

# 基于 LSTM 的风洞设备健康状态评估方法研究

吴 魁<sup>1</sup>, 孙 洁<sup>1</sup>, 蒋 波<sup>1</sup>, 王仙勇<sup>1</sup>, 黄玉龙<sup>1,2</sup>

(1. 北京航天测控技术有限公司, 北京 100041;

2. 北京市高速交通工具智能诊断与健康重点实验室, 北京 100041)

**摘要:** 针对风洞设备健康状态评估中特征提取困难、量化算法复杂等问题, 提出了一种基于深度学习的健康度评估方法, 利用正常状态样本数据训练 LSTM 编解码器网络并构建特征空间, 利用测量数据特征向量与特征空间的欧氏距离衡量健康状态的退化程度, 从而高效地实现了系统或设备的健康状态量化评估; 经风洞试验室轴流风机转子不平衡故障、长轴轴承裂缝故障等两个数据集进行验证, 取得了与设备工作状态一致的健康度评估值, 具有很强的工程应用价值。

**关键词:** 深度学习; LSTM; 健康状态评估

## Study of Health Assessment for Wind Tunnel Based on LSTM

Wu Kui<sup>1</sup>, Sun Jie<sup>1</sup>, Jiang Bo<sup>1</sup>, Wang Xianyong<sup>1</sup>, Huang Yulong<sup>1,2</sup>

(1. Beijing Aerospace Measure & Control Corp. Ltd, Beijing 100041, China; 2. Beijing Key

Laboratory of High-speed Transport Intelligent Diagnostic and Health Management, Beijing 100041, China)

**Abstract:** This paper presents a health assessment method for wind tunnel based on deep learning networks, which utilizes the LSTM encoder-decoder to build up the normal status features space via computing the hidden status of examples data. Meanwhile, the quantitative value of the diversity between the measurement data and example data is calculated using Euclidean distance from feature vector to the normal status feature space, and then hundred-mark health index can be specified. As result, health assessment method achieves high accuracy in evaluation of two fault data sets of wind tunnel, which show a significant effect and strong application value.

**Keywords:** deep learning; LSTM; health assessment

## 0 引言

风洞是开展空气动力学试验的基本设备之一, 是航空、航天飞行器研制过程中不可缺少的重要环节。近年来, 随着我国大型运载火箭、大飞机、登月工程等重大项目全面启动, 风洞试验作为航空航天技术研究的重要手段, 其发挥作用也日益突出。风洞试验时各相关设备处于正常的工作状态, 是保证试验安全、有效和可靠进行的前提条件, 同时也是确保试验数据真实、准确和可信的重要基础。风洞系统组成复杂、精密设备和部件众多, 为满足现代飞行器试验要求面临着各种复杂的试验环境和工况, 同时由于风洞试验任务日益加重导致设备的使用频率增大, 这些都使得风洞试验系统的可靠运行和维修保障面临很大的挑战<sup>[1]</sup>。

构建以健康状态评估、监测、预测、控制、管理等为核心功能的风洞自主式维修保障系统已成为有效保障风洞高效运行的重要手段, 在对试验设备运行状态实时监测、性能在线测试、故障智能诊断的基础上, 可实现风洞设备由“定时”、“事后”向“视情”的维修模式转变, 从而提高风洞设备运行效率、可靠性和科学化化管理<sup>[2]</sup>。这种“视情”维修模式的基础就是依据设备的健康状况决定维护、保养或维修措施, 因此对设备健康状况的评估成为关键技术之一。

健康度用于表示系统或设备运行情况的健康程度, 并采用规定到一定区间内的数值表示出来。例如可采用百分制, 即健

康度范围为 0~100, 健康度数值越接近 100 说明系统运行越稳定, 而随着健康度数值变小则说明系统在退化; 当健康度数值低于某一门限值时, 系统将处于完全故障的状态。健康度评估主要思想是: 通过研究历史数据的特点与变化规律, 确定最佳数据的表现形式及其变化情况, 通过当前采集的数据与历史最佳数据进行比较, 越相似则健康度越高。对复杂系统而言, 可即分层次计算各个设备和子系统的健康度, 再通过信息融合的方法确定全系统的综合健康度。

国内外经常使用的评估方法主要包括模糊综合评价法<sup>[3]</sup>、熵值法<sup>[4]</sup>、灰色综合评价法<sup>[5]</sup>等。这些方法一般不能对传感器采集的原始数据进行处理, 必须将原始数据转换为特征值再进行处理<sup>[6]</sup>。特征值提取本身就需要相应工程领域专家针对不同的信号设计不同的特征提取算法, 技术门槛很高, 在工程应用中有一定的局限性。

深度学习 (Deep Learning) 是人工智能和模式识别领域的一种新兴方法, 具备强大的自动特征提取能力, 在图像识别、语音识别等方面已经取得了辉煌的成果<sup>[7]</sup>。其中深度置信网络 (DBNs, deep belief networks) 和卷积网络 (CNNs, convolutional neural networks) 已在系统故障检测、多传感器信号故障诊断等方面开展了应用研究<sup>[8]</sup>。递归神经网络 (RNN, recurrent neural network) 作为深度学习 (Deep Learning) 的另一种经典模型<sup>[9]</sup>, 除了具备强大原始数据特征提取能力之外, 还因其具备时域记忆功能, 具备处理时序信号天然优势, 特别是长短时记忆模型 (LSTM, long-short term memory) 在解决 RNN 梯度退化、梯度爆炸等问题后在自然语言处理、图像内容表达等领域取得突出效果。

本文提出了一种基于 LSTM 风洞设备健康状态实时评价

收稿日期: 2017-12-11; 修回日期: 2018-01-05。

作者简介: 吴 魁 (1977-), 男, 江西南昌人, 研究员, 主要从事数据处理、故障诊断方向的研究。

方法, 可通过无监督方式学习正常工作状态下数据, 建立正常状态特征空间, 在获取实时监测数据后与正常状态空间的偏差程度计算健康度值, 实现对设备健康程度的实时评估。

### 1 LSTM 模型概述

LSTM 是深度学习中最适用于序列学习和识别的模型, 已成功应用于机器翻译、语义表达、行为识别等方面, 展现了其在序列数据处理方面的优势。

基于 LSTM 的编解码器 (LSTM Encoder-Decoder) 模型已在异常检测中开始应用<sup>[10]</sup>, 其基本思路是: 利用正常数据拟合一个 LSTM 编码和解码网络模型, 异常数据通过该网络模型编码和解码时会出现很大的误差, 从而触发异常告警。基于 LSTM 的编解码器网络也是本文采用的基础模型。

#### 1.1 LSTM 单元

LSTM 单元是包含 1 个细胞单元和 3 个不同类型的门, 分别是: 传入门  $i$ , 决定让多少新的信息加入到细胞单元状态中来; 遗忘门  $f$ , 决定丢弃哪些信息; 传出门  $o$ , 决定输出哪些值。

LSTM 有多种变体和扩展形式, 本文采用的模型描述如下:

$$\begin{pmatrix} i_t \\ f_t \\ o_t \\ g_t \end{pmatrix} = \begin{pmatrix} \sigma \\ \sigma \\ \sigma \\ \tanh \end{pmatrix} T_{m \times n, n \times n} \begin{pmatrix} z_t \\ a_{t-1} \end{pmatrix} \quad (1)$$

其中:  $T_{m_1, n_2}: R^{n_1} \rightarrow R^{n_2}$  是形式为  $W_{z+b}$  的映射 (矩阵  $W$  和矢量  $b$  满足相应的维度要求);  $\sigma(z) = \frac{1}{1+e^{-z}}$ ;  $\tanh(z) = 2\sigma(2z) - 1$ ; 变量  $x_t \in R^m$ 、 $i_t$ 、 $f_t$ 、 $o_t$ 、 $g_t$ 、 $a_t$ 、 $c_t \in R^n$ ; 记忆单元激活方程和隐藏状态激活方程分别为:

$$c_t = f_t c_{t-1} + i_t g_t \quad (2)$$

$$a_t = o_t \tanh(c_t) \quad (3)$$

#### 1.2 编码和解码

LSTM 编码器采用定长的表达矢量存储对输入时间序列的编码, 而解码器用这个表达矢量重构出时间序列, 原理示意图 1 所示。

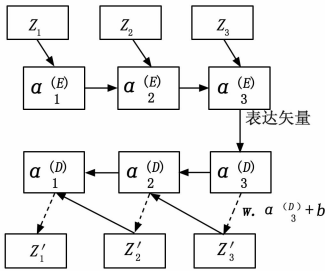


图 1 LSTM 编解码器原理

假设输入的时间序列为  $Z = [z_1 \ z_2 \ \dots \ z_t]$ , 其中  $t$  为时间序列长度;  $a_t^{(E)}$  是编码器在时刻  $t$  的隐藏状态,  $t \in \{1, 2, \dots, l\}$ ;  $a_t^{(E)} \in R^c$ , 常数  $C$  是编码器隐藏层 LSTM 单元的个数, 例如图 1 中的  $C=3$ 。

其中, 编码器隐藏层最后一个 LSTM 单元输出的隐藏状态  $a_t^{(E)}$  作为解码器第一个单元的初始输入值  $a_1^{(D)}$ , 采用线性变换预测解码器中的下一个输入值, 即  $z'_t = w^T a_t^{(D)} + b$ ; 再将  $z'_t$  作为下一个单元的输入值, 重复计算直至完成所有单元计算。

重构错误定义为:

$$e_t^{(u)} = \|z_t^{(u)} - z_t'^{(u)}\| \quad (4)$$

模型训练优化目标函数为:

$$E = \sum_{u \in U} \sum_{t=1}^l (e_t^{(u)})^2 \quad (5)$$

其中:  $u$  为单个训练样本,  $U$  是训练样本的集合。

### 2 健康度的评估方法

随着工作时间的逐渐增加, 系统或设备将经历从开始的正常运行, 到由于轻微故障引起的异常运行, 再到强故障引起的功能失效的过程。因此, 系统或设备的健康状态一般从正常状态到功能不断退化直至最终失效。

健康度评估的目的是量化计算系统或设备的退化程度。本文所采用的基本方法是: 为正常状态数据建立特征空间, 通过度量测量数据与正常状态样本空间的差异程度来量化计算退化程度, 再转换为百分制健康度, 如图 2 所示。




图 2 基于 LSTM 的健康度评估流程

其中正常状态数据样本为  $u_i \in U$ ,  $i \in \{1, 2, \dots, N\}$ ,  $U$  为正常状态数据所构成的样本空间,  $N$  为正常状态样本数量; 这里  $N$  用于训练基于 LSTM 的编解码器  $E$ , 其优化目标由式 (5) 定义; 若  $a_i \in A$  是样本  $u_i$  通过编解码器  $E$  按式 (3) 计算的编码隐藏状态, 将其定义为正常样本特征向量, 则  $A$  为正常状态特征空间。

由以上定义可知,  $A$  为正常状态下样本的特征空间, 是系统或设备正常工作状态的一种表达, 再定义  $\sigma_N$  为  $A$  的标准间距均值 (Inner Average Distance), 用于量化  $A$  中个特征矢量分布范围, 其中:

$$\sigma_N = \sum_{i=1}^n \sum_{j=1}^n \|a_i - a_j\| \quad (6)$$

设  $u_t$  为时刻  $t$  采集的数据样本,  $a_t$  样本  $u_t$  通过编解码器  $E$  按式 (3) 计算的特征向量; 定义  $\sigma_t$  为样本至正常状态空间的外部距离均值 (Outer Average Distance), 用于表征  $a_t$  与正常状态样本特征空间  $A$  的距离, 其物理含义为  $u_t$  与正常状态信号的差异程度, 可用于反映此时此刻系统或设备的退化程度, 因此又可称为样本退化间距。

$$\sigma_t = \frac{\sum_{i=1}^N \|a_t - a_i\|}{N} \quad (7)$$

定义百分制健康度  $H_t$  使得  $\sigma_t$  度量形式符合 PHM 惯例和易于比较。

$$H_t = \begin{cases} \frac{\sigma_N}{\sigma_t} \cdot 100, & \text{如果 } \sigma_t \geq \sigma_N \\ 100, & \text{如果 } \sigma_t < \sigma_N \end{cases} \quad (8)$$

在对具体系统或设备进行评估时, 健康度  $H_t$  可反映健康程度 (退化程度) 的相对差异。在对设备或系统全生命周期状态 (涵盖正常运行、部分故障、完全失效等) 进行评估之后, 可获取完整的健康度  $H_t$  曲线, 并能相应的门限阈值, 从而进一步开展基于健康度  $H_t$  的故障分类、剩余可用寿命预估等应用。

### 3 风洞设备健康度评估应用案例

基于 LSTM 的健康状态评估模型在风洞设备健康度评估中的应用方法如图 3 所示。其中，风洞设备在运行过程中监测系统可获取丰富参数数据来评价设备的运行状态，这些数据从不同层面、不同角度反映了设备的运行状况的好坏。尽管大数据分析需要充分利用各种数据，但综合考虑数据处理效率，对于具体设备的健康度评估首先还是要根据相关性原则选择用于评估的监测数据，在采集正常状态数据之后形成数据集，用于后续模型的训练。




图 3 风洞试验设备健康度评估方法

应用方法时中模型训练和健康度实时评估是核心内容，又可分为以下几个步骤：1) 根据选取的数据性质，确定时间序列长度  $l$ ；2) 利用正常工作状态样本数据，训练基于 LSTM 的编解码器  $E$ ；3) 构建正常状态数据样本特征空间  $A$ ，并计算标准间距差  $\sigma_N$ ；4) 将实时获取的数据样本输入  $E$  进行编码，得到为样本退化间距  $\sigma_t$ ；5) 计算该样本健康度  $H_t$ 。

在风洞设备中，轴流风机用于维持风洞气体流动能量，是动力源和主要的旋转机械。本文分别选取某型号轴流风机转子不平衡故障、某型号轴流风机长轴轴承裂缝故障工况下健康度评估作为算例，验证和分析本文提出的方法。

#### 3.1 某型号轴流风机轴承裂缝故障

轴流风机传动滚动轴承是易发生故障的部件，而轴承裂缝是最常见的故障。本文利用风洞故障试验室采集到的某型号轴流风机长轴轴承正常状态和裂缝故障工况下数据，验证本文提出的方法。

该数据集为单路振动数据，由固定轴承上方机壳上的加速度传感器以 12 kHz 的采样频率采集；正常状态数据 (F0) 为 102 400 个样本；裂缝内圈裂痕深度分别为 23 mm、32 mm、43 mm、56 mm 等 4 种故障状态数据 (F1~4) 分别为 10 240 个样本。

利用数据集 F0 对 LSTM 编解码器进行训练，样本时间序列为长度 1 024 的单通道数据；隐藏状态位数 (特征矢量长度) 为 128；采用 SGD 优化算法。健康度评估结果采用各数据集计算结果均值结果如表 1 所示。

表 1 轴承裂缝故障评估结果表

代号	裂痕深度 (mm)	故障评级 (人工评定)	健康度评估值
F0	0	正常	100
F1	23	轻微	88.22
F2	32	中度	56.13
F3	43	严重	49.21
F4	56	失效	13.92

其故障退化间距和故障健康度曲线分别如图 4~5 所示。




图 4 轴承裂缝故障退化间距  $\sigma_t$




图 5 轴承裂缝故障健康度  $H_t$

从以上结果可以看出，轴承裂缝故障退化间距  $\sigma_t$  和健康度  $H_t$  的评估结果与故障严重程度和人工评估结果一致，可作为该设备健康状态评估的量化值。

#### 3.2 某型轴流风机转子不平衡故障

转子不平衡是指转子在长期运行中产生不均匀的磨损、腐蚀、变形、零件脱落、不均匀结垢等各种因素的影响，使其质心和旋转中心线之间存在一定的偏心距，被认为是引起机械设备振动的主要原因之一。

本文选用某型轴流风机进行故障试验时采集的数据，工作状态分别为 4 个正常状态数据集 (F0~F3) 和转子零件脱落故障 (F4)，测量参数为：电流、转速、振动频率、输入功率、空气流量、空气压力数据，采样频率为 12 kHz，每种工作状态采集 1 200 万条数据记录，属于较大规模数据集。

利用数据集 F0 对 LSTM 编解码器进行训练，样本时间序列为长度 1 024 的 6 单通道数据；隐藏状态位数 (特征矢量长度) 为 512；采用 Adam 优化算法。健康度评估结果采用各数据集计算结果均值结果如表 2 所示。

表 2 转子不平衡故障评估结果表

代号	工作状态	故障评级 (人工评定)	健康度评估值
F0	正常	正常	100
F1	正常	正常	89.35
F2	正常	正常	90.52
F3	正常	正常	95.21
F4	转子零件脱落	失效	8.26

其故障退化间距和故障健康度曲线分别如图 6、7 所示。




图 6 转子不平衡故障退化间距  $\sigma_t$

从以上结果可以看出，F0~3 这 4 个正常工作状态的故障

