



(12) 发明专利

(10) 授权公告号 CN 110346005 B

(45) 授权公告日 2020. 09. 22

(21) 申请号 201910499207.0

(22) 申请日 2019.06.11

(65) 同一申请的已公布的文献号
申请公布号 CN 110346005 A

(43) 申请公布日 2019.10.18

(73) 专利权人 华南理工大学
地址 510640 广东省广州市天河区五山路
381号

(72) 发明人 刘亚俊 张研晋 刘振东

(74) 专利代理机构 广州市华学知识产权代理有
限公司 44245
代理人 梁莹 顾思妍

(51) Int. Cl.
G01F 1/84 (2006.01)
G06N 7/00 (2006.01)

(56) 对比文件

KR 1020190018293 A, 2019.02.22

CN 109522854 A, 2019.03.26

卢敏嘉等.《液体流量校准装置应用集成平台》.《机床与液压》.2018,第46卷(第15期),
翁润滢.《基于自适应最优核卷积神经网络的气液两相流流型识别方法》.《化工学报》.2018,

审查员 宋丽敏


权利要求书3页 说明书6页 附图2页

(54) 发明名称

基于深度学习的科里奥利质量流量计数字
信号处理方法

(57) 摘要

本发明提供一种基于深度学习的科里奥利质量流量计数字信号处理方法,首先,建立水流量测试平台;其次,对每组样本数据进行预处理,分别得到样本的第二训练集、验证集和测试集;然后,构建第一深度学习网络模型和第二深度学习网络模型,采用第二训练集分别对第一深度学习网络模型和第二深度学习网络模型进行训练;在训练过程中,采用批归一化方法使得第一深度学习网络模型和第二深度学习网络模型收敛;最后,采用基于贝叶斯的模型融合法对第一流量信号和第二流量信号进行融合,得到流量信号的最优估计值,以提高流量测量的精度。本发明的科里奥利质量流量计测量的振动信号通过本发明方法处理可得到高精度的流量信号,从而提高流量的测量精度。



CN 110346005 B

1. 一种基于深度学习的科里奥利质量流量计数字信号处理方法,其特征在于:首先,建立水流量测试平台,并采集水流量测试平台的拾振信号作为输入特征,采集水流量测试平台中科里奥利质量流量计的输出瞬时质量流量作为样本标签;其中,输入特征与对应的样本标签组成一组样本数据;

其次,对每组样本数据进行预处理,分别得到样本的第二训练集、验证集和测试集;

然后,构建第一深度学习网络模型和第二深度学习网络模型,采用第二训练集分别对第一深度学习网络模型和第二深度学习网络模型进行训练;在训练过程中,采用批归一化方法以提高第一深度学习网络模型和第二深度学习网络模型的收敛速度,采用验证集对建立的第一深度学习网络模型和第二深度学习网络模型进行验证并调整超参数,采用测试集对调整好的第一深度学习网络模型和第二深度学习网络模型进行性能测试,以得到性能好的第一深度学习网络模型和第二深度学习网络模型;

最后,采用科里奥利质量流量计与性能好的第一深度学习网络模型结合测量计算得到所需的第一流量信号,采用科里奥利质量流量计与性能好的第二深度学习网络模型结合测量计算得到所需的第二流量信号,并采用基于贝叶斯的模型融合法对第一流量信号和第二流量信号进行融合,得到流量信号的最优估计值,以提高流量测量的精度;

所述对每组样本数据进行预处理,分别得到样本的第二训练集、验证集和测试集是指:包括以下步骤:

第一步,对每组样本数据进行剔除错误数据;

第二步,对每组样本数据输入标准化;标准化公式如下:

$$x_{ij}^* = \frac{x_{ij} - \bar{x}_i}{\sigma_i}$$

其中, x_{ij} 为第j个样本,第i个特征量的取值, x_{ij}^* 则为更新后的取值; $\bar{x}_i$ 为第i个特征量的样本均值; σ_i 为第i个特征量的样本方差;

第三步,对标准化后的样本数据分配为第一训练集、验证集和测试集;

第四步,随机打乱第三步的第一训练集顺序,得到第二训练集;

所述采用第二训练集分别对第一深度学习网络模型和第二深度学习网络模型进行训练是指:采用第二训练集并使用mini-batch梯度下降法分别训练第一深度学习网络模型和第二深度学习网络模型,即将第二训练集划分为若干个小的训练集分别训练第一深度学习网络模型和第二深度学习网络模型。

2. 根据权利要求1所述的基于深度学习的科里奥利质量流量计数字信号处理方法,其特征在于:所述水流量测试平台包括变频泵、标准表、节流阀一、节流阀二、节流阀三、被检表和水箱;所述变频泵、标准表、节流阀一、被检表、节流阀二、水箱和变频泵依次连接,形成循环;所述变频泵通过节流阀三与水箱连接。

3. 根据权利要求2所述的基于深度学习的科里奥利质量流量计数字信号处理方法,其特征在于:所述标准表和被检表均为科里奥利质量流量计且标准表的测量精度高于被检表的测量精度。

4. 根据权利要求2所述的基于深度学习的科里奥利质量流量计数字信号处理方法,其特征在于:所述采集水流量测试平台的拾振信号作为输入特征,采集水流量测试平台中科里奥利质量流量计的输出瞬时质量流量作为样本标签是指:通过RS-485接口和数据采集卡

分别记录标准表所测得的瞬时质量流量作为样本标签,以及采集被检表两端的拾振信号LP0和RP0作为输入特征;

采样期间不断地改变变频泵的输入频率,以及对节流阀一、节流阀二和节流阀三的开度进行调节,以获得各状态下的样本数据。

5.根据权利要求1所述的基于深度学习的科里奥利质量流量计数字信号处理方法,其特征在于:所述第一深度学习网络模型由输入层、三层隐藏层L1,L2和L3、以及输出层连接组成;其中,L1为LSTM层,L2为LSTM层的输出层,L3为全连接层并采用tanh激活函数;L1和L2的长度S等于待处理的信号序列长度,L1和L2的隐含节点数分别为16和4,L3的神经元数为300;

所述第一深度学习网络模型的损失函数为:

$$Loss = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 + \frac{\lambda}{m} \sum_j \omega_j^2$$

其中,等式右边的第一项为均方误差; λ 为正则化系数。

6.根据权利要求1所述的基于深度学习的科里奥利质量流量计数字信号处理方法,其特征在于:第二深度学习网络模型由输入层、输出层以及三层隐藏层组成,且各层之间均为全连接;三层隐藏层的神经元数分别为256、128和300。

7.根据权利要求1所述的基于深度学习的科里奥利质量流量计数字信号处理方法,其特征在于:所述采用批归一化方法使得第一深度学习网络模型和第二深度学习网络模型收敛是指:采用以下公式对第一深度学习网络模型和第二深度学习网络模型的输出进行批归一化:

$$\mu_B \leftarrow \frac{1}{m} \sum_{i=1}^m x_i$$

$$\sigma_B^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2$$

$$\hat{x}_i \leftarrow \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}$$

$$y_i \leftarrow \gamma \hat{x}_i + \beta$$

其中 γ 和 β 是新增的两个参数,可通过第一深度学习网络模型或第二深度学习网络模型训练来调整;m代表mini-batch梯度下降法训练第一深度学习网络模型或第二深度学习网络模型的样本个数;

在采用批归一化方法使得第一深度学习网络模型和第二深度学习网络模型收敛过程中,采用滑动平均法计算得到全局均值和方差:

$$\mu_{\text{global}} \leftarrow D \times \mu_{\text{global}} + (1-D) \times \mu_B$$

$$\sigma_{\text{global}} \leftarrow D \times \sigma_{\text{global}} + (1-D) \times \sigma_B$$

其中,D是衰减系数。

8.根据权利要求1所述的基于深度学习的科里奥利质量流量计数字信号处理方法,其特征在于:所述采用基于贝叶斯的模型融合法对第一流量信号和第二流量信号进行融合,

得到流量信号的最优估计值是指：设质量流量的状态量为 Y ，第一流量信号和第二流量信号为 Z ；条件概率密度函数 $P(Z|Y)$ 表示在状态 $Y=y$ 下，模型输出值 $Z=z$ 的概率； Y 服从均匀分布，先验概率 $P(Y)$ 为常数；在 Z 已知条件下 Y 的后验条件概率如下式所示：

$$P(Y|Z) = \frac{P(Z|Y)P(Y)}{\int P(Z|Y)P(Y) dY}$$

其中，式中的分母只与模型输出 Z 有关，由最大后验估计可得：

$$\hat{Y}_{MAP} = \operatorname{argmax} P(Y|Z) \propto P(Z|Y)P(Y)$$

每个模型的输出均服从高斯分布，即：

$$P(Z_k = z_k | Y = y) = \frac{1}{\sigma_k \sqrt{2\pi}} \exp\left[-\frac{(z_k - y)^2}{2\sigma_k^2}\right]$$

由上式可得最优估计值：

$$\hat{Y}_{MAP} = \frac{\sum_{k=1}^l \frac{Z_k}{\sigma_k^2}}{\sum_{k=1}^l \frac{1}{\sigma_k^2}}$$

该最优估计值则为流量信号的最优估计值。

基于深度学习的科里奥利质量流量计数字信号处理方法

技术领域

[0001] 本发明涉及数字信号处理技术领域,更具体地说,涉及一种基于深度学习的科里奥利质量流量计数字信号处理方法。

背景技术

[0002] 随着工业技术的不断发展,流量测量的精度也越来越高,科里奥利质量流量计以其优越的性能被广泛应用于各个领域。科里奥利质量流量计主要由激振器、测量管和拾振器组成。测量管在激振器的驱动下作简谐运动,当没有流体流经测量管时,位于测量管两端的拾振器输出信号为相同幅值相同相位的正弦信号。相反地,当流体流过测量管,在科里奥利力的作用下两端正弦信号产生相位差 $\Delta\varphi$,而此时的质量流量 q_m 与该相位差成正比,同时比例系数 K 只和流量计本身参数有关,与流体的物理参数无关。正是这个鲜明的特点,致使科里奥利质量流量计从众多测量仪器中脱颖而出。因此,关于科里奥利流量计的研究工作大部分都集中在如何从两路正弦信号中提取相位差。

[0003] 目前,科里奥利流量计针对单相流的测量精度很高并因此被广泛应用于各个领域,但当被测介质(medium metered)为多相流时,上述算法均无法保证其精度,因此最近发展了许多非直接技术以解决这一技术瓶颈。大部分的研究人员尝试在现有的测量方法基础上,结合智能算法修正测量值。Liu以温度、阻尼、流速作为径向基网络网络(radial basis function network,RBF)的输入去修正两相流的质量流量误差,使得误差保持在2%以内。Safarinejadian应用了模糊算法(fuzzy)修正两相流的质量流量。算法以阻尼、密度以及质量流量作为输入生成质量流量的修正量,但是其性能依赖于模糊规则的建立,而且实验结果在文中没有作详细的说明。

[0004] 现有关于科里奥利流量计信号处理方法,包括上文所提到的一些非直接式算法,都离不开科里奥利效应作用下测量管的理想力学模型,但实际工况条件下该理想假设难以实现,例如测量管两端在加工精度、电子元件等方面必然存在不对称的情况,因此本文提出一种基于深度学习的数字信号处理技术。

发明内容

[0005] 本发明的目的在于克服现有技术中的缺点与不足,提供一种基于深度学习的科里奥利质量流量计数字信号处理方法,科里奥利质量流量计测量的振动信号通过该方法处理可得到高精度的流量信号,从而提高流量的测量精度。

[0006] 为了达到上述目的,本发明通过下述技术方案予以实现:一种基于深度学习的科里奥利质量流量计数字信号处理方法,其特征在于:首先,建立水流量测试平台,并采集水流量测试平台的拾振信号作为输入特征,采集水流量测试平台中科里奥利质量流量计的输出瞬时质量流量作为样本标签;其中,输入特征与对应的样本标签组成一组样本数据;

[0007] 其次,对每组样本数据进行预处理,分别得到样本的第二训练集、验证集和测试集;

[0008] 然后,构建第一深度学习网络模型和第二深度学习网络模型,采用第二训练集分别对第一深度学习网络模型和第二深度学习网络模型进行训练;在训练过程中,采用批归一化方法以提高第一深度学习网络模型和第二深度学习网络模型的收敛速度,采用验证集对建立的第一深度学习网络模型和第二深度学习网络模型进行验证并调整超参数,采用测试集对调整好的第一深度学习网络模型和第二深度学习网络模型进行性能测试,以得到性能好的第一深度学习网络模型和第二深度学习网络模型;

[0009] 最后,采用科里奥利质量流量计与性能好的第一深度学习网络模型结合测量计算得到所需的第一流量信号,采用科里奥利质量流量计与性能好的第二深度学习网络模型结合测量计算得到所需的第二流量信号,并采用基于贝叶斯的模型融合法对第一流量信号和第二流量信号进行融合,得到流量信号的最优估计值,以提高流量测量的精度。

[0010] 所述水流量测试平台包括变频泵、标准表、节流阀一、节流阀二、节流阀三、被检表和水箱;所述变频泵、标准表、节流阀一、被检表、节流阀二、水箱和变频泵依次连接,形成循环;所述变频泵通过节流阀三与水箱连接。

[0011] 所述标准表和被检表均为科里奥利质量流量计且标准表的测量精度高于被检表的测量精度。

[0012] 所述采集水流量测试平台的拾振信号作为输入特征,采集水流量测试平台中科里奥利质量流量计的输出瞬时质量流量作为样本标签是指:通过RS-485接口和数据采集卡分别记录标准表所测得的瞬时质量流量作为样本标签,以及采集被检表两端的拾振信号LPO和RPO作为输入特征;

[0013] 采样期间不断地改变变频泵的输入频率,以及对节流阀一、节流阀二和节流阀三的开度进行调节,以获得各状态下的样本数据。

[0014] 所述对每组样本数据进行预处理,分别得到样本的第二训练集、验证集和测试集是指:包括以下步骤:

[0015] 第一步,对每组样本数据进行剔除错误数据;通过RS-485接口进行设备通讯容易发生通讯出错,因此在采集质量流量的过程难免引入一些错误信息,而这些错误信息直接影响后续模型的训练效果;

[0016] 第二步,对每组样本数据输入标准化;标准化公式如下:

$$[0017] \quad x_{ij}^* = \frac{x_{ij} - \bar{x}_i}{\sigma_i}$$

[0018] 其中, x_{ij} 为第j个样本,第i个特征量的取值, x_{ij}^* 则为更新后的取值; $\bar{x}_i$ 为第i个特征量的样本均值; σ_i 为第i个特征量的样本方差;

[0019] 第三步,对标准化后的样本数据分配为第一训练集、验证集和测试集;

[0020] 第四步,随机打乱第三步的第一训练集顺序,得到第二训练集。

[0021] 所述采用第二训练集分别对第一深度学习网络模型和第二深度学习网络模型进行训练是指:采用第二训练集并使用mini-batch梯度下降法分别训练第一深度学习网络模型和第二深度学习网络模型,即将第二训练集划分为若干个小的训练集分别训练第一深度学习网络模型和第二深度学习网络模型。

[0022] 所述第一深度学习网络模型由输入层、三层隐藏层L1,L2和L3、以及输出层连接组成;其中,L1为LSTM层,L2为LSTM层的输出层,L3为全连接层并采用tanh激活函数;L1和L2的

长度S等于待处理的信号序列长度,L1和L2的隐含节点数分别为16和4,L3的神经元数为300;

[0023] 所述第一深度学习网络模型的损失函数为:

$$[0024] \quad Loss = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 + \frac{\lambda}{m} \sum_j \omega_j^2$$

[0025] 其中,等式右边的第一项为均方误差; λ 为正则化系数。

[0026] 第二深度学习网络模型由输入层、输出层以及三层隐藏层组成,且各层之间均为全连接;三层隐藏层的神经元数分别为256、128和300。

[0027] 所述采用批归一化方法使得第一深度学习网络模型和第二深度学习网络模型收敛是指:采用以下公式对第一深度学习网络模型和第二深度学习网络模型的输出进行批归一化:

$$[0028] \quad \mu_B \leftarrow \frac{1}{m} \sum_{i=1}^m x_i$$

$$[0029] \quad \sigma_B^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2$$

$$[0030] \quad \hat{x}_i \leftarrow \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}$$

$$[0031] \quad y_i \leftarrow \gamma \hat{x}_i + \beta$$

[0032] 其中 γ 和 β 是新增的两个参数,可通过第一深度学习网络模型或第二深度学习网络模型训练来调整;m代表mini-batch梯度下降法训练第一深度学习网络模型或第二深度学习网络模型的样本个数;

[0033] 在采用批归一化方法使得第一深度学习网络模型和第二深度学习网络模型收敛过程中,采用滑动平均法计算得到全局均值和方差:

$$[0034] \quad \mu_{\text{global}} \leftarrow D \times \mu_{\text{global}} + (1-D) \times \mu_B$$

$$[0035] \quad \sigma_{\text{global}} \leftarrow D \times \sigma_{\text{global}} + (1-D) \times \sigma_B$$

[0036] 其中,D是衰减系数。

[0037] 所述采用基于贝叶斯的模型融合法对第一流量信号和第二流量信号进行融合,得到流量信号的最优估计值是指:设质量流量的状态量为Y,第一流量信号和第二流量信号为Z;条件概率密度函数 $P(Z|Y)$ 表示在状态 $Y=y$ 下,模型输出值 $Z=z$ 的概率;Y服从均匀分布,先验概率 $P(Y)$ 为常数;在Z已知条件下Y的后验条件概率如下式所示:

$$[0038] \quad P(Y|Z) = \frac{P(Z|Y)P(Y)}{\int P(Z|Y)P(Y) dY}$$

[0039] 其中,式中的分母只与模型输出Z有关,由最大后验估计可得:

$$[0040] \quad \hat{y}_{MAP} = \operatorname{argmax} P(Y|Z) \propto P(Z|Y)P(Y)$$

[0041] 每个模型的输出均服从高斯分布,即:

$$[0042] \quad P(Z_k = z_k | Y = y) = \frac{1}{\sigma_k \sqrt{2\pi}} \exp \left[-\frac{(z_k - y)^2}{2\sigma_k^2} \right]$$

[0043] 由上式可得最优估计值：

$$[0044] \quad \hat{y}_{MAP} = \frac{\sum_{k=1}^l \frac{z_k}{\sigma_k^2}}{\sum_{k=1}^l \frac{1}{\sigma_k^2}}$$

[0045] 该最优估计值则为流量信号的最优估计值。

[0046] 与现有技术相比，本发明具有如下优点与有益效果：科里奥利质量流量计测量的振动信号通过本发明方法处理可得到高精度的流量信号，从而提高流量的测量精度。

附图说明

[0047] 图1是本发明基于深度学习的科里奥利质量流量计数字信号处理方法的流程示意图；

[0048] 图2是水流量测试平台的示意图；

[0049] 其中，1为变频泵、2为标准表、3为节流阀一、4为节流阀二、5为节流阀三、6为被检表、7为水箱。

具体实施方式

[0050] 下面结合附图与具体实施方式对本发明作进一步详细的描述。

[0051] 实施例

[0052] 如图1和图2所示，本发明基于深度学习的科里奥利质量流量计数字信号处理方法，其特征在于：首先，建立水流量测试平台，并采集水流量测试平台的拾振信号作为输入特征，采集水流量测试平台中科里奥利质量流量计的输出瞬时质量流量作为样本标签；其中，输入特征与对应的样本标签组成一组样本数据；

[0053] 其次，对每组样本数据进行预处理，分别得到样本的第二训练集、验证集和测试集；

[0054] 然后，构建第一深度学习网络模型和第二深度学习网络模型，采用第二训练集分别对第一深度学习网络模型和第二深度学习网络模型进行训练；在训练过程中，采用批归一化方法以提高第一深度学习网络模型和第二深度学习网络模型的收敛速度，采用验证集对建立的第一深度学习网络模型和第二深度学习网络模型进行验证并调整超参数，采用测试集对调整好的第一深度学习网络模型和第二深度学习网络模型进行性能测试，以得到性能好的第一深度学习网络模型和第二深度学习网络模型；

[0055] 最后，采用科里奥利质量流量计与性能好的第一深度学习网络模型结合测量计算得到所需的第一流量信号，采用科里奥利质量流量计与性能好的第二深度学习网络模型结合测量计算得到所需的第二流量信号，并采用基于贝叶斯的模型融合法对第一流量信号和第二流量信号进行融合，得到流量信号的最优估计值，以提高流量测量的精度。

[0056] 其中，水流量测试平台包括变频泵1、标准表2、节流阀一3、节流阀二4、节流阀三5、被检表6和水箱7，其中，变频泵1、标准表2、节流阀一3、被检表6、节流阀二4、水箱7和变频泵1依次连接，形成循环，变频泵1通过节流阀三5与水箱7连接。标准表2和被检表6均为科里奥利质量流量计且标准表2的测量精度高于被检表6的测量精度。被检表测量管的振动频率在300Hz附近。

[0057] 上述采集水流量测试平台的拾振信号作为输入特征,采集水流量测试平台中科里奥利质量流量计的输出瞬时质量流量作为样本标签是指:通过RS-485接口和数据采集卡分别记录标准表2所测得的瞬时质量流量作为样本标签,以及采集被检表6两端的拾振信号LP0和RP0作为输入特征。样本流量范围设定在5-25kg/min内,在采样期间不断地改变变频泵1的输入频率,以及对节流阀一3、节流阀二4和节流阀三5的开度进行调节,以获得各状态下的样本数据。其中,RS-485的查询频率 f_{s1} 为20Hz,而数据采集卡同步采样频率 f_{s2} 为6000Hz,

[0058] 上述对每组样本数据进行预处理,分别得到样本的第二训练集、验证集和测试集是指:包括以下步骤:

[0059] 第一步,对每组样本数据进行剔除错误数据;通过RS-485接口进行设备通讯容易发生通讯出错,因此在采集质量流量的过程难免引入一些错误信息,而这些错误信息直接影响后续模型的训练效果;

[0060] 第二步,对每组样本数据输入标准化;标准化公式如下:

$$[0061] \quad x_{ij}^* = \frac{x_{ij} - \bar{x}_i}{\sigma_i}$$

[0062] 其中, x_{ij} 为第j个样本,第i个特征量的取值, x_{ij}^* 则为更新后的取值; $\bar{x}_i$ 为第i个特征量的样本均值; σ_i 为第i个特征量的样本方差;

[0063] 第三步,对标准化后的样本数据分配为第一训练集、验证集和测试集;在本实施例中,数据集的总样本数是8448,第一训练集、验证集和测试集各占比例为10:1:1,其中第一训练集用于模型的训练,验证集用于调整模型的超参数,而测试集用于评估最终模型的效果。

[0064] 第四步,随机打乱第三步的第一训练集顺序,得到第二训练集。

[0065] 上述采用第二训练集分别对第一深度学习网络模型和第二深度学习网络模型进行训练是指:采用第二训练集并使用mini-batch梯度下降法分别训练第一深度学习网络模型和第二深度学习网络模型,即将第二训练集划分为若干个小的训练集分别训练第一深度学习网络模型和第二深度学习网络模型。

[0066] 本发明的第一深度学习网络模型由输入层、三层隐藏层L1,L2和L3、以及输出层连接组成;其中,L1为LSTM层,L2为LSTM层的输出层,L3为全连接层并采用tanh激活函数;L1和L2的长度S等于待处理的信号序列长度,L1和L2的隐含节点数分别为16和4,L3的神经元数为300。

[0067] 该第一深度学习网络模型的损失函数为:

$$[0068] \quad Loss = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 + \frac{\lambda}{m} \sum_j \omega_j^2$$

[0069] 其中,等式右边的第一项为均方误差; λ 为正则化系数。

[0070] 本发明第二深度学习网络模型由输入层、输出层以及三层隐藏层组成,且各层之间均为全连接;三层隐藏层的神经元数分别为256、128和300。

[0071] 本发明采用批归一化方法使得第一深度学习网络模型和第二深度学习网络模型收敛是指:采用以下公式对第一深度学习网络模型和第二深度学习网络模型的输出进行批

归一化：

$$[0072] \quad \mu_B \leftarrow \frac{1}{m} \sum_{i=1}^m x_i$$

$$[0073] \quad \sigma_B^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2$$

$$[0074] \quad \hat{x}_i \leftarrow \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}$$

$$[0075] \quad y_i \leftarrow \gamma \hat{x}_i + \beta$$

[0076] 其中 γ 和 β 是新增的两个参数, 可通过第一深度学习网络模型或第二深度学习网络模型训练来调整; m 代表 mini-batch 梯度下降法训练第一深度学习网络模型或第二深度学习网络模型的样本个数;

[0077] 在采用批归一化方法使得第一深度学习网络模型和第二深度学习网络模型收敛过程中, 采用滑动平均法计算得到全局均值和方差:

$$[0078] \quad \mu_{\text{global}} \leftarrow D \times \mu_{\text{global}} + (1-D) \times \mu_B$$

$$[0079] \quad \sigma_{\text{global}} \leftarrow D \times \sigma_{\text{global}} + (1-D) \times \sigma_B$$

[0080] 其中, D 是衰减系数。

[0081] 本发明采用基于贝叶斯的模型融合法对第一流量信号和第二流量信号进行融合, 得到流量信号的最优估计值是指: 设质量流量的状态量为 Y , 第一流量信号和第二流量信号为 Z ; 条件概率密度函数 $P(Z|Y)$ 表示在状态 $Y=y$ 下, 模型输出值 $Z=z$ 的概率; Y 服从均匀分布, 先验概率 $P(Y)$ 为常数; 在 Z 已知条件下 Y 的后验条件概率如下式所示:

$$[0082] \quad P(Y|Z) = \frac{P(Z|Y)P(Y)}{\int P(Z|Y)P(Y) dY}$$

[0083] 其中, 式中的分母只与模型输出 Z 有关, 由最大后验估计可得:

$$[0084] \quad \hat{y}_{MAP} = \operatorname{argmax} P(Y|Z) \propto P(Z|Y)P(Y)$$

[0085] 每个模型的输出均服从高斯分布, 即:

$$[0086] \quad P(Z_k = z_k | Y = y) = \frac{1}{\sigma_k \sqrt{2\pi}} \exp \left[-\frac{(z_k - y)^2}{2\sigma_k^2} \right]$$

[0087] 由上式可得最优估计值:

$$[0088] \quad \hat{y}_{MAP} = \frac{\sum_{k=1}^l \frac{z_k}{\sigma_k^2}}{\sum_{k=1}^l \frac{1}{\sigma_k^2}}$$

[0089] 该最优估计值则为流量信号的最优估计值。

[0090] 上述实施例为本发明较佳的实施方式, 但本发明的实施方式并不受上述实施例的限制, 其他的任何未背离本发明的精神实质与原理下所作的改变、修饰、替代、组合、简化, 均应为等效的置换方式, 都包含在本发明的保护范围之内。




图1




图2