文章编号:1674-2974(2025)06-0155-11 DOI:10.16339/j.cnki.hdxbzkb.2025185

面向登高作业的视觉与气压传感器融合高程测量方法

赵旭,罕天玺,唐立军,杨迎春†
(云南电网有限责任公司 电力科学研究院,云南 昆明 650500)

摘 要:为了在作业现场便捷、准确地测量登高作业人员距离地面的高度,提出了一种融合大气压力测高和视觉检测的高程测量方法.建立YOLOX深度网络来检测现场作业图像中的登高作业人员,确定作业人员在图像中的高度位置.利用大气压力传感器对作业人员登高过程中短期的实际高度变化值进行检测.根据大气压力测高结果以及视觉检测结果,利用支持向量回归(SVR)建立并更新作业人员的图像位置与实际高程之间的回归模型,最终由回归模型获得高准确度的测高结果.在实际的登高作业实验中,将所提方法与大气压力传感器直接测高及大气压力传感器比对法测高进行对比,该方法的平均绝对测高误差和均方根测高误差均低于0.2 m,优于其他对比方法.所提方法通过视觉与大气压力传感器的融合,既克服了大气压力传感器测高漂移严重、长时间使用时精度低的问题,也避免了视觉检测中的人工标定过程,测高精度能够满足登高作业现场的人员测高需求,且便于实施,不会增加作业人员的工作负担,对于登高作业安全监护具有明显的实用性.

关键词:高度测量;目标检测;YOLOX;回归分析;高空作业
中图分类号:TP391.4 **文献标志码**:A

An Elevation Measurement Method Based on Fusion of Vision and Barometric Sensors for Aerial Work

ZHAO Xu, HAN Tianxi, TANG Lijun, YANG Yingchun†
(Research Institute of Electric Power Science, Yunnan Power Grid Co., Ltd., Kunming 650500, China)

Abstract: An elevation measurement method via the fusion of vision and barometric sensors is proposed to achieve convenient and accurate measurement of the elevations of operators during aerial work. A YOLOX deep neural network is constructed to detect the aerial operators and their positions in the pictures of the aerial work site. The changes of real altitude in the relatively short period of climbing are measured via a barometric sensor. Using the barometric elevation measurement and vision detection results, the support vector regression (SVR) is applied to construct and update the regressive model between the image position and the actual elevation of the operator, and the high accuracy elevation measurement results are obtained through the regressive model. In real-world aerial work experiments, the proposed method is compared with the direction elevation measurement using a single barometric

* **收稿日期**:2023-09-18
基金项目:中国南方电网有限责任公司创新项目(YNKIXM20210196), Innovation Program of China Southern Power Grid Co., Ltd. (YNKIXM20210196)
作者简介:赵旭(1989—),男,云南昆明人,云南电网有限责任公司电力科学研究院高级工程师
† 通信联系人,E-mail:kmyyc@126.com

sensor and the differential elevation measurement by two barometric sensors. The measurement errors, in the mean absolute error as well as in the root-mean squares-error, of the proposed method are all lower than 0.2 m, and are superior to the two rival methods. The performances of the proposed methods are achieved by fusing the vision detection and the barometric elevation measurement, which overcomes the serious signal shifting and degradation of measurement accuracy of the barometric sensors, and also avoids the laborious calibration procedure of the vision detection system. The proposed method's elevation measurement accuracy satisfies the requirement on the operator in aerial work, and it is easy to apply in work sites without putting extra burdens on the operators, making the method a practical choice for operator safeguarding in aerial work.

Key words: altitude measurement; target detection; YOLOX; regression analysis; aerial work

近年来电力系统行业的快速发展,使得电力设施的维护和安全检查成为电网工作人员的核心任务之一[1]. 但在实际工作中,电力设施通常位于高塔或电线杆等高空危险环境,长时间的高空作业会造成现场工作人员的安全作业意识减弱,导致高空作业中安全生产事故发生. 在高空作业违章行为的检测过程中,首要任务是准确测量配网作业现场作业人员及工器具相对于地面的高度,从而进一步确保安全生产等目标的实现. 因此,实时在线监控电网工作人员并进行身份识别,以及精确测量施工高度,有助于降低工作风险,提升工作效率,减少事故的发生率,确保安全生产[2].

作业现场的高度测量,主要是测量作业人员或工器具相对于地面的高度. 目前测量两点间相对高度的技术手段主要包含激光测距仪、超声波测距仪、GPS测量、气压传感器等[3]. 文献[4]通过激光测距仪测量出工作人员与监测基站之间的空间距离,并结合气压高度传感器和温度计对获取的高度值进行修正. 但激光测距仪受光照影响较大,建立监测基站会增大成本. 超声波测距仪对光照变化的鲁棒性相对较强,文献[5]提出了一种便携式的大量程超声波线缆测高仪以准确测量高压架空线缆对地高度和相间距离. 但是超声波测距仪依然存在受环境噪声和声波传播速度的影响导致精度降低的问题. 针对配网作业现场应用来说,气压传感器因具有成本低、便于携带等优势,正在被广泛地应用于电网行业测高领域. 然而,气压传感器随着工作时间的推移会存在漂移等问题. 为解决该问题,文献[6]使用气压高度计和无线电高度表进行高度数据融合,对无线电高度表的高频噪声和气压高度计的零漂和时漂进行抑制. 文献[7]为了解决单独使用气压高度计时存在的数据不稳定以及精度不够等问题,采用卡尔曼滤波算法对气压高度计与GPS测量高度数据进行数据融合,提高GPS/气压高度计组合测高系统的测量精度,满足在高处作业设备高度测量应用中的要求. 然而,传统的检测手段检测精度有限,难以满足作业现场复杂环境的人员安全隐患检测需求,并对其进行相应管理.

随着计算机算力的飞速发展,卷积神经网络(CNN)以其卓越的自动特征学习能力、适应性、泛化能力以及端到端学习优势和多模态数据处理能力等,已经成为各个领域的有力工具[8]. 目标检测作为计算机视觉中最核心的任务之一,可以同时学习低级和高级图像特征,有更好的检测精度和泛化能力[9],从而被广泛应用于行人检测、施工作业现场等领域. 如文献[10]提出了一种基于改进的YOLOv3算法的行人检测方法. 针对施工现场的设备检测与定位问题,文献[11]提出了一种基于改进YOLOv3和改进灰狼优化器定位的极端学习机的实时多尺度设备检测和定位模型,文献[12]提出了一种基于改进YOLOv5的露天矿山目标检测方法.

目前,基于深度学习的目标检测主要分为两类:两阶段检测和单阶段检测[13]. 两阶段检测算法如区域卷积神经网络(Region-CNN)、快速区域卷积神经网络(FAST R-CNN)等具有精度高等优势,但是计算量过大,限制了它们在线下部署中的应用. 单阶段检测方法则以其较低的计算需求获得了广泛应用,代表性的算法包括YOLO系列、单次多框检测器(single shot multibox detector, SSD)、反卷积单次多框检测器(deconvolutional single shot detector, DSSD)

等[14]. 单阶段检测虽然精度略低,但是需要的算力大幅减少,尤其是YOLO算法以其出色的实时性能,已经在电力行业等领域取得了广泛应用. 如文献[15]针对作业人员穿戴防护服和安全帽不规范的问题,搭建了基于YOLOv4-MobileNetv3的目标检测网络模型,其在识别精度满足需求的基础上提升了检测速度. 文献[16]建立了基于模式识别的作业人员身份鉴定系统,通过增强Adaboost算法进行作业人员的人脸检测和身份识别,通过改进的YOLOv3检测算法提高了现场作业人员及安全帽佩戴情况的检测稳定性.

登高作业是配网作业中事故率较高的作业场景,本文针对传统高度测量算法精度差的问题,提出一种基于YOLOX (you only look once X)模型和支持向量回归(support vector regression, SVR)算法的拟合修正算法YOLOX-SVR,实现对电网工人施工高度的准确测量,提高单气压传感器的检测精度,去除漂移产生的误差. 该算法首先采集工人爬杆、爬梯数据,构建数据集,在YOLOX预训练模型上进行训练和验证. 然后,利用SVR算法对模型识别出的电网工人坐标变化和单气压传感器的高度变化进行迭代拟合,以达到修正漂移误差的目的. 最后,分别在爬梯和爬杆场景下对所提算法进行验证,实验结果表明该算法效果远远优于双气压传感器的测高.

1　相关理论

1.1　YOLOX目标检测算法

YOLOX是一种端到端的无锚框(anchor-free)的单阶段目标检测算法[17]. 相较于YOLOv3、YOLOv4、YOLOv5,YOLOX在网络结构、锚机制和正负样本匹配策略等方面有所优化,提高了模型的检测速度和精度[18]. YOLOX根据网络不同的宽度和高度,分为标准网络结构和轻量级网络结构. 为在爬高人员检测中保证较高的实时性,本文选择了轻量级模型YOLOX-S.

YOLOX-S网络结构主要由特征提取模块、特征融合模块和预测模块3部分组成,网络架构如图1所示.

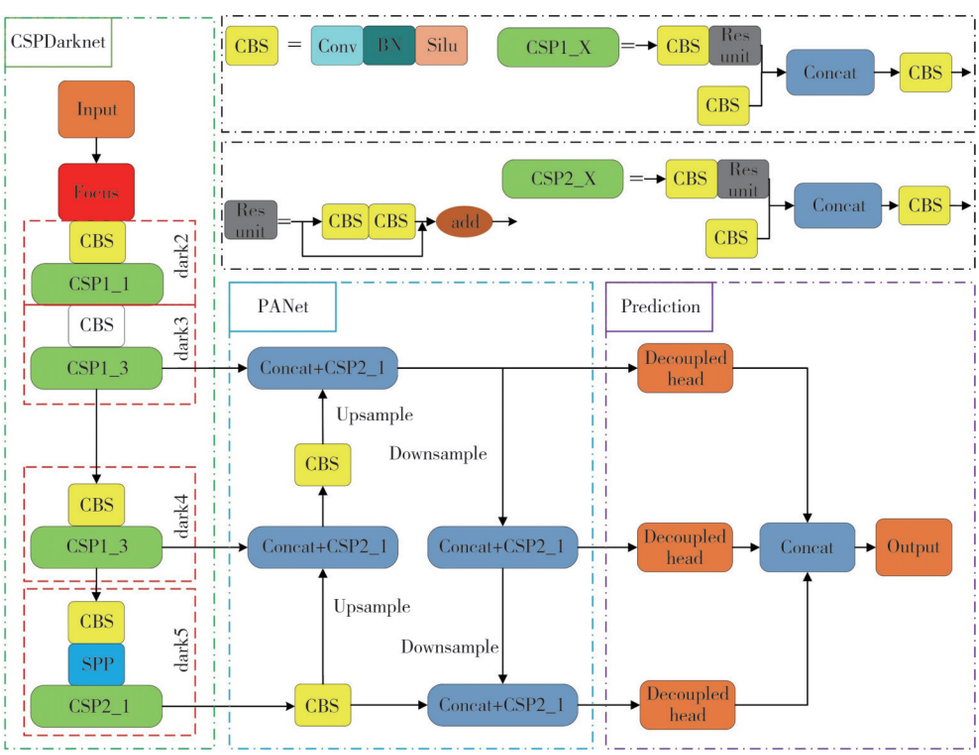


图1　YOLOX-S网络架构

Fig.1　YOLOX-S network structure

特征提取模块采用CSPDarknet网络架构,该架构主要包含聚焦(Focus)结构、跨阶段局部网络(cross stage partial network, CSPNet)模块和空间金字塔池化(spatial pyramid pooling, SPP)模块[19]. Focus结构通过对图片进行隔像素抽取,将高分辨率区域和低分辨率区域相结合实现了下采样操作,如图2

所示;跨阶段局部网络(CSPNet)包含的残差结构可以避免网络深度增加带来的梯度消失问题;SPP模块通过对不同大小的区域进行池化操作,并将池化结果进行拼接,从而实现了对不同尺度的输入特征图进行自适应的池化操作,增大了感受野,优化了模型对不同大小目标的检测效果,如图3所示.

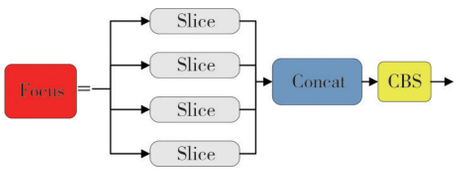


图2 Focus模块结构

Fig.2 Focus module structure

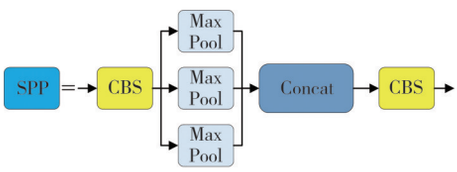


图3 空间金字塔池化模块结构

Fig.3 SPP module structure

图1中特征融合模块通过上采样和下采样来实现特征融合.从底层特征图开始,通过上采样逐步提高特征图的分辨率和语义信息;从高层特征图开始,通过下采样和卷积等操作逐步降低特征图的分辨率,提高语义信息.

在预测模块,YOLOX-S选择解耦头作为检测层部分.与耦合头不同的是,解耦头将分类和回归任务独立出来,每个任务使用单独的神经网络来处理[20].如图4所示,模型首先通过1×1的卷积层将通道数目减少到256个,然后增加两个平行的分支,每个分支由两个3×3的卷积层组成,分别用于分类任务和回归任务.最终在预测端输出3个尺度的特征图,大小分别为20×20、40×40、80×80.

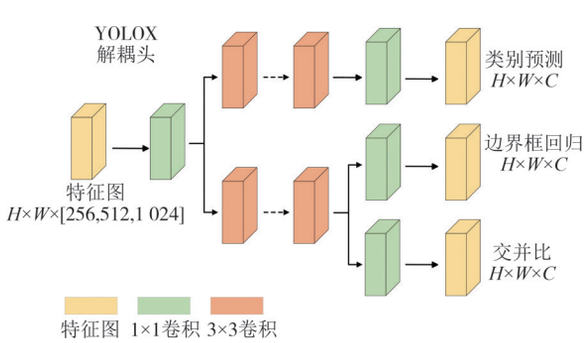


图4 解耦头网络结构

Fig.4 Decoupled head network structure

为了提高模型性能,YOLOX-S在标签分配策略上对最优传输分配(optimal transport assignment, OTA)进行了简化,提出了SimOTA标签分配策略来动态分配正负样本[21].通过限制搜索空间的数量得到样本最佳匹配,将代价函数分为分类损失和回归损失,最小化代价函数使网络以最小的学习成本获得有效信息.首先根据锚框的中心点对锚点进行预筛选,设定一个大小为5×5的固定中心区域.接着根据初步筛选确定正样本候选区域位置,计算初步确定正样本候选区域的预测框与真实目标边界框之间的IOU损失函数与分类置信度损失函数,对这两种损失函数进行加权求和.初步筛选正样本预测框的代价损失函数如式(1)所示:

$$\mathbf{cost}_{ij} = L_{ij}^{\mathrm{cls}} + \alpha L_{ij}^{\mathrm{reg}} \tag{1}$$

式中:α为位置回归损失函数的权重系数;L_{ij}^{cls}为正样本预测框与真实框之间分类损失;L_{ij}^{reg}为正样本预测框与真实框之间的位置回归损失;i代表样本的编号;j代表预测结果的类别分类.

针对每个真实框,动态确定分配预测框个数p,具体包括:选取前10个IOU最大的预测框,对于每个真实框中的10个预测框,将其交并比相加取整,得到需要分配的个数p,前p个预测框则会被当作正样本处理,每个真实目标框代价矩阵**cost**排名最小的前p个先验框作为正样本,其余的均为负样本.

1.2 支持向量回归

支持向量回归算法是在支持向量机(support vector machine, SVM)算法的基础上对解决回归问题的进一步应用[22],该算法实现了最小化总损失和最大化间隔,保证结果最优化的目的,如图5所示.训练数据集$T = \{(\boldsymbol{x}_i, \boldsymbol{y}_i), i = 1, 2, \cdots, m\}$用于在线预测,其中$\boldsymbol{x}_i \in X \subseteq \mathbf{R}^n$,$\boldsymbol{y}_i \in Y \subseteq \mathbf{R}^n$,$m$是训练样本总数,SVR的线性回归函数可以表示为:

$$f(\boldsymbol{x}_i) = \boldsymbol{w}^{\mathrm{T}}\phi(\boldsymbol{x}_i) + b \tag{2}$$

式中:$\boldsymbol{w}$是特征空间$\boldsymbol{F}$中权重向量;$\phi(\boldsymbol{x}_i)$是输入X映射到$\boldsymbol{F}$中的向量;b为偏移量.

为使数据到超平面的距离d最小,SVR算法在线性函数的两侧设置容忍偏差ε.对样本点$\boldsymbol{x}_i$,如果其回归值在容忍偏差内,则忽略其损失,超出容忍偏差则计算损失值$l_\varepsilon(\boldsymbol{x}_i)$:

$$l_\varepsilon(\boldsymbol{x}_i) = \begin{cases} 0, & |f(\boldsymbol{x}_i) - \boldsymbol{y}_i| \leqslant \varepsilon \\ |f(\boldsymbol{x}_i) - \boldsymbol{y}_i| - \varepsilon, & |f(\boldsymbol{x}_i) - \boldsymbol{y}_i| > \varepsilon \end{cases} \tag{3}$$

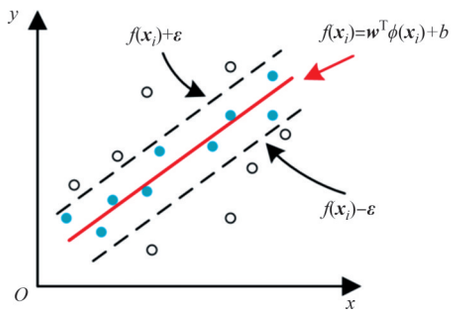


图 5　SVR 算法原理图

Fig.5　SVR algorithm schematic diagram

为确保大部分数据在容忍偏差内,SVR 算法加入松弛变量ξ. 引入松弛变量后的SVR 表示为如下最小化问题:

$$\min_{w,b}:\frac{1}{2}\|w\|^2+C\sum_{i=1}^{m}\left(\xi_i^{+}+\xi_i^{-}\right) \tag{4}$$

$$\text{s.t.}\begin{cases} f(x_i)-y_i\leqslant\varepsilon+\xi_i^{+} \\ y_i-f(x_i)\leqslant\varepsilon+\xi_i^{-} \\ \xi_i^{+}\geqslant 0,\xi_i^{-}\geqslant 0,i=1,2,\cdots,m \end{cases} \tag{5}$$

式中:ξ_i^{+}、ξ_i^{-}分别为上、下边界的松弛因子;C为惩罚因子,其值越小,拟合误差对回归结果的影响越小.

为更好地处理非线性关系的回归任务,解决高维度特征空间中目标函数不可微的问题,SVR 算法引入核函数,如线性核、多项式核、高斯核、拉普拉斯核以及 Sigmoid 核. 核函数的存在可以将数据映射到高维空间,以此实现对非线性数据点的分离,同时增加了模型的复杂度,提高模型的拟合能力. 由于高斯核具有更好的自适应性和更快的计算速度,因此本文选择高斯核作为模型的核函数,其表达式为:

$$k(x_i,x_j)=\exp\left(-\frac{\|x_i-x_j\|^2}{2\sigma^2}\right) \tag{6}$$

式中:$\sigma>0$为高斯核的带宽. 此时,SVR 算法求得的最优决策函数为:

$$f(x)=\sum_{i=1}^{m}\left(\tilde{\alpha}_i-\alpha_i\right)k\left(x_i,x_j\right)+b \tag{7}$$

式中:$\tilde{\alpha}_i,\alpha_i$为引入的拉格朗日算子.

2　YOLOX-SVR 拟合模型构建

为实现对登高作业人员进行精准识别以及对其高度进行准确输出的目的,本节针对登高作业人员和登高数据集训练得到 YOLOX 模型,设定合适阈值,优化验证模块的输出部分,以去除行人和其他干扰. 在目标检测部分达到准确识别后,将检测目标的中心点像素坐标输入改进的SVR 算法中,设置修正拟合算法对气压传感器的漂移量进行修正.

2.1　模型构建

2.1.1　数据集构建

本文旨在设计一个登高人员检测算法,实现对室外环境的登高行为的准确识别,因此需要构建一个大型数据集对模型进行训练和测试. 构建的数据集共包含 2 589 张实验人员户外工作的图片,使用 LabelImg 软件对实验人员进行边界框和标签的标注. 然后将数据按照 7∶3 的比例划分为训练集和测试集,用于模型的训练,如图 6(a)所示. 为验证所训练的模型对登高等行为的识别能力,本文同时采集了不同背景下的爬梯和爬杆两种数据,来验证模型的鲁棒性和泛化性,如图 6(b)所示.



(a)训练数据集



(b)验证数据集

图 6　部分训练数据集和验证数据集

Fig.6　Part of the training data set and validation data set

2.1.2　模型训练

实验训练环境为:深度学习框架 Pytorch 1.8.1,CUDA12.2;操作系统 Ubuntu 20.04.6 LTS;处理器 4 核 Intel(R) Core i7-7820X CPU @3.60 GHz;内存 32 GB;RTX3090 显卡,显存 24 GB.

实验参数配置如下:训练批次为 300,Batchsize 为 64,学习率初始值为 0.01,SGD 动量为 0.9. 数据输入的初始大小为 640×640×3,经过 CSPDarknet 特征提取模块后,分别输出 80×80×256、40×40×512、20×20×1 024,如图 7(a)所示. 将以上 3 种不同维度的输出分别输入 PANet 特征融合模块中进行不同尺度下

的上采样和下采样操作,如图7(b)所示.在预测模块,通过解耦头得到3个不同维度的特征图,最终输出8 400个预测框,模型各模块具体输入和输出如图7(c)所示.每个预测边框可以用特征向量$\boldsymbol{P}$表示为:

$$\boldsymbol{P}=\left(b_x, b_y, b_w, b_h, \text{object_conf}, \text{cls_conf}\right) \tag{8}$$

式中:b_x为预测框中心点x轴坐标;b_y为预测框中心点y轴坐标;b_w和b_h分别为预测框宽和高;object_conf代表特征点预测框内部包含物体的概率;cls_conf代表特征点对应测高工作人员的概率.最后,通过非极大值抑制(NMS)筛选,保留最可靠的预测框以及种类.经多次训练后,选择最优训练模型以供后续使用.

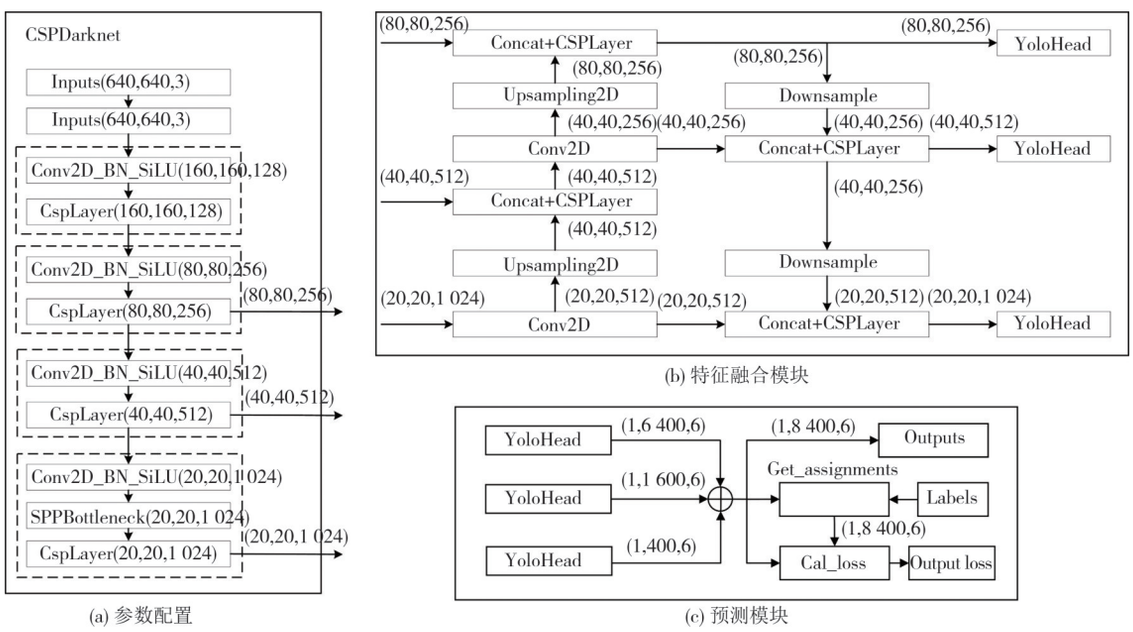


图7 YOLOX-S模型输入输出图

Fig.7 YOLOX-S model input and output diagram

2.1.3 模型输出的阈值处理

为验证训练模型的可靠性,准确输出验证数据集中预测框中心点的像素坐标,本节采用验证数据集对模型进行验证.考虑到施工现场会出现地面工作人员和路人等情况,本节对验证算法中的输出端进行修改,通过设置阈值来检测像素变化,进而判断是否为爬高工人,保证在测高过程中像素坐标输出的准确性.具体包括:在1 s内,对预测框中心点x轴像素坐标变化值$\left|\Delta b_x\right|$小于或等于阈值a_1和y轴像素坐标变化值$\left|\Delta b_y\right|$大于或等于阈值a_2的预测框进行输出,反之删除该框.检测结果is_op为:

$$\text{is_op}=\begin{cases}\text{True}, & \left|\Delta b_x\right| \leqslant a_1 \text{且} \left|\Delta b_y\right| \geqslant a_2 \\ \text{False}, & \text{其他}\end{cases} \tag{9}$$

图8是模型验证结果图.当不使用阈值处理时,在较为复杂的环境下,例如有行人经过视频采集区域时,模型会将行人识别出来,从而导致模型对实验人员位置坐标输出错误.加入阈值处理后,模型可有效排除行动轨迹主要在水平方向的非实验人员,并保留主要行动方向在垂直方向的登高实验人员,提高了检测的准确性,为后续的融合处理打下了良好的基础.



(a)t_1时刻不使用阈值处理 (b)t_1时刻使用阈值处理 (c)t_2时刻不使用阈值处理 (d)t_2时刻使用阈值处理

图8 模型验证结果图

Fig.8 Model verification result chart diagram

2.2 融合视觉信息的SVR回归

如果将登高人员的像素坐标数据集Y与实际高度数据集H直接作为算法的输入和输出进行拟合,则结果受到的测高噪声影响偏大.利用视觉检测的结果,可以形成对测高结果的“反馈”,从而减小误差.因此,为实现YOLOX算法得出的像素点纵轴坐标b_y与电网工人真实高度h两者之间的较好拟合,本文采用融合视觉信息的SVR算法对数据进行分析

拟合.

理论分析表明,作为回归函数自变量的作业人员像素高度位置所覆盖的取值范围越大,回归模型的稳定性越好.因此,为了提高本文中建立的线性回归模型的稳定性,设置起始阈值T_0,当作业人员的像素高度位置与初始时刻位置之差大于或等于T_0时,算法开始执行回归分析.同时,为降低时漂数据对回归函数拟合精度的影响以及减少模型逐点拟合所增加的计算量,设置终止阈值T_1,当参与拟合的数据点数量总和超过T_1时,模型停止回归拟合操作,此时该点的拟合函数作为最终的线性回归函数.算法具体步骤如下:

设定初始时刻作业人员的像素高度位置为b_{y_1},实际高度h_1=0.初始时刻算法运行于非拟合状态.

设从作业起始时刻开始,在非拟合状态下到当前时刻为止所得到的作业人员像素高度位置序列为$Y_n=\{b_{y_1},b_{y_2},b_{y_3},\cdots,b_{y_{n-1}},b_{y_n}\}$,单气压传感器测量得到的相应作业人员高度变化序列为$H_n=\{h_1,h_2,h_3,\cdots,h_{n-1},h_n\}$.$b_{y_k}$表示第$k$次检测到有登高人员且其高度位置发生变化时所得到的对应像素高度位置,即YOLOX模型输出的is_op为True时人员的相对高度位置;h_k则是由起始时刻开始,每次is_op为True时大气压力测高信号中所对应的高度变化值.

如果b_{y_n}首次满足:

$$\left|b_{y_n}-b_{y_1}\right|\geqslant T_0 \tag{10}$$

则算法切换到拟合状态.此时,利用SVR算法对Y_n和H_n进行拟合,得到当前的回归模型$h=f_n\left(b_y\right)$.利用当前回归函数f_n得到修正后的当前时刻登高人员实际高度值为:

$$h'_n=f_n\left(b_{y_n}\right) \tag{11}$$

用当前时刻修正后的实际高度替代原始测得的实际高度,得到修正后的实际高度序列:

$$H'_n=\{h_1,h_2,h_3,\cdots,h_{n-1},h'_n\} \tag{12}$$

对于视频下一帧输入的作业人员像素高度$b_{y_{n+1}}$,以及其对应的高度值h_{n+1},继续通过SVR拟合,得到回归模型$h=f_{n+1}\left(b_y\right)$,进而得到修正后的当前时刻实际高度值为:

$$h'_{n+1}=f_{n+1}\left(b_{y_{n+1}}\right) \tag{13}$$

修正后的实际高度序列为:

$$H'_{n+1}=\{h_1,h_2,\cdots,h_{n-1},h'_n,h'_{n+1}\} \tag{14}$$

对于第k(k>n)次检测到作业人员高度变化,若k=T_1,则$h=f_k\left(b_y\right)$作为最终的线性回归函数,该点之后不再进行回归拟合操作.对于第k+1次所对应的登高人员实际高度值为

$$h'_{k+1}=f_k\left(b_{y_{k+1}}\right) \tag{15}$$

2.3 算法整体流程

图9为YOLOX-SVR拟合模型的具体流程,其步骤如下:

输入:登高作业视频、单气压传感器高度数据、x轴像素坐标变化阈值a_1、y轴像素坐标变化阈值a_2、起始阈值T_0、终止阈值T_1.

输出:YOLOX-SVR算法测量高度.

步骤1:以变量K表示算法是否处于拟合状态,并初始化为False.

步骤2:获取视频帧,利用YOLOX模型检测登高人员位置,返回位置坐标.

步骤3:判断YOLOX模型检测次数是否k>T_1,若是,则至步骤7;否则,至步骤4.

步骤4:如果K = True,则将当前时刻的实际高度测得值与视频中登高人员的像素高度位置加入拟合数据集,利用SVR得到回归模型h.否则,至步骤5.

步骤5:如果当前时刻登高人员的像素高度位置满足式(10)的判断条件,则置K=True,至步骤4;否则,以当前时刻实际高度测得值作为测量结果,并加入算法测得的高度序列,至步骤2.

步骤6:利用步骤4所得回归模型h得到修正后的实际高度值,以修正后的值作为测量结果加入算法测得的高度序列,至步骤2.

步骤7:输入当前像素高度值至步骤4所得回归模型h,得到实际高度值.

3 实验结果与分析

3.1 误差评判指标

为分析YOLOX-SVR所得高度的误差,本文选择平均绝对误差(mean absolute error, MAE)和均方根误差(root-mean-square error, RMSE)两种不同的误差评判指标,并且与使用单个气压传感器测高的

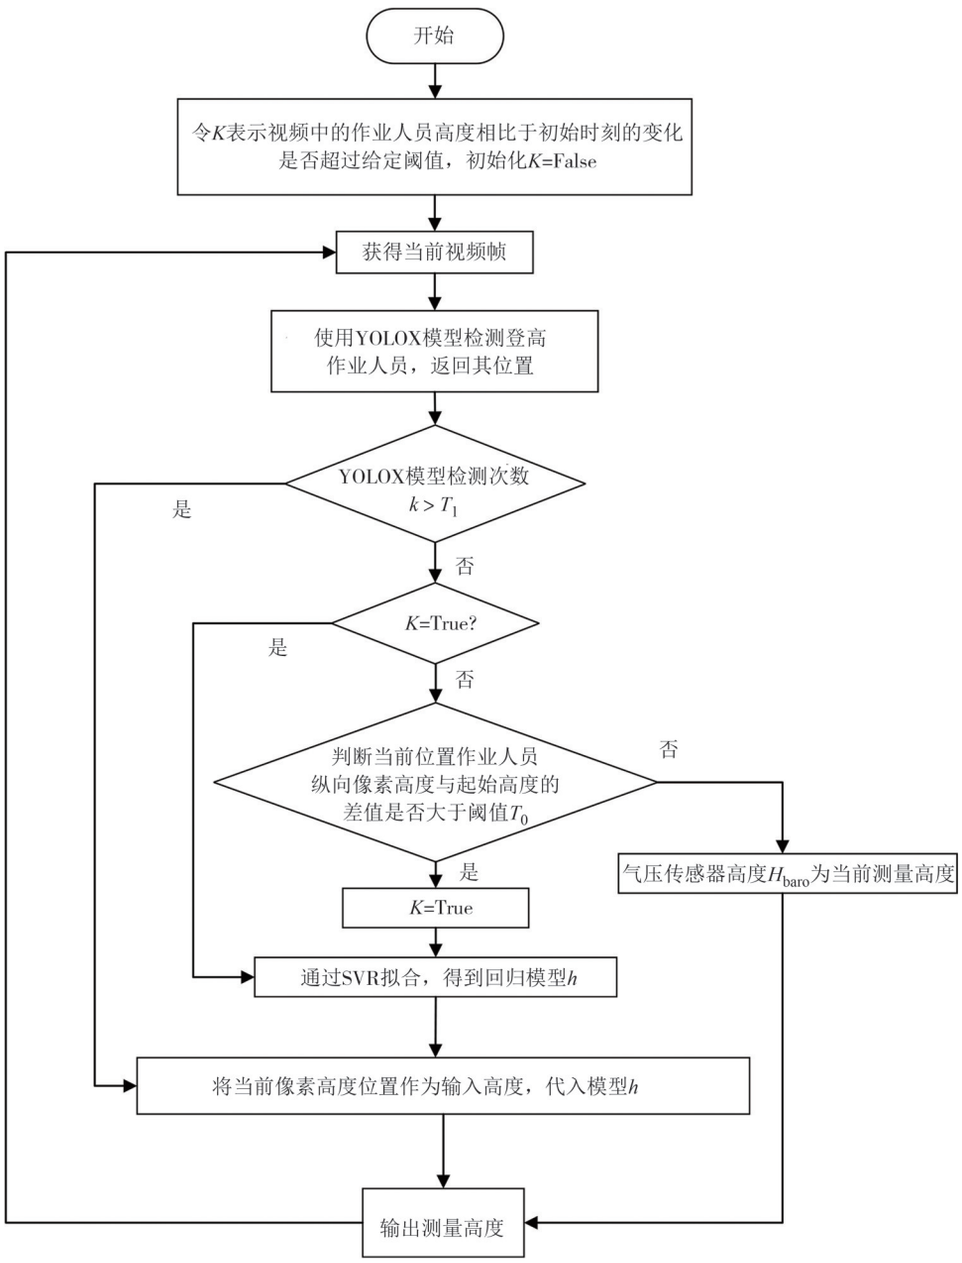


图 9 YOLOX-SVR 模型流程图

Fig.9 Flow chart of YOLOX-SVR model

结果,和利用与地面参考气压传感器比对的双气压传感器法所得的测高结果,进行算法性能比较.

MAE计算公式为:

$$\mathrm{MAE}=\frac{1}{m}\sum_{i=1}^{m}\left|h\left(x_i\right)-y_i\right| \tag{16}$$

其中,MAE是预测误差绝对值的平均值,直接反映预测值与真实值的平均绝对偏差.

RMSE计算公式为:

$$\mathrm{RMSE}=\sqrt{\frac{1}{m}\sum_{i=1}^{m}\left(h\left(x_i\right)-y_i\right)^2} \tag{17}$$

其中,RMSE 是预测误差平方的平均值的平方根,衡量预测值与真实值之间的标准差.

3.2 结果与分析

本文分别在爬梯和爬杆两种不同场景下对YOLOX-SVR模型拟合方法进行验证,并与单气压传感器和双气压传感器两种方法进行对比.结果表明,所提出的YOLOX-SVR模型拟合方法在两种场景下的高度预测效果均优于其他方法.

如图10所示,红色线段为本文提供的YOLOX-SVR模型预测值;蓝色为单气压传感器测量值;绿色为双气压传感器测量值;黑色为真实高度.可以看

出,在爬梯场景下,3种测量方法的高度变化趋势相同,表明本文所提的拟合测高方法测量的高度与气压传感器所测得的高度均具有可信度.但是本文所提模型的预测值与单气压传感器和双气压传感器的测量值相比,更接近于真实值.且从图10可以看出,单气压传感器测量值随着时间的增长,出现漂移的情况较为明显.双气压传感器起到了去除漂移的作用,但是整体测量值均低于真实值,导致该方法误差较大.如表1所示,在MAE指标下,YOLOX-SVR模型拟合的高度与双气压传感器方法相比误差减少了25.00%,与单气压传感器方法相比误差减少了78.82%;在RMSE指标下,YOLOX-SVR模型拟合的高度与双气压传感器方法相比误差减少了26.92%,与单气压传感器方法相比误差减少了80.61%.

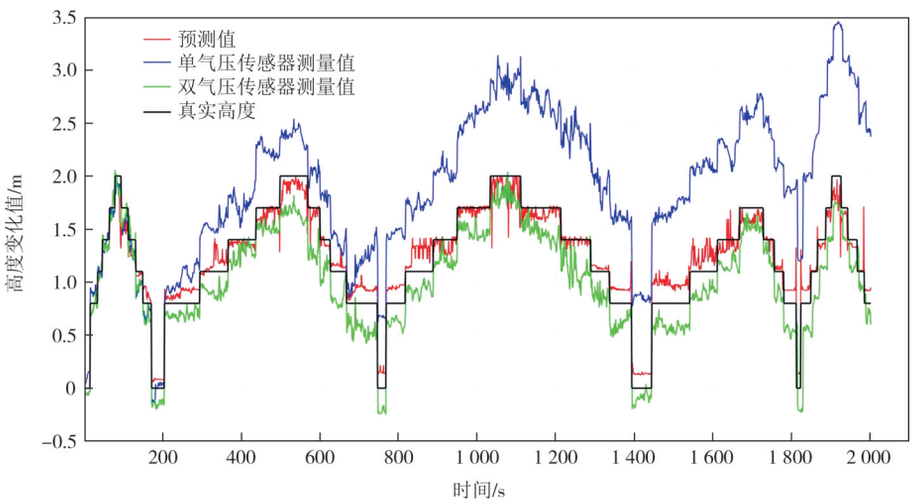


图10　爬梯环境下测量高度变化趋势图

Fig.10　Trend chart of measurement height change in the ladder climbing environment

如图11所示,在爬杆场景下,3种测高方法测得的高度值均出现不同程度波动,但是从整体波动趋势分析,YOLOX-SVR拟合方法的波动区间更小.如表2所示,在MAE指标下,YOLOX-SVR模型拟合的高度与双气压传感器方法相比误差减少了52.38%,与单气压传感器方法相比误差减少了85.71%;在RMSE指标下,YOLOX-SVR模型拟合的高度与双气压传感器方法相比误差减少了45.83%,与单气压传感器方法相比误差减少了83.75%.

表1　爬梯环境下不同指标的误差结果

Tab.1　Error results of different indicators in ladder climbing environment

测量方法	MAE/m	RMSE/m
单气压传感器	0.85	0.98
双气压传感器	0.24	0.26
YOLOX-SVR	0.18	0.19

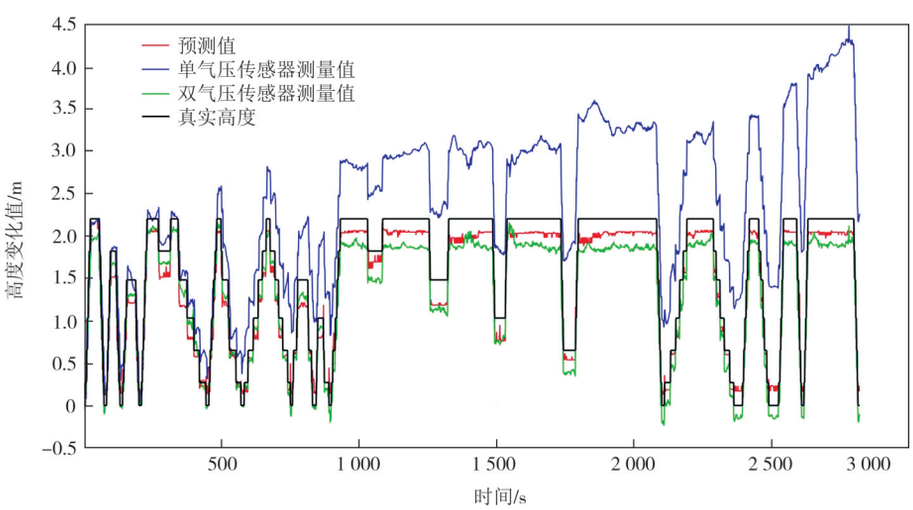


图11　爬杆环境下测量高度变化趋势图

Fig.11　Trend chart of measurement height change in pole climbing environment

表 2 爬杆环境下不同指标的误差结果

Tab.2 Error results of different indicators in pole climbing environment

测量方法	MAE/m	RMSE/m
单气压传感器	0.70	0.80
双气压传感器	0.21	0.24
YOLOX-SVR	0.10	0.13

4 结 论

针对在高空作业过程中施工人员实时高度监测困难,传统检测手段精度有限等问题,本文提出了一种 YOLOX-SVR 模型拟合的高度测量方法. 本文主要工作内容如下:

1) 构建爬高数据集,并利用 LabelImg 软件,手工对所得图像数据进行了标签化处理,并训练最优 YOLOX 模型用以识别爬高工人.

2) 采用回归拟合的理念,构建 YOLOX-SVR 模型框架. 通过设定预测框像素中心点坐标变化的阈值,有效消除了检测过程中行人干扰的问题. 并在 SVR 拟合过程中采用逐点回归拟合的方案,实现对单气压传感器漂移量修正的目的.

3) 将所提的 YOLOX-SVR 拟合模型在平均绝对误差和均方根误差两种不同的误差评判指标下分别与单气压传感器和双气压传感器差值作对比,实验结果表明,本文所提的测量方法预测结果远远优于气压传感器测量的结果,不仅降低了对施工人员高度测量的误差,而且为气压传感器固有的漂移问题提供了新的解决思路.

参考文献

[1] 郭强. 面向物联网的电力电缆综合维护检测系统研究[D]. 西安: 西安电子科技大学,2022.
GUO Q. Research on integrated maintenance and detection system of power cables for Internet of Things [D]. Xi' an: Xidian University,2022.(in Chinese)

[2] 肖扬. 电网运维在线监测系统的设计与实现[D]. 成都: 电子科技大学, 2020.
XIAO Y. Design and implementation of online monitoring system for power grid operation and maintenance [D]. Chengdu: University of Electronic Science and Technology of China, 2020.(in Chinese)

[3] 刘奇, 张双成, 刘宁, 等. GPS反射信号用于海冰识别与海面测高[J]. 测绘科学, 2021, 46(9): 43-48.
LIU Q, ZHANG S C, LIU N, et al. Sea ice recognition and sea surface altimetry use GPS reflected signal [J]. Science of Surveying and Mapping,2021,46(9):43-48.(in Chinese)

[4] 许明杰,徐光智. 安全帽高度定位方法及系统: CN111750823A [P]. 2020-10-09.
XU M J, XU G Z. Helmet height positioning method and system: CN111750823A [P]. 2020-10-09.(in Chinese)

[5] 何凯. 大量程超声波线缆测高仪设计与开发[D]. 西安: 西安建筑科技大学,2018.
HE K. Design and development of large-range ultrasonic cable altimeter [D]. Xi' an: Xi' an University of Architecture and Technology,2018.(in Chinese)

[6] 刘伟, 曾培香, 管伟涛, 等. 微小型惯性/光学/磁罗盘/气压高度组合导航系统研究[J]. 遥测遥控, 2013, 34(5): 21-26.
LIU W, ZENG P X, GUAN W T, et al. Research on mins/optical/magnet compass/barometer integrated navigation system [J]. Telemetry and Remote Control, 2013, 34 (5): 22-26. (in Chinese)

[7] 桂宇贵, 孙佳, 吴杰, 等. 基于GPS/气压高度计的高度数据融合算法研究[J]. 机械与电子, 2017, 35(1): 11-14.
GUI Y G, SUN J, WU J, et al. Research on height data fusion algorithm based on GPS/barometric altimeter [J]. Machinery & Electronics,2017,35(1):11-14.(in Chinese)

[8] OVEIS A H, GIUSTI E, SGHIO S, et al. A survey on the applications of convolutional neural networks for synthetic aperture radar: Recent advances [J]. IEEE Aerospace and Electronic Systems Magazine,2022, 37(5): 18-42.

[9] 张阳婷, 黄德启, 王东伟, 等. 基于深度学习的目标检测算法研究与应用综述[J]. 计算机工程与应用, 2023, 59(18): 1-13.
ZHANG Y T, HUANG D Q, WANG D W, et al. A review on research and application of deep learning-based target detection algorithms [J]. Computer Engineering and Applications, 2023, 59(18): 1-13.(in Chinese)

[10] ZHANG J Q, CHEN X L, LI Y L, et al. Pedestrian detection algorithm based on improved YOLOv3 [C]//2021 IEEE International Conference on Power, Intelligent Computing and Systems (ICPICS). July 29-31, 2021, Shenyang, China: IEEE, 2021: 180-189.

[11] ZENG T C, WANG J J, CUI B, et al. The equipment detection and localization of large-scale construction jobsite by far-field construction surveillance video based on improving YOLOv3 and grey wolf optimizer improving extreme learning machine [J]. Construction and Building Materials, 2021, 291: 1-5.

[12] 秦晓辉, 黄启东, 常灯祥, 等. 基于改进YOLOv5的露天矿山目标检测方法[J].湖南大学学报(自然科学版), 2023, 50(2): 23-30.
QIN X H, HUANG Q D, CHANG D X, et al. Object detection method in open-pit mine based on improved YOLOv5[J]. Journal of Hunan University (Natural Sciences), 2023, 50(2): 23-30. (in Chinese)

[13] XIAO Y Z, TIAN Z Q, YU J C, et al. A review of object detection based on deep learning[J]. Multimedia Tools and Applications, 2020, 79(33): 23729-23791.

[14] CHEN Y C, XU X N. The research of underwater target recognition method based on deep learning [C]//2017 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). October 22-25, 2017, Xiamen, China: IEEE, 2017: 1-5.

[15] 王林林. 基于目标检测与动作识别的多目标视觉监管技术研究[D]. 长春:吉林大学, 2021.
WANG L L. Research on multi-target visual supervision technology based on target detection and motion recognition[D]. Changchun: Jilin University, 2021. (in Chinese)

[16] 许可暘. 基于图像处理技术的电力现场作业人员智能识别及监控系统设计[D]. 杭州: 浙江大学, 2022.
XU K Y. Design of intelligent identification and monitoring system for electric field workers based on image processing technology [D]. Hangzhou: Zhejiang University, 2022. (in Chinese)

[17] SONG J, ZHAO Y, SONG W, et al. Fisheye image detection of trees using improved YOLOX for tree height estimation [J]. Sensors, 2022, 22(10): 1-6.

[18] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO series in 2021[J]. arXiv preprint arXiv: 2107.08430, 2021.

[19] ZHANG Q, HUANG Y R, SONG R. A ship detection model based on YOLOX with lightweight adaptive channel feature fusion and sparse data augmentation[C]//2022 18th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS). November 29 - December 2, 2022, Madrid, Spain: IEEE, 2022: 1-8.

[20] LIU B Q, HUANG J Y, LIN S, et al. Improved YOLOX-S abnormal condition detection for power transmission line corridors [C]//2021 IEEE 3rd International Conference on Power Data Science (ICPDS). December 26, 2021, Harbin, China: IEEE, 2021: 13-16.

[21] WANG G, LIU Z, SUN H, et al. YOLOX-BTFPN: An anchor-free conveyor belt damage detector with a biased feature extraction network[J]. Measurement, 2022, 200: 1-6.

[22] CHEN Y B, XU P, CHU Y Y, et al. Short-term electrical load forecasting using the support vector regression (SVR) model to calculate the demand response baseline for office buildings[J]. Applied Energy, 2017, 195: 659-670.