

变电站表计读数环境预判断模型

侯春萍, 曹凯鑫, 王致芃*

天津大学电气自动化与信息工程学院, 天津 300072

摘要 为了解决变电站智能巡检机器人对环境的预判断缺乏有效评估的问题,以雾环境下的表计读数为研究对象,提出一种基于支持向量回归机(SVR)的表计读数环境预判断模型。该模型利用离散余弦变换(DCT)频域特征和基于局部二值模式旋转不变算子的空间结构特征来反映雾浓度,利用深度图像的统计特征来反映距离,利用SVR对所有图像特征进行训练拟合,从而综合考虑雾浓度与距离对表计读数造成的影响,提高判别准确率。在采集的图像数据库上对算法进行测试并与其他算法进行对比。实验结果表明,与未加入深度图特征相比,深度图特征的加入显著提升各算法的性能,有效反映占屏比对表计读数的影响;与其他相关算法相比,所提算法的性能最优,能够有效解决环境预判断的问题。

关键词 图像处理; 智能巡检机器人; 环境感知; 频域特征; 结构特征; 深度图特征

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202158.1210026

Environment Pre-Judgment Model of Substation Meter Reading

Hou Chunping, Cao Kaixin, Wang Zhipeng*

School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China

Abstract To solve the problem of the lack of effective evaluation of environmental pre-judgment by the intelligent inspection robot of the substation, the meter reading in the fog environment is considered the research object, and a support vector regression (SVR)-based meter reading environmental pre-judgment model is proposed. The proposed model uses discrete cosine transform (DCT) frequency domain and spatial structure features based on the local binary pattern rotation invariant operator to reflect the fog density. Besides, it uses the statistical features of the depth image to reflect the distance and SVR to train and fit all image features. Thus, the influence of fog density and distance on the meter reading is comprehensively considered, and the discrimination accuracy is improved. The proposed algorithm is tested on the collected image database and compared with the existing algorithms. The experimental results show that the addition of the depth map feature significantly improves the performance of each algorithm compared with the absence of the depth map feature. It effectively shows the influence of the screen ratio on the meter reading. Compared with other related algorithms, the performance of the proposed algorithm is optimal. The proposed algorithm can effectively solve the problem of environmental pre-judgment.

Key words image processing; intelligent inspection robot; environmental perception; frequency domain features; structural features; depth image features

OCIS codes 100.2000; 100.2960; 100.3010; 110.3000

1 引言

表计读数是变电站巡检机器人的核心任务之

一,其结果反映着变电站各设备的运行情况,而读数结果的准确性与采集图像的现场环境息息相关。变电站多修建于山区或郊外,受到地理条件的影响,该

收稿日期: 2020-09-29; 修回日期: 2020-10-18; 录用日期: 2020-12-14

基金项目: 国家自然科学基金(61520106002)、南方电网公司科技项目(ZBKJXM20170086)

* E-mail: zpwang@tju.edu.cn

区域易遭遇浓雾天气^[1],使得采集到的表计图像可能会产生不同程度的模糊失真。此外,巡检过程中,机器人与表计之间的距离会不断变化,当距离过大时,会造成采集到的表计图像占屏比过小,导致表针难以分辨。受到雾浓度和距离两种因素的共同影响,采集到的图像质量会有不同程度的下降,这增加了表计读数的难度,降低了表计读数算法^[2-7]的准确率。因此,机器人需要搭载一种表计读数环境预判断模型,通过评估图像质量可以自动感知当前现场环境是否适合采集图像,为机器人寻找最佳的图像采集时机及位置提供判别依据,从而使最终采集到的表计图像更适宜读数,减少环境因素对表计读数造成的影响。

对于雾环境的评估^[8-12],主要通过以下两种方式:第一,利用能见度或能见距离^[13]来衡量雾浓度,精度约为 10 m,其判定结果的颗粒度大大超出了机器人的工作范围,因此不适用;第二,雾环境下采集图像会导致图像质量下降,无参考图像质量评价(BIQA)算法^[14-24]通过提取雾敏感特征来评估图像质量,常被用于雾浓度预测模型^[25-27],因此可在一定程度上完成表计读数环境的预判断工作,但其评估的是整幅图像的质量,忽略了表计占屏比的影响,当加入距离因素时,将无法进行有效判别。

综上所述,在表计读数环境的预判断方面,传统的能见度方法和 BIQA 算法目前都还存在一定的不足。鉴于此,本文提出一种表计读数环境预判断模型并用以完成相关工作。该模型主要有三个贡献:第一,借鉴图像质量评价的思想提出一种基于单幅图像的机器人表计读数环境预判断方法,该方法满足变电站巡检机器人的载荷特点,为巡检机器人的智能环境感知提供新的解决办法;第二,引入深度图像的统计特征并用来反映距离,综合考虑距离和雾浓度的共同影响可以弥补传统 BIQA 算法在表计读数环境预判断方面的不足;第三,构建模型的过程中,建立贴近实际使用环境的表计雾环境图像数据集,包含大量的不同背景、不同距离表计图像及相应的主观评分,使该数据集具有充足性和完备性。实验结果表明,所提算法与传统方法相比,性能更具优势。

2 相关工作

变电站智能机器人巡检系统的环境感知工作主要受到雾浓度和距离两种因素的影响。对于距离因素,目前还缺乏有效研究。对于雾浓度判别,目前主

要存在两种方式,即利用能见度或能见距离对雾浓度进行粗略估计,以及采用质量评价方法来构建雾浓度估计模型。

2.1 能见度估计模型

传统的雾浓度估计方法多采用能见度或能见距离^[12]作为度量指标,该方法总体可分为三类,如人员目测、仪器设备检测和基于视频图像检测^[8-12]。其中人员目测的及时性最差,目测的精准度最低,一般无法用于实际工程;仪器设备检测的精准度较高,但用于能见度检测的仪器设备一般都价格昂贵,不适于大面积分布使用,而且此类设备的体积较大,无法搭载到智能巡检机器人系统上,因此无法满足变电站实时实地的检测需要;近年来,基于视频图像的能见度检测方法得到了广泛关注,而且文献^[8-11]提出了日光有雾条件下的能见度估计模型并对夜间雾浓度进行了评估^[12],但此类方法多是针对交通安全问题,精准度约为 10 m,但当距离超过 2 m 时表计就无法精确读数,故此方法也不适用于表计读数环境的预判断。

2.2 图像质量评价算法

客观质量评价算法通常分为三类:全参考质量评价算法^[28-30]、半参考质量评价算法^[31-33]以及无参考质量评价算法^[14-24]。全参考或半参考质量评价算法均需要输入原始图像或原始图像的部分特征作为参考,然而大多情况下很难获取到原始无失真的图像,因此实际应用中更多采用无需任何参考图像信息的无参考质量评价算法。无参考图像质量评价算法通过提取不同图像特征并结合主观评分进行训练来得到评价模型^[14-20],最终完成图像评分。使用自然场景统计(NSS)模型来统计大量无失真自然图像的特征以得到“有规律”的分布,接着利用“距离指标”度量失真图像与自然图像之间的特征分布差异,从而估计测试图像的质量分数^[21-24]。然而无论何种质量评价算法,针对的都是整幅图像而非表计区域,这就忽略了距离对表计读数的影响。当表计由距离较远而导致占屏比较小时,即使图像质量很高也会无法读数,因此仅依赖质量评价算法也无法完成读数环境的预判断工作。

3 表计读数环境预判断模型

基于支持向量回归(SVR)的两步模型框架如图 1 所示,其中 DCT 为离散余弦变换。首先提取图像频域特征和空间域结构特征来反映雾浓度,并提取深度图像的统计特征以反映距离,提取的图像




图 1 表计读数环境预判断模型的框架

Fig. 1 Framework of environmental prejudgment model for meter reading

特征具有完备性。然后将提取到的各特征向量进行归一化处理,并利用 SVR 对其进行训练,最终得到表计读数环境的预判断数据。

3.1 基于 DCT 的频域特征

一幅图像由多种频率成分组成,图像的频域通常包含丰富的视觉信息。一般来说,人眼对于图像低频分量的变化更为敏感,这是由于图像信息多集中在低频部分。当图像受到雾浓度的影响而产生模糊时,这会导致图像信息的丢失,而且低频分量会产生明显变化。因此,通过 DCT 将图像由空间域转换到频率域来获取图像的频域信息,并截取低频分量作为特征向量并用来反映雾浓度对图像的影响。




图 2 不同雾浓度下的表计图像及其 DCT 变换图像。(a)分值为 1 的图像;(b)分值为 3 的图像;(c)分值为 5 的图像;(d)分值为 7 的图像

Fig. 2 Meter images and DCT transform images under different fog concentrations. (a) Images with score of 1; (b) images with score of 3; (c) images with score of 5; (d) images with score of 7

3.2 基于局部二值模式算子的空间结构特征

图像结构特征又称纹理特征,是一种整体性统计特征,其包含多个像素点而非单个像素点,可以反映图像纹理特征体现的全局信息,具有良好的抗噪声性能。图像失真不仅影响图像的亮度信息,即改变像素强度,也会破坏图像局部纹理的变化规律,即

二维 DCT 变化公式为

$$F(u, v) = c(u)c(v) \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \times \cos \left[\frac{\pi(2x+1)u}{2M} \cdot \frac{\pi(2y+1)v}{2N} \right], \quad (1)$$

其中

$$c(u) = \begin{cases} \sqrt{1/M}, & u = 0 \\ \sqrt{2/M}, & u = 1, 2, \dots, M-1 \end{cases}, \quad (2)$$

$$c(v) = \begin{cases} \sqrt{1/N}, & v = 0 \\ \sqrt{2/N}, & v = 1, 2, \dots, N-1 \end{cases}, \quad (3)$$

式中: M 和 N 分别为图像的宽和高; (x, y) 为空间采样点; (u, v) 为频域采样点; $F(u, v)$ 为变换系数; $f(x, y)$ 为图像块的像素值。

对不同雾浓度的表计图像进行 DCT 处理,结果如图 2 所示。从图 2 可以看到,在不同雾浓度的情况下,图像的低频分量具有明显的差别;当雾浓度越大时,图像所包含的低频分量越少,即图像信息的损失越大,因此通过提取 DCT 频域中的低频分量特征可以有效反映由雾浓度造成的图像失真程度,最终提取去除直流分量后的归一化 1~21 阶低频对角线 DCT 系数并将其组合作为特征向量。

影响图像的结构信息。因此,基于像素强度的图像空间域结构统计特征的变化情况,可以有效描述图像的失真程度。

基于文献[34]提出的理论,使用局部非线性操作来处理图像亮度具有良好的去相关作用,可通过局部均值减法、除法和归一化来计算图像局部的归

一化亮度 $\hat{I}(x, y)$, 表达式为

$$\hat{I}(x, y) = \frac{I(x, y) - \mu(x, y)}{\sigma(x, y) + C}, \quad (4)$$

式中: $I(x, y)$ 为图像的原始亮度; $x \in 1, 2, \dots, M$, $y \in 1, 2, \dots, N$; C 为一个常量, 防止分母趋于零, 通常 $C=1$; $\mu(x, y)$ 和 $\sigma(x, y)$ 分别为高斯滤波后的结果与标准差。

得到 $\hat{I}(x, y)$ 后, 采用圆型的局部二值模式 (LBP) 算子对其进行处理以获取图像结构信息。不同雾浓度下的表计图像及其对应的归一化预处理后的 LBP 图像如图 3 所示。从图 3 可以看到, 不同雾浓度下的表计图像经过局部非线性归一化与 LBP 处理后, 得到的结果图像去除了天空等环境的影响; 当雾浓度越大时, 图像信息的损失越多, 最后得到的纹理信息也越少; 当雾浓度越小时, 图像信息的损失越少, 最后得到的结构信息越丰富。




图 3 不同雾浓度下的表计图像和归一化预处理后的 LBP 图像。(a) 分值为 1; (b) 分值为 4; (c) 分值为 7

Fig. 3 Meter images and LBP images after normalization pretreatment under different fog concentrations.

(a) Score of 1; (b) score of 4; (c) score of 7

采用 LBP 旋转不变性与等价模式对原始的 LBP 模式进行降维。等价模式规定任意 LBP 模式的跳变不超过两次即为等价模式, 否则为非等价模式。跳变次数记为 U , 计算公式为

$$U(L_{LBP,P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{i=0}^{P-1} |s(g_i - g_c) - s(g_{i-1} - g_c)|, \quad (5)$$

其中

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}, \quad (6)$$

式中: g_c 为中心像素值; g_i 为相邻像素值; P 为采样点的个数; R 为邻域范围; L_{LBP} 为 LBP 模式。采用旋转不变等价模式将 P 位二进制编码转化为 LBP 值, 表达式为

$$L_{LBP,P,R}(i, j) = \begin{cases} \sum_{i=0}^{P-1} s(g_i - g_c), & U(L_{LBP,P,R} \leq 2) \\ P + 1, & \text{other} \end{cases}. \quad (7)$$

进一步计算等价模式统计直方图, 能够更好地提取图像本质特征, 表达式为

$$H_{LBP,P,R}(k) = \sum_{i=1}^M \sum_{j=1}^N \hat{I}(i, j) f[L_{LBP,P,R}(i, j), k], \quad (8)$$

其中

$$f(x, y) = \begin{cases} 1, & x = y \\ 0, & \text{other} \end{cases}, \quad (9)$$

式中: $k=0, 1, \dots, P+1$ 。

将像素强度作为权重并加入统计直方图中, 可以综合考虑图像结构和对比度的变化, 能够更有效地反应图像的失真程度。当利用 $L_{LBP,P,R}$ 对图像进行处理时, P 为 8, R 为 1, 则最终得到 10 个模式。为了获取多尺度空间结构信息, 将图像进行缩放处理, 在两个尺度上分别对等价模式进行直方图统计, 提取结构统计特征并进行归一化处理, 最终得到 20 维特征向量。

3.3 深度图像统计特征

除去雾浓度的影响以外, 距离也是影响表计读数的重要因素之一。当距离较近时, 表计占屏比较大, 即使图像受到雾浓度的影响而有一定的模糊, 但也不影响读数结果。当距离较远时, 表计占屏比较小, 即使图像清晰无失真, 也无法准确读数。为此, 提取深度图像特征并用以反映距离对表计读数的影响。深度图像也称为距离图像, 像素值反映了场景各点到图像采集器的距离, 获取深度图像的统计直方图能够有效表征图像的距离。

深度图的估计方法多种多样, 如基于条件随机场 (CRF) 的深度估计方法、非参数深度估计方法以及基于深度学习的方法等。但在有雾的环境下, 空气中悬浮的固体颗粒会造成光的散射和折射, 影响采集到的图像清晰度, 上述方法将很难获得满意的结果。即使是深度学习方法, 由于缺乏对应的清晰

图像也无法通过单张图像来获取到精准的深度图。大气物理模型通过数学方式来描述雾天图像的形成原理,而且很多去雾算法均通过传输模型来恢复无雾图像,因此受到大气物理模型的启发,可以利用大气透射率图(传输图)与深度图之间的关系来获取准确的雾天图像深度图估计。大气物理模型定义为

$$I(x) = J(x)t(x) + A[1 - t(x)], \quad (10)$$

式中: $I(x)$ 为有雾图像; $J(x)$ 为原始无雾图像; A 为全球大气光成分; $t(x)$ 为大气折射率(传输图),表达式为

$$t(x) = \exp[-\beta d(x)], \quad (11)$$

式中: β 为大气消光系数, $\beta > 0$; $d(x)$ 为深度图像。通过 $t(x)$ 即可求得 $d(x)$,表达式为

$$d(x) = -[\ln t(x)]/\beta. \quad (12)$$

对(10)式进行变换,可得

$$\frac{I_C(x)}{A_C} = t(x) \frac{J_C(x)}{A_C} + 1 - t(x), \quad (13)$$

式中: $I_C(x)$ 为每个通道(RGB)的有雾图像; $J_C(x)$ 为每个通道的彩色图像; A_C 为对应通道的大气光成分。

基于 He 等^[35]提出的暗通道理论,无雾图像的亮度值在亮度最低的通道上经过最小值滤波后趋于 0,则对(13)式两端求最小值并进行最小值滤波,即可求得

$$\tilde{t}(x) = 1 - \omega \min_{y \in \Omega(x)} \left[\min_c \frac{I_C(y)}{A_C} \right], \quad (14)$$

式中: $\Omega(x)$ 为以像素 x 为中心的最小滤波器窗口; ω 为恒定参数; $\tilde{t}(x)$ 为改进的大气折射率。 A_C 可通过暗通道前 0.1% 的最大像素值所对应位置的原图像亮度最大值来得到。暗通道理论认为雾的存在可以提升人们对景深的感受,因此设置 $\omega = 0.95$ 来保存一定程度的雾。利用原灰度图像对得到的 $\tilde{t}(x)$ 进行导向滤波处理,即可得到更为精细的传输图 $t(x)$,然后利用大气消光系数 β 及(12)式即可得到准确的 $d(x)$ 。

β 值与波长相关,一般方法都假设此相关可忽略不计,将 β 值近似为常量,这限制了深度图估计的准确性。不同的雾浓度会导致电磁波的波长发生变化,进而影响大气消光系数 β 。因此,针对不同的雾浓度进行深度图估计需要采用不同的 β 值。根据经验可知,雾浓度变化与 β 值成正比,即随着雾浓度的增加 β 值也随之增大。采用 FISH(Fast Image Sharpness)算法^[36](一种基于清晰度的质量评价算法,精准度较高)对样本图像进行评分,然后分析质

量分数与相应 β 值之间的关系。通过实验发现,图像评分越大(图像质量越好)所对应的 β 值越小,可将质量分数大致分为三个等级,分别对应三个 β 值。

根据不同雾浓度图像所对应的 β 值并利用(12)式即可得到相应的深度图像,得到的深度图像经过处理后,像素值处于 $[0, 255]$ 。当计算深度图像的统计直方图时,一般需要去除天空和背景的影响,天空被视为无限远距离,而在深度图像中距离越远像素值越大。因此,对每个像素值的像素个数进行统计,可以获得深度图的空间分布 $H(i)$ ($i = 0, 1, \dots, 255$),然后将 $H(255)$ 置 0 即可去除天空的影响。最后将 $H(i)$ [$H(255) = 0$]平均划分为 16 个子区间,计算落在每个子区间内的像素点个数并进行归一化处理,即可得到 16 维的深度图像统计特征。

迄今为止,得到的图像特征共 56 维,将这些特征输入 SVR 中并进行训练,最终可以得到表计读数环境预判模型,其中核函数选择 RBF(Radial Basis Function)。不同雾浓度下的表计图像及深度图如图 4 所示。




图 4 不同雾浓度下的表计图像及深度图。(a)分值为 1; (b)分值为 4; (c)分值为 7

Fig. 4 Meter images and depth images at different fog concentrations. (a) Score of 1; (b) score of 4; (c) score of 7

4 实验结果及分析

目前,在变电站智能机器人的环境感知方面尚缺乏有效研究,采用无参考质量评价算法可对表计图像进行评分,进而完成环境的预判工作。为了验证提出模型与各类无参考图像质量评级算法的有

效性,采集了不同环境下的表计图像并加以评分,从而制作了表计图像读数环境的数据集,并在该数据集上对不同算法及提出模型进行性能测试。为了验证深度图像特征的有效性,进一步在数据集上对各种算法加入深度图特征前后的性能进行对比测试。

4.1 数据集

采集到的数据集包含不同背景、不同雾浓度和不同距离下的表计图像,共 1500 张,图像尺寸均为 1920 pixel × 1080 pixel,部分图像如图 5 所示。选择 20 人对采集到的图像进行主观评分并取其平均值作为最终评分结果,评分标准为表计读数的难易程度,评分范围为 1~7,其中 1 分最难读数,7 分最易读数。随机选取其中 500 张图像作为测试集,另外 1000 张图像则作为训练集。



图 5 数据集中的部分表计图像

Fig. 5 Partial meter images in dataset

4.2 性能评价指标

若要评价一个算法的优劣,需评价该算法的评分与主观评分的相关度。采取三种评价参数来评估算法的性能。第一种参数为 SROCC (Spearman Rank-Order Correlation Coefficient),其评价的是两组数据的等级相关性,表达式为

$$S_{\text{SROCC}} = \frac{\sum_{p=1}^n (a_p - \bar{a})(b_p - \bar{b})}{\sqrt{\sum_{p=1}^n (a_p - \bar{a})^2 \sum_{p=1}^n (b_p - \bar{b})^2}}, \quad (15)$$

式中: n 为两组数据中的数据个数; \bar{a} 和 \bar{b} 分别为两组数据划分等级后的等级平均值; a_p 和 b_p 分别为两组数据相应的等级划分值。第二种参数为 PLCC (Pearson Linear Correlation Coefficient),其用于评价两组数据的线性相关关系,表达式为

$$P_{\text{PLCC}} = \frac{C_{\text{COV}}(\mathbf{X}, \mathbf{Y})}{\delta_x \delta_y}, \quad (16)$$

式中: \mathbf{X} 和 \mathbf{Y} 为两组数据向量,分别对应两组数据;

$C_{\text{COV}}(\mathbf{X}, \mathbf{Y})$ 为向量 \mathbf{X} 和 \mathbf{Y} 的协方差; δ_x 和 δ_y 分别为两组数据的标准差。最后一个评价标准为 RMSE (Root Mean Squared Error),其用于评估两组数据的一致性,表达式为

$$M_{\text{RMSE}} = \sqrt{\frac{\sum_{p=1}^n (x_p - y_p)^2}{n}}, \quad (17)$$

式中: x_p 和 y_p 分别为实际值与预测值。

三种评价方式中,SROCC 值和 PLCC 值越接近 1, RMSE 值越接近 0,算法性能越好。

4.3 性能测试

BIQA 算法总体可分为两类:完全无参考图像质量评价方法和依据人类主观评分进行训练的方法。实验中,将所提方法分别与 9 种来自两类的算法进行对比。

LPSI (Local Pattern Statistics Index)^[19]、NIQE (Natural Image Quality Evaluator)^[20]、BIQI (Blind Image Quality Indices)^[21] 和 ASIQA (Accelerated Screen Image Quality Evaluator)^[22] 属于完全无参考图像质量评价算法,不需要主观评分以及对失真图像进行训练,直接对输入图像进行处理就可得到质量分数。第二类包含 5 种常用算法,即 BLINDS2 (Blind Image Integrity Notator Using DCT Statistics 2)^[14]、BRISQUE (Blind Referenceless Image Spatial Quality Evaluator)^[15]、GM-LOG-BIQA (Gradient Magnitude-Laplacian of Gaussian-Blind Image Quality Assessment)^[16]、GWH-GLBP-BIQA (Gradient Weighted Histogram of Local Binary Pattern Calculated on the Gradient Map-BIQA)^[17] 和 SSEQ (Spatial-Spectral Entropy-Based Quality)^[18],通过处理失真图像来提取相应特征,并利用 SVR 和图像的主观评分对这些特征进行训练,最终得到评分模型。

对于第一类算法,直接输入测试集的全部图像,即可得到评分结果。第二类算法则需要采集到的表计图像数据集上进行重训练。首先需要对训练集中的所有表计图像进行特征提取,然后利用最终主观评分和 SVR 对提取到的图像特征进行训练以得到评分模型,最后提取测试集中的图像特征并输入评分模型中,从而得到评分结果。得到各算法的测试结果后,利用各个评价指标对各算法的性能进行评估,结果如表 1 所示。

为了方便地比较各类算法,将各算法的类别也列于表中。从表 1 可以看到,第二类算法的总体

表 1 不同算法的性能对比

Table 1 Performance comparison of different algorithms

Algorithm	Type	SROCC	PLCC	RMSE
LPSI	I	0.5224	0.5369	2.1758
NIQE	I	0.7508	0.6940	1.7389
BIQI	I	0.8239	0.8277	1.4612
ASIQE	I	0.8396	0.8657	2.9554
GM-LOG-BIQA	II	0.8347	0.8176	1.3644
BRISQUE	II	0.8478	0.8486	1.3606
GWH-GLBP-BIQA	II	0.8676	0.8482	1.2479
BLINDS2	II	0.9168	0.8817	0.9887
SSEQ	II	0.9178	0.8852	0.9890
Proposed algorithm	II	0.9493	0.9353	0.8280

性能优于第一类算法,尤其是 RMSE 指标,第一类算法的最小值为 1.4612,第二类算法(除去所提算法)的最小值为 0.9890,下降了 0.4722。RMSE 反映了测试结果与真实结果之间的误差,结果表明第一类算法的误差普遍更大。这是因为第一类算法未经过训练而是直接对测试集进行处理,第二类算法则均基于真实评分在采集到的训练集上进行重训练。训练集与测试集的相关性,以及训练过程中所添加的反映距离的深度图特征,使第二类方法的测试结果与真实结果之间的误差更小,也具有更好的关联性。

此外,所提算法在 SROCC、PLCC 和 RMSE 三个指标上都达到了最佳的预测性能,而且是唯一一个 SROCC 值和 PLCC 值均超过 0.9 的算法。所提算法的 SROCC 值和 PLCC 值分别为 0.9493 和 0.9353,而 RMSE 值仅有 0.8280,与第一类算法中性能最优的 ASIQE 算法相比,所提算法的 SROCC 值和 PLCC 值分别提高 0.1097 和 0.0696, RMSE 值降低 2.1274。进一步与另外 5 种的第二类算法

相比,与其中性能最优的为 SSEQ 法相比,所提算法相应的 SROCC 值和 PLCC 值分别提高 0.0315 和 0.0501, RMSE 值降低 0.1610,性能提升的原因在于所提算法所提取的图像特征更为全面。除去深度图特征,所提算法还提取了 DCT 频域特征以及空间域结构统计特征,而其他算法有的只针对空间域提取图像特征,如 GM-LOG-BIQA 算法、BRISQUE 算法和 GWH-GLBP-BIQA 算法,有的只针对 DCT 频域特征提取特征,如 BLINDS2 算法。SSEQ 算法虽然在空间域和 DCT 域均提取了熵值特征,也反映了失真对图像整体信息量的影响,但却忽略了图像结构的变化,而所提算法对图像质量的变化更为敏感,最终得到的结果也更加精确。

4.4 可视化对比

散点图能够更直观地体现各种算法的性能,由于第一类算法的误差较大,因此只将所提算法与第二类的 5 种算法进行对比,结果如图 6 所示。从图 6 可以看到,所提算法的散点分布最为紧密,性能最好;与所提算法类似,SSEQ 算法也提取了时域和频域特征,因此效果也最为接近;BLINDS2 算法虽然数值与 SSEQ 算法相差较小,但由散点图可以看到,分布更为分散,性能较差。

4.5 深度图特征的性能对比

为了证明深度图特征的有效性,将第二类算法不包含深度图特征的评分模型与最终模型进行性能对比,结果如表 2 所示。从表 2 可以看到,各算法加入深度图特征后,性能都有明显提升,这证明深度图特征可以有效反映距离或占屏比对表计读数的影响;对于所提算法,加入深度图特征后的 SROCC 值和 PLCC 值分别提高 0.0386 和 0.0533, RMSE 值降低 0.0540,与其他算法加入深度图特征后相比,所提算法的最终性能最优。

表 2 不同算法在有无深度图特征下的性能对比

Table 2 Comparison of performance of different algorithms with or without depth map feature

Algorithm	Without depth feature			With depth feature		
	SROCC	PLCC	RMSE	SROCC	PLCC	RMSE
BLINDS2	0.8202	0.7907	1.2734	0.9168	0.8817	0.9887
BRISQUE	0.7614	0.7441	1.4170	0.8478	0.8486	1.3606
GM-LOG-BIQA	0.7211	0.7153	1.6692	0.8347	0.8176	1.3644
GWH-GLBP-BIQA	0.7919	0.7541	1.5858	0.8676	0.8482	1.2479
SSEQ	0.8275	0.8026	1.2948	0.9178	0.8852	0.9890
Proposed algorithm	0.9107	0.8820	1.4994	0.9493	0.9353	0.8280

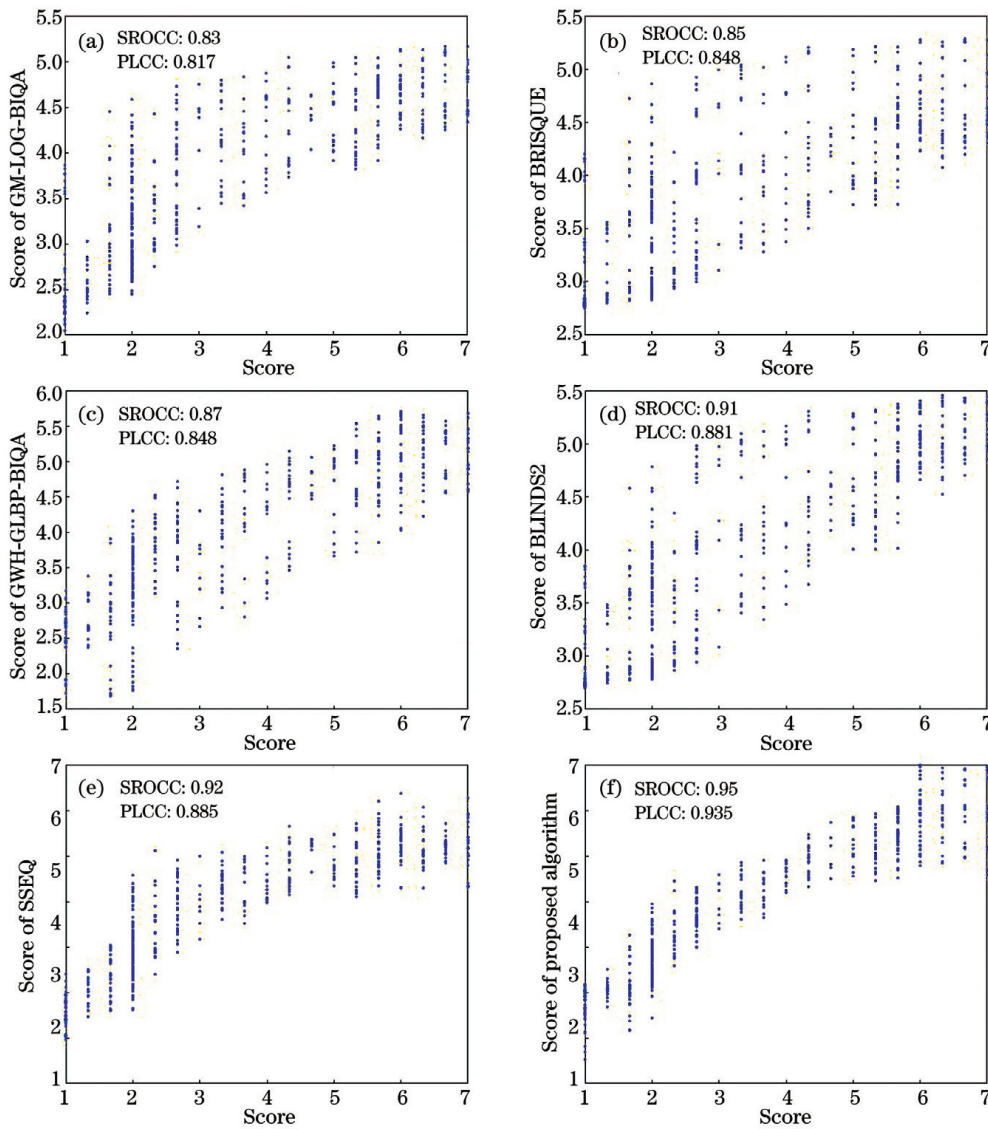


图 6 不同算法的最终评分散点图。(a)GM-LOG-BIQA 算法;(b)BRISQUE 算法;(c)GWH-GLBP-BIQA 算法;
(d)BLINDS2 算法;(e)SSEQ 算法;(f)所提算法

Fig. 6 Final evaluation scatterplots of different algorithms. (a) GM-LOG-BIQA algorithm; (b) BRISQUE algorithm;
(c) GWH-GLBP-BIQA algorithm; (d) BLINDS2 algorithm; (e) SSEQ algorithm; (f) proposed algorithm

4.6 其他对比实验

4.6.1 DCT 频域特征与 LBP 结构特征的有效性

4.5 节验证了深度特征的有效性,此外实验还提取了 DCT 频域特征和空间域结构统计特征。为了验证这两种特征的有效性,分别将去除两种特征的评分模型与最终模型进行性能对比,结果如表 3 所示。从表 3 可以看到,去除 DCT 频域特征和空间域结构特征后,SROCC 值分别下降 0.0973 和 0.0722,PLCC 值分别降低 0.0886 和 0.0786,而 RMSE 值的增长甚至超出了 100%,模型性能明显下降。综上结果表明,所提算法可以有效反映图像信息,对模型起到了重要的作用。

表 3 所提算法在去除 DCT 特征和空间结构特征后的性能对比

Table 3 Comparison of performance of proposed algorithm after removing DCT features and spatial structure features

Feature	SROCC	PLCC	RMSE
Without DCT feature	0.8520	0.8467	1.9713
Without structural feature	0.8771	0.8567	1.9711
Without all features	0.9493	0.9353	0.8280

4.6.2 β 取值的影响

受到不同雾浓度的影响,则电磁波的波长会发

生变化,进而影响 β 的取值。实验对 β 的固定取值与根据 FISH 算法的不同评分所取得的值进行对比,结果如表 4 所示。从表 4 可以看到,当 β 根据不同雾浓度分别取值时,性能优于 β 取固定值。

表 4 不同 β 值的性能对比

Table 4 Performance comparison with different β values

β	SROCC	PLCC	RMSE
2.0	0.9327	0.9033	1.0548
2.5	0.9356	0.9168	0.9877
3.0	0.9350	0.9142	1.0127
Fixed value	0.9493	0.9353	0.8280

4.7 不同距离下的表计图像直方图

当采集距离超出 2 m 时,表计占屏比过小,造成无法读数,因此采集距离一般在 2 m 以内。实际应用中很难直接获取到真实深度图,故所提算法基于大气物理模型进行深度图估计。不同距离下的表计图像及其对应的深度估计直方图如图 7 所示。实验发现,不同距离下表计图像的深度估计直方图变化很大,因此所提算法利用深度图统计特征可以有

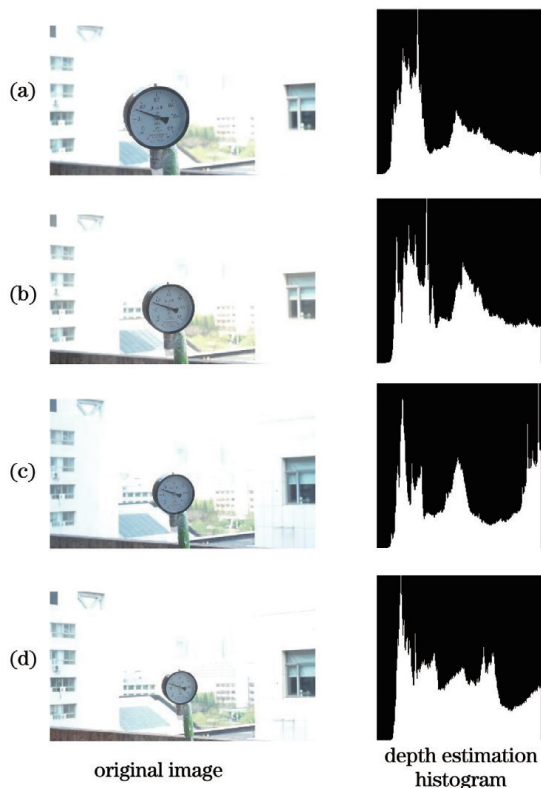


图 7 不同距离下的表计图像及其对应的深度估计直方图。

(a) 1.00 m; (b) 1.25 m; (c) 1.50 m; (d) 1.75 m

Fig. 7 Meter images and their corresponding depth estimation histograms at different distances.

(a) 1.00 m; (b) 1.25 m; (c) 1.50 m; (d) 1.75 m

效表征距离,且误差小于 0.25 m。

4.8 硬件系统的实现

本模型的硬件系统采用 TX1,其搭载了 4 核 CPU 以及 GPU,并配有一块完整的接口载板。GPU 可用来进行与图像相关的操作,利用 CUDA 的核函数并使用并行多线程可以提高处理效率。CPU 的 4 核并行计算也可以大大提高程序的运行速度。CPU 和 GPU 共用 4 G LPDDR4 内存,16 G eMMC5.1 闪存,并使用 SATA 接口外接固态硬盘,而且添加 10 G 的交换内存。载板部分可以连接外设,如摄像头和无线天线等,从而增加了 TX1 的额外功能。

TX1 作为一种小型的计算机群,核心板只有信用卡大小,载板也只有平板大小。变电站巡检机器人为国自机器人,尺寸为 900 mm × 650 mm × 1000 mm,因此 TX1 的体积能够满足变电站机器人搭载的要求。此外, TX1 配置高,性能好,经过实验证明,单张表计图像利用模型完成评分的时间仅需 0.047 ms,能够满足模型运行的硬件条件。本模型采用海康摄像头,与国自机器人采用的摄像头同为一种品牌,因此该模型硬件部分能够满足变电站巡检机器人各方面的要求,故可以将模型搭载在巡检机器人上,实时实地抓取图像,从而完成表计读数环境的预判工作。

5 结 论

提出一种基于 SVR 的变电站表计读数环境预判模型。雾浓度和距离是对表计读数影响最大的两个环境因素,传统的图像质量评价算法只能评估雾浓度,无法有效判别距离因素的影响。考虑到这一点,通过提取深度图像的统计特征来描述距离。实验结果表明,通过添加深度图像的统计特征可以显著提高各算法评估的准确性,并且由于提出模型的图像特征更具完整性,使得该模型的性能优于其他算法。提出的模型能够根据单幅图像来快速判断工作环境是否适合采集图像并进行读数,有效解决机器人确定最佳图像采集点的问题,使得采集到的表计图像更易读数且读数结果更加精确,增强了变电站智能机器人的实用性。影响表计读数的环境因素除雾浓度和距离外还有光照和角度等,接下来主要研究方向就是将这些因素也加入到评价过程中,提出一种更加全面的表计读数环境预判模型。

参 考 文 献

- [1] Tardif R, Rasmussen R M. Event-based climatology

- and typology of fog in the New York City region[J]. *Journal of Applied Meteorology and Climatology*, 2007, 46(8): 1141-1168.
- [2] Gao J W, Xie H T, Zuo L, et al. A robust pointer meter reading recognition method for substation inspection robot [C] // 2017 International Conference on Robotics and Automation Sciences (ICRAS), August 26-29, 2017, Hong Kong, China. New York: IEEE Press, 2017: 43-47.
- [3] Zhang J G, Wang Y, Lin F T. Automatic reading recognition system for analog measuring instruments base on digital image processing [J]. *Journal of Applied Sciences*, 2013, 13(13): 2562-2567.
- [4] Li Q, Fang Y J, He Y, et al. Automatic reading system based on automatic alignment control for pointer meter [C] // IECON 2014-40th Annual Conference of the IEEE Industrial Electronics Society, October 29-November 1, 2014, Dallas, TX, USA. New York: IEEE Press, 2014: 3414-3418.
- [5] Zhang L, Fang B, Zhao X, et al. Pointer-type meter automatic reading from complex environment based on visual saliency [C] // 2016 International Conference on Wavelet Analysis and Pattern Recognition (ICWAPR), July 10-13, 2016, Jeju, Korea. New York: IEEE Press, 2016: 264-269.
- [6] Guan Y D, Zou Y, Huang B W, et al. Pointer-type meter reading method research based on image processing technology [C] // 2010 Second International Conference on Networks Security, Wireless Communications and Trusted Computing, April 24-25, 2010, Wuhan, China. New York: IEEE Press, 2010: 107-110.
- [7] Zhang P, Ding Y Z, Wang Z P, et al. Accurate reading and reliability estimation model of substation pointer meter [J]. *Laser & Optoelectronics Progress*, 2020, 57(10): 101012.
张平, 丁永泽, 王致芄, 等. 变电站指针式仪表精准读数及可靠度估计模型 [J]. *激光与光电子学进展*, 2020, 57(10): 101012.
- [8] Cheng X G, Yang B, Liu G Q, et al. A variational approach to atmospheric visibility estimation in the weather of fog and haze [J]. *Sustainable Cities and Society*, 2018, 39: 215-224.
- [9] Hautière N, Tarel J P, Lavenant J, et al. Automatic fog detection and estimation of visibility distance through use of an onboard camera [J]. *Machine Vision and Applications*, 2006, 17(1): 8-20.
- [10] Negru M, Nedeveschi S. Image based fog detection and visibility estimation for driving assistance systems [C] // 2013 IEEE 9th International Conference on Intelligent Computer Communication and Processing (ICCP), September 5-7, 2013, Cluj-Napoca, Romania. New York: IEEE Press, 2013: 163-168.
- [11] Hautiere N, Aubert D, Dumont E. Mobilized and mobilizable visibility distances for road visibility in fog [C] // 26th Session of the CIE, July 4, 2007, Beijing, China. [S.l.: s.n.], 2007: 784-787.
- [12] Gallen R, Cord A, Hautière N, et al. Nighttime visibility analysis and estimation method in the presence of dense fog [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2015, 16(1): 310-320.
- [13] Tan R T. Visibility in bad weather from a single image [C] // 2008 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2008, Anchorage, AK, USA. New York: IEEE Press, 2008: 10139948.
- [14] Saad M A, Bovik A C, Charrier C. Blind image quality assessment: a natural scene statistics approach in the DCT domain [J]. *IEEE Transactions on Image Processing*, 2012, 21(8): 3339-3352.
- [15] Mittal A, Moorthy A K, Bovik A C. No-reference image quality assessment in the spatial domain [J]. *IEEE Transactions on Image Processing*, 2012, 21(12): 4695-4708.
- [16] Xue W F, Mou X Q, Zhang L, et al. Blind image quality assessment using joint statistics of gradient magnitude and Laplacian features [J]. *IEEE Transactions on Image Processing*, 2014, 23(11): 4850-4862.
- [17] Li Q H, Lin W S, Fang Y M. No-reference quality assessment for multiply-distorted images in gradient domain [J]. *IEEE Signal Processing Letters*, 2016, 23(4): 541-545.
- [18] Liu L X, Liu B, Huang H, et al. No-reference image quality assessment based on spatial and spectral entropies [J]. *Signal Processing: Image Communication*, 2014, 29(8): 856-863.
- [19] Wu Q B, Wang Z, Li H L. A highly efficient method for blind image quality assessment [C] // 2015 IEEE International Conference on Image Processing (ICIP), September 27-30, 2015, Quebec City, QC, Canada. New York: IEEE Press, 2015: 339-343.
- [20] Mittal A, Soundararajan R, Bovik A C. Making a "completely blind" image quality analyzer [J]. *IEEE Signal Processing Letters*, 2013, 20(3): 209-212.
- [21] Moorthy A K, Bovik A C. A two-step framework for constructing blind image quality indices [J]. *IEEE Signal Processing Letters*, 2010, 17(5): 513-516.
- [22] Gu K, Zhou J, Qiao J F, et al. No-reference quality

- assessment of screen content pictures [J]. IEEE Transactions on Image Processing, 2017, 26(8): 4005-4018.
- [23] Qiao Z A, Liu T. Non-reference image quality evaluation in color channel[J]. Laser & Optoelectronics Progress, 2020, 57(12): 121101.
乔子昂, 刘涛. 颜色通道下的无参考图像质量评价[J]. 激光与光电子学进展, 2020, 57(12): 121101.
- [24] Yu W, Xu J J, Liu Y Y, et al. No-reference quality evaluation for gamut mapping images based on natural scene statistics[J]. Laser & Optoelectronics Progress, 2020, 57(14): 141006.
余伟, 徐晶晶, 刘玉英, 等. 基于自然场景统计的色域映射图像无参考质量评价[J]. 激光与光电子学进展, 2020, 57(14): 141006.
- [25] Ling Z G, Gong J W, Fan G L, et al. Optimal transmission estimation via fog density perception for efficient single image defogging[J]. IEEE Transactions on Multimedia, 2018, 20(7): 1699-1711.
- [26] Choi L K, You J, Bovik A C. Referenceless perceptual fog density prediction model[J]. Proceedings of SPIE, 2014, 9014: 90140H.
- [27] Jiang Y T, Sun C M, Zhao Y, et al. Fog density estimation and image defogging based on surrogate modeling for optical depth[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3397-3409.
- [28] Tong Y B, Konik H, Cheikh F A, et al. Full reference image quality assessment based on saliency map analysis [J]. Journal of Imaging Science and Technology, 2010, 54(3): 030503.
- [29] Chandler D M. Most apparent distortion: full-reference image quality assessment and the role of strategy[J]. Journal of Electronic Imaging, 2010, 19(1): 011006.
- [30] Jain A, Bhatnagar V. A full-reference image quality metric for objective evaluation in spatial domain[C]// 2011 International Conference on Communication and Industrial Application, December 26-28, 2011, Kolkata, India. New York: IEEE Press, 2011: 12540272.
- [31] Rehman A, Wang Z. Reduced-reference image quality assessment by structural similarity estimation [J]. IEEE Transactions on Image Processing, 2012, 21(8): 3378-3389.
- [32] Li Q, Wang Z. Reduced-reference image quality assessment using divisive normalization-based image representation[J]. IEEE Journal of Selected Topics in Signal Processing, 2009, 3(2): 202-211.
- [33] Qiang L, Member S, Zhou W. Reduced-reference image quality assessment using a wavelet-domain natural image statistic model [J]. Proceedings of SPIE, 2005, 5666: 149-159.
- [34] Ruderman D L. The statistics of natural images[J]. Network: Computation in Neural Systems, 1994, 5(4): 517-548.
- [35] 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.
- [36] Vu P V, Chandler D M. A fast wavelet-based algorithm for global and local image sharpness estimation [J]. IEEE Signal Processing Letters, 2012, 19(7): 423-426.