

基于分类器链的产品多标签意象识别方法

初建杰, 王鹏超, 陈晨, 史颖茜

(西北工业大学 工业设计与人机工效工信部重点实验室, 西安 710072)

摘要: **目的** 为快速准确识别消费者对产品意象的认知, 提出一种基于分类器链的产品意象识别方法。**方法** 首先, 构建产品意象数据集, 通过相似性聚类和网络爬虫得到产品意象词与产品图像, 在此基础上, 进行产品意象实验, 获得消费者对于产品意象的认知, 构建产品意象数据集; 然后, 提取图像特征, 利用卷积神经网络 ResNet50 提取产品图像特征; 最后, 使用分类器链算法构建产品意象识别模型, 提出基于混淆矩阵与条件熵的分类器链标签顺序确定方法, 确定产品意象标签顺序。**结论** 为了验证所述标签顺序确定方法在识别产品意象中具有优越性设计了对比实验。实验结果表明, 相较于其他方法, 基于分类器链的产品多标签意象识别方法考虑了标签的识别结果与相关关系, 能显著提升模型对于产品多标签意象的预测性能。

关键词: 产品意象; 多标签分类; 分类器链; 深度学习

中图分类号: TB472 **文献标识码:** A **文章编号:** 1001-3563(2021)14-0040-07

DOI: 10.19554/j.cnki.1001-3563.2021.14.004

Product Multi-label Image Recognition Method Based on Classifier Chain

CHU Jian-jie, WANG Peng-chao, CHEN Chen, SHI Ying-xi

(Key Laboratory of Industrial Design and Ergonomics, Ministry of Industry and Information Technology, Northwestern Polytechnical University, Xi'an 710072, China)

ABSTRACT: In order to identify consumers' cognition of product image in a quick and accurate manner, a product image recognition algorithm based on classifier chain is proposed. First, product image data sets are built, and product labels and pictures are obtained by similarity clustering and web crawler. On this basis, consumers' cognition of product image is obtained and product image data sets are built through product image experiment. The next step is to extract the image features. The product image features are extracted using the convolutional neural network RESTNet50, then the product image recognition model is constructed using the classifier chain algorithm, and, based on confusion matrix and conditional entropy, the label order of product image is determined. A comparative experiment is designed to verify that the algorithm has advantages in product image recognition. The experimental results show that, compared with other methods, it takes into account the label identification results and the related relationship, thus can significantly improve prediction performance of the model for product multi-label image.

KEY WORDS: product image; multi-label classification; classifier chain; deep learning

随着社会生产力的发展, 物质生活水平的提高, 消费者越来越注重自身的感性需求。产品所表达的不同感性意象正是消费者获得不同情感需求的重要媒介。因此开发符合消费者感性意象认知的产品已逐

渐成为产品设计中的重点^[1]。在产品设计阶段, 设计师根据自身工作经验与知识结构给产品赋予了具有强烈主观色彩的意象特征。然而, 消费者对产品意象的认知也具有自己强烈的个性, 并且与设计师感知的

收稿日期: 2021-02-15

基金项目: 国家重点研发计划资助项目(2019YFB1405701)

作者简介: 初建杰(1981—), 男, 山东人, 博士, 西北工业大学工业设计与人机工效工信部重点实验室副教授, 主要研究方向为数字化工业设计方法、人机工效技术等。

意象相比常常存在着较大差异^[2]。因此，构建能快速准确辅助设计师识别消费者意象的模型就显得十分重要^[3]。

深度学习技术的发展，为产品意象研究提供了新的思路。朱斌等人^[4]利用卷积神经网络 VGGNet 进行训练，从简单—复杂、轻巧—笨重、柔软—硬朗 3 个意象维度分别对产品意象进行了识别，通过 3 个产品意象深度学习模型，判断产品是否符合意象标签，并取得了较好的效果，对于这 3 对意象词的识别准确率达 95.3%、85.2%、74.2%。宗杰等人^[5]利用神经网络探究了产品文化符号意象识别与评价方法。然而单一的风格意象标签很难完整地描述产品风格，因此需要采用多意象词来综合表征产品的意象^[6]。并且现有采用卷积神经网络进行的多标签意象识别的研究，由于需要训练多个不同的模型，耗时耗力。而多标签分类算法可以同时解决单个目标的多属性分类问题，目前已在场景分类及数据挖掘等领域得到了广泛应用。因此，本文提出采用多标签分类算法进行产品意象的识别，以综合表征产品风格。

1 研究内容与方法框架

1.1 分类器链算法

分类器链 (Classifier Chains, 简称 CC) 算法是实现多标签分类最简单高效的一种算法，其基本思想是将多标签分类问题转化为一个二值分类问题链，链中后续的二值分类器建立在对输入特征和之前二值分类器预测的基础上^[7]。CC 能够学习到标签之间的相关关系，在多标签分类领域得到了较好的应用，但也存在着一些不足之处，如标签的顺序会影响识别的准确率。而如何确定最佳的标签顺序已成为近年来 CC 需要改进的研究方向之一。因此，提出一种新的 CC 标签确定方法，并将其应用到产品意象识别中，构建产品意象识别模型。同时将该方法与其他方法比较，以验证其优越性。

1.2 产品意象数据集的构建方法

产品意象数据集的构建是实现意象识别的基础，同时会直接影响构建的多标签模型对意象识别的性能。产品意象数据集的构建是在获取感性意象词集与产品样本集的基础上，通过产品意象实验实现的。本文通过设计产品意象实验来获取产品意象数据集。

1.3 基于分类器链的产品多标签意象识别方法

提出基于分类器链的产品多标签意象识别方法框架，见图 1。首先，基于聚类分析得出感性意象词集，并筛选图片得出产品样本集，通过意象实验构建产品意象数据集；随后利用 RestNet50 提取产品图像特征；然后基于分类器链算法构建产品意象识别模型；最后将基于分类器链的产品多标签意象识别算法

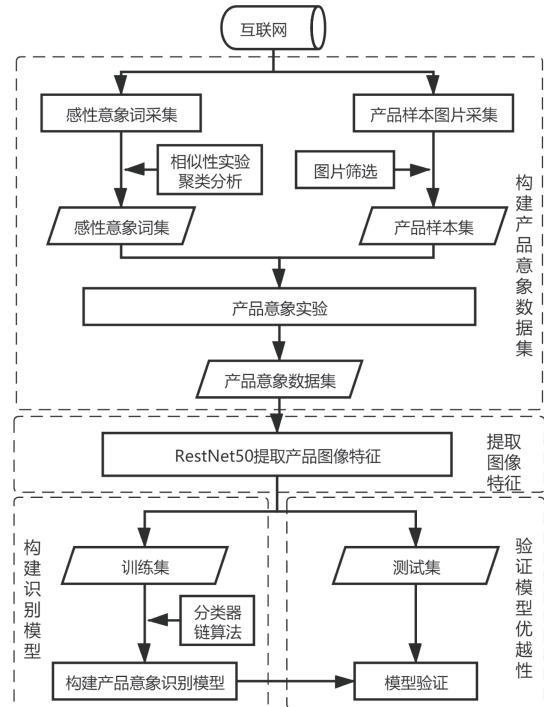


图 1 基于分类器链的产品多标签意象识别方法框架
Fig.1 A framework for product multi-label image recognition based on classifier chain

与其他算法比较，验证此算法的优越性。

2 基于混淆矩阵与条件熵的分类器链算法

2.1 符号定义

在产品多意象分类中，一个训练数据的特征向量为 $X = [x_1, x_2, \dots, x_p]$ ，真实标签向量为 $Y = [y_1, y_2, \dots, y_q]$ ，预测的标签向量为 $\hat{Y} = [\hat{y}_1, \hat{y}_2, \dots, \hat{y}_q]$ ，其中 p 为产品图像特征的个数， q 为标签的个数， y_1, y_2, \dots, y_q 表示具有一定排列顺序的标签。设 N 为训练集数据的个数， M 为测试集数据的个数， N 个训练数据组成特征矩阵 $X = [x_1, x_2, \dots, x_p] \in R^{p \times N}$ ，真实标签矩阵为 $Y = [y_1, y_2, \dots, y_q] \in R^{q \times N}$ ， M 个测试数据特征矩阵 $X = [x_1, x_2, \dots, x_p] \in R^{p \times M}$ ，预测的标签矩阵为 $\hat{Y} = [\hat{y}_1, \hat{y}_2, \dots, \hat{y}_q] \in R^{q \times M}$ 。

2.2 分类器链算法

分类器链 CC (Classifier Chains) 算法的基本思想是将多标签分类问题转化为一个二值分类问题链，链中后续的二值分类器建立在对输入特征和之前二值分类器预测的基础上。

分类器链中第 j 个 ($1 \leq j \leq q$) 训练集 D_j 、测试集 S_j 的定义：

$$D_j = \begin{cases} [x_1, x_2, \dots, x_p] & j = 1 \\ [x_1, x_2, \dots, x_p, y_1, \dots, y_{j-1}] & j \geq 2 \end{cases} \quad (1)$$

$$S_j = \begin{cases} [x_1, x_2, \dots, x_p] & j = 1 \\ [x_1, x_2, \dots, x_p, \hat{y}_1, \dots, \hat{y}_{j-1}] & j \geq 2 \end{cases} \quad (2)$$

2.3 基于混淆矩阵与条件熵的分类器链算法

为了确定在 CC 中的最佳标签顺序,同时考虑标签的预测结果与标签间的相互关系,从而确定标签顺序。

2.3.1 基于混淆矩阵与熵的分类器链算法

假设只有两个标签 y_1 和 y_2 , 需要确定标签顺序 y_1, y_2 , 或者 y_2, y_1 , 分别在 CC 中的应用效果, JUN X 等人^[8]提出的核心思想是当 $H(y_1) \leq H(y_2)$ 时, 标签顺序为 y_1, y_2 时更好, 反之标签顺序为 y_2, y_1 时更好。其中 $H(y_1)$ 、 $H(y_2)$ 表示训练集中标签 y_1 、 y_2 的信息熵。信息熵的定义为对于一个具有 n 个可能结果的随机实验 Y , 可能结果出现的概率分布 $p = (p_1, p_2, \dots, p_n)$, 其中 $0 \leq p_i \leq 1 (i=1, 2, \dots, n) \sum_{i=1}^n p_i = 1$ 。Shannon 引入函数:

$$H(Y) = H(p_1, p_2, \dots, p_n) = -\sum_{i=1}^n p_i \log p_i \quad (3)$$

式(3)中, $H(Y)$ 称为 Y 的信息熵。信息熵是对某随机事件的不确定性或者信息混乱无序的度量。当任何一个 $p_i = 1$ 时, 则 $H(Y) = 0$, 这时可以直接对随机事件做出正确的判断, 不存在不确定性。 $H(Y)$ 越小, 表示随机事件的不确定性或者混乱无序性越小。JUN X 等人^[8]对标签排序采用的核心思想是高信息熵的标签应该放在低信息熵标签的后面。信息熵越大, 就意味着不确定性越高, 可能导致分类的难度越大, 这一点与文献[9-10]所述的核心思想一致。

文献[8]所述的算法建立在对训练集标签 y_1 、 y_2 信息熵的基础上。标签 y_1 、 y_2 都只有两个可能出现的结果 $\{0,1\}$ 。当标签 y_1 、 y_2 识别准确率接近 100% 时, 训练集上标签 y_1 、 y_2 可以较为全面地反映测试集 \hat{y}_1 、 \hat{y}_2 标签的分布信息, 因此可以比较 y_1 与 y_2 的信息熵, 从而进行标签排序。然而当标签 y_1 、 y_2 识别的准确率较低时, 利用训练集标签的信息熵来确定排序顺序, 显然是不合理的。因为对标签进行排序时, 只考虑到训练集标签的信息熵, 所以可能会出现将识别准确率低的标签排列在分类器链前端的情况, 导致对于前端标签的错误预测会一直沿着链传播, 进而影响到后端标签的判断。因此只有同时考虑到预测结果与标签分布, 才能得出更加合理的标签排列顺序。

以多标签分类中第 j 个 ($1 \leq j \leq q$) 标签来说, 可以利用混淆矩阵描述分类器输出结果与标签的真实信息, 见表 1, 混淆矩阵中包括 4 类数据: (1) TP (True Positive) 为被预测为正的样本, $y_j=1, \hat{y}_j=1$; (2) FP (False Positive) 为被预测为正的负样本, $y_j=0, \hat{y}_j=1$; (3) FN (False Negative) 为被预测为负的正样本, $y_j=1, \hat{y}_j=0$; (4) TN (True Negative) 为被预测为负的负样本, $y_j=0, \hat{y}_j=0$ 。

表 1 混淆矩阵

Tab.1 Confusion matrix

T/F	Positive	Negative
True	TP	FN
False	FP	TN

第 j 个 ($1 \leq j \leq q$) 标签的准确率 (Accuracy) 和召回率 (Recall) 分别表示:

$$Acc_j = \frac{TP_j + TN_j}{TP_j + FN_j + FP_j + TN_j} \quad (4)$$

$$Rec_j = \frac{TP_j}{TP_j + FN_j} \quad (5)$$

此时对于测试集上标签 \hat{y}_j , 考虑到预测结果计算 $H(\hat{y}_j)$ 时, 可能出现 4 种结果 $\{TP, FP, FN, TN\}$ 。根据这 4 种可能出现的结果去计算信息熵, 可以将标签分布与预测结果同时考虑。因此, 提出将训练集上对信息熵 $H(y_1)$ 、 $H(y_2)$ 的比较, 改进为比较测试集上的信息熵 $H(\hat{y}_1)$ 、 $H(\hat{y}_2)$, 以此确定标签的顺序。

以上讨论的是只有两个标签的情况, 当标签的个数大于 2 时, 延续两个标签时的核心思想, 信息熵较高的标签应该放在信息熵低的标签之后。基于混淆矩阵与信息熵的分类器链算法 (Confusion Matrix and Entropy based Classifier Chains, 简称 CMECC) 给出标签排序的过程: (1) 计算 $H(\hat{y}_1)$ 、 $H(\hat{y}_2) \dots H(\hat{y}_q)$; (2) 将 $H(\hat{y}_i)$ 从小到大排序, 输出标签排序结果。

虽然 CMECC 考虑到了标签的预测结果与分布情况, 但是无法表示标签之间的相关关系。为了明确标签间的相互关系引入条件熵的概念, 对理论方法进一步优化。

2.3.2 基于混淆矩阵与条件熵的分类器链算法

信息熵能表示信息的混乱程度, 使用信息熵作为排序的依据时, 无法体现第 i 个标签 ($1 \leq j \leq q$) 与其之前标签间的关联关系。条件熵 $H(Y|X)$ 表示在已知随机变量 X 的条件下, 随机变量 Y 的不确定性或者混乱程度。条件熵 $H(Y|X)$ 定义为在 X 给定条件下, Y 的条件概率分布的熵对 X 的数学期望。条件熵的计算公式:

$$H(Y|X) = \sum_{x \in X} p(x) H(Y|X=x) = -\sum_{x \in X} p(x) \sum_{y \in Y} p(y|x) \log p(y|x) = -\sum_{x \in X} \sum_{y \in Y} p(x,y) \log p(y|x) \quad (6)$$

当给定标签 \hat{y}_i , \hat{y}_j 的条件熵为 0 时, 即 $H(\hat{y}_j|\hat{y}_i) = 0$, 表明标签 \hat{y}_i 一定时, 标签 \hat{y}_j 不确定性或者混乱程度为 0, 因此标签 \hat{y}_j 可以通过标签 \hat{y}_i 完美预测。如果 $H(\hat{y}_j|\hat{y}_i)$ 足够低, 那么意味着标签 \hat{y}_j 保留了关于标签 \hat{y}_i 的大部分信息, 因此可以说标签 \hat{y}_j 与标签 \hat{y}_i 具有

较强的相关性, 标签 \hat{y}_i 的值可以通过观察标签 \hat{y}_i 较好地预测出来。由此提出基于混淆矩阵与条件熵的分类器链算法 (Confusion Matrix and Conditional Entropy based Classifier Chains, 简称 CMCECC)。CMCECC 的核心思想是保证第 i 个 ($2 \leq j \leq q$) 标签与该前 $i-1$ 个标签的相关性最强。在排序过程中第 i 个标签 y_i ($2 \leq j \leq q$) 的定义:

$$y_i = \arg \max_{\hat{y}_j \in G} -H(\hat{y}_j | w_{i-1}) \quad (7)$$

式(7)中, w_{i-1} 表示前 $i-1$ 个标签组成的排序; G 表示剩下未参与排序标签的集合。这一点与文献^[11]所述的核心观点一致。

CMCECC 的过程: (1) 确定排序的开头, 计算 $H(\hat{y}_1)$ 、 $H(\hat{y}_2) \cdots H(\hat{y}_q)$, 将信息熵最小的标签作为排序的开头, 即作为 w_i ($i=1$) 中的元素; (2) 确定第 i 个标签排序, 分别计算 $H(\hat{y}_i | w_{i-1})$ ($2 \leq i \leq q, \hat{y}_i \in G$), 将最小的值放入 w_{i-1} 中; (3) 确定排序的结尾, 重复第二个步骤, 直到剩下最后一个标签, 并将其作为标签排序的结尾, 最后输出标签排序结果。

通过上述过程, CMCECC 在进行标签排序时, 同时考虑了标签间的相关关系与标签识别结果, 在保证模型空间复杂度和时间复杂度的情况下, 提高了模型对于产品多标签意象的识别性能。

3 构建产品意象数据集与提取产品图像特征

为了验证本文所提出的方法在产品意象识别中的优越性, 需要构建产品意象数据集。产品意象数据集的构建方法: 首先通过聚类分析获得产品意象标签; 然后使用爬虫获得产品图像; 在此基础上进行产品意象实验, 获得产品图像对应的意象标签; 最后使用卷积神经网络提取图像特征。产品图像特征与产品图像对应的意象标签组成产品意象数据集。

3.1 意象标签的采集与筛选

意象标签的采集与筛选参考文献^[12]所述方法。通过采访消费者和设计师、文献分析和进一步筛选, 确定能描述座椅的 27 个意象的感性词汇, 构建相似性矩阵, 以五维的多元尺度法展开分析。取各群距离中心点最近者为该群的代表, 见表 2。最后得到 5 群中代表及其含义相反的形容词, 构成产品意象标签集, y_1, y_2, \dots, y_{10} 分别为“时尚的”“古典的”“简约的”“复杂的”“商务的”“休闲的”“优美的”“粗犷的”“奢华的”“质朴的”。

3.2 产品图像的采集图筛选

本文意象识别研究的对象为椅子。椅子图像主要通过设计网站和购物网站爬虫下载获得。通过进一步筛选, 遴选出背景简单, 图像分辨率高, 意象识别容易的椅子图像, 最终确定了 1038 把椅子图像。

表 2 意象词聚类结果
Tab.2 Image word clustering results

第 1 群	第 2 群	第 3 群	第 4 群	第 5 群
个性的	简单的	理性的	圆润的	别致的
开放的	温和的	商务的	柔和的	精致的
潮流的	简约的	庄严的	柔美的	奢华的
独特的	质朴的	严谨的	优美的	高端的
时尚的	大方的	成熟的	优雅的	精巧的
—	轻巧的	—	华美的	—




图 2 “时尚—古典的”意象实验问卷
Fig.2 Image experiment questionnaire of “fashionable-classical”

3.3 产品意象实验

3.3.1 意象实验

在产品意象实验中, 45 名具有多次家具购买经验的被试受邀参加。包含男性 23 名和女性 22 名, 年龄在 22~49 岁。实验采用李克特量表法获取被试的感性意象。实验中对于“时尚—古典的”这一感性意象词的调查问卷, 见图 2。

意象实验要求: (1) 实验环境选择明亮、安静、通风良好的实验室, 以减少环境对于被试认知的影响; (2) 为了减少时间负荷对于被试的影响, 随机将被试与产品图像均等分为 3 组, 即每名被试需要对 346 个产品的意象进行评价, 每个产品由 15 名被试进行评价; (3) 被试进行实验时产品图像会展示 2 s, 被试在 2 s 内评价产品意象, 每评价 10 个产品会休息 15 s; (4) 对于 5 组不同产品意象评价, 重复 5 次产品意象实验, 每次实验间隔 2 h 以上。

3.3.2 产品意象实验结果

在意象实验中, 被试完成一次实验所需的时间为 30 min, 实验过程中尽可能为被试营造一个舒适的实验环境, 同时采用诸多措施减少时间负荷对于被试的影响。这些都使得被试的实验数据具有更高的准确性。在对实验数据进行可信度分析之前, 首先剔除掉意象认知差异较大的产品, 例如由于被试认知的差异, 存在一些产品一半被试认为“非常时尚”, 而另一半被试认为“非常古典”。这种分歧较大, 被试无法达成共识的实验数据为无效数据, 它的存在会进一步影响深度学习的识别效果, 需要被剔除。剔除 46 条无效数据后, 采用克隆巴赫系数对实验数据进行检验, 实验数据的总体 α 系数为 0.762, 属于高信度, 表示该意象实验得出的实验结果具有较高的可信度。

表3 样本图片及其意象标签(部分)

Tab.3 Sample pictures and image labels (partial)

样本图片	意象标签	样本图片	意象标签
	时尚的 简约的 休闲的 质朴的		商务的 质朴的
	古典的 复杂的 优美的 奢华的		古典的 简约的 质朴的

计算被试的均值并将其作为判断产品意象的标准。例如,评价“时尚—古典的”这一组意象词时,若意象评价均值大于1,则这款产品是时尚的;若意象评价均值小于-1,则这款产品是古典的;当意象评价均值在-1与1之间,由于产品意象的主观性,可以认为这款产品在“时尚—古典的”表现的特点并不突出,因此这款产品既不时尚也不古典,也就不含有“时尚的”或“古典的”这两个标签。本文采用分类器链的方法识别产品多意象标签,要求产品至少具有1个意象标签。最终由984张产品图像与其对应的产品意象标签组成产品意象数据集。样本图片及其意象标签(部分)见表3。

3.4 产品图像特征提取

利用残差神经网络(ResNet)^[13]提取产品图像特征。获得RestNet50平均池化层后的图像特征。输入的产品图像形状为 $[n, 224, 224, 3]$,获得的特征向量形状为 $[n, 2048]$ 。其中 n 表示输入图像的个数。

4 构建产品意象识别模型及实验结果分析

4.1 实验设置

4.1.1 数据集

产品意象数据集中含有984条数据,随机分为训练集和测试集两个部分,分别包含734条和250条数据。为了减少产品图片噪声对实验的影响,每个产品图像减去颜色均值,得到零均值化的训练样本。此外,使用数据增强法^[14](最简单、常见的防止过拟合的方法),将每个产品图像都进行了旋转;然后进行224像素×224像素的随机裁剪,作为提取产品图像特征的输入项。

4.1.2 对比实验

一共设立8组对比实验,分别是BR^[15]、CC、ECC^[16]、PCC^[17]、CEbCC^[8]、LOCC^[18],以及本文提出的CMECC和CMCECC。其中,BR将多标签分类问题转化为多个独立的二分类问题;CC建立链式结构,利用标签间的相互关系进行多标签分类;ECC

表4 标签间信息熵矩阵

Tab.4 Information entropy matrix between labels

Y_n/Y_n	Y_1	Y_2	Y_3	...	Y_n
Y_1	0	$H_x(Y_2 Y_1)$	$H_x(Y_3 Y_1)$...	$H_x(Y_n Y_1)$
Y_2	$H_x(Y_1 Y_2)$	0	$H_x(Y_3 Y_2)$...	$H_x(Y_n Y_2)$
Y_3	$H_x(Y_1 Y_3)$	$H_x(Y_2 Y_3)$	0	...	$H_x(Y_n Y_3)$
...
Y_n	$H_x(Y_1 Y_n)$	$H_x(Y_2 Y_n)$	$H_x(Y_3 Y_n)$...	0

表5 标签共现频率矩阵

Tab.5 Label co-occurrence frequency matrix

Y_n/Y_n	Y_1	Y_2	Y_3	...	Y_n
Y_1	$F(Y_1-Y_1)$	$F(Y_2-Y_1)$	$F(Y_3-Y_1)$...	$F(Y_n-Y_1)$
Y_2	$F(Y_1-Y_2)$	$F(Y_2-Y_2)$	$F(Y_3-Y_2)$...	$F(Y_n-Y_2)$
Y_3	$F(Y_1-Y_3)$	$F(Y_2-Y_3)$	$F(Y_3-Y_3)$...	$F(Y_n-Y_3)$
...
Y_n	$F(Y_1-Y_n)$	$F(Y_2-Y_n)$	$F(Y_3-Y_n)$...	$F(Y_n-Y_n)$

随机产生多个标签链,以减少标签顺序对分类结果的影响,同时ECC中的阈值 t 能确定最终的分类结果;PCC对整个标签的联合分布进行估计,确定多标签分类结果。以上方法均为对CC算法的直接优化。对于标签顺序的算法优化过程可简要叙述如下。

在CEbCC中利用训练集中条件熵构建两类标签间的条件熵矩阵,见表4。

并根据标签间的条件熵给出4条排序策略:(1)计算每一行的总和,如果第 i 行求和值最小,那么 Y_i 应该放在链的末端;(2)计算每一行的总和,如果第 i 行求和值最大,那么 Y_i 应该放在链的开头;(3)计算每一列的总和,如果第 i 列求和值最小,那么 Y_i 应该放在链的开头;(4)计算每一列的总和,如果第 i 列求和值最大,那么 Y_i 应该放在链的末端。

以第一条策略为例,表中有 n 行和 n 列。找到行求和后值最小的行,即第 i 行,将对应的类标签放在链中的第 n 个位置。删除表中的第 i 行和第 i 列,只留下 $n-1$ 行和 $n-1$ 列。找到行求和后值最小的行,将相应的类标签放在表的第 $n-1$ 个位置,删除相应的行和列,留下 $n-2$ 行和 $n-2$ 列。对剩余的标签应用此过程,直到表为空为止。所有的标签都包含在链条中。CEbCC会得出表4中排序结果。

LOCC算法利用标签间的共现频率优化标签排序。构建标签共现频率矩阵,见表5,其中 $F(Y_i-Y_j) = F(Y_j-Y_i)$ 。

得出排序策略:首先确定 Y_1 到 Y_n 出现频率最多的标签;将其排在标签的首位,假设第 i 个标签出现的频率最多,将第 i 个标签放置在首位;在剩下的 $n-1$ 个标签中寻找与第 i 个标签共现次数最多的标签,将其放在 Y_i 后,假设第 j 个标签与第 i 个标签共现的频率最多,则标签顺序为 Y_i, Y_j ;在剩下的 $n-2$ 个标签

表 6 不同多标签分类方法实验结果
 Tab.6 Experimental results of different multi-label classification methods

算法/指标	Hamming Loss	Accuracy	Exact-Match	F1	Macro F1	Micro F1
BR	0.278	0.458	0.098	0.679	0.534	0.699
CC	0.267	0.513	0.140	0.674	0.573	0.721
ECC	0.274	0.458	0.115	0.700	0.546	0.657
PCC	0.249	0.519	0.102	0.695	0.615	0.727
CEbCC1	0.293	0.481	0.095	0.681	0.623	0.729
CEbCC2	0.286	0.476	0.089	0.652	0.614	0.716
CEbCC3	0.301	0.492	0.086	0.747	0.575	0.698
CEbCC4	0.234	0.507	0.108	0.658	0.618	0.724
LOCC	0.259	0.516	0.123	0.706	0.597	0.714
CMECC	0.233	0.546	0.139	0.732	0.604	0.731
CMCECC	0.215	0.537	0.142	0.729	0.635	0.748

中寻找与标签 Y_j 共现频率最多的标签，以此类推，直至所有标签完成排序。

4.1.3 实验设置

本实验使用 TensorFlow 实现算法。使用随机梯度下降 (Stochastic Gradient Descent, 简称 SGD) 算法, 将其学习率默认值设置为 $\eta=0.01$, 实验中损失函数的权重参数设置为 $\lambda=1$, 正则系数设置为 $\tau=0.01$ 。ECC 中设置随机生成的标签顺序个数为 10 个。阈值设置成 0.6, 即在 10 次实验中若 6 次及 6 次以上实验预测某个标签为 1, 则该标签预测的最终结果为 1, 否则为 0。

4.1.4 预实验

在预实验中需要使用对比实验中所述的方法获得标签顺序。CEbCC 使用 4 种不同策略获得 4 种不同的标签顺序。

CEbCC1: $Y_9, Y_2, Y_8, Y_1, Y_5, Y_3, Y_7, Y_6, Y_{10}, Y_4$

CEbCC2: $Y_2, Y_1, Y_8, Y_5, Y_6, Y_7, Y_3, Y_4, Y_9, Y_{10}$

CEbCC3: $Y_4, Y_3, Y_{10}, Y_5, Y_7, Y_8, Y_6, Y_9, Y_1, Y_2$

CEbCC4: $Y_3, Y_4, Y_{10}, Y_7, Y_6, Y_8, Y_5, Y_1, Y_2, Y_9$

LOCC 获得的标签顺序: $Y_4, Y_{10}, Y_2, Y_6, Y_9, Y_7, Y_1, Y_3, Y_8, Y_5$

通过本文所述方法计算出 CMECC、和 CMCECC 标签顺序。

CMECC: $Y_4, Y_3, Y_9, Y_7, Y_{10}, Y_5, Y_8, Y_1, Y_2, Y_6$

CMCECC: $Y_4, Y_3, Y_{10}, Y_9, Y_5, Y_7, Y_2, Y_8, Y_1, Y_6$

4.1.5 评价指标

在评价模型多标签识别性能中, 常用的评价指标有 Hamming Loss、Accuracy、Exact-Match、F1、Macro F1、Micro F1。以上 6 个指标基于实例的指标有 Hamming Loss、Accuracy、Exact-Match、F1; 基于标签的指标有 Macro F1、Micro F1。这些评价标准在评价多标签分类中得到了广泛应用, 它们从不同的方面来评价多标签算法的性能。除 Hamming Loss 外,

其他指标的值越大, 模型的性能越好。

4.2 实验结果及分析

不同多标签分类方法实验结果见表 6, 可得不同多标签分类方法在 Hamming Loss、Accuracy、Exact-Match 等指标上的实验结果。从表中可以得出 BR 将多标签分类问题转化为多个二值分类问题, 结果并不理想。CC 考虑到标签之间的相互关系, 相比于 BR 性能较好。优化标签排序算法相较于基于算法改进 CC, 从整体来说对于模型性能的提升更加显著。本文提出的 CMCECC 在 10 种算法中取得了最好的效果。这证明在实现产品多标签意象上, CMCECC 具有优越性。

5 结语

本文提出了一种基于分类器链的产品多标签意象识别方法。在优化标签排序时考虑标签的识别准确率与相互关系, 使用混淆矩阵和条件熵实现对标签的排序。在构建产品意象数据集的基础上, 将本文所述的 CMECC、CMCECC 与其他算法进行比较, 得出该算法在识别意象方面具有优越性。使用 CMCECC 算法能快速准确识别设计方案的感性意象, 辅助设计师进行设计。然而本文也存在一定不足, 如意象实验的主观性会影响到整个算法的预测准确率, 后续的研究将围绕降低意象实验的主观性展开。

参考文献:

- [1] 陈国东, 陈思宇, 王军, 等. 面向复合意象的产品形态多目标优化[J]. 中国机械工程, 2015, 26(20): 2763-2770. CHEN Guo-dong, CHEN Si-yu, WANG Jun, et al. Multi-objective Optimization of Product Form Based on Composite Image[J]. China Mechanical Engineering, 2015, 26(20): 2763-2770.
- [2] 罗仕鉴, 朱上上. 用户和设计师的产品造型感知意象

- [J]. 机械工程学报, 2005(10): 28-34.
LUO Shi-jian, ZHU Shang-shang. User and Designer's Perception Image of Product Form[J]. Journal of Mechanical Engineering, 2005(10): 28-34.
- [3] 平恩顺, 檀润华, 孙建广. 基于TRIZ的机械产品突破性创新设想产生过程研究[J]. 中国机械工程, 2014, 25(18): 2439-2446.
PING En-shun, TAN Run-hua, SUN Jian-guang. Generation Process of Breakthrough Innovation Assumption of Mechanical Products Based on TRIZ[J]. China Mechanical Engineering, 2014, 25(18): 2439-2446.
- [4] 朱斌, 杨程, 俞春阳, 等. 基于深度学习的产品意象识别[J]. 计算机辅助设计与图形学学报, 2018, 30(9): 1778-1784.
ZHU Bin, YANG Cheng, YU Chun-yang, et al. Product Image Recognition Based on Deep Learning[J]. Journal of Computer-Aided Design & Computer Graphics, 2018, 30(9): 1778-1784.
- [5] 宗杰, 赵卫国, 张振江, 等. 基于神经网络的产品文化符号意象认知评价方法研究[J]. 包装工程, 2021, 42(8): 261-267.
ZONG Jie, ZHAO Wei-guo, ZHANG Zhen-jiang, et al. Cognitive Evaluation Method of Product Cultural Symbol Image Based on Neural Network[J]. Packaging Engineering, 2021, 42(8): 261-267.
- [6] 苏建宁, 陈彦嵩, 景楠, 等. 产品意象造型设计中的耦合特性研究[J]. 机械设计, 2017, 34(1): 105-109.
SU Jian-ning, CHEN Yan-hao, JING Nan, et al. Coupling Characteristics of Product Image Forming Design[J]. Journal of Machine Design, 2017, 34(1): 105-109.
- [7] WENG W, WANG D, CHEN C, et al. Label Specific Features-Based Classifier Chains for Multi-label Classification[J]. IEEE Access, 2020, 8(27): 51265-51275.
- [8] JUN X, LU Y, LEI Z, et al. Conditional Entropy Based Classifier Chains for Multi-Label Classification[J]. Neurocomputing, 2019, 335(36): 185-194.
- [9] SENGE R, DELCOZ J J, HÜLLERMEIER E. Rectifying Classifier Chains for Multi-label Classification[J]. Space, 2013, 2(8): 162-169.
- [10] SENGE R, DELCOZ J J, HÜLLERMEIER E. On the Problem of Error Propagation in Classifier Chains for Multi-Label Classification[J]. Machine Learning and Knowledge Discovery, 2012: 163-170.
- [11] LEE JAEDONG, KIM HEERA. An Approach for Multi-label Classification By Directed Acyclic Graph with Label Correlation Maximization[J]. Information Sciences, 2016, 351: 101-114.
- [12] 孙凌云, 孙守迁, 许佳颖. 产品材料质感意象模型的建立及其应用[J]. 浙江大学学报(工学版), 2009, 43(2): 283-289.
SUN Ling-yun, SUN Shou-qian, XU Jia-ying. Construction and Application of Product Material Texture Image Model[J]. Journal of Zhejiang University (Engineering Science), 2009, 43(2): 283-289.
- [13] HE Kai-min, ZHANG Xiang-yu. Deep Residual Learning for Image Recognition[J]. Corr, 2015, 1512: 85.
- [14] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. Computer Science, 2014: 1556.
- [15] TSOUMAKAS G, KATAKIS I, VLAHAVAS I. Mining Multi-label Data[M]. Berlin: Springer, 2010.
- [16] READ J, PFAHRINGER B, HOLMES G, et al. Classifier Chains for Multi-Label Classification[J]. Machine Learning, 2011, 85(3): 333-359.
- [17] DEMBCZYŃSKI K, CHENG W, HÜLLERMEIER E. Bayes Optimal Multilabel Classification via Probabilistic Classifier Chains[C]. Haifa: 27th International Conference on Machine Learning, 2010.
- [18] ALI T, ASGHAR S. Efficient Label Ordering for Improving Multi-label Classifier Chain Accuracy[J]. Journal of the National Science Foundation of Sri Lanka, 2019, 47(2): 175-184.