

# 一种基于图像分类的航空紧固件产品自动分类方法

胡京徽 许鹏

中国航空制造技术研究院 北京 100024

**摘要** 随着我国航空紧固件制造业的高速发展,生产车间流水线上的紧固件制造工艺变得越来越复杂。目前,生产流水线上工段内中不同规格产品的流转停留在人工分类阶段,这种做法不仅耗费人力,还很难满足实时处理分类需求。文中提出一种基于图像分类算法的航空紧固件自动分类方法,设计了一套紧固件图像采集和自动分类实施方案,并根据真实工业数据执行评估实验,评估实验统计了卷积神经网络和 Inception-v3 模型的准确率、查全率、查准率和 F1 值指标。实验结果表明,Inception-v3 的各项评估指标优于卷积神经网络,Inception-v3 模型分类的准确率达到 98% 以上,可以有效对航空紧固件产品实现自动分类。

**关键词:** 航空紧固件;图像分类;卷积神经网络;Inception-v3

中图分类号 TP301

## Automatic Classification of Aviation Fastener Products Based on Image Classification

HU Jing-hui and XU Peng

AVIC Manufacturing Technology Institute, Beijing 100024, China

**Abstract** With the rapid development of aviation fastener manufacturing, the fastener manufacturing process on the production workshop assembly line becomes more and more complicated. At present, the transfer of different fastener products in the production line still stays in the manual work. This method is not only complicated and tiring, but also difficult to satisfy the real-time classification requirement. In this paper, an automatic classification method for aviation fasteners based on image classification algorithms is proposed. A set of fastener image acquisition and automatic classification implementation schemes are designed, and evaluation experiments are performed based on real industrial data. The evaluation experiments count convolutional neural networks (CNN) and Inception-v3 model accuracy, recall, precision and F1-Score. The experimental results show that Inception-v3 is superior to CNN in various evaluation indicators, and the accuracy of Inception-v3 model classification reaches more than 98%, which can effectively realize automatic classification of aviation fastener products.

**Keywords** Aviation fastener, Image classification, Convolutional neural network, Inception-v3

### 1 引言

在我国航空制造业高速发展的推动下,航空紧固件产品的订单需求量逐年攀升。根据对航空制造产业的调研和现场考察,紧固件产品的研制过程具有交付品种类繁多、成品质量要求高、产品检验把关严格和制造工艺流程复杂等诸多特点<sup>[1-2]</sup>。与上述研制特点相对应的是,紧固件需求厂商在定制紧固件产品时,与供货方签订的订单中往往包含产品数量庞大、协商供货周期短、需求产品种类和交付数量变动频繁等特点。航空紧固件制造厂为避免产品的库存积压和过量生产滞销带来的经济损失,往往会改善制造产线,灵活制造需求厂商订单所需的产品,动态调控产线的生产能力<sup>[3]</sup>。

目前,智能化制造车间常见的生产流水线可以同时制造不同规格的航空紧固件产品。根据生产管理的基本原则,一

个生产线的不同制造工序会被划分到不同的工段上。一方面,对于不同工段之间的工序,不同规格的在制品的流转通过工段间的工作交接来人为分配;同一工段之间的工序,由于制造流程具有相关性,不同规格产品的分类无法使用人工方式实现。另外一方面,由于不同规格产品在同种工艺上所需的制造参数存在差异,不同规格产品在生产线上流转需要根据规格分发到与之对应的制造子线上。

图 1 是某类航空紧固件的典型加工工艺简化流程,图中详细展示了紧固件产品从下料到成品入库所经历的各项工艺流程以及在多个工段流转的细节。由图可知,数控加工工段和包装工段所涉及到的工艺关联比较紧密,并且这些工艺已经基本实现了自动化。综上所述,如果实现自动分类出不同规格产品,完成自动分拣不同规格的产品,可以大大提高生产线加工多种类及小批量定制产品的生产能力,减少重复的人

工操作。因此,如何正确且高效地分类不同规格的紧固件产品就成为了一项亟需解决的实际生产问题。

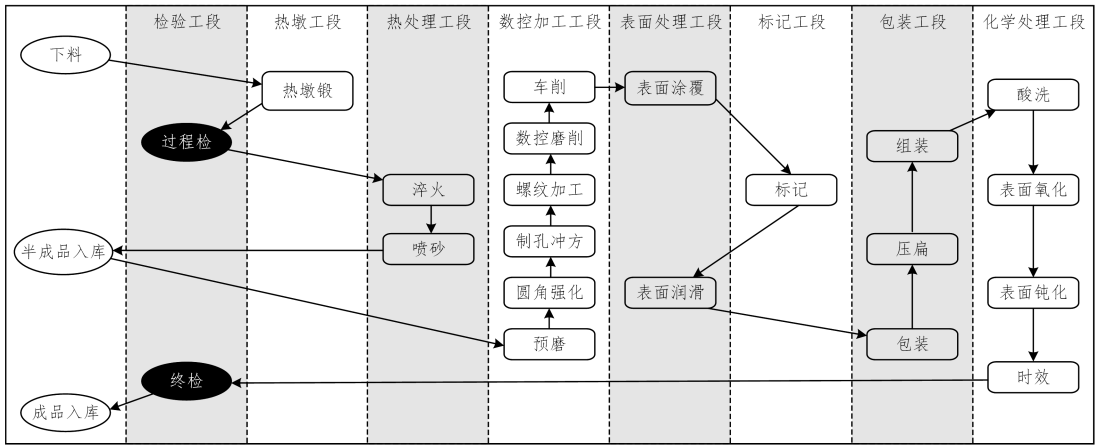


图1 一种典型航空紧固件生产工艺流程图

Fig.1 Typical aviation fastener production process flow chart

## 2 图像分类算法

### 2.1 卷积神经网络算法

1998年,LeCun首次提出卷积神经网络算法,并实现了基于反向传播的多层卷积神经网络的算法<sup>[4]</sup>。2014年,Jia开源了基于GPU计算的开源卷积神经网络计算框架Caffe<sup>[5]</sup>。2016年,谷歌公司开源了支持Python语言的TensorFlow深度学习框架<sup>[6]</sup>。此后,卷积神经网络被广泛运用于图像分类和图像识别等领域<sup>[7]</sup>。

卷积神经网络是一种特殊的神经网络算法,它常用于对图像数据识别分类等一系列实际问题。研究表明,卷积神经网络在此类问题中可以得到比较高的识别准确率。卷积神经网络运用图像离散卷积运算,通过训练集数据对卷积核的参数训练,最终可以得到高效提取图像特征的卷积神经网络模型。本文选用的卷积神经网络除了包含卷积层以外,还使用到了卷积神经网络常用的池化层、dense层和dropout层等,具体参数如表1所列。

表1 卷积神经网络的参数结构

Table 1 Parameters table of CNN

| 类型        | 卷积核   | 步长 | 输入尺寸           |
|-----------|-------|----|----------------|
| conv 卷积层  | 5 * 5 | 1  | 256 * 256 * 3  |
| pool 池化层  | 2 * 2 | 2  | 256 * 256 * 32 |
| conv 卷积层  | 5 * 5 | 1  | 128 * 128 * 11 |
| pool 池化层  | 2 * 2 | 2  | 128 * 128 * 64 |
| dense 层   |       |    | 64 * 64 * 22   |
| dropout 层 |       |    |                |
| 传播层       |       |    | 90 112         |
| 传播层       |       |    | 22 528         |
| softmax 层 | 分类器   |    | 5 632          |

### 2.2 Inception-v3 分类模型

在2014到2015年间,谷歌公司的谷歌大脑小组先后提出了3个版本的Inception模型,分别被称作Inception-v1, Inception-v2, Inception-v3<sup>[8-10]</sup>。这3个版本的Inception模型都在识别准确率上不断优化和改进。

Inception-v3模型的输入是一张任意分辨率的3通道彩色图片,通过对图片进行缩放运算符操作,得到一张299 \* 299分辨率的图片,将其传入Inception-v3的结构中。其中Inception-v3的网络结构包含的层次比较深,它包含了如卷积

层、池化层和线性层等卷积神经网络的常见网络结构。Inception-v3的网络结构比较复杂。本文构建模型的具体参数详见表2中的数据。

表2 Inception-v3 模型参数

Table 2 Parameters of Inception-v3

| 类型               | 卷积核    | 步长 | 输入尺寸           |
|------------------|--------|----|----------------|
| conv 卷积层         | 3 * 3  | 2  | 299 * 299 * 3  |
| conv 卷积层         | 3 * 3  | 1  | 149 * 149 * 32 |
| conv 卷积层         | 3 * 3  | 1  | 147 * 147 * 32 |
| pool 池化层         | 3 * 3  | 2  | 147 * 147 * 64 |
| conv 卷积层         | 3 * 3  | 1  | 73 * 73 * 64   |
| conv 卷积层         | 3 * 3  | 2  | 71 * 71 * 80   |
| conv 卷积层         | 3 * 3  | 1  | 35 * 35 * 192  |
| 3个 Inception1 单元 | 见图2    |    | 35 * 35 * 288  |
| 5个 Inception2 单元 | 见图2    |    | 17 * 17 * 768  |
| 2个 Inception3 单元 | 见图2    |    | 8 * 8 * 1280   |
| pool 池化层         | 8 * 8  |    | 8 * 8 * 2048   |
| linear 线性层       | logits |    | 1 * 1 * 2048   |
| softmax 层        | 分类器    |    | 1 * 1 * 1000   |

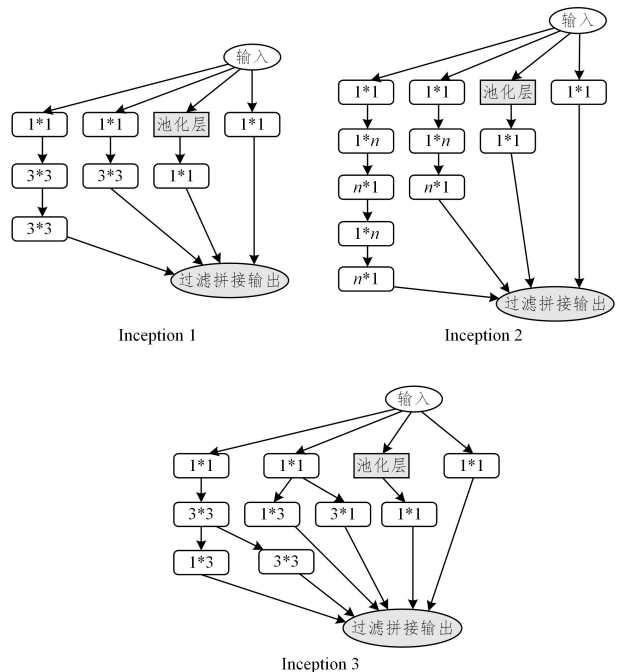


图2 3种 Inception-v3 的结构单元

Fig.2 Three Inception-v3 unit structures

本文构建的模型除了使用了几种通用的卷积神经网络以外,还使用到了3类特殊的结构单元,这3类结构被称作 Inception 结构单元。本文中构建的分类模型网络使用的 Inception 结构单元见图3。在通过 Inception-v3 网络后,已经可以提取到航空紧固件图片的基本特征向量,该输出连接一个全连接层,使用 softmax 回归函数计算各个分类结果的概率,最后通过对比概率值就可以得到分类结果。

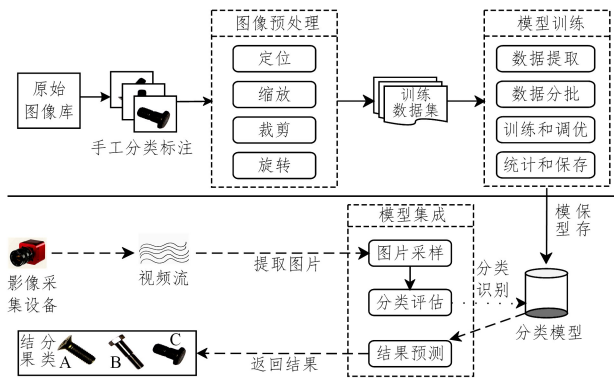


图3 航空紧固件分类训练和识别的总体方案

Fig. 3 Overall design diagram of aviation fastener classification training and identification

### 3 紧固件分类总体方案

本文的设计方案包括图像预处理、模型训练和模型集成3个模块,主要功能包括模型训练和模型集成。首先,方案中建立待分类的航空紧固件产品数字化的图像库,这里称为原始图像库。原始图像库通过手工分类标注的方式对图像标注所属的产品规格,得到待分类的初始产品图像。初始产品图像通过定位、缩放、裁剪和旋转等一系列图像预处理操作,相当于对产品图像进行分类效果增强,最终得到的训练数据集。

本文采用卷积神经网络和 Inception-v3 模型的图像分类技术对上述的数据集进行训练,该部分功能主要包含在模型训练模块中。模型训练模块首先对训练数据集进行数据提取,提取后的数据是结构化的张量。然后,将训练数据集随机分成若干小规模的小批次,使用深度学习的方法进行小批量多次数的重复训练,不断学习。经过多次训练和参数调优得到优化的分类模型,同时统计训练过程中的实验数据,最后保存训练好的分类模型,为后续的紧固件分类提供原始模型支持。

方案中模型集成模块的基本流程是通过训练好的分类模型实时分类不同规格的航空紧固件。首先通过工业相机采集影像数据,得到输入的视频流。然后从视频流采样提取到输入图片,将输入图片进行处理,结果传入分类评估模块。接着,借助训练好的分类模型进行计算,得到输入图片对应的不同种类的预测概率值。最后,取预测概率值最大的种类作为预测结果,完成对紧固件的分类。

## 4 实验与评估

### 4.1 紧固件实验数据集

评估实验使用的数据集主要来源于实际生产的航空紧固件产品拍摄的图像,它包含了30种规格的航空紧固件产品,总计15000多张图像。对每一类产品数量的具体统计如图4所示。




图4 30种紧固件产品实验数据图像数量的统计

Fig. 4 Statistics of 30 kinds of fastener products image data

### 4.2 实验评估指标

评估实验定义的评估指标包括预测的准确率(acc)、宏平均查准率(mAP)、宏平均查全率(mAR)、宏平均 F1 值(mAF)、加权平均查准率(wAP)、加权平均查全率(wAR)和加权平均 F1 值(wAF)<sup>[11]</sup>。各类评估指标的定义如下:

$$acc = \frac{1}{n} \sum_i m_i \tag{1}$$

$$mAP = \frac{1}{n} \sum_i P_i \tag{2}$$

$$mAR = \frac{1}{n} \sum_i R_i \tag{3}$$

$$mAF = \frac{1}{n} \sum_i F_i \tag{4}$$

$$wAP = \frac{1}{n} \sum_i n_i P_i \tag{5}$$

$$wAR = \frac{1}{n} \sum_i n_i R_i \tag{6}$$

$$wAF = \frac{1}{n} \sum_i n_i F_i \tag{7}$$

其中,  $n_i$  是评估实验中第  $i$  种产品的总数量,  $m_i$  是第  $i$  种产品预测结果正确的总数量,  $P_i$  是第  $i$  种产品预测结果的查准率,  $R_i$  是第  $i$  种产品预测结果的查全率,  $F_i$  是第  $i$  种产品预测结果的 F1 得分。

### 4.3 模型训练过程评估

本文基于 Python 3.6 版本的 TensorFlow 1.13.1 实现实验代码并进行评估实验。实验的硬件平台为英伟达 16 GHz 显存的 Tesla V100 GPU 计算显卡。

本实验将模型训练实验数据集进行随机分批训练,每个训练批次选取 200 张图像作为训练输入,一共进行 5000 次迭代训练。训练过程中,每隔 100 代,计算模型在测试集中预测的准确率。

本评估实验一共分成 6 组执行,其中前 3 组使用卷积神经网络构建模型,后 3 组通过 Inception-v3 结构构建训练模型。实验统计得到训练准确率的预测趋势如图 5 所示。




图5 卷积神经网络和 Inception-v3 训练过程的对比

Fig. 5 Training process comparison diagram of CNN and Inception-v3

通过图 5 的对比可以看出,卷积神经网络和 Inception-v3 在训练过程中随着训练代数的增加对紧固件识别的准确率呈现不断攀升的趋势,最终都能达到 90% 的识别准确率。其中,卷积神经网络在识别训练过程中准确率的波动比较大,模型收敛效果不好。另外,Inception-v3 在训练达到 2000 代以后识别准确率基本维持在 95% 以上,比卷积神经网络的准确率高。综上可以说明 Inception-v3 的训练过程更加有效。

表 3 6 组实验评估结果汇总

Table 3 Summary of 6 groups experimental evaluation results

| 组别                 | 准确率<br><i>acc</i> | 宏平均        |            |            | 加权平均       |            |            |         |
|--------------------|-------------------|------------|------------|------------|------------|------------|------------|---------|
|                    |                   | <i>mAP</i> | <i>mAR</i> | <i>mAF</i> | <i>wAP</i> | <i>wAR</i> | <i>wAF</i> |         |
|                    |                   | (单位:%)     |            |            |            |            |            |         |
| 卷积神经网络<br>模型       | 1                 | 87.8674    | 88.4450    | 87.0712    | 86.0471    | 88.6125    | 87.8674    | 86.5460 |
|                    | 2                 | 88.3100    | 93.2379    | 87.2456    | 87.9854    | 93.1066    | 88.3100    | 88.7877 |
|                    | 3                 | 86.6284    | 90.3068    | 86.2241    | 84.8844    | 91.2893    | 86.6284    | 85.9244 |
|                    | avg.              | 87.6019    | 90.6633    | 91.0028    | 86.8469    | 87.6019    | 86.3056    | 87.0860 |
| Inception-v3<br>模型 | 4                 | 98.3778    | 98.2717    | 98.2488    | 98.2445    | 98.4094    | 98.3778    | 98.3788 |
|                    | 5                 | 98.6708    | 98.6582    | 98.6037    | 98.6165    | 98.6965    | 98.6708    | 98.6711 |
|                    | 6                 | 98.2281    | 98.1599    | 98.1110    | 98.1288    | 98.2291    | 98.2281    | 98.2224 |
|                    | avg.              | 98.4256    | 98.3633    | 98.4450    | 98.3212    | 98.4256    | 98.3299    | 98.4241 |

从训练结果可以看出,第 1 组到第 3 组的平均准确率为 87.6019%,第 4 组到第 6 组的平均准确率为 98.4256%,从结果中直观地看出 Inception-v3 模型的准确率优于传统的卷积神经网络。卷积神经网络的准确率相对于 Inception-v3 而言,3 次实验得到的结果数值波动较大,说明传统卷积神经网络模型的稳定性低于 Inception-v3 模型。

在前 3 组的卷积神经网络实验中,查准率、查全率和 F1 值使用宏平均或加权平均进行计算,得到的查全率都低于查准率,说明卷积神经网络模型在测试样本中的部门分类结果没有判定出来,查找到的效率较低。在后 3 组的 Inception-v3 实验中,查准率、查全率和 F1 值波动较小,说明 Inception-v3 可以有效地完成对紧固件的分类。

**结束语** 本文提出了一种航空紧固件的自动分类方法。针对实际工业生产环境产生的数据进行整理训练,并实现了传统卷积神经网络和 Inception-v3 模型的对比,实验表明 Inception-v3 在航空紧固件分类上的各项指标优于传统的卷积神经网络。但目前还存在一定的局限性:1) 本文实验的分类模型选取了 CNN 和 Inception-v3 作为分类依据,接下来可以尝试 VGG, ResNet 和 DenseNet 等分类模型;2) 实验使用的工业数据集来源于历史积累的数据,数据量较少,后续的工作将着重于实时生成的图像,进一步完善分类模型;3) 除了利用数据训练的模型,后续还会考虑使用迁移学习技术来提高分类效率。

**致谢** 本文的实验数据来源于北京航为高科连接技术有限公司的合作项目,非常感谢贵公司提供宝贵的实验环境和对车间现场工艺的耐心讲解。


## 参考文献

- [1] CHEN C, WANG Z X. Applications Status and Development Trends of Intelligent Technology on Metal-Cutting Machine Tools [J]. Aeronautical Manufacturing Technology, 2014, 455(11):52-55.
- [2] LI W Q, LIU F L, RENG C, et al. Manufacturing and Testing of Titanium Alloy Fastener With Large Length-Diameter Ratio

## 4.4 模型测试指标评估

本实验将模型训练实验数据集随机划分成测试集和训练集进行评估。在训练集上进行训练得到分类模型,然后在测试集上测试得到准确率、宏平均和加权平均各个指标的百分率。一共进行了 6 组评估实验,其中前 3 组使用传统的卷积神经网络作为训练方案,后 3 组使用 Inception-v3 模型作为训练方案。评估实验结果汇总如表 3 所列。

- [J]. Aeronautical Manufacturing Technology, 2012, 408(12): 65-67.
- [3] FENG S, CHEN C. Quantitative Study and Improvement of Streamline Balance in Production Workshop of Aviation Fasteners [J]. Aeronautical Manufacturing Technology, 2017, 60(22):66-71.
- [4] LECUN Y, BOTTOU L. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [5] JIA Y, SHELHAMER E, DONAHUE J, et al. Caffe: Convolutional Architecture for Fast Feature Embedding[C]// Proceedings of the 22nd ACM International Conference on Multimedia. 2014:675-678.
- [6] ABADI M, AGARWAL A, BARHAM P, et al. TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems[C]// Proceedings of 12th USENIX Symposium on Operating Systems Design and Implementation. 2016:265-283.
- [7] LITJENS G, KOOI T, BEJNORDI B E, et al. A Survey on Deep Learning in Medical Image Analysis[J]. Medical Image Analysis, 2017, 42(9):60-88.
- [8] SZEGEDY C, LIU W, JIA Y, et al. Going Deeper with Convolutional Networks[C]// CVPR. 2014.
- [9] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift[C]// Proceedings of the 32nd International Conference on International Conference on Machine Learning. 2015:448-456.
- [10] CHRISTIAN S, VINCENT V, SERGEY I, et al. Rethinking the Inception Architecture for Computer Vision [C]// Computer Vision and Pattern Recognition. 2015.
- [11] TSOUMAKAS G, KATAKIS I, VLAHAVAS I. Mining Multi-label Data[M]// Data Mining and Knowledge Discovery Handbook. Boston: Springer, 2009:667-686.



**HU Jing-hui**, born in 1992, master, assistant engineer. His main research interests include intelligent manufacturing technology, search-based software engineering and machine learning.