arXiv:2603.01325v1 [physics.soc-ph] 1 Mar 2026

从 GEV 到 ResLogit：用于行人运动预测的空间相关离散选择模型

Rulla Al-Haideri[1*] Bilal Farooq[1†]

[1]交通创新实验室（LiTrans），多伦多都会大学，加拿大安大略省多伦多市维多利亚街 350 号

摘要

在与自动驾驶汽车（AV）交互时，可通过采用行为框架（例如能够明确考虑相似移动备选项之间相关性的离散选择模型），提升高频行人运动预测的效果。我们将行人的下一步选择表述为空间离散选择问题，并以速度调整和航向变化构成网格。基于 nuScenes 和 Argoverse 2 中自然状态下的行人—自动驾驶车辆交互数据（决策间隔为 1 秒），我们估计了一个多项 Logit 基准模型和四种空间广义极值（GEV）设定（SCL、GSCL、SCNL 和 GSCNL）。随后，我们将这些模型与残差神经网络 Logit（ResLogit）模型进行比较；该模型在保留可解释的线性效用成分的同时，能够学习跨选项效应。在所评估的数据中，空间 GEV 结构相较多项 Logit 仅带来微小改进，而 ResLogit 则显著提升了拟合效果，并产生了行为上连贯、集中于相邻网格单元的误差。结果表明，对于密集的高频空间选择集，基于学习的残差校正比分析者设定的 GEV 嵌套结构更有效地捕捉邻近性诱导的相关性，同时保持可解释性。

关键词：行人移动选择；空间离散选择；广义极值模型；残差神经网络；自动驾驶车辆；轨迹数据

1 引言

在地理及时空建模中，距离是决定人类运动模式的基础因素。托布勒第一定律指出，彼此邻近的实体往往比相距较远的实体更为相关 [1]。在离散选择建模中，这意味着位置相近的备选项

*通讯作者。电子邮箱：rullaalhaideri@torontomu.ca
†电子邮箱：bilal.farooq@torontomu.ca

可能具有相同的未观测属性，从而导致其效用之间存在相关性。在空间选择场景中，这一点尤其值得关注，因为相邻备选项往往是彼此密切的替代项，而分析者无法完全观测到其中的原因。

大量文献聚焦于对空间相关的备选项进行建模，尤其是位置选择。早期方法依赖灵活的误差结构，最常见的是采用 Probit 模型和混合Logit模型框架。空间自回归多项Probit模型形式通过外生设定的空间权重矩阵，引入地理位置相近的备选项之间的相关性 [2]。随后，研究者将空间自回归过程嵌入基于模拟的混合Logit模型设定中的效用确定性和随机性部分 [3]。其他相关扩展则对方差—协方差结构采用基于距离的参数化，使距离较近的备选项呈现更强的相关性，同时保留混合Logit核和基于模拟的似然评估 [4]。这些方法具有较强的表达能力，但通常需要进行复杂的矩阵构造。此外，它们还需要谨慎设定空间加权方案的先验，并且模拟过程会带来额外的计算负担。

与此同时，广义极值（GEV）族中的封闭形式模型能够以解析上便于处理的方式放宽独立性假设，同时保持选择概率易于计算 [5]。空间 GEV 形式通过调整 GEV 生成函数来捕捉反映备选项之间空间关系的相关结构。空间相关Logit（SCL）模型依靠邻接矩阵，在单一相关参数下将备选项分配至重叠巢 [6]。广义SCL（GSCL）以基于距离的分配规则取代二元邻接关系，使相关性随距离增加而衰减，同时保留单一相关参数 [7]。空间相关嵌套Logit（SCNL）允许采用多个嵌套系数，但仍保留由分析者设定、基于邻接关系进行分配的空间关联 [8]。在此基础上，广义空间相关嵌套Logit（GSCNL）旨在减少对预先设定的邻接关系或距离衰减假设的依赖，通过数据估计分配模式。这使相关强度和分配模式能够根据观测到的选择行为进行调整 [9]。这些封闭形式的空间 GEV 模型仍然颇具吸引力，因为它们兼具可解释性和计算效率。然而，这些模型仍要求分析者施加或论证空间关联设计；当选择集密集且决策频率较高时，这种要求可能会造成限制。

这一挑战在高频行人移动建模中尤为关键。下一步步行决策本质上具有空间性，因为每个决策时刻都要从具有空间结构的选择集中选出一个移动备选方案。在我们的设定中，备选项构成一个由速度调整和航向变化定义的 3×3 网格。相邻的移动备选项在构造上彼此相似。因此，由接近程度引起的相关性是选择集固有的特征。针对街区中段交互情境预测行人运动，对自动驾驶汽车（AV）的运行也具有重要意义。规划和

让行决策依赖于短时域预测，即预测行人在交互压力下如何调整速度和航向。下一步移动模型可支持街区中段的行人微观仿真，并为运动预测提供行为基线。在后续工作中，这一基线将扩展为具有时间依赖性、包含更丰富场景与交互情境的多步预测，同时保留离散选择结构和可解释性。

与此同时，针对自动驾驶汽车附近行人的运动预测，主要采用机器学习方法，根据过去的轨迹和场景上下文预测未来坐标。研究人员已广泛运用序列建模和表征学习来研究行人轨迹预测。早期的深度学习方法采用循环网络，并借助社会池化等社会交互模块来捕捉拥挤环境中的行人间交互 [10, 11]。后续研究进一步拓展至多模态预测、图结构交互建模和地图感知预测，例如模块化图循环架构和矢量化地图编码器 [12–14]。许多方法纳入场景上下文、与车辆的距离、头部朝向或其他行为线索，以提升在人行横道和街区中段交互场景中的预测效果 [15]。相关研究还关注行人过街意图预测和行为理解，并将任务设定为意图分类，或联合预测意图与轨迹 [16, 17]。

尽管取得了这些进展，仍有两个直接相关的不足。第一，许多轨迹预测模型专注于预测准确度和强大的特征学习，但并未构建行为模型来量化输入如何改变选择概率（即弹性），也未说明在结构化选择集中，概率如何在相邻的移动备选项之间转移。第二，在决策应用中，最重要的预测错误往往是那些仍发生在同一个小范围动作邻域内的错误。对于3×3 移动网格，预测到相邻单元格（即速度调整或航向略有变化）通常远不如预测到代表性质不同动作的远处单元格有害（例如，行人实际上减速了，却预测为加速）。这些原因促使我们将行人运动建模为空间选择，即在离散化移动网格上进行选择，并根据模型的误差及相关结构是否在可行移动的局部邻域内保持行为一致来评估模型。基于这些原因，本文将行人的下一步运动表述为一个离散选择问题。在每个决策时刻，行人从由速度调整和航向变化定义的移动网格中选择一个备选项。离散选择表述提供了一种行为决策规则，其线性效用包含结构可解释参数。这使我们能够直接阐述权衡以及交互变量的方向性影响，同时明确呈现相邻备选项之间的替代模式。

近期提出的混合选择模型旨在通过直接从数据中学习系统性的交叉效应，减少对分析者定义的相关结构的依赖。Wong 和 Farooq 提出了残差神经网络 Logit（ResLogit）模型。该模型在多项 Logit（MNL）基础上加入残差层，以学习非线性交叉效应和未观测到的行为结构，同时仍支持替代模式和弹性等行为指标 [18]。针对有序响应，Kamal 和 Farooq 将 ResLogit 与一致的秩 Logit 构造相结合，扩展出 Ordinal-ResLogit [19]。这些模型代表了数据驱动方法，可用于捕捉相关性和异质性；否则，这些特征可能需要通过分析者定义的嵌套、邻接矩阵或距离衰减设定来建模。

本文将行人的下一步移动选择构建为空间选择问题。本文评估经典空间 GEV 模型是否仍适用于高频移动选择，还是基于混合学习的选择模型能更好地表征邻近性诱导的相关性。研究从两个公开的轨迹数据集中提取了涉及自动驾驶车辆交互的自然情境路段中部行人过街决策：nuScenes [20] 和 Argoverse 2 [21]。主要目标是比较 MNL、空间 GEV 形式（SCL、GSCL、SCNL 和 GSCNL）与 ResLogit，考察它们捕捉移动选择网格中空间相关性及其预测性能的能力。

本文其余部分安排如下。第 2 节介绍数据集、空间选择集的构建，以及包括空间 GEV 和 ResLogit 在内的模型形式。第 3 节展示估计结果、预测性能和诊断分析，以阐释为何经典空间相关结构在密集移动网格中的收益有限。第 4 节总结全文，讨论其对行为基础运动预测的启示，并指出序列建模和多智能体建模方面的拓展方向。

2 文献综述

2.1 行人运动预测

行人运动预测长期以来一直被视为自动驾驶汽车从感知到规划的核心能力。这是因为短时域的不确定性会直接影响让行、避撞和舒适性约束机动。早期的数据驱动研究采用循环神经网络实现了序列到序列的行人轨迹预测，并通过社会池化引入显式的交互建模，以捕捉人群中的邻近轨迹 [10]。Social-GAN 将这一思路扩展为生成式框架，能够生成多样且符合社会行为规律的未来轨迹，重点关注多模态性和交互一致性，而非单一的最佳预测 [11]。

随着轨迹 随着轨迹预测在自动驾驶车辆场景中日趋成熟，各种方法开始捕捉异构场景

上下文信息。这些信息包括语义地图、车道几何、智能体动态，以及多个道路使用者之间的交互结构。Trajectron++ 提出了一种图结构循环架构，能够处理异构智能体类型，并纳入环境信息，同时支持多模态预测 [13]。VectorNet 引入了地图元素和轨迹的向量化表示[14]。该框架采用分层图网络来捕捉空间局部性和全局交互，并在大规模自动驾驶基准上展现出有竞争力的性能。这类方法体现了一种主流范式：将行人运动预测为与过去运动和场景上下文相关联的连续未来坐标 [13, 14]。相比之下，我们的研究将短时域行人运动建模为在结构化移动选项之间进行离散选择。这使得我们能够解释不同备选项之间的权衡，并明确呈现其替代模式。因此，这种建模方式能够为候选移动备选项生成经过校准的概率分布。该方法可直接用于基于假设的自动驾驶车辆规划，并可通过替代和误分类方面的局部一致性进行评估。

轨迹预测文献中的两个局限与行为基础运动预测直接相关。首先，许多高容量预测器注重表征学习和预测准确性，却未提供明确的行为决策规则，因而无法支持对离散移动备选项之间的权衡、弹性或替代模式进行解释。其次，在控制和风险评估方面，并非所有预测误差都会造成同等严重的后果。混淆两个相邻的移动备选项，往往几乎不会产生运行影响；而混淆性质迥异的备选项，则可能导致截然不同的风险评估和规划决策。这促使我们采用侧重于预测概率分布局部一致性和误分类结构的评估与建模设计。尤其是当预测问题定义在一组结构化候选动作之上，而非连续坐标空间中时，这一点更为重要。

2.2 S运动预测中的结构化动作空间与离散化

大量文献采用离散化或结构化的动作集合来表示多模态性，并实现对未来行为的可处理概率推理。在自动驾驶汽车中，已采用基于有限候选轨迹集的基于分类的预测来管理人体运动固有的多模态性，同时保持推断高效。CoverNet将运动预测表述为对一组精心筛选的可行轨迹进行分类[22]。作者认为，在实际时间范围内不同动作的数量是有限的，离散轨迹集可以捕捉多样的未来。MultiPath使用一组固定的锚点轨迹来表示未来分布的模态，并预测锚点上的离散分布以及连续偏移量 [23]。由此得到一种适用于概率查询的紧凑混合表示。相关工作还将轨迹

预测视为对轨迹库的排序，模型为更合理的候选赋予更高分数 [24]。

这些设计明确了自动驾驶汽车场景下行人预测中的一个重要观点：与其将多模态性表示为一条经回归得到的单一路径，不如将其表示为在相互竞争的运动假设之间进行选择。离散化为预测与规划之间提供了自然的接口。规划器在评估碰撞风险和安全应对措施时，往往会考察有限数量的候选行人运动。不过，在行为建模中，离散化也带来了必须解决的技术挑战。离散动作集可能十分密集且具有对称性，类别频率也可能不均衡。此外，彼此接近的备选项可能是近似替代项，其效用共享未观测到的组成部分。这些特性往往会加剧备选项之间的相关性，并削弱对相关结构的可识别性，尤其是当这些结构依赖分析者强行施加的几何约束时。因此，当选择集被定义为由微动作构成的结构化网格时，建模的关键问题便不再是多模态性是否存在，而是如何捕捉局部相似性和跨备选项相关性，从而使概率分布和误差在局部保持一致。

2.3 离散选择中备选项之间的相关性

在随机效用模型中，MNL 仍然是应用最广泛的基准模型，因为它具有封闭形式且易于解释。其主要局限在于无关备选项独立性这一性质，而该性质由独立同分布的 I 型极值误差 [5] 所隐含。在密集且具有结构的选择集中，由于某些备选项在行为意义上较为接近，独立性可能变得不切实际。例如，备选项之间可能具有空间邻近性，或在速度和航向变化方面具有相似性。此类备选项往往共享一些未观测属性。当存在这种相关性时，MNL 可能会通过在不相似的备选项之间过于激进地重新分配概率分布，从而错误地刻画替代模式。

已有两大类方法被用于放宽独立性假设。基于模拟的开放形式模型（例如多项Probit模型和混合Logit模型）能够容纳灵活的误差相关性和异质性。然而，这些模型通常需要复杂的协方差设定，并需要进行基于模拟的似然评估。对于重复估计以及规模较大或较复杂的选择集，这在计算上可能代价高昂[5]。广义极值模型族中的封闭形式模型通过解析定义的生成函数，在保持可处理性的同时，为相关效用提供了一种替代方案 [5]。经典例子包括嵌套Logit模型和更一般的交叉嵌套结构。这些结构能够在部分备选项之间引入相关性。实际难点在于，封闭形式的相关性要求分析人员定义、论证并落实相似性结构，以决定备选项如何共享嵌套。此外，当选择集密集且相似性的几何关系模糊时，设计选择可能会主导结果

对于离散化运动选择集，这些问题尤为关键。当备选项之间仅相差细微微调时，相关性是内在存在的。然而，正确的相关拓扑往往并不显而易见。在这种情况下，评估目标不仅是改善拟合效果，还要实现行为上连贯的替代模式。换言之，概率分布和误分类应集中在相邻备选项之间，这些备选项代表了对观测行为合理的细微变体。因此，这直接推动了空间与度量相关模型的发展，也推动了通过学习方法从数据中推断跨备选项结构的研究。

2.4 行人运动与相关备选项的离散选择模型

离散选择模型已广泛应用于交通运输领域，用于描述决策过程并获得可解释的行为参数。在行人动力学研究中，该框架被直接用于短时域步行决策，将下一步建模为在空间定义的移动备选项中进行选择。Antonini 等人提出了一种行人步行动力学的离散选择表述，对环境进行空间离散化，并利用视频跟踪轨迹估计了交叉嵌套和混合嵌套 Logit 模型 [25]。Robin 等人进一步推进了这一研究方向，提出、估计并验证了一种行人步行行为模型，该模型区分了不受约束的行为与受交互约束的行为 [26]。他们采用交叉嵌套 Logit 结构来捕捉空间相关性。在道路穿越研究中，离散选择模型也被用于描述车辆引发的危险和异质性条件下骑行者与行人的微观行为，例如采用 MNL 和潜类别设定来建模环岛人行横道处的穿越决策 [27, 28]。最近，研究者利用混合学习型离散选择模型，基于自然驾驶数据对自动驾驶车辆交互过程中行人移动的调整进行建模，同时保留了基于效用的可解释性 [29]。

下一步运动选择的一项关键挑战，是如何表示空间上或行为上相似的备选项之间的相关性。在密集且结构化的动作网格中，相邻备选项天然互为近似替代项，也可能具有共同的未观测属性。这可能违反 MNL [5] 的独立性假设。广义极值模型族中的封闭形式模型通过结构化误差分量引入相关性，同时保留易于处理的选择概率。空间 GEV 形式通过依据邻接性或基于距离的关联规则[6–9]将备选项分配至重叠巢中，从而将相似性转化为模型结构。这些模型适用于高频运动选择，因为它们兼具可解释性，并能计算解析概率。然而，其表现取决于分析者指定的关联设计是否符合数据中实际存在的局部替代模式。

当选择集规模较小、具有对称性且排列紧密时，连接几何结构可能难以明确识别，而重叠巢可能会将相关性分散到许多分量中。这可能会削弱巢参数对预测概率分配的实际影响。

基于学习的离散选择混合模型通过直接从数据中学习跨选项效应，同时保留行为效用骨干，从而降低了对分析者设定的相关结构的依赖。ResLogit 在 Logit模型中加入残差层，以学习非线性交叉效应和未观测结构，同时保留可解释的线性效用成分 [30]。在结构化运动网格中，相似性具有局部性，但也取决于上下文。残差学习能够捕捉相邻动作之间系统性的概率重新分配，而不牺牲可解释性。因此，在离散化行人运动选择场景中，将空间 GEV 模型与 ResLogit 进行比较，可以直接检验：在高频情况下，分析者设定的度量相关性是否仍然充分，抑或学习得到的残差修正能否更好地表示密集动作空间中的邻近性诱导的相关性。

2.5 研究空白

现有关于行人运动预测和行人步行行为的研究，在行为可解释性、空间相关性建模与高频动作离散化的交汇处仍存在空白。首先，自动驾驶汽车场景下的轨迹预测文献主要聚焦于利用高容量的基于序列和图的神经网络架构进行连续坐标预测。这些模型虽然预测性能出色，但通常没有提供明确的行为决策规则，也没有刻画结构化移动选项之间的替代模式。因此，难以解读风险、接近程度或目标导向之间的权衡如何改变相互竞争的微动作的相对可能性。其次，离散选择模型已成功应用于行人步行与过街行为，包括短期步伐决策和考虑交互的移动调整。然而，现有大多数应用要么依赖施加选项间独立性的 MNL 设定，要么采用为位置选择等较大空间选择集而设计的空间交叉嵌套结构。这些相关结构在密集、对称且规模较小的动作网格中的表现仍未得到充分研究。第三，空间 GEV 形式通过分析者指定的邻接性或距离衰减规则引入相关性。当备选项在构造上高度相似时，这些连接设计可能难以得到充分识别，尽管它们在分析上较为方便。离散化运动网格中就可能出现这种情况。在此类场景下，尚不清楚预先设定的空间嵌套结构是否会在 MNL 基线之外实质性地影响替代模式。最后，近期基于学习的离散选择混合模型提供了一种数据驱动方法，能够捕捉跨选项相关性，同时保留具有可解释性的效用基础。然而，

在具有结构化动作空间的高频行人运动选择场景中，这些模型相较于空间 GEV 模型的表现尚未得到系统评估。因此，我们明确提出一个方法论上的空白：分析者施加的空间相关结构是否足以表示密集行人移动网格中的邻近性诱导相关性，抑或基于残差学习的校正能否更符合行为规律地表示局部替代，这些问题仍未得到解答。本文针对这一空白，将行人下一步运动选择表述为空间离散选择问题，并在同一离散化运动框架内直接比较 MNL、空间 GEV 模型（SCL、GSCL、SCNL 和 GSCNL）以及 ResLogit。

3 方法

本研究提出了一种用于行人运动预测的离散选择模型，旨在剖析在密集 3×3 移动网格（图 1）中备选项相关性的表现。关于具有时间依赖和更丰富交互情境的多步预测扩展，将留待后续研究。

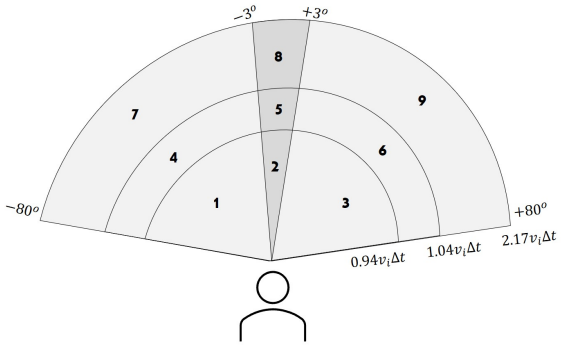

图 1：行人空间选择集网格。

3.1 数据集

使用了两个公开可用的轨迹数据集——nuScenes [20] 和 Argoverse 2 [21]，它们以 1 秒的决策间隔记录了行人与自车自动驾驶车辆之间的自然交互。基于我们先前提出的 ResLogit 框架（我们使用 nuScenes 数据集对行人速度调整进行建模，并定义加速和减速备选项（两种选择）），[29]，我们从两个方面扩展了这一设定。首先，除了 nuScenes 数据集外，我们还纳入了 Argoverse 2 数据集。其次，我们将下一步选择集从仅包含速度调整扩展为一个 3×3 移动网格，该网格联合表示速度调整（减速、保持速度、加速）和航向变化（左转、保持方向、右转）。每个

表1：观　　测到的移动选择计数（筛选至定义的 3×3网格前后）　　.

	Argoverse 2	nuScenes
决策步总数（原始）	1133	2170
排除的步数（网格外或最后一步）	270	340
处理后的决策步数（有效 1–9）	863	1830
选择1	65	180
选择2	55	222
选择3	92	136
选择4	81	150
选择5	144	398
选择6	109	150
选择7	110	155
选择8	106	266
选择9	101	173

选择项表示行人在下一时间步可能到达的位置（即选择）。图1 展示了空间移动选择集网格。每个观测到的选择项表示行人的下一步移动位置，并由在 $t+1$ 时计算的两个变量来刻画：速度相对变化和航向相对变化。这两个变量共同将观测到的位置映射到空间网格的九个单元之一。网格边界根据轨迹数据中单步速度和航向变化的观测分布，通过经验方法确定。类似框架的选择集边界构建详情见 [28, 31]。有些步骤无法被赋予有效标签。当推定的速度变化比率或航向变化超出预先定义的网格边界，或观测对应于行人轨迹的最后一个时间步且不存在下一步时，就会出现这种情况。这些步骤会从模型估计中排除。表 1 汇总了提取的决策步总数、排除数量以及有效标签的分布。对于 Argoverse 2，提取了 1,133 个决策步（即有效的观测选择项），筛选后保留 863 个。对于 nuScenes，提取了 2,170 个决策步，筛选后保留 1,830 个。对于所有保留的决策步，均在每个决策时刻计算运动学、空间和交互变量，并将其用作离散选择模型的输入。

3.2 模型结构

令 $t\in\{1,\dots,N\}$ 表示决策步（即时间步），令 $i\in\mathcal{C}=\{1,\dots,J\}$ 表示$J=9$ 网格中的 3×3 移动备选项。备选项 i 在决策步 t 的总效用为

$$U_{it}=V_{it}+\varepsilon_{it}, \tag{1}$$

其中， V_{it} 为系统效用部分， ε_{it} 表示未观测影响。在MNL模型下， ε_{it} 服从独立同分布的I型极值分布。选择概率表示为

$$P_{it}^{\mathrm{MNL}} = \frac{e^{V_{it}}}{\sum_{j \in \mathcal{C}} e^{V_{jt}}}. \tag{2}$$

为放松空间备选项的独立性，我们考虑空间广义极值族。误差项的联合分布由GEV生成函数 $G(\cdot)$ [5]生成。遵循SCL模型 [6], ，相关性通过重叠的成对嵌套来表示。对于每个满足 $i < m$的无序对（i, m），定义嵌套（im），其分配参数为$\alpha_{i,im}$ 和$\alpha_{m,im}$，且对每个 i满足 $0 < \alpha_{i,im} < 1$ 和$\sum_{m \neq i} \alpha_{i,im} = 1$ 。空间交叉嵌套Logit生成函数由下式给出

$$G\big(e^{V_{1t}}, \ldots, e^{V_{Jt}}\big) = \sum_{i=1}^{J-1} \sum_{m=i+1}^{J} \Big[\big(\alpha_{i,im} e^{V_{it}}\big)^{1/\lambda} + \big(\alpha_{m,im} e^{V_{mt}}\big)^{1/\lambda} \Big]^{\lambda}, \tag{3}$$

其中 $\lambda \in (0, 1]$ 为嵌套系数，当 $\lambda = 1$时，模型退化为MNL。

给定 $G(\cdot)$，广义极值类下的选择概率可表示为

$$P_{it} = \frac{e^{V_{it}} \, \dfrac{\partial G}{\partial e^{V_{it}}}}{G(e^{V_{1t}}, \ldots, e^{V_{Jt}})}. \tag{4}$$

对于式（3）中的空间交叉嵌套Logit生成函数，概率可表示为对成对嵌套求和 [6]:

$$P_{it}^{\mathrm{SCL}} = \sum_{m \neq i} P_t(i \mid im)\, P_t(im). \tag{5}$$

选择嵌套项（im）中 i 的条件概率为

$$P_t(i \mid im) = \frac{\big(\alpha_{i,im} e^{V_{it}}\big)^{1/\lambda}}{\big(\alpha_{i,im} e^{V_{it}}\big)^{1/\lambda} + \big(\alpha_{m,im} e^{V_{mt}}\big)^{1/\lambda}}. \tag{6}$$

我们将成对包容值定义为

$$S_{im,t} = \big(\alpha_{i,im} e^{V_{it}}\big)^{1/\lambda} + \big(\alpha_{m,im} e^{V_{mt}}\big)^{1/\lambda}. \tag{7}$$

则选择嵌套（im）的概率为

$$P_t(im) = \frac{S_{im,t}^{\lambda}}{\sum_{s=1}^{J-1} \sum_{l=s+1}^{J} S_{sl,t}^{\lambda}}. \tag{8}$$

在SCL模型中，分配使用邻接指标来定义 ω_{im} 等于1，若备选项 i与 m 空间相邻，否则为0 [6]:

$$\alpha_{i,im} = \frac{\omega_{im}}{\sum_{s \neq i} \omega_{is}}. \tag{9}$$

GSCL模型用基于距离的分配规则替代邻接性，使相关性随距离增加而衰减 [7]:

$$\alpha_{i,im} = \frac{d_{im}^{\vartheta}}{\sum_{s \neq i} d_{is}^{\vartheta}}, \qquad \vartheta < 0, \tag{10}$$

其中， d_{im} 是空间选择集内备选项 i 与 m之间的距离。

SCNL模型允许在预定义的嵌套类别 [8]之间使用多个嵌套系数。令 $k \in \{1, \ldots, K\}$ 表示嵌套类别的索引，并令 λ_k 表示类别k的嵌套系数。对于每个成对嵌套（im），定义 $k(im)$ 为分配给备选项对（i, m）的类别，并设定$\lambda_{im} \equiv \lambda_{k(im)}$。选择概率表示为对成对嵌套求和:

$$P_{it}^{\mathrm{SCNL}} = \sum_{m \neq i} P_t^{\mathrm{SCNL}}(i \mid im)\, P_t^{\mathrm{SCNL}}(im). \tag{11}$$

给定嵌套（im）时选择 i 的条件概率为

$$P_t^{\mathrm{SCNL}}(i \mid im) = \frac{\left(\alpha_{i,im} e^{V_{it}}\right)^{1/\lambda_{im}}}{\left(\alpha_{i,im} e^{V_{it}}\right)^{1/\lambda_{im}} + \left(\alpha_{m,im} e^{V_{mt}}\right)^{1/\lambda_{im}}}. \tag{12}$$

SCNL的成对包容值可表示为

$$S_{im,t}^{\mathrm{SCNL}} = \left(\alpha_{i,im} e^{V_{it}}\right)^{1/\lambda_{im}} + \left(\alpha_{m,im} e^{V_{mt}}\right)^{1/\lambda_{im}}. \tag{13}$$

那么，嵌套概率为

$$P_t^{\mathrm{SCNL}}(im) = \frac{\left(S_{im,t}^{\mathrm{SCNL}}\right)^{\lambda_{im}}}{\sum_{s=1}^{J-1} \sum_{l=s+1}^{J} \left(S_{sl,t}^{\mathrm{SCNL}}\right)^{\lambda_{sl}}}, \tag{14}$$

其中 $\lambda_{sl} \equiv \lambda_{k(sl)}$。

GSCNL模型通过从数据中估计分配模式，而不是使用邻接矩阵或距离衰减规则将其固定，进一步提高了灵活性 [9]。分配参数采用候选嵌套成员关系上的伪 Logit 形式进行设定:

$$\alpha_{i,im} = \frac{e^{\sum_p \delta_p I_{imp}}\, I_{im}}{\sum_{q \neq i} e^{\sum_p \delta_p I_{iqp}}\, I_{iq}}. \tag{15}$$

其中 I_{imp} 表示对（i, m）这一对是否属于嵌套类别 p, I_{im} 表示（i, m）是否构成一个嵌套，而 δ_p 是待估参数，用于控制各类别间的分配。嵌套系数因类别而异， $\lambda_k \in (0,1]$。由此得到的选择概率遵循公式（11）–（14）中的 SCNL 分解，分配参数由公式（15）给出。

ResLogit [18] 首先计算 MNL 系统效用 $\mathbf{V}_t = (V_{1t}, \ldots, V_{Jt})^\top$，然后依次应用一系列残差层以获得校正效用。我们定义 $\mathbf{h}_t^{(0)} = \mathbf{V}_t$ ，并更新

$$\mathbf{h}_t^{(m)} = \mathbf{h}_t^{(m-1)} - \text{softplus}\left(\mathbf{h}_t^{(m-1)}\mathbf{W}^{(m)}\right), m = 1, \ldots, M, \quad (16)$$

其中，$\mathbf{W}^{(m)} \in \mathbb{R}^{J\times J}$ 是可学习的权重矩阵，$\text{softplus}(x) = \ln(1 + e^x)$ 逐元素应用。校正后的观测效用为 $\mathbf{U}_t = \mathbf{h}_t^{(M)}$ ，定义 $\mathbf{g}_t = \mathbf{U}_t - \mathbf{V}_t$可得 $U_{it} = V_{it} + g_{it}$。假设校正效用周围的误差服从独立同分布的 I 型极值分布，则隐含的选择概率为

$$P_{it}^{\text{ResLogit}} = \frac{e^{U_{it}}}{\sum_{j\in\mathcal{C}} e^{U_{jt}}} = \frac{e^{V_{it}+g_{it}}}{\sum_{j\in\mathcal{C}} e^{V_{jt}+g_{jt}}}. \quad (17)$$

当残差组件恒为零时，模型便退化为 MNL。

3.3 模型设定

表2 总结了各模型所包含的组成部分，并突出展示了闭式空间 GEV 公式与基于学习的 ResLogit 之间的差异。在所有设定中，系统效用 V_{it} 均由同一组移动和交互变量构成（表3）。各模型对备选项之间相关性和替代关系的表征方式各不相同。在空间 GEV 模型中，这些关系通过分配参数 $\alpha_{i,im}$ 和嵌套系数 λ（或 λ_k）来刻画。在 ResLogit 中，则通过对效用向量进行残差校正来刻画。

ResLogit 模型中的系统效用采用简约设定，包含八个参数，并预先定义了与 3×3 移动网格一致的备选项映射：

$$\begin{aligned} V_{it} = {} & \beta_{\text{dec}} I_i^{\text{dec}} + \beta_{\text{acc}} I_i^{\text{acc}} + \beta_{\text{turn}} I_i^{\text{turn}} + \beta_{\text{ddist}}\, \text{ddist}_{it} \\ & + \beta_{\text{ddir}}\, \text{ddir}_{it} + \beta_{\text{front}}\, \text{FCRP}_t\, I_i^{\text{dec}} + \beta_{\text{rear}}\, \text{RCRP}_t\, I_i^{\text{acc}} \\ & + \beta_{\text{dist}} \frac{1}{D_t}\left(I_i^{\text{dec}} + I_i^{\text{acc}}\right). \end{aligned} \quad (18)$$

减速指示变量适用于备选项 $\{1,2,3\}$，加速指示变量适用于 $\{7,8,9\}$，转向指示变量适用于 $\{1,3,4,6,7,9\}$，而距离倒数项仅适用于 $\{1,2,3,7,8,9\}$。

表 2：各设定中包含的模型组成部分。

模型	I^{dec}	I^{acc}	I^{turn}	FCRP	RCRP	$1/D$	距离	距离	方向	α	λ
ResLogit √		✓	✓	✓	✓	✓	✓	✓			
MNL	✓	✓	✓	✓	✓	✓					
SCL	✓	✓	✓	✓	✓	✓				✓	✓
GSCL	✓	✓	✓	✓	✓	✓				✓[a]	✓
SCNL	✓	✓	✓	✓	✓	✓				✓	✓[b]
GSCNL	✓	✓	✓	✓	✓	✓				√[c]	√[b]

[a] GSCL 使用基于距离的分配（距离衰减）$\alpha_{i,\ im}$ 而非邻接性。[b] SCNL 和 GSCNL 允许在预定义的嵌套类别中使用多个嵌套系数。[c] GSCNL 使用基于候选嵌套成员关系的伪 Logit 形式，根据数据估计分配参数$\alpha_{i,\ im}$。

表 3：模型变量和参数的定义。

符号	定义
I_i^{dec}	减速备选项指示符（网格行：减速）。
I_i^{acc}	加速备选项指示符（网格行：加速）。
I_i^{turn}	转向备选项指示符（左侧或右侧锥桶）。
D_t	决策步 t 的自动驾驶车辆与行人的距离（指定为 $1/D_t$）。
FCRP_t	决策步 t 的前向碰撞风险接近度（前向强度按 $1+$闭合碰撞时间$_t$缩放）。
RCRP_t	决策步 t 的后向碰撞风险邻近度（后向强度按 $1+$闭合碰撞时间$_t$缩放）。
ddist_{it}	步骤 t时备选项 i 的备选项特定的目的地吸引距离指标。
ddir_{it}	步骤 t时备选项 i的备选项特定的目的地吸引方向指标。
$\alpha_{i,im}$	分配参数，将备选项 i 的一部分分配给空间中的成对嵌套（im）广义极值模型。
λ	控制嵌套内相关性的嵌套系数（SCL、GSCL）。
λ_k	类别特定嵌套系数（SCNL、GSCNL）。

碰撞角定义为行人速度向量与从行人指向自动驾驶车辆的视线向量之间的方位角。在各扇区内，利用该角度的余弦值将角度映射为前后扇区方向强度指标（0 到 1）。数值越大表示方向对齐程度越高。随后，将这些方向强度与一种称为闭合碰撞时间（CTTC）的交通冲突指标相结合 [31]。这样做是为了构建碰撞风险邻近度指标：当自动驾驶车辆在方向上更加显著且时间上更加接近时，该指标便会增大。前向碰撞风险邻近度（FCRP）和后向碰撞风险邻近度（RCRP）变量的计算公式如下：

$$\text{FCRP}_t = \frac{\tau_t^{\text{front}}}{1+\text{CTTC}_t}, \qquad \text{RCRP}_t = \frac{\tau_t^{\text{rear}}}{1+\text{CTTC}_t}. \tag{19}$$

其中，τ_t^{front}为前扇区方向强度，$\tau_{\text{后方}t}$为后扇区方向强度。前扇区风险仅适用于备选项 $\{1,2,3\}$，因为这些对应减速备选方案。这使模型能够捕捉行人减速的情况，即

自动驾驶车辆从前方接近时。后方扇区风险仅适用于备选项 $\{7, 8, 9\}$，因为这些对应加速备选方案。这使模型能够捕捉自动驾驶车辆从后方接近时行人加速的情况。

目的地吸引分量 ddist_{it} 和 ddir_{it} 针对每个备选项定义，并在全部九个备选项中使用通用系数 [28]。ddist_{it} 是备选项 i的质心与目的地之间的距离，单位为米。目的地近似为行人在该轨迹段中最后一次观测到的位置。ddir_{it} 是行人在决策步 t的当前位置处两条线之间的角度偏差，单位为度。第一条线连接当前位置与目的地，第二条线连接当前位置与移动备选方案 i的质心。

对于 MNL 和空间 GEV 模型（SCL、GSCL、SCNL 和 GSCNL），使用方程（18）中的相同系统效用，但不包含目的地吸引项 ddist_{it} 和 ddir_{it} 。这些模型通过 GAUSS 26 采用最大似然法进行估计。备选项之间的相关性通过分配参数 $_{,im}$ 以及嵌套系数 λ或 λ_k引入，如表 2所总结。具体而言，SCL 使用基于邻接性的分配（方程（9）），并采用单一嵌套系数；GSCL 将邻接性替换为基于距离的分配（方程（10））；SCNL 则允许不同嵌套类别具有多个嵌套系数。GSCNL 进一步通过伪 logit 分配规则（方程（15））根据数据估计分配模式。

ResLogit 使用基于随机梯度的优化方法在 Python 中进行估计。方程（**18**）中的系统效用向量$_t = (V_{1t}, \ldots, V_{Jt})^\top$ 经过方程（16）中的残差校正层处理，得到校正效用$\mathbf{U}_t$ ，概率则根据方程（17）计算。进行估计时，使用带梯度裁剪（范数为 5.0）和 ℓ_2 权重衰减的 Adam优化器，通过最小化交叉熵损失（等价于最大化多项对数似然）来学习参数。使用贝叶斯优化（高斯过程最小化），以验证对数似然为目标，对学习率、轮次数、残差层数 M 和权重衰减进行超参数调优。原始数据模型选定的配置采用学习率 2.54×10^{-2}, ℓ_2，权重衰减为 10^{-2}, $M = 2$ ，残差层数为 M，训练轮次为 500。

4 结果与讨论

表4 展示了 ResLogit 和空间 GEV 模型（MNL、SCL、GSCL、SCNL、GSCNL）在训练样本（$N = 1$，850）上的拟合指标。从表中可以看出，相较于 MNL，模型的改进幅度不大。平均对数似然（LL）从 -2.14696 （MNL）增加到 -2.13728 （GSCL），AIC 则从 7，955.75 降至 7，923.94。这表明，加入分析人员指定的邻近相关性（α 和 λ 结构，可能只能有限地提升这个稠密 3×3 移动网格在

当前样本量下的表现。ResLogit 的拟合效果显著更好，其平均对数似然−1.71634和 AIC 为 6，690.47。

拟合效果的提升反映了模型纳入了学习得到的残差交叉效应，这些效应会在线性部分之外调整效用。拟合差异的幅度也具有参考价值。空间 GEV 模型相较于 MNL，平均对数似然的提升不足 0。01。ResLogit 的拟合效果每个观测值约提升 0。43。在密集的离散移动网格中，平均对数似然的微小变化也可能导致相邻备选项之间的概率重新分配出现明显差异。图 2 中的混淆矩阵表明，在这种情形下，GEV 结构并未显著改变预测的替代模式。因此，ResLogit 的改进并非仅仅是统计假象。它带来了预测行为上的定性变化：概率分配不再集中于少数几个主导类别，而是更均匀地分布在相邻备选项之间（图 3）。

表 4：估计样本上的模型拟合效果（原始数据训练集，$N = 1,850$）。

模型	k	LL	平均 LL	AIC
MNL	6	-3,971.8760	-2.14696	7,955.75
SCL	7	-3,957.7975	-2.13935	7,929.60
GSCL	8	-3,953.9680	-2.13728	7,923.94
SCNL	8	-3,957.7050	-2.13930	7,931.41
GSCNL	9	-3,955.4295	-2.13807	7,928.86
ResLogit	8	-3,175.2334	-1.71634	6,366.46

一种合理的解释是，3×3 网格既密集又高度对称。这使行为变异集中体现为相邻备选项之间的微小差异。因此，在此类情形下，分析者指定的相关结构可能难以得到充分识别。SCL 和 GSCL 中的成对巢分配规则施加了特定的依赖结构。鉴于现有样本量和类别不平衡，数据提供的信息可能不足以明确支持某一种空间关联设计优于其他设计。此外，重叠巢将相关性分散到了许多成对分量中。当系统效用已主导备选项的排序时，这可能会削弱嵌套系数对预测概率的实际影响。因此，空间 GEV 模型的边际改进并不意味着基于邻近性的相关性不存在。相反，这些结果表明，此处评估的特定闭式 GEV 参数化——基于预先定义的邻接性或距离衰减连接规则——灵活性不足，无法再现移动网格中的局部替代经验模式。相比之下，ResLogit 通过直接在效用向量上学习跨备选项修正，改善了拟合效果。

该模型会学习哪些相邻备选项相对于实际发生的移动最常被误分类。

4.1 混淆矩阵与分类指标

为考察空间 GEV 模型的预测性能，我们采用最大概率（MaxP）预测，即在每个决策步选择预测选择概率最高的备选项。图 2显示，GEV 设定将预测集中在少数几个备选项上，使大部分 3×3 移动网格归结为占主导地位的选择。这与表 4中的边际改进一致。相较于 MNL 基线，在这种情况下，估计得到的相关结构不足以（或无法充分识别到足以）实质性改变预测的替代模式。

相比之下，ResLogit 模型生成的预测分布更广（图3），大多数误差出现在相邻的移动备选项之间。这种误差结构在行为层面与移动网格中的局部相似性相符。表 5量化了这一模式。原始训练集上的 top-1 准确率为 0.3557，原始测试集上为 0.3215。此外，top-3 准确率最高增至 0.7438（训练集）和 0.6714（测试集）。平衡准确率和宏平均 F1 仍低于加权指标，这反映了九个备选项之间存在类别不平衡和召回率不均的问题。

从自动驾驶车辆规划的角度来看，预测误差的结构至关重要。在离散网格中，将具体单元格分类错误，其危害程度因误差类型而异。混淆集中在相邻单元格时，通常对应于速度调整或航向变化的微小偏差。这可能更符合人体运动变异性和感知噪声的特点。相比之下，跨越网格的误差则对应着性质迥异的动作。ResLogit 的混淆矩阵显示，大多数误差都局限于局部。这与以下假设相符：残差层学会了对 MNL 进行邻近一致性校正。

表5还揭示了若干其他现象。首先，top-1 准确率中等，表明在自然场景变异性下，准确预测备选项仍然困难。如果相邻备选项之间仅存在细微的微调差异，这一结果便在意料之中。其次，top-1 准确率与 top-3 准确率之间的显著差距也颇具启示意义。尽管模型并非总能预测出确切单元格，但它通常会为一个由合理的邻近移动构成的小型局部集合赋予较高概率。对于需要评估多个候选行人运动，而非依赖单一点预测的自动驾驶车辆系统而言，这种行为可能具有实际意义。

第三，较低的平衡准确率和宏平均 F1 表明，少数移动类别更难以识别，这与罕见

表 5： ResLogit 在原始数据和合成数据集（训练集和测试集）上的预测指标 .

数据集	划分	N	平均对数似然	前 1 名	前2名	前3名	平衡准确率	F1（宏平均）	F1（加权）
原始数据	训练集	1,850	-1.71634	0.355676	0.599459	0.743784	0.317683	0.316760	0.329193
原始数据	Test	843	-1.84081	0.321471	0.533808	0.671412	0.287930	0.281386	0.296082
合成训练集	35,000		-0.49340	0.808971	0.950057	0.984514	0.761628	0.767302	0.808282
合成测试集		15,000	-0.50019	0.807467	0.948333	0.982933	0.754620	0.762970	0.806300

表 6：ResLogit 线性效用系数估计值。

	原始数据（聚类自助法）			合成数据（独立同分布自助法）		
变量	系数	S.E.	p	系数	S.E.	p
β_{dec}	1.091490	1.257677	0.386576	1.010338	0.028384	0.000000
β_{acc}	0.471755	0.862350	0.584988	0.453966	0.036242	0.000000
β_{turn}	0.266480	0.229563	0.247188	0.226830	0.016002	0.000000
β_{dist}	0.033585	0.206108	0.870735	0.018264	0.008713	0.037334
β_{front}	0.035592	0.327723	0.913633	0.038941	0.012480	0.002076
β_{rear}	-0.119108	0.449637	0.791379	-0.119021	0.014455	0.000000
β_{ddist}	-3.177150	0.802500	0.000107	-2.996716	0.029279	0.000000
β_{ddir}	-1.280984	0.385602	0.001074	-1.200089	0.012576	0.000000

备选项代表性不足的情况一致。最后，合成结果起到了内部一致性检验的作用。当以更大的变异性生成特征，并从拟合模型中抽取选择结果时，模型性能显著提升（top-1 高于 0.80）。这表明，当数据中存在足够的异质性时，ResLogit 设定能够识别出明显的决策模式。自然场景样本上的较低性能，更可能是由于相邻备选项之间的行为区分度有限以及类别不平衡，而非数值不稳定性或模型设定错误。

4.2 线性效用系数的解释

表6 列出了公式 (18) 中针对经过处理的自然场景样本 (原始数据) 和合成生成样本 (合成数据) 估计的线性效用参数。

两种估计的符号相同，数值大小也接近，这支持对线性部分作出一致的行为解释。在两个数据集中，目的地吸引项主导了行为信号。 β_{ddist} 在原始数据（-3.177）和合成数据（-2.997）的估计中均为负值。

这意味着，ddist_{it} 较小（更接近目的地）的备选项具有更高的效用。 β_{ddir} 在原始数据（-1.281）和合成数据（-1.200）的估计中也均为负值。这表明，ddir_{it} 较小（与目的地方向对齐程度更高）的备选项具有更高的效用。这两个系数表明，行人偏好目标导向运动，并会对绕行以及偏离目的地方向的角度偏差进行惩罚。

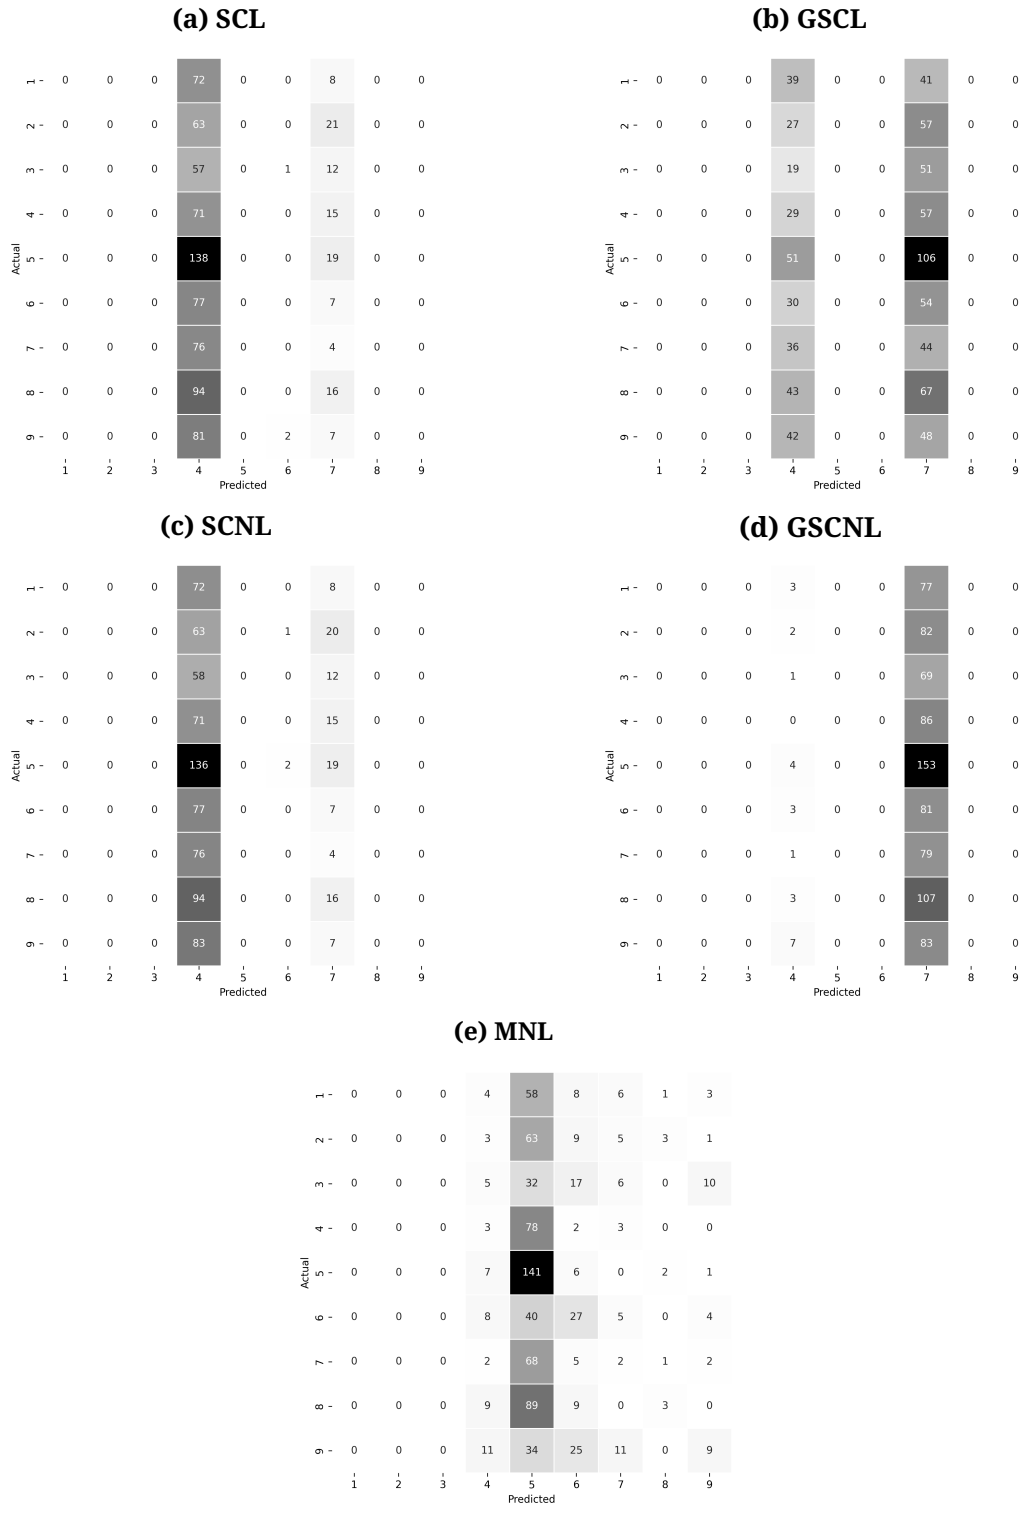

图2：使用最大概率（MaxP）预测的空间 GEV 模型混淆矩阵。

加速、减速和转向备选项特定常数刻画了加速、减速或转向的总体倾向，并且在两个数据集中符号保持一致。β_{dec} 和 β_{acc} 在两列中均为正，这表明减速备选项（$I_i^{\text{dec}} = 1$）和加速备选方案（$I_i^{\text{acc}} = 1$）相对于保持速度备选项获得了正向的基线效用偏移。

转向常数 β_{turn} 在两列中同样为正，这意味着转向备选项（$I_i^{\text{turn}} = 1$）相对于直行参考备选项获得正向效用偏移，尽管该偏移接近于零。这与短时域行人运动中在离散化 3×3 网格内常见小幅航向调整相一致。

交互项的行为如公式（18）所规定，仅影响其所映射的移动备选项。前方碰撞风险接近项以FCRP$_t$ I_i^{dec}的形式进入，且仅应用于减速备选项 $\{1, 2, 3\}$。后向碰撞风险邻近度项以RCRP$_t$ I_i^{acc}的形式进入，且仅应用于加速备选方案 $\{7, 8, 9\}$。接近程度项$\frac{1}{D_t}\left(I_i^{\text{dec}} + I_i^{\text{acc}}\right)$ 也仅影响速度变化备选项（减速或加速）。估计符号遵循这些映射，并在原始数据和合成数据估计中保持一致。 $\beta_{\text{dist}} > 0$ 表明更近的自动驾驶车辆距离会提高改变速度的效用。 $\beta_{\text{front}} > 0$ 表明更高的FCRP$_t$ 会提高减速备选项的效用。 $\beta_{\text{rear}} < 0$ 表明更高的RCRP$_t$ 会降低加速备选方案的效用。我们假设这些变量刻画了穿越过程中依赖于阶段的感知紧迫性。当前方的自动驾驶车辆在方向上显著且在时间上逼近时，前向碰撞风险接近度（FCRP$_t$）会提高感知威胁，并促使行人降低速度，这与 $\beta_{\text{front}} > 0$ 通过FCRP$_t$ I_i^{front}将效用转向减速备选项相一致。相比之下，后向碰撞风险邻近度（RCRP$_t$）可在穿越后期阶段被激活，此时交互已经结束（例如，自动驾驶车辆已移动到行人后方、更接近路缘入口时）。在这种情况下，行人提高速度的紧迫性较低，倾向于保持原有步速而非加速。这与 $\beta_{\text{rear}} < 0$ 通过RCRP$_t$ I_i^{rear}降低加速备选方案的效用相一致。最后，正的距离敏感度 $\beta_{\text{dist}} > 0$ 表明更近的自动驾驶车辆距离会提高改变速度（减速或加速）相对于保持速度的相对效用，从而刻画一种一般性的接近度诱发的速度调整倾向。

为了诊断自然场景样本中有限的信息性变异是否导致若干原始数据系数的统计支持较弱，我们通过从正态分布中抽样特征来生成合成数据集；这些分布根据原始训练集的均值和标准差进行校准，并将方差扩大 SIGMA MULT $= 1.5$。我们施加指示变量约束，并将连续变量限制在允许范围内。随后，我们根据在这些合成输入上计算出的拟合 ResLogit 概率，对合成选择进行抽样。此实验用于内部一致性诊断，而非外部验证。

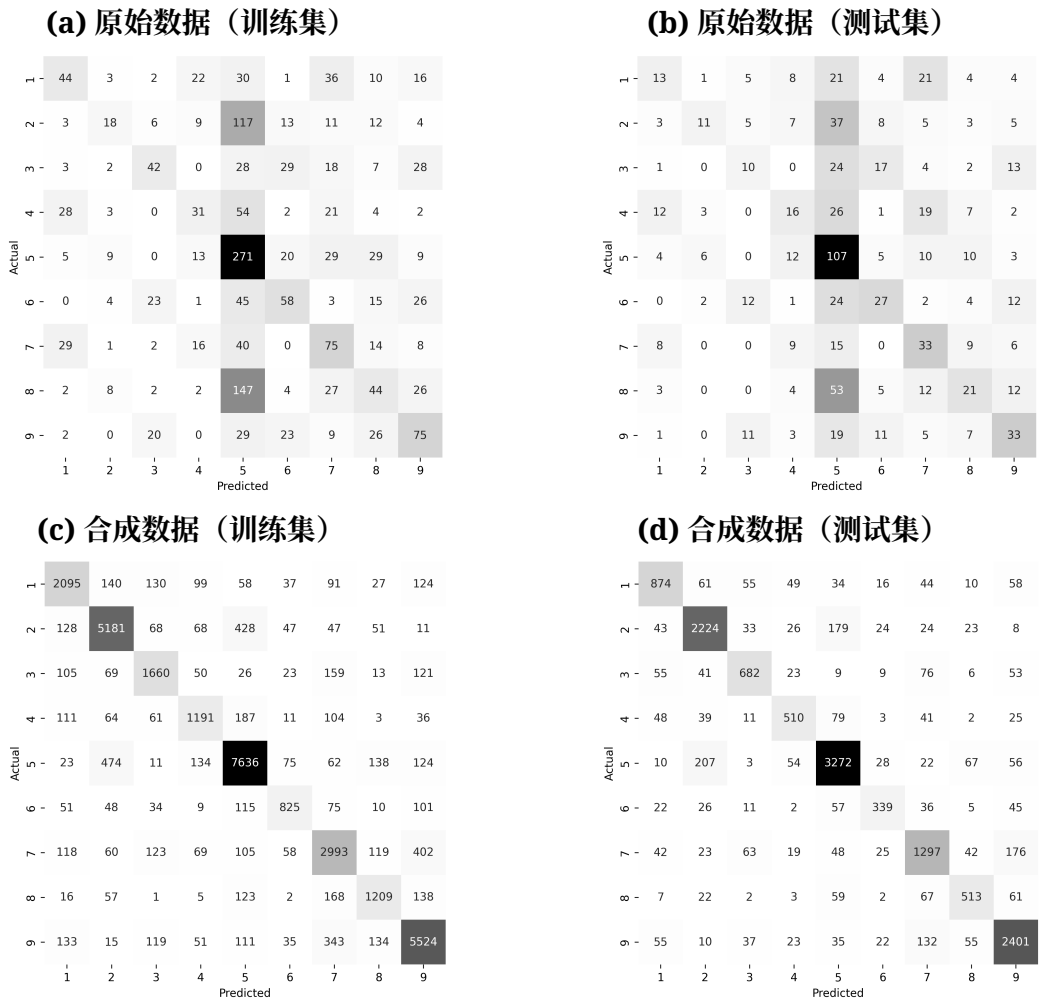

图3：ResLogit 在原始数据和合成数据上的混淆矩阵。

在这种合成方式下，预期准确率会更高、统计显著性会更强，因为变量是根据用于重新估计的同一模型类别生成的。尽管如此，合成结果支持一个具体结论：若干原始数据系数显著性较弱，可能是由样本中的异质性有限所致，而非数值不稳定性或估计错误。与此一致，合成数据上的重新估计显著降低了标准误，并得到了高度显著的系数；混淆矩阵也明显更趋于对角化（图 3），平衡准确率和宏平均 F1 均大幅提升（表 5）。

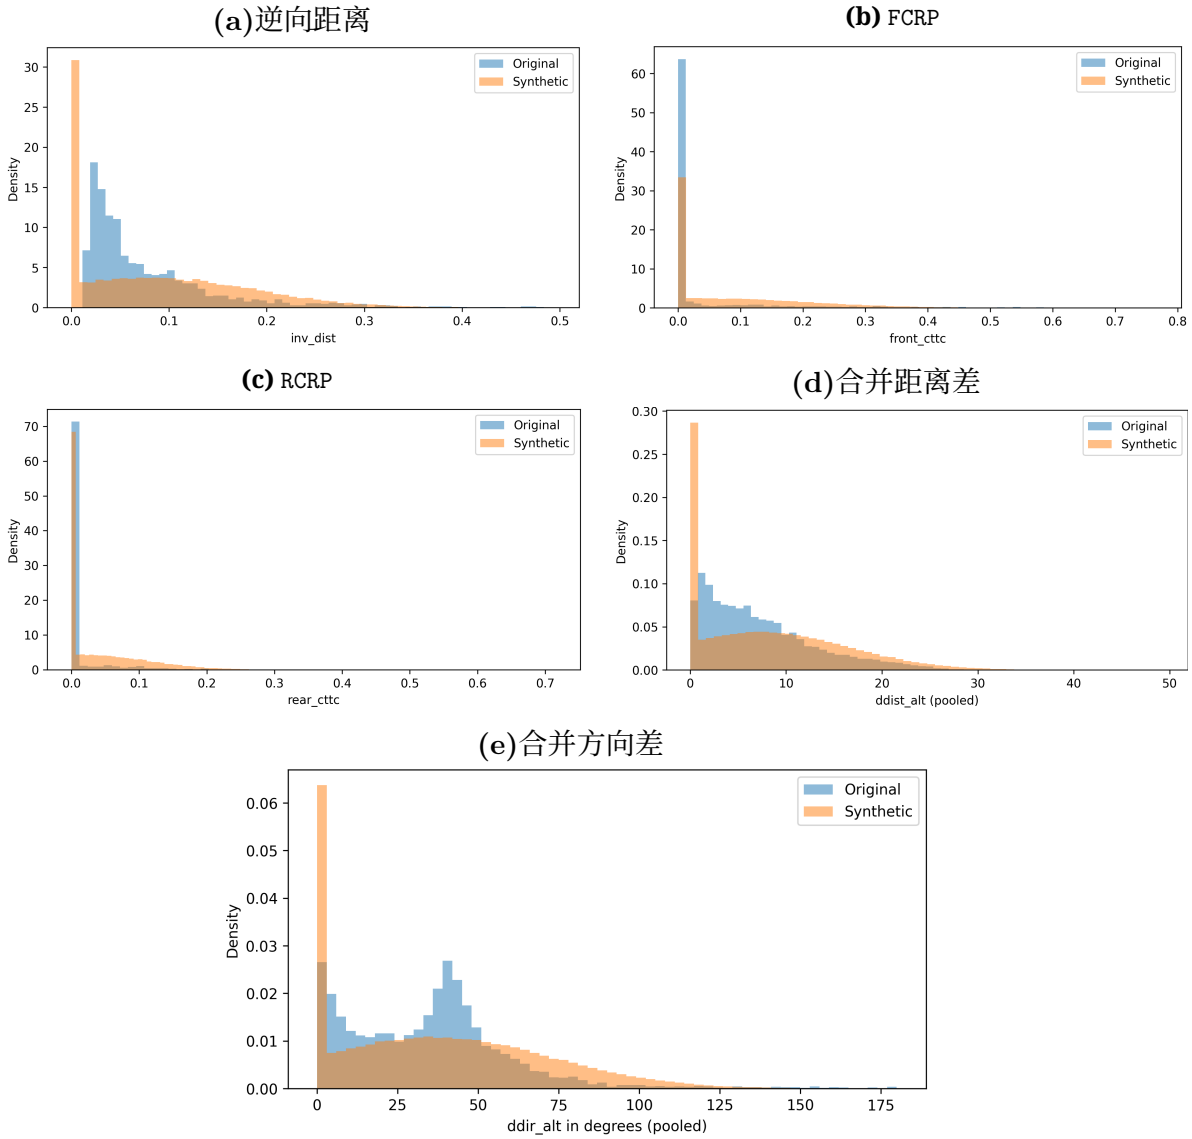

图 4：ResLogit 变量的原始数据与合成数据分布对比。ddist 和 ddir 图是对九个备选项进行合并后的结果。

5 结论

本文将自动驾驶车辆交互情境下，街区中段自然情境下的行人高频下一步运动建模为一种空间离散选择，其备选项为由速度和航向调整构成的 3×3 网格。随后，本文将经典空间 GEV 模型（SCL、GSCL、SCNL 和 GSCNL）与 ResLogit 进行比较。实证结果表明，在这种密集的高频场景中，通过空间 GEV 结构施加分析者指定的邻近相关性，相较于 MNL 仅带来有限提升（平均对数似然最多从-2.147 提高到 -2.137 ）。相比之下，ResLogit 显著改善了模型拟合（平均

对数似然为 -1.716），且其误差模式集中在相邻的移动备选项之间。这与离散化移动网格中的局部相似性相一致。

对于精确类别（top-1）预测，预测性能仍属中等，但在 top-k 评估下显著提升（测试集上的 top-1 为 0.321，top-3 为 0.671）。这表明，即使未能预测出确切单元格，模型通常也会为一小组局部且合理的下一步移动分配较高概率。尽管 ResLogit 引入了可学习残差层，该模型仍以行为离散选择表述为基础。线性效用保留了结构可解释参数，并明确界定了与速度和航向调整相关的备选项。残差组件发挥了校正机制的作用，捕捉预定义嵌套无法充分表示的备选项间依赖。从这个意义上说，该方法不同于直接回归未来坐标的轨迹预测模型。它在行动权衡层面保留了行为可解释性，同时利用学习提升拟合效果和局部替代的真实性。

根据对模型线性参数的解读，系数估计值表明，移动过程主要由目标导向驱动，同时受到交互压力的调节。目的地项显著为负，说明行人往往会持续朝目的地移动。这反映出，在穿越过程中，行人倾向于选择能够同时缩短与目的地的距离并减小角度偏差的备选项。交互项会改变速度变化备选项的相对效用。接近程度越高，行人调整速度而非保持速度的倾向越强。此外，前方风险会提高减速备选项的吸引力。后方风险对加速的影响为负。这与以下情况相符：车辆位于行人后方且交互即将结束时，行人加速的紧迫性会降低。ResLogit 的线性效用结构使这些解读成为可能，并且能够直接用行为术语表达；这正是我们采用离散选择表述的主要动机。

当前结论受到若干局限的制约。首先，提取的交互场景以自动驾驶车辆为中心，未明确建模行人周围与其他类型道路使用者的交互，也未纳入更丰富的场景上下文。这可能降低九种移动备选项之间的可分性。其次，该框架将决策视为短视的下一步选择，未表示时间依赖、记忆或潜在意图，尽管行人运动具有序贯性且依赖历史信息。第三，正如合成样本时所显示的，自然场景样本可能存在异质性较低的问题。这会限制少数移动类别的稳定估计，并降低平衡性能指标。最后，该建模设计捕捉了行人对自动驾驶车辆的反应，却未体现双向耦合，即车辆运动会同时适应行人行为。本研究应被视为一个基线研究。它在一致的效用设定下，分离出密集移动网格中的备选项相关性。这为后续拓展至

序贯多步预测和多智能体交互建模提供了基础。未来研究应通过纳入周边道路使用者和明确的交互情境，将选择框架拓展至多智能体场景。此外，应通过引入能够捕捉意图和短期动态的时间状态变量或注意力／记忆机制，放宽短视假设。还应采用耦合的行人与车辆建模方法，共同表示双方的相互适应，从而进一步提升行为真实性，并增强其在自动驾驶规划、让行和仿真流程中的适用性。

作者贡献

作者确认对本文的贡献如下：研究构思与设计：Al-Haideri, R.、Farooq, B.；数据整理：Al-Haideri, R.、Farooq, B.；结果分析与阐释：Al-Haideri, R.、Farooq, B.；论文初稿撰写：Al-Haideri, R.、Farooq, B.。所有作者均审阅了研究结果，并批准了论文最终版本。

利益冲突声明

作者声明，在本研究、作者身份和/或本文发表方面不存在任何潜在利益冲突。

资金支持

作者披露，本文研究、撰写和发表获得了以下经费支持：本研究由加拿大颠覆性交通技术与服务研究主席资助（CRC-2022-00480）。

参考文献

[1] Waldo R. Tobler. 模拟底特律地区城市发展的计算机动画。经济地理，46(2):234–240, 1970年。doi: 10.2307/143141.[2]Denis Bolduc、Bernard Fortin 和 Stephen Gordon. 空间相互依赖选择的多项Probit模型估计：两种新技术的实证比较。《国际区域科学评论》，20(1-2):77–101，1997年。doi: 10.1177/ 016001769702000105.[3] Kenji Miyamoto、V. Vichiensan、Naoki Shimomura 和 Antonio P´aez. 用于区位分析的结构化空间效应离散选择模型。《交通研究记录》，1898(1):183–190，2004年。doi: 10.3141/1898-22.

[4] Adam Weiss 和 Khandker Nurul Habib. 使用空间加权误差相关离散选择模型，探究停车换乘与即停即走接送站点选择的差异。《交通地理学杂志》，59:111–119，2017年。doi: 10.1016/ j.jtrangeo.2017.01.010.[5] Kenneth E. Train. 《模拟离散选择方法》。剑桥大学出版社，剑桥，2009年。[6] Chandra R. Bhat 和 Jessica Guo. 混合空间相关 Logit 模型：模型构建及其在居住选择建模中的应用。《交通研究*B*辑：方法论》，38(2):147–168，2004年。doi: 10.1016/S0191-2615(03)00005-5.[7] Ipek N. Sener、Ram M. Pendyala 和 Chandra R. Bhat. 在离散选择模型中考虑选择备选项间的空间相关性：居住地选择行为建模的应用。《交通地理学杂志》，19(2):294–303，2011年。doi: 10.1016/j.jtrangeo.2010.06.015.[8] Jose-Benito P´erez-L´opez、Margarita Novales 和 Alfonso Orro. 用于空间位置选择的空间相关嵌套 Logit 模型。《交通研究*B*辑：方法论》，161:1–12，2022年。doi: 10.1016/j.trb.2022.05.006.[9] Rulla Al-Haideri、Karim Ismail 和 Adam Weiss. 环岛骑行者过街行为：广义空间相关嵌套 Logit 模型。审稿中，2026年。[10] Alexandre Alahi、Kratarth Goel、Vignesh Ramanathan、Alexandre Robicquet、李飞飞和 Silvio Savarese. Social LSTM：拥挤空间中的人体轨迹预测。载于*IEEE*计算机视觉与模式识别会议（*CVPR*）论文集，第961–971页，2016年。[11] Agrim Gupta、Justin Johnson、李飞飞、Silvio Savarese 和 Alexandre Alahi. Social GAN：利用生成对抗网络生成社会可接受轨迹。载于*IEEE*计算机视觉与模式识别会议（*CVPR*）论文集，第2255–2264页，2018年。[12] Boris Ivanovic 和 Marco Pavone. Trajectron：基于动态时空图的概率多智能体轨迹建模。载于*IEEE/CVF*国际计算机视觉大会（*ICCV*）论文集，第2375–2384页，2019年。[13] Tim Salzmann、Boris Ivanovic、Prateek Chakravarty 和 Marco Pavone. Trajectron++：利用异构数据进行满足动态可行性的轨迹预测。《计算机视觉——*ECCV 2020*》，2020年。《计算机科学讲义》（LNCS）。[14] Jiyang Gao、Chen Sun、Hang Zhao、David Shen、Dragomir Anguelov、Changqing Li 和 Cordelia Schmid. VectorNet：从向量化表示中编码高精地图和智能体动态。载于*IEEE/CVF*计算机视觉与模式识别会议（*CVPR*）论文集，第11525–11533页，2020年。[15] Arash Kalatian 和 Bilal Farooq. 面向自动驾驶车辆的上下文感知行人轨迹预测框架。《交通研究*C*辑：新兴技术》，2022年。

[16] Amir Rasouli 和 John K. Tsotsos。与行人互动的自动驾驶车辆：理论与实践综述。*IEEE*智能交通系统汇刊，2019年。[17] F. G. Landry 等。自动驾驶车辆中的行人过街意图预测：综述。神经计算，2024年。[18] Melvin Wong 和 Bilal Farooq。ResLogit：用于数据驱动的选择建模的残差神经网络 Logit 模型。《交通研究*C*辑：新兴技术》，126:103050，2021年。doi: 10.1016/j.trc.2021.103050。[19] Kimia Kamal 和 Bilal Farooq。Ordinal-ResLogit：用于有序选择的可解释深度残差神经网络。《选择建模杂志》，50:100454，2024年。doi: 10. 1016/j.jocm.2023.100454。[20] Holger Caesar、Varun Bankiti、Alex H. Lang、Sourabh Vora、Venice Erin Liong、Qiang Xu、Anush Krishnan、Yu Pan、Giancarlo Baldan 和 Oscar Beijbom。nuScenes：用于自动驾驶的多模态数据集。载于*IEEE/CVF*计算机视觉与模式识别会议（*CVPR*）论文集，第11621–11631页，2020年。[21] Benjamin Wilson、William Qi、Tanmay Agarwal、John Lambert、Jagjeet Singh、Siddhesh Khandelwal、Bowen Pan、Ratnesh Kumar、Andrew Hartnett、Jhony Kaesemodel Pontes、Deva Ramanan、Peter Carr 和 James Hays。Argoverse 2：新一代自动驾驶感知与预测数据集。载于神经信息处理系统数据集与基准专题论文集，2021年。[22] Tung Phan-Minh、Elena Corina Grigore、Freddy A Boulton、Oscar Beijbom 和 Eric M Wolff。CoverNet：利用轨迹集进行多模态行为预测。载于*IEEE/CVF*计算机视觉与模式识别会议（*CVPR*）论文集，2020年。[23] Yuning Chai、Benjamin Sapp、Mayank Bansal 和 Dragomir Anguelov。MultiPath：用于行为预测的多种概率锚点轨迹假设。学习理论会议（*COLT*），2020年。[24] Yevgeny Biktairov、Artem Zholus、Alexey Kobzev、Alexander Gotovets 和 Sergey Nikolenko。Prank：通过排序进行运动预测。载于神经信息处理系统进展（*NeurIPS*），2020年。[25] Gianluca Antonini、Michel Bierlaire 和 Mats Weber。行人步行行为的离散选择模型。《交通研究*B*辑：方法论》，40(8):667–687，2006年。doi: 10.1016/j.trb.2005.09.006。[26] Th. Robin、G. Antonini、M. Bierlaire 和 J. Cruz。行人步行行为模型的设定、估计与验证。《交通研究*B*辑：方法论》，43(1):36–56，2009年。doi: 10.1016/j.trb.2008.06.010。[27] Rulla Al-Haideri、Adam Weiss 和 Karim Ismail。环形交叉口人行横道处的行人行为建模：探索一种微观行为学方法。2026年。doi: 10.13140/RG.2.2.30619.12329。

[28] Rulla Al-Haideri、Adam Weiss 和 Karim Ismail。用于捕捉骑行者在人行横道处过街行为中未观测异质性的离散选择潜在类别方法。事故分析与预防，211:107850，2025年。[29] Rulla Al-Haideri 和 Bilal Farooq。利用自然驾驶数据集对自动驾驶车辆交互中的行人行为进行建模。载于第*37*届*IEEE*智能车辆研讨会，2026年。doi: 10.48550/arXiv.2602.05142。[30] Melvin Wong 和 Bilal Farooq。ResLogit：用于数据驱动的选择建模的残差神经网络 Logit 模型。《交通研究*C*辑：新兴技术》，126:103050，2021年。[31] Rulla Al-Haideri、Karim Ismail 和 Adam Weiss。超越传统模型：环形交叉口车辆交互建模的离散选择方法。《交通计量学*A*辑：交通科学》，第1–45页，2025年。