


DOI: 10.12086/oe.2022.220007

结合遥感卫星及深度神经 决策树的夜间海雾识别

李 涛, 金 炜*, 符冉迪, 李 纲, 尹曹谦

宁波大学信息科学与工程学院, 浙江 宁波 315211



摘要: 遥感卫星具有覆盖范围广、连续观测等特点,被广泛应用于海雾识别相关研究。本文首先借助能够穿透云层,获取大气剖面信息的星载激光雷达 (cloud-aerosol LiDAR with orthogonal polarization, CALIOP) 对中高云、低云、海雾、晴空海表样本进行了标注。然后结合葵花 8 号卫星 (Himawari-8) 多通道数据提取了各类样本的亮温特征与纹理特征。最后根据海雾监测的需求,抽象出海雾监测的推理决策树,并据此建立深度神经决策树模型,实现了高精度监测夜间海雾的同时具备较强的可解释性。选择 2020 年 6 月 5 日夜间 Himawari-8 每时段连续观测数据进行测试,监测结果能够清晰地展现此次海雾事件的动态发展过程。同时本文方法海雾监测平均命中率 (probability of detection, POD) 为 87.32%, 平均误判率 (false alarm ratio, FAR) 为 13.19%, 平均临界成功指数 (critical success index, CSI) 为 77.36%, 为海上大雾的防灾减灾提供了一种新方法。

关键词: 葵花 8 号卫星; CALIOP 星载激光雷达; 深度神经决策树; 夜间海雾识别

中图分类号: TP751

文献标志码: A

李涛, 金炜, 符冉迪, 等. 结合遥感卫星及深度神经决策树的夜间海雾识别 [J]. 光电工程, 2022, 49(9): 220007

Li T, Jin W, Fu R D, et al. Nighttime sea fog recognition based on remote sensing satellite and deep neural decision tree[J].

Opto-Electron Eng, 2022, 49(9): 220007

Nighttime sea fog recognition based on remote sensing satellite and deep neural decision tree

Li Tao, Jin Wei*, Fu Randi, Li Gang, Yin Caoqian

Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo, Zhejiang 315211, China

Abstract: Remote sensing satellites have the characteristics of wide coverage and continuous observation, and are widely used in research related to the sea fog identification. Firstly, the Cloud-Aerosol LiDAR with Orthogonal Polarization (CALIOP), which is capable of penetrating clouds and obtaining atmospheric profiles, was used to annotate medium and high cloud, low cloud, sea fog, and clear sky sea surface samples. Then, bright temperature features and texture features were extracted from each type of sample in combination with multi-channel data from the Himawari-8 satellite. Finally, according to the needs of sea fog monitoring, the inference decision tree for sea fog monitoring was abstracted and a deep neural decision tree model was built accordingly, which could achieve high accuracy for nighttime sea fog monitoring while having strong interpretability. The continuous observation data of Himawari-8 on the night of June 5, 2020 was selected to test the sea fog. The monitoring results can clearly show the dynamic development process of the sea fog events. At the same time, the sea fog monitoring method in

收稿日期: 2022-03-01; 收到修改稿日期: 2022-05-22

基金项目: 国家自然科学基金资助项目 (42071323); 宁波市公益类科技计划项目 (202002N3104)

*通信作者: 金炜, xyjw1969@126.com.

版权所有©2022 中国科学院光电技术研究所

this paper has an average probability of detection (POD) of 87.32%, an average false alarm ratio (FAR) of 13.19%, and an average critical success index (CSI) of 77.36%, which provides a new method for disaster prevention and mitigation of heavy fog at sea.

Keywords: Himawari-8; CALIOP; deep neural decision tree; nighttime sea fog recognition

1 引言

海雾是受海洋影响发生在海上或沿海地区低层大气中的凝结现象, 通常会使得大气水平能见度小于 1 km^[1]。海雾不仅对海上交通运输、渔业捕捞等活动产生很大安全隐患, 而且对沿海地区的交通、农业、电力、空气质量也具有一定影响, 严重威胁人民的生命财产安全。因此, 监测或跟踪海雾的消长变化, 能为有关部门实施科学调控和管理应对提供依据, 对海上防灾减灾具有重要现实意义。

由于海上只有少数的观测站点, 缺乏实地观测资料, 且天气和环境生态系统变化迅速, 因此海雾无法像陆地雾一样使用常规监测方式进行大范围、长时间的连续监测。卫星遥感具有快速、覆盖范围广、可连续观测等优势, 已成为海雾监测中不可或缺的重要技术手段。利用遥感数据对海雾的监测始于上世纪 70 年代, 经过多年的研究, 已趋于成熟。研究人员通过分析不同类型云雾在卫星多通道光谱信息上的差异, 建立阈值或者机器学习模型用于大雾的监测。Shin 等^[2]在海洋和气象卫星 (communication, ocean and meteorological satellite, COMS) 数据的基础上引入海表亮温数据, 并根据海雾红外通道亮温差与海表云顶亮温差的特性建立无监督算法来学习优化数据的显著特征, 自动设置最佳阈值, 完成了对夜间海雾的检测。Kim 等^[3]基于地球静止海洋彩色成像仪和葵花 8 号 (Himawari-8) 双卫星观测数据, 通过分析海雾的光学和空间特性, 建立了决策树算法实现了海雾的动态监测。郝姝馨等^[4]基于新一代静止气象卫星 Himawari-8 高时空分辨率多通道数据, 对 2018–2019 年黄、渤海海雾事件的多通道红外亮温辐射特性进行了分析, 通过设置海雾、晴空水体和一般云系分离指数, 建立多指数概率分布算法, 完成了对夜间海雾的监测。

近年来, 深度学习快速发展, 在医学分割、云检测与云图生成等领域取得不错的成绩^[5-9]。目前, 已有研究人员成功地将深度学习技术迁移到海雾监测任务上。Jeon 等^[10]基于 GOCI 的红外亮温和可见光反射率数据, 对卫星云图进行分析标注, 建立了雾分类数

据集, 并在此基础上, 采用迁移学习的方法, 将在自然图像数据集上预训练过的卷积神经网络迁移到海雾数据集上, 开展了不同波段组合对海雾识别精度影响的研究。Xu 等^[11]借助无监督域自适应的方法, 将丰富的标注陆地雾样本和未标注海雾样本有效结合进行海雾检测, 提高了海雾识别准确率。文献 [12-14] 将基于深度学习的分割技术推广到海雾识别, 使用融合空间信息的图像级别检测代替传统单像元检测, 解决了传统海雾检测缺乏空间语义信息的问题, 实现了雾区的精细化反演。虽然深度学习方法能够表征数据语义信息, 具有特征学习能力强、预测精度高等优点, 但其通常以“端到端”模式进行训练和推理, 具有“黑盒子”特性, 即难以解释其推理过程。另外, 深度学习模型通常需要大量有标签的样本进行训练, 而上述基于深度学习的海雾监测研究大多针对于日间场景。通过结合云图分析专家对可见光与红外波段数据分析后的建议, 对海雾样本进行手工标注。由于夜间缺乏可见光波段数据, 因此难以快速准确地对样本进行标注, 这也导致深度学习方法在夜间海雾识别中应用难度更大。

针对上述问题, 本文首先借助能够穿透云层, 获取大气剖面信息的星载激光雷达对样本进行标注。相比手工标注, 该方法更加便捷准确, 能够获取海量的云、雾及下垫面标注数据, 可以满足深度学习对训练数据量的要求。然后基于葵花 8 号气象卫星多通道数据提取标注样本的亮温、纹理特征, 建立夜间海雾监测数据集。最后根据海雾监测的需求, 抽象出对应的推理决策树, 并将其嵌入到卷积神经网络中, 建立深度神经决策树模型, 在高精度识别海雾的同时具备较强的可解释性, 实现对夜间海雾的有效监测。

2 数据与方法

2.1 葵花 8 号卫星

本文基于葵花 8 号静止卫星数据进行研究。葵花 8 号静止气象卫星是日本气象厅运营的第三代地球静止气象卫星, 2014 年 10 月 7 日发射上空, 2015

年7月投入使用, 现位于赤道上方东经140.7°。其搭载的高级葵花成像仪(advanced Himawari imager, AHI), 覆盖了可见光与红外共16个波段, 空间分辨力为0.5 km~2 km, 时间分辨力为6次/小时。相比于上代静止气象卫星, 葵花8号静止气象卫星在波段数量、空间与时间分辨力上均得到了大幅度提升。因此, 本文使用葵花8号气象卫星数据进行海雾的监测与识别研究。

2.2 结合星载激光雷达的样本标签提取

云-气溶胶激光雷达和红外探测者卫星(Cloud-Aerosol LiDAR and Infrared Pathfinder Satellite Observations, CALIPSO)由美国国家航天局与法国国家航天中心合作研制, 于2006年4月28日成功发射, 在太阳同步轨道上运行, 距地高度705 km, 倾角98.2°。其携带的探测器星载激光雷达(cloud-aerosol LiDAR with orthogonal polarization, CALIOP)是第一个可以测量全球大气状态的星载偏振激光雷达, 能够持续不断发射和接收激光脉冲, 穿透云层及气溶胶, 获取大气垂直剖面结构信息。

目前CALIOP的公开数据分为一级(Level 1)、二级(Level 2)和三级(Level 3)产品(下载地址: <https://subset.larc.nasa.gov/calipso/login.php>)。其中二级垂直特征掩模产品(vertical feature mask, VFM)提供了背向散射的连续大气区域的类别信息, 如云、气溶胶、晴空等。VFM产品虽没有雾这一类别, 但是雾实际上就是贴地的云, 当产品中识别为水云且云贴地时即认为是雾。除此之外, 由于海雾的云底高度非常低, 接近于海平面, 在CALIOP数据反演无法计算海雾的底层高度信息时, 就把海雾归为同样无法计算底层高度信息的海水一类中, 即出现海表误判^[15]。吴东等^[16]统计了大气低层云雾和气溶胶的衰减后向散射系数, 给出了海表误判剔除气溶胶的阈值。综上, 本文获取海雾标签的方法为: 在VFM产品数据中, 当分类结果为云, 且云底距海表不超过一个测量单元时, 认为是海雾; 当分类结果是海表, 并且超出水平高度两个及以上的测量单元也判为海雾; 此外, 为了消除气溶胶的影响, 在上述判断的基础上, 需要同时满足1064 nm 衰减后向散射系数 $\beta'_{1064\text{nm}} > 0.025 \text{ km}^{-1}\text{sr}^{-1}$, 且532 nm 总衰减后向散射系数 $\beta'_{532\text{nm}} > 0.03 \text{ km}^{-1}\text{sr}^{-1}$ ^[17]。本文利用CALIOP数据, 将样本标记为中高云、低云、海雾与晴空海表四类。

2.3 基于Himawari-8的样本特征构建

提取丰富的特征是准确识别海雾的基础。受太阳光照的影响, Himawari-8卫星在夜间场景下可见光波段与近红外波段数据缺失, 只有红外波段数据可用。因此, 本文基于Himawari-8红外波段通道进行了特征提取。为了增强对空间信息的挖掘, 本文选取以样本中心大小3×3的局部窗口作为样本的亮温特征。由于低云和海雾的组成相似, 海雾抬升成为低云, 低云下沉变为海雾, 因此两者在物理和光学性质上都表现出一致性。虽然难以从物理和光学性质上辨别, 但可以利用纹理特征对其进行区分。通常海雾是在稳定大气条件下由暖湿空气平流到冷的表面上形成的, 其纹理一般比较均匀, 在图像上表现为顶部光滑且边缘整齐清晰, 易受地表的影响, 雾区像素的亮温值波动更加稳定^[1]。因此, 纹理特征能加大海雾与低云的可区分性, 提高模型识别海雾的精度。

本文首先提取了局部二值模式(local binary patterns, LBP)特征。LBP通过比较中心像素与3×3邻域像素的灰度值进行阈值运算, 并按照指定的编码规则生成编码, 最终的编码值能够体现中心像素和3×3邻域像素灰度值的大小关系。由于LBP仅采样局部3×3邻域, 不能体现更大范围的纹理分布情况, 为提取更大邻域的纹理特征, 本文选取以样本为中心的7×7大小矩阵计算了灰度共生矩阵(gray-level co-occurrence matrix, GLCM), 灰度游程矩阵(gray-level run length matrix, GLRLM)与灰度区域大小矩阵(gray-level size zone matrix, GLSZM)三种纹理特征并以此作为样本的纹理特征。其中GLCM保存了邻域内所有灰度组合在定义的距离和方向条件下“共生”的频数。GLRLM保存了邻域内具有相同灰度值的连续像素的长度和个数信息。GLSZM保存了邻域内具有相同灰度强度的连通域大小和个数信息。

最终, 本文基于Himawari-8红外波段通道提取了亮温特征与纹理特征共128维的向量作为构造的样本特征, 以进行夜间海雾识别研究。

2.4 基于深度神经决策树的海雾识别

2.4.1 网络整体结构设计

传统海雾监测算法通常借助云雾对于卫星不同通道的反照率或者亮温分布差异, 建立单通道或者多通道模型来逐步分离晴空海表、中高云、低云, 最终达到识别海雾的目的。虽然此方法简单高效、可解释强, 但其海雾识别精度通常较低, 且易受季节、区域等因

素影响。卷积神经网络作为深度学习的主要方法，具有特征学习能力强、预测精度高等优点，被广泛应用于云图相关领域。虽然目前已有不少研究将卷积神经网络迁移到海雾监测任务上，但都局限于日间海雾监测。相较于日间监测场景，夜间缺乏可见光波段数据，海雾识别的精度较低，有必要借助卷积神经网络来提升夜间海雾识别的精度。尽管卷积神经网络能够提高海雾识别的精度，但其通常以“端到端”模式进行训练和推理，具有“黑盒子”特性，即难以对其推理过程进行解释。

为使得模型高精度识别海雾的同时具备合理的解释性，本文通过分析传统海雾识别方法，抽象出了符合海雾监测需求的决策树，并将此决策树嵌入卷积神经网络中，建立对应的深度神经决策树模型，对海雾进行识别研究。本文方法如图 1 所示。

首先对云图中提取的 128 维的特征进行预处理，如图 1(a) 所示。使用零填充的方式将其填充为 144 维的特征向量，并对填充后的特征向量进行变换，转换成大小为 12×12 的特征矩阵，以满足卷积网络的输入需求。之后将此特征矩阵输入卷积网络，如图 1(b) 所示。特征矩阵输入卷积网络后首先经过 conv0 进行处理，conv0 包含了一层卷积与批次归一化 (BatchNorm)^[18] 操作。随后输入 4 组级联的卷积块 block 进行特征变换与学习。每个卷积块 block 都包

含两组卷积、批次归一化以及 ReLU 函数激活操作。卷积块之间使用跳跃连接的方式进行连接，以输入的残差为学习的目标，有助于梯度的反向传播，加速网络的学习。

卷积网络最终输出特征图被展平为 d 维的特征向量 $\mathbf{x} = (x_1, x_2, \dots, x_d)$ 。此时传统的深度网络通常直接使用全连接层将特征向量 \mathbf{x} 映射到输出类别空间中，如图 1(c) 所示。虽然这种方式简单直接，但丧失了可解释性，使得我们无法了解模型的推理过程。为使深度网络在高精度的同时具备更加清晰的决策过程，符合海雾监测的常规流程，本文根据海雾识别的需求建立了二叉决策树，并将其转换为对应的推理规则嵌入到深度网络中进行训练，使得网络能够按照预先建立的规则进行推理。

2.4.2 海雾识别决策树

本文建立的海雾识别二叉决策树如图 1(e) 所示。由图可知，此决策树符合常规的海雾监测思想，图中绿色标注的节点为决策树叶节点，对应数据集中具体类别，分别为晴空海表 (sea surface)、中高云 (middle/high clouds)、低云 (stratus) 和海雾 (sea fog) 四类。灰色标注的节点是非叶子节点，为虚拟节点，即数据集中并不存在对应的具体类别，分别为整体 (whole)、云 (cloud) 和低层云 (low level cloud)。决策树中父节点所对应的类别与子节点所对应的类别在逻辑

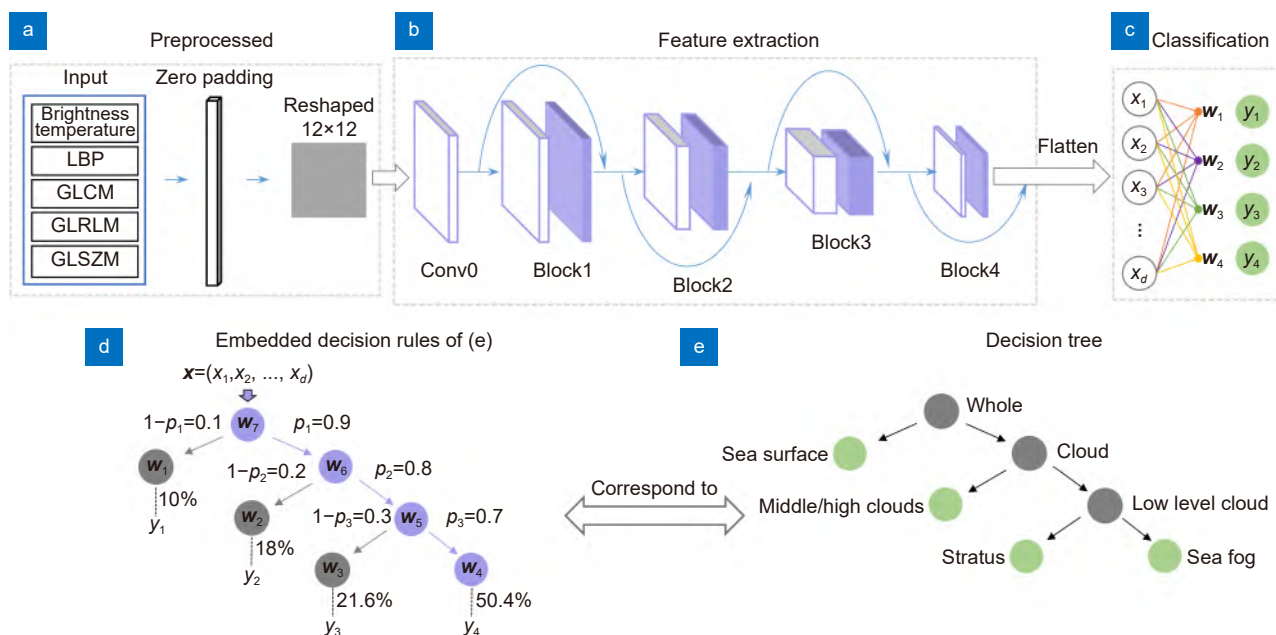


图 1 算法流程图

Fig. 1 Overall algorithm flow chart

辑上为父子关系。如海雾和低云的父节点为低层云, 则表示低层云包含海雾和低云。通过此决策树对输入样本进行逐级判断后, 输入样本将归属到某叶子节点, 即晴空海表、中高云、低云和海雾中的一类。综上, 所建立的决策树能够从逻辑上完成海雾识别任务, 输入样本从决策树根节点转移至叶子节点即完成分类。

2.4.3 深度推理规则

为使得网络能够按照决策树指定的规则进行训练与推理, 需在卷积网络与决策树之间建立联系。本文基于卷积网络的全连接层权重与目标决策树建立了可嵌入学习的推理规则来显式约束网络。推理规则是与目标决策树相对应的树形结构, 不同之处在于推理规则的节点与卷积网络的参数相关联, 如图 1(d) 所示。设 y_1, y_2, \dots, y_4 分别表示晴空海表、中高云、低云和海雾四类。推理规则的叶子节点分别为 w_1, w_2, \dots, w_4 , 对应图 1(c) 全连接层 y_1, y_2, \dots, y_4 的参数, 为 d 维的权重向量。推理规则的非叶子节点在全连接层中无对应参数, 使用以非叶子节点为根节点子树的所有叶子节点的均值进行填充^[19], 即 $w_5 = (w_3 + w_4)/2$, $w_6 = (w_2 + w_3 + w_4)/3$, $w_7 = (w_1 + w_2 + w_3 + w_4)/4$ 。推理规则可代替决策树进行推理, 其叶节点与决策树的节点一一对应, 表示不同类别, 并且节点权重与卷积网络相关联, 能够对网络起到约束。从推理规则根节点转移到叶节点即可完成推理, 计算方式如下:

设输入样本经卷积网络处理后的特征为 $x = (x_1, x_2, \dots, x_d)$, 非叶节点 i 的子节点集合 $C(i) = \{C(i)_1, C(i)_2, \dots, C(i)_n\}$, 则输入样本从父节点 i 转移到子节点 $C(i)_j$, $j = 1, 2, \dots, n$ 的概率为

$$p(C(i)_j | i) = \frac{e^{x \cdot w_{C(i)_j}}}{\sum_{k=1}^n e^{x \cdot w_{C(i)_k}}}, j = 1, 2, \dots, n, \quad (1)$$

其中: $w_{C(i)_j}$ 表示子节点 $C(i)_j$ 的权重向量, n 为节点的子节点数量, 由于所建为二叉树, 因此 $n = 2$ 。设根节点到叶节点 l 的路径 $P(l) = \{n_0, n_1, \dots, n_m\}$, 则从根节点转移至叶节点的 l 的概率为

$$p(l) = \prod_{j=0}^{m-1} p(n_{j+1} | n_j), l = 1, 2, \dots, 4, \quad (2)$$

其中: $p(n_{j+1} | n_j)$ 表示从父节点 n_j 转移至子节点 n_{j+1} 的概率, m 为根节点到叶节点的路径长度, $p(l)$ 表示样本从根节点转移到叶节点 l 的概率, 即样本归属叶节点 l 对应类别的概率。从根节点转移至所有叶节点的

概率计算完成后, 选择概率最大的作为网络最终预测的类别:

$$\hat{y} = \arg \max_l p(l), l = 1, 2, \dots, 4, \quad (3)$$

其中: \hat{y} 表示网络最终预测的类别, $p(l)$ 为从推理规则根节点转移至叶节点 l 的概率, 即样本属于类别 l 的概率。如图 1(d) 展示了输入的样本为海雾时推理规则推理的过程, 图中标注为紫色的部分即为输入样本的转移路径, 节点旁数字表示从对应的父节点转移至子节点的概率。由图可知, 最终 y_4 对应的叶节点的概率为 $p_1 \times p_2 \times p_3 = 50.4\%$, 大于其它叶节点概率, 因此海雾为网络预测的类别。

2.4.4 损失函数

为显式约束卷积网络遵从决策规则的方式进行推理, 使用决策树损失对网络进行约束。另外, 卷积网络原始分类损失表征模型预测类别与样本真实类别之间的误差大小, 能够引导模型参数进行优化, 因此在决策树损失的基础上引入分类损失对网络训练过程进行监督^[19]。综上, 网络损失函数如下所示:

$$L = H(y, \hat{y}_{\text{tree}}) + \lambda H(y, \hat{y}), \quad (4)$$

其中: y 为真实标签, \hat{y}_{tree} 为推理规则预测的类别概率, \hat{y} 为原始网络的预测类别概率, λ 为超参数, 用于控制模型原始分类损失与决策树损失的比重。 $H(\cdot, \cdot)$ 为交叉熵损失, 如式 (5) 所示:

$$H(p, q) = - \sum_{j=1}^4 p_j \log(q_j), \quad (5)$$

其中: p 是样本标签, q 为模型的预测结果。

3 实验结果与分析

3.1 实验环境及网络参数设置

本文实验环境为 64 位版本的 Ubuntu16.04 操作系统, CPU 为 Intel Core i7-11700k, 显存为 12 G 的 NVIDIA GTX 3080Ti 显卡。使用的编程语言为 Python, 采用了 Pytorch, Sklearn 等框架。在模型的训练过程中, 使用随机值初始化权重, 将批量大小设置为 256, 学习率设置为 0.001, 损失权重 λ 设置为 1^[19], 并使用 Adam 作为优化器进行训练。为了测试本文模型在海雾识别中的有效性, 将数据集按照 8:2 的比例随机划分为训练集和测试集, 使用训练集对模型进行训练并验证模型在测试集的性能, 其中训练集包含 16693 个样本, 测试集包含 4173 个样本。

为了定量评价本文方法是否能正确识别海雾区域,

本文使用了命中率 (probability of detection, POD, 用 P_d 表示), 误判率 (false alarm ratio, FAR, 用 F_r 表示) 和临界成功指数 (critical success index, CSI, 用 C_s 表示) 三种指标对模型进行了评价, 如下所示。

1) 命中率, 模型正确识别正样本数量与真实正样本数量的比值, 其值越大则模型错误地将正样本识别为负样本的比例越小, 即漏检数量越少。

$$P_d = \frac{TP}{TP+FN} \quad (6)$$

2) 误判率, 模型错误识别的正样本数量占所有识别为正样本的比例, 其值越小, 模型错误地将负样本识别为正样本的比例越小, 即误检数量越少。

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

3) 临界成功指数, 综合了命中率和误判率的结果, 其值越高说明模型的综合性能越好。

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

上述公式中, 真阳性 (true positive, TP) 表示模型正确检测到的正样本数量, 假阳性 (false positive, FP) 表示模型错误检测到的正样本数量, 假阴性 (false negative, FN) 表示模型错误检测到负样本数量。

3.2 网络结构分析

为了确定卷积网络的深度, 对网络中 block 的组数进行实验。本文以 3 组 block 模块为初始, 依次增加, 实验结果如表 1 所示。

由表可知, 6 组 block 网络的中高云命中率最高, 为 91.99%, 但其误判率较高为 11.67%, 对于其它类别, 4 组 block 网络命中率相对较高。从平均评价指标来看, 4 组 block 网络最高, 平均临界成功指数为 77.36%。综合考虑识别精度与效率, 选择 4 组 block 网络为训练模型。

为了探讨不同形式卷积网络对模型识别海雾的影响, 分别使用二维卷积网络 (CNN_2D) 与一维卷积网络 (CNN_1D) 构建深度决策树进行对比。一维卷积网络除了将二维卷积替换为一维卷积外, 其余结构与二维卷积网络相同。不同卷积网络识别结果如表 2 所示。

由表可知, 一维卷积网络的平均命中率为 83.42%, 平均误判率为 16.33%, 平均临界成功指数为 72.20%, 二维卷积网络的平均命中率为 87.32%, 平均误判率为 13.19%, 平均临界成功指数为 77.36%。二维卷积网络在识别精度上相比于一维卷积网络有较大的提升。这表明二维卷积网络能够学习更有效的特征组合模式, 增强了不同类别样本的特征区分度, 因此提高了对应模型的识别精度。

3.3 模型有效性分析

为了验证纹理特征以及决策树监督损失对模型识别海雾的影响, 分别对深度决策树的纹理特征与决策树损失进行消融实验, 结果如表 3 所示。

表中, ATF 表示消融纹理特征后的模型 (ablation

表 1 不同网络层数实验结果

Table 1 Experimental results of different network layers

Method		Middle/high clouds	Stratus	Sea fog	Sea surface	Average
Three-groups	POD/(%)	89.30	76.71	82.12	92.15	85.07
	FAR/(%)	11.07	20.37	21.13	7.42	15.00
	CSI/(%)	80.36	64.13	67.31	85.81	74.40
Four- groups	POD/(%)	89.09	80.87	86.47	92.84	87.32
	FAR/(%)	7.06	18.64	19.14	7.90	13.19
	CSI/(%)	83.44	68.23	71.78	85.99	77.36
Five- groups	POD/(%)	90.40	78.59	82.00	90.65	85.41
	FAR/(%)	11.07	19.82	19.24	7.54	14.42
	CSI/(%)	81.25	65.81	68.60	84.41	75.02
Six- groups	POD/(%)	91.99	77.60	80.24	91.34	85.29
	FAR/(%)	11.67	20.43	17.83	7.05	14.24
	CSI/(%)	82.02	64.71	68.34	85.42	75.12

表 2 不同卷积网络结果对比

Table 2 Comparison of results of different convolution networks

Method		Middle/high clouds	Stratus	Sea fog	Sea surface	Average
CNN_1D	POD/(%)	87.36	76.11	81.76	88.45	83.42
	FAR/(%)	11.60	25.07	23.79	4.84	16.33
	CSI/(%)	78.38	60.66	65.14	84.64	72.20
CNN_2D	POD/(%)	89.09	80.87	86.47	92.84	87.32
	FAR/(%)	7.06	18.64	19.14	7.90	13.19
	CSI/(%)	83.44	68.23	71.78	85.99	77.36

表 3 消融结果对比

Table 3 Comparison of ablation results

Method		Middle/high clouds	Stratus	Sea fog	Sea surface	Average
ATF	POD/(%)	90.40	67.59	73.65	93.30	81.24
	FAR/(%)	11.55	24.72	21.55	18.30	19.03
	CSI/(%)	80.85	55.31	61.25	77.17	68.65
ATL	POD/(%)	89.44	81.96	80.47	89.49	85.34
	FAR/(%)	8.80	20.40	21.92	7.52	14.66
	CSI/(%)	82.34	67.73	65.64	83.42	74.78
WOA	POD/(%)	89.09	80.87	86.47	92.84	87.32
	FAR/(%)	7.06	18.64	19.14	7.90	13.19
	CSI/(%)	83.44	68.23	71.78	85.99	77.36

texture features, ATF), ATL 表示消融决策树损失后的模型 (ablation tree loss, ATL), WOA 表示未进行消融的模型 (without ablation, WOA)。由表可知, 消融纹理特征后模型的平均命中率为 81.24%, 平均误判率为 19.03%, 平均临界成功指数为 68.65%, 引入纹理特征后模型的性能得到了提升, 平均命中率为 87.32%, 平均误判率为 13.19%, 平均临界成功指数为 77.36%。上述现象表明纹理特征能够有效区分不同类别的样本, 提升模型的识别精度。对比表中 ATL 与 WOA 两种方法可知, 引入决策树损失后模型的精度得到了一定的提升, 平均命中率提升 1.98%, 平均误判率下降 1.47%, 平均临界成功指数提升 2.58%, 不同类别的识别精度也得到了提升。这不仅表明引入

决策树损失能够有效地监督模型, 也间接说明本文所建立的决策树具有区分不同类别样本的能力。

为了客观地评价本文方法在海雾监测中的应用潜力, 使用测试集对该模型进行了测试, 并展示了测试结果的混淆矩阵, 如表 4 所示。

由表可知, 本文模型对于中高云和晴空海表具有较强的区分能力, 这与云图影像中所展示的迹象相一致。中高云和晴空海表的图像特征通常比低层云雾更明显。由于海雾和低云在组成成分、光学特征和物理性质十分接近, 海雾上升演变为低云, 低云下降成为海雾, 因此识别低层云雾相比其它类别更加困难。本文模型在区分低云和海雾的能力上有一定的改进空间。对于这种差异, 下一步可以考虑结合不同区域、时间

表 4 模型分类混淆矩阵

Table 4 Confusion matrix of model

True label	Middle/high clouds	Stratus	Sea fog	Sea surface
Middle/high clouds	1290	85	58	15
Stratus	56	816	98	39
Sea fog	36	64	735	15
Sea surface	6	38	18	804

段样本以及多卫星观测资料, 充分挖掘海雾的空间特征, 来提高模型的鉴别能力。

为了验证本文方法对海雾识别的决策过程具备可解释性, 对 2020 年 6 月 2 日出现在黄渤海区域的海雾进行了识别, 并可视化了模型识别海雾的推理过程, 如图 2 所示。

其中图 2(a) 为模型识别结果, 识别出的海雾标记为绿色, 图 2(b) 为模型对经纬度为 120.4°E, 38.4°N 的样本点 A 的推理过程, 节点旁边文字代表节点类别, 数字代表样本点 A 归属本节点类别的概率。图中标记为紫色路径的节点为模型对样本 A 的推理路径, 即 A 以 91% 的概率归属云 (cloud), 然后以 98% 的概率归属低层云 (low level cloud), 最后以 99% 的概率归属海雾 (sea fog) 类别。样本 A 最终归属海雾类别的概率为推理路径上所有概率的乘积, 即 $91\% \times 98\% \times 99\% = 88\%$ 。模型预测 A 为海雾节点的概率大于其它三个叶子节点的概率, 因此样本 A 最终的类别为海雾。上述现象表明深度决策树模型对海雾进行识别时能够按照预先建立的决策规则对样本进行逐层判断, 符合常规的海雾识别监测流程, 具有较好的可解释性。

3.4 不同算法海雾识别结果对比分析

为了验证算法的有效性, 本文进行了对比实验。对比模型包括支持向量机 (support vector machine, SVM)、决策树 (decision tree, DT) 与卷积神经网络 ResNet^[20]。将上述模型的识别结果与本文模型进行比较, 分析不同模型在海雾识别中的有效性。不同模型使用 POD、FAR 和 CSI 进行评估, 结果如表 5 所示。

从单类别的角度来看, 对于中高云, 不同模型均

具有相对较高的临界成功指数, 其中决策树最低为 68.07%, 本文方法最高为 83.44%。对于晴空海表, ResNet 的临界成功指数最高为 88.36%, 其次是本文方法为 85.99%, 决策树最低为 69.43%。海雾和低云相比于中高云、晴空海表来说, 模型的识别精度较低。本文方法对低云和海雾的临界成功指数分别为 68.23% 和 71.78%, ResNet 的临界成功指数分别为 68.94%、71.74%, 基于传统机器学习模型的方法相对较差。从不同方法类型来看, 对于机器学习方法, 支持向量机相比于决策树具有更好的性能, 平均命中率为 79.39%, 平均误判率为 20.19%, 平均临界成功指数为 67.07%。深度学习方法相比于传统机器学习方法具有较大的提高。对于深度学习方法, 本文方法对中高云和海雾的临界成功指数分别为 83.44%、71.78%, 识别效果优于 ResNet, 而对于低云和晴空海表的识别效果相对较差。ResNet 的平均命中率为 87.58%, 平均误判率为 12.67%, 平均临界成功指数为 78.05%, 整体的性能最优。本文方法的平均命中率为 87.32%, 平均误判率为 13.19%, 平均临界成功指数为 77.36%, 略低于 ResNet。上述现象表明, 相比其它类别, 海雾与低云的识别难度较高, 传统机器学习模型难以有效地对它们进行区分, 本文将显式的决策规则引入卷积神经网络中, 建立的深度决策树模型能够有效地对海雾进行识别, 整体识别精度能够达到常规深度学习方法的水平, 并且具有较好的可解释性。

为了更加直观地比较模型, 本文选取了 2020 年 6 月 5 日出现在黄渤海区域的海雾天气进行分析。使用不同模型对 UTC 18:20 时刻的卫星云图进行海雾识别, 结果如图 3 所示。

图中 3(a)、3(b)、3(c)、3(d) 分别为通过 SVM 模




图 2 模型推理示例

Fig. 2 An example of the model inference process

表 5 不同海雾识别方法分类结果对比

Table 5 Classification accuracy of different sea fog recognition methods

Method		Middle/high clouds	Stratus	Sea fog	Sea surface	Average
SVM	POD/(%)	85.28	81.71	58.78	91.78	79.39
	FAR/(%)	19.12	21.56	31.02	9.05	20.19
	CSI/(%)	70.97	66.72	46.49	84.10	67.07
DT	POD/(%)	81.42	64.22	62.71	82.10	72.61
	FAR/(%)	19.41	35.01	36.85	18.18	27.36
	CSI/(%)	68.07	47.72	45.91	69.43	57.78
ResNet	POD/(%)	89.99	81.17	85.41	93.76	87.58
	FAR/(%)	8.37	17.94	18.24	6.13	12.67
	CSI/(%)	83.15	68.94	71.74	88.36	78.05
Ours	POD/(%)	89.09	80.87	86.47	92.84	87.32
	FAR/(%)	7.06	18.64	19.14	7.90	13.19
	CSI/(%)	83.44	68.23	71.78	85.99	77.36

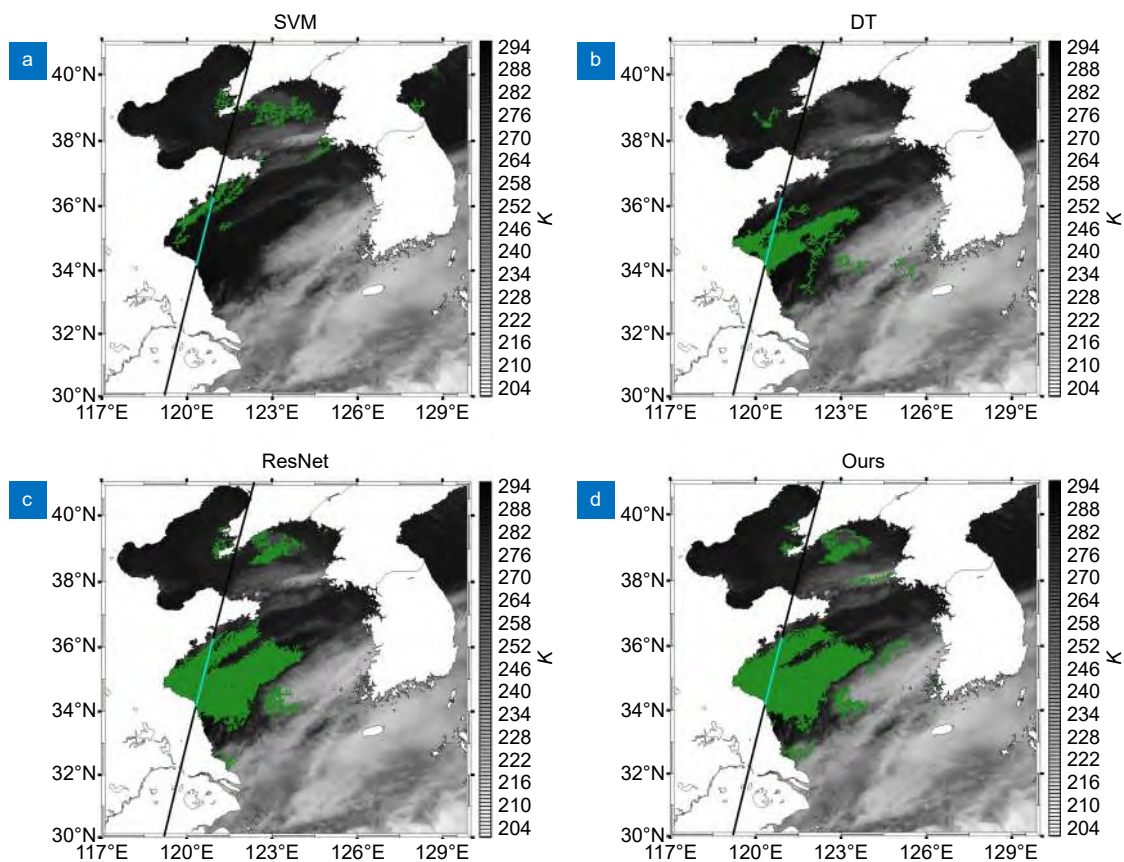


图 3 黄渤海区域 2020 年 6 月 5 日 UTC 18:20 时刻的海雾识别图

Fig. 3 Sea fog identification result at UTC 18:20 on June 5, 2020 in the Yellow Sea and Bohai Sea

型、决策树、ResNet 以及深度决策树进行预测的海雾识别图。图中黑色实线表示星载激光雷达在该时间段的运行轨迹线，轨迹线标记为青色的部分是通过星载激光雷达资料判定为海雾样本的像元。图中绿色部分为模型识别为海雾的区域。由图可知，相比深度学习模型，传统机器学习模型海雾识别效果较差。支持向量机与决策树模型都产生了不同程度的漏检，错误识别星载激光雷达轨迹线上标记的海雾样本。ResNet 与深度决策树基本完全识别出星载激光雷达

轨迹线上的海雾样本，效果较优。上述现象说明基于深度决策树模型进行海雾识别具有较好的性能。

3.5 海雾识别个例分析

国家气象中心发布了海雾预报：2020年6月5日夜间到6日白天，由于偏南暖湿气流加强，导致黄海中部和南部海域、山东南部 and 江苏东部沿岸海域能见度小于 1 km，出现了海雾天气，影响了我国北方海域。本文利用深度决策树模型对此次海雾过程进行了分析。图 4 给出了基于深度决策树对 2020 年 6 月

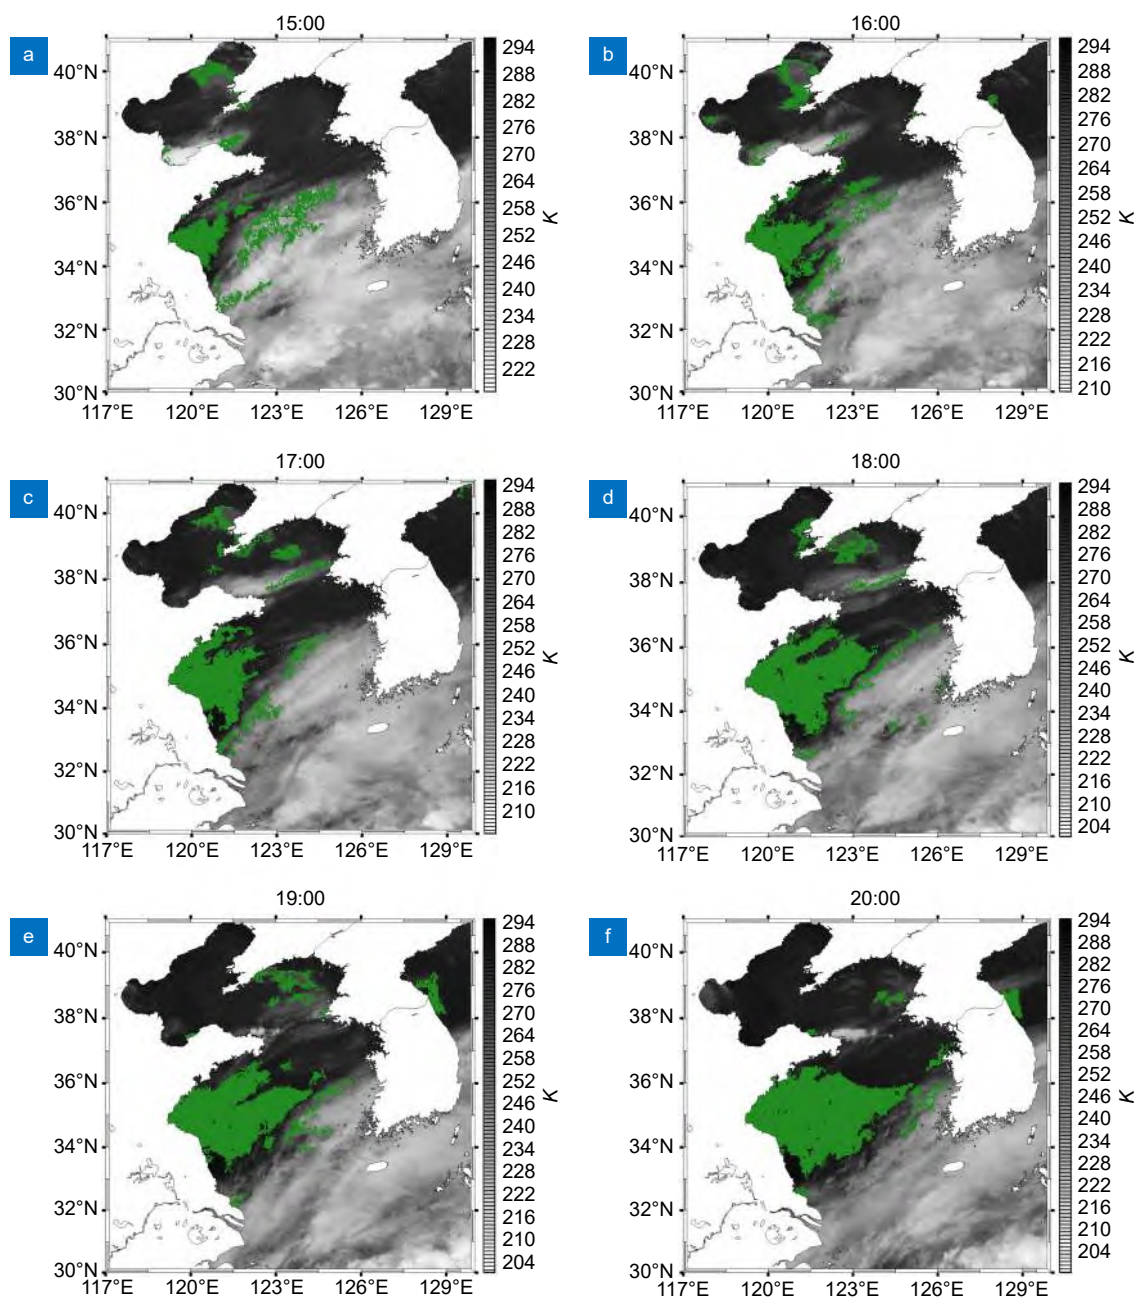


图 4 黄渤海区域 2020 年 6 月 5 日 UTC 15:00~20:00 海雾监测图

Fig. 4 The monitoring results of sea fog in the Yellow Sea and Bohai Sea from 15:00 to 20:00 UTC on June 5, 2020

5日UTC 15:00~20:00整点时刻的海雾监测结果。由海雾监测结果可知,在15:00时刻海雾出现在黄海西部沿岸区域,主体呈三角状,少量散布于渤海沿岸;15:00~20:00之间,海雾处于发展期,主体逐渐向南、东、北方向进行蔓延;到20:00时刻,海雾主体扩张到最大,南至33°N,北至37°N,东至125°E附近。海雾主体接壤山东半岛,跨越黄海中部,延伸至朝鲜半岛西部。监测结果清晰地展现了本次海雾动态发展、稳定的过程。

4 结 论

海雾因其恶劣的能见度而对海上及沿岸地区的交通运输、海洋捕捞和海洋开发工程以及军事活动等造成不良影响,因此对于海雾的实时监测和预报就显得尤为重要。目前,越来越多的研究人员开始借助深度学习方法来进行海雾的识别,但深度学习通常对标签具有较高要求,需要专业的云图分析专家对海雾进行标注,是一项艰巨而繁琐的工作,而且难以对深度学习方法进行合理解释。为了解决这些问题,本文利用Himawari-8静止卫星与星载激光雷达对海雾进行标注,提取其亮温特征和纹理特征,并构建深度决策树模型对夜间海雾进行自动识别。通过实验对模型有效性进行了分析与不同模型进行了对比,结果表明,该方法在较高精度识别海雾的同时具备可解释性,可作为实践中进行识别海雾的辅助工具。当然,该方法也还存在一些不足之处,区分海雾和低云的能力还有提升空间,未来可进一步研究海雾与低云的物理性质差异、结合多卫星观测数据提取更具辨别度的特征,以及借助生成对抗网络生成夜间伪可见光数据等方式,提升模型识别海雾的能力。

参考文献

- [1] Xiao Y F, Zhang J, Cui T W, et al. Review of sea fog detection from satellite remote sensing data[J]. *Marine Sciences*, 2017, **41**(12): 146-154.
肖艳芳, 张杰, 崔廷伟, 等. 海雾卫星遥感监测研究进展[J]. *海洋科学*, 2017, **41**(12): 146-154.
- [2] Shin D, Kim J H. A new application of unsupervised learning to nighttime sea fog detection[J]. *Asia Pac J Atmos Sci*, 2018, **54**(4): 527-544.
- [3] Kim D, Park M S, Park Y J, et al. Geostationary Ocean Color Imager (GOCI) marine fog detection in combination with Himawari-8 based on the decision tree[J]. *Remote Sens*, 2020, **12**(1): 149.
- [4] Hao S X, Hao Z Z, Huang H Q, et al. Nighttime sea fog recognition based on Himawari-8 data[J]. *Haiyang Xuebao*, 2021, **43**(11): 166-180.
郝姝馨, 郝增周, 黄海清, 等. 基于Himawari-8数据的夜间海雾识别[J]. *海洋学报*, 2021, **43**(11): 166-180.
- [5] Zhou Z W, Siddiquee M M R, Tajbakhsh N, et al. UNet++: a nested U-Net architecture for medical image segmentation[M]// Stoyanov D, Taylor Z, Carneiro G, et al. *Deep learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. Cham: Springer, 2018: 3-11.
- [6] Xuan R R, Li T, Wang Y T, et al. Prenatal prediction and typing of placental invasion using MRI deep and radiomic features[J]. *BioMed Eng OnLine*, 2021, **20**(1): 56.
- [7] Zha S J, Jin W, He C F, et al. Detecting of overshooting cloud tops via Himawari-8 imagery using dual channel multiscale deep network[J]. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2021, **14**: 1654-1664.
- [8] Kim J H, Ryu S, Jeong J, et al. Impact of satellite sounding data on virtual visible imagery generation using conditional generative adversarial network[J]. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2020, **13**: 4532-4541.
- [9] Kim K, Kim J H, Moon Y J, et al. Nighttime reflectance generation in the visible band of satellites[J]. *Remote Sens*, 2019, **11**(18): 2087.
- [10] Jeon H K, Kim S, Edwin J, et al. Sea fog identification from GOCI images using CNN transfer learning models[J]. *Electronics*, 2020, **9**(2): 311.
- [11] Xu M Q, Wu M, Guo J, et al. Sea fog detection based on unsupervised domain adaptation[J]. *Chin J Aeron*, 2022, **35**(4): 415-425.
- [12] Huang Y X, Wu M, Guo J, et al. A correlation context-driven method for sea fog detection in meteorological satellite imagery [J]. *IEEE Geosci Remote Sens Lett*, 2022, **19**: 1003105.
- [13] Liu S X, Yi L, Zhang S P, et al. A study of daytime sea fog retrieval over the yellow sea based on fully convolutional networks[J]. *Trans Oceanol Limnol*, 2019(6): 13-22.
刘树霄, 衣立, 张苏平, 等. 基于全卷积神经网络方法的日间黄海海雾卫星反演研究[J]. *海洋湖沼通报*, 2019(6): 13-22.
- [14] Huang B, Wu M, Sun S Y, et al. Sea fog monitoring method based on deep learning satellite multi-channel image fusion[J]. *Meteorol Sci Technol*, 2021, **49**(6): 823-829,850.
黄彬, 吴铭, 孙舒悦, 等. 基于深度学习的卫星多通道图像融合的海雾监测处理方法[J]. *气象科技*, 2021, **49**(6): 823-829,850.
- [15] Wan J H, Su J, Liu S W, et al. The research on the spectral characteristics of sea fog based on CALIOP and MODIS data[J]. *Int Arch Photogramm Remote Sens Spatial Inf Sci*, 2018, **XLII-3**: 1667-1671.
- [16] Wu D, Lu B, Zhang T C, et al. A method of detecting sea fogs using CALIOP data and its application to improve MODIS-based sea fog detection[J]. *J Quant Spectr Radiat Transfer*, 2015, **153**: 88-94.
- [17] Si G, Fu R D, He C F, et al. Daytime sea fog recognition based on remote sensing satellite and deep neural network[J]. *J Optoelectron-Laser*, 2020, **31**(10): 1074-1082.
司光, 符冉迪, 何彩芬, 等. 结合遥感卫星及深度神经网络的白天

海雾识别[J]. 光电子·激光, 2020, 31(10): 1074–1082.

- [18] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]// *Proceedings of the 32nd International Conference on International Conference on Machine Learning*, 2015: 448–456.
- [19] Wan A, Dunlap L, Ho D, et al. NBDT: neural-backed decision

trees[Z]. arXiv: 2004.00221, 2020. <https://arxiv.org/abs/2004.00221>.

- [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*, 2016.

作者简介



李涛 (1997-), 男, 硕士研究生, 研究方向为深度学习、海雾识别、图像处理。

E-mail: taol1024@163.com

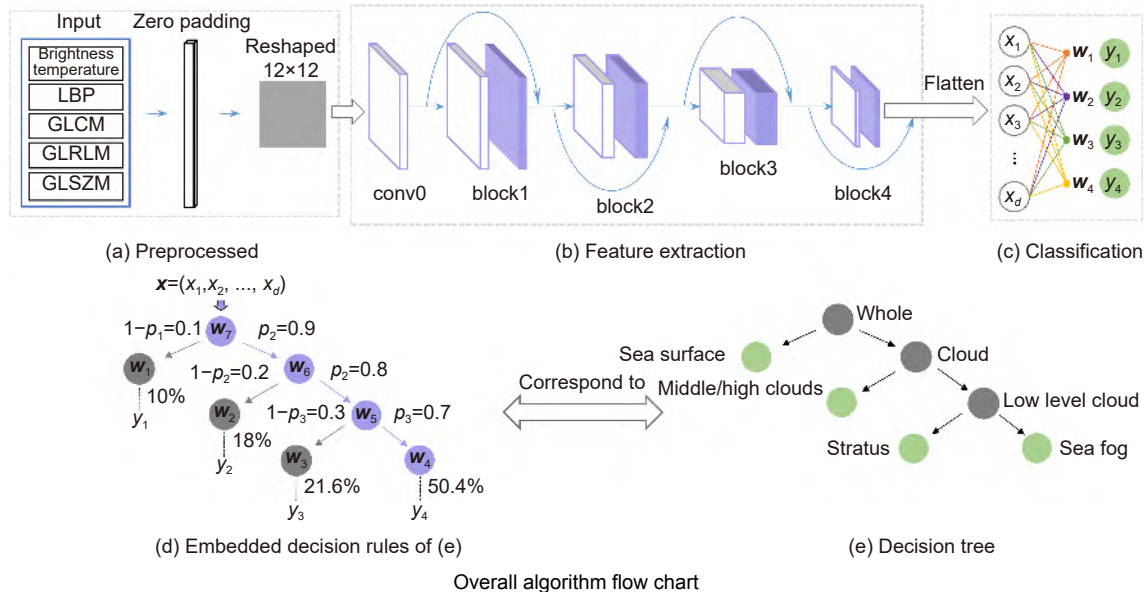


【通信作者】金炜 (1969-), 男, 博士, 教授, 研究方向为数字图像处理。

E-mail: xyjw1969@126.com

Nighttime sea fog recognition based on remote sensing satellite and deep neural decision tree

Li Tao, Jin Wei*, Fu Randi, Li Gang, Yin Caoqian



Overview: Sea fog is a dangerous weather phenomenon that seriously affects maritime traffic and other operations at sea. Remote sensing satellites have the characteristics of wide coverage and continuous observation, and are widely used in research related to the sea fog identification. Traditional sea fog monitoring algorithms usually establish a single channel or multi-channel model to gradually separate the clear sky sea surface, medium and high clouds, and low clouds with the help of the differences of reflectivity or brightness-temperature distribution of clouds in different channel satellite cloud images, so as to finally achieve the purpose of identifying sea fog. Although this method has the advantages of being simple, efficient, and highly interpretable, its sea fog identification accuracy is usually low, and is susceptible to seasonal and regional influences. As the main method of deep learning, convolutional neural network has the advantages of strong feature learning ability and high prediction accuracy. It is widely used in cloud image related fields. Although many studies have transferred convolutional neural network to sea fog monitoring task, they are limited to daytime sea fog monitoring. It is more difficult to label sea fog because of the lack of visible wavelength data at night compared to daytime monitoring scenarios. In addition, convolutional neural network is "black box" in nature, i.e. it is difficult to explain their inference process in a reasonable way.

In order to make the recognition of sea fog with high accuracy and reasonable interpretability, the cloud-aerosol LiDAR with orthogonal polarization (CALIOP), which is capable of penetrating clouds and obtaining atmospheric profiles, was first used to annotate medium and high cloud, low cloud, sea fog, and clear sky sea surface samples. Then, bright temperature features and texture features were extracted for each type of sample in combination with multi-channel data from the Himawari-8 satellite. Finally, according to the needs of sea fog monitoring, the inference decision tree for sea fog monitoring was abstracted and a deep neural decision tree model was built accordingly, which achieves high accuracy for nighttime sea fog monitoring while having strong interpretability. The continuous observation data of Himawari-8 on the night of June 5, 2020 was selected to test the sea fog. The monitoring results can clearly show the dynamic development process of the sea fog events. At the same time, the proposed sea fog monitoring method has an average probability of detection (POD) of 87.32%, an average false alarm ratio (FAR) of 13.19%, and an average critical success index (CSI) of 77.36%, which provides a new method for disaster prevention and mitigation of heavy fog at sea.

Li T, Jin W, Fu R D, et al. Nighttime sea fog recognition based on remote sensing satellite and deep neural decision tree[J]. *Opto-Electron Eng*, 2022, 49(9): 220007; DOI: 10.12086/oe.2022.220007

Foundation item: National Natural Science Foundation of China (42071323) and Public Welfare Science and Technology Project of Ningbo (202002N3104).

Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo, Zhejiang 315211, China

* E-mail: xyjw1969@126.com