

基于卷积神经网络的复杂构件 内部零件装配正确性识别

赵耀霞¹, 吴桐², 韩焱²

(1. 中北大学电气与控制工程学院, 山西太原 030051; 2. 中北大学信息与通信工程学院, 山西太原 030051)

摘要: X射线成像是解决复杂构件内部零件装配正确性识别的最有效方法, 现有特征识别方法是以图像中的连通区域形状、长宽比、面积等特征为目标。虽然检测效果较好, 但受机械精度、装配公差、零件错位等因素影响, 识别鲁棒性较差。基于此, 综合卷积神经网络目标分类识别技术与X射线多视角成像技术, 首先设计了一个深度卷积神经网络模型, 通过深度学习的方法提取特征、训练分类器, 对工件内部零件进行分类, 输出坐标框, 完成工件零件漏装检测。进而针对所识别零件坐标信息; 依据CT投影正弦特性, 找到与当前检测工件投影角度相符的标准工件投影, 完成零件换位、错位等识别。通过实验验证, 此方法在自行建立的数据集上完成了对工件内部零件漏缺和换位的识别, 鲁棒性较高。

关键词: 装配识别; 卷积神经网络; 区域生成网络; X射线多视角; 角度匹配

中图分类号: TP391.4

文献标识码: A

文章编号: 0372-2112 (2018)08-1983-06

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2018.08.025

Identifying the Correctness of Fit of Internal Components Based on a Convolutional Neural Network

ZHAO Yao-xia¹, WU Tong², HAN Yan²

(1. School of Electrical and Control Engineering, The North University of China, Taiyuan, Shanxi 030051, China;

2. School of Information and Communication Engineering, The North University of China, Taiyuan, Shanxi 030051, China)

Abstract: X-ray imaging is the most effective way to solve the correctness of fit of the internal components. Although the previous detection method, which is based on extracting and matching characteristics such as the shape of the connected regions in sample images, the aspect ratio or the area, achieves a better detection result. But by mechanical precision, assembly tolerances, parts dislocation and other factors, it is less robust. To solve this problem, by combining convolution neural network classification with CT technology, this dissertation first designed a deep Convolutional Neural Network model. Extracted features and trained the classifier using deep learning methods to classify the internal parts of a workpiece, outputting the coordinate frame and performing missing part detection. Then, uses the coordinates of the detected parts, we find standard workpiece views that conform to the current test-workpiece's angle based on CT projection sinusoidal properties. Perform assembly error detection, such as transposition or dislocation of the test workpiece's internal parts. Experiments show that our combined approach can identify missing and misaligned internal parts of a workpiece. The overall system is robust to factors such as overlapping among the internal parts of the workpiece.

Key words: assembly identification; convolutional neural network; region proposal network; multiple angle x-ray; angle match

1 引言

在仪器仪表、精密机械、电子装备等行业均涉及整

机系统的零部件装配, 在目前的装配工艺中, 无论是手工装配还是机器人自动装配, 受零件结构复杂、尺寸不一、形状类似等影响, 往往存在错装、漏装、错位等问题,

影响整机装备质量、运行性能及安全,造成难以估计的损失.所以,对其进行装配快速正确识别极为重要.但是,一般装配的整机及装备都是非透明壳体,无法直接通过人眼直观判断识别,唯有借助 X 射线成像方式实现装配结构的直观显示与识别. X 射线数字成像(Digital Radiography, DR)^[1]是积分式的投影成像,在某一视角下的图像存在零部件的相互遮挡无法直接判读装配信息. X 射线 CT(Computer Tomography)^[2,3]通过旋转采集不同角度的投影图像,利用投影重建获得三维图像,可识别产品每一部件的空间位置结构,但是该方法检测成本高、耗时,不适宜生产线上检测.

X 射线 CT 能够实现任意结构的空成,主要是利用多视角成像,依据该原理,中北大学韩跃平、韩焱等人,在 DR 成像基础上,结合多视角成像交叉识别,研发了国内复杂产品内部结构装配正确性 X 射线在线自动检测系统^[4],成功应用于重庆长安汽车集团的多种复杂结构产品的快速自动检测.但是该方法主要基于图像特征提取与匹配,对检测工装的机械精度要求较高,同时对零部件错位识别准确性差.解决这一问题,重点在于提取不受空间位置约束、旋转不变、尺度不变的特征信息,但是目前常用特征提取方法^[5,6],特征种类单一,无法保证复杂结构件投影图像的精准识别.近年来,基于深度学习^[7]的目标识别技术在复杂背景情况下取得了比较好的结果,特别是提出的 R-CNN^[8], Fast-RCNN^[9], Faster-RCNN^[10],从最初的 66.0%^[8]到 68.1%^[9]到 73.2%^[10],在检测速度上也有了质的飞跃.而且,卷积神经网络在一定意义上具有尺度不变性和位移不变性,一定程度上解决了现有方法鲁棒性较差的问题,对工件内部零件错位、机械精度、装配公差等情况具有较高的容错度.

卷积神经网络仅能定位所识别射线图像中的目标位置,但是对于零件装配识别问题,受积分投影的相互遮挡影响,需进一步结合 CT 多视角的正弦投影原理,进行装配识别.因此,论文基于上述思想,设计一个卷积神经网络模型,以标准工件投影数据训练模型,分别以模型的两个输出层-分类结果和定位框完成内部零件的缺漏检测和错位检测,进一步结合 CT 多视角成像,完成零部件装配正确性检测.

2 X 射线多视角成像识别原理及流程

依据 X 射线的衰减规律,当 X 射线管产生的 X 射线透照到检测对象上时,由于检测对象内部结构存在密度、厚度等方面的差异,使透照在检测对象上的射线衰减程度各不相同,即透过检测对象的 X 射线强度分布发生变化,对应的携带检测对象信息的 X 射线形成 X 射线信息影像.该影像由于零部件投影的相互遮挡,无

法辨识零件的装配信息.但是在射线成像系统上,配备机械转台,可实现多个角度的投影信息获取.按照投影几何关系,可以综合各个角度的投影信息实现零部件结构的识别.具体识别过程如下:

- (1) 选取合格工件,获取 $[0, 2\pi)$ 范围内全周向投影序列;
- (2) 提取投影序列中的特征建立样本数据库;
- (3) 随机获取检测样品任一角度下的投影图像,与样本数据进行匹配分析,实现图像的投影角度定位及特征判断;
- (4) 考虑遮挡问题,对检测样品旋转 90 度,继续进行特征匹配分析;
- (5) 综合判断过程(4)和(5)的识别结果,完成零件装备正确性的识别.

3 基于卷积神经网络的工件内部零件装配识别

对于投影识别过程中设计的特征匹配方法,由于机械运动精度及零部件的装配公差影响,鲁棒性较低,对此采用卷积神经网络的方法进行实现.

3.1 卷积神经网络(CNN)

常规的卷积神经网络一般由特征提取层和全连接层组成^[11],特征提取层又包括卷积层和池化层,二者间隔分布.以输入一副图像为例,首先经过第一个卷积层对图像进行卷积操作,每个卷积层有多个不同大小的卷积核,每个卷积核都会对图像进行不同的特征提取,从而得到多个不同的卷积结果,卷积结果通过一个激活函数后,就可以得到输出的特征映射,每一个输出特征映射可能是组合多个输入特征映射的值:

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} c_{ij}^l + b_j^l\right) \quad (1)$$

式中, l 表示层数, i 表示特征映射图上的点, j 表示特征映射图上的编号, x 表示计算数值(如在输入级表示图像某通道的灰度值), c 表示卷积核, b 表示加性偏置, M_j 表示特征映射图集合.经过卷积操作得到的卷积结果经由下采样层进行局部相加,利用训练参数对其添加乘性偏置和加性偏置,然后输入非线性函数中计算,得到下采样结果:

$$x_j^l = f(\beta_j^l \text{down}(x_j^{l-1}) + b_j^l) \quad (2)$$

对于下采样层来说,有多少个输入的特征映射,就有多少个输出的特征映射,只是每个输出都变小了. $\text{down}()$ 表示一个下采样函数,在本文中采用最大值池化,保留一个区域内最主要的特征.每个输出特征映射都对应一个属于自己的乘性偏置 β 和一个加性偏置 b ,池化操作在对卷积映射降维的同时也降低了模型过拟合的风险.提取特征后,特征提取层结果作为输入进入

全连接网络,进行特征进行判定分类.在具体应用过程中,特征提取层和全连接层的数目可根据需要进行调节的.

3.2 基于 CNN 的工件内部零件分类识别

CNN 分类模型训练算法可分为候选区域生成、特征提取、分类、坐标框回归四个步骤:

(1)将图像分割成许多个小区域,并对候选框进行筛选;

(2)对每个候选区域,使用卷积 CNN 提取特征;

(3)提取到的特征送入每一类的 SVM 分类器,并判别是否属于该类,为正样本还是负样本;

(4)对于某一特征的候选框,使用回归器修正其位置,将深度网络最后的池化层数据作为输入,输出的修正结果为 XY 方向的平移和缩放.卷积神经网络的输入包含 3 个部分:样本图像、标定值 (ground truth) 以及“目标可能的位置”(object proposals).如图 1 所示,输入样本图像及其标定值,经过候选区域生成阶段判断“目标可能的位置”,通过计算数据集标定的 ground truth 与 object proposals 的覆盖率,得到每个数据集图像中的感兴趣区域 (ROIS).卷积神经网络通过特征提取层获得样本的卷积特征,ROI 池化层对每一个感兴趣区域提取出对应的特征向量,所有的特征向量经过全连接层得到两个输出层,分别为分类结果以及检测框坐标结果,如图 2 所示.前一个输出层用来判断每个感兴趣区域为 k 个类的概率 p ,后一个输出层用来计算 k 个类型检测框的坐标值.基于此,本文利用分类结果完成工件内部零件装配缺漏检测,利用检测框坐标结果完成工件内部零件换位检测.同时,在训练阶段加入深度卷积神经网络实现区域生成 (Region Proposal Network, RPN),使得它与检测网络共享卷积层的卷积结果,以此代替以往 RCNN 算法选择性搜索^[12]生成候选框的过程,卷积神经网络模型结构及训练、分类流程如图 2 所示.




图1 算法流程示意图

将图像输入卷积神经网络,经由五个卷积层提取特征后输入 RPN 网络. RPN 的输入是任意大小的图像,输出一组打过分的候选框.在卷积的最后一层特征图上使用固定大小的窗口滑动,每个窗口会输出固定大小维度的特征,每一个窗口对候选的 9 个 box (3 种尺度 {128, 256, 512}, 3 种长宽比 {1:1, 1:2, 2:1} 共 9 种)

进行回归坐标和分类.训练数据的生成标准为判断 box 覆盖 ground truth 是否超过 70%,超过就将当前 box 的目标分类标记为存在;如果都没有超过 70%,就选择一个覆盖比例最大的标记为存在.最后与真值框进行对比,取前 300 个与真实区域重叠较高区域作为输入进行目标检测,其它的区域直接抛弃不进行训练,大大加快了训练速度和检测速度.图 2 中最大值池化为对邻域内特征点取最大,LPN 层的作用是对局部输入区域进行归一化,ROI 池化层的作用为对输出的多个矩形框进行池化.经过卷积的特征图进入两个全连接层进而输出分类结果和坐标框,到此卷积神经网络完成了对工件内部零件的分类.




图2 卷积神经网络训练、分类流程

3.3 基于 CT 正弦投影的零件定位

基于 CNN,仅能完成零件有无的识别及识别零件的位置信息,对于零件的错装、错位、换位无法有效识别,需进一步研究零件的位置识别.按照 CT 旋转成像原理,零件投影数据呈正弦分布,如此在 CNN 识别的零件坐标信息的基础上,分别以检测图像中各个零件坐标信息与合格工件中对应零件坐标信息进行匹配.若得到匹配图像,则将检测工件投影与当前检测工件投影角度相符的合格工件投影进行比对完成换位检测;若无结果,则说明该零件有可能出现位移、换位故障,继续将检测工件中其它零件坐标信息与标准工件相对应零件坐标信息进行匹配,直到找出相符合角度投影进行零件位置对比,完成零件位移检测,匹配流程如图 3 所示.




图3 检测图像与标准工件角度匹配流程

4 实验及分析

4.1 数据集构造

获取投影数据所采用的 CT 系统为 YXLON FF20, CT 射线源到实验物体的距离为 550mm,实验物体到探测器的距离为 200mm.射线管电压为 170kV,管电流为 60 μ A.将实验工件置于旋转台上并带动其旋转,开启射

线源采集投影数据. 本文间隔 0.5° 进行一次采样, 获得 720 幅投影图像, 并通过翻转平移, 灰度变化, 随机裁剪等方法增大数据集. 将投影数据分为训练集, 验证集和测试集, 用训练集训练网络参数, 验证集调节网络超参数, 测试集测试模型分类效果. 同时, 取出工件中的几个零件, 并进行零件换位作为模拟的不合格件, 测试算法检测效果, 在随机方位下成像作为测试图像, 内部 10 个零件定义及投影数据训练集如图 4, 图 5 所示.

图4 自制工件内部零件类名定义



图5 投影数据训练集

4.2 仿真装配识别实验

对训练图像集中工件内部零件进行标定, 作为样本真值框. 实验环境的配置选取 Win7 64 位 + Cuda 7.5 + VS2013, 同时选取 caffe 深度学习框架 + Quadro m4000 显卡训练实验数据集, 分类模型训练完成后用测试图像测试模型的分类效果. 将未参与训练的检测图像(包括 10 个零件装配正确的合格工件和零件缺失的不合格件)代入训练好的卷积神经网络模型, 进行上述工件内部零件分类过程, 实验结果如图 6、图 7 所示.




图6 合格工件检测结果

将检测图像代入训练好的卷积神经网络模型, 分类器逐个对检测图像中的零件进行类别判定. 图 6(a) 为单一零件的分类结果, 框体为对目标零件的定位结果, 框上方的文字代表该类类名, 数字表示定位零件与该类的符合程度. 当工件内部 10 个零件装配正确时, 模

型会对工件内部 10 个零件进行检测, 完成分类, 如图 6(b) 所示. 当工件内部零件出现缺漏, 模型会对剩余零件进行分类, 并将检测图像中未检测到的类作为缺漏零件类型进行报错, 将工件检测为故障件, 如图 7 所示.




图7 内部零件缺失不合格件检测结果

在检测过程中, 如果当前采集角度下工件内部零件遮挡过于紧密, 模型很可能出现分类错误的情况, 不能精确定位零件, 如图 8(a) 所示. 在这种情况下, 只需要将工件旋转 90° , 采集当前角度下工件投影进行检测. 在两个角度下利用 CT 采集投影数据, 对内部零件分类定位, 就会避免模型的误分类, 如图 8(b) 所示. 然而, 在实际产品的检测过程中, 零件的遮挡情况并没有自制工件这么严重, CNN 模型会展现出很好的分类效果.




图8 两个角度下进行检测

根据 3.3, 当转台带动工件旋转, 射线源采集到的图像序列中物体呈现正弦分布状态, 因此任一角度下采集的检测工件投影总能在标准工件投影数据集序列中找到与之角度相符合的一副或几幅图像(零件轻微位移引起的偏差). 基于此, 在完成工件内部零件缺失检测后, 以检测网络输出的检测工件内部零件坐标信息作为输入, 与样本工件零件坐标数据库进行匹配, 找到当前角度下与之对应的标准工件投影图像, 并进行比对, 判断工件内部零件是否有移位、换位等缺陷, 实验结果如图 9 所示.

在这组实验数据中, 首先对检测工件进行零件分类并完成缺漏检测, 检测结果: 缺少定义为“part1”的零件(图 9(a), 不同颜色框代表不同类, 文本框为相应零件类名及此零件与训练模型的符合程度). 在卷积神经网络完成缺漏检测后, 以工件中零件坐标信息为匹配准则, 将检测算法分类的标识框坐标与标准工件内零



(a) 分类结果 (b) 匹配结果




(c) 换位检测

图9 当前角度检测图像匹配标准工件相同角度图像

件坐标进行匹配,得到匹配结果(图9(b)).进而将检测工件投影与匹配得到的对应角度标准工件投影进行对比,找出换位的零件(在分类结果的基础上,图9(a)与图9(b)中零件坐标信息对比后仅保留坐标发生较大变化的类),完成工件内部零件换位检测(图9(c)),将内部零件换位、位移件定义为不合格件。

4.3 实际装配识别实验

为了验证正确性检测算法在实际检测过程中的可行性,采用真实产品进行验证.图10为所采用实际产品内部结构的三维可视图(图10(a))和内部零件定义(图10(b)).




(a) 三维可视图 (b) 内部零件定义

图10 实际产品内部结构

正确性检测流程如图11所示,CNN模型在实际产品的检测过程中表现出了很好的分类能力,首先利用CNN模型分类结果输出缺漏零件(图11(a)),进而匹配当前角度的标准工件投影(图11(b)),利用CNN模型的零件定位结果检测换位零件(图11(c)).

4.4 分析与讨论

在上文完成了对自制工件内部零件装配正确性检



(a) 分类结果 (b) 匹配结果 (c) 换位检测

图11 实际产品正确性检测实验

测实验的基础上,采用与以往方法相同的真实产品比对两种特征提取方法,如图12所示。




图12 本文方法与以往方法特征选择对比

在以往的检测方法中,把每个层面看作一种独立且具有单一结构的产品,将单个产品的检测问题转化为对多个产品的并行检测问题,虽然漏检率很低,但误检率很高.对某些产品来说,某些小区域内部零件的位移并不会造成该产品的使用故障(如本实验所采取的实验工件,第一层和第二层的铝珠为非固定零件,有可能产生一定的位移),但以区域为识别特征则会导致该产品检测为故障件,虽然保证了无漏检故障件的刚需,却在很大程度上造成了资源的浪费.与之对比,本文采用以卷积神经网络输入图像提取特征,将产品内的每个零件标记为模型的“感兴趣区域”,先以分类结果判断零件是否缺漏,再以检测框坐标判断零件的位移,在保证识别效率的同时,降低了检测方法的误检率.对




图13 旋转投影检测

于有一定偏差角度的旋转图像,模型也有着较好的泛化能力,如图 13 所示.同时,在检测的过程中,也可以不断将各种不同状态下的检测产品加入训练数据,增强模型的泛化能力,提升分类结果的准确率.

将检测工件投影旋转一定角度后直接代入模型进行检测,CNN 模型依然表现出很好的分类效果,这在一定程度上体现了 CNN 模型具有很强的泛化能力

5 结论

本文提出了一种将卷积神经网络分类识别方法与 CT 系统相结合的检测方法,同时在候选框生成阶段加入 RPN 网络与检测网络共享权值,提高了训练速度和检测效率.首先利用卷积神经网络训练模型对工件内部零件进行分类识别和漏装检测,输出零件分类信息和坐标框;进而基于 CT 射线源生成投影的正弦特性将当前角度下检测工件投影与标准样本工件投影相匹配,完成进一步的零件位移,换位检测,完成整个正确性检测流程.本文采用的检测方法验证了卷积神经网络在位移、尺度、形变上的移不变性,整个系统具有较强的鲁邦性.为了更好的完善整个检测系统,形成一套通用的自动在线检测理论体系,下一步的研究重点将放在对整体发生旋转和位移的工件进行内部零件装配正确性检测.

参考文献

- [1] Pf V D S, Better Imaging: The advantages of digital radiography [J]. Journal of the American Dental Association, 2008, 139(1): S7 - S13.
- [2] Kruth J P, Bartscher M, Carmignato S, et al. Computed Tomography for Dimensional Metrology [M]. CIRP Annals-Manufacturing Technology, 2011, 60(2): 821 - 842.
- [3] Jiang H. Computed Tomography: Principles, Design, Artifacts, and Recent Advances [M]. SPIE-the International Society for Optical Engineering, 2009. 39 - 46.
- [4] Han Y P, Han Y, Wang L M, Pan J X. Development of X-Ray digital radiography automatic inspection system for testing the interior structure of complex [J]. Product. Acta Armentarll, 2012, 33(7): 881 - 885.
- [5] Nebi Gedik, A new feature extraction method based on multi-resolution representations of mammograms [J]. Applied Soft Computing, 2016, 44(c): 128 - 133.
- [6] I. Uroukov and R. Speller, A preliminary approach to intelligent X-ray imaging for baggage inspection at airports [J]. Signal Processing Research, 2015, 4(5): 1 - 11.
- [7] Hinton G E, Salakhutdinov R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504 - 507.
- [8] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [J]. CVPR, 2014: 580 - 587.
- [9] Girshick R. Fast R-CNN [J]. Computer Science, 2015.
- [10] Ren S, He K, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137 - 1149.
- [11] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 60(2): 1097 - 1105.
- [12] Uijlings J R R, Sande KEAVD, Gevers T, et al. Selective search for object recognition [J]. International Journal of Computer Vision, 2013, 104(2): 154 - 171.

作者简介



赵耀霞 女, 1979 年 12 月出生, 山西祁县人, 硕士, 中北大学电气与控制工程学院讲师, 主要从事信号与信息处理、控制工程方面的研究工作。

Email: zhao@nuc.edu.cn



吴桐 男, 1993 年 8 月出生, 硕士研究生, 研究方向为深度学习, 无损检测。

Email: wt_825@qq.com



韩焱 男, 1957 年 6 月出生, 山西文水人, 博士, 中北大学教授, 博士生导师, 主要从事信息感知、图像处理与反演等方面的研究工作。

Email: pc0912@163.com