

基于卷积神经网络的发动机故障预测方法

元尼东珠¹, 杨浩^{2,3,4}, 房红征^{2,3,4}

(1. 青海民族大学 计算机学院, 西宁 810007; 2. 北京航天测控技术有限公司, 北京 100041;

3. 北京市高速交通工具智能诊断与健康重点实验室, 北京 100041;

4. 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: 近年来, 卷积神经网络 (CNN) 等深度学习方法的发展为发动机故障诊断和预测带来了新的思路; CNN 具有局部连接、权值共享、池化操作以及多层结构等特点, 能够有效提取局部特征, 降低网络的训练难度, 使 CNN 具有很强的学习能力和特征表达能力; 开展了深度卷积神经网络故障预测方法研究, 实现了面向发动机气路故障预测算法架构; 利用基于发动机试验仿真数据对该方法进行了验证, 并与其他几种常见的基于数据驱动的预测方法进行了比较, 验证结果表明文章提出的基于卷积神经网络的预测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。

关键词: 故障预测; 深度学习; 卷积神经网络 (CNN); 发动机

Aero-engine Prognostic Method Based on Convolutional Neural Network

Yuan Nidongzhu¹, Yang Hao^{2,3,4}, Fang Hongzheng^{2,3,4}

(1. Computer College, Qinghai Nationalities University, Xining 810007, China; 2. Beijing Aerospace Measure & Control Corp. Ltd, Beijing 100041, China; 3. Beijing Key Laboratory of High-speed Transport Intelligent Diagnostic

and Health Management, Beijing 100041, China; 4. National and Local Joint Engineering Research Center of Equipment Life Cycle Condition Monitoring and Health Management Technology and Application, Beijing 100041, China)

Abstract: In recent years, the development of deep learning methods have brought new ideas to engine prognosis and health management. CNN has the characteristics of sparse connectivity, shared weights, pooling operation and multi-layer structure. It can effectively extract local features, reduce the training difficulty of the network, and make CNN have strong learning ability and feature expression ability. The prognostic method based on convolutional neural network is studied, and the software platform of the algorithm for engine gas path fault prognosis is realized. Using the test data from engine simulation, verification study shows that prognostic method proposed has better feasibility and effectiveness for the prognostic technology of aero-engine compared with other data-driven prediction methods.

Keywords: prognostic; deep learning; convolutional neural network (CNN); aero-engine

0 引言

在发动机等典型设备的故障诊断中, 具有较好的非线性问题处理能力的神经网络等方法得到了很多成功的应用。随着人工智能科学的发展, 机器学习算法不断丰富, 学习深度不断加深, 性能不断提高, 基于深度学习得到广泛应用, 在图像、视觉和智能对弈等领域取得了空前的成功^[1-2]。深度学习方法是多层表示的表示学习方法, 多层表示由一个从低到高的非线性简单模块网络获得, 每个模块将表示从一个层次 (起始于原始输入) 转化至另一个更高的更抽象的层次。深度学习是机器学习的一个分支, 基于一个尝试使用多复杂结构处理层或多非线性变化来模型化高层次抽象的算法集。

常见的深度学习包括深度神经网络 (Deep Neural Network, DNN)^[3-4]、深度置信网络 (Deep Belief Network, DBN)^[5-6]、递归神经网络 (Recurrent Neural Network,

RNN)^[7]、卷积神经网络 (Convolutional Neural Network, CNN) 等^[8-9]。其中, 卷积神经网络 (CNN) 作为一种重要的深度神经网络方法, 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, 在模式识别各个领域都取得了很好的成果^[10]。此外在工业生产流水线上对磁片的缺陷检测、潜射武器健康状态评估也有了初步应用^[11-12]。

基于卷积神经网络的预测方法已经有了一些研究。文献 [13] 利用 CNN 方法权值共享的特性带来的减少网络参数数量、降低训练难度、便于网络优化的优势, 对飞行器的航迹进行了预测。文献 [14] 利用改进卷积神经网络 DropSample 训练方法构建短时交通流量预测模型, 并利用 Adam 算法的优化器对预测模型进行优化, 与传统的 CNN、卡尔曼滤波、BP 神经网络等方法相比取得了更高的预测精度。文献 [15] 建立了一种用于太阳能辐照度预测的卷积神经网络结构, 针对 CNN 预测模型因为超参数选取不当而导致预测性能差的问题, 利用融合算法对 CNN 网络的超参数进行优化, 有效地提高了 CNN 的预测性能。但是目前在

收稿日期: 2019-07-15; 修回日期: 2019-08-20。

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。

发动机故障预测领域的应用较少。本文针对卷积神经网络故障预测方法进行了研究, 基于发动机试验仿真数据对提出的方法进行了验证, 并与其它一些传统的方法进行了比较, 验证结果表明, 提出的基于卷积神经网络的预测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。

1 基于卷积神经网络的故障预测方法

1.1 卷积神经网络原理

卷积神经网络的模型构建如图 1 所示。CNN 具有局部连接、权值共享、池化操作以及多层结构等特点, 一方面使得 CNN 可以有效提取局部特征, 并通过网络参数数量的减少从而降低训练过程的难度; 另一方面对于平移、缩放、倾斜或其他形式的变形具有不变性, 使其适用于时间序列和语音等信号的处理; 此外, 其多层结构的特点还具有比其他方法更强的学习与特征表达能力。

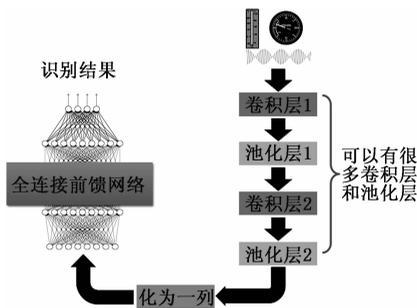


图 1 卷积神经网络模型构建示意图

卷积神经网络的基本结构包括输入层、卷积层、激活层、池化层、全连接层和输出层等。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。

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。

1.2 基于 CNN 的故障预测方法

基于 CNN 的预测方法的流程如图 2 所示。首先, 对发动机的故障预测试验数据集进行预处理, 将相应的数据进行归一化。然后准备用于训练和测试的数据集, 其中每个样本包含时间窗内的时间序列信息。之后, 基于特定的信号处理问题和数据集信息, 开始建立用于预测的卷积神经网络, 并且确定其配置包括隐藏层的数量, 卷积滤波器数量和长度等。卷积神经网络将标准化训练数据作为输入, 并且训练样本的标记剩余寿命值用作网络的目标输出。反

向传播学习用于更新网络中的权重。对于每个训练周期, 将样本随机分成多个小批量, 每批包含若干(如 512)个样本, 并放入训练系统。接下来, 基于每个小批量的平均损失函数来优化网络信息, 即每层中的权重。批量大小的选择会影响网络训练性能。例如本研究中根据实验发现 512 个样品的批量大小是合适的, 并且它被用于本文的所有案例研究中。此外, 采用不同的学习率。最后, 将测试数据样本馈送到训练的网络中以进行剩余寿命估计, 并且得到预测准确性。

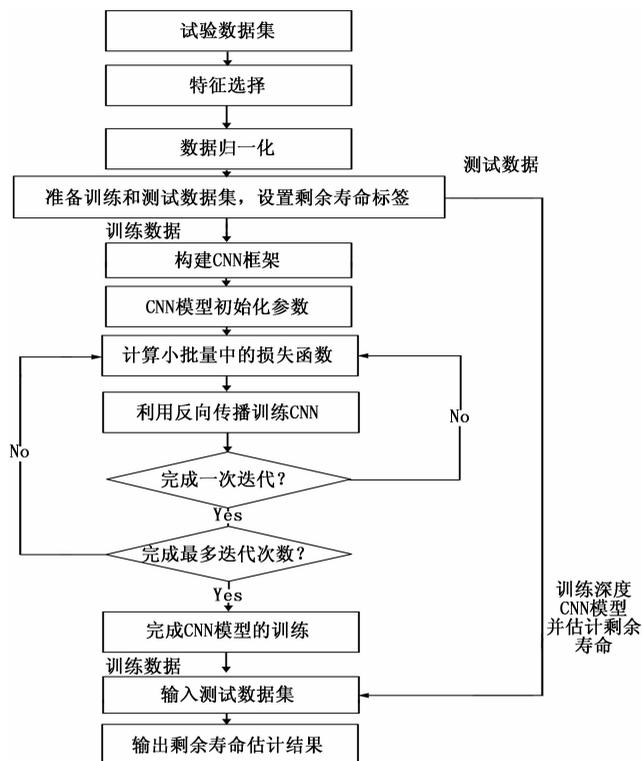


图 2 卷积神经网络模型构建示意图

2 基于卷积神经网络的气路故障预测软件平台

在卷积神经网络方法研究基础上开发了基于深度学习的气路故障诊断预测软件平台。算法实现基于 TensorFlow 平台架构, 使用 Python 语言实现深度学习和其他算法。TensorFlow 平台架构示意如图 3 所示。

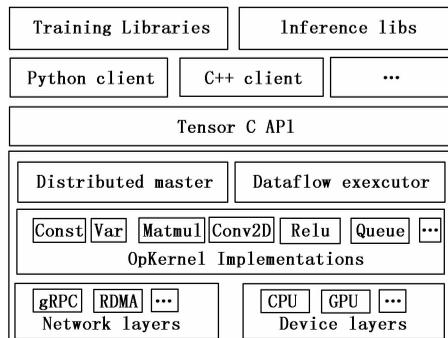


图 3 TensorFlow 平台架构示意图

如图 3 所示, 通过平台 API 接口层的核心功能, 可以

实现相关的实验和应用^[16]。TensorFlow 的系统架构如图 3 所示。它从底部分为设备管理/通信层, 数据操作层, 图形计算层, API 接口层和应用层。在所有层中, 管理/通信层, 数据操作层和图形计算层是 TF 的核心层。

在方法层面, 整个过程包括数据集成, 数据处理, 特征工程, 模型培训, 数据集成, 模型评估, 模型保存等。选择卷积神经网络 (CNN)、长短时记忆网络 (LSTM) 等深度学习模型, 选择 MES, RMSE 和相关系数等评价指标, 评价试验数据的预测精度。气路预测算法包括诊断过程构建模块, 过程模板管理模块, 数据集设置管理模块, 算法模型编辑管理模块, 算法模型训练模块和算法性能评估模块等。

利用软件平台各个功能模块, 通过平台构建模型的过程主要包括: 创建流程; 选择流程模板; 修改流程参数; 训练模型, 评估性能。深度学习模型评估页面如图 4 所示。

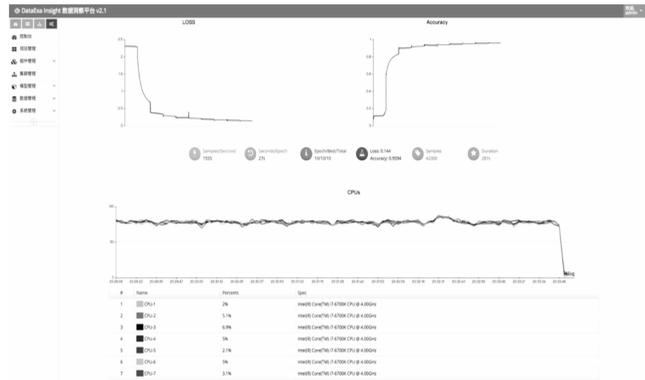


图 4 深度学习模型评估页面示意图

3 实验和分析

3.1 实验说明

发动机测试数据源自于 NASA 发布的一组发动机实验数据, 该组数据包含了一系列多元多变量时间序列。NASA 发布该数据主要用于开展发动机寿命预测方面的竞赛等目标^[17]。发动机实验数据描述如表 1 所示。

表 1 发动机实验数据描述

训练数据	测试数据	剩余寿命数据
train_FD001	test_FD001	RUL_FD001
train_FD002	test_FD002	RUL_FD002
train_FD003	test_FD003	RUL_FD003
train_FD004	test_FD004	RUL_FD004

这里利用该数据开展基于数据的发动机的故障预测方法研究, 通过人工智能方法实现基于数据的预测。本试验数据的每一组数据被划分成了训练和测试数据, 每台发动机的全寿命测试数据, 测试数据中分别含有 100 台、259 台、248 台发动机某生命周期阶段中的数据, 剩余寿命

数据给出了测试数据中每台发动机的实际剩余寿命。

实验数据主要记录了发动机每次工作循环的以下 26 个参数:

- 1) 发动机号; 2) 循环次数; 3) 运行设置 1; 4) 运行设置 2; 5) 运行设置 3; 6) 风扇入口总温 T2; 7) LPC 出口总温 T24; 8) HPC 出口总温 T30; 9) LPT 出口总温 T50; 10) 风扇入口压力 P2; 11) 旁通总压 P15; 12) HPC 出口总压 P30; 13) 物理风扇转速 Nf; 14) 物理核心机转速 Nc; 15) 发动机机压气 Epr (P50/P2); 16) HPC 出口静压 Ps30 (Psia); 17) 燃油流量 Phi; 18) 换算风扇转速 NRF; 19) 换算高压转速 NRC; 20) 涵道比 (BPR); 21) 燃烧室油气比 (FarB); 22) 气流焓值 (htBleed); 23) 要求的风扇转速 Nf_dmd; 24) 要求修正的风扇转速 PCNfR_dmd (R/min); 25) HPT 冷却流量 W31 (Lbm/s); 26) LPT 冷却流量 W32。

3.2 数据选取处理

本文选取 test_FD002 文件数据作为验证数据, 选取 RUL_FD002 文件数据作为观察值数据, 并对数据进行归一化等处理。训练数据样本和测试数据样本文件如图 5、图 6 所示。

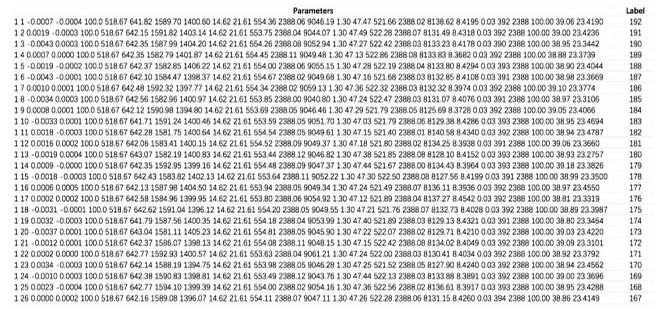


图 5 训练数据样本文件



图 6 测试数据样本文件

根据数据特点, 再进行归一化等预处理操作。数据的结尾为标签信息。由于数据特征空间不一致, 需要进行归一化处理, 以品名各特征权重。预处理后生成相应的结果数据。

3.3 模型搭建

根据卷积神经网络模型原理, 结合上述试验数据, 在

相关文献基础上^[17-18], 搭建学习模型, 实现相关预测过程。模型包含 2 层 CNN 和 2 层的池化层构建神经网络, 如图 7 所示。

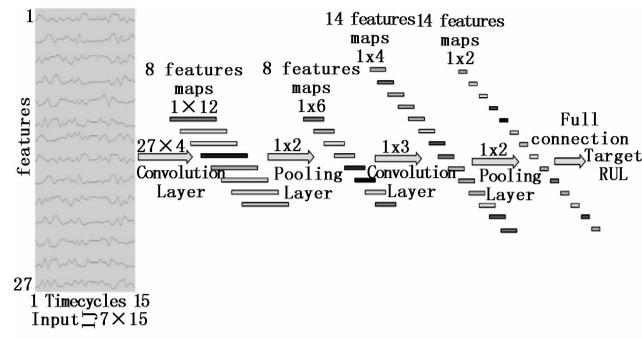


图 7 面向发动机故障预测的 CNN 模型示意图

由于综合了连续的 15 条记录进行预测, 所以选择了卷积神经网络进行建模。卷积神经网络通过卷积核, 将卷积视野下的连续几个特征卷积在一起, 达到了更好的提取局部特征的功能。

池化层采用下采样操作 (最大值方法), 即对于某个 Filter 抽取到若干特征值, 只取其中得分最大的那个值作为 Pooling 层保留值, 其它特征值全部抛弃, 值最大代表只保留这些特征中最强的, 而抛弃其它弱的此类特征。

面向发动机试验数据的 CNN 模型结构主要包括以下过程: 卷积 (Convolution): 特征扫描、提取; 池化 (Pooling): 特征过滤, 最大值法; 降维 (Flatten): 实现数据的平展与降维; 分类 (Dense): 对提取的特征进行分类。

3.4 模型验证

将处理后的训练数据, 利用神经网络进行训练, 得到训练后的气路系统故障诊断与预测模型。之后, 将测试数据导入模型中进行计算, 得出每个发动机的剩余寿命, 并将其与实际结果进行对比与评价。评价方法选用 MES、RMSE、Pearson 相关系数等指标。计算方法如下:

$$MES = \frac{1}{n} \sum_{i=1}^n (Observed_i - Predicted_i) \quad (1)$$

$$RMSE = \sqrt{MSE} \quad (2)$$

$$PCC = \frac{1}{n-1} \sum_{i=1}^n \left(\left(\frac{X_i - \bar{X}}{S_x} \right) \left(\frac{Y_i - \bar{Y}}{S_y} \right) \right) \quad (3)$$

其中: MSE 主要用于评价数据的变化程度; RMSE 主要用于评价样本离散程度; Pearson 相关系数 (PCC) 主要用来衡量定距变量间的线性关系。

利用卷积神经网络将处理后的训练数据进行训练, 得到发动机气路系统故障预测模型。将测试数据导入模型预测每台发动机的剩余寿命。如图 8 所示。

3.4 结果对比分析

为便于与本文提出的方法进行对比, 在验证过程中对一些数据驱动的方法进行了应用分析, 包括支持向量机、线性回归、岭回归、弹性网络、贝叶斯脊回归等方法, 具体说明如下: 1) 支持向量机方法建立在统计学习和结构风

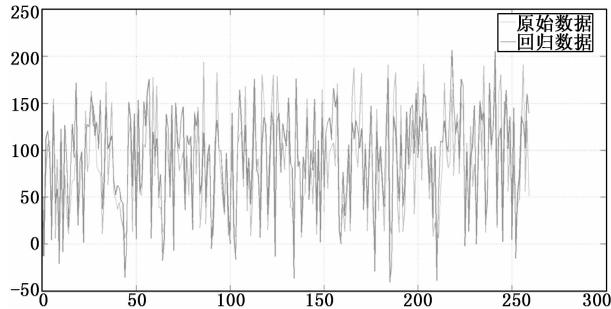


图 8 基于 CNN 模型的预测结果示意图

险最小原理的基础上, 可作为二元分类器, 对线性可分和线性非可分数据的分类较为有效, 对发动机数据拟合与预测有良好的适应性; 2) 线性回归是一种传统的基于回归分析的数理统计分析方法, 包括简单回归和多元回归等; 3) 岭回归建立在最小二乘估计基础上并进行了改进, 较为适合针对线性数据的分析; 4) 弹性网络是一种适用于很少的权重不为零的稀疏模型的线性回归模型; 5) 贝叶斯脊回归方法主要用于解决最大似然估计中很难决定模型的复杂程度, 并对数据进行正规化处理。

上述各种算法的预测结果如图 9~12 所示, 预测结果分析如表 2 所示。

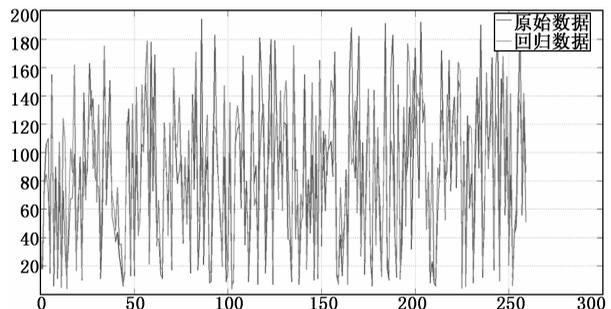


图 9 基于支持向量机的预测结果示意图

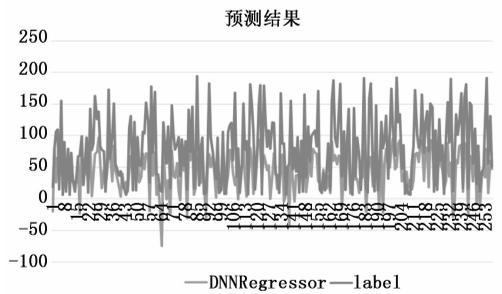


图 10 基于线性回归的预测结果示意图

表 2 基于实验数据的预测算法验证结果对比分析结果

误差及方法	CNN	线性回归	岭回归	弹性网络	支持向量机
MSE	976.137 1	3 056.32	1 627.26	2 088.91	1 018.6
RMSE	31.243 2	55.28	40.34	45.70	31.916
Pearson 相关系数	0.730	0.677	0.723	0.726	0.8108

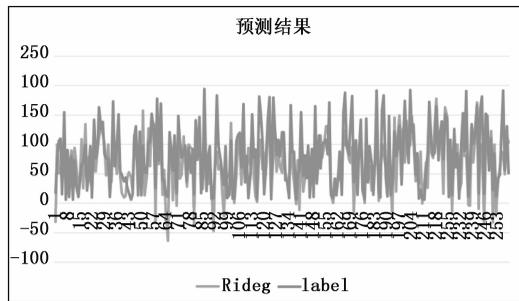


图 11 基于岭回归的预测结果示意图

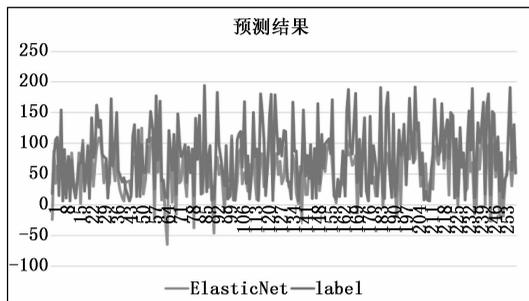


图 12 基于弹性网络的预测结果示意图

从表 2 可见, 通过各算法的 MSE、RMSE 和 Pearson 系数可得出, CNN 由于具有良好的容错能力和自学习能力, 其预测精度最高, 与实际数据的相关度也较高, 基于回归分析的预测精度最差; SVM 由于具备非线性及高维模式识别的优势, 也具有较好的预测精度和效果, 且与实际数据的相关度更高。

4 结论

本文研究了基于卷积神经网络的发动机故障预测方法, 构建了基于深度学习的发动机故障预测人工智能算法平台, 实现的人工智能算法, 较传统支持向量机以及回归分析等方法相比, 在预测的准确率上有较大的提升。研究方法可直接应用于典型实验环境下的航空发动机气路故障诊断与预测; 算法经适应性调整和训练后, 亦可推广应用于其他类型的发动机装备中, 具有较好的推广前景和价值。

参考文献:

- [1] Lee H, Grosse R, Ranganath R, et al. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations [A]. International Conference on Machine Learning, ICML 2009 [C]. Montreal, Quebec, Canada, 2009: 609 - 616.
- [2] Raina R, Battle A, Lee H, et al. Self-taught learning: transfer learning from unlabeled data [A]. International Conference on Machine Learning [C]. ACM, 2007: 759 - 766.
- [3] Tang Y, Eliasmith C. Deep networks for robust visual recognition [A]. International Conference on Machine Learning [C]. 2010: 1055 - 1062, 2010.
- [4] 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.
- [5] Lee H, Pham P T, Yan L, et al. Unsupervised feature learning for audio classification using convolutional deep belief networks [A]. Conference on Neural Information Processing Systems 2009 [C]. Vancouver, British Columbia, Canada, pp: 1096 - 1104, 2009:.
- [6] Hamel P, Eck D. Learning features from music audio with deep belief networks [A]. International Society for Music Information Retrieval Conference [C]. Ismir 2010, Utrecht, Netherlands, 2010: 339 - 344.
- [7] Li H R, Gu S S. A fast parallel algorithm for a recurrent neural network [J]. Acta Automatica Sinica, 30 (4): 516 - 522, 2004.
- [8] Glorot X, Bordes A, Bengio Y. Domain adaptation for large scale sentiment classification: a deep learning approach [C]. Proc of the 28th International Conference on Machine Learning, 2011, 513 - 520.
- [9] 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: 1 - 15.
- [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] 姚明海, 杨 圳. 基于轻量级卷积神经网络的实时缺陷检测方法研究 [J], 计算机测量与控制, 2018, 27 (6): 22 - 25, 40.
- [12] 郑帮涛. 基于大数据分析的潜射武器健康状态评估 [J]. 计算机测量与控制, 2018, 26 (4): 272 - 275.
- [13] 吴一凡, 冉晓旻. CNN 神经网络在航迹预测中的应用 [J]. 电子设计工程, 2019, 27 (12): 13 - 20.
- [14] 陈深进, 薛 洋. 基于改进卷积神经网络的短时公交客流预测 [J]. 计算机科学, 2019, 46 (5): 175 - 184.
- [15] 董 娜, 常建芳, 吴爱国. 基于融合算法优化的卷积神经网络预测方法 [J]. 天津大学学报 (自然科学与工程技术版), 2019, 52 (9): 990 - 998.
- [16] Ertam F, et al. Data classification with deep learning using Tensorflow [A]. 2017 International Conference on Computer Science and Engineering (UBMK) [C]. Antalya, Turkey, 2017.
- [17] Saxena A, Kai G, Simon D. Damage propagation modeling for aircraft engine run-to-failure simulation [A]. International Conference on Prognostics & Health Management [C]. 2008: 1 - 9.
- [18] Li X, Ding Q, Sun J Q. Remaining useful life estimation in prognostics using deep convolution neural networks [J]. Reliability Engineering & System Safety, 2018, 172: 1 - 11.