

动车组滚动轴承故障预测的实时性研究*

刘瞰东¹, 张馨月¹, 张泽华^{2,3}, 吴晓敏¹, 邵桂芳¹

(1. 厦门大学航空航天学院 厦门, 361102)

(2. 北京交通大学经济管理学院 北京, 100044)

(3. 厦门物之联智能科技有限公司 厦门, 361000)

摘要 针对动车组设备中滚动轴承故障预测实时性不强的问题, 提出了基于增强节点更新的宽度神经网络方法。首先, 采用宽度神经网络的方法对预处理之后的滚动轴承原始振动数据进行模型训练; 其次, 在训练过程中通过增加增强节点进行权值更新; 最后, 使用宽度网络对设置滑动窗口的数据进行预测并输出最终结果。动车组模拟实验台采集的滚动轴承故障数据的实验结果表明: 模型训练时间得以缩短, 预测时间控制在 30 ms 以内, 达到实际工业设备预测要求; 与传统深度学习相比, 基于增强节点更新的宽度神经网络其预测准确性得以保障, 且预测实时性优于其他方法。

关键词 动车组; 滚动轴承; 故障预测; 宽度神经网络; 实时性

中图分类号 TH133.33; TH17

引言

高速轨道列车运行速度不断提升, 其工作过程中的安全监控十分重要。在动车组滚动轴承工作过程中, 由于动车组组件中的机械零件发生持续摩擦而导致最终磨损, 从而对滚动轴承整个系统造成严重后果^[1]。为此, 对动车组滚动轴承故障预测的实时性研究具有重要意义。

以往动车组的滚动轴承故障预测多集中于振动信号分析, 但在提取轴承故障信号特征值时需要大量的计算时间, 且滚动轴承故障信号通常是非线性、非平稳的, 仅靠单一的振动信号分析方法所得结果不一定准确可靠^[2], 因此传统的振动信号分析方法在实际应用中存在着一定的局限性。

随着基于深度学习的轴承故障诊断方法成为机器学习领域的又一热点。卷积神经网络^[3]、深度信念网络^[4]等表现出了非凡的性能。随着基于深度学习的滚动轴承故障预测研究的深入, 神经网络处理复杂模式及进行相关推理与组织的优势被发掘, 预测准确率也得到了很大提升。目前, 国内针对动车组滚动轴承故障方面的研究多聚焦在深度学习上。谷玉海等^[5]针对传统故障预测方法准确率不高且泛化能力差的问题, 提出基于经验模态分解与卷积神

经网络(convolutional neural networks, 简称 CNN)的诊断方法。包括 CNN 在内的深度网络结构涉及大量参数和复杂的结构, 在训练过程中十分耗时。同时, 深度网络的训练方法多基于反向传播与梯度下降^[6], 导致大多数深度网络的训练过程用时过多, 难以实现实时性预测。

广义学习系统(broad learning system, 简称 BLS)是一种不需要深层架构也能够实现实时性高效学习的增量学习系统^[7]。该系统采用宽度网络结构, 消除了层与层之间的耦合, 网络结构非常简洁。由于没有多层连接, 宽度网络不需要利用梯度下降来进行权值更新, 通过在训练过程中增加增强节点来实时更新与优化训练模型, 使其计算速度大大优于深度学习且准确性并未降低, 适用于滚动轴承这种数据特征不多、但对预测实时性要求较高的系统。

笔者采用广义学习系统, 同时使用滑动窗口对滚动轴承数据进行预处理, 保证用于训练模型的数据长度一致性和数据的时序性。在故障预测过程中实时对运行数据进行预测, 并根据实际情况调整窗口大小。为监测提出方法的实际效果, 在实验台上进行轴承模拟故障实验。通过在滚动轴承上安装高精度的传感器, 对采集的振动数据进行处理, 输出预测故障的准确率与所耗时间, 并与不同增量方式下

* 国家自然科学基金面上资助项目(51975496)

收稿日期: 2022-05-23; 修回日期: 2022-10-26

的宽度网络及传统深度网络进行对比,以验证笔者提出方法的实时性优势。

1 动车组滚动轴承故障问题分析

1.1 动车组故障问题

安全是轨道交通重点考虑因素。动车组运行过程中故障主要诊断对象如图1所示。滚动轴承的故障需要立即发出警示,其预测的实时性尤为重要。

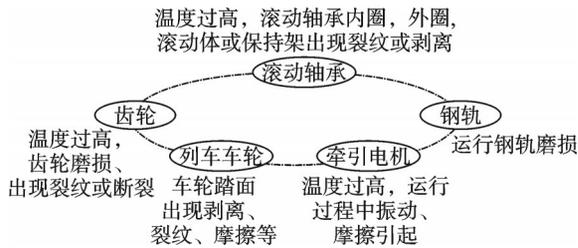


图1 动车组运行过程中故障主要诊断对象

Fig.1 The main fault diagnosis object of multiple units

1.2 滚动轴承典型模型

滚动轴承的故障可分为:内圈故障、外圈故障、滚动体故障与保持架故障。常用滚动轴承构造如图2所示。本研究对象为滚动轴承上的单个故障点。

滚动轴承转子系统包含具有固定在刚性支架上的滚珠轴承外圈与固定在轴上的内圈,滚动轴承将产生由于轴承总刚度连续周期变化而形成的不同合规性(varying compliance,简称VC)振动^[8]。

假设滚动体在内外圈滚道上均进行理想化滚动,滚动体与外圈接触点的线速度为 V_{out} ,角速度为 ω_{out} ,与内圈接触点的线速度为 V_{in} ,角速度为 ω_{in} ,则滚动体中心的线速度为

$$V_{cage} = (V_{out} + V_{in})/2 \quad (1)$$

由于外圈固定,即 $V_{out} = 0$,因此相应的滚动体中心角速度为

$$\omega_{cage} = \frac{V_{cage}}{(d_1 + d_2)/2} = \frac{V_{in}/2}{(d_1 + d_2)/2} = \frac{\omega_{in}d_1}{d_1 + d_2} \quad (2)$$

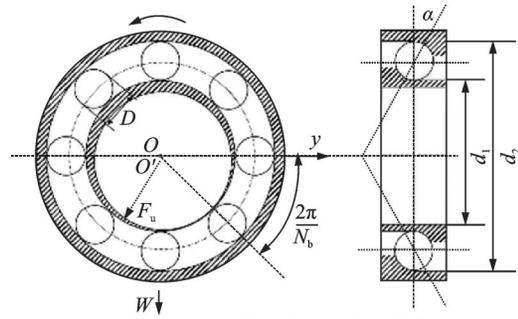
设轴承系统中滚动体个数为 N_b ,则VC频率为

$$\omega_{vc} = \omega_{cage} \left(\frac{d_1}{d_1 + d_2} N_b \right) = \omega_{cage} B_N \quad (3)$$

其中:参数 B_N 的值取决于所研究轴承的尺寸。

设第 i 个滚动体处的接触角度为 θ_i ,时间为 t ,则有

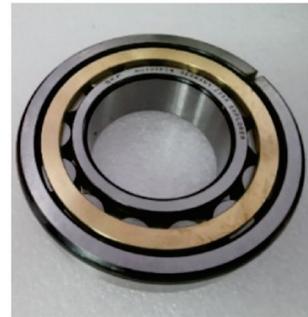
$$\theta_i = \frac{2\pi}{N_b} (i - 1) + \omega_{cage} t \quad (i = 1, 2, \dots, N_b) \quad (4)$$



D -滚动体直径; α -接触角; d_1 -内滚道直径; d_2 -外滚道直径; N_b -滚动体个数; F_v -不平衡力

(a) 滚动轴承平面结构图

(a) Plane structure drawing of rolling bearing



(b) 滚动轴承实物图

(b) Physical drawing of rolling bearing

图2 滚动轴承构造图

Fig.2 Construction drawing of rolling bearing

设内圈中心在 x 和 y 方向上产生的振动位移分别为 x' 和 y' ,轴承间隙为 d_0 。由非线性赫兹接触理论,得到滚动体在法向正方向上产生的总接触压力 F_x 与 F_y 分别为

$$F_x = M \sum (x \cos \theta_i + y \sin \theta_i - d_0)^{\frac{3}{2}} + \cos \theta_i F_y = M \sum (x \cos \theta_i + y \sin \theta_i - d_0)^{\frac{3}{2}} + \sin \theta_i \quad (5)$$

其中: M 为赫兹接触刚度,与相互接触的材料与形状有关。

基于式(5)建立系统的二阶非线性微分方程为

$$m\ddot{x} + C\dot{x} + M \sum_{i=1}^{N_b} (x \cos \theta_i + y \sin \theta_i - d_0)^{\frac{3}{2}} + \cos \theta_i = W + F_u \cos(\omega t)$$

$$m\ddot{y} + C\dot{y} + M \sum_{i=1}^{N_b} (x \cos \theta_i + y \sin \theta_i - d_0)^{\frac{3}{2}} + \sin \theta_i = F_u \sin(\omega t) \quad (6)$$

其中: m 为轴承支撑的转子质量和内圈质量; C 为阻尼; F_u 为不平衡力; ω 为转子转速。

基于此模型的滚动轴承可用于分析轴承在变速和变载时的瞬时特性,但面对实际运行环境,无法仅依靠模型对滚动轴承进行故障预测与处理。因此,

笔者对依赖实际工作状态下的轴承实时振动数据进行研究。

1.3 故障预测的实时性研究

故障预测是指在设备运作过程中,对其可能发生的故障进行预测^[9]。

传统故障预测多利用振动信号分析与深度网络来进行模型的建立,虽能满足预测的准确率要求,但由于频谱分析特征提取的时间过长,与深度网络复杂的网络结构在实时性需求上有所欠缺。针对动车组滚动轴承故障预测实时性不足的问题,提出采用宽度神经网络对其进行训练建模,该算法基本步骤为:数据采集与预处理、特征选择、建立训练模型以及最终预测。数据采集借助不同类型的传感器,在实验台轴承处选择测点进行振动数据的采集;笔者使用基于更新增强节点个数的宽度神经网络进行特征选择与建立训练模型,通过循环迭代并增加网络中增强节点个数的方式进行权值的更新,得到性能达标的模型;最后,使用该广义模型对实时采集到的动车组滚动轴承数据进行故障诊断与预测。

2 基于增强节点更新规则的 BLS

基于传统深度学习在训练过程中耗时过长的问题,Pao 等^[10]提出了随机向量函数链接神经网络(random vector functional link neural network,简称 RVFLNN),其结构如图 3 所示。RVFLNN 能够基本解决传统深度网络在训练过程中的耗时问题^[11],但对于一些高维度数据问题还不能完美解决^[12]。

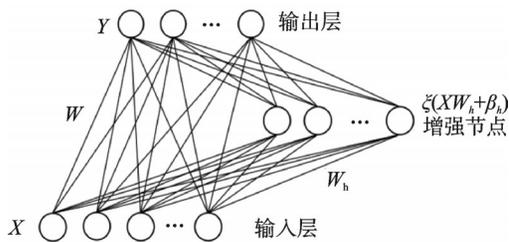


图 3 随机向量函数链接神经网络结构

Fig.3 Structure of random vector functional link neural network

与传统 RVFLNN 结构不同的是,Chen 等^[7]提出的广义学习系统在搭建过程中需要先通过映射输入构造相应的映射节点,然后通过映射节点建立增强节点。在实际应用中,原有的广义学习模型并不能达到要求,可通过增量学习对模型优化。笔者选用增加增强节点的方法更新系统的权重,增加模型

的复杂度。在这个过程中,即使网络结构由于增量学习算法而改变,也只需要在上一次权值的基础上进行更新,而不用重新训练整个网络。这也是宽度神经网络能够满足实时性的重要原因。增加增强节点的广义学习系统的设计步骤如下。

1) 对输入数据进行映射投影,将得到的映射特征作为网络的特征节点。假设输入数据为 X , $\phi_i(XW_{ei} + \beta_{ei})$ 表示对数据进行投影得到模型的第 i 个映射特征,该特征用 Z_i 表示。其中: $Z^i = [Z_1, Z_2, \dots, Z_i]$ 表示模型前 i 组映射特征的串联结果; W_{ei} 为通过稀疏自编码确定的最优输入权重矩阵; β_{ei} 为相应的偏置矩阵;权重 W_{ei} 与偏置 β_{ei} 都是随机生成的。

2) 映射的特征节点通过非线性映射被增强为随机生成权重的增强节点。 $\xi_j(Z^i W_{hj} + \beta_{hj})$ 为模型的第 j 组增强节点,用 H_j 表示, $H^j = [H_1, H_2, \dots, H_j]$ 表示前 j 组的增强节点连接。其中: ξ_j 为非线性激活函数; W_{hj} 与 β_{hj} 分别为第 j 组增强节点的随机权重与随机偏置。

假设输入数据集 X 有 N 个样本,每个样本有 M 个维度, Y 为 $R^{N \times C}$ 的输出矩阵。对于 m 个特征映射,每个映射产生 k 个节点,即

$$Z_i = \phi_i(XW_{ei} + \beta_{ei}) \quad (i = 1, 2, \dots, m) \quad (7)$$

$Z^m = [Z_1, Z_2, \dots, Z_m]$, 表示所有特征节点。对于模型的第 n 组增强节点,将其表示为

$$H_j = \xi_j(Z^i W_{hj} + \beta_{hj}) \quad (j = 1, 2, \dots, n) \quad (8)$$

3) 将所有映射的特征和增强节点拼接作为隐藏层,直接连接到输出端^[13],相对应的输出权重通过岭回归计算矩阵伪逆的算法得到。设 W^n 为广义结构的连接权重,即

$$W^n = [Z^m | H^n]^+ Y \quad (9)$$

将合并矩阵 $[Z^m | H^n]$ 表示为 A , $[Z^m | H^n]^+$ 解的求解算法计算式为。

$$A^+ = \lim_{\lambda \rightarrow 0} (\lambda I + AA^T)^{-1} A^T \quad (10)$$

最终得出广义学习系统的模型为

$$\begin{aligned} Y &= [Z_1, Z_2, \dots, Z_m | \xi(Z^m W_{h1} + \beta_{h1}), \\ &\dots, \xi(Z^m W_{hn} + \beta_{hn})] W^n = \\ &[Z_1, Z_2, \dots, Z_m | H_1, H_2, \dots, H_n] W^n = \\ &[Z^m | H^n] W^n \end{aligned} \quad (11)$$

4) 在迭代过程中通过增加增强节点个数的方式进行权重更新,实现增量学习。在广义学习系统

的基础上,假设保持网络中的特征节点数不变,增加增强节点后隐藏层为

$$A^{n+1} = [\xi \xi (Z^m W_{h_{n+1}} + \beta_{h_{n+1}})] \quad (12)$$

其中: A^{n+1} 表示 $A^n = [Z^m | H^n]$ 的更新; ξ 为激活函数; $W_{h_{n+1}}$ 和 $\beta_{h_{n+1}}$ 分别为新的随机权重与偏置。

这里矩阵中涉及的伪逆求解方法依然使用式(10)的正则化公式求出,故只用求出附加增强节点的伪逆,减少了计算量,真正实现了快速的增量学习。图4为宽度神经网络的增加增强节点算法。

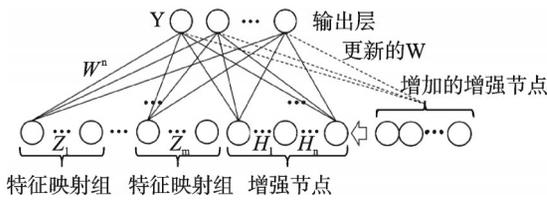


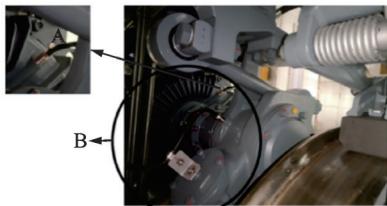
图4 宽度神经网络的增加增强节点算法

Fig.4 Enhanced node incremental algorithm of broad learning system

除了基于增加增强节点的宽度学习系统,相关研究中还介绍了基于增加特征节点及基于增加输入个数的宽度网络。直接加入增强节点的更新方式在理论上训练时长明显缩短,随着迭代更新的次数增加,这种差距进而被放大。因此,笔者选择基于增加增强节点的宽度学习系统进行模型建立与预测。实验结果也证明了该方法在预测实时性上的优势。

3 动车组滚动轴承故障预测的BLS模型

图5为动车组滚动轴承安装图。图中圆圈处为动车组车底的滚动轴承组件,通过在轴承上连接传感器能够获取动车组运行时的原始振动数据。



A-滚动轴承的传感器连接; B-动车组滚动轴承

图5 动车组滚动轴承安装图

Fig.5 Mounting drawing of rolling bearing for motor car

为了得到更为优化的训练模型,笔者在训练过程中使用增加增强节点的更新方式进行模型的迭代更新与优化,其网络模型如下。

将从传感器处获得的原始振动数据作为输入数据 X_D , X_D 经过映射投影得到映射特征,并将其作为宽度神经网络中的特征节点。实验假设预先设置的初始特征节点数目为 m , Z_{D_i} 为该网络模型的第 i 个映射特征,其方程为

$$Z_{D_i} = \phi_i(X_D W_{ei} + \beta_{ei}) \quad (i = 1, 2, \dots, m) \quad (13)$$

其中: $Z_D^m \equiv [Z_{D1}, Z_{D2}, \dots, Z_{DM}]$,为所有特征节点。

将特征节点 Z_{D_i} 通过非线性映射,增强为随机生成权重的增强节点。假设预先设置的初始增强节点数目为 n , H_{D_j} 为该网络模型的第 j 组增强节点,其方程为

$$H_{D_j} = \xi_j(Z_D^i W_{hj} + \beta_{hj}) \quad (j = 1, 2, \dots, n) \quad (14)$$

将所有的特征节点与增强节点拼接在一起作为宽度神经网络的隐藏层,再将隐藏层直接连接到输出层输出结果,得到动车组滚动轴承故障检测的广义系统学习模型 Y_D 为

$$Y_D = [Z_{D1}, Z_{D2}, \dots, Z_{DM}] \xi(Z_D^m W_{h1} + \beta_{h1}), \dots, \xi(Z_D^m W_{hn} + \beta_{hn}) W^n = [Z_{D1}, Z_{D2}, \dots, Z_{DM} | H_{D1}, H_{D2}, \dots, H_{Dn}] W^n = [Z_D^m | H_D^n] W^n \quad (15)$$

其中:输出权重通过式(9)和式(10)得到。

在实际运行环境下,为解决初始广义学习系统模型训练效果不佳的问题,在迭代过程中增加增强节点个数的方法来更新权重。假设更新过后 A_D^n 为 A_D^{n+1} ,则增加增强节点之后的隐藏层变为

$$A_D^{n+1} = [\xi \xi (Z_D^m W_{h_{n+1}} + \beta_{h_{n+1}})] \quad (16)$$

动车组滚动轴承故障预测问题的广义学习系统模型如图6所示。采用滑动窗口的形式对测试数据进行固定单位长度的动态预测。实验最终输出平均

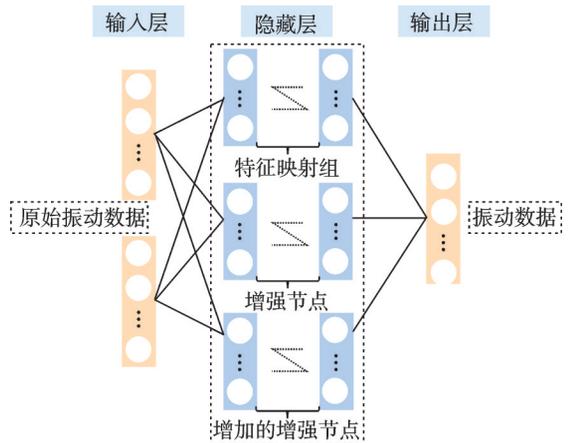


图6 动车组滚动轴承故障预测问题的BLS模型

Fig.6 The BLS model of rolling bearing fault prediction of motor car

准确率以及预测时间,并与实际动车组故障预警系统的预测时间和不同深度网络模型的预测结果进行对比。

4 实验与结果分析

4.1 故障预测流程

基于建立的动车组滚动轴承故障预测的广义学习系统模型,笔者采用该算法来对其实时性进行研究。图 7 为动车组滚动轴承故障预测流程图。

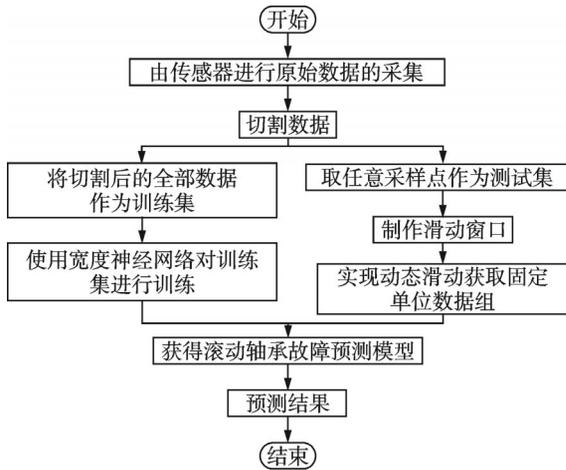


图 7 动车组滚动轴承故障预测流程图

Fig.7 Flow chart of rolling bearing fault prediction of motor car

动车组滚动轴承故障预测过程如下:

- 1) 在电动机的滚动轴承上部署相应的传感器,得到相同环境下不同状态的原始振动数据,再对正常与故障状态下的滚动轴承数据进行预处理。
- 2) 将原始数据按滑动窗口大小进行切割,使用切割后的所有原始振动数据作为训练数据。
- 3) 确定网络模型训练参数以及更新节点个数,使用宽度神经网络对原始振动数据进行模型训练。
- 4) 在测试环节设置滑动窗口,实现同一采样点数据的实时滑动与预测。
- 5) 通过宽度神经网络训练模型,随机选取原始数据进行验证,输出结果以检验预测效果。

4.2 实验算法伪代码

Algorithm 1 为基于增加增强节点更新的宽度神经网络算法的伪代码。Algorithm 1 基于增加增强节点更新的广义学习系统算法如下。

输入: 训练数据 X ;

输出: W

for $i=0; i \leq m$ do

随机生成 W_{ei}, β_{ei} ;

计算特征映射 $Z_i = \Phi_i(XW_{ei} + \beta_{ei})$;

end for

设置特征映射组 $Z^m = [Z_1, Z_2, \dots, Z_m]$;

for $j=0; j \leq n$ do

随机生成 W_{hj}, β_{hj} ;

计算增强节点 $H_j = \xi_j(Z^m W_{hj} + \beta_{hj})$;

end for

设置增强节点组 $H^n = [H_1, H_2, \dots, H_n]$;

设置 A^n 并使用伪逆式(9)计算 $(A^n)^+$;

while 训练误差阈值不满足时 do

随机生成 W_{hn+1}, β_{hn+1} ;

计算更新后的增强节点 H_{n+1} ;

设置 $A^{n+1} = [A^n | H_{n+1}]$;

计算 $(A^{n+1})^+$ 与 W^{n+1} ;

$n = n + 1$;

end while

设置 $W = W^{n+1}$

4.3 实验数据选取

实验数据来自厦门物之联公司的动车组滚动轴承故障模拟实验台,该实验台能够模拟动车组实际运行过程中滚动轴承的工作实况。通过在滚动轴承上安装传感器获取振动数据,并且同步获得相应测点的轴温、环境温度、起始与结束的转速数据。实验数据包含正常轴承和内环故障轴承上采集的原始振动数据。采样轴承的轴径为 50 mm,中径为 60.6 mm,滚径为 11.2 mm,滚子数为 14,接触角为 0° 。动车组滚动轴承故障模拟实验台如图 8 所示。



图 8 动车组滚动轴承故障模拟实验台

Fig.8 Fault simulation test-bed for rolling bearing of multiple units

实验选取动车组滚动轴承上的 4 个不同测点,在这 4 个测点上测出正常与故障轴承共 287 组数据。其中:正常测试点数据为 143 组,故障测试点数据为 144 组。每组测量数据选取 8~9 s 时间内采集的 1 021 个原始振动数据,共 293 027 个数据。数据

预处理过程如下。

1) 数据样本进行切分。以 10 为步长,对每个数据采集点的 1 021 个数据,以 100 个数据作为一个滑动窗口数据样本进行切分,每切分一组单位长度为 100 的振动数据,就往后滑动 10 个数据单位,以此类推,始终保持 100 个单位长度的滑动窗口。将所得的每一组统一长度的滑动窗口数据写入训练集文件,共得到 26 691 组训练数据,每组数据含 100 项。

2) 对训练数据进行标签化处理。对每组数据使用遍历法,将极值过大或者过小的数据组作为故障数据组划分出来。原本在故障滚动轴承处测得的一组数据,按滑动窗口单位被划分为正常数据与故障数据的整合。相对于传统方法,使用滑动窗口能够保证数据的统一长度与时序性,且能够根据实际情况调整窗口大小,更加贴合预测的实时性要求。

4.4 使用宽度神经网络进行模型训练

使用宽度神经网络对划分并标签好的训练数据进行训练,训练前需要设置训练参数并确定网络结构与更新方式。用于动车组滚动轴承故障预测的宽度神经网络参数设置如表 1 所示。

表 1 宽度神经网络参数设置
Tab.1 Parameter setting of broad learning system

参数名称	参数值
特征激活函数	线性整流单元
增强激活函数	线性整流单元
每组神经元个数	30
初始特征节点数	3
初始增强节点数	3
每次训练增加增强节点数	2
训练迭代次数	10

实验初始,增强节点与特征节点数均为 3,在每次迭代中增加 2 个增强节点。测量增强节点为 3~23 个情况下的训练时间与准确率,不同增强节点数对预测时间与准确率的影响如表 2 所示。可以看出,随着迭代次数的增加,网络的增强节点数也按照每次 2 个的规律递增。在这个过程中宽度神经网络对模型训练的时间逐步增加,最终 10 次迭代后的训练总时长为 17.697 427 s,其准确率也随着迭代次数的增加有小幅递增的趋势,最终达到 95.388%。

基于宽度神经网络的 3 种增量方式,笔者分别将其作为训练模型进行实验。除了选择迭代过程中增加 2 个增强节点的方法,同时采用迭代过程中增加 2 个特征节点、以及增加 2 个输入个数的方式对

表 2 不同增强节点数对预测时间与准确率的影响

Tab.2 Effect of different number of enhanced nodes on prediction time and accuracy

增强节点数	每次训练时间/s	准确率/%
3	0.296 849	65.624
5	0.828 224	92.372
7	0.968 868	93.380
9	1.125 075	94.028
11	1.313 757	94.578
13	1.500 375	95.073
15	1.796 925	95.223
17	2.015 704	95.242
19	2.281 567	95.313
21	2.625 258	95.380
23	2.944 825	95.388

模型进行训练。不同增量方式下的 BLS 训练准确率和训练时长如图 9,10 所示。

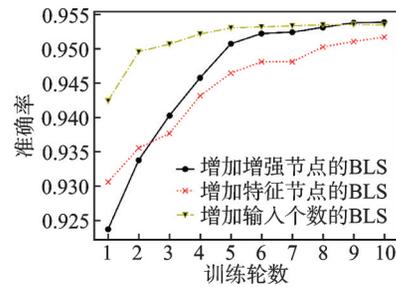


图 9 不同增量方式下的 BLS 训练准确率

Fig.9 The training accuracy of BLS in different incremental ways

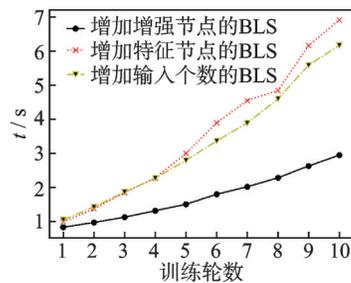


图 10 不同增量方式下的 BLS 训练时长

Fig.10 The length of training of BLS in different incremental ways

可以看出:随着迭代过程的进行,3 种网络模型的训练准确率均逐渐提高,训练准确率基本一致;在训练时间上,采用增加增强节点方式的 BLS 算法明显快于其他 2 种算法,从数据上佐证了该增量更新方式更加贴近提出模型的实时性需求。

4.5 实验结果与分析

确定训练模型后,首先,进行测试集的选择,实验中测试集随机选取 100 个采样点(正常采样点数据和故障采样点数据各 50 组),得到一个正常状态及故障状态下的 102 100 个振动数据;其次,从开始的 100 个数据作为第 1 个滑动口,之后以 10 为步长进行窗口滑动,在滑动的过程中每得到一个 100 单位的滑动窗口,就对其进行标签并放入训练好的模型进行预测,直至遍历每个采样点的 1 021 个数据,再对下一采样点进行同样的操作。将每一次的预测结果与实际标签进行对比,输出测试集训练准确率和平均预测时间,最终得到滑动窗口 9 300 组。宽度神经网络预测结果如表 3 所示。

表 3 宽度神经网络预测结果

项目	预测数据组	预测准确率/%	预测时间/ms
数值	9 300	97.656	25.314 5

可以看出,使用宽度神经网络对动车组滚动轴承故障预测的准确率能够达到 97.656%,只需 25.314 5 ms 就能完成轴承故障预测,完全能够达到设备实际运行的要求。

4.6 实验对比分析

在相同测试数据结构与滑动窗口过程下,不同增量方式下 BLS 的预测时间对比如图 11 所示。可以看出,采用笔者选用的增加增强节点的增量宽度神经网络算法在预测时间上明显优于其他 2 种算法。

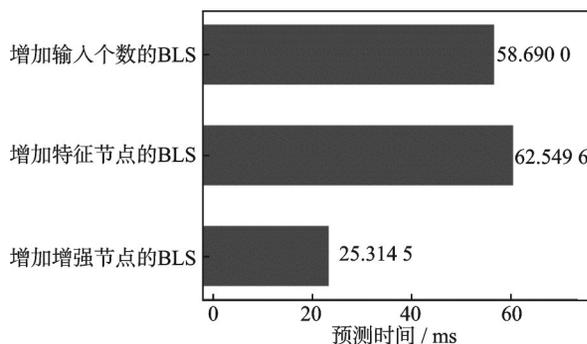


图 11 不同增量方式下 BLS 的预测时间对比

Fig.11 Comparison of prediction time of BLS under different increment patterns

为验证笔者提出方法在动车组滚动轴承故障问题上的实时性优势,使用全连接神经网络(deep neural networks,简称 DNN),LSTM,一维卷积神经网络

(one-dimensional convolutional neural networks,简称 1D CNNs),二维卷积神经网络(two-dimensional convolutional neural networks,简称 2D CNNs)对该动车组滚动轴承故障数据进行预测实验。为保证实验的对比效果,所有方法均在相同数据结构和预测参数下进行。不同网络结构下的预测时间对比如图 12 所示。可以看出,在相同实验条件下,基于增加增强节点的宽度神经网络算法在动车组滚动轴承故障问题上的预测时间优势明显。

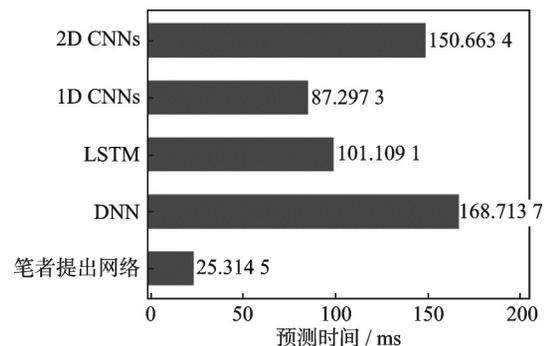


图 12 不同网络结构下的预测时间对比

Fig.12 Comparison of prediction time under different network structures

将不同的深度网络模型与 3 种不同增量宽度神经网络模型所得预测结果进行对比,不同网络算法下预测结果对比如表 4 所示。可以看出,对于动车组滚动轴承,笔者提出模型的预测准确率与结构复杂的深度学习结果一致,且预测延时能够达到 30 ms 以内。可见,在准确率得以保障的情况下,采用本研究算法最能满足动车组滚动轴承故障预测的实时性需求。

表 4 不同网络算法下预测结果对比

网络模型	预测时间/ ms	预测准确 率/%
DNN	168.713 7	97.398
LSTM	101.109 1	93.623
一维卷积神经网络(1D CNNs)	97.297 3	95.349
二维卷积神经网络(2D CNNs)	150.663 4	97.473
增加特征节点的BLS	62.549 6	97.613
增加输入个数的BLS	58.690 0	97.860
笔者提出网络模型	25.314 5	97.656

5 结束语

笔者使用基于增加增强节点的宽度神经网络对

动车组滚动轴承故障的预测问题进行研究,使用厦门市物之联有限公司提供的模型动车组滚动轴承数据进行验证。不同于传统的深度网络,宽度神经网络大大降低了网络结构的复杂度,对于滚动轴承这类低维度的数据,能够在保证其预测准确率的基础上,大大缩短故障预测所需的时间,同时也能够克服单一振动信号分析方法无法建立精确模型的问题。笔者通过在迭代过程中增加增强节点的个数来更新模型,过程中不需要重新训练已有的结构和参数,只需要计算新增部分的参数。同时,直接增加增强节点的更新方式,省去了输入节点进行映射得到增强节点的过程,节省了时间。实验结果表明,基于增加增强节点的宽度网络训练效果优于另外2种增量学习宽度网络,且在动车组滚动轴承故障预测问题上,相比传统深度网络与其他更新方式下的宽度神经网络,只有笔者提出算法能够在30 ms延期内得到预测结果,计算效率提高了3~7倍,计算精度也完全达到甚至超过了传统方法,符合设备实际需求,完全满足动车组滚动轴承故障预测的实时性需求。

参 考 文 献

- [1] ZHENG Z, JIANG W L, HU H S, et al. Research on rolling bearings fault diagnosis method based on EEMD morphological spectrum and kernel fuzzy C-means clustering[J]. Journal of Vibration Engineering, 2015, 28(2): 324-330.
- [2] 桂卫华, 刘晓颖. 基于人工智能方法的复杂过程故障诊断技术[J]. 控制工程, 2002, 9(4): 1-6.
GUI Weihua, LIU Xiaoying. Fault diagnosis technologies based on artificial intelligence for complex process [J]. Control Engineering of China, 2002, 9(4): 1-6. (in Chinese)
- [3] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251. (in Chinese)
- [4] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7): 1527-1554.
- [5] 谷玉海, 朱腾腾, 饶文军, 等. 基于EMD二值化图像和CNN的滚动轴承故障诊断[J]. 振动、测试与诊断, 2021, 41(1): 105-113.
GU Yuhai, ZHU Tengting, RAO Wenjun, et al. Fault diagnosis for rolling bearing based on EMD binarization image and CNN[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(1): 105-113. (in Chinese)
- [6] LAROCHELLE H, BENGIO Y, LOURADOUR J, et al. Exploring strategies for training deep neural networks [J]. Journal of Machine Learning Research, 2009, 10(1): 1-40.
- [7] CHEN C L P, LIU Z L. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(1): 10-24.
- [8] FUKATA S, GAD E H, KONDOU T, et al. On the radial vibration of ball bearings: computer simulation [J]. Bulletin of JSME, 1985, 28(239): 899-904.
- [9] 陈志强, 陈旭东, DE OLIVIRA J V, 等. 深度学习在设备故障预测与健康中的应用[J]. 仪器仪表学报, 2019, 40(9): 206-226.
CHEN Zhiqiang, CHEN Xudong, DE OLIVIRA J V, et al. Application of deep learning in equipment prognostics and health management [J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 206-226. (in Chinese)
- [10] PAO Y H, TAKEFUJI Y. Functional-link net computing: theory, system architecture, and functionalities [J]. Computer, 1992, 25(5): 76-79.
- [11] NARENDRA K S, PARTHASARATHY K. Identification and control of dynamical systems using neural networks [J]. IEEE Transactions on Neural Networks, 1990, 1(1): 4-27.
- [12] CHEN C L P, ZHANG C Y. Data-intensive applications, challenges, techniques and technologies: a survey on big data [J]. Information Sciences, 2014, 275: 314-347.
- [13] 袁利平, 陈川南. 宽度学习的教育价值及其意义[J]. 中国电化教育, 2019(5): 34-40.
YUAN Liping, CHEN Chuannan. The value and significance of broad learning [J]. China Educational Technology, 2019(5): 34-40. (in Chinese)



第一作者简介:刘瞰东,男,1970年2月生,博士、教授、博士生导师。主要研究方向为云计算、网络信息技术、嵌入式系统以及工业机器人等。曾发表《An energy-efficient task scheduling for mobile devices based on cloud assistant》(《Future Generation Computer Systems》2016, Vol.61)等论文。
E-mail: ltd@xmu.edu.cn