[文章编号] 1003－4684(2026)02-0008-06

基于机器视觉的立铣刀底面磨损在线检测

付 强，朱传军，周紫璇

（湖北工业大学机械工程学院，湖北 武汉 430068）

[摘 要] 为解决实际生产中测量刀具磨损需人工操作、停机检测等问题，实现铣刀磨损状态高效、精准监测，降低加工成本。基于机器视觉技术，搭建刀具磨损图像自动在线采集平台。采集三刃立铣刀底面从全新到完全磨损全生命周期内的高清图像，构建包含 300 幅图像的数据集。对采集的图像依次进行裁剪、旋转校正、对比度增强、去噪等预处理操作，采用 Hough 变换和 Canny 边缘检测提取关键特征，运用融入 ECA-NET 注意力机制改进的 U-Net 算法进行磨损区域分割，进而计算磨损区域平均宽度。在宝鸡 MLV600 加工中心开展切削实验，将监测系统检测的磨损量与工业相机测量结果进行对比，测量偏差小于 0.01 mm，平均误差为 3.82%。加入 ECA-NET 注意力机制后，磨损区域测量值更接近真实值，磨损初期与后期的误差收敛性更好。所提出的基于机器视觉的立铣刀底面磨损在线监测方法准确性高、稳定性好，可有效应用于铣削加工中刀具磨损状态的实时监测，为实际生产提供可靠的技术支撑。

[关键词] 机器视觉；立铣刀底面磨损；在线检测；注意力机制

[中图分类号] TH391.4；TH161 [文献标识码] A

刀具磨损的状态对工件加工精度和表面质量具有重要影响。研究表明，在加工过程中因更换刀具而导致机床停机时间占总停机时间的 20%。过早或过晚更换均会造成材料和成本的浪费，而更换刀具成本约占总成本的 3%～12%[1]。因此，借助有效的刀具磨损监测技术，精准确定刀具最佳更换时间，具有重要的现实意义。

近年来，国内外学者在刀具磨损监测技术领域开展了广泛研究。依据检测原理，刀具磨损监测方法通常可分为间接法和直接法。间接检测方法通过传感器采集与刀具磨损状态相关的信号特征，如电流、切削力、振动和主轴功率等，并建立特征信号与刀具磨损之间的关系模型，实现实时监测[2]。Prakash[3]利用声发射信号可识别微细铣刀的磨损状态，而声发射信号与刀具磨损之间存在一定的关系。Shao[4]研究发现切削功率参数与刀具磨损之间存在密切关系，其中平均切削功率能够有效反映铣刀磨损的变化。Wang[5]利用分布式高斯 ART-MAP(dGAM)网络，通过主轴的力信号实现刀具磨损状态的分类，并采用经验模态分解(EEMD)技术提取振动信号特征，结合最小二乘支持向量机(LS-SVM)对刀具磨损状态进行识别。陈刚[6]使用测力仪和加速度传感器采集加工信息，并通过信号分析和处理提取特征信号，经过特征降维和选择，应用模糊逻辑、神经网络和回归分析等方法对刀具磨损状态进行有效监测。尽管许多学者在相关领域已经取得了成果，然而，间接法通常需要采用专门的测量设备，在实际信号采集过程中，声信号采集成本高、环境噪声大，振动信号易受到噪声与传感器安装位置的影响，切削力信号安装位置不易确定，主轴功率信号存在延迟且灵敏度低，故而间接法检测精度一般低于直接法。

直接测量法基于机器视觉技术，在加工过程中直接对刀具的磨损状态进行监测，以刀具本身作为检测目标，不仅降低了处理海量数据的计算成本，而且测量结果更加准确。HOU[7]提出了一种自匹配算法，采用偏角阈值方法提取切削刃，拟合并计算刀具底部磨损值。Moldovan[8]采用 OTSU 法获取立铣刀待测区二值图像，结合 Sobel 算子识别刀具磨损。LI[9]提出一种用于刀具磨损监测的微视觉系统，通过分水岭变换将刀具磨损区域分割为多个区域，实现自动聚焦与分割，再利用 Markov 算法分割刀具磨损的各个区域。LIU 通过贝叶斯学习，识别出切削刃与磨损位置边界的相关性，并重构原始刀具边界，实现了刀具磨损的高精度估计；构建对应的网络，可有效实现刀具磨损区域提取；引入基于马修

[收稿日期] 2024－11－05

[第一作者] 付 强(2000—)，男，湖北十堰人，湖北工业大学硕士研究生，研究方向为刀具磨损、机器视觉。

[通信作者] 朱传军(1971—)，男，湖北仙桃人，湖北工业大学副教授，研究方向为智能制造、车间调度。

斯相关系数的代理损失函数进行深度监督，有助于解决少样本与数据不平衡问题。

然而，现有直接法研究仍存在一些问题：机加工过程中采集图像通常需要停机，影响加工效率；在线采集的刀具图像旋转角度随机，增加了图像处理的复杂性；立铣刀底面磨损数据集较为匮乏，不利于模型学习与训练。针对上述问题，本研究提出一种基于机器视觉的立铣刀底面磨损监测系统，通过图像预处理、图像分割等技术手段，实现刀具磨损量在线监测。

1　实验平台的搭建

本实验在加工中心进行立铣刀切削实验，搭建的实验平台由硬件部分和软件部分组成，具体结构如图 1 所示。



1－加工中心；2－加工材料；3－三刃立铣刀；4－吹气装置；5－挡板；6－电子显微镜；7－LED 光源；8－控制面板；9－工业计算机

图 1　实验平台

硬件部分由加工中心、加工材料、立铣刀、吹气装置、电子显微镜、LED 光源以及工业计算机组成；软件部分由上位机控制程序和图像采集装置组成。表 1 为具体硬件参数。

表 1　硬件参数

硬件条件	型号和参数
加工中心	宝鸡 MLV600
加工材料	H13 模具钢
铣刀	D12X30X75X3F
电子显微镜	AOSVI 4K 高清相机 3840×2160
LED 光源	HSJS 环形光源

加工中心是采用 Fauc 数控系统，上位机程序使用 C＃编写，通过调用 fwlib32 库实现对加工中心的连接与控制，机床每完成一次加工便到达拍照点，并以固定角度停止，上位机检测到主轴停止运动后调用脚本对铣刀底面进行拍照。主要代码如图 2 所示。

左侧图为机床采集图像的 G 代码，当开始检测时刀具抬起，进行吹气并移动至拍照位置；右侧图像

```
%O0113
G91X220F#1
M7
G91G00Z250
M9
M05
G90G00X385.462
  Y-59.831
G90G00Z40.686
M19
```

```
private void buttom3_Click_1(object sender, EventArgs e)
{
    FanucOpe.ODBST statinfo = new FanucOpe.ODBST();
    short youret = FanucOpe.cnc_statinfo(FanucOpe.h, statinfo);
    if (youret == FanucOpe.EW_OK)
    {
        short run = statinfo.run;
        string shortcutPath = @"E:\Program Files\MII\ImageView\x64\imageview.exe";
        Process process = Process.Start(shortcutPath);
            if (process != null)
            {
                process.WaitForInputIdle();
                Thread.Sleep(100);
                SendKeys.SendWait("{F1}");
            }
    }
}
```

图 2　自动采集程序

为电脑自动采集图像的脚本，接收到刀具到达拍照点的信号后，便自动执行拍照。

图 3 为图像自动采集流程。首先修改机床切削参数与固定拍照点旋转角度，对显微镜进行对焦并用标尺标定；将上位机与机床连接后，在上位机启动程序，铣刀加工后到达拍照点，调用拍照程序进行拍照，采集图像像素为 3840×2160，拍完延迟 2 s，机床再次启动，自动往复循环，直到刀具磨损达到磨钝判据后停止。

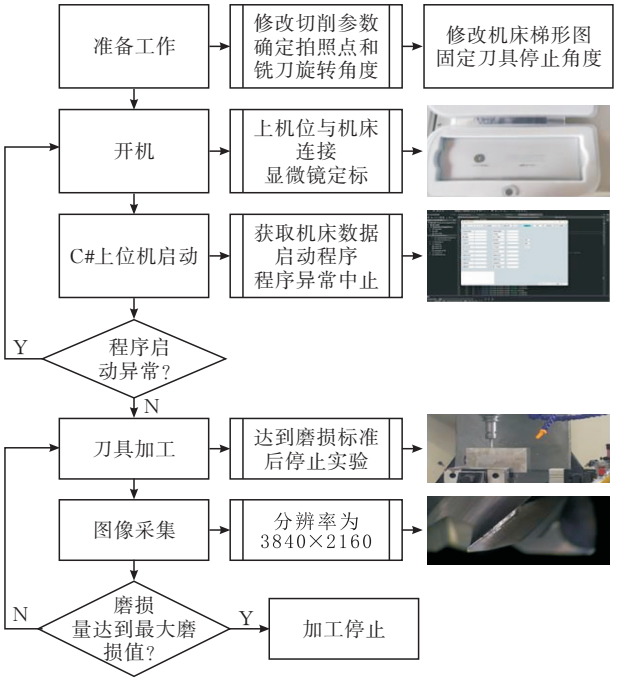

图 3　图像自动采集流程

2　立铣刀底面磨损检测识别

2.1　图像预处理

采集的原始图像包含大量冗余的背景信息。为降低计算量，需对原始图像进行预处理，保留刀具磨损区域后再进行磨损量检测。预处理过程如图 4 所示。

三刃立铣刀底面原始图像大小为 3840×2160，经过两次裁剪，得到尺寸为 260×180 像素的最大磨损刃图像。为便于后续磨损值的测量，需将裁剪后的图像旋转一定角度，使刀刃处于竖直状态。通过霍夫变换检测刀刃左轮廓直线，并计算所需旋转角

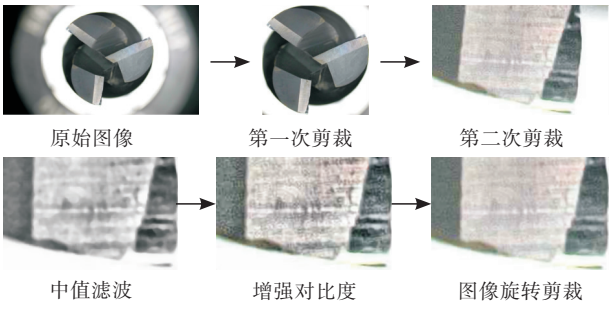

图 4 立铣刀底面磨损

度,然后以图像中心点为旋转中心进行旋转,再裁剪掉边缘失真部分,最终得到240×150尺寸大小的图像。

刀具磨损图像可分为背景区域、刀具磨损区域和刀具非磨损区域。不同区域边界附近的像素灰度差别较大,而区域内像素灰度变化相对平稳。为改善图像视觉效果,采用自适应直方图均衡化(AHE)方法对图像进行对比度增强。不同方法的对比效果如图 5 所示。AHE 变换后,刀具磨损区域像素点灰度值波动范围增大,有效突出了磨损区域与背景区域、非磨损区域之间的反差,有利于后续磨损区域边界的提取。

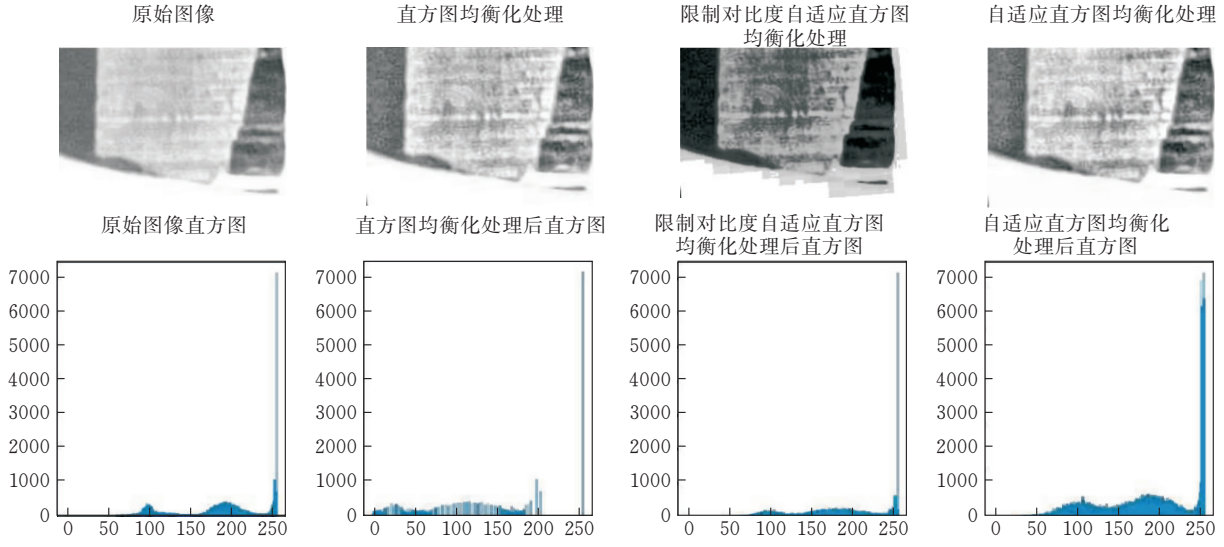

图 5 不同滤波方式

如图 6a 所示,图像中存在大量噪声点,经分析可知为高斯噪声。选择对去除高斯噪声效果较好的中值滤波进行处理。中值滤波的工作原理是在图像中移动一个指定尺寸的滤波窗口,对窗口内的像素值进行排序,并选取中间值作为输出像素值。该方法能够有效去除图像中的噪声,同时保留边缘信息。本研究选择 5×5 尺寸的滤波窗口进行去噪处理。首先将图像转换为灰度图像,减少通道数,降低计算成本,同时更便于噪声检测。处理后的结果如图 6b 所示,图像中噪点得到有效去除。

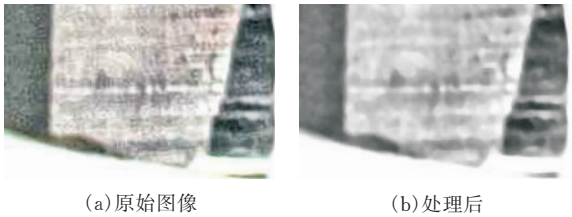

(a)原始图像 (b)处理后

图 6 去噪对比

2.2 磨损区域分割

2.2.1 语义分割网络 编码器-解码器结构的语义分割网络是较早采用全卷积的网络模型,具有编码器-解码器结构和跳跃连接,能够处理不同尺度的特征信息。编码器负责对输入图像进行特征提取和下采样,降低图像的空间分辨率,同时保留重要的语义特征。该网络结构采用卷积层与池化层交替堆叠,通过逐步缩小特征图的尺寸和深度,提取图像的全局特征信息。解码器部分负责对编码器提取的特征图进行上采样和特征融合,恢复图像的空间分辨率,并生成像素级的语义分割结果。通过上采样层和跳跃连接的方式,将编码器不同层级的特征图与解码器对应层级的特征图进行融合,从而提升分割精度。这对于检测不同尺寸和形状的刀具磨损部位非常重要,可以保证检测的鲁棒性和泛化能力。

相比于其他语义分割网络,U-Net 的优点在于能够针对小型数据集进行端到端快速、有效的训练。然而,将模型直接应用在刀具磨损图像的分割上效果不是很好,这主要是由于刀具磨损图像中的磨损部分非常细微,甚至可能被周围的噪声所掩盖。这些细节可能对 U-Net 等网络的分割性能造成影响,加上模型在深层的感受也有限,导致检测精度不高。本文提出一种融入 ECA-NET 注意力机制改进的网络进行刀具磨损图像分割。

2.2.2 ECA-NET ECA-NET(efficient channel at-

tention network)是在 SE-NET 注意力机制基础上进行改进的网络。该方法提出一种不降维的局部跨通道交互策略和一维卷积核的自适应选取算法。采用该方法选取的一维卷积核具有非完全连接特点，仅与部分通道进行卷积，可实现适当的跨通道交互，而非全连接层的全通道交互。其核心思想是通过引入轻量级注意力机制提升卷积神经网络性能。该注意力机制专注于学习通道间的关系，通过对通道间相关性建模来调整特征图中不同通道的权重，从而提高模型图像特征的表征能力。其模块结构如图 7 所示。

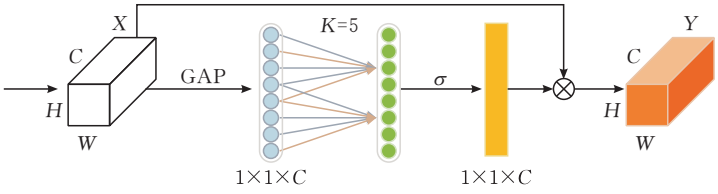

图 7　ECA-NET 网络结构

给定输入特征图 X，其形状为 $C\times H\times W$，其中 C 表示通道数，H 和 W 分别表示特征图的高度和宽度。首先对输入特征图 X 进行全局平均池化操作，将每个通道的特征图转换为一个标量，得到全局平均池化(global average pooling，GAP)结果，其形状为 $C\times1\times1$，具体计算公式如下：

$$X_C=\frac{1}{H\times W}\sum_{i=1}^{H}\sum_{j=1}^{W}X_{cij} \tag{1}$$

然后使用一维卷积操作实现了跨信道的局部交互，以计算每个通道的特征重要程度。卷积核尺寸

$$K=\frac{\log_2 C+1}{2} \tag{2}$$

最后，利用 Sigmoid 函数计算一维卷积输出的激活值，生成表示不同通道特征重要程度的权值。将这些权值乘以原始输入特征，完成每个通道特征的权重更新，得到输出图 Y。

2.2.3　融入 ECA-NET 注意力机制的 U-Net　网络模型如图 8 所示，输入图像为 320×320×1。下采样包含 4 个模块，每个模块由 3×3 的卷积层和 2×2 的最大池化层组成。上采样同样包含 4 个模块，每个模块包括规格为 2×2 的转置卷积，并与下采样 ECA-NET 模块加权的特征映射连接。最后经过一层 1×1 卷积进行降维处理，得到刀刃图像分割图。

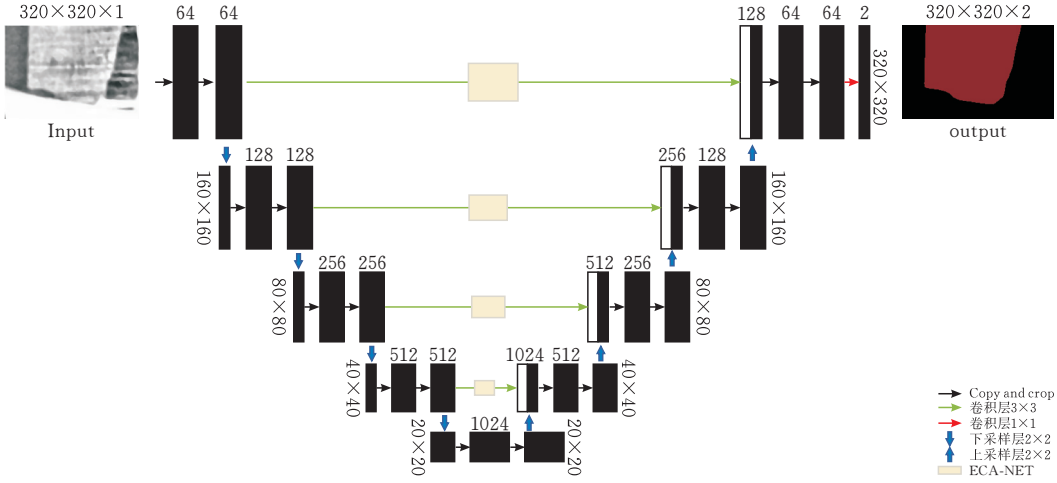

图 8　U-Net 网络结构

2.3　磨损宽度测量

刀具磨损区域右侧经加工磨损已不完整。为便于磨损距离测量，如图 9 所示，选择将刀刃剩余部分分割测量宽度，将初始刀刃的宽度减去剩余部分宽度，得到磨损区域的长度。初始刀刃的宽度固定，由工业相机测量，剩余部分的宽度由 Canny 边缘检测算法计算平均宽度的像素值乘以定标时的分辨率得到。

图中长度单位为 mm，红线的长度表示刀具未磨损的距离，黄线为刀具已磨损的长度。

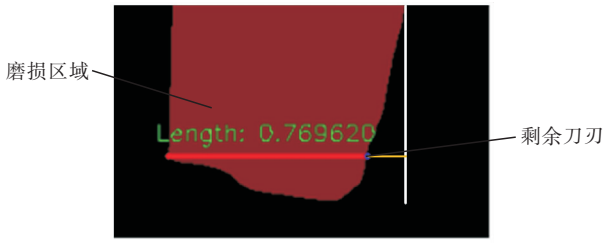

图 9　磨损宽度测量

3 具磨损检测切削实验与结果

3.1 立铣刀磨钝判断

根据 GB/T 16460—2016 表述，由于后刀面磨损量较易测量，因此在刀具磨损研究中，多以后刀面磨损带最大部分的平均磨损量允许达到的最大值 VB(后刀面磨损带平均宽度)＜0.5 mm 作为磨钝判据。

3.2 刀具磨损图像数据集

在加工中心进行三刃立铣刀加工实验，加工参数如表 2 所示。将一把新刀加工至磨钝，共采集 300 幅图像，按 8∶2 的比例，从中随机取 240 幅作为训练集，剩余 60 张为验证集。

表 2 加工参数

主轴转速/($r \cdot min^{-1}$)	进给速度/($mm \cdot min^{-1}$)	加工宽度/mm	切削深度/mm
3500	1500	4	10

3.3 消融实验

为了探究本研究改进措施对模型性能的具体影响，开展了针对模型的消融实验，着重对比添加 ECA 模块前后模型的性能表现。在实验过程中，保持其他实验条件完全一致，包括数据集、训练参数、测试环境等。使用包含 300 幅三刃立铣刀底面磨损图像的数据集，按 8∶2 的比例划分为训练集和验证集。训练过程采用 Adan 优化器，学习率设为 0.001，损失函数选择二分类交叉熵损失，batch size 为 4，迭代次数为 100 轮。

实验结果对比如表 3 所示。

表 3 模型添加 ECA 模块前后性能指标对比

模型	P(精确度)	R(召回率)	mAP@0.5
U-Net	0.852	0.846	0.873
改进后模型	0.954	0.948	0.937

从实验数据可知：添加 ECA 模块后，改进模型在各项指标上有显著提升。准确率从 0.852 提升至 0.954，说明改进模型能够更准确地识别出真正的磨损部分，从而减少误判情况的发生。召回率从0.846 提高到 0.948，表明改进模型能够更好地捕捉到图像所有磨损区域。平均精度均值(mAP@0.5)从0.873 提升至 0.937，进一步证明了改进模型在整体性能上的优越性，即对不同大小和复杂程度的磨损区域都能实现更精准的检测。

本次消融实验充分验证了在模型中添加 ECA 模块的有效性，证明该模块能够显著提升模型对刀具磨损图像的分割和检测能力，为基于机器视觉的立铣刀底面磨损在线检测提供了支持。

3.4 刀具磨损区域测量结果

刀刃剩余部分的测量结果如图 10 所示。加入 ECA-NET 注意力机制后测量值更贴合真实值，磨损初期和后期的误差收敛性更好，平均相对误差由 1.92%降低到 1.68%。

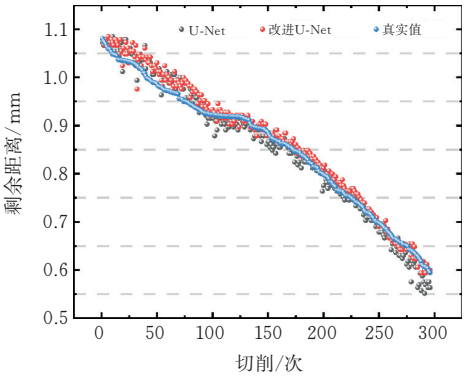

(a)测量刀具剩余距离

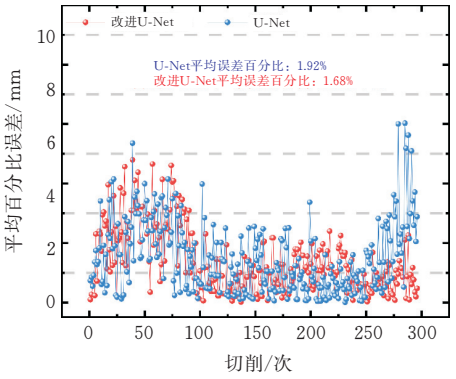

(b)平均误差对比

图 10 刀刃剩余部分测量结果

刀刃实际磨损测量结果如图 11 所示。红色线为真实值，蓝色线为本文方法测量值。可以看出，平均误差整体呈现先上升后下降的趋势。这是因为在磨损初期，磨损量较小，磨损区域不明显，导致测量误差较大；而进入稳定磨损阶段后，误差逐渐减小。总体而言，平均误差控制在 3.82%，表明通过视觉检测系统获取的磨损量具有较高准确度，检测系统的准确性和稳定性良好，能够满足立铣刀在机视觉检测的要求。

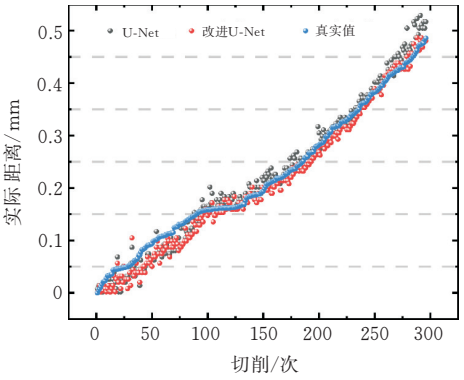

(a)实际磨损值

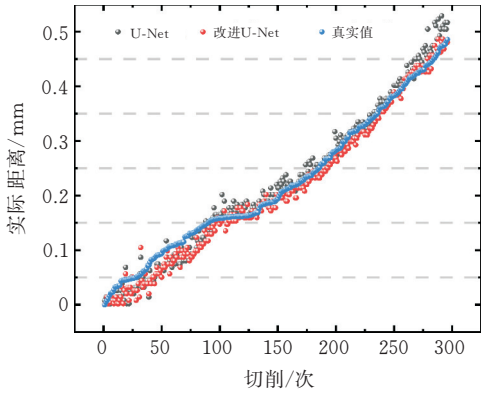

(b)平均误差对比

图 11　刀刃实际磨损测量结果

3.5　实时性验证

研究对刀具磨损检测系统的各个环节进行了时间记录与分析。图像采集环节，由于采用了自动在线采集平台，每次图像采集的时间稳定在 2 s。该平台能够在机床完成一次加工到达拍照点并停止主轴运动后，迅速响应并完成图像采集操作。

图像处理环节，包括图像预处理、特征提取以及磨损区域分割和磨损宽度测量等步骤。整个处理流程平均耗时 32 ms，得益于优化的算法实现和高效的计算资源配置，确保了在短时间内完成复杂的图像处理任务。

从图像采集开始到最终输出刀具磨损量的检测结果，整个系统的平均响应时间为34 ms。这一实时性指标表明，相较于实际加工周期，本研究提出的刀具磨损在线检测方法能够及时反馈刀具的磨损状态，满足立铣刀在机视觉检测的实时性要求，为实际加工过程中刀具的及时更换和加工质量的稳定控制，提供了有力保障。

4　结束语

本研究基于机器视觉技术，提出了一种铣刀磨损状态在线监测方法，并构建了完整的刀具磨损监测系统。该系统由硬件和软件两部分协同构成，硬件负责精准采集刀具后刀面磨损图像，软件则对采集的图像进行深度处理，二者结合共同实现铣刀底面磨损量的自动化检测。这一系统的搭建，为铣削加工过程中刀具磨损状态的实时监测提供了有效的技术手段。

通过开展立铣刀磨损切削实验，对所构建的刀具磨损监测系统的性能进行了全面验证。实验结果显示，监测系统测得的刀具磨损量与显微镜测量值之间的平均误差仅为 3.82%。这一数据充分表明，所设计的监测系统具备较高的精度，能够可靠地应用于铣削加工中刀具磨损状态的实时监测，为实际生产过程中刀具更换时机的精准把握提供了有力支持。

[参　考　文　献]

[1] 中华人民共和国国家质量监督检验检疫总局，中国国家标准化管理委员会. GB/T 16460－2016 立铣刀寿命试验[S]. 北京：中国标准出版社，2016.

[2] 陈高华.切削加工过程中刀具状态的智能监测技术研究 [D]. 太原:太原科技大学,2021.

[3] PRAKASH M，KANTHABABU M，KUMAR A A J，et al. Identification of tool wear status and correlation of chip morphology in micro-end milling of mild steel (SAE 1017) using acoustic emission signal[J/OL]. IOP Conference Series：Materials Science and Engineering,2020,912:032066[2026-03-12]. https://doi.org/10.1088/1757-899X/912/3/032066.

[4] SHAO H H,WANG L，ZHAO X M. A cutting power model for tool wear monitoring in milling[J]. International Journal of Machine Tools & Manufacture，2004，44(14)：1503-1509.

[5] WANG G，GUO Z，YANG Y. Force sensor based online toolwear monitoring using distributed Gaussian ARTMAP network[J]. Sensors Actuators A Phys，2013,192(07):111-118.

[6] 陈刚，焦黎，颜培，等.基于多传感器数据融合的刀具磨损状态监测研究[J].新技术新工艺,2017(11):23-28.

[7] HOU Q，SUN J，HUANG P. A novel algorithm for tool wearonline inspection based on machine vision [J]. The International Journal of Advanced Manufacturing Technology，2019,101(9-12)：2415-2423.

[8] MOLDOVAN O G，DZITAC S，MOGA I C，et al. Tool-wear analysis using image processing of the tool flank[J]. Symmetry，2017，9(12)：296.

[9] LI L H,AN Q B. An in-depth study of tool wear monitoring technique based on image segmentationand texture analysis[J].Measurement,2016,79:44-52.

(下转第 18 页)