

DOI: 10.13382/j.jemi.B2206007

基于深度迁移学习的天气图像识别*

封皓元 段 勇

(沈阳工业大学信息科学与工程学院 沈阳 110870)

摘要: 当对天气图像等场景复杂和特征不明显的图像进行识别时,往往存在识别率不高和特征冗余等问题。基于此,本文提出了一种基于深度迁移学习的图像分类算法。该算法利用 ImageNet 数据集的模型参数构建 ResNeXt、Xception 以及 SENet 3 种网络模型提取图像特征,采用领域自适应的判别联合分布自适应算法来相似化特征向量,完成高质量的特征表示,并以其结果为准融合模型特征,将融合特征经过多层感知机训练以实现高准确率识别的图像分类。实验结果表明,该算法的性能优于传统的单一网络模型,进一步提升了图像分类准确率的上限。

关键词: 模型融合;深度学习;迁移学习;领域自适应;天气识别

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.2

Weather image recognition based on fusing deep transfer learning

Feng Haoyuan Duan Yong

(School of Information Science and Engineering, Shenyang University of Technology, Shenyang 110870, China)

Abstract: When recognizing images with complex scenes and obscure features such as weather images, there are often problems such as low recognition rate and feature redundancy. Based on this, an image classification algorithm based on deep transfer learning is proposed in this paper. The algorithm uses the model parameters of ImageNet dataset to construct three network models, ResNeXt, Xception and SENet, to extract image features, and uses a domain-adaptive discriminative joint distribution adaptive algorithm to resemble the feature vectors to complete a high-quality feature representation, and uses the result as a criterion to fuse the model features, and trains the fused features through a multilayer perceptron to achieve image classification with high accuracy recognition. The experimental results show that the algorithm outperforms the traditional single network model and further improves the upper limit of image classification accuracy.

Keywords: model fusion; deep learning; transfer learning; domain adaptation; weather recognition

0 引言

随着计算机视觉的不断发展与进步,天气识别在实际研究中展现出重要的价值,目前已被应用于灾害预警、自动驾驶以及场景理解等诸多领域。传统算法通常利用人工提取特征,如直方图、透射率、对比度、饱和度特征等,然后构造机器学习分类器对特征进行分类。张世辉等^[1]提出计算天气特征重要性的方法,构造随机森林分类器对多通道的室外天气图像进行分类识别。针对局部与全局图像特征的特点,李鹏程等^[2]提取出天气图像的

天空、地面以及全局图像所蕴含的形状、纹理等多种特征,再使用特征训练出随机森林的模型分类器以达到分类的目的。史静等^[3]利用词袋模型和空间金字塔获取天气特征,再构造二级分类器对室外天气状态进行识别。马啸等^[4]将饱和度作为图像特征,利用改进的 K 均值聚类算法,从而完成对雾霾天气这一特殊天气现象的识别。

近年来,深度学习逐渐展示出巨大的潜力,自 AlexNet^[5]神经网络出现,许多研究使用深度学习技术应用于目标检测^[6]、模式识别、图像分类^[7]等领域,相比较于传统的手工提取特征,性能有着很大的提升。王立刚等^[8]利用 LeNet 卷积神经网络识别了 LED 灯类字体。吕

收稿日期: 2022-11-15 Received Date: 2022-11-15

* 基金项目: 辽宁省高等学校优秀科技人才支持计划(LR15045)项目资助

辉等^[9]将通道注意力机制与跨阶段密集连接网络结合代替残差网络,提升 YOLOv4 对交通的目标检测。其中,一些学者在天气识别的应用中使用了深度学习的方法。崔洪涛等^[10]使用深度神经网络将注意力机制引入特征提取模块,投票机制作为分类模块对复杂天气条件下场景进行识别。王亚朝等^[11]提出一种通过扩张卷积捕捉天气信息与利用深度分离卷积减少计算量为核心模块的卷积神经网络方法识别非固定场景天气。郭志强等^[12]融合了 AlexNet 网络模型所提取的深度学习特征以及对比度、饱和度、暗通道等传统图像特征,实现了对天气的判别。

在深度学习的背景下,一些学者尝试将迁移学习嵌入到神经网络中,加快网络的训练速度,减少过拟合,提升模型稳定性。孙伟帅^[13]利用迁移学习微调的方式提升了模型鲁棒性,优化了 Xception 的网络结构,提升了对天气图像识别的准确率。Al-Haija 等^[14]将预训练模型的权重系数迁移到 ResNet18 模型中,实现对多类天气的识别。

本文针对传统算法提取特征方式复杂,深度学习单一网络识别能力有限的问题,提出了基于深度迁移学习的图像分类算法。在图像分类的任务中,该算法提升了分类准确率的上限,并使用此方法实现了对天气图像的分类。

以 ImageNet 数据集上预训练的网络模型作为基础网络,通过微调的方式训练网络模型,进行特征提取。为了减少特征冗余,完成高质量的特征变换,通过迁移学习的领域自适应完成特征的相似化处理,并依据结果选取表现最佳的特征表示进行模型的特征融合,将融合特征放入多层感知机训练进行图像分类。最后将本文提出的算法应用于实际场景中(天气图像识别)进行实验。

1 图像识别的融合模型

1.1 深度卷积的基础网络模型

图像识别的任务,通常使用卷积层对数据进行准确、全面的特征提取,以此保证分类识别的正确性。然而单一网络的模型性能,通常受到场景复杂、特征不显著图像任务的限制。特别是天气图像的识别任务,其特点在于不能局限于图像中的某个局部部分进行识别,天气图像如图 1 所示,图例表示在复杂的环境中,若仅对部分识别,容易转换成物品分类,如图 1(a)的街灯与图 1(b)的交通信号灯。因此,通常需要深度学习网络对整体进行解释和说明,才能达到天气识别的效果。

伴随基础网络的深度和宽度不断增加,导致训练难度逐渐增大,为了减少训练成本,增强图像的可解释性,提升准确率的上限,采用 3 种深度学习模型融合的算法



图 1 天气图像原图

Fig. 1 Original weather image

识别天气图像。本文使用多种 ImageNet 预训练好的模型作为基础网络,冻结底层网络参数,修改全连接层,获取图像的特征表达,弥补单一网络的不足。本文采用 ResNeXt、SENet 以及 Xception 这 3 种模型实现网络模型的融合。

为了提取更好的图像语义特征,本文将 ResNeXt^[15]应用到图像的特征提取中,ResNeXt 模型采用高度模块化的设计,融合了 VGG 网络堆叠、ResNet 网络残差模块^[16]以及 Inception 网络拆分-变换-聚合的思想。其中,拆分-变换-聚合与残差模块聚合的形式如式(1)所示:

$$R(x) = x + \sum_{i=1}^C T_i(x) \quad (1)$$

式中: x 是输入向量、 T_i 是能把 x 投影到子空间进行变换的函数, C 是基数,表示包含相同分支的数目,通过基数的引入,新增了一个变量,解决了模型依赖深度和宽度增加性能的约束,使模型的表达能力得到更好的提升。

本文使用 SENet^[17],在 ResNeXt 网络模型的基础上,将 SE 架构添加到模型中,以提升模型的表示能力,通过对通道注意力机制的引入,利用额外的神经网络模块,自适应的为每个通道分配不同的权重系数,以此令神经网络为有效的特征分配更大的权重,同时遏制无效的特征,进而获得更好的效果。

文中采用 Xception^[18]提取更好的图像细节特征。Xception 达成对跨通道相关性和空间性的解耦。其中, 1×1 的卷积映射跨通道相关性,空间性是通过输出通道的空间卷积所映射出来的。该模型通过引入深度可分离卷积增加网络宽度,利用残差连接改进网络结构,降低模型收敛的时间,不仅提升了准确率,同时使细节特征的学习能力得到提升。

3 种基础网络的体系结构和内核不同,特征关注点不同,图 2 使用网络中间层的特征展现了 3 种基础网络理解和解释所学习的天气图像。

1.2 基于领域自适应的迁移学习

迁移学习是将在原领域学习过的模型,利用任务、模型和数据三者之间的相关性,迁移到新领域的学习过程。简单来讲,域(domain)是指由数据特征和特征分布组成的数据,源域(source domain)是指已有知识的域,而目标

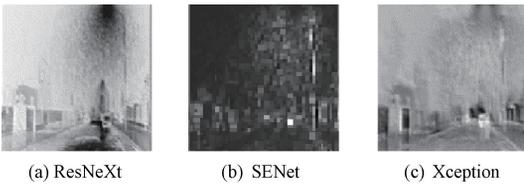


图2 天气图像3种网络特征图的可视化
Fig. 2 Visualization of three network feature maps for weather images

域(target domain)是指要进行学习的域,因此,迁移学习就是将模型从源域 D_s 中学到的知识迁移到目标域 D_t 。本文使用迁移学习减少了网络模型需要的训练时间,避免图像数量较少引发的过拟合问题。但是在进行迁移学习的过程中,如果 D_s 和 D_t 之间的差异较大,会导致迁移学习效果不理想,为此,采用迁移学习的领域自适应实现在领域不变的条件下,对知识的跨域迁移和复用。

领域自适应是迁移学习重要的研究方向,在自适应问题中,给定一个表示有 n_s 个样本的源域 $D_s = \{x_i, y_i\}_{i=1}^{n_s}$, 一个表示有 n_t 个样本的目标域 $D_t = \{x_j\}_{j=1}^{n_t}$, 假设域之间的特征空间和标签空间都相同,但是两个域之间特征分布不同,通过 D_s 训练一个分类器 $f(x)$, 其功能是精准的预测 D_t 的标签结果。即将两个领域的数据映射到同一个域不变特征的空间,然后进行分布对齐,以解决域分布不一致的问题。本文利用领域自适应的判别联合分布自适应(joint probability distribution adaptation, JPDA)^[19]减少相同标签之间的分布差异,提升不同标签之间的分布距离,实现相似化,提高模型的性能。

2 基于领域自适应的深度学习模型融合算法

2.1 判别联合分布自适应

迁移学习领域自适应的传统方法主要使用最大均值差异(maximum mean discrepancy, MMD)推算边缘概率分布和条件概率分布之间的差异,实现对目标域的误差优化。MMD将两个域之间数据分布的特征通过函数映射到再生核希尔伯特空间,计算两个域特征均值的距离。目前许多领域自适应方法使用联合最大均值差异(joint maximum mean discrepancy, JMMD),其计算方法是求出边缘分布差异和条件分布差异的加权和,如式(2)所示:

$$d(D_s, D_t) \approx d(P(X_s), P(X_t)) + d(P(Y_s | X_s), P(Y_t | X_t)) \quad (2)$$

其中, d 为最大均值差异的度量, $P(X_s)$ 是源域边缘分布, $P(X_t)$ 是目标域边缘分布, $P(Y_s | X_s)$ 是源域条件分

布, $P(Y_t | X_t)$ 是目标域条件分布。但是该方法忽略了不同类之间的可区分性,以及边缘分布和条件分布之间的依赖关系,JPDA使用判别联合概率的最大均值差异(discriminative joint probability MMD, DJP-MMD)替代了JMMD,该算法增加了数据分布差异的可转移性和可区分性, M_T 测量不同域之间同一类的可转移性,如式(3)所示:

$$M_T = \sum_{c=1}^c \frac{1}{n_s} \sum_{i=1}^{n_s^c} A^T x_{s,i}^c - \frac{1}{n_t} \sum_{j=1}^{n_t^c} A^T x_{t,j}^c \quad (3)$$

其中, n_s, n_t 表示源域和目标域的数量, n_s^c, n_t^c 表示源域和目标域第 c 类的数量,设置 h 为 x 的特征映射函数 $h(x) = A^T x, x_{s,i}^c, x_{t,j}^c$ 表示源域和目标域中第 c 类的特征。 M_D 测量不同域中不同类之间的可区分性,如式(4)所示:

$$M_D = \sum_{c \neq \hat{c}} \sum_{\hat{c}=1}^c \left\| \frac{1}{n_s} \sum_{i=1}^{n_s^c} A^T x_{s,i}^c - \sum_{j=1}^{\hat{c}} \frac{1}{n_t} A^T x_{t,j}^{\hat{c}} \right\|^2 \quad (4)$$

其中, c, \hat{c} 分别表示源域和目标域的标签,将二者结合,最小化 M_T 与 M_D , 实现 DJP-MMD, 如式(5)所示。

$$d(D_s, D_t) = M_T - \mu M_D \quad (5)$$

其中, μ 是一个超参数。将 DJP-MMD 应用于领域自适应形成 JPDA, 该算法使相同标签在不同域之间的分布差异最小化实现可转移性,使不同领域的不同标签之间的分布差异最大化实现可辨别性,相较于其他 MMD 方法,JPDA 在不同领域之间的差异更有成效。

2.2 多深度学习模型特征融合

深度学习模型融合是利用不同网络模型的结构和内核,提取出多尺度属性的特征,从而解除单个模型识别准确率的限制。采用融合多特征模型的方式,进一步挖掘有效的图像信息,最大程度保留优质特征,丰富语义信息和纹理信息,通过简易分类器就能够获得极佳的预测效果。文中通过使用 ResNeXt、Xception 以及 SENet 所提取的特征,利用特征拼接的融合方式^[20]进行合并,实现多特征模型融合。多深度学习的模型融合过程如图3所示。

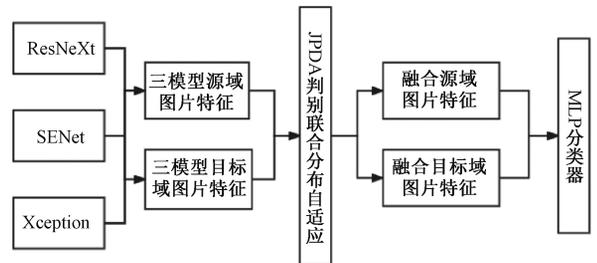


图3 多深度学习的模型融合过程

Fig. 3 Model fusion process for multiple deep learning

其中,通过设置 JPDA 的迭代次数,将内核设置为线

性方式,筛选出效果最优的特征表示,设定好单个网络模型输出的维度,再使用特征拼接方式融合特征,实现不同模型的优势互补,搭建简易多层感知机 (multi-layer perceptron, MLP) 分类器,设置激活函数为 ReLU 函数,通过 ADAM 优化方法加快分类器收敛速度,提升分类结果。

2.3 算法流程

本文提出的多模型分类算法主要分成两个部分,一部分是迁移学习的特征提取,另一部分是以迁移学习领域自适应为准则的融合特征。特征提取部分设计了以迁移模型为基础的网络模型,通过该模型可以减少跨域学习时产生的分布漂移,学习到图像的可迁移特征。融合特征部分主要使用 JPDA 实现对特征的相似化处理,缩减数据之间的差异性,再通过特征拼接融合特征,提升准确率上限。算法详细步骤如图 4 所示。

1) 创建 ResNeXt、Xception、SENet 这 3 种在 ImageNet 数据集训练的预训练网络模型。

2) 利用数据增强的方式处理源域数据集,并按照 8 : 2 的数据划分方式分成训练集和验证集,目标域数据集作为测试集。

3) 使预训练网络模型适用于天气图像的数据,采取微调处理。

4) 将训练集和验证集导入网络,进行迁移学习,获取迁移模型。

5) 以迁移模型为基准,改进网络结构,实现对天气图像特性的提取和抽象。

6) 通过 JPDA 学习一个 MLP 分类器,将该分类器应用于测试集,并以其结果为准筛选出效果最佳的特征表示。

7) 将特征表示以特征拼接方式融合,训练 MLP 分类器,将测试集输入分类器,查看预测结果。

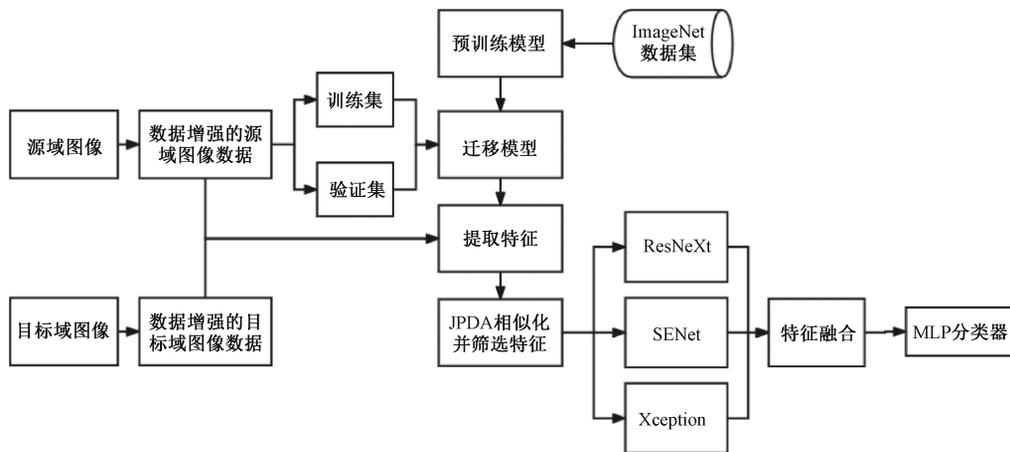


图 4 基于深度迁移学习的图像模型框架

Fig. 4 Image modeling framework based on deep migration learning

3 实验与结果分析

3.1 数据集简介

本文实验数据使用了 Kaggle 社区的 Weather dataset 数据集。Weather dataset 数据集的类型分为 5 大种类,共计 1 514 张图像,具体图像如图 5 所示。其中,图 5 (a) Cloudy 包含 303 张图像、图 5 (b) Foggy 包含 305 张图像、图 5 (c) Rainy 包含 300 张图像、图 5 (d) Sunny 包含 253 张图像、图 5 (e) Sunrise 包含 353 张图像。同时,使用 Office31 数据集验证本文算法的通用性,Office31 是图像识别中常用的数据集,图像来自 3 个域对象,包括 Amazon 在线电商图像,Webcam 低解析度图像,Dslr 高解析度图像,每个域对象共有 31 类,总计 4 110 张图像,每一

类包含 60~150 张图像。

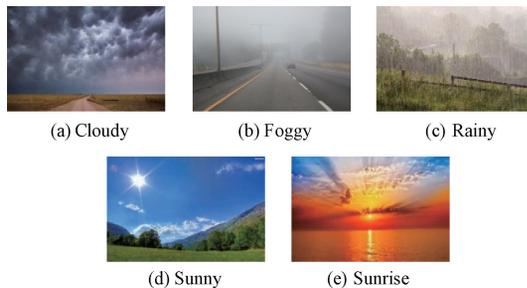


图 5 Weather dataset 五分类

Fig. 5 Weather dataset five categories

3.2 实验设置

实验根据图片类别的不同进行数据划分,随机抽取

数据样本总数的 64% 训练集, 16% 验证集, 20% 测试集。针对样本不足引发的模型过拟合问题, 对部分数据集进行随机裁剪、上下翻转、随机缩放、高斯噪声等数据增强处理, 提升模型对新领域的适应能力。标准化处理所需要的均值和方差依据 ImageNet 设置。

实验对划分的数据集进行迁移学习, 利用 ImageNet 的预训练网络为初始权重。训练过程中, 将划分出来的训练集和验证集作为源域数据, 测试集作为目标域数据, 微调网络以适用于图片分类数据, 采用随机梯度下降的方式优化模型。利用迁移学习, 保证了在微调之前, 模型的初始性能更高, 在训练过程中, 模型的训练速率更快, 确保在训练结束后, 模型的收敛效果更好。迁移学习所用参数如表 1 所示。

表 1 预训练模型训练参数及结构参数

Table 1 Pre-training model training parameters and structural parameters

	ResNeXt	SENet	Xception
Batch size	10	10	10
Epoch	20	20	20
Momentum	0.9	0.9	0.9
Learning rate	0.000 1	0.000 1	0.000 1
Network layers	160	224	155
Params	22.99 M	25.52 M	20.82 M
FLOPs	4 286.15 M	4 294.10 M	8 439.91 M

本文设置两组实验。第 1 组: 相同实验环境下, 分别对单一基础网络、JPDA 算法以及融合结果进行横向对比, 确保准确率逐步提升, 验证算法的有效性, 同时, 利用消融实验验证 3 种模型融合的合理性。第 2 组: 将经典数据集 Office31 在相同环境下使用同种方法进行实验, 验证算法的普适性和通用性。

3.3 评价指标

本文使用准确率 (accuracy)、AP (average precision)、AUC (area under roc) 对模型的分类效果进行评估。其中, 准确率体现模型性能以及预测能力, AP 是 PR 曲线 (precision-recall curves) 所围成的面积, 衡量分类器面对不平衡数据进行分类时的能力, AUC 是 ROC 曲线 (receiver operating characteristic) 所围成的面积, 展现模型的泛化能力。3 个衡量指标如式 (6) ~ (10) 所示。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

$$True Positive Rate = \frac{TP}{TP + FN} \quad (9)$$

$$False Positive Rate = \frac{FP}{TN + FP} \quad (10)$$

其中, Precision 是查准率表示 PR 曲线的纵坐标、Recall 是查全率表示 PR 曲线的横坐标、True Positive Rate 是真正例率表示 ROC 曲线的纵坐标、False Positive Rate 是假正例率表示 ROC 曲线的横坐标。根据实际结果和预测结果的不同, TP (true positive) 是真正例、FP (false positive) 是假正例、FN (false negative) 是真反例、TN (true negative) 是假反例。

3.4 实验结果

为了验证算法在天气图像分类的有效性, 将基础网络和本文算法的特征表示, 通过 t-SNE 图可视化对比两者的特征分布。其中, 不同种类相距越大, 相同种类相距越接近, 预测结果就越好。以 ResNeXt50 基础网络为对比对象, 如图 6 所示。

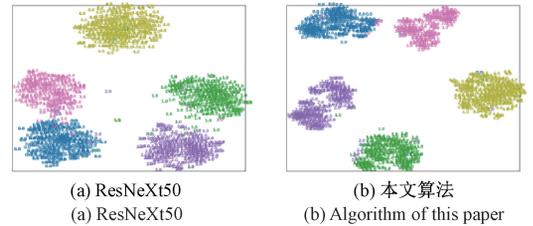


图 6 ResNeXt50 和本文算法特征分布 t-SNE 图
Fig. 6 ResNeXt50 and the t-SNE plot of the feature distribution of the algorithm in this paper

图 6 表示不同颜色的分布代表不同特征的类别, 图 6 (a)、(b) 可以看出, 本文算法令相同分类结果之间的距离分布减少, 不同分类结果之间的距离分布增大, 特征分布更加分散, 分类结果更加清晰。通过 PR 曲线和 ROC 曲线衡量模型性能, PR 曲线的结果如图 7 所示, 用于衡量模型面对不平衡数据时的分类能力。

根据图 7 所示, 局部放大图展示出 3 条曲线围成面积的总体趋势是上升的, 在 3 种方法中, 融合模型的曲线面积最大。经本文算法处理, 3 种模型在迁移模型中提取到 2 048 维的特征表示, 再通过 JPDA 算法将 3 种模型提取到的特征表示均降低到 100 维, 最终融合 3 组特征, 将特征表示融合成 300 维, 实现了在维数减少的情况下, 面积依然不断上升的结果, 说明模型性能不断提升, 图像分类的性能逐渐增强。ROC 曲线通常被用来观测模型的泛化能力, 结果如图 8 所示。

图 8 说明经过 JPDA 处理, 由于降维导致 AUC 降低, 然而下降程度微弱, 经过融合特征处理, AUC 超过单一基础网络, 泛化能力得到提高。两个衡量指标显示出模型经由算法的处理, 充分发挥了不同模型特征表示的优势, 使模型的分类能力增强。通过 3 种基础网络、JPDA

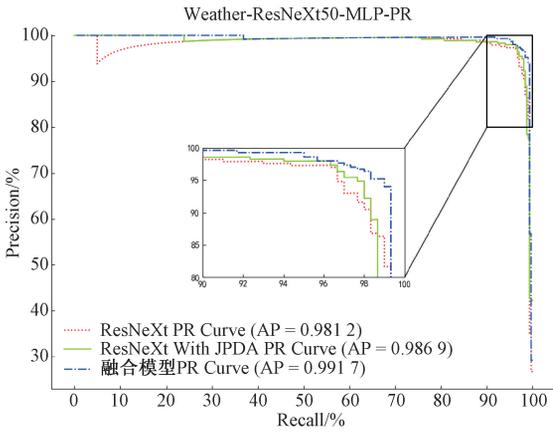


图 7 不同处理方式 PR 曲线对比

Fig. 7 Comparison of PR curves of different processing methods

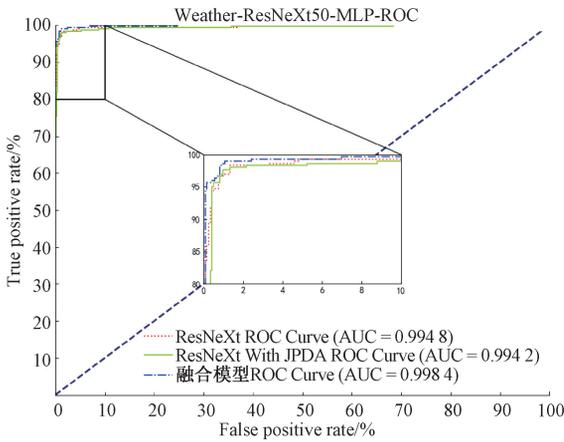


图 8 不同处理方式 ROC 曲线对比

Fig. 8 Comparison of ROC curves of different treatment methods

处理以及融合模型准确率的结果进行横向对比,结果如表 2 所示。

表 2 单一基础网络、JPDA 以及融合模型实验结果

Table 2 Experimental results of single base network, JPDA and fusion model

方法	ACC/%
ResNeXt50	94.68
Xception	96.68
SE-ResNeXt50	95.32
ResNeXt50+JPDA	96.68
Xception+JPDA	97.67
SE-ResNeXt50+JPDA	97.11
本文算法	99.00

注:加粗字体为每行最优值。

经过表 2 对比得出,基础模型中,Xception 相比于其他网络展现出更好的性能,得到了最高准确率。然而,模型融合弥补了基础网络的不足,提高了准确率上限,融合结果在 Xception 模型的基础上,提升了 2.3%。使用本文

算法处理,准确率不断提升,融合特征的准确率达到最高,整体准确率提高了 2.3%~4.3%。从一定程度说明,融合模型的结构与单一的基础网络相比,拥有更好的稳定性和分类性能。利用消融实验将经过 JPDA 算法处理后的单一网络两两融合,并与本文算法进行比较。

实验结果如图 9 所示,其中,横坐标表示经过 JPDA 处理的单一网络和多种融合模型,纵坐标表示准确率。在两两融合的结果中,两模型融合均高于单一网络的结果,验证了 ResNeXt 提取的语义特征、Xception 提取的细节特征、SENet 增强模型提取特征能力的融合是有效的。其中,Xception 和 SENet 效果最差,凸显 ResNeXt 特征的重要性,侧面说明在天气图像的识别过程中,语义特征更加重要。同时 ResNeXt 和 Xception 的融合在天气图像中的效果最佳,但是与本文算法仍然有差距,说明本文算法将 3 种模型融合是合理且有效的。

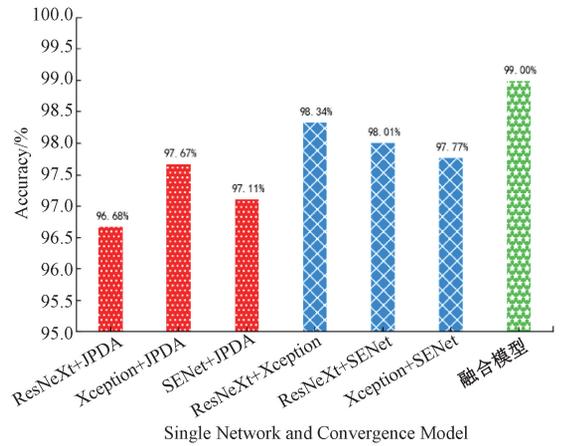


图 9 消融实验

Fig. 9 Ablation experiment

为了验证本文方法的普适性和通用性,将 Office31 经典数据集作为实验依据,其中,amazon 作为源域数据,webcam 作为目标域数据以提高识别难度,实验结果如表 3 所示。

表 3 Office31 实验结果

Table 3 Office31 experimental results

方法	ACC/%	AP	AUC
ResNeXt50	74.09	0.83	0.97
Xception	77.74	0.83	0.97
SE-ResNeXt50	75.22	0.79	0.96
ResNeXt50+JPDA	84.53	0.84	0.97
Xception+JPDA	87.17	0.91	0.98
SE-ResNeXt50+JPDA	89.43	0.93	0.98
本文算法	91.45	0.94	0.99

注:加粗字体为每行最优值。

经过表 3 分析,单一基础网络的准确率、AP、AUC 都是最低结果,经过算法的处理,3 种衡量指标获得显著的

提升,其中,准确率提升 17.36%、AP 提升 0.15、AUC 提升 0.03,说明本文算法在分类问题是可行的,适用于其他图像分类任务,拥有良好的普适性和通用性。

4 结 论

针对场景复杂,特征不显著的天气图像,本文提出了一种基于深度迁移学习的图像分类算法,该算法的核心是将迁移学习的 JPDA 作为衡量标准,以获取效果最佳的特征表示,同时,利用融合方式弥补单一网络识别能力的不足。实验结果表明,本文算法有效提升了图像分类准确率的上限,通过融合特征便可搭建高水平分类性能的简易分类器,有效地提取了高质量的特征表示。横向对比实验结果,验证了本文算法对于图像识别的有效性和通用性。

在实验过程中发现,本文算法可以有效提取图像特征,但是由于图像数量限制以及图像背景的复杂程度,导致部分样本在识别时仍然会受到影响。未来的研究工作将致力于解决图像背景过于复杂的问题,通过对图像从不同角度进行数据增强的处理,同时在模型中添加 DropBlock 模块,减少复杂背景对于识别的干扰。

参考文献

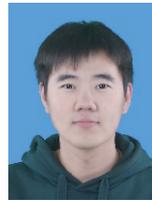
- [1] 张世辉,杜雪哲,何琦,等. 基于单幅户外彩色图像实现天气晴阴分类[J]. 计量学报, 2019, 40(6): 986-993.
ZHANG SH H, DU X ZH, HE Q, et al. Weather classification of sunny or cloudy day based on an outdoor color image[J]. Acta Metrologica Sinica, 2019, 40(6): 986-993.
- [2] 李鹏程,吕昌峰,于向茹,等. 基于分区域特征提取的单张图像天气识别[J]. 济南大学学报(自然科学版), 2020, 34(4): 321-327.
LI P CH, LYU CH F, YU X R, et al. Single-image weather recognition based on sub-regional feature extraction[J]. Journal of University of Jinan (Science and Technology), 2020, 34(4): 321-327.
- [3] 史静,朱虹. 基于随机森林的天气场景判别算法[J]. 微型机与应用, 2017, 36(24): 51-53.
SHI J, ZHU H. Random forest based weather scene discrimination algorithm [J]. Microcomputer & Its Applications, 2017, 36(24): 51-53.
- [4] 马啸,邵利民,徐冠雷,等. 基于 K 均值聚类算法的雾霾天气自动识别[J]. 舰船电子工程, 2018, 38(12): 124-128.
MA X, SHAO L M, XU G L, et al. Automatic recognition of hazy weather based on K-means clustering algorithm [J]. Ship Electronic Engineering, 2018, 38(12): 124-128.
- [5] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25: 1097-1105.
- [6] 杨瑾,陈灯,张彦铎,等. 基于多尺度特征融合网络的铁路工机具目标检测[J]. 电子测量技术, 2022, 45(17): 94-100.
YANG J, CHEN D, ZHANG Y D, et al. Railway machinery target detection based on multi-scale feature fusion network[J]. Electronic Measurement Technology, 2022, 45(17): 94-100.
- [7] 程德强,陈杰,寇旗旗,等. 融合层次特征和注意力机制的轻量化矿井图像超分辨率重建方法[J]. 仪器仪表学报, 2022, 43(8): 73-84.
CHENG D Q, CHEN J, KOU Q Q. Lightweight mine image super-resolution reconstruction method combining hierarchical features and attention mechanism [J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 73-84.
- [8] 王立刚,张志佳,李晋,等. 基于卷积神经网络的 LED 灯类字体数字识别[J]. 电子测量与仪器学报, 2020, 34(11): 148-154.
WANG L G, ZHANG ZH J, LI J, et al. LED lamp font digital recognition based on convolutional neural network [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(11): 148-154.
- [9] 吕辉,董帆. 基于 YOLOv4 的复杂交通状况下多目标检测算法[J]. 国外电子测量技术, 2022, 41(12): 41-47.
LYU H, DONG F. Multi target detection algorithm under complex traffic conditions based on YOLOv4[J]. Foreign Electronic Measurement Technology, 2022, 41(12): 41-47.
- [10] 崔洪涛,曹科,张虎,等. 基于联合投票网络的交通场景天气分类方法[J]. 西南交通大学学报, 2021, 56(3): 579-587.
CUI H T, CAO K, ZHANG H, et al. A joint voting network based weather classification method for traffic scenes [J]. Journal of Southwest Jiaotong University, 2021, 56(3): 579-587.
- [11] 王亚朝,赵伟,徐海洋,等. 基于轻量级卷积神经网络的非固定场景天气识别算法[J]. 电子测量技术, 2019, 42(17): 152-156.
WANG Y ZH, ZHAO W, XU H Y, et al. Non-fixed scene weather recognition algorithm based on lightweight convolutional neural network [J]. Electronic Measurement Technology, 2019, 42(17): 152-156.

- [12] 郭志强, 胡永武, 刘鹏, 等. 基于特征融合的室外天气图像分类[J]. 计算机应用, 2020, 40(4): 1023-1029.
GUO ZH Q, HU Y W, LIU P, et al. Outdoor weather image classification based on feature fusion [J]. Journal of Computer Applications, 2020, 40(4): 1023-1029.
- [13] 孙伟帅. 基于迁移学习的天气图像识别[J]. 西华大学学报(自然科学版), 2021, 40(1): 22-26.
SUN W SH. Weather image recognition based on transfer learning [J]. Journal of Xihua University (Natural Science Edition), 2021, 40(1): 22-26.
- [14] AL-HAIJA Q A, SMADI M A, ZEIN-SABATTO S. Multi-class weather classification using ResNet-18 CNN for autonomous IoT and CPS applications [C]. 2020 International Conference on Computational Science and Computational Intelligence (CSCI). IEEE, 2020: 1586-1591.
- [15] XIE S, GIRSHICK R, DOLLÁR P, et al. Aggregated residual transformations for deep neural networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1492-1500.
- [16] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [17] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [18] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]. Proceedings of the IEEE

Conference on Computer Vision and Pattern Recognition, 2017: 1251-1258.

- [19] ZHANG W, WU D. Discriminative joint probability maximum mean discrepancy (DJP-MMD) for domain adaptation [C]. 2020 International Joint Conference on Neural Networks (IJCNN). IEEE, 2020: 1-8.
- [20] LI C, BAI Y. Fire flame image detection based on transfer learning [C]. 2018 5th IEEE International Conference on Cloud Computing and Intelligence Systems (CCIS). IEEE, 2018: 370-374.

作者简介



封皓元, 2020 年于中国石油大学胜利学院获得学士学位, 现为沈阳工业大学硕士研究生, 主要研究方向为计算机视觉、深度学习。

E-mail: fhy_private@163.com

Feng Haoyuan received his B. Sc. degree from Shengli College China University of Petroleum in 2020. He is now a M. Sc. candidate at Shenyang University of Technology. His main research interests include computer vision.



段勇(通信作者), 沈阳工业大学信息科学与工程学院教授, 博士生导师, 主要研究方向为自主机器人、机器学习、计算机视觉。

E-mail: duanyong0607@126.com

Duan Yong (Corresponding author) is now a professor and Ph. D. supervisor at School of Information Science and Engineering, Shenyang University of Technology. His main research interests include autonomous robot, machine learning and computer vision.