

1-8-2019

A Horizon Detection Method Based on Deep Learning and Random Forest

Jihua Ye

School of Computer Information Engineering, Jiangxi Normal University, Nanchang 330022, China;

Shuxia Shi

School of Computer Information Engineering, Jiangxi Normal University, Nanchang 330022, China;

Hanxi Li

School of Computer Information Engineering, Jiangxi Normal University, Nanchang 330022, China;

Jiali Zuo

School of Computer Information Engineering, Jiangxi Normal University, Nanchang 330022, China;

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

A Horizon Detection Method Based on Deep Learning and Random Forest

Abstract

Abstract: The detection effect of existing horizon line detection methods is greatly affected by the environment, and the computational complexity is high. Aiming at the problem of horizon line detection in complex road scene in real-life, *a horizon line detection method based on deep learning and random forest is proposed. The deep learning model is used to extract the depth features, then the obtained depth features are used for random forest training. The results of horizon line detection are obtained by random forest regression-voting.* The simulation results show that this method has good detection effect. The detection results are not only similar to the real value on the straight road, but also are basically coincident with the true value in the shadow and the curve area. It shows that the method is robust. It can be used to detect the horizon line in complex road scene.

Keywords

horizon line, deep learning, random forest, complex road scene, simulation

Authors

Jihua Ye, Shuxia Shi, Hanxi Li, Jiali Zuo, and Shimin Wang

Recommended Citation

Ye Jihua, Shi Shuxia, Li Hanxi, Zuo Jiali, Wang Shimin. A Horizon Detection Method Based on Deep Learning and Random Forest[J]. Journal of System Simulation, 2018, 30(7): 2507-2514.

一种结合深度学习和随机森林的地平线检测方法

叶继华, 时淑霞, 李汉曦, 左家莉, 王仕民

(江西师范大学 计算机信息工程学院, 南昌 330022)

摘要: 已有地平线检测方法检测效果受环境影响较大, 计算复杂度较高。提出了一种基于深度学习与随机森林相结合的地平线检测方法。利用深度学习模型进行深度特征提取, 将得到的深度特征用于随机森林训练, 采用随机森林回归投票方式得到地平线检测结果。仿真结果表明, 所提方法检测效果较好。不仅在笔直的道路上检测结果与真实值比较相近, 而且在阴影区域以及弯道中的预测值也基本与真实值重合, 表明该方法鲁棒性强, 能够很好的用于复杂道路场景中的地平线检测。

关键词: 地平线检测; 深度学习; 随机森林; 复杂道路场景; 仿真

中图分类号: TP391 文献标识码: A 文章编号: 1004-731X (2018) 07-2507-08

DOI: 10.16182/j.issn1004731x.joss.201807010

A Horizon Detection Method Based on Deep Learning and Random Forest

Ye Jihua, Shi Shuxia, Li Hanxi, Zuo Jiali, Wang Shimin

(School of Computer Information Engineering, Jiangxi Normal University, Nanchang 330022, China)

Abstract: The detection effect of existing horizon line detection methods is greatly affected by the environment, and the computational complexity is high. Aiming at the problem of horizon line detection in complex road scene in real-life, a horizon line detection method based on deep learning and random forest is proposed. The deep learning model is used to extract the depth features, then the obtained depth features are used for random forest training. The results of horizon line detection are obtained by random forest regression-voting. The simulation results show that this method has good detection effect. The detection results are not only similar to the real value on the straight road, but also are basically coincident with the true value in the shadow and the curve area. It shows that the method is robust. It can be used to detect the horizon line in complex road scene.

Keywords: horizon line; deep learning; random forest; complex road scene; simulation

引言

地平线是道路方向的重要特征, 它可以区分道路区域与非道路区域, 排除空间区域、花草树木以及房屋等的干扰。一般检测地平线的思路都是充分利用天地之间的区别, 将图像分割开。地平线检测

在许多实际生活应用中起着至关重要的作用, 例如: 道路检测、智能驾驶、机器人视觉导航等。许多学者研究了地平线检测的方法。大量的基于远距离景观形状的地平线轮廓估计方法被提出^[1-2], 或者是通过预测路面的三维参数来估计地平线^[3], 还有基于道路场景布局估计的方法^[4]。赵世峰等^[5]设计了一个准则 J , 确保所得到的直线两边的均方差越大, J 越大, 从而找到最大的 J 值时, 地平线也就提取出了。Chen 等^[6]搜索 CMYK 颜色空间, 并将图像通过阈值分割成两部分, 该阈值使得所设计



收稿日期: 2017-06-28 修回日期: 2017-11-29;
基金项目: 国家自然科学基金(61462042, 61462043, 61650105);
作者简介: 叶继华(通讯作者 1966-), 男, 江西上饶, 硕士, 教授, 硕导, 研究方向为普适计算、机器学习; 时淑霞(1991-), 女, 江西九江, 硕士生, 研究方向为机器学习、数据融合。

<http://www.china-simulation.com>

• 2507 •

的 M 的值取得最小。Fefilyayev 等^[7]通过机器学习的方法获得地平线。程序等^[8]通过穷举出一些直线, 求出所有的被直线分成的两类之间的方差, 以结果最大值对应的直线为地平线。Zafarifar 等^[9]提出了一种在数字图像中检测地平线的方法, 综合了基于边缘和基于色彩的地平线检测技术两者之间的优势。Nechyba 等^[10]提出一种优化方法, 找到使直线两边 RGB(red, green, and blue)类间方差最小的直线。Thurrowgood 等^[11]提出的方法是利用天空部分的亮度(红外线的情况下)往往比地面的亮或者暗的这个规律判断方向。但当天空中光线很暗时, 红外线传感器对误差特别敏感。基于视觉的估计姿态的方法, 由于其需要复杂的光谱和强度分析才能准确得出天和地的分割, 所有它在集成运算和应用在实时的系统中并不容易。大部分的这些已有地平线检测方法是依赖于边缘检测, 并且要求地平线是比较明显的, 或者是路面上有比较突出的特征, 并且可以根据这些特征分割出图像中路面区域。这些方法都可以在一定的约束条件下实现有效的地平线检测, 其精度也是比较可观的, 并且有些方法还可以实现实时的地平线检测。但是大部分已有的这些地平线检测方法在实际生活中的应用, 其检测效果受环境影响较大, 例如在复杂的道路场景(遮挡、阴影、车道线模糊不清及拥堵等场景)中, 已有的方法不能非常准确的检测出地平线, 并且检测的计算复杂度也比较高。

为了解决这类道路场景的地平线检测问题, 本

文提出了一种比较快速有效的地平线检测方法, 该方法是一种基于深度学习与随机森林相结合的方法。近年来, 随机森林在目标检测与定位以及姿态估计等^[12-14]方面的应用层出不穷, 并且取得了不错的效果。我们的方法中首先将实验所使用的图片放入 SSD 模型(Single Shot MultiBox Detector)^[15]中, 进行训练并抽取深度特征, 然后将所提取的深度特征用于随机森林训练, 采用随机森林回归算法得到精确的地平线估计。

1 结合深度学习和随机森林的地平线检测方法

1.1 SSD 模型

本文用于提取特征的深度学习模型是 SSD 模型。SSD 模型是由 UNC Chapel Hill(北卡罗来纳大学教堂山分校)的 Wei Liu 博士提出的。该模型是在既保证速度, 又保证精度的情况下提出的, 是当前较优的物体检测模型。与现在比较流行的检测模型^[16,17]一样, SSD 是将检测过程全部整合成一个单深度神经网络, 便于训练与优化, 同时提高检测速度。该模型的最开始部分, 是一个 VGG-16 卷积神经网络(除去后面的全连接层), 这一部分称作基础网络, 是用于图像分类的标准架构。在基础网络之后, 添加了一些额外的卷积特征层, 这些卷积特征层的大小是逐层递减的, 可以在多尺度下进行预测, 并且在 Titan X 上以 58 帧/s 的速率得到 72.1% 的 mAP。SSD 模型如图 1 所示。

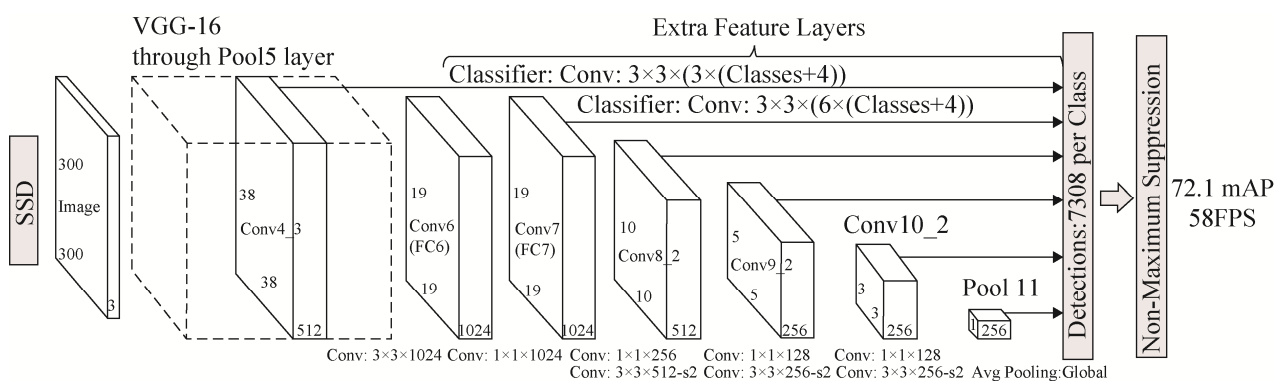


图 1 SSD 模型结构图

Fig. 1 Structural diagram of SSD model

1.2 随机森林算法

随机森林是一种比较新颖的机器学习算法。它是由很多棵 CART(Classification And Regression Tree)构成的, 对于每一棵树, 所使用的训练集都是通过自助法(bootstrap)重采样的方式, 其中引入随机样本选择和随机特征选择两个特性, 使得随机森林不容易陷入过拟合, 抗噪声能力好。随机森林能够处理非常高维度的数据, 不需要降维, 对数据集的适应能力非常强, 它既能处理离散型数据集, 也能够处理连续型数据集, 数据集都不需要做规范化。随机森林训练速度快, 在训练过程中能够生成相似矩阵, 可以度量样本之间的相似性, 也可以得到变量重要性的排序。

1.3 结合深度学习和随机森林的地平线检测方法

本文方法中, 首先利用 SSD 模型对实验的数据集进行深度特征提取, 然后将得到的深度特征进行随机森林模型训练, 回归地平线并进行测试评估。用来预测地平线的 y 坐标, 它是基于一个经过 SSD 网络的方形图像块的图像特征。为了计算不同尺寸图片的不同信息, 本文学习了两种 SSD 模型, 输入图片的尺寸大小分别为 150 px×150 px 和 300 px×300 px。

px 首先取混合数据集中 N 张图片作为训练集 $I = \{I_1, I_2, \dots, I_N\}$, 将其进行预处理, 即训练集 I 中的每张图片分别进行随机裁取最小边长为 150 px 和 300 px 的图片(利用多尺度图片进行模型训练, 有利于提高模型的精度), 然后对这两类图片的每一张分别进行裁取 K 张尺寸为 150 px×150 px 和尺寸为 300 px×300 px 的图片块, 则每一种尺寸的训练集 $P = \{P_1, P_2, \dots, P_M\}$, 这里的 $M = NK$, 将经过预处理的图片放入 SSD 网络中训练, 学习得到两种不同的 SSD 模型。

在精调 SSD 模型时, 我们使用回归 l_2 损失函数作为评价标准, 如公式(1)所示。

$$l = \arg \min_{\delta} \sum_{i=1}^M \|f(P_i; \delta) - y_i\|_{l_2} \quad (1)$$

这里的函数 $f(P_i; \delta)$ 是一个网络函数, 它表示的是输入块 P_i 到一个预测的地平线位置的映射。 δ 是模型参数, 它表示的是回归精调时用于检测的初始学习值。

通过上述精调过程, 学习得到 SSD 模型, 然后抽取其中 3 个卷积层(本文中抽取的特征层是 fc7, conv8_2, conv9_2)的特征, 进行随机森林训练, 将抽取的特征集记为 $V = \{v_1, v_2, \dots, v_m\}$, 其中 m 为特征总数, 每种尺寸的图片训练 3 个随机森林, 每个随机森林训练 500 棵树, 然后利用随机森林回归估计地平线。

随机森林中的决策树通过递归分支的方式, 将特征样本 $v \in V$ 分类到这棵树的左支或者右支直到达到叶子节点为止。树中的每一个叶子节点 j 都与一个二分裂函数相关联, 将该二分裂函数记为:

$$h(v, \theta_j) \in \{0, 1\} \quad (2)$$

式中: 带有参数 θ_j 。如果 $h(v, \theta_j) = 0$, 则表明节点 j 被分类在 v 的左边, 否则被分类在 v 的右边, 依次判断分类直至达到叶子节点。对于输入的样本 v 经过递归分类达到叶子节点, 会输出一个该样本的预测目标类 Y 。

在进行随机森林模型训练时, 每一棵树都是独立的递归的方式进行训练的。对于一个给定的节点 j 和训练集 $K_j \subset V \times Y$, 目标是找到分割函数 $h(v, \theta_j)$ 中的最优参数 θ_j , 使得被分类的数据集在最终的分类型为最好的结果。因此, 定义一个信息增益准则, 它的形式如下:

$$G_j = G(K_j^L, K_j^R) \quad (3)$$

这里 $K_j^L = \{(x, y) \in K_j \mid h(v, \theta_j) = 0\}$, $K_j^R = K_j \setminus K_j^L$ 。分割参数 θ_j 选择使得信息增益 G_j 最大时的取值。

然后以递归的方式处理左节点的数据集 K_j^L , 并以同样的方式处理右节点的数据集 K_j^R , 当训练达到最大深度时停止训练, 或者是当信息增益或训练集大小下降到一个固定的阈值时, 停止训练。

对于多类分类的信息增益标准定义给定如下:

$$G_j = H(K_j) - \sum_{r \in \{L, R\}} \frac{|K_j^r|}{K_j} H(K_j^r) \quad (4)$$

式中： $H(K) = -\sum_i p_i \log(p_i)$ 表示香农熵， p_i 是数据集 K 中带有标签 t 的分数。

在实验过程中，预测结果是由随机森林中的全部决策树的综合结果决定的，在这里使用投票的方式进行结果的预测。随机森林回归投票^[9]是一个很强大的技术，可以得到快速准确而且鲁棒的检测结果。假设测试样本为 a ，预测结果为 c ，则两者的关系可以表示为：

$$c = \arg \max_a \left(\frac{1}{n} \sum_{i=1}^n \theta \left(\frac{\delta_{i,a}}{\delta_i} \right) \right) \quad (5)$$

式中： n 是随机森林中的决策树的数量； $\theta(\bullet)$ 是一个示性函数； $\delta_{i,a}$ 是森林中第 i 棵树对 a 的分类结果； δ_i 是第 i 棵树的总分类结果。

通过上述方式进行随机森林训练，得到训练结果后，利用随机森林回归估计地平线。地平线的回归目标函数为 $y_i, i = 1, 2, \dots, M$ ，则

$$y_i = h_i / x_i \quad (6)$$

式中： h_i 为图片垂直方向上与地平线真实值 (ground-truth) 的偏移量， x_i 表示的是图片的尺寸大小，取值为 150px 或者 300px。

2 仿真实验

本文的实验是在 KITTI 和 Guangzhou_ADAS 两个数据集上进行的，共 15 000 张图片。其中，KITTI 数据集是用于道路场景中车辆检测、语义分割等方面的公开数据集，也是现在测试智能驾驶等车辆识别算法的常用数据集。首先对数据集进行人工标注，保存标注结果，作为训练和测试的标签。

基于深度学习与随机森林结合的地平线检测方法实验仿真过程如图 2 所示。




图 2 地平线检测仿真流程图

Fig. 2 Flow chart of the horizon simulation

实验过程中，首先对数据集进行预处理，将图片进行裁剪，每张图片分别随机截取三张尺寸大小为 150 px×150 px 和 300 px×300 px 的图片，然后将数据集以 3:1 的比例(即 75% 作为训练数据集，25% 作为测试数据集)进行实验。在训练过程中，使用随机梯度下降(SGD)的方式，参照目前最优检测模型的参数设置，将学习率设为 5×10^{-4} ，权重衰减设为 5×10^{-4} ，实验批量处理的块大小(batchsize) 设置为 32，迭代次数为 40 000 次。

利用深度学习模型 SSD 进行特征提取，两种不同尺度情况下抽取的 3 个卷积层的特征详情如表 1 所示。

表 1 SSD 模型中抽取两种尺度图片的特征详情
Tab. 1 Features of two scale images in the SSD model

Name	Kernel size	Stride	Pad	Output size
data	-	-	-	300×300×3
fc7	1×1	-	-	19×19×1024
conv8_2	3×3	2	1	10×10×512
conv9_2	3×3	2	1	5×5×256
data	-	-	-	150×150×3
fc7	1×1	-	-	10×10×1024
conv8_2	3×3	2	1	5×5×512
conv9_2	3×3	2	1	3×3×256

SSD 网络模型的特征抽取层次细节(以输入图片尺寸 150 px×150 px 为例)：

1) 输入层：

由于 SSD 模型的输入采用的是固定尺寸大小的图片，所以在进入模型训练之前，先对图片进行预处理，将其裁剪为尺寸 150 px×150 px 的图片，每一张输入图片中裁剪出 3 张图片用于训练。

2) fc7(conv7)卷积层：

SSD 模型的基础网络是 VGG16 的前 13 个卷积层直到 pool5。由基础网络的输出经过 1 024 个不同内容的 3×3 卷积核，得到 fc6 层的输出为 1 024 个尺寸大小为 10×10 的特征图，再经过 1 024 个不同内容的 1×1 卷积核，得到 fc7 层的输出为 1 024 个 10×10 的特征。

3) conv8_2 卷积层：

由 fc7 的输出结果经过 256 个不同内容的 1×1 卷积核, 步幅为 1 的操作过程, 得到 conv8_1 层的输出为 256 个尺寸大小为 10×10 的特征图, 再经过 512 个不同内容的 3×3 卷积核, 步幅为 2, 并对输入进行填充 (pad=1), 得到 conv8_2 层的输出为 512 个 5×5 的特征。

4) conv9_2 卷积层:

由 conv8_2 层的输出结果经过 128 个不同内容的 1×1 卷积核, 步幅为 1 的操作过程, 得到 conv9_1 层的输出为 128 个尺寸大小为 5×5 的特征图, 再经过 256 个不同内容的 3×3 卷积核, 步幅为 2, 并对输入进行填充(pad=1), 得到 conv9_2 层的输出为 256 个 3×3 的特征。

下面将本实验方法的效果与一些较新的实验方法进行比较, 以地平线检测值与真实值之间距离大小作为对比评估准则, 如果两者之间的距离小于输入尺寸的 0.05 倍, 那么认为预测正确。计算方式为:

$$A = 1 - \frac{1}{M} \sum_{i=1}^M \phi \left(\left\| y_i - y_i^{gd} \right\|_1 > 0.05 x_i \right) \quad (7)$$

式中: $\phi(\bullet)$ 是一个示性函数; M 是测试样本的数量; y_i 是第 i 张图片的预测地平线坐标; y_i^{gd} 是第 i 张图片的真实地平线坐标; x_i 是测试样本的尺寸(即 150px 或者 300px)。这里所使用的评估方法, 考虑的是预测结果与真实值之间的接近程度, 计算的结果是预测值与真实值之间的距离, 我们将其表示为精度。实验效果如图 3 所示, 图中红色表示的是地平线真实值, 蓝色表示的是地平线预测值。

由图 3 展示的各种道路场景下的地平线检测效果图可知, 该模型的检测不仅在宽敞的笔直大道上检测结果与真实值比较相近, 而且在阴影区域以及弯道中的预测值也基本与真实值完全重合, 由此可知, 该实验提取的深度特征的鲁棒性强。针对实验测试数据进行了统计, 比较三种方法在两个数据集上的测试结果, 实验估计的地平线结果与地平线真实值之间距离在一定范围内, 我们认为测试结果是正确的, 详情如表 2~3 所示。



图 3 各种道路场景下的地平线检测效果图

Fig. 3 Horizon detection effect diagram in various road scenarios

表2 3种方法在KITTI数据集上的实验结果
Tab. 2 Results of three methods on KITTI dataset

实验方法	测试正确的图片数 /总图片数	测试不正确的图片 数/总图片数
Zhang ^[10]	750/1250	500/1250
HOG+RF	950/1250	300/1250
SSD+RF	1025/1250	225/1250

表3 3种方法在Guangzhou_ADAS数据集上的实验结果
Tab. 3 Results of three methods on Guangzhou_ADAS dataset

实验方法	测试正确的图片 数/总图片数	测试不正确的图片 数/总图片数
Zhang ^[10]	1125/2500	1375/2500
HOG+RF	1575/2500	925/2500
SSD+RF	1825/2500	675/2500

实验中对3种方法的实验结果进行了统计,在KITTI数据集上的测试所使用的图片为1250张,在Guangzhou_ADAS数据集上的测试所使用的图片为2500张。从表3可以看出,测试结果与真实值之间距离在一定范围内时,本文实验测试结果准确的图片张数分别为1025和1825张,与其他方法相比,准确度有所提高。根据公式(7)计算了本实验结果的精度,并与一些较新的实验方法结果进行了对比,如表4所示。

表4 本文实验的精度及其对比实验结果
Tab. 4 Experiment accuracy and the experimental compared results

Data Set	Zhang ^[10]	HOG+RF	SSD+RF
KITTI	0.60	0.76	0.82
Guangzhou_ADAS	0.45	0.63	0.73

表4中的实验精度及其对比结果显示,利用Zhang^[10]的方法在两个数据集上的检测结果的精度分别为0.6和0.45,而利用提取HOG特征结合随机森林的方法(即HOG+RF)得到的检测结果的精度分别为0.76和0.63,本文实验方法利用深度学习特征结合随机森林的方法得到的检测结果的精度分别为0.82和0.73,与前两种方法相比,在两个数据集上的精度都有一定的提高,表明本文采用深度学习模型SSD提取深度特征,结合随机森林回归算法进行的地平线检测方法,其检测效果较好,


较近些年一些较新的地平线检测效果更优。本文实验中用于随机森林回归目标的三层特征,是经过多层卷积及池化操作的深层次网络特征,对原始数据具有很强的代表性,并且选择了多个不同分辨率的特征的预测,经过投票得到最终的回归目标,说明用深度学习模型提取的特征鲁棒性更强。

以150px×150px为例,分析使用单尺度图片进行SSD模型训练,抽取特征,进行实验的情况,得到的实验结果(在KITTI上进行测试,1250张图片)如表5所示。

表5 用单尺度150×150进行实验的结果
Tab. 5 Experiment results with a single scale of 150×150

预测值与真实值 之间的距离/像素	图片数量/张	准确度/%
≤5	332	26.65
≤10	664	51.36
≤15	970	77.60
≤20	1149	91.92

根据表5的数据,计算出各个预测值与真实值之间距离对应的实验结果的准确度,它们的关系如图4所示。

图4 实验预测值与真实值之间距离对应准确度的变化关系
Fig. 4 Relationship between the accuracy and the distance of the experimental predicted value and the actual value

通过上述实验结果可以看出,本文的实验方法在一定程度上提高了地平线检测的准确度。本文实验方法是不依赖于边缘检测或者是路面上有比较突出特征的地平线检测算法,并且在多尺度情况下训练的模型检测效果比单尺度情况训练的模型检测效果较好。在不同场景中,根据实际需求,本文实验模型受环境影响较小,鲁棒性较强,能够较好

的检测出复杂场景中地平线的分布情况。并且本文实验主要是在 GPU 平台上进行, 其计算速度较快。详细的实验速率对比情况如表 6 所示。

表 6 本文实验检测速率及其实验对比结果
Tab. 6 Experimental detection rate and its experimental compared results

Data Set	Zhang ^[10]	HOG+RF	SSD+RF
KITTI	0.098	0.205	21.3
Guangzhou_ADAS	0.123	0.260	23.7

本文实验方法(SSD+RF)主要在 GPU(Nvidia Titan X)上进行训练及测试, 而其他方法是在 CPU(Intel i7-4770)平台上进行的测试, 上表中实验结果的单位为帧/s。

3 结论

本文提出了一种基于深度学习与随机森林相结合的地平线检测方法。该方法比较快速有效, 并且鲁棒性较强, 能够较好的应用于复杂场景中的地平线检测。为道路检测及智能驾驶等方面的研究提供重要的道路方向特征信息。本文方法在两个混合的数据集上进行了分析评估, 并与较新的方法进行比较, 其效果有所改进, 并且在阴影区域等较为复杂的场景中的检测结果也较为准确, 说明本文方法具有较强的稳定性。实验所使用的数据集的人工标注精度对地平线检测结果影响较大, 需要进一步提高。实验对硬件设备的要求需要进一步改善。

参考文献:

- [1] T Ahmad, G Bebis, M Nicolescu, et al. An Edge-less Approach to Horizon Line Detection[C]// 14th International Conference on Machine Learning and Applications, Miami, United States, ICMLA 2015, 1095-1102.
- [2] A Pouryazdanpanah, E E Regentova, V Muthukumar, et al. Real-time horizon line detection based on fusion of classification and clustering[J]. International Journal of Computer Applications (S0975-8887), 2015, 121(10): 5-11.
- [3] R Tonge, S Maji, C V Jawahar. Parsing world's skylines using shape-constrained MRFs[C]//Columbus, Ohio: CVPR2014: 3174-3181.
- [4] Donghao Zhang, Xuming He, Hanxi Li. Data-driven street scene layout estimation for distant object detection[C]//International Conference on Digital Image Computing: Techniques and Applications, Wollongong, New South Wales, Australia: DICTA2014: 1-7.
- [5] 赵世峰, 张海, 范耀祖. 一种基于计算机视觉的飞行器姿态估计算法[J]. 北京航空航天大学学报, 2006, 32(8): 885-889.
Zhao Shifeng, Zhang Hai, Fan Yaozu. Attitude estimation method for flight vehicles based on computer vision[J]. Journal of Beijing University of Aeronautics and Astronautics, 2006, 32(8): 885-889.
- [6] Chen Y J, Abushakra A, Lee J. Vision-based Horizon Detection and Target Tracking for UAVs[C]//Las Vegas, NV, USA: ISVC2011: 310-319.
- [7] Fefilatyeve S, Smarodzinava V, Hall L O, et al. Horizon Detection using Machine Learning Technique[C]// Proceedings of the 5th International Conference on Machine Learning and Applications, Orlando, Florida, USA: ICMLA2006: 17-21.
- [8] 程序, 郝群, 宋勇, 等. 基于直线模型的微型飞行器姿态角计算[J]. 北京理工大学学报, 2010, 30(7): 798-802.
Cheng Xu, Hao Qun, Song Yong, et al. Method for Calculating MAV Attitude Angles Based on Straight Line Model[J]. Transactions of Beijing Institute of Technology, 2010, 30(7): 798-802
- [9] Zafarifar B, Weda H. Horizon detection based on sky-color and edge features[C]//Proceedings of SPIE, San Diego, California, United States: SPIE, 2008: 6822201-6822209.
- [10] Nechyba S M, Ifju M C, Waszak P G. Vision-guided Flight Stability and Control for Micro Air Vehicles[C]// International Conference on Intelligent Robots and Systems, Lausanne, Switzerland: IROS2002: 2134-2140.
- [11] Thurrowgood S, Soccol D, Moore R J D, et al. A Vision Based System for Attitude Estimation of UAVs[C]//The 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems, Louis, MO, USA: IROS2009: 5725-5727.
- [12] 乔体洲, 戴树岭. 基于回归森林的面部姿态分析[J]. 计算机辅助设计与图形学学报, 2014, 26(7): 1151-1158.
Qiao Tizhou, Dai Shuling. Regression Forests for Head Pose Estimation Analysis[J]. Journal of Computer-Aided

- Design&Computer Graphics, 2014, 26(7): 1151-1158.
- [13] 王丽婷, 丁晓青, 方驰. 基于随机森林的人脸关键点精确定位方法[J]. 清华大学学报, 2009, 49(4): 543-546.
Wang Liting, Ding Xiaoqing, Fang Chi. Accurate localization of facial feature points based on random forest classifier[J]. J Tsinghua Univ (Sci& Tech), 2009, 49(4): 543-546.
- [14] Claudia Lindner, Paul A Bromiley, Mircea C Ionita, et al. Robust and Accurate Shape Model Matching Using Random Forest Regression-Voting [C]//UNITED STATES, Transactions on Pattern Analysis and Machine Intelligence, 2015: 1862-1874.
- [15] Wei Liu, Dragomir Anguelov, Dumitru Erhan, et al.SSD: Single Shot MultiBox Detector[C]//Amsterdam: ECCV2016.
- [16] Girshick R. Fast R-CNN[C]//ICCV, IEEE International Conference on Computer Vision, Santiago, Chile: ICCV2015, 1440-1448.
- [17] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [C]//Montreal: International Conference on Neural Information Processing Systems, 2015, 39(6): 91-99.

(上接第 2506 页)

- [12] YANG J, YANG J-Y, ZHANG D, et al. Feature Fusion: Parallel Strategy Vs. Serial Strategy [J]. Pattern Recognition (S0031-3203), 2003, 36(6): 1369-1381.
- [13] LLINAS J, HALL D L. Introduction to Multi-Sensor Data Fusion[C]//Proc of the 1998 IEEE International Symposium on Circuits and Systems. NEW YORK, NY: IEEE, 1998, 6: 537-540.
- [14] BREIMAN L. Random Forests [J]. Machine Learning (S0885-6125), 2001, 45(1): 5-32.
- [15] LAPTEV I, CAPUTO B. Recognition of human actions [EB/OL].(2005-01-18)[2017-01-10]. <http://www.nada.kth.se/cvap/actions/>.
- [16] GORELICK L, BLANK M, SHECHTMAN E, et al. Actions as Space-Time Shapes [EB/OL]. (2007-11-24) [2017-05-03]. <http://www.wisdom.weizmann.ac.il/~vision/SpaceTimeActions.html>.