

深度学习及其在电机控制中的研究现状与展望^{*}

曹美禾, 宋琳, 孙军, 李忠瑞, 聂子玲

(海军工程大学 舰船综合电力技术国防科技重点实验室, 湖北 武汉 430033)

摘要: 状态观测器、卡尔曼滤波器等传统观测器由于应用范围的局限性, 自身结构的缺陷性, 会使电机控制系统的设计变复杂, 观测精度降低, 观测范围受限等。深度学习具有非线性拟合能力和泛化能力好以及特征提取能力强等优点。以深度学习观测器为主线, 阐述了其应用到电机控制系统中的优势, 以四种典型网络为例介绍了深度学习的原理和结构, 列举并重点分析了深度学习在电机控制中的应用, 对未来深度学习在电机观测器控制中的发展方向进行了展望。

关键词: 电机控制; 深度学习; 神经网络观测器; 卷积神经网络

中图分类号: TM301 文献标志码: A 文章编号: 1673-6540(2023)05-0001-09

doi: 10.12177/emca.2023.041

Research and Prospect on Deep Learning and Its Application in Motor Control^{*}

CAO Meihe, SONG Lin, SUN Jun, LI Zhongrui, NIE Ziling

(National Defense Key Laboratory of Science and Technology on Vessel Integrated Power System, Naval University of Engineering, Wuhan 430033, China)

Abstract: Due to the limitations of the application range and the defects of their own structures, the traditional observers such as state observers and Kalman filters may complicate the design of motor control systems, reduce the observation accuracy and limit the observation range, etc. Deep learning has the advantages of non-linear fitting capability, good generalization ability and strong feature extraction ability, etc. Deep learning observer is taken as the main line, the advantages of its application in motor control system is described. The principle and structure of deep learning with four typical networks is taken as examples, the analysis of the application of deep learning in motor control is listed and focused on, and on the future developing direction of deep learning in motor observer control is forecasted.

Key words: motor control; deep learning; neural network observer; convolutional neural network (CNN)

0 引言

近年来,随着工业化进程的发展,深度学习因其建模方便、数据处理能力强等显著优势,广泛应用于电机控制领域。作为深层次的神经网络结构,其具有强大的非线性拟合能力和特征提取能

力,能够处理巨量的高维度数据,高效地对数据进行分类^[1-3]。

使用光电编码器、磁感应传感器等传统传感器监测电机状态时会带来硬件成本增加、系统可靠性降低等问题。无传感器控制技术通过采集易测量的电气模拟量(如定子侧电压电流等),输入

收稿日期: 2022-10-27; 收到修改稿日期: 2023-02-13

^{*} 基金项目: 国家自然科学基金项目(52077219)

作者简介: 曹美禾(1999—),男,硕士研究生,研究方向为电力电子与电力传动。

聂子玲(1975—),男,博士,教授,研究方向为电力电子与电力传动。

观测器计算得到电机状态,无传感器技术广泛应用于变频调速场合,在伺服系统中的应用也逐渐增多^[4-5]。

观测器可分为线性观测器和非线性观测器。线性观测器包括龙伯格观测器、卡尔曼滤波器等;非线性观测器包括扰动观测器、滑模观测器(SMO)等^[6]。线性观测器由于研究对象的局限性导致难以单独大规模的应用到电机控制系统中。非线性观测器往往针对某一问题进行特殊设计,导致结构本身存在弱点^[7-8],引入深度学习技术为电机观测器设计提供了新的研究思路。

本文在概述深度学习思想和模型结构基础上,回望观测器的相关研究,总结深度学习在电机

观测器方面的应用,并对未来深度学习在电机控制领域的发展做出展望。

1 深度学习概述

深度学习具有悠久的历史,20 世纪 40 年代~20 世纪 90 年代,深度学习先后以控制论、联结主义的形式出现。2006 年,正式以深度学习的名称登上历史的舞台,研究初期旨在模拟生物学习能力。现在深度学习超越了神经学科的观点,更注重多层次组合这一思想。深度学习作为更深层的神经网络,将抽象的高层属性分解成低层特征的组合,从而分布式地处理数据^[9],常见的深度学习模型按结构分类如图 1 所示。




图 1 深度学习模型

在电机控制领域中较为公认的深度学习模型有基于受限玻尔兹曼机(RBM)的深度信念网络(DBN)、基于自动编码器(AE)的堆叠自动编码器(SAE)、卷积神经网络(CNN)、循环神经网络(RNN)等^[10]。本文将介绍 DBN、SAE、CNN、RNN 四种典型深度学习模型的结构和原理。

1.1 DBN

DBN 最早由 Hinton 于 2006 年提出,DBN 的引入开启了深度学习的复兴之路^[11]。DBN 由一系列 RBM 单元堆叠而成,包括可见层和多隐含层,两者之间通过一定权重相连,每层内的节点无连接。顶部两层之间的连接是无向的,其他层之间的连接均是有向的,箭头指向最接近数据的层^[12]。训练时,需要反复执行数个 Gibbs 采样,

即将可见层向量值映射给隐含层单元,可见层再由隐含层单元重建,重复执行上述步骤^[13],DBN 模型如图 2 所示。




图 2 DBN 模型

训练数据输入可见层,再映射到隐含层即构

成一个 RBM, 自下而上多个 RBM 堆叠形成 DBN。与传统方法相比, 由逐层贪婪学习得到的高层属性类别, 提高了训练数据在 DBN 模型下似然概率的变分下界, 更有利于挖掘数据的深层特性^[14]。

1.2 堆叠自动编码器

SAE 由多个 AE 堆叠而成。AE 通过编码器和解码器使输入与输出尽可能接近, 通过内部表示或编码 h (隐含层, 产生编码表示输入) 将输入映射到输出^[15], 如图 3 所示。




图 3 AE 模型

为避免 AE 训练中, 过度追求输入与输出误差最小化导致得到恒等目标函数 $g[f(x)] = x$, 需添加约束, 引入 SAE^[16]。SAE 将最小化输入与输出之间的差值作为目标, 每个 AE 单独训练, 前一层输出作为下一层输入, 逐层训练直至训练完成^[17]。将 AE 训练好的权重和偏置作为 SAE 初始值, 进一步完善得到各层权值^[18], 上述过程如图 4 所示。




图 4 SAE 模型

与传统观测器相比, SAE 通过堆叠多个 AE, 使输出接近输入但不完全相等, 具有高阶特征表示能力和收敛能力更强等优点^[19]。

1.3 CNN

CNN 用于处理具有类似网格结构的数据, 如时间序列数据(时间轴上有规律地采样形成的一

维网格) 和图像数据(二维像素网格)^[20]。经典的 CNN 结构由卷积层、池化层、全连接层组成, 卷积层和池化层交替堆叠, 学习输入数据的抽象特征表示, CNN 的模型如图 5 所示。




图 5 CNN 模型

数据输入到卷积层, 多个卷积核对数据进行卷积运算, 提取特征, 降低数据维度得到多个特征图。特征图进入池化层, 通过给定的池化策略进一步减少模型参数数量, 约简特征图尺寸。卷积层和池化层多次交替堆叠之后, 经过全连接层逐层组合得到高阶特征数据输出^[21]。

卷积操作如下:

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

式中: x_j^l 为第 l 隐含层的第 j 个神经元输出; x_i^{l-1} 为第 l 隐含层的第 i 个神经元输入; M_j 为输入的 $j \times 1$ 数据集合; K_{ij}^l 为第 l 隐含层的 $i \times j$ 卷积核; b_j^l 为第 l 隐含层的第 j 个神经元偏置; $f(\cdot)$ 为非线性神经元激活函数, 典型的有线性整流单元 (ReLU)、高斯误差线性单元 (GELU) 等; “*” 为卷积计算。

池化操作如下:

$$x_j^l = f[\beta_j^l \text{down}(x_i^{l-1}) + b_j^l] \quad (2)$$

式中: β_j^l 为乘性偏置; $\text{down}(\cdot)$ 为池化函数。

CNN 是生物学拓展到机器学习最成功的案例之一, 与传统观测器相比, CNN 结合了生物学的优势, 能够对图像信息进行处理^[22]。

1.4 RNN

RNN 用于处理形如 $x^{(1)}, x^{(2)}, \dots, x^{(\tau)}$ 的序列数据, 可以扩展到任意长度序列^[23]。RNN 隐含层的输入不仅包括数据此刻的输入, 还包括上一时刻同隐含层的输出, 且节点之间相互连接^[24], 其原理图如图 6 所示。

隐含层节点数据与时间紧密相关, $t-1$ 、 t 、 $t+1$ 表示三个连续时刻。隐含层与输入层之间存在反馈连接^[25], RNN 的数学模型可表示为




图6 RNN原理图

$$\begin{cases} s_t = f(Ux_t + W * s_{t-1}) \\ y_t = g(V * s_t) \end{cases} \quad (3)$$

式中： x_t 为 t 时刻输入； s_t 为 t 时刻隐含层状态； y_t 为 t 时刻输出； U 、 V 、 W 分别为输入层与隐含层、隐含层与输出层、 $t-1$ 时刻隐含层与 t 时刻隐含层之间的连接权值。

当前 RNN 的隐含层连接到下一 RNN 的隐含层,需考虑当前样本对后续样本的影响,类似于“因果”结构,当前的信息只从过去的序列中捕获^[26],如图 7 所示。




图7 RNN模型

同时还存在双向循环神经网络 (BiRNN) 结构,该结构需考虑前后样本对当前样本的影响,结合时间上从序列起点开始移动的 RNN 和另一个时间从序列末尾开始移动的 RNN^[27-29]。RNN 构建了不同时刻信息之间的相关性,完成了整个时序到目标的映射。

2 深度学习在电机控制中的应用

在电机控制智能化的进程中,研究如何应用神经网络至关重要,其中浅层神经网络是基础,深度学习是进阶。深度学习电机观测器是在浅层神经网络电机观测器的研究基础上发展而来的,本文综述了已应用的浅层神经网络电机观测器和深度学习电机观测器,并简述了深度学习在电机控制邻域的其他研究,对如何将浅层神经网络观测器的设计思路应用到深度学习观测器的设计中以

及如何将已有的深度学习模型迁移到电机观测器中进行了思考。

2.1 基于反向传播神经网络的位置观测器

针对传统观测器调整参数复杂,信号易受干扰的问题,文献[30]提出了基于反向传播神经网络(BPNN)的位置观测器。采用高频电压注入法,向 d 轴注入高频电压,通过锁相环观测器提取电流的幅值信息计算得到估计的转子位置和转速,用于系统的闭环控制,实现无传感器控制。将观测器提取到的电机参数作为样本数据送入 BPNN,训练出准确性高、泛化能力强的模型,基于 BPNN 的电机控制结构如图 8 所示。




图8 基于BPNN的电机控制结构

对基于 BPNN 的模型参数通过反向传播算法进行在线调整,修正项的引入增强了观测器的鲁棒性。前馈神经网络具有任意精度逼近能力,对非线性项的拟合可以达到较为理想的结果。在给定逼近误差大于零的情况下,一定存在合适的权值和阈值使 BPNN 在误差允许的范围内拟合非线性函数^[31]。

BPNN 适用于数据量小,结构简单的电机控制系统。在优化目标函数时,BPNN 算法本质为梯度下降法,所以会使收敛速度变慢。在优化权值时,用到的局部搜索算法可能使权值收敛到局部极小点。BPNN 的质量与学习样本的好坏有关,依赖于从问题中选出典型样本进行训练^[32]。

2.2 基于径向基函数-滑模观测器的位置估计

针对传统 SMO 存在时间和空间滞后导致系统产生抖振的问题,文献[33]提出基于径向基函数神经网络(RBFNN)的 SMO 转子位置估计。结合 RBFNN 局部逼近能力和良好的泛化能力,将

滑模变量作为 RBFNN 的输入,观测器的控制策略作为 RBFNN 的输出,将控制目标从跟踪误差转为优化滑模函数,利用神经网络的自学习能力,实现基于 RBFNN 的滑模控制,基于 RBFNN 的 SMO 结构如图 9 所示。




图 9 RBFNN-SMO 结构图

图 9 中 SMO 部分,通过定子电流和线电压来估计电机转子的位置和速度。 v 为观测器的控制律, $v = v_{eq} + v_n$, 等效控制 v_{eq} 通过 RBFNN 得到, 具有更好的控制精度。在 RBFNN 中, 将高斯函数作为径向基函数, 引入鲁棒项来抑制神经网络逼近误差, 避免局部极小值问题。因为 RBFNN 的隐含层到输出层的映射是线性的, 所以可以大大加快学习速度。

RBFNN 适用于对控制精度和响应速度有要求, 且含轻微扰动的非线性电机控制系统。RBFNN 将问题特征全部转化为数字信息, 推理过程全部转化为数值计算, 导致中间过程无法解释, 甚至可能丢失部分数据信息^[34]。

2.3 基于 RNN 的状态观测器

针对电机驱动控制系统中, 非线性干扰和测量噪声导致部分机电状态不可测的问题, 文献[35]提出基于 Elman RNN 的状态观测器。Elman RNN 结构类似于输入或输出带延迟的多层感知器, RNN 算法允许数据并行处理, Elman 用于处理复杂的非线性对象, 引入的延迟反馈用状态空间来描述, Elman RNN 模型包括输入层、第一隐含层、带延迟元素的反馈和输出层。Elman RNN 数学模型用离散非线性微分方程组描述如下:

$$\begin{cases} \mathbf{x}(k+1) = f[W_a \mathbf{x}(k), W_b \mathbf{u}(k)] \\ \mathbf{y}(k) = C\mathbf{x}(k) \end{cases} \quad (4)$$

式中: $\mathbf{x}(k)$ 为系统的状态向量; $\mathbf{u}(k)$ 为输入向量;

$\mathbf{y}(k)$ 为输出向量; W_a 为第一隐含层的权重; W_b 为输入端的权重; C 为输出层的权重; f 为非线性激活函数。

基于 Elman RNN 的状态观测器结构如图 10 所示。




图 10 Elman RNN 状态观测器结构图

在基于 Elman RNN 的状态观测器中, 神经网络维数为 6-15-3, 电机电流 i_m 和角速度 ω_1 为输入信号, 具有深度为 2 的单位延迟, 观测目标为弹性扭矩 $\hat{T}_{21}$ 和第二角速度 $\hat{\omega}_2$, 隐藏层的激活函数为 tansig, 输出层的激活函数为 satlins。针对隐含层和输出层不同的数据特征, 选择不同的激活函数进行数据处理。通过时延模块将当前隐含层的信息作为下一隐含层的输入输送进网络中, 充分利用历史数据实现对输出值的准确观测。

RNN 适用于处理参数与时间相关, 无需太多隐含层的电机控制模型, 在时间序列的学习和分析中具有较强的适应性和准确性。普通 RNN 存在梯度消失或梯度爆炸的问题, 训练和实现的难度较大, 不能堆叠为任意深度的神经网络。

2.4 基于卷积神经网络的转矩观测器

针对电机参数具有非线性特征导致电磁转矩难以估计的问题, 文献[36]提出基于 CNN 的电磁转矩估算方法。将内嵌式永磁同步电机模型的输出作为 CNN 转矩观测器的样本数据, 用一维卷积核代替二维卷积核提取向量特征, 实现多个特征映射的融合。引入 ReLU 激活函数, 简化计算过程, 加快系统收敛速度, CNN 转矩观测器结构如

图 11 所示。




图 11 CNN 转矩观测器结构图

将 d 轴和 q 轴电流 i_d 和 i_q 作为网络输入,通过 i_d, i_q 来确定电机的转矩 T_e ,由 CNN 算法建立关于 T_e 的非线性拟合,网络输出为观测到的 T_e 。图 11 中用 ReLU 函数作为激活函数提高卷积核输出的非线性映射能力,ReLU 的函数功能如下:

$$\text{ReLU}(x) = f(x) = \max(x, 0) \quad (5)$$

模型优化过程中,首先通过神经网络前向传播算法得到预测值,计算预测值和真实值之间的差值。然后通过反向传播算法计算损失误差对应的每个参数梯度,由梯度下降算法更新每个参数。最后使损失函数达到最小值^[37],快速且精准地得到观测转矩值。

CNN 适用于数据量大、维数高、采样点少的非线性电机控制系统。CNN 实现较复杂,训练样本需求大,训练速度较慢。CNN 有强大的二维图像数据处理能力,但在工业数据处理方面的效果并不理想,将工业信号转化为图像数据是 CNN 神经网络的研究重点之一^[38]。

在参数辨识、模型预测以及故障诊断等领域,深度学习的应用也是日益成熟。针对非线性电机控制系统模型难以用线性函数或经验建立的问题,提出通过深度学习对电机控制模型进行建模。基于深度学习观测器进行参数辨识的电机控制系统需要对模型进行预测,结合当前系统的状态和预测模型,对未来可能出现的状态进行预测,并通过观测器给出最优控制参数,达到对电机系统的实时控制^[39]。文献[40]对电机调速时电流超调造成结果波动的问题,提出参数辨识无位置控制,将参数辨识结果进行滤波,然后用于辨识闭环,如图 12 所示。




图 12 具有参数辨识的无位置控制框图

目前将深度学习应用于故障诊断中的研究较多,文献[41]分别采用深度学习中经典的 CNN 和 RNN 两种算法对电机故障进行诊断并分析比较,最终得出两种算法均有较高的准确率,但 CNN 算法准确率略高于 RNN 算法,RNN 具有更强的抗干扰能力。文献[42]提出将系统状态通过图片体现,利用深度学习对数据强大的降维能力将图片降维,从而达到特征提取及数据分析的目的,如 Lange 等^[43]利用 SAE 强大的学习数据特征能力,成功对数据特征进行了提取,并且比浅层神经网络具有更高的提取精度。文献[44]提出利用深度学习模型拟合 PID 控制,智能控制系统中的控制量不再单一,需要对整个系统状态进行分析,DBN 具备强大的数据分类能力,所以提出将 DBN 与 PID 控制器组合使用,以达到精准控制的目的。

深度学习模型突出的优点是无需人工特征提取,避免了人为因素带来的干扰,提高了系统的智能性;明显的短板是依赖样本数据,调参复杂,训练模型耗时长。结合神经网络在电机观测器控制、参数辨识以及故障诊断等应用中的研究,表 1 总结归纳了 BPNN、RBFNN 和四种典型深度学习模型适用的场景,以及相较于传统观测器其在应用中的优缺点。

3 深度学习在电机控制中的展望

深度学习目前在电机控制中的应用还存在中间过程数学定义不清晰、网络参数优化有难度、硬件要求高等问题。学者们可从这些问题出发,提升和完善深度学习在应用中的性能,探索如何将前沿技术与现有技术相结合,取长补短,互为补

表 1 神经网络模型的优缺点及应用场景

模型	优点	缺点	适用场景
BPNN	(1)非线性映射能力 (2)网络结构简单 (3)泛化能力强	(1)局部极小化问题 (2)降低收敛速度 (3)样本依赖性	数据量小, 结构简单
RBFNN	(1)唯一最佳逼近性能 (2)收敛速度快 (3)抗噪和修复能力	(1)缺乏推理过程和依据 (2)信息丢失	控制精度高, 响应速度快, 含轻微扰动
CNN	(1)海量高维数据处理能力 (2)局部感知、共享权重 (3)改进策略丰富	(1)网络结构复杂 (2)需大量带二维标签数据 (3)工业应用能力有限	数据量大、维数高, 采样点少, 二维图像数据
RNN	(1)时间序列隐含信息的使用 (2)随机长度序列	(1)梯度消失或梯度爆炸 (2)训练难度大	参数与时间相关, 隐含层不多
SAE	(1)鲁棒性 (2)数据特征学习能力 (3)优化变种能力	(1)训练速度慢 (2)需预训练	输入维度远小于输出, 逐层训练
DBN	(1)自适应学习数据特征 (2)避免维数灾难 (3)结构简单	(1)可能收敛于局部最优 (2)训练速度慢、效率低	一维数据和未标记数据, 特征分类

充,同时思考如何将理论研究应用到实际工程中,降低深度学习学习使用的成本,简化参数优化过程、降低硬件要求,减少使用成本等。

深度学习在电机控制中的展望如下。

(1) 深度学习与现有观测器的结合。针对电机参数复杂,观测器模型难以构建,现有神经网络观测器不够完善的问题。将深层、浅层神经网络与现有观测器融合,构建混合深度学习观测器,通过神经网络将非线性样本训练出一个拟合较好的线性函数,然后在成熟的观测器上构建模型,各种方法之间有机结合可以实现高效且高准确率电机控制目标,取长补短弥补现有神经网络观测器的缺陷。

(2) 数据迁移学习和领域自适应的应用。针对深度学习观测器依赖大量样本数据,在新环境下训练时间较长,模型精度不高的问题,可提升数据和模型的迁移能力。建立源域标记数据到目标域未标记数据的关系,通过域自适应算法减小两域之间的差异,设计合适的域自适应模块以保证数据迁移时的真实性和准确性。从而减少收集样本数据和训练模型的时间,进而降低模型对样本数据的依赖。

(3) 深度学习电机观测器的实际应用。针对目前大多基于深度学习的电机观测器仅停留在试

验研究层面,不具备实际应用的问题,可从硬件和软件两方面入手,充分考虑成本、实用性、可靠性、效率等因素。软件方面针对深度学习模型内部运算不清晰,导致应用时缺乏足够理论支撑的问题,通过算法和操作平台的优化实现模型可视化,为深度学习体系提供理论依据,如高维数据可视化、可视化操作平台等;硬件方面针对目前计算速度和计算精度有限的问题,充分利用图形处理器(GPU)、现场可编程门阵列(FPGA)、数字信号处理(DSP)等高性能硬件进行加速,组合使用取长补短、优势互补以达到最佳性能。

4 结 语

在人工智能、大数据迅猛发展的今天,深度学习作为更深层次的神经网络与观测器控制的结合才刚刚崭露头角,目前研究尚处于“浅层”阶段,还有较大的研究空间与价值。在未来必将会有更多资源投入到其中,并在各个领域的发展进程中扮演着越来越重要的角色。将深度学习融入到电机观测器的研究中,对整个电机控制系统的发展具有重大意义。

【参 考 文 献】

[1] 杨晨,黄平林,袁磊. 基于人工神经网络的永磁电

- 机无传感器控制与实现[J]. 电机与控制应用, 2022, 49(2): 20.
- [2] HAN Z, YU S, LIN S, et al. Depth selection for deep ReLU nets in feature extraction and generalization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(4): 1853.
- [3] 李超然, 肖飞, 樊亚翔, 等. 基于深度学习的锂离子电池 SOC 和 SOH 联合估算[J]. 中国电机工程学报, 2021, 41(2): 681.
- [4] 莫会成, 闵琳. 现代高性能永磁交流伺服系统综述——传感装置与技术篇[J]. 电工技术学报, 2015, 30(6): 10.
- [5] 刘长征, 叶瑰昀, 陈德运, 等. 无传感器无刷直流电机变频调速系统设计与实现[J]. 电机与控制学报, 2008, 56(6): 729.
- [6] 王轶昆. 永磁同步电机全速度无传感器控制研究[D]. 北京: 北京交通大学, 2019.
- [7] 刘计龙, 肖飞, 沈洋, 等. 永磁同步电机无位置传感器控制技术研究综述[J]. 电工技术学报, 2017, 32(16): 76.
- [8] KHALIL H K. High-gain observers in feedback control: application to permanent magnet synchronous motors[J]. IEEE Control Systems Magazine, 2017, 37(3): 25.
- [9] SHRESTHA A, MAHMOOD A. Review of deep learning algorithms and architectures [J]. IEEE Access, 2019, 7: 53040.
- [10] 孙志军, 薛磊, 许阳明, 等. 深度学习研究综述[J]. 计算机应用研究, 2012, 29(8): 2806.
- [11] 刘洋, 赵凯岐. 基于神经网络的双闭环伺服系统自适应控制[J]. 电机与控制应用, 2022, 49(7): 22.
- [12] HUA Y, GUO J, ZHAO H. Deep belief networks and deep learning [C] // Proceedings of 2015 International Conference on Intelligent Computing and Internet of Things, 2015.
- [13] 王功明, 乔俊飞, 关丽娜, 等. 深度信念网络研究现状与展望[J]. 自动化学报, 2021, 47(1): 35.
- [14] KUO J Y, PAN C W, LEI B. Using stacked denoising autoencoder for the student dropout prediction[C] // 2017 IEEE International Symposium on Multimedia (ISM), 2017.
- [15] 邓俊锋, 张晓龙. 基于自动编码器组合的深度学习优化方法[J]. 计算机应用, 2016, 36(3): 697.
- [16] XU Q, ZHANG C, ZHANG L, et al. The learning effect of different hidden layers stacked autoencoder [C] // 2016 8th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC), 2016.
- [17] 朱乔木, 陈金富, 李弘毅, 等. 基于堆叠自动编码器的电力系统暂态稳定评估[J]. 中国电机工程学报, 2018, 38(10): 2937.
- [18] 叶林, 葛鸥翔, 郭永红, 等. 基于堆叠自动编码器的汽轮发电机多指标故障诊断模型[J]. 中国电机工程学报, 2022, 42(10): 3656.
- [19] FANG Y, WANG M, WEI L. Deep transfer learning in inter-turn short circuit fault diagnosis of PMSM [C] // 2021 IEEE International Conference on Mechatronics and Automation (ICMA), 2021.
- [20] 李世晓, 杜锦华, 龙云. 基于一维卷积神经网络的机电作动器故障诊断[J]. 电工技术学报, 2022, 37(增1): 62.
- [21] 李耀华, 赵承辉, 周逸凡, 等. 基于卷积神经网络和直接转矩控制的永磁同步电机模型预测转矩控制策略[J]. 电机与控制应用, 2020, 47(9): 8.
- [22] 李超然, 肖飞, 樊亚翔, 等. 基于卷积神经网络的锂离子电池 SOH 估算[J]. 电工技术学报, 2020, 35(19): 4106.
- [23] TURKOGLU M O, D'ARONCO S, WEGNER J D, et al. Gating revisited: deep multi-layer RNNs that can be trained [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(8): 4081.
- [24] CHOI D, HAN J, PARK S, et al. Comparison of motor fault diagnosis performance using RNN and K-means for data with disturbance [C] // 2020 20th International Conference on Control, Automation and Systems (ICCAS), 2020.
- [25] SONG L, NIE Z, XU J, et al. An RNN-EKF observer for time delay of large-scale motor control system[C] // 2022 IEEE 10th Joint International Information Technology and Artificial Intelligence Conference (ITAIC), 2022.
- [26] LIN C, CHIANG P, TSENG C. Adaptive backstepping control for a permanent magnet synchronous motor drive using RNN uncertainty observer [C] // 2010 5th IEEE Conference on Industrial Electronics and Applications, 2010.
- [27] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(增2): 1.
- [28] SUN F, PAN X, LIU Y. The design of position estimator for PMSM by using diagonal recurrent

- neural network [C] // 2007 IEEE International Conference on Automation and Logistics, 2007.
- [29] LIN C, LIN M, WU R. Integral backstepping control for a PMSM drive using adaptive RNN uncertainty observer [C] // 2012 International Symposium on Computer, Consumer and Control, 2012.
- [30] PAN J D, LIANG J N, SUN T F, et al. Optimization of rotor position observer with BP neural network [C] // 2019 22nd International Conference on Electrical Machines and Systems (ICEMS), 2019.
- [31] 耿建平, 闫俞佰, 熊光阳, 等. 基于 BP 神经网络的永磁同步电机转矩观测器设计 [J]. 电机与控制应用, 2020, 47(1): 78.
- [32] 彭斌, 王文奎. 基于模糊系数修正 BP 神经网络 PID 的 BLDCM 控制系统仿真研究 [J]. 电机与控制应用, 2021, 48(6): 17.
- [33] 刘慧博, 江帅璐. 基于 RBF 终端滑模观测器的电机转子位置估计 [J]. 计算机应用与软件, 2020, 37(1): 71.
- [34] 陈李济, 应保胜, 马强, 等. 基于模糊径向基函数神经网络的永磁同步电机滑模观测器设计 [J]. 电机与控制应用, 2019, 46(6): 66.
- [35] BELOV M P, VAN LANH N, KHOA T D. State observer based Elman recurrent neural network for electric drive of optical-mechanical complexes [C] // 2021 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus), 2021.
- [36] 李涉川, 孙天夫, 黄新, 等. 基于卷积神经网络的永磁同步电机转矩观测器 [J]. 集成技术, 2018, 7(6): 60.
- [37] ARORA D, GARG M, GUPTA M. Diving deep in deep convolutional neural network [C] // 2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN), 2020.
- [38] ULLAH A, AHMAD J, MUHAMMAD K, et al. Action recognition in video sequences using deep bi-directional LSTM with CNN features [J]. IEEE Access, 2017(6): 1155.
- [39] 任建, 王淑红, 黄济文, 等. 基于参数辨识的永磁同步电机无位置传感器控制 [J]. 电机与控制应用, 2022, 49(1): 8.
- [40] 刘伟, 王俊. 永磁同步电机参数辨识研究综述 [J]. 电气技术, 2020, 21(8): 1.
- [41] CHOI D J, HAN J H, PARK S U, et al. Comparative study of CNN and RNN for motor fault diagnosis using deep learning [C] // 2020 IEEE 7th International Conference on Industrial Engineering and Applications (ICIEA), 2020.
- [42] BRIVADIS L, ANDRIEU V, SERRES U. Luenberger observers for discrete-time nonlinear systems [C] // 2019 IEEE 58th Conference on Decision and Control (CDC), 2019.
- [43] LANGE S, RIEDMILLER M. Deep auto-encoder neural networks in reinforcement learning [C] // The 2010 International Joint Conference on Neural Networks, 2010.
- [44] LU P, HUANG W, XIAO J. Speed tracking of brushless DC motor based on deep reinforcement learning and PID [C] // 2021 7th International Conference on Condition Monitoring of Machinery in Non-Stationary Operations (CMMNO), 2021.

声 明

本刊已许可万方数据、重庆维普、中国学术期刊(光盘版)电子杂志社、北京世纪超星信息技术发展有限责任公司在其网站及其系列数据库产品中以数字化方式复制、汇编、发行、信息网

络传播本刊全文。该社著作权使用费与本刊相关费用抵消。如作者不同意文章被收录,请在来稿时向本刊声明,本刊将做适当处理。

《电机与控制应用》编辑部