

# 基于分层搜索与局部约束线性编码的机场检测

胡运强<sup>1\*</sup>, 曹云峰<sup>2</sup>, 丁萌<sup>3</sup>, 庄丽葵<sup>2</sup>

<sup>1</sup>南京航空航天大学自动化学院, 江苏 南京 210016;

<sup>2</sup>南京航空航天大学航天学院, 江苏 南京 210016;

<sup>3</sup>南京航空航天大学民航学院, 江苏 南京 210016

**摘要** 提出一种用于固定翼无人机自主着陆导航的分层机场检测方法,以提高机场检测的速度。采取一种由粗到细的分层搜索结构,逐层缩小搜索面积以快速提取机场的候选区域。首先进行伪地平线检测将机场搜索区域限制为地面区域,然后根据机场区域包含大量垂直线的事实确定机场近似区域候选区以进一步缩小机场搜索区域,最后利用 Edge Boxes 得到高定位精度的机场候选区域。利用局部约束线性编码(LLC)特征学习法以尺度不变特征变换(SIFT)为基础特征提取机场候选区域特征并使用线性支持向量机(SVM)分类器完成机场检测。实验中在不同天气、不同背景条件下对所提机场检测方法进行了综合测试,并与其他方法进行比较,实验结果表明本文机场检测方法能有效提高机场检测速度,且准确率高。

**关键词** 机器视觉; 视觉导航; 固定翼无人机; 自主着陆; 机场检测

中图分类号 V249

文献标识码 A

doi: 10.3788/AOS201838.0815025

## Airport Detection Based on a Hierarchical Architecture and Locality-Constrained Linear Coding

Hu Yunqiang<sup>1\*</sup>, Cao Yunfeng<sup>2</sup>, Ding Meng<sup>3</sup>, Zhuang Likui<sup>2</sup>

<sup>1</sup> College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing, Jiangsu 210016, China;

<sup>2</sup> College of Astronautics, Nanjing University of Aeronautics and Astronautics, Nanjing, Jiangsu 210016, China;

<sup>3</sup> College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing, Jiangsu 210016, China

**Abstract** An airport detection method is proposed for the navigation of fixed-wing unmanned aerial vehicle (UAV) autonomous landing in this paper, which aims at improving the efficiency of detection. A hierarchical architecture is adopted to obtain airport candidate regions which reduces the search space gradually. The pseudo horizon is detected to limit the searching space to the ground area, then candidate approximate airport area is acquired based on the fact that the airport area contains lots of orthogonal line segments. Edge Boxes is adopted to obtain proposals with good localization on the candidate approximate airport areas. Locality-constrained linear coding (LLC) is used for feature extraction with scale-invariant feature transformation (SIFT) as the basic features and linear support vector machine (SVM) is used to finish the task of airport detection. We evaluate the proposed method under different conditions and compare it with other methods. The results show that our method improves the efficiency of airport detection and has a higher average precision.

**Key words** machine vision; visual navigation; fixed-wing unmanned aerial vehicle; autonomous landing; airport detection

**OCIS codes** 150.1135; 100.3008; 200.4560

## 1 引 言

自主着陆是固定翼无人机自主飞行中最具挑战的任务。一些导航系统如惯性导航、卫星导航系统

被尝试用于固定翼无人机自主着陆中<sup>[1]</sup>。但惯性导航系统存在累积误差,卫星导航系统在卫星信号丢失的情况下将无法获得准确的位置信息。这些传统的导航系统不能完全胜任各种条件下的无人机自主

收稿日期: 2018-04-02; 修回日期: 2018-05-02; 录用日期: 2018-05-30

\* E-mail: hupenghyq@163.com

着陆任务。在自然界中,视觉是动物常用且非常有效的局部导航方式。为此,利用视觉进行无人机自主着陆是一个可选的方式。利用视觉进行固定翼无人机自主着陆,其过程根据无人机与跑道的距离可以分为两个阶段:第一阶段无人机离跑道较远,跑道在图像中面积很小,此时只需进行机场检测识别以确定无人机飞行方向;第二阶段无人机离跑道较近,跑道在图像中面积足够大,视觉算法可以有效提取跑道的几何结构,此时需要进行跑道检测以估计无人机相对于跑道的位姿参数。

目前机场检测研究主要针对遥感图像,而用于无人机着陆第一阶段的机场检测研究比较少。遥感图像中的机场检测与用于无人机着陆的机场检测有所不同,但其所使用的方法仍具有一定的借鉴作用。由于遥感图像具有较高的分辨率,现有遥感图像中机场检测主要利用机场跑道的边缘几何特征来进行检测。例如, Kou 等<sup>[2]</sup>提出一种基于直线段检测(line segment detector, LSD)算法的机场检测方法。他们用 LSD 算法提取图像中的直线段,并假设机场区域具有最长的平行线段。Tang 等<sup>[3]</sup>通过直线分类与纹理分类来进行机场检测。跑道边缘线分类器用于提取机场的感兴趣区域(regions of interest, ROIs),基于纹理特征的分类器用于识别机场区域。Zhu 等<sup>[4]</sup>结合自底向上与自顶向下的显著性方法来提取机场 ROIs。在自顶向下的显著性方法中,他们将跑道边缘近似平行作为先验知识。最后基于尺度不变特征转换(scale-invariant feature transform, SIFT)特征进行机场识别。Budak 等<sup>[5]</sup>利用改进的 LSD 算法提出一种高效的机场检测方法。他们假设机场区域包含长平行线来提取机场的 ROIs。

由上可知,遥感图像中大多利用跑道的几何特征特别是跑道的边缘线来进行机场的检测。由于用于着陆的图像是前向图像,图像中跑道的两条边缘线因仿射变换而不再平行。同时在着陆过程中,因计算能力限制,用于检测机场的图像分辨率远小于遥感图像。在第一阶段,跑道在图像中的面积很小,难以将两条边缘线有效地检测出来。因此遥感图像中的机场检测方法并不能很好地解决着陆过程中的机场检测问题。

目前用于无人机着陆过程的机场检测方法常与其他传感器相结合。如 Laiacker 等<sup>[6]</sup>提出一种基于跑道表面与其周围表面颜色不同的机场检测方法。他们先通过惯性测量单元(IMU)与 GPS 获得

无人机相对的位置与方向信息,然后确定机场在图像中的大致位置以及需要处理的区域范围。Liu 等<sup>[7]</sup>结合多种传感器,以实现在低能见度情况下的机场检测。他们同样使用了 GPS 与 AHRS (attitude heading reference system)来帮助准确提取机场跑道。Gui 等<sup>[8]</sup>在跑道两边放置红外灯以辅助进行机场的检测。这些方法利用其他辅助信息能快速有效地检测机场。但视觉导航系统有时在其他传感器无法提供有效的相关信息时则需仅靠视觉技术来进行机场检测。目前有许多跑道检测方法,如文献<sup>[9-11]</sup>通过跑道边缘线识别来检测跑道,Wu 等<sup>[12]</sup>使用改进的 LSD 算法来提取跑道的感兴趣区域,然后使用区域特征及上下文信息来识别跑道。Khaled 等<sup>[13]</sup>设计了一种跑道模型,他们把跑道设计为近似的两条平行直线来进行跑道检测。这些用于无人机着陆的方法主要应用于着陆第二阶段,无人机离机场较近,视觉算法能清晰检测出跑道的两条边缘线。但在无人机自主着陆第一阶段时,跑道往往被检测为一条直线,此时这些方法将难以用于机场检测。

本实验室选用的摄像机分辨率为  $1280 \text{ pixel} \times 720 \text{ pixel}$ ,水平视场角为  $56.3^\circ$ ,垂直视场角为  $67.1^\circ$ 。假设跑道宽为  $60 \text{ m}$ ,长为  $3 \text{ km}$ 。当高度为  $500 \text{ m}$ ,无人机距离跑道为  $5 \text{ km}$  时,根据小孔成像模型跑道在图像中的大小为  $73 \text{ pixel} \times 8 \text{ pixel}$ ,视觉算法能有效提取跑道的几何特征。故取无人机与跑道距离大于  $5 \text{ km}$  时为着陆第一阶段,小于  $5 \text{ km}$  为第二阶段。本文针对着陆过程第一阶段无人机离机场大于  $5 \text{ km}$  的情况,为解决机场面积小引起的检测困难问题,并为实现机场检测的实时性,提出了一种分层的机场检测方法。

## 2 机场检测算法

利用分层结构由粗到细逐渐缩小机场搜索区域以快速获得机场候选区域,然后利用基于局部约束线性编码(LLC)<sup>[14]</sup>特征学习方法提取特征,最后用线性 SVM 完成机场识别。算法流程如图 1 所示。从图 1 中可以看到,候选区域提取分为两层:粗层、细层。在粗层先提取伪地平线,将需要进行图像分析处理的区域缩小到地面区域,然后利用先验知识提取候选的机场近似区域(机场近似区域是指该区域不仅包含机场,还可能包含其他背景区域)以进一步缩小机场搜索区域。然后利用 Edge Boxes<sup>[15]</sup>提取高精度定位的机场候选区域。

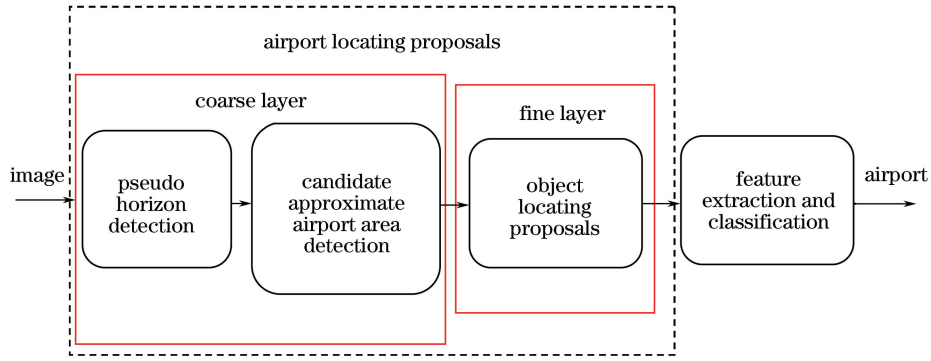


图 1 算法框架

Fig. 1 Block schematic of the proposed method

## 2.1 机场候选区域提取

### 2.1.1 粗层: 候选机场近似区域候选区提取

#### 2.1.1.1 伪地平线提取

在着陆过程中,前视图像中天空区域占据很大比例。而机场仅存在于地面区域,因此仅需要分析处理地面区域。图像中天空与地面区域在蓝色分量灰度值上会有较大区别,据此提取地平线能将天空与地面区域分离。在着陆过程中无人机的滚转角较小,提取精确的地平线耗时且不必要。为此假设伪地平线是图像中的一条水平线,用伪地平线检测替代地平线检测以提取地面区域。本文利用 Ostu 最大类间方差算法提取伪地平线。根据 Ostu 算法原理<sup>[16]</sup>,

$$\sigma^2(k) = n'_k n_k (\mu_k - \mu'_k)^2, \quad (1)$$

式中: $k$  指图中第  $k$  行; $n_k$  为图像前  $k$  行的像素数量; $n'_k$  为图像中大于  $k$  行的像素数量; $\mu_k$  为图像前  $k$  行像素灰度值平均值; $\mu'_k$  为图像大于  $k$  行的像素灰度值平均值。 $\sigma^2(k)$  取得最大值时, $k$  即为伪地平线的位置。

#### 2.1.1.2 候选机场近似区域提取

由于在初始着陆阶段,着陆序列图像中跑道的面积较小,无法同时检测出跑道的两条边缘线。因此在着陆第一阶段无法利用跑道两边缘线平行作为先验知识进行机场检测。但注意到在机场区域存在大量的直线,比如机场草坪边缘,跑道,滑跑道。而许多直线段相互垂直。在无人机着陆的第一阶段跑道虽可能只检测出一条直线,但机场区域仍能检测出一些相互垂直的直线段。因此可根据这一事实来提取机场的候选近似区域。定义候选机场近似区域为包含一组以上相互垂直直线组的区域。

着陆时一般使用前视图像进行导航,由于仿射影响,实际相互垂直的直线在图像中会有一些误差。

为此可设定一个阈值来减弱仿射的影响。同时图像中相互垂直的线段可能距离较远,不属于同一类别区域,需要对相互垂直的线段距离进行约束以使其处在同一区域内。定义满足以下条件的两条直线相互垂直:

$$\left| \theta_{ij} - \frac{\pi}{2} \right| < x_{Th}, \quad (2)$$

$$|l_{ij}| < l_i \text{ and } |l_{ij}| < l_j, \quad (3)$$

式中: $\theta_{ij}$  是两条线段  $s_i$ 、 $s_j$  的夹角; $l_{ij}$  是这两条线段的点之间最短距离; $l_i$ 、 $l_j$  分别为两条线段的长度; $x_{Th}$  为阈值。

为避免复杂的线段提取操作,本文用像素组进行替代。给定一幅图像,首先利用基于结构化森林快速边缘检测算法<sup>[17]</sup>进行边缘检测;然后利用简单的贪婪法将邻近的具有相同相位的边缘像素组合在一起,直到其相位差异和大于某一设定的阈值,比如  $\pi/2$ 。这样一条线段  $s_i$  就可以用一个像素组  $g_i$  来表示。

根据这一先验知识,能得到多个包含垂直线的候选区域。图像中的城镇、草坪这些人造建筑都包含大量相互垂直的线段。而与跑道相似度较高的高速公路则由于其只含有平行线而被排除。

#### 2.1.2 细层: 机场高精度定位候选区域提取

粗层得到的候选区域为机场近似区域,定位精度比较差。候选区域的定位精度与分类器的分类结果相关。将候选机场近似区域直接用于分类器分类将会降低识别率。对此,采用 Edge Boxes 进一步处理,以提取高精度定位的机场候选区域。

Edge Boxes 基于以下事实提出:采样框中完全包含的轮廓数量与其包含物体的可能性呈正相关。轮廓可由边缘线表示出来。相似性越高的边缘线属于同一物体轮廓的可能性越大。同时,采样框内部

分包含的边缘线属于采样框中包含的物体轮廓的可能性小。Edge Boxes 根据这一事实对边框包含完整物体的可能性进行评分。评分越高,则边框越可能包含所需要检测的目标。

具体实现上,首先根据文献[15]中的搜索策略进行采样得到采样边框,采样区域限制为候选机场近似区域。由于将采样区域限定到较小的区域,可以使用更小的采样步长进行密集采样以得到较高定位精度的采样边框。然后根据

$$a(g_i, g_j) = |\cos(\theta_i - \theta_{ij}) \cos(\theta_j - \theta_{ij})|^2, \quad (4)$$

计算采样区域内各边缘像素组间的相似性,以将相邻具有较高相似度的边缘像素组组合在一起形成更大的连续轮廓。式中: $a(g_i, g_j)$ 是边缘像素组  $g_i$ 、 $g_j$  的相似性; $\theta_i$ 、 $\theta_j$  分别是它们的相位角; $\theta_{ij}$ 是它们间的夹角。根据

$$w_b(g_i) = 1 - \max \prod_j^{|T|-1} a(t_j, t_{j+1}), \quad (5)$$

判断  $g_i$  是否包含在采样边框  $b$  中,当  $g_i$  完全包含在边框  $b$  中时  $w_b(g_i) = 1$ ,当部分包含于  $b$  中时则  $0 < w_b(g_i) < 1$ ,当完全在边框  $b$  外部时  $w_b(g_i) = 0$ 。最后根据上文所述事实,利用

$$h_b = \frac{\sum_i w_b(g_i) g_{m_i}}{2(b_w + b_h)^{1.5}}, \quad (6)$$

得到边框  $b$  的包含物体可能性的评分  $h_b$ 。

(5)~(6)式中: $b_w$ 、 $b_h$  是边框的宽和高; $g_{m_i}$  是像素组  $g_i$  中所有像素的边缘幅值和; $w_b(g_i)$  表示  $g_i$  是否完全包含于边框  $b$  中; $T$  是边框中像素组的一个有序路径,它从某个包含于边框中的像素组  $t_1$  开始,到  $t_T = g_i$  结束。

## 2.2 机场分类过程

特征提取与分类器设计是分类的两个核心部分。好的特征对分类很重要,如果特征区分度高则使用简单设计的分类器就可以完成分类任务,反之则需要比较复杂的分类器。在着陆的第一阶段,机场的面积较小且背景复杂,背景中存在许多干扰物体如高速公路。特征如 HOG(histogram of gradient)、LBP(local binary pattern)、SIFT 区分度不足以将机场从复杂背景中识别出来。本文以 SIFT 作为基本特征,利用局部限定编码特征学习法来学习更深层次的特征以增加特征的区分度。最后使用线性 SVM 完成分类。分类过程框图如图 2 所示。




图 2 分类流程图

Fig. 2 Schematic of the classification

### 2.2.1 SIFT 特征提取

由 Lowe<sup>[18]</sup>在 2004 年提出的 SIFT 特征在图像中的分布一般不均匀。为保证特征点分布均匀本文采用 dense SIFT。给定一图像块,设其像素大小为  $H \times W$ ,以一定大小滑窗及步长均匀采样提取 SIFT 特征,每个滑窗内提取一个 SIFT 特征点,得到一个特征集  $X = \{x_1, x_2, \dots, x_M\}$ ,  $x_i \in R^{128}$ 。在本文中滑窗尺寸为 16 pixel  $\times$  16 pixel,步长为 8 pixel。假设输入图像块为 59 pixel  $\times$  130 pixel,则得到  $M = 8 \times 20$  个 SIFT 特征。

### 2.2.2 LLC

LLC 通过解决下述问题获得更具描述力的特征:

$$\min_C \sum_{i=1}^N (\|x_i - Bc_i\|^2 + \lambda \|d_i \odot c_i\|^2) \quad (7)$$

s.t.  $1^T c_i = 1, \forall i,$

式中: $B \in R^{n \times m}$  是训练得到的字典, $n$  是基础特征的

描述子维度, $m$  是字典中原子个数,这里  $B \in R^{128 \times 1024}$ ;  $C = \{c_1, c_2, \dots, c_k\}$  ( $k$  为输入 SIFT 特征总数量)是投影系数集合, $c_i \in R^{1024}$ ;  $d_i$  是  $x_i$  到原子的距离,是限制距离大的原子的影响因素。

LLC 实现由两部分组成:字典训练与编码。训练过程主要是求取字典,此时  $B$ 、 $C$  都为变量。为此分两步来实现训练,第一步先固定  $B$ ,优化  $C$ ;第二步固定  $C$ ,优化  $B$ 。迭代这两步,得到最终结果。在编码过程中  $B$  已知求  $C$ 。

### 2.2.3 池化

从图 2 中可知,编码后得到的仍是输入图像块的局部特征集合,不能直接输入到分类器中,为此需要进行池化处理。为保留各局部特征的空间关系,采用金字塔结构,并利用最大值法进行池化。金字塔结构分为三层:第一层是整个图像块,第二层将图像块分为 4 个大小相同的区域,第三层将图像块分为 16 个大小相同的区域。最后将得到 21 个多种尺寸的图像

区域。将这 21 个区域中 SIFT 编码得到的描述子以最大值池化法得到 21 个 1024 维(本文中采用的字典包含 1024 个原子,  $B \in R^{128 \times 1024}$ ) 向量, 将这 21 个向量首尾相连得到 21504 维的最终特征描述子。

#### 2.2.4 线性 SVM 分类器

完成特征提取后, 将特征向量输入到分类器中进行分类。由于所采用的特征具有较高的描述力, 线性 SVM 分类器足以完成机场识别任务, 其功能函数如下:

$$f(z) = w^T z + b, \quad (8)$$

线性 SVM 训练时间为  $O(n)$ , 测试时间为  $O(1)$ , 且测试时间与样本的数量无关。对输入的样本, 若  $f(z) > 0$ , 则该候选区域被判定为机场, 否则为背景。

### 3 实验分析与讨论

本文所使用的测试集由飞行仿真软件




图 3 实验场景图。(a) KLVK\_sunny; (b) KLVK\_cloudy; (c) KLVK\_mist; (d) KSQL\_sunny

Fig. 3 The image sets used for experiments. (a) KLVK\_sunny; (b) KLVK\_cloudy; (c) KLVK\_mist; (d) KSQL\_sunny

从 4 个数据集中选取共 400 个正样本与 450 个负样本进行 SVM 分类器训练, 并从每个数据集中分别选取 300 帧图像作为测试样本。所有实验在内存为 3 GB, CPU 为 intel Core E7500 台式计算机上进行, 算法由 MATLAB 实现。

#### 3.1 粗层评估

##### 3.1.1 伪地平线检测

伪地平线检测结果如图 4 所示, 可以看到本文的算法能有效将天地分离。同时从图像中可以看到




图 4 伪地平线检测

Fig. 4 Results of pseudo horizon detection

##### 3.1.2 机场近似区域候选区提取

在机场近似区域候选区提取过程中, 垂直直线组判定中的阈值  $x_{Th}$  会对判定产生较大影响。当  $x_{Th}$  设置值较小时, 机场容易丢失; 而当  $x_{Th}$  设置较大时则得到的机场近似区域候选区增多, 后续所要

Flightgear 仿真无人机着陆得到, 共获取 4 组不同条件下的着陆视频, 分别为 KLVK\_sunny、KLVK\_cloudy、KLVK\_mist、KSQL\_sunny, 每段视频持续大约 90s。从各个视频中分别截取无人机离机场距离从 10 km 到 5 km 的序列图像, 每帧图像为 1280 pixel  $\times$  720 pixel, 如图 3 所示。数据集详细情况如下。

1) KLVK\_sunny: 模拟天气晴朗, 中午 12:00。机场附近背景简单, 没有干扰物。

2) KLVK\_cloudy: 模拟多云天气, 下午 5:00。机场附近背景简单, 没有干扰物。

3) KLVK\_mist: 模拟薄雾天气, 中午 12:00。机场附近背景简单, 没有干扰物。

4) KSQL\_sunny: 模拟晴朗天气, 中午 12:00。机场附近背景复杂, 有城镇, 高速公路等干扰物。

天空区域占据图像较大部分。图 5 为伪地平线检测对整个机场候选区域提取算法的影响, 横坐标 IOU 表示交并比 (Intersection-over-union)。图 5 表明, 在没有伪地平线检测进候选区域提取需要 0.88 s, 而有伪地平线检测时所用时间为 0.48 s。伪地平线剔除了天空区, 减小了机场搜索面积, 极大地降低了时间消耗。但从图 5 中也可以看到, 伪地平线对召回率几乎没有影响, 主要原因是天空区域不存在影响机场候选提取的与机场表现相似的干扰物。

处理的图像面积增加, 从而影响算法的速度。因此  $x_{Th}$  不能设置过大也不能设置过小。这里  $x_{Th}$  设置为 1。图 6 为检测结果。

##### 3.1.3 粗层对机场候选区域提取的影响

将无粗层时机场候选区域提取结果与完整结构

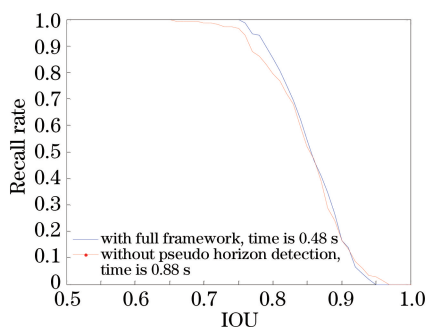


图 5 有/无伪地平线检测机场候选区域提取结果  
Fig. 5 Proposal locating with full framework and without pseudo horizon detection




图 6 机场近似区域候选区检测结果

Fig. 6 Results of candidate approximate airport area detection

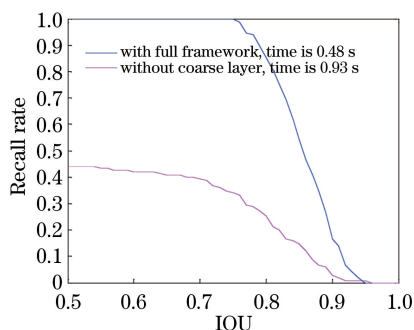


图 7 粗层对机场候选区域提取的影响  
Fig. 7 Influence of the coarse layer on the airport candidate region detection

### 3.2 机场候选区域提取评估

图 8 是本文提出的机场候选区域提取方法在不同天气、不同背景条件下的结果。每帧图像提取 50 个高定位精度预选区域作为机场候选区域。从图 8 中可以看到,算法在 KLVK\_cloudy、KLVK\_mist、KSQL\_sunny 上的曲线相似。IOU 在区间 $[0.65, 0.85]$ 时,算法在 KLVK\_sunny 上的召回率要高于其他曲线。而 IOU 在 $[0.75, 0.9]$ 时,所有曲线的下降速率相似。由此可知,多云、薄雾、复杂背景会对

机场候选区域算法提取结果进行比较,如图 7 所示。从图 7 中可以看到,完整结构机场候选区域算法每帧平均耗时 0.48 s,而无粗层时耗时增加到每帧 0.93 s。粗层逐渐缩小机场搜索面积,极大提高了算法的速度。同时,完整结构的机场候选区域提取方法其召回率在同一 IOU 下皆大于无粗层时的。其原因在于:一是粗层能有效排除一些与机场非常相似的目标如高速公路,高速公路区域由于一般只含有平行线,在机场近似区域候选区提取过程中将被排除;二是粗层缩小了搜索范围,取相同数量的预选区域时,检索对象会更密集,覆盖机场目标的可能性更大。

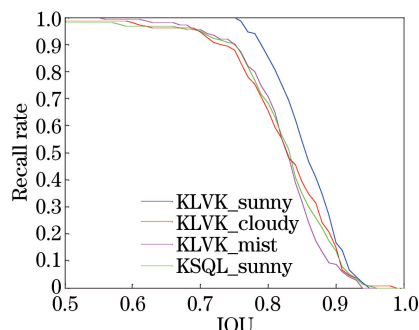


图 8 不同天气、背景下机场候选区域提取算法的检测结果  
Fig. 8 Results of the proposed airport detection method under different weather and background conditions

候选区域提取算法产生有限的影响。由于候选区域提取算法主要基于图像的边缘信息,多云天气会使光照发生变化,薄雾则使图像模糊化,多云薄雾天气都会使获得的图像中的一些弱边缘无法被检测出来从而影响算法结果,但影响较小。Edge Boxes 通过密集采样提供高精度定位的候选区域,但它给采样框评分依据的不是机场的先验知识,而是采样框包含物体的可能性。当背景复杂时,在粗层会有更多区域被检测为机场近似区域候选区,这增加了 Edge

Boxes 给包含其他物体边框评分高分值的可能性,从而影响了算法结果。

### 3.3 机场检测评估

对上述 4 个数据集测试提出的机场检测算法的准确性。图 9、图 10 是检测结果。从图 9 中可以看到 IOU 阈值为 0.5 时,算法在数据集 KLVK\_mist 上识别率(RT)为 99.3%,在其他 3 个数据集上表现相似且召回率皆大于 0.94。光照对算法影响较小,而薄雾天气对算法结果有一定不利影响,这是因为薄雾天气降低了图像质量,使图像模糊,这也说明光学传感器的使用受限于尘雾天气。算法在 4 个数据集上的召回率都随 IOU 阈值的增大而缓慢下降。但 IOU 阈值区间在 [0.5, 0.7] 时,算法在 KSQL\_sunny 数据集上召回率下降速率远大于在其他数据集上的。可知复杂背景会降低检测结果的位置精度,其原因在于复杂背景下,机场跑道附近存在干扰物,算法检测到的机场近似区域候选区数量及面积

增加(如图 6 所示),同时在候选机场近似区域提取完整包含多个物体的采样框获得的评分更高,当按评分大小顺序取一定数目采样框作为机场候选区域时其定位精度就可能降低,从而影响最终检测结果的定位精度。




图 9 本文所提算法的机场检测结果  
Fig. 9 Results of our proposed airport detection method




图 10 机场检测部分结果

Fig. 10 A part of results of the airport detection

将本文提出的机场检测算法与其他两种机场检测算法(文献[3]和文献[19])进行比较,。文献[3]使用跑道边缘线分类器对图像中提取的线段进行分类以获得机场候选区域,然后采用纹理特征进行分类。文献[19]利用基于图的显著性方法获得机场候选区域,然后采用 SIFT 特征对候选区域进行分类以完成机场检测。本文中测试其他方法参数按照参考文献给定的进行设置,比较结果如表 1 所示。从表 1 可以看到,本文提出的机场检测算法在准确率与效率上均高于其他方法。文献[3]及文献[19]采用的特征均是纹理或 SIFT 等基础特征描述目标,而本文以 SIFT 特征为基础使用 LLC 特征学习法得到描述能力更强的特征,因此本文方法平均准确

率(AP)更高。本文机场检测算法平均每帧图像耗时 4.9 s,平均准确率为 95%。从结果可知本文提出的分层候选区域提取方法能有效地提高机场检测速度,基于 LLC 特征学习提取特征能有效地将机场从背景中检测出来。

表 1 本文所提算法与其他方法的比较结果  
Table 1 Results comparison among our method and other methods

Methods	Average precision	Average time for each image /s
Ours	0.95	4.9
Method in Ref.[3]	0.85	48
Method in Ref.[19]	0.75	137

## 4 结 论

提出了一种用于固定翼无人机自主着陆的机场检测方法,主要是解决以下两个问题:提高机场检测的速度与尝试解决在着陆过程第一阶段机场跑道面积小而带来的机场检测的困难。为提高机场检测速度,提出了一种分层结构,通过不断缩小机场搜索区域以快速提取机场候选区域;为解决着陆第一阶段(无人机距离机场大于 5 km)机场跑道面积小带来的机场检测困难,根据机场作为人工建筑包含许多相互垂直的线段组的事实提出一种判定标准来确定候选机场近似区域,并在此基础上利用 Edge Boxes 得到高定位精度的机场候选区域。利用 LLC 特征学习法提取特征并用线性 SVM 完成机场识别。在不同天气、背景下测试了所提出的机场检测方法,并与其他方法进行比较。本文所提出的机场检测方法每帧图像平均耗时 4.9 s,平均准确率为 95%,优于相比较的方法。结果表明,提出的分层结构能有效提高检测速度,并为解决着陆第一阶段机场检测问题打下基础。

在之后的工作中,将继续研究复杂背景下的机场检测,并考虑将序列图像中的时序信息引入到检测中以进一步加快机场检测速度。

## 参 考 文 献

- [1] Zhang L, Yang Y Y, Zhang T L, *et al.* Research of UAV landing guidance technology based on solar-blind ultraviolet imaging [J]. Chinese Journal of Lasers, 2016, 43(7): 0704001.  
张磊, 杨雨英, 张铁林, 等. 基于日盲区紫外成像的无人机着陆引导技术研究[J]. 中国激光, 2016, 43(7): 0704001.
- [2] Kou Z Y, Shi Z W, Liu L. Airport detection based on line segment detector [C] // 2012 International Conference on Computer Vision in Remote Sensing (CVRS), Xiamen, China, New York: IEEE, 2012: 72-77.
- [3] Tang G F, Xiao Z F, Liu Q, *et al.* A novel airport detection method via line segment classification and texture classification [J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(12): 2408-2412.
- [4] Zhu D, Wang B, Zhang L M. Airport target detection in remote sensing images: a new method based on two-way saliency[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(5): 1096-1100.
- [5] Budak Ü, Halıcı U, Şengür A, *et al.* Efficient airport detection using line segment detector and fisher vector representation[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(8): 1079-1083.
- [6] Laiacker M, Kondak K, Schwarzbach M, *et al.* Vision aided automatic landing system for fixed wing UAV [C] // RSJ International Conference on Intelligent Robots and Systems (IROS), Tokyo, Japan, New York: IEEE, 2013: 2971-2976.
- [7] Liu C J, Zhao Q J, Zhang Y, *et al.* Runway extraction in low visibility conditions based on sensor fusion method[J]. IEEE Sensors Journal, 2014, 14(6): 1980-1987.
- [8] Gui Y, Guo P Y, Zhang H L, *et al.* Airborne vision-based navigation method for UAV accuracy landing using infrared lamps [J]. Journal of Intelligent & Robotic Systems, 2013, 72(2): 197-218.
- [9] Tandra S, Rahman Z. Robust edge-detection algorithm for runway edge detection[J]. Proceedings of SPIE, 2008, 6813: 68130L.
- [10] Trisiripisal P, Parks M, Abbott Y, *et al.* Stereo analysis for vision-based guidance and control of aircraft landing [C] // Proceedings of 44th AIAA Aerospace Science Meeting and Exhibit, Reno, Nevada, AIAA, 2006. AIAA 2006-1438.
- [11] Shang J J, Shi Z K. Vision-based runway recognition for UAV autonomous landing [J]. International Journal of Computer Science and Network Security, 2007, 7(3): 112-117.
- [12] Wu W, Xia R B, Xiang W, *et al.* Recognition of airport runways in FLIR images based on knowledge [J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(9): 1534-1538.
- [13] Abu-Jbara K, Alheadary W, Sundaramorthi G, *et al.* A robust vision-based runway detection and tracking algorithm for automatic UAV landing [C] // 2013 International Conference on Unmanned Aircraft Systems (ICUAS), Denver, CO, USA, New York: IEEE, 2015: 1148-1157.
- [14] Wang J, Yang J, Yu K, *et al.* Locality-constrained linear coding for image classification [C] // 2010 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), New York: IEEE, 2010: 3360-3367.
- [15] Zitnick C L, Dollár P. Edge Boxes: locating object proposals from edges [C] // Fleet D, Pajdla T, Schiele B, *et al.* Computer Vision-ECCV 2014. Lecture Notes in Computer Science Cham: Springer, 2014, 8693: 391-405.
- [16] Duan Z G, Li Y, Wang E D, *et al.* Road and navigation line detection algorithm from shadow image based on the illumination invariant image [J]. Acta Optica Sinica, 2016, 36(12): 1215004.



- 段志刚, 李勇, 王恩德, 等. 基于光照不变图像的阴影图像道路及导航线提取算法[J]. 光学学报, 2016, 36(12): 1215004.
- [17] Dollar P, Zitnick C L. Fast edge detection using structured forests[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(8): 1558-1570.
- [18] Wang X, Lü Q, Wang B, *et al.* Airport detection in remote sensing images: a method based on saliency map[J]. Cognitive Neurodynamics, 2012, 7(2): 143-154.
- [19] Lowe D G. Distinctive image features from scale-invariant keypoints [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.