

# 基于 LSTM 神经网络的双馈风机控制参数辨识方法

薛飞<sup>1</sup>, 李宏强<sup>1</sup>, 李旭涛<sup>1</sup>, 徐恒山<sup>2</sup>

(1. 国网宁夏电力有限公司电力科学研究院, 宁夏银川 750001; 2. 三峡大学 电气与  
新能源学院, 湖北宜昌 443002)

**摘要:** 针对暂态工况下难以高精度获取双馈风机 (doubly fed induction generator, DFIG) 电磁模型控制参数的问题, 提出了一种基于长短期记忆 (long short-term memory, LSTM) 神经网络的 DFIG 控制参数高精度辨识方法。首先, 利用 RT-LAB 半实物仿真平台测量并获取 DFIG 控制器硬件在环数据, 并在 PLECS 平台中搭建 DFIG 模型的辨识模型; 然后, 采用 Person 相关系数法提取出高相关性特征并进行神经网络训练; 最后, 利用提出的 LSTM 神经网络对 DFIG 的控制参数进行辨识, 并与实测数据进行对比, 验证了所提方法的可行性、有效性和实用性。结果表明, 相比于传统辨识方法, 所提 LSTM 神经网络参数辨识方法在暂态工况下可有效提高 DFIG 电磁模型控制参数的辨识精度。

**关键词:** 双馈风机; 硬件在环; 参数辨识; 长短时记忆网络; Person 相关系数法

**DOI:** 10.11930/j.issn.1004-9649.202208091

## 0 引言

能源危机促进了新能源的快速发展, 以风电为代表的新能源机组在电网中的占比不断提高, 但具有间歇性和随机性特征的风电机组通过非线性电力电子变流器大量接入电网对电力系统的安全稳定运行带来巨大挑战<sup>[1]</sup>, 主要原因之一是风机控制参数对其出力特性影响巨大, 而风机实际控制参数难以收集, 导致研究人员无法获得风机的精确模型, 因此, 从风机自身特性研究和电力系统稳定性分析的角度来看, 对风机的真实控制参数进行高精度辨识具有极为重要的实际意义和研究意义<sup>[2-4]</sup>。

在风机控制参数辨识方面, 国内外学者开展了大量研究<sup>[5-13]</sup>。文献<sup>[8]</sup>基于风机原理证实其控制参数具有可辨识性; 文献<sup>[9]</sup>采用阻尼最小二乘法对风机解耦参数进行了辨识, 但其内环控制参数的辨识结果较差; 文献<sup>[10]</sup>利用粒子群算法对并网逆变器的控制参数进行了辨识, 但粒子群算法容易陷入局部最优, 容易出现局部控制参数

辨识精度较差的问题; 文献<sup>[11]</sup>基于逆变器的输出状态对风机的控制参数进行了辨识; 文献<sup>[12]</sup>结合伪随机信号和频域解析法提取出了风机的控制参数, 但对时域响应跟踪能力较差; 文献<sup>[13]</sup>在对双馈风机叠加三相 M 序列激励信号的基础上, 利用正余弦优化算法对控制参数进行辨识寻优, 但其所采用的激励信号及其实施过程较为复杂。

控制参数在暂态故障下对并网点的动态特性影响最为明显, 采用人工智能算法通过辨识手段获取双馈风机控制参数是较为有效的技术手段。文献<sup>[14]</sup>针对电压跌落故障提出了基于粒子群算法的分步辨识方法, 实现了对网侧电流内环参数和无功电流支撑参数的辨识, 但该方法容易陷入局部最优, 无法适应复杂工况, 甚至单一工况下也难以获得完备且准确的控制参数。作为深度学习经典方法之一, 长短期记忆 (long short-term memory, LSTM) 具有通过提取时序数据特征来挖掘未来数据复杂变化趋势的能力<sup>[15]</sup>, 而双馈风机响应具有复杂的非线性和时序性, 因此, 将 LSTM 算法用于双馈风机的参数辨识具有天然优势。

根据上述研究背景, 针对暂态工况下传统辨识方法难以高精度辨识双馈风机电磁模型控制参数的问题, 本文提出一种基于 LSTM 的双馈风机

**收稿日期:** 2022-08-25; **修回日期:** 2023-04-27。

**基金项目:** 宁夏回族自治区自然科学基金资助项目 (2022 AAC03612)。

控制系统参数辨识方法。基于 RT-LAB 半实物仿真平台获得来自真实控制器的双馈风机硬件在环测试数据,采用 Person 相关系数法提取高相关性特征并进行神经网络训练,利用 LSTM 神经网络对双馈风机的控制参数进行辨识。

## 1 网侧控制系统建模

图 1 给出了双馈风机的网侧变流器控制模型,采用电网电压定向矢量双闭环控制<sup>[16]</sup>,电压外环用于控制直流母线电压,电流内环  $d$  轴的参考值  $i_{dg\_ref}$  由直流电压外环计算得到,根据文献<sup>[17]</sup>,电流内环  $q$  轴的参考值  $i_{qg\_ref}$  设置为 0。根据图 1 所示的控制框图搭建双馈风机的辨识模型,辨识模型中变压器、滤波器和其他元件的电气参数与半实物测试模型的电气参数一致。

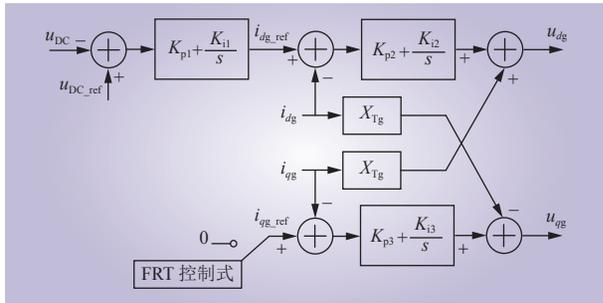


图 1 网侧变流器控制框图

Fig. 1 Diagram of grid-side converter

假设中间变量为  $x_1$ 、 $x_2$ 、 $x_3$ ,网侧变流器的控制方程可写为

$$\frac{dx_1}{dt} = u_{DC\_ref} - u_{DC} = -\Delta u_{DC} \quad (1)$$

$$i_{dg\_ref} = -K_{p1}\Delta u_{DC} + K_{i1}x_1 \quad (2)$$

$$\frac{dx_2}{dt} = i_{dg\_ref} - i_{dg} = -K_{p1}\Delta u_{DC} + K_{i1}x_1 - i_{dg} \quad (3)$$

$$\frac{dx_3}{dt} = i_{qg\_ref} - i_{qg} \quad (4)$$

式中:  $K_{p1}$ 、 $K_{i1}$  分别为电压控制器的比例和积分系数;  $u_{DC}$ 、 $u_{DC\_ref}$  分别为直流母线电压的实际值和参考值;  $\Delta u_{DC}$  为直流母线电压实际值与参考值的差值;  $i_{dg}$ 、 $i_{qg}$  分别为网侧  $d$ 、 $q$  轴电流的实际值。

结合式 (1) ~ (4) 可得

$$u_{dg} = K_{p2}(-K_{p1}\Delta u_{DC} + K_{i1}x_1 - i_{dg}) + K_{i2}x_2 + X_{Tg}i_{qg} \quad (5)$$

$$u_{qg} = K_{p3}(i_{qg\_ref} - i_{qg}) + K_{i3}x_3 - X_{Tg}i_{dg} \quad (6)$$

式中:  $K_{p2}$ 、 $K_{i2}$  分别为电流内环控制器的第 1 组比例和积分系数;  $K_{p3}$ 、 $K_{i3}$  分别为电流内环控制器的第 2 组比例和积分系数;  $u_{dg}$ 、 $u_{qg}$  分别为网侧  $d$ 、 $q$  轴电压的实际值;  $X_{Tg}$  为连接在变流器和电网之间的变压器电抗值。

正常工况下,  $i_{qg\_ref}$  一般为 0,但在故障工况下,  $i_{qg\_ref}$  由低电压穿越控制模块直接给定,其值为

$$i_{qg\_ref} = \begin{cases} 0, & U_N > 0.9 \text{ p.u.} \\ kI_N(0.9 - U_N), & 0.2 \text{ p.u.} \leq U_N \leq 0.9 \text{ p.u.} \end{cases} \quad (7)$$

$$I_N = \sqrt{i_{dg}^2 + i_{qg}^2} \quad (8)$$

式中:  $k$  为无功电流支撑系数;  $U_N$  为风机并网点额定电压;  $I_N$  为网侧变流器额定电流。

当低电压穿越发生时,网侧变流器会发出一定的无功功率,无功电流的数值可根据式 (7) 得到,此时,  $q$  轴电流内环切换到低电压穿越控制模式,  $q$  轴参考值由低电压穿越控制模块给定。

## 2 基于 LSTM 的参数辨识方法

### 2.1 关键特征提取

在搭建双馈风机 LSTM 神经网络参数辨识模型前,需采集特征-输出数据集,其中输入特征值为与风机网侧控制器有关的参数,包括直流母线电压  $u_{DC}$ 、输出电流的  $dq$  分量  $i_{dg}$  和  $i_{qg}$  及其与硬件在环测试数据的误差值  $R$ ,输出值为网侧变流器的控制参数。由于不同模型对特征的要求不同,无关特征或特征过少不仅会导致神经网络训练效果明显变差,还会大幅削弱神经网络的泛化能力<sup>[18]</sup>,导致损失函数 Loss 上升。因此,在训练神经网络模型前,需增加输入特征集维度并去除无关特征。

为了增加输入特征集维度,依据 NB/T 31066—2015《风电机组电气仿真模型建模导则》,以  $u_{DC}$  为例,如图 2 所示,将仿真时间划分为 5 个区间:稳态区间 A、C 和 E,暂态区间 B 和 D,并将输入特征值中的  $u_{DC}$ 、 $i_{dg}$  和  $i_{qg}$  通过此方式分区间取值作为特征集。其中  $u_{DC}$  通过分区间取值后得到特征值  $V_a$ 、 $V_b$ 、 $V_c$ 、 $V_d$  和  $V_e$ ,  $i_{dg}$  通过分区间取

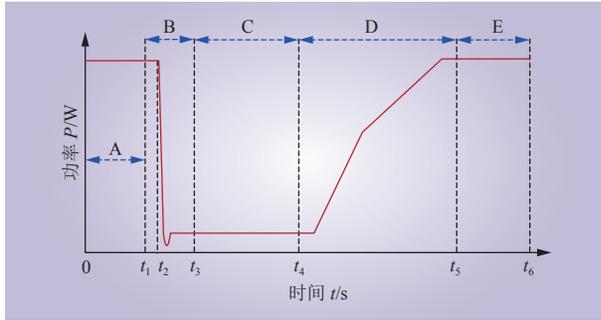


图 2 仿真结果的区间划分

Fig. 2 Interval division diagram of simulation results

值后得到特征值  $I_{da}$ 、 $I_{db}$ 、 $I_{dc}$ 、 $I_{dd}$  和  $I_{de}$ ， $i_{qg}$  通过分区间取值后得到特征值  $I_{qa}$ 、 $I_{qb}$ 、 $I_{qc}$ 、 $I_{qd}$  和  $I_{qe}$ 。

为了去除无关特征，采用 Person 相关系数法对增加维度后的特征集进行相关性分析，相关系数是一种用于表征变量之间变化关系的数学统计指标，包含标准差和协方差<sup>[19]</sup>。通过估算 2 个变量之间的协方差和标准差，可得到 Person 相关系数为

$$P = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (9)$$

式中： $X_i$ 、 $Y_i$  分别为样本 1、2 的第  $i$  个数值； $\bar{X}$  为样本 1 均值； $\bar{Y}$  为样本 2 均值； $n$  为样本中数值的数量。 $P$  的绝对值越大，表明两变量之间的相关性越强。通过计算各区间特征值与输出控制参数的 Person 相关系数，最终得出  $P$  值较大的区间特征值并将其作为输入特征集。

图 3 为各特征值与待辨识参数的 Person 系数和， $I_{da}$ 、 $I_{dd}$ 、 $I_{dc}$  和  $I_{qa}$  的 Person 系数和较其他特征

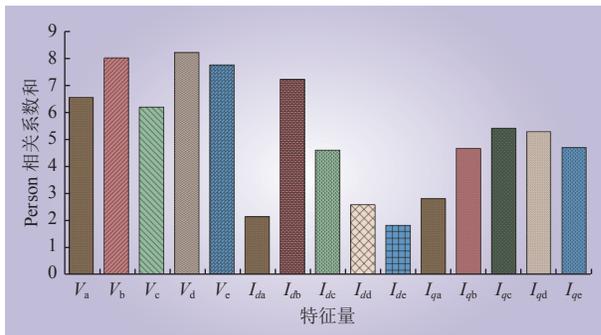


图 3 各特征值 Person 系数和

Fig. 3 Sum of Person coefficients for eigenvalues

值较小，对待辨识参数影响较小，于是在特征集中去除  $I_{da}$ 、 $I_{dd}$ 、 $I_{dc}$  和  $I_{qa}$  这 4 项输入特征值，取其余 11 项及  $R$  作为该神经网络模型的输入特征集。

## 2.2 LSTM 神经网络算法

循环神经网络 (recurrent neural Network, RNN) 主要用于处理序列数据，基础的 RNN 结构中，通常后输入的数据对训练结果产生的影响大，前输入的数据对训练结果产生的影响小，继而产生了梯度消失问题。为解决 RNN 长期依赖问题，LSTM 在 RNN 的基础上增加了遗忘机制和保存机制<sup>[20]</sup>，可保留较长序列数据中的重要信息，忽略不重要信息，以较精确的方式传递记忆。为准确模拟目标模型，首先需要采集输出参数与对应的输入特征数据集，经数据处理后，用于训练和测试 LSTM 神经网络模型。

LSTM 神经网络的神经元结构如图 4 所示，其核心细胞状态  $c$  受控于遗忘门、输入门和输出门，其中： $\sigma$  为 sigmoid 函数； $x_t$  为第  $t$  个单元的输入； $c_t$  为第  $t$  个单元的细胞状态； $h_t$  为第  $t$  个单元的隐状态； $\oplus$ 、 $\otimes$  分别为向量元素求和、求积符号； $c_{t-1}$  为第  $t-1$  个单元的细胞状态； $h_{t-1}$  为第  $t-1$  个单元的隐状态。

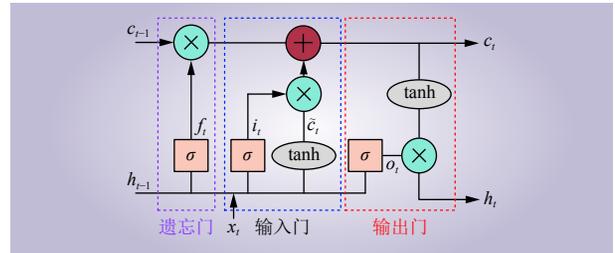


图 4 LSTM 循环单元结构

Fig. 4 Circular unit structure of LSTM

输入门用于控制网络当前输入数据流入记忆单元的数量，保存在  $c$  中，计算式为

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (10)$$

遗忘门可判断上一时刻记忆单元信息  $c_{t-1}$  对当前记忆单元  $c_t$  的影响程度，计算式为

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (11)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (12)$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes \tilde{c}_t \quad (13)$$

输出门控制记忆单元  $c_t$  对输出值  $h_t$  的影响，计算式为

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (14)$$

$$h_t = o_t \odot \tanh c_t \quad (15)$$

式中： $W_i$ 、 $W_f$ 和 $W_o$ 分别为输入门、遗忘门和输出门的网络层权重； $b_i$ 、 $b_f$ 和 $b_o$ 分别为输入门、遗忘门和输出门的偏置项； $b_c$ 为网络层偏置； $f_t$ 为遗忘门输出值； $\tilde{c}_t$ 为 $t$ 时刻输入到神经元的信息； $W_c$ 为计算 $\tilde{c}_t$ 的权重； $o_t$ 为输出门输出值； $\odot$ 为哈达玛积运算符。

在 LSTM 神经网络训练中，数据集的选择和分配及参数的调节对预测结果的准确性具有直接影响。在 LSTM 神经网络训练过程中，随机选取 90% 数据集作为训练集，10% 数据集作为验证集，设置迭代训练次数为 500，消除单次训练产生的误差，提高预测准确度。风机网侧变流器控制参数 LSTM 神经网络辨识的总体流程如图 5 所示，具体如下。

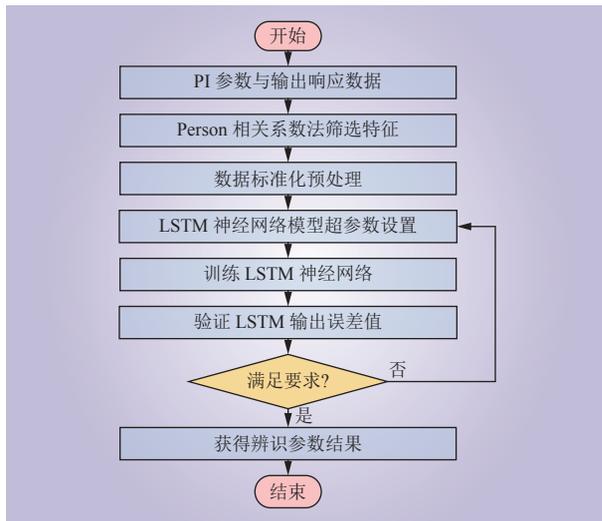


图 5 LSTM 神经网络参数辨识流程

Fig. 5 Flow chart of parameter identification based on LSTM neural network

- 1) 采集参数  $K_{p1}$ 、 $K_{i1}$ 、 $K_{p2}$ 、 $K_{i2}$ 、 $K_{i3}$ 、 $K_{i3}$  与输出响应数据集；
- 2) 增加输入特征集维度并依据 Person 相关系数法去除无关特征；
- 3) 对数据进行标准化处理，并划分样本训练集和验证集；
- 4) 初始化 LSTM 神经网络参数；
- 5) 训练 LSTM 神经网络并得到辨识结果；
- 6) 若误差小于一定值，输出最优解即为辨识结果，否则重复步骤 4) 和 5)。

### 3 仿真算例

为验证所提双馈风机控制参数 LSTM 神经网络辨识方法的可行性、有效性和准确性，在 Plescs 平台搭建双馈风机真实控制器的同构辨识模型，双馈风机控制器半实物测试平台如图 6 所示，双馈风机网侧变流器的电气参数见表 1。



图 6 双馈风机控制器半实物测试平台

Fig. 6 HIL test platform for DFIG controller

表 1 双馈风机变流器电气参数

Table 1 Electrical parameters of DFIG converter

参数	数值	参数	数值
定子电阻/ $\Omega$	0.001 83	换流器直流侧电压/V	1 100
定子漏感/H	0.000 192	换流器直流侧电容/mF	15
转子电阻/ $\Omega$	0.001 87	风机额定电压/V	690
转子漏感/H	0.000 175	风机额定功率/MW	2
互感/H	0.003 938	网侧电抗器/ $\mu$ H	280
电机极对数	3	网侧滤波电容/ $\mu$ F	334 (角接)

#### 3.1 数据获取

为了验证辨识模型对复杂工况的适应性，设置了 2 组风机并网点电压跌落程度，分别为 20% 和 80%，跌落时间从 0.95 s 持续至 1.65 s，持续时间为 0.7 s，每种工况采集 100 组数据，利用 200 组数据进行 LSTM 神经网络模型训练。电压跌落 20% 时硬件在环实验数据波形如图 7 所示，电压跌落 80% 时硬件在环实验数据波形如图 8 所示，可以看出，在电压跌落开始和恢复时有振荡产生，这是因为伴随着并网点电压跌落和恢复，双馈风力发电系统内部将出现过电流、过电压与转子转速骤升等一系列问题。

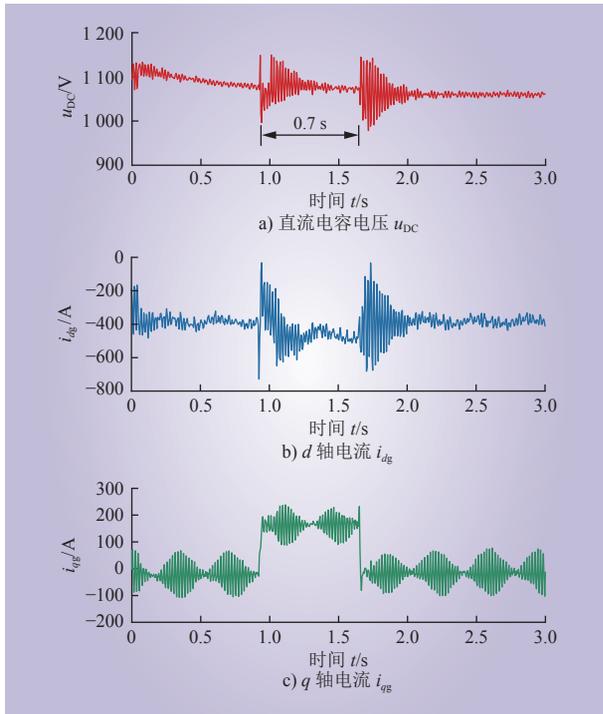


图 7 电压跌落 20% 时硬件在环实验数据波形

Fig. 7 HIL test data waveform with voltage drop of 20%

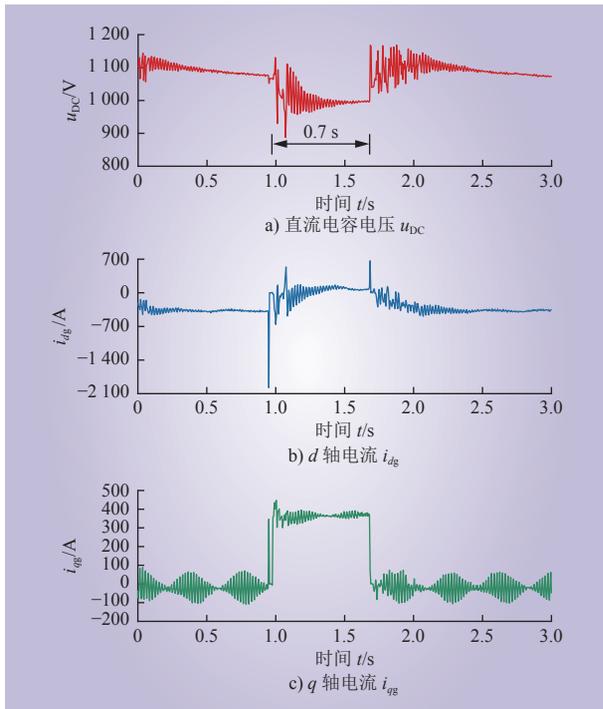


图 8 电压跌落 80% 时硬件在环实验数据波形

Fig. 8 HIL test data waveform with voltage drop of 80%

### 3.2 数据预处理

获得历史样本数据后，需对数据进行预处理以获得可供模型训练的数据集。首先，对于存在

缺失或异常数据点的历史样本进行剔除，以免影响神经网络辨识的准确度。然后，采用 Pearson 相关系数法去除无关特征，筛选出与风机  $dq$  轴输出特性相关性较高的特征变量作为神经网络的输入。最后，对所采集数据进行归一化处理，限定预处理的数据在  $[0, 1]$  内，消除奇异样本数据导致的不良影响。

### 3.3 模型训练

首先，将预处理后的 200 组数据作为 LSTM 神经网络的输入，其中 90% 作为训练集，10% 作为验证集；然后，设置损失函数 MSE 和优化器 Adam，采用 LSTM 神经网络对所采集序列进行辨识；最后，设置验证集最后一组特征为实际数据，其输出的参数作为最终辨识值。经大量调试工作后，得到 LSTM 神经网络的结构参数与网络训练参数，如表 2 所示。

表 2 LSTM 神经网络结构参数与训练参数  
Table 2 Structural and training parameters of LSTM neural network

输入维度	输出维度	隐藏层层数	隐藏层神经元数	学习率	训练次数
12	6	2	11	0.015	500

模型训练过程中，损失函数的变化过程如图 9 所示，训练 350 次后损失函数达到 0.01 以下，训练 375 次后损失函数达到 0.005 以下，训练 500 次后模型的损失函数为 0.0034。

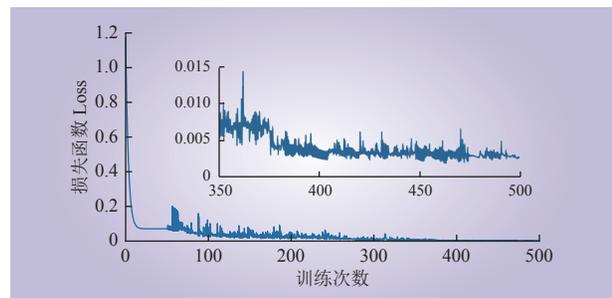


图 9 损失函数曲线

Fig. 9 Curve of loss function

不同阶段风电往往通过切换控制模式来实现控制目标，控制参数也会随之变化，一组控制参数不能完全满足对真实控制器的仿真需求，因此本文通过对稳态期间和低电压穿越期间的控制参数分别进行辨识，得到 2 组控制参数输入仿真模型。图 10 为模型训练稳态控制参数的最终结果，

图 11 为模型训练低电压穿越期间控制参数的最终结果，模型辨识结果与样本数据基本重合，取得

了良好辨识效果。

为了进一步验证所提模型辨识的有效性和实

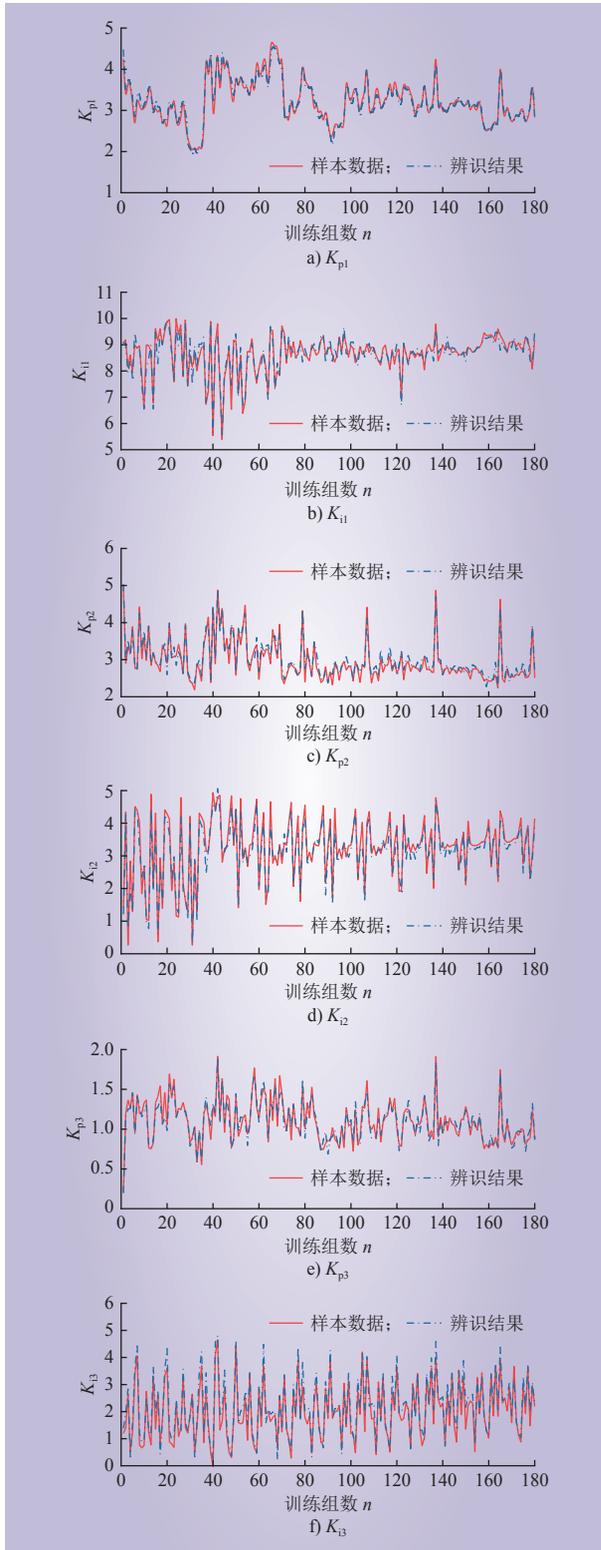


图 10 稳态控制参数训练结果

Fig. 10 Training results of steady-state control parameters

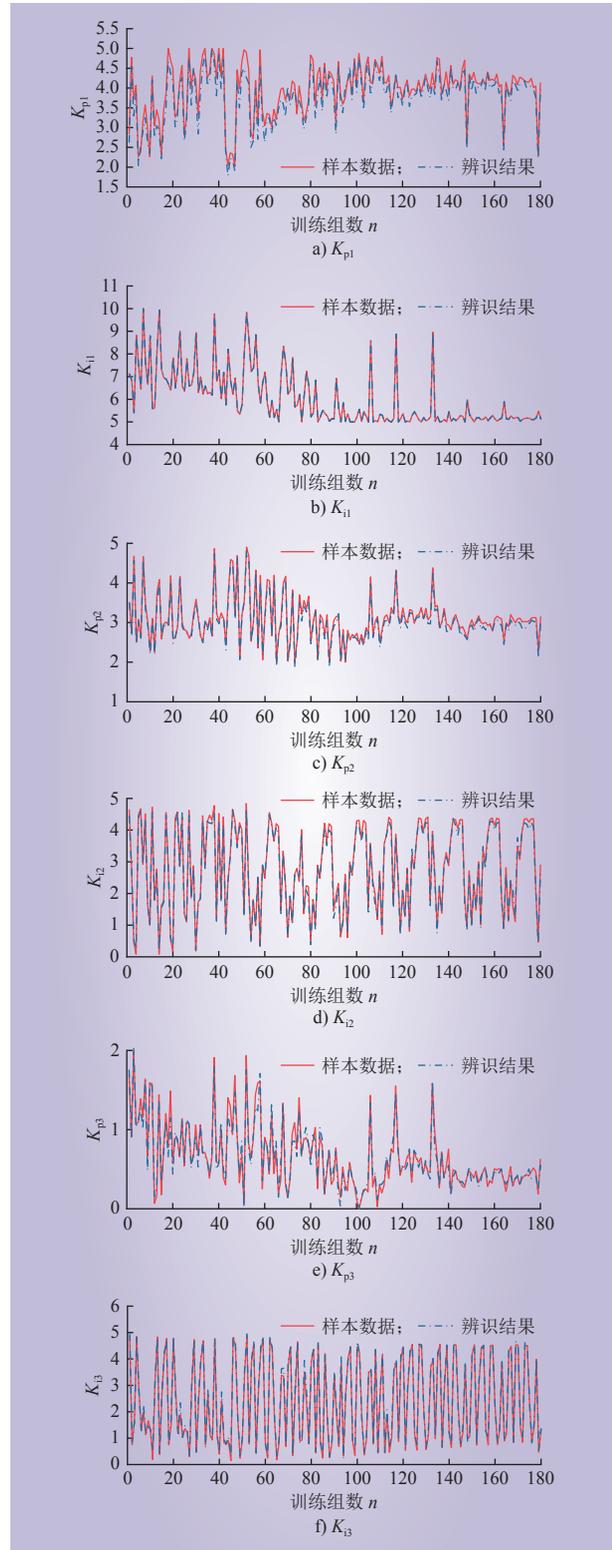


图 11 低电压穿越期间控制参数训练结果

Fig. 11 Training results of control parameters during low voltage ride through

用性，将本文的 LSTM 模型同 BP 模型及 RNN 模型进行对比，采用相同实测数据对上述模型进行训练。BP 模型和 RNN 模型参数设置如表 3 所示。

表 3 BP 和 RNN 神经网络结构参数与训练参数  
Table 3 Structural and training parameters of BP and RNN neural networks

方法	输入维度	输出维度	隐藏层层数	隐藏层神经元数	学习率	训练次数
BP	12	6	1	20	0.050	20 000
RNN	12	6	2	11	0.015	500

将 3 组辨识曲线与实测曲线对比，电压跌落 20% 条件下测试结果如图 12 所示，电压跌落 80% 条件下测试结果如图 13 所示。

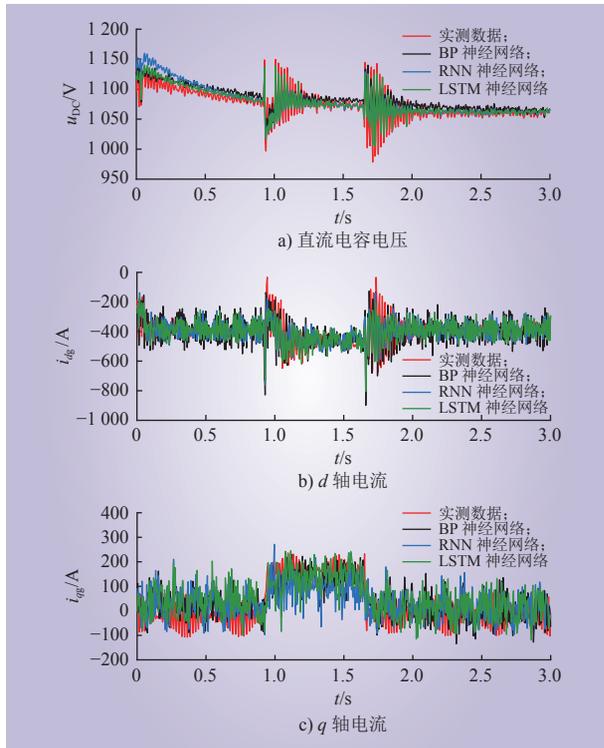


图 12 电压跌落 20% 时的输出响应  
Fig. 12 Output response with voltage drop of 20%

由图 12 和 13 可知，不同模型辨识曲线趋势相同，但在波动较为明显的时间区域，辨识误差较大，而本文 LSTM 模型得到的辨识结果与实测结果最为接近，得到的控制参数也最为接近实际控制参数。

以  $u_{DC}$  为例，按照式 (16) 分别计算电压跌落程度 20% 和 80% 下 3 种模型辨识结果在 A、B、C、D 和 E 区间的平均偏差，再对 4 种工况下的平均偏差取平均值，即

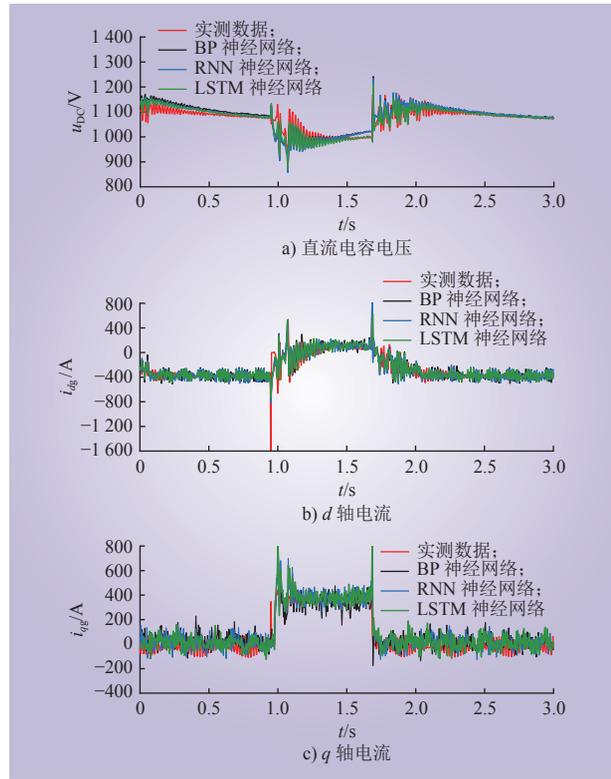


图 13 电压跌落 80% 时的输出响应  
Fig. 13 Output response with voltage drop of 80%

$$F_V = \left| \frac{\sum_{i=K_{start}}^{K_{end}} (u_M - u_i)}{K_{end} - K_{start} + 1} \right|, \quad V = A, B, C, D, E \quad (16)$$

式中： $F_V$  为区间  $V$  的平均偏差； $u_M$  为实测直流电容电压； $u_i$  为辨识模型直流电容电压； $K_{start}$ 、 $K_{end}$  分别为区间第一个和最后一个仿真数据序号。

得到 BP、RNN 和 LSTM 模型输出结果在各区间的误差如表 4 所示。

表 4 3 种辨识模型误差对比  
Table 4 Comparison of errors for three identification models

模型	$V_a$	$V_b$	$V_c$	$V_d$	$V_e$	$I_{da}$	$I_{db}$	$I_{dc}$
BP	1.15	2.88	1.45	0.94	0.87	0.35	5.13	1.35
RNN	1.72	3.39	1.89	1.32	2.01	0.13	4.01	1.22
LSTM	0.64	1.65	1.13	0.67	0.71	0.11	2.87	0.98

模型	$I_{dd}$	$I_{de}$	$I_{qa}$	$I_{qb}$	$I_{qc}$	$I_{qd}$	$I_{qe}$
BP	0.97	0.28	0.32	0.64	0.82	3.84	1.63
RNN	1.13	0.62	1.23	0.96	2.87	5.58	1.78
LSTM	0.72	0.11	0.21	0.58	0.69	2.74	1.57

由表 4 可知, 相比于 BP、RNN 模型, LSTM 模型对  $u_{DC}$ 、 $i_{dg}$ 、 $i_{qg}$  的辨识结果精度更高, 可在 A、B、C、D 和 E 区间以更高的精度辨识出 20% 和 80% 低电压穿越工况下双馈风机的控制参数  $K_{p1}$ 、 $K_{i1}$ 、 $K_{p2}$ 、 $K_{i2}$ 、 $K_{p3}$  和  $K_{i3}$ 。

## 4 结语

针对暂态工况下难以高精度获取双馈风机电磁模型控制参数的问题, 本文提出了基于 LSTM 神经网络算法的双馈风机控制参数辨识方法, 并通过测试实验证实了所提方法在双馈风机控制参数辨识问题上的可行性、有效性和实用性。相比于 BP、RNN 算法的辨识结果, 提出的 LSTM 算法或模型在 20% 和 80% 低电压穿越工况下具有更高的控制参数辨识精度。

## 参考文献:

- [1] 张兴, 孙艳霞, 李丽娜, 等. 风电机组电磁暂态建模及验证 [J]. 中国电力, 2020, 53(7): 106–112.  
ZHANG Xing, SUN Yanxia, LI Lina, *et al.* Electromagnetic transient modelling and verifying of wind turbine generator[J]. *Electric Power*, 2020, 53(7): 106–112.
- [2] JIN Y Q, LU C J, JU P, *et al.* Probabilistic preassessment method of parameter identification accuracy with an application to identify the drive train parameters of DFIG[J]. *IEEE Transactions on Power Systems*, 2020, 35(3): 1769–1782.
- [3] 李振焱, 摆世彬, 方若水, 等. 基于广域测量系统的双馈风力发电机组在线参数辨识方法 [J]. 南方电网技术, 2021, 15(5): 89–97.  
LI Zhenyao, BAI Shibin, FANG Ruoshui, *et al.* Online parameter identification method of doubly fed induction generator based on wide area measurement system[J]. *Southern Power System Technology*, 2021, 15(5): 89–97.
- [4] 陆友文, 崔昊, 陈佳宁, 等. 基于 RA-CNN 和同步相量的风电场次/超同步振荡参数智能辨识方法 [J]. 中国电力, 2023, 56(4): 46–55, 67.  
LU Youwen, CUI Hao, CHEN Jianing, *et al.* Intelligent identification method of wind farm sub-synchronous/super-synchronous oscillation parameters based on RA-CNN and synchrophasor[J]. *Electric Power*, 2023, 56(4): 46–55, 67.
- [5] 张辉, 蒲天骄, 王刚, 等. 基于实测频率轨迹的机组调速器参数辨识 [J]. 电力系统保护与控制, 2014, 42(1): 24–33.  
ZHANG Hui, PU Tianjiao, WANG Gang, *et al.* Governor parameter identification of generation system based on measured frequency curve[J]. *Power System Protection and Control*, 2014, 42(1): 24–33.
- [6] 乔腾, 张益铭, 曹一家, 等. 基于概率可靠性评估的永磁直驱风机低电压穿越控制模型参数辨识 [J]. 中国电力, 2021, 54(12): 102–111.  
QIAO Teng, ZHANG Yiming, CAO Yijia, *et al.* Parameter identification of low voltage ride-through control model for permanent magnet direct-drive wind turbine based on probabilistic reliability assessment[J]. *Electric Power*, 2021, 54(12): 102–111.
- [7] GAUTAM D, VITTAL V, HARBOUR T. Impact of increased penetration of DFIG-based wind turbine generators on transient and small signal stability of power systems[J]. *IEEE Transactions on Power Systems*, 2009, 24(3): 1426–1434.
- [8] 张仰飞, 袁越, 陈小虎, 等. 风力机参数的可辨识分析 [J]. 电力系统自动化, 2009, 33(6): 86–89.  
ZHANG Yangfei, YUAN Yue, CHEN Xiaohu, *et al.* Analysis on wind turbine parameters identifiability[J]. *Automation of Electric Power Systems*, 2009, 33(6): 86–89.
- [9] 沈欣炜, 郑竞宏, 朱守真, 等. 光伏并网逆变器控制参数的  $dq$  轴解耦辨识策略 [J]. 电力系统自动化, 2014, 38(4): 38–43.  
SHEN Xinwei, ZHENG Jinghong, ZHU Shouzheng, *et al.* A  $dq$  axis decoupling parameter identification strategy for grid-connected inverter controller of photovoltaic generation system[J]. *Automation of Electric Power Systems*, 2014, 38(4): 38–43.
- [10] 孙黎霞, 林雪, 金宇清, 等. 基于粒子群优化算法的并网光伏发电单元建模 [J]. 电网技术, 2015, 39(5): 1213–1218.  
SUN Lixia, LIN Xue, JIN Yuqing, *et al.* Modeling of grid-connected photovoltaic generation unit based on particle swarm optimization algorithm[J]. *Power System Technology*, 2015, 39(5): 1213–1218.
- [11] 金宇清, 鞠平, 潘学萍, 等. 光伏逆变器控制参数的分步辨识方法 [J]. 电网技术, 2015, 39(3): 594–600.  
JIN Yuqing, JU Ping, PAN Xueping, *et al.* A stepwise method to identify controller parameters of photovoltaic inverter[J]. *Power System Technology*, 2015, 39(3): 594–600.
- [12] 潘学萍, 鞠平, 温荣超, 等. 解耦辨识双馈风电机组转子侧控制器参数的频域方法 [J]. 电力系统自动化, 2015, 39(20): 19–25, 108.  
PAN Xueping, JU Ping, WEN Rongchao, *et al.* Decoupling estimation of parameters in rotor side controller of DFIG-based wind turbine by frequency domain method[J]. *Automation of Electric Power Systems*, 2015, 39(20): 19–25, 108.
- [13] 许饶琪, 彭晓涛, 秦世耀, 等. 基于 M 序列的双馈风机变流器参数辨识方法研究 [J]. 电网技术, 2022, 46(2): 578–586.  
XU Raoqi, PENG Xiaotao, QIN Shiyao, *et al.* Parameter

- identification of doubly-fed induction generator converter based on M-sequence[J]. *Power System Technology*, 2022, 46(2): 578–586.
- [14] 秦继朔, 贾科, 孔繁哲, 等. 基于寻优算法的永磁风机并网逆变器故障穿越控制参数分步辨识 [J]. *中国电机工程学报*, 2021, 41(增刊1): 59–69.
- QIN Jishuo, JIA Ke, KONG Fanzhe, *et al.* Stepwise parameter identification of fault ride-through control parameters of PMSG grid-connected inverter based on optimization algorithm[J]. *Proceedings of the CSEE*, 2021, 41(S1): 59–69.
- [15] 郭建军, 韩铃钰, 董佳琦, 等. 基于 SSA-PSO-LSTM 模型的羊舍相对湿度预测技术 [J]. *农业机械学报*, 2022, 53(9): 365–373, 398.
- GUO Jianjun, HAN Qianyu, DONG Jiaqi, *et al.* Prediction of sheep house humidity based on SSA PSO LSTM model[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(9): 365–373, 398.
- [16] 付敏, 盖凯凯, 林悦铭. 带滤波电路的双馈风力发电系统网侧控制策略 [J]. *控制工程*, 2017, 24(2): 396–401.
- FU Min, GAI Kaikai, LIN Yueming. Research on the control strategy of grid side of doubly-fed wind power system with filter circuit[J]. *Control Engineering of China*, 2017, 24(2): 396–401.
- [17] GÜNTHER K, SOURKOUNIS C. Investigation of virtual synchronous machine control for the grid-side converter of wind turbines with permanently excited synchronous generator[C]//*IECON* 2019-45th Annual Conference of the IEEE Industrial Electronics Society. Lisbon, Portugal. IEEE, 2019: 2395–2401.
- [18] 李温鹏, 周平. 高炉铁水质量鲁棒正则化随机神经网络建模 [J]. *自动化学报*, 2020, 46(4): 721–733.
- LI Wenpeng, ZHOU Ping. Robust regularized RVFLNs modeling of molten iron quality in blast furnace ironmaking[J]. *Acta Automatica Sinica*, 2020, 46(4): 721–733.
- [19] 陈世群, 高伟, 陈孝琪, 等. 一种基于极限学习机和皮尔逊相关系数的光伏阵列故障快速诊断方法 [J]. *电气技术*, 2021, 22(10): 57–64.
- CHEN Shiqun, GAO Wei, CHEN Xiaoqi, *et al.* A fast fault diagnosis method for photovoltaic array via extreme learning machine and Pearson's correlation coefficient[J]. *Electrical Engineering*, 2021, 22(10): 57–64.
- [20] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735–1780.

#### 作者简介:

薛飞 (1994—), 男, 硕士, 工程师, 从事新能源发电与并网、电力电子技术及应用研究, E-mail: tjuxf1010@126.com;

徐恒山 (1989—), 男, 通信作者, 博士, 硕士生导师, 从事新能源发电与并网、电力电子技术及应用研究, E-mail: xuhengshan@ctgu.edu.cn.

(责任编辑 许晓艳)

## Identification Method for Control Parameters of Doubly-Fed Induction Generator Based on LSTM Neural Network

XUE Fei<sup>1</sup>, LI Hongqiang<sup>1</sup>, LI Xutao<sup>1</sup>, XU Hengshan<sup>2</sup>

(1. Electric Power Research Institute of State Grid Ningxia Electric Power Co., Ltd., Yinchuan 750001, China; 2. College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, China)

**Abstract:** Since it is difficult to obtain highly accurate control parameters of the electromagnetic model of a doubly-fed induction generator (DFIG) under transient conditions, a high precision identification method for the control parameters of DFIG based on long short-term memory (LSTM) neural network was proposed. Firstly, the RT-LAB hardware-in-the-loop (HIL) simulation platform was used to measure and obtain the HIL data of the DFIG controller, and the identification model of DFIG was built in the Plecs platform. Secondly, the Person correlation coefficient method was used to extract highly correlated features and train the neural network. Finally, the proposed LSTM neural network was used to identify the control parameters of DFIG and compare them with the measured data. As a result, the feasibility, effectiveness, and practicability of the proposed method were verified. The results show that compared with the traditional identification methods, the proposed parameter identification method based on LSTM neural network can effectively improve the identification accuracy of the control parameters of the electromagnetic model of DFIGs under transient conditions.

This work is supported by Natural Science Foundation of Ningxia Hui Autonomous Region (No.2022AAC03612).

**Keywords:** doubly-fed induction generator; hard-in-the-loop; parameter identification; long short-term memory network; Person correlation coefficient method