

文章编号: 2095-2163(2020)05-0186-05

中图分类号: TP391.4

文献标志码: A

基于全局-局部注意机制的天气分类算法

程 玉, 陈洪刚, 王正勇, 卿粼波, 吴晓红

(四川大学 电子信息学院, 成都 610065)

摘要: 天气分类算法是户外交通视频分析以及计算机视觉应用的重要组成部分, 针对天气分类在多样性和准确性等方面的要求, 提出了一种基于全局-局部注意机制的多类天气分类算法, 对户外交通图像进行天气分类。利用基础网络 ResNet 获得图像的特征图, 构建一种改进的通道注意模型来引入全局注意分支, 通过堆叠一系列的卷积层、非线性层和池化层得到能够充分表征全局信息的特征, 进一步结合局部注意分支网络, 通过学习得到与图像语义信息最具鉴别性的局部特征, 将增强之后的特征图用于天气分类模型。

关键词: 天气分类; 卷积; 全局特征; 局部特征

Weather classification algorithm based on global-local attention mechanism

CHENG Yu, CHEN Honggang, WANG Zhengyong, QING Linbo, WU Xiaohong

(College of Electronics and Information Engineering, Sichuan University, Chengdu 610065, China)

[Abstract] Weather classification algorithm is an important part of outdoor traffic video analysis and computer vision applications. To meet the requirements of weather classification in terms of diversity and accuracy, a multi-class weather classification algorithm based on global-local attention mechanism is proposed for outdoor traffic images are used for weather classification. First, the image feature map is obtained by using the basic network ResNet; then, an improved channel attention model is constructed to introduce global attention branch, and features that can fully represent global information are obtained by stacking a series of convolutional layers, non-linear layers and pooling layers. Combining with the local attention branch network, the most discriminative local features with the semantic information of the image are obtained. Finally, the enhanced feature map is applied to the weather classification model.

[Key words] Weather classification; Convolutional neural network; Global feature; Local feature

0 引言

天气状况不但影响我们的日常生活, 而且影响许多视觉系统的功能使用, 例如户外视频监控系统 and 车辆辅助驾驶系统等。不同的天气其能见度也有所区别, 恶劣天气下(例如雨天、雾天)获取的视频图像质量和清晰度不高, 会显著降低依赖于图像、视频特征提取或视觉注意力建模的户外视觉系统的性能。

一般来说, 户外天气分类方法可以分为基于传统手工特征的分类方法和基于卷积神经网络的分类方法。Roser 等人^[1]定义雨天图像中的感兴趣区域 (ROI), 并利用直方图特征来识别雨天天气。Yan 等人^[2]提出采用梯度直方图、颜色直方图以及道路辅助信息对晴天、阴天和雨天进行分类。Zhao 等人^[3]提出动态天气条件(雨、雪等)的像素强度随时间波动, 而静态天气条件(晴、雾等)几乎保持不变,

并且根据差异利用时空和颜色特征来进一步估计天气类别。Li 等人^[4]提出根据不同特征之间的距离构建决策树并对天气进行分类。

近年来, 卷积神经网络在图像分类、目标检测与识别等各种计算机视觉任务中表现出了压倒性的性能, 包括 AlexNet^[5]、VGGNet^[6] 和 ResNet^[7] 等一些优秀的卷积神经网络在很大程度上超越了传统的天气分类算法。Elhoseiny 等人^[8]提出在两类天气分类数据集上直接对 AlexNet^[5] 网络进行微调, 取得了较好的结果。Lu 等人^[9]将传统天气特征与 CNN 提取的特征相结合, 进一步提高了分类性能。Liu 等人^[10]提出训练一个 CNN 模型, 结合稀疏分解对天气状况进行分类。Guerra 等人^[11]在已有方法的基础上, 提出一个基于超像素掩码、CNN 和 SVM 分类器的框架来检测雨、雾和雪这 3 个天气类别; Zhao 等人^[12]提出使用一个基于 CNN 的模型, 该模型包

基金项目: 成都市产业集群协同创新项目(2016-XT00-00015-GX); 国家自然科学基金(61871278); 四川省科技计划项目(2018HH0143); 四川省教育厅项目(18ZB0355)。

作者简介: 程 玉(1994-), 女, 硕士研究生, 主要研究方向: 智能系统与设计、图像处理。

通讯作者: 陈洪刚 Email: honggang_chen@scu.edu.cn

收稿日期: 2020-03-17

含一个 LSTM 注意模型, 在给定时间内根据输入图像的特征推断出天气类别。Hapsari 等人^[13]采用基于主成分分析和线性判别分析的方法, 设计基于云图像的天气分类系统。然而, 目前大多数相关算法只研究了较少的天气种类, 准确率也有待提高。因此, 如何在保证天气分类准确性的同时增加天气的种类, 逐渐成为天气分类算法的研究趋势。

本文提出一种端到端的多类天气分类算法。首先通过卷积网络 ResNet 提取图像的特征图, 然后利用全局-局部注意模型获得图像的全局及局部特征, 再将特征进一步结合以增强特征表达, 得到最终天气分类结果。

1 算法基础

随着深度卷积网络的不断完善, 在网络训练精度达到饱和后暴露出快速退化的问题。为了解决这个问题, He 等人^[7]提出了一种基于残差学习的深度卷积神经网络-ResNet, 减轻了深度网络的降级问题。网络中多个层组成的结构, 当输入为 x 时, 学习的特征表示为 $H(x)$, 残差学习的目的是确定学习特征和输入之间的残差 $F(x) = H(x) - x$, 即获取的特征为 $H(x) = F(x) + x$ 。与 VGGNet 和 GoogleNet 等网络模型相比, 多层网络直接拟合 x 与 $H(x)$ 之间的映射关系更容易学习残差关系。残差学习单元的结构如图 1 所示, 建立 x 与 $F(x)$ 的映射, 通过恒等映射直接得到 x , 当 $F(x)$ 为 0 时, 残差学习单元相当于进行简单的映射, 这不会降低网络性能。但是在实际情况下 $F(x)$ 不为 0, 因此, 残差学习单元可以基于图像输入学习新特征并改善网络性能。具体可以表示为:

$$y_l = h(x_l) + F(x_l, W_l), \quad (1)$$

$$x_{l+1} = f(y_l). \quad (2)$$

其中, x_l 和 x_{l+1} 表示第一个残差学习单元的输入和输出, $F(x_l, W_l)$ 表示残差函数, $h(x_l)$ 表示恒等映射。




图 1 残差学习单元

Fig. 1 Residual learning unit

2 本文算法

2.1 算法框架

本文提出了一种基于全局-局部注意机制的户外交通图像天气分类算法, 算法框架如图 2 所示, 主要步骤为:

- (1) 输入待分类图像, 选择 ResNet-50 作为基础网络, 获得图像的卷积特征图。
- (2) 构建一种改进的通道注意模型来引入全局注意分支 (Global attention mechanism), 通过堆叠一系列的卷积层、非线性层和池化层, 获得能够充分表征全局信息的特征。
- (3) 结合局部注意分支网络 (Local attention mechanism), 通过学习得到与图像语义信息最具鉴别性的局部特征。
- (4) 将图像的全局特征和局部特征进行特征融合, 增强之后的特征图用于天气分类模型, 得到天气分类结果。

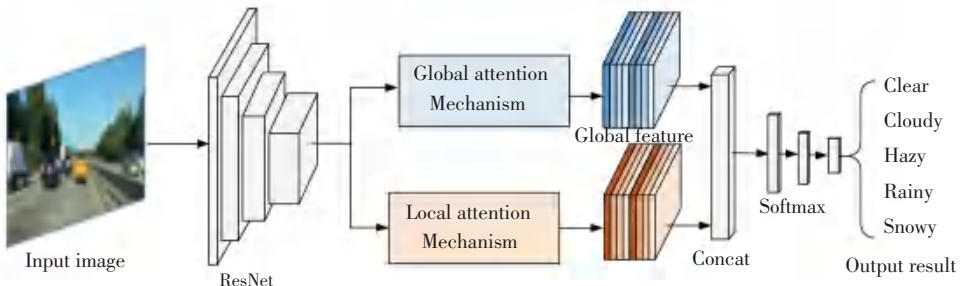


图 2 本文算法框架

Fig. 2 Algorithm framework of proposed method

2.2 全局注意分支

户外图像的特征提取和信息表达可以为天气分

类提供重要的分析依据, 图像内容特征提取最终可以反映图像中包含的信息。多数研究认为不同信道

的特征权值比例相同,实际上图像中某些通道特征比其他通道特征具有更多的信息,从不同的通道中选择特征有助于提高分类的准确性。因此, Hu 等人^[14]提出压缩-激活网络(SE-Net)建立各通道之间的相互依赖关系以增强分类网络的表征能力。受SE-Net的启发,本文使用 Squeeze-Excitation 模块学习不同通道特征图之间的相互关系,并对各通道权重进行自适应调整。SE 模块的结构如图 3 所示,包含压缩变换和激活变换。给定输入特征图 $F = [F_1, F_2, \dots, F_c]$, C 表示特征图的通道数,利用全局平均池化对图像进行压缩操作,即:

$$z_c = S(F_c) = \frac{1}{H \times W} \sum_m^H \sum_n^W F_c(m, n). \quad (3)$$

其中, $H \times W$ 表示特征图大小, $F_c(m, n)$ 表示在 (m, n) 处的特征图, z_c 表示 F 的全局统计特征。

其次是激活操作,通过全连接层(FC)降低通道数,而后经过 relu 激活层和下一个全连接层,将通道数还原至 C 个通道,最后利用 Sigmoid 激活函数得到各通道的权重系数,此过程可以表示为

$$w_c = \sigma(W_2 \delta(W_1 z_c)). \quad (4)$$

其中, σ 和 δ 分别表示 Sigmoid 激活函数和 relu 激活函数, $W_1 \in R^{C \times C}$ 和 $W_2 \in R^{C \times C}$ 表示两个全连接层的权重。




图 3 全局注意机制

Fig. 3 Global attention mechanism

通过学习特征图的通道权重信息以引入全局分支,对不同的通道分配不同的权重,进行特征的通道自适应调整。则各通道的全局特征可以表示为:

$$f_{g_c} = w_c \cdot F_c. \quad (5)$$

户外图像的全局特征表示为:

$$F_{global} = (f_{g_1}, f_{g_2}, \dots, f_{g_C}). \quad (6)$$

2.3 局部注意分支

从整幅图像中提取的全局特征可以获得图像上下文信息,但也忽略了局部细节信息。因此,在基于SE-Net的全局注意模块之外,构建一种有效的局部注意模块,提取图像的局部特征图。通过局部注意

分支,从相同的特征图中学习更多的判别语义信息,将局部特征和全局特征结合起来,得到一个综合的特征表示。

空间注意能够强调或抑制不同空间位置的特征,突出更有用的局部空间信息。如图 4 所示,采用一种基于空间信息的注意模块以提取图像不同空间的特征信息,首先对输入卷积特征图谱 $F \in R^{H \times W \times C}$ 进行最大值池化和平均池化操作,分别得到两个特征图 $f_{max} \in R^{H \times W \times 1}$ 和 $f_{avg} \in R^{H \times W \times 1}$ 。然后将两者进行特征级联,得到级联之后的特征图 $f_{sum} \in R^{H \times W \times 2}$,即

$$f_{sum} = f_{max} \oplus f_{avg} = \text{concat}[f_{max}, f_{avg}]. \quad (7)$$

其中 \oplus 表示特征级联操作。为保证特征图大小不变,使用步长为 1,填充大小为 1,卷积核大小为 3×3 的卷积层对 f_{sum} 进行卷积操作,即

$$f_l = \text{Conv}_{3 \times 3}(f_{sum}) = \text{Conv}_{3 \times 3}(\text{concat}[f_{max}, f_{avg}]), \quad (8)$$

其中, f_l 表示通过卷积运算得到的中间层特征图谱。通过 Sigmoid 激活函数将各空间位置的权重归一化到区间 $[0, 1]$, 得到各空间位置的权重系数。此过程可以表示为

$$v_{i,j} = \sigma f_l, \quad (9)$$

其中, σ 表示 Sigmoid 激活函数, $i \in [1, W]$, $j \in [1, H]$ 表示各空间位置。各位置的局部空间特征可以表示为:

$$f_{i,j} = v_{i,j} F_{i,j}. \quad (10)$$

通过引入局部注意分支得到最具鉴别性的局部空间特征信息可以表示为

$$F_{local} = (f_{1,1}, \dots, f_{i,j}, \dots, f_{H,W}). \quad (11)$$

全局注意机制和局部注意机制分别从全局和局部对特征图进行自动校正,突出有用信息并抑制无用信息,从而增强特征图的判别能力。




图 4 局部注意机制

Fig. 4 Local attention mechanism

3 实验结果与分析

3.1 实验数据集

实验数据集大部分图片来自 BDD100K 数据

集。BDD100K 数据集包含 100 000 张行车视频图像,涵盖了晴天、阴天和雨天等不同的天气状况。由于 BDD100K 数据集中晴天图像较多,训练数据分布不均匀,采取减少晴天图像数量的策略,并从其他数据集中获取雾天、雨天图像,完成相应的标签处理,数据集共有 100 000 张各类天气的图片,训练集和测试集比例为 8 : 2。

3.2 实验环境

实验环境为 Ubuntu18.04 64 位操作系统,显卡为 NVIDIA GTX 2080Ti,深度学习框架选用 Pytorch。

表 1 本文算法的天气分类结果

Tab. 1 Weather classification results of proposed method

Weather	Number	Classification result					Accuracy/%
		Clear	Cloudy	Hazy	Rainy	Snowy	
Clear	4 144	4025	119	0	0	0	97.13
Cloudy	4 831	362	4 441	28	0	0	91.93
Hazy	3 547	0	58	3 249	186	54	91.60
Rainy	3 209	0	30	177	2 910	92	90.68
Snowy	4 269	0	43	60	144	4 022	94.21

从表 1 可以看出,该算法对不同天气类别的图像分类结果有较高的准确率。测试集包含 4144 张晴天图像、4831 张阴天图像、3547 张雾天图像、3209 张雨天图像和 4269 张雪天图像,其中晴天图像的正确分类数量为 4025,准确率为 97.13%;阴天图像的正确分类数量为 4441,准确率为 91.93%;雾天图像的正确分类数量为 3249,准确率为 91.60%;雨天图像的正确分类数量为 2910,准确率为 90.68%;雪天图像的正确分类数量为 4022,准确率为 94.21%。在

表 2 天气分类结果对比

Tab. 2 Comparison of weather classification results

	Clear	Cloudy	Hazy	Rainy	Snowy	Avg_Acc %
ResNet-50	76.66	76.80	61.94	58.27	69.07	68.55
ResNet-50+GAM	90.48	87.81	85.81	80.10	88.07	86.45
ResNet-50+LAM	77.87	89.15	75.71	70.20	71.33	76.85
ResNet-50+GAM+LAM(Proposed)	97.13	91.93	91.60	90.68	94.21	93.11

表 2 中, ResNet - 50 表示不使用注意机制, ResNet - 50 + GAM 表示只引入全局注意机制, ResNet-50+LAM 表示只引入局部注意机制, ResNet -50+GAM+LAM 表示基于全局-局部注意机制的天气分类算法。由表 2 可知,该算法平均准确率为 93.11%,对于不同天气的图像有更高的准确性。ResNet-50 主干网络提取的特征是浅层语义特征,针对晴天图像和阴天图像分类的准确率较高,这是因为晴天或阴天的图像特征比较明显。引入全局注

基础网络为 ResNet - 50,网络训练迭代次数为 20 次,学习率设为 0.001, batch_size 设为 16。

3.3 实验结果分析

为了衡量算法的性能,选择分类的准确率作为评价指标,其计算方法如公式(12):

$$Accuracy(y, \hat{y}) = \frac{1}{n_{samples}} \sum_{i=0}^{n_{sample}-1} 1(\hat{y}_i = y_i). \quad (12)$$

其中, $n_{samples}$ 表示样本总数; $1(x)$ 是一个指标函数,表示分类结果和样本标签相同。

算法对测试集中各类天气分类结果如表 1 所示。

测试中也存在分类错误的情况,例如,由于拍摄角度的问题,晴朗天空区域只占图片的小部分,大部分为阴影覆盖的道路,容易将晴天图像分类为阴天图像。另外,由于数据集中有些雨天图片也存在雾气,导致雾天图像和雨天图像之间存在相互误检的情况。

为了评估该算法的有效性,以 ResNet50 为主干网络,分别使用不同的注意机制网络提取图像特征,并对户外图像进行分类,基于不同注意机制的分类准确率统计如表 2 所示。

意机制后,各类天气的分类准确率得到了较大的提高,但是对于具有混淆性的图像无法得到准确的结果,例如对比晴天图像分类准确率为 90.48%,雪天图像分类准确率为 88.07%,雨天图像的分类准确率为 80.10%,因为雨天图像中含有水汽,雾气等特征,比较容易混淆。局部注意机制只关注图像的局部特征而无法反映图像整体信息,导致分类准确率较低。结合全局和局部注意机制,在图像整体信息的基础上得到具有鉴别性的局部特征,不仅能够对一般户

外图像的天气进行准确分类,还提高了混淆性图像的天气分类准确率。综上所述,该算法具有更好的天气图像分类性能。

4 结束语

本文提出一种用于户外交通场景图像天气分类算法,通过引入全局注意机制和局部注意机制,学习全局上下文信息和局部语义信息,将全局信息和局部信息进行融合形成一种有效的特征表示,对于多种天气的图像均有较好的分类效果。

参考文献

- [1] ROSER M, MOOSMANN F. Classification of weather situations on single color images [C]//2008 IEEE Intelligent Vehicles Symposium. IEEE, 2008: 798-803.
- [2] YAN X, LUO Y, ZHENG X. Weather recognition based on images captured by vision system in vehicle [C]//International Symposium on Neural Networks. Springer, Berlin, Heidelberg, 2009: 390-398.
- [3] ZHAO X, LIU P, LIU J. A time, space and color-based classification of different weather conditions [C]//2011 Visual Communications and Image Processing (VCIP). IEEE, 2011: 1-4.
- [4] LI Q, KONG Y, XIA S. A method of weather recognition based on outdoor images [C]//2014 International Conference on Computer Vision Theory and Applications (VISAPP). IEEE, 2014, 2: 510-516.
- [5] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [C]//Advances in neural information processing systems. 2012: 1097-1105.

- [6] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. arXiv preprint arXiv:1409.1556, 2014.
- [7] HE K, ZHANG X, REN S. Deep residual learning for image recognition [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.
- [8] ELHOSEINY M, HUANG S, ELGAMMAL A. Weather classification with deep convolutional neural networks [C]//2015 IEEE International Conference on Image Processing (ICIP). IEEE, 2015: 3349-3353.
- [9] LU C, LIN D, JIA J, et al. Two-class weather classification [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2014: 3718-3725.
- [10] LIU W, YANG Y, WEI L. Weather Recognition of Street Scene Based on Sparse Deep Neural Networks [J]. Journal of Advanced Computational Intelligence and Intelligent Informatics, 2017, 21 (3): 403-408.
- [11] GUERRA J C V, KHANAM Z, EHSAN S, et al. Weather Classification: A new multi-class dataset, data augmentation approach and comprehensive evaluations of Convolutional Neural Networks [C]//2018 NASA/ESA Conference on Adaptive Hardware and Systems (AHS). IEEE, 2018: 305-310.
- [12] ZHAO B, LI X, LU X, et al. A CNN-RNN architecture for multi-label weather recognition [J]. Neurocomputing, 2018, 322: 47-57.
- [13] HAPSARI Y. Weather classification based on hybrid cloud image using principal component analysis (PCA) and linear discriminant analysis (LDA) [J]. JPhCS, 2019, 1167(1): 012064.
- [14] 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.

(上接第185页)

善:一是数据库处于实验室水平,尚未达到上限要求;二是访问方式单一,缺乏其他形式的客户端。后期将集中于 Android、IOS 版本的开发和应用数据挖掘技术对数据库内容进行扩充。

参考文献

- [1] 赵改善. 石油物探智能化发展之路:从自动化到智能化 [J]. 石油物探, 2019, 58(06): 791-810.
- [2] 武仲芝. 典型系统基于架构的层级化建模技术研究 [J]. 计算机科学, 2018, 45(S2): 542-544.
- [3] 韩豫, 孙昊, 李宇宏, 等. 智慧工地系统架构与实现 [J]. 科技进步与对策, 2018, 35(24): 107-111.
- [4] 浦东平, 樊重俊, 袁光辉. 知识管理视角下平台型企业的管理模式和系统架构研究 [J]. 中国人力资源开发, 2018, 35(12): 103-111.
- [5] Technology - Information Technology; Study Data from South China Normal University Update Understanding of Information

Technology (Semantic Search Exploiting Formal Concept Analysis, Rough Sets, and Wikipedia) [J]. Computers, Networks & Communications, 2019.

- [6] Yilmaz F G K. Exploring the role of Facebook adoption and virtual environment loneliness on knowledge sharing behaviors in a Facebook learning community [J]. Education and Information Technologies, 2019, 24(2): 1699-1714.
- [7] 安波, 韩先培, 孙乐. 融合知识表示的知识库问答系统 [J]. 中国科学: 信息科学, 2018, 48(11): 1521-1532.
- [8] Metzler S, Günnemann S, Miettinen P. Stability and dynamics of communities on online question-answer sites [J]. Social Networks, 2019, 58: 50-58.
- [9] 朱韵攸, 戴诚, 陈聿, 等. 基于人工智能的在线电力智慧客服系统设计 (英文) [J]. 机床与液压, 2018, 46(24): 9-14+61.
- [10] Christine Weiser. MAKING WEBSITES ACCESSIBLE [J]. Tech & Learning, 2019, 40(5).
- [11] 尹桂萍. Dreamweaver 在网页制作中的常用技巧 [J]. 张家口职业技术学院学报, 2019, 32(03): 53-56.