



属性值加权的一依赖估测器模型分类算法研究

余良俊¹, 甘胜丰¹, 范正薇²

(1. 湖北第二师范学院 计算机学院, 武汉 430205; 2. 湖北广播电视大学 继续教育学院, 武汉 430074)

摘 要: 分类问题是数据挖掘和机器学习领域研究的重点问题, 贝叶斯网络模型因其简单高效的特点而广泛应用于分类问题。一依赖估测器(ODE)模型作为半监督学习贝叶斯网络模型中的经典模型, 受到研究人员的广泛关注。现有的 ODE 模型分类器在进行分类判别时, 未考虑不同的属性节点作为根节点时对分类过程的贡献不同, 为此, 将 ODE 模型分类器与属性值加权方法相结合并提出 MI-ODE 算法。采用相互信息(MI)度量属性根节点的属性值与类变量之间的依赖关系并作为 ODE 模型的权值, 对 ODE 分类器模型进行属性值加权平均。将 MI-ODE 算法应用于现实分类问题的 36 个标准数据集, 结果表明, 相比于 NB 算法、AODE 算法与 TAN 算法, 该算法的分类性能更优。

关键词: 贝叶斯网络; 一依赖估测器; 分类算法; 结构扩展; 属性值加权

开放科学(资源服务)标志码(OSID):



中文引用格式: 余良俊, 甘胜丰, 范正薇. 属性值加权的一依赖估测器模型分类算法研究[J]. 计算机工程, 2020, 46(11): 315-320.

英文引用格式: YU Liangjun, GAN Shengfeng, FAN Zhengwei. Research on classification algorithm combining weighted attribute values with one-dependence estimator model[J]. Computer Engineering, 2020, 46(11): 315-320.

Research on Classification Algorithm Combining Weighted Attribute Values with One-Dependence Estimator Model

YU Liangjun¹, GAN Shengfeng¹, FAN Zhengwei²

(1. College of Computer, Hubei University of Education, Wuhan 430205, China;

2. School of Continuing Education, Hubei Radio & TV University, Wuhan 430074, China)

【Abstract】 In the field of data mining and machine learning, classification is a key problem to which the Bayesian network model is frequently applied due to its simplicity and high efficiency. As a classical Bayesian network model for semi-supervised learning, One-Dependence Estimator (ODE) has been widely concerned by researchers. However, the existing ODE model classifiers do not consider the varying contribution of different attribute nodes acting as root nodes to the classification process. Therefore, this paper combines ODE model classifier with the attribute value weighting method, and on this basis proposes the MI-ODE algorithm. The algorithm adopts Mutual Information (MI) to measure the dependence between attribute values and class variables of the attribute root node, which is used as the weight of the ODE model. Then weighted average is implemented for the attribute values of the ODE classifier model. The MI-ODE algorithm is tested on 36 standard data sets for real-world classification problems, and results show that compared with NB algorithm, AODE algorithm and TAN algorithm, the proposed algorithm has better classification performance.

【Key words】 Bayesian network; One-Dependence Estimator (ODE); classification algorithm; structure extension; attribute value weighting

DOI: 10.19678/j.issn.1000-3428.0056498

基金项目: 湖北省自然科学基金面上项目“属性值加权的贝叶斯网络分类算法研究”(2018CFC893); 湖北省中央引导地方科技发展专项立项项目“区域基础教育资源配置与优化关键技术的研究与应用”(2019ZYD012); 湖北省重点实验室开放基金项目“基于贝叶斯网络分类算法的岩爆预测研究”(KLIGIP-2018A05); 湖北省技术创新专项“土木工程智慧建造仿真交互软硬件系统”(2019AEE020)。

作者简介: 余良俊(1984—), 女, 副教授、博士, 主研方向为数据挖掘、机器学习; 甘胜丰, 副教授、博士; 范正薇, 高级工程师。

收稿日期: 2019-11-05 **修回日期:** 2019-12-08 **E-mail:** yuliangjun@huc.edu.cn

0 概述

分类是机器学习中一项非常重要的任务,是当前人工智能领域的热点研究课题^[1]。常见的分类器构造方法有贝叶斯网络、决策树、演化算法、人工神经网络、粗糙集与模糊集等^[2]。其中,贝叶斯网络结合统计学、图论的相关知识,成为机器学习领域研究中最为流行的方法之一^[3-4],并广泛应用于文本分类^[5]、风险预警^[6]、核密度估计^[7]与情感分析^[8]等诸多领域。

为了提升分类性能,研究人员提出了很多贝叶斯网络分类算法,然而学习最优的贝叶斯网络是一个 NP-hard 问题^[9]。朴素贝叶斯网络模型作为贝叶斯网络模型中经典、简单且高效的模型,得到了广泛的研究应用。朴素贝叶斯网络假设属性之间是相互独立的,该假设称为属性条件独立假设。但由于该假设与现实分类问题并不相符,因此影响了朴素贝叶斯网络的分类性能。目前,对朴素贝叶斯网络分类算法的改进研究主要围绕结构扩展^[10-11]、属性加权^[12-13]、属性选择^[14-15]、实例加权^[16]以及实例选择^[17]等 5 个方面进行展开,结构扩展方法通过增加有限的有向边来扩展朴素贝叶斯网络的拓扑结构,表达属性变量之间的依赖关系,削弱朴素贝叶斯网络的属性条件独立假设,提升分类性能^[18]。

一依赖估测器(One-Dependence Estimator, ODE)是朴素贝叶斯网络结构扩展方法中的经典模型。文献[18]提出平均一依赖估测器(Average One-Dependence Estimator, AODE)算法。在该算法中,类变量作为每个属性节点的父亲节点,同时把一个属性变量作为其余所有属性的父亲节点。TANB(Tree Augmented Naive Bayes)算法^[19]以 ODE 模型为基础,在属性变量之间增加了树结构模型,通过计算属性之间的条件相互信息来确定树结构模型。HNB 算法^[20]可以避免学习贝叶斯网络拓扑结构,为每个属性节点建模,产生隐性的父亲节点,其是一种特殊的 ODE 模型结构。

以上算法均可提升 ODE 模型的分类性能,但查阅最新资料发现,现有的 ODE 模型分类算法在进行分类判别时,认为不同的属性作为根节点对应的分类器在分类过程中起到的贡献是相同的,然而并未考虑不同的属性作为根节点时对分类过程的贡献不同。因此,本文以 ODE 模型为基础,采用属性值加权的方法对 ODE 模型进行改进,利用相互信息(Mutual Information, MI)计算属性值对应的权值,并在标准数据集上对本文提出的 MI-ODE 算法的分类性能进行评估。

1 算法的建模与设计

朴素贝叶斯网络分类算法作为机器学习领域的经典算法之一,虽然网络拓扑结构简单,但分类效果与其他经典的机器学习分类器模型相当,而且分类性能更稳定、高效,因此得到了研究人员的广泛关注。本文用 $A_1, A_2, \dots, A_m$ 表示 m 个属性变量,待测实例 x 表示为 $x = \langle a_1, a_2, \dots, a_m \rangle$, 其中, a_i 为第 i 个属性 A_i 对应的取值。假设属性变量个数为 4, 朴素贝叶斯网络的模型结构如图 1 所示。从图 1 可以看出,朴素贝叶斯网络中属性之间是相互独立的,没有依赖关系。




图 1 朴素贝叶斯网络模型结构

Fig. 1 Structure of naive Bayesian network model

利用 ODE 模型对朴素贝叶斯网络的结构模型进行扩展,并对所有的属性都确定一个非类属性的父亲节点,以此来表达属性变量间的依赖关系,提升算法的分类精度。现有的 ODE 模型分类算法在进行分类判别时,仅对每个 ODE 模型进行算术平均,并未考虑不同的属性作为根节点时,不同的 ODE 模型对分类过程的贡献不同。本文将 ODE 模型与属性值加权方法相结合,以 ODE 模型为研究基础,开展属性值加权方法研究。在对模型计算权值的过程中,采用 MI 的度量方式计算属性值父亲节点与类变量节点之间的依赖关系,并作为 ODE 模型的权值。同时,对 ODE 分类器模型进行属性值加权平均,并提出 MI-ODE 算法。本文算法的研究设计分为 2 个部分:ODE 建模和属性值加权方法研究。

1.1 一依赖估测器模型建模

ODE 模型在建模过程中,对每一个属性节点构建了一个特殊的树扩展贝叶斯网络拓扑结构,每个拓扑结构就是一个 ODE 分类器,ODE 分类器的个数取决于属性变量的个数。在每个 ODE 模型中,类变量是所有属性变量的父亲节点。同时,遍历每个属性节点作为父亲节点构建多个树拓扑结构,在每个树结构中每个属性有且仅有一个属性父亲节点。假设属性变量个数为 4, AODE 模型结构如图 2 所示。其中, A_1, A_2, A_3, A_4 表示 4 个属性变量, C 表示类变量,其是每个属性节点的父亲节点。




图2 AODE模型结构

Fig. 2 Structure of AODE model

在每个ODE模型中,均有一个属性变量是其余所有属性的父亲节点。当属性 A_i 作为属性父亲节点时,对应的ODE模型分类器用式(1)进行分类:

$$c(x) = \operatorname{argmax}_{c \in C} P(a_i, c) \prod_{k=1 \wedge k \neq i}^m P(a_k | a_i, c) \quad (1)$$

其中, a_i 为第 i 个属性 A_i 对应的取值, a_k 表示父亲节点取值为 a_i 时对应的属性子节点的取值。类标记 c 对应类变量取值集合 C 中的某一个取值。概率 $P(a_i, c)$ 和 $P(a_k | a_i, c)$ 的计算方法分别如式(2)、式(3)所示:

$$P(a_i, c) = \frac{F(a_i, c) + 1.0 / (n_i \times q)}{n + 1.0} \quad (2)$$

$$P(a_k | a_i, c) = \frac{F(a_k, a_i, c) + 1.0 / n_k}{F(a_i, c) + 1.0} \quad (3)$$

其中, n 为训练实例的个数, a_i 为第 i 个属性 A_i 对应的取值, a_k 表示父亲属性节点取值为 a_i 时对应的属性子节点的取值, n_i 为第 i 个属性的取值个数。 $F(a_i, c)$ 表示属性值 a_i 和类标记 c 同时出现的频率次数, $F(a_k, a_i, c)$ 表示属性值 a_i 、属性值 a_k 和类标记

c 同时出现的频率次数。当有 m 个属性变量时,按照图2的建模方式建立 m 个ODE模型分类器,即对朴素贝叶斯模型进行 m 种不同的拓扑结构扩展,并根据每个ODE模型分类器计算出待测实例的类标记。

1.2 属性值加权方法研究

MI-ODE算法对ODE模型采取属性值加权方法进行研究,改变了现有算法对每个ODE模型进行算术平均的现状。综合考虑不同属性作为根节点时不同ODE模型对分类过程的不同贡献。本文算法利用相互信息作为信息度量方式,计算属性值父亲节点和类变量之间的依赖关系,对ODE进行属性值加权。对依赖关系大的ODE模型分配大权值,同时给依赖关系小的ODE模型分配小权值。属性值加权的ODE模型结构如图3所示。其中, A_1, A_2, A_3, A_4 表示4个属性变量,类变量 C 为每个属性节点的父亲节点, W_{i, a_i} 表示第 i 个属性作为父亲节点,且属性变量的取值为 a_i 时对应ODE模型的权值。




图3 属性值加权的ODE模型结构

Fig. 3 Structure of ODE model with attribute value weighting

MI-ODE 算法根据属性变量对 ODE 模型进行建模,当有 m 个属性变量时,建立 m 个不同的 ODE 模型拓扑结构。但与传统研究方法不同的是,本文 MI-ODE 算法对每个 ODE 模型计算了根节点属性值的权值,通过计算属性父亲节点的属性值与类变量之间的关联性来获取 ODE 模型权重,再对 m 个不同的 ODE 模型进行属性值加权平均。

在计算分类精度时,对每个 ODE 模型引入属性值加权平均,待测实例用式(4)进行分类:

$$c(x) = \underset{c \in C}{\operatorname{argmax}} \frac{\sum_{i=1}^m W_{i,a_i} P(a_i, c) \prod_{k=1 \wedge k \neq i}^m P(a_k | a_i, c)}{\sum_{i=1}^m W_{i,a_i}} \quad (4)$$

合理计算 ODE 模型权重 W_{i,a_i} 以及合理度量属性父亲节点的属性值与类变量之间的关联性是本文算法的难点问题。MI-ODE 算法在计算权重的过程中,采用相互信息作为度量方式来计算某一属性值作为根节点时对应的 ODE 模型权重。相互信息在信息论中常用来度量 2 个变量之间的依赖程度,表示 2 个变量之间的共同信息量^[21-22]。属性变量 A_i 和类变量 C 之间的相互信息则定义为:

$$MI(A_i; C) = \sum_{a_i, c} P(a_i, c) \lg \frac{P(a_i, c)}{P(a_i)P(c)} \quad (5)$$

其中,相互信息 $MI(A_i; C)$ 度量了属性变量 A_i 对类变量 C 的依赖程度,可以反映属性变量 A_i 在分类过程中的重要性,且其值越大,在分类过程中对应的作用越大。

在本文算法中,需要计算当属性父亲节点 A_i 取值为 a_i 时,与其对应的 ODE 模型的权值 W_{i,a_i} 。 W_{i,a_i} 表示属性值 a_i 和类变量 C 之间的依赖关系。根据相互信息度量可得:

$$W_{i,a_i} = MI(a_i; C) = \sum_c P(a_i, c) \lg \frac{P(a_i, c)}{P(a_i)P(c)} \quad (6)$$

当有 m 个属性变量时,即可根据式(6)计算出 m 个不同的 ODE 模型对应的权值,再根据式(4)对每个 ODE 模型进行属性值加权平均来求取待测实例的类标记。

本文提出的 MI-ODE 算法具体步骤为:

输入 训练数据集 D , 测试实例 x

输出 测试实例 x 的类标记

步骤 1 当有 m 个属性变量时,建立 m 个不同的 ODE 模型拓扑结构。

1) 对每个属性父亲节点的属性值 a_i 和每个类标记 c ,根据式(2)计算 $P(a_i, c)$ 。

2) 对每个属性父亲节点 A_i 对应的属性子节点对应的每个属性值 $a_k (k \neq i)$,根据式(3)计算 $P(a_k | a_i, c)$ 。

3) 对 m 个不同的 ODE 模型拓扑结构,根据属性父亲节点的属性值 a_i ,根据式(6)计算对应的 ODE 模型的权值。

步骤 2 根据式(4)计算测试实例 x 的类标记。

步骤 3 返回测试实例 x 对应的类标记。

2 实验设计与分析

2.1 实验数据与实验平台

本文研究将借助国际数据挖掘 WEKA 实验平台以及 Eclipse 软件进行。实验数据集来源于加州大学欧文分校经过精心挑选用于现实分类问题的 36 个 UCI 标准数据集。数据集来源于现实生活中的分类问题,且包含的实例数众多。不同的数据集包含的实例数和类标记的数量各不相同,因此该数据集在国际数据挖掘领域具有较强的代表性。

由于相关数据挖掘算法只能对名词性属性进行处理,因此首先需要对 36 个 UCI 标准数据集进行预处理。本文对数据集的预处理包括采用 WEKA 实验平台的无导师过滤器 Replace Missing Values 替换缺失值,有导师过滤器 Discretize 对数值型数据进行离散,以及无监督过滤器 Remove 对无用属性进行删除等操作。

2.2 实验设计与结果分析

以预处理后的 36 个 UCI 标准数据集为研究对象,借助 WEKA 实验平台以及 Eclipse 软件完成实验。实验比较了 MI-ODE 算法、NB 算法、AODE 算法以及 TAN 算法的分类性能。为了更准确地评估本文提出的 MI-ODE 算法的分类性能,对所有算法均设置了相同的数据集、相同的实验平台以及相同的评估方法,且实验均采用 10 次十折交叉验证法,并采用置信度为 95% 的 t-test 统计测试方法^[23]对算法的分类精度以及 AUC^[24] 指标进行分析比较。4 种算法的分类精度结果如表 1 所示,AUC 指标结果如表 2 所示。其中,表 1 和表 2 中的 $w/t/l$ 值是指

MI-ODE 算法相对于其他算法,在置信度为 95% 的 t-test 统计测试方法下得到的比较结果。 w 表示 MI-ODE 算法的分类精度高于其他算法的实例集总数量, t 表示 MI-ODE 算法的分类精度与其他算法相等的实例集总数量, l 表示 MI-ODE 算法的分类精度低于其他算法的实例集总数量。

表 1 4 种算法的分类精度对比
Table 1 Comparison of classification accuracy of four algorithms

数据集	分类精度/%			
	MI-ODE 算法	NB 算法	AODE 算法	TAN 算法
anneal	98.90	96.13	98.01	98.61
anneal. ORIG	93.73	92.66	93.35	94.55
audiology	75.95	71.40	71.66	65.35
autos	86.34	72.30	80.74	80.85
balance-scale	69.39	71.08	69.34	70.75
breast-cancer	70.82	72.94	72.53	69.53
breast-w	96.58	97.25	96.97	96.27
colic	81.49	81.39	82.64	81.00
colic. ORIG	75.79	73.62	74.62	68.31
credit-a	86.33	86.25	86.71	85.39
credit-g	75.95	75.43	76.50	73.54
diabetes	77.66	77.85	78.07	78.70
glass	77.71	74.39	76.08	76.23
heart-c	83.26	83.60	83.20	81.62
heart-h	85.72	84.46	84.43	84.05
heart-statlog	82.44	83.74	83.33	82.44
hepatitis	85.90	84.22	84.98	86.01
hypothyroid	99.37	98.48	98.76	99.15
ionosphere	93.77	90.77	92.79	92.25
iris	93.33	94.47	93.20	94.20
kr-vs-kp	94.30	87.79	91.01	92.88
labor	94.37	93.13	94.70	92.47
letter	91.63	74.00	88.76	85.49
lymphography	88.21	84.97	86.98	85.30
mushroom	99.99	95.52	99.95	99.99
primary-tumor	47.76	47.20	47.67	44.77
segment	96.92	91.71	95.77	95.58
sick	97.66	97.10	97.39	97.40
sonar	86.75	85.16	86.60	84.45
soybean	94.28	92.20	93.28	94.98
splice	96.30	95.42	96.12	94.95
vehicle	72.77	62.52	72.31	73.39
vote	94.41	90.21	94.52	94.43
vowel	84.49	65.23	80.87	86.09
waveform-5000	86.60	80.72	86.03	82.22
zoo	96.93	93.98	94.66	95.15
平均分类精度	86.49	83.31	85.68	84.95
$w/t/l$	—	15/20/1	9/27/0	9/27/0

表 2 4 种算法的 AUC 对比
Table 2 AUC comparison of four algorithms

数据集	AUC/%			
	MI-ODE 算法	NB 算法	AODE 算法	TAN 算法
anneal	99.66	99.20	99.45	99.84
anneal. ORIG	98.61	97.78	97.98	98.66
audiology	97.66	96.93	96.98	95.92
autos	96.39	92.34	95.66	94.85
balance-scale	87.10	87.74	87.04	87.58
breast-cancer	67.72	70.18	70.81	65.36
breast-w	99.22	99.25	99.25	99.07
colic	87.08	84.97	86.77	86.55
colic. ORIG	83.37	82.32	83.50	75.66
credit-a	93.01	92.21	93.05	91.81
credit-g	79.52	78.99	79.78	76.29
diabetes	84.43	84.64	84.74	84.86
glass	91.46	91.10	91.45	91.00
heart-c	91.96	91.27	91.75	90.00
heart-h	92.00	91.44	91.62	91.65
heart-statlog	91.61	91.47	91.64	91.11
hepatitis	90.07	91.25	91.04	89.45
hypothyroid	99.82	99.66	99.77	99.83
ionosphere	97.78	97.24	98.30	98.17
iris	98.79	98.95	98.95	98.89
kr-vs-kp	98.65	95.19	97.42	98.26
labor	99.13	99.17	99.42	98.50
letter	99.82	97.89	99.69	99.42
lymphography	93.54	92.89	92.85	92.21
mushroom	100.00	99.80	100.0	100.0
primary-tumor	83.57	82.79	82.89	80.97
segment	99.84	99.15	99.75	99.72
sick	96.64	96.01	96.18	96.15
sonar	94.71	93.34	93.92	93.44
soybean	99.69	99.48	99.57	99.79
splice	99.51	99.35	99.45	99.18
vehicle	92.34	86.23	92.16	92.40
vote	98.80	97.15	98.67	98.75
vowel	98.90	95.41	98.48	99.09
waveform-5000	97.22	95.94	97.22	95.55
zoo	99.98	99.94	99.94	99.89
平均 AUC	93.88	93.02	93.81	93.05
$w/t/l$	—	16/20/0	9/26/1	11/25/0

从表 1 可以看出,MI-ODE 算法的平均分类精度最高,为 86.49%。相较于 NB 算法,MI-ODE 算法在 15 个数据集上的分类精度有明显提升;相较于 AODE 算法、TAN 算法,MI-ODE 算法均在 9 个数据集上的分类精度有明显提升;相较于 NB 算法,MI-ODE 算法在数据集 letter 上的分类精度提升了 17.63%,提升效果非常显著,这说明相较于其他算法,本文提出的 MI-ODE 算法的分类精度性能最优。

从表 2 可以看出,MI-ODE 算法的平均 AUC 指标最高,为 93.88%。相较于 NB 算法,MI-ODE 算

法在 16 个数据集上的 AUC 指标有明显提升;相较于 AODE 算法,MI-ODE 算法在 9 个数据集上的 AUC 指标有明显提升;相较于 TAN 算法,MI-ODE 算法在 11 个数据集上的 AUC 指标有明显提升;相较于 NB 算法,MI-ODE 算法在数据集 vehicle 上的 AUC 指标提升了 6.11%,提升效果非常显著,这说明相较于其他算法,本文提出的 MI-ODE 算法的 AUC 指标性能最优。

综上所述,相比于 NB 算法、AODE 算法以及 TAN 算法,本文提出的 MI-ODE 算法的分类精度和 AUC 均有所改进,且分类性能最优。

3 结束语

为解决现有 ODE 模型未考虑到不同属性作为根节点时对分类过程贡献不同的问题,本文提出基于相互信息的属性值加权 MI-ODE 算法。实验结果表明,MI-ODE 算法提升了朴素贝叶斯网络分类算法以及 ODE 模型经典算法的分类性能。后续将继续以树扩展的朴素贝叶斯模型为基础,对贝叶斯网络分类算法进行改进。

参考文献

- [1] MAROZZO F, TALIA D, TRUNFIO P. A workflow management system for scalable data mining on clouds[J]. IEEE Transactions on Services Computing, 2018, 11(3): 480-492.
- [2] WU Jia, PAN Shirui, ZHU Xingquan, et al. Self-adaptive attribute weighting for Naive Bayes classification[J]. Expert Systems with Applications, 2015, 42(3): 1487-1502.
- [3] BERMEO P, GÁMEZ J A, PUERTA J M. Speeding up incremental wrapper feature subset selection with Naive Bayes classifier[J]. Knowledge-Based Systems, 2014, 55: 140-147.
- [4] SPIEGLER R. Bayesian networks and boundedly rational expectations[J]. The Quarterly Journal of Economics, 2016, 131(3): 1243-1290.
- [5] TANG B, KAY S, HE H B. Toward optimal feature selection in naive Bayes for text categorization[J]. IEEE Transactions on Knowledge and Data Engineering, 2016, 28(9): 2508-2521.
- [6] FU Zhe, ZHANG Hao, CHEN Qiang, et al. Application of naive Bayes classifier in stampede risk early-warning of large-scale activities[C]//Proceedings of 2016 International Conference on Industrial Informatics-Computing Technology, Intelligent Technology, Industrial Information Integration. Washington D. C., USA: IEEE Press, 2016: 174-180.
- [7] XIANG Z L, YU X R, KANG D K. Experimental analysis of naïve Bayes classifier based on an attribute weighting framework with smooth kernel density estimations[J]. Applied Intelligence, 2016, 44(3): 611-620.
- [8] KHAN F H, QAMAR U, BASHIR S. SWIMS: semi-supervised subjective feature weighting and intelligent model selection for sentiment analysis[J]. Knowledge-Based Systems, 2016, 100: 97-111.
- [9] JIANG Liangxiao, ZHANG Lungan, YU Liangjun, et al. Class-specific attribute weighted naive Bayes[J]. Pattern Recognition, 2019, 88: 321-330.
- [10] JIANG Liangxiao, ZHANG Lungan, LI Chaoqun, et al. A correlation-based feature weighting filter for naive Bayes[J]. IEEE Transactions on Knowledge and Data Engineering, 2019, 31(2): 201-213.
- [11] ZHENG Xiaolin, LIN Zhen, XU Huan, et al. Efficient learning ensemble super parent-one-dependence estimator by maximizing conditional log likelihood[J]. Expert Systems with Applications, 2015, 42(21): 7732-7745.
- [12] XIANG Z L, KANG D K. Attribute weighting for averaged one-dependence estimators[J]. Applied Intelligence, 2017, 46(3): 616-629.
- [13] LEE C H. A gradient approach for value weighted classification learning in naive Bayes[J]. Knowledge-Based Systems, 2015, 85: 71-79.
- [14] LIU Ximeng, LU Rongxing, MA Jianfeng, et al. Privacy-preserving patient-centric clinical decision support system on naïve Bayesian classification[J]. IEEE Journal of Biomedical and Health Informatics, 2016, 20(2): 655-668.
- [15] LIN Jiaping, NIU Jianwei, LI Hui. PCD: a privacy-preserving predictive clinical decision scheme with E-health big data based on RNN[C]//Proceedings of 2017 IEEE Conference on Computer Communications Workshops. Washington D. C., USA: IEEE Press, 2017: 808-813.
- [16] ZHANG Yongshan, WU Jia, ZHOU Chuan, et al. Instance cloned extreme learning machine[J]. Pattern Recognition, 2017, 68: 52-65.
- [17] BAI Yu, WANG Haishuai, WU Jia, et al. Evolutionary lazy learning for Naive Bayes classification[C]//Proceedings of 2016 International Joint Conference on Neural Networks. Washington D. C., USA: IEEE Press, 2016: 3124-3129.
- [18] WEBB G I, BOUGHTON J R, WANG Z H. Not so naive Bayes: aggregating one-dependence estimators[J]. Machine Learning, 2005, 58(1): 5-24.
- [19] ZHAO Zhongquan, LIU Dan. Web proxy server cache optimization based on tree augmented naive Bayes classifier[J]. Computer Engineering, 2017, 43(1): 115-119. (in Chinese)
赵中全, 刘丹. 基于树扩展朴素贝叶斯分类器的 Web 代理服务器缓存优化[J]. 计算机工程, 2017, 43(1): 115-119.
- [20] JIANG L X, ZHANG H, CAI Z H. A novel Bayes model: hidden naive Bayes[J]. IEEE Transactions on Knowledge and Data Engineering, 2009, 21(10): 1361-1371.
- [21] CHEN J L, XIAO T Q, SHENG J, et al. Gender prediction on a real life blog data set using LSI and KNN[C]//Proceedings of the 7th Annual Computing and Communication Workshop and Conference. Washington D. C., USA: IEEE Press, 2017: 1-12.
- [22] LI Chaoqun, JIANG Liangxiao, LI Hongwei, et al. Toward value difference metric with attribute weighting[J]. Knowledge and Information Systems, 2017, 50(3): 795-825.
- [23] WU Jia, PAN Shirui, ZHU Xingquan, et al. SODE: self-adaptive one-dependence estimators for classification[J]. Pattern Recognition, 2016, 51: 358-377.
- [24] NADEAU C, BENGIO Y. Inference for the generalization error[J]. Machine Learning, 2003, 52(3): 239-281.