

基于直线邻近平行性和 GBVS 显著性的遥感 图像机场目标检测

朱丹^{1,2}, 王斌^{1,2*}, 张立明^{1,2}

(1. 复旦大学信息科学与工程学院智慧网络与系统研究中心, 上海 200433;
2. 复旦大学电磁波信息科学教育部重点实验室, 上海 200433)

摘要:现有的全色遥感图像机场目标检测方法,对机场目标的直线特征利用得非常有限。提出一种同时利用自顶向下和自底向上显著性机制的新方法。利用线段检测算法检测直线,通过跑道线段间邻近、平行且长度范围一定的特点,提出了邻近平行性的概念,可以深度挖掘机场跑道几何关系的先验知识。同时使用简化的基于图的视觉显著性模型,提取自底向上的显著性。两者协同得到机场的候选位置。最后,通过尺度不变特征变换提取特征,利用支撑向量机进行判决,可以精确定位机场目标。在具有各种类型的机场图像数据库上的实验结果表明,相对于其他方法,所提算法具有速度快、识别率高、虚警率低的优势,同时对于复杂背景具有更强的鲁棒性。

关 键 词:机场目标检测;线段检测算法;邻近平行性;基于图的视觉显著性;尺度不变特征变换;支撑向量机
中图分类号:TN911.73 文献标识码:A

Airport detection based on near parallelity of line segments and GBVS saliency

ZHU Dan^{1,2}, WANG Bin^{1,2*}, ZHANG Li-Ming^{1,2}

(1. Research Center of Smart Networks and Systems, School of Information Science and Technology,
Fudan University, Shanghai 200433;
2. Key Laboratory for Information Science of Electromagnetic Waves (MoE), Fudan University, Shanghai 200433)

Abstract: State-of-the-art methods for airport detection in panchromatic remote sensing images utilize very limit geometrical features of airport line segments. This paper proposed a new method which uses both bottom-up and top-down saliency. Because the airport runways have features of vicinity and parallelity, and their lengths are among certain range, the concept of near parallelity is introduced after using an improved line segments detector (LSD). It is used as a priori knowledge which can fully exploit geometrical relationship of airport runways to get top-down saliency. Meanwhile, a simplified graph-based visual saliency (GBVS) model is used to extract bottom-up saliency. Candidate regions can be gotten by combining those two clues. After that, scale-invariant features transform (SIFT) and support vector machine (SVM) are used to finally determine whether the regions contain an airport or not. The proposed method is tested on an image dataset composed of different kinds of airports. The experimental results show that the method has advantages in terms of speed, recognition rate and false alarm rate. Also, the method is more robust to complex background.

Key words: airport target detection, line segment detector, near parallelity, graph-based visual saliency, scale-invariant feature transform, support vector machine

PACS: 84.40. Xb

收稿日期:2014-03-10,修回日期:2014-08-18

Received date: 2014-03-10, revised date: 2014-08-18

基金项目:国家自然科学基金(61071134, 41371337);上海市教育委员会科研创新项目(13ZZ005);高等学校博士学科点专项科研基金(20110071110018)

Foundation items: Supported by the National Natural Science Foundation of China (61071134 and 41371337); the Innovation Program of the Shanghai Municipal Education Commission (13ZZ005); the Research Fund for Doctoral Program of Higher Education of China (20110071110018)

作者简介(Biography):朱丹(1989-),男,江苏南通人,硕士研究生,主要研究领域为选择性视觉注意模型。E-mail: 12210720045@fudan.edu.cn

*通讯作者(Corresponding author):E-mail: wangbin@fudan.edu.cn

引言

在卫星、航天技术日益发达的今天,对遥感图像进行自动机场目标检测无论在军事还是民用领域已经成为了十分迫切的需求,吸引了越来越多的关注。然而机场往往处于城市或城市的边缘,场景中背景非常复杂,道路、河流、山脉、建筑等目标会对检测造成严重干扰。加上机场大小、形状也各有差异,准确地自动检测机场目标仍然是一项较为困难的任务。此外,遥感图像庞大的数据量对检测算法的计算速度也提出了较高的要求。

目前为止,各研究学者对机场检测已提出了一些算法。这些算法一般可分为两类^[1],一类是基于边缘直线特征提取的,另一类是基于场景分割的。由于机场主要组成部分是跑道,所以第一类方法着重针对于机场的直线特征,从图像中利用 Hough 变换^[2-3]等算法提取机场的跑道,加上部分纹理的识别,以此来定位机场目标。另一方面,机场的纹理通常与周边背景纹理差异性较大,第二类方法通过分割进行纹理分析,达到定位机场的目的^[4-5]。

两种方法各有优缺点。基于直线特征提取的算法原理简单,速度快,但一般对直线特征的筛选不够严谨,导致其他具有直线特征的目标(如道路、河流、山脉等)会对检测结果造成较为严重的影响。例如文献[2],利用 Hough 变换提取直线特征,替换 GBVS 显著性模型的方向通道提取显著图。然后从显著图的候选区域中提取特征,使用多层分类回归(Hierarchical Discriminant Regression, HDR)树对特征进行判决。但该算法除了对于直线长度限制外,就没有其他特征的筛选了,这对系统高层次的识别造成了负担,较大地影响了其准确性。而第二类方法能更好地刻画机场纹理特征,提取出感兴趣的区域,一般而言,这类方法普适性也较高。但分割的方法一般涉及到依赖于参数的分割算法或重叠的滑动窗口,计算效率成为难以突破的瓶颈。同时,由于分割往往得到其局部特性,机场的整体性可能被破坏,导致描述特征的可信度降低。

事实上,观察者一眼看到含有机场的遥感图像时会立即被机场吸引。这里,视觉显著性机制发挥了不可替代的作用。人眼在搜索机场目标这个任务时,能第一时间内注意到场景中聚集在一起的、平行的且具有一定长度的直线。这三个重要特征是人脑对机场的固有印象,从认知角度看是自顶向下(Top-Down, TD)的显著性机制,它是知识驱动的。同时相

比于周边环境具有较高亮度对比或纹理差异较大的区域也能轻松地被注意到。这种机制和观察者的经验无关,是特征驱动的自底向上(Button-Up, BU)的显著性机制。这两种显著性是相互依存缺一不可的。

当前,对 BU 显著性的研究已经有非常多的成果。早期 Itti 等人根据特征综合理论,提出了一种模仿人眼视网膜认知的显著性可计算模型^[6]。之后 Harel 等人更改了 Itti 模型中“中心周边差分”的步骤,从图论的角度提出了基于图的显著性(Graph-Based Visual Saliency, GBVS)模型^[7],为显著性的计算拓宽了思路。接着,基于频率域的可计算显著性模型被提出^[8-10]。其中最近被提出的基于频率调制的显著性(Frequency-Tuned Saliency, FTS)模型^[9]在自然图像的显著性检测中有非常不错的效果。这些方法计算速度快,能很好地估计目标显著性。但频率域方法往往容易突出边缘,不能胜任复杂场景的显著性提取。最新的显著性提取方法更偏向于工程计算的模型,如利用图像共现直方图(Co-Occurrence Histograms, COH)统计特性的显著性模型^[11],能很好地强调纹理的相异性,因此对人眼注视点的预测也有非常好的效果。相对于 BU 显著性模型,通用的 TD 显著性研究成果就比较少。传统的单纯基于直线的机场检测方法,往往会忽视邻近和平行这两个 TD 的先验知识。

机场目标检测的方法从显著性的角度也可以被抽象地归为 TD 和 BU 这两类。TD 的方法尝试利用机场的形状(如跑道直线特征)、纹理等先验知识确定其位置,然而先验知识的数学表述并不简单。BU 的方法以机场底层特征的显著性作为假设,但场景中 BU 显著性最高的很有可能不是机场目标。为此只有同时引入两者才能达到最好的效果。本文从这一角度出发,提出一种利用机场跑道线段间独特的几何关系作为 TD 显著性,并同时利用 BU 显著性机制来提取候选区域的方法。

本算法首先利用最新提出的线段检测算法^[12](Line Segments Detector, LSD)提取直线段。该算法速度快、虚警率低,唯一的缺点是线段会在相交点处断开。为了区分较短的干扰线段和较长的机场跑道线段,本文对断开的线段进行了连接。随后,注意到机场目标三个非常关键的先验知识:第一,线段往往是平行的;第二,线段大量聚集在一起;第三,在相同分辨率下,机场跑道的长度总有一个范围。本文提出线段邻近平行性这一概念,并将其作为提取出的线段的加权,获得知识驱动的 TD 显著性。相比于传

统基于直线特征的检测算法,这种先验知识的引入能更准确地突显机场跑道。另一方面,为了加快计算速度、抑制背景的干扰,本文通过实验从众多方法中选用“简化的 GBVS 模型”来提取 BU 的显著性。通过综合 TD 和 BU 两种机制,最终得到机场目标检测任务中的显著性。

实验表明,相比于其他单独利用一种显著性机制的算法,本文算法获取的显著图能更精准地突出机场目标的位置。最后,利用显著图生长出候选区域,使用尺度不变特征变换^[13](Scale-Invariant Feature Transform, SIFT)从候选区域中提取特征。并用支撑向量机^[14](Support Vector Machine, SVM)对候选区域 SIFT 特征进行分类,以判决该候选区域是否包含机场。

1 模型构建

1.1 TD 的显著性计算——机场目标的邻近平行性

通过对大量机场目标的观察和归纳,观察者在识别机场的时候会下意识地使用到机场的三个几何先验知识。第一,机场的跑道大多都聚集在一起,其线段间具有邻近性。第二,代表机场跑道的线段间具有相当强的平行性。第三,在相同分辨率下,机场跑道长度总是有一定范围的,太长或太短的线段都不可能是机场的跑道。基于这三点先验知识,本文提出了线段的“邻近平行性”概念,作为线段是否属于机场跑道的一个准则对每条线段加权,最后得到 TD 的显著图(TD_Sal)。下面段落将对邻近平行性的构建进行展开。

1.1.1 直线的检测与连接

机场的跑道包含了直线,很多遥感图像的机场检测采用 Hough 变换提取场景中的直线^[2]。该变换的缺点就是过分依赖于参数和耗时较多,如果参数选取不当,会导致检测出的直线可靠性下降。本文采

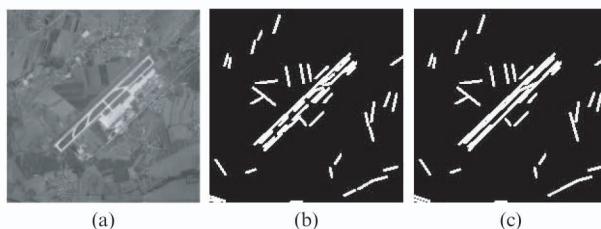


图 1 LSD 机场场景线段检测结果,(a) 原机场场景(中间平行线为跑道)(b) LSD 检测出来的跑道被断开(c) 通过连接后的跑道

Fig. 1 Line segments detected in the scene and its connection result. (a) Original RSI. (b) LSD results. (c) After connection

用最近被提出的 LSD 算法^[12]获取场景中的线段。这种方法无参数依赖,计算复杂度低,虚警率低,且具有能对复杂纹理区域进行抑制等优点。算法首先计算图像梯度,利用梯度垂直方向进行区域生长。如果某个相邻像素点的梯度方向角和区域的平均梯度方向角的误差在允许范围之内(22.5°),则将该像素点包含进该生长区域中。之后用一个矩形去拟合这个区域。最后通过计算虚警率剔除不符合要求的矩形,从而得到有效的线段位置、长度及宽度。针对机场的情况,本文将原 LSD 算法中的用于区域生长的误差允许值从 22.5° 减小为 15° 。此外,由于该算法是基于梯度方向,在两直线相交点处梯度为零,造成线段的不连续。若直接用于机场检测,由于在平行跑道间存在的垂直联络跑道,会使得检测到的直线断开(如图 1(b) 所示)。本文算法将较短的线段视为非机场的干扰线段进行抑制,因此断开的线段不利于机场的检测。为了不影响算法的有效性,必须将断开的线段连在一起。

连结断开线段的方法是测试两条线段的共线条件。假设两条相邻的线段为 AB 和 CD,如图 2 所示。在 $\{AC, AD, BC, BD\}$ 中,连接最长的一条线段,作为目标连接,不妨设为 AD,而 AD 与 AB、CD 之间的夹角分别记为 α, β 。通过观察和逻辑推断,发现当两条线段同时满足如下 3 个评判标准后,可以近似认为这两条线段原本是连接在一起的:

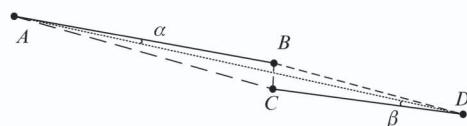


图 2 两条线段的连接

Fig. 2 Illustration of line segments connection

- (1) AB, CD 倾角差的绝对值小于阈值 θ_{thr1}
- (2) $\alpha < \theta_{thr2} \& \beta < \theta_{thr2}$
- (3) $| |AD| - |AB| - |CD| | < l_{thr3} \& |BC| < l_{thr3}$

此时 AB 和 CD 线段可以用 AD 线段进行替代。对于其中的三个阈值参数,实验中选用 $\theta_{thr1} = \theta_{thr2} = 5^\circ, l_{thr3} = 10$ 来表征允许的误差。算法首先考虑两线段的平行性评判标准(1),若不满足则直接跳过后续条件的检验,这样可以有效降低计算复杂度。同时,以最长的线段优先计算的原则依次进行共线判定。当所有线段间的连接可能性都判定后,对新线段的集合再次进行连接,一共遍历三次。通过连接运算之后,可以看到机场的跑道变得更加完整(如图 1

(c)所示).如果连接后的线段若不足3条,则认定场景中不含机场.

1.1.2 线段邻近性检测

如何评判线段间的邻近关系,在一般情况下,使用线段中心距离来衡量(图3(a)中的 d).但是这对于邻近且平行的线段是不公平的.如图3(b)所示,更直观地觉得AB线段和CD线段靠得很近,用中心距离反而很远(图3(b)中的 d'),因而用两条线段上的点的最近距离作为定义更为合适(图3(b)中的 d).但是,当存在多条相邻且断开的折线(如弯曲的海岸线),如图3(c)中的AB线段和CD线段,这种线段的端点邻近和机场跑道平行地邻近不是同一个概念.

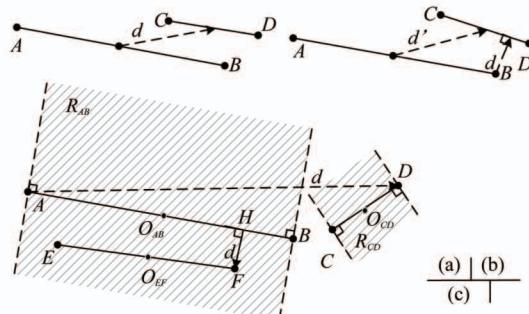


图3 线段间距离的各种定义,(a)使用中心点距离的定义,(b)使用线段间最短距离的定义,(c)线段邻近平行性距离定义

Fig. 3 Definition of the distance between two line segments, (a) by center distance, (b) by the shortest distance between two points lay in the line segments, (c) by the near parallelity distance

综合两种因素,定义线段AB和CD间距离为:

$$dis(AB, CD) = \begin{cases} \max \{ \| xy \| \mid x \in AB \& y \in CD \}, \\ \text{当 } |AB| > |CD|, O_{CD} \notin R_{AB} \\ \text{或 } |AB| < |CD|, O_{AB} \notin R_{CD} \\ \min \{ \| xy \| \mid x \in AB \& y \in CD \}, \text{其他} \end{cases}, \quad (1)$$

其中 $\|\cdot\|$ 表示两点的欧氏距离, $|\cdot|$ 表示线段长度, R_{AB} 和 R_{CD} 分别表示线段AB和CD的支撑区域(两条分别经过线段两个端点且垂直于线段的直线所夹的中间区域,如图3(c)阴影部分所示), O_{AB} 、 O_{CD} 分别表示线段AB、CD的中点.图中,AB、CD距离是用线段上点的最大距离进行定义的(AD),而AB、EF距离是用线段垂直距离(FH)定义的.

1.1.3 线段之间的平行性检测

通过线段倾角引入线段的平行特性.若记第m条线段为 L_m ,第n条线段为 L_n ,两条线段倾角差记为 $\Delta\theta_{m,n}$,则两条线段间的平行性定义为倾角差的函

数 $TiltW(\Delta\theta_{m,n})$ (如图4(a)所示), $TiltW(\Delta\theta_{m,n})$ 越大,越平行,在图4(a)中 $[0, \theta_{thr}] \cup [180^\circ - \theta_{thr}, 180^\circ]$ 范围内为升余弦的形式,在其他范围内为0. θ_{thr} 是两条线段认定为具有平行关系的最大允许倾角差.

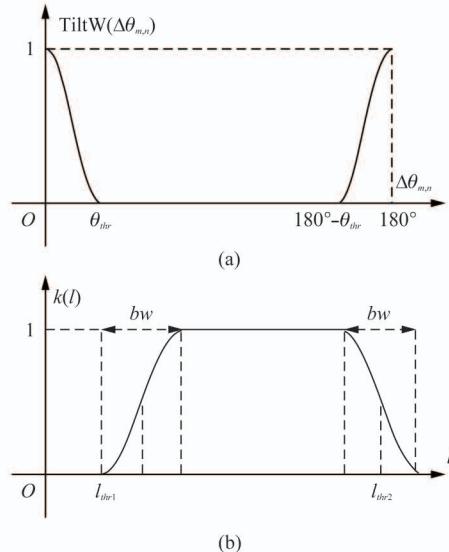


图4 邻近平行特性的交角加权函数和长度修正函数,(a)线段倾角差筛选权重函数
(b)线段长度修正函数

Fig. 4 Revise functions, (a) the function to define two line segments parallelity and (b) the length factor function of line segments

1.1.4 线段的长度因素

考虑到在固定分辨率下被检测的机场跑道线段长度必定在一定范围内,因此,线段 L_m 的长度也可以作为测定它是否属于机场的依据,用下面的公式表示长度

$$LenW(L_m) = k(|L_m|) \times |L_m|, \quad (2)$$

其中 $|\cdot|$ 表示线段长度, $k(l)$ 是线段长度 l 的修正项,其形式如图4(b)示.其中为 bw 为长度因素中截止区的宽度,仍为升余弦的形式, l_{thr1} 、 l_{thr2} 为截止区的中心值.长度过长或过短的线段都不可能是机场的跑道,即 $k(l)$ 在长度允许范围外为0.

综合上述三个特性(1.1.2~1.1.4),利用图4和公式(1)~(2),得到每条线段的“邻近平行性”权重值.对线段 L_m ,它的权值为:

$$W(L_m) = LenW(L_m) \times \sum_{\substack{L_n \in L_s \\ n \neq m}} \left(\exp\left(\frac{-dis(L_m, L_n)^2}{2\sigma^2} \right) \cdot TiltW(\Delta\theta_{m,n}) \right), \quad (3)$$

其中 L_s 为场景中所有线段的集合, L_n 为线段集合中的另一条线段, σ 为高斯核的半径参数.当场景中每

条线段计算完权重值后,归一化为线段的亮度值,亮度值越高,对应直线的邻近平行性越强,越可能是机场.加上 LSD 检测出的线段宽度和位置,将所有线段绘制在一张黑色背景图上,高斯平滑,即得到知识驱动的 TD 显著图.

实验中,在已知遥感图像地面分辨率的情况下,通过对机场跑道长度的大致估计,设定 $l_{thr1} = 45, l_{thr2} = 120, bw = 5$. 而对跑道间的距离进行估计可以设定 σ 的值,实验中取 $\sigma = 15$. 机场的跑道复杂程度决定了 θ_{thr} 的值,若机场跑道交叉较多,则应扩大该值,否则就减小该值,从而可以加强平行性的判决要求. 实验中取 $\theta_{thr} = 30^\circ$.

如图 5 所示,图 5(a) 为原机场场景,图 5(b) 为 LSD 检测和连接后的线段,可以看到,场景中的农田、河流产生了很多干扰的线段. 图 5(c) 为知识驱动的 TD 显著图. 在图 5(c) 中,大部分短的干扰线段被抑制,邻近平行性为 0,河流相比机场场景,其邻近平行性较弱,这是由于其线段断断续续,且平行性和邻近性都不足导致的. 在 5(c) 中机场目标被显著突出.

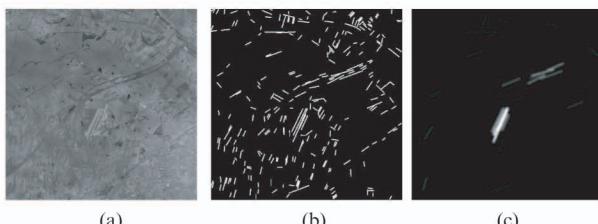


图 5 使用邻近平行性获取 TD 显著图的过程,(a) 原机场场景 (b) LSD 检测和连接后的线段 (c) 加权处理后的 TD 显著性图

Fig. 5 Results obtained by TD saliency detection. (a) Original RSI. (b) Connected LSD results. (c) TD saliency map

1.2 BU 显著性计算——简化的 GBVS 模型

人眼在场景目标识别中,能够从复杂的背景中快速提取出目标,供后续大脑高级皮层处理. 这其中自底向上的视觉注意机制起到至关重要的作用. Harel 等人在经典的 Itti 模型^[6]上,提出了 GBVS 模型^[7]. 该模型使用颜色、亮度、方向(使用 Gabor 滤波器得到方向)这三个通道分别做多次低通滤波和 1/2 降采样,得到各通道的多层高斯金字塔,其每一层对应通道的一个尺度. 然后对金字塔的每一层,以每个像素作为节点,根据像素间的灰度对比度差异及位置间的欧氏距离作为连接权重,建立一个无向图. 连接权重矩阵归一化后形成马尔科夫转移矩阵. 随机初始化一个维数与像素

节点数目相同的状态向量,使用转移矩阵对该状态向量进行多次迭代,最终收敛到一个平衡状态. 把平衡状态向量重新排成二维的形式,构成一个平衡图. 将其拉伸到原图像的大小、归一化并和其他通道处理后的平衡图叠加,最终得到和原场景大小一致的显著图.

原始的 GBVS 模型继承了经典 Itti 模型^[6]的多通道、多尺度分析的优势,采用图论模型,改进了 Itti 模型中的“中心周边差分”操作,使用稳态平衡作为通道显著性衡量,能够全局整体地、动态地考虑图像中每对点之间的显著性提升关系,从而对复杂背景有更好的适应性,在机场目标检测中,非常适合场景前期的筛选. 然而,随着图像矩阵的增大,其计算量也会急剧攀升. 因此,结合固定分辨率全色遥感图像的特点,在此对原始 GBVS 进行简化.

“原始的 GBVS 使用 Gabor 滤波器提取方向特征,因此其方向通道具有离散特性,即只能在 $\{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ 四个方向有响应. 并且模型未能将线段位置关系考虑在内,场景中只要在上述 4 个方向上有孤立的长线段则肯定会被突出,而这大多数情况下都是公路、河流等目标,反而对机场检测造成严重的干扰. 加上本算法已经利用 LSD 引入了线段的邻近平行特性,因此,模型中去除原 GBVS 的方向通道. 同时,考虑到全色遥感图像的灰度特性,同时去除原模型中的颜色通道. 另一方面,考虑到遥感图像具有相同的分辨率,机场目标的尺寸范围相对一致,因此采用单一的、优化的尺度能更好地抑制干扰. 原始 GBVS 的高斯金字塔策略尽管对自然图像非常适用,但在遥感图像中反而会突出不同尺度的显著目标,造成不必要的干扰.

简化后的模型在计算速度上会有质的提升,并且更加适用于机场显著性提取.

1.3 显著图的综合及最终识别

将得到的 TD 和 BU 显著图的灰度值逐点相乘、归一化后得到最终的显著图.

在显著图上选取显著值最大的点,使用四邻域的区域生长算法,得到一个机场的候选区域. 在该候选区域内提取 SIFT^[13] 特征点,每个特征点将对应于一个特征向量,计算区域内所有特征向量的平均值作为该区域的一个 SIFT 特征描述. 之后,使用事先训练好的支撑向量机^[14] 对该描述向量进行分类,判断该区域是否包含机场. 如果识别为背景,则将本区域显著性置为 0,在更新后的显著图上,再提取显著性值最大的点,重复上述操作.

如果在三次迭代之后,仍没有区域被识别为包含机场,则认定该场景块不含机场目标.

2 算法的总框架

在上面章节详细介绍过模型细节后,在此给出模型总框架,如图 6 所示.

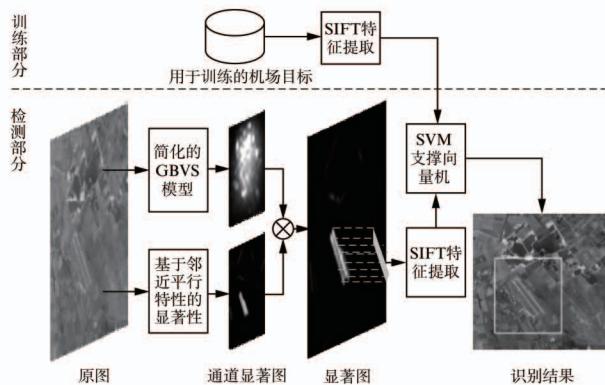


图 6 本文方法的总框架
Fig. 6 Flowchart of the proposed model

本文提出的算法,其输入为一张全色遥感图像,输出为一张使用矩形框标识机场位置的遥感图像(场景中含有机场目标)或原图像(表示场景中无机场目标).如图 6 总框图所示,算法可以分为两部分,第一部分是机场 SIFT 特征的训练部分,其流程如下:

(1) 在训练图像中,人工标记机场目标区域的位置.

(2) 使用 SIFT 算法提取遥感图像中的特征点和特征向量. 将处于人工标记的机场区域内的特征向量均值作为正样本,背景区域内特征向量的均值作为负样本.

(3) 使用正负样本训练 SVM.

由于训练所使用的都是同一个分辨率的遥感图像,因此,对同分辨率的不同遥感图像数据库,不需要重复训练新的 SVM 便可以进行机场检测任务.

算法的第二部分,也即机场检测算法的主体部分,具体步骤如下:

(1) 使用 LSD 提取遥感图像场景中的线段并用 1.1.1 节的方法进行共线连接,若线段少于 3 条,判定场景不包含机场,结束算法,输出原图.

(2) 利用图 4 和公式(1)~(3)计算每条线段的邻近平行性的权. 若场景中最高邻近平行性值低于阈值则认定该场景不包含机场,结束算法,输出原图. 否则以归一化后的邻近平行性权重值作为亮度

值,绘制自顶向下的、知识驱动的 TD 显著性图: Sal_TD.

(3) 使用简化的 GBVS 模型提取自底向上的 BU 显著性图: Sal_BU.

(4) 将两个线索的显著图逐点相乘得到最后的显著图: Sal, 并提取整个场景的 SIFT 特征点和特征向量. 设置判决计数为 0.

(5) 在显著图 Sal 的最大值点位置使用四邻域区域生长的方法提取候选区域,并统计位于该区域内的特征点数目及对应特征向量的均值.

(6) 若候选区域内无 SIFT 特征点,则判决该区域不包含机场,执行(7). 否则使用训练好的 SVM 判决当前候选区域的 SIFT 特征向量均值是否在描述机场目标,如果是,则结束算法,当前候选区域作为机场目标位置输出. 否则执行下一步.

(7) 将显著图 Sal 的当前候选区域显著性值置为 0. 判决计数自增 1. 执行下一步.

(8) 若当前 SVM 判决计数已达到三次,则结束本算法,输出当前场景不含机场,否则,执行(5).

3 实验

对本文提出的方法在实际遥感图像上进行测试. 实验采用的遥感图像来自于 Google Earth, 固定场景块的大小为 600×600 , 缩放视图的远近固定其地面分辨率为 $20 \text{ m} \times 20 \text{ m}$, 共 510 张清晰的全色遥感图像. 其中 400 张为包含机场目标的遥感图像. 这些机场目标中,有结构复杂的大型国际机场(如中国浦东国际机场、韩国仁川国际机场、美国洛杉矶国际机场等),尺寸占到了整个场景的大部分区域,其数量占少数,数据库中大部分场景是只有几条跑道的小型民用机场(最短的跑道只有 1.5 km 左右). 另外 110 张不包含机场目标,这些场景包含山区、农田、城市周边等各种类型的背景,随机选取于世界各地. 在本文中将数据库简称为 GE510.

在实验中,采用的评价指标为识别率、虚警率及每幅场景的平均检测时间. 识别率定义为:

$$\text{识别率} = \frac{\text{正确检测出机场位置的图像数目}}{\text{数据库中包含机场的图像数目}} \quad (4)$$

虚警率定义为:

$$\text{虚警率} = \frac{\text{错误识别为包含机场的图像数目}}{\text{不包含机场的图像总数目}} \quad (5)$$

实验采用的计算机硬件配置是 Intel(R) Core(TM) i7-2600@3.40 GHz 3.80 GHz, 12.0 GB 内存, 其软件环境是 Windows 7 操作系统, 程序使用 Mat-

lab 2013a 进行编写的.

3.1 算法实现分析

本文提出的模型能很好地估计机场跑道的位置,但在算法构建中,邻近平行性值对场景的筛选及 BU 显著性模型的选取是两个比较关键的环节. 本节将用实验说明算法中这两部分的重要性,并将解释其中参数是如何确定的.

3.1.1 邻近平行性权重用于场景筛选

邻近平行性权重在整个模型中扮演着重要的角色. 实验的第一步计算了数据库上每个场景所对应的所有线段中最大的邻近平行性值 W_{\max} . 得到的结果与图像索引的关系绘图如 7 所示.

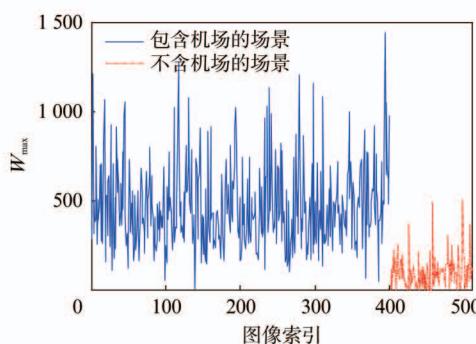


图 7 GE510 图像库中各场景的邻近平行性最大值
Fig. 7 The maximum near parallelity values in all 510 RSIs

图 7 中索引在 1 ~ 400 的图像为包含机场的场景, 401 ~ 510 的图像为不包含机场的场景. 图中可以看到这两个分组的最大邻近平行性值有明显的区别, 前者值相对较大, 后者值相对较小. 因此, 模型中采用阈值划分的方法实现对场景是否包含机场的筛选. 若场景中最大邻近平行性值满足 $W_{\max} < thr_w$, 则认为场景中线段的邻近平行性不足, 不包含机场. 而 thr_w 选取的区间可以通过图 7 进行估计.

实验的第二步, 记录不同 thr_w 所对应的识别率和虚警率, 得到图 8. 可以看到, 随着阈值的减小, 虚警率得到降低, 但识别率也相应降低. 在 thr_w 增大到 155 之后, 虚警率的降低已经趋于平缓, 而识别率曲线的斜率明显增大. 考虑到在实际应用中识别率的重要性更高, 实验中 thr_w 阈值选取为 155. 在实际应用中, 这个阈值可以根据遥感图像的地面分辨率、复杂度等信息通过经验进行估计.

3.1.2 自底向上显著性模型的选取

不同自底向上的显著性方法各有优势. 本实验首先使用不同的自底向上模型得到包含机场的遥感

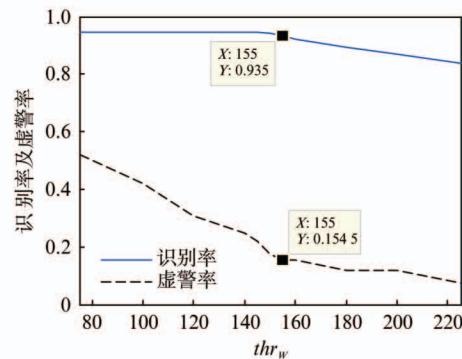


图 8 邻近平行性阈值对检测效果的影响

Fig. 8 The recognition rate and the false alarm rate decline with the growth of the threshold for near parallelity values

图像显著图, 并绘制出它们的受试者工作特征曲线 (Receiver Operating Characteristic Curve, ROC), 实验结果如图 9 所示, 绘制 ROC 曲线所需的地面真实信息为人工标注.

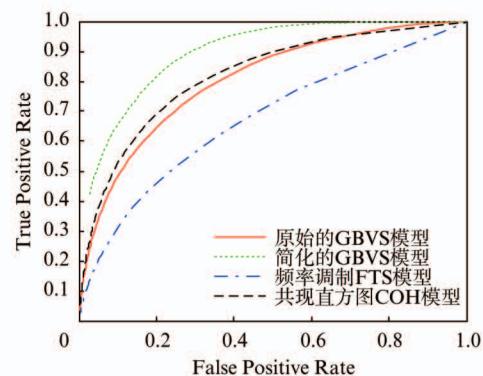


图 9 各显著性模型在数据库上的受试者工作特征曲线

Fig. 9 ROC curves of different BU saliency models in GE510

通过对 ROC 曲线的观察, 可以得出结论, 改进的 GBVS 对于场景中机场目标的显著性近似程度最高, 原 GBVS 模型和 Co-Occurrence Histogram 模型^[11] (本文后简称 COH) 显著性检测效果近似, 而 FTS 虽然是四个模型中结构最简单、速度最快的, 但其效果也是最差的. 考虑到显著性模型对于遥感图像的兼容性, 其他一些经典的模型在实验中未曾考虑.

实验的第二部分, 用于测试不同 BU 显著性模型对最终识别结果的影响. 实验中在保持整体框架 (如图 6) 不变的同时, 比较了使用简化的 GBVS 的最终模型结构和使用其他显著性算法的模型结构的

识别效果,数据陈列在表 1 中. 其中还对比了不使用 BU 显著性模型,而仅仅依赖于 TD 通道的结果.

表 1 在算法框架中替换 BU 显著性模型对于识别结果的影响

Table 1 The performances of the scheme with different BU saliency models

数据库: GE510	识别率	虚警率	平均检测时间(s)
GBVS [7]	83.5%	22.7%	3.6
FTS [9]	81.5%	29.1%	0.257
COH [11]	84.3%	20.9%	0.601
不使用 BU 显著性模型	80.8%	35.5%	0.237
简化的 GBVS 模型	93.5%	15.5%	0.359

从结果可以总结出,第一, 使用邻近平行性得到的 TD 显著性对识别结果的贡献非常大, 即使不再使用 BU 的显著性模型, 也可以达到仍能接受的识别效果. 第二, 在多种 BU 显著性模型中, 改进的 GBVS 版本效果是最好的. COH 充分考虑了纹理特征, 因此, 稀有的纹理会被突出, 但机场周边城镇的纹理非常容易吸引注意. 且该模型对于边缘的抑制性也不够, 因此得到的检测效果差于简化的 GBVS 模型. 原始 GBVS 模型由于存在“没有筛选能力”的方向通道, 反而对检测造成干扰, 检测结果与 COH 的相近. 如图 10 所示, 若采用原始 GBVS 模型, 具有水平方向的河流被错误地突出(图 10(a)), 非标准方向的机场反而被忽略, 在简化后的 GBVS 模型中可以正确检测(图 10(b)). 原始 GBVS 的计算时间也是不能容忍的, 需要 3.6 s, 其他模型在大框架相同的情况下都在 1 s 每幅以内. 由于 FTS 模型只考虑颜色(本文灰度)分布, 对于云层、城市、农田等具有较强对比的目标抗干扰能力较弱, 所以在数据库上的表现不佳. 这个结论和前面的 ROC 曲线分析的结果是一致的.

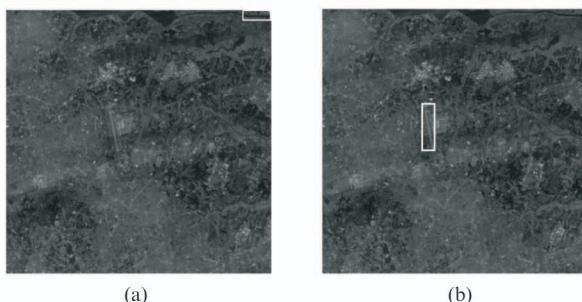


图 10 使用原始 GBVS 的检测结果和改进后的 GBVS 模型的检测结果比较,(a)使用原始 GBVS 的检测结果(b)使用简化后的 GBVS 得到的检测结果

Fig. 10 The comparison between the detection results by initial GBVS model (a) and the simplified one (b)

3.2 识别结果

本文提出的算法在含有多种类型机场的数据库上有不错的效果, 部分效果如图 11 所示.

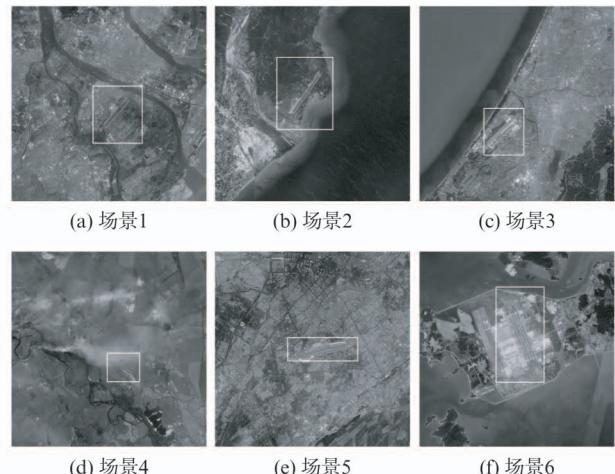


图 11 一些包含机场目标的场景检测结果
Fig. 11 Some successful detection examples

实验结果表明, 本文的方法对于各种不同类型复杂背景的鲁棒性都较好, 在图 11(a)场景中有多条河道, 这些河道各具形态, 长直的河道由于边缘邻近性不足, 弯曲的河道线段长度较短, 因此都被很好的排除干扰, 最终准确定位到机场目标. 在图 11(b, c, f)场景中, 机场处于海岸线周边, 这些海岸线一般都是孤立的长线段, 由于没有其他线段与之并行排列, 所以也被轻松去除. 在图 11(d)场景中机场被云层覆盖了一部分, 但隐约仍能看到两条并排的机场跑道, 因此云层的部分遮挡对算法没有太大挑战. 在图 11(e)场景中, 虽然机场所处的城市纹理非常复杂, 并且机场灰度对比也不强烈, 但由于城市道路纵横交错, 邻近平行性较低, 因此对算法检测结果不构成威胁. 图 11(f)场景中的机场相比于前面的机场复杂度更高, 但仍能准确定位到机场的主体部分, 证明本算法对于各种类型的机场都可以较好地进行检测.

图 12 给出了两个检测失败的案例. 图 12(a)中存在多条道路相平行, 虽然他们之间的距离不小, 但是考虑到叠加效应, 仍然会产生较大的邻近平行性值. 在图 12(b)中, 道路的长度在允许的范围以内, 大量农田的边缘线和道路平行, 而与机场目标不平行, 机场的平行性加权受到影响. 同时, 该道路在 SIFT 特征上与机场具有某种相似性, 最终未能成功检测到机场. 通过对包括图 12 在内的失败案例进行总结, 可以归纳出算法失败的三点主要原因. 其一,

机场目标不具有或者很少具有前文总结的邻近平行性先验(例如极简单的单根跑道机场). 其二,背景干扰物中含有大量平行直线(例如边缘邻近平行的农田或道路). 其三,结构简单且在灰度上被背景完全埋没的机场(此时即使人眼也较难分辨是否为机场). 这些需要在以后工作中进一步改进.

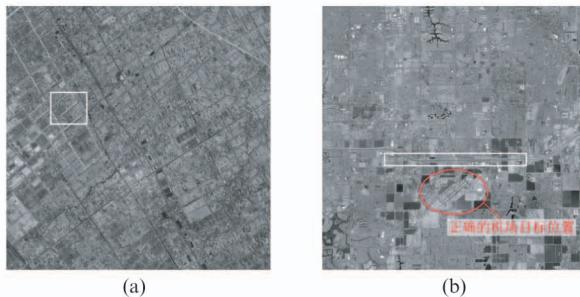


图 12 两个检测失败的例子,(a) 不含有机场的一个虚警检测(b) 含有机场的一个错误检测
Fig. 12 Two failed detection examples. (a) A false alarm detection. (b) Detected a wrong location

3.3 与其他方法的对比

本文算法与文献[2]、[3]、[5]的方法进行了对比,实验结果如表 2 所示. 其中文献[2]的方法也利用了显著性,但基本可以归为 BU 显著性的类型,因为它的 TD 部分只考虑了机场跑道是直线的这一特性. 文献[3]的方法同时利用了分块提取统计特性和 Hough 变换提取直线特征的两种思路,也能较好的定位机场目标. 文献[5]的方法改进了 Iiit 的经典显著性模型,引入方差、交叉点、惊讶值(一种基于贝叶斯模型、用于表征观察结果与先验知识对比的度量)等通道,同时并行地提取主旨性特征. 之后构

造显著性和主旨性特征合成的 198 维向量. 最后使用训练好的 SVM 进行分类,达到检测机场的目的. 为适应本实验,将每张 600×600 分成 150×150 的小块,小块与小块之间有 75 像素的重叠. 对每个小块使用文献[5]的算法判决是否包含机场,以此定位机场的位置.

表 2 和其他算法的比较

Table 2 Comparison to other models

方法	识别率	虚警率	平均检测时间(s)
文献[2]	83.8%	22.7%	1.15
文献[3]	72.5%	35.5%	1.08
文献[5]	69.3%	37.3%	121
本文方法	93.5%	15.5%	0.359

从比较中可以验证得到,本文提出的算法在识别效果和平均检测时间上都有明显的优势. 文献[2]、[3]的算法先验知识考虑不足是最大的缺陷,文献[5]的方法直接从纹理的显著性和主旨性入手,虽然方法具有普适性,但是针对性不足,并且,提取特征的繁复导致时间上无法容忍. 相比之下,本文在兼顾 BU 显著性的同时,更加注重 TD 先验知识的细节,自然可以在识别率和虚警率上有显著的提升. 同时,由于采用的 LSD 算法计算时间和图像像素数目成正比、连接算法中大部分线段间的连接可能性可以快速排除、简化的 GBVS 模型只保留了亮度通道,且同时图的节点对应于缩小后的遥感图像像素点,计算量可以大大减小. 考虑到这三点原因,本文算法的计算速度相比于其他方法也有较大的提升,从而更适用于实时应用.

一些方法对比的示例图如图 13 所示. 在两个

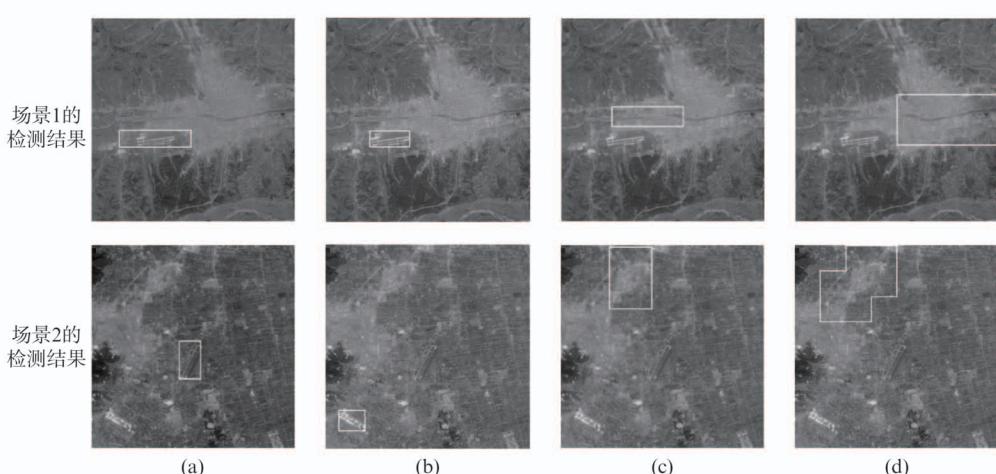


图 13 实验结果对比(a)本文算法,(b)文献[2],(c)文献[3],(d)文献[5]

Fig. 13 Comparison of some detection results with References [2-3,5]. (a) the proposed method. (b) Ref. [2]. (c) Ref. [3]. (d) Ref. [5]

场景中,本文的方法都准确地检测到机场位置。文献[2]仅在场景1中检测到机场,而文献[3]、[5]在这两个场景中都未能正确定位机场目标。仔细分析失败的案例,可以发现,大多是被具有直线特征或者和机场纹理类似的特征所吸引。文献[2]的方法由于较大程度依赖于BU显著性,从而在场景2中错误地定位到一块较亮的长方形厂房区域。本文算法深入分析了跑道间的几何关系作为TD的先验知识,同时分析了BU显著性做进一步核实,因此没有被这些干扰目标所误导。

4 结论

提出了一种基于线段邻近平行特性和简化的GBVS显著性模型的全色遥感图像机场目标检测算法。该模型深度挖掘了机场跑道的几何关系,作为TD的先验知识,同时利用简化后的GBVS模型高效地提取了BU显著性。TD和BU显著性的结合,使得对机场位置的估计更加准确。在之后的流程中,使用SIFT描述子和SVM分类机制,对候选区域进行甄选,得到最后的机场目标位置。在更广泛的数据库实验中,本文的算法效果更好、速度更快。算法优化后,完全可以胜任实时应用,无论在军事领域还是民用领域都有非常广阔的应用前景。当前算法的不足是对于平行直线纹理区域的抑制,这也是我们今后研究改进的重点。

References

- [1] WANG W, LIU L, HU C B, et al. Airport detection in SAR image based on perceptual organization [C]. Proceedings of International Workshop on Multi-platform/ Multi-sensor Remote Sensing and Mapping, Los Alamitos: IEEE Computer Society Press, 2011: 1–5.
- [2] WANG X, LV Q, WANG B, ZHANG L M. Airport detection in remote sensing images: a method based on saliency map [J]. *Cognitive Neurodynamics*, 2013, 7(2): 143–154.
- [3] Qu Y Y, Li CH, Zheng N N. Airport detection base on support vector machine from a single image [C]. Proceedings of Fifth International Conference on Information, Communications and Signal Processing 2005. Los Alamitos: IEEE Computer Society Press, 2005: 546–549.
- [4] TAO C, TAN Y H, CAI H J, et al. Airport detection from large IKONOS images using clustered SIFT keypoints and region information [J]. *IEEE Geoscience and Remote Sensing Letters*, 2011, 8(1): 128–132.
- [5] LI Z, ITTI L, Saliency and Gist Features for Target Detection in Satellite Images [J]. *IEEE Transactions On Image Processing*, 2011, 20(7): 2017–2029.
- [6] ITTI L, KOCH C, NIEBUR E, et al. A model of saliency-based visual attention for rapid scene analysis [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1998, 20(11): 1254–1259.
- [7] HAREL J, KOCH C, PERONA P. Graph-based visual saliency [C]. Proceedings of advances in neural information processing systems, 2007: 545–552.
- [8] HOU X D, ZHANG L Q. Saliency detection: a spectral residual approach [C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Los Alamitos: IEEE Computer Society Press, 2007: 1–8.
- [9] ACHANTA R, HEMAMI S, ESTRADA F, et al. Frequency-tuned salient region detection [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2009: 1597–1604.
- [10] GUO C L, MA Q, ZHANG L M. Spatio-temporal saliency detection using phase spectrum of quaternion Fourier transform [C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Los Alamitos: IEEE Computer Society Press, 2008: 1–8.
- [11] LU S J, TAN C, JOO-HWEE LIM. Robust and Efficient Saliency Modeling from Image Co-occurrence Histograms, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 36, No. 1, 2014, 195–201.
- [12] VON GIOI R G, JAKUBOWICZ J, MOREL J-M, et al. Lsd: A fast line segment detector with a false detection control. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(4): 722–732.
- [13] LOWE D G. Distinctive image features from scale-invariant keypoints [J]. *International Journal of Computer Vision*, 2004, 60(2): 91–110.
- [14] BOSER B E, GUYON I M, VAPNIK V N. A training algorithm for optimal margin classifier. [C] In Proc. 5th ACM Workshop on Computational Learning Theory, 1992, 7: 144–152.