

基于服装图像视觉特征的冷启动问题缓解

贺 宇,史有群,陶 然,罗 辛

(东华大学计算机科学与技术学院,上海 201600)

[摘要] 冷启动问题是协同过滤推荐算法中被广泛关注的问题,它的存在严重影响协同过滤算法的推荐质量. 提出深度卷积神经网络提取的服装商品图像视觉特征用于计算用户对新商品喜好度的方法来缓解冷启动问题,并利用矩阵分解模型估算用户对服装商品的评分. 通过从服装商品图像视觉特征到商品特征向量的映射函数计算新商品的特征向量,给出了两种映射函数形式: K 最近邻映射和线性映射. 实验结果表明,服装图像视觉特征能够有效缓解协同过滤算法冷启动问题.

[关键词] 协同过滤,矩阵分解,冷启动,图像视觉特征

[中图分类号] TP391 **[文献标志码]** A **[文章编号]** 1672-1292(2019)03-0015-06

Mitigation of Cold-Start Problem Based on Visual Features of Clothing Images

He Yu, Shi Youqun, Tao Ran, Luo Xin

(School of Computer Science and Technology, Donghua University, Shanghai 201600, China)

Abstract: The cold-start problem is a classic problem which has widely been concerned in the collaborative filtering recommendation algorithm. The problem seriously affects the recommendation quality of the collaborative filtering algorithm. This paper proposes a way to alleviate the cold-start problem by using the visual feature of the clothing product image learned by the deep convolutional neural network. The paper uses the matrix factorization model to estimate the users' score on clothing items. In this paper, the items feature vector is calculated by a mapping function from the clothing product image visual feature to the items feature vector. The paper mentions two forms of mapping functions: K nearest neighbor mapping and linear mapping. The experimental results show that the visual feature of clothing image can effectively alleviate the cold-start problem of collaborative filtering algorithm.

Key words: collaborative filtering, matrix factorization, cold-start, visual feature

协同过滤作为推荐算法的经典算法,在服装推荐领域有着广泛的应用. 主流的协同过滤推荐算法有两种:基于记忆的协同过滤推荐算法和基于模型的协同过滤推荐算法^[1]. 基于记忆的协同过滤算法通过训练用户对商品的反馈信息,为目标用户生成与其有着相同品味的用户集. 通过分析集中用户的交易数据,为目标用户生成商品推荐集. 基于模型的协同过滤推荐算法采用矩阵分解、统计、机器学习、数据挖掘等技术,学习目标用户喜好,构建目标用户模型^[2],并用于生成目标用户的商品推荐集.

协同过滤推荐算法所利用的用户商品信息包括显式反馈信息和隐式反馈信息. 显式反馈信息包括用户对商品的打分、评价等,直观地表现了用户对商品的喜好程度. 隐式反馈信息包括用户交易数据、浏览记录、搜索记录等,是电商平台常见的用户商品信息. 本文的协同过滤推荐算法使用隐式反馈信息.

协同过滤算法是基于用户商品信息的推荐算法,这意味着只有拥有足够的用户商品信息的商品才会被作为推荐对象. 但是,对于一个新进商品来说,用户商品信息处于缺失状态,这导致新进商品很难作为目标用户的推荐对象. 这种新进商品无法被推荐的现象称为冷启动问题^[2-3],它的存在严重影响协同过滤算法的推荐质量.

协同过滤推荐算法中冷启动问题的主流解决方法是在生成目标用户推荐集的过程中考虑用户或者商

收稿日期:2019-07-05.

基金项目:广东省协同创新与平台环境建设专项基金(2014B090908004)、东莞市专业镇创新服务平台建设项目.

通讯联系人:罗辛,博士,副教授,研究方向:机器学习、模式识别. E-mail:xluo@mail.dhu.edu.cn

品自身语义信息. 常见自身语义信息包括: 用户喜好、用户社会身份、商品描述、地点、天气等^[4-5]. 实际应用中, 由于这些信息的获取偏差以及影响力等原因, 导致无法准确挖掘目标用户潜在兴趣, 为其推荐合适的商品. 本文提出一种利用服装图像视觉特征来缓解协同过滤推荐算法中冷启动问题的方法. 首先, 服装图像视觉特征作为一种服装类商品语义信息的表示, 能够对用户购买意向产生更加直观有力的影响. 其次, 无论是商品库中已存在的商品, 还是新进商品, 商品图像视觉特征都处于可获得状态.

本文基于服装商品图像视觉特征缓解冷启动问题的算法框架分为两个模块: 基础模块和核心模块. 基础模块基于矩阵分解(matrix factorization, MF)^[6], 此模块的主要作用是估算用户对商品的评分. 矩阵分解可以得到两个矩阵: 用户特征矩阵和商品特征矩阵. 用户特征矩阵表示用户对特征的偏喜度, 商品特征矩阵表示商品对特征的占有度, 用户对商品的评分则被表示为目标用户特征向量与商品特征向量的积. 核心模块是映射函数(Mapping Function), 反映商品图像视觉特征与商品特征向量之间的关系, 其作用是通过商品图像视觉特征得到商品特征向量. 新商品的图像视觉特征经过核心模块映射函数求得商品特征向量. 基础模块中, 目标用户特征矩阵与新商品特征向量相乘可求得用户对新商品的评分, 根据评分高低为目标用户生成推荐对象集. 具体过程如图 1 所示.

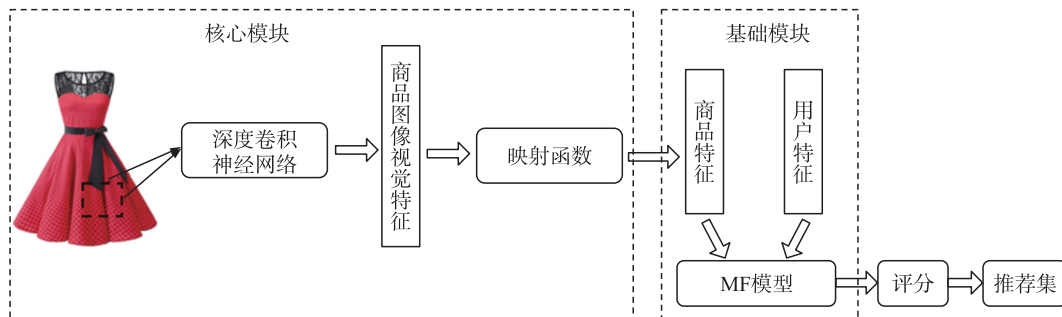


图 1 基于服装商品图像视觉特征的冷启动问题算法框架

Fig. 1 Algorithm framework of visual features of clothing images based cold-start problem

本文中, 我们的主要工作包括:

- (1) 通过对用户商品交易数据的处理, 生成用户商品评分表.
- (2) 训练 MF 模型. 在有用户商品交易数据的训练集中训练 MF 模型, 并使用该模型估算目标用户对商品的评分.
- (3) 利用映射函数将服装商品图像视觉特征映射到商品特征向量中, 得到新商品的特征向量, 来缓解协同过滤算法中冷启动问题.

1 相关工作

在基于模型的协同过滤算法中, 通过对用户商品(user-item)评分矩阵进行分解可以反映出用户购买欲与商品本身的关系. 传统矩阵分解采用奇异值分解(singular value decomposition, SVD)^[7], 要求用户商品矩阵为稠密矩阵. 但在实际中, 往往由于用户商品交易数据的缺失导致用户商品评分矩阵为稀疏矩阵. 此外, 奇异值分解输出三个矩阵, 产生大量计算任务, 导致无法为目标用户产生实时推荐^[8]. 为了解决上述问题, Simon Funk 提出 Funk-SVD 算法, 该算法对传统奇异值分解算法进行了改进.

Funk-SVD 算法通过分解用户商品评分矩阵来取得用户的特征偏喜度和商品的特征占有度, 用户对商品的评分则通过目标用户特征偏喜度向量和商品特征向量获得. 由于新商品交易数据的缺失导致新商品特征向量处于未知状态, 新商品就无法作为目标用户的推荐对象, 这种现象是导致冷启动问题产生的根本因素.

冷启动问题解决的关键在于利用用户或者商品自身语义信息, 包括用户喜好、用户年龄、用户身份信息、商品文本描述、地点天气和用户关注点^[9-10]等. 这些信息的加入在一定程度上缓解了协同过滤算法冷启动问题, 但在挖掘用户喜好方面效果并不理想. 因此本文针对服装商品提出了使用服装图像视觉特征来缓解冷启动问题的方法.

服装图像视觉特征在现实中已被广泛应用于各领域. Gatys 等人^[11]利用图像视觉特征解析服装, Kiapour 等人^[12]将图像视觉特征应用于服装的精确查找, Priya 等人^[13]利用图像特征进行病灶检测等. 服

装图像视觉特征的提取有很多方法,本文采用 Kanagal^[14] 提出的深度卷积神经网络 (deep convolutional neural networks, DCNN) 提取服装图像视觉特征。

2 基于服装图像视觉特征的冷启动缓解方法

2.1 问题定义

服装商品推荐算法中首要的两个对象为用户和商品。本文定义用户集为 $U = \{1, 2, 3, \dots, m\}$, 其中 $m \in \mathbf{N}^+$ 表示用户数量, 定义商品集为 $I = \{1, 2, 3, \dots, n\}$, 其中 $n \in \mathbf{N}^+$ 表示商品数量。

本文推荐算法使用模块化设计方式, 算法被分为两个模块: 以矩阵分解为主的基础模块和以映射函数为主的核心模块。

矩阵分解的输入矩阵是用户-商品评分矩阵。用户-商品评分矩阵通过用户交易数据获得。本文中用户交易数据表示用户的购买记录。现定义用户交易数据集 $T = \{(u, i) | u \in U, i \in I\}$, 其中 (u, i) 表示用户-商品对。定义 $T = T_{ui}^+ + T_{ui}^-$, 其中 T_{ui}^+ 表示拥有交易数据的用户-商品对集合, T_{ui}^- 表示没有交易数据的用户-商品对集合。定义 $I_u^+ = \{i | i \in I, u \in U, (u, i) \in T_{ui}^+\}$ 为用户 u 购买的所有商品集合, 定义 $I_u^- = \{i | i \in I, u \in U, (u, i) \in T_{ui}^-\}$ 为未被用户 u 购买过的商品集合。定义用户-商品评分矩阵 $S \in \{0, 1\}^{m \times n}$, 其中 $s_{ui} = 1$ 表示用户 u 购买过商品 i , 即 $(u, i) \in T_{ui}^+$, $s_{ui} = 0$ 表示用户 u 未购买过商品 i , 即 $(u, i) \in T_{ui}^-$ 。

映射函数主要反映服装图像视觉特征与商品特征向量之间关系。本文中为每一件服装选取一张图像作为 DCNN 算法的输入以获取服装图像视觉特征。定义 $f_i, i \in I$ 表示商品 i 的图像视觉特征。

2.2 描述符及其含义

本节详细描述冷启动问题解决方法以及基础模块和核心模块中所涉及到的核心算法。表 1 为文本中用到的描述符及其含义。

表 1 描述符及其含义
Table 1 Notation and explanation

描述符	含义
U, I	用户集和商品集
m, n	用户总数和商品总数
T	用户交易数据集
T_{ui}^+, T_{ui}^-	拥有交易数据的用户-商品对集合, 没有交易数据的用户-商品对集合
I_u^+, I_u^-	用户 u 购买过的所有商品集合, 未被用户 u 购买过的商品集合
S	用户-商品评分矩阵
f_i	DCNN 服装图像视觉特征
$U_{m \times k}, V_{k \times n}$	用户特征矩阵, 商品特征矩阵
r_{ui}, \hat{r}_{ui}	用户 u 对商品 i 的实际评分, 用户 u 对商品 i 的预测评分

2.3 矩阵分解模型

本文通过 Funk-SVD 算法分解用户-商品评分矩阵 S , 并利用已知评分训练矩阵分解模型, 使矩阵分解模型的评分估算结果拟合实际用户对商品的评分。

Funk-SVD 算法将评分矩阵 S 分解为两个矩阵: $S_{m \times n} = U_{m \times k}^T \cdot V_{k \times n}$, 其中矩阵 $U_{m \times k}$ 表示用户特征矩阵, 反映用户的特征偏喜度, 矩阵 $V_{k \times n}$ 表示商品特征向量, 反映商品的特征占有度。矩阵分解模型估算的用户 u 对商品 i 的评分表示为: $\hat{r}_{ui} = \mathbf{u}_u^T \mathbf{v}_i$ 。使用均方差作为损失函数来拟合用户对商品的实际评分结果。

定义用户 u 对商品 i 的实际评分 r_{ui} , 我们期望 $(r_{ui} - \mathbf{u}_u^T \mathbf{v}_i)^2$ 尽可能的小, 如果考虑所有商品和样本的组合, 则期望将下式最小化:

$$\sum_{u, i} (r_{ui} - \mathbf{u}_u^T \mathbf{v}_i)^2. \quad (1)$$

同时, 求出极值所对应的 \mathbf{u}_u 和 \mathbf{v}_i , 便可得到矩阵 U 和 V , 用户 u 对商品 i 的评分估算为 $\mathbf{u}_u^T \mathbf{v}_i$ 。

实验中, 为了防止过拟合现象, 加入一个 L^2 的正则化项, 因此 Funk-SVD 的优化目标函数 $J(\mathbf{u}, \mathbf{v})$ 表示为:

$$\underbrace{\argmin}_{\mathbf{u}_u, \mathbf{v}_i} \sum_{u, i} (r_{ui} - \mathbf{u}_u^T \mathbf{v}_i) + \lambda (\|\mathbf{u}_u\|_2^2 + \|\mathbf{v}_i\|_2^2). \quad (2)$$

式中, λ 为正则化系数. 对于这个优化问题, 通过梯度下降法来进行优化. 将上式分别对 $\mathbf{u}_u, \mathbf{v}_i$ 求导得到:

$$\frac{\partial J}{\partial \mathbf{u}_u} = -2(r_{ui} - \mathbf{u}_u^T \mathbf{v}_i) \mathbf{v}_i + 2\lambda \mathbf{u}_u. \quad (3)$$

$$\frac{\partial J}{\partial \mathbf{v}_i} = -2(r_{ui} - \mathbf{u}_u^T \mathbf{v}_i) \mathbf{u}_u + 2\lambda \mathbf{v}_i. \quad (4)$$

则在梯度下降法迭代时, $\mathbf{u}_u, \mathbf{v}_i$ 的迭代公式为:

$$\mathbf{u}_u = \mathbf{u}_u + \alpha((r_{ui} - \mathbf{u}_u^T \mathbf{v}_i) \mathbf{v}_i - \lambda \mathbf{u}_u). \quad (5)$$

$$\mathbf{v}_i = \mathbf{v}_i + \alpha((r_{ui} - \mathbf{u}_u^T \mathbf{v}_i) \mathbf{u}_u - \lambda \mathbf{v}_i). \quad (6)$$

通过迭代最终可以得到 \mathbf{U} 和 \mathbf{V} .

2.4 映射函数

映射函数通过服装图像视觉特征计算商品的特征向量, 现定义用户 u 对新品 i 评分的通用表达式为

$$\hat{r}_{ui} = \mathbf{u}_u^T \phi(f_i). \quad (7)$$

式中, f_i 表示商品 i 的图像视觉特征向量, $\phi(f_i)$ 表示由映射函数 ϕ 计算出的商品 i 的特征向量. 文中分别使用两种映射函数: K 最近邻匹配和线性匹配.

(1) K 最近邻匹配 (K -Nearest-Neighbor Mapping)

对于一个新商品 i , 我们使用 KNN 算法得到与之最相近的 k 个商品, 商品集定义为 N_k . 为了得到新商品的特征向量, 我们对 $i \in N_k$ 里所有商品的特征向量进行加权计算:

$$\phi f(f_i) = \frac{\sum_{j \in N_k(i)} \text{sim}(f_i, f_j) v_j}{\sum_{j \in N_k(i)} \text{sim}(f_i, f_j)}. \quad (8)$$

式中, $\text{sim}(f_i, f_j) = \frac{\langle f_i, f_j \rangle}{\|f_i\| \cdot \|f_j\|}$.

(2) 线性匹配 (Linear Mapping)

线性匹配中, 商品的特征向量通过对服装商品图像视觉特征加权求得, 线性匹配公式定义为

$$\phi f(f_i) = \sum_{l=1}^L w_l f_{il} \mathbf{E}. \quad (9)$$

式中, w_l 表示权值, 矩阵 \mathbf{E} 实现服装图像视觉特征向量降维以匹配图像特征向量. 线性匹配函数的参数通过训练得到, 本文采用文献[15]中实现的方法进行训练.

3 实验与结果分析

为了验证服装商品图像视觉特征对协同过滤推荐算法中新商品冷启动问题的缓解效果, 针对冷启动问题的基准方法作对比实验. 同时, 也比较了两种映射函数对新商品冷启动问题的缓解效果.

3.1 数据集

本文中使用的 Mcauley 等人^[16]使用过的亚马逊数据集. 数据集如表 2 所示. 数据集中交易数据代表用户对商品的购买行为, 本文将其整理为用户商品评分表用于 MF 模型的训练. 此外, 为每一商品都选取一张图片用于商品图像视觉特征的计算. 商品图像视觉特征使用 DCNN 提取^[17].

表 2 数据集

Table 2 Datasets

商品数据集	用户	商品	交易数据
Amazon Women	98 504	502 561	80 681
Amazon Men	80 920	430 251	63 518
总计	179 424	932 812	144 199

3.2 比较方法

为了验证实验效果, 分别进行如下实验:

Funk-SVD MF: 此方法是协同过滤冷启动问题传统解决方法. Funk-SVD MF 方法作为本实验的基准方法.

KNN-MF: 采用 K 最近邻 (KNN) 匹配算法计算新进商品的特征向量, 然后利用训练好的 MF 模型为目标用户生成推荐集合.

LM-MF:采用线性匹配函数将商品的图像视觉特征映射到单品特征向量上,实现新进商品的推荐。

3.3 评价指标

本文采用精确率、召回率、 F_1 值来衡量推荐算法的预测准确率。首先用混淆矩阵来描述真正类 (true positive, TP)、真负类 (true negative, TN)、假正类 (false positive, FP)、假负类 (false negative, FN) 的概念,本文定义 T^+ 表示 TP, T^- 表示 TN, F^+ 表示 FP, F^- 表示 FN, 如表 3 所示。

召回率 (Recall, R):表示推荐系统推荐了且在测试集中确实存在的行为列表占测试集中全部行为列表的比例。

$$R = \frac{T^+}{T^+ + F^-}. \quad (10)$$

精确率 (Precision, P):表示系统推荐了且在测试集中确实存在的行为列表占推荐系统推荐的全部行为列表的比例。

$$P = \frac{T^+}{T^+ + F^+}. \quad (11)$$

F_1 值: F_1 对 P 和召回率 R 都进行了加权,均匀地反映了推荐效果。

$$F_1 = \frac{2PR}{P+R} = \frac{2T^+}{2T^+ + F^+ + F^-}. \quad (12)$$

3.4 实验结果

选取两种映射函数与一种基准方法分别在 Amazon Women 和 Amazon Men 两个数据集中作对比试验,分别比较不同算法在召回率 R 、精确率 P 和 F_1 值的表现,结果如图 2 所示。

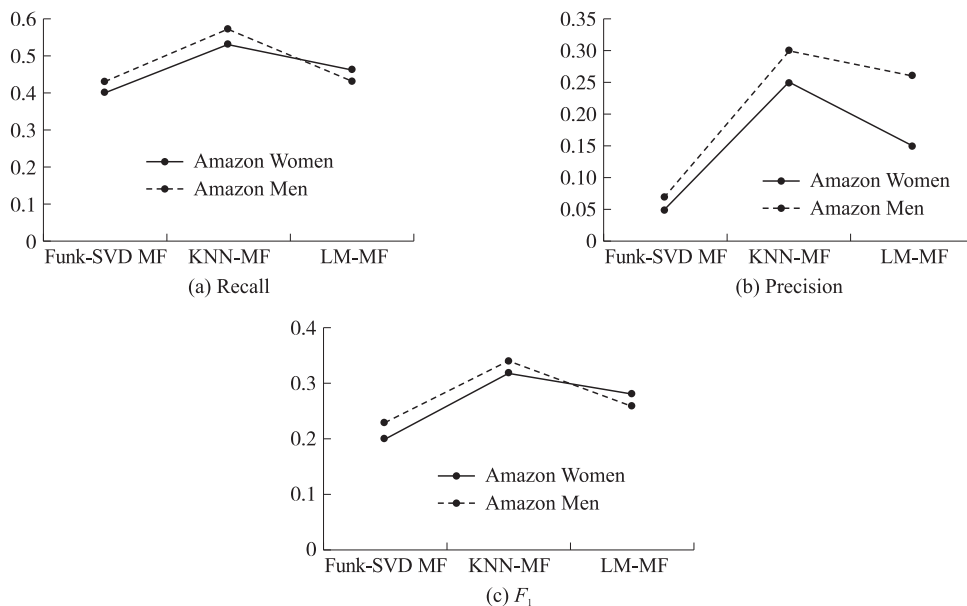


图 2 召回率、精确率和 F_1 值

Fig. 2 Recall, Precision and F_1

实验结果显示,相比于基准 Funk-SVD MF 方法,KNN-MF 方法和 LM-MF 方法在召回率、精确率和 F_1 值均有提升。基准方法 Funk-SVD 在计算用户对新商品喜好度的时候,并没有考虑服装图像视觉特征这一重要特性,只是简单地对已有评分进行计算,导致其对新商品评分预测不准确。KNN-MF 和 LM-MF 两种方法利用不同的映射函数,将服装图像视觉特征映射到商品特征,从而将服装图像视觉特征对商品评分的影响考虑在内,进而提高对新商品评分预测的准确性,缓解了推荐算法中冷启动问题。此外,实验结果显示,KNN 算法解决冷启动问题的效果要优于 LM 算法。

4 结语

协同过滤推荐算法深受冷启动问题的影响,传统解决冷启动问题的方法效果不佳。本文提出一种利

用服装商品图像视觉特征来缓解协同过滤冷启动问题的方法. 此方法分为两个模块:基础模块和核心模块. 基础模块利用用户-商品评分矩阵训练 MF 模型,并用 MF 模型预测用户对商品的评分. 核心模块利用 DCNN 算法提取服装商品图像视觉特征,并使用映射函数将服装商品图像视觉特征映射到商品特征向量上. 通过比较两种映射函数与基准方法的实验结果,服装商品视觉特征有效缓解了协同过滤冷启动问题.

[参考文献](References)

- [1] BREESE J S,HECKERMAN D,KADIE C M,et al. Empirical analysis of predictive algorithms for collaborative filtering[C]//Uncertainty in Artificial Intelligence. Madison,Wisconsin,USA,1998.
- [2] JIA Y,SHELHAMER E,DONAHUE J,et al. Caffe:convolutional architecture for fast feature embedding[C]//ACM Multimedia. Orlando,Florida,USA,2014.
- [3] SCHEIN A I,POPESCU A,UNGAR L H,et al. Methods and metrics for cold-start recommendations[C]//International ACM SIGIR Conference on Research and Development in Information Retrieval. Tampere,Finland,2002.
- [4] DONAHUE J,JIA Y,VINYALS O,et al. DeCAF:A deep convolutional activation feature for feneric visual recognition[C]//International Conference on Machine Learning. Beijing,China,2014.
- [5] BOBADILLA J,ORTEGA F,HERNANDO A,et al. Recommender systems survey[J]. Knowledge based systems,2013,46:109-132.
- [6] KOREN Y,BELL R M,VOLINSKY C,et al. Matrix factorization techniques for recommender systems[J]. IEEE computer,2009,42(8):30-37.
- [7] POLAT H,DU W. SVD-based collaborative filtering with privacy[C]//ACM Symposium on Applied Computing. Santa Fe,New Mexico,USA,2005.
- [8] MNIH A,SALAKHUTDINOV R. Probabilistic matrix factorization[C]//Neural Information Processing Systems. Vancouver,British Columbia,Canada,2007.
- [9] BAO J,ZHENG Y,MOKBEL M F,et al. Location-based and preference-aware recommendation using sparse geo-social networking data[C]//Advances in Geographic Information Systems. Redondo Beach,California,USA,2012.
- [10] DE MELO E V,NOGUEIRA E A,GULIATO D,et al. Content-based filtering enhanced by human visual attention applied to clothing recommendation[C]//International Conference on Tools with Artificial Intelligence. Vietri Sul Mare,Italy,2015.
- [11] GATYS L A,ECKER A S,BETHGE M,et al. Image style transfer using convolutional neural networks[C]//Computer Vision and Pattern Recognition. Las Vegas,Nevada,USA,2016.
- [12] KIAPOUR M H,HAN X,LAZEBNIK S,et al. Where to buy it:matching street clothing photos in online shops[C]//International Conference on Computer Vision. Santiago,Chile,2015.
- [13] PRIYA S S,RAMAMURTHY B. Lung cancer detection using image processing techniques[J]. Research journal of pharmacy and technology,2018,11(5):2045-2049.
- [14] KANAGAL B,AHMED A,PANDEY S,et al. Supercharging recommender systems using taxonomies for learning user purchase behavior[J]. ACM digital library,2012,5(10):956-967.
- [15] HASTIE T,TIBSHIRANI R,FRIEDMAN J. The elements of statistical learning,second edition:data mining,inference,and prediction[M]. Germany:Springer,2009.
- [16] MCAULEY J,TARGETT C,SHI Q,et al. Image-based recommendations on styles and substitutes[C]//International ACM SIGIR Conference on Research and Development in Information Retrieval. Santiago,Chile,2015.
- [17] CORR R O,DENG J,SU H,et al. ImageNet large scale visual recognition challenge[J]. International journal of computer vision,2015,115(3):211-252.

[责任编辑:陈 庆]