

牛程程,鲁大营,郑亚森.基于堆叠式长短期记忆网络的篮球运动员微动作评价方法[J].湖南科技大学学报(自然科学版), 2022,37(2): 95-103. doi:10.13582/j.cnki.1672-9102.2022.02.014

NIU C C, LU D Y, ZHENG Y M. Evaluation Method of Basketball Player Micro Motions Based on Stackable Long and Short Term Memory Network [J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2022,37(2): 95-103. doi:10.13582/j.cnki.1672-9102.2022.02.014

基于堆叠式长短期记忆网络的篮球运动员 微动作评价方法

牛程程¹,鲁大营^{2*},郑亚森³

(1.青岛黄海学院 通识教育学院,山东 青岛 266427;2.曲阜师范大学 软件学院,山东 济南 273165;
3.曲阜师范大学 体育科学学院,山东 济南 273165)

摘要:为了评估运动员微动作在持球回合中的贡献,提出一个端到端深度学习的评价方法.所提方法不需要复杂的特征提取(如状态间转换的定义和建模),而是将球员和篮球的原始轨迹作为输入,利用堆叠式长短期记忆(Long Short-Term Memory, LSTM)网络学习时空窗口的特征表示,通过一个额外的全连接层对场上球员的隐性空间表征进行级联处理.利用 Softmax 层对球员的终结动作(如投篮得分、失误、犯规等)的概率进行估计,每个终结动作均与一个预期分值关联,并用其估计预期得分.为了解决数据的不平衡性,对训练阶段使用参数化的下采样方案.实验结果表明:所提方法可以准确地估计回合结果的概率分布,对技术统计数据之外的微动作评价具有参考价值.

关键词:深度学习;长短期记忆网络;时空跟踪数据;篮球微动作;下采样

中图分类号:TP391 **文献标志码:**A **文章编号:**1672-9102(2022)02-0095-09

Evaluation Method of Basketball Player Micro Motions Based on Stackable Long and Short Term Memory Network

NIU Chengcheng¹, LU Daying², ZHENG Yamiao³

(1. School of General Education, Qingdao Huanghai University, Qingdao 266427, China;
2. School of Software, Qufu Normal University, Jinan 273165, China;
(3. School of Physical Education Science, Qufu Normal University, Jinan 273165, China)

Abstract: To evaluate the contribution of basketball micro motions in holding round, an evaluation method of end-to-end deep learning was proposed. The proposed method needn't complex feature extraction (such as the definition and modeling of transition between states), but took the original trajectory of players and basketball as input. The long short term memory (LSTM) network was used to learn the feature representation of spatiotemporal window, and the implicit spatial representation of players on the court was cascaded through an extra full connection layer. The Softmax layer was used to estimate the probability of a player's final actions (such as shooting, mistakes, fouls, etc.), and each finishing action was associated with an expected score, and the expected score was estimated by using it. In order to solve the imbalance of data, a parameterized down sampling

收稿日期:2020-06-07

基金项目:山东省高等学校科技计划项目资助(J15LN83);山东省社会科学规划研究项目资助(14CTYJ21)

*通信作者,E-mail: ludaying@126.com

scheme was used in the training phase. The experimental results show that the proposed method accurately estimate the probability distribution of turn results, and has reference value for micro motion evaluation beyond technical statistics.

Keywords: deep learning; LSTM network; time-space tracking data; basketball micro motions; down-sampling

近年来,CBA和NBA等大型篮球赛场均安装了光学跟踪系统^[1].光学跟踪系统可对球场上的球员位置和篮球位置进行每秒至少25次的信息采集,并利用其他信息(如当前得分、比赛计时器时间和当前回合计时器时间等)对这些数据进行进一步标注,从而可以更精确地进行数据分析.

目前,这方面的研究已取得了一些成果.如Franks等^[2]利用跟踪数据得到的空间信息来捕捉球员的防守能力,该方法结合了空间点过程、矩阵分解和分层回归模型,能够揭示无法用技术统计数据推导出的信息;高慧萍^[3]通过采集不同角度的篮球运动员的跳投动作图像,组建摄像机的投影矩阵,求得摄像机之间的外参数,并提出了改进KLT(Kanade-Lucas-Tomasi)特征点的篮球运动员跳投动作三维重构方法;Miller等^[4]利用非负矩阵分解,对球员投篮图的空间分布进行降维,以平滑原始的投篮图,提高数据展示的直观性和可读性;Papalexakis等^[5]利用张量分解法对Miller等^[4]提出的方法进行扩展,构建考虑上下文信息(如计时器秒数、分差等)的投篮概要;秦海玉等^[6]提出一种基于当前运动轨迹和赛场环境特征的跟踪检测方法,该方法基于当前轨迹和比赛环境特征训练随机决策森林;贺娇瑜^[7]对篮球比赛视频进行事件分类,基于深度学习实现球员的检测、分割和姿态估计,利用超像素的全卷积网络(Fully Convolution Network, FCN)分割算法滤除球员周围的复杂背景,通过长短期记忆(Long Short-Term Memory, LSTM)实现球员特征在时域的事件分析,从而对篮球事件进行分类,但复杂度较高;Yoon等^[8]为了实现对篮球的鲁棒控制,开发了一种基于轨迹优化和深度学习的控制方法,其生成的控制图使模拟玩家能够在这些技能之间进行转换,并响应用户的交互信息,是深度学习领域的有效应用;Liu等^[9]提出一个应用,在多个摄像机或移动设备捕捉竞技场活动的情况下,选择摄像机进行实时高质量的广播,并利用基于篮球能量图像的深层神经网络,将得分片段检测为亮点视频片段,但难以对篮球动作进行精确分类.

以上方法大多关注投篮和传球,对于构成投篮的微动作(包括掩护、传球或切入等)关注很少.这些微动作对于球队战术的成功与否至关重要,虽然传统的统计能得到这些动作数据,但由于缺少上下文信息,难以评估每个微动作的重要性.

为此,提出对篮球比赛微动作进行量化的端到端机器学习框架.利用深度神经网络^[10]估计预期得分值,其主要优势是不需要特征提取,而是将所有球员和篮球的原始轨迹作为输入,学习对于一个回合的终结动作来说最具预测性的特征.为了解决数据的不平衡性,针对训练阶段使用一种参数化的下采样方案.实验结果证明了所提方法的有效性.

1 时空数据的定义

首先将篮球场表示为一个三维坐标系空间,使用沿 xoy 平面的直角坐标来表示进攻球员和防守球员的赛场位置,通过第3个坐标来表示篮球的赛场位置和高度.在比赛中的每一秒,以均匀时间间隔每秒记录这些信息25次,标注特定时间和回合结果.利用该注释,可简单地将比赛分割为球队保持球权控制和试图得分的片段.此外,该数据还包含球场上特定球员以及计时器剩余秒数(控制着该回合的最大剩余长度)的相关信息.参数符号说明如表1所示.

1.1 持球回合

将一个持球回合 i 定义为由 n 个时刻组成的序列 $(\mathbf{x}_t^{(i)})_{t=1}^n$,其中,每个时刻为一个24维向量,即 $\mathbf{x}_t^{(i)} \in \mathbf{R}^{24}$.前20个元素通过 xoy 坐标系来捕捉10个球员的赛场位置,后3个元素通过 (x, y, z) 坐标来表示篮球的赛场位置和高度,最后1个元素表示计时器的当前数值.每个相关时刻均标注了事件描述,例如,在时刻 $(\mathbf{x}_\tau^{(i)})$ 中发生了一次传球.此外,每个持球回合 i 中,通过编码,保持赛场上的5个进攻球员 $\{\mathbf{s}_j^{(i)}\}_{j=1}^5$ 和5个防守球员 $\{\mathbf{s}_j^{(i)}\}_{j=6}^{10}$ 的相关信息.

表1 参数符号说明

符号	解释
ϵ_{π}	预期得分值
$\Delta \epsilon_{\pi}$	预期增加得分值
$\mathbf{x}_t^{(i)}$	捕捉时间 t 处球员和篮球位置的回合 i
$s^{(i)}$	回合 i 中的场上球员
$\mathbf{W}_{\tau}^{(i)}$	在时间 τ 结束的回合 i 内的时间序列窗口
T	时间窗口 \mathbf{W} 的长度
r	时间窗口 \mathbf{W} 结束处的盲区(缓冲区)
K	下采样参数
α	比赛中球员的微动作(传球、切入、掩护等)
e	使回合结束的终结动作(投篮尝试、失误等)
L	终结动作集合

1.2 时间窗口

为估计一个回合的预期得分,定义一个时间窗口作为框架的时空输入.即对于持球回合 i 和时刻 τ ,将长度为 T 的时间窗口定义为以下序列:

$$\mathbf{W}_{\tau}^{(i)} = (\mathbf{x}_t^{(i)}), \{\tau - (T + r) \leq t \leq \tau - r\}. \quad (1)$$

在时刻 τ 处定义的窗口,对感兴趣时间 τ 及缓冲区(或盲区) r 之前的一个持球回合的 T 个时刻进行捕捉,每个窗口将被指定一个结果标签 $y_{\tau}^{(i)}$, 对应一个回合终结动作.盲区用于窗口末端的剪枝信息,仅作为终结动作的象征,即动作定义(如对于刚完成的投篮,其篮球高度的数值较大).

此外,不使用从回合开始时的整个轨迹,将时间窗口限制为较小的窗口,在篮球背景下更为合理^[11].大部分战术的时长较短(通常小于 5 s),若未能成功执行(如找到无人防守投篮机会),则会重置进攻方案.因此,同一个持球回合中可能会出现多个战术,时间窗口将样本限制到给定时刻之前的有用信息.为此,本文将使用 $T=128$ (略大于 5 s)和 $r=16$ (略大于 0.5 s)这 2 个时刻,2 个时刻之间的时间距离等于数据采样率,即 0.04 s.

1.3 结果标签

如上文所述,使用结果 $y_{\tau}^{(i)}$ 标注每个窗口,该标签表示窗口结束时回合终结动作的类型.若回合终结动作(如投篮出手、失误等)发生在时刻 τ ,则以该动作标注 $\mathbf{W}_{\tau}^{(i)}$, 否则将其标注为空.终结动作集合 L 包含:

- 1) 投篮出手:窗口以投篮出手结束,无论是否得分.
- 2) 投篮犯规:窗口以投篮出手被犯规(非法防守动作)结束,被犯规的球员得到罚球机会.
- 3) 非投篮犯规:窗口以防守方球员被判罚非投篮犯规结束.
- 4) 失误:窗口以进攻方出现失误(如传球出界、被防守方抢断、进攻犯规等)结束,并将球权交给对手.
- 5) 空:在窗口结束时未记录下终结动作,因此,持球回合依然在继续.

加入空标签至关重要,一次进攻战术通常会在较短时间内执行,其后若有必要则重置进攻战术,因此,需对整个回合而非滑动窗口进行标注.例如,某个持球回合进攻方最初进行了一次无效的掩护,因此,必须重置进攻并执行另一个方案,进攻方得到了底角三分机会并命中得分.若该回合仅标注单个标签,那么无效掩护动作将被标注为能够增加数值的终结动作.而在使用本文的标注方案(滑动时间窗口)时,无效掩护所在的窗口将被标注为空,因为其并未导向直接的投篮/得分或失误.由于大部分窗口会以“空事件”来结束,在训练阶段需要考虑该数据的不平衡性,为此,需要对分类进行参数化的下采样.

2 基于堆叠 LSTM 的微动作评价方法

本节首先解释用于学习时空数据的深度特征表示以及估计预期得分的架构,然后给出解决训练数据高度不平衡的问题.

2.1 基本框架

本文方法的流程图如图1所示.所提方法主要分为2个模块:第1个模块为核心处理模块,使用堆叠式LSTM网络^[12]来学习时刻 τ 之前的时空窗口,该模块捕捉与场上动作(有球或无球动作)相关的重要信息;第2个模块用于捕捉场上球员的信息,对回合预期分值的影响进行建模,通过Softmax输出进行概率估计.

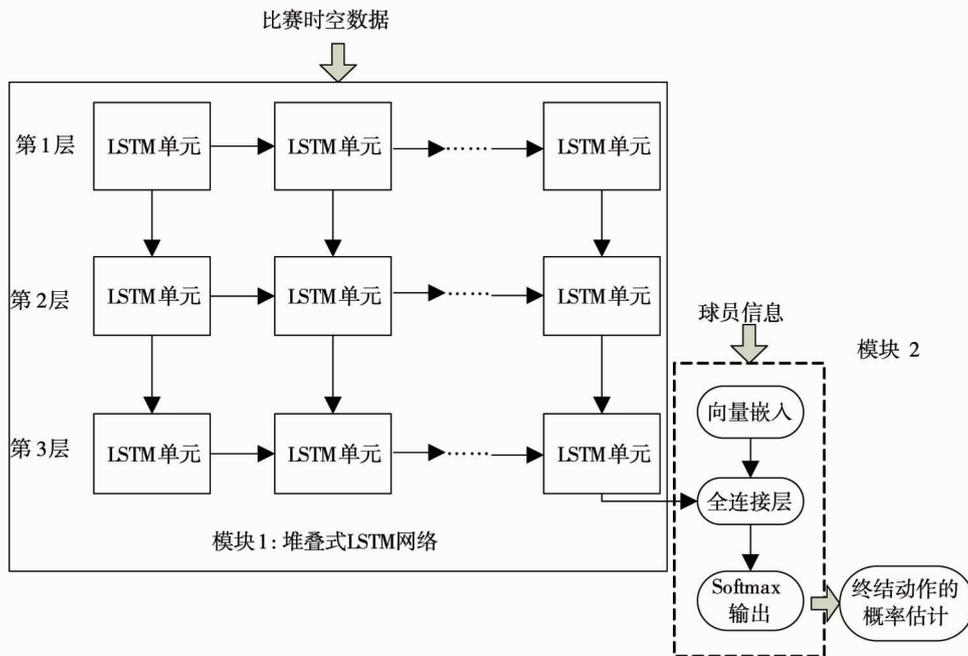


图1 本文方法的流程

2.2 将标签转换至每回合得分

给定一个持球回合 i ,定义在回合 i 内每个时刻 τ 计算出的预期分值为 $\epsilon_{\pi}^{(i)}(\tau)$,用其评估回合内的微动作的价值.

2.2.1 预期得分

每个回合均有一个基准预期得分值 β_{π} ,用所有比赛总得分除以总回合数来计算出每回合基准预期得分值.具体来说,定义函数 $v: \mathcal{L} \rightarrow \mathbf{R}$,将每个分类/终结动作映射到一个数值,代表成功完成该终结动作后将得到的超出预期(即超过 β_{π})之上的分值.例如,以投篮终结的回合的平均得分(每次投篮平均得分)为1.25,由此,以投篮尝试所终结的回合比基准分值超出 $1.25 - \beta_{\pi} = 1.25 - 1.02 = 0.23$,所以定义 $v = 0.23$.对于非投篮犯规,将防守方犯规(进攻方得到罚球)次数超限情况下的犯规部分合并在一起.

现在,可将回合 i 在时间 τ 的预期分值 $\epsilon_{\pi}^{(i)}(\tau)$ 定义为根据时间窗口 $\mathbf{W}_{\tau}^{(i)}$ 和场上球员所计算出的超出 β_{π} 的预期数值.具体来说,设 y 为窗口 $\mathbf{W}_{\tau}^{(i)}$ 输出的离散随机变量,且遵循概率分布 $P(y)$,则 $\epsilon_{\pi}^{(i)}(\tau)$ 可定义为

$$\epsilon_{\pi}^{(i)}(\tau) = \beta_{\pi} + E[v(y) | \mathbf{W}_{\tau}^{(i)}, \{s_j^{(i)}\}_{j=1}^{10}]. \tag{2}$$

2.2.2 增加的预期分值

定义 ϵ_{π} 的主要目的是向特定微动作 α 分配数值.直观上,在回合 i 的时间窗口 $\mathbf{W}_{\tau}^{(i)}$ 内纳入有价值的微动作将会改变结果的分布,且很可能会使新窗口的分值更高.形式上,若 α 在回合 i 的时刻 τ 发生,则增加的预期得分值可计算为

$$\Delta \epsilon_{\pi}(\alpha, \tau)^{(i)} = \epsilon_{\pi}^{(i)}(\tau + \epsilon) - \epsilon_{\pi}^{(i)}(\tau - \epsilon). \tag{3}$$

式中: ϵ 为某个时刻微动作的时移, $\epsilon > \tau$,以确保微动作 α 发生在新窗口 $\mathbf{W}_{\tau+\epsilon}^{(i)}$ 中.

基于上述讨论,计算预期分值和预期增加分值的问题可转换为对概率分布的估计 $P(y | \mathbf{W}_{\tau}^{(i)}, \{s_j^{(i)}\}_{j=1}^{10})$.利用Softmax函数对每个标签的概率进行建模,则标签 y_i 的概率估计可表示为

$$P(y | \mathbf{W}_\tau^{(i)}, \{\mathbf{s}_j^{(i)}\}_{j=1}^{10}) = \frac{e^{z_i}}{\sum_{y_j \in \mathcal{L}} e^{z_j}}. \quad (4)$$

使用从神经网络 g 习得的特征计算 z :

$$z = \mathbf{U}^T g(\mathbf{W}_\tau^{(i)}, \{\mathbf{s}_j^{(i)}\}_{j=1}^{10}; \Theta) + \mathbf{b}. \quad (5)$$

式中: \mathbf{U} 和 \mathbf{b} 对应于生成对数结果的线性层; Θ 为学习 $\mathbf{W}_\tau^{(i)}$ 和 $\{\mathbf{s}_j^{(i)}\}_{j=1}^{10}$ 的联合特征表示而优化的网络 g 的参数.

期望数据分布可表示为负对数似然最小化:

$$\min_{\mathbf{U}, \mathbf{b}, \Theta} -E \sum_{y_j \in \mathcal{L}} l\{y_j\} \log_2 P(y_j | \mathbf{W}_\tau^{(i)}, \{\mathbf{s}_j^{(i)}\}_{j=1}^{10}). \quad (6)$$

式中: l 为指标函数.

2.3 核心模块与不平衡问题的解决

2.3.1 堆叠 LSTM 网络

通常, LSTM 网络能够有效地处理序列输入的神经网络^[13]. LSTM 网络的每层均有一定数量的 LSTM 神经元(LSTM 网络分为 3 层, 每层 32 个神经元). LSTM 单元的计算情况如图 2 所示, 时间步 t 处第 i 个神经元的状态表示为向量 $\mathbf{h}^{(i)}$ 的第 i 个元素. 每个神经元的处理类似于 RNN 标准单位的数据, 即利用上一个状态信息和当前输入, 计算一个外部状态 $\mathbf{h}^{(i)}$, 但还存在一个额外内部状态 $c^{(i)}$ 以及一定数量的控制信息流. 对于给定一个窗口 $\mathbf{W}_\tau = (\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(T)})$, 所提框架使用了一个(深度)堆叠式 LSTM, 任何后续层都将 $\mathbf{x}^{(i)}$ 替换为其上一层的 $\mathbf{h}^{(i)}$. 由此, 堆叠 LSTM 网络将上一层的外部状态作为下一层的输入. 堆叠 LSTM 被限制为处理固定长度的序列(即长度为 T 的窗口), 因此, LSTM 网络的输出定义为最后一层的最终状态 $\mathbf{h}^{(T)}$, 然后将其与球员表征级联, 并由级联层进行处理.

2.3.2 球员表征

如前文所述, 在端到端架构内对个体球员嵌入向量进行联合学习. 球员通过向量来表示, 利用每个训练样本对向量进行更新. 这种更新取决于其在网络 g 的输出. 向量嵌入^[14]对一组 d 维向量 $\mathbf{a}^j \in \mathbf{R}^d$ 进行随机初始化, 以表征每个球员. 若形成张量 $\mathbf{A} = [\mathbf{a}^1, \dots, \mathbf{a}^m] \in \mathbf{R}^{d \times m}$, 则可使用第 j 个球员的编码 $\mathbf{s}_j^{(i)}$, 通过矩阵乘法 $\mathbf{A} \mathbf{s}_j^{(i)}$ 提取球员表征. 提取出的球员表征与 LSTM 的最后一层的最终状态 $\mathbf{h}^{(T)}$ 相级联, 并通过一个额外的级联层进行分类. 由此对球员表征进行联合学习, 每当一名球员出现在赛场上, 则在反向传播过程中对该球员的随机初始化向量进行更新, 以最小化分类任务的损失, 即式(6).

2.3.3 下采样方案

利用定义的网络 g 来解决空标签的不平衡性, 这些空标签在高度不平衡的数据上进行训练, 会影响校准概率, 对多数类进行下采样是处理数据高度分类不平衡的一种技术^[15]. 为了确保每个回合在新生成的训练集中有着平等的代表权, 本文提出一种下采样方法, 即对于回合 i , 均匀采样 K 个时间步 $\{t_{i,k}\}_{k=1}^K$, 其相应的窗口 $\mathbf{W}_{i,k}^{(i)}$ 被标注为空. 其后, 除了被标记为该回合的终结动作的窗口 $\mathbf{W}_\tau^{(i)}$ 之外, 将所有其他窗口均丢弃. 由此, 在训练阶段, 利用大小为 K 的下采样, 计算大小为 N 的回合批数据的损失率 ρ :

$$L_i = \sum_{y_j \in \mathcal{L}} l\{y_j\} \log_2 P(y_j | \mathbf{W}_\tau^{(i)}, \{\mathbf{s}_j^{(i)}\}_{j=1}^{10}); \quad (7)$$

$$L'_i = \sum_{k=1}^K \sum_{y_j \in \mathcal{L}} l\{y_j\} \log_2 P(y_j | \mathbf{W}_{i,k}^{(i)}, \{\mathbf{s}_j^{(i)}\}_{j=1}^{10}); \quad (8)$$

$$\rho = -\frac{1}{N(K+1)} \sum_{i=1}^N L_i + L'_i. \quad (9)$$

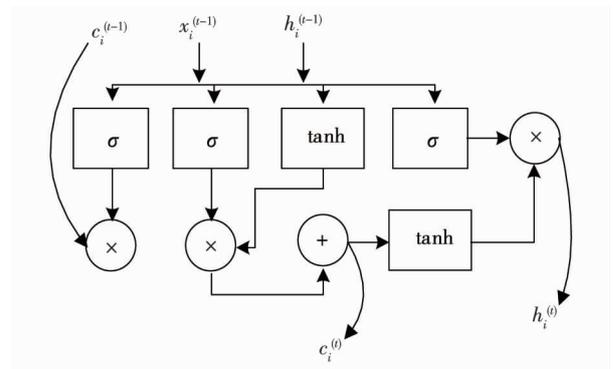


图 2 LSTM 单元的计算流程

式中: L_i 为标注损失; L'_i 为采样损失.

通过参数化 K , 在每代额外重新生成下采样数据集, 为每个回合重新提取样本 $\{t_{i,k}\}_{k=1}^K$.

3 实验与分析

实验的硬件平台是 Intel 酷睿 i5-4200U CPU@ 2.40 GHz, GPU Geforce GTX 1080 Ti, RAM 8.0 GB. 开发环境为 Python 3.5 语言的 PyCharm 集成开发工具, 使用 Keras 框架提供的 LSTM 模型.

3.1 实验参数设置与训练测试

训练集、验证集和测试集分别按照 75%, 10% 和 15% 分配数据. 监测度量为 Brier 得分, 要求 5 代中至少有 0.01 的改进. 所有实验中, 3 个 LSTM 层, 每层包含 32 个神经元; 1 个嵌入向量层, 维数 $d=8$; 1 个全连接层, 单元数为 128. 为防止网络过拟合和提高网络的泛化能力, 向全连接层输出应用 0.3 的 dropout 率^[16]. 通过 LSTM 网络应用 0.2 的变分 dropout 率^[17], 以用于输入状态和递归状态的转换.

LSTM 的训练一批一批进行, 每个样本包含从该样本往后连续 32 个(神经元个数)样本, 训练集上的 dropout 率设置为 0.5 较好(dropout 率的设置对训练时间没有差别, 但对损失和网络的准确性来说有较大差别, 很多研究表明, 训练集上的 dropout 率设置为 0.5 时最佳). 训练与测试时间如表 2 所示. 由于训练阶段的数量调整非常耗时, 可以适时终止训练, 即设置大量训练时段, 通过检验点检查模型在训练集和验证集上的性能来决定是否终止训练.

表 2 LSTM 网络的训练与测试时间

类别	耗时/min	损失	网络准确率/%
训练集	70.25	1.654	77.32
测试集	70.25	1.762	69.57

3.2 概率校准

本小节的目的是对可能持球回合的预测结果进行准确度评估, 因为这直接表明了预期分值的准确度. 概率校准的评估通过 Brier 得分和可靠性曲线来完成.

3.2.1 Brier 得分

Brier 得分是较为合理的得分规则, 对概率预测集合的校准进行量化^[18]. 若存在 M 个样本(即预测)和 R 个可能结果, 则 Brier 得分可计算为

$$\xi = \frac{1}{M} \sum_{i=1}^M \sum_{\vartheta=1}^R (f_{i,\vartheta} - o_{i,\vartheta})^2. \quad (10)$$

式中: $f_{i,\vartheta}$ 为样本 i 上的结果/标签 ϑ 的模型预测概率, 若样本 i 的标签为 r 则 $o_{i,\vartheta}$ 为 1, 否则 $o_{i,\vartheta}$ 为 0.

从上述定义可发现, 在 2 个模型中, Brier 得分较低的模型被校准得更好.

一般将模型的 Brier 得分与气象学模型进行比较, 其中, 气象学模型将每个结果指定为基线概率, 即每个结果的历史发生频率. 利用气象学模型的 Brier 得分 S_{ref} 计算出概率技术估计^[18] 即 Brier 技术评分 ζ , 计算公式为

$$\zeta = 1 - \frac{\xi}{S_{\text{ref}}}. \quad (11)$$

经过完美校准模型的 $\zeta=1$, 等价于 $\xi=0$. 若一个模型的技术未超过气象学模型, 则该模型的 ζ 将为 0, 因为 $\xi=S_{\text{ref}}$, 若 $\zeta < 0$, 则表示该模型的技术比参考模型还要低.

3.2.2 下采样率 K 值与 Brier 得分

本文方法与相应的气象学模型的 Brier 得分如表 3 所示, 表 3 给出了所提方法在使用下采样率(K 值)的 Brier 技术得分. 由表 3 可知: 无论 K 取何值, 所提方法的校准均较优. 此外, 通过比较 Brier 技术得分, 发现当 $K=2$ 时, 所提方法实现了相对于气象学模型的最大提升. 为此, 下文实验取 $K=2$.

表 3 所提方法与相应气象学模型的 Brier 得分

下采样率	所提方法 Brier 得分	气象学模型 Brier 得分	所提方法 Brier 技术得分
$K=1$	0.452	0.603	0.241
$K=2$	0.350	0.506	0.266
$K=3$	0.301	0.408	0.299
$K=4$	0.281	0.331	0.214
$K=5$	0.224	0.302	0.200

3.2.3 可靠性曲线

如果将一个回合中相同的窗口重放若干次,并估计其最终达到每种可能结果的次数,将是较为理想的,但这显然无法实现,因此,需要依赖可靠性曲线.鉴于概率的连续性,对于某个特定输出分类,该类别的估计概率应该是箱形的(本案例中,间隔大小为 0.05).然后针对每个分箱,计算出该类别的实际发生值.由此,完美校准出现在发生值等于估计概率(即 $y=x$)的情况下.图 3 给出了所提方法的预测概率的可靠性曲线.其中,虚线 $y=x$ 代表完美校准.由图 3 可以看出:所提方法与完美校准较为接近,能够准确估计出结果概率.总体上,所提方法表现出较好的校准性能.除低概率事件以外,所提方法能够准确地估计出如投篮尝试、投篮犯规、空类等概率(范围)较大的结果类别.

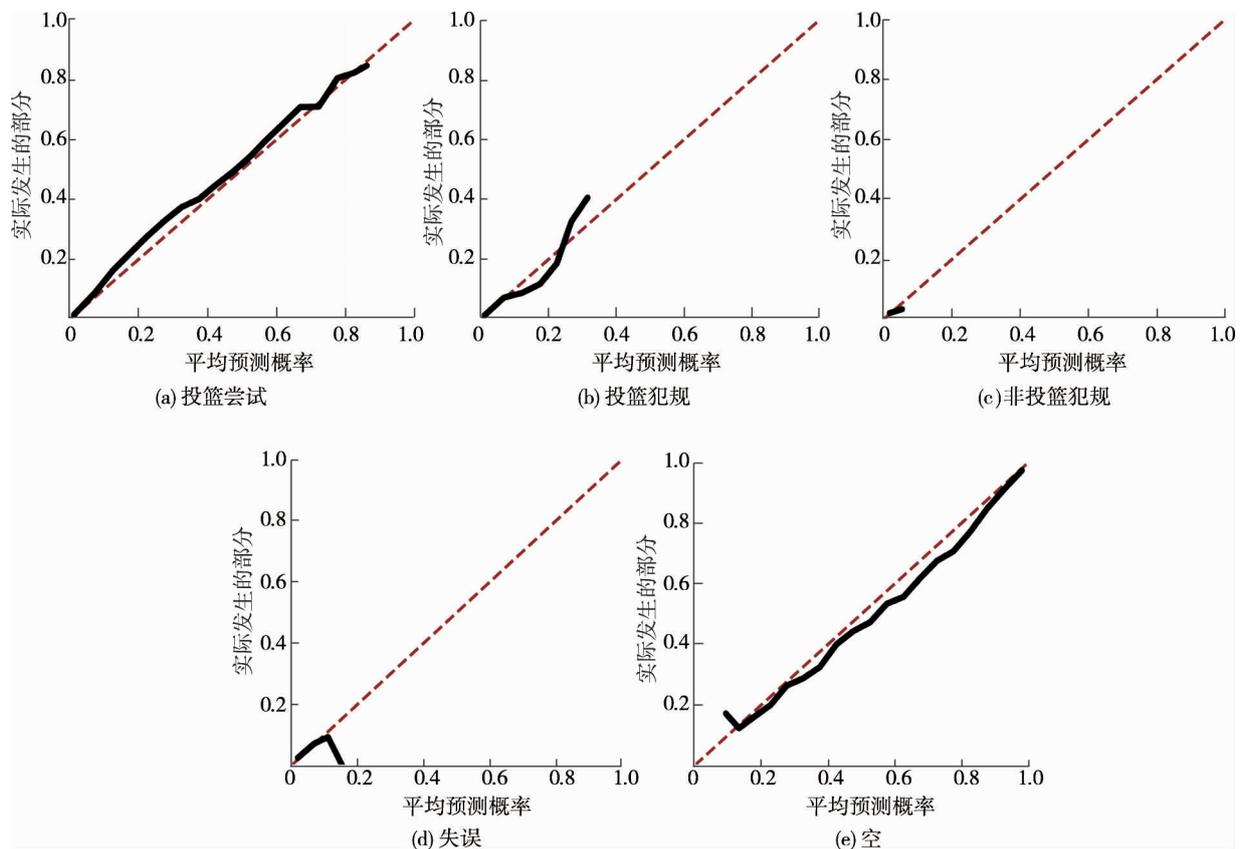


图 3 所提方法概率估计的可靠性曲线

3.3 微动作评价

3.3.1 传球评估

使用所提方法可以评估普通传球与得分传球之间的数值差异.具体来说,用式(3)计算出 512 个随机采样传球和 512 个随机采样助攻(得分传球)的预期增加分值.图 4 给出了不同类型传球之间预期增加分值的 Violin 图和四分位数.由图 4 可以看出:助攻在篮球中非常重要,能够表现出优秀的篮球转移和球队表现.因此,导致得分事件的传球(助攻)的价值高于普通传球.图 4 给出的估计分布证明本文方法能够实现这一目标,70%以上的助攻增加了预期分值.与之相比,普通传球的增加分值接近 0.

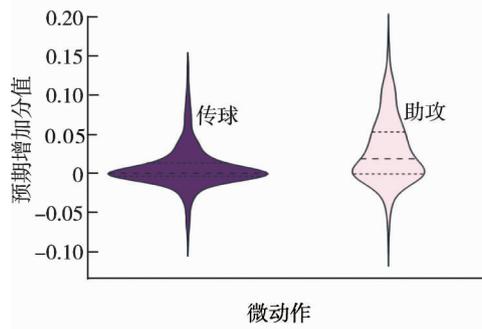


图4 预期增加分值的 Violin 图

3.3.2 实际应用评估

为了验证在实际应用中的效果,针对某次篮球比赛的某些回合进行微动作评价,图5和图6是所提方法在实例1和实例2中应用的结果.在图5中,白队的一个球员在得到一次掩护后向禁区方向切入,持球者将球传给切入的球员,后者完成了一次转身后仰的中距离跳投,其过程如图5a所示.所提方法识别出该战术的发展过程,终结动作的概率估计从“空”移向投篮尝试,小幅增加了预期分值,如图5b所示.其后,在一次成功掩护后,白队一球员切入,此时所提方法大幅增加了投篮尝试的概率,并估计出较高的预期分值,如图5c所示.图6中,白队球员向篮下运球,将球传给另一个队友,后者尝试了一次底角的三分投篮,这次进攻表现出所提方法对是否可能出现投篮犯规的识别能力.随着白队持球者靠近三分区内的多个防守球员,投篮尝试和投篮犯规的可能性均会增加,而“空”类的可能性则下降.在持球者将球传给左翼空位队友的过程中,由于球在空中,投篮犯规的概率显著下降,但投篮的可能性的变化相对较小.在队友接球后,投篮尝试的概率大幅上升,投篮犯规的概率依然较低,因为该球员附近没有防守球员,图6b给出了这个过程示意,图6c的预期得分也反映了这个过程.从这2个实例可以看出:所提方法能够准确地估计回合结果的概率分布,可以预测篮球微动作对赛场的贡献情况.

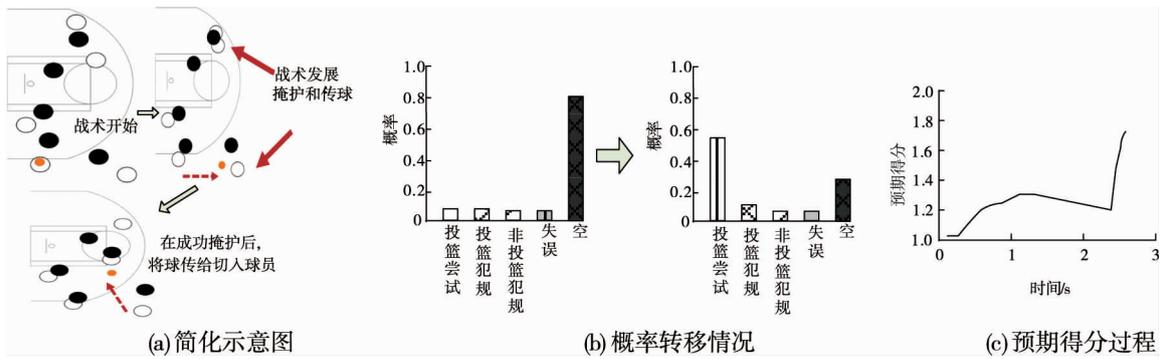


图5 实例1

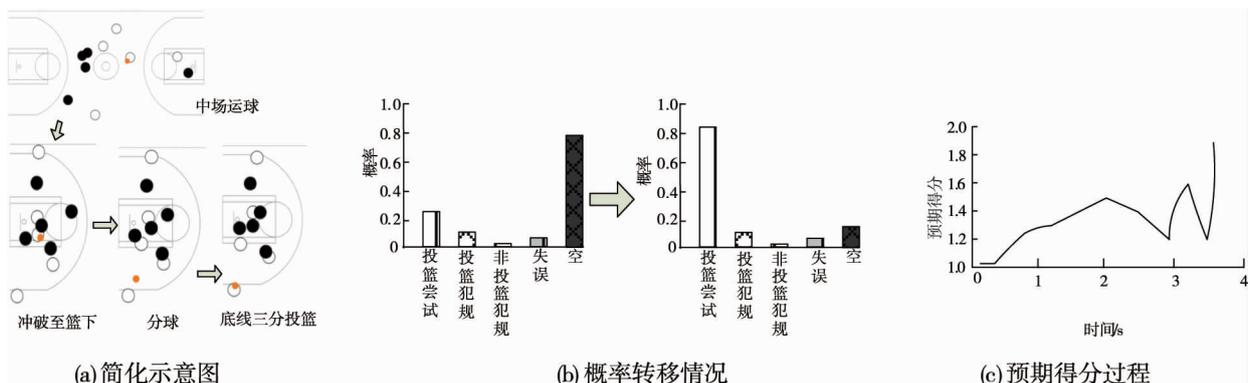


图6 实例2

4 结论

1) 利用深度神经网络估计预期得分值,不需要复杂的特征提取(如状态间转换的定义和建模等),而是将球员和篮球的原始轨迹作为输入。

2) 为了解决数据的不平衡性,针对训练阶段使用参数化的下采样方案,所提方法能够准确估计回合结果的概率分布,进而对微动作进行评价。此外,本文方法可以考虑扩展到其他运动项目中。

3) 未来将研究不同的球员嵌入向量方法,如对球员技术统计数据进行离线嵌入。此外,还可对提出的深度学习框架进行扩展,以估计其他比赛项目的预期得分。

参考文献:

- [1] 金尚勇.光学跟踪系统及光学跟踪系统的跟踪方法;201580068912.5[P]. 2017-08-29.
- [2] Franks A, Miller A, Bornn L, et al. Counterpoints: advanced defensive metrics for NBA basketball[C]// Proceedings of the 9th Annual MIT Sloan Sports Analytics Conference, 2015: 39-48.
- [3] 高慧萍.篮球运动员跳投动作精度视频三维监测仿真[J].计算机仿真,2016,33(10): 183-186.
- [4] Miller A, Bornn L, Adams R, et al. Factorized Point Process Intensities: A Spatial Analysis of Professional[C]// Proceedings of the 31st International Conference on International Conference on Machine Learning (ICML). 2014,32: 235-243.
- [5] Papalexakis E E, Pelechris K. tHoops: A Multi-Aspect Analytical Framework for Spatio-Temporal Basketball Data[C]// Proceedings of the 27th ACM International Conference on Information and Knowledge Management (CIKM '18). ACM, 2018: 2223-2232.
- [6] 秦海玉,廖志武.基于比赛环境特征的多目标运动员跟踪方法[J].计算机工程与设计,2017,38(11): 291-296.
- [7] 贺娇瑜.融合领域知识和深度特征的篮球比赛视频语义事件分析[D].北京:北京工业大学,2018.
- [8] Yoon Y, Hwang H, Choi Y, et al. Analyzing Basketball Movements and Pass Relationships using Realtime Object Tracking Techniques based on Deep Learning[J]. IEEE Access, 2019, 7:56564-56576.
- [9] Liu W, Yan C C, Liu J, et al. Deep learning based basketball video analysis for intelligent arena application[J]. Multimedia Tools and Applications, 2017, 76(23): 1-19.
- [10] 高君宇,杨小汕,张天柱,等.基于深度学习的鲁棒性视觉跟踪方法[J].计算机学报,2016,39(7):1419-1434.
- [11] 阮浩轩.不同水平篮球裁判员在执裁过程中的眼动研究[D].天津:天津体育学院,2015.
- [12] 黄婷婷,余磊. SDAE-LSTM 模型在金融时间序列预测中的应用[J].计算机工程与应用,2019,55(1):148-154.
- [13] 金志刚,韩玥,朱琦.一种结合深度学习和集成学习的情感分析模型[J].哈尔滨工业大学学报,2018,50(11):38-45.
- [14] Pascanu R, Gulcehre C, Cho K, et al. How to Construct Deep Recurrent Neural Networks[J]. Computer Science, 2013, 48(11): 109-118.
- [15] Chawla N V. Data Mining for Imbalanced Datasets: An Overview[M]. New York: Springer press, 2005.
- [16] 杨渺渺.具有时滞的递归神经网络稳定性分析[D].成都:电子科技大学,2015.
- [17] Gal Y, Ghahramani Z. A theoretically grounded application of dropout in recurrent neural networks[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. Curran Associates Inc., 2016: 36-45.
- [18] 皇甫雪官.国家气象中心集合数值预报检验评价[J].应用气象学报,2002,13(1):29-36.