

DOI:10.19651/j.cnki.emt.2210198

基于机器学习的有色金属冶炼工序识别^{*}

汪繁荣^{1,2} 方祖春^{1,2} 刘宇航¹ 汪筠涵¹

(1. 湖北工业大学电气与电子工程学院 武汉 430068; 2. 襄阳湖北工业大学产业研究院 襄阳 441100)

摘要:为实现生产工序的准确识别,提出基于机器学习的工序识别模型,分别选取时间卷积网络、长短期记忆网络、支持向量机构建工序识别模型,并结合某钛金属冶炼企业生产能耗数据对模型进行测试验证。首先对历史功率及工序数据进行预处理,然后根据生产特征构造用于模型训练及测试数据集,最后结合数据集对模型进行训练和测试。结果表明基于时间卷积网络的识别模型具有较高的工序识别准确率,针对测试集的工序识别准确率达96.94%。

关键词:机器学习;时间卷积网络;长短期记忆网络;支持向量机;工序识别

中图分类号: TM714 文献标识码: A 国家标准学科分类代码: 510.1050

Non-ferrous metal smelting process identification based on machine learning

Wang Fanrong^{1,2} Fang Zuchun^{1,2} Liu Yuhang¹ Wang Junhan¹

(1. School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, China;

2. Xiangyang Industrial Institute of Hubei University of Technology, Xiangyang 441100, China)

Abstract: In order to realize the accurate identification of production processes, a process identification model based on machine learning was proposed. Time convolution network, long and short term memory network and support vector machine were selected to build the process identification model, and the model was tested and verified with the production energy consumption data of a titanium metal refining enterprise. Firstly, the historical power and process data were preprocessed, and then the model training and testing data set was constructed according to the production characteristics. Finally, the model was trained and tested based on the data set. The results shows that the recognition model based on time convolution network has a high accuracy of process identification, and the accuracy of process identification for test sets reaches 96.94%.

Keywords: machine learning; time convolution network; long and short term memory network; support vector machine; production process recognition

0 引言

近年来由于温室效应的不断恶化和自然资源的逐渐枯竭,可持续发展和低碳节能逐渐得到许多行业的关注与支持。我国钢铁、有色金属等冶炼行业由于其生产工艺特点,一直存在能耗高的问题,是我国减少碳排放重点关注行业之一。因此针对有色金属冶炼的生产能耗管理系统具备一定的应用前景。根据相关生产数据确定生产工序,即有助于对生产线生产过程进行实时监测,也可计算出每道工序对应的生产时间、功率,结合能耗管理系统进行详细的用能分析。同时根据电能计费的峰-平-谷规则,在确保产量等要求的情况下,对所有的生产过程进行合理的安排与规划,

避开计费高峰,从而降低企业生产成本,提高生产效益,而确定生产工序有助于管理人员监测实际生产过程是否与计划保持一致,并及时做出相应的处理。目前针对少量数据、规律较明显的工序识别可以通过人工分析确定,如文献[1]通过系统采集的瓦斯浓度变化规律判定掘进工作面生产工序。但是对于数据量大、逻辑关系较复杂的生产工序确定问题,人工分析实现起来较困难,或识别结果准确率难以达到应用要求。如今机器学习在机器视觉、文本识别、故障判别等领域^[2-3]取得了一系列的成就,基于机器学习方法的分类模型在分类或识别方面拥有更强的能力,通过数据驱动的识别或分类模型能够从海量数据中学习输入与输出间的高维、非线性关系,并排除错误信息,最终做出智能诊断决

收稿日期:2022-06-03

*基金项目:国家自然科学基金(61903129)项目资助

策^[4-6]。本文选择常用的 3 种机器学习算法进行模型构建, 分别为时间卷积网络 (temporal convolutional network, TCN)、长短期记忆神经网络 (long short term memory, LSTM)、支持向量机 (support vector machine, SVM)。并结合青海某钛金属冶炼企业某生产线生产能耗及生产工序信息对模型进行训练和测试, 选出工序识别率准确率较高的模型, 用于企业生产线实际工序识别, 并结合能耗管理系统、生产管理系统, 助力企业实现节能、增效目的。

1 方法介绍

1.1 TCN 网络

时间卷积网络 (TCN) 是一种基于残差模块的卷积网络, 其不仅具备卷积网络在数据特征提取、并行处理等方面的优势, 而且通过卷积操作代替递归操作还可用于处理时序数据^[7]。TCN 的结构如图 1 所示, 从结构图中可知, 任意 t 时刻的输出, 只和 t 时刻及之前的输入有关, 且每一层链接到上一层时可以间隔一定距离选择数据, 依次类推, 可以保证输出层具有较大范围的视野, 从而该模型可以学习数据的长期依赖关系。因此, 结合相关激活函数 TCN 既可以用于构建数据预测类模型, 也可用于解决故障诊断分类等问题。




图 1 TCN 结构

TCN 主要结构的组成部分及介绍如表 1 所示。其中膨胀卷积使得模型拥有较大的视野同时减小了模型的复杂度, 因此 TCN 可以处理长期的数据依赖关系。残差连接可以加速模型收敛, 同时防止模型退化, 避免出现梯度消失问题。

表 1 TCN 各组成部分

名称	数学表达式	说明
因果卷积	$F(x_t) = \sum_{i=1}^K f_i \times x_{t-K+i}$	按照时间先后进行卷积操作, 保证没有泄露未来信息。
膨胀卷积	$F(x_t) = \sum_{i=0}^M f_i \times x_{t-d \times i}$	增大每层感受野, 减小卷积层数量。
残差连接	$F(x_t, \mathbf{W}_t) = H(x_t) - x_t$	防止模型退化, 模型收敛更快。

式中: f_i 为滤波器 i 对应的参数, K 为卷积核大小, M 为滤波器个数, d 为膨胀系数, \mathbf{W}_t 为 t 层的权重参数矩阵,

$H(x_t)$ 为实际目标映射值。

1.2 LSTM 网络

长短期记忆网络 (LSTM) 是一种改进的循环神经网络, 相对于传统的循环神经网络 RNN 只能处理一定短期依赖问题, LSTM 算法可用于处理长期非线性、非平稳的时间序列数据^[8-9]。

LSTM 网络单元结构如图 2 所示。




图 2 LSTM 网络单元结构

相对于传统的循环神经网络 RNN 新增了门结构和单元状态, 其中门结构包含类型及相关信息如表 2 所示^[10]。

表 2 门结构类型及相关信息

门类型	数学表达式	作用
遗忘门	$f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, x_t] + \mathbf{B}_f)$	决定单元状态中丢弃的数据
输入门	$i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, x_t] + \mathbf{B}_i)$	决定单元状态中保存的数据
	$r_t = \tanh(\mathbf{W}_r \cdot [h_{t-1}, x_t] + \mathbf{B}_r)$	
	$c_t = f_t \cdot c_{t-1} + i_t \cdot r_t$	
输出门	$o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, x_t] + \mathbf{B}_o)$	决定单元状态中输出的数据
	$h_t = o_t \cdot \tanh(c_t)$	

x_t 为 t 时刻的输入信息, h_t 为 t 时刻的输出信息, σ 为 sigmoid 激活函数, \tanh 是双曲正切激活函数, x_t 表示当前时刻的样本输入, 其中, $\mathbf{W}_f, \mathbf{W}_i, \mathbf{W}_r, \mathbf{W}_o, \mathbf{B}_f, \mathbf{B}_i, \mathbf{B}_r, \mathbf{B}_o$ 为相关矩阵, c_t 为当前单元状态, r_t 表示当前时刻保存的信息。

1.3 SVM 算法

支持向量机 (SVM) 是一种运用统计学相关理论进行机器学习训练的人工智能算法^[11], 主要用于解决二分类问题, 其主要思想为求解以最大间隔分割训练数据的最优超平面, 对于线性不可分等复杂数据, 使用相关核函数将原始数据映射到高维特征空间中进行求解^[12]。基于 SVM 的模型由于其精确、稳健, 且不容易出现过拟合现象等优点在分类、回归及模式识别领域具有一定的应用前景^[13-14]。

假定给定的分类集为:

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\} \quad (1)$$

式中: $x_m \in R^n$ 为第 m 个训练样本的 n 维输入列向量, 其表达式为:

$$x_m = [x_m^1, x_m^2, \dots, x_m^n]^T, x_m \in R^n \quad (2)$$

y_m 为第 m 个训练样本的分类值, 为 +1 或 -1, 取值条件为:

$$\begin{cases} x_m \in \Omega_{no}, & y_m = +1 \\ x_m \in \Omega_{fa}, & y_m = -1 \end{cases} \quad (3)$$

式中: Ω_{no} 为正确分类集合, Ω_{fa} 为错误分类集合。

在高维空间的分类器或超平面表达式为:

$$D(x_m) = \omega^T \phi(x_m) + b \quad (4)$$

其中, $\phi(x_m)$ 为映射后的特征向量, ω 为待求解的最优 n 维列向量, b 为最优阈值, 假定分类点到分类器或最优超平面的距离为 $S(\omega, \xi)$, 则通过添加相关的约束条件将求解最优超平面转化为求解二次规划最优解问题^[15], 即:

$$\begin{aligned} \min S(\omega, \xi) &= \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \\ s.t., & \begin{cases} y_i(\omega \cdot x_i + b) \geq 1 - \xi_i, & i = 1, 2, \dots, n \\ \xi_i \geq 0 \end{cases} \end{aligned} \quad (5)$$

式中: ξ_i 为误差值, C 为惩罚系数。

以上为二分类的 SVM 模型介绍, 对于多分类问题, 如分为 m 类, 则分为第 j 类和第 k 类其求解公式如下^[16]:

$$\begin{aligned} \min_{\omega^{jk}, b^{jk}, \xi^{jk}} & \frac{1}{2} \|\omega^{jk}\|^2 + C \sum_{i=1}^n \xi_i^{jk} \\ s.t., & \begin{cases} (\omega^{jk})^T \phi(x_i) + b^{jk} \geq 1 - \xi_i^{jk}, & y_i = j \\ (\omega^{jk})^T \phi(x_i) + b^{jk} \leq \xi_i^{jk} - 1, & y_i \neq k \\ \xi_i^{jk} \geq 0, & i = 1, 2, \dots, m \end{cases} \end{aligned} \quad (6)$$

粒子群优化算法(particle swarm optimization, PSO)由于其原理易于理解、结构简单、容易实现等特点逐渐得到人们的重视并逐步应用于多种模型的参数寻优中^[16]。相对于网格搜索法等传统方法, PSO 通过模仿群体行为进行相互合作学习来寻找最优解, 因此能以更快的收敛速度在全局搜索中获得更好的结果, 其算法流程图及相关理论见文献[16], 本文使用 PSO 求解 SVM 模型关键参数 C 和核函数参数 gama 在指定取值范围内的最优组合。

2 模型搭建

2.1 工序识别模型搭建流程

本文提出的基于机器学习的工序识别模型搭建流程如图 3 所示。

2.2 基于 TCN 和 LSTM 的识别模型

使用 python 语言基于 keras 框架分别搭建了 TCN 和 LSTM 识别分类模型, 模型最后一层全连接层激活函数为 softmax, 模型使用 adam 优化器, 并将分类交叉熵损失(categorical cross entropy loss)作为损失函数^[17], 模型的关键参数采用经验法和试错法, 通过不同的参数组合结合训练数据对模型进行训练, 比较得出对应模型识别准确率最高的参数组合。




图 3 工序识别模型搭建流程

2.3 基于 SVM 的识别模型

使用 python 语言及相关框架搭建了 SVM 判断模型, 使用径向基核函数对数据进行相关映射处理, 模型关键参数 C 和 gama 经 PSO 获得。

3 实验过程及结果

3.1 实验数据获取与处理

本文选取青海某钛金属冶炼企业某一生产线自 2021 年 8 月 6 日~2021 年 8 月 30 日共 25 天连续生产能耗数据, 结合生产工序记录数据, 最后获得 3 556 组生产能耗与对应工序数据。针对原始数据个别值差异太大可能会影响模型收敛效果的问题, 对数据进行归一化处理, 按照统一比例将样本数据大小映射到 $[0, 1]$ 范围内。

该有色金属生产线运行方式为按照固定流程进行 24 h 不间断运作, 主要生产流程包括容器清理、容器抽真空、加热、拉铤、补缩、冷却, 各工序间存在中断等待时间, 本文根据不消耗电能将容器清理和等待归为一类, 其余工序各为一类, 最终的工序定义如表 3 所示。

表 3 生产工序分类

序号	对应工序
0	清炉或等待
1	炉内抽真空
2	炉内加热
3	拉铤
4	补缩
5	冷却

经归一化处理后根据生产特征构造相关数据集, 如选取前一时刻功率、当前功率、前 287 时刻工序数据构成特征数据集, 以当前时刻生产工序作为标签数据, 最后得到 3 268 组特征数据集及对应的标签数据集。选择前 2 941 组特征数据集及对应的标签数据集作为模型训练数据集, 后 327 组相关数据集作为模型测试数据集。训练集中标签

数据集各工序统计信息如表 4 所示。

表 4 训练集中各工序数量及比例

工序编号	数量	占比/%
0	913	31.04
1	248	8.43
2	414	14.07
3	903	30.7
4	127	4.32
5	336	11.42

从表中可以看出,测试数据集包含各种工序的训练数据,测试数据集种类完整,但是工序 0 和工序 3 所占的比例最大,各工序分布存在不平衡现象。

测试集中标签数据集各工序统计信息如表 5 所示,同样存在个别工序对应的数据所占比例较大,在实际应用中应尽可能获取更多平衡、完整的数据集,减少数据集不平衡对模型训练的影响。

表 5 测试集中各工序数量及比例

工序编号	数量	占比/%
0	82	25.07
1	15	4.59
2	23	7.03
3	167	51.07
4	16	4.89
5	24	7.34

选取测试集中目标数据集即生产工序进行展示,对应的图形如图 4 所示。




图 4 测试集生产工序图

3.2 实验过程

按照工序识别模型搭建流程图,结合训练数据集和测试数据集,分别建立基于 TCN、LSTM、SVM 的工序识别模型,模型评价指标为工序识别准确率,计算表达式如下:

$$acc = \frac{N_{acc}}{N} \times 100\% \quad (7)$$

式中: N_{acc} 为工序识别结果与实际值保持一致的数量, N 为测试集数据总数。

实际生产中除工序 0 以外,其他工序严格按照顺序进行,且单个完整的生产过程持续时间在 30 h 左右,为使模型获取足够长的观察视野,同时减少模型的复杂度和训练时间,本文分别选择 24 h、36 h、48 h 时间窗口构造特征数据集,标签集为当前时刻的工序类型并保持不变,以模型的识别准确率作为目标函数,然后采取遍历的方式寻找最高识别率对应的模型参数。其中基于 TCN 的工序识别模型的数据处理流程如图 5 所示。在指定模型的参数范围及目标函数后,分别带入不同的特征数据集与标签数据集进行训练与测试。




图 5 基于 TCN 模型的数据处理流程

3.3 实验结果

各工序识别模型针对测试集的识别结果如图 6 所示,识别正确率如表 6 所示。

由图 6 可以看出 3 种工序识别模型的识别结果在工序进行切换时均无法准确识别,存在一个或多个采样间隔的错误,同时对于工序中间的短暂跳变,如工序 2 到工序 0,再到工序 3,3 种模型均无法识别,而基于 SVM 的工序识别模型效果较差,存在某道工序连续多个采样间隔均无法正确识别的情况。从 3 种模型的识别结果对比图中可以看出在采样序号 200~225 之间,基于 SVM 的工序识别模型并未识别出对应的正确工序,造成针对测试集的识别结果误差较大,其对应的整体识别正确率最低,仅为 85.32%,同样基于 LSTM 的识别模型在采样序号 225~250 之间存在较多的错误识别结果,基于 TCN 的识别模型识别结果基本和目标工序保持一致,仅有个别的识别错误,针对测试集的识别准确率最高。




图 6 各识别模型针对测试集识别结果及对比

3 种识别模型的测试结果及对比表明相对于其他方法,时间卷积网络能从数据中学习到更多逻辑关系,较适合本文研究的应用场景,能提供较为准确的工序识别服务。

表 6 识别模型针对测试集识别准确率

算法	准确率/%
TCN	96.94
LSTM	95.11
SVM	85.32

4 结 论

本文通过分别建立基于 TCN、LSTM、SVM 算法的生产工序识别模型,并结合青海某钛金属冶炼企业某生产线实际生产能耗及工序信息对模型进行训练和测试,研究结果表明基于机器学习的工序识别模型在处理数据量大、关系较复杂的逻辑关系中具有一定的优势,原始数据经过简单的处理后可以直接输入到预先训练好的识别模型中进行识别处理,相对于人工分析方法,无需繁琐的数据处理与分析过程,简化识别过程的同时也能取得较高的识别准确率。同时该研究结果可结合生产管理系统及能耗管理系统,有助于企业实现如下节能、增效目的:结合生产计划及时调整生产安排,避开电费计量高峰期,达到降低企业生产成本、提高生产效益的目的;结合能耗管理系统,对生产过程涉及的每道工序能耗进行精准分析,及时发现存在耗能异常的工序并提醒管理人员做出相应处理。

但是本文所提模型的识别准确率还有待提升,后续可从优化模型相关参数方向进行深入研究,可以通过其他算法进一步优化模型的相关参数,提高模型识别准确率的同时优化模型结构,减少模型训练时间,提高本研究成果的实用性,助力企业实现节能、降本增效目的。

参考文献

- [1] 屈世甲. 矿井掘进巷道生产工序自动识别方法的探索[J]. 煤矿安全, 2015, 46(4): 206-209.
- [2] ZHANG R, BAHRAMI Z, WANG T, et al. An adaptive deep learning framework for shipping container code localization and recognition[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-13.
- [3] 张昌凡, 刘佳峰, 何静, 等. 基于改进卷积双向门控循环网络的轴承故障诊断[J]. 电子测量与仪器学报, 2021, 35(11): 61-67.
- [4] LI P. Research on radar signal recognition based on automatic machine learning[J]. Neural Computing & Applications, 2019, 32(7): 1959-1969.
- [5] 吉兴全, 陈金硕, 张玉敏, 等. 基于 CNN-SVM 的配电网故障分类研究[J]. 智慧电力, 2022, 50(1): 94-100.
- [6] ULLAH F U M, OBAIDAT M S, MUHAMMAD K, et al. An intelligent system for complex violence pattern analysis and detection[J]. International Journal

- of Intelligent Systems, 2022, 37(12): 10400-10422.
- [7] 刘辉, 李永康, 张森, 等. 基于 GWO-TCN 网络的 HVDC 输电线路故障诊断[J]. 电子测量技术, 2021, 44(22): 168-174.
- [8] ZHAO Y, XU H, YANG T, et al. A hybrid recognition model of microseismic signals for underground mining based on CNN and LSTM networks[J]. Geomatics, Natural Hazards and Risk, 2021, 12(1): 2803-2834.
- [9] ABDELSALAM A A, HASSANIN A M, HASANIEN H M. Categorisation of power quality problems using long short-term memory networks [J]. IET Generation, Transmission & Distribution, 2021, 15(10): 1626-1639.
- [10] HUANG F, LI X, YUAN C, et al. Attention-Emotion-Enhanced Convolutional LSTM for Sentiment Analysis[J]. IEEE Trans Neural Netw Learn Syst, 2021, DOI:10.1109/TNNLS.2021.3056664.
- [11] TABRIZI S S, PASHAZADEH S, JAVANI V. Comparative study of table tennis forehand strokes classification using deep learning and SVM[J]. IEEE Sensors Journal, 2020, 20(22): 13552-13561.
- [12] SHI Q, ZHANG H. Fault diagnosis of an autonomous vehicle with an improved SVM algorithm subject to unbalanced datasets [J]. IEEE Transactions on Industrial Electronics(1982), 2021, 68(7): 6248-6256.
- [13] WANG M, CHEN H. Chaotic multi-swarm whale optimizer boosted support vector machine for medical diagnosis [J]. Applied Soft Computing, 2020, 88: 105946.
- [14] DENG F, GUO S, ZHOU R, et al. Sensor multifault diagnosis with improved support vector machines[J]. IEEE Transactions on Automation Science and Engineering, 2017, 14(2): 1053-1063.
- [15] ZHOU Z, ZHANG R, WANG Y, et al. Color difference classification based on optimization support vector machine of improved grey wolf algorithm[J]. Optik(Stuttgart), 2018, 170: 17-29.
- [16] 张友鹏, 魏智健, 杨妮, 等. 基于 KPCA-SVM 的 S700K 转辙机故障诊断方法[J]. 安全与环境学报, 2022: 1-10.
- [17] 宫文峰, 陈辉, 张美玲, 等. 基于深度学习的电机轴承微小故障智能诊断方法[J]. 仪器仪表学报, 2020, 41(1): 195-205.

作者简介

汪繁荣,博士,副教授,主要研究方向为电网控制与智能制造、能耗管理、非侵入式负荷分解。

E-mail:77129580@qq.com

方祖春(通信作者),硕士研究生,主要研究方向为电网控制与智能制造、能耗管理。

E-mail:1639264984@qq.com

刘宇航,硕士研究生,主要研究方向为电网控制与智能制造、非侵入式负荷分解。

E-mail:1144367412@qq.com

汪筠涵,硕士研究生,主要研究方向为电网控制与智能制造。

E-mail:1195341202@qq.com