



(12) 发明专利申请

(10) 申请公布号 CN 118114189 A

(43) 申请公布日 2024. 05. 31

(21) 申请号 202410537564.2

G06F 119/02 (2020.01)

(22) 申请日 2024.04.30

(71) 申请人 成都市工业互联网发展中心

地址 610000 四川省成都市武侯区一环路
南三段24号

(72) 发明人 姜陈升 李玉珍 黎军 唐明祥
夏维瀚

(74) 专利代理机构 成都立新致创知识产权代理
事务所(特殊普通合伙)
51277

专利代理师 刘俊

(51) Int. Cl.

G06F 18/2433 (2023.01)

G06F 18/25 (2023.01)

G06F 30/27 (2020.01)

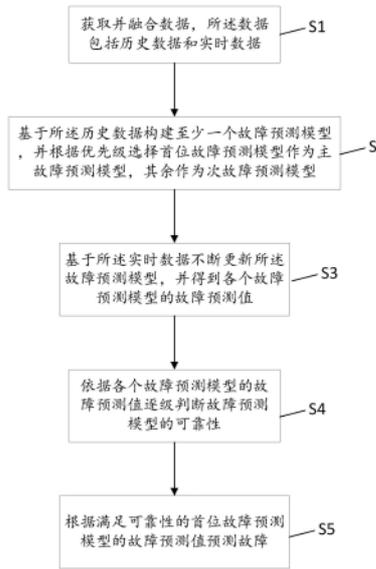
权利要求书2页 说明书9页 附图6页

(54) 发明名称

基于标识解析的时空数据融合方法及系统

(57) 摘要

本发明提供一种基于标识解析的时空数据融合方法及系统,获取并融合数据,所述数据包括历史数据和实时数据;基于所述历史数据构建至少一个故障预测模型,并根据优先级选择首位故障预测模型作为主故障预测模型,其余作为次故障预测模型;基于所述实时数据不断更新所述故障预测模型,并得到各个故障预测模型的故障预测值;依据各个故障预测模型的故障预测值逐级判断故障预测模型的可靠性;根据满足可靠性的首位故障预测模型的故障预测值预测故障,通过历史时空数据构建故障预测模型,以优化维护策略,通过预测故障以降低维修成本,通过实时数据持续地优化模型以及设计冗余模型来提高预测模型的可靠性,提高生产效率。



1. 一种基于标识解析的时空数据融合方法,其特征在于,所述融合方法包括以下步骤:
 - S1:获取并融合数据,所述数据包括历史数据和实时数据;
 - S2:基于所述历史数据构建至少一个故障预测模型,并根据优先级选择首位故障预测模型作为主故障预测模型,其余作为次故障预测模型;
 - S3:基于所述实时数据不断更新所述故障预测模型,并得到各个故障预测模型的故障预测值;
 - S4:依据各个故障预测模型的故障预测值逐级判断故障预测模型的可靠性;
 - S5:根据满足可靠性的首位故障预测模型的故障预测值预测故障。
2. 根据权利要求1所述的一种基于标识解析的时空数据融合方法,其特征在于,步骤S1包括:
 - S101:为实体分配唯一标识,所述实体包括传感器、设备和系统;
 - S102:从实体中采集数据,并存储于数据库中;
 - S103:根据标识方式解析数据,将不同标识方式的数据映射为统一的数据格式;
 - S104:根据实体的唯一标识,将属于同一实体的数据按照时间和空间维度进行融合,并生成时空数据。
3. 根据权利要求1所述的一种基于标识解析的时空数据融合方法,其特征在于,步骤S2包括:
 - S201:基于机器学习算法构建故障预测模型并初始化;
 - S202:通过所述历史数据训练所述故障预测模型;
 - S203:计算得到所述故障预测模型的参数和权重;
 - S204:评估并确定所述故障预测模型。
4. 根据权利要求3所述的一种基于标识解析的时空数据融合方法,其特征在于,所述故障预测模型的优先级是由编号确定的。
5. 根据权利要求3所述的一种基于标识解析的时空数据融合方法,其特征在于,在步骤S201中,所述机器学习算法为神经网络。
6. 根据权利要求1所述的一种基于标识解析的时空数据融合方法,其特征在于,步骤S3包括:
 - S301:利用融合的实时数据对已构建的故障预测模型进行更新;
 - S302:根据每个更新后的故障预测模型,使用实时数据进行故障预测值的计算。
7. 根据权利要求1所述的一种基于标识解析的时空数据融合方法,其特征在于,步骤S4包括:
 - S401:依据同一实体的时空数据计算所述故障预测模型的故障预测值;
 - S402:对除首位外所有故障预测模型的故障预测值求平均值D,计算公式如下:
$$D = \frac{D_2 + D_3 + \dots + D_n}{n - 1}$$其中,n代表故障预测模型的个数, D_n 代表故障预测模型的故障预测值;
- S403:判断首位故障预测模型的故障预测值与预测值平均值的差值是否小于设定的异常阈值;

若差值 $<$ 异常阈值,则表明首位故障预测模型为正常状态;

若差值 \geq 异常阈值,则表明首位故障预测模型为故障状态;

S404:剔除处于异常状态的首位故障预测模型,并按照优先级顺序认定下一个故障预测模型为首位,直至首位故障预测模型为正常状态。

8.根据权利要求7所述的一种基于标识解析的时空数据融合方法,其特征在于,步骤S5包括:

判断首位故障预测模型的故障预测值是否落入正常阈值区间;

若首位故障预测模型的故障预测值落入正常阈值区间,则表明对应的实体处于正常状态;

若首位故障预测模型的故障预测值未落入正常阈值区间,则表明对应的实体处于故障状态。

9.一种基于标识解析的时空数据融合系统,其特征在于,包括:

数据融合模块,用于获取并融合数据,所述数据包括历史数据和实时数据;

模型构建模块,用于基于所述历史数据构建至少一个故障预测模型,并根据优先级选择首位故障预测模型作为主故障预测模型,其余作为次故障预测模型;

故障预测值计算模块,用于基于所述实时数据不断更新所述故障预测模型,并得到各个故障预测模型的故障预测值;

可靠性判断模块,用于依据各个故障预测模型的故障预测值逐级判断故障预测模型的可靠性;

故障预测模块,用于根据满足可靠性的首位故障预测模型的故障预测值预测故障。

10.根据权利要求9所述的一种基于标识解析的时空数据融合系统,其特征在于,所述故障预测模型的优先级是由编号确定的。

基于标识解析的时空数据融合方法及系统

技术领域

[0001] 本发明涉及工业互联网数据处理技术领域,尤其涉及一种基于标识解析的时空数据融合方法及系统。

背景技术

[0002] 工业互联网是指通过物联网、云计算、大数据分析等技术手段,将传统工业设备、生产线、企业管理系统等与互联网进行连接和融合,实现设备之间的信息共享、智能化管理和优化决策的一种新型产业形态。

[0003] 对于工业互联网中所涉及的各类设备、产品、材料等进行唯一标识的解析和识别,通过给每个实体分配一个独一无二的标识符,可以实现对其进行全局追溯、管理和控制,标识解析还可以为工业互联网中的设备提供自动注册、配置和升级功能,简化设备接入和管理的过程;同时,不同设备、传感器和系统产生的数据往往具有不同的时间戳和空间位置信息,通过标识解析进行时空数据融合,可以将这些异构数据进行整合、校准和关联,从而得到更全面、准确的数据视图。

[0004] 在工业互联网的快速发展中,实时监测和预测设备故障的需求越来越迫切,传统的维护方式往往是基于定期检查或事后维修的方式,无法满足工业生产中高效、准确、及时的故障诊断和预测要求。

[0005] 因此,有必要提供一种基于标识解析的时空数据融合方法及系统解决上述技术问题。

发明内容

[0006] 为解决上述技术问题,本发明提供一种基于标识解析的时空数据融合方法及系统,通过历史时空数据构建故障预测模型,以优化维护策略,通过预测故障以降低维修成本,通过实时数据持续地优化模型以及设计冗余模型来提高预测模型的可靠性,提高生产效率。

本发明提供了一种基于标识解析的时空数据融合方法,所述融合方法包括以下步骤:

S1:获取并融合数据,所述数据包括历史数据和实时数据;

S2:基于所述历史数据构建至少一个故障预测模型,并根据优先级选择首位故障预测模型作为主故障预测模型,其余作为次故障预测模型;

S3:基于所述实时数据不断更新所述故障预测模型,并得到各个故障预测模型的故障预测值;

S4:依据各个故障预测模型的故障预测值逐级判断故障预测模型的可靠性;

S5:根据满足可靠性的首位故障预测模型的故障预测值预测故障。

[0007] 优选的,步骤S1包括:

S101:为实体分配唯一标识,所述实体包括传感器、设备和系统;

S102:从实体中采集数据,并存储于数据库中;

S103:根据标识方式解析数据,将不同标识方式的数据映射为统一的数据格式;

S104:根据实体的唯一标识,将属于同一实体的数据按照时间和空间维度进行融合,并生成时空数据。

[0008] 优选的,步骤S2包括:

S201:基于机器学习算法构建故障预测模型并初始化;

S202:通过所述历史数据训练所述故障预测模型;

S203:计算得到所述故障预测模型的参数和权重;

S204:评估并确定所述故障预测模型。

[0009] 优选的,所述故障预测模型的优先级是由编号确定的。

[0010] 优选的,在步骤S201中,所述机器学习算法为神经网络。

[0011] 优选的,步骤S3包括:

S301:利用融合的实时数据对已构建的故障预测模型进行更新;

S302:根据每个更新后的故障预测模型,使用实时数据进行故障预测值的计算。

[0012] 优选的,步骤S4包括:

S401:依据同一实体的时空数据计算所述故障预测模型的故障预测值;

S402:对除首位外所有故障预测模型的故障预测值求平均值D,计算公式如下:

$$D = \frac{D_2 + D_3 + \dots + D_n}{n - 1}$$

其中,n代表故障预测模型的个数,代表故障预测模型的故障预测值;

S403:判断首位故障预测模型的故障预测值与预测值平均值的差值是否小于设定的异常阈值;

若差值<异常阈值,则表明首位故障预测模型为正常状态;

若差值≥异常阈值,则表明首位故障预测模型为故障状态;

S404:剔除处于异常状态的首位故障预测模型,并按照优先级顺序认定下一个故障预测模型为首位,直至首位故障预测模型为正常状态。

[0013] 优选的,步骤S5包括:

判断首位故障预测模型的故障预测值是否落入正常阈值区间;

若首位故障预测模型的故障预测值落入正常阈值区间,则表明对应的实体处于正常状态;

若首位故障预测模型的故障预测值未落入正常阈值区间,则表明对应的实体处于故障状态。

[0014] 一种基于标识解析的时空数据融合系统,包括:

数据融合模块,用于获取并融合数据,所述数据包括历史数据和实时数据;

模型构建模块,用于基于所述历史数据构建至少一个故障预测模型,并根据优先级选择首位故障预测模型作为主故障预测模型,其余作为次故障预测模型;

故障预测值计算模块,用于基于所述实时数据不断更新所述故障预测模型,并得到各个故障预测模型的故障预测值;

可靠性判断模块,用于依据各个故障预测模型的故障预测值逐级判断故障预测模

型的可靠性；

故障预测模块,用于根据满足可靠性的首位故障预测模型的故障预测值预测故障。

[0015] 优选的,所述故障预测模型的优先级是由编号确定的。

[0016] 与相关技术相比较,本发明提供一种基于标识解析的时空数据融合方法及系统具有如下有益效果:

1、本发明利用历史时空数据构建故障预测模型,同时通过实时时空数据不断地优化故障预测模型,帮助修正故障预测模型中的偏差,并提高预测的准确性,以优化维护策略,降低维修成本,提高生产效率。

[0017] 2、本发明通过故障预测模型的冗余设计,通过将主故障预测模型的预测值与其他模型的平均值进行比较,可以更准确地评估主故障预测模型的可靠性,并及时发现主故障预测模型可能存在的问题,也可以提高故障预测系统的稳定性和可靠性。

附图说明

[0018] 图1为本发明的一种基于标识解析的时空数据融合方法的主流程示意图；

图2为本发明的一种基于标识解析的时空数据融合方法的步骤S1流程示意图；

图3为本发明的一种基于标识解析的时空数据融合方法的步骤S2流程示意图；

图4为本发明的一种基于标识解析的时空数据融合方法的步骤S3流程示意图；

图5为本发明的一种基于标识解析的时空数据融合方法的步骤S4流程示意图；

图6为本发明的一种基于标识解析的时空数据融合方法的故障预测模型异常判断示意图；

图7为本发明的一种基于标识解析的时空数据融合系统的模块结构示意图。

具体实施方式

[0019] 下面结合附图和实施方式对本发明作进一步说明。

[0020] 实施例一

参考图1所示,本发明提供一种基于标识解析的时空数据融合方法,该融合方法包括以下步骤:

S1:获取并融合数据,数据包括历史数据和实时数据。

[0021] 具体的,参考图2所示,步骤S1包括:

S101:为实体分配唯一标识,实体包括传感器、设备和系统。

[0022] 在本实施例中,使用全球唯一标识符为传感器、设备和系统等实体分配唯一标识,这些标识在后续数据融合时,可以融合同一实体产生的时间数据和空间数据,提高数据融合的速度,例如:采用UUID技术为实体分配唯一的标识。

[0023] 此外,历史数据是指实体已经发生过的数据,它们记录了过去某个时间段内的测量信息,通过回顾和分析过去实体的行为,以方便构建初级的故障预测模型;而实时数据则是指当前正在发生或接收到的实体数据,其反映了当下实体状态和情况,为故障预测模型的优化提供了更加全面的数据支持。

[0024] S102:从实体中采集数据,并存储于数据库中。

[0025] 在本实施例中,利用物联网技术和传感器网络,实时采集实体产生的数据,同时采用统一的时间同步协议NTP,对不同实体的数据进行时间校准,消除时间差异,确保各个设备在时间上的同步。

[0026] 此外,将从各个实体采集到的时间数据和空间数据存储于数据库,例如云端或边缘服务器的数据库,通过建立数据模型和数据库结构,以便有效组织和管理时空数据,考虑到时间数据和空间数据的特性,选择一种支持地理数据的模型,例如地理信息系统(GIS)模型。

[0027] S103:根据标识方式解析数据,将不同标识方式的数据映射为统一的数据格式。

[0028] 在本实施例中,首先,了解实体的标识方式,例如设备ID、MAC地址、IP地址等,这些标识可以帮助我们识别和区分不同的设备,然后,根据设备标识方式,通过对应的解析规则来处理各种数据格式;接着,按照对应的解析规则,对数据库中的原始数据进行解析,再接着,根据设备标识方式提取所需的字段和值,最后,将解析后的数据映射为统一的数据格式,以确保不同格式的数据以一致的方式表示和存储。

[0029] S104:根据实体的唯一标识,将属于同一实体的数据按照时间和空间维度进行融合,并生成时空数据。

[0030] 在本实施例中,在时空数据融合阶段,将解析后的数据按照时间和空间维度进行融合,通过时间维度的融合,可以观察数据的变化趋势和周期性规律;通过空间维度的融合,可以将来自不同设备的数据进行整合,提供更全面的信息视角。

[0031] S2:基于历史数据构建至少一个故障预测模型,并根据优先级选择首位故障预测模型作为主故障预测模型,其余作为次故障预测模型。

[0032] 在本实施例中,基于历史数据构建的故障预测模型为初级的故障预测模型,并不能够更加准确地预测故障,同时,通过数字为设置的故障预测模型进行编号,例如:故障预测模型1、故障预测模型2、…、故障预测模型n,较低的数字通常表示较高的优先级,即数字越小,优先级越高。

[0033] 工作时,选择优先级最高的故障预测模型作为主故障预测模型,其余的故障预测模型则作为次故障预测模型,只有在主故障预测模型发生异常时,下一优先级的故障预测模型才会认定主故障预测模型。

[0034] 具体的,参考图3所示,步骤S2包括:

S201:基于机器学习算法构建故障预测模型并初始化。

[0035] 在本实施例中,采用神经网络模型作为故障预测模型的基础模型,而神经网络则采用卷积神经网络。

[0036] 设计卷积神经网络CNN模型的LeNet-5架构,在训练模型之前,需要对CNN进行初始化,本申请采用随机初始化的方法,将网络权重和偏差设置为较小的随机值。

[0037] 此外,初始化的方式还可以是在预训练的模型参数进行初始化,如使用在类似任务上训练好的模型参数。

[0038] S202:通过历史数据训练故障预测模型。

[0039] 在本实施例中,在训练故障预测模型前,需要预处理获取的历史数据,以确保数据的质量和一致性,并进行必要的清洗、去噪声、标准化等。

[0040] 然后,对历史数据进行特征提取和转换,以便更好地适配CNN模型。这包括使用时

间序列分析方法或频域分析方法提取有意义的特征,如时域统计特征、频域特征等。

[0041] 最后,将数据转换成CNN所需的输入格式,对于单变量时间序列数据,可以将其转换为形状为(样本数,时间步长,通道数)的3D张量;对于多变量时间序列数据,可以将其转换为形状为(样本数,时间步长,通道数)或(样本数,时间步长,特征数)的3D张量。

[0042] S203:计算得到故障预测模型的参数和权重。

[0043] 在本实施例中,选择适当的优化器来更新故障预测模型的参数和权重,例如随机梯度下降(SGD)优化器,通过调整学习率、动量、批次大小等超参数,可以优化模型的训练效果。

[0044] S204:评估并确定故障预测模型。

[0045] 在本实施例中,使用历史数据验证集评估训练好的CNN模型性能,通过计算预测准确率、召回率、F1分数等指标来评估模型的性能,根据评估结果,可以进行模型调整和改进。

[0046] S3:基于实时数据不断更新故障预测模型,并得到各个故障预测模型的故障预测值。

[0047] 具体的,参考图4所示,步骤S3包括:

S301:利用融合的实时数据对已构建的故障预测模型进行更新。

[0048] 在本实施例中,在实时数据优化故障预测模型阶段,通过不断采集和更新实时数据,对已有的预测模型进行优化,根据实际情况调整模型参数、增加新的特征变量或改进模型结构,以提高预测的准确性和适应性。

[0049] S302:根据每个更新后的故障预测模型,使用实时数据进行故障预测值的计算。

[0050] 在本实施例中,将经过预处理的实时数据输入到加载的故障预测模型中,以获得故障预测值,使用前向传播算法计算输出结果,预测值表示为实体故障的概率。

[0051] S4:依据各个故障预测模型的故障预测值逐级判断故障预测模型的可靠性。

[0052] 具体的,参考图5所示,步骤S4包括:

S401:依据同一实体的时空数据计算故障预测模型的故障预测值。

[0053] S402:对除首位外所有故障预测模型的故障预测值求平均值D,计算公式如下:

$$D = \frac{D_2 + D_3 + \dots + D_n}{n - 1}$$

其中,n代表故障预测模型的个数,代表故障预测模型的故障预测值。

[0054] S403:判断首位故障预测模型的故障预测值与预测值平均值的差值是否小于设定的异常阈值。

[0055] 若差值<异常阈值,则表明首位故障预测模型为正常状态。

[0056] 若差值≥异常阈值,则表明首位故障预测模型为故障状态。

[0057] S404:剔除处于异常状态的首位故障预测模型,并按照优先级顺序认定下一个故障预测模型为首位,直至首位故障预测模型为正常状态。

[0058] S5:根据满足可靠性的首位故障预测模型的故障预测值预测故障。

[0059] 具体的,判断首位故障预测模型的故障预测值是否落入正常阈值区间;

若首位故障预测模型的故障预测值落入正常阈值区间,则表明对应的实体处于正常状态;

若首位故障预测模型的故障预测值未落入正常阈值区间,则表明对应的实体处于

故障状态。

[0060] 在本实施例中,参考图6所示,首先,设定一个阈值区间,用于界定可靠性,该阈值区间应基于预测结果的范围和误差容忍度来确定。

[0061] 获取主故障预测模型的预测值,并计算所有从故障预测模型的预测值的平均值。

[0062] 将主故障预测模型的预测值与平均预测值进行比较。

[0063] 如果主故障预测模型的预测值位于阈值区间内,即在可接受的范围内,则判断主故障预测模型的预测值为可靠。

[0064] 如果主故障预测模型的预测值不在阈值区间内,即超出可接受的范围,则判断主故障预测模型可能发生了故障或存在问题。

[0065] 若主故障预测模型被判定为不可靠或故障,在这种情况下,可以选择使用下一个优先级的从故障预测模型作为新的主故障预测模型,直至作为首位的主故障预测模型非故障状态。

[0066] 通过将主故障预测模型的预测值与其他模型的平均值进行比较,我们可以更准确地评估主故障预测模型的可靠性,并及时发现主故障预测模型可能存在的问题,可以提高故障预测系统的稳定性和可靠性。

[0067] 本发明提供的一种基于标识解析的时空数据融合方法的工作原理如下:本发明利用历史时空数据构建故障预测模型,同时通过实时时空数据不断地优化故障预测模型,帮助修正故障预测模型中的偏差,并提高预测的准确性,以优化维护策略,降低维修成本,提高生产效率;同时通过故障预测模型的冗余设计,通过将主故障预测模型的预测值与其他模型的平均值进行比较,可以更准确地评估主故障预测模型的可靠性,并及时发现主故障预测模型可能存在的问题,也可以提高故障预测系统的稳定性和可靠性。

[0068] 实施例二

参考图7所示,本发明还提供了一种基于标识解析的时空数据融合系统,包括:数据融合模块,用于获取并融合数据,数据包括历史数据和实时数据。

[0069] 在本实施例中,数据融合模块具体用于:

为实体分配唯一标识,实体包括传感器、设备和系统。

[0070] 在本实施例中,使用全球唯一标识符为传感器、设备和系统等实体分配唯一标识,这些标识在后续数据融合时,可以融合同一实体产生的时间数据和空间数据,提高数据融合的速度,例如:采用UUID技术为实体分配唯一的标识。

[0071] 此外,历史数据是指实体已经发生过的数据,它们记录了过去某个时间段内的测量信息,通过回顾和分析过去实体的行为,以方便构建初级的故障预测模型;而实时数据则是指当前正在发生或接收到的实体数据,其反映了当下实体状态和情况,为故障预测模型的优化提供了更加全面的数据支持。

[0072] 从实体中采集数据,并存储于数据库中。

[0073] 在本实施例中,利用物联网技术和传感器网络,实时采集实体产生的数据,同时采用统一的时间同步协议NTP,对不同实体的数据进行时间校准,消除时间差异,确保各个设备在时间上的同步。

[0074] 此外,将从各个实体采集到的时间数据和空间数据存储于数据库,例如云端或边缘服务器的数据库,通过建立数据模型和数据库结构,以便有效组织和管理时空数据,考虑

到时间数据和空间数据的特性,选择一种支持地理数据的模型,例如地理信息系统(GIS)模型。

[0075] 根据标识方式解析数据,将不同标识方式的数据映射为统一的数据格式。

[0076] 在本实施例中,首先,了解实体的标识方式,例如设备ID、MAC地址、IP地址等,这些标识可以帮助我们识别和区分不同的设备,然后,根据设备标识方式,通过对应的解析规则来处理各种数据格式;接着,按照对应的解析规则,对数据库中的原始数据进行解析,再接着,根据设备标识方式提取所需的字段和值,最后,将解析后的数据映射为统一的数据格式,以确保不同格式的数据以一致的方式表示和存储。

[0077] 根据实体的唯一标识,将属于同一实体的数据按照时间和空间维度进行融合,并生成时空数据。

[0078] 在本实施例中,在时空数据融合阶段,将解析后的数据按照时间和空间维度进行融合,通过时间维度的融合,可以观察数据的变化趋势和周期性规律;通过空间维度的融合,可以将来自不同设备的数据进行整合,提供更全面的信息视角。

[0079] 模型构建模块,用于基于历史数据构建至少一个故障预测模型,并根据优先级选择首位故障预测模型作为主故障预测模型,其余作为次故障预测模型。

[0080] 在本实施例中,模型构建模块具体用于:

基于机器学习算法构建故障预测模型并初始化。

[0081] 在本实施例中,采用神经网络模型作为故障预测模型的基础模型,而神经网络则采用卷积神经网络。

[0082] 设计卷积神经网络CNN模型的LeNet-5架构,在训练模型之前,需要对CNN进行初始化,本申请采用随机初始化的方法,将网络权重和偏差设置为较小的随机值。

[0083] 此外,初始化的方式还可以是在预训练的模型参数进行初始化,如使用在类似任务上训练好的模型参数。

[0084] 通过历史数据训练故障预测模型。

[0085] 在本实施例中,在训练故障预测模型前,需要预处理获取的历史数据,以确保数据的质量和一致性,并进行必要的清洗、去噪声、标准化等。

[0086] 然后,对历史数据进行特征提取和转换,以便更好地适配CNN模型。这包括使用时间序列分析方法或频域分析方法提取有意义的特征,如时域统计特征、频域特征等。

[0087] 最后,将数据转换成CNN所需的输入格式,对于单变量时间序列数据,可以将其转换为形状为(样本数,时间步长,通道数)的3D张量;对于多变量时间序列数据,可以将其转换为形状为(样本数,时间步长,通道数)或(样本数,时间步长,特征数)的3D张量。

[0088] 计算得到故障预测模型的参数和权重。

[0089] 在本实施例中,选择适当的优化器来更新故障预测模型的参数和权重,例如随机梯度下降(SGD)优化器,通过调整学习率、动量、批次大小等超参数,可以优化模型的训练效果。

[0090] 评估并确定故障预测模型。

[0091] 在本实施例中,使用历史数据验证集评估训练好的CNN模型性能,通过计算预测准确率、召回率、F1分数等指标来评估模型的性能,根据评估结果,可以进行模型调整和改进。

[0092] 故障预测值计算模块,用于基于实时数据不断更新故障预测模型,并得到各个故

障预测模型的故障预测值。

[0093] 在本实施例中,故障预测值计算模块具体用于:

利用融合的实时数据对已构建的故障预测模型进行更新。

[0094] 在本实施例中,在实时数据优化故障预测模型阶段,通过不断采集和更新实时数据,对已有的预测模型进行优化,根据实际情况调整模型参数、增加新的特征变量或改进模型结构,以提高预测的准确性和适应性。

[0095] 根据每个更新后的故障预测模型,使用实时数据进行故障预测值的计算。

[0096] 在本实施例中,将经过预处理的实时数据输入到加载的故障预测模型中,以获得故障预测值,使用前向传播算法计算输出结果,预测值表示为实体故障的概率。

[0097] 可靠性判断模块,用于依据各个故障预测模型的故障预测值逐级判断故障预测模型的可靠性。

[0098] 在本实施例中,可靠性判断模块具体用于:

依据同一实体的时空数据计算故障预测模型的故障预测值。

[0099] 对除首位外所有故障预测模型的故障预测值求平均值D,计算公式如下:

其中,n代表故障预测模型的个数, \bar{D} 代表故障预测模型的故障预测值。

[0100] 判断首位故障预测模型的故障预测值与预测值平均值的差值是否小于设定的异常阈值。

[0101] 若差值<异常阈值,则表明首位故障预测模型为正常状态。

[0102] 若差值 \geq 异常阈值,则表明首位故障预测模型为故障状态。

[0103] 剔除处于异常状态的首位故障预测模型,并按照优先级顺序认定下一个故障预测模型为首位,直至首位故障预测模型为正常状态。

[0104] 故障预测模块,用于根据满足可靠性的首位故障预测模型的故障预测值预测故障。

[0105] 本发明提供一种基于标识解析的时空数据融合系统的工作原理如下:利用历史时空数据构建故障预测模型,同时通过实时时空数据不断地优化故障预测模型,帮助修正故障预测模型中的偏差,并提高预测的准确性,以优化维护策略,降低维修成本,提高生产效率;同时通过故障预测模型的冗余设计,通过将主故障预测模型的预测值与其他模型的平均值进行比较,可以更准确地评估主故障预测模型的可靠性,并及时发现主故障预测模型可能存在的问题,也可以提高故障预测系统的稳定性和可靠性。

[0106] 本申请是参照根据本申请实施例的方法、设备(系统)和计算机程序产品的流程图和/或方框图来描述的。应理解可由计算机程序指令实现流程图和/或方框图中的每一流程和/或方框,以及流程图和/或方框图中的流程和/或方框的结合。可提供这些计算机程序指令到通用计算机、专用计算机、嵌入式处理机或其他可编程数据处理设备的处理器以产生一个机器,使得通过计算机或其他可编程数据处理设备的处理器执行的指令产生用于实现在流程图一个流程或多个流程和/或方框图一个方框或多个方框中指定的功能的装置。

[0107] 本领域普通技术人员可以理解上述实施例的各种方法中的全部或部分步骤是可以通程序来指令相关的硬件来完成,该程序可以存储于一种计算机可读存储介质中,存储介质包括只读存储器(Read-Only Memory,ROM)、随机存储器(Random Access Memory,RAM)、可编程只读存储器(Programmable Read-only Memory,PROM)、可擦除可编程只读存

存储器(Erasable Programmable Read Only Memory,EPR0M)、一次可编程只读存储器(One-time Programmable Read-Only Memory,0TPROM)、电子抹除式可复写只读存储器(Electrically-Erasable Programmable Read-Only Memory,EEPR0M)、只读光盘(CompactDisc Read-Only Memory,CD-ROM)或其他光盘存储器、磁盘存储器、磁带存储器,或者能够用于携带或存储数据的计算机可读的任何其他介质。

[0108] 还需要说明的是,术语“包括”“包含”或者其任何其他变体意在涵盖非排他性的包含,从而使得包括一系列要素的过程、方法、商品或者设备不仅包括那些要素,而且还包括没有明确列出的其他要素,或者是还包括为这种过程、方法、商品或者设备所固有的要素。在没有更多限制的情况下,由语句“包括一个……”限定的要素,并不排除在包括要素的过程、方法、商品或者设备中还存在另外的相同要素。

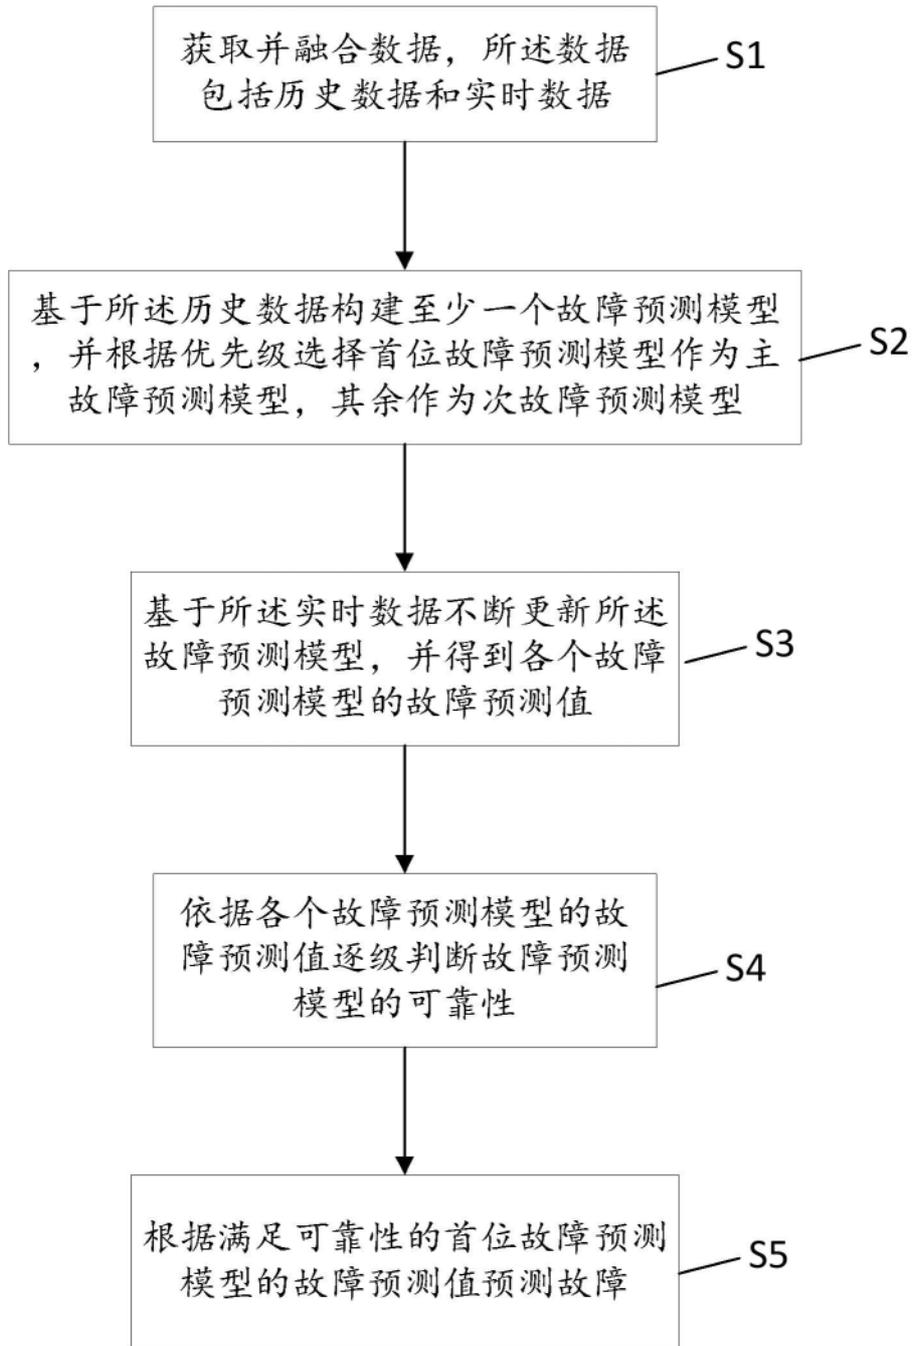


图1

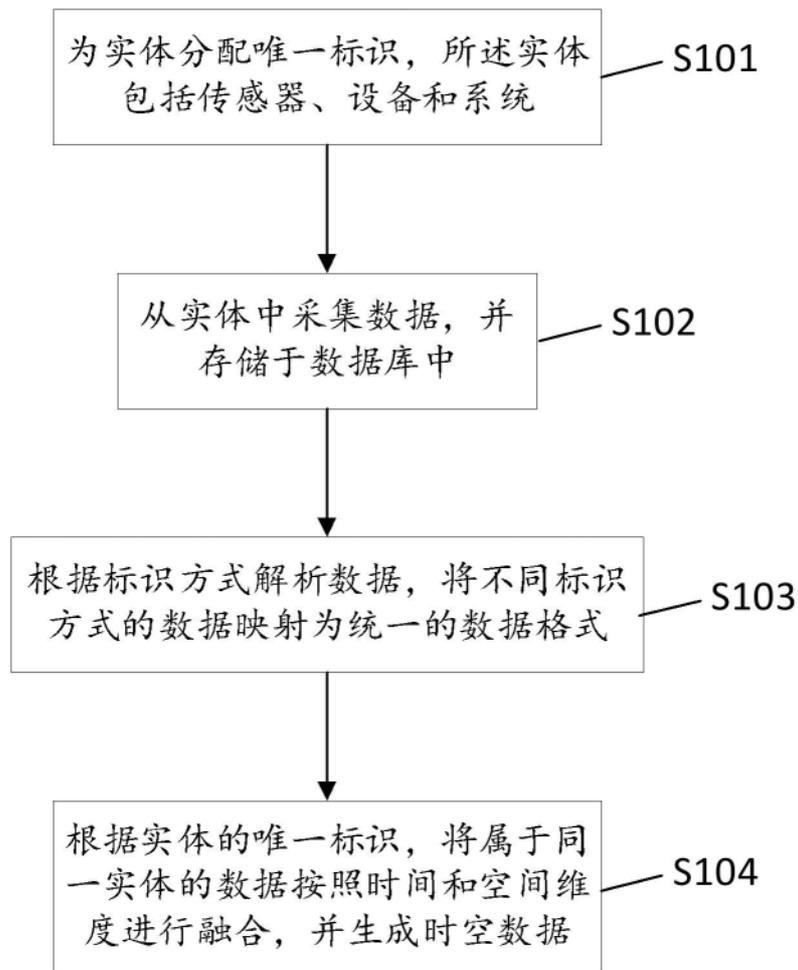


图2

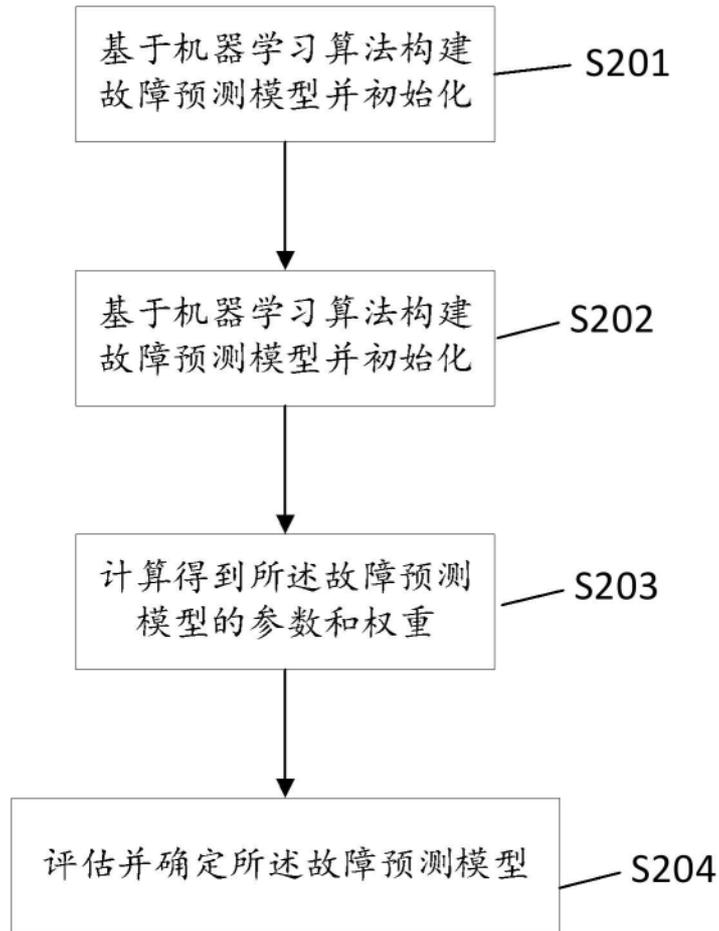


图3

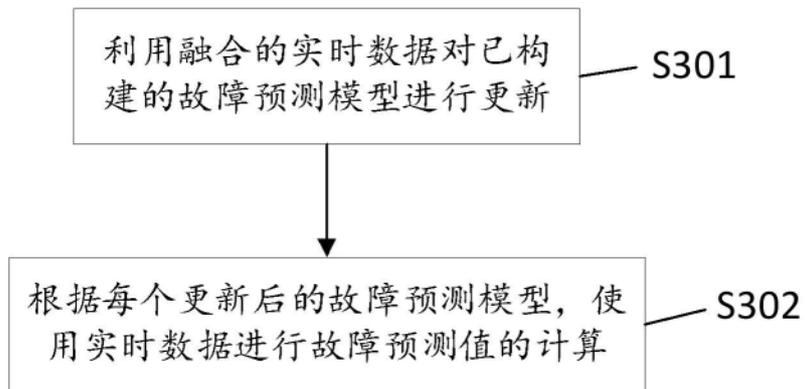


图4

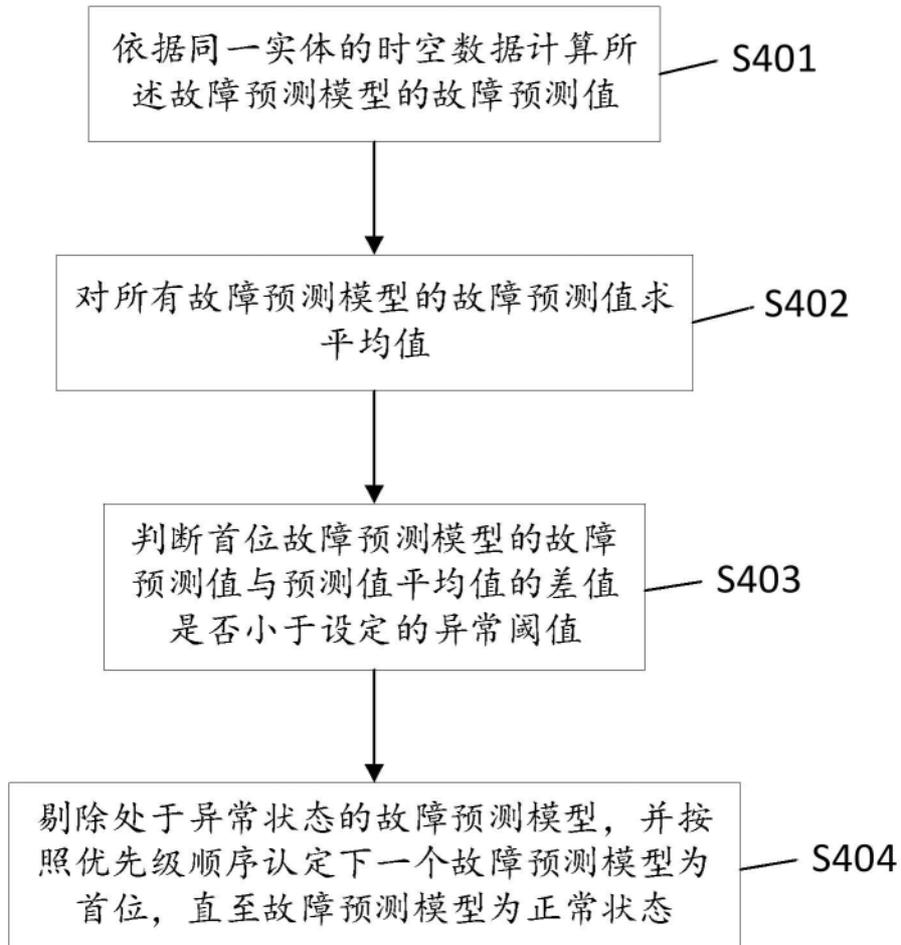


图5

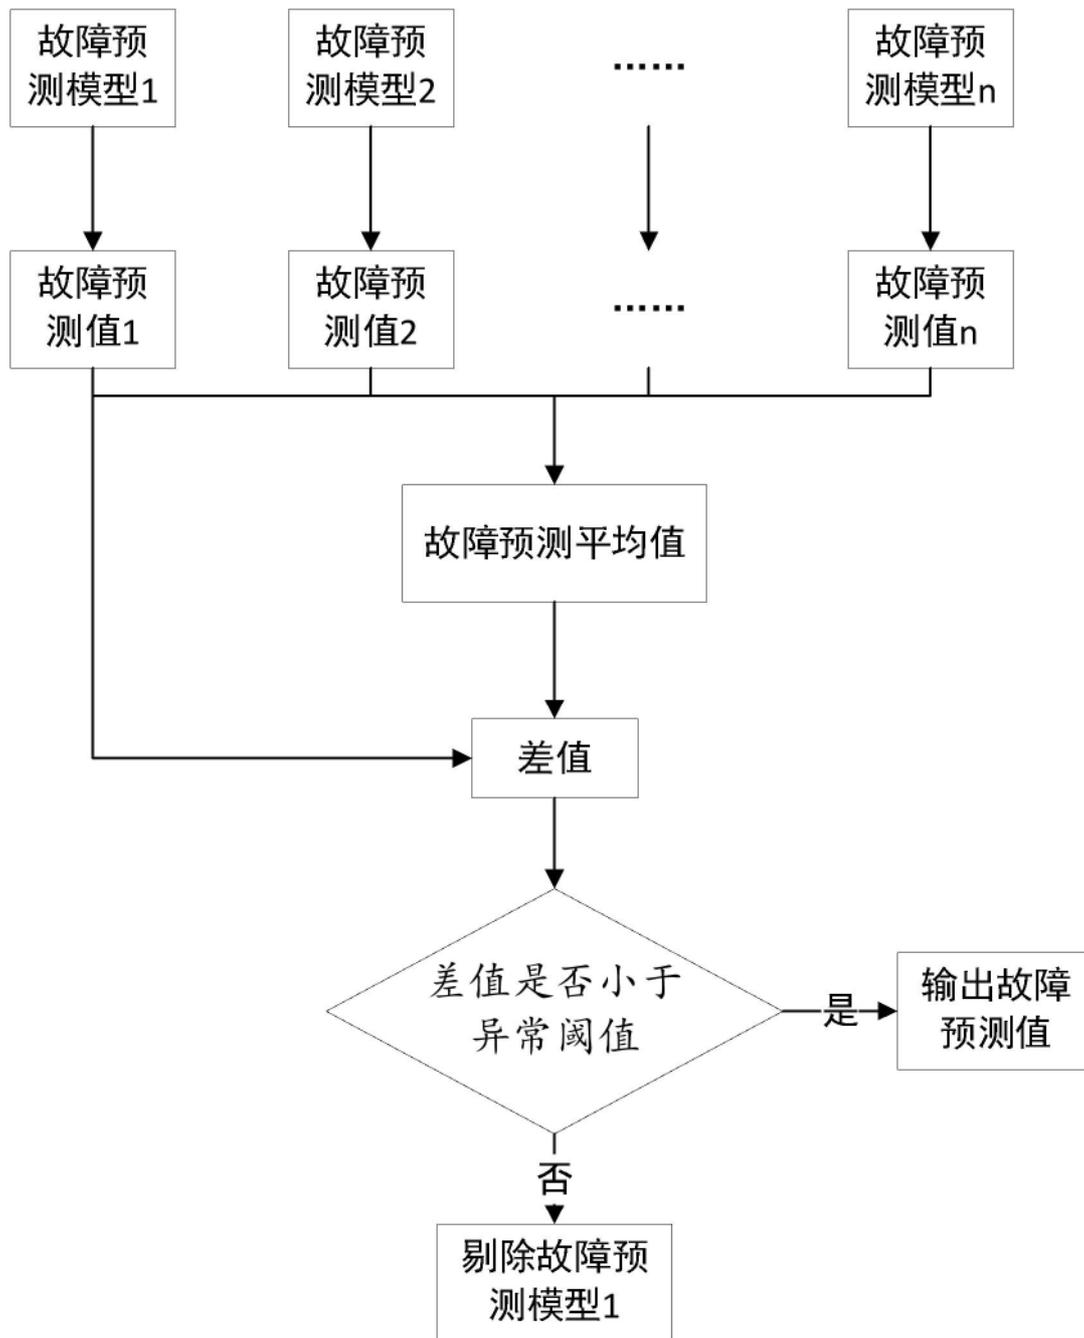


图6

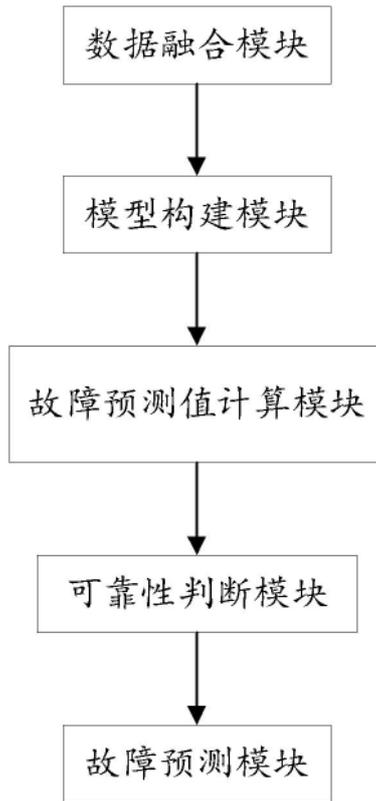


图7