

DOI:10.3969/j.issn.1003-5060.2026.05.006

基于贝叶斯优化学习模型的 电励磁同步电机控制方法研究

秦学丰¹, 李国丽², 刘方², 李泽华²

(1. 埃尔朗根-纽伦堡大学 电力电子信息学院, 德国 埃尔朗根 91058; 2. 安徽大学 电气工程与自动化学院, 安徽 合肥 230601)

摘要:电励磁同步电机(electrically excited synchronous motor, EESM)可通过相电流的精确控制来输出期望的输出扭矩和角速度。与离线方法相比,基于机器学习的在线控制方法具有实时性好、准确性高和控制模型复杂度低的优点,但存在参数数量多、设置难的问题。文章提出一种基于贝叶斯优化(Bayesian optimization, BO)学习模型的电励磁同步电机控制方法,采用BO中的熵搜索和期望提升方法对模型自动调参。结果表明:所提方法能够实现学习模型参数的自动调节,提高了学习模型的精确度,有效减少重复试验次数;在大样本量训练下,与高斯过程相比,神经网络精确性更高、时间复杂度更低,但内存占用更多;在小样本量训练下,高斯过程精确性更高、计算成本与神经网络相差不大,内存占用更少。

关键词:电励磁同步电机;参考电流;机器学习;高斯过程回归(GPR);神经网络;贝叶斯优化(BO)

中图分类号:TP181

文献标志码:A

文章编号:1003-5060(2026)05-0613-08

Research on control method of electrically excited synchronous motor based on Bayesian optimization learning model

QIN Xuefeng¹, LI Guoli², LIU Fang², LI Zehua²

(1. Department of Electrical Engineering, Friedrich-Alexander-Universität Erlangen-Nürnberg, Erlangen 91058, Germany; 2. School of Electrical Engineering and Automation, Anhui University, Hefei 230601, China)

Abstract: An electrically excited synchronous motor(EESM) can achieve the desired torque and angular velocity by precisely controlling the phase current. Compared to offline methods, machine learning-based online control methods have advantages such as real-time performance, high accuracy, and low model complexity. However, they face challenges related to a large number of parameters and difficulties in setting them. Therefore, this paper proposes an EESM control method based on the Bayesian optimization(BO) learning model. This method utilizes entropy search and expectation enhancement techniques in BO to automatically adjust the model parameters. Simulation analysis results demonstrate that the proposed method can achieve automatic adjustment of the learning model parameters, improve the accuracy of the learning model, and effectively reduce the number of repeated experiments. Furthermore, the comparison results indicate that when the training sample size is large, neural networks outperform Gaussian processes in terms of accuracy and time complexity, but they require more memory. On the other hand, when the training sample size is small, Gaussian processes exhibit higher accuracy, similar computational costs to neural networks, and lower memory usage.

Key words: electrically excited synchronous motor(EESM); reference current; machine learning; Gaussian process regression(GPR); neural network; Bayesian optimization(BO)

收稿日期:2024-01-17;修回日期:2024-03-04

基金项目:国家自然科学基金区域创新联合基金重点资助项目(U23A20647)

作者简介:秦学丰(1997—),男,安徽全椒人,埃尔朗根-纽伦堡大学硕士生;

李国丽(1961—),女,江苏泰州人,博士,安徽大学教授,博士生导师,通信作者,E-mail:liguoli@ahu.edu.cn.

0 引言

电励磁同步电机(electrically excited synchronous motor, EESM)在整个转速区间内都有良好的运行效率,近些年在电动汽车领域应用广泛^[1-3]。与永磁电机相比,EESM 减少了稀土元素的使用,有效地减轻了国内稀土储量的压力,降低了制造成本^[4]。转子的可调节磁通量代表了额外的自由度,使得 EESM 能够以节能且灵活的方式实现所需的扭矩^[5]。可根据 EESM 的期望输出扭矩及角速度计算出相应的参考电流,输出扭矩控制可通过磁场定向控制来实现。参考电流控制法使 EESM 在最大限度考虑诸多物理限制的同时,铜损耗达到最小,EESM 的输出扭矩得到精确控制^[6]。参考电流一般通过查表法^[7]、有限元方法(finite element method, FEM)^[8],并结合决策树的数值优化问题^[6]离线获得。

查表法主要使用离线实验,获得测试 EESM 在不同转子位置处的电流和电压来计算离散的磁链和扭矩,拟合出相对于电流和转子位置的扭矩函数,从而计算不同扭矩下的参考电流。文献[7]提出一种基于拉格朗日乘子的代数查表法,在转速和扭矩的限制下计算出产生最小铜损的参考电流,并存储在查找表中。查找表可以加载到嵌入式处理器中即插即用,也可以在移动端远程控制。文献[9]提出一种基于强化学习的查找表生成方法,从运行数据中学习合适的参数以及对应的电流,组成查找表。这种方法具有更快的收敛特性和更高的识别分辨率。但是作为一种离线方法,在约束较多时,例如增加接近期望扭矩的约束时,难以在 EESM 运行时即时灵活在线计算多种条件、约束下的参考电流^[10-11]。

有限元方法(FEM)根据所设计的永磁同步电动机的结构参数,建立 EESM 的三维有限元电磁场仿真模型,离线计算参考电流^[8]。这种方法可以尽可能多地考虑如交叉饱和与铁损耗的具体限制。有限元计算需要专业软件的支持,这些软件对计算资源需求较高。因此这种方法难以迁移到单片机等工控设备上。

通过求解带条件约束的数值优化问题也可以计算参考电流^[6]。通过最大电流、电压以及励磁电流等物理条件的约束,分成多种情况组成决策树在线求解参考电流。然而随着模型假设逐渐完善,物理条件和约束作为控制系统的输入通道会相应增多,决策树将会更加复杂,而模型的空间大

小也会增加,使得运行时的内存需求增大。一定程度上影响了参考电流的在线计算速度和计算成本。

与前述 3 种离线方法相比,基于机器学习的在线方法,可在脱离原有物理模型和约束条件的基础上,实现期望扭矩和转速所需参考电流的快速、精准预测。离线方法在精确性上必然高于拟合观测集生成的学习模型,然而随着学习模型精度提升,预测误差也会缩小至可接受的范围。在一些对实时性和设备计算性能受限的场景下,简化的模型空间结构和稳定的时间复杂度相较于精确性更为重要。因此,机器学习近年来被多数学者引入到 EESM 的控制方法研究中。文献[10]利用神经网络训练观测集,生成预测参考电流的模型,并将其加载到 EESM 的控制系统。测得的扭矩、转速作为观测集的输入,与其他物理约束计算出的参考电流作为输出^[10-11]。但超参数对学习模型的准确建立影响较大,偏差较大的参数会严重影响模型性能。

现有研究中模型超参数的设置一般通过最大对数似然或经验确定。然而,最大对数似然虽然能够实现精确求解^[12-13],但在模型观测集样本较大的情况下计算效率较低,且求解多峰、非凸非凹的复杂函数可能出现不合理的解^[14]。

针对上述问题,本文提出了一种基于贝叶斯优化(Bayesian optimization, BO)的学习模型的电励磁同步电机的控制方法,研究并设计了一种基于高斯过程回归(Gaussian process regression, GPR)和卷积神经网络(convolutional neural network, CNN)的 EESM 控制方法,离线训练采样观测集,在线预测参考电流。结果表明,本文所提方法减少了系统的输入数量,使控制模型结构大大简化,模型结构和时间复杂度不受外部物理约束条件的影响。使用 BO 算法自动优化学习模型中的超参数,有效减少了超参数调节的工作量,也提高了模型和超参数估计的精确性,还有效地搜索超参数空间,优化采样过程。同时对 2 种机器学习方法在不同样本量情况下的性能进行对比研究。

1 基于 BO 的 EESM 控制模型

1.1 EESM 电流控制原理

EESM 的控制系统框图如图 1 所示。图 1 中:电压 U_{DC} 为整个系统的输入,通过电压源逆变器(voltage source inverter, VSI)转换为三相电流

$i_{a,b,c}$, 传输到 EESM 中进行控制; i_e 为励磁电流; 转矩 T 、角速度 ω 等测量值作为 EESM 和整个系统的输出, 并作为学习模型的输入。




图1 EESM 控制系统结构框图

学习模型 $[f_d, f_q, f_e]'$ 作为观测器被加载到控制系统中。EESM 在运行时的输出数据 T 和 ω 等作为模型输入, 可输出参考电流 $i_{d,q,e}^*$ 作为反馈值。EESM 中的三相电流 $i_{a,b,c}$ 经过派克变换成 $d-q$ 轴电流 $i_{d,q,e}$, 与模型输出的参考电流 $i_{d,q,e}^*$ 相结合, 由控制器调节参考电压 $u_{d,q,e}^*$ 输入到 VSI 中。从而控制 VSI 输出新的三相电流 $i_{a,b,c}$, 以控制 EESM 实现期望输出扭矩和损耗。

1.2 BO 理论

BO 通过迭代搜索目标函数的最小值, 由目标函数 $f(x_t)$ 和获得函数 $\alpha_t(x_t)$ 两部分组成, x_t 为 t 次迭代时的模型的超参数, 通过求解获得函数的极大值来搜寻下一个采样点。目标函数往往作为未知的黑盒函数, 无法通过常规的梯度下降法求解最优值, 并且计算目标函数的时间成本较大, 使用网格搜索和随机搜索求解的代价较高。通常使用高斯过程等代理函数来代替目标函数, 对初始选取的点进行拟合。而采样函数则是在当前代理函数的基础上, 使下一步的 x_{t+1} 获得最大收益^[14]。不同的 BO 方法使用不同的采样函数。

通常 BO 过程为: ① 初始化代理函数的先验分布; ② 选择数据点 x_t , 使得采集函数 $\alpha_t(x_t)$ 取得最大值; ③ 在目标函数 $f(x_t)$ 中评估数据点, 并获取其结果 $y_t = f(x_t)$; ④ 使用新数据 (x_t, y_t) 更新代理函数, 得到后验分布, 作为下一步的先验分布; ⑤ 重复步骤②~④, 直到最大迭代次数。

1.3 基于机器学习的模型构建

模型学习、构建并预测的过程如图 2 所示。图 2 中: 上方部分表示通过观测集训练并产生相互线性独立的模型 $[f_d, f_q, f_e]$ 的过程, 观测集分为模型的输入 $[T, \omega]$ 和输出 $[i_d, i_q, i_e]$, 由测量或

由其他离线采样而得的数据构成, 输入、输出分别相互线性无关; 下方部分表示模型 $[f_d, f_q, f_e]$ 对新的输入数据 T^* 和 ω^* 等预测新的参考电流 $[i_d^*, i_q^*, i_e^*]$ 的过程, 用以测试模型的预测性能。




图2 模型学习、预测过程示意图

基于机器学习的模型由观测集直接训练而成, 对非线性的、不确定的黑盒物理模型进行拟合。学习模型嵌入到控制系统中, 使整个系统只需提供 EESM 所需得电压源, 而无需连接外部的物理约束(如最大电流、电压限制等), 简化系统结构, 有效降低了系统的复杂程度。文献[15-16]采用的基于神经网络的学习模型优化原有系统, 能够兼具精确性和良好的动态性能。

2 仿真分析

2.1 观测集的构建

学习模型 $f_{d,q,e}(T, \omega)$ 的输入值由 EESM 输出的转矩 T 和角速度 ω 组成, 参考电流 I_{opt} 作为模型的输出值^[5]。在给定范围内均匀采样获得, 经过仿真模型求解后输出观测集。

$$I_{opt} = \arg \min_{i_{d,q,e}} (T(i_{d,q,e}; L) - T_{des})^2 \quad (1)$$

$$\text{s. t.} \quad i_d^2 + i_q^2 \leq I_{max}^2 \quad (2)$$

$$U(i_{d,q,e}, \omega; R, L) \leq U_{max}^2 \quad (3)$$

$$0 \leq i_e \leq \hat{I}_{e,max} \quad (4)$$

其中, 转矩 T 由输入到 EESM 的电流 $i_{d,q,e}$ 及 EESM 等效电感 L 得到, $d-q$ 轴上输入电流 $[i_d, i_q]$ 、励磁电流 i_e 和系统输入的直流电压 U 应分别在相应的最大电流 I_{max} 、 $\hat{I}_{e,max}$ 和最大电压 U_{max} 的限制内。这组参考电流使 EESM 的输出转矩 T 最

接近期望转矩 T_{des} , 但实际情况下并非唯一解。为确保能够获取唯一确定的参考电流, 在以上一组解 I_{opt} 的基础上, 选择可产生最小铜损耗 P_{Cu} 的电流 $i_{d,q,e}^*$, 作为观测集和学习模型输出值的参考电流, R 为 EESM 等效欧姆电阻。

$$i_{d,q,e}^* = \arg \min_{i \in I_{\text{opt}}} P_{\text{Cu}}(i; R) \quad (5)$$

对这些给定范围内的输入变量, 沿每个轴等间距采样 n 个数据, 形成一组网格状的输入数据, 如图 3 所示。图 3 中, 红色点为实际采样数据, 输入、输出均作为数值优化模型中所用的数据来源。采样后的数据大小为 n^m , 总采样时间 T_z 为:

$$T_z = T_s N_{\text{samp}}^m - T_s \quad (6)$$

其中: N_{samp}^m 为采样数据个数; T_s 为采样间隔时间, 一般取 1×10^{-3} s; m 为输入维度, 本文取 $m=2$ 。




图 3 采样点形成的观测集分布

高斯过程充分利用所有的观测数据通过构建核函数矩阵的方式建模。在计算中矩阵作为模型的核心被全部加载到运行内存中, 其大小为:

$$S(n, m) = \frac{(n^m)^2 \times 8}{1\ 024^3} \quad (7)$$

其中内存单位为 kiB。考虑到计算机的内存限制, 其矩阵占用内存空间大小不应超过总内存的 70%, 本文所使用的计算机内存为 16 GiB。经计算, 即每个输入维度采样数量 n 应当小于 150。

观测值采样范围见表 1 所列。采样数据用来进行训练的数据量见表 2 所列。

表 1 采样数据范围

输入特征值	最小值	最大值
转矩/(N·m)	0	200
角速度/(rad/s)	0	5 000

观测集分为大小 2 种规模的样本, 用于

2 种方法在不同规模数据中的性能差异的对比研究。测试集采用相同的数据用以对比, 数据由随机采样获得, 总量为 64 个, 每个维度采样 8 个数据。

表 2 采样数据量

观测集	采样数	维度	数据总量
小样本量	8	2	64
大样本量	100	2	10 000

由表 1 可知, 采样数据的范围由于单位的不同差异很大, 增加了训练难度。因此, 对原先的数值优化模型中的输入、输出变量进行归一化处理: $x_0 = x/x_B$, x 为原变量, x_B 为参考值, 这里设为采样范围的最大值^[3]。

考虑到高斯过程中观测集中每组特征都应符合高斯分布的假设, 因此输入输出的每个维度都有自己的分布, 可通过标准化使所有特征向量的均值和方差分别维持在 0 和 1, 即

$$\frac{x - \mu_0}{\sigma_0} = X_{\text{Stand}} \sim (0, 1) \quad (8)$$

其中: μ_0 和 σ_0 分别为原数据的均值和方差; x 和 X_{Stand} 分别为在标准化前、后的样本值。在训练和预测完成后, 应当将输出数据(即计算出的参考电流)还原, 以分析其误差对 EESM 实际工况的影响。

2.2 EESM 仿真模型参数设置

由参考电流的求解模型(1)、(2)可知, 参考电流的确定与转矩、转速直接相关, 定子上的电感 L 和欧姆电阻 R 作为方程中的给定参数提前设置。

2.2.1 电感

电感在 EESM 上等效成 $d-q$ 轴电流对应的自感 L_d 、 L_q 和互感 L_m 。等效电感会随着 EESM 运行的变化而变化, 一般无法直接测量, 难以得出解析解。目前一般通过查表法、有限元法和最小二乘法估计电感值^[17-18]。在实际应用中, 也可以根据电机制造商所提供的数据设置电感值。

2.2.2 电阻

文献[17, 19]给出了定子上的电阻与温度的变化, 其关系式如下:

$$R = R_{\text{ref}}[1 + \alpha_{\text{Cu}}(T_0 - T_{\text{ref}})] \quad (6)$$

其中: R_{ref} 和 T_{ref} 分别为电阻和温度的参考值; α_{Cu} 为温度系数; T_0 为 EESM 运行时的温度。从式(6)可以看出, 电阻 R 仅与温度有关, 为简化计算, 一般可假设工作温度变化范围小, 即电阻为固定参数。

2.2.3 噪声变量

数值模型可作为一种“确定性模型”^[20],其观测集数据与噪声数据无关,噪声数据在实验中衡量模型的可变性。为简化模型,不考虑噪声数据。

另外,在高斯过程模型中,为更稳定地计算核函数矩阵 $\mathbf{K}$ 的逆 $\mathbf{K}^{-1}$,避免核函数矩阵的值 $|\mathbf{K}|$ 等于或接近于 0,导致奇异解,可在计算完成的核函数矩阵后加入一个小变量构成的单位矩阵 $\sigma_n \mathbf{I}$,以使核函数矩阵恒为正定矩阵^[12]。

2.3 模型参数设置

贝叶斯优化选择常用的期望提升方法(expectation improvement, EI)^[21]。此外,针对 GPR 方法的优化,本文还引入了熵搜索方法(entropy search, ES)^[22]。基于高斯过程和卷积神经网络 2 种方法的参数设置分别见表 3、表 4 所列,神经网络的结构设计见表 5 所列,包含了各层的功能、深度及其规模。

表 3 GPR 模型的参数选择与设置

参数选择	参数数值设置
“KernelFunction”	“ardsquardexpotential”
“ComputationMethod”	“QR”
“FitMethod”	“none”
“PredictMethod”	“sd”
“Sigma”	1E-3
“DistanceMethod”	“accurate”

表 4 CNN 模型的参数选择与设置

参数选择	小样本观测集	大样本观测集
验证集比例/%	10	15
“numFilter”	16	16
“InitialLearnRate”	0.01	0.001
“Momentum”	0.9	0.9
“GradientDecayFactor”	0.9	0.9
“L2Regularization”	0.000 1	0.000 1
“miniBatchSize”	2	8
“validationFrequency”	28	50

表 5 CNN 模型结构设计

层编号	层类型	深度或大小
1	图像输入	$m \times n \times 1$
2	卷积层	16
3	ReLU 层	1
4	卷积层	16
5	全连接层	200
6	ReLU 层	1
7	全连接层	200
8	全连接层	1
9	回归层	1

高斯过程和卷积神经网络由训练学习模型并进行测试。作为对照,使用贝叶斯优化中的 EI 和 ES 方法优化上述 2 种模型,相关参数说明分别详见文献[22-23]。然而在大样本(10 000 组)观测集中,由于采样数据密度过大,会出现 ES 方法无法计算的情况。

2.4 运行环境

模型运行的计算机配置见表 6 所列。为考察 2 种机器学习方法训练的稳定性和模型平均性能,每种观测集重复训练每个模型 10 次,分析这 10 次误差。在运行前应当清空 MATLAB 中的所有内存。模型空间受其结构复杂度(如 CNN 层结构)、参数及超参数数量的影响。因此每种模型的多次运行结果相差不大,本文选取这 10 次结果的均值进行比较。

表 6 计算机配置

设备	配置	版本
CPU	Core (TM) i7-7700 @3.60 GHz	核数 8
内存	容量 16 GiB	
显卡	Intel (R) HD Graphics 630	显存大小 7.9 GiB
软件	MATLAB	R2022 b 64-bit

3 模型性能评价

基于机器学习的模型首先应当保证预测结果的精确性,即软件层面的性能。当模型预测结果的精确性在满意的范围内时,再评估硬件层面上的性能,即计算效率和资源占用率。

3.1 预测结果的精确性

同一个误差值对不同数量级的预测结果影响不同,如参考电流 i_d^* 在还原成原单位后,范围为 $[-186.6, 108.2]$ A,则数量级的变化为 $[10^0, 10^2]$ 。采用平均绝对百分比误差(mean absolute percentage error, MAPE)以比例方式清晰展示误差在不同数量级的影响^[24],其表达式为:

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \frac{\delta_i}{y_1} = \frac{1}{n} \sum_{i=1}^n \frac{\hat{y}_1 - \hat{y}_i}{\hat{y}_1} \times 100\% \quad (9)$$

其中: δ_i 为测试结果和测试集中的真实输出的误差; $\hat{y}_1$ 为真实值输出; y_i 为预测值输出。特别地,当 $\hat{y}_1$ 为 0 或一个极小值时,应将其剔除,避免结果出现极值^[25]。

当 MAPE 在 5% 以内时,本文认为其满足精确度的要求;当 MAPE 略微超过 5%,即在 8% 以内

也可以视为满足要求。

小样本(64 个观测值)和大样本(10 000 个观测值)观测集所训练的模型精确度情况如图 4、图 5 所示,以 d - q 轴上的参考电流的预测误差 MAPE 表示。




图 4 使用小样本观测集预测结果的精确度

由图 4a、图 5a 可知, d 轴电流 i_d^* 随输入变化的波动较复杂,因此预测所需的数据数量大,预测误差大于 i_q^* 和 i_e^* 。另外 2 组电流 i_q^* 和 i_e^* 随输入变化平稳增加,所有模型预测效果良好。贝叶斯优化模型在电流 i_q^* 和 i_e^* 中均优于未经优化的模型,其中由 EI 优化模型均能保持满意的准确率,并且有最精准的预测结果。因此后文仅分析各模型对 i_e^* 的预测误差。

由图 4a 可知,在小样本观测集中,只有 EI 和 ES 优化后的 GPR 模型达到合适范围,最优值分别为 7.55% 和 7.86%,均小于 8.00%,且远优于 CNN 训练的模型。ES 优化的 GPR 模型预测误差更稳定,对观测集的拟合更好。这意味着只需

要较少次数的建模试验即可训练出合格的模型,图 4a 中 EI 优化的 GPR 模型,仅 6 个试验可满足要求。由图 5a 可知,随着训练数据的增加,优化后的 GPR 和 CNN 模型精度都达到合适的范围内,而未经优化的 GPR 算法性能较差。结合图 4、图 5,经过贝叶斯优化的模型,训练后的结果都优于未优化的模型。具体统计数值见表 7、表 8 所列。




图 5 使用大样本观测集预测的精度

表 7 小样本量观测集的训练准确度

电流	最精确模型	MAPE/%	其他合格模型
i_d^*	GPR-EI	7.56	GPR-ES
i_q^*	GPR-EI	0.62	全部
i_e^*	GPR-EI	0.64	全部

表 8 大样本量观测集的训练准确度

电流	最精确模型	MAPE/%	其他合格模型
i_d^*	GPR-EI	0.14	GPR-ES,CNN,CNN-EI
i_q^*	GPR-EI	0.04	全部
i_e^*	GPR-EI	0.01	全部

3.2 计算效率

仅当模型精确度在合适范围内时,分析硬件性能才有意义。计算速度由于计算机性能及程序运行时外部环境的不同,运行时间有较大差异。本文采用预测时的时间复杂度来定性讨论2种方法训练的模型的计算效率。

BO并没有改变机器学习算法的结构,仅对GPR核函数的系数、CNN输入的训练批次、卷积层输出通道数等在训练时在线优化。在离线预测时不会改变时间复杂度的数量级,因此,BO在优化精确度的同时,并不会对模型的运行速度有显著影响。

由于需要计算2个核函数矩阵的乘积,基于GPR的模型时间复杂度为 $O(n^3)$,经过Cholesky分解后的时间复杂度为 $O(n^2)$ 。即GPR方法的时间复杂度取决于构成核函数矩阵的观测集个数为 n ,其复杂度为 $O(n^3)$ 。

根据表5中本文设计的CNN的结构,卷积层的时间复杂度为 $O(MKC_{in}C_{out})$,其中, M 和 K 是每个卷积核输出的特征图及卷积核的面积, C_{in} 和 C_{out} 表示卷积核的输入和输出通道数,本文均为1。而 $M \times K$ 远小于观测集数量,复杂度的数量级仅随深度变化,为 $O(n)$ 。全连接层在本文中层数远大于输入维度,复杂度随深度的增加而增加,为 $O(n)$ 。激活函数的复杂度为 $O(1)$ 。即CNN方法的时间复杂度取决于网络中各层的深度 n ,其复杂度为 $O(n^3)$ 。

综上所述,基于CNN的模型主要受其各网络层深度的影响,基于GPR的模型则主要受核函数矩阵空间的影响。在小样本阶段,两者实际计算效率相差较小。随着样本数量的增加,核函数矩阵空间成平方级增长,GPR的计算效率明显降低,而CNN模型中各层层数不随观测集的变化而变化,因此神经网络的计算速度则更加稳定。

3.3 内存占用

在参考电流的计算时,学习模型一般预先被载入到只读存储器中,较小模型可以更好地适应不同的运算平台上,如单片机等内存较小的设备上。各模型自身空间大小见表9所列。

由表9可知,ES方法对空间优化显著,而EI方法虽然在准确度和计算速度上对模型有显著提升,但在一定程度上增大模型空间。

4 结 论

本文提出了一种基于BO学习模型的电励磁同步电机控制方法,采用BO中的熵搜索和期望提升方法对学习模型自动调参。对低维度(2维)样本使用高斯过程和神经网络分别训练观测集,并对模型预测的精确性方面进行对比。结果表明,在少量样本下,高斯过程有更好的训练效果,而当样本数量增加时,神经网络有更好的表现。BO对所有模型都可以在训练阶段自动完成超参数调节,对高斯过程和神经网络都有良好优化效果,且对高斯过程的优化更加显著。ES方法尽管目前无法在高样本密度的情况下使用,但在小样本量数据的训练下有更稳定的精度表现,这使得ES方法在较少的建模试验后取得期望的效果。

在时间复杂度上,学习模型的计算效率主要受超参数的数量以及学习模型的结构(如GPR的核函数矩阵、CNN各功能层与层数)的影响,而逐渐复杂的物理模型约束条件并不会降低学习模型的计算效率。因此,学习模型对于在线拟合动态的黑盒模型能够始终保持良好的实时性。同时,BO不会改变学习模型的结构,因此不会在预测阶段对计算速度上有明显的影响。

在资源占用率方面,当核函数矩阵规模小时,由于神经网络的层数一般较多,其模型空间要比高斯过程模型大。随着样本数量的增加,高斯过程模型的空间也急剧增加,其远大于神经网络的空间。BO中,仅ES优化能有效缩减了高斯过程模型空间,其他优化方法对模型空间的优化并没有帮助,反而略微增加了模型空间,给模型的兼容带来了一定的阻碍。

由于高斯过程中的核函数矩阵对观测集大小的限制,出于对比的需要,本文仅给出了最高达10 000组观测集对模型进行训练。对于神经网络模型的预测能力,可在后续研究中增加观测集大小,以检测学习模型对大量数组的预测性能。

本文在仿真环境中验证了学习模型的可行性。后续研究中,可将模型应用于真实电机上,以检验该模型在真实环境下的实际性能。此外,为验证模型对不同运算平台的适应能力,今后可将模型迁移至单片机等嵌入式设备上进行测试。

表9 模型空间大小

单位:KiB

观测集	GPR	GPR-EI	GPR-ES	CNN	CNN-EI
小样本	22.1	36.8	1.9	179.0	162.0
大样本	15 155.2	15 155.2		149.0	198.0

[参 考 文 献]

- [1] TERBRACK C, STÖTTNER J, ENDISCH C. Operation of an externally excited synchronous machine with a hybrid multilevel inverter[C]//2020 22nd European Conference on Power Electronics and Applications (EPE'20 ECCE Europe). Lyon: IEEE, 2020: 1-12.
- [2] DE-SANTIAGO J, BERNHOFF H, EKERGÅRD B, et al. Electrical motor drivelines in commercial all-electric vehicles; a review[J]. IEEE Transactions on Vehicular Technology, 2011, 61(2): 475-484.
- [3] STANCU C, WARD T, RAHMAN K M, et al. Separately excited synchronous motor with rotary transformer for hybrid vehicle application[J]. IEEE Transactions on Industry Applications, 2017, 54(1): 223-232.
- [4] WINZER P, DOPPELBAUER M. Charakterisierung und Auslegung von fremderregten synchronmaschinen als traktionsantrieb mit hilfe der normierten parameterebene[C]//Energieversorgung auf dem Weg nach 2050; Internationalen ETG-Kongresses. Berlin: [s. n.], 2013: 1-6.
- [5] HACKMANN W, WAGNER B, ZWINGEL R, et al. Fremderregte synchronmaschinen im einsatz als achshybridantriebe[C]//International ETG Congress. [S. l. : s. n.], 2007: 55-64.
- [6] REINHARD J, LÖHE K, GRAICHEN K. Optimal current set-point computation for externally excited synchronous machines [C]//2022 IEEE Conference on Control Technology and Applications (CCTA). Trieste: IEEE, 2022: 1319-1326.
- [7] AWAN H A A, SONG Z, SAARAKKALA S E, et al. Optimal torque control of synchronous motor drives; plug-and-play method[C]//2017 IEEE Energy Conversion Congress and Exposition (ECCE). Cincinnati, OH: IEEE, 2017: 334-341.
- [8] GIRARDIN A, FRIEDRICH G. Optimal control for a Wound Rotor Synchronous starter generator[C]//Conference Record of the 2006 IEEE Industry Applications Conference Forty-First IAS Annual Meeting. Tampa, FL: IEEE, 2006: 14-19.
- [9] QI X, CAO W, AARNIOVUORI L. Reinforcement learning based parameter lookup table generating method for optimal torque control of induction motors[J]. IEEE Transactions on Industrial Electronics, 2022, 70(5): 4516-4525.
- [10] BUETTNER M A, MONZEN N, HACKL C M. Artificial neural network based optimal feedforward torque control of interior permanent magnet synchronous machines; a feasibility study and comparison with the state-of-the-art[J]. Energies, 2022, 15(5): 1838.
- [11] MONZEN N, HACKL C M. Artificial neural network based optimal feedforward torque control of electrically excited synchronous machines[C]//2023 IEEE 32nd International Symposium on Industrial Electronics (ISIE). Helsinki: IEEE, 2023: 1-8.
- [12] WILLIAMS C K I, RASMUSSEN C E. Gaussian processes for machine learning[M]. Cambridge, Mass.: MIT Press, 2006: 16-19.
- [13] EBDEN M. Gaussian processes; a quick introduction[EB/OL]. (2015-08-29)[2023-10-15]. <https://arxiv.org/pdf/1505.02965>.
- [14] FRANZIER P I. A tutorial on Bayesian optimization [EB/OL]. (2018-07-08)[2023-10-15]. <https://arxiv.org/abs/1807.02811>.
- [15] 吴宝志, 袁晓梅. 基于神经网络的汽车空调系统变工况运行仿真研究[J]. 合肥工业大学学报(自然科学版), 1999, 22(3): 45-49.
- [16] 王华强, 石亚娟, 王健波. 神经网络模糊 PID 在水轮机调速系统中的应用[J]. 合肥工业大学学报(自然科学版), 2012, 35(9): 1187-1191.
- [17] ENGLERT T. Nichtlineare modellprädiktive drehmomentregelung elektrischer antriebssysteme für hochdynamische anwendungen[D]. Ulm: Ulm University, 2020.
- [18] JEONG I, GU B G, KIM J, et al. Inductance estimation of electrically excited synchronous motor via polynomial approximations by least square method[J]. IEEE Transactions on Industry Applications, 2014, 51(2): 1526-1537.
- [19] SEILMEIER M. Modelling of electrically excited synchronous machine (EESM) considering nonlinear material characteristics and multiple saliencies[C]//Proceedings of the 2011 14th European Conference on Power Electronics and Applications. Birmingham: IEEE, 2011: 1-10.
- [20] SACKS J, WELCH W J, MITCHELL T J, et al. Design and analysis of computer experiments[J]. Statistical Science, 1989, 4(4): 409-423.
- [21] JONES D R, SCHONLAU M, WELCH W J. Efficient global optimization of expensive black-box functions[J]. Journal of Global optimization, 1998, 13: 455-492.
- [22] HENNIG P, SCHULER C J. Entropy search for information-efficient global optimization[J]. Journal of Machine Learning Research, 2012, 13(6): 1809-1837.
- [23] Math Works. Help center-fitrgp[EB/OL]. [2023-10-20]. <https://ww2.mathworks.cn/help/stats/fitrgp.html>.
- [24] DE MYTTENAERE A, GOLDEN B, LE GRAND B, et al. Mean absolute percentage error for regression models[J]. Neurocomputing, 2016, 192: 38-48.
- [25] MAKRIDAKIS S. Accuracy measures; theoretical and practical concerns[J]. International Journal of Forecasting, 1993, 9(4): 527-529.

(责任编辑 吴 亮)