

面向教育过程的剩余时间预测方法

李 婷¹, 徐兴荣², 高腾腾¹, 陈 彬¹, 楚 旭¹

(1. 淄博师范高等专科学校, 山东 淄博 255130;
2. 淄博市广播电视台, 山东 淄博 255000)

摘要: 教育过程挖掘(EPM)旨在挖掘、提取、利用、分析、可视化教育过程数据,揭示教学活动规律、优化教育实践、推动教育改革。目前,EPM只在控制流的角度分析、还原教育过程,缺少在时间维度上的流程辨析。为此,基于深度学习设计面向教育过程的剩余时间预测方法(EPRT),以学生在线学习微处理器系统设计课程为例,根据学生学习过程特征信息构建双向循环神经网络(Bi-RNN)剩余时间预测模型,并引入注意力机制(Attention)学习学生受教育过程中不同事件的权重。同时,为进一步提升剩余时间预测效果,提出一种教育过程表示学习方法(EPRL)与教育过程预测模型层次训练方法(EPHTM),以解决学生学习过程事件中的高质量向量表示以及单一预测模型无法顾及有效信息导致的预测质量不佳的问题。实验表明,所提方法相较于基础方法预测准确率平均提升约60.1%,能有效预测教育过程中学生学习过程的剩余时间,为优化教育过程、提升学生学习体验、助力教学治理科学化奠定良好基础。

关键词: 教育过程挖掘;深度学习;表示学习;模型迭代策略;剩余时间预测

DOI:10.11907/rjdk.241631

扫描二维码阅读全文:

中图分类号:G434

文献标识码:A

文章编号:1672-7800(2025)011-0042-07



Remaining Time Prediction Methods Oriented to the Educational Process

LI Ting¹, XU Xingrong², GAO Tengting¹, CHEN Bin¹, CHU Xu¹

(1. Zibo Normal University, Zibo 255130, China;
2. Zibo Radio and Television Station, Zibo 255000, China)

Abstract: Educational Process Mining (EPM) aims to mine, extract, utilize, analyze, and visualize educational process data, reveal teaching activity patterns, optimize educational practices, and promote educational reform. At present, EPM only analyzes and restores the educational process from the perspective of control flow, lacking process analysis in the time dimension. To this end, based on deep learning, an educational process oriented residual time prediction method (EPRT) is designed. Taking the course of designing a microprocessor system for students' online learning as an example, a bidirectional recurrent neural network (Bi-RNN) residual time prediction model is constructed based on the characteristic information of students' learning process, and attention mechanism is introduced to learn the weights of different events in students' education process. At the same time, in order to further improve the prediction effect of remaining time, an Educational Process Representation Learning Method (EPRL) and an Educational Process Prediction Model Hierarchical Training Method (EPHTM) are proposed to solve the problem of high-quality vector representation in student learning process events and poor prediction quality caused by the inability of a single prediction model to take into account effective information. The experiment shows that the proposed method has an average prediction accuracy improvement of about 60.1% compared to the basic method, and can effectively predict the remaining time of students' learning process in the education process, laying a good foundation for optimizing the education process, improving students' learning experience, and assisting in the scientific governance of teaching.

Key Words: educational process mining; deep learning; representation learning; model iteration strategy; remaining time prediction

收稿日期:2024-07-24

基金项目:淄博师范高等专科学校研究课题(2023xk042)

作者简介:李婷(1996-),女,硕士,淄博师范高等专科学校讲师,研究方向为过程挖掘、深度学习;徐兴荣(1995-),男,硕士,淄博市广播电视台工程师,研究方向为过程挖掘、自然语言处理、深度学习;高腾腾(1996-),男,硕士,淄博师范高等专科学校讲师,研究方向为路径规划、深度学习;陈彬(1981-),男,硕士,淄博师范高等专科学校副教授,研究方向为大数据技术;楚旭(1996-),女,硕士,淄博师范高等专科学校讲师,研究方向为自然语言处理。本文通讯作者:李婷。

0 引言

随着各学科教学环境普适性日益扩大,获取不同维度的在线教学事件成为可能。通过系统自身的跟踪和记录能力,可获得从鼠标、键盘敲击至高级学习的整体活动、文档编辑历史记录数据、学习资源使用记录数据等,并将其以各种格式、不同粒度级别进行存储^[1]。从学生、教师或教育管理部门的角度,充分挖掘、提取、利用、分析、可视化丰富的教育数据,能够在一定程度上揭示教学活动规律、优化教育实践,为今后教育改革起到一定的推动作用,即教育过程挖掘(Education Process Mining, EPM)^[2,3]。

EPM 作为过程挖掘(Process Mining, PM)中的一项新兴课题,能直接借助教育事件日志自动生成完整、简洁的教育过程模型,提升了模型在复杂环境下的建模能力^[4]。同时,EPM 在建模过程中不依靠专家先验知识,降低了人为因素影响,确保了模型准确性与有效性。此外,EPM 与当前挖掘技术也存在一定的差别,主要以全局性为主,不仅可自动生成教育模型,还能改进教育模型,为解决教育研究难题提供了新思路与方法。

目前,EPM 的焦点集中在评估模型能否精确还原教育过程,验证挖掘模型与实际教育过程的匹配度,但忽视了时间维度对 EPM 的影响。为此,本文进行了针对性探索与实验,借助深度学习设计面向教育过程的剩余时间预测方法,以验证时间维度在 EPM 上的作用。

1 相关工作

在教育领域,过程挖掘技术尚处于初级阶段。Aalst^[5]首次将过程挖掘技术引入教育领域。Bogarín 等^[6]依据视频观看时间、评论数量等数据,将学生划分成不同的组别,以挖掘、还原学生学习过程。Bannert 等^[7]将模糊挖掘算法应用到学生的认知过程中,结合建模工具重构学生在线学习行为的理论模型,对学生认知过程进行可视化重现。Mukala 等^[8]利用轨迹对齐策略剖析学生学习模式,为个性化教学提供新视角。Aalst 等^[9]利用过程立方体构建过程模型,以对比荷兰学生与其他国家学生学习过程中存在的区别。

随着机器学习的广泛应用,Bao 等^[10]将支持向量机与过程相似度结合,以评价学生表现。Kong 等^[11]通过 Xgboost 方法预测学生学习成绩和学习行为。Forji 等^[12]收集每位学生的学习动机信息,利用决策树预测学生的学习成绩等。然而,上述研究仅在控制流、数据流的角度对教育及学生在线学习过程开展针对性分析,未考虑时间维度的影响。为此,本文对存在的问题展开深入研究,创新点在于:①提出一种基于注意力机制的双向循环神经网络剩余时间预测模型;②提出一种教育过程表示学习方法,高质

量向量表示学生学习过程,以达到提升剩余时间预测准确度的目标;③为解决单一预测模型预测效果不理想的问题,设计了一种教育过程预测模型层次训练方法。

2 预备知识

EPM 的基本思想是从事件日志(由信息系统记录)中提取知识来发现、监控和改进真实过程,具体研究框架(见图 1)包括以下 4 个模块:

(1)教育世界。该模块是多元化、多维度的复杂系统,学生处于教育世界的中心,既是教学活动设计的出发点,又是教育过程评价的落脚点。教师则为了保障教学活动有效进行,提供了设计、组织、提供、监督、评价等支持。

(2)信息系统。该模块是 EPM 的重要载体,提供了支持教学交互行为的技术环境、记录教育事件的技术平台、分析学生基本情况工具等^[2]。

(3)事件日志。该模块描述观察到的案例执行情况的事件序列,包含不同教育过程执行的重要信息。例如,学生注册程序、考试记录、教学资源使用情况、电子学习环境中的活动日志等。

(4)过程模型。该模块通过相关挖掘技术得到过程性的知识表征,为改进教育世界与教育信息提供充实的理论与实践引导^[2]。




Fig. 1 Three major scenarios for educational process mining: discovery, compliance and enhancement

图 1 教育过程挖掘的三大场景:发现、合规性和增强

定义 1(事件) 事件是业务系统中活动的一次运行实例,通过多元组 $e = \{Caseid, a, Time, p_{1,2,\dots,n}\}$ 表示^[13]。其中,Caseid 为事件所属案例的 ID; a 为事件执行活动的名称; $Time$ 为事件执行时间 ($Time = \text{事件结束时间 } EndTime - \text{事件开始时间 } StartTime$); $p_{1,2,\dots,n}$ 为事件其余属性,包括资源等信息。

定义 2(轨迹) 轨迹是一个非空且有限的事件序列,可表示为 $\sigma = \{e_1, e_2, \dots, e_{|\sigma|}\}$ 。其中, $|\sigma|$ 表示轨迹 σ 中事件数量。

定义 3(轨迹前缀) 形式化为 $\sigma^{(l)} = \langle e_1, \dots, e_l \rangle (1 \leq l \leq |\sigma|)$, 轨迹 σ 在执行第 l 个事件后 $\sigma^{(l)}$ 的剩余时间记为:

$\text{Remain}(\sigma, l) = e_{|o|, \text{complete.end}} - e_l.\text{complete.end}^{[14]}$ 。

定义4(流程实例) 流程实例是整个业务流程的一次完整的执行,可表示为元组 $Q = \{\text{Caseid}, \sigma, P_{[1, 2, \dots, m]}\}$ 。

定义5(事件日志) $L = (C, A, \rho)$ 表示一个事件日志,当且仅当: $C \subseteq \mathcal{C}$ 是一组案例(即流程实例); $A \subseteq \mathcal{A}$ 是一组活动; $\rho \subseteq C \rightarrow A^*$ 将每个案例映射到活动序列(即轨迹)上。

定义6(剩余时间预测) 在业务系统中,若内部事件空间为 Y ,则流程实例包含轨迹及轨迹前缀空间可表示为 Y^* ,剩余时间预测旨在利用构建预测模型 $f = Y^* \rightarrow R^+$ 预测流程实例轨迹的前缀剩余时间^[14]。

3 面向教育过程的剩余时间预测方法

图2为面向教育过程的剩余时间预测方法的框架。首先,提取学生学习过程的事件日志,逐条遍历存在的学生学习轨迹,并划定 $[\min, \max]$ 长度范围截取轨迹前缀,以获得不同长度的轨迹前缀和剩余时间作为训练样本 $DB_{\min}, \dots, DB_{\max}$,并将训练样本相互组合后得到训练数据集 DB ;其次,抽取训练集数据集 DB 中全部学生的学习过程事件,利用教育过程将学习方法进行向量化表示,并将形式化向量输入双向循环神经网络剩余时间预测模型;最后,为解决单一预测模型预测效果不理想的问题,通过所提方法迭代训练预测模型,得到学生学习过程的剩余时间。

3.1 教育过程表示学习方法

目前,在利用深度学习开展剩余时间预测任务的过程中,大都将独热编码(One-Hot)作为模型输入,但存在维度爆炸、特征稀疏等问题导致语义鸿沟^[15]。为此,本文提出一种教育过程表示学习方法(Educational Process Represent Learning, EPRL)。由定义1可知,活动与执行时间是事件的关键组成属性,故将二者作为学生学习过程事件的主要标识且向量化表示。由于时间是连续值,则需先对其进行离散化,具体计算过程为:

$$\hat{t}(e) = \left\lfloor \frac{t(e) - t_{\min(\text{endtime} - \text{starttime})}(e, a)}{t_{\max(\text{endtime} - \text{starttime})}(e, a) - t_{\min(\text{endtime} - \text{starttime})}(e, a)} \cdot M \right\rfloor \quad (1)$$

式中: $t(e)$ 表示学生学习过程事件的连续执行时间; $t_{\min(\text{endtime} - \text{starttime})}$ 、 $t_{\max(\text{endtime} - \text{starttime})}$ 表示学生学习活动执行的最短与最长时间; M 表示经离散化后学生学习过程事件执行时间所划分的数量。

由此,学生学习过程事件向量即为学生学习活动与离散化执行时间的拼接,经训练可得向量 $\theta^{<a, \hat{t}(e)>}$ 。在对学生学习过程事件进行表示时,借鉴了自然语言处理领域中的词袋模型(Continuous Bag-of-Word Model, CBOW)^[16],如图3所示。首先,选取 t 时刻学生学习过程事件的上下文 c ($c=2$) 个事件,将其进行 One-Hot 编码后作为模型输入;其次,将该向量与权重矩阵相乘,在加权平均后得到隐藏层输出向量;再次,将隐藏层输出向量与权重矩阵相乘,通过 Softmax 函数处理得到学生学习过程事件的概率分布;最后,经多次迭代训练获得学生学习过程事件的表示向量。




Fig. 2 Framework for remaining time prediction methods in the educational process

图2 面向教育过程的剩余时间预测方法框架




Fig. 3 CBOW structure

图 3 CBOW 结构

3.2 基于注意力机制的双向循环神经网络剩余时间预测模型

作为处理序列数据的深度神经网络模型,循环神经网络(Recurrent Neural Network, RNN)将每个神经元在 t 时刻的输出作为 $t+1$ 时刻输入的一部分,对变长序列数据进行建模^[17]。RNN 神经元以 LSTM(Long Short-Term Memory)与 GRU(Gated Recurrent Unit)为具体实现方式,有效解决了 RNN 的梯度消失和梯度爆炸问题^[18]。Chung 等^[19]在序列建模任务上进行实验与分析,验证了 GRU 相较于 LSTM 能取得较优效果,因此本文选择 GRU 作为神经元。

GRU 由重置门 r_t 、更新门 z_t 组成。其中,重置门 r_t 决定了遗忘先前信息的程度;更新门 z_t 决定了先前信息的保留程度^[20]。在 t 时刻 GRU 的更新过程为:

$$r_t = \sigma(W_r \cdot [h_{t-1}, X_t] + b_r) \quad (2)$$

$$\tilde{h}_t = \tanh(W_h \cdot (r_t * [h_{t-1}, X_t]) + b_h) \quad (3)$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, X_t] + b_z) \quad (4)$$

$$h_t = (1 - z_t) * \tilde{h}_t + z_t * h_{t-1} \quad (5)$$

式中: σ 、 $\tanh$ 表示激活函数; h_{t-1} 、 h_t 表示第 $t-1$ 、 t 时刻的输出; $\tilde{h}_t$ 表示单元状态候选值; W_r 、 W_z 、 W_h 表示变换矩阵; b_r 、 b_h 、 b_z 表示偏置值。

由于单向 GRU 在处理序列建模任务时存在局限性,且无法较好地顾及上下文之间的关联性。为此,本文在 GRU 的基础上融合双向机制和注意力机制,设计了基于注意力机制的双向 GRU 循环神经网络(Bi-directional Gated Recurrent Unit Recurrent Neural Network with Attention, Att-

Bi-GRU)预测模型,如图 4 所示。




Fig. 4 Structure of dual GRU based on attention mechanism

图 4 基于注意力机制的双 GRU 循环神经网络结构

(1) 基于双向 GRU 的上下文编码。本文通过双向机制有效解决了单向 GRU 上下文关联性较差的问题。双向 GRU 由一条正向 GRU 与一条反向 GRU 组成,第 t 时刻正向与反向 GRU 得到的输出隐向量分别为 $\vec{h}_t$ 、 $\overleftarrow{h}_t$,双向 GRU 可表示为 $H_t = [\vec{h}_t, \overleftarrow{h}_t]$ 。

(2) 基于注意力机制编码。依据双向 GRU 上下文编码 H_t ,可通过注意力机制计算得到轨迹前缀编码。

$$v = \sum_i a_i \cdot H_i \quad (6)$$

式中: a_i 表示在第 t 时刻权重信息,反映了学生学习过程中不同事件预测剩余时间重要程度。

3.3 教育过程预测模型层次训练方法

划分学生学习过程轨迹生成长度不一的轨迹前缀训练样本,会导致轨迹前缀数量持续减少。同时,仅在不同长度的轨迹前缀训练样本上进行训练,不仅无法获得较准确的预测模型,还在一定程度上忽略了各轨迹前缀之间的相关性。为此,本文提出一种教育过程预测模型层次训练方法(Hierarchical Training Method for Educational Process Prediction Model, EPHTM),如图 5 所示。

EPHTM 的基本思想:首先,利用构建的 Att-Bi-GRU




Fig. 5 Process of hierarchical training method for educational process prediction model

图 5 教育过程预测模型层次训练方法过程

预测模型,在长度范围 $[min, max]$ 的训练样本 $DB_{min}, \dots, DB_{max}$ 上逐一训练,即先在长度短(min)且数量多的训练样本 DB_{min} 上进行训练得到预测模型 M_{min} ;其次,将预测模型 M_{min} 训练参数共享至轨迹前缀长度为 $min+1$ 的预测模型 M_{min+1} 上迭代训练;最后,经多轮层次训练后获得轨迹前缀长度为 max 的预测模型 M_{max} 。

4 实例分析

4.1 数据集与评价指标

本文选用学生在线学习微处理器系统设计课程作为数据集,共分为6节内容,包含学生查看学习视频、测试等事件,详细信息如表1所示。同时,通过平均绝对误差(Mean Absolute Error, MAE)评价预测学生学习过程剩余时间的效果,值越低表明剩余时间预测越准确。

Table 1 Basic information of the dataset

表1 数据集基本信息

事件日志	事件数量	活动数量	轨迹最大长度	轨迹最小长度
Session1	71 836	28	3	5
Session2	83 014	38	5	8
Session3	60 412	48	2	11
Session4	83 036	40	6	7
Session5	71 918	42	2	6
Session6	108 564	42	3	7

$$MAE(f) = \sum_{(\sigma^{(l)}, \text{Remain}(\sigma, l)) \in DB} |f(\sigma^{(l)}) - \text{Remain}(\sigma, l)| \quad (7)$$

式中: $f(\sigma^{(l)})$ 表示学生学习过程轨迹前缀剩余时间的预测值; $\text{Remain}(\sigma, l)$ 表示学生学习过程轨迹前缀剩余时间的真实值。

4.2 实例结果

4.2.1 学生学习过程剩余时间预测效果

表2为预测学生学习过程剩余时间的结果。由此可知,在基础剩余时间预测模型GRU上引入双向机制(Bi-GRU)后,在6个数据集上的MAE值相较于GRU平均下降10.5%,表明双向机制可在一定程度上提升上下文之间的关联性。在Bi-GRU上引入注意力机制后,在6个数据集上的MAE值平均下降5.3%,表明注意力机制通过计算学生学习过程中不同学习事件的权重,可区分重要的学习事件。此外,在Att-Bi-GRU剩余时间预测模型上融入EPRL、EPHTM方法(即EPRT),在6个数据集上的MAE值最佳,表明所提方法可有效预测学生学习剩余时间、优化教育过程、提升学生学习体验,提供决策性建议与意见,具备一定可行性与优越性。

Table 2 Comparison of prediction results of remaining time in student learning process

表2 学生学习过程剩余时间预测效果比较 (min)

预测模型	Session1	Session2	Session3	Session4	Session5	Session6
GRU	44.502	96.834	74.215	44.678	63.741	103.919
Bi-GRU	41.366	92.335	55.763	42.982	56.747	97.432
Att-Bi-GRU	39.980	91.292	53.096	40.980	48.829	91.302
EPRT	22.017	26.870	31.933	7.917	19.170	28.908

4.2.2 教育过程表示学习方法分析

为了表明EPRL方法在学生剩余时间预测任务上的有效性,开展针对性的比较实验,即将EPRL方法训练得到的向量(EPRL)、One-Hot向量(NO_EPRL)分别作为GRU、Bi-GRU、Att-Bi-GRU预测模型的输入进行实验,结果如图6所示。




Fig. 6 Analysis results of learning methods in educational process representation

图6 教育过程表示学习方法分析结果

由此可见,在 6 个数据集上以 EPRL 方法训练得到向量作为输入的 MAE 值,相较于以 One-Hot 向量作为输入的效果更优,说明 EPRL 方法将相近事件映射到位置相同的向量空间,有效解决了 One-Hot 编码维度爆炸等问题,进一步提升了语义信息表达性。

4.2.3 教育过程预测模型层次训练方法分析

本文以 GRU、Bi-GRU、Att-Bi-GRU 为基准预测模型,在 6 个数据集中进行迭代训练,具体为:①在训练样本 $DB_{in}, \dots, DB_{max}$ 上依次单独训练学生学习过程剩余时间

预测模型,以 NO_EPHTM 表示;②利用 EPHTM 方法在训练样本 $DB_{min}, \dots, DB_{max}$ 上训练多个学生学习过程剩余时间预测模型,以 EPHTM 表示。教育过程预测模型层次训练方法实验结果如图 7 所示。

由此可见,融入 EPHTM 方法的 GRU、Bi-GRU、Att-Bi-GRU 预测模型在 6 个数据集上的 MAE 值优于未融入 EPHTM 的方法,表明 EPHTM 方法解决了划分后轨迹前缀数量的差异性而导致预测效果不佳的问题,有效提升了不同轨迹前缀之间的相关性。




Fig. 7 Experimental results of hierarchical training method for educational process prediction model

图 7 教育过程预测模型层次训练方法实验结果

5 结语

在教育过程中运用教育过程挖掘方法,可为学生学习过程提供建议,为教师、研究人员提供反馈意见,进而制定或改进教学策略,优化资源配置。为此,本文针对教育过程挖掘中未在时间维度进行辨析的问题,设计了一种面向教育过程的剩余时间预测方法。

实验表明,所提方法在预测学生学习过程剩余时间上效果较好、具有可行性,可进一步提升教育教学产出。然而,所提方法只利用学生学习过程中的轨迹与事件信息,其他额外属性尚未探索。为此,可在当前工作的基础上适当引入额外属性,探索多属性对预测学生剩余时间的影响程度。同时,有效的编码方式也有助于提升剩余时间预测的准确度,根据属性特点构建有针对性的属性编码方式。

参考文献:

[1] LI J P. Research on student learning behavior analysis based on process mining[D]. Zibo: Shandong University of Technology, 2023.

李金鹏. 基于过程挖掘的学生学习行为分析方法研究[D]. 淄博: 山东理工大学, 2023.

- [2] HUANG Y, ZHAO C L, ZHAO G, et al. Intelligent technology of education process mining: research framework, status and prospect[J]. E-education Research, 2020, 41(8): 49-57.
黄琰, 赵呈领, 赵刚, 等. 教育过程挖掘智能技术: 研究框架、现状与趋势[J]. 电化教育研究, 2020, 41(8): 49-57.
- [3] BOGARIN A, CEREZO R, ROMERO C. A survey on educational process mining[J]. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 2018, 8(1): 12-30.
- [4] DENG L J, DONG D X, CHEN X X. Research and application of process mining technology[J]. Cyber Security and Data Governance, 2017, 36(18): 11-14.
邓璐娟, 董东晓, 陈欣欣. 过程挖掘技术的研究与应用[J]. 网络安全与数据治理, 2017, 36(18): 11-14.
- [5] AALST W V D. Process mining: making knowledge discovery process centric[J]. Sigkdd Explorations, 2012, 13(2): 45-49.
- [6] BOGARIN A, ROMERO C, CEREZO R, et al. Clustering for improving educational process mining[C]// Proceedings of the Fourth International Conference on Learning Analytics and Knowledge, 2014: 11-15.
- [7] BANNERT M, REIMANN P, SONNENBERG C. Process mining tech-

- niques for analysing patterns and strategies in students' self-regulated learning[J]. *Metacognition and Learning*, 2014, 9(2):161-185.
- [8] MUKALA P, BUIJS J, DER A W M. Uncovering learning patterns in a MOOC through conformance alignments[J]. *Information Systems*, 2015, 12(7): 1509-1529.
- [9] AALST W V D, GUO S, GORISSEN P J B. Comparative process mining in education: an approach based on process cubes[C]// *International Symposium on Data-Driven Process Discovery and Analysis*, 2015:110-134.
- [10] BAO Y X, LU F M, WANG Y. Student performance prediction based on behavior process similarity[J]. *Chinese Journal of Electronics*, 2020, 13(11):10-18.
- [11] KONG Y. Student performance prediction and learning intervention system model based on machine learning[C]// *International Conference on Cyber Security Intelligence and Analytics*, 2022: 862-870.
- [12] FORJI A, VASSILEVA J. Machine learning approach for predicting students academic performance and study strategies based on their motivation[DB/OL]. <https://arxiv.org/abs/2210.08186>.
- [13] XU X R, ZHANG S P, LI T, et al. Business process remaining time prediction method based on trajectory clustering[J]. *Computer Engineering*, 2022, 48(11): 247-256, 265.
徐兴荣, 张帅鹏, 李婷, 等. 基于轨迹聚类的业务流程剩余时间预测方法[J]. *计算机工程*, 2022, 48(11): 247-256, 265.
- [14] XU X R, LIU C, LI T, et al. Business process remaining time prediction: an approach based on bidirectional quasi recurrent neural network with attention[J]. *Acta Electronica Sinica*, 2022, 50(8): 1975-1984.
徐兴荣, 刘聪, 李婷, 等. 基于双向准循环神经网络和注意力机制的业务流程剩余时间预测方法[J]. *电子学报*, 2022, 50(8): 1975-1984.
- [15] XIAO L, CHEN Z J. Review of data-driven approaches to chinese named entity recognition[J]. *Computer Engineering and Applications*, 2024, 60(16):34-48.
肖蕾, 陈镇家. 数据驱动的中文实体抽取方法综述[J]. *计算机工程与应用*, 2024, 60(16):34-48.
- [16] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space [DB/OL]. <https://arxiv.org/abs/1301.3781>.
- [17] NI W J, SUN Y J, LIU T, et al. Business process remaining time prediction using bidirectional recurrent neural networks with attention [J]. *Computer Integrated Manufacturing System*, 2020, 26(6): 1564-1572.
倪维健, 孙宇健, 刘彤, 等. 基于注意力双向循环神经网络的业务流程剩余时间预测方法[J]. *计算机集成制造系统*, 2020, 26(6): 1564-1572.
- [18] LI X L. Research on time series prediction model based on improved recurrent neural network[D]. Shijiazhuang: Hebei University of Science and Technology, 2023.
李晓磊. 基于改进循环神经网络的时间序列预测模型研究[D]. 石家庄:河北科技大学, 2023.
- [19] CHUNG J, GULCEHRE C, CHO K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[DB/OL]. <https://arxiv.org/pdf/1412.3555>.
- [20] ZHANG X Y, CAI Z J. Text sentiment analysis based on Bert-BiGRU-CNN[J]. *Computer Simulation*, 2023, 40(7): 519-523.
张鑫玉, 才智杰. 基于 Bert-BiGRU-CNN 的文本情感分析[J]. *计算机仿真*, 2023, 40(7): 519-523.

(责任编辑:刘嘉文)