

基于集成学习的涡扇发动机剩余寿命预测模型

张一鸣¹, 刘晓锋¹, 崔 宝², 唐 瑞²

(1. 北京航空航天大学 交通科学与工程学院, 北京 100191;
2. 中国船舶集团有限公司第七〇三研究所, 黑龙江 哈尔滨 150078)

摘 要:为了解决涡扇发动机的监测数据维数高、时间跨度长、给预测发动机剩余使用寿命带来困难的问题。本文提出了一种基于集成神经网络模型的发动机寿命预测系统,采用集成学习中的 Stacking 方法对单一的学习器进行集成来预测涡扇发动机的剩余使用寿命(RUL)。模型在 NASA 公共数据集 C-MAPSS(Commercial Modular Aero-Propulsion System Simulation)上进行了发动机寿命预测实验验证,并与常用的机器学习方法和单一神经网络进行了比较。实验结果表明:模型在多种评价方法上综合表现最佳,且在超前预测上表现良好。

关 键 词:寿命预测;神经网络;模型融合;集成学习

中图分类号:V235 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2022.04.009

[引用本文格式]张一鸣,刘晓锋,崔 宝,等. 基于集成学习的涡扇发动机剩余寿命预测模型[J]. 热能动力工程,2022,37(4):64-70. ZHANG Yi-ming, LIU Xiao-feng, CUI Bao, et al. Turbofan engine remaining useful life prediction model based on ensemble learning [J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(4): 64-70.

Turbofan Engine Remaining Useful Life Prediction Model based on Ensemble Learning

ZHANG Yi-ming¹, LIU Xiao-feng¹, CUI Bao², TANG Rui²

(1. School of Transportation Science and Engineering, Beihang University, Beijing, China, Post Code:100191; 2. No. 703 Research Institute of CSSC, Harbin, China, Post Code: 150078)

Abstract: In order to solve the difficulties in predicting the remaining useful life (RUL) of turbofan engine caused by the high dimension and long time span of the monitoring data of the turbofan engine, this paper proposes an engine life prediction system based on the integrated neural network model, which uses the stacking method in ensemble learning to integrate the single learner to predict the RUL of turbofan engine. The model is validated by an experimental test of engine useful life prediction on the NASA public data set Commercial Modular Aero-Propulsion System Simulation (C-MAPSS), compared with common machine learning method and single neural network. The experimental results show that the model has optimum performance in a variety of evaluation methods and does well in prediction ahead of time.

Key words: life prediction, neural network, multi-model combination, ensemble learning

收稿日期:2021-03-28; 修订日期:2021-11-25

基金项目:国家科技重大专项(2017-I-0007-0008)

Fund-supported Project: National Science and Technology Major Project(2017-I-0007-0008)

作者简介:张一鸣(1997-),女,内蒙古呼和浩特人,北京航空航天大学硕士研究生。

通讯作者:刘晓锋(1979-),男,辽宁凌源人,北京航空航天大学副教授。

引 言

涡扇发动机作为航空航天领域的核心设备之一,其健康状况决定了飞机能否稳定可靠地运行。判断涡扇发动机的剩余使用寿命(RUL)是设备监控和维护的重要组成部分。涡扇发动机故障预测与健康管理(Prognostics Health Management, PHM)的研究近年来得到了广泛开展。通过准确预测剩余使用寿命,实时监测涡扇发动机的健康状况,从而指导发动机管理人员采取合理的维修措施,在降低发动机维修成本的同时保证飞机的可靠飞行。

PHM 领域 RUL 预测方法主要分为物理建模方法、数据驱动方法和二者结合的方法^[1]。物理建模方法对部件的退化过程进行建模,因而需要深入掌握涡扇发动机结构与运行相关的专业知识。数据驱动方法则利用统计学习、机器学习和深度学习方法对多源传感器的数据进行分析,并对预测模型进行训练。

涡扇发动机的复杂结构对精确的物理建模提出了挑战,因此数据驱动方法得到了广泛的研究。研究人员使用基于正常运行时间、开始退化时间和工作故障的连续时间 3 个元素的隐马尔可夫模型(Hidden Markov Model, HMM)来预测涡扇发动机的 RUL。研究人员还使用循环神经网络模型(Recurrent Neural Network, RNN)从时间序列中提取信息。RNN 具有独特的递归结构,当前时刻的输出取决于前一刻的状态,长期信息在迭代过程中逐渐变得模糊,不利于使用。研究人员进一步引入了长短期记忆(Long-Short Term Memory, LSTM)模型。LSTM 在 RNN 的基础上引入控制门,并通过其内部输入门、输出门和遗忘门之间的配合来传输有效的长期信息。然而,上述方法都存在一定的局限性与缺陷。与传统的使用单一神经网络进行预测的方法相比,集成学习首先训练多个学习器(基学习器),再将基学习器的预测结果结合,从而得到了更为精确的预测结果。集成学习增强了模型的泛化能力,同时降低了方差和偏差的影响,此结论已在多领域的实证研究中得以证实^[2]。

本文训练了多个神经网络模型,并应用集成学

习中的 Stacking 方法对这些模型进行集成。实验结果表明,集成学习模型对发动机剩余寿命的预测精度高于所有子模型,在测试集中具有最小的均方根误差(Root Mean Squared Error, RMSE)。这一结论说明集成学习的确可以发挥各神经网络模型优势,提高综合预测表现,在发动机剩余寿命预测领域具有极强的现实应用价值。

1 预测模型

1.1 多层感知器(Multi-Layer Perceptron, MLP)

多层感知器是全连接神经网络组成的最基本的神经网络结构,它由 1 个输入层、1 个输出层和至少 1 个隐藏层组成,各层之间通过激活函数对输出进行变换。常见的激活函数包括 ReLU 函数, sigmoid 函数和 tanh 函数。图 1 为包含 1 个隐藏层的多层感知器模型。




图 1 MLP 模型示意图
Fig.1 Schematic diagram of MLP model

该 MLP 模型中输入层和输出层各包含 3 个单元,隐藏层包含 4 个单元,单层感知器仅允许线性函数,而多层感知器允许应用非线性函数进行学习,因此有更好的预测表现。

1.2 循环神经网络(RNN)

循环神经网络与常见的神经网络不同,其通过将隐藏层的输出作为输入,实现反复的迭代,从而处理元素之间前后关联的问题^[3~4]。这一特性决定了 RNN 与一般的神经网络相比,能更好地处理时间序列信息。如同人类拥有记忆,循环神经网络的输出

依赖于当前时间的输入和之前时间的“记忆”。循环神经网络的单元结构如图 2 所示。

图 3 将 RNN 单元结构按时间顺序展开。其中,在 $t-1$ 时刻输入的向量 i ,在经过隐藏层的作用后,不仅输出了结果,同时还将信息传递给了 t 时刻的神经元。因此,在 t 时刻隐藏层的输出不仅取决于此时的输入,也取决于上一时刻的隐藏层。正是由于这种特性,RNN 对于时间序列数据十分敏感。




图 2 RNN 单元结构示意图

Fig.2 Structural diagram of RNN unit




图 3 RNN 模型示意图

Fig.3 Schematic diagram of RNN model

1.3 双向循环神经网络 (Bidirectional RNN, BRNN)

RNN 的结构导致了网络仅能通过之前时刻的信息预测下一时刻的输出,然而在实际应用中,当前时刻的输出往往是依赖于之前的状态和未来的状态,双向循环神经网络解决了这一问题,BRNN 由 2 个 RNN 组成,其基本结构如图 4 所示^[5]。

这样的结构使得 BRNN 在序列的任意时刻,既可以获得之前的信息,也可以获得之后的信息,基于完整的时间序列得到预测结果。




图 4 BRNN 模型示意图

Fig.4 Structure of BRNN model

双向传播的神经元之间没有连接,输出由 2 个 RNN 的状态同时决定,过程为:

$$s_i^1 = f(u^1 \cdot x_i + w^1 \cdot s_{i-1}) \tag{1}$$

$$s_i^2 = f(u^2 \cdot x_i + w^2 \cdot s_{i-1}) \tag{2}$$

$$o_i = \text{softmax}(v \cdot [h_i^1; h_i^2]) \tag{3}$$

式中: u^1 与 w^1 —前向 RNN 过程中的权重矩阵, u^2 与 w^2 —后向 RNN 过程中的权重矩阵, s_{i-1}^1 和 s_{i-1}^2 — $t-1$ 期的隐藏层取值; o_i —输出值。

1.4 长短期记忆网络 (LSTM)

长短期记忆神经网络是一种广泛应用的深度学习算法,与一般的神经网络模型相同,包含输入层、隐藏层和输出层^[6]。与 RNN 相比,LSTM 添加了遗忘机制和保存机制,以更精确的形式传递时间序列中包含的信息,能准确判断需要被注意和丢弃的信息。数学描述为:

$$\text{remember}_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \tag{4}$$

$$\text{save}_t = \sigma(W_s x_t + U_s h_{t-1} + b_s) \tag{5}$$

$$\text{focus}_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \tag{6}$$

$$\text{ltm}_t' = \tanh(W_l x_t + U_l h_{t-1} + b_l) \tag{7}$$

式中: h_t —LSTM 网络中的工作记忆,类似于 RNN 中的隐藏态; ltm_t —长期记忆; remember_t —记忆向量,称为遗忘门; save_t —保存向量,称为输入门; focus_t —注意向量,称为输出门; W/U —各个过程中的权重矩阵; b —对应的偏置向量。

如图 5 所示,遗忘门、输入门和输出门 3 个门函数控制着序列信息的输入和删除,确保神经网络能有捕获和记忆数据长期相关性的能力。

1.5 双向长短期记忆网络模型 (Bidirectional Long Short Term Memory, BiLSTM)

LSTM 与 RNN 相同的单向传播结构导致了网络仅能通过之前时刻的信息预测下一时刻的输出,而双向长短期记忆网络的前向传播层和反向传播层

共同连接着输出层,在任一时刻,最初的输出值都由前向传播层和反向传播层的相应时刻输出共同决定^[7-8]。双向 LSTM 同时保存了过去和未来的信息,有效进行对时间序列信息的学习。过程为:

$$h_t = \text{LSTM}(x_i, h_{t-1}) \tag{8}$$

$$h'_t = \text{LSTM}(x_i, h_{t+1}) \tag{9}$$

$$y_t = W_{fy} h_t + W_{by} h'_t + b_y \tag{10}$$

式中: W_{fy} 一前向传播层到输出层的权重; W_{by} 一反向传播层到输出层的权重。




图 5 LSTM 模型示意图

Fig. 5 Schematic diagram of LSTM model

1.6 Stacking 集成学习模型(Ensemble Model)

集成学习(Ensemble Learning)通过多算法融合,将单一模型得到的预测偏差信息融合生成新模型,获得比单一模型更好的训练效果。集成学习具有极高的灵活性,不局限于基学习器的具体类别,集成学习方法不依赖于单一的学习器的模型能力,因此具有很好的泛化能力。

采用 Stacking(堆叠)方法来实现基学习器预测结果的集成。Stacking 集成学习模型具有两层结构,如图 6 所示。第一层由性能优异且存在差异性的基学习器组成。原始数据分别在各基学习器上进行训练,输出预测结果。第二层为元学习器,第一层得到的预测结果组成了新的向量矩阵,作为第二层的输入,在元学习器中训练后输出最终的预测值,纠正基学习器中预测产生的偏差^[9-10]。选择以径向基函数(Radial Basis Function, RBF)为核函数的支

持向量回归(Support Vector Regression, SVR)做为元学习器。




图 6 Stacking 集成学习模型

Fig. 6 Stacking model

2 实验设计和结果

2.1 数据集

使用的数据集为来自于美国国家航空航天局(NASA)的 C-MAPSS 数据集,其模拟了涡扇发动机在不同工作状况下的退化过程^[11]。根据仿真设定的不同,C-MAPSS 共分为 4 个子数据集,分别包含测试集和训练集。选择其中的 FD001 子数据集作为研究数据,FD001 数据集包含 100 台发动机,共 20 360 个训练样本点和 13 095 个测试样本点。

对训练数据 RUL 的标签进行处理。实践发现,在发动机的早期运行阶段,RUL 基本为常数,后期出现线性的衰退,设备的剩余使用寿命随时间呈非均匀变化。为了对剩余使用寿命进行更好地预测,当设备运行周期小于 120 时,将 RUL 设为一个固定值,当运行周期大于 120 时,RUL 设置为随运行周期增加而单调递减,并递减为零,如图 7 所示。




图 7 RUL 标签处理

Fig. 7 RUL label

2.2 评价指标

采取均方根误差和评分函数 (Scoring Function) 两种指标来评估模型的表现,两者定义分别为:

均方根误差:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2}$$
 (11)

式中: m —测试集中发动机个数; y_i —发动机 i 的真实 RUL; $\hat{y}_i$ —发动机 i 的 RUL 预测值。

评分函数:

$$Score = \begin{cases} \sum_{i=1}^m e^{-\left(\frac{\hat{y}_i - y_i}{13}\right)} - 1, \hat{y}_i - y_i < 0 \\ \sum_{i=1}^m e^{\left(\frac{\hat{y}_i - y_i}{10}\right)} - 1, \hat{y}_i - y_i \geq 0 \end{cases}$$
 (12)

评分函数对于滞后预测的惩罚更大,这是由于在发动机剩余寿命预测时,滞后的预测带来的维修成本更高、危害更大^[12]。Score 与 RMSE 与预测误差值的关系如图 8 所示。




图 8 Score 与 RMSE 函数对比

Fig. 8 Comparison of score function and RMSE

2.3 实验环境与参数配置

选用径向基函数 (RBF) 为核函数的支持向量回归作为元学习器。为了进一步增强集成模型的表现与泛化能力,防止潜在的过拟合问题,应用交叉验证方法来训练元学习器。并通过以下方式减少复杂神经网络带来的过拟合风险:

(1) 辍学(dropout):辍学是指随机删除一些隐藏层神经元,然后根据修改后的网络结构进行训练。因此,在应用辍学方法后,每次训练中的网络都具有不同的结构。最后对这些网络进行整合,得到平均预测结果。这减少了神经元之间的依赖,提高了泛化能力。

(2) 早期停止(early stopping):当训练大型模型迭代次数太多时,模型在验证集上的性能将恶化。这是一种常见的过度拟合,可以通过早期停止来避免。随着早期停止,当模型的性能开始下降时,算法终止,以达到训练时间和模型泛化能力之间的平衡。

为了提高集成模型的预测能力,首先对基学习器进行模型优化和参数寻优,性能优异的基学习器使集成模型的表现更好。各模型的网络结构设置如表 1 所示。根据对不同基模型组合方式进行训练,最终选择 MLP、BRNN、BiLSTM 3 种网络作为基学习器。

表 1 基模型网络结构设置

Tab. 1 Network settings of learners

模型	神经元数	辍学
MLP	(10,5,1)	无
RNN	32	0.5
BRNN	64	0.7
BiLSTM	50	0.5
GRU	50	0.5

2.4 结果对比

表 2 中为基学习器与 stacking 集成模型在同一数据集上的预测结果。可以看出,无论是在 RMSE 还是评分函数的评判标准下,集成学习的表现都是最好的。在基学习器中,与多层感知器相比,时间序列网络有着更好的性能。而相比各个子模型,集成网络进一步提高了 RUL 的预测性能,体现出集成模型在长时间内对数据的良好实用性。

表 2 不同预测模型结果对比

Tab. 2 Comparison of performance of different models

模型	RMSE	评分函数
集成学习模型	17.879	177
MLP	18.400	7890
RNN	23.494	780
BRNN	22.343	262
BiLSTM	19.309	435
GRU	18.258	885

随机抽取 FD001 数据集集中的 6 台发动机,将多层感知器模型和集成模型预测结果分别与真实的剩余寿命进行对比,如图 9 所示。从图中可以看出,集成模型的预测结果更加符合发动机的真实寿命,其预测效果优于一般的多层感知器模型,在超前预测上的表现更好。




图 9 预测效果对比

Fig.9 Comparison of prediction effects of different models

3 结 论

基于降低模型过拟合风险与提高模型泛化能力和预测表现的考虑,提出了一种基于集成学习的涡扇发动机剩余生命预测模型。首先训练了多种单一神经网络模型,然后利用支持向量机对其进行集成,

从而得到对发动机剩余寿命的最终预测。

(1) 与传统的多层感知器相比,RNN 类型的神经网络结构能够捕获到更多的时间特征,具有更好的预测效果。与单一的时间序列神经网络相比,双向循环神经网络和双向长短期记忆网络还具有按照时间逆序来传递信息的特性,可使网络掌握更多信息,有着更好的精度。

(2) 集成模型在 RMSE 和评分函数上的表现都大大优于单一的神经网络,同时在超前预测上也有着良好的表现,有效提高了模型对发动机剩余寿命的预测能力。

(3) 在对发动机剩余寿命进行预测时,集成学习可以充分地利用与结合过去所提出的各种预测模型,吸收各模型优势,同时提高模型的泛化能力。

参考文献:

[1] ELSHEIKH A, YACOUT S, OUALI M S. Bidirectional handshaking LSTM for remaining useful life prediction[J]. Neurocomputing,2019,323:148 – 156.

[2] DIETTERICH T G. Ensemble learning[J]. The Handbook of Brain Theory and Neural Networks,2002(2):110 – 125.

[3] ZAREMBA W, SUTSKEVER I, VINYALS O. Recurrent neural network regularization[J]. ArXiv:1409.2329,2014.

[4] MIKOLOV T, KARAFIÁT M, BURGET L, et al. Recurrent neural network based language model[C]//Eleventh Annual Conference of the International Speech Communication Association,2010.

[5] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks[J]. IEEE Transactions on Signal Processing, 1997, 45(11):2673 – 2681.

[6] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation,1997,9(8):1735 – 1780.

[7] GRAVES A, FERNÁNDEZ S, SCHMIDHUBER J. Bidirectional LSTM networks for improved phoneme classification and recognition[C]//International Conference on Artificial Neural Networks. Springer, Berlin, Heidelberg,2005.

[8] GRAVES A, SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks,2005,18(5 – 6):602 – 610.

[9] WOLPERT D H. Stacked generalization[J]. Neural Networks, 1992,5(2):241 – 259.

[10] BREIMAN L. Stacked regressions[J]. Machine Learning, 1996, 24(1):49 – 64.

[11] SAXENA A, GOEBEL K, SIMON D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation[C]//2008 International Conference on Prognostics and Health Management. IEEE,2008.

[12] ZHENG S, RISTOVSKI K, FARAHAT A, et al. Long short-term memory network for remaining useful life estimation[C]//2017 IEEE International Conference on Prognostics and Health Management(ICPHM). IEEE,2017:88 – 95.

(姜雪梅 编辑)