

基于深度学习的女装图片分类探索

叶 锦^{1,2} 彭小江¹ 乔 宇¹ 邢 昊³

¹(中国科学院深圳先进技术研究院 深圳 518055)

²(中国科学院大学 北京 100049)

³(唯品会研究院 广州 510000)

摘 要 互联网商品图像的属性分类是人工智能领域的重要研究课题之一, 针对商品图像属性分布不平衡以及不同属性间存在相关性等问题, 该文以女装图像为分类目标, 提出了一种基于卷积神经网络的商品图像分类方法。首先, 从电商网站获取大量商品图像, 并进行人工标注; 然后, 基于卷积神经网络框架, 采用了一种有效的采样策略, 通过增加新的损失函数, 实现了基于多任务学习方法的商品图像属性准确分类; 最后, 通过对不同策略下分类结果的对比分析, 验证了该方法的有效性。结果显示, 所提出方法具有较高的分类精度。

关键词 商品图像; 卷积神经网络; 采样; 多任务

中图分类号 TG 156 文献标志码 A doi: 10.12146/j.issn.2095-3135.20181226001

Classification of Women Dress Images Based On Deep Learning

YE Jin^{1,2} PENG Xiaojiang¹ QIAO Yu¹ XING Hao³

¹(Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)

²(University of Chinese Academy of Sciences, Beijing 100049 China)

³(Vipshop Research Group, Guangzhou 510000, China)

Abstract With the rapid development of Internet online shopping, automatic classification of product images has become an interesting research topic. In this paper, an accurate classification method for women dress images are investigated. Firstly, 40 000 product images were crawled from the Vipshop online shopping websites, which all are annotated by several experts. Then, several baselines using deep convolutional networks were provided. Finally, a new loss function was introduced and the multi-task learning method was used to improve the classification accuracy. With the comparison of different strategies, the experimental results show that the proposed method can obtain higher classification accuracy.

Keywords product image; convolutional neural networks; sampling; multi-task

收稿日期: 2018-12-26 修回日期: 2019-01-18

基金项目: 商品图像细粒度分类与弱监督学习算法研究项目(SY8Z003)

作者简介: 叶锦, 硕士研究生, 研究方向为计算机视觉、深度学习、商品图像分析; 彭小江(共同第一作者), 博士, 副研究员, 硕士研究生导师, 研究方向为计算机视觉、深度学习、商品图像分析、人脸识别等; 乔宇(通讯作者), 博士, 研究员, 博士研究生导师, 研究方向为计算机视觉、深度学习、行为识别、场景识别、人脸识别、目标检测等, E-mail: yu.qiao@siat.ac.cn; 邢昊, 研究员, 研究方向为商品图像分析。

1 引言

随着互联网、手机设备等的快速发展,网上购物已经成为人们日常生活中不可缺少的一部分,天猫更是在 2014 年“双 11”创造了 350 亿元的销售奇迹^[1]。网上购物相比传统的购物方式有许多优点,例如:在省去了租门面的成本后,网络购物能以更低的价格购买到相同的商品;对消费者来说,可以节约大量的时间和精力去实体店挑选;能买到许多本地不能买到的商品等。伴随着网购的快速发展,相应的问题也应运而生,如当人们想要在淘宝、京东、唯品会等平台购买商品时,往往会根据商品的类别及其属性来筛选需要购买的目标商品,因此商家会为每件商品制定很多属性以便于用户检索。面对海量的商品图像数据,如果使用人工标注的方式对商品图像的属性进行标注,需要花费大量的人力和时间。因此,如何自动对商品属性正确分类便成了一个重要且具有实际意义的课题。商品图片的特点是:有些商品不同的属性之间数量差异很大,即商品的属性存在数据分布不平衡的特性,如“衣长”属性,日常生活中人们穿得最多的是标准的到达髋部位置的衣服(普通外套、T 恤等),其他的如风衣、长短裙(到达大腿或小腿位置)等的数量明显少于到达髋部位置的衣服;有些商品不同的属性之间差异很小,可以看作是细粒度分类问题,如“领型”属性,一些领型属性之间的差异非常小,常人难以区分开来。这两个问题加大了商品图像属性分类的难度。

为了解决这个问题,近年来,许多研究人员尝试过从网上搜集一些商品数据并对其进行分类。Bossard 等^[2]使用随机森林的方法对服装图像进行分类并取得了较好的结果,但是其做法比较复杂。首先,需要从原始商品图像中检测出目标区域。然后,再对目标区域进行特征提取和分类。Xiao 等^[3]尝试在一小部分准确标注的数据以及大量的噪声数据中学习一个较好的模型对商品

图像进行分类;Liu 等^[4]提出了一个 FashionNet 网络来对商品的类别以及部分属性进行预测。与 Deep fashion^[4]数据库不同的是,本文数据库是由电商直接定义标注并且根据需求定义了 13 个子任务,具有上百种细类别。

本文基于深度学习技术^[5-6],使用卷积神经网络对商品图像的属性分类进行研究。首先,从唯品会网站上爬取了 46 049 个商品图片,并将这些图片分为 13 个子任务:女上衣品类、主颜色模式、次颜色、主模式、次模式、纹理模式、流行元素、领型、袖长、衣长、版型、门襟、面料。每一个子任务都是一个独立的细粒度多分类任务,且几乎每个子任务都具有严重的数据分布不平衡问题,这无疑大大增加了问题的难度。由于数据分布不平衡问题的存在,直接使用传统的图像分类方法无法得到较优的分类结果。因此本文在传统图像分类的基础上,尝试不同的采样策略、增加不同的损失函数优化网络以及使用多任务学习的策略来提高分类的精度,通过对不同策略的结果进行对比和分析,验证了所采取的策略是有效的。本文所使用的方法具有以下优点:(1)采样策略和增加针对不平衡数据的损失函数能够在一定程度上抑制数据分布不平衡所带来的问题;(2)由于一些子任务具有一定相关性,使用多任务联合训练能挖掘任务之间的相关性并提高模型的分类准确率以及泛化能力。

本文内容组织如下:第 2 部分主要介绍本文搜集的数据集;第 3 部分阐述本文采用的方法策略;第 4 部分对所采用的方法在该数据集上进行实验验证;第 5 部分将本文结果与国内外相似研究进行对比分析;第 6 部分总结。

2 建立数据集

2.1 数据集收集以及处理

由于女装在网购中占有主导地位,因此本

文考虑在女装图像上进行实验。本文首先从唯品会网站上爬取了大量的女装图像并进行筛选保留了 46 049 张质量比较高的图像。然后, 将这些图像分为 13 个子任务(女上衣品类、主颜色模式、

次颜色、主模式、次模式、纹理模式、流行元素、领型、袖长、衣长、版型、门襟、面料), 其中每一个子任务都是一个独立的细粒度多分类问题。图 1 展示了衣长、女上衣品类、主颜色和



图 1 女装样例展示

Fig. 1 Clothes samples



图 2 女装数据分布统计

Fig. 2 Statistics of the distribution of clothes data

主花色模式的一些样本。最后,在清洗完数据之后,本文请一些专家对数据进行标定和检验,以确保数据的可靠性。从图 2 可以看到,每个子任务的数据分布都是不均匀的,衣长、主颜色以及主花色模式分布更是极其不平衡,该现象增加了分类问题的难度。

2.2 评测方法

本文先随机将每个子任务按照 8:2 的比例分为训练集和测试集;然后,采取两种评价方式对实验结果进行评价。

(1) 总平均精度 ($Acc.$): 即为正确识别的测试样本数目占总测试样本的比例,如公式(1)所示。

$$Acc. = \frac{TP}{TP + FP} \quad (1)$$

其中, TP 代表被正确分类为正样本的正测试样本数; FP 代表被错误分类为正样本的负测试样本数; $TP + FP$ 代表所有被分为正样本的测试样本数。

(2) $F1$ 评分 ($F1$ Score): 除女上衣品类子任务外,其他子任务的数据分布都极其不平衡,而 $F1$ 评分是对不平衡数据更为公平的评价方式。因此除了平均精度之外,本文还引入 $F1$ 评分对实验结果进行评价,计算方法如公式(2)所示。

$$F1 = \frac{2 \times Acc. \times Recall}{Acc. + Recall} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

其中, FN 代表被错误分类为负样本的正测试样本数; $TP + FP$ 代表所有的正测试样本; $Recall$ 代表召回率。

3 研究方法

3.1 基础网络介绍

2012 年, Alex 等提出的深度神经网络结

构 AlexNet^[7]在 ImageNet 分类大赛^[8]上获得冠军之后,卷积神经网络便开始风靡学术及工业界。在此之后,涌现出了许多比较出名的网络结构^[5-6,9-10]。本文选择了 3 个较具有代表性的网络 (Resnet101、空洞卷积网络和压缩激励网络),并在此基础上进行实验设计。

(1) Resnet101: 在深度学习初期,由于梯度消失的问题,网络结构的深度一直是一个难以解决的难题。残差网络 Resnet^[6]引入一个所谓的恒等快捷连接,将上一层的输入直接与后面层的输出相加,很好地解决了梯度消失的问题。

(2) 空洞卷积网络 (Dilated Convolution Network, DRN): 在使用深度神经网络解决分类任务的问题上,维护图像的分辨率是一个很重要的任务,即输入的分辨率越大,分类的效果越好。但由于硬件设备的限制,不能无限地增大图像分辨率,而 DRN^[10]使用空洞卷积^[11]的思想很好地解决了这个问题,即使用较小分辨率的输入一样能得到很好的效果。

(3) 压缩激励网络 (Squeeze-and-Excitation Networks, SENet): SENet^[9]获得了 ImageNet 2017 图像识别大赛的冠军。其做法是通过学习的方式自动获取到每个特征通道的重要程度,然后依照这个重要程度去提升有用的特征并抑制对当前任务用处不大的特征。

3.2 对不平衡数据的处理方法

从数据分布来看,除了女上衣品类外,其他子任务都是不平衡分布。学术上对于不平衡数据的处理方法大致分为基于采样的方法^[12-14]和基于代价的方法^[15]。本文分别从这两个方面进行实验探索。

(1) 基于采样的方法: 在不平衡分布的数据中使用采样方法,目的是为了将不平衡的数据变为均匀分布。许多研究表明,将分布不平衡的数据变为均匀分布之后能够有效提高分类精度^[12]。常见的采样方法一般分为升采样和降采

样。其中, 升采样一般又有随机升采样、合成新数据等方法; 降采样一般有随机降采样、指导性降采样等方法。本文采用随机升采样和随机降采样方法。其中, 随机升采样的做法是: 从样本数量少的类别集合 $S_{\min}$ 中随机复制一部分样本, 然后将其添加到总样本集合 E 中, 最终使总样本集合中的样本分布达到平衡。而随机降采样的做法则是相反: 将样本数量多的类别集合 $S_{\max}$ 中随机删掉一部分样本, 最终使总样本集合 E 分布达到平衡。

(2) 基于代价的方法: 主要是从损失函数方面入手解决样本分布不平衡的问题。由图 3 所示可知, 对类 A , 其类内之间的距离 D_1 非常大, 需要增加一种约束将其类内之间的距离缩小; 而对类 B 和类 C , 其类间距离 D_2 太近了, 因此需要一种约束来将其类间距离拉大。出于该动机, 本文使用了 Rangeloss 损失函数^[15]来解决这个问题。其中, Rangeloss 是一种和样本数目无关的损失函数。具体地, Rangeloss 分为类内损失函数和类间损失函数两部分。其中, 对某一类的类内损失函数是在一个批 (Batch) 里面计算该类所有样本的距离矩阵, 取最大的 k 个距离计算调和平均数作为该类的类内损失函数, 具体如公式 (4) 所示。




图 3 类内以及类间距离举例

Fig. 3 Inter and intra distances of samples

$$L_{R_{\text{intra}}} = \sum_{i \in I} L_{R_{\text{intra}}}^i = \sum_{i \in I} \frac{k}{\sum_{j=1}^k \frac{1}{D_j}} \quad (4)$$

其中, D_j 代表该类中样本之间的距离; I 代表该批中的所有类别; i 代表该批中的一个类别。

不同于类内距离的计算方式, 类间损失函数是在一个批中求出所有类的特征均值, 计算所有均值的距离矩阵, 取最小的距离, 使得这个距离至少要大于阈值 m , 具体如公式 (5) 所示。

$$L_{R_{\text{inter}}} = \max(m - D_{\text{center}}, 0) = \max\left(m - \|\bar{x}_Q - \bar{x}_R\|_2^2, 0\right) \quad (5)$$

其中, D_{center} 代表类间距离矩阵中的最小距离; $\bar{x}_Q$ 与 $\bar{x}_R$ 代表在该批中类间距离最小的两个类别中心; m 取 1 作为 Zhang 等^[15]和本文的默认设置。

最终, 将类内和类间的损失函数进行加权求和得到最终的损失函数。

$$L_R = \alpha L_{R_{\text{intra}}} + \beta L_{R_{\text{inter}}} \quad (6)$$

其中, α 和 β 是对类内距离和类间距离的权重参数。根据 Zhang 等^[15]的实验评估结果, 当 $\alpha = \beta = 0.001$ 时能够获得较好的结果, 故本文沿用这一设置。

3.3 多任务联合训练策略

由于本文所使用的数据集对所有任务的图片是相同的, 而在这 13 个子任务中, 有些子任务之间可能是具有相关性的, 如女上衣品类和衣长、主颜色和次颜色、纹理模式和版型等。若将每个子任务看作一个独立的子任务显然会忽略任务之间的一些相关性。为了将任务之间的相关性利用起来, 本文探索了多任务联合训练策略。多任务学习是将多个相关任务放在一起学习的一种机器学习方法, 其结构如图 4 所示。多个任务在浅层共享参数, 在最后使用各自任务所对应的分类器进行分类, 每个子任务的分类器都是以一层或多层全连接层实现的。在训练时, 每个子任务的分类结果使用交叉熵损失函数计算损失, 并将每个子任务的损失加权求和得到最后




图 4 多任务联合训练框架图

Fig. 4 Multi-task training framework

的损失。具体地，每个子任务的交叉熵损失函数如公式(7)所示。

$$J = -\sum_{c=1}^M y_c \log(p_c) \quad (7)$$

其中， M 是类别的数量； y 表示变量(0 或 1)，如果该类别和样本的类别相同就是 1，否则是 0； p 是对于观测样本属于类别 c 的预测概率。在得到每个子任务的损失之后，利用公式(8)对所有的损失进行求和。

$$L_{muti} = \sum_{i=1}^n J_i \quad (8)$$

4 实验设计及结果

本文采用 Ubuntu16.04+python2.7+pytorch 0.4 作为深度学习框架，并在此基础上进行实验。实验中使用显卡为 TITAN XP。

4.1 不同网络结构的实验对比分析

本文将在 Resnet101、DRN 和 SENet 这 3 个网络上进行对比实验，对比不同网络对分类结果的影响。本文使用 ImageNet 预训练的 Pytorch 模

型，具体设置为：将训练图片缩放为 224×224 ，不进行裁剪，训练数据使用随机水平翻转进行数据增强。其中，批大小(BatchSize)设置为 64，固定所有的批标准化层(BatchNorm Layer)。学习率初始设为 0.001，并在第 5、8、10 个周期(Epoch)降低 10 倍。测试时将图片缩放为 224×224 。在同样的实现细节情况下(批大小因网络模型不同而异)，不同网络的总体平均精度对比如表 1 所示。从任务平均精度看，DRN105 优于 SENet154 和 ResNet101。DRN 在流行元素任务的提升比较明显，该现象也证实了 DRN 根据小区域特征进行分类的情况比较好，因其能保持较高的输出分辨率。

4.2 不平衡数据处理方法实验以及分析

4.2.1 采样策略的实验评估

首先对升采样和降采样策略进行对比分析，这两种都是基于对训练数据进行采样的策略。本文选择在衣长任务上对这两种策略进行测试。由于在选择的 3 个网络中，Resnet101 的训练速度是最快的，因此实验选择在 ResNet101 上进行。在衣长任务上测试集的表现如图 5 所示。没有

表 1 不同网络的分类结果对比

Table 1 Different network results

模型类别	平均精度 (%)													
	女装类	主颜色	次颜色	主模式	次模式	纹理	流行元素	领型	袖长	衣长	版型	面料	门襟	任务平均
Resnet101	81.65	81.23	86.77	83.99	93.72	86.78	69.96	77.61	84.72	80.12	80.86	80.89	84.32	82.51
SENet154	83.67	81.27	86.97	85.64	94.58	87.01	71.67	81.11	85.84	80.43	80.77	82.96	86.74	83.74
DRN105	83.99	81.76	87.40	85.39	94.83	87.24	72.53	81.44	85.64	81.74	81.57	83.65	87.05	84.17




图 5 不同采样方法实验结果对比

Fig. 5 Different sampling methods results

做采样处理的基础结果在几个少样本类别上的精度均为 0, 加上采样策略后在几个少样本类别上的精度就不为 0 了(及地裙除外, 因为只有一个测试样本), 但是在总平均精度上采样策略都有所下降。升采样策略由于加了过量的少样本强行将分布拉平衡, 导致了在模型学习的过程中容易出现过拟合现象, 因此导致了多样本的类别(除“小腿”)如“臀部”和“大腿”这两个类的精度有所下降。由于这两类的样本数量过大, 导致最终的总平均精度有所下降。而降采样策略的整体表现都不如升采样, 一个很重要的原因是降采样去掉了很多样本数目, 导致模型更加容易过拟合, 降低了其泛化能力。最后, 从 $F1$ 评价来看, 升采样策略优于基础结果并优于降采样策略, 证明了升采样策略是能有效提高分类结果的策略。除此之外, 由于升采样会导致总平均精度降低, 本文考虑将基础的分类结果和升采样的分类结果进行相加融合。该实验在衣长任务的测试结果如图 6 所示: 模型分数融合后, $F1$ 分数还能在升采样策略的基础上提高 2.3%, 且总体平均精度和基础结果接近。在门襟任务的测试结果如图 7 所示, 除了几个样本数量特

别多的类别(套头、单排扣、居中拉链和暗门襟等)外, 样本数量较少的类别精度确实有所提升, 这也再次证明了升采样策略容易出现过拟合现象。虽然最终总平均精度有所下降, 但是经过相加融合之后, 总平均精度和 $F1$ 分数都有所提升。

4.2.2 Rangeloss 的实验评估

本文在 Resnet101 上对 Rangeloss 进行实验对比, 实验在衣长任务上进行测试。基础实验是直接使用 Resnet101 得到的分类结果, Rangeloss 实验结果是在基础实验的基础上直接加入 Rangeloss 损失函数对网络进行监督学习。实验结果如表 2 所示, 可以看到, Rangeloss 能够有效提高分类的总平均精度和 $F1$ 分数, 说明 Rangeloss 确实有减小类内距离和增大类间距离的作用。

表 2 Rangeloss 实验结果对比

Table 2 Rangeloss results

数据类别	总平均精度 (%)	$F1$ 评分 (%)
基础结果	80.12	44.22
Rangeloss	79.98	48.98

4.3 多任务联合训练的实验评估

由于所有任务的图片是相同的, 所以有些任




图 6 升采样与基础结果融合在衣长任务上的实验结果对比

Fig. 6 Baseline and upsampling fusion results in cloth length task




图 7 升采样与基础结果融合在门襟任务上的实验结果对比

Fig. 7 Baseline and upsampling fusion results in closure task

务之间可能是相关的，如女上衣品类和衣长；也有些品类衣长分别是比较有规律的，所以使用多任务进行训练会有帮助。本文对比了 Resnet101 基础实验、上采样策略以及使用上采样策略进行多任务联合训练的实验结果。因为从人们的直观感受来看，女上衣品类和衣长是具有较强相关性的，因此在多任务联合训练实验中，本文选取了

女上衣品类和衣长这两个子任务进行联合训练。衣长的实验结果如表 3 所示，使用多任务进行联合训练之后，衣长任务的 $F1$ 评分相对于使用升采样策略提高了 2.36%，相对于基础结果提高了 7.96%。相对于使用升采样策略，多任务联合训练还能提高总平均精度。女上衣品类任务的结果如表 4 所示，采用多任务联合训练和升

采样策略相对于基础结果在总平均精度和 $F1$ 评分都有所提高。这个实验也证明了多任务联合训练确实可以发掘出不同任务之间的相关性, 并提高分类结果。

表 3 多任务联合训练实验对比(衣长任务)

Table 3 Multi-task results (cloth length task)

数据类别	总平均精度 (%)	$F1$ 评分 (%)
基础结果	80.12	44.22
升采样	74.75	49.92
升采样+多任务	76.89	52.18

表 4 多任务联合训练实验对比(女上衣品类任务)

Table 4 Multi-task results (cloth category task)

数据类别	总平均精度 (%)	$F1$ 评分 (%)
基础结果	80.19	79.45
升采样	79.30	78.80
升采样+多任务	81.54	80.96

5 与国内外相似研究的对比分析

现阶段对商品分类的研究, 主要集中在传统的支持向量机、随机森林等方法 and 神经网络模型。Bossard 等^[2]采用随机森林的分类方法对商品图像进行分类并在其数据集上能够达到平均精度 41.36%。除了使用传统的机器学习算法之外, Liu 等^[4]提出了一个 FashionNet 的深度学习对商品的类别以及部分属性进行预测, 与 Deep fashion^[4]数据库不同的是, 本文的数据库是由电商直接定义标注并且根据需求定义了 13 个子任务、上百种细类别。对于商品属性的预测, 除了将任务分为每个子任务来分别对待, 还能将其看作多标签问题。Chen 等^[16]便将商品属性预测看作是多标签的问题, 但将其转换为多标签问题会面临标签缺失的问题。当然, 本文使用的方法还存在不足之处, 未来工作将重点研究如何进一步在分布不平衡的数据上提高分类精度, 以及如何能让模型自动发现任务之间的相关性并自主选择相关任务进行学习。

6 结 论

本文提出了一个新的女装属性预测数据集, 该数据集具有严重的数据分布不平衡现象。针对这一问题, 本文首先采用了升采样和降采样方法来使数据分布平衡, 并证明了升采样方法在数据不平衡问题上有一定的效果; 然后, 利用 Rangloss 进一步减轻数据不平衡带来的负面影响; 最后, 发现某些子任务之间具有一定的相关性, 因此采用多任务联合训练的策略来提高最终的分类精度, 并验证了其有效性。在未来的研究中, 将考虑进一步优化采样策略, 以及如何让深度网络能够自动发现任务之间的相关性并自动选择相关的任务进行多任务联合优化。

参 考 文 献

- [1] 吴艺晖. 购物中心应对电子商务的策略性转型 [J]. 现代商业, 2014(13): 54-55.
- [2] Bossard L, Dantone M, Leistner C, et al. Apparel classification with style [C] // Asian Conference on Computer Vision, 2012: 321-335.
- [3] Xiao TT, Xia NT, Yang NY, et al. Learning from massive noisy labeled data for image classification [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2015: 2691-2699.
- [4] Liu ZW, Luo P, Qiu S, et al. Deepfashion: powering robust clothes recognition and retrieval with rich annotations [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1096-1104.
- [5] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J]. arXiv: 1409.1556v6, 2015.
- [6] He KM, Zhang XY, Ren SQ, et al. Deep residual learning for image recognition [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.

-
- [7] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks [C] // Advances in Neural Information Processing Systems, 2012: 1097-1105.
- [8] Deng J, Dong W, Socher R, et al. Imagenet: a large-scale hierarchical image database [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248-255.
- [9] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [J]. arXiv: 1709.01507, 2017.
- [10] Yu F, Koltun V, Funkhouser TA. Dilated residual networks [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017: 3.
- [11] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions [J]. arXiv: 1511.07122v1, 2015.
- [12] He HB, Garcia EA. Learning from imbalanced data [J]. IEEE Transactions on Knowledge & Data Engineering, 2009, 21(9): 1263-1284.
- [13] Guo HX, Li YJ, Shang J, et al. Learning from class-imbalanced data: review of methods and applications [J]. Expert Systems with Applications, 2017, 73: 220-239.
- [14] Buda M, Maki A, Mazurowski M. A systematic study of the class imbalance problem in convolutional neural networks [J]. Neural Networks, 2018, 106: 249-259.
- [15] Zhang X, Fang ZY, Wen YD, et al. Range loss for deep face recognition with long-tailed training data [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017: 5409-5418.
- [16] Chen Q, Huang JS, Feris R, et al. Deep domain adaptation for describing people based on fine-grained clothing attributes [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2015: 5315-5324.