

基于模糊粗糙神经网络的用户个性化关联推荐方法^{*}

陈翔¹, 唐俊勇²

(1. 西安工业大学 建筑工程学院; 2. 西安工业大学 计算机科学与工程学院, 西安 710021)

摘要:【目的】针对电子商务中关联推荐的有效性,基于模糊粗糙神经网络提出了一种新的方法。【方法】该方法首先提出了个性化推荐模型,并根据关联规则给出了推荐算法流程。同时利用模糊粗糙神经网络对上述模型进行求解,通过计算模糊关联系数和模糊关联度来获得用户行为特征。【结果】利用仿真实验深入研究影响该方法的关键因素,结果发现:最小可信阈值和最小支持度取值越小,预测精度就越高。【结论】与其他算法相比,该算法能在一定的程度上较小预测的误差,使得推荐结果更加满足客户的需求。

关键词:个性化;关联推荐;行为特征;模糊粗糙神经网络;预测精度

中图分类号:TP39

文献标志码:A

文章编号:1672-6693(2018)03-0137-06

近些年来,随着电子商务的迅速发展,网上购物日渐成为一种主流的购物方式,而准确高效、具有用户个性化的网络推荐应用也变得愈加重要起来。面对海量的物品信息,现有的通用搜索引擎、门户网站等仅能够帮助用户实现信息过滤从而满足用户的一般需求,对于不同背景、不同目的和不同时期的用户个性化信息需求则难以满足。因此,个性化关联推荐系统日益成为解决信息过载问题的有效途径。

个性化推荐系统主要利用客户的历史消费信息、历史销售信息等找出若干商品之间的关联度,并提炼出规则以便为客户进行产品推荐^[1-5],提升用户平均访问步长和商品页的点击量,从而提升电子商务站点的整体营销性能。推荐系统按照所使用的数据来分类,可以分为协同过滤、内容过滤和社会化推荐共3类系统^[6-8]。而个性化推荐系统则是通过算法识别出具有相同爱好的用户,并对用户评分进行个性化加权处理,进而实现对用户的推荐。对此,国内外学者提出大量算法和模型。文献[9]研究了如何利用用户间的社会关系来进一步提高传统推荐方法的性能,并给出了一种能够将社会关系信息进行整合的概率矩阵分解框架。文献[10]通过对用户间信任关系的传播现象进行建模,提出了一种基于信任传播的推荐方法,并能够降低推荐系统中的马太效应。针对关联规则算法存在的问题,文献[11]提出加入时效度和兴趣度、基于分层和用户偏好度的TOP-K算法的设计。文献[12]通过研究用户推荐Tweets,提出了一种基于社会上下文信息的推荐算法,并使用推荐对象间的内容相似性对目标函数进行约束,但是该方法并没有考虑推荐对象间显示的关联关系。文献[13]通过拓宽经典关联规则的应用范围进行了交叉挖掘、考虑时态关系的挖掘。文献[14]重点研究了如何不断提高经典关联规则算法效率将关联算法应用于分布式环境。文献[15]利用上下文感知的推荐方法,通过数据采集、用户偏好提取,生成上下文感知推荐,并进行评价与自适应改进。但是,目前的有关推荐方法仍然存在效率不高、个性化低等问题。在上述工作的基础上,笔者首先给出了个性化推荐模型,并基于关联规则给出了系统推荐算法流程,同时还利用模糊粗糙神经网络^[16-19]来对个性化推荐模型进行求解,最后通过仿真实验来验证本算法的有效性。

1 个性化推荐系统模型

目前个性化推荐系统主要有基于关联规则的推荐和基于内容的推荐,笔者主要基于关联规则的推荐系统来进行研究。这类系统能动态的根据用户兴趣变化来进行推荐,能有效去除那些强关联规则但顾客并不感兴趣的推荐。推荐系统采用挖掘技术,通过网页的日志和数据库中用户的交易数据来获取客户的行为,并根据用户的

^{*} 收稿日期:2017-05-19 修回日期:2018-04-11 网络出版时间:2018-05-22 10:01

资助项目:陕西省科技厅工业科技攻关项目(No. 2016GY-088)

第一作者简介:陈翔,男,讲师,研究方向为计算机软件与理论,E-mail:chengxiang1977@hainan.net

网络出版地址: <http://kns.cnki.net/kcms/detail/50.1165.N.20180522.1001.006.html>

访问情况,实时的向用户推荐用户可能感兴趣的商品的超链接。笔者将采用关联规则客户的数据进行挖掘,它能够集中反映各数据项之间关联,有关关联规则定义如下:

定义 1 设某购物网页中有 n 个商品集 $X = \{x_1, x_2, \dots, x_n\}$, 则 $x_k (k=1, 2, \dots, n)$ 代表网页中的某一类商品。

定义 2 设 $D = \{T_1, T_2, \dots, T_m\}$ 为数据库事务集合即用户购买交易集, 即在该网页中某用户一次交易包含了 m 笔交易, T_k 为商品集 X 的一个子集。

定义 3 对于商品集 I' , 假设 $C(I' \in T_k)$ 为交易集 D 中包含 I' 的商品数量, 则商品集 I' 的支持度为:

$$S(I') = \frac{C(I' \in T_k)}{m} \quad (1)$$

定义 4 最小支持度是指商品集 $X = \{x_1, x_2, \dots, x_n\}$ 的最小支持阈值, 支持阈值表示用户对关联规则影响的认可程度, 令最小支持阈值为 $S_{\min}$, 支持度大于或等于最小阈值的商品集称为频繁集; 可信度定义为两类商品 Q_1 和 Q_2 的交易数量与包含商品 Q_1 的交易数之比:

$$C(Q_1 \Rightarrow Q_2) = \frac{S(Q_1 \Rightarrow Q_2)}{S(Q_1)} \quad (2)$$

其中, $(Q_1 \Rightarrow Q_2)$ 表示商品 Q_1 在某一用户订单出现导致 Q_2 也以某一概率出现在该用户的订单中, 可信度能反映订单中在包含商品 Q_1 的前提下包含商品 Q_2 的概率。关联规则是形如 $P \rightarrow B$ 这样的蕴含式, 满足 P 和 B 均为 X 的子集, 且 P 和 B 无交集, 则对数据集进行关联规则算法挖掘之后可得到一个关联规则集 R :

$$R = \{P_1 \rightarrow B_1, P_2 \rightarrow B_2, \dots, P_k \rightarrow B_k, \dots, P_m \rightarrow B_m\} \quad (3)$$

关联规则一般由支持度和可信度两个指标来衡量, 假设最小可信阈值为 $C_{\min}$, 当支持度与可信度均不小于 $S_{\min}$ 和 $C_{\min}$ (强关联) 时, 输出商品集即为用户最感兴趣的物品集。

基于关联规则, 下面给出系统推荐算法流程:

1) 初始化数据。随机初始化一个商品集 $X = \{x_1, x_2, \dots, x_n\}$, 初始化最小支持阈值 $S_{\min}$ 和最小可信阈值 $C_{\min}$ 。

2) 生成推荐规则集。遍历数据库和用户日志, 获取目标用户的行为集 P_1 和规则集 R , 对数据库中的规则集与目标用户行为进行匹配, 直到将数据库中的规则集遍历完全, 输出推荐规则集 R_u 并跳转到下一步。

3) 计算推荐规则集评分值。推荐规则集 R_u 中的规则能与目标客户相匹配, 具有一定的推荐能力。若用户的购买记录或点击记录满足某条规则, 则认为该用户支持这条规则, 用户对商品项评分的均值可作为规则项的评分值。令 U_k 为客户对推荐前件 $P_k = \{p_1, p_2, \dots, p_n\}$ 中每个商品项的评分组成的向量, 计算公式如下:

$$U_k = \frac{1}{|m|} \left(\sum_{i=1}^{|m|} c_i x_k \right) \quad (4)$$

其中: $C = \{c_1, c_2, \dots, c_m\}$ 表示行为满足规则 r_i 的客户集; $c_i x_k$ 表示客户 c_i 对推荐集商品 x_k 的评分值。

4) 将评分值大于阈值 ω 的商品项加入候选推荐集 R'_u , 检查规则表是否遍历完全。若遍历完全则将候选推荐集 R'_u 按置信度大小排序, 保留前 n 项对用户进行推荐。

关联规则的优点是推荐准确程度高, 不用建立复杂的用户度量模型, 可行性高。但该规则仍存在一些不足, 如: 关联规则的抽取费时, 若数据库庞大则需要大量时间; 产品性质相同但名字不同时, 使用此规则无法区分。因此, 笔者提出了基于模糊粗糙神经网络的关联推荐方法, 该方法能够对历史数据进行聚类, 得到与当前时刻数据相似度较高的数据, 并将之作为训练样本, 这样能明显的提高预测精度。

2 基于模糊粗糙神经网络的关联推荐方法

粗糙集理论能有效地分析各种不完备的用户行为信息, 从这些不完备的信息中发现用户隐含的爱好等信息, 能揭示用户的行为对推荐准确性的影响程度, 删除冗余的推荐集, 具体计算流程如下:

1) 采集数据和数据预处理。从数据库中获取到商品数据、客户数据及用户交易数据, 生成初始决策表。

2) 离散化连续属性值。假设用户属性的取值空间为 $X = \{x_1, x_2, \dots, x_n\}$, 离散化后的类标号是 $Y = \{y_1, y_2, \dots, y_n\}$ 。对于电子商务物品关联推荐的连续属性的检测数据, 先对数据进行离散处理, 用户信息数据的条件属性为 {用户 ID, 用户订单量, 用户浏览次数, ...}, 决策属性为 {规则项评分, 用户满意度}, 设给定的决策表为 $S = \langle U, A, V, f \rangle$, 其中 $U = \{u_1, u_2, \dots, u_n\}$ 为论域, A 为条件属性集 $M = \{m_1, m_2, \dots, m_l\}$ 和决策属性集 $T = \{t_1, t_2,$

$\dots, t_k\}$ 的并集, V_t 为属性 t 的值域, $f: U * A \rightarrow V$ 为信息函数, 它制定 U 中的对象 u_i 的属性值。假设用户信息集中元素 x_i 在关系 T 下对用户行为集合 X 的粗糙隶属函数计算如下:

$$\varphi_A^T(x_i) = \frac{|\lfloor x_i \rfloor_T \cap A|}{|\lfloor x_i \rfloor_T|} \quad (5)$$

其中: $\lfloor x_i \rfloor_T$ 表示 x_i 包含在 T 的等价类, 表示用户信息集中元素的个数。比较各个 X_i 对于 Y_i 的粗糙集隶属函数值, 取阈值为 0.1, 当粗糙集隶属函数值小于阈值时, 表明该变量对推荐结果的影响很小, 可以删去不计, 最终取得简化后的用户行为数据。

3) 计算各决策属性 m_i 关于条件属性 t_i 的依赖度, 计算公式如下:

$$\rho_{t_i}(m_i) = \frac{\text{pos}_{t_i}(m_i)}{|U|}, \quad (6)$$

$$\text{pos}_{t_i}(m_i) = \bigcup_{T \in \frac{U}{m_i}} \{T - t_i\}. \quad (7)$$

4) 计算模糊关联系数和模糊关联度:

$$\psi(p_i, p_j) = \frac{\sum_{k=0}^m (x_k(i) \wedge x_k(j))}{\sum_{k=0}^m (x_k(i) \vee x_k(j))}, \quad (8)$$

$$\psi(p_i, \bar{p}_i) = \frac{1}{n-1} \sum_{j=1, j \neq i}^n (\psi(p_i, p_j)), i=1, 2, \dots, n. \quad (9)$$

其中: $x_i(k)$ 表示用户的第 k 点特征指标值; $\psi(p_i, \bar{p}_i)$ 表示用户特征值 p_i 对用户其余特征值的干扰程度, 它的值越大说明该特征值越能代表用户的喜好程度。

5) 对所有的模糊关联度进行规范化处理得到各行为特征的相对权重值:

$$\omega_i = \frac{\psi(p_i, \bar{p}_i)}{\sum_{i=1}^n \psi(p_i, \bar{p}_i)}. \quad (10)$$

其中, x_i 和聚类中心 x_0 的差异值可通过距离确定, 具体计算公式如下:

$$d_{0i} = \sqrt[p]{\sum_{k=1}^n |\omega_{ki} (1 - \xi_{0i}(k))|^p}. \quad (11)$$

模糊神经网络的模糊规则由知识简约而得到, 一个模糊神经网络包含了输入层、隶属度函数层、 T -范数层、归一化层和输出层共 5 个大模块。首先将离散化的 m 个用户行为数据 $\{x_1, x_2, \dots, x_m\}$ 作为输入层的输入变量, 每一个变量代表 1 个节点; 将输入层输入的用户变量输出到隶属度函数层, 并根据(5)式对每一个节点求隶属值。将隶属度函数层中简化后的数据作为 T -范数层的输入, 在该网络层中, 每一个节点代表 1 条模糊规则, 通过该层之后得到被第 j 个规则 R_j 约束后的输出:

$$\Phi_j = \exp\left(-\frac{\|X - C_j\|}{\sigma_j^2}\right), j=1, 2, \dots, u. \quad (12)$$

其中: $X = (x_1, x_2, \dots, x_t) \in R^t$; $C_j = (c_{1j}, c_{2j}, \dots, c_{tj}) \in R^t$ 表示第 j 个用户行为特征离散点, u 表示模糊规则数。

6) 为了提高神经网络的收敛速度个学习速度, 对数据进行归一化处理, 在归一化层中节点个数与模糊规则额数相等, 将 T -范数层的输出作为该层的输入, 得到的输出结果为 $\{\rho_1, \rho_2, \dots, \rho_n\}$, 具体计算公式如下:

$$\rho_j = \frac{\Phi_j}{\sum_{k=1}^u \Phi_k}, j=1, 2, \dots, u. \quad (13)$$

输出最终用户行为数据:

$$Y_i(X_i) = \sum_{i=1}^n \epsilon_k \rho_j. \quad (14)$$

其中 ϵ_k 表示第 k 个规则对于整个规则集的隶属度。

同时, 笔者给出了基于模糊粗糙神经网络的关联推荐算法流程图, 如图 1 所示; 此外图 2 给出了该算法的核心伪代码。




图 1 算法流程图

Fig. 1 Algorithm flowchart

```

%初始化各参数值,并导入用户属性的取值空间 X={x1,x2,...,xn},论域 U={u1,u2,...,un},条件属性集 M={m1,m2,...,mi},决策属性集 T={t1,t2,...,tn}离散化得到类标号 Y={y1,y2,...,yn}%
for k=1:1:200
    t(k)=k*ts;
    u(k)=0.5*sin(6*pi*k*ts);
    y(k)=u_1^3+y_1/(1+y_1^2);
    f1=x; %输入层处理%
    for i=1:2 %模糊化层处理%
        for j=1:5
            net2(i,j)=-(f1(i)-c(i,j))^2/b(j)^2;
        end
    end
    for i=1:2
        for j=1:5
            f2(i,j)=exp(net2(i,j));
        end
    end
    for j=1:5 %模糊推理层处理%
        m1(j)=f2(1,j);
        m2(j)=f2(2,j);
    end
end
  
```

```

for i=1:5
    for j=1:5
        ff3(i,j)=m2(i)*m1(j)
    end
end
f3=[ff3(1,:),ff3(2,:),ff3(3,:),ff3(4,:),ff3(5,:)];
f4=t_1*f3 %输出层处理%
ym(k)=f4;
e(k)=y(k)-ym(k);
d_t=0*t_1;
for j=1:25
    d_t(j)=xite*e(k)*f3(j);
end
t=t_1+d_1+alfa*(t_1-t_2)
delta2=-e(k)*t'*f3';
d_b=0*b_1;
for j=1:5
    d_b(j)=xite*delta2*2*(x(1)-c(1,j)^2)*(b(j)^-3);
end
for i=1:2
    for j=1:5
        d_c(i,j)=-xite*delta2*2*(x(i)-c(i,j))*b(j)^-2;
    end
end
%输出结果%
end
  
```

图 2 核心伪代码

Fig. 2 Core pseudo code

3 仿真实验与分析

笔者选取淘宝网站作为分析对象。淘宝系统记录了用户评论记录、交易记录、产品信息等,选取历史数据中的 1 个月用户购买手机数据用于建模,部分数据如表 1 所示。同时设置迭代次数为 200,最小可信阈值 $C_{\min}=S_{\min}=0.2$,在粗糙集-模糊神经网络训练过程中,衰减常数为 0.96,最大误差为 0.5,最小误差为 0.01,用均方误差 E 、平均绝对误差 D 和平均绝对百分比误差 λ 作为预测性能指标:

$$E = \frac{1}{N} \sum_{i=1}^N (x_i - x_i')^2. \quad (15)$$

$$D = \frac{1}{N} \sum_{i=1}^N |x_i - x_i'|. \quad (16)$$

$$\lambda = \frac{1}{N} \sum_{i=1}^N \frac{|x_i - x_i'|}{x_i}. \quad (17)$$

为克服个别不良数据及噪声的影响,设置依赖度增量的阈值为 0.005,只有依赖度增量大于此阈值时,才认为该属性存在于约简中。笔者使用 Matlab 进行数据分析,对比了本研究所提算法与 BP 算法、FNN 算法性能,预测误差结果如图 3 所示。从图中可以看出,3 种算法的误差随时间的变化在一定的范围内波动,但 BP 算法和 FNN 算法的预测误差普遍比本研究所提的算法的误差高,由此可以看出本研究所提的算法是合理的,能在一定的程度上较小预测的误差,使得推荐结果更加满足客户的需求。

图 4 描述了迭代次数对本研究算法预测精度的影响。迭代可以使得推荐集更加优化,因此笔者研究了迭代次数对预测精度的影响。从图 4 中可以看出:迭代次数和预测精度呈正相关;但是迭代次数到达 150 左右时,预测

表 1 部分采集数据

Tab. 1 Partially collected data

手机型号	评论记录/条	评分值	交易记录/条
三星 Galaxy C5	424	0.92	97
iPhone 6s	1 340	0.96	101
三星 Galaxy On5	3 353	0.91	189
华为 P9	231	0.93	11
小米 5S	3 973	0.95	61
华为 Mate9	10 084	0.96	1 119
荣耀 6x	6 858	0.94	477
OnePlus	3 059	0.93	205
魅蓝 note5	3 605	0.89	49
红米 4A	31 900	0.92	879

精度趋于平稳。

图5显示了迭代次数对规则评分项的影响。评分项越高,表明该规则越贴近客户的喜好程度。因此,笔者也对迭代次数与规则评分项的关系进行研究。从图5中可以看出,随着迭代次数的增加,规则的评分值也在增加。这是因为随着迭代次数的增加,不相关的干扰项逐渐被淘汰,留下的属性更贴近用户的真实喜好,因而更符合客户的想法。

最小可信阈值和最小支持度是强关联的必要条件,最小可信阈值和最小支持度对预测结果的影响如图6所示。

由图6可知,最小可信阈值和最小支持度对预测精度有一定影响;最小可信阈值和最小支持度取值越小,预测精度就越高。这是因为当最小可信阈值和最小支持度取值越小时,关联强度就越强;关联强度的大小与用户的喜好程度有直接联系。因此,在对用户进行推荐时,应尽可能选取关联强度大的商品;否则会使用户厌倦,给用户造成困扰。

4 结论

为解决电子商务中关联推荐的有效性问题的,本研究基于模糊粗糙神经网络提出了一种新的刻画方法。该方法首先提出了个性化推荐模型,并根据关联规则给出了推荐算法流程。同时利用模糊粗糙神经网络对上述模型进行求解,通过计算模糊关联系数和模糊关联度来获得用户行为特征。最后利用仿真实验深入研究影响该方法的关键因素,与BP算法和FNN算法相比,该方法在预测精度上有较大提高。在后续研究过程中,可以考虑结合大数据等方法来融合用户行为特征,使用户个性化推荐模型更加适合电子商务。

参考文献:

- [1] WANG L, WU B, YANG J, et al. Personalized recommendation for new questions in community question answering [C]//2016 IEEE International Conference on Advances in Social Networks Analysis and Mining. [S. l.]:IEEE, 2016: 901-908.
- [2] ALHAMID M F, RAWASHDEH M, DONG H, et al. Exploring latent preferences for context-aware personalized recommendation systems [J]. IEEE Transactions on Human-Machine Systems, 2016, 46(4): 615-623.
- [3] SONG N, HOU J, LIU P, et al. An intelligent and personalized tobacco brand recommendation method [C]//2015 International Conference on Intelligent Transportation, Big Data and Smart City. [S. l.]:IEEE, 2015: 98-101.
- [4] PALACIO-BAUS K, SAQUICELA V. Semantic recommender systems for digital tv: from demographic stereotyping to personalized recommendations [C]//2015 Asia-Pacific Conference on Computer Aided System Engineering. [S. l.]:IEEE, 2015: 392-396.
- [5] ADOMAVICIUS G, TUZHILIN A. Toward the next generation of recommender systems: a survey of the state-of-




图3 不同算法的预测误差比较

Fig. 3 Comparison of prediction errors of different algorithms




图5 迭代次数对规则评分项的影响

Fig. 5 The effect of iterations on rule score items




图4 迭代次数对本文算法预测精度的影响

Fig. 4 The influence of iterative times on the accuracy of the algorithm




图6 $C_{\min}$ 和 $S_{\min}$ 对预测精度的影响

Fig. 6 The effect of $C_{\min}$ and $S_{\min}$ on prediction accuracy

- the-art and possible extensions[J]. IEEE Transactions on Knowledge and Data Engineering, 2005, 17(6): 734-749.
- [6] THIENGBURANATHUM P, SHUANG C, YU H N. Overview of personalized travel recommendation systems [C]//2016 22nd International Conference on Automation and Computing. [S. l.]: IEEE, 2016: 415-422.
- [7] JAMALI M, ESTER M. A matrix factorization technique with trust propagation for recommendation in social networks[C]//Proceedings of the 4th ACM Conference on Recommender Systems. Barcelona, Spain: [s. n.], 2010: 135-142.
- [8] ROUANE-HACENE M, HUCHARD M, NAPOLI A, et al. Relational concept analysis: mining concept lattices from multi-relational data[J]. Annals of Mathematics and Artificial Intelligence, 2013, 67(1): 81-108.
- [9] MA H, ZHOU D, LIU C, et al. Recommender systems with social regularization[C]//Proceedings of the 4th ACM International Conference on Web Search and Data Mining. Hongkong, China: [s. n.], 2011: 287-296.
- [10] YANG M M, ZHOU Y, ZHOU Q, et al. Observation of matthew effects in Sina Weibo microblogger[J]. IEEE Internet Computing, 2013, 10(1): 41-43.
- [11] 毛宇星, 陈彤兵, 施伯乐. 一种高效的多层和概化关联规则挖掘方法[J]. 软件学报, 2011, 22(12): 2965-2980.
- MAO Y X, CHEN T B, SHI B L. Efficient method for mining multiple-level and generalized association rules [J]. Journal of Software, 2011, 22(12): 2965-2980.
- [12] JIANG M, CUI P, LIU R, et al. Social contextual recommendation[C]//Proceedings of the 21st ACM International Conference on Information and Knowledge Management. Maui, USA: [s. n.], 2012: 45-51.
- [13] ZHANG Li L, HU C F, CHEN Q. Domain knowledge based personalized recommendation model and its application in cross-selling[J]. Procedia Computer Science, 2012, 9(10): 1314-1323.
- [14] 王大玲, 于戈, 鲍玉斌. 一种具有最大推荐非空率的关联规则挖掘方法[J]. 软件学报, 2014, 15(8): 1182-1188.
- WANG D L, YU G, BAO Y B. An approach of association rules mining with maximal nonblank for recommendation [J]. Journal of Software, 2004, 15(8): 1182-1188.
- [15] 王立才, 孟祥武, 张玉洁. 上下文感知推荐系统[J]. 软件学报, 2012, 23(1): 1-20.
- WANGL C, MENG X W, ZHANG Y J. Context-aware recommender systems[J]. Journal of Software, 2012, 23(1): 1-20.
- [16] 叶玉玲. 模糊粗糙神经网络的结构与参数优化[J]. 系统工程与电子技术, 2009, 31(12): 2988-2993.
- YE Y L. Structure and parameters optimization of fuzzy rough neural network[J]. Systems Engineering and Electronics, 2009, 31(12): 2988-2993.
- [17] 张蕾, 章毅. 大数据分析的无限深度神经网络方法[J]. 计算机研究与发展, 2016, 53(1): 68-79.
- ZHANG L, ZHANG Y. Big data analysis by infinite deep neural networks[J]. Journal of Computer Research and Development, 2016, 53(1): 68-79.
- [18] 随婷婷, 王晓峰. 一种基于 CLMF 的深度卷积神经网络模型[J]. 自动化学报, 2016, 42(6): 875-882.
- SUI T T, WANG X F. Convolutional neural networks with candidate location and multi-feature fusion[J]. Acta Automatica Sinica, 2016, 42(6): 875-882.
- [19] 李耀龙, 张永科, 罗镇宝. 应用深度卷积神经网络的机场及机场内飞机目标识别技术[J]. 重庆理工大学学报(自然科学), 2018, 32(3): 210-216.
- LI Y L, ZHANG Y K, LUO Z B. Target recognition technology of airport and airport aircraft based on deep convolution neural network[J]. Journal of Chongqing University of Technology (Natural Science), 2018, 32(3): 210-216.

The User Association Recommendation Method Based on Fuzzy Rough Neural Network

CHEN Xiang¹, TANG Junyong²

(1. School of Civil Engineering, Xi'an Technological University;

2. School of Computer Science and Engineering, Xi'an Technological University, Xi'an 710021, China)

Abstract: [Purposes] In order to improve the effectiveness of the association recommendation in e-commerce, a new method is proposed with fuzzy rough neural network. [Methods] At first, the personalization recommendation model is presented in this model, and the recommendation algorithm process is given by the association rule. Then, it is solved with fuzzy rough neural network, and user behavioral characteristics are calculated with fuzzy correlation coefficient and correlation degree. [Findings] Finally, a simulation is conducted to study the key influence factor of this method. The result was found that the smaller the minimum trustworthiness threshold and the minimum support value, the higher the prediction accuracy. [Conclusions] Compared with other algorithms, this algorithm can reduce the prediction error to a certain extent, and make the recommendation result more satisfying to the customer's needs.

Keywords: personalization; association recommendation; behavioral characteristics; fuzzy rough neural network; prediction accuracy

(责任编辑 方 兴)