学报. (已录用, 拟在 2024 年 6 月发表)

二、主要参与项目

- [1] 安徽中烟工业有限责任公司芜湖卷烟厂的企业委托项目——《CTD 过程控制状态一致性机理分析及提升技术研究》。
- [2] 2022 年度安徽省教育厅科学研究重点项目“RV 减速器隐性故障诊断应用性能提升技术研究”(2022AH050995)

致谢

行文至此，落笔为终。凡是过往，皆为序章。我与安工程始于 2021 年金秋，终于 2024 年初夏，这三年美好的学生生涯，到这里也就此告一段落了。总以为来日方长，却不知时光匆匆。在安徽工程大学攻读硕士期间，虽遇各种困难和压力，但有良师无私的帮助，益友真诚的陪伴，家人全力的支持，也倍感充实。借此对所有给我生命中带来光亮的人致以最诚挚的感谢！

“桃李不言，下自成蹊”。首先，我要对我的恩师赵转哲教授衷心的道一声，谢谢！赵老师渊博的学识，严谨求实的治学态度、以及对学科前沿敏锐的洞察力和探索精神，使我深受启迪并终生受益，也将激励我在今后的工作生活中奋发向上，不断进取。赵老师不但在学术上给予我悉心的指导，在工作和生活上也同样给予了我非常多的关怀和照顾。值此，谨向我尊敬的导师再次致以衷心的感谢和崇高的敬意。特别感谢 806 课题组的刘永明导师，您的知识渊博，和蔼可亲、无私奉献、敢于担当的精神是我学习和做人的榜样！在充满艰辛的科研路上与我一路同行，拼荆斩棘，才有了现在一个不一样的我，这份恩情永生难忘，定当谨记于心！同时还要感谢 806 课题组的陈玉、张振、刘志博等老师这三年来给予我的帮助。

“树高千尺不忘根深沃土”。感谢我的父母、奶奶对我经济上与精神上的双重资助，感谢你们对我不求回报的付出，尊重我的每一个决定，为我营造和谐轻松的家庭氛围，让我内心充满能量。二十余年的养育之恩，不是一朝一夕，愿你们平安健康，未来我将努力成为你们的依靠。

“山水一程，三生有幸”。感谢课题组的全体同学，感谢师兄芮羽健、马强等及我的同届同学王梦娴、宋俊玉、詹伟剑等人一直以来对我科研上的帮助，独学而无友，则孤陋而寡闻，今得与君同窗，如切如磋，如琢如磨，其乐无穷。“总有些惊奇的际遇”。感谢我的好朋友王雪、凌鑫给予的温暖和陪伴，在毕业压力、工作压力接踵而来感到焦灼不安时给予我最大的耐心和鼓励。

最后，感谢伟大的祖国，给予我们每一个科研人幸福而安全的学习环境，读书不仅是为了往后的生活，更是为了实现中华民族伟大复兴而奋斗！

尚德敏学 唯实惟新

