

多目标优化控制在中药提取中的应用

黄挚雄¹, 章志兵^{1, 2}, 罗 安³, 李 佳¹

(1. 中南大学 信息科学与工程学院, 湖南 长沙, 410083;
2. 株洲南车时代电气股份有限公司 技术中心, 湖南 株洲, 412001;
3. 湖南大学 电气与信息工程学院, 湖南 长沙, 410082)

摘要: 针对中药生产提取工段控制量多、耦合强的特点, 以减小提取罐中药液温度稳定时间、提高挥发油的回收量、减小能源消耗总量和增加有效药液提取量4个指标作为优化目标, 提出一种利用神经网络对控制器进行多目标优化的设计方案, 神经网络的权值和结构分别用遗传算法和变结构算法训练。实践结果表明, 设计出的中药生产提取工段的控制器具有良好的综合性能: 缩短了药液温度达到稳定值的时间, 提高了药液和挥发油的产量, 降低了总能耗, 很好地完成了多项目标的优化。

关键词: 中药生产; 提取; 多目标优化; 遗传算法; 变结构算法

中图分类号: TP183; TP202⁺. 7 文献标识码: A 文章编号: 1672-7207(2006)04-0790-06

Multi-objective optimal control and its application in withdrawing Chinese traditional medicine

HUANG Zhixiong¹, ZHANG Zhibing^{1, 2}, LUO An³, LI Jia¹

(1. School of Information Science and Engineering, Central South University, Changsha 410083, China;
2. Technology Center, Zhuzhou CSR Times Electric Co., Ltd, Zhuzhou 412001, China;
3. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: A multi-objective optimal control scheme, which introduced a neural network to optimize the controller, was put forward. Meanwhile, genetic algorithm and variable structure algorithm were used to train the weight parameters and structure of neural network. Because of excessive controlling variables and strong coupling in withdrawing Chinese traditional medicine, decreasing the steady time of the temperature in the withdrawing pot, increasing the output of the naphtha, decreasing the energy consumption and enhancing the amount of effective liquid in withdrawing were taken as four optimal objectives. The results show the designed controller of withdrawing Chinese traditional medicine has better synthetic performance and the optimizing of objectives, such as less steady time, lower energy consumption, more naphtha and effective liquid are completely achieved.

Key words: production of Chinese traditional medicine; withdrawing; multi-objective optimization; genetic algorithm; variable structure algorithm

提取工段是中药生产的一个重要环节, 该工段的各设备能否正常、高效地运转, 直接关系到中药产品的质量和生产厂家的经济效益。

中药生产提取工段的控制是典型的复杂过程控

制, 变量多, 扰动大, 并且在控制过程中还存在着非线性、大延时、时变和强耦合等因素的困扰, 由此带来的问题是: 各被控量之间存在不同程度的关联, 系统不易建立准确的数学模型, 这样传统控制

收稿日期: 2005-12-05

基金项目: 国家计委中药生产自动化示范工程(计高技[2002]2141号)

作者简介: 黄挚雄(1960-), 男, 湖南长沙人, 教授, 从事非线性系统建模与控制、电力系统控制理论及应用研究

通讯作者: 章志兵, 男, 硕士; 电话: 0733-8493784(O); E-mail: ladder_2003@163.com

就难以完成对生产过程的有效控制; 提取工段另外一个显著的特点是控制目标多, 如: 药液的加热提取, 挥发油的回收以及水冷系统等过程都需要控制动态平衡。传统控制显然很难使上述目标同时达到最优^[1~3]。基于神经网络的控制方法, 在优化计算、模式识别、智能控制等领域得到广泛应用^[4~6], 具有强大的学习能力和定量数据的直接处理能力, 通过网络的离线训练和在线自学习, 使控制器有自适应和自调整能力, 从而能进一步提高对中药提取生产过程的实时控制效果。为此, 本文作者采用神经网络来完成中药生产提取工段的多目标优化决策问题, 以提高中药提取率, 获取良好的经济效益。

1 中药生产提取工段系统

1.1 工艺

提取工序的目的是将中药材的有效成分提取出来, 通常采用的溶剂是水。通过加料口向提取罐内加入 120 kg 的药材, 分 3 次加入纯净水以使药材的有效成分充分析出, 每次加水约 700 L。加水后通入蒸汽煎煮罐中的药材和水的混合物, 长时间沸腾并检验成分后得到有效药液。药材的提取次数、提取温度和沸腾度等参数由工艺决定。提取工序的主要设备除了提取罐外还有冷却器和油水分离器, 二者组合完成对挥发油(副产品)提取的控制, 其提取工段流程如图 1 所示。

1.2 控制系统结构

在提取生产过程中, 提取罐内的温度和压力等变量的平衡很难控制。提取罐中压力过大和泡沫面过高时导致药液跑料, 减少药液的提取量; 压力过小又会使药液蒸发过程缓慢。提取罐夹层压力的调节阀开度过大将导致药液温度达到平衡点的调节时间加长。回收挥发油时蒸汽和冷凝水也要维持动态平衡: 如果蒸汽量过大而冷凝水量较小, 会使挥发油在冷却器中充分冷却, 这样不但浪费蒸汽资源, 而且使挥发油的回收量降低; 如果蒸汽量过小而冷凝水量较大, 则冷凝器中出现真空, 导致挥发油不能沿正常管道流出。

对上述难题的控制, 若采用传统控制方法, 当扰动较大或者蒸汽过量时, 要经过若干次调节才能使整个系统恢复平衡, 影响提取药液的质量并且浪费能源; 同时超调增大会导致调节过程增长, 调节阀频繁动作, 缩短了它们的维修周期和使用寿命。理想的控制效果是: 在线检测罐内温度 θ 和压力 p , 当温度和压力离给定值比较接近时, 控制器实时给出调节阀的开度, 这样使阀门能够 1 次或者少量次调节到位, 避免阀门的频繁动作, 同时减小能耗, 稳定药液质量。因此, 在中药生产提取工段, 构造一个基于神经网络的多目标优化控制系统, 其结构如图 2 所示。图中: σ 为调节阀控制指令信号; $F(X)$ 为满意目标输出; Q 为调节阀开度; y 为提取罐内温度、压力的实时值。

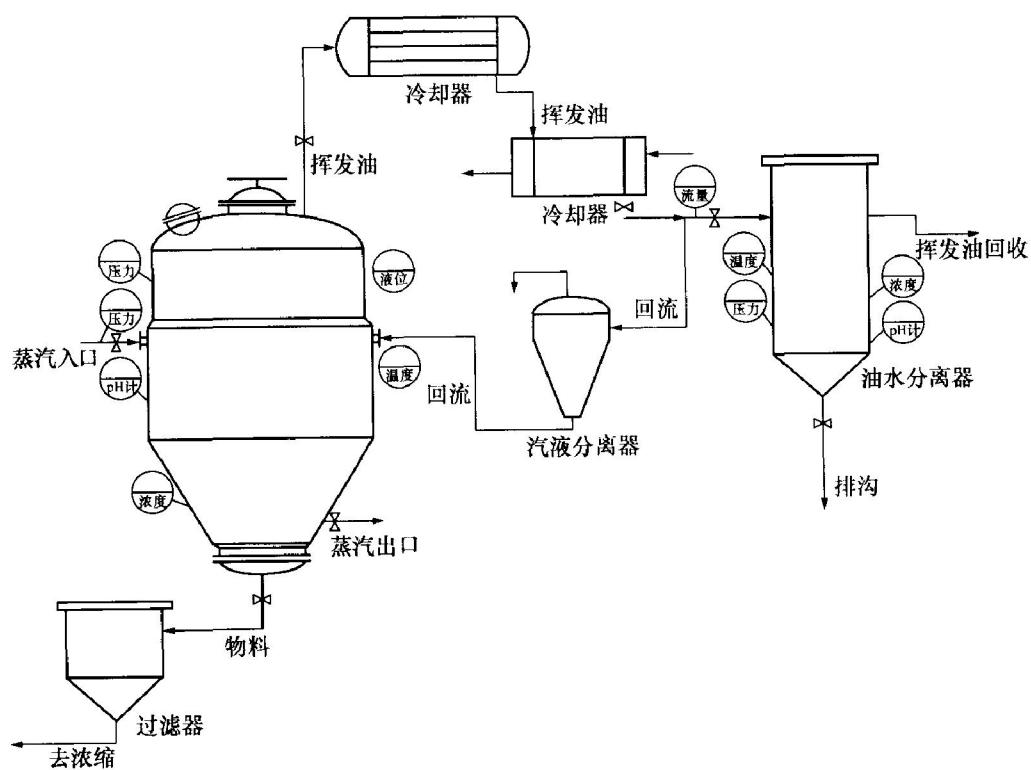


图 1 中药生产过程提取工段流程图

Fig. 1 Flow chart of withdrawing of Chinese traditional medicine

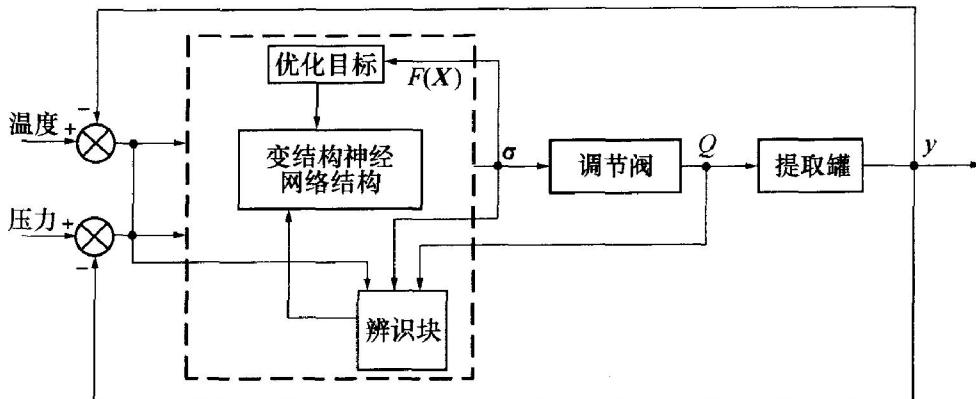


图 2 提取工段控制系统结构

Fig. 2 Frame of control system in withdrawing of Chinese traditional medicine

2 控制器的设计

2.1 多目标优化控制的数学模型

在多目标控制系统中, 应使各个目标达到最优, 但是由于某个目标的变化可能导致其他目标向反方向变化, 因此, 系统的多目标优化控制决策就是在满足一定约束条件的情况下, 寻找一个不使某一目标变劣而能使其他目标更优的可行解或者满意解。

提取工段控制器优化目标如下:

目标 1: 提取罐内温度达到预定值平衡点的调节时间少;

目标 2: 蒸汽与冷凝水的动态平衡调节, 确保挥发油回收量更大;

目标 3: 能源损耗总量小;

目标 4: 压力和泡沫高度的平衡, 保证药液提取量更多。

构建如下函数 $f_1(\mathbf{X})$, $f_2(\mathbf{X})$, $f_3(\mathbf{X})$ 和 $f_4(\mathbf{X})$ 分别代表所优化的目标 1, 2, 3 和 4。

$$\begin{cases} f_1(\mathbf{X}) = \min \sum_{i=1}^n t_{is}, \quad t_{is} \leq t_{\max}, \\ f_2(\mathbf{X}) = \max \sum_{i=1}^{n-1} A_i, \\ f_3(\mathbf{X}) = \min \sum_{i=1}^n (k_1 a + k_2 b), \\ f_4(\mathbf{X}) = \max \sum_{i=1}^n B_i, \quad B_{\min} \leq \sum_{i=1}^n B_i \leq B_{\max}. \end{cases} \quad (1)$$

式中: n 为提取次数; t_{is} 为各次提取时药液温度的调节时间; A_i 为各次挥发油产量(最后一次不收回挥发油); k_1 和 k_2 分别为柴油和电的价格因子; a

为耗油量; b 为耗电量; t_{\max} 为厂方提出最大调节时间; B_{\min} 和 B_{\max} 为提取药液量的上、下限, 提取液的量过多或者过少都不合格。

因此, 多目标优化决策的数学模型如下:

$$\begin{cases} \text{Find } \sigma = [\theta, \dot{\theta}, p, \dot{p}]^T, \\ \text{Opt } F(\mathbf{X}) = [f_1(\mathbf{X}), f_2(\mathbf{X}), f_3(\mathbf{X}), f_4(\mathbf{X})]^T, \\ \text{S. t. } \mathbf{X} = g(\sigma, Q). \end{cases} \quad (2)$$

式中: $[\theta, \dot{\theta}, p, \dot{p}]^T$ 为系统状态变量; $\mathbf{X} = g(\sigma, Q)$ 为系统辨识所得到的系统状态方程^[7]。

采用动态规划^[8]方法, 求得系统各单目标函数 $f_k(\mathbf{X})$ 的最优控制解 $\bar{\sigma}_k$, 目标函数的最优值为 $f_k[g(\bar{\sigma}_k, Q)]$ 。将 $\bar{\sigma}_k$ 代入其余的目标函数表达式, 得 $f_q[g(\bar{\sigma}_k, Q)] (q=1, 2, 3, 4, q \neq k)$ 。对各单目标 $f_k(\mathbf{X}) (k=1, 2, 3, 4)$ 循环按上述方法求解。然后找出各单目标函数可能的最小值 m_k 和最大值 M_k , 即

$$\begin{cases} m_k = \min_{1 \leq q \leq 4} f_q[g(\bar{\sigma}_k, Q)] = f_k[g(\bar{\sigma}_k)], \\ M_k = \max_{1 \leq q \leq 4} f_q[g(\bar{\sigma}_k, Q)]. \end{cases} \quad (3)$$

式中: $k=1, 2, 3, 4$ 。因此, 提取工段控制系统的多目标优化设计问题已经转化为在满足一定约束条件下, 使上述 4 个最大、最小函数达到协调的最优解搜索问题。下面采用一种改进的神经网络控制方法解决此问题。

2.2 变结构的神经网络控制

采用 3 层前向神经网络实现提取工段的多目标优化控制, 神经网络的基本结构如图 3 所示。其中, S 为隐含层神经元, W 为神经网络输出层的权值。输入层神经元数目即系统的 4 个优化目标, 输出层神经元为遗传算法中的染色体 \mathbf{Y} 。

为了提高神经网络的收敛速度, 有效地避免神

经网络陷入局部极值^[9], 从而实时控制调节阀的开度, 在神经网络基础上改进算法^[10, 11], 使其经过两大部分训练: 一是采用遗传算法训练神经网络的权值; 二是采用变结构算法训练神经网络的结构。

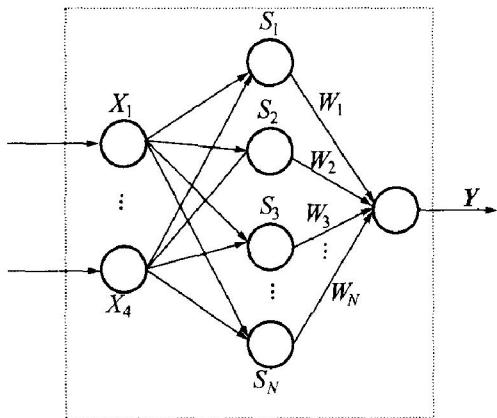


图 3 变结构神经网络控制器示意图

Fig. 3 Schematic diagram of variable structure neural network controller

2.2.1 神经网络学习样本的确定

神经网络模型对学习样本有致密性、遍历性和相容性的要求, 为了减小网络的输出与实际输出的误差, 将正交设计法^[12]引入神经网络样本设计, 尽可能减少训练网络占用的资源。正交法选取的样本有代表性强、无矛盾样本、所需试验次数很少的特点。文中神经网络的输入变量为 4 个, 设定位级为 3, 若采用全面试验进行完全位级的组合, 共需 $3^4 = 81$ 组试验, 而采用正交试验, 则只需 9 组试验。

2.2.2 神经网络权值的训练

遗传算法是一种基于自然选择和自然遗传的全局优化算法, 采用遗传算法优化神经网络权值的一个重要问题是如何定义合理的适应度函数。根据优化的目标, 构造适应度函数如下:

$$\begin{cases} F_1(\mathbf{Y}) = K_1 - f_1(\mathbf{X}), \\ F_2(\mathbf{Y}) = f_2(\mathbf{X}), \\ F_3(\mathbf{Y}) = K_2 - f_3(\mathbf{X}), \\ F_4(\mathbf{Y}) = f_4(\mathbf{X}). \end{cases} \quad (4)$$

式中: K_1 和 K_2 为常数, 其值根据经验确定; 染色体 $\mathbf{Y} = [W_1, W_2, \dots, W_N]^T$ 表示成神经网络权值基因链形式, N 为神经网络隐层神经元数。染色体编码采用实数编码的方式, 初始种群规模数为 M , 由伪随机数在染色体 \mathbf{Y} 所对应的论域空间内产生。

遗传算法训练神经网络权值的核心是协调各适应度函数之间的关系, 尽量使它们同时比较大。为此, 在遗传算法中引入 ε 制约法, 给 3 个适应度函

数 $F_2(\mathbf{Y})$, $F_3(\mathbf{Y})$ 和 $F_4(\mathbf{Y})$ 设定阈值常数进行制约, 其中:

$$\begin{cases} \min f_1(\mathbf{X}) \leq F_2(\mathbf{Y}) \leq \max f_2(\mathbf{X}), \\ \min f_3(\mathbf{X}) \leq F_3(\mathbf{Y}) \leq K_2, \\ 0 \leq F_4(\mathbf{Y}) \leq \max f_4(\mathbf{X}). \end{cases} \quad (5)$$

将 $F_1(\mathbf{Y})$ 的寻优问题限定在一个约束空间内, 即

$$\begin{cases} \max F_1(\mathbf{Y}), \\ \mathbf{Y} \in \{\mathbf{Y} | \varepsilon_{\min} \leq F_j(\mathbf{Y}) \leq \varepsilon_{\max}, j = 2, 3, 4\}. \end{cases} \quad (6)$$

这样, 不仅可以使种群向 $F_1(\mathbf{Y})$ 较大的方向进化, 而且能使 $F_2(\mathbf{Y})$, $F_3(\mathbf{Y})$ 和 $F_4(\mathbf{Y})$ 较好的基因, 避免算法陷入 $F_1(\mathbf{Y})$ 的局部最优解。

对第 t 代染色体实施如下选择操作:

a. 将 $F_1(i)$, $F_2(i)$, $F_3(i)$ 或 $F_4(i)$ 最大的染色体 i 以 100% 的概率选择到下一代。

b. 保留满足 $\varepsilon_{\min} \leq F_j(i) \leq \varepsilon_{\max} (j = 2, 3, 4)$ 的染色体 i , 也就是保留使 $F_j (j = 2, 3, 4)$ 较好的染色体, 期待经过遗传操作出现 F_1 更大的染色体, 使得在该条件下 F_1 较大的染色体随着进化过程而不断优化。

c. 对 $\varepsilon_{\min} \leq F_j(i) \leq \varepsilon_{\max} (j = 2, 3)$ 但不满足 $\varepsilon_{\min} \leq F_4(i) \leq \varepsilon_{\max}$ 的染色体 i 以概率 P_{S23} 进行选择, 使得满足 F_2 和 F_3 阈值条件的染色体朝着 F_1 和 F_4 更好的方向进化; 同理, 可选择另外两类满足条件的染色体。

d. 对 $\varepsilon_{\min} \leq F_2(i) \leq \varepsilon_{\max}$ 但不满足 $\varepsilon_{\min} \leq F_j(i) \leq \varepsilon_{\max} (j = 3, 4)$ 的染色体 i 以概率 P_{S2} 进行选择, 使得满足 F_2 阈值条件的染色体朝着 F_1 , F_3 和 F_4 更好的方向进化; 同理, 可选择另外两类满足条件的染色体;

e. 对不满足 $\varepsilon_{\min} \leq F_j(i) \leq \varepsilon_{\max} (j = 2, 3, 4)$ 的染色体 i 以概率 P_S 进行选择, 为产生满足阈值条件或良种条件的染色体创造条件。其中:

$$P_{S23} = \frac{F_1(i)}{\sum_{j=1}^M F_1(j)} \cdot \left[1 - \frac{\min\{| \varepsilon_{\min} - F_4(i) |, | F_4(i) - \varepsilon_{\max} |\}}{\sum_{j=1}^M \min\{| \varepsilon_{\min} - F_4(j) |, | F_4(j) - \varepsilon_{\max} |\}} \right]. \quad (7)$$

$$P_{S2} = \frac{F_1(i)}{\sum_{j=1}^M F_1(j)} \cdot \left[1 - \frac{\min\{| \varepsilon_{\min} - F_3(i) |, | F_3(i) - \varepsilon_{\max} |\}}{\sum_{j=1}^M \min\{| \varepsilon_{\min} - F_3(j) |, | F_3(j) - \varepsilon_{\max} |\}} \right]. \quad (8)$$

$$\left| 1 - \frac{\min\{|\varepsilon_{\min} - F_4(i)|, |F_4(i) - \varepsilon_{\max}| \}}{\sum_{j=1}^M \min\{|\varepsilon_{\min} - F_4(j)|, |F_4(j) - \varepsilon_{\max}| \}} \right|^n. \quad (8)$$

$$P_S = \frac{F_1(i)}{\sum_{j=1}^M F_1(j)}.$$

$$\left| 1 - \frac{\min\{|\varepsilon_{\min} - F_2(i)|, |F_2(i) - \varepsilon_{\max}| \}}{\sum_{j=1}^M \min\{|\varepsilon_{\min} - F_2(j)|, |F_2(j) - \varepsilon_{\max}| \}} \right|^n.$$

$$\left| 1 - \frac{\min\{|\varepsilon_{\min} - F_3(i)|, |F_3(i) - \varepsilon_{\max}| \}}{\sum_{j=1}^M \min\{|\varepsilon_{\min} - F_3(j)|, |F_3(j) - \varepsilon_{\max}| \}} \right|^n.$$

$$\left| 1 - \frac{\min\{|\varepsilon_{\min} - F_4(i)|, |F_4(i) - \varepsilon_{\max}| \}}{\sum_{j=1}^M \min\{|\varepsilon_{\min} - F_4(j)|, |F_4(j) - \varepsilon_{\max}| \}} \right|^n. \quad (9)$$

式中: M 为种群规模(种群内染色体数目)。

f. 为保持种群规模不变, 在上述选择操作完成后, 根据已选染色体数量, 复制一定数目的良种染色体, 即 **a.** 和 **b.** 中选出的染色体, 以补足种群。

通过上面的染色体选择机制, 使 $F_2(Y)$, $F_3(Y)$ 和 $F_4(Y)$ 较好的染色体有更大机会进入下一代种群, 从而使种群内染色体对 $F_2(Y)$, $F_3(Y)$ 和 $F_4(Y)$ 的进化沿着满足阈值条件且靠近上界的方向进行。上述算法使网络权值经过遗传算法的逐代整定后得到了训练, 同时也间接实现了多个控制目标的优化。

2.2.3 神经网络结构的训练

以神经网络输出误差的平方和函数 δ 为神经网络的性能评价标准:

$$\delta = \frac{1}{2} \sum_q (\sigma - v)^2. \quad (10)$$

经过训练 n 步后, 其输出衰减率为

$$D = \frac{\delta(m) - \delta(m+n)}{\delta(m)}. \quad (11)$$

式中: σ 和 v 分别为输出层的实际输出和期望输出; q 为训练样本序号; $\delta(m)$ 和 $\delta(m+n)$ 分别为第 m 步和第 $(m+n)$ 步训练输出误差平方和。

神经网络训练每学习 n 步后(n 可根据需要取值), 根据以下规则进行网络结构调整:

a. 设定输出衰减率 D 的适度范围为 $[D_1, D_2]$;

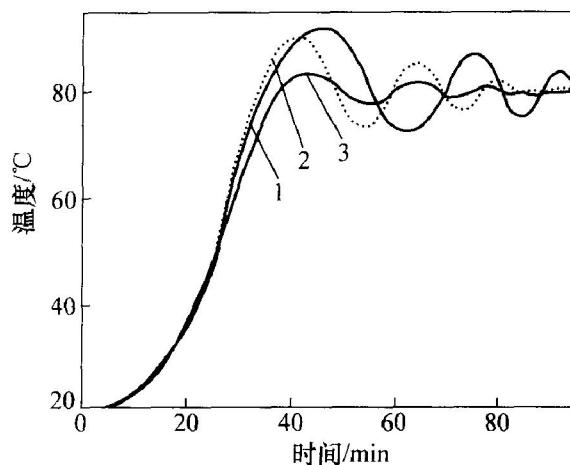
b. 当第 $(m+n)$ 步的衰减率 $D(m+n) > D_2$ 时, 表明网络性能优良, 网络结构保持不变;

c. 当第 $(m+n)$ 步的衰减率 $D(m+n) \in [D_1, D_2]$ 时, 表明网络性能还可以, 网络结构保持不变;

d. 当第 $(m+n)$ 步的衰减率 $D(m+n) < D_1$ 时, 表明网络性能差, 网络很难收敛, 网络隐层节点数增加 1。

3 优化结果

该算法已经用于哈药集团长沙慈航制药有限公司提取生产工段自动控制系统。对提取罐中的药液温度进行实时跟踪, 其设定值为 80 ℃, 控制方式不同时分别绘出它们的曲线, 如图 4 所示。



1—手动控制; 2—传统 PID 控制; 3—多目标优化控制

图 4 不同控制方式时提取罐药液温度曲线

Fig. 4 Temperature curves of effective liquid in withdrawing pot by different control methods

从图 4 可以看出, 提取罐中药液温度的控制有大滞后的特征。该系统没有完成自动化改造前(手动控制), 由于对提取罐中药液温度的控制全凭人的直觉和经验, 所以温度曲线与理论曲线相差较大; 系统完成自动化改造后, 分别用 2 种不同算法控制; 与传统 PID 控制相比, 多目标优化控制使温度的最大超调减小, 振荡周期也相应变短, 从而使药液温度达到稳定值的时间大大缩短。

采用文中提出的多目标优化控制算法后, 挥发油回收量和药液提取量显著提高, 能源总耗也有不同程度地降低。采用不同控制方式时, 各项重要控制结果如表 1 所示。

从表 1 可知: 采用多目标优化的先进控制算法后, 与手动操作相比, 挥发油提取率提高 30%, 药液提取率提高 12.64%, 能耗总额降低 28.25%; 与传统 PID 控制相比, 挥发油提取率提高 12.07%, 药液提取率提高 6.2%, 能耗总额降低 18.20%。由此可见, 基于神经网络的多目标优化算法在中药生

产提取工段发挥了重要作用, 大大提高了生产效率, 降低了生产成本。

表1 不同控制方式下系统的控制结果比较

Table 1 Comparing results of system with different control methods

控制方式	挥发油回收量/kg	药液提取量/L	柴油消耗量/L	耗电量/(kW·h)	能耗总金额/元
手动控制	50	1 820	200	250	855.5
传统PID控制	58	1 930	160	320	750.4
多目标优化控制	65	2 050	125	300	613.8

注: 能源消耗由柴油(燃烧产生蒸汽)消耗和电消耗两部分组成, 柴油 3.59 元/L, 电 0.55 元/(kW·h)。

4 结 论

a. 引入遗传算法和变结构算法训练神经网络控制器的权值和结构以达到控制目标的优化, 减少了药液温度达到稳定值的时间, 增加了挥发油的回收量和药液的提取量, 降低了整套系统的能源消耗总量。

b. 新控制算法的引入解决了药液的加热提取、挥发油的回收以及水冷系统等动态过程的平衡问题。

参考文献:

- [1] 颜文俊, 张森林. 新型多目标优化控制策略及其应用研究[J]. 浙江大学学报: 工学版, 2004, 38(6): 692-696.
YAN Wen-jun, ZHANG Sen-lin. New multiobjective optimization control and its application to nonlinear evaporation process [J]. Journal of Zhejiang University: Engineering Science, 2004, 38(6): 692-696.
- [2] 汤伟, 施颂椒, 赵小梅, 等. 纸浆洗涤过程双目标优化分布式控制系统[J]. 控制理论与应用, 2002, 19(4): 555-560.
TANG Wei, SHI Song-jiao, ZHAO Xiao-mei, et al. Pulp washing process DCS based on double-objective optimization [J]. Control Theory and Applications, 2002, 19(4): 555-560.
- [3] 梁治安, 叶庆凯. 动态系统控制器的多目标优化设计方法. [J]. 自动化学报, 2001, 27(3): 424-427.
LIANG Zhi-an, YE Qing-kai. A designing method for multiobjective optimization controllers [J]. Acta Automatica Sinica, 2001, 27(3): 424-427.

- [4] 王耀南. 智能控制系统—模糊逻辑·专家系统·神经网络控制[M]. 长沙: 湖南大学出版社, 1996.
WANG Yao-nan. Intelligent control system: fuzzy logic · expert system · ANN for control [M]. Changsha: Hunan University Press, 1996.
- [5] Huang S H, Zhang H C. Artificial neural network in manufacturing: concepts applications, and perspectives [J]. IEEE Transaction on Components, Packaging and Manufacturing Technology, 1994, 17(2): 212-228.
- [6] Narendra K S, Parthasarathy K. Identification and control systems using neural networks [J]. IEEE Trans on Neural Networks, 1990, 1(1): 4-27
- [7] 舒迪前, 饶立昌, 柴天佑. 自适应控制[M]. 沈阳: 东北大学出版社, 1994.
SHU Di-qian, RAO Li-chang, CHAI Tian-you. Adaptive control [M]. Shenyang: Northeastern University Press, 1994.
- [8] 胡中楫, 邹伯敏, 林冬青, 等. 最优控制原理及其应用[M]. 杭州: 浙江大学出版社, 1988.
HU Zhong-ji, ZOU Bo-min, LIN Dong-qing, et al. Theory and application of optimal control [M]. Hangzhou: Zhejiang University Press, 1988.
- [9] 邱焕耀, 毛宗源. 变结构模糊神经网络在交流解耦变结构系统中的应用[J]. 控制理论与应用, 1999, 16(5): 673-676.
QIU Huan-yao, MAO Zong-yuan. The application of variable structure fuzzy neural network in AC decoupling variable system [J]. Control Theory and Applications, 1999, 16(5): 673-676.
- [10] 侯祥林, 陈长征, 虞和济, 等. 神经网络权值和阈值的优化方法[J]. 东北大学学报: 自然科学版, 1999, 20(4): 447-450.
HOU Xiang-lin, CHEN Chang-zheng, YU He-ji, et al. Optimum method about weights and thresholds of neural network [J]. Journal of Northeastern University: Natural Science, 1999, 20(4): 447-450.
- [11] 钟守楠, 蔡伟. 多目标拟神经优化方法[J]. 武汉水利电力大学学报, 2000, 33(5): 102-106.
ZHONG Shou-nan, CAI Wei. Multiobjective quasi neural optimization method [J]. J Wuhan Univ Hydr Elec Eng, 2000, 33(5): 102-106.
- [12] 周斌, 李玉梅, 志贺圣一. 神经网络内燃机排放模型学习样本的选定[J]. 西南交通大学学报, 2002, 37(6): 659-663.
ZHOU Bin, LI Yu-mei, Shiga S. Selection of the learning samples of neural networks for internal combustion engine emission [J]. Journal of Southwest Jiaotong University, 2002, 37(6): 659-663.