

航空发动机的健康指标构建与剩余寿命预测

彭开香[†], 皮彦婷, 焦瑞华, 唐 鹏

(北京科技大学 自动化学院 工业过程知识自动化教育部重点实验室, 北京 100083;
北京科技大学 人工智能研究院, 北京 100083)

摘要: 预测与健康管理技术能够有效的评估系统健康状态、预测系统剩余使用寿命, 是提高复杂系统安全性、经济性的重要保障。为全面评估系统健康状态, 本文提出了一种基于深度置信网络(DBN)的无监督健康指标构建方法, 并结合隐马尔可夫模型(HMM)进行系统剩余寿命预测。首先, 通过无监督训练深度置信网络实现历史数据的特征提取, 进而构建健康指标; 其次, 利用健康指标集训练隐马尔可夫模型, 实现设备健康状态的自动识别; 最后, 通过DBN-HMM混合模型来计算系统剩余寿命。采用商用模块化航空推进系统仿真软件(C-MAPSS)给出的航空发动机数据集, 验证了上述方法的有效性。

关键词: 深度置信网络; 隐马尔可夫模型; 健康指标; 健康状态识别; 剩余寿命预测

引用格式: 彭开香, 皮彦婷, 焦瑞华, 等. 航空发动机的健康指标构建与剩余寿命预测. 控制理论与应用, 2020, 37(4): 713 – 720

DOI: 10.7641/CTA.2019.90039

Health indicator construction and remaining useful life prediction for aircraft engine

PENG Kai-xiang[†], PI Yan-ting, JIAO Rui-hua, TANG Peng

(Key Laboratory of Knowledge Automation for Industrial Processes of Ministry of Education, School of Automation and Electrical Engineering, University of Science and Technology Beijing, Beijing 100083, China;
Institute of Artificial Intelligence, School of Automation and Electrical Engineering, University of Science and Technology Beijing, Beijing 100083, China)

Abstract: Prognostics and health management can effectively evaluate the health status and predict the remaining useful life of the system. It is an important guarantee to improve the safety and economy of complex systems. In order to fully assess the health status of the system, an unsupervised health indicator construction method based on the deep belief network (DBN) is proposed in this paper, and remaining useful life of the system is predicted with the hidden Markov model (HMM). Firstly, the feature extraction of historical data is realized by unsupervised training deep belief network, and then the health indicator is constructed. Secondly, the health indicator set is used to train the hidden Markov model, then the automatic recognition of equipment health state can be realized. Finally, the remaining useful life of the system is calculated by the DBN-HMM hybrid model. To validate the effectiveness of the proposed approach, a case study is performed on the commercial modular aero-propulsion system simulation (C-MAPSS) aircraft engine datasets.

Key words: deep belief network; hidden Markov model; health indicator; health status recognition; remaining useful life prediction

Citation: PENG Kaixiang, PI Yanting, JIAO Ruihua, et al. Health indicator construction and remaining useful life prediction for aircraft engine. *Control Theory & Applications*, 2020, 37(4): 713 – 720

收稿日期: 2019–01–16; 录用日期: 2019–09–12.

[†]通信作者. E-mail: kaixiang@ustb.edu.cn; Tel.: +86 10-62333084.

本文责任编辑: 王郸维。

国家自然科学基金项目(61873024, 61773053), 中央高校北京科技大学基本科研业务项目(FRF-GF-17-A4, FRF-BD-17-002A, FRF-BD-18-002A)资助。

Supported by the National Natural Science Foundation of China (61873024, 61773053) and the Fundamental Research Funds for the China Central Universities of USTB (FRF-GF-17-A4, FRF-BD-17-002A, FRF-BD-18-002A).

1 引言

预测与健康管理 (prognostics and health management, PHM) 是一种在系统实际生命周期中评估其可靠性的方法, 通过预测失效的发生来降低系统风险^[1]. PHM 技术能够有效提高复杂系统的安全性、可靠性, 实现设备的视情维修, 应用于国防军事、航空航天、生产制造等领域中尤为重要. 系统剩余使用寿命 (remaining useful life, RUL) 预测是PHM中的一项关键技术, 通过预测系统的RUL, 能够实现有效的系统级维护, 对维修决策提供重要信息. 其中面临的一个关键问题就是如何构建可以反映系统退化趋势的健康指标(health indicator, HI), 这是因为合理的健康指标能够在简化预测模型的同时提高RUL预测精度.

当下的RUL预测方法主要分为3类: 基于机理模型的方法、数据驱动的方法和两者结合的方法^[2]. 基于机理模型的方法能够更精确的给出系统退化过程, Haile 等^[3]利用机械设备RUL预测中最常用的Paris-Erdogan(PE)模型对旋翼机主要构件进行裂纹退化建模; Zhao等^[4]提出了齿轮传动系统的一般预测框架, 利用齿轮有限元模型和损伤传播模型对齿轮进行退化建模及RUL预测. 但实际工业过程中机理建模非常困难, 很多复杂设备无法精确建立机理模型. 数据驱动的方法只需要利用设备运行的观测数据, 即可对退化过程建模, 逐渐成为主流研究方法^[5]. Zhang等^[6]利用高炉温度监测数据并结合两个随机过程, 提出了一种非齐次复合泊松过程的跳跃扩散过程描述系统退化过程的方法, 对高炉进行了退化建模与RUL预测; Wen等^[7]提出了一种贝叶斯框架下退化信号的多相建模方法, 并利用改进粒子滤波算法预测RUL; Zhang等^[8]利用卡尔曼滤波和期望最大化算法提出了一种迭代估计方法来识别退化状态, 研究了公共噪声下的非线性多退化系统的RUL预测; Wang等^[9]选用不同核参数进行相关向量机回归对轴承退化过程建模, 并结合指数模型来提高RUL预测精度; 喻勇等^[10]分析了基于协变量方法的数据驱动的剩余寿命预测进展, 并总结了存在的问题与挑战. Liu等^[11]提出了一种基于证据推理和置信规则库的设备寿命评估方法, 将有限的数据进行有效折合可以得到更可靠的寿命评估结果.

按照数据所反映的对象系统退化行为即HI划分, 可以将数据驱动的RUL预测方法分为两类: 直接预测方法和间接预测方法^[12]. 直接预测方法是将原始数据直接作为系统的HI, 通常这类方法得到的HI曲线性能较差, 不利于后续预测RUL. 间接预测方法是对原始数据进行特征提取, 必要的情况下进行特征融合, 通过多种特征结合得到系统HI. 间接HI构建方法能够更有效的反映系统退化过程, 便于预测RUL, 因此近年来得到了广泛的研究. 传统的间接HI构建方法主要有两大类, 基于信号处理的方法如计算方均根值^[13]、小波分析^[14]等, 基于机器学习的方法如主成分分析^[15]、

支持向量机^[16]、神经网络^[17]等. 近年来深度学习理论以其强大的建模和表征能力迅速在语音识别^[18]、故障诊断^[19]等领域兴起, 并逐渐应用于预测与健康管理领域中^[20]. Guo等^[21]利用深度卷积网络对轴承数据进行特征提取, 证明了所构建HI的有效性, 然而构建过程需要人工设计标签有监督训练网络. Hu等^[22]利用极限学习机和自编码器构成深度网络, 得到了抗噪较好的轴承HI曲线, 然而未对RUL进行预测. Liao等^[23]提出了一种增强受限玻尔兹曼机结合自组织映射网络来构建HI的方法, 有效提高了轴承RUL预测精度.

以上研究中, 利用深度学习理论的HI构建方法大多是通过人工设计标签进行有监督训练, 过程费时费力且方法不具有通用性. 深度置信网络 (deep belief network, DBN) 作为深度学习理论中主流网络之一, 可以从原始输入数据中学习其本质特征, 具有强大的自动特征提取能力. 基于此, 本文提出了一种基于DBN的无监督健康指标构建并结合隐马尔可夫模型 (hidden Markov model, HMM) 进行系统剩余寿命预测的方法. 所提出的方法能够自适应提取系统健康指标, 识别系统健康状态并进行剩余寿命预测. 首先, 通过无监督训练DBN对观测数据进行特征提取, 构建系统健康指标; 其次, 结合构建的健康指标训练HMM, 识别系统健康状态, 在此基础上, 得到系统剩余寿命预测值; 最后, 在商用模块化航空推进系统仿真软件 (commercial modular aero-propulsion system simulation, C-MAPSS) 航空发动机数据集中验证了所提方法的有效性. 本文提出的方法具有以下优点: 1) 利用DBN网络自动提取特征, 不需要大量专家经验, 所提出的HI构建方法具有通用性; 2) 网络训练过程为无监督方式, 不需要人工预先设计标签, 节约人力及时间成本; 3) 创新性地提出了DBN-HMM架构, 可以有效的提高RUL预测精度.

2 基于DBN的健康指标构建

深度置信网络由多个受限玻尔兹曼机(restricted Boltzmann machine, RBM)堆叠^[24]以及一个分类层(或回归层)组合而成, 在提取数据特征方面有着速度快、自动性好、不需要标签等优势, 所以选择通过训练DBN来实现观测数据的特征提取, 进而构建出系统的健康指标.

2.1 受限玻尔兹曼机

受限玻尔兹曼机RBM源于基于能量函数的建模方法, 在玻尔兹曼机基础上优化而来, 结构上是一种生成式随机网络, 由可见层和隐藏层两层结构组成^[25], 可见层神经元和隐藏层神经元之间相互连接, 同一层的神经元之间相互独立, 即层内之间没有连接, 各层之间全部连接. 神经元状态取“1”和“0”代表激活和未激活状态. 受限玻尔兹曼机结构示意图如

图1所示。

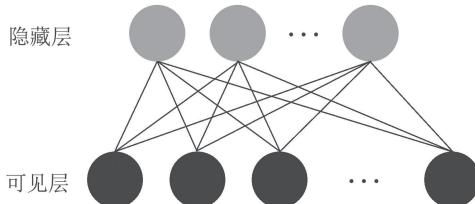


图1 RBM结构示意图

Fig. 1 The structure diagram of RBM

可见层神经元表示为 $v = \{v_1, v_2, \dots, v_m\}$, 隐藏层神经元为 $h = \{h_1, h_2, \dots, h_n\}$, 受限玻尔兹曼机 RBM 能量函数定义为

$$\begin{aligned} E(v, h) = & \\ -a^T v - b^T h - h^T W v = & \\ -\sum_{i=1}^m a_i v_i - \sum_{j=1}^n b_j h_j - \sum_{i=1}^m \sum_{j=1}^n h_j w_{ij} v_i, & (1) \end{aligned}$$

式中: a_i 为可见层偏置; b_j 为隐藏层偏置; w_{ij} 为可见层与隐藏层之间的连接权重; RBM 模型参数可表示为 $\theta = \{a_i, b_j, w_{ij}\}$.

由能量函数可以得出隐藏层与可见层之间的联合概率分布为

$$P_\theta(v, h) = \frac{1}{Z_\theta} e^{-E_\theta(v, h)}, \quad (2)$$

式中 $Z_\theta = \sum_v \sum_h e^{-E_\theta(v, h)}$ 为归一化指标, 也称配分函数。由式(2)可得出可见层神经元概率分布 $P_\theta(v)$ 、隐藏层神经元概率分布 $P_\theta(h)$, 表达式为

$$P_\theta(v) = \sum_h P_\theta(v, h) = \frac{1}{Z_\theta} \sum_h e^{-E_\theta(v, h)}, \quad (3)$$

$$P_\theta(h) = \sum_v P_\theta(v, h) = \frac{1}{Z_\theta} \sum_v e^{-E_\theta(v, h)}. \quad (4)$$

由于 RBM 结构中同一层神经元之间无连接, 所以给定某层神经元状态时, 另一层神经元状态条件分布相互独立, 可得如下概率:

$$P_\theta(v|h) = \prod_{i=1}^m P(v_i|h), \quad (5)$$

$$P_\theta(h|v) = \prod_{j=1}^n P(h_j|v). \quad (6)$$

推导得出神经元激活概率:

$$p(h_j = 1|v) = \text{sigmoid}(b_j + \sum_{i=1}^m w_{ji} v_i), \quad (7)$$

$$p(v_i = 1|h) = \text{sigmoid}(a_i + \sum_{j=1}^n w_{ji} h_j), \quad (8)$$

式中激活函数为 $\text{sigmoid} = \frac{1}{1 + e^{-x}}$.

2.2 深度置信网络

深度置信网络 DBN 的底层为输入数据向量, 中间

层堆叠数个 RBM, 低一层 RBM 的输出为高一层 RBM 的输入, 逐层网络实现输入数据的特征提取^[26], 本文选用的 DBN 最上层叠加一层自编码器(AutoEncoder, AE)网络, 实现无监督特征提取, 对整个网络权值进行调整。本文中以 2 个 RBM 为例, 深度置信网络结构示意图如图 2 所示。

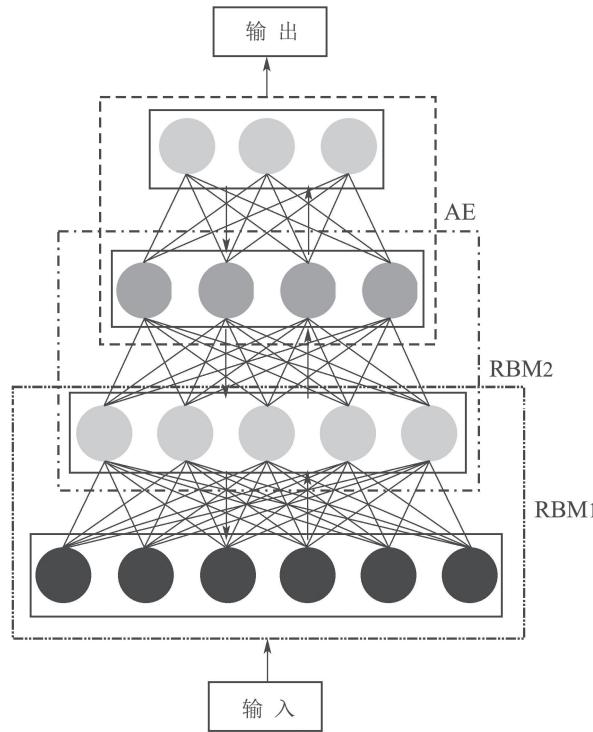


图2 DBN结构示意图

Fig. 2 The structure diagram of DBN

深度置信网络的训练包含两个过程, 预训练阶段和反向微调阶段^[27]。预训练阶段为前向贪婪学习, 逐层训练 RBM, 实现输入数据转换到隐层, 逐层训练得到最终提取出的特征数据。RBM 模型参数表示为 $\theta = \{a_i, b_j, w_{ij}\}$ 时, 通过调整参数 θ , 使 RBM 在该参数下, 概率分布最大可能的符合输入数据分布, 即通过最大化似然函数来训练每一层 RBM。似然函数表示为

$$\mathcal{L}_{\theta, S} = \prod_{i=1}^m P(v_i), \quad (9)$$

式中 $S = \{v_1, v_2, \dots, v_m\}$ 。为了便于计算, 极大化似然函数 $\mathcal{L}_{\theta, S}$ 可变为极大化 $\ln \mathcal{L}_{\theta, S}$, 表达式为

$$\ln \mathcal{L}_{\theta, S} = \ln \prod_{i=1}^m P(v_i) = \sum_{i=1}^m \ln P(v_i). \quad (10)$$

使用马尔可夫链蒙特卡罗(Markov chain Monte Carlo, MCMC)方法可以对式(10)求出最大似然函数, 但存在训练时间长、过程缓慢的问题。通常使用 Hinton 提出的对比散度(contrastive divergence, CD)算法, 也称 CD-k 算法, 经验证 $k = 1$ 即能够短时间实现很好的训练效果。利用对比散度算法可得到权值和偏置的更新:

$$W_t = W_{t-1} + \varepsilon(v \cdot p(h|v) + v' \cdot p(h'|v')), \quad (11)$$

$$a_t = a_{t-1} + \varepsilon(p(h|v) - p(h'|v')), \quad (12)$$

$$b_t = b_{t-1} + \varepsilon(p(h) - p(v|h')), \quad (13)$$

式中 ε 为学习率.

完成RBM逐层训练后,当下的前向最优特征数据进入到AE网络,由于本文的目的是无监督提取数据特征,不是数据分类或回归,所以选用AE网络而不是BP网络.通过反向传播算法微调,实现全局最优特征数据提取.

2.3 健康指标构建

DBN训练过程中,输入数据由可见层映射到隐含层,逐层传递,每一层中由隐藏层数据重构可见层数据,重构数据与实际数据误差最小时,认为隐藏层数据是可见层的最优特征,逐层训练后反向微调,得到数据全局最优特征.通过训练DBN网络提取数据特征可以构建出合适的健康指标,首先对历史观测数据进行滤波及标准化处理,处理后的数据输入DBN网络进行训练,之后通过调节网络参数使得网络重构误差最小,得到训练好的DBN网络模型,分别将历史失效数据与实时观测数据代入DBN网络,输出失效特征与实时特征,通过实时数据特征与失效数据特征做差,由式(14)构造出HI:

$$HI_K = \sqrt{\sum_{t=1}^K (f_t - f_{\text{fault}})^2}, \quad (14)$$

式中: f_t 为实时数据特征; f_{fault} 为失效数据特征; K 为HI序列长度.

算法评价方面,本文选择了单调性(monotonicity)和鲁棒性(robustness)两个常用指标对构造出的HI进行评价^[28],表达式为

$$\text{Mon(HI)} = \frac{1}{K-1} |\text{Num} > 0 - \text{Num} < 0|, \quad (15)$$

$$\text{Rob(HI)} = \frac{1}{K} \sum_{t=1}^K \exp(-|\frac{HI_t - HI_t^T}{HI_t}|), \quad (16)$$

式中: $HI = \{HI_t\}_{t=1:K}$ 为构造出的健康指标序列; K 为HI序列长度; $\text{Num} = HI_{t+1} - HI_t$ 为HI曲线相邻点之差.

3 基于HMM的健康状态识别

隐马尔可夫模型HMM是一种和时间顺序相关的概率模型^[29],由于它强大的数学基础,已经被成功应用于许多领域. HMM阐述的是隐藏状态下的马尔可夫链,与一个可见的随机序列相对应,组成一个整体,只有每个可见的序列能够被观察到,通过可见的序列去推断隐藏的状态.由于设备退化过程不可逆,所以HMM模型选为左右型隐马尔可夫模型,示意图如图3所示.

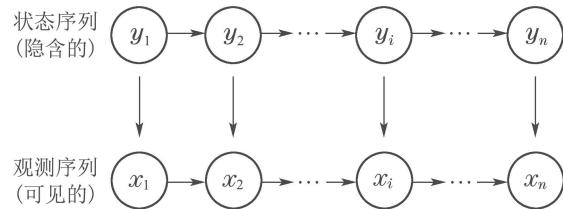


图3 HMM结构示意图

Fig. 3 The structure diagram of HMM

隐马尔可夫链的方法一般用于具有离散退化状态的情况,本文研究的是能表征复杂设备连续退化健康状态的健康指标.而如果将连续状态进行离散化处理则会丢失很多过程信息.因此,选用混合高斯分布作为HMM观测值概率密度函数,得到混合高斯的隐马尔可夫模型^[30],进而实现复杂设备健康状态的退化过程建模.假设状态值序列可表示为 $S = \{s_1, s_2, \dots, s_N\}$, N 为状态个数.设备的 k 次的观测值序列可表示为 $O = \{O_1, O_2, \dots, O_k\}$.混合高斯隐马尔可夫模型数学形式可表示为

$$\lambda = (\pi, A, C, \mu, U), \quad (17)$$

式中: π 代表初始概率矩阵, $\pi = \{\pi_1, \pi_2, \dots, \pi_n\}$,
 $\pi_n = P[q_t = s_n] \geq 0, \sum_{n=1}^N \pi_n = 1$.

A 为概率转移矩阵:

$$A = \begin{pmatrix} a_{11} & \cdots & a_{1N} \\ \vdots & \ddots & \vdots \\ a_{N1} & \cdots & a_{NN} \end{pmatrix},$$

$$a_{ij} = P[q_{t+1} = s_j | q_t = s_i] \geq 0, \sum_{j=1}^N a_{ij} = 1;$$

C 代表混合高斯分布的混合权重矩阵:

$$C = \begin{pmatrix} c_{11} & \cdots & c_{1m} \\ \vdots & \ddots & \vdots \\ c_{n1} & \cdots & c_{nm} \end{pmatrix},$$

$$c_{nm} \geq 0, \sum_{m=1}^M c_{nm} = 1, 1 \leq n \leq N, 1 \leq m \leq M;$$

μ 代表混合高斯均值矩阵, U 代表混合高斯的协方差矩阵:

$$\mu = \begin{pmatrix} \vec{\mu}_{11} & \cdots & \vec{\mu}_{1M} \\ \vdots & \ddots & \vdots \\ \vec{\mu}_{N1} & \cdots & \vec{\mu}_{NM} \end{pmatrix}, U = \begin{pmatrix} U_{11} & \cdots & U_{1M} \\ \vdots & \ddots & \vdots \\ U_{N1} & \cdots & U_{NM} \end{pmatrix},$$

式中: $\vec{\mu}_{NM}$ 是在混合 x_{NM} 中的 D 维均值向量, U_{NM} 是 $D \times D$ 维协方差矩阵.

观测值 $o_t^{(k)}$ 在状态 S_n 下的概率密度函数为^[31]

$$b_{t,n}^{(k)} = \sum_{m=1}^M c_{nm} \times b_{t,nm}^{(k)} =$$

$$\sum_{m=1}^M c_{nm} \times \frac{\exp(-0.5(\vec{o}_t^{(k)} - \vec{\mu}_{nm})^T \cdot U_{nm}^{-1}(\vec{o}_t^{(k)} - \vec{\mu}_{nm}))}{\sqrt{(2 \times \pi)^2 \times |U_{nm}|}}, \quad (18)$$

式中: $b_{t,n}^{(k)}$ 为在隐藏状态 S_n 下的观测向量 $\vec{o}_t^{(k)}$ 的概率密度函数; $b_{t,nm}^{(k)}$ 为在混合 x_{nm} 时观测向量 $\vec{o}_t^{(k)}$ 的概率密度函数。

运用经典的 Baum-Welch 算法对 HMM 模型参数进行调节, 通过极大似然估计可求出观测序列下概率最大的模型^[32]。得到 HMM 模型后, 运用维特比算法, 可以得出设备健康状态转移过程, 从而实现设备当前健康状态的有效识别。

4 基于DBN-HMM的剩余寿命预测

传统的利用混合高斯 HMM 模型的设备健康状态识别通常直接将数据代入模型, 直接利用输入数据进行模型训练、识别健康状态和计算剩余寿命。本文提出利用 DBN 网络对数据进行特征提取, 通过处理特征数据构造健康指标, 将得到的健康指标用来训练 HMM, 得到训练好的 DBN-HMM 模型, 在此模型基础上进行设备健康状态识别与剩余寿命的计算, 能够得到更准确的健康状态划分, 同时克服了单独依据健康指标或健康状态来进行剩余寿命预测的缺点, 有效

提高了预测精度。基于 DBN-HMM 的剩余寿命预测整体流程如图 4 所示。具体步骤如下:

1) 对原始数据进行线性最小二乘滤波及标准化处理, 去除噪声影响的同时便于 DBN 网络调节, 得到处理后的训练集数据;

2) 处理后的训练集数据划分为退化过程数据与失效数据, 代入 DBN 网络, 通过前向预训练与反向微调网络权值实现重构误差最小化, 得到训练好的 DBN 网络模型, 输出退化特征与失效特征;

3) 利用退化数据特征与失效数据特征, 由式(14)构造得出系统健康指标;

4) 将构造的 HI 代入 HMM 模型, 通过 Baum-Welch 算法对 HMM 进行训练实现模型概率最大化, 得到训练好的 DBN-HMM 模型;

5) 对实时数据进行滤波及标准化处理, 代入得到的 DBN-HMM 模型中, 构建健康指标后, 进行健康状态识别并计算剩余寿命。剩余寿命由式(19)计算得出:

$$RUL = \sum_{i=1}^m E(d_i)p_i, \quad (19)$$

式中: $E(d_i) = \frac{1}{1-a_{ii}}$ 为状态 i 停留时间的期望, a_{ii} 为 HMM 中状态 i 的自身转移概率; p_i 为状态概率; m 为当前一共经历的状态数。

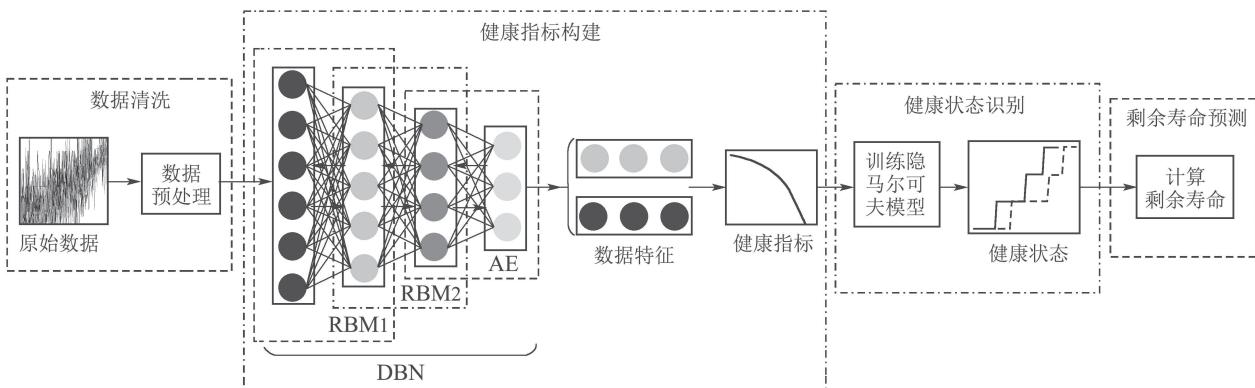


图 4 基于DBN-HMM的剩余寿命预测整体框架

Fig. 4 The framework of lifetime pronostics based on DBN-HMM

本文选用常用的算法性能指标 RMSE^[33], MAE, FPR, FNR 和准确度 A ^[34] 来对 RUL 进行评价。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\text{error}_i)^2}, \quad (20)$$

式中: $\text{error}_i = \hat{RUL} - RUL$ 为 RUL 预测误差; i 为样本序号, $1 \leq i \leq N$ 。

$$MAE = \frac{1}{N} \sum_{i=1}^N |\text{error}_i|, \quad (21)$$

$$FPR = \frac{\text{Num}_p}{100} \times 100\%, \quad (22)$$

式中 Num_p 为 $\text{error}_i < -10$ 的个数。

$$FNR = \frac{\text{Num}_n}{100} \times 100\%. \quad (23)$$

式中 Num_n 为 $\text{error}_i > 13$ 的个数。

$$A = \frac{100}{N} \sum_{i=1}^N I(\text{error}_i), \quad (24)$$

式中

$$I(\text{error}_i) = \begin{cases} 1, & -10 \leq \text{error}_i \leq 13, \\ 0, & \text{error}_i < -10, \text{error}_i > 13. \end{cases}$$

5 实例验证

5.1 数据集描述

本文选用PHM'08故障预测与健康管理国际会议的C-MAPSS航空发动机数据集^[35]对提出的方法进行应用验证。数据集包含不同故障模式和工况下的4组数据，本文选用第1组编号为FD001的单一故障模式数据。FD001数据中包含100台全寿命训练数据、100台部分测试数据和测试数据对应的真实剩余寿命数据，测试数据中每台发动机的起始状态不同，所以观测序列长度也不同。观测数据为21个含噪声的传感器变量时间序列。

5.2 实验结果及分析

选取100台发动机中14个有变化的变量数据作为训练集，进行滤波及标准化处理，选取训练集中后5%的数据作为失效数据，代入DBN网络提取失效特征。DBN网络中，RBM设为2层，第1层节点数为50，第2层节点数为14，对DBN网络进行无监督训练，输出实时数据特征。实时数据特征与失效特征按式(14)处理得出发动机健康指标。图5为100台发动机训练集数据构建出的健康指标。1代表初始健康状态，0代表系统失效，曲线1到0的下降过程直观的表示出了系统的退化过程。

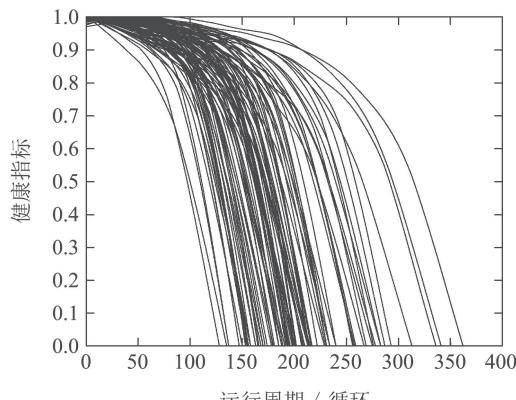


图 5 通过DBN网络构建的训练集HI曲线

Fig. 5 The health indicator curves constructed by DBN

本文对比了传统的线性回归、BP神经网络构建出的健康指标的单调性、鲁棒性，在100台发动机测试数据上进行测试，平均评价指标对比如表1所示。

表 1 HI评价指标对比

Table 1 Comparison of HI evaluation index

构建HI方法	Mon	Rob
线性回归	0.8011	2.4311×10^{-5}
BP	0.5399	1.3298
DBN	0.6822	1.6798

对比可以看出，传统的线性回归HI单调性良好，但鲁棒性较差，不能得到较好的系统退化过程健康指标。通过DBN网络构建的HI更加平滑，单调性、鲁棒性均强于BP网络，更适合后续进行RUL预测。

构建健康指标后，利用得到的HI对隐马尔可夫模型进行训练。本文设定设备退化共会经历4个状态^[36]：正常状态、初步退化状态、严重退化状态、失效状态，分别用状态1, 2, 3, 4表示，初始设备处于正常状态，逐步退化至失效。将DBN网络构建出的系统健康指标代入HMM，得到训练好的模型后，代入测试集数据。结合HI的健康状态转移路径(第34台为例)如图6所示。能够直观的表示出发动机退化状态，便于依据退化状态制定维修计划。

为便于对比基于传统 HMM 方法与基于 DBN-HMM 方法的健康状态识别结果，选取第34台发动机测试数据(时间循环数为203)为例，受篇幅限制，选取两种方法的7个时间循环的健康状态识别结果分别列于表2和表3，此发动机实际处于第4个健康状态。对比可以看出，基于DBN-HMM方法的健康状态识别率明显高于基于传统HMM方法得到的结果。

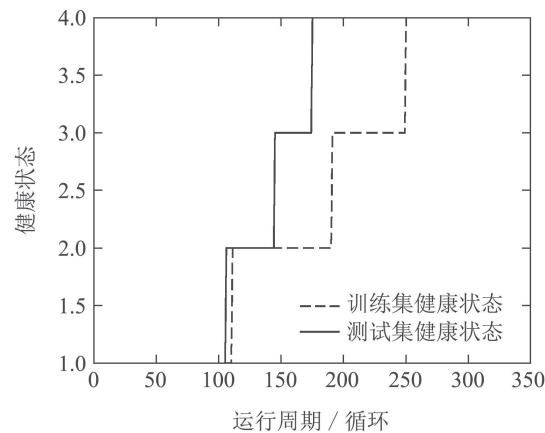


图 6 通过DBN-HMM识别的健康状态转移曲线

Fig. 6 The health states transition curves recognized by DBN-HMM

表 2 传统HMM识别结果
Table 2 The recognition results of traditional HMM

时间循环	状态1	状态2	状态3	状态4	状态识别率/%
197	0	0	0.9969	0.0031	0.31
198	0	0	0.9957	0.0043	0.43
199	0	0	0.9941	0.0059	0.59
200	0	0	0.9922	0.0078	0.78
201	0	0	0.9901	0.0099	0.99
202	0	0	0.9878	0.0122	1.22
203	0	0	0.9854	0.0146	1.46

表 3 DBN-HMM识别结果

Table 3 The recognition results of DBN-HMM

时间循环	状态1	状态2	状态3	状态4	状态识别率/%
197	0	0	0.9297	0.0703	7.03
198	0	0	0.8496	0.1504	15.04
199	0	0	0.6658	0.3342	33.42
200	0	0	0.3675	0.6325	63.25
201	0	0	0.1236	0.8764	87.64
202	0	0	0.0278	0.9722	97.22
203	0	0	0.0049	0.9951	99.51

将实时数据代入构建好的DBN-HMM模型中,由式(19)计算出剩余寿命。本文对比了多源信息融合、多层感知机(MLP)、深度卷积网络(DeepCNN)、长短时记忆网络(LSTM)和传统的隐马尔可夫模型(HMM)的剩余寿命预测结果,对比结果如表4所示。NR表示此项数据原文没有提到。可以看出在RMSE指标上,基于DBN-HMM的结果大于DeepCNN的结果,但明显小于基于MLP和传统HMM的结果。MAE指标上,多源信息融合方法效果最好。在FPR、FNR和A等准确度指标上, DBN-HMM预测效果更好,剩余寿命预测准确度相对较高。此外,本文提出的DBN-HMM方法能够对系统健康状态进行识别,相比于以上方法,在预测RUL的基础上能够更全面地监测系统退化过程,便于给出系统健康状态评估结果。

表 4 RUL预测结果对比

Table 4 Comparison of RUL prediction results

预测RUL方法	RMSE	MAE	FPR	FNR	A
多源信息融合 ^[37]	NR	5.02	NR	NR	NR
MLP ^[38]	37.5629	NR	NR	NR	NR
DeepCNN ^[38]	18.4480	NR	NR	NR	NR
LSTM ^[34]	NR	18	34%	30%	36%
HMM	45.1071	34.0401	51%	31%	18%
DBN-HMM	33.8181	24.5448	18%	40%	42%

6 结论

本文通过基于DBN的无监督健康指标构建,结合隐马尔可夫模型提出了一种系统剩余寿命预测新方法。在C-MAPSS航空发动机数据集中应用结果表明,所提出的方法能够自适应提取系统健康指标,利用DBN网络自动提取特征的HI构建方法具有通用性,且训练过程为无监督方式,不需要人工预先设计标签,省时省力。通过DBN-HMM架构可以全面的对系统退化过程建模,识别系统健康状态,并可以有效的提高RUL预测准确度。

参考文献:

- [1] VICHARE N M, PECHT M G. Prognostics and health management of electronics. *IEEE Transactions on Components and Packaging Technologies*, 2006, 29(1): 222 – 229.

- [2] PECHT M. Prognostics and health management of electronics. *Encyclopedia of Structural Health Monitoring*. Hoboken, New Jersey: John Wiley & Sons, Ltd, 2009.
- [3] HAILE M A, RIDICK J C, ASSEFA A H. Robust particle filters for fatigue crack growth estimation in rotorcraft structures. *IEEE Transactions on Reliability*, 2016, 65(3): 1438 – 1448.
- [4] ZHAO F Q, TIAN Z G, ZENG Y. Uncertainty quantification in gear remaining useful life prediction through an integrated prognostics method. *IEEE Transactions on Reliability*, 2013, 62(1): 146 – 159.
- [5] SI Xiaosheng, HU Changhua. *Data-driven Remaining Useful Life Prediction Theory and Applications for Equipment*. Beijing: Defense Industrial Press, 2016.
(司小胜, 胡昌华. 数据驱动的设备剩余寿命预测理论及应用. 北京: 国防工业出版社, 2016.)
- [6] ZHANG J X, HU C H, HE X, et al. Lifetime prognostics for deteriorating systems with time-varying random jumps. *Reliability Engineering & System Safety*, 2017, 167: 338 – 350.
- [7] WEN Y X, WU J G, YUAN Y. Multiple-phase modeling of degradation signal for condition monitoring and remaining useful life prediction. *IEEE Transactions on Reliability*, 2017, 66(3): 924 – 938.
- [8] ZHANG H W, CHEN M Y, ZHOU D H. Remaining useful life prediction for a nonlinear multi-degradation system with public noise. *Journal of Systems Engineering and Electronics*, 2018, 29(2): 429 – 435.
- [9] WANG B, LEI Y G, LI N P, et al. An improved fusion prognostics method for remaining useful life prediction of bearings. *International Conference on Prognostics and Health Management*. Dallas, TX: IEEE, 2017: 18 – 24.
- [10] YU Yong, SI Xiaosheng, HU Changhua, et al. Data driven reliability assessment and life-time prognostics: a review on covariate models. *Acta Automatica Sinica*, 2018, 44(2): 216 – 227.
(喻勇, 司小胜, 胡昌华, 等. 数据驱动的可靠性评估与寿命预测研究进展: 基于协变量的方法. 自动化学报, 2018, 44(2): 216 – 227.)
- [11] LIU Jiajun, HU Changhua, ZHOU Zhijie, et al. Life assessment approach of equipment based on belief-rule-base and evidential reasoning. *Control Theory & Applications*, 2015, 32(2): 231 – 238.
(刘佳俊, 胡昌华, 周志杰, 等. 基于证据推理和置信规则库的装备寿命评估. 控制理论与应用, 2015, 32(2): 231 – 238.)
- [12] PENG Yu, LIU Datong. Data-driven prognostics and health management: a review of recent advances. *Chinese Journal of Scientific Instrument*, 2014, 35(3): 481 – 495.
(彭宇, 刘大同. 数据驱动故障预测和健康管理综述. 仪器仪表学报, 2014, 35(3): 481 – 495.)
- [13] SHEN Zhongjie, CHEN Xuefeng, HE Zhengjia, et al. Remaining life predictions of rolling bearing based on relative features and multi-variable support vector machine. *Journal of Mechanical Engineering*, 2013, 49(2): 183 – 189.
(申中杰, 陈雪峰, 何正嘉, 等. 基于相对特征和多变量支持向量机的滚动轴承剩余寿命预测. 机械工程学报, 2013, 49(2): 183 – 189.)
- [14] ABBAS R B, AREF A, ADDIN A H. Estimation of remaining useful life of rolling element bearings using wavelet packet decomposition and artificial neural network. *Iranian Journal of Science and Technology Transactions of Electrical Engineering*, 2019, 43(1): 233 – 245.
- [15] LASHERAS F S, NIETO P J G, DE COS JUEZ F J, et al. A hybrid PCA/CART/MARS-based prognostic approach of the remaining useful life for aircraft engines. *Sensors*, 2015, 15(3): 7062 – 7083.
- [16] HUANG H Z, WANG H K, LI Y F, et al. Support vector machine based estimation of remaining useful life: current research status and future trends. *Journal of Mechanical Science and Technology*, 2015, 29(1): 151 – 163.

- [17] GUO L, LI N P, JIA F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings. *Neurocomputing*, 2017, 240: 98 – 109.
- [18] ZHANG Z X, GEIGER J, POHJALAINEN J, et al. Deep learning for environmentally robust speech recognition. *ACM Transactions on Intelligent Systems and Technology*, 2018, 9(5): 1 – 28.
- [19] HE M, HE D. Deep learning based approach for bearing fault diagnosis. *IEEE Transactions on Industry Applications*, 2017, 53(3): 3057 – 3065.
- [20] KHAN S, YAIRI T. A review on the application of deep learning in system health management. *Mechanical Systems and Signal Processing*, 2018, 107: 241 – 265.
- [21] GUO L, LEI Y G, LI N P, et al. Deep convolution feature learning for health indicator construction of bearings. *Prognostics and System Health Management Conference (PHM-Harbin)*. Harbin: IEEE, 2017: 1 – 6.
- [22] HU Y, PALME T, FINK O. Deep health indicator extraction: a method based on auto-encoders and extreme learning machines. *Annual Conference of the Prognostics and Health Management Society*. Denver, CO: PHM Society Conference, 2016: 1 – 7.
- [23] LIAO L X, JIN W J, PAVEL R. Enhanced restricted boltzmann machine with prognosability regularization for prognostics and health assessment. *IEEE Transactions on Industrial Electronics*, 2016, 63(11): 7076 – 7083.
- [24] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks. *Science*, 2006, 313(5786): 504 – 507.
- [25] DECELLE A, FISSORE G, FURTLEHNER C. Thermodynamics of restricted boltzmann machines and related learning dynamics. *Journal of Statistical Physics*, 2018, 172(6): 1576 – 1608.
- [26] FU Y, ZHANG Y, QIAO H, et al. Analysis of feature extracting ability for cutting state monitoring using deep belief networks. *The 15th CIRP Conference on Modelling of Machining Operations (CMMO)*. Karlsruhe: Procedia CIRP, 2015, 31: 29 – 34.
- [27] LI Benwei, LIN Xuesen, YANG Xinyi, et al. Research on application of deep belief networks on engine gas path component performance degradation defect diagnostics. *Journal of Propulsion Technology*, 2016, 37(11): 2173 – 2180.
(李本威, 林学森, 杨欣毅, 等. 深度置信网络在发动机气路部件性能衰退故障诊断中的应用研究. 推进技术, 2016, 37(11): 2173 – 2180.)
- [28] LEI Y G, LI N P, GUO L, et al. Machinery health prognostics: a systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing*, 2018, 104: 799 – 834.
- [29] KANG J S, ZHANG X H, ZHAO J M, et al. Gearbox fault prognosis based on CHMM and SVM. *The 2012 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering*. Chengdu: IEEE, 2012: 703 – 708.
- [30] RABINER L R. A tutorial on hidden Markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 1989, 77(2): 257 – 286.
- [31] LE T T, CHATELAIN F, BERENGUER C. Hidden Markov models for diagnostics and prognostics of systems under multiple deterioration modes. *Proceedings of the 24th European Safety and Reliability Conference (ESREL 2014)*. Wroclaw: CRC Press/Balkema, 2014: 1197 – 1204.
- [32] RAMASSO E, DENOEUX T. Making use of partial knowledge about hidden states in HMMs: an approach based on belief functions. *IEEE Transactions on Fuzzy Systems*, 2014, 22(2): 395 – 405.
- [33] ZHANG C, LIM P, QIN A K, et al. Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(10): 2306 – 2318.
- [34] MALHOTRA P, TV V, RAMAKRISHNAN A, et al. Multi-Sensor prognostics using an unsupervised health index based on LSTM encoder-decoder. 2016, *arXiv: 1608.06154*.
- [35] SAXENA A, GOEBEL K, SIMON D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation. *The 2008 International Conference on Prognostics and Health Management*. Denver, USA: IEEE, 2008: 1 – 9.
- [36] RAMASSO E, ROMBAUT M, ZERHOUNI N. Joint prediction of observations and states in time-series based on belief functions. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 2013, 43(1): 37 – 50.
- [37] LIANG Zeming, JIANG Hongquan, ZHOU Bingzhi, et al. Multi-variable similarity-based information fusion method for remaining useful life prediction. *Computer Integrated Manufacturing Systems*, 2018, 24(4): 813 – 819.
(梁泽明, 姜洪权, 周秉直, 等. 多参数相似性信息融合的剩余寿命预测. 计算机集成制造系统, 2018, 24(4): 813 – 819.)
- [38] BABU G S, ZHAO P, LI X L. Deep convolutional neural network based regression approach for estimation of remaining useful life. *The 21th International Conference on Database Systems for Advanced Applications (DASFAA)*. Dallas, USA: Springer, 2016: 214 – 228.

作者简介:

彭开香 教授, 目前研究方向为复杂工业系统的容错控制、故障诊断与预测, E-mail: kaixiang@ustb.edu.cn;

皮彦婷 硕士研究生, 目前研究方向为数据驱动的故障预测, E-mail: YantingPi@163.com;

焦瑞华 博士研究生, 目前研究方向为数据驱动的故障预测, E-mail: jorry0123@163.com;

唐 鹏 博士研究生, 目前研究方向为数据驱动的故障诊断, E-mail: gnepnat@163.com.