

一种基于云模型的贝叶斯网络 EM 参数学习算法

曹如胜¹ 倪世宏¹ 张 鹏¹ 奚显阳²

(空军工程大学航空航天工程学院 西安 710038)¹ (中国人民解放军 95881 部队 北京 100095)²

摘 要 针对贝叶斯网络连续节点离散化后,概念知识表达存在模糊性和随机性的问题,提出一种将云模型与 EM (Expectations Maximization) 算法相结合的贝叶斯网络参数学习算法。首先运用启发式高斯云变换算法 (Heuristic Gaussian Cloud Transformation) 和云发生器将连续节点定量样本转换成定性概念,并记录下样本对所属概念的确定度,运用确定度概率转换公式将确定度转换成相应概率;随后复制扩充样本并按概率选择所属概念;样本更新后结合 EM 算法进行参数优化,实现贝叶斯网络的参数学习。仿真实验结果表明,通过云模型表征概念得到的参数学习结果更加符合实际情况,参数学习精度和网络推理准确性得到了提高。

关键词 云模型,贝叶斯网络,参数学习,离散化

中图分类号 TP181 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.8.039

EM Parameter Learning Algorithm of Bayesian Network Based on Cloud Model

CAO Ru-sheng¹ NI Shi-hong¹ ZHANG Peng¹ XI Xian-yang²

(College of Aeronautics and Astronautics Engineering, Air Force Engineering University, Xi'an 710038, China)¹

(Chinese People's Liberation Army 95880 Troops, Beijing 100095, China)²

Abstract The conception of node which has been discrete is fuzzy and random in Bayesian network. To solve this problem, a learning algorithm based on cloud model and EM was proposed. Firstly, the measurable specimen is transformed into qualitative conception through strategy of heuristic gaussian cloud transformation and cloud generator. The conception of certainty is recorded and changed to probability with formula. Then, specimen is expended and the conception is confirmed based on the probability. Finally, parameter is optimized on the basis of EM algorithm. The simulation experimental results show that the effect of parameter learning is more correspond to actual fact after cloud discretization. Precision of parameter learning and accuracy of reasoning are improved.

Keywords Cloud model, Bayesian network, Parameter learning, Discretization

1 引言

在处理不确定性复杂问题时,贝叶斯网络 (Bayesian Network, BN) 采用系统变量间的关联描述替代联合概率分布,减少了系统描述的信息量;同时利用变量间的条件独立性,有效地降低了学习和推理中的计算复杂性。因此,BN 在模式识别、数据挖掘、计算智能等领域得到了广泛的应用^[1]。对于已知结构的 BN,其条件概率表 (Conditional Probability Table, CPT) 的构建可以基于专家知识,也可以基于数据进行参数学习。基于专家知识的构建方法存在人为主观因素,不同的专家得到的结果往往不同,使得网络推理准确性降低。基于数据参数学习的 CPT 构建方法能够较好地拟合实际情况,但当贝叶斯网络中连续节点作为离散节点的父节点时,存在条件概率难以确定、网络参数学习困难的问题,参数学习通常将连续节点统一离散化为离散节点^[2],学者们对离散后贝叶斯网

络的参数学习进行了大量的研究。

目前研究较多的参数学习算法有极大似然估计算法 (Maximum Likelihood Estimation, MLE)^[3]、梯度上升算法^[4]、EM 算法^[5]。MLE 算法将参数看作是确定的量,通过最大化所观察的样本概率得到最优的参数,能有效逼近网络真实参数,但当观测数据有缺失时,得到的参数难以达到满意的效果。梯度上升算法利用梯度来快速计算函数极大值,适应性强,但需要在所有合理的参数范围空间中搜索,存在局部极值,因此需要结合优化技巧来求得理想结果。EM 算法能对网络参数近似估计,通过计算完整似然的期望,求使得完整似然的期望最大的参数,再不断迭代地进行参数估计,可保证算法收敛,但迭代速度较慢。

上述算法均是基于传统的离散化方法而提出的参数学习算法,没有考虑节点离散后概念存在的模糊性和随机性,对概念的划分是一种非此即彼的硬性划分,容易导致概念交接处

到稿日期:2016-01-02 返修日期:2016-05-04

曹如胜(1993—),男,硕士生,主要研究方向为数据处理与挖掘,E-mail: crsloveys@163.com;倪世宏(1963—),男,教授,博士生导师,主要研究方向为飞行状态监控与地面数据处理;张 鹏(1982—),男,博士,讲师,主要研究方向为飞机故障诊断、故障预测与健康管理。

的数据所属概念划分错误,从而降低参数学习精度。云模型^[6]是一种优秀的不确定性知识表达模型,可以通过经典的概率论和模糊数学给出解释,反映了随机性和模糊性之间的关联。本文将云模型引入贝叶斯网络,将连续节点软划分成离散的概念,结合 EM 算法,提出基于云模型的 EM 参数学习算法(Expectations Maximization Based on Cloud, EMC),对网络参数进行优化,以实现贝叶斯网络的参数学习。以鸢尾花种类识别仿真实验为例,验证了本文算法的有效性。

2 EMC 算法参数学习步骤

针对贝叶斯网络中的连续节点,离散化时采用 HGCT 算法^[7]将定量样本划分成多个定性的概念,用云模型来表征概念,这样既可保证概念核心区域的非此即彼性,又可体现概念之间不确定性区域的亦此亦彼性,实现了概念的软划分。通过云发生器^[6]将连续节点定量样本转换为定性的概念,由于概念的不确定性区域存在交叠,部分样本会出现同时属于两种概念的情况。针对该问题,将样本复制扩充后,依据数据归属两个概念的概率,在复制的样本中选择相应数目的概念,从而可以在保留样本不确定性的同时获得便于参数估计的样本。更新样本后结合 EM 算法进行参数优化,实现网络的参数学习。

2.1 定量-定性转换

采用 HGCT 算法,将连续节点样本集合

$$X_1 = \{x_i | i=1, 2, \dots, N\} \quad (1)$$

转换成 M 个定性的认知概念,获得 M 个概念对应的云模型:

$$\{C_k(Ex_k, En_k, He_k) | k=1, \dots, M\} \quad (2)$$

M 的取值依据为保证各概念云含混度最小^[7]。相比于传统专家知识的划分结果,基于云模型的概念划分方法更加符合实际,概念划分智能化程度更高。

2.2 样本所属概念判别

采用云发生器,将连续节点的样本带入得到的概念云中,记录对应各个概念云的确定度 μ ,得到样本集:

$$X_2 = \{(x_i, (C_k, \mu_k)) | i=1, 2, \dots, N; k=1, \dots, M\} \quad (3)$$

当 $\mu > 10^{-4}$ 时保留其对应的概念;当 $\mu < 10^{-4}$ 时将对应概念舍去,获得由定性概念组成的样本集:

$$X_3 = \{(x_i, C_k) | i=1, 2, \dots, N; k=1, \dots, M\} \quad (4)$$

其中有部分样本同时属于两种概念,即

$$X_3' = \{(x_i, (C_k, C_{i(k+1)})) | i=1, 2, \dots, N; k=1, \dots, M\} \quad (5)$$

2.3 确定度概率转换

将样本集 X_2 中的确定度信息转换成概率信息,只属于一个概念的样本的概率为 1,样本集为

$$X_4 = \{(x_i, P_{C_k} = 1) | i=1, 2, \dots, N; k=1, \dots, M\} \quad (6)$$

对于同时属于两种概念的样本,通过确定度概率转换公式^[8]

$$P(x) = \frac{\mu(x)}{\mu(C_k) + \mu(C_{i(k+1)})} \quad (7)$$

可得到其分别属于两个概念的概率 P_{C_k} 和 $P_{C_{i(k+1)}}$,其中 x 取 C_k 或 $C_{i(k+1)}$, $\mu(x)$ 为概念 x 对应的确定度,可取 $\mu(C_k)$ 或 $\mu(C_{i(k+1)})$,得到的样本集为:

$$X_4' = \{(x_i, (P_{C_k}, P_{C_{i(k+1)}})) | i=1, 2, \dots, N; k=1, \dots, M\} \quad (8)$$

2.4 扩充样本并选择概念

按上述步骤将网络中连续节点样本离散化,将各节点样本都转化为定性概念,针对连续节点部分样本同时属于两种概念的情况,对整体样本进行复制扩充,在复制的样本中依据样本所属两个概念的概率来选择该点样本对应的概念。

将整体样本复制扩充 N 份, N 值的选择要求使得 $N \cdot P_{C_k}$ 和 $N \cdot P_{C_{i(k+1)}}$ 为整数,在前 $N \cdot P_{C_k}$ 份样本中连续节点选择概念 C_k ,在后 $N \cdot P_{C_{i(k+1)}}$ 份样本中选择概念 $C_{i(k+1)}$,可得连续节点样本集为:

$$X_5 = \underbrace{\{(x_i, C_k), \dots, (x_i, C_k)\}}_{N \cdot P_{C_k}}, \underbrace{\{(x_i, C_{i(k+1)}), \dots, (x_i, C_{i(k+1)})\}}_{N \cdot P_{C_{i(k+1)}}} \quad (9)$$

$i=1, 2, \dots, N; k=1, \dots, M$

2.5 参数优化

对于上述步骤处理得到的样本,采用 EM 算法对节点参数进行优化,获得贝叶斯网络的条件概率分布。EM 算法包括两个步骤:期望步骤(Expectation Step, E-Step)和最大化步骤(Maximization Step, M-Step)^[9]。EM 算法使用样本的似然函数 $L_c(\theta, x)$,其对数似然函数为 $\log L_c(\theta, x)$,当 x 缺失了部分数据观测不到时,可以用条件期望来代替^[10]。算法描述如下。

1)假定 θ 的初始值为 $\theta^{(0)}$,参数空间为 Θ ;

2)E 步:计算对数似然函数的期望

$$Q(\theta, \theta^{(k)}) = E_{\theta^{(k)}} \{\log L_c(\theta, x)\} \quad (10)$$

3)M 步:找 $\theta^{(k+1)} \in \Theta$,使得

$$Q(\theta^{(k+1)}, \theta^{(k)}) \geq Q(\theta, \theta^{(k)}), \text{对 } \forall \theta \in \Theta \text{ 成立。}$$

对 E 步和 M 步不断迭代产生参数值序列 $\{\theta^{(k)}\}$,其似然函数是单调的,所以当 $|L(\theta^{(k+1)}) - L(\theta^{(k)})| < \varepsilon (\forall \varepsilon > 0)$ 时,停止迭代,此时 $\{\theta^{(k+1)}\}$ 就是要寻找的 θ 的估计。

E 步的作用是求期望,即在给定观测数据的条件下,计算完整似然的期望,其中涉及的计算缺失数据的条件期望需要利用参数的当前估计值;M 步是求极大值,即求使得完整似然期望最大的参数。

基于 EMC 算法的参数学习流程如图 1 所示。




图 1 EMC 算法参数学习流程图

3 仿真实例

3.1 构建贝叶斯网络模型

选择贝叶斯网络标准测试集中的鸢尾花识别数据作为实

验样本^[11]。以花萼长度(Calyx_length)、花萼宽度(Calyx_width)、花瓣长度(Petal_length)和花瓣宽度(Petal_width)为父节点,以所属种类(Category)为子节点,构建贝叶斯网络如图2所示。其中4个父节点均为连续节点,子节点为离散节点。




图2 鸢尾花识别贝叶斯网络

3.2 参数学习

选择100组数据作为网络训练样本,50组数据作为测试样本^[12],采用HGCT算法将各连续节点软划分成相应的概念,其中花萼长度和花瓣宽度分为3个状态,用long,middle和short表示。花萼宽度和花瓣长度分为两个状态,用long和short表示。图3—图6分别为4个父节点软划分后得到的概念云图。离散节点鸢尾花种类为3个概念,分别为Iris-setosa,Iris-versicolor和Iris-virginica。




图3 花萼长度概念云图

图4 花萼宽度概念云图




图5 花瓣长度概念云图

图6 花瓣宽度概念云图

表1 概念表达方式的对比

节点	概念	等区间法	云模型
Calyx_length	long	(4.3—5.5)	C ₁ (4.907,0.147,0.0187)
	middle	(5.5—6.7)	C ₂ (5.855,0.318,0.0379)
	short	(6.7—7.9)	C ₃ (6.627,0.106,0.0245)
Calyx_width	long	(2—3.2)	C ₁ (2.921,0.046,0.0044)
	short	(3.2—4.4)	C ₂ (3.221,0.069,0.0066)
Petal_length	long	(1—3.95)	C ₁ (1.465,0.186,0.0436)
	short	(3.95—6.9)	C ₂ (4.905,0.885,0.1073)
Petal_width	long	(0.1—0.9)	C ₁ (0.239,0.101,0.0140)
	middle	(0.9—1.7)	C ₂ (1.360,0.183,0.0214)
	short	(1.7—2.5)	C ₃ (2.075,0.185,0.0217)

与传统的参数学习中概念表达方式相比,云模型的表达方法能够体现概念的模糊性和随机性,体现出位于概念边缘的不确定性区域的亦此亦彼性,与基于传统等区间法划分的概念相比,其对概念的表达更加合理。表1给出了传统等区间法^[13]划分的概念表达方式和基于云模型的表达方式。

通过云发生器将训练样本的定量数据转换成相应的定性概念,其中部分样本如表2所列。从表2可以看出,样本中某些节点存在同时属于两种概念的情况,其中中括号内是属于两种概念所占的概率。

表2 带有概率的部分定性样本

序号	Calyx_length	Calyx_width	Petal_length	Petal_width	Category
1	middle	short	long	long	Iris-setosa
2	long[86%] middle[14%]	short	long	long	Iris-setosa
3	middle	short	short	middle[82%] short[18%]	Iris-versicolor
4	long	long	short	middle	Iris-versicolor
5	middle	long[95%] short[5%]	short	middle[17%] short[83%]	Iris-virginica
6	short	long	short	short	Iris-virginica

将样本复制扩充,对带有概率的节点概念样本,按照各个概念所占概率,在复制的样本中选择该节点的相应概念。以表2的序号2和序号3样本为例,将样本整体复制100份,对于Calyx_leng节点,前86份样本中序号2的概念选择long,后14份选择middle;对于Petal_width节点,前82份样本序号3的概念选择middle,后18份选择short,结果如表3所列。

表3 去概率后的部分定性样本

份数	序号	Calyx_length	Calyx_width	Petal_length	Petal_width	Category
1	2	long	short	long	long	Iris-setosa
	3	middle	short	short	middle	Iris-setosa
	:	:	:	:	:	:
82	2	long	short	long	long	Iris-setosa
	3	middle	short	short	middle	Iris-setosa
	:	:	:	:	:	:
83	2	long	short	long	long	Iris-setosa
	3	middle	short	short	short	Iris-setosa
	:	:	:	:	:	:
87	2	middle	short	long	long	Iris-setosa
	3	middle	short	short	short	Iris-setosa
	:	:	:	:	:	:
100	2	middle	short	long	long	Iris-setosa
	3	middle	short	short	short	Iris-setosa

更新样本后结合EM算法进行参数优化,可得到所建网络的CPT,4个父节点的CPT如表4所列,子节点的CPT如表5所列,表5中未给出的某些父节点组合状态均是3个识别种类等概率的情况。

表4 父节点条件概率表

	Calyx_length			Calyx_width		Petal_length			Petal_width		
概念	long	middle	short	long	short	long	short	long	middle	short	
概率(%)	26.3	46.7	27	56.4	43.6	33.3	66.7	33.3	35.8	30.9	

表 5 子节点条件概率表

序号	节点				Category		
	Calyx_length	Calyx_width	Petal_length	Petal_width	Iris-setosa(%)	Iris-versicolor(%)	Iris-virginica(%)
1	long	long	long	long	100	0	0
2	long	long	short	middle	0	80.6	19.4
3	long	long	short	short	0	0	100
4	long	short	long	long	100	0	0
5	middle	long	short	middle	0	89.5	10.5
6	middle	long	short	short	0	0	100
7	middle	short	long	long	100	0	0
8	middle	short	short	middle	0	100	0
9	middle	short	short	short	0	31	69
10	short	long	short	middle	0	82.5	17.5
11	short	long	short	short	0	4	96
12	short	short	short	middle	0	100	0
13	short	short	short	short	0	0	100

在加拿大 Norsys 公司开发的 Netica 软件中建立模型,将参数学习得到的 CPT 代入,可得如图 7 所示模型。




图 7 鸢尾花识别贝叶斯网络模型

与传统 EM 算法相比,所提 EMC 算法在节点概念知识表达上更加符合实际,虽然复杂的节点概念的表达导致学习时间有所增加,但在迭代过程中并没有导致迭代步骤明显增多,图 8 给出了 EMC 算法与 EM 算法在迭代过程中似然函数 $L(\theta^{(k)})$ 的变化趋势,从图中可以看出,所提 EMC 算法在迭

代过程中似然函数 $L(\theta^{(k)})$ 的收敛速度与 EM 算法的相当。




图 8 迭代过程中似然函数变化趋势

3.3 实验结果及分析

利用测试样本对上述建立的模型进行测试,首先将测试样本的定量数据转换成定性的概念,对于节点同时属于两种概念的测试样本,将其属于两种概念的概率以先验概率的形式代入模型,部分测试结果如表 6 所列。

表 6 部分测试样本的识别结果

序号	观测节点				真实所属种类	不同算法识别结果(%)		
	Calyx_length	Calyx_width	Petal_length	Petal_width		梯度上升算法	EM 算法	EMC 算法
1	5.1	3.8	1.6	0.2	Iris-setosa	97.2	100	100
2	5.5	2.5	4	1.3	Iris-versicolor	32.8	33.0	89.5
3	7.7	3	6.1	2.3	Iris-virginica	89.2	90	96.3
4	5.3	3.7	1.5	0.2	Iris-setosa	97.2	100	100
5	6.1	3	4.6	1.4	Iris-versicolor	87.9	88.9	90.6
6	6.3	2.5	5	1.9	Iris-virginica	97.5	99	100

由表 6 可以看出,基于不同参数学习算法所得的网络都能够有效识别鸢尾花的种类,以单个测试样本对真实种类的识别概率作为识别精度,基于梯度上升算法与 EM 算法参数学习所得测试结果识别精度相当,EM 算法识别精度稍高,本文 EMC 算法对部分测试样本来说,识别精度与另两种算法相当,对另一部分测试样本则有明显提高。为验证本文 EMC 算法的学习性能,以 50 个测试样本的平均识别精度作为参数学习精度的评价指标^[11],与基于梯度上升算法和 EM 算法的参数学习精度进行对比,结果如表 7 所列。从表 7 中可以看出,所提 EMC 参数学习算法的学习精度要高于梯度上升算法和 EM 算法。

表 7 参数学习精度对比

	梯度上升算法	EM 算法	EMC 算法
参数学习精度(%)	88	89	92

以表 6 中序号为 2 的测试样本为例,本文方法识别结果正确,而基于梯度上升算法和 EM 算法的识别结果错误。观

察序号 2 原始测试样本发现,其 Calyx_length 节点和 Petal_length 节点的观测数据正处于两个概念之间的分界点,此时对于数据的归属概念存在不确定性,此类数据容易导致概念错分,从而影响网络推理准确性,而基于云模型的概念表达方法则不存在这种含有分界点的区域。以测试样本中识别结果正确的样本所占比例作为网络推理准确率,为验证所提 EMC 参数学习算法对网络测试准确率的影响,对 50 个测试样本的识别结果的准确率进行统计,与梯度上升算法和 EM 算法参数学习所得网络的测试准确率对比,把数据处于两个概念分界点观测样本定义为概念模糊区域,结果如表 8 所列。

表 8 测试结果准确率对比

	整体样本 测试准确率(%)	概念明确 区域准确率(%)	概念模糊 区域准确率(%)
梯度上升算法	92	94.8	81.82
EM 算法	92	94.8	81.82
EMC 算法	98	97	100

从表 8 可以看出,本文提出的 EMC 参数学习算法得到

的测试结果的准确率要高于梯度上升算法和 EM 算法的准确率;特别是对于处于概念模糊区域的样本,EMC 算法的识别准确率有显著提高,可以看出提出的 EMC 参数学习算法能有效处理概念划分过程中概念知识的模糊性和随机性,在参数学习过程中能够考虑到知识的不确定性,对概念模糊区域的参数学习精度也有显著提升,从而提高了网络推理的准确性。

结束语 在贝叶斯网络的参数学习过程中需将连续节点离散化,传统的参数学习算法未考虑节点定性概念存在的模糊性和随机性,对概念的划分是一种非此即彼的硬划分,在概念交接处,容易导致样本归属概念选择错误。对此,本文提出了 EMC 参数学习算法,在连续节点概念划分时充分考虑了知识表达存在的模糊性和随机性。仿真实验结果表明,所提的 EMC 参数学习算法能够有效地提高参数学习的精度,特别在概念模糊区域识别精度有明显提高,从而有效提高了网络推理的准确性。由于 EMC 算法增加了节点概念的表达的复杂性,使得参数学习所耗时间增加,如何进一步优化学习及缩短学习时间,是下一步需要继续研究的问题。

参考文献

- [1] 肖秦琨,高嵩. 贝叶斯网络在智能信息处理中的应用[M]. 北京:国防工业出版社,2012
- [2] Meng Guang-lei, Gong Guang-hong. Threat assessment of aerial targets based on hybrid Bayesian network[J]. Systems Engineering and Electronics, 2013, 32(11): 2398-2401 (in Chinese)
孟光磊,龚光红. 基于混合贝叶斯网的空域目标威胁评估方法[J]. 系统工程与电子技术, 2013, 32(11): 2398-2401
- [3] Fei Zhi-gen, Xu Xiao-jie, Dong Xi-yan. The MLE Algorithm on the Bayes Network for Machine Fault Diagnosis[J]. Henan Science, 2007, 25(1): 98-100 (in Chinese)
费致根,徐小洁,董喜燕. 用于机械故障诊断 Bayes 网络的 MLE 学习方法[J]. 河南科学, 2007, 25(1): 98-100
- [4] Yan Dai-wei, Gu Liang-xian, Pan Lei. A Study of New Method for Weapon System Effectiveness Evaluation Based on Bayesian Network[J]. Journal of China Ordnance, 2008, 3(3): 209-213
- [5] Li Hong, Emmanuel A, Li Ping, et al. Imputation algorithm of

missing values based on EM and Bayesian network[J]. Computer Engineering and Applications, 2010, 46(5): 123-125 (in Chinese)

李宏,阿玛尼,李平,等. 基于 EM 和贝叶斯网络的丢失数据填充算法[J]. 计算机工程与应用, 2010, 46(5): 123-125

- [6] 李德毅,杜鹑. 不确定性人工智能[M]. 北京:国防工业出版社, 2005
- [7] Liu Yu-chao. Study on calculating method based on cloud model [D]. Beijing: Tsinghua University, 2012 (in Chinese)
刘玉超. 基于云模型的粒计算方法研究[D]. 北京:清华大学, 2012
- [8] Zhang Yin-yan, Li Bi-cheng, Cui Jia-wei. Method of Target Threat Assessment Based on Cloudy Bayesian Network[J]. Computer Science, 2013, 40(10): 127-131 (in Chinese)
张银燕,李弼程,崔家玮. 基于云贝叶斯网络的目标威胁评估方法[J]. 计算机科学, 2013, 40(10): 127-131
- [9] 茆诗松,程依明,濮晓龙. 概率论与数理统计[M]. 北京:高等教育出版社, 2011
- [10] 苏良军. 高等数理统计[M]. 北京:北京大学出版社, 2007
- [11] Gao Jian-guo, Cui Ye-qin. A New Discretization Method for Continuous Attributes Based on Information Entropy[J]. Microelectronics & Computer, 2011, 28(7): 187-194 (in Chinese)
高建国,崔业勤. 基于信息熵理论的连续属性离散化方法[J]. 微电子学与计算机, 2011, 28(7): 187-194
- [12] Zheng Zhong-zhi, Duan Peng, He Xuan-jun, et al. Improvement of Bayesian classification based on the cloud model theory[J]. Journal of Yunnan University of Nationalities (Natural Sciences Edition), 2013, 22(3): 226-229 (in Chinese)
郑钟志,段鹏,贺宣军,等. 基于云模型理论改进的贝叶斯分类算法[J]. 云南民族大学学报(自然科学版), 2013, 22(3): 226-229
- [13] Zhou Xuan, Wang Lei, Zhu Yan-guang, et al. A Discretization Method of Continuous Variable in Bayesian Network Parameter Learning[J]. Computer Simulation, 2012, 26(10): 136-139 (in Chinese)
周旋,王磊,朱延广,等. 贝叶斯网络参数学习中连续变量离散化方法研究[J]. 计算机仿真, 2012, 26(10): 136-139

(上接第 170 页)

- [11] Sun J G, Ai L R. Collaborative filtering recommendation algorithm based on item attribute and cloud model filling[J]. Journal of Computer Application, 2012, 32(3): 658-660, 668 (in Chinese)
孙金刚,艾丽蓉. 基于项目属性和云填充的协同过滤推荐算法[J]. 计算机应用, 2012, 32(3): 658-660, 668
- [12] Zhang G W, Kang J C, Li H S, et al. Context based on Collaborative filtering recommendation algorithm[J]. Journal of System Simulation, 2006, 18(Suppl. 2): 595-601 (in Chinese)
张光卫,康建初,李鹤松,等. 面向场景的协同过滤推荐算法[J]. 系统仿真学报, 2006, 18(Suppl. 2): 595-601
- [13] Zhang G W, Li D Y, Li P, et al. A collaborative filtering recommendation algorithm based on cloud model[J]. Journal of Software, 2007, 18(10): 2403-2411 (in Chinese)
张光卫,李德毅,李鹏,等. 基于云模型的协同过滤推荐算法[J]. 软件学报, 2007, 18(10): 2403-2411
- [14] Li S. Collaborative filtering recommendation algorithm based on cloud clustering of multi-indicators item evaluation[C] // 2011 International Conference on Business Computing and Global Information. Shanghai, China: IEEE CPS, 2011: 654-648

- [15] Li X H. Personalized recommendation algorithm research based on Jaccard item category similarity [D]. Changsha: Central South University, 2010: 31-32 (in Chinese)

李小慧. 基于 Jaccard 项目类别相似性的个性化推荐算法研究[D]. 长沙:中南大学, 2010: 31-32

- [16] Li D Y, Liu C Y. Study on the universality of the normal cloud model[J]. Chinese Engineering Science, 2004, 6(8): 28-34 (in Chinese)
李德毅,刘常昱. 论正太云模型的普适性[J]. 中国工程科学, 2004, 6(8): 28-34
- [17] Zhang Y, Zhao D N, Li D Y. The similar cloud and measurement method[J]. Information and Control, 2004, 33(2): 129-132 (in Chinese)
张勇,赵东宁,李德毅. 相似云及其度量分析方法[J]. 信息与控制, 2004, 33(2): 129-132
- [18] Li H L, Guo C H, Qiu W R. Similarity measurement between normal cloud models[J]. Acta Electronica Sinica, 2011, 39(11): 2561-2567 (in Chinese)
李海林,郭崇慧,邱望仁. 正态云模型相似度计算方法[J]. 电子学报, 2011, 39(11): 2561-2567