

控制与决策

Control and Decision

基于序列到序列结构的MOBA游戏局势趋势预测模型

李康维, 田佳, 曹啸博, 申德荣, 聂铁铮, 寇月

引用本文:

李康维, 田佳, 曹啸博, 申德荣, 聂铁铮, 寇月. 基于序列到序列结构的MOBA游戏局势趋势预测模型[J]. *控制与决策*, 2023, 38(4): 1137–1143.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.0903>

您可能感兴趣的其他文章

Articles you may be interested in

基于时间序列迁移递归预测的未知工况下滚动轴承在线剩余寿命评估

Online remaining useful life estimation of bearing under unknown working conditions based on time series transfer recursive prediction

控制与决策. 2023, 38(1): 112–122 <https://doi.org/10.13195/j.kzyjc.2021.1011>

基于深度卷积神经网络的刀具寿命动态预测研究

Research on dynamic prediction of tool life based on deep convolutional neural network

控制与决策. 2022, 37(8): 2119–2126 <https://doi.org/10.13195/j.kzyjc.2020.1530>

一种并行LSTM-FCN模型在船舶航迹预测中的应用

Parallel LSTM-FCN model applied to vessel trajectory prediction

控制与决策. 2022, 37(8): 1955–1961 <https://doi.org/10.13195/j.kzyjc.2020.1795>

一种基于深度学习的时间序列预测方法

A time series prediction method based on deep learning

控制与决策. 2021, 36(3): 645–652 <https://doi.org/10.13195/j.kzyjc.2019.0809>

基于深度时序特征迁移的轴承剩余寿命预测方法

Remaining useful life prediction of bearing based on deep temporal feature transfer

控制与决策. 2021, 36(7): 1699–1706 <https://doi.org/10.13195/j.kzyjc.2019.1809>

基于序列到序列结构的MOBA游戏局势趋势预测模型

李康维¹, 田佳², 曹啸博², 申德荣^{1†}, 聂铁铮¹, 寇月¹

(1. 东北大学 计算机科学与工程学院, 沈阳 110169; 2. 北京机电工程总体设计部, 北京 100039)

摘要: 多人在线战术竞技(MOBA)游戏是当前世界最流行的电子游戏类型之一, 该类游戏涉及的知识领域相当复杂. 随着电子竞技产业的飞速发展, 数据分析对MOBA游戏的影响也越来越大, 在对该类游戏的实时局势进行评价时, 一般是选择过程变量作为指标, 例如经济差、经验差, 但目前缺少趋势预测的相关研究. 针对该问题, 提出一种基于序列到序列结构的MOBA游戏趋势预测模型(MOBA-Trend). 在预处理阶段, 针对该类游戏数据的特点, 设计一种数据缩放算法体现数据间的重要度, 并使用低通滤波器消除数据噪声; 之后将双方阵容与历史战斗信息作为输入特征, 构建带有注意力机制的序列模型, 同时预测经济差、经验差; 最后将模型应用于Dota 2, 构建并发布相关数据集. 实验结果表明, 所提出的模型能够有效地预测序列的变化趋势.

关键词: MOBA 游戏; 时间序列预测; 序列到序列结构; 深度学习; 注意力机制

中图分类号: TP391 文献标志码: A

DOI: 10.13195/j.kzyjc.2021.0903

引用格式: 李康维, 田佳, 曹啸博, 等. 基于序列到序列结构的MOBA游戏局势趋势预测模型[J]. 控制与决策, 2023, 38(4): 1137-1143.

MOBA game trend prediction model based on sequence-to-sequence structure

LI Kang-wei¹, TIAN Jia², CAO Xiao-bo², SHEN De-rong^{1†}, NIE Tie-zheng¹, KOU Yue¹

(1. College of Computer Science and Engineering, Northeastern University, Shenyang 110169, China; 2. Beijing System Design Institute of the Electro-mechanic Engineering, Beijing 100039, China)

Abstract: Multiplayer online battle arena (MOBA) is currently one of the most popular genres of digital games around the world. With the development of E-sports, the impact of data analysis on MOBA games is increasing. The in-game variables like gold & experience are generally selected as indicators to evaluate the real-time game situations. However, there are few previous studies on forecasting game-evolving trends. To learn the trend information in time-series data, we propose a MOBA game trend prediction model based on the sequence-to-sequence structure, called MOBA-Trend. Firstly, we design a data scaling algorithm and use a low-pass filter to eliminate noise in the data. Then, the model takes both lineups and historical variable sequences as inputs. And the seq2seq structure with attention mechanism is used to forecast the future trends of gold & experience. Finally, we apply the model to Dota 2, one of the most popular MOBA games. Experiments on a large number of match replays show that the model can effectively forecast the evolving trends.

Keywords: MOBA game; time-series prediction; sequence-to-sequence; deep learning; attention mechanism

0 引言

多人在线战斗竞技(MOBA)游戏是即时战略游戏的子类型. 在该类游戏中玩家被分为两个队伍, 每个队伍一般有5名玩家, 每个玩家控制着一个独一无二的游戏角色, 胜利的目标是摧毁敌方基地的主要建筑. 在游戏过程中, 两队会周期性地派出由电脑控制的小兵协助进攻, 英雄可以通过击杀小兵、中立生物、敌方英雄和建筑获得经验和金币. 与其他竞技类游

戏相比, MOBA游戏除了考验玩家的操作外, 还需要考验团队成员间相互配合、玩家的战术策略等. 这种复杂的机制极大地提升了游戏性和观赏性, 从而吸引了大量的玩家. 随着电子竞技行业在近几年的蓬勃发展, MOBA游戏的大众关注度和认可度也达到了极高的水平, Dota 2便是其中最流行的游戏之一.

近些年电竞相关的产业链逐渐发展成熟, 目前数据分析已经应用于游戏和电竞赛事中, 例如Dota 2官

收稿日期: 2021-05-23; 录用日期: 2022-01-28.

基金项目: 国家自然科学基金项目(62072084, 62072086, 62172082); 国防基础科学研究计划项目(JCKY2018205C012); 中央高校基本科研业务费专项资金项目(N2116008).

†通讯作者. E-mail: shendr@mail.neu.edu.cn.

方推出了Plus助手,该服务通过大数据分析提供英雄选择建议、实时出装、实时胜率预测等功能.现有研究大都集中于特定时间点的预测,然而该方向仅能够为用户提供微量的信息;游戏趋势预测就是根据当前可观测到的信息预测未来局势的可能变化情况,从而辅助玩家制定相关战术,最大化己方的胜率.同时,趋势预测还能够为MOBA游戏其他方向研究提供支持,例如可作为强化学习中的奖励函数、阵容推荐模型中的评价指标等.在篮球等传统竞技类比赛中,能够从双方实时比分情况轻松判断当前的局势,但是像Dota 2这样的MOBA游戏取胜并不依赖于“比分”机制,而是需要摧毁敌方的主基地,在这个过程中局势通常通过多个过程变量体现,例如双方经济差、经验差等,因此在这种情况下评价和预测未来局势发展是十分困难的.

通过对游戏深入分析,将局势趋势抽象为时间序列,该序列包括双方的经济差、经验差两个变量,采用时间序列分析的思路解决趋势预测问题.但由于游戏数据具有复杂性、无规律、多变量、相关性等特点,现有方法不适用于处理该类数据.本文的主要贡献如下:

1) 提出MOBA-Trend,一种MOBA游戏趋势预测模型,将一局比赛中双方阵容、历史经济差、经验差、死亡数差、防御塔、补刀等战斗数据作为输入特征,构建带注意力机制的序列到序列(sequence-to-sequence, seq2seq)模型,能在任意时刻预测未来一段时间的经济差、经验差序列.

2) 从玩家角度对游戏数据进行分析,假设不同资源基数的情况下数据重要程度也不同,设计一种数据缩放算法以体现数据间的重要度,并使用低通滤波器消除噪声.

3) 构建并发布Dota 2职业联赛数据集,共包括30697场职业比赛数据,并采用该数据集开展一系列实验,从多个角度验证模型的有效性.

1 相关工作

MOBA游戏作为最受欢迎的电子游戏类型之一,目前在全球范围内已经累积了大量玩家,极大地带动了娱乐、直播、电商、社交等产业的发展.由于MOBA游戏的设计复杂,同时具有极高的人气,该类游戏中包含的领域知识具有重大研究价值,从而吸引了各类的前沿研究,本文主要介绍游戏预测的相关知识.

游戏预测指的是,根据一局游戏中的可观测信息,对实时或未来状态进行预测.已有研究集中于

在特定时间点的预测,即根据某时刻的可观测信息直接预测游戏的胜负,由于游戏结局只有输赢,该类研究把预测看作二分类问题.其中根据数据的选择不同,又可将胜负预测分为赛前预测和实时预测两类.赛前预测是指仅根据双方选择的阵容等信息,在比赛开始之前对胜负进行预测;实时预测是根据比赛中特征的实时变化情况,预测特定时间点的实时胜率.Wang等^[1]分别采用逻辑回归、随机森林、支持向量机模型直接预测比赛的胜负;Yu等^[2]设计了折扣评估函数作为相对优势评估的定量标准,用于替换传统的二分类标签,将预测问题转化为回归问题,并设计了独特的神经网络模型,该模型具有同时预测胜负和剩余游戏时间的功能.

先前研究都是直接预测游戏的胜负,而忽略了过程信息.在现实应用中,学习和预测未来演变的趋势显得更加重要.由于MOBA游戏中没有用来表示局势的变量,普遍的方法是用双方的经济差、经验差进行评价,然而目前缺少该方向的研究,可以借鉴时间序列预测的相关思路进行分析.

随着深度学习的广泛应用,神经网络逐渐成为时间序列预测的主流研究方法.Qin等^[3]针对多影响因素对单目标变量问题设计了一个双阶段注意力的循环神经网络,第1阶段的输入注意力层用于平衡多输入变量的权重,第2阶段的时序注意力层用于调整输入与时间步之间的权重;Lin等^[4]为了消除数据中的噪声,使用 L_1 趋势滤波器将时间序列抽象为 N 个线段,每段表示一个趋势,通过该方法可将时间序列转化为二元组表示——[斜率,持续时间],接下来使用LSTM从中学习序列的长期依赖,使用卷积神经网络学习短期依赖,将二者特征融合得到最终的输出,取得了显著的效果;Xu等^[5]拓展了Lin的工作,考虑到现实中多变量特征相互影响的问题,在原本模型架构上引入了多任务学习的思想,通过设计一个自适应共享记忆单元,使模型自动学习变量间的动态关联,从而实现了对复杂时间序列的预测.

上述模型均是针对数据特点^[6-7]进行建模,虽然在各自问题中均取得了优秀的成果,但这些模型不适合应用于MOBA游戏上.该类游戏数据同时具有复杂、无规律、多变量等特点,由于局势变化十分迅速,需要一个能够直接预测未来序列的模型,目前鲜有针对该数据的相关研究.本文通过深入分析已有工作,从游戏角度出发考虑局势的影响因子,提出MOBA-Trend,同时考虑历史战斗数据和阵容特征的影响,采用seq2seq^[8]结构建模,并使用注意力机制^[9-11]平衡

输入与输出间的权重,同时对经济差、经验差两个目标进行预测.

2 问题定义

MOBA类游戏中局势通常由团队经济和团队经验评价,造成该类特征变化的主要原因在于双方阵容的选择、历史战斗数据和玩家操作的水平.由于玩家操作具有较高的不确定性,难以对其进行量化评估,本文旨在从另外两个角度进行分析,从而预测未来趋势的发展.针对趋势预测问题进行如下定义.

定义1 将某一局比赛的阵容选择^[12]定义为 $L = h_1^i, h_2^i, \dots, h_{119}^i$. 其中: h_j^i 为单个英雄,表示英雄 j 被队伍 i 选择; j 的取值表示英雄编号; $i = 0, 1, 2$ 分别表示该英雄未被选择、被天辉方选择、被夜魔方选择.

定义2 将某一局比赛的历史战斗数据^[13]定义为 $S_d = \{(D_t, B_t, C_t, G_t, E_t)\}_T$. 其中: D_t 为死亡数差; B_t 为防御塔、兵营数差; C_t 为补刀、反补差; G_t 为经济差; E_t 为经验差; S_d 表示在时间点为 d 时,在此之前 T 长度时间窗口内的历史战斗数据.

定义3 局势趋势预测的目的是构建一个非线性函数 $F(\cdot)$, 在某一局比赛中,游戏时间为 d 时刻,根据当前阵容 L 和历史战斗数据 S_d , 预测未来 \hat{T} 时间窗口内经济差、经验差序列,即

$$\{(\hat{G}_t, \hat{E}_t)\}_{\hat{T}} = F(d, L, S_d; \theta). \quad (1)$$

其中: \hat{G}_t 为预测经济差, \hat{E}_t 为预测经验差, θ 为对应的网络参数.

3 游戏数据分析

3.1 数据准备

本文选择MOBA游戏中代表作之一的Dota 2开展实验. Dota 2在游戏过程中会生成回放文件来记录过程中所有的信息,使用OpenDota的api爬取2018年7月至2020年6月共30697场职业比赛的回放下载地址(<https://docs.opendota.com/>),下载后共占用1.48 T. 游戏时长的平均值为33.69 min, 标准差为10.93 min. 之后采用回放解析的方式从中提取结构化数据,使用开源的解析项目Clarity2(<https://github.com/skadistats/clarity>)从回放中提取时间片,采样的频率为每30 s/次,时间片包含的信息有:时间戳,双方的英雄选择、英雄属性、英雄装备、英雄数据、防御塔等. 目前数据集已经发布在Kaggle(<https://www.kaggle.com/peaxcd/dota2-dataset>)上. 处理得到某局比赛的经济差、经验差趋势如图1所示.

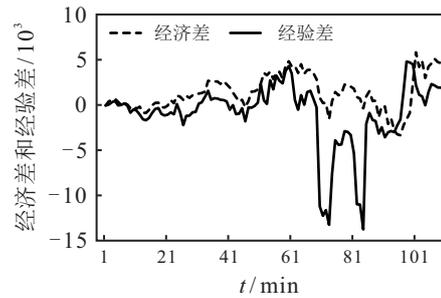


图1 某局比赛的经济差、经验差趋势

从图1中可以发现:经济差、经验差与传统的时间序列不同,没有显著的变化规律,同时二者还具有较强的相关性,这是因为趋势的拐点与团战、推塔、补刀等行为紧密关联,可以通过观测这些事件预测未来一段时间的趋势变化.此外,由于游戏中团战通常发生在数秒之内,远小于采样时间,导致原始序列具有较多的锯齿状波动,这些数据在短时间内频繁波动不利于模型的预测.

3.2 数据预处理策略

本问题的输入特征有两类,分别为阵容特征和历史战斗数据.采用离散编码将阵容特征嵌入为向量.截止至实验阶段Dota 2共有119个英雄,因此用0初始化一个119维的向量,每一位对应一个英雄,当天辉方选择某个英雄时,其对应位为1,当夜魔方选择某个英雄时,其对应位为-1,可得到比赛的阵容向量 L .

历史战斗数据由一个多元组序列构成,每个多元组包括死亡数差、补刀差、反补差、防御塔差、近战兵营差、远程兵营差、经济差、经验差.由于经济、经验数据同时作为模型的输入和待预测的目标,数据质量将直接影响预测结果,首先对全部时间片进行统计分析.如图2所示,其中 k 表示千.

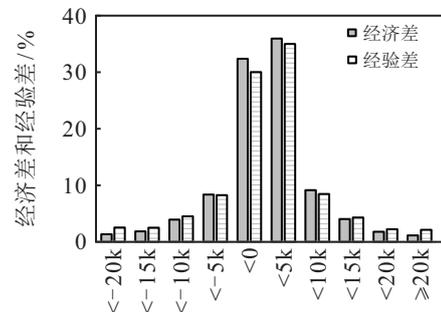


图2 经济差、经验差分布区间占比

从图2可以发现,绝大部分时间片的经济差、经验差绝对值在20k以内,大约占比97%和95%,通常而言,该数据表示游戏的某一方已经处于巨大优势,可以基本确定该局的胜利,因此将 $\pm 20k$ 设为阈值,将

所有的数据映射至 $[-20k, 20k]$ 之间. 此外, 根据游戏经验, 假设不同时间段的资源差距对局势的影响程度也不同, 例如在5 min时, 双方经济基数为1000和1500, 在20 min时, 双方经济基数为8000和8500, 虽然二者差值均为500, 但是在游戏前期, 微弱的经济优势可能“滚雪球”式帮助团队进一步扩大优势. 为此本文设计一种数据缩放算法, 具体流程如下:

$$z = \text{Diff} \frac{\max(R_r, R_d)}{\min(R_r, R_d)}, \quad (2)$$

$$X = \frac{Z - \text{TD}_{\min}}{\text{TD}_{\max} - \text{TD}_{\min}}. \quad (3)$$

其中: R_r 、 R_d 分别为时间片中天辉、夜魔的团队经济

或经验, Diff为二者的差值, TD_{\max} 和 TD_{\min} 分别为阈值. 式(2)考虑了双方资源基数的影响, 以提升前期资源基数较小时数据的重要程度; 式(3)则通过线性变化将 X 投影至 $[0, 1]$ 区间, 以便模型的预测.

最后为了消除原始数据中存在的噪声, 将时间序列抽象为数字信号, 采用低通滤波器对单场比赛数据进行处理. 该滤波器的特点为容许低于截止频率的信号通过, 可以将原始数据中锯齿图像平滑化, 最终得到序列特征 $\{(G_t, E_t)\}$.

4 MOBA-Trend

MOBA-Trend整体结构如图3所示.

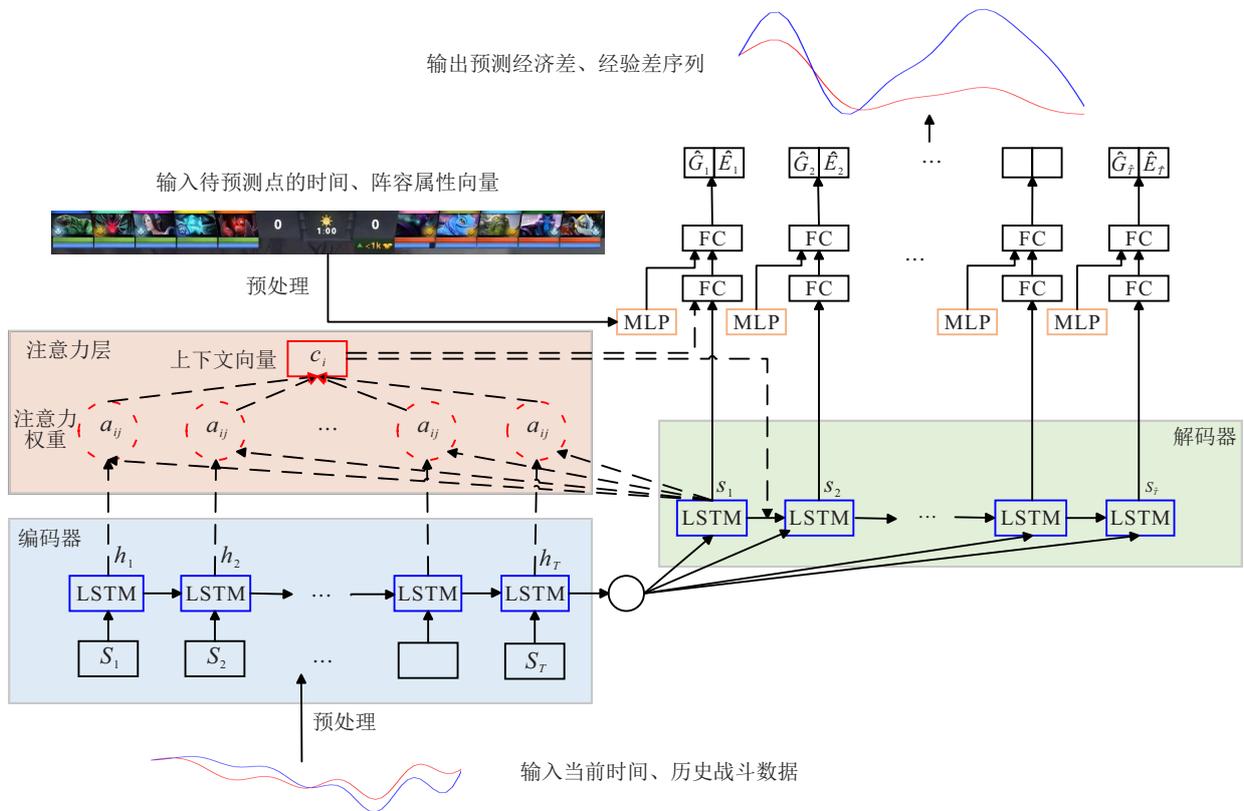


图3 MOBA-Trend整体结构

本文主要考虑两类不同的输入特征, 即阵容特征和历史战斗数据, 因此对应设计两个子模块, 分别是阵容模块和序列模块.

阵容模块使用多个多层感知器 (multilayer perceptron, MLP) 构建, MLP的个数与输出序列的长度 \hat{T} 一致, 每个MLP的输入为待预测时间和阵容嵌入向量, 结构上由 l 层全连接的神经网络构建, 每层网络的神经元个数为 n_i , 激活函数为relu, 可学习该阵容在特定时间戳的隐藏向量表示, 用特征向量 \hat{y}_L^t 表示游戏时间 t 的阵容嵌入向量, 具体如下:

$$\hat{y}_L^t = \text{MLP}(W \cdot [L \oplus t] + B). \quad (4)$$

其中: \oplus 为向量的横向拼接, W 为权重矩阵, B 为偏置值矩阵.

序列模块使用seq2seq结构构建, 编码器和解码器均由单向的LSTM组成. 其中: 编码器的输入是长度为 T 的多元组序列, 表示最近一段时间的战斗信息, 每个多元组包括当前时间、死亡数差、补刀差、防御塔差、经济差、经验差等信息, 经过编码器处理后可得到隐向量 (h_1, h_2, \dots, h_T) , 将最后一个位置的隐向量 h_T 作为解码器的输入; 解码器的长度为 \hat{T} , 对应输出序列的长度, 经过处理后可得到隐向量 $(s_1, s_2, \dots, s_{\hat{T}})$. 在此基础上, 添加注意力机制调节不同时间片

的重要程度,具体流程如下。

首先,计算解码器第*i*个位置对应的上下文向量,由编码器隐向量的加权平均值计算得到

$$c_i = \sum_{j=1}^T a_{ij} h_j. \quad (5)$$

每个 h_j 的权重 a_{ij} 可定义为

$$a_{ij} = \frac{\exp(e_{ij})}{\sum_{k=1}^T \exp(e_{ik})}. \quad (6)$$

其中: e_{ij} 为对齐模型,代表位置*j*的输入与位置*i*的输出匹配程度的分数,该分数通过解码器和编码器的隐向量计算,需要在训练过程中学习,即

$$e_{ij} = \text{score}(s_i, h_j). \quad (7)$$

然后,将上下文向量 c_i 与对应解码器的隐向量 s_i 拼接,作为解码器下一个位置隐向量的输入,可计算得到 s_{i+1} , θ 表示网络的参数,且有

$$s_{i+1} = \text{LSTM}([s_i \oplus c_i], h_T; \theta). \quad (8)$$

同时将拼接后的向量输入至序列模块的输出层,输出层是激活函数为Relu的全连接层,共有 n_j 个神经元,可得各个时间点的序列嵌入向量 \hat{y}_S^i , W_i 为对应权重矩阵, B_i 为偏置值矩阵,且有

$$\hat{y}_S^i = \text{Relu}(W_i \cdot [s_i \oplus c_i] + B_i). \quad (9)$$

最后,将阵容模块的输出向量 \hat{y}_L^i 与序列模块的输出向量 \hat{y}_S^i 相拼接,使用最终的输出层预测得到游戏时间*t*的经济差 \hat{G}_t 、经验差 \hat{E}_t ,具体如下:

$$\hat{G}_t = \text{Sigmoid}(W_g \cdot [\hat{y}_L^i \oplus \hat{y}_S^i] + B_g), \quad (10)$$

$$\hat{E}_t = \text{Sigmoid}(W_e \cdot [\hat{y}_L^i \oplus \hat{y}_S^i] + B_e). \quad (11)$$

其中: W_g 、 W_e 为权重矩阵, B_g 、 B_e 为偏置值矩阵.给定真实的序列 $\{(G_t, E_t)\}_{\hat{T}}$,模型的损失函数定义如下:

$$\text{Loss} = \frac{1}{\hat{T}} \left(\sum_{t=1}^{\hat{T}} |\hat{G}_t - G_t| + \sum_{t=1}^{\hat{T}} |\hat{E}_t - E_t| \right). \quad (12)$$

5 实验

在Dota2数据上开展一系列实验,数据集共包括30697场职业比赛,训练集、验证集、测试集的划分比例为6:2:2.将这些比赛按照发生时间顺序排序,并选择后20%作为测试集,训练集和验证集则按照随机采样的方式抽取。

在参数设置方面,模型输入、输出的序列长度 T 、 \hat{T} 均设为10,MLP的层数 $l = 5$,每层网络的神经元

个数 $n_i = 256$,编码器、解码器LSTM单元数为128,MLP和解码器输出层神经元个数均为64,最终模型输出层神经元个数为2,模型训练过程中使用Adam优化器,学习率为0.001.

由于目前没有针对MOBA趋势预测方向的研究,无法与其他论文数据进行对比,为了进一步验证本文方法的有效性,从模型与数据两个角度进行消融实验.本部分选择的对比模型包括LSTM、阵容模块、序列模块、moba-trend、MOBA-Trend_G、MOBA-Trend_E.其中:阵容模块主要测试模型的MLP部分,仅输入阵容特征进行预测;LSTM和序列模块仅输入历史战斗数据;moba-trend删除了注意力层;MOBA-Trend_G和MOBA-Trend_E分别是仅预测经济差序列和仅预测经验差序列的单任务模型.以上所有模型均使用相同参数构建和训练,评价指标使用经济差、经验差的平均绝对误差(mean absolute error, MAE),该值越小表示误差越低,模型的性能越优秀.实验结果如表1所示.

表1 不同模型的实验结果

| 模型名称 | MAE _G | MAE _E |
|-------------------------|---------------------|---------------------|
| 阵容模块 | 0.130 982 98 | 0.142 152 6 |
| LSTM | 0.046 677 20 | 0.066 017 74 |
| 序列模块 | 0.012 590 68 | 0.017 701 69 |
| moba-trend | 0.014 188 41 | 0.019 936 81 |
| MOBA-Trend _G | 0.014 487 26 | / |
| MOBA-Trend _E | / | 0.019 925 95 |
| MOBA-Trend | 0.011 690 87 | 0.016 778 12 |

从表1可以看出:本文提出的MOBA-Trend在两个预测任务中均达到了最优,验证了模型的有效性;在这些模型中阵容模块的效果最差,说明仅通过双方阵容难以得到对未来趋势的有效预测,游戏趋势还是更依赖于过程行为信息,例如团战、推塔、兵线推进等;通过对LSTM模型和序列模块的比较可以看出,seq2seq结构在处理时间序列数据时更具优势;moba-trend模型在去除了注意力层后性能略微降低,说明注意力机制可以为预测提供额外的信息,从而提升预测精度;最后两个单任务模型虽然均取得了不错的效果,但还是略低于本文模型,说明经济差、经验差的变化具有较强的相关性,多任务学习的方式则可以从中学到这种相关性,从而获取到更丰富的信息,帮助提升预测的准确率。

为了进一步探索预处理中数据缩放和滤波器对预测结果的影响,分别采用不同方法构建4个数据集,如表2所示。

表2 数据集属性

| 数据集名称 | 数据缩放 | 低通滤波器 |
|-----------|------|-------|
| Raw | × | × |
| Rescaled | ✓ | × |
| Filtered | × | ✓ |
| Processed | ✓ | ✓ |

在表2中:Raw数据集为对照组,不做任何的预处理;Rescaled数据集仅使用数据缩放算法;Filtered数据集仅使用低通滤波器;Processed数据集为完整预处理流程.之后使用MOBA-Trend分别对这4个数据集进行训练和测试,测试结果如表3所示.

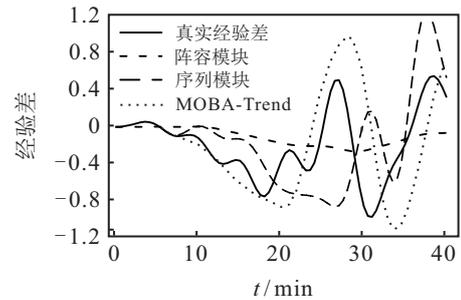
表3 不同数据集的实验结果

| 数据集名称 | MAE _G | MAE _E |
|-----------|---------------------|---------------------|
| Raw | 0.046 479 29 | 0.067 902 36 |
| Rescaled | 0.038 523 86 | 0.058 980 54 |
| Filtered | 0.012 134 33 | 0.017 349 97 |
| Processed | 0.011 690 87 | 0.016 778 12 |

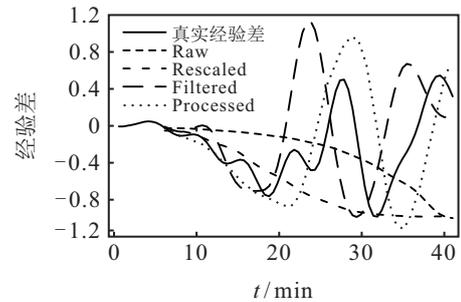
从表3可以看出:经过预处理后数据集的结果要优于原始数据,其中Rescaled数据集与对照组相比准确率略微提升,验证了之前的假设,即相同经济差、经验差在不同资源基数的情况下的重要程度也不同,而本文提出的数据缩放算法能够在一定程度上凸显这一重要性;Filtered数据集预测结果有较大的提升,说明滤波器可以从噪声数据中精准提取其潜在的趋势,能够较大幅度地提升数据质量;Processed数据集在两个预测任务中取得了最佳结果,进一步验证了本文使用的两步预处理流程的有效性.

在实际应用场景中,越早给出预测趋势,对局势的发展越有利,因此接下来仅输入前5min的可观测信息,采用循环预测的方式,首先预测得到第5~10min的经济差、经验差序列,然后将预测值输入至模型中,预测得到第10~15min的预测序列,重复上述流程可得整局比赛的预测趋势.由于模型的预测值仅有经济差、经验差,无法预知未来的击杀、补刀等信息,按照本文模型结构和参数额外训练了仅使用阵容、经济差、经验差的模型.图4展示了不同模型、数据预处理算法针对同一局比赛的经验差预测结果.需要注意的是,该预测方法存在误差传递的缺点,因此在预测过程中的误差会随着预测长度的增加而不断累积,从而使模型的预测结果难以完美拟合真实数据.

从图4(a)中可以看出:阵容模块的预测趋势变化较为平缓,且拥有较明确的变化方向,不会产生较大的波动,而序列模块则恰恰相反,预测趋势一般会伴



(a) 不同模型的经验差预测



(b) 不同数据集模型的经验差预测

图4 不同模型针对同一局比赛的经验差预测结果

有频繁的变化,且在游戏的中后期会有较大的波动趋势;MOBA-Trend吸取了上述二者的特点,在信息相对稀缺的情况下准确地预测到游戏在中期产生的波动.在图4(b)中:Raw数据未经过任何预处理,其预测数据在前期仅能产生小幅度变化,直至25min左右才产生了较为明确的预测趋势,且无法预测在过程中的波动;而Rescaled数据经过缩放后,前期数据重要性显著提升,预测图像在15min便产生了明确的演变趋势,但仍然无法预测游戏中期的波动;Filtered数据经过滤波算法消除噪声后,特征表示能力获得了显著的提升,能够灵活地预测潜在的拐点,但在拐点时间的预测上出现了部分误差;Processed数据准确预测到拐点的时间和波动幅度,体现了数据缩放和滤波算法在游戏数据中的有效性.

6 结论

本文提出了MOBA-Trend,一种基于seq2seq结构的MOBA游戏趋势预测模型.将双方阵容、历史经济差、经验差、击杀数差、防御建筑差、补刀差等信息作为模型的输入,预测未来一段时间的经济差、经验差序列,用于描述游戏局势的变化趋势.在数据预处理阶段,通过深入研究游戏数据的潜在特点,假设经济差、经验差数据在不同时间段,对未来趋势的影响程度也不同,并设计了一种数据缩放算法来体现资源基数对数据的重要程度,之后使用低通滤波器消除噪声,提取潜在的趋势信息,最后将该模型部署于Dota 2上,通过相关实验进一步验证了模型的有效性.

目前本研究还有几部分可以改进的方向: 1) 特征方面添加更细粒度的信息, 例如每个英雄的实时经济、击杀、推塔等. 因为在游戏过程中, 不同英雄对团队的重要程度也不同, 例如某些阵容存在核心英雄, 这些英雄需要获取大部分的团队资源, 并能够显著影响未来局势的变化, 可以添加额外的注意力层学习不同英雄的重要程度; 2) 提升模型的可解释性^[13-15]. 造成局势发生变化的因素有多种, 例如团战的失利、补刀被压制、阵容上的劣势等, 可以从可解释性的角度入手, 在预测的同时输出各因素的贡献程度, 以便更直观理解预测结果; 3) 经济差、经验差仅是局势的一种最直观的表现形式, 其影响因素还有双方阵容、装备选择等, 可以将局势进一步抽象为胜率, 用胜率变化曲线作为预测结果进行展示.

参考文献(References)

- [1] Wang N Z, Li L, Xiao L L, et al. Outcome prediction of DOTA2 using machine learning methods[C]. Proceedings of 2018 International Conference on Mathematics and Artificial Intelligence. New York, 2018: 61-67.
- [2] Yu L J, Zhang D W, Chen X Q, et al. MOBA-slice: A time slice based evaluation framework of relative advantage between teams in MOBA games[C]. Computer Games. Cham, 2019: 23-40.
- [3] Qin Y, Song D J, Chen H F, et al. A dual-stage attention-based recurrent neural network for time series prediction[J/OL]. 2017, arXiv: 1704.02971.
- [4] Lin T, Guo T, Aberer K. Hybrid neural networks for learning the trend in time series[C]. Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence. Melbourne: International Joint Conferences on Artificial Intelligence Organization, 2017: 2273-2279.
- [5] Xu D K, Cheng W, Zong B, et al. Tensorized LSTM with adaptive shared memory for learning trends in multivariate time series[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(2): 1395-1402.
- [6] Liu G, Mao Y Z, Sun Q, et al. Multi-scale two-way deep neural network for stock trend prediction[C]. Proceedings of the 29th International Joint Conference on Artificial Intelligence. Yokohama: International Joint Conferences on Artificial Intelligence Organization, 2020: 4555-4561.
- [7] Zhao J H, Zeng D L, Liang S, et al. Prediction model for stock price trend based on recurrent neural network[J]. Journal of Ambient Intelligence and Humanized Computing, 2021, 12(1): 745-753.
- [8] Wang J, Sun T, Liu B Y, et al. CLVSA: A convolutional LSTM based variational sequence-to-sequence model with attention for predicting trends of financial markets[J/OL]. 2021, arXiv: 2104.04041.
- [9] Zhou H Y, Zhang S H, Peng J Q, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[J/OL]. 2020, arXiv: 2012.07436.
- [10] Luong T, Pham H, Manning C D. Effective approaches to attention-based neural machine translation[J/OL]. 2015, arXiv: 1508.04025.
- [11] Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate[J/OL]. 2014, arXiv: 1409.0473.
- [12] Grutzik P, Higgins J, Tran L. Predicting outcomes of professional DotA 2 matches[R]. San Francisco: Stanford University, 2017.
- [13] Yang Z L, Pan Z F, Wang Y, et al. Interpretable real-time win prediction for honor of kings—a popular mobile MOBA esports[J/OL]. 2020, arXiv: 2008.06313.
- [14] Yang Y, Qin T, Lei Y H. Real-time esports match result prediction[J/OL]. 2016, arXiv: 1701.03162.
- [15] Assaf R, Schumann A. Explainable deep neural networks for multivariate time series predictions[C]. Proceedings of the 28th International Joint Conference on Artificial Intelligence. Macao: International Joint Conferences on Artificial Intelligence Organization, 2019: 6488-6490.

作者简介

李康维(1998—), 男, 硕士生, 从事大数据分析的研究, E-mail: 1572872924@qq.com;

田佳(1994—), 女, 工程师, 从事大数据技术、数据分析挖掘算法的研究, E-mail: tianjiachn@163.com;

曹啸博(1986—), 男, 高级工程师, 博士, 从事系统工程和大数据相关技术等研究, E-mail: caoxiaobo198610@163.com;

申德荣(1964—), 女, 教授, 博士生导师, 从事分布式数据管理、大数据集成、社交网络、知识图谱等研究, E-mail: shendr@mail.neu.edu.cn;

聂铁铮(1980—), 男, 副教授, 博士, 从事大数据管理、数据集成与融合、区块链等研究, E-mail: nietiezheng@mail.neu.edu.cn;

寇月(1980—), 女, 副教授, 博士, 从事社交网络分析与挖掘、个性化推荐、数据集成与融合等研究, E-mail: kouyue@mail.neu.edu.cn.

(责任编辑: 闫妍)