

基于 LSTM-Attention 的高黏稠食品灌装流量检测

doi:10.3969/j.issn.1674-7100.2020.01.005

张昌凡 孙琳
孙晓

湖南工业大学
电气与信息工程学院
湖南 株洲 412007

摘要:针对黏稠食品灌装过程中高精度检测流量的难题,提出一种基于深度学习的高黏稠食品灌装流量实时检测方法。首先对采集到的流量相关过程变量进行序列化及归一化处理,转化为可供有监督学习网络处理的数据;然后对注意力机制下的长短时记忆神经网络(LSTM-Attention)进行训练和泛化,采用自适应矩估计优化算法(Adam),进而建立高黏稠食品灌装流量检测模型;最后将本模型检测所得流量值与其实际值进行对比,用均方误差函数(MSE)对该模型在灌装流量检测上的性能进行评价。通过与循环神经网络(RNN)、普通长短期记忆模型下流量检测的均方误差作比较,实验结果表明,本模型的流量检测精度较高,流量检测数据实时跟踪效果较好。

关键词:高黏稠食品;灌装流量检测;长短时记忆神经网络;注意力机制;深度学习

中图分类号: TP183

文献标志码: A

文章编号: 1674-7100(2020)01-0036-07

引文格式:张昌凡,孙琳,孙晓.基于 LSTM-Attention 的高黏稠食品灌装流量检测[J].包装学报,2020,12(1):36-42.

0 引言

在流质食品的自动化灌装过程中,流量精准测量是保证灌装速度和定量精度的一个关键环节。目前,大多数灌装设备中所使用的物料定量方式主要分为两种:一种是在灌装阀中内置电磁流量计,通过物料流过管体来进行流量计量,但由于黏稠食品的起泡性、高黏性、流动不稳定性等物理特性,会使流量计的计量精度在一定程度上受到影响;另一种是在灌装机的卡瓶部位安装称重传感器,通过作用在瓶子上的重力转换为可计量的输出信号来实现物料定量,而鉴于称重传感器的过载能力较差,故难以达到较高的精确等级。此外这两种方式都具有一定的滞后性,

对于流量的实时检测及灌装阀的通断控制的参考性也有所降低。因此,研究高精度的黏稠食品灌装流量实时检测方法有着重要的意义。

在现有研究中,已有许多学者在流量实时测量领域作出了贡献。T. T. Nguyen 等^[1]提出一种基于超声多普勒原理(Doppler ultrasound)的管道流体流量测量方法,但此类方法容易因被测介质温度多变而导致检测精度下降;S. Yayla 等^[2]提出一种基于粒子成像测速仪(particle image velocimetry, PIV)的多相流流量测量方法,该方法的缺陷在于通过示踪粒子只能反映局部流量信息;Zhou Q. 等^[3]提出一种基于小波变换的纸浆悬浮液流量实时软测量方法;Tang Y. 等^[4]提出了基于 BP 算法的动态流量软测量方法,实现了

收稿日期: 2019-12-14

基金项目: 国家重点研发计划基金资助项目(2018YFD0400705)

作者简介: 张昌凡(1960-),男,湖北武昌人,湖南工业大学教授,博士生导师,主要从事复杂工业工程控制,包装工业自动化方面的研究, E-mail: zhangchangfan@263.net

通信作者: 孙晓(1972-),男,浙江温岭人,湖南工业大学教授,硕士生导师,主要从事机电控制技术,包装装备设计等方面的研究, E-mail: sxbug@163.com

液压系统中流量在线测量精度的提高。尽管软测量技术在实时监测领域有较好效果,但简单的神经网络模型由于训练过程收敛速度慢^[5],容易发生拟合,稳定性差等不足已无法适用复杂流体流量的测量。

近年来,计算机硬件水平的不断增强为深度神经网络的应用创造了必要的条件。G. E. Hinton 等^[6]于 2006 年第一次提出深度置信网络的概念,相对于传统的浅层学习方法,深度学习^[7]可以从原始特征中提取更有效的多尺度特征,收敛速度更快,鲁棒性更好^[8]。在众多的数据处理模型中,长短时记忆神经网络(long-short term memory, LSTM)模型因其对时序数据的强大处理能力而在实时检测领域中已有不少成功的应用案例。Ke W. S. 等^[9]提出了基于长短时记忆单元的软测量建模方法,以解决工业过程中的动态性问题;李泽龙等^[10]提出基于 LSTM 模型的铁水硅含量检测方法,有效改善了高炉炼铁中的滞后问题;Song X. J. 等^[11]提出了基于 LSTM-Kalman 模型的空气污染物数据检测方法,进一步提高了 LSTM 长期检测能力。以上研究成果证明了 LSTM 模型在时序数据检测中的可行性。因此,本文提出一种基于 LSTM 的流量实时检测方法,以克服高黏稠食品复杂流变特性给流量测量带来的滞后问题,提高黏稠食品灌装精度,保证灌装质量。

1 数据选择与处理

1.1 数据选择

为了在高黏稠食品灌装过程中实现流量实时连续测量,本课题组选取流量检测模型中的相关过程变量。根据灌装生产知识经验,选取了 5 个灌装机中可以影响流量测量的相关因子作为模型的输入,分别是压力、压差、温度、流动噪声和物料黏度。因此本文

从 DCS (data communication system) 采集的高黏稠食品灌装系统的数据中选取了 4000 个时间点的变量值,每个时间点的数据为以上 5 个变量与当前时刻的体积流量状态数据,数据导出的文件格式为 .csv。

1.2 数据预处理

数据集中压力、压差、温度、流动噪声、物料黏度和体积流量这 6 个变量数据具有不同的量纲,数值与分布差别较大,若将其直接作为模型的输入,数据分析结果则会受到指标之间的量纲影响。归一化^[12]是一种简化计算的方式,即将有量纲的表达式,经过变换,化为无量纲的表达式,成为标量。因此将流量相关变量数据进行归一化,在一定程度上提高了模型的检测精度,此外,也加快了梯度下降求最优解的速度。常用的归一化方法有线性归一化(min-max 标准化)、标准差归一化(Z-score 标准化)、非线性归一化^[13],本文采用 min-max 标准化。记一段连续时间内的流量相关变量数据为 X ,即

$$X = (X_1, X_2, \dots, X_6) = (X^{(1)}, X^{(2)}, \dots, X^{(t)})^T, \quad (1)$$

式中: X_m 为一段时间内第 m 个流量相关变量的数据向量;

$X^{(t)}$ 为 t 时刻所有流量相关变量的数据向量。

对 t 时刻的第 m 个流量相关变量的数据进行归一化^[14]处理,

$$\bar{x}_m^{(t)} = \frac{x_m^{(t)} - X_m^{\min}}{X_m^{\max} - X_m^{\min}}, \quad X_m^{\max} \neq X_m^{\min}. \quad (2)$$

其中:

$$X_m^{\max} = \max\{X_m^{(1)}, X_m^{(2)}, \dots, X_m^{(t)}\}, \quad (3)$$

$$X_m^{\min} = \min\{X_m^{(1)}, X_m^{(2)}, \dots, X_m^{(t)}\}. \quad (4)$$

经归一化后的部分网络训练样本如表 1 所示。

表 1 网络训练样本

Table 1 Network training samples

样本序号	输入向量					输出向量
	压力	压差	温度	流动噪声	物料黏度	体积流量
1	0.239 005	0.764 846	0.965 366	0.058 625	0.025 417	0.299 583
2	0.231 841	0.758 805	0.968 558	0.051 866	0.050 835	0.312 090
3	0.225 871	0.780 926	0.973 255	0.046 049	0.108 610	0.316 855
4	0.219 303	0.768 589	0.973 723	0.039 748	0.158 274	0.319 833
5	0.217 911	0.742 641	0.977 128	0.042 172	0.194 188	0.340 697

1.3 流量数据反归一化

将相关流量变量数据作为模型的输入,但模型

的输出并不是最终流量检测值,而是由归一化的输入数据所产生的归一化后的结果,因此,需要对模

型的输出进行反归一化处理。反归一化的计算表达式如下：

$$\hat{y}^{(t)} = \bar{y}^{(t)} (Y_j^{\max} - Y_j^{\min}) + Y_j^{\min} \quad (5)$$

式中： $\bar{y}^{(t)}$ 为模型的输出；

$\hat{y}^{(t)}$ 为模型输出经反归一化后的结果，即最终检测流量值。

2 灌装流量检测模型的建立

本文提出的灌装流量检测方法是將 LSTM 与多层感知器 (multi-layer perception, MLP) 方法相结合，

其不仅能够弥补普通循环神经网络梯度消失、梯度爆炸、长期记忆能力不足等问题，还能自动地提取数据中隐藏在多个流量相关变量之间的复杂非线性关系^[15]。此外，为改善多个时间序列样本相关性不同的问题，引入注意力机制 (attention)，并以采集的过去一段时间内 5 个流量相关变量 (压力、压差、温度、流动噪声、物料黏度) 经归一化后的数据作为模型的输入，以其对应当前时刻经反归一化处理后的体积流量值作为输出，构建了多输入单输出的黏稠食品灌装流量检测模型。灌装流量检测模型的整体结构框架图如图 1 所示。

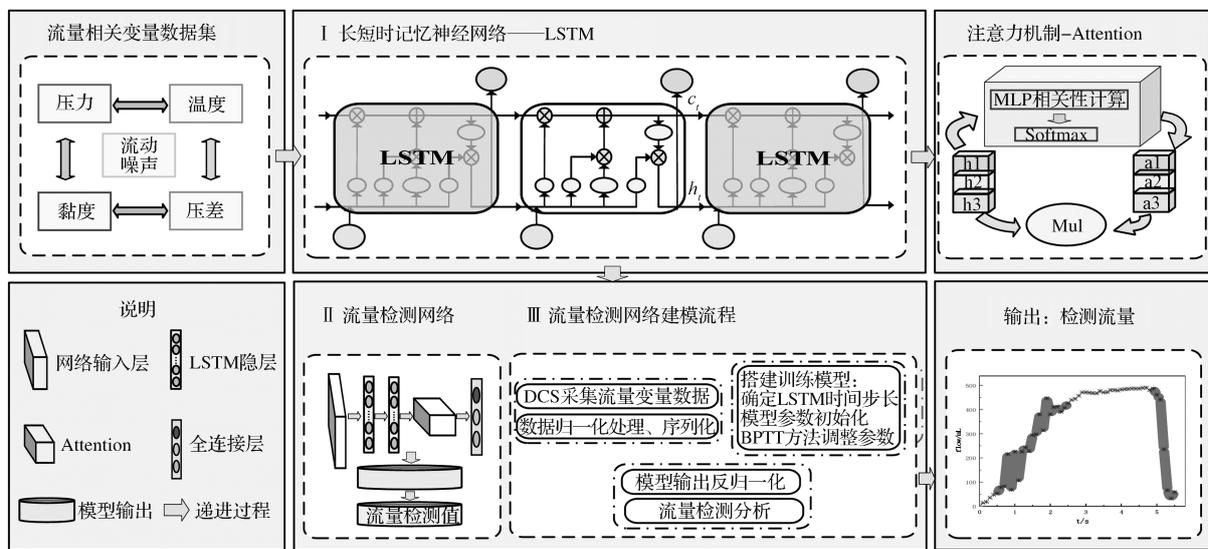


图 1 基于 LSTM-Attention 灌装流量检测模型的框架图

Fig. 1 Framework of filling flow detection model based on LSTM-Attention

2.1 LSTM 模型

作为一种特殊的循环神经网络 (recurrent neural network, RNN)，LSTM 也具有类似于 RNN 的递归结构。但是，与简单的 RNN 网络不同，LSTM 通过引入门控开关的思想，使其可以在较长时间内传递对输出有价值的信息，从而实现长期依赖关系^[16]。LSTM 网络结构如图 2 所示^[17]。

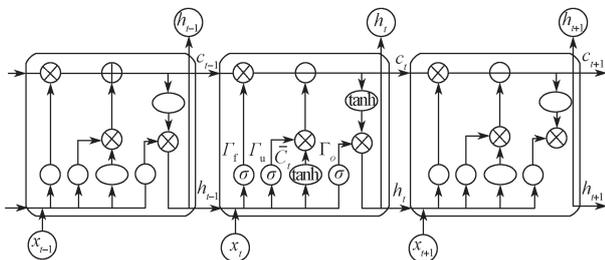


图 2 LSTM 结构图

Fig. 2 LSTM network structure diagram

LSTM 的前向传播过程^[18]如下：

首先，通过 tanh 层创建一个新的候选细胞状态，并创建输入门，用以控制候选细胞中的信息是否被保留以及更新细胞状态。相关处理的表达式如下：

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (6)$$

$$\Gamma_u = \sigma(W_u[h_{t-1}, x_t] + b_u) \quad (7)$$

式中： \tilde{C}_t 为候选细胞状态；

Γ_u 为输入门；

σ 为 sigmoid 函数；

\tanh 为双曲正切激活函数；

h_{t-1} 为 $t-1$ 时刻 LSTM 单元隐层的输出；

x_t 为 t 时刻 LSTM 网络的输入；

W 为权重系数矩阵；

b 为偏置项。

其次，通过 sigmoid 函数构建遗忘门，用以决定

上一时刻细胞中的哪些信息被保留, 并与候选细胞状态中的信息相结合, 从而实现细胞状态的更新。相关处理的表达式如下:

$$\Gamma_f = \sigma(W_f[h_{t-1}, x_t] + b_f), \quad (8)$$

$$C_t = \Gamma_f \cdot C_{t-1} + \Gamma_u \cdot \tilde{C}_t. \quad (9)$$

式中: Γ_f 为遗忘门;

C_t 为更新后的当前细胞状态;

C_{t-1} 为上一时刻的细胞状态。

最后, 使用 sigmoid 函数确定输出门, 通过 tanh 函数处理当前细胞状态, 将其与输出门的输出相乘, 用以 LSTM 单元的隐层状态更新。相关处理的表达式如下:

$$\Gamma_o = \sigma(W_o[h_{t-1}, x_t] + b_o), \quad (10)$$

$$h_t = \Gamma_o \cdot \tanh(C_t). \quad (11)$$

式中: Γ_o 为输出门;

h_t 为当前时刻更新后的 LSTM 单元隐含层状态。

2.2 注意力机制

注意力机制的实质是从所有信息中有侧重地选取对目标有用的关键信息^[19]。信息数据集是一段时间内流量相关变量的历史数据与当前时间可观测数据合并得到的完整数据集。在多个时间点的样本信息数据集中, 每个时间点的样本信息对当前流量检测的贡献并不相同, 因此引入 Attention 机制, 为不同时间点的样本信息引入一个对当前灌装流量检测作用的权重分配, 这不仅能使其更有针对性地依赖不同时间点的信息, 更在极大程度上提高了流量检测的实时性和精确度。

2.3 训练流量检测模型

2.3.1 确定时间步长

LSTM 模型能处理任意时间步长, 但随着输入时间步长的增加, 网络训练的时间也会随之加长, 因此需要为网络输入层的设计确定合适的时间步长。本模型选取时间步长 $n=8$, 即利用之前 8 个时间点的历史数据加上当前时刻对应的 5 个流量相关变量的数据, 每个时间对应 8 个时间点的流量相关变量样本信息, 将原本维度大小为 [6] 的数据变成了维度大小为 [8, 6]。

2.3.2 初始化参数

对 LSTM 的各门控开关以及 MLP 中的权重和偏置等参数采用 Xvaier 方法初始化。令当前网络层输入节点数目为 n_i , 输出节点数目为 n_o , Xvaier 方式可

实现下式的均匀分布^[20]:

$$W \sim U \left[-\frac{\sqrt{6}}{\sqrt{n_i + n_o + 1}}, \frac{\sqrt{6}}{\sqrt{n_i + n_o + 1}} \right]. \quad (12)$$

2.3.3 BPTT 调整参数

参数初始化之后, 训练模型, 根据输入灌装流量检测网络的数据得到流量检测值。本文采用基于时间的反向传播算法 (backpropagation trough time, BPTT), 对整个模型的参数进行更新和调整, 从而最小化检测误差, 经多次迭代后完成整个模型的训练。计算检测流量误差的表达式为

$$E = \sum_{i=1}^l (y_i - \hat{y}_i), \quad (13)$$

式中: \hat{y}_i 为第 i 个数据样本的检测值;

y_i 为对应的流量真实值。

2.4 模型流程

本方法流程如下: 首先将 DCS 采集的流量相关变量数据进行归一化处理, 然后训练 LSTM 流量检测模型, 将模型的输出值进行反归一化处理, 得到流量检测值, 随后进行流量检测精度的分析, 完成黏稠食品灌装流量的检测。灌装流量检测的具体流程如图 3 所示。



图 3 灌装流量检测模型的建模流程图

Fig. 3 Modeling process of filling flow detection model

3 实验部分

为验证黏稠食品灌装流量检测模型的检测精度, 本课题组用 PyCharm 编辑器 +Python 语言 +Keras 框架实现模型的训练。Keras 框架对 tensorflow 的调用

使模型搭建更简单方便。模型检测结果的拟合精度采用均方误差 (mean squared error, MSE) 评价。

3.1 参数设定

流量检测模型的初始学习率设为 0.001, 每次迭代选取一个批次样本进行梯度下降, 批次大小 (batchsize) 为 256, 一次迭代周期会遍历完所有的训练序列样本, 设置迭代 300 个 epoch, 采用 Adam 优化方法。网络输入层设置 6 个节点, 2 个 LSTM 隐层, LSTM 隐层设置 32 个节点, MLP 隐层设置 32 个节点。

3.2 实验结果与分析

在实际灌装生产线中, 一个灌装周期为瓶子进入灌装工位到离开并进入送瓶星轮的时间。以 500 mL 的黏稠食品灌装为例, 其灌装过程分为粗灌装、正常灌装和细灌装 3 个阶段, 细灌装的目的是让灌装速度减慢, 精度更高, 其精细灌装的时间大约为一个灌装周期的 1/5。在刚进入粗灌装和正常灌装的模式时, 因为突变冲击, 流量变化产生波动, 随后逐渐恢复到正常状态。将灌装流量相关变量数据集按照 7:3 划分为训练集和测试集。

图 4 为 Attention 机制下 LSTM 模型在一个灌装周期内的流量检测结果与实际流量值对比图。

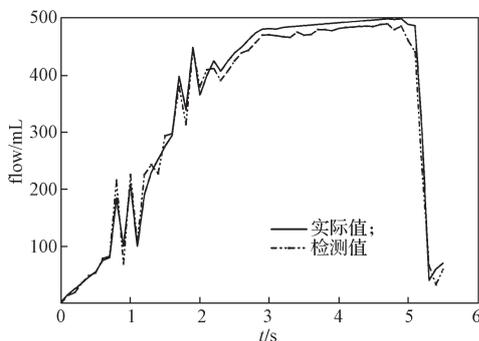


图 4 检测流量与实际流量对比图

Fig. 4 The comparison between the detected and actual flow

由图 4 可知, 在一个灌装周期内, 本模型取得了较理想的检测效果, 其数据跟踪效果较好, 检测流量变化整体趋势与实际灌装的流量走势基本一致, 检测结果稳健。

图 5 为黏稠食品灌装流量检测模型的训练集和测试集的损失函数值变化曲线。

由图 5 可知, 损失函数值随着模型训练次数的增加而减少, 在训练了 600 次时基本稳定, 损失函数值低至 0.04, 可见模型的检测与真实流量值很接近, 误差小, 泛化能力较强。

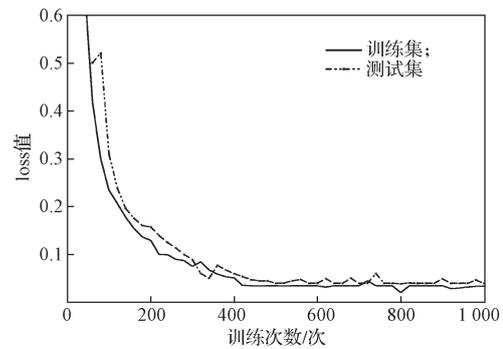


图 5 损失函数值变化曲线

Fig. 5 Curve of loss function

为了进一步验证本文所用模型在黏稠食品灌装流量检测中的性能, 将其与 RNN、LSTM 进行对比实验。各模型均迭代 300 个 epoch, 检测结果用 MSE 评价, 具体结果如表 2 所示。

表 2 针对灌装流量检测的各模型 MSE 结果

Table 2 The MSE comparison of filling flow detection models

模型	MSE	时间 /s
本文模型	0.022	15.314
LSTM	0.063	18.376
RNN	0.139	14.290

由表 2 可知, 本文模型的 MSE 值为 0.022, 明显比 LSTM 和 RNN 模型检测的 MSE 值低; 由于 RNN 的结构简单, 本文模型在 RNN 基础上增加了 LSTM 门控单元以及 Attention 机制, 因而本模型耗时比 RNN 略高, 但远不足以影响模型的训练效果, 这证明了本模型在黏稠食品灌装流量检测的可行性和精确性。

4 结语

考虑灌装生产过程中流量相关变量数据的时间特性, 本文提出了基于 LSTM 的黏稠食品灌装流量检测方法, 在 LSTM 模型的基础上引入了 Attention 机制, 并利用流量数据集验证了本模型的有效性。实验结果表明: 1) 本模型能更好地提取不同时间步长的样本之间的多尺度特征; 2) 在黏稠食品的一个灌装周期内, 检测流量曲线与流量实际变化趋势拟合的效果较好; 3) 与 RNN 及 LSTM 模型进行对比, 本模型的检测精度更高, MSE 值仅为 0.022。因此, 本文提出的基于 LSTM-Attention 的黏稠食品灌装流量检测模型具有良好的性能和泛化能力。

参考文献:

- [1] NGUYEN T T, KIKURA H, MURAKAWA H, et al. Measurement of Bubbly Two-Phase Flow in Vertical Pipe Using Multiwave Ultrasonic Pulsed Doppler Method and Wire Mesh Tomography[J]. Energy Procedia, 2015, 71: 337-351.
- [2] YAYLA S, TEKSIN S. Flow Measurement Around a Cylindrical Body by Attaching Flexible Plate: A PIV Approach[J]. Flow Measurement and Instrumentation, 2018, 62: 56-65.
- [3] ZHOU Q. Soft Measurement of Pulp Suspension Flow Velocity Based on Wavelet Transform[J]. The Canadian Journal of Chemical Engineering, 2010, 88(1): 81-87.
- [4] 唐勇, 马卉宇, 王益群. 动态流量软测量中 BP 算法平坦区问题[J]. 机械工程学报, 2009, 45(9): 89-92.
- TANG Yong, MA Huiyu, WANG Yiqun. Flat Area Problem of BP Algorithm on Soft Measurement System of Dynamic Flow[J]. Journal of Mechanical Engineering, 2009, 45(9): 89-92.
- [5] WANG Y H. Listed Company Financial Risk Prediction Based on BP Neural Work[C]//2015 Seventh International Conference on Measuring Technology and Mechatronics Automation (ICMTMA). Nanchang: IEEE, 2015: 601-604.
- [6] HINTON G E, SALAKHUTDINOV R R. Reducing the Dimensionality of Data with Neural Networks[J]. Science, 2006, 313(5786): 504-507.
- [7] LECUN Y, BENGIO Y, HINTON G. Deep Learning[J]. Nature, 2015, 521(7553): 436-444.
- [8] WANG X Y, GAO L J, MAO S W, et al. CSI-Based Fingerprinting for Indoor Localization: A Deep Learning Approach[J]. IEEE Transactions on Vehicular Technology, 2016, 66(1): 763-776.
- [9] KE W S, HUANG D X, YANG F, et al. Soft Sensor Development and Applications Based on LSTM in Deep Neural Networks[C]//2017 IEEE Symposium Series on Computational Intelligence (SSCI). Honolulu: IEEE, 2017: 8280954.
- [10] 李泽龙, 杨春节, 刘文辉, 等. 基于 LSTM-RNN 模型的铁水硅含量预测[J]. 化工学报, 2018, 69(3): 992-997.
- LI Zelong, YANG Chunjie, LIU Wenhui, et al. Research on Hot Metal Si-Content Prediction Based on LSTM-RNN[J]. CIESC Journal, 2018, 69(3): 992-997.
- [11] SONG X J, HUANG J J, SONG D W. Air Quality Prediction Based on LSTM-Kalman Model[C]//2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC). Chongqing: IEEE, 2019: 695-699.
- [12] MESSINA R, LOURADOUR J. Segmentation-Free Handwritten Chinese Text Recognition with LSTM-RNN[C]//2015 13th International Conference on Document Analysis and Recognition (ICDAR). Tunis: IEEE, 2015: 171-175.
- [13] 何静, 程涛, 黄良辉, 等. 深度可分离卷积神经网络在自动分拣中的应用[J]. 包装学报, 2018, 10(6): 33-40.
- HE Jing, CHENG Tao, HUANG Lianghui, et al. Depth Separable Convolutional Neural Network and Its Application in Automatic Sorting[J]. Packaging Journal, 2018, 10(6): 33-40.
- [14] GENG Z Q, CHEN J, HAN Y M. Energy Efficiency Prediction Based on PCA-FRBF Model: A Case Study of Ethylene Industries[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2017, 47(8): 1763-1773.
- [15] DONAHUE J, HENDRICKS L A, ROHRBACH M, et al. Long-Term Recurrent Convolutional Networks for Visual Recognition and Description[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 677-691.
- [16] KARIM F, MAJUMDAR S, DARABI H, et al. LSTM Fully Convolutional Networks for Time Series Classification[J]. IEEE Access, 2018, 6: 1662-1669.
- [17] GREFF K, SRIVASTAVA R K, KOUTNIK J, et al. LSTM: A Search Space Odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2222-2232.
- [18] SAINATH T N, VINYSALS O, SENIOR A, et al. Convolutional, Long Short-Term Memory, Fully Connected Deep Neural Networks[C]//2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). South Brisbane: IEEE, 2015: 4580-4584.
- [19] LIU J, WANG G, HU P, et al. Global Context-Aware Attention LSTM Networks for 3D Action Recognition[C]//2017 IEEE Conference on Computer

Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 3671-3680.

- [20] 邵伟明, 葛志强, 李浩, 等. 基于循环神经网络的半监督动态软测量建模方法[J]. 电子测量与仪器学报, 2019, 33(11): 7-13.

SHAO Weiming, GE Zhiqiang, LI Hao, et al.

Semisupervised Dynamic Soft Sensing Approaches Based on Recurrent Neural Network[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(11): 7-13.

(责任编辑: 邓彬)

Detection for Filling Flow of High Viscosity Food Based on LSTM-Attention

ZHANG Changfan, SUN Lin, SUN Xiao

(College of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: Aimed at the challenge of high precision detection for filling flow during the filling process of viscous food, a real-time filling flow detection method based on deep learning was proposed. The collected flow-related process variables were serialized and normalized to be converted into data that could be handled by the supervised learning network firstly. Then, the neural network of long short-term memory based on the attention mechanism (LSTM-Attention) was trained and generalized by using the Adaptive moment estimation (Adam) optimization algorithm, thus the model for detecting filling flow of thick liquid food was established. Lastly, the filling flow value detected by this method was compared with the actual flow value, and in the meanwhile the performance of the model in the filling flow detection was evaluated with the mean square error function (MSE). Moreover, compared with the Recurrent Neural Network (RNN) and common long short-term memory (LSTM) method, the experimental results demonstrated that the validity and the high precision of the proposed model were verified, and the real-time tracking effect of the filling flow rate data was better.

Keywords: high viscosity food; filling flow detection; long-short term memory; attention mechanism; deep learning