

DOI:10.20033/j.1003-7241.(2026)01-0046-04

# 基于文本解析的工业设备调令管理系统

承孝敏<sup>1,2</sup>

(1. 中国科学技术大学 信息科学技术学院, 安徽 合肥 230026; 2. 长三角信息智能创新研究院, 安徽 芜湖 241000)

**摘要:** 企业发布工业设备调令对工厂设备进行调度和安排, 这需要人工重度参与, 成本较高且效率低下, 针对此问题构建基于文本解析的工业设备调令管理系统。根据调令文本特征, 设计了一个文本语义解码盒子, 通过服务层、数据层、应用层, 对调令文本信息进行摘录、解码和分发。通过双向长短期记忆网络和注意力机制实现文本的序列标注, 结合复制机制的序列到序列的深度学习模型完成文本解析。实验结果表明, 设计的工业设备调令管理系统平均准确率达到 96.33%, 平均响应时间小于 3 s。设计系统有效提升了调令安排效率并降低了成本。

**关键词:** 工业设备调令; 文本解析; 深度学习; 管理系统

中图分类号: TP391.43

文献标志码: A

文章编号: 1003-7241(2026)01-0046-04

## Industrial equipment dispatch management system based on text parsing

CHENG Xiaomin<sup>1,2</sup>

(1. School of Information Science and Technology, University of Science and Technology of China, Hefei 230026, Anhui, China;

2. Yangtze River Delta Information Intelligence Innovation Research Institute, Wuhu 241000, Anhui, China)

**Abstract:** The enterprise issues industrial equipment dispatch orders to schedule and arrange factory equipment, a process that currently requires heavy manual involvement, resulting in high costs and low efficiency. In response to this challenge, it develops an industrial equipment dispatch management system based on text parsing. This system incorporates a text semantic decoding box designed to leverage the features of dispatch order texts. Operating through service, data, and application layers, it facilitates the extraction, decoding, and distribution of dispatch order information. Utilizing bidirectional long short-term memory networks and attention mechanisms, the system achieves text sequence labeling. Furthermore, by integrating a sequence-to-sequence deep learning model with a copy mechanism, it completes text parsing. Experimental results demonstrate that the designed industrial equipment dispatch management system achieves an average accuracy of 96.33% and an average response time of less than 3 seconds. Thus, the system effectively enhances dispatch arrangement efficiency and reduces costs.

**Keywords:** industrial equipment dispatch; text parsing; deep learning; management system

在现代工业生产中, 工业设备的运行和维护是保障生产效率和产品质量的关键环节。为了实现工业设备的高效运行和管理, 工厂和企业通常会制定调令, 对设备的运行、维护、维修等进行调度和安排。传统分发调令的管理模式审批流程冗长繁琐, 记录粗略<sup>[1]</sup>, 导致工业设备管理低效和企业成本增加。

田野等<sup>[2]</sup>开发基于加密二维码的工业设备管理系统, 为用户提供高效和安全的设备管理服务, 刘志华<sup>[3]</sup>和康华夏等<sup>[4]</sup>开发了不同的工业设备管理平台来管理设备, 但没有涉及到对工业设备调令的解析。袁枫等<sup>[5]</sup>对铁路调令提出一种基于生成式摘要模型和知识蒸馏的解析算法, 取得了较高的精度和鲁棒性; 张锡然等<sup>[6]</sup>针对电网调令提出一种基于语义识别的解析系统, 有效降低了电气误操作风险。

本文旨在研究工业设备调令的信息抽取和解析技术, 提出了基于文本解析的工业设备调令管理系统, 结合深度学习技术, 提高调令解析的正确率, 进而实现工业设备高效运行和调度, 帮助企业实现降本增效的目标。

## 1 系统技术架构

本文设计的工业设备调令管理系统采用分层式的技术架构, 在文本语义解码盒子的框架下分为服务层、数据层和应用层, 如图 1 所示。

服务层部署有包括命令筛选、摘录入库、文本解码等服务。其中命令筛选服务实时接收基于企业调度中心所发布的调度命令, 自动筛选出与部署设备相关的调度命令; 摘录入库服务摘录原始调度命令, 提取出命令号、发布时间、发令人、受令人等基本信息, 并按照规定表结构存入

收稿日期: 2024-04-02; 录用日期: 2024-05-14

基金项目: 2020 安徽省科技重大专项 (202003a05020058)

作者简介: 承孝敏 (1971—), 男, 硕士, 高级工程师, 研究方向: 大数据、人工智能。

引用本文: 承孝敏. 基于文本解析的工业设备调令管理系统[J]. 自动化技术与应用, 2026, 45(1): 46-48, 122. (CHENG Xiaomin. Industrial equipment dispatch management system based on text parsing[J]. Techniques of Automation and Applications, 2026, 45(1): 46-48, 122.)

指定数据库,作为摘录数据;文本解码服务实时请求摘录后的调度命令数据进行文本解码,将调度命令中的设备、

时间、类型等信息提取出,并按照规定表结构存入指定数据库,作为解码数据。

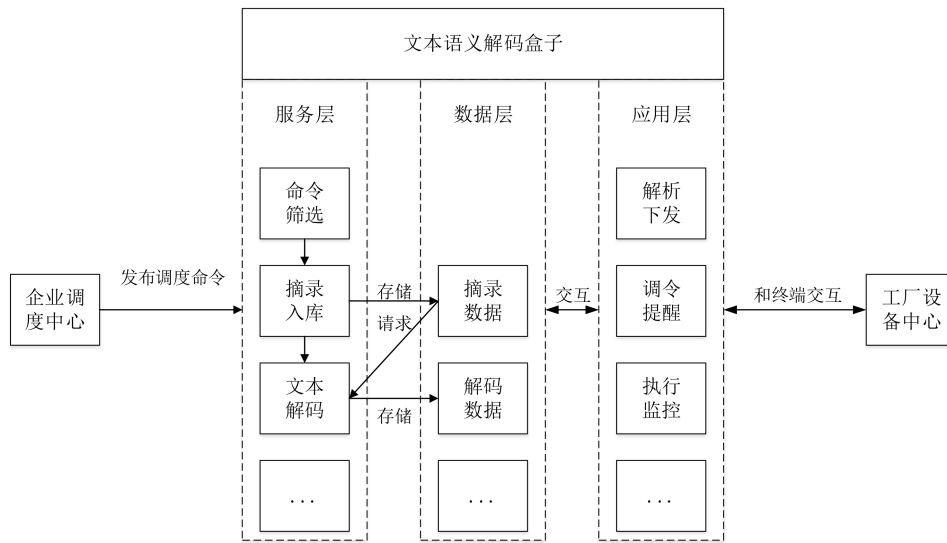


图1 系统技术架构

Fig.1 System technical architecture

数据层实现摘录数据、解码数据的存储,支撑工业设备调令分解系统内有关摘录数据和解码数据的基本查询功能及增删改功能。

应用层支持命令下发、调令提醒、调令执行监控等应用,由这些应用构建出工业设备调令分解系统。系统与各地方下各个工厂终端交互,通过文本语义解码盒子将审核通过后的解码数据实时下发到各个工厂终端。实时收集各个工厂终端反馈的调度命令任务执行情况,并在系统展示以供工作人员监控,对于未在指定时间内反馈调度命令的车间,定时推送消息以提醒其完成调度命令任务。

## 2 文本解析算法

工业设备调令的制定和执行依赖于大量的文本信息。为了更高效地处理这些调令文本,研究和设计一种自动化的信息抽取和解析模型,旨在从调令文本中自动提取出关键信息,并将其转化为结构化的数据格式。

### 2.1 调令文本的序列标注

针对工业设备调令文本中存在很多的专有名词,首先对文本进行分词处理时,在分词词库中添加专有名词。然后对分词后的文本序列进行向量化,输入双向长短期记忆网络(Bi-LSTM)层获取词语长距离的上下文特征,之后引入注意力机制(Attention)对Bi-LSTM层的输入与输出之间的相关性进行重要度计算<sup>[7]</sup>,根据重要度获取文本整体特征,最后输入条件随机场(CRF)层,构建标签转移矩阵,给出全局最优标注序列。

对于Bi-LSTM和Attention,首先基于权威的中文语料库,采用词向量(word2vec)模型将划分后的词语转换为向量表示。而后采用Bi-LSTM网络作为编码层的基本结构,以更有效地利用词语所在位置上下文的语义信息。针对

第 $t$ 个词语,使用前向LSTM计算其左侧上下文的隐向量 $\vec{h}_t$ ,使用后向LSTM计算其右侧上下文的隐向量 $\overleftarrow{h}_t$ ,融合两者后得到编码层对第 $t$ 个词语的输出结果 $e_t = g(\vec{h}_t, \overleftarrow{h}_t)$ 。

在注意力层,利用自注意力模型,通过构建注意力权重矩阵来表征当前目标词与输入词语序列中所有词的相关性。针对第 $i$ 个词语与第 $j$ 个词语之间的注意力权重计算方式为 $\alpha_{ij} = \frac{\exp(s_{ij})}{\sum_{k=1}^n \exp(s_{ik})}$ ,其中 $s$ 表示向量距离计算函

数。融合注意力机制输出的权重与Bi-LSTM输出结果,将更有效的信息 $o_i = g(\alpha_{ij}, e_i)$ 输入到CRF层。

序列标注可以被看成是一类特殊的分类问题,相比于传统的分类问题,序列标注问题中对序列元素划分标签时往往需要考虑前后标签之间的依赖关系,因此我们使用CRF对分词后的调令文本序列进行标注。CRF主要构建两个矩阵来表征词语与标签之间的关联关系:标签转移矩阵 $L$ 与状态转移矩阵 $T$ 。编码层在时刻 $t$ 对输入的词语 $x_t$ 的输出为预测其对应标签的分布向量 $d_t$ ,状态转移矩阵 $T$ 由向量 $d_t$ 构成,用来建模词语与标签之间的交互关系 $T_{n \times k} = [d_1, d_2, \dots, d_n]$ ,其中 $k$ 为标签集中不同标签的个数。对于一个可能的标签结果预测序列 $y = (y_1, y_2, \dots, y_n)$ ,计算该预测序列的得分 $\text{score}(X, y) = \sum_{i=0}^n L_{y_i, y_{i+1}} + \sum_{i=1}^n T_{i, y_i}$ ,其中 $L_{i, j}$ 表示标签从 $i$ 转移到 $j$ 的概率,矩阵 $L$ 为CRF训练过程中可学习的参数。整体优化目标为预测标签序列对应得分的对数概率 $\log(p(y | X)) = \text{score}(X, y) - \log(\sum_{\tilde{y} \in Y_X} e^{\text{score}(X, \tilde{y})})$ ,其中 $Y_X$ 为针对输入文本序列 $X$ 所有可能的标签序列,若序列 $y$ 是正确的预测结果序列,则

目标函数对应的对数概率最大,因此在预测中使用维特比算法,通过计算最大后验概率来预测全局最优输出为

$$y^* = \underset{\tilde{y} \in Y_X}{\operatorname{argmax}} p(\tilde{y} | X) \quad (1)$$

## 2.2 调令文本的实体提取

本项目实体(设备、时间、停机、运转等)提取模型采

用具有复制(copy)机制的序列到序列(Seq2Seq)的深度学习模型<sup>[8]</sup>,该模型能够以端到端方式提取多个实体。模型包含编码器(encoder)、解码器(decoder)以及copy机制,具体结构如图2所示。

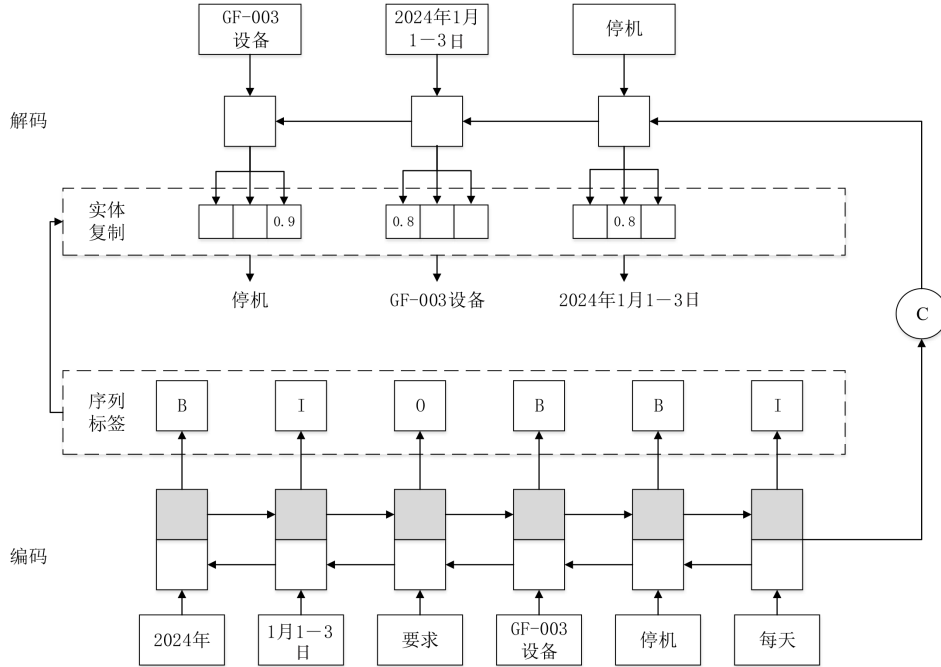


图2 实体提取模型

Fig. 2 Entity extraction model

编码器中,对输入的调令文本分词后的结果序列  $S = \{w_1, w_2, \dots, w_n\}$ , 其中  $w_i$  是分词得到的第  $i$  个词,  $n$  是分词后的序列长度。我们将  $S$  编码为矩阵  $X = \{x_1, x_2, \dots, x_n\}$ , 其中  $x_i$  是  $w_i$  的嵌入向量。编码器使用 Bi-LSTM 网络作为特征提取网络,并以  $X$  为输入,在时间步  $t$  输出对应的向量  $\vec{o}_t^e$  和隐藏状态  $\vec{h}_t^e$ , 其计算公式为  $\vec{o}_t^e, \vec{h}_t^e = \vec{f}(x_t, \vec{h}_{t-1}^e)$  和  $\overleftarrow{o}_t^e, \overleftarrow{h}_t^e = \overleftarrow{f}(x_t, \overleftarrow{h}_{t-1}^e)$ , 其中  $\vec{f}$  和  $\overleftarrow{f}$  分别表示前向和反向的 LSTM,  $\vec{O} = \{\vec{o}_1^e, \vec{o}_2^e, \dots, \vec{o}_n^e\}$  和  $\overleftarrow{O} = \{\overleftarrow{o}_1^e, \overleftarrow{o}_2^e, \dots, \overleftarrow{o}_n^e\}$  分别表示前向和反向的输出向量集合,  $\vec{H} = \{\vec{h}_1^e, \vec{h}_2^e, \dots, \vec{h}_n^e\}$  和  $\overleftarrow{H} = \{\overleftarrow{h}_1^e, \overleftarrow{h}_2^e, \dots, \overleftarrow{h}_n^e\}$  分别表示前向和反向的隐藏状态集合。拼接两个方向的输出向量和隐藏状态  $\vec{O} = \operatorname{concat}(\vec{O}, \overleftarrow{O})$  和  $\vec{H} = \operatorname{concat}(\vec{H}, \overleftarrow{H})$ 。解码器采用单向 LSTM 从左向右按序列预测输出,用于解码生成三元组。编码器输出的隐藏状态  $\vec{O}$  用于初始化解码器的隐藏状态,使用 copy 机制来复制原文中的实体来构建三元组,同时引入 attention 机制来提升模型的准确率。 $\vec{o}_t^d, \vec{h}_t^d = \operatorname{LSTM}(u_t, \vec{h}_{t-1}^d)$  和  $u_t = [v_t; c_t] \cdot W_u$  中,  $\vec{o}_t^d$  和  $\vec{h}_t^d$  分别是解码器的  $t$  时间步输出向量和隐藏状态,  $u_t$  是解码器  $t$  时间步的输入,  $c_t$  是注意力向量,  $v_t$  是 entity copy 的嵌入向量,  $W_u$  是可学习参数。

为了更好地提取调令文本的信息,本文使用 copy 机制来复制源文中的实体。首先结合序列标注的 BIOES 结果来计算置信向量  $Q = \{q_1, q_2, \dots, q_m\}$ , 其计算公式  $q_i = \operatorname{relu}([\vec{o}_i^d; \hat{\vec{o}}_i^e] \cdot W_{ec})$  中,  $\hat{\vec{o}}_i^e$  是编码器根据序列标注结果计算得到的输出向量,  $W_{ec}$  是可学习参数。

在提取实体时,有可能提取的实体不是调令解析任务中所需要的实体,即 NA-实体,这样就会生成 NA-三元组。针对这一点本文改进 copy 机制,将 NA-实体作为 copy 机制的输入,置信向量计算公式为  $q^{NA} = \operatorname{relu}(\vec{o}_t^d \cdot W_{NA} + b_{NA})$ , 其中,  $W_{NA}$  和  $b_{NA}$  是可学习参数。将  $q^{NA}$  和  $Q$  进行拼接并使用 softmax 函数来计算概率分布  $P = \{p_1, p_2, \dots, p_m\}$  为

$$P = \operatorname{softmax}[Q; q^{NA}] \quad (2)$$

根据概率分布结果,我们选择概率值最高对应的实体作为复制实体,并将该实体的编码向量作为计算下一个时间步的输入,最终输出多个<时间,设备,动作>三元组。

## 3 系统测试

基于某企业历年的工业设备调令信息构建数据集,完成标注之后,采用5折交叉验证法,对5次评估结果取平 (下转第122页)