



(12) 发明专利

(10) 授权公告号 CN 112131760 B

(45) 授权公告日 2022. 08. 23

(21) 申请号 202011206202.3

(51) Int. Cl.

(22) 申请日 2020.11.02

G06F 30/20 (2020.01)

(65) 同一申请的已公布的文献号

G06N 3/04 (2006.01)

申请公布号 CN 112131760 A

G06N 3/08 (2006.01)

G06F 119/04 (2020.01)

(43) 申请公布日 2020.12.25

审查员 沈晴

(66) 本国优先权数据

201911064237.5 2019.11.04 CN

(73) 专利权人 中国人民解放军国防科技大学

地址 410073 湖南省长沙市开福区德雅路
109号

(72) 发明人 牛彩云 葛冰峰 姜江 叶燕清

陈英武 郭波

(74) 专利代理机构 国防科技大学专利服务中心

43202

专利代理师 王文惠

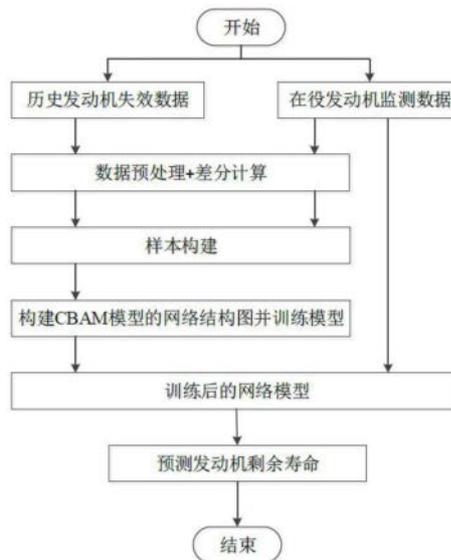
权利要求书3页 说明书10页 附图7页

(54) 发明名称

基于CBAM模型的航空发动机剩余寿命预测方法

(57) 摘要

本发明提供基于CBAM模型的航空发动机剩余寿命预测方法,属于故障预测与健康管理(Prognostics and Health Management,PHM)领域。先对发动机的原始监测变量进行一阶差分计算得到(新的)差分特征,并和原始特征一起来表征其退化。接着,提出一个嵌入CBAM模块的并行CNN网络的剩余寿命预测模型,对由常规卷积计算获得的特征图进一步从通道注意力和空间注意力两个维度来凸显有价值特征信息并弱化无用或噪声信息。按照监测变量和剩余寿命间的映射关系构建样本的输入输出,并用于训练模型。最后,对于在役航空发动机,构建出测试样本,并输入到训练好的预测模型中,得到在役航空发动机的剩余寿命预测值。本发明所提出的方法计算过程简单有效,且预测精度很高。



1. 基于CBAM模型的航空发动机剩余寿命预测方法,其特征在于,包括:

步骤一,获取历史航空发动机失效数据,形成训练集 $X_{L \times V}$,其中, $L=L_1+L_2+\dots+L_N$ 表示N个航空发动机样本总的运行轨迹长度,N表示航空发动机样本个数, L_n 表示第n个航空发动机样本的监测轨迹长度, $n=1,2,\dots,N$,V表示航空发动机中传感器的个数;

步骤二,对V个监测变量进行特征选择,得到F个监测变量,对应的训练集降维为 $X_{L \times F}$;对F个监测变量按照“最小-最大”的方法进行标准化处理,计算公式如下:

$$x_{i,j}^{(n)} = \frac{2(x_{i,j}^{(n),original} - x_{\min}^j)}{x_{\max}^j - x_{\min}^j} - 1, n=1,2,\dots,N, i=1,2,\dots,L_n, j=1,2,\dots,F.$$

其中, $x_{i,j}^{(n),original} \in X_{L \times F}$ 表示第n个发动机信号j的第i个时刻的原始数据, $x_{i,j}^{(n)}$ 是 $x_{i,j}^{(n),original}$ 标准化后的值,而 x_{\max}^j 和 x_{\min}^j 分别表示信号j的最大值和最小值;

然后,将标准化后的变量做差分运算生成新的变量,和原始特征共同组成航空发动机性能退化的数据矩阵 $X_{L \times 2F}$,且d阶差分运算的计算公式如下:

$$x_{i,j+F}^{(n)} = x_{i,j}^{(n)} - x_{i-d,j}^{(n)}, n=1,2,\dots,N, i=d+1,d+2,\dots,L_n, j=1,2,\dots,F.$$

步骤三,构建嵌入CBAM模块的并行CNN网络架构

首先,建立监测变量X和剩余寿命RUL之间的映射关系,表示如下:

$$f: X \rightarrow RUL, \text{ i.e., } RUL(t) = f(X_{t-s+1}, X_{t-s+2}, \dots, X_t);$$

其中,t表示时刻,s表示时间步, $X_i, i=t-s+1, \dots, t$ 表示时刻i所对应的监测数据,其长度为2F的向量形式;

在对航空发动机剩余寿命预测时,在基础CNN网络嵌入CBAM模块,通过对由常规卷积运算得到的特征图在通道注意力和空间注意力两个角度赋权重的方式来凸显有价值特征信息并弱化无用或噪声信息;由于所收集到的数据来自于多个不同传感器监测到的时序数据,考虑到不同特征的差异性,在CNN中的卷积运算采用一维卷积运算,以对同一特征上的数据才进行聚合操作,具体阐述如下:

确定输入的1维序列数据是 $x = [x_1, x_2, \dots, x_N]$,其中N表示序列长度,卷积层中的卷积运算定义为滤波器内核 $w, w \in \mathbb{R}^{F_L}$ 和串联向量 $\mathbf{X}_{i:i+F_L-1}$ 的乘法运算,表示如下

$$z_i = \varphi(w^T \mathbf{X}_{i:i+F_L-1} + b)$$

其中,输出 z_i 是由卷积核w学得特征, φ 表示非线性激活函数,b表示偏置, $*$ ^T表示转置操作, $\mathbf{X}_{i:i+F_L-1}$ 表示一个从第i个数据点开始的窗口长度为 F_L 的序列数据,由 \oplus 表示的如下数据连接操作:

$$\mathbf{X}_{i:i+F_L-1} = x_i \oplus x_{i+1} \oplus \dots \oplus x_{i+F_L-1}$$

将经第j个卷积核操作后得到的特征图表示为:

$$\mathbf{z}_j = [z_1^j, z_2^j, \dots, z_{N-F_L+1}^j].$$

其中, $z_i^j, i=1,2,\dots,N-F_L+1$ 表示第j个卷积核对序列 $\mathbf{X}_{i:i+F_L-1}$ 进行非线性操作 φ

后的向量形式的输出；

在基础CNN后面接上CBAM模块,包括通道注意力和空间注意力两个维度;对于一个中间层的特征图 $F \in \mathbb{R}^{H \times W \times C}$,CBAM将顺序得到1维的通道注意力图 $M_c \in \mathbb{R}^{1 \times 1 \times C}$ 和2维的空间注意力图 $M_s \in \mathbb{R}^{H \times W \times 1}$,整个过程如下所示:

$$F' = M_c(F) \otimes F$$

$$F'' = M_s(F') \otimes F'$$

其中, \otimes 为点乘,首先将通道注意力图与输入的特征图相乘得到 F' ,接着计算 F' 空间注意力图,并将两者相乘得到最终的输出 F'' ;

具体地,通道注意力模块的操作为:首先,对特征图在空间维度上分别使用平均池化 AvgPool 和最大池化 MaxPool 进行压缩;接着,将得到的两个不同的空间描述输入到一个共享多层感知机网络 MLP;最后,对由 MLP 得到的结果作和,并进行非线性激活,得到通道注意力图 M_c ;

$$\begin{aligned} M_c(F) &= \sigma \left(MLP \left(AvgPool(F) \right) + MLP \left(MaxPool(F) \right) \right) \\ &= \sigma \left(W_1 \left(W_0 \left(F_{avg}^c \right) \right) + W_1 \left(W_0 \left(F_{max}^c \right) \right) \right) \end{aligned}$$

其中, $W_0 \in \mathbb{R}^{C/r \times C}$, $W_1 \in \mathbb{R}^{C \times C/r}$, r 表示减少率, W_0 后面接 ReLU 函数; F_{avg}^c 、 F_{max}^c 表示对特征图 F 在空间维度上进行平均池化、最大池化的结果; σ 表示 sigmoid 激活函数; M_c 表示最终得到的通道注意力图;

空间注意力模块的操作为:对特征图在通道维度上分别进行平均池化 AvgPool 和最大池化 MaxPool 得到两个不同的特征描述 F_{avg}^s 和 F_{max}^s ;接着,将这两个特征合并起来并进行卷积运算 f^{conv} ;最后,对卷积运算的结果进行非线性激活,得到空间注意力图 M_s ;

$$\begin{aligned} M_s(F) &= \sigma \left(f^{conv} \left(\left[AvgPool(F); MaxPool(F) \right] \right) \right) \\ &= \sigma \left(f^{conv} \left(\left[F_{avg}^s; F_{max}^s \right] \right) \right) \end{aligned}$$

其中, $F_{avg}^s \in \mathbb{R}^{H \times W \times 1}$ 、 $F_{max}^s \in \mathbb{R}^{H \times W \times 1}$ 表示对特征图 F 在通道维度上进行平均池化、最大池化的结果; f^{conv} 表示卷积操作; σ 表示 sigmoid 激活函数; M_s 表示最终得到的空间注意力图;

构造样本的输入和输出,对 $X_{L \times 2F}$ 中每个发动机的退化轨迹数据分别采用窗口滑动法构建出训练样本的输入,且其对应输出的标签即剩余寿命 RUL 根据分阶线性函数进行修正,最终将得到成对的样本的输入和输出,其中窗口滑动法描述如下:

对于 $X_{L \times 2F}$ 中第 n 个发动机的退化轨迹数据 $X^{(n)} = \left(x_{ij}^{(n)} \right)_{L_n \times 2F}$, 表示为如下的二维矩阵形式

$$X^{(n)} = \begin{bmatrix} x_{1,1}^{(n)} & x_{1,2}^{(n)} & \cdots & x_{1,2F}^{(n)} \\ x_{2,1}^{(n)} & x_{2,2}^{(n)} & \cdots & x_{2,2F}^{(n)} \\ \vdots & \vdots & \ddots & \vdots \\ x_{L_n,1}^{(n)} & x_{L_n,2}^{(n)} & \cdots & x_{L_n,2F}^{(n)} \end{bmatrix}$$

进一步,按照步长 $s=1$ 得到如下第 n 个发动机的第 k 个样本:

$$x_{k:k+N_t-1}^{(n)} = \begin{bmatrix} x_{k,1}^{(n)} & x_{k,2}^{(n)} & \cdots & x_{k,2F}^{(n)} \\ x_{k+1,1}^{(n)} & x_{k+1,2}^{(n)} & \cdots & x_{k+1,2F}^{(n)} \\ \vdots & \vdots & \ddots & \vdots \\ x_{k+N_t-1,1}^{(n)} & x_{k+N_t-1,2}^{(n)} & \cdots & x_{k+N_t-1,2F}^{(n)} \end{bmatrix}, k=1, 2, \dots, L_n - N_t + 1.$$

其中, N_t 表示所构建样本时间窗口的长度;

其中分阶线性函数表达式如下:

$$Label = \begin{cases} R_{early} & RUL \geq R_{early} \\ RUL & RUL < R_{early} \end{cases}.$$

其中,Label表示构建样本数据的标签,RUL表示获取到的历史航空发动机失效数据中的实际剩余寿命, R_{early} 表示根据情况而设置的阈值;

步骤四,对于待进行剩余寿命预测的在役航空发动机的监测数据,构建出测试样本的输入,形成测试集;将构建的测试集输入到训练好的航空发动机剩余寿命预测模型中,得到在役航空发动机的剩余寿命预测值。

2.如权利要求1所述的基于CBAM模型的航空发动机剩余寿命预测方法,其特征在于,所述步骤二中 d 取值为1,即进行一阶差分运算,通过一阶差分运算生成的新变量用来刻画系统退化的速度。

3.如权利要求1所述的基于CBAM模型的航空发动机剩余寿命预测方法,其特征在于,所述步骤三中 R_{early} 取值为125。

基于CBAM模型的航空发动机剩余寿命预测方法

技术领域

[0001] 本发明是涉及航空发动机剩余寿命(Remaining Useful Life,RUL)预测方法,特别是涉及由差分技术生成新的特征,嵌入同时考虑空间和通道注意力机制的CBAM(convolutional block attention module)模块的CNN(Convolutional Neural Network)网络,在此基础上所构建的集成CBAM模块的并行CNN模型用来预测航空发动机的剩余寿命,属于故障预测与健康管理(Prognostics and Health Management,PHM)领域。

背景技术

[0002] 作为飞行器的“心脏”,航空发动机的健康状况直接决定了飞行与旅客安全,但其长时间所处的高温、高压、极寒等极端工作环境,又不断挑战其性能状况。因此,如何对航空发动机进行健康管理,确保其可靠性和安全性一直是行业界的关注焦点,其中,剩余寿命预测是健康管理中最具挑战的核心关键技术。然而,作为高精密度技术器件,航空发动机具有错综复杂的内部结构、自身的耦合作用以及极端的外部环境,难以通过简单的单变量退化过程或精确的数学预测模型对发动机性能状态进行表征。

[0003] 随着传感器与存储技术的飞速发展,能够收集、记录并储存了航空发动机以及各部件的海量监控数据,为航空发动机的剩余寿命预测问题提供了一种新的解决途径。近年来,深度学习方法在数据驱动的剩余寿命预测中越来越受到重视。作为一种流行的深度学习,CNN已成功应用于图像识别等多个领域。为提高CNN的性能,除了对其深度、宽度和基数三个方面来改善网络结构外,注意力机制的引入是另一种提高其性能的实现方式。其中,SE(Squeeze-and-Excitation)模块是从通道注意力机制的角度来对不同卷积特征赋予不同的权重。CBAM模块是同时考虑了空间注意力机制和通道注意力机制的体系结构,除了对不同通道的特征赋予权重外,对同一特征图的不同区域也进行权重计算。

发明内容

[0004] 本发明要解决的技术问题在于:在对航空发动机进行剩余寿命预测时,差分特征通过对原始特征采用一阶差分计算得到的,可以在数据层面丰富退化信息;CNN模型具备从带有噪声的多维监测变量中提取到高质量的退化信息的优势。为进一步识别出强的退化特征并减弱无效特征或噪声的影响,本发明在CNN模型基础上引入注意力机制,即CBAM模块,通过对由常规卷积运算得到的特征图在通道注意力和空间注意力两个维度赋权重的方式来凸显有价值特征信息并弱化无用或噪声信息。因此,本发明提出基于CBAM模型的航空发动机剩余寿命预测方法。

[0005] 为实现本发明之目的,采用以下技术方案予以实现:

[0006] 基于CBAM模型的航空发动机剩余寿命预测方法,包括:

[0007] 步骤一,获取历史航空发动机失效数据,形成训练集 $X_{L \times V}$,其中, $L=L_1+L_2+\dots+L_N$ 表示N个航空发动机样本总的运行轨迹长度,且N表示航空发动机样本个数, L_n 表示第n个航空发动机样本的监测轨迹长度, $n=1,2,\dots,N$,V表示航空发动机中传感器的个数;

[0008] 步骤二,对V个监测变量进行特征选择,得到F个监测变量,原来的训练集降维为 $X_{L \times F}$ 。对F个监测变量按照“最小-最大”的方法进行标准化处理,计算公式如下:

$$[0009] \quad x_{i,j}^{(n)} = \frac{2(x_{i,j}^{(n),original} - x_{\min}^j)}{x_{\max}^j - x_{\min}^j} - 1, n=1, 2, \dots, N, i=1, 2, \dots, L_n, j=1, 2, \dots, F.$$

[0010] 其中, $x_{i,j}^{(n),original} \in X_{L \times F}$ 表示第n个发动机信号j的第i个时刻的原始数据, $x_{i,j}^{(n)}$ 是 $x_{i,j}^{(n),original}$ 标准化后的值,而 x_{\max}^j 和 x_{\min}^j 分别表示信号j的最大值和最小值;

[0011] 然后,将标准化后的变量做差分运算生成新的变量,和原始特征共同组成航空发动机性能退化的数据矩阵 $X_{L \times 2F}$,且d阶差分运算的计算公式如下:

$$[0012] \quad x_{i,j+d}^{(n)} = x_{i,j}^{(n)} - x_{i-d,j}^{(n)}, n=1, 2, \dots, N, i=d+1, d+2, \dots, L_n, j=1, 2, \dots, F.$$

[0013] 在本发明中,d默认取值为1,即进行一阶差分运算,通过一阶差分运算生成的新变量用来刻画系统退化的速度;

[0014] 步骤三,构建嵌入CBAM模块的并行CNN网络架构

[0015] 首先,建立监测变量X和剩余寿命RUL之间的映射关系,表示如下:

$$[0016] \quad f: X \rightarrow RUL \quad \text{i.e.,} \quad RUL(t) = f(X_{t-s+1}, X_{t-s+2}, \dots, X_t).$$

[0017] 其中,t表示时刻,s表示时间步, $X_i, i=t-s+1, \dots, t$ 表示时刻i所对应的监测数据,其长度为2F的向量形式;

[0018] 在对航空发动机剩余寿命预测时,在基础的CNN网络中嵌入CBAM模块,通过对由常规卷积运算得到的特征图在通道注意力和空间注意力两个角度赋权重的方式来凸显有价值特征信息并弱化无用或噪声信息。由于所收集到的数据来自于多个不同传感器监测到的时序数据,考虑到不同特征的差异性,在CNN中的卷积运算采用一维卷积运算,以对同一特征上的数据才进行聚合操作,具体阐述如下:

[0019] 确定输入的1维序列数据是 $x = [x_1, x_2, \dots, x_N]$,其中N表示序列长度,卷积层中的卷积运算定义为滤波器内核 w , $w \in \mathbb{R}^{F_L}$ 和串联向量 \mathbf{x}_{ii+F_L-1} 的乘法运算,表示如下

$$[0020] \quad z_i = \varphi(w^T \mathbf{x}_{ii+F_L-1} + b)$$

[0021] 其中,输出 z_i 是由卷积核 w 学得特征, φ 表示非线性激活函数,b表示偏置, $*$ ^T表示转置操作, \mathbf{x}_{ii+F_L-1} 表示一个从第i个数据点开始的窗口长度为 F_L 的序列数据,由 \oplus 表示的如下数据连接操作:

$$[0022] \quad \mathbf{x}_{ii+F_L-1} = x_i \oplus x_{i+1} \oplus \dots \oplus x_{i+F_L-1}$$

[0023] 将经第j个卷积核操作后得到的特征图表示为:

$$[0024] \quad \mathbf{z}_j = [z_1^j, z_2^j, \dots, z_{N-F_L+1}^j].$$

[0025] 其中, $z_i^j, i=1, 2, \dots, N-F_L+1$ 表示第j个卷积核对序列 \mathbf{x}_{ii+F_L-1} 进行非线性操作 φ 后的向量形式的输出;

[0026] 在基础CNN后面接上的CBAM模块,包括通道注意力和空间注意力两个维度。对于一

个中间层的特征图 $F \in \mathbb{R}^{H \times W \times C}$, CBAM将顺序得到1维的通道注意力图 $M_c \in \mathbb{R}^{1 \times 1 \times C}$ 和2维的空间注意力图 $M_s \in \mathbb{R}^{H \times W \times 1}$, 整个过程如下所示:

$$[0027] \quad F' = M_c(F) \otimes F$$

$$[0028] \quad F'' = M_s(F') \otimes F'$$

[0029] 其中, \otimes 为点乘, 首先将通道注意力图与输入的特征图相乘得到 F' , 接着计算 F' 空间注意力图, 并将两者相乘得到最终的输出 F'' 。

[0030] 具体地, 通道注意力模块的操作为: 首先, 对特征图在空间维度上分别使用平均池化 (AvgPool) 和最大池化 (MaxPool) 进行压缩; 接着, 将得到的两个不同的空间描述输入到一个多层感知机 (MLP) 构成的共享网络; 最后, 对由 MLP 得到的结果作和 (\oplus), 并进行非线性激活 (σ), 得到通道注意力图 M_c 。

$$[0031] \quad \begin{aligned} M_c(F) &= \sigma \left(MLP \left(AvgPool(F) \right) + MLP \left(MaxPool(F) \right) \right) \\ &= \sigma \left(W_1 \left(W_0 \left(F_{avg}^c \right) \right) + W_1 \left(W_0 \left(F_{max}^c \right) \right) \right) \end{aligned}$$

[0032] 其中, $W_0 \in \mathbb{R}^{C/r \times C}$, $W_1 \in \mathbb{R}^{C \times C/r}$, r 表示减少率, W_0 后面接 ReLU 函数; F_{avg}^c 、 F_{max}^c 表示对特征图 F 在空间维度上进行平均池化、最大池化的结果; σ 表示 sigmoid 激活函数; M_c 表示最终得到的通道注意力图。

[0033] 空间注意力模块的操作为: 对特征图在通道维度上分别进行平均池化 (AvgPool) 和最大池化 (MaxPool) 得到两个不同的特征描述 F_{avg}^s 和 F_{max}^s ; 接着, 将这两个特征合并起来并进行卷积运算 (f^{conv}); 最后, 对卷积运算的结果进行非线性激活 (σ), 得到空间注意力图 M_s 。

$$[0034] \quad \begin{aligned} M_s(F) &= \sigma \left(f^{conv} \left(\left[AvgPool(F); MaxPool(F) \right] \right) \right) \\ &= \sigma \left(f^{conv} \left(\left[F_{avg}^s; F_{max}^s \right] \right) \right) \end{aligned}$$

[0035] 其中, $F_{avg}^s \in \mathbb{R}^{H \times W \times 1}$ 、 $F_{max}^s \in \mathbb{R}^{H \times W \times 1}$ 表示对特征图 F 在通道维度上进行平均池化、最大池化的结果; f^{conv} 表示卷积操作; σ 表示 sigmoid 激活函数; M_s 表示最终得到的空间注意力图。

[0036] 构造样本的输入和输出, 对 $X_{L \times 2F}$ 中每个发动机的退化轨迹数据分别采用窗口滑动法构建出训练样本的输入, 且其对应输出的标签即剩余寿命 RUL 根据分阶线性函数进行修正, 最终将得到成对的样本的输入和输出, 其中窗口滑动法描述如下:

[0037] 对于 $X_{L \times 2F}$ 中第 n 个发动机的退化轨迹数据 $X^{(n)} = \left(x_{ij}^{(n)} \right)_{L_n \times 2F}$, 表示为如下的二维矩阵形式

$$[0038] \quad X^{(n)} = \begin{bmatrix} x_{1,1}^{(n)} & x_{1,2}^{(n)} & \cdots & x_{1,2F}^{(n)} \\ x_{2,1}^{(n)} & x_{2,2}^{(n)} & \cdots & x_{2,2F}^{(n)} \\ \vdots & \vdots & \ddots & \vdots \\ x_{L_n,1}^{(n)} & x_{L_n,2}^{(n)} & \cdots & x_{L_n,2F}^{(n)} \end{bmatrix}$$

[0039] 进一步,按照步长 $s=1$ 得到如下第 n 个发动机的第 k 个样本:

$$[0040] \quad x_{k:k+N_t-1}^{(n)} = \begin{bmatrix} x_{k,1}^{(n)} & x_{k,2}^{(n)} & \cdots & x_{k,2F}^{(n)} \\ x_{k+1,1}^{(n)} & x_{k+1,2}^{(n)} & \cdots & x_{k+1,2F}^{(n)} \\ \vdots & \vdots & \ddots & \vdots \\ x_{k+N_t-1,1}^{(n)} & x_{k+N_t-1,2}^{(n)} & \cdots & x_{k+N_t-1,2F}^{(n)} \end{bmatrix}, k=1, 2, \dots, L_n - N_t + 1.$$

[0041] 其中, N_t 表示所构建样本时间窗口的长度。

[0042] 其中分阶线性函数表达式如下:

$$[0043] \quad Label = \begin{cases} R_{early} & RUL \geq R_{early} \\ RUL & RUL < R_{early} \end{cases}.$$

[0044] 其中,Label表示构建样本数据的标签,RUL表示获取到的历史航空发动机失效数据中的实际剩余寿命, R_{early} 表示根据情况而设置的阈值,如在本发明中将其默认取值为125;

[0045] 步骤四,对于待进行剩余寿命预测的在役航空发动机的监测数据,构建出测试样本的输入,形成测试集。将构建的测试集输入到训练好的航空发动机剩余寿命预测模型中,得到在役航空发动机的剩余寿命预测值。

[0046] 本发明的优点在于:

[0047] 以航空发动机的剩余寿命RUL为预测目标,首先,建立了用以表征系统退化过程的特征变量与预测目标之间的映射关系,且进一步采用差分技术生成新的特征变量以便提供更多的退化信息;其次,通过在CNN网络中嵌入CBAM模块同时考虑了空间和通道两个维度上的注意力机制,既考虑不同通道特征的重要性,又考虑了同一通道不同区域的重要性。因此,在利用通道-空间注意力机制的思想下,对于原始特征和差分特征构建出嵌入CBAM的并行CNN网络模型来学习上述这一映射关系。

附图说明

[0048] 为了更清楚地说明本发明实施例中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来讲,在不付出创造性劳动的前提下,还可以根据这些附图获得其它的附图。

[0049] 图1为本发明一实施例中基于CBAM模型的航空发动机剩余寿命预测方法的流程图;

[0050] 图2为嵌入CBAM模块的并行CNN网络架构示意图;

- [0051] 图3为一维卷积运算示意图；
 [0052] 图4为CBAM模块的示意图；
 [0053] 图5为本发明一实施例中航空发动机结构和仿真模块逻辑关系图；
 [0054] 图6为本发明一实施例中航空发动其21个传感器信号散点图；
 [0055] 图7为基于CBAM模型的网络结构图；
 [0056] 图8为100个测试发动机按RUL排序后的预测结果对比图。

具体实施方式

[0057] 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,所描述的实施例仅仅是本发明一部分实施例,而不是全部的实施例。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劳动前提下所获得的所有其它实施例,均属于本发明保护的范围。

[0058] 参照图1,图1为本发明一实施例中基于CBAM模型的航空发动机剩余寿命预测方法的流程图,包括以下步骤:

[0059] 基于CBAM模型的航空发动机剩余寿命预测方法,包括:

[0060] 步骤一,获取历史航空发动机失效数据,形成训练数据 $X_{L \times V}$,其中, $L=L_1+L_2+\dots+L_N$ 表示N个航空发动机样本总的运行轨迹长度,且N表示航空发动机样本个数, L_n 表示第n个航空发动机样本的监测轨迹长度, $n=1,2,\dots,N$,V表示航空发动机中传感器的个数;

[0061] 步骤二,对V个监测变量进行特征选择,得到F个监测变量,原来的训练集降维为 $X_{L \times F}$ 。对F个监测变量按照“最小-最大”的方法进行标准化处理,计算公式如下:

$$[0062] \quad x_{i,j}^{(n)} = \frac{2(x_{i,j}^{(n),original} - x_{\min}^j)}{x_{\max}^j - x_{\min}^j} - 1, n=1,2,\dots,N, i=1,2,\dots,L_n, j=1,2,\dots,F.$$

[0063] 其中, $x_{i,j}^{(n),original} \in X_{L \times F}$ 表示第n个发动机信号j的第i个时刻的原始数据, $x_{i,j}^{(n)}$ 是 $x_{i,j}^{(n),original}$ 标准化后的值,而 x_{\max}^j 和 x_{\min}^j 分别表示信号j的最大值和最小值;

[0064] 然后,将标准化后的变量做差分运算生成新的变量,和原始特征共同组成发动机性能退化的数据矩阵形式 $X_{L \times 2F}$,且d阶差分运算的计算公式如下:

$$[0065] \quad x_{i,j+F}^{(n)} = x_{i,j}^{(n)} - x_{i-d,j}^{(n)}, n=1,2,\dots,N, i=d+1,d+2,\dots,L_n, j=1,2,\dots,F.$$

[0066] 在本发明中,d默认取值为1,即进行一阶差分运算,通过一阶差分运算生成的新变量用来刻画系统退化的速度;

[0067] 步骤三,构建嵌入CBAM模块的并行CNN网络架构

[0068] 首先,建立监测变量X和剩余寿命RUL之间的映射关系,表示如下:

$$[0069] \quad f: X \rightarrow RUL \quad \text{i.e.,} \quad RUL(t) = f(X_{t-s+1}, X_{t-s+2}, \dots, X_t).$$

[0070] 其中,t表示时刻,s表示时间步, $X_i, i=t-s+1, \dots, t$ 表示时刻i所对应的监测数据,其长度为2F的向量形式;

[0071] 在对航空发动机剩余寿命预测时,所提出的CBAM模型示意图如图2所示,在基础的CNN网络中嵌入CBAM模块,通过对由常规卷积运算得到的特征图在通道注意力和空间注意

力两个角度赋权重的方式来凸显有价值特征信息并弱化无用或噪声信息。由于所收集到的数据来自于多个不同传感器监测到的时序数据,考虑到不同特征的差异性,在CNN中的卷积运算采用图3中的一维卷积运算,以对同一特征上的数据才进行聚合操作,具体阐述如下:

[0072] 确定输入的1维序列数据是 $x = [x_1, x_2, \dots, x_N]$,其中 N 表示序列长度,卷积层中的卷积运算定义为滤波器内核 w , $w \in \mathbb{R}^{F_L}$ 和串联向量 $\mathbf{x}_{i:i+F_L-1}$ 的乘法运算,表示如下

$$[0073] \quad z_i = \varphi(\mathbf{w}^T \mathbf{x}_{i:i+F_L-1} + b)$$

[0074] 其中,输出 z_i 是由卷积核 w 学得特征, φ 表示非线性激活函数, b 表示偏置, $*$ ^T表示转置操作, $\mathbf{x}_{i:i+F_L-1}$ 表示一个从第 i 个数据点开始的窗口长度为 F_L 的序列数据,由 \oplus 表示的如下数据连接操作:

$$[0075] \quad \mathbf{x}_{i:i+F_L-1} = x_i \oplus x_{i+1} \oplus \dots \oplus x_{i+F_L-1}$$

[0076] 将经第 j 个卷积核操作后得到的特征图表示为:

$$[0077] \quad \mathbf{z}_j = [z_1^j, z_2^j, \dots, z_{N-F_L+1}^j].$$

[0078] 其中, $z_i^j, i=1, 2, \dots, N-F_L+1$ 表示第 j 个卷积核对序列 $\mathbf{x}_{i:i+F_L-1}$ 进行非线性操作 φ 后的向量形式的输出;

[0079] 在基础CNN后面接上的CBAM模块如图4所示,包括通道注意力和空间注意力两个维度。对于一个中间层的特征图 $F \in \mathbb{R}^{H \times W \times C}$,CBAM将顺序得到1维的通道注意力图 $M_c \in \mathbb{R}^{1 \times 1 \times C}$ 和2维的空间注意力图 $M_s \in \mathbb{R}^{H \times W \times 1}$,整个过程如下所示:

$$[0080] \quad F' = M_c(F) \otimes F$$

$$[0081] \quad F'' = M_s(F') \otimes F'$$

[0082] 其中, \otimes 为点乘,首先将通道注意力图与输入的特征图相乘得到 F' ,接着计算 F' 空间注意力图,并将两者相乘得到最终的输出 F'' 。

[0083] 具体地,通道注意力模块的操作为:首先,对特征图在空间维度上分别使用平均池化(AvgPool)和最大池化(MaxPool)进行压缩;接着,将得到的两个不同的空间描述输入到一个共享多层感知机网络(MLP);最后,对由MLP得到的结果作和(\oplus),并进行非线性激活(σ),得到通道注意力图 M_c 。

$$[0084] \quad \begin{aligned} M_c(F) &= \sigma\left(MLP\left(AvgPool(F)\right) + MLP\left(MaxPool(F)\right)\right) \\ &= \sigma\left(W_1\left(W_0\left(F_{avg}^c\right)\right) + W_1\left(W_0\left(F_{max}^c\right)\right)\right) \end{aligned}$$

[0085] 其中, $W_0 \in \mathbb{R}^{C/r \times C}$, $W_1 \in \mathbb{R}^{C \times C/r}$, r 表示减少率, W_0 后面接ReLU函数; F_{avg}^c 、 F_{max}^c 表示对特征图 F 在空间维度上进行平均池化、最大池化的结果; σ 表示sigmoid激活函数; M_c 表示最终得到的通道注意力图。

[0086] 空间注意力模块的操作为:对特征图在通道维度上分别进行平均池化(AvgPool)

和最大池化 (MaxPool) 得到两个不同的特征描述 F_{avg}^s 和 F_{max}^s ;接着,将这两个特征合并起来并进行卷积运算 (f^{conv});最后,对卷积运算的结果进行非线性激活 (σ),得到空间注意力图 M_s 。

$$\begin{aligned} [0087] \quad M_s(F) &= \sigma\left(f^{conv}\left(\left[AvgPool(F); MaxPool(F) \right]\right)\right) \\ &= \sigma\left(f^{conv}\left(\left[F_{avg}^s; F_{max}^s \right]\right)\right) \end{aligned}$$

[0088] 其中, $F_{avg}^s \in \mathbb{R}^{H \times W \times 1}$ 、 $F_{max}^s \in \mathbb{R}^{H \times W \times 1}$ 表示对特征图 F 在通道维度上进行平均池化、最大池化的结果; f^{conv} 表示卷积操作; σ 表示 sigmoid 激活函数; M_s 表示最终得到的空间注意力图。

[0089] 构造样本的输入和输出,对 $X_{L \times 2F}$ 中每个发动机的退化轨迹数据分别采用窗口滑动法构建出训练样本的输入,且其对应输出的标签即剩余寿命 RUL 根据分阶线性函数进行修正,最终将得到成对的样本的输入和输出,其中窗口滑动法描述如下:

[0090] 对于 $X_{L \times 2F}$ 中第 n 个发动机的退化轨迹数据 $X^{(n)} = \left(x_{ij}^{(n)}\right)_{L_n \times 2F}$, 表示为如下的二维矩阵形式

$$[0091] \quad X^{(n)} = \begin{bmatrix} x_{1,1}^{(n)} & x_{1,2}^{(n)} & \cdots & x_{1,2F}^{(n)} \\ x_{2,1}^{(n)} & x_{2,2}^{(n)} & \cdots & x_{2,2F}^{(n)} \\ \vdots & \vdots & \ddots & \vdots \\ x_{L_n,1}^{(n)} & x_{L_n,2}^{(n)} & \cdots & x_{L_n,2F}^{(n)} \end{bmatrix}$$

[0092] 进一步,按照步长 $s=1$ 得到如下第 n 个发动机的第 k 个样本:

$$[0093] \quad x_{k:k+N_t-1}^{(n)} = \begin{bmatrix} x_{k,1}^{(n)} & x_{k,2}^{(n)} & \cdots & x_{k,2F}^{(n)} \\ x_{k+1,1}^{(n)} & x_{k+1,2}^{(n)} & \cdots & x_{k+1,2F}^{(n)} \\ \vdots & \vdots & \ddots & \vdots \\ x_{k+N_t-1,1}^{(n)} & x_{k+N_t-1,2}^{(n)} & \cdots & x_{k+N_t-1,2F}^{(n)} \end{bmatrix}, k=1, 2, \dots, L_n - N_t + 1.$$

[0094] 其中, N_t 表示所构建样本时间窗口的长度。

[0095] 其中分阶线性函数表达式如下:

$$[0096] \quad Label = \begin{cases} R_{early} & RUL \geq R_{early} \\ RUL & RUL < R_{early} \end{cases}.$$

[0097] 其中, Label 表示构建样本数据的标签, RUL 表示获取到的历史航空发动机失效数据中的实际剩余寿命, R_{early} 表示根据情况而设置的阈值,如在本发明中将其默认取值为 125;

[0098] 步骤四,对于待进行剩余寿命预测的在役航空发动机的监测数据,构建出测试样本的输入,形成测试集。将构建的测试集输入到训练好的航空发动机剩余寿命预测模型中,

得到在役航空发动机的剩余寿命预测值。

[0099] 下面结合一具体应用实例对本发明的实现过程以及预测效果进行说明：

[0100] 本具体实施中,采用的是NASA提供关于航空发动机的CMAPSS仿真数据集。CMAPSS是美国NASA的格林研究中心研发了的一款模块化的航空推进系统仿真软件,旨在模拟出飞机由正常到故障的整个退化过程,为预测模型提供数据基础。仿真实验是在Matlab Simulink工具下创建的,仿真了具有90000磅推力的发动机模型,程序包括一个大气模型和电管理系统,涉及风扇、低压压缩机(LPC)、高压压缩机(HPC)、高压涡轮机(HPC)和低压涡轮机(LPT)五个部件模块。图5中显示了航空发动机仿真实验中的五个模块的逻辑结构关系。

[0101] 该开源数据一共包含四组仿真数据,本发明具体实施过程分别选取“train_FD001”和“test_FD001”分别作为训练集和测试集,其中,每个子数据集含有26列,即包括编号、运行周期、环境设置1、环境设置2、环境设置3以及21个监测指标,而21个监测数据用于输出仿真实验中发动机退化过程中的信号数据,所代表的具体含义描述如表1所示。

[0102] 表1. 发动机监测指标描述

变量	符号	描述
Sensor 1	T_2	扇片入口处总温度
Sensor 2	T_{24}	低压压缩机出口处总温度
Sensor 3	T_{30}	高压压缩机出口处总温度
Sensor 4	T_{50}	低压涡轮出口处总温度
Sensor 5	P_2	扇片入口处压力
[0103] Sensor 6	P_{15}	旁通管总压力
Sensor 7	P_{30}	高压压缩机出口处总温度
Sensor 8	N_f	风扇物理转速
Sensor 9	N_c	核心物理转速
Sensor 10	epr	发动机压比
Sensor 11	P_{s30}	高压压缩机出口处静态压力

	Sensor 12	ϕ	燃料流/ P_3 30
	Sensor 13	NR_f	修正的扇片速度
	Sensor 14	NR_c	修正的核心速度
	Sensor 15	BPR	涵道比
	Sensor 16	farB	(燃烧室) 燃料气体
[0104]	Sensor 17	htBleed	渗出焓
	Sensor 18	Nf_{dmd}	设定的扇片速度
	Sensor 19	PCNfR _{dmd}	设定的核心机换算转速
	Sensor 20	w_{31}	高压涡轮冷却剂流
	Sensor 21	w_{32}	低压冷却剂流

[0105] 步骤一,从第一组仿真数据集中的train_FD001.txt文件中可获取航空发动机失效数据 $X_{20631 \times 26}$,指的是从发动机某一开始时刻到最终故障的全过程数据。20631行是100台发动机运行周期的总时长,26列包括编号、运行周期、环境设置1、环境设置2、环境设置3以及21个监测指标。其中,21个监测指标的可视化结果如图6所示。

[0106] 步骤二,从图6中21个监测变量在整个寿命周期中的变化趋势将传感器数据大致分为两类:常值的和变化的(即递增或递减趋势的)。在对发动机退化过程的刻画上,常值的信号显然是不起作用的,故在后期模型的输入变量上将不予考虑。另外,Sensor 6同样被认为对刻画发动机退化现象是没有贡献的。因此,选取其中的14个指标作为RUL预测模型的原始输入特征,其编号分别为2、3、4、7、8、9、11、12、13、14、15、17、20和21。

[0107] 接着,对选择的14个监测变量按照“最小-最大”的方法进行标准化处理,计算公式如下:

$$[0108] \quad x_{i,j}^{(n)} = \frac{2(x_{i,j}^{(n),original} - x_{\min}^j)}{x_{\max}^j - x_{\min}^j} - 1, n = 1, 2, \dots, 100, i = 1, 2, \dots, L_n, j = 1, 2, \dots, 14.$$

[0109] 其中, $x_{i,j}^{(n),original} \in X_{20631 \times 14}$ 表示第n个发动机信号j的第i个时刻的原始数据, $x_{i,j}^{(n)}$ 是 $x_{i,j}^{(n),original}$ 标准化后的值,而 x_{\max}^j 和 x_{\min}^j 分别表示信号j的最大值和最小值;

[0110] 然后,将标准化后的变量做一阶差分运算生成新的变量,和原始特征共同组成发动机性能退化的数据矩阵形式 $X_{20631 \times 28}$,一阶差分运算的计算公式如下:

$$[0111] \quad x_{i,j+1}^{(n)} = x_{i,j}^{(n)} - x_{i-1,j}^{(n)}, n = 1, 2, \dots, 100, i = 2, 3, \dots, L_n, j = 1, 2, \dots, 14.$$

[0112] 步骤三,对于基于CBAM模型的网络结构图绘制如图7所示。将由训练集构建的样本输入到所述网络架构中,训练轮次epoch=200且损失函数 $\text{cost}=\text{RMSE}+\alpha \cdot \text{Score}$ ($\alpha=0.025$),得到训练好的航空发动机剩余寿命预测模型。其中,RMSE和Score的表达式如下所示:

$$[0113] \quad \text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n d_i^2}$$

$$[0114] \quad \text{Score} = \sum_{i=1}^n s_i, s_i = \begin{cases} e^{\frac{d_i}{13}} - 1 & d_i < 0 \\ e^{\frac{d_i}{10}} - 1 & d_i \geq 0 \end{cases}$$

[0115] 其中,n表示样本的个数, $d_i = \text{RUL}'_i - \text{RUL}_i$ 表示第i个样本预测值和真实值之间的误差。

[0116] 对于训练集中的每台发动机数据,按照时间窗方法构造出尺寸大小为 $N_t \times N_f$ 的样本输入,其中 $N_t=30, N_f=28$;采用分阶线性函数方法对真实的剩余寿命进行重置形成样本输出,假设在初始阶段具有恒定的RUL值 $R_{\text{early}}=125$ 。

[0117] 步骤四,对测试集test_FD001.txt中的数据经步骤二的数据预处理后,按照步骤三中的方法构建出预测模型的样本输入。将100台测试发动机的样本输入到训练好的航空发动机剩余寿命预测模型中,得到预测结果,如图8。

[0118] 综上,本发明建立了用以表征系统退化过程的特征变量与预测目标(RUL)之间的映射关系;根据差分技术来获得新生成的特征用以刻画系统退化的速度信息,在CNN网络中嵌入CBAM模块是通过对由常规卷积运算得到的特征图在通道注意力和空间注意力两个角度赋权重的方式来凸显有价值特征信息并弱化无用或噪声信息,既考虑不同通道特征的重要性,又考虑了同一通道不同退化特征的重要性,并用所构建网络模型来学习提出的映射关系。对原始监测数据进行预处理并构建出用于输入所提模型的样本,将所构建的样本输入到设置好的模型中训练得到最终的预测模型;最后将测试样本输入到训练好的模型中得到预测结果和预测性能指标。本发明通过上述步骤很好的解决了数据驱动的航空发动机剩余寿命预测问题,有助于建立起大数据和智能系统健康管理连接的桥梁。相比现有方法,本发明所提出的算法计算过程简单有效。通过上述具体实施方式可知,本发明所提出的算法预测精度很高。

[0119] 虽然本发明已以较佳实施例揭露如上,然其并非用以限定本发明,任何本领域普通技术人员,在不脱离本发明的精神和范围内,当可作各种更动与润饰,因此本发明的保护范围当视权利要求书界定的范围为准。

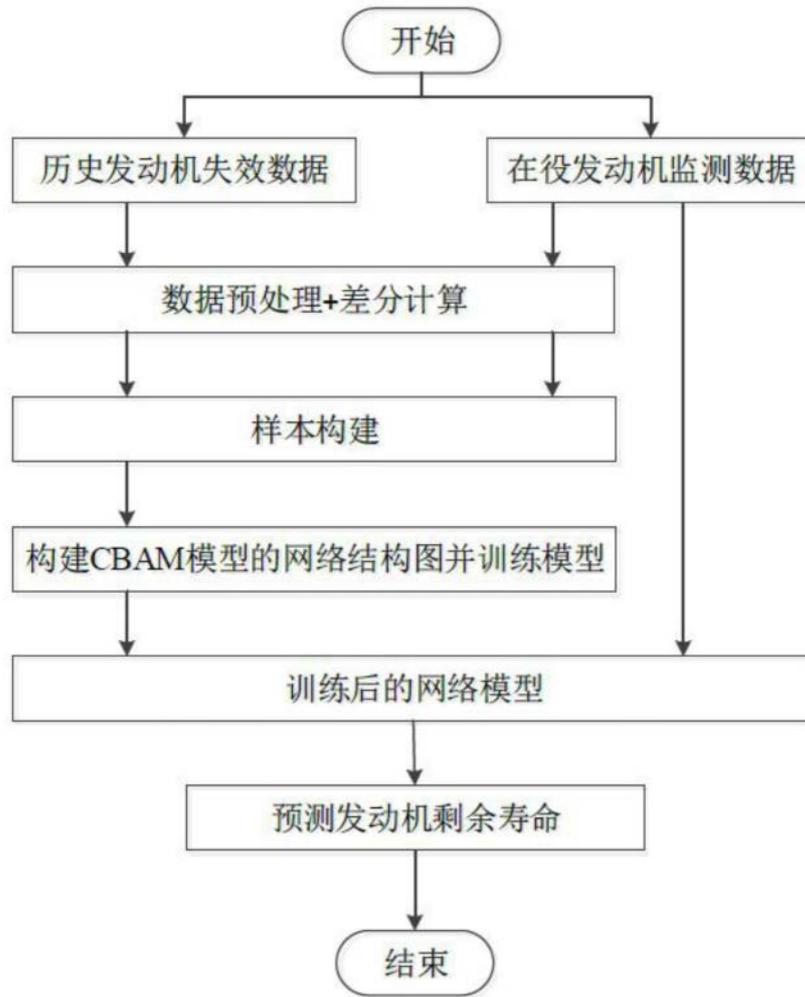


图1

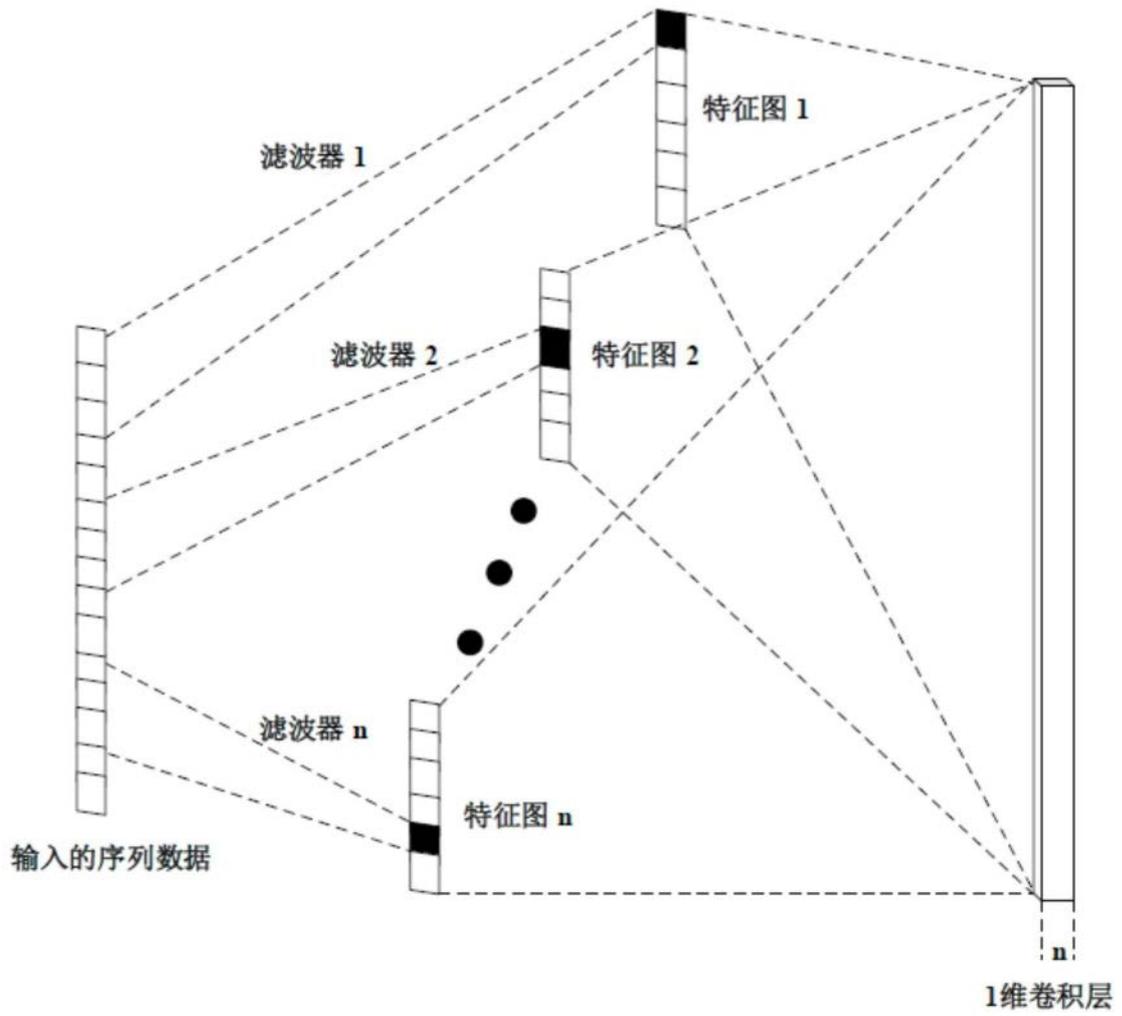


图3

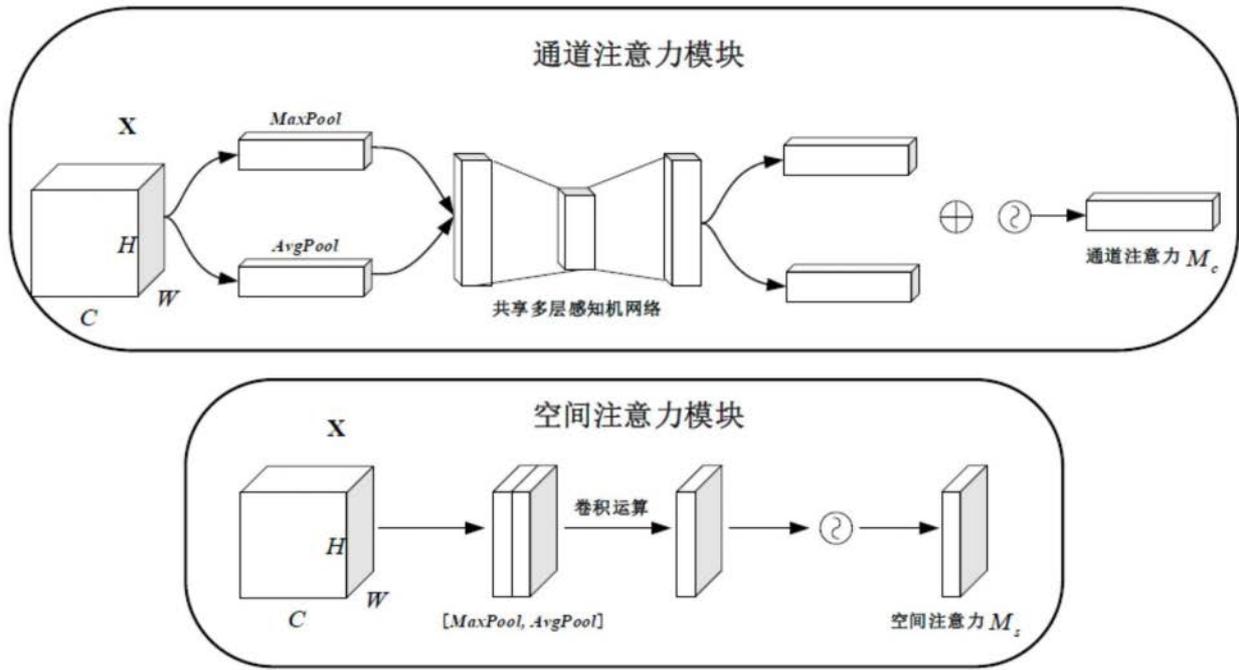


图4

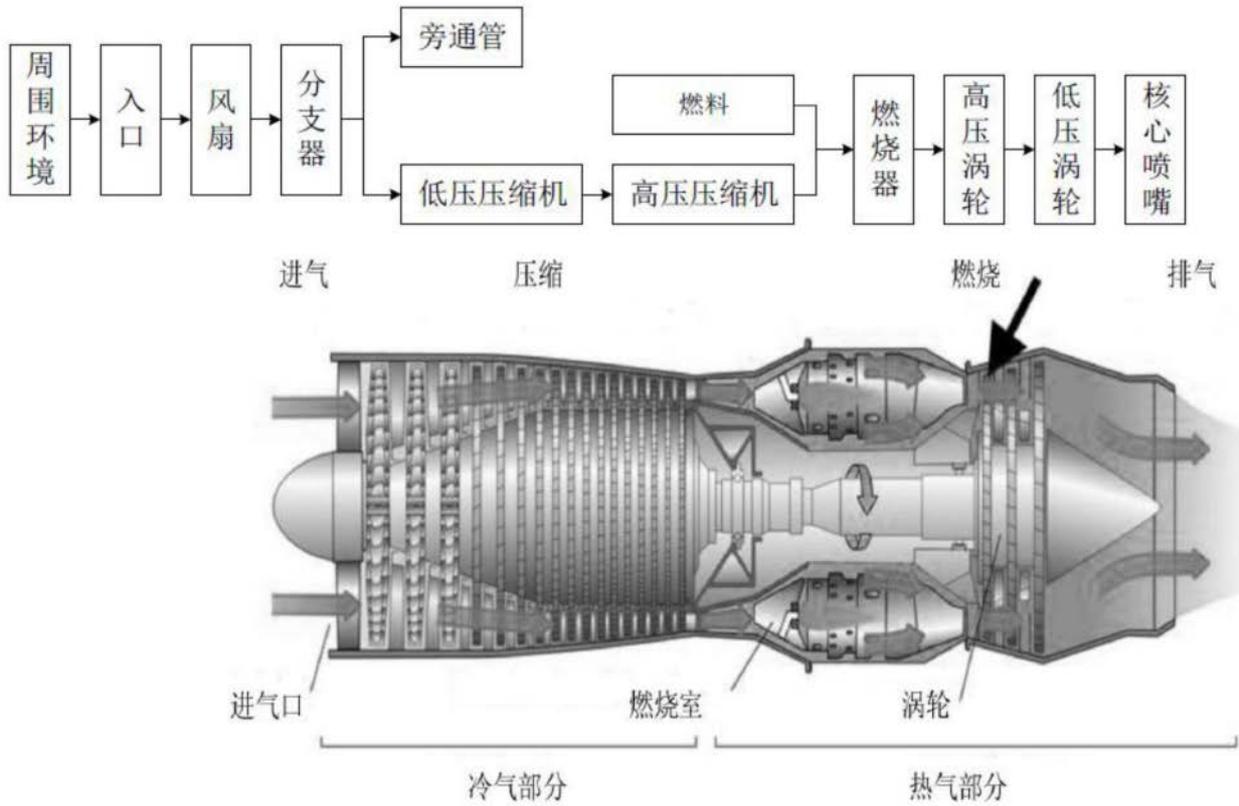


图5

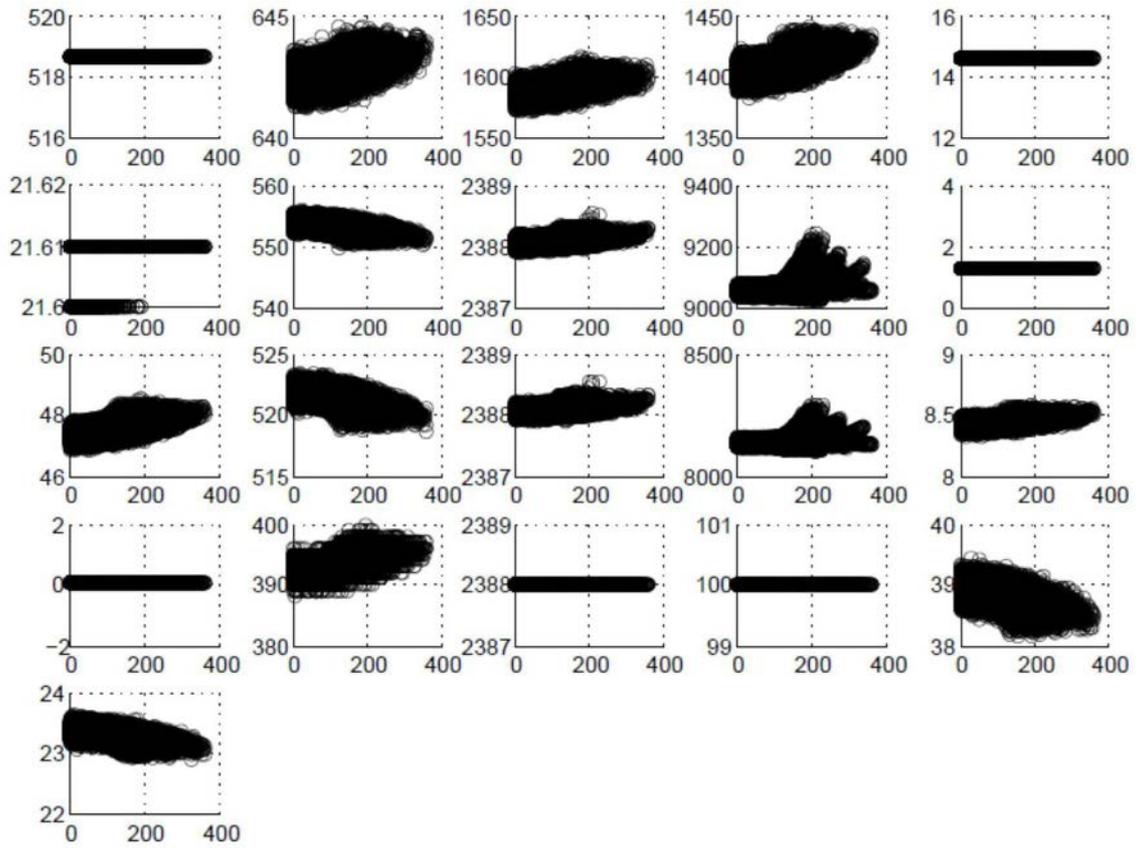


图6

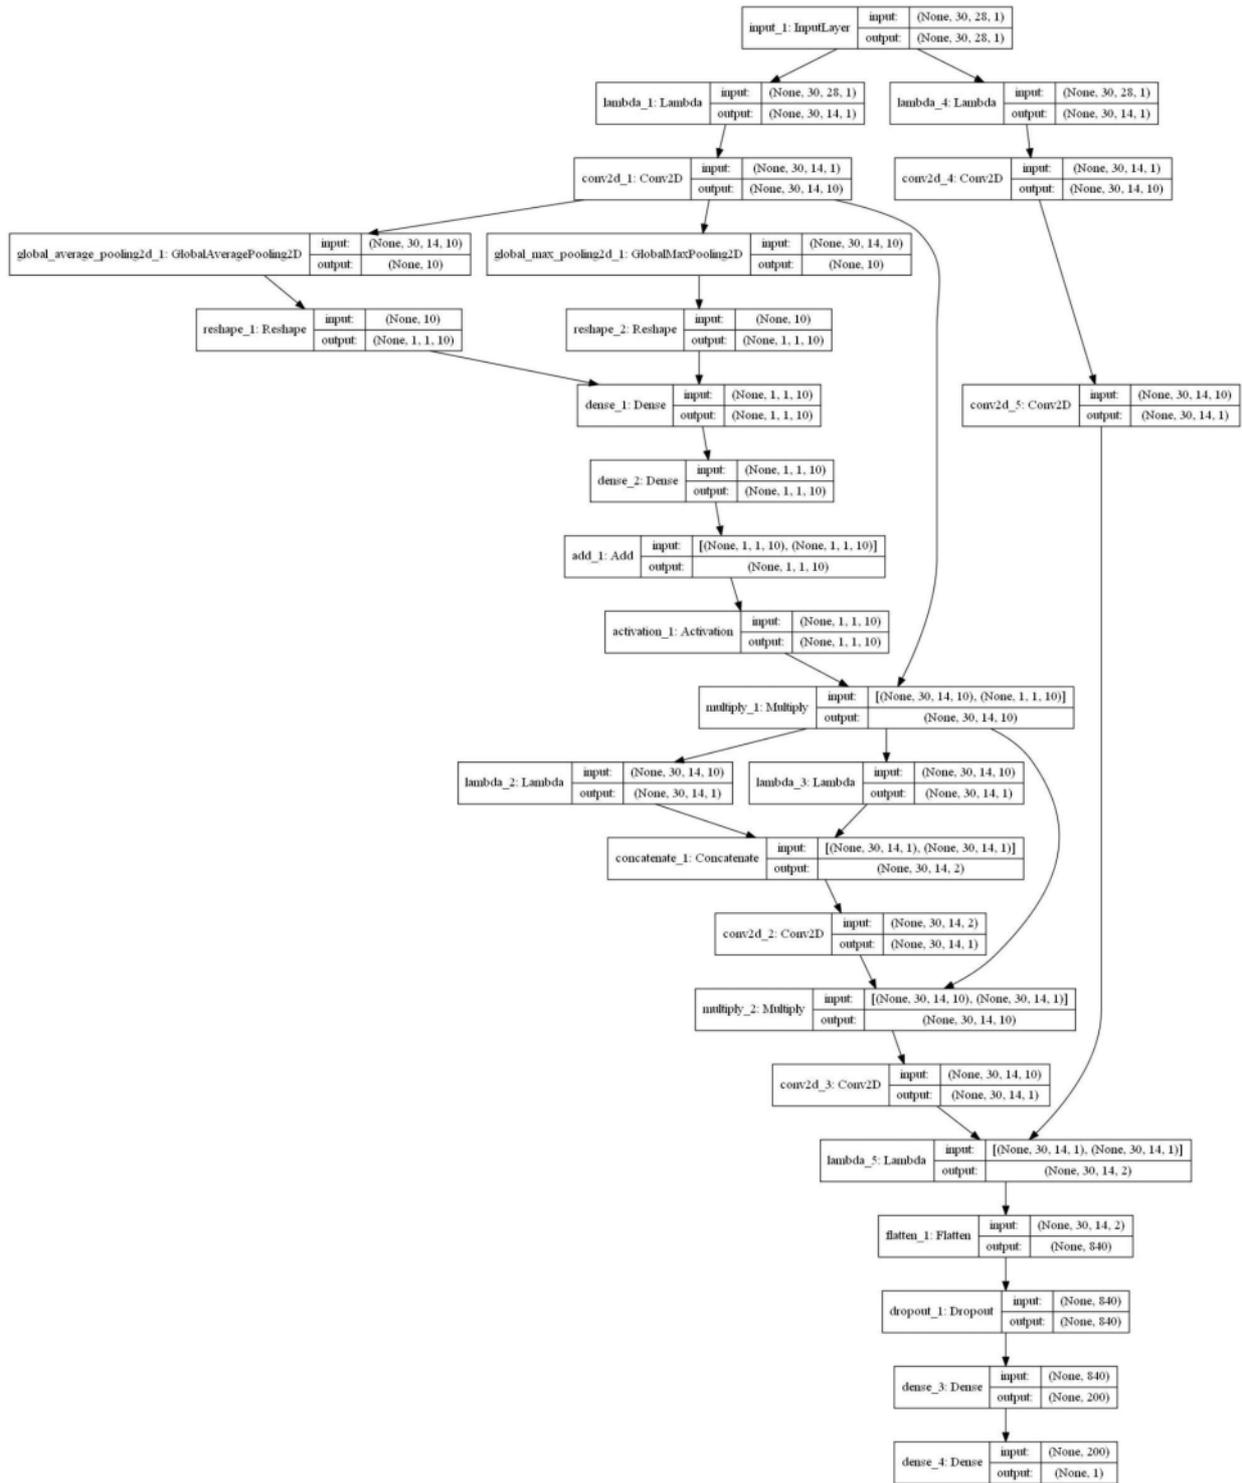


图7

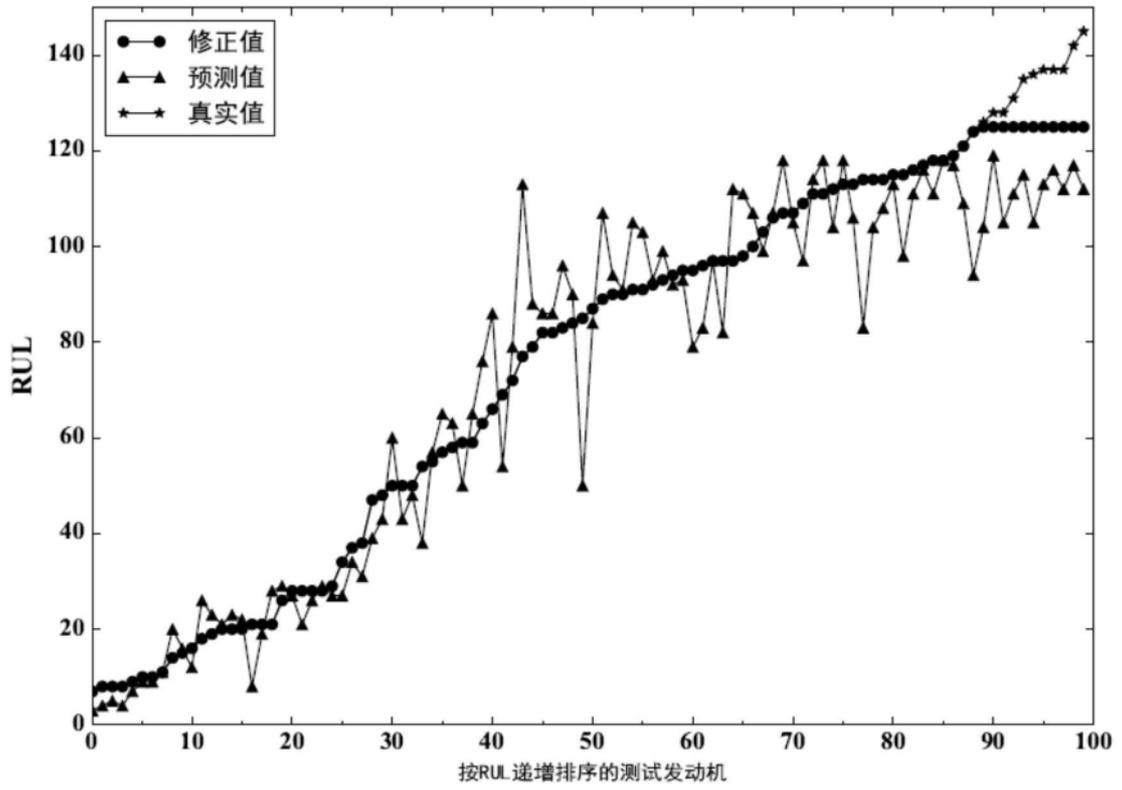


图8