

用于秸秆燃料热值估计的图像分析系统设计

郑雅羽¹, 陈超¹, 梁圣浩¹, 何德峰¹, 李廉明²

(1. 浙江工业大学 信息工程学院, 杭州 310023; 2. 嘉兴新嘉爱斯热电有限公司, 浙江 嘉兴 314016)

摘要: 针对秸秆燃料送往循环流化床锅炉燃烧发电时, 其热值无法在线估量, 计量实效性低的问题, 设计了一套用于秸秆燃料热值估计的图像分析系统; 该系统由工业摄像机、图像分析主机、服务器和工业互联通信网络总线组成; 系统通过工业摄像机在秸秆燃料进入锅炉前进行图像采集, 并将采集到的图像通过高速差分信号传送给图像分析主机, 主机采用改进的 U-Net 深度学习网络对图像进行分割; 得到的分类结果结合从服务器读取的秸秆燃料的成分组成和组分的热值, 加之实时返回的秸秆燃料含水率等参数, 通过热值计算公式实时计算出燃料热值; 测试结果表明, 基于改进 U-Net 深度学习网络的图像分割算法分割效果较好, 平均精度 (mean Average Precision) 达到 0.86, 平均重合度 (mean Intersection over Union) 达到 0.68, 可以满足燃料热值的在线估量要求。

关键词: 秸秆; 热值估计; 图像分割; 深度学习; U-Net

Image Analysis System for Estimating Calorific Value of Straw Fuel

Zheng Yayu¹, Chen Chao¹, Liang Shenghao¹, He Defeng¹, Li Lianming²

(1. College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China;

2. Jiaying New Jies Thermal Power Co., Ltd., Jiaying 314016, China)

Abstract: In view of the difficulty and low effectiveness of calorific value estimation while the straw fuel is sent to CFB boiler for combustion power generation, an image analysis system is designed to resolve the problem. The system consists of an industrial camera, an image analysis host, a server and an industrial interconnected communication network bus. The system uses industrial camera to gather images of straw fuel before entering the boiler, and the collected images are sent to the image analysis host through a high speed differential signal, the host uses the improved U-Net deep learning network to segment the image. The classification results are combined with the composition of the straw fuel and the calorific value obtained from the server, together with the water content of straw fuel returned in real time, then the calorific value of fuel can be calculated in real time based on caloric value formula. The test results show that the image segmentation algorithm based on improved U-Net deep learning network has nice segmentation effect. The mean Average Precision is over 0.86 and the mean Intersection over Union is over 0.68, which can meet the online estimation requirement of fuel calorific value.

Keywords: straw fuel; calorific value estimation; image segmentation; deep learning; U-Net

0 引言

秸秆可以替代煤炭、石油和天然气等矿物质燃料产生电力, 不仅减少人类对矿物能源的依赖, 保护国家能源资源, 而且通过严格控制秸秆的高效燃烧将有效降低我国 PM_{2.5} 浓度, 减轻能源消费给环境造成的污染^[1]。目前欧美国家建立了较为完善的秸秆类农业废弃物燃烧发电厂, 证明秸秆直燃发电具有显著的能源效益和环境效益, 而且回收废弃秸秆增加了农民收入, 从经济上保证农民不再乱烧秸秆, 目前秸秆燃烧技术在我国发展十分迅速。

不同于煤炭、石油和天然气等矿物质燃料, 不同品种和产地的秸秆具有不同固定碳、挥发份、水分、灰分等成

分比例, 加上回收时预处理手段和当地气候的影响, 造成了秸秆燃料品质的差异很大。由于秸秆燃料品质的变化, 导致燃烧单位质量秸秆的发热量也随之发生改变, 这给秸秆燃烧发电循环流化床锅炉的燃烧效率控制和发电过程控制造成了不利的影响。因此, 在实际秸秆燃烧发电过程中, 为了更好的控制秸秆循环流化床锅炉燃烧效率, 提高秸秆燃料的发电效率和发电安全性, 需要对送入循环流化床锅炉燃烧发电的秸秆燃料进行热值计量操作, 并将计量结果及时反馈给秸秆燃烧发电过程控制系统。

目前秸秆燃烧发电过程燃料热值计量方法仍然采用化学检验方法为主^[2], 在秸秆燃料购买后进厂入库时取样, 然后烘干秸秆燃料样本, 收集蒸发的水蒸气, 得到秸秆燃料的含水率, 再燃烧烘干的秸秆燃料样本, 结合用化学试剂测定的成分组成, 建立样本绝干料的热值, 进而计量本批次秸秆燃料的热值。但目前这些方法和装置不能实现燃烧发电的所有秸秆燃料的热值的在线计量, 而且操作周期长, 应用过程复杂, 计量实效性低, 远远不能满足现代秸秆燃烧发电过程的高品质燃烧控制要求。因此, 近年来相关学

收稿日期: 2018-08-07; 修回日期: 2018-09-14。

基金项目: 国家自然科学基金(61773345); 浙江省重点研发计划项目(2017C01073)。

作者简介: 郑雅羽(1978-), 男, 浙江省温州人, 博士, 副研究员, 硕士生导师, 主要从事视频编码和视频分析, 嵌入式系统应用方向的研究。

者对于这个具有挑战性的难题做了一些探索性研究,以满
足现代秸秆燃烧发电过程对秸秆燃料热值的在线实时计量的
迫切需要^[3]。

本文结合秸秆燃烧发电过程中的实际需求,设计了一
套针对秸秆燃料热值在线实时计量的图像分析系统。不同
于传统的化学检验方法,本系统定制了一套基于深度学习
U-Net^[4]网络的图像分割算法来实现秸秆燃料分类功能,
更进一步地,良好的分类结果为秸秆燃烧发电过程中的热
值估算以及后续的燃料量的在线自动调整控制提供了参考
依据。

1 系统硬件设计

根据秸秆燃料图像分析系统的设计需求,本文设计的
系统框架如图 1 所示。

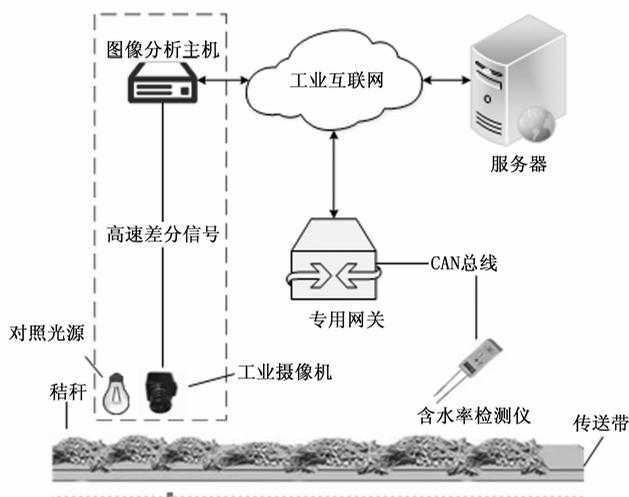


图 1 秸秆燃料图像分析系统框架

系统包括工业摄像机、图像分析主机、服务器和工业
互联网通信网络总线、含水率检测仪,其中含水率检测仪本
文不作任何介绍,但最后的含水率参数通过工业互联网返
回给主机用于在线计算燃料热值。

图像分析系统硬件设计如图 1 虚线框所示,主要包
括工业摄像机和图分析主机两部分。

1.1 工业摄像机的设计

工业摄像机的设计主要包括 ISP 处理板和摄像头板两
部分。

ISP 处理板选用 TI 公司开发的针对高清视频处理的高性
价比 DaVinci 系列多媒体处理器 DM365,主频最高可达 300
MHz,芯片内部包含一个视频处理子系统,有独立的视频处
理前端和视频处理后端组成,提供了成熟的图像处理功能,
能够针对多种类型的图像传感器进行图像质量上的优化。

摄像头板选用 Aptina 公司的 CMOS 传感器 AR0135 搭
配 M12 接口,焦距为 6 mm 的定焦镜头,最大图像传输率
能达到 720p@60fps,采用全局曝光的方式,能够有效地避
免因传送带快速运动而引起的“拖影”和“果冻现象”,进
而拍摄出清晰的秸秆燃料图片。

此外,经过 ISP 处理后的图像数据通过一根双绞线以
串行的方式传送至图像分析主机。

1.2 图像分析主机的设计

图像分析主机的设计主要包括核心板以及接口板两
部分。

1.2.1 图像分析核心板的设计

图像分析核心板采用 TI 公司的一款浮点双 DSP C66x
+ 双 ARM Cortex-A15 工业控制及高性能音视频处理
器 AM5728。

AM5728 处理器最高主频为 750 MHz (DSP) + 1.5
GHz (ARM),ROM 为 4 G/8 GByte MMC,片上 L3 RAM
高达 2.5 MB,双 DDR3/DDR3L 存储器接口 (EMIF) 模块,
最高支持 DDR3-1066,每 EMIF 支持高达 2 GB。支持全
高清视频 (1080P@60fps),多个视频输入和视频输出,具
有 DMA 引擎和多达 3 条管线的显示控制器。同时拥有丰
富的外设接口:集成千兆网,PCIe,GPMC,USB,
UART,SPI,SATA,I2C,DCAN 及工业控制总线等
接口。

此外,核心板体积极小,大小仅为 80 mm×70 mm,底
部为工业级精密 B2B 连接器,0.5 mm 间距,稳定,易插
拔,防反插,关键大数据接口使用高速连接器,保证信号
完整性。核心板是最主要的信号处理分析核心,高速信号
分布密集,采用了十层板层叠设计,同时预留一大块裸铜
散热区。

1.2.2 图像分析接口板的设计

图像分析接口板,主要负责与外设进行交互。板上除
了常用的 HDMI,USB,SATA,UART 接口外还集成了 4
G 模块,用于连接工业互联网,以达到和系统中的其他设
备进行通信的目的。

4 G 模块选用一款 Neoway 的基于高通平台的 4 G 全
网通工业级模块 N720,搭载 ARM Cortex-A7 处理器,具有
超宽工作温度低至 -40℃ 高至 +85℃,静电能力达到 8
KV;支持国内移动/联通/电信三大运营商的 2 G/3 G/4 G
网络制式。N720 通过 USB 虚拟串口与主控芯片 AM5728
进行通信。

2 系统软件设计

在硬件系统的基础上,软件开发需要完成的任务包括
各模块的驱动编写、图像的采集和处理、工作状态的检测、
训练标注平台的设计、图像分割算法的实现以及秸秆热值
的计算。图像分割算法和秸秆热值估算将单独在后两节
实现与分析。整个系统的运行流程如图 2 所示。

2.1 ISP 图像处理

图像传感器经过曝光得到的图像数据为原始数据 (Raw
Data),由于保存的图像信息量较大,无法直接传递给后续
算法处理,所以需要经由 ISP 处理^[5],在格式上,质量上对
图像进行优化。ISP 图像处理主要流程如图 3 所示。

2.2 工作状态检测算法

本系统利用了感知哈希算法^[6]计算并比较图像的相似

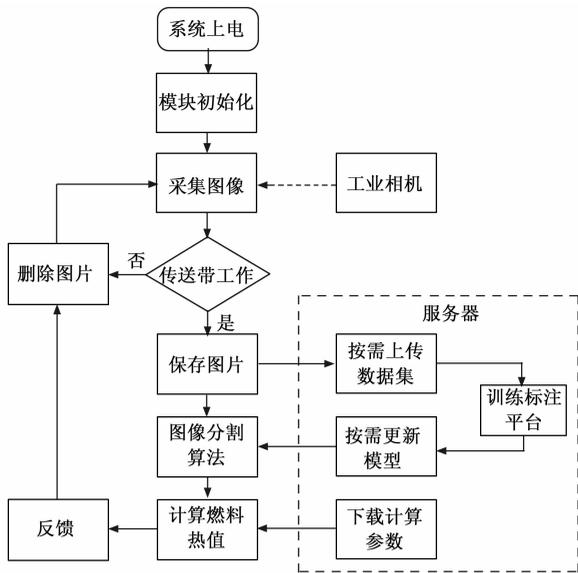


图 2 系统运行流程

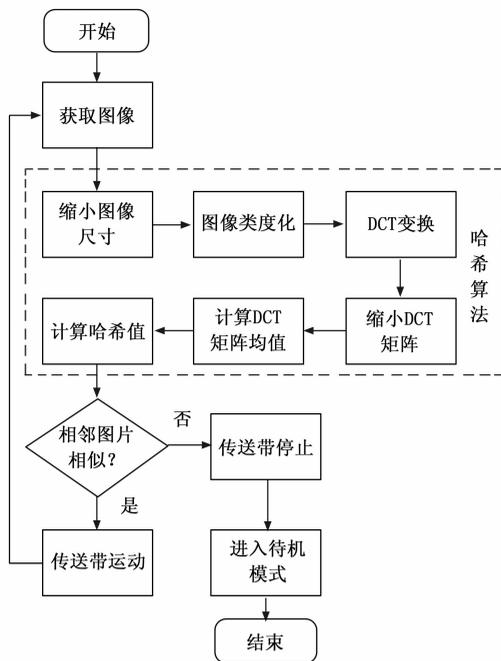


图 4 系统运行流程

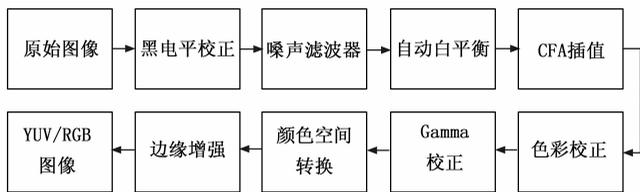


图 3 ISP 处理流程

为了方便拓展, 训练标注服务器被设计成分布式结构, 其架构如图 5 所示。

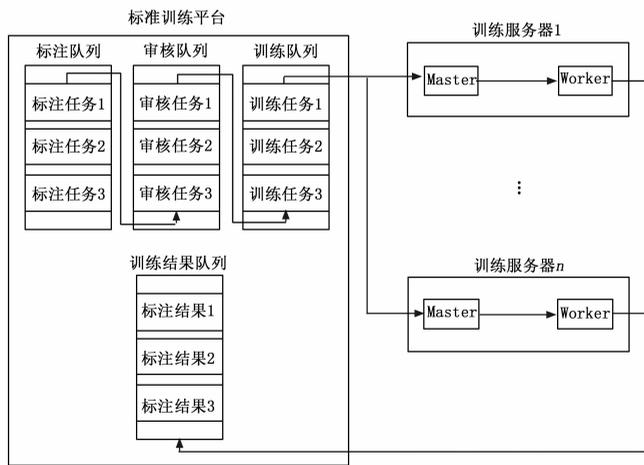


图 5 标注训练服务器分布式架构

度来检测运送秸秆燃料的传送带是否处于工作状态, 同时根据工作状态来关闭图像分析系统中的一些功能模块, 进入待机模式, 等待下一次工作, 以此降低整个系统的功耗和网络流量消耗。工作状态检测算法的流程如图 4 所示。

本系统在算法中通过 DCT 变换, 利用 DCT 低频系数之间的相关性构造哈希^[7]。通过计算 8x8DCT 的矩阵的均值与 64 个数进行比较, 大于等于 DCT 均值设为 1, 小于 DCT 均值的设为 0。最后得到一个 64 位的哈希值作为每一张图片的“指纹编码”, 通过比较这个“指纹编码”来比较两张图片的相似度, 进而判断工作状态。

2.3 训练标注平台

训练标注平台用 ruby on rails 框架开发。结构如表 1 所示, 主要由数据存储模块、任务管理模块、标注功能模块、登录管理模块、标签组管理模块、训练管理模块组成。

表 1 各模板类别识别时间

模块名称	功能描述
数据存储模块	存储设备上传的图片数据及对应的标注结果
任务管理模块	创建、分配和审核标注任务
标注功能模块	实现标注任务的具体标注执行
登陆管理模块	实现用户的登录管理
训练功能模块	分发训练任务给训练服务器, 展示训练结果
标签管理功能	以组的形式管理各种任务标签

标注平台首先将用户或者设备上传的图片数据按照不同的标签组标识的任务分发给不同的标注人员, 形成标注队列, 当用户标注提交任务完成后, 返回给平台形成审核队列, 当分发任务人员审核通过后, 即可发布训练任务, 形成一个训练队列, 由训练服务器轮询认领任务。

Master 程序主要实现任务认领, 下载相关的图片数据包, 返回训练进度, Worker 程序主要用于训练, 生成训练结果, 当 Worker 程序训练完成时, 会通知 Master 程序将训练结果返回给平台, 在训练平台中形成训练结果队列, 以供给用户展示结果。

3 分割算法

在燃料秸秆的分割算法中, 核心算法主要由两个部分组成:

图像数据增强算法和语义分割算法。图像数据增强是指对现有的图像数据进行各种变换操作，以达到数据扩展的效果。语义分割是将采集到的图像输入到 U-Net 改进网络中，先集后经过编码器、解码器、归一化等多种操作得到语义分割图像。

3.1 图像数据增强算法

深度学习是基于数据的算法，数据越多，其效果就越好，并且数据集越大，模型过拟合的可能就越小，可以说是百利无一害。而由于语义分割的数据集标注成本较高，故我们引入了数据增强算法来对已有的标注数据集进行扩张。

3.1.1 随机修剪

随机裁剪就是指在原图像上随机裁剪指定大小的图片用于训练，假设原始图像为 256×256 ，裁剪得到 224×224 的图片进行输入，这可以使我们的数据集扩张 1024 倍。设定一个图片大小，在原始数据集上的随机位置裁剪下该大小的图片用于训练。本系统设定的裁剪大小为 512×512 。

3.1.2 PCA Jittering

首先按照 RGB 三个颜色通道计算了均值和标准差，对网络的输入数据进行规范化，随后我们在整个训练集上计算了协方差矩阵，进行特征分解，得到特征向量和特征值，用来做 PCA Jittering^[8]。对秸秆燃料数据集做 PCA jittering 的效果如图 6 所示。

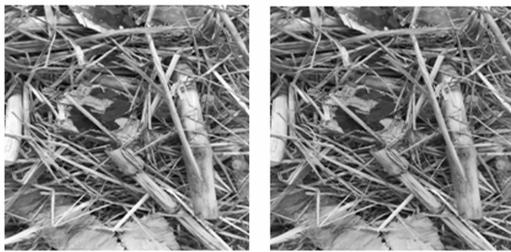


图 6 施加 PCA jittering 效果图

PCA jittering 是利用主成分来给 RGB 像素值加偏差的处理方式，PCA jittering 操作就是在训练数据上执行 PCA 找到主成分，然后为每个训练图像添加多个找到的主成分。

3.2 语义分割算法

语义分割^[9-10]是整个系统的核心，通过深度学习方法来对秸秆燃料进行分割，以分割的结果计算得到秸秆的占比，最后通过占比和各组分的热值估算出当前燃料堆的热值是本算法研究的主要方向。

尽管我们采用了图像数据增强来对数据集进行扩张，但是由于，其场景比较单一，各张图片内容会比较相似，所以实际数据集还是会偏小。因此我们选择 U-Net 结构作为算法的核心架构。U-Net 结构的网络在小数据集上也能训练得到一个较好的模型，并且相对于逐像素点分类的其他网络，其网络速度更快。

3.2.1 网络结构

原始的 U-Net 网络^[4]在编码器侧使用了典型的卷积^[11-12]网络架构，每次重复两个卷积层和一个池化层，深度略显不足，而深度可以使模型拟合能力指数增长^[13]。

编码器部分主要是为了提取图片的特征，而图像分类网络在图片特征提取方面的效果非常不错，谷歌最近发布的 MobileNet V2^[14]是一个轻量网络，在速度上超过了许多网络，并且效果很好，所以我们选择 MobileNet V2 网络来作为编码器。优化后的网络结构如图 7 所示。图片输入网络后的步骤描述如下：

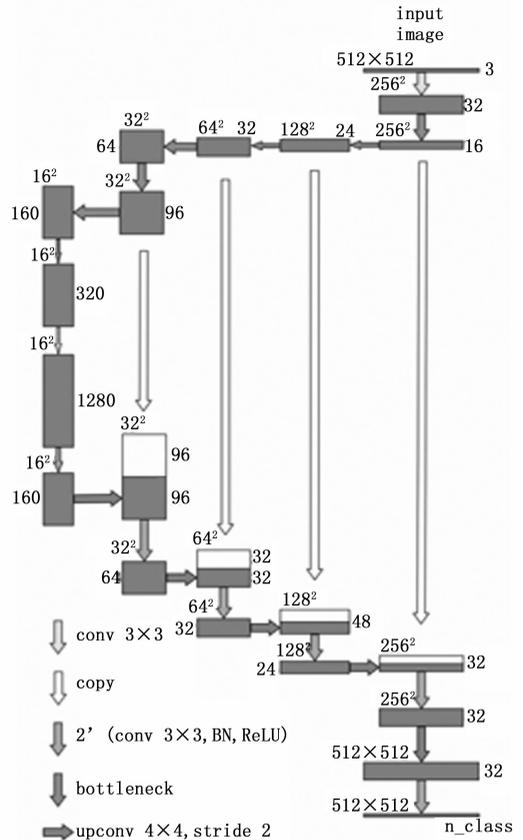


图 7 U-Net 网络结构

步骤一：对输入进行卷积得到特征图。

步骤二：复制一份特征图，对其中一份特征图继续前向卷积操作，保留另一份准备进行 copy 操作。

步骤三：重复步骤一、二 4 次。

步骤四：将前向得到的特征图同之前保留的特征图融合并进行卷积操作，重复 4 次。

步骤五：得到最后的输出图。

一般而言，卷积层越多，提取的特征越高级，即从提取线慢慢变成提取物体特征，具体提取的效果可以由网络根据给定数据自动拟合

3.2.2 Loss 函数

损失函数是用来评估预测结果与真值之间的差异程度，损失值越小，说明模型的效果越好。这里我们采用交叉熵函数作为网络的 loss 函数。

交叉熵损失函数公式如式 (1) 所示：

$$C = -\frac{1}{n} \sum_x [y \ln a + (1 - y) \ln(1 - a)] \quad (1)$$

其中： n 为训练数据的个数， x 为训练输入， y 为期望的输出， a 为实际的输出。其导数公式如式 (2)，式 (3) 所示：

$$\frac{\partial C}{\partial \omega_j} = \frac{1}{n} \sum_x x_j (\sigma(z) - y) \quad (2)$$

$$\frac{\partial C}{\partial b} = \frac{1}{n} \sum_x (\sigma(z) - y) \quad (3)$$

其中: $\sigma(z) = a$, $z = \sum_j \omega_j x_j + b$, ω 为神经元权重, b 为神经元偏置。

根据导数可以看出, 在使用交叉熵作为损失函数时, 权重的学习速率可以被控制, 也就是可以被结果的误差控制。那么当误差大的时候, 权重更新就快, 当误差小的时候, 权重的更新就慢。

3.2.3 优化算法

优化算法主要是通过改善训练方式来帮助模型最小化损失函数。我们选择 Adam 算法^[15]作为网络训练的优化算法。Adam 算法是在深度学习领域非常流行的算法, 是一种可以替代传统 SGD 算法的优化算法, 它能计算每个参数的自适应学习率, 在非凸优化问题中有着许多优势。

4 热值估算

在以下估算过程中, 为方便叙述, 将秸秆燃料主要分为三类: 小麦秸秆、玉米秸秆、木头。

计算步骤如表 2 所示。

表 2 秸秆燃料热值估算步骤

步骤 1	获取秸秆燃料分割图, 即特征图
步骤 2	分类统计像素值
步骤 3	持续累加像素值一段时间
步骤 4	根据累加值估算平均占比
步骤 5	通过工业互联网获取燃料的含水率
步骤 6	从服务器读取每类燃料绝干料的热值
步骤 7	结合占比, 含水率, 决干料热值估算总热值

4.1 占比计算

4.1.1 表面积占比

用数据增强后的秸秆燃料数据集来训练网络, 训练 1 000 个 epoch 后得到可以使用的语义分割模型。将秸秆图像输入模型, 得到一张的特征图, 不同维度预测的是不同种类物体的位置信息。我们将同位置不同维度的像素值大小视为该维度代表的种类的置信度, 根据每个点在所有维度上的像素最大值的维度值, 得到秸秆分割图, 即一张的特征图。

$$P(m, n) = \arg \max_i (F(m, n, i)) \quad (4)$$

其中: m, n 表示坐标信息, i 表示输出特征图的第 i 维, $P(m, n)$ 代表坐标 (m, n) 的像素值, $F(m, n, i)$ 表示在 (m, n, i) 位置的像素值。

对于处理得到的特征图, 每一个像素值就代表一种物体。在本文中, 0 代表小麦秸秆, 1 代表玉米秸秆, 2 代表木头, 3 代表背景。最后我们通过统计不同像素值的个数做计算得到各个物体的占比。

4.1.2 总体占比估算

通过分割算法得到的占比仅仅是表面积占比, 不代表总体占比。在实际应用中, 我们不需要每隔几秒就反馈一

次占比给控制系统, 因此针对燃料堆放不均匀, 上下层次混乱等问题, 本文通过累加法计算一段时间内的平均占比来降低随机性, 以此提高估算的精度。时间 T 的取值过小, 过大都会影响系统的稳定性。

假设系统每隔 Δt 做一次图像分割算法, 某一成分的像素值在时刻 t 出现的次数为 $freq_t$, $m \times n$ 表示特征图的大小, 那么一段时间 T 内, 该类成分的平均占比 \bar{P} 计算如式 (5) 所示:

$$\bar{P} = \frac{\sum_{t=0}^T freq_t}{T \times m \times n} \quad (5)$$

4.2 含水率问题

除了占比的问题, 实际热值估算中还需要考虑含水率对热值的影响。

由于秸秆燃料的库存量通常很大, 而且存放周期也较长, 因此即使是同一批次秸秆燃料, 经过长时间存放后, 由于含水率的变化它们的燃烧热值都将发生很大的改变和不同。

通过含水率检测仪在线测量秸秆燃料的含水率并返回给图像分析主机, 读取服务器中对应秸秆燃料的成分组成和组分的热值^[3], 采用秸秆热值计算公式计量秸秆燃料的热值, 热值计算公式参见式 (5):

$$Q = q(1 - 0.01\omega) - a_1\omega \quad (6)$$

其中: Q 表示单位质量某一类秸秆燃料的热值, 单位 J/kg; ω 表示当前时间段内秸秆燃料的含水率, 单位 %; q 表示秸秆燃料的决干料的热值, 单位 J/kg, 计算参见式 (6):

$$q = a_1q_C + a_2q_H + a_3q_S + a_4q_N - a_5q_O \quad (7)$$

其中: q_C, q_H, q_S, q_N 和 q_O 分别表示秸秆燃料中中碳、氢、硫、氮和氧的质量含量, 单位 %; 系数 a_1, a_2, a_3, a_4 和 a_5 分别表示对应秸秆燃料中对应成分的单位质量的热值, 单位 J/kg。

4.3 热值估算公式

综上所述, 结合平均占比计算公式和热值估算公式得到一段时间 T 内总热值的估算公式如式 (7) 所示:

$$Q_{total} = MT[(1 - 0.01\tau\omega) \sum_{i=1}^k \bar{P}_i q_i - \tau \sum_{i=1}^k \bar{P}_i q_i a_{ci}] \quad (8)$$

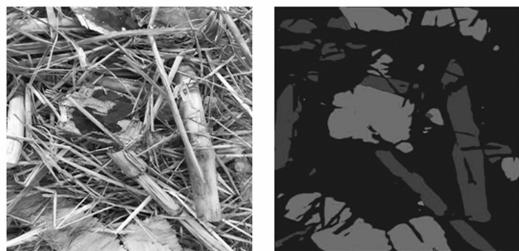
其中: Q_{total} 表示 T 时间段内所有秸秆燃料的总热值, 单位 J, M 表示单位时间内传送带上经过的秸秆燃料总质量, τ 表示当前时间段内秸秆燃料的含水率, i 表示第 i 类成分, q_i 表示第 i 类成分的决干料的热值, \bar{P}_i 表示第 i 类成分的在 T 时间段内的平均占比, a_{ci} 表示第 i 成分中碳的单位质量的热值。

5 系统测试

5.1 分割效果

输入测试集到 U-Net 网络中, 得到特征图, 以像素值来区分不同的类别。在本实验中, 像素值 0 代表小麦秸秆, 1 代表玉米秸秆, 2 代表木头, 3 代表背景, 由于不同的像

素值在视觉上无法给人直观的感受，所以我们对像素值进行了编码，将 4 个像素值以不同的 RGB 值映射到图片中。其中，黑色为小麦秸秆部分，红色为玉米秸秆，绿色为木头，黄色为背景。效果展示如图 8 所示。



(a) 原图 (b) RGB映射图

图 8 分割算法效果图

5.2 算法性能测试

本文对基于改进 U-Net 网络的分割算法进行了量化测试，分别以 150 张人工标注过的图片和 300 张人工标注过的图片作为训练集对算法进行训练，挑选 30 张为训练图片进行测试，计算每一种成分的平均精度，平均重合度，结果如表 3，表 4 所示。

表 3 训练集为 150 的算法性能

燃料类型	平均精度(mAP)	平均重合度(mean IU)
玉米秸秆	0.786	0.617
小麦秸秆	0.891	0.803
木块(屑)	0.710	0.567
全部燃料	0.843	0.604

表 4 训练集为 300 的算法性能

燃料类型	平均精度(mAP)	平均重合度(mean IU)
玉米秸秆	0.796	0.627
小麦秸秆	0.896	0.813
木块(屑)	0.723	0.573
全部燃料	0.861	0.675

通过比较，可以明显的得知几个结论：

- 1) 小麦秸秆的分割效果最好，玉米秸秆次之，木块的分割效果较差。
- 2) 训练集的大小影响分割效果，一般而言，训练集越大，分割效果越好。
- 3) 训练集中每种成分的多少也会影响最后的分割效果，例如训练集里小麦秸秆比例大，所以最后小麦秸秆的分割效果最优。
- 4) 平均精度和平均重合度越大，分类结果越准确，最后得出的热值估值也就越精确。

6 结束语

本文针对秸秆燃料燃烧发电时的实际需求，设计了用于秸秆燃料热值估计的图像分析系统，先后介绍了该系统的硬件和软件系统，加入了传送带工作状态的检测机制，

设计了用于标注训练秸秆数据的平台，提出了基于改进 U-Net 网络的图像分割算法，并通过大量实验验证了该算法的精确度。系统测试结果表明，在训练集大于 300 以上时，算法的平均精度达到 0.86 以上，平均重合度达到 0.68 左右，算法稳定性和适应性较好，能根据秸秆燃料的成分不同，训练出不同的模型。

但是由于秸秆燃料堆放不均匀，层次复杂等问题，得到的表面积占比不足以代表最后的占比，后续将针对如何选择合理的 T 值使秸秆燃料占比估算的过程最优化进行研究，并结合实际应用场景，基于大量实验数据，给出一个合理的时间阈值 T ，优化整个系统的精确度。

参考文献：

- [1] 裘一冰, 叶波, 陆若辉. 浙江省农作物秸秆饲料化利用现状的分析与探讨 [J]. 浙江农业科学, 2018 (2): 51.
- [2] 张立权. 浅析秸秆直接燃烧发电技术的应用前景 [J]. 电站系统工程, 2007, 23 (3): 69-69.
- [3] 浙江工业大学. 基于图像远程分类的秸秆燃烧发电过程燃料热值在线计量装置 [P]. 中国专利: 20180269717.4, 2018-08-03.
- [4] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation [A]. Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015. Springer International Publishing [C]. 2015: 234-241.
- [5] Techcon A. Image pipeline: Fine-tuning digital camera processing blocks [J]. Eetimes Com, 2007.
- [6] 张慧, 张海滨, 李琼, 等. 基于人类视觉系统的图像感知哈希算法 [J]. 电子学报, 2008, 36 (b12): 30-34.
- [7] 曾勇. 图像感知哈希算法及应用 [D]. 杭州: 浙江理工大学, 2012.
- [8] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C]. International Conference on Neural Information Processing Systems. Curran Associates Inc. 2012: 1097-1105.
- [9] Badrinarayanan V, Kendall A, Cipolla R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Scene Segmentation. [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, PP (99): 1-1.
- [10] Noh H, Hong S, Han B. Learning Deconvolution Network for Semantic Segmentation [C]. IEEE International Conference on Computer Vision. IEEE Computer Society, 2015: 1520-1528.
- [11] Shelhamer E, Long J, Darrell T. Fully Convolutional Networks for Semantic Segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39 (4): 640-651.
- [12] Chen L C, Papandreou G, Kokkinos I, et al. Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFs [J]. Computer Science, 2014 (4): 357-361.
- [13] Pascanu R, Cho K, Bengio Y. On the number of linear regions of deep neural networks [C]. International Conference on Neural Information Processing Systems. MIT Press, 2014: 2924-2932.
- [14] Sandler M, Howard A, Zhu M, et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks [J]. 2018.
- [15] Kingma D, Ba J. Adam: A Method for Stochastic Optimization [J]. Computer Science, 2014.