

# 基于声发射与关键帧选择的 LSP 表面硬度监测

都正尧<sup>1</sup>, 张志芬<sup>1</sup>, 秦锐<sup>1</sup>, 李耿<sup>1</sup>, 温广瑞<sup>1</sup>, 何卫锋<sup>2</sup>

(1.西安交通大学, 西安 710049; 2.空军工程大学, 西安 710038)

**摘要:** 目的 提高激光冲击强化 (Laser Shock Peening, LSP) 表面硬度的在线检测能力, 探究声发射信号关键帧对 LSP 表面硬度分类识别性能的影响。方法 在 LSP 处理期间声发射弹性波 (Acoustic Emission, AE) 具有与材料内部晶格位错和塑性变形密切相关的动态信息, 是激光冲击强化在线监测的一种极具潜力的手段。但其高采样频率导致大量的实时计算, 对在线监测技术的工业应用提出了巨大的挑战。为解决这一问题, 提出了注意力权重统计方法获取激光冲击强化过程中声发射信号的关键帧。结果 四通道传感器各自的关键帧信号长度相比原始信号的有效长度均大幅度减少, 最大可减少 83.74%, 相比原始数据每一轮测试 (350 个冲击样本), 最大可减少 57.37% 的测试时间。关键帧信号的模型识别准确率最高可达到 97.04%, 相比原始数据集提升了 2.93%。结论 与原始声发射信号相比, 关键帧信号得到了更高的测试准确率, 同时有效地减少了数据量。基于关键帧数据集的最高准确率和最短测试时间, 评价了 4 种不同传感器中信号采集的最佳传感器, 其结果可作为 LSP 质量监测领域的参考。

**关键词:** 表面硬度; 激光冲击强化; 声发射; 关键帧; LSTM

中图分类号: TG668 文献标识码: A 文章编号: 1001-3660(2022)11-0035-10

DOI: 10.16490/j.cnki.issn.1001-3660.2022.11.004

## Surface Hardness Monitoring of Laser Shock Peening: Acoustic Emission and Key Frame Selection

DU Zheng-yao<sup>1</sup>, ZHANG Zhi-fen<sup>1</sup>, QIN Rui<sup>1</sup>, LI Geng<sup>1</sup>, WEN Guang-rui<sup>1</sup>, HE Wei-feng<sup>2</sup>

(1. Xi'an Jiaotong University, Xi'an 710049, China; 2. Air Force Engineering University, Xi'an 710038, China)

**ABSTRACT:** Laser Shock Peening (LSP) is a new technology which can improve the surface hardness of target and change the surface properties of metal materials. It has the advantages of good controllability and high processing efficiency, and is widely used in surface strengthening treatment of key components such as aero-engine blades. In order to overcome the problems of long cycle and low efficiency of off-line methods such as hardness testing, it is urgent to improve the on-line testing ability of laser shock strengthened surface hardness, improve the reliability and consistency of LSP processing quality while improving the quality testing efficiency, and ensure the service performance of aviation equipment. During LSP treatment, Acoustic

收稿日期: 2022-07-14; 修订日期: 2022-10-26

Received: 2022-07-14; Revised: 2022-10-26

基金项目: 国家自然科学基金资助项目 (52175433); 国家科技重大专项 (2019-VII-0019-0161)

Fund: National Natural Science Foundation of China (52175433); National Science and Technology Major Project (2019-VII-0019-0161)

作者简介: 都正尧 (1999—), 男, 硕士研究生, 主要研究方向为激光冲击强化在线监测。

Biography: DU Zheng-yao (1999-), Male, Postgraduate, Research focus: laser shock strengthening on-line monitoring.

通讯作者: 张志芬 (1984—), 女, 博士, 副教授, 主要研究方向激光冲击强化过程监控、金属激光增材制造 (SLM) 质量在线检测等。

Corresponding author: ZHANG Zhi-fen (1984-), Female, Doctor, Associate professor, Research focus: monitoring of laser shock peening process, on-line quality inspection of metal selective laser melting (SLM), etc.

引文格式: 都正尧, 张志芬, 秦锐, 等. 基于声发射与关键帧选择的 LSP 表面硬度监测[J]. 表面技术, 2022, 51(11): 35-44.

DU Zheng-yao, ZHANG Zhi-fen, QIN Rui, et al. Surface Hardness Monitoring of Laser Shock Peening: Acoustic Emission and Key Frame Selection[J]. Surface Technology, 2022, 51(11): 35-44.

Emission (AE) has dynamic information closely related to lattice dislocation and plastic deformation in the material, and it is a promising method for on-line monitoring of LSP. Therefore, we can identify the surface hardness of LSP by exploring the information of AE signal. In this paper, the surface hardness of 7 kinds of samples under different laser energy impacts is collected through off-line characterization experiments, and it is used as the basis for online detection and classification. However, the high sampling frequency of AE signals leads to a large number of real-time calculations, which poses a huge challenge to the industrial application of online monitoring technology. To solve this problem, attention weight statistics (AWS) method is proposed to obtain the key frames of acoustic emission signals during LSP. The time dimension weight of attention mechanism in LSTM model is visualized. After collecting a large number of attention weight samples, we find that some categories of attention weight samples are multi-peak, and multiple peak positions average the weight distribution, while some categories of attention weight samples are single-peak, and the peak positions cover most of the weights. Faced with the different weight distribution characteristics of each category, AWS method can comprehensively reflect the attention weight of each category of AE signals, and can be used as a reference for extracting key frames. Compared with the effective length of the original signal, the four-channel sensor's key frame signal length can be greatly reduced by 83.74% at the maximum, and the test time can be reduced by 57.37% at the maximum compared with each round of testing of the original data (350 AE samples). The model classification accuracy of key frame signals can reach 97.04%, which is 2.93% higher than the original data set. Compared with the original AE signal, key frames set of the signal provide greater test accuracy while effectively reducing the amount of data. Based on the highest accuracy and the shortest test time of key frames set, the best sensors of signal acquisition in four different sensors are evaluated. The method proposed in this paper is affected by the number of experimental samples, and at present it can only represent the detection effect of the network model on the existing data. Although the quantitative results will change with the change of experimental conditions, the method itself has certain universality, and the results can be used as a reference in the field of LSP quality monitoring.

**KEY WORDS:** surface hardness; laser shock peening; acoustic emission; key frame; LSTM

激光冲击强化是一种新型表面强化技术,主要由基体、吸收保护层、约束层和激光器组成。LSP 利用高频率短脉冲激光在短时间内形成高温高压等离子体,进而爆炸产生冲击波。约束层使冲击波在材料内部传播,引起材料的塑性变形和晶格位错<sup>[1]</sup>。LSP 广泛应用于航空发动机叶片,以提高结构的抗疲劳能力和延长使用寿命,在核电工业、生物医学和材料成型等领域也有相关应用<sup>[2]</sup>。

硬度作为材料抵抗变形的一个重要性能,可以通过 LSP 处理来提高,是评价 LSP 处理质量的参数之一<sup>[3]</sup>。表面硬度和硬化深度已被证明能有效提高相应部件的疲劳寿命<sup>[4-5]</sup>。传统的离线监测方法检测周期长,检测效率低,如 X 射线应力测量和维氏显微硬度估计。高周疲劳试验会造成永久性损伤,钻孔应变法为工件打孔并释放局部残余应力,测量材料的横截面硬度需要切断工件,这些方法必然会损伤工件<sup>[6-7]</sup>。因此,迫切需要开发一种可靠、实时、无损的硬度检测方法——LSP 在线监测方法。

学者们目前已经提出了多种在线监测 LSP 的方法,例如振动固有频率<sup>[8]</sup>、等离子体光谱<sup>[9]</sup>、等离子体声波<sup>[10]</sup>、激光功率密度和搭接率<sup>[11]</sup>。然而,其中部分方法并不能避免瞬态强化过程的高度随机性所导致的加工质量的影响<sup>[12]</sup>。另一部分方法受传感器信息传递的影响以及采样频率和环境因素的限制,导致

不能准确反映 LSP 过程中材料内部的变化。在 LSP 过程中,声发射(Acoustic Emission, AE)具有与材料中晶格位错和塑性变形密切相关的动态信息<sup>[13]</sup>,信号采样率高、采样方法方便、环境影响小。因此,声发射可以实时响应 LSP 过程中的材料特性。

2011 年,Deaton 等<sup>[14]</sup>通过计算声发射信号产生和接收之间的时间差来评估 LSP 过程。2016 年,Takata 等<sup>[12]</sup>对声发射传感器的布置进行了优化。选择在水层中放置多个声发射传感器来检测声波在水中的传播,而不是直接在加工零件上安装传感器。这种新的传感器布置方式将不受限于加工零件的几何形状。2018 年,Wu 等<sup>[15]</sup>通过三次方程拟合建立了表面残余应力与声信号能量的经验公式,从而实现了基于声发射信号的 LSP 在线监测。在以往的研究中,学者们试图建立声发射与表面质量的相关性,保证了可靠性和稳定性。然而,声发射技术存在采样频率高的局限性,将导致实时计算量过大,使得在线监测任务沉重。因此,有必要发展一种快速的实时检测方法,从大量的信息中选取信号的关键帧,只保留关键帧进行实时检测和分析,从而减轻数据存储和计算的压力。

关键帧的概念主要应用于视频处理领域,如视频摘要<sup>[16-17]</sup>和运动识别<sup>[18-19]</sup>。在视频识别中由于相似帧的大量存在,对于识别具体动作产生了非必要性。此

外, 关键帧还可以减少每个视频序列在分类上的处理时间。Sima<sup>[20]</sup>对人体运动视频进行时间和空间切片, 对切片图像进行聚类, 根据聚类结果提取关键帧。Elahi 等<sup>[21]</sup>提出了一种在线可学习的视频关键帧提取模块, 并证明了其有效性。Savran Kızıltepe 等<sup>[22]</sup>提出了一种基于识别每帧的信息区域, 并根据区域之间的相似性选择关键帧的方法。上述学者在视频处理领域提取关键帧的方法为研究者提供了参考思路。

对于 AE 信号, 在区分关键帧方面不如视频关键帧明显, 因此从 AE 信号中提取关键帧并解释其物理意义的难度会大大提高。而值得肯定的是, 在声发射信号的时间序列中, 一定存在某一段或几段信号最能反映 LSP 过程中材料特性的变化。

LSTM (Long Short-Term Memory) 网络模型擅长处理时间序列数据<sup>[23]</sup>。目前已应用于机械故障诊断和检测领域, 如齿轮寿命预测和故障诊断<sup>[24-25]</sup>、刀具磨损预测<sup>[26]</sup>、旋转机械故障诊断<sup>[27]</sup>、GTAW 测量<sup>[28]</sup>。

结合注意机制, 进一步提高了 LSTM 网络的分类和预测精度。Vinyals 等<sup>[29]</sup>使用了一种具有注意机制的递归神经网络来生成句子解析树, 并通过可视化注意矩阵来分析句子解析树的生成。Ding 等<sup>[30]</sup>提出了基于注意机制的洪水预报 LSTM 模型 (STA-LSTM)。基于中国 3 个中小流域的实验结果, 证明该网络在大多数情况下优于 CNN 和 GCN。Qin 等<sup>[31]</sup>通过宏微观注意机制对融合特征信息的重要性进行过滤, 使 LSTM 网络数据和递归数据的权重得到多级实时放大, 并以此模型预测齿轮和轴承的剩余寿命, 提高预测精度。

与上述注意机制在 LSTM 网络中的应用不同, 本文将 BiLSTM (Bi-directional Long Short-Term Memory) 注意机制中的时间维度权重可视化, 并将其作为选择声发射信号关键帧的评价标准之一。本文构建了卷积层-BiLSTM-注意力 (C-BiLSTM-A) 网络作为激光冲击强化的在线监测分类模型。依靠卷积层的特征提取功能, 自动提取时间序列信号的特征, 避免了归一化等步骤带来的过程复杂性, 具有抗噪声能力<sup>[32]</sup>。同时, 可以将原始的时间信号序列压缩成更短的时间特征序列, 从而显著缩短网络处理分类问题所需的时间<sup>[33]</sup>。而且在情感分类问题上, 已经证明了 C-LSTM 网络的性能优于 CNN 和 LSTM 单独使用<sup>[34]</sup>。

借助深度学习模型, 本文的主要目标是获取声发射信号的关键帧, 提出 LSP 过程中声发射信号关键帧的选择和评价方法。轻量化的数据可以减轻工业数据存储的压力, 提高在线监测的速度, 这与 LSP 过程的高效密切相关。

## 1 C-BiLSTM-A 模型

C-BiLSTM-A 模型的结构如图 1 所示。该模型可

分为 3 个部分。第一部分, 将原始数据输入一维卷积层, 通过卷积层的特征提取获得时间维特征。第二部分, 卷积层提取的特征通过 Tanh 激活函数进行非线性变换, 输入到 BiLSTM 中。第三部分, 注意力机制在时间维度上对 BiLSTM 的输出赋予注意力权重, 最终通过全连接层变为 7 个概率值。

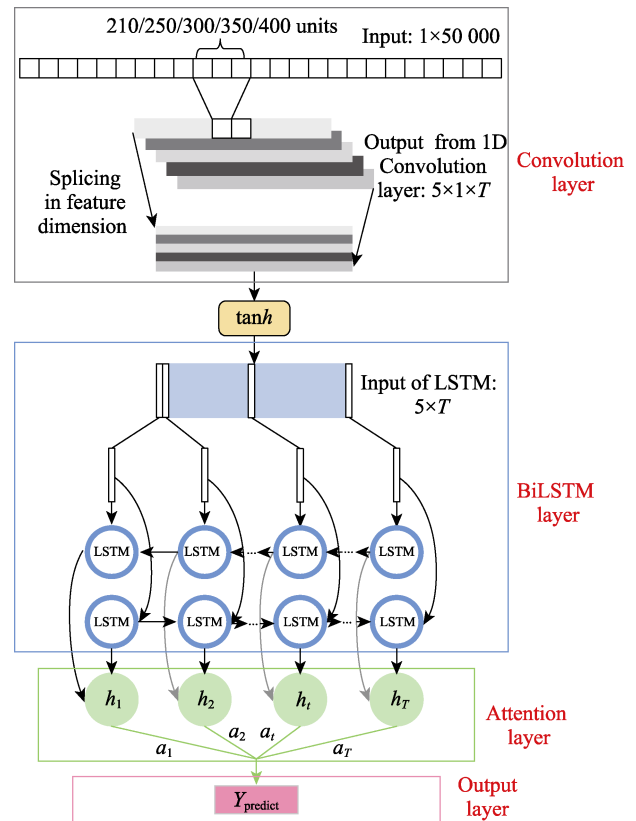


图 1 C-BiLSTM-A 模型简图  
Fig.1 C-BiLSTM-A classification model

### 1.1 时间序列特征提取

在本节中, 构建了 5 个一维卷积层并将其各自提取出的卷积特征保持时间维度不变, 在特征维度拼接, 从而获得不同尺度的声发射信号时间特征, 作为 BiLSTM 网络的输入。5 个独立的一维卷积层都具有相同的步长 (stride 取 200)、不同的卷积核大小 (kernel size 取 210、250、300、350、400)。具有不同核大小的 5 个卷积提取了不同尺度的时间特征, 通过分析不同尺度下的信号获得的特征信息也更加丰富。

### 1.2 BiLSTM-注意力层

在第二部分中, 卷积层输出作为 BiLSTM 网络的输入。BiLSTM 网络的单元与 LSTM 的相同, 包括遗忘门、输入门和输出门。与 LSTM 网络不同之处在于, BiLSTM 网络由前向 LSTM 和后向 LSTM 组成, 能够更好地捕捉双向语义依赖。

如图 1 的第三部分所示,引入了时间维度的注意机制。将 BiLSTM 的隐藏层特表示为  $\mathbf{H}=[h_1, \dots, h_t]$  其中  $t$  为时间步长, 矩阵  $\mathbf{H}$  大小为: (Batch size, 时间步长,  $2 \times \text{LSTM}$  神经元个数)。将  $\mathbf{H}$  放入注意模块可以在不同的时间点赋予特征不同的权重。softmax 函数用于获取注意权重, 如式 (1) 和式 (2) 所示。

$$P = \text{softmax}(\mathbf{H}) \quad (1)$$

$$P = [P_1, \dots, P_t] \quad (2)$$

式中:  $\mathbf{P}$  是权重向量,  $P_t$  是每个时间步长的权重。然后, 将生成的注意力权重乘以相应的隐藏层状态, 如公式 (3) 所示。

$$a = \sum_{t=1}^T P_t \cdot h_t \quad (3)$$

其中,  $a$  为经过注意力权重加权处理之后的 LSTM 隐藏层状态, 此时已经在时间维度上进行求和, 矩阵  $a$  大小为: (Batch size,  $2 \times \text{LSTM}$  神经元个数)。

注意机制加强了重要时间点的信息对最终分类结果的影响, 提高了模型的准确性。而本文更关注的是注意力权重在数据时间维度上的分布, 以此作为判断时间序列中关键帧的标准。

## 2 基于注意力权重统计的关键帧选择

本节提出了一种基于注意力权重统计 (Attention Weight Statistics, AWS) 的声发射信号关键帧获取方法。对实验中采集 7 类声发射数据进行收集之后, 发现相同类别数据的权重分布非常相似, 不同类别之间的权重分布差异较大。图 2 展示了传感器 3 中 3 类样本获取的注意力权重示例, 可以发现部分类别的注意力权重样本呈现多峰状, 多个峰值位将权重分布进行平均化, 而部分类别样本呈现单峰状, 峰值位涵盖了大部分权重。

AWS 的目标在于通过统计的方式得出具有代表

性的关键帧分布, 因此每个类别传达的信息同样重要和有效, 倘若将得到的所有注意力权重样本直接相加, 多峰状样本由于其峰值权重较小, 最终的计算结果将体现不出该类样本的影响。为了尽可能客观地反映每个传感器的注意力权重分布, 提出如图 3 所示的注意力权重统计方法。

将相同类别数据的所有注意力权重样本相加, 如图 3 步骤 1 所示。由于神经网络训练的随机性, 不可能在 2 次训练中获得完全相同的模型, 因此, 在步骤 2 中使用相同的数据训练了 10 个重复的模型, 并在模型测试时存储了所有的注意力权重样本, 所有重复训练的结果相加在一起。

通过上述步骤, 获得了最能代表 7 个传感器数据类别的注意力权重分布的 7 个权重向量, 如图 3 步骤 3 所示。由于某些类别的权重向量峰值不够集中, 其贡献无法体现在直接相加的结果中, 但希望七大类数据所反映的重要位置能够在这个传感器最终的重分布中得到体现。

利用加权求和的思想, 在步骤 3 中对 7 类权重向量的峰值进行放大和归一化。设 7 类权重向量中的任何一类为  $\mathbf{W}=[w_1, \dots, w_t]$ , 其中  $t$  为时间步长。

通过公式 (4) 放大的每个元素的值:

$$Y(i) = W(i) \times \frac{W(i)}{\sum W(i)} \quad (4)$$

其中  $i \in (1, 2, \dots, t)$ ,  $Y(i)$  以  $W(i)$  各点自身之和为权重, 放大各点的值。

$$Z(i) = \frac{Y(i)}{\sum Y(i)} \quad (5)$$

$Y(i)$  由公式 (5) 进行归一化, 以获得输出权重向量  $\mathbf{Z}$ , 并确保  $\sum Z(i) = 1$ 。最后, 将 7 类输出权重向量  $\mathbf{Z}$  相加, 可以得到每个传感器的最终注意力权重分布。

上述过程旨在确保 7 个类别的权重向量同等重要。7 个类别的权重向量的峰值位置信息可以反映在每个传感器的最终注意力权重分布中。




图 2 注意力权重样本示例

Fig.2 Attention weight samples: a) sample of category 1 of sensor 3; b) sample of category 4 of sensor 3; c) sample of category 7 of sensor 3

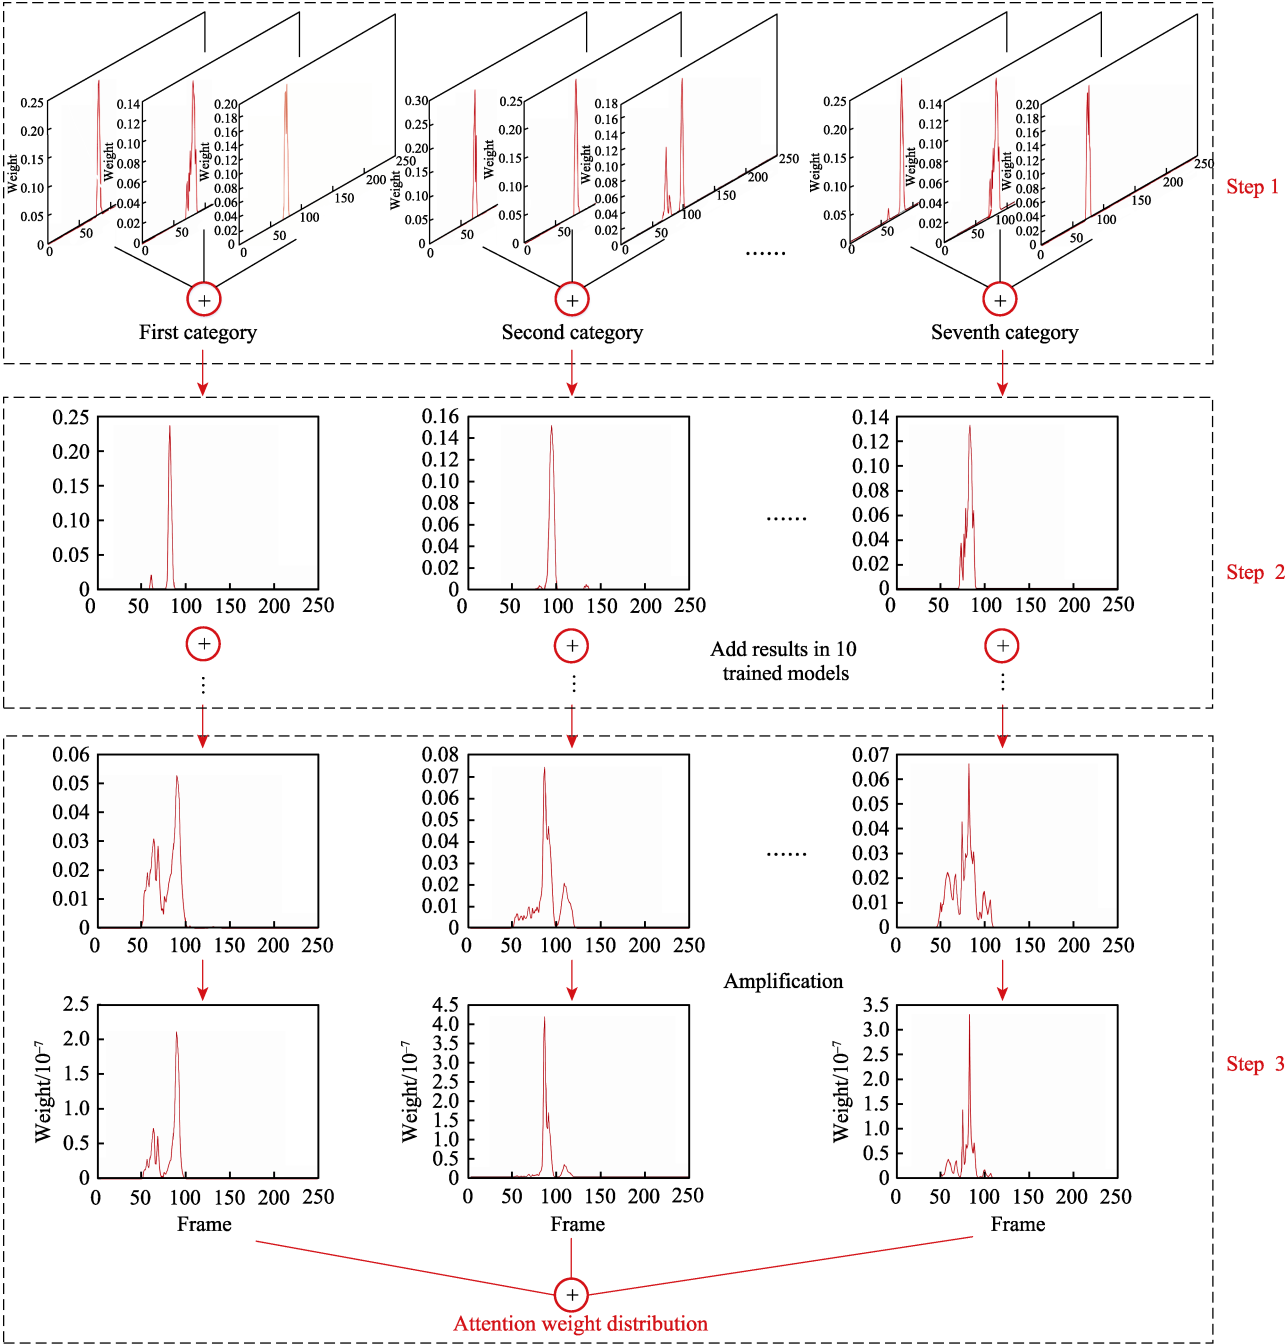


图 3 注意力权重统计法获得一个 AE 传感器的信号关键帧  
Fig.3 AWS method processes the signal samples of one sensor to obtain key frames

### 3 数据和标签的获取

#### 3.1 LSP 实验与声发射信号采集

LSP 加工系统包括六轴联动机器人、夹具、水约束和激光器。在冲击过程中, 激光脉冲能量、光斑直径和搭接率等参数由工控机控制和调整。该加工系统的激光器类型为 Nd:YAG, 加工定位精度小于 0.10 mm, 可实现不同搭接比的多次冲击加工实验。按表 1 所示的实验参数, 沿 S 形冲击路径完成 5×5 正方形冲击区域, 如图 4 所示。

表 1 实验参数  
Tab.1 Experimental parameters

Parameter	Value
Spot lap ratio/%	50
Impact times	25
Spot diameter/mm	3
Repetition frequency/Hz	1
Laser pulsed energy/J	3-5
Wavelength/mm	1 064
Laser pulse width/ns	18






图4 LSP实验设备和传感器分布  
Fig.4 LSP Experimental equipment and sensor location

为了获得 LSP 加工过程中的实时声发射信号, 建立了一个基于声发射信号的 LSP 监测系统。该系统包括声发射传感器、前置放大器、数据采集卡和工业计算机。由于电信号较弱, 采用放大增益为 20 dB 的前置放大器对信号进行放大。信号采集卡采用 DS5-8B 型 2-8 通道便携式声发射采集器, 采样精度为 16 位, 最高采样频率为 10 MHz。在实际实验中, 使用 3 MHz 的采样频率。为了提高声发射信号的信噪比, 在传感器和待处理样品之间涂上一层耦合剂。约束层选用匀速流动的天然水, 吸收层选用厚度均匀的工业黑胶带。

实验材料选用了作为航空航天核心部件理想材料的 7075 铝合金。声发射传感器布置在材料表面, 如图 4 所示, 传感器类型见表 2。其中宽频传感器采集范围为 100 Hz~900 kHz。谐振传感器采集范围为 50 Hz~400 kHz, 中心频率为 150 kHz。为了比较传感器类型与安装方式对网络模型识别的影响, 在本实验中使用了 2 种不同类型的传感器, 宽频传感器和谐振传感器。以往实验数据曾出现 AE 信号幅值溢出测量范围的情况, 因此在其中 2 个传感器前增加 1 个前置衰减器, 其衰减增益为 -20 dB。

表2 传感器类型  
Tab.2 Type of four sensor

Serial number	Sensor type
1	Broadband sensor+Attenuator
2	Broadband sensor
3	Resonant sensor
4	Resonant sensor+Attenuator

### 3.2 LSP 表面硬度表征实验

实验采用 MHVS-1000 自动转塔式显微硬度计, 进行维氏硬度测量。压力为 100 g, 加载保载时间为 15 s。测量路径如图 4 所示, 从冲击区域起始点的中心, 即图中左上角, 沿冲击区域对角线, 测量至冲击区域最终点的中心, 即图中右下角, 每间隔 0.1 mm 测量 1 次。

7 类能量冲击区对应的平均硬度如表 3 所示。随着激光脉冲能量的增加, 样品的平均硬度也呈递增趋势。但由于能量间隔较小, 导致部分类别试样的硬度区分不明显。造成这种情况的主要原因有: (1) 测量设备的测量特性, 导致人为测量误差的存在; (2) 测量路径为冲击区的对角线, 路径上存在不同冲击次数的残余应力层导致硬度测量值呈现波动。

表3 7类试样的平均硬度  
Tab.3 Average hardness of seven kinds of samples

Laser pulsed energy/J	Average hardness(HV)
3.0	211.91
3.4	213.86
3.8	215.25
4.0	216.58
4.2	220.07
4.6	227.73
5.0	230.30

## 4 结果与分析

### 4.1 AE 关键帧提取

如图 5 所示, 步骤 1 和步骤 2 已经完成了 LSP

的在线监测, 这是建立深度学习模型的最终目标。使用模型进行识别或检测之前, 需要训练模型以生成大量的注意力权重样本。在步骤 3 中, 保存了由模型生成的所有注意力权重样本。当模型训练完成后, 将保存的大量样本使用 AWS 方法进行步骤 4 的处理, 从而获取了关键帧的起点和终点, 从而在以后的在线检测中, 直接在步骤 1 采集数据时提取关键帧, 无需存储剩余的数据, 大大减少了数据量与计算量。

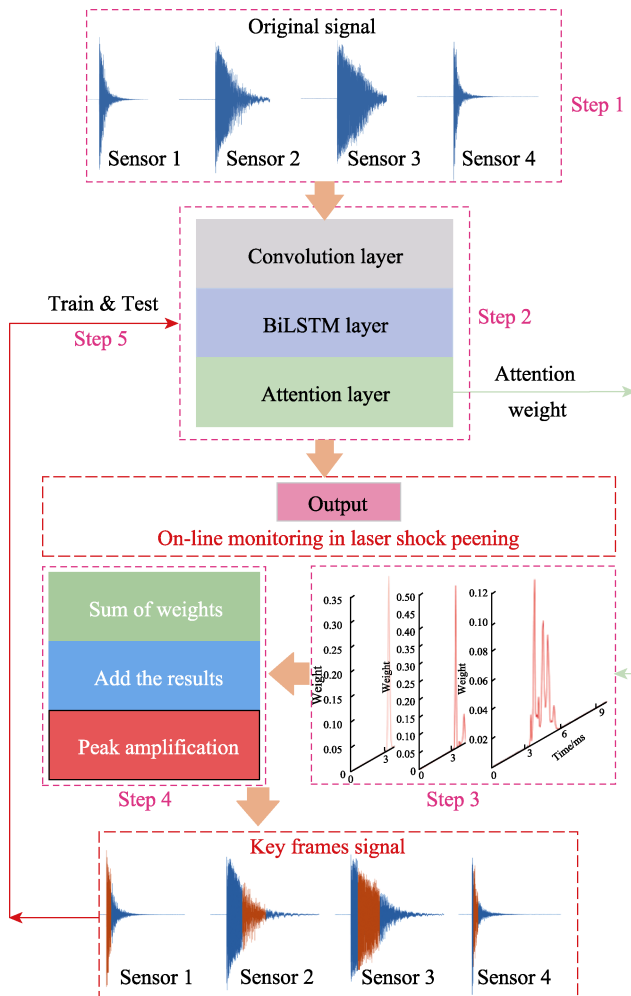


图 5 激光冲击强化在线检测及关键帧提取流程  
Fig.5 Flow chart of LSP on-line detection and key frame extraction

由于原始信号被截断为固定长度, 每个传感器的信号长度为 50 000 个采样点, 存在冗余信息。按照传统的阈值截断方法, 几乎可以保留信号的所有有用信息。该方法的原理是将信号前端和后端幅值超过阈值的第一点作为截断起点和截断终点。由于 4 个传感器采集的信号不同, 所有传感器的前端阈值为 0.01, 传感器 1 和传感器 4 的后端阈值均为 0.1, 传感器 2 和传感器 3 的后端阈值均为 0.4。该方法并非本文的主要研究内容, 且受人为主观因素的影响较大, 不再进一步讨论。

表 4 展示了通过传统阈值截断方法获得的信号

的起点、终点和长度。将该方法得到的信号长度视为原始信号的有效长度, 意味着 4 个传感器信号的有效长度分别为 2.95、7.05、8.28、2.46 ms。

表 4 传统阈值截断法得到的信号截断的起始位置和结束位置

Tab.4 Starting position and ending position of signal truncation obtained by traditional threshold truncation method

Sensor	Start position/ms	End position/ms	Length/ms
1	3.32	6.27	2.95
2	3.08	10.14	7.05
3	2.93	11.21	8.28
4	3.32	5.79	2.46

通过注意力权重统计方法, 获得了 4 个传感器中每个传感器的注意力权重分布, 如图 6 所示。由于添加了衰减器, 传感器 1 和传感器 4 具有更短的信号长度和更集中的注意力权重分布。传感器 2 和传感器 3 的信号长度较长, 注意力权重呈多峰状分布。

通过逐步删除信号两端权重较低的信号片段, 可以将剩余信号片段中的注意力权重保持在  $90\% \pm 5\%$  得到关键帧数据集 1, 如表 5 所示。长度比和权重比的计算公式如下:

$$L_r = \frac{L_k}{L_e} \times 100\% \quad (6)$$

$$W_r = \frac{W_k}{W_e} \times 100\% \quad (7)$$

式中:  $L_r$  为长度比;  $L_k$  为关键帧信号长度;  $L_e$  为信号有效长度;  $W_r$  为权重比;  $W_k$  为关键帧信号权重;  $W_e$  为信号总权重。

在关键帧数据集 1 的基础上, 进一步删除信号两端权重较低的信号段, 使剩余信号段中包含的注意力权重保持在  $60\% \pm 5\%$ , 得到关键帧数据集 2, 如表 6 所示。

## 4.2 关键帧数据集性能

在 4.1 节中, 依据注意力权重的分布获得了关键帧数据集 1 和关键帧数据集 2。本小节将 2 组关键帧数据集输入到 C-BiLSTM-A 模型中进行训练和测试, 在模型准确率 (公式 (8)) 和计算速度方面与原始信号进行比较。其中,  $TP$  表示模型识别为正类样本, 实际也是正类样本;  $FP$  表示模型识别为正类样本, 实际是负类样本;  $FN$  表示模型识别为负类样本, 实际是正类样本;  $TN$  表示 True Negative, 模型识别为负类样本, 实际也是负类样本。

$$acc = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (8)$$

本小节使用的网络模型的参数除数据长度以外均与原始模型相同。进行了与原始数据相同的训练过程之后, 重复训练 10 个相同的模型以获得平均准确率。结果如表 7 所示。

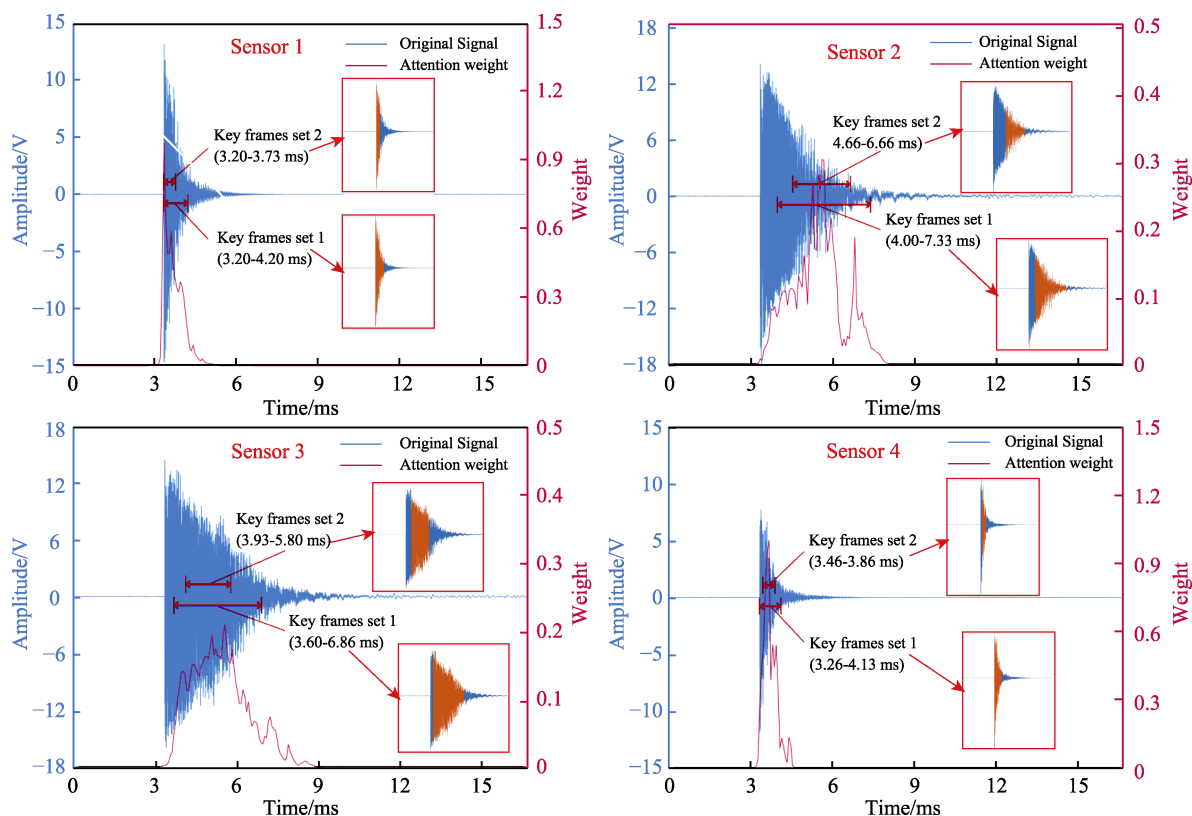


图6 4个传感器的注意权重分布及其关键帧数据集

Fig.6 Attention weight distribution of four sensors and key frame set

表5 关键帧数据集1参数  
Tab.5 Parameters of key frames set 1

Sensor	Start and end position/ms	End position/ms	Length/ms	Length ratio/%	Weight ratio/%
1	3.2	4.2	1	33.89	91.97
2	4	7.333	3.333	47.27	90.32
3	3.6	6.866	3.266	39.44	89.14
4	3.266	4.133	0.867	35.24	92.79

表6 关键帧数据集2参数  
Tab.6 Parameters of key frames set 2

Sensor	Start position/ms	Start and end position/ms	Length/ms	Length ratio/%	Weight ratio/%
1	3.2	3.733	0.533	18.06	62.94
2	4.666	6.666	2	28.36	64.53
3	3.933	5.8	1.866	22.53	62.73
4	3.466	3.866	0.4	16.26	58.71

表7 各个数据集的平均准确率  
Tab.7 Mean accuracy of each data set

Sensor	Original data	Key frames set 1	Key frames set 2	%
1	92.75	93.64	87.61	
2	94.11	95.96	97.04	
3	93.18	93.61	92.29	
4	95.96	95.04	96.96	

在关键帧数据集2中,传感器1的准确率明显下降,比原始数据下降了5.14%,比关键帧数据集1下降了6.03%。这意味着该传感器的有效信息因注意力权重减少而丢失,信号可识别性下降。

与原始数据相比,传感器2的关键帧数据集1的准确率提高了1.85%,关键帧数据集2的准确率提高了2.93%,是4个传感器中提升最大的。传感器3的3个数据集的准确率没有大的变化,差值在1%以内。与原始数据相比,传感器4的关键帧数据集2提高了1%的准确率。

以上现象的产生原因有:(1)传感器2、3、4的信号采集方法,包括传感器的选择与安装是较为合适的;(2)传感器2、3、4的关键帧信号覆盖了时间序列中最重要的分类信息,从而获得较高的识别准确率;(3)衰减器对宽频传感器的信号采集造成了一定的负面影响,即使是原始信号的准确率对比中,传感器1的平均准确率也低于不加衰减器的传感器2。

基于pytorch平台,在Intel(R) Core (TM) i5-10400F CPU @ 2.90GHz和NVIDIA GeForce GT 1030 GPU的测试下,一轮测试(350个AE样本)所需的时间如表8所示。为了突出对比重点,反映模型复杂度以及信号长度对测试时间的影响,本文在此并未关注各个模型之间的准确率差异(这部分工作将在后续实验中完成),可以看出对于相同的传感器数据,RNN模型的时间成本最短,并且随着模型复杂度的增加,测试时间也相应增加。



表 8 一轮测试(350 个冲击样本)的时间成本  
Tab.8 Time cost (s) in one epoch (350 shock samples) of test

Sensor	RNN		LSTM		BiLSTM		BiLSTM-A		Signal
	Set 1	Set 2	Set 1	Set 2	Set 1	Set 2	Set 1	Set 2	
1	0.508 4	0.503 8	0.519 8	0.507 6	0.535 4	0.523 0	0.539 0	0.528 5	1.249 1
2	0.532 4	0.516 5	0.572 0	0.537 5	0.626 0	0.568 8	0.642 1	0.588 2	1.222 3
3	0.535 3	0.517 1	0.570 3	0.536 9	0.620 2	0.569 1	0.632 2	0.578 7	1.252 4
4	0.504 8	0.500 5	0.510 5	0.503 9	0.529 1	0.521 3	0.532 4	0.523 1	1.227 1

关键帧采样点最少的传感器 4 其测试时间最短, 其次为传感器 1。对于 C-BiLSTM-A 模型, 在关键帧数据集 2 的测试中, 传感器 1 的测试时间比原始数据缩短 57.69%, 传感器 2 的测试时间比原始数据缩短 51.88%, 传感器 3 的测试时间比原始数据缩短 53.79%, 传感器 4 的测试时间比原始数据缩短 57.37%。

5 结论

1) 提出了一种基于注意力权重统计的方法, 获得了 LSP 过程中 4 个传感器声发射信号的关键帧。传感器 1 和传感器 4 的关键帧长度较短, 分别只有 0.533 ms 和 0.4 ms, 相比有效长度减少了 81.94%和 83.74%。传感器 2 和传感器 3 没有配备衰减器, 所以关键帧信号稍长, 分别为 2 ms 和 1.866 ms, 相比有效信号长度减少了 71.64%和 77.47%。有效减少 AE 信号占用的存储空间。

2) 将关键帧数据集放入 C-BiLSTM-A 模型进行训练和测试, 传感器 2 和传感器 4 的准确率分别提高了 2.93%和 1%。传感器 3 的准确率变化不明显, 在 1%以内。传感器 1 的准确率降低了 5.14%。传感器 1 的 AE 信号不适合通过提取关键帧的方法进行识别。

3) 采用本文传感器 2 (无衰减器宽带传感器) 或传感器 4 (带衰减器谐振传感器) 的传感方法, 关键帧数据集可以达到较高的准确率, 分别为 97.04%和 96.96%。350 个冲击样本的测试时间分别为 0.588 2 s 和 0.523 1 s, 比原始数据中的 1.222 3 s 和 1.227 1 s 的测试时间分别减少 51.88%和 57.37%。

实验中存在的可变条件例如: 添加衰减器、增大传感器与冲击区域的距离将使得信号高频段衰减增加, 低频段信号幅值明显减小, 关键帧权重分布将集中在 AE 信号起始的快速衰减段。而冲击次数、激光脉冲能量、光斑搭接则通过改变 LSP 加工的残余应力层深度、表面硬度等属性, 通过声发射源对所得到的 AE 信号造成影响。受实验样本数量的限制, 基于关键帧统计方法得到的结论仅代表网络模型对现有数据的学习成效, 虽然定量结果会随实验条件发生变化, 但方法本身仍具有一定的通用性。在今后的工作中, 将采取正交实验验证本文提出的关键帧获取方法的有效性。同时尝试将传感器安装在通

用性更高的位置, 例如安装于实验台夹具, 以探索更具普适性的监测方法, 并满足不同工作条件下的 LSP 加工需求。

参考文献:

[1] MONTROSS C S, WEI Tao, YE Lin, et al. Laser Shock Processing and Its Effects on Microstructure and Properties of Metal Alloys: A Review[J]. International Journal of Fatigue, 2002, 24(10): 1021-1036.

[2] WU Jia-jun, ZHAO Ji-bin, QIAO Hong-chao, et al. Research on the Technical Principle and Typical Applications of Laser Shock Processing[J]. Materials Today: Proceedings, 2021, 44: 722-731.

[3] WU Jia-jun, ZHAO Ji-bin, QIAO Hong-chao, et al. Evaluating Methods for Quality of Laser Shock Processing[J]. Optik, 2020, 200: 162940.

[4] JAMES M N, TING S P, BOSI M, et al. Residual Strain and Hardness as Predictors of the Fatigue Ranking of Steel Welds[J]. International Journal of Fatigue, 2009, 31(8-9): 1366-1377.

[5] LUO Si-hai, NIE Xiang-fan, ZHOU Liu-cheng, et al. High Cycle Fatigue Performance in Laser Shock Peened TC4 Titanium Alloys Subjected to Foreign Object Damage[J]. Journal of Materials Engineering and Performance, 2018, 27(3): 1466-1474.

[6] QIAO Hong-chao. Experimental Investigation of Laser Peening on Ti17 Titanium Alloy for Rotor Blade Applications[J]. Applied Surface Science, 2015, 351: 524-530.

[7] SCHAJER G S, WHITEHEAD P S. Hole-drilling method for measuring residual stresses[M].

[8] DAVIS B M, MCCLAIN R D, SUH U W, et al. Real Time Laser Shock Peening Quality Assurance by Natural Frequency Analysis. 2005-.

[9] WU P P, BENICEWICZ P K, AZER M N. System and Method for Monitoring Laser Shock Processing. 2007-.

[10] WU Jia-jun, LIU Xue-jun, ZHAO Ji-bin, et al. The Online Monitoring Method Research of Laser Shock Processing Based on Plasma Acoustic Wave Signal Energy[J]. Optik, 2019, 183: 1151-1159.

[11] WU Jia-jun, LIU Xue-jun, QIAO Hong-chao, et al. Using an Artificial Neural Network to Predict the Residual Stress Induced by Laser Shock Processing[J]. Applied

- Optics, 2021, 60(11): 3114-3121.
- [12] TAKATA T, ENOKI M, CHIVAVIBUL P, et al. Acoustic Emission Monitoring of Laser Shock Peening by Detection of Underwater Acoustic Wave[J]. Materials Transactions, 2016, 57(5): 674-680.
- [13] WANG H L, SONG D Z, LI Z L, et al. Acoustic Emission Characteristics of Coal Failure Using Automatic Speech Recognition Methodology Analysis[J]. International Journal of Rock Mechanics and Mining Sciences, 2020, 136: 104472.
- [14] DEATON J J B, AZAD F H, AZER M N, et al. Laser Shock Peening System with Time-of-Flight Monitoring[M]. Orlando: Laser Institute of America, 2005: 844-850.
- [15] WU Jia-jun, ZHAO Ji-bin, QIAO Hong-chao, et al. Acoustic Wave Detection of Laser Shock Peening[J]. Opto-Electronic Advances, 2018, 1(9): 18001601-18001605.
- [16] ROCHAN M, WANG Yang. Video summarization by learning from unpaired data[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, CA, USA. IEEE, : 7894-7903.
- [17] WU Jia-xin, ZHONG Sheng-hua, LIU Yan. Dynamic Graph Convolutional Network for Multi-Video Summarization[J]. Pattern Recognition, 2020, 107: 107382.
- [18] SCHINDLER K, VAN GOOL L. Action Snippets: How Many Frames Does Human Action Recognition Require? [C]//2008 IEEE Conference on Computer Vision and Pattern Recognition. Anchorage: IEEE, 2008: 1-8.
- [19] WEINLAND D, RONFARD R, BOYER E. A Survey of Vision-Based Methods for Action Representation, Segmentation and Recognition[J]. Computer Vision and Image Understanding, 2011, 115(2): 224-241.
- [20] SIMA Ming-jun. Key Frame Extraction for Human Action Videos in Dynamic Spatio-Temporal Slice Clustering[J]. Journal of Physics: Conference Series, 2021, 2010(1): 012076.
- [21] ELAHI G M M, YANG Y H. Online Learnable Keyframe Extraction in Videos and Its Application with Semantic Word Vector in Action Recognition[J]. Pattern Recognition, 2022, 122: 108273.
- [22] SAVRAN KIZILTEPE R, GAN J Q, ESCOBAR J J. A Novel Keyframe Extraction Method for Video Classification Using Deep Neural Networks[J]. Neural Computing and Applications, 2021: 1-12.
- [23] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [24] ZHANG Bin, ZHANG Shao-hui, LI Wei-hua. Bearing Performance Degradation Assessment Using Long Short-Term Memory Recurrent Network[J]. Computers in Industry, 2019, 106: 14-29.
- [25] ZHANG Jin-hua, YAN Jie, INFELD D, et al. Short-Term Forecasting and Uncertainty Analysis of Wind Turbine Power Based on Long Short-Term Memory Network and Gaussian Mixture Model[J]. Applied Energy, 2019, 241: 229-244.
- [26] TSIRONI E, BARROS P, WEBER C, et al. An Analysis of Convolutional Long Short-Term Memory Recurrent Neural Networks for Gesture Recognition[J]. Neurocomputing, 2017, 268: 76-86.
- [27] XIA Tang-bin, SONG Ya, ZHENG Yu, et al. An Ensemble Framework Based on Convolutional Bi-Directional LSTM with Multiple Time Windows for Remaining Useful Life Estimation[J]. Computers in Industry, 2020, 115: 103182.
- [28] SHI Jun-chuan, PENG Di-kang, PENG Zhong-xiao, et al. Planetary Gearbox Fault Diagnosis Using Bidirectional-Convolutional LSTM Networks[J]. Mechanical Systems and Signal Processing, 2022, 162: 107996.
- [29] VINIYALS O, KAISER L, KOO T, et al. Grammar as a Foreign Language[J]. Advances in Neural Information Processing Systems, 2014, 9: 589.
- [30] DING Yu-kai, ZHU Yue-long, FENG Jun, et al. Interpretable Spatio-Temporal Attention LSTM Model for Flood Forecasting[J]. Neurocomputing, 2020, 403: 348-359.
- [31] QIN Yi, XIANG Sheng, CHAI Yi, et al. Macroscopic-Microscopic Attention in LSTM Networks Based on Fusion Features for Gear Remaining Life Prediction[J]. IEEE Transactions on Industrial Electronics, 2020, 67(12): 10865-10875.
- [32] LU Wei-jia, JIANG Jie-hui, MA Liang, et al. An Arrhythmia Classification Algorithm Using C-LSTM in Physiological Parameters Monitoring System under Internet of Health Things Environment[J]. Journal of Ambient Intelligence and Humanized Computing, 2021: 1-11.
- [33] LIU Yuan, HUANG Yu-xuan, ZHANG Xue-xi, et al. Deep C-LSTM Neural Network for Epileptic Seizure and Tumor Detection Using High-Dimension EEG Signals[J]. IEEE Access, 8: 37495-37504.
- [34] ZHOU C, SUN C, LIU Z, et al. A C-LSTM Neural Network for Text Classification[J]. Neurocomputing, 2015, 21: 5312.

责任编辑：万长清