

基于深度信念网络的航空发动机维修等级决策

车畅畅, 王华伟, 刘伟

(南京航空航天大学 民航学院, 南京 210016)

摘 要: 准确的航空发动机维修等级决策, 能够避免过维修和欠维修, 在保证航空发动机运行安全的前提下节约维修成本。结合航空发动机状态监控信息和维修等级特点, 采用深度信念网络(DBN)算法, 挖掘状态监测及维修等级决策之间的深层次对应关系, 实现对维修等级的分类和预测。该模型通过 DBN 预训练和反向传播(BP)神经网络反向微调提取出样本特征, 从而提高维修等级预测准确率。以某航空公司 CF6 航空型发动机的状态参数和维修等级数据作为实例进行验证, 结果显示: 该模型能够通过构建多层网络结构挖掘出样本的更深层次信息, 在分类能力、决策准确性方面优于传统神经网络, 有较强的特征提取能力, 对维修等级分类有较高的正确率, 能得出更准确的维修等级决策结果, 避免因维修等级误判而带来不必要的损失。

关键词: 深度信念网络; 维修等级决策; 运行安全; 状态监控; 特征提取

中图分类号: V263.6

文献标志码: A

Maintenance level decision for aero-engine based on deep belief network

CHE Changchang, WANG Huawei, LIU Wei

(College of Civil Aviation,

Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: The accurate maintenance level decision can avoid the excessive maintenance and shortage of maintenance and save maintenance cost on the premise of ensuring the safe operation of aero-engine. To achieve the classification and prediction for maintenance level, monitor information and characteristics of maintenance level, using algorithm of deep belief network (DBN), were combined, excavating deep relationship between the condition monitoring and maintenance level decision making. The model can extract sample feature from DBN pretreatment and back propagation (BP) neural network reverse fine-tuning and improve the forecast accuracy of maintenance level. Taking the state parameters and maintenance level data of an airline CF6 engine as example, the analysis results showed that the model could excavate the deeper information of the sample through the construction of multi-layer network structure, which was superior to the traditional neural network in the classification ability and the accuracy of decision-making. So the model had strong ability of feature extraction and higher classification accuracy for the maintenance level. The model was able to get more accurate results maintenance level decision and avoided unnecessary losses due to misclassification of maintenance level.

Key words: deep belief network; maintenance level decision; safety operation;

收稿日期: 2016-12-01

基金项目: 国家自然科学基金青年基金(61401073)

作者简介: 车畅畅(1994—), 男, 硕士生, 主要从事可靠性与维修性研究。

通讯作者: 王华伟(1974—), 女, 教授、博士生导师, 博士, 主要从事航空安全方面研究。E-mail: wang_hw@163.com。

引用格式: 车畅畅, 王华伟, 刘伟. 基于深度信念网络的航空发动机维修等级决策[J]. 航空动力学报, 2018, 33(6): 1528-1536. CHE Changchang, WANG Huawei, LIU Wei. Maintenance level decision for aero-engine based on deep belief network[J]. Journal of Aerospace Power, 2018, 33(6): 1528-1536.

condition monitoring; feature extraction

航空发动机维修等级决策是航空发动机翼下管理的重要内容,对发动机维修后的性能、在翼寿命、航空发动机维修成本乃至航空公司运营成本控制都有重要影响。航空发动机通过状态监控来确保发动机的可靠性以及发动机功能状态,并根据航空发动机的状态信息确定其送修等级;送修等级越高,维修费用也将大幅增加。不能准确划分维修等级,将会出现过维修或欠维修问题,导致不必要的资金浪费,甚至影响运行安全。当前各航空公司确定单元体维修等级主要通过制造商提供的工作范围计划指导文件^[1] (workscope planning guide, WPG),由于 WPG 不能完全考虑到航空公司的实际情况,影响了维修等级决策的准确性。对于维修厂商而言,研究航空发动机送修等级决策分析模型等问题,有利于制定合理的、有效的送修工作范围,准确而快速地进行修理。对于航空公司而言,准确的维修等级决策不但能够降低维修成本,而且可以提高维修人员工作效率,从而节约运营成本。

国内外学者在维修等级决策领域开展了相关研究。谢海军、谢庆华等人^[2-3]通过数据挖掘的方法来研究维修等级决策,核心方法是基于监控参数和维修等级信息,使用变精度粗糙集、数据的离散化等方法提取规则,从而指导维修等级决策。王雄威^[4]通过分析航空公司已有的发动机状态参数和发动机维修等级之间的关系,提出基于最小二乘支持向量机挖掘模型,并使用粒子群算法对模型的参数进行优化处理。井立国等人^[5]结合灰色决策和模糊综合决策,从航空发动机故障维修历史数据出发,总结出灰色维修模糊决策方法。李欣玥等人^[6]用费用决策模型对系统研究,得出预防性维修间隔期,优化了各修理级别对应的工作组合情况,为各维修等级工作提供合理决策。索海波^[7]分析了影响维修等级的因素,在达到整机目标排气温度裕度(EGTM)恢复的情况下,建立了基于维修成本优化的航空发动机送修等级决策分析模型,用来合理地确定送修等级和相应工作。

Rastegari 等人^[8]建立了基于计算机的维修管理系统 (computerized maintenance management system, CMMS) 的维修决策模型,使用准则决策 (multi-criteria decision-making, MCDM) 技术、technique for order preference by similarity to an ideal solution (TOPSIS)、 k -均值聚类技术,根据影响机器的决定要素,从多个维修策略中得

出最佳维修决策。Mahmoodian 等人^[9]研究了大型软件系统的维修分类,利用朴素贝叶斯理论和决策树方法进行问题的分类,并使用 10 倍交叉验证评估了系统的性能,有效地提高了系统维修分类的准确性。Moreira 等人^[10]提出以预测飞机部件性能为基础的支持向量机 (support vector machine, SVM) 二元分类模型,根据飞行数据和维护日志来训练和测试模型,从飞机的空气管理系统的参数中提取一些特征进行分类,然后从分类结果中创建一个退化参数来进行维修决策。

上述研究存在着推导过程复杂、结果不够直观、缺乏软件集成等问题,影响了研究成果的应用和推广;同时维修等级的决策准确度受样本信息偏差的影响较大,算法模型不能充分挖掘样本的深层次信息,影响了结果的准确度。因此,针对航空发动机监测信息丰富、健康状况信息多样、运行速率高、安全性要求严格的特点,本文提出了能处理大数据、充分发掘样本特征信息的深度信念网络算法模型。

深度学习方法在语音识别^[11]、人脸识别^[12]等大数据分析上取得了很大成就。本文采用的基于深度学习的深度信念网络研究航空发动机维修等级决策,通过模拟人体大脑的学习过程,建立了深层网络模型来训练大量数据,从而发掘出数据中的隐含特征,提高分类和预测的准确度。目前在工程领域也有很大的应用前景。

1 基于状态监控的航空发动机维修等级决策

利用状态监测信息指导航空发动机维修等级决策的核心问题是有效处理状态监测的信息,并提取出有效的数据表征并挖掘出深层次的信息,从而高效利用数据、准确分类维修等级。

1.1 航空发动机状态监测信息

航空发动机的主要状态参数包括涡轮后燃气温度偏差 (DEGT)、低压转子振动偏差值 (ZVB1F)、高压转子转速偏差值 (DN2)、高压转子振动偏差值 (ZVB2R)、燃油消耗量偏差值 (DWF) 等。

航空公司将 DEGT 作为衡量发动机性能衰退的主要指标,以此作为航空发动机下发、更换和排队的依据。航空发动机巡航状态^[13]下监控高压转子和低压转子偏差值对及时发现发动机不良状态、预防飞行事故具有重要作用。控制燃油

消耗量不仅能够节约航空公司运营成本,还能及时发现潜在系统故障。

发动机故障与状态监控参数有一定相关性^[14]。如发动机压比(EPR)传感器故障,会使上述参数 DEGT、ZVB1F、DN2、ZVB2R、DWF 趋势同时增加或同时减小,变化量与 EPR 相关。如果 DEGT 和 DN2 的传感器故障,一般只会对自身参数产生影响,其他参数不会偏移。

对状态监控参数有较大影响的系统有:引气系统、可调静子叶片(variable stator vane, VSV)系统和涡轮间隙控制系统等。这些系统故障往往伴随着参数的较大偏移。例如涡轮间隙控制系统故障会导致涡轮效率降低,使 DEGT 和 DWF 增加, DN2 则会下降。VSV 系统对 DN2 影响较大,对 DEGT 和 DWF 影响较小, VSV 的调节会影响到高低压转子转速的匹配关系。引气系统故障会造成 DEGT、DWF 和 DN2 的增加。

1.2 航空发动机维修等级决策

航空发动机维修等级是指对发动机的维修深度,它决定了航空发动机送修范围。其核心问题是在确保系统可靠性和安全性的条件下,对成本和收益进行综合权衡,然后做出最佳的维修等级决策,从而实现及时、有效和经济的维修。维修等级决策^[6]分为整机级决策和单元体级决策。本文从整机级维修等级决策出发把航空发动机分为多个单元体,然后提取出每个单元体的特征量,进行维修等级决策。维修等级分为三级,随费用的增加依次分别是一般检查(VC)、性能恢复(POH)、翻修(OH)。其中 VC 适用于单元体没有明显硬件故障或性能问题的发动机, POH 用来恢复发动机排气温度(EGT)裕度以及降低燃油消耗率, OH 是对发动机零部件进行彻底的检查和修理。

2 基于深度信念网络的航空发动机维修等级决策

2.1 DBN 建模思路

深度信念网络模型^[15]结合了无监督学习和监督学习,能够直接从原始数据出发对特征进行分类识别,该方法省去了人工特征提取与优化过程,减少了人工参与因素,更加智能化。DBN 的流程图如图 1 所示,主要思路是首先输入样本到 DBN 开始无监督训练,然后使用 BP 神经网络有监督反向微调,最后把测试数据带到模型中统计出正确率。




图 1 DBN 流程图
Fig. 1 Flow chart of DBN

2.2 基于 DBN 的航空发动机维修等级决策流程

结合航空发动机的特点与深度学习的优势,本文建立了基于深度信念网络的航空发动机维修等级决策模型。通过深度信念网络对样本数据进行训练,建立维修等级与各状态参数之间的多层 DBN 模型。该模型能够从多维的大量样本中提取特征量,对样本进行分类,从而确定航空发动机的维修等级。

模型结构如图 2 所示。首先采集航空发动机状态监控信息和维修等级信息,并且初始化参数,再将训练数据输入到第一层受限波兹曼机(restricted Boltzmann machine, RBM),从第一层到高层逐层学习 DBN 中所有 RBM,在训练的过程中对参数不断进行修正更新,直到达到规定的迭代次数或者重构误差达到规定值;然后将训练好的网络参数输入到 BP 神经网络中,利用训练集的样本标签进行反向微调;最后把测试集输入到训练好的网络中,并且把分类好的结果和测试集的标




图 2 基于 DBN 的航空发动机维修等级决策流程图
Fig. 2 Flow chart of aero-engine maintenance level decision based on DBN

签进行比较得出正确率。

3 基于深度信念网络的航空发动机维修等级算法

3.1 DBN 理论

深度信念网络是有多层感知器的神经网络。它由一系列 RBM^[16] 堆叠而成的。RBM 结构图如图 3 所示,每个 RBM 由可视层和隐藏层组成,层与层之间通过权值连接,层内无连接。其中 n 和 m 分别表示可视层和隐藏层的神经元个数; w 表示可视层与隐藏层间的权值矩阵; v 表示可视层状态向量; h 表示隐藏层状态向量; b 和 a 是偏置向量。其中 $i \in [1, n], j \in [1, m], w_{ij}$ 为可视层节点 i 与隐藏层节点 j 之间的连接权重值; v_i 表示可视层第 i 个神经元的状态, h_j 表示隐藏层第 j 个神经元的状态, a_i, b_j 分别是可视层、隐含层的偏置值。




图 3 RBM 结构图

Fig. 3 Structure diagram of RBM

RBM 中的神经元均为二维随机单元,即对于 $\forall i, j$, 都有 $v_i \in \{0, 1\}, h_j \in \{0, 1\}$, 因此可定义该 RBM 能量函数

$$E(v, h; \theta) = -v^T w h - b^T v - a^T h - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m w_{ij} v_i h_j \quad (1)$$

定义 $\theta = \{w, a, b\}$, 由能量函数可以得到可视单元 v 和隐藏单元 h 的联合概率分布函数

$$P(v, h; \theta) = \frac{1}{Z(\theta)} \exp[-E(v, h; \theta)] \quad (2)$$

其中

$$Z(\theta) = \sum_{v, h} \exp[-E(v, h; \theta)] \quad (3)$$

由式(2)可以得到可视单元 v 和隐藏单元 h 的条件分布:

$$P(v|h; \theta) = \frac{P(v, h; \theta)}{P(h; \theta)} = \frac{\frac{1}{Z(\theta)} \exp[-E(v, h; \theta)]}{\frac{1}{Z(\theta)} \sum_v \exp[-E(v, h; \theta)]} = \prod_i P(v_i | h; \theta) \quad (4)$$

同理可得

$$P(h|v; \theta) = \prod_j P(h_j | v) \quad (5)$$

由于状态向量 v, h 中的神经元为二维随机单元,所以可以推导出已知可视层 v , 隐藏层单元 h_j 被激活(即取值为 1)的概率为

$$P(h_j = 1 | v) = \delta \left[a_j + \sum_{i=1}^n w_{ij} v_i \right] \quad (6)$$

同理可得已知隐藏层, 可视层单元被激活的概率为

$$P(v_i = 1 | h) = \delta \left[b_i + \sum_{j=1}^m w_{ij} h_j \right] \quad (7)$$

其中 $\delta(x) = 1/(1 + e^{-x})$ 称为 Sigmoid 函数。RBM 采用迭代的方式进行训练, 训练的目标在于学习出参数 $\theta = \{w, a, b\}$ 的值, 以拟合给定的训练数据。用最大似然函数表示为

$$L(\theta) = \prod_v L(\theta | v) = \prod_v P(v) \quad (8)$$

采用随机梯度上升法优化参数 θ , 其迭代公式为

$$\theta = \theta + \epsilon \cdot \frac{\partial \ln L}{\partial \theta} \quad (9)$$

其中 ϵ 为预训练的学习率。然后采用对比散度算法对重构数据进行近视采样, 可以得到参数 θ 的迭代更新公式

$$\Delta w_{ij} = \epsilon (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}}) \quad (10)$$

$$\Delta a_i = \epsilon (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}}) \quad (11)$$

$$\Delta b_j = \epsilon (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}}) \quad (12)$$

其中 $\langle \rangle_{\text{data}}$ 为训练样本集定义的概率分布上的数学期望; $\langle \rangle_{\text{recon}}$ 为重构模型所定义的概率分布上的期望。

3.2 DBN 训练步骤

DBN 的训练过程是基于对比散度的 RBM 算法, 其步骤^[17]如下:

1) 设置参数。学习率 ϵ 、网络层数、节点数。输入训练集 $x = (x_1, x_2, x_3, \dots, x_n)$ 。

2) 用极小值随机赋值于参数 θ 。设置初始可视层状态为 $v^{(1)} = x$ 。小标 1 代表训练次。

3) 开始第 1 次训练, 用式(6)求出各隐藏节点的 $P(h_j^{(1)} = 1 | v^{(1)})$ 并从中抽样出 $h_j^{(1)} \in \{0, 1\}$ 即 $h^{(1)}$ 层的状态。

4) 已知 $h^{(1)}$, 利用式(7)求出 $P(v_i^{(2)} = 1 | h^{(1)})$ 并得出 $v^{(2)}$ 的状态。

5) 开始第 2 次训练, 已知 $v^{(2)}$ 再用式(6)求 $P(h_j^{(2)} = 1 | v^{(2)})$ 并抽样出 $h^{(2)}$ 的状态。

6) 已知两次训练的状态参数, 利用式(10)~

式(12)进行参数更新

$$\boldsymbol{w} = \boldsymbol{w} + \epsilon \{ [P(h_j^{(1)} = 1 | \boldsymbol{v}^{(1)})] (\boldsymbol{v}^{(1)})^T - P(h_j^{(2)} = 1 | \boldsymbol{v}^{(2)}) (\boldsymbol{v}^{(2)})^T \}$$

(13)

$$\boldsymbol{a} = \boldsymbol{a} + \epsilon (\boldsymbol{v}^{(1)} - \boldsymbol{v}^{(2)})$$

(14)

$$\boldsymbol{b} = \boldsymbol{b} + \epsilon [P(h_j^{(1)} = 1 | \boldsymbol{v}^{(1)}) - P(h_j^{(2)} = 1 | \boldsymbol{v}^{(2)})]$$

(15)

7) 重复第 3 步到第 6 步,完成规定迭代次数的参数更新。在训练完该层 RBM 后,把最后一次迭代后得到的 $\boldsymbol{h}^{(2)}$ 作为下一个 RBM 的 $\boldsymbol{v}^{(1)}$,然后训练下一层 RBM。

3.3 误差分析

根据文中第 3.2 节得出的各变量的条件概率分布,可以通过 Gibbs 抽样得出重构样本,通过比较重构样本与原始样本的差异得出 RBM 训练的重构误差(e)^[18],用下式表示:

$$e = \sum_{t=1}^T \|x - \bar{x}_t\|$$

(16)

其中 x 为原始样本; $\bar{x}_t$ 为重构样本; T 为进行重构的迭代次数。

3.4 BP 反向微调

RBM 训练过程属于无监督学习,BP 神经网络的训练过程为有监督学习。把 RBM 训练得到的网络参数作为 BP 神经网络的输入,根据已知样本的状态标签逐步反向重新调整 DBN 模型的参数,使模型结果达到全局最优化,这个过程称为向后微调学习。通过 BP 反向微调,结合了无监督学习和有监督学习的优势,用 RBM 能对无标签样本预处理,然后通过 BP 神经网络对有标签样本的处理对整个 DBN 进行优化。

4 实例分析

本文采集并仿真了某航空公司近几年期间 CF6 型发动机的状态参数及送修等级信息^[19]。每个样本的维修等级包括 VC(一般检查)、POH(性能恢复)、OH(翻修)3 级。本文共采用了 900 个样本。样本参数特征如表 1 所示。

从表 1 中可以看出,各参数范围都有所重叠,直接提取参数特征显然不可能。因此把数据带入到 DBN 中进行处理。

4.1 MATLAB 算法实现

DBN 的训练和测试过程用 MATLAB 编程实现。首先把收集到的样本随机分组成训练集和测试集,其中以五维矩阵 $\boldsymbol{r}_1$ 作为训练集的输入样

表 1 样本统计表

Table 1 Sample statistics list

状态参数	VC	POH	OH
DEGT	6.02~10.8	-6.99~9.46	-1.57~21.6
DN2	0.01~0.47	-0.12~0.62	-0.65~0.52
DWF	-4.28~-2.06	-1.87~2.06	-3.15~5.47
ZVBIF	0.11~0.24	0.003~0.55	0.03~0.82
ZVB2R	0.06~0.08	0.04~0.42	0.06~0.56

本,代表 5 个状态监控参数。以三维矩阵 $\boldsymbol{u}_1$ 作为训练集样本标签,代表 3 个维修等级,矩阵采用二进制编号;然后建立五维矩阵 $\boldsymbol{q}_1$ 作为测试集,三维矩阵 $\boldsymbol{s}_1$ 为测试集样本标签。在训练过程中,首先将训练集 $\boldsymbol{r}_1$ 输入 RBM 中进行预训练,其次将训练得到的结果和样本标签 $\boldsymbol{u}_1$ 带入 BP 神经网络进行反向微调;最后将测试集 $\boldsymbol{q}_1$ 带入训练好的 DBN 中得出分类结果,然后把分类结果与 $\boldsymbol{s}_1$ 对比并统计正确率。

实验采用 600 个训练集,300 个测试集。训练集包括 150 个无标签样本。样本训练和测试过程见图 4,参数 $\boldsymbol{w}$ 、 $\boldsymbol{a}$ 、 $\boldsymbol{b}$ 矩阵各元素初值设为 0.1,学习率 ϵ 设置为 0.5。DBN 每层循环次数设为 100,BP 最大循环次数设为 3 000,DBN 输入层节点为 5,输出层节点为 3,层间节点数最大为 13,按照层数的多少共分为 6 组进行实验。




图 4 样本训练和测试图

Fig. 4 Flow chart of sample training and testing

4.2 结果与误差分析

以 5 层 DBN 的训练过程为例,节点数为[5 7 6 5 4 3],首先把训练集 r_1 带入到第 1 层 RBM 网络中得到训练后的参数 θ ,其中 $\theta=[w,a,b]$,按照式(13)~式(15)进行更新。可以得到 w 为元胞数组,包含 5 个矩阵,分别为 $5\times 7,7\times 6,$

$6\times 5,5\times 4,4\times 3$ 矩阵; a 和 b 每层训练都得到一维矩阵,每一列代表对应节点。对应结果如下所示。用式(16)计算对应重构误差为 0.003,其误差曲线见于图 5,误差曲线反映了迭代次数与重构误差的关系,如图 5 所示,在迭代循环 60 次时重构误差为 0.003,跳出循环。

$$w^T = \left[\begin{array}{c} \begin{bmatrix} 0.52 & -2.22 & -0.10 & -1.08 & 1.38 & -0.44 & 0.29 \\ 1.08 & -1.62 & 0.59 & 0.40 & -1.15 & 0.46 & 0.48 \\ -0.70 & -0.62 & 1.16 & 0.48 & 0.93 & 0.03 & -2.13 \\ 0.98 & 0.79 & -0.52 & 1.14 & 0.99 & 0.66 & -0.73 \\ 0.38 & 0.73 & 0.68 & 0.76 & 0.41 & -1.75 & -2.36 \end{bmatrix} \\ \begin{bmatrix} -2.35 & -0.17 & -0.73 & -0.01 & 1.36 & -0.02 \\ 2.16 & 0.42 & 0.05 & 0.80 & -1.82 & -1.12 \\ -1.94 & 0.54 & -2.49 & 0.60 & 1.51 & 0.50 \\ -0.51 & 0.49 & 0.06 & -0.32 & -0.19 & 0.85 \\ -0.72 & 0.92 & -1.63 & -0.58 & -0.58 & 0.33 \\ -2.77 & -0.72 & -2.46 & 0.56 & -0.06 & 0.56 \\ 0.49 & -1.82 & 0.91 & -0.32 & 1.46 & -0.47 \end{bmatrix} \\ \begin{bmatrix} -3.03 & -0.59 & -1.29 & -1.18 & -2.57 \\ -0.84 & -2.38 & -0.30 & -1.79 & 1.71 \\ -0.77 & 0.38 & -1.23 & -1.67 & -2.37 \\ 0.16 & -3.13 & 2.56 & -0.23 & -0.32 \\ -0.36 & -0.62 & 2.00 & -1.11 & 1.65 \\ 0.22 & -0.36 & 2.05 & -2.45 & 1.26 \end{bmatrix} \\ \begin{bmatrix} 0.56 & 0.20 & -1.69 & 2.17 \\ 0.16 & -0.58 & -1.45 & -3.58 \\ 1.74 & 1.54 & 2.59 & -0.34 \\ -2.54 & 0.07 & -1.07 & -1.56 \\ 0.34 & -0.74 & 0.80 & 3.37 \end{bmatrix} \\ \begin{bmatrix} -1.86 & 2.25 & -0.55 \\ -2.22 & -0.90 & -0.52 \\ -1.22 & 1.73 & -0.12 \\ 1.53 & 3.92 & 1.05 \end{bmatrix} \end{array} \right] \tag{17}$$

$$b^T = \left[\begin{array}{c} [-0.15 \quad -1.83 \quad 0.62 \quad -1.42 \quad -1.82 \quad 0.81 \quad 0.004] \\ [-1.64 \quad 0.37 \quad -2.21 \quad 2.02 \quad 2.21 \quad 1.75] \\ [0.65 \quad -0.91 \quad 0.11 \quad -0.52 \quad 0.80] \\ [0.20 \quad 0.17 \quad 0.95 \quad 0.36] \\ [-1.38 \quad -0.03 \quad -0.86] \end{array} \right] \tag{18}$$

$$a^T = \left[\begin{array}{c} [0.273 \quad 0.1865 \quad -0.012 \quad 0.222 \quad 0.2] \\ [-0.10 \quad -1.75 \quad 0.68 \quad -1.49 \quad -1.76 \quad 0.78 \quad 0.01] \\ [-1.68 \quad 0.64 \quad -2.17 \quad 2.05 \quad 2.19 \quad 1.79] \\ [0.66 \quad -0.75 \quad 0.01 \quad -0.54 \quad 0.82] \\ [0.21 \quad 0.19 \quad 0.94 \quad 0.36] \end{array} \right] \tag{19}$$




图 5 重构误差图

Fig. 5 Graph of reconstruction error

将上述参数和训练样本 r_1 以及对应的维修等级标签 u_1 带入到 BP 神经网络中,使多层 RBM 提取出的样本特征与维修等级相匹配,从而得出最终训练的 w 结果如下。由于训练次数较多以及初始误差较大,因此误差图选取其局部误差数据,如图 6 所示。经过 BP 反向微调得到的 BP 误差为 0.157,BP 误差越小,说明提取的样本特征与维修等级标签的匹配度越高。

然后把测试集 q_1 带入到完成参数优化、训练完成的 DBN 中可得出维修等级的分类结果,把结果与 s_1 对比可得正确率为 99.17%。

$$w^T = \begin{bmatrix} \begin{bmatrix} 2.96 & -2.75 & -0.09 & 0.30 & 5.79 & -3.25 & 2.73 \\ 3.99 & -2.22 & 2.18 & 2.31 & -6.28 & -2.96 & -0.66 \\ -2.78 & 1.89 & 1.89 & -0.52 & 0.04 & 1.46 & -7.66 \\ 0.58 & 1.96 & 1.77 & 1.55 & 1.18 & 4.02 & -3.37 \\ -0.63 & 1.41 & -3.86 & 1.16 & 0.06 & 0.45 & -7.92 \end{bmatrix} \\ \begin{bmatrix} -2.34 & -3.93 & -0.67 & 0.52 & 1.36 & 0.00 \\ 2.16 & 2.86 & 0.05 & -0.13 & -1.85 & -1.19 \\ -1.91 & 3.07 & -2.44 & -0.88 & 1.46 & 0.38 \\ -0.50 & 2.65 & 0.08 & -1.83 & -0.19 & 0.84 \\ -0.70 & 5.13 & -1.62 & -2.22 & -0.60 & 0.12 \\ -2.76 & -3.36 & -2.44 & 0.23 & -0.12 & 0.57 \\ 0.49 & -6.48 & 0.95 & 1.55 & 1.44 & -0.51 \end{bmatrix} \\ \begin{bmatrix} -3.03 & -0.59 & -1.29 & -1.18 & -2.58 \\ -9.93 & -2.38 & -0.37 & -1.81 & 7.59 \\ -0.74 & 0.38 & -1.23 & -1.67 & -2.41 \\ 2.83 & -3.10 & 2.54 & -0.25 & -2.51 \\ 1.10 & -0.58 & 1.95 & -1.12 & -0.10 \\ 1.16 & -0.32 & 2.01 & -2.47 & 0.18 \end{bmatrix} \\ \begin{bmatrix} 9.15 & 7.00 & -6.05 & 0.86 \\ 0.18 & -0.46 & -1.48 & -3.59 \\ 1.71 & -1.26 & 0.84 & -0.78 \\ -2.48 & 0.28 & -1.12 & -1.58 \\ -6.09 & -8.42 & 1.88 & 4.39 \end{bmatrix} \\ \begin{bmatrix} -6.04 & 5.65 & 0.23 \\ -5.79 & -7.64 & 9.79 \\ 5.56 & -1.47 & -3.71 \\ 4.97 & 2.55 & -1.01 \end{bmatrix} \end{bmatrix} \tag{20}$$

为确定 DBN 的最佳层数,避免由于层数的增多陷入局部最优,采用试算法根据 DBN 层数的不同,分为 6 组,每组做 3 次实验,得出的训练结果如表 2 所示。

然后对表 2 的结果建立更加直观的立体图见

图 7 所示,每组 DBN 用不同颜色表示,可以看出每次实验正确率、DBN 重构误差、BP 误差的关系。从图中可以看出浅蓝色的 5 层 DBN 重构误差和 BP 误差都较小并且有最大正确率,同时运行时间也较短,因此选取 5 层 DBN 作为最终选取




图 6 BP 误差图

Fig. 6 Graph of BP error

表 2 DBN 训练结果
Table 2 DBN training results

层数	正确率/%	重构误差	BP 误差	时间/s
3	98.50	0.018	0.373	129
4	98.22	0.007	0.243	128
5	99.17	0.003	0.157	111
6	98.17	0.008	8.050	120
7	98.06	0.022	18.43	171
8	97.94	0.025	28.70	194




图 7 DBN 层数、正确率和 BP 误差关联图

Fig. 7 Correlation diagram among DBN layers,
correct rate and BP error

的网络模型。

4.3 实验对比

首先,从网络结构进行对比,建立多层 BP 神经网络,按照 DBN 的节点和层数设置分为 6 组,代入有标签训练样本并统计正确率,然后与 DBN 对比,见于表 3。可以看出 DBN 每组的实验正确率都高于 BP 神经网络,DBN 比 BP 神经网络有更好的特征提取和决策能力。

表 3 正确率统计表
Table 3 Statistical table of accuracy

层数	平均正确率/%	
	BP	DBN
3	93.58	98.50
4	94.00	98.22
5	94.50	99.17
6	93.83	98.17
7	92.58	98.06
8	91.33	97.94

其次,从网络功能上对比,选取具有良好泛化能力,能够处理复杂非线性关系的径向基神经网络,它只含有 1 个隐层,隐层节点激活函数为径向基函数,输出层节点激活函数为线性函数。代入训练集到径向基神经网络并统计结果可得其维修等级分类正确率为 92%。

最后,提取正确率较高的 5 层 DBN、5 层 BP 神经网络、径向基网络的实验结果,并统计其中过维修和欠维修次数,见表 4,可以看出无论是从网络层数设置,还是从网络功能,DBN 都比传统神经网络有更好的特征提取能力和维修等级决策,能够有效地减少过维修和欠维修次数,提高维修决策正确率。

表 4 测试结果统计表
Table 4 Statistical table of test results

统计结果	DBN	BP	径向基
过维修	4	19	17
欠维修	1	14	31
准确数	595	567	552
总数	300	300	300
正确率/%	99.17	94.5	92

5 结 论

本文对航空发动机状态监控数据和维修记录进行收集分析,运用了 RBM 原理,构建了 DBN-BP 模型,对航空发动机维修等级进行分类。通过对模型的训练和测试,选择出最佳 DBN 层数和变量参数。通过与其他模型对比,结果表明:DBN 模型在挖掘深层次信息、分类能力、决策准确性方面优于传统神经网络,能够准确地得出维修等级决策,从而避免因维修等级误判而带来的

不必要的损失。

参考文献:

- [1] 付旭云,钟诗胜.民用航空发动机单元体送修工作范围决策[J].航空动力学报,2010,25(10):2195-2200.
FU Xuyun, ZHONG Shisheng. Civil aero-engine module workscope decision-making[J]. Journal of Aerospace Power, 2010, 25(10): 2195-2200. (in Chinese)
- [2] 张海军.民航发动机性能评估方法与视情维修决策模型研究[D].南京:南京航空航天大学,2007.
ZHANG Haijun. Research on methods of performance synthetic estimation and CBM decision-making models for aero-engine[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2007. (in Chinese)
- [3] 谢庆华,梁剑.基于变精度粗糙集的航空发动机送修等级决策[J].系统工程理论方法应用,2006,15(4):380-384.
XIE Qinghua, LIANG Jian. Studies on maintenance level decision of aero-engine based on variable precision rough sets theory[J]. System Engineering Theory Methodology Application, 2006, 15(4): 380-384. (in Chinese)
- [4] 王雄威.基于性能参数预测的航空发动机维修决策支持系统研究[D].哈尔滨:哈尔滨工业大学,2013.
WANG Xiongwei. Aeroengine maintenance decision support system development based on performance parameters prediction[D]. Harbin: Harbin Institute of Technology, 2013. (in Chinese)
- [5] 井立国,王端民.航空发动机维修灰色模糊决策方法研究[J].黑龙江大学自然科学学报,2009,26(3):342-346.
JING Ligu, WANG Duanmin. Study on grey fuzzy relation decision-making method of aero engine maintenance [J]. Journal of Natural Science of Heilongjiang University, 2009, 26(3): 342-346. (in Chinese)
- [6] 李欣玥,贾云献.基于预防性维修工作组合的维修等级优化研究[J].指挥控制与仿真,2012,34(1):115-158.
LI Xinyue, JIA Yunxian. Study on optimal maintenance level based on preventive group maintenance police[J]. Command Control and Simulation, 2012, 34(1): 115-158. (in Chinese)
- [7] 索海波. CFM56 发动机送修等级决策分析模型研究[D].四川 广汉:中国民用航空飞行学院,2012.
SUO Haibo. Analysis model studies on maintenance level decision of CFM56 engine[D]. Guanghan, Sichuan: Civil Aviation Flight University of China, 2012. (in Chinese)
- [8] RASTEGARI A, MOBIN M. Maintenance decision making, supported by computerized maintenance management system[C]//Reliability and Maintainability Symposium. Tucson, Arizona, US: IEEE, 2016: 1-8.
- [9] MAHMOODIAN N, ABDULLAH R, MURAD M A A. Text-based classification incoming maintenance requests to maintenance type[C]//Proceedings of International Symposium in Information Technology. Kuala Lumpur, Malaysia: IEEE, 2010: 693-697.
- [10] MOREIRA R D P, NASCIMENTO C L. Prognostics of aircraft bleed valves using a SVM classification algorithm [C]//Proceedings of Aerospace Conference. Big Sky, US: IEEE, 2012: 1-8.
- [11] AHMED M, SHILL P C, ISLAM K, et al. Acoustic modeling using deep belief network for Bangla speech recognition[C]//Proceedings of International Conference Computer and Information Technology. Dhaka, Bangladesh: IEEE, 2016: 306-311.
- [12] LIN M, FAN X. Low resolution face recognition with pose variations using deep belief networks[C]//Proceedings of International Congress on Image and Signal Processing. Shanghai: IEEE, 2011: 1522-1526.
- [13] 同峰,付为刚.航空发动机高压转子转速(N2)基线的建模方法[J].机械设计与制造,2015(1):148-151.
YAN Feng, FU Weigang. A modeling method for high compressor rotor speed(N2) baseline of the aero-engine [J]. Machinery Design and Manufacture, 2015(1): 148-151. (in Chinese)
- [14] 瞿红春.民用涡扇发动机健康智能监控技术的研究[D].天津:天津大学,2010.
QU Hongchun. Study on civil turbofan engine health intelligent monitoring technologies[D]. Tianjin: Tianjin University, 2010. (in Chinese)
- [15] LIN X S, LI B W, YANG X Y. Engine components fault diagnosis using an improved method of deep belief networks[C]//Proceedings of International Conference on Mechanical and Aerospace Engineering. London: IEEE, 2016: 454-459.
- [16] UEYOSHI K, MARUKAME T, ASAI T, et al. Memory-error tolerance of scalable and highly parallel architecture for restricted Boltzmann machines in deep belief network [C]//International Symposium on Circuits and Systems. Montreal, Canada: IEEE, 2016: 357-360.
- [17] 单外平.基于深度信念网络的变速器故障分类识别研究[D].广州:华南理工大学,2015.
SHAN Waiping. Classification and recognition of transmission fault based on deep belief network[D]. Guangzhou: South China University of Technology, 2015. (in Chinese)
- [18] 黄海波,李人宪.基于 DBNs 的车辆悬架减振器异响鉴别方法[J].西南交通大学学报,2015,50(5):776-782.
HUANG Haibo, LI Renxian. Identifying abnormal noise of vehicle suspension shock absorber based on deep belief networks[J]. Journal of Southwest Jiaotong University, 2015, 50(5): 776-782. (in Chinese)
- [19] ZHANG H J, ZUO H F, ZHU S. Study on maintenance level decision-making and continuous data discretization for aero-engine[C]//Proceedings of 2nd International Conference on Information Science and Engineering. Wuhan: IEEE, 2011: 5455-5457.

(编辑:陈 越)