

DOI: 10.3901/JME.2021.20.292

# 基于时空全卷积循环神经网络的零件 表面形貌预测\*

邵益平 谭 健 鲁建厦

(浙江工业大学机械工程学院 杭州 310023)

**摘要:** 零件表面形貌预测对于降低产品质量波动和加工成本、减少零件废品率有重要意义。基于高清晰测量数据,提出一种时空全卷积循环神经网络非平稳时空序列预测模型,实现零件加工表面三维形貌的预测。通过计算全局莫兰指数和时间自相关函数进行时空相关性分析,为模型构建准确的输入,并克服传统预测方法未充分利用数据全局特征和局部特征的缺点以及模型输入的随意性。实例研究的结果表明,提出的方法具有更优的综合预测效果,其预测精度优于传统方法12%~18%,预测时间是传统方法的1/5。

**关键词:** 表面预测; 时空相关性分析; 神经网络; 高清晰测量; 非平稳时空序列

**中图分类号:** TH161

## A Spatio-temporal Fully Convolutional Recurrent Neural Network Based Surface Topography Prediction

SHAO Yiping TAN Jian LU Jiansha

(College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310023)

**Abstract:** Surface topography prediction is of great significance to reduce the fluctuation of product quality and processing cost as well as the scrap rate of parts. Based on the high definition metrology (HDM) measured data, a spatio-temporal series prediction model called spatio-temporal fully convolutional recurrent neural network (STFCRNN) is proposed, which achieves the 3D surface topography prediction of machining surface. The time autocorrelation function and global Moran's I are calculated to analyze the spatiotemporal correlation of the surface data, which is used to conduct an accurate input of the model, thereby overcoming the shortcomings of traditional prediction methods that do not make full use of the global and local features of the data and the randomness of model input. Moreover, the result of case study shows that the proposed method has a better comprehensive prediction performance, and its prediction accuracy is 12%-18% better than that of traditional methods and the prediction time is 1/5 of traditional methods.

**Key words:** surface topography prediction; spatio-temporal correlation analysis; neural networks; high definition metrology; nonstationary spatio-temporal series

## 0 前言

机械加工零件的表面形貌是联系设计和制造的纽带,大部分情况下零件的表面形貌直接定义了零

件的表面性能,达到加工预期的表面形貌质量对产品设计功能的实现至关重要<sup>[1-2]</sup>。在机械制造领域,为了获得满意的零件表面加工质量,零件表面形貌预测一直是人们所研究的热点。BENARDOS等<sup>[3]</sup>对零件表面形貌预测方法进行了回顾和总结,将预测方法分为基于加工理论和切削运动学<sup>[4-5]</sup>的理论型方法和基于真实试验数据的试验型方法,其中理

\* 浙江省重点研发计划(2018C01003)和浙江省博士后科研择优(ZJ2021119)资助项目。20210308收到初稿,20210920收到修改稿

论型方法包括考虑刀具振动、主轴安装误差、切削回切现象和多重再生效应等因素影响对加工过程进行建模<sup>[1, 6-8]</sup>, 试验型方法包括光谱分析、回归分析、田口试验设计和机器学习方法<sup>[9-13]</sup>。对于复杂加工表面的预测, 各类加工参数等影响因素无法在单一理论模型上综合体现, 而基于真实数据的试验方法在反映表面形貌形成机制方面更具优势。人工智能方法是试验型方法中的一种, 诸如多层感知机、支持向量机、回归树和随机森林等传统机器学习模型均能完成表面形貌预测任务<sup>[14]</sup>。然而, 传统机器学习模型需要耗费大量时间对数据进行人工的特征提取, 且提取的特征未必适合预测建模, 其灵活性较差<sup>[15]</sup>。深度学习是目前实现预测任务的最有效方法之一<sup>[16]</sup>, 它能实现对原始数据的自动特征提取并学习其变化规律, 克服传统机器学习人工特征提取耗时和不准确的问题, 大幅缩短了开发周期<sup>[17]</sup>。

对于表面形貌预测, 获取大量且完整的表面测量数据是学习表面形貌演化规律的基础, 也是实现准确预测的前提。随着表面计量学的发展, 表面形貌的评价已从粗糙度和波纹度等二维形貌扩展到了三维形貌<sup>[18]</sup>, 故需要更为精密的三维测量数据。近年来, 由 HUANG 等<sup>[19]</sup>提出的一种高清晰测量(High definition metrology, HDM)技术实现了大尺寸、多孔洞零件表面形貌的三维测量(图 1)。HDM 综合了激光干涉和全息匹配技术, 其  $x$ - $y$  方向精度为  $150\ \mu\text{m}$ ,  $z$  方向分辨率为  $1\ \mu\text{m}$ , 测量范围为  $300\ \text{mm} \times 300\ \text{mm}$ , 测量点云数据可达到每平方米 40 个测点, 能够同时满足高密度、大范围采样测量, 实现零件三维表面形貌的高清晰复现, 为表面预测提供了新的数据基础。




图 1 发动机顶面表面形貌高清晰测量过程

连续加工过程中零件表面形貌 HDM 数据本质上属于时空序列数据, 单个形貌数据不同空间单元

之间存在明显的空间聚集, 多个形貌数据同一空间单元之间存在一定的联系, 如何利用 HDM 数据揭示加工精度形成规律, 预测未加工零件表面形貌成为工业界一个新的难题。对于时空序列预测, MARTIN 等<sup>[20]</sup>提出了第一个真正意义上的时空相关统计模型, 即时空自相关平滑平均模型(Spatio-temporal autocoregressive and moving averages, STARMA), 但 STARMA 模型本质上只能拟合线性数据且要求数据平稳, 存在一定的局限性。近年来, 卷积神经网络(Convolutional neural networks, CNN)和循环神经网络(Recurrent neural networks, RNN)在图像处理和时序预测分析领域做出了巨大贡献, HOCHREITER 等<sup>[21]</sup>提出了长短期记忆网络(Long short-term memory, LSTM)。SHI 等<sup>[22]</sup>将卷积操作引入全连接长短期记忆网络(Fully connected LSTM, FC-LSTM)提出卷积长短期记忆网络(Convolutional LSTM, ConvLSTM)。SHELHAMER 等<sup>[23]</sup>提出了全卷积网络(Fully convolutional network, FCN), 并将其应用于图像语义分割。FAYYAZ 等<sup>[24]</sup>通过扩展全卷积网络提出了时空全卷积神经网络(Spatio-temporal fully convolutional neural network, STFCN)。但 HDM 数据存在复杂的时空自相关性、非线性和非平稳性, 直接利用以上模型进行预测无法达到最优的预测效果。

基于上述分析, 针对传统方法未充分利用数据全局特征和局部特征的缺点以及模型输入的随意性, 本文提出了一种基于时空全卷积循环神经网络的零件表面三维形貌预测方法。通过深度学习建立一个时空序列分析模型, 提取并融合了 HDM 数据的全局特征和局部特征, 对零件加工表面的三维形貌进行预测。通过时间自相关性分析和空间自相关性分析为模型找到准确的输入, 有效提升了模型的预测精度和计算经济性。

## 1 表面形貌预测方法建模

### 1.1 方法概述

针对工程中存在的大尺寸多孔表面, 本文提出了适用于稳定加工过程中大尺寸多孔零件表面形貌预测方法。本文的预测方法主要由大尺寸多孔零件表面形貌测量、时空序列数据空间自相关性分析、时间自相关性分析、搭建并训练时空全卷积循环神经网络(Spatio-temporal fully convolutional recurrent neural network, STFCRNN)模型和模型预测评价等 5

个步骤组成, 该预测方法框架如图 2 所示。

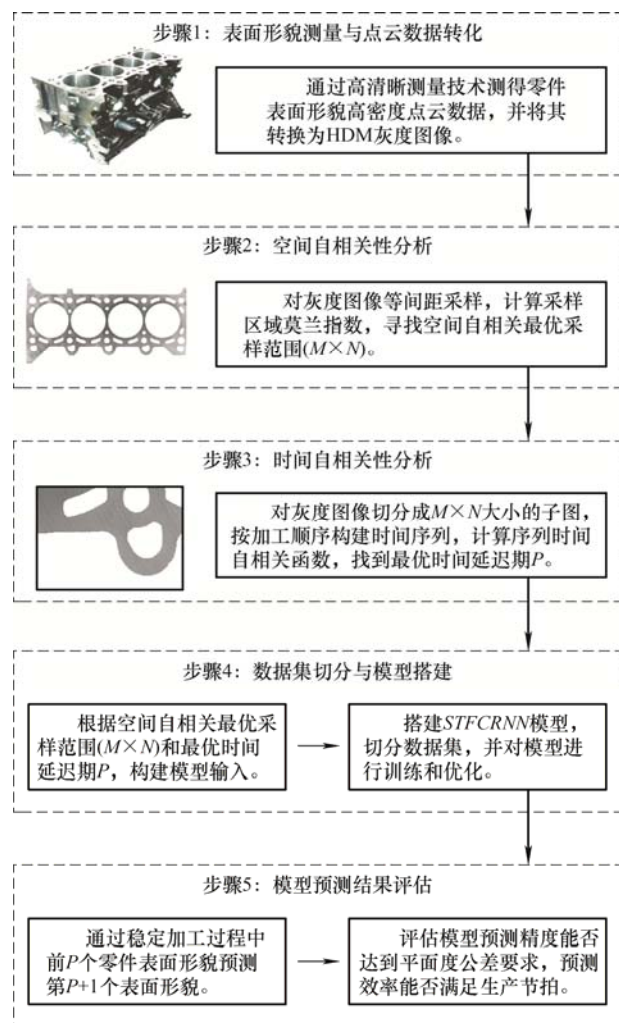


图 2 零件表面形貌预测方法框架图

## 1.2 空间自相关性分析

稳定连续加工过程中零件表面形貌数据和时间序列数据相比存在空间相关性, 体现在同一零件表面上空间相邻观测点之间存在相互依赖关系。本节对高清晰测量技术得到的灰度图像进行空间自相关性分析, 找到零件表面形貌数据的空间自相关最优采样范围  $M \times N$ ,  $M$ 、 $N$  为最优采样范围的宽和高, 为后续 STFCRNN 模型构建准确的输入, 降低模型运算成本。空间自相关性分析流程图如图 3 所示, 具体步骤如下。

(1) 采样切分。以  $B$  像素为采样间距、 $W \times H$  像素为初始采样图像尺寸、 $n$  为采样个数对高清晰测量技术得到的灰度图像进行等间距采样, 采样初始位置随机选取但应利于后续切分操作。将灰度图像切分为一系列采样子图  $I_1, I_2, \dots, I_n$ , 采样子图尺寸  $S_n$  为

$$S_n = [W + (n-1) \times B] \times [H + (n-1) \times B] \quad (1)$$

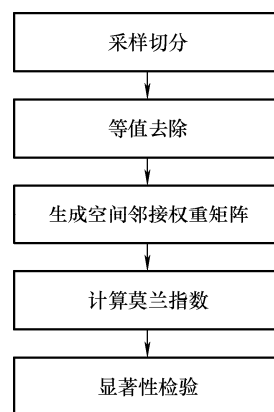


图 3 空间自相关性分析流程图

(2) 零值去除。为消除灰度图像背景对空间自相关性分析的干扰, 对采样子图  $I_1, I_2, \dots, I_n$ , 进行去零值操作, 分别得到  $q_1, q_2, \dots, q_n$  个非零点, 即采样子图总共有  $q_1, q_2, \dots, q_n$  个空间单元。

(3) 生成空间邻接权重矩阵。空间邻接权重矩阵是空间权重矩阵的一种, 用于定量描述某一空间单元  $i$  在空间上受周围空间单元  $j$  的影响, 通常用  $w_{ij}$  表示。本文选用共边界法建立去零值后采样子图的空间邻接权重矩阵, 计算方法为

$$w_{ij} = \begin{cases} 1 & i \text{ 与 } j \text{ 共边界} \\ 0 & \text{其他} \end{cases} \quad (2)$$

去零值后采样子图的空间邻接权重矩阵维度为  $q_1 \times q_1, q_2 \times q_2, \dots, q_n \times q_n$ , 以空间单元  $q = 4$  为例, 建立空间邻接权重矩阵  $w_{ij}$  如图 4 所示。




图 4 空间单元分布及邻接权重矩阵示意图

(4) 计算莫兰指数。空间自相关性是空间数据的重要性质, 所描述的是在空间区域中位置  $i$  与其邻近位置  $j$  上同一变量的相关性。莫兰指数分为全局莫兰指数和局部莫兰指数, 全局莫兰指数常用于检验和判定研究区域内空间变量是否存在全局自相关关系, 而局部莫兰指数可以找出研究区域内空间变量存在空间聚集现象的具体位置。本文只需要分析去零值后采样子图的灰度值在空间上的平均关联程度, 因此采用全局莫兰指数。空间自相关的全局莫兰指数统计量  $I$  可表示为

$$I = \frac{n}{W_0} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3)$$

式中,  $x_i$ 、 $x_j$  分别表示空间变量  $x$  在空间单元  $i$  和  $j$  上的属性值,  $\bar{x}$  为空间单元属性值均值,  $n$  为区域空间单元总数,  $W_0 = \sum_{i=1}^n \sum_{j=1}^n w_{ij}$  表示所有空间权重的聚合,  $w_{ij}$  为空间邻接权重矩阵。

(5) 显著性检验。灰度图像因为空间单元数足够多, 所以空间变量  $x$  近似服从正态分布, 在正态分布假设下, 使用  $Z$  检验对全局莫兰指数统计量  $I$  进行显著性检验

$$Z(I) = \frac{I - E(I)}{\sqrt{\text{Var}(I)}} \quad (4)$$

$$E(I) = -\frac{1}{n-1} \quad (5)$$

$$\text{Var}(I) = \frac{n^2 S_1 - n S_2 + 3 S_0^2}{S_0^2 (n^2 - 1)} - E^2(I) \quad (6)$$

式中,  $S_1 = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (w_{ij} + w_{ji})^2$ ,  $S_2 = \sum_{i=1}^n (w_i + w_j)^2$ ,

$$w_i = \sum_{j=1}^n w_{ij}, \quad w_j = \sum_{i=1}^n w_{ji}.$$

在显著性为 5% 水平下, 若  $|Z(I)| > 1.96$ , 则表明全局莫兰指数显著, 研究范围内的空间单元属性值在空间上存在显著相关性。因此, 可以根据全局莫兰指数大小判断属性值的空间自相关程度高低, 进而找出空间自相关最优采样范围  $M \times N$ 。

### 1.3 时间自相关性分析

稳定连续加工过程中零件表面形貌数据的时间相关性体现在加工时间相邻的零件上同一空间位置测点之间存在相关性。对零件表面形貌灰度图像进行时间自相关性分析, 找到时间序列最优时间延迟阶数  $P$ , 为后续 STFCRNN 模型构建准确的输入, 帮助模型快速收敛。时间自相关性分析流程图如图 5 所示, 具体步骤如下。

(1) 构建时间序列。以第 1.2 节中得到的空间自相关程度最优采样范围  $M \times N$  为切分尺寸, 将零件表面形貌灰度图像切分成一系列大小相同的子图,

并将相同空间位置的子图按照零件加工顺序构建时间序列。



图 5 时间自相关性分析流程图

(2) 序列平稳性检验及平稳化。为使自相关系数能在较短的时间延迟阶数内快速趋近于 0, 计算时间自相关函数之前, 需要验证时间序列是否平稳, 对非平稳序列进行差分运算, 差分后再次进行检验, 直到检验结果为平稳序列为止。平稳性检验采用 ADF(Augmented Dickey-Fuller) 检验, 判断序列中是否存在单位根, 如果序列中存在单位根, 则序列不平稳; 反之, 则序列平稳。

(3) 计算时间自相关函数。时间自相关函数 (Autocorrelation function, ACF) 用于量化时间序列对象属性在时间上的依赖程度。对通过平稳性检验的  $m$  个平稳时间序列  $D_1^t, D_2^t, \dots, D_m^t, t \in [1, T]$ , 计算其时间自相关函数  $\rho_m^k$ 。

$$\rho_m^k = \frac{\sum_{t=1}^{T-k} (D_m^t - \bar{D}_m)(D_m^{t+k} - \bar{D}_m)}{\sum_{t=1}^T (D_m^t - \bar{D}_m)^2} \quad (7)$$

式中,  $t$  表示时间阶数,  $T$  表示时间序列最大时间阶数,  $\bar{z}_m$  表示第  $m$  个时间序列的平均值,  $k$  表示时间延迟阶数。

(4) 最优时间延迟阶数识别。 $|\rho_m^k|$  值越大, 说明序列对应属性值之间相关性越高。生成能反映时间自相关函数值与其对应的时间延迟阶数之间关系的时间自相关图, 用于分析随时间延迟阶数  $k$  的增加, 时间自相关系数值  $\rho_m^k$  的变化趋势。通过设定 95% 置信度的置信区间  $\mu$  识别最优时间延迟阶数  $P$ ,  $\mu$  的计算方法如下。

$$\bar{z} - \frac{1.96\sigma}{\sqrt{n}} \leq \mu \leq \bar{z} + \frac{1.96\sigma}{\sqrt{n}} \quad (8)$$

式中,  $\bar{z}$  为样本均值,  $n$  为样本总量,  $\sigma$  为样本标准差。

#### 1.4 预测模型构建

ConvLSTM 能建立端到端的图像预测模型,且能较好的解决长期依赖问题<sup>[22]</sup>。以 FCN 的跳层结构作为连接 CNN 和 ConvLSTM 的桥梁,构建 STFCRNN 预测模型,模型结构如图 6 所示。根据空间相关性分析和时间相关性分析,构建模型输入维度为  $(P, M, N, 1)$ , 模型输出维度为  $(M, N, 1)$ , 即通过稳定加工过程中前  $1, 2, \dots, P$  个零件表面形貌预测第  $P+1$  个零件表面形貌, 模型的输入输出如图 7 所示。

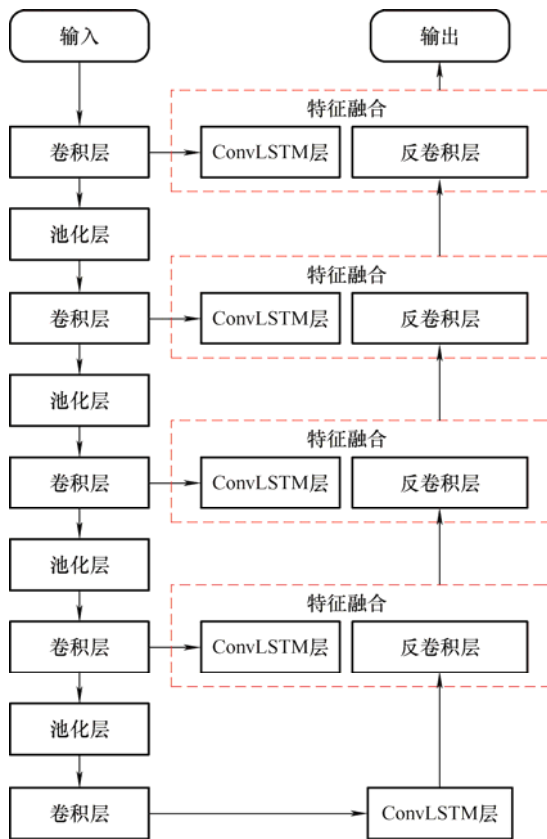


图 6 STFCRNN 模型结构图

假设模型输入为  $X, X \in \mathbb{R}^{P \times M \times N}$ , 先将  $X$  输入到深层卷积网络提取图像的全局特征和局部特征, 得到第  $L$  的输出记为  $X_1^L, X_2^L, \dots, X_P^L$  (池化层因为不具有权重和参数, 在计算网络层数时, 卷积层和池化层计为一层, 且最后一层没有池化层), 经过卷积层后的输出图像尺寸计算方法为

$$O_{output} = \left\lfloor \frac{I_{input} - k_c + 2V}{d} \right\rfloor + 1 \quad (9)$$

式中,  $O_{output}$  表示输出图像尺寸,  $I_{input}$  表示输入图像尺寸,  $k_c$  表示卷积核尺寸,  $V$  表示边界填充参数,  $d$  为滑移步长, 输出图像通道数等于卷积核数量。池

化层输出尺寸计算和卷积层类似, 但池化层不改变图像通道数量。

假设第  $L$  层细胞单元输出为  $C_1^L, C_2^L, \dots, C_P^L$ , 隐藏层状态为  $H_1^L, H_2^L, \dots, H_P^L$ , “ $*$ ”表示卷积运算, “ $\circ$ ”表示矩阵对应位乘积运算。卷积网络每层输出  $X_1^L, X_2^L, \dots, X_P^L$  作为每层 ConvLSTM 的输入, ConvLSTM 计算过程为

$$\tilde{C}_P^L = \tanh(W_{xc}^L * X_P^L + W_{hc}^L * H_{P-1}^L + b_c^L) \quad (10)$$

$$\Gamma_{u-L}^{(P)} = \sigma(W_{xu}^L * X_P^L + W_{hu}^L * H_{P-1}^L + W_{cu}^L * C_{P-1}^L + b_u^L) \quad (11)$$

$$\Gamma_{f-L}^{(P)} = \sigma(W_{xf}^L * X_P^L + W_{hf}^L * H_{P-1}^L + W_{cf}^L * C_{P-1}^L + b_f^L) \quad (12)$$

$$C_P^L = \Gamma_{f-L}^{(P)} \circ C_{P-1}^L + \Gamma_{u-L}^{(P)} * \tilde{C}_P^L \quad (13)$$

$$\Gamma_{o-L}^{(P)} = \sigma(W_{xo}^L * X_P^L + W_{ho}^L * H_{P-1}^L + W_{co}^L * C_P^L + b_o^L) \quad (14)$$

$$H_P^L = \Gamma_{o-L}^{(P)} \circ \tanh(C_P^L) \quad (15)$$

式中,  $\tilde{C}_P^L$  为候选记忆单元,  $\Gamma_{u-L}^{(P)}$  为更新门,  $\Gamma_{f-L}^{(P)}$  为遗忘门,  $\Gamma_{o-L}^{(P)}$  为输出门,  $\Gamma_u$ 、 $\Gamma_f$ 、 $\Gamma_o$ 、 $\tilde{C}$ 、 $C$ 、 $H$  均为三维张量,  $\sigma$  为 sigmoid 激活函数,  $\Gamma_{u-L}^{(P)}$  决定是否要用  $\tilde{C}_P^L$  更新  $C_P^L$ ,  $\Gamma_{f-L}^{(P)}$  决定  $C_P^L$  是否会被保留或遗忘,  $\Gamma_{o-L}^{(P)}$  用于控制记忆单元的结果是否输出。通过控制三个门控单元的开关程度保留重要信息, 遗忘无用信息, 利用窥视孔连接使门值的变化不仅受  $X_P^L$  和  $H_P^L$  影响, 也受上一个细胞单元值  $C_{P-1}^L$  影响。

ConvLSTM 单元输入图像尺寸和输出图像尺寸一致, 第  $L$  层 ConvLSTM 单元的输出经过反卷积运算后与第  $L-1$  层 ConvLSTM 单元的输出进行相加融合, 反卷积层输出图像尺寸计算公式为

$$O_{output}^T = d^T (I_{input}^T - 1) + 2V^T - k_c^T + 2 \quad (16)$$

式中,  $O_{output}^T$  表示输出图像尺寸,  $I_{input}^T$  表示输入图像尺寸,  $k_c^T$ 、 $V^T$  和  $d^T$  分别表示反卷积层卷积核尺寸、边界填充参数和滑移步长, 输出图像通道数等于反卷积层卷积核数量。

模型搭建完成之后, 将第 1.3 节中构建的时间序列数据划分为训练集、验证集和测试集, 以批量的形式输入模型进行训练、调参优化和测试。






图 7 STFCRNN 模型的输入与输出

### 1.5 模型预测误差评价

平均绝对误差(Mean absolute error, MAE)、均方误差(Mean square error, MSE)和均方根误差(Root mean square error, RMSE)是反映模型预测值与真实值之间偏差的重要评价指标。根据测试集预测结果的三个评价指标以及预测时间,评价模型预测精度能否达到零件表面的平面度公差要求,预测效率是否符合生产节拍,三个评价指标计算方法如下。

$$MAE(X, h) = \frac{1}{m} \sum_{i=1}^m |h(x_i) - y_i| \quad (17)$$

$$MSE(X, h) = \frac{1}{m} \sum_{i=1}^m (h(x_i) - y_i)^2 \quad (18)$$

$$RMSE(X, h) = \sqrt{\frac{1}{m} \sum_{i=1}^m (h(x_i) - y_i)^2} \quad (19)$$

## 2 案例分析

以连续稳定的发动机缸体顶面铣削加工过程为例验证本文方法的有效性。发动机缸体的材料为灰铸铁 FC250, 在 EX-CELL-O XS211 柔性加工中心通过铣削加工制成, 平面铣刀包括 15 个半精加工刃和 3 个修光刃。实际生产加工参数为转速 816.4 m/min, 切削深度 0.5 mm, 进给速度 3 360 mm/min, 冷却液选用 Quaker 370 KLG。在铣刀进入稳定磨损阶段后, 连续加工 16 个缸体顶面, 通过高清晰测量技术对各缸体顶面的表面形貌进行测量, 得到各缸体顶面的三维点云数据。将三维点云数据转换成灰度图像<sup>[18]</sup>, 灰度图像灰度值 0~255 对应缸体表面形貌高度值 -0.025~0.025 mm, 随机选取(211, 511)为采样初始位置, 以 25 像素为采样间距、50×50 像素为初始采样尺寸、12 为采样个数对任意一张生成的灰度图像进行等间距采样, 得到 12 张采样子图  $I_1, I_2, \dots, I_{12}$ , 采样子图尺寸  $S_1, S_2, \dots, S_{12}$  如图 8 所示。

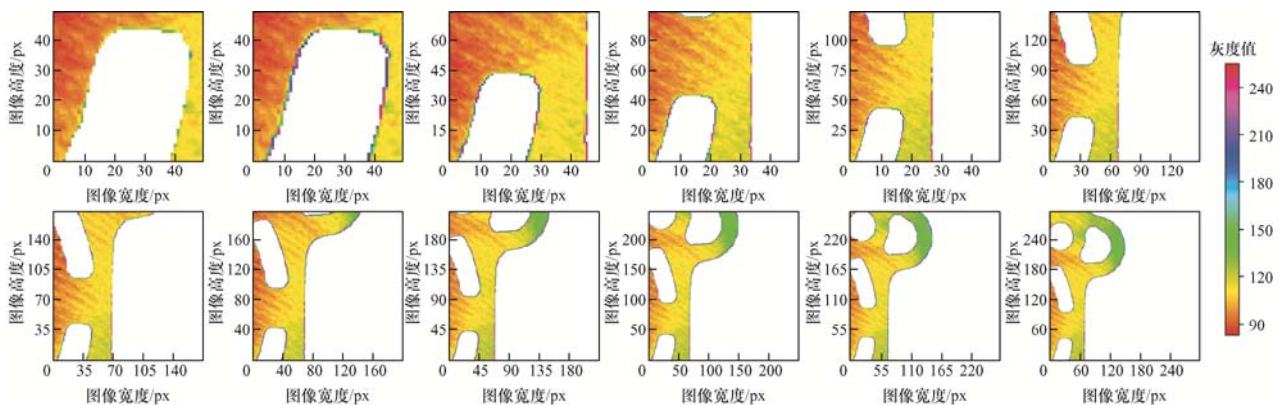


图 8 采样子图切分图

对采样子图  $I_1, I_2, \dots, I_{12}$  去零值操作后, 建立其对应的空间邻接权重矩阵, 再计算各子图全局莫兰指数, 生成莫兰指数折线图, 如图 9 所示。尺寸最大和最小采样子图的空间变量柱状分布图, 如图 10 所示。采样子图的空间变量  $x$  近似服从正态分布, 因此假设空间变量  $x$  服从正态分布, 对全局莫兰指数进行显著性检验, 检验结果如表 1 所示。




图 9 全局莫兰指数折线图




图 10 采样子图空间变量分布图

表 1 全局莫兰指数显著性检验结果

采样尺寸/ 像素	50×50	75×75	100×100	125×125	150×150	175×175	200×200	225×225	250×250	275×275	300×300	325×325
$ Z(I) $	13.154	20.400	30.700	34.991	26.653	31.823	43.923	53.306	60.357	67.322	73.628	73.050

由表 1 可知, 所有采样子图的  $|Z(I)|$  均大于 1.96, 因此全局莫兰指数均显著, 选取全局莫兰指数值最大的采样子图尺寸 300 像素×300 像素作为空间自相关最优范围。将缸体顶面灰度图像切分成一系列 300×300 像素大小的子图, 按照缸体顶面加工顺序构建时间序列  $K_1, K_2, \dots, K_{15}$ , 具体方法如图 11 所示。




图 11 缸体顶面时序切分图

同一铣刀连续加工的 16 件缸体顶面数据为一组, 共 20 组。同一组中, 前 15 个表面形貌数据作为训练集和验证集, 第 16 个表面形貌数据作为测试集标签, 根据前 15 件缸体数据进行调参建模, 对第 16 件缸体进行预测。图 12 所示为 15 个时间序列  $K_1, K_2, \dots, K_{15}$  的建模子图测点高度的均值折线

图, 通过图 12 可以初步判断序列为非平稳时间序列, 对序列进行差分运算得到平稳序列  $D_1, D_2, \dots, D_{15}$ , 差分运算后子图测点高度均值如图 13 所示, 序列  $D_1, D_2, \dots, D_{15}$  的 ADF 检验结果如表 2 所示, 可知差分后的时间序列为平稳序列。计算 15

表 2 平稳序列的 ADF 检验结果

序列	差分阶数	ADF	临界值(cValue)			最优时间延迟阶数 $P$
			1%	5%	10%	
$D_1$	1	-4.344	-4.138	-3.155	-2.714	$3.72 \times 10^{-4}$
$D_2$	2	-4.095	-4.332	-3.233	-2.749	$9.86 \times 10^{-4}$
$D_3$	1	-8.820	-4.069	-3.127	-2.702	$1.89 \times 10^{-14}$
$D_4$	2	-6.924	-4.223	-3.189	-2.730	$1.12 \times 10^{-9}$
$D_5$	0	-4.838	-4.473	-3.290	-2.772	$4.60 \times 10^{-5}$
$D_6$	1	-4.521	-4.138	-3.155	-2.714	$1.80 \times 10^{-4}$
$D_7$	0	-3.610	-4.012	-3.104	-2.691	$5.58 \times 10^{-3}$
$D_8$	0	-3.550	-4.473	-3.290	-2.772	$6.78 \times 10^{-3}$
$D_9$	3	-5.464	-4.665	-3.367	-2.803	$2.48 \times 10^{-6}$
$D_{10}$	1	-3.790	-4.069	-3.127	-2.702	$3.00 \times 10^{-3}$
$D_{11}$	1	-5.584	-4.069	-3.127	-2.702	$1.38 \times 10^{-6}$
$D_{12}$	4	-4.812	-4.665	-3.367	-2.803	$5.17 \times 10^{-5}$
$D_{13}$	2	-4.808	-4.332	-3.233	-2.749	$5.25 \times 10^{-5}$
$D_{14}$	2	-3.811	-4.473	-3.290	-2.772	$2.80 \times 10^{-3}$
$D_{15}$	3	-10.347	-4.223	-3.189	-2.730	$2.60 \times 10^{-18}$

个平稳序列  $D_1, D_2, \dots, D_{15}$  的时间自相关函数, 得到各序列在不同时间延迟阶数  $k$  下的时间自相关系数

值  $\rho_m^k (k=0, 1, \dots, 14, m=1, 2, \dots, 15)$  以及时间自相关函数图, 如图 14 所示。

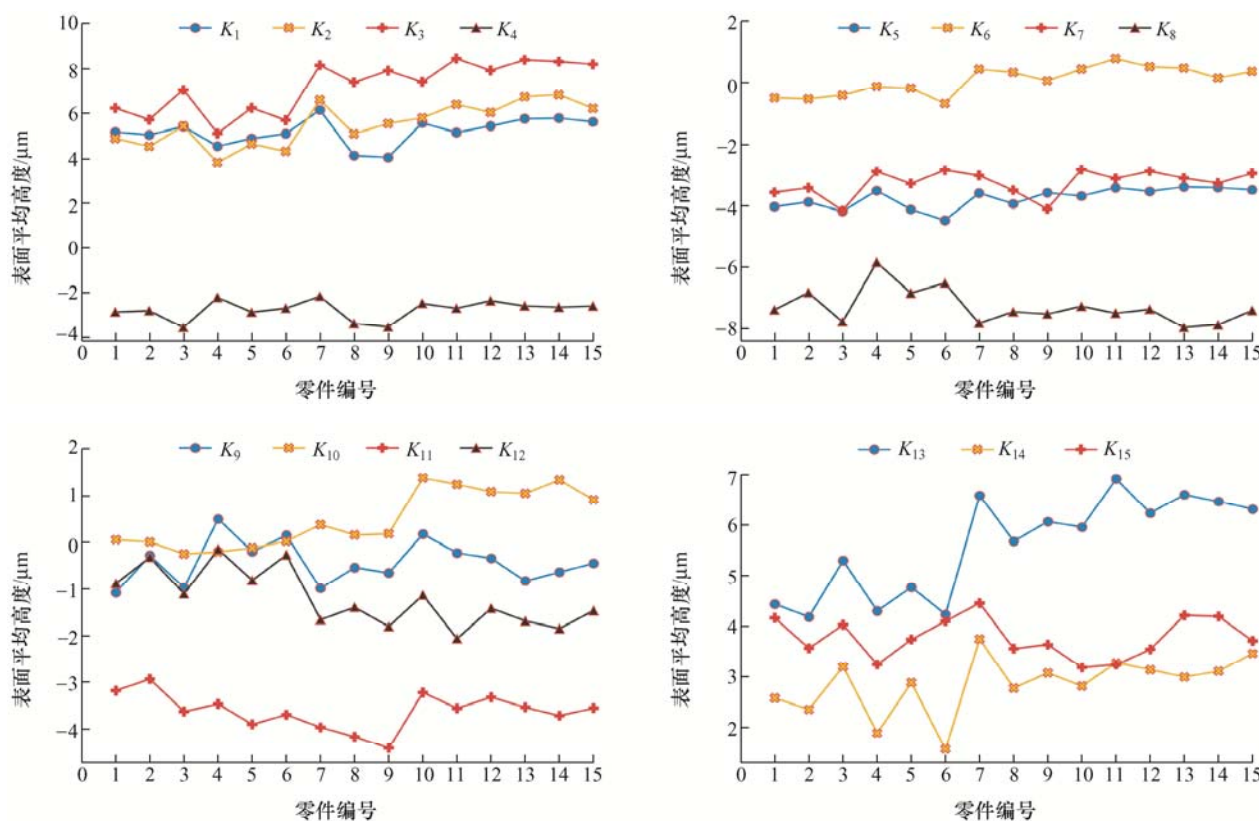


图 12 序列  $K_1$  至  $K_{15}$  研究表面的平均高度

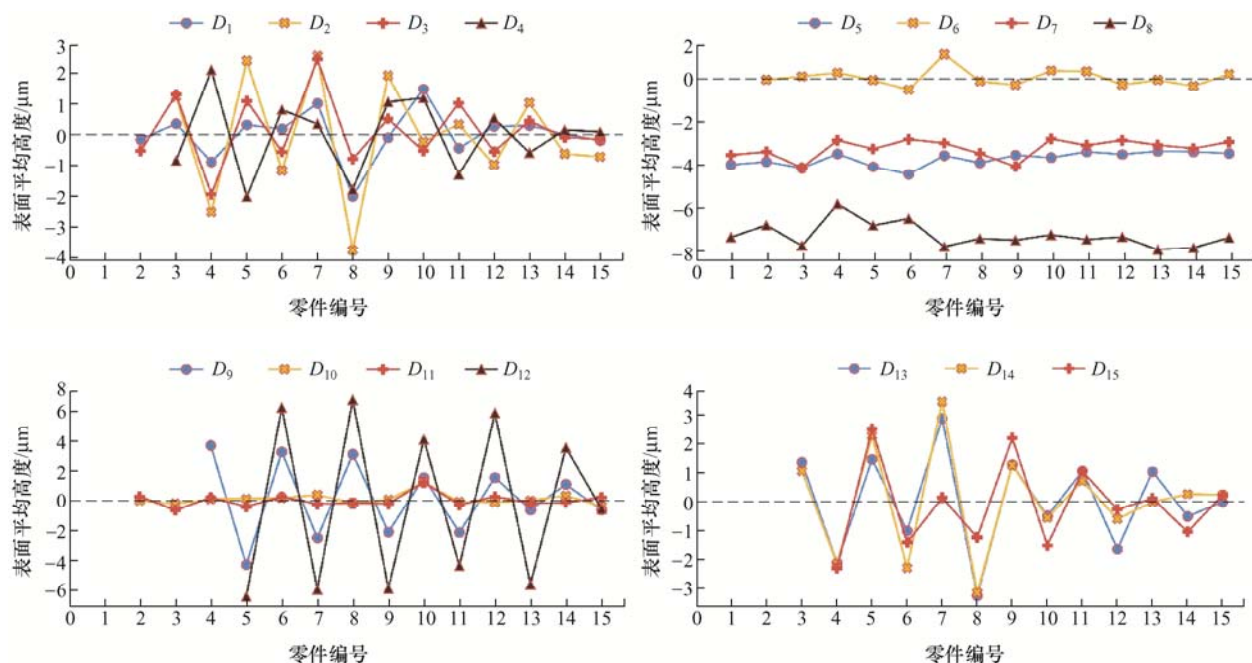


图 13 序列  $D_1$  至  $D_{15}$  研究表面的平均高度






图 14 平稳序列的时间自相关函数图

计算不同时间延迟阶数  $k$  下各序列的时间自相关系数绝对值的最大值  $|\rho^k|_{\max}$ , 计算结果如图 15 所示。因为序列  $D_1, D_2, \dots, D_{15}$  为差分运算之后的平稳序列, 近似服从  $N(0, 1/m)$  正态分布, 所以序列 95% 置信度置信区间  $\mu \pm 1.96/\sqrt{m} \approx \pm 0.5$ 。通过图 15 可得, 当时间延迟阶数  $k \geq 6$  时,  $|\rho^k|_{\max}$  完全落入置信区间内, 取第 6 阶的前一阶作为平稳序列  $D$  的整体最优时间延迟阶数  $P$ , 即  $P=5$ 。




图 15 差分序列的时间自相关函数图

根据空间自相关最优采样范围  $M \times N$  以及最优时间延迟阶数  $P$ , 构建 STFCRNN 模型输入维度为  $(5, 300, 300, 1)$ 、输出维度为  $(300, 300, 1)$ , 最后将模

型输出的预测子图拼接成整体预测图, 即通过前 5 件连续加工缸体顶面的表面形貌预测第 6 件缸体顶面的表面形貌。模型损失函数选用 L2 损失函数, 即预测图像灰度值与真实图像灰度值之间的均方误差, 优化器选用 Adam Optimizer, 激活函数采用 ReLU, Batch size 设置为 3, 初始学习率为  $10^{-3}$ , 训练集、验证集、测试集划分比例为 77.3%、13.6%、9.1%。通过与传统 ConvLSTM、CNN+ConvLSTM 模型进行对比分析, 验证本文提出模型的可行性及优越性。本文模型以及对比模型的训练过程如图 16 和图 17 所示。




图 16 STFCRNN 和对比模型训练过程的 MAE 变化图




图 17 STFCRNN 和对比模型训练过程的 Loss 变化图

模型训练 30 个批次, 即 27 万次迭代之后损失函数值和平均绝对误差下降趋于稳定。对比发现, 在训练集上 STFCRNN 模型效果优于对比模型, 损失值和平均绝对误差均低于对比模型, 各模型在验证集和测试集上的表现如表 3 所示。本文提出的

表 3 验证集和测试集模型预测结果分析表

模型	验证集 MSE/ $\mu\text{m}^2$	验证集 MAE/ $\mu\text{m}$	测试集 MSE/ $\mu\text{m}^2$	测试集 MAE/ $\mu\text{m}$	预测 时间/s
STFCRNN	0.203	0.837	0.225	0.905	5.00
CNN+ ConvLSTM	0.301	1.142	0.330	1.268	2.00
ConvLSTM	0.239	0.916	0.275	1.030	24.00
差值 1(%)	32.560	26.710	31.820	28.630	-150.00
差值 2(%)	15.060	8.620	18.180	12.140	79.17

STFCRNN 模型相比单独使用 ConvLSTM 模型, 在验证集和测试集上的预测精度均提高了 8.5% 以上, 预测效率提高了 79.19%; 相比 CNN+ConvLSTM 模型, 虽然损失了 3 s 的预测效率, 但在生产节拍允许的范围内

提升了 25% 以上的预测精度。综合考虑各模型在训练集、验证集和测试集上的预测精度以及预测效率, STFCRNN 模型的综合预测效果优于对比模型。各模型的整体预测结果对比图如图 18 所示。

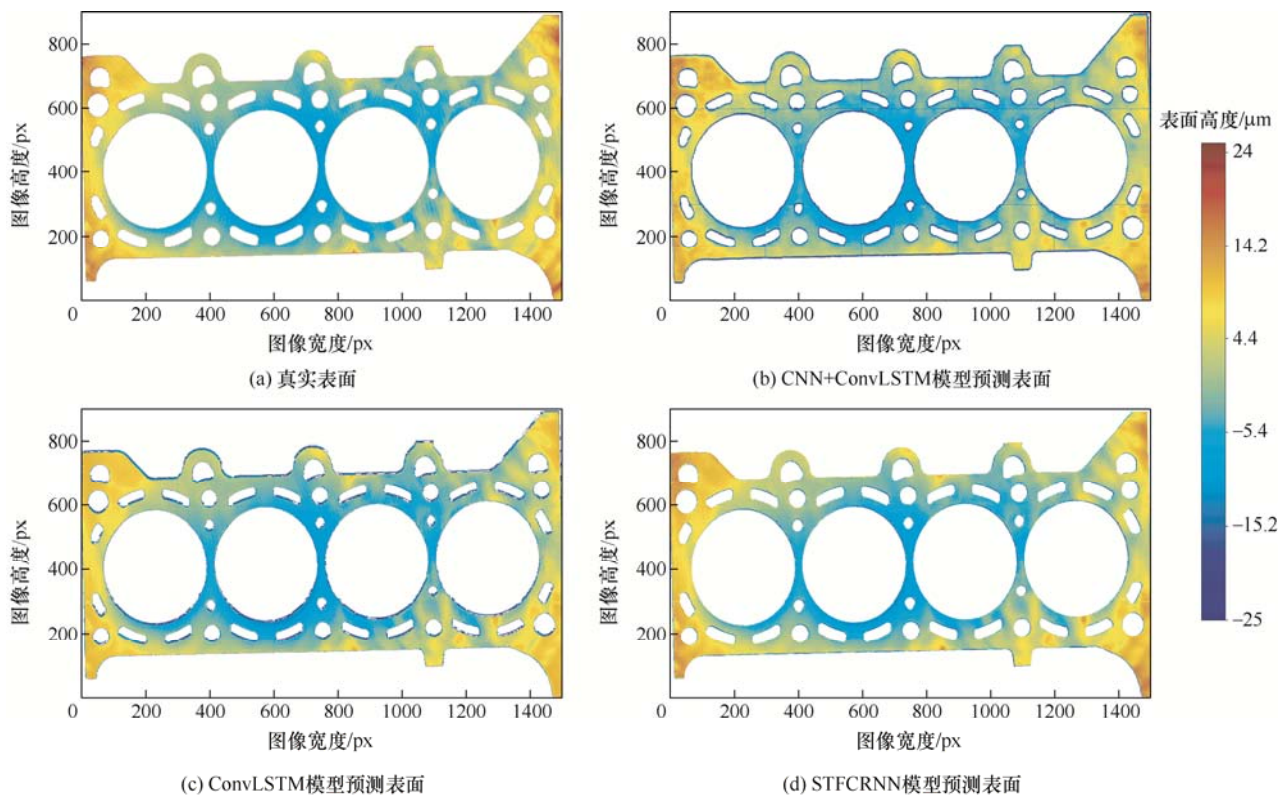


图 18 真实表面与预测表面

通过与真实图片对比发现, 单独使用 ConvLSTM 模型由于损失掉了图像的全局特征, 影响了模型对于图像边缘的预测效果; 传统将深层卷积网络最末层输出直接作为 ConvLSTM 模型输入的方法, 由于图像局部特征的丢失, 模型对图像局部细节的预测能力相对较差, 预测子图拼接处存在较为明显的裂痕, 影响整图预测效果; STFCRNN 模型提取并融合了图像的全局特征和局部特征, 综合考虑了图像整体轮廓和局部细节的预测, 进一步提高了模型的预测精度, 缸体顶面某区域灰度图像局部特征和全局特征如图 19 所示。随机选取 5 个

75 像素×75 像素大小区域分析 STFCRNN 模型对零件局部形貌的预测能力, 选取区域编号如图 20 所示。




图 20 模型局部形貌预测所选区域编号图




图 19 不同卷积层提取的缸体顶面某区域灰度图像特征

缸体顶面真实局部形貌与 STFCRNN 模型预测局部形貌三维对比图如图 21 所示, 模型局部形貌预测精度评价指标值如表 4 所示。模型局部形貌预测的 MSE 和 RMSE 均低于  $0.9 \mu\text{m}^2$ , MAE 低于  $2.8 \mu\text{m}$ , 相比  $50 \mu\text{m}$  的零件平面度公差, 本文建立的表面形貌预测模型具有较高的预测精度, 且三个预测精度重要评价指标表现出了良好的一致性。



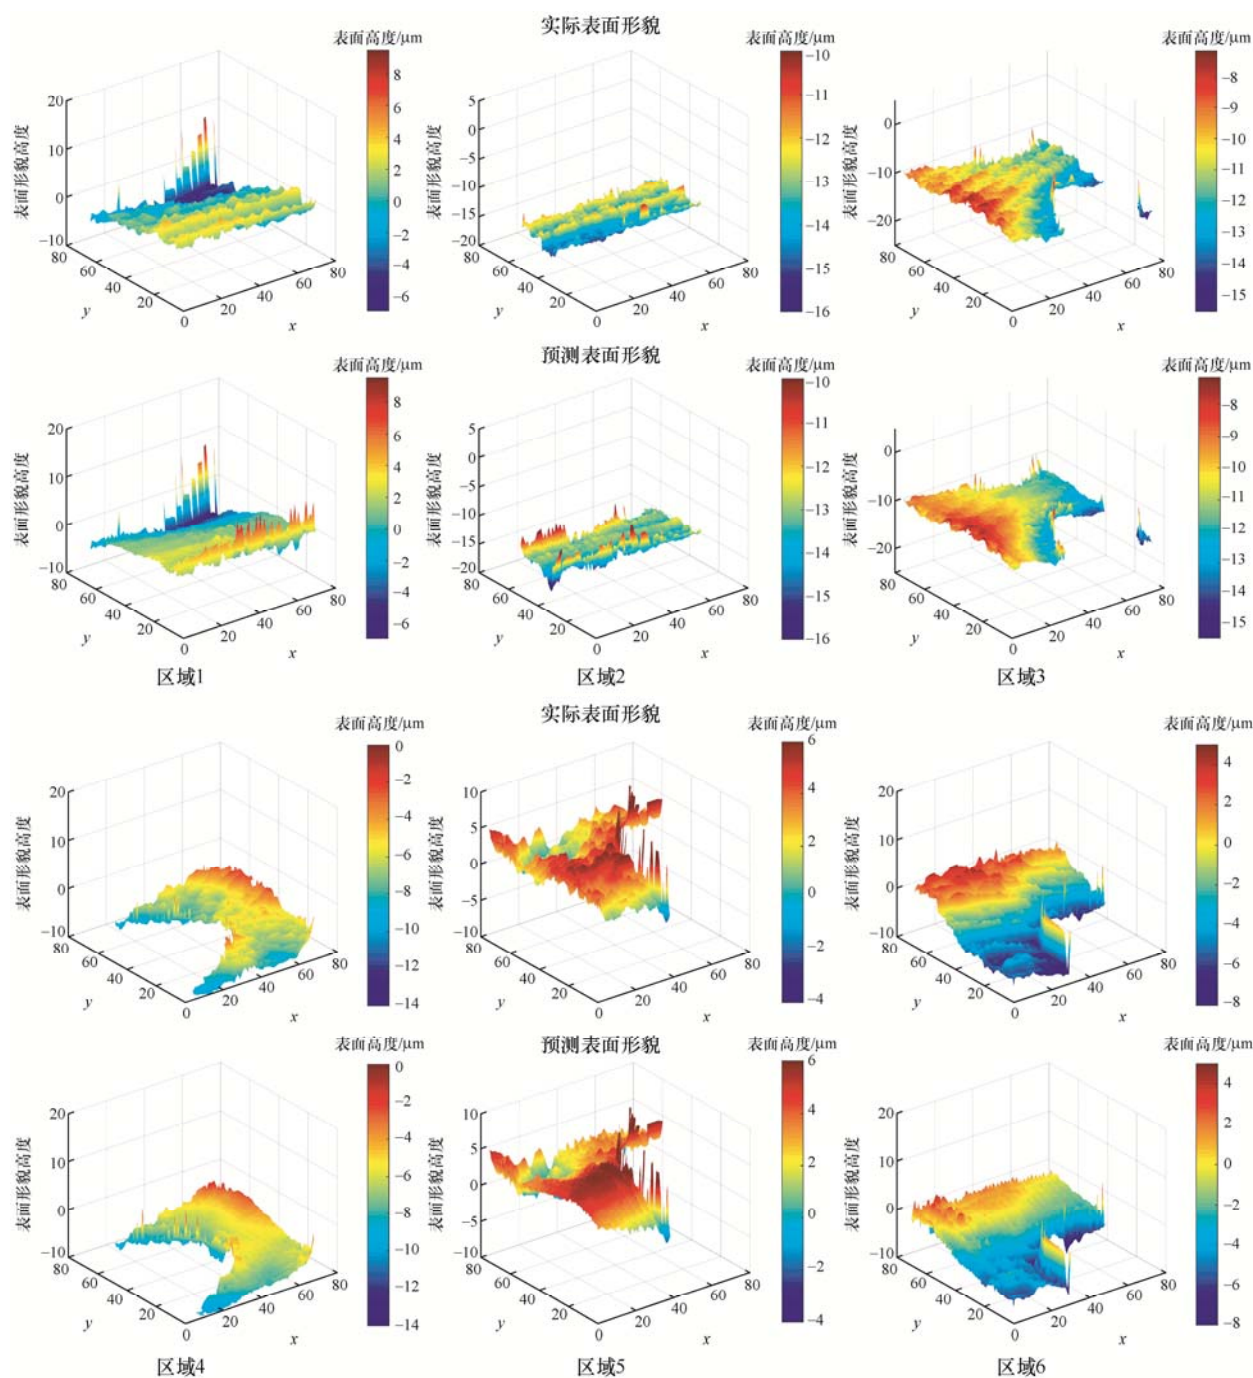


图21 真实局部表面形貌与模型预测局部表面形貌对比图

表4 模型局部预测精度分析表

评价指标	区域编号					
	1	2	3	4	5	6
MSE/ $\mu\text{m}^2$	0.392	0.372	0.560	0.481	0.275	0.733
RMSE/ $\mu\text{m}^2$	0.626	0.610	0.784	0.693	0.525	0.856
MAE/ $\mu\text{m}$	1.735	1.237	2.042	1.525	1.312	2.760

### 3 结论

(1) 基于深度学习对连续稳定加工过程中零件

表面形貌预测做了深入研究,针对HDM数据,提出了一种基于STFCRNN的零件表面形貌预测方法,通过案例分析和模型对比验证了本文提出方法具有最优的综合预测效果。

(2) 通过计算全局莫兰指数和时间自相关函数,能有效提高模型预测精度和计算经济性。

(3) 将ConvLSTM单元引入FCN构建的时空序列分析网络,能降低网络空间数据冗余,完成对全局图像特征和局部图像特征的提取和融合,且具备时序分析能力。

(4) 将预测得到的未加工零件表面形貌信息反馈给加工系统, 从而预控加工过程, 推进高精度自动化质量监控是下一步研究方向。

### 参 考 文 献

- [1] DENKENA B, BÖB V, NESPOR D, et al. Prediction of the 3D surface topography after ball end milling and its influence on aerodynamics[J]. *Procedia CIRP*, 2015, 31: 221-227.
- [2] OMAR O, EL-WARDANY T, NG E, et al. An improved cutting force and surface topography prediction model in end milling[J]. *International Journal of Machine Tools & Manufacture*, 2007, 47(7-8): 1263-1275.
- [3] BENARDOS P G, VOSNIAKOS G C. Predicting surface roughness in machining: A review[J]. *International Journal of Machine Tools and Manufacture*, 2003, 43(8): 833-844.
- [4] 董永亨, 李淑娟, 李言, 等. 球头铣刀余摆线加工表面形貌的建模与仿真研究[J]. *机械工程学报*, 2018, 54(19): 212-223.
- DONG Yongheng, LI Shujuan, LI Yan, et al. Research on modeling and simulation of surface topography obtained by trochoidal milling mode with ball end milling cutter[J]. *Journal of Mechanical Engineering*, 2018, 54(19): 212-223.
- [5] 王艳, 李德藺, 刘建国, 等. 基于动态轮廓采样法的轴向超声振动辅助磨削工件表面形貌预测与试验验证[J]. *机械工程学报*, 2018, 54(21): 221-230.
- WANG Yan, LI Delin, LIU Jianguo, et al. Prediction and experimental verification of workpiece surface topology in axial ultrasonic vibration assisted grinding based on dynamic profile sampling method[J]. *Journal of Mechanical Engineering*, 2018, 54(21): 221-230.
- [6] LU Xiaohong, HU Xiaochen, JIA Zhenyuan, et al. Model for the prediction of 3D surface topography and surface roughness in micro-milling Inconel 718[J]. *The International Journal of Advanced Manufacturing Technology*, 2018, 94(5): 2043-2056.
- [7] TORTA M, ALBERTELLI P, MONNO M. Surface morphology prediction model for milling operations[J]. *The International Journal of Advanced Manufacturing Technology*, 2020, 106(1): 3189-3201.
- [8] WANG Wei, LI Qingzhao, JIANG Yunfeng. A novel 3D surface topography prediction algorithm for complex ruled surface milling and partition process optimization[J]. *The International Journal of Advanced Manufacturing Technology*, 2020, 107(9): 3817-3831.
- [9] BUSTILLO A, GRZENDA M, MACUKOW B. Interpreting tree-based prediction models and their data in machining processes[J]. *Integrated Computer-Aided Engineering*, 2016, 23(4): 349-367.
- [10] COSTES J P. A predictive surface profile model for turning based on spectral analysis[J]. *Journal of Materials Processing Technology*, 2013, 213(1): 94-100.
- [11] DUAN Chunzheng, HAO Qinglong. Surface roughness prediction of end milling process based on IPSO-LSSVM[J]. *Journal of Advanced Mechanical Design, Systems, and Manufacturing*, 2014, 8(3): 1-12.
- [12] MANDAL N, DOLOI B, MONDAL B. Surface roughness prediction model using zirconia toughened alumina (ZTA) turning inserts: Taguchi method and regression analysis[J]. *Journal of The Institution of Engineers (India): Series C*, 2016, 97(1): 77-84.
- [13] MAUDES J, BUSTILLO A, GUERRA A J, et al. Random forest ensemble prediction of stent dimensions in microfabrication processes[J]. *The International Journal of Advanced Manufacturing Technology*, 2017, 91(1): 879-893.
- [14] PIMENOV D Y, BUSTILLO A, MIKOLAJCZYK T. Artificial intelligence for automatic prediction of required surface roughness by monitoring wear on face mill teeth[J]. *Journal of Intelligent Manufacturing*, 2018, 29(5): 1045-1061.
- [15] TABERNIK D, ELA S, SKVAR J, et al. Segmentation-based deep-learning approach for surface-defect detection[J]. *Journal of Intelligent Manufacturing*, 2019, 31(3): 759-776.
- [16] 胡芑庆, 陈徽鹏, 程哲, 等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法[J]. *机械工程学报*, 2019, 55(7): 9-18.
- HU Niaoqing, CHEN Huipeng, CHENG Zhe, et al. Fault diagnosis for planetary gearbox based on EMD and deep convolutional neural networks[J]. *Journal of Mechanical Engineering*, 2019, 55(7): 9-18.
- [17] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. *机械工程学报*, 2018, 54(5): 94-104.
- LEI Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. *Journal of Mechanical Engineering*, 2018, 54(5): 94-104.
- [18] WANG Meng, XI Lifeng, DU Shichang. 3D surface form error evaluation using high definition metrology[J].



- Precision Engineering, 2014, 38(1): 230-236.
- [19] HUANG Zhenhua, SHIH A J, NI Jun. Laser interferometry hologram registration for three-dimensional precision measurements[J]. Journal of Manufacturing Science and Engineering, 2006, 128(4): 1006-1013.
- [20] MARTIN R L, OEPPEN J E. The identification of regional forecasting models using space: Time correlation functions[J]. Transactions of the Institute of British Geographers, 1975, 66: 95-118.
- [21] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [22] SHI Xingjian, CHEN Zhouong, WANG Hao, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting[C]// Advances in Neural Information Processing Systems. December 7-12, 2015, New York: Curran Associates, 2015: 802-810.
- [23] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [24] FAYYAZ M, SAFFAR M H, SABOKROU M, et al. STFCN: Spatio-temporal fully convolutional neural network for semantic segmentation of street scenes[C]// Asian Conference on Computer Vision. November 20-24, 2016, Cham: Springer, 2016: 493-509.
- 
- 作者简介: 邵益平, 男, 1991 年出生, 博士, 讲师。主要研究方向为精密制造与质量控制。  
E-mail: syp123gh@zjut.edu.cn
- 鲁建厦(通信作者), 男, 1963 年出生, 硕士, 教授, 博士研究生导师。主要研究方向为智能物流装备与技术、智能制造与质量控制、精益生产。  
E-mail: ljs@zjut.edu.cn