



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于VMD-CNN的高噪声动态生产过程质量异常监控

刘玉敏, 王德园, 王宁, 田光杰

引用本文:

刘玉敏,王德园,王宁,田光杰. 基于VMD-CNN的高噪声动态生产过程质量异常监控[J]. 控制与决策, 2024, 39(5): 1595–1603.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1560>

您可能感兴趣的其他文章

Articles you may be interested in

基于2D-OTSU图像边缘检测的回转窑工况识别方法

Condition recognition method of rotary kiln based on 2D-OTSU image edge detection

控制与决策. 2021, 36(10): 2427–2434 <https://doi.org/10.13195/j.kzyjc.2020.0348>

基于自适应混合核典型变量分析的工业过程质量相关故障检测

Quality-related fault detection for industrial processes based on adaptive mixed kernel canonical variable analysis

控制与决策. 2021, 36(4): 801–807 <https://doi.org/10.13195/j.kzyjc.2020.0690>

复杂背景下全景视频运动小目标检测算法

Panoramic video motion small target detection algorithm in complex background

控制与决策. 2021, 36(1): 249–256 <https://doi.org/10.13195/j.kzyjc.2019.0686>

面向复杂网络的异常检测研究进展

Research progress of anomaly detection for complex networks

控制与决策. 2021, 36(6): 1293–1310 <https://doi.org/10.13195/j.kzyjc.2020.0055>

基于模式运动的一类生产过程调节性能与聚类参数关系

Relationship between clustering parameters and regulation performance of a class of production processes based on pattern moving

控制与决策. 2020, 35(5): 1025–1038 <https://doi.org/10.13195/j.kzyjc.2018.1142>

基于VMD-CNN的高噪声动态生产过程质量异常监控

刘玉敏¹, 王德园^{1,2}, 王宁^{1†}, 田光杰¹

(1. 郑州大学 商学院, 郑州 450001; 2. 郑州大学 管理学院, 郑州 450001)

摘要: 针对由智能制造现场动态生产过程的复杂随机因素影响造成的高噪声和质量异常监控方法效率低等问题, 将变分模态分解方法 (variational mode decomposition, VMD) 与深度卷积神经网络 (convolutional neural network, CNN) 相结合, 提出一种基于 VMD-CNN 的实时质量监控新方法. 首先, 利用 VMD 方法, 将高噪声动态过程原始数据分解为包含质量异常特征和噪声信息的两类本征模态函数, 通过去除噪声数据的本征模态函数, 消除动态生产过程的高噪声干扰; 进而, 采用灰度变换将保留原始质量异常特征的本征模型函数转化为质量异常图像, 构建 VMD-CNN 模型对质量异常图像进行识别, 并提出基于 VMD-CNN 的高噪声动态过程质量异常实时监控框架; 最后, 通过实验验证所提方法的有效性, 并与小波去噪方法和 CNN 识别模型进行对比分析, 实验结果显示所提方法的识别精确度显著优于现有的动态过程质量异常监控方法.

关键词: 高噪声动态过程; 变分模态分解; 卷积神经网络; 质量异常特征识别; 质量监控

中图分类号: TP391.4; TH165+3

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1560

引用格式: 刘玉敏, 王德园, 王宁, 等. 基于 VMD-CNN 的高噪声动态生产过程质量异常监控 [J]. 控制与决策, 2024, 39(5): 1595-1603.

Abnormal quality monitoring for strong noise dynamic process based on VMD-CNN

LIU Yu-min¹, WANG De-yuan^{1,2}, WANG Ning^{1†}, TIAN Guang-jie¹

(1. Business of School, Zhengzhou University, Zhengzhou 450001, China; 2. School of Management, Zhengzhou University, Zhengzhou 450001, China)

Abstract: For the problems of strong noise and low quality abnormal monitoring efficiency in dynamic process of intelligent manufacturing scene, the real-time abnormal quality monitoring method is proposed by combining the variational mode decomposition (VMD) and deep convolutional neural network (CNN). Firstly, the VMD is used to divide the original data into two kinds of intrinsic model functions which reflect the quality abnormal characteristics and noise data. By removing the noise intrinsic model function, strong noise is disposed in the dynamic production process. Furthermore, the intrinsic model functions that retain the original quality abnormal features are transformed into quality abnormal images by gray level transformation, and the VMD-CNN model is constructed to identify the images to monitor dynamic abnormal quality process. Finally, the simulation experiments are used to compare and analysis the CNN, wavelet denoising reconstruction and the proposed method. Results show that the performance of the proposed method is significantly better than the existing dynamic process abnormal quality monitoring methods.

Keywords: strong noise dynamic process; variational mode decomposition (VMD); convolutional neural network (CNN); abnormal quality feature recognition; quality monitoring

0 引言

生产过程质量是保证产品质量的基础, 是实现智能制造的关键^[1]. 智能制造生产线上安装了大量的传感器, 以实时采集反映生产过程运行状态的数据. 由于制造过程的复杂性和传感器种类的多样性, 用于监

测生产过程质量的数据具有高噪声、时序性、多模态等特点^[2], 形成了高噪声动态生产过程. 在动态生产过程中, 数据传输、采集、存储中的异常以及传感器自身漂移、不同传感器的采样速率、测量延迟等因素, 使得过程数据流呈现出趋势、阶跃、周期等质量异常

收稿日期: 2022-09-02; 录用日期: 2023-01-20.

基金项目: 国家自然科学基金重点项目 (U1904211); 国家自然科学基金项目 (20BTJ059); 河南省高等学校青年骨干教师培养专项资金项目 (2021GGJS006); 河南省高校哲学社会科学创新人才支持项目 (22HASTIT022); 郑州大学精尖学科支持项目 (XKLMJX202201).

†通讯作者. E-mail: zz-wn@zzu.edu.cn.

模式^[3]. 动态生产过程异常模式会导致严重的质量事故, 给企业带来重大经济损失^[4]. 因而, 如何消除高噪声的影响, 有效地提取质量异常特征, 实时高效地监控动态过程运行状态已成为确保安全生产、提升经济效益的关键.

高噪声动态过程质量监控的研究主要围绕着高噪声数据的处理和质量异常模式的识别方法展开. 目前关于高噪声数据的处理大都集中在概率偏最小二乘方法、小波变换方法、最小均方算法^[5]、主元分析方法^[6-7]、经验模态分解方法等. 李庆华等^[8]引入 t 分布描述噪声, 通过改进的概率偏最小二乘(probabilistic partial least squares, PPLS)模型, 降低离群点和噪声的影响, 提高工业过程变量监控的鲁棒性. 姚家琪等^[9-10]构建的含噪多模态故障诊断系统, 通过经验小波变换(empirical wavelet transform, EWT)对数据进行重构降噪, 提高噪声适应性; Yin等^[11]在噪声干扰下进行故障诊断时, 运用经验模态分解方法将原始数据迭代包络, 分解降噪信号, 从而提取故障特征. 尽管这些高噪声处理方法得到了广泛的应用, 但仍有不足之处. 概率偏最小二乘方法、最小均方算法等根据统计原理构建的统计量需要服从特定分布, 而且残差变量随机波动^[12]. 小波变换方法和经验模态分解方法虽然克服了统计方法的局限性, 但其依然存在频率重叠和模式混合的不足^[13-14]. 在质量异常模式识别方面, 动态生产过程的




图1 动态过程的6种质量模式

综上所述, 变分模态分解模型弥补了现有方法在处理高噪声非平稳数据方面的不足, 具有更高的可靠度和精确度, 并在故障诊断、寿命预测、特征提取和模式识别领域取得了长足的进展^[27-28], 但该方法在生产过程质量异常监控领域的研究仍为鲜见, 而现有的生产过程质量监控方法在利用卷积神经网络进行质量异常识别时, 由于过程数据高噪声多模态等特点的影响, 监控效率和精确度通常较低. 本文将变分模态分解方法和卷积神经网络相结合, 构建一种新的高噪声动态生产过程质量监控模型. 首先, 将动态过程的原始数据分解为包含质量异常特征信息和高噪声数

运行状态通常会呈现出围绕关键质量特性设计目标值随机波动的质量正常模式和出现异常波动的5种质量异常模式(上升趋势、下降趋势、向上阶跃、向下阶跃和周期)^[3], 如图1所示. 质量正常和质量异常模式统称为质量模式. 近些年, 深度机器学习方法通过深层非线性网络结构实现了复杂函数的逼近, 获得了对于输入数据本质特征的强大抽取识别能力, 已成为制造过程质量模式监控方向的重要研究内容^[15]. 过程质量异常监控技术亦逐渐从基于统计技术的控制图方法^[16]、支持向量机(SVM)^[17]、反向传播神经网络(BPNN)^[18]等浅层学习方法过渡到深度置信网络^[19-20]、卷积神经网络等深度学习方法^[21-22].

变分模态分解(variational mode decomposition, VMD)能够有效地克服小波变换和经验模态分解依赖于极值点选取、频率重叠等问题, 引起了愈来愈多学者的关注^[14]. Zhao等^[23]使用变分模态分解模型处理风电机组非平稳、高噪声的振动数据, 实现对风电机组故障类型的诊断与识别. 王冉等^[24]为了提高锂电池剩余寿命预测精度, 提出基于变分模态分解与集成深度模型的锂电池剩余使用时长模型. 罗亦泳^[25]针对高噪声和非平稳的变形数据, 利用变分模态分解方法, 构建特征提取与智能分析模型, 提高数据的可靠性与精确度. Pang等^[26]结合使用自回归谱法与变分模态分解模型, 以解决时变和非平稳数据的模态识别问题.

据的两类本征模态函数, 通过VMD分离动态生产过程的高噪声干扰; 然后, 为了充分发挥CNN模型提取图像数据特征的能力, 通过灰度变换将消除高噪声的本征模态函数转换成质量图像, 构建动态过程质量异常识别的VMD-CNN模型, 进而提出基于VMD-CNN的动态过程质量异常实时监控框架; 最后, 利用仿真实验对比分析, 验证所提模型的有效性.

1 基于VMD的质量数据去噪预处理

1.1 质量异常数据的VMD模型

VMD是自适应非递归进行模态分解的方法, 该方法能够将所获取的高噪声动态过程数据分解

为多个稳定的包含该过程质量信息的本征模态函数(intrinsic model function, IMF), 以实现质量异常信息与噪声数据的分离. 下面首先按照 Dragomiretskiy 等^[13]提出的概念, 界定本征模态函数, 并介绍高噪声动态过程质量模式信息的变分模态分解原理.

本征模态函数是一种调幅调频信号, 其函数表达式为

$$u_k(t) = A_k(t) \cos(\Phi_k(t)). \quad (1)$$

其中: $A_k(t)$ 为振幅, $\Phi_k(t)$ 为相位, $u_k(t)$ 为原始数据分解至第 k 个时的本征模态函数.

VMD 的目标是将高噪声动态过程的数据流分解成 K 个离散的本征模态函数 $u_k(t)$ ($k = 1, 2, \dots, K$), 且其相应的中心频率为 ω_k ($k = 1, 2, \dots, K$).

假设本征模态函数的带宽是有限的, 并将高噪声动态过程质量信息记为 $f(t)$, 则高噪声动态过程质量模式的变分问题可描述为: 寻求 K 个本征模态函数 $u_k(t)$ ($k = 1, 2, \dots, K$), 使得所有本征模态函数的估计带宽之和最小, 并且满足各模态之和等于原始输入信号 $f(t)$ 的约束条件, 即

$$f(t) = \sum_k u_k(t). \quad (2)$$

为了估计有限带宽并确定对应的中心频率, 从而获得本征模态函数 $u_k(t)$, 首先对 $u_k(t)$ 进行希尔伯特变换, 可得到其解析表达式

$$\left(\delta(t) + \frac{j}{\pi t}\right) * u_k(t); \quad (3)$$

其次对该解析表达式进行频率调制, 表达式为

$$\left[\left(\delta(t) + \frac{j}{\pi t}\right) * u_k(t)\right] e^{-j\omega_k t}; \quad (4)$$

进而利用梯度平方范数估计本征函数 $u_k(t)$ 的带宽^[29], 其表达式为

$$\left\|\partial_t \left[\left(\delta(t) + \frac{j}{\pi t}\right) * u_k(t)\right] e^{-j\omega_k t}\right\|_2^2. \quad (5)$$

根据以上步骤, 可构建高噪声动态过程质量异常数据的 VMD 模型如下:

$$\begin{aligned} & \min \left\{ \sum_k \left\|\partial_t \left[\left(\delta(t) + \frac{j}{\pi t}\right) * u_k(t)\right] e^{-j\omega_k t}\right\|_2^2 \right\}; \\ & \text{s.t. } \sum_k u_k(t) = f(t). \end{aligned} \quad (6)$$

其中: ω_k 为第 k 个本征模态函数对应的中心频率, $\delta(t)$ 为单位冲击函数, $*$ 为卷积运算, $f(t)$ 为高噪声动态过程质量数据.

由式(6)可知, 高噪声动态过程质量异常数据的变分模态分解问题可归结为求解所有本征模态函数的估计带宽之和最小.

1.2 VMD模型的求解

为了获得高噪声动态过程质量数据 VMD 模型的最优解, 通过惩罚因子 α 使得包含噪声的多个本

征模态函数维持对原始数据的精确重构, 通过引入 Lagrange 乘子 λ , 保证式(6)约束条件的严格性, 并获得无约束条件的增广 Lagrange 函数, 其表达式如下:

$$\begin{aligned} L(u_k, \omega_k, \lambda) = & \alpha \sum_k \left\|\partial_t \left[\left(\delta(t) + \frac{j}{\pi t}\right) * u_k(t)\right] e^{-j\omega_k t}\right\|_2^2 + \\ & \left\|f(t) - \sum_k u_k(t)\right\|_2^2 - \left[\lambda(t), f(t) - \sum_k u_k(t)\right]. \end{aligned} \quad (7)$$

利用乘子交替方向法不断迭代求得表达式(7)的各个鞍点, 可分别获得 ω_k^{n+1} 和 $u_k(t)$, 其表达式如下:

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega}, \quad (8)$$

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{m \neq k} \hat{u}_m(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2}. \quad (9)$$

其中: \hat{u}_k^{n+1} 为剩余量 $\hat{f}(\omega) - \sum_{m \neq k} \hat{u}_m(\omega)$ 通过最小平方滤波器获得, 中心频率 ω_k^{n+1} 通过 $\hat{u}_k(\omega)$ 自适应确定.

1.3 质量数据去噪的VMD方法

为了利用 VMD 方法对高噪声动态过程进行变分模态分解, 需要对 VMD 的参数进行设置, 其中最重要的参数为本征模态函数个数 K . 本文使用互相关系数法^[30]确定该参数, 不仅可以避免所分解的模态模式产生混合, 而且可使得分解效果达到最优. 互相关系数公式为

$$\rho_{xy} = \frac{\sum_{k=1}^K [(x_k - \bar{x})(y_k - \bar{y})]}{\left[\sum_{k=1}^K (x_k - \bar{x})^2 \sum_{k=1}^K (y_k - \bar{y})^2\right]^{\frac{1}{2}}}. \quad (10)$$

阈值公式^[31]为

$$\mu = \frac{\max(\rho_{xy})}{10 \max(\rho_{xy}) - 3}. \quad (11)$$

其中: 互相关系数 ρ_{xy} 表示任意两个 x 和 y 之间的相关程度, $\max(\cdot)$ 表示最大值函数, 阈值 μ 可以确定这些相关关系的有效性.

由于本文考虑高噪声影响下的质量异常监控, 原始数据包含有噪声信息和质量异常特征, 通过枚举法设定 $K = 2, 3, \dots$, 不同取值多次实验, 最终确定 K 等于 2 时可以将噪声干扰和质量特征信息进行有效地分解. 进一步地, 分别计算本征模态函数 IMF₁、IMF₂ 与原始数据之间的互相关系数, 比较取得最大互相关系数确定阈值, 验证了 $K = 2$ 在理论方面的合理性. 通过对 VMD 方法中 K 的选择优化, 获得 IMF₁ 为原始数据中的质量特征信息, IMF₂ 可以作为高噪声分量进行去除, 从而有效避免本征模态函数的混合并

使分解效果最佳.

高噪声动态过程通常会呈现出正常模式和上升趋势、下降趋势、向上阶跃、向下阶跃、周期5种质量异常模式. 现给出向上阶跃异常模式的变分模态分解结果, 其他的将在本文的仿真实验中展示. 由于 $K = 2$, 通过变分模态分解, 将向上阶跃质量异常模式的原始数据分解为两个本征模态函数 IMF_1 和 IMF_2 , 如图2所示.




图2 向上阶跃异常模式的原始数据与IMF

由图2可知, 向上阶跃质量异常模式数据被分解为低频数据 IMF_1 和高频数据 IMF_2 . 本征模态函数 IMF_1 保留了向上阶跃质量异常模式的原始特征, IMF_2 则为随机噪声. 类似地, 通过VMD可分别将正常和异常6种质量模式的质量特征与高噪声干扰有效地分离, 以实现高噪声动态过程的去噪.

2 质量异常特征的CNN识别方法

2.1 质量图像获取

为了实现高噪声动态过程的去噪, 可将6种质量模式中包含随机噪声的 IMF_2 去掉, 仅保留 IMF_1 作为输入进行质量异常特征的识别. 为了借助CNN提取

图像数据特征的优势, 分别将 $N \times N$ 个反映动态过程质量异常信息的 IMF_1 数据, 构成如下的数据矩阵:

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1N} \\ x_{21} & x_{22} & \dots & x_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{NN} \end{bmatrix}. \quad (12)$$

可利用灰度变换分别将本征模态函数 IMF_1 的数据 $X_{uv}(u = 1, 2, \dots, N, v = 1, 2, \dots, N)$ 转化为像素为 $N \times N$ 的质量图像 Y , 从而通过灰度变换将数值数据转化为二维灰度图形式的质量图像, 以便充分发挥卷积神经网络模型对质量图像特征强大的学习和识别能力^[19]. 灰度变换公式为

$$y = INT \left[\frac{x_{uv} - \min(X)}{\max(X) - \min(X)} \right]. \quad (13)$$

其中: $INT[\cdot]$ 为取整函数, y 为范围为 $[0 \ 255]$ 的灰度值. 图2中向上阶跃质量异常模式的 IMF_1 数据被转换为如图3所示的质量异常图像.




图3 向上阶跃异常模式的IMF1图像

2.2 质量异常识别的CNN模型

CNN是可直接处理图像数据的深度学习方法. 下面构建基于CNN的高噪声动态过程质量异常识别模型. 用于高噪声动态过程质量异常识别的CNN结构可划分为质量异常特征提取和质量异常特征分类两部分, 如图4所示.

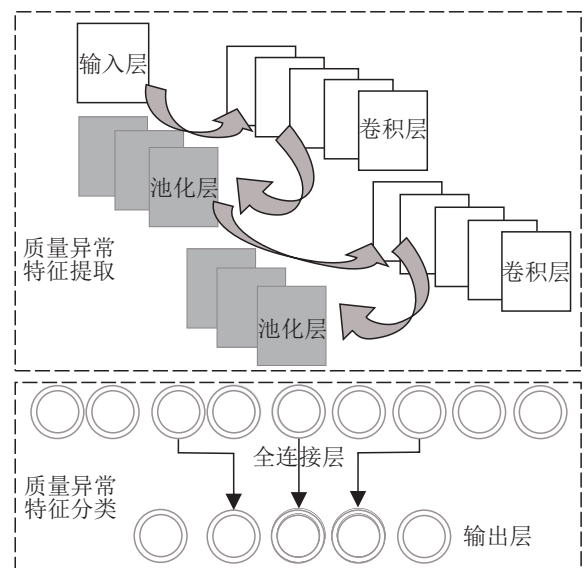


图4 质量异常识别的CNN结构

动态过程质量异常特征提取部分由多个交替连接的卷积层和池化层组成. 使用VMD去噪后的质量

图像作为CNN模型的输入层. 卷积层及池化层的作用是从图像数据中提取质量异常特征. 每一个卷积层包含多个尺寸相同的卷积核, 从而提取输入图像不同的质量特征图. 卷积运算的表达式为

$$Y_p^l = G\left(\sum_{q \in M_p} Y_p^{l-1} * w_{qp}^l + b_p^l\right). \quad (14)$$

其中: Y_p^l 为第 l 卷积层第 p 个输出质量特征图, M_p 为用于输出 Y_p^l 质量特征图的输入特征图子集, w_{qp}^l 为卷积核的权重, $*$ 为卷积运算, b_p^l 为卷积后的偏置项, G 为卷积层激活函数. 本文选用 ReLU 激活函数, 其表达式为

$$G(y) = \max(0, \lg(1 + e^y)). \quad (15)$$

卷积层之后是池化层, 池化层通过固定窗口大小聚合质量异常的局部特征, 从而在不损失总体质量特征的情况下, 实现降维和提高运行速率. 池化层的表达式为

$$Y_p^{l+1} = R[\beta_p^l d(Y_p^l) + e_p^l]. \quad (16)$$

其中: Y_p^{l+1} 为第 $l+1$ 池化层第 p 个输出质量特征图, 它由前一层卷积层输出质量特征图 Y_p^l 经过池化窗口加权和激活函数运算后获得; $d(\cdot)$ 为下采样函数; β_p^l 为池化层权重; e_p^l 为池化层的偏置项; $R[\cdot]$ 为池化函数. 本文使用最大池化方式, 采用尺寸为 $n \times n$ 的池化窗口, 对卷积层的输出进行无重叠的滑动聚合, 求得窗口内的最大值, 从而使池化层输出的质量特征图在两个维度上缩小了 n 倍. 通过交替连接的卷积层和池化层提取原始输入图像的多个不同质量特征图, 并使质量特征图的维度不断缩小至 1×1 .

质量异常分类由全连接层和输出层完成. 全连接层将前一层的所有质量特征进行加权并确定偏置, 形成一维质量特征向量, 以便确定输入质量图像所属的异常类别, 其函数表达式为

$$Y^l = h(w^l Y_p^{l-1} + b^l). \quad (17)$$

其中: Y^l 为全连接层输出, $h(\cdot)$ 为全连接层激活函数, w^l 为全连接层的权重, b^l 为全连接层的偏置项. 全连接层连接作为分类器的输出层. 本文选用 Softmax 分类器, 以加大分类差距使其具有更好的逻辑回归特性. 将全连接层的结果进行分类输出, 从而实现质量图像的分类.

3 基于VMD-CNN的质量异常监控框架

通过VMD方法对动态过程数据去噪后, 可利用CNN识别模型对质量异常特征进行提取与分类, 由此形成基于VMD-CNN的质量异常实时监控框架. 该框架共分为VMD去噪处理、CNN识别模型训练和质量异常实时监控3个阶段, 如图5所示.

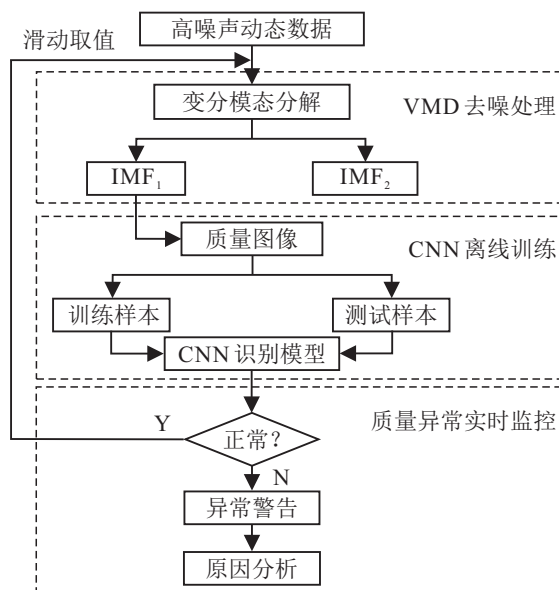


图5 动态过程质量异常实时监控框架

高噪声动态过程质量异常实时监控的具体步骤如下.

step 1: 实时采集动态过程质量模式原始数据, 并分别进行变分模态分解, 将其分解为低频数据的IMF₁和低频数据IMF₂.

step 2: 分别除去表示随机噪声的高频数据. 利用灰度变换将每种质量模式的IMF₁数据转化为质量图像, 并将其划分为训练样本和测试样本.

step 3: 将训练集中的质量图像作为CNN模型的输入, 并提取特征图进入CNN的卷积层和池化层. 经过若干次卷积运算和最大池化运算, 可进入全连接层和输出层, 获得完成训练的CNN模型.

step 4: 将测试集输入训练完成的卷积神经网络, 验证测试算法的性能, 获得质量异常的VMD-CNN识别模型.

step 5: 如果当前质量模式显示为正常模式, 则采用步长为1, 取值长度与训练集和测试集长度相同的滑动窗口, 返回step 1.

step 6: 如果当前质量模式显示为异常模式, 则VMD-CNN识别模型判别某种质量异常模式出现, 发出预警信号, 进而进行质量异常原因的诊断和排查.

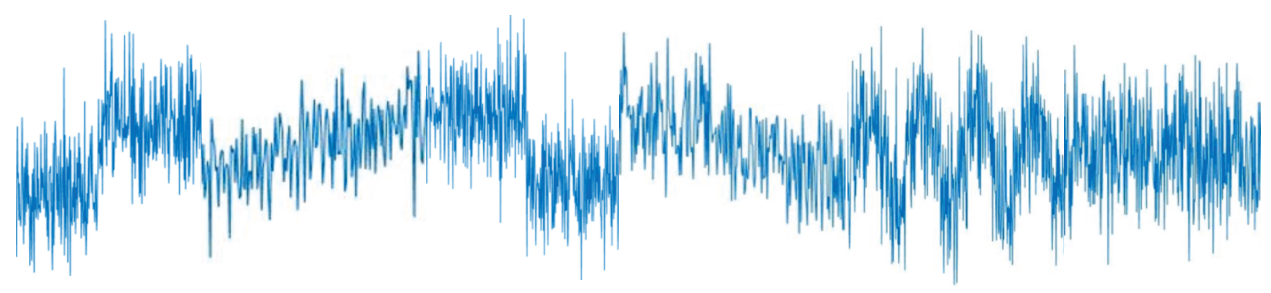
4 仿真实验分析

4.1 质量异常模式数据来源

为获得高噪声动态过程数据, 按照每种质量模式的公式, 通过蒙特卡洛方式模拟质量正常和异常的数据^[4], 如表1所示. 其中: $F(t)$ 为服从正态分布的随机噪声干扰, s 为斜率, a 为阶跃点位置, c 为阶跃幅度, A 为周期幅度, T 为周期, x 为过程数据变量. 以784为样本规模, 每种质量模式均产生1000个样本数据.

表1 质量模式的实验数据

向上阶跃	上升趋势	向下阶跃	下降趋势	周期	正常
$x_5(t) = F(t) + ac$	$x_4(t) = F(t) + st$	$x_3(t) = F(t) - ac$	$x_2(t) = F(t) - st$	$x_1(t) = F(t) + A \sin(2\pi/t)$	$x_0(t) = F(t)$



4.2 数据去噪与质量图像获取

按照1.3节中的方法利用VMD对所获取的质量模式数据进行去噪处理. 选取参数 $\alpha = 2000, K = 2$, 可将6种质量模式的样本数据分别分解为相应的两个本征模态分量 IMF_1 和 IMF_2 , 如图6所示. IMF_1 保留了原始数据的特征信息, IMF_2 为随机噪声. 因此,

可去除随机噪声 IMF_2 , 而将 IMF_1 样本数据转化成 28×28 的矩阵数据, 并利用灰度变换将该矩阵数据转换为相应的质量图像, 如图7所示. 进而将原始的高噪声动态过程数据经过变分模态分解去噪后转换为质量图像, 共获得了 1000×6 个规模为 28×28 的图像数据.

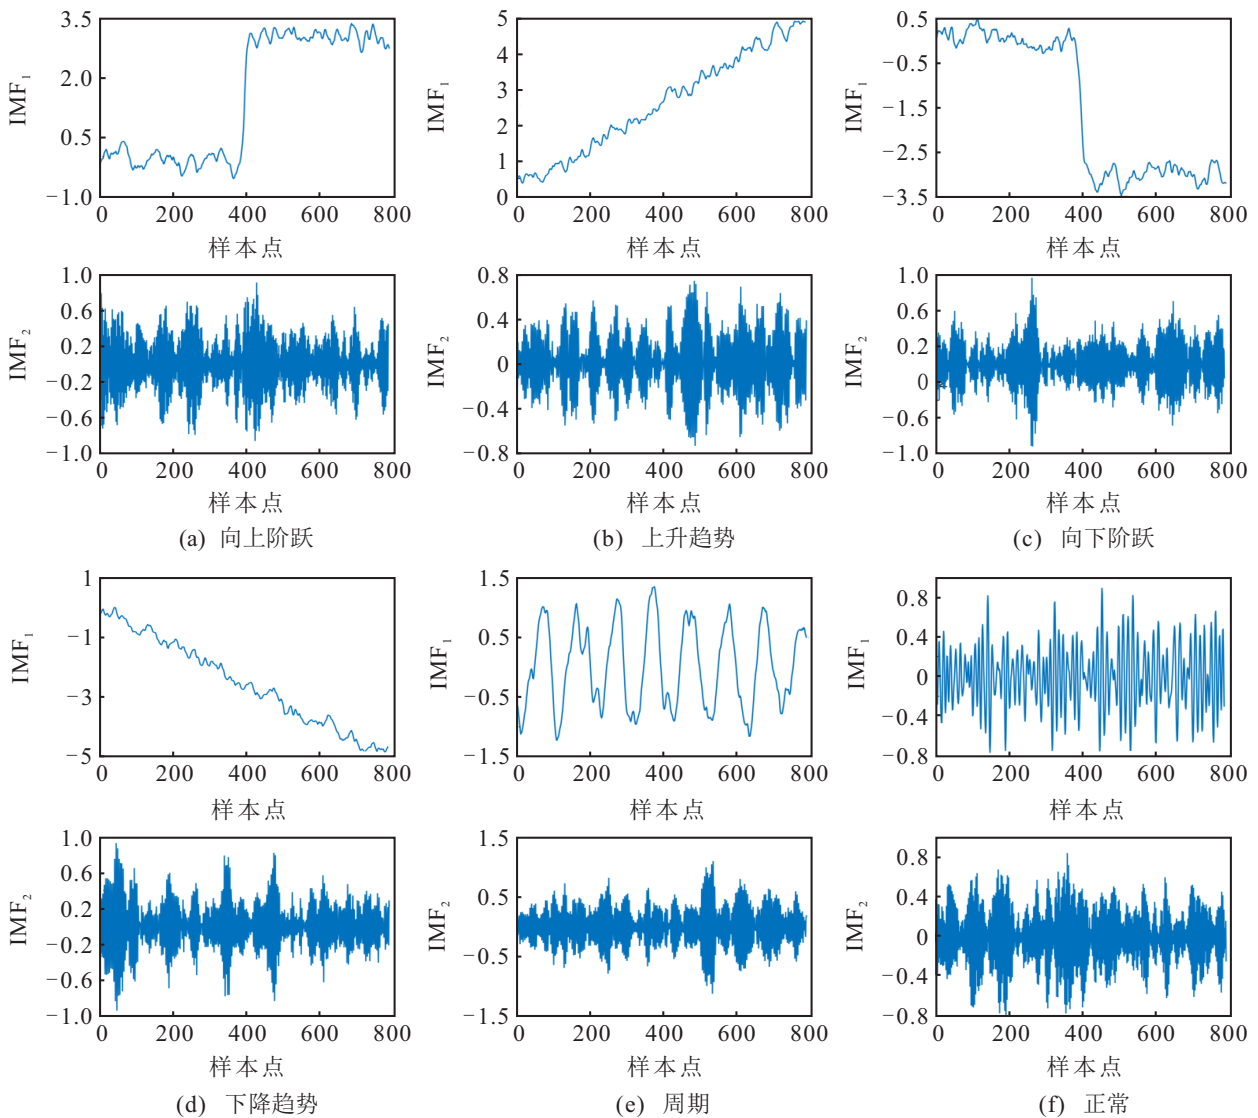


图6 VMD分解结果

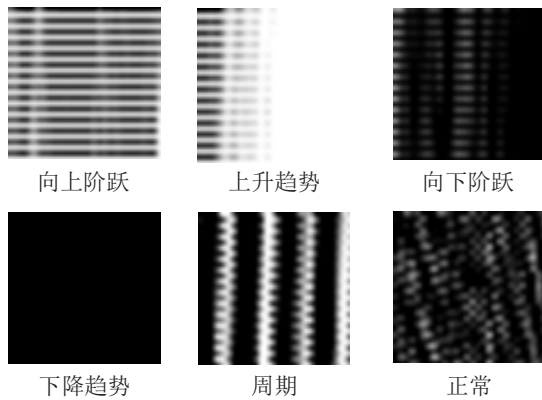


图7 IMF₁的质量图像

4.3 质量异常识别结果分析

本文采用 lenet-5 结构的卷积神经网络^[14], 其结构为输入层、3个卷积层、2个池化层、全连接层和输出层, CNN的网络结构与参数如表2所示。

表2 CNN网络结构与参数

网络结构	卷积核尺寸	数量	步长	激活函数
第1层卷积	3 × 3	8	1	Relu
第1层池化	2 × 2	8	2	最大池化函数
第2层卷积	3 × 3	16	1	Relu
第2层池化	2 × 2	16	2	最大池化函数
第3层卷积	3 × 3	32	1	Relu

随机从 1000 × 6 个规模为 28 × 28 的质量图中抽出 750 × 6 个作为本文训练样本, 剩余 250 × 6 个作为测试样本, 对 CNN 模型进行训练和测试。本文通过随机梯度下降算法对 CNN 训练, 学习率为 0.01, 最大迭代次数为 140, 输出层通过归一化操作进行逻辑分类, 从而识别出 6 种质量模式。高噪声动态过程质量异常识别结果如图 8 所示。




图8 质量异常识别结果

由图 8 可知, 经过 VMD 处理抑制了原始数据中高噪声非平稳特点的影响, 将质量图像作为输入构建卷积神经网络监控模型, 提高了质量异常模式识别效率和正确率。本文精确度表示正确识别质量图像模式的样本比率, 经过不断迭代, 所提模型的精确度最终稳定在 99.81%, 损失值趋近于 0。实验结果验证了本文所提模型的有效性。

4.4 对比分析

目前, 小波重构去噪和改进卷积神经网络是最为有效的动态过程去噪和质量异常识别的方法。为了验证基于 VMD-CNN 的动态过程质量异常方法的有效性, 分别将本文所提模型与文献[22]的改进卷积神经网络的模型 1 和文献[4]的小波重构的模型 2 进行对比分析。使用相同的动态过程实验数据比较 3 种模型的质量异常识别精确度, 其结果如表 3 所示。

表3 不同模型质量模式识别精确度 %

模型	上升趋势	下降趋势	向上阶跃	向下阶跃	周期	正常	平均精确度
模型 1	84	0	12	0	0	4	84.35
	0	83	0	14	0	3	
	13	0	84	0	0	3	
	0	14	0	84	0	2	
	0	1	0	0	84	15	
	0	0	0	0	13	87	
模型 2	99	0	1	0	0	0	99.03
	0	99	0	1	0	0	
	2	0	99	0	0	0	
	0	1	0	98	0	0	
	0	0	0	0	100	1	
	0	0	0	0	0	99	
本文模型	100	0	0	0	0	0	99.81
	0	99	0	1	0	0	
	1	0	100	0	0	0	
	0	0	0	99	0	0	
	0	0	0	0	100	1	
	0	0	0	0	1	99	

由表 3 可以看到, 将不同质量模式的动态过程数据输入模型 1 时: 上升趋势的识别精确度为 84%, 12% 被错误识别为向上阶跃, 4% 被识别为正常模式出现漏检情况; 下降趋势的识别精确度为 83%, 剩余 17% 被识别为向下阶跃和正常模式; 向上阶跃的识别精确度为 84%, 13% 被错误识别为上升趋势, 3% 被识别为正常模式, 同样出现漏检情况。由于模型 1 对 6 种质量模式分别识别时数据取整, 单一模式识别率之和在 99% ~ 101% 之间, 而模型 1 的 6 种质量模式平均精确度为 84.35%, 其他数据以此类推。数据结果显示本文所提 VMD-CNN 模型的平均识别精确度为 99.81%, 而模型 1 仅为 84.35%, 是 3 种模型中识别精度最低的, 因为尽管深度 CNN 模型具有较好的质量异常识别的效率, 但是如果未有效地消除数据的高噪声, 将会影响到动态过程质量异常的识别精度。虽然模型 2 利用小波重构方法去除了高噪声数据的干扰, 但是其使用了 BPNN 的浅层机器学习方法, 所以其识别精度不及本文所提的方法。实验对比显示, 基于 VMD-CNN 的动态过程质量异常识别方法不仅能

够有效地消除高噪声干扰,同时可极大地提高CNN识别模型的精度。

5 结论

在智能制造的生产过程中,由于数据的采集与存储方式传感器采样速率等随机因素的存在,造成高噪声动态过程的质量异常模式。如何消除高噪声的影响,对动态生产过程异常进行有效的监控是确保产品质量的关键。本文利用变分模态分解方法首先对动态过程中的高噪声进行分解,将原始数据分解为低频的质量特征数据和高频的噪声数据,通过去除高频本征模态函数实现去噪。进而通过灰度变换将保留原始质量异常特征的本征模型函数转化为质量异常图像,并利用卷积神经网络强大的图像特征提取能力,对质量异常图像进行分类,从而提供了基于VMD-CNN的高噪声动态过程质量异常的实时监控方法,最终有效地解决了高噪声处理难和质量异常识别精度低的问题。与现有动态过程质量异常方法的比较结果显示,本文所提方法的识别精度和效率明显优于其他方法。同时,所提方法不仅有效地处理了高噪声动态生产数据的质量异常监控问题,而且可拓展至高噪声非线性多维数据流或轮廓(profile)数据的研究中,这将是需要进一步研究的问题。

参考文献(References)

- [1] Liu J F, Cao X W, Zhou H G, et al. A digital twin-driven approach towards traceability and dynamic control for processing quality[J]. *Advanced Engineering Informatics*, 2021, 50: 101395.
- [2] Zhang M Q, Luo X L. Modified canonical variate analysis based on dynamic kernel decomposition for dynamic nonlinear process quality monitoring[J]. *ISA Transactions*, 2021, 108: 106-120.
- [3] 刘玉敏, 周昊飞. 基于小波重构与SVM-BPNN的动态过程在线智能监控[J]. *系统工程理论与实践*, 2016, 36(7): 1890-1897.
(Liu Y M, Zhou H F. On-line intelligent monitoring of dynamic process based on wavelet reconstruction and SVM-BPNN[J]. *System Engineering—Theory & Practice*, 2016, 36(7): 1890-1897.)
- [4] 周昊飞, 刘玉敏. 基于小波重构的动态过程LSSVM-BPNN在线智能监控模型[J]. *系统管理学报*, 2018, 27(2): 291-298.
(Zhou H F, Liu Y M. LSSVM-BPNN online intelligent monitoring model for dynamic process based on wavelet reconstruction[J]. *Journal of Systems & Management*, 2018, 27(2): 291-298.)
- [5] Shahdoosti H R, Hazavei S M. Image denoising in dual contourlet domain using hidden Markov tree models[J]. *Digital Signal Processing*, 2017, 67: 17-29.
- [6] 彭开香, 张丽敏. 基于核典型相关性-熵成分分析的工业过程质量监测方法[J]. *控制与决策*, 2021, 36(12): 2999-3006.
(Peng K X, Zhang L M. A quality monitoring method for industrial process based on kernel canonical correlation-entropy component analysis[J]. *Control and Decision*, 2021, 36(12): 2999-3006.)
- [7] Huang J, Yan X F. Related and independent variable fault detection based on KPCA and SVDD[J]. *Journal of Process Control*, 2016, 39(2): 88-99.
- [8] 李庆华, 陈家益, 潘丰, 等. 基于 t 分布噪声的鲁棒PPLS回归模型[J]. *系统工程理论与实践*, 2018, 38(9): 2416-2423.
(Li Q H, Chen J Y, Pan F, et al. Robust PPLS regression modeling[J]. *System Engineering—Theory & Practice*, 2018, 38(9): 2416-2423.)
- [9] 姚家琪, 荆华, 赵春晖. 一种面向噪声环境中旋转机械故障诊断的多模态耦合输入神经网络[J]. *控制与决策*, DOI: 10.13195/j.kzyjc.2021.1851.
(Yao J Q, Jin H, Zhao C H. A multimode coupled input neural network for rotating machinery fault diagnosis in the noisy environment[J]. *Control and Decision*, DOI: 10.13195/j.kzyjc.2021.1851.)
- [10] 马愈昭, 刘逵, 张岩峰, 等. CEEMD结合改进小波阈值的激光雷达信号去噪算法[J]. *系统工程与电子技术*, <https://kns.cnki.net/kcms/detail/11.2422.TN.20211215.0948.018.html>.
(Ma Y Z, Liu K, Zhang Y F, et al. Laser radar signal denoising method based on CEEMD and new wavelet threshold[J]. *Systems Engineering and Electronics*, <https://kns.cnki.net/kcms/detail/11.2422.TN.20211215.0948.018.html>.)
- [11] Yin C, Wang Y L, Ma G C, et al. Weak fault feature extraction of rolling bearings based on improved ensemble noise-reconstructed EMD and adaptive threshold denoising[J]. *Mechanical Systems and Signal Processing*, 2022, 171: 108834.
- [12] Yang C L, Sutrisno H. Reducing response delay in multivariate process monitoring by a stacked long-short term memory network and real-time contrasts[J]. *Computers & Industrial Engineering*, 2021, 153: 107052.
- [13] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [14] Dibaj A, Etefagh M M, Hassannejad R, et al. A hybrid fine-tuned VMD and CNN scheme for untrained compound fault diagnosis of rotating machinery with unequal-severity faults[J]. *Expert Systems with Applications*, 2021, 167: 114094.
- [15] Abell J A, Chakraborty D, Escobar C A, et al. Big data-driven manufacturing—Process monitoring-for-quality philosophy[J]. *Journal of Manufacturing Science and Engineering*, 2017, 139(10): 101009.
- [16] Farahani S, Xu B, Filipi Z, et al. A machine learning approach to quality monitoring of injection molding

- process using regression models[J]. *International Journal of Computer Integrated Manufacturing*, 2021, 34(11): 1223-1236.
- [17] Ismail M, Mostafa N A, El-assal A. Quality monitoring in multistage manufacturing systems by using machine learning techniques[J]. *Journal of Intelligent Manufacturing*, 2022, 33(8): 2471-2486.
- [18] 房鑫洋, 张洁, 吕佑龙, 等. 基于Attention-BLSTM的复杂产品制造质量预测方法[J]. *计算机集成制造系统*, <http://kns.cnki.net/kcms/detail/11.5946.TP.20211126.1817.008.html>.
(Fang Y Y, Zhang J, Lv Y L, et al. Attention-BLSTM-based quality prediction for complex products[J]. *Journal of Systems and Management*, <http://kns.cnki.net/kcms/detail/11.5946.TP.20211126.1817.008.html>.)
- [19] Liu Y M, Zhou H F, Tsung F, et al. Real-time quality monitoring and diagnosis for manufacturing process profiles based on deep belief networks[J]. *Computers & Industrial Engineering*, 2019, 136(7): 494-503.
- [20] Wang K, Yuan X F, Chen J, et al. Supervised and semi-supervised probabilistic learning with deep neural networks for concurrent process-quality monitoring[J]. *Neural Networks*, 2021, 136(4): 54-62.
- [21] Gonzalez-Val C, Pallas A, Panadeiro V, et al. A convolutional approach to quality monitoring for laser manufacturing[J]. *Journal of Intelligent Manufacturing*, 2020, 31(3): 789-795.
- [22] 赵哲耘, 刘玉敏, 王宁. 基于改进卷积神经网络的动态过程质量异常模式识别[J]. *工业工程与管理*, 2021, 26(4): 69-76.
(Zhao Z Y, Liu Y M, Wang N. Dynamic process quality abnormal pattern recognition based on improved convolutional neural network[J]. *Industrial Engineering and Management*, 2021, 26(4): 69-76.)
- [23] Zhao Q, Han T, Jiang D X, et al. Application of variational mode decomposition to feature isolation and diagnosis in a wind turbine[J]. *Journal of Vibration Engineering & Technologies*, 2019, 7(6): 639-646.
- [24] 王冉, 后麒麟, 石如玉, 等. 基于变分模态分解与集成深度模型的锂电池剩余寿命预测方法[J]. *仪器仪表学报*, 2021, 42(4): 111-120.
(Wang R, Hou Q L, Shi R Y, et al. Remaining useful life prediction method of lithium battery based on variational mode decomposition and integrated deep model[J]. *Chinese Journal of Scientific Instrument*, 2021, 42(4): 111-120.)
- [25] 罗亦泳. 基于变分模态分解与相关向量机的变形特征提取及智能分析研究[J]. *测绘学报*, 2021, 50(7): 991.
(Luo Y Y. Feature extraction and intelligent analysis of deformation based on variational mode decomposition and relevant vector machine[J]. *Acta Geodaetica et Cartographica Sinica*, 2021, 50(7): 991.)
- [26] Pang B, Nazari M, Tang G J. Recursive variational mode extraction and its application in rolling bearing fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2022, 165: 108321.
- [27] Li T R, Lu S X, Xu E J. Location detection method of detector in pipeline using VMD algorithm and machine learning classifier[J]. *Electronics*, 2021, 10(12): 1436-1447.
- [28] Paing M P, Tungjitkusolmun S, Bui T H, et al. Automated segmentation of infarct lesions in T1-weighted MRI scans using variational mode decomposition and deep Learning[J]. *Sensors*, 2021, 21(6): 1952-1971.
- [29] Li R H, Luo J, Hu B. Lamb wave-based damage localization feature enhancement and extraction method for stator insulation of large generators using VMD and wavelet transform[J]. *Sensors*, 2020, 20(15): 4205-4220.
- [30] 李华, 刘韬, 伍星, 等. 相关奇异值比的SVD在轴承故障诊断中的应用[J]. *机械工程学报*, 2021, 57(21): 138-149.
(Li H, Liu T, Wu X, et al. Application of SVD based on correlation singular value ratio in bearing fault diagnosis[J]. *Journal of Mechanical Engineering*, 2021, 57(21): 138-149.)
- [31] 罗小燕, 卢文海, 游义平, 等. 基于VMD和SVD联合降噪方法的球磨机振动信号随机噪声压制[J]. *噪声与振动控制*, 2019, 39(6): 169-175.
(Luo X Y, Lu W H, You Y P, et al. A method for ball mill vibration signal random noise suppression based on VMD and SVD[J]. *Noise and Vibration Control*, 2019, 39(6): 169-175.)

作者简介

- 刘玉敏(1956—), 女, 教授, 博士生导师, 从事质量工程、质量智能诊断等研究, E-mail: zzuym1@163.com;
- 王德园(1993—), 男, 博士生, 从事质量工程、缺陷检测等研究, E-mail: deyuanwang111@163.com;
- 王宁(1983—), 男, 教授, 博士生导师, 从事质量管理、过程监控等研究, E-mail: zz-wn@zzu.edu.cn;
- 田光杰(1994—), 男, 博士生, 从事质量管理、缺陷检测等研究, E-mail: guangjtian@163.com.