

DOI: 10.19783/j.cnki.pspc.190712

深度学习理论及其在电机故障诊断中的研究现状与展望

丁石川^{1,2}, 厉雪衣^{1,2}, 杭俊^{1,2}, 王尹江^{1,2}, 王群京^{1,2}

(1. 安徽大学电气工程与自动化学院, 安徽 合肥 230601;

2. 安徽大学高节能电机及控制技术国家地方联合工程实验室, 安徽 合肥 230601)

摘要: 电机已经被广泛应用到人们生产生活的各个领域, 电机的故障不但会对电机本身会造成损害, 甚至会引发经济损失、人员伤亡等各种问题。因此, 将及时且高效的故障诊断技术应用于电机有着重要意义。相比较传统故障诊断技术而言, 深度学习因其更强大更复杂的数据表达能力, 已被应用于电机故障诊断领域, 并取得了一定的研究成果。因此, 介绍了深度置信网络(DBN)、自编码网络(AE)、卷积神经网络(CNN)和循环神经网络(RNN)这四类经典的深度学习模型, 并总结了这四类模型在电机故障诊断中的应用。最后对深度学习在电机故障诊断领域中所面临的问题和挑战进行了总结和展望。

关键词: 电机; 故障诊断; 深度学习; 深度置信网络; 自编码网络; 卷积神经网络; 循环神经网络

Deep learning theory and its application to fault diagnosis of an electric machine

DING Shichuan^{1,2}, LI Xueyi^{1,2}, HANG Jun^{1,2}, WANG Yinjiang^{1,2}, WANG Qunjing^{1,2}

(1. School of Electrical Engineering and Automation, Anhui University, Hefei 230601, China; 2. National Engineering Laboratory of Energy-Saving Motor & Control Technology, Anhui University, Hefei 230601, China)

Abstract: The electric machine has been widely used in various fields, and its failure may not only cause damage to the machine, but also many problems, such as economic loss, casualties and so on. Therefore, it is important to apply timely and efficient fault diagnosis technology. Deep learning has been applied in fault diagnosis of electric machines and obtained some useful results because of its more powerful and more complex feature expression ability than traditional techniques. Hence, this paper introduces four classic types of deep learning model, the Deep Belief Networks (DBN), Auto-Encoders (AE), Convolutional Neural Networks (CNN) and Recurrent Neural Networks (RNN), and summarizes the application of these four deep learning models in electric machine fault diagnosis. Finally, the problems and challenges that deep learning faces in this application are summarized and prospects discussed.

This work is supported by National Natural Science Foundation of China (No. 51637001, No. 51607001, and No. 51507002) and Natural Science Foundation of Anhui Province (No. 1508085ME87 and No. 1708085QE108).

Key words: electric machine; fault diagnosis; deep learning; deep belief network; auto-encoders; convolutional neural networks; recurrent neural network

0 引言

在当今生产活动和日常生活中, 电机已是最重要的原动力和驱动装置, 已经被广泛应用到人们生产生活的各个领域。电机的故障发生或者停止运

行不但会对电机本身会造成损害, 而且也可能引发巨大经济损失、人员伤亡、污染环境等各种社会问题。因此, 电机故障诊断技术的研究具有重大意义。

电机故障诊断技术可以在故障的初期发现电机的故障问题, 从而能够及时进行针对性的检修, 节省了大量时间以及用于故障维修的资金, 在避免生产停顿的同时也提高了经济效益。传统的故障诊断方法需要人为提取大量的特征数据, 如时域特征、频域特征和时频域特征^[1-3], 增加了故障诊断的不确

基金项目: 国家自然科学基金项目资助(51637001, 51607001, 51507002); 安徽省自然科学基金项目资助(1508085ME87, 1708085QE108)

定性和复杂性。然而,随着电机的复杂、高效发展,反映电机运行状态的数据呈现出海量、多样化、流动速度快以及价值密度低等“大数据”特点^[4-6],这使得传统的故障诊断方法无法满足在大数据背景下的故障诊断需求。与此同时,人工智能技术的发展促使故障诊断技术由传统技术向智能化技术方向发展^[7]。20世纪80年代,人工神经网络兴起,浅层神经网络无需建立精确的数学模型便能够自适应学习特征^[8],避免了由人为干预带来的不确定性和复杂性,然而传统的浅层神经网络存在梯度衰减、过度拟合、局部最小、需要丰富的先验知识等缺点,使得故障诊断的效果大打折扣^[9]。

Hinton 等人^[10]在2006年首次提出了深度学习(Deep learning, DL)的思想,并证明了通过深度多层的网络结构得到的数据特征能够更加完整地描述原始数据;通过逐层初始化的方法可以有效降低深度神经网络的训练难度。深度学习在学术界和工业界的浪潮因此而开启。为了增强模型的泛化能力,Y. Bengio 等人^[11]于2007年提出了利用无监督贪婪逐层算法(unsupervised greedy layer-wise training)来训练深度神经网络,以此来优化深度网络结构的参数。在此基础上,Bengio 等人^[12]提出了利用误差反向传播算法对深度网络结构的参数进行进一步的优化,该方法的应用使得模型的性能进一步提高。

自深度学习理论被提出以后,深度学习在学术界和工业界发展迅猛,基于深度学习的很多传统识别任务的识别率显著提升,深度学习处理复杂识别任务的能力吸引了大批学者研究其理论和应用^[13]。深度学习理论也因此被广泛应用于各个领域来解决各个领域的难题,与此同时,基于深度学习的各种改进算法也在不断地被提出并加以应用。深度学习发展至今短短十几年,已经在图像^[14]、语音^[4]、人脸识别^[15]等领域取得了突破性进展。在电机故障诊断领域,基于深度学习的研究也正如火如荼,考虑到深度学习为电机的故障诊断提供了新思路和新方法,而系统地阐述深度学习理论及其应用于电机故障诊断研究现状的文献比较少。因此,本文详述了四类经典的深度学习模型的主要思想、工作原理以及建模方法,并且分析和总结了近年来国内外采用深度学习方法实现电机故障诊断的研究现状,其中重点总结了深度置信网络和自编码网络的原理以及训练过程,希望能够补充现有文献,并且帮助读者更好地理解深度学习原理,同时给读者提供新思路。

1 深度学习理论

作为机器学习的分支,深度学习源于神经网络

的研究,可以理解为是具有多隐层的神经网络^[16],现用来泛指基于多层网络结构的机器学习模型。与浅层神经网络相比,深度学习模型可以直接将原始数据作为输入,通过多层模型逐层学习数据特征,从而实现更加有效的特征表达^[17]。目前较为公认的深度学习模型有深度置信网络(Deep Belief Network, DBN)^[18-32]、自编码网络(Auto-Encoder, AE)^[33-55]、卷积神经网络(Convolutional Neural Networks, CNN)^[56-72]、循环神经网络(Recurrent Neural Network, RNN)^[73-96]。本节将较为详细地阐述上述深度学习模型的原理。

1.1 深度置信网络

深度置信网络(Deep Belief Network, DBN),亦称深度信念网络,是一种经典的深度学习网络,由Hinton 等人在2006年提出。DBN的实质是由堆叠起来的多个受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)^[18-19]和一个分类器构成的多层神经网络,通过组合低层特征形成抽象高层的方式来学习数据特征,其中低层表示原始数据,高层表示数据属性类别。

1.1.1 受限玻尔兹曼机

RBM 是一个两层的递归神经网络,如图1所示,RBM 由一层可视层(visible layer)和一层隐层(hidden layer)构成,分别包含 n 个显元(visible unit) $v=\{v_1, v_2, \dots, v_n\}$ 和 m 个隐元(hidden unit) $h=\{h_1, h_2, \dots, h_m\}$,而且显元和隐元都是状态为0或1的二元变量。显层及隐层的内部神经元之间没有连接,显层与隐层的神经元之间通过权重 w 连接。

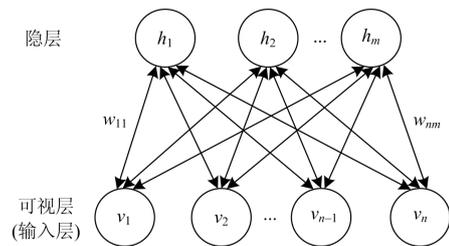


图1 受限玻尔兹曼机的结构

Fig. 1 Structure of RBM

RBM 是一种基于能量的模型,认为能量函数越小系统越稳定,通过训练使网络能量达到最小的同时也得到网络的最优参数。因此对于一组确定的神经元状态 (v, h) , RBM 的能量函数定义为

$$E(v, h|\theta) = -\sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m w_{ij} v_i h_j \quad (1)$$

式中: $\theta = \{w, a, b\}$; v_i 表示可视层第 i 个神经元状态; h_j 表示隐层第 j 个神经元状态; a_i 表示显元的偏

置; b_j 表示隐元的偏置; w_{ij} 表示显元 v_i 与隐元 h_j 之间的权重。连接显层和隐层的权重矩阵可以用 W 表示。

$$W = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1n} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{m1} & w_{m2} & \dots & w_{nm} \end{bmatrix} \quad (2)$$

1.1.2 深度置信网络的结构

图 2 是由一个分类器和 n 个 RBM 堆叠而成的 DBN 结构模型, 可视层 v (即输入层) 和隐层 h_1 构成 RBM_1 , RBM_1 的隐层 h_1 和第二层隐层 h_2 构成 RBM_2 (即 RBM_1 的输出作为 RBM_2 的输入), 以此类推, RBM_{n-1} 的隐层 h_{n-1} 和第 n 层隐层 h_n 构成 RBM_n , RBM_n 的隐层 h_n 和分类层 (即输出层) 则构成最顶层的分类器。样本特征从底层可视层输入, 经由中间 n 层进行特征提取, 最后从顶层的输出层输出分类识别的结果。其中输入层有 D 个单元, 对应样本的 D 维特征; 输出层有 c 个单元, 对应样本的 c 个类别, $W = \{W_1, W_2, \dots, W_{n+1}\}$ 为相邻两层之间的权值,

隐层的层数以及每层单元数需要根据经验设置。

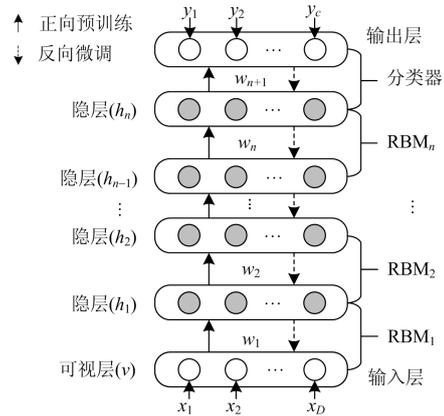


图 2 深度置信网络的结构

Fig. 2 Structure of DBN

1.1.3 深度置信网络的训练

图 3 所示为 DBN 的训练流程图。DBN 的训练分为预训练和反向微调两个阶段^[20-21]。

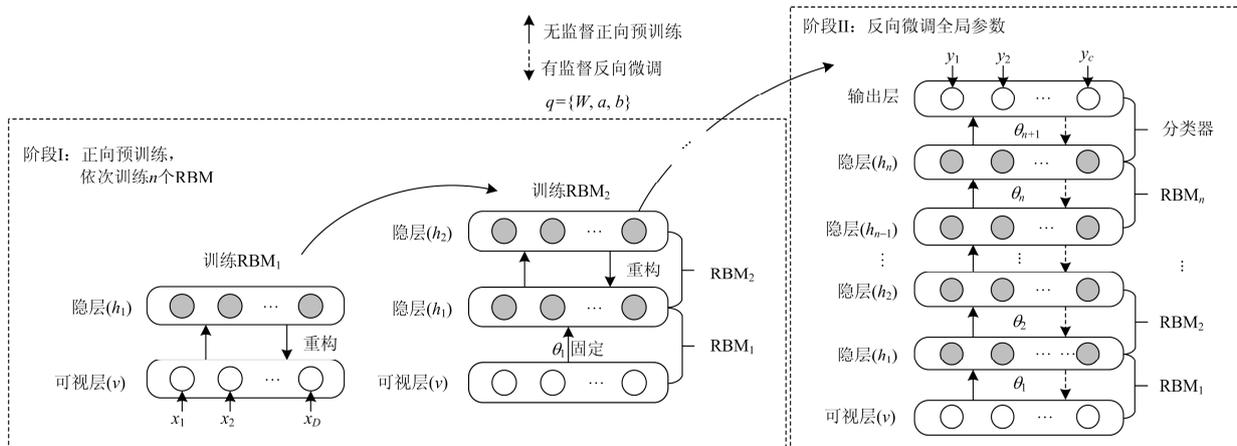


图 3 深度置信网络的训练流程

Fig. 3 Training process of DBN

第一阶段为预训练阶段, 采用自下而上逐层训练的方法, 首先训练 RBM_1 , 通过正向传播和反向重构更新 RBM_1 中的参数, 达到最大循环次数时, RBM_1 训练完毕, 此时固定 RBM_1 的参数, 再将 RBM_1 的输出作为 RBM_2 的输入对 RBM_2 进行训练, 以此类推依次训练 n 个 RBM, 并得到 n 个 RBM 所对应的输入层神经元偏置 a 、隐层神经元偏置 b 以及任意相邻两层之间的权值 W 。经过逐层训练后, 低层的原始特征被组合形成更加深度抽象的高层特征表达。由于预训练阶段不需要类别信息, 因此这种训练方式也被称为无监督贪婪逐层预训练 (unsupervised greedy layer-wise pre-training)^[11]。但由

于这种预训练方法无法使得整个网络的参数最优, 因此需要进入第二阶段对全局参数进行优化。

第二阶段为微调阶段, 在相应分类器中, 通过反向传播, 自顶向下调整参数, 最终得到微调后的参数 $\{W', a', b'\}$ 。由于微调量需要通过学习类别信息得到, 所以该阶段为有监督的训练, 因此微调过程又被称为有监督微调 (supervised fine-tuning)。DBN 这种半监督训练方式有效地解决了传统神经网络训练方法不适用于多层网络的问题^[22]。

1.2 自编码网络

自编码网络 (Auto-Encoder, AE) 是一种典型的三层非监督特征学习模型, 通过自适应学习特征,

令输出尽可能还原输入^[33-36]。根据定义特征表达的标准不同, 例如稀疏性的特征、降噪的特征、正则约束的特征等等, 演变出了相对应的自编码网络模型, 其中最常用的为稀疏自编码网络(Sparse AE)^[37-43]和降噪自编码网络(Denoising AE)^[41,44-48]。深度自编码网络则具有多层结构, 由多个自编码网络堆叠而成, 其中最常用的为栈式自编码网络(Stacked AE)^[40-42,47-55]。本节将介绍原始自编码网络、稀疏自编码网络、降噪自编码网络和栈式自编码网络。

1.2.1 原始自编码网络

图 4(a)为自编码网络的拓扑结构图, 如图 4 所示, 自编码网络是一种包含输入层、隐藏层、输出层的三层神经网络, 主要由编码器(Encoder)和解码器(Decoder)两部分组成, 其中由输入层和隐层构成编码器, 由隐层和输出层构成解码器。原始数据通过编码器的编码, 在隐层得到特征输出向量, 然后通过解码器将特征输出向量重构原始数据, 当输出数据和输入数据之间的误差足够小时, 则认为隐层的特征输出为原始数据的特征表达。

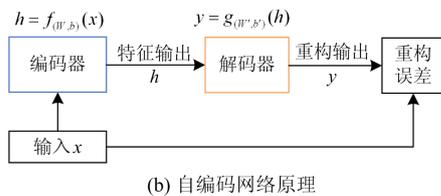
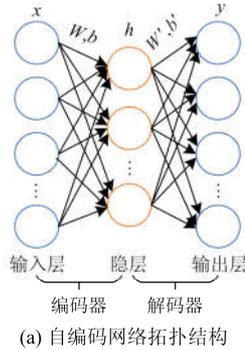


图 4 自编码网络的结构

Fig. 4 Structure of AE

图 4(b)为自编码网络的原理图, 从输入 x 经过编码器得到特征输出 h 的过程 f 称为编码(encoding), $h=f_{(W,b)}(x)=s_f(WX+b)$, 其中 W 为连接输入层和隐层的权值矩阵, b 为输入层和隐层之间的偏置矩阵, s_f 为编码器的神经元激活函数。特征输出 h 经过解码器得到重构输出 y 的过程 g 称为解码(decoding), $y=g_{(W',b')}(h)=s_g(W'h+b')$, 其中, W' 为连接隐层和输出层的权值矩阵, b' 为隐层和输出

层的偏置矩阵, s_g 为解码器的神经元激活函数。

自编码网络通过寻求最优参数 $\{W, W', b, b'\}$ 令重构输出 y 尽可能接近原始信号 x 。输入与输出的接近程度通过重构误差来表示。根据数据的不同形式, 重构误差有两种定义方式, 分别为均方差(mean square error)和交叉熵(cross-entropy):

$$L_{mse}(x, y) = \frac{1}{m} \sum_{i=1}^m \frac{1}{2} \|x - y\|^2 \quad (3)$$

$$L_{ce}(x, y) = \frac{1}{m} \sum_{i=1}^m (y \log(x) + (1 - y) \log(1 - x))$$

由于交叉熵函数的导数更陡, 因此也能够更快地收敛, 但交叉熵只适用于值域在 $[0, 1]$ 之间的场合。鉴于交叉熵的这个特性, 当网络输出层使用非线性激励函数时使用均方差, 当网络输出层使用线性激励函数时则使用交叉熵。

自编码网络的代价函数一般可以写为

$$J(W, b) = L(x, g(f(x))) + \lambda \cdot \Omega_{weight} = L(x, y) + \frac{\lambda}{2} \sum_{l=1}^{n_l-1} \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (W_{ij}^{(l)})^2 \quad (4)$$

式中: $L(x, y)$ 为重构误差; $\lambda \Omega$ 为防止过度拟合的权重衰减项^[36]; m 、 n_l 、 s_l 分别表示样本数、网络层数和 l 层神经元个数; W_{ij} 表示层间连接权重; b 为 l 层的单元偏置。

1.2.2 稀疏自编码网络

稀疏自编码网络(Sparse AE)利用了稀疏编码原理, 如图 5 所示, 在自编码网络模型基础上引入稀疏惩罚项, 即令隐层满足稀疏性, 使得自编码网络能够在稀疏性限制下学习到相对稀疏简明的特征表达^[37-43]。其中, 稀疏性的定义为: 对于隐层中的神经元, 定义其值接近 1 时为激活状态(activated), 接近 0(对应 sigmoid 激励函数)或 -1(对应 tanh 激励函数)时为抑制状态(not activated); 限制神经元在大多数状态下处于抑制状态, 少数状态下处于激活, 称之为稀疏性限制。

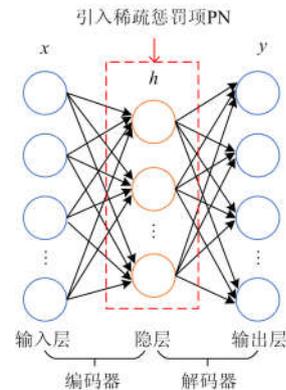


图 5 稀疏自编码网络的结构

Fig. 5 Structure of sparse AE

通常情况下, KL 散度被选做稀疏惩罚项 PN , 如式(5)所示。

$$PN = \sum_{j=1}^S KL(\rho \parallel \hat{\rho}_j) = \sum_{j=1}^S \rho \ln \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \ln \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (5)$$

式中: S 为隐层的单元数; ρ 为一个接近 0 的稀疏常数; $\hat{\rho}_j$ 为第 j 个单元的平均激活量。当 $\hat{\rho}_j = \rho$ 时,

KL 散度值为 0, 且 KL 散度值随着 $\hat{\rho}_j$ 偏离 ρ 而逐渐增大。则参照式(4), 包含稀疏惩罚项的自编码网络代价函数可写为

$$J_{\text{sparse}} = J(W, b) + \beta \cdot PN \quad (6)$$

式中, β 为稀疏惩罚项系数。

1.2.3 降噪自编码网络

降噪自编码网络(Denoising AE, DAE)由 Pascal Vincent 等人^[44]提出, 将含有一定统计特性的噪声随机加入原始样本信号, 对其进行编码与解码后, 最终映射还原出一个未受噪声影响的样本信号。降噪自编码网络的原理类似于人体的感官系统, 例如当人眼看物体时, 如果某一小部分被遮住了, 人依然可以辨识出该物体。同理, 降噪自编码网络通过添加噪声进行编解码重构, 可有效减少机械工况变化或环境噪声等随机因素对信号提取的影响。相比较原始自编码网络而言, 降噪自编码网络具有更强的泛化能力和特征表达能力, 其鲁棒性有明显提升^[44-48]。

降噪自编码网络的结构如图 6, 通过随机映射 $x' \sim q_D(x'|x)$ ^[44] 对原始信号 x 进行干扰来模拟噪声, 得到受噪声影响的信号 x' 。通过编码器对 x' 进行编码得到特征输出 $y = f_{(W,b)}(x') = s_f(Wx' + b)$, 其中 W 为连接输入层和隐层的权值矩阵, b 为输入层和隐层之间的偏置矩阵, s_f 为编码器的神经元激活

函数。再通过解码器对特征表达 y 解码后, 获得重构无污染的信号 $z = g_{(W',b')}(y) = sg(W'y + b')$, 其中 W' 为连接隐层和输出层的权值矩阵, b' 为隐层和输出层的偏置矩阵, sg 为解码器的神经元激活函数。通过寻求最优参数 $\{W, W', b, b'\}$ 令重构输出 z 尽可能接近原始信号 x 。与原始自编码网络相比, 降噪自编码网络的重构误差仍然表示输入与输出的接近程度, 但降噪自编码网络的特征输出 y 由受噪声影响的信号 x' 映射得到而非原始信号 x , 这迫使降噪自编码网络去学习更加智能的映射: 一种有利于去噪的特征提取方法。

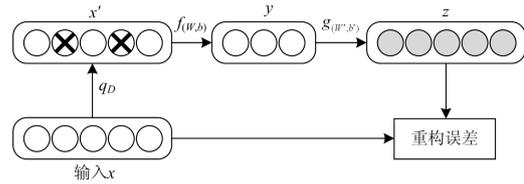


图 6 降噪自编码网络的结构

Fig. 6 Structure of denoising AE

1.2.4 栈式自编码网络

栈式自编码网络(Stacked AE)的基本单元是自编码网络(AE), 也可以是由 AE 演变而来的稀疏自编码网络, 降噪自编码网络等。栈式自编码网络利用了 Hinton 等人^[10]提出的贪婪逐层训练法, 解决了传统神经网络训练算法容易陷入局部极值的问题。如图 7(a)所示, 栈式自编码网络由多个自编码网络堆叠而成, 能够逐层地学习原始数据的特征, 其中每一层的输入都以前一层的特征输出为基础, 且每一层的特征表达都比前一层更抽象。对于分类任务, 往往会在栈式自编码网络的顶层加一层分类层。与原始自编码网络相比, 栈式自编码器更加适合复杂的分类等任务。

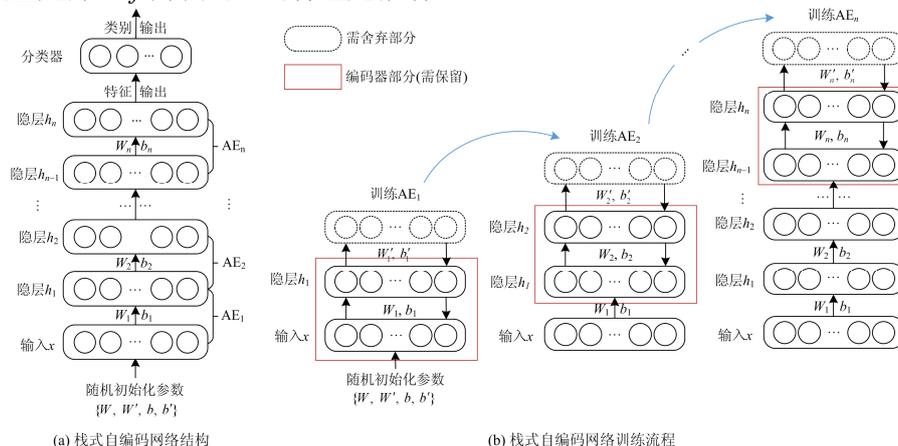


图 7 栈式自编码网络的结构及训练流程

Fig. 7 Structure and training process of stacked AE

栈式自编码网络的训练过程与 DBN 类似, 分为正向训练和反向微调两个阶段。图 7(b)为栈式自编码网络的正向训练流程图。首先训练 AE_1 , 随机初始化 AE_1 的初始权值和偏置 $\{W, b, W', b'\}$, 根据式(4), 计算输入与输出的重构误差, 并利用反向传播算法不断将 AE_1 中的参数进行更新, 直到重构误差最小, 此时 AE_1 训练完毕, 只保留 AE_1 的编码器部分, 再将 AE_1 的特征输出作为 AE_2 的输入对 AE_2 进行训练, 以此类推, 依次训练 n 个 AE, 当所有 AE 完成训练时, AE_n 的隐层输出即为最终的特征输出。栈式自编码网络的反向微调阶段可以调整整个网络的参数(此类情况与 DBN 相同, 且适合训练数据量较大的情况), 还可以只调整分类器的参数(此时将栈式自编码网络看作一个特征提取器)。

1.3 卷积神经网络

卷积神经网络(Convolutional Neural Networks, CNN)是一种典型的深度学习模型。CNN 具有局部感知、共享权重、空间上或时间上的降采样等特点^[56-60], 减少参数的同时充分利用了数据本身包含的局部性特征。

CNN 包括输入层、多个隐层、全连接层和输出层, 隐层主要由卷积层和子采样层组成, 输入可以是图像或是向量形式的的数据。卷积层主要用来提取特征, 传统的 CNN 通常选用 sigmoid 函数作为卷积层的激活函数。一个卷积层含有若干个卷积核, 每个卷积核可以看作是一个滤波器, 每个滤波器根据扫描步长扫描输入的图像或数据(每一个滤波器每一次扫描图像或数据的局部), 且一个滤波器在每次扫描时使用相同的权值和偏置(不同的滤波器使用不同的权值和偏置)。经过卷积后的向量大小为 $(n-k+m)/m$, 其中, n 为输入向量的大小, k 为卷积核的大小, m 为扫描的步长。卷积核的大小、个数

及扫描的步长需要根据人为经验调节。卷积层的数学模型为

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} \times K_{ij}^l + b_j^l\right) \quad (7)$$

式中: M_j 为输入特征; l 表示第 l 层网络; K 表示卷积核; b 为偏置; x_j^l 为第 l 层输出; x_i^{l-1} 为第 $l-1$ 层输入, 也是第 l 层的输入。

子采样层主要用来特征降维, 亦称池化(pooling)。子采样过程可以看作是将卷积得到的特征划分为多个不相交的区域, 并取该区域数据的最大值(最大池化法)或平均值(均值池化法)作为采样后的特征。子采样的尺寸代表特征稀疏的程度, 尺寸越大, 稀疏化效果越强, 所得特征的鲁棒性越好。子采样层的数学模型为

$$x_j^l = f(\beta_j^l \text{down}(x_i^{l-1}) + b_j^l) \quad (8)$$

式中: $\text{down}(\cdot)$ 为子采样函数; β 为网络乘性偏置。CNN 是一种有监督的深度学习模型, 其训练方法与人工神经网络的训练方法相似, 通常采用反向传播算法逐层反向传递误差, 并利用梯度下降法调整网络中的参数。

为了方便理解, 以时间序列信号分析为例, 如图 8。输入为 32×1 的信号, 输出为分类结果。C1 为卷积层, 选择 6 个 5×1 的卷积核, 步长为 1, 可以得到 6 组 28×1 的特征, 其中 $28 = (32 - 5 + 1) / 1$, 并且 C1 中的神经元只与前一层的部分神经元相连接。S1 为子采样层, 以最大池化法为例, 选择子采样尺寸为 7×1 , 对 C1 中的 6 组特征进行分块, 每一块的尺寸为 4×1 , 并取每一块的最大值, 可以得到 6 组 7×1 的特征, 进行多次卷积和池化后, 在全连接层对所得的特征进行处理并在输出层得到类别输出, 其中, 全连接层采用普通的一层或多层神经网络^[56], 且一层中的每个神经元与其前一层的所有神经元都连接。

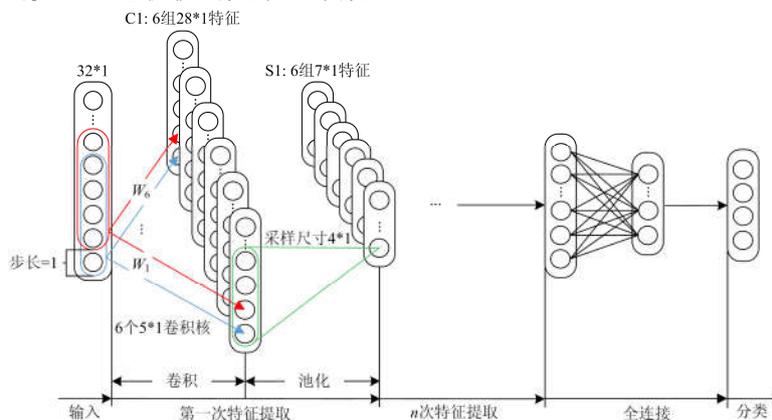


图 8 卷积神经网络的结构

Fig. 8 Structure of CNN

1.4 循环神经网络

DBN、AE 和 CNN 都假设：元素之间是相互独立的，输入与输出也是独立的。然而，很多元素都是相互联系的。循环神经网络(Recurrent Neural Network, RNN)通过连接同一层内的单元，形成一个有向循环的神经网络，RNN 的输出就依赖于当前的输入和记忆^[73]。为适应多种动态性能的要求，人们已经提出了几十种 RNN 结构^[74]。本小节主要介绍最经典的两种 RNN 模型：Jordan 网络^[74-78]和 Elman 网络^[74-76,78-81]。

图 9 为 RNN 的简单结构示意图，从图中可以看出，隐层单元不仅接收当前时刻的数据输入，还接收上一时刻的隐层输出。因此，网络可以记住以前的信息。网络的数学模型由式(9)给出。

$$\begin{cases} S_t = f(WS_{t-1} + Ux_t) \\ y_t = g(VS) \end{cases} \quad (9)$$

式中： x_{t-1} 、 x_t 和 x_{t+1} 分别对应 $t-1$ 、 t 和 $t+1$ 时刻的输入； S_{t-1} 、 S_t 和 S_{t+1} 分别对应 $t-1$ 、 t 和 $t+1$ 时刻的隐层状态； y_{t-1} 、 y_t 和 y_{t+1} 分别对应 $t-1$ 、 t 和 $t+1$ 时刻的输出； f 和 g 为激活函数； U 、 W 和 V 分别对应输入层到隐层的权值、隐层到隐层的权值和隐层到输出层的权值。

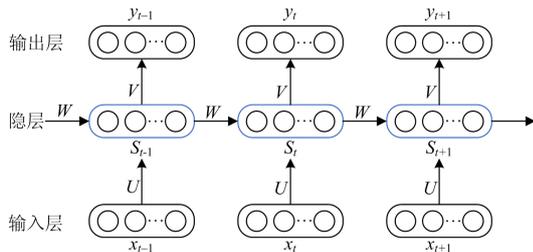


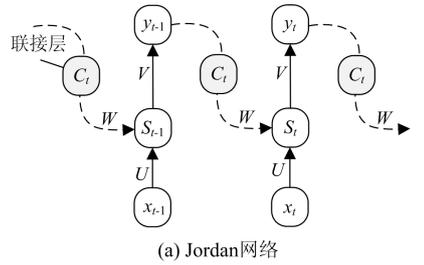
图 9 循环神经网络的结构

Fig. 9 Structure of RNN

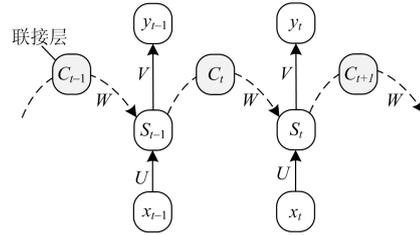
如图 10 所示为最早被提出也是最经典的两种 RNN 结构：a. Jordan 网络，b. Elman 网络。从图 10(a)中可以看出，Jordan 网络在基础 RNN 上添加了联接层，将反馈得到的上一时刻的输出和当前时刻的网络输入作为当前时刻的隐层输入，相当于输出反馈。Jordan 网络的数学模型为

$$\begin{cases} S_t = f(W \cdot C_t + U \cdot x_t) \\ C_t = y_{t-1} + \alpha C_{t-1} \\ y_t = g(V \cdot S_t) \end{cases} \quad (10)$$

式中： x_t 为 t 时刻的输入； S_t 为 t 时刻的隐层状态， y_{t-1} 为 $t-1$ 时刻的输出； C_{t-1} 和 C_t 分别为 $t-1$ 和 t 时刻的联接层输出； α 为反馈增益因子； f 和 g 为激活函数； U 、 W 、 V 分别对应输入层到隐层的权值、联接层到隐层的权值、隐层到输出层的权值。



(a) Jordan 网络



(b) Elman 网络

图 10 Jordan 网络和 Elman 网络的结构

Fig. 10 Structure of Jordan and Elman

从图10(b)中可以看出，Elman 网络通过联接层，将上一时刻的隐层状态和当前时刻的网络输入作为当前时刻的隐层输入，相当于状态反馈。Elman 网络的数学模型为

$$\begin{cases} S_t = f(W \cdot C_t + U \cdot x_t) \\ C_t = S_{t-1} + \alpha C_{t-1} \\ y_t = g(V \cdot S_t) \end{cases} \quad (11)$$

Jordan 网络只能表达反映到输出的特性，而 Elman 网络中则存在状态反馈，相比较而言，Elman 网络具有更好的动态系统表达能力^[73,75]。

2 深度学习在电机故障诊断中的应用

常见的电机故障有轴承故障、定子故障、转子故障和气隙偏心故障^[97-98]，其中轴承故障的发生概率最高，并且滚动轴承易引发齿轮箱故障。

在传统的故障诊断中，往往采用信号处理方法结合分类算法(如支持向量机、决策树、K 近邻等)的方法来进行故障的分类识别。其中，信号处理方法则根据不同故障类型应用不同的方法。例如，当电机轴承发生故障时，常常采用振动信号或定子电流信号，并利用时频域分析法、统计分析法、小波分解法等方法来提取信号中的特征；当电机转子发生故障时，最常用的为定子电流检测法，因为定子电流信号易于采集，通过傅里叶变换或 Hilbert 变换等方法来提取定子电流信号中的特征；当电机定子发生故障时，通常采用建立电机故障的数学模型或采用电流电压信号检测方法来诊断故障，采用信号检测法时，仍需要进行特征提取计算；当电机发生气

隙偏心故障时, 往往也采用电流信号分析法来诊断故障。

由此可以看出, 常用的传统电机故障诊断方法中, 不可避免地需要进行人为的特征选择和提取, 这往往会增加电机故障诊断的不确定性, 影响电机故障诊断的准确率。而深度学习模型可以自适应提取源信号中的特征, 从而避免了人为特征提取带来的影响。

2.1 深度置信网络在电机故障诊断中的应用

自 DBN 于 2006 年被首次提出后, 最初应用于机器视觉领域。2013 年, DBN 首次应用在故障诊断领域中, Tamilselvan 等人^[18]提出了基于 DBN 的飞机发动机故障诊断方法, 虽然该方法将 DBN 作为分类器实现了故障分类, 没有实现基于 DBN 的特征提取, 但是为实现基于 DBN 的故障诊断方法做出了贡献。2014 年, Tran 等人^[19]将 DBN 应用于压缩机的故障诊断, 推动了 DBN 在故障诊断领域中的发展。Xie 等人^[23]提出了一种基于 Nesterov 动量优化的 DBN 模型, 从旋转机械中提取频域信号, 输入到模型中进行特征学习和分类, 实现了对轴承的故障类别和故障程度的同时识别, 作者同时还使用了传统 DBN 模型和支持向量机对相同信号进行分类, 且利用实验证明了三种方法的分类准确率由高到低为优化后的 DBN 模型 > 传统 DBN 模型 > 支持向量机。李梦诗等人^[27]提出了一种基于 DBN 的风力发电机故障诊断方法, 该方法通过 DBN 网络构建了故障诊断模型, 在仿真过程中采用高斯噪声来模拟风力发电机实际运行环境中的噪声。其中, 故障类型有包括传感器故障, 执行器故障和系统故障在内的 9 类。同时, 针对这 9 类故障, 作者将 DBN 模型与贝叶斯分类法、随机森林分类法、K 近邻算法和决策树这四种传统诊断方法进行了对比, 并用实验证明了基于 DBN 的诊断方法具有更好的鲁棒性和稳定性。

发展至今短短几年, DBN 在电机故障诊断领域中的应用范围越来越广, 包括滚动轴承^[23-26]、风力发电机组^[27-28]、传感器^[9,29]、齿轮箱^[30-32]等, 并且实现了基于 DBN 的特征提取。

总结现有的基于 DBN 的电机故障诊断方法, 其故障诊断框架如图 11 所示, 主要包括以下步骤:

步骤 1 利用传感器以及信号预处理方法获得设备在正常以及故障状态下的时/频域信号;

步骤 2 对信号进行分段并归一化, 并分为训练集和测试集;

步骤 3 建立多隐层 DBN 模型, 并使用训练集进行无监督贪婪逐层训练;

步骤 4 引入类别信息对 DBN 模型中的参数进行微调;

步骤 5 利用训练好的 DBN 模型对测试集进行故障诊断。

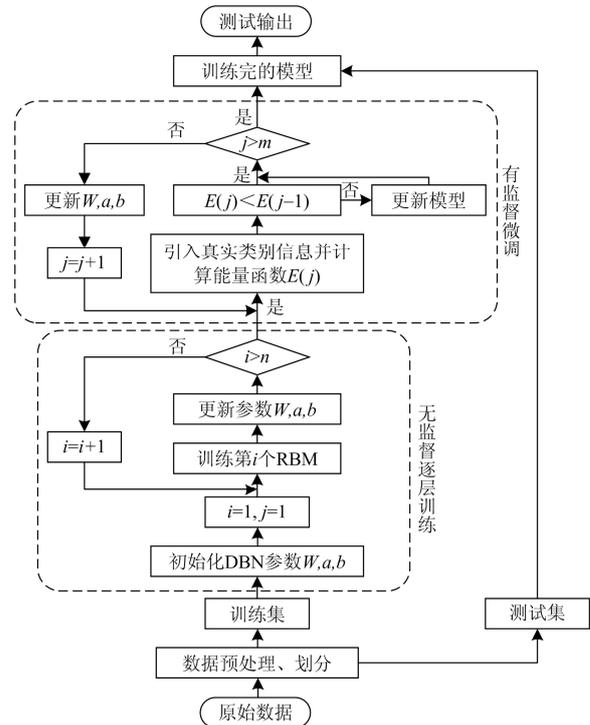


图 11 基于深度置信网络的故障诊断框架

Fig. 11 Fault diagnosis framework of DBN

2.2 自编码网络在电机故障诊断中的应用

原始自编码网络以及其演变而来的稀疏自编码网络和降噪自编码网络都是浅层网络, 在实际应用中往往堆叠成深层的栈式自编码网络, 栈式自编码网络因其强大的学习数据特征的能力而被许多专家学者关注。文献[43]利用深度稀疏自编码网络诊断永磁同步电机的匝间短路故障, 由负序电流和转矩信号构成样本, 利用生成对抗网络(GAN)对样本进行扩张并建立训练集, 用训练样本训练构建好的稀疏自编码网络并用于测试分类, 实验证明其分类准确率高达 99.4%。文献[47]通过振动分析来诊断风力发电机齿轮箱的故障, 并针对振动信号含大量噪声且大多数降噪自编码网络使用单一噪声来训练网络的问题, 提出了基于多层去噪自编码网络(SMLDAEs)的风力机变速箱故障诊断方法, 该方法使用多个噪声级来训练网络, 从而能够在振动信号中学习得更详细、更通用的故障特征, 经过实验验证, 该方法的分类准确率稳定在 97.5%~98%这个范围。文献[40]利用深度自编码网络实现了对滚动轴承的故障诊断, 他们通过将稀疏自编码网络和降噪自编码网络

结合来提高去噪能力，降低计算复杂度以及训练收敛速度，相比较单一的稀疏自编码网络或降噪自编码网络，该方法具有更好的鲁棒性，能够更有效地提高滚动轴承故障诊断的准确率。文献[42]提出了一种基于栈式自编码网络的滚动轴承和行星齿轮箱的故障诊断方法，该文献利用栈式自编码网络对轴承和齿轮箱在不同负载下的 10 类故障进行分类，其分类准确率高达 99.68%，并与浅层神经网络故障诊断方法比较，证明了该方法具有较高的诊断精度。发展至今，栈式自编码网络的研究已经扩展到旋转机械^[40,46]、风力发电机组^[47,49]、滚动轴承^[41,50-51]、齿轮^[52-53]、航空设备^[54-55]等领域，均取得了良好的效果。另外，文献[33]阐述了自编码网络的发展历程，详细介绍了十余种自编码网络的原理并做了对比分析。

总结现有的基于深度自编码网络的电机故障诊断方法，诊断框架如图 12 所示，主要包括以下步骤：

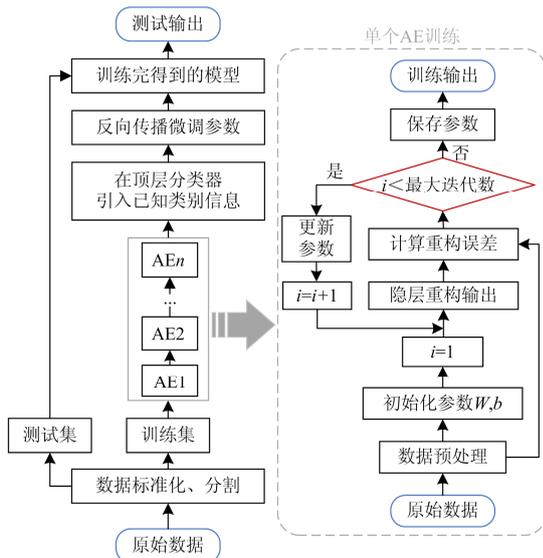


图 12 基于栈式自编码网络的故障诊断框架

Fig. 12 Fault diagnosis framework of stacked AE

步骤 1 利用传感器获得设备在正常以及故障状态下的信号；

步骤 2 对信号进行预处理，并分为训练集和测试集；

步骤 3 根据数据选择重构误差，建立深层自编码网络模型，并使用训练集进行无监督贪婪逐层训练；

步骤 4 在顶层加入分类算法，根据需求调整整个深度自编码网络的参数或只调整分类器中的参数；

步骤 5 利用训练好的深度自编码网络模型对测试集进行故障诊断。

从利用自编码网络或深度自编码网络来实现故

障诊断的方法来看，自编码网络主要用于降噪和特征提取，相比较 DBN 而言，自编码网络训练所需的样本更少，特征提取能力更强，鲁棒性也更好。

2.3 卷积神经网络在电机故障诊断中的应用

CNN 具有局部感知和权值共享等特点，极大地减少了网络参数的数量，能够在一定程度上避免网络产生过拟合。因此，其受到了许多学者的关注和研究。由于在传统 CNN 中，激励函数一般为饱和非线性函数例如 sigmoid 函数，tanh 函数，文献[61-62]提出并验证了非饱和非线性函数(ReLU 函数)能够提升 CNN 网络的性能。文献[63]提出了一种基于 CNN 的齿轮箱振动信号故障诊断方法，但是方法仍然需要手工提取特征来形成输入，针对这个问题，文献[64]提出了可以自适应学习特征的基于 CNN 的齿轮箱振动信号故障诊断方法。针对齿轮箱振动信号固有的多尺度特征的问题，文献[67]提出了一种新的多尺度卷积神经网络(MSCNN)体系结构，用于同时进行多尺度特征提取和分类，该方法利用多对卷积层和子采样层的分层学习结构提高了特征提取的效率，提高了诊断性能。文献[68]提出了一种基于电机振动信号特征的诊断框架(DTS-CNN)，该方法并非直接将提取到的原始振动信号作为 CNN 的输入，而是通过在 CNN 的卷积层前添加错位层，实现了提取周期性机械信号中不同间隔的信号之间的关系，克服了传统神经网络的缺点，更适用于现代电机，尤其是在非平稳条件下。文献[69]提出了一维 CNN 的实时电机故障诊断方法，该方法在训练阶段利用大量的一维滤波核来提取高分辨特征，并结合分类算法，实现了对电机实时电流信号的特征提取和分类，取得了高于 97%的故障诊断准确率。文献[70]则针对传统故障诊断方法在复合故障诊断方面的局限性(例如缺少对单一故障和复合故障之间的联系考虑，传统的分类器对复合故障的检测样本只能输出一个标签等)，提出了一种基于深度解耦 CNN 的智能复合故障诊断方法，并利用边缘损失函数对模型进行训练和优化，使得深度 CNN 能够从原始的振动信号中学习更多有效特征，克服了传统故障诊断方法的局限性，实现了对复合故障的准确识别和解耦。综合现在的文献来看，CNN 应用于电机故障诊断领域的方法大致可以分为两类，一类是将 CNN 作为分类器^[63,65-66]，此时需要对数据进行预处理以及特征提取；另一类是将 CNN 作为特征提取以及识别分类模型^[64,67-72]，在实现自适应特征学习的同时进行分类。

基于 CNN 的电机故障诊断框架如图 13 所示，主要步骤总结如下：

步骤 1 利用传感器获得设备在正常以及故障状态下的时域或频域信号;

步骤 2 对信号进行预处理并分为训练集和测试集;

步骤 3 根据所得数据确定 CNN 的卷积核大小、个数、扫描步长以及隐层数, 并建立 CNN 模型;

步骤 4 初始化 CNN 网络参数后, 使用训练集进行有监督训练, 不断更新网络参数直到达到最大迭代数;

步骤 5 利用训练好的 CNN 模型对测试集进行故障诊断。

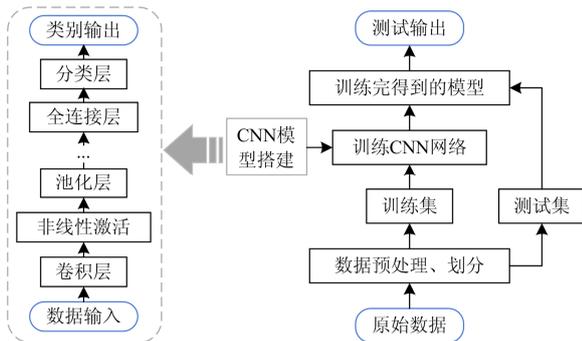


图 13 基于卷积神经网络的故障诊断框架

Fig. 13 Fault diagnosis framework of CNN

CNN 是一种非常适用于处理海量数据的深度学习模型, 但在电机故障诊断方面存在局限性, CNN 往往只能处理一维信号数据, 对于多维数据的处理能力较弱, 利用 CNN 处理多维数据的文献也非常少, 因此, 其适合处理何种故障也有待进一步探讨^[73]。

2.4 循环神经网络在电机故障诊断中的应用

RNN 是一种擅长处理时间序列的网络模型, 具有收敛速度快、精度高、稳定性好等特点^[82]。在故障诊断方面, RNN 非常适用于复杂设备或系统的故障诊断^[83-86]。

文献[87]指出传统 RNN 存在梯度消失或者梯度爆炸的问题, 这会导致其无法利用过去长时间的信息, 故提出了长短时记忆神经网络(LSTM)来解决这个问题。LSTM 因解决了梯度问题以及其在处理与时间序列相关度较高的数据方面的优势而被广泛应用于故障诊断领域^[88-92]。文献[89]提出了一种基于 LSTM 的电机故障检测方法, 通过捕捉前一采样瞬间的三相电流值和电角度信息, 实时预测下一采样瞬间的三相电流值, 以此来实时观察电机的运行状态。仿真结果表明了该方法的有效性。文献[90]利用小波包变换提取风电机组滚动轴承振动信号的特征向量, 将 LSTM 作为分类器, 从而诊断出风电

机组滚动轴承的 3 种常见故障, 该文献通过案例研究验证了该方法的有效性, 并证明了在故障特征量差异不明显的环境下, LSTM 仍具有良好的故障诊断性能。文献[91]结合经验模态分解和 LSTM, 实现了对旋转机械的状态监控和预测, 并与支持向量回归机(SVRM)进行比较, 验证了 LSTM 能够有效避免参数选择难题并且具有更高的准确率。文献[90-91]都是将 LSTM 网络作为分类器, 需要结合其他特征提取方法, 而文献[92]则实现了 LSTM 的自适应特征提取和分类, 不再需要结合其他特征提取方法或分类器。如图 14 所示为一种基于 LSTM 的故障诊断框架。

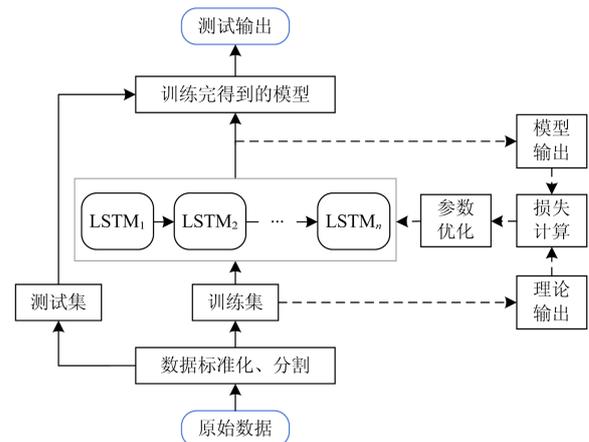


图 14 基于 LSTM 的故障诊断框架

Fig. 14 Fault diagnosis framework of LSTM

传统 RNN 还存在训练速度慢的问题^[93], 针对这个问题, 文献[94]提出了一种将 RNN 与动态贝叶斯网络相结合的异步电机故障检测方法, 同时利用同步扰动随机逼近法(SPSA)对神经网络进行训练, 提高了训练效率以及故障诊断的准确率。文献[95]则提出了一种具有鲁棒性的 RNN 自适应梯度下降(RAGD)训练算法, 大大提高了 RNN 的训练速度。基于 RNN 的改进模型还有很多, 文献[83]提出了一种用对角 RNN 来诊断异步电动机定子绕组匝间故障的方法, 文献[84]利用带偏差单元的 RNN 实现了基于整流器畸变电压波形的故障分类, 并且实验证明了该方法对于诊断复杂电力电子设备或系统的有效性, 文献[96]将基于 RNN 改进的回声状态网络应用于机电系统。

3 总结与展望

深度学习模型因具有传统故障诊断方法缺乏的优点, 而引起广大学者的关注。与传统特征提取方式相比, 深度学习模型最突出的优点是无需人为特

征提取,避免了人为干预所带来的不确定性和复杂性^[19],增强了识别过程的智能性,传统故障诊断方法和深度学习模型分析过程比较如图 15 所示。

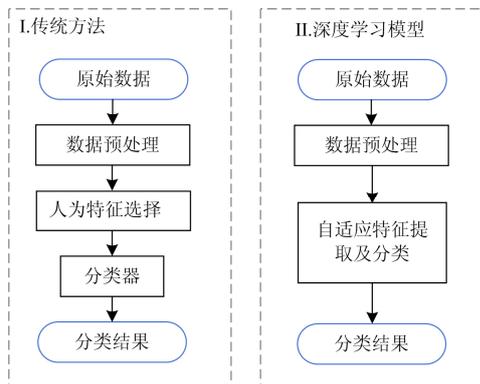


图 15 传统故障诊断方法和深度学习分析过程

Fig. 15 Fault diagnosis framework of LSTM

除此之外,本文所概述的四类深度学习模型分别具有其独特的优势,总结如下:

1) DBN 无需精确数学模型即可自适应学习数据特征^[27],DBN 的多隐层结构可以有效避免维数灾难的问题,DBN 的半监督训练方式有效地解决了传统神经网络训练方法不适用于多层网络的问题;

2) 稀疏 AE 有利于减小计算复杂度,获得更简明的特征,DAE 可有效减少机械工况变化或环境噪声等随机因素对信号提取的影响,栈式 AE 具有更好的鲁棒性;

3) CNN 具有强大的海量数据处理能力^[99],还具有局部感知、共享权重、空间上或时间上的降采样等特点,减少了网络参数,同时还可以避免网络过拟合;

4) RNN 有很好的动态系统表达能力,在时间序列学习分析中具有很强的适用性和更高的准确性^[100]。

这些优点都是传统故障诊断方法无法比拟的。但是,这四类深度学习模型仍存在一些缺点,总结如下:

1) DBN 的训练方式为半监督训练,需要逐个训练 RBM 并逐层调节参数,因此训练速度会远慢于传统故障诊断方法,并且不适合的参数选择会导致训练收敛于局部最优。

2) 普通 AE 的输出和输入完全相同,这使得 AE 在映射过程中易出现数据过拟合的问题。若 AE 的隐层维数小于输入数据维数,在一定程度上可以防止过拟合,但是这使得 AE 能够表达的特征有限,从而导致重构困难。深层的 AE 能够表达更多有效的特征,但这使得 AE 的训练速度大大减慢。

3) CNN 的实现相对比较复杂,并且 CNN 的训练需要大量的数据,这也导致了 CNN 的训练速度非常慢。CNN 处理 2 维数据的优势使得它通常被用于图像处理,由于图像与工业信号的差异,CNN 在工业应用中的效果并不十分理想,因此,CNN 在电机故障诊断中的应用研究也相对较少。

4) 普通 RNN 存在梯度消失或梯度爆炸的问题,LSTM 能够在一定程度上解决这个问题,但 LSTM 往往作为分类器使用,少有文章利用 LSTM 实现特征的自适应提取。

另外,深度学习在电机故障诊断中的应用仍处于初步发展阶段,本文提到的四种模型以及现有的其他深度学习模型仍然存在一些有待解决的问题:

1) 很多传统机器学习方法的性能在一定条件下有严格的理论保障,而对于深度学习,现存的数学理论尚不能很好地给出定量解释和理论支持^[101]。

2) 虽然深度学习模型的深层网络结构以及强大的特征学习能力令其能够满足“大数据”背景下的故障诊断,但是深度学习模型的训练速度远远慢于线性模型,并且与训练数据集息息相关,而关于优化深度学习训练速度的报道却很少见。

3) 综合现有的文献可以看到,深度学习模型中的隐层层数和部分参数需要根据经验设定,且容易受输入数据的影响,这也是目前亟待解决的问题。

4) 深度学习方法和传统故障诊断方法没有绝对的优劣之分。现如今,已有一些学者尝试结合深度学习方法和传统故障诊断方法来获得更好的诊断效果,但目前还远远没有达到“相互兼容”的程度^[73]。

本文概述了目前较为公认且应用广泛的四类深度学习模型,并讨论了深度学习在电机故障诊断领域中的研究现状,总结了目前深度学习模型体现的优点和不足之处。希望本文可以给读者提供思路,同时,作者也相信未来理论研究的进步将会进一步加快深度学习的发展,并为深度学习理论的改进和应用做出更好的指引。

参考文献

- [1] NAYANA B R, GEETHANJALI P. Analysis of statistical time-domain features effectiveness in identification of bearing faults from vibration signal[J]. IEEE Sensors Journal, 2017, 17(17): 5618-5625.
- [2] DHAMANDE L S, CHAUDHARI M B. Bearing fault diagnosis based on statistical feature extraction in time and frequency domain and neural network[J]. International Journal of Vehicle Structures and Systems, 2016, 8(4): 229-240.

- [3] JIANG W L, ZHU Y, WANG Z W, et al. Fault diagnosis method based on precise frequency domain integral and vibration severity[J]. ICIC Express Letters, Part B: Applications, 2016, 7(11): 2301-2307.
- [4] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49-56.
LEI Yaguo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data[J]. Journal of Mechanical Engineering, 2015, 51(21): 49-56.
- [5] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-16.
LI Han, XIAO Deyun. Survey on data driven fault diagnosis methods[J]. Control and Decision, 2011, 26(1): 1-16.
- [6] 陶雪娇, 胡晓峰, 刘洋. 大数据研究综述[J]. 系统仿真学报, 2013, 25(增刊 1): 142-146.
TAO Xuejiao, HU Xiaofeng, LIU Yang. Overview of big data research[J]. Journal of System Simulation, 2013, 25(S1): 142-146.
- [7] 李红卫, 杨东升, 孙一兰, 等. 智能故障诊断技术研究综述与展望[J]. 计算机工程与设计, 2013, 34(2): 632-637.
LI Hongwei, YANG Dongsheng, SUN Yilan, et al. Study review and prospect of intelligent fault diagnosis technique[J]. Computer Engineering and Design, 2013, 34(2): 632-637.
- [8] 毛健, 赵红东, 姚婧婧. 人工神经网络的发展及应用[J]. 电子设计工程, 2011, 19(24): 62-65.
MAO Jian, ZHAO Hongdong, YAO Jingjing. Application and prospect of artificial neural network[J]. Electronic Design Engineering, 2011, 19(24): 62-65.
- [9] 郑晓飞, 郭创, 姚斌, 等. 基于深度学习的航空传感器故障诊断方法[J]. 计算机工程, 2017, 43(7): 281-287.
ZHENG Xiaofei, GUO Chuang, YAO Bin, et al. Fault diagnosis method for aerial sensor based on deep learning[J]. Computer Engineering, 2017, 43(7): 281-287.
- [10] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [11] BENGIO Y, LAMBLIN P, POPOVICI D, et al. Greedy layer-wise training of deep networks[J]. Advances in Neural Information Processing Systems, 2007: 153-160.
- [12] BENGIO Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning, 2009, 2(1): 1-55.
- [13] 段艳杰, 吕宜生, 张杰, 等. 深度学习在控制领域的研究现状与展望[J]. 自动化学报, 2016, 12(5): 643-654.
DUAN Yanjie, LÜ Yisheng, ZHANG Jie, et al. Deep learning for control: the state of the art and prospects[J]. Acta Automatica Sinica, 2016, 12(5): 643-654.
- [14] 郭晓洁. 基于深度学习模型的机械传动系统故障诊断研究[D]. 苏州: 苏州大学, 2017.
GUO Xiaojie. Research on fault diagnosis of mechanical transmission system based on deep learning model[D]. Suzhou: Suzhou University, 2017.
- [15] TAIGMAN Y, YANG M, RANZATO M A, et al. Deepface: closing the gap to human-level performance in face verification[C] // Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA: 1701-1708.
- [16] ZHANG D X, HAN X Q, DENG C Y. Review on the research and practice of deep learning and reinforcement learning in smart grids[J]. CSEE Journal of Power and Energy Systems, 2018, 4(3): 362-370.
- [17] HU Z L, HE T, ZENG Y H, et al. Fast image recognition of transmission tower based on big data[J]. Protection and Control of Modern Power Systems, 2018, 3(3): 149-158. DOI: 10.1186/s41601-018-0088-y.
- [18] TAMILSELVAN P, WANG P. Failure diagnosis using deep belief learning based health state classification[J]. Reliability Engineering & System Safety, 2013, 115: 124-135.
- [19] TRAN V T, ALTHOBIANI F, BALL A. An approach to fault diagnosis of reciprocating compressor valves using Teager-Kaiser energy operator and deep belief net-works[J]. Expert Systems with Applications, 2014, 41(9): 4113-4122.
- [20] 朱乔木, 党杰, 陈金富, 等. 基于深度置信网络的电力系统暂态稳定评估方法[J]. 中国电机工程学报, 2018, 38(3): 735-744.
ZHU Qiaomu, DANG Jie, CHEN Jinfu, et al. A method for power system transient stability assessment based on deep belief networks[J]. Proceedings of the CSEE, 2018, 38(3): 735-744.
- [21] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2016, 18(7): 1527-1554.
- [22] AREL I, ROSE D, KARNOWSKI T. Deep machine learning-a new frontier in artificial intelligence research[J]. IEEE Computational Intelligence Magazine, 2010, 5(4): 13-18.
- [23] XIE J Q, DU G F, SHEN C Q, et al. An end-to-end model based on improved adaptive deep belief network and its application to bearing fault diagnosis[J]. IEEE Access, 2018, 6: 63584-63596.
- [24] CHEN Z Y, LI W H. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief

- network[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(7): 1693-1702.
- [25] SHAO H D, JIANG H K, ZHANG H Z, et al. Electric locomotive bearing fault diagnosis using a novel convolutional deep belief network[J]. IEEE Transactions on Industrial Electronics, 2018, 65(3): 2727-2736.
- [26] 李巍华, 单外平, 曾雪琼. 基于深度信念网络的轴承故障分类[J]. 振动工程学报, 2016, 29(2): 340-347.
LI Weihua, SHAN Waiping, ZENG Xueqiong. Bearing fault identification based on deep belief network[J]. Journal of Vibration Engineering, 2016, 29(2): 340-347.
- [27] 李梦诗, 余达, 陈子明, 等. 基于深度置信网络的风力发电机故障诊断方法[J]. 电机与控制学报, 2019, 23(2): 114-123.
LI Mengshi, YU Da, CHEN Ziming, et al. Fault diagnosis and isolation method for wind turbines based on deep belief network[J]. Electric Machines and Control, 2019, 23(2): 114-123.
- [28] 王春梅. 基于深度置信网络的风电机组主轴承故障诊断方法研究[J]. 自动化仪表, 2018, 39(5): 33-37.
WANG Chunmei. Research on the fault diagnosis method based on deep belief network for main bearing of wind turbine[J]. Process Automation Instrumentation, 2018, 39(5): 33-37.
- [29] MANDAL S, SANTHI B, SRIDHA S, et al. Nuclear power plant thermocouple sensor-Fault detection and classification using deep learning and generalized likelihood ratio test[J]. IEEE Transactions on Nuclear Science, 2017, 64(6): 1526-1534.
- [30] LI C, SANCHEZ R V, ZURITA G, et al. Gearbox fault diagnosis based on deep random forest fusion of acoustic and vibratory signals[J]. Mechanical Systems and Signal Processing, 2016, (S76-77): 283-293.
- [31] LI C, SANCHEZ R V, ZURITA G, et al. Multimodal deep support vector classification with homologous features and its application to gearbox fault diagnosis[J]. Neurocomputing, 2015, 168(C): 119-127.
- [32] QIN Y, WANG X, ZOU J Q. The optimized deep belief networks with improved logistic Sigmoid units and their application in fault diagnosis for planetary gearboxes of wind turbines[J]. IEEE Transactions on Industrial Electronics, 2019, 66(5): 3814-3824.
- [33] 袁非牛, 章琳, 史劲亭, 等. 自编码神经网络理论及应用综述[J]. 计算机学报, 2019, 42(1): 203-230.
YUAN Feiniu, ZHANG Lin, SHI Jinting, et al. Theories and applications of auto-encoder neural networks: a literature survey[J]. Chinese Journal of Computers, 2019, 42(1): 203-230.
- [34] BENGIO Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning, 2009, 2(1): 1-12.
- [35] ERHAN D, BENGIO Y, CORVILLE A, et al. Why does unsupervised pre-training help deep learning?[J]. Journal of Machine Learning Research, 2010, 11: 625-660.
- [36] LIU W F, ZHOU T Z, XIE Q S, et al. LMAE: a large margin auto-encoders for classification[J]. Signal Processing, 2017, 141: 137-143.
- [37] MICHELE R S, SMITH B, PHOHA S. Non-negative sparse autoencoder neural networks for the detection of overlapping, hierarchical communities in networked datasets[J]. Chaos, 2012, 22(4): 043141.
- [38] WEN L, GAO L, LI X Y. A new deep transfer learning based on sparse auto-encoder for fault diagnosis[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2019, 49(1): 136-144.
- [39] XU J, XIANG L, LIU Q S, et al. Stacked sparse autoencoder (SSAE) for nuclei detection on breast cancer histo-pathology images[J]. IEEE Transactions on Medical Imaging, 2016, 35(1): 119-130.
- [40] QI Y M, SHEN C Q, WANG D, et al. Stacked sparse autoencoder-based deep network for fault diagnosis of rotating machinery[J]. IEEE Access, 2017, 5: 5066-15079.
- [41] ZHANG J L, CHEN Z G, DU X L, et al. Application of stack marginalised sparse denoising auto-encoder in fault diagnosis of rolling bearing[J]. The Journal of Engineering, 2018(16): 1772-1777.
- [42] JIA F, LEI Y G, LIN J, et al. Deep neural networks: a promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. Mechanical Systems and Signal Processing, 2016, 72: 303-315.
- [43] 李垣江, 张周磊, 李梦含, 等. 采用深度学习的永磁同步电机匝间短路故障诊断方法[J/OL]. 电机与控制学报. <http://kns.cnki.net/kcms/detail/23.1408.TM.20181018.1422.004.html>.
LI Yuanjiang, ZHANG Zhoulei, LI Menghan, et al. Fault diagnosis of interturn short circuit of permanent magnet synchronous motor based on deep learning[J/OL]. Electric Machines and Control, 2018(10): 1-8[2018-10-22]. <http://kns.cnki.net/kcms/detail/23.1408.TM.20181018.1422.004.html>.
- [44] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders[C] // Proceedings of the 25th International Conference on Machine Learning, July 5-9, 2008, Helsinki, Finland: 1096-1103.
- [45] HUANG W, XIAO L, WEI Z H, et al. A new pan-sharpening method with deep neural networks[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(5): 1037-1041.

- [46] LU C, WANG Z Y, QIN W L, et al. Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification[J]. *Signal Processing*, 2017, 130(C): 377-388.
- [47] JIANG G Q, HE H B, XIE P, et al. Stacked multilevel denoising autoencoders: a new representation learning approach for wind turbine gearbox fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66(9): 2391-2402.
- [48] XIA M, LI T, LIU L Z, et al. Intelligent fault diagnosis approach with unsupervised feature learning by stacked denoising autoencoder[J]. *IET Science, Measurement & Technology*, 2017, 11(6): 687-695.
- [49] 赵洪山, 刘辉海, 刘宏杨, 等. 基于堆叠自编码网络的风电机组发电机状态监测与故障诊断[J]. *电力系统自动化*, 2018, 42(11): 102-108.
ZHAO Hongshan, LIU Huihai, LIU Hongyang, et al. Condition monitoring and fault diagnosis of wind turbine generator based on stacked autoencoder network[J]. *Automation of Electric Power Systems*, 2018, 42(11): 102-108.
- [50] ZHAO W L, LU C, MA J, et al. A deep learning method using SDA combined with dropout for bearing fault diagnosis[J]. *Vibroengineering Procedia*, 2015(5): 151-156.
- [51] SUN J D, YAN C H, WEN J T. Intelligent bearing fault diagnosis method combining compressed data acquisition and deep learning[J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67(1): 185-195.
- [52] LI C H, ZHANG W, PENG G L, et al. Bearing fault diagnosis using fully-connected winner-take-all autoencoder[J]. *IEEE Access*, 2017, 6: 2169-3536.
- [53] CHENG F Z, WANG J, QU L Y, et al. Rotor-current-based fault diagnosis for DFIG wind turbine drivetrain fearboxes using frequency analysis and a deep classifier[J]. *IEEE Transactions on Industry Applications*, 2018, 54(2): 1062-1071.
- [54] PANG S, YANG X Y, ZHANG X F. Aero engine component fault diagnosis using multi-hidden-layer extreme learning machine with optimized structure[J]. *International Journal of Aerospace Engineering*, 2016, 1329561.
- [55] 陈华坤, 章卫国, 史静平, 等. 航空电子设备故障预测特征参数提取方法研究[J]. *西北工业大学学报*, 2017, 35(3): 364-373.
CHEN Huakun, ZHANG Weiguo, SHI Jingping, et al. Research on feature extraction method for fault prediction of avionics[J]. *Journal of Northwestern Polytechnical University*, 2017, 35(3): 364-373.
- [56] PENG H K, MARCULESCU R. Multi-scale compositionality: identifying the compositional structures of social dynamics using deep learning[J]. *PLOS One*, 2015, 10(4): e0118309.
- [57] 张西宁, 向宙, 唐春华. 一种深度卷积自编码网络及其在滚动轴承故障诊断中的应用[J]. *西安交通大学学报*, 2018, 52(7): 1-9.
ZHANG Xining, XIANG Zhou, TANG Chunhua. A deep convolutional auto-encoding neural network and its application in bearing fault diagnosis[J]. *Journal of Xi'an Jiaotong University*, 2018, 52(7): 1-9.
- [58] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [59] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [60] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. *计算机学报*, 2017, 40(6): 1229-1251.
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network[J]. *Chinese Journal of Computers*, 2017, 40(6): 1229-1251.
- [61] JARRETT K, KAVUKCUOGLU K, MARC'AURELIO R, et al. What is the best multi-stage architecture for object recognition?[C] // *Proceedings of the 2009 IEEE 12th International Conference on Computer Vision*, 2009: 2146-2153.
- [62] NAIR V, HINTON G E, FARABET C. Rectified linear units improve restricted Boltzmann machines[C] // *Proceedings of 27th International Conference on Machine Learning*, June 21-24, 2010, Haifa, Israel: 807-814.
- [63] CHEN Z Q, LI C, SANCHEZ R V. Gearbox fault identification and classification with convolutional neural networks[J]. *Shock and Vibration*, 2015.
- [64] XIA M, LI T, XU L, et al. Fault diagnosis for rotating machinery using multiple sensors and convolutional neural networks[J]. *IEEE/ASME Transactions on Mechatronics*, 2018, 23(1): 101-110.
- [65] LIU G J, YIN Z Z, JIA Y J, et al. Passenger flow estimation based on convolutional neural network in public transportation system[J]. *Knowledge-Based Systems*, 2017: 1-14.
- [66] KAO I H, WANG W J, LAI Y H, et al. Analysis of permanent magnet synchronous motor fault diagnosis based on learning[J]. *IEEE Transactions on Instrumentation and Measurement*, 2019, 68(2): 310-324.
- [67] JIANG G Q, HE H B, YAN J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(4): 3196-3207.
- [68] LIU R N, MENG G T, YNAG B Y, et al. Dislocated time series convolutional neural architecture: an intelligent

- fault diagnosis approach for electric machine[J]. IEEE Transactions on Industrial Informatics, 2017, 13(3): 1310-1320.
- [69] INCE T, KIRANYAZ S, EREN L, et al. Real-time motor fault detection by 1-D convolutional neural networks[J]. IEEE Transactions on Industrial Electronics, 2016, 63(11): 7067-7075.
- [70] HUANG R Y, LIAO Y X, ZHANG S H, et al. Deep decoupling convolutional neural network for intelligent compound fault diagnosis[J]. IEEE Access, 2018(7): 1848-1858.
- [71] 陈伟, 何家欢, 裴喜平. 基于相空间重构和卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2018, 46(14): 87-93.
CHEN Wei, HE Jiahuan, PEI Xiping. Classification for power quality disturbance based on phase-space reconstruction and convolution neural network[J]. Power System Protection and Control, 2018, 46(14): 87-93.
- [72] 林颖, 郭志红, 陈玉峰. 基于卷积递归网络的电流互感器红外故障图像诊断[J]. 电力系统保护与控制, 2015, 43(16): 87-94.
LIN Ying, GUO Zhihong, CHEN Yufeng. Convolutional-recursive network based current transformer infrared fault image diagnosis[J]. Power System Protection and Control, 2015, 43(16): 87-94.
- [73] 任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域中的研究现状与挑战[J]. 控制与决策, 2017, 32(8): 1345-1358.
REN Hao, QU Jianfeng, CHAI Yi, et al. Deep learning for fault diagnosis: the state of the art and challenge[J]. Control and Decision, 2017, 32(8): 1345-1358.
- [74] 丛爽, 戴谊. 递归神经网络的结构研究[J]. 计算机应用, 2004, 24(8): 18-20, 27.
CONG Shuang, DAI Yi. Structure of recurrent neural networks[J]. Computer Applications, 2004, 24(8): 18-20, 27.
- [75] 丛爽, 高雪鹏. 几种递归神经网络及其在系统辨识中的应用[J]. 系统工程与电子技术, 2003, 23(2): 194-197.
CONG Shuang, GAO Xuepeng. Recurrent neural networks and their application in system identification[J]. Systems Engineering and Electronics, 2003, 23(2): 194-197.
- [76] 陈如清. 两种基于神经网络的故障诊断方法[J]. 中国电机工程学报, 2005, 25(16): 112-115.
CHEN Ruqing. Comparison between two fault diagnosis methods based on neural network[J]. Proceedings of the CSEE, 2005, 25(16): 112-115.
- [77] MOUSTAPHA A I, SELMIC R R. Wireless sensor network modeling using modified recurrent neural networks: application to fault detection[J]. IEEE Transactions on Instrumentation and Measurement, 2008, 57(5): 981-988.
- [78] WANG J G, WU G X, WAN L, et al. Recurrent neural network applied to fault diagnosis of underwater robots[C] // 2009 IEEE International Conference on Intelligent Computing and Intelligent Systems, November 20-22, 2009, Shanghai, China: 538-598.
- [79] LIN C M, BOLDBAATAR E A. Fault accommodation control for a biped robot using a recurrent wavelet Elman neural network[J]. IEEE Systems Journal, 2017, 11(4): 2882-2893.
- [80] 时小虎, 梁艳春, 徐旭. 改进的Elman模型与递归反传控制神经网络[J]. 软件学报, 2003, 14(6): 1110-1119.
SHI Xiaohu, LIANG Yanchun, XU Xu. An improved Elman model and recurrent back-propagation control neural networks[J]. Journal of Software, 2003, 14(6): 1110-1119.
- [81] BARALDI P, MAIO F D, GENINI D, et al. Comparison of data-driven reconstruction methods for fault detection[J]. IEEE Transactions on Reliability, 2015, 64(3): 852-860.
- [82] 李若晨, 朱帆, 朱永利, 等. 结合受限玻尔兹曼机的递归神经网络电力系统短期负荷预测[J]. 电力系统保护与控制, 2018, 46(17): 83-88.
LI Ruochen, ZHU Fan, ZHU Yongli, et al. Short-term power load forecasting using recurrent neural network with restricted Boltzmann machine[J]. Power System Protection and Control, 2018, 46(17): 83-88.
- [83] 王旭红, 何怡刚. 基于对角递归神经网络的异步电动机定子绕组匝间故障诊断方法[J]. 电力自动化设备, 2009, 29(7): 60-63.
WANG Xuhong, HE Yigang. Inter-turn fault detection of asynchronous motor stator winding based on diagonal recurrent neural network[J]. Electric Power Automation Equipment, 2009, 29(7): 60-63.
- [84] XU X, CHEN R Q. Recurrent neural network based online fault diagnosis approach for power electronic devices[C] // Third International Conference on Natural Computation, August 24-27, 2007, Haikou, China: 700-704.
- [85] TALEBI H A, KHORASANI K, TAFAZOLI S. A recurrent neural-network-based sensor and actuator fault detection and isolation for nonlinear system with application to the satellite's attitude control subsystem[J]. IEEE Transactions on Neural Networks, 2009, 20(1): 45-60.
- [86] TALEBI H A, KHORASANI K. A neural network-based multiplicative actuator fault detection and isolation of nonlinear systems[J]. IEEE Transactions on Control Systems Technology, 2013, 21(3): 842-851.
- [87] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is

- difficult[J]. IEEE Transactions on Neural Networks, 1994, 5(2): 157-166.
- [88] BRUIN T D, VERBERT K, BABUSKA R. Railway track circuit fault diagnosis using recurrent neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(3): 523-533.
- [89] LUO Y F, QIU J Q, SHI C W. Fault detection of permanent magnet synchronous motor based on deep learning method[C] // 2018 21st International Conference on Electrical Machines and Systems, October 7-10, 2018, Jeju, Korea: 699-703.
- [90] 张建付, 宋雨, 李刚, 等. 基于长短时记忆神经网络的风电机组滚动轴承故障诊断方法[J]. 计算机测量与控制, 2017, 25(1): 16-19.
ZHANG Jianfu, SONG Yu, LI Gang, et al. A method of fault diagnosis for rolling bearing of wind turbines based on long short-term memory neural network[J]. Computer Measurement & Control, 2017, 25(1): 16-19.
- [91] 赵建鹏, 周俊. 基于长短时记忆网络的旋转机械状态预测研究[J]. 噪声与振动控制, 2017, 37(4): 155-159.
ZHAO Jianpeng, ZHOU Jun. State prognosis of rotary machines based on long/short term memory recurrent neural network[J]. Noise and Vibration Control, 2017, 37(4): 155-159.
- [92] ZHAO H, SUN S, JIN B. Sequential fault diagnosis based on LSTM neural network[J]. IEEE Access, 2018, 6: 12929-12939.
- [93] HORN J, DE JESUS O, HAGAN M T. Spurious valleys in the error surface of recurrent networks—analysis and avoidance[J]. IEEE Transactions on Neural Networks, 2009, 20(4): 686-700.
- [94] CHO H C, KNOWLES J, FADALI M S, et al. Fault detection and isolation of induction motors using recurrent neural networks and dynamic bayesian[J]. IEEE Transactions on Control Systems Technology, 2010, 18(2): 430-437.
- [95] SONG Q, WU Y L, SOH Y C. Robust adaptive gradient-descent training algorithm for recurrent neural networks in discrete time domain[J]. IEEE Transactions on Neural Networks, 2008, 29(11): 1841-1853.
- [96] LIU L, WANG Z, YAO X, et al. Echo state networks based data-driven adaptive fault tolerant control with its application to electromechanical system[J]. IEEE/ASME Transactions on Mechatronics, 2018, 23(3): 1372-1382.
- [97] 徐波, 黄陈蓉, 卢阿丽. 感应电机常见故障及关键故障诊断技术分析[J]. 微电机, 2015, 48(5): 106-110.
XU Bo, HUANG Chenrong, LU Ali. Induction motor common faults and key fault diagnostics[J]. Micromotors, 2015, 48(5): 106-110.
- [98] 孙丽玲. 感应电机常见故障及关键故障诊断技术分析[D]. 北京: 华北电力大学, 2007.
SUN Liling. Research on the detection and diagnosis scheme of induction motor fault[D]. Beijing: North China Electric Power University, 2007.
- [99] 李西戌. 基于卷积神经网络的网络故障诊断模型[J]. 软件导刊, 2017, 16(12): 40-43.
LI Youxu. A network fault diagnosis model based on convolution neural network[J]. Software Guide, 2017, 16(12): 40-43.
- [100] 王鑫, 吴际, 刘超, 等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. 北京航空航天大学学报, 2018, 44(4): 772-784.
WANG Xin, WU Ji, LIU Chao, et al. Exploring LSTM based recurrent neural network for failure time series prediction[J]. Journal of Beijing University of Aeronautics and Astronautics, 2018, 44(4): 772-784.
- [101] 胡越, 罗东阳, 花奎, 等. 关于深度学习的综述与讨论[J]. 智能系统学报, 2019, 14(1): 1-18.
HU Yue, LUO Dongyang, HUA Kui, et al. Overview and discussion on deep learning[J]. CAAI Transactions on Intelligent Systems, 2019, 14(1): 1-18.

收稿日期: 2019-06-19; 修回日期: 2019-07-26

作者简介:

丁石川(1980—), 男, 通信作者, 博士, 副教授, 研究方向为电动汽车电机及驱动系统关键技术; E-mail: dingsc@126.com

厉雪衣(1995—), 女, 硕士研究生, 研究方向为电机故障诊断;

杭俊(1987—), 男, 通信作者, 博士, 副教授, 硕士研究生导师, 研究方向为新能源发电、电机驱动及控制、状态监测与故障诊断。E-mail: jun_hang511@163.com

(编辑 周金梅)