

基于GA优化GRU-LSTM-FC组合网络的风电场动态等值建模

丁新虎,潘学萍,和大壮,梁伟,孙晓荣,郭金鹏

(河海大学能源与电气学院,江苏南京 210098)

摘要:针对风电场动态等值建模依赖于运行方式和特定扰动,难以获得普适性强的通用等值模型的难题,提出了基于门控循环单元-长短期记忆-全连接(GRU-LSTM-FC)组合网络的数据驱动建模方法,并提出基于遗传算法(GA)对组合网络模型进行调优。首先将风电机组描述为一组微分代数方程组,模型输入为测风塔风速、风向和公共耦合点处的电压时间序列,模型输出为风电场功率时间序列。然后对比了具有记忆作用的LSTM(GRU)网络结构与风电机组微分方程的相似性,以及FC网络结构与风电机组代数方程的相似性,提出基于GRU-LSTM-FC组合网络的风电场等值建模方法。为对组合网络进行模型调优,利用GA优化组合网络中的FC层数和各层神经元数目。最后以某风电场为例验证了所提组合网络进行风电场等值建模的可行性,并将所提方法与其他神经网络模型进行了对比,分析了所提模型的优越性。

关键词:风电场;动态建模;深度学习;公共耦合点;遗传算法

中图分类号:TM614;TM712

文献标志码:A

DOI:10.16081/j.epae.202306012

0 引言

新能源场站的动态等值建模对保障电力系统安全稳定运行具有重要意义^[1-2]。等值建模方法包括机理建模、非机理建模以及数据驱动建模3类,目前大部分侧重于机理建模研究。

机理建模方法包括机组分群、等值机的参数获取、集电网络的等值等内容。由于单机等值存在误差大、适用于机组少且分布集中的新能源场站等局限性^[3],近年来多机等值^[4]受到较高重视。其中机组分群是多机等值的核心内容,分群方法包括基于稳态风速^[5]、基于特征量^[6]、基于动态响应特征^[7]的分群等。文献[8]提出综合风电机组稳态特性和动态特性的2维分群方法,具有较高的等值精度。

随着同步相量测量技术的发展,基于实测数据的非机理建模方法得到了广泛应用。非机理建模方法根据新能源场站的动态响应轨迹,采用数学模型拟合输入-输出响应特性,该方法不关心新能源机组的模型细节,着重刻画新能源场站的整体特性。如文献[9]提出了基于传递函数的风电场非机理等值建模方法;文献[10]根据实测双馈型风电机组的故障穿越响应特性,提出适用于对称和不对称电压跌落的故障穿越响应的非机理模型。文献[11]还将机理建模方法与基于响应特性的传递函数建模方法进行了对比,比较了2种建模方法的特点和相关性。

然而基于响应特性的非机理建模方法一般适用于特定扰动下的响应描述,模型的普适性不高。

近年来,随着大数据技术的不断进步,数据驱动的建模方法越来越受到重视。该方法不仅利用某特定扰动下的响应数据,还充分挖掘历史数据的特征信息,与基于传递函数的非机理建模方法相比,其具有更好的适应性。如文献[12]提出数据驱动的风电机组建模方法,并将其应用于风电机组的功率和转速的预测;文献[13]提出基于深度卷积神经网络的风电机组功率曲线建模方法;文献[14]根据主动配电网数学模型与长短期记忆(long short term memory, LSTM)网络计算流程的相似性,提出基于LSTM网络的主动配电网等值建模方法。由于LSTM网络参数多,建模时间较长,文献[15]提出将门控循环单元(gate recurrent unit, GRU)和LSTM网络组合应用于云计算资源负载的预测,结果表明该组合模型在预测精度和预测时间上兼具优势。这是因为作为LSTM网络变体的GRU网络减少了一个门,较少的网络参数使得预测时间变短。综上,本文提出将GRU和LSTM网络组合应用于风电场等值建模,有望在提高建模精度的同时缩短建模时间。

深度学习网络大部分面临模型调优问题,主要包括网络结构的调整和超参数的调整两部分。工程人员通常根据历史经验进行调优,然而当数据规模较大、网络模型较深时,每一次训练都要消耗大量的时间,故需寻找高效的模型调优方法。文献[16]提出采用遗传算法(genetic algorithm, GA)对LSTM网络模型参数进行优化,提升了模型的预测精度。结合该方法,本文提出将GA应用于优化GRU-LSTM的

收稿日期:2022-10-13;修回日期:2023-06-04

在线出版日期:2023-06-30

基金项目:国家自然科学基金资助项目(52077061)

Project supported by the National Natural Science Foundation of China(52077061)

网络参数,提升新能源场站等值建模的精度。

综上,本文首先对比风电机组动态模型与LSTM算法流程的相似性,分析基于LSTM进行风电场等值建模的可行性。然后以风电场测风塔风速和公共耦合点(point of common coupling, PCC)处的电压跌落曲线为输入信号,以PCC处的有功功率和无功功率为输出信息,基于GRU-LSTM网络构建风电场动态等值模型。进一步通过GA优化网络层数和各层神经元数目。最后基于风电场算例结果对比分析了不同深度学习网络的建模精度,并将本文方法与现有机理建模方法进行对比,验证了本文所提建模方法的可行性和优越性。

1 风电机组的数学模型

1.1 考虑尾流效应的风电场稳态功率

计及尾流效应的影响,风电场内部各机组端口风速计算见附录A式(A1)。风电机组的输入风速 v 与稳态功率 P_0 间的关系为:

$$P_0 = \begin{cases} 0 & v < v_{in}, v > v_{out} \\ \frac{v - v_{in}}{v_N - v_{in}} P_N & v_{in} \leq v < v_N \\ P_N & v_N \leq v \leq v_{out} \end{cases} \quad (1)$$

式中: v_{in} 和 v_{out} 分别为切入风速和切出风速; v_N 为额定风速; P_N 为风电机组的额定功率。

1.2 风电机组的动态模型

基于中国电科院电力系统分析综合程序平台中的风电机组数学模型^[17],根据其在正常以及低电压穿越期间的控制方式,风电机组的数学模型可以统一表示为一组微分-代数方程组,即:

$$\begin{cases} \frac{dx}{dt} = f(x, u_{PCC}) \\ y = z(x, u_{PCC}) \end{cases} \quad (2)$$

式中: u_{PCC} 为风电场PCC处的电压; x 为风电机组的状态变量; y 为风电场输出的有功功率和无功功率列向量; f 和 z 为函数运算。将式(2)中的微分方程差分化可得:

$$x_t = f'(x_{t-1}, u_{PCC,t-1}, u_{PCC,t}) \quad (3)$$

式中:下标 t 表示当前时刻,下标 $t-1$ 表示前一时刻,后同; f' 为函数运算符号。

综合式(1)~(3)可知,风电场的动态输出 y 与风电机组的状态量 x 、风电场PCC处的电压 u_{PCC} 以及初始运行点(风速 v_0 以及风向 k_0)密切相关,风电场数据驱动模型如图1所示。因此,如果能获取风电场丰富的历史运行数据以及扰动响应数据,则将测风塔处的风速 v_0 及风向 k_0 、PCC处的电压 u_{PCC} 作为输入,以有功功率和无功功率响应作为输出 y ,根据式(2)选择合适的深度学习模型,可获得风电场动态等值的数据模型。

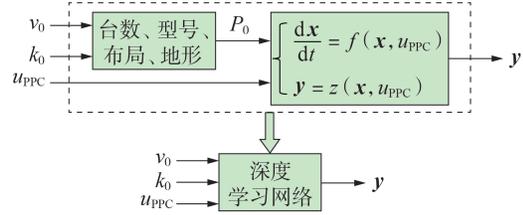


图1 风电场数据驱动模型

Fig.1 Data-driven model of wind farm

2 基于GRU-LSTM-FC组合网络的风电场等值建模方法

2.1 LSTM网络原理

LSTM网络属于循环神经网络(recurrent neural network, RNN)的改进形式,适用于处理时序数据^[18]。其通过引入细胞状态与门机制控制特征的流通和损失,解决了RNN中的梯度爆炸和梯度消失问题。LSTM网络结构如附录A图A1所示。

LSTM网络包含输入门(i)、遗忘门(l)和输出门(o)3种门控结构。输入门控制当前时刻输入信息,遗忘门控制前一时刻细胞状态的保留程度,输出门决定当前时刻输出信息。LSTM网络的计算流程见附录A式(A2)。为了更直观地表明LSTM网络隐藏层中输入与输出的关系 h_t ,式(A2)可进一步简化为:

$$h_t = F(h_{t-1}, u_t, u_{t-1}, w, b) \quad (4)$$

式中: F 为函数符号; b 为偏置量; u 为输入量; w 为门(i, l, o)以及线路(g, h, o)间的权重集合。

2.2 GRU网络原理

GRU网络是LSTM网络的简化变体^[19],其单元结构见附录A图A2。GRU网络内部包含重置门(r)和更新门(z),重置门控制前一时刻状态信息的保留程度,更新门控制前一时刻状态信息并入当前状态的程度。GRU计算过程同样可简化为式(4)。

2.3 全连接网络原理

全连接(full connection, FC)网络的所有隐藏层节点均相互连接,这虽然增加了网络权重,但其通过简单非线性函数多次复合,可实现输入空间到输出空间的复杂映射,故应用广泛。FC算法流程可表示为:

$$y = \psi(x', b') \quad (5)$$

式中: ψ 为tanh激活函数; x' 为输入; b' 为偏置量。

2.4 基于GRU-LSTM-FC组合网络的风电场动态等值建模

LSTM网络结构中的反馈连接将当前时刻的状态和前一时刻的状态联系起来。将风电机组动态模型式(3)与LSTM的算法流程式(4)对比发现,2者在数学表达上具有相似性,这说明采用LSTM或GRU模拟风电机组/风电场动态特性具有可行性。同时由于式(5)所示FC层的计算流程可描述风电机组/风电场动态模型中的代数方程,因此在进行深

深度学习网络的构建时,可在 LSTM 网络后面进一步叠加 FC 网络模拟风电场的动态模型。据此构建 GRU-LSTM-FC 组合网络的结构。

GRU-LSTM-FC 组合网络包括 3 层:第 1 层为 GRU 层,替代 LSTM 层用于减小计算量;第 2 层为 LSTM 层,GRU-LSTM 网络结构用于模拟风电场数学模型的微分方程;第 3 层为 FC 层,用于模拟风电场数学模型的代数方程。

输入数据包括风电场测风塔处的风速、风向以及 PCC 处的电压时间序列 $u_{\text{PCC},t}$,根据风速、风向结合式(1)和式(A1),可得风电场的初始有功功率 P_0 。对输入数据进行标准化处理后得到的输入为 $\bar{U}_{\text{PCC}}(t)$ 和 \bar{P}_0 。输出数据为风电场出口的有功功率和无功率时间序列。

3 基于 GA 优化组合网络超参数

3.1 待优化超参数

超参数优化是提升深度学习网络性能的关键,其中较为重要的超参数包括模型网络结构、学习率等。由于学习率可结合训练过程与经验获得,GRU-LSTM-FC 组合网络中需确定的超参数为各隐藏层的层数以及各层神经元数目。

超参数的确定分 2 步进行:①通过性能比较确定组合网络中 GRU 与 LSTM 各为 1 层;②选取全局搜索能力好、拓展性强的 GA 优化获得 FC 层数以及各隐藏层神经元数目这 2 类超参数。

3.2 基于 GA 的超参数寻优流程

由于 GA 具备较好的全局寻优能力^[20],本文选择 GA 进行 GRU-LSTM-FC 组合网络的超参数寻优。寻优流程见附录 A 图 A3,主要包括种群染色体编码、适应度函数的设计两部分,具体如下。

进行种群染色体编码时,本文将 FC 层数与各隐藏层神经元数目组合,构建种群中个体的染色体 C 结构为:

$$C = \{n, \Phi_1, \Phi_2, \Phi'_1, \Phi'_2, \dots, \Phi'_n\} \quad (6)$$

式中: n 为 FC 的层数; Φ_1 为 GRU 层神经元数目; Φ_2 为 LSTM 层神经元数目; Φ'_1 — Φ'_n 分别为 FC 层中第 1— n 层的神经元数目。

采用准确率、泛化性、训练效率 3 个指标综合衡量组合网络的性能,适应度函数为 3 个指标之和,具体见式(7)。

$$J = \alpha \frac{\xi_{L,0}}{\xi_L} + \beta \frac{\xi'_{L,0}}{\xi'_L} + \gamma \frac{\xi_{T,0}}{\xi_T} \quad (7)$$

式中: J 为适应度函数; $\xi_{L,0}$ 和 ξ_L 分别为训练集的目标均方误差和实际均方误差,二者比值用以表征网络的准确率; $\xi'_{L,0}$ 和 ξ'_L 分别为测试集的目标均方误差和实际均方误差,二者比值用以表征网络的泛化能力; $\xi_{T,0}$ 为目标训练时长,取值为多次训练的平均时长, ξ_T

为实际训练时长,二者比值用以表征网络的训练效率; α 、 β 和 γ 为各指标的权重系数。

4 算例分析

4.1 风电场布局

以附录 A 图 A4 所示的某风电场布局为研究对象,该风电场包含 36 台风电机组,以 6×6 方式均匀分布,各台风电机组相距均为 500 m。其中 1—18 为双馈型风电机组,19—36 为直驱型风电机组,单机额定功率均为 1.5 MW。风电场经由机端箱变和主变两级升压接入 CEPRI-36 节点系统的母线 BUS₃₀。所有风电机组均在线,且配置低电压穿越控制,未考虑虚拟惯量等其他控制。CEPRI-36 节点系统结构图见附录 A 图 A5,风电机组和集电线路详细参数见附录 A 表 A1。

4.2 数据准备

深度学习网络输入数据包括测风塔测得的风速、风向数据及风电场 PCC 处的电压时间序列;输出数据包括风电场的有功功率和无功率时间序列。

训练集数据包括:风速在切入风速 3 m/s 和额定风速 12 m/s 范围内变化,间隔为 1 m/s;风向为 $[0^\circ, 180^\circ]$ (由于 $(180^\circ, 360^\circ)$ 与 $[0^\circ, 180^\circ]$ 内的风向变化带来的尾流效应一致,故仅考虑 $[0^\circ, 180^\circ]$ 内风向),方向间隔为 10° 。设 0.1 s 时 PCC 处发生三相短路故障,0.25 s 时切除故障,电压跌落范围为 $[0.1, 0.9]U_n$ (U_n 为电压额定值),跌落间隔为 $0.1U_n$ 。数据采样总时长为 1 s,采样间隔为 0.001 s。因此共有样本数据 1 710 组(10×19×9)用于模型训练,每条数据长度为 1 000。

测试集数据包括:风电场风速、风向以及 PCC 处电压跌落程度。这 3 类数据都以更小的变化尺度(即 0.1 m/s、 1° 、 $0.01U_n$)随机组合,共 100 组数据。

采用均方误差 E 来评价基于 GRU-LSTM-FC 组合网络的输出与实际响应之间的匹配程度;同时,以各时间点的绝对误差 e 来描述整个暂态区间内的瞬时误差。两指标表达式分别见附录 A 式(A3)、(A4)。

4.3 组合网络中 GRU 与 LSTM 层数验证

为了验证组合网络中 GRU 与 LSTM 层数对风电场等值模型性能的影响,本文从迭代效率、训练集和测试集的均方误差 2 个方面分别对单层 LSTM、单层 GRU、双层 LSTM、双层 GRU 和单层 GRU-单层 LSTM 这 5 种网络进行性能评价。上述 5 种网络中的 FC 层数统一设为 1 层,所有隐藏层神经元数目设为 50。组合网络训练的迭代终止误差设为 10^{-2} ,最大迭代次数设为 30 000。

设模型学习率 I_λ 表示以迭代次数 λ 为自变量的反比例函数,具体为:

$$I_r = \frac{I_0}{0.0009\lambda + 1} \quad (8)$$

式中： $I_0=10^{-2}$ 为模型初始学习率。

本文基于Pytorch1.7.1(CUDA 11.0)平台构建深度学习框架,通过配置为Intel Core i5-7300CPU、2.5 GHz处理器以及8 GB内存的电脑进行数据训练。5种网络在训练集的均方误差(标么值,后同)见图2,表1给出了5种组合网络在训练集和测试集的总均方误差。

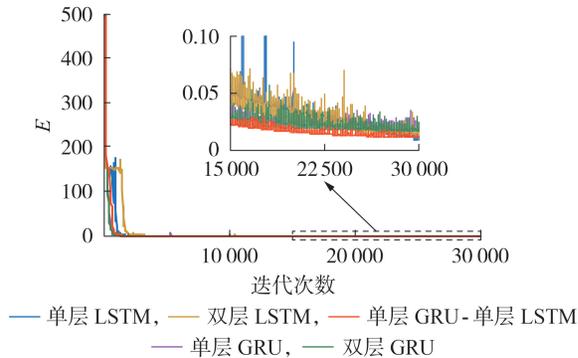


图2 5种网络结构在训练集的均方误差

Fig.2 Mean square error of five kinds of network structures at training set

表1 收敛后5种网络结构在训练集和测试集的均方误差

Table 1 Mean square error of five kinds of network structures at training set and testing set

网络结构	E	
	训练集	测试集
单层 LSTM	0.01107	0.04893
单层 GRU	0.01918	0.26215
双层 LSTM	0.01625	0.08423
双层 GRU	0.01742	0.13990
单层 GRU-单层 LSTM	0.01274	0.02164

由图2和表1可以得到如下结论。

1)迭代次数在 $[0, 2000)$ 范围内时,GRU网络的收敛速度均快于单层GRU-单层LSTM网络以及LSTM网络,但在迭代2000次左右时误差仍较大,不满足停止训练误差要求;迭代次数在 $(2000, 15000]$ 范围内时,GRU网络的收敛速度变慢,低于单层GRU-单层LSTM网络;整个迭代期间单层LSTM网络和双层LSTM网络的收敛速度最慢。总体而言,在整个迭代期间单层GRU-单层LSTM网络的收敛效率最高,且在测试集的误差较小,表明该模型精度高且收敛速度快。

2)收敛后单层(双层)GRU网络在训练集和测试集中的均方误差均高于单层(双层)LSTM网络。在对风电场的等值建模中GRU网络具有更高的收敛效率,而LSTM则需要更多的迭代次数。

3)单纯增加LSTM或GRU的层数并未使模型性能得到明显提升。

因此,本文确定以单层GRU-单层LSTM作为网络模型的基本结构。

4.4 基于GA的组合网络超参数优化

为选取合适的FC层数以及各层(GRU、LSTM和FC)的神经元个数,这里基于GA进行超参数优化。GA参数设置为:种群中个体数为40,初始种群每个个体的染色体全部在其变化范围内随机生成,其中FC层数 n 变化范围为0~8层;隐藏层神经元数目 Φ 变化范围为20~80;GA的交叉率设为0.3;变异率设为0.1。此外式(7)所示适应度函数指标中,权重系数 α 、 β 和 γ 分别为0.3、0.6和0.5, $\xi_{L,0}$ 取值为0.01, $\xi'_{L,0}$ 取值为0.01, $\xi_{r,0}$ 取值为3 min。适应度函数标准值设为5,遗传迭代终止条件设为种群中出现个体适应度指标达到98%,即 $J \geq 4.9$ 。算例中GA迭代到第10次时收敛。

图3给出了GA在迭代过程中的迭代次数与不同FC层数(含对应FC层数下各层神经元数目)下适应度占比结果。图中: ρ_{FC} 为适应度占比,其值为第 r ($r=0, 1, \dots, 8$)层下FC的适应度与0~8层FC的总适应度之比。

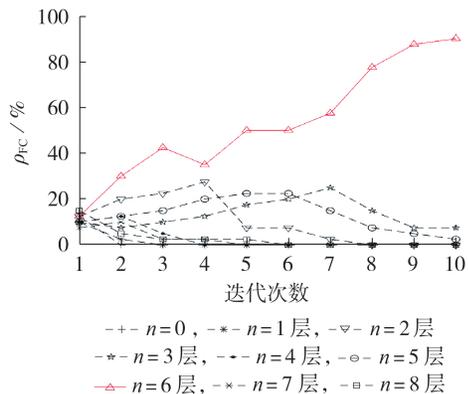


图3 不同FC层数在各代遗传种群中的适应度占比

Fig.3 Fitness ratio of different FC layers in each genetic population

从图3可以看出:在迭代过程中,FC层数为6层时适应度占比最高,迭代到第10次时其适应度占比高达88.684%,因此FC层数确定为6层,此时染色体最优值 $C=\{6, 71, 66, 48, 79, 45, 26, 77, 49\}$,即FC为6层,GRU和LSTM的神经元数目分别为71和66,FC各层神经元数目分别为48、79、45、26、77和49。

4.5 基于GRU-LSTM-FC组合网络的风电场等值建模

基于GA优化后的GRU-LSTM-FC组合网络对风电场进行动态等值建模。优化前、后,100组测试样本下GRU-LSTM-FC组合网络输出有功功率 P 的均方误差 $E(P)$ 和无功功率 Q 的均方误差 $E(Q)$ 见图4。由图可知:基于GA优化后的GRU-LSTM-FC组合网络可显著提高风电场的等值建模精度。

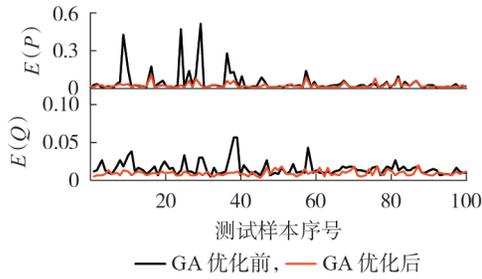


图4 GA优化前、后测试样本建模的均方误差

Fig.4 Mean square error of modeling in test samples before and after GA optimization

图5给出了测试集第10号样本(初始风速为10.6 m/s,风向为127°,电压跌落至0.82U_n)在[0, 0.5] s时段内有功、无功功率响应及其各时间点的绝对误差e(P)、e(Q)。由图可知:基于GRU-LSTM-FC组合网络的风电场等值模型具有较高的精度。有功功率的均方误差为0.02727 p.u.,各时间点绝对误差均小于2.55%的实际轨迹值;无功功率的均方误差为0.01098 p.u.,各时间点绝对误差均小于2.56%的实际轨迹值。

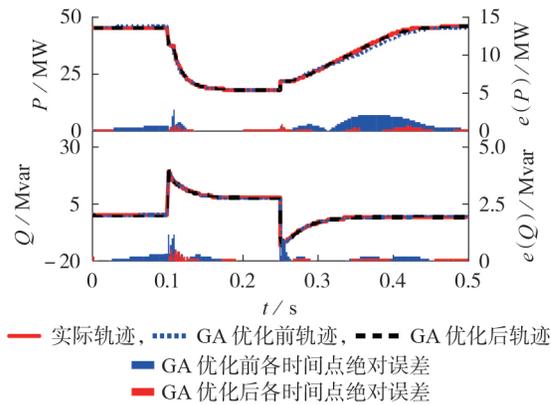


图5 GA优化前、后模型等值结果

Fig.5 Equivalent results before and after GA optimization

此外,附录A图A6还给出了第54号样本(初始风速为9.6 m/s,风向为116°,电压跌落至0.11U_n)下的实际功率响应和等值模型的功率响应。由于故障期间电压小于0.2U_n,导致风电场内机组全部脱网,此时等值模型中有功与无功响应的均方误差分别为0.00171 p.u.以及0.00556 p.u.。可以看出:当电压跌落较深、机组全部脱网时,本文模型仍具有较高的等值精度。

4.6 不同数据驱动建模方法的比较

为验证本文基于GRU-LSTM-FC组合网络的等值效果,仍旧以上述算例及训练数据为例,采用BP神经网络、RNN、带外源输入的非线性自回归神经网络(nonlinear autoregressive neural network with external input, NARX)^[21]进行建模。4种模型在100组

测试样本中有功功率和无功功率的均方误差见图6及表2,表2还给出了4种网络的模型训练时间。同时,图7还给出了4种模型基于测试集第67号样本(初始风速为11.4 m/s,风向为73°,电压跌落至0.46U_n)在0~1.0 s时段的功率受扰轨迹。

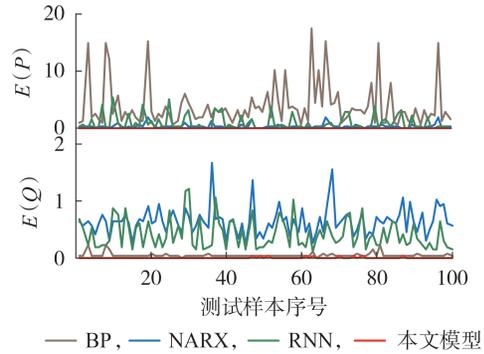


图6 4种模型在测试样本数据的均方误差

Fig.6 Mean square error of four kinds of models in test samples

表2 4种模型的建模性能对比

Table 2 Modeling performance of four kinds of models

网络结构	E(P)	E(Q)	平均训练时间/s
BP	4.00215	0.04439	91
RNN	1.04354	0.41124	257
NARX	0.51146	0.63713	289
本文模型	0.01941	0.00889	173

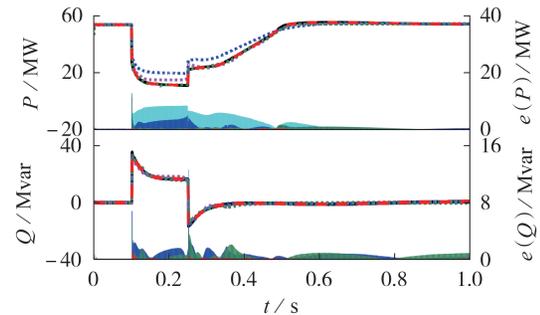


图7 基于4种模型的功率响应及各时间点绝对误差

Fig.7 Power responses and absolute error at each time point of four kinds of models

由图6、7及表2可得结论如下:①基于BP神经网络的模型训练时间最短,但其误差最大,本文模型的等值精度最高,且训练时间可接受;②RNN和NARX都具有记忆能力,有功功率的预测精度高于BP神经网络,但无功功率的预测误差较大,且模型的训练时间较长。

4.7 与基于物理模型等值方法的对比

下面进一步将本文方法与现有机理建模等值方

法进行对比。在进行机理建模时,采用文献[8]提出的多机等值方法,该方法首先综合稳态特性一致性和动态特性一致性对风电机组进行分群,在初始风速为 11.4 m/s ,风向为 73° 且电压跌落至 $0.46U_n$ 时,附录A图A4所示风电场机组可分为4群,分别为:群1 $\{1-3, 7-9, 13-15, 19, 25, 31\}$,群2 $\{20, 21, 26, 27, 32, 33\}$,群3 $\{4-6, 10-12, 16-18\}$ 以及群4 $\{22-24, 28-30, 34-36\}$ 。然后采用加权法获得各等值机的初始参数,进一步通过辨识方法获得各等值机的重点参数。

图8给出了电压跌落至 $0.46U_n$ 场景下原系统实际轨迹、本文模型预测轨迹以及机理等值模型的受扰轨迹。由图可知:本文模型的预测轨迹与机理等值模型的受扰轨迹都具有较高的等值精度;从误差曲线来看,本文模型的预测精度稍高于机理等值模型。

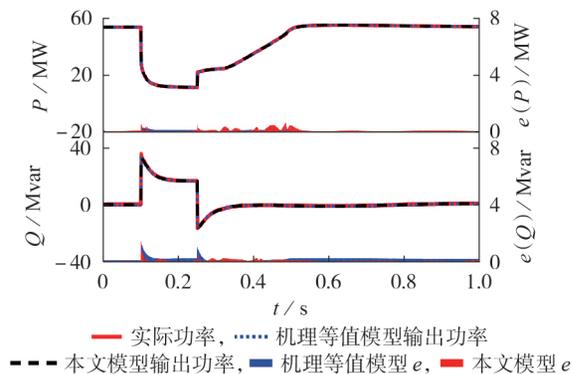


图8 本文模型与机理等值模型的功率响应及各时间点绝对误差

Fig.8 Responses and absolute error at each time point of proposed model and mechanism-based equivalent model

5 结论

本文提出了基于GRU-LSTM-FC组合网络的风电场动态等值的数据驱动建模方法。首先讨论了将LSTM与FC组合描述风电机组动态特性的可行性,进一步提出采用GA对GRU-LSTM-FC组合网络进行超参数优化。算例结果表明,采用GA优化GRU-LSTM-FC组合网络的超参数可显著提升建模的精度。

将本文方法与浅层BP神经网络、RNN、NARX等数据驱动建模方法比较发现,本文方法的建模精度高,且所需模型训练时间较短。同时与现有基于机理模型的等值方法相比,本文模型的精度稍高于机理等值模型,训练效率也在可接受的范围内。

本文模型的训练数据可以通过对风电场的仿真获取。对于实际场景,采用“离线训练、实时匹配”的方式,将实际场景与历史仿真场景匹配,获得实际场

景的电压序列,采用训练好的组合网络模型进行功率预测。由于预测过程不需要对组合网络训练,因此建模时间较短,适用于风电场的在线建模。未来的工作包括针对某一或多座实际风电场,收集尽可能多的实测数据。通过不断丰富的历史数据,对所建GRU-LSTM-FC组合网络参数持续修正,从而提升数据驱动建模方法的精度。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 杨茂,杨琼琼. 风电机组风速-功率特性曲线建模研究综述[J]. 电力自动化设备,2018,38(2):34-43.
YANG Mao, YANG Qionqiong. Review of modeling of wind speed-power characteristic curve for wind turbine[J]. Electric Power Automation Equipment, 2018, 38(2): 34-43.
- [2] 邵振国,刘懿莹,张嫣. 基于实测数据的风电场风速-功率特性仿射建模方法[J]. 电力自动化设备,2019,39(6):96-101.
SHAO Zhenguo, LIU Yixuan, ZHANG Yan. Affine modelling method of wind speed-power characteristics in wind farm based on measured data[J]. Electric Power Automation Equipment, 2019, 39(6): 96-101.
- [3] 古庭赞,杨骥嘉,林呈辉,等. 基于单机等值与选择模态分析的风电场等值建模方法[J]. 电力系统保护与控制,2020,48(1):102-111.
GU Tingyun, YANG Qijia, LIN Chenghui, et al. A wind farm equivalent modeling method based on single-machine equivalent modeling and selection modal analysis[J]. Power System Protection and Control, 2020, 48(1): 102-111.
- [4] ZHOU Y H, ZHAO L, MATSUO I B M, et al. A dynamic weighted aggregation equivalent modeling approach for the DFIG wind farm considering the Weibull distribution for fault analysis[J]. IEEE Transactions on Industry Applications, 2019, 55(6): 5514-5523.
- [5] LI W X, CHAO P P, LIANG X D, et al. A practical equivalent method for DFIG wind farms[J]. IEEE Transactions on Sustainable Energy, 2018, 9(2): 610-620.
- [6] 丁明,朱乾龙,韩平平,等. 计及Crowbar保护的双馈风电场等值建模研究[J]. 太阳能学报,2016,37(9):2209-2216.
DING Ming, ZHU Qianlong, HAN Pingping, et al. Analysis on aggregation method for equivalent modeling of DFIG-based wind farm considering Crowbar protection[J]. Acta Energetica Solaris Sinica, 2016, 37(9): 2209-2216.
- [7] 高远,金宇清,鞠平,等. 考虑Crowbar动作特性的DFIG风电场动态等值研究[J]. 电网技术,2015,39(3):628-633.
GAO Yuan, JIN Yuqing, JU Ping, et al. Dynamic equivalence of wind farm composed of double fed induction generators considering operation characteristic of Crowbar[J]. Power System Technology, 2015, 39(3): 628-633.
- [8] 潘学萍,戚相威,梁伟,等. 综合模型聚合和参数辨识的风电场多机等值及参数整体辨识[J]. 电力自动化设备,2022,42(1):124-132.
PAN Xueping, QI Xiangwei, LIANG Wei, et al. Multi-machine equivalence and global identification of wind farms by combining model aggregation and parameter estimation[J]. Electric Power Automation Equipment, 2022, 42(1): 124-132.
- [9] WU F, QIAN J X, JU P, et al. Transfer function based equivalent modeling method for wind farm[J]. Journal of Modern Power Systems and Clean Energy, 2019, 7(3): 549-557.

- [10] 齐金玲,李卫星,晁璞璞,等. 直驱风机故障穿越全过程的通用电磁暂态建模方法[J]. 中国电机工程学报,2022,42(4):1428-1442.
QI Jinling,LI Weixing,CHAO Pupu,et al. General electromagnetic transient modeling method for the whole process of direct-drive fan fault ride-through[J]. Proceedings of the CSEE, 2022,42(4):1428-1442.
- [11] BAI F F,LIU Y,LIU Y L,et al. Methods to establish input-output relationship for system identification-based models[C]//2014 IEEE PES General Meeting Conference & Exposition. National Harbor,MD,USA:IEEE,2014:1-5.
- [12] KUSIAK A,LI W Y. Virtual models for prediction of wind turbine parameters[J]. IEEE Transactions on Energy Conversion,2010,25(1):245-252.
- [13] YANG L X,WANG L,ZHANG Z J. Generative wind power curve modeling via machine vision:a deep convolutional network method with data-synthesis-informed-training[J]. IEEE Transactions on Power Systems,2023,38(2):1111-1124.
- [14] ZHENG C,WANG S R,LIU Y L,et al. A novel equivalent model of active distribution networks based on LSTM[J]. IEEE Transactions on Neural Networks and Learning Systems,2019,30(9):2611-2624.
- [15] 贺小伟,徐靖杰,王宾,等. 基于GRU-LSTM组合模型的云计算资源负载预测研究[J]. 计算机工程,2022,48(5):11-17,34.
HE Xiaowei,XU Jingjie,WANG Bin,et al. Research on cloud computing resource load forecasting based on GRU-LSTM combination model[J]. Computer Engineering,2022,48(5):11-17,34.
- [16] 张甲甲,万定生. 基于混合GA优化LSTM的中小流域流量预测研究[J]. 计算机仿真,2022,39(2):283-287,342.
ZHANG Jiajia,WAN Dingsheng. Improved hybrid genetic algorithm and its application in run off prediction[J]. Computer Simulation,2022,39(2):283-287,342.
- [17] 中国电力科学研究院. PSASP 7版动态元件库用户手册[EB/OL]. [2023-06-20]. <https://www.docin.com/p-826860807.html>.
- [18] GRAVES A. Long short-term memory[M]. Berlin,German: Springer,2012:1735-1780.
- [19] 邱锡鹏. 神经网络与深度学习[M]. 北京:机械工业出版社,2020:88-100,144-147.
- [20] 于瑛,陈笑,贾晓宇,等. 基于GA-BP神经网络的逐时总辐射分组模型研究[J]. 太阳能学报,2022,43(8):157-163.
YU Ying,CHEN Xiao,JIA Xiaoyu,et al. Research on grouping model of hourly global solar radiation based on GA-BP neural network[J]. Acta Energetica Solaris Sinica,2022,43(8):157-163.
- [21] 李应求,安勃,李恒通. 基于NARX及混沌支持向量机的短期风速预测[J]. 电力系统保护与控制,2019,47(23):65-73.
LI Yingqiu,AN Bo,LI Hengtong. Short-term wind speed prediction based on NARX and chaos-support vector machine [J]. Power System Protection and Control, 2019, 47 (23) : 65-73.

作者简介:



丁新虎

丁新虎(1998—),男,硕士研究生,主要研究方向为风力发电系统建模分析(E-mail:373977391@qq.com);

潘学萍(1972—),女,教授,博士研究生导师,博士,主要研究方向为新能源电力系统建模、分析与控制(E-mail:xueping_pan@hhu.edu.cn);

郭金鹏(1992—),男,副研究员,博士,通信作者,主要研究方向为新型电力系统稳定性分析和控制(E-mail:jinpeng.guo@hhu.edu.cn)。

(编辑 王欣竹)

Wind farm dynamic equivalent modeling by GA-optimized GRU-LSTM-FC combined network

DING Xinhua,PAN Xueping,HE Dazhuang,LIANG Wei,SUN Xiaorong,GUO Jinpeng
(College of Energy and Electrical Engineering,Hohai University,Nanjing 210098,China)

Abstract: Aiming at the dynamic equivalent modeling of a wind farm depends on its operation mode and specific disturbance, which is difficult to obtain a general equivalent model, a data-driven modeling method based on gate recurrent unit-long short term memory-full connection (GRU-LSTM-FC) combined network is proposed, and the genetic algorithm (GA)-based method is proposed to optimize the combined network model. Firstly, the wind turbine is described as a set of differential-algebraic equations. The model input is the wind speed, wind direction at the anemometer tower, and the time series of voltage at the point of common coupling (PCC), and the model output is the time series of the wind farm power. Then, by comparing the similarity between the LSTM/GRU network structure with memory ability and the differential equation of wind turbine, and the similarity between the FC network structure and the algebraic equation of wind turbine, an equivalent modeling method of wind farm based on GRU-LSTM-FC combined network is proposed. In order to optimize the combined model, GA is applied to optimize the number of FC layers and the number of neurons at each layer in the combined network. Finally, taking a wind farm as an example, the feasibility of data-driven equivalent modeling with the proposed combined network is verified, and the proposed method is compared with other neural network models, and the advantages of the proposed model are analyzed.

Key words: wind farms; dynamic modeling; deep learning; PCC; genetic algorithm

附录 A

$$\begin{cases} v_d = v_0 \left[1 - \left(\frac{r}{d \tan \varphi + r} \right)^2 (1 - \sqrt{1 - C_T}) \right] \\ v_i = \sqrt{v_{i0}^2 + \sum_{j=1, j \neq i}^m (v_{j-i}^2 - v_{i0}^2)} \end{cases} \quad (\text{A1})$$

式中： v_0 为测风塔所测风速； v_d 为距测风塔 d 处仅受测风塔处风电机组尾流影响的风速； r 为风轮半径； $\tan \varphi$ 为尾流下降常数； C_T 为推力系数； v_i 为风电机组的输入风速； v_{i0} 为不考虑尾流时作用在第 i 台风电机组的风速； v_{j-i} 为考虑尾流时第 j 台风电机组作用在第 i 台时的风速； m 为风电机组总台数。

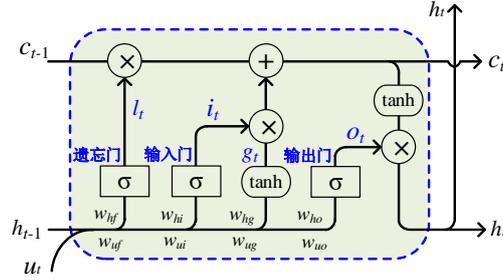


图 A1 LSTM 网络结构

Fig.A1 Architecture of LSTM network

LSTM 的计算流程如下：

$$\begin{cases} i_t = \sigma(w_{ui}u_t + w_{hi}h_{t-1}) \\ l_t = \sigma(w_{ul}u_t + w_{hl}h_{t-1}) \\ g_t = \tanh(w_{ug}u_t + w_{hg}h_{t-1}) \\ o_t = \sigma(w_{uo}u_t + w_{ho}h_{t-1}) \\ c_t = l_t \odot c_{t-1} + i_t \odot g_t \\ h_t = o_t \odot \tanh(c_t) \end{cases} \quad (\text{A2})$$

式中：下标 t 和 $t-1$ 分别表示 t 时刻和 $t-1$ 时刻； u 为输入量； i 、 l 和 o 分别为输入门、遗忘门以及输出门的输出； c 为记忆主线； g 为主线补给； w 为各个门（ i 、 l 、 o ）或线路（ g 、 h 、 o ）间的权重矩阵中的各元素； σ 为sigmoid函数， \tanh 为双曲正切函数； \odot 为矩阵点乘。

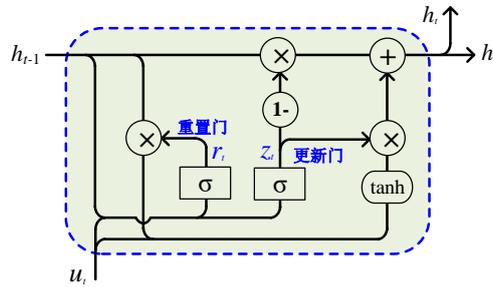


图 A2 GRU 网络的结构

Fig.A2 Architecture of GRU network

表 A1 风电场模型参数

Table A1 Parameters of wind farm

元件	参数	参数值	元件	参数	参数值
发电机	额定功率/MW	1.5	风力机	切入风速/(m·s ⁻¹)	3
	额定频率/Hz	50		额定风速/(m·s ⁻¹)	12
	额定电压/V	690		切出风速/(m·s ⁻¹)	25
	R_s	0.009 8		叶轮半径/m	37.5
	R_r	0.009 3	元件	参数	参数值
	X_m	4.100 0	集电线路	$r_0/(\Omega \cdot \text{km}^{-1})$	0.332
	X_s	0.086 0		$x_0/(\Omega \cdot \text{km}^{-1})$	0.4
X_r	0.094 7				

表中： R 、 X 为标么值。

$$E = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (\text{A3})$$

$$e_i = |y_i - \hat{y}_i| \quad (\text{A4})$$

式中： y_i 为 i 时刻风电场的实际响应值； \hat{y}_i 为 GRU-LSTM-FC 组合网络在 i 时刻的输出； $N=1\ 000$ ， N 为整个时域仿真过程中采样的数据总数。

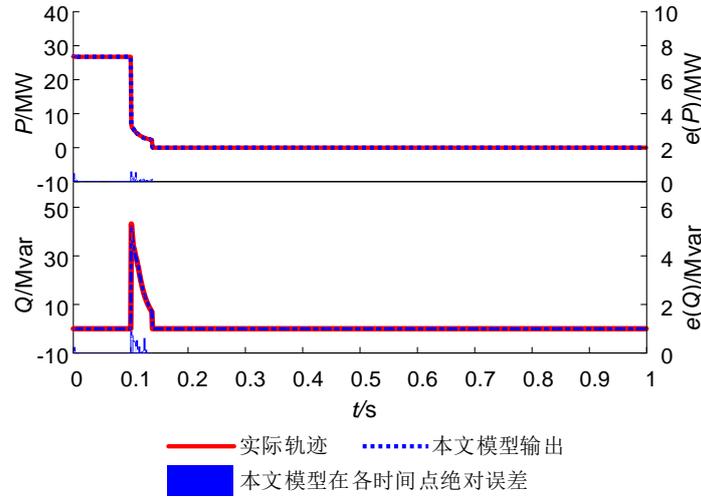


图 A6 电压跌落期间风电机组全部脱网时等值结果

Fig. A6 Model equivalence when all WTGs are tripped from power grid during voltage sag