

# 基于图像分块与特征融合的户外图像天气识别



左杰格 柳晓鸣 蔡 兵

大连海事大学信息科学技术学院 辽宁 大连 116026

(1204655420@qq.com)

**摘 要** 在视频监控及智能交通等领域,雾、雨、雪等恶劣天气会严重影响视频图像能见度,因此快速识别出当前的天气情况,并自适应地对监控视频进行清晰化处理极为重要。针对传统天气识别方法效果差以及天气图像数据集缺乏的问题,构建了一个多类别天气图像分块数据集,并提出了一种基于图像分块与特征融合的天气识别算法。该算法基于传统方法提取平均梯度、对比度、饱和度、暗通道 4 种特征作为天气图像的浅层特征,基于迁移学习对 VGG16 预训练模型进行微调,提取微调模型的全连接层特征作为天气图像的深层特征,将天气图像浅层特征与深层特征融合作为最终特征用于训练 Softmax 分类器,实现对雾、雨、雪、晴 4 类天气图像的识别。实验结果表明,所提算法能达到 99.26% 的识别准确率,并且可作为天气识别模块应用于自适应视频图像清晰化处理系统。

**关键词:** 图像分块;天气识别;卷积神经网络;迁移学习;特征提取;特征融合

中图法分类号 TP391.41

## Outdoor Image Weather Recognition Based on Image Blocks and Feature Fusion

ZUO Jie-ge, LIU Xiao-ming and CAI Bing

School of Information Science and Technology, Dalian Maritime University, Dalian, Liaoning 116026, China

**Abstract** In video surveillance and intelligent traffic, bad weather such as foggy, rainy and snowy can seriously affect the visibility of video images. Therefore, it is very important to quickly identify the current weather conditions and make adaptive clearness processing of surveillance videos. Aiming at the problems of poor effect of traditional weather recognition methods and lack of weather image data sets, a multi-class weather image blocks data set is constructed, and a weather recognition algorithm based on image blocks and feature fusion is proposed. The algorithm uses traditional methods to extract four features, namely average gradient, contrast, saturation and dark channel, which are taken as the shallow features of weather images. The algorithm uses transfer learning to fine-tune the VGG16 pre-training model, and extracts the full-connection layer features of the fine-tuning model, which are taken as the deep features of the weather image. The shallow and deep features of weather images are fused and used as the final features to train the Softmax classifier. The classifier can realize the recognition of foggy, rainy, snowy and sunny weather images. Experimental results show that the recognition accuracy of the proposed algorithm can reach 99.26%, and the algorithm can be used as a weather recognition module in the adaptive video image sharpening system.

**Keywords** Image blocks, Weather recognition, Convolutional neural network, Transfer learning, Feature extraction, Feature fusion

## 1 引言

现有的计算机视觉研究大部分是基于天气状况良好的图像或视频,但是在雾、雨、雪等恶劣天气情况下,视频图像受能见度不良的限制,难以做到全天候监控。因此,在视频监控领域,能够快速获取当前的天气情况并及时对视频图像进行清晰化处理极为重要。

传统识别天气的方法主要是使用传感器或者雷达<sup>[1]</sup>,但

是其功能单一、范围有限且成本较高。现有的天气识别研究基本是使用摄像头获取视频图像并通过计算机来识别天气。

目前,基于图像识别天气的算法主要分为 3 类:基于天气图像底层特征训练分类器的识别方法、基于深度学习的端到端的识别方法和基于融合特征训练分类器的识别方法。

第一类方法是提取天气图像底层特征训练分类器,用于天气识别,该方法需要设计天气图像特征。Zhang 等提出了一种基于字典学习和多核学习的天气图像分类方法,用于

到稿日期:2020-12-30 返修日期:2021-04-09 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(62001078);福建海事局基金(2018Z0093)

This work was supported by the National Natural Science Foundation of China(62001078) and Maritime Safety Administration Foundation of Fujian Province, China(2018Z0093).

通信作者:柳晓鸣(lxmdmu@dlnu.edu.cn)

提取天空、阴影、雨线、雪花、暗通道 4 个局部特征及对比度、饱和度 2 个全局特征,使用多核学习算法学习所有特征的最优权重,并用于识别雾、雨、雪、晴 4 类图像,识别准确率为 71%<sup>[2]</sup>。传统的特征提取方法属于挖掘式的方法,提取的特征能够表达图像的浅层信息,但缺乏对图像深层语义的表达,因此第一类方法的识别效果通常较差。

第二类方法是基于深度学习的端到端的识别方法。Guerra 等创建了包含雨、雾、雪 3 类天气图像的 RFS(Rain Fog Snow)数据集,并提出使用超像素掩膜对 RFS 数据集进行增强,然后使用 10 种卷积神经网络分别进行训练,都能达到 70% 以上的识别准确率,但是 RFS 数据集目前未公开<sup>[3]</sup>。Wang 等收集并标记了一个包含 9 类天气图像的数据集,并集成深度残差网络和密集卷积网络对天气进行识别,能达到 80% 左右的识别准确率<sup>[4]</sup>。Fang 等提出了一种基于改进 SqueezeNet 的天气分类算法,可以在参数量减少为原来的 1/50 的情况下达到 AlexNet 的水平,但是其分类效果不如 ResNet, VGG16<sup>[5]</sup>。Ye 等构建了室外输电线路场景下的天气图像数据集,包括雾天、雨天、下雪和晴天的图像,并在此基础上,提出了一种基于块图像和投票策略的天气图像分类方法,通过微调 ResNet50 来提取天气图像特征,该方法有不错的天气识别效果,但是缺乏对天气图像浅层信息的表达<sup>[6]</sup>。神经网络有较强的特征提取能力,端到端的深层特征能有效表达图像更为抽象和内在的信息<sup>[7]</sup>,训练神经网络时,数据集越大表现越好,第二种方法在大型天气图像数据集上训练时,能达到较高的识别准确率。

第三类方法结合了前两类方法,融合传统方法提取的底层特征和深度学习特征训练分类器。Guo 等提出了基于特征融合的室外天气图像分类方法,融合传统特征天空、对比度、饱和度、暗通道与 AlexNet 网络提取的深层特征,能达到 90% 以上的识别正确率<sup>[8]</sup>。第三类方法结合了天气图像底层特征与深度特征,从不同角度更加详细地表达了图像信息,相比前两类方法,进一步提高了天气识别的准确率。

针对户外图像天气识别中公开数据集少、数据集与本文应用目的不完全相符的问题,本文构建了一个多类别天气图像分块数据集 MWIBD(Multi-class Weather Image Blocks Dataset),该数据集包括雾、雨、雪、晴 4 类户外天气图像。

为了提高模型的训练效率,本文改进了第三类天气识别方法,提出了基于图像分块与特征融合的户外图像天气识别算法,使用迁移 VGG16 网络模型来提取天气图像的深层特征,然后与浅层特征平均梯度、对比度、饱和度、暗通道融合,用于训练 Softmax 分类器,从而实现雾、雨、雪、晴 4 类天气的识别。

## 2 天气图像分块数据集

目前公开的天气图像数据集非常有限。Chu 等构建了数据集 Image2Weather dataset,数据集有 183 798 幅图像,包含晴、多云、雪、雨、雾以及其他 6 个类别<sup>[9]</sup>。Lin 等构建了天气数据集 MWD(Multi-class Weather Dataset),数据集有 65 000 幅图像,包含晴、阴、雨、雪、雾、雷 6 个类别<sup>[10]</sup>。虽然这两个公开数据集都有 6 个类别的天气,但是其中多云、阴天对视频

图像目标识别基本没有影响,不存在遮掩、模糊目标等现象,雷电天气则比较少见。因此,本文分类识别的天气是雾、雨、雪、晴 5 类天气。

本文从 Image2Weather dataset 和 MWD 中筛选了部分符合本文需求的图像,并收集了部分公开图像,构建了天气图像数据集 Dataset,数据集 Dataset 的具体来源如表 1 所列。

表 1 天气图像数据集的来源分布

Table 1 Source distribution of Dataset

weather image data set	foggy	rainy	snowy	sunny
Image2Weather dataset	500	100	200	400
MWD	200	600	600	300
公开图像	300	300	200	300
Dataset	1 000	1 000	1 000	1 000

数据集 Dataset 包括雾、雨、雪、晴 4 类图像,每类图像有 1 000 幅。基于本文天气识别模型的应用目的,数据集集中的雨天、雪天图像选取的是正在下雨、正在飘雪的图像。

由于数据集 Dataset 较小,并且其中不同类型的天气图像中存在大量相同的目标和特征,如道路、树木、车辆、行人等,会严重干扰户外图像天气的识别。因此,本文选择对图像进行裁剪以及翻转,筛选出带天气特征的图像,从而降低干扰,有效提高天气的识别效果。

本文对数据集 Dataset 进行处理,构建多类别天气图像分块数据集 MWIBD。处理过程如图 1 所示。

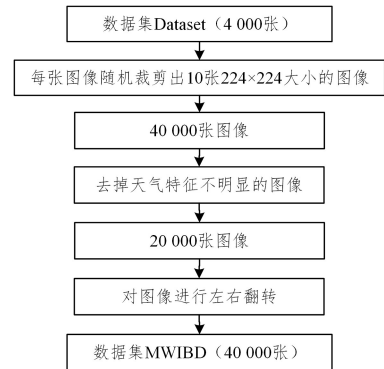


图 1 数据集的处理过程

Fig. 1 Processing of Dataset

首先将数据集 Dataset 中的每张图像随机裁剪出 10 张  $224 \times 224$  大小的图像,裁剪出来的图像中可能存在不带天气特征的图像,如雾天图像的远景区域,雾气很淡,近似于晴天图像,因此需要对图像进行筛选,去掉不带天气特征(雾气、雨滴、雪花)或者天气特征不明显的图像,然后对剩下的图像进行左右翻转,最终形成多类别天气图像分块数据集 MWIBD。

MWIBD 数据集的样例如图 2 所示。




图 2 MWIBD 数据集的样例

Fig. 2 Samples of MWIBD data set

天气图像分块数据集 MWIBD 包括雾、雨、雪、晴 4 类天气图像,每类图像有 10 000 张,每张图像尺寸为  $224 \times 224$ 。MWIBD 数据集中 80% 的图像用于训练,20% 的图像用于测试。

### 3 天气图像特征提取

本文提取天气图像浅层特征来表达图像的浅层信息,提取深层特征表达天气图像更为抽象和内在的信息。

#### 3.1 浅层特征提取

##### 3.1.1 平均梯度

Jin 等指出,图像的平均梯度可以反映图像的清晰度<sup>[11]</sup>。图像的平均梯度越大,图像中的边缘信息就越丰富,图像也越清晰。灰度图像的平均梯度如式(1)所示:

$$G = \frac{\sum_{i=1}^w \sum_{j=1}^h \sqrt{(A_{ij} - A_{(i+1)j})^2 + (A_{ij} - A_{i(j+1)})^2}}{2} / (w * h) \quad (1)$$

其中, $A_{ij}$  表示图像在像素点  $(i, j)$  处的灰度值, $w$  表示图像宽度, $h$  表示图像高度。

##### 3.1.2 对比度

Jin 等指出,对比度描述了图像值在图像空间中的变化<sup>[11]</sup>。清晰图像的对比度一般大于降质图像。在不同天气情况下,对比度差别较大,因此可作为区分天气图像的特征。对比度如式(2)所示:

$$C = \frac{V}{\sqrt{\sqrt{\left[ \sum_{k=1}^{255} (k-G)^4 * \frac{N_k}{w * h} \right] / V^2}}} \quad (2)$$

其中, $G$  是图像的平均梯度, $V$  是图像的标准差, $N_k$  表示灰度值为  $k$  的像素个数, $k$  代表输入图像的灰度值, $k \in [0 \cdots 255]$ 。

其中,图像的标准差  $V$  如式(3)所示:

$$V = \sqrt{\left[ \sum_{i=1}^w \sum_{j=1}^h (A_{ij} - \bar{A}_{ij})^2 \right] / (w * h)} \quad (3)$$

其中, $\bar{A}_{ij}$  表示  $A_{ij}$  的均值。

##### 3.1.3 饱和度

Zhang 等指出,饱和度不受光照的影响,因此它可以描述不同光照条件下的不同图像<sup>[22]</sup>。图像  $I$  每个像素的归一化饱和度和如式(4)所示:

$$S_{i,j} = \frac{S_{i,j} - \min(S_I)}{\max(S_I) - \min(S_I)} \quad (4)$$

其中, $S_{i,j}$  表示像素点  $(i, j)$  的饱和度, $\max(S_I)$  是图像  $I$  的最大饱和度值, $\min(S_I)$  是图像  $I$  的最小饱和度值。

##### 3.1.4 暗通道

He 等提出了暗通道先验理论用于图像去雾。暗通道先验理论指在户外无雾图像中的大部分局部区域,存在一些像素点在至少一个颜色通道中具有非常低的值,趋近于零<sup>[12]</sup>。因此,可以利用暗通道来表示雾霾天气。图像  $I$  的暗通道如式(5)所示:

$$I_d(x) = \min_{c \in \{R, G, B\}} (I_c(x)) \quad (5)$$

其中, $I_c$  表示图像的 RGB 通道。

#### 3.2 深层特征提取

##### 3.2.1 迁移学习

在传统的机器学习以及数据挖掘领域中,训练集和测试集在同一特征空间且分布统一时才能达到较好的效果,每处理

一个新任务都需要构建一个新的数据集,这是需要一定成本的,因此迁移学习受到了越来越多的关注<sup>[13]</sup>。

迁移学习就是将训练好的模型参数迁移到新的模型来优化模型训练。因为大部分的数据和任务之间是存在相关性的,所以使用迁移学习就能达到较好的训练效果<sup>[14]</sup>。

本文采用的迁移学习方法是基于 VGG16 网络模型进行微调的。

##### 3.2.2 VGG16 网络模型

Russakovsky 等为了解决 ImageNet 中的 1 000 类图像分类和定位问题,构建了一种网络结构 VGG16<sup>[15]</sup>。相比 Krizhevsky 等提出的 AlexNet 网络结构<sup>[16]</sup>,VGG16 采用了更小的  $3 \times 3$  和  $1 \times 1$  的卷积核、 $2 \times 2$  的池化核,在加深网络深度的同时能够大幅减少网络的参数。

VGG16 网络模型的结构如图 3 所示。




图 3 VGG16 结构图

Fig. 3 Structure of VGG16

VGG16 由 13 个卷积层、5 个池化层和 3 个全连接层组成。

##### 3.2.3 基于迁移学习的深层特征提取

VGG16 网络模型在将网络迁移到新任务上时,有着非常好的泛化能力。基于 VGG16 的模型迁移如图 4 所示。

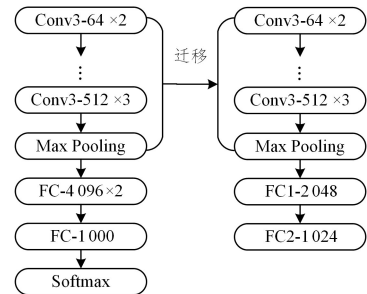


图 4 迁移 VGG16 模型

Fig. 4 Transfer the VGG16 model

基于 VGG16 模型的迁移思路如下:冻结 13 个卷积层,拆掉预训练模型的所有全连接层,添加自己设计的 2 个全连接层。将新的两个全连接层分别命名为  $FC_1$ ,  $FC_2$ 。设置  $FC_1$ ,  $FC_2$  输出的神经元个数分别为 2048, 1024。

VGG16 网络模型中 3 个全连接层 FC-4096, FC-4096, FC-1000 的训练参数量分别为:  $7 \times 7 \times 512 \times 4096 =$

102760448,  $4\ 096 \times 40\ 96 = 16\ 777\ 216$ ,  $4\ 096 \times 1\ 000 = 4\ 096\ 000$ 。而基于 VGG16 的迁移模型 VGG16-TL 的两个全连接层  $FC_1, FC_2$  的训练参数分别为:  $7 \times 7 \times 512 \times 2\ 048 = 51\ 380\ 224$ ,  $2\ 048 \times 1\ 024 = 2\ 097\ 152$ 。可以看出,微调 VGG16 之后大大减少了训练参数,使训练效率更高。

本文进行网络模型优化时使用的优化器是 Adam<sup>[17]</sup>,它结合了 AdaGrad 和 RMSProp 两种优化算法的优点。Adam 计算更新的步长不是由当前梯度直接决定的,而是由梯度一阶矩估计修正、梯度二阶矩估计修正两部分进行自适应调节。使用 Adam 更新参数不受梯度的伸缩变换影响,并且能够自动调整学习率。Adam 的相关计算公式如下。

目标函数  $J(\theta)$  对  $\theta$  求导得到梯度  $g_t$ :

$$g_t = \nabla_{\theta} J(\theta_{t-1}) \quad (6)$$

其中,  $\theta$  是网络的参数,指权重、偏差或激活值;  $J(\theta)$  指待优化的带有参数  $\theta$  的目标函数。

梯度  $g_t$  的一阶矩估计  $m_t$  如式(7)所示:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (7)$$

其中,  $\beta_1$  是一阶矩衰减系数。

梯度  $g_t$  的二阶矩估计  $v_t$  如式(8)所示:

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (8)$$

其中,  $\beta_2$  是二阶矩衰减系数。

由于  $m_t$  初值为 0,因此在训练初期偏向 0,需要对  $m_t$  进行偏差纠正,如式(9)所示:

$$\hat{m}_t = m_t / (1 - \beta_1^t) \quad (9)$$

其中,  $\beta_1^t$  为  $\beta_1$  的  $t$  次方。

由于  $v_t$  初值为 0,因此在训练初期偏向 0,需要对  $v_t$  进行偏差纠正,如式(10)所示:

$$\hat{v}_t = v_t / (1 - \beta_2^t) \quad (10)$$

其中,  $\beta_2^t$  为  $\beta_2$  的  $t$  次方。

更新的步长  $\theta_t$  如式(11)所示:

$$\theta_{t+1} = \theta_t - \alpha \frac{1}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t \quad (11)$$

其中,Kingma 等通过实验建议,设置  $\epsilon = 10^{-8}$ ,学习率  $\alpha$  可以根据具体情况进行调整<sup>[17]</sup>,本文根据实验将其设置为 0.0001。

基于 VGG16 的迁移学习模型 VGG16-TL 中全连接层  $FC_1, FC_2$  的特征能较好地表达天气图像的深层信息,并且全连接层特征是一维特征,便于与传统特征融合。因此,本文提取 VGG16-TL 的  $FC_1$  与  $FC_2$  层的特征作为天气图像的深层特征。

## 4 天气图像特征融合

### 4.1 特征融合方法

Liu 等详细分析了对不同类型特征的融合方式,提到了深度特征融合方法,包括加性融合、最大融合和级联融合等<sup>[18]</sup>。

本文采用级联融合方法的思想,将天气图像浅层特征与深层特征融合。特征融合的方式如式(12)所示:

$$F = [F_G, F_C, F_S, F_I, F_{FC_1}, F_{FC_2}] \quad (12)$$

其中,  $F_G$  表示平均梯度特征,  $F_C$  表示对比度特征,  $F_S$  表示

饱和度特征,  $F_I$  表示暗通道特征,  $F_{FC_1}$  和  $F_{FC_2}$  分别表示从 VGG16-TL 的全连接层  $FC_1, FC_2$  提取的深层特征。

### 4.2 天气图像特征融合

浅层特征是提取平均梯度、对比度、饱和度、暗通道的直方图,每个特征是 256 维,浅层特征共有 1 024 维。深层特征是提取 VGG16-TL 全连接层  $FC_1$  与  $FC_2$  的特征,深层特征共有 3 072 维,然后把所有特征级联融合形成 4 096 维天气图像特征。

本文在特征融合模块使用 TensorFlow 中的 `tf.concat()` 函数实现对平均梯度、对比度、饱和度、暗通道、 $FC_1, FC_2$  的级联融合。

## 5 天气图像识别模型

本文设计的基于图像分块与特征融合的户外图像天气识别模型如图 5 所示。

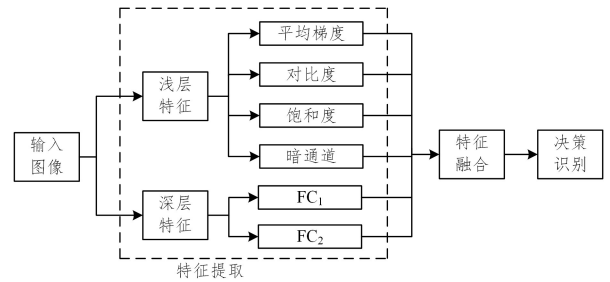


图 5 天气识别模型

Fig. 5 Weather recognition model

天气识别模型主要分为特征提取、特征融合和决策识别 3 个模块。

特征提取模块包括深层特征提取与浅层特征提取,浅层特征主要是提取平均梯度、对比度、饱和度、暗通道,深层特征主要是提取 VGG16-TL 的全连接层特征  $FC_1$  和  $FC_2$ 。特征提取模块的具体内容见第 3 节。

特征融合模块是将提取的深层特征与浅层特征级联融合。特征融合模块的具体内容见第 4 节。

决策识别模块是通过 Softmax 训练融合后的特征,能够实现雾、雨、雪、晴 4 种天气状况的识别。

## 6 实验结果及分析

### 6.1 实验环境

本文中的实验均在 Intel(R) Core(TM) i7-9750H CPU @ 2.60GHz 2.60GHz, 8GB RAM, 64 位 Windows 10 系统、NVIDIA GeForce GTX 1660 Ti, python 3. 6、TensorFlow 2. 2. 0 GPU 环境下进行。

### 6.2 评价指标

混淆矩阵是评估模型效果的一种指标,可用于评估本文设计的天气识别模型<sup>[8]</sup>。混淆矩阵如表 2 所列。表 2 中,  $T_P$  表示图像标定为正样本,分类结果也为正样本;  $F_P$  表示图像标定为负样本,分类结果为正样本;  $F_N$  表示图像标定为正样本,分类结果为负样本;  $T_N$  表示图像标定为负样本,分类结果也为负样本。

表2 混淆矩阵  
Table 2 Confusion matrix

混淆矩阵	真实值		
	正样本	负样本	
预测值	正样本	$T_P$	$F_P$
	负样本	$F_N$	$T_N$

$P$  表示精确率 Precision,表示在被识别为正类别的样本中分类正确的比例:

$$P = \frac{T_P}{T_P + F_P} \quad (13)$$

$R$  表示召回率 Recall,表示在所有正类别样本中预测正确的比例:

$$R = \frac{T_P}{T_P + F_N} \quad (14)$$

$A$  表示准确率 Accuracy,表示预测正确的样本数占总样本数的比例:

$$A = \frac{T_P + T_N}{T_P + F_P + T_N + F_N} \quad (15)$$

### 6.3 实验 1:浅层特征实验

本文设计实验 1,用于对比浅层特征局部二值模式(Local Binary Pattern,LBP)、方向梯度直方图(Histogram of Oriented Gradient,HOG)、亮度、平均梯度、对比度、饱和度、暗通道的天气识别效果。

LBP 是将图像局部区域中心像素的灰度值作为阈值,与邻域进行比较,若邻域像素值大于中心像素值,则该像素点的位置被标记为 1,否则为 0,将由此产生的二进制数转换为十进制数,这个十进制数就是中心像素的 LBP 值,然后统计所有局部区域的 LBP 值形成直方图,构成图像特征。HOG 是通过计算图像局部区域中不同方向的梯度值,来形成直方图以构成特征。

浅层特征对比实验结果如表 3 所列。

表3 浅层特征对比  
Table 3 Comparison of shallow features

浅层特征	A/%
LBP	36.75
HOG	42.50
亮度	43.80
饱和度	51.83
暗通道	55.08
平均梯度	60.25
对比度	62.66
平均梯度+对比度+饱和度+暗通道	74.66

由表 3 可看出:单一浅层特征达到的识别效果并不好,因为单一特征可能对某一类图像的识别准确率较高,难以识别其他类型的图像。如暗通道能够有效识别雾天图像,但是对雨天、雪天的分类效果较差;对比度能有效区分雾天、晴天、雨天图像,但是难以区分雨天与雪天图像。

虽然单一浅层特征的分类效果不佳,但是 4 种浅层特征融合能达到不错的分类效果。平均梯度、对比度、饱和度和暗通道 4 个浅层特征融合能够达到 74.66% 的识别准确率。


对比 7 种浅层特征,其中 HOG、LBP、亮度的 Accuracy

相对较低。本文选择使用平均梯度、对比度、饱和度、暗通道 4 种浅层特征。


### 6.4 实验 2:深层特征实验

设计实验 2 对比 4 个网络模型 AlexNet<sup>[16]</sup>,GoogLeNet<sup>[19]</sup>,ResNet50<sup>[20]</sup>,VGG16<sup>[15]</sup>与这 4 个网络模型的迁移模型 AlexNet-TL,GoogLeNet-TL,ResNet50-TL 和 VGG16-TL 的识别效果。

所有模型的训练参数设置一致,批尺寸 batch\_size 设置为 32,网络模型优化器使用的是 Adam,学习率 learning rate 设置为 0.000 1,训练迭代次数 epoch 设置为 100。4 个网络模型 AlexNet,GoogLeNet,ResNet50,VGG16 在不同迭代周期的识别准确率的变化曲线如图 6 所示。



(a) 损失变化



(b) 准确率变化

图 6 网络模型


Fig. 6 Network model

由图 6 可以看出,训练的 4 个网络模型中 GoogLeNet 的训练损失相对最小,在 20 个 epoch 之后的训练损失基本都低于 0.1,并且分类准确率较高,最高可达 96.20%。


对比 4 个全训练模型,首先,AlexNet 使用大小为  $11 \times 11$  和  $5 \times 5$  这样的大卷积核,而 VGG16 采用了更小的大小为  $3 \times 3$  和  $1 \times 1$  的卷积核,采用小卷积核替代大卷积核能够加深网络深度并减少网络参数,因此 VGG16 的效果优于 AlexNet。其次,AlexNet 和 VGG16 都是由卷积层、池化层和全连接层堆叠而成,ResNet50 使用了残差结构,而 GoogLeNet 使用了 Inception Module 结构,并将全连接转化为稀疏连接<sup>[19]</sup>,因此 GoogLeNet 不仅有效地控制了参数和计算量,还拥有更好的识别效果。

在对比了 4 个全训练模型之后,再对比一下这 4 个模型的迁移网络模型,即 AlexNet-TL,GoogLeNet-TL,ResNet50-TL,VGG16-TL,这 4 个迁移模型在不同迭代周期的分类准确率变化曲线如图 7 所示。由图 7 可以看出,4 个迁移网络模型的收敛速度均快于全训练的网络模型,但 GoogLeNet-TL,ResNet50-TL 的训练损失比全训练的 GoogLeNet,Res-

Net50 大。对比 4 个迁移网络模型,其中 VGG16-TL 模型的训练损失相对最小,在 10 个 epoch 之后训练损失就已经低于 0.1,并且分类准确率较高,最高可达 97.29%。



(a) 损失变化



(b) 准确率变化

图 7 迁移网络模型

Fig. 7 Transfer network model

虽然在 4 个全训练模型中,GoogLeNet 的识别效果较好,但是在进行迁移学习时,VGG16-TL 有更好的泛化能力,能够达到很好的迁移效果,因此 VGG16-TL 是从天气图像中提取深层特征的 CNN 首选模型。

对比全训练模型及迁移模型共 8 个模型的训练损失变化以及准确率变化曲线可以看出,VGG16-TL 模型的损失相对较小、训练收敛速度最快。

4 个网络模型以及 4 个迁移网络模型具体的识别准确率对比如表 4 所列。

表 4 网络模型的识别准确率

Table 4 Accuracy of network model

网络模型	A / %
AlexNet-TL	79.93
AlexNet	85.78
GoogLeNet-TL	87.53
ResNet50-TL	91.76
VGG16	94.86
ResNet50	95.25
GoogLeNet	96.20
VGG16-TL	97.29

通过表 4 可以看出,VGG16-TL 模型的识别准确率相对最高。

综合来看,VGG16-TL 模型的损失较小、训练收敛速度最快,并且达到的天气识别准确率最高。因此,本文选择 VGG16-TL 模型来提取天气图像的深层特征。

### 6.5 实验 3:不同方法的对比

为了验证本文模型的有效性与其优越性,设计实验 3 来对比本文方法与 Wang 等<sup>[4]</sup>、Guo 等<sup>[8]</sup>、Goswami<sup>[21]</sup>提出的方法。

本文对比了 4 种方法在雾、雨、雪、晴 4 类图像上的识别效果,实验结果如表 5 所列。

表 5 4 种方法的对比

Table 5 Comparison of four ways

(单位:%)

评价指标	文献[8]的方法	文献[4]的方法	文献[21]的方法	本文方法	
雾	P	95.55	96.65	97.15	99.65
	R	95.98	96.41	98.18	99.55
雨	P	89.35	90.55	96.15	99.00
	R	90.57	92.82	95.86	99.05
雪	P	89.70	91.80	95.75	98.55
	R	89.97	92.12	96.62	99.29
晴	P	96.80	98.20	99.40	99.85
	R	94.81	95.76	97.79	99.16
A	92.85	94.30	97.11	99.26	

从表 5 中可以看出,本文模型总的识别准确率可达 99.26%,在雾、雨、雪、晴上的识别效果以及总的识别正确率均优于其他模型。其中,尤其是对雨、雪的识别效果相比其他方法有较大提升。Guo 等的方法中使用的网络结构是 AlexNet,通过实验 2 也可以看出,AlexNet 全训练的天气识别效果较差。Wang 等的方法可以提取图像深层特征,表达图像深层语义信息,但是缺乏对图像浅层信息的表达,因此 Wang 等的方法在本文数据集 MWIBD 上的识别准确率虽然达到了 90% 以上,但是其识别效果还有待提升。Goswami 的方法能够很容易识别雾天,但是对雨天、雪天的识别效果较差,Goswami 通过实验证明了增加卷积层数很难提高网络模型的天气识别效果。因此,本文融合 VGG16-TL 提取的图像深层特征和图像浅层特征用于天气识别,能够达到更好的天气识别效果。

综合来看,本文提出的天气识别模型同时考虑了天气图像的浅层特征与深层特征,在雾天、雨天、雪天、晴天 4 类天气上均达到了更好的识别效果。

但是本文模型也有出现误识别的情况,该模型对雨天、雪天的识别效果不如雾天、晴天好,这是因为雨天与雪天这两种降质类型比较相似,容易混淆。

本文设计的户外图像天气识别模型是为了应用在自适应视频图像清晰化处理系统中,当识别出视频图像当前的天气后,自动调取相应的清晰化处理方法,以提高降质视频图像的能见度。如识别出当前天气是正在下雨时,调用视频图像去雨的方法进行实时处理,及时提高视频监控的能见度。

**结束语** 本文针对户外图像天气识别,构建了一个多类别天气图像分块数据集 MWIBD,并提出了一种基于图像分块与特征融合的天气识别模型。该模型融合天气图像浅层特征与深层特征进行分类,既能表达图像的浅层信息,又能表达图像的深层语义信息,有效提高天气识别的准确率。

总体而言,本文提出的天气识别模型的训练损失小、收敛速度快且准确率高。因此该模型可应用在自适应视频图像清晰化处理系统中。

对未来工作的展望:

- (1) 挖掘其他对天气图像分类有较大影响的浅层特征;
- (2) 改进提取深层特征的网络模型;
- (3) 研究能有效区分雨天与雪天这两种降质类型相似的特征。

## 参 考 文 献

- [1] RIVERO J, GERBICH T, TEILUF V, et al. Weather Classification Using an Automotive LIDAR Sensor Based on Detections on Asphalt and Atmosphere[J]. *Sensors (Basel, Switzerland)*, 2020, 20(15):1-20.
- [2] ZHANG Z, MA H D, FU H Y, et al. Scene-free multi-class weather classification on single images[J]. *Neurocomputing*, 2016, 207(26):365-373.
- [3] 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). Edinburgh, UK, 2018:305-310.
- [4] WANG Y, LI Y X. Research on Multi-class Weather Classification Algorithm Based on Multi-model Fusion[C] // 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). Chongqing, China, 2020: 2251-2255.
- [5] FANG C, LV C, CAI F, et al. Weather Classification for Outdoor Power Monitoring based on Improved SqueezeNet [C] // 2020 5th International Conference on Information Science, Computer Technology and Transportation (ISCTT). Shenyang, China, 2020:11-15.
- [6] YE R, YAN B, MI J. BIVS: Block Image and Voting Strategy for Weather Image Classification[C] // 2020 IEEE 3rd International Conference on Computer and Communication Engineering Technology (CCET). Beijing, China, 2020:105-110.
- [7] RAO Y M, LU J W, LIN J, et al. Runtime Network Routing for Efficient Image Classification[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 41(10):2291-2304.
- [8] GUO Z 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.
- [9] CHU W T, ZHENG X Y, DING D S. Camera as Weather Sensor: Estimating Weather Information from Single Images[J]. *Journal of Visual Communication and Image Representation*, 2017, 46:233-249.
- [10] LIN D, LU C W, HUANG H, et al. RSCM: Region Selection and Concurrency Model for Multi-Class Weather Recognition[J]. *IEEE Transactions on Image Processing*, 2017, 26(9):4154-4167.
- [11] JIN L S, CHEN M, JIANG Y Y, et al. Multi-Traffic Scene Perception Based on Supervised Learning[J]. *IEEE Access*, 2018, 6:4287-4296.
- [12] HE K M, SUN J, TANG X O. Single Image Haze Removal Using Dark Channel Prior[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(12):2341-2353.
- [13] ARBANE M, BENLAMRI R, BRIK Y, et al. Transfer Learning for Automatic Brain Tumor Classification Using MRI Images [C] // 2020 2nd International Workshop on Human-Centric Smart Environments for Health and Well-being(IHSH). Boumerdes, Algeria, 2021:210-214.
- [14] RIBANI R, MARENGONI M. A Survey of Transfer Learning for Convolutional Neural Networks[C] // 2019 32nd SIBGRAPI Conference on Graphics, Patterns and Images Tutorials (SIB-GRAPIT). Rio de Janeiro, Brazil, 2019:47-57.
- [15] RUSSAKOVSKY O, DENG J, SU H, et al. Imagenet large scale visual recognition challenge[J]. *International Journal of Computer Vision*, 2015, 115(3):211-252.
- [16] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. *Advances In Neural Information Processing Systems*, 2012, 25(2): 1097-1105.
- [17] KINGMA D P, BA J L. Adam: A Method for Stochastic Optimization[C] // International Conference on Learning Representations 2015 (ICLR 2015). San Diego, CA, 2015:1-15.
- [18] LIU W B, ZOU Z Y, XING W W. Feature Fusion Methods in Pattern Classification[J]. *Journal of Beijing University of Posts and Telecommunications*, 2017, 40(4):1-8.
- [19] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA, 2015:1-9.
- [20] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual Learning for Image Recognition[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, 2016: 770-778.
- [21] GOSWAMI S. Towards Effective Categorization of Weather Images using Deep Convolutional Architecture[C] // 2020 International Conference on Industry 4.0 Technology (I4Tech). Pune, India, 2020:76-79.



**ZUO Jie-ge**, born in 1997, postgraduate. Her main research interests include video image processing and image quality assessment.



**LIU Xiao-ming**, born in 1959, professor. His main research interests include traffic electronic information system, navigation and radar information system.