

预测节点状态的方法和装置

5 本申请要求于 2020 年 05 月 14 日提交中国专利局、申请号为 202010409392.2、申请名称为“预测节点状态的方法和装置”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 本申请涉及人工智能技术领域，具体涉及一种预测节点状态的方法和装置。

背景技术

15 在一些网络中，节点的当前状态除了与时间相关，还与该节点所处的空间相关。例如，在蜂窝网络中，一个基站在白天承载的流量与晚上承载流量不同，即，基站承载的流量与时间存在关联关系；此外，位于网络中心的基站承载的流量与位于网络边缘的基站承载的流量不同，即，基站承载的流量与空间存在关联关系。为了便于网络管理和维护，需要对网络中的节点在未来一段时间的状态进行预测。

20 一种预测节点状态的方法是获取预设的网络拓扑图，基于预设的网络拓扑图以及一些与网络相关的时间信息预测网络中节点的状态，这种方法适用于拓扑结构在较长时间内处于固定状态的网络，对于蜂窝网络等拓扑结构随时间发生较快变化的网络，应用上述方法的效果不够理想。

发明内容

25 本申请提供了一种预测节点状态的方法和装置，能够提高具有动态拓扑关系的网络中节点状态的预测准确度。

30 第一方面，提供了一种预测节点状态的方法，包括：获取目标网络中多个节点的静态图和动态图，所述静态图和所述动态图均为拓扑图；根据所述静态图和所述动态图，生成所述多个节点的空间特征数据；获取所述多个节点的时间特征数据；根据所述空间特征数据和所述时间特征数据，获取目标节点在目标时段内的预测状态，所述目标节点为所述多个节点中的任意一个节点。

 在预测节点状态的过程中，除了使用了时间特征和静态空间特征，还使用了动态空间特征，从而提高了具有动态拓扑关系的网络中的节点状态的预测准确度，使得网络在节点状态预测方面更智能化。

35 可选地，所述获取所述多个节点的时间特征数据，包括：获取所述多个节点在第一历史时段内的观测数据，所述第一历史时段为所述目标时段之前的时段；在时间维度上对所述观测数据进行切片，获取时间切片数据，所述时间切片数据的数据量小于所述观测数据的数据量；根据所述时间切片数据获取所述时间特征数据。

 时间切片数据是从完整的观测数据集中选取的部分数据，与完整的观测数据集相比，

时间切片数据的数据量较小,使用时间切片数据进行预测能够减少预测所需的时间。

可选地,所述时间切片数据包括:所述第一历史时段中与所述目标时段相邻的时段内的观测数据。

- 5 可选地,所述第一历史时段中特定时段内的观测数据;其中,所述特定时段位于第一周期内,所述目标时段位于第二周期内,所述特定时段包括所述目标时段在所述第一周期内对应的时段。

相邻时段与目标时段较近,特定时段与目标时段处于不同周期的对应时域位置,因此,相邻时段和特定时段内的观测数据与目标时段内节点的状态有较强的关联性,使用相邻时段和/或特定时段内的观测数据进行预测有利于提高预测准确度。

- 10 可选地,所述获取多个节点的静态图和动态图,包括:获取所述多个节点在第二历史时段内的观测数据,所述第二历史时段为所述目标时段之前的时段;根据所述观测数据,构建所述静态图和所述动态图。

第二历史时段与第一历史时段可以相同,也可以不同。利用观测数据构建静态图和动态图,能够及时获最新的取空间特征。

- 15 可选地,所述观测数据包括以下数据中的至少一个:气象数据、网络拓扑数据、流量数据、语音数据、信令数据、兴趣点 POI 数据、重大事件数据、以及节假日数据。

网络拓扑数据、流量数据、语音数据、信令数据和 POI 数据可以用于构建静态图和动态图,以便于获取空间特征数据;气象数据、重大事件数据和节假日数据可以用于获取时间特征数据,上述用于获取空间特征数据的观测数据也可以用于获取时间特征数据。上述
20 数据的来源不同,数据结构也不同,可以称为多源异构数据,从多源异构数据中获取时间特征数据和空间特征数据,使得时间模型和空间模型能够学习到更丰富的知识,提高预测准确度。

- 25 可选地,还包括:获取所述目标节点在所述目标时段内的真实状态;根据所述真实状态和所述预测状态训练时间模型和空间模型,其中,所述时间模型用于根据输入的观测数据输出所述时间特征数据,所述空间模型用于根据输入的所述静态图和所述动态图输出所述空间特征数据。

通过训练,能够提高空间模型和时间模型的预测准确度。

可选地,所述静态图属于第一类拓扑图,所述动态图属于第二类拓扑图,所述第一类拓扑图的拓扑关系变化速率小于所述第二类拓扑图的拓扑关系变化速率。

- 30 可选地,所述目标网络为通信网络,所述静态图为表征所述多个节点基于流量的拓扑关系的拓扑图,所述动态图为表征所述多个节点基于物理线路的拓扑关系的拓扑图。

第二方面,本申请提供了一种预测节点状态的装置,包括用于执行第一方面所述的方法的单元。该装置可以是终端设备或服务器,也可以是终端设备或服务器内的芯片。该装置可以包括输入单元和处理单元。

- 35 当该装置是终端设备或服务器时,该处理单元可以是处理器,该输入单元可以是收发器;该终端设备还可以包括存储单元,该存储单元可以是存储器;该存储单元用于存储指令,该处理单元执行该存储单元所存储的指令,以使该终端设备执行第一方面所述的方法。

当该装置是终端设备或服务器内的芯片时,该处理单元可以是芯片内部的处理单元,该输入单元可以是输入/输出接口、管脚或电路等;该处理单元执行存储单元所存储的指

令,以使该芯片执行第一方面所述的方法,该存储单元可以是该芯片内的存储单元(例如,寄存器、缓存等),也可以是位于该芯片外部的存储单元(例如,只读存储器、随机存取存储器等)。

- 5 第三方面,本申请提供了一种计算机可读存储介质,该计算机可读存储介质中存储了计算机程序,该计算机程序被处理器执行时,使得处理器执行第一方面所述的方法。

第四方面,本申请提供了一种计算机程序产品,该计算机程序产品包括:计算机程序代码,当该计算机程序代码被处理器运行时,使得处理器执行第一方面所述的方法。

附图说明

- 10 图1是示出了适用于本申请的一种网络;
图2是本申请提供的一种动态图和静态图的示意图;
图3是本申请提供的预测节点状态的方法的示意图;
图4是本申请提供的一种历史流量的示意图;
图5是本申请提供的一种获取时间切片数据的方法的示意图;
15 图6是本申请提供的一种预测基站状态的方法的示意图;
图7是本申请提供的一种预测节点状态的装置的示意图;
图8是本申请提供的一种预测节点状态的设备的示意图。

具体实施方式

- 20 下面将结合附图,对本申请的技术方案进行描述。

图1示出了适用于本申请的一种网络。网络100包括多个基站,基站可以称为节点。基站之间存在两种连接关系,一种是物理线路,另一种是流量,其中,基站之间的流量和基站共同构成了网络100的一种拓扑图,基站之间的物理线路和基站共同构成网络100的另一种拓扑图。受用户的使用行为和移动行为的影响,各个基站承载的流量与时间维度和空间维度具有较强的关联性,因此,基于流量的拓扑图随时间不断变化,这种拓扑关系随时间变化较快的拓扑图可以称为动态图。物理线路不受用户的使用行为和移动行为的影响,这种拓扑图的拓扑关系随时间变化较慢,因此,可以称为静态图。

网络100的动态图和静态图如图2所示。黑色的点表示基站,在动态图中,黑色的点之间的连线表示流量;在静态图中,黑色的点之间的连线表示物理线路。

- 30 除网络100之外,其它存在动态图和静态图的网络均适用于本申请。

例如,在电网中,变电站可以视为节点,变电站之间的输电线路和变电站共同构成电网的静态图,变电站之间的电流和变电站共同构成电网的动态图。

又例如,在社交网络中,用户可以视为节点,朋友用户之间的关系和这些用户共同构成社交网络的静态图,陌生用户之间的关系和这些用户共同构成社交网络的动态图。

- 35 下面以网络100为例详细介绍本申请的技术方案。

如图3所示,方法300包括:

S310,获取目标网络中多个节点的静态图和动态图,所述静态图和所述动态图均为拓扑图。

静态图和动态图属于无向无权图,可以通过 $G=(V,E)$ 表示一个无向无权图,其中, V

表示节点的集合, $\mathcal{E}$ 表示节点之间的连线的集合。可以通过连接矩阵 $A(i, j)$ 表示节点 i 和节点 j 之间的连接关系, 当 $A(i, j)=1$ 时, 表示节点 i 和节点 j 之间存在连接关系; 当 $A(i, j)=0$ 时, 表示节点 i 和节点 j 之间不存在连接关系。

执行方法 300 的装置可以通过多种方法构建不同的图对应的连接矩阵。

- 5 例如, 当基站的经纬度已知时, 可以确定基站之间的距离, 随后可以根据公式 (1) 确定基站之间的连接矩阵, 进而确定静态图。

$$A_{SD}(i, j) = \mathcal{F} \left(e^{\left(\frac{d_{ij}^2}{\sigma^2} \right)} \right) \quad (1),$$

- 10 $A_{SD}(i, j)$ 表示根据距离确定的基站 i 和基站 j 之间的连接关系, 当 $A_{SD}(i, j)=1$ 时, 表示基站 i 和基站 j 之间存在连接关系, 当 $A_{SD}(i, j)=0$ 时, 表示基站 i 和基站 j 之间不存在连接关系; d_{ij} 表示基站 i 和基站 j 之间的距离; e 表示自然常数; σ 为超参数, 用于控制

基站距离数值的大小; $\mathcal{F}$ 是一个映射函数, 用于将 $e^{\left(\frac{d_{ij}^2}{\sigma^2} \right)}$ 映射为 1 或 0。

又例如, 当基站的历史流量已知时, 可以通过历史流量计算相似性, 随后根据公式 (2) 确定基站之间的连接矩阵, 进而确定静态图。

$$A_{FS}(i, j) = \mathcal{F} \left(\rho_{x_w(i), x_w(j)} \right) \quad (2),$$

- 15 $A_{FS}(i, j)$ 表示根据历史流量确定的基站 i 和基站 j 之间的连接关系, 当 $A_{FS}(i, j)=1$ 时, 表示基站 i 和基站 j 之间存在连接关系, 当 $A_{FS}(i, j)=0$ 时, 表示基站 i 和基站 j 之间不存在连接关系; $x_w(i)$ 表示基站 i 的流量的周平均数据; $x_w(j)$ 表示基站 j 的流量的周平均数据; $\rho_{x_w(i), x_w(j)}$ 表示 $x_w(i)$ 和 $x_w(j)$ 的皮尔逊 (pearson) 相关系数; $\mathcal{F}$ 是一个映射函数, 用于将 $\rho_{x_w(i), x_w(j)}$ 映射为 1 或 0。

- 20 上文介绍了确定静态图的方法, 下面介绍确定动态图的方法。

例如, 可以将一个静态图作为初始图, 然后利用实时数据更新该初始图, 从而获得动态图。

又例如, 可以利用实时数据直接构造动态图, 如公式 (3) 所示。

$$A_{TC}^t(i, j) = \mathcal{F} \left(\rho_{x_t(i), x_t(j)} \right) \quad (3),$$

- 25 $A_{TC}^t(i, j)$ 表示基于流量确定的基站 i 和基站 j 之间在时刻 t 的连接关系, $x_t(i) = (x_{t-H+1}(i), \dots, x_{t-1}(i))$, 表示在离时刻 t 最近的 H 个时刻内基站 i 的流量的集合; $x_t(j) = (x_{t-H+1}(j), \dots, x_{t-1}(j))$, 表示在离时刻 t 最近的 H 个时刻内基站 j 的流量的集合; $\rho_{x_t(i), x_t(j)}$ 表示 $x_t(i)$ 和 $x_t(j)$ 的皮尔逊相关系数; $\mathcal{F}$ 是一个映射函数, 用于将 $\rho_{x_t(i), x_t(j)}$ 映射为 1 或 0。

- 30 可选地, 上述几个示例中的 $\mathcal{F}$ 映射变量的方法如公式 (4) 所示。

$$\mathcal{F}(z) = \begin{cases} 1, & |z| \geq \epsilon \\ 0, & |z| < \epsilon \end{cases} \quad (4),$$

z 表示 $e^{\left(\frac{d_{ij}^2}{\sigma^2} \right)}$ 或 $\rho_{x_w(i), x_w(j)}$ 或 $\rho_{x_t(i), x_t(j)}$; ϵ 为超参数, 用于控制拓扑图的疏密度。

适用于本申请的确定静态图和动态图的方法不限于上述示例。

获取静态图和动态图后，执行方法 300 的装置可以执行下列步骤。

S320，根据所述静态图和所述动态图，生成所述多个节点的空间特征数据。

例如，可以通过图神经网络（graph neural networks，GCN）处理静态图和动态图，使用 GCN 的卷积核在静态图和动态图上分别进行卷积操作，获取空间特征数。

S330，获取所述多个节点的时间特征数据。

S320 和 S330 的执行顺序不分先后。可以通过递归神经网络（recursive neural network，RNN）中的门控循环单元（gate recurrent unit，GRU）处理多个节点在历史时段内的观测数据，获得时间特征数据。

上述观测数据包括以下数据中的至少一个：气象数据、网络拓扑数据、流量数据、语音数据、信令数据、兴趣点（point of interest，POI）数据、重大事件数据、以及节假日数据。

通常情况下，观测数据的数据量较大，直接使用观测数据进行预测所需的时间较长，因此，在处理观测数据之前，可以对观测数据进行预处理以减小预测所需的时间。

例如，可以利用观测数据的时间近邻性、周期性等特点对观测数据进行切片（即，采样），从观测数据中确定时间切片数据，其中，时间切片数据的数据量小于观测数据的数据量；随后通过 GRU 处理时间切片数据获取时间特征数据。

下面介绍本申请提供的一种对流量数据进行时间切片的方法。

图 4 示出了目标基站的历史时段（20 天）内的流量数据。可以看出，流量数据呈现明显的周期性。可以基于目标时段（即，待预测的时段）在一个周期内的位置对流量数据进行切片，将其它周期内与目标时段对应的时段内的流量数据确定为时间切片数据，由于不同周期内对应时段内的数据具有相似性，基于此特性获取的时间切片数据进行预测能够在不影响预测效果的同时减小预测所需的时间。

图 5 示出了一种获取时间切片数据的方法。

目标时段为 2018 年 9 月 1 日（周六（Sat.））的上午（a.m.）8:15-9:15，可以以天（day）或周（week）为周期，将相邻周期内与目标时段对应的时段内的流量数据确定为时间切片数据。

例如，目标时段（上午 8:15-9:15）所在的周期（2018 年 9 月 1 日）为第二周期，则 2018 年 8 月 30 日可以作为第一周期，2018 年 8 月 30 日的上午 8:15-9:15 为目标时段在第一周期内对应的时段，可以将包含该对应时段的时段称为特定时段，在图 5 的示例中，2018 年 8 月 30 日的特定时段为上午 6:30-9:30。类似地，还可以确定 2018 年 8 月 30 日的上午 6:30-9:30 为特定时段。本示例中，每个特定时段可以称为 T_d 。

又例如，目标时段（上午 8:15-9:15）所在的周期（2018 年 8 月 27 日至 2018 年 9 月 2 日）为第二周期，则 2018 年 8 月 20 日至 2018 年 8 月 26 日可以作为第一周期，2018 年 8 月 25 日（周六）的上午 8:15-9:15 为目标时段在第一周期内对应的时段，可以将包含该对应时段的时段称为特定时段，在图 5 的示例中，2018 年 8 月 20 日至 2018 年 8 月 26 日的特定时段为 2018 年 8 月 25 日（周六）的上午 6:30-9:30。类似地，还可以确定 2018 年 8 月 11 日（周六）的上午 6:30-9:30 为特定时段。本示例中，每个特定时段可以称为 T_w 。

确定特定时段后，特定时段内的观测数据即时间切片数据。

类似地，还可以以月（month）或季度（quarter）为周期从历史时段内的流量数据中确定时间切片数据。

图 5 所示的例子中，时间切片数据还包括与目标时段相邻的时段内的流量数据，该相邻的时段例如是 2018 年 9 月 1 日的上午 5:00-8:00 以及 2018 年 8 月 30 日的下午（p.m.）

5 8:00-11:00，本示例中，每个相邻的时段可以称为 T_r 。

需要说明的是，上述几个关于时间切片数据的示例可以独立使用，也可以结合使用。

若历史时段内的流量数据为间隔 15 分钟的数据，则图 5 中每个时间切片（ T_d 、 T_w 或 T_r ）包含 12 个数据；可以选择 3 个 T_d 、3 个 T_w 以及 4 个 T_r 内的数据作为时间切片数据，则时间切片数据共有 120 个数据（相当于 8 个小时的数据）。20 天的流量数据一共约 1920 个数据，与时间切片数据相比，使用时间切片数据进行预测能够在不影响预测效果的同时减小预测所需的时间。

获取时间特征数据和空间特征数据后，执行方法 300 的装置可以执行下列步骤。

S340，根据所述空间特征数据和所述时间特征数据，获取目标节点在目标时段内的预测状态，所述目标节点为所述多个节点中的任意一个节点。

15 图 6 示出了本申请提供的一种预测方法。

图 6 中， X' 表示对 t 时刻之前的基站观测数据进行时间切片处理后得到的数据， X' 输入时间模型（temporal modeling），经过时间模型的处理输出时间特征数据 Y' ，该时间模型例如是 GRU。

20 将静态图和动态图输入空间模型（spatial modeling），经过空间模型的处理输出空间特征数据。空间模型例如是 GCN，时间特征数据包括 $\Theta_{*G_i^t}$ ， $\Theta_{*G_i^t}$ 表示利用 GCN 的卷积核 Θ 在图 G_i^t 上进行卷积操作的结果， G_i^t 为 t 时刻之前的动态图和静态图中的一个。

随后，将 Y' 输入空间模型，基于 Y' 和 $\Theta_{*G_i^t}$ 可以得到融合了时间特征和空间特征的结果 Z_i' ，如公式（5）所示。

$$Z_i' = \text{ReLU}\left(\Theta_{*G_i^t}(Y')\right) \quad (5),$$

25 其中， ReLU 表示线性整流函数（rectified linear unit）。

将多个 Z_i' 累加，可以得到空间模型的最终输出结果 Z' ，如公式（6）所示。

$$Z' = \sum_{i=1}^m Z_i' \quad (6).$$

随后，可以通过一个全连接（fully connected, FC）层处理 Z' ，得到 $\hat{x}_{t+k}$ ，如公式（7）所示。

$$30 \quad \hat{x}_{t+k} = Z'W_f + b_f \quad (7),$$

其中， W_f 是 FC 层的权重参数， b_f 是 FC 层的偏置参数， $\hat{x}_{t+k}$ 表示目标基站在 $t+k$ 时刻的预测状态。

35 由上可知，在预测节点状态的过程中，除了使用了从观测数据中获取的时间特征和静态空间特征，还使用了从观测数据中获取的动态空间特征，从而提高了具有动态拓扑关系的网络中的节点状态的预测准确度。

在训练过程中，可以通过最小化损失函数对时间模型、空间模型以及 FC 层进行联合训练，一种可选的损失函数如公式（8）所示。

$$L(\hat{x}_{t+k}, x_{t+k}) = \sum_{t \in T_{train}} \frac{1}{N} \sum_{i=1}^N \left((\hat{x}_{t+k}(i) - x_{t+k}(i))^2 + \alpha \frac{1}{N} |\hat{x}_{t+k}(i) - x_{t+k}(i)| \right) \quad (8),$$

其中, $L(\hat{x}_{t+k}, x_{t+k})$ 为损失函数, x_{t+k} 为 $t+k$ 时刻目标基站的真实状态, $(\hat{x}_{t+k}(i) - x_{t+k}(i))^2$ 为均方误差 (mean square error, MSE), $|\hat{x}_{t+k}(i) - x_{t+k}(i)|$ 平均绝对误差 (mean absolute error, MAE), α 用于平衡 MSE 和 MAD 的权重, N 为节点的数量。

5 下面通过对比方法 300 的预测效果与其它方法的预测效果来说明本申请的有益效果。

参与对比的方法包括历史均值 (historical average, HA)、预言模型 (Prophet)、时空图卷积网络 (spatio-temporal graph convolutional network, STGCN)、注意力时空图卷积网络 (attention spatio-temporal graph convolutional network, ASTGCN) 和扩散卷积循环神经网络 (diffusion convolutional recurrent neural network, DCRNN), 评价指标为均方根误差 (root mean square error, RMSE) 和 MAE, RMSE 和 MAE 的值越小, 说明方法的预测能力越好。对比结果如表 1 所示。

表 1

	15 分钟		30 分钟		45 分钟		1 小时	
	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
HA	108.9	44.2	108.9	44.2	108.9	44.2	108.9	44.2
Prophet	70.3	42.3	72.2	43.0	73.8	43.7	75.2	44.2
STGCN	52.7±1.0	24.7±0.2	66.8±1.6	30.8±0.4	75.3±2.0	34.7±0.6	82.4±2.5	37.9±0.8
ASTGCN	72.4±2.7	28.5±1.2	74.5±2.7	29.9±1.2	78.1±2.6	32.6±1.2	82.1±2.7	35.2±1.3
DCRNN	52.6±0.3	24.4±0.1	64.1±0.7	29.8±0.2	71.8±1.0	33.4±0.3	78.5±1.2	36.5±0.5
方法 300	45.6±0.6	21.4±0.2	51.9±0.8	24.9±0.3	56.4±1.3	27.3±0.4	62.3±1.8	30.6±0.5

STGCN、ASTGCN、DCRNN 和方法 300 都是基于深度学习的方法, 每次运行的结果会有一些差异, 表 1 给出了这几种方法分别预测 10 次的结果, 并给出了均值和方差。由表 1 可以看出, 方法 300 在几种方法中取得了最优的预测效果。

上文详细介绍了本申请提供的预测节点状态的方法的示例。可以理解的是, 相应的装置为了实现上述功能, 其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。

本申请可以根据上述方法示例对装置进行功能单元的划分, 例如, 可以将各个功能划分为各个功能单元, 也可以将两个或两个以上的功能集成在一个单元中。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。需要说明的是, 本申

请中对单元的划分是示意性的，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。

图 7 示出了本申请提供的一种预测节点状态的装置的结构示意图。装置 700 包括输入单元 710 和处理单元 720。

- 5 处理单元 720 用于：获取目标网络中多个节点的静态图和动态图，所述静态图和所述动态图均为拓扑图；根据所述静态图和所述动态图，生成所述多个节点的空间特征数据；获取所述多个节点的时间特征数据；根据所述空间特征数据和所述时间特征数据，获取目标节点在目标时段内的预测状态，所述目标节点为所述多个节点中的任意一个节点。

- 10 可选地，输入单元 710 用于：获取所述多个节点在第一历史时段内的观测数据，所述第一历史时段为所述目标时段之前的时段；处理单元 720 具体用于：在时间维度上对所述观测数据进行切片，获取时间切片数据，所述时间切片数据的数据量小于所述观测数据的数据量；根据所述时间切片数据，获取所述时间特征数据。

可选地，所述时间切片数据包括：所述第一历史时段中与所述目标时段相邻的时段内的观测数据。

- 15 可选地，所述时间切片数据包括：所述第一历史时段中特定时段内的观测数据；其中，所述特定时段位于第一周期内，所述目标时段位于第二周期内，所述特定时段包括所述目标时段在所述第一周期内对应的时段。

- 20 可选地，输入单元 710 用于：获取所述多个节点在第二历史时段内的观测数据，所述第二历史时段为所述目标时段之前的时段；处理单元 720 具体用于：根据所述观测数据，构建所述静态图和所述动态图。

可选地，所述观测数据包括以下数据中的至少一个：气象数据、网络拓扑数据、流量数据、语音数据、信令数据、POI 数据、重大事件数据、以及节假日数据。

- 25 可选地，处理单元 720 还用于：获取所述目标节点在所述目标时段内的真实状态；根据所述真实状态和所述预测状态训练时间模型和空间模型，其中，所述时间模型用于根据输入的观测数据输出所述时间特征数据，所述空间模型用于根据输入的所述静态图和所述动态图输出所述空间特征数据。

可选地，所述静态图属于第一类拓扑图，所述动态图属于第二类拓扑图，所述第一类拓扑图的拓扑关系变化速率小于所述第二类拓扑图的拓扑关系变化速率。

- 30 可选地，所述目标网络为通信网络，所述静态图为表征所述多个节点基于流量的拓扑关系的拓扑图，所述动态图为表征所述多个节点基于物理线路的拓扑关系的拓扑图。

装置 700 执行预测节点状态的方法的具体方式以及产生的有益效果可以参见方法实施例中的相关描述。

- 35 图 8 示出了本申请提供的一种预测节点状态的设备的结构示意图。图 8 中的虚线表示该单元或该模块为可选的。设备 800 可用于实现上述方法实施例中描述的方法。设备 800 可以是终端设备或服务器或芯片。

设备 800 包括一个或多个处理器 801，该一个或多个处理器 801 可支持设备 800 实现方法实施例中的方法。处理器 801 可以是通用处理器或者专用处理器。例如，处理器 801 可以是中央处理器（central processing unit，CPU）。CPU 可以用于对设备 800 进行控制，执行软件程序，处理软件程序的数据。设备 800 还可以包括通信单元 805，用以实现信号

(如观测数据和预测结果)的输入(接收)和/或输出(发送)。

例如,设备 800 可以是芯片,通信单元 805 可以是该芯片的输入和/或输出电路,或者,通信单元 805 可以是该芯片的通信接口,该芯片可以作为终端设备或网络设备或其它电子设备的组成部分。

5 又例如,设备 800 可以是终端设备或服务器,通信单元 805 可以是该终端设备或该服务器的收发器,或者,通信单元 805 可以是该终端设备或该服务器的收发电路。

设备 800 中可以包括一个或多个存储器 802,其上存有程序 804,程序 804 可被处理器 801 运行,生成指令 803,使得处理器 801 根据指令 803 执行上述方法实施例中描述的方法。可选地,存储器 802 中还可以存储有数据(如观测数据)。可选地,处理器 801 还可以读取存储器 802 中存储的数据,该数据可以与程序 804 存储在相同的存储地址,该数据也可以与程序 804 存储在不同的存储地址。

处理器 801 和存储器 802 可以单独设置,也可以集成在一起,例如,集成在终端设备的系统级芯片(system on chip, SOC)上。

处理器 801 执行方法实施例的具体方式可以参见方法实施例中的相关描述。

15 应理解,上述方法实施例的各步骤可以通过处理器 801 中的硬件形式的逻辑电路或者软件形式的指令完成。处理器 801 可以是 CPU、数字信号处理器(digital signal processor, DSP)、专用集成电路(application specific integrated circuit, ASIC)、现场可编程门阵列(field programmable gate array, FPGA)或者其它可编程逻辑器件,例如,分立门、晶体管逻辑器件或分立硬件组件。

20 本申请还提供了一种计算机程序产品,该计算机程序产品被处理器 801 执行时实现本申请中任一方法实施例所述的方法。

该计算机程序产品可以存储在存储器 802 中,例如是程序 804,程序 804 经过预处理、编译、汇编和链接等处理过程最终被转换为能够被处理器 801 执行的可执行目标文件。

25 本申请还提供了一种计算机可读存储介质,其上存储有计算机程序,该计算机程序被计算机执行时实现本申请中任一方法实施例所述的方法。该计算机程序可以是高级语言程序,也可以是可执行目标程序。

该计算机可读存储介质例如是存储器 802。存储器 802 可以是易失性存储器或非易失性存储器,或者,存储器 802 可以同时包括易失性存储器和非易失性存储器。其中,非易失性存储器可以是只读存储器(read-only memory, ROM)、可编程只读存储器(programmable ROM, PROM)、可擦除可编程只读存储器(erasable PROM, EPROM)、电可擦除可编程只读存储器(electrically EPROM, EEPROM)或闪存。易失性存储器可以是随机存取存储器(random access memory, RAM),其用作外部高速缓存。通过示例性但不是限制性说明,许多形式的 RAM 可用,例如静态随机存取存储器(static RAM, SRAM)、动态随机存取存储器(dynamic RAM, DRAM)、同步动态随机存取存储器(synchronous DRAM, SDRAM)、双倍数据速率同步动态随机存取存储器(double data rate SDRAM, DDR SDRAM)、增强型同步动态随机存取存储器(enhanced SDRAM, ESDRAM)、同步连接动态随机存取存储器(synchlink DRAM, SLDRAM)和直接内存总线随机存取存储器(direct rambus RAM, DR RAM)。

本领域的技术人员可以清楚地了解到,为了描述的方便和简洁,上述描述的装置和设

备的具体工作过程以及产生的技术效果，可以参考前述方法实施例中对应的过程和技术效果，在此不再赘述。

5 在本申请所提供的几个实施例中，所揭露的系统、装置和方法，可以通过其它的方式实现。例如，以上所描述的方法实施例的一些特征可以忽略，或不执行。以上所描述的装置实施例仅仅是示意性的，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，多个单元或组件可以结合或者可以集成到另一个系统。另外，各单元之间的耦合或各个组件之间的耦合可以是直接耦合，也可以是间接耦合，上述耦合包括电的、机械的或其它形式的连接。

10 在本申请的各种实施例中，序号的大小并不意味着执行顺序的先后，各过程的执行顺序应以其功能和内在逻辑确定，而不对本申请的实施例的实施过程构成任何限定。

另外，本文中的术语“和/或”，仅仅是一种描述关联对象的关联关系，表示可以存在三种关系，例如，A 和/或 B，可以表示：单独存在 A，同时存在 A 和 B，单独存在 B 这三种情况。另外，本文中字符“/”，一般表示前后关联对象是一种“或”的关系。

15 总之，以上所述仅为本申请技术方案的较佳实施例而已，并非用于限定本申请的保护范围。凡在本申请的原则之内，所作的任何修改、等同替换、改进等，均应包含在本申请的保护范围之内。