

# 基于BP神经网络与遗传算法的烘丝机干燥工艺参数优化

赵晓雷

(广西中烟工业有限责任公司柳州卷烟厂,广西柳州545001)

**摘要:**针对传统烘丝机工艺参数优化缺乏具体的数学模型以及烘丝机工艺参数多的问题,提出采用主成分分析法对工艺参数进行降维,筛选出主要影响参数作为BP神经网络的输入,实现叶丝含水率的预测;在烘丝机工艺参数约束下,利用遗传算法搜索最优解,进而求解出烘丝机最佳工艺参数,提升叶丝质量。结果表明:主成分分析法结合BP的训练时间和平均相对误差绝对值都具有很大优势,平均相对误差绝对值为0.42%,分别降低了0.06%和1.08%;通过遗传算法可求解出最佳工艺参数,且在最佳烘丝工艺参数条件下,输出的叶丝含水率与最优值(12.7%)的误差为 $1.464 \times 10^{-6}$ ,实现了烘丝过程对叶丝含水率的精确控制。

**关键词:**烘丝机;主成分分析;BP神经网络;遗传算法

**中图分类号:**TP183 **文献标志码:**B **文章编号:**1671-5276(2023)05-0185-05

## Process Parameter Optimization of Silk Dryer Based on BP Neural Network and Genetic Algorithm

ZHAO Xiaolei

(Liuzhou Cigarette Factory of Guangxi China Tobacco Industry Co., Ltd., Liuzhou 545001, China)

**Abstract:** Regarding the lack of specific mathematical model for the optimization of process parameters of traditional silk dryer and enormous process parameters of silk dryer, the principal component analysis method is proposed to reduce the dimension of process parameters and screen out the main influencing parameters. The selected process parameters are used as the input of BP neural network to predict the moisture content of leaf silk. Under the constraints of the technological parameters of the dryer, the genetic algorithm is applied to search the optimal solution, and proceed to solve the optimal technological parameters of the dryer to improve the quality of the leaf silk. The results show that the training time and the absolute value of average relative error of principal component analysis combined with BP have great advantages with absolute value of average relative error as 0.42%, reduced by 0.06% and 1.08% respectively. The optimal process parameters can be solved by genetic algorithm, and under the condition of the optimal silk drying process parameters, the error between the output silk moisture content and the optimal value (12.7%) is  $1.464 \times 10^{-6}$ , which realizes the accurate control of silk moisture content in drying process.

**Keywords:** silk dryer; principal component analysis; BP neural network; genetic algorithm

## 0 引言

预测制丝过程中烘丝机的出口叶丝含水率并设置合理的烘丝机工艺参数,对保障卷烟品质具有重要意义。为此,汪文良等通过采用帕累托图分析法对卷烟制丝工艺质量影响因素进行分析,认为制丝过程中烘丝机的质量与卷烟质量存在较大的关系,其次是烘丝机工艺参数调控<sup>[1]</sup>;金发岗等通过采用随机森林对影响烘丝机工艺参数的特征变量进行筛选,并结合差分进化优化极限学习机(DE-ELM)构建预测模型,实现了对烘丝机入口叶丝含水率的预测<sup>[2]</sup>,该预测方法可较为准确地预测叶丝入口含水率;李自娟等根据制丝过程中不同工序,分别采用人工神经网络和多元回归建模方法构建预测模型,实现了对制丝过程各个工序叶丝含水率的预测<sup>[3]</sup>,该方法具有很强的数据分

析能力和预测能力,可用于卷烟制丝环节各关键工序的水分预测。综上所述,目前对制丝过程中烘丝机工艺的研究集中在叶丝含水率的预测上,未涉及到烘丝机工艺参数的优化。因此,为了进一步提高卷烟质量,结合BP神经网络与遗传算法,通过构建叶丝含水率预测模型与烘丝机目标参数优化模型,实现对制丝过程中烘丝机工艺参数的优化。

## 1 烘丝机干燥目标参数预测

### 1.1 烘丝机干燥原理

烘丝机是卷烟制丝干燥的关键设备,由烘丝筒、蒸汽管路系统、热风系统等部件组成,通过传导和对流的方式,可起到良好干燥叶丝的作用。常见的滚筒式烘丝机干燥叶丝的原理如图1所示。

**基金项目:**广西中烟工业有限责任公司资助项目(GXZYZZ2021E001)

**作者简介:**赵晓雷(1978—),男,河南禹州人,工程师,本科,研究方向为制丝工艺、装备及控制技术,zxl65995@163.com。




图1 滚筒式烘丝机工作原理

滚筒式烘丝机的工艺流程为:叶丝通过前室进入烘筒,在烘筒的转动下翻滚向前并从后室出料口掉落。叶丝在烘筒内滚动前进的同时,蒸汽通过管路到达旋转接头,并进入薄板式热交换装置中对烘丝进行加热,加快叶丝干燥,并蒸发叶丝中游离烟碱等影响叶丝品质的物质。由于叶丝在烘筒中快速升温会蒸发出水汽等,需要通过循环热风进行排出。循环热风分为两路,一路从烘筒后室经过除尘系统排出,一路通过前室进入循环热风进行混合,再通过除尘系统排出。叶丝通过烘丝机,可增加叶丝松散度和卷曲度,提高叶丝的填充值,进而可改善叶丝的品质。

### 1.2 工艺参数选定

根据图1烘丝机工作原理可知,烘丝机在进行干燥时,干燥过程复杂,且控制变量较多,主要包括切叶丝含水率、环境温湿度、工艺气流量、负压等。而要获取高品质的叶丝,最重要的是稳定出口叶丝含水率。因此,在烘丝机干燥过程中,需要对变量进行不断调节。本文参考文献[4],选定表1所示的工艺参数作为烘丝机干燥工艺优化参数。

表1 制丝过程中烘丝机工艺参数

参数名称	符号/单位
切叶丝含水率	$a/\%$
工艺流量	$b/(\text{kg} \cdot \text{h}^{-1})$
SX 蒸汽阀门开度	$c/\%$
物料流量	$d/(\text{kg} \cdot \text{h}^{-1})$
膨胀单元蒸汽流量(体积)	$e/\text{m}^3$
膨胀单元蒸汽流量(质量)	$f/\text{kg}$
排潮阀门开度	$g/\%$
桶壁二区蒸汽阀门开度	$h/\%$
桶壁一区蒸汽阀门开度	$i/\%$
循环风阀门开度	$j/\%$
循环风蒸汽阀门开度	$k/\%$
负压	$l/\text{kPa}$
工艺气速度	$m/(\text{m} \cdot \text{s}^{-1})$
I 区筒壁温度	$n/^\circ\text{C}$
II 区筒壁温度	$o/^\circ\text{C}$
出料含水率(叶丝干燥)	$p/\%$
出料温度	$q/^\circ\text{C}$
热风温度	$r/^\circ\text{C}$
出料含水率(叶丝冷却)	$s/\%$

### 1.3 目标参数预测模型构建

制丝过程中烘丝机工艺参数是影响叶丝出口含水率的重要因素。但由于其工艺参数众多,参数间的函数关系复杂,因此为表征参数的函数关系,本文借助BP神经网络具有较强映射能力的特点,构建烘丝机目标参数预测近似函数。由于工艺参数多,若全部输入BP神经网络,可能降低BP模型的训练速度和预测精度。为解决该问题,采用主成分分析法对烘丝机干燥工艺参数进行降维,以提高BP模型运行的速度[5]。具体步骤如下。

1) 初始化BP神经网络参数,确定各层神经元数量。其中输入层由输入变量数量决定,输出层由输出结果确定,隐藏层可根据式(1)确定。

$$Z = \sqrt{i+j} + a, \quad a \in [0, 10] \quad (1)$$

式中  $i, j$  为输入与输出层神经元数量。

2) 删除数据大量缺失等异常数据,并采用主成分分析法对变量进行降维,以减少输入BP神经网络的参数数量。如存在  $p$  个初始变量降低到了  $m$  个主成分,则可将制丝过程中烘丝机目标参数数学模型记作式(2)。

$$\begin{cases} F_1 = a_{11}a + a_{12}b + \dots + a_{1p}r \\ F_2 = a_{21}a + a_{22}b + \dots + a_{2p}r \\ \vdots \\ F_m = a_{m1}a + a_{m2}b + \dots + a_{mp}r \end{cases} \quad (2)$$

式中  $F_m$  表示主成分;  $a_{mp}$  表示系数。

3) 根据式(2)计算初始变量的累积贡献率  $\eta_m$  为

$$\eta_m = \frac{\lambda_1 + \lambda_2 + \dots + \lambda_m}{\lambda_1 + \lambda_2 + \dots + \lambda_p} \geq \varepsilon, \quad \varepsilon \in (0, 1) \quad (3)$$

式中  $\lambda_m$  表示第  $m$  大特征值。

4) 当  $\eta_m$  满足需求,则  $[a_1, a_2, \dots, a_m]^T$  是主成分的系数矩阵  $W$ ,由此可确定  $F_m$  表达式。将所有初始变量代入即可得到制丝过程中的所有主成分数据。

5) 设置BP神经网络训练次数、学习速率等参数,并将主成分筛选的数据输入训练,得到预测模型,表示为

$$S = S_{\text{net}}(F_1, F_2, \dots, F_m) \quad (4)$$

上述训练过程如图2所示。

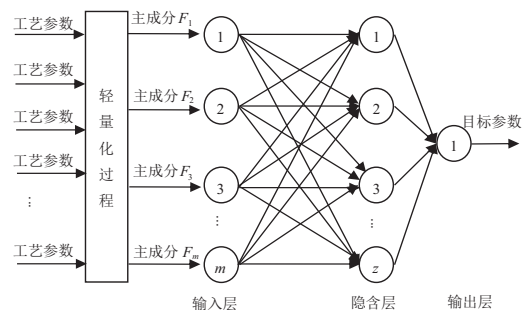


图2 基于BP神经网络的预测模型

## 2 制丝过程中烘丝机工艺参数优化模型构建

由于上述构建的基于BP神经网络的烘丝机干燥工艺参数预测模型仅反映了烘丝机工艺参数与叶丝出口含水率的

关系,没有具体的函数表达式,因此传统的求解方法很难对干燥参数进行寻优<sup>[6-7]</sup>。为解决该问题,在构建工艺参数约束条件基础上,尝试利用遗传算法的快速随机搜索能力对问题进行求解,从而获得烘丝机干燥的最佳工艺参数。

### 2.1 约束条件

以某企业叶丝干燥工艺过程为研究对象,其工艺参数约束条件见式(5)<sup>[8]</sup>。其中,由于变量*i*取值通常为0,故将其设计为常量;*s*为叶丝含水率,通常取值为12.70。

$$\min Y = (S_{net}(a, b, \dots, r) - s)$$

$$\begin{cases} 20.29 \leq a \leq 20.63 \\ 5\ 995.82 \leq b \leq 6\ 006.19 \\ 29.37 \leq c \leq 30.57 \\ 9.13 \leq d \leq 10.85 \\ 166.99 \leq e \leq 171.20 \\ 512.28 \leq f \leq 528.26 \\ 59.56 \leq g \leq 62.10 \\ 34.67 \leq h \leq 39.21 \\ 35.75 \leq j \leq 37.91 \\ 42.04 \leq k \leq 43.42 \\ -33.38 \leq l \leq -27.74 \\ 0.21 \leq m \leq 0.22 \\ 143.10 \leq n \leq 145.97 \\ 143.06 \leq o \leq 145.92 \\ 13.59 \leq p \leq 13.94 \\ 62.62 \leq q \leq 64.48 \\ 109.56 \leq r \leq 110.48 \end{cases} \quad (5)$$

式(5)中所有边界值为实际采集的某企业制丝过程工艺参数边界值。

### 2.2 工艺参数优化模型求解

利用遗传算法快速随机搜索的特点<sup>[9]</sup>,对烘丝机干燥工艺参数进行最优求解,具体求解流程如图3所示。

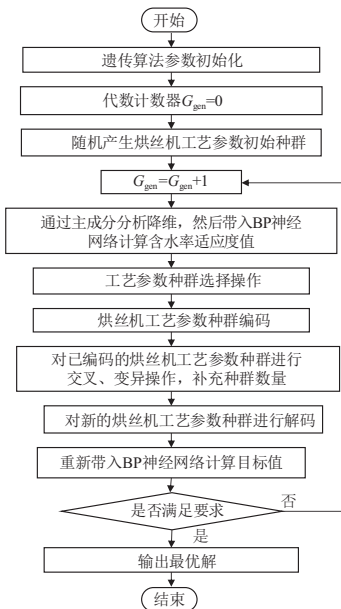


图3 基于遗传算法的烘丝机工艺参数求解流程

1) 初始种群大小、迭代次数、变异率等参数。其中,种群大小根据烘丝机边界条件设置,具体可由式(6)确定;迭代次数和变异率等参数需根据制丝过程实际情况确定<sup>[10]</sup>。

$$P_n = a' + (b' - a') \times R \quad (6)$$

式中: $P_n$ 表示第*n*烘丝机工艺参数; $a'$ 、 $b'$ 表示工艺参数*n*的最小值与最大值; $R$ 为(0,1)之间的随机数。

2) 根据式(4)对初始种群  $P_n$  进行降维处理,得到主成分种群,并输入 BP 神经网络计算个体适应。

3) 采用锦标赛选择法选择个体适应度最好的个体加入父代种群,并按二进制编码方式将工艺参数编码成一个染色体,具体如图4所示。

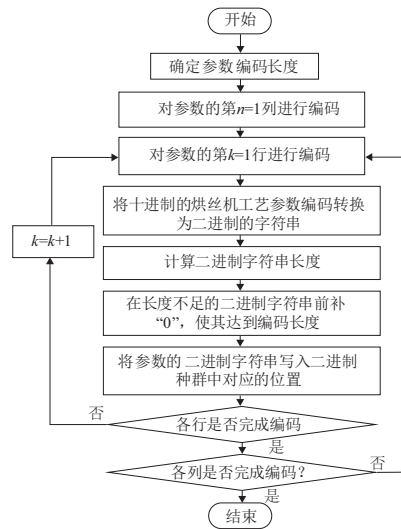


图4 烘丝机工艺参数个体编码

4) 随机选择种群中的个体,以交叉率  $G_{cro}$ , 变异率  $G_{var}$  的概率进行交叉和变异操作,产生新个体,具体交叉操作如图5所示。

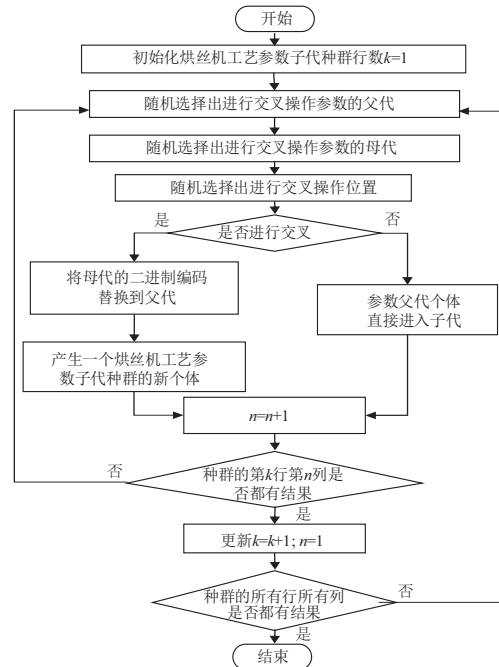


图5 工艺参数交叉变异操作

5)将编码产生的二进制字符串解码成十进制的工艺参数数据,并将其父代个体与子代个体进行合并,生成新种群。

6)采用主成分分析法对新种群进行降维处理,获取轻量化数据。

7)采用预测模型求解目标值矩阵,当模型训练达到最大迭代次数,结束算法,输出结果。

### 3 仿真实验

#### 3.1 实验环境

为验证上述方法的可行性,在 Matlab 中进行算法合成,在 64 位 Windows7 操作系统上运行。系统配置 Intel core i7-9750H CPU,内存为 12 GB, GPU 选用 NVIDIA GeForce GTX1650。

#### 3.2 数据来源及预处理

本次实验选用某企业第 5 批次制丝过程生产数据作为实验数据,分别构建制丝过程轻量化数据化预测模型和烘丝机工艺参数优化模型。制丝过程中烘丝机的参数如表 1 所示。将收集的实验数据进行整理分析发现,第 4 组数据物料流量含有大量的异常样本,第 9 组数据桶壁一区蒸汽阀门开度含大量缺失样本。为避免以上数据影响模型预测结果的准确性,本次实验采用直接删除的方式进行了预处理。最终获取共 655 组制丝过程烘丝机工艺参数数据。对上述工艺参数数据进行降维处理。首先计算工艺参数的累积贡献率,得到表 2 所示结果。由表可知, $a-f$ 工艺参数累积贡献率为 68.03%,超过所有工艺参数贡献率的一半。因此,选用前 6 个工艺参数作为主成分。

表 2 累积贡献率

参数	初始特征值		
	总计	方差/%	累积/%
$a$	2.850	16.740	16.74
$b$	2.770	16.290	33.03
$c$	1.980	11.640	44.67
$d$	1.680	9.880	54.54
$e$	1.230	7.260	61.81
$f$	1.060	6.230	68.03
$g$	0.982	5.780	73.81
$h$	0.952	5.600	79.41
$j$	0.821	4.830	84.24
$k$	0.788	4.630	88.87
$l$	0.571	3.360	92.23
$m$	0.456	2.680	94.91
$n$	0.373	2.200	97.11
$o$	0.255	1.500	98.61
$p$	0.229	1.350	99.95
$q$	0.008	0.050	99.99
$r$	0.000	0.003	100.00

#### 3.3 参数设置

降维前 BP 神经网络模型参数为:输入层神经元=17, 隐藏层神经元=10, 输出层神经元=1, 学习率=0.02, 训练

次数=1 000, 显示间隔=25, 其余参数为默认值。降维后的 BP 神经网络模型参数输入层神经元设置为 6, 其余参数不变。初始种群规模=30, 最大迭代次数=100, 交叉率=变异率=0.1, 选择率=0.5, 编码长度=20。

#### 3.4 评价指标

选用相对误差  $\varepsilon$  评估模型预测性能, 采用相对误差范围评估模型预测值偏离范围。 $\varepsilon$  的计算方法如式(7)所示, 相对误差范围计算方法如式(8)所示。

$$\varepsilon = \frac{\sum_{i=1}^n \frac{|S_{\text{net}}^i - S_t^i|}{S_t^i}}{n}, \quad i \in (1, n) \quad (7)$$

$$\begin{cases} \varepsilon_{\min} = \min\left(\frac{S_{\text{net}}^i - S_t^i}{S_t^i}\right) \\ \varepsilon_{\max} = \max\left(\frac{S_{\text{net}}^i - S_t^i}{S_t^i}\right) \end{cases} \quad (8)$$

式中: $S_{\text{net}}$ 、 $S_t$  分别为叶丝含水率预测值与实际值; $n$  为测试数据组数; $\varepsilon_{\min}$ 、 $\varepsilon_{\max}$  为相对误差最小值和最大值。

#### 3.5 结果与分析

##### a) 模型验证

为验证所提模型的有效性, 实验对比了降维前后模型的预测结果。

##### 1) 降维前模型预测结果

将预处理后的实验数据按 3:1 比例划分为训练集和测试集。分别采用训练集和测试集对降维前 BP 网络进行训练与测试。模型训练可用时间为 0.75 s, 对制丝过程中叶丝含水率的预测结果及误差变化曲线如图 6 所示。由图 6 可知, 降维前模型的预测值与实际值变化趋势大致相同, 但预测值与实际值存在一定误差, 预测误差为 0.004 9。由此说明, 模型可预测制丝过程叶丝含水率, 反映叶丝含水率与烘丝机工艺参数的关系, 但整个分析预测过程耗时较长, 预测精度也有待提高。





图 6 降维前 BP 神经网络预测结果

## 2) 降维后模型预测结果

采用主成分分析降维法对实验数据进行降维处理,获得6个主成分数据。将主成分数据按3:1比例划分为训练集和测试集,并分别对模型进行训练与测试。模型训练时间为0.47 s,预测结果及误差变化曲线如图7所示。相较于降维前的模型,降维后模型训练时间约为0.47 s,训练时间缩短了一半。降维后模型的预测值与实际值变化趋势基本相同,且预测值与实际值较为接近,相对误差较小,大约为0.002 2,相比降维前预测误差减小了0.002 7。由此说明,降维处理后的实验数据可提高模型的预测精度,缩短模型训练时间,即所构建的轻量化BP神经网络相较于传统神经网络具有一定的有效性和优越性。





图7 降维后BP神经网络预测结果

## b) 模型训练时间和预测结果对比

为进一步验证所提的主成分分析结合BP神经网络的有效性,对比BP神经网络和多元回归预测模型的预测时间和误差,具体结果如表3所示。由表3可知,相较于对比模型,成分分析结合BP神经网络的训练时间更短且误差绝对值更小。由此说明,所提模型具有一定的优越性。

表3 不同模型预测结果对比

方法	平均训练耗时/s	平均相对误差绝对值/%
主成分分析结合BP神经网络	0.660 3	0.42
BP神经网络	0.675 8	0.48
多元回归预测	—	1.50

## c) 最佳工艺参数求解结果

将所提模型对制丝过程的烘丝机工艺参数进行求解,求解过程与结果如图8所示。由图8可知,模型在迭代31

次后开始收敛,叶丝含水率与最优值12.7的误差小于 $1.47 \times 10^{-6}$ ,满足设计需求。制丝过程的最优工艺参数为: $a=20.32, b=6.004, c=29.5, d=9.43, e=170.82, f=521.14, g=60.16, h=36.97, j=37.78, k=47.74, l=-29.48, m=0.22, n=144.08, o=144.06, p=13.73, q=62.77, r=110.11$ 。




图8 优化过程

## 4 结语

本文方法在确保预测精度的同时,有效减少了模型输入的参数,提高了训练速度。从结果中也看出,主成分分析结合BP预测的平均相对误差绝对值为0.42%,相较于传统的BP网络预测模型和多元回归预测模型,分别减小了0.06%和1.08%,具有一定的有效性和优越性;采用遗传算法优化求解得到最佳工艺参数,实现了叶丝含水率的精确控制,且误差只有 $1.464 \times 10^{-6}$ ,为生产高质量的叶丝提供了一种新思路。

## 参考文献:

- [1] 汪文良,范兴,朱雪峰,等. 基于帕累托图的卷烟制丝工艺质量分析[J]. 现代农业科技,2021(13):235-239,243.
- [2] 金发岗,王雅琳,张鹏程,等. 随机森林和DE-ELM的烘丝机入口含水率预测[J]. 控制工程,2020,27(3):532-539.
- [3] 李自娟,刘博,高杨,等. 卷烟制丝环节关键工序水分预测模型的建立与检验[J]. 食品与机械,2020,36(10):190-195,205.
- [4] 顾茜,钱继春. 基于时序数据库与深度学习的制丝实时数据应用研究[J]. 中国烟草学报,2021,27(3):104-113.
- [5] 祁林,唐习书,王仕宏,等. 两段式滚筒烘丝机干燥模式对烟丝致香物质的影响[J]. 贵州农业科学,2020,48(11):100-104.
- [6] 刘远涛,陆妍. HDT气流烘丝机工艺参数对卷烟感官质量的影响[J]. 湖北农业科学,2020,59(S1):427-430.
- [7] 舒歆. 基于因子分析法的食品制造业公司绩效评价研究[J]. 湖北经济学院学报(人文社会科学版),2022,19(3):53-56.
- [8] 李冬辉,赵墨刊,高龙. 基于CNN-CRU的冷水机组传感器偏差故障诊断方法[J]. 湖南大学学报(自然科学版),2022,49(2):74-82.
- [9] 张立欣,张楠楠,张晓. 基于机器学习算法对苹果产地的判别分析[J]. 激光与光电子学进展,2022,59(4):451-457.
- [10] 冉星. 基于函数型主成分聚类的失业人口研究[J]. 东莞理工学院学报,2022,29(1):1-6.

收稿日期:2022-04-18