



# 基于神经网络与马尔可夫组合模型的视频流行度预测算法

马学森<sup>1</sup>, 陈树友<sup>1</sup>, 许向东<sup>2</sup>, 储昭坤<sup>1</sup>

(1. 合肥工业大学计算机与信息学院, 安徽 合肥 230601;

2. 中国电信股份有限公司研究院, 广东 广州 510630)

**摘要:** 为了提升用户体验, 降低运营商的成本, 将播放最多的视频内容提前放入用户侧缓存是业界的通用做法, 如何有效预测视频播放热度已经成为业界热点问题。针对传统预测算法非线性映射能力差、预测精度低及自适应性弱等缺点, 提出基于神经网络与马尔可夫组合模型的视频流行度预测算法 (Mar-BiLSTM), 该算法通过构建双向长短期记忆 (bi-directional long short-term memory, BiLSTM) 网络模型可以保留时间序列两个方向的信息依赖; 同时在避免引入外部变量导致模型复杂度增加的情况下, 利用马尔可夫性质进一步提高了模型的预测精度。实验结果表明, 与传统的时间序列和经典的神经网络算法相比, 所提算法提升了视频流行度预测的准确性、时效性, 并降低了计算量。

**关键词:** 流行度预测; 内容缓存; 双向长短期记忆网络; 马尔可夫

**中图分类号:** TP391

**文献标识码:** A

**doi:** 10.11959/j.issn.1000-0801.2021116

## Neural network and Markov based combination prediction algorithm of video popularity

MA Xuesen<sup>1</sup>, CHEN Shuyou<sup>1</sup>, XU Xiangdong<sup>2</sup>, CHU Zhaokun<sup>1</sup>

1. School of Computer and Information, Hefei University of Technology, Hefei 230601, China

2. Research Institute of China Telecom Co., Ltd., Guangzhou 510630, China

**Abstract:** Caching popular video into user-side in advance improves the user experience and reduces operator costs, which is a common practice in the industry. How to effectively predict the popularity of videos has become a hot issue in the industry. On account of the shortcomings of traditional prediction algorithms such as poor nonlinear mapping ability, low prediction accuracy and weak adaptability, a video popularity prediction algorithm based on a neural network and Markov combined model (Mar-BiLSTM) was proposed. Information dependencies were preserved by constructing bidirectional memory network model (bi-directional long short-term memory, BiLSTM), the prediction

收稿日期: 2020-12-24; 修回日期: 2021-06-12

**基金项目:** 国家重点研发计划项目 (No.2020YFC1512601); 广东省科技发展专项基金资助项目 (No.2017A010101001); 安徽省教育厅高等学校省级质量工程 (No.2019MOOC020); 中央高校基本科研业务费专项基金资助项目 (No.PA2019GDKPK0079)

**Foundation Items:** The National Key Research & Development Program of China (No.2020YFC1512601), Science and Technology Development Special Foundation of Guangdong Province (No.2017A010101001), Colleges & Universities Quality Engineering Project of Education Department of Anhui Province (No.2019MOOC020), Fundamental Research Funds for the Central Universities (No.PA2019GDKPK0079)

accuracy of the model was further improved by using Markov properties while avoiding the increase of the complexity of the model caused by the introduction of external variables. Experimental results show that compared with traditional time series and classic neural network algorithms, the proposed algorithm improves predicting accuracy, effectiveness and reduces the amount of calculation.

**Key words:** popularity prediction, content caching, BiLSTM network, Markov

## 1 引言

根据思科 2020 年的统计<sup>[1]</sup>, 视频流量占据了整个网络流量的 80%。在传统网络架构中, 用户的访问请求需要经过基站的接入、核心网的访问以及冗长的链路回传才能完成, 频繁的用户请求容易造成核心网络的拥塞<sup>[2]</sup>。将热点视频在边缘侧进行缓存, 一方面可以减少纵向流量, 另一方面还能降低时延, 提升用户体验<sup>[3]</sup>。

其中, 各类视频门户网站的电视剧播放量又占据了绝大部分的视频流量, 并且电视剧通常周期性地更新剧集。为了减少中心节点与边缘节点内容的反复迁移, 将未来一个星期内流行度较高的视频放入缓存更有价值, 因此对视频流行度进行准确的中长期预测成为急需解决的问题<sup>[4]</sup>。

传统的视频流行度预测模型大致分为两类: 一类是以线性回归与自回归模型为代表的时间序列预测模型, 参考文献[5-7]基于历史流行度构建回归预测模型, 此类模型虽然训练简单, 但非线性映射能力差, 很难捕捉流行度的动态变化, 并且无法保留时间序列上的信息依赖, 随着时间步长的增加会逐渐失去对数据的学习能力, 在中长期预测中表现不佳。另一类是基于特征提取与用户聚类的有监督学习方法来加强预测效果<sup>[8-9]</sup>, 此类方法在一定程度上提高了模型的预测精度, 但由于引入过多的外部变量, 导致模型复杂度较高, 极大地增加了模型的训练难度, 不适用于实际应用场景。随着深度学习理论不断发展, 具有较强学习能力的循环神经网络 (recurrent neural network, RNN) 和长短期记忆 (long short-term

memory, LSTM) 网络主要应用于模式识别、语音处理等方面<sup>[10]</sup>, 近年国内外学者也将其应用在船舶航迹、小区的负荷指标等预测领域<sup>[11-12]</sup>, 实验表明预测精度优于传统方法, 但是在视频流行度预测领域的应用有待进一步研究。

基于以上分析, 本文提出基于神经网络与马尔可夫组合模型的视频流行度预测算法, 利用 LSTM 结合双向 RNN 构建双向长短期记忆 (bi-directional long short-term memory, BiLSTM) 网络模型, 可以保留时间序列上两个方向的特征依赖; 并且考虑马尔可夫具有根据系统当前状态对系统未来状态进行预测的性质<sup>[13]</sup>, 利用 BiLSTM 网络训练时产生的误差信息建立马尔可夫修正模型, 在避免引入过多变量导致模型复杂度增加的情况下进一步提高了网络模型的预测精度。

## 2 基于神经网络与马尔可夫的预测模型

### 2.1 BiLSTM 网络模型的构建

回归模型本质上是对数据的线性拟合, 不容易捕捉非线性的波动趋势; 传统的 BP 神经网络虽然可以有效地解决非线性映射问题, 但在长时间序列训练过程中会出现梯度爆炸和梯度消失等问题。LSTM 通过引入控制门机制, 可以在一定程度上避免此类问题, 但 LSTM 的单向学习机制只能在一个方向上学习时间序列的数据特征。在视频流行度的预测中, 某个时间点视频流行度的预测值, 除了可由过去的数据进行推导计算, 未来时刻的数据也对当前时刻流行度的计算有影响, 因此本文在 LSTM 的基础之上融入双向 RNN 隐藏层构建 BiLSTM 网络模型。




图1 BiLSTM 网络模型

BiLSTM 网络模型如图 1 所示, BiLSTM 通过神经元之间的双向隐藏层来保存两个输入方向的信息, 可以有效学习流行度序列上两个方向的关系依赖, 增强了模型的学习能力; 同时通过多层神经网络的叠加结构实现了流行度序列深层次的特征挖掘, 有效提高了模型的预测效果。

## 2.2 BiLSTM 的马尔可夫修正

为了进一步提高模型的预测精度, 如果通过继续引入特征变量的方式, 新的变量会作为输入层的参数重新训练, 过多的变量会导致模型训练困难。基于上述考虑, 本文在不引入新的外部变量的情况下, 通过对网络模型的预测误差建立马尔可夫修正模型来进一步提高模型的预测精度, 如图 2 所示。




图2 马尔可夫修正模型

假定网络模型历史拟合值为  $\widetilde{\text{fitting}}$ , 视频流行度的真实值为  $\text{real}$ , 因此构造误差序列  $\text{error}$ , 进而根据  $\text{error}$  划分状态区间  $E_i = (Q_{i1}, Q_{i2}]$ ,  $i = 1, 2, \dots, N$ , 其中  $Q_{i1}$ 、 $Q_{i2}$  分别表示相对误差的上、下限,  $N$  为状态区间个数; 然后估算状态  $E_m$  转移到状态  $E_n$  的一步转移概率  $p_{mn}$ , 所有的一步状态转移概率构成一步转移矩阵  $\mathbf{P}^{(1)}$ ; 最后根据初始时刻状态空间  $P_0$ , 可以求得未来时刻  $\text{error}$  的概率分布, 如式 (1) 所示:

$$P_{t+1} = P_0[\mathbf{P}^{(1)}]^{t+1} \quad (1)$$

其中,  $P_{t+1}$  为  $t+1$  时刻  $\text{error}$  状态空间的概率分布, 基于等距原则, 进而求得误差修正值, 如式 (2) 所示:

$$P_{t+1} = \frac{Q_{i1} + Q_{i2}}{2} \quad (2)$$

因此, 本文视频流行度的预测模型可以定义为式 (3), 其中  $\text{predict}_i$  为网络模型的预测值,  $\text{middle}_i$  为求得的修正值, 最终视频流行度的求解可以转化为  $\text{Final}_i$  的求解:

$$\text{Final}_i = \text{predict}_i + \text{middle}_i \quad (3)$$

## 3 Mar-BiLSTM 算法设计与求解

### 3.1 视频流行度的预测问题描述

电视剧周期性地更新剧集, 其中内容热度可以体现当前剧集的受欢迎程度, 用序列  $\text{Popularity} = \{\text{popularity}_1, \text{popularity}_2, \dots, \text{popularity}_n\}$  描述电视剧当前时刻的流行度。其中内容热度  $\text{Popularity}$  由平台综合播放量以及互动因子等指标计算, 更加能够反映视频的流行度。研究指出, 电视剧的微博搜索指数和百度搜索指数与电视剧流行度具有很强的线性关系<sup>[14]</sup>, 因此分别构造微博指数序列  $\text{Index1} = \{\text{index1}_1, \text{index1}_2, \dots, \text{index1}_n\}$  和百度搜索指数序列  $\text{Index2} = \{\text{index2}_1, \text{index2}_2, \dots, \text{index2}_n\}$ ; 另外在新剧集更新当天的电视剧播放量会比平常有一个明显的增加, 因此利用 One-hot 编码构造序列  $\text{Flag} = \{\text{flag}_1, \text{flag}_2, \dots, \text{flag}_n\}$  标记该

变化, 其中  $\text{flag}_i$  代表星期一,  $\text{flag}_7$  代表星期日; 最后利用预测模型  $\varphi$  预测下一个时间单位的电视剧流行度, 如式 (4) 所示。

$$\text{popularity}_{T,k} = \varphi\{\text{Popularity}_{i,\dots,k-1}, \text{Index1}_{i,\dots,k-1}, \text{Index2}_{i,\dots,k-1}, \text{Flag}_{i,\dots,k-1}\} \quad (4)$$

问题定义: 在线电视剧  $T$ , 已经上线  $i$  天, 流行度记为  $\text{Popularity}$ , 特征序列为  $\text{Feature}$ , 预测目标为未来几天流行度的记录  $\{\text{popularity}_{i+1}, \text{popularity}_{i+2}, \dots, \text{popularity}_{i+n}\}$ 。

### 3.2 Mar-BiLSTM 流行度预测算法

基于第 2.2 节构建的马尔可夫修正的 BiLSTM 网络模型, 本文设计了 Mar-BiLSTM 算法来求解视频流行度预测问题, 算法框架如图 3 所示。

Mar-BiLSTM 算法大致可以分为 5 个步骤, 算法的详细流程如下。

**步骤 1** 基于 Scrapy 技术对电视剧的流行度进行特征分析, 得到 Index1、Index2、Flag 等特征序列。

**步骤 2** 获取电视剧从上线开始后 3 个星期的内容热度值  $\text{popularity}_i$ , 微博搜索指数值  $\text{index1}_i$ , 百度搜索指数  $\text{index2}_i$ ;  $\text{flag}_i$  表示当天是否为剧集更新日, 当  $\text{flag}_i = 1$  时表示当天有剧集更

新,  $\text{flag}_i = 0$  时表示当天没有剧集更新; 进而根据特征向量序列构建特征向量矩阵。

**步骤 3** 利用特征向量  $\text{Feature}$  进行模型训练, 取序列  $\text{Popularity}$  前两个星期的数据作为模型的训练数据, 最后一个星期的数据用于模型的检验; 同时将序列处理为适合监督学习的数据。

**步骤 4** 对序列进行差分处理, 以此减小数据波动对模型训练的影响; 同时采用 min-max 策略对原始数据进行归一化处理来消除量纲的差异, 其转换如式 (5) 所示:

$$X = \frac{x - \min}{\max - \min} \quad (5)$$

**步骤 5** 采用自适应估计方法计算每个参数的学习率; 同时为避免过拟合现象采用 dropout 机制来提高模型的泛化能力; 最后利用网络模型的预测误差建立马尔可夫修正模型, 根据式 (3) 得到修正后的流行度预测值  $\text{Final}_i$ 。

Mar-BiLSTM 算法实现的伪代码如算法 1 所示。

#### 算法 1 Mar-BiLSTM 算法

**输入** 训练集  $\text{Train\_set}$ , 测试集  $\text{Test\_set}$ , 属性 (特征序列)

**输出** 视频流行度预测值

**步骤 1** 进行特征分析, 得到特征序列:




图 3 Mar-BiLSTM 算法框架



Popularity = {popularity<sub>1</sub>, popularity<sub>2</sub>, ..., popularity<sub>k</sub>},  
k = 1, 2, ..., 21

Index1 = {index1<sub>1</sub>, index1<sub>2</sub>, ..., index1<sub>n</sub>}, n = 1, 2, ..., 14

Index2 = {index2<sub>1</sub>, index2<sub>2</sub>, ..., index2<sub>m</sub>}, 1, 2, ..., 14

Flag = {flag<sub>1</sub>, flag<sub>2</sub>, ..., flag<sub>s</sub>}, s = 1, 2, ..., 14

步骤 2 将各个时间序列进行整合得到输入时间序列:

concatSequence (i, i + 1, ..., t)

步骤 3 将时间序列数据转化为有监督数据:

If I > n<sub>in</sub> and I < 0

input sequence (t - n, ..., t - 1)

Else if I > 0 and I < n<sub>out</sub>

forecast sequence (t, t + 1, ..., t + n)

步骤 4 max-min 特征变换:

Return (Train\_set)

Return (Test\_set)

步骤 5 Train\_set Train BiLSTM-Markov

Test\_set Test BiLSTM-Markov

Return (均方根误差、平均绝对误差)

Return (流行度预测值)

end

Mar-BiLSTM 算法时间复杂度可分为 5 个部分。

步骤 1 时间复杂度可以记为 O(|m|);

步骤 2 序列整合的时间复杂度为 O(|m|);

步骤 3 序列转化为有监督数据的时间复杂度为 O(|n||m|);

步骤 4 max-min 特征变换的时间复杂度为 O(|n||m|);

步骤 5 计算均方根误差及平均绝对误差的时间复杂度为 O(|n||m||i|); 因此, Mar-BiLSTM 算法的时间复杂度为 O(|n||m|)。

## 4 实验设计与分析

### 4.1 实验环境

实验环境为联想 Thinkpad E440 笔记本计算机, CPU 为 Intel® Core™ i5-4210 CPU @ 2.60 GHz,

内存为 8 GB, 操作系统为 Windows10 教育版, 使用基于 Python3.5 语言的 PyCharm 社区版集成开发工具构建神经网络模型, 利用 MATLAB R2018b 开发工具进行对比试验设计。

### 4.2 评价指标

实验采用预测模型常用的均方根误差 (root mean squared error, RMSE) 及平均绝对误差 (mean absolute error, MAE) 作为预测性能的评价标准<sup>[15]</sup>。RMSE 可以评价数据的变化情况, RMSE 值越小, 表示模型有更好的预测精确度, MAE 可以更好地反映预测值与真实值偏离程度的实际情况, 如式 (6)、式 (7) 所示。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2} \quad (6)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (7)$$

### 4.3 网络模型参数选择

隐藏层的层数以及神经元个数的选择对网络模型的性能影响很大, 因此需要选择训练误差最小的网络参数。不同 W 值下的 RMSE 值如图 4 所示, 在隐藏层数 W=2、隐藏层单元数 L=6 时的 RMSE 值最小, 过多的隐藏层或者单元数都会使得网络过于复杂而丧失网络优势。因此, 选择 W=2、L=6 作为网络模型的训练参数。




图 4 不同 W 值下的 RMSE 值

#### 4.4 实验设计及结果分析

实验爬取电视剧《爱情公寓5》自2020年1月12日上线到同年2月1日的全网数据（其中包括播放量、评论数、点赞数、收藏数、百度搜索指数与微博搜索指数等），使用前两个星期的数据训练模型、后一个星期的数据用来验证本文算法的优越性：首先选取回归模型中常用于时间序列预测的灰色预测（grey model, GM）与指数平滑（exponential smoothing, ES）验证算法的有效性，进而选取神经网络中常用于时间序列预测的传统BP神经网络和LSTM神经网络验证算法的优越性；最后通过爬取2021年1月至2021年3月期间的10部首播电视剧的数据对其排名进行预测，以此验证算法的普适性。

##### 4.4.1 LSTM与回归模型对比

本节设计LSTM与GM、ES之间的对比实验，以此来验证LSTM的预测精度优于传统回归模型。

GM、ES及LSTM模型的预测值对比如图5所示，由于流行度数据不符合幂指数规律，因此基于指数规律建模的GM没有很好地预测数据的波动规律；ES利用序列差分机制，可以预测很小的波动，但并不吻合真实数据的波动规律；LSTM基于RNN与门控单元机制可以学习长时间序列上的信息依赖，对未来数据的波动给出了大致的





图5 GM、ES及LSTM模型的预测值对比

预测，验证了LSTM的预测效果优于传统回归模型。


##### 4.4.2 BiLSTM与BP、LSTM模型对比

本节设计了LSTM网络与BP神经网络之间的对比试验，就其预测精度及其收敛性进行分析；在此基础上，引入BiLSTM进行对比实验，以此验证BiLSTM的优越性，为Mar-DBiLSTM组合预测理论模型提供实验数据支撑。

BP、LSTM模型训练误差如图6所示。BiLSTM、BP、及LSTM模型预测值对比如图7所示。从图6可以看出，LSTM较BP神经网络的收敛速度要快，在迭代次数为200次左右时，网络已经趋于收敛，此时BP神经网络的训练误差还处于较高水平；同时从图7可以看出，BP神经网络虽然能够预测数据大致的波动趋势，但LSTM的预测曲线更加贴合于真实值，因此LSTM不仅学习性能强于传统的神经网络，而且其预测效果也优于普通的BP神经网络；基于LSTM改进的



(a) BP神经网络



(b) LSTM网络

图6 BP、LSTM模型训练误差




图7 BiLSTM、BP及LSTM模型预测值对比

BiLSTM 可以学习时间序列上两个时间方向的信息依赖,因而能够更好地对数据的波动趋势进行学习,从图7也可以看出,BiLSTM较LSTM、BP均具有更高的预测精度,验证了本文BiLSTM模型预测效果的优越性。

#### 4.4.3 Mar-BiLSTM与BiLSTM模型对比

在前两轮实验的基础之上,为了验证Mar-BiLSTM算法的有效性,设计该对比实验。通过第2.2节的描述,对BiLSTM的预测误差构建马尔可夫修正模型,最终可以求得未来几天预测误差可能的状态区间,见表1。

表1 模型预测误差状态区间

| 时间   | 起始状态 | 转移步数 | E1    | E2    | E3    | E4    |
|------|------|------|-------|-------|-------|-------|
| 1.25 | E3   | 1    | 0.200 | 0     | 0.600 | 0.200 |
| 1.24 | E1   | 2    | 0.413 | 0.25  | 0.500 | 0     |
| 1.23 | E2   | 3    | 0.413 | 0.063 | 0.425 | 0.100 |
| 1.22 | E1   | 4    | 0.323 | 0.075 | 0.500 | 0.102 |
| 合计   |      |      | 1.348 | 0.388 | 2.025 | 0.402 |

由表1可知,26号最有可能的误差状态区间为E3,由式(2)计算得到误差修正值为22,BiLSTM模型的预测值为9096,根据式(3)得到修正后的预测值为9091。在对27号误差状态进行预测时,将26号误差预测值作为已知值,并将最原始的信息剔除,按照上述方法重复,可以计算出接下来6天的误差修正值。




图8 Mar-BiLSTM、BiLSTM模型预测值对比

由图8可知,经马尔可夫修正过的BiLSTM预测值要更加贴近真实值,预测效果更好,证明了本文算法的优越性。

综上,根据第4.2节提出的性能指标,给出对比预测模型的性能分析,见表2。

表2 性能对比

| 模型         | RMSE      | MAE       |
|------------|-----------|-----------|
| GM         | 246.436 7 | 216.732 5 |
| ES         | 449.256 5 | 374.285 7 |
| BP         | 210.362 5 | 196.382 4 |
| LSTM       | 187.346 9 | 157.714 3 |
| BiLSTM     | 178.386 0 | 148.712 4 |
| Mar-BiLSTM | 121.491 3 | 109.857 1 |

#### 4.4.4 电视剧排名预测

为了进一步验证算法的普适性,从全网爬取2021年1月至3月期间首播的10部不同种类的电视剧数据,并对其排名进行预测。由于电视剧并非在同一时间上线,其上线时间越长,累积播放量会越高;并且由于剧集数的不同,累计播放量也会有相应的影响。因此,为了更加准确地体现电视剧的真实排名,选择均集播放量和均天播放量的加权值作为衡量电视剧真实排名的依据,排名预测结果见表3。

从表3可以看出,排名靠前的《斗罗大陆》《锦心似玉》《爱的理想生活》等热播电视剧得到了准

表3 电视剧排名预测结果

| 电视剧名称   | 剧集数/集 | 均集播放量/次     | 上线天数/天 | 均天播放量/次      | 加权值/次       | 真实排名 | 预测排名 |
|---------|-------|-------------|--------|--------------|-------------|------|------|
| 斗罗大陆    | 40    | 119 000 000 | 50     | 95 200 000   | 214 200 000 | 1    | 2    |
| 锦心似玉    | 39    | 87 435 897  | 29     | 117 586 207  | 205 022 104 | 2    | 1    |
| 爱的理想生活  | 43    | 61 153 846  | 26     | 36 976 744   | 98 130 590  | 3    | 3    |
| 司藤      | 30    | 27 666 667  | 19     | 43 684 211   | 71 350 878  | 4    | 4    |
| 我的小确幸   | 28    | 46 071 429  | 73     | 17 671 233   | 63 742 662  | 5    | 6    |
| 我就是这般女子 | 40    | 33 750 000  | 68     | 19 852 941   | 53 602 941  | 6    | 5    |
| 玲珑      | 40    | 25 250 000  | 40     | 17 719 299   | 42 969 299  | 7    | 8    |
| 暴风眼     | 40    | 17 000 000  | 32     | 221 2500 000 | 38 250 000  | 8    | 7    |
| 你好，安怡   | 30    | 18 333 333  | 36     | 15 277 778   | 33 611 111  | 9    | 9    |
| 这个世界不看脸 | 45    | 11 555 556  | 75     | 69 333 33    | 18 488 889  | 10   | 10   |

确的预测，排名靠后的《你好，安怡》和《这个世界不看脸》等冷门电视剧也有较好的预测。因此，本文算法对不同类型电视剧的流行度均给出了不错的预测效果，证明了算法的普适性较高。

## 5 结束语

本文针对传统视频流行度预测算法非线性映射能力差，在中长期预测中存在精度低、自适应性弱等缺点，提出基于神经网络与马尔可夫组合模型的视频流行度预测算法。该算法在预测过程中兼具时间相关性和非线性特征，充分保留了时间序列上前向、后向两个方向的长期依赖信息；并利用 BiLSTM 网络训练时产生的预测误差建立马尔可夫修正模型，在避免引入过多变量导致模型复杂度增加的情况下进一步提高了模型的预测精度。下一步工作拟将 Mar-BiLSTM 算法引入边缘侧的缓存调度策略中，尝试建立根据视频流行度预测的缓存替换策略，提高用户的服务体验质量。

## 参考文献:

- [1] YAQOOB A, BI T, MUNTEAN G M. A survey on adaptive 360°video streaming: solutions, challenges and opportunities[J]. IEEE Communications Surveys & Tutorials, 2020, 22(4): 2801-2838.
- [2] 孔令义. 面向 5G 的网络优化和重构[J]. 电信科学, 2020, 36(2): 117-125.  
KONG L Y. Network optimization and reconstruction for 5G[J]. Telecommunications Science, 2020, 36(2): 117-125.
- [3] 孟令彬, 李娟, 薛楠, 等. 5G 边缘计算共享研究与展望[J]. 电信科学, 2020, 36(6): 38-44.  
MENG L B, LI J, XUE N, et al. Research and prospect of 5G edge computing sharing[J]. Telecommunications Science, 2020, 36(6): 38-44.
- [4] MALIK S U R. Moving toward 5G: significance, differences, and impact on quality of experience[J]. IEEE Consumer Electronics Magazine, 2020, 9(6): 9-14.
- [5] SZABO G, HUBERMAN B A. Predicting the popularity of online content[J]. Communications of the ACM, 2010, 53(8): 80-88.
- [6] TAN Z Y, WANG Y F, ZHANG Y, et al. A novel time series approach for predicting the long-term popularity of online videos[J]. IEEE Transactions on Broadcasting, 2016, 62(2): 436-445.
- [7] 陈春燕, 张钰, 常标, 等. 基于 ARMA 模型的在线电视剧流行度预测[J]. 计算机科学与探索, 2016, 10(3): 425-432.  
CHEN C Y, ZHANG Y, CHANG B, et al. Predicting popularity of online teleplays with ARMA models[J]. Journal of Frontiers of Computer Science and Technology, 2016, 10(3): 425-432.
- [8] SU Y T, LI Y, BAI X, et al. Predicting the popularity of micro-videos via a feature-discrimination transductive model[J]. Multimedia Systems, 2020, 26(5): 519-534.



- [9] HASSANPOUR M, HOSEINITABATABAEI S A, BARNAGHI P, et al. Improving the accuracy of the video popularity prediction models through user grouping and video popularity classification[J]. ACM Transactions on the Web, 2020, 14(1): 1-28.
- [10] SMAGULOVA K, JAMES A P. A survey on LSTM memristive neural network architectures and applications[J]. The European Physical Journal Special Topics, 2019, 228(10): 2313-2324.
- [11] 权波, 杨博辰, 胡可奇, 等. 基于 LSTM 的船舶航迹预测模型[J]. 计算机科学, 2018, 45(S2): 126-131.  
QUAN B, YANG B C, HU K Q, et al. Prediction model of ship trajectory based on LSTM[J]. Computer Science, 2018, 45(S2): 126-131.
- [12] 王睿怡, 邓寿提, 刘琳, 等. 基于 LSTM 算法的 LTE 小区级负荷指标预测研究[J]. 电信科学, 2020, 36(Z2): 1-8.  
WANG R Y, DENG S T, LIU L, et al. Research on LTE cell-level load index prediction based on LSTM algorithm[J]. Telecommunications Science, 2020, 36(Z2): 1-8.
- [13] SCAPINI V, ZUÑIGA E. A Markov chain approach to model reconstruction[J]. International Journal of Computational Methods and Experimental Measurements, 2020, 8(4): 316-325.
- [14] 徐晓枫, 贺樑, 杨静. 融合社交与搜索数据的电视剧点播排名预测研究[J]. 计算机工程, 2015, 41(8): 6-12, 17.  
XU X F, HE L, YANG J. Study of TV drama on demand ranking prediction fused with social and search data[J]. Computer Engineering, 2015, 41(8): 6-12, 17.
- [15] 曹婧, 沈华伟, 高金华, 等. 基于深度学习的流行度预测研究综述[J]. 中文信息学报, 2021, 35(2): 1-18, 32.  
CAO Q, SHEN H W, GAO J H, et al. Survey on deep learning based popularity prediction[J]. Journal of Chinese Information Processing, 2021, 35(2): 1-18, 32.

## [作者简介]



马学森 (1976- ), 男, 合肥工业大学计算机与信息学院副教授, 主要研究方向为移动边缘计算、无线网络。



陈树友 (1995- ), 男, 合肥工业大学计算机与信息学院硕士生, 主要研究方向为高可靠性分布式系统、移动边缘计算。



许向东 (1978- ), 男, 现就职于中国电信股份有限公司研究院, 主要研究方向为移动通信、5G 智慧应用、物联网应用、大数据及 AI 系统研发、网络运营技术等。



储昭坤 (1996- ), 男, 合肥工业大学计算机与信息学院硕士生, 主要研究方向为移动边缘计算、无线网络。