

磨浆过程输出纤维长度随机分布预测 PDF 控制

李明杰¹ 周平¹

摘要 磨浆过程作为制浆和造纸工业最为重要的生产环节之一,其输出纤维长度随机分布 (Fiber length stochastic distribution, FLSD) 形状直接决定着后续造纸过程的能耗和纸品质量. 针对传统的均值和方差难以描述输出 FLSD 特征,即具有非高斯分布特性,本文提出一种磨浆过程输出 FLSD 的预测概率密度函数 (Probability density function, PDF) 控制方法. 首先,采用径向基函数 (Radical basis function, RBF) 神经网络逼近输出 FLSD 的 PDF,在采用迭代学习方法完成基函数参数整定基础上对相应权值向量进行估计. 其次,针对权值之间存在强耦合特点,利用随机权神经网络 (Random vector functional-link networks, RVFLNs) 建立表征输入变量和权值之间关系的预测模型. 最后,基于建立的输出 FLSD 模型设计预测 PDF 控制器,最终实现对期望输出 PDF 的跟踪控制. 基于工业数据实验验证了所提方法的有效性,为磨浆过程优化运行和控制提供理论依据.

关键词 磨浆过程, 纤维长度随机分布, 预测 PDF 控制, 随机权神经网络

引用格式 李明杰, 周平. 磨浆过程输出纤维长度随机分布预测 PDF 控制. 自动化学报, 2019, 45(10): 1923–1932

DOI 10.16383/j.aas.2018.c170225

Predictive PDF Control of Output Fiber Length Stochastic Distribution in Refining Process

LI Ming-Jie¹ ZHOU Ping¹

Abstract As one of the most important production links in the pulp and papermaking industry, the output fiber length stochastic distribution (FLSD) shaping of the refining process directly determines the energy consumption and paper quality of the subsequent papermaking processes. The traditional mean and variance are insufficient to describe the characteristics of the output FLSD, which displays non-Gaussian distributional properties. This paper proposes a predictive probability density function (PDF) control method for the output FLSD in the refining process. Firstly, use the radical basis function (RBF) neural network to approximate PDF of the output FLSD, the iterative learning technique is utilized to tune the parameters of basis functions, and the corresponding weights vector can be estimated. Secondly, in view of the strong coupling between these weighting vectors, the random vector functional link networks (RVFLNs) are employed to characterize the prediction model between the input variables and the weights. Finally, we design the predictive PDF controller based on the established output FLSD model, thus realizing the tracking control of the desired output PDF. Furthermore, the industrial data based experiment verifies the effectiveness of the proposed method, which provides theoretical basis for optimal operation and control of the refining process.

Key words Refining process, fiber length stochastic distribution (FLSD), predictive PDF control, random vector functional-link networks (RVFLNs)

Citation Li Ming-Jie, Zhou Ping. Predictive PDF control of output fiber length stochastic distribution in refining process. *Acta Automatica Sinica*, 2019, 45(10): 1923–1932

磨浆过程主要为后续造纸过程提供满足相应物理特性的纸浆纤维,同时也是保证纸品质量的前提.

收稿日期 2017-04-27 录用日期 2017-09-15
Manuscript received April 27, 2017; accepted September 15, 2017

国家自然科学基金 (61890934, 61473064, 61790572, 61333007), 中央高校基本科研业务费项目 (N180802003, N160805001) 资助
Supported by National Natural Science Foundation of China (61890934, 61473064, 61790572, 61333007) and the Fundamental Research Funds for the Central Universities (N180802003, N160805001)

本文责任编辑 吴立刚
Recommended by Associate Editor WU Li-Gang
1. 东北大学流程工业综合自动化国家重点实验室 沈阳 110819
1. State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110819

但由于磨机物理结构复杂性以及磨浆运行过程中受外界不确定因素的影响,导致纤维长度具有较强的随机分布特性,而传统的均值或者方差并不足以表征整个纤维长度随机分布 (Fiber length stochastic distribution, FLSD) 特征,即具有非高斯分布特性^[1]. 而事实上, FLSD 形状作为衡量磨浆过程中最主要的生产指标之一,不仅影响到纸浆脱水效率和后续造纸过程的电耗,而且直接影响到整个制浆和造纸工业的能耗和最终的纸品质量^[2–6]. 在这种情况下,就必须寻找一种能够对磨浆过程输出 FLSD 进行有效控制的方法.

虽然一些学者较早地意识到 FLSD 在纸浆生产

过程中的重要作用,但目前仍利用离线获得的纤维长度的均值和方差作为衡量纸浆纤维质量的生产指标^[3-9].如文献[3-6]采用长纤维百分含量作为评价纸浆质量的工艺指标,而事实上,这种以统计纤维束长度的均值和方差并足以有效表征整个纤维长度的分布特征,甚至会导致 FLSD 信息的缺失,这主要因为木片等富含纤维的纸浆原料经过盘磨机的横向挤压和纵向帚化后,虽然使得纤维束逐渐分解成单根纤维,然而,也导致纤维长度的分布形状具有很强的随机性和不确定性.此外,加之纤维长度分布在线检测仪器缺失,使得通过离线纤维长度的均值和方差来调整过程操作变量,其检测的滞后性难以使纸浆纤维质量稳定在工艺要求范围内,致使长纤维百分含量的控制大多过度依赖操作人员的经验,然而人工调整主观性较强,常常造成工况波动大,严重影响磨浆过程生产指标的稳定性.

另一方面,现有针对随机动态系统的最小方差控制、自校正控制、随机线性二次型控制,均假设系统服从高斯分布,主要集中在针对过程输出随机变量的均值和方差进行建模和控制,然而,针对输出变量服从非高斯分布的有界动态随机系统,1996年王宏教授提出了直接设计控制器以使输出 PDF 形状跟踪期望 PDF 形状的控制策略,并系统地提出了多种建模和控制方法^[10-18].这类控制策略包含了传统以输出均值和方差为目的的随机控制方法,具有更为广泛的应用.近些年,随机分布控制理论已成功应用于各类具有随机分布动态特性的工业过程,如造纸过程的絮凝粒径分布^[10,12]、燃烧过程的火焰分布^[18-19]、聚合过程的分子量分布^[20]、铜粗选过程的泡沫尺寸分布^[21]等,这些过程输出随机变量均不能满足高斯分布特征,并且具有较强的随机分布动态特性.

另外,在制浆和造纸工业领域,目前已有多种用于测量纸浆纤维各种形态参数的在线自动化检测和

分析仪器,这些检测仪器常采用数码 CCD 摄像机获取的纤维图像经数字化后传输到计算机系统进行处理,通过实时二维图像分析软件将每根纤维从图像信号中识别出来,逐一测量纤维的形态参数,能迅速准确地获得纤维形态参数是测量结果.如加拿大 Optest 公司 FQA-360、芬兰 Kajaani 公司 FS-300、丹麦 Fiber-Visions 等^[8-9],这些先进测量仪器为研究基于磨浆过程输出 FLSD 的建模及控制提供了技术支持.

磨浆过程输出 FLSD 具有典型的非高斯分布动态特性,采用传统纤维长度的均值和方差难以有效描述其分布特征,本文根据随机分布相关控制理论^[10],利用 RBF 神经网络逼近输出 FLSD 的 PDF,为了改善传统线性权值模型^[14-19]精度不高、泛化能力不强等问题,采用随机神经网络(Random vector functional-link networks, RVFLNs)^[22-24]建立表征输入变量和权值向量之间的非线性模型,基于磨浆过程输出 FLSD 模型提出了一种预测 PDF 控制方法,实现了对输出 FLSD 形状的跟踪控制,基于工业数据实验表明了所提方法的有效性.

1 磨浆过程描述

典型的磨浆过程工艺流程如图 1 所示,磨浆过程即是将植物原料经盘磨机反复研磨后,经汽浆分离后获得造纸所需的纸浆纤维.其主要包括喂料系统,供水系统,液压伺服系统和磨盘调速系统.当磨机运行时,首先将经过将被筛选木片在蒸煮仓里进行高温预处理,经清除杂质后的木片在螺旋喂料器作用下送入磨室.磨机作为磨浆过程中的核心设备,主要有定盘、动盘、电液伺服装置和主电机等组成.当预处理后木片和稀释水注入磨区后,利用电液伺服装置可以实时调节磨盘间隙,动盘在主电机带动下通过机械摩擦、剪切、撕裂、




图 1 典型磨浆过程工艺流程图

Fig. 1 Flowsheet of typical refining process

切割等作用, 最终将预处理后木片分解为单根纤维. 然后, 纸浆通过送入旋风分离器实现汽浆分离, 最终获得满足造纸过程所需的纸浆纤维. 可以看出, 由于工艺流程长及现场环境恶劣等原因, 若操作变量调节不当, 即便通过磨机的反复研磨, 也难以获得满意的 FLSD 形状, 这样不但导致纸浆质量无法满足工艺要求, 而且也极易造成原料浪费和过程能耗过大.

磨浆过程的主要操作变量包括磨盘间隙、稀释水流量、动盘转速和螺旋喂料量等. 研究表明: 长纤维百分含量作为衡量磨浆过程纤维长度均值的工艺指标, 主要与注入磨区的稀释水流量和磨盘间隙密切相关^[3, 5-6], 由于磨浆过程主要目的是对纤维进行切断、压溃、吸水膨胀, 最终使纤维束分离为单根纤维, 所以, 磨盘间隙直接影响纸浆纤维被切断和压溃强度. 同时, 为使植物纤维能够较好地分离为单根纤维, 需要让纤维获得足够的水份进行膨胀, 纸浆纤维的吸水膨胀程度主要取决于注入磨区的稀释水流量. 而植物纤维被切断、压溃强度以及吸水膨胀程度决定了最终获得的纤维长度随机分布形状. 另外, 结合实际工程经验, 通常情况下分别通过改变喂料螺旋转速和供水泵转速来调节螺旋喂料量和稀释水流量, 根据工程实践经验, 当产量一定的情况下, 动盘转速是固定不变的, 螺旋喂料量也是恒定的. 因此, 稀释水流量和磨盘间隙不但可以看作影响长纤维百分含量的主要变量, 同样也可以作为影响最终 FLSD 形状的关键变量, 对整个制浆生产流程都起着极为关键的作用. 因此, 本文将稀释水流量和磨盘间隙作为影响磨浆过程输出 FLSD 形状的关键输入变量.

2 控制策略

根据有界动态随机分布控制相关理论^[10] 可知, 随机分布系统模型主要由随机变量的 PDF 输出部分和权值与输入变量之间的动态部分组成. 为了表示输入变量和输出 PDF 之间的动态关系, 常引入一

组基函数 (如 B 样条基函数^[16-17, 20-21]、RBF 基函数^[15, 18-19]) 来逼近输出随机变量的 PDF, 通过调节基函数的权值来控制输出 PDF 形状, 这样将随机分布系统的输出 PDF 和输入变量之间的动态关系转化为权值向量和输入变量之间的动态关系, 最终通过对相对应权值的控制实现对输出 PDF 形状的动态调节. 为此, 本文针对磨浆过程输出 FLSD 提出预测 PDF 控制策略如图 2 所示, 具体如下:

1) 首先, 需寻找一组合适的 RBF 基函数来逼近输出 FLSD 的 PDF. 采用 RBF 神经网络逼近输出 PDF 的均方根, 基于迭代学习方法实现 RBF 基函数参数整定, 并对实际输出 PDF 相应权值向量进行估计.

2) 其次, 针对常规线性权值向量模型精度不高, 泛化能力不强等缺点, 本文基于随机神经网络^[22-24] 方法建立输入变量和前 $n-1$ 个权值向量之间的非线性模型, 进而获得磨浆过程输出 FLSD 模型.

3) 最后, 基于输出 FLSD 模型设计预测 PDF 控制器, 使得输出 PDF 获得良好的目标跟踪能力.

3 纤维长度随机分布预测 PDF 控制

3.1 随机分布系统模型

随着数据采集技术和检测仪器的快速发展, 对随机变量的输出 PDF 等已经有了较为成熟的检测方法. 为了方便描述各种随机过程, 假设 $z(k) \in [a, \zeta]$ 为描述动态随机系统输出的一致有界随机过程变量, $u(k) \in \mathbf{R}^m$ 为 k 时刻控制随机系统分布形状的输入向量, 这表明在任一采样时刻 k , $z(k)$ 就可以通过其概率密度函数来描述, 其定义式如下:

$$P(a < z(k) < \zeta, u(k)) = \int_a^\zeta \gamma(y, u(k)) dy \quad (1)$$

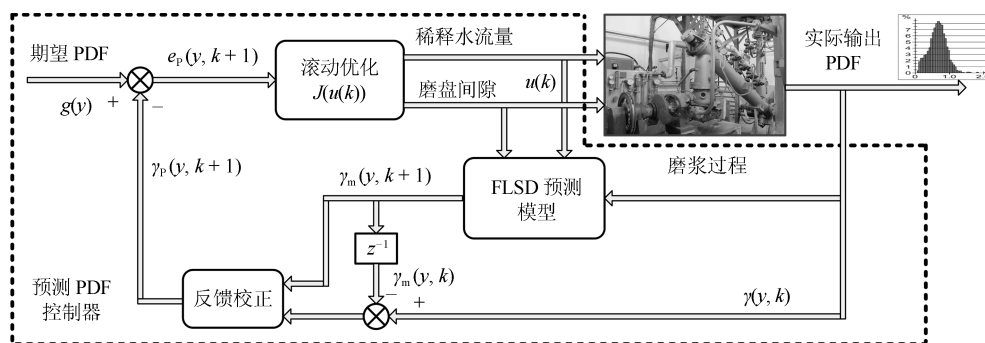


图 2 输出纤维长度随机分布预测 PDF 控制策略图

Fig. 2 Strategy diagram of the predictive PDF control for the output FLSD

式中, $P(a < z(k) < \zeta, u(k))$ 表示随机系统在 $u(k)$ 作用下输出落在区间 $[a, \zeta]$ 内的概率, 即 $z(k)$ 的输出 PDF $\gamma(y, u(k))$ 形状由输入变量 $u(k)$ 控制. 假设区间 $[a, b]$ 为已知, 并且输出 PDF $\gamma(y, u(k))$ 连续且有界, 采用如下具有高斯型 RBF 神经网络来逼近输出的 PDF 均方根

$$R_l(y) = \exp\left(-\frac{(y - \mu_l)^2}{\sigma_l^2}\right), l = 1, 2, \dots, n \quad (2)$$

式中, l 表示第 l 个网络节点, n 为网络节点总数, μ_l 和 σ_l 分别表示第 l 个网络节点函数的中心值和宽度. 根据 RBF 神经网络逼近原理, 此时输出 PDF $\gamma(y, u(k))$ 的均方根可以表示为

$$\sqrt{\gamma(y, u(k))} = \mathbf{C}(y)\mathbf{V}(k) + R_n(y)\omega_n(k) + e_0(y, k) \quad (3)$$

式中, $\mathbf{C}(y) = [R_1(y), R_2(y), \dots, R_{n-1}(y)]$, $\mathbf{V}(k) = [\omega_1(k), \omega_2(k), \dots, \omega_{n-1}(k)]^T$, $\omega_n(k)$ 为第 n 个基函数相对应的权值, $e_0(y, k)$ 为逼近误差. 此外, 由于输出 PDF 需要满足隐含条件

$$\int_a^b \gamma(y, u(k))dy = 1 \quad (4)$$

为便于分析忽略逼近误差 $e_0(y, k)$, 则第 n 个权值 $\omega_n(k)$ 可用权值向量 $\mathbf{V}(k)$ 的非线性函数 $h(\mathbf{V}(k))$ 表示为

$$h(\mathbf{V}(k)) = \frac{\sqrt{\Sigma_2 - \mathbf{V}^T(k)\Sigma_3\mathbf{V}(k)} - \Sigma_1\mathbf{V}(k)}{\Sigma_2} \quad (5)$$

式中, $\Sigma_0 = \int_a^b \mathbf{C}^T(y)\mathbf{C}(y)dy$, $\Sigma_1 = \int_a^b R_n(y)\mathbf{C}(y)dy$, $\Sigma_2 = \int_a^b R_n^2(y)dy$, $\Sigma_3 = \Sigma_2\Sigma_0 - \Sigma_1^T\Sigma_1$.

从式 (5) 可以看出, 若保证非线性函数 $h(\mathbf{V}(k))$ 存在, 需满足如下约束条件:

$$\mathbf{V}^T(k)\Sigma_4\mathbf{V}(k) < 1 \quad (6)$$

式中, $\Sigma_4 = \Sigma_2^{-1}\Sigma_3 > 0$, 不等式 (6) 可以看作在动态权值向量 $\mathbf{V}(k)$ 需满足的约束条件. 由式 (5) 可以看出, 一旦所有的基函数确定, 由于有界区间 $[a, b]$ 已知, $\mathbf{C}(y)$ 和 $R_n(y)$ 均已知, 这就意味着在 n 个权值中有 $n - 1$ 个是相互独立的.

当实际工业过程中输出随机变量的 PDF 可测量时, 可通过如式 (7)~(9) 方法对相应的权值进行估计. 结合式 (3) 和式 (5) 所示的输出 PDF 的均方根可以表示为

$$\sqrt{\gamma(y, u(k))} = \begin{bmatrix} \mathbf{C}(y) & R_n(y) \end{bmatrix} \begin{bmatrix} \mathbf{V}(k) \\ h(\mathbf{V}(k)) \end{bmatrix} \quad (7)$$

对式 (7) 两边左乘 $[\mathbf{C}(y) R_n(y)]^T$, 并对两端在区间 $[a, b]$ 上进行积分, 由此可得到:

$$\begin{bmatrix} A_1 \\ A_2 \end{bmatrix} = \begin{bmatrix} \Sigma_0 & \Sigma_1 \\ \Sigma_1^T & \Sigma_2 \end{bmatrix} \begin{bmatrix} \mathbf{V}(k) \\ h(\mathbf{V}(k)) \end{bmatrix} \quad (8)$$

式中, $A_1 = \int_a^b \mathbf{C}^T(y)\sqrt{\gamma(y, u(k))}dy$, $A_2 = \int_a^b R_n(y)\sqrt{\gamma(y, u(k))}dy$.

当矩阵 $\begin{bmatrix} \Sigma_0 & \Sigma_1 \\ \Sigma_1^T & \Sigma_2 \end{bmatrix}$ 非奇异时, 式 (8) 所示权值可以通过矩阵求逆获得:

$$\begin{bmatrix} \mathbf{V}(k) \\ h(\mathbf{V}(k)) \end{bmatrix} = \begin{bmatrix} \Sigma_0 & \Sigma_1 \\ \Sigma_1^T & \Sigma_2 \end{bmatrix}^{-1} \begin{bmatrix} A_1 \\ A_2 \end{bmatrix} \quad (9)$$

式 (9) 揭示了输出随机变量的 PDF 与权值向量之间的关系, 可以看出当 RBF 基函数确定后, 只要输出 PDF 可测量, 便可很容易获得相应的权值向量. 通常情况下在获得相应的权值向量之后, 采用最小二乘法或子空间辨识法获得权值和输入变量之间的线性动态模型^[15, 18-20]. 从式 (9) 可以看出, 在 RBF 基函数已知的情况下, 若要获得理想的输出 FLSD 模型. 首先, 需要对不同时刻实际输出 PDF 进行权值估计. 其次, 建立输入变量和权值向量之间动态模型. 然而, 由于实际工业过程高度非线性、机理复杂等原因存在, 采用常规线性模型难以有效描述权值向量的动态特性. 为此, 必须采用有效手段, 获取基于磨浆过程输出 FLSD 模型, 以实现 FLSD 形状的在线连续估计及控制.

另外, 对于不能或者难以获得机理模型的复杂工业过程, 基于数据驱动建模方法通常被看作一种非常有效的替代手段. 目前, 常见的数据驱动建模方法主要有支持向量机方法^[25]、模糊推理方法^[26]、案例推理方法^[27] 以及随机神经网络方法^[22] 等. 其中, 随机神经网络作为一种简单易用、有效的单隐层前馈神经网络学习算法, 在保证逼近任意连续函数的前提下, 采用随机给定神经元隐含层权值和偏置, 通过计算隐含层输出矩阵的广义逆建立学习网络, 克服了传统单隐层神经网络的缺点, 由于训练速度快, 模型结构简单、易于实现以及泛化能力强等鲜明特点, 在很多领域获得广泛应用^[23-24]. 本文利用随机神经网络方法建立输出变量和前 $n - 1$ 个权值向量之间非线性预测模型. 因此, 最终磨浆过程输出 FLSD 模型可以表示为

$$\begin{cases} \mathbf{V}(k+1) = f(\mathbf{V}(k), \mathbf{u}(k)) \\ \sqrt{\gamma(y, \mathbf{u}(k))} = \mathbf{C}(y)\mathbf{V}(k) + R_n(y)h(\mathbf{V}(k)) \end{cases} \quad (10)$$

式中, $f(\cdot)$ 为表示过程输入和权值之间的非线性表达式, 可以看出在控制输入和输出 PDF 可测量情况下, 同时在 RBF 基函数已知时, 在利用式 (9) 获得权值向量之后, 通过随机神经网络方法很容易获得输入变量和权值向量之间的非线性模型.

从式 (10) 明显发现要获得理想的输出 FLSD 模型, 首先需要选择一组合适的 RBF 基函数, 若 RBF 基函数的中心值和宽度选择不当, 不但影响 PDF 输出部分的近似精度, 而且也难以获得满意的输出 FLSD 模型. 因此, RBF 基函数的选择对于磨浆过程输出 FLSD 的建模精度显得至关重要.

3.1.1 RBF 基函数参数整定

为了提高随机分布模型输出 PDF 对实际输出 PDF 逼近精度, 文献 [15] 中提出了一种基于迭代学习控制原理的 RBF 基函数参数更新算法, 假设给出初始的 RBF 基函数参数, 结合实际输出 PDF 数据, 通过式 (9) 可以获得初始的权值向量, 并将此初始向量乘以相应的初始 RBF 基函数, 便可获得近似的输出 PDF. 基于迭代学习控制原理, RBF 基函数的中心值和宽度要根据上一迭代学习周期的逼近误差来调节, 通过对 RBF 基函数参数的反复调节, 最终使得将近似输出 PDF 与实际输出 PDF 之间误差最小. 因此, 所采用的性能指标主要考察近似输出 PDF 跟踪期望的输出 PDF 能力, 所以所用误差来自迭代周期内的每一个采样点, 采用如下性能指标

$$J_p(i) = \int_a^b \left(\sqrt{\gamma_{p+1}(y, u_i)} - \sqrt{g(y)} \right)^2 dy \quad (11)$$

式中, $J_p(i)$ 可以表示为第 p 个迭代周期后第 i 个采样时刻 RBF 神经网络近似输出 PDF 的均方根与期望输出 PDF $g(y)$ 的均方根之间的逼近性能指标. 同时, 定义在第 p 个迭代周期后 M 个采样点近似输出 PDF 分别与期望输出 PDF 之间构成性能指标向量可表示如下

$$\mathbf{E}_p = [J_p(1), J_p(2), \dots, J_p(M)]^T \quad (12)$$

为了实现式 (10) 所示的 RBF 基函数参数整定, 在相邻的第 p 次和第 $(p+1)$ 次迭代学习周期内采用如下 P 型迭代学习控制率

$$\begin{cases} \mu_{l,p+1} = \mu_{l,p} + \alpha_\mu \mathbf{E}_p \\ \sigma_{l,p+1} = \sigma_{l,p} + \beta_\sigma \mathbf{E}_p \end{cases} \quad (13)$$

式中, 学习参数 α_μ 和 β_σ 分别定义如下

$$\begin{cases} \alpha_\mu = \zeta_\mu [\lambda_1, \lambda_2, \dots, \lambda_M] \\ \beta_\sigma = \zeta_\sigma [\lambda'_1, \lambda'_2, \dots, \lambda'_M] \end{cases}$$

其中, λ 和 λ' 分别为学习元素, 参数 ζ_μ 和 ζ_σ 分别为迭代学习率. 从式 (13) 看出所有元素均为非负, 这

表明迭代学习率可以为正数也可以为负数, 这就意味着 RBF 基函数的中心值和宽度随着迭代学习次数呈现出增加或者降低趋势.

3.1.2 基于 RVFLNs 权值模型

从式 (10) 可以看出当前时刻输出 PDF 不但与磨浆过程输入变量有关, 同时与前一时刻的输出 PDF 形状也密切相关, 而输出 PDF 通过调节 RBF 基函数中心值和宽度以及相应的权值, 所以在获得理想 RBF 基函数参数之后, 通过式 (9) 可以获得所有时刻输出 PDF 相对应权值向量, 然而由于权值向量之间相互耦合, 因此, 权值向量模型可以看作是一个多输入多输出的回归建模问题. 为此, 采用基于 RVFLNs^[22-24] 建立输入变量与前 $n-1$ 个权值向量之间的非线性模型.

假设分别有 m 个输入变量与权值向量组成的样本集合 $(\mathbf{u}_i, \mathbf{V}_i)$, 其中 $\mathbf{u}_i = [u_{i1}, u_{i2}, \dots, u_{im}]^T \in \mathbf{R}^m$ 为磨浆过程的输入变量, $\mathbf{V}_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{i(n-1)}]^T \in \mathbf{R}^{n-1}$ 表示 n 个权值中的前 $n-1$ 个权值向量. 对于一个有 L 个隐层节点, 若以 $g(x)$ 作为激活函数的 RVFLNs 输出可以表示为

$$f_R(\mathbf{u}_i) = \sum_{j=1}^L \beta_j g(\omega_j \cdot \mathbf{u}_i + b_j) \quad (14)$$

式中, \mathbf{u}_i 为磨浆过程的输入变量, $\omega_j = [\omega_{j1}, \omega_{j2}, \dots, \omega_{jm}]^T$ 为 m 个输入节点连接第 j 个隐含层的输入权重, $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{j(n-1)}]^T$ 为第 j 个隐含层连接输出节点的输出权重, b_j 是第 j 个隐层单元的偏置, $\omega_j \cdot \mathbf{u}_j$ 表示 ω_j 和 \mathbf{u}_i 的内积.

随机神经网络和其他单隐层神经网络学习目标一样均是使得模型输出 $f_R(\mathbf{u}_i)$ 与实际输出 \mathbf{V}_i 之间误差最小, 即有 $\sum_{j=1}^L \|f_R(\mathbf{u}_i) - \mathbf{V}_i\| \rightarrow 0$. 当存在 β_j , ω_j 和 b_j , 使得

$$\mathbf{V}_i = \sum_{j=1}^L \beta_j g(\omega_j \cdot \mathbf{u}_j + b_j) \quad (15)$$

此时, 将式 (15) 可以矩阵表示为

$$H\beta = Y \quad (16)$$

式中, H 为隐含层输出矩阵, β 为输出权重, Y 为预测模型的权值输出. 且有

$$H(\omega_1, \dots, \omega_L, b_1, \dots, b_L, \mathbf{u}_1, \dots, \mathbf{u}_L) = \begin{bmatrix} g(\omega_1 \cdot \mathbf{u}_1 + b_1) & \dots & g(\omega_L \cdot \mathbf{u}_1 + b_L) \\ \vdots & \dots & \vdots \\ g(\omega_1 \cdot \mathbf{u}_N + b_1) & \dots & g(\omega_L \cdot \mathbf{u}_N + b_L) \end{bmatrix}_{N \times L}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times (n-1)}, \quad Y = \begin{bmatrix} \mathbf{V}_1^T \\ \vdots \\ \mathbf{V}_L^T \end{bmatrix}_{N \times (n-1)}$$

从式 (16) 可以看出, 当输入权重 ω_j 和隐层偏置 b_j 被随机确定后, 只需调整输出层权值就可以使网络具有较好的逼近性能. 为了能够较好地训练上述网络, 希望获得最优的输出权重 $\hat{\beta}$, 使得

$$\hat{\beta} = \arg \min_{\beta} \|H\beta - Y\|^2 \quad (17)$$

此时随机权神经网络的学习问题就转化为式 (16) 所示的线性系统 $H\beta = Y$ 的最小二乘求解问题, 为此隐层输出矩阵 H 就能被唯一确定, 此时可以获得输出权重 β 可以表示为

$$\hat{\beta} = H^{\dagger}Y \quad (18)$$

式中, H^{\dagger} 是矩阵 H 的 Moore-Penrose 广义逆. 可以看出此算法只需要设置网络的隐层节点个数, 便可以随机初始化输入权重和偏置并得到相应的输出权重. 所以该算法在执行过程中不需要调整网络的输入权值以及隐元的偏置, 便可以获得唯一的最优解.

为了更好地反映磨浆过程输出 FLSO 动态特性, 将当前采样时刻输入变量 $\mathbf{u}(k) = [u_1(k), u_2(k), \dots, u_m(k)]$, m 为输出变量个数以及当前时刻相对应的权值向量 $\mathbf{V}(k)$ 作为非线性模型综合输入, 即建立的权值动态预测模型用于实现如下的非线性动态映射关系:

$$\mathbf{V}_m(k+1) = f_R\{\mathbf{V}(k), \mathbf{u}(k)\} \quad (19)$$

式中, $\mathbf{V}_m(k+1)$ 为模型输出的前 $n-1$ 个权值向量. 此时, 在第 k 时刻预测输出 PDF 为

$$\begin{aligned} \sqrt{\gamma_m(y, k+1)} &= \mathbf{C}(y)\mathbf{V}_m(k+1) + R_n(y) \\ h(\mathbf{V}_m(k+1)) &= \mathbf{C}(y)f_R\{\mathbf{V}(k), \mathbf{u}(k)\} + \\ &R_n(y)h(f_R\{\mathbf{V}(k), \mathbf{u}(k)\}) \end{aligned} \quad (20)$$

3.2 预测 PDF 控制

由于实际工业过程中非线性、时变、模型失配和随机扰动等不确定性因素的存在, 模型输出 PDF 难以与实际输出 PDF 完全一致, 然而在滚动优化过程中, 需要实际输出 PDF 与模型输出 PDF 保持一致, 因此, 通常采用反馈校正来降低过程的不确定性对系统性能的影响, 提高系统的控制精度和鲁棒性.

假设模型在 k 时刻第 j 步预测输出 PDF 为

$$\begin{aligned} \sqrt{\gamma_m(y, k+j)} &= \mathbf{C}(y)\mathbf{V}_m(k+j) + \\ &R_n(y)h(\mathbf{V}_m(k+j)) = \\ &R_n(y)\mathbf{C}(y)f_R\{\mathbf{V}(k+j-1), \mathbf{u}(k+j-1)\} + \\ &R_n(y)h(f_R\{\mathbf{V}(k+j-1), \mathbf{u}(k+j-1)\}) \end{aligned} \quad (21)$$

另外, 在第 k 时刻实际输出 PDF 和预测输出 PDF 之间的误差为

$$\begin{aligned} e(y, k) &= \sqrt{\gamma(y, k)} - \sqrt{\gamma_m(y, k)} = \mathbf{C}(y)(\mathbf{V}(k) - \\ &f_R\{\mathbf{V}(k-1), \mathbf{u}(k-1)\}) + R_n(y) \cdot \\ &(h(\mathbf{V}(k)) - h(f_R\{\mathbf{V}(k-1), \mathbf{u}(k-1)\})) \end{aligned} \quad (22)$$

利用该误差对第 j 步预测输出 PDF $\sqrt{\gamma_m(y, k+j)}$ 进行反馈修正, 补偿后预测输出 PDF 为

$$\sqrt{\gamma_p(y, k+j)} = \sqrt{\gamma_m(y, k+j)} + \beta_j e(y, k) \quad (23)$$

式中, β_j ($0 < \beta_j < 1$) 为校正系数. 此时结合式 (21)~(23) 在 k 时刻第 j 步期望输出 PDF 和补偿后的预测输出 PDF 之间误差为

$$\begin{aligned} e_p(y, k+j) &= \sqrt{\gamma_g(y, k+j)} - \sqrt{\gamma_p(y, k+j)} = \\ &\mathbf{C}(y)[\mathbf{V}_g(k+j) - \\ &f_R\{\mathbf{V}(k+j-1), \mathbf{u}(k+j-1)\}] + \\ &R_n(y)[h(\mathbf{V}_g(k+j)) - \\ &h(f_R\{\mathbf{V}(k+j-1), \mathbf{u}(k+j-1)\})] + \\ &\beta_j[\mathbf{C}(y)(\mathbf{V}(k) - f_R\{\mathbf{V}(k-1), \\ &\mathbf{u}(k-1)\})] + \beta_j R_n(y)[h(\mathbf{V}(k)) - \\ &h(f_R\{\mathbf{V}(k-1), \mathbf{u}(k-1)\})] \end{aligned} \quad (24)$$

式中, $\gamma_g(y, k+j)$ 和 $\gamma_p(y, k+j)$ 分别为 k 时刻第 j 步的期望输出 PDF 和预测输出 PDF.

此外, 预测控制作为一种优化控制算法, 常通过最小化系统的性能指标函数来确定未来的最优控制序列, 使得未来预测输出尽可能接近期望的目标输出. 在实际工业过程中, 为了保证操作的可行性等要求, 普遍存在着输入变量带约束的情形, 同时对控制作用的大小加以约束, 避免控制作用变化过于剧烈. 本文设计预测 PDF 控制器目的是尽可能地使输出 PDF 尽可能跟踪期望输出 PDF, 所以选取如下所

示性能指标函数

$$\begin{aligned} \min_{\Delta u} J = & \sum_{j=1}^{N_p} \int_a^b \left(\sqrt{\gamma_g(y, k+j)} - \sqrt{\gamma_p(y, k+j)} \right)^2 dy + \\ & \sum_{j=0}^{N_c-1} [\lambda_j \Delta u(k+j)]^2 \\ \text{s.t. } & u_{\min} < \Delta u(k+j) + u(k+j-1) < u_{\max}, \\ & \Delta u_{\min} < \Delta u(k+j) < \Delta u_{\max} \end{aligned} \quad (25)$$

式中, N_p 和 N_u 分别为预测时域和控制时域, λ_j 为控制增量加权系数, u_{\max} 和 u_{\min} 分别为输入变量的上限和下限值, Δu_{\max} 和 Δu_{\min} 分别为输入变量变化率的上限和下限值. 可以看出对输出 PDF 跟踪控制最终转化为对前 $n-1$ 个权值跟踪控制.

从式 (25) 明显可以看出上述预测 PDF 控制器的设计可以看作是一个带有约束条件的非线性优化求解问题. 针对上述求解问题通常采用遗传算法、粒子群算法、序列二次规划算法 (Sequence quadratic program, SQP) 等优化算法获得非线性最优预测控制率, 其中, SQP 算法作为一种求解约束非线性优化问题的有效方法之一, 具有收敛性快、计算效率高、边界搜索能力强, 在实际中受到广泛重视和应用. 本文采用 SQP 方法求解式 (25) 所示的带约束的非线性规划问题设计预测 PDF 控制器, 使得磨浆过程输出 PDF 具有良好的目标跟踪能力.

4 工业数据验证

本文利用某化机浆磨浆过程的稀释水流量、磨盘间隙以及 FLSD PDF 生产数据对所提方法进行数据验证, 具体如下:

4.1 RBF 基函数参数整定

为了获得磨浆过程输出 FLSD 模型, 首先, 需要确定一组合适的 RBF 基函数近似输出 PDF, 采用基于迭代学习方法研究 RBF 神经网络对期望输出 PDF 的逼近效果, 并将得到 RBF 基函数作为本批次近似输出 PDF 的基函数, 此外, 通过大量 FLSD 的 PDF 数据分析获得期望输出 PDF, 本文选择 4 个 RBF 基函数来验证对期望输出 PDF 的近似效果, 这里中心值和宽度参数迭代学习率分别为 $\alpha_\mu = 0.01$, $\beta_\sigma = 0.005$, 另外, 假设中心值和宽度的初始值如下所示

$$\begin{aligned} \mu_1 = 0.3, \mu_2 = 0.8, \mu_3 = 1.3, \mu_4 = 1.8, \\ \sigma_1^2 = \sigma_2^2 = \sigma_3^2 = \sigma_4^2 = 0.06 \end{aligned} \quad (26)$$

基于式 (26) 所示的初始 RBF 基函数, 首先, 可以通过式 (9) 获得期望输出 PDF 权值估计, 然后利用得到的估计权值与初始 RBF 基函数相乘便得到对应的逼近值, 以此利用迭代学习方法通过调整中心值和宽度, 直到获得理想的逼近效果. 经过 100 次迭代学习后, 获得中心值和宽度分别为

$$\begin{aligned} \mu_1 = 0.40, \mu_2 = 0.91, \mu_3 = 1.25, \mu_4 = 1.46, \\ \sigma_1^2 = 0.068, \sigma_2^2 = 0.074, \sigma_3^2 = 0.098, \sigma_4^2 = 0.027 \end{aligned} \quad (27)$$

另外, 图 3 为在迭代学习 50 次和 100 次后的 RBF 基函数位置变化趋势图, 可以看出随着迭代次数的增加, 中心值和宽度逐渐向理想位置移动. 图 4 为性能指标函数值随迭代学习次数的变化趋势, 可以看出随着迭代次数的增加, 目标性能函数逐渐减小, 并在迭代学习 80 次时基本不再变化. 中心值和宽度随迭代次数变化趋势分别如图 5 和图




图 3 位置变化趋势

Fig. 3 Variation tendency of position




图 4 性能指标变化趋势

Fig. 4 Variation tendency of the performance index

6 所示, 从图 5 和图 6 看出在迭代学习 100 次后, 中心值和宽度均趋于平稳. 图 7 为在迭代学习 100

次后, 近似输出 PDF 与期望输出 PDF 的逼近结果, 可以看出本文方法对输出 PDF 具有满意的逼近效果. 同时, 利用式 (9) 对期望输出 PDF 数据进行权值估计, 此时获得相对应的期望权值为 $\mathbf{V}_g = [1.5411 \ 0.5080 \ 0.141 \ 0.166]^T$.




图 5 中心值变化趋势

Fig. 5 Variation tendency of the center value




图 6 宽度变化趋势

Fig. 6 Variation tendency of width

4.2 预测 PDF 控制效果

在完成 RBF 基函数参数整定同时利用式 (4) 对不同时刻输出 PDF 进行权值估计, 然后利用 RVFLNs 方法建立前三组权值的非线性预测模型, 利用稀释水流量、磨盘间隙和输出 PDF 数据, 采用所提方法建立磨浆过程输出 FLSD 模型, 并基于 SQP 算法优化式 (25) 设计预测 PDF 控制器.




图 7 输出 PDF 近似效果

Fig. 7 Approximation effect of the output PDF

本文取预测时域 $N_p = 3$, 控制时域 $N_u = 2$, 控制增量加权系数 $\lambda_j = 0.05$, 反馈校正系数 $\beta_j = 0.55$. 另外, 根据实际操作经验, 输入变量稀释水流量 (u_1) 和磨盘间隙 (u_2) 分别满足 $70 \text{ L/min} < u_1 < 75 \text{ L/min}$, $0.8 \text{ mm} < u_2 < 1.2 \text{ mm}$, $|\Delta u_1| < 1$, $|\Delta u_2| < 1$. 根据上述分析可知, 在 4 个权值中有 3 个是相互独立的, 因此, 期望 PDF 相对的应权值 $\mathbf{V}_g = [1.5411 \ 0.5080 \ 0.141]^T$, 则 $h(\mathbf{V}_g) = 0.166$. 另外, 假设初始输出 PDF 所对应的权值 $\mathbf{V}_0 = [1.2 \ 0.6 \ 0.3]^T$, 则 $h(\mathbf{V}_0) = 1.205$, 输入变量稀释水流量 (u_1) 和磨盘间隙 (u_2) 的初始值分别为 $u_1 = 71 \text{ L/min}$, $u_2 = 1.0 \text{ mm}$.

图 8 和图 9 分别在预测 PDF 控制器下预测权值输出响应曲线、控制输入的动态响应, 从图 8 可以看出预测权值输出能够实现对期望权值的跟踪, 但权值动态模型由于非线性存在, 在一定程度上影




图 8 预测 PDF 控制器下权值响应

Fig. 8 Weight response with the predictive PDF controller

响到预测权值输出对期望权值跟踪控制性能. 此外, 图 9 所示输入变量稀释水流量和磨盘间隙均能较好地稳定在可操作区内. 图 10 和图 11 分别为输出 FLSD 的 PDF3D 图以及初始时刻、目标、最终时刻输出 PDF, 从图 10 和图 11 明显能够看出在预测 PDF 控制器作用下, 实际输出 PDF 从初始输出 PDF 形状具有很明显逼近期望输出 PDF 趋势, 并最终实现对输出 PDF 跟踪控制.




图 9 预测 PDF 控制器下控制输入

Fig. 9 Control input with the predictive PDF controller




图 10 预测 PDF 控制器下输出 PDF 3D 响应

Fig. 10 3D responses of the output PDF with the predictive PDF controller




图 11 初始 PDF、最终 PDF 和期望 PDF

Fig. 11 Initial PDF, final PDF, and desired PDF

5 结论

本文从当前磨浆过程实际控制问题出发, 针对具有典型非高斯分布特征的输出 FLSD 形状提出了一种预测 PDF 控制方法. 采用迭代学习方法获得理想的 RBF 基函数基础上对不同时刻输出 PDF 相对应的权值进行估计, 针对权值之间强耦合、非线性强等特点, 采用 RVFLNs 建立表征输出变量和权值向量之间关系的预测模型, 最终将输出 PDF 的控制转化为对权值向量的控制, 基于工业数据实验结果表明了所提方法的有效性.

References

- Smook G A. *Handbook for Pulp and Paper Technologists*. Vancouver: Angus Wilde Publications, 1992.
- Sikter D, Karlström A, Sandberg C, Engstrand P. Economic perspectives on quality control in TMP refining processes. *Nordic Pulp & Paper Research Journal*, 2008, **23**(3): 305–314
- Lama I, Perrier M, Stuart P. Controllability analysis of a TMP-newsprint refining process. *Pulp & Paper Canada*, 2006, **107**(10): 44–48
- Karlström A, Hill J. Refiner optimization and control Part I: fiber residence time and major dynamic fluctuations in TMP refining processes. *Nordic Pulp & Paper Research Journal*, 2014, **29**(4): 635–652
- Harinath E, Biegler L T, Dumont G A. Control and optimization strategies for thermo-mechanical pulping processes: nonlinear model predictive control. *Journal of Process Control*, 2011, **21**(4): 519–528
- Harinath E, Biegler L T, Dumont G A. Predictive optimal control for thermo-mechanical pulping processes with multi-stage low consistency refining. *Journal of Process Control*, 2013, **23**(7): 1001–1011
- Gharehkhani S, Sadeghinezhad E, Kazi S N, Yarmanda H, Badarudina A, Safaei M R, Zubira M N M. Basic effects of pulp refining on fiber properties — a review. *Carbohydrate Polymers*, 2015, **115**: 785–803
- Lacerda T M, Zambon M D, Frollini E. Effect of acid concentration and pulp properties on hydrolysis reactions of mercerized sisal. *Carbohydrate Polymers*, 2013, **93**(1): 347–356
- Savastano Jr H, Warden P G, Coutts R S P. Mechanically pulped sisal as reinforcement in cementitious matrices. *Cement and Concrete Composites*, 2003, **25**(3): 311–319
- Wang H. *Bounded Dynamic Stochastic Distributions: Modelling and Control*. London: Springer-Verlag, 2000.
- Wang Hong, Yue Hong. Output PDF control of stochastic distribution systems: modelling, control and applications. *Control Engineering of China*, 2003, **10**(3): 193–197 (王宏, 岳红. 随机系统输出分布的建模、控制与应用. *控制工程*, 2003, **10**(3): 193–197)
- Wang H. Robust control of the output probability density functions for multivariable stochastic systems with guaranteed stability. *IEEE Transactions on Automatic Control*, 1999, **41**(11): 2103–2107

- 13 Wang H, Zhang J H. Bounded stochastic distributions control for pseudo-ARMAX stochastic systems. *IEEE Transactions on Automatic Control*, 2001, **46**(3): 486–490
- 14 Wang H. Minimum entropy control of non-Gaussian dynamic stochastic systems. *IEEE Transactions on Automatic Control*, 2002, **47**(2): 398–403
- 15 Wang H, Afshar P. ILC-based fixed-structure controller design for output PDF shaping in stochastic systems using LMI techniques. *IEEE Transactions on Automatic Control*, 2009, **54**(4): 760–773
- 16 Guo L, Wang H. PID controller design for output PDFs of stochastic systems using linear matrix inequalities. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2005, **35**(1): 65–71
- 17 Yue H, Zhou J L, Wang H. Minimum entropy of B-spline PDF systems with mean constraint. *Automatica*, 2006, **42**(6): 989–994
- 18 Zhou J L, Yue H, Zhang J F, Wang H. Iterative learning double closed-loop structure for modeling and controller design of output stochastic distribution control systems. *IEEE Transactions on Control Systems Technology*, 2014, **22**(6): 2261–2276
- 19 Wang A P, Afshar P, Wang H. Complex stochastic systems modelling and control via iterative machine learning. *Neurocomputing*, 2008, **71**(13–15): 2685–2692
- 20 Zhang J F, Yue H, Zhou J L. Predictive PDF control in shaping of molecular weight distribution based on a new modeling algorithm. *Journal of Process Control*, 2015, **30**: 80–89
- 21 Zhu J Y, Gui W H, Yang C H, Xu H L, Wang X L. Probability density function of bubble size based reagent dosage predictive control for copper roughing flotation. *Control Engineering Practice*, 2014, **29**: 1–12
- 22 Igel'nik B, Pao Y H. Stochastic choice of basis functions in adaptive function approximation and the functional-link net. *IEEE Transactions on Neural Networks*, 1995, **6**(6): 1320–1329
- 23 Stosic D, Stosic D, Zanchettin C, Ludermir T, Stosic B. QRNN: q generalized random neural network. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, **28**(2): 383–390
- 24 Zhou P, Lv Y B, Wang H, Chai T Y. Data-driven robust RVFLNs modeling of a blast furnace iron-making process using Cauchy distribution weighted M-estimation. *IEEE Transactions on Industrial Electronics*, 2017, **64**(9): 7141–7151
- 25 Lu X J, Zou W, Huang M H. A novel spatiotemporal LS-SVM method for complex distributed parameter systems with applications to curing thermal process. *IEEE Transactions on Industrial Informatics*, 2016, **12**(3): 1156–1165
- 26 Zhou P, Chai T Y, Sun J. Intelligence-based supervisory control for optimal operation of a DCS-controlled grinding system. *IEEE Transactions on Control Systems Technology*, 2013, **21**(1): 162–175
- 27 Zhou P, Lu S W, Chai T Y. Data-driven soft-sensor modeling for product quality estimation using case-based reasoning and fuzzy-similarity rough sets. *IEEE Transactions on Automation Science and Engineering*, 2014, **11**(4): 992–1003



李明杰 东北大学流程工业综合自动化国家重点实验室博士研究生。主要研究方向为复杂工业过程建模与控制, 随机分布控制。E-mail: limingj88@126.com
(**LI Ming-jie** Ph.D. candidate at the State Key Laboratory of Synthetic Automation for Process Industries, Northeastern University. His research interest covers modeling and control of complex industrial process, and stochastic distribution control.)



周平 东北大学教授, 博士生导师。分别于 2003 年、2006 年、2013 年获得东北大学学士学位, 硕士学位和博士学位。主要研究方向为工业过程运行反馈控制, 数据驱动建模与控制。本文通信作者。E-mail: zhouping@mail.neu.edu.cn
(**ZHOU Ping** Professor and Ph.D. supervisor at Northeastern University.

He received his bachelor degree, master degree and Ph.D. degree from Northeastern University in 2003, 2006, and 2013, respectively. His research interest covers operation feedback control of industrial process, data-driven modeling and control. Corresponding author of this paper.)