Transformer-RNN Model for the Identification of Hazardous Chemical Vehicle Loading and Unloading Process*

LI Xiaohui[1], SUN Ziwen[1,2*]

(1.School of Internet of Things, Jiangnan University, Wuxi Jiangsu 214122, China;
2.Engineering Research Center of Internet of Things Technology Applications of Ministry of Education, Wuxi Jiangsu 214122, China)

Abstract: In view of safety accidents caused by theft and leakage during the transportation of hazardous chemicals, Transformer-RNN model is built to identify three states of operation, loading and unloading in the transportation process. Firstly, the original data such as velocity, load and original AD value are obtained from the vehicle installed sensors, and then characteristics of velocity difference, load difference and direction difference are extracted. Secondly, a classification model integrating Transformer and RNN is established. Transformer is used to complete the representation learning of input, RNN is used for learning, and the self-attention mechanism highlights key features. Finally, the classification results are output by the fully connected network. The experimental results show that the accuracy rate, precision rate, recall rate and F1 value of the model are all superior to the existing models.

Key words: vehicle loading and unloading; Transformer; recurrent neural networks; self-attention; time series

EEACC: 7230 **doi**: 10.3969/j.issn.1004-1699.2025.02.010

危化品车辆装卸载过程识别的 Transformer-RNN 模型*

李晓辉[1], 孙子文[1,2*]

(1.江南大学物联网工程学院, 江苏 无锡 214122; 2.物联网技术应用教育部工程研究中心, 江苏 无锡 214122)

摘 要: 针对危化品运输过程的偷倒、漏倒问题导致的安全事故, 构建 Transformer-RNN 模型, 对运输过程中的运行、装载、卸载三种状态进行识别。首先获取通过安装了传感器的车辆传回的速度、载重、原始 AD 值等实时数据, 通过差分提取速度差、载重差、方向差等特征; 其次构建融合 Transformer 和 RNN 的分类模型, 通过 Transformer 完成对输入的表征学习, RNN 进行学习, 自注意力机制突出关键特征; 最后由全连接网络输出分类结果。实验结果表明, 所构建的模型在危化品车运输过程识别中的准确率、查准率、查全率和 F1 值均优于现有模型。

关键词: 车辆装卸载识别; Transformer 模型; 循环神经网络; 自注意力机制; 时间序列

中图分类号: TP391 **文献标识码**: A **文章编号**: 1004-1699(2025)02-0272-07

危险化学品(简称危化品)指具有毒害、腐蚀、爆炸、燃烧等性质, 并对人体、环境具有危害的化学品, 其在运输过程中存在不安全因素[1]。一方面, 装盛危化品的罐体经不起碰撞挤压, 在运输过程中容易发生损坏、泄露; 另一方面, 运输人员在运输过程中存在偷倒、漏倒的行为, 造成经济损失的同时也存在一定的安全隐患。近年来, 随着危化品运输量与日俱增, 相应的危化品运输事故屡见不鲜[2], 但危化品运输车(简称危化品车)运输过程长期脱离监控。要实现对危化品车运输过程的实时监控, 需借助车载传感器实时采集运输过程相关信息, 以判断车辆的运行状态, 这对保障危化品安全规范运输, 促进安全生产具有重要意义。

目前, 国内对危化品车安全监管研究处于起步阶段[3-5], 危化品运输监控应向综合化、联合化、动态化的方向发展: 为科学解决危化品道路运输路径的决策问题, 构建基于概率语言平均解距离评价法的危化品道路运输路径决策模型[3]; 针对港口危化品风险监管存在的问题, 构建考虑安全事故发生率的演化博弈模型[4]; 为实现危化品全过程安全监管, 利用区块链技术研究危化品各个环节数据的安全可信共享和多个主体之间的协同管理技术[5]。上述研究在一定程度上保障了危化品的运输安全, 但目前针对偷倒、漏倒问题的研究尚处于空白阶段, 在具体如何判别车辆运输状态的方法上未见深入。相比于在管理站的静态监控, 运输过程中的动态监控更依赖于传感器的数据反馈, 但目前能够采集的数据由于车辆运行而

项目来源: 国家自然科学基金项目(62173160)
收稿日期: 2022-11-18 **修改日期**: 2023-07-24

存在大量的噪声和扰动,难以准确地判别车辆的运行状态。

危化品车运输过程产生的数据具有时间相关性,是一种典型的时间序列数据,可借鉴时间序列[6]相关的分析方法进行研究。目前,针对时间序列,主要分析方法有 K 邻近法[7]、长短期记忆网络[8](Long Short-Term Memory,LSTM)等,这些方法具有较强的泛化能力,然而在捕捉时间序列的时间依赖问题时,往往过分关注邻近数据的影响,而缺乏对序列整体的概括能力[9]。采用注意力机制可以有效地概括时间序列的全局信息,基于注意力机制并采用编码器-解码器结构的 Transformer 模型[10],在自然语言处理[11]、计算机视觉[12]等领域均取得了不错的效果。

针对危化品车的运输状态识别问题,研究车辆运输中装卸载过程的识别模型,主要贡献如下:

①针对识别车辆运输状态问题,将运输状态分为装货、运输、卸货三类,依据传感器收集的实时数据,动态识别运输状态。

②针对危化品运输序列数据中各时间步显性联系较弱的问题,采用 k 步差分的方法进行特征构造,体现序列中数据间的变化特征。

③针对状态难以判断问题,将 Transformer 与循环神经网络(Recurrent Neural Network,RNN)相结合,研究 Transformer-RNN 模型,将处理后的数据输入到 Transformer 中完成表征学习,而后通过 RNN 提取时序信息并输出分类结果。

1　数据预处理和特征构造

通过安装在车身的各个传感器获取危化品车运输数据(载重、车速等),并通过中控系统进行数据的整合,采用滑动窗口的方式获取危化品车运输数据,通过归一化消除各数据不同量纲的影响,使用前向差分构造车辆运行中对运动状态变化敏感的特征,具体步骤如下。

1.1　数据获取

采用滑动窗口截取危化品车的运输数据,当需要判断 t 时刻的运行状态时,截取 t 时刻前后各 n 个数据点形成一个长度为 $2n+1$ 的滑动窗口,并根据窗口内数据判断 t 时刻危化品车的运行状态。判断 $t+1$ 时刻的运行状态时,则窗口整体向后滑动一个时间点,以此类推。以 $x_{t,j}$ 表示原始数据中 t 时刻第 j 个特征的值,滑动窗口截取危化品运输数据的过程如图 1 所示。本文采集的传感器数据如表 1 所示。

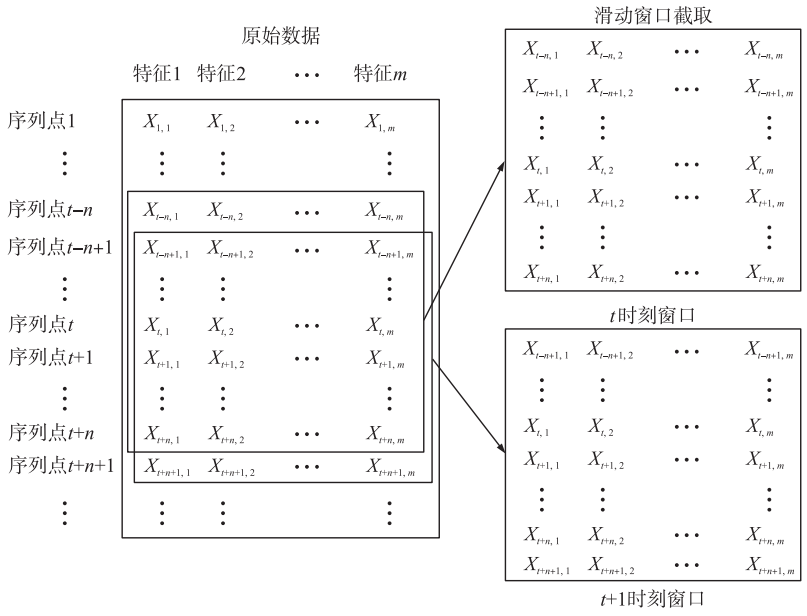

图 1　滑动窗口截取示意图

表 1　危化品车传感器采集数据

数据/单位	物理信息描述
载重/kg	车辆载重值
车速/(km/h)	车辆速度
方向/(°)	车辆行进方向
原始 AD 值	载重传感器形变程度
海拔高度/m	车辆绝对垂直距离

取 $n=10$,特征数为 5 的危化品运输数据序列 A^i 可以描述为:

$$A^i=\{(m_{i-10},v_{i-10},d_{i-10},\mathrm{ad}_{i-10},h_{i-10}),\cdots,(m_i,v_i,d_i,\mathrm{ad}_i,h_i),\cdots,(m_{i+10},v_{i+10},d_{i+10},\mathrm{ad}_{i+10},h_{i+10})\} \tag{1}$$

式中:$(m_i,v_i,d_i,\mathrm{ad}_i,h_i)$ 表示 i 时刻对应窗口序列,包含载重(m_i)、车速(v_i)、方向(d_i)、原始 AD 值(ad_i)、

海拔高度(h_i)等数据信息。

1.2 数据归一化

传感器采集的各项数据信息具有不同的量纲,因此,采用均值-标准差对式(1)进行归一化处理:

$$(nm_i,nv_i,nd_i,n\mathrm{ad}_i,nh_i)=\left(\frac{m_i-\bar{m}}{\sigma m},\frac{v_i-\bar{v}}{\sigma v},\frac{d_i-\bar{d}}{\sigma d},\frac{\mathrm{ad}_i-\overline{\mathrm{ad}}}{\sigma \mathrm{ad}},\frac{h_i-\bar{h}}{\sigma h}\right) \tag{2}$$

式中:$\bar{m},\bar{v},\bar{d},\overline{\mathrm{ad}},\bar{h}$ 表示各项数据的均值,$\sigma m,\sigma v,\sigma d,\sigma ad,\sigma h$ 为各项数据的标准差,计算公式分别见式(3)和式(4):

$$(\bar{m},\bar{v},\bar{d},\overline{\mathrm{ad}},\bar{h})=\frac{1}{21}\sum_{k=i-10}^{i+10}(m_k,v_k,d_k,\mathrm{ad}_k,h_k) \tag{3}$$

$$(\sigma m,\cdots,\sigma h)=\sqrt{\frac{1}{21}\sum_{k=i-10}^{i+10}[(m_k-\bar{m})^2,\cdots,(h_k-\bar{h})^2]} \tag{4}$$

归一化处理后运输数据序列 NA^i 表示为:

$$\begin{aligned}\mathbf{NA}^i=\{&(nm_{i-10},nv_{i-10},nd_{i-10},n\mathrm{ad}_{i-10},nh_{i-10}),\\&\cdots,(nm_i,nv_i,nd_i,n\mathrm{ad}_i,nh_i),\\&\cdots,(nm_{i+10},nv_{i+10},nd_{i+10},n\mathrm{ad}_{i+10},nh_{i+10})\}\end{aligned} \tag{5}$$

1.3 特征提取

为更加充分地表现序列中各时间步间的变化,采用前向差分[13]进一步提取特征。第 i 个序列点的载重 l 步前向差分为:

$$\Delta nm_i^l=nm_i-nm_{i-l} \tag{6}$$

提取第 i 个序列点的载重、速度、方向的前向 10 步和 5 步差分,得到长度为 21、共 6 个差分特征的滑动差分序列:

$$\begin{aligned}\mathbf{DA}^i=\{&(\Delta nm_{i-10}^5,\Delta nv_{i-10}^5,\Delta nd_{i-10}^5,\Delta nm_{i-10}^{10},\Delta nv_{i-10}^{10},\Delta nd_{i-10}^{10}),\cdots,\\&(\Delta nm_i^5,\Delta nv_i^5,\Delta nd_i^5,\Delta nm_i^{10},\Delta nv_i^{10},\Delta nd_i^{10}),\cdots,\\&(\Delta nm_{i+10}^5,\Delta nv_{i+10}^5,\Delta nd_{i+10}^5,\Delta nm_{i+10}^{10},\Delta nv_{i+10}^{10},\Delta nd_{i+10}^{10})\}\end{aligned} \tag{7}$$

定义第 i 个时间点车辆运行特征的滑动窗口序列 $\mathrm{CA}^i\in\boldsymbol{R}^{21\times11}$ 由 5 个基本特征(5)和 6 个差分特征(7)共 11 个特征组成,如式(8)所示:

$$\begin{aligned}\mathrm{CA}^i=\{\mathrm{NA}^i\,|\,\mathrm{DA}^i\}=\{\boldsymbol{w}_1,\cdots,\boldsymbol{w}_i,\cdots,\boldsymbol{w}_{21}\}=\\\{(nm_{i-10},nv_{i-10},nd_{i-10},\cdots,\Delta nm_{i-10}^{10},\Delta nv_{i-10}^{10},\Delta nd_{i-10}^{10}),\\\cdots,(nm_i,nv_i,nd_i,\cdots,\Delta nm_i^{10},\Delta nv_i^{10},\Delta nd_i^{10}),\\\cdots,(nm_{i+10},nv_{i+10},nd_{i+10},\cdots,\Delta nm_{i+10}^{10},\Delta nv_{i+10}^{10},\Delta nd_{i+10}^{10})\}\end{aligned} \tag{8}$$

式中:向量 $\boldsymbol{w}_i$ 表示序列 CA^i 中的第 i 个序列点。

2 危化品车装卸载识别模型

本文研究一种融合 Transformer 和 RNN 的危化品车装卸载识别模型,由位置嵌入模块、Transformer 表征学习模块和循环神经网络分类模块组成,模型整体结构如图 2 所示。位置嵌入模块对输入 $\boldsymbol{w}_i$ 嵌入位置信息,使 Transformer 可以获知各个输入序列点的位置;Transformer 表征学习模块将输入向量 $\boldsymbol{h}_i$ 转化为更易被分类模型理解的向量 $\boldsymbol{g}_i$;循环神经网络分类模块通过自注意力(Self Attention)和 RNN 输出危化品运输输入序列对应的运行状态。

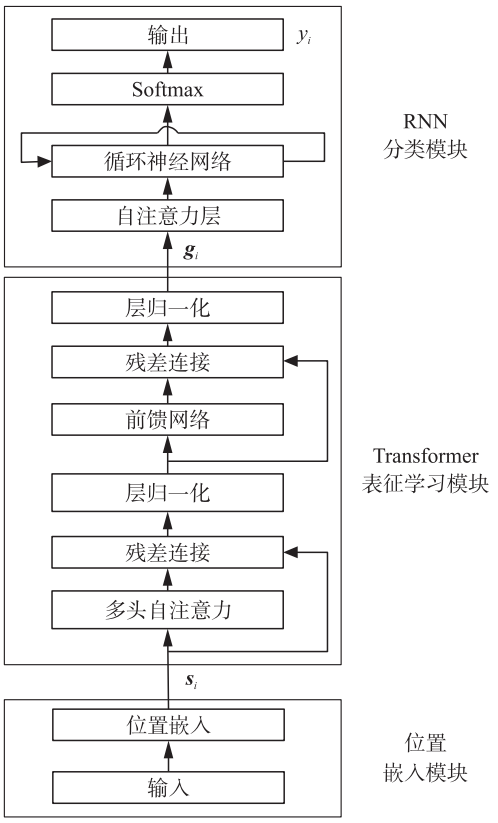

图 2 本文模型 Transformer-RNN

2.1 位置嵌入模块

在处理时间序列数据时,Transformer 中多头自注意力将输入作为一个整体进行计算,并行计算能够提高计算效率,但不能直接获得序列中各数据点间的顺序信息,所以需要额外的信息告知模型输入中各个点的位置信息,此处采用余弦函数生成位置矩阵,其具有与输入序列相同的维度,将位置矩阵与输入序列相加后输入模型,位置矩阵 **PE** 中各元素 $p_{i,j}$ 计算公式如下:

$$\begin{cases}p_{i,2k}=\sin(i/10\,000^{2k/d})\\p_{i,2k+1}=\cos(i/10\,000^{2k/d})\end{cases} \tag{9}$$

式中:$p_{i,2k},p_{i,2k+1}$ 分别表示位置 i 的编码向量的第 $2k$、$2k$+1 个分量,d 是特征维度,在危化品运输数据序列中 $d=11$,以 $\boldsymbol{p}_i$ 表示位置矩阵的第 i 行向量。位置嵌入的输入为输入序列 **CA** 中的第 i 个序列点 $\boldsymbol{w}_i$,则位置嵌入的输出 $\boldsymbol{s}_i$ 可表示为:

$$\boldsymbol{s}_i=\boldsymbol{w}_i+\boldsymbol{p}_i \tag{10}$$

2.2 Transformer 表征学习模块

本文采用 Transformer 的编码器部分作为模型的表征学习模块,对输入序列进行表征学习,使其转化为更易被分类模块理解的抽象特征。一个 Transformer 的编码器由多头自注意力子层和前馈网络子层组成,其原理如下文所示。

2.2.1 多头自注意力机制

多头自注意力[14](Multi-head Self Attention)由自注意力机制演化而来,自注意力机制(Self Attention)将查询($\boldsymbol{Q}$)、键($\boldsymbol{K}$)和值($\boldsymbol{V}$)映射到输出,$\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 均由输入产生,将 $\boldsymbol{Q}$ 与 $\boldsymbol{K}$ 进行内积运算,并对结果除以$\sqrt{d}$进行缩放,输入 Softmax 函数进行缩放以得到权重,乘以 V 得到自注意力的输出。其计算过程如下式所示:

$$\boldsymbol{Q}=\boldsymbol{W}^{Q}\boldsymbol{X},\boldsymbol{K}=\boldsymbol{W}^{K}\boldsymbol{X},\boldsymbol{V}=\boldsymbol{W}^{V}\boldsymbol{X} \tag{11}$$

$$\mathrm{Softmax}(z_i)=\frac{\mathrm{e}^{z_i}}{\sum_{j=1}^{d}\mathrm{e}^{z_j}}\quad i=1,\cdots,d \tag{12}$$

$$\mathrm{Attention}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=\mathrm{softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d}}\right)\times V \tag{13}$$

式中:X 表示自注意力的输入序列,$\boldsymbol{W}^{Q}$,$\boldsymbol{W}^{K}$,$\boldsymbol{W}^{V}$ 分别为 $\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 对用的变换矩阵,在模型训练过程中进行参数更新,d 为输入的特征数,Softmax 是归一化指数函数,用于将分类结果转化为概率分布矩阵。

多头自注意力在自注意力的基础上,将输入序列划分成多个不同的表征子空间,并分别对其进行自注意力计算,从而学习不同位置的表达信息,随后将学习到的表征信息进行拼接,转化为特定维度的输出,每个头的计算过程如下式:

$$\mathrm{head}_i=\mathrm{Attention}(\boldsymbol{Q}\boldsymbol{W}_i^{Q},\boldsymbol{K}\boldsymbol{W}_i^{K},\boldsymbol{V}\boldsymbol{W}_i^{V}) \tag{14}$$

$$\mathrm{MHead}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=\mathrm{Concat}(\mathrm{head}_1,\cdots,\mathrm{head}_i,\cdots,\mathrm{head}_m) \tag{15}$$

式中:$\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 分别表示查询矩阵、键矩阵和值矩阵;$\boldsymbol{W}_i^{Q}$、$\boldsymbol{W}_i^{K}$、$\boldsymbol{W}_i^{V}$ 分别为 $\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 对用的变换矩阵;m 表示多头自注意力的头数;MHead($\boldsymbol{Q}$,$\boldsymbol{K}$,$\boldsymbol{V}$)表示对多头信息进行拼接。由于多头自注意力中的运算是一系列的矩阵乘法运算,相比于 CNN、RNN,并行运算能力更强。

2.2.2 残差连接和前馈神经网络

残差连接[15](Rasidual Block)部分将编码器层的输入和多头自注意力层的输出进行求和,可以减少模型复杂度以防止过拟合。层归一化(Layer Normalization)对序列中每个数据点各个特征进行归一化处理,处理方法与 1.2 数据归一化方法一致。

经过残差连接和层归一化后的结果会送入前馈神经网络(Feed-Forward Network)中,由两个全连接层组成,其中第一层采用 ReLU 作为激活函数,第二层无激活函数,对应计算式如下:

$$\mathrm{FeedForward}(\boldsymbol{X})=\max(0,\boldsymbol{X}\boldsymbol{W}_1+\boldsymbol{b}_1)\boldsymbol{W}_2+\boldsymbol{b}_2 \tag{16}$$

式中:$\boldsymbol{X}$ 为前馈网络的输入,$\boldsymbol{W}_1$、$\boldsymbol{W}_2$ 为网络的权值矩阵,$\boldsymbol{b}_1$、$\boldsymbol{b}_2$ 为网络的偏置。

最后再经过一次残差连接和层归一化,即完成一次 Transformer 的计算。通过 Transformer 进行表征学习后的结果将会送入循环神经网络分类模块进行分类输出。

2.3 循环神经网络分类模块

RNN 在处理时间序列数据方面表现出强大的能力[16],相比传统的神经网络模型,RNN 当前时刻的输出不仅取决于当前时刻的输入,还取决于上一时刻的输出,其具体表现形式为网络会对前面的数据信息进行记忆并应用到当前输出的计算中去。将 RNN 按时间步展开的结构如图 3 所示,其计算过程如下式所示:

$$q_i=\sigma(\boldsymbol{w}_{\mathrm{gq},i}g_i+\boldsymbol{w}_{\mathrm{qq},i-1}q_{i-1}+\boldsymbol{b}_q)\quad i=1,\cdots,21 \tag{17}$$

$$o=\boldsymbol{W}_{qo}q_{21}+\boldsymbol{b}_o \tag{18}$$

$$y=\mathrm{Softmax}(o) \tag{19}$$

$$\sigma(x)=\frac{\mathrm{e}^{x}-\mathrm{e}^{-x}}{\mathrm{e}^{x}+\mathrm{e}^{-x}} \tag{20}$$

式中:g_i 为输入序列的第 i 个序列点,$\sigma(x)$ 指 Tanh 激活函数,$\boldsymbol{W}_{\mathrm{gq}}$为输入到隐藏层的连接权重矩阵,$\boldsymbol{W}_{\mathrm{qq}}$为隐藏层之间的连接权重矩阵,$\boldsymbol{W}_{qo}$为隐藏层到输出之间的连接权重矩阵,$b_q$、$b_o$ 是偏置向量。在实际计算中,需要先计算第一个时间步的 q_1,再结合 q_1 和下一时间步的输入来计算 q_2,以此类推,并最终计算 RNN 的输出。这样的前向传播方式帮助 RNN 考虑过去时刻的输入对当前时刻输出的影响。

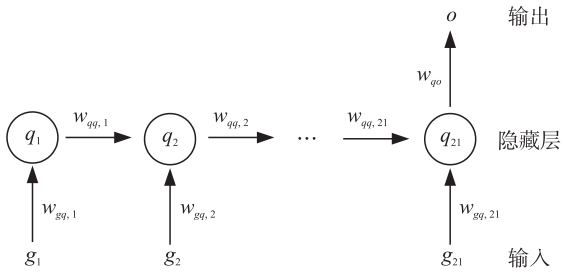

图 3　RNN 按时间步展开

Transformer 表征学习模块的输出将会送入一个自注意力层进行权重更新,此时,$\boldsymbol{W}^{q}=\boldsymbol{W}^{k}=\boldsymbol{W}^{v}=\boldsymbol{W}_0$(式(11)~式(13)),最后经过 RNN 和 softmax 函数输出分类结果。

3 实验结果与分析

3.1 评价指标

实验采用查准率(P)、查全率(R)、F_1 值(F_1)和准确率(Acc)4 个评价指标来衡量模型的有效性。装卸载状态识别属于多分类问题,其混淆矩阵见表 2,采用宏平均的方式进行总体的性能评估,根据每个类别的查准率、查全率和 F_1 值求得算数平均。

表 2 运输状态三分类对应混淆矩阵

真实类别	分类结果		
	正常运行	装货	卸货
运输	a_0	a_1	a_2
装货	b_0	b_1	b_2
卸货	c_0	c_1	c_2

以运输样本为例,对于分类为正常运行的情况,

$$\mathrm{TP}_0=a_0;\mathrm{FN}_0=a_1+a_2;\mathrm{FP}_0=b_0+c_0;\mathrm{TN}_0=b_1+b_2+c_1+c_2 \tag{21}$$

此时,分类为正常运行的查准率 P_0 和查全率 R_0 如下:

$$P_0=\frac{\mathrm{TP}_0}{\mathrm{TP}_0+\mathrm{FP}_0}\times 100\% \tag{22}$$

$$R_0=\frac{\mathrm{TP}_0}{\mathrm{TP}_0+\mathrm{FN}_0}\times 100\% \tag{23}$$

使用宏平均方式进行总体的性能评估,

$$\mathrm{macroP}=\frac{1}{3}\sum_{i=0}^{2}P_i \tag{24}$$

$$\mathrm{macroR}=\frac{1}{3}\sum_{i=0}^{2}R_i \tag{25}$$

$$\mathrm{macroF}_1=\frac{2\times\mathrm{macroP}\times\mathrm{macroR}}{\mathrm{macroP}+\mathrm{macroR}} \tag{26}$$

式中:查准率表示正确识别的实体数量占识别出的所有实体数量的百分比;查全率表示正确识别的实体数量占所有该类标注实体数量的百分比;F_1 值是精确率和召回率的调和平均数,从查准和查全 2 个角度综合反映模型的效果,本文用来对实体识别实验进行整体评估,F_1 值越大,表明模型正确识别的实体数量越多且越全。

特别地,在实际应用中,可以容许一部分的装货、卸货过程识别为正常运行,但正常运行被识别为装货、卸货是不被允许的,因而,除上述 4 个性能指标外,还需额外关注查全率 R_0。

在实验对比部分,最终以准确率(ACC)、查准率(macroP)、查全率(macroR)、F_1 值(macroF_1)、正常运行查全率(R_0)作为性能指标进行对比。

3.2 实验结果及对比分析

将经过特征处理的数据按照 6∶3∶1 的比例划分为训练集、验证集和测试集,实验环境为 Windows10 64 位操作系统,显卡为 GTX1050,内存为 16 GB,使用基于 Python3.7 的 Tensorflow2.5 深度学习框架进行实验。

3.2.1 循环神经网络对比实验

RNN 是最为基本的循环神经网络,而目前在相关领域较为常见的循环神经网络是 RNN 的变种 LSTM 和 GRU(Gate Recurrent Unit)。为了对比分析并决定使用哪一种循环神经网络作为模型的分类器,对三种模型分别进行实验,实验结果如表 3 所列。

表 3 RNN 与其变种对比结果

模型	macroP	macroR	macroF_1	时间
RNN	0.902 7	0.901 8	0.902 2	12.5 min
LSTM	0.907 8	0.907 5	0.907 6	27 min
GRU	0.905 4	0.901 5	0.903 4	21 min

表 3 中模型均采用最基本的单层结构进行实验,进行 1 000 轮迭代后完成训练。通过对比,LSTM 的性能表现高于 GRU 和 RNN,但训练耗费时间上,LSTM 和 GRU 的训练耗时也远高于 RNN,由于模型较为复杂,如果采用 LSTM 或者 GRU 作为分类器,训练时间将会远远长于使用 RNN 的模型,且 RNN 变种针对数据集的训练表现相差不大,F_1 值仅比 LSTM 低 0.005 4,比 GRU 低 0.001 2,综合考虑,RNN 的训练效率高于其变种,本文采用 RNN 作为分类器。

3.2.2 不同模型分类效果对比实验

为证实本文所提模型的有效性,此处将 Transformer-RNN 模型与几种常用的分类算法进行对比实验,其实验结果如表 4 所列,其对应的验证准确率曲线如图 4 所示。

表 4 不同分类算法对比结果

模型	macroP	macroR	macroF_1	Accuracy	R_0
FCN	0.899	0.887	0.893	0.899	0.932
RNN	0.903	0.902	0.902	0.905	0.929
Transformer	0.916	0.905	0.911	0.916	0.948
Transformer-RNN	0.926	0.924	0.925	0.926	0.947

从表 4 可以看出,仅仅采用 Transformer 单一结构的模型,就已经取得了优于全连接网络和 RNN 网络的性能优势,其准确率和 F_1 值均优于其他模型,在 Transformer 模型的基础上,添加 RNN 作为信息提取器,并通过 Attention 机制突出重要特征的权

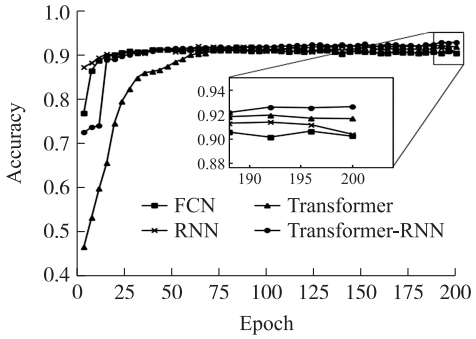

图 4　不同模型对应验证曲线

重,最后输出分类结果的 Transformer-RNN 模型取得了 92.64%的验证准确率和 0.924 9 的 F_1 值。实验表明,通过 Transformer 模型,结合 RNN 模型和注意力机制,在本文所使用的危化品车装卸载数据中,能够取得优于其他模型的分类效果。

3.2.3　不同特征构造分类效果对比实验

本文采用差分的方法进行特征构造,为验证差分方法是否能有效提升模型的分类效果,此处将本文所用的前向 5 步、10 步差分分别与只进行 5 步差分、10 步差分、不进行差分的情况进行对比,其对应各项性能指标如表 5 所示,训练验证曲线如图 5 所示。

表 5　不同特征构造下各项指标对比

差分选择	macroP	macroR	macroF$_1$	Accuracy	R_0
无差分	0.711	0.641	0.674	0.698	0.744
5 步差分	0.895	0.857	0.876	0.891	0.933
10 步差分	0.881	0.874	0.878	0.887	0.921
5、10 步差分	0.926	0.924	0.925	0.926	0.947

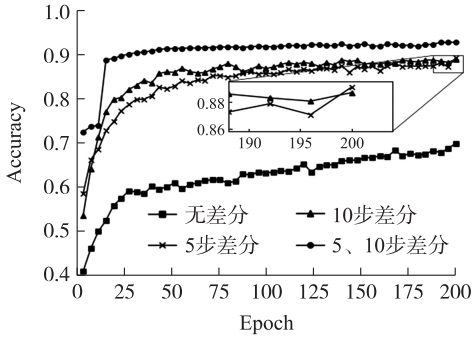

图 5　不同特征构造下对应验证曲线

从图 5 可以看出,没有进行特征构造的情况下,训练效果最差,其验证准确率只能达到 69.78%,而进行差分后各项指标均取得较大提升,5 步差分和 10 步差分的验证准确率从 70%分别提升至89.14%、88.69%,而同时进行这两步差分的情况下,模型训练效果已达到最优,准确率为 92.64%,各项指标见表 5。实验表明,通过差分的方法进行特征构造有助于提升对危化品装卸载过程的识别精度。

4　结论

时间序列数据分类是工业数据分析中的一个重要领域,本文针对危化品车运输过程中的装卸载过程分类任务,研究 Transformer-RNN 时间序列分类模型,首先使用 Transformer 模型对数据进行特征提取,经过 Attention 机制突出数据中重要特征的权重,最后通过 RNN 输出分类结果。实验结果表明:①针对危化品车运输数据,RNN 模型足够胜任其任务,其他变种模型大大延缓了模型整体的训练效率;②采用前向差分进行特征构造能够有效体现序列中数据间的变化特征;③Transformer-RNN 模型相比其他传统分类器,各项性能指标均有显著提升。

基于 Transformer-RNN 的分类模型对危化品车装卸载过程分类任务具有显著效果,这对后续追踪朔源运输过程的相关问题具有重要意义。在后续工作中,可以考虑结合无监督学习的训练方式,对数据进行自动标注,减少数据标注工作中的人力成本,并进一步提高模型的分类性能。

参考文献:

[1] Huang X,Zhang M,Wang J,et al. Study on Law of Scenario Evolution Based on Accident Statistics of Hazardous Chemicals Transportation[C]//2018 IEEE International Conference of Safety Produce Informatization(IICSPI),Chongqing,China,2018:80-83.

[2] Wang B,Wu C,Reniers G,et al. The Future of Hazardous Chemical Safety in China:Opportunities,Problems,Challenges and Tasks[J]. Science of the Total Environment,2018,643:1-11.

[3] 郭硕,孙玉峰,代霞,等. 一类基于概率语言 EDAS 的危化品道路运输路径决策方法[J]. 安全与环境工程,2022,29(6):95-103.

[4] 刘家国,王军进,周欢,等. 基于安全风险等级的港口危化品监管问题研究[J]. 系统工程理论与实践,2018,38(5):1141-1152.

[5] 刘祺彬. 基于区块链的危化品全流程监管平台[J]. 中国安全科学学报,2022,32(S2):195-199.

[6] Gasparin A,Lukovic S,Alippi C. Deep Learning for Time Series Forecasting:The Electric Load Case[J]. CAAI Transactions on Intelligence Technology,2022,7(1):1-25.

[7] Geler Z,Kurbalija V,Ivanović M,et al. Weighted KNN and Constrained Elastic Distances for Time-series Classification[J]. Expert Systems with Applications,2020,162:113829.

[8] Song X,Liu Y,Xue L,et al. Time-Series Well Performance Prediction Based on Long Short-Term Memory(LSTM) Neural Network Model[J]. Journal of Petroleum Science and

Engineering,2020,186:106682.

[9] 彭能松,张维纬,张育钊,等. 基于时间序列数据的无线传感器网络的异常检测方法[J]. 传感技术学报,2018,31(4):595-601.

[10] Vaswani A, Shazeer N, Parmar N, et al. Attention is All You Need[C]//31st International Conference on Advances in Neural Information Processing Systems, Long Beach, CA, USA, 2017:6000-6010.

[11] Casola S, Lauriola I, Lavelli A. Pre-Trained Transformers: An Empirical Comparison[J]. Machine Learning with Applications, 2022, 9:100334.

[12] Liu Z H, Wang Y H, Han K, et al. Post-Training Quantization for Vision Transformer[C]//35th International Conference on Neural Information Processing Systems, Virtual, 2021:28092-28103.

[13] 张元杰,田茂再. K 步差分面板分位回归方法研究[J]. 系统科学与数学,2015,35(9):1037-1048.

[14] Zhang Y, Gong Y, Zhu H, et al. Multi-Head Enhanced Self-Attention Network for Novelty Detection[J]. Pattern Recognition, 2020, 107:107486.

[15] Chen Y, Xia S, Zhao J, et al. ResT-ReID: Transformer Block-Based Residual Learning for Person Re-Identification[J]. Pattern Recognition Letters, 2022, 157:90-96.

[16] 孙伟,董小瑞,樊群才,等. 基于循环神经网络的关键输电线路辨识及预测方法[J]. 电子器件,2023,46(2):516-522.

李晓辉(1999—),男,浙江台州人,在读硕士研究生,研究方向为人工智能与模式识别,li_xh23@hdec.com;

孙子文(1968—),女,四川大竹人,博士,教授,主要研究方向为模式识别、人工智能、无线传感器网络理论与技术、信息安全,sunziwen@jiangnan.edu.cn。