

DOI: 10.19783/j.cnki.pspc.240611

无间隔棒输电线路轨迹提取与椭圆检测的舞动辨识

金沫含¹, 张辰², 冯子瑜¹, 王琛^{1,3}, 刘舒⁴, 梁睿¹

(1. 中国矿业大学电气工程学院, 江苏 徐州 221116; 2. 中国矿业大学计算机科学与技术学院, 江苏 徐州 221116;
3. 国网连云港供电公司, 江苏 连云港 222000; 4. 国网泰州供电公司, 江苏 泰州 225300)

摘要: 无间隔棒输电线路由于缺少机械部件的分隔与连接, 在大风、冻雨、暴雪等条件下舞动风险更大, 当前研究仍无法实现针对性的实时高精度监测。针对该问题, 提出了一种无间隔棒输电线路轨迹提取与椭圆检测的舞动辨识方法。首先进行数据增广和低照度图像增强处理。其次对传统 DeepLabV3+模型进行轻量化改进, 在视频初始帧锁定目标线路并实现快速分割。最后在提取短时段内线路运行轨迹的基础上, 结合巡检专家知识将舞动监测转化为线路轨迹的椭圆检测。结果表明, 在复杂环境条件下, 所提方法有效平衡了线路轨迹提取的速度与精度, 能够分析得到对应线路的舞动程度, 对极端天气下的输电线路巡检有重要现实价值。

关键词: 输电线路; 无间隔棒; 线路轨迹; 舞动; 轻量化

Galloping identification of transmission lines without spacers based on trajectory extraction and ellipse detection

JIN Mohan¹, ZHANG Chen², FENG Ziyu¹, WANG Chen^{1,3}, LIU Shu⁴, LIANG Rui¹

(1. School of Electrical Engineering, China University of Mining and Technology, Xuzhou 221116, China; 2. School of Computer Science & Technology, China University of Mining and Technology, Xuzhou 221116, China; 3. State Grid Lianyungang Power Supply Company, Lianyungang 222000, China; 4. State Grid Taizhou Power Supply Company, Taizhou 225300, China)

Abstract: Because of the absence of mechanical components for separation and connection, transmission lines without spacers are at a higher risk of galloping during strong winds, freezing rain, and heavy snow. However, current research has yet to achieve targeted real-time high-precision monitoring. To address this issue, this paper proposes a galloping identification method for transmission lines without spacers based on trajectory extraction and ellipse detection. First, data augmentation and low-illumination image enhancement processing are performed. Next, a lightweight improvement of the traditional DeepLabV3+ model is carried out to lock into the target line and fast segmentation is realized in the initial frame of the video. Finally, after extracting the short-term operational trajectory of the transmission line, the galloping monitoring process is transformed into ellipse detection of the trajectory based on inspection expert knowledge. The results demonstrate that the proposed method effectively balances the speed and accuracy of line trajectory extraction, and can analyze the galloping severity in transmission lines in complex environmental conditions. This has significant practical value for transmission line inspection in extreme weather.

This work is supported by the National Natural Science Foundation of China (No. 52077215).

Key words: transmission line; no spacers; line trajectory; galloping; lightweight

0 引言

输电线路作为电力系统电能传输的主要载体, 其稳定运行是保障电力系统安全的基础^[1]。近年来, 我

国多个地区受大风、冻雨、暴雪等极端天气影响, 输电线路出现不均匀覆冰的现象, 线路舞动风险增加^[2]。线路舞动是长期以来造成恶劣天气下输电线路跳闸事故的关键原因之一, 影响居民生活和社会经济发展^[3]。目前我国大部分地区的输电线路仍采用无间隔棒结构, 缺少机械部件的分隔与连接, 导致线路舞动更容易发生。同时, 实际的输电线路舞

基金项目: 国家自然科学基金项目资助(52077215); 江苏省碳达峰碳中和科技创新专项资金资助(BE2022609)

动巡检仍依靠人工完成, 耗费了大量的时间成本。因此, 需要针对无间隔棒线路实现实时性的低成本舞动监测。

输电线路舞动受到众多因素影响, 包括气象条件、地形条件、线路结构等, 这些因素相互耦合关系复杂, 因此对线路舞动进行监测和分析具有较大的挑战^[4]。当前线路舞动监测方案主要分为传感器监测^[5]、仿真模拟^[6]以及深度学习^[7]。传感器测量的参数包括线路舞动的加速度、角度、幅值、振动半波数和频率等。文献[8]基于张力传感器设计了线路舞动自动监测系统, 综合考虑线路舞动参数和风速、空气湿度等环境参数, 实现了多源信息的综合利用。针对传统风振监测装置可靠性较低且难以维护的问题, 文献[9]以多参数分布式光纤传感为核心, 建立了新型的线路舞动监测系统, 并在不同振动频率和幅值条件下验证了其可行性与精度。为了获取准确的线路舞动参数并可靠地分析线路状态以模拟舞动轨迹, 需要安装足够数量的传感器。然而, 一旦传感器数量过多, 在增加成本的同时会导致线路运动状态分析更加困难。

在计算机仿真软件的支持下, 通过设置仿真软件参数模拟真实线路舞动的各种条件, 可以分析得到线路舞动特性。文献[10]对比了几何非线性和线性有限元方法以及不同类型导线振幅。文献[11]将风攻角和风速作为分岔参数, 有效地反映了随初始风攻角和风速参数变化舞动的响应特性。文献[12]采用 ANSYS Fluent 和 RecurDyn 软件进行输电线路建模, 通过施加风荷载在仿真中模拟了线路舞动的动态特性。仿真条件的不断进步为线路分析提供了极大的便利^[13]。然而, 由于研究的分散性, 各类线路舞动模型之间存在较大的差异。同时, 对于真实场景中众多因素交互影响的情况, 当前的仿真研究仍存在一定的局限性。此外, 计算机深度学习算法不断更迭^[14], 为输电线路的轨迹识别与舞动监测提供了一系列新方法。文献[15]通过跟踪算法提取线路特征点。文献[16]则通过跟踪间隔棒判定线路舞动。文献[17]在 Android 平台上设计并部署了基于视频跟踪的舞动检测系统。然而, 输电线路轨迹识别领域面临着众多复杂而多变的挑战, 包括实际环境的复杂性、实际应用的实时性需求等。

为解决以上问题, 本文提出了一种无间隔棒输电线路轨迹提取与椭圆检测的舞动辨识方法。首先, 使用数据增广与图像增强的方法对图像数据进行预处理, 实现丰富数据集和提高数据质量的目的; 其次, 对传统 DeepLabV3+模型进行轻量化改进, 在视频初始帧快速锁定目标输电线路; 最后, 在提取

短时段内目标线路运行轨迹的基础上, 结合巡检专家知识将舞动监测问题转化为线路轨迹的椭圆检测。通过检测所得的椭圆参数和线路轨迹形成椭圆的概率, 能够实现无间隔棒输电线路的舞动辨识。

1 图像数据预处理

为提高线路运行轨迹提取与舞动辨识的准确性, 需要对采集的原始输电线路视频数据进行图像增广^[18]和图像增强^[19]。使用色彩空间变换进行数据扩充, 模拟不同光照和天气条件下的输电线路拍摄图像。此外, 使用 Retinex 算法处理夜晚、风沙等低照度图像^[20], 具体使用单尺度视网膜算法, 示意图如图 1 所示。摄像机所采集的原始图像 $I(x, y)$ 可表示为

$$I(x, y) = L(x, y) \times R(x, y) \quad (1)$$

式中: x 、 y 分别为图像像素点横纵坐标; $L(x, y)$ 为入射分量; $R(x, y)$ 为反射分量。



图 1 基于 Retinex 算法的图像增强示意图

Fig. 1 Image enhancement sketch based on Retinex algorithm

首先对图像进行高斯滤波, 滤波结果即入射分量 $L(x, y)$ 可用式(2)表示。

$$L(x, y) = I(x, y) * G(x, y) \quad (2)$$

式中: $G(x, y)$ 代表高斯卷积核; “*” 代表卷积运算。

采用对数变换将乘法运算转化为加法运算, 以缩减计算时间, 方便工程应用。对式(1)取对数, 变换可得式(3)。

$$\begin{aligned} \log(R(x, y)) &= \log(I(x, y)) - \log(L(x, y)) = \\ &= \log(I(x, y)) - \log(I(x, y) * G(x, y)) \end{aligned} \quad (3)$$

最后进行线性拉伸, 提高图像对比度且将像素值限制在 0~255 内, 如式(4)所示。

$$R(x, y) = 255 \times (V - V_{\min}) / (V_{\max} - V_{\min}) \quad (4)$$

式中: V 为待限制的像素值; V_{\max} 为迭代最大结果; V_{\min} 为迭代最小结果; $R(x, y)$ 为图像增强结果, 即反射分量。

2 基于轻量化 DeepLabV3+的输电线路分割

输电线路轨迹提取的首要步骤是分离图像背景, 在视频初始帧定位目标线路, 即实现线路的快速分割^[21]。本文对 DeepLabV3+模型进行轻量化改进, 平衡模型的计算效率和分割精度, 方便复杂背

景下的实时应用。

DeepLabV3+模型是当前图像分割较成熟的方法^[22], 但实际中仍面临计算效率低、参数量大及识别精度欠佳等问题^[23], 需要进行轻量化改进。本文改进包括三方面: 主干网络改为使用 MobileNetV2 网络; 扩张空间卷积池化金字塔(atrous spatial pyramid pooling, ASPP)模块优化; 引入坐标注意力(coordinate attention, CA)机制。轻量化 DeepLabV3+ 网络结构如图 2 所示。

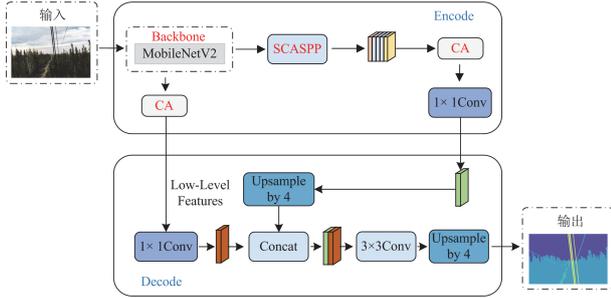


图 2 轻量化 DeepLabV3+ 网络结构图

Fig. 2 Lightweight DeepLabV3+ network structure diagram

2.1 MobileNetV2 主干网络设计

传统 DeepLabV3+ 以 Xception 作为主干特征提取网络, 无法满足轻量化要求^[24]。而 MobileNetV2 能够节省计算资源, 同时引入了逆残差和线性瓶颈来保证分割精度, 其结构如图 3 所示。为进一步减少模型参数数量, 本文仅运用 MobileNetV2 的前 8 层作为 DeepLabV3+ 主干网络进行特征提取, 并以 512×512 的 RGB 图像输入网络进行输电线路特征提取, 兼顾模型性能与运行效率。MobileNetV2 详细优化结构如表 1 所示, 其中: T 为通道扩展后的倍数; N 为重复次数; S 为步距。

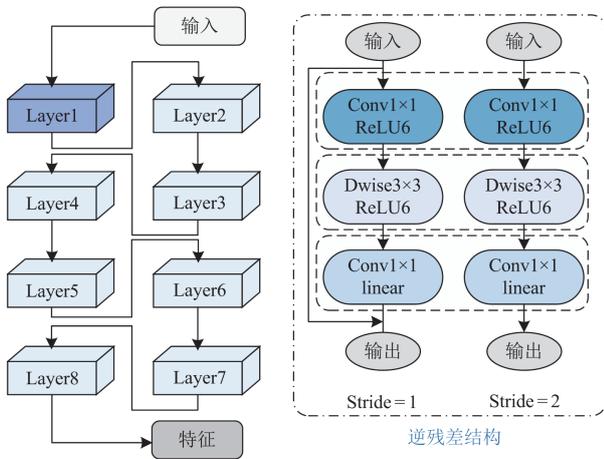


图 3 MobileNetV2 网络及逆残差模块

Fig. 3 MobileNetV2 network and inverted residual structure

表 1 MobileNetV2 详细优化结构

Table 1 MobileNetV2 detailed optimization structure

层	输入通道数	操作结构	T	输出通道数	N	S
1	$512 \times 512 \times 3$	Conv2d	—	$256 \times 256 \times 32$	1	2
2	$256 \times 256 \times 32$	bottleneck	1	$256 \times 256 \times 16$	1	1
3	$256 \times 256 \times 16$	bottleneck	6	$128 \times 128 \times 24$	2	2
4	$128 \times 128 \times 24$	bottleneck	6	$64 \times 64 \times 32$	3	2
5	$64 \times 64 \times 32$	bottleneck	6	$32 \times 32 \times 64$	4	2
6	$32 \times 32 \times 64$	bottleneck	6	$32 \times 32 \times 96$	3	1
7	$32 \times 32 \times 96$	bottleneck	6	$16 \times 16 \times 160$	3	2
8	$16 \times 16 \times 160$	bottleneck	6	$16 \times 16 \times 320$	1	1

2.2 ASPP 模块优化

传统模型由于空洞卷积操作的使用, 导致输出特征图的像素在空间上规则排列, 易导致分割边界不平滑、细节丢失等问题。因此使用顺序级联 ASPP(sequential cascade ASPP, SCASPP)模块, 通过不同扩张率的空洞卷积并行化捕捉不同尺度的信息, 此外卷积之间共享参数并使用 1×1 卷积降低输入特征维度以减少参数。模块结构如图 4 所示。

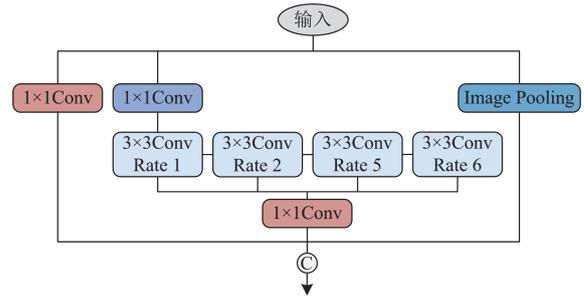


图 4 SCASPP 模块结构

Fig. 4 SCASPP module structure

2.3 引入坐标注意力机制

本文引入 CA 机制, 将位置信息融入通道注意力, 在不显著增加计算负担的情况下扩大网络感受野^[25], 进一步保证分割精度。其由坐标信息嵌入模块和坐标注意力生成模块组成, 坐标注意力机制网络结构如图 5 所示。其中输入维度为通道数 \times 通道高度 \times 通道宽度 ($C \times H \times W$), r 为控制块大小的还原率。

3 轨迹提取与椭圆检测的线路舞动辨识

分析线路运动轨迹是判断线路是否发生舞动的直接方法^[26], 在计算机视觉层面可以通过跟踪算法实现^[27]。在锁定线路目标后, 本文使用 SiamMask 算法跟踪目标线路弧段并提取运行轨迹形状, 结合线路巡检专家知识, 对轨迹形状进行椭圆检测实现线路舞动辨识。

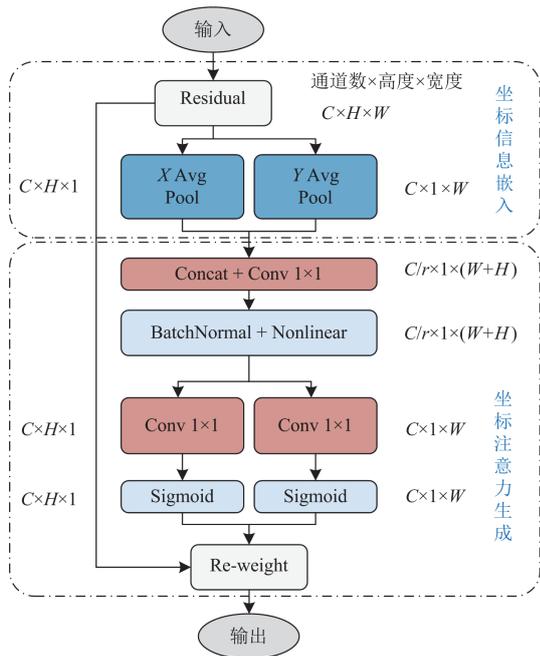


图5 坐标注意力机制网络结构图
Fig. 5 Coordinate attention mechanism network structure diagram

3.1 基于 SiamMask 算法的线路轨迹提取

与传统的目标跟踪算法相比，SiamMask 算法能够在较短的时间内完成目标跟踪和持续分割，方便实时应用^[28]。SiamMask 算法结合孪生网络和分割技术，能够实现对输电线路的实时跟踪和精准分割，SiamMask 网络结构如图 6 所示。SiamMask 算法的核心思想是利用孪生网络提取目标和背景的特征，通过相关性计算来确定目标位置，并且通过引入分割分支，生成目标线路的二元掩模。

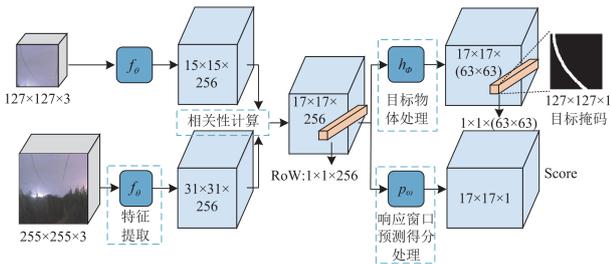


图6 SiamMask 网络结构
Fig. 6 SiamMask network structure

基于 SiamMask 的输电线路轨迹形状提取流程如图 7 所示。首先，输入短视频的初始帧图像，利用轻量化的 DeepLabV3+模型进行分割，获取线路的初始掩码。其次，在后续帧中执行目标搜索和匹配，利用之前帧的掩码信息进行线路位置的精细调整，利用线路特征进行匹配，并对可能含有线路的

候选区域进行位置更新，确保线路跟踪的准确性。最后，利用 SiamMask 模型的分割分支结构对更新位置后的当前帧图像进行分割，获取线路掩码。该分割掩码将在下一帧图像的跟踪过程中用作候选区域参考，最终获得整个视频样本每一帧线路对应的掩码信息。将每帧的线路掩码信息进行逻辑“或”运算，利用边界填充方法填充掩码集合中间的空心部分，最后获取整个视频样本的输电线路舞动范围，即其运行轨迹的边缘拟合形状，为后续的舞动定性分析提供数据基础。

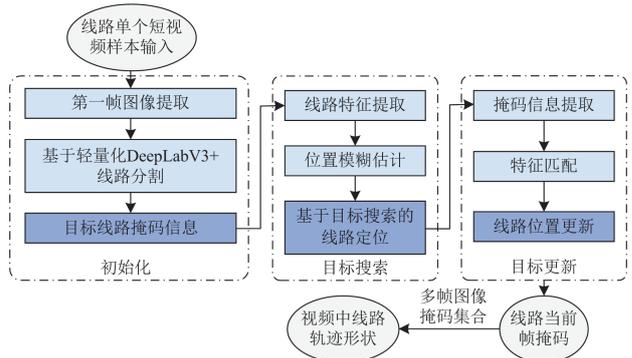


图7 基于 SiamMask 的输电线路轨迹形状提取
Fig. 7 Transmission line trajectory shape extraction based on SiamMask

3.2 结合椭圆检测的输电线路舞动辨识

基于输电线路巡检专家的工程经验，在空间中，无间隔棒线路在大风的作用下会进行旋转运动，在多数情况下形成一个椭球橄榄体，从任何方向的横切面观察都呈椭圆状。因此，在固定摄像头下，当线路在某时段的轨迹边缘形状在二维图像中呈椭圆时，表明其存在舞动现象，且椭圆的形状和参数可以反映舞动的幅度和方向。具体而言，椭圆的长短轴比例和倾斜方向可以显示舞动的强度和方向，而椭圆的形成概率则反映了舞动的稳定程度和持续性。因此，结合椭圆检测能够进行输电线路的舞动辨识。

3.2.1 线路轨迹形状的椭圆检测

线路轨迹形状的椭圆检测流程如图 8 所示。

1) 线路弧段筛选

首先，采用 Canny 边缘检测算法识别图像边缘，提取边缘弧段^[29]。每个边缘像素点用坐标和梯度方向表示，梯度方向 $g(T_i)$ 分为两类，如式(5)所示。

$$g(T_i) = \begin{cases} +1, \tan(\omega_i) > 0 \\ -1, \tan(\omega_i) < 0 \end{cases} \quad (5)$$

式中， $T_i = (x_i, y_i, \omega_i)$ 为边缘像素点， x_i 与 y_i 分别表示该像素点的纵横坐标，该像素点的梯度方向由

Canny 边缘检测算法得到, 以 ω_i 表示。在像素点 8 邻域内连接相同类别的像素点形成边缘弧段, 以 M^k 表示第 k 条边缘弧段的像素点数, 则第 k 条边缘弧段 Ω^k 表示为

$$\Omega^k = \{T_1^k, \dots, T_{M^k}^k\} \quad (6)$$

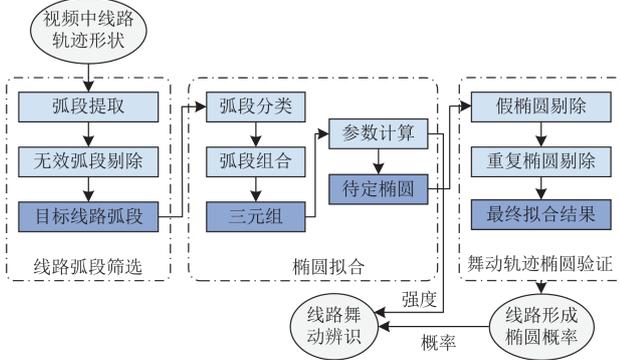


图 8 线路轨迹椭圆检测

Fig. 8 Line trajectory ellipse detection

其次, 剔除无效弧段即直线段, 采用三角形面积去除方法, 如图 9 所示。弧段 α 的左右端点分别以 L 和 R 表示, O 表示弧段中点, 通过连接 L 、 R 、 O 构成三角形 LOR , 其面积 $S_{\Delta LOR}$ 与弧段扁平程度及长度有关, 长度确定时便可用面积反映扁平程度。因此面积与长度的比值可以反映弧段是否为直线。具体比值 r 计算公式如式(7)所示。

$$r = \frac{S_{\Delta LOR}}{N_p} \quad (7)$$

式中, N_p 为弧段边缘像素点总数, 反映弧段长度。设置经验阈值 T_{hr} , 若 $T_{hr} < r$ 则判定弧段为直线, 予以剔除。

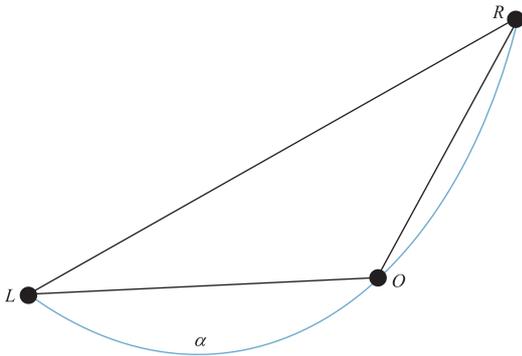


图 9 直线段剔除方法示意图

Fig. 9 Schematic diagram of straight line segment elimination method

2) 椭圆拟合

首先, 确定椭圆三元组^[30]中的弧所属部分。将相

同梯度方向的边缘点在 8 邻域内连成弧段, 得到的边缘弧段梯度方向 $G(\alpha_k)$ 也可分为两类, 如式(8)所示。

$$G(\alpha_k) = \begin{cases} +1, \nabla g(T_i) = +1 \\ -1, \nabla g(T_i) = -1 \end{cases} \quad (8)$$

式中, α_k 表示第 k 个弧段。

本文根据梯度方向和凹凸性可将椭圆弧段分为 4 类, 如图 10 所示。

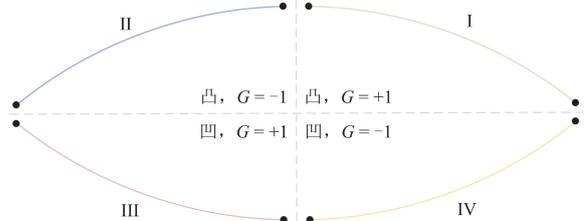


图 10 椭圆弧段分类

Fig. 10 Elliptical arc segment classification

此外, 椭圆的极性依据其内外明暗的差异判断, 内明外暗则为正极性, 同一椭圆的弧段极性相同, 弧段极性 $P_{pol}(\alpha_k)$ 判断如式(9)所示。

$$P_{pol}(\alpha_k) = \begin{cases} +1, \mathbf{G}_{ra}(O) \cdot \overline{OQ} > 0 \\ -1, \mathbf{G}_{ra}(O) \cdot \overline{OQ} < 0 \end{cases} \quad (9)$$

式中, 弧段 α_k 和弦 LR 的中点分别以 O 与 Q 表示, $\mathbf{G}_{ra}(O)$ 表示点 O 的梯度向量。

实际应用中, 复杂背景的存在会造成部分弧段缺失, 本文将具有任意三类圆弧的集合作为一个三元组, 可构建出 4 种类别三元组, 如表 2 所示。

表 2 三元组分类

Table 2 Triplet classification

符号	所含弧段类型
$\Psi_{I\ II\ III}$	I、II、III
$\Psi_{I\ II\ IV}$	I、II、IV
$\Psi_{I\ III\ IV}$	I、III、IV
$\Psi_{II\ III\ IV}$	II、III、IV

其次, 形成 3 个约束条件, 以此剔除不属于同一椭圆的三元组。约束 1 要求三元组中的弧上的点必须符合帕斯卡定理。约束 2 规定了三元组中的各个弧段需要满足图 10 的相对位置关系, 依据各弧段的左端点和右端点坐标实现。约束 3 限制三元组弧段极性, 式(9)判断所得的 3 个弧段的极性需相同。

最后, 进行椭圆参数估计。

对上述符合约束的三元组进行参数估计, 包括椭圆中心 (x_c, y_c) 、长半轴 a 、短半轴 b 以及椭圆倾斜角 ρ 。椭圆中心依据平行弦定理获得, 其他参数由椭圆中心坐标及各弧段点坐标得到。通过上述步

骤，最终得到了一系列带有椭圆参数的三元组。

3) 舞动轨迹椭圆验证

本文采用可靠性指标和准确性指标来剔除假椭圆和重复椭圆，用以提高椭圆检测的准确性和效率。

首先，剔除假椭圆，将三元组中椭圆像素点个数与总数的比值 η 用于衡量椭圆检测的准确性，如式(10)所示。

$$\eta = \frac{|w|}{|\alpha_1| + |\alpha_2| + |\alpha_3|} \quad (10)$$

式中： $|w|$ 表示椭圆像素点的个数； $|\alpha_1|$ 、 $|\alpha_2|$ 、 $|\alpha_3|$ 分别表示三元组 $\varphi_k = \{\alpha_1, \alpha_2, \alpha_3\}$ 的 3 条弧段像素点个数。设定 T_{hn} 为应用场景的阈值，若 $\eta < T_{\text{hn}}$ 则判定为假椭圆，予以剔除。

用三元组各弧段长度与拟合椭圆周长之比衡量拟合椭圆可靠性 R_{el} 。以边缘点像素个数表示弧段长度，周长 L_{en} 通过式(11)计算，可靠性 R_{el} 通过式(12)计算。设定 T_{hRel} 为应用场景的可靠性阈值，若 $R_{\text{el}} < T_{\text{hRel}}$ 则判定为假椭圆，予以剔除。

$$L_{\text{en}} = \pi \left[\frac{3(a+b)}{2} + \sqrt{ab} \right] \quad (11)$$

$$R_{\text{el}} = \frac{|\alpha_1| + |\alpha_2| + |\alpha_3|}{L_{\text{en}}} \quad (12)$$

其次，剔除重复椭圆。如图 11 所示，同一椭圆边缘被误拟合成多个椭圆存在两种主要情况：(1) 同一弧段被分别纳入不同的三元组；(2) 图像质量引起的边缘提取不连续。

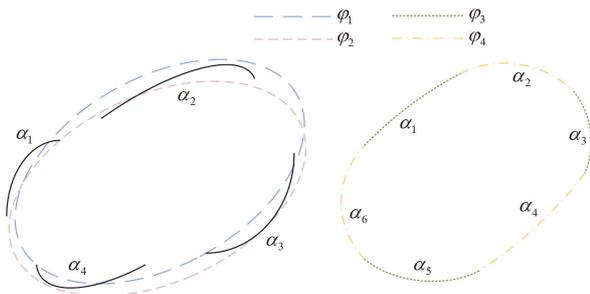


图 11 重复椭圆类型

Fig. 11 Repeating ellipse types

针对第一种情况产生的重复椭圆，通过检查两个候选椭圆对应的三元组是否存在相同的弧段来判别。对于第二种情况产生的重复椭圆，通过比较两个候选椭圆的参数来确定它们之间的差异。确定重复椭圆后，选取具有最高得分的重复椭圆作为检测结果，每个椭圆的得分 S_{core} 的计算公式为

$$S_{\text{core}} = \lambda \eta + (1 - \lambda) R_{\text{el}} \quad (13)$$

式中， λ 为权重参数，取值为 0.5。

最后，用交并比计算线路形成椭圆的概率 U ，如式(14)所示。

$$U = \frac{S_j \cap S_z}{S_j \cup S_z} \quad (14)$$

式中， S_j 和 S_z 分别表示检测椭圆 j 和真实椭圆 z 的面积。

3.2.2 输电线路舞动风险辨识

将舞动幅度指标和椭圆形成概率经验阈值结合，划分线路舞动风险级别，如表 3 所示。

表 3 线路舞动风险级别

风险级别	舞动幅度指标	椭圆概率	备注
无	无	小于 20%	无
低	较小	20%~50%	无
中	中等	50%~70%	需要加强巡检
高	较大	大于 70%	立即进行检修和维护

4 算例分析

4.1 数据预处理

本文实验数据来自内蒙准噶尔某露天矿区实地拍摄的视频图像及公开的电力线数据集 TTPLA。其中，公开数据集用于增强识别线路的泛化能力，精准分割出线路弧段。此外，用于线路弧段跟踪的拍摄视频划分为每 6 s 一个视频样本，每 1 s 为 24 帧。对于硬件配置，本文采用的 CPU 为 12th Gen Intel(R) Core(TM) i9-12900H，GPU 为 NVIDIA GeForce RTX3060，显存为 6 GB。软件配置方面，本文采用 Windows 11 操作系统。深度学习架构选择 pytorch1.6 架构，实验中网络均依靠 Python 编程语言完成。输电线路分割数据集使用 Labelme 软件进行，以.json 文件存储标注信息。此外，对线路跟踪所需的视频数据进行标注，采用 VGG Image Annotator 软件，以.json 文件存储标注信息。

色彩空间变换数据扩充效果如图 12 所示，图中从左至右、从上到下依次为原图、亮度变换、对比度变换、饱和度变换、灰度图和组合变换。由图 12 可知，色彩空间变换可以模拟不同的气象条件，提升模型的泛化能力。图 13 从左至右、从上到下依次呈现了输电线路原始图像以及高斯滤波、直方图均衡和 Retinex 算法处理后的效果。可以发现，使用 Retinex 算法能有效应对低照度图像特征不明显的问题，与其他方法相比更能还原场景细节。

4.2 线路分割对比分析实验

本文设计轻量化 DeepLabV3+ 以实现实际输电

线路的分割, 从精度和速度两个方面对算法进行评估。在精度方面, 选择平均交并比(mean intersection over union, MIoU)和平均像素精度(mean pixel accuracy, MPA)对模型分割精度进行评价。在速度方面, 选择帧率(frames per second, FPS)和参数量对模型分割速度进行评价。在进行线路舞动检测时, 主要关注输电线路的运动情况, 因此仅需要分割出线路而不必考虑其他背景元素。通过阈值处理、形态学操作及区域合并技术, 将全景分割结果转换为仅包含线路和背景的分割结果, 有助于减少后续舞动检测任务的计算量, 如图 14 所示。

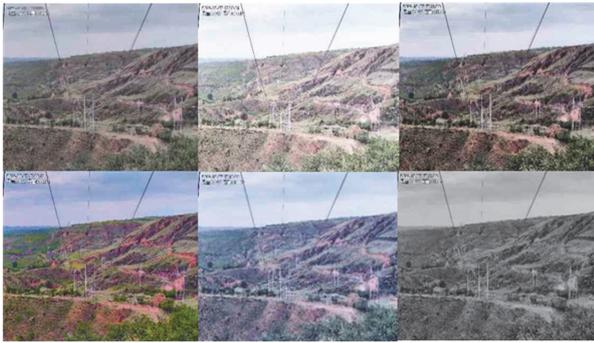


图 12 色彩空间变换数据扩充效果图

Fig. 12 Color space transformation data expansion effects



图 13 低照度图像数据增强结果对比图

Fig. 13 Comparison of low-light image data enhancement results

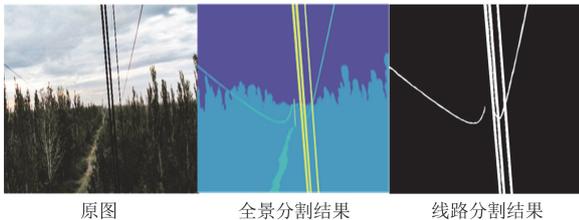


图 14 全景分割及线路分割结果示例

Fig. 14 Examples of panoramic segmentation and line segmentation result

4.2.1 图像增强有效性分析

将未经过图像增强的数据集和增强后的数据集分割结果作对比, 如表 4 所示。由对比结果可知, Retinex 方法作为有效的图像增强技术, 有效提升了分割精度。

表 4 低照度图像增强分割效果

指标	未预处理	预处理
MIoU/%	72.61	80.79
MPA/%	85.74	92.16

4.2.2 与其他模型的对比分析

为验证本文的轻量化 DeepLabV3+模型的有效性和优越性, 与现有分割主流模型 PSPNet、U-Net、SegNet 以及未进行轻量化改进的原始 DeepLabV3+模型进行比较, 对比结果如表 5 所示。在精度方面, 轻量化 DeepLabV3+模型表现出了明显的优势, MIoU 和 MPA 分别达到了 80.79%和 92.16%, 远高于其他模型。同时, 关注模型的运行速度和参数量。轻量化 DeepLabV3+模型在 FPS 和参数量方面均表现出了较大优势, FPS 达到了 51.05 Hz, 参数量仅为 10.18 MB。因此, 轻量化 DeepLabV3+模型能在保持较高准确性的同时, 具有较快的运行速度和较小的模型体积。

表 5 对比实验模型评价指标参数

模型	MIoU/%	MPA/%	FPS/Hz	参数量/MB
PSPNet	69.84	80.65	56.92	167.70
U-Net	76.35	88.35	34.47	95.13
SegNet	74.78	86.17	31.82	37.12
DeepLabV3+	79.28	87.66	42.99	58.87
轻量化 DeepLabV3+	80.79	92.16	51.05	10.18

将多场景下的分割结果进行纵向对比, 如图 15 所示。各算法在场景 2、3 中的简单背景下表现良好, 但在场景 1 中存在明显差异。具体而言, PSPNet 表现出了较为频繁的断续分割, 可能是由于金字塔池化模块导致的尺度不匹配降低了分割质量; U-Net 未能正确提取复杂场景下的边界信息, 将相似像素错误地分割, 导致错误分割和漏分割; SegNet 的边界分割不够准确, 易将绝缘子、杆塔等目标错误分类为线路。这些问题使得这些传统算法在复杂场景中的应用受到限制。相比之下, 本文提出的轻量化 DeepLabV3+模型通过对 ASPP 模块进行顺序级联, 并引入坐标注意力机制, 有效地解决了上述问题。

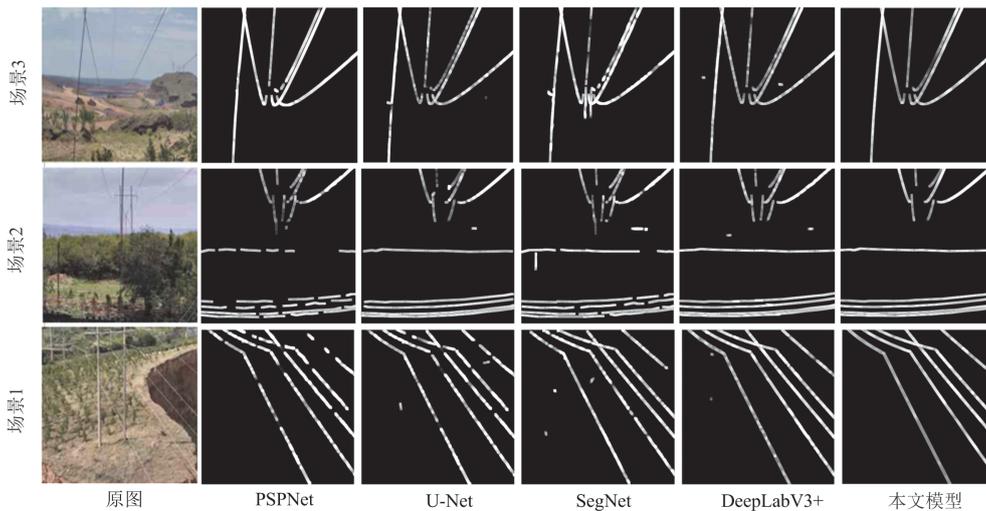


图 15 输电线路多场景分割结果可视化

Fig. 15 Visualization of multi-scene segmentation results of transmission lines

4.2.3 模块消融实验

通过对比不同组合的实验结果，深入分析 MobilenetV2、SCASPP 和 CA 这 3 个模块(分别对应表 6 中模型 1、2、3)对模型性能的影响，实验数据如表 6 所示。结果表明，原始 DeepLabV3+模型分割准确性最高，MIoU 和 MPA 分别达到了 79.28% 和 87.66%，但其参数量最大，分割速度最慢。MobilenetV2 作为骨干网络后明显降低了模型的参数量，但 MIoU 和 MPA 分别降低至 77.89% 和 86.45%。SCASPP 模块的引入进一步降低了参数量并保持了较高的 FPS，同时 MIoU 和 MPA 也有所提高。坐标注意力机制引入后获得了最高的准确性，同时保持了较佳的分割速度，MIoU 和 MPA 分别达到了 80.79% 和 92.16%。

表 6 轻量化 DeepLabV3+模型消融实验结果

Table 6 Lightweight DeepLabV3+ model ablation experimental results

模型			指标			
1	2	3	MIoU/%	MPA/%	FPS/Hz	参数量/MB
			79.28	87.66	42.99	58.87
✓			77.89	86.45	56.05	11.94
✓	✓		78.84	88.15	53.23	8.47
✓	✓	✓	80.79	92.16	51.05	10.18

4.3 线路轨迹提取及舞动辨识

4.3.1 轨迹形状提取

利用 SiamMask 模型对视频中的目标线路进行跟踪分析，评估模型时关注其准确率、鲁棒性以及平均重叠期望(expected average overlap, EAO)，结果如表 7 所示。

表 7 跟踪模型评价指标结果

Table 7 Results of tracking model evaluation indicators

准确率	鲁棒性	EAO
0.708	0.264	0.397

如图 16 所示，对利用 SiamMask 实现的线路跟踪可视化结果进行分析。观察整体跟踪效果发现，场景 1 和场景 3 中的线路位置变化相对不明显，表明这两个场景在拍摄时段内无风或风速较小。与之相比，场景 2 中的目标线路呈现出更为显著的位置变化，这是由于该场景在拍摄时段内风速较大。因此，SiamMask 模型能够有效捕捉线路的位置变化，可以用于轨迹形状提取。整合线路掩码可以进一步得到每条线路的轨迹形状。选取典型风速较大场景进行轨迹形状整合，该场景有 3 条线路，轨迹提取结果如图 17 所示。

4.3.2 椭圆检测的线路舞动辨识

典型场景各线路轨迹椭圆检测结果如图 18 和表 8 所示。利用舞动线路椭圆检测结果对该场景各线路舞动情况进行分析，线路 1 未被检测出椭圆，这意味着该线路轨迹构成椭圆概率较低，舞动幅度相对较小，因此不需要立即采取措施进行检修和维护。然而，线路 2 和线路 3 被检测出椭圆，并且构成椭圆的概率分别为 0.728 和 0.661。参照表 3，线路 2 超过检测阈值 70%，构成椭圆的可能性较高，需要立即进行检修和维护。线路 3 未超过检测阈值 70%，舞动程度中等，建议加强巡检。如表 9 所示，进一步分析线路 2 和线路 3 轨迹拟合椭圆的参数，椭圆中心坐标和倾斜角反映了舞动线路所在区域及方向，长短轴比值一定程度上反映了舞动的强度。

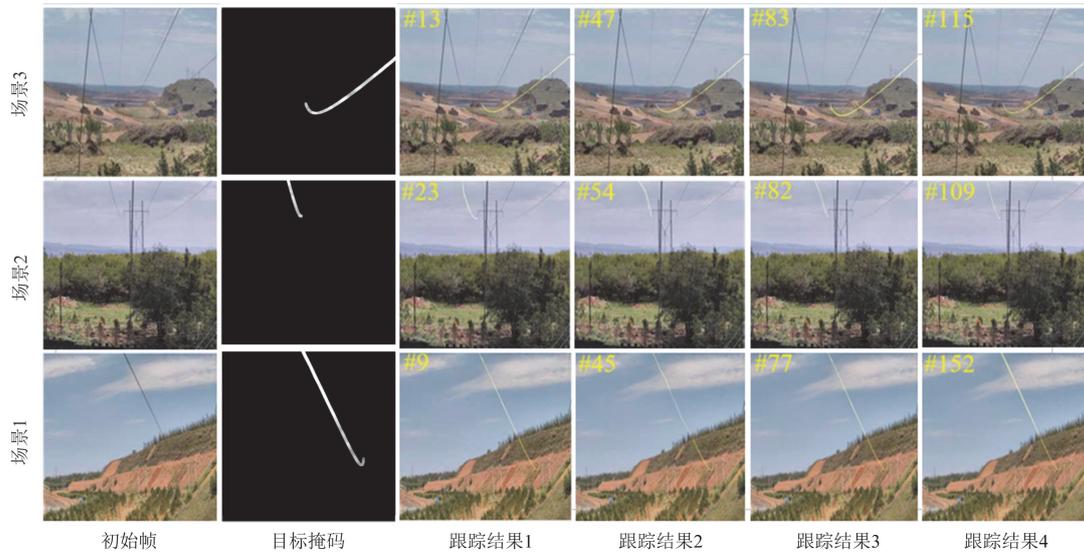


图 16 不同帧线路轨迹跟踪结果

Fig. 16 Line trajectory tracking results of different frames

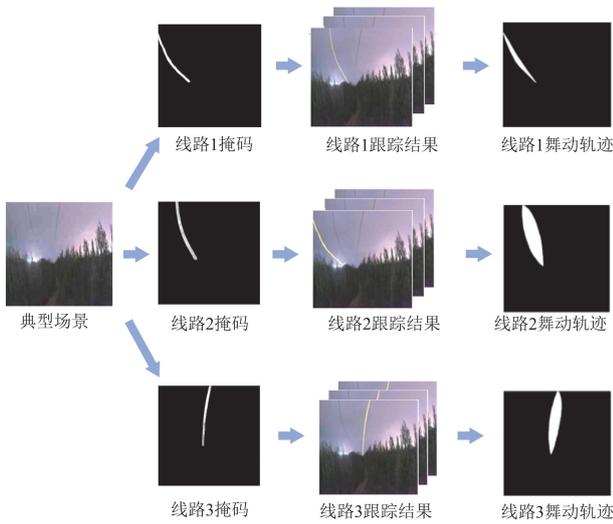


图 17 典型场景舞动线路轨迹提取

Fig. 17 Typical scene galloping line trajectory extraction

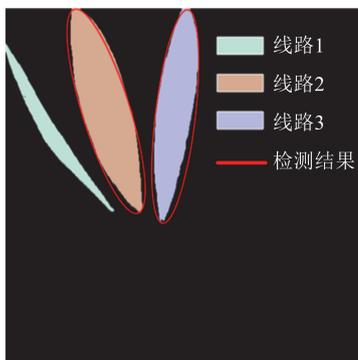


图 18 线路轨迹椭圆检测结果可视化

Fig. 18 Visualization of line trajectory ellipse detection results

表 8 线路轨迹椭圆检测结果

Table 8 Line trajectory ellipse detection results

检测结果	是否检测为椭圆	概率
线路 1	否	—
线路 2	是	0.728
线路 3	是	0.661

表 9 线路轨迹椭圆检测参数信息

Table 9 Line trajectory ellipse detection parameter information

参数	x_c	y_c	a	b	ρ
线路 2	37.665	88.009	76.0515	17.079	106.815
线路 3	61.186	87.901	78.279	14.891	83.261

线路 2 长短轴比值 a/b 较线路 3 要小, 反映到舞动程度上说明线路 2 舞动程度更加剧烈, 需要重点关注。

5 结论

针对目前无间隔棒输电线路舞动风险难以预估的问题, 本文提出了一种无间隔棒输电线路轨迹提取与椭圆检测的舞动辨识方法, 结论如下所述。

1) 本文利用色彩空间变换进行数据增广, 利用 Retinex 算法进行数据增强。进行数据预处理后, 输电线路分割精度有明显提升。

2) 本文使用轻量化 DeepLabV3+模型对输电线路进行分割, 在视频初始帧锁定目标线路。实验表明, 该模型在保持高准确性的同时, 具有较快的运行速度和较小的模型体积。

3) 本文在提取短时段内目标线路运行轨迹的

基础上, 结合椭圆检测实现线路舞动辨识。通过分析椭圆参数和线路轨迹在接下来形成椭圆的概率, 得到对应线路的舞动程度, 对极端天气下的输电线路巡检有重要工程应用价值。

参考文献

- [1] 赵启, 王建, 林丰恺, 等. 基于格拉姆角场与 ResNet 的输电线路故障辨识方法[J]. 电力系统保护与控制, 2024, 52(10): 95-104.
ZHAO Qi, WANG Jian, LIN Fengkai, et al. Transmission line fault identification method based on Gramian angular field and ResNet[J]. Power System Protection and Control, 2024, 52(10): 95-104.
- [2] 曹海林, 陶璐, 蔡文斌, 等. 弧长约束下基于分布式倾角信息的输电线路舞动曲线重建[J]. 高电压技术, 2018, 44(5): 1535-1541.
CAO Hailin, TAO Lu, CAI Wenbin, et al. Transmission line galloping curve reconstruction based on distributed inclination information and arc-length constraint[J]. High Voltage Engineering, 2018, 44(5): 1535-1541.
- [3] WU Huijuan, TANG Bo, XIAO Yao, et al. Monitoring of the transmission line galloping with a novel distributed optical fibre sensor and its statistical data analysis[J]. IET Generation, Transmission & Distribution, 2020, 14(1): 166-171.
- [4] 刘赫, 杨代勇, 赵春明, 等. 利用深度学习提取配电网线路舞动特征[J]. 电力系统及其自动化学报, 2023, 35(5): 89-94.
LIU He, YANG Daiyong, ZHAO Chunming, et al. Extraction of galloping characteristics of overhead line in distribution network by using deep learning method[J]. Proceedings of the CSU-EPSA, 2023, 35(5): 89-94.
- [5] 耿亮, 王峥, 王海宝, 等. 基于加速度传感器的输电线路舞动监测系统研发及应用[J]. 电气时代, 2018(4): 80-84.
- [6] 龚棻, 赵峰, 李冬华, 等. 基于压缩感知的架空线路舞动波形重构方法[J]. 电力系统保护与控制, 2021, 49(9): 97-104.
GONG Yu, ZHAO Feng, LI Donghua, et al. Method for reconstructing galloping waveforms of overhead lines based on compressed sensing[J]. Power System Protection and Control, 2021, 49(9): 97-104.
- [7] 黄新波, 陶保震, 冯玲. 基于光流场的输电导线舞动监测方法[J]. 电力自动化设备, 2012, 32(7): 99-103.
HUANG Xinbo, TAO Baozhen, FENG Ling. Transmission line galloping monitoring based on optical flow field[J]. Electric Power Automation Equipment, 2012, 32(7): 99-103.
- [8] QUAIA S, MAURI A, MAREGA M, et al. Subtransmission overhead lines mechanical monitoring for fast detection of damaging events[J]. Electrical Engineering, 2022, 104(6): 3881-3891.
- [9] 杨芳, 唐小亮, 尹文阔, 等. 基于多参量分布式光纤传感的架空输电线路风振监测分析[J]. 电力系统保护与控制, 2022, 50(11): 169-177.
YANG Fang, TANG Xiaoliang, YIN Wenkuo, et al. Analysis of transmission line wind vibration monitoring based on a multi parameter distributed optical fiber sensor[J]. Power System Protection and Control, 2022, 50(11): 169-177.
- [10] 孙珍茂, 楼文娟. 覆冰输电导线舞动非线性有限元分析[J]. 电网技术, 2010, 34(12): 214-218.
SUN Zhenmao, LOU Wenjuan. Nonlinear finite element analysis on galloping of ice-coated transmission line[J]. Power System Technology, 2010, 34(12): 214-218.
- [11] 楼文娟, 杨伦, 潘小涛, 等. 覆冰导线舞动响应的双参数分岔研究[J]. 中国电机工程学报, 2014, 34(36): 6592-6600.
LOU Wenjuan, YANG Lun, PAN Xiaotao, et al. Double-parameter bifurcation study on galloping of iced-bundle conductor[J]. Proceedings of the CSEE, 2014, 34(36): 6592-6600.
- [12] OH Y J, SOHN J H. Stability evaluation of the transmission line by using galloping simulation[J]. International Journal of Precision Engineering and Manufacturing, 2020, 21: 2139-2147.
- [13] 詹坤, 高广德, 陈亚龙, 等. 基于辅助磁芯阻抗自适应调整的输电线路在线稳定取能方法[J]. 电力系统保护与控制, 2024, 52(10): 74-83.
ZHAN Kun, GAO Guangde, CHEN Yalong, et al. An online stable energy extraction method for a transmission line based on adaptive adjustment of auxiliary core impedance[J]. Power System Protection and Control, 2024, 52(10): 74-83.
- [14] 张焕龙, 齐企业, 张杰, 等. 基于改进 YOLOv5 的输电线路鸟巢检测方法研究[J]. 电力系统保护与控制, 2023, 51(2): 151-159.
ZHANG Huanlong, QI Qiye, ZHANG Jie, et al. Bird nest detection method for transmission lines based on improved YOLOv5[J]. Power System Protection and Control, 2023, 51(2): 151-159.
- [15] YANG Wei, SHAO Yingbiao, LÜ Zhongbin, et al. Study on monitoring for power transmission line galloping based on monocular vision method[C] // 2014 International Conference on Power System Technology, October 20-22, 2014, Chengdu, China: 1571-1575.
- [16] 任佳颖, 李小雨, 房体育, 等. 基于间隔棒跟踪的输电线路舞动检测[J]. 济南大学学报(自然科学版), 2022, 36(4): 424-432.
REN Jiaying, LI Xiaoyu, FANG Tiyu, et al. Detection of transmission line galloping based on spacer tracking[J]. Journal of University of Jinan (Science and Technology), 2022, 36(4): 424-432.
- [17] 谢天叶. 基于视频跟踪的输电线路舞动监测技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2021.
XIE Tianye. Research on monitoring technology of

- transmission line galloping based on video tracking[D]. Harbin: Harbin Institute of Technology, 2021.
- [18] 魏贤哲, 卢武, 赵文彬, 等. 基于改进 Mask R-CNN 的输电线路防外破目标检测方法研究[J]. 电力系统保护与控制, 2021, 49(23): 155-162.
WEI Xianzhe, LU Wu, ZHAO Wenbin, et al. Target detection method for external damage of a transmission line based on an improved Mask R-CNN algorithm[J]. Power System Protection and Control, 2021, 49(23): 155-162.
- [19] 王道累, 张正刚, 张世恒, 等. 基于密集连接网络的航拍绝缘子旋转目标精准定位方法[J]. 电力系统保护与控制, 2024, 52(1): 35-43.
WANG Daolei, ZHANG Zhenggang, ZHANG Shiheng, et al. Accurate positioning method of insulator rotating target in aerial photography based on dense connection network[J]. Power System Protection and Control, 2024, 52(1): 35-43.
- [20] 麻祥才, 曹前, 白春燕, 等. 基于光谱反射率的低照度图像增强方法研究[J]. 光谱学与光谱分析, 2024, 44(3): 610-616.
MA Xiangcai, CAO Qian, BAI Chunyan, et al. Research on low illumination image enhancement method based on spectral reflectance[J]. Spectroscopy and Spectral Analysis, 2024, 44(3): 610-616.
- [21] 肖志云, 王海强. 图像双分割与小波域多特征融合的高压输电线路典型小目标故障识别[J]. 电网技术, 2021, 45(11): 4461-4469.
XIAO Zhiyun, WANG Haiqiang. Typical small target fault identification of high-voltage transmission lines based on image double segmentation and fusion of multi-features in wavelet domain[J]. Power System Technology, 2021, 45(11): 4461-4469.
- [22] 何雪东, 宣士斌, 王款, 等. 融合累积分布函数和通道注意力机制的 DeepLabV3+图像分割算法[J]. 计算机应用, 2023, 43(3): 936-942.
HE Xuedong, XUAN Shibin, WANG Kuan, et al. DeepLabV3+image segmentation algorithm fusing cumulative distribution function and channel attention mechanism[J]. Journal of Computer Applications, 2023, 43(3): 936-942.
- [23] 刘士坤, 金诚谦, 陈满, 等. 基于 DeepLabV3+网络的机收大豆破碎率在线检测方法[J]. 中国农机化学报, 2023, 44(5): 170-175.
LIU Shikun, JIN Chengqian, CHEN Man, et al. Online detection method of detecting crushing rate of soybean harvesters based on DeepLabV3+network[J]. Journal of Chinese Agricultural Mechanization, 2023, 44(5): 170-175.
- [24] 李烁, 顾益军, 谭昊, 等. 改进 Xception 网络的声纹对抗检测研究[J]. 计算机工程与应用, 2023, 59(14): 232-241.
LI Shuo, GU Yijun, TAN Hao, et al. Research on voiceprint adversarial detection of improved Xception network[J]. Computer Engineering and Applications, 2023, 59(14): 232-241.
- [25] 颜玉松, 尹芳洁, 王彩玲. 融合 Xception 特征提取和坐标注意力机制的血细胞分割[J]. 计算机系统应用, 2023, 32(1): 275-280.
YAN Yusong, YIN Fangjie, WANG Cailing. Blood cell segmentation fusing Xception feature extraction and coordinate attention mechanism[J]. Computer Systems & Applications, 2023, 32(1): 275-280.
- [26] 王有元, 任欢, 杜林. 输电线路导线舞动轨迹监测分析[J]. 高压技术, 2010, 36(5): 1113-1118.
WANG Youyuan, REN Huan, DU Lin. Analysis on conductor galloping track monitoring of transmission line[J]. High Voltage Engineering, 2010, 36(5): 1113-1118.
- [27] 秦珮瑄. 结合注意力机制和在线样本库的目标跟踪算法[D]. 南昌: 南昌航空大学, 2021.
QIN Peixuan. Object tracking method based on attention model and online sample pool[D]. Nanchang: Nanchang Hangkong University, 2021.
- [28] 谢青松, 刘晓庆, 安志勇, 等. 基于前景优化的视觉目标跟踪算法[J]. 电子学报, 2022, 50(7): 1558-1566.
XIE Qingsong, LIU Xiaoqing, AN Zhiyong, et al. Visual object tracking algorithm based on foreground optimization[J]. Acta Electronica Sinica, 2022, 50(7): 1558-1566.
- [29] 寇鹏, 智帅峰, 程耘, 等. 空间目标自适应光学图像椭圆部件检测[J]. 中国光学, 2022, 15(3): 454-463.
KOU Peng, ZHI Shuaifeng, CHENG Yun, et al. Detection of elliptical components in adaptive optical image of space target[J]. Chinese Optics, 2022, 15(3): 454-463.
- [30] 鲍文霞, 邱翔, 胡根生, 等. 基于椭圆型度量学习空间变换的水稻虫害识别[J]. 华南理工大学学报(自然科学版), 2020, 48(10): 136-144.
BAO Wenxia, QIU Xiang, HU Gensheng, et al. Identification of rice pests based on space transformation by elliptic metric learning[J]. Journal of South China University of Technology (Natural Science Edition), 2020, 48(10): 136-144.

收稿日期: 2024-05-16; 修回日期: 2024-08-18

作者简介:

金沫含(2001—), 女, 硕士研究生, 主要研究方向为输电线路巡检; E-mail: ts22230028a311d@cumt.edu.cn

梁睿(1981—), 男, 通信作者, 博士, 教授, 主要研究方向为电力系统安全与保护、综合能源系统优化运行。E-mail: liangrui@cumt.edu.cn

(编辑 周金梅)