

# 基于卷积神经网络的发动机气路故障诊断方法

元尼东珠<sup>1</sup>, 罗亚锋<sup>2</sup>, 房红征<sup>3,4,5</sup>, 杨浩<sup>3,4,5</sup>

(1. 青海民族大学 计算机学院, 西宁 810007; 2. 火箭军装备部驻北京地区第八军事代表室,

北京 100192; 3. 北京航天测控技术有限公司, 北京 100041;

4. 北京市高速交通工具智能诊断与健康重点实验室, 北京 100041;

5. 装备全寿命周期状态监测与健康管理与应用国家地方联合工程研究中心, 北京 100041)

**摘要:** 深度学习是一种新的基于特征表示的机器学习方法; 深度学习模型包含多个隐藏层, 可以通过对输入数据进行自动学习来获取隐藏的功能层中的特征信息; 与传统的诊断方法相比, 深度学习具备从原始信息中提取更丰富的特征的能力, 因此已经成为基于机器学习的故障诊断研究的新方向, 为发动机气路等复杂系统故障诊断带来了新思路; 结合发动机气路试验数据的特点与深度学习的优势, 提出基于卷积神经网络的故障诊断方法, 包括预处理、模型训练及优化等过程, 并实现了复杂系统故障诊断预测算法平台; 经某发动机气路试验仿真数据实例验证, 提出的方法具有较好的可行性和效果, 能够充分利用深度学习的优点, 更准确地识别发动机气路的健康状况。

**关键词:** 无故障诊断; 深度学习; 卷积神经网络 (CNN); 深度神经网络 (DNN); 发动机; 气路

## Aero-engine Gas Path Fault Diagnostic Method Based on Convolutional Neural Network

Yuanni Dongzhu<sup>1</sup>, Luo Yafeng<sup>2</sup>, Fang Hongzheng<sup>3,4,5</sup>, Yang Hao<sup>3,4,5</sup>

(1. Computer College, Qinghai Nationalities University, Xining 810007, China; 2. No. 8 Military Representative Office of

Rocket Force Military Equipment Department in Beijing District, Beijing 100192, China; 3. Beijing Aerospace

Measurement & Control Corp. Ltd, Beijing 100041, China; 4. Beijing Key Laboratory of High-speed Transport

Intelligent Diagnostic and Health Management, Beijing 100041, China; 5. National and Local Joint

Engineering Research Center of Equipment Life Cycle Condition Monitoring and Health Management

Technology and Application, Beijing 100041, China)

**Abstract:** Deep learning is a new machine learning method based on feature representation. The deep learning model consists of multiple hidden layers, and the feature information in the hidden functional layer can be obtained by automatically learning the input data. Compared with traditional diagnostic methods, deep learning has the ability to extract more abundant features from the original information, so it has become a new area of machine learning-based fault diagnosis research. It brings new idea of the complex system fault diagnostic such as aero-engine gas path. Combining the characteristics of complex system test data and the advantages of deep learning, a fault diagnostic method based on convolutional neural network is proposed, including preprocessing, model training and optimization. Then a complex system fault diagnostic algorithm platform based on deep learning method is realized. The simulation method of an aero-engine gas path test proves that the proposed method has good feasibility and effect, it can make full use of the advantages of deep learning and more accurately identify the health state of the aero-engine gas path.

**Keywords:** fault diagnostic; deep learning; convolutional neural network (CNN); deep neural network (DNN); engine; gas path

## 0 引言

在发动机气路等典型机电设备的故障诊断中, 神经网络出色的非线性问题处理能力<sup>[1-2]</sup>, 有利于帮助解决故障诊断与预测等领域的难点问题, 因此得到了大量的应用。此外, 常见的故障诊断方法还包括专家系统<sup>[3]</sup>、模糊集、支持向量机等。其中支持向量机 (Support vector machine, SVM) 在解决非线性、较高维、小样本等方面有突出的优

点, 但其参数的选取在一定程度上影响了其性能和实用性。目前复杂系统故障诊断预测领域中, 所使用的机器学习算法大多为支持向量机、BP神经网络等浅层学习方法。随着人工智能科学和大数据的发展, 机器学习算法不断丰富, 学习深度不断加深, 性能不断提高, 将最新的机器深度学习成果应用于故障诊断领域已经成为一个热点。深度学习方法例如深度神经网络 (Deep Neural Network, DNN)<sup>[5-6]</sup>、深度置信网络 (Deep Belief Network, DBN)<sup>[7-8]</sup>、递归神经网络 (Recurrent Neural Network, RNN)<sup>[9]</sup>、卷积神经网络 (Convolutional Neural Network, CNN) 等<sup>[10-11]</sup>, 由于近几年随着大数据处理的广泛应用而刚成为研究热点, 但在发动机气路故障诊断中应用和研究还较少<sup>[12]</sup>。

收稿日期: 2019-05-15; 修回日期: 2019-06-27。

作者简介: 元尼东珠 (1982-), 男, 青海西宁人, 硕士, 讲师, 主要从事计算机应用技术等方向的研究。

DBN 方法本质上是具有向图模型, 该方法的主要目的是通过在观察数据的同时调整变量之间的权重来导出隐含变量的状态。DBN 模型是一种将无监督和有监督混合的深度结构学习模型, 好处是不需要大量标记的训练数据、收敛速度快, 不足是不容易进行局部收敛。RNN 方法的基本特征是在其处理单元之间存在内部反馈连接和前馈连接。内部反馈连接可以保留隐藏层节点的状态。网络的输出不仅取决于当前输入, 还取决于先前网络的内部状态, 因此具有更好的动态特性。CNN 方法与 DBN 和 RNN 等方法相比具有自己的优势, 可以为识别二维形状提供多层感知器, 对于平移、缩放、倾斜或其他形式的变形具有高度不变的特点, 因此更适合于用于时间序列和语音信号的处理。

深度学习是一种新的基于特征表示的机器学习方法。深度学习模型包含多个隐藏层, 可以通过对输入数据进行自动学习来获取隐藏的功能层中的特征信息。与传统的诊断方法相比, 深度学习具备从原始信息中提取更丰富的特征的能力, 因此已经成为基于机器学习的故障诊断研究的新方向。由于种种原因, 深度学习在故障诊断方面的应用基础和成果, 远远落后于图像、语音处理等方面的成果。文献 [13] 提出了基于深度神经网络 (DNN) 的卫星电源故障诊断方法, 该方法在初步训练阶段采用去噪自动编码器 (DAE) 作为无监督算法, 在微调阶段采用反向传播 (BP) 算法作为监督算法。文献 [14] 提出了一种基于深度学习的航空发动机故障融合诊断方法, 首先将航空发动机性能参数和故障类型样本输入深度置信网络 (DBN) 模型, 并提取样本特征以输出故障分类数据; 然后将输出数据代入决策融合的决策融合算法模型, 得到航空发动机故障融合诊断结果。目前, 基于 CNN 的诊断方法的研究结果很少, 该方法作为一种重要的深度神经网络方法, 是一种深度监督和学习的机器学习模型, 擅长挖掘局部数据特征, 自适应地提取全局训练特征和分类。此外, CNN 方法非常适合用于处理海量数据。通过了解海量数据的特征, 可以识别海量数据中包含的信息。因此, 使用 CNN 的诊断是基于深度学习的故障诊断方法研究发展方向之一。

基于 CNN 的诊断和预测技术研究目前还不多<sup>[15]</sup>, 特别是在发动机故障诊断方面的应用较少。本文针对卷积神经网络故障诊断方法进行了研究, 基于发动机试验仿真数据对提出的方法进行了验证, 并与支持向量机等传统方法进行了比较, 验证结果表明, 提出的基于卷积神经网络的诊断方法具有较好的可行性和效果, 可作为开展发动机 PHM 技术研究的参考。通过开展复杂装备基于 CNN 等深度学习的故障诊断研究, 实现对地面测试与运行阶段海量数据的充分利用, 可以为装备典型功能系统的多参数之间的综合分析诊断与评估提供依据, 确保装备的稳定健康运行。

## 1 基于卷积神经网络的故障诊断方法

深度神经网络模型的构建如图 1 所示。这里采用基于 DNN 深度神经网络的 CNN 卷积神经网络, 实现发动机气

路诊断, 适用于解决复杂设备在物理模型难以构建时的诊断模型构建问题。与传统的 DNN 算法相比, CNN 可以解决 DNN 模型参数数量过多、容易过度拟合、容易陷入局部最优等问题。

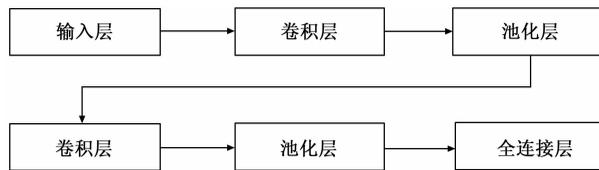


图 1 深度神经网络模型的构建

CNN 是一种特殊的深度神经网络模型, 该方法的神经元连接是非完全连接的, 此外, 同一层中某些神经元之间的连接的权重是共享的 (即相同的)。CNN 在自学习、并行处理、容错性等方面均具有较强的能力, 能够降低网络模型的复杂性和权重的数量。

如图 2 所示, 卷积神经网络结构包括卷积层、采样层、全连接层等。其中, 卷积层主要负责提取对象的各种特征; 采样层主要实现对原始特征信息的抽象, 目的是大幅减少训练参数并减轻模型过拟合的程度。

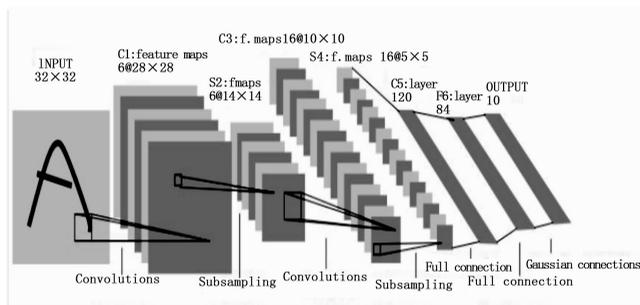


图 2 卷积神经网络结构图

CNN 的训练算法分为两个阶段: 前向传播阶段: 该阶段首先需要从样本集中取样并输入网络, 然后再计算相应的实际输出。后向传播阶段: 需要先计算真实结果与预期结果之间的差值, 然后再根据最小化误差的方法调整权重矩阵。

综合第一阶段和第二阶段的 CNN 网络训练过程包括如下步骤: 1) 选择训练组, 从样本集中随机选择  $N$  个样本作为训练对象; 2) 将每个权重和阈值设置为接近 0 的随机值, 并初始化精度控制参数和学习速率; 3) 从训练组中选择一个输入模式并将其添加到网络中, 给出其目标输出向量, 并计算中间层输出向量和网络的实际输出向量; 4) 比较输出向量中的元素与目标向量中的元素, 以计算输出误差和中间层的隐藏单元的误差; 6) 依次计算每个权重和阈值的调整量, 并调整权重和阈值; 7) 重复进行多次训练, 判断指标是否满足精度要求, 如果不满足, 则继续从训练组中选择输入模式并将其添加到网络中进行迭代, 否则训练结束; 8) 在训练结束时, 将权重和阈值保存在文件中, 此时可认为权重已经稳定并且已经形成分类器。再次进行

训练时，就可以直接从文件导出权重和阈值以进行训练而无需初始化。

本文使用 CNN 主要用于数据的预处理，将发动机训练层进行卷积化，每 15 条发动机数据作为一个 window size 的单位数据，如图 3 所示。

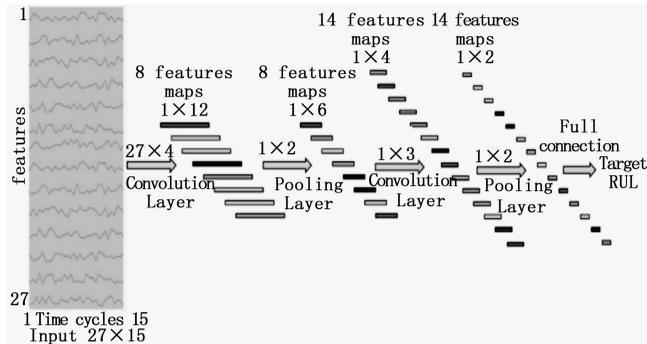


图 3 基于 CNN 的数据预处理

模型训练过程开始后选择数据集，对数据集进行处理生成数据训练文件，通过 split 操作进行文件切割，如图 4 所示。使用线性回归器进行参数网络选择，线性回归器、参数网络、回归评估器共同支撑数据进行验证训练，最后生成预测结果，比对观察值进行模型评估，如图 5 所示。

采用 CNN 模型，在预处理阶段使用  $24 \times \text{window size}$  大小的数据

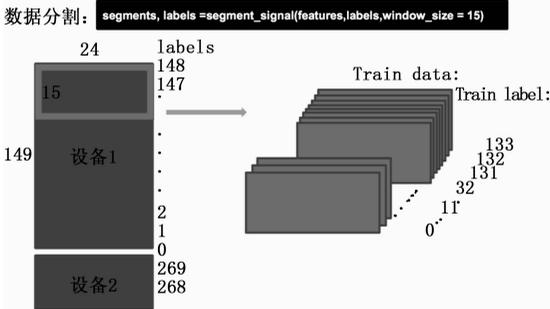


图 4 数据分割与训练示意

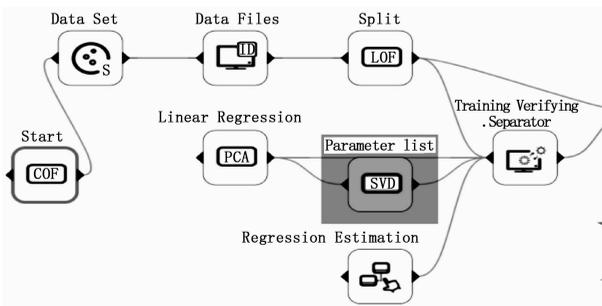


图 5 训练模型优化示意

## 2 基于卷积神经网络的气路故障诊断软件平台

在 CNN 方法研究基础上开发了基于 CNN 的气路故障诊断软件平台，如图 6 所示。

发动机气路故障诊断属于典型的复杂系统故障模式识别问题，其反应故障状态的特征维度较大，反映的信息较

为丰富且复杂，因此通过单层的神经网络进行建立故障模式识别模型不足以达到有效的识别精度和识别效果，难以对特征值中反映的有效信息进行提取。采用深度学习方法可以在神经网络的基础上对于数据中反映的特征信息进行多次的降维和重构，达到对高阶信息的提取和整合目的。

基于海量数据的发动机气路故障诊断涉及到多维参数（如温度、压力、高度、马赫数、高压转速、油门角度等）的处理。这也是发动机气路故障诊断需要解决的技术难点。深度学习中的卷积神经网络（CNN）有助于解决上述问题。该方法通过获取空间内部多维参数的信息，最大化挖掘出数据背后的规律，以实现较好的故障诊断效果。

CNN 方法的应用首先是进行卷积层 CNN，并通过卷积+池化的方法提取出某个时间点特征之间的空间信息，具体包括：

- 1) 卷积层：对整体数据做卷积，通过多个卷积核来提取不同角度的空间信息；
- 2) 池化层：减少模型的参数维度，提高模型训练的效率。

机器深度学习模型在构建之后，需要输入固定的数据维度和特征，这就导致不同设备可能由于输入数据不同无法复用，当遇到新的设备或者部件需要故障诊断，就需要重新开发对应的算法，虽然算法的总体核心结构没有差异，但是也需要针对模型接口进行重新定义、针对数据进行重新训练，同时这也带来了模型测试、验证的复合问题，这也是基于海量数据的发动机气路故障诊断的另一个技术难点。为解决该问题，拟从模型的开发效率、复用性、测试性、验证性多个角度出发，搭建机器学习的诊断预测统一平台，作为平台算法的管理中心、开发中心和测试中心。

基于机器学习的诊断预测建模平台能够提供基础算法库、专业算法库、专业模板库、模型管理、在线建模等功能，用户能够基于自己以往的算法、专业算法、专业模板对模型进行复用，极大的提高模型定制开发的效率。同时，平台提供模型训练、验证一体化功能，并提供后台 GPU 分布式集群，保证训练的速度，从算法开发、维护、复用、训练、验证全角度实现用户的算法需求，最终保证 PHM 系统的整体算法智能化。该平台基于 TensorFlow 架构，采用 Python 语言实现深度学习等算法，并通过 API 接口层调用 TensorFlow 核心功能实现相关实验和应用<sup>[16]</sup>。

本文的算法实现基于 Python 语言。Python 是一种面向对象的解释型计算机编程语言，包含丰富强大的算法工具库，可快速实现各种深度神经网络方法，并通过 TensorFlow 平台实现集成和调用。

在方法层面，整体过程包括：数据集成、数据处理、特征工程、模型训练、模型评估、模型保存等。重点选择 CNN、DNN 等神经网络模型，选用故障检测率（FDR）评价指标，实现对测试数据诊断效果的评估。

复杂系统（发动机气路）故障诊断算法平台功能包括：诊断流程创建模块、流程模版管理模块、数据集设置管理

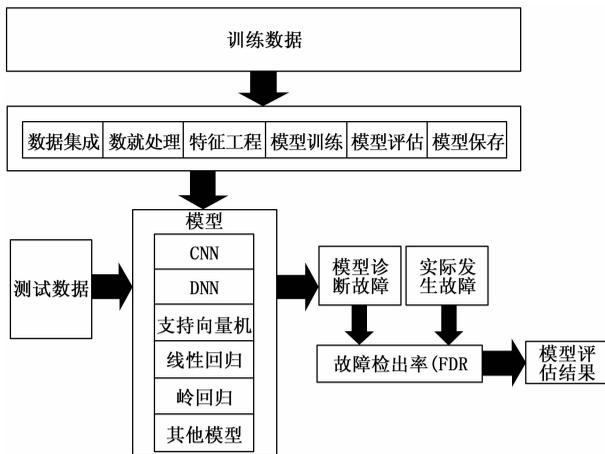


图 6 基于深度学习的发动机气路故障诊断算法总体实现思路

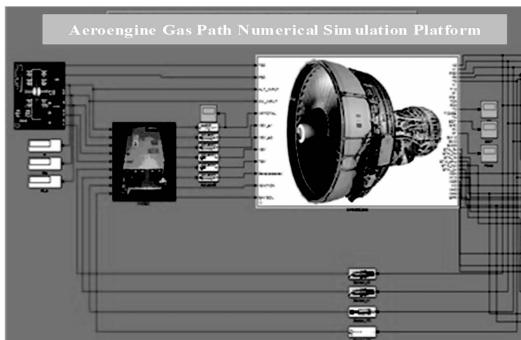


图 8 航空发动机气路故障仿真平台

模块、算法模型编辑管理模块、算法模型训练模块、算法性能评估模块等。如图 7 所示。

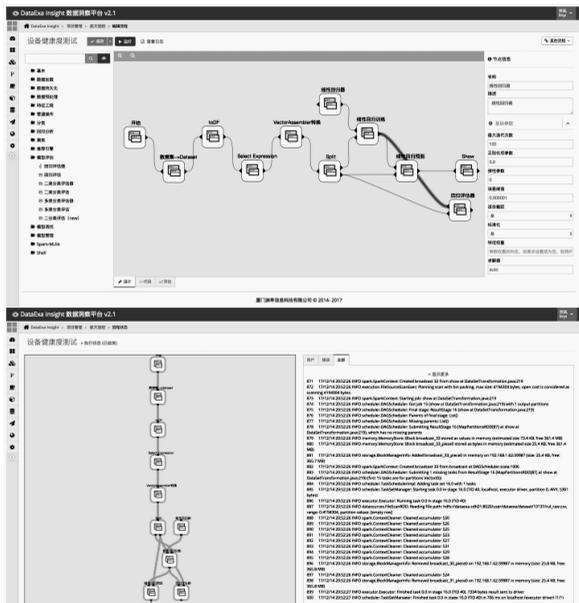


图 7 机器学习建模、机器学习训练页面示意图

### 3 实验和分析

#### 3.1 实验说明

该组仿真数据源于根据某型航空发动机气路模型所生产的发动机气路故障数据, 数据描述的是发动机从启动到稳态, 然后在稳态期间进行故障注入, 期间采集到的相关数据, 如图 8 所示。

故障数据包含 HPC 效率突降 (叶冠掉块)、HPT 效率突降 (盘裂纹)、LPT 效率突降 (盘裂纹) 等三类故障模式的注入。每种故障都设定了 9 种初始条件, 仿真过程中油门杆以 15° (慢车点) 起步, 经过寻找初始平衡点并给定阶跃输入到 20 s 后模型到设定的目标稳态工作点, 40 s 时加入 3% 气路部件故障, 故障程度经过 50 s 按照斜坡发展至

5%, 然后平稳至 100 s 仿真结束。

仿真模型每隔 0.02 s 采集输出一次数据, 持续 100 s, 主要包含以下发动机参数信息:

- 1) 温度; 2) 压力; 3) 高度; 4) 马赫数; 5) 高压转速; 6) 油门角度; 7) ETA\_Fc 风扇内涵效率; 8) ETA\_Fd 风扇外涵效率; 9) ETA\_fb 增压级效率; 10) ETA\_cmp 压气机效率; 11) ETA\_hpt 高压涡轮效率; 12) ETA\_lpt 低压涡轮效率; 13) W13 风扇外涵出口流量; 14) W24 风扇内涵出口流量; 15) W26 增压级出口流量; 16) W3 压气机出口流量; 17) W45 高压涡轮出口流量; 18) W5 低压涡轮出口流量; 19) N1 低压转速; 20) P13 风扇外涵进口总压; 21) P2 风扇内涵进口总压; 22) P24 风扇内涵出口总压; 23) P26 增压级出口总压; 24) P3 压气机出口总压; 25) P45 高压涡轮出口总压; 等等。

#### 3.2 数据选取处理

选取 HPC、HPT、LTP 三类故障文件数据作为训练集与验证集, 将故障注入产生的文件进行整理合并, 合并后的文件分别定义数据标签 (正常、HPC 效率突降 (叶冠掉块)、HPT 效率突降 (盘裂纹)、LPT 效率突降 (盘裂纹))。数据文件中前 10 000 的数据作为验证数据集, 10 000 以后的数据为训练数据集。

178648	9054.3	2522.8	8858.9	22525	1.94E+05	51002	7576.2	6.2892	4.6105	8.9710	14.658	38.764	85.225	61.528	24758	0.005007	0.28557	1
178651	7868.3	481.59	7858.9	22564	2.35E+05	50473	6476.3	4.7867	3.28045	5.6205	11.501	41.028	88.918	60.889	32274	0.003289	0.33821	1
178652	8612.2	1543.6	8400.8	22662	2.12E+05	54620	7123.9	6.7891	2.821	7.5311	13.471	35.283	87.24	60.564	28654	0.005281	0.33564	1
178675	7896.6	-15.82	7859.9	22881	2.41E+05	60211	6380.1	4.6553	-0.028464	5.2337	11.571	40.188	89.882	60.82	30175	0.003282	0.33706	1
278889	7896	-451.77	7452.2	22923	2.50E+05	61890	6171	3.7899	-0.82556	4.5911	11.104	40.307	90.664	60.886	31099	0.005644	0.34587	1
178695	8077.2	367.45	7946.6	22871	2.34E+05	58952	6566.8	5.0388	0.67151	5.801	12.043	38.905	88.215	60.825	29979	0.003446	0.32957	1
178697	7594.1	-678.05	7460.7	22998	2.54E+05	62734	6564.3	3.6812	-1.2291	4.2594	10.707	42.407	91.11	60.583	31587	0.006028	0.33502	1
178619	8782.1	1785.9	8525.4	22854	2.08E+05	52782	7242.6	1.7128	3.2172	7.8888	13.782	38.201	86.898	60.708	28572	0.004282	0.33204	1
178623	8088.4	300.52	7857.9	22829	2.34E+05	59843	6577.4	5.0582	0.69541	5.8237	12.066	38.924	89.252	60.886	29711	0.003422	0.32954	1
178635	7965.1	105.51	7728.1	22885	2.38E+05	59951	6447	4.6435	0.18383	5.4192	11.733	40.071	89.786	60.986	29928	0.003655	0.33512	1
178642	7871.2	-527.33	7428	22929	2.51E+05	62244	6434.2	3.6921	-0.9837	4.4884	10.961	40.387	90.921	60.977	31287	0.006116	0.34783	1
178651	7785	-328.35	7522.9	22622	2.48E+05	61545	60414	3.991	-0.60289	4.7798	11.206	40.308	90.598	60.974	30887	0.005118	0.34396	1
178619	8427.3	1102	8288.2	21783	2.21E+05	56371	6026.8	6.1461	2.0138	6.8518	12.956	38.584	88.265	60.861	27889	0.007734	0.33333	1
178673	8883.9	2313.1	8714.4	22614	1.98E+05	51949	7406.6	7.9633	4.2238	8.8738	14.431	38.885	85.878	60.735	25596	0.005126	0.32988	1
178635	8123.9	434.77	7883.9	22881	2.34E+05	60121	51487	0.74955	5.0106	12.146	38.949	89.275	90.945	28096	0.003282	0.32989	1	
178634	8840.2	1994.2	8635.5	22865	2.04E+05	53342	7351.4	7.489	3.6444	8.2094	14.025	38.185	86.49	60.789	29888	0.003209	0.32748	1
179001	8837.6	1546.1	8425.5	22728	2.13E+05	47949	7242.4	6.8266	2.8554	7.5006	13.506	38.403	87.317	60.961	29547	0.003565	0.33065	1
179012	7394	142.32	7351.9	22688	2.38E+05	59913	6476.3	4.7867	3.28045	5.6205	11.795	40.122	89.861	61.015	29603	0.003171	0.33499	1
179017	6261.9	798.05	6295.5	8289.5	8.28E+04	15787	6766.8	5.6803	1.4418	6.4373	12.588	38.884	88.713	60.987	28572	0.005948	0.32028	1
179014	7961.5	68.963	7727.3	22916	2.41E+05	60249	64583	0.12001	5.3766	11.704	41.178	40.102	61.05	30101	0.003817	0.33661	1	
179044	8717.1	1824.9	8584	22709	2.08E+05	53827	7279.3	7.2395	3.335	7.9668	13.855	38.295	86.685	60.888	28382	0.004082	0.33013	1
179054	7952.7	59.849	7783.8	22628	2.41E+05	60208	64424	4.5866	0.10837	5.3655	11.704	40.187	90.089	61.079	30133	0.003263	0.33594	1
179065	8076.1	1375.9	8055	22175	2.18E+05	59497	7070.8	6.9988	2.5345	7.8388	13.513	38.941	87.744	60.983	27482	0.005946	0.33016	1
179073	8228.3	428.44	7854.4	22864	2.35E+05	59329	6611.5	5.309	0.74277	6.379	12.182	40.24	88.937	61.074	28414	0.004282	0.33214	1
179089	8131.2	413.29	7904.4	22889	2.35E+05	59252	6611.2	5.3222	0.75259	6.9022	12.143	40.045	89.514	61.088	28406	0.004082	0.33008	1
179001	7679.2	-565.9	7423.6	22012	2.53E+05	62783	6146.2	3.6487	-1.0242	4.4485	10.948	40.545	91.261	61.01	31475	0.006128	0.34972	1
179103	8168.2	486.08	7938.4	22800	2.33E+05	58799	64424	3.991	-0.60289	4.7798	11.206	40.308	89.424	61.009	29885	0.003282	0.32878	1
179114	7982.1	-760.2	7942.3	22042	2.58E+05	62096	6547.7	3.3881	-1.3893	4.3169	10.725	40.659	89.879	61.226	31898	0.007548	0.33773	1
179124	6832.3	-285.4	6361	22341	2.94E+05	70573	5348.6	0.27744	-1.1808	1.1295	8.017	41.478	90.593	61.484	30156	0.017747	0.34926	1
179132	8211.7	589.23	7981.3	22924	2.32E+05	58625	6691.9	5.3006	1.0403	6.1258	12.345	40.102	88.384	61.142	29109	0.005748	0.32773	1
179143	8401	978.97	8178.9	22881	2.24E+05	57055	6893.5	5.9748	1.7854	6.728	12.844	38.812	88.621	61.116	28251	0.005943	0.33192	1

图 9 训练数据样本文件

将数据输入与合并, 对输入数据进行预处理, 对于特征数据进行标准归一化处理, 对于标签数据进行 one-hot 形式的编码梳理。

6992	5431.6	7547.8	2522.3	1454.1	-1.51E+05	-27897	-27484	3.79E+05	1.41E+05	8764.8	1.02E+05	-76347	-34498	-15.175	-10.152	-0.02997	-0.18995	0
6993	2092.8	5711	2297.8	2234.1	-1.13E+05	-24958	-2369.9	2.88E2	4.23E5	2.578	1.432E2	-32348	-12.111	-13.141	-14035	-0.08202	-0.14315	0
6994	7489.7	13276	7636.6	9752	-1.88E+05	-36983	-179.92	7.198E	8.8492	7.029E	5.0013	-6.0703	-23.679	-21.533	-22737	-0.13441	-0.25369	0
6995	8454.5	14629	8035.9	15462	-2.02E+05	-39161	221	6.026E	3.0389	7.8222	5.339	-8.741	-25.768	-20.049	-24268	-0.14401	-0.27269	0
6996	7935.5	13868	8091.3	1240	-1.92E+05	-37887	11.863	7.5543	10.273	7.3772	5.2848	-29.916	-24.579	-22.171	-23387	-0.13848	-0.2822	0
6997	4226.3	8678.5	4356.2	382.54	-1.41E+05	-29471	-1464.1	4.4627	6.4287	4.3299	2.848	-5.742	-16.584	-16.849	-17382	-0.10137	-0.18587	0
6998	5194	7106.1	5281	1338.9	-1.29E+05	-27034	-1939	3.7371	5.2625	3.4529	2.1457	-5.0132	-14.211	-14.684	-16654	-0.09078	-0.184	0
6999	2142.8	5743.1	2245.5	2164.4	-1.12E+05	-24738	-2289.9	2.7358	4.258	2.9288	1.4988	-4.3198	-12.122	-13.931	-13895	-0.08204	-0.14301	0
7000	2398.3	6105.5	2526	2033.1	-1.18E+05	-25272	-2224.8	2.9300	4.5122	2.8184	1.6401	-4.4867	-12.253	-13.465	-14388	-0.08235	-0.14805	0
7001	4031.4	8388.5	4146.2	1028.4	-1.38E+05	-28955	-1544.4	4.2834	6.1391	4.1325	2.7137	-5.5784	-16.091	-15.945	-16971	-0.09072	-0.1809	0
7002	2907.6	6345.5	2916.3	1204.3	-1.17E+05	-25440	-2166.6	3.0184	4.0272	2.9895	1.7137	-4.4479	-12.855	-13.592	-14524	-0.08492	-0.1499	0
7003	2290	5937.1	2261.9	2047.9	-1.14E+05	-23615	-1859.9	2.8331	4.398	2.7259	1.5702	-17.323	-18.055	-4.4636	-13752	-0.07996	-0.1463	0
7004	1441.2	4337	1450.5	1458.8	-52323	-20297	-1854.2	2.2049	3.3609	2.0774	1.3674	18.834	4.9514	-5.0788	-11642	-0.063875	-0.12154	1
7005	2327.4	5521.9	2402.7	1329.5	-81374	-15505	-908.33	2.8665	4.0905	2.7454	1.8337	19.347	5.1183	-1.8948	-11793	-0.064528	-0.12762	1
7006	1922.4	51026	1932.3	221	-1.02E+05	-22886	682.45	5.7602	7.5311	5.9075	4.3789	17.262	-12.289	-7.645	-16427	-0.029276	-0.07179	1
7007	3184.7	6104.6	3200.4	-88.639	-70788	-16118	89.49	34.112	4.5221	3.2504	2.4119	18.801	4.7959	-2.1206	-10969	-0.060117	-0.1232	1
7008	2340.2	4658.7	2344	412.56	-57314	-10832	98.582	2.6258	3.451	2.5089	2.0172	20.321	7.8274	0.4612	86704	-0.044573	-0.094364	1
7009	8903.8	14647	8984.9	4797.8	-1.49E+05	-28770	3500.7	8.7939	10.998	8.6126	6.9396	15.154	-6.3709	-10.173	-19580	-0.11239	-0.22246	1
7010	4311.7	6474.8	4223.6	3833.7	-82855	-10140	1462.9	3.9794	4.7963	3.7442	3.1254	19.163	8.4925	0.82826	10391.1	-0.048984	-0.09941	1
7011	5939.6	8892.9	5941.5	3335.9	-73813	-12827	2603.4	5.4115	6.5978	5.2916	4.4265	18.729	7.214	-0.5441	-11255	-0.026289	-0.11573	1
7012	6427.7	9351.9	6444.8	3909.3	-70827	-10006	3231.4	5.7737	6.6276	5.5525	4.7979	18.825	9.5509	0.97304	-11041	-0.06117	-0.10388	1
7013	4482.2	6231.7	4413.4	3177.8	-30617	-8072	2777.7	4.0266	4.8629	3.8865	3.5377	20.563	17.266	6.1974	-8868.4	-0.02942	-0.02894	1
7014	5988.8	8978.9	5956.2	3914	-29402	-2293.5	3407.6	4.551	5.1704	4.4519	4.0155	20.511	18.899	7.6163	-4852	-0.03002	-0.02746	1
7015	1542	1786.2	1448.4	2222.2	29455	6241.7	2389.9	1.5461	1.3231	1.4894	1.7186	23.283	30.962	15.384	-22.41	0.00534	0.08942	1
7016	4129.9	5214.8	4045.6	4220	7711	5359.8	3877.9	3.4481	3.7961	3.353	3.4855	22.009	28.518	13.977	-3201.3	-0.012468	-0.04719	1
7017	5234.4	11962	5199.2	7182.5	-48788	-2681.9	6488	7.8504	8.8763	7.7072	6.9148	19.979	22.702	8.7599	-20189	-0.055103	-0.021255	1
7018	-2048.8	-3991.5	-2249.1	1335.8	1346E+05	24153	1994	-1.5982	-2.9568	-1.6134	-0.52857	36.83	49.88	27.869	8604.8	0.058921	0.1083	1
7019	6104.1	7043.7	5877.3	19274	19374	9517.9	8070.1	5.2177	5.0331	4.9454	2.054	36.89	18.237	-2920.1	-0.018897	-0.028423	1	
7020	4835.5	4917.3	4925.5	6191.1	49319	15220	5875.2	3.9175	3.8722	3.8901	4.1336	23.345	43.199	22.594	286.07	0.009173	0.12141	1
7021	2289.3	1118.6	226	-548.6	99984	23499	5381.1	1.7873	0.82895	1.7311	2.4751	25.424	51.935	28.44	3455.9	0.048821	0.12356	1
7022	2022.1	2103.6	2976.2	6505.1	96951	24336	6010.8	2.4851	1.9508	2.4215	3.1126	25.265	53.368	29.173	5221.3	0.030016	0.22057	1

图 10 验证数据样本文件

### 3.3 深度学习模型搭建

在深度学习模型搭建过程中，主要实现目的是根据这些数据进行故障诊断，最终通过计算故障准确率，以诊断正确性比率作为模型评价指标。故障注入标签有 3 个故障模式，分别为 HPC 效率突降（叶冠掉块），HPT 效率突降（盘裂纹），LPT 效率突降（盘裂纹），因此模型搭建为四分类问题：0：正常；1：HPC 故障；2HPT 故障；3：LPT 故障。

由于该问题属于四分类问题，所以神经网络的最最后一层有 4 个神经元，并使用 softmax 作为其输出层的激活函数。深度学习模型结构如图 11 所示。

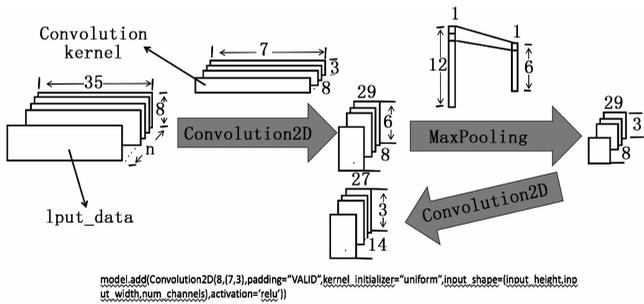


图 11 深度学习模型图卷积池化过程

课题采用训练器为 SGD（Stochastic Gradient Descent，随机梯度下降），损失函数使用的是交叉熵函数，评估标采取的 acc（分类准确率）。深度学习模型图训练过程如表 1 所示。

表 1 深度学习模型图训练过程

层	输出	参数
conv2d_1(conv2D)	(None, 29, 6, 8)	176
max_pooling2d_1(maxPooling2)	(None, 15, 3, 8)	0
conv2d_2(conv2D)	(None, 13, 3, 14)	350
flatten_1(Flatten)	(None, 546)	0
dense_1(Dense)	(None, 128)	70016
dropout_1(Dropout)	(None, 128)	0
activation_1(Activation)	(None, 128)	0
dense_2(Dense)	(None, 4)	516

全部参数:71058; 可训练参数:71058; 不可训练参数:0

### 3.4 结果对比分析

#### 3.4.1 基于 SVM 方法的气路故障诊断

支持向量机作为一种机器学习方法，建立在统计学习和结构风险最小原理的基础上。支持向量机作为二元分类器。对线性可分和线性非可分数据的分类非常有效，对发动机数据拟合与预测有良好的适应性。

通过 SVM 算法对模型生成发动机气路故障训练数据进行训练，得到分类训练模型。之后，将测试数据导入模型中进行计算，诊断发动机的运行状态，并将其与实际状态进行对比。其分类结果如表 2 所示。

表 2 基于 SVM 的气路诊断验证统计结果

测试样本总数	正确分类样本数	错误分类样本数	诊断准确率
2 625	1 750	875	66.67%

从表 2 可见，采用 SVM 算法对该组发动机试验数据进行分类，其诊断的准确率仅为 66.67%。

#### 3.4.2 基于深度学习方法的故障诊断

采用本课题构建的深度神经网络，经过 3 个 epochs（1 个 epoch 表示过了 1 遍训练集中的所有样本）的循环学习，训练集合上的准确率即可达到了较高的程度。训练 10 个 epochs 之后，保存生成模型。在测试验证集上，对于训练得到的模型进行监测，最终得到的故障检测准确率指标接近 100%，即全部测试数据识别诊断均为正确，可见基于 CNN 的深度学习能力，其分类能力能够实现较高的精度指标。由此可见，深度学习方法较传统分类方法，在气路故障诊断应用上能够得到较大的准确率提升。

表 3 基于 CNN 的气路诊断验证统计结果

测试样本总数	正确分类样本数	错误分类样本数	诊断准确率
2 625	2 620	5	99.8%

## 4 结论

本文研究了基于卷积神经网络的发动机气路故障诊断方法，并实现了复杂系统故障诊断预测算法平台。经某发动机气路试验仿真数据实例验证，提出的方法具有较好的可行性和效果，较传统的支持向量机方法，在诊断的检测率上有较大的提升，能够充分利用深度学习的优点，更准确地识别发动机气路的健康状况。

### 参考文献:

[1] Yuan K, Guo X. Fault diagnosis of diesel engine based on BP neural network information engineering and applications [C]. Springer London, 2012: 890 - 897.

[2] 赵 军, 候宽新, 赖安卿. 基于径向神经网络的航空发动机气路故障诊断 [J]. 计算机测量与控制, 2016, 24 (7): 76 - 81.

[3] Yu M, Pan F, Lian X F, et al. Fault diagnosis system of A2 /

- O process based on parameter estimation and expert System [J]. Applied Mechanics and Materials, 2013, 263: 1647-1651.
- [4] Qu H C, Ding X B. Civil aero-engine fault diagnosis based on fuzzy least square support vector machine [J]. Applied Mechanics and Materials, 2012, 130: 2047-2050.
- [5] Tang Y, Eliasmith C. Deep networks for robust visual recognition [A]. International Conference on Machine Learning [C]. 2010: 1055-1062.
- [6] Sze V, Chen Y H, Yang T J, et al. Efficient processing of deep neural networks: a tutorial and survey [A]. Proceedings of the IEEE [C]. 2017, 105 (12): 2295-2329.
- [7] Lee H, Pham P T, Yan L, et al. Unsupervised feature learning for audio classification using convolutional deep belief networks [A]. Advances in Neural Information Processing Systems 22: , Conference on Neural Information Processing Systems 2009 [C]. Vancouver, British Columbia, Canada, 2009: 1096-1104.
- [8] Hamel P, Eck D. Learning features from music audio with deep belief networks [A]. International Society for Music Information Retrieval Conference [C]. Netherlands, 2010: 339-344.
- [9] Li H R, Gu S S. A fast parallel algorithm for a recurrent neural network [J]. Acta Automatica Sinica, 2004, 30 (4): 516-522.
- [10] Glorot X, Bordes A, Bengio Y. Domain adaptation for large scale sentiment classification: a deep learning approach [A]. Proc of the 28th International Conference on Machine Learning [C]. 2011: 513-520.
- [11] Mesnil G, Dauphin Y, Glorot X, et al. Unsupervised and transfer learning challenge: a deep learning Approach [A]. Workshop on Unsupervised & Transfer Learning [C]. 2011, 7: 1-15.
- [12] 吴瑀倩, 李 静, 吴晓舟. 基于深度信念网络的民航发动机状态监测 [J]. 计算机测量与控制, 2017, 25 (7): 28-31.
- [13] Fang H Z, Shi H, Dong Y F, et al. Spacecraft power system fault diagnosis based on DNN [A]. 2017 Prognostics and System Health Management Conference (PHM-Harbin) [C]. 2017: 1-5.
- [14] 车畅畅, 王华伟, 倪晓梅, 等. 基于深度学习的航空发动机故障融合诊断 [J]. 北京航空航天大学学报, 2018, 44 (3): 621-628.
- [15] Jiang Z D, Fang H Z, Shi H, et al. The prognostic method of engine gas path based on Convolutional Neural Network [A]. Proceedings of the 3rd International Conference on Information Technology and Industrial Automation (ICITIA2018) [C]. 2018.
- [16] Ertam F, Ardin G. Data classification with deep learning using Tensorflow [A]. 2017 International Conference on Computer Science and Engineering (UBMK) [C]. Antalya, Turkey. 2017: 5-8.
- [17] Abhinav S, Kai G, Don S, et al. Damage propagation modeling for aircraft engine run-to-failure simulation [A]. International Conference on Prognostics and Health Management [C]. USA: IEEE, 2008: 1-9.

(上接第 4 页)

建设激光装备的数字化验证能力, 构建激光系统效能数据库;

3) 加速推动试验鉴定能力建设, 在满足高能激光系统技术攻关要求的同时, 着眼于激光装备应用部署需要, 建成能够满足全系统研制和试验评价需求的集成、测试和效能验证平台, 为我国高能激光系统的实战化应用提供有力支撑。

#### 参考文献:

- [1] 刘 铭. 国外激光系统技术的发展 [J]. 舰船电子工程, 2011, 31 (4): 18-23.
- [2] 刘晓明, 葛悦涛. 高能激光系统的发展分析 [J]. 战术导弹技术, 2014, 1: 5-9.
- [3] 李怡勇, 王建华, 李 智. 高能激光系统发展态势 [J]. 兵器装备工程学报, 2017, 38 (6): 1-6.
- [4] 程 勇, 郭延龙, 唐 璜, 等. 战术激光系统的发展动向 [J]. 激光与光电子学进展, 2016 (11).
- [5] Glen P, Salvatore J, Robert L, et al. 激光系统系统导论 [M]. 北京: 国防工业出版社, 2014.
- [6] 冯寒亮, 韩 锋, 张 平. 美国海军舰载高能激光系统 [J]. 激光与光电子学进展, 2006, 43 (7): 41-45.
- [7] 刘 毅. 机载战术激光系统关键技术探讨 [J]. 航空兵器, 2011, 5: 43-46.
- [8] 辜 璐. 机载激光系统回顾与发展 [J]. 红外与激光工程, 2006, 35: 48-51.
- [9] 何奇毅, 宗思光. 舰载激光系统发展进展与思考 [J]. 激光与红外, 2017, 47 (12): 1455-1460.
- [10] 李 旻. 激光系统的发展动向与分析 [J]. 舰船电子工程, 2017, 37 (11): 16-20.
- [11] 张晶晶. 舰载激光系统的发展 [J]. 舰船电子工程, 2016, 36 (6): 17-20.
- [12] 薄 中, 冯 策, 孙 超, 等. 美军联合任务环境下的能力试验方法分析 [J]. 中国电子科学研究院学报, 2018, 13 (4): 471-475.
- [13] 王国盛, 洛 刚. 美军一体化试验鉴定分析及启示 [J]. 装备指挥技术学院学报, 2010, 21 (2): 95-98.
- [14] 杨 磊, 武小悦. 美军装备一体化试验与评价技术发展 [J]. 国防科技, 2010, 31 (2): 8-14.
- [15] 张 睿, 郝桂友, 方 博, 等. 美军武器装备试验鉴定中可靠性工作分析及启示 [J]. 质量与可靠性, 2018, 195 (3): 19-22.