

基于多算法融合的图像实时去雾算法研究

王军杰, 李 帅, 冯云霞

(青岛科技大学 信息科技学院, 山东 青岛 266061)

摘要: 雾霾等复杂的天气会严重降低自动驾驶汽车采集的图像质量; 传统的图像去雾方法存在去雾效果不明显、去雾效率较低的问题, 导致汽车环境感知准确度低、去雾实时性差, 极大降低汽车环境感知能力, 给汽车自动驾驶带来极大的安全隐患; 针对上述问题, 采用多尺度空间特征提取和特征融合模块, 通过局部连接和权值共享计算优化去雾模型; 同时, 在去雾模型训练的前向传播和反向传播过程中加入优化的 Attention 机制, 完成基于多算法融合的去雾算法研究; 在不同数据集条件下, 将提出的去雾算法和传统去雾算法的去雾和消雾效果进行对比, 以峰值信噪比 PSNR 和结构相似度 SSIM 作为评价性能的主要指标, 分析不同算法的去雾效果; 实验结果表明: 提出的算法去雾效果更明显、去雾效率更高, 极大地提高了自动驾驶汽车环境感知能力, 从而提高了自动驾驶汽车的行驶安全性能。

关键词: 多算法融合; 特征提取; 特征融合; Attention 机制; 自动驾驶; 环境感知

Research on Real-time Image Dehazing Algorithm Based on Multi-algorithm Fusion

WANG Junjie, LI Shuai, FENG Yunxia

(School of Information Science and Technology, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: Adverse weather conditions such as smog significantly affects the quality of the images captured by autonomous driving vehicles. Traditional image dehazing methods often have the characteristics of limited defogging effects and low defogging efficiency, leading to the low accuracy of vehicle environmental perception and poor real-time performance of dehazing, greatly reducing the vehicle's environmental perception capability and posing significant safety hazards to autonomous driving systems. To address these challenges, a novel dehazing algorithm that integrates multi-scale spatial feature extraction and feature fusion modules is proposed. Through local connections and weight sharing mechanisms, a dehazing model is calculated and optimized. Additionally, an enhanced attention mechanism is incorporated during the forward and backward propagation processes of the dehazing model training to further refine the multi-algorithm fusion dehazing algorithm. Through evaluation on multiple datasets, the proposed approach is compared with traditional dehazing methods in the peak signal-to-noise ratio (PSNR) and structural similarity index (SSIM). Experimental results demonstrate that the proposed algorithm achieves superior dehazing effectiveness and efficiency, significantly enhancing the environmental perception capabilities of autonomous vehicles, thereby improving their overall driving safety.

Keywords: multi-algorithm fusion; feature extraction; feature fusion; attention mechanism; autonomous driving; environmental perception

0 引言

在居民日常生活中, 由于雾霾天气的影响, 空气质量下降, 能见度降低, 容易引发交通事故, 严重影

响了居民交通出行, 对居民生命安全带来了一定的安全隐患。同时严重的大雾或雾霾天气, 会导致道路上的监控无法有效录制清晰的交通画面, 在发生交通事故时, 交通执法部门也无法快速定位交通事故原因, 从而难以

收稿日期:2025-03-12; 修回日期:2025-05-14。

基金项目:山东省大数据产教融合研究生联合培养示范基地项目;国家自然科学基金面上项目(52571384)。

作者简介:王军杰(1999-),男,硕士研究生。

通讯作者:冯云霞(1977-),女,博士,副教授,硕士生导师。

引用格式:王军杰,李 帅,冯云霞. 基于多算法融合的图像实时去雾算法研究[J]. 计算机测量与控制, 2026, 34(3):163-170.

找到交通事故的真正责任方,影响交通执法的效率与准确度。此外,雾天还会给航天航空和军事安全等方面带来一定的困难,机场上空空能见度极端恶化时会导致飞机无法正常起飞降落,这对出行人员的行程会有极大的影响^[1-3]。因此如何在雾天进行快速去雾、改善有雾图像的质量,是研究学者们一直致力解决的问题。

国内外学者们在图像去雾方面进行了深入研究,文献 [4] 通过研究对比度增强的方法,能够将有雾图像中的有用信息进行突出显示,从而提出了基于图像增强的图像去雾算法,但是该算法去雾效果不够显著,只能简单淡化图像雾霾区域的影响。文献 [5] 提出了一种新的图像去雾算法,该算法以大气物理模型为基础,将估算得到的大气光照值和透射率值应用在大气散射模型中,从而将有雾图像进行复原。但该算法在计算透射率和大气光照的数值时计算量大,导致算法运行效率低^[5]。文献 [6] 首次提出基于深度学习的传统图像去雾算法,主要利用大量图像去雾数据集的输入来训练去雾模型,从而估算出无雾图像,但是该类传统去雾算法未考虑卷积网络层数过多的问题,导致训练参数较多,计算过程较为繁琐,影响去雾效率,从而导致图像去雾实时性较差^[6]。

针对上述图像去雾存在的诸多问题,本文提出了一种基于多算法融合的去雾算法,在传统卷积神经网络算法的基础上,加入多尺度去雾模块和注意力优化机制,构建轻量化的具有并行结构的神经网络结构,大大降低了特征提取时卷积神经网络的计算量。通过将图像中不同尺度特征之间的非线性加权融合,在得到高性能去雾模型的同时,还能够快速提取图像特征,细化雾特征参数,提高去雾算法速度,使去雾计算更加便捷、去雾效果更加明显,从而能够保证图像去雾的高效和实时性,达到快速准确去雾的效果。

1 实时去雾算法研究

本文以雾霾天气为例,研究了复杂天气情况下,自动驾驶汽车采集的周边环境图像的处理问题。在保证采集图像实时性的前提下,在恶劣的雾霾天气下,确保自动驾驶汽车仍能获得高质量的图像数据,为自动驾驶提供安全的数据保证。

1.1 传统去雾算法研究

传统去雾算法主要是基于卷积神经网络的去雾。卷积神经网络的结构分为卷积层、池化层和输出层等,不同网络层包含有多个神经元数量不等的卷积特征图^[7]。

1.1.1 卷积层

卷积层的主要功能是提取有雾图像中的有用特征信息,并对卷积核进行卷积操作,得到有雾图像特征图^[8]。

假设输入矩阵的大小为 $X \times X$,卷积核数量为 M ,大小为 $W \times W$,移动步长为 S ,填充值为 P ,则经过卷积和激活函数后,特征图大小为^[9]:

$$\left(\frac{X-W+2P}{S}+1\right) \times \left(\frac{X-W+2P}{S}+1\right) \quad (1)$$

则卷积过程为:

$$s(i,j) = (X * W)(I,J) + b \quad (2)$$

经过卷积操作后可得^[16]:

$$s(i,j) = \sum_{k=1}^n (X_k * W)(I,J) + b \quad (3)$$

式中, n 表示输入矩阵个数, X_k 表示输入的第 k 个矩阵, W_k 表示卷积核矩阵, k 代表第 k 个卷积核矩阵。

1.1.2 池化层

池化层是卷积神经网络的采样层,主要是接收卷积层输入的有雾图像特征图,利用不同的池化方法进行压缩,减少卷积神经网络所需的运算参数。

池化层计算过程如下^[10]:

$$f = \text{downsampling}(x) \quad (4)$$

其中: x 表示池化层采样区域,大小取决于采样步长; $\text{downsampling}(\cdot)$ 表示采样操作。

1.1.3 激活函数

卷积神经网络具有较强的非线性处理能力,能够拟合不同卷积层的非线性函数,其性能主要取决于激活函数,本文主要采用 ReLU 函数^[12]进行计算。

ReLU 函数能够较好解决模型梯度弥散的问题,计算公式表示为^[21]:

$$f(x) = \begin{cases} x, & \text{if } x \geq 0 \\ 0, & \text{if } x < 0 \end{cases} \quad (5)$$

当 $x < 0$ 时,ReLU 函数硬饱和;当 $x \geq 0$ 时,不存在饱和问题,可以保持模型梯度不衰减。

虽然 ReLU 激活函数不易饱和,但是容易造成数据偏移,导致收敛速度变慢,因此本文引入改进的 PSoft-plus 激活函数,计算公式为^[13]:

$$f(x) = \alpha[\ln(e^x + 1) - \beta] \quad (6)$$

其中:参数 β 用于调整负数输入的输出, α 用于调节函数坡度和改变函数饱和位置。

1.1.4 ResNet 残差网络

为了简化深度学习网络的训练过程,本文引入 ResNet 残差网络进行计算。整个网络可以进行端对端的训练,大大减少模型计算量,图 1 为 ResNet 残差网络结构。

图 1 中,输入为 x ,非线性层为 $F(x)$,那么输出,也就是原始映射可以被重铸为 $F(x) + x$,其中 x 表示一个层的输入,则残差网络计算公式为:

$$y = F(x, \{W_i\}) + x \quad (7)$$

其中:参数 x 、 y 分别表示输入、输出向量,函数




图 1 ResNet 残差网络结构

$F(x)$ 指待学习的残差映射; W_i 表示第 i 层的权重系数。

1.2 改进去雾模型构建

由于卷积神经网络间接去雾模型在去雾图像处理中效果不好, 因此本文在传统卷积神经网络算法的基础上, 加入多尺度去雾模块和注意力优化机制, 从而构建多尺度空间卷积神经网络结构。多尺度空间卷积神经网络结构如图 2 所示。

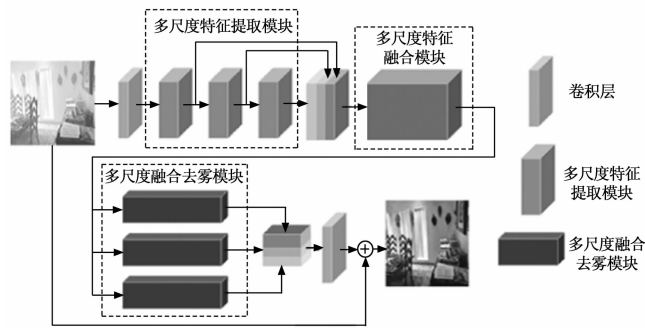


图 2 多尺度空间卷积神经网络结构

由图 2 可知, 多尺度空间卷积神经网络结构由 3 个部分组成: 多尺度特征提取模块是数据处理的第一个阶段, 主要用于提取有雾图像的关键特征。多尺度特征融合模块主要用来对有雾图像中的不同尺度特征进行非线性加权融合。而多尺度融合去雾模块则是将融合后的关键特征转化为去雾所需特征, 从而生成无雾清晰图像^[6]。

1.2.1 多尺度特征提取

传统的卷积神经网络算法主要是利用卷积层和池化层来提取图像中的有用特征信息, 但是传统算法无法实时处理复杂图像的去雾, 因此利用扩张卷积能够减少图像特征信息丢失的这一优势, 将其应用在多尺度特征提取模块中, 在相互串联的特征提取单元中加入两个经过实例归一化以及 ReLU 操作处理后的平滑扩张卷积, 最后通过局部残差连接提取出复杂的特征。因此特征提取模块大大降低了特征提取时卷积神经网络的计算量。本文研究的多尺度特征提取模块结构如图 3 所示。

假设 f_{IN}^E 表示多尺度特征提取模块的输入特征, f_{OUT}^E 表示输出特征, 每行标记为 $C \in \{1, 2, 3, 4\}$, 膨胀率为 $R=2C-1$, f_{IN}^E 输入至第 1 行第 4 列, 则不同列提取的多尺度特征计算公式为^[17]:




图 3 多尺度特征提取模块结构

$$f_2^{2C-1} = \begin{cases} SIR_2^{2C-1}(f_1^{2(C+1)-1}), & C = 1 \\ SIR_2^{2C-1}(cat[f_1^{2(C-1)-1}, f_1^{2(C+1)-1}]), & C = 2, 3 \\ SIR_2^{2C-1}(f_1^{2(C-1)-1}), & C = 4 \end{cases} \quad (8)$$

式中, $SIR_m^n(\cdot)$ 表示第 m 行膨胀率为 n 的平滑扩张卷积归一化层和 ReLU 操作; $f_m^n(\cdot)$ 表示经 $SIR_m^n(\cdot)$ 提取出的图像特征; cat 表示图像特征连接操作。

实例归一化操作是指是对一个实例库中所有图像分别进行归一化操作, 通过选取 3×3 卷积核, 逐渐将膨胀率按 1、2、5 进行增大, 改变卷积层的感受野, 从而实现特征提取模块的多级特征提取, 保证特征提取过程信息的全面, 从而提高特征提取的有用信息量, 达到较好的去雾效果。

1.2.2 多尺度特征融合

通过多尺度特征提取模块提取的大量多尺度图像特征具有不同感受野大小, 但是不同尺度下的图像特征彼此之间相互独立, 而且不能相互作用, 去雾模型性能有所降低。因此需要多尺度特征进行融合。

由于雾霾在空气中分布不均匀, 导致有雾图像雾霾信息会出现较大偏差, 需要将特征提取模块得到的有用特征乘上其对应的像素权重, 从而确保有雾图像中的浓雾区域能够分配到更高的权重, 从而可以提取更多的浓雾区域的特征信息。多尺度特征融合模块结构如图 4 所示。




图 4 多尺度特征融合模块结构

假设 f_{IN}^F 表示多尺度特征融合模块的输入特征, f_{OUT}^F 表示输出特征, 则有^[18]:

$$f_{IN}^E = f_{OUT}^F \quad (9)$$

多尺度特征提取模块提取的多尺度特征经过特征融

合可得：

$$f_{\text{OUT}}^F = PA\{ECA\{RB[Conv(f_{\text{IN}}^F)]\}\} + Conv(f_{\text{IN}}^F) \quad (10)$$

式中, $Conv(\cdot)$ 表示卷积操作对应的函数; $RB(\cdot)$ 表示残差块对应的函数; $ECA(\cdot)$ 表示有效通道注意力机制对应的函数; $PA(\cdot)$ 表示像素注意力机制对应的函数。

多尺度特征融合模块用有雾图像特征中核大小为 1×1 的卷积层减去特征维数, 将通道数降低为 64。采用卷积层 3×3 的残差块, 加入注意力机制进行加权融合, 最后采取局部残差连接的训练方法提升去雾模型的性能及训练的稳定性^[19], 从而提高去雾图像的质量。

1.2.3 多尺度融合去雾

多尺度融合去雾模块首先通过 3 个卷积层 (大小为 3×3) 进行浅层特征提取, 再通过两个组结构中将卷积层输出的特征进行融合, 而每个组结构由 5 个串行的基础块组成。经过组结构处理后, 再利用扩张卷积提取足够多的有雾图像关键特征, 最后采用全局残差连接的方法对提升多尺度空间卷积网络模型进行优化, 最终获得初步去雾图像。多尺度融合去雾模块的结构如图 5 所示。




图 5 多尺度融合去雾模块结构

多尺度融合去雾模块提取的特征为：

$$f_{i,j} = \begin{cases} B_{i,j}(f_m), & i = 1, j = 1 \\ B_{i,j}(f_{i-1,5}), & i = 2, j = 1 \\ B_{i,j}(f_{i,j-1}), & \text{其他} \end{cases} \quad (11)$$

式中, $f_{i,j}$ 表示第 $i \in \{1, 2\}$ 个组结构中第 $j \in \{1, 2, \dots, 5\}$ 个基础块所提取出的特征; $B_{i,j}(\cdot)$ 表示第 i 个组结构中第 j 个基础块进行的操作; f_m 表示第 1 个组结构中第 1 个基础块输入的浅层特征。

2 去雾模型优化

2.1 优化 ResNet 模型构建

在利用卷积神经网络对有雾图像模型训练时, 由于有雾图像识别分类设计的参数较多, 而过多的参数量会严重影响模型训练时间和准确度, 因此采取局部连接和权值共享的方法^[20], 从而减少卷积神经网络去雾模型的参数量。

2.1.1 局部连接

在卷积神经网络中神经元部分相连, 能够更好反映局部有雾图像, 同时局部连接有效减少了训练参数量。

局部连接的第一层神经元个数为 6 个, 第二层神经元个数为 4 个, 则局部连接参数量为 $4 \times (3+1) = 16$, 其中 3 表示权重参数个数, 1 表示偏置参数个数。而完全连接总数为: $4 \times (6+1) = 28$ 。

2.1.2 权值共享

权值共享是指采样有雾图像的特征图神经元具有相同数量的权值和偏置, 在进行卷积操作时, 参数不发生变化。在局部连接中, 颜色相同的连接权值相同, 则第二层和第一层相连神经元的所有权值相同, 则第二层偏置和权值数量大大减少, 从而缩短训练时间。由于卷积神经网络层次过深, 导致训练误差高, 因此本文应用 ResNet 模型^[21]对有雾图像的分割数据集进行训练, 寻找最优的分类网络。引入残差网络模块, 通过输入输出的元素叠加, 加快模型训练速度, 提高训练效果。

ResNet 模型中的残差网络模块是一个恒等映射, 其前向传播和反向传播的计算公式为^[22]:

$$F = W_2 \sigma(W_1 x) \quad (12)$$

$$y = F\{x, (W_i)\} + x \quad (13)$$

$$\nabla x = \frac{\partial \text{Error}}{\partial y} \cdot \left(\frac{\partial y}{\partial F} \cdot \frac{\partial F}{\partial x} + \frac{\partial y}{\partial x} \right) \quad (14)$$

$$\nabla x = \frac{\partial \text{Error}}{\partial y} \cdot \left(\frac{\partial y}{\partial F} \cdot \frac{\partial F}{\partial x} + 1 \right) \quad (15)$$

$$\nabla x = \frac{\partial \text{Error}}{\partial y} \cdot \frac{\partial y}{\partial F} \cdot \frac{\partial F}{\partial x} + \frac{\partial \text{Error}}{\partial y} \quad (16)$$

其中: x 表示残差网络模块输入数据; W_1 表示残差网络模块第一个参数层参数, $\sigma(\cdot)$ 表示 ReLu 激活函数, W_2 表示第二个参数层参数, y 表示残差网络模块的输出数据; Error 表示最终误差, $\partial \text{Error} / \partial y$ 表示输出误差。

2.2 优化 ResNet 模型训练

卷积神经网络去雾模型主要有两个训练阶段: 前向传播和反向传播, 前向传播是指正常的有雾图像特征提取的过程, 反向传播是指借助标签数据集产生的误差不断更新卷积参数的过程。

2.2.1 前向传播

首先在对多尺度空间卷积神经网络去雾模型进行训练前, 将所有的图像特征数据权值初始化, 再对卷积层和池化层进行前向传播计算。卷积层经过非线性激活函数后, 输出特征图计算公式为^[23]:

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l\right) \quad (17)$$

其中: l 表示当前去雾模型的卷积层; x_j^l 表示第 l 个卷积层输出的第 j 个去雾图像特征图, M_j 表示前一个卷积层特征图的集合, f 表示激活函数, k_{ij}^l 表示当前卷积层的卷积核, b_j^l 表示偏置。

2.2.2 反向传播

反向传播主要是利用误差梯度的下降, 实现权重和

偏置的更新。训练误差损失函数计算公式为:

$$E^n = \frac{1}{2} \sum_{k=1}^c (t_k^n - y_k^n)^2 = \frac{1}{2} \|t_k^n - y_k^n\|_2^2 \quad (18)$$

其中: c 表示输出层阶段个数, t 表示真实训练结果, t_k^n 表示样本 n 的第 k 维真实值; y 表示模型训练结果; y_k^n 表示样本 n 的第 k 维输出值。

反向传播算法更新参数计算过程如下:

$$W_{new}^1 = W_{old}^1 - \eta \frac{\partial E}{\partial W_{old}^1} \quad (19)$$

$$b_{new}^1 = b_{old}^1 - \eta \frac{\partial E}{\partial b_{old}^1} \quad (20)$$

其中: η 表示参数更新学习率, 利用误差损失函数不断对 W 和 b 的梯度进行计算, 得到最新值。

同时在前向传播和反向传播计算过程中, 为防止多尺度空间卷积神经网络过拟合, 加入 dropout 算法, 多尺度空间卷积神经网络去雾模型训练的输入输出可表示为^[24]:

$$x_j^l \sim Bernoulli(p) \quad (21)$$

$$y^{l+1} = r^{(l)} * y^{(l)} \quad (22)$$

$$z_i^{l+1} = \omega_i^{l+1} y^{(l)} + b_i^{l+1} \quad (23)$$

$$y_i^{l+1} = f(z_i^{l+1}) \quad (24)$$

加入 dropout 算法前后网络结构如图 6 所示。




图 6 加入 dropout 算法前后网络结构

由图 6 可知, 加入 dropout 算法前, 卷积神经网络去雾模型结构较为复杂, 训练所需时间长; 加入 dropout 算法后, 多尺度空间卷积神经网络去雾模型结构较为简化, 训练所需时间大大缩短。

2.3 Attention 机制优化

在处理长时间序列的优化问题时, 由于局部输出的特征序列需要对全部的输入特征序列进行联系, 导致多尺度空间卷积神经网络去雾模型计算时间过长, 同时无法聚焦有雾图像的关键特征信息, 导致去雾效果不好、去雾效率较低。因此本文引入 Attention 机制^[25], 通过调节权重矩阵, 可以确保部分特征输入联系即将输出的这部分特征数据时, 去雾模型能够快速聚焦这部分特征。

Attention 机制聚焦关键特征信息主要是通过模型中输入 Key 关键词, 利用 Query 进行索引, 得到特征信息 S , 通过对数据进行归一化处理, 得到权重系数

a , 再通过 Key-Value 数据库分析比较, 得到相似度最高的 Key, 最后输出和 Key 相对应的 Value。

归一化权重系数计算公式为:

$$a_i = softmax(sim_i) = \frac{e^{sim_i}}{\sum_{i=1}^n e^{sim_i}} \quad (25)$$

最后将上一步得到的权值系数和关键数据的对应值进行加权求和, 得到索引对应值, 即多尺度空间卷积神经网络去雾模型的自注意力值为^[26]:

$$Attention(Query, Source) = \sum_{i=1}^n a_i \cdot Value_i \quad (26)$$

整个 Attention 机制计算过程如图 7 所示。

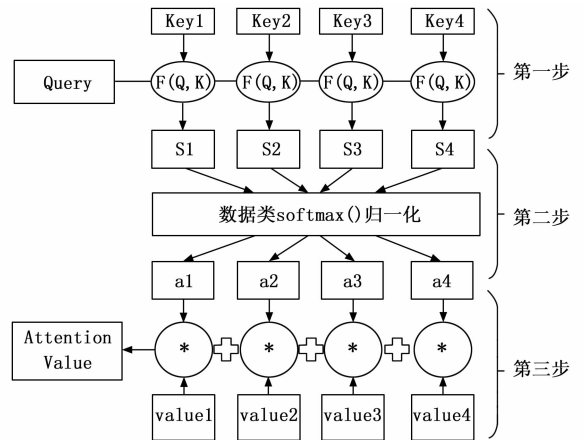


图 7 Attention 机制结构图

3 方案性能验证

3.1 数据集设置

本文采取的图像去雾数据集为 RESIDE 数据集, 该数据集包含有不同的测试子集: ITS (室内训练集)、SOTS (合成客观测试集)、HSTS (混合主观测试集)。后续对真实的模糊图像适用对象的边界框进行注释后又形成了 RESIDE- β 集合^[27], 两数据集的组成结构如表 1 所示。

表 1 两种数据集组成结构

	子集	图片数量	真实/合成	室内/室外	添加注释
RESIDE	ITS(室内训练集)	13 990	合成	室内	否
	SOTS(合成客观测试集)	500	合成	室内	否
	HSTS(混合主观测试集)	20	真实	室外	否
RESIDE- β	OTSC(室外训练集)	72 135	合成	室外	否
	RTTS (现实任务驱动测试集)	4 322	真实	室外	是

表 1 中 RESIDE 测试集有两部分组成, 即客观测试集 SOTS 和混合主观测试集 HSTS 组成, 客观测试集即为客观存在的没有进行一系列操作的图像, 混合主观测试集是经过人为改造的, 设计这两种测试集的目的是为了表现不同的评估指标与评估效果, 客观测试集在室内

深度数据集中选取了 500 幅图片，并将其合成模糊的带雾图像。RESIDE- β 包含有室外训练集 OTS 和现实任务驱动测试集 RTTS。

去雾性能验证实验所需的实验环境以及开展实验对应的实验参数如表 2 所示。

表 2 实验参数和实验环境

实验环境及参数名称	参数值
系统环境	Windows 10
操作系统	64 位操作系统
运行硬件	CPU-Intel-8750H, 主频 2.20 GHz, GPU-Nvidia GTX 1060
程序	Python 编写
网络框架	torch 1.4.0+cu92
训练次数	10 000 次
Batchsize 值	12
学习率	0.000 1
其他	每训练 1 000 次, 学习率下降到当前值的 0.1 倍

3.2 性能评价指标分析

图像去雾质量评价指标主要是指用来反应去雾图像质量好坏的指标，包括峰值信噪比 PSNR 和结构相似度 SSIM^[28]。

1) 峰值信噪比 PSNR 主要用来表示图像信号中最大功率与噪声的比值，峰值信噪比 PSNR 越大，去雾图像和清晰无雾图像越接近，PSNR 计算公式为：

$$PSNR = 10 \times \lg \left[\frac{MAX_I^2}{MSE} \right] \quad (27)$$

式中， MAX_I^2 表示像素最大值。

2) 结构相似度 SSIM 主要用来评价去雾图像和清晰无雾图像之间结构的相似程度，结构相似度 SSIM 越大，去雾图像和清晰无雾图像越相似，SSIM 计算公式为：

$$SSIM = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \cdot \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (28)$$

其中： μ_x 、 μ_y 表示去雾图像与清晰无雾图像的均值， σ_x 、 σ_y 表示两图形的标准差； $\sigma_x\sigma_y$ 表示两图像的协方差； C_1 、 C_2 为常数。

3.3 去雾实验与分析

实验前，将图像尺寸统一预处理成大小为 256×256 像素，RESIDE-ITS 数据集、RESIDE-SOTS 数据集和 HSTS

数据集的训练次数分别设置为 13 990、1 000 和 10 张。对于 RESIDE- β 数据集，训练次数设置为 72 135。大气散射光参数设置为 [0.7, 1.0]，大气散射系数为 [0.6, 1.8]。

为定量评估基于多算法融合的图像去雾算法的性能，本文通过将传统的去雾算法 DCP、DehazeNet、MSCMN、阶梯式去雾算法（基于 Res Net 与 U-Net 联合）与本文所提算法进行对比，利用峰值信噪比 PSNR 和结构相似指数 SSIM 评估去雾图像质量。不同算法的去雾效果如图 8 所示。




图 8 不同算法去雾效果对比图

由图 8 可知：DCP 去雾算法方法处理的图像部分区域颜色失真比较严重，视觉效果较差。而经过 DeHazeNet 算法及阶梯式去雾算法处理的图像虽然基本没有出现颜色失真的区域，但 DeHazeNet 方法处理后的图像中还残留有大量雾，部分细节上还存在模糊现象。

阶梯式去雾方法和 DeHazeNet 方法去雾效果相差不大，而且图像整体亮度低。MSCMN 虽然减少了大气散射模型变量的估算，整体去雾效果优于前几种方法，但去雾结果仍有部分不太理想。本文提出的方法充分开展了图像去雾和细节恢复工作，去雾效果最为清晰且细节可见性较强。因此验证了基于多算法融合的去雾技术对图像去雾的有效性。不同去雾方法在 5 种数据集上的去雾效果评价指标如表 3 所示。

表 3 不同方法的 PSNR 和 SSIM 指标对比

数据集指标 方法	ITS		SOTS		HSTS		OTS		RTTS	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
DCP	16.61	0.855	19.14	0.861	11.94	0.762	11.99	0.528	13.27	0.576
DehazeNet	19.82	0.821	24.75	0.927	12.85	0.751	14.58	0.688	15.77	0.697
MSCMN	32.51	0.977	33.64	0.982	17.34	0.862	23.93	0.891	24.36	0.749
阶梯式去雾算法	20.51	0.816	24.14	0.92	13.94	0.743	15.34	0.704	16.45	0.684
本文方法	35.16	0.988	33.78	0.985	17.48	0.864	20.73	0.813	25.80	0.875

由表 3 可知, 在不同数据集上进行测试, 本文提出的方法计算得到的峰值信噪比 PSNR 和结构相似指数 SSIM, 比其他传统方法得到的数值高, 均为最优值。

因此评价指标进一步验证了本文提出的去雾算法的有效性。

此外, 同时记录在 SOTS 数据集和 OTS 数据集下不同算法在单幅图像去雾平均时间, 如表 4 所示。

表 4 不同数据集下图像识别准确率

模型	SOTS 数据集	OTS 数据集
DCP	1.60	2.33
DehazeNet	2.15	2.46
MSCMN	2.39	2.71
阶梯式去雾算法	1.06	1.32
本文方法	0.72	1.08

由表 4 可知: 本文提出的去雾算法在 SOTS 数据集和 OTS 数据集上单幅图像去雾效率最高, 所需时间最短。

3.4 消融实验与分析

为验证本文提出的算法中各模块的有效性, 分别对多尺度特征提取模块、多尺度特征融合模块以及去雾优化模块进行了消融实验, 本文选取 3 个图像进行分析, 分别记录原始图像、Ground Truth 图像、多尺度特征提取模块、多尺度特征融合模块以及多模块融合模块在处理有雾图像时的消融实验, 不同模块的消融实验得到的峰值信噪比 PSNR 和结构相似度 SSIM 结果如表 5 所示。

表 5 不同模块的消融实验定量比较

	PSNR	SSIM
Ground Truth 图像	14.22	0.58
多尺度特征提取模块	14.73	0.63
多尺度特征融合模块	14.35	0.62
多模块融合模块	17.91	0.70

由表 5 可知, 本文研究的多模块融合模块在消融实验中的 PSNR 和 SSIM 值最大, 去雾效果接近无雾图像, 验证了本算法实现的消融效果的最优性。

去雾结果如图 9 所示。

由图 9 可知, 在消融实验中, 经过多模块融合模块处理的去雾图像与原始图像最接近, 且细节处理最为清晰, 既克服了经过多尺度特征提取模块处理后局部细节颜色失真的情况 (图像 1 凳子把手颜色失真), 又避免出现经过多尺度特征提取模块和多尺度特征融合模块融合模块处理后的细节信息模糊且色彩恢复不足的现象 (图像 2 墙面颜色偏暗), 从而验证本文所提方法中各个组件消融的有效性。

同时为了更全面地评价本文所提出的模型, 本文将所提出的模型与其他去雾模型的复杂性和计算效率进行



图 9 消融实验结果对比

了比较, 其中设定运行时间为模型处理一张 512×512 大小的图像所消耗的时间。

表 6 为本文所提出的模型与其他去雾模型的参数量和平均运行时间的比较结果。

表 6 不同模型的参数量和运行效率比较结果

模型	参数量	运行时间/ms
本文所提出的模型	10.60 M	57.19
DCP 模型	17.38 M	71.93
DehazeNet 模型	12.57 M	68.01
MSCMN 模型	24.59	95.01
阶梯式去雾算法模型	14.45	63.57

由表 6 可知, 本文所提出的模型不管是在参数量上还是在运行时间上, 都比其他基于深度学习的方法提出的模型参数量更小、运行时间更短。

4 结束语

为解决传统去雾算法存在的去雾效果差、去雾效率低等问题, 本文深入研究卷积神经网络算法工作原理, 建立间接去雾模型, 引入多尺度空间特征提取和特征融合模块, 利用局部连接和权值共享对去雾模型进行优化, 同时加入优化的 Attention 机制完成去雾模型的训练, 最后通过设置不同数据集, 分析去雾效果评价指标, 进行实验对比, 分析去雾效果、峰值信噪比 PSNR 和结构相似度 SSIM, 充分验证了基于多算法融合的去雾算法的有效性。通过去雾和消融实验, 结果表明: 该算法去雾效果明显、去雾效率高, 能够清晰、快速识别目标, 有效提高了自动驾驶汽车的环境感知能力, 有助于自动驾驶汽车安全出行。但是, 图像去雾是一个较为复杂的过程, 当有雾图像中浓雾区域占比较大时, 会导致图像中的部分细节与背景信息看不清, 有用特征提取难度增大, 使得算法的去雾效果降低, 因此后续采用学习能力更强的算法提高去雾算法的鲁棒性, 并应用在高级视觉任务如目标检测、目标识别、目标追踪的成功率中, 是今后研究和改进的重点方向。

- 参考文献:**
- [1] 刘树东, 姚文渤, 张 艳. 雾天条件下基于机器视觉的森林火灾监测 [J]. 计算机工程与科学, 2020, 42 (7): 1253-1261.
 - [2] 冷贵峰, 孙学宝, 王 宇. 恶劣天气环境下图像快速清晰化算法 [J]. 控制工程, 2017, 24 (9): 1930-1934.
 - [3] LIU Z, TAN Y, HE Q, et al. Swin net: swin transformer drives edge-aware RGB-D and RGB-T salient object detection [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2021, 32 (7): 4486-4497.
 - [4] 杨 亿. 基于深度学习的图像去雾算法研究 [D]. 南京: 南京邮电大学, 2023.
 - [5] 何立风, 周广彬, 姚 斌, 等. 基于引导系数加权和自适应图像增强去雾算法 [J]. 微电子学与计算机, 2020, 37 (9): 73-77.
 - [6] 郑 敏. 基于 Retinex 理论的图像去雾去噪算法 [J]. 智能计算机与应用, 2020, 10 (2): 93-96.
 - [7] 张冬明, 靳国庆, 代 锋, 等. 基于深度融合的显著性目标检测算法 [J]. 计算机学报, 2019, 42 (9): 2076-2086.
 - [8] 何信华, 赵 龙. 基于改进高斯混合模型的实时运动目标检测与跟踪 [J]. 计算机应用研究, 2010, 27 (12): 4768-4771.
 - [9] 田 源. 基于混合远景和近景区域暗通道算法的图像去雾研究 [J]. 计量学报, 2019, 40 (4): 583-588.
 - [10] REN W, MA L, ZHANG J, et al. Gated fusion network for single image dehazing [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 3253-3261.
 - [11] 杨 燕, 王志伟. 基于均值不等关系优化的自适应图像去雾算法 [J]. 电子与信息学报, 2020, 42 (3): 755-763.
 - [12] 潘健鸿, 高 银. 基于天空区域分割和多尺度融合的单幅雾天图像复原算法 [J]. 南京理工大学学报, 2019, 43 (5): 592-599.
 - [13] LIU X, MA Y, SHI Z, et al. Griddehazenet: attention-based multi-scale network for image dehazing [C] // Proceedings of the IEEE International Conference on Computer Vision, 2019: 7314-7323.
 - [14] YIN J L, HUANG Y C, CHEN B H, et al. Color transferred convolutional neural networks for image dehazing [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2019, 30 (11): 3957-3967.
 - [15] QIN X, WANG Z, BAI Y, et al. FFA-Net: feature fusion attention network for single image dehazing [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34 (7): 11908-11915.
 - [16] 何宜鸿, 李彦锋, 黄树恺, 等. 基于深度卷积神经网络的自适应图像去雾算法 [J]. 电子科技, 2020, 33 (8): 70-73.
 - [17] 梁志勇. 基于最少帧差法图像识别的智能监控系统的研究 [D]. 广州: 广东工业大学, 2005.
 - [18] 刘广洲, 李金宝, 任东东, 等. 密集连接扩张卷积神经网络的单幅图像去雾 [J]. 计算机科学与探索, 2021, 15 (1): 185-194.
 - [19] 王柯俨, 王 迪, 赵 熹, 等. 基于卷积神经网络的联合估计图像去雾算法 [J]. 吉林大学学报 (工学版), 2020, 50 (5): 1771-1777.
 - [20] 陈清江, 张 雪. 基于全卷积神经网络的图像去雾算法 [J]. 应用光学, 2019, 40 (4): 596-602.
 - [21] 宋聪莹, 邵 清. 基于暗通道先验的 Retinex 去雾算法研究 [J]. 软件导刊, 2021, 20 (1): 214-218.
 - [22] 刘兴瑞. 自适应直方图均衡处理下船舶视频监控图像去雾算法 [J]. 舰船科学技术, 2020, 42 (16): 70-72.
 - [23] 林存毅. 基于多尺度注意力优化的单幅图像去雾方法 [D]. 哈尔滨: 哈尔滨师范大学, 2021.
 - [24] 赵春丽, 董静薇, 徐 博, 等. 融合直方图均衡化与同滤波的雾天图像增强算法研究 [J]. 哈尔滨理工大学学报, 2019, 24 (6): 93-97.
 - [25] LI Y, CHENG D, ZHANG D, et al. Single image dehazing with an independent Detail-Recovery network [J]. Knowledge-Based Systems, 2022, 254: 109579.
 - [26] SHYAM P, YOON K J, KIM K S. Towards domain invariant single image dehazing [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35 (11): 9657-9665.
 - [27] ANCUTI C O, ANCUTI C, Timofte R. NH-HAZE: an image dehazing benchmark with non-homogeneous hazy and haze-free images [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2020: 444-445.
 - [28] KOCH M D, ROHRBACH A J B J. Label-free imaging and bending analysis of microtubules by ROCS microscopy and optical trapping [J]. Biophysical Journal, 2018, 114 (1): 168-177.
 - [29] 李 燕. 基于深度学习的图像去雾算法研究 [D]. 济南: 山东师范大学, 2023.
 - [30] 韩 洋. 基于深度学习的图像雾化去除方法研究 [D]. 哈尔滨: 哈尔滨理工大学, 2023.
 - [31] 路佳琪. 基于卷积神经网络的单幅图像去雾方法研究 [D]. 燕山: 燕山大学, 2022.
 - [32] HE K, FAN H, WU Y, et al. Momentum contrast for unsupervised visual representation learning [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2020: 9729-9738.
 - [33] 汪秦峰, 陈 莉, 樊泰亭, 等. 基于同态滤波和 Retinex 的图像去雾算法 [J]. 火控雷达技术, 2016, 45 (2): 44-51.
 - [34] 肖 俊. 基于深度学习的交通图像识别关键技术研究 [D]. 桂林: 桂林电子科技大学, 2023.