

文章编号: 1001-0920(2017)01-0163-04

DOI: 10.13195/j.kzyjc.2015.1556

## 小时间序列的动态朴素贝叶斯分类器学习与优化

王双成<sup>a,b†</sup>, 高 瑞<sup>a</sup>, 杜瑞杰<sup>a</sup>

(上海立信会计学院 a. 数学与信息学院, b. 立信会计研究院, 上海 201620)

**摘 要:** 小时间序列在宏观经济领域普遍存在, 对小时间序列的分类预测也有着广泛的需求. 由于小时间序列蕴含的信息不充分, 有效地提高小时间序列分类预测的可靠性非常困难, 目前也缺少这方面的研究. 针对这种情况, 在基于引入平滑参数的高斯核函数估计属性边缘密度的基础上, 建立用于小时间序列分类预测的动态朴素贝叶斯分类器, 并给出平滑参数的同步和异步优化方法. 实验结果表明, 优化能够显著提高小时间序列分类预测的准确性.

**关键词:** 贝叶斯网络; 分类器; 时间序列; 高斯核函数; 平滑参数

中图分类号: TP181

文献标志码: A

## Learning and optimization of dynamic naive Bayesian classifiers for small time series

WANG Shuang-cheng<sup>a,b†</sup>, GAO Rui<sup>a</sup>, DU Rui-jie<sup>a</sup>

(a. School of Mathematics & Information, b. Lixin Accounting Research Institute, Shanghai Lixin University of Commerce, Shanghai 201620, China)

**Abstract:** The small time series exists generally in the field of macroeconomy. There are wide demands for the classification of small time series in macroeconomy. Because the information contained in the small time series is not sufficient, it is very difficult to effectively improve the reliability of small time series classification. In view of this situation, on the basis of using the Gaussian kernel function of introducing the smoothing parameter to estimate the attribute marginal density, the dynamic naive Bayesian classifier for small time series classification is presented, and the synchronous and asynchronous optimization method for smoothing parameters are given. The experimental results show that the classification accuracy of the small time series classifier can be improved significantly by optimization.

**Keywords:** Bayesian network; classifiers; time series; Gaussian kernel function; smoothing parameter

### 0 引 言

动态贝叶斯网络<sup>[1]</sup>是描述随机变量之间依赖关系的图模型, 可在统一的概率框架下将静态与动态信息融为一体, 并通过量化推理进行时间序列分析、预测和控制等. 动态贝叶斯网络有两种主要的表现形式, 它们分别是用于因果分析的因果动态贝叶斯网络和用于预测的动态贝叶斯网络分类器. 一般的动态贝叶斯网络分类器不适合于小时间序列的分类, 因为它需要大量的离散数据用于训练. 动态朴素贝叶斯分类器(DNBC)不需要许多时序数据用于训练, 只需估计类转移概率和属性边缘密度<sup>[2-3]</sup>, 并且可以直接处理连续属性, 因此可用于小时间序列的分类. 虽然目前存在一些动态贝叶斯网络分类器方面的研究, 但主要针对的是离散属性的情况, 需要将连续属性离散化,

但离散化连续属性可能导致信息丢失, 引入噪声和类对属性的变化不够敏感等问题, 对于小时间序列更是如此. 采用不对连续属性进行离散化的方法建立动态朴素贝叶斯分类器, 需估计属性的密度. 在基于属性密度估计的贝叶斯网络分类器方面已有许多研究. 20 世纪末, John 等<sup>[4]</sup>研究了使用高斯边缘密度和高斯核边缘密度的朴素贝叶斯分类器(NBC); Pérez 等<sup>[5-6]</sup>采用高斯函数和高斯核函数估计属性的条件密度, 建立了贝叶斯网络分类器, 进一步发展了 John 和 Langley 的工作; 文献 [7-10] 基于高斯函数(或高斯核函数)估计属性联合密度进行了完全贝叶斯分类器学习. 这些属性密度估计方法的研究有力地推动了连续属性贝叶斯网络和动态贝叶斯网络分类器的发展, 但在对小时间序列的分类方面均不同程度地存在一些问题.

收稿日期: 2015-12-16; 修回日期: 2016-04-29.

基金项目: 国家自然科学基金项目(61272209); 上海市自然科学基金项目(15ZR1429700).

作者简介: 王双成(1958—), 男, 教授, 博士, 从事人工智能、机器学习、数据采掘及其应用等研究; 高瑞(1980—), 女, 讲师, 博士, 从事应用统计与数据采掘的研究.

†通信作者. E-mail: wangsc@lixin.edu.cn

DNBC 受条件独立性假设的约束,这一假设使得 DNBC 适合于小时间序列的分类,但同时也会降低 DNBC 的分类准确性.目前主要通过通过对 DNBC 的依赖扩展解决这一问题,但效果并不明显,其主要原因是小时间序列蕴含的信息不充分,这使依赖扩展的过程和扩展后分类器的学习在可靠性方面都得不到保障.

本文的主要贡献如下:

1) 在将高斯函数的平移叠加(充分利用每一个例子数据(纵向)蕴含的信息)与高斯函数曲线的形状调整(充分挖掘每一个属性(横向)在分类过程中的潜在作用)相结合的基础上,建立适合于小时间序列分类的动态朴素贝叶斯分类器(DNBK).

2) 将动态分类准确性标准、平滑参数的区间异步长划分与完全打分搜索相结合,分别给出平滑参数的同步优化(提高分类器整体与数据的拟合程度)和异步优化(提高分类器局部与数据的拟合程度)的方法,在能够有效提高 DNBK 与数据拟合程度的同时,可避免产生过度拟合问题.

3) 选择具有实际意义的宏观经济问题和小时间序列数据进行实验,验证使用 DNBK 进行小时序分类的可靠性.

文章分为5个部分:第1部分是动态贝叶斯网络分类器的发展回顾与分析;第2部分给出建立 DNBK 的方法,其核心是属性密度估计;第3部分是平滑参数的同步和异步优化方法;第4部分使用宏观经济时序数据进行实验与分析;第5部分是结论和进一步的工作.

## 1 DNBK

采用  $X_i[1], \dots, X_i[t], \dots, X_i[T]$  ( $1 \leq i \leq n, 1 \leq t \leq T$ ) 和  $C[1], \dots, C[t], \dots, C[T]$  表示属性和类变量序列,  $x_i[1], \dots, x_i[t], \dots, x_i[T]$  和  $c[1], \dots, c[t], \dots, c[T]$  是具体的取值;  $D[1], \dots, D[t], \dots, D[T]$  是累计时间片数据集序列,  $D[1] \subset \dots \subset D[t] \subset \dots \subset D[T]$  和  $N[1], \dots, N[t], \dots, N[T]$  是时间序列数据集中满足相应条件的例子数量.

### 1.1 DNBK 表示

DNBK 具有确定的结构,不需要结构学习.具体的 DNBK 结构用  $S[t]$  表示,如图1所示.




图1 DNBK 结构

根据图1给出的 DNBK 结构可以得到

$$p(c[t]|c[1], \dots, c[t-1], x_1[1], \dots, x_n[1], \dots, x_1[t], \dots, x_n[t], S[t]) =$$

$$p(c[t]|c[t-1], x_1[t], \dots, x_n[t], S[t]) = \frac{f(c[t], c[t-1], x_1[t], \dots, x_n[t], S[t])}{f(c[t-1], x_1[t], \dots, x_n[t], S[t])} = \alpha p(c[t]|c[t-1]) \prod_{i=1}^n f(x_i[t]|c[t]). \quad (1)$$

其中:  $\alpha$  是与  $c[t]$  无关的量,  $p(c[t]|c[t-1])$  是类转移概率,  $f(x_i[t]|c[t])$  是属性条件密度.

根据式(1), DNBK 可表示为

$$\operatorname{argmax}_{c[t](c[t-1], x_1[t], \dots, x_n[t])} \left\{ p(c[t]|c[t-1]) \prod_{i=1}^n f(x_i[t]|c[t]) \right\}. \quad (2)$$

用  $\operatorname{dnbk}(c[t](c[t-1], x_1[t], \dots, x_n[t]))$  表示 DNBK.

### 1.2 基于高斯核函数的属性密度估计

用  $\hat{f}(x_i[t]|c[t], D[t], S[t])$  表示  $f(x_i[t]|c[t], S[t])$  的估计,则有

$$\hat{f}(x_i[t]|c[t], D[t], S[t]) = \frac{1}{N(c[t-1])} \sum_{v=1}^{t-1} \operatorname{signa}(c[v]) \times g\left(x_i[t]; x_i[v], \frac{h_i}{\sqrt{N(c[t-1])}} | D[t], S[t]\right). \quad (3)$$

其中:  $N(c[t-1])$  是时序数据集中  $c[v] = c[t]$  ( $1 \leq v \leq t-1$ ) 的情况数量;  $g(\cdot)$  是高斯函数;  $h_i$  ( $i = 1, 2, \dots, n$ ) 是平滑参数; 且有  $\operatorname{signa}(c[v]) = \begin{cases} 1, & c[v] = c[t]; \\ 0, & c[v] \neq c[t]. \end{cases}$

通过对平滑参数  $h_i$  的优化提高 DNBK 的分类准确性,用  $\mathbf{h} = (h_1, h_2, \dots, h_n)$  表示平滑参数向量.

### 1.3 分类准确性的评价

对于  $x_1[1], \dots, x_n[1], c[1], \dots, x_1[T], \dots, x_n[T], c[T]$ , 选择一个阈值  $T_0$ , 用  $\operatorname{accuracy}(\operatorname{dnbk}, \mathbf{h}, D[T], T_0)$  表示 DNBK 的分类准确率,  $c_{\text{prediction}}[t]$  是使用  $x_1[1], \dots, x_n[1], c[1], \dots, x_1[t-1], \dots, x_n[t-1], c[t-1]$  进行训练, 并依据  $x_1[t], x_2[t], \dots, x_n[t]$  的配置对  $c[t]$  的预测结果,  $c_{\text{true}}[t]$  是真正的结果, 则有

$$\operatorname{accuracy}(\operatorname{dnbk}, \mathbf{h}, D[T], T_0) = \frac{1}{T - T_0} \sum_{t=T_0+1}^T \operatorname{signb}(c_{\text{prediction}}[t], c_{\text{true}}[t]), \quad (4)$$

其中

$$\operatorname{signb}(c_{\text{prediction}}[t], c_{\text{true}}[t]) = \begin{cases} 1, & c_{\text{prediction}}[t] = c_{\text{true}}[t]; \\ 0, & c_{\text{prediction}}[t] \neq c_{\text{true}}[t]. \end{cases}$$

## 2 平滑参数优化

分两个阶段对平滑参数进行优化,对所有的平滑参数进行同步优化,获得最优设置  $h^*$ ,在此基础上再进行一致异步优化,得到配置  $h_1^*, h_2^*, \dots, h_n^*$ . 根据  $T'$  与  $T$  的接近程度决定是否实施非一致异步优化. 如

果需要,则最终得到非一致异步优化的配置  $h_1^{**}, h_2^{**}, \dots, h_n^{**}$ , 具体的优化流程如图2所示。

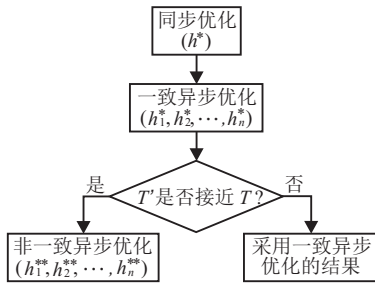


图2 平滑参数优化

## 2.1 同步优化

设  $h = h_1 = \dots = h_n$ , 对于区间  $(0, 1)$ , 选择较小的  $\Delta_1^{(0,1)}$ , 这样得到一个  $h$  值序列  $s_1^{(1)} = \Delta_1^{(0,1)}, s_2^{(1)} = s_1^{(1)} + \Delta_1^{(0,1)}, s_3^{(1)} = s_1^{(1)} + 2\Delta_1^{(0,1)}, \dots$ . 用  $a^{(1)}$  表示在  $h$  值序列中  $\text{accuracy}(\text{dnbk}, h, D[T], T_0)$  的最大值, 设对应的  $h$  值序列为  $m_{r_1}^{(1)} \Delta_1^{(0,1)}, m_{r_1+1}^{(1)} \Delta_1^{(0,1)}, \dots, m_{r_1+s_1}^{(1)} \Delta_1^{(0,1)}$ . 对于  $m_{r_1}^{(1)} \Delta_1^{(0,1)}$  和  $m_{r_1+s_1}^{(1)} \Delta_1^{(0,1)}$ , 若  $m_{r_1}^{(1)} \Delta_1^{(0,1)} - \Delta_1^{(0,1)} = 0$ , 则修正左端点为  $s_1^{(2)} = m_{r_1}^{(1)} \Delta_1^{(0,1)} - \frac{1}{2} \Delta_1^{(0,1)}$ , 而  $m_{r_1+s_1}^{(1)} \Delta_1^{(0,1)} + \Delta_1^{(0,1)} = 1$  时修正右端点为  $m_{r_1+s_1}^{(1)} \Delta_1^{(0,1)} + \frac{1}{2} \Delta_1^{(0,1)}$ . 选取  $\Delta_2^{(0,1)} = \frac{1}{10} \Delta_1^{(0,1)}$ , 关于区间  $(m_{r_1}^{(1)} \Delta_1^{(0,1)} - \Delta_1^{(0,1)}, m_{r_1+s_1}^{(1)} \Delta_1^{(0,1)} + \Delta_1^{(0,1)})$  (或者修正后的区间) 又得到一个  $h$  值序列  $s_1^{(2)}, s_2^{(2)} = s_1^{(2)} + \Delta_2^{(0,1)}, s_3^{(2)} = s_1^{(2)} + 2\Delta_2^{(0,1)}, \dots$ . 用  $a^{(2)}$  表示在新的  $h$  值序列中  $\text{accuracy}(\text{dnbk}, h, D[T], T_0)$  的最大值, 对应的  $h$  值序列为  $m_{r_2}^{(2)} \Delta_2^{(0,1)}, m_{r_2+1}^{(2)} \Delta_2^{(0,1)}, \dots, m_{r_2+h_2}^{(2)} \Delta_2^{(0,1)}$ . 同样, 如果  $m_{r_2}^{(2)} \Delta_2^{(0,1)} - \Delta_2^{(0,1)} = 0$ , 则修正左端点为  $s_1^{(3)} = m_{r_2}^{(2)} \Delta_2^{(0,1)} - \frac{1}{2} \Delta_2^{(0,1)}$ , 而  $m_{r_2+h_2}^{(2)} \Delta_2^{(0,1)} + \Delta_2^{(0,1)} = 1$  时修正右端点为  $m_{r_2+h_2}^{(2)} \Delta_2^{(0,1)} + \frac{1}{2} \Delta_2^{(0,1)}$ . 如果  $a^{(2)} = a^{(1)}$ , 则选取  $h^* = \frac{1}{2}(m_{r_2+h_2}^{(2)} \Delta_2^{(0,1)} - m_{r_2}^{(2)} \Delta_2^{(0,1)})$  (如果有修正值, 则使用修正值计算); 否则继续, 直到  $a^{(k)} = a^{(k-1)}$  最终选取  $h^* = \frac{1}{2}(m_{r_k+h_k}^{(k)} \Delta_k - m_{r_k}^{(k)} \Delta_k)$ . 对于区间  $[1, h_{\max}]$  ( $h_{\max}$  由实验确定) 可作类似处理, 只需将  $\Delta_1^{[1, h_{\max}]}$  设置得更大一些 (平滑参数的值越大, 分类准确率对平滑参数的变化越不敏感). 两个区间  $(0, 1)$  与  $[1, h_{\max}]$  可联合进行搜索, 也可分别进行搜索, 再通过比较确定最后的平滑参数值。

## 2.2 异步优化

在对类时间序列预测时, 由于被预测的时序类值与时序邻近的类值往往关系比较密切, 能够准确预测邻近的时序类值越多的分类器应该更加可靠. 基于这一原则建立下面的属性平滑参数异步优化方法, 异步优化方法又可分为一致异步优化和非一致异步优化。

1) 一致异步优化。

用  $h^*$  表示经过同步优化的平滑参数值, 取  $h_1 =$

$\dots = h_n = h^*$ . 采用同步优化方法使  $\text{accuracy}(\text{dnbk}, \mathbf{h}, D[T], T) = 1$  为标准, 其中  $i = 1, 2, \dots, n$ , 依次对  $h_1, h_2, \dots, h_n$  进行优化设置, 假设最优配置是  $h_1^{(T)}, h_2^{(T)}, \dots, h_n^{(T)}$ . 在  $h_1^{(T)}, h_2^{(T)}, \dots, h_n^{(T)}$  的基础上, 再以  $\text{accuracy}(\text{dnbk}, \mathbf{h}^{(T)}, D[T], T-1) = 1$  为标准, 依次对  $h_1^{(T)}, h_2^{(T)}, \dots, h_n^{(T)}$  进行优化设置, 假设最优配置是  $h_1^{(T-1)}, h_2^{(T-1)}, \dots, h_n^{(T-1)}$ . 以此类推, 设  $h_1^*, h_2^*, \dots, h_n^*$  是使  $\text{accuracy}(\text{dnbk}, \mathbf{h}^*, D[T], T') = 1, T' \leq T$ , 但是  $\text{accuracy}(\text{dnbk}, \mathbf{h}^*, D[T], T'-1) = \eta < 1$  的配置, 选择  $h_1^*, h_2^*, \dots, h_n^*$  作为  $h_1, h_2, \dots, h_n$  的一致异步优化配置。

2) 非一致异步优化。

当  $T'$  与  $T$  比较接近时, 可以进行非一致异步优化. 设  $T''$  使得  $\text{accuracy}(\text{dnbk}, \mathbf{h}^{**}, D[T], T'') = \eta$ , 但  $\text{accuracy}(\text{dnbk}, \mathbf{h}^{**}, D[T], T''-1) = \xi < \eta$ , 则结束非一致异步优化, 并选择  $h_1^{**}, h_2^{**}, \dots, h_n^{**}$  作为  $h_1, h_2, \dots, h_n$  的非一致异步优化配置. 另外, 也可以使用随机搜索方法 (遗传算法和蚁群算法等) 进行平滑参数的同步或异步优化。

同步优化得到的是所有平滑参数同步变化的最优设置, 但无法体现不同平滑参数 (对应一个属性的边缘分布) 之间的差异. 经过异步优化才能使分类器更好地拟合数据, 而所依据分类准确性标准和原则又可避免分类器与数据的过度拟合, 因此经过异步优化的分类器更加可靠。

## 3 实验与分析

选择与工业增加值 (IAV)、房地产价格 (REP) 和通货膨胀率 (IR) 相关的实际问题, 按照是否为时序转折点 (时序变化的上下局部极值点为转折点) 对 3 个指标进行二值离散化作为类变量, 设置  $\Delta_1^{(0,1)} = 0.001, \Delta_1^{[1, h_{\max}]} = 0.1, h_{\max} = 10$ . 使用 6 个分类器, 从分类预测准确率比较方面进行实验与分析. 6 个分类器分别是采用高斯边缘密度 (GDN)、高斯核边缘密度 (GKDN, 使用 MISE 设置平滑参数)、平滑参数同步优化 (SOD)、平滑参数一致异步优化 (DNBK) 的 4 个 DNBC、条件随机场 (CRF) 分类器、基于高斯条件密度的动态 TAN 分类器 (DTAN).  $T_0$  的值依次选取后 12 个年度, 实验结果如表 1~表 3 所示。

表 1~表 3 的数据显示: 在分类准确性方面, 相对于其他 5 个分类器, DNBK 具有明显优势. 对 3 个数据集的平均值部分再求平均值, 从上到下的顺序依次是 56.06、44.81、46.77、48.53、65.82 和 92.76. 分类器 DNBK 优于其他分类器的百分比分别是 65%、107%、98%、91% 和 41%. 还可以发现: 经过异步优化和同步优化的分类准确率差异较大, 这说明异步优化能使分类器更好地拟合数据. 对 DNBC 进行树结构依赖扩展而得到的 DTAN 分类器的分类准确率相对于 GDN 和 GKDN 有所提高, 但提高的幅度相对较小。

表1 IAV波动转折点预测准确率比较

分类器	$T_0 = 18$	$T_0 = 19$	$T_0 = 20$	$T_0 = 21$	$T_0 = 22$	$T_0 = 23$	$T_0 = 24$	$T_0 = 25$	$T_0 = 26$	$T_0 = 27$	$T_0 = 28$	平均
CRF	36.36	40.00	44.44	50.00	57.14	66.66	60.00	50.00	33.33	50.00	0.00	44.36
GDN	45.45	50.00	55.55	62.50	71.42	66.66	60.00	50.00	33.33	50.00	0.00	49.54
GKDN	54.54	60.00	66.66	75.00	71.42	66.66	60.00	50.00	33.33	50.00	0.00	53.42
DTAN	36.36	40.00	55.55	62.50	71.42	66.66	60.00	50.00	33.33	50.00	0.00	47.80
SOD ( $h = 0.01$ )	63.63	70.00	77.77	87.50	85.71	83.33	80.00	75.00	66.66	100.00	100.00	80.87
DNBK	81.81	90.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	97.44

表2 REP波动转折点预测准确率比较

分类器	$T_0 = 20$	$T_0 = 21$	$T_0 = 22$	$T_0 = 23$	$T_0 = 24$	$T_0 = 25$	$T_0 = 26$	$T_0 = 27$	$T_0 = 28$	$T_0 = 29$	$T_0 = 30$	平均
CRF	54.54	60.00	66.66	75.00	71.42	83.33	80.00	75.00	66.66	50.00	0.00	62.06
GDN	36.36	40.00	33.33	37.50	42.85	50.00	40.00	50.00	33.33	0.00	0.00	33.03
GKDN	27.27	30.00	33.33	37.50	28.57	33.33	40.00	25.00	33.33	50.00	0.00	30.76
DTAN	36.36	40.00	55.55	62.50	42.85	50.00	40.00	50.00	66.66	50.00	0.00	44.90
SOD ( $h = 0.4$ )	54.54	60.00	55.55	62.50	71.42	66.66	60.00	75.00	66.66	50.00	0.00	56.58
DNBK	63.63	60.00	66.66	75.00	85.71	100.00	100.00	100.00	100.00	100.00	100.00	86.45

表3 IR波动转折点预测准确率比较

分类器	$T_0 = 14$	$T_0 = 15$	$T_0 = 16$	$T_0 = 17$	$T_0 = 18$	$T_0 = 19$	$T_0 = 20$	$T_0 = 21$	$T_0 = 22$	$T_0 = 23$	$T_0 = 24$	平均
CRF	81.81	80.00	77.77	75.00	71.42	66.66	60.00	50.00	66.66	50.00	0.00	61.76
GDN	54.54	60.00	55.55	50.00	57.14	66.66	60.00	50.00	66.66	50.00	0.00	51.87
GKDN	63.63	60.00	66.66	62.50	71.42	66.66	60.00	50.00	66.66	50.00	0.00	56.14
DTAN	54.54	60.00	66.66	50.00	57.14	66.66	60.00	50.00	66.66	50.00	0.00	52.88
SOD ( $h = 0.6$ )	72.72	70.00	77.77	75.00	71.42	66.66	60.00	50.00	66.66	50.00	0.00	60.02
DNBK	81.81	80.00	88.88	87.50	100.00	100.00	100.00	100.00	100.00	100.00	100.00	94.38

## 4 结 论

针对目前缺少可用于小时序数据分类的分类器这一实际情况, 本文在将属性密度估计中的高斯函数平移叠加与函数曲线的形状调整相结合的基础上, 建立了适合于小时序数据分类的DNBK, 并分别通过平滑参数的同步和异步优化提高DNBK的分类准确性. 宏观经济数据的实验结果显示, 基于DNBK的小时序数据分类具有良好的分类准确性. 进一步的研究是将类变量的时序影响与平滑参数的调整相结合, 建立平滑参数配置树, 使小时序数据的分类更加可靠.

### 参考文献(References)

- [1] Friedman N, Murphy K, Russell S. Learning the structure of dynamic probabilistic networks[C]. Proc of the 14th Int Conf on Uncertainty in Artificial Intelligence. Madison: Morgan Kaufmann, 1998: 139-147.
- [2] Gao R, Wang S C, Du R J. Extending dynamic naive Bayesian classifier for the time-delay impact analysis of macroeconomic boom index[J]. ICIC Express Letters. Part B, Applications: An International J of Research and Surveys, 2015, 6(11): 3127-3133.
- [3] Friedman N, Geiger D, Goldszmidt M. Bayesian network classifiers[J]. Machine Learning, 1997, 29(2/3): 131-161.
- [4] John G H, Langley P. Estimating continuous distributions in Bayesian classifiers[C]. Proc of the Eleventh Conf on Uncertainty in Artificial Intelligence(UAI-1995). Madison: Morgan Kaufmann, 1995: 338-345.
- [5] Pérez A, Larrañaga P, Inza I. Supervised classification with conditional Gaussian networks: Increasing the structure complexity from naive Bayes[J]. Int J of Approximate Reasoning, 2006, 43(1): 1-25.
- [6] Pérez A, Larranga P, Inza I. Bayesian classifiers based on kernel density estimation: Flexible classifiers[J]. Int J of Approximate Reasoning, 2009, 50(2): 341-362.
- [7] 王双成, 高瑞, 杜瑞杰. 约束高斯分类网研究[J]. 自动化学报, 2015, 41(12): 2128-2140.  
(Wang S C, Gao R, Du R J. Restricted Gaussian classification network[J]. Acta Automatica Sinica, 2015, 41(12): 2128-2140.)
- [8] 王双成, 高瑞, 杜瑞杰. 基于高斯核函数的朴素贝叶斯分类器依赖扩展[J]. 控制与决策, 2015, 30(12): 2280-2284.  
(Wang S C, Gao R, Du R J. Dependency extension of naive Bayesian classifiers based on Gaussian kernel function[J]. Control and Decision, 2015, 30(12): 2280-2284.)
- [9] Dong W Y, Zhou M C. Gaussian classifier-based evolutionary strategy for multimodal optimization[J]. IEEE Trans on Neural Networks & Learning Systems, 2014, 25(6): 1200-1216.
- [10] Pavani S K, Gomez D D, Frangi A F. Gaussian weak classifiers based on co-occurring Haar-like features for face detection[J]. Pattern Analysis and Applications, 2014, 17(2): 431-439.