



(12) 发明专利

(10) 授权公告号 CN 108564227 B

(45) 授权公告日 2021. 08. 06

(21) 申请号 201810382245.3

(22) 申请日 2018.04.26

(65) 同一申请的已公布的文献号
申请公布号 CN 108564227 A

(43) 申请公布日 2018.09.21

(73) 专利权人 重庆大学
地址 400044 重庆市沙坪坝区正街174号

(72) 发明人 杨梦宁 唐启铖 杨滢 徐玲
赵小超 陈开润

(74) 专利代理机构 重庆晟轩知识产权代理事务
所(普通合伙) 50238
代理人 王海凤

(51) Int. Cl.
G06Q 10/04 (2012.01)
G06Q 50/30 (2012.01)

(56) 对比文件

CN 107103394 A, 2017.08.29

CN 106372722 A, 2017.02.01

WO 2016054360 A1, 2016.04.07

CN 107529651 A, 2018.01.02

王永坤等. 面向公共安全的时空数据挖掘综述.《重庆邮电大学学报》.2018,

审查员 张慧敏

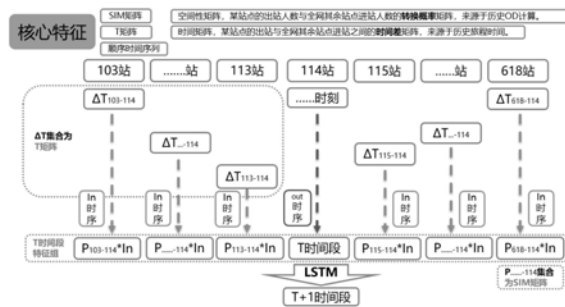
权利要求书3页 说明书10页 附图1页

(54) 发明名称

一种基于时空特征的轨道交通客流量预测方法

(57) 摘要

本发明涉及一种基于时空特征的轨道交通客流量预测方法,包括如下步骤:S1采集轨道交通客流量的历史数据;S2从S1步骤采集的历史数据中,提取0至t时刻目标站点的空间特征和时序特征;S3将步骤S2中0至t时刻目标站点历史数据的空间特征和时序特征对应的合成0至t时刻目标站点的二维向量;S4建立LSTM人工神经网络模型,将0至t时刻目标站点的二维向量作为输入对LSTM人工神经网络模型进行训练,然后再将t时刻目标站点的二维向量输入训练后的LSTM人工神经网络模型,得到t+1时刻目标站点的出站客流量。本发明方法将空间特征和时序特征进行结合,用于预测轨道交通目标站点的客流量,预测精度高。



1. 一种基于时空特征的轨道交通客流量预测方法,其特征在於:包括如下步骤:

S1:采集轨道交通客流量的历史数据;

所述步骤S1中采集轨道交通客流量的历史数据,并使用如下公式对描述历史数据:

$$x_{j,t,in} = \sum_{i \in M} \{i | i.otime \in t; i.ostation = j\} \quad (1-1);$$

$$x_{j,t,out} = \sum_{i \in M} \{i | i.dtime \in t; i.dstation = j\} \quad (1-2);$$

其中, i 代表整个轨道交通数据集 M 中的一条数据, $otime, dtime, ostation, dstation$ 是数据 i 的属性,分别代表进站刷卡时间、出站刷卡时间、起始站编号和终点站编号;

S2:从S1步骤采集的历史数据中,提取0至 t 时刻目标站点的空间特征和时序特征;

所述步骤S2中0至 t 时刻目标站点的空间特征采用如下方法计算:

$$S_{j,r} = \sum_{k=1}^n P_{k,j,r} \ln_{k,r-\Delta T}, r \in [0, t] \quad (2);$$

其中: $S_{j,r}$ 是指 r 时刻其他站点将要到达目标站点 j 的客流总数,即 r 时刻目标站点的空间特征;

n 是 站点集合 N 的总数据量;

N 是轨交通全网站点的集合;

$P_{k,j,r}$ 是指 r 时刻站点 k 与目标站点 j 的空间关联因子;

$\ln_{k,r-\Delta T}$ 代表站点 k 在 $r-\Delta T$ 时间段的进站人数;

ΔT 是站点 k 与目标站点 j 的平均旅行时间差;

$$P_{k,j,r} = \overline{p_{k,j,r^*}}, r^* \in \{r, r+w, r+2w, \dots, r+kw\}, r \in [0, t] \quad (2-1);$$

$$p_{k,j,r} = \frac{x_{k,j,r-\Delta T}}{\ln_{k,r-\Delta T}}, r \in [0, t] \quad (2-2);$$

$$x_{k,j,r-\Delta T} = \sum_{i=1}^m \{i | i.otime \in r - \Delta T; i.ostation = k; i.dstation = j\},$$

$$r \in [0, t] \quad (2-3)$$

$$\ln_{k,r-\Delta T} = \sum_{i=1}^m \{i | i.otime \in r - \Delta T; i.ostation = k\}, r \in [0, t] \quad (2-4);$$

其中, $\ln_{k,r-\Delta T}$ 代表站点 k 在 $r-\Delta T$ 时间段的进站人数;

i 代表整个轨道交通数据集 M 中的一条数据;

m 代表轨道交通数据集 M 的总数据量;

$x_{k,j,r-\Delta T}$ 代表的是 $r-\Delta T$ 时间段,从站点 k 到目标站点 j 的客流人数;

w 代表时间周期;

$P_{k,j,r}$ 就是 r 时刻所有历史同期的 $p_{k,j,r}$ 的平均值;

所述步骤S2中0至 t 时刻目标站点的时序特征采用如下方法获得:

$$T_{j,r} = (t_{j,r} t_{j,r-1} \dots t_{j,r-time_step})^T \quad (3);$$

其中, $T_{j,r}$ 是指 r 时刻历史时间段内目标站点 j 的出站客流总数;

$t_{j,r}$ 代表的是 r 时刻,目标站点 j 的出站人数;

time_step代表的是时间步；

S3: 将步骤S2中0至t时刻目标站点历史数据的空间特征和时序特征对应的合成0至t时刻目标站点的二维向量；

S4: 建立LSTM人工神经网络模型, 将0至t时刻目标站点的二维向量作为输入对LSTM人工神经网络模型进行训练, 然后再将t时刻目标站点的二维向量输入训练后的LSTM人工神经网络模型, 得到t+1时刻目标站点的出站客流量。

2. 如权利要求1所述的基于时空特征的轨道交通客流量预测方法, 其特征在于: 所述步骤S3中0至t时刻目标站点的空间特征和时序特征对应合成0至t时刻目标站点的二维向量Input_{j,r}如下:

$$Input_{j,r} = \begin{pmatrix} t_{j,r} & t_{j,r-1} & \cdots & t_{j,r-time_step} \\ s_{j,r} & s_{j,r-1} & \cdots & s_{j,r-time_step} \end{pmatrix}^T, r \in [0, t] \quad (5)。$$

3. 如权利要求2所述的基于时空特征的轨道交通客流量预测方法, 其特征在于: 所述步骤S4建立的LSTM人工神经网络模型如下:

$$a_r = \sigma(W_{a,r} \cdot x_r + b_{a,r}) \quad (4-1);$$

$$f_r = \sigma(W_{f,r} \cdot [h_{r-1}, a_r] + b_{f,r}) \quad (4-2);$$

$$i_r = \sigma(W_{i,r} \cdot [h_{r-1}, a_r] + b_{i,r}) \quad (4-3);$$

$$\tilde{C}_r = \tanh(W_{c,r} \cdot [h_{r-1}, a_r] + b_{c,r}) \quad (4-4);$$

$$C_r = f_r * C_{r-1} + i_r * \tilde{C}_r \quad (4-5);$$

$$o_r = \sigma(W_{o,r} \cdot [h_{r-1}, a_r] + b_{o,r}) \quad (4-6);$$

$$h_r = o_r * \tanh(C_r) \quad (4-7);$$

其中, a_r 表示r时刻全连接层输出, $W_{a,r}$ 表示r时刻全连接层权重, $b_{a,r}$ 表示r时刻全连接层的偏置, x_r 表示r时刻的输入;

f_r 表示r时刻遗忘门限, h_{r-1} 表示r-1时刻单元的输出, $W_{f,r}$ 表示r时刻遗忘门权重, $b_{f,r}$ 表示r时刻遗忘门的偏置;

i_r 表示r时刻输入门限, $W_{i,r}$ 表示r时刻输入门权重, $b_{i,r}$ 表示r时刻输入门的偏置;

\tilde{C}_r 表示r时刻的cell产生的新状态, $W_{c,r}$ 表示r时刻cell的权重, $b_{c,r}$ 表示r时刻cell的偏置;

\tilde{C}_r 表示r-1时刻的cell状态;

C_r 表示r时刻的cell总状态;

o_r 表示r时刻输出门限, $W_{o,r}$ 表示r时刻输出门的权重, $b_{o,r}$ 表示r时刻输出门的偏置;

h_r 表示r时刻的输出。

4. 如权利要求3所述基于时空特征的轨道交通客流量预测方法, 其特征在于, 所述步骤S4建立的LSTM人工神经网络模型的训练过程如下:

1) 令 $r=1$;

2) 二维向量Input_{j,r}作为输入, 即令 $x_r = \text{Input}_{j,r}$, 并执行如下关系式的计算:

$$a_r = \sigma(W_{a,r} \cdot x_r + b_{a,r}) \quad (4-1);$$

$$f_r = \sigma(W_{f,r} \cdot [h_{r-1}, a_r] + b_{f,r}) \quad (4-2);$$

$$i_r = \sigma(W_{i,r} \cdot [h_{r-1}, a_r] + b_{i,r}) \quad (4-3);$$

$$\tilde{C}_r = \tanh(W_{c,r} \cdot [h_{r-1}, a_r] + b_{c,r}) \quad (4-4);$$

$$C_r = f_r * C_{r-1} + i_r * \tilde{C}_r \quad (4-5);$$

$$o_r = \sigma(W_{o,r} \cdot [h_{r-1}, a_r] + b_{o,r}) \quad (4-6);$$

$$h_r = o_r * \tanh(C_r) \quad (4-7);$$

3) 当 $r > t$ 时, 执行下一步, 否则令 $r = r + 1$, 并返回2);

输出当前LSTM人工神经网络模型, 该模型即为训练后的LSTM人工神经网络模型。

5. 如权利要求4所述的基于时空特征的轨道交通客流量预测方法, 其特征在于: 所述步骤S3中将 t 时刻目标站点的二维向量作为输入, 输入训练后的LSTM人工神经网络模型, 即令

$x_{r=t} = \text{Input}_{j,t}$, 则输出 $h_{j=t} = y_{t+1}$;

y_{t+1} 表示预测结果, 即预测出来的轨道交通 $t+1$ 时刻目标站点 j 的出站客流量。

一种基于时空特征的轨道交通客流量预测方法

技术领域

[0001] 本发明涉及轨道交通客流量预测技术领域,尤其涉及一种基于时空特征的轨道交通客流量预测方法。

背景技术

[0002] 轨道交通客流预测具有很高的价值,在宏观层面,可以为运营调控、线路规划等工程提供支持;在微观层面,可以为大众用户的出行选择提供建议。所以如何准确地预测轨道交通客流成为了一个热门的问题。

[0003] 轨道交通数据的一个显著特点就是具有时间维度,传统的人工神经网络,例如CNN、RNN等,并不能很好的处理时序数据,从而不能很好的根据历史数据来预测轨道交通客流。后来研究人员提出的一些模型,这些模型都可以很好的处理时序数据,但是这些模型对轨道交通客流的预测精度较低,在轨道交通客流预测领域不具有实用性。

发明内容

[0004] 针对现有技术之不足,本发明提供了一种轨道交通客流量预测方法,该方法基于时序特征预测精度高。

[0005] 为实现上述目的,本发明采用如下技术方案:一种基于时空特征的轨道交通客流量预测方法,包括如下步骤:

[0006] S1:采集轨道交通客流量的历史数据;

[0007] S2:从S1步骤采集的历史数据中,提取0至t时刻目标站点的空间特征和时序特征;

[0008] S3:将步骤S2中0至t时刻目标站点历史数据的空间特征和时序特征对应的合成0至t时刻目标站点的二维向量;

[0009] S4:建立LSTM人工神经网络模型,将0至t时刻目标站点的二维向量作为输入对LSTM人工神经网络模型进行训练,然后再将t时刻目标站点的二维向量输入训练后的LSTM人工神经网络模型,得到t+1时刻目标站点的出站客流量。

[0010] 作为改进,所述步骤S1中采集轨道交通客流量的历史数据,并使用如下公式对描述历史数据:

[0011] $x_{y,t,in} = \sum_{i \in M} \{i \mid i.otime \in t; i.ostation = j\}$ (1-1);

[0012] $x_{j,t,out} = \sum_{i \in M} \{i \mid i.dtime \in t; i.dstation = j\}$ (1-2);

[0013] 其中,i代表整个轨道交通数据集M中的一条数据,otime,dtime,ostation,dstation是数据i的属性,分别代表进站刷卡时间、出站刷卡时间、起始站编号和终点站编号。

[0014] 作为改进,所述步骤S2中0至t时刻目标站点的空间特征采用如下方法计算:

[0015] $S_{j,r} = \sum_{k=1}^n P_{k,j,r} \ln_{k,t-\Delta T}, r \in [0, t]$ (2);

[0016] 其中： $S_{j,r}$ 是指r时刻其他站点将要到达目标站点j的客流总数，即r时刻目标站点的空间特征；

[0017] N是轨交通全网站点的集合；

[0018] N代表站点集合N的总数据量；

[0019] $P_{k,j,r}$ 是指r时刻站点k与目标站点j在t时刻的空间关联因子；

[0020] $In_{k,t-\Delta T}$ 代表站点k在r- ΔT 时间段的进站人数；

[0021] ΔT 是站点k与目标站点j的平均旅行时间差；

[0022] $P_{k,j,r} = \overline{p_{k,j,r^*}}, r^* \in \{r, r+w, r+2w, \dots, r+kw\}, r \in [0, t]$ (2-1)；

[0023] $p_{k,j,r} = \frac{x_{k,j,r-\Delta T}}{In_{k,r-\Delta T}}, r \in [0, t]$ (2-2)；

[0024] $x_{k,j,r-\Delta T} = \sum_{i=1}^m \{i | i.otime \in t - \Delta T; i.ostation = k; i.dstation = j\},$

$$r \in [0, t] \quad (2-3)$$

[0025] $In_{k,t-\Delta T} = \sum_{i=1}^m \{i | i.otime \in r - \Delta T; i.ostation = k\}, r \in [0, t]$ (2-4)；

[0026] 其中， $In_{k,t-\Delta T}$ 代表站点k在r- ΔT 时间段的进站人数；

[0027] i代表整个轨道交通数据集M中的一条数据；

[0028] m代表轨道交通数据集M的总数据量；

[0029] $x_{k,j,r-\Delta T}$ 代表的是r- ΔT 时间段，从站点k到目标站点j的客流人数；

[0030] w代表时间周期；

[0031] $P_{k,j,r}$ 就是r时刻所有历史同期的 $p_{k,j,r}$ 的平均值。

[0032] 作为改进，所述步骤S2中0至t时刻目标站点的时序特征采用如下方法获得：

[0033] $T_{j,r} = (t_{j,r}, t_{j,r-1}, \dots, t_{j,r-time_step})^T$ (3)；

[0034] 其中， $T_{j,r}$ 是指r时刻历史时间段内目标站点j的出站客流总数；

[0035] $t_{j,r}$ 代表的是r时刻，目标站点j的出站人数；

[0036] time_step代表的是时间步。

[0037] 作为改进，所述步骤S3中0至t时刻目标站点的空间特征和时序特征对应合成0至t时刻目标站点的二维向量 $Input_{j,t}$ 如下：

[0038] $Input_{j,r} = \begin{pmatrix} t_{j,r} & t_{j,r-1} & \dots & t_{j,r-time_step} \\ S_{j,r} & S_{j,r-1} & \dots & S_{j,r-time_step} \end{pmatrix}^T, r \in [0, t]$ (5)。

[0039] 作为改进，所述步骤S4建立的LSTM神经网络模型如下：

[0040] $a_r = \sigma(W_{a,r} \cdot x_r + b_{a,r})$ (4-1)；

[0041] $f_r = \sigma(W_{f,r} \cdot [h_{r-1}, a_r] + b_{f,r})$ (4-2)；

[0042] $i_r = \sigma(W_{i,r} \cdot [h_{r-1}, a_r] + b_{i,r})$ (4-3)；

[0043] $\tilde{c}_r = \tanh(W_{c,r} \cdot [h_{r-1}, a_r] + b_{c,r})$ (4-4)；

[0044] $C_r = f_r * C_{r-1} + i_r * \tilde{C}_r$ (4-5);

[0045] $o_r = \sigma(W_{o,r} \cdot [h_{r-1}, a_r] + b_{o,r})$ (4-6);

[0046] $h_r = o_r * \tanh(C_r)$ (4-7);

[0047] 其中, a_r 表示r时刻全连接层输出, $W_{a,r}$ 表示r时刻全连接层权重, $b_{a,r}$ 表示r时刻全连接层的偏置, x_r 表示r时刻的输入;

[0048] f_r 表示r时刻遗忘门限, h_{r-1} 表示r-1时刻单元的输出, $W_{f,r}$ 表示r时刻遗忘门权重, $b_{f,r}$ 表示r时刻遗忘门的偏置;

[0049] i_r 表示r时刻输入门限, $W_{i,r}$ 表示r时刻输入门权重, $b_{i,r}$ 表示r时刻输入门的偏置;

[0050] \tilde{C}_r 表示r时刻的cell产生的新状态, $W_{c,r}$ 表示r时刻cell的权重, $b_{c,r}$ 表示r时刻cell的偏置;

[0051] \tilde{C}_r 表示r-1时刻的cell状态;

[0052] C_r 表示r时刻的cell总状态;

[0053] o_r 表示r时刻输出门限, $W_{o,r}$ 表示r时刻输出门的权重, $b_{o,r}$ 表示r时刻输出门的偏置;

[0054] h_r 表示r时刻的输出。

[0055] 作为改进,所述步骤S4建立的LSTM人工神经网络模型的训练过程如下:

[0056] 1) 令 $r=1$;

[0057] 2) 二维向量 $\text{Input}_{j,r}$ 作为输入, 即令 $x_r = \text{Input}_{j,r}$, 并执行如下关系式的计算:

[0058] $a_r = \sigma(W_{a,r} \cdot x_r + b_{a,r})$ (4-1);

[0059] $f_r = \sigma(W_{f,r} \cdot [h_{r-1}, a_r] + b_{f,r})$ (4-2);

[0060] $i_r = \sigma(W_{i,r} \cdot [h_{r-1}, a_r] + b_{i,r})$ (4-3);

[0061] $\tilde{C}_r = \tanh(W_{c,r} \cdot [h_{r-1}, a_r] + b_{c,r})$ (4-4);

[0062] $C_r = f_r * C_{r-1} + i_r * \tilde{C}_r$ (4-5);

[0063] $o_r = \sigma(W_{o,r} \cdot [h_{r-1}, a_r] + b_{o,r})$ (4-6);

[0064] $h_r = o_r * \tanh(C_r)$ (4-7);

[0065] 3) 当 $r > t$ 时, 执行下一步, 否则令 $r=r+1$, 并返回2);

[0066] 输出当前LSTM人工神经网络模型, 该模型即为训练后的LSTM人工神经网络模型。

[0067] 作为改进,所述步骤S3中将t时刻目标站点的二维向量作为输入, 输入训练后的LSTM人工神经网络模型, 即令 $x_{r=t} = \text{Input}_{j,t}$, 则输出 $h_{j=t} = y_{t+1}$;

[0068] y_{t+1} 表示预测结果, 即预测出来的轨道交通t+1时刻目标站点j的出站客流量。

[0069] 本发明具有以下有益效果:

[0070] 本发明创新性的引入了轨道交通两种维度的特征, 时间特征和空间特征, 并且将两种特征进行了结合, 形成二维向量, 将0-t时刻目标站点的二维向量作为输入训练LSTM人工神经网络模型, 再将t时刻目标站点的二维向量作为输入, 预测目标站点t+1时刻的出站客流量, 预测精度高。

附图说明

[0071] 图1是本发明方法的流程简图。

[0072] 图2是本发明方法具体流程图。

具体实施方式

[0073] 为使本发明的目的、技术方案和优点更加清楚明了,下面结合具体实施方式并参照附图,对本发明进一步详细说明。应该理解,这些描述只是示例性的,而并非要限制本发明的范围。此外,在以下说明中,省略了对公知结构和技术的描述,以避免不必要地混淆本发明的概念。

[0074] 轨道交通数据具有时空二维性。

[0075] 时间性:一定时间段内的客流数据具有一定的规律,相邻时间段之间的数据也存在着一定的关联。

[0076] 空间性:两个站点之间在空间上存在着一定的关联。每两个不同站点,在不同时间段的往来存在着一定的规律。

[0077] 由于轨道交通数据除了时间性,还具有空间性,每两个站点之间在空间上存在着一定的关联,这种关联最直接的体现就是旅客的旅行时间。通过将两站点间的空间距离转化为旅行的时间,也就是时间差 ΔT ,就可以表达两站点间的空间关系,本发明通过构建时间差矩阵T来引入全网站点间的空间位置关系。此外,对于某一给定的时间段,每两个站点间的往来客流量存在着一定规律,通过引入空间影响因子矩阵SIM,来引入这种关系。

[0078] 在本发明提出的架构中,将空间影响量转化为时间差来进行处理,这样就可以用处理时序数据的人工神经网络来处理空间性。将时序数据与空间影响量结合,来预测站点的进出站数据,得到了很好的效果。

[0079] 参见图1和图2,一种基于时空特征的轨道交通客流量预测方法,包括如下步骤:

[0080] S1:采集轨道交通客流量的历史数据;

[0081] 具体地,采集轨道交通客流量的历史数据,并使用如下公式对描述历史数据:

$$[0082] \quad x_{j,t,in} = \sum_{i \in M} \{i \mid i.otime \in t; i.ostation = j\} \quad (1-1);$$

$$[0083] \quad x_{j,t,out} = \sum_{i \in M} \{i \mid i.dtime \in t; i.dstation = j\} \quad (1-2);$$

[0084] 其中,i代表整个轨道交通数据集M中的一条数据,otime,dtime,ostation,dstation是数据i的属性,分别代表进站刷卡时间、出站刷卡时间、起始站编号和终点站编号。

[0085] S2:从S1步骤采集的历史数据中,提取0至t时刻目标站点的空间特征和时序特征;

[0086] 具体地,所述步骤S2中0至t时刻目标站点的空间特征采用如下方法计算:

$$[0087] \quad S_{j,r} = \sum_{k=1}^n P_{k,j,r} In_{k,t-\Delta T}, r \in [0, t] \quad (2);$$

[0088] 其中: $S_{j,r}$ 是指r时刻其他站点将要到达目标站点j的客流总数,即r时刻目标站点的空间特征;

[0089] N是轨交通全网站点的集合;

[0090] N代表站点集合N的总数据量;

[0091] $P_{k,j,r}$ 是指r时刻站点k与目标站点j在t时刻的空间关联因子;

[0092] $In_{k,t-\Delta T}$ 代表站点k在r- ΔT 时间段的进站人数;

[0093] ΔT 是站点k与目标站点j的平均旅行时间差;所有站点两两之间的 ΔT 组成了T矩阵,下文详述)所有的P就构成了SIM矩阵(SIM矩阵后面详述),就是目标站点j的出站人数与全网其余站点进站人数的转换概率矩阵(t时间段,从站点k到站点j的进站人数占站点k总进站人数的比率。

$$[0094] \quad P_{k,j,r} = \overline{p_{k,j,r^*}}, r^* \in \{r, r+w, r+2w, \dots, r+kw\}, r \in [0, t] \quad (2-1);$$

$$[0095] \quad p_{k,j,r} = \frac{x_{k,j,r-\Delta T}}{In_{k,r-\Delta T}}, r \in [0, t] \quad (2-2);$$

$$[0096] \quad x_{k,j,r-\Delta T} = \sum_{i=1}^m \{i | i.otime \in t - \Delta T; i.ostation = k; i.dstation = j\},$$

$$r \in [0, t] \quad (2-3)$$

$$[0097] \quad In_{k,t-\Delta T} = \sum_{i=1}^m \{i | i.otime \in r - \Delta T; i.ostation = k\}, r \in [0, t] \quad (2-4);$$

[0098] 其中, $In_{k,t-\Delta T}$ 代表站点k在r- ΔT 时间段的进站人数;

[0099] i代表整个轨道交通数据集M中的一条数据;

[0100] m代表轨道交通数据集M的总数据量;

[0101] $x_{k,j,r-\Delta T}$ 代表的是r- ΔT 时间段,从站点k到目标站点j的客流人数;

[0102] w代表时间周期;

[0103] $P_{k,j,r}$ 就是r时刻所有历史同期的 $p_{k,j,r}$ 的平均值。

[0104] 历史同期:每周的同一时间段,比如所有周数周一的8点30分,就组成了周一8点30分的历史同期组,注意:这里的8点30分指的是一段时间,代表的是8:21~8点30。这段时间为10分钟,是因为我们的实验中预测精度是10分钟,如果预测精度为v,那么t时间段指的就是t-v到t这一段时间。

[0105] 具体地,0至t时刻目标站点的时序特征采用如下方法获得:

$$[0106] \quad T_{j,r} = (t_{j,r} t_{j,r-1} \dots t_{j,r-time_step})^T \quad (3);$$

[0107] 其中, $T_{j,r}$ 是指r时刻历史时间段内目标站点j的出站客流总数;

[0108] $t_{j,r}$ 代表的是r时刻,目标站点j的出站人数;

[0109] time_step代表的是时间步。LSTM神经网络中的常量,由使用者给定具体数值。

[0110] S3:将步骤S2中0至t时刻目标站点历史数据的空间特征和时序特征对应的合成0至t时刻目标站点的二维向量;

[0111] 具体地,所述步骤S3中0至t时刻目标站点的空间特征和时序特征对应合成0至t时刻目标站点的二维向量Input $_{j,t}$ 如下:

$$[0112] \quad Input_{j,r} = \begin{pmatrix} t_{j,r} & t_{j,r-1} & \dots & t_{j,r-time_step} \\ s_{j,r} & s_{j,r-1} & \dots & s_{j,r-time_step} \end{pmatrix}^T, r \in [0, t] \quad (5).$$

[0113] 即将长度为time_step的二维向量作为LSTM人工神经网络模型的输入,经过全连接层处理,全连接层的输出Output $_{full}$ 作为输入层的输入在作为输入层的输入;最后输出一

个长度为1的一维向量。该输出即为目标站点j客流总数的预测值。其实LSTM人工神经网络模型的输出为一个具体的数。

[0114] 经过多次实验发现,该采用二维向量作为输入出站人数较小,数据波动较大的站点,表现普遍较好。

[0115] S4:建立LSTM人工神经网络模型,将0至t时刻对应的二维向量作为输入对LSTM人工神经网络模型进行训练,然后再将t时刻对应的二维向量输入训练后的LSTM人工神经网络模型,得到t+1时刻目标站点的出站客流量。

[0116] 具体地,步骤S4建立的LSTM人工神经网络模型如下:

$$[0117] \quad a_r = \sigma(W_{a,r} \cdot x_r + b_{a,r}) \quad (4-1);$$

$$[0118] \quad f_r = \sigma(W_{f,r} \cdot [h_{r-1}, a_r] + b_{f,r}) \quad (4-2);$$

$$[0119] \quad i_r = \sigma(W_{i,r} \cdot [h_{r-1}, a_r] + b_{i,r}) \quad (4-3);$$

$$[0120] \quad \tilde{C}_r = \tanh(W_{C,r} \cdot [h_{r-1}, a_r] + b_{C,r}) \quad (4-4);$$

$$[0121] \quad C_r = f_r * C_{r-1} + i_r * \tilde{C}_r \quad (4-5);$$

$$[0122] \quad o_r = \sigma(W_{o,r} \cdot [h_{r-1}, a_r] + b_{o,r}) \quad (4-6);$$

$$[0123] \quad h_r = o_r * \tanh(C_r) \quad (4-7);$$

[0124] 其中, a_r 表示r时刻全连接层输出, $W_{a,r}$ 表示r时刻全连接层权重, $b_{a,r}$ 表示r时刻全连接层的偏置, x_r 表示r时刻的输入;

[0125] f_r 表示r时刻遗忘门限, h_{r-1} 表示r-1时刻单元的输出, $W_{f,r}$ 表示r时刻遗忘门权重, $b_{f,r}$ 表示r时刻遗忘门的偏置;

[0126] i_r 表示r时刻输入门限, $W_{i,r}$ 表示r时刻输入门权重, $b_{i,r}$ 表示r时刻输入门的偏置;

[0127] \tilde{C}_r 表示r时刻的cell产生的新状态, $W_{C,r}$ 表示r时刻cell的权重, $b_{C,r}$ 表示r时刻cell的偏置;

[0128] \tilde{C}_r 表示r-1时刻的cell状态;

[0129] C_r 表示r时刻的cell总状态;

[0130] o_r 表示r时刻输出门限, $W_{o,r}$ 表示r时刻输出门的权重, $b_{o,r}$ 表示r时刻输出门的偏置;

[0131] h_r 表示r时刻的输出。

[0132] 在传统的LSTM人工神经网络的输入层前,加入一个全连接层,全连接层的作用是将上文

[0133] 中的形状为[time_step,2]的向量转化为形状为[time_step,rnn_unit]的向量(rnn_unit是细胞数,LSTM神经网络中的常量,由使用者给定具体数值),将转化后的向量输入LSTM的输入层。

[0134] 具体地,所述步骤S4建立的LSTM人工神经网络模型的训练过程如下:

[0135] 1) 令r=1;

[0136] 2) 二维向量Input_{j,r}作为输入,即令 $x_r = \text{Input}_{j,r}$,并执行如下关系式的计算:

$$[0137] \quad a_r = \sigma(W_{a,r} \cdot x_r + b_{a,r}) \quad (4-1);$$

$$[0138] \quad f_r = \sigma(W_{f,r} \cdot [h_{r-1}, a_r] + b_{f,r}) \quad (4-2);$$

$$[0139] \quad i_r = \sigma(W_{i,r} \cdot [h_{r-1}, a_r] + b_{i,r}) \quad (4-3);$$

$$[0140] \quad \tilde{C}_r = \tanh(W_{c,r} \cdot [h_{r-1}, a_r] + b_{c,r}) \quad (4-4);$$

$$[0141] \quad C_r = f_r * C_{r-1} + i_r * \tilde{C}_r \quad (4-5);$$

$$[0142] \quad o_r = \sigma(W_{o,r} \cdot [h_{r-1}, a_r] + b_{o,r}) \quad (4-6);$$

$$[0143] \quad h_r = o_r * \tanh(C_r) \quad (4-7);$$

[0144] 3) 当 $r > t$ 时, 执行下一步, 否则令 $r = r + 1$, 并返回2);

[0145] 输出当前LSTM人工神经网络模型, 该模型即为训练后的LSTM人工神经网络模型。

所述步骤S3中合成的二维向量作为步骤S4中的输入对LSTM人工神经网络模型进行训练, 得到 $W_{a,r}$ 、 $b_{a,r}$ 、 $W_{f,r}$ 、 $b_{f,r}$ 、 $W_{i,r}$ 、 $b_{i,r}$ 、 $W_{c,r}$ 、 $b_{c,r}$ 、 $W_{o,r}$ 和 $b_{o,r}$, 确定训练后的LSTM人工神经网络模型。

[0146] 所述步骤S3中将 t 时刻目标站点的二维向量作为输入, 输入训练后的LSTM人工神经网络模型, 即令 $x_{r=t} = \text{Inpu}_{j,t}$, 则输出 $h_{j=r} = y_{t+1}$;

[0147] y_{t+1} 表示预测结果, 即预测出来的轨道交通 $t+1$ 时刻目标站点 j 的出站客流量。

[0148] 本发明中模型以时间特征和空间特征数据为输入, 输出未来时刻的出站客流数据。输入的时间特征和空间特征数据, 创新性的引入了轨道交通两种维度的特征, 时间特征和空间特征。将时间特征和空间特征二者进行了结合, 形成二维向量作为模型的输入, 输出即为目标站点 $t+1$ 时刻的出站客流量。

[0149] T矩阵的结构如下:

$$[0150] \quad T_t = \begin{pmatrix} \Delta T_{1,1} & \Delta T_{1,2} & \dots & \Delta T_{1,m} \\ \Delta T_{2,1} & \Delta T_{2,2} & \dots & \Delta T_{2,m} \\ \dots & \dots & \Delta T_{k,j} & \dots \\ \Delta T_{m,1} & \Delta T_{m,2} & \dots & \Delta T_{m,m} \end{pmatrix} \quad k, j \in N \quad t \in H$$

[0151] T_t 代表的是 t 时间段的时间差矩阵 T 。

[0152] $\Delta T_{k,j}$ 代表的是 t 时间段站点 k 到站点 j 的时间差的历史同期平均(与计算 $P_{k,j,t}$ 时的历史平均方法一样):

$$[0153] \quad \Delta t_{k,j,t} = \overline{(i.dtime - i.otime)}$$

[0154] ($i \in M, i.dtime \in t, i.ostation = k, i.dstation = j$)

$$[0155] \quad \Delta T_{k,j,t} = \overline{\Delta t_{k,j,t^*}}, t^* \in \{t, t+w, t+2w, \dots, t+kw\}$$

[0156] $\Delta t_{k,j,t}$ 代表的是 t 时刻, 站点 k 到站点 j 的平均旅行时间。

[0157] $\Delta T_{k,j,t}$ 就是所有历史同期的 $\Delta t_{k,j,t}$ 的平均值, 公式中 w 代表一周。

[0158] N 是全网站点的集合, 全网共122个站点, 即 $m = 122$ 。

[0159] H 是所有时间段集合, 一周7天, 每天地铁运营1000分钟, 时间段长度(预测精度)为10分钟, 所以共有 $7 * 1000 / 10 = 700$ 个时间段。

[0160] 对于给定的时间段 t , 就对应一个T矩阵, 矩阵大小是站点数*站点数(122*122, 全网共122个站点), 刻画了全网站点两两之间, 在 t 时间段的旅行时间。在预测实验中, 一天有100个时间段。而且我们还发现, 天与天之间, 两站点的旅行时间都有所不同, 但大致以一周为周期循环(周一到周日全网每两站点间都有不同的旅行时间)。所以, 我们共用到了 $7 * 100$

个T矩阵,每个矩阵大小为122*122。

[0161] SIM矩阵的结构如下:

$$[0162] \quad SIM_t = \begin{pmatrix} P_{1,1} & P_{1,2} & \dots & P_{1,m} \\ P_{2,1} & P_{2,2} & \dots & P_{2,m} \\ \dots & \dots & P_{k,j} & \dots \\ P_{m,1} & P_{m,2} & \dots & P_{m,m} \end{pmatrix} \quad k, j \in N \quad t \in H$$

[0163] SIM_t 代表的是t时刻的空间影响因子矩阵SIM。

[0164] $P_{k,j}$ 代表的是t时刻站点k到站点j的空间影响因子的历史同期平均。

[0165] N是全网站点的集合,全网共122个站点,即 $m=122$ 。

[0166] H是所有时间段集合,一周7天,每天地铁运营1000分钟,时间段长度(预测精度)为10分钟,所以共有 $7*1000/10=700$ 个时间段。

[0167] 对于给定的t时刻,就对应一个SIM矩阵,矩阵大小是站点数*站点数(122*122,全网共122个站点),刻画了全网站点两两之间,在t时刻的进站人数和出站人数的相关度。在预测实验中,一天有100个时间段。而且我们还发现,天与天之间,两站点进站人数和出站人数的相关度规律都有所不同,但大致以一周为周期循环(周一到周日全网每两站点间都有不同的相关度规律)。所以,我们共用到了 $7*100$ 个SIM矩阵,每个矩阵大小为122*122。

[0168] 试验

[0169] 实验数据集与实验对象

[0170] 数据源:2017年3月重庆市全网轨道交通刷卡数据

[0171] 预测对象:重庆100个轨道交通站点的出站人数

[0172] 精度:10分钟

[0173] 数据量:100个站点,每天1000分钟,共30天,每个站点分别有进站客流数据和出站客流数据,全网共 $100*(1000/10)*30*2=600000$ 个数据,其中前28天做训练,后2天做测试。

[0174] 训练次数:3000次。

[0175] 测试模型:仅有时序数据进行预测的传统模型,和加入空间影响量的时空预测模型。

[0176] 准确度衡量指标

[0177] 1) 最大误差

[0178] 预测结果中,预测值与实际值差的绝对值中的最大值。

$$[0179] \quad e_{MAX} = \max\{|x_i - x_i^*|\}$$

[0180] 2) 平均误差

[0181] 预测结果中,预测值与实际值差的绝对值平均。

$$[0182] \quad e_{AVE} = \overline{|x_i - x_i^*|}$$

[0183] 3) 均方根误差

[0184] 预测结果中,预测值与实际值差的绝对值平方和开方。

$$[0185] \quad e_{RMSE} = \sqrt{\overline{|x_i - x_i^*|^2}}$$

[0186] 4) 相对准确度

[0187] 预测结果中,预测值与实际值差的绝对值与实际值的平均百分比。

$$[0188] \quad e_{RE} = \left(\frac{|x_t - x_t^*|}{x_t^*} \right)$$

[0189] 试验结果

模型名称	最大误差	平均误差	均方根误差	相对准确度
二维输入时空预测模型	127.90	19.06	27.87	83.81%
时序预测模型	182.88	24.81	37.51	79.16%

[0191] 实验结论

[0192] 经过对100个站点的实验后,两种结合方式的时空预测模型的表现良好,各项指标明显高于传统的时序预测模型,预测准确度有显著提升。

[0193] 为了防止字母所表示含义缺失,做如下列表:

名称	含义
$x_{j,t,in}$	站点 j 在 t 时间段的进站人数
$x_{j,t,out}$	站点 j 在 t 时间段的出站人数
$otime$	进站时间
$dtime$	出站时间
$ostation$	起始站编号
$dstation$	终点站编号
$T_{j,t}$	站点 j 在 t 时间段的时序特征
$S_{j,t}$	站点 j 在 t 时间段的时空特征
$P_{k,j,t}$	站点 k 与站点 j 在 t 时间段的时空关联因子
$In_{k,t-\Delta T}$	站点 k 在 $t - \Delta T$ 时间段的进站人数
$time_step$	时间步, LSTM 中的常量
rnn_unit	细胞数。LSTM 中的常量

	T_t	t 时刻的时间差矩阵
	SIM_t	t 时刻的空间影响因子矩阵
[0195]	集合 M	刷卡数据集
	集合 N	站点编号集
	集合 H	时间段集

[0196] 以上所述,仅为本发明的具体实施方式,但本发明的保护范围并不限于此,任何熟悉本技术领域的技术人员在本发明揭露的技术范围内,可轻易想到变化或替换,都应涵盖在本发明的保护范围之内。因此,本发明的保护范围应以权利要求的保护范围为准。




图1

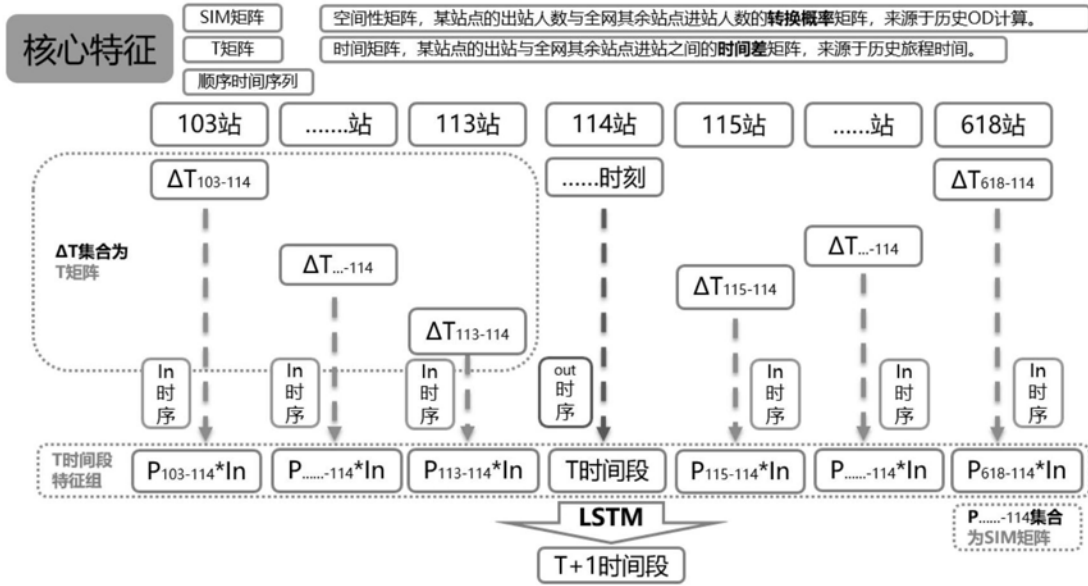


图2