

# 基于 SDAE 的航空发动机燃油流量基线模型构建

黄曦<sup>1</sup>, 卿新林<sup>1</sup>, 王奕首<sup>1</sup>, 殷锴<sup>2</sup>, 赵奇<sup>2</sup>

(1. 厦门大学 航空航天学院, 福建厦门 361102; 2. 中国航发商用航空发动机有限责任公司, 上海 200241)

**摘要:** 为克服传统的基线模型算法(如 BP 神经网络算法)存在的泛化能力不高、鲁棒性差且容易陷入局部最优解等缺点, 构建了基于堆叠降噪自动编码器(SDAE)的航空发动机燃油流量基线模型, 利用民航发动机的真实飞行数据对基线模型进行训练与验证, 并与基于 BP 神经网络的基线模型进行对比分析。结果表明: 基于 SDAE 的燃油流量基线模型具有更高的精度和更强的鲁棒性。

**关键词:** 燃油流量; 实时监控; 堆叠降噪自动编码器; 基线模型; 航空发动机

中图分类号: V240.2

文献标识码: A

doi: 10.13477/j.cnki.aeroengine.2019.02.006

## Construction of Aeroengine fuel flow baseline Model based on Stacked Denoising Autoencoders

HUANG Xi<sup>1</sup>, QING Xin-lin<sup>1</sup>, WANG Yi-shou<sup>1</sup>, YIN Kai<sup>2</sup>, ZHAO Qi<sup>2</sup>

(1. School of Aerospace Engineering, Xiamen University, Xiamen Fujian 361102, China;

2. AECC Commercial Aircraft Engine Co.Ltd., Shanghai 200241, China)

**Abstract:** In order to overcome the shortcomings of traditional baseline model algorithm (such as Back Propagation), such as low generalization ability, poor robustness and easy to fall into local optimal solution, a fuel flow baseline model of aeroengine based on Stacked Denoising Autoencoders (SDAE) was established. The baseline model was trained and verified by using the real flight data of civil aviation engine, and compared with the baseline model based on BP neural network. The results show that the fuel flow baseline model based on SDAE has higher accuracy and stronger robustness.

**Key words:** fuel flow; real-time monitoring; Stacked Denoising Autoencoders; baseline model; aeroengine

## 0 引言

航空发动机工作在高温、高压、高速等极端条件下, 容易产生故障, 致使飞机迫降停飞, 甚至诱发飞行事故、危及飞行安全<sup>[1]</sup>。NASA 的统计资料表明: 在民用领域, 发动机故障占有所有飞机机械故障中的 1/3。全世界每年花费的 310 亿美元维修费用中发动机日常维护占 31%, 翻修占 27%<sup>[2]</sup>。为了在飞行过程中对航空发动机的健康状态实时监控, 需要建立相应的参数基线。以往航空发动机的相关参数基线无法直接测量, 一般由发动机生产商经过大量试验才能得到, 属于发动机生产商的机密信息。随着大数据时代的到来, 使用飞行数据建立基线模型的方法越来越普遍, 需要根据基线值与实际值的偏差来判断发动机的运

行状态, 确定维修方案等。燃油流量是发动机重要参数之一, 建立准确的燃油流量基线对于预防飞行事故的发生具有重要意义。

国内外的专家学者对于发动机重要参数基线模型开展了大量研究工作, 取得了不少成果。朱睿和刘志荣<sup>[3]</sup>利用线性拟合建立发动机整体及风扇、压气机、高压涡轮和低压涡轮 4 个单元体性能的健康曲线, 用于判断发动机整体及单元体的性能衰退情况; 钟诗胜<sup>[4]</sup>采用基于核函数的多元非线性回归分析方法, 对 Rolls-Royce 公司的发动机排气温度、燃油流量、高压转速和低压转速基线方程进行了求解; 闫锋<sup>[5]</sup>设计了以高斯函数为隐含层激励函数、以线性函数为输出层激励函数的多输入单输出的 RBF 神经网络, 建立了发动机燃油流量的健康基线来监测巡航过程中发动

收稿日期: 2018-05-28 基金项目: 中央高校基本科研业务项目(20720180120)资助

作者简介: 黄曦(1993), 男, 在读硕士研究生, 研究方向为航空发动机健康管理; E-mail: huangxi@stu.xmu.edu.cn.

引用格式: 黄曦, 卿新林, 王奕首, 等. 基于 SDAE 的航空发动机燃油流量基线模型构建[J]. 航空发动机, 2019, 45(2): 29-33. HUANG Xi, QING Xinlin, WANG Yishou, et al. Construction of aeroengine fuel flow baseline model based on stacked denoising autoencoders[J]. Aeroengine, 2019, 45(2): 29-33.

机状态参数的异常变化。但这些传统的算法普遍存在诊断精度不高、鲁棒性差等缺点。

目前常见的深度学习算法有自动编码器(Autoencoder, AE)<sup>[6]</sup>、深度置信网络(Deep Belief Network, DBN)<sup>[7]</sup>、卷积神经网络(Convolutional Neural Networks, CNN)<sup>[8]</sup>以及循环神经网络(Recurrent Neural Networks, RNN)<sup>[9]</sup>等。其中自编码器在图像识别<sup>[10]</sup>、语音识别<sup>[11]</sup>、自然语言处理<sup>[12]</sup>等领域已经广泛应用。堆叠降噪自动编码器(Stacked Denoising Autoencoders, SDAE)算法由 Vincent 在 2010 年提出<sup>[13]</sup>,是在自动编码器和降噪自动编码器(Denoising Autoencoder, DAE)<sup>[14]</sup>基础上的改进算法,精度高、抗噪声能力强。为了克服传统机器学习算法在故障诊断领域的不足,本文采用 SDAE 建立了发动机的燃油流量的健康基线模型。

## 1 燃油流量基线模型构建

### 1.1 总体流程

自动编码器利用 SDAE 算法对燃油流量  $F$  建立基线模型的步骤如下:

(1)从真实的飞行数据中选取与  $F$  相关的参数作为输入;

(2)对初始数据进行预处理及其参数的修正;

(3)将预处理的数据按照 7:3:3 的比例来构建训练集、验证集和测试集;

(4)将训练集输入到 SDAE 模型中,根据验证集结果调整 SDAE 模型的超参数;

(5)将测试集输入到近似最优的 SDAE 模型中,来确定模型的拟合精度;

(6)将预处理的数据加上随机高斯噪声,重复第(4)、(5)步骤,检验 SDAE 模型的抗噪声能力。

### 1.2 真实飞行数据的获取

试验数据选自某航空公司波音 787 客机的真实飞行数据,其部分参数的原始巡航数据见表 1。

### 1.3 数据预处理及参数修正

考虑到飞行数据存在一些异常点和缺失点,建模前必须要对数据进行预处理。本文利用滑动中位数法对数据进行异常点去除,即建立 1 个滑动窗口,统计窗口内数据的中位数,若窗口内数据与中位数相差大于一定的阈值,则判定为异常点,对异常点和缺失数据点利用滑动窗口的均值补全。

表 1 波音 787 客机部分飞行数据

	$T_1$	$T_2$	$T_3$	...	$T_{1300}$
$F/(kg/s)$	0.684	0.689	0.696	...	0.678
$E_{GT}/K$	939.15	939.15	942.15	...	941.15
$N_1/\%$	81.1	81.0	81.5	...	80.9
$N_2/\%$	101	101	100	...	100
$A_{LT}/km$	9.484	9.484	9.485	...	9.485
$T_{AT}/K$	259.80	259.77	259.73	...	260.62
$V_{SV}/(^\circ)$	71.34	72.24	71.94	...	70.98
$Ma$	0.814	0.815	0.813	...	0.814
$P_3/MPa$	1.462	1.470	1.487	...	1.442
$T_3/K$	760.05	760.65	761.95	...	763.95

注: $E_{GT}$ 为该发动机的排气温度; $N_1$ 、 $N_2$ 分别为该发动机低、高压转子实际转速与额定转速的百分比,无量纲,实际建模时需要将其修正到标准大气压海平面状态下; $A_{LT}$ 为巡航阶段的飞行高度; $T_{AT}$ 为巡航阶段的外界大气总温; $V_{SV}$ 为发动机可调静子叶片偏离原设计的角度; $Ma$ 为飞行马赫数; $P_3$ 、 $T_3$ 分别为高压压气机出口压力和出口温度。

在建模前需要将燃油流量、压力、温度和转速修正到标准大气压海平面状态下。在此引入温度修正因子  $\theta$  和压力修正因子  $\delta$ <sup>[15]</sup>

$$\theta = \frac{T_{AT} + 273.15}{288.15} \quad (1)$$

$$\delta = (3.5 + 0.7Ma^2) \times (1 - 2.26 \times 10^{-5}H)^{5.23585}, H \leq 11000 \quad (2)$$

$$\delta = (3.5 + 0.7Ma^2) \times 0.224e^{-\frac{H-11000}{634.62}} \quad (3)$$

式中: $H$ 为飞行高度,根据  $\theta$  和  $\delta$  对参数进行修正。

温度修正公式为

$$T_{cor} = \frac{T_{raw}}{\theta} \quad (4)$$

式中: $T_{cor}$ 为修正后温度; $T_{raw}$ 为修正前温度。

压力修正公式为

$$P_{cor} = \frac{P_{raw}}{\delta} \quad (5)$$

式中: $P_{cor}$ 为修正后压力; $P_{raw}$ 为修正前压力。

转速修正公式为

$$N_{cor} = \frac{N_{raw}}{\sqrt{\theta}} \quad (6)$$

式中: $N_{cor}$ 为修正后转速; $N_{raw}$ 为修正前转速。

燃油流量修正公式为

$$F_{cor} = \frac{F_{raw}}{\delta\sqrt{\theta}} \quad (7)$$

式中: $F_{cor}$ 为修正后燃油流量; $F_{raw}$ 为修正前燃油流量。

### 1.4 堆叠降噪自动编码器

自动编码器(Auto-Encoder, AE)是深度学习网络

中常见的基础结构,是 1 种无监督的学习算法,主要用于学习输入数据集压缩的抽象表达。基本的 AE 由 1 个 3 层神经网络构成:1 个输入层,1 个隐藏层和 1 个输出层,如图 1 所示。由输入层(L1)到隐藏层(L2)的过程称为编码阶段,由隐藏层(L2)到输出层(L3)的过程称为解码阶段。

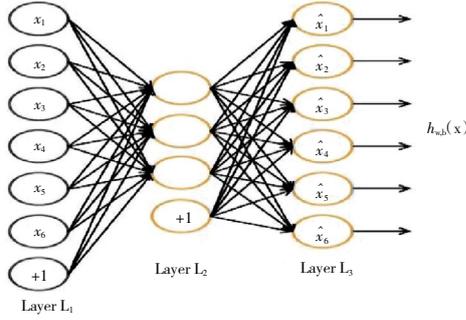


图 1 AE 网络结构

令  $f$  和  $g$  分别代表编码函数与解码函数。则有

$$Y=f(X)=S_f(W_f X+b_f) \quad (8)$$

$$Z=g(Y)=S_g(W_g Y+b_g) \quad (9)$$

式中: $S_f, S_g$  分别代表编码器和解码器的激活函数; $W_f$  为编码权重矩阵; $W_g$  为解码权重矩阵; $b_f, b_g$  分别为编码器和解码器偏置向量。一般选择 sigmoid 函数

$$\text{sigmoid}(z)=1/(1+e^{-z}) \quad (10)$$

且权重矩阵  $W_g$  通常取  $W_f^T$ 。自编码网络的作用是将输入样本  $X$  压缩到隐藏层  $Y$ ,再在输出端  $Z$  重建样本。其目标是使输出和输入之间误差尽量小。一般使用平方误差

$$L(X, Z)=\|X-Z\|^2 \quad (11)$$

或者交叉熵

$$L=-\sum_{i=1}^d [x_i \log(z_i)+(1-x_i) \log(1-z_i)] \quad (12)$$

作为自动编码器的损失函数。

式中: $d$  为输入和输出的维度。

对于样本容量为  $N$  的训练样本,自动编码器的风险函数为

$$J(\theta)=\frac{1}{N} \sum_{X} L(X, g(f(X))) \quad (13)$$

式中: $\theta=\{W_f, b_f, b_g\}$ 。

最后通过随机梯度下降算法最小化  $J(\theta)$ , 求出参数空间  $\theta$ 。

DAE 是在自动编码器的基础上为了防止过拟合问题而对输入的数据(网络的输入层)加入噪声,使学

习得到的编码器具有较强的鲁棒性,从而增强模型的泛化能力,其结构如图 2 所示。对输入数据加入噪声的方法,一般为加入与输入数据同分布的高斯噪声,或以一定概率将输入向量的分量置 0。

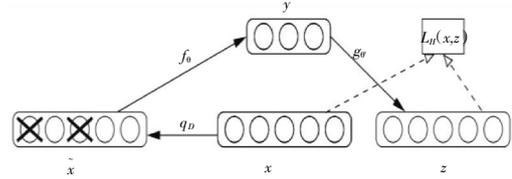


图 2 DAE 结构

SDAE 是多个降噪自动编码器堆叠组成的 1 种深度网络结构,利用前 1 层编码器的输出作为当前层编码器的输入。为了解决深度网络训练过程中出现的梯度消失等问题,Hinton 基于深度置信网络提出了 1 种贪婪逐层训练算法,即每次只训练 1 层网络,然后再将训练好的网络固定去训练下 1 层<sup>[16]</sup>,如图 3 所示。通过第 1 层 DAE 的学习得到的编码输出,再以此输出通过相同的方法添加噪声进行训练得到第 2 层的编码输出,最后根据需要重复此过程。

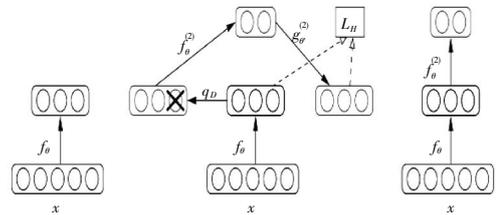


图 3 SDAE 结构

通过无监督训练得到的 SDAE 只是得到的原始数据精炼、抽象的 1 种表达,称为整个基线模型的预训练阶段,还不具备对基线的拟合能力。要想建立准确的健康基线,一般需要在 SDAE 顶端再添加 1 个回归层(如线性回归层),并结合少量有标注的训练数据在损失函数的指导下对系统的参数进行微调,使得整个网络能够完成对发动机燃油流量基线的建立。

## 2 试验及结果分析

### 2.1 模型建立

试验共选取 1300 组数据用于建立基线模型,其中 700 组用作模型的训练集,300 组用作模型的验证集,300 组用作模型的测试集。令

$$X=[E_{GT}, N_1, N_2, A_{LT}, T_{AT}, Ma, V_{SV}, P_3, T_3], Y=F \quad (14)$$

利用深度学习开源框架 Keras 构建 BP (Back Propa-

gation)神经网络和 SDAE 模型。针对 2 种模型分别选取一些不同的网络结构进行训练,记录验证集的均方误差 (Mean Squared Error, MSE) 随着迭代次数的变化,从而确定较优的网络结构和迭代次数。其中 BP 分别选取网络结构为 (9,10,1)、(9,15,1)、(9,20,1)、(9,10,10,1)、(9,15,15,1)、(9,10,20,1)进行验证。验证结果如图 4 所示。从图中可见,当 BP 网络结构为 (9,10,1),迭代次数为 750 次时,验证集的 MSE 最小。

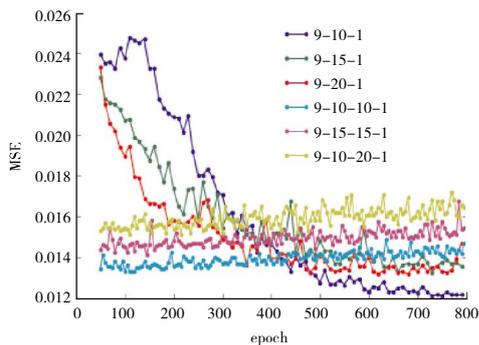


图 4 BP 模型验证集的 MSE

同理,分别选取结构为(9,10,5,1)、(9,10,7,1)、(9,7,4,1)、(9,8,5,1)的 SDAE 模型进行验证,其结果如图 5 所示。当 SDAE 模型结构为(9,10,7,1),迭代次数为 250 次时,验证集的 MSE 最小。

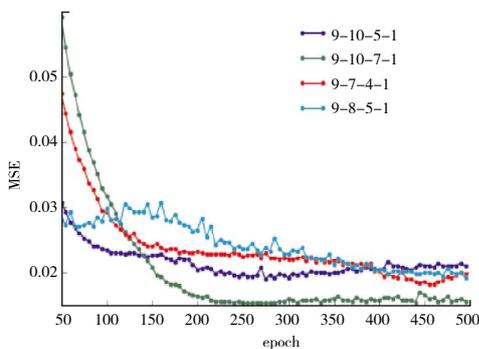


图 5 SDAE 模型验证集的 MSE

## 2.2 模型结果对比

对训练好的近似最优的 BP 模型和 SDAE 模型在测试集上的 MSE 比较可知,BP 的 MSE 为 0.023,而 SDAE 的 MSE 为 0.017。基于 BP 模型和 SDAE 模型的燃油流量预测曲线分别如图 6、7 所示。从图中可见,SDAE 模型在波动聚集区间的预测效果明显优于 BP 模型的。

BP 模型和 SDAE 模型的预测误差百分比分别如图 8、9 所示。从图中可见,SDAE 模型的预测误差百

分比小于 BP 模型的。

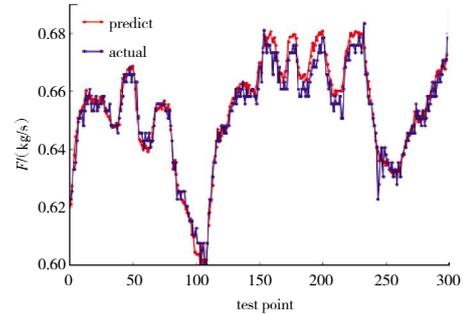


图 6 基于 BP 模型的燃油流量预测曲线

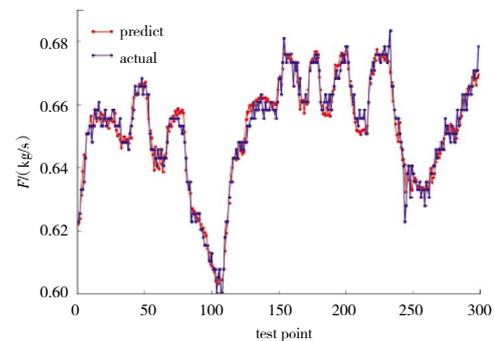


图 7 基于 SDAE 模型的燃油流量预测曲线

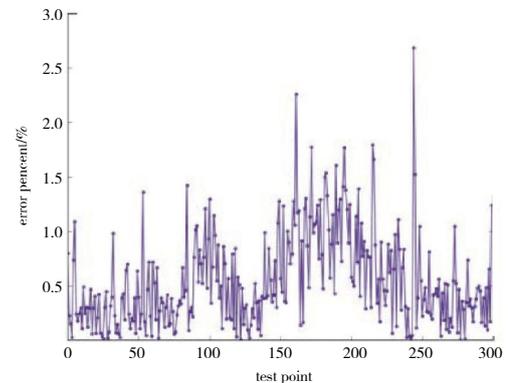


图 8 BP 模型预测误差百分比

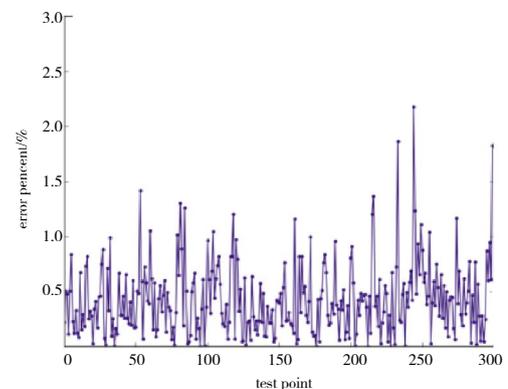


图 9 SDAE 模型预测误差百分比

实际飞行数据中不可避免地存在噪声,需要评估所建立模型的抗噪声能力。本文对输入数据加入不同

等级的高斯噪声,比较 BP 模型和 SDAE 模型在不同噪声等级下的拟合精度。2 种模型抗噪声能力的比较如图 10 所示。从图中可见,随着噪声等级的增加,2 种模型的 MSE 都在上升,但是 SDAE 模型的 MSE 上升的趋势相对更平缓,因此判断 SDAE 模型比 BP 模型有更好的抗噪声能力。

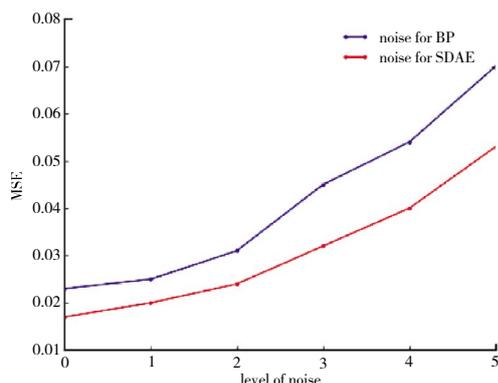


图 10 BP 模型和 SDAE 模型抗噪声能力比较

### 3 结束语

本文首次将深度学习算法中的堆叠降噪自编码用于发动机燃油流量基线模型的构建。利用真实民航飞行数据对模型进行验证,并将其与传统的 BP 神经网络算法在基线建立精度和抗噪声能力上进行比较。试验结果表明,基于 SDAE 的航空发动机燃油流量基线模型的精度和抗噪能力都优于基于 BP 算法的基线模型的。

#### 参考文献:

- [1] 杨洪富,贾晓亮,任寿伟. 基于数据驱动的航空发动机故障诊断与预测方法综述[J]. 航空精密制造技术,2016,52(5):6-9.  
YANG Hongfu, JIA Xiaoliang, REN Shouwei. Review of data-driven aeroengine fault diagnosis and prognosis methods[J]. Aviation Precision Manufacturing Technology, 2016, 52(5): 6-9. (in Chinese)
- [2] 王施,王荣桥,陈志英. 航空发动机健康管理综述[J]. 燃气涡轮试验与研究,2009(1):51-58.  
WANG Shi, WANG Rongqiao, CHEN Zhiying. Survey on aircraft engine health management [J]. Gas Turbine Experiment and Research, 2009(1): 51-58. (in Chinese)
- [3] 朱睿,刘志荣. 发动机健康基线及评估准则研究[J]. 厦门大学学报(自然科学版),2010,49(4):520-525.  
ZHU Rui, LIU Zhirong. Research of engine health baselines and evaluation criterion [J]. Journal of Xiamen University (Natural Science), 2010, 49(4): 520-525. (in Chinese)
- [4] 钟诗胜. Rolls-Royce 发动机基线挖掘方法 [J]. 计算机集成制造系统,2010,16(10):2265-2270.  
ZHONG Shisheng. Baseline mining method of RR's engine[J]. Computer Intergrated Manufacturing Systems, 2010, 16(10): 2265-2270. (in Chinese)
- [5] 闫锋. 一种航空发动机燃油流量基线的建模方法[J]. 计算机测量与控制,2015,23(5):1635-1638.  
YAN Feng. A modeling method for fuel flow baseline of aeroengine[J]. Computer Measurement & Control, 2015, 23(5): 1635-1638. (in Chinese)
- [6] Hinton G E, Rumelhart D E. Learning representations by back-propagating errors[J]. Nature, 1986, 323: 533-536.
- [7] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313: 504-507.
- [8] Sutskever A, Krizhevsky, Hinton G E. Imagenet classification with deep convolutional neural networks [J]. Neural Information Processing Systems, 2012, 25(2): 1097-1105.
- [9] Ronald J W, David Z. A learning algorithm for continue running fully recurrent neural networks [J]. Neural Computation, 1989, 1(2): 270-280.
- [10] Yeung D Y, Wang N. Learning a deep compact image representation for visual tracking [J]. Neural Information Processing Systems, 2013, 1: 809-817.
- [11] Sun M, Zhang X W. Unseen noise estimation using separable deep auto encoder for speech enhancement [J]. IEEE/ACM Transactions on Audio, Speech and Language Processing (TASLP), 2016, 24(1): 93-104.
- [12] Lajly S, Larochelle H. An autoencoder approach to learning bilingual word representations [J]. Neural Information Processing Systems, 2014, 2: 1561-1583.
- [13] Vincent P, Larochelle H, Lajoie I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion [J]. Journal of Machine Learning Research, 2010, 11: 3371-3408.
- [14] Vincent P, Larochelle H, Bengio Y, et al. Extracting and composing robust features with denoising autoencoders [C]//International Conference on Machine Learning. Helsinki: ACM, 2008: 1096-1103.
- [15] 林兆福,范作民. 发动机基线方程的建立和应用[J]. 中国民航学院学报,1992(4):20-32.  
LIN Zhaofu, FAN Zuomin. Development and application of engine baseline equations [J]. Journal of Civil Aviation Institute of China, 1992(4): 20-32. (in Chinese)
- [16] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.

(编辑:刘 静)