

板料成形

## 基于卷积神经网络的三维沉孔特征识别及关键参数提取

沈大为<sup>1,2</sup>, 向 华<sup>1,2</sup>, 庄新村<sup>1,2</sup>, 赵 震<sup>1,2</sup>

(1. 上海交通大学 塑性成形技术与装备研究院, 上海 200030; 2. 上海交通大学 模具 CAD 国家工程研究中心, 上海 200030)

**摘要:** 精冲零件的工艺特征识别和关键参数提取是实现精冲工艺设计智能化的关键。针对典型精冲工艺特征——沉孔, 构建了一个以三维 CAD 模型为输入的特征识别和参数提取模型。利用改进的自适应体素化算法, 将基于参数驱动批量生成的沉孔 CAD 模型转化为体素化模型, 建立模型样本数据集; 采用两步法, 分别以工艺特征体素化模型为输入建立基于三维卷积神经网络的沉孔特征识别模型和以沉孔中心截面图像为输入建立基于二维卷积神经网络的参数提取模型, 依次实现了 3 类主要沉孔特征的分类识别和参数提取。经过验证和评估, 所建模型对于沉孔特征类型识别与关键参数提取均有较高的准确率, 可以为精冲工艺的智能化工艺设计提供有力支撑。

**关键词:** 沉孔; 体素化; 卷积神经网络; 特征识别; 参数提取

**DOI:** 10.13330/j.issn.1000-3940.2022.11.011

**中图分类号:** TG386      **文献标志码:** A      **文章编号:** 1000-3940 (2022) 11-0078-09

## 3D countersink hole feature recognition and key parameter extraction based on convolutional neural network

Shen Dawei<sup>1,2</sup>, Xiang Hua<sup>1,2</sup>, Zhuang Xincun<sup>1,2</sup>, Zhao Zhen<sup>1,2</sup>

(1. Institute of Forming Technology & Equipment, Shanghai Jiao Tong University, Shanghai 200030, China;

2. National Engineering Research Center of Die & Mold CAD, Shanghai Jiao Tong University, Shanghai 200030, China)

**Abstract:** Process feature recognition and key parameter extraction of fine blanking parts are the key point to realize intelligent process design for fine blanking. Therefore, for the typical fine blanking feature of countersink hole, a model for feature recognition and parameter extraction was constructed with 3D CAD model as input. Then, using the improved adaptive voxelization algorithm, the CAD model of countersink hole generated in batches based on parameter-driven was converted into a voxelized model, and a data set of model sample was established. Furthermore, the two-step method was used by using the voxelization model of process features as input to establish a countersink hole feature recognition model based on 3D convolutional neural network and using the center cross-section image of countersink hole as input to establish a parameter extraction model based on 2D convolutional neural network, respectively, and the classification recognition and parameter extraction for three main types of countersink hole features were realized in turn. The results show that after verification and evaluation, the established model has high accuracy for the recognition of countersink hole feature types and the extraction of key parameters, which can provide strong support for the intelligent process design of fine blanking process.

**Key words:** countersink hole; voxelization; convolutional neural network; feature recognition; parameter extraction

随着技术的发展与进步, 精冲作为一种先进的板料成形技术, 与挤压、压扁、压沉孔和弯曲等成形工艺相结合形成精冲复合成形技术, 用于直接生产尺寸精度高、剪切面光洁的三维复杂零件, 被广泛应用于汽车制造等领域<sup>[1-2]</sup>。这种发展趋势

使得相应的精冲模具由单工序复合模逐步发展为更为复杂的多工序连续模, 给工艺和模具设计带来了极大的挑战。为减少对设计人员水平与经验的依赖, 研究和开发数字化和智能化的精冲复合工艺设计系统, 已成为精冲技术发展的重要方向<sup>[3-4]</sup>。

对精冲零件工艺特征的识别和关键参数的提取是实现精冲工艺设计智能化的关键, 是工步排样和力能计算的前提和基础。特征识别技术一直是各种板料成形计算机辅助设计系统设计的研究热点。曾顺等<sup>[5]</sup>提出以面为中心, 基于规则和痕迹的混合特

收稿日期: 2021-12-07; 修订日期: 2022-03-08

基金项目: 国家自然科学基金资助项目 (51875351)

作者简介: 沈大为 (1998-), 男, 硕士研究生

E-mail: shdw0120@sjtu.edu.cn

通信作者: 赵 震 (1972-), 男, 博士, 教授

E-mail: zzhao@sjtu.edu.cn

征识别方法,实现箱体类零件的常见制造特征的识别;吕祝星等<sup>[6]</sup>根据零件分块曲面的属性及曲面间的拓扑关系,利用一定的规则实现了覆盖件特征识别;李正旭等<sup>[7]</sup>通过建立几何元素与钣金件内外特征间的规则库来实现钣金件三维模型特征的自动识别。然而这些传统方法均是基于规则来实现识别,缺乏一定的柔性。

近年来,随着以神经网络为代表的深度学习技术的快速兴起,在图像识别领域,相比传统方法,在大数据集的驱动下在识别准确率上已取得了极大的优势。一些学者在零件特征识别领域也开展了相关研究:张禹等<sup>[8]</sup>以零件最小子图作为输入,采用改进的 BP 神经网络实现了零件 Step-NC 制造特征识别;Zhang Z B 等<sup>[9]</sup>采用三维卷积神经网络、基于零件模型体素化数据实现了机加特征的识别;张航等<sup>[10]</sup>利用零件模型的点云数据,基于 PointNet 网络结构搭建了深度学习网络,实现了孔特征可制造性分析。然而,在板料零件特征识别方面,目前的研究还较少。因此,通过研究开发数据驱动的特征识别模型以替代传统的、基于规则的识别模型,并应用于板料成形领域,是十分有意义的。

本文以典型的精冲工艺特征——沉孔为研究对象,提出了一种改进的自适应体素化算法,完成了工艺特征 STL 模型到可用于神经网络输入的体素化模型的转换。使用两步法,分别构建了以工艺特征体素化模型为输入的基于三维卷积神经网络的沉孔特征识别模型和以沉孔中心截面为输入的基于二维卷积神经网络的参数提取模型,实现了 3 类典型沉孔特征的识别和关键参数提取,模型具有较高的准确率,可以为精冲工艺的智能化工艺设计提供有力支撑。

## 1 沉孔特征模型数据集构建

### 1.1 沉孔特征模型分类和关键参数

沉孔,是采用凸模在工件表面压制与凸模形状相似的凹槽的工艺过程,但由于材料沿凸模的径向流动受到限制,往往在沉孔区域会出现明显的鼓形,为了避免这种情况,常采用预冲孔形式与精冲技术相结合<sup>[11]</sup>。精冲复合成形中,典型的沉孔特征主要分为 3 类:柱形沉孔、锥形沉孔和倒圆沉孔,其几何模型如图 1 所示。本文将以此 3 类沉孔特征作为研究的识别对象。

这 3 类典型的沉孔特征虽分类不同,但结构形




图 1 沉孔特征的几何模型

(a) 柱形沉孔 (b) 锥形沉孔 (c) 倒圆沉孔

Fig. 1 Geometric models of countersink hole feature

(a) Cylindrical countersink hole (b) Conical countersink hole  
(c) Fillet countersink hole

态上有所近似,其关键几何参数能够统一为相同的参数进行描述,如图 2 所示。其中, $D$  为沉孔直径, $d$  为预冲孔直径, $H$  为沉孔深度, $S$  为板料厚度。沉孔深度  $H$  和板料厚度  $S$  与沉孔特征的成形工艺存在一定的联系。如果已知  $H$  和  $S$  的取值和沉孔类别,依据一定的工艺规则,可推得该特征的工步排列结果。图 3 为  $0.15 < H/S < 0.40$  以及毛刺在沉孔侧时,锥形沉孔特征成形的工艺排列示例<sup>[12]</sup>。此外,成形力的大小也直接取决于上述 4 个关键几何参数,材料参数可通过文献 [11] 的力能计算模型得到。因此,通过沉孔特征类型及关键参数的识别,基于一定工艺规则,可实现沉孔特征的智能化工艺设计。

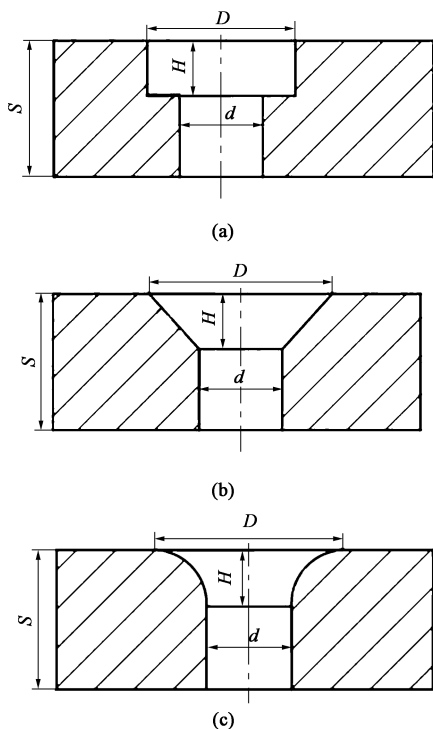


图 2 沉孔特征的关键几何参数

(a) 柱形沉孔 (b) 锥形沉孔 (c) 倒圆沉孔

Fig. 2 Key geometric parameters of countersink hole feature

(a) Cylindrical countersink hole (b) Conical countersink hole

(c) Fillet countersink hole

## 1.2 三维工艺特征模型自适应体素化处理

考虑到模型对于不同商业化 CAD 设计软件的适用性,工艺特征的三维模型统一采用了 STL 通用三维模型数据格式。STL 模型的数据是由 1 组构成模型实体的有向三角面片集合而成,其三角面片的数量、大小和形态取决于具体的三维模型,并不适于作为神经网络模型的输入,需要将模型数据预处理为尺寸一致的结构化数据。本文采用了体素化方法来对三维 STL 模型数据进行预处理,体素化方法是一种能够将三维模型的曲面转化为规则的并且充分保留模型几何结构的最直观的离散方法,其离散体素的结构化数据使得卷积神经网络能够直接从三维形状中进行特征学习。

体素化过程是根据设定的体素分辨率,如  $32 \times 32 \times 32$ ,将三维模型分为多个均匀的单元体的过程,这些均匀的单元体即为体素,在模型外部的体素单元的值为 0,反之为 1。一般来说,体素单元为尺寸为  $l/n$  的立方体(其中,  $l$  为三维模型包围盒的最大边长,  $n$  为指定分辨率),但对于板料零件特征来说,其在板料平面方向上的特征尺寸常会几倍于厚度方向的尺寸,特别是对于本文研究的沉孔特征来




图 3 锥形沉孔特征成形工艺过程

(a) 半冲孔 (b) 冲孔 (c) 落料

Fig. 3 Forming process of conical countersink hole feature

(a) Semi-piercing (b) Piercing (c) Blanking

说,其中一类典型的沉孔深度小于板料厚度的 15%,如果体素单元采用常规的立方体和较小的体系分辨率来进行体素化,可能会导致板料厚度方向的一些特征细节尺寸小于体素单元大小而被忽略,而采用更大的体素分辨率,体素数据量会呈三次方增长,一方面计算代价会很大,另一方面则会导致大量体素单元的值为 0,影响神经网络特征的识别。

为了解决这个问题,特别是针对沉孔特征,提出了一种自适应体素化算法,其核心思想为采用高度方向尺寸自适应的长方体体素单元替代常规的立方体体素单元,如图 4 所示,其中  $k$  为自适应比例系数,其取值是确保在板料特征厚度上的有效体素单元数量不少于阈值,对于沉孔来说,阈值可以取 20,从而不会导致沉孔深度方向特征被忽略。具体的体素化算法流程如图 5 所示。

图 6 为分别采用常规体素化和自适应体素化算法对锥形沉孔特征三维模型进行体素化处理的输出结果。由图 6 可知,相比常规体素化算法,采用自适应体素化算法,当板料厚度相比沉孔直径较小时,




图 4 常规体素单元 (a) 和自适应体素单元 (b) 对比

Fig. 4 Comparison between conventional voxel unit (a) and adaptive voxel unit (b)




图 6 锥形沉孔三维模型体素化结果对比

(a) 常规体素化 (b) 自适应体素化

Fig. 6 Comparison of voxelization results for conical countersink 3D model

(a) Conventional voxelization (b) Adaptive voxelization

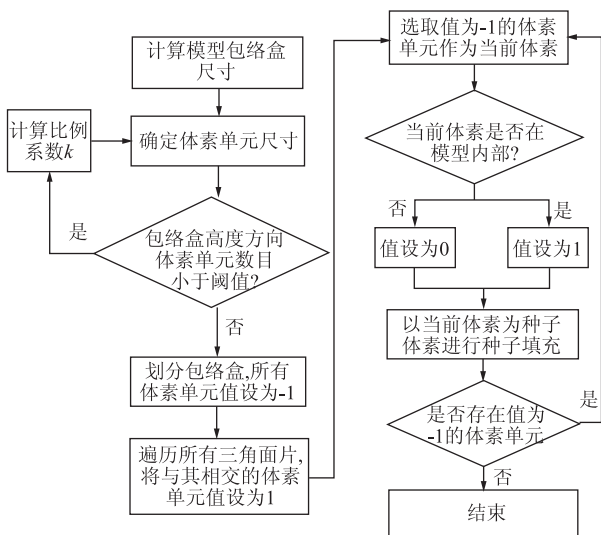


图 5 自适应体素化算法流程图

Fig. 5 Flow chart of adaptive voxel algorithm

可以有效地增加高度方向上的体素单元数量, 放大沉孔高度方向的特征, 避免因沉孔深度过小而在体素化模型中被忽略。虽然生成的体素化模型相比原始模型有一定的变形, 但沉孔特征的特点并未改变, 不会影响识别结果, 而关键参数沉孔深度  $H$  和板料厚度  $S$  可以通过自适应比例系数  $k$  进行还原, 不会影响参数精度。

### 1.3 模型数据样本集构建

神经网络学习需要一个包含大量样本数据的训

练数据集, 而三维 CAD 模型难以获取大数据, 本文采用参数化特征建模的方法, 结合特征的关键几何参数, 批量生成训练网络用的样本数据集。具体而言, 首先, 使用 NX 针对不同的工艺特征分别创建特征零件模板, 并定义模板中主要特征驱动参数; 然后, 建立模板特征驱动参数和关键几何参数间的关联; 最后, 根据关键几何参数取值表, 使用 NX 二次开发相关接口, 批量生成一系列零件的 CAD 模型。沉孔特征关键几何参数的取值范围如表 1 所示, 本文采用上述方法分别生成了 1000 组柱形沉孔、锥形沉孔和倒圆沉孔的三维 CAD 模型, 同时考虑实际板料零件上, 沉孔既可能在板料上表面, 也可能在下表面, 因此, 将生成的 CAD 模型旋转  $180^\circ$  可以得到另外 3000 组特征模型。此外, 为了提高识别可信度, 又批量建立了其他零件工艺特征模型, 包括冲

表 1 沉孔几何参数范围

Table 1 Range of countersink hole geometry parameters

参数	范围
板料厚度 $S/\text{mm}$	3~8
沉孔深度 $H/\text{板料厚度 } S/\%$	10~70
预冲孔直径 $d/\text{mm}$	$\Phi 4 \sim \Phi 24$
沉孔直径 $D/\text{mm}$	$\Phi 8 \sim \Phi 40$



孔、挤压、半冲等 2000 组 CAD 模型, 再将这些 CAD 模型进行体素化处理, 最终得到 8000 组特征体素化模型构成待建立神经网络模型的样本数据集。

## 2 基于三维卷积神经网络的沉孔特征识别

### 2.1 沉孔特征识别模型构建

卷积神经网络作为深度学习的代表算法之一, 具有较强的表征学习能力, 已被广泛用于图像识别、分类和目标检测等领域。目前应用最为广泛的仍为二维卷积神经网络, 而三维卷积神经网络的应用还

较少。考虑本文直接采用三维板料工艺特征 CAD 模型作为识别对象, 因此, 基于三维卷积神经网络构建了沉孔特征识别模型, 其神经网络拓扑结构如图 7 所示, 其中,  $(3 \times 3 \times 3, 8, 2)$  表示 (卷积核尺寸, 数量, 步长),  $(32 \times 32 \times 32, 8)$  表示该卷积层的 (输出尺寸, 通道数量),  $(512)$  表示输出单元数量, 其他参数含义同理。主要是通过构建 3D 卷积核从体素模型学习简单的空间结构, 比如平面、边和角; 再通过叠加多重卷积层级, 进一步允许网络识别三维模型中复杂的工艺特征结构特点; 最后展开成一维向量, 用以表达工艺特征结构的关键信息参数, 并采用全连接层的形式建立起多层神经网络完成工艺特征的分类识别。




图 7 沉孔特征识别模型网络结构图

Fig. 7 Network structure diagram of countersink hole feature recognition model

该沉孔特征识别模型共包含 1 个输入层、4 个卷积层、1 个池化层、2 个全连接层和 1 个分类输出层。输入层为三维体素模型转换的三维矩阵, 其矩阵每项的值为 0 或 1, 需进行零中心化 (Zero-Centering) 预处理, 即将每项的值减去 0.5, 然后乘以 2, 从而将每项的值变为 -1 或 1, 有助于更均衡梯度的存在和更快地收敛<sup>[7]</sup>。考虑精冲工艺特征结构上的稀疏性, 第 1 层和第 2 层卷积层中卷积核的步长为 2, 在保留图像中的关键信息的同时可以有效地减少参数量。池化层采用了最大池化来减少过多参数的过拟合。卷积层和全连接层均采用 Relu 激活函数。最后一个分类输出层的输出分别为非沉孔类和 3 类沉孔特征的概率, 采用了 Softmax 激活函数。

沉孔特征识别模型的建立实质上是通过对三维数据进行特征识别从而进行分类的数学问题, 因此, 训练过程的损失函数采用交叉熵损失函数  $L$ , 如式 (1) 所示。

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^M y_{ic} \lg(p_{ic}) \quad (1)$$

式中:  $N$  为样本总数;  $M$  为类别的数量;  $y_{ic}$  为符

号函数 (0 或 1), 如果样本  $i$  的真实类别等于  $c$  则取 1, 否则取 0;  $p_{ic}$  为观测样本  $i$  属于类别  $c$  的预测概率。

为保证训练效果的有效性并且避免过拟合的发生, 将所获得的特征模型数据集划分为训练集、验证集和测试集, 训练集、验证集和测试集数据量之比为 8 : 1 : 1, 即通过训练集对卷积神经网络模型进行训练, 验证集用于测试所得到的沉孔特征识别模型的泛化能力, 避免过拟合。整个模型基于 Tensorflow 平台并采用 Python 开发实现, 训练的硬件环境为 Intel Core i7 3.2 GHz 四核处理器, 16 GB 内存, NVIDIA GeForce GTX 1080 GPU。

### 2.2 模型参数影响

为了将三维特征 CAD 模型作为卷积神经网络模型的输入, 本文将 CAD 模型进行了离散体素化处理。其中体素分辨率是一个关键参数, 直接影响了沉孔特征识别模型的计算效率和分类精度。与低分辨率体素化相比, 更高分辨率的体素化对 CAD 模型的细节描述更好, 有更高的精度, 然而模型参数会呈指数化增长。为了研究分辨率对沉孔特征识别模型的影响, 分别采用了  $32 \times 32 \times 32$ 、 $64 \times$

64×64 和 128×128×128 这 3 种不同分辨率对特征模型数据集进行体素化处理, 并输入到上述沉孔特征识别模型分别进行了训练和测试, 识别准确率和训练时间的结果如表 2 所示。由表 2 可知, 当体素分辨率提升至 64×64×64 时, 模型识别准确率得到了大幅的提升, 而当分辨率为 128×128×128 时, 由于模型全连接层参数量过大, 识别准确率反而有所降低, 而训练效率随着体素分辨率的增大而大幅下降, 因此, 采用 64×64×64 体素分辨率是比较合适的。

表 2 不同体素分辨率对识别准确率和训练时间的影响

Table 2 Influence of different voxel resolutions on recognition accuracy and training time

体素分辨率	训练集识别准确率	测试集识别准确率	训练时间/s
32×32×32	0.787	0.750	63
64×64×64	0.958	0.941	850
128×128×128	0.945	0.933	15350




图 8 卷积核尺寸 (a) 和数量分布 (b) 对识别准确率的影响

Fig. 8 Influences of convolution kernel size (a) and quantity distribution (b) on recognition accuracy

### 2.3 模型结果评估

通过 2.2 节对比分析, 体素化模型分辨率为 64×64×64、卷积核尺寸为 3×3×3、数量分布为 8-8-16-16 时, 沉孔特征识别模型可以取得较好的结果。基于上述参数, 对建立的沉孔特征识别模型进行了进一步的优化训练, 学习率为 0.001, 优化器为随机梯度下降 (Stochastic Gradient Descent, SGD) 优化, 批次大小设定为 64, 在两层全连接层中设置 Dropout 率为 0.25。图 9 显示了训练集识别准确率和验证集识别准确率随训练次数的变化过程。由图 9 可知, 所构建的沉孔特征识别模型具有较好的收敛性, 整体的训练和验证的识别准确率分别达到了能

此外, 对于卷积神经网络模型来说, 卷积核是最具特性的部分, 其大小决定了局部感受野的大小。局部感受野过小, 提取的特征会超出卷积核的表达范围, 而局部感受野过大, 则无法提取有效的局部特征, 是影响结果的主要因素。图 8 列出了体素分辨率为 64×64×64 时, 不同卷积核尺寸和卷积核数量对沉孔特征识别模型识别准确率的影响。结果表明, 随着卷积核尺寸的逐渐增大, 训练集和测试集的识别准确率逐渐降低, 当卷积核大小取 3×3×3 时, 识别准确率最高, 对于样本集的沉孔特征识别能力最强。而对于卷积核数量来说, 数量过少或过多均会影响模型的识别准确率, 过少时不能进行充分的特征描述, 过多时会产生过拟合现象, 从而导致识别准确率下降。因此, 在设计深度卷积神经网络时, 可逐步调整每 1 层的卷积核数量, 直至获得较为满意的模型识别准确率, 对于本文所建立的卷积网络结构来说, 8-8-16-16 数量分布则较为合适。




图 9 沉孔特征识别的训练曲线

Fig. 9 Training curves of countersink hole feature recognition

0.97 和 0.95 左右, 能满足沉孔特征识别模型的性能要求。

对于沉孔特征识别模型的沉孔特征分类识别结果, 测试集上进一步采用真阳率  $TPR$ 、假阳率  $FPR$ 、真阴率  $TNR$ 、假阴率  $FNR$  和准确率  $Acc$  来评价, 具体结果如表 3 所示。结果表明, 所构建的沉孔特征识别模型对于 3 类沉孔特征的识别准确率均较高, 真阳率分别达到了 0.9760、0.9440 和 0.9300。而倒圆沉孔的真阳率最低, 仅有 0.9300。这是因为倒圆沉孔与锥形沉孔的几何特征在体素数据的表示下部分模型差别较小, 对于识别准确率产生了一定的影响。

表 3 不同沉孔特征的分类识别结果

Table 3 Recognition results for classification of different countersink hole feature

沉孔特征	真阳率 $TPR$	假阳率 $FPR$	真阴率 $TNR$	假阴率 $FNR$	准确率 $Acc$
柱形沉孔	0.9760	0.0090	0.9910	0.0240	0.9780
锥形沉孔	0.9440	0.0320	0.9680	0.0560	0.9732
倒圆沉孔	0.9300	0.0365	0.9635	0.0700	0.9636
非沉孔	0.9520	0.0229	0.9782	0.0417	0.9576

### 3 沉孔特征关键参数提取

#### 3.1 沉孔特征关键参数提取模型

考虑到特征识别和参数提取分别为属于分类和回归问题, 采用单一深度学习模型一步实现沉孔特征的识别和关键参数的提取, 不仅模型结构会更加复杂, 而且也很难保证足够的准确率, 因此, 本文采用了两步法, 第 1 步通过上述建立的沉孔特征识别模型完成沉孔的分类识别, 然后在已确定的沉孔类型的基础上, 通过针对该类沉孔特征建立的参数提取模型, 实现沉孔关键参数的提取。这样可以通过多个神经网络模型替代单一深度学习模型, 不仅简化了模型

结构, 而且模型的更新和重用也更加灵活。

对于待建立的沉孔特征参数提取模型, 输入层同样可采用上一步识别模型所用的体素模型, 然后考虑到 4 个关键几何参数均在中心截面上 (图 2), 因此, 在第 1 步已识别体素模型含有的沉孔特征的基础上, 可以根据沉孔中心截面的特点, 通过扫描算法从体素模型中获取二维的沉孔中心截面图, 并转变为黑白图像作为参数提取模型的输入, 相比直接输入三维体素模型, 会大幅度降低模型的参数量, 提高模型的准确率。

由于 3 类沉孔特征具有一定的相似性, 其关键参数提取模型基于二维卷积神经网络, 采用了相同的拓扑结构, 如图 10 所示, 以锥形沉孔为例, 其他两种沉孔特征模型的建模过程和结果基本一致, 不再一一叙述。沉孔特征参数提取模型共包含 1 个输入层、4 个卷积层、1 个池化层、2 个全连接层和 1 个输出层。输入层为  $64 \times 64$  的中心截面图像, 通过卷积神经网络的卷积层和池化层对沉孔中心截面图像进行区域化特征提取, 得到不同卷积核对应的图像特征, 将其合并展开为一维向量形式, 进一步通过全连接层最终输出沉孔特征结构的 4 个关键信息参数。卷积层、全连接层和输出层均采用 Relu 激活函数。

沉孔特征参数提取模型属于对数据进行回归的一类数学问题, 因此, 将训练过程的损失函数定义为均方根误差  $RMSE$  损失函数, 如式 (2) 所示。训练过程中通过调整深度神经网络模型中的权值和偏置, 使每一迭代步的均方根误差  $RMSE$  逐渐缩小, 最终得到参数提取模型。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (2)$$

式中:  $y_i$  为样本  $i$  的真实沉孔特征关键参数值;  $\hat{y}_i$  为提取的样本  $i$  的沉孔特征关键参数值,  $i = 1, 2, \dots, N$ ;  $N$  为样本总数。

将所获得的特征模型数据集划分为训练集、验




图 10 沉孔参数提取模型网络结构图

Fig. 10 Network structure diagram of countersink hole parameters extraction model



证集和测试集，训练集、验证集和测试集数据量之比为 8 : 1 : 1。

3.2 模型结果和评价

对所建立的沉孔特征关键参数提取模型进行训练，模型取得较好结果。图 11 显示了训练集提取准确率和验证集提取准确率随训练次数的变化过程。由图 11 可知，所构建的沉孔特征关键参数提取模型具有较好的收敛性，在 40 次左右基本收敛，整体的训练和验证的提取准确率分别达到了 0.94 和 0.91 左右，具有较高的提取准确率。




图 11 关键参数提取的训练曲线  
Fig. 11 Training curves of key parameters extraction

在测试集上进一步分别对沉孔直径  $D$ 、预冲孔直径  $d$ 、沉孔深度  $H$ 、板料厚度  $S$  进行提取准确率分析，结果如表 4 所示。由表 4 可知，4 个锥形沉孔关键参数的提取准确率均在 90% 以上，可以满足工程计算需求。其中板料厚度  $S$  的参数提取准确率较高，而沉孔深度  $H$  的参数提取准确率较低，主要是由于沉孔深度相比其他参数，部分模型数值较小，在体素化过程中会损失部分准确率。

表 4 锥形沉孔特征关键参数的提取准确率结果 (%)

Table 4 Extraction accuracy results of key parameters for conical countersink hole features (%)				
关键参数	沉孔直径 $D$	冲孔直径 $d$	沉孔深度 $H$	板料厚度 $S$
提取准确率	93.68	91.53	90.34	96.75

4 应用案例分析

图 12 为精冲实例零件的三维模型，采用所建立沉孔特征识别和参数提取模型进行了应用分析。由于输入的为整个零件模型，这里采用结合连通域和

自适应体素化的孔特征分割算法，先从零件模型上进行了沉孔特征分割。具体思路为：首先体素化整个精冲件，然后采用连通域算法标记孔特征，最后从精冲件上分割标记的孔特征，再二次体素化孔特征为固定分辨率为  $64 \times 64 \times 64$  的体素化模型。分割体素化的孔特征模型如图 13 所示。




图 12 精冲实例零件  
Fig. 12 Example part of fine blanking




图 13 分割的沉孔特征体素化模型  
(a) 特征 1 (b) 特征 2  
Fig. 13 Segmentation voxel model of countersink hole features  
(a) Feature 1 (b) Feature 2

将分割体素化的孔特征模型输入到沉孔特征识别模型中进行识别，识别结果见表 5。由表 5 可知，特征 1 为锥形沉孔的概率达到 99.78%，确定为锥形沉



表 5 沉孔特征识别结果 (%)

Table 5 Recognition results of countersink hole feature (%)

沉孔特征	柱形沉孔	锥形沉孔	倒圆沉孔	非沉孔
特征 1	0.06	99.78	0.14	0.02
特征 2	0.26	0.12	0.06	99.56

孔, 而特征 2 为挤压特征, 识别结果为非沉孔的概率为 99.56%, 与实际相符, 说明识别模型的有效性。

在识别模型确定特征 1 为锥形沉孔后, 特征 1 的体素化模型会进一步输入到锥形沉孔关键参数提取模型, 输出结果如表 6 所示。由表 6 可知, 结果精度基本与表 4 一致, 沉孔深度  $H$  准确率较低, 板料厚度的准确率最高。其中  $H/S$  的结果对于沉孔工序来说最为重要, 模型提取值和实际值分别为 0.264 和 0.287, 根据模型提取值可直接基于规则推理采用图 3 所示的 3 道次工序来实现沉孔特征成形, 满足工艺设计需要。

表 6 特征 1 关键参数的提取结果

Table 6 Extraction results of key parameters for feature 1

关键参数	沉孔直径 $D$	冲孔直径 $d$	沉孔深度 $H$	板料厚度 $S$
实际值/mm	$\Phi 5.00$	$\Phi 3.00$	1.000	3.500
提取值/mm	$\Phi 4.76$	$\Phi 2.76$	0.892	3.377
准确率/%	95.20	92.00	89.20	96.50

## 5 结论

(1) 针对沉孔特征的特点, 提出了自适应体素化算法, 相比常规体素化算法, 当板料厚度相比沉孔直径较小时, 可以有效地放大沉孔高度方向的特征, 避免因沉孔深度过小而在体素化过程中被忽略, 有效地提高了模型准确率。

(2) 基于工艺特征体素化模型和三维卷积神经网络构建了沉孔特征识别模型, 确定了主要模型参数, 经过验证和评估, 所建模型对于柱形沉孔、锥形沉孔和倒圆沉孔这 3 类沉孔特征具有较好的识别准确率, 分别达到 0.9760、0.9440 和 0.9300, 可以满足沉孔特征识别的性能要求。

(3) 基于两步法分别完成沉孔特征识别和参数提取, 在第 1 步确定沉孔特征的基础上, 提出以沉孔中心截面图像作为输入建立了沉孔特征参数提取模型, 有效地减少了模型参数数量, 对于沉孔特征 4 个关键参数均有较高的预测准确率, 可以满足工程计算需求。

## 参考文献:

- [1] 涂光祺. 精冲技术 [M]. 北京: 机械工业出版社, 2005.  
Tu G Q. Fineblanking Technology [M]. Beijing: China Machine Press, 2005.
- [2] 杨泽亚, 杜贵江, 李佳盈, 等. 精冲技术研究现状及发展趋势 [J]. 锻造与冲压, 2020, (16): 16, 18-20.  
Yang Z Y, Du G J, Li J Y, et al. Status and development trend of research on fineblanking technology [J]. Forging & Metalforming, 2020, (16): 16, 18-20.
- [3] Zheng Q D, Zhuang X C, Zhao Z. State-of-the-art and future challenge in fine-blanking technology [J]. Production Engineering, 2019, 13 (1): 61-70.
- [4] Wang Y L, Long H C. A feature-based process planning approach for fineblanking-forming-stamping parts [J]. Advanced Materials Research, 2011, 308-310: 816-819.
- [5] 曾顺, 张璐, 周雄辉. 箱体类零件的特征识别和 CAD/CAPP 集成 [J]. 模具技术, 2013, (4): 12-16.  
Zeng S, Zhang L, Zhou X H. Feature recognition for box-type parts and CAD/CAPP integration [J]. Die & Mould Technology, 2013, (4): 12-16.
- [6] 吕祝星, 宋燕利, 兰箭, 等. 基于 STL 三角网格的汽车覆盖件特征识别方法 [J]. 塑性工程学报, 2017, 24 (4): 124-132.  
Lyu Z X, Song Y L, Lan J, et al. Feature recognition applied to automobile panels based on STL triangular mesh [J]. Journal of Plasticity Engineering, 2017, 24 (4): 124-132.
- [7] 李正旭, 章志兵, 张勋, 等. 基于成形过程的钣金特征识别与工序排配 [J]. 精密成形工程, 2020, 12 (2): 31-36.  
Li Z X, Zhang Z B, Zhang X, et al. Sheet metal feature recognition and process arrangement based on forming process [J]. Journal of Netshape Forming Engineering, 2020, 12 (2): 31-36.
- [8] 张禹, 董小野, 李东升, 等. 基于 STEP 和改进神经网络的 STEP-NC 制造特征识别方法 [J]. 航空学报, 2019, 60 (7): 422687.  
Zhang Y, Dong X Y, Li D S, et al. Method for STEP-NC manufacturing feature recognition based on STEP and improved neural network [J]. Acta Aeronautica et Astronautica Sinica, 2019, 60 (7): 422687.
- [9] Zhang Z B, Jaiswal P, Rai R. FeatureNet: Machining feature recognition based on 3D convolution neural network [J]. Computer-Aided Design, 2018, 101: 12-22.
- [10] 张航, 张树生, 杨磊. 基于深度学习的孔特征可制造性分析方法 [J]. 图学学报, 2021, 42 (1): 117-123.  
Zhang H, Zhang S S, Yang L. Deep learning based manufacturability analysis approach for hole features [J]. Journal of Graphics, 2021, 42 (1): 117-123.
- [11] Schmidt R A, Birzer F, Hofel P, et al. Cold Forming and Fineblanking, a Handbook on Cold Processing, Steel Material Properties, Part Design [M]. Munchen: Carl Hanser Verlag, 2007.
- [12] 周开华. 简明精冲手册 [M]. 2 版. 北京: 国防工业出版社, 1993.  
Zhou K H. Fine Blanking Handbook [M]. 2nd Edition. Beijing: National Defense Industry Press, 1993.