

基于主成分分析-改进的极限学习机方法的 精对苯二甲酸醋酸含量软测量

贺彦林, 王 晓, 朱群雄[†]

(北京化工大学 信息科学与技术学院, 北京 100029)

摘要: 目前, 化工生产过程日益复杂, 生产操作变量越来越多, 由于客观条件的限制, 有些重要的过程参数无法通过直接测量的手段精确测得. 通过软测量可实现复杂化工生产过程重要参数的精确测量, 进而指导化工企业的生产, 提高化工生产的产出效率, 是解决问题的一个有效的方法. 针对复杂化工过程软测量建模中存在的问题, 本文提出了一种改进的极限学习机模型(improved extreme learning machine, IELM). 一方面将主成分分析(principal component analysis, PCA)方法应用到极限学习机(ELM)里, 通过PCA对模型输入变量进行主成分分析, 不仅去除了变量间的线性相关关系, 而且对高数据进行降维处理, 最终降低了极限学习机的输入复杂性; 另一方面利用相关系数判断输入主元数据与输出数据间的相关关系, 从而得到正相关输入和负相关输入, 依据这两类数据构造ELM模型, 使得每类输入数据对网络的输出有同样的作用, 进一步提高极限学习机的泛化能力. 最后建立了PCA-IELM模型, 首先用标准数据库的Triazines数据集验证该模型有效性, 随后得出了基于PCA-IELM方法的精对苯二甲酸(purified terephthalic acid, PTA)溶剂脱水塔塔顶醋酸含量软测量模型, 仿真结果表明PCA-IELM模型处理高维数据时较传统的ELM算法具有稳定性好, 建模精度高等特点, 为神经网络在复杂化工应用领域提供新思路.

关键词: 极限学习机; 主成分分析; 精对苯二甲酸; 软测量

中图分类号: TP273

文献标识码: A

Modeling of acetic acid content in purified terephthalic acid solvent column using principal component analysis based improved extreme learning machine

HE Yan-lin, WANG Xiao, ZHU Qun-xiong[†]

(College of Information Science & Technology, Beijing University of Chemical Technology, Beijing 100029, China)

Abstract: Currently, chemical production processes are more and more complex, and there are more and more operation variables in chemical plants. Therefore, some important process variables can not be measured directly because of the limitations in practical conditions. A soft-sensing based method is adopted to realize that the production is measured accurately online, based on which the chemical company can enhance the production amount. To solve the problem, a principal component analysis (PCA) based improved extreme learning machine (IELM) soft-sensing model was proposed in this paper. On one hand, IELM method is combined with PCA to let the input values be analyzed by PCA for improving the generalization performance. On the other hand, the correlation coefficient was used to calculate the positive or negative relationship between the components and the outputs. Then the network structure can be determined according to the positive components and the negative components. This structure has an advantage: the input components have the same effect on the outputs, which can enhance the performance of ELM. Finally, PCA-IELM model was built, and the Triazines dataset from UCI standard database was selected to verify the effectiveness of this model. Then the PCA-IELM was used as a soft sensor for modeling purified terephthalic acid (PTA) solvent column acetic acid content. The experimental results show that when dealing with high-dimensional data the PCA-IELM has better and higher precision modeling than the ELM. The PCA-IELM model provides a new idea for neural networks applying to complex chemical processes.

Key words: extreme learning machine; principal component analysis; purified terephthalic acid; soft-sensing

1 引言(Introduction)

近年来,随着化工生产过程日益复杂化,对产品质量标准和环境污染的监测已经日益引起研究人员的广泛关注.为了实现这个目标,需要采取有效的控制策略来实现产品的质量控制和相应的环境指标控制.由此看来,对化工生产流程中重要的过程变量进行准确监控显得越来越重要.但是由于客观条件的限制,一些十分重要的参数无法直接测量,而现有的测量仪表成本昂贵且存在时间响应滞后的缺陷不利于优化控制的实现.软测量建模技术通过构造化工对象可测量的关键变量与产品质量间的函数关系,以过程操作数据为基础获得产品质量的估计值,是解决某些参数难以测量的有效手段^[1].

软测量方法^[2]中基于数据驱动的建模方法取得了大量的成功应用,其中神经网络等技术作为一种建模方法已被广泛应用于化工过程建模和优化中^[2-4].本文采用的神经网络模型是新近提出的一种快速且泛化性能好的基于单隐含层前馈神经网络-极限学习机(extreme learning machine, ELM)^[5].相对于传统的神经网络模型,ELM具有模型简单、计算速度快、精度高等特点,比较适合软测量模型的建立,已经成功应用到很多领域^[6-11].

但随着化工生产装置规模越来越大,其测量参数多且耦合性较强,带噪声的高维输入数据通常难以满足ELM隐含层输出矩阵 H 列满秩的要求^[12].为了进一步提高ELM模型的精度,建立精度更高的软测量模型,本文对ELM进行了改进.首先,作者将极限学习机方法同主成分分析方法(principal component analysis, PCA)相结合,减少网络模型的输入变量维数,从而ELM模型就会需要较少的隐含层节点,较少的隐含层节点意味着矩阵 H 的列数较少,从而有利于保证矩阵 H 列满秩,这样保证了ELM输出层权值 β 解的存在,并且PCA之后去除了现场数据里的噪声,提高建模的精度.然后利用相关系数判断降维后的输入数据与输出数据间的正负相关关系,从而分出正相关输入和负相关输入,依据此结果建立了一种基于正负相关性的新型ELM模型.由此,本文提出了一种基于PCA的改进ELM模型(PCA based improved ELM, PCA-IELM).最后采用UCI标准数据集Triazines对模型进行测试,然后应用于PTA溶剂脱水塔塔顶醋酸含量的软测量.实验结果验证了PCA-IELM模型用于PTA软测量的可行性和有效性,能有效为企业做出相关指导.

2 极限学习机算法(Extreme learning machine algorithm)

图1为传统ELM模型^[5]的结构示意图,下面对其算法进行介绍:对于 N 个不同的网络学习样本 $U = (x_i, t_i) \in [\mathbb{R}^m \times \mathbb{R}^n] (i = 1, 2, \dots, N)$,具有 K 个隐含层神经元的ELM输出表达式为

$$\Theta(x_i) = \sum_{k=1}^K \beta_k g(A_k \cdot x_i + b_k), \quad (1)$$

其中: $A_k = (a_{k1}, a_{k2}, \dots, a_{km})^T$ 为输入层神经元与第 k 个隐含层神经元的连接权值向量, b_k 为第 k 个隐含层神经元的阈值, $\beta_k = (\beta_{k1}, \beta_{k2}, \dots, \beta_{kn})^T$ 为第 k 个隐含层神经元与输出神经元的连接权值向量, $A_k \cdot x_i$ 表示 A_k 与 x_i 的内积, $g(\cdot)$ 为隐含层的激活函数.




图1 传统ELM模型

Fig. 1 Traditional ELM model

在ELM算法中,对于给定的 K 个隐含层神经元和激活函数,存在 β_k , A_k 和 b_k ,使得该单隐含层前馈神经网络能够以接近零误差逼近样本的期望值 t_n .由式(1)可得一个含有 n 个方程的线性方程组:

$$H\beta = t, \quad (2)$$

其中:

$$H = \begin{bmatrix} g(A_1x_1+b_1) & \cdots & g(A_Kx_1+b_K) \\ \vdots & \ddots & \vdots \\ g(A_1x_N+b_1) & \cdots & g(A_Kx_N+b_K) \end{bmatrix}_{N \times K},$$

$$\beta = (\beta_1^T, \beta_2^T, \dots, \beta_K^T)_{K \times n}^T,$$

$$t = (t_1^T, t_2^T, \dots, t_N^T)_{N \times n}^T.$$

由此,隐含层神经元与输出层神经元的连接权值 β 可以由式(2)的极小2-范数最小二乘解得

$$\hat{\beta} = H^+t, \quad (3)$$

其中 H^+ 为 H 的广义逆矩阵.所以,给定训练样本集 U ,隐含层激活函数 $g(\cdot)$ 以及隐含层神经元个数 K 之后,ELM学习算法的步骤可概括为

- 1) 随机选取输入权值 A_k 和 $b_k (k = 1, 2, \dots, K)$;
- 2) 计算网络隐含层输出矩阵 H ;
- 3) 计算输出权值 β : $\beta = H^+t$, H^+ 为 H 的广义逆矩阵.

可见,ELM是一种非常简单并且快速的神经网络学习算法.但是,将ELM学习算法直接用于化工过程建模中,仍存在一些问

首先,化工生产过程日益复杂化导致采集的数据呈现高维、高耦合和冗余信息多的特点,从而需要较多的隐含层节点,这样不利于 H 矩阵满足列满秩,因此会降低网络的建模精度;其次,化工过程的工作环境恶劣,测量数据中存在离群点,使得ELM网络的性能和鲁棒性降低.

3 改进的极限学习机方法(Improved ELM method)

为了克服ELM学习算法在处理高维数据时存在的问题,提高建模精度,一方面对数据进行了主元分析处理,把高维的数据折射到低维的空间且去除了数据间的线性关系和冗余信息;另一方面对传统的极限学习机算法进行了改进,建立的模型依据与输入输出的正负关系,这样建立起来的模型使得输入对输出有相同的作用效果,有助于网络的学习,进一步提高网络的泛化性能。

3.1 ELM模型构造改进(ELM model construction improvements, IELM)

输入输出数据间有着不一样的影响关系,有的输入数据对输出具有正方向的引导作用,称这类数据为正相关输入数据;另外一部分输入数据可能对输出具有反方向的引导作用,称这类输入数据为负相关输入数据。本文用相关系数来表征输入数据与输出数据间的关系,对于给定的 n 组输入输出数据 (x, y) , $x \in \mathbb{R}^d$, $y \in \mathbb{R}^e$ 相关系数可由下式计算得到:

$$r_j = \frac{\sum_{i=1}^n (x_{ij} - \bar{x}_j)(y_{ki} - \bar{y}_k)}{\sqrt{\sum_{i=1}^n (x_{ij} - \bar{x}_j)^2 \sum_{i=1}^n (y_{ki} - \bar{y}_k)^2}}, \quad (4)$$

其中: $i=1, 2, \dots, n$; $j=1, 2, \dots, d$; $k=1, 2, \dots, e$; r_j 代表输入变量里的第 j 个输入属性与第 k 个输出的相关系数。若 r_j 的值大于零,说明该输入属性与输出是正相关,即正相关输入;若 r_j 的值小于零,说明该输入属性与输出是负相关,即负相关输入。由此把输入数据里的所有正相关数据放一起,负相关数据放一起,由此建立ELM模型。图2展示了该模型的建立理念。




图2 新型ELM模型构造

Fig. 2 Construction of ELM model

图2里改进的ELM模型由输入的不同分为两部分,分别为正相关输入部分和负相关输入部分,相对于图1里传统的ELM模型,该改进的模型有如下优点:

1) 传统ELM模型并没有分析输入数据与输出数据之间的关系,而改进的模型将输入数据与输出数据

之间的关系分为正关系和负关系两部分,并依据这两部分输入分别建立局部的输入单元,实现每个单元的输入数据对输出的作用是相同的,而不像传统ELM模型里输入数据是杂乱无章的。这样的结构有利于网络的训练,从而提高网络的性能;

2) 相对于图1传统的ELM模型结构,该结构对输入单元进行了分块,且正、负两输入单元之间并没有信息交互,即正单元的输入模块与负单元输入模块的隐含层之间没有连接关系,同样负单元的输入模块与正单元输入模块的隐含层之间也没有连接关系,这样防止了对输出作用不同的输入模块之间互相独立,而且可以得到同隐含层节点数目的情况下,改进后的模型比传统的ELM模型输入权值的连接个数要少的结论。两个输入单元的相互独立性和输入权值数目相对较少的特点都有利于网络模型的计算,从而增加网络的性能。

3.2 PCA-IELM网络模型(PCA based IELM neural network model)

主成分分析(principal component analysis, PCA)是一种用于数据压缩和特征提取的经典方法,已经成功应用于数据分析、模式识别和信息处理等领域^[13-16]。PCA主要的功能是将高维的数据投射到低维空间、去除变量间的线性关系以及冗余信息。

本文所采集的数据一般取自于现场的生产数据,这样的数据不可避免地带有一定的噪声,而这些噪声体现在那些不重要的主成分,所以可以采用PCA去除这些解释噪声的主成分,一方面实现了对噪声的过滤,另一方面也降低了输入数据的维数^[17-20]。网络模型对低维数的输入往往需要较少的隐含层节点数目,这意味着极限学习机隐含层输出矩阵的列数较少,更容易满足列满秩的要求,从而保证了广义逆解的存在,进一步提高了网络的性能。由此本文基于PCA和改进ELM构建了PCA-IELM模型,其结构如图3所示。




图3 PCA-IELM模型

Fig. 3 PCA-IELM model

由图3可知建立PCA-IELM模型的流程共有3步:

首先, 对原数据进行主元分析, 得到合理的主元个数; 其次, 对得到的主元用公式(4)进行相关分析, 从而得到正相关输入主元和负相关输入主元; 最后, 根据得到的正、负相关输入主元构造网络模型。

为了初步验证网络模型的有效性, 利用本文选取UCI数据库里的Triazines数据集进行测试, 之后作为PTA脱水塔塔顶醋酸含量的软测量模型进行了验证。

4 Triazines 实验测试 (Experimental test on Triazines data set)

为初步验证本文建立的PCA-IELM模型的有效性, 选取UCI数据库中的Triazines数据集对其进行测试, Triazines数据集有60个输入属性和1个输出属性, 共有186组数据, 随机分为训练数据(总数据的三分之二)和泛化数据(总数据的三分之一), 实验过程及结果分析如下:

进行PCA处理的原则是保证方差累积贡献率至少达到0.9的基础上选取原数据维数一半作为主元的个数。针对于Triazines数据集, 经过实验选取主元个数为30个, 此时方差累积贡献率已达到0.9以上。然后将这30个主元一次标号为1, 2, $\dots$, 30, 对这30个主元进行相关系数分析后, 得到15个正相关的主元, 他们的标号为: 2, 3, 5, 8, 11, 13, 15, 17, 18, 21, 22, 23, 25, 27, 28, 剩下的15个主元为负相关主元。然后进行网络训练和测试, 得到模型的泛化结果如表1所示。

表1 Triazines数据集测试结果对比

Table 1 Testing results comparison of Triazines dataset

Triazines	PCA-IELM	ELM	ELM
隐含层节点数	6	6	20
平均相对误差	0.1792	0.1996	0.1801
均方根误差	0.1294	0.1419	0.1299

从表1可看出, 在Triazines数据集验证中, 当隐含层神经元的个数为6时(正主元输入模块隐含层节点数为3, 负主元输入模块隐含层节点数为3), PCA-IELM网络的泛化均方根误差即可达到0.1294, 平均相对误差为0.1792。而传统的ELM网络, 采用相同的隐含层神经元个数时, 其泛化均方根误差为0.1419, 平均相对误差为0.1996。若要达到与PCA-IELM相近的精度, ELM需要的隐含层神经元个数为20个。从上述分析得知, 在隐含层节点数目较少的时候, PCA-IELM网络能达到更好的泛化精度。由此说明了PCA-IELM网络在结构相对简单时具有较高的建模的精度, 验证了该模型的有效性。下一节将介绍PCA-IELM软测量模型在PTA的应用。

5 PTA软测量模型PCA-IELM的验证(PCA-IELM experimental test on PTA process)

5.1 PTA简介(Introduction of PTA)

精对苯二甲酸(purified terephthalic acid, PTA)是

化工企业生产聚酯重要原料之一, 也是轻纺工业的前导产品。近些年来为了促进PTA行业的生产产量和技术, 各国的相关生产企业致力于不断地扩大生产装置和规模以及不断地降低装置物耗能耗两方面的研究。随着装置的日益扩大, 衡量装置是否具有竞争力的一个重要指标便是装置物耗能耗水平的高低。对二甲苯(para-xylene, PX)空气氧化制对苯二甲酸(terephthalic acid, TA)是在醋酸(AcOH)为溶剂, 醋酸钴、醋酸锰为催化剂, 四溴乙烷为促进的共同作用下进行的化学反应。该反应过程里, 醋酸主要作为移热介质, 本身并不参与PX氧化反应。在对PTA装置考核的一个重要指标是醋酸(AcOH)单耗。醋酸单耗的多少也是衡量工艺技术是否最优的主要指标之一。由此看来, 降低醋酸单耗是企业降低生产成本、提高经济效益的重要目标之一。

PTA生产装置如图4所示, PTA生产装置主要由3部分构成: 溶剂脱水塔、再沸器和回流罐。由装置的实际生产情况, 醋酸的损耗主要由以下几个方面造成: 醋酸在氧化过程的燃烧; 薄膜蒸发器去杂质时回收醋酸; 回收塔塔顶废水携带醋酸以及吸收塔洗涤水量。由于氧化过程能耗物耗的相关技术比较成熟, 所以溶剂系统的优化是降低PTA生产过程醋酸消耗的主要手段。溶剂系统单元由3部分构成: 溶剂脱水塔、薄膜蒸发器和高压吸收塔。而溶剂脱水塔的原料和醋酸息息相关, 所以溶剂脱水塔的好坏将直接影响到醋酸的分离效果, 对装置的醋酸单耗有很大的影响。在回收醋酸浓度满足工艺要求和平稳的条件下, 脱水塔顶的水相酸浓度最低可最大限度的醋酸和共沸剂的流失。在实际工业生产过程中, 塔顶的醋酸浓度难以在线测量, 因而不能快速指导溶剂脱水塔的优化操作。因此, 本文考虑对PTA生产装置中的溶剂脱水塔塔顶的醋酸含量采用软测量的方法实现其准确的测量。




图4 PTA生产装置

Fig. 4 PTA process plant

5.2 建模变量的选择(Choose modeling variables)

为了更准确地建立PTA脱水塔塔顶醋酸含量软测

量模型, 首先需要对影响醋酸量的因素进行深入的分析, 以避免建模过程变量信息不完备而降低模型的精度. 由于直接对塔顶醋酸含量难以直接进行测量, 且现场并没有直接检测醋酸含量的输出量, 所以用与醋酸含量具有一一对应关系的塔顶电导率的数据来反映醋酸的含量.

由于影响溶剂脱水塔塔顶醋酸含量的因素有很多, 所以需要对变量进行选取. 模型输入变量的确定主要依据工艺机理和经验知识. 溶剂脱水塔的流程如图4所示, 通过对溶剂脱水塔的机理和操作特性进行分析, 最终确定17个输入变量: 进料量FC1501, 温度TI1504, 回流量FC1502, 1503, 1504; 温度TI15010, 再沸器蒸汽流量FC1507, 塔内温度TI1511 ~ TI1519, TC1501; 模型输出为塔顶的电导率测量值. 共采取了260组生产数据, 随机选取174组数据(总数据的三分之二)作为训练数据, 剩下的86组数据(总数据的三分之一)作为模型泛化数据.

5.3 PTA 溶剂脱水塔塔顶醋酸含量软测量建模 (Soft measured modeling of PTA solvent column acetate content)

基于PCA-IELM方法的PTA塔顶醋酸含量建模步骤如下:

首先, 输入数据主成分分析以及相关分析处理.

- 1) 对采集的260组数据组成的矩阵命名为 X .
- 2) 求取协方差阵 $X^T X$ 的特征值和特征向量.
- 3) 求取累积贡献率, 在累积贡献率达到0.9的前提下选取主元的个数.

4) 根据确定的主元个数, 得到相应的模型辅助变量学习样本.

5) 对主元变量进行标号, 然后通过相关性分析得到正输入主元和负输入主元.

其次, 建立PCA-IELM网络模型.

1) 将得到的正相关主元变量放到网络正相关输入的模块, 同样将负相关主元放到网络负相关输入的模块.

2) 给定网络隐含层激活函数, 本实验用的是单S型函数.

3) 随机设定输入层与隐含层间的连接权值和隐含层节点的阈值.

4) 分别计算正、负网络模块隐含层的输出, 并将它们并为一个矩阵, 本文称之为网络隐含层总的输出矩阵 H .

5) 根据广义逆求出隐含层与输出层间的权值.

最后, 模型检验.

利用测试数据验证PTA塔顶醋酸含量模型, 若测试误差较大则返回上述步骤重新建模, 若误差在允许

的误差范围之内则建模结束.

5.4 结果分析(Results analysis)

对PTA选取的变量进行主元分析, 结果在累积贡献率超过0.9的基础上, 选取主元个数为8, 对其进行标号为1, 2, ..., 8, 对这8个主元进行相关系数分析后, 得到6个正相关的主元, 他们的标号为1, 3, 4, 5, 6, 7, 剩下的2个主元为负相关主元. 然后进行网络训练和测试, 所得模型泛化结果如表2和图5所示.

表2 PTA溶剂脱水塔塔顶醋酸含量软测量模型性能比较

Table 2 Testing results comparison of PTA solvent column acetic acid content

建模方法	PCA-IELM	ELM	ELM
隐含层节点数	20	20	55
平均相对误差	0.0086	0.0101	0.0087
均方根误差	0.507	0.5936	0.5115




图5 PCA-IELM模型泛化性能

Fig. 5 Generalization performance of PCA-IELM model

从表2可以看出, 在PTA塔顶醋酸含量软测量模型中, 当隐含层神经元的个数为20时(正主元输入模块隐含层节点数为15, 负主元输入模块隐含层节点数为5), PCA-IELM网络的泛化均方根误差为0.507, 平均相对误差是0.0086. 而传统的ELM网络, 采用相同的隐含层神经元个数时, 其泛化均方根误差为0.5936, 平均相对误差为0.0101. 若要达到与PCA-IELM相近的精度, ELM需要的隐含层神经元个数为55个. 从上述分析得知, 在隐含层节点数目较少的时候, PCA-IELM网络能达到更好的泛化性能. 由此说明了基于PCA-IELM方法的PTA塔顶醋酸含量软测量模型在结构相对简单时具有较好的精度, 为PTA塔顶醋酸含量的测量提供了一种行之有效的方法.

6 结论(Conclusions)

针对工业现场没有测量PTA溶剂脱水塔塔顶的醋酸含量, 难以实施监测监控脱水塔的运行情况, 本文

基于PCA-IELM的方法建立了PTA塔顶醋酸含量的软测量模型. 为了简化模型而获取较高的建模精度, 一方面通过主元分析的方法对输入变量进行压缩, 在减少了输入变量维数的同时在相当程度上滤除掉了噪声, 从而在提高了模型的预报精度上也简化了输入量; 另一方面对传统的ELM也进行了改进, 通过对降维后的主元进行相关分析, 得到了正相关主元和负相关主元, 改进的ELM根据这两部分输入分别构造了正相关输入模块和负相关输入模块, 而且正负相关模块相互独立, 之间并没有权值相连接, 使得在简化模型计算的基础上使得模型的输入模块对输出具有同方向的影响, 有助于模型的训练而提高网络的精度. 因此相比于单纯的ELM方法, 本文提出的PCA-IELM在减少了模型规模和计算量的同时, 提高了模型的泛化能力, 满足了现场高精度的测量要求. 因此, 本文提出的PCA-IELM方法适合应用到PTA塔顶醋酸含量建模中, 并为化工过程难以测量的变量提供了一种行之有效的软测量方法.

参考文献(References):

- [1] FORTUNA L, GRAZIANI S, RIZZO A, et al. *Soft Sensors for Monitoring and Control of Industrial Processes* [M]. London: Springer, 2007.
- [2] SLISKOVIC D, GRBIC R, HOCENSKI Z. Methods for plant data-based process modeling in soft-sensor development [J]. *Automatica*, 2012, 52(4): 306 – 318.
- [3] AHMAD Z, ZHANG J. Selective combination of multiple neural networks for improving model prediction in nonlinear systems modeling through forward selection and backward elimination [J]. *Neurocomputing*, 2009, 72(4/5/6): 1198 – 1204.
- [4] KASHANI M N, SHAHHOSSEINI S. A methodology for modeling batch reactors using generalized dynamic neural networks [J]. *Chemical Engineering Journal*, 2010, 159(1/2/3): 195 – 202.
- [5] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: A new learning scheme of feed-forward neural networks [C] // *Proceedings of the International Joint Conference on Neural Networks*. Budapest, Hungary: IEEE, 2004: 25 – 29.
- [6] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications [J]. *Neurocomputing*, 2006, 70(1/2/3): 489 – 501.
- [7] 高慧慧, 贺彦林, 朱群雄. 基于数据属性划分的递阶ELM研究及化工应用 [J]. *化工学报*, 2013, 64(12): 4348 – 4353.
(GAO Huihui, HE Yanlin, ZHU Qunxiong. Research and chemical application of data attributes decomposition based hierarchical ELM neural network [J]. *CIESC Journal*, 2013, 64(12): 4348 – 4353.)
- [8] 彭荻, 贺彦林, 徐圆, 等. 基于数据特征提取的AANN-ELM研究及化工应用 [J]. *化工学报*, 2012, 63(9): 2921 – 2925.
(PENG Di, HE Yanlin, XU Yuan, et al. Research and chemical application of data feature extraction based AANN ELM neural network [J]. *CIESC Journal*, 2012, 63(9): 2921 – 2925.)
- [9] 韩广, 乔俊飞, 薄迎春. 溶解氧浓度的前馈神经网络建模控制方法 [J]. *控制理论与应用*, 2013, 30(5): 585 – 591.
(HAN Guang, QIAO Junfei, BO Yingchun. Feedforward neural network modeling and control for dissolved oxygen concentration [J]. *Control Theory & Applications*, 2013, 30(5): 585 – 591.)
- [10] 褚菲, 王福利, 王小刚, 等. 基于径向基函数神经网络的多级离心压缩机混合模型 [J]. *控制理论与应用*, 2012, 29(9): 1205 – 1210.
(CHU Fei, WANG Fuli, WANG Xiaogang, et al. Hybrid model for multi-stage centrifugal compressor based on radial basis function neural network [J]. *Control Theory & Applications*, 2012, 29(9): 1205 – 1210.)
- [11] 乔俊飞, 韩红桂. 神经网络结构动态优化设计的分析与展望 [J]. *控制理论与应用*, 2010, 27(3): 350 – 357.
(QIAO Junfei, HAN Honggui. Dynamic optimization structure design for neural networks: review and perspective [J]. *Control Theory & Applications*, 2010, 27(3): 350 – 357.)
- [12] YUAN Y B, WANG Y G, CAO F L. Optimization approximation solution for regression problem based on extreme learning machine [J]. *Neurocomputing*, 2011, 74(16): 2475 – 2482.
- [13] HUI C, MATS N, SIRKKA L. Evaluation of PCA methods with improved fault isolation capabilities on a paper machine simulator [J]. *Chemometrics and Intelligent Laboratory Systems*, 2008, 92(3): 186 – 199.
- [14] MOORE B. Principal component analysis in linear systems: Controllability, observability, and model reduction [J]. *IEEE Transactions on Automatic Control*, 1981, 26(1): 17 – 32.
- [15] JACKSON J E, MUDHOLKAR G S. Control procedures for residuals associated with principal component analysis [J]. *Technometrics*, 1979, 21(3): 341 – 349.
- [16] BALDI P, HORNIK K. Neural networks and principal component analysis: Learning from examples without local minima [J]. *Neural Networks*, 1989, 2(1): 53 – 58.
- [17] MACHIZAWA M G, DRIVER J. Principal component analysis of behavioural individual differences suggests that particular aspects of visual working memory may relate to specific aspects of attention [J]. *Neuropsychologia*, 2011, 49(6): 1518 – 1526.
- [18] ZHANG L, DONG W, ZHANG D, et al. Two-stage image denoising by principal component analysis with local pixel grouping [J]. *Pattern Recognition*, 2010, 43(4): 1531 – 1549.
- [19] LIANG N Y, HUANG G B. A fast and accurate online sequential learning algorithm for feed-forward networks [J]. *IEEE Transactions on Neural Networks*, 2006, 17(6): 1411 – 1423.
- [20] PENG D Z, ZHANG Y. Dynamics of generalized PCA and MCA learning algorithms [J]. *IEEE Transactions on Neural Networks*, 2007, 18(6): 1777 – 1784.

作者简介:

贺彦林 (1987–), 男, 博士研究生, 主要从事神经网络及复杂工业过程建模研究, E-mail: Y.L.He@hotmail.com;

王 晓 (1990–), 女, 硕士研究生, 主要从事神经网络及复杂工业过程建模研究, E-mail: wangxiaoshore@163.com;

朱群雄 (1960–), 男, 教授, 博士生导师, 主要从事神经网络及复杂工业过程建模研究, E-mail: zhuqx@mail.buct.edu.cn.