

# 基于改进 SOM 神经网络的数控机床振动故障自动检测系统设计

曹劲草<sup>1</sup>, 齐贺男<sup>2</sup>

(1. 陕西国防工业职业技术学院 智能制造学院, 西安 710300;

2. 苏州大学应用技术学院 工学院, 江苏 苏州 215325)

**摘要:** 针对数控机床信号在传输线上传播时因线路的阻抗不匹配导致信号的衰减、难以准确检测出振动信号的问题, 提出了一种基于改进 SOM 神经网络的数控机床振动故障自动检测系统; 采用 RS6103 振动传感器与改进的信号调理电路, 将衰减的电流信号转换为稳定电压信号并去除噪声, 以 EP4CE10 FPGA 为核心控制器; 通过免疫遗传算法优化 SOM 神经网络, 提高训练速度和检测精度; 系统从振动信号中提取特征向量, 利用改进后的 SOM 神经网络实现故障检测; 实验结果显示, 该系统能有效提升振动信号质量, 实现准确的振动故障检测。

**关键词:** 数控机床; 信号自动检测; 振动传感器; 改进 SOM 神经网络; 振动故障; 振动信号调理电路

## Design of Automatic Vibration Fault Detection System for CNC Machine Tools Based on Improved SOM Neural Network

CAO Jincan<sup>1</sup>, QI Henan<sup>2</sup>

(1. School of Intelligent Manufacturing, Shaanxi Institute of Technology, Xi'an 710300, China;

2. Institute of Technology, Soochow University College of Applied Technology, Suzhou 215325, China)

**Abstract:** The signals of computer numerical control (CNC) machine tools have the disadvantages of signal attenuation and difficulty in accurately detecting vibration signals caused by impedance mismatch in the transmission line. To address this problem, a CNC machine tool vibration fault automatic detection system based on an improved self organizing maps (SOM) neural network is proposed. By using a RS6103 vibration sensor and improved signal conditioning circuit, the attenuated current signal is converted into a stable voltage signal, and the noise is removed, with EP4CE10 FPGA as the core controller. Optimizing SOM neural network through immune genetic algorithm to improve training speed and detection accuracy. The system extracts feature vectors from vibration signals and uses the improved SOM neural network to achieve fault detection. Experimental results show that the system can effectively improve the quality of vibration signals and achieve the accurate detection of vibration faults.

**Keywords:** CNC machine tools; automatic signal detection; vibration sensor; improved SOM neural network; vibration fault; vibration signal conditioning circuit

## 0 引言

数控机床在高效运转的同时<sup>[1-2]</sup>, 也面临着振动问题的挑战。振动不仅会降低机床的加工精度, 导致零件

尺寸和形状出现偏差, 还会加速机床部件的磨损, 缩短设备的使用寿命<sup>[3]</sup>。振动问题的根源在于机床设计、制造工艺、使用环境或操作方式等多个方面, 因此, 对其进行深入分析和实时监测至关重要。

收稿日期:2025-01-13; 修回日期:2025-02-21。

基金项目:陕西国防工业职业技术学院 2023 年校级重点科研项目(Gfy23-07);陕西省“十四五”教育科学规划 2023 年度课题(SGH23Y3035)。

作者简介:曹劲草(1992-),男,硕士,讲师。

引用格式:曹劲草,齐贺男. 基于改进 SOM 神经网络的数控机床振动故障自动检测系统设计[J]. 计算机测量与控制, 2025, 33(6):86-93.

针对数控机床振动故障检测方法进行深入研究, 可以确保数控机床的稳定运行, 提升加工精度和设备寿命, 为制造业的持续健康发展提供有力保障。就现有研究成果来看, 已有振动故障检测系统由于应用算法、模型或者技术的缺陷, 无法获得精准的振动故障检测结果。其中, 文献 [4] 利用振动信号对铁路转辙机进行故障诊断, 通过变分模式分解 (VMD) 预处理振动信号, 结合多域特征提取与集成特征选择策略, 最终采用支持向量机 (SVM) 进行诊断分析。设计系统在实际应用中会受到环境噪声、设备老化等多种因素的干扰, 导致诊断准确率下降; 文献 [5] 以边云协同架构为基础, 利用一维卷积神经网络在边缘客户端进行本地模型训练, 基于云服务器端进行模型聚合和优化。通过减小数据上传规模和分担计算压力, 提高了故障诊断的效率和准确率。设计系统的实施需要边缘客户端和云服务器之间良好通信, 如果网络延迟或中断, 可能会影响模型的实时性和准确性; 文献 [6] 结合图论诊断法和小波包变换, 对数控机床进给系统进行未知故障诊断。通过图论模型快速定位故障原因, 再利用小波包变换进一步精确定位, 实现高效准确的诊断。图论诊断法会受到故障模型准确性和完备性的限制, 导致诊断结果出现偏差。与此同时, 小波包变换的计算复杂度和参数选择也是影响诊断性能的关键因素; 文献 [7] 基于增量学习的深度卷积诊断模型, 能够处理主轴轴承和刀具在不同转速下的故障诊断问题。通过人工判断跨转速诊断时的未知故障类型, 并重新输入网络进行增量学习, 实现知识迁移和模型更新。人工判断跨转速诊断时的未知故障类型会引入主观性和误差, 影响模型的准确性和可靠性。此外, 增量学习过程中的数据标签质量和数量也是影响模型性能的重要因素; 文献 [8] 基于多元状态评估和相关分析, 对汽轮发电机的轴振、瓦振进行异常预警和故障诊断。通过计算参量估计值与实际值的残差和相关系数残差, 提取异常特征, 并进行预警和诊断。设计系统会受到数据质量和数量的限制, 导致异常特征提取不准确或诊断结果出现偏差。为了解决上述问题或者缺陷, 提出基于改进 SOM 神经网络的数控机床振动故障自动检测系统设计研究。

## 1 系统硬件设计

系统软硬件总体设计如图 1 所示。

数控机床振动故障自动检测系统硬件设计以高效、准确、可靠为核心, 采用模块化结构, 主要包括振动传感器模块、振动信号调理电路模块和核心控制器模块。振动传感器模块选用高精度、低噪声的 RS6103 型号传感器, 确保振动信号采集的精准度。振动信号调理电路

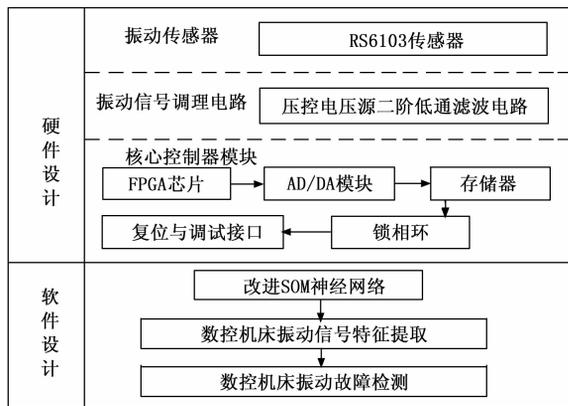


图 1 软硬件总体设计框图

模块经过改进设计, 包括流压转换、去噪/放大与滤波等环节, 有效解决了噪声干扰和信号衰减问题, 提高了振动信号的准确性和可靠性。核心控制器模块采用高性能、低功耗的 EP4CE10 型号 FPGA 芯片, 具有丰富的 I/O 资源和强大的处理能力, 能够满足复杂应用场景的需求, 为数控机床振动故障检测提供了坚实的支撑。整个系统硬件设计实现了信号采集、调理、处理和故障诊断的完整流程, 为实时监测和诊断数控机床振动故障提供了有力保障。

通过引入免疫遗传算法对 SOM 神经网络进行改进, 实现了连接权重的快速寻优, 从而大幅提升了振动故障的检测精度和速度。同时, 设计了振动信号特征提取方法, 从原始振动信号中精准地提取出多种关键特征, 为后续故障识别与诊断提供数据支持。在检测流程上, 实现了特征向量到振动故障类型的无缝映射, 确保了检测结果的准确性和实时性。

### 1.1 振动传感器模块

振动传感器的选择与配置是确保设计系统准确性和可靠性的关键所在。依据数控机床振动故障检测需求, 选取 RS6103 型号振动传感器作为设计系统的关键硬件之一, 应用其实时采集数控机床振动信号<sup>[9]</sup>。RS6103 型号振动传感器参数支持自定义, 可以迎合数控机床的振动特性, 最大限度地提升数控机床振动信号采集的精准度。RS6103 型号振动传感器参数自定义结果如表 1 所示。

需要注意的是, 在安装 RS6103 型号振动传感器之前, 应对其进行校准, 以确保数控机床振动信号测量结果的准确性。与此同时, 在使用过程中, 也应定期校准 RS6103 型号振动传感器, 以补偿因长期使用或者环境因素导致的性能变化<sup>[10]</sup>。此外, RS6103 型号振动传感器的安装位置和方向对数控机床振动信号测量结果有很大影响, 故应该确保 RS6103 型号振动传感器安装在数

表 1 RS6103 型号振动传感器参数自定义表

参数名称	参数配置
测量范围/(mm/s)	1 270
横向灵敏度比/%	≤5
振幅非线性/%	1
灵敏度/mm	4
频率响应/Hz	4~4 000
激励电压/VDC	18~28
噪声/ $\mu$ V	<50
恒流源激励/mA	2~10
满量程输出/V	5
输出阻抗/ $\Omega$	<100
偏置电压/V	10~12
对地绝缘/ $\Omega$	≥108
工作温度/ $^{\circ}$ C	-40~+121
冲击极限/g	3 000

控机床振动幅度最大的位置，并正确设置振动信号的测量方向，以此来获取准确的数控机床振动信息（具体见 3.1 节）。

### 1.2 振动信号调理电路模块

振动信号调理电路作为数控机床振动故障检测系统的前端核心组件之一，承担着将振动传感器捕捉到的微弱信号放大、滤波、转换等重要任务，以便后续的信号处理与分析能够准确有效地进行。然而，现有数控机床振动故障检测系统中的振动信号调理电路存在着诸多不足，例如噪声干扰、信号衰减、信号处理不准确等问题，已成为制约系统性能提升的瓶颈。其中，噪声干扰是振动信号调理电路面临的首要挑战。在工业生产环境中，数控机床的运行伴随着复杂的电磁环境和机械振动，其都可能成为噪声源，干扰振动信号的纯净性。噪声不仅可能掩盖微弱的振动故障信号，还可能引起误报或漏报，降低振动故障检测的准确性。信号衰减是另一个不可忽视的问题。振动信号在传输过程中，由于电路元件的非理想特性（例如电阻、电容的损耗）、线路阻抗不匹配等原因，会导致信号强度逐渐减弱。信号衰减不仅会降低信号的信噪比，还可能使得某些关键振动故障特征信息丢失，影响振动故障诊断的敏感度。

为了解决上述问题，设计系统对振动信号调理电路进行改进设计。改进后的振动信号调理电路主要包括流压转换、去噪/放大与滤波 3 个环节，通过协同作用可以将传感器输出的微弱电流信号转换为稳定的电压信号，并有效地去除噪声干扰，提高振动信号的准确性和可靠性。振动信号调理电路改进结果如图 2 所示。

如图 2 所示，流压转换电路采用高精度电流环结构，将传感器输出的电流信号转换为电压信号。电流环结构具有高精度和低噪声的特点，能够确保转换后的电

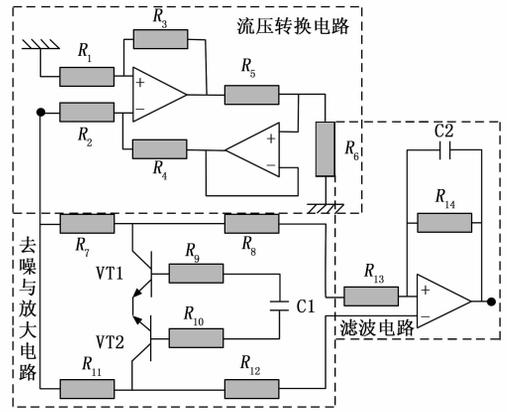


图 2 振动信号调理电路改进设计图

压信号稳定且准确；去噪与放大电路主要由压控电压源二阶低通滤波电路与同相电压放大电路构成。其中，压控电压源二阶低通滤波电路能够滤除高频噪声，保留低频振动信号。通过合理设计滤波器的参数，可以确保滤波效果达到最佳。同相电压放大电路对电压信号进行放大处理，使其符合振动传感器的采集要求。同相电压放大电路具有输入阻抗高、输出阻抗低的特点，能够确保信号的稳定性和准确性<sup>[11]</sup>。同时，通过调整放大器的增益，可以实现对不同振动信号的灵活处理；滤波电路对振动信号进行滤波处理，以进一步去除可能存在的噪声干扰，最大限度地提升振动信号的质量，达到振动信号调制的效果。

### 1.3 核心控制器模块

已有系统（如文献 [4-8]）控制器存在着处理速度慢、控制精度不足、扩展性差、通信稳定性差等缺陷，极大地降低系统的应用性能。因此，设计系统选取 EP4CE10 型号 FPGA 芯片作为核心控制器，其具有高性能、低功耗、丰富的 I/O 资源、高效的嵌入式内存、强大的 DSP 处理能力、灵活的时钟结构等优势，有助于系统的设计与开发。

依据设计系统需求，合理配置核心控制器（EP4CE10 型号 FPGA 芯片）的资源，如表 2 所示。

通过表 2 所示的资源配置，核心控制器（EP4CE10 型号 FPGA 芯片）能够满足多种复杂应用场景的需求，为数控机床振动故障检测提供充足的支撑。

## 2 数控机床振动故障自动检测方法设计

### 2.1 SOM 神经网络改进方法

SOM 神经网络是振动故障检测的主要应用模型之一，由于原始 SOM 神经网络由于输入层神经元与竞争层神经元之间的连接权重寻优难度较大，致使其训练速度较慢，振动故障检测精度较低<sup>[12]</sup>。因此，设计系统采用免疫遗传算法（IGA）对其进行改进，主要是针对

连接权重寻优环节, 为振动故障识别与诊断提供优质的模型支撑。

SOM 神经网络是一种无监督学习的神经网络模型, 其能够将输入数据映射到一个低维的、通常是离散的输出空间, 同时保持输入数据的拓扑结构。免疫遗传算法 (IGA) 是一种结合免疫算法和遗传算法的优化方法, 其利用免疫系统的多样性和自我调节能力来增强遗传算法的搜索性能<sup>[13]</sup>。基于免疫遗传算法 (IGA) 的 SOM 神经网络模型连接权重 (输入层神经元与竞争层神经元之间的连接强度) 寻优过程如表 2 所示。

表 2 核心控制器资源配置表

资源类型	配置数值	配置说明
逻辑单元	10 000 个	用于实现逻辑设计与算法
I/O 口	179 个	支持 LVDS、LVPECL 等标准, 可用于连接外设和接口
嵌入式内存	414 kbit	46 个嵌入式存储单元, 每个单元 9 kbit, 用于数据缓存、临时存储等
乘法器	360 个	乘法器规格为 $18 \times 18$ , 支持高速 DSP 运算, 适用于信号处理、图像处理等应用
锁相环	2 个	PLL 锁相环独立, 用于时钟管理和频率合成, 支持多种时钟域之间的同步
全局时钟网络	10 个	提供低延迟、高扇出的时钟信号, 确保设计系统中时钟信号的稳定性和一致性
通信接口	8 种	RS485、CAN 总线、网线接口 (RJ45)、HDMI、VGA、I2C、SPI、UART 等, 支持多种通信协议, 便于设计系统集成和扩展, 用于连接各种传感器和执行器
模拟/数字转换模块	1 个	板载 AD/DA 模块, 实现模拟信号与数字信号的转换, 适用于模拟信号处理场景
存储器	3 个	W25Q16、EEPROM 和 SDRAM, 用于存储程序、数据和配置参数等
复位与调试接口	2 个	机械式复位按键和 FPGA 下载器接口, 用于程序的复位控制和下载、固化以及调试等
电源	1 个	6~12 V 的直流电源, 为设计系统提供稳定的电源供应

### 1) 编码与初始化种群:

将 SOM 神经网络的连接权重矩阵表示为遗传算法中的个体, 即每个个体是一个包含所有连接权重的向量。随机生成一个包含  $N$  个个体的初始种群, 其中, 每个个体代表一组可能的连接权重, 即  $P_0 = \{\omega_1, \omega_2, \dots, \omega_i, \dots, \omega_N\}$ 。其中,  $\omega_i$  是第  $i$  个个体的连接权重向量。

### 2) 计算适应度:

适应度函数主要根据 SOM 神经网络振动故障检测

均方误差来构造, 用于评估每个个体的优劣, 表达式为:

$$f(\omega_i) = \frac{1}{\frac{1}{M} \sum_{j=1}^M (Q_j - \hat{Q}_j)^2} \quad (1)$$

式中,  $f(\omega_i)$  为个体  $\omega_i$  的适应度值。 $f(\omega_i)$  越大, 表明个体  $\omega_i$  越优秀;  $\frac{1}{M} \sum_{j=1}^M (Q_j - \hat{Q}_j)^2$  为振动故障检测均方误差;  $M$  为样本总数量;  $Q_j$  为第  $j$  个个体的振动故障检测结果;  $\hat{Q}_j$  表示第  $j$  个个体的振动故障实际结果。

### 3) 选择操作:

根据适应度值选择一定数量的个体作为父代, 用于生成下一代。设计系统依据轮盘赌选择策略计算个体被选中作为父代的概率, 表达式为:

$$p(\omega_i) = \frac{f(\omega_i)}{\sum_{i=1}^N f(\omega_i)} \quad (2)$$

式中,  $p(\omega_i)$  为个体  $\omega_i$  被选中作为父代的概率。

### 4) 交叉与变异操作:

(1) 交叉操作, 设计系统依据单点交叉策略对父代个体进行交叉操作, 生成新的子代个体, 其连接权重向量由父代个体的连接权重向量组合而成<sup>[14]</sup>。

(2) 变异操作, 设计系统主要是通过对连接权重向量中的某些元素进行随机扰动, 实现子代个体的变异操作, 以增加种群的多样性。

需要注意的是, 交叉概率  $p_c$  和变异概率  $p_m$  需要依据具体应用场景进行设置, 分别控制交叉和变异操作的发生频率。

### 5) 引入免疫机制:

将训练样本  $\{Y_1, Y_2, \dots, Y_j, \dots, Y_M\}$  视为抗原, 将 SOM 神经网络的连接权重视为抗体。通过计算抗体与抗原之间的亲和度, 保留高亲和度的抗体进行繁殖, 表达式为:

$$\alpha(\omega_i, Y_j) = \beta \frac{p(\omega_i)}{(Q_j - \hat{Q}_j)^2} \quad (3)$$

式中,  $\alpha(\omega_i, Y_j)$  为抗体  $\omega_i$  与抗原  $Y_j$  之间的亲和度;  $\beta$  为亲和度计算辅助参量, 其取值范围为  $0 \sim 1$ 。

记录历史中表现优秀的个体 (即高适应度值个体), 对其进行克隆, 生成多个相同的个体, 以增加其在种群中的比例。与此同时, 对克隆后的个体进行微调, 以提高其适应度值<sup>[15]</sup>。

### 6) 更新种群与终止条件:

将新生成的子代个体加入种群中, 并替换掉适应度值较低的父代个体, 更新后的种群记为  $P_t$ 。如果免疫遗传算法 (IGA) 达到最大迭代次数  $T$ , 则停止算法迭代运算; 否则, 返回步骤 2 继续迭代。

7) 应用寻优后的连接权重:

经过多轮迭代后, 得到最优的连接权重向量  $\hat{\omega}_i$ , 即适应度值最高的个体, 将其应用于 SOM 神经网络中, 以提高其训练速度和振动故障检测准确率, 从而完成了 SOM 神经网络的改进与优化。

## 2.2 数控机床振动信号特征提取方法

将利用 RS6103 型号振动传感器实时采集并调理后的数控机床的振动信号记为  $x(n)$ , 提取其特征——均值、峰峰值、峰值因子、偏度、峭度、均方频率、重心频率与频率方差, 为后续数控机床振动故障识别与诊断提供依据。振动信号特征提取公式为:

$$\left\{ \begin{aligned} a_1 &= \frac{\sum x(n)}{N_{\text{total}}} \\ a_2 &= \max[x(n)] - \min[x(n)] \\ a_3 &= \frac{\max[x(n)]}{\sqrt{\frac{\sum [x(n)]^2}{N_{\text{total}}}}} \\ a_4 &= \alpha(\omega_i, Y_j) \sum [x(n) - a_1]^{2/3} \\ a_5 &= \sum [x(n) - a_1]^2 - 3 \\ a_6 &= \frac{\sum [F(n)]^2 s(n)}{\sum s(n)} \\ a_7 &= \frac{\sum F(n) s(n)}{\sum s(n)} \\ a_8 &= \frac{\sum [F(n) - a_7]^2 s(n)}{\sum s(n)} \end{aligned} \right. \quad (4)$$

式中,  $a_1$  为振动信号的均值, 反映了振动信号的中心趋势;  $N_{\text{total}}$  为振动信号的总采样点;  $a_2$  为振动信号的峰峰值, 即振动信号幅值最大值和最小值之间的差值, 反映了振动信号的变化范围;  $\max[\cdot]$  与  $\min[\cdot]$  为最大值与最小值函数;  $a_3$  为振动信号的峰值因子, 即振动信号中尖峰的大小, 用于评估振动信号的峰值特性;  $a_4$  为振动信号的偏度, 衡量振动信号概率密度函数的偏斜程度, 即振动信号分布的不对称性。一般情况下, 正偏度表示振动信号右偏, 负偏度表示振动信号左偏;  $a_5$  为振动信号的峭度, 反映一段时间内振动信号分布的尖锐程度, 即信号四阶中心矩与方差平方的比值减去 3;  $a_6$  为振动信号的均方频率, 反映了振动信号频率成分的平均能量;  $F(n)$  为振动信号  $x(n)$  的频率;  $s(n)$  为振动信号  $x(n)$  的频率谱密度;  $a_7$  为振动信号的重心频率, 反映了振动信号频率分布的中心位置信息;  $a_8$  为振动信号频率方差, 衡量了振动信号频率成分的分散程度<sup>[16]</sup>。

将上述提取的振动信号特征记为向量形式  $\mathbf{A} = [a_1 \ a_2 \ a_3 \ a_4 \ a_5 \ a_6 \ a_7 \ a_8]^T$ , 方便后续研究

的应用。

## 2.3 数控机床振动故障检测方法

将 2.2 节提取的数控机床振动信号特征向量  $\mathbf{A}$  输入至改进 SOM 神经网络中, 模型输出结果即为数控机床振动故障检测结果, 具体流程如下所示:

1) 输入层加载数控机床振动信号特征向量  $\mathbf{A}$ , 将其作为改进 SOM 神经网络的输入数据<sup>[17]</sup>。与此同时, 依据输入数据设置输入层神经元数量为 1 个;

2) 设定竞争层神经元数量为  $N$  (通过改进 SOM 神经网络模型训练获取), 每个神经元代表一种振动故障类型, 通过 2.1 节确定其与输入层神经元之间的连接权重向量为  $\hat{\omega}_i$ 。竞争学习原理为: 将输入特征向量  $\mathbf{A} = [a_1 \ a_2 \ a_3 \ a_4 \ a_5 \ a_6 \ a_7 \ a_8]^T$  与竞争层中每个神经元的连接权重向量  $\hat{\omega}_i$  进行比较, 找到最匹配的神经元 (即欧几里德距离最小的神经元), 该神经元被称为最佳匹配单元 (BMU), 其对应的振动故障类型即为数控机床振动故障的检测结果<sup>[18]</sup>。欧几里德距离计算公式为:

$$D(\mathbf{A}, \hat{\omega}_i) = a_8 \sqrt{\sum_{l=1}^8 \sum_{i=1}^N \sum_{j=1}^N \bar{\chi} (a_l - \hat{\omega}_{ij})^2} \quad (5)$$

式中,  $D(\mathbf{A}, \hat{\omega}_i)$  为振动信号特征向量与第  $i$  个神经元连接权重向量之间的欧几里德距离;  $\bar{\chi}$  为欧几里德距离计算辅助参数, 其取值范围为  $[0, 1]$ <sup>[19]</sup>;  $a_l$  为振动信号特征向量中的第  $l$  个分量;  $\hat{\omega}_{ij}$  表示第  $i$  个神经元连接权重向量  $\hat{\omega}_i$  中的第  $j$  个分量。最佳匹配单元确定规则如下式所示:

$$W_i = \underset{i}{\operatorname{argmin}} D(\mathbf{A}, \hat{\omega}_i) \quad (6)$$

式中,  $W_i$  为最佳匹配单元, 即神经元及其对应的振动故障类型。

3) 输出层根据振动信号特征向量在竞争层上的映射位置  $W_i$ , 获取其所属的振动故障类型, 输出数控机床振动故障检测结果 (第  $i$  个神经元对应的振动故障类型)<sup>[20]</sup>。综上所述, 在 SOM 神经网络的改进与应用背景下, 实现了数控机床振动故障的检测, 为数控机床安全、稳定运行提供有效的助力。

## 3 实验与结果分析

选择基于边云协同的振动故障检测系统 (文献 [5] 系统)、基于增量学习的振动故障检测系统 (文献 [7] 系统) 分别作为对照系统 1 与对照系统 2, 并将设计系统设置为实验系统, 通过数控机床振动故障检测对比实验, 通过实验数据记录、处理与计算, 验证设计方法的应用效果。

### 3.1 实验场景搭建

选取某型号数控机床作为实验对象, 联合数控机床

振动故障检测对比实验需求, 搭建实验场景。

为了方便后续实验的进行, 对数控机床全部振动故障类型进行确定与编码, 如表 3 所示。

表 3 振动故障类型确定与编码表

类别	振动故障类型	编码
主轴振动故障	主轴不平衡	K1
	主轴偏摆	K2
	主轴松动	K3
进给轴振动故障	工件不平衡	K4
	夹具不稳定	K5
	切削力不平衡	K6
机械传动系统振动故障	传动链条松动	K7
	齿轮啮合不良	K8
其他振动故障	刀具振动	K9
	冷却系统故障	K10
	机床结构松动	K11

### 3.2 改进 SOM 神经网络训练

从 CWRU 数据集中随机抽取两个数据集合, 分别为训练集合与测试集合, 如表 4 所示。

表 4 数据集合构建表

振动故障类型编码	训练集样本数量/个	测试集样本数量/个
K1	45	96
K2	32	88
K3	41	75
K4	65	66
K5	78	105
K6	101	120
K7	89	114
K8	77	101
K9	35	85
K10	31	75
K11	68	62

应用训练集合与 2.1 节所示的免疫遗传算法 (IGA) 对改进 SOM 神经网络模型进行训练, 从而确定改进 SOM 神经网络模型参数的最佳取值, 如下所示:

- 1) 种群大小: 200;
- 2) 遗传代数: 100;
- 3) 交叉概率: 0.7;
- 4) 变异概率: 0.002;
- 5) 免疫算子参数: 0.5;
- 6) 亲和度计算辅助参量: 0.3;
- 7) 欧几里德距离计算辅助参数: 0.6。

### 3.3 振动信号调理性能分析

随机在测试集合中抽取一个样本作为实验对象, 应用实验系统、对照系统 1 与对照系统 2 对其振动信号进行调理。对照系统的调理过程如下: 对照系统 1 去除振

动信号中的异常值和噪声, 并放大信号, 突出振动信号中的关键特征, 从原始信号中提取出对故障诊断最有价值的特征, 从而减小数据上传的规模, 提高振动信号调理效率; 而对照系统 2 通过振动传感器采集数控机床的振动信号, 并经过去噪、放大和滤波等操作, 提高信号的质量和清晰度。从振动信号中提取时域特征、频域特征, 利用增量学习算法对模型进行训练和更新, 实现了模型的持续优化和性能提升, 实现信号调理, 如图 3 所示。

相较于原始振动信号来看, 实验系统、对照系统 1 与对照系统 2 应用后均能够去除一定体量的噪声信号, 显著提升了振动信号的整体质量。与对照系统 1 与对照系统 2 相比较, 由于实验系统改进设计了振动信号调理电路, 致使其振动信号调理结果信噪比更高, 整体质量更好。实验系统中的振动信号调理电路是一个精心设计的组合, 其包括流压转换子电路、去噪/放大子电路以及滤波子电路。其中, 流压转换子电路负责将振动传感器捕捉到的机械振动电流信号转换为电压信号, 不仅确保了信号的准确性, 还为后续的去噪和放大步骤提供了稳定的输入。通过精确的流压转换, 电路能够捕捉到更细微的振动变化, 这对于提高信号的分辨率至关重要; 去噪/放大子电路对转换后的振动信号进行初步处理, 有效地识别并去除信号中的噪声成分。同时, 其还具有信号放大功能, 能够增强信号的强度, 使其在后续处理中更加易于检测和解析。去噪/放大子电路对于提升信号的信噪比至关重要, 因为其直接减少了噪声对信号质量的干扰; 滤波子电路对去噪/放大后的信号进行进一步的优化, 能够根据信号的频率特性进行精确筛选。通过滤除不必要的高频成分, 滤波子电路能够进一步提纯信号, 使其更加接近真实的振动特征。滤波子电路不仅提高了信号的清晰度, 还为后续的信号分析和处理提供了更加可靠的基础。由此可见, 实验系统的振动信号调理性能更佳。

### 3.4 振动信号特征提取性能分析

随机在测试集合中抽取 60 个样本作为实验对象, 应用实验系统、对照系统 1 与对照系统 2 对振动信号特征进行提取, 以振动信号偏度特征为例, 显示振动信号特征提取性能, 如图 4 所示。

实验系统应用后提取的振动信号偏度特征与实际特征趋于一致, 而对照系统 1 与对照系统 2 应用后提取的振动信号偏度特征与实际特征存在着较大的偏差。这主要是因为实验系统通过改进设计振动信号调理电路对原始振动信号进行有效处理, 最大限度地提升了振动信号的整体质量, 使其特征更加凸显, 从而提高了振动信号偏度特征的提取精度, 为数控机床振动故障的自动检测

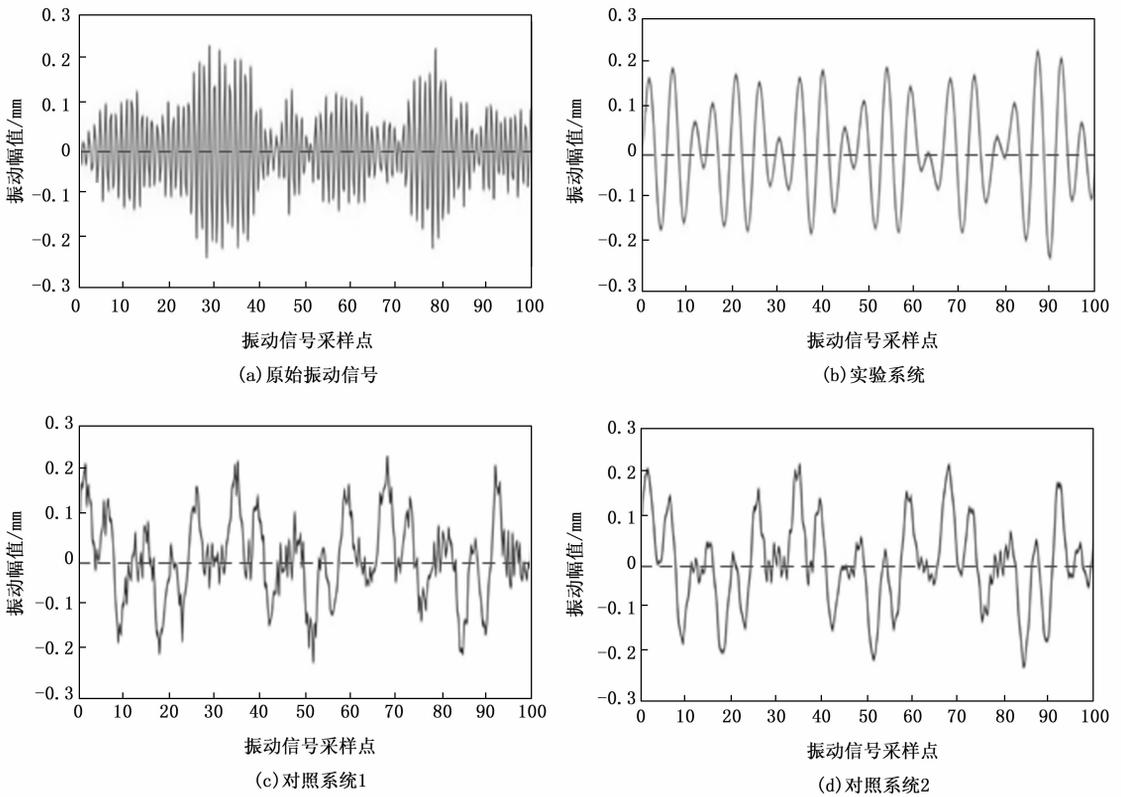


图 3 振动信号调理结果示意图

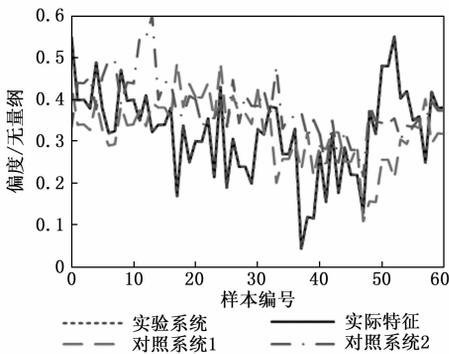


图 4 振动信号偏度特征提取结果示意图

### 3.5 振动故障检测性能分析

在测试集合每种振动故障类型中随机抽取 5 个样本作为实验对象，应用实验系统、对照系统 1 与对照系统 2 对其进行检测，如图 5 所示。

应用实验系统获取的振动故障检测结果与实验对象所属的振动故障类型编码相同，而应用对照系统 1 与对照系统 2 获取的振动故障检测结果与实验对象所属的振动故障类型编码不一致。这主要是因为实验系统引入并改进了 SOM 神经网络，SOM 神经网络作为一种无导师学习方法，具有良好的自组织和可视化特性。在振动故障检测中，SOM 神经网络能够通过输入振动信号特征的学习与训练，自动找到具有相似特征的向量数据

提供更加精准的特征数据支撑。

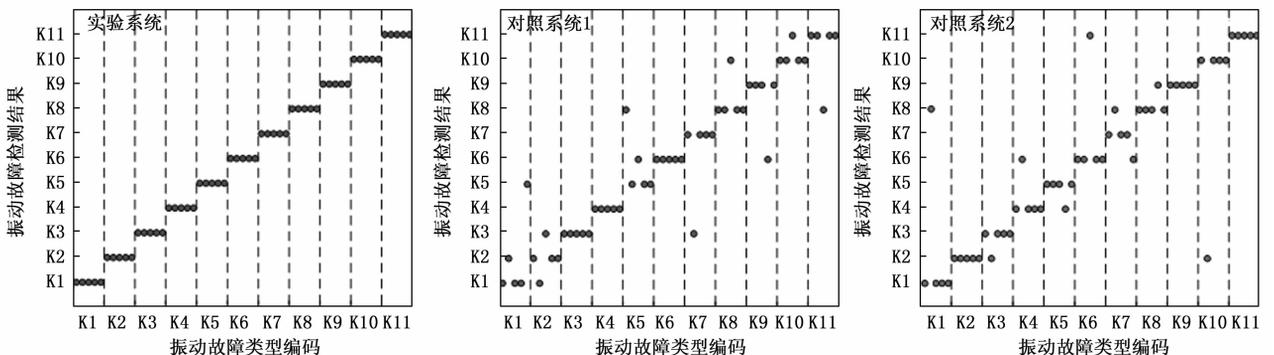


图 5 振动故障检测结果示意图

(竞争层神经元), 进而实现对不同振动故障类型的有效检测。在实验系统中, 为了进一步优化 SOM 神经网络的性能, 应用免疫遗传算法 (IGA) 对 SOM 神经网络进行了改进, 即对 SOM 神经网络连接权重向量进行寻优。免疫遗传算法首先通过初始化种群生成一系列候选的连接权重向量集, 随后利用遗传操作——选择、交叉和变异, 来迭代地优化连接权重向量, 以期找到能够更准确地映射输入振动信号特征与振动故障类型之间关系的配置。关键的是, 免疫遗传算法还引入了免疫机制, 有效避免了早熟收敛和陷入局部最优的问题。此外, 免疫遗传算法 (IGA) 设计了专门的适应度函数来评估每个候选连接权重向量的优劣, 确保了改进后的 SOM 神经网络在振动故障检测任务中具有更高的准确性和鲁棒性。

#### 4 结束语

本文围绕数控机床在运行过程中普遍存在的振动问题展开了深入研究, 探讨了振动对机床加工精度、表面质量以及部件磨损等方面的影响, 并强调了振动故障检测在预防机械故障、保障生产效率和机床稳定性方面的重要性。通过引入基于改进 SOM 神经网络的数控机床振动故障自动检测系统, 本文旨在为数控机床的振动故障检测提供一种非侵入式、安全高效的解决方案。研究结果显示, 该系统能够有效地识别和分析机床振动信号中的异常特征, 从而及时发现潜在的故障隐患, 避免机床因故障而导致的停机时间和维修成本增加。

然而, 本研究仍存在一些不足之处。针对不同类型的数控机床和不同的振动故障类型, 系统的适应性和泛化能力也需要进行更深入的研究和优化。未来, 本研究将致力于进一步完善数控机床振动故障自动检测系统的设计和优化, 以实现针对不同类型机床和故障类型更精确的检测。

#### 参考文献:

[1] 史 燕, 吴 璞. 基于 PID 控制的多轴联动数控机床运动误差补偿 [J]. 计算机仿真, 2023, 40 (1): 278-282.

[2] 徐丹丹, 张 帝. 基于数据驱动和本体建模的数控机床主轴故障诊断与推理 [J]. 机床与液压, 2024, 52 (12): 244-252.

[3] 何清波, 李天奇, 彭志科. 旋转机械故障诊断中的振动信号模型综述 [J]. 振动·测试与诊断, 2024, 44 (4): 629-639.

[4] CAO Y, SUN Y K, LI P, et al. Vibration-based fault diagnosis for railway point machines using multi-domain features, ensemble feature selection and SVM [J]. IEEE Transactions on Vehicular Technology, 2024, 73 (1):

176-184.

[5] 徐玲艳, 陆 艺, 赵 静. 基于边云协同的数控机床故障诊断联邦学习研究 [J]. 计量学报, 2024, 45 (6): 873-880.

[6] 黄 华, 薛文虎, 姚嘉靖, 等. 基于图论诊断法与小波包变换的数控机床进给系统故障诊断研究 [J]. 振动与冲击, 2022, 41 (15): 130-137.

[7] 张煜莹, 陆 艺, 赵 静. 基于增量学习的数控机床故障诊断系统 [J]. 计量学报, 2022, 43 (11): 1456-1463.

[8] 黄杨森, 王 勇, 刘云平, 等. 基于多元状态评估和相关分析的振动故障诊断 [J]. 振动与冲击, 2024, 43 (17): 269-277.

[9] 尚海昆, 黄 涛, 林 伟, 等. ISWD-SVD 联合方法的变压器振动信号降噪 [J]. 噪声与振动控制, 2024, 44 (6): 123-128.

[10] 钱国超, 胡 锦, 代维菊, 等. 基于振动非线性特征的变压器绕组状态检测 [J]. 电力工程技术, 2024, 43 (6): 194-202.

[11] 赵南洋, 茆志伟, 张进杰, 等. 柴油机多源冲击振动信号稀疏表示及其故障诊断应用 [J]. 噪声与振动控制, 2024, 44 (4): 125-131.

[12] 李俊逸, 尧 远, 刘明浩. 基于振动信号最优特征提取算法的风力机齿轮箱 SVM 故障诊断 [J]. 太阳能学报, 2024, 45 (7): 626-633.

[13] 姜 红, 康瑞雪, 郝小辉. 基于 SOM-FDA 利用 XRF 对药品铝塑包装片的分类 [J]. 浙江大学学报 (理学版), 2024, 51 (6): 747-752.

[14] 隆二红, 王 刚, 莫凌飞. 一种基于 SOM 与脉冲神经网络的音频识别方法 [J]. 传感技术学报, 2024, 37 (11): 1885-1892.

[15] 李 根, 杨剑征, 刘 祺. 基于 SOM-BP 神经网络的船舶柴油机故障诊断方法 [J]. 舰船科学技术, 2023, 45 (22): 121-125.

[16] 牛礼民, 胡 超, 万凌初, 等. 基于深度迁移学习的车辆悬架高频异常振动故障诊断 [J]. 重庆交通大学学报 (自然科学版), 2024, 43 (3): 121-127.

[17] 丁小飞, 廖明夫, 韩方军, 等. 某型航空发动机振动值波动故障诊断和排除 [J]. 振动·测试与诊断, 2024, 44 (2): 274-279.

[18] 李奇彦, 马建成, 黄 兴, 等. 高速电梯振动测试与故障诊断研究 [J]. 控制工程, 2024, 31 (4): 661-668.

[19] 谢丽蓉, 严 侣, 吐松江·卡日, 等. 基于特征判定系数的电力变压器振动信号故障诊断 [J]. 电力工程技术, 2024, 43 (3): 217-225.

[20] 田 萌. 拖拉机底盘振动故障诊断与优化——基于模态识别模型 [J]. 农机化研究, 2024, 46 (12): 234-239.