

基于 LSTM/NN 的道岔故障特征提取与识别研究

唐维华

(东华大学信息科学与技术学院 上海 201620)
(卡斯柯信号有限公司 上海 200040)

摘要 道岔转辙机是保证列车安全运营的重要室外设备之一。分析道岔动作电流曲线,可以及时判断道岔的实时工作状态。采用基于长短期记忆(LSTM)模型结合传统神经网络的识别算法,从原始电流序列中自动提取特征,再根据特征利用神经网络分类器(NNC)来对道岔动作电流曲线进行智能故障识别。实验结果表明,所提算法不会丢失电流曲线的有效信息,并且提高了准确率,训练集上的准确率为 100%,在测试集上准确率达到了 99.7%。算法能够满足铁路现场实际应用需要,对保障道岔的正常运行具有十分重要的现实意义。

关键词 道岔故障识别 动作电流 长短期记忆 时间序列 特征提取 神经网络分类器

中图分类号 TP3 文献标识码 A DOI:10.3969/j.issn.1000-386x.2019.01.029

EXTRACTION AND RECOGNITION OF SWITCH MACHINE FAULT FEATURES BASED ON LSTM/NN

Tang Weihua

(College of Information Sciences and Technology, Donghua University, Shanghai 201620, China)
(Casco Signal Co., Ltd., Shanghai 200040, China)

Abstract The switch machine is one of the most important outdoor devices to ensure the safe operation of the train. The real-time working state of the switch machine can be judged in time by analyzing the action current curve. In this paper, based on LSTM model, we adopted the recognition algorithm which combined traditional neural network. Features were extracted automatically from the original current sequence. According to the characteristics, the neural network classifier (NNC) was used to intelligently recognize the fault of action current curve. The experimental results show that the algorithm does not lose the effective information of the action current curve. It improves the accuracy. The accuracy rate on the training set is 100%. The accuracy rate reaches 99.7% on the test set. It can meet the practical needs of the railway field. It is of great practical significance for ensuring the normal operation of the switch.

Keywords Switch machine fault recognition Action current Long-short term memory (LSTM) Time series Feature extraction Neural network classifier(NNC)

0 引言

由于道岔现场环境复杂,道岔的搬动频繁,引起的机械磨损会影响道岔的性能。借助对道岔动作时产生的电流进行监控,可以准确测量到道岔转动时产生的电流值大小和动作时长,并通过这种方式,分析出道岔的相关特性。比较正常条件下道岔转动电流与道岔故

障条件下的转动电流之间的差异,可以及时发现问题的隐患,准确判断道岔转辙机的实时状态,对防止道岔发生故障有不可替代的作用^[1]。

为了实现道岔故障的智能诊断,国内外学者通过将不同的机器学习方法和人工智能应用于道岔的智能诊断,已经进行了大量的研究并取得了许多重要成果。文献[1]从定性分析的角度提出了一种基于定性趋势分析的故障诊断方法。文献[2]中,基于三次样条插

值的数据集成模块用于将不同维度的道岔动作当前数据分类为统一的数据维度,通过新的 RBF 神经网络进行分析和诊断。文献[3]利用信号专家诊断系统接收微机监测的相关数据进行分析。文献[4]提出了一种基于神经网络的道岔智能故障诊断方法,将道岔搬动期间的动作电流集合作为特征值收集,并建立特征向量。以故障类型为输入构造 BP 神经网络训练模型,进行故障识别。在文献[5]中,基于所收集的瞬时电流值,提出了一种基于支持向量机的铁路道岔故障诊断方法。采用高斯径向基核函数对训练样本进行学习,此模型对于少量样本虽然适用,但是输出的是有无故障的二分类分类器,对失败的类型没有详细的判断。在文献[6]中,道岔曲线以两个角度(时域和范围)进行描述和分析,Fisher 算法用于选择道岔电流曲线的特性,并且制定了基于独立特征选择的办法和选择特征的标准。文献[7]将空间、时间、环境和上下文信息特征融合提高群集聚类正确率。文献[8]引入确定性测量矩阵来筛选出最佳压缩特征。

本文分析了“总功率+三相电流”模式的道岔曲线。选择 A、B、C 三相电流的所有数据进行训练而不去人工提取特征,采用多变量时间序列预测的 LSTM 模型来自动进行特征提取,对每种故障类型进行精准的预测,从而避免了人工方式提取特征并不能包含原始曲线的所有信息导致很多很重要的信息丢失的缺点,具有提取一些和最终结果具有很强相关性的隐含特征的优点。

1 问题描述

1.1 道岔动作电流曲线分析

道岔转辙机的正常动作过程可分为:解锁→转换→锁闭→构通的表示。道岔动作曲线有:AB 线电压、BC 线电压、AC 线电压;A 相电压、B 相电压、C 相电压;A 相电流、B 相电流、C 相电流。其中,道岔转动电流曲线中电流的变化趋势对应了道岔搬动的四个阶段。

1.2 道岔典型故障类型

通过分析电流曲线,可以判断出道岔的电气特性,时间特性和机械特性,及时发现隐患。例如:1) 道岔动作功率曲线的峰值发生在刚解锁时,则说明密贴调整过紧或各牵引点动作不一致;2) 若三相交流电的动作电流曲线不合一,或电流曲线有波动,主要原因有拐轴动作不灵活、动接点打入深度不够、自动开闭器动接点压力不足、接点表面氧化严重等安全隐患;3) 如果道岔转换时间比正常转换时间长,则可能存在道岔油

缸缺油、油管漏油或油管内排气不干净的故障隐患。

2 算法设计

2.1 基于 LSTM 的故障诊断模型

本文采用 LSTM 来自动进行特征提取,可以使算法自动选取有效的特征而不必依靠人工的方式。因为人工方式提取的特征并不能包含原始曲线的所有信息,会使很多重要的信息丢失,而且一些复杂的隐含特征可能和最终的结果具有很强的相关性是根本无法靠人工方式提取出来的。

该特征从时间序列中提取并发送到 Softmax 神经网络分类器。Softmax 本质上是一种神经元输出的概率分布形式,最后一个输出层的节点个数与分类任务的目标数相等。分类任务的目标数即为道岔故障类型,那么对于每一个样例,神经网络可以得到一个多维的数组作为输出结果,数据向量中每个维度值对应于一个类别。

构建的 LSTM 诊断模型的整体框架如图 1 所示。

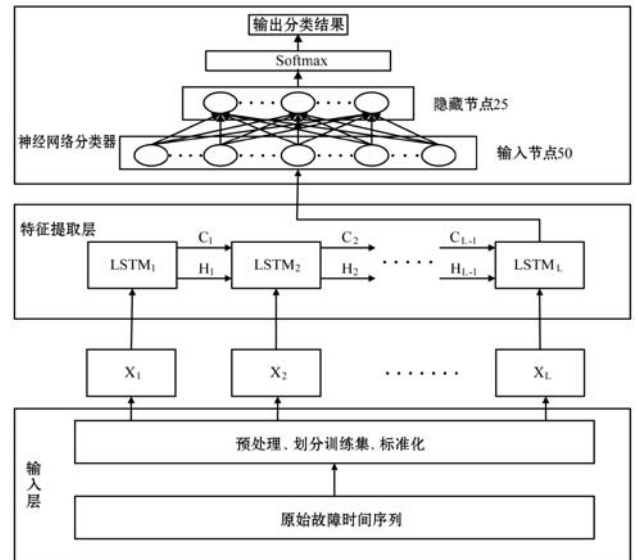


图1 LSTM 诊断模型的整体框架视图

2.2 输入数据的预处理

输入数据包含 3 行和 k 列电流值,数据排列如式(1)矩阵所示:

$$I = \begin{bmatrix} I_{A1} & \cdots & I_{Ak} \\ I_{B1} & \cdots & I_{Bk} \\ I_{C1} & \cdots & I_{Ck} \end{bmatrix} \quad (1)$$

$$X_i = \begin{bmatrix} I_{Ai} \\ I_{Bi} \\ I_{Ci} \end{bmatrix}$$

式中:下标 A、B 和 C 代表三相电流的电序,下标 k 表

示第 k 个采集时间。 I_{Ak} 表示在第 k 个时刻道岔 A 相的电流数值。 X_i 是由在第 i 个采集时间获取的 A、B 和 C 的三相电流组成的三维向量。

将道岔的搬动时间设置为 T , 微机监控系统采集时间间隔大多为 0.04 s, 因此采样点的数量 $k \in (1, 2, \dots, \frac{T}{0.04})$ 。一般在正常状况下, 道岔的搬动时间约为 6 s, 微机监控采集数据的周期为 0.04 s, 所以正常情况下采集的时间序列点集为 150 左右。

由于人为操作不当以及设备老化对数据采集过程的影响, 不良数据的产生极大地影响了预测模型的准确性。因此, 在输入训练数据之前, 有必要识别和处理样本中的不良数据。使用样本的统计指标和设定的阈值来确定是否存在异常数据, 处理步骤如下:

首先设 $N = T/0.04$, 式(2)、式(3)分别用于计算采样序列的均值与方差。

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i \quad (i = 1, \dots, N) \quad (2)$$

$$\delta^2 = \frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2 \quad (3)$$

然后, 通过式(4)进行 3σ 原理的非正常采样数判断, 其中 ε 是阈值, 通常取 $1 \sim 1.5$ 。

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2} \quad (4)$$

$$|X_i - \bar{X}| > 3\sigma\varepsilon$$

如果数据满足式(4), 则 X_i 是坏数据, 并且可以通过式(5)来执行权重修正。

$$X_i^* = \frac{\alpha}{2} \sum X_{i+1} + \frac{\beta}{2} \sum X_i^{1,2} + \gamma \bar{X} \quad (5)$$

式中: $\alpha + \beta + \gamma = 1$, X_i^* 为第 n 个采样周期第 i 点修正数据, X_{i+1} 为 X_i 横向附近两个电流采集点的值, $X_i^{1,2}$ 为距离 X_i 最近的 2 个相似电流所对应的采集点的值。

对坏数据识别和处理后, 对新采样且合格的数据集进行归一化处理, 设经过归一化处理的数据集矩阵为 I^R , 如式(6)所示:

$$I^R = \begin{bmatrix} I_{A1}^R & \dots & I_{Ak}^R \\ I_{B1}^R & \dots & I_{Bk}^R \\ I_{C1}^R & \dots & I_{Ck}^R \end{bmatrix} \quad (6)$$

$I_{ij}^R = \frac{I_{ij} - \min I_{ik}}{\max I_{ik} - \min I_{ik}}$ ($i = A, B, C; j = 1, 2, \dots, N$), 经过变换后电流数据均在 $0 \sim 1$ 之间。

2.3 特征提取

LSTM 模型最早在文献[9]中提出, 它是 RNN 的一个变种, 是为了解决 RNN 模型长期依赖和梯度消失

问题而提出的, 可以很好地用在时间序列预测上。LSTM 模型结构如图 2 所示, LSTM 单元由细胞核和控制门组成。

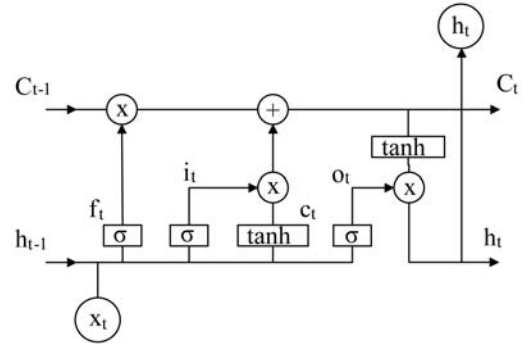


图 2 标准的 LSTM 结构

如图 2 所示, 穿过 LSTM 中的图形水平线表示隐藏层中神经网络的状态 C 。信息流可以很容易地流转保持不变, 并且状态 C 的变化受到三个控制门的影响。三个控制门是用于保护和控制细胞的状态的输入门、输出门和遗忘门。

首先“遗忘门”用于判断细胞中丢弃的信息。该门会使用 sigmoid 函数读取 h_{t-1} 和 x_t 输出一个在 0 到 1 之间的值。该值代表了对状态 C_{t-1} 中细胞数值的遗忘程度, 1 代表完全保留, 0 表示完全舍弃, “遗忘门”的计算方式如式(7)所示:

$$f_k = \sigma(W_f \cdot [h_{k-1}, X_k] + b_f) \quad (7)$$

式中: h_{t-1} 为之前状态的输出, x_t 为当前状态的输入 (即某个采集时刻采集的 A、B、C 三相电流组成的三维向量)。

然后决定在细胞状态中可以保留哪些新的信息。这里包含两部分, 见式(8)。其中一部分是 sigmoid 层, 称为“输入门”, 它决定细胞将要更新的值。另一部分是 tanh 层, 它创建一个新的候选值向量 \tilde{C}_t , 并被添加状态中。这允许使用这两条信息来生成状态更新。

$$i_k = \sigma(W_i \cdot [h_{k-1}, X_k] + b_i) \quad (8)$$

$$\tilde{C}_k = \tanh(W_c \cdot [h_{k-1}, X_k] + b_c)$$

接下来按照式(9)更新细胞的状态, 将旧状态 C_{t-1} 与 f_t 相乘去除掉需要丢弃的信息, 接着加上 $i_t \times \tilde{C}_t$ 就得到了新的状态 C_t 。

$$C_k = f_k \times C_{k-1} + i_k \times \tilde{C}_k \quad (9)$$

最终依据细胞状态确定输出值, 体现的是 x_t 时间序列的特征。式(10)是输出值, 首先运行 sigmoid 层以确定将输出哪个部分的单元状态。接下来, 通过 tanh 处理单元状态以获得介于 -1 和 1 之间的值并乘以 sigmoid 层, 最后仅输出所确定的部分。

$$o_k = \sigma(W_o \cdot [h_{k-1}, X_k] + b_o) \quad (10)$$

$$h_k = o_k \times \tanh(C_k)$$

通过这样的方式将电流序列的前后信息进行学习,得到电流序列之间的前后关联信息,实现电流特征信息的提取。

在本文中,多变量单模型方法用于构建网络。与传统神经网络相比,学习所需的参数大大减少,并且仅需要一个网络来执行高精度预测任务。经过实验发现特征提取节点设置为 50 的时候可以达到最高的准确率,所以这里设置输出节点为 50,表示 LSTM 将从 A、B 和 C 三相电流数据中提取 50 个相关特征。LSTM 进行特征提取的伪代码如算法 1 所示。

算法 1 LSTM 特征提取算法

1. 输入: $X_1, X_2, \dots, X_{T/0.04}$
2. 输出: 提取的特征向量
3. LSTM 初始状态权重初始化
4. For k from 1 to $\frac{T}{0.04}$:
5. $f_k = \sigma(W_f \cdot [h_{k-1}, X_k] + b_f)$
6. $i_k = \sigma(W_i \cdot [h_{k-1}, X_k] + b_i)$
7. $\tilde{C}_k = \tanh(W_c \cdot [h_{k-1}, X_k] + b_c)$
8. $C_k = f_k \times C_{k-1} + i_k \times \tilde{C}_k$
9. $o_k = \sigma(W_o \cdot [h_{k-1}, X_k] + b_o)$
10. $h_k = o_k \times \tanh(C_k)$
11. End For
12. 输出 h_k 即为最终的特征向量

2.4 神经网络分类

为了让 LSTM 提取出的特征组合出更复杂的特征以提高预测精度,LSTM 提取出特征后加入了一层包含 25 个节点的隐藏层,它可以对特征进行再加工抽取更加复杂的关系。最终的 Softmax 层里设置最终需要诊断的故障类别个数,它会将节点的输出值通过计算转换为概率,最终概率最高的类别将作为最终结果输出,用交叉熵来判定实际的输出与期望的输出的接近程度。如图 3 所示。

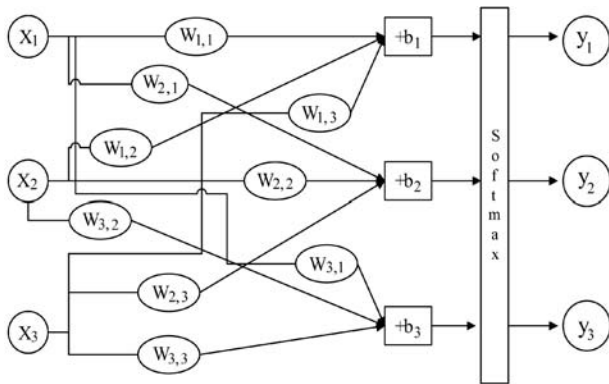


图 3 Softmax 的计算方式

图 3 表明了 Softmax 的计算方式,图中的神经网络最终输出三个节点的值,分别为 Z_1, Z_2, Z_3 , 三个节点

值的计算公式如式(11)所示:

$$\begin{cases} Z_1 = W_{1,1}X_1 + W_{1,2}X_2 + W_{1,3}X_3 + b_1 \\ Z_2 = W_{2,1}X_1 + W_{2,2}X_2 + W_{2,3}X_3 + b_2 \\ Z_3 = W_{3,1}X_1 + W_{3,2}X_2 + W_{3,3}X_3 + b_3 \end{cases} \quad (11)$$

经过 Softmax 层之后的输出为:

$$\begin{cases} Y_1 = \frac{e^{Z_1}}{e^{Z_1} + e^{Z_2} + e^{Z_3}} \\ Y_2 = \frac{e^{Z_2}}{e^{Z_1} + e^{Z_2} + e^{Z_3}} \\ Y_3 = \frac{e^{Z_3}}{e^{Z_1} + e^{Z_2} + e^{Z_3}} \end{cases} \quad (12)$$

最终的输出可以解释为概率, Y_1, Y_2, Y_3 的概率之和为 1,概率最大的类别将作为预测的输出类别。

3 实验结果和分析

在正常情况下,道岔故障因为很少发生。为了保证样本的多样性和验证算法的有效性,将样本集用随机法分为训练样本集和测试样本集,为了充分利用数据采用十倍交叉验证的方式来进行训练和验证算法的有效性。基于 Python 3.6 的环境,利用 sklearn 进行数据预处理,采用 Keras 深度学习框架和来搭建故障诊断模型,最终的实验结果如图 4 - 图 6 所示。




图 4 特征节点个数和验证集准确率的关系曲线

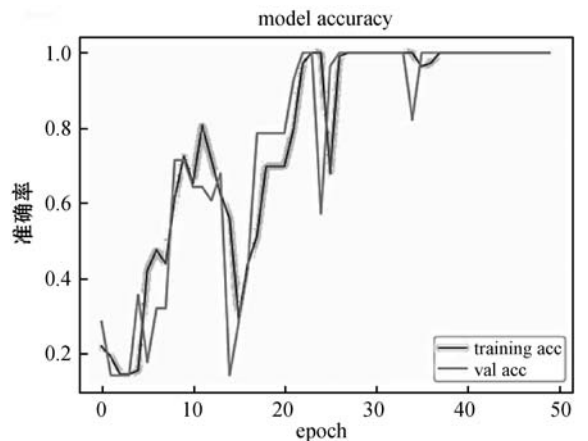


图 5 准确率和迭代次数的关系曲线

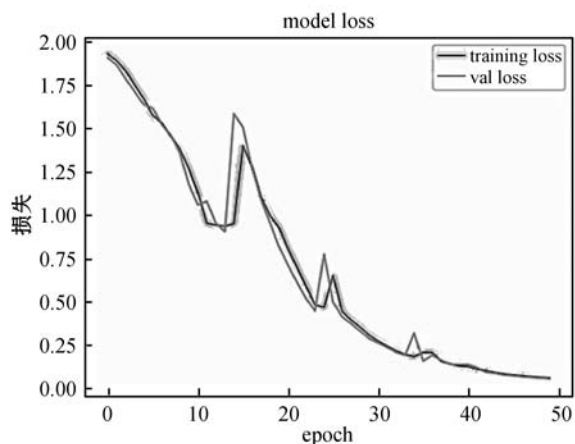


图 6 模型学习过程交叉熵损失曲线

图 4 反映了输出特征个数和最终预测准确率的关系,从图中可以看出当输出特征节点为 50 的时候验证集刚好达到最高准确率。如果输出特征个数取太多会增加计算量减慢计算速度,甚至容易导致模型过拟合,因此本实验最终选择输出特征个数为 50。

如图 5 所示,training acc 是训练集准确率, val acc 是验证集准确率。由最终的实验结果可以看出模型迭代到 40 代以后收敛,训练集上的准确率为 100%,验证集上准确率为 99.7%。如图 6 所示,训练集和验证集交叉熵损失也在 40 代以后接近为 0。因为本文使用的训练数据是电流曲线的所有采集点没有丢失任何电流曲线的有效信息,模型可以根据训练集自动地学习出和结果十分相关的中间特征,因而大大提高了准确率。

由表 2 可以看出,基于 LSTM 和神经网络结合的方式不仅可以用来预测故障而且在预测的准确率上也比其他方法高。

表 2 LSTM 故障诊断模型和其他方法的对比

模型	预测方式	预测准确率
LSTM 故障诊断模型	识别多类别故障	99.7%
基于 SVM 的故障诊断	识别有无故障的二分类	88%
基于 BP 神经网络的故障诊断	识别多类别故障	97%

4 结 语

本文采用通过构建 LSTM 诊断模型,结合传统神经网络的识别算法,为自动地从原始三相电流序列中提取重要的特征,根据特征来对道岔动作电流曲线进行智能故障识别提出了一种改进的方法。与其他模型的准确率比较,本文提出和实验的方法在预测准确率方面明显高于其他模型算法,在测试集上达到了 99.7%

准确率。针对铁路道岔故障的预测与识别,在第一时间发现道岔故障和保障列车在铁路道岔现场的实时应用安全具有重要的现实意义、经济和社会意义。

参 考 文 献

- [1] 韩煜霖,杨静,邢宗义. 基于定性趋势分析的道岔故障诊断方法研究[J]. 铁道标准设计,2017,61(12):120-125,130.
- [2] 梅欢,马艳东,单九思,等. 基于样条插值与 RBF 网络的道岔故障诊断系统[J]. 计算机技术与发展,2017,27(5):160-163,169.
- [3] 余飞. 信号专家诊断系统及其在设备故障预防中的应用[J]. 神华科技,2016,14(1):87-90.
- [4] 张凯. 基于神经网络的铁路道岔故障智能诊断研究[D]. 西安:长安大学,2016.
- [5] 张星,魏文军. 基于支持向量机的道岔故障动作电流识别[J]. 电脑知识与技术,2016,12(7):264-265.
- [6] 程宇佳. 基于核方法的高速铁路道岔故障诊断[D]. 北京:北京交通大学,2016.
- [7] 唐德权,史伟奇,张波云. 基于多模态信息特征融合的犯罪预测算法研究[J]. 计算机应用与软件,2018,35(7):221-225,262.
- [8] 冷建伟,李鹏. 基于最优特征更新分类器的压缩跟踪算法[J]. 计算机应用与软件,2018,35(2):206-211.
- [9] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.

(上接第 82 页)

- [2] 黄曦,丁友东,吴兵. 老电影全局闪烁修复系统的设计与实现[J]. 电视技术,2016,40(12):125-129.
- [3] 许文韬,陈昭炯. 主体对象可控的渐进式色彩传递[J]. 计算机工程,2016,42(9):246-251.
- [4] 仲红玉,尹丽菊,高明亮. 多参数亮度值重映射的颜色传递方法[J]. 红外与激光工程,2018,47(5):21-28.
- [5] 张引,饶娜,张三元,等. 自动采集样本的图像颜色传递算法[J]. 中国图象图形学报,2005,10(10):1258-1263.
- [6] 朱黎博,孙韶媛,谷小婧,等. 基于色彩传递与扩展的图像着色算法[J]. 中国图象图形学报,2010,15(2):200-205.
- [7] 滕秀花,胡文瑜,陈敏. 一种基于 SLIC 的超像素快速色彩传递算法[J]. 哈尔滨师范大学自然科学学报,2014,30(3):77-80.
- [8] Reinhard E, Adhikhmin M, Gooch B, et al. Color transfer between images[J]. IEEE Computer Graphics and Applications, 2002, 21(5):34-41.
- [9] 李在万. 设计师谈商业配色密码[M]. 北京:电子工业出版社,2007.
- [10] 商露兮,方建安,谷小婧,等. 夜视图像自动彩色化源图像选择算法[J]. 激光与红外,2009,39(2):223-226.