

(19) 中华人民共和国国家知识产权局



(12) 发明专利说明书

(10) 申请公布号 CN 110210644 A

(43) 申请公布日 2019.09.06

(21) 申请号 CN201910308192.5

(22) 申请日 2019.04.17

(71) 申请人 浙江大学

地址 310058 浙江省杭州市西湖区余杭塘路 866 号

(72) 发明人 李春光 权钰杰

(74) 专利代理机构 杭州求是专利事务有限公司

代理人 林超

(51) Int. CI

权利要求说明书 说明书 幅图

(54) 发明名称

基于深度神经网络集成的交通流量
预测方法

(57) 摘要

本发明公开了一种基于深度神经网络集成的交通流量预测方法。获取交通流量原始数据进行数据预处理，构建样本数据，将样本数据划分为训练集和测试集，样本数据主要为多个交通流量测量值组成的一维时间序列数据；构建用于交通流量预测的卷积神经网络预测模型，将样本数

据输入到模型中使用梯度优化算法进行训练，并在训练集上对训练好的模型计算预测误差的方差；根据预测误差的方差使用卷积神经网络预测模型作为个体学习器，构建用于交通流量预测的卷积神经网络集成模型；使用卷积神经网络集成模型对待测的交通流量数据进行预测。本发明基于卷积神经网络模型，利用集成学习方法，提出了一种改进的交通流量预测方法，提高了预测的准确性。

法律状态

法律状态公告日

法律状态信息

法律状态

2021-11-02

发明专利申请公布后的视为撤回

发明专利申请公布后的
视为撤回

2019-10-08

实质审查的生效

实质审查的生效

2019-09-06

公开

公开

权利要求说明书

1.一种基于深度神经网络集成的交通流量预测方法,其特征在于:包括以下几个步骤:

(1)获取交通流量原始数据进行数据预处理,构建样本数据,将样本数据划分为训练集和测试集,所述样本数据主要为多个交通流量测量值组成的一维时间序列数据;

(2)构建用于交通流量预测的卷积神经网络预测模型,将样本数据输入到模型中使用梯度优化算法进行训练,并在训练集上对训练好的模型计算预测误差的方差;

(3)根据预测误差的方差使用步骤(2)中的卷积神经网络预测模型作为个体学习器,构建用于交通流量预测的卷积神经网络集成模型;

(4)使用步骤(3)中的卷积神经网络集成模型对待测的交通流量数据进行预测。

2.根据权利要求1所述的一种基于深度神经网络集成的交通流量预测方法,其特征在于:所述步骤(1)具体如下:

(1.1)通过布置在道路上的传感器进行测量记录,由单个传感器得到的交通流量测量值按照时间顺序组成一组交通流量数据序列 $\{x_t$

t

, $t=1, 2, \dots$ 其中 x_t

t

表示 t 时刻的交通流量测量值, T 表示测量时刻总数,每个传感器对应具有一个交通流量数据序列,获得交通流量原始数据;

(1.2)对各个传感器得到的交通流量数据序列进行数据预处理,数据预处理包括最大最小值归一化,然后经过数据预处理后构建样本容量为 N 的样本数据:

$\{(x_t$

t

, y_t

t

), $\in N\}$

x_t

t

$= [x_t$

$$\begin{bmatrix} x_t \\ x_{t-1} \\ x_{t-2} \\ \dots \\ x_{t-d+1} \end{bmatrix} = y_t$$

$N=T-d+1$

其中, (x_t, y_t)

表示构成了一个样本, x_t

表示交通流量输入序列,是由 t 时刻交通流量测量值 x_t

及 $(d-1)$ 个 t 时刻之前历史的交通流量测量值构成的一维时间序列数据, d 表示交通流量输入序列 x_t

的数据长度; y_t

表示交通流量输出值;

(1.3)将样本数据划分为训练集和测试集。

3.根据权利要求1所述的一种基于深度神经网络集成的交通流量预测方法,其特征在于:所述步骤(2)的具体步骤如下:

(2. a)构建一个具有分支结构的卷积神经网络预测模型,包括依次连接的主干部分、分支部分和输出部分的三个部分:

主干部分,包括依次连接的输入层、三层第一堆叠结构和最大池化层,输入层后面连接三层由一维卷积层和修正线性单元(ReLU) 激活函数层组成的第一堆叠结构,最后一个第一堆叠结构后连接一个最大池化层;

分支部分,包括两条相互独立的分支子结构,一条分支子结构上采用主要由一维卷积层和修正线性单元激活函数层组成的三个第二堆叠结构,三个第二堆叠结构依次连接并连接到主干部分的最大池化层之后;另一条分支子结构只使用一个卷积层,卷积层连接到主干部分的最大池化层之后;两条分支子结构之后经过各自的最大池化层后再连接拼接合并层进行拼接合并,且拼接合并后的数据展平为可被输出部分全连接层处理的一维向量数据;

输出部分,包括依次连接的两个全连接层,第一个全连接层连接到分支部分的拼接合并层之后,两个全连接层中间包含一个修正线性单元激活函数层,第二个全连接层的输出作为预测模型的输出值;

(2. b)卷积神经网络预测模型中使用中心化误差熵损失函数作为损失函数进行训练,包括误差熵损失函数和相关熵损失函数:

交通流量数据中, t 时刻的输入数据 x

t

输入并经过卷积神经网络预测模型处理得到预测输出值

建立训练误差表示为

由包含 M 个样本数据计算得到的训练误差的二次 Renyi 熵估计

如公式(1)所示:

$i = (x$

i

, y
i
)

其中, e

i

, e

j

分别表示样本 i, 的训练误差, 样本 i, 表示为不同的样本, M 表示训练集中的样本总数,

是高斯核函数, σ 是核函数的带宽;

所述的误差熵损失函数 J

MEE

具体表示为:

所述的相关熵损失函数 J

MCC

具体表示为:

其中, e

i

表示样本 i 的训练误差, M 表示训练集中的样本总数,

是高斯核函数, σ 是核函数的带宽;

结合误差熵损失函数 J

MEE

与相关熵损失函数 J

MCC

构成熵测度函数,即中心化误差熵损失函数 J

CEEC

,如公式(4)所示:

其中, λ 表示熵测度权值系数;

(2. b)使用 Adam 梯度优化算法对采用了中心化误差熵损失函数的卷积神经网络预测模型进行训练,使用训练好的卷积神经网络预测模型再对交通流量数据训练集进行处理预测,并计算获得预测误差的方差

其中,

表示样本 i 的预测误差,
表示样本 i 的预测输出值,
表示预测误差
的均值。

4.根据权利要求 1 所述的基于深度神经网络集成的交通流量预测方法,其特征在于:
所述步骤(3)中,卷积神经网络集成模型构建如下:

具体过程如下:根据预测误差的方差

随机生成具有方差

的独立同分布高斯噪声序列,利用独立同分布高斯噪声序列在交通流量原始数据上
添加高斯噪声扰动数据,生成 K 组模拟数据:

其中,

表示方差为

的第 k 个独立同分布高斯噪声序列中 t 时刻的元素, k 表示独立同分布高斯噪声序列
的序数, K 表示随机生成的独立同分布高斯噪声序列的总数;

然后将生成的 K 组模拟数据加上交通流量原始数据,共计 $K+1$ 组数据均各自作为训
练集分别采用步骤(2)中的方法训练得到训练好的模型,每个训练好的模型作为一个
个体学习器,共得到 $K+1$ 个个体学习器。

5.根据权利要求 1 所述的基于深度神经网络集成的交通流量预测方法,其特征在于:
所述步骤(4)的具体步骤如下:将待测的交通流量数据分别输入到 $K+1$ 个个体学习器
中,得到 $K+1$ 个预测输出值,再对所有预测输出值计算平均值,作为卷积神经网络集成
模型的预测结果。

说明书

<p>技术领域

本发明属于机器学习和智能交通系统领域,特别是涉及一种基于深度神经网络集成的交通流量预测方法。

背景技术

智能交通系统是一种以信息技术、传感器技术等先进科学技术为基础发展起来的道路交通综合管理系统。

交通流量预测是智能交通系统中重要的技术环节,实现准确可靠的交通流量预测至关重要。交通流量预测能够根据当前路况信息,对未来一段时间内交通流量的变化趋势做出合理准确的推断,有助于实施精确有效的交通调度,提高运输效率,是智能交通系统中的重要技术环节。交通流量数据,包括车速、车流量等,可以通过传感器进行有效测量,并记录为一组时间序列数据。在现实场景中,道路交通状况十分复杂,交通流量数据往往表现出明显的非线性,且测量数据易受到复杂噪声环境的干扰,这些因素都增加了交通流量预测的难度。

目前解决交通流量预测问题的方法大致可分为两类:参数化方法和非参数化方法。参数化方法需要预先假设模型参数的具体形式,其中以 ARIMA(求和自回归滑动平均)模型为代表的时序分析方法应用广泛。ARIMA 模型利用时序数据中存在的自相关性,基于交通流量历史观测数据完成模型的构建。但是 ARIMA 模型属于线性估计模型,不能很好地处理交通流量数据中普遍存在的复杂非线性特性。

非参数化方法不需要预先对模型做出具体假设,而是以数据驱动的方式,从数据中发掘出有助于模型构建的有效信息,神经网络是其中一种典型代表。神经网络具有良好的非线性拟合能力,与 ARIMA 类模型相比,能够更好地适用于对非线性数据特征

的提取。目前已有许多关于神经网络模型在交通流量预测问题中的应用研究。伴随着近年来发展起来的深度学习技术,越来越多的深度神经网络模型被用来解决交通流量预测问题。现有的基于深度神经网络模型的预测方法大多是以均方误差函数作为损失函数进行训练的,这在高斯噪声环境中可以得到理想的预测效果。但是现实场景中交通流量数据的测量环境往往十分复杂,会存在异常数据等非高斯噪声的干扰,基于均方误差损失函数的模型就无法从训练数据中获得充分有效的信息,导致模型性能受到严重影响。另外,深度神经网络模型拥有十分庞大的参数量,存在模型训练不稳定,易陷入性能较差的局部极小点等问题。

发明内容

本发明的目的在于针对现有预测方法的不足,提出了一种基于深度神经网络集成的交通流量预测方法,利用集成学习方法,从而提高预测准确度。本发明解决了以ARIMA 模型为代表的时序分析方法不能很好地处理交通流量数据中明显的非线性特征、预测性能不佳的技术问题,解决了深度学习技术在非高斯噪声环境下无法充分提取出交通流量数据中的有效信息而影响模型性能的技术问题,解决了深度神经网络还存在训练不稳定的技术问题。

本发明解决其技术问题所采用的技术方案具体包括如下步骤:

(1)获取交通流量原始数据进行数据预处理,构建样本数据用于卷积神经网络模型的训练和测试,将样本数据划分为训练集和测试集,所述样本数据主要为多个交通流量测量值组成的一维时间序列数据;

(2)构建用于交通流量预测的基于中心化误差熵损失函数的卷积神经网络预测模型,将样本数据输入到模型中使用梯度优化算法进行训练,并在训练集上对训练好的模型计算预测误差的方差;

(3)根据预测误差的方差使用步骤(2)中的卷积神经网络预测模型作为个体学习器,构建用于交通流量预测的卷积神经网络集成模型;

(4)使用步骤(3)中的卷积神经网络集成模型对待测的交通流量数据进行预测。待测的交通流量数据同时也要经步骤(1)中数据预处理和构建样本数据后再输入集成模型中。

所述步骤(1)具体如下:

(1.1)通过布置在道路上的传感器进行测量记录,由单个传感器得到的交通流量测量值按照时间顺序组成一组交通流量数据序列 $\{x$

t

, $t=1, 2, \dots$ 其中 x

t

表示 t 时刻的交通流量测量值, T 表示测量时刻总数,每个传感器对应具有一个交通流量数据序列,获得交通流量原始数据;

所述的传感器可以采用红外传感器对道路车辆进行计数。

(1.2)对各个传感器得到的交通流量数据序列进行数据预处理,数据预处理包括最大最小值归一化,然后经过数据预处理后构建样本容量为 N 的样本数据:

$\{(x$

t

, y

t

), $\in \mathbb{N}$

x

t

= [x

t

, x

t-1

, x

t-2

..., x

t-d+1

]

y

t

$=x$

$t+1$

$N=T-d+1$

其中, $(x$

t

, y

t

)表示构成了一个样本, x

t

表示交通流量输入序列,是由 t 时刻交通流量测量值 x

t

及 $(d-1)$ 个 t 时刻之前历史的交通流量测量值构成的一维时间序列数据, d 表示交通流量输入序列 x

t

的数据长度; y

t

表示交通流量输出值, x

t

, y

t

将分别作为卷积神经网络预测模型的输入数据和期望输出数据;

本发明对短时交通流量数据进行预测,即以 t 时刻可以获得的交通流量数据信息去预测未来 $t+1$ 时刻的交通流量数据值。因为时间序列数据的特殊性,这里的 t 既可以表示 t 时刻,也可以表示第 t 个样本序数。

(1.3)将样本数据划分为训练集和测试集,分别用于卷积神经网络模型的训练和测试。

所述步骤(2)的具体步骤如下:

(2. a)构建一个具有分支结构的卷积神经网络预测模型,包括依次连接的主干部分、分支部分和输出部分的三个部分:

主干部分,包括依次连接的输入层、三层第一堆叠结构和最大池化层,输入层后面连接三层由一维卷积层和修正线性单元(ReLU) 激活函数层组成的第一堆叠结构,最后一个第一堆叠结构后连接一个一维的最大池化层,最大池化层对网络中的数据进行下采样;

分支部分,包括两条相互独立的分支子结构,一条分支子结构上采用主要由一维卷积层和修正线性单元激活函数层组成的三个第二堆叠结构,三个第二堆叠结构依次连接并连接到主干部分的最大池化层之后;另一条分支子结构只使用一个卷积层,卷积层连接到主干部分的最大池化层之后;两条分支子结构之后经过各自的一维的最大池化层后再连接拼接合并层进行拼接合并,且拼接合并后的数据展平为可被输出部分全连接层处理的一维向量数据;

输出部分,包括依次连接的两个全连接层,第一个全连接层连接到分支部分的拼接合并层之后,两个全连接层中间包含一个修正线性单元激活函数层,第二个全连接层的输出作为预测模型的输出值;

(2. b卷积神经网络预测模型中使用中心化误差熵损失函数作为损失函数进行训练,包括误差熵损失函数和相关熵损失函数:

误差熵衡量了模型预测误差分布的不确定性,使用基于 Parzen窗方法的二次 Renyi 熵估计来计算误差熵。

交通流量数据中, t 时刻的输入数据 x

t

输入并经过卷积神经网络预测模型处理得到预测输出值

建立训练误差表示为

由包含 M 个样本数据计算得到的训练误差的二次 Renyi 熵估计

如公式(1)所示:

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/538115122025007006>