



(12) 发明专利申请

(10) 申请公布号 CN 113642779 A

(43) 申请公布日 2021. 11. 12

(21) 申请号 202110829782.X

(22) 申请日 2021.07.22

(71) 申请人 西安理工大学

地址 710048 陕西省西安市碑林区金花南路5号

(72) 发明人 谢国 杨婧 李艳恺 穆凌霞

梁莉莉 辛菁 刘涵 钱富才

李思雨 王承兰

(74) 专利代理机构 西安弘理专利事务所 61214

代理人 王敏强

(51) Int. Cl.

G06Q 10/04 (2012.01)

G06K 9/62 (2006.01)

G06N 3/04 (2006.01)

G06N 3/08 (2006.01)

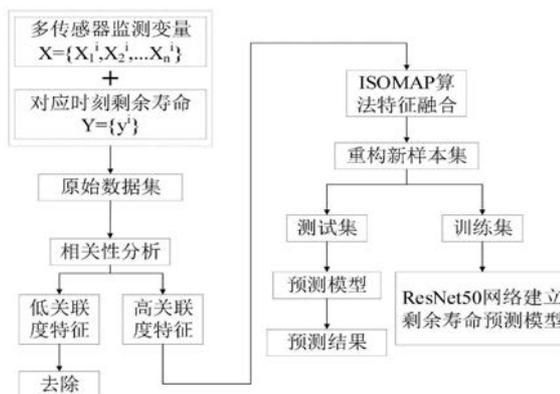
权利要求书3页 说明书8页 附图4页

(54) 发明名称

基于特征融合的ResNet50网络关键设备剩余寿命预测方法

(57) 摘要

本发明公开了一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法,首先对系统设备中各传感器采集的数据信息进行相关性分析,过滤与寿命关联程度较低的特征变量,确定影响系统寿命的高关联度特征变量;然后利用ISOMAP算法融合高关联度特征变量,得到融合特征变量,有效的集成传感器信息;针对融合特征变量,和系统对应时刻的剩余寿命构成剩余寿命预测总样本集,最后建立预测模型并预测剩余寿命,得到系统剩余寿命预测结果。本发明对工业领域中的设备寿命进行准确预测,及时提示工作人员对设备进行预防性维护。



1. 一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法,其特征在于,具体按照以下步骤实施:

步骤1、对系统中各传感器采集的数据信息进行相关性分析,过滤与寿命关联程度较低的特征变量,确定影响系统寿命的高关联度特征变量;

步骤2、对所述步骤1得到的高关联度特征变量进行特征融合:利用ISOMAP算法融合步骤1中的高关联度特征变量,得到融合特征变量,有效的集成传感器信息;

步骤3、构建数据集构造策略:针对步骤2中得到的融合特征变量,和系统对应时刻的剩余寿命构成剩余寿命预测总样本集,并将其分为训练集与测试集;

步骤4:建立预测模型并预测剩余寿命:将步骤3中得到的剩余寿命预测总样本集的训练集作为深度残差网络Resnet50的输入训练该预测网络,利用训练好的网络对测试样本进行预测,得到系统剩余寿命预测结果。

2. 根据权利要求1所述的一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法,其特征在于,所述步骤1具体如下:

步骤1.1、对系统中传感器采集的数据信息进行编号, $n$ 表示为传感器的序号, $x_n$ 为第 $n$ 个传感器的监测数据信息,监测数据 $X$ 表示为 $X = \{x_1^i, x_2^i, \dots, x_n^i\}$ ,其中, $x_n^i$ 为系统中 $i$ 时刻第 $n$ 个传感器的监测数据信息, $i = 1, 2, \dots, t$ ,该系统的剩余寿命 $Y$ 表示为 $Y = \{y^i\}$ ,其中, $y^i$ 为系统对应 $i$ 时刻的剩余寿命;

步骤1.2、利用相关性分析计算相关系数 $\rho_{x_n Y}$ ,

$$\rho_{x_n Y} = \frac{Cov(x_n, Y)}{\sqrt{D(x_n)}\sqrt{D(Y)}} \quad (1)$$

其中, $Cov(x_n, Y)$ 为监测数据信息 $x_n$ 和剩余寿命 $Y$ 之间的协方差, $\sqrt{D(x_n)}$ 和 $\sqrt{D(Y)}$ 分别为监测数据信息 $x_n$ 和剩余寿命 $Y$ 的标准差;

步骤1.3、计算监测数据信息 $x_n$ 和剩余寿命 $Y$ 的Pearson相关系数 $\rho_{x_n Y}$ ,具体如下:

$$\text{相关系数 } \rho_{x_n Y} \text{ 范围: } \begin{cases} 0.8 \leq \rho_{x_n Y} \leq 1, & \text{极强相关} \\ 0.6 \leq \rho_{x_n Y} \leq 0.8, & \text{强相关} \\ 0.4 \leq \rho_{x_n Y} \leq 0.6, & \text{中等程度相关} \\ 0.2 \leq \rho_{x_n Y} \leq 0.4, & \text{弱相关相关} \\ 0 \leq \rho_{x_n Y} \leq 0.2, & \text{极弱相关或无相关} \end{cases} \quad (2)$$

保留结果超过0.8以上的高关联度特征变量。

3. 根据权利要求2所述的一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法,其特征在于,所述步骤2具体如下:

步骤2.1、选取邻域,构造邻域图 $G$ :近邻参数设置为 $k$ ,将步骤1.3保留的高关联度特征变量构造样本集 $D = \{x_1, x_2, \dots, x_m\}$ , $m$ 是原始 $d$ 维空间的样本集 $D$ 中样本点的个数,在样本集 $D = \{x_1, x_2, \dots, x_m\}$ 中任意选取某两个数据点 $x_h$ 与 $x_j$ ,其中, $h, j$ 是样本集 $D$ 中选取的两个数据点的编号, $h, j \in 1, 2, 3 \dots m$ ,第一个数据点 $x_h$ 与近邻参数 $k$ 间距离设为欧氏距离,另一个数据点 $x_j$ 是 $x_h$ 最近的近邻参数 $k$ 个点之一时,表示它们相近邻,邻域图 $G$ 有边,即邻域图 $G$ 构造完

毕；

步骤2.2、计算最短路径距离矩阵：若邻域图G上两点 $x_h, x_j$ 存在边连接时，定义样本点 $x_h$ 与 $x_j$ 之间的最短路径为 $d_G(x_h, x_j) = d(x_h, x_j)$ ；否则 $d_G(x_h, x_j) = \infty$ ，其中， $d(x_h, x_j)$ 为数据点 $x_h$ 与 $x_j$ 的欧氏距离；

对 $l \in 1, 2, 3 \dots m$ ，有：

$$d_G(x_h, x_j) = \min \{d_G(x_h, x_j), d_G(x_h, x_l) + d_G(x_l, x_j)\} \quad (3)$$

其中， $x_l$ 是样本集D中新的样本点， $d_G(x_h, x_l)$ 表示样本点 $x_h$ 与 $x_l$ 之间的最短路径， $d_G(x_l, x_j)$ 表示样本点 $x_l$ 与 $x_j$ 之间的最短路径， $d_G(x_h, x_j)$ 表示样本点 $x_h$ 与 $x_j$ 之间的最短路径；

基于此，即可确定最短路径距离矩阵为 $D_G = [d_G^2(x_h, x_j)]_{h,j=l}^m$ ，其中， $m$ 是 $d$ 维原始空间的样本集D中样本点的个数， $h, j, l$ 是样本集D中选取的三个数据点的编号， $h, j, l \in 1, 2, 3 \dots m$ ；

步骤2.3、通过对 $d$ 维原始空间降维，构造 $d'$ 维新样本空间，并且使得 $d'$ 维新样本空间与 $d$ 维原始空间中的距离保持不变，求取降维后样本的内积矩阵B：令 $B = Z^T Z \in R^{m \times m}$ ，其中， $d$ 是原始空间的维数， $d'$ 是新样本空间的维数， $Z$ 为 $d$ 维原始空间嵌入 $d'$ 维新样本空间的矩阵表示， $R$ 为实数集；

构造新样本空间后， $d' < d$ ，且任意两个样本在 $d'$ 维新样本空间中的欧氏距离等于 $d$ 维原始空间中的距离，即：

$$\|z_h - z_j\| = \text{dist}_{h_j} \quad (4)$$

其中， $z_h, z_j$ 分别表示样本点 $x_h, x_j$ 在 $d'$ 维新样本空间中的欧氏距离， $\text{dist}_{h_j}$ 表示样本点 $x_h$ 和 $x_j$ 在 $d$ 维原始空间中的距离；

将式(4)展开并对等号两端求平方得：

$$\text{dist}_{h_j}^2 = \|z_h\|^2 + \|z_j\|^2 - 2z_h^T z_j \quad (5)$$

$b_{hj} = z_h^T z_j$ ， $b_{hh}$ 与 $b_{jj}$ 以此类推，则有：

$$\text{dist}_{h_j}^2 = b_{hh} + b_{jj} - 2b_{hj} \quad (6)$$

$$b_{hj} = -\frac{1}{2}(\text{dist}_{h_j}^2 - \text{dist}_h^2 - \text{dist}_j^2 + \text{dist}_{..}^2) \quad (7)$$

其中， $b_{hj}$ 为内积矩阵B中第 $h$ 行 $j$ 列的元素， $b_{hh}$ 与 $b_{jj}$ 以此类推， $\text{dist}_{h_j}$ 表示样本点 $x_h$ 和 $x_j$ 在 $d$ 维原始空间的距离， $\text{dist}_h, \text{dist}_j$ 及 $\text{dist}_{..}$ 以此类推；

通过求得 $b_{hj}, b_{hh}, b_{jj}$ 等内积矩阵B中的元素可得内积矩阵B；

步骤2.4、对最短路径距离矩阵 $D_G$ 构造 $d$ 维嵌入，最终得到样本通过 $d$ 维原始空间嵌入 $d'$ 维新样本空间的矩阵表示 $Z \in R^{d' \times m}$ ；

由步骤2.3求得的内积矩阵B通过特征分解获得特征值矩阵和特征向量矩阵，即：

$$B = V \Lambda V^T \quad (8)$$

其中， $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_d)$ 为特征值构成的对角矩阵， $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$ ， $\lambda_1, \lambda_2, \dots, \lambda_d$ 为分解获得的特征值， $V$ 为对应的特征向量矩阵。

则 $d$ 维原始空间嵌入 $d'$ 维新样本空间的矩阵表示 $Z$ 的计算公式为： $Z = \Lambda^{\frac{1}{2}} V^T \in R^{d' \times m}$ ，计

算Z的结果后可得到矩阵表示为： $Z = \{z_1^i, z_2^i, \dots, z_m^i\}$ 。此时的结果 $Z = \{z_1^i, z_2^i, \dots, z_m^i\}$ 便是融合后的特征变量；

其中，有 $d^*$ 个非零特征值， $\Lambda_* = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_{d^*})$ 为特征值构成的对角矩阵，特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{d^*}$ ， $V_*$ 为对应的特征向量矩阵； $z_{m'}^i$ 为 $d'$ 维新样本空间中 $i$ 时刻第 $m'$ 个样本点的融合特征变量， $m'$ 是 $d'$ 维新样本空间中样本点的个数。

4. 根据权利要求3所述的一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法，其特征在于，所述步骤3具体如下：

步骤3.1、构造样本集：将步骤2中得到的融合后的特征变量 $Z = \{z_1^i, z_2^i, \dots, z_m^i\}$ 和系统剩余寿命 $Y = \{y^i\}$ 重构为剩余寿命预测样本集 $\{y^i, z_1^i, z_2^i, \dots, z_m^i\}$ ， $y^i, z_1^i, z_2^i, \dots, z_m^i$ 分别为重构的剩余寿命预测样本集中的特征变量，并按照7:3的比例划分为训练集和验证集，其中， $y^i$ 为系统对应 $i$ 时刻的剩余寿命；

步骤3.2、构造子训练集和子测试集：将步骤3.1中划分好的训练集再次按照7:3的比例划分为子训练集和子测试集；

步骤3.3、构造总训练集和总测试集：将步骤3.2得到的子训练集中的特征变量按照列堆叠的形式合并为总训练集，同时，对应步骤3.2中子训练集的合并顺序，将子测试集中的特征变量以列堆叠的形式合并为总测试集，最终形成由总训练集、总测试集和步骤3.1得到的验证集构成的剩余寿命预测总样本集。

5. 根据权利要求4所述的一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法，其特征在于，所述步骤4具体如下：

步骤4.1、构建50层深度残差网络ResNet50：深度残差网络ResNet50由3部分组成，分别为卷积池化部分、4个残差块部分、池化展平部分，残差块部分有两个基本的结构，分别为恒等残差块和卷积残差块；

步骤4.2、特征提取：将步骤3中得到的剩余寿命预测总样本集的训练集作为深度残差网络Resnet50的输入，采用一维卷积核对训练集进行特征提取，并对提取的卷积特征进行最大值池化，以获得池化特征；

步骤4.3、残差块的特征提取：将池化特征作为残差块的输入，深度残差网络Resnet50的残差块由以下四部分组成：一个卷积残差块和两个恒等残差块、一个卷积残差块和三个恒等残差块、一个卷积残差块和五个恒等残差块、一个卷积残差块和两个恒等残差块，上述四个残差块按照顺序连接组成为残差网络核心部分；

步骤4.4、建立预测模型：经平均池化层整合残差块的输出，再通过展平层获得预测模型；

步骤4.5、得到剩余寿命预测结果：将测试集输入预测模型中，得到剩余寿命预测结果，每进行一次预测得到输出的预测结果，将该预测结果和系统采集的剩余寿命真实数据之间的误差反向传播给深度残差网络Resnet50，并对网络中的各参数进行调优，当网络的误差小于0.05时，说明网络收敛，利用训练好的网络对测试样本进行预测，最终得到系统剩余寿命预测结果，实现系统的剩余寿命的准确预测。

## 基于特征融合的ResNet50网络关键设备剩余寿命预测方法

### 技术领域

[0001] 本发明属于智能制造系统的监测与维护技术领域,具体涉及一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法。

### 背景技术

[0002] 预测与健康(Predictive and Health Management, PHM)技术在现代工业中至关重要,并已广泛应用于民用航空、汽车和制造业。随着时间的累积,由于设备在受到内部因素和各种外部因素(如磨损、外部冲击、负载、运行环境)的影响下,其性能及健康状态将会呈现不同程度的退化趋势,不断累积最终导致设备发生故障,造成无法估量的经济损失与安全事故等。剩余使用寿命(RUL)预测是现代工业领域预测健康管理(PHM)技术中最重要的组成部分之一,它的定义是从当前时刻的使用寿命到该寿命结束的长度。为了提高系统的安全性与可靠性,降低维修成本,需要确保在最佳时期对设备进行维护,定期更换零件,防止故障的累积最终造成的设备失效。对设备各部件传感器数据进行监测,准确的预测设备处于某时刻的剩余使用寿命,便可找到适当的时机对设备进行预防性维护,减少设备的停机时间,节约成本。

[0003] 由于对系统剩余使用寿命的预测主要基于多传感器收集到的大量监测数据,来评估系统整体的退化状态,及时对系统做出维护。单个传感器特征不足以准确判断系统的健康状态,因此需要多种特征。但特征过多会造成信息冗余,增大计算负担。于是过滤与寿命关联度低的特征并对其余多传感器特征进行融合,以获得更好的健康指标,提高预测方法的准确性,使预防性维护更加及时有效。针对剩余寿命预测研究中,特征过多导致维数爆炸从而使得计算效率低下的问题,提出一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法,该方法不仅能够增强对剩余寿命预测研究的信心,对于该学科和行业的进步起着关键性的作用。

### 发明内容

[0004] 本发明的目的是提供一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法,对工业领域中的设备寿命进行准确预测,及时提示工作人员对设备进行预防性维护。

[0005] 本发明所采用的技术方案是,一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法,具体按照以下步骤实施:

[0006] 步骤1、对系统设备中各传感器采集的数据信息进行相关性分析,过滤与寿命关联程度较低的特征变量,确定影响系统寿命的高关联度特征变量;

[0007] 步骤2、对所述步骤1得到的高关联度特征变量进行特征融合:利用ISOMAP算法融合步骤1中的高关联度特征变量,得到融合特征变量,有效的集成传感器信息;

[0008] 步骤3、构建数据集构造策略:针对步骤2中得到的融合特征变量,和系统对应时刻的剩余寿命构成剩余寿命预测总样本集,并将其分为训练集与测试集;

[0009] 步骤4:建立预测模型并预测剩余寿命:将步骤3中得到的剩余寿命预测总样本集

的训练集作为深度残差网络Resnet50的输入训练该预测网络,利用训练好的网络对测试样本进行预测,得到系统剩余寿命预测结果。

[0010] 本发明的特点还在于,

[0011] 步骤1具体如下:

[0012] 步骤1.1、对系统设备中传感器采集的数据信息进行编号, $n$ 表示为传感器的序号,

$x_n$ 为第 $n$ 个传感器的监测数据信息,监测数据 $X$ 表示为 $X = \{x_1^i, x_2^i, \dots, x_n^i\}$ ,其中, $x_n^i$ 为系统中 $i$ 时刻第 $n$ 个传感器的监测数据信息, $i = 1, 2, \dots, t$ ,该系统的剩余寿命 $Y$ 表示为 $Y = \{y^i\}$ ,其中, $y^i$ 为系统对应 $i$ 时刻的剩余寿命;

[0013] 步骤1.2、利用相关性分析计算相关系数 $\rho_{x_n Y}$ ,

$$[0014] \quad \rho_{x_n Y} = \frac{\text{Cov}(x_n, Y)}{\sqrt{D(x_n)}\sqrt{D(Y)}} \quad (1)$$

[0015] 其中, $\text{Cov}(x_n, Y)$ 为监测数据信息 $x_n$ 和剩余寿命 $Y$ 之间的协方差, $\sqrt{D(x_n)}$ 和 $\sqrt{D(Y)}$ 分别为监测数据信息 $x_n$ 和剩余寿命 $Y$ 的标准差;

[0016] 步骤1.3、计算监测数据信息 $x_n$ 和剩余寿命 $Y$ 的Pearson相关系数 $\rho_{x_n Y}$ ,具体如下:

[0017] 相关系数 $\rho_{x_n Y}$ 范围:

$$\left\{ \begin{array}{l} 0.8 \leq \rho_{x_n Y} \leq 1, \text{ 极强相关} \\ 0.6 \leq \rho_{x_n Y} \leq 0.8, \text{ 强相关} \\ 0.4 \leq \rho_{x_n Y} \leq 0.6, \text{ 中等程度相关} \\ 0.2 \leq \rho_{x_n Y} \leq 0.4, \text{ 弱相关相关} \\ 0 \leq \rho_{x_n Y} \leq 0.2, \text{ 极弱相关或无相关} \end{array} \right. \quad (2)$$

[0018] 保留结果超过0.8以上的高关联度特征变量。

[0019] 步骤2具体如下:

[0020] 步骤2.1、选取邻域,构造邻域图 $G$ :近邻参数设置为 $k$ ,将步骤1.3保留的高关联度特征变量构造样本集 $D = \{x_1, x_2, \dots, x_m\}$ , $m$ 是原始 $d$ 维空间的样本集 $D$ 中样本点的个数,在样本集 $D = \{x_1, x_2, \dots, x_m\}$ 中任意选取某两个数据点 $x_h$ 与 $x_j$ ,其中, $h, j$ 是样本集 $D$ 中选取的两个数据点的编号, $h, j \in 1, 2, 3 \dots m$ ,第一个数据点 $x_h$ 与近邻参数 $k$ 间距离设为欧氏距离,另一个数据点 $x_j$ 是 $x_h$ 最近的近邻参数 $k$ 个点之一时,表示它们相近邻,邻域图 $G$ 有边,即邻域图 $G$ 构造完毕;

[0021] 步骤2.2、计算最短路径距离矩阵:若邻域图 $G$ 上两点 $x_h, x_j$ 存在边连接时,定义样本点 $x_h$ 与 $x_j$ 之间的最短路径为 $d_G(x_h, x_j) = d(x_h, x_j)$ ;否则 $d_G(x_h, x_j) = \infty$ ,其中, $d(x_h, x_j)$ 为数据点 $x_h$ 与 $x_j$ 的欧氏距离;

[0022] 对 $l \in 1, 2, 3 \dots m$ ,有:

$$[0023] \quad d_G(x_h, x_j) = \min \{d_G(x_h, x_j), d_G(x_h, x_1) + d_G(x_1, x_j)\} \quad (3)$$

[0024] 其中, $x_1$ 是样本集 $D$ 中新的样本点, $d_G(x_h, x_1)$ 表示样本点 $x_h$ 与 $x_1$ 之间的最短路径, $d_G(x_1, x_j)$ 表示样本点 $x_1$ 与 $x_j$ 之间的最短路径, $d_G(x_h, x_j)$ 表示样本点 $x_h$ 与 $x_j$ 之间的最短路径;

[0025] 基于此,即可确定最短路径距离矩阵为 $D_G = [d_G^2(x_h, x_j)]_{h,j=1}^m$ ,其中,m是d维原始空间的样本集D中样本点的个数,h,j,l是样本集D中选取的三个数据点的编号,h,j,l $\in$ 1,2,3...m;

[0026] 步骤2.3、通过对d维原始空间降维,构造d'维新样本空间,并且使得d'维新样本空间与d维原始空间中的距离保持不变,求取降维后样本的内积矩阵B:令 $B = Z^T Z \in R^{m \times m}$ ,其中,d是原始空间的维数,d'是新样本空间的维数,Z为d维原始空间嵌入d'维新样本空间的矩阵表示,R为实数集;

[0027] 构造新样本空间后,d'<d,且任意两个样本在d'维新样本空间中的欧氏距离等于d维原始空间中的距离,即:

$$[0028] \quad \|z_h - z_j\| = \text{dist}_{h_j} \quad (4)$$

[0029] 其中, $z_h, z_j$ 分别表示样本点 $x_h, x_j$ 在d'维新样本空间中的欧氏距离, $\text{dist}_{h_j}$ 表示样本点 $x_h$ 和 $x_j$ 在d维原始空间中的距离;

[0030] 将式(4)展开并对等号两端求平方得:

$$[0031] \quad \text{dist}_{h_j}^2 = \|z_h\|^2 + \|z_j\|^2 - 2z_h^T z_j \quad (5)$$

[0032]  $b_{hj} = z_h^T z_j$ , $b_{hh}$ 与 $b_{jj}$ 以此类推,则有:

$$[0033] \quad \text{dist}_{h_j}^2 = b_{hh} + b_{jj} - 2b_{hj} \quad (6)$$

$$[0034] \quad b_{hj} = -\frac{1}{2}(\text{dist}_{h_j}^2 - \text{dist}_h^2 - \text{dist}_j^2 + \text{dist}_{..}^2) \quad (7)$$

[0035] 其中, $b_{hj}$ 为内积矩阵B中第h行j列的元素, $b_{hh}$ 与 $b_{jj}$ 以此类推, $\text{dist}_{h_j}$ 表示样本点 $x_h$ 和 $x_j$ 在d维原始空间的距离, $\text{dist}_h$ 、 $\text{dist}_j$ 及 $\text{dist}_{..}$ 以此类推;

[0036] 通过求得 $b_{hj}, b_{hh}, b_{jj}$ 等内积矩阵B中的元素可得内积矩阵B;

[0037] 步骤2.4、对最短路径距离矩阵 $D_G$ 构造d维嵌入,最终得到样本通过d维原始空间嵌入d'维新样本空间的矩阵表示 $Z \in R^{d' \times m}$ ;

[0038] 由步骤2.3求得的内积矩阵B通过特征分解获得特征值矩阵和特征向量矩阵,即:

$$[0039] \quad B = V \Lambda V^T \quad (8)$$

[0040] 其中, $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_d)$ 为特征值构成的对角矩阵, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d, \lambda_1, \lambda_2, \dots, \lambda_d$ 为分解获得的特征值,V为对应的特征向量矩阵。

[0041] 则d维原始空间嵌入d'维新样本空间的矩阵表示Z的计算公式为:

$Z = \Lambda_*^{-\frac{1}{2}} V_*^T \in R^{d' \times m}$ ,计算Z的结果后可得到矩阵表示为: $Z = \{z_1^i, z_2^i, \dots, z_m^i\}$ 。此时的结果 $Z = \{z_1^i, z_2^i, \dots, z_m^i\}$ 便是融合后的特征变量;

[0042] 其中,有d\*个非零特征值, $\Lambda_* = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_{d'})$ 为特征值构成的对角矩阵,特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{d'}$ , $V_*$ 为对应的特征向量矩阵; $z_m^i$ 为d'维新样本空间中i时刻第m'个样本点的融合特征变量,m'是d'维新样本空间中样本点的个数。

[0043] 步骤3具体如下:

[0044] 步骤3.1、构造样本集:将步骤2中得到的融合后的特征变量 $Z = \{z_1^i, z_2^i, \dots, z_m^i\}$ 和系统

剩余寿命 $Y = \{y^i\}$ 重构为剩余寿命预测样本集 $\{y^i, z_1^i, z_2^i, \dots, z_m^i\}$ ,  $y^i, z_1^i, z_2^i, \dots, z_m^i$ 分别为重构的剩余寿命预测样本集中的特征变量,并按照7:3的比例划分为训练集和验证集,其中, $y^i$ 为系统对应 $i$ 时刻的剩余寿命;

[0045] 步骤3.2、构造子训练集和子测试集:将步骤3.1中划分好的训练集再次按照7:3的比例划分为子训练集和子测试集;

[0046] 步骤3.3、构造总训练集和总测试集:将步骤3.2得到的子训练集中的特征变量按照列堆叠的形式合并为总训练集,同时,对应步骤3.2中子训练集的合并顺序,将子测试集中的特征变量以列堆叠的形式合并为总测试集,最终形成由总训练集、总测试集和步骤3.1得到的验证集构成的剩余寿命预测总样本集。

[0047] 步骤4具体如下:

[0048] 步骤4.1、构建50层深度残差网络ResNet50:深度残差网络ResNet50由3部分组成,分别为卷积池化部分、4个残差块部分、池化展平部分,残差块部分有两个基本的结构,分别为恒等残差块和卷积残差块;

[0049] 步骤4.2、特征提取:将步骤3中得到的剩余寿命预测总样本集的训练集作为深度残差网络Resnet50的输入,采用一维卷积核对训练集进行特征提取,并对提取的卷积特征进行最大值池化,以获得池化特征;

[0050] 步骤4.3、残差块的特征提取:将池化特征作为残差块的输入,深度残差网络Resnet50的残差块由以下四部分组成:一个卷积残差块和两个恒等残差块、一个卷积残差块和三个恒等残差块、一个卷积残差块和五个恒等残差块、一个卷积残差块和两个恒等残差块,上述四个残差块按照顺序连接组成为残差网络核心部分;

[0051] 步骤4.4、建立预测模型:经平均池化层整合残差块的输出,再通过展平层获得预测模型;

[0052] 步骤4.5、得到剩余寿命预测结果:将测试集输入预测模型中,得到剩余寿命预测结果,每进行一次预测得到输出的预测结果,将该预测结果和系统采集的剩余寿命真实数据之间的误差反向传播给深度残差网络Resnet50,并对网络中的各参数进行调优,当网络的误差小于0.05时,说明网络收敛,利用训练好的网络对测试样本进行预测,最终得到系统剩余寿命预测结果,实现系统的剩余寿命的准确预测。

[0053] 本发明的有益效果是,一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法,通过相关性分析的方法排除影响系统设备寿命的低关联度特征,利用ISOMAP算法对高关联度特征进行融合,有效的集成传感器信息,并且消除传感器之间的耦合性。将ISOMAP算法和深度残差网络Resnet50结合,使融合后的传感器特征信息作为深度残差网络Resnet50的输入训练该预测网络,学习各特征之间的隐层关系,构建剩余寿命预测模型,实现了剩余寿命的预测。通过实验仿真验证了所提方法在剩余寿命预测方面的准确性和高效性。

## 附图说明

[0054] 图1为本发明基于特征融合的ResNet50网络关键设备剩余寿命预测方法总体流程图;

- [0055] 图2为本发明中传感器特征变量相关性分析结果图；  
 [0056] 图3为本发明中采用ISOMAP算法进行特征融合流程图；  
 [0057] 图4为本发明中深度残差网络ResNet50整体结构图；  
 [0058] 图5为本发明中深度残差网络ResNet50预测过程流程图；  
 [0059] 图6为本发明预测结果图。

### 具体实施方式

[0060] 下面结合附图和具体实施方式对本发明进行详细说明。

[0061] 本发明一种基于特征融合的ResNet50网络关键设备剩余寿命预测方法,流程图如图1所示,具体按照以下步骤实施:

[0062] 步骤1、保留影响系统设备运行时长的高关联度特征变量:对系统设备中各传感器采集的数据信息进行相关性分析,过滤与寿命关联程度较低的特征变量,确定影响系统寿命的高关联度特征变量;

[0063] 结合图2~图5,步骤1具体如下:

[0064] 步骤1.1、对系统设备中传感器采集的数据信息进行编号, $n$ 表示为传感器的序号, $x_n$ 为第 $n$ 个传感器的监测数据信息,监测数据 $X$ 表示为 $X = \{x_1^i, x_2^i, \dots, x_n^i\}$ ,其中, $x_n^i$ 为系统中 $i$ 时刻第 $n$ 个传感器的监测数据信息, $i = 1, 2, \dots, t$ ,该系统的剩余寿命 $Y$ 表示为 $Y = \{y^i\}$ ,其中, $y^i$ 为系统对应 $i$ 时刻的剩余寿命;

[0065] 步骤1.2、利用相关性分析计算相关系数 $\rho_{x_n Y}$ ,

$$[0066] \quad \rho_{x_n Y} = \frac{Cov(x_n, Y)}{\sqrt{D(x_n)}\sqrt{D(Y)}} \quad (1)$$

[0067] 其中, $Cov(x_n, Y)$ 为监测数据信息 $x_n$ 和剩余寿命 $Y$ 之间的协方差, $\sqrt{D(x_n)}$ 和 $\sqrt{D(Y)}$ 分别为监测数据信息 $x_n$ 和剩余寿命 $Y$ 的标准差;

[0068] 步骤1.3、计算监测数据信息 $x_n$ 和剩余寿命 $Y$ 的Pearson相关系数 $\rho_{x_n Y}$ ,具体如下:

[0069] 相关系数 $\rho_{x_n Y}$ 范围:

$$\left\{ \begin{array}{l} 0.8 \leq \rho_{x_n Y} \leq 1, \text{ 极强相关} \\ 0.6 \leq \rho_{x_n Y} \leq 0.8, \text{ 强相关} \\ 0.4 \leq \rho_{x_n Y} \leq 0.6, \text{ 中等程度相关} \\ 0.2 \leq \rho_{x_n Y} \leq 0.4, \text{ 弱相关相关} \\ 0 \leq \rho_{x_n Y} \leq 0.2, \text{ 极弱相关或无相关} \end{array} \right. \quad (2)$$

[0070] 保留结果超过0.8以上的高关联度特征变量。

[0071] 步骤2、对所述步骤1得到的高关联度特征变量进行特征融合:利用ISOMAP算法融合步骤1中的高关联度特征变量,得到融合特征变量,有效的集成传感器信息;

[0072] 步骤2具体如下:

[0073] 步骤2.1、选取邻域,构造邻域图 $G$ :近邻参数设置为 $k$ ,将步骤1.3保留的高关联度特征变量构造样本集 $D = \{x_1, x_2, \dots, x_m\}$ , $m$ 是原始 $d$ 维空间的样本集 $D$ 中样本点的个数,在样

本集 $D = \{x_1, x_2, \dots, x_m\}$ 中任意选取某两个数据点 $x_h$ 与 $x_j$ ,其中, $h, j$ 是样本集 $D$ 中选取的两个数据点的编号, $h, j \in 1, 2, 3 \dots m$ ,第一个数据点 $x_h$ 与近邻参数 $k$ 间距离设为欧氏距离,另一个数据点 $x_j$ 是 $x_h$ 最近的近邻参数 $k$ 个点之一时,表示它们相近邻,邻域图 $G$ 有边,即邻域图 $G$ 构造完毕;

[0074] 步骤2.2、计算最短路径距离矩阵:若邻域图 $G$ 上两点 $x_h, x_j$ 存在边连接时,定义样本点 $x_h$ 与 $x_j$ 之间的最短路径为 $d_G(x_h, x_j) = d(x_h, x_j)$ ;否则 $d_G(x_h, x_j) = \infty$ ,其中, $d(x_h, x_j)$ 为数据点 $x_h$ 与 $x_j$ 的欧氏距离;

[0075] 对 $l \in 1, 2, 3 \dots m$ ,有:

$$[0076] \quad d_G(x_h, x_j) = \min \{d_G(x_h, x_j), d_G(x_h, x_l) + d_G(x_l, x_j)\} \quad (3)$$

[0077] 其中, $x_l$ 是样本集 $D$ 中新的样本点, $d_G(x_h, x_l)$ 表示样本点 $x_h$ 与 $x_l$ 之间的最短路径, $d_G(x_l, x_j)$ 表示样本点 $x_l$ 与 $x_j$ 之间的最短路径, $d_G(x_h, x_j)$ 表示样本点 $x_h$ 与 $x_j$ 之间的最短路径;

[0078] 基于此,即可确定最短路径距离矩阵为 $D_G = [d_G^2(x_h, x_j)]_{h,j=1}^m$ ,其中, $m$ 是 $d$ 维原始空间的样本集 $D$ 中样本点的个数, $h, j, l$ 是样本集 $D$ 中选取的三个数据点的编号, $h, j, l \in 1, 2, 3 \dots m$ ;

[0079] 步骤2.3、通过对 $d$ 维原始空间降维,构造 $d'$ 维新样本空间,并且使得 $d'$ 维新样本空间与 $d$ 维原始空间中的距离保持不变,求取降维后样本的内积矩阵 $B$ :令 $B = Z^T Z \in R^{m \times m}$ ,其中, $d$ 是原始空间的维数, $d'$ 是新样本空间的维数, $Z$ 为 $d$ 维原始空间嵌入 $d'$ 维新样本空间的矩阵表示, $R$ 为实数集;

[0080] 构造新样本空间后, $d' < d$ ,且任意两个样本在 $d'$ 维新样本空间中的欧氏距离等于 $d$ 维原始空间中的距离,即:

$$[0081] \quad \|z_h - z_j\| = \text{dist}_{h_j} \quad (4)$$

[0082] 其中, $z_h, z_j$ 分别表示样本点 $x_h, x_j$ 在 $d'$ 维新样本空间中的欧氏距离, $\text{dist}_{h_j}$ 表示样本点 $x_h$ 和 $x_j$ 在 $d$ 维原始空间中的距离;

[0083] 将式(4)展开并对等号两端求平方得:

$$[0084] \quad \text{dist}_{h_j}^2 = \|z_h\|^2 + \|z_j\|^2 - 2z_h^T z_j \quad (5)$$

[0085]  $b_{hj} = z_h^T z_j$ , $b_{hh}$ 与 $b_{jj}$ 以此类推,则有:

$$[0086] \quad \text{dist}_{h_j}^2 = b_{hh} + b_{jj} - 2b_{hj} \quad (6)$$

$$[0087] \quad b_{hj} = -\frac{1}{2}(\text{dist}_{h_j}^2 - \text{dist}_{h \cdot}^2 - \text{dist}_{\cdot j}^2 + \text{dist}_{\cdot \cdot}^2) \quad (7)$$

[0088] 其中, $b_{hj}$ 为内积矩阵 $B$ 中第 $h$ 行 $j$ 列的元素, $b_{hh}$ 与 $b_{jj}$ 以此类推, $\text{dist}_{h \cdot}$ 表示样本点 $x_h$ 和 $x_j$ 在 $d$ 维原始空间的距离, $\text{dist}_{\cdot j}$ 及 $\text{dist}_{\cdot \cdot}$ 以此类推;

[0089] 通过求得 $b_{hj}, b_{hh}, b_{jj}$ 等内积矩阵 $B$ 中的元素可得内积矩阵 $B$ ;

[0090] 步骤2.4、对最短路径距离矩阵 $D_G$ 构造 $d$ 维嵌入,最终得到样本通过 $d$ 维原始空间嵌入 $d'$ 维新样本空间的矩阵表示 $Z \in R^{d' \times m}$ ;

[0091] 由步骤2.3求得的内积矩阵 $B$ 通过特征分解获得特征值矩阵和特征向量矩阵,即:

$$[0092] \quad B = V \Lambda V^T \quad (8)$$

[0093] 其中, $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_d)$ 为特征值构成的对角矩阵, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d, \lambda_1,$

$\lambda_2, \dots, \lambda_d$ 为分解获得的特征值,  $V$ 为对应的特征向量矩阵。

[0094] 则  $d$  维原始空间嵌入  $d'$  维新样本空间的矩阵表示  $Z$  的计算公式为:

$Z = \Lambda_*^{-\frac{1}{2}} V_*^T \in R^{d' \times m}$ , 计算  $Z$  的结果后可得到矩阵表示为:  $Z = \{z_1^i, z_2^i, \dots, z_m^i\}$ 。此时的结果

$Z = \{z_1^i, z_2^i, \dots, z_m^i\}$  便是融合后的特征变量;

[0095] 其中, 有  $d^*$  个非零特征值,  $\Lambda_* = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_{d^*})$  为特征值构成的对角矩阵, 特征值  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{d^*}$ ,  $V_*$  为对应的特征向量矩阵;  $z_m^i$  为  $d'$  维新样本空间中  $i$  时刻第  $m'$  个样本点的融合特征变量,  $m'$  是  $d'$  维新样本空间中样本点的个数。

[0096] 步骤3、构建数据集构造策略: 针对步骤2中得到的融合特征变量, 和系统对应时刻的剩余寿命构成剩余寿命预测总样本集, 并将其分为训练集与测试集;

[0097] 步骤3具体如下:

[0098] 步骤3.1、构造样本集: 将步骤2中得到的融合后的特征变量  $Z = \{z_1^i, z_2^i, \dots, z_m^i\}$  和系统剩余寿命  $Y = \{y^i\}$  重构为剩余寿命预测样本集  $\{y^i, z_1^i, z_2^i, \dots, z_m^i\}$ ,  $y^i, z_1^i, z_2^i, \dots, z_m^i$  分别为重构的剩余寿命预测样本集中的特征变量, 并按照7:3的比例划分为训练集和验证集, 其中,  $y^i$  为系统对应  $i$  时刻的剩余寿命;

[0099] 步骤3.2、构造子训练集和子测试集: 将步骤3.1中划分好的训练集再次按照7:3的比例划分为子训练集和子测试集;

[0100] 步骤3.3、构造总训练集和总测试集: 将步骤3.2得到的子训练集中的特征变量按照列堆叠的形式合并为总训练集, 同时, 对应步骤3.2中子训练集的合并顺序, 将子测试集中的特征变量以列堆叠的形式合并为总测试集, 最终形成由总训练集、总测试集和步骤3.1得到的验证集构成的剩余寿命预测总样本集。

[0101] 步骤4: 建立预测模型并预测剩余寿命: 将步骤3中得到的剩余寿命预测总样本集的训练集作为深度残差网络Resnet50的输入训练该预测网络, 利用训练好的网络对测试样本进行预测, 得到系统剩余寿命预测结果, 及时提示工作人员对设备整体进行预防性维护。

[0102] 步骤4具体如下:

[0103] 步骤4.1、构建50层深度残差网络ResNet50: 深度残差网络ResNet50由3部分组成, 分别为卷积池化部分、4个残差块部分、池化展平部分, 残差块部分有两个基本的结构, 分别为恒等残差块和卷积残差块; 整体结构如图4所示。两种残差块的不同点在于捷径连接处有无卷积层, 作用是解决维度不匹配的问题。

[0104] 步骤4.2、特征提取: 将步骤3中得到的剩余寿命预测总样本集的训练集作为深度残差网络Resnet50的输入, 采用一维卷积核对训练集进行特征提取, 并对提取的卷积特征进行最大值池化, 以获得池化特征;

[0105] 步骤4.3、残差块的特征提取: 将池化特征作为残差块的输入, 深度残差网络Resnet50的残差块由以下四部分组成: 一个卷积残差块和两个恒等残差块、一个卷积残差块和三个恒等残差块、一个卷积残差块和五个恒等残差块、一个卷积残差块和两个恒等残差块, 上述四个残差块按照顺序连接组成为残差网络核心部分, 随着网络层数的加深, 经由

残差块特有的捷径连接,将残差结果逼近于0,减少输入的损失;

[0106] 步骤4.4、建立预测模型:经平均池化层整合残差块的输出,再通过展平层获得预测模型;

[0107] 步骤4.5、得到剩余寿命预测结果:将测试集输入预测模型中,得到剩余寿命预测结果,具体的寿命预测流程见图5所示。每进行一次预测得到输出的预测结果,将该预测结果和系统采集的剩余寿命真实数据之间的误差反向传播给深度残差网络Resnet50,并对网络中的各参数进行调优,当网络的误差小于0.05时,说明网络收敛,利用训练好的网络对测试样本进行预测,最终得到系统剩余寿命预测结果,实现系统的剩余寿命的准确预测。

[0108] 实施例

[0109] 本次实验以涡轮发动机系统为研究对象,共收集了21个传感器在四种故障模式下的样本数据,以一种故障模式的数据集为例(100台发动机共20631个样本数据),随机选取第17台发动机数据(共276个寿命周期数据)。经过相关性分析与ISOMAP特征融合后,保留相关系数 $\rho_{x,y}$ 超过0.8的4个特征变量。将前200个寿命周期数据作为总训练集,将后76个寿命周期数据作为总测试集。基于以上数据,采用本发明的方法进行多变量剩余寿命预测,为了更加清晰地描述实验结果,将仿真结果可视化,结果见图6。通过观察图6可知,所提模型的预测结果与实际数据误差较小,效果较好。

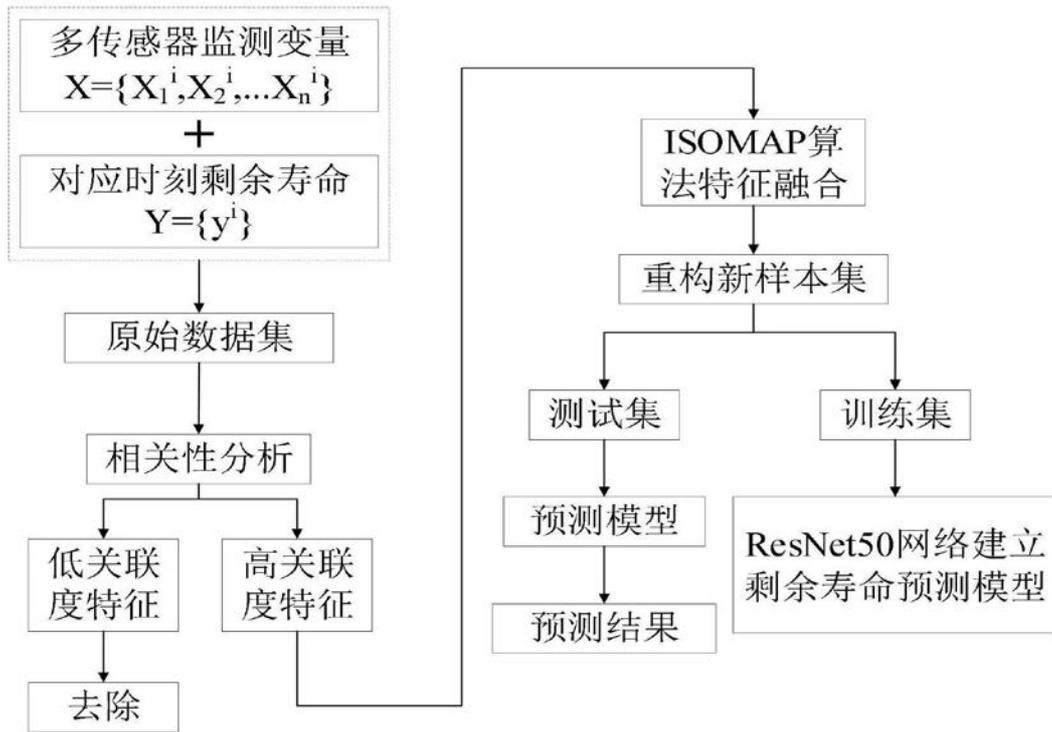


图1

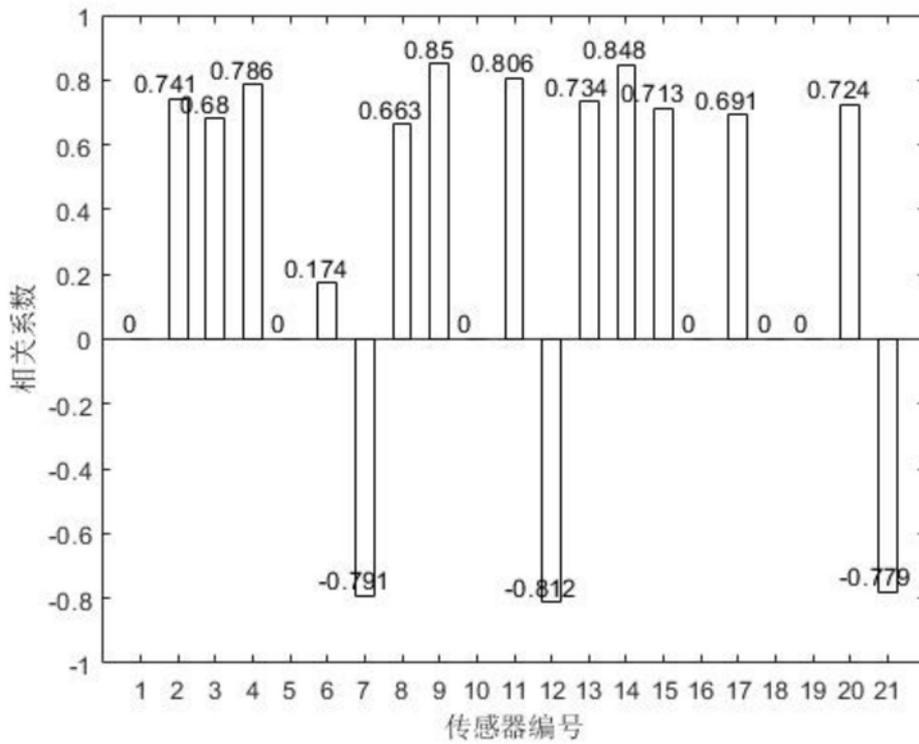


图2

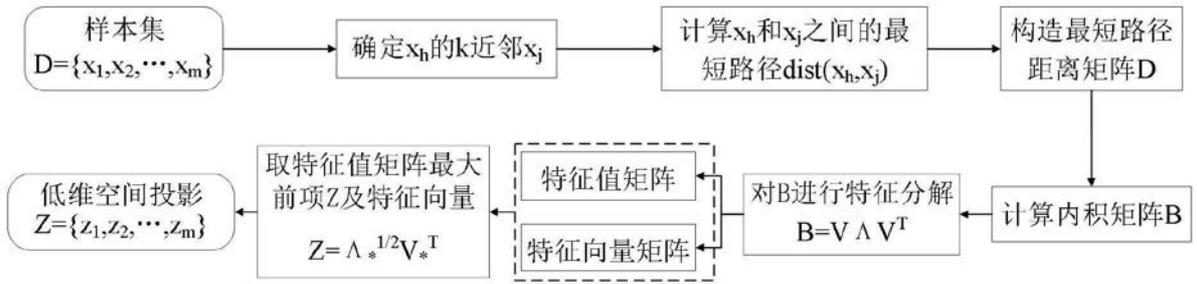


图3

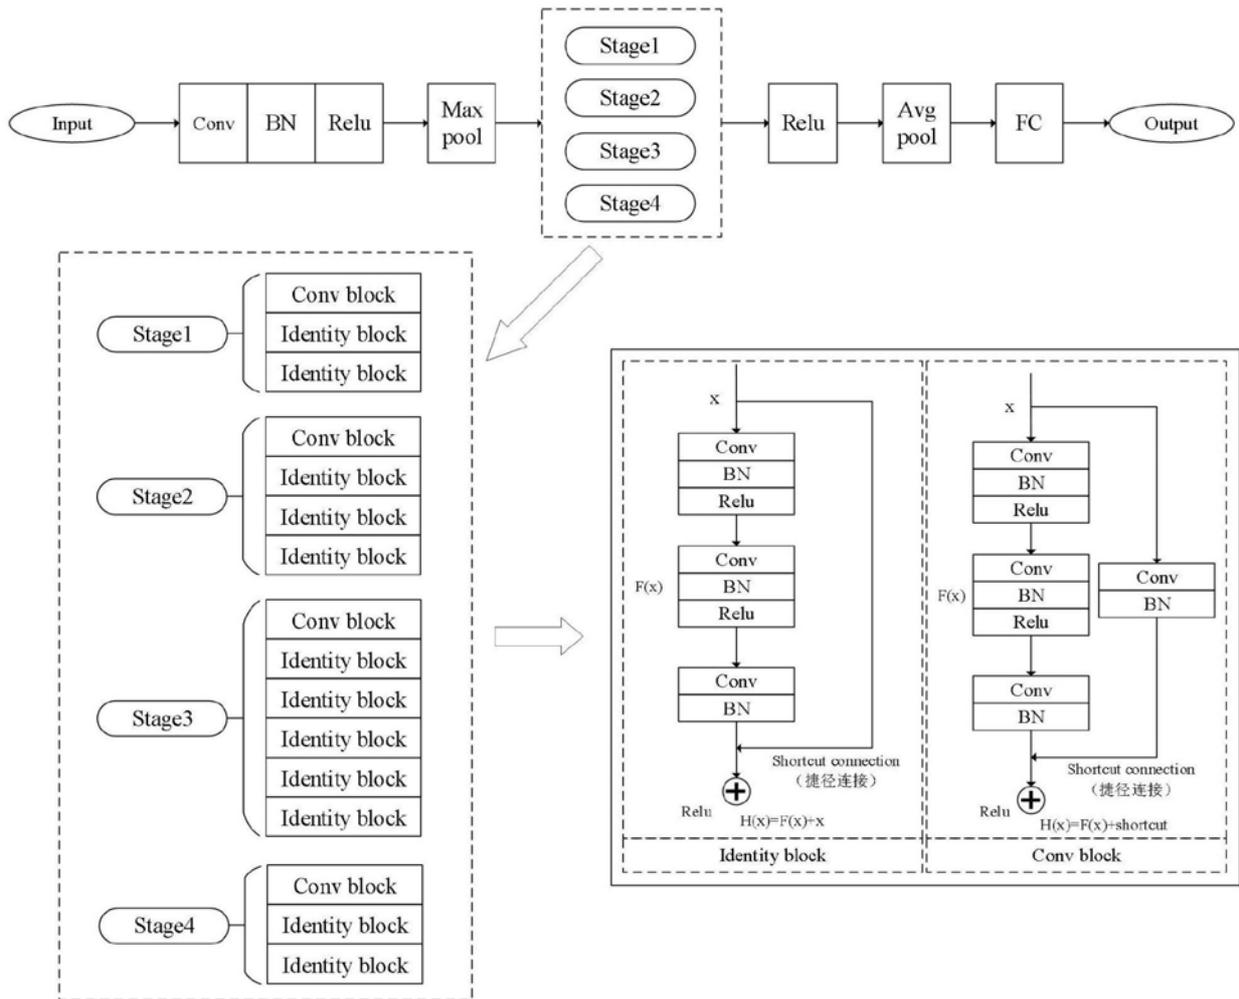


图4



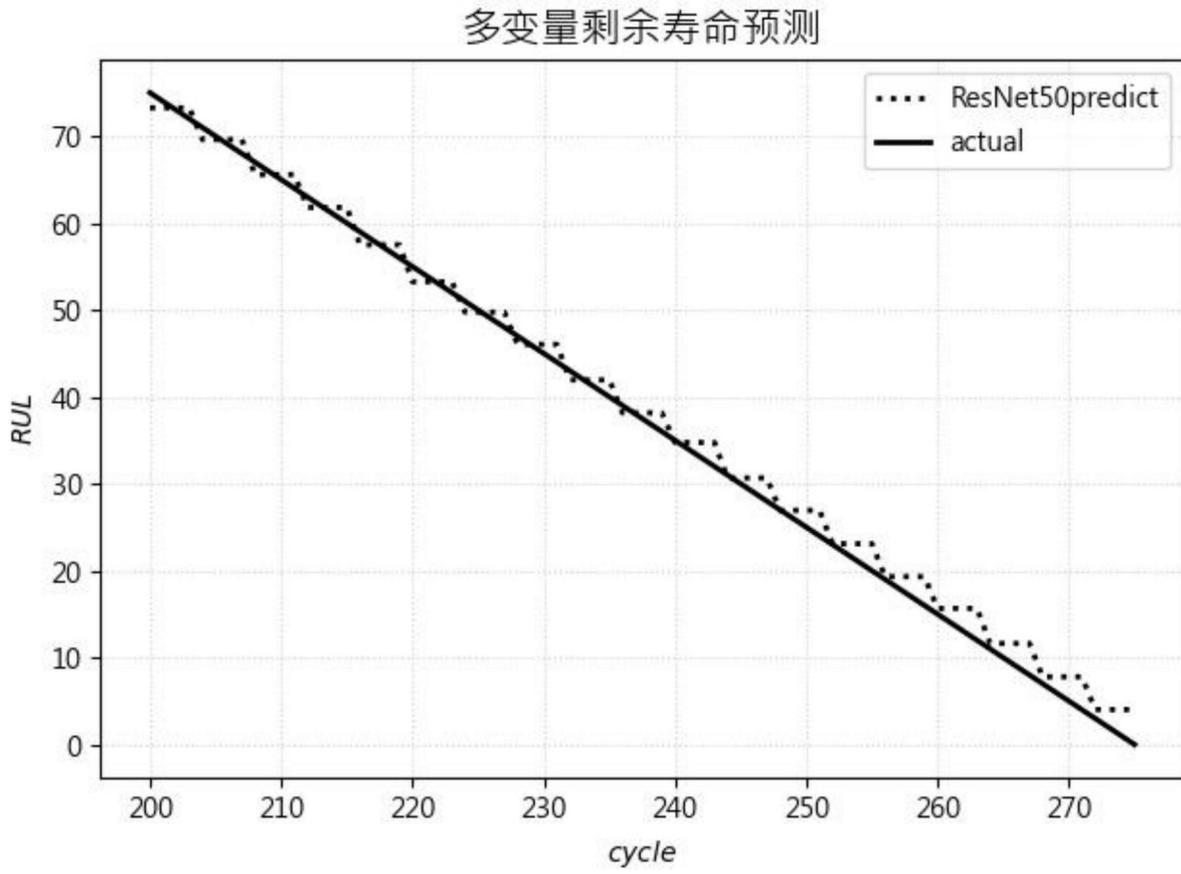


图6