

# 基于注意力机制的泊位占有率预测模型研究

王竹荣, 薛伟, 牛亚邦, 崔颖安, 孙钦东, 黑新宏

(西安理工大学计算机科学与工程学院, 陕西 西安 710048)

**摘要:** 为解决泊位占有率的预测精度随步长增加而下降的问题, 提出了一种基于注意力机制的泊位占有率预测模型。通过卷积神经网络获得多变量的时间模式信息作为模型的注意力机制。通过对模型训练、学习特征信息, 并对相关性高的序列分配较大的学习权重, 来实现解码器输出高度相关的有用特征预测目标序列。应用多个停车场数据集对模型进行测试, 测试结果及对比分析表明, 所提模型在步长达到 36 时对泊位占有率的预测数据能较好地估计真实值, 预测精度和稳定性相比 LSTM 均有提高。

**关键词:** 时间序列预测; 泊位占有率预测; 注意力机制; 序列到序列模型

**中图分类号:** TP391

**文献标识码:** A

**doi:** 10.11959/j.issn.1000-436x.2020241

## Research on berth occupancy prediction model based on attention mechanism

WANG Zhurong, XUE Wei, NIU Yabang, CUI Ying'an, SUN Qindong, HEI Xinhong

School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China

**Abstract:** To solve the problem that the berth occupancy prediction accuracy decreases while the prediction step was increasing, a berth occupancy prediction model based on an attention mechanism was proposed, which was the multivariate time pattern information obtained by convolutional neural networks (CNN). The characteristic information was learned by the model training, and the sequence with higher correlation was assigned a larger learning weight, so that the highly correlated features output from the decoder could be used to predict the target sequence. Data sets of multiple parking lot were adopted to test the model. The test results show that the proposed model can estimate the real value well when the step length of berth occupancy prediction reaches 36. The prediction accuracy and stability of the model are improved compared with long short-term memory (LSTM) model.

**Key words:** time series prediction, berth occupancy prediction, attention mechanism, sequence-to-sequence model

### 1 引言

近年来, 智能交通系统 (ITS, intelligent transportation system) 迅速发展<sup>[1]</sup>。停车诱导信息系统 (PGIS, parking guidance information system) 是 ITS 中不可缺少的组成部分, 泊位占有率预测

是其中一项重要技术。根据国际停车协会 (IPI, International Parking Institute) 的一项调查, 超过 30% 的汽车在公路上寻找停车位, 而这些巡航汽车在城市地区造成了高达 40% 的交通堵塞<sup>[2]</sup>。研究数据显示, 在公路的车流量中, 泊车车辆占道路车流量的 12%~15%。寻找车位的过程会增加

收稿日期: 2020-07-07; 修回日期: 2020-10-07

通信作者: 黑新宏, heixinhong@xaut.edu.cn

基金项目: 国家重点研发计划基金资助项目 (No.2018YFB1201500); 国家自然科学基金资助项目 (No.61773313); 陕西省重点研发计划基金资助项目 (No.2017ZDXM-GY-098); 陕西省教育厅重点实验室基金资助项目 (No.17JS100)

**Foundation Items:** The National Key Research and Development Program of China (No.2018YFB1201500), The National Natural Science Foundation of China (No.61773313), Shaanxi Key Research and Development Program (No.2017ZDXM-GY-098), Shaanxi Provincial Department of Education Key Laboratory Project (No.17JS100)

30%的燃油消耗<sup>[3]</sup>。泊位占有率预测和泊位信息共享对停车场的日常运行、调度规划以及交通运行状态具有重要影响。泊位占有率预测已经引起学术界和工业界的广泛关注。例如,谷歌地图基于用户调查和轨迹数据<sup>[4]</sup>预测全市范围内的停车困难程度;百度地图基于环境上下文特征(如兴趣点、地图查询等),估计全市范围内的实时停车位可用信息<sup>[5]</sup>。上述方法是对某一区域的停车难度进行预测和分级,这可能导致对于单个停车场的泊位占有率预测结果不准确。

现有的泊位占有率预测方法主要为基于统计学的预测方法和基于机器学习的预测方法。基于统计学的预测方法虽然计算较为简单,时间复杂度较低,但是预测精度不高且稳定性较差。例如,Dunning 等<sup>[6]</sup>提出建立一个停车场数据收集以及泊位预测的 PGIS,利用差分整合移动平均自回归模型进行泊位占有率预测,实验结果表明该模型的预测效果并不稳定,仅能预测占有率相对平稳的时间段,在出现波峰或者波谷的时间段预测效果较差。Caliskan 等<sup>[7]</sup>利用 PGIS 采集的车辆抵达停车场的的时间和停车场泊位占有率等历史数据,使用连续时间齐次马尔可夫与排队论预测方法进行泊位占有率预测。Chen 等<sup>[8]</sup>对泊位占有率预测展开研究,结合泊位占有率的外在影响因素,利用通用代数建模系统(GAMS, the general algebraic modeling system)进行建模求解,泊位占有率预测精度有一定提升。Rajabioun 等<sup>[9]</sup>和 Klappenecker 等<sup>[10]</sup>通过数学方法进行泊位占有率预测,该方法依赖于参数控制,具有很强的样本依赖性,虽然降低了计算的时间复杂度,但稳健性较差。Richter 等<sup>[11]</sup>通过分析停车场的泊位历史数据,对泊位数据时间和空间进行聚类,来选择最优的时空特征,预测准确性进一步提高。为解决基于统计学泊位占有率预测方法的不足,基于机器学习的泊位占有率预测方法近几年大量涌现。杨兆升等<sup>[12]</sup>将 BP (back propagation) 神经网络应用到泊位占有率预测问题中。陈群等<sup>[13]</sup>利用相空间重构对泊位数据进行预处理,并利用 Elman 神经网络泊位预测方法进一步提升模型预测精度。Blythe 等<sup>[14]</sup>和季彦婕等<sup>[15]</sup>提出基于小波变换的泊位预测模型,然后利用启发式算法对神经网络进行优化,提出粒子群优化的小波神经网络停车场泊位预测模型。陈海鹏等<sup>[16]</sup>采用小波变换和 ELM (wavelet transform with extreme learning) 相结合的

方法进行泊位的短时预测,所提模型在不降低预测精度的情况下,提升了传统神经网络的训练效率。韩印等<sup>[17]</sup>提出基于灰色-小波神经网络的有效泊位预测算法。

综上分析可知,基于统计学的泊位预测方法在时间复杂度方面具有优势,但是预测精度相对较低且样本依赖性强。与之相比,基于机器学习的泊位预测方法的预测精度大幅提升,适合时间跨度较长的泊位预测场景要求。

泊位占有率预测是一种具有典型时间序列特征的时间序列预测问题。随着深度学习在图像处理和自然语言领域的发展,很多新的神经网络模型和方法被用于时间序列预测问题,如 Seq2seq 模型结合残差网络<sup>[18]</sup>、深度神经网络结合统计学方法的 ARMAM (autoregressive moving average model)<sup>[19]</sup>、基于注意力机制的长短时记忆网络<sup>[20]</sup>、基于时间注意力学习的多视野时间序列预测方法<sup>[21]</sup>、基于时间模式的神经网络<sup>[22-23]</sup>、基于 DTW (dynamic time warping) 的直觉模糊时间序列预测模型<sup>[24]</sup>和利用直觉模糊多维取式推理建立的高阶模型<sup>[25]</sup>。其他的模型介绍如下。自注意力机制转移网络模型<sup>[26]</sup>通过矩阵控制序列权重的学习方式学习特征信息,主要适用于自然语言处理问题,是目前自然语言处理研究和应用最为广泛的模型。自注意力机制的卷积模型<sup>[27]</sup>通过改变自注意力机制结构,将原有的注意力用于计算全局的隐含层向量权重,此模型利用卷积神经网络(CNN, convolutional neural network)获取局部信息,将时间复杂度从  $O(n^2)$  降低到  $O(n(\log n)^2)$ ,加快了运算速度。基于社会注意力的行人轨迹预测模型提高了预测的可解释性和预测精度<sup>[28]</sup>。何坚等<sup>[29]</sup>提出了综合考虑多维时空因果关系的泊位占有率预测技术和方法。梅振宇等<sup>[30]</sup>对泊位占有率序列的复杂性度量方法进行了分析。

从长远发展角度考虑,PGIS 不仅要及时地为用户提供的泊位信息,还应对未来一段时间的泊位需求信息做出预估,给予用户更长时间进行出行规划。因此,泊位的中长期预测研究是必要的。目前,对泊位占有率中长期预测的研究相对较少,现有的预测方法主要以传统的迭代计算为主,预测效果较差。深度学习方法提供了处理多元时间序列的预测新思路。对泊位的中长期预测方法进行研究,在增加预测步长的前提下,提升预测精度及预测序列的稳定性指标成为必要工作。

本文主要工作如下。1)提出了一种高效的时间序列预测模型。所提模型以 sequence-to-sequence 为整体框架,以双向长短时记忆(BiLSTM, bi-directional long short-term memory)网络<sup>[31]</sup>为模型的编码器和解码器的内部结构,通过一维 CNN 提取多变量的局部特征作为模型的注意力机制,捕获泊位预测问题特征的时间模式信息。2)将所提模型用于预测泊位占有率数据预测,测试结果及对比分析表明,所提带有注意力机制的神经网络模型有较强的非线性特征提取能力,与 LSTM (long short-term memory)网络模型相比预测精度较高,有较强的稳健性和稳定性。

## 2 基于注意力机制的 sequence-to-sequence 泊位预测模型

sequence-to-sequence 模型实现了从一个序列到另一个序列的转换。Google 曾用 sequence-to-sequence 模型加注意力机制来实现翻译功能。sequence-to-sequence 模型突破了传统的循环神经网络(RNN, recurrent neural network)模型输入输出序列大小固定的限制。sequence-to-sequence 由编码器(encoder)和解码器(decoder)两部分组成,能有效提取输入数据的特征。停车场泊位数据具有典型的时间序列特征,通过历史数据预测未来停车场占有率,符合序列到序列模型的时间数据序列特征。因此,本文利用 sequence-to-sequence 模型结合时间模式的注意力机制进行泊位占有率预测。

本文采用 sequence-to-sequence 编解码器结构作为泊位预测模型,其中编码器和解码器采用 BiLSTM 网络。编码器端将不定长序列输出为定长序列,由于输入序列较长,解码器端难以获得有效的数据信息。因此,本文引入注意力机制,增强局

部数据特征学习能力,保留 BiLSTM 编码器对输入序列的输出,通过 CNN 获得多变量的时间模式信息,并存储上下文信息。通过对模型进行训练,根据学习特征信息,将输入序列与模型输出关联起来,并对相关性高的序列分配较高的学习权重,用输出序列提取高度相关的有用特征。解码器将结合编码器输出信息及注意力机制存储的时间模式信息,输出预测目标序列。

### 2.1 BiLSTM 工作原理

BiLSTM 是双向 LSTM,由前向 LSTM 与后向 LSTM 组合而成,它们用来建模上下文信息,具有更强的长期信息记忆能力。

BiLSTM 的单元结构如图 1 所示,其中  $(x_1, x_2, \dots, x_m)$  为输入序列,  $LSTM_L$  为前向 LSTM,  $LSTM_R$  为后向 LSTM,  $h_{Lm}$  为前向 LSTM 隐藏状态向量,  $h_{Rm}$  为后向 LSTM 隐藏状态向量,  $h_t$  为 BiLSTM 的隐藏状态向量。BiLSTM 的隐藏状态需要结合前向和后向 2 个方向的隐藏状态。

BiLSTM 的隐藏状态向量为

$$h_t = \{h_{Lm}, h_{Rm}\} \tag{1}$$

BiLSTM 是由 2 条 LSTM 链式结构组成,而 LSTM 的内部结构可参见文献[32-33]。

BiLSTM 中的单向 LSTM 描述如下。每一个步长  $t$  与其对应的输入序列为  $X = \{x_1, x_2, \dots, x_w\}$  ( $w$  为滑动窗口大小),网络内部单元中包括输入门  $i_t$ 、遗忘门  $f_t$ 、输出门  $o_t$  和隐含层  $h_t$ 。状态单元  $c_t$  通过控制  $i_t$ 、 $f_t$  和  $o_t$  来控制数据的记忆及遗忘,如式(2)~式(9)所示。

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \tag{2}$$

$$\sigma(x) = \text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \tag{3}$$

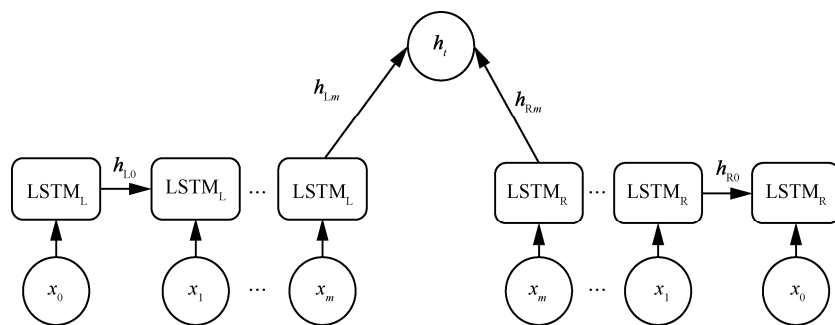


图 1 BiLSTM 单元结构

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (4)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (5)$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (6)$$

$$c_t = f_t \bullet c_{t-1} + i_t \bullet \tilde{c}_t \quad (7)$$

$$\tanh(x) = \frac{\sinh x}{\cosh x} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (8)$$

$$h_t = o_t \bullet \tanh(c_t) \quad (9)$$

其中,  $W_i$ 、 $W_f$ 、 $W_o$ 、 $W_c$  表示输入过程的权重参数,  $U_i$ 、 $U_f$ 、 $U_o$ 、 $U_c$  表示状态转移权重参数,  $b_i$ 、 $b_f$ 、 $b_o$ 、 $b_c$  表示偏差参数,  $\tilde{c}_t$  表示候选记忆细胞,  $\tanh(\cdot)$  表示双曲正切函数,  $\bullet$  表示点乘。

sigmoid 函数  $\sigma(x)$  为一个 logistic 函数, 它可以将一个实数映射到(0,1)。 $\tanh(\cdot)$  是双曲正切函数, 它可以数值缩放到(-1,1)。三类门限控制单元共同控制信息进入和离开记忆细胞, 输入门  $i_t$  调节进入记忆细胞的新信息, 遗忘门  $f_t$  控制记忆细胞中保存的信息, 输出门  $o_t$  定义输出信息。LSTM 的门结构使时间序列上的信息形成一个有效的依赖关系。

## 2.2 sequence-to-sequence 模型结构

sequence-to-sequence 模型在处理序列任务时, 对输入序列或输出序列的长度没有限制, 可执行不定长输入和不定长输出。sequence-to-sequence 模型结构如图 2 所示。




图 2 sequence-to-sequence 模型结构

图 2 中, sequence-to-sequence 模型由编码器、上下文向量  $v_t$  和解码器组成。编解码器通常是多层的 RNN 或 LSTM 结构, 本文选择 BiLSTM 网络作为编码器和解码器网络。上下文向量  $v_t$  包含了  $x_1, x_2, \dots, x_m$  隐含层编码信息。对于时间  $t$ , 将编码器隐含层  $h_t$ 、解码器之前时刻的输出  $y_{t-1}$ 、之前时刻的隐含层状态  $s_{t-1}$  以及  $v_t$  输入解码器。最后得到解码器的隐含层状态  $s_t$ , 解码器对输出值进行预测。

sequence-to-sequence 编解码器结构模型计算式

如式(10)和式(11)所示。

$$\mathbf{x} = (x_1, x_2, \dots, x_m) \quad (10)$$

$$\mathbf{y} = (y_1, y_2, \dots, y_n) \quad (11)$$

其中,  $\mathbf{x}$  和  $\mathbf{y}$  分别为 sequence-to-sequence 编码器端输入序列和解码器端最终输出预测值。

编码器输入端是  $\mathbf{x}$  和上一个时间步的隐藏状态  $h_{t-1}$ , 输出端是当前时间步的隐藏状态  $h_t$ , 即

$$h_t = \text{BiLSTM}_{\text{enc}}(x_t, h_{t-1}) \quad (12)$$

对原始时间序列使用 BiLSTMBlockCell 处理, 得到每个时间步的隐藏状态  $h_t$  ( $h_t$  为列向量), 每个  $h_t$  维度为  $m$ ,  $w$  是滑动窗口长度, 得到的隐藏状态矩阵  $\mathbf{H} = \{h_{t-w}, h_{t-w+1}, \dots, h_{t-1}\}$ 。隐藏状态矩阵的行列向量意义如下。

- 1) 行向量代表单个变量在所有时间步的状态, 即同一变量的所有时间步构成的向量。
- 2) 列向量代表单个时间步状态, 即同一时间步下的所有变量构成的向量。

## 2.3 TPA 机制

所提模型中利用一维 CNN 学习时间序列数据的时间模式信息, 即 TPA(temporal pattern attention) 作为网络的局部特征学习方式<sup>[23]</sup>。TPA 机制结构如图 3 所示。图 3 中最左侧箭头表示对变量的处理, 每一行表示一个变量的时间序列数据。通过卷积计算获得该变量在卷积核范围内的时间模式矩阵  $H_{i,j}^c$ , 评分函数计算时间模式矩阵的分值, 并通过 sigmoid 函数将分值归一化, 获得注意力权重  $\alpha$ , 结合时间模式矩阵及注意力权重计算得到上下文向量  $v_t$ 。将 encoder 中的上下文向量  $v_t$  及隐藏状态  $h_t$ , 与 decoder 中的隐藏状态  $s_t$  进行连接, 并通过输出层及 softmax 函数来计算输出预测值。

以下详细描述 TPA 机制在所提模型中的作用机理。

首先, 利用一维 CNN 进行卷积计算。

卷积配置为  $k$  个滤波器(filter), 卷积核(kernel)尺寸为  $1 \times T$  ( $T$  代表注意力所覆盖的范围, 通常令  $T=w$ ), 将上述 kernel 沿隐藏状态矩阵  $\mathbf{H}$  的行向量计算卷积, 提取该变量在该卷积核范围  $\text{attn\_length}$  内的时间模式矩阵  $H_{i,j}^C$ , 如式(13)所示。

$$H_{i,j}^C = \sum_{l=1}^w C_{j,T-w+l} * H_{i,(t-w-l+1)} \quad (13)$$

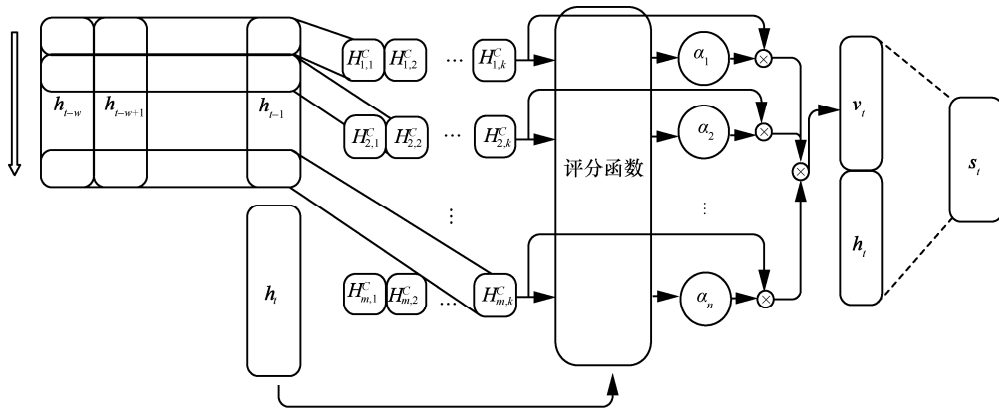


图 3 TPA 机制结构

其中， $H_{i,j}^C$  表示第  $j$  个滤波器对第  $i$  行注意力机制在  $[t-w, t-1]$  内进行卷积计算的时间模式矩阵； $H_{i,(t-w-1:t)}$  决定卷积计算的范围；卷积核  $C_{j,T-w+1}$  对该范围内的数据进行卷积运算。

对上述学习到的时间模式进行评分，时间模式的评分函数  $f$  为

$$f(H_i^C, h_t) = (H_i^C)^T W_a h_t \quad (14)$$

其中， $H_i^C$  表示时间模式矩阵  $H^C$  的第  $i$  行， $h_t$  表示 encoder 输出的隐藏状态， $W_a$  表示权值参数。

注意力权重  $\alpha_i$  为

$$\alpha_i = \text{sigmoid}(f(H_i^C, h_t)) \quad (15)$$

对  $H^C$  的每一行做加权求和，得到上下文向量  $v_t$  为

$$v_t = \sum_{i=1}^m \alpha_i H_i^C \quad (16)$$

其中， $\alpha_i$  为时间模式矩阵  $H^C$  的第  $i$  行注意力权重， $H_i^C$  为时间模式矩阵  $H^C$  的第  $i$  行。

将上下文向量  $v_t$  与 encoder 的隐藏状态  $h_t$  传入 decoder。将 encoder 的隐藏状态  $h_t$ 、上下文向量  $v_t$  与 decoder 隐藏状态  $s_t$  连接，如式(17)所示。

$$s_t = \tanh(W_v[v_t; h_t]) \quad (17)$$

其中， $W_v$  为权值参数。

decoder 通过接收前一个输出序列  $y_{t-1}$  以及 decoder 的上一个时间步的隐藏状态  $s_{t-1}$  和上下文向量  $v_t$  计算当前隐藏状态  $s_t$ ，如式(18)所示。

$$s_t = \text{BiLSTM}_{\text{dec}}(y_{t-1}, v_t, s_{t-1}) \quad (18)$$

最后，结合 decoder 当前时间步隐藏状态  $s_t$  及上下文向量  $v_t$ ，通过输出层及 softmax 函数来计算输出  $y_t$ ，如式(19)所示。

$$y_t = \text{softmax}(W_y s_t + W_v v_t + b_y) \quad (19)$$

softmax 函数是一个概率函数，max 表示取大概率最大值，它的作用是将所有输出映射到(0,1)，softmax 最大值作为最终的输出。

假设有一个数组  $Y$ ，数组长度为  $k$ ， $y_i$  表示  $Y$  中的第  $i$  个元素，那么元素  $y_i$  的 softmax 值为

$$\text{softmax}(y_i) = \frac{e^{y_i}}{\sum_{j=1}^k e^{y_j}} \quad (20)$$

### 2.4 基于注意力机制的 sequence-to-sequence 泊位占有率预测算法

泊位占有率预测过程如图 4 所示。首先，获取目标停车场历史停车数据信息；然后，对数据进行清洗及预处理，对基于注意力机制的 sequence-to-sequence 泊位预测模型进行训练；最后，将训练好的预测模型




图 4 泊位占有率预测过程

进行泊位预测。基于注意力机制的 sequence-to-sequence 泊位占有率预测算法流程如图 5 所示。

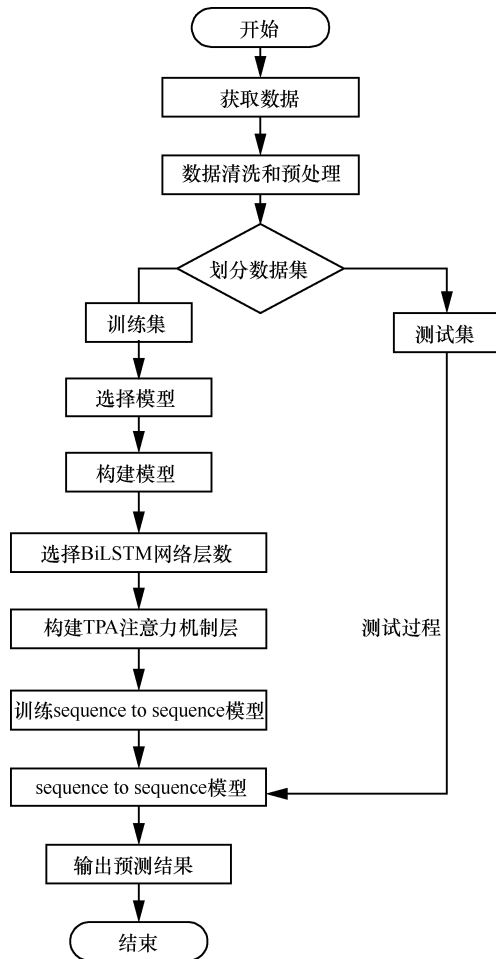


图 5 基于注意力机制的 sequence-to-sequence 泊位占有率预测算法流程

基于注意力机制的 sequence-to-sequence 泊位占有率预测算法如算法 1 所示。

**算法 1** 基于注意力机制的 sequence-to-sequence 泊位占有率预测算法

- 1) 输入原始数据;
- 2) 对数据进行清洗及预处理, 包括缺失数据填充、剔除无用数据、数据标准化和归一化;
- 3) 进行特征相关性计算和检验;
- 4) 划分训练集和测试集;
- 5) 建立基于 sequence-to-sequence 泊位预测模型结构;
- 6) 构建 TPA 机制层;
- 7) 用训练集训练基于注意力机制的 sequence-to-sequence 泊位预测模型及结构参数, 得到训练好的预测模型;
- 8) 通过将测试集输入训练好的预测模型得到

预测结果。

### 2.5 时间序列预测的评价指标

本文采用均方根误差 (RMSE, root mean squared error) 和平均绝对误差 (MAE, mean absolute error) 对所建模型的预测结果进行度量。RMSE 和 MAE 计算式如式(21)和式(22)所示。

$$RMSE = \left( \frac{\sum_{i=1}^n d_i^2}{n} \right)^{\frac{1}{2}} \quad (21)$$

$$MAE(x_i, \hat{x}_i) = \frac{1}{n} \sum_{i=1}^n |\hat{x}_i - x_i| \quad (22)$$

其中,  $n$  表示样本数,  $d_i$  表示一组测量值与真实值的偏差,  $x_i$  表示真实值,  $\hat{x}_i$  表示预测值。

MAE 范围为 $[0, +\infty)$ , 当预测值与真实值完全吻合时 MAE=0, 为完美模型, 误差越大, MAE 越大。RMSE 描述所有预测结果的偏离程度, 而 MAE 在对预测结果进行评价时, 可克服误差相互抵消的问题, 因此对于实际预测误差大小的反映更为准确。

## 3 实验分析

### 3.1 测试数据集

本文测试数据来自加州大学欧文分校 (UCI, University of California Irvine) 的停车场数据库 UCI, 该数据集包括伯明翰市某区域内 29 个停车场从 2016 年 10 月 4 号至 2016 年 12 月 19 号之间的 36 285 条数据。数据信息包含停车场 ID、停车时间、停车场的泊位数、已有车辆。本文使用数据集中包括 BHMBCCMKT01 在内的 28 个停车场的停车数据作为实验测试数据。

所提模型选取泊位入驻数、天气、节假日、工作日作为模型的 4 个特征。首先对数据集中数据缺失值进行临近均值填充, 然后对数据集进行归一化处理。对每个单个停车场数据集进行划分, 其中 80% 为训练集, 20% 为测试集。

本文测试分为两部分, 第一部分测试所提模型的结构, 并通过消融实验, 重点测试所提模型带有注意力机制和不带注意力机制的数据及对比分析; 第二部分测试所提模型对停车场数据的测试结果及对比分析。

### 3.2 所提模型结构确定

本文采用 sequence-to-sequence 编解码器结构

来预测泊位占有率,采用 BiLSTM 结构进行编解码操作,然后通过 BiLSTM 层数优化模型参数。最初实验的学习率设置为 0.01,衰减率设置为 0.5,隐含层节点的数量设置为 64,CNN 设置 4 个滤波器,卷积核大小为 $1 \times 18$ 。将数据集输入网络进行训练,测试编码器和解码器不同层数 BiLSTM 网络的 RMSE 变化情况。

本文分别对单层、双层、三层、四层及五层 BiLSTM 进行测试,并记录各自的 RMSE 变化过程。测试结果表明,当模型经过多次迭代 RMSE 趋于稳定时,采用单层、四层 BiLSTM 结构的训练 RMSE 较大,经过双层、三层及五层 BiLSTM 结构训练 RMSE 相对较小且三层为最小。因此,本文选择编码器解码器内部 BiLSTM 层数为 RMSE 最小的三层 BiLSTM。在深度学习中,模型通过训练从数据样本中学习所有样本的变化规律,容易导致过拟合或欠拟合。通过增加模型训练迭代的次数,可以克服模型拟合不足的现象。对于过拟合的处理,对神经单元以一定概率断开 dropout,dropout 通过概率断开神经网络之间的连接,减少每次训练时实际参与计算的模型的数量,从而减少了模型的实际容量,来防止过拟合。需要注意的是,在测试时,dropout 会恢复所有的连接,保证模型测试时具有更强的泛化特性,使预测结果具有更好的多样性。本文中 dropout 概率设置为 0.5。

### 3.3 泊位占有率模型确定与数据预测

以下实验将利用所提模型分别对单个停车场 BHMBCCMKT01 和总体 28 个停车场的泊位占有率进行仿真测试。

#### 3.3.1 单个停车场数据测试分析及对比实验

本节首先进行所提预测模型有注意力机制和无注意力机制在不同步长下对单个停车场数据执行预测的误差对比分析,然后给出不同预测模型对单个停车场数据的预测精度的对比。

当训练 sequence-to-sequence 模型时,使用迭代预测,并且通过选择模型的参数来获得实验结果。sequence-to-sequence 泊位预测模型参数如表 1 所示,输出步长为 36,编码器端 BiLSTM 隐含神经元的个数  $E\_hidden$  和解码器端 BiLSTM 隐含神经元个数  $D\_hidden$  均为 64,学习率 Learning\_rate 为 0.001,遗忘率 Drop\_rate 为 0.75,输入特征数 Input\_dim 为 4,迭代次数 Epoch 为 1 000,输入数据长度 Time\_step 为 18。

表 1 sequence-to-sequence 泊位预测模型参数

参数	参数值
训练集数据量/个	1 302
迭代次数/次	1 000
学习率	0.001
隐含层节点数/个	64
输入数据长度	18
测试集数据量/个	326
输出步长	36
遗忘率	0.75
输入特征数/个	4

表 2 为所提模型有注意力机制和无注意力机制对数据集 BHMBCCMKT01 的预测值与真实值对比,图 6 和图 7 为相应预测值与真实值对比曲线。图 8 为所提模型有注意力机制和无注意力机制下泊位预测 MAE 随步长变化的曲线。

由表 2 数据可知,有注意力机制的预测数据平均误差为 6.75,无注意力机制的预测数据平均误差为 17.75。对比图 6 和图 7 可以看出,注意力机制在所提模型中具有重要作用。从图 8 可以看出,所提模型无注意力机制时,其 MAE 随步长的增加上升较快;而有注意力机制时,其 MAE 随步长的增加上升较慢。

当利用所提预测模型预测未来 36 个目标步长的停车场泊位占有率时,其对应的真实值为 194,而预测值为 178,其误差为 16,预测结果可以满足实际预测精度要求。综上分析可知,所提模型在步长取较大值时预测结果的误差相对稳定,模型可达到较好的预测效果。

#### 3.3.2 多个停车场数据测试分析

使用 28 个停车场作为实验数据,并对每一个停车场数据集按 4:1 进行数据划分,然后进行模型训练和测试。使用基于注意力机制的 sequence-to-sequence 预测模型同 LSTM 预测模型进行对比分析。表 3 为泊位占有率预测最小 MAE,显示了 sequence-to-sequence 泊位占有率预测模型以及 LSTM 泊位预测模型在数据集上的总体效果。LSTM 预测模型的预测步长为 10,sequence-to-sequence 预测步长为 36,从表 3 中可以看出,sequence-to-sequence 泊位预测模型在 28 个停车场的数据集测试中,有 23 个预测结果的 MAE 小于或等于 LSTM 泊位预测模型。sequence-to-sequence 泊位预测模型 MAE 的中位数

表 2 所提模型有注意力机制与无注意力机制的预测值与真实值对比 (步长=36)

预测步	真实值/个	有注意力机制预测值/个	误差/个	无注意力机制预测值/个	误差/个
1	181	172	9	95	86
2	197	192	5	171	26
3	196	200	4	172	24
4	200	197	3	172	28
5	203	198	5	172	31
6	196	197	1	173	23
7	186	182	4	172	14
8	175	167	8	169	6
9	149	155	6	164	15
10	131	129	2	134	3
11	105	123	18	109	4
12	11	22	11	90	79
13	14	21	7	15	1
14	26	21	5	16	10
15	39	39	0	34	5
16	63	65	2	54	9
17	87	85	2	83	4
18	113	119	6	105	8
19	126	128	2	132	6
20	148	143	5	136	12
21	161	167	6	154	7
22	172	170	2	161	11
23	177	178	1	166	11
24	170	171	1	166	4
25	165	162	3	160	5
26	149	145	4	155	6
27	142	128	14	135	7
28	106	127	21	125	19
29	95	86	9	90	5
30	11	39	28	82	71
31	11	22	11	15	4
32	22	18	4	13	9
33	39	35	4	28	11
34	83	74	9	58	25
35	120	115	5	120	0
36	194	178	16	144	50
平均	—	—	6.75	—	17.75




图 6 sequence-to-sequence 有注意力机制模型预测值与真实值对比曲线




图 7 sequence-to-sequence 无注意力机制模型预测值与真实值对比曲线




图 8 所提模型有注意力机制和无注意力机制 MAE 随步长变化的曲线

表 3 泊位占有率预测的最小 MAE 对比数据

停车场	LSTM (步长=10)	sequence to sequence (步长=36)
BHMBCCMKT01	0.008 6	<b>0.010</b>
BHMBCCPST01	0.024	<b>0.021</b>
BHMBCCSNH01	0.037	<b>0.035</b>
BHMBCCTHL01	0.028	0.030
BHMBRCBRG01	0.033	0.036
BHMBRCBRG02	0.078	<b>0.059</b>
BHMBRCBRG03	0.033	<b>0.029</b>
BHMEURBRD01	0.025	<b>0.021</b>
BHMEURBRD02	0.012	<b>0.012</b>
BHMMBMMBX01	0.030	<b>0.027</b>
BHMNCPHST01	0.044	<b>0.040</b>
BHMNCPLDH01	0.022	<b>0.015</b>
BHMNCPNHS01	0.019	<b>0.012</b>
BHMNCPNST01	0.015	0.016
BHMNCPPLS01	0.019	<b>0.017</b>
BHMNCPRAN01	0.018	0.019
Broad Street	0.021	<b>0.015</b>
Bull Ring	0.035	<b>0.035</b>
NIA Car Parks	0.015	<b>0.013</b>
NIA South	0.014	<b>0.011</b>
Others-CCCP105a	0.032	<b>0.027</b>
Others-CCCP119a	0.018	<b>0.016</b>
Others-CCCP133	0.015	<b>0.013</b>
Others-CCCP135a	0.049	<b>0.040</b>
Others-CCCP202	0.041	<b>0.034</b>
Others-CCCP8	0.035	<b>0.029</b>
Others-CCCP98	0.021	<b>0.021</b>
Shopping	0.028	0.029
中位数 (median)	0.025	<b>0.021</b>
平均值 (mean)	0.028	<b>0.024</b>
最大值 (max)	0.078	<b>0.059</b>
最小值 (min)	0.008 6	0.010
标准偏差 (std)	0.015	<b>0.011</b>

(median) 为 0.021, LSTM 泊位预测模型 MAE 的中位数为 0.025。sequence-to-sequence 泊位预测模型 MAE 的平均值 (mean) 为 0.024, LSTM 泊位预测模型 MAE 的平均值 (mean) 为 0.028。sequence-to-sequence 泊位预测模型 MAE 的最大值 (max) 为 0.059, LSTM 预测模型 MAE 的最大值 (max) 为 0.078。sequence-to-sequence 预测模型 MAE 最小值 (min) 为 0.010, LSTM 泊位预测模型最小值 (min) 为 0.008 6。从整体来看, sequence-to-sequence 泊位预测模型预测结果 MAE 的中位数、平均值、最大值均优于 LSTM 泊位预测模型。

如图 9 所示, sequence-to-sequence 泊位预测模型预测结果的 MAE 更为集中且相对更小。因此, sequence-to-sequence 泊位预测模型预测精度整体优于 LSTM 泊位预测模型且更为稳定。

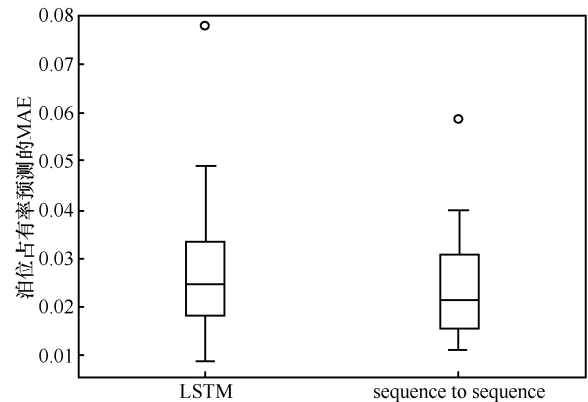


图 9 sequence to sequence 模型与 LSTM 模型 MAE 箱线图分布

综上所述, 基于注意力机制的 sequence-to-sequence 泊位预测模型在泊位预测中, 在增加了预测步长的前提下预测精度和稳定性均有提升。

#### 4 结束语

本文以泊位占有率的预测作为研究对象, 提出了一种基于注意力机制的 sequence-to-sequence 模型对泊位占有率问题进行求解, 为了提高泊位占有率的预测精度, 在模型中将天气、工作日、节假日等特征作为泊位占有率的融合特征, 使模型的泛化能力更强, 精度更高。在本文的预测模型中, 利用时间模式注意力机制捕获数据的局部特征, 利用 sequence-to-sequence 模型多输入多输出的特性, 使模型的拟合能力更强。通过对模型的训练和参数调整, 对测试集进行测试, 使用 RMSE 和 MAE 对模型预测结果进行评估, 结果表明, 所提模型表现出

更好的预测效果。将所提模型与 LSTM 模型的泊位占有率预测算法得到的预测数据进行比较, 验证了所提模型和方法的有效性。在未来工作中, 将对存在奇异点和噪声数据集的处理进行研究, 并考虑泊位占有率的空间特征关联信息, 设计处理更为复杂情形的预测模型, 致力于模型的理论分析和可解释性, 进一步提高预测精度, 并推广预测模型的应用前景。

### 参考文献:

- [1] ZHANG J, WANG F Y, WANG K, et al. Data-driven intelligent transportation systems: a survey[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2011, 12(4): 1624-1639.
- [2] DONALD C S. Cruising for parking[J]. *University of California Transportation Center Working Papers*, 2007, 13(6): 479-486.
- [3] AYALA D, WOLFSON O, XU B, et al. Pricing of parking for congestion reduction[C]//*Proceedings of the 20th International Conference on Advances in Geographic Information Systems*. New York: ACM Press, 2012: 43-51.
- [4] ARORA N, COOK J, KUMAR R, et al. Hard to park? Estimating parking difficulty at scale[C]//*Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM Press, 2019: 2296-2304.
- [5] RONG Y, XU Z, YAN R, et al. Du-parking: spatio-temporal big data tells you realtime parking availability[C]//*Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM Press, 2018: 646-654.
- [6] AN D. Method and system for projecting dynamic parking availability based on an ongoing survey for remote lots with high demand: US7049979[P]. (2006-05-23)[2020-07-07].
- [7] CALISKAN M, BARTHELS A, SCHEUERMANN B, et al. Predicting parking lot occupancy in vehicular ad hoc networks[C]//*2007 IEEE 65th Vehicular Technology Conference-VTC2007-Spring*. Piscataway: IEEE Press, 2007: 277-281.
- [8] CHEN B, PINELLI F, SINN M, et al. Uncertainty in urban mobility: predicting waiting times for shared bicycles and parking lots[C]//*16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)*. Piscataway: IEEE Press, 2013: 53-58.
- [9] RAJABIOUN T, FOSTER B, IOANNOU P. Intelligent parking assist[C]//*21st Mediterranean Conference on Control and Automation*. Piscataway: IEEE Press, 2013: 1156-1161.
- [10] KLAPPENECKER A, LEE H, WELCH J L. Finding available parking spaces made easy[J]. *Ad Hoc Networks*, 2014, 12: 243-249.
- [11] RICHTER F, DI M S, MATTFELD D C. Temporal and spatial clustering for a parking prediction service[C]//*2014 IEEE 26th International Conference on Tools with Artificial Intelligence*. Piscataway: IEEE Press, 2014: 278-282.
- [12] 杨兆升, 陈晓冬. 智能化停车诱导系统有效停车泊位数据的预测技术研究[J]. *交通运输系统工程与信息*, 2003, 3(4): 12-15.  
YANG Z S, CHEN X D. Research on the estimation for effective parking space of the intelligentized parking guidance system[J]. *Journal of Transportation System Engineering and Information Technology*, 2003, 3(4): 12-15.
- [13] 陈群, 晏克非, 王仁涛, 等. 基于相空间重构及 Elman 网络的停车泊位数据预测[J]. *同济大学学报 (自然科学版)*, 2007, 35(5): 607-611.  
CHEN Q, YAN K F, WANG R T, et al. Parking space information prediction based on phrase construction and Elman neural network[J]. *Journal of Tongji University (Natural Science)*, 2007, 35(5): 607-611.
- [14] BLYTHE P, JI Y, GUO W, et al. Short-term forecasting of available parking space using wavelet neural network model[J]. *IET Intelligent Transport Systems*, 2015, 9(2): 202-209.
- [15] 季彦婕, 陈晓实, 王炜, 等. 基于小波变换和粒子群小波神经网络组合模型的有效停车泊位短时预测[J]. *吉林大学学报(工学版)*, 2016, 46(2): 399-405.  
JI Y J, CHEN X S, WANG W, et al. Short-term forecasting of parking space using particle swarm optimization-wavelet neural network model[J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2016, 46(2): 399-405.
- [16] 陈海鹏, 图晓航, 王玉, 等. 基于小波-ELM 神经网络的短期停车泊位预测[J]. *吉林大学学报(理学版)*, 2017, 55(2): 388-392.  
CHEN H P, TU X H, WANG Y, et al. Short-term parking space prediction based on wavelet -ELM neural networks[J]. *Journal of Jilin University(Science Edition)*, 2017, 55(2): 388-392.
- [17] 韩印, 郑喆, 赵靖, 等. 基于灰色—小波神经网络的有效泊位预测[J]. *交通运输系统工程与信息*, 2017, 17(5): 60-67.  
HAN Y, ZHENG Z, ZHAO J, et al. Forecasting of effective parking space based on grey-distributed wavelet neural network model[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2017, 17(5): 60-67.
- [18] GONG G J, AN X N, NAWARAJ K M, et al. Research on short-term load prediction based on seq2seq model[J]. *Energies*, 2019, 12(16): 3199(1-18).
- [19] RANGAPURAM S S, SEEGER M W, GASTHAUS J, et al. Deep state space models for time series forecasting[C]//*Advances in Neural Information Processing Systems*. Massachusetts: MIT Press, 2018: 7785-7794.
- [20] RAN X D, SHAN Z G, FANG Y F, et al. An LSTM-based method with attention mechanism for travel time prediction[J]. *Sensors*, 2019, 19(4): 1-22.
- [21] FAN C, ZHANG Y, PAN Y, et al. Multi-horizon time series forecasting with temporal attention learning[C]//*Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM Press, 2019: 2527-2535.
- [22] LAI G, CHANG W C, YANG Y, et al. Modeling long-and short-term temporal patterns with deep neural networks[C]//*The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval*. New York: ACM Press, 2018: 95-104.
- [23] SHIH S Y, SUN F K, LEE H. Temporal pattern attention for multivariate time series forecasting[J]. *Machine Learning*, 2019, 108(8-9): 1421-1441.
- [24] 范晓诗, 雷英杰, 路艳丽, 等. 基于 DTW 的长期直觉模糊时间序列预测模型[J]. *通信学报*, 2016, 37(8): 95-104.  
FAN X S, LEI Y J, LU Y L, et al. Long-term intuitionistic fuzzy time series forecasting model based on DTW[J]. *Journal on Communications*, 2016, 37(8): 95-104.
- [25] 王亚男, 雷英杰, 雷阳, 等. 高阶直觉模糊时间序列预测模型[J]. *通信学报*, 2016, 37(5): 115-124.

WANG Y N, LEI Y J, LEI Y, et al. High order intuitionistic fuzzy time series forecasting model[J]. Journal on Communications, 2016, 37(5): 115-124.

[26] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Advances in Neural Information Processing Systems. Massachusetts: MIT Press, 2017: 5998-6008.

[27] LI S, JIN X, XUAN Y, et al. Enhancing the locality and breaking the memory bottleneck of transformer on time series forecasting[C]//Advances in Neural Information Processing Systems. Massachusetts: MIT Press, 2019: 5244-5254.

[28] 李琳辉, 周彬, 连静, 等. 基于社会注意力机制的行人轨迹预测方法研究[J]. 通信学报, 2020, 41(6): 175-183.

LI L H, ZHOU B, LIAN J, et al. Research on pedestrian trajectory prediction method based on social attention mechanism[J]. Journal on Communications, 2020, 41(6): 175-183.

[29] 何坚, 朱喆, 王伟东, 等. 多维时空因果关系学习的停车泊位占用率预测技术[J]. 北京工业大学学报, 2020, 46(1): 17-23.

HE J, ZHU Z, WANG W D, et al. Saliency fusion of multispectral images with non-uniform texture and complex surface defects[J]. Journal of Beijing University of Technology, 2020, 46(1): 17-23.

[30] 梅振宇, 章伟. 基于复杂性测度的泊位占有率序列动力学分析[J]. 浙江大学学报(工学版), 2018, 52(4): 727-734, 743.

MEI Z Y, ZHANG W. Dynamic analysis of parking space occupancy series based on complexity measurement[J]. Journal of Zhejiang University(Engineering Science), 2018, 52(4): 727-734, 743.

[31] HUANG C G, HUANG H Z, LI Y F. A bidirectional LSTM prognostics method under multiple operational conditions[J]. IEEE Transactions on Industrial Electronics, 2019, 66(11): 8792-8802.

[32] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[33] GRAVES A. Supervised sequence labelling with recurrent neural networks[M]. Berlin: Springer, 2012.

#### [作者简介]



王竹荣 (1966- ), 男, 湖南衡阳人, 博士, 西安理工大学副教授、硕士生导师, 主要研究方向为智能计算、深度学习及优化应用等。




薛伟 (1993- ), 男, 陕西韩城人, 西安理工大学硕士生, 主要研究方向为深度学习与进化计算。




牛亚邦 (1993- ), 男, 山西吕梁人, 西安理工大学硕士生, 主要研究方向为深度学习。



崔颖安 (1975- ), 男, 陕西西安人, 博士, 西安理工大学讲师, 主要研究方向为社交媒体大数据抽样与大数据处理。



孙钦东 (1975- ), 男, 山东莒南人, 西安理工大学教授、博士生导师, 主要研究方向为智能信息处理、网络安全。



黑新宏 (1976- ), 男, 陕西延安人, 博士, 西安理工大学教授、博士生导师, 主要研究方向为智能系统与安全关键系统。