

许立兵,孔扬,成思蒙,等. 基于深度学习的海雾图像分类方法研究[J]. 陕西气象,2024(6):54-58.

文章编号:1006-4354(2024)06-0054-05

基于深度学习的海雾图像分类方法研究

许立兵¹,孔 扬²,成思蒙¹,过莹烨¹

(1. 无锡九方科技有限公司,江苏无锡 214011;2. 宁波市气象局,浙江宁波 315012)

摘要:基于宁波港口摄像头采集的图像及附近能见度观测站数据建立数据集,采用 VGG16 模型和改进的 VGG16 模型对图像进行海雾等级识别。改进模型将全连接层替换为全局平均池化层,引入深度可分离卷积进一步降低模型参数量,卷积层和激活函数之间加入了批归一化,降低迭代次数和训练难度;针对拍摄的海雾图像存在细节不清晰、对比度不高和色彩失真等问题,在特征提取方面增加了 HSV 色彩空间及基于暗通道的图像增强算法。结果表明,改进 VGG16 模型对海雾等级识别的准确率、精确率、召回率、 F_1 值分别为 92.89%,93.81%,92.13%,92.86%,较改进之前上述指标提升 14.00% 以上,改进模型可显著提升港口海雾监测与等级分类识别能力。

关键词:港口海雾;能见度;图像识别;深度学习

中图分类号:TP391.4

文献标识码:A

宁波舟山港地处中国大陆海岸线中部,位于“丝绸之路经济带”和“21 世纪海上丝绸之路”交汇处,是中国沿海向全球各大港口运输的重要集散地,连续十三年货物吞吐量排名全球第一,2021 年集装箱吞吐量排名全球第三。宁波舟山港所处区域气象情况复杂,海雾、台风等任何一种灾害性天气都有可能给航道通行、港口作业等带来安全隐患和重大的经济损失,甚至造成人员伤亡。舟山群岛地形复杂,狭管效应明显,并且港区具有大量化工、能源等重点企业,存在地势复杂和管理难的特点。大雾天气能见度较差,对港口安全生产、作业调度、引航、航运、临港产业等都会带来诸多不利影响。

目前对于能见度的观测除了人工现场观测外,采用较为广泛的是使用能见度观测仪进行监测。但能见度观测仪布设和维护的成本较高,安装密度较低,对于局地浓雾和团雾的监测能力有限^[1-2];而利用港口的视频监控图像是对海雾识别的有效补充。随着计算机视觉技术的发展,基于

视频图像数据、站点观测数据,利用统计方法或机器学习算法识别海雾、反演能见度的研究及应用也越来越多。李勃等^[3]用车道分割线提取感兴趣域,通过 Kalman 滤波器滤除干扰,得到能见度;邓小丽等^[4]利用西安咸阳国际机场高速公路 3 个 8 要素气象监测站逐小时资料、部分时段的逐分钟资料,对低能见度出现的概率及影响进行了分析,对低能见度的预报预警有重要意义;李勇军等^[5]用分水岭分割法提取双光源的亮度差异来计算能见度,与 Vaisala FD12 前向散射能见度仪的结果具有较好的一致性;史达伟等^[6-7]基于多种机器学习算法,建立了强浓雾气象要素诊断模型,利用 75% 的研究样本训练模型,剩余 25% 的样本测试模型的泛化能力,测试准确率为 82.25%;近年来,深度卷积神经网络(CNN)由于采用局部连接和权值共享的方式构建网络,在无需人为干预的情况下,模型可以自动从图像中学习特征,构建分类模型^[8],可对模型进行优化处理,能降低模型的

收稿日期:2023-10-09

作者简介:许立兵(1988—),男,汉族,江苏无锡人,硕士,高级工程师,从事大数据处理、机器学习的研究。

通信作者:孔扬(1988—),男,汉族,浙江宁波人,硕士,高级工程师,从事气象预报服务、大数据处理研究。

基金项目:宁波市科技计划项目(2022S181);浙江省气象科技计划项目(2022ZD26)

训练难度及解决过拟合问题^[9]。Su 等^[10]研究表明,相对于其他深度学习分类模型,多层堆叠式的VGG16 模型具有更高的识别准确率,具有良好的泛化能力。为了高效识别舟山市虾峙导航台的海雾,满足在实际港口航道的应用需求,本文通过对VGG16 模型进行改进,以降低模型的训练难度,提升训练速度,提高识别的准确率,为港口海雾监测和识别提供新的方法和思路。

1 数据来源

1.1 数据介绍

虾峙门航道是进出宁波舟山港的重要航道,实验采用宁波市气象局提供的虾峙导航台2022年3月3日至2023年6月2日图像数据,时间分辨率为10 min;虾峙东口能见度站2023年3月3日至2023年6月2日的10 min平均能见度数据。能见度站位置为122°18'37"E, 29°44'7"N, 摄像头位置为122°18'14"E, 29°44'40"N, 两站的直线距离为1 191.34 m。

1.2 数据集构建

本实验图像数据采用虾峙导航台摄像机采集的数据,该港口摄像头拍摄主要是往海面方向进行拍摄,图像数据经过质控:首先人工剔除镜头有污垢、水滴等情况的样本;考虑到夜晚光照条件差,过滤掉18—06时的低照度的图像;为了进一步提高样本的质量,减少错误样本,对样本进行了人工的识别和剔除,共得到27 994张样本。根据虾峙东口能见度站的10 min平均能见度观测数据,将港口拍摄的图像数据根据能见度等级分为3类,分别为:无雾,轻雾,大雾,具体的分类标准及图像的数量情况如表1所示。

表1 2022-03-03—2023-06-02 虾峙导航台海雾的分类等级及相应的图像数量统计表

等级	平均能见度 V/m	图像数量/张	占比/%
无雾	V>10 000	20 148	71.97
轻雾	1 000≤V≤10 000	6 812	24.33
大雾	V<1 000	1 034	3.70

1.3 数据预处理

为了能更好提取色彩的明暗、色调及不同等

级的海雾特征,将图像从RGB 色彩空间转换到HSV(hue, saturation, value) 色彩空间。在HSV 色彩空间中,图像由色调(H)、饱和度(S)和明度(V)三个要素构成。图像经过归一化处理,为了满足模型的输入要求,将图像的尺寸从1 920×1 080 调整为224×224。由于不同等级的数据分布不均衡,对轻雾、大雾的图像进行2倍比例的过采样,对无雾的图像按照50%比例进行随机欠采样,预处理后的数据集按照7:2:1的比例划分为训练集、验证集和测试集。采样后的数据集如表2 所示。

表2 过/欠采样后的数据集分布

类型	无雾	轻雾	大雾
训练集	7 051	9 536	1 447
验证集	4 029	2 724	413
测试集	1 007	681	212

1.4 评价指标

对海雾分类等级采用准确率(A)、精确率(P)、召回率(R)和 F_1 作为机器学习算法模型的评价指标。其中, T_p 代表实际为某类海雾并被正确预测的样本数量, F_n 代表实际为其他类海雾而被预测为某类的样本数量, F_p 代表实际为某类海雾却被错误预测的样本数量, T_n 表示实际为其他类海雾并被正确预测为其他类的样本数量^[11]。四种评价指标及具体计算方法如下:

$$A = (T_p + T_n) / (T_p + F_p + T_n + F_n), \quad (1)$$

$$P = T_p / (T_p + F_p), \quad (2)$$

$$R = T_p / (T_p + F_n), \quad (3)$$

$$F_1 = 2PR / (P + R). \quad (4)$$

其中准确率是最主要的评价指标,其值越接近1,说明模型的分类效果越优;精确率主要是衡量模型对海雾预测的查准率,其值越大表示查准率越高;召回率用来衡量模型对海雾预测的查全率; F_1 用于调和精确率与召回率之间的矛盾,是这两种评价指标的调和平均值,其值与分类效果成正相关,值越大说明海雾识别的效果越好。

2 算法与模型

2.1 模型选择

本次实验采用在ImageNet 图像分类与定位

挑战赛 ILSVRC-2014 中,取得分类任务第二,定位任务第一的 VGG16 作为基础模型^[12]。VGG16 包含 13 个卷积层和 3 个全连接层,在卷积层中有多个大小为 3×3 的卷积核,以步长为 1 对上一层的特征图(feature map)进行卷积操作,使用 ReLU 激活函数做非线性变换。使用最大池化(max pooling)对卷积操作提取的特征图进行数据降维,池化窗口大小为 2×2 ^[13-14]。

2.2 模型改进

由于原始 VGG16 的全连接层的参数量过大,会增加网络的训练难度,且过多的参数容易造成模型的欠拟合。本实验将 VGG16 的全连接层替换为全局平均池化层,全局平均池化可以将全连接层前的特征图按照均值转化为一个特征值。一张港口拍摄图像大小为 $224 \times 224 \times 3$,增加色调(H)、饱和度(S)和明度(V),为了去除图像的噪声,取每个图像点 R、G、B 三个值中最低的一个值,构建一幅暗通道图(Dark)^[15],输入模型的图像为 $224 \times 224 \times 7$,经过 VGG16 的卷积操作后大小变为 $7 \times 7 \times 512$ 的特征图;将该特征图传给全局平均池化层后,输出的特征向量为 $1 \times 1 \times 512$;再将该特征向量送入 Softmax Loss 损失函数进行分类^[16]。损失函数(L_s)表达为

$$L_s = - \sum_{i=1}^m \lg \frac{e^{w_j^T y_i x_i + b_{y_i}}}{\sum_{j=1}^n e^{w_j^T x_i + b_j}}. \quad (5)$$

上式中: x_i 表示 m 个样本中属于 y_i 的第 i 个样本特征; y_i 表示该样本所属海雾的等级; n 表示海雾的等级类别数,本实验中 n 为 3; w_j 表示在全连接层的参数矩阵中第 j 列; T 表示矩阵的转置; b 为模型节点的偏置。

此外,本实验在 VGG16 的卷积层和激活函数之间加入了批归一化(batch normalization)处理,在归一化层中求解每个训练批次数据均值和方差,然后激活值被归一化后进行映射,降低迭代次数,降低训练难度,具体处理算法如下。

首先输入 m 个样本: $B = \{x_1, x_2, \dots, x_m\}$,计算批处理数据均值 μ_B , $\mu_B \leftarrow \frac{1}{m} \sum_{i=1}^m x_i$,方差为 $\sigma_B^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2$ 。

归一化处理: $\tilde{x}_i \leftarrow \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}$ 。其中, \tilde{x}_i 表示归

一化的属于 y_i 的第 i 个样本特征; ϵ 为常数,增加 ϵ 的目的是防止归一化处理时候分母等于 0。

为避免归一化影响特征分布,需通过尺度变化和偏移来恢复原有特征分布, $y_i \leftarrow \gamma_i x_i + \beta_i$,其中参数 γ_i 和 β_i 通过训练得到, $\gamma_i = \sqrt{\text{Var}(x_i)}$, $\beta_i = E(x_i)$, $\text{Var}(x_i)$ 为方差函数; $E(x_i)$ 为均值函数。

该操作的目的是将数据规整到统一区间,减少数据的发散程度,防止每次卷积操作后数据的分布发生改变,从而导致梯度消失,降低网络的学习难度。此外归一化后,使用 γ_i 、 β_i 作为还原参数,在一定程度上保留原数据的分布,还可以加快模型的收敛。

通过引入深度可分离卷积进一步降低参数量。将网络中的 Conv2D 替换为 Separable-Conv2D,即深度方向的空间卷积与通道混合在一起的逐点卷积。深度可分离卷积对输入特征的每个通道分别使用一个卷积核,将所有卷积核的输出进行拼接得到输出,然后对输出逐点使用一个 1×1 的卷积核,进行升维或降维,得到最终结果。通过使用深度可分离卷积,进一步降低参数量,加速模型收敛,降低训练难度,使得需要提供学习的数据更少,弥补数据不足的劣势,改进前后的 VGG16 网络结构如表 3 所示。

3 结果分析

本实验采用随机梯度下降法(SGD)对网络进行训练,选择 Softmax Loss 作为损失函数,训练集和验证集的损失函数的变化曲线如图 1 所示。图 1 中训练集的 Loss 曲线显示模型在第 30 批次左右的时候基本收敛,验证集的 Loss 曲线则呈现波动下降的趋势。造成这种现象的原因主要有两点:(1)训练集、验证集的样本少且不均衡。虽然对数量少的轻雾、大雾进行了过采样,但是由于轻雾、大雾样本的数量与无雾样本相比,差异过大,过采样的样本被重复学习,导致模型的泛化能力不足^[17]。如果随着样本的不断积累,获得更多轻雾、大雾的样本,则在某种程度上可以解决这个问题。(2)依据能见度站 10 min 平均能见度对样本

表 3 改进前后 VGG16 模型结构对比

原始 VGG16 模型	改进后 VGG16 模型
input($224 \times 224 \times 3$)	input($224 \times 224 \times 7$)
RGB	RGB+HSV+Dark
conv3-64	sepconv3-64
conv3-64	sepconv3-64
maxpool	maxpool
conv3-128	BN-64
conv3-128	sepconv3-128
maxpool	sepconv3-128
conv3-256	maxpool
conv3-256	BN-128
conv3-256	sepconv3-256
maxpool	sepconv3-256
conv3-512	maxpool
conv3-512	BN-256
conv3-512	sepconv3-512
maxpool	sepconv3-512
conv3-512	maxpool
conv3-512	BN-512
conv3-512	sepconv3-512
conv3-512	sepconv3-512
maxpool	sepconv3-512
FC-4096	maxpool
FC-4096	AdaptiveMaxPool
FC-1000	FC-3
FC-3	Softmax
Softmax	Softmax

进行分类,可能导致一些训练样本的分类出现错误。如人工判断该图片为无雾,然而对应的能见度数据属于轻雾,因能见度观测仪的观测方向与摄像头拍摄画面方向不一致,导致雾的分类等级出现错误。针对此类人工判断和能见度观测不一致的情况,以人工判断的为准。在测试集上,还存在少量样本的模型识别结果、人工判断结果和能

见度观测结果不一致的情况,如识别模型判断为轻雾,人工判断为无雾,能见度观测为无雾;识别模型判断为轻雾,人工判断为轻雾,能见度观测为无雾,存在误判的情况。针对此类问题可通过积累更多的样本,提高模型的泛化性能。

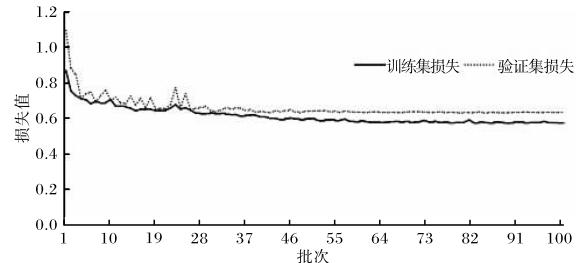


图 1 训练集和验证集上损失函数变化曲线图

识别模型在测试集上的分类准确率,精确率,召回率, F_1 如表 4 所示。模型改进后的识别准确率从 73.89% 提升至 92.89%,提升了 19.00%;精确率从 79.41% 提升至 93.81%,提升了 14.40%;召回率从 74.33% 提升至 92.13%,提升了 17.80%;用于调和精确率与召回率之间冲突的 F_1 从 75.14% 提升至 92.86%,提升了 17.72%。

表 4 VGG16 模型改进前后评价指标对比 %

模型	准确率	精确率	召回率	F_1
改进前	73.89	79.41	74.33	75.14
改进后	92.89	93.81	92.13	92.86

改进前和改进后的模型在测试集上的混淆矩阵如图 2 所示。对角线上的数值表示各个等级的海雾图像识别的准确率。模型改进前对于轻雾、无雾、大雾 3 个等级的识别准确率分别为 68%、85%、70%;改进后的模型识别准确率分别为 93%、93%、90%,可见改进后的模型的准确率得到了较大的提高。

4 结论和讨论

(1)改进后的 VGG16 模型进一步降低参数量,加速模型收敛,降低训练难度;在特征处理方面增加色调、饱和度、明度及暗通道特征,弥补 RGB 三通道数据表达能力不足的问题。实验结果表明,改进后的 VGG16 模型可显著提高海雾等级的识别能力,对海雾等级识别的准确率、精确

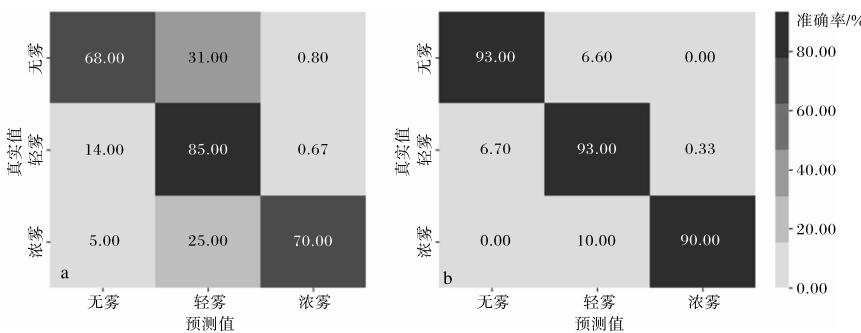


图 2 改进前(a)、改进后(b)VGG16 模型分类结果混淆矩阵图

率、召回率、 F_1 分别为 92.89%，93.81%，92.13%，92.86%，改进前分别为 73.89%，79.41%，74.33%，75.14%，相关评价指标提升 14.00% 以上。

(2) 由于单个站点的数据量较少, 同时存在样本不均衡等问题, 模型的性能仍有进一步提升的空间, 随着样本的不断积累, 可以获取更多轻雾、大雾的样本, 则可以进一步提升模型的鲁棒性及分类精度。

参考文献:

- [1] 王敏, 张世国, 汪玮, 等. 前向散射式能见度仪示值对比及标定方法研究[J]. 气象科技, 2017, 45(2): 217–222.
- [2] 黄亮, 张振东, 肖鹏飞, 等. 基于深度学习的公路能见度分类及应用[J]. 大气科学学报, 2022, 45(2): 203–211.
- [3] 李勃, 董蓉, 陈启美. 无需人工标记的视频对比度道路能见度检测[J]. 计算机辅助设计与图形学学报, 2009, 21(11): 1575–1582.
- [4] 邓小丽, 乔娟, 张楠, 等. 西咸高速公路低能见度特征及影响因子分析[J]. 陕西气象, 2021(5): 36–41.
- [5] 李勇军, 张玉钩, 周毅, 等. 基于分水岭分割算法夜间能见度仪的图像处理方法研究[J]. 大气与环境光学学报, 2012, 7(2): 131–138.
- [6] 史达伟, 李超, 史逸民, 等. 基于机器学习的大雾天气背景下特强浓雾本地化诊断研究[J]. 灾害学, 2018, 33(2): 193–199.
- [7] 史达伟, 张静, 曹庆, 等. 基于决策树算法的海州湾地区海雾预测[J]. 气象科学, 2022, 42(1): 136–142.
- [8] 刘海兵, 卢秋芳. GMDH 神经网络在雷电预警中的应用[J]. 陕西气象, 2023(5): 74–79.
- [9] GEETHA G, KIRTHIGADEVI T, GODWIN PON-SAM G, et al. Image captioning using deep convolutional neural networks (CNNs) [J]. Journal of Physics: Conference Series, 2020, 1712: 012015.
- [10] SU D, ZHANG H, CHENH, et al. Is robustness the cost of accuracy?: A comprehensive study on the robustness of 18 deep image classification models[C]//Proceedings of the European conference on computer vision (ECCV), 2018: 644–661.
- [11] 车翔玖, 刘华罗, 邵庆彬. 基于 Fast RCNN 改进的布匹瑕疵识别算法[J]. 吉林大学学报(工学版), 2019, 49(6): 2038–2044.
- [12] 李社宏. 气象领域深度学习知识体系框架及前沿应用[J]. 陕西气象, 2018(1): 21–25.
- [13] 沈卫东, 李文韬, 刘娟, 等. 基于改进 Canny 边缘检测的指针式仪表自动读数算法研究[J]. 国外电子测量技术, 2021, 40(2): 60–66.
- [14] 陈姣, 刘小红. 基于生成对抗网络的遮挡人脸表情识别方法研究[J]. 现代计算机, 2023, 29(6): 77–79.
- [15] 王治. 结合暗通道先验和变分模型的单幅图像去雾去噪算法[D]. 青岛: 青岛大学, 2018.
- [16] 侯向宁, 徐草草, 杨井荣. 基于 Spark 的花卉图像分类研究[J]. 计算机技术与发展, 2022, 32(7): 70–74.
- [17] 罗渠, 冯静雯, 赖虹宇, 等. 精神分裂症和抑郁症患者静息态脑电分类[J]. 计算机工程与应用, 2021, 57(13): 138–146.