

基于机器学习算法的寿命预测与故障诊断技术的发展综述

郭一帆, 唐家银

(西南交通大学 数学学院统计系, 成都 611756)

摘要: 寿命预测与故障诊断作为复杂装备系统可靠性分析中的两类重要问题, 基于数据驱动的机器学习分析方法具有良好的工程效果; 文章系统地从事故障预测与寿命估算及后续健康管理的实际工程需求出发, 深入分析该类型系统因性能衰退出现的早期故障诊断与维护时间确定的共性难点问题并深度挖掘其所对应的关键科学问题, 对机器学习算法在其中的应用与研究进行综述, 重点阐述了人工神经网络、支持向量机等机器学习算法, 对于完善可靠性分析方法, 进一步推动机器学习算法在可靠性工程领域的运用具有一定的指导意义。

关键词: 机器学习; 寿命预测; 故障诊断; 可靠性

A Review of The Development of Life Prediction and Fault Diagnosis Technology Based on Machine Learning Algorithm

Guo Yifan, Tang Jiayin

(Department of Statistics, College of Mathematics, Southwest Jiaotong University, Chengdu, Sichuan 611756)

Abstract: Life prediction and fault diagnosis are two important problems in the reliability analysis of complex equipment systems, and The data-driven machine learning analysis method has good engineering effects. Based on the actual engineering requirements of fault prediction, life estimation and subsequent health management, this paper systematically analyzes the common emblems of early fault diagnosis and maintenance time determination due to performance degradation and deeply explores the key scientific problems. We review the application and research of machine learning algorithms, and focuses on machine learning algorithms such as artificial neural networks and support vector machines. It is necessary to improve the reliability analysis method and further promote the application of machine learning algorithms in the field of reliability engineering.

Keywords: Machine Learning; Life prediction; Fault diagnosis; Reliability

0 引言

寿命预测与故障诊断是可靠性分析中的两大基本问题。寿命预测, 也被称为剩余服役寿命预测或剩余使用寿命预测, 指在规定的运行工况下, 能够保证机器安全、经济运行的剩余时间, 而在可靠性工程中的寿命预测是进行预测与健康管理的核心技术, 是减少生产损失的方法, 可以节省维护成本。故障诊断则是指故障检测和故障隔离这两个过程, 其中利用各种检查和测试方法, 发现系统和设备是否存在故障的过程是故障检测; 故障隔离则是要求把故障定位到实施修理时可更换的产品层次(可更换单位), 因此故障诊断可以判定出设备故障类型与故障部位, 从而对设

备进行维修, 减少由于设备停运时间过长而造成的损失。

针对不同的时期, 寿命预测分为早期预测和中晚期预测^[1]。在可靠性工程领域中, 早期寿命预测能确定设备的设计(计算)寿命, 中期预测则是通过实况监测还处于设计寿命中的设备从而实现对其寿命的预测, 从而达到避免设备在使用期间出现意外情况的目的; 采用晚期预测是因为设计寿命往往都会比较保守, 设备还没有得到充分利用就会被认为已经到达使用寿命, 这样一来就会造成很大的经济浪费, 因此需要利用晚期预测对累计使用时间已经超过设计寿命的设备进行寿命预测。目前寿命预测的方法大体可以划分为三类: 基于力学的寿命预测方法、基于概率统计的寿命预测方法、基于信息新技术的寿命预测方法^[2]。从本质上来看, 基于力学的寿命预测方法是从动力学特性(失效和破坏机制)上来进行寿命预测, 可是当多失效模式发生耦合情况的时候, 该方法运用起来就得稍显吃力; 根据积累的数据(试验数据与现场数据)来建立统计模型, 通过确定寿命分布的特征值以及失效概率, 在指定可靠度下预测寿命是基于概率统计的寿命预测方法, 但此方法的前提是大量的试验和数据的积累。而如今的数

收稿日期: 2018-12-26; 修回日期: 2019-01-10。

基金项目: 中国铁路总公司科技研究开发计划项目(2017J003-H); 四川省统计科学研究计划项目资助(2016sc50); 中央高校基本科研业务费专项资助(2682018ZT25)。

作者简介: 郭一帆(1994-), 女, 重庆潼南人, 硕士研究生, 主要从事应用统计, 可靠性理论与工程方向的研究。

通讯作者: 唐家银(1976-), 男, 安徽无为, 博士, 副教授, 主要从事应用统计, 可靠性理论与工程方向的研究。

据都来源于试验技术：真实的现场试验以及在实验室进行模拟或加速试验，这两种获取数据的方法都是使用产品原型进行试验，普通类型的机械产品适合这两种常规方法，而对于小批量生产的重大机械装备，其造价昂贵，供货时间也长，因而常规的大样本试验方法是非常不合适的，这个时候就需要采用基于信息新技术的寿命预测方法，做到同时兼顾大/小样本数据达到寿命预测的目的。

在可靠性工程中进行故障诊断的步骤：首先判定设备有无故障，接着分析原因，确定故障类型，最后划分故障类别，诊断出设备具体的故障部位以及故障原因，为恢复故障设备做准备。目前，故障诊断的方法也大致分成三类：基于解析模型的故障诊断方法、基于信号处理的故障诊断方法以及基于人工智能的故障诊断方法^[3]。发展最早、研究最系统的故障诊断方法是基于解析模型的故障诊断方法，它能够深入系统本质的动态性质和实时诊断，但是很难获得一个系统模型，同时由于建模中有误差、扰动和噪声，使得鲁棒性问题渐渐凸显；基于信号处理的方法尽管易于实现、实时性也比较好，但在对潜在的故障进行诊断的时候就会凸显其不足之处，因此往往将其用于故障检测。而基于人工智能的故障诊断方法能够克服对于模型的过分依赖性，也能对潜在的故障进行诊断，从而提高故障诊断的精度。

当前处于大数据时代，基于信息新技术的寿命预测方法与基于人工智能的故障诊断方法几乎都是利用机器学习算法来进行，但随着技术的不断进步，机器学习算法的种类也在不断增加，因此本文总结了目前在寿命预测与故障诊断中最常用的几种机器学习算法，分析了现有研究的不足，展望未来的研究重点和发展趋势。

1 机器学习算法简介

机器学习，即是通过自主学习大量数据中存在的规律，获得新经验和知识从而提高计算机智能，使得计算机拥有类似人类的决策能力。

基于学习形式的不同通常可将机器学习算法分为监督学习 (Supervised Learning)、无监督学习 (Unsupervised Learning) 以及强化学习 (Reinforcement Learning) 三类：

(1) 监督学习 (Supervised Learning)：给学习算法提供标记的数据和所需的输出，对于每一个输入，学习者都被提供了一个回应的目标。监督学习主要被应用于快速高效地教熟 AI (Artificial Intelligence) 现有的知识，被用于解决分类和回归的问题。常见的算法有：决策树、Ada-boost 算法、人工神经网络算法 (Artificial Neural Networks, ANN)、支持向量机 (Support Vector Machine, SVM)、朴素贝叶斯、K 近邻、逻辑回归、随机森林。

(2) 无监督学习 (Unsupervised Learning)：给学习算法提供的数据是未标记的，并且要求算法识别输入数据中的模式，主要是建立一个模型，用其试着对输入的数据进

行解释，并用于下次输入。现实情况下往往很多数据集都有大量的未标记样本，有标记的样本反而比较少。如果直接弃用，很大程度上会导致模型精度低。这种情况解决思路往往是结合有标记的样本，通过估计的方法把未标记样本变为伪的有标记样本，所以无监督学习比监督学习更难掌握。主要用于解决聚类 and 降维问题，常见的算法有：聚类算法 (K 均值、Expectation Maximization 算法、Affinity Propagation 聚类、层次聚类)、降维算法 (主成分分析、局部线性嵌入降维算法)。

(3) 强化学习 (Reinforcement Learning) 该算法与动态环境相互作用，把环境的反馈作为输入，通过学习选择能达到其目标的最优动作。强化学习这一方法背后的数学原理与监督/非监督学习略有差异。监督/非监督学习更多地应用了统计学，而强化学习更多地结合了离散数学、随机过程这些数学方法。常见的算法有：TD (λ) 算法、Q-learning 算法。

监督学习、无监督学习、强化学习三类方法的主要区别点见表 1。

表 1 三类机器学习算法的比较

机器学习算法分类	应用学科	用途	数据有无标签
监督学习	统计学	预测、分类等	有
无监督学习	统计学	聚类、降维、异常检测等	无
强化学习	离散数学、随机过程等	机器人的自动控制、游戏的人工智能等	不依赖数据标签，有无没有影响

2 机器学习算法在寿命预测中的应用与发展

目前，机器学习算法在寿命预测中应用最多是基于人工神经网络与支持向量机，并在这些算法的基础上灵活运用其他算法或模型进行优化改进，从而提高寿命预测的精度。

自 20 世纪 80 年代以来，人工神经网络 (又被称为神经网络或类神经网络) 逐渐成为了人工智能领域兴起的研究热点，是从信息处理的角度出发，对人脑的神经网络进行抽象，从而建立起某种简单的模型，根据不同的连接方式组成不同的网络。人工神经网络属于一类运算模型，是由大量的节点 (神经元) 相互连接构成的，这里每一个节点都代表一种特定的输出函数，称其为激励函数；而每两个节点间的连接被称为权重，即对通过该连接信号的加权重值。网络的输出则随着网络的连接方式、权重值以及激励函数而改变。而网络自身往往是对自然界的某种算法、函数的逼近，或者是对一种逻辑策略的表达。由于现在已知的人工神经网络种类较多，因此目前在寿命预测中通常使用 BP (Back Propagation) 神经网络以及结合灰色模型与人

工神经网络模型的灰色神经网络, 也有少量采用其他人工神经网络如极限学习机 (Extreme Learning Machine, ELM)、递归神经网络 (Recurrent Neural Network, RNN) 等。在工程中的应用与研究, 仅采用 BP 神经网络有: 文献 [4-7] 通过 BP 神经网络分别建立起了继电器剩余寿命的关系模型、油浸式变压器固体绝缘老化模型, 机械密封寿命预测模型、AISI1045 钢材疲劳寿命预测模型, 都得到了较好的寿命预测结果; Elforjani Mohamed^[8] 等则通过对比实验发现 BP 神经网络预测声射技术机器的慢速轴承的剩余寿命的结果优于支持向量机与高斯回归过程。

但由于 BP 神经网络的初始权值和阈值是随机获取的, 容易导致训练陷入局部最优以及延长收敛时间, 因此往往需要用其他算法对 BP 神经网络进行优化改进。在应用与研究中常常与 BP 神经网络结合的算法有遗传算法、粒子群算法 (Particle Swarm Optimization, PSO), 文献 [9-12] 都是用遗传算法去优化 BP 神经网络分别预测了 LED、刀具、除湿机、液压支架的寿命, 发现其预测误差小, 普适度高; 文献 [13-15] 则是用粒子群算法优化网络权值及阈值, 分别对刀具寿命、电动机绝缘剩余寿命、电镀金刚石套钻使用寿命进行预测, 并证明了 PSO-BP 模型的预测精度较 BP 神经网络模型有一定的提高。也有采用其他算法进行改进的, 文献 [16-18] 都运用了 L-M (Levenberg-Marquardt) 算法去训练 BP 神经网络, 但很少有关注意到对算法本身进行改进之后再去训练神经网络, 而文献 [19] 则首先对 L-M 算法进行改进, 提出了一种采用了动态动量和阻尼 L-M 算法的混合优化算法, 再结合 BP 神经网络对轴承的剩余寿命进行了预测。当然, 除了 BP 神经网络以外, 工程中还存在其他种类的神经网络的应用与研究, 如 Zhang^[20] 等发现在预测刀具剩余寿命预测中, 模糊神经网络 (Neuro-Fuzzy Network, NFN) 的预测效果优于 BP 神经网络和径向基函数网络 (Radial Basis Function Network, RBFN); 杜占龙^[21] 等则针对多分类极限学习机缺乏概率输出能力的问题, 提出一种基于由 Platt^[22] 提出的 sigmoid 后验概率映射和 Lagrange 成对耦合法的多分类 ELM (Multi-class Probabilistic ELM, MPELM), 并将其用于剩余寿命预测, 实验结果表明, 相比于多分类概率支持向量机 (Multi-class Probabilistic Support Vector Machine, MPSVM), MPELM 耗时高于 MPSVM, 但 MPELM 所需优化参数少, 预测精度高于 MPSVM; 与基于 Hastie^[23] 成对耦合法的 MPELM 相比, 两者预测精度相近; Guo^[24] 等提出了一种基于递归神经网络的健康指标用于轴承的剩余寿命预测, 并从实验和工业领域收集的两个轴承数据集进行验证, 其结果表明, 改进后的模型具有较高的单调性和相关性, 提高了剩余寿命的预测精度。表 2 则详细梳理了以上文献中对于神经网络算法改进的具体创新点。

在工程中常用的机器学习算法除了人工神经网络之外,

表 2 神经网络算法在寿命预测中的改进

文献	创新点
[9-12]	把 BP 神经网络的初始权值和阈值作为染色体, 建立种群, 利用生物遗传特性 (复制、交叉、变异) 逐代进行选择, 高收敛精度与速度保证了搜索到全局范围内的最优解。
[13-15]	利用 PSO 算法全局随机最优解搜索的特性, 对传统 BP 神经网络模型的权值和阈值进行优化设计。
[19]	与以往仅仅用 LM 算法结合 BP 神经网络的文献 [16-18] 不同, 提出了一种采用了动态动量和阻尼 LM 算法的混合优化算法。
[21]	根据极限学习机在多分类问题中泛化能力强、所需优化参数少这两个优点, 提出基于多分类概率极限学习机的剩余使用寿命预测算法; 传统 ELM 不具备概率输出能力, 因此利用 Platt 提出的 sigmoid 后验概率映射算法, 将 ELM 的数值型输出映射为概率输出, 同时为克服 sigmoid 后验概率映射法只能用于二分类问题的局限性, 采用 Lagrange 成对耦合法融合所有的二分类概率输出。
[24]	基于许多现有的轴承健康指标存在以下两个缺点: (1) 由于这些统计特征的范围不, 许多统计特征对健康指标的构建没有相同的贡献; (2) 由于不同机器的健康指标在故障时通常不同, 因此难以确定故障阈值。为了克服这些缺点, 本文提出了一种基于递归神经网络的健康指标 (RNN-HI, Recurrent Neural Network based Health Indicator) 用于轴承的 RUL 预测。

还有支持向量机。支持向量机是 1995 年由 Vapnik 依据统计学习理论提出的一种基于结构风险最小化的二分类器。这里的结构风险最小化是指在保证经验风险 (即自检正确率) 的基础上, 优化分类函数的置信范围 (即分类函数的可推广性), 取得实际风险的最小。二分类器 (Binary Classifier): 采用两类样本 X_A 、 X_B 训练得到二分类器 SVM_{A-B} , 给定测试样本 X_T , SVM_{A-B} 能够判定 X_T 更可能属于类别 A 或是类别 B。介于只使用支持向量机所建寿命预测模型精度较低, 一般在工程运用中会将支持向量机与其他寿命预测模型或算法相结合, 从而提高预测精度: Chen^[25] 等提出了基于相似理论与 SVM 的航空发动机的剩余寿命预测模型, 并用数据验证了该模型的有效性; Gao 和 Huang^[26] 提出了一种基于多项式核和径向基核函数的新型多核 SVM, 并运用粒子群优化算法搜索模型的核参数, 惩罚因子和权重系数, 运用该模型去预测锂电池的剩余使用寿命, 并通过验证得到改进后的算法不仅具有更好的预测精度和更强的泛化能力, 而且还减少了训练时间和计算复杂度; 于震梁^[27] 等针对现有机械零件剩余寿命预测模型在建模过程中无法同时采用已有数据库数据及被预测产品实时退化数据, 提

出了一种基于 SVM 和非线性卡尔曼滤波相结合的机械零件剩余寿命预测模型, 并以某型号滚动轴承为例, 验证了所提出剩余寿命预测模型的精度、稳定性及工程应用价值; 王莉^[28]等则提出了一种新的电池寿命预测模型, 即基于最小二乘 SVM 的电池寿命预测, 并利用此预测模型对实验数据进行了比较验证, 验证结果表明, 该模型在阀控式铅酸蓄电池寿命预测中具有很好的实用性, 预测值与实测值能够保持很好的一致性, 因此, 基于最小二乘 SVM 的阀控式铅酸蓄电池寿命预测方法是切实可行的。表 3 详细梳理了以上应用与研究对 SVM 算法进行改进的具体创新点。

表 3 SVM 算法在寿命预测中的改进

文献	创新点
[25]	运用相似度的方法去进行寿命估计时的条件是足够多的故障数据, 而实际上存在样本数据是退化数据的情况, 因此提出了基于相似理论与 SVM 的新的寿命预测方法。
[26]	用于预测锂离子电池寿命的 SVM 使用传统的单径向基核函数, 这种分类器具有较弱的泛化能力, 容易出现数据迁移的问题, 导致对锂离子电池寿命预测不准确, 提出了一种基于多项式核和径向基核函数的新型多核 SVM。此外, 运用粒子群优化算法去搜索 MSVM 模型的核参数, 惩罚因子和权重系数。
[27]	由于现有机械零件剩余寿命预测模型在建模过程中, 无法同时采用已有数据库数据及被预测产品实时退化数据, 因此提出一种 SVM 和非线性卡尔曼滤波相结合的机械零件剩余寿命预测模型: 根据现有全寿命试验数据训练所得的 SVM 回归模型, 建立非线性卡尔曼滤波状态更新方程, 依据机械零件退化特征构造时间更新方程, 设定初始剩余寿命值及其方差, 通过逐步迭代计算各时刻剩余寿命估计值及一定置信水平的置信区间。
[28]	采用最小二乘线性系统作为损失函数, 代替传统支持向量机采用的二次规划方法, 简化了计算的复杂性。

除了采用人工神经网络与支持向量机这两种机器学习算法, 也有采用朴素贝叶斯与随机森林去进行寿命预测, 如 Wu^[29]等采用了基于随机森林的工具磨损寿命预测的方法, 并与前馈反向神经网络、支持向量回归作比较, 随机森林寿命预测模型更准确; Ng Selina^[30]考虑在恒定工作条件下在不同环境温度 and 放电电流值下的锂离子电池剩余寿命预测, 提出了一种朴素贝叶斯 (Native Bayes, NB) 模型, 用于在不同操作条件下对电池进行剩余寿命预测。在该分析中显示, 在恒定放电环境下, 可以使用 NB 方法预测, 且不用管操作条件的确切值。并且通过实例表明, NB 比 SVM 产生稳定且有竞争力的预测性能。

从上述应用与研究可以看出, 机器学习算法在寿命预

测中的发展是由单一算法 (BP 神经网络、SVM) 的应用作为起点, 为了提高预测精度以及改进算法在不同零件、设备寿命预测中的不足之处, 从而将其他种类算法与之结合。而随着人工智能领域的不断发展, 又引入了其他种类的机器学习算法, 如随机森林、朴素贝叶斯等。

3 机器学习算法在故障诊断中的应用与发展

在数学问题中, 故障诊断属于分类问题, 故而可以选用机器学习算法中的分类算法进行故障诊断。一般情况下, 智能故障诊断系统主要包含以下几个功能模块: 数据库模块、知识获取机构、诊断推理模块、学习机构、解释机构以及人机接口。不同的系统与诊断方法会建立的不同功能的故障诊断系统, 但前提是必须保证设计的诊断系统符合需求, 如可靠性、实用性、可维护性等等; 并且要达到指定的诊断准确率和诊断速度。故障信息的不间断更新会影响诊断性能, 得到更多的故障知识, 实时更新故障内容, 并将故障知识用恰当的诊断系统表达出来, 这样能使得故障诊断系统的性能更好。在故障诊断中使用机器学习算法的整体框架见下图, 在实际情况下, 会根据不同的诊断对象对应建立不同的故障诊断模型, 并在诊断中不断地对模型进行修改、更新、完善。一般用于故障诊断的机器学习算法是 SVM、灰色神经网络、Elman 神经网络。




图 1 机器学习算法的两种应用

运用 SVM 时, 往往跟其用于寿命预测中一样, 会用其他算法去进行优化改进。SVM 算法在工程中的应用与研究常常出现在滚动轴承的故障诊断, 如 Li^[31]等提出一种基于分层符号动态熵 (Hierarchical Symbol Dynamic Entropy, HSDE) 和二叉树支持向量机 (Binary Tree Support Vector Machine, BT-SVM) 的滚动轴承故障诊断方法; Zhou^[32]等提出了在少量训练样本可用时保持较高的故障识别准确率的新方法, 即基于集合经验模态分解 (Ensemble Empirical Mode Decomposition, EEMD)、加权置换熵 (Weighted Permutation Entropy, WPE) 和改进支持向量机集成分类器相结合的故障诊断方法, 结果表明, 该方法能够有效地检测轴承故障; 阮婉莹^[33]等则是针对滚动轴承故障振动信号的非平稳性和低信噪比的特点, 提出基于变分模态分解 (Variational Mode Decomposition, VMD) 排列熵和粒子群优化支持向量机 (Particle Swarm Optimization-Support Vector Machine, PSO-SVM) 的故障诊断方法, 在滚动轴承故障诊断实例中, 通过与 VMD 结合 SVM 和集成经验模

态分解结合 PSO-SVM 进行对比。结果表明,新提出的方法故障诊断的准确率更高。当然,SVM 算法的应用不仅仅局限在滚动轴承的故障诊断,例如在感应电动机的故障诊断中,Gangsar 和 Tiwar^[34]用小波包变换与 SVM 相结合的故障诊断方法,并且考虑了不同小波的影响,其结果表明即使在某些电机工作条件下数据或信息有限,所提出的故障诊断方法也可用于成功检测和隔离各种故障;Liu 和 Zio^[35]针对数据来源不同提出了基于 KNN 的模糊 SVM 方法,文中分别用反向 KNN 检测异常值以及 KNN 识别边界点用于定义支持向量机中的分类超平面,最后对高速列车的制动系统中进行故障诊断,验证了新方法的可行性;何庆飞^[36]等针对单方法所建液压泵寿命预测模型精度较低的缺陷,提出基于灰色理论和支持向量机的组合预测模型的液压泵寿命预测方法,采用该模型对液压泵进行寿命预测,并与灰色模型、单一支持向量机模型进行预测性能对比。结果表明,灰色支持向量机预测性能最优。在表 4 中,对 SVM 算法在故障诊断中的应用与研究的创新点进行了梳理。

表 4 SVM 算法在故障诊断中的改进

文献	创新点
[31]	由于多尺度动态熵仅考虑低频分量中的故障信息,可能会丢弃隐藏在高频分量中的故障信息,因此提出了基于分层符号动态熵和二叉树支持向量机的滚动轴承故障诊断方法。
[32]	由于现有模型在少量训练样本可用时的故障识别准确率不是特别高,因此提出了一个新方法,即基于集合经验模态分解、加权置换熵和改进支持向量机集成分类器相结合的故障诊断方法。
[33]	考虑到 VMD 可以将非平稳信号分解转化成若干个平稳模态分量,PSO-SVM 在小样本、非线性和高维模式识别问题中优势明显,提出了 VMD 排列熵结合 PSO-SVM 的滚动轴承故障诊断方法。
[34]	在某些电机工作条件下,存在数据或信息有限的问题,因此提出了基于小波包变换和支持向量机的感应电动机故障诊断方法。
[35]	提出了基于 K 最近邻的模糊支持向量机用于解决故障检测中的计算负担,解决不平衡数据与异常数据的问题。
[36]	通过灰色累加生成操作对原始序列进行数据处理,以增强数据的规律性;运用最小最终误差预测准则确定嵌入维数,选择模型的参数;采用支持向量机进行预测,利用灰色累减生成操作还原数据,得到预测结果。

在实际中,仅采用 SVM 算法进行故障诊断解决问题具有一定局限性的,故而会采用其他机器学习算法,如人工神经网络。与 SVM 算法类似,为了提高预测准确率,会将

其他算法与人工神经网络算法相结合,灰色神经网络就是由灰色模型与人工神经网络结合而成的。在故障诊断中,会因为对某些设备的故障信息掌握得不够全面而使得设备故障具有一定程度的灰色性,因此可以采用灰色系统理论来对应解决这类故障诊断问题。灰色理论的一个重要分支是灰色关联度分析,它的作用是确定系统的边界、判别主要因子、模式识别、灰关联聚类分析等。李婧与王娜^[37]将 BP 神经网络与灰色关联度分析结合,对典型灰色系统变频调速系统进行故障诊断,并通过实例证明该灰色神经网络容易实现,诊断准确率也有所提高;程加堂^[38]等针对油中溶解多种气体含量会影响变压器故障类型,为了提高故障诊断的精度,利用灰色神经网络建立了变压器的故障诊断模型,拟合输入、输出之间复杂的非线性函数关系,并证明了该方法的可行性;Elman 神经网络是由 J. L. Elman 在 1990 年针对语音处理问题而提出的,它属于一种典型的局部回归网络,可以被看作是局部记忆单元和局部反馈连接的递归神经网络。通过对已有应用与研究的整理,发现 Elman 网络多用于滚动轴承的故障诊断,比如 Fu^[39]等为实现随机噪声下滚动轴承的精确故障诊断,提出了一种基于集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)和优化 Elman-AdaBoost 的故障诊断方法;杨红叶与高伟军^[40]针对提取滚动轴承故障特征向量信号和识别故障类型的问题,为了提高故障诊断的精度,提出了一种新方法:结合小波包分析和 BP 算法权值修正的 Elman 神经网络。表 5 则详细梳理了以上应用与研究对神经网络算法进行改进的具体创新点。

表 5 神经网络算法在故障诊断中的改进

文献	创新点
[37]	基于灰色关联度的故障诊断方法,优点是方法简单、计算量小、诊断结果可靠,但计算精度不高、并行处理能力差,将它与神经网络相结合,形成灰色神经网络,正好弥补了以上两个缺点,同时又解决了一般神经网络需要大量样本训练网络的缺点。
[38]	由于变压器油中气体含量呈高度非线性和随机性,难以用精确的数学模型加以描述。而灰色预测模型与神经网络相结合则可以建立一个数学模型对变压器故障加以诊断。
[39]	为实现随机噪声下滚动轴承的精确故障诊断,提出了一种基于集合经验模态分解和优化 Elman-AdaBoost 的故障诊断方法。
[40]	基于文中滚动轴承的故障振动信号是通过搭建实验台采集到的模拟故障信号。想要直接根据各个频带能量大小想要准确地判断其故障类型比较困难且不能精确实现。因此通过 Elman 神经网络辨识技术,把提取的各频带能量特征作为输入变量,以此来提高故障诊断的准确性。

在故障诊断中还存在其他机器学习算法。比如温江涛和周熙楠^[41]针对在旋转机械的智能故障诊断中, 复杂网络结构的非监督学习方法调节参数多, 训练时间长, 而结构简单的网络诊断准确率不够理想这些问题, 采用模糊信息粒化和稀疏自编码器搭建并行结构的学习网络, 并行结构的稀疏自编码器同时对粒化后重新构成的多个有效参量信息自适应的进行特征提取, 随后使用随机森林方法对提取的特征进行融合分类, 实验结果表明该方法可以有效实现高精度故障诊断, 且与常用的串行多网络处理结构相比, 降低了网络参数调节的复杂度和多层网络的前后影响, 并且提高了诊断精度, 减少了训练时间; Liu^[42]等提出了基于固有时间尺度分解和多级 Adaboost 相关向量机的故障诊断方法对柴油机故障诊断; Yao^[43]等提出了一种利用局部特征尺度分解多尺度置换熵和 ELM-AdaBoost 算法进行轴承故障诊断的新方法, 并用结果表明该方法可以有效地准确诊断铁路轴箱轴承故障。

4 发展趋势

从上述应用与研究中可以发现, 机器学习算法在寿命预测与故障诊断中还需要解决的问题主要有以下 3 个:

第一, 机器学习算法的运用现状还仅仅局限于材料试件与局部构件, 距离实现重大装备整体的寿命预测与故障诊断还有较大的差距, 这未来机器学习算法需要突破的一个重大难点;

第二, 目前还只是运用了极少数的机器学习算法, 其中应用与研究最为广泛的是人工神经网络与支持向量机, 还有大量机器学习算法有待发掘;

第三, 已经应用的算法更适用于拥有大样本试验数据的设备, 而实际中获得的小样本试验数据的情况居多, 因此如何利用机器学习算法对小样本数据的设备进行寿命预测与故障诊断也是需要攻坚的一个难点。

以上难点都需要对其他种类的机器学习算法进行深入学习与研究, 才可能最大化地挖掘机器学习算法在寿命预测与故障诊断中的作用。

5 结束语

人工智能下的机器学习算法为可靠性分析中的寿命估计与故障诊断提供了一种高效手段, 并且已逐渐运用于工程领域中。本文梳理了机器学习算法的具体应用与研究现状, 从现有数据来源来看, 都是通过试验技术得到, 而试验技术的方法都是采用产品原型试验进行确定, 适用于普通机械产品, 而对于小批量生产的机械重大装备, 由于价格昂贵, 供货时间长, 采用常规的大样本试验方法是非常不适宜的, 甚至是不可能的, 因此需要机器学习算法对小样本数据进行寿命预测与故障诊断; 从研究对象来看, 当前绝大多数运用机器学习算法进行寿命预测的研究还是停留在各种材料试件或者机械装备的各种零部件, 距离实现

机械重大装备整体寿命预测还需要不断深入研究; 从对机器学习算法的运用来看, 尽管现如今存在众多机器学习算法, 但目前运用最为广泛的是人工神经网络与支持向量机, 距离实现机器学习算法的全面应用还需要不断深入发展。

参考文献:

- [1] 国家自然科学基金委员会工程与材料科学部. 机械工程学科发展战略报告(2011-2020) [M]. 北京: 科学出版社, 2010.
- [2] 张小丽, 陈雪峰, 李兵, 等. 机械重大装备的寿命预测综述 [J]. 机械工程学报, 2011, 47 (11): 100-116.
- [3] 魏晓斌, 马小平, 李亚朋. 故障诊断技术综述 [J]. 煤矿机电, 2009, (1): 63-65.
- [4] 张菲菲, 李志刚. 基于 BP 神经网络的继电器剩余寿命预测 [J]. 低压电器, 2012 (1): 11-14.
- [5] 林朝晖, 张彼德. 基于 BP 神经网络的油浸式变压器寿命预测 [J]. 高压电器, 2010, 46 (4): 84-87.
- [6] 周剑锋, 顾伯勤. 基于人工神经网络的机械密封寿命预测 [J]. 流体机械, 2006, 34 (3): 19-23.
- [7] Kashyzadeh Kazem Reza, Malek Erfan. Experimental investigation and artificial neural network modeling of warm galvanization and hardened chromium coatings thickness effects on fatigue life of AISI 1045 carbon steel [J]. Journal Of Failure Analysis And Prevention, 2017, 17 (6): 1276-1289.
- [8] Elforjani Mohammed, Shanbr Suliman. Prognosis of bearing acoustic emission signals using supervised machine learning [J]. Transactions on Industrial Electronics, 2018, 65 (7): 5864-5871.
- [9] Zhao Zeqi, Liang Bin, Wang Xueqian, et al. Remaining useful life prediction of aircraft engine based on degradation pattern learning [J]. Reliability Engineering & System Safety, 2017, (164): 74-83.
- [10] 夏颖怡. 基于 GA-BP 神经网络的刀具寿命预测研究 [J]. 精密制造与自动化, 2017, (2): 9-11.
- [11] 张琪, 吴亚峰, 徐健. 基于遗传神经网络的除湿机故障诊断与寿命预测 [J]. 装备环境工程, 2017, 14 (1): 78-83.
- [12] Wang Jingtao, Lu Jingui, Zhu Zhengquan, Qian Peng, Lim Xiaochuan, Wang Bangxiang. Approximate estimation of fatigue life of hydraulic support [J]. Industry and Mine Automation, 2017, 43 (3): 39-42.
- [13] 王虎, 刘佩松, 叶润章, 等. 基于 PSO-BP 神经网络的刀具寿命预测 [J]. 现代制造技术与装备, 2017, (6): 53-54.
- [14] 汪庆年, 饶利强, 龚文军, 等. 基于 PSO 优化的 BP 神经网络在电动机绝缘剩余寿命预测中的应用 [J]. 水电能源科学, 2015, 33 (12): 161-164.
- [15] 李薇. 粒子群优化神经网络的电镀金刚石套钻使用寿命预测 [J]. 电镀与精饰, 2017, 39 (3): 29-32.
- [16] Mazhar M I, Kara S, Haebernick H. Remaining life estimation of used components in consumer products: Life cycle data

- analysis by Weibull and artificial neural networks [J]. *Journal of Operations Management*, 2007, 25 (6): 1184 - 1193.
- [17] Mahamad A K, Saon S, Hiyama T. Predicting remaining useful life of rotating machinery based artificial neural network [J]. *Computers & Mathematics with Applications*, 2010, 60 (4): 1078 - 1087.
- [18] Tian Z G. An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring [J]. *Journal of Intelligent Manufacturing*, 2012, 23 (2): 227 - 237.
- [19] Zhang Xinghui, Xiao Lei, Kang Jianshe. Bearing remaining useful life prediction based on an improved back propagation neural network [J]. *International Journal of Performability Engineering*, 2014, 10 (6): 653 - 657.
- [20] Zhang Cunji, Yao Xifan, Zhang Jianming, et al. Tool condition monitoring and remaining useful life prognostic based on a wireless sensor in dry milling operations [J]. *Sensors*, 2016, 16 (6).
- [20] Uygur, Cicek A, Toklu E, et al. Fatigue life predictions of metal matrix composites using artificial neural networks [J]. *Archives of Metallurgy and Materials*, 2014, 59 (1): 97 - 103.
- [21] 杜占龙, 李小民, 席雷平, 等. 多分类概率极限学习机及其在剩余使用寿命预测中的应用 [J]. *系统工程与电子技术*, 2015, (12): 2777 - 2784.
- [22] Platt J C. Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods [J]. *Advances in Large Margin Classifiers*, 1999, 10 (3): 61 - 74.
- [23] Trevor H, Robert T. Classification by pairwise coupling [J]. *The Annals of Statistics*, 1998, 26 (2): 451 - 471.
- [24] Guo Liang, Li Naipeng, Jia Feng, et al. A recurrent neural network based health indicator for remaining useful prediction of bearings [J]. *Neurocomputing*, 2017, (240): 98 - 109.
- [25] Chen Zhongzhe, Cao Shuchen, Mao Zijian. Remaining useful life estimation of aircraft engines using a modified similarity and supporting vector machine (SVM) approach [J]. *Energies*, 2018, 11 (1).
- [26] Gao Dong, Huang Miaohua. Prediction of remaining useful Life of lithium - ion battery based on multi - kernel support vector machine with particle swarm optimization [J]. *Journal of Power Electronics*, 2017, 17 (5): 1288 - 1297.
- [27] 于震梁, 孙志礼, 曹汝男, 等. 基于支持向量机和卡尔曼滤波的机械零件剩余寿命预测模型研究 [J]. *兵工学报*, 2018, (5): 991 - 997.
- [28] 王 莉, 杨永辉, 詹 益, 等. 基于最小二乘支持向量机阀控式铅酸蓄电池寿命预测 [J]. *大连交通大学学报*, 2017, 38 (3): 116 - 119.
- [29] Wu Dazhong, Jennings Connor, Terpeny Janis, et al. A comparative study on machine learning algorithms for smart manufacturing: Tool wear prediction using random forests [J]. *Journal Of Manufacturing Science and Engineering - transactions Of The Asme*, 2017, 139 (7).
- [30] Ng Selina S Y, Xing Yinjiao, Tsui Kwok L. A naive Bayes model for robust remaining useful life prediction of lithium - ion battery [J]. *Applied Energy*, 2014, 118: 114 - 123.
- [31] Li Yongbo, Yang Yuantao, Wang Xianzhi, et al. Early fault diagnosis of rolling bearings based on hierarchical symbol dynamic entropy and binary tree support vector machine [J]. *Journal Of Sound And Vibration*, 2018, (428): 72 - 86.
- [32] Zhou Shenghan, Qian Silin, Chang Wenbing, et al. c [J]. *Sensors*, 2018, 18 (6).
- [33] 阮婉莹, 马增强, 李亚超. 基于变分模态分解排列熵和粒子群优化支持向量机的滚动轴承故障诊断方法 [J]. *济南大学学报*, 2018, (4): 291 - 298.
- [34] Gangsar Purushottam, Tiwari Rajiv. Multifault diagnosis of induction motor at intermediate operating conditions using wavelet packet transform and support vector machine [J]. *Journal Of Manufacturing Science and Engineering - transactions Of The Asme*, 2018, 140 (8).
- [35] Liu Jie, Zio Enrico. A scalable fuzzy support vector machine for fault detection in transportation systems [J]. *Expert Systems With Applications*, 2018, (102): 36 - 43.
- [36] 何庆飞, 陈桂明, 陈小虎, 等. 基于灰色支持向量机的液压泵寿命预测方法 [J]. *润滑与密封*, 2012, 37 (4): 73 - 77.
- [37] 李 婧, 王 娜. 基于灰色神经网络的变频调速系统故障诊断的研究 [J]. *科技信息*, 2012, (8): 149 - 151.
- [38] 程加堂, 熊 伟, 段志梅, 等. 灰色神经网络在变压器故障诊断中的应用 [J]. *高压电器*, 2010, 46 (8): 56 - 58.
- [39] Fu Qiang, Jing Bo, He Pengju, et al. Fault feature selection and diagnosis of rolling bearings based on EEMD and optimized Elman - AdaBoost Aalgorithm [J]. *Sensors Journal*, 2018, 18 (12): 5024 - 5034.
- [40] 杨红叶, 高军伟. 基于小波包和 ElmanNN 的滚动轴承故障识别 [J]. *制造业自动化*, 2018 (3): 92 - 96.
- [41] Liu Yu, Zhang Junhong, Qin Kongjian, et al. Diesel engine fault diagnosis using intrinsic time - scale decomposition and multistage Adaboost relevance vector machine [J]. *Proceedings Of The Institution Of Mechanical Engineers Part C - journal Of Mechanical Engineering Science*, 2018, 232 (5): 881 - 894.
- [42] 温江涛, 周熙楠. 模糊粒化非监督学习结合随机森林融合的旋转机械故障诊断 [J]. *机械科学与技术*, 2018.
- [43] Yao Dechen, Yang Jianwei, Pang Zhifen, et al. Railway axle box bearing fault identification using LCD - MPE and ELM - AdaBoost [J]. *Journal Of Vibroengineering*, 2018, 20 (1): 165 - 174.