

多模型融合的对抗网络图像去雾研究

尹思源, 王行建*

东北林业大学计算机与控制工程学院, 黑龙江 哈尔滨

收稿日期: 2023年9月3日; 录用日期: 2023年10月1日; 发布日期: 2023年10月7日

摘 要

为了应对单一网络模型在雾天场景下去雾效果不理想的, 去雾后图像颜色失真等问题, 提出一种基于循环生成对抗网络(CycleGAN)的多去雾模型融合的去雾算法。首先, 在整体去雾模型上, 针对不同雾气浓度, 将传统的单一模型改为多去雾模型, 分别将不同浓度的雾气图像传入对应的去雾网络, 接着在生成器模块中引入CBAM注意力机制, 帮助模型可以更好的考虑通道上和空间上的影响, 赋予重要特征以更多的权重, 最后针对生成的无雾图像颜色失真问题, 提出一种基于Lab色彩空间的新的色彩损失函数。实验结果表明, 与传统的CycleGAN模型相比, 本文算法在公共合成数据集和真实世界的图像上取得了更好的性能和更好的视觉效果。

关键词

图像去雾, 循环生成式对抗网络, 信息融合

Research on Defogging of Adversarial Network Images Based on Multi-Model Fusion

Siyuan Yin, Xingjian Wang*

College of Computer and Control Engineering, Northeast Forestry University, Harbin Heilongjiang

Received: Sep. 3rd, 2023; accepted: Oct. 1st, 2023; published: Oct. 7th, 2023

Abstract

In order to deal with the problems such as the unsatisfactory effect of single network model in foggy scenes and the image color distortion after fog removal, a new algorithm based on the fusion of multiple fog removal models based on CycleGAN was proposed. First of all, in terms of the over-

*通讯作者。

all de-fogging model, the traditional single model is changed into a multi-de-fogging model according to different fog concentrations, and the fog images of different concentrations are respectively introduced into the corresponding de-fogging network. Then, CBAM attention mechanism is introduced into the generator module to help the model better consider the influence on channel and space, and give more weight to important features. Finally, a new color loss function based on Lab color space is proposed to solve the color distortion problem of the generated fog free image. The experimental results show that compared with the traditional CycleGAN model, the proposed algorithm achieves better performance and better visual effect on public synthetic data sets and real world images.

Keywords

Image Defogging, Cycle-Consistent Adversarial Network, Information Fusion

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

近年来, 雾霾问题严重地威胁着人们的生存与生存。在雾霾条件下, 由于空气中的微粒及其他粒子的存在, 会导致光线的散射与吸收, 导致场景中的一些细节模糊, 从而降低了成像质量与视觉效果。针对这一问题, 提出了一种基于深度学习的图像去雾的新方法, 将其应用于目标检测、目标识别[1]、语义分割[2]、卫星遥感监测等多个领域, 以改善雾霾环境下的图像质量。

最近的一些研究显示, 图像去雾技术正处于一个非常活跃的发展阶段。最早的几种去除雾霾的方法, 都是建立在经典的物理模型基础上, 再加上滤波技术[3] [4] [5], 其中最具代表性的是: 直方图均衡[6], Retinex 算法[7], 同态滤波[8], 以及小波变换[9]等。然而, 现有的理论模型都假定全影像内的光线和透过系数是均一的, 因此不能精确估算出光线和透过系数, 从而制约了该方法对不同光线条件下的光线变化进行精确建模。针对此问题, 本文在前期工作中提出了一种新的利用暗通道信息的算法[10], 在此基础上, 利用目标区域内的整体极小点以及大气环境下的光线信息, 精确地估算出目标区域的透过系数, 从而实现对目标区域的高分辨率重建。另外, 在计算机视觉领域, 深度学习的快速发展为解决这一问题提供了新的契机。基于 CNN 的深度学习方法是解决当前影像去雾霾问题的一项关键技术。研究人员提出了以深度学习模型为基础的图像去雾算法[11], 其中包括了不需要使用先验知识的 GCAnet [12], 多合一去雾网络 AOD-net [13], 以及 DehazeNet [14]等。

虽然目前已有较大的发展, 但仍面临着许多亟待解决的问题。目前, 在实际应用中, 对复杂环境进行去雾化处理仍是一项极具挑战的课题。现有的去雾方法在背景复杂, 对比度低, 纹理微弱等条件下仍有一定的局限性。同时, 现有的深度神经网络方法也存在着对多场景泛化性能不足的问题, 尤其是在处理未知场景、未知区域的图像去雾等问题时, 难以取得理想效果。

为了解决以上的问题, 并考虑现有的成对的图像去雾数据集有限的问题, 本文选择可采用非配对数据集的循环一致性生成对抗网络 CycleGAN (Cycle-Consistent Adversarial Network) [15]作为网络基础, 利用不同密度雾霾数据集进行训练, 从而形成一种将多个除雾模型进行有效融合的除雾算法。为了提高去雾效果, 本文还给出了一个在 Lab 颜色空间中的图像损失函数。最后, 在该模型中, 为了获得去雾的关键信息, 引入 CBAM 注意力机制[16], 以增强网络对于信息权重的分配。

2. 工作基础

2.1. 循环生成式对抗网络

循环生成式对抗网络 CycleGAN 是一种在生成式对抗网络 GAN(Generative Adversarial Network) [17] 基础上提出的无监督图像转换模型, 用于实现跨域图像的转换。CycleGAN 的目标是学习两个域之间的映射关系。与传统的图像转换方法不同, CycleGAN 不需要成对的训练数据来指导转换, 而是通过对抗学习的方式进行训练。它包括两个生成器网络和两个判别器网络, 分别用于两个域的图像转换和对抗判别[18]。其原理图如图 1 所示, 其中 G_{AB} 与 G_{BA} 分别进行域 A 与域 B 之间的映射, D_A 和 D_B 为这两个生成过程的判别器, 用来判别生成图像是真还是假。




Figure 1. Network structure diagram of CycleGAN

图 1. CycleGAN 网络结构图

生成器 G_{AB} 生成图像 $G_{AB}(a)$, 然后由判别器 D_B 来判断 $G_{AB}(a)$ 是否为真实图像, 其损失函数表示如下表示:

$$L_{GAN}(G_{AB}, D_B, A, B) = E_{b \sim p_{data}(b)} [\lg D_B(b)] + E_{a \sim p_{data}(a)} [\lg(1 - D_B(G_{AB}(a)))] \quad (1)$$

同理 G_{BA} 和 D_A 的损失函数如下表示:

$$L_{GAN}(G_{BA}, D_A, B, A) = E_{a \sim p_{data}(a)} [\lg D_A(a)] + E_{b \sim p_{data}(b)} [\lg(1 - D_A(G_{BA}(b)))] \quad (2)$$

生成器 G_{AB} 将图像 A 转换为 $G_{AB}(a)$, 再由 G_{BA} 转换为 $G_{BA}(G_{AB}(a))$ 后, 为了保证在两次生成的过程中, 图像的质量保持一致, 需要计算原始图像与 $G_{BA}(G_{AB}(a))$ 之间的损失。循环一致损失如下表示:

$$L_{cyc}(G_{AB}, G_{BA}) = E_{a \sim p_{data}(a)} [\|G_{BA}(G_{AB}(a)) - a\|_1] + E_{b \sim p_{data}(b)} [\|G_{AB}(G_{BA}(b)) - b\|_1] \quad (3)$$

最后, CycleGAN 整体的损失函数为以上三个损失函数相结合, 其中 λ 为的权重系数, 组合方式为:

$$L(G_{AB}, G_{BA}, D_A, D_B) = L_{GAN}(G_{AB}, D_B, A, B) + L_{GAN}(G_{BA}, D_A, B, A) + \lambda L_{cyc}(G_{AB}, G_{BA}) \quad (4)$$

2.2. CBAM 注意力机制

CBAM (Convolutional Block Attention Module)是一种于 2018 年提出的轻量级注意力模块,它具有空间和信道两个维度的注意能力,可以实现对图像关键区域的注意。

如图 2 所示, CBAM 由两个子系统组成: 信道注意 CAM (Channel Attention Module)和空间注意 SAM (Spatial Attention Module)两个子系统。在输入了一个特征以后, CAM 模组对其进行一维卷积, 并将其与原始图像相乘, 然后以 CAM 的输出为输入, 在 SAM 模组中进行二维卷积, 最终将其与原始图像相乘, 从而获得权重后的特征。




Figure 2. The overall structure diagram of CBAM

图 2. CBAM 整体结构图

图 3 所示为 CAM 模块的结构图, 在 CAM 模块中, 特征的通道维度不变, 压缩其空间维度。将输入的特征经过两个并行的最大池化层和平均池化层, 将特征图从 $C * H * W$ 变为 $C * 1 * 1$ 的大小, 然后经过 Share MLP 模块, 在该模块中, 它首先将通道数目压缩至原先的 $1/R$ (Reduction, 减少率) 倍, 然后再将通道数目扩展至原通道数, 之后经过 ReLU 激活函数得到两个激活后的结果。将这两个输出结果进行逐元素进行叠加, 再通过一个 Sigmoid 激活函数得到 Channel Attention 的输出结果, 最后将这个输出结果乘原图, 变回 $C * H * W$ 的大小。




Figure 3. Structure diagram of CAM

图 3. CAM 结构图

通道注意力公式:

$$\begin{aligned} M_c(F) &= \sigma \left(MLP(AvgPool(F)) + MLP(MaxPool(F)) \right) \\ &= \sigma \left(W_1 \left(W_0 \left(F_{avg}^c \right) \right) + W_1 \left(W_0 \left(F_{max}^c \right) \right) \right) \end{aligned} \quad (5)$$

图 4 所示为 SAM 模块的结构图, 在 SAM 模块中, 特征的空间维度不变, 压缩其通道维度。将 CAM 的输出结果通过最大池化和平均池化得到两个 $1 * H * W$ 的特征图, 然后经过将两个特征图进行拼接, 通过 $7 * 7$ 卷积变为 1 通道的特征图, 再经过一个 Sigmoid 得到 SAM 的特征图, 最后将输出结果乘原图变回 $C * H * W$ 大小。




Figure 4. Structure diagram of SAM

图 4. SAM 结构图

空间注意力公式:

$$\begin{aligned} M_s(F) &= \sigma \left(f^{7 \times 7} \left(\left[\text{AvgPool}(F); \text{MaxPool}(F) \right] \right) \right) \\ &= \sigma \left(f^{7 \times 7} \left(\left[F_{avg}^s; F_{max}^s \right] \right) \right) \end{aligned} \quad (6)$$

3. 本文方法

本文根据已有图像去雾技术, 提出一种可融合多去雾模型的网络。该网络包含有薄雾, 厚雾和普通雾气三个去雾模型, 分别用薄雾数据集, 厚雾数据集和普通雾气数据集进行训练。整体模型以 CycleGAN 网络架构作为基础, 对其进行了改进, 引入了雾气浓度判别模型以及将多去雾模型效果进行融合的网络结构, 同时通过引入新的色彩损失函数以及 CBAM 注意力机制, 克服当前图像去雾处理中出现的畸变及去雾效果不够真实的问题。

3.1. 多去雾模型网络

图 5 为本文算法的整体结构, 在网络的开始, 图像先经雾气浓度判别模型后产生 0 到 1 的数值, 浓度依据图像的大气光值以及透射率得出, 数值的大小表示雾气浓度的大小, 数值越接近 0, 表示图像雾气浓度越接近薄雾; 数值越接近 1, 表示图像雾气浓度越接近厚雾, 由此数值作为去雾模型效果融合的权重。之后根据此数值去选择相应的两个去雾模型当数值大于 0.5 时, 将厚雾模型和普通雾气模型效果进行融合; 当数值大于小于 0.5 时, 将薄雾模型和普通雾气模型效果进行融合, 雾气浓度值作为融合的权重值; 等于 0.5 时只采用普通雾气模型。

3.2. 雾气合成算法及数据集制作

本文共 3 组数据集, 分别为浓雾数据集, 普通雾气数据集以及薄雾数据集, 其中普通雾气数据集选用 NYU2 公共数据集, 浓雾和薄雾数据集是对 NYU2 数据集中的无雾图像进行雾化处理。

雾化处理过程基于大气散射模型, 公式如下:

$$\begin{aligned} I(x) &= J(x)e^{-\beta d(x)} + A(1 - e^{-\beta d(x)}) \\ t(x) &= e^{-\beta d(x)} \end{aligned} \quad (7)$$

其中 J 为无雾图像, I 为有雾图像, A 为大气光值, d 为深度矩阵, β 为散射系数, t 为透射率。雾化时先

对雾气图像进行大气光值, 透射率的计算, 之后将大气光值和透射率分别提高再将其运用在对应的无雾图像上得到厚雾数据集, 反之得到薄雾数据集图像。




Figure 5. Overall structure of the model

图 5. 模型整体结构

3.3. 改良后的生成器网络结构

图 6 是本文算法中去雾模型的生成器网络结构, 在经典 CycleGAN 模型的生成器的基础上, 在其下采样过程的第 2 层和第 3 层卷积过程中加入 CBAM 注意力模块, 使得模型能够更加集中地关注与任务相关的信息, 忽略无关或噪声的部分。这样可以减少冗余信息的干扰, 提高模型的准确性和泛化能力。




Figure 6. Generator structure diagram

图 6. 生成器结构图

3.4. Lab 色彩空间损失函数

原 CycleGAN 模型中使用的损失函数对于色彩图像的色彩方面缺少足够的控制, 无法保证去雾后图像的质量, 所以本文算法引入 Lab 色彩空间损失函数。

在 Lab 颜色空间中, 颜色被分为 L, a 和 b 三个通道: L 通道表示亮度, a 通道表示从红色到绿色的色调, b 通道表示从黄色到蓝色的色调。

损失函数计算方法为 L1 loss, 具体计算过程为, 将两幅图像转换到 Lab 色彩空间后, 由于 Lab 色彩空间的范围和均衡性可能会导致在计算损失时不同通道的权重不平衡, 先对 L 通道, a 通道和 b 通道进行归一化处理以均衡不同通道的范围, 之后对转换后的 Lab 图像进行逐像素的比较。对于每个像素位置, 计算两个图像在各个通道上的差异, 然后将这些差异进行求和以及平均化, 得到最后的 L1 loss。

4. 实验结果分析

4.1. 实验数据集

本文共有厚雾, 薄雾和普通雾气 3 组训练集, 其中厚雾和薄雾数据集基于 NYU2 [19]数据集制作, 普通雾气训练集直接采用 NYU2 数据集。测试集使用 SOTS [20]数据集。训练过程中, 图像统一先调整为 256 像素 × 256 像素, 然后分别对三种训练集进行训练, 形成三种去雾模型。

4.2. 实验环境

实验环境配置: CPU 为英特尔酷睿 i7-8700 @3.20GHZ, 内存为 16GB, GPU 选用英伟达 RTX 3060 12GB 显存版本, 选用 Pytorch1.11.0 版本作为深度学习框架, Cuda 为 11.6 版本, 解释器为 Python 3.8 版本。

实验参数设置: 学习速率初始化为 0.0002, batch-size 设置为 2, 迭代次数为 200 次, 动量参数设置为 0.5, 优化器采用 Adam 优化。

4.3. 实验结果

为验证本文算法的有效性, 本文在 SOTS 数据集中随机选取 100 张图片进行效果测试, 对比算法选择 DCP、GCANet、DehazeNet 和 AOD-Net 算法, 并从主观评价和客观评价两个方面对所提算法进行了分析。同时, 以结构相似度 SSIM [21]、PSNR [22]为评估指标, 对消雾效果进行更加客观的评估。

图 7 为去雾效果对比图, 经对比可发现 DCP 算法在去雾效果上存在着明显的色彩失真, 同时 GCANet、AOD-Net 和 DehazeNet 算法的去雾效果不彻底, 仍留有薄雾, 其中 GCANet 算法对天空去雾效果色彩也存失真问题。经过表 1 的客观数值对比分析可以发现, 本文算法在 SOT 数据集上的 PNSR 和 SSIM 数据均得到了较高值, 与其它方法相比, 本文方法能获得更好的图像质量。






Figure 7. Comparison of fog removal effect of different algorithms
图 7. 不同算法去雾效果对比图

Table 1. Comparison of experimental results of different algorithms
表 1. 不同算法实验结果对比

环境	评估指标	DCP 算法	DehazeNet 算法	AOD-Net 算法	GCANet 算法	本文算法
室内	PSNR/dB	17.28	24.54	25.64	28.79	31.37
	SSIM	0.8007	0.8465	0.8774	0.9626	0.9876
室外	PSNR/dB	16.36	23.11	22.78	27.62	31.02
	SSIM	0.8264	0.8651	0.8843	0.9379	0.9824

5. 消融实验

为了进一步证明本文提出的多去雾模型效果融合算法、Lab 色彩损失函数和 CBAM 注意力机制的有效性。本文以 CycleGAN 模型为基础，对加以提出的改进进行对比实验。

对比试验选用 CycleGAN 作为基础对比模型，再加上采用多去雾融合网络模型但未采用 Lab 色彩损失函数和 CBAM 注意力机制的 Model-A、采用多去雾融合网络模型和 CBAM 注意力机制的 Model-B 和同时采用多去雾融合网络模型，CBAM 注意力机制以及 Lab 色彩损失函数 Model-C 共 4 个模型进行测试。

正如在图 8 中所示，基础的 CycleGAN 模型在雾气去除方面是有一定的效果的，但在将去雾后的图像与原始无雾图像进行对比过后，我们可以发现经过基础的 CycleGAN 网络处理后的图像在色彩还原方面并不理想，使得去雾效果不自然，而引入多去雾模型融合以及 Lab 色彩损失函数和 CBAM 注意力机制的网络模型所生成的图像同基础的 CycleGAN 网络生成的图像相比，去雾效果都要更好一些，图像去雾后更加自然。同时经过表 2 中的客观数值对比可以发现在 SSIM 和 PNSR 两项数值上来说，本文算法改进后的模型均取得更高值，更有说服力地证明本文算法改进是真实有效的。




Figure 8. Comparison chart of ablation algorithm effects

图 8. 消融算法效果对比图

Table 2. Comparison of ablation algorithm effects

表 2. 消融算法效果对比

评估指标	CycleGAN	Model-A	Model-B	Model-C
PSNR/dB	20.28	24.54	28.64	30.79
SSIM	0.8607	0.9265	0.9674	0.9826

6. 结论

本文设计了一种基于 CycleGAN 模型的多去雾模型效果融合的图像去雾算法, 该算法以不同浓度的雾气图像训练集进行分别训练, 使得更有针对性的对复杂雾气图像进行去雾工作。通过对试验结果的分析, 本文算法产生的图像, 不管是在视觉感受上, 还是在客观指标值上, 都要比原始网络更好。它可以更好地保存图像中的一些细节信息, 比如天空区域等, 对亮度转换区域转变不自然的问题进行了改进, 同时还对去雾图像中存在的颜色失真和细节缺失等问题进行了改进。结果表明, 与常规的去雾算法比较, 该算法对图像中雾气现象有着较好的抑制作用, 且能获得较好的视觉结果。

基金项目

黑龙江省自然科学基金项目(LH2020C048)。

参考文献

- [1] 董鹏曙, 向龙, 谢幼才, 等. 基于运动补偿的动目标检测处理方法[J]. 探测与控制学报, 2020, 42(6): 29-34.
- [2] 刘尚旺, 崔智勇, 李道义. 基于 Unet 网络多任务学习的遥感图像建筑地物语义分割[J]. 国土资源遥感, 2020, 32(4): 74-83.

- [3] Dou, Z., Han, Y., Sheng, W., et al. (2015) Image Dehaze Using Alternating Laplacian and Beltrami Regularizations. *Journal of Electronic Imaging*, **24**, Article ID: 023004. <https://doi.org/10.1117/1.JEI.24.2.023004>
- [4] 覃宏超, 李炎炎, 龙伟, 等. 基于引导滤波和暗原色先验理论透射率估值的视频去雾算法[J]. 浙江大学学报: 工学版, 2018, 52(7): 1302-1309.
- [5] Jin, W., Mi, Z., Wu, X., et al. (2012) Single Image de-Haze Based on a Newdark Channel Estimation Method. 2012 *IEEE International Conference on Computer Science and Automation Engineering*, Zhangjiajie, 25-27 May 2012, 791-795. <https://doi.org/10.1109/CSAE.2012.6272884>
- [6] Sengupta, D., Biswas, A. and Gupta, P. (2021) Non-Linear Weight Adjustment in Adaptive Gamma Correction for Image Contrast Enhancement. *Multimedia Tools and Applications*, **80**, 3835-3862. <https://doi.org/10.1007/s11042-020-09583-1>
- [7] Tang, Q., Yang, J., He, X., et al. (2021) Nighttime Image Dehazing Based on Retinex and Dark Channel Prior Using Taylor Series Expansion. *Computer Vision and Image Understanding*, **202**, Article ID: 103086. <https://doi.org/10.1016/j.cviu.2020.103086>
- [8] Liang, J., Ju, H., Ren, L., et al. (2020) Generalized Polarimetric Dehazing Method Based on Low-Pass Filtering in Frequency Domain. *Sensors*, **20**, 1729. <https://doi.org/10.3390/s20061729>
- [9] Chen, Z. and Ou, B. (2021) Visibility Detection Algorithm of Single Fog Image Based on the Ratio of Wavelength Residual Energy. *Mathematical Problems in Engineering*, **2021**, Article ID: 5531706. <https://doi.org/10.1155/2021/5531706>
- [10] He, K.M., Sun, J. and Tang, X.O. (2011) Single Image Haze Removal Using Dark Channel Prior. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **33**, Article ID: 12301542. <https://doi.org/10.1109/TPAMI.2010.168>
- [11] Ju, M., Ding, C., Zhang, D., et al. (2018) Gamma-Correction-Based Visibility Restoration for Single Hazy Images. *IEEE Signal Processing Letters*, **25**, 1084-1088. <https://doi.org/10.1109/LSP.2018.2839580>
- [12] Chen, D., He, M., Fan, Q., et al. (2019) Gated Context Aggregation Network for Image Dehazing and Deraining. 2019 *IEEE Winter Conference on Applications of Computer Vision (WACV)*, 7-11 January 2019, Waikoloa Village, 1375-1383. <https://doi.org/10.1109/WACV.2019.00151>
- [13] Li, B., Peng, X., Wang, Z., et al. (2017) Aod-Net: All-In-One Dehazing Network. *Proceedings of the IEEE International Conference on Computer Vision*, Venice, 22-29 October 2017, 4770-4778. <https://doi.org/10.1109/ICCV.2017.511>
- [14] Cai, B., Xu, X., Jia, K., et al. (2016) Dehazenet: An End-to-End System for Single Image Haze Removal. *IEEE Transactions on Image Processing*, **25**, 5187-5198. <https://doi.org/10.1109/TIP.2016.2598681>
- [15] Zhu, J.Y., Park, T., Isola, P., et al. (2017) Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks. *Proceedings of the IEEE International Conference on Computer Vision*, Venice, 22-29 October 2017, 2223-2232. <https://doi.org/10.1109/ICCV.2017.244>
- [16] Woo, S., Park, J., Lee, J.Y., et al. (2018) Cbam: Convolutional Block Attention Module. *Proceedings of the European Conference on Computer Vision (ECCV)*, Munich, 8-14 September 2018, 3-19. https://doi.org/10.1007/978-3-030-01234-2_1
- [17] Goodfellow, I., Pouget-Abadie, J., Mirza, M., et al. (2014) Generative Adversarial Nets. *Proceedings of the 27th International Conference on Neural Information Processing Systems*, Vol. 2, 2672-2680.
- [18] 黄山, 贾俊. 基于改进循环生成式对抗网络的图像去雾方法[J]. 计算机工程, 2022, 48(12): 218-223, 231. <https://doi.org/10.19678/j.issn.1000-3428.0064162>
- [19] Silberman, N., Hoiem, D., Kohli, P., et al. (2012) Indoor Segmentation and Support Inference from RGBD Images. *Proceedings of the 12th European Conference on Computer Vision*, Florence, 7-13 October 2012, 746-760. https://doi.org/10.1007/978-3-642-33715-4_54
- [20] Yuan, F. and Huang, H. (2018) Image Haze Removal via Reference Retrieval and Scene Prior. *IEEE Transactions on Image Processing*, **27**, 4395-4409. <https://doi.org/10.1109/TIP.2018.2837900>
- [21] Wang, Z., Bovik, A.C., Sheikh, H.R., et al. (2004) Image Quality Assessment: from Error Visibility to Structural Similarity. *IEEE Transactions on Image Processing*, **13**, 600-612. <https://doi.org/10.1109/TIP.2003.819861>
- [22] Huynh-Thu, Q. and Ghanbari, M. (2008) Scope of Validity of PSNR in Image/Video Quality Assessment. *Electronics Letters*, **44**, 800-801. <https://doi.org/10.1049/el:20080522>