



(12) 发明专利申请

(10) 申请公布号 CN 115906648 A

(43) 申请公布日 2023.04.04

(21) 申请号 202211531192.X

G06N 3/08 (2023.01)

(22) 申请日 2022.12.01

G06F 119/04 (2020.01)

(71) 申请人 广东粤电科试验检测技术有限公司

地址 510000 广东省广州市越秀区西华路  
捶帽新街1-3号华业大厦附楼六楼601  
室

(72) 发明人 傅明 黄伟杰 谢榕昌 王流火

高新华 卢启付 冉旺

(74) 专利代理机构 北京集佳知识产权代理有限公司

公司 11227

专利代理师 乔欢欢

(51) Int. Cl.

G06F 30/27 (2020.01)

G06N 3/044 (2023.01)

G06N 3/0442 (2023.01)


权利要求书2页 说明书6页 附图1页

(54) 发明名称

用于恶劣多变工况下变压器剩余使用寿命  
预测方法和系统

(57) 摘要

本发明公开了一种用于恶劣多变工况下变压器剩余使用寿命的预测方法,模型训练阶段包括:将多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型,挖掘不同维度的隐藏特征,输出预测的剩余使用寿命;利用真实剩余使用寿命和输出的预测剩余使用寿命之间的预测偏差,对多维度循环神经网络模型进行调整和优化;预测阶段包括:收集待预测的大型变压器的测试数据,测试数据包括多传感监测数据和运行状态数据;将测试数据实时输入到训练好的多维度循环神经网络模型中,得到大型变压器的预测剩余使用寿命。通过对多传感器监测数据和运行状态数据进行建模分析,可以精准预测大型变压器的预测剩余使用寿命。



1. 用于恶劣多变工况下变压器剩余使用寿命预测方法,其特征在于,包括:模型训练阶段和预测阶段;

所述模型训练阶段包括:

步骤S11、将多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型,挖掘不同维度的隐藏特征,输出预测的剩余使用寿命;

步骤S12、利用真实剩余使用寿命和输出的预测剩余使用寿命之间的预测偏差,对多维度循环神经网络模型进行调整和优化;

所述预测阶段包括:

步骤S21、收集待预测的大型变压器的测试数据,所述测试数据包括多传感监测数据和运行状态数据;

步骤S22、将所述测试数据实时输入到训练好的多维度循环神经网络模型中,得到大型变压器的预测剩余使用寿命。

2. 根据权利要求1所述的用于恶劣多变工况下变压器剩余使用寿命预测方法,其特征在于,步骤S11包括:

步骤S111、收集大型变压器的历史数据,构造训练数据集,所述历史数据包括多传感器监控数据、运行状态数据和相应的真实剩余使用寿命;

步骤S112、将训练数据集中的多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型;

步骤S113、通过并行的BLSTM层和BGRU层挖掘输入数据特征,以捕获来自不同维度的隐藏特征;

步骤S114、根据挖掘的不同维度的隐藏特征,从全连接层输出大型变压器的预测剩余使用寿命。

3. 根据权利要求2所述的用于恶劣多变工况下变压器剩余使用寿命预测方法,其特征在于,步骤S112包括:

步骤S1121、输入的多传感监测数据首先在两个全连接层中进行线性转换,获取数据隐藏特征;

步骤S1122、将运行状态数据并入到转换后的多传感监测数据中,构建高阶向量。

4. 根据权利要求2所述的用于恶劣多变工况下变压器剩余使用寿命预测方法,其特征在于,在步骤S113中,采用dropout技术防止重复捕获相同的特征。

5. 根据权利要求1所述的用于恶劣多变工况下变压器剩余使用寿命预测方法,其特征在于,在步骤S12中,使用自适应矩估计算法对对多维度循环神经网络模型进行调整和优化。

6. 用于恶劣多变工况下变压器剩余使用寿命预测系统,其特征在于,包括:模型训练模块和预测模块;

所述模型训练模块包括:

模型构建单元,用于将多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型,挖掘不同维度的隐藏特征,输出预测的剩余使用寿命;

模型优化单元,用于利用真实剩余使用寿命和输出的预测剩余使用寿命之间的预测偏差,对多维度循环神经网络模型进行调整和优化;

所述预测模块包括：

数据收集单元，用于收集待预测的大型变压器的测试数据，所述测试数据包括多传感监测数据和运行状态数据；

预测单元，用于将所述测试数据实时输入到训练好的多维度循环神经网络模型中，得到大型变压器的预测剩余使用寿命。

7. 根据权利要求6所述的用于恶劣多变工况下变压器剩余使用寿命预测系统，其特征在于，所述模型构建单元包括：

历史数据收集子单元，用于收集大型变压器的历史数据，构造训练数据集，所述历史数据包括多传感器监控数据、运行状态数据和相应的真实剩余使用寿命；

数据输入子单元，用于将训练数据集中的多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型；

特征挖掘子单元，用于通过并行的BLSTM层和BGRU层挖掘输入数据特征，以捕获来自不同维度的隐藏特征；

结果输出子单元，用于根据挖掘的不同维度的隐藏特征，从全连接层输出大型变压器的预测剩余使用寿命。

8. 根据权利要求7所述的用于恶劣多变工况下变压器剩余使用寿命预测系统，其特征在于，所述数据输入子单元用于将输入的多传感监测数据首先在两个全连接层中进行线性转换，获取数据隐藏特征，将运行状态数据并入到转换后的多传感监测数据中，构建高阶向量。

9. 根据权利要求7所述的用于恶劣多变工况下变压器剩余使用寿命预测系统，其特征在于，所述特征挖掘子单元采用dropout技术防止重复捕获相同的特征。

10. 根据权利要求6所述的用于恶劣多变工况下变压器剩余使用寿命预测系统，其特征在于，所述模型优化单元使用自适应矩估计算法对多维度循环神经网络模型进行调整和优化。

## 用于恶劣多变工况下变压器剩余使用寿命预测方法和系统

### 技术领域

[0001] 本发明涉及变压器技术领域,尤其涉及一种用于恶劣多变工况下变压器剩余使用寿命预测方法和系统。

### 背景技术

[0002] 大型变压器的突发故障都可能导致巨大的经济损失。开展大型变压器剩余使用寿命预测可以有效地估计出大型变压器在一定性能水平下剩余的有效工作时间,是保障大型变压器可靠性、可用性、可维护性和安全性的重要手段。

[0003] 恶劣多变工况下大型变压器剩余使用寿命预测是一个非常具有挑战性的问题,不仅需要分析大型变压器的多传感监测数据,还要综合利用运行状态数据。尽管部分现有的大型变压器剩余使用寿命预测方法声称其可用于变工况大型变压器剩余使用寿命预测,但是这些方法通常仅分析大型变压器的监测数据,无法实现对监测数据和运行状态数据同时建模分析,导致这些方法在大多数多变工况下的大型变压器上预测性能较差。

### 发明内容

[0004] 有鉴于此,本发明旨在解决现有针对大型变压器剩余使用寿命的预测方法在大多数多变工况下预测性能较差的问题。

[0005] 为了解决上述技术问题,本发明提供以下技术方案:

[0006] 第一方面,本发明提供了一种用于恶劣多变工况下变压器剩余使用寿命预测方法,包括:模型训练阶段和预测阶段;

[0007] 模型训练阶段包括:

[0008] 步骤S11、将多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型,挖掘不同维度的隐藏特征,输出预测的剩余使用寿命;

[0009] 步骤S12、利用真实剩余使用寿命和输出的预测剩余使用寿命之间的预测偏差,对多维度循环神经网络模型进行调整和优化;

[0010] 预测阶段包括:

[0011] 步骤S21、收集待预测的大型变压器的测试数据,测试数据包括多传感监测数据和运行状态数据;

[0012] 步骤S22、将测试数据实时输入到训练好的多维度循环神经网络模型中,得到大型变压器的预测剩余使用寿命。

[0013] 进一步的,步骤S11包括:

[0014] 步骤S111、收集大型变压器的历史数据,构造训练数据集,历史数据包括多传感器监控数据、运行状态数据和相应的真实剩余使用寿命;

[0015] 步骤S112、将训练数据集中的多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型;

[0016] 步骤S113、通过并行的BLSTM层和BGRU层挖掘输入数据特征,以捕获来自不同维度

的隐藏特征；

[0017] 步骤S114、根据挖掘的不同维度的隐藏特征，从全连接层输出大型变压器的预测剩余使用寿命。

[0018] 进一步的，步骤S112包括：

[0019] 步骤S1121、输入的多传感监测数据首先在两个全连接层中进行线性转换，获取数据隐藏特征；

[0020] 步骤S1122、将运行状态数据并入到转换后的多传感监测数据中，构建高阶向量。

[0021] 进一步的，在步骤S113中，采用dropout技术防止重复捕获相同的特征。

[0022] 进一步的，在步骤S12中，使用自适应矩估计算法对对多维度循环神经网络模型进行调整和优化。

[0023] 第二方面，本发明提供了一种用于恶劣多变工况下变压器剩余使用寿命预测系统，包括：模型训练模块和预测模块；

[0024] 模型训练模块包括：

[0025] 模型构建单元，用于将多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型，挖掘不同维度的隐藏特征，输出预测的剩余使用寿命；

[0026] 模型优化单元，用于利用真实剩余使用寿命和输出的预测剩余使用寿命之间的预测偏差，对多维度循环神经网络模型进行调整和优化；

[0027] 预测模块包括：

[0028] 数据收集单元，用于收集待预测的大型变压器的测试数据，测试数据包括多传感监测数据和运行状态数据；

[0029] 预测单元，用于将测试数据实时输入到训练好的多维度循环神经网络模型中，得到大型变压器的预测剩余使用寿命。

[0030] 进一步的，模型构建单元包括：

[0031] 历史数据收集子单元，用于收集大型变压器的历史数据，构造训练数据集，历史数据包括多传感器监控数据、运行状态数据和相应的真实剩余使用寿命；

[0032] 数据输入子单元，用于将训练数据集中的多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型；

[0033] 特征挖掘子单元，用于通过并行的BLSTM层和BGRU层挖掘输入数据特征，以捕获来自不同维度的隐藏特征；

[0034] 结果输出子单元，用于根据挖掘的不同维度的隐藏特征，从全连接层输出大型变压器的预测剩余使用寿命。

[0035] 进一步的，数据输入子单元用于将输入的多传感监测数据首先在两个全连接层中进行线性转换，获取数据隐藏特征，将运行状态数据并入到转换后的多传感监测数据中，构建高阶向量。

[0036] 进一步的，特征挖掘子单元采用dropout技术防止重复捕获相同的特征。

[0037] 进一步的，模型优化单元使用自适应矩估计算法对对多维度循环神经网络模型进行调整和优化。

[0038] 综上，本发明提供了一种用于恶劣多变工况下变压器剩余使用寿命预测方法和系统，能够实现恶劣多变工况下大型变压器剩余使用寿命预测。本发明通过多维度循环神

神经网络中,多传感器监测数据和运行状态数据通过不同的输入通道馈入模型,捕获来自不同维度的隐藏特征,根据捕获的多维度特征预测剩余使用寿命,同时利用真实标签和预测标签之间的偏差,对模型进行调整优化,以实现大型变压器恶劣多变工况下剩余使用寿命的精确预测。本发明同时利用了大型变压器的监测数据和运行状态数据进行建模分析,从而提高了在恶劣多变工况下的预测精度。

### 附图说明

[0039] 为了更清楚地说明本发明实施例或现有技术中的技术方案,下面将对实施例或现有技术描述中所需要使用的附图作简单地介绍,显而易见地,下面描述中的附图仅仅是本发明的一些实施例,对于本领域普通技术人员来讲,在不付出创造性劳动性的前提下,还可以根据这些附图获得其它的附图。

[0040] 图1为本发明实施例提供的多维度循环神经网络模型结构示意图;

[0041] 图2为本发明实施例提供的Dropout技术示意图。

### 具体实施方式

[0042] 为使得本发明的目的、特征、优点能够更加的明显和易懂,下面将结合本发明实施例中的附图,对本发明实施例中的技术方案进行清楚、完整地描述,显然,下面所描述的实施例仅仅是本发明一部分实施例,而非全部的实施例。基于本发明中的实施例,本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其它实施例,都属于本发明保护的范围。

[0043] 针对现有技术中无法实现对监测数据和运行状态数据同时建模分析,导致这些方法在大多数变工况大型变压器上的预测性能较差的问题,提供一种用于恶劣多变工况下变压器剩余使用寿命预测方法和系统。在模型训练阶段,利用多传感监测数据和运行状态数据训练多维度循环神经网络模型,挖掘不同维度的隐藏特征,输出预测的剩余使用寿命;同时利用真实剩余使用寿命和输出的预测剩余使用寿命之间的预测偏差,对多维度循环神经网络模型进行调整和优化;在预测阶段,将收集的待预测的大型变压器的测试数据,实时输入到训练好的多维度循环神经网络模型中,得到大型变压器的预测剩余使用寿命。通过对多传感器监测数据和运行状态数据进行建模分析,可以精准预测大型变压器的预测剩余使用寿命。

[0044] 为了更好的理解上述技术方案,下面将结合说明书附图以及具体的实施方式对上述技术方案进行详细的说明,应当理解本发明实施例以及实施例中的具体特征是对本申请技术方案的详细的说明,而不是对本申请技术方案的限定,在不冲突的情况下,本发明实施例以及实施例中的技术特征可以相互组合。

[0045] 本发明的多维度循环神经网络模型不仅可以执行单工况下的预测任务,同时可以完成恶劣多变工况下的预测任务。

[0046] 以下对本发明的一种用于恶劣多变工况下变压器剩余使用寿命预测方法的实施例进行详细的介绍。

[0047] 本实施例提供一种用于恶劣多变工况下变压器剩余使用寿命预测方法,包括:模型训练阶段和预测阶段。

[0048] 在模型训练阶段将多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型,挖掘不同维度的隐藏特征,输出预测的剩余使用寿命;利用真实剩余使用寿命和输出的预测剩余使用寿命之间的预测偏差,对多维度循环神经网络模型进行调整和优化;

[0049] 在预测阶段收集待预测的大型变压器的测试数据,所述测试数据包括多传感监测数据和运行状态数据;将所述测试数据实时输入到训练好的多维度循环神经网络模型中,得到大型变压器的预测剩余使用寿命。

[0050] 具体地,在本实施例中,针对恶劣多变工况下的预测任务,首先收集大型变压器的历史数据,包括多传感器监控数据、运行状态数据和相应的真实剩余使用寿命,以构造训练集  $\{X_i, O_i, r_i\}^K$ , 其中  $K$  表示训练样本总个数。 $X_i = \{x_1, x_2, \dots, x_t, \dots, x_N\}$  表示输入数据样本集,其中  $x_t \in R^{s \times 1}$  是  $t$  时刻来自  $s$  个所选传感器的信号数据组成的向量。 $O_i = \{o_1, o_2, \dots, o_t, \dots, o_N\}$  表示运行状态数据样本集,其中  $o_t \in R^{p \times 1}$  是  $t$  时刻  $p$  个运行状态数据组成的向量。 $r_i$  表示在  $t$  时刻的与  $X_i$  和  $O_i$  相对应的真实剩余使用寿命。

[0051] 具体地,在本实施例中,将训练数据集中的多传感器监测数据和运行状态数据通过不同的输入通道被同时输入到模型中。然后,多维度循环神经网络通过并行的BLSTM层和BGRU层挖掘输入数据特征,以捕获来自不同维度的隐藏特征。最终,从最后一个全连接层输出预测的大型变压器剩余使用寿命。多维度循环神经网络的模型结构如图1所示。

[0052] 假设  $X_i = \{x_1, x_2, \dots, x_t, \dots, x_N\}^T$  表示第  $i$  个输入数据样本,其中  $x_t \in R^{s \times 1}$  是  $t$  时刻来自  $s$  个所选传感器的信号数据组成的向量。 $O_i = \{o_1, o_2, \dots, o_t, \dots, o_N\}$  表示运行状态数据样本集,其中  $o_t \in R^{p \times 1}$  是  $t$  时刻  $p$  个运行状态数据组成的向量。如图2所示,输入的多传感监测数据首先在两个全连接层中进行线性转换,以获取数据隐藏表征,表示为:

$$[0053] \quad F_i = W_{d1} X_i + b_{d1} \quad (1)$$

[0054] 式中,  $W_{d1}$  和  $b_{d1}$  是全连接层权重矩阵和偏置。 $X_i$  表示输入的  $i$  时刻监测数据向量,  $F_i$  表示Dense层输出的数据隐藏表征。

[0055] 然后,将运行状态数据拼接到  $F_i$  中,以构造一个高阶向量  $U_i$ , 表示如下:

$$[0056] \quad U_i = [F_i, O_i] \quad (2)$$

[0057] 式中,  $O_i$  表示输入的  $i$  时刻运行状态数据向量。

[0058] 接下来,将向量  $U_i$  分别传送到堆叠的BLSTM层和BGRU层中,并且获得不同维度的隐藏特征。第一个和中间的BLSTM层和BGRU层的输出可以表示为:

$$[0059] \quad H_{i,M}^{(BL)} = h_N^{(BL)} = \bar{h}_N^{(L)} \oplus \bar{h}_N^{(L)} \quad (5)$$

$$[0060] \quad H_{i,M}^{(BG)} = h_N^{(BG)} = \bar{h}_N^{(G)} \oplus \bar{h}_N^{(G)} \quad (6)$$

[0061] 其中  $H_{i,M}^{(BL)}$  和  $H_{i,M}^{(BG)}$  被认为是来自不同维度的隐藏特征。一旦获得了  $H_{i,M}^{(BL)}$  和  $H_{i,M}^{(BG)}$ , 这些隐藏的特征矩阵就被拼接为一个合并的特征向量,表示为

$$[0062] \quad H_i = [H_{i,M}^{(BL)}, H_{i,M}^{(BG)}] \quad (7)$$

[0063] 最后,将合并的特征向量输入到另外两个线性回归密集层中,以生成预测结果。

$$[0064] \quad \hat{r}_i = W_{d2} H_i \quad (8)$$

[0065] 其中,  $\hat{r}_i$  表示输出的预测结果。 $W_{d2}$  表示线性回归层中的权重矩阵。

[0066] 值得说明的是, 本方法虽然是针对多工况预测问题设计的, 但这并不代表该方法只适应于多工况预测问题。在处理单工况预测问题时, 考虑到状态数据的不变的, 对预测结果没有影响。所以只需将上述公式2改为  $U_i = F_i$ , 以屏蔽掉状态数据  $O_i$  即可实现单工况下的预测功能。

[0067] 进一步地, 在本实施例中, 在利用训练数据集得到多维度循环神经网络模型后, 还需要对得到的多维度循环神经网络模型进行优化。通过反向传播利用真实剩余使用寿命和预测剩余使用寿命之间的预测偏差, 并利用合理的反向传播策略和优化算法来对模型进行调整和优化。考虑到数据样本量过小或模型结构过于复杂都会造成模型过拟合的问题, 还需要设计相应的模型正则化方法。

[0068] 模型参数的优化算法会直接影响多维度循环神经网络训练的效率。因此, 采用自适应矩估计 (Adaptive moment estimation, Adam) 算法来代替传统的随机梯度下降 (Stochastic gradient descent, SGD) 优化器, 以最小化多维度循环神经网络的损失函数。在模型参数优化过程中, 传统的SGD算法保持着固定的学习速率来更新所有参数, 这导致网络参数的更新效率极其低下。Adam算法对网络参数的更新过程表示如下:

$$[0069] \quad \mathbf{g}_t = \nabla_{\theta} \sum_i L(\theta_{t-1}) \quad (9)$$

$$[0070] \quad \mathbf{m}_t = \beta_1 \mathbf{m}_{t-1} + (1 - \beta_1) \mathbf{g}_t \quad (10)$$

$$[0071] \quad \mathbf{n}_t = \beta_2 \mathbf{n}_{t-1} + (1 - \beta_2) \mathbf{g}_t^2 \quad (11)$$

$$[0072] \quad \hat{\mathbf{m}}_t = \frac{\mathbf{m}_t}{1 - \beta_1^t} \quad (12)$$

$$[0073] \quad \hat{\mathbf{n}}_t = \frac{\mathbf{n}_t}{1 - \beta_2^t} \quad (13)$$

$$[0074] \quad \theta_t = \theta_{t-1} - \eta \times \frac{\hat{\mathbf{m}}_t}{\sqrt{\hat{\mathbf{n}}_t} + \epsilon} \quad (14)$$

[0075] 其中,  $\mathbf{g}_t$  是损失函数  $L(\theta)$  对网络参数集  $\theta$  的梯度。 $\mathbf{m}_t$  和  $\mathbf{n}_t$  分别是梯度的一阶矩估计和二阶矩估计。 $\hat{\mathbf{m}}_t$  和  $\hat{\mathbf{n}}_t$  分别是  $\mathbf{m}_t$  和  $\mathbf{n}_t$  的偏差修正结果。 $\beta_1^t$  和  $\beta_2^t$  分别是一阶矩估计和二阶矩估计的指数衰减率。 $\eta$  表示步长,  $\epsilon$  表示数值稳定常数。 $\theta_t$  是计算出的  $\theta_{t-1}$  在  $t$  时间的更新值。

[0076] 进一步地, 神经网络层数的增加会提高模型训练时间, 并增加过拟合风险。过拟合导致神经网络在训练数据集上表现优异, 而在测试数据集上表现较差。为了克服这个问题, 本发明的多维度循环神经网络中采用了 dropout 技术来防止重复捕获相同的特征。dropout 技术的示意图如图2所示。在这个示意图中, 颜色较深的圈是在多维度循环神经网络的训练过程中按建用于从监测信号中获取数据以构造高维输入向量。一旦时间窗完成这次采集, 它将沿时间方向滑动一个采样周期, 以执行下一次采集, 直到信号结束。

[0077] 进一步地, 在模型训练阶段, 将输入数据输入到多维度循环神经网络模型中, 模型按照公式1至9的过程前向传递。为了实现多维度循环神经网络的反向传播, 需要为多维度



神经网络模型设计一个恰当的模型损失函数。基于模型输出的预测值 $\hat{r}_i$ 和真实的数据值 $r_i$ ,引入均方误差函数,设计如下的损失函数:

$$[0078] \quad L(\theta) = \frac{1}{K} \sum_{i=1}^K (r_i - F_{MDRNN}(X_i, O_i; \theta))^2 \quad (15)$$

[0079] 其中, $F_{MDRNN}(X_i, O_i, \theta)$ 表示将传感监测数据 $X_i$ 和运行状态数据 $O_i$ 输入多维度循环神经网络模型得到的预测输出, $\theta$ 表示多维度循环神经网络模型参数集合。

[0080] 进一步地,在本实施例中,在测试过程中,先将在线测试数据预处理,再实时输入到训练好的多维度循环神经网络模型中,即可得到预测的大型变压器剩余使用寿命。其中,输入数据主要为变压器监测数据,包括:变压器油温度、负荷监测、油中溶解气体及微水信号、铁芯接地电流、变压器振动信号等;输出数据为变压器剩余使用寿命。

[0081] 相应地,本发明还提供一种用于恶劣多变工况下变压器剩余使用寿命的预测系统,包括包括模型训练模块和预测模块。

[0082] 具体地,在本实施例中,模型训练模块包括:

[0083] 模型构建单元,用于将多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型,挖掘不同维度的隐藏特征,输出预测的剩余使用寿命;

[0084] 模型优化单元,用于利用真实剩余使用寿命和输出的预测剩余使用寿命之间的预测偏差,对多维度循环神经网络模型进行调整和优化,使用自适应矩估计算法对多维度循环神经网络模型进行调整和优化。

[0085] 具体地,在本实施例中,预测模块包括:

[0086] 数据收集单元,用于收集待预测的大型变压器的测试数据,所述测试数据包括多传感监测数据和运行状态数据;

[0087] 预测单元,用于将所述测试数据实时输入到训练好的多维度循环神经网络模型中,得到大型变压器的预测剩余使用寿命。

[0088] 进一步地,在本实施例中,模型构建单元包括:

[0089] 历史数据收集子单元,用于收集大型变压器的历史数据,构造训练数据集,所述历史数据包括多传感器监控数据、运行状态数据和相应的真实剩余使用寿命;

[0090] 数据输入子单元,用于将训练数据集中的多传感监测数据和运行状态数据通过不同的输入通道同时输入到多维度循环神经网络模型,其中,首先将输入的多传感监测数据首先在两个全连接层中进行线性转换,获取数据隐藏特征,然后将运行状态数据并入到转换后的多传感监测数据中,构建高阶向量;

[0091] 特征挖掘子单元,用于通过并行的BLSTM层和BGRU层挖掘输入数据特征,以捕获来自不同维度的隐藏特征,采用dropout技术防止重复捕获相同的特征;

[0092] 结果输出子单元,用于根据挖掘的不同维度的隐藏特征,从全连接层输出大型变压器的预测剩余使用寿命。

[0093] 以上实施例仅用以说明本发明的技术方案,而非对其限制;尽管参照前述实施例对本发明进行了详细的说明,本领域的普通技术人员应当理解:其依然可以对前述各实施例所记载的技术方案进行修改,或者对其中部分技术特征进行等同替换;而这些修改或者替换,并不使相应技术方案的本质脱离本发明各实施例技术方案的精神和范围。

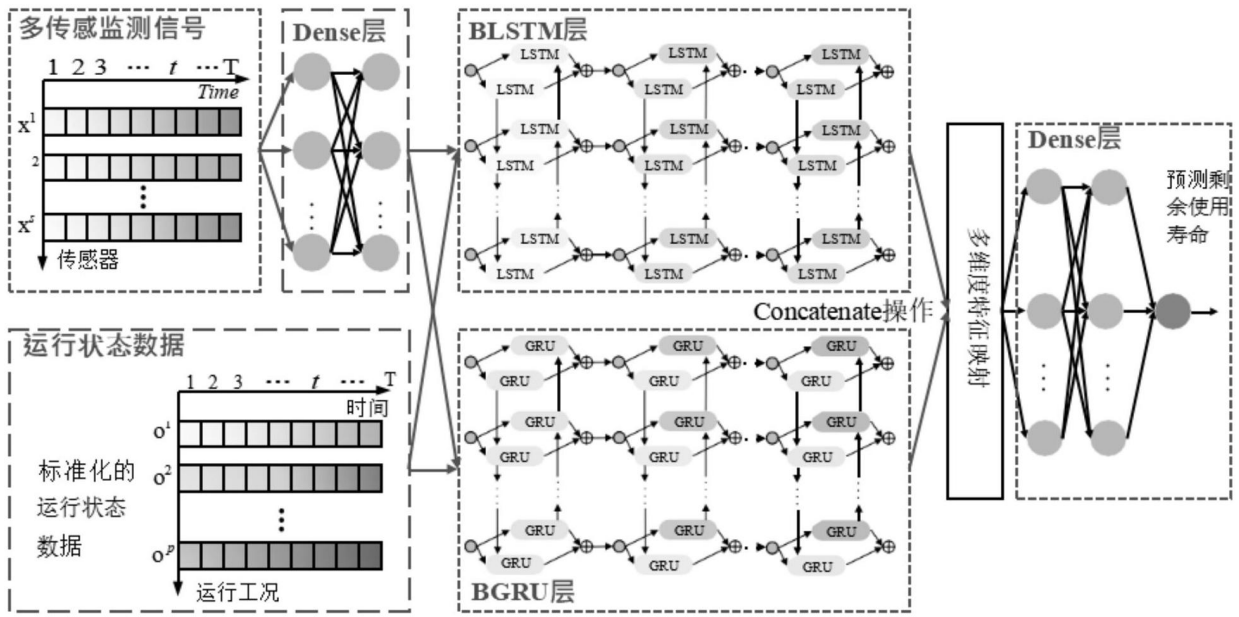


图1




图2