

本文全文线上首发由
上海电机系统节能工程技术
研究中心有限公司
支持

王子旋,黎向锋,张宇翔,胡嘉琨,
徐礼林,左敦稳.
基于DNN的舵机用永磁式线性力
电机驱动力预测模型.
电机与控制应用,2021,48(9):72.

MTST系列 电机型式试验系统



MTST系列 电机型式试验系统①



MTST系列 电机型式试验系统②



MTST系列 电机型式试验系统③



MTST系列 电机型式试验系统④



MTST系列 电机型式试验系统⑤

CS-XY型电机出厂试验测试系统



DZC系列电机定子性能综合测试仪



TZ型电机堵转转矩测试仪



RZJ系列绕组匝间冲击耐电压测试仪



SEARI
上電科

上科電機

地址：上海市武宁路505号 传真：021-62163904

电话：021-62574990-436、18918357509

邮编：200063 邮箱：wangcj@seari.com.cn

上海电机系统节能工程技术研究中心有限公司 www.seari.com.cn

基于 DNN 的舵机用永磁式线性力电机驱动力预测模型^{*}

王子旋¹, 黎向锋¹, 张宇翔¹, 胡嘉琨^{2,3}, 徐礼林^{2,3}, 左敦稳¹

(1. 南京航空航天大学 机电学院, 江苏南京 210016;

2. 南京机电液压工程研究中心, 江苏南京 211106;

3. 航空机电系统综合航空科技重点实验室, 江苏南京 211106)

摘要: 永磁式线性力电机是直驱式电液伺服阀的重要部件之一, 其驱动力可以对进入阀口的金属碎片进行切割, 防止阀口被碎片挡住, 因此, 准确预测其驱动力对永磁式线性力电机的设计具有极其重要的研究意义。首先基于 ANSOFT 对永磁式线性力电机电磁场进行有限元仿真, 获得其零位在极限电流作用下的驱动力。其次根据优化目标和约束条件确定永磁式线性力电机的关键结构参数及其取值范围。随后, 采用基于最大最小距离准则的拉丁超立方算法进行关键结构参数在多维空间尺度上的样本采样。最后, 提出带有转换层的深度神经网络模型, 把电机结构参数经过转换层后提取出电机模型的 100 个参数, 使深度神经网络能从更多的特征中组合出新的高维特征, 从而提高模型预测精度, 且应用 PReLU 激活函数和 SmoothL1 Loss 损失函数, 建立了舵机用永磁式线性力电机驱动力预测模型。与传统的预测模型 Kriging 和 RBF 相比, 充分验证了此模型的有效性和准确性。

关键词: 永磁式线性力电机; 深度神经网络; ANSOFT; 驱动力预测

中图分类号: TM 359.4 **文献标志码:** A **文章编号:** 1673-6540(2021)09-0072-09

doi: 10.12177/emca.2020.074

Prediction Model of Permanent Magnet Linear Force Motor Driving Force Used by Actuator Based on Deep Neural Network^{*}

WANG Zixuan¹, LI Xiangfeng¹, ZHANG Yuxiang¹, HU Jiakun^{2,3}, XU Lilin^{2,3}, ZUO Dunwen¹

(1. College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

2. Nanjing Engineering Institute of Aircraft Systems, Nanjing 211106, China;

3. Aviation Key Laboratory of Science and Technology on Aero Electromechanical System Integration, Nanjing 211106, China)

Abstract: The permanent magnet linear force motor is one of the important components of the direct drive servo valve. Its driving force can cut the metal fragments entering the valve port to prevent the valve port from being blocked by them. Therefore, the accurate prediction of the driving force has extremely important research significance for designing the permanent magnet linear force motor. Firstly, a finite element simulation model of the permanent magnet linear force motor is established with ANSOFT, getting the driving force under the zero position and its limiting current. Secondly, the key structural parameters and their value ranges of the linear force motor are determined

收稿日期: 2021-04-24; 收到修改稿日期: 2021-07-16

*基金项目: 国家自然科学基金联合基金项目(U20A20293)

作者简介: 王子旋(1996—), 男, 硕士研究生, 研究方向为智能制造。

黎向锋(1971—), 女, 博士, 教授, 博士生导师, 研究方向为计算机智能加工、抗疲劳制造。

according to the optimization goal and constraint conditions. Then, the Latin hypercube algorithm based on the maximum and minimum distance criterion is used to sample data in a multi-dimensional space. Finally, a deep neural network model with a conversion layer is proposed. The conversion layer extracts 100 parameters from motor model, so that deep neural network can combine new high-dimensional features from more features and improve its prediction accuracy. The prediction model of permanent magnet linear force motor driving force used by actuator with PReLU and SmoothL1Loss is established. The comparison with traditional prediction models of both Kriging and RBF proves the effectiveness and accuracy of the new model.

Key words: permanent magnet linear force motor; deep neural network; ANSOFT; prediction of driving force

0 引言

传统电液舵机采用喷挡伺服阀驱动主控阀,分配流量控制下游的作动筒,喷挡伺服阀的工作特性决定了该类舵机不可避免地存在内漏大、抗污染能力差等不足^[1]。随着永磁材料和数字伺服控制技术的发展,直驱式电液伺服阀逐渐发展成熟。在马达和滑阀之间没有喷嘴挡板的液压放大器,而是采用直线电机直接驱动阀芯运动^[2]。因此具有结构简单、装配调试方便、静动态性能好、内漏小及抗污染能力强等优点。目前 F-22、B-2、EFA-2000、JAS39 等机型均应用了这一技术,国内军机也正逐步采用此技术^[1]。

在舵机产品的制造与装配使用过程中,零星金属碎片会随流体在产品中流动,如果在主控阀关闭过程中阀口被碎片挡住,阀芯不能回中,则会导致产品工作失效。如果考虑对可能进入阀口的金属碎片进行切割,阀芯和阀套是一种很有效的切削工具^[1]。永磁式线性力电机通过比较输入指令的极性和阀位移极性,使其具备故障检测能力。若 2 次以上重复出现故障指示,系统会短时施加一个较大反向剪切电流,对可能进入阀口的金属碎片进行切割,使阀芯能够回中,从而具备恢复能力。因此,在电机结构设计中需要调整电机结构参数使电机具有足够大的碎片剪切力。电机分析方法主要包括磁路法、解析法和有限元法。当涉及电机复杂几何结构、严重的磁饱和情况,有限元法比磁路法和解析法有更大的优势^[3]。

传统预测模型能够针对少数样本数据拟合目标值与输入变量的数学关系,在很大程度上减少有限元仿真次数,适合于有限元仿真和计算流体动力学仿真等高计算成本的应用场合^[4~6]。其主要包括 Kriging 模型、响应曲面设计方法(RSM)、

径向基函数(RBF)、支持向量机(SVM)、最近邻居法(KNN)等^[7]。文献[3]针对磁通切换永磁直线电机,使用 Kriging 模型建立了有效的电机推力预测模型。文献[8]针对双侧线性游标永磁电机,利用 RSM 建立了永磁体宽度等电机结构参数与电机功率因素、平均推力及推力波动的映射关系。文献[9]针对永磁同步电机采用 RBF 建立了电机速度预测模型。文献[10]研究了用于微秒激光切割机的永磁同步直线电机,通过 SVM 建立了电机结构参数(永磁体高度、空气间隙等)与电机平均推力、推力波动和谐波失真率之间的映射关系。文献[11]针对双层反向倾斜线圈的永磁同步直线电机,使用 KNN 建立了电机高精度快速计算模型。

深度神经网络(DNN)是由多层自适应的非线性单元组成,通过逐层学习不断减小模型预测误差,现已在语音声学^[12]、轴承故障诊断^[13]和船舶检测^[14]等回归建模中证明了有效性。文献[15]针对双次级直线电机,使用基于 ReLU 激活函数的 DNN 模型建立了电机结构与电机推力和推力波动的映射关系。在拥有大量样本的情况下,可通过 DNN 中多隐藏层的逐层参数学习来有效提高模型的预测精度^[16]。本文综合使用有限元磁场仿真和 DNN 建立永磁式线性力电机驱动力的预测模型。

1 舵机用永磁式线性力电机原理

1.1 舵机用永磁式线性力电机结构

舵机用永磁式线性力电机主要由端盖、轴承、轴、衔铁、外套等部件及密封圈、螺母、螺钉等标准件组成,如图 1 所示,其中衔铁是其核心零件,以此构成完整的电磁回路。如部件 7,环形磁钢共有 2 块,对称分布在左右两侧;线圈环绕在线圈骨

架之上。

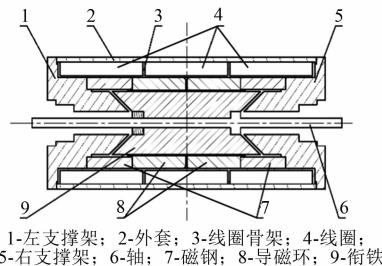


图 1 舵机用永磁式线性力电机简化结构

1.2 永磁式线性力电机驱动力

该永磁式线性力电机的驱动力主要由气隙磁场产生,而气隙磁场由 2 部分产生:(1)由永磁体建立,是气隙磁场的主要部分;(2)由辅助励磁绕组的电流来激励产生,起调节磁场的作用。此外,永磁式线性力电机结构中的支撑弹簧具有失效对中功能,在切断系统输入电流时,其回中力刚度能够克服滑阀摩擦力,从而使阀芯回到中位。输入电流为 0 时,衔铁处于中位,此时左、右工作气隙相等,永磁体的磁势在工作气隙处产生固定磁通且大小相等,且弹簧力为 0,故驱动力为 0。图 2 所示的衔铁偏离中位向左,则弹簧力和固定磁通力的合力向右。如果此时衔铁受力自平衡,即对外的驱动力为 0,需要通电流提供向左的电磁力,继续加大此方向电流,电机就能提供向左的驱动力。反之减小甚至改为反向电流,则电机就能提供向右的驱动力^[1]。

在电机实现碎片剪切功能时,其电磁综合力(即电磁力与固定磁通力的合力)与弹簧力不再平衡,此时衔铁仅受回中方向的弹簧力以及瞬时改变方向的电磁综合力,此电磁综合力和弹簧力的合力即为碎片剪切力。在进行电磁场有限元

仿真和设计时,弹簧力并不是影响因素。并且为了便于测试验收,0 位时的电磁综合力与极限位置的电磁综合力也存在着一定的内联关系。故本文使用 0 位时的电磁综合力来替代碎片剪切力。由于 0 位时电机驱动力中的弹簧力为 0,故此位置的电磁综合力即为电机驱动力。

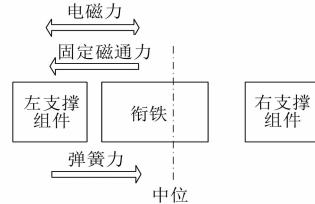


图 2 电机驱动力组成示意^[1]

2 永磁式线性力电机驱动力预测模型建立流程

永磁式线性力电机驱动力预测模型建立流程如图 3 所示。该预测模型建立流程主要包括电机结构参数确定、样本库建立、DNN 模型搭建及精度检验。其中永磁式线性力电机结构参数确定包括:ANSOFT 有限元电磁场仿真模型建立以获得其驱动力,并明确其优化目标(足够的电机驱动力)和约束条件(电机外径尺寸恒定),选取关键的电机结构参数(气隙轴向间距、衔铁厚度、气隙角度、磁钢及导磁环厚度);样本库建立是指采用拉丁超立方采样方法和最大最小距离准则,通过 ANSOFT 仿真得到 1 000 组采样数据,作为训练集和测试集用于下一步 DNN 的训练和精度检验;DNN 模型搭建包括转换层关键点的确定、损失函数及激活函数的确定及批标准化算法;精度检验部分是将 DNN 与传统预测模型 RBF 和 Kriging 进行比较,以检验 DNN 模型的准确性。

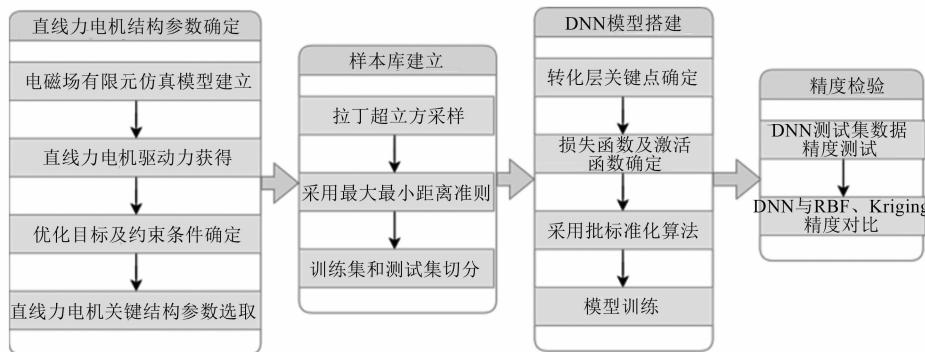


图 3 永磁式线性力电机驱动力预测模型建立流程

3 永磁式线性力电机结构参数的确定

3.1 基于 ANSOFT 的永磁式线性力电机电磁场有限元仿真

研究永磁式线性力电机的结构参数(如气隙宽度等)对电机性能影响时,通常使用 ANSOFT Maxwell 商用低频电磁场有限元软件进行电磁场的仿真^[17]。依据电磁驱动装置的原理,将该永磁式线性力电机简化为二维轴对称图形。图 4 为 0 位时施加极限电流的磁感强度分布图,由图 4 可知左侧气隙磁感应强度大于右侧气隙。此外,由 ANSOFT 仿真结果还能获得衔铁所受合力,该合力即为 0 位极限电流的电磁综合力,也是电机驱动力。

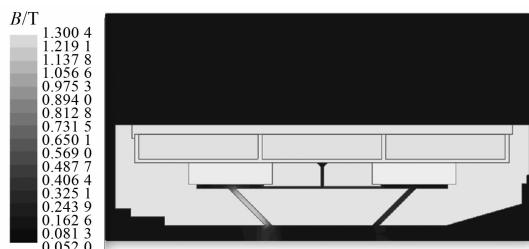


图 4 永磁式线性力电机磁感强度分布图

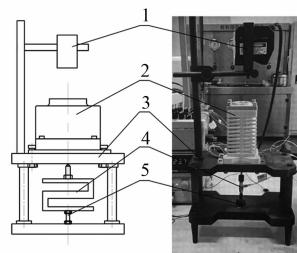
该仿真模型中材料主要分为 3 类:左右支撑架、外套、衔铁和导磁环等软磁材料;磁钢等永磁材料;线圈和骨架等铜类材料。软磁材料 DT4A 的 B - H (磁化)曲线及永磁材料(剩磁和矫顽力)等参数由相关研究所提供。为了防止过大的求解区域造成计算成本增加,仿集中引入气球边界条件。

为了验证 ANSOFT 仿真的有效性,要测量电机 0 位极限电流下的电磁综合力,其测试装置结构简图如图 5 所示。利用拉压力传感器测量电磁综合力,利用激光传感器测量位移使电机衔铁处于 0 位,电机衔铁位置用螺纹机构调节。

相关研究所提供的 3 组试验数据。对比仿真模型结果和试验测试值之间误差在 15% 以内,如图 6 所示。分析后认为仿真值与试验值之间的误差一方面来源于电机的材料及热处理影响;另一方面来源于所用拉压力传感器精度不高带来的测量误差。

3.2 永磁式线性力电机关键结构参数的选取

本文中电机结构外径尺寸不变,电机轴向尺



1-激光传感器; 2-电机; 3-夹具; 4-拉压力传感器; 5-螺纹机构

图 5 永磁式线性力电机电磁综合力测试示意与测试

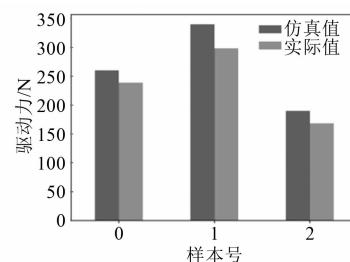


图 6 仿真有效性对比

寸可微调,其微调是通过改变电机内各个零件(包括衔铁、左右支撑架、磁钢、导磁环及线圈骨架,如图 1 所示)的尺寸及位置等参数实现的。故永磁式线性力电机结构的关键结构参数^[18]如图 7 所示,其中 δ 代表气隙轴向间距; R_1 代表衔铁厚度; α 代表气隙角度; R_2 对应着衔铁厚度、磁钢及导磁环厚度及其间的缝隙高度之和。 R_1 不变时, R_2 的变化能够代表磁钢及导磁环的厚度。永磁式线性力电机关键结构参数初始值及选取范围如表 1 所示。

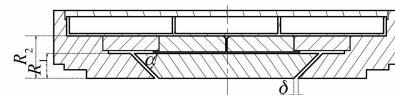


图 7 永磁式线性力电机结构的关键结构参数

表 1 永磁式线性力电机的关键结构参数

名称	初始值	选取范围
气隙轴向间距 δ /mm	1.5	0.8~2.5
衔铁厚度 R_1 /mm	12.8	10~15
气隙角度 α (°)	45	30~90
磁钢及导磁环厚度 R_2 /mm	19	18~23

4 样本库建立

根据表 1 确定的关键结构参数, 使用 ANSOFT 有限元仿真其电机驱动力, 如果采用 4 因素 5 水平的变量就会有 1 024 种组合方式。考虑到获取代表性良好的抽样点是建立其预测模型的基础, 为此应尽可能使抽样点均匀分布于整体抽样空间。拉丁超立方采样^[19]提供了一个非常有效而实用的小样本采样技术, 已广泛应用于具有随机输入变量的复杂分析模型的统计和概率分析, 是一种生成准随机采样分布的统计方法。假设输入数据为 m 维, 需要采样 n 个样本, 传统拉丁超立方采样步骤如下:

- (1) 将每个维度均分为 n 个等分的取样空间;
- (2) 在每个维度的 n 个小区间内分别随机取一个点;
- (3) 依次从每个维度中随机抽取步骤 2 中选取的点, 将这些点组成向量即为 1 个抽样样本。所有的点均随机组合完成后即可获得 n 个样本。

传统的拉丁超立方设计的样本点均为随机取得, 因而会存在一些空间填充度较低以及两两因素间的相关性过大的问题^[20]。使用优化准则替代步骤 3 中的随机组合, 可以让样本点在设计空间中分散开, 使每一个样本点均能够充分描述样本空间性能。优化准则包括最大最小距离准则、 ϕ_p 准则、后验熵准则和中心 L_2 偏差准则等^[21]。其中常用最大最小距离准则, 即最大化试验样本点对之间的最小距离, 满足以下条件:

$$\max \{ \min_{1 \leq i, j \leq n, i \neq j} d(x_i, x_j) \} \quad (1)$$

其中

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^m (x_{ik}, x_{jk})^2}.$$

本文使用在最大最小距离准则下的拉丁超立方采样方法采样 1 000 个样本, 其中随机抽取 700 个样本作为训练集, 剩余 300 个样本作为测试集。抽样点分布示意图如图 8 所示, 将采集到的 1 000 个样本投影到 6 个平面中, 获取的抽样点在各投影平面内均保持有良好的均匀性与随机性, 即具有良好的空间填充效果。依次观察各幅图的各坐标轴可知, 抽样点在各因素取值区间内划分的各小区间上均有分布, 即具有良好的边界分布效果。

— 76 —

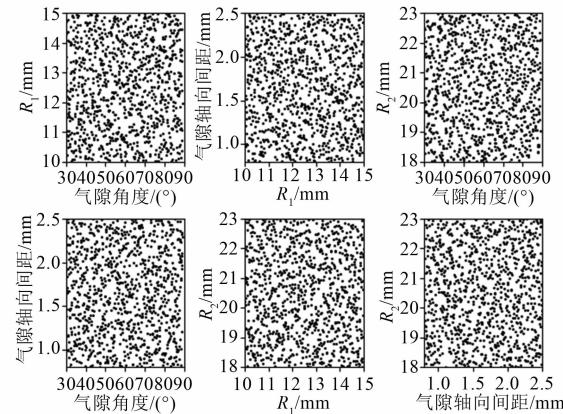


图 8 抽样点分布示意图

5 DNN 模型搭建

5.1 DNN 的结构

神经网络一般分为输入层、隐藏层和输出层, 对于 DNN 来说隐藏层不止一层, 相对于浅层神经网络来说能够为复杂非线性系统提供建模, 多出的隐藏层为模型提供了更高的抽象层次, 因而提高了模型拟合的能力^[22]。如图 9 所示, 本文使用的 DNN 模型为全连接神经网络, 输入层有 4 个神经元, 分别表示气隙轴向间距 δ 、衔铁厚度 R_1 、气隙角度 α 、磁钢及导磁环厚度 R_2 。隐藏层负责特征提取, 每一层均可以表示为权重与神经元的向量相乘再加上偏置。输出层负责输出最后结果, 只有一个节点表示电机输出力。相对于传统的 DNN 结构^[16], 本文所使用的 DNN 在输入层与隐藏层之间增加了转换层, 负责将输入特征转化为实际电机结构的点坐标。如果没有转换层, 整个神经网络将只从这 4 个输入特征中学习, 无论增加模型的复杂度还是增加样本数, 模型学习到的特征总是这 4 个特征的组合, 其预测精度很难得到进一步的提升。如图 10 所示, 这 4 个结构参数经过转换层后被转化为 45 个关键点的坐标, 如图中 31 个圆点和 7 个方块点所示, 其中方块点代表重合点, 考虑到电机结构使用的是简化二维模型, 对应着 90 个输入参数。此外还包括 3 个线圈和 2 个磁钢的长和宽如图中深黑色标识的边 (10 条), 共计 100 个输入参数。由于神经网络在训练中能够自动学习并区分特征的重要性, 模型可以从更多地特征中组合出新的高维特征, 从而提高模型

精度。

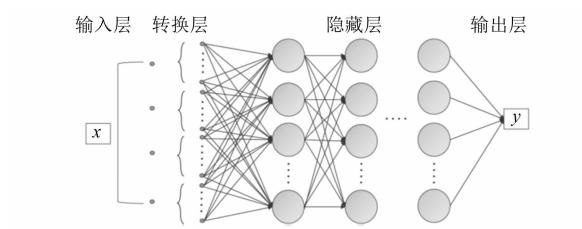


图 9 DNN 结构

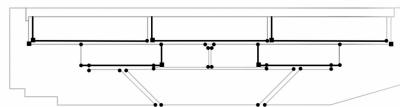


图 10 转化层关键点选取规则

本文采用 PyTorch(1.7.1 版本)机器学习框架搭建和训练 DNN 模型。优化器采用自适应矩估计优化(Adam)算法;隐藏层激活函数采用参数化修正线性单元(PReLU)函数^[23],其数学表达式如下:

$$\text{PReLU}(x) = \begin{cases} x, & x \geq 0 \\ ax, & x < 0 \end{cases} \quad (2)$$

PReLU 是一个带有参数 α 的 ReLU 函数,当参数 α 为 0 时,PReLU 会退化为 ReLU;如果 α 是一个很小的固定值,则 PReLU 退化为 LReLU。由此可见 PReLU 可以自适应地学习 ReLU 的参数从而提高预测准确率。

对于回归问题,损失函数一般使用均方根误差即 L_2 损失函数或者平均绝对值误差即 L_1 损失函数。 L_2 损失函数计算预测值与真实值之间距离的平方和,给予离群样本较大的权重,预测模型会以牺牲其他样本的误差为代价,朝减小离群样本误差的方向更新,最终降低模型的整体性能。 L_1 损失函数计算目标值和预测值之差的绝对值之和,相对于 L_2 损失函数来说,没有给予离群样本较大的权重,因此对于离群样本拥有更好的鲁棒性,但是 L_1 损失函数大部分情况下梯度相等,这意味着即使对于小的损失值,其梯度也是大的,不利于函数的收敛和模型的学习^[24]。本文使用 SmoothL1Loss 损失函数,其数学表达式如下所示:

$$\text{loss}(x, y) = \frac{1}{n} \sum_i z_i \quad (3)$$

其中,

$$z_i = \begin{cases} 0.5 \times \frac{(f(x_i) - y_i)^2}{\beta}, & |f(x_i) - y_i| < \beta \\ |f(x_i) - y_i| - 0.5 \times \beta, & |f(x_i) - y_i| \geq \beta \end{cases}$$

式中: β 为 SmoothL1Loss 损失函数的超参数,其取值与具体应用相关,本文 β 取值为 20。

由上式可见,该损失函数是一个分段函数,相当于 L_1 损失函数与 L_2 损失函数的结合,当预测值和真实值差别较小时使用的是 L_2 损失,解决了 L_1 损失的不光滑问题;当预测值和真实值差别较大时使用的是 L_1 损失,解决了 L_2 损失的离群点梯度爆炸问题。

5.2 DNN 的批标准化

为了控制各隐藏层内神经元的参数波动和提升网络的收敛速率,在 DNN 的每层隐藏层开始计算前,对输入的数据要进行批标准化(BN)^[25] 处理。如图 11 所示,使用批标准化和不使用批标准化的神经网络在训练过程中的训练集损失值变化曲线,可以看出,由于使用小批量梯度下降,每次微批的数据均不一样,批标准化会改变其均值和方差,可以看作引入了噪声,相对于不使用批标准化来说其损失函数的波动更大。使用批标准化可以增加模型的收敛速度,由图 11 可以分析出,在第 200 次迭代后使用批标准化可以让模型收敛到一个更小的损失值。

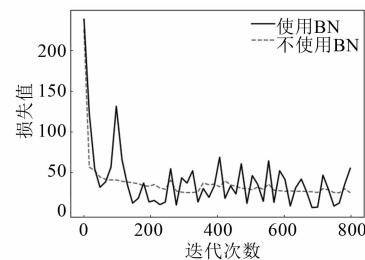


图 11 有无批标准化处理训练集损失函数值的对比

6 DNN 的精度验证

图 12 为 DNN 与传统预测模型(Kriging 和 RBF)的结果对比。其中 Kriging 模型是一种插值模型,能同时给出未知函数的估计值,对非线性和多峰函数能很好地近似拟合;RBF 模型是一种局部逼近网络,能够逼近任意的非线性函数,具有良好的泛化能力以及很快的学习收敛速度,但是相

对 DNN 模型只有 1 个隐藏层, 特征学习能力更差, 学习得到的特征对数据没有更本质的刻画。由图 12 可看出, 从测试集中选出前 15 个样本, Kriging 模型对 0、1 和 2 号样本拟合程度较高, 但是对 3~14 号样本拟合程度较差; RBF 实际值与预测值之间的差距比较明显; DNN 模型对 3~14

号拟合程度比 Kriging 模型好。这是因为 DNN 的模型更加复杂, 所以表达能力更强, 能够用来表征更复杂的情况, 对于离群样本有更好的拟合能力。如表 2 所示, 测试集中前 15 个样本的 DNN 模型预测值与仿真模型实际值对比, 模型预测的误差范围大致在 2%~10% 之间。

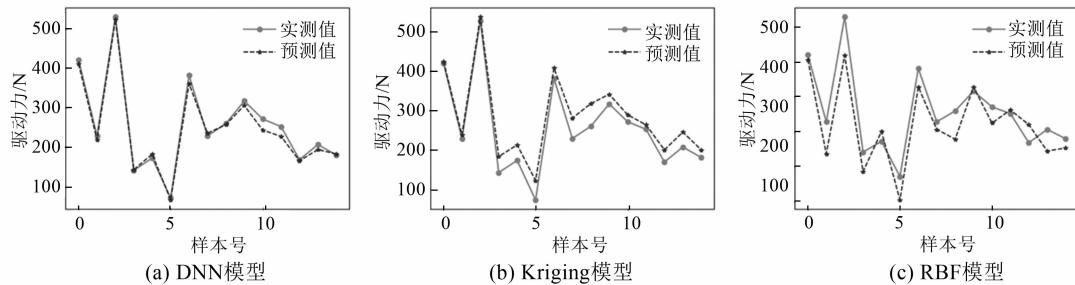


图 12 DNN 与传统预测模型结果对比

表 2 DNN 电机驱动力预测值和仿真值对比

样本号	气隙角度/(°)	R_1/mm	气隙轴向间距/mm	R_2/mm	预测值/N	仿真值/N	误差/N	误差百分比/%
0	67.08	13.19	1.14	20.08	392.08	420.79	-28.71	-6.82
1	88.73	12.41	2.08	22.09	223.15	228.79	-5.64	-2.47
2	73.26	14.09	0.95	20.90	510.39	529.38	-18.99	-3.59
3	76.26	12.88	2.44	18.47	176.88	173.01	3.87	2.23
4	68.99	10.16	2.49	21.54	130.74	143.58	-12.84	-8.94
5	32.95	10.37	1.54	21.96	64.43	72.21	-7.78	-10.78
6	86.76	12.22	1.00	22.84	388.98	381.43	7.55	1.98
7	33.54	14.86	2.48	21.83	224.18	228.88	-4.70	-2.05
8	62.81	14.58	1.34	18.21	275.22	259.92	15.30	5.89
9	69.06	13.51	1.58	19.18	286.96	316.97	-30.01	-9.47
10	80.50	11.82	1.79	19.37	249.51	271.46	-21.95	-8.09
11	60.04	11.49	1.78	21.22	226.05	252.30	-26.25	-10.40
12	72.99	10.54	2.46	19.64	172.32	168.82	3.50	2.07
13	78.48	12.68	2.36	21.43	207.58	207.13	0.45	0.22
14	30.36	12.61	1.92	20.81	164.46	180.38	-15.92	-8.83

通过 DNN 预测了测试集的电机结构参数对应的电机驱动力指标值, 与测试集样本点数据比较后, 计算了均方根误差(RMSE)、平均绝对误差(MAE) 和 R^2 (决定系数), 以此对 DNN 与传统预测模型(Kriging 和 RBF) 模型的预测精度做详细分析。各个指标的计算式如下所示:

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2} \quad (4)$$

$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m |\hat{y}_i - y_i| \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (\hat{y}_i - y_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (6)$$

其中, $\bar{y}_i = \frac{1}{m} \sum_{i=1}^m y_i$

如图 13 和表 3 所示,对于 MAE 来说,DNN 模型对应的值较低,意味着其拟合精度较高。对于 RMSE 来说,DNN 模型比传统模型低了接近一半,由于均方根误差对较大的残差更敏感,说明 DNN 模型的残差波动更小,符合图 12 的分析结果。决定系数 R^2 反映模型拟合优度,用来评价回归模型的优劣,该值越接近 1 说明模型拟合程度越高。Kriging 模型和 RBF 模型均低于 0.8,而 DNN 模型的 R^2 高于 0.9,可见其间的精度差距比较明显。

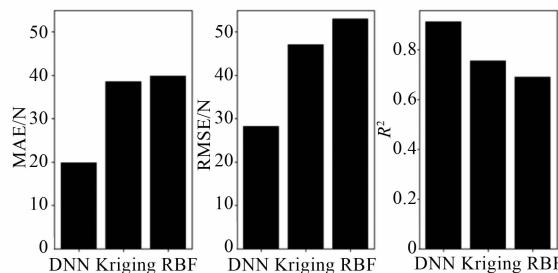


图 13 DNN 与传统模型预测精度对比

表 3 DNN 与传统模型预测精度对比

模型名称	MAE/N	RMSE/N	R^2
DNN	20.95	27.60	0.92
Kriging	38.56	47.10	0.76
RBF	39.81	53.02	0.69

7 结语

本文研究一种基于 DNN 的舵机用永磁式线性力电机驱动力预测模型建立方法,作为后续启发式智能算法优化电机结构参数的代理模型。本文研究内容及结论如下:

(1) 对用于直驱式电液伺服阀的永磁式线性力电机的碎片剪切力分析和 ANSOFT 电磁仿真模型建立的基础上,确定了关键结构参数。

(2) 采用最大最小距离准则的拉丁超立方采样方法,获得较好随机性和均匀性的样本点。

(3) 引入 DNN,基于样本库建立了电机驱动力预测模型。该 DNN 模型应用了 PRuLU 激活函数和 SmoothL1Loss 损失函数,使用 BN 控制各隐藏层内神经元参数的波动和提升网络的收敛速率。

(4) 设置结构参数到关键坐标点的转换层,

增加网络输入的有效特征数量。

(5) 测试表明,与传统的预测模型 Kriging 和 RBF 相比,对于 RMSE、MAE,本文的 DNN 模型表现更好,具有更高的预测精度和稳定性。该 DNN 模型的决定系数大于 0.9,具有较好的拟合优度。

【参考文献】

- [1] 徐礼林.直接驱动舵机用直线力电机的驱动力设计分析[J].液压与气动,2006(5): 83.
- [2] 田源道.电液伺服阀技术[M].北京:航空工业出版社,2008.
- [3] 张邦富,程明,王飒飒,等.基于改进型代理模型优化算法的磁通切换永磁直线电机优化设计[J].电工技术学报,2020,35(5): 1013.
- [4] ZHANG B F, CHENG M, CAO R W, et al. Analysis of linear flux-switching permanent magnet motor using response surface methodology[J]. IEEE Transactions on Magnetics, 2014, 50(11): 8103004.
- [5] TARAN N, IONEL D M, DORRELL D G. Two-level surrogate-assisted differential evolution multi-objective optimization of electric machines using 3-D FEA[J]. IEEE Transactions on Magnetics, 2018, 54 (11): 8107605.
- [6] JOUHAUD J C, SAGAUT P, MONTAGNAC M, et al. A surrogate-model based multidisciplinary shape optimization method with application to a 2D subsonic airfoil[J]. Computers & Fluids, 2007, 36(3): 520.
- [7] WANG G G, SHAN S Q. Review of metamodeling techniques in support of engineering design optimization[J]. Journal of Mechanical Design, 2007, 129(2): 370.
- [8] ZHAO W X, MA A Q, JI J H, et al. Multiobjective optimization of a double-side linear vernier PM motor using response surface method and differential evolution [J]. IEEE Transactions on Industrial Electronics, 2020, 67(1): 80.
- [9] 柳海科,袁忠于,曹奔,等.基于 RBF 神经网络的永磁同步电机预测控制[J].兰州交通大学学报,2019,38(5): 90.
- [10] SONG J C, DONG F, ZHAO J W, et al. A new design optimization method for permanent magnet synchronous linear motors [J]. Energies, 2016, 9 (12): 992.
- [11] 汪伟涛,赵吉文,宋俊材,等.双层反向倾斜线圈永磁同步直线电机的设计与优化[J].中国电机工程

- 学报,2020,40(3): 980.
- [12] 秦楚雄,张连海. 基于 DNN 的低资源语音识别特征提取技术[J]. 自动化学报,2017,43(7): 1208.
- [13] 温江涛,同常弘,孙洁娣,等. 基于压缩采集与深度学习的轴承故障诊断方法[J]. 仪器仪表学报,2018,39(1): 171.
- [14] TANG J X, DENG C W, HUANG G B, et al. Compressed-domain ship detection on spaceborne optical image using deep neural network and extreme learning machine [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 53 (3): 1174.
- [15] WANG W T, ZHAO J W, ZHOU Y, et al. New optimization design method for a double secondary linear motor based on R-DNN modeling method and MCS optimization algorithm [J]. Chinese Journal of Electrical Engineering, 2020, 6 (3): 98.
- [16] 杨阳,赵吉文,宋俊材,等. 基于深度神经网络模型的无铁心永磁同步直线电机结构优化研究[J]. 中国电机工程学报,2019,39(20): 6085.
- [17] 穆玉康,苏琦,徐兵,等. 直驱式电液伺服阀用线性力马达耐高温优化设计[J]. 北京理工大学学报,2020,40(5): 477.
- [18] 师今卓,白志红,熊光煜. 永磁直线力电机的特性计算[J]. 微特电机,2005(5): 8.
- [19] HELTON J C, DAVIS F J. Latin hypercube sampling and the propagation of uncertainty in analyses of complex systems [J]. Reliability Engineering & System Safety, 2003, 81 (1): 23.
- [20] KE L, QIU H B, CHEN Z Z, et al. Engineering design based on hammersley sequences sampling method and SVR [J]. Advanced Materials Research, 2012, 544: 206.
- [21] 黄靓,易伟建,汪优. 最优实验设计的改进随机进化算法[J]. 计算机工程与应用,2008(27): 12.
- [22] 范周伟,余雄庆,王朝,等. 基于深度神经网络模型的客机总体主要设计参数敏感性分析[J]. 航空学报,2021,42(4): 378.
- [23] HE K M, ZHANG X Y, REN S Q, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification [C]//Proceedings of the IEEE International Conference on Computer Vision, 2015: 1026.
- [24] GIRSHICK R. Fast R-CNN [C]//Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440.
- [25] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]//International Conference on Machine Learning, 2015: 448.

(上接第 66 页)

- [5] 范庆锋,王光晨. 转子不同方式分段斜极对永磁同步电机噪声的影响[J]. 电机与控制应用,2020,47(9): 79.
- [6] WANG C, BAO X, SHENG X, et al. Analysis of vibration and noise for different skewed slot type squirrel-cage induction motor[J]. IEEE Transactions on Magnetics, 2017, 53(11): 8206006.
- [7] 陈永校,诸自强. 电机噪声的分析和控制[M]. 杭州: 浙江大学出版社,1987.
- [8] VAGATI A, CANOVA A. Design refinement of synchronous reluctance motors through finite-element analysis [J]. IEEE Transactions on Industry Applications, 2000, 36(4): 1094.
- [9] VAGATI A, PASTORELLI M, FRANCHESCHINI G, et al. Design of low-torque-ripple synchronous reluctance motors[J]. IEEE Transactions on Industry Applications, 2002, 34(4): 758.
- [10] 钱喆,唐光华,王群京,等. 转子结构优化削弱车用永磁同步电机振动噪音[J/OL]. 电机与控制学报, <http://kns.cnki.net/kcms/detail/23.1408.tm.20210415.1100.010.html>.