

轨迹预测方法、装置及车辆

5 本申请要求于 2025 年 01 月 21 日提交中国专利局、申请号为 202510095366.X、申请名称为“轨迹预测方法、装置及车辆”的中国专利申请的优先权，其全部内容通过引用结合在本申请中。

技术领域

10 本申请涉及汽车技术领域，尤其涉及汽车轨迹预测技术领域，具体涉及一种轨迹预测方法、装置及车辆。

背景技术

15 自动驾驶车辆作为车辆产业转型升级的引领者，其在全球范围内受到的重视与认可不言而喻。这一技术的核心在于使车辆能够在各种复杂的交通环境中做出精准且及时的决策，从而确保行驶的安全与效率。为了实现这一目标，对周围待预测车辆（如其他车辆、行人等）的意图或运动轨迹的提前预知显得尤为重要。

相关技术中，提出的 Multi-PPTP 中采用了 Mobile Net 轻量化网络，作为栅格图的特征编码器，但存在不能很好地利用交通场景信息的稀疏性的问题，导致预测轨迹不准确的问题。

20 相关技术中，提出一种车辆轨迹特征提取方法，为车辆轨迹分类或预测提供标准化的特征数据，但是存在引入采样使编码过程不确定增大，导致预测轨迹不准确的问题。

发明内容

25 本申请提供一种轨迹预测方法、装置及车辆，以至少解决相关技术中预测轨迹可行性较低的技术问题。本申请的技术方案如下：

根据本申请提供的第一方面，提供一种轨迹预测方法，该方法包括：获取待预测车辆的第一位置序列特征和车道段序列特征；第一位置序列特征用于表征多个历史时刻的待预测车辆的位置特征；车道段序列特征用于表征待预测车辆与周边车道段的位置关系；基于第一位置序列特征和车道段序列特征进行注意力机制运算，得到第一车道段融合特征；基

于第一车道段融合特征，得到待预测车辆的预测轨迹。

基于上述技术方案，本申请实施例融合多维度信息（第一位置序列特征和车道段序列特征），通过注意力机制运算，使模型能够自动学习并强调对预测结果有重要影响的位置序列特征和车道段序列特征，从而提高了预测轨迹的准确性和鲁棒性。

5 在一些实施例中，基于第一车道段融合特征，得到待预测车辆的预测轨迹，包括：获取车辆交互特征和待预测车辆的周边车辆对应的第二车道段融合特征；车辆交互特征用于表征待预测车辆与周边车辆之间的位置关系；基于第一车道段融合特征、车辆交互特征和第二车道段融合特征进行注意力机制运算，得到目标融合特征；根据目标融合特征，生成待预测车辆的预测轨迹。

10 基于上述技术方案，本申请实施例在上述车道段序列特征的基础上融合了周边车辆对应的第二车道段融合特征和车辆交互特征，以此能够准确表征待预测车辆与周边车辆之间的相对位置和动态关系，并通过注意力机制运算，使模型能够更好地理解复杂交通场景中的车辆行为模式，从而生成更可靠的预测轨迹。

15 在一些实施例中，获取待预测车辆的第一位置序列特征，包括：获取待预测车辆的历史位置信息；基于第一多层感知机 MLP 对历史位置信息进行处理，得到待预测车辆的第二位置序列特征；将第二位置序列特征和时间嵌入参数进行融合，得到第三位置序列特征；针对第三位置序列特征进行注意力机制运算，得到第一位置序列特征。

20 基于上述技术方案，本申请实施例使用第一多层感知机 MLP 对历史位置信息进行处理，能够提取出车辆运动的深层次特征（第二位置序列特征），该第二位置序列特征有助于更准确地预测车辆未来的位置。同时，引入时间嵌入参数，使得模型能够考虑时间因素的影响，进一步提高了预测的准确性。

25 在一些实施例中，获取待预测车辆的车道段序列特征，包括：获取待预测车辆的周边车道段位置信息；基于第二多层感知机 MLP 对周边车道段位置信息进行处理，得到车道段序列特征。

30 基于上述技术方案，本申请实施例通过第二多层感知机 MLP 对周边车道段位置信息进行处理，可以高效地提取出车道段的关键特征。而第二多层感知机 MLP 作为一种前馈神经网络，具有强大的非线性拟合能力，能够学习到车道段位置信息与车辆运动之间的复杂关系，以此使得模型在后续的位置预测或轨迹规划中能够更准确地理解车道段的结构和约束条件。

30 在一些实施例中，基于第一位置序列特征和车道段序列特征进行注意力机制运算，得

到第一车道段融合特征，包括：基于第三多层感知机 MLP 将第一位置序列特征映射为第一查询向量；基于第四多层感知机 MLP 将第一拼接特征映射为第一键向量和第一值向量；第一拼接特征为第一位置序列特征和车道段序列特征拼接得到的特征；基于第一查询向量、第一键向量和第一值向量进行注意力机制运算，得到第一车道段融合特征。

- 5 基于上述技术方案，本申请实施例通过第三多层感知机 MLP 和第四多层感知机 MLP，可以灵活地将第一位置序列特征和车道段序列特征映射到高维空间中的查询向量、键向量和值向量。以此通过该映射方式能够保留原始特征中的重要信息，同时减少冗余和噪声。同时，通过注意力机制能够根据查询向量和键向量之间的相似度，动态地调整不同特征在融合过程中的权重，使得轨迹预测模型能够更准确地理解第一位置序列特征和车道段序列特征之间的关系，从而生成第一车道段融合特征。
- 10

在一些实施例中，获取车辆交互特征，包括：获取待预测车辆的周边车辆位置信息；基于第五多层感知机 MLP 对周边车辆位置信息进行处理，得到车辆交互特征。

- 基于上述技术方案，本申请实施例可以通过在当前时刻下建立待预测车辆和周边车辆之间的连接关系，并利用嵌入表示和相对坐标提取边特征，实现了全局交互编码的构建。
- 15 该方法能够准确捕捉各个车辆之间的动态交互关系，为智能交通、自动驾驶等领域的智能化处理提供了有效的技术支持。

- 在一些实施例中，基于第一车道段融合特征、车辆交互特征和第二车道段融合特征进行注意力机制运算，得到目标融合特征，包括：基于第六多层感知机 MLP 将第一车道交互特征映射为第二查询向量；基于第七多层感知机 MLP 将第二拼接特征映射为第二键向量和第二值向量；第二拼接特征为第一车道段融合特征、车辆交互特征和第二车道段融合特征拼接得到的特征；基于第二查询向量、第二键向量和第二值向量进行注意力机制运算，得到目标融合特征。
- 20

- 根据本申请提供的第二方面，提供一种轨迹预测模型的训练方法，该方法包括：获取车辆在第一样本时刻的第一位置序列特征和车道段序列特征；第一位置序列特征表征在第一样本时刻之前的多个历史时刻的车辆的位置；车道段序列特征表征多个历史时刻下车辆与周边车道段的位置关系；获取车辆在第二样本时刻对应的目标车道段真值标签和真实轨迹；基于轨迹预测模型对第一位置序列特征和车道段序列特征进行处理，得到第二样本时刻对应的预测车道段标签和预测轨迹；轨迹预测模型用于基于第一位置序列特征和车道段特征进行注意力机制运算，得到第一车道段融合特征；基于第一车道段融合特征，得到预测轨迹，并确定预测轨迹对应的预测车道段标签；基于目标车道段真值标签和预测车道段
- 25
- 30

标签计算第一损失；基于真实轨迹和预测轨迹计算第二损失；根据第一损失和第二损失，调整轨迹预测模型。

基于上述技术方案，本申请实施例通过综合考虑了车辆的历史位置信息和与周边车道段的位置关系，上述两种特征共同作用于轨迹预测，能够更全面地反映车辆的行驶状态和可能的行驶路径。同时，通过注意力机制运算，使模型能够动态地调整不同特征在预测过程中的权重，从而更准确地捕捉车辆行驶的关键信息，提高预测的准确性。

在一些实施例中，获取车辆在第一时间序列的第一位置序列特征和车道段序列特征，包括：获取车辆在多个历史时刻的历史位置信息和多个历史时刻的待预测车辆的周边车道段位置信息；基于轨迹预测模型对历史位置信息和周边车道段位置信息进行处理，分别得到第一位置序列特征、车道段序列特征。

在一些实施例中，方法还包括：获取车辆的车辆交互特征和车辆的周边车辆对应的第二车道段融合特征；车辆交互特征用于表征车辆在第一时间序列与周边车辆之间的位置关系；基于轨迹预测模型对第一位置序列特征和车道段序列特征进行处理，得到第二样本时刻对应的预测车道段标签和预测轨迹，包括：基于轨迹预测模型对第一车道段融合特征、车辆交互特征和第二车道段融合特征进行处理，得到第二样本时刻对应的预测车道段标签和预测轨迹；轨迹预测模型用于基于第一位置序列特征和车道段特征进行注意力机制运算，得到第一车道段融合特征；基于第一车道段融合特征、车辆交互特征和第二车道段融合特征进行注意力机制运算，得到目标融合特征；根据目标融合特征，生成车辆的预测轨迹，并确定预测轨迹对应的预测车道段标签。

根据本申请提供的第三方面，提供一种车辆，包括一种轨迹预测装置。

根据本申请提供的第四方面，提供一种电子设备，包括：处理器；用于存储处理器可执行指令的存储器；其中，处理器被配置为执行指令，以实现上述第一方面及其任一种可能的实施方式的方法。

根据本申请提供的第五方面，提供一种计算机可读存储介质，当计算机可读存储介质中的指令由电子设备的处理器执行时，使得电子设备能够执行上述第一方面中及其任一种可能的实施方式的方法。

根据本申请提供的第六方面，提供一种计算机程序产品，计算机程序产品包括计算机指令，当计算机指令在电子设备上运行时，使得电子设备执行上述第一方面及其任一种可能的实施方式的方法。

由此，本申请的上述技术特征具有以下有益效果：

(1) 本申请实施例融合多维度信息（第一位置序列特征和车道段序列特征），通过注意力机制运算，使模型能够自动学习并强调对预测结果有重要影响的位置序列特征和车道段序列特征，从而提高了预测的准确性和鲁棒性。

(2) 本申请实施例在上述车道段序列特征的基础上融合了周边车辆对应的第二车道段融合特征和车辆交互特征，以此能够准确表征待预测车辆与周边车辆之间的相对位置和动态关系，并通过注意力机制运算，使模型能够更好地理解复杂交通场景中的车辆行为模式，从而生成更可靠的预测轨迹。

(3) 本申请实施例使用第一多层感知机 MLP 对历史位置信息进行处理，能够提取出车辆运动的深层次特征（第二位置序列特征），该第二位置序列特征有助于更准确地预测车辆未来的位置。同时，引入时间嵌入参数，使得模型能够考虑时间因素的影响，进一步提高了预测的准确性。

(4) 本申请实施例通过第二多层感知机 MLP 对周边车道段位置信息进行处理，可以高效地提取出车道段的关键特征。而第二多层感知机 MLP 作为一种前馈神经网络，具有强大的非线性拟合能力，能够学习到车道段位置信息与车辆运动之间的复杂关系，以此使得模型在后续的位置预测或轨迹规划中能够更准确地理解车道段的结构和约束条件。

(5) 本申请实施例通过第三多层感知机 MLP 和第四多层感知机 MLP，可以灵活地将第一位置序列特征和车道段序列特征映射到高维空间中的查询向量、键向量和值向量。以此通过该映射方式能够保留原始特征中的重要信息，同时减少冗余和噪声。同时，通过注意力机制能够根据查询向量和键向量之间的相似度，动态地调整不同特征在融合过程中的权重，使得轨迹预测模型能够更准确地理解第一位置序列特征和车道段序列特征之间的关系，从而生成第一车道段融合特征。

(6) 本申请实施例通过在当前时刻下建立待预测车辆和周边车辆之间的连接关系，并利用嵌入表示和相对坐标提取边特征，实现了全局交互编码的构建。该方法能够准确捕捉各个车辆之间的动态交互关系，为智能交通、自动驾驶等领域的智能化处理提供了有效的技术支持。

(7) 本申请实施例通过综合考虑了车辆的历史位置信息和与周边车道段的位置关系，上述两种特征共同作用于轨迹预测，能够更全面地反映车辆的行驶状态和可能的行驶路径。同时，通过注意力机制运算，使模型能够动态地调整不同特征在预测过程中的权重，从而更准确地捕捉车辆行驶的关键信息，提高预测的准确性。

需要说明的是，第二方面至第六方面中的任一种实现方式所带来的技术效果可参见第

一方面中对应实现方式所带来的技术效果，此处不再赘述。

应当理解的是，以上的一般描述和后文的细节描述仅是示例性和解释性的，并不能限制本申请。

5 附图说明

此处的附图被并入说明书中并构成本说明书的一部分，示出了符合本申请的实施例，并与说明书一起用于解释本申请的原理，并不构成对本申请的不当限定。

- 图 1 是根据一示例性实施例示出的一种车辆的结构示意图；
- 图 2 是根据一示例性实施例示出的一种轨迹预测装置的框图；
- 10 图 3 是根据一示例性实施例示出的一种轨迹预测方法的流程示意图；
- 图 4 是根据一示例性实施例示出的一种轨迹预测方法的场景图；
- 图 5 是根据一示例性实施例示出的另一种轨迹预测方法的场景图；
- 图 6 是根据一示例性实施例示出的另一种轨迹预测方法的场景图；
- 图 7 是根据一示例性实施例示出的另一种轨迹预测方法的场景图；
- 15 图 8 是根据一示例性实施例示出的另一种轨迹预测方法的场景图；
- 图 9 是根据一示例性实施例示出的另一种轨迹预测装置的框图；
- 图 10 是根据一示例性实施例示出的一种电子设备的框图。

具体实施方式

- 20 为了使本领域普通人员更好地理解本申请的技术方案，下面将结合附图，对本申请实施例中的技术方案进行清楚、完整地描述。

- 需要说明的是，本申请的说明书和权利要求书及上述附图中的术语“第一”、“第二”等是用于区别类似的对象，而不必用于描述特定的顺序或先后次序。应该理解这样使用的数
据在适当情况下可以互换，以便这里描述的本申请的实施例能够以除了在这里图示或描述
25 的那些以外的顺序实施。以下示例性实施例中所描述的实施方式并不代表与本申请相一致
的所有实施方式。相反，它们仅是与如所附权利要求书中所详述的、本申请的一些方面相
一致的装置和方法的例子。

- 在本申请实施例中，“示例性的”、“比如”、或者“例如”等词用于表示作例子、
例证或说明。本申请实施例中被描述为“示例性的”“比如”、或者“例如”的任何实施
30 例或设计方案不应被解释为比其它实施例或设计方案更优选或更具优势。确切而言，使用

“示例性的”“比如”、或者“例如”等词旨在以具体方式呈现相关概念。

首先，对本申请中所涉及相关技术进行解释说明，以便于本领域技术人员理解。

近年来，深度神经网络在轨迹预测领域的广泛应用确实为自动驾驶、智能交通等领域带来了显著的进步。其中，基于目标驱动的轨迹预测方法通过将问题分解为预测可能目标
5 和基于上下文特征进行运动估计两个子任务，实现了对车辆未来轨迹的更为精准的预测。然而，这些方法在追求低预测误差的同时，往往忽视了预测轨迹的物理可行性，这是一个值得深入探讨的问题。

为了解决上述问题，目标可以采用更加复杂的轨迹表示方法，以更全面地描述车辆在空间中的占用情况，进而生成车辆的预测轨迹，以此克服可行性较低的问题。这种方法可
10 以更准确地反映车辆的实际占用空间，从而提高预测结果的物理可行性。

总之，虽然基于深度学习的轨迹预测方法在降低预测误差方面取得了显著成果，但物理可行性仍然是制约其实际应用的关键因素之一。未来，研究者们需要在预测模型中引入更多的物理约束和更复杂的轨迹表示方法，以确保生成的预测轨迹既准确又可行。这将为自动驾驶等智能交通系统的实际应用提供更加可靠的保障。

15 下面将结合本申请实施例中的附图，对本申请实施例中的技术方案进行描述，显然，所描述的实施例仅仅是本申请一部分实施例，而不是全部的实施例。

本申请实施例提供的轨迹预测方法，可以应用在车辆中。如图 1 所示，为本申请实施例提供的一种车辆的结构示意图，该车辆 100 可以包括底盘 110、车身 120、车轮 130。可以理解的是，该车辆 100 可以为燃油汽车、电动汽车、油电混合汽车、燃气汽车、甲醇汽
20 车、太阳能汽车等。

示例性地，车辆 100 可以为轿车、运动型多用途汽车（sport utility vehicle，SUV）、多用途汽车（multi-purpose vehicles，MPV）等乘用车，也可以为客车、载货汽车、半挂车等。本申请对此不做具体限制。

可以理解的是，上述部件仅为对车辆 100 的一部分部件的举例，并不是对车辆 100 的
25 具体结构的限定。

可选地，为了对车辆进行控制，车辆 100 还可以包括轨迹预测系统 140。该轨迹预测系统 140 可以实现对车辆 100 的周边的待预测车辆运动轨迹的预测。

如图 2 所示，本申请实施例提供一种轨迹预测系统 140 的框图。该轨迹预测系统 140 包括获取模块 210 和轨迹预测模块 220。

30 其中，获取模块 210 用于获取待预测车辆的第一位置序列特征和车道段序列特征；并

将第一位置序列特征和车道段序列特征发送至轨迹预测模块 220。

在一些实施例中，第一位置序列特征用于表征多个历史时刻的待预测车辆的位置特征；车道段序列特征用于表征待预测车辆与周边车道段的位置关系。

5 轨迹预测模块 220 用于基于第一位置序列特征和车道段序列特征进行注意力机制运算，得到第一车道段融合特征，并基于第一车道段融合特征，得到待预测车辆的预测轨迹。

需要说明的是，本申请实施例描述的轨迹预测系统是为了更加清楚的说明本申请实施例的技术方案，并不构成对于本申请实施例提供的技术方案的限定，本领域普通技术人员可知，随着电子设备的演变和其他电子设备的出现，本申请实施例提供的技术方案对于类似的技术问题，同样适用。以下实施例中的方法均可以在具有上述硬件结构的轨迹预测系
10 统中实现。

以下实施例中的方法均可以在具有上述硬件结构的轨迹预测系统中实现。

下面结合附图，详细介绍本申请实施例提供的轨迹预测方法。

本申请实施例的轨迹预测方法可以应用于预测待预测车辆的运动轨迹。如图 3 所示，该轨迹预测方法可以包括步骤 301-步骤 303。其中，步骤 301 也可以称为“获取待预测车
15 辆的第一位置序列特征和车道段序列特征”流程，步骤 302-步骤 303 可以称为“生成待预测车辆的预测轨迹”流程。以下对步骤 301-步骤 303 进行详细说明。

步骤 301、获取待预测车辆的第一位置序列特征和车道段序列特征。

在本申请相关的实施例中，第一位置序列特征用于表征多个历史时刻的待预测车辆的位置特征；车道段序列特征用于表征待预测车辆与周边车道段的位置关系。

20 在一些实施例中，轨迹预测系统可以获取待预测车辆的历史位置信息，并基于第一多层感知机 MLP 对历史位置信息进行处理，得到待预测车辆的第二位置序列特征，进而将第二位置序列特征和时间嵌入参数进行融合，得到第三位置序列特征，针对该第三位置序列特征进行注意力机制运算，得到第一位置序列特征。

示例性地，如图 4 所示，轨迹预测系统可以获取待预测车辆的历史位置信息 ($H_{i,t}$)，
25 每个历史位置信息包括但不限于时间戳和待预测车辆的坐标值，其中 t 表示不同的历史时间戳 ($t=0, t=-1, t=-2$)， i 表示第 i 个待预测车辆。

进而，轨迹预测系统可以检查待预测车辆的历史位置信息 $H_{i,t}$ 对应的时间戳是否有效。对于时间戳无效（如缺失、格式错误等）或与其他历史位置信息相比明显异常（如时间跳跃过大）的位置信息，将其视为无效位置，并将其对应的坐标值设置为零，以在后续
30 分析中避免其影响。

对于有效位置数据，计算相邻位置信息之间（如，步长为 1）的坐标增量 $\Delta H_{i,t}$ ，即 $\Delta x = x(t+1) - x(t)$ 和 $\Delta y = y(t+1) - y(t)$ （或 Δz 在三维空间中），以此表示待预测车辆的瞬时方向和瞬时速度信息。

此外，对于瞬时速度信息还可以结合时间戳信息，计算待预测车辆在相邻位置之间的移动距离，并除以时间间隔，得到瞬时速度信息，将计算得到的瞬时方向和瞬时速度信息输出，供后续路径规划、避障及导航等应用使用。

由此，本申请实施例通过时间戳有效性检查和无效位置数据处理机制，有效提高了待预测车辆瞬时方向和瞬时速度信息的准确性。同时，利用步长为 1 的坐标增量来表示待预测车辆的运动状态，为待预测车辆的运动分析和控制提供了可靠的数据支持。

10 可选地，如图 5 所示，本申请实施例可以通过 Transformer 模型构建时序编码器，通过构建两个残差模块分别计算自注意力特征与全连接特征。

进一步地，轨迹预测系统可以通过第一多层感知机（multilayer perceptron, MLP）将坐标增量 $\Delta H_{i,t}$ 投影到维度为 d 的特征空间作为第二位置序列特征 $e_{i,t}$ 。

更进一步地，本申请实施例可以初始化一组可学习参数作为时间嵌入，其长度等于待预测车辆的历史位置信息的时间步长，并将初始化后的时间嵌入与第二位置特征序列进行拼接。其中，拼接操作可以在特征维度上进行，即将时间嵌入作为待预测车辆特征的一个额外维度。

进而对拼接后的特征进行维度变换，以满足后续预测轨迹模型处理的需求，经过时间嵌入的初始化、特征拼接及维度变换后，得到包含时序信息的第三位置序列特征。其中，20 该维度变换可以包括调整特征的形状、进行线性变换等。

应理解，该时间嵌入的维度可以根据具体任务需求设定，该时间嵌入的参数在后续模型训练过程中会被不断优化，以更好地捕捉时序信息。

更进一步地，通过层归一化与第一多层感知机将第三位置序列特征映射为查询向量 Query、键向量 Key 和值向量 Value 特征，即以下公式 1：

$$25 \quad \{Q_t, K_t, V_t\} = \{\phi_Q(e_{i,t}), \phi_K(e_{i,t}), \phi_V(e_{i,t})\} \quad \text{公式 1}$$

其中， $\phi_Q(e_{i,t})$ 表示第三位置序列特征映射为的查询向量 Query 特征， $\phi_K(e_{i,t})$ 表示第三位置序列特征映射为的键向量 Key 特征， $\phi_V(e_{i,t})$ 表示第三位置序列特征映射为的值向量 Value 特征。

采用自注意力机制计算得到第一位置序列特征，即以下公式 2：

$$30 \quad e_{att_{i,t_1}} = att(Q_{t_1}^T K_{t_2}) \quad \text{公式 2}$$

其中, $e_{att_{i,t_1}}$ 表示第一位置序列特征, i 表示第 i 个待预测车辆, t_1 和 t_2 表示不同的历史时刻, $Q_{t_1}^T$ 表示 t_1 时刻待预测车辆的查询向量 Query 特征矩阵的转置, T 表示矩阵的转置, K_{t_2} 表示时刻 t_2 时刻待预测车辆的键向量 Key 特征矩阵。

优选地, 如图 5 所示, 轨迹预测系统可以采用多头注意力进行稳定训练, 即将 Q (查询向量 Query 特征)、 K (键向量 Key 特征) 和 V (值向量 Value 特征) 均分为 g 组, 使批次大小 (batch size) 扩大为 g 倍, 每组特征的维度为 $\frac{1}{g}$, 在完成注意力计算后, 通过拼接多头特征来得到最终的注意力特征。

进一步地, 通过层归一化与多层感知机依次对注意力特征进行变换, 得到全连接特征, 即以下公式 3:

$$e_{ffn_{i,t_1}} = \phi_{ffn}(e_{att_{i,t_1}} + e_{i,t_1}) \quad \text{公式 3}$$

其中, $e_{ffn_{i,t_1}}$ 表示全连接特征, $e_{att_{i,t_1}}$ 表示第一位置序列特征。

更进一步地, 引入残差连接以求出新的待预测车辆特征, 即以下公式 4:

$$e_{i,t_1} = e_{att_{i,t_2}} + e_{i,t} + e_{ffn_{i,t_1}} \quad \text{公式 4}$$

其中, e_{i,t_1} 表示第一位置序列特征, $e_{att_{i,t_2}}$ 表示由自注意力机制得到的位置序列特征, $e_{i,t}$ 表示第二位置序列特征, $e_{ffn_{i,t_1}}$ 为全连接特征。

为了减少过拟合效应, 在残差连接中引入随机深度与层缩放, 随机深度即为在模型的训练过程中的残差连接有一定的概率被遗弃, 该概率随着层数的增加而增加, 即以下公式 5:

$$p_l = 1 - \frac{l}{L}(1 - p_L) \quad \text{公式 5}$$

式中, p_l 为第 l 层的遗弃概率, L 为总层数, p_L 为最后一层的遗弃概率。层缩放是对每一层的残差特征在特征维度上进行独立的缩放, 使不同通道特征的差异更丰富, 即以下公式 6:

$$e' = w_{ls} \cdot e \quad \text{公式 6}$$

式中, e 和 e' 分别为原始残差特征与更新的残差特征, w_{ls} 为的可学习权重。

应理解, 如图 4 所示, 待预测车辆的第一位置序列特征由时序编码器输出。时序编码器能够对待预测车辆的历史状态或行为数据进行编码, 提取出具有时序特性的特征, 该特征代表了待预测车辆在当前时刻的状态或行为模式。

在一些实施例, 轨迹预测系统可以获取待预测车辆的周边车道段位置信息, 并基于第二多层感知机 MLP 对周边车道段位置信息进行处理, 得到车道段序列特征。

示例性地，轨迹预测系统可以基于待预测车辆的历史位置信息，确定待预测车辆运动方向上预设距离的车道段（即周边车道段），根据第二多层感知机 MLP 对筛选出的周边车道段的坐标进行处理，得到周边车道段位置信息。

进一步地，将周边车道段位置信息（即周边车道段的线段的中点坐标），转换至待预测车辆的局部坐标系下，以此使得线段中点坐标相对于待预测车辆的位置得以明确表达。

利用第二多层感知机对上述转换后的线段中点坐标进行处理。第二多层感知机通过对输入数据的非线性变换，提取出线段中点坐标中的深层特征，该深层特征被用作图结构中边的特征（即车道段序列特征）。

优选地，本申请实施例可以将经过第二多层感知机 MLP 处理的车道段序列特征与待预测车辆的第一位置序列特征相结合，构建出车道段与待预测车辆之间的时空图结构。该时空图结构不仅反映了车道段与待预测车辆之间的空间关系，还融入了待预测车辆的时序状态信息，从而实现了对待预测车辆周围环境的全面描述。

本申请实施例通过上述方法，高效地构建出车道段与待预测车辆之间的相对位置关系（时空图结构），为后续的路径规划、轨迹预测等任务提供有力的支持。

步骤 302、基于第一位置序列特征和车道段序列特征进行注意力机制运算，得到第一车道段融合特征。

在一些实施例中，轨迹预测系统可以基于第三多层感知机 MLP 将第一位置序列特征映射为第一查询向量，并基于第四多层感知机 MLP 将第一拼接特征映射为第一键向量和第一值向量，进而根据第一查询向量、第一键向量和第一值向量进行注意力机制运算，得到第一车道段融合特征。

其中，第一拼接特征为第一位置序列特征和车道段序列特征拼接得到的特征；

示例性地，如图 6 所示，轨迹预测系统可以通过第三多层感知机 MLP 将第一位置序列特征投射为第一查询向量 $Q_{i,t}$ ，将通过第四多层感知机 MLP 将第一位置序列特征和车道段序列拼接之后的第一拼接特征投射为第一键向量 $K_{j,t}$ 和第一值向量 $V_{j,t}$ 。其中，通道数可以以为 d 。

如图 4 所示，利用车道特征融合模块的异注意力机制将车道段序列特征融合到第一位置序列特征中，得到残差特征 e_{res_i} ，即以下公式 7：

$$e_{res_i} = att(Q_{i,t} \cdot K_{j,t}) \quad \text{公式 7}$$

进一步地，轨迹预测系统可以将残差特征 e_{res_i} 和第一位置序列特征拼接之后进行归一化以及第四多层感知机 MLP 处理，得到更新后的待预测车辆的位置序列特征 e'_i ，即以下

公式 8:

$$e'_i = \eta_2(\phi(\eta_1(e_i + e_{res_i})) + \eta_1(e_i + e_{res_i})) \quad \text{公式 8}$$

其中, η_1 和 η_2 表示归一化函数, ϕ 表示全连接层的第四多层感知机 MLP 网络结构。

通过时序编码器进一步使有向车道段特征与待预测车辆 A_i 的节点特征融合, 并以 $t=0$ 的待预测车辆序列特征 $e_{i,t}|t=0$ 作为待预测车辆嵌入 b_i 。

更进一步地, 利用时序编码器对车道段序列特征与更新后的待预测车辆的位置序列特征 e'_i 进行融合处理, 在时序编码的基础上, 选取时间 $t=0$ 这一特定时刻的待预测车辆序列特征 $e_{i,t}|t=0$, 该特征既包含了待预测车辆自身的动态信息, 也融入了车道段序列特征对其影响的静态与动态特征。此特征被设定为待预测车辆的嵌入表示 b_i , 该嵌入向量 b_i 能够全面且紧凑地反映待预测车辆在初始时刻的状态及其与周围环境的交互关系。

应理解, 时序编码器能够捕捉时间序列数据的动态变化, 通过其内部机制 (如循环神经网络 RNN、长短时记忆网络 LSTM 或门控循环单元 GRU 等) 有效整合时间维度上的信息, 从而生成融合了时空特性的新特征集。

步骤 303、基于第一车道段融合特征, 得到待预测车辆的预测轨迹。

在一些实施例中, 轨迹预测系统可以获取车辆交互特征和待预测车辆的周边车辆对应的第二车道段融合特征, 进而基于第一车道段融合特征、车辆交互特征和第二车道段融合特征进行注意力机制运算, 得到目标融合特征, 并根据目标融合特征, 生成待预测车辆的预测轨迹。

其中, 车辆交互特征用于表征待预测车辆与周边车辆之间的位置关系。

示例性地, 如图 4 所示, 轨迹预测系统的轨迹预测模块可以将目标融合特征输入多组多层感知机进行解码, 得到多个预测轨迹和每个预测轨迹对应的置信度, 并确定多个预测轨迹中置信度最高的预计轨迹为待预测车辆的预测轨迹。

在一些实施例中, 上述所提及的目标融合特征可以通过以下方式得到: 轨迹预测系统可以基于第六多层感知机 MLP 将第一车道交互特征映射为第二查询向量, 并基于第七多层感知机 MLP 将第二拼接特征映射为第二键向量和第二值向量, 进而根据第二查询向量、第二键向量和第二值向量进行注意力机制运算, 得到目标融合特征。

其中, 第二拼接特征为第一车道段融合特征、车辆交互特征和第二车道段融合特征拼接得到的特征。

示例性地, 如图 4 所示, 轨迹预测系统的车道目标预测模块可以通过第六多层感知机 MLP 将第一车道交互特征投射为第二查询向量 $Q_{i,t}$, 将通过第七多层感知机 MLP 将第一

车道段融合特征、车辆交互特征和第二车道段融合特征拼接之后的第二拼接特征投射为第二键向量 $K_{l,t}$ 和第二值向量 $V_{l,t}$ 。其中， l 表示第1个周边车辆（ $l=1, 2, \dots$ ），通道数可以为 d 。

利用自注意力机制将第二车道段融合特征融合到第一位置序列特征中，得到残差特征
5 b_{res_i} ，即以下公式 9：

$$b_{res_i} = att(Q_{i,t} \cdot K_{l,t}) \quad \text{公式 9}$$

进一步地，轨迹预测系统可以将残差特征 b_{res_i} 和第一位置序列特征拼接之后进行归一化以及第七多层感知机 MLP 处理，得到目标融合特征 b'_i ，即以下公式 10：

$$b'_i = \eta_2(\phi(\eta_1(b_i + b_{res_i})) + \eta_1(b_i + b_{res_i})) \quad \text{公式 10}$$

10 其中， η_1 和 η_2 表示归一化函数， ϕ 表示全连接层的第七多层感知机 MLP 网络结构。

在一些实施例中，上述所提及的车辆交互特征可以通过以下方式得到：轨迹预测系统可以获取待预测车辆的周边车辆位置信息，并基于第五多层感知机 MLP 对周边车辆位置信息进行处理，得到车辆交互特征。

示例性地，如图 4 所示，轨迹预测系统的交互融合模块可以获取待预测车辆周边每个
15 车辆的位置信息，该位置信息包括不限于车辆的历史行为、属性及当前状态等信息，进而计算周边车辆位置信息相对于待预测车辆的相对坐标，该相对坐标可以体现待预测车辆与周边车辆之间的空间位置关系，利用第五多层感知机 MLP 对该相对坐标进行处理，从而得到待预测车辆与周边车辆的车辆交互特征，该车辆交互特征不仅包括待预测车辆与周边车辆之间的空间距离信息，还可以通过第五多层感知机的非线性映射能力捕捉到更复杂的
20 的交互关系，如速度差异和运动方向等。

可选地，轨迹预测系统还可以通过上述得到的车辆交互特征、待预测车辆和周边车辆的位置信息，构建全局交互编码。也即是说，将待预测车辆、周边车辆的位置信息和车辆交互特征整合到一个图结构中，其中待预测车辆作为节点，它们之间的连接关系作为边。通过图神经网络（GNN）或其他图处理算法，可以进一步提取全局交互编码中的深层信息，
25 为后续的决策、预测或优化任务提供支持。

应理解，本申请实施例通过在当前时刻下建立待预测车辆和周边车辆之间的连接关系，并利用嵌入表示和相对坐标提取边特征，实现了全局交互编码的构建。该方法能够准确捕捉各个车辆之间的动态交互关系，为智能交通、自动驾驶等领域的智能化处理提供了有效的技术支持。

30 本申请实施例提供的轨迹预测方法，通过综合考虑多个历史时刻的车辆位置特征（即

第一位置序列特征)，方法能够捕捉车辆的动态行驶模式，从而更准确地预测其未来轨迹，并且引入车道段序列特征，即车辆与周边车道段的位置关系，提供了额外的上下文信息，有助于更精确地理解车辆的行驶环境，进一步提高预测的准确性。

同时，本申请实施例提供的轨迹预测方法依赖于车辆的动态行驶模式和与车道段的相对位置，而非固定的路径或模式，这使得模型能够适应不同的交通场景和道路结构，且注意力机制的引入使得模型能够动态地关注重要的输入特征，从而在不同情况下做出更合理的预测。

如图 7 所示，本申请实施例提供一种轨迹预测模型的训练方法，该方法具体包括以下步骤 701-步骤 706。

10 步骤 701、获取车辆在第一样本时刻的第一位置序列特征和车道段序列特征。

在本申请相关的实施例中，第一位置序列特征表征在第一样本时刻之前的多个历史时刻的车辆的位置；车道段序列特征表征多个历史时刻下车辆与周边车道段的位置关系。

在一些实施例中，获取车辆在多个历史时刻的历史位置信息和多个历史时刻的待预测车辆的周边车道段位置信息，并基于轨迹预测模型对历史位置信息和周边车道段位置信息
15 进行处理，分别得到第一位置序列特征、车道段序列特征。

需要说明的是，轨迹预测模型获取以及对历史位置信息和周边车道段位置信息的处理过程与上述轨迹预测方法的过程相同，此处概不赘述。

步骤 702、获取车辆在第二样本时刻对应的目标车道段真值标签和真实轨迹。

在本申请实施例中，可以将给定的轨迹预测数据集按照 4：1 的比例进行划分，形成
20 训练集与验证集。其中，训练集占总数据量的 80%，用于训练轨迹预测模型；验证集占总数据量的 20%，用于评估模型的预测性能。并将数据集内已包含的车辆第二样本时刻对应的真实轨迹设定为轨迹预测模型的最终预测输出真值标签。应理解，该真值标签可以作为监督信息，用于指导并优化模型的预测任务训练过程。

示例性地，对轨迹预测数据集中的车道数据进行预处理。该预处理步骤依据车辆当前
25 的行驶方向进行筛选，即沿着车辆的行驶方向，查找位于一定距离范围内的周边车道段，该周边车道段可以被视为未来的候选目标向量。

在确定的距离范围内，筛选出与车辆行驶方向相符的周边车道段，形成未来候选目标向量的集合，进而在候选目标向量集合中，计算每个时刻的车辆的轨迹点与各个周边车道段的距离，选择最接近的目标周边车道段作为该时刻的目标车道段标签。该目标车道段标
30 签构成目标车道段的真值标签集合，用于监督辅助任务检测头的训练。

步骤 703、基于轨迹预测模型对第一位置序列特征和车道段序列特征进行处理，得到第二样本时刻对应的预测车道段标签和预测轨迹。

在本申请相关的实施例，轨迹预测模型用于基于第一位置序列特征和车道段特征进行注意力机制运算，得到第一车道段融合特征；基于第一车道段融合特征，得到预测轨迹，
5 并确定预测轨迹对应的预测车道段标签。

需要说明的是，上述轨迹预测模型确定第一车道段融合特征，以及根据第一车道段融合特征得到预测轨迹的过程与轨迹预测方法的过程相同，此处概不赘述。应理解，在得到预测轨迹之后，车辆行驶过的预测轨迹将对应有相应的车道段，则轨迹预测模型可以将相应的车道段作为预测车道段标签。

10 优选地，如图 8 所示，轨迹预测模型可以根据多层感知机 MLP 将第一位置序列特征映射为第三查询向量，并根据多层感知机 MLP 将车道段特征映射为第三键向量和第三值向量，即以下公式 11：

$$\begin{aligned} \{Q_{i,t}\} &= \{(\phi_Q(e_{i,t}))\} \\ \{K_{j,t}, V_{j,t}\} &= \{(\phi_K(e_{j,t}), \phi_V(e_{j,t}))\} \end{aligned} \quad \text{公式 11}$$

15 式中， $\phi_Q(e_{i,t})$ 表示第一位置序列特征映射为的第三查询向量 Query 特征， $\phi_K(e_{j,t})$ 表示车道段特征映射为的第三键向量 Key 特征， $\phi_V(e_{j,t})$ 表示车道段特征映射为的第三值向量 Value 特征。

通过多头交叉注意力机制对第三键向量、第三值向量和第三查询向量进行处理，确定车道段集合中分类得分最高的车道段为预测车道段。也即是说，使用多头交叉注意力机制
20 计算每个历史时刻下车辆对周边车道段的多头注意力系数，即以下公式 12：

$$\alpha_{i,j,t} = \text{cross_attn}(Q_{i,t}^T, K_{j,t}, V_{j,t}) \quad \text{公式 12}$$

其中， $\alpha_{i,j,t}$ 表示交叉注意力系数， cross_attn 表示单头交叉注意力计算函数， $Q_{i,t}^T$ 表示 t 时刻第 i 个车辆的第一位置序列特征的转置， $K_{j,t}$ 和 $V_{j,t}$ 分别表示 t 时刻的车道段序列特征。

进一步地，针对每个头部（head），将其对应的交叉注意力系数进行求和操作，随后
25 对求和结果应用 Softmax 函数进行归一化处理。应理解，该步骤用于根据各头部的注意力权重，计算出在第二样本时刻下，针对各个车道段的分类得分 $\mu_{(j,t,f)}$ 。

利用每个时刻的目标车道段标签，从计算得到的分类得分中选取与目标车道段标签相对应的目标车道段分类得分。该步骤确保了用于后续损失计算的分类得分与真实车道目标段的一致性。

30 在一些实施例中，轨迹预测模型可以获取车辆的车辆交互特征和车辆的周边车辆对应

的第二车道段融合特征。

其中，车辆交互特征用于表征车辆在第一时间时刻与周边车辆之间的位置关系。

需要说明的是，上述获取车辆交互特征和第二车道段融合特征的过程与轨迹预测方法中获取车辆交互特征和第二车道段融合特征的过程相同，此处概不赘述。

- 5 在一些实施例中，基于轨迹预测模型对第一车道段融合特征、车辆交互特征和第二车道段融合特征进行处理，得到第二样本时刻对应的预测车道段标签和预测轨迹。

其中，轨迹预测模型用于基于第一位置序列特征和车道段特征进行注意力机制运算，得到第一车道段融合特征；基于第一车道段融合特征、车辆交互特征和第二车道段融合特征进行异注意力机制运算，得到目标融合特征；根据目标融合特征，生成车辆的预测轨迹，
10 并确定预测轨迹对应的预测车道段标签。

需要说明的是，上述轨迹预测模型确定第一车道段融合特征和目标融合特征，以及根据目标融合特征得到预测轨迹的过程与轨迹预测方法的过程相同，此处概不赘述。应理解，在得到预测轨迹之后，车辆行驶过的预测轨迹将对应相应的车道段，则轨迹预测模型可以将相应的车道段作为预测车道段标签。

- 15 步骤 704、基于目标车道段真值标签和预测车道段标签计算第一损失。

在一些实施例中，基于选取的目标车道段分类得分，采用交叉熵分类损失(Binary Cross Entropy, BCE_loss)作为损失函数，计算辅助任务的训练损失。此损失函数用于衡量模型预测的分类得分与实际车道目标点之间的误差，从而指导模型的训练过程。

- 20 示例性地，将目标车道段真值标签与预测车道段标签进行匹配，例如以时间或空间维度为基准，确保两者在相同的时间点或空间位置上进行比较，并计算匹配后的目标车道段真值标签与预测车道段标签之间的差异，该差异包括但不限于车道段的位置偏差、方向偏差、宽度偏差等。

- 进一步地，基于上述差异计算得到第一损失函数 $loss_{goal}$ ，即交叉熵目标分类损失(记为 loss_goal)。该损失函数旨在量化预测车道段标签与目标车道段真值标签之间的不一致程度，通常可以采用数学上的距离度量(如欧氏距离、曼哈顿距离等)或概率度量(如交叉熵损失、KL 散度等)。
25

应理解，第一损失函数的计算结果反映了模型预测的准确性，即模型预测的车道段与实际车道段之间的差异越小，模型的预测性能越好。

步骤 705、基于真实轨迹和预测轨迹计算第二损失。

- 30 示例性地，对真实轨迹与预测轨迹进行时间同步或空间对齐，确保两者在相同的时间

点或空间位置上进行比较。例如，采用适当的度量方法，计算真实轨迹与预测轨迹之间的差异。该差异包括但不限于轨迹的几何形状差异（如路径长度、曲率等）、动态特性差异（如速度、加速度变化等）以及时间同步性差异（如时间延迟、时间间隔等）。

基于上述差异计算得到第二损失函数。该第二损失函数旨在量化预测轨迹与真实轨迹之间的不一致程度，通常采用数学上的距离度量（如欧几里得距离、曼哈顿距离、弗雷歇距离等）、动态特性度量（如速度误差、加速度误差等）或时间同步性度量（如时间延迟损失等）。

又一种示例性地，对该预测轨迹与真实轨迹进行 SmoothL1 回归损失 $loss_reg$ 的计算，并对预测轨迹进行第二损失函数 $loss_cls$ （交叉熵分类损失）的计算。该交叉熵分类损失旨在提高该模态对应的置信度，使其更准确地反映真实情况。

步骤 706、根据第一损失和第二损失，调整轨迹预测模型。

示例性地，将计算得到的第一损失和第二损失进行融合，形成联合损失函数。例如，可以通过简单的加权求和、乘积或其他复杂的非线性组合方式来实现，其中，该联合损失函数旨在全面反映模型在车道段预测和轨迹预测两个方面的性能。

进一步地，利用梯度下降或其他优化算法，根据联合损失函数的梯度信息，对轨迹预测模型的参数进行调整。调整过程中，模型会不断尝试减少联合损失，从而逐渐提高车道段预测和轨迹预测的准确性。

应理解，在模型训练阶段，可以将调整后的模型在包含丰富多样场景的数据集上进行迭代训练，同时持续监控联合损失的变化情况。通过不断的参数调整和优化，使模型逐渐收敛至最优解。

在模型验证阶段，利用独立的验证数据集对训练好的模型进行性能评估。通过比较模型在验证集上的预测结果与实际数据之间的差异，验证模型的泛化能力和预测准确性。进而，根据验证结果，对模型进行进一步的优化和调整。

又一种示例性地，最终训练损失函数 $loss_total$ 是第一损失函数 $loss_goal$ 、SmoothL1 回归损失 $loss_reg$ 和第二损失函数 $loss_cls$ 的线性组合。具体地， $loss_total$ 的计算方式可以为公式 13：

$$loss_total=(1-\alpha)\cdot[\beta\cdot loss_cls+(1-\beta)\cdot loss_reg]+\alpha\cdot loss_goal \tag{公式 13}$$

其中，线性系数 α 和 β 分别设置为 0.2 和 0.5，以平衡不同损失项的影响，并达到车道目标预测辅助轨迹预测的效果。在训练过程中，本申请实施例使用神经网络模型训练中的反向传播技术，对模型参数进行迭代更新。通过不断调整模型参数，使损失函数 $loss_total$

的计算结果不断下降。当损失函数计算结果小于一定阈值时，认为模型已经训练至最佳模式，此时模型具有较高的预测准确性和可靠性。

上述主要从方法的角度对本申请实施例提供的方案进行了介绍。为了实现上述功能，图像采集装置或电子设备包含了执行各个功能相应的硬件结构和/或软件模块。本领域技术人员应该很容易意识到，结合本文中所公开的实施例描述的各示例的单元及算法步骤，本申请能够以硬件或硬件和计算机软件的结合形式来实现。某个功能究竟以硬件还是计算机软件驱动硬件的方式来执行，取决于技术方案的特定应用和设计约束条件。专业技术人员可以对每个特定的应用来使用不同方法来实现所描述的功能，但是这种实现不应认为超出本申请的范围。

10 本申请实施例可以根据上述方法，示例性的对图像采集装置或电子设备进行功能模块的划分，例如，图像采集装置或电子设备可以包括对应各个功能划分的各个功能模块，也可以将两个或两个以上的功能集成在一个处理模块中。上述集成的模块既可以采用硬件的形式实现，也可以采用软件功能模块的形式实现。需要说明的是，本申请实施例中对模块的划分是示意性的，仅仅为一种逻辑功能划分，实际实现时可以有另外的划分方式。

15 图 9 是根据一示例性实施例示出的另一种轨迹预测装置的框图。该轨迹预测装置可以应用于轨迹预测方法，也可以应用于训练方法。参照图 9，该轨迹预测装置包括：处理单元 901 和获取单元 902。获取单元 902，用于获取待预测车辆的第一位置序列特征和车道段序列特征；第一位置序列特征用于表征多个历史时刻的待预测车辆的位置特征；车道段序列特征用于表征待预测车辆与周边车道段的位置关系；处理单元 901，用于基于第一位置序列特征和车道段序列特征进行注意力机制运算，得到第一车道段融合特征；处理单元 20 901，还用于基于第一车道段融合特征，得到待预测车辆的预测轨迹。

25 在一些实施例中，处理单元 901，具体用于获取车辆交互特征和待预测车辆的周边车辆对应的第二车道段融合特征；车辆交互特征用于表征待预测车辆与周边车辆之间的位置关系；基于第一车道段融合特征、车辆交互特征和第二车道段融合特征进行注意力机制运算，得到目标融合特征；根据目标融合特征，生成待预测车辆的预测轨迹。

在一些实施例中，处理单元 901，具体用于获取待预测车辆的历史位置信息；基于第一多层感知机 MLP 对历史位置信息进行处理，得到待预测车辆的第二位置序列特征；将第二位置序列特征和时间嵌入参数进行融合，得到第三位置序列特征；针对第三位置序列特征进行注意力机制运算，得到第一位置序列特征。

30 在一些实施例中，处理单元 901，具体用于获取待预测车辆的周边车道段位置信息；

基于第二多层感知机 MLP 对周边车道段位置信息进行处理，得到车道段序列特征。

在一些实施例中，处理单元 901，具体用于基于第三多层感知机 MLP 将第一位置序列特征映射为第一查询向量；基于第四多层感知机 MLP 将第一拼接特征映射为第一键向量和第一值向量；第一拼接特征为第一位置序列特征和车道段序列特征拼接得到的特征；

5 基于第一查询向量、第一键向量和第一值向量进行注意力机制运算，得到第一车道段融合特征。

在一些实施例中，处理单元 901，具体用于获取待预测车辆的周边车辆位置信息；基于第五多层感知机 MLP 对周边车辆位置信息进行处理，得到车辆交互特征。

在一些实施例中，处理单元 901，具体用于基于第六多层感知机 MLP 将第一车道交互特征映射为第二查询向量；基于第七多层感知机 MLP 将第二拼接特征映射为第二键向量和第二值向量；第二拼接特征为第一车道段融合特征、车辆交互特征和第二车道段融合特征拼接得到的特征；基于第二查询向量、第二键向量和第二值向量进行注意力机制运算，得到目标融合特征。

10

获取单元 902，还用于获取车辆在第一样本时刻的第一位置序列特征和车道段序列特征；第一位置序列特征表征在第一样本时刻之前的多个历史时刻的车辆的位置；车道段序列特征表征多个历史时刻下车辆与周边车道段的位置关系；获取单元 902，还用于获取车辆在第二样本时刻对应的目标车道段真值标签和真实轨迹；处理单元 901，还用于基于轨迹预测模型对第一位置序列特征和车道段序列特征进行处理，得到第二样本时刻对应的预测车道段标签和预测轨迹；轨迹预测模型用于基于第一位置序列特征和车道段特征进行注意力机制运算，得到第一车道段融合特征；基于第一车道段融合特征，得到预测轨迹，并确定预测轨迹对应的预测车道段标签；基于目标车道段真值标签和预测车道段标签计算第一损失；基于真实轨迹和预测轨迹计算第二损失；根据第一损失和第二损失，调整轨迹预测模型。

15

20

在一些实施例中，处理单元 901，具体用于获取车辆在多个历史时刻的历史位置信息和多个历史时刻的待预测车辆的周边车道段位置信息；基于轨迹预测模型对历史位置信息和周边车道段位置信息进行处理，分别得到第一位置序列特征、车道段序列特征。

25

在一些实施例中，处理单元 901，还用于获取车辆的车辆交互特征和车辆的周边车辆对应的第二车道段融合特征；车辆交互特征用于表征车辆在第一样本时刻与周边车辆之间的位置关系；基于轨迹预测模型对第一位置序列特征和车道段序列特征进行处理，得到第二样本时刻对应的预测车道段标签和预测轨迹，包括：基于轨迹预测模型对第一车道段融

30

合特征、车辆交互特征和第二车道段融合特征进行处理，得到第二样本时刻对应的预测车道段标签和预测轨迹；轨迹预测模型用于基于第一位置序列特征和车道段特征进行注意力机制运算，得到第一车道段融合特征；基于第一车道段融合特征、车辆交互特征和第二车道段融合特征进行注意力机制运算，得到目标融合特征；根据目标融合特征，生成车辆的
5 预测轨迹，并确定预测轨迹对应的预测车道段标签。

关于上述实施例中的装置，其中各个模块执行操作的具体方式已经在有关该方法的实施例中进行了详细描述，此处将不做详细阐述说明。

图 10 是根据一示例性实施例示出的一种电子设备的框图。如图 10 所示，电子设备包括但不限于：处理器 1001 和存储器 1002。

10 其中，上述的存储器 1002，用于存储上述处理器 1001 的可执行指令。可以理解的是，上述处理器 1001 被配置为执行指令，以实现上述实施例中的图像采集方法。

需要说明的是，本领域技术人员可以理解，图 10 中示出的电子设备结构并不构成对电子设备的限定，电子设备可以包括比图 10 所示更多或更少的部件，或者组合某些部件，或者不同的部件布置。

15 处理器 1001 是电子设备的控制中心，利用各种接口和线路连接整个电子设备的各个部分，通过运行或执行存储在存储器 1002 内的软件程序和/或模块，以及调用存储在存储器 1002 内的数据，执行电子设备的各种功能和处理数据，从而对电子设备进行整体监控。处理器 1001 可包括一个或多个处理单元。可选的，处理器 1001 可集成应用处理器和调制解调处理器，其中，应用处理器主要处理操作系统、用户界面和应用程序等，调制解调处
20 理器主要处理无线通信。可以理解的是，上述调制解调处理器也可以不集成到处理器 1001 中。

存储器 1002 可用于存储软件程序以及各种数据。存储器 1002 可主要包括存储程序区和存储数据区，其中，存储程序区可存储操作系统、至少一个功能模块所需的应用程序（比如确定单元、处理单元等）等。此外，存储器 1002 可以包括高速随机存取存储器，还可以
25 以包括非易失性存储器，例如至少一个磁盘存储器件、闪存器件、或其他易失性固态存储器件。

在示例性实施例中，还提供了一种包括指令的计算机可读存储介质，例如包括指令的存储器 1002，上述指令可由电子设备的处理器 1001 执行以实现上述实施例中的方法。

在实际实现时，图 10 中的获取单元 301、显示单元 302 和控制单元 302 的功能均可以
30 可以由图 10 中的处理器 1001 调用存储器 1002 中存储的计算机程序实现。其具体的执行过

程可参考上实施例中的方法部分的描述，这里不再赘述。

可选地，计算机可读存储介质可以是非临时性计算机可读存储介质，例如，该非临时性计算机可读存储介质可以是只读存储器（Read-Only Memory，ROM）、随机存储存储器（Random Access Memory，RAM）、CD-ROM、磁带、软盘和光数据存储设备等。

- 5 在示例性实施例中，本申请实施例还提供了一种包括一条或多条指令的计算机程序产品，该一条或多条指令可以由电子设备的处理器 1001 执行以完成上述实施例中的方法。

需要说明的是，上述计算机可读存储介质中的指令或计算机程序产品中的一条或多条指令被电子设备的处理器执行时实现上述方法实施例的各个过程，且能达到与上述方法相同的技术效果，为避免重复，这里不再赘述。

- 10 通过以上的实施方式的描述，所属领域的技术人员可以清楚地了解到，为描述的方便和简洁，仅以上述各功能模块的划分进行举例说明，实际应用中，可以根据需要而将上述功能分配由不同的功能模块完成，即将装置的内部结构划分成不同的功能模块，以完成以上描述的全分类部或者部分功能。

- 15 在本申请所提供的几个实施例中，应该理解到，所揭露的装置和方法，可以通过其它的方式实现。例如，以上所描述的装置实施例仅仅是示意性的，例如，模块或单元的划分，仅仅为一种逻辑功能划分，实际实现时可以有另外的划分方式，例如多个单元或组件可以结合或者可以集成到另一个装置，或一些特征可以忽略，或不执行。另一点，所显示或讨论的相互之间的耦合或直接耦合或通信连接可以是通过一些接口，装置或单元的间接耦合或通信连接，可以是电性，机械或其它的形式。

- 20 作为分离部件说明的单元可以是或者也可以不是物理上分开的，作为单元显示的部件可以是一个物理单元或多个物理单元，即可以位于一个地方，或者也可以分布到多个不同地方。可以根据实际的需要选择其中的部分或者全分类部单元来实现本实施例方案的目的。

- 25 另外，在本申请各个实施例中的各功能单元可以集成在一个处理单元中，也可以是各个单元单独物理存在，也可以两个或两个以上单元集成在一个单元中。上述集成的单元既可以采用硬件的形式实现，也可以采用软件功能单元的形式实现。

- 30 集成的单元如果以软件功能单元的形式实现并作为独立的产品销售或使用，可以存储在一个可读存储介质中。基于这样的理解，本申请实施例的技术方案本质上或者说对现有技术做出贡献的部分或者该技术方案的部分或全部可以以软件产品的形式体现出来，该软件产品存储在一个存储介质中，包括若干指令用以使得一个设备（可以是单片机，芯

片等)或处理器(processor)执行本申请各个实施例方法的全分类部或部分步骤。而前述的存储介质包括:U 盘、移动硬盘、ROM、RAM、磁碟或者光盘等各种可以存储程序代码的介质。

- 5 以上,仅为本申请的具体实施方式,但本申请的保护范围并不局限于此,任何在本申请揭露的技术范围内的变化或替换,都应涵盖在本申请的保护范围之内。因此,本申请的保护范围应以权利要求的保护范围为准。

权 利 要 求 书

1.一种轨迹预测方法，其中，所述方法包括：

获取待预测车辆的第一位置序列特征和车道段序列特征；所述第一位置序列特征用于表征多个历史时刻的所述待预测车辆的位置特征；所述车道段序列特征用于表征所述待预测车辆与周边车道段的位置关系；

基于所述第一位置序列特征和所述车道段序列特征进行注意力机制运算，得到第一车道段融合特征；

基于所述第一车道段融合特征，得到所述待预测车辆的预测轨迹。

2.根据权利要求1所述的方法，其中，所述基于所述第一车道段融合特征，得到所述待预测车辆的预测轨迹，包括：

获取车辆交互特征和所述待预测车辆的周边车辆对应的第二车道段融合特征；所述车辆交互特征用于表征所述待预测车辆与所述周边车辆之间的位置关系；

基于所述第一车道段融合特征、所述车辆交互特征和所述第二车道段融合特征进行注意力机制运算，得到目标融合特征；

根据所述目标融合特征，生成所述待预测车辆的预测轨迹。

3.根据权利要求1或2所述的方法，其中，所述获取待预测车辆的第一位置序列特征，包括：

获取所述待预测车辆的历史位置信息；

基于第一多层感知机MLP对所述历史位置信息进行处理，得到所述待预测车辆的第二位置序列特征；

将所述第二位置序列特征和时间嵌入参数进行融合，得到第三位置序列特征；

针对所述第三位置序列特征进行注意力机制运算，得到所述第一位置序列特征。

4.根据权利要求1-3任一项所述的方法，其中，获取待预测车辆的车道段序列特征，包括：

获取所述待预测车辆的周边车道段位置信息；

基于第二多层感知机MLP对所述周边车道段位置信息进行处理，得到所述车道段序列特征。

5.根据权利要求1-4任一项所述的方法，其中，所述基于所述第一位置序列特征和所述车道段序列特征进行注意力机制运算，得到第一车道段融合特征，包括：

基于第三多层感知机MLP将所述第一位置序列特征映射为第一查询向量；

基于第四多层感知机 MLP 将第一拼接特征映射为第一键向量和第一值向量；所述第一拼接特征为所述第一位置序列特征和所述车道段序列特征拼接得到的特征；

基于所述第一查询向量、所述第一键向量和所述第一值向量进行所述注意力机制运算，得到所述第一车道段融合特征。

6.根据权利要求 2 所述的方法，其中，所述获取车辆交互特征，包括：

获取所述待预测车辆的周边车辆位置信息；

基于第五多层感知机 MLP 对所述周边车辆位置信息进行处理，得到所述车辆交互特征。

7.根据权利要求 2 或 6 所述的方法，其中，所述基于所述第一车道段融合特征、所述车辆交互特征和所述第二车道段融合特征进行注意力机制运算，得到目标融合特征，包括：

基于第六多层感知机 MLP 将所述第一车道交互特征映射为第二查询向量；

基于第七多层感知机 MLP 将第二拼接特征映射为第二键向量和第二值向量；所述第二拼接特征为所述第一车道段融合特征、所述车辆交互特征和所述第二车道段融合特征拼接得到的特征；

基于所述第二查询向量、所述第二键向量和所述第二值向量进行所述注意力机制运算，得到所述目标融合特征。

8.一种轨迹预测模型的训练方法，其中，所述方法包括：

获取车辆在第一个样本时刻的第一位置序列特征和车道段序列特征；所述第一位置序列特征表征在所述第一个样本时刻之前的多个历史时刻的所述车辆的位置；所述车道段序列特征表征所述多个历史时刻下所述车辆与周边车道段的位置关系；

获取所述车辆在第二个样本时刻对应的目标车道段真值标签和真实轨迹；

基于轨迹预测模型对所述第一位置序列特征和所述车道段序列特征进行处理，得到所述第二个样本时刻对应的预测车道段标签和预测轨迹；所述轨迹预测模型用于基于所述第一位置序列特征和所述车道段特征进行注意力机制运算，得到第一车道段融合特征；基于所述第一车道段融合特征，得到所述预测轨迹，并确定所述预测轨迹对应的预测车道段标签；

基于所述目标车道段真值标签和所述预测车道段标签计算第一损失；

基于所述真实轨迹和所述预测轨迹计算第二损失；

根据所述第一损失和所述第二损失，调整所述轨迹预测模型。

9.根据权利要求 8 所述的方法，其中，获取车辆在第一个样本时刻的第一位置序列特征和车道段序列特征，包括：

获取所述车辆在所述多个历史时刻的历史位置信息和所述多个历史时刻的待预测车辆的周边车道段位置信息；

基于所述轨迹预测模型对所述历史位置信息和所述周边车道段位置信息进行处理，分别得到所述第一位置序列特征、所述车道段序列特征。

10.根据权利要求 8 或 9 所述的方法，其中，所述方法还包括：

获取所述车辆的车辆交互特征和所述车辆的周边车辆对应的第二车道段融合特征；所述车辆交互特征用于表征所述车辆在所述第一样本时刻与所述周边车辆之间的位置关系；

基于轨迹预测模型对所述第一位置序列特征和所述车道段序列特征进行处理，得到所述第二样本时刻对应的预测车道段标签和预测轨迹，包括：

基于轨迹预测模型对所述第一车道段融合特征、所述车辆交互特征和所述第二车道段融合特征进行处理，得到所述第二样本时刻对应的预测车道段标签和预测轨迹；所述轨迹预测模型用于基于所述第一位置序列特征和所述车道段特征进行注意力机制运算，得到第一车道段融合特征；基于所述第一车道段融合特征、所述车辆交互特征和所述第二车道段融合特征进行注意力机制运算，得到目标融合特征；根据所述目标融合特征，生成所述车辆的预测轨迹，并确定所述预测轨迹对应的预测车道段标签。

11.一种轨迹预测装置，其中，所述装置包括：处理单元和获取单元。

12.一种车辆，其中，所述车辆包括权利要求 11 所述的装置。

13.一种电子设备，其中，包括：

处理器；

用于存储所述处理器可执行指令的存储器；

其中，所述处理器被配置为执行所述指令，以实现如权利要求 1 至 7 中任一项所述的方法或者以实现如权利要求 8 至 10 中任一项所述的方法。

14.一种计算机可读存储介质，其中，当所述计算机可读存储介质中存储的计算机执行指令由电子设备的处理器执行时，所述电子设备能够执行如权利要求 1 至 7 中任一项所述的方法或者以实现如权利要求 8 至 10 中任一项所述的方法。

15.一种包含指令的计算机程序产品，其中，当所述指令被计算机运行时，使得所述计算机执行如权利要求 1 至 7 中任一项所述的方法或者以实现如权利要求 8 至 10 中任一项所述的方法。