



## (12)发明专利申请

(10)申请公布号 CN 105829831 A

(43)申请公布日 2016.08.03

(21)申请号 201480061737.2

(74)专利代理机构 北京三友知识产权代理有限公司 11127

(22)申请日 2014.10.27

代理人 吕俊刚

## (30)优先权数据

14/077,689 2013.11.12 US

(51)Int.Cl.

G01C 21/36(2006.01)

## (85)PCT国际申请进入国家阶段日

2016.05.11

## (86)PCT国际申请的申请数据

PCT/JP2014/079006 2014.10.27

## (87)PCT国际申请的公布数据

W02015/072349 EN 2015.05.21

(71)申请人 三菱电机株式会社

地址 日本东京都

(72)发明人 J·R·赫尔歇 李凌波 李沛霖

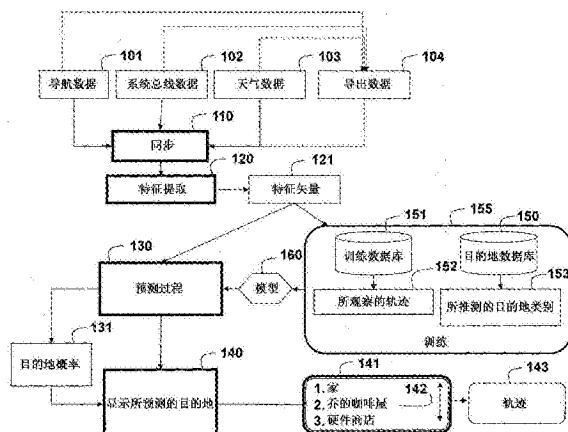
权利要求书1页 说明书7页 附图3页

## (54)发明名称

用于在行进期间预测目的地的方法

## (57)摘要

本发明的实施方式提供了一种在导航系统中根据目的地的历史来预测行进目的地的方法。用于预测的模型包含目的地数据库，该目的地数据库可包括用户最喜爱的、即最可能的目的地。该模型还使用可包括诸如当前时刻、星期几、当前位置、当前方向、过去位置、天气等特征的环境。即使未准确知道目的地，该模型也推测目的地和目的地类别。具体地说，方法使用表示行进的先前状态的预测模型，基于表示行进的当前状态的特征矢量、目的地和目的地的类别的概率在行进期间预测目的地。将具有最高概率的目的地和目的地类别的子集输出以供用户选择。



1. 一种用于在行进期间预测目的地的方法,该方法包括以下步骤:  
基于所述行进的先前状态,推测过去曾行进到的目的地和目的地类别的概率;  
基于表示所述行进的当前状态的特征矢量,使用基于所述行进的先前状态、所述目的地和目的地类别的预测模型来预测所述目的地的类别的概率;以及  
输出具有最高概率的类别子集供用户选择,  
其中,上述步骤在处理器中执行。
2. 根据权利要求1所述的方法,其中,所述特征矢量包括车辆导航数据、车辆系统总线数据、天气数据和导出数据。
3. 根据权利要求1所述的方法,其中,所述预测模型基于N-gram。
4. 根据权利要求1所述的方法,其中,所述模型是概率+单位(概率单位)回归模型,其中因变量只能够取两个值。
5. 根据权利要求1所述的方法,所述方法还包括以下步骤:  
调整所述模型的参数;并且  
将特征矢量变换到更低维的子空间。
6. 根据权利要求1所述的方法,其中,所述预测使用概率模型。
7. 根据权利要求1所述的方法,其中,使用多项分布来预测所述目的地。
8. 根据权利要求1所述的方法,其中,类别包括类型、名称和目的地的层级。
9. 根据权利要求1所述的方法,其中,所述预测使用目的地的数据库和位置的历史的组合。

## 用于在行进期间预测目的地的方法

### 技术领域

[0001] 本发明总体上涉及预测行进目的地,尤其是基于历史数据进行预测。

### 背景技术

[0002] 导航系统正在取代纸质地图和海图来辅助司机和船长航行通过不熟悉的区域到达不熟悉的目的地。大多数导航系统包括全球定位系统(GPS),以确定车辆、船只或飞机的精确位置。作为优点,导航系统中的数据可以被不断更新,增加额外的航路信息,并且在系统之间容易地传送。

[0003] 通常,目的地由驾驶员或乘客设置。目的地可以基于位置名称、地址、电话号码、从预先登记的目的地的列表中选择的预先选择的地理点等等。特定路线的知识,连同状况和环境数据(例如,交通和天气)可用于辅助驾驶员领航员到达特定目的地。

[0004] 美国专利7,233,861描述了一种用于预测目的地并且接收车辆位置数据的方法。车辆位置数据包括当前行程,将该当前行程与先前行程相比较以预测该车辆的目的地。还可以建议到达该目的地的路径。

[0005] 美国专利公报20110238289描述了一种导航装置和用于预测行程目的地的方法。该方法确定包括行程的起点、起始时间和日期在内的起始参数。通过使用行程历史的信息生成预测算法。

[0006] 美国专利公报20130166096描述了一种使车辆导航系统辅助获得车辆的目的地的预测式目的地录入系统。导航系统使用先前的驾驶历史或习惯。该信息用于对车辆的用户所期望的当前目的地进行预测。该信息可以被分离成不同的用户配置文件,并且可以包括车辆位置、车辆先前的驾驶历史、车辆的用户的先前的检索历史或与车辆的一个或更多个特征有关的感觉输入(sensory input)。

### 发明内容

[0007] 本发明的实施方式提供了一种在导航系统中根据目的地的历史来预测行进目的地的方法。用于预测的模型包含目的地数据库,该目的地数据库可包括用户最喜爱的(即,最可能的)目的地。

[0008] 该模型还使用可包括诸如当前时刻、星期几、当前位置、当前方向、过去位置、天气等特征的环境。即使未准确知道目的地时,该模型也可以推测目的地。

[0009] 具体地说,方法使用基于行进的先前状态的预测模型,基于表示行进的当前状态的特征矢量和目的地的类别的概率在行进期间预测目的地。将具有最高概率的类别的子集输出以供用户选择。

### 附图说明

[0010] 图1是根据本发明的实施方式的用于基于历史数据来预测行进目的地的方法的流程图。

[0011] 图2是根据本发明的实施方式的层级式目的地类别预测模型。

[0012] 图3是根据本发明的实施方式、凭借目的地类别依赖性的目的地类别预测模型。

## 具体实施方式

[0013] 概述

[0014] 本发明的实施方式提供了一种在导航系统中用于根据行进活动的历史预测行进目的地的方法。在本文中描述的示例中，行进由车辆执行。然而，可以理解的是，其他行进模式也可以由本文中所述的方法预测。这些方法可以在连接到由总线连接的存储器、输入/输出接口的处理器中执行。输出装置可包括向用户指示目的地的显示器或扬声器。输入装置可包括来自选择具体目的地的全球定位系统(GPS)触摸屏、键盘和语音识别系统的位置轨迹。

[0015] 方法综述

[0016] 本方法获取导航数据101、(车辆)系统总线数据102、天气数据103和导出数据。一些导出数据可从车辆导航系统、车辆总线和天气数据101-103获得。导航系统可包括GPS以及到各种信息服务器的无线互联网连接。车辆总线被定义为将车辆(例如，机动车、公共汽车、火车、工业或农业车辆、船舶或飞机)内部的部件互连的任意特殊的内部通信网络。将数据同步110并且提取120特征作为特征矢量121。各特征矢量集体表示某段过去时间的行进的先前状态。

[0017] 训练

[0018] 在可以是一次性的、间歇的、周期性的或连续的训练阶段155期间，在训练数据库151中存储特征。训练还维护含有与诸如企业、政府机关、住宅、地标和其他地理定位实体的具体目的地关联的位置、地址、名称、标识符、类别的目的地数据库150。这种目的地数据库还可以位于服务器上。目的地类别可以含有诸如其类型、质量、可用性等与目的地选择相关的任意语义信息。

[0019] 在训练期间，推测153目的地类别的概率。即，与目的地的类别关联的概率。目的地类别的概率不应与如在现有技术系统中通常发现的目的地的标识混淆。训练还确定152所观察的在行进期间轨迹。在经由用户导航接口不知道用户的实际目的地的情况下，使用所观察的轨迹来推测与各目的地和关联的类别关联的概率。在训练期间所推测的轨迹、概率性地推测的目的地和目的地类别用于构建预测模型160。

[0020] 操作

[0021] 操作期间，实时获取并由预测过程130处理实际行进的当前状态的类似特征，以获得目的地概率131、目的地类别以及诸如给目的地打电话的相关动作。显示140具有最高概率(即，最高三个概率)的预测的目的地、类别和动作，或者在诸如语音输出的用户输出接口141上经由其他手段呈现给用户作为选择。所显示的具有最高概率的选项数量可以由用户指定。然后，用户可以使用用户输入接口来选择142目的地、目的地类别或动作，然后在向所选择的目的地行进的期间，可以生成路线信息或轨迹143。

[0022] 理论依据

[0023] 本发明基于行进者在他们的目的地序列呈现的规则性的直观性，例如，

[0024] 家→饮料/小吃店→工作→商店→家。

[0025] 本发明的实施方式将从诸如先前的目的地、目的地类别以及时刻、星期几、行程状况、行进方向等当前和过去的轨迹导出的特征作为输入。预测被视为使用表示目的地、目的地类别以及最终到达位置的变量进行的推测任务。当仅观察到到达位置时，训练算法可以推测目的地和目的地类别作为隐含变量。

[0026] 简化模型

[0027] 在随机变量对 $\{x, s\}$ 中， $x$ 代表特征矢量，并且 $s$ 代表位置，例如经度和纬度，例如，行程区间的终点。

[0028] 特征矢量 $x = [x_1, \dots, x_F]$ 包括轨迹标识(ID)、针对各轨迹的区间ID、针对各区间的点ID、高度、时刻、速度和方向，并且可能包括它们的统计情况，例如，平均值、均值、偏差等，总体地称为行进状况。

[0029] 我们推测目的地 $d$ 的多项类别(或“类型”) $z \in [1, \dots, C]$ ，多项类别是来自目的地数据库的目的地或从用户处获得的“最喜爱”目的地来对可能目的地加索引的多项式。

[0030] 我们将此用公式表示为多项式逻辑回归模型：

$$[0031] p(z|x) = \frac{\exp(\lambda_z^T \phi(x))}{Z_\lambda},$$

[0032] 其中， $\lambda = [\lambda_1, \dots, \lambda_C]^T$ ， $\lambda$ 是权重，并且 $Z_\lambda = \sum_z \exp(\lambda_z^T \phi(x))$ ，并且 $\phi(x)$ 是我们的输入特征 $x$ 的矢量值函数。依赖于推测的类型，我们还可以使用与多项式逻辑回归模型类似但是可能对于基于样本的方法更方便的多项式概率单位(probit)回归模型。

[0033] 我们的直观假设在用户已选择具有较高概率的类别 $c$ 之后，用户将最可能选择来自该类别的目的地 $d$ ：

$$[0034] p(d|z) \propto \begin{cases} 1 & z \in \text{cat}(d) \\ 0 & \text{否则,} \end{cases}$$

[0035] 其中，“cat”是用目的地 $d$ 标识的一组类别。这是涵盖与类别 $c$ 一致的目的地的统一多项式。

[0036] 我们假设用户在所选 $d$ 附近的位置 $s$ 处停车。这可以建模为

$$[0037] p(s|d) = \mathcal{N}(s; \text{loc}(d), \Sigma),$$

[0038] 其中， $\Sigma = \sigma^2 I_2$ 并且 $\sigma$ 是某人停车距目的地的距离的标准差，并且 $\text{loc}(d) = [d_{lat}, d_{lon}]^T$ 是关注点 $d$ 的位置(经度和纬度)。

[0039] 模型训练

[0040] 为了训练155这种模型160，考虑例如， $x_i, s_i$ 对，其中， $x_i$ 在区间的中间。训练的目标函数是：

[0041]

$$\max_x \sum_i \log p(x_i, s_i) = \sum_i \log \sum_{z_i, d_i} p(z_i|x_i) p(d_i|z_i) p(s_i|d_i) \quad (1)$$

$$= \sum_i \log \sum_{z_i} \frac{\exp(\lambda_{z_i}^T \phi(x_i))}{\sum_z \exp(\lambda_z^T \phi(x_i))} \frac{1}{|\mathcal{D}_i(z_i)|} \sum_{d_i \in \mathcal{D}_i(z_i)} \mathcal{N}(s_i; \text{loc}(d_i), \Sigma) \quad (2)$$

其中，

我们只对一组目的地求和

[0042]  $\mathcal{D}_i(z_i) = \{d_i : |\text{loc}(d_i) - s_i| < 5\sigma, \text{并且 } z_i \in \text{cat}(d_i)\}$ ,

[0043] 因为  $p(z|d)$  和 / 或  $p(s|d)$  在该组之外为零或者相对小。

[0044] 规则化方案

[0045] 逻辑回归受益于某种形式的  $L_1$  和 / 或  $L_2$  规则化。将特征变换到更低维的子空间也可以改善泛化性能。

[0046] 变换模型是：

$$[0047] p(z|x) = \frac{\exp(\lambda_s^T A \phi(x))}{Z_{A,A}},$$

[0048] 其中， $A$  是所有类和所有用户共享的  $(R \times F)$  矩阵。通常， $R < F$  以执行降维。

[0049] 作为目标函数，模型是：

$$\max_{A,A} \sum_i \log p(x_i, s_i) = \sum_i \log \sum_{s_i, d_i} p(z_i|x_i) p(d_i|z_i) p(s_i|d_i) \quad (3)$$

$$[0050] = \sum_i \log \sum_{s_i} \frac{\exp(\lambda_s^T A \phi(x_i))}{\sum_s \exp(\lambda_s^T A \phi(x_i)) |\mathcal{D}_i(z_i)|} \frac{1}{|\mathcal{D}_i(z_i)|} \sum_{d_i \in \mathcal{D}_i(z_i)} \mathcal{N}(s_i; \text{loc}(d_i), \Sigma) \quad (4)$$

[0051] 我们加入  $L_1$  和  $L_2$  规则化，使得目标函数变为

$$\begin{aligned} [0052] \max_{A,A} \sum_i \log p(x_i, s_i) &= \sum_i \log \sum_{s_i} \frac{\exp(\lambda_s^T A \phi(x_i))}{\sum_s \exp(\lambda_s^T A \phi(x_i)) |\mathcal{D}_i(z_i)|} \frac{1}{|\mathcal{D}_i(z_i)|} \sum_{d_i \in \mathcal{D}_i(z_i)} \mathcal{N}(s_i; \text{loc}(d_i), \Sigma) \quad (5) \\ &\quad - \alpha \sum_s |\lambda_s| - \beta \sum_s |\lambda_s|_2 \end{aligned} \quad (6)$$

[0053] 其中， $\alpha = 0.5$  并且  $\beta = 0.5$  对于模型参数的规则化最理想。我们不对  $A$  加入规则化矩阵。

[0054] 用于类别预测的概率模型

[0055] 不是使用逻辑回归对  $p(z|x)$  来建模，我们发现使用从生成模型的视点较容易处理的概率单位回归很有用。我们使用利用数据  $x$  回归到的辅助变量  $Y \in \mathbb{R}^{C \times N}$  和参数（回归因子） $w \in \mathbb{R}^{C \times N}$ 。遵循常规的噪音模型  $\epsilon \sim N(0, 1)$ ，（该模型会导致得到  $y_{ci} = w_c \phi(x_i) + \epsilon$ ，其中， $w_c$  是类  $c$  回归因子的  $1 \times N$  行矢量，并且  $\phi(x_i)$  是第  $i$  个元素的内积的  $N \times 1$  列矢量）将得出以下高斯概率分布：

$$[0056] p(y_{ci}|w_c, \phi(x_i)) = \mathcal{N}(w_c \phi(x_i), 1).$$

[0057] 从辅助变量  $y_{ci}$  到作为对象的离散目标类别  $z_i \in \{1, \dots, C\}$  的联系是：

[0058]  $z_i = j$ , , 如果  $y_{ij} > y_{ij'}$ ,  $\forall j \neq j'$ ,

[0059] 并且通过以下边缘化

$$[0060] p(z_i = j|w, \phi(x_i)) = \int p(t_i = j|y_i) p(y_i|w, \phi(x)) dy_i$$

[0061] 其中， $p(z_i = j|y_i)$  是德爾塔函数，得到多项式单位可能性

$$[0062] p(z_i = j | w, \phi(x)) = \mathbb{E}\left\{\prod_{j' \neq j} \Phi(u + (w_j - w_{j'})\phi(x_i))\right\}$$

.....

[0063] 其中, E是相对于常规正态分布取得的期望值

[0064]  $p(u) = \mathcal{N}(0, 1)$  和  $\Phi$

[0065] 是正态累计密度函数。

[0066] 类别预测模型

[0067] 回想一下, 我们有  $\{x_i, s_i\}_{i=1}^N$ , 其中  $x_i \in \mathbb{R}^D$  是 D 维特征矢量并且  $s_i$  是终点的位置。我们希望对各个时刻 i 预测类别。对于各个类别, 我们可以构建线性分类器或非线性分类器。对于线性情况,  $\phi(x_i) = x_i$ , 而对于非线性情况,  $\phi(x_i) = [K(x_i, x_1), K(x_i, x_2), \dots, K(x_i, x_N)]$ , 其中  $K(\cdot, \cdot)$  是内核函数。

[0068] 回归因子  $w_{ic}$  遵循均值为零和方差为  $\alpha_{ic}^{-1}$  的传统正态分布, 其中  $\alpha_{ic}^{-1}$  遵循具有超参数  $\tau, v$  的伽玛分布。通过将  $\tau, v$  设置为足够小的值, 例如 ( $< 10^{-5}$ ), 回归因子  $w_{nc}$  的仅小子集为非零, 随后导致稀疏性。

[0069] 我们假设对于每一个类别 c, 存在关于目的地  $\{\hat{d}_n\}_{n \in L_c}$  的唯一分布  $\mu_c$ , 其中,  $L_c$  是其类别包括 c 的所推测的目的地 153, 并且  $\hat{d}_n$  表示被指标化为 n 的目的地。

[0070] 根据多项-狄利克雷(Dir)分布获得最终目的地  $d_i$  的模型。假设某人在目的地附近停车, 我们使用所选择的目的地的位置的均值为  $d_i$ 、方差为  $\sigma^2 I_2$  的高斯分布对  $s_i$  建模,  $\sigma^2$  可以是固定的或被进一步施加伽玛先验概率。

[0071] 图 2 图形地示出了我们的模型, 其具有如本文中所述并且如下总结的变量:

$$\begin{aligned} y_{ic} &\sim \mathcal{N}(w_c^T \phi(x_i), 1) \\ w_c &\sim \mathcal{N}(0, \alpha_{ic}^{-1}) \\ \alpha_{ic} &\sim \text{Gamma}(\tau, v) \\ z_i &= c, \text{ 如果 } y_{ic} > y_{ij}, \forall c \neq j \\ d_i &\sim \sum_{n \in L_{d_i}} \mu_{d_i, n} \delta_{\hat{d}_n} \\ \mu_c &\sim \text{Dir}\left(\frac{\gamma}{|L_c|}, \dots, \frac{\gamma}{|L_c|}\right) \\ s_i &\sim \mathcal{N}(\text{loc}_{(d_i)}, \sigma^2 I_2) \\ \sigma^2 &\sim \text{InverseGamma}(a_0, b_0) \end{aligned}$$

[0073] 我们还可以将各个分类的目的地的参数作为用户偏好来学习。然而, 为了学习, 可能需要更多的训练数据。在这种情况下, 我们需要包括关于分类的目的地的信息的层级以对此进一步约束。例如, 我们可以有“类型” g 和“名称” 或“品牌” b (例如, “starbucks” 相对于 “dukin donuts”) 以及实际的目的地 d (例如, 特定地址处的特定 “starbucks”)。我们可以将这些表示为树结构:  $c \rightarrow g \rightarrow b \rightarrow d$ , 并且这些关系可以是确定性的。 $b \in \text{brand}(d)$ ,  $g \in \text{genre}(b)$ ,  $c \in \text{cat}(g)$ 。

[0074] 在存在超过一个的标签与各项目关联的情况下, 我们将这些用公式表示为组, 但

一般而言,树中的各项目具有单个亲项。以此方式,可以包括用户对类型和品牌名称的偏好,而不必学习实际位置d的级别的参数。

$$[0075] \quad p(b|g) \propto \begin{cases} \pi_{b|g} & g \in \text{genre}(b) \\ 0 & \text{否则,} \end{cases}$$

[0076] 因为我们还可以包括其他用户数据,所以我们可以用公式表示全局先验概率

$$[0077] \quad p(\pi) = \text{Dir}(\pi; \gamma),$$

[0078] 来约束这些概率。

[0079] 位置预测

[0080] 如果我们希望预测用户将从前一位置行进到的下一个位置,那么我们可以考虑集群化位置,以降低推测的复杂性。我们使用一组离散的集群区域  $r \in R$ 。我们可以使用基于N-gram的马尔可夫模型  $p(r_i | r_{i-1}, r_{i-2}, \dots, r_{i-n+1})$  根据先前区域推测当前区域  $r_t$ ,其中,n是马尔可夫模型的阶并且N-gram是区域序列  $r_i, r_{i-1}, r_{i-2}, \dots, r_{i-n+1}$  可以平滑化N-gram模型,以提供针对未见的N-gram的概率。

[0081] 我们还可以考虑用户向附近区域行进的模型:

$$[0082] \quad p(r_i | r_{i-1}) = \frac{\mathcal{N}(\text{loc}(r_i) | \text{loc}(r_{i-1}), \Sigma_{\text{loc}})}{\sum_{r'_i} \mathcal{N}(\text{loc}(r'_i) | \text{loc}(r_{i-1}), \Sigma_{\text{loc}})},$$

[0083] 我们还可以考虑经由指示用户是否向附近位置行进的辅助随机变量  $o_i$ ,或者经由上面的马尔可夫动态来对这些进行组合:

$$[0084] \quad \pi_{r_i | r_{i-1}} = \begin{cases} \frac{\mathcal{N}(\text{loc}(r_i) | \text{loc}(r_{i-1}), \Sigma_{\text{loc}})}{\sum_{r'_i} \mathcal{N}(\text{loc}(r'_i) | \text{loc}(r_{i-1}), \Sigma_{\text{loc}})} & o_i = 1 \\ \pi_{r_i | r_{i-1}} & \text{否则,} \end{cases}$$

[0085] 将上式和先验概率  $p(o_i)$  组合并且假设观察到  $r_i$ ,我们可以最优化目标函数以学习  $\pi_{r_i | r_{i-1}}$ :

$$[0086] \quad \log p(r_i) = \sum_k \log \sum_{o_i} p(o_i) p(r_i | o_i, r_{i-1}) \quad (7)$$

$$\geq \sum_k \sum_{o_i} q(o_i) (\log p(o_i) + \log p(r_i | o_i, r_{i-1}) - \log q(o_i)). \quad (8)$$

[0087] 由于两个分量之间的冗余性,可能无法很好地学习  $p(o_i)$ ,并且使用交叉验证来设置可能更好,或者将狄利克雷先验概率置于其上,以有利于均匀分布。

[0088] 用于区域预测的判别模型

[0089] 可能难以在用于区域预测的N-gram模型中组合诸如时刻等的其他环境特征。作为另选方案,我们可以使用诸如上述逻辑回归或概率单位回归模型等基于分类器的方法。在这种情况下,我们可以按照与  $p(z_i | x_i)$  类似的方式定义  $p(r_i | x_i)$ 。在这种情况下,除了用于类别预测的任意其它特征之外,特征  $x_i$  还含有表示先前目的地  $r_{i-1}, r_{i-2}, \dots, r_{i-n+1}$  的特征。

[0090] 用于目的地类别选择的位置依赖性

[0091] 我们还可以对所预测的区域  $r$ 、所预测的类别  $z$  与目的地  $d$  之间的依赖性建模。可以

借助如下的目的地可能性组合区域预测和类别预测：

$$[0092] \quad p(d_i|r_i, z_i) \propto \begin{cases} \mathcal{N}(\text{loc}(d_i)|\text{loc}(r_i), \Sigma_{\text{pos}}) & z_i \in \text{cat}(d_i) \\ 0 & \text{否则} \end{cases},$$

[0093] 目的地数据库依赖性

[0094] 我们可以具有多于一个的目的地数据库150并且数据库可以在确定用户目的地时具有不同的重要性。尤其，用户可以拥有一批“最喜爱”的目的地。这里，我们把这些视为具有比来自通用数据库的先验概率更高的先验概率的目的地数据库。因此，我们使用指示用于预测行程区间i的目的地、由用户选择的数据库的多项式随机变量 $f_1:\text{Mult}(\lambda)$ 。为了实现目的地数据库的选择，我们将集合 $L_{c,k}$ 定义为来自类别包括c的数据库k的目的地的库。然

后， $d_i : \sum_{n \in L_{z_i, f_i}} \mu_{d_i n} \delta_{\hat{d}_n}$ ，其中， $\hat{d}_n$ 表示被索引为n的目的地。

[0095] 假设数据根据模型来分布：

[0096] ● 目的地指标概率 $\lambda:\text{Dirichlet}(\eta)$

[0097] ● 方差参数 $\sigma^2:\text{InverseGamma}(c_0, d_0)$

[0098] ● 目的地概率 $\mu_c:\text{Dirichlet}(\gamma)$

[0099] ● 回归因子 $w_c : \mathbf{N}(\mathbf{0}, \alpha_c^{-1} I_N) \text{Gamma}(\alpha_c; a_0, b_0)$

[0100] ● 对于各个点 $i=1, \dots, N$

[0101] - 目的地数据库指标 $f_i:\text{Multinomial}(\lambda)$

[0102] - 潜在变量 $y_{ic} : \mathbf{N}(w_c^T \phi(x_i), 1)$

[0103] - 索引 $z_i=c$ , 如果 $y_{ic} > y_{ij}, \forall c \neq j$

[0104] - 目的地 $d_i : \sum_{n \in L_{z_i, f_i}} \mu_{d_i n} \delta_{\hat{d}_n}$

[0105] - 停车位置 $s_i : \mathbf{N}(\text{loc}(d_i), \sigma^2 I_2)$

[0106] 图3示出了具有本文中所定义的变量、利用目的地数据库依赖性的目的地类别预测模型。

[0107] 无监管区域建模

[0108] 在上述模型中，区域被视为或者通过平铺地理空间，或者集群化用户频繁行进的目的地和/或位置而导出的预定义位置。将目的地位置的空间分布考虑作为区域模型是合理的扩展。在这种情况下，区域的位置可以以无监管方式在模型的环境中学习。

[0109] 轨迹建模

[0110] 在上述模型中，位置预测基于区域历史。预测还可以基于包括行进方向、道路区间、沿着路线的距离、根据当前路线和地图信息导航到目的地的容易性、交通信息的地理特征。这种模型化是本方法的合理扩展，其改进了到新位置的预测和泛化。

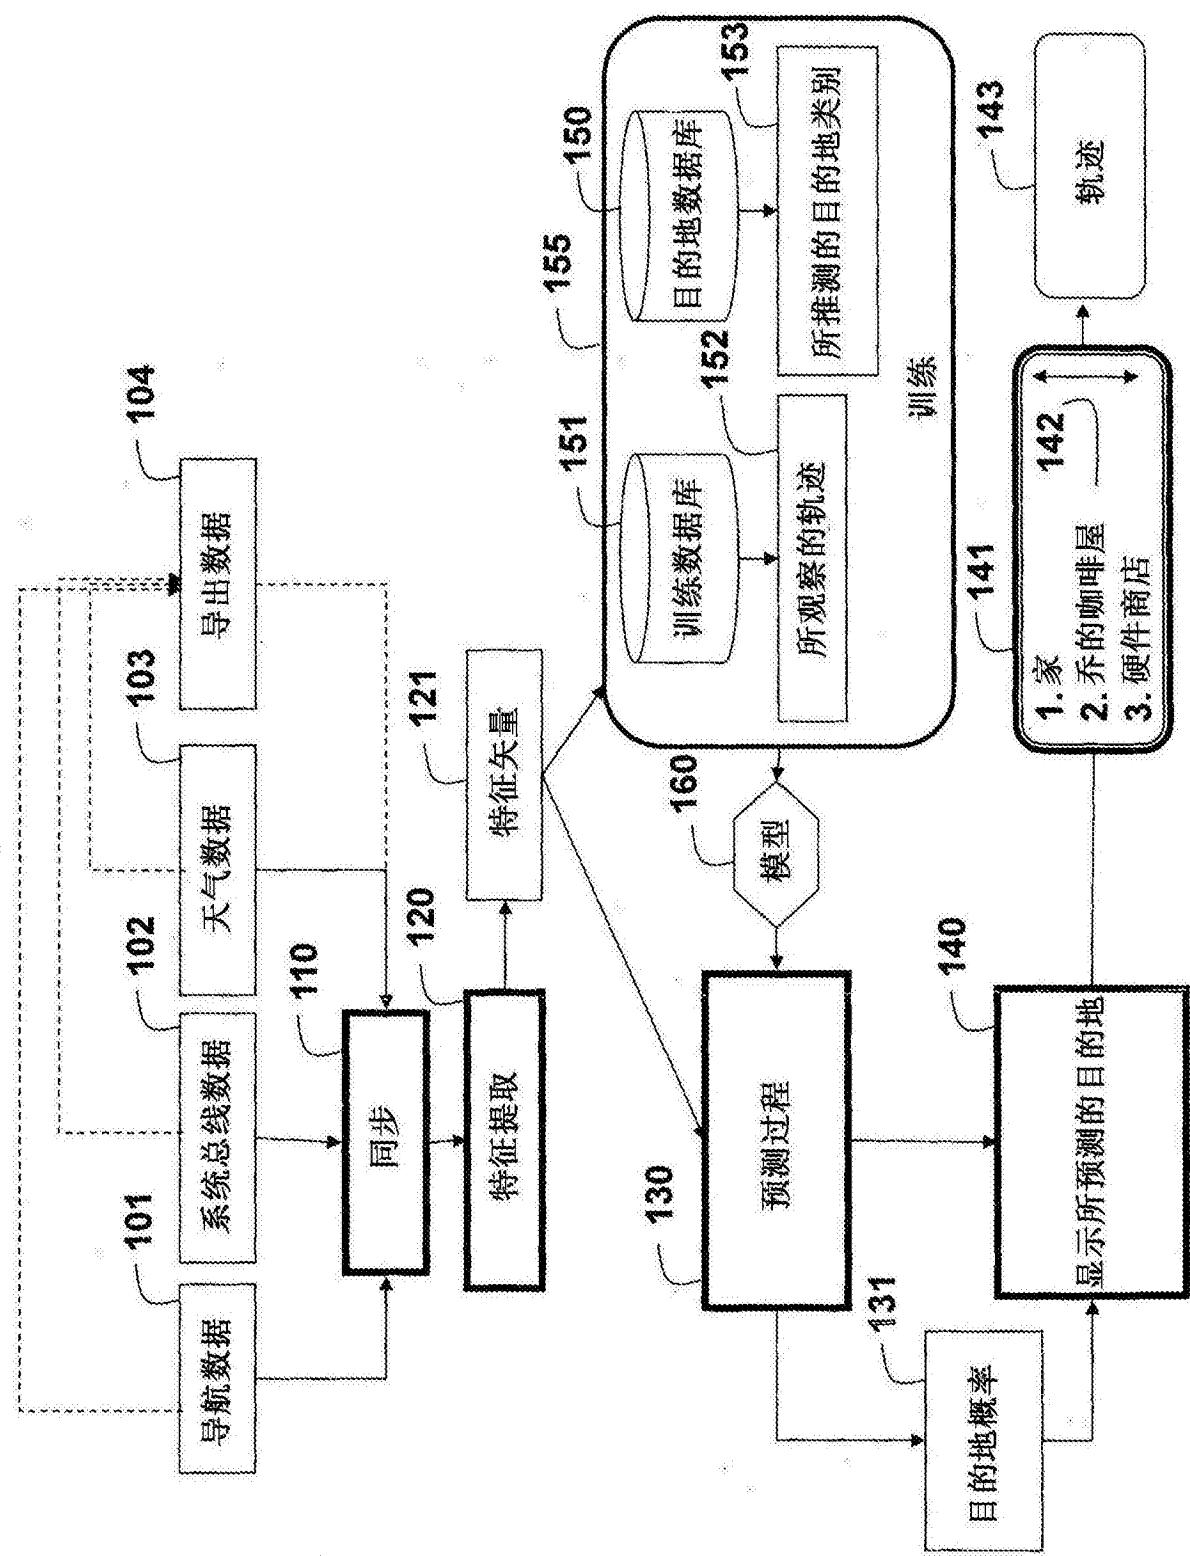


图1

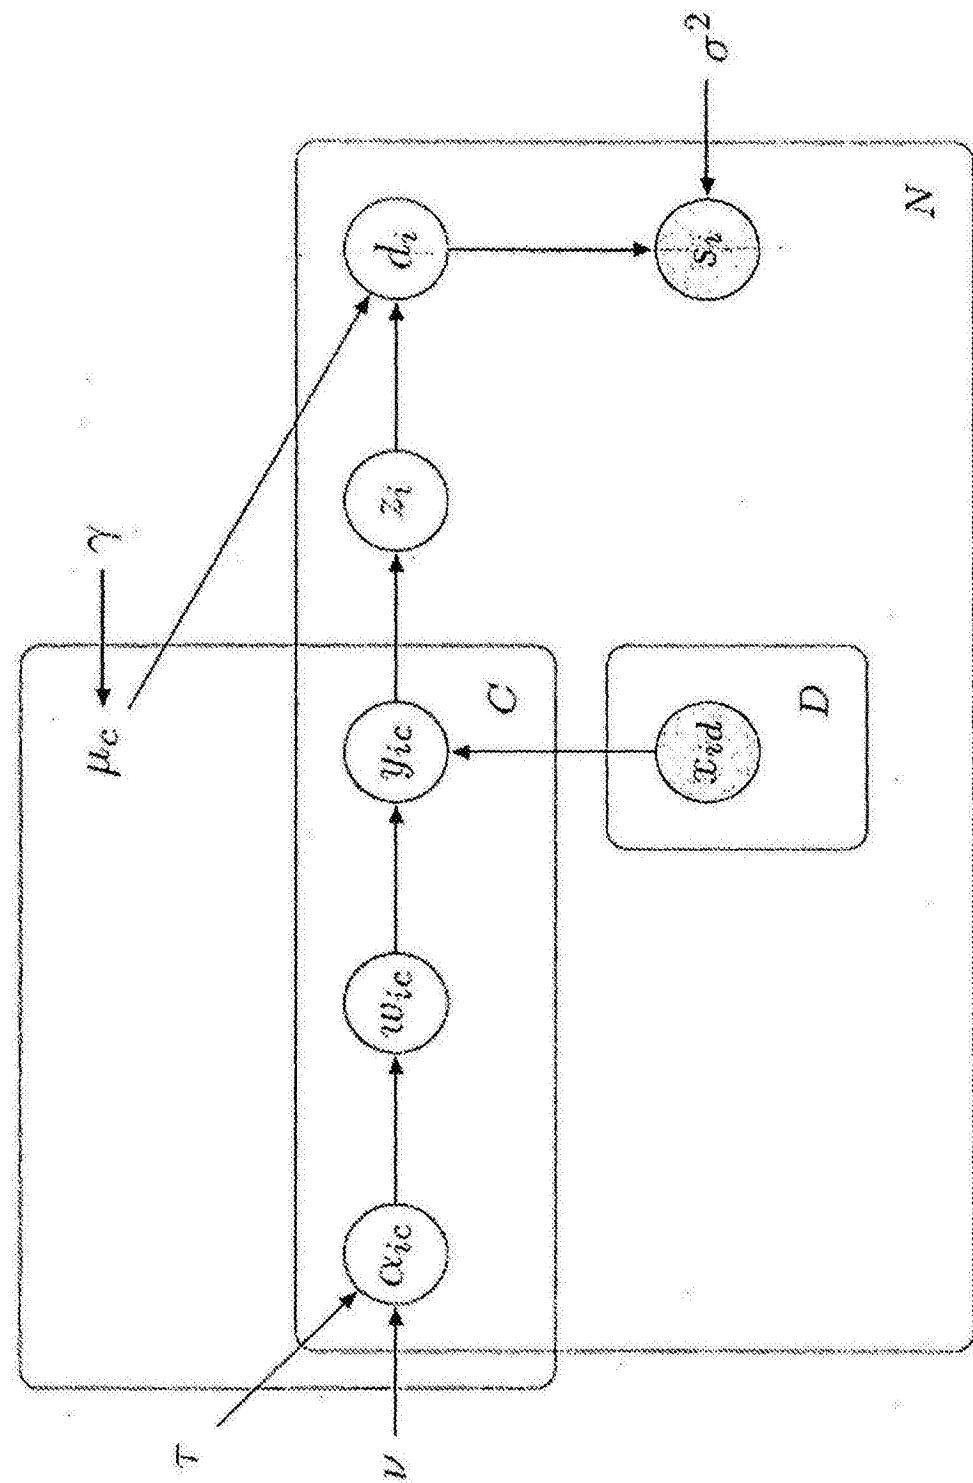


图2

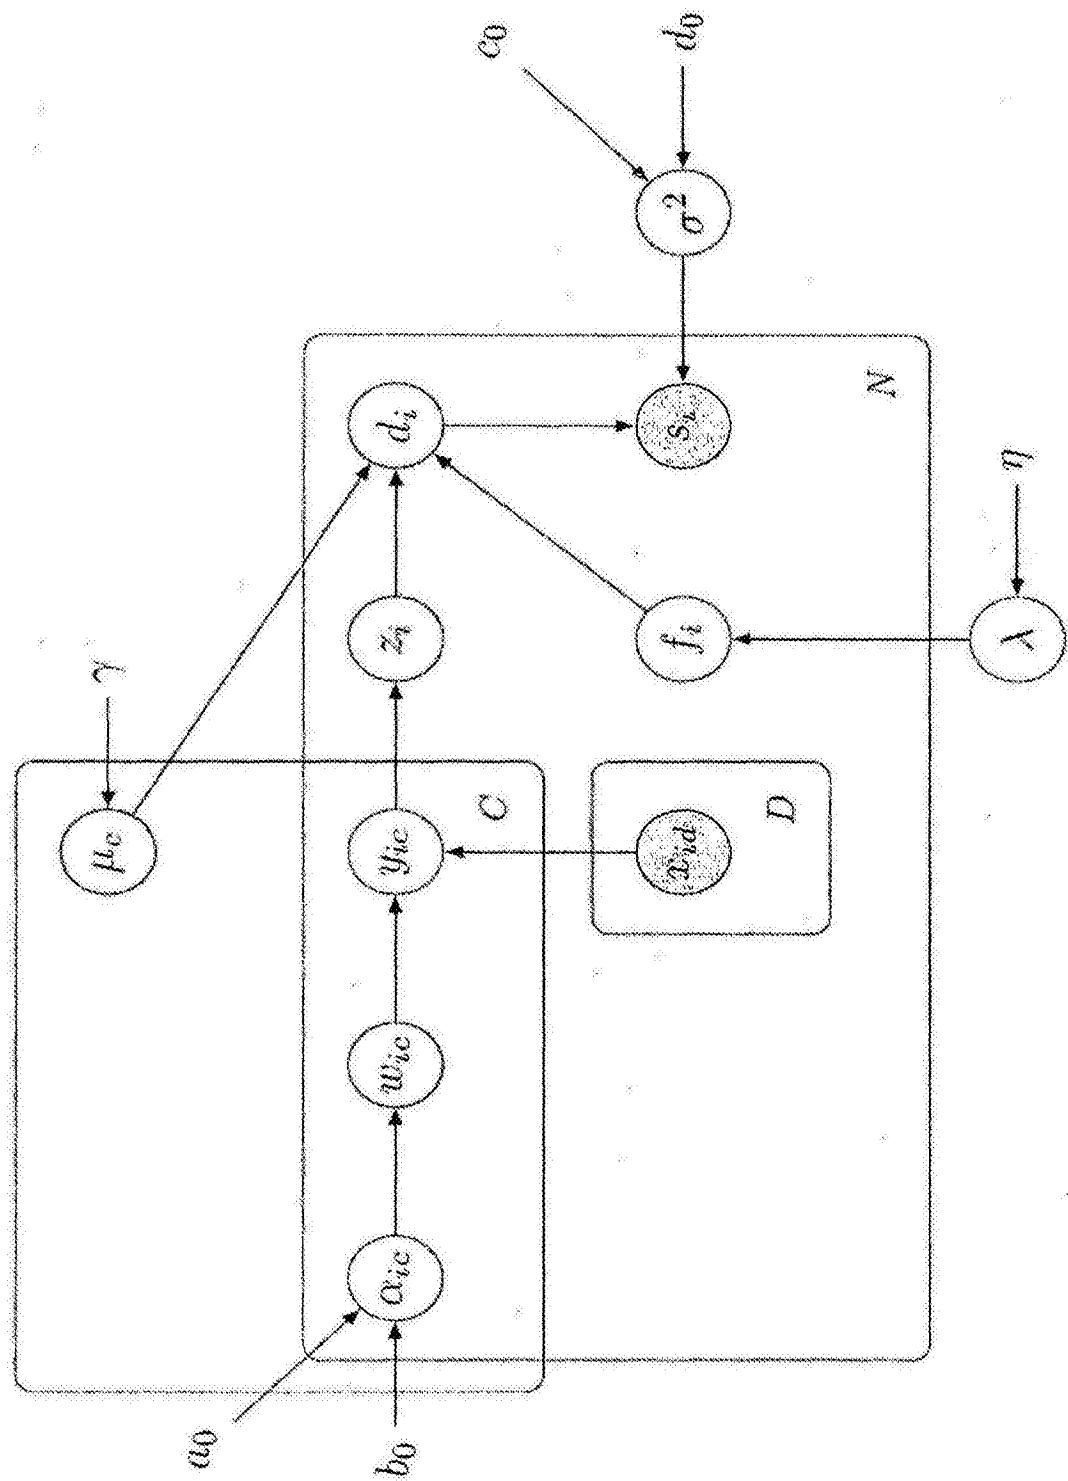


图3