

1-2-2019

Multi-Response Parameters Optimization Based on PCA and Neural Network

Jianli Yu

1.School of Management Science Engineering, Zhengzhou University of Aeronautical, Zhengzhou 450046, China;;

Hongqi Huang

1.School of Management Science Engineering, Zhengzhou University of Aeronautical, Zhengzhou 450046, China; ;

Manxiang Miao

2.School of Mechatronics Engineering, Zhengzhou University of Aeronautical, Zhengzhou 450046, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Multi-Response Parameters Optimization Based on PCA and Neural Network

Abstract

Abstract: A multi-response parameters optimization method based on principal component analysis (PCA) and neural network is proposed. It is used to optimize temperature and time parameters in complex thermal polymerization process. By using the method of weighted PCA, two response indexes, capacity value and loss tangent value, are converted into a single quality performance index. The main effect value is used to identify the search range. The radical basis function (RBF) neural network model is established to search and identify the optimal process parameters. Results show that response indexes are improved and the optimization effect is obvious. Therefore, this study method is a convenient and effective method to solve the complicated nonlinear response process parameters optimization, and has practical application value.

Keywords

PCA, neural network, metallized film capacitor, parameter optimization

Recommended Citation

Yu Jianli, Huang Hongqi, Miao Manxiang. Multi-Response Parameters Optimization Based on PCA and Neural Network[J]. Journal of System Simulation, 2018, 30(1): 176-184.

基于主成分分析与神经网络的多响应参数优化

禹建丽¹, 黄鸿琦¹, 苗满香²

(1. 郑州航空工业管理学院 管理工程学院, 河南 郑州 450046; 2. 郑州航空工业管理学院 机电工程学院, 河南 郑州 450046)

摘要: 研究多响应参数优化问题, 给出一种基于主成分分析与神经网络的参数优化方法, 对复杂热聚合工艺中温度和时间参数进行优化设计。用加权主成分分析方法将容量值和损耗正切值两个响应质量指标转化为单一的质量绩效指标, 用其主效应值确定优化范围; 建立径向基神经网络模型, 搜索并确定最优工艺参数。结果表明, 该方法设计的最优工艺参数使两个响应指标均得到较大改善, 优化效果明显, 是解决复杂非线性多响应工艺参数优化的一种方便有效的方法, 具有实际应用价值。

关键词: 主成分分析; 神经网络; 金属化膜电容器; 参数优化

中图分类号: TP114.2 文献标识码: A 文章编号: 1004-731X (2018) 01-0176-09

DOI: 10.16182/j.issn1004731x.joss.201801022

Multi-Response Parameters Optimization Based on PCA and Neural Network

Yu Jianli¹, Huang Hongqi¹, Miao Manxiang²

(1. School of Management Science Engineering, Zhengzhou University of Aeronautical, Zhengzhou 450046, China;

2. School of Mechatronics Engineering, Zhengzhou University of Aeronautical, Zhengzhou 450046, China)

Abstract: A multi-response parameters optimization method based on principal component analysis (PCA) and neural network is proposed. It is used to optimize temperature and time parameters in complex thermal polymerization process. By using the method of weighted PCA, two response indexes, capacity value and loss tangent value, are converted into a single quality performance index. The main effect value is used to identify the search range. The radical basis function (RBF) neural network model is established to search and identify the optimal process parameters. Results show that response indexes are improved and the optimization effect is obvious. Therefore, this study method is a convenient and effective method to solve the complicated nonlinear response process parameters optimization, and has practical application value.

Keywords: PCA; neural network; metallized film capacitor; parameter optimization

引言

金属化聚丙烯薄膜电容器 (Metallized Polypropylene Film Capacitor, MPPFC)是在聚丙烯膜上用真空蒸镀的方法镀上一层很薄的铝金属等

做电极卷烧而成, 与普通电容器的电极材料相比, 省去了电极箔的厚度, 使得电容器单位容量的体积缩小, 易做成小型、容量大的电容器, 因此具有体积小、重量轻、电性能优良、耐高温、容量范围宽、高可靠性和产品寿命长等特点, 是当今脉冲功率系统中最常见的储能元件^[1-2]。

金属化薄膜电容器的使用过程中, 常会出现由于电容量衰减而造成产品不能达到抑制电源电磁干扰的效果或停止工作。其中, 膜层间的空气对电



收稿日期: 2015-11-17 修回日期: 2016-02-29;
基金项目: 国家自然科学基金(71171180), 河南省自然科学基金(142102210105);
作者简介: 禹建丽(1960-), 女, 河南, 博士, 教授, 研究方向为智能控制与质量管理工程。

<http://www.china-simulation.com>

容量的衰减影响较大, 通过电离等作用产生臭氧, 常温下分解为氧, 在低浓度下可瞬间氧化金属镀层, 形成不导电介质, 缩小了极板面积, 使电容器容量下降。热聚合是消除金属化薄膜层间空气的关键工序, 热聚合条件(温度和时间)对改善电容器容量衰减起着重要作用^[3], 若热聚合不充分将会导致容量下降, 损耗角正切值增大。对热聚合工艺过程温度和时间两个参数进行优化设计, 有望改善容量和损耗角正切值两个表征电容器性能的特性值, 从而提高电容器产品的品质。

对温度和时间两个热聚合工艺参数进行设计, 改善电容器的容值和损耗角正切值两个质量特性值, 属于多响应参数优化设计问题, 解决此类问题时, 由于多个响应之间可能存在一定的关联关系, 同一组参数难以使多个响应同时达到最优, 因此, 多响应参数优化问题比单响应优化更困难。如何确定一组合理的可控因子变量组合, 使多个响应相互妥协达到整体效果的最优, 是多响应参数优化设计的有效方法^[4-9]。加权主成分分析法可将具有一定相关性的多个响应指标, 重新组合成一组互不相关的新指标, 并能够将多响应参数设计问题转化为单一响应的参数设计问题^[10-12]。对经由加权主成分分析法得到的单一响应, 用实验设计方法进行参数设计, 得到的参数设计结果只能是实验中因子变量(影响因子)的有限个离散的水平组合值, 而热聚合工艺的温度和时间两个参数是连续变量, 最优参数有可能是所有离散值水平组合以外的其它组合值。在多变量参数优化设计中广泛应用的响应曲面法^[13-15]可以进行连续变量的优化设计。但是, 响应曲面法建立的因子变量与响应变量之间的映射函数模型是因子变量的一阶或二阶线性函数模型, 或者是可以化为一阶或二阶线性函数的模型, 不适于建立复杂非线性过程的函数关系模型。径向基函数(Radical Basis Function, 简记为 RBF)神经网络是一种高效的前馈式人工神经网络^[16-17], 具有较强的自学习能力和泛化能力, 能够逼近任意的非线性函数, 可以处理系统内的难以解析的规律性, 并

且结构简单, 训练速度快, 对于复杂的非线性映射, 无需事先了解其函数关系, 可以方便地建立其映射关系函数模型。

基于以上分析, 本文利用加权主成分分析方法将金属化薄膜电容器的多响应特性值容值和损耗角正切值转化为单一优化质量指标值, 然后利用径向基神经网络建立反映温度和时间两个因子值与单一优化质量指标值之间的映射模型, 通过神经网络搜索, 对电容器热聚合过程温度与时间两个工艺参数进行优化设计, 使电容器产品的容值和损耗角正切值两个质量特性达到整体优化, 实现以较少的实验次数得到理想的工艺参数优化设计, 以达到提高产品质量, 增加经济效益的目的。

1 主成分分析与神经网络模型概述

1.1 加权主成分分析

假设实际生产过程有 p 个响应, Y_1, Y_2, \dots, Y_p , 对响应值进行主成分分析, 可将 p 个响应转化为 $k(k \leq p)$ 个无关的主成分, Z_1, Z_2, \dots, Z_k 即:

$$Z_q = e_{q1}Y_1 + e_{q2}Y_2 + \dots + e_{qp}Y_p \quad (1)$$

Z_q 表示第 q 个主成分, Y_p 表示第 p 个响应, $Y = (Y_1, Y_2, \dots, Y_p)'$, $e_{q1}, e_{q2}, \dots, e_{qp}$ 表示第 q 个主成分的系数。主成分满足如下条件:

- 1) 每个主成分的系数平方和为 1, 即 $e_{q1}^2 + e_{q2}^2 + \dots + e_{qp}^2 = 1$;
- 2) 主成分互不相关, $Cov(Z_i, Z_j) = 0$, 其中 $i \neq j, i, j = 1, 2, \dots, k$, 即将具有一定相关性的多个指标, 重新组合成一组互不相关的新指标, 若忽视响应相关性的存在将会影响优化参数的选择;
- 3) 每一个主成分中所含响应的信息用方差贡献率表示($\alpha_q = \lambda_q / \sum_{q=1}^k \lambda_q$, λ_q 为 Y 的协方差矩阵的第 q 个特征值, 下同), 主成分按照方差依次递减排列, $Var(Z_1) \geq Var(Z_2) \geq \dots \geq Var(Z_k)$, 即主成分重要性依次减小。

利用 Minitab 软件进行主成分分析可得主成分

载荷矩阵及主成分方差贡献率，选取 $m(m \leq k \leq p)$ 个主成分，累计方差贡献率 r 需要满足公式：

$$r = \sum_{q=1}^m \lambda_q / \sum_{q=1}^k \lambda_q \geq 85\% \quad (2)$$

用前 m 个主成分 Z_1, Z_2, \dots, Z_m 替代原始变量 Y_1, Y_2, \dots, Y_p ，在降低变量维数的同时，能够保证足够的信息。加权主成分方法是将 m 个主成分的方差贡献率作为权重，得出 m 个主成分的加权和，作为多响应综合绩效指标 MPI(Multi-response Performance Index)：

$$MPI = \sum_{q=1}^m \alpha_q Z_q \quad (3)$$

通过比较分析 MPI 值可将多响应优化转化为单响应优化问题。

为保证多响应综合绩效指标 MPI 进行单响应优化的有效性，多响应指标中望大、望目、望小特性应该转化为相同的特性。对于望大特性的响应，MPI 越大，质量水平越高；对于望小特性的响应，MPI 越小，质量水平越高；对于望目特性的响应，可将其转化为望小特性。本文将响应均值与其目标值之差的绝对值作为响应值，即将望目特性转化为望小特性。

1.2 RBF 神经网络模型

径向基函数神经网络是由输入层、隐层和输出层构成的三层前向网络，如图 1 所示。




图 1 RBF 神经网络结构图

Fig. 1 RBF neural network model structure

RBF 神经网络学习算法需要求解基函数的中心、方差以及隐含层到输出层的权值。

RBF 神经网络的激活函数中较为常用且较优的是高斯函数：

$$R(x_p - c_i) = \exp\left(-\frac{1}{2\sigma^2} \|x_p - c_i\|^2\right) \quad (4)$$

式中： $\|x_p - c_i\|$ 表示欧式范数； c 表示高斯函数的中心； σ 表示高斯函数的方差。

图 1 中的径向基神经网络的输出层的输出：

$$y_j = \sum_{i=1}^h w_{ij} \exp\left(-\frac{1}{2\sigma^2} \|x_p - c_i\|^2\right) \quad (5)$$

式中： $x_p = (x_1^p, x_2^p, \dots, x_m^p)$ 表示第 p 个输入样本， $p=1, 2, \dots, P$ ， P 表示样本总数； c_i 表示网络隐层结点的中心； w_{ij} 表示隐含层到输出层的连接权值； $i=1, 2, \dots, h$ 表示隐层的节点数； y_j 表示与输入样本对应的网络的第 j 个输出结点的实际输出。

设 d 是样本的期望输出值，基函数的方差可表示为

$$\sigma = \frac{1}{p} \sum_j \|d_j - y_j c_i\|^2 \quad (6)$$

RBF 神经网络学习算法分为两个阶段：一是自组织学习阶段，寻求隐含层基函数的中心与方差；二是有导师学习阶段，寻求隐含层到输出层之间的连接权值。

基函数中心 c 用 K-均值聚类方法寻求，方法如下：

1) 初始化：随机选取 h 个训练样本作为聚类中心 $c_i(i=1, 2, \dots, h)$ 。

2) 将输入的训练样本按最近规则分组：根据 x_p 与中心为 c_i 之间的欧式距离将 x_p 分配到输入样本的各个聚类集合 $\mathcal{G}_p(p=1, 2, \dots, P)$ 中。

3) 重新调整聚类中心：计算各个聚类集合 \mathcal{G}_p 中训练样本的平均值，即新的聚类中心 c_i ，如果新的聚类中心不再发生变化，则此时得到的 c_i 即为 RBF 神经网络最终的基函数中心，否则返回 2)，进入下一轮迭代求解。

基函数方差 σ_i 由下式求解：

$$\sigma_i = \frac{c_{\max}}{\sqrt{2h}} \quad i=1, 2, \dots, h \quad (7)$$

式中： c_{\max} 表示所选取中心之间的最大距离。

隐层至输出层之间神经元的连接权值用最小二乘法直接得到。

2 热聚合工艺与实验数据

2.1 热聚合工艺分析

金属化聚丙烯薄膜电容器的生产过程暴露在大气中,目前的工艺水平使得膜层间存在的微量空气难以完全消除。在电容器工作时,空气在电场作用下可被电离产生臭氧,空气潮湿时击穿电位低更易产生大量臭氧,而臭氧可在常温下分解为氧,作为一种强氧化剂,在低浓度下可瞬间氧化金属镀层,形成不导电介质,缩小了极板面积,使电容器容量下降。因为,电容量是电容器性能的基本参数之一,所以,欲提高电容器质量,减缓电容量衰减,需减少膜层间的空气和潮气。

热聚合是消除金属化薄膜层之间空气和潮气的关键工艺,该工艺是将卷绕好的电容器芯子放入鼓风烘箱中,将温度控制在一定高温环境范围恒温加热一定时间,烘箱确保空气流通,温度分布均匀,待烘箱温度低于 60 °C 时热聚合工艺过程完成。由于聚丙烯薄膜具有受热收缩的物理特性,在加热过程中,聚丙烯在纵向、横向发生均匀热收缩,从而把卷绕时残留在金属化膜层间的空气挤出,同时因受热能蒸发掉吸附在膜上的潮气。

热聚合过程会提高电容器的紧密度从而增加产品的可靠性,温度控制过低时,将达不到薄膜收缩的效果;而如果只是一味地延长受热时间、提高受热温度,电容器芯子端面将受到损伤,降低电容器的载流能,同时可能出现电容器鼓肚,反而增加膜间缝隙。实际工作中,如果热聚合工艺中加热温度和恒温时间等参数设定不科学,会使得热聚合不充分,造成芯子定形不彻底,膜层松弛等现象,从而导致容量下降,损耗角正切值增大。电容器的损耗角正切值也是电容器可靠性评价的基本参数之一,是在规定的正弦交流电压和频率下,电容器的有功功率与无功功率的比值,是衡量电容器损耗特性的衡量参数,损耗角正切值越大,电容器发热越多,电容器损耗越大,电容器质量越差。

2.2 热聚合实验及数据整理

根据对热聚合工艺过程分析,为提高电容器产品的稳定性和可靠性,将电容器的两个质量特性值电容量和损耗角正切值作为待优化响应变量,将热聚合温度和时间作为影响因子变量,对某种铝金属化聚丙烯膜电容器热聚合工艺进行实验设计。将热聚合温度(记为 x_1)分别设定为 95 °C、100 °C、105 °C、110 °C、115 °C、120 °C 和 125 °C 等 7 个水平,记为 1、2、3、4、5、6、7 水平,将热聚合时间(记为 x_2)分别设定为 4 h、6 h、8 h、10 h 等 4 个水平,记为 1、2、3、4 水平,进行全面 28 组热聚合实验,各水平组合中温度设置在 1、2、3 水平的分别做 10 次重复实验,温度设置在 4、5、6、7 水平的分别做 5 次重复实验。响应变量容值(记为 y_1)为望目特性(目标值为 45.45 μF),响应变量损耗角正切值(记为 y_2)为望小特性。为统一为相同的特性,将容值特性值调整为容值与目标值之差的绝对值,使响应变量容值也变为望小特性。计算每组实验两个响应特性值的平均值,为消除量纲影响,对两个响应均值分别进行标准化处理,得到 28 组标准化响应均值 Y_1 、 Y_2 ,实验结果如表 1 所示。

3 用加权主成分分析法进行参数设计

为消除响应之间的相关性,同时将多响应优化参数转化为单一响应的优化参数,利用 Minitab 计算机软件对两个响应做加权主成分分析,主成分分别用 Z_1 、 Z_2 表示,其特征值及特征向量如表 2 所示。

根据(1)式,将主成分系数作为响应权重得到主成分 Z_1 与 Z_2 ;根据(3)式,将方差贡献率作为主成分的权重得到多响应绩效指标 MPI, MPI 的计算结果如表 1 所示。

$$Z_1 = 0.707 \times Y_1 + 0.707 \times Y_2$$

$$Z_2 = 0.707 \times Y_1 - 0.707 \times Y_2$$

$$MPI = 0.522 \times Z_1 + 0.478 \times Z_2 =$$

$$0.6919 \times Y_1 + 0.044 \times Y_2$$

表 1 实验结果数据及 MPI 值
Tab. 1 Table of experimental data and MPI value

试验 次序	影响因 子变量		响应变量均值		标准化 响应均值		MPI	试验 次序	影响因 子变量		响应变量均值		标准化 响应均值		MPI
	x_1	x_2	$y_1(\mu F)$	$y_2(\times 10^{-4})$	Y_1	Y_2			x_1	x_2	$y_1(\mu F)$	$y_2(\times 10^{-4})$	Y_1	Y_2	
1	1	1	0.205	3.8	0.534	1.081	0.411	15	4	3	0.019	3.6	-0.799	0.463	-0.551
2	1	2	0.033	3	-0.703	-1.390	-0.540	16	4	4	0.044	3.6	-0.622	0.463	-0.425
3	1	3	0.038	3.4	-0.666	-0.154	-0.476	17	5	1	0.123	3.6	-0.054	0.463	-0.024
4	1	4	0.010	3.6	-0.869	0.463	-0.600	18	5	2	0.064	2.8	-0.477	-2.008	-0.400
5	2	1	0.126	3.6	-0.029	0.463	-0.006	19	5	3	0.107	3.6	-0.169	0.463	-0.105
6	2	2	0.033	3.1	-0.700	-1.081	-0.529	20	5	4	0.131	3.8	0.005	1.081	0.037
7	2	3	0.004	3.7	-0.909	0.772	-0.618	21	6	1	0.164	3.8	0.241	1.081	0.204
8	2	4	0.006	3.3	-0.896	-0.463	-0.648	22	6	2	0.163	3	0.237	-1.390	0.124
9	3	1	0.066	3.9	-0.461	1.390	-0.283	23	6	3	0.230	3.6	0.716	0.463	0.521
10	3	2	0.014	3	-0.838	-1.390	-0.636	24	6	4	0.119	3.6	-0.080	0.463	-0.042
11	3	3	0.056	3.7	-0.536	0.772	-0.355	25	7	1	0.367	3.8	1.699	1.081	1.235
12	3	4	0.060	3.5	-0.510	0.154	-0.356	26	7	2	0.423	2.8	2.104	-2.008	1.425
13	4	1	0.026	3.4	-0.753	-0.154	-0.537	27	7	3	0.506	3.6	2.698	0.463	1.922
14	4	2	0.097	3	-0.244	-1.390	-0.216	28	7	4	0.419	3.4	2.075	-0.154	1.462

表 2 主成分分析表
Tab. 2 Table of principal component analysis

主 成 分	初始特征值			特征向量	
	特征值	方差 比率	累积 比率	Z_1	Z_2
1	1.043	0.522	0.522	0.707	0.707
2	0.956	0.478	1.000	0.707	-0.707

利用 Minitab 软件作 MPI 主效应图(如图 2 所示), 图中的点是每个因子各个水平的 MPI 变量的平均值, 由于 y_1 、 y_2 为望小特性, MPI 值越小, 该水平响应值越优, 即使主效应值最小的水平组合为最优参数组合, 如 MPI 主效应图中, x_1 在水平 2 对应的 MPI 主效应值最小, x_2 在水平 2 对应的 MPI 主效应值最小, 从而通过加权主成分分析得到最优参数组合为(2, 2)。

4 基于 RBF 神经网络的参数优化

在上述基于加权主成分分析方法的实验设计中, 影响因子温度取 95 °C~125 °C 之间 7 个离散水平值, 时间取 4~10 h 之间 4 个离散水平值, 进行相对较少的实验次数, 得到了有限个参数组合中的最优设计结果。由于温度和时间是连续变量, 最优

参数有可能是上述所有离散值水平组合以外的其它组合值。本节利用 RBF 神经网络模型, 改进基于加权主成分分析的多响应参数优化方法, 在不增加实验次数的前提下, 进一步搜索离散水平限制域外的优化参数组合, 使多质量特性达到更好的整体优化效果。




图 2 MPI 主效应图
Fig. 2 MPI value main effect diagram

4.1 构建 RBF 神经网络模型

将所有离散可控因子水平组合作为神经网络的输入变量, 对应的多响应绩效指标 MPI 值作为神经网络的期望输出变量, 建立 RBF 神经网络模型。

利用 Matlab 应用软件构建网络模型:

$p=[x_1 \ x_2]'$; x_1 、 x_2 分别为影响因子变量温度和时间的水平所有组合值(见表 1), 作为 RBF 神经网络模型的输入向量;

$t=[y]'$; y 表示对应的响应变量 MPI 值(见表 1), 作为输出向量;

$net=newrbe(p,t,spread)$; RBF 神经网络训练, $spread$ 为径向基层的散布常数;

$y11=sim(net,p)$; 用 $sim()$ 函数对训练后的网络进行回检试验;

$e=t-y11$; e 为期望值与回检值之间的误差向量;

$ee=mse(e)$; $mse(e)$ 为均方误差, 其值越小网络拟合度越高。

网络训练将径向基层的散布常数 $spread$ 设置为 0.8, 期望值与回检值之间的误差向量为:

$$e=1.0e-014 *$$

-0.0722; 0.1332; 0.1332; -0.0333; 0.1337;
-0.0111; -0.0555; 0.0555; 0.1721; 0.0999; 0.1110;
0.0333; -0.0111; -0.0250; 0.0555; -0.0167; 0.0465;
0.0333; 0.0430; 0.0520; 0.0472; -0.0111; 0.0111;
0.0035; 0.0666; 0.0222; 0.0222; 0.0888

均方误差 $ee=5.2413e^{-31}$, 经网络训练, 误差达到了精度要求, 网络回检的均方误差也非常小, 网络构建良好。

4.2 用 RBF 神经网络模型搜索最优工艺参数

利用已训练得到的 RBF 神经网络模型, 搜索最优工艺参数。

迭代 1: 由加权主成分分析方法得到的设计参数是(2, 2), 然而从主效应图(参见图 2)中可知 x_1 在水平 2、3、4 对应的 MPI 主效应值比较接近且

均较小, x_2 也是在水平 2、3、4 对应的 MPI 主效应值比较接近且均较小。因此, 为搜索最优工艺参数, 将搜索范围确定为: x_1 选取水平 1.5、2、2.5、3、3.5、4、4.5, x_2 选取水平 1.5、2、2.5、3、3.5、4、4.5。将上述 x_1 与 x_2 水平的全部组合代入 RBF 神经网络模型, 计算 RBF 神经网络对应输出的 MPI 主效应值, 依主效应值 MPI 的最小值对应的参数水平组合作为迭代 1 的搜索结果(搜索方法下同), 迭代 1 的搜索结果如表 3 所示。

由表 3 中第一次迭代搜索结果可知, 最优参数组合为(1.5, 3.5), 其 MPI 值为-0.930 4。

迭代 2: 在迭代 1 最优组合附近选取参数组合, x_1 选取水平 1.2、1.25、1.3、1.35、1.4, 等间距 0.05 直至 1.8, 共 13 个水平, x_2 选取水平 3.2、3.25、3.3、3.35、3.4, 等间距 0.05 直至 3.8, 共 13 个水平。通过 RBF 神经网络计算, 第 2 次迭代最优参数组合为(1.5, 3.65), 其 MPI 值为-0.959。

迭代 3: 从第 2 次搜索结果数据中分析(如图 3)得出, x_1 取 1.4 到 1.6 之间水平值, x_2 取 3.58 到 3.76 之间水平值时, MPI 值均较小, 在该范围内, 将 x_1 取 1.41, 1.42, 1.43, 直到 1.6 共 21 个水平值, x_2 取 3.58, 3.59, 3.6, 直到 3.76 共 19 个水平值, 重复进行第三次迭代搜索。第三次迭代搜索结果的最优参数组合为(1.49, 3.67)、(1.49, 3.68)、(1.5, 3.67)、(1.5, 3.68), 其 MPI 值均为-0.959 6, 4 组最优参数组合非常接近, 且该次迭代较上一次迭代 MPI 值减少仅为 0.000 6, 迭代搜索完成。考虑到生产的经济性和生产仪器的精度限制, 迭代 3 最优参数组合选择(1.5, 3.67)。

表 3 迭代 1 的搜索结果
Tab. 3 Predicted results of iteration 1

x_2	x_1						
	1.5	2.0	2.5	3.0	3.5	4.0	4.5
1.5	-0.383 7	-0.649 9	-0.674 8	-0.731 2	-0.930 4	-0.816 9	-0.024 9
2.0	-0.392 9	-0.529 0	-0.537 8	-0.618 0	-0.789 6	-0.648 0	0.103 1
2.5	-0.508 1	-0.586 3	-0.466 5	-0.419 2	-0.539 6	-0.427 2	0.242 2
3.0	-0.638 9	-0.636 0	-0.445 6	-0.355 0	-0.460 0	-0.356 0	0.287 7
3.5	-0.610 6	-0.428 9	-0.357 9	-0.477 2	-0.622 5	-0.441 6	0.262 3
4.0	-0.491 7	-0.216 0	-0.270 5	-0.551 0	-0.692 2	-0.425 0	0.308 7
4.5	-0.402 6	-0.267 4	-0.258 2	-0.371 7	-0.409 8	-0.148 9	0.491 3

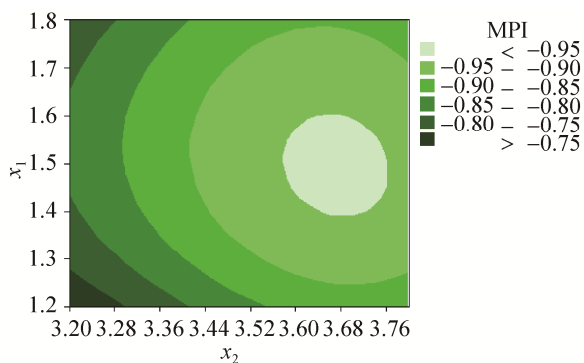


图 3 MPI 与 x_1 、 x_2 的等值线图
Fig. 3 Contour map among MPI with x_1 、 x_2

5 响应预测

由于 RBF 神经网络具有良好的泛化能力，本文建立 RBF 神经网络预测模型，对优化参数 $(x_1, x_2) = (1.5, 3.67)$ 处的容值与损耗角正切值进行响应预测。

根据表 1 的实验数据，将影响因子变量温度 (x_1) 和时间 (x_2) 作为 RBF 神经网络的输入变量，将响应变量容值和损耗角正切值的均值分别作为输出变量建立两个 RBF 神经网络预测模型。利用 Matlab 应用软件编程，用表 1 中的数据作为训练样本，对两个 RBF 神经网络进行训练，调用语句 `net=newrb(p,t,GOLE,spread)`，训练精度 GOLE 设置为 0，容值和损耗角正切值所构建的 RBF 神经网络的散布常数 `spread` 分别设置为 0.6 和 0.1，预测影响因子温度和时间的最优化参数 $(x_1, x_2) = (1.5, 3.67)$ 处的容值和损耗角正切值，预测结果如表 4 所示。

表 4 最优化参数响应
Tab. 4 Optimization parameters of responses

质量特性	响应预测值	神经网络回检均方误差/mse
容值	45.4477 μF	5.589 6e ⁻²⁹
损耗角	3.000 0 $\times 10^{-4}$	4.895 2e ⁻³⁰

两个 RBF 神经网络模型回检预测输出值与期望值的均方误差均非常小，说明构建的 RBF 神经网络预测模型性能良好。

实际生产中采用的工艺参数温度为 110 $^{\circ}\text{C}$ ，

时间为 8 h，即 $(x_1, x_2) = (4, 3)$ ，对应的响应容值的均值为 45.469 8 μF ，损耗角正切的均值为 3.6×10^{-4} 。因此，利用基于主成分分析与 RBF 神经网络的工艺参数优化设计得到的最优工艺参数，对电容器的容值和损耗角正切值两个质量特性均有所改善，达到了比较理想的工艺参数优化设计效果。

与企业实际应用参数及主成分分析法设计参数的响应进行比较，结果如表 5 所示。可以看出，加权主成分分析方法得到的设计参数，使电容器的损耗角正切值得到较大的改善，而容值的优化结果不够理想。用本文方法设计的最优化工艺参数，使得电容器容值和损耗角正切值较原来企业实际参数的相应水平值均得到较大改善，优化效果明显。

表 5 参数优化结果对比
Tab. 5 Parameter optimization result contrast

方法	因子组合	容值-中心值 (y_1)	损耗角 (y_2)
企业实际应用	(4, 3)	0.0198	3.6
加权主成分分析法	(2, 2)	0.0336	3.1
本文优化方法	(1.5, 3.67)	0.0023	3.0

6 结论

本文给出了一种基于 RBF 神经网络的改进加权主成分分析多响应参数优化方法。利用加权主成分分析方法消除变量间相关性，将多响应特性值转化成为单一优化质量指标值。为克服加权主成分分析方法最优参数组合选择的局限性，引进 RBF 人工神经网络模型，对加权主成分分析的多响应参数优化方法进行改进。在不增加实验次数的条件下，将可控因子水平组合作为神经网络的输入变量，对应的多响应绩效指标 MPI 值作为神经网络的输出变量，建立 RBF 神经网络模型。利用主成分分析的 MPI 主效应值，确定最优参数组合的搜索范围，用 RBF 神经网络模型进行迭代搜索，直到搜索过程收敛，得到了铝金属化膜电容器热聚合工艺温度和时间参数的最优水平组合 $(1.5, 3.67)$ 。

将可控因子变量温度 (x_1) 和时间 (x_2) 作为 RBF

神经网络的输入变量, 响应变量容值和损耗角正切值的均值分别作为输出变量建立两个 RBF 神经网络预测模型, 对最优参数水平组合的响应进行预测。

由于 RBF 神经网络具有较强的学习能力, 适用于建立非线性输入输出映射模型, 因此, 对于复杂非线性生产工艺过程的多响应参数优化问题, 用本文给出的基于神经网络的多响应参数优化方法, 可以在不增加实验次数的条件下, 设计出最优工艺参数, 达到有效改善产品的多个质量指标的目的。

参考文献:

- [1] 李智威, 李化, 杨佩原, 等. 不同场强下金属化聚丙烯膜电容器泄漏特性[J]. 电工技术学报, 2013, 28(9): 274-280.
Li Z W, Li H, Yang P Y, et al. Leakage Characteristic of Metallized Polypropylene Film Capacitors under Different Electric Fields[J]. Transactions of China Electrotechnical Society, 2013, 28(9): 274-280.
- [2] 彭宝华, 周经伦, 冯静, 等. 金属化膜脉冲电容器剩余寿命预测方法研究[J]. 电子学报, 2011, 39(11): 2674-2679.
Peng B H, Zhou J L, Feng J, et al. Residual Lifetime Prediction of Metallized Film Pulse Capacitors[J]. Acta Electronica Sinica, 2011, 39(11): 2674-2679.
- [3] 樊红杰. 金属化薄膜电容器电容量衰减的解决方案[J]. 电子元件与材料, 2011, 30(9): 40-42.
Fan H J. Design and optimization of capacitance decay program for metallized film capacitors[J]. Electronic Components and Materials, 2011, 30(9): 40-42.
- [4] Candioti L V, De Zan M M, Camara S, et al. Goicoechea. Experimental Design and Multiple Response Optimization. Using the Desirability Function in Analytical Methods Development[J]. Talanta (S0039-9140), 2014, 124: 123-138.
- [5] Salmasnia A, Bashiri M. A new desirability function-based method for correlated multiple response optimization [J]. The International Journal of Advanced Manufacturing Technology(S0268-3768), 2015, 76: 1047-1062.
- [6] 张流洋, 马义中, 汪建均, 等. 考虑协变量的相关多响应稳健优化设计[J]. 系统工程, 2015, 33(2): 126-133.
Zhang L Y, Ma Y Z, Wang J J, et al. Correlated multi-response robust design and optimization with considering covariates[J]. Systems Engineering, 2015, 32(2): 126-133.
- [7] 汪建均, 马义中, 翟云焕. 相关多质量特性的优化设计[J]. 管理工程学报, 2011, 25(2): 66-73.
Wang J J, Ma Y Z, Zhai Y H. Optimization Design of Correlated Multiple Quality Characteristics[J]. Journal of Industrial Engineering and Engineering Management, 2011, 25(2): 66-73.
- [8] 田亮, 刘芳, 刘鑫屏, 等. 高速率变负荷模式下火电机组协调控制系统参数优化[J]. 系统仿真学报, 2015, 27(7): 1532-1540.
Tian L, Liu F, Liu X P, et al. Parameter Optimization on Coordinated Control System of Thermal Power Units in High Rate Variable Load Operation Mode[J]. Journal of System Simulation, 2015, 27(7): 1532-1540.
- [9] 刘长良, 马增辉. Smith 预估模型参数仿真分析及多目标优化[J]. 系统仿真学报, 2014, 26(8): 1706-1712.
Liu C L, Ma Z H. Simulation Analysis and Multi-objective Optimization of Smith-Predictor Parameters Tuning[J]. Journal of System Simulation, 2014, 26(8): 1706-1712.
- [10] Shit J S, Tzeng Y F, Yang J B. Principal Component Analysis for Multiple Quality Characteristics Optimization of Metal Inert Gas Welding Aluminum Foam Plate [J]. Materials and Design(S0261-3069), 2011, 32(3): 1253-1261.
- [11] Gauri S K, Pal S. The Principal Component Analysis (PCA)-Based Approaches for Multi-response Optimization: Some Areas of Concerns[J]. The International Journal of Advanced Manufacturing Technology(S0268-3768), 2014, 70: 1875-1887.
- [12] 张迎冬, 何桢. 改进的主成分分析法在多响应优化中的应用[J]. 组合机床与自动化加工技术, 2012(11): 97-100.
Zhang Y D, He Z. Application of improved principal component analysis method to the multi-response optimization[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2012(11): 97-100.
- [13] Zhang Y Y, Pan B C. Modeling Batch and Column Phosphate Removal by Hydrated Ferric Oxide-based Nanocomposite Using Response Surface Methodology and Artificial Neural Network[J]. Chemical Engineering Journal(S1385-8947), 2014, 249: 111-120.
- [14] Peng A H, Xiao X M, Yue R. Process Parameter Optimization for Fused Deposition Modeling Using Response Surface Methodology Combine with Fuzzy Inference System[J]. The International Journal of Advanced Manufacturing Technology(S0268-3768), 2014, 73: 87-100.