

文章编号: 1001-0920(2013)04-0531-06

基于共同主成分的多元时间序列降维方法

李正欣, 郭建胜, 惠晓滨, 宋飞飞

(空军工程大学 装备管理与安全工程学院, 西安 710051)

摘要: 针对常见的降维方法难以有效保留多元时间序列主要特征的问题, 分析了传统主成分分析(PCA)方法在多元时间序列降维中的局限性, 提出一种基于共同主成分分析的多元时间序列降维方法, 并通过仿真实验比较了两种方法的降维有效性和计算复杂度. 实验结果表明, 所提出的降维方法能够以相对较小的计算代价, 更有效地对多元时间序列进行降维.

关键词: 降维; 多元时间序列; 主成分分析; 共同主成分分析; 计算复杂度

中图分类号: TP311

文献标志码: A

Dimension reduction method for multivariate time series based on common principal component

LI Zheng-xin, GUO Jian-sheng, HUI Xiao-bin, SONG Fei-fei

(Institute of Equipment Management and Safety Engineering, Air Force Engineering University, Xi'an 710051, China.

Correspondent: LI Zheng-xin, E-mail: lizhengxin_2005@163.com)

Abstract: Existing dimension reduction method for multivariate time series can't preserve their feature effectively. Therefore, the drawback of PCA method is analyzed, when it is used in MTS dimension reduction, and based on common principal component analysis, a dimension reduction method for multivariate time series is proposed. The computational complexity and the validity of dimension reduction are compared between different methods. The results of experiments show that the proposed method can reduce dimension effectively at comparatively low computational cost, and at the same time preserve most feature of multivariate time series.

Key words: dimension reduction; multivariate time series; principal component analysis; common principal component analysis; computational complexity

0 引言

现实中存在大量的多元时间序列(MTS)类型的数据, 如航天飞船等重要仪器的运行状态数据, 互联网中关键服务器的通讯流量数据, 高新生物医学实验中的测量数据, 天文方面的重要测量数据以及应用于多种行业的人体运动捕捉数据等. 从广义上讲, 任何包含多变量数据存储的数据集均可视为多元时间序列.

随着时间序列获取方法的日益丰富和存储技术的不断进步, 时间序列的分析处理逐渐成为研究热点. 随着维数的不断提高, 数据将提供更加丰富、细致的信息, 但同时也给后续的数据分析处理带来前所未有的困难, 如: 大量的特征, 许多与给定任务无关的特征, 许多对于给定任务冗余的特征(如特征相互之间存在强烈的相关度)以及噪声数据等.

降维是在保留主要特征的基础上, 把原始数据从高维空间映射到低维特征空间的过程^[1]. 降维是用来克服“维数灾难”和模型化高维数据的一种典型数据处理技术, 它可通过对离散数据集的分析来探求嵌入在高维数据空间中本征低维流形的不同样式, 寻求事物的本质规律^[2]. 如果算法的时间或存储复杂性依赖于输入数据的维数, 则降维可以有效地降低算法的复杂性.

目前, 针对MTS降维的研究成果并不丰富, 由于不同于一般的多元数据对象, 研究MTS的降维方法具有现实意义和广阔的应用前景. 本文针对MTS的特点, 提出一种基于共同主成分的MTS降维方法, 与传统的主成分分析(PCA)降维方法进行了对比, 通过实验验证了所提出方法的有效性和优越性.

收稿日期: 2011-06-24; 修回日期: 2012-04-12.

作者简介: 李正欣(1982—), 男, 博士, 从事信息系统工程与智能决策、数据挖掘的研究; 郭建胜(1965—), 男, 教授, 博士生导师, 从事信息智能处理与决策等研究.

1 基本概念及相关研究

定义 1 (多元时间序列)^[3] 一系列观察值 $x_t(j)$ 称为多元时间序列, $t(t = 1, 2, \dots, n)$ 表示第 t 个时间点, $j(j = 1, 2, \dots, m)$ 表示第 j 个变量, $x_t(j)$ 表示第 j 个变量在第 t 个时间点上的观察值。

定义 2 (多元时间序列的同构性) 在数据集中, 各多元时间序列的变量维数相同, 变量之间一一对应, 且表示相同的含义。

定义 3 (降维幅度) 降维减少的变量数与原始变量数之比。

定义 4 (降维有效性) 降维结果保持原始数据主要特征的水平。

MTS 可以用一个 $m \times n$ 的矩阵表示. 其中: m 为变量个数, n 为时间长度. 一般地, MTS 数据集具有同构性, 但各 MTS 的时间长度往往不同. 降维有效性需要针对某种特定应用来度量。

与传统的多元数据对象相比, 针对 MTS 降维方法的研究相对较少. 目前, PCA 方法是针对 MTS 最常见的降维方法, 原因在于它具有概念上的简单性、计算上的方便性以及最优线性重构误差等优良特性^[2]. 文献 [3] 对 MTS 进行主成分分析, 得到了方差贡献率占 95% 以上的主成分, 然后使用奇异值分解 (SVD) 方法对降维后的特征数据进行了相似性比较. 文献 [4] 在主成分分析的基础上, 根据方差贡献率得到了各个主成分的权重, 应用该权重和特征向量矩阵的正交变换得到原变量集合的一个加权综合属性, 从而将多元时间序列降为一元时间序列. 文献 [5] 和 [6] 采用主成分分析方法对 MTS 数据进行降维, 在此基础上进行了后续的分析处理。

上述方法对 MTS 降维时, 分别对数据集中每个 MTS 进行主成分分析, 采用方差贡献率较大的前几个主成分作为基向量, 形成低维特征空间, 再将 MTS 向该低维特征空间上投影以实现降维. 这些方法存在以下不足: 1) 在对每个 MTS 进行主成分分析时, 由于各 MTS 的低维特征空间互不相同, 各个 MTS 是向不同的低维空间上投影实现的降维, 虽然达到了降维的目的, 但却破坏了降维序列的同构性; 2) 需要分别对数据集中每个 MTS 进行主成分分析, 计算复杂度较高; 3) 对 MTS 降维后, 仅仅比较分析了降维前后的变量维数, 而对于降维的有效性缺少必要的分析。

本文仅研究针对变量维的约简, 而针对时间维的约简一般被称为特征模式提取^[7-8]。

2 主成分分析与共同主成分分析

2.1 主成分分析

主成分分析 (PCA)^[9] 是统计学中分析多元数据

的一种有效方法, 它可以在不损失或损失很少原有信息的前提下, 将原来个数较多且彼此相关的变量用线性组合的方法转化为新的个数较少且彼此不相关的综合指标, 起到一种“降维”的作用。

它将方差的大小作为衡量信息量多少的标准, 通过线性变换保留方差大、含信息多的分量, 丢掉信息量少的分量, 从而在最小均方误差下, 降低数据的维数. PCA 已成为数据处理中应用最为广泛的降维方法之一。

2.2 共同主成分分析

PCA 方法实际上是寻找一组相互正交的方向向量 (主成分), 构成一个低维特征空间, 使得原始数据在低维特征空间上的投影能够最大程度地体现差异性^[10-11]. 例如, 对二元变量 (X_1, X_2) 的 30 次观察值进行主成分分析, 得到两个相互正交的主成分 PC_1 和 PC_2 , 如图 1 所示, 两个主成分均可由原始变量的线性变换得到. 从图 1 中可以看出, 二维平面上 30 个点的波动大部分可以归结为在 PC_1 方向的波动, 而在 PC_2 方向上的波动很小, 可以忽略, 这样可以将二维问题降为一维处理, 从而达到降维的目的。




图 1 多元数据对象的两个主成分

在传统的降维计算中, PCA 方法仅针对一组多元数据对象, 即一个矩阵便能表示全部原始数据. 在 MTS 数据集中, 每个序列都是一组多元数据对象, 按照文献 [3-6] 的思路, 分别对每一序列进行主成分分析, 也能达到降维的目的. 但由于各序列的主成分不同, 降维是通过向不同低维空间上投影实现的. 因各降维序列上的对应变量是由原始变量的不同线性变化得到的, 故不同序列降维后的变量之间并不完全对应, 它们表示的含义也不完全相同, 可见降维破坏了 MTS 的同构性, 给后续的分析处理带来了困难。

降维本身不是最终目的, 而是为了简化后续的分析处理, 为此, 针对 MTS 数据集, 本文提出一种基于共同主成分分析 (CPCA) 的降维方法。

CPCA 基于如下假设^[12]: 对于 MTS 数据集中的所有序列, 存在一个由相互正交的向量构成的公共子空间, 使得各序列在该公共子空间上的投影能够最大程度地体现特征差异. 构成公共子空间的这组相互正交的向量被称为共同主成分。

3 基于 CPCA 的 MTS 降维方法

3.1 基于 CPCA 的 MTS 降维模型

MTS 数据集中, 第 k ($k = 1, 2, \dots, l$) 个序列可以视为一组随机变量 $X_k = [x_1, x_2, \dots, x_m]^T$ 在 n_k 个连续时间点上的观察值. 设数学期望 $E(X_k) = 0$; 若 $E(X_k) \neq 0$, 则令 $X_k' = X_k - E(X_k)$, 从而得到 $E(X_k') = 0$. 而协方差为

$$C_k = E[(X_k - E(X_k))(X_k - E(X_k))^T]. \quad (1)$$

因为 $E(X_k) = 0$, 故协方差矩阵为自相关矩阵, 即

$$C_k = E(X_k X_k^T). \quad (2)$$

MTS 具有相同的变量数 m , 仅在时间长度上存在差异, 因此, C_k 是一个 $m \times m$ 的矩阵. C_k 中第 i 行、第 j 列上的元素 $C_k(i, j)$ 表示第 k 个 MTS 中第 i 个变量和第 j 个变量间的协方差.

如果对 l 个序列的协方差矩阵取平均, 即

$$\bar{C} = \frac{1}{l} \sum_{k=1}^l C_k, \quad (3)$$

则矩阵 \bar{C} 可以理解成 l 个序列的平均协方差矩阵, 矩阵中的元素 $\bar{C}(i, j)$ 表示第 i 个变量和第 j 个变量在 l 个序列上的平均协方差.

计算 \bar{C} 的特征值 $\lambda_1, \lambda_2, \dots, \lambda_m$ 和对应的归一化特征向量 U_1, U_2, \dots, U_m , 有

$$\bar{C}U_i = \lambda_i U_i, \quad i = 1, 2, \dots, m. \quad (4)$$

不妨设特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$, 则 $y_i = U_i^T X$ ($i = 1, 2, \dots, m$) 即为输入数据在低维特征空间第 i 个维度上的投影. 定义方差贡献率

$$\varphi(p) = \frac{\sum_{i=1}^p \lambda_i}{\sum_{i=1}^m \lambda_i}. \quad (5)$$

当 $\varphi(p)$ 足够大时, 可将前 p 个特征向量 u_1, u_2, \dots, u_p 构成的空间作为低维投影空间, 从而达到降维的目的.

从以上推导过程可知, CPCA 方法可视为 PCA 方法在处理 MTS 数据集时的推广. 当数据集中仅包含一组序列时, CPCA 方法自然过渡为 PCA 方法.

3.2 基于 CPCA 的 MTS 降维步骤

基于 CPCA 的 MTS 降维步骤如下:

1) 将 MTS 的变量理解为随机变量, 各个时间点上的值视为随机变量的观察值, 计算 l 个 MTS 的协方差矩阵 C_k ($k = 1, 2, \dots, l$);

2) 由式 (3) 计算 l 个 MTS 的平均协方差矩阵 \bar{C} ;

3) 由式 (4) 计算平均协方差矩阵 \bar{C} 的特征值与特征向量;

4) 由步骤 3) 的结果, 按照数值大小对特征值进行排序, 再根据排序结果确定对应特征向量的次序;

5) 由式 (5) 和方差贡献率, 确定需要保留的特征个数 p ;

6) 以前 p 个特征向量张成的空间作为公共低维特征空间, 把 l 个 MTS 依次向该空间上投影, 得到变量维数为 p 的降维序列 ($p < m$).

3.3 计算复杂度分析

下面比较 PCA 和 CPCA 方法的计算复杂度. 两种方法都包括以下主要步骤: 1) 计算序列的协方差矩阵; 2) 计算协方差矩阵的特征值与特征向量; 3) 向低维特征空间上投影.

针对含有 l 个 MTS 的数据集, 两种方法在各步骤上的计算次数如表 1 所示. 可以看出, 与 PCA 方法相比, CPCA 方法节省了 $l - 1$ 次特征值与特征向量的求解, 而计算一次特征值与特征向量的复杂度为 $O(m^3)$. 当 l 很大时, 节省的计算量较为明显.

表 1 两种方法计算复杂度的比较

降维方法	计算协方差矩阵	计算特征值与特征向量	低维投影
PCA	l	l	l
CPCA	l	1	l

4 实验与分析

4.1 实验方法与实验数据

实验从两方面比较降维性能: 1) 降维幅度, 其值越大, 说明降维效果越明显; 2) 降维有效性, 即原始数据的特征是否得到有效保留, 保留得越充分, 降维结果越有效. 实验以降维结果作为模式匹配方法的输入数据, 通过匹配精度来间接比较降维结果的有效性.

为了便于比较, 选用已知分类结果的 MTS 数据集, 采用 k -近邻的方法进行实验, 步骤描述如下.

实验数据集中含有 n 个 MTS 样本, 对所有样本进行降维处理, 从降维结果集中任意抽取一个降维序列作为样本, 记为输入样本 X . 然后, 使用相应的模式匹配方法, 在降维结果集中找出与 X 最相似的“ k 个样本”. 统计找出的“ k 个样本”中与 X 类别相同的样本个数 n_0 , 按照下式计算准确率 e :

$$e = n_0/k. \quad (6)$$

对于降维结果集中其他任意一个降维序列, 一一作为输入样本, 重复以上实验, 并计算相应的准确率, 这样便可得到 n 个模式匹配的准确率. 如果将准确率作为一个离散型随机变量 ε , 则准确率的数学期望可按式确定:

$$e^* = \sum_{t=1}^k p(\varepsilon = e_t) \times e_t, \quad (7)$$

并用其作为降维有效性的比较依据. 准确率的数学期望越高, 说明在该模式匹配模型下, 降维方法的特征保留能力越强、降维有效性越高.

实验环境为: Matlab 7.0, Windows XP Professional SP3, 300 G 硬盘, 1.98 G 内存, Intel(R) Core(TM)2 Duo CPU. 选取两组 MTS 数据集作为实验对象: Australian sign language^[13]和 EEG^[14].

Australian sign language (记为 ASL) 包含 22 个变量, 左、右手的动作特征各用 11 个变量刻画: 6 个变量 (分别对应 6 个自由度) 表示手所处的位置, 5 个变量表示各手指的弯曲程度. 该数据集包含 95 种语意 (95 个类), 每种语意都有 27 组序列. 不失一般性, 选取前 8 种语意对应的序列作为实验数据集, 一共 216 个样本, 时间跨度在 47~95 之间.

EEG 是用 256 Hz 的电极同时在 64 个部位测得的一组脑电图数据, 数据来源于两种人群 (2 个类): alcoholic subjects 和 control subjects. 不失一般性, 选取前 2 位测试者 (编号为 co2a0000364 和 co2c0000337) 的前 11 次测试作为实验数据集, 一共 22 个样本, 时间跨度均为 256.

4.2 模型参数选择

两种方法都仅包含一个参数——方差贡献率 σ . σ 越大, 特征保留程度越高, 但保留变量数越多、降维幅度越小; σ 越小, 特征保留程度越低, 但保留变量数越少、降维幅度越高. σ 取值一般为 70%~90%^[9], 实验中取 $\sigma = 80%$.

PCA 方法需要对每个 MTS 逐个进行主成分分析, 当确定 σ 后, 每个序列保留的主成分数 p_i 有所不同. 此时, 按下式计算主成分数的最大值 p :

$$p = \max(p_1, p_2, \dots, p_n), \quad (8)$$

并用其作为每个序列保留的主成分数.

4.3 实验结果与分析

实验 1 两种方法降维幅度的比较.

分别使用两种方法对 ASL 和 EEG 数据集进行降维, 降维前后的变量数及降维幅度如表 2 所示, 降维幅度保留 2 位有效数字.

表 2 两种方法的降维幅度

降维方法	ASL (22 个原始变量)		EEG (64 个原始变量)	
	降维后变量数	降维幅度	降维后变量数	降维幅度
PCA	2	0.91	11	0.83
CPCA	2	0.91	4	0.94


与 PCA 方法相比, CPCA 方法保留的特征数更少, 这是因为在 $\sigma = 80%$ 的条件下, CPCA 方法只通过一次主成分分析来确定主成分数 p ; 而 PCA 方法需要先对每个 MTS 逐个进行主成分分析, 再由式 (8) 得到各主成分数的最大值.

实验 2 两种方法的降维有效性分析.


以实验 1 的降维结果作为有效性分析的输入数

据, 分别使用 DTW、PD^[15]和 SVD 三种模式匹配模型进行 k -近邻查询, 以匹配精度作为降维有效性比较的依据. 实验结果见图 2~图 4. 其中: 横坐标表示 k 的取值, 纵坐标表示准确率的数学期望. 为了便于分析比较, 图中还包括直接以原始数据作为输入的匹配精度和随机方法的匹配结果.

随机方法是指进行 k -近邻匹配时, 从数据集中随机抽取 k 个样本作为输入样本的 k -近邻, 其匹配精度等于匹配模型失效时的结果. 例如, ASL 包含 8 种类别, 每种类别包含的样本数量相同, 当匹配准确率为 $1/8$ 时, 相当于从数据集中随机抽取 k 个样本作为输入样本的 k -近邻.




(a) 针对 ASL 的实验结果




(b) 针对 EEG 的实验结果

图 2 使用 DTW 模型比较两种方法的降维有效性



(a) 针对 ASL 的实验结果



(b) 针对 EEG 的实验结果

图 3 使用 PD 模型比较两种方法的降维有效性

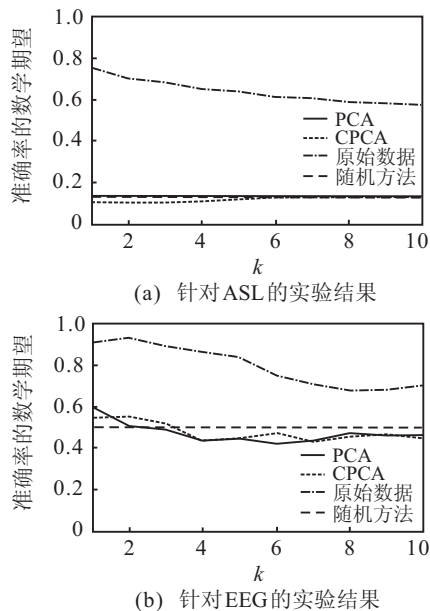


图4 使用SVD模型比较两种方法的降维有效性

图2是DTW模型的匹配结果,在ASL和EEG中,CPCA方法的准确率均高于PCA方法.图3是PD模型的匹配结果,其中:PD方法针对ASL、EEG降维结果的分割形式分别为 $X[i-1:i+1, j-1:j+1]$, $X[i-3:i+3, j-4:j+4]$;针对ASL、EEG原始数据的分割形式分别为 $X[i-1:i+1, j-1:j+1]$, $X[i-16:i+16, j-4:j+4]$.图3(a)中,CPCA方法的准确率高于PCA方法;图3(b)中,CPCA方法的匹配精度与PCA方法相当,但前者保留的变量数远少于后者.图4是使用SVD匹配模型的实验结果,可以看出,以两种方法的降维结果作为输入,匹配精度都很低,与随机方法的结果相近.

由以上分析可知:1)与PCA方法相比,CPCA方法的降维有效性更高.这是因为PCA方法是通过把各个序列向不同低维空间上投影来实现降维,破坏了MTS的同构性,减弱了降维序列间的可比较性;而CPCA方法是通过把各个序列向一个公共低维空间上投影来实现降维.2)两种方法对DTW、PD匹配模型具有适用性,而不适用于SVD匹配模型.这是因为两种方法都以主成分分析为基础,降维消除了变量间的相关性;而SVD方法则以变量间的相关系数作为特征提取和模式匹配的基础.




图5 两种方法耗费时间的比较

实验3 方差贡献率 σ 取不同值时,测量两种方法的时间消耗.为了消除实验环境引起的偏差,以两种方法计算时间的比值作为比较依据,结果见图5.可以看出,在ASL和EEG中,CPCA方法的耗费时间均小于PCA方法.

5 结论

本文提出了一种适用于多元时间序列的降维方法,并通过实验验证了该方法的有效性.与PCA方法相比,CPCA方法的优点是:1)通过把各个多元时间序列向一个公共的低维特征空间上投影,保持了降维序列的同构性,提高了降维的有效性;2)在一定程度上,降低了计算复杂度.实验结果表明,CPCA方法对DTW和PD匹配模型均具有较好的适用性,而不适用于SVD匹配模型.

参考文献(References)

- [1] 胡洁. 高维数据特征降维研究综述[J]. 计算机应用研究, 2008, 25(9): 2601-2605.
(Hu J. Survey on feature dimension reduction for high-dimensional data[J]. Application Research of Computers, 2008, 25(9): 2601-2605.)
- [2] 毛云建. 多维时间序列数据挖掘的方法研究及应用[D]. 上海: 上海交通大学自动控制系, 2007.
(Mao Y J. Research and implementation of multidimensional time-series data mining methods[D]. Shanghai: Automation Department, Shanghai Jiaotong University, 2007.)
- [3] 张军, 吴绍春, 王炜. 多变量时间序列模式挖掘的研究[J]. 计算机工程与设计, 2006, 27(18): 3364-3366.
(Zhang J, Wu S C, Wang W. Research of data mining method on multivariate time series[J]. Computer Engineering and Design, 2006, 27(18): 3364-3366.)
- [4] 杨兴江, 周勇. 多元时间序列相似性研究[J]. 西南民族大学学报, 2007, 33(4): 864-869.
(Yang X J, Zhou Y. Research on similarity of the multivariate time series[J]. J of Southwest University for Nationalities, 2007, 33(4): 864-869.)
- [5] 周大镛, 吴晓丽, 闫红灿. 一种高效的多变量时间序列相似查询算法[J]. 计算机应用, 2008, 28(10): 2541-2543.
(Zhou D Z, Wu X L, Yan H C. An efficient similarity search for multivariate time series[J]. Computer Applications, 2008, 28(10): 2541-2543.)
- [6] 周大镛, 姜文波, 李敏强. 一个高效的多变量时间序列聚类算法[J]. 计算机工程与应用, 2010, 46(1): 137-139.
(Zhou D Z, Jiang W B, Li M Q. Efficient clustering algorithm for multivariate time series[J]. Computer Engineering and Applications, 2010, 46(1): 137-139.)

- [7] 陈湘涛, 李明亮, 陈玉娟. 基于分割模式的时间序列矢量符号化算法[J]. 计算机工程, 2011, 37(4): 55-57.
(Chen X T, Li M L, Chen Y J. Vector symbolization algorithm for time series based on segmentation mode[J]. Computer Engineering, 2011, 37(4): 55-57.)
- [8] 李正欣, 张凤鸣, 李克武. 多元时间序列模式匹配方法研究[J]. 控制与决策, 2011, 26(4): 565-570.
(Li Z X, Zhang F M, Li K W. Research on pattern matching method for multivariate time series[J]. Control and Decision, 2011, 26(4): 565-570.)
- [9] Jolliffe I T. Principal component analysis[M]. New York: Springer, 2002: 55-58.
- [10] 范金城, 梅长林. 数据分析[M]. 北京: 科学出版社, 2002: 141-142.
(Fan J C, Mei C L. Data analysis[M]. Beijing: Science Press, 2002: 141-142.)
- [11] 张煜东, 霍元铠, 吴乐南, 等. 降维技术与方法综述[J]. 四川兵工学报, 2010, 31(10): 1-7.
(Zhang Y D, Huo Y K, Wu L N, et al. Survey of dimension reduction technology and methods[J]. Sichuan Acta Armamentar, 2010, 31(10): 1-7.)
- [12] Yoon Hyunjin, Yang Kiyoun, Shahabi Cyrus. Feature subset selection and feature ranking for multivariate time series[J]. IEEE Trans on Knowledge and Data Engineering, 2005, 17(9): 1186-1198.
- [13] Mohammed Waleed Kadous. High-quality recordings of Australian sign language signs[EB/OL]. [2011-04-26]. [http://kdd.ics.uci.edu/databases/High-quality Australian Sign Language/High-quality Australian Sign Language.html](http://kdd.ics.uci.edu/databases/High-quality%20Australian%20Sign%20Language/High-quality%20Australian%20Sign%20Language.html).
- [14] Henri Begleiter. EEG database[EB/OL]. [2011-05-12]. <http://kdd.ics.uci.edu/databases/eeg/eeg.html>.
- [15] 管河山, 姜青山, 王声瑞. 基于点分布特征的多元时间序列模式匹配方法[J]. 软件学报, 2009, 20(1): 67-79.
(Guan H S, Jiang Q S, Wang S R. Pattern matching method based on point distribution for multivariate time series[J]. J of Software, 2009, 20(1): 67-79.)

(上接第530页)

- [9] 阳春华, 温丽敏, 朱红求, 等. 基于满意优化的氧化铝生料浆调配方法[J]. 控制与决策, 2008, 23(10): 1168-1172.
(Yang C H, Wen L M, Zhu H Q, et al. Satisfactory optimization of raw slurry arrangement for process of alumina production[J]. Control and Decision, 2008, 23(10): 1168-1172.)
- [10] 阳春华, 段小刚, 王雅琳, 等. 烧结法生产氧化铝生料浆的配料专家系统设计[J]. 中南大学学报, 2005, 36(4): 648-652.
(Yang C H, Duan X G, Wang Y L, et al. Blending expert system for raw mix slurry in production of alumina with sintering process[J]. J of Center South University, 2005, 36(4): 648-652.)
- [11] 白锐, 柴天佑, 周俊武. 生料浆配料过程磨机负荷的混合智能控制[J]. 信息与控制, 2009, 38(4): 473-478.
(Bai R, Chai T Y, Zhou J W. Hybrid intelligent control of mill load in the blending process of raw slurry[J]. Information and Control, 2009, 38(4): 473-478.)
- [12] 白锐. 生料浆配料过程智能优化控制系统的研究[D]. 沈阳: 东北大学信息科学与工程学院, 2007.
(Bai R. Intelligent optimizing control system for the blending process of raw slurry[D]. Shenyang: College of Information Science and Engineering, Northeastern University, 2007.)
- [13] Bai R, Tong S C, Chai T Y. Intelligent prediction method of technical indices in the industrial process and its application[C]. The 48th IEEE Conf on Decision and Control. Shanghai, 2009: 7291-7296.
- [14] 孔玲爽, 阳春华, 王雅琳, 等. 一种解决蕴含不确定性信息的氧化铝配料问题的智能优化方法[J]. 控制理论与应用, 2009, 26(9): 1051-1055.
(Kong L S, Yang C H, Wang Y L, et al. Intelligent optimization of raw material blending for alumina production with information uncertainty[J]. Control Theory & Applications, 2009, 26(9): 1051-1055.)
- [15] Yang C H, Gui W H, Kong L S. A genetic-algorithm-based optimal scheduling system for full-filled tanks in the processing of starting materials for alumina production[J]. Canadian J of Chemical Engineering, 2008, 86(4): 804-812.
- [16] 郭万里, 白锐, 王春霞. 基于 PSO 算法的生料浆调槽过程优化控制[J]. 中南大学学报, 2011, 42(增): 165-168.
(Guo W L, Bai R, Wang C X. Optimal control of the raw slurry blending tank process based on the particle swarm optimization algorithm[J]. J of Center South University, 2011, 42(S): 165-168.)