推断体育比赛中的球员位置：有限观测下的多智能体空间插补

Gregory Everett 南安普顿大学，英国
gae1g17@soton.ac.uk

Ryan J. Beal Sentient Sports，英国
ryan.beal@sentientsports.com

Tim Matthews Sentient Sports，英国
tim.matthews@sentientsports.com

Joseph Early 南安普顿大学，英国
j.a.early@soton.ac.uk

Timothy J. Norman 南安普顿大学，英国
t.j.norman@soton.ac.uk

Sarvapali D. Ramchurn 南安普顿大学，英国
sdr1@soton.ac.uk

arXiv:2302.06569v1 [cs.LG] 13 Feb 2023

摘要

理解多智能体系统（MAS）中的智能体行为，是自动驾驶、灾害响应和体育分析等领域中的一个重要问题。现有的多智能体系统问题通常采用均匀时间步，并对所有智能体进行观测。在这项工作中，我们分析了智能体位置插补问题，具体而言，研究的是具有非均匀时间步和有限智能体可观测性的环境（~95% 缺失值）。我们采用长短期记忆网络和图神经网络组件，学习时间模式和智能体间模式，从而预测每个时间步所有智能体的位置。我们将这一方法应用于足球领域，根据稀疏的事件数据（例如射门和传球）插补一场比赛中所有球员的位置。我们的模型将球员位置的估计误差控制在 ~6.9 米以内；与表现最佳的基线相比，失误减少了 ~62%。该方法有助于开展球员身体指标、球员覆盖范围和球队场地控制等下游分析任务。现有的此类任务解决方案通常需要光学追踪数据，这类数据获取成本高，且仅限精英俱乐部使用。通过利用易于获取的事件数据插补球员位置，我们提高了下游任务的可及性。

关键词

多智能体系统；足球；插补；智能体行为

ACM 引用格式：
Gregory Everett、Ryan J. Beal、Tim Matthews、Joseph Early、Timothy J. Norman 和 Sarvapali D. Ramchurn。2023。推断体育比赛中的球员位置：基于有限观测的多智能体空间插补。载于 *第22届自主智能体与多智能体系统国际会议论文集（AAMAS 2023）*，英国伦敦，*2023*年*5*月*29*日至*6*月*2*日，IFAAMAS，共11页。

1 引言

许多多智能体系统 (MAS) 应用都涉及智能体在时空中交互，以实现各自及共同的目标。预测此类智能体的行为，是许多领域中的重要任务，例如预测自动驾驶车辆的行驶路径 [25]，利用手机数据或无人机影像预测灾害响应场景中平民的位置 [22, 27]，以及体育分析 [18]。然而，有时环境的可观测性可能受限。例如，自动驾驶车辆可能会因视野受阻而看不见附近的行人；在搜寻受伤平民时，无人机影像也可能无法充分观测某个区域。在这些情况下，需要合理估计智能体位置，以提升响应系统的效能。在本研究中，我们构建了一种名为*Agent Imputer*的多智能体时间序列插补模型，该模型能够学习智能体之间典型的时空交互，从而在系统可观测性受限时估计智能体的位置。我们将该模型应用于协会足球（soccer；本文后文简称足球）领域，通过仅观测持球智能体的位置和动作（例如传球或射门），来预测球场上所有球员的位置。

足球为将球队建模为动态多智能体系统提供了一个有趣的领域，其中每名球员都有各自的角色和行为。尽管所有球员都表现出不同的行为，但球的运动是整个系统的核心。因此，在本研究中，我们利用球和持球球员的相关数据，估算事件发生时所有球员的位置。我们构建了一个由长短期记忆网络（LSTM）和图神经网络（GNN）组件组成的模型，以学习足球比赛中球员的时间关系和智能体间关系，从而对比赛中未观测到的球员位置进行泛化预测。

足球分析数据有多种用途，包括对球队战术进行建模、计算体能指标（如跑动距离），以及衡量球队的球场控制力 [7, 12, 23]。足球俱乐部还可以利用这些数据进行球员评估、球探考察和对手分析。本研究探讨如何利用有球动作的稀疏足球事件数据，插补球员位置相关信息。这样无需昂贵的追踪数据，也能支持所需的下游分析任务。

我们的贡献如下：

(1) 我们提出了一种新颖的 *AgentImputer* 模型，用于在系统可观测性有限的情况下预测智能体位置。该模型利用 LSTM 和图神经网络组件学习时间交互和智能体间交互，从而估算足球运动中的智能体定位。(2) 我们使用真实足球比赛的事件数据和追踪数据训练并测试模型，发现其预测智能体定位的平均欧几里得距离误差为~6.9米，性能优于多种基线方法 ~62%。(3) 我们将模型预测应用于足球领域的真实下游应用，例如估算球员身体指标、球场控制力以及生成球员覆盖热力图。

第*22*届自主智能体与多智能体系统国际会议论文集，*A. Ricci*、*W. Yeoh*、*N. Agmon*、*B. An*（编），*2023*年*5*月*29*日至*6*月*2*日，英国伦敦。 © 2023 国际自主智能体与多智能体系统基金会（www.ifaamas.org）。保留所有权利。

本文其余部分安排如下。第2节讨论足球领域的相关文献和数据，第3节正式定义问题。随后，第4节介绍我们新颖的*Agent Imputer*模型。第5节介绍评估结果，第 6 节展示下游应用。第7节讨论模型结果和未来工作。最后，第8节总结全文。

2 背景

本节将讨论多智能体系统（MAS）中的智能体行为预测任务（第 2.1 节），接着介绍多智能体系统在体育领域中的现有应用（第 2.2 节），最后通过讨论可用的足球数据来源，说明插补球员追踪数据的必要性（第 2.3 节）。

2.1 预测智能体时空行为

在不同的多智能体系统领域中，已有不少研究致力于预测动态多智能体环境内智能体的时空行为。这些领域包括自动驾驶车辆的碰撞规避 [25, 28], 人群中的行人轨迹预测 [1, 10, 15], 人群的位置习惯 [16, 17], 以及体育分析 [11, 18, 26]。我们将现有研究归为两类应用场景：预测未来行为，以及在行为间歇性观测时插补智能体位置。

预测智能体未来行为。 基于多智能体系统中智能体以往的行为，预测其未来行为可能会很有用。文献中针对不同问题提出了多种方法，例如使用 LSTM 估计人群中的人体轨迹 [1, 10], 使用变分循环神经网络预测篮球比赛中球员未来的轨迹 [26],以及使用模仿学习预测足球运动员未来的轨迹 [11]。

智能体行为插补。与预测未来行为不同，插补着重于利用过去和未来的观测，补全有关智能体行为的缺失信息。当行为是间歇性观测到的情况，这种方法尤其有用。在足球领域的一个应用案例是，当球员离开摄像机视野时，对其智能体轨迹进行插补；该方法使用了图神经网络和变分自编码器 [18]。未来行为预测和插补也可以通过单个模型实现 [20]。

2.2 体育领域的多智能体系统

体育领域的既有研究将球队建模为多智能体系统，以更好地理解球队行为。这包括对球员之间的交互网络进行建模，以评估团队协作 [6],；通过将比赛序列映射到比赛战术来刻画球队行为 [14], ；以及对防守动作进行分类，为球队战术分析提供框架 [21]。与对球队进行建模不同，还有一些研究在多智能体系统背景下对个体球员行为进行建模。这包括使用模仿学习识别协同球队结构中的多个智能体策略 [11] ，以及使用长短期记忆网络预测篮球球员的轨迹 [9]。

与现有研究不同，我们并非针对某项特定的下游体育分析任务构建模型，而是提出一种用于插补缺失球员数据的模型，并进一步展示它如何助力各种应用，为只能获取稀疏体育数据源的人创造价值。

2.3 足球数据

足球领域的两大时空数据源是追踪数据和事件数据。下文将对这两类数据进行比较。

追踪数据。 作为足球分析领域当前的黄金标准，光学追踪数据每秒记录球员和球的位置 ~20 次 [2]。这意味着在一场比赛中，单个球员会产生 ~108,000个位置数据。获取追踪数据后，俱乐部可以通过分析无球球员移动和球队表现 [7, 23], 优化战术部署或招募策略，从而支持许多工业下游用例。然而，收集此类数据需要在体育场内安装昂贵的设备，因此目前主要局限于欧洲顶级联赛。无法获取追踪数据的俱乐部无法像顶级俱乐部那样开展同等程度的下游分析，进而导致球队表现差距进一步扩大。

事件数据。 与高频追踪数据相比，事件数据只记录比赛事件（例如传球和射门）以及事件位置和相关球员的信息 [19]。一场典型的比赛包含 ~3750 个事件，或平均每名球员 ~170 个事件。这类数据适用于有球统计，但由于它不收集球员在无球状态下的信息，因此无法直接用于许多无球下游任务。然而，这类数据的成本低得多，也更容易获取——许多数据提供商都拥有大量事件数据，覆盖 80+ 个全球联赛。

本文提出了一种模型，利用事件数据插补无球球员的位置，从而为比赛期间的所有事件提供所有球员位置的快照。这弥合了事件数据与追踪数据之间的差距，并为无法获取追踪数据的俱乐部开展所需的下游分析提供了便利。图1直观展示了事件数据与追踪数据的区别，以及我们如何利用模型估算追踪数据。

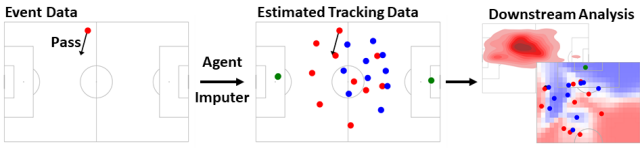

图1：单个时间段内事件数据与追踪数据的对比，以及我们的模型如何估算追踪数据，以便为下游分析工具提供支持。

与现有研究所用的数据不同，足球事件数据中的智能体观测更加稀疏，且时间步不均匀。这是因为只有当智能体执行有球动作（例如传球、射门、抢断）时，才会收集该球员的行为数据。这通常会导致一段时间内智能体事件密集出现，随后则是较长时间的信息缺失，因为球员此时不再控球。此外，由于每个时间步只有一名球员能够执行有球事件，因此每个时间步只会收集一名智能体的数据。因此，事件数据无法捕捉重要的无球信息，例如跑入空当的进攻跑动或集体防守站位；而这些信息对于分析球队表现至关重要。

据我们所知，此前尚无研究探讨过我们在本文中处理的问题：当信息以非均匀时间步出现，且每次仅涉及一个智能体时，如何在多智能体系统中补全智能体行为。下一节将正式定义这一问题。

3 问题表述

我们的多智能体系统由 N 个智能体组成，$\mathbf{A} = [a_1, \ldots, a_N]$。在我们的目标领域——足球中，$N = 22$（两支球队各有 11 名场上球员）。该时间序列由一系列 T 事件 $\mathbf{E} = [\mathbf{e}_1, \ldots\ldots, \mathbf{e}_T]$ 构成。请注意，该时间序列是非均匀的，因为每个元素 $\mathbf{e_t} \in \mathbf{E}$ 都是在智能体执行持球动作（例如传球、带球或射门）时记录的，因此各时间步之间的间隔不一。

对于每个事件 $\mathbf{e_t} \in \mathbf{E}$，我们都有一组观测 $\Phi_t = [\phi_t^1, \ldots, \phi_t^N]$，其中 ϕ_t^n是时间步 t对智能体 n的观测。这构成了关于 $\mathbf{\Phi} = [\Phi_1, \ldots, \Phi_T]$ 的完整时间观测集。然而，在我们的设置中，每个 $\Phi_t \in \mathbf{\Phi}$ 中只有一个值已知，也就是说，每个Φ_t都有 $N - 1$ 个缺失值，总计有 $T(N - 1)$个缺失值。这是因为我们在每个时间步只观测一个智能体——在我们的目标领域足球中，这就是持球智能体的位置。随着被观测的智能体随时间变化，我们构造一个独热编码掩码 $\mathbf{M}$，其中 $\mathbf{M}_t^n = 1$ 表示在时间步 t观测到智能体 n，否则为 0。这个 $(T \times N)$ 二进制矩阵完整地记录了时间序列问题中已知和未知观测的信息。

在此配置中，插补模型的目标是预测未知观测的值。形式上，对于每个$\mathbf{e_t} \in \mathbf{E}$，模型都会为每个 $n \in [1, \ldots, N]$ 预测一个值 $\hat{\phi}_t^n$。由此得到一组完整的预测观测$\hat{\mathbf{\Phi}} = [\hat{\Phi}_1, \ldots, \hat{\Phi}_T]$，其中 $\hat{\Phi}_t = [\hat{\phi}_t^1, \ldots, \hat{\phi}_t^N]$。请注意，在此设置中，模型也会预测它已经观测到的情况（即持球球员）的观测值。不过，在应用下游分析（第 6 节）时，对于已观测到的智能体，我们会改用其实际位置。

联系上述内容与我们的足球目标领域，预测观测$\hat{\mathbf{\Phi}}$ 是每个事件$\mathbf{e_t} \in \mathbf{E}$中所有球员（包括持球和无球球员）的估计位置。已知观测根据所发生事件的位置得出。因此，对于具有持球智能体 $a_n \in A$ 的事件$\mathbf{e_t} \in \mathbf{E}$，分配的观测 ϕ_t^n 为 $e_{\mathrm{x,y}\,t}$，其中 $e_{\mathrm{x,y}\,t}$ 是发生该事件时的 x,y 位置。

总而言之，已知观测集合 $\mathbf{\Phi}$ （包含缺失数据）是一个 $(T \times N \times 2)$ 张量，而插补后的观测集合 $\hat{\mathbf{\Phi}}$ 也是一个 $(T \times N \times 2)$ 张量。请注意，由于我们使用的是智能体的 x,y 位置，因此每个观测都是二维的；在其他领域中，这些观测的维度可能不同。下一节将介绍我们用于解决这一插补问题的模型。

4 AgentImputer模型

第 3 节中描述的问题非常复杂，因为 $\mathbf{\Phi}$ 中超过 95% 的值都缺失。我们的目标是从事件数据中提取有关智能体时空行为模式的有用信息，并将其应用于能够考量智能体随时间移动以及彼此之间相对运动的模型。本节将概述我们的方法所采用的特征工程（第 4.1 节）、模型架构（第 4.2 节）和训练过程（第 4.3 节）。实现细节请参见附录 A。

4.1 特征工程

给定时间步可用的特征严格来说都源自持球事件数据，包括事件位置、持球球员、事件发生的时间，以及当前比分等其他信息。这几乎没有提供任何关于无球智能体时空背景的信息，例如其位置最近一次被观测到的时间（即其上一次持球的时间）。因此，我们对事件数据进行特征工程，生成自己的特征集，以更全面地呈现每个智能体以及比赛的整体走势。我们为每个智能体创建这些特征，因此它们兼具智能体专属特征和全局特征。对于包含事件 $\mathbf{e}_t \in \mathbf{E}$ 的时间步 t 以及观测到的智能体 $a_n \in A$，我们计算以下特征：

智能体专属特征

`prevAgentTime,prevAgentX,prevAgentY`：智能体上一次被观测到时距今的时间，以及它当时的位置。形式上，这使用智能体上一次持球的最近前序时间步：$t_\prime$ s.t. $\mathbf{M}_{t'}^n = 1$ and $t_\prime \leq t$，可通过从 t 开始沿时间反向迭代找到。注意，如果智能体当前正在持球，则 $t_\prime = t$。给定 $t_\prime$，$(\texttt{prevAgentX}, \texttt{prevAgentY}) = e_{\mathrm{x,y}\,t'}$，且 $\texttt{prevAgentTime} = t - t_\prime$。如果尚未观测到该智能体，则用首次观测到它的时间步上的值插补这些特征。

`nextAgentTime,nextAgentX,nextAgentY`：距离智能体下一次被观测到还有多久，以及它当时的位置。与前述时间和位置特征类似，这使用智能体下一次持球的最早未来时间步（包括当前时间步）：$t_\prime$ s.t. $\mathbf{M}_{t'}^n = 1$ and $t_\prime \geq t$，可通过从 t 开始沿时间正向迭代找到。给定 $t_\prime$，$(\texttt{nextAgentX}, \texttt{nextAgentY}) = e_{\mathrm{x,y}\,t'}$，且 $\texttt{nextAgentTime} = t_\prime - t$。如果该智能体没有未来观测，则使用其最后一次被观测到时的值插补这些特征。

`avAgentX,avAgentY`：智能体在整场比赛中的平均位置，即所有满足条件的事件中智能体位置的平均值 $\mathbf{M}^n = 1$。

`agentRole`：智能体在球队中的角色（例如中后卫或守门员）。不同的数据提供商对角色的标注方式各不相同——对于我们的数据源，共有 16 种可能的角色，详见附录 B.2。

`agentSide`：用于指示智能体是否与当前持球智能体属于同一球队的二元标记。

`agentObserved`：用于指示该智能体是否正在执行当前持球动作的二元标记。

`goalDiff`：两队之间的比分差（该智能体所属球队的进球数减去对方球队的进球数）。

全局特征

`eventX,eventY`：当前事件的位置（即 $e_{\mathrm{x,\,y}\,t}$）。

`eventType`：当前事件的类型（例如传球或射门）。更多详情请参阅附录 B.1。

对于每个智能体在每个时间步的这 15 个特征，表示对原始事件数据的转换。经过转换后，数据更便于机器学习方法使用。请注意，智能体位置是相对于智能体自身的球门线而言的，不受进攻方向影响（与球场上的绝对位置相反）。在下一小节中，我们将详细介绍 *Agent Imputer* 模型。

4.2 模型架构

我们的*Agent Imputer* 模型利用事件集合$\mathbf{E}$的工程化特征，估计智能体位置集合 $\hat{\Phi}$。该模型旨在捕捉智能体随时间的移动、持球事件与无球智能体位置之间的关系，以及智能体如何在多智能体系统中作为一支球队进行互动。在足球领域，这通常被定义为球队结构。我们构建了一种能够在多智能体系统中跨时间和智能体进行学习的架构。下面，我们将

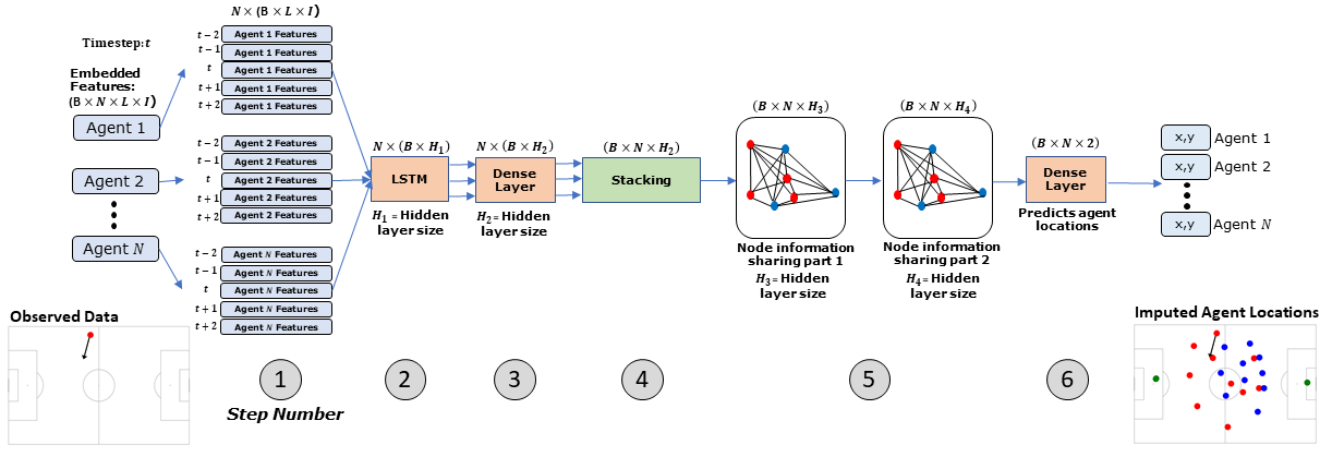

图 2：Agent Imputer 模型架构。事件的所有智能体位置估计均使用第 4.1 节所述的智能体特征信息生成，其中批大小为 B，智能体数量为 N，序列长度为 L，特征数量为 I。

按照逐步流程解释该模型，并在图 2 中标出架构中对应的组成部分。

4.2.1 步骤 ***1***：输入格式化。 为捕捉球和智能体随时间变化的位置，我们输入一个事件数据窗口。我们提取由第 4.1 节定义的特征集，覆盖 $L = 5$ 个事件组成的序列。该序列以特定时间步 t 为中心，即我们计算时间步 $\{t-2, \ldots, t+2\}$ 的特征。[1] 每个分类特征（智能体角色、智能体方位、智能体观测状态、进球差、事件类型）都会转换为嵌入（详情见附录 A.2）。我们的插补模型将所有智能体特征集作为一个同步输入整体处理，使模型能够学习整个系统的空间结构（而非分别处理每个智能体）。因此，输入数据的形状为 $(B \times N \times L \times I)$，其中 B 为批大小，N 为智能体数量，L 为序列长度，I 为特征集嵌入后的维度，包含数值特征和嵌入分类特征。在本研究中，$I = 24$ 和 $B = 128$。

4.2.2 步骤 ***2***：***LSTM***组件。每个智能体都会单独输入一个共享的双向LSTM组件，即将输入数据拆分为 N 个大小为（$B \times L \times I$）的片段。随后，LSTM 能够学习工程化特征与智能体位置之间的时间关系。重要的是，所有智能体共享同一个 LSTM。这解决了智能体观测数据稀疏的问题，因为 LSTM 能够通过角色相似的智能体共有的移动模式来学习智能体定位。由于时间步之间的时间间隔不规则，因此需要扩展 LSTM 架构以处理非均匀性。因此，我们使用时间感知 LSTM [3]，它会根据当前事件与序列中先前或后续动作之间的时间差调整细胞记忆，从而改变折扣率。在本研究中，我们使用具有一个大小为 $H_1 = 100$ 的隐藏层的 LSTM。

4.2.3 步骤 ***3***：带 ***ReLU*** 激活的全连接层。 提取 LSTM 模型在当前时间步 t（即输入序列中间位置）为每个智能体生成的输出。将该输出输入一个带 ReLU 激活函数的全连接层，以得到一个大小为 $H_2 = 50$的输出，从而为每个智能体生成时间聚合特征的潜在表示。

4.2.4 步骤 ***4***：堆叠智能体嵌入。 将经过时间聚合的潜在表示堆叠在一起，得到大小为（$B \times N \times H_2$）的输出张量。现在，这些数据适合作为图神经网络（GNN）的输入，其中每个张量行代表智能体信息，并作为 GNN 的节点特征。

4.2.5 步骤 ***5***：***GNN***组件。 该网络模型中的 LSTM组件用于对智能体行为的时间特征进行建模。接下来，我们还将对多智能体系统中的智能体间关系，以及这些关系如何影响每个智能体的行为进行建模。我们构建一个全连接图，并将经过时间聚合的智能体表示作为节点特征。GNN利用这一图结构，在所有智能体之间共享信息。GNN架构由两个消息传递层组成，特征维度分别为 $H_3 = 64$ 和 $H_4 = 32$，并使用SAGEConv算子 [8]。该架构通过均值聚合方案更新节点特征，以学习有关智能体邻域（即智能体交互）的信息。

4.2.6 步骤 ***6***：使用 ***ReLU*** 激活的全连接层。GNN 组件的最终输出大小为 $(B \times N \times H_4)$，即每个智能体都有一个大小为 32 的潜在表示，其中包含时间信息以及智能体间的交互信息。随后，这些最终表示会经过一个带有 ReLU激活函数的全连接层，为每个智能体预测最终位置 (x,y)。因此，最终模型输出的大小为 $(B \times N \times 2)$。

4.3 模型训练

我们在训练期间使用追踪数据作为目标变量，并将其作为真实标签来测试我们的*Agent Imputer* 模型的预测准确度。我们使用预测位置与真实位置之间的平均欧氏距离作为损失函数来训练模型。模型训练了 150 轮，批大小为 128。我们使用 AdamW [13] 优化器，初始学习率为 0.002。这些超参数和模型的具体架构（例如隐藏层大小）是通过反复试验确定的，也就是说，没有进行正式的超参数调优。

[1]如果由于处于比赛开始或结束时而不存在当前时间步之前或之后的时间步，则改用当前时间步的数据。

表1：模型在五折交叉验证中的平均预测性能及其95%置信区间。我们分别报告 X、Y 和欧几里得（XY）方向上的性能。所有失误均以米为单位。粗体结果表示最佳性能（失误最低）。

	训练			Test		
模型	X 方向失误	Y 方向失误	XY 方向失误	X 失误	Y 失误	XY 失误
基线1	14.20 ± 0.02	9.69 ± 0.02	18.81 ± 0.05	14.22 ± 0.24	9.70 ± 0.14	18.82 ± 0.22
基线 2	14.10 ± 0.02	9.79 ± 0.02	18.91 ± 0.05	14.04 ± 0.48	9.78 ± 0.17	18.80 ± 0.50
基线 3	13.37 ± 0.05	9.63 ± 0.01	18.15 ± 0.05	13.27 ± 0.44	9.57 ± 0.14	18.01 ± 0.46
XGBoost	5.88 ± 0.01	5.14 ± 0.02	8.67 ± 0.02	6.42 ± 0.35	5.50 ± 0.09	9.26 ± 0.26
时间感知 LSTM	4.46 ± 0.02	4.26 ± 0.02	6.89 ± 0.02	4.48 ± 0.08	4.49 ± 0.1	7.09 ± 0.06
GNN	5.28 ± 0.05	5.08 ± 0.1	8.18 ± 0.09	5.42 ± 0.35	5.13 ± 0.14	8.32 ± 0.25
Agent Imputer	**4.06 ± 0.02**	**4.12 ± 0.02**	**6.47 ± 0.02**	**4.29 ± 0.09**	**4.41 ± 0.11**	**6.88 ± 0.1**

5 实证评估

本节将介绍用于训练和评估模型的数据（第 5.1 节），介绍我们用于比较的基线方法（第 5.2 节），并给出实验结果（第 5.3 节）。

5.1 数据集

我们使用从 KLeague12 收集并由 Bepro Group Ltd 提供给我们的 34 场比赛的事件和足球追踪数据来训练和评估模型。这些是行业黄金标准数据集，可用于严格评估我们的方法。每场比赛都提供事件序列（用作模型输入）和追踪数据（用作训练目标和评估依据）。总计有 ~64,000 个事件和 ~1.4 百万个追踪位置。我们采用 31/3（~91.2%/8.8%）的训练/测试集划分，并通过五折交叉验证评估模型。所有几何数据均按标准足球场尺寸 105x68 米进行缩放。有关该数据集的更多详细信息，请参见附录 B.1。

5.2 基线方法

我们使用多种基线方法来评估，与其他插补方法相比，我们的模型是否提升了性能。首先，我们提出三种朴素插补基线。基线1仅根据比赛期间该智能体的平均持球位置来预测智能体位置。基线 2预测该智能体最后一个和下一个观测位置之间的质心，基线 3则预测该智能体最后一个和下一个观测位置之间直线轨迹上的一个按时间缩放的位置。我们还将*Agent Imputer* 模型与使用相同输入特征集的其他机器学习模型进行比较，包括 XGBoost 回归模型、时间感知 LSTM 模型（即图 2 中不含步骤 5 的同一模型），以及图神经网络模型（即图 2 中的步骤 4、5 和 6，并使用原始输入序列中间部分作为输入特征）。后两种基线使我们能够比较*Agent Imputer* 模型的组成部分分别对性能有何贡献。

5.3 结果

我们通过四项实验评估 *Agent Imputer* 模型及相关基线方法的性能。我们评估球员位置预测（第5.3.1节）、随时间变化的性能（第5.3.2节）、不同位置上的性能（第5.3.3节），以及性能如何随观测情况变化（第5.3.4节）。

[2]韩国顶级男子职业足球联赛级别

5.3.1 位置预测。我们在表1中评估模型和基线方法的预测性能。请注意，X方向沿球场长度方向（105米），Y方向沿球场宽度方向（68米），且我们没有根据球场尺寸对这两个方向上的失误进行归一化。我们发现，*AgentImputer* 模型预测智能体位置的准确度最高（距离失误最低）。我们还发现，时间感知LSTM模型的表现优于图神经网络模型，这表明我们 *Agent Imputer* 的核心部分是 LSTM组件。不过，将图神经网络组件纳入 *Agent Imputer* 模型后，性能仍有所提升，证明了对智能体交互进行建模的价值。与表现最佳的朴素基线相比，使用 *Agent Imputer* 可使失误减少61.8%。我们还发现，*Agent Imputer* 模型在X和Y方向上的失误大致相同。

5.3.2 时间上的可预测性。我们评估模型在比赛不同阶段的预测准确度。足球比赛分为两个各45分钟的半场，因此我们评估模型准确度在这些阶段中的变化。我们通过模型误差的滚动平均值来计算，见图3。半场结束时的补时也纳入考量——上半场补时与下半场初期的预测合并，而超过90分钟的数值则用于表示下半场补时。

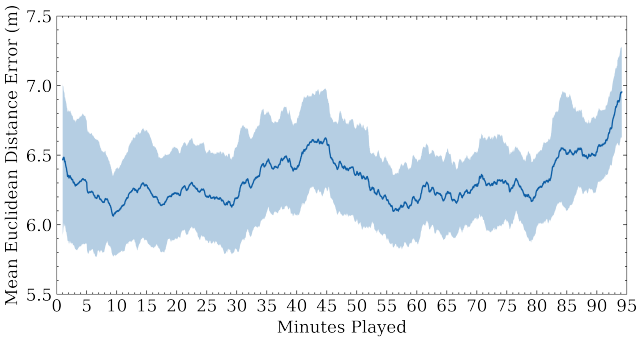

图3：使用合并后的训练数据和测试数据（全部34场比赛）计算的*Agent Imputer*模型随时间变化的预测性能，采用欧几里得误差的滚动平均（5分钟窗口，步长为1秒）。阴影表示各场比赛均值的标准差。

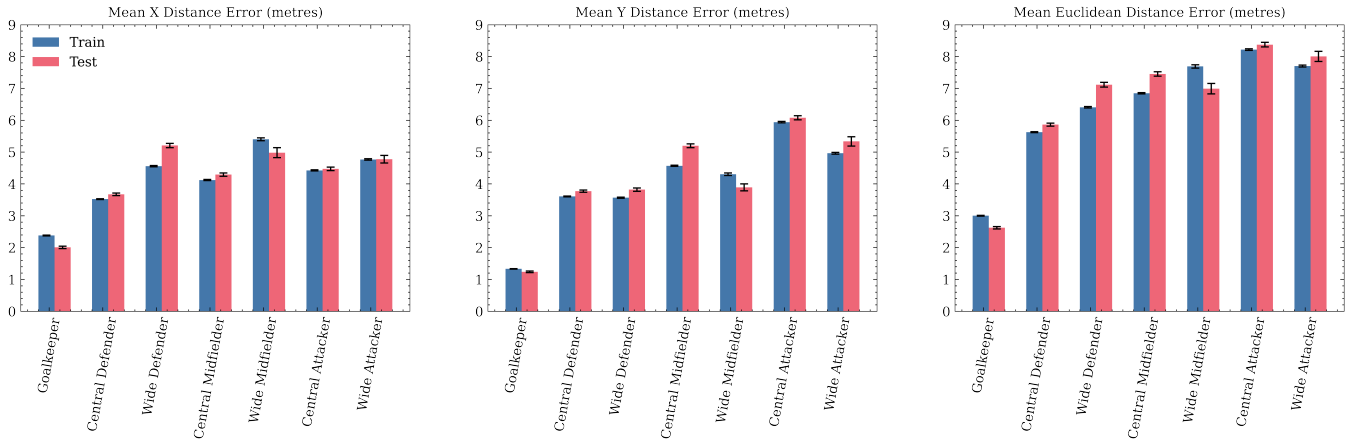

图4：使用*Agent Imputer*模型估计各智能体角色球员位置时的平均距离误差。

根据这些结果，我们认为，比赛中最难预测的时刻出现在两个半场的末尾。考虑到误差范围，我们进行t检验，以检验这样的假设：半场中段的样本分布均值低于半场末段的样本分布。对上半场进行检验时（比较第20至25分钟的所有事件与第42.5至47.5分钟的所有事件），结果显著（$p<0.01$）。下半场的差异（比较第65至70分钟的所有事件与第87.5至92.5分钟的所有事件）也达到显著水平（$p<0.01$）。

这支持了我们的理论：半场结束时比赛更难以预测，也印证了人们普遍的直觉，即球员会感到疲劳，而球队在半场结束时的结构性会降低。此外，球队可能会试图扳回比赛局势或守住领先优势，从而导致更加混乱且难以预测的阶段。这凸显了球队结构会发生变化的比赛阶段，而此类分析还可能揭示球员以“异常”方式移动的情形。此类分析可以进一步用于识别异常移动模式与球队表现之间的联系，并作为一种潜在工具，在比赛期间主动识别表现变化。

5.3.3 不同角色的可预测性。 我们在图4中评估了*Agent Imputer*模型在不同智能体角色中的表现。这有助于了解智能体在球队中的目标和职责如何影响其行为的可预测性。为简化起见，在本实验及下游应用（第 6 节）中，我们将角色归入边路和中路位置，从而将位置总数由16个减少到7个（见附录 B.2）。守门员通常是最容易预测的角色，因为其移动范围通常仅限于己方禁区。我们还发现，后卫比前锋更容易预测，这表明防守型智能体的行为比进攻型智能体更具结构性。

从 X 和 Y 方向的位置误差中也能得出一些有趣的发现。总体趋势是，与中路场上球员相比，模型更难预测边路场上球员的 X 方向位置（平均误差分别为 4.99 米和 4.15 米）；这在预料之中，因为边路球员会沿着球场边路移动很长距离。不过，模型通常能比中路球员更准确地预测边路球员的 Y 方向位置（4.35 米和 5.02 米），这也在预料之中，因为边路球员通常只活动在球场的一侧。这些比较有助于找出模型可以改进之处，也可用于在下游分析中传达不确定性。

5.3.4 不同观测时间间隔下的预测性能。 在图5中，我们评估了所提出模型的预测性能与“距上次观测的时间”之间的关系——即特定智能体上次参与某个事件以来经过的时间。我们还考察了“距下次观测的时间”——即该智能体下次参与某个事件之前的时间。我们发现，随着时间增加，XGBoost 和图神经网络模型的性能迅速下降。相比之下，*Agent Imputer* 和时间感知 LSTM 模型的性能下降较为缓慢，且趋于较低的平台期。这表明，对预测中的时间因素进行建模十分必要。不过，时间感知模型的性能仍会随着时间增加而下降。与按球员角色划分的失误（第5.3.3节）类似，这或许有助于衡量模型预测的不确定性；也就是说，对于近期更多控球的智能体，其预测结果更加确定。

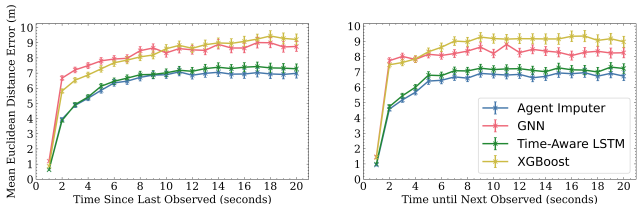

图5：模型性能与智能体上一次（左）和下一次（右）被观测到的时间进行比较。我们以一秒为间隔，使用一秒的时间窗口，例如，在2秒时，我们对1至2秒之间的所有事件进行评估。

6 模型应用

在本节中，我们将展示如何利用我们的*Agent Imputer*模型的输出进行下游分析。在足球领域，顶级俱乐部通常会利用追踪数据开展这类分析。不过，我们将证明，资源有限的低级别联赛俱乐部也可以使用我们的模型执行与顶级俱乐部类似的流程，而无需

昂贵且难以获取的追踪数据。我们将使用模型分析球员身体指标（第 6.1 节）、球场控制（第 6.2 节）和位置热图（第 6.3 节）。

6.1 球员身体指标

我们展示了如何利用 *Agent Imputer* 模型预测的球员位置来估计球员的体能指标。我们重点关注跑动距离，该指标通过对比赛期间球员预测位置之间的欧氏距离求和计算得出。我们最初发现，预测的跑动距离始终高于实际跑动距离：*Agent Imputer*的平均高估幅度为 11.5%，时间感知 LSTM 为 16.8%，图神经网络为 31.7%，XGBoost 为 29.7%。

这种高估偏差可归因于大量事件在另一事件发生后不久便接连发生——29.9%的事件发生在前一事件之后的一秒内。通常，这些事件是两支球队各有一名球员参与的对抗，或是一名球员接球后迅速传球。在这些情况下，球员的预测位置会发生显著变化，即移动速度超过球员的最大速度。这表明，对于快速连续发生的事件之间的球员轨迹，模型并未考虑其现实性。修正这一模型问题将是未来的工作。目前，我们采用后处理步骤，将彼此发生时间间隔在一秒以内的事件合并；分组时，使用初始事件的模型输出作为球员位置。这样可以更准确地估计跑动距离。不同球员角色的预测跑动距离平均结果如表2所示。[3]

表2：球员跑动距离结果。距离为测试数据的平均值，单位为千米。绝对误差为每场比赛中各球员角色的平均值。

Role	预测距离	真实距离	绝对百分比误差
守门员	3.23	3.12	4.05 ± 2.52
中后卫	8.26	8.42	4.31 ± 1.38
边后卫	8.97	9.08	4.99 ± 1.89
中前卫	9.37	9.48	3.66 ± 1.26
边前卫	8.73	8.97	2.79 ± 0.76
中路进攻球员	8.34	8.35	6.03 ± 2.32
边路进攻球员	8.26	8.70	5.33 ± 0.76

6.2 球场控制分析

为了测试一种考虑系统内智能体位置相互关系的模型应用，我们计算了球队的球场控制。球场控制 [7, 23, 24]是足球分析中的一种常用下游分析工具，它利用球员位置和轨迹来计算球队占据主导地位的区域。该工具将球场划分为网格区域，并计算如果球到达某个区域，进攻方控制球的概率。例如，如果防守球员比距离最近的进攻球员更靠近该区域，那么进攻方很可能无法控制该区域内的球，

[3]距离按所有球员均参加90分钟比赛的情况进行归一化（即考虑加时赛和换人）。参加比赛时间少于20分钟的球员不纳入这些结果。结果为某一角色球员在所有比赛中的平均值。

我们对 [18]采用类似的分析方法——利用 *Agent Imputer* 的输出计算球场控制，并将其与根据追踪数据中的实际球员位置计算出的结果进行比较。表3展示了各模型球场控制的平均绝对误差，并表明*Agent Imputer* 的表现最佳。

表3：球场控制表现与真实值的比较。基于测试数据计算。

模型	平均绝对误差
基线1	0.272 ± 0.002
基线 2	0.304 ± 0.002
基线 3	0.305 ± 0.002
XGBoost回归	0.150 ± 0.001
GNN	0.149 ± 0.001
时间感知 LSTM	0.135 ± 0.001
Agent Imputer	**0.130 ± 0.001**

我们在图 6 中提供了球场控制输出示例。俱乐部可以利用这些可视化结果，在不同比赛场景下评估球队对特定球场区域的控制程度。该图还展示了不同模型预测的球员位置之间的差异。可以看到，对于防守方，*Agent Imputer* 的预测中球员间距更大，并呈现出有序的水平防线。而在其他模型的预测中，一些后卫会垂直重叠排列——考虑到足球队通常采用的防守阵型和策略，这种预测极不可能。这表明图神经网络模块正确地学习了智能体之间的空间交互。

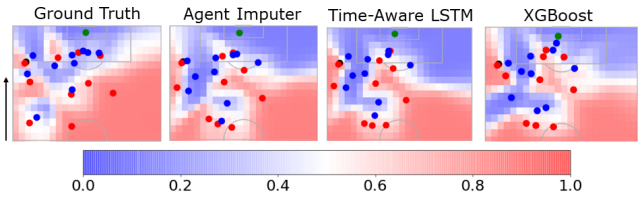

图 6：对比三个模型与真实值的球场控制图。红色区域由进攻方控制，蓝色区域由防守方控制。我们只展示进攻半场，因为球场其余部分完全由进攻方控制（红色）。箭头表示进攻方向。

6.3 球员热力图分析

在本节中，我们使用*Agent Imputer* 模型预测的球员位置，生成整场比赛的球员热力图。这能为教练提供有用信息，显示球员最常活动的区域。请注意，虽然可以根据事件数据生成热力图，但受数据本身性质的影响，~95%的球员位置将会缺失。图 7 展示了使用插补后的位置生成的中路进攻球员和中后卫热力图对比。

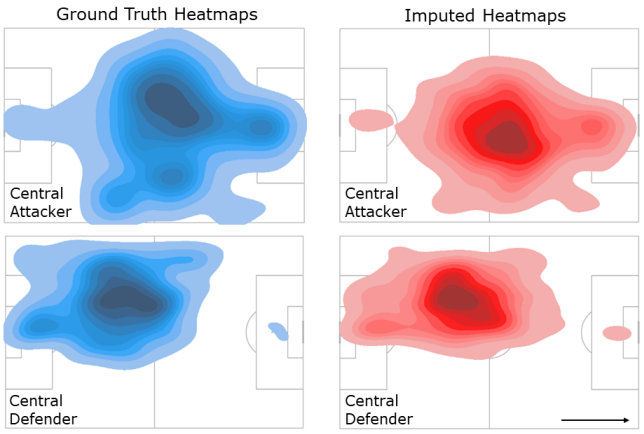

图 7：*Agent Imputer* 热力图示例与真实值热力图的对比。最深色区域表示球员最常活动的区域。球员由左向右进攻。更多图表见附录 C。

插补后的热力图与真实值热力图有许多相似之处。请注意，模型捕捉到了一些有趣的特征，例如中后卫在对方球门附近有一块小而明显的区域。这很可能源于定位球（例如角球），说明*AgentImputer* 已经学会了比赛状态的特征，以及这些特征如何影响球员位置。此外，中后卫的热力图偏向球场左侧边路，而中路进攻球员的热力图则更靠近中路。这表明模型已经学会了角色特定信息——通常有两到三名中后卫，因此他们可以专注于球场的特定一侧；而中路进攻球员则往往更自由，能够以无固定模式的方式活动。

7 讨论

本节将进一步讨论我们的研究结果（第 7.1 节），并指出研究局限和未来工作方向（第 7.2 节）。

7.1 结果分析

正如我们的结果（第 5.3 节）所示，我们的模型能够利用非常稀疏的数据插补智能体位置，其准确性高于朴素基线和其他机器学习模型。与 XGBoost 相比，性能有所提升，这表明 LSTM 和图神经网络组件所捕捉的时间动态和智能体间动态有助于学习智能体位置。

我们的 *Agent Imputer* 模型还能够更轻松地应用于足球领域中富有价值的用例，例如球员身体指标、球员热力图和球队球场控制分析（见第 6 节）。资源较少的低级别联赛俱乐部也可以采用这些用例，开展与顶级俱乐部类似的球员评估、球探考察和比赛分析工作。这有助于缩小这些球队之间的实力差距。

例如，研究表明，球员热力图与比赛中呈现的真实值热力图高度相关。这可以为对手数据分析球探提供帮助，使其能够监测对手，并让己方球员利用对方球队经常未能覆盖的区域。此外，这也有助于球探发现更常出现在危险区域的球员。

我们的模型所展现出的预测能力表明，足球中的站位在一定程度上是可以预测的。这很可能是因为球队会采用稳定的阵型进行防守和进攻，这涉及战术站位。探讨球队战术博弈论影响的研究，或许能进一步揭示球队行为的可预测性及其随时间的变化 [4, 5]。此外，担任特定角色的球员会收到指示，了解在特定比赛模式中应如何站位。我们的模型能够学习这些模式，从而预测此类站位未来出现的情况。

7.2 未来工作与局限性

我们的 *Agent Imputer* 方法也可应用于可观测性有限的其他多智能体系统，例如在灾害响应系统中搜寻受伤平民，或根据手机位置数据预测人类移动 [16, 17]。领域的变化不可避免地会带来问题结构上的差异，例如环境的边界或数据集的稀疏程度。将我们的方法应用于其他领域时，必须考虑这些差异。另一个研究方向是将模型改为概率式模型，从而量化智能体位置的不确定性。

我们的模型在位置估计方面表现良好。然而，正如第 5.3.2节所述，当事件接连快速发生时，根据这些估计提取的轨迹有时会不切实际（不过，我们注意到，与我们的方法相比，非时序模型中的这一问题更为严重）。未来的工作可以考虑同时预测智能体在多个时间步内的轨迹，以缓解这一问题。

进一步的研究还可以将我们提出的 *Agent Imputer*模型与使用追踪数据而非事件数据的最先进模型进行比较（例如， [11, 18]）。在本研究中，我们只与其他使用事件数据的模型进行了比较。与追踪数据模型进行比较，有助于更好地评估我们的补全方法在下游分析任务中的有效性。

最后，由于追踪数据难以获取，本研究使用的比赛数量相对较少（总计34场）。未来的工作可以扩展我们的数据集，纳入更多比赛。这将有助于模型学习更广泛的比赛场景，而不仅限于当前数据集中出现的场景。此外，这也将推动开发更具针对性的模型，例如专注于特定球员或球队的模型。

8 结论

本文提出了一种新颖的 *Agent Imputer* 模型，用于解决系统可观测性有限的动态环境中的多智能体行为预测问题。我们将这一任务应用于足球领域，仅利用有球数据来插补无球球员位置。结果表明，我们的模型能够将球员位置插补到误差在 ~6.9 米以内，优于多个基线补全模型。我们还深入分析了模型的表现，考察其在不同比赛时间、球员角色和观测率下的准确性。此外，我们介绍了借助该模型实现的足球分析应用，使低级别联赛俱乐部无需获取昂贵数据，也能执行与顶级俱乐部类似的分析流程。这项新颖的研究还可应用于其他智能体可见性有限的现实世界领域，例如灾害响应，或利用手机数据追踪日常人类移动。

致谢

我们感谢 Bepro Group Ltd 为本研究提供支持和数据资源。Gregory Everett 的资助来自 Sentient Sports；Sarvapali Ramchurn 则通过可信自主系统中心（EP/V00784X/1）和 AXA研究基金获得英国工程与自然科学研究委员会（EPSRC）的资助。

参考文献

[1] Alexandre Alahi、Kratarth Goel、Vignesh Ramanathan、Alexandre Robicquet、Li Fei-Fei 和 Silvio Savarese。2016。社会LSTM：拥挤空间中的人类轨迹预测。载于*IEEE*计算机视觉与模式识别会议论文集。961–971。[2] Sian Barris 和 Chris Button。2008。体育中基于视觉的运动分析综述。运动医学 38, 12（2008），1025–1043。[3] Inci M Baytas、Cao Xiao、Xi Zhang、Fei Wang、Anil K Jain 和 Jiayu Zhou。2017。通过时间感知LSTM网络进行患者分型。载于第*23*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集。65–74。[4] Ryan Beal、Georgios Chalkiadakis、Timothy J Norman 和 Sarvapali D Ramchurn。2020。优化足球比赛战术。载于第*19*届自主智能体与多智能体系统国际会议论文集。141–149。[5] Ryan Beal、Georgios Chalkiadakis、Timothy J Norman 和 Sarvapali D Ramchurn。2021。使用现实世界流畅目标优化长期结果：足球领域的应用。载于第*20*届自主智能体与多智能体系统国际会议论文集。196–204。[6] Ryan Beal、Narayan Changder、Timothy Norman 和 Sarvapali Ramchurn。2020。学习团队协作的价值以组建高效团队。载于*AAAI*人工智能会议论文集，第34卷。7063–7070。[7] Javier Fernández、Luke Bornn 和 Dan Cervone。2019。分解难以衡量的体育运动：面向足球的深度学习预期控球价值框架。载于第*13*届*MIT*斯隆体育分析大会。[8] Will Hamilton、Zhitao Ying 和 Jure Leskovec。2017。在大型图上进行归纳表示学习。神经信息处理进展 30（2017）。[9] Sandro Hauri、Nemanja Djuric、Vladan Radosavljevic 和 Slobodan Vucetic。2021。NBA球员的多模态轨迹预测。载于*IEEE/CVF*冬季计算机视觉应用会议论文集。1640–1649。[10] Boris Ivanovic 和 Marco Pavone。2019。Trajectron：利用动态时空图进行概率多智能体轨迹建模。载于*IEEE/CVF*国际计算机视觉会议论文集。2375–2384。[11] Hoang M Le、Yisong Yue、Peter Carr 和 Patrick Lucey。2017。协调式多智能体模仿学习。载于国际机器学习会议。PMLR，1995–2003。[12] Daniel Link、Steffen Lang 和 Philipp Seidenschwarz。2016。利用时空跟踪数据实时量化足球中的危险性。*PLOS ONE* 11, 12（2016），e0168768。[13] Ilya Loshchilov 和 Frank Hutter。2018。解耦权重衰减正则化。载于国际学习表征会议。

[14] Patrick Lucey、Alina Bialkowski、Peter Carr、Eric Foote 和 Iain Matthews。2012。根据部分球队轨迹刻画多智能体团队行为：来自英格兰足球超级联赛的证据。载于*AAAI*人工智能会议论文集，第26卷。1387–1393。[15] Francesco Marchetti、Federico Becattini、Lorenzo Seidenari 和 Alberto Del Bimbo。2020。利用记忆增强网络预测移动智能体的多条轨迹。*IEEE*模式分析与机器智能汇刊 （2020）。[16] James McInerney、Alex Rogers 和 Nicholas R Jennings。2012。利用概率潜在语义分析改进面向新用户的位置预测服务。载于*2012*年*ACM*普适计算会议论文集。906–910。[17] James McInerney、Jiangchuan Zheng、Alex Rogers 和 Nicholas R Jennings。2013。针对数据稀疏情况下的位置预测，对人群中的异质位置习惯进行建模。载于*2013*年*ACM*普适与泛在计算国际联合会议论文集。469–478。[18] Shayegan Omidshafiei、Daniel Hennes、Marta Garnelo、Zhe Wang、Adria Recasens、Eugene Tarassov、Yi Yang、Romuald Elie、Jerome T Connor、Paul Muller 等。2022 12, 1 2022 1 13。足球中的多智能体屏幕外行为预测。《科学报告》（），–。[19] Luca Pappalardo、Paolo Cintia、Alessio Rossi、Emanuele Massucco、Paolo Ferragina、Dino Pedreschi 和 Fosca Giannotti。2019。足球赛事中时空比赛事件的公开数据集。《科学数据》6, 1（2019），1–15。[20] Mengshi Qi、Jie Qin、Yu Wu 和 Yi Yang。2020。用于轨迹预测与插补的模仿式非自回归建模。载于*IEEE/CVF*计算机视觉与模式识别会议论文集。12736–12745。[21] Dominik Raabe、Reinhard Nabben 和 Daniel Memmert。2022。用于分析多智能体时空体育数据的图表示。《应用智能》（2022），1–21。[22] Sarvapali D Ramchurn、Trung Dong Huynh、Feng Wu、Yukki Ikuno、Jack Flann、Luc Moreau、Joel E Fischer、Wenchao Jiang、Tom Rodden、Edwin Simpson 等。2016。基于人类—智能体集体的灾害响应系统。《人工智能研究杂志》57（2016），661–708。[23] William Spearman。2018。超越预期进球。载于第*12*届麻省理工学院斯隆体育分析大会论文集。1–17。[24] William S pearman、Austin Basye、Greg Dick、Ryan Hotovy 和 Paul Pop。2017。足球传球概率的基于物理的建模。载于第*11*届麻省理工学院斯隆体育分析大会论文集。[25] NN Sriram、Buyu Liu、Francesco Pittaluga 和 Manmohan Chandraker。2020。SMART：同步多智能体循环轨迹预测。载于欧洲计算机视觉会议。施普林格，463–479。[26] Chen Sun、Per Karlsson、Jiajun Wu、Joshua B Tenenbaum 和 Kevin Murphy。2018。基于部分观测的多智能体交互随机预测。载于国际学习表征会议。[27] Jing Wang、Jianping Cai、Xiaohang Yue 和 Nallan C Suresh。2021。预先部署与实时灾害响应行动：利用手机位置数据进行优化。《交通研究*E*辑：物流与交通评论》150（2021），102344。[28] Xu Xie、Chi Zhang、Yixin Zhu、Ying Nian Wu 和 Song-Chun Zhu。2021。用于碰撞规避的拥堵感知多智能体轨迹预测。载于*2021*年*IEEE*机器人与自动化国际会议（*ICRA*）。IEEE，13693–13700。

A 实现细节

本节列出本研究使用的计算资源（A.1节），并进一步介绍特征嵌入过程（A.2节）。

A.1 计算资源

本研究使用 Python 3.8.8 实现，机器学习功能由 PyTorch 提供。[4] 模型训练通过 Google Colab 提供的远程图形处理器服务完成，使用配备 32 GB 显存的 NVIDIA V100 图形处理器。我们使用 CUDA 在图形处理器上进行训练。训练 *Agent Imputer* 模型时，每个折叠最长耗时三小时。代码可在此处的公开 GitHub 代码库中获取：https://github.com/GregSoton/PlayerImputation。

A.2 特征嵌入

我们使用随机嵌入向量对分类变量（智能体角色、智能体方位、智能体观测状态、进球差、事件类型）进行嵌入，其中每个变量对应的向量大小为其类别数的平方根。这使类别特征维度总数从 5 增至 14。未来的工作应考虑使用可训练嵌入。我们使用针对 X 和 Y 方向分别设置的最小-最大缩放器对空间特征进行归一化。对于基于时间的特征，我们使用 scikit-learn 软件包中的 RobustScaler。[5] 这种方法能够恰当地缩放时间，同时对事件之间异常长的间隔（例如，因受伤造成的间隔）所导致的异常值具有鲁棒性。

B 数据集详情

本节将进一步介绍 数据集结构（B.1 节） 以及球员位置（B.2 节）

B.1 数据集结构

我们使用的真实追踪数据集以 30 Hz 的频率记录球员位置。为将球员追踪与事件数据对齐，我们会找到与事件时间戳最接近的追踪时间戳（通常只相差几毫秒）。对于我们的数据，可能的事件类型包括：传球、接到传球、犯规、造犯规、对抗、抢断、射门、扑救、干预、球权回收、拦截、过人、封堵、接球、解围、失误、失球、越位、头球解围、比赛暂停、乌龙球、受压控球、折射、带球、换人。传球事件不会突出显示接球的球员，而是引用一个接到传球事件。这种模式贯穿整个数据集，每个事件都会引用与之相关的事件。

B.2 球员位置

所提供的事件数据为每场比赛中的球员角色提供了标签。共有 16 种不同的角色，我们将其输入模型。在进行下游分析时，我们会对角色进行分组，以便于理解，并增加每种角色的数据量。下方列出了角色组（粗体）及其角色（嵌套项目符号）：

- **守门员 –** 守门员
- **中后卫 –** 中后卫– 中路防守型中场
- **边后卫 –** 左后卫– 右后卫 – 左翼卫 – 右翼卫
- **中场 –** 中前卫
- **边前卫 –** 左前卫– 右前卫
- **中路进攻球员 –** 攻击型中场– 中锋
- **边路进攻球员 –** 左边锋 – 右边锋 – 左前锋 – 右前锋

[4] https://pytorch.org/ [5] https://scikit-learn.org/stable/index.html.

C 补充球员位置热力图

在本节中，我们提供了各个角色的更多球员热力图；详见图 A1。

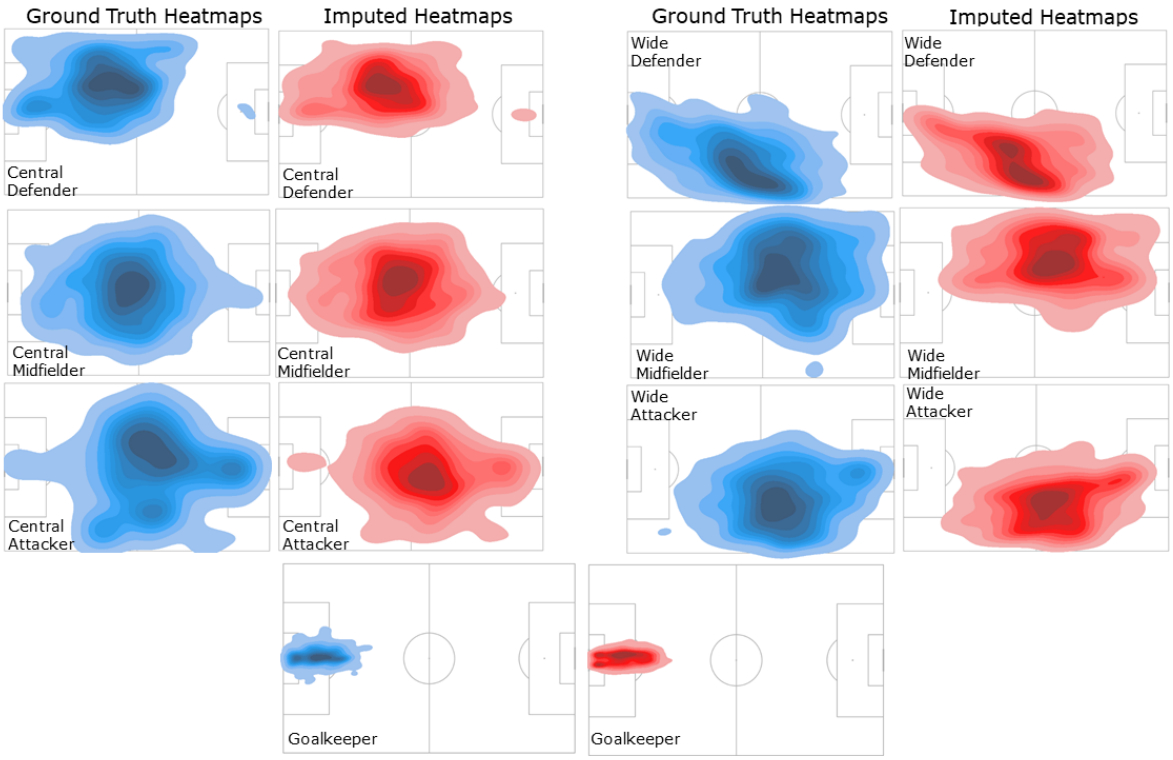

图 A1：所有角色的球员热力图。