

基于优化极限学习机的直流微电网并网等效建模

吴忠强, 戚松岐, 尚梦瑶, 申丹丹

(燕山大学 电气工程学院, 河北 秦皇岛 066004)

摘要:针对直流微电网的并网建模问题,提出了一种基于优化极限学习机的直流微电网并网等效建模方法。以直流微电网并网接入点的电压和功率数据分别作为极限学习机的输入和输出,构建基于极限学习机的直流微电网并网等效模型。由于极限学习机在初始化过程中,输入权值和隐层阈值随机设定且不再改变,会导致极限学习机建模缺乏自适应性,影响建模精度。利用鲨鱼气味优化算法对极限学习机的输入权值和隐层阈值进行优化,进一步提高建模精度。鲨鱼气味优化算法通过模拟鲨鱼捕猎过程进行寻优,通过气味粒子浓度引导鲨鱼位置的更新,是一种效率极高的优化算法。通过与微电网的实际仿真模型对比,验证了建模方法的合理性和准确性,说明所提方法具有较好的实际应用价值。

关键词:直流微电网;极限学习机;等效建模;鲨鱼气味优化算法;优化

中图分类号:TM 732;TP 273.4

文献标志码:A

DOI:10.16081/j.epae.202005030

0 引言

随着微电网数量、容量的不断增加,研究微电网接入对配电网的影响十分必要^[1]。由于微电网位于电网末端,其整体的动态特性影响大电网的稳定运行^[2-3]。因此,在电力系统分析时将微电网作为整体考虑,建立其等效模型,研究各部分间的相互作用^[4-9]。

微电网的建模方法包括传统的元器件搭建法^[10-11]、等效电路建模法^[12]和智能建模法。传统的元器件搭建法和等效电路建模法的缺点在于:实际电力系统由成千上万套设备构成,利用详细的元件模型进行电力系统仿真和分析既不现实又非必要。特别地,随着含可再生能源发电的微电网大量接入,其内部包含大量电力电子设备,网络拓扑结构和元件参数难以获得,给电力系统仿真分析带来极大困难。智能建模法主要包括利用神经网络和智能优化等算法对微电网进行等效建模。智能建模法的优点在于微电网可以等效为可控的“负荷”或者“电源”。因此,在电力系统仿真分析过程中需要对微电网进行等效建模,将微电网整体视为外部系统,其内部元件不必详细描述,进而降低微电网系统的整体规模,提高电力系统的仿真速度。智能建模方法为直流微电网及其并网仿真分析提供了一种思路和解决方案,所建模型具有较高的精度。文献[13]利用模糊径向基(RBF)神经网络对微电网进行等效建模,并用改进的细菌觅食算法优化神经网络的参数,得到一种可靠的建模方法。文献[14]通过RBF神经网络

对微电网进行等效建模,并利用粒子群优化算法进行参数优化,所建模型可以很好地描述微电网的运行特性。

由智能建模法所构建的微电网等效模型有效地规避了内部元件结构和参数难以获得等问题,简化了各元件间相互作用的复杂度。对一个实际微电网系统,只需要获得并网接入点的电压、电流和功率数据,建立其等效模型,无需微电网内部网络的拓扑结构和网络参数,所建模型可用于配电网的仿真分析及改进设计,有效地提高了电力系统动态仿真分析速度。

极限学习机ELM(Extreme Learning Machine)是一种新型的单隐层前向神经网络,具有训练速度快和泛化能力强的优点,已被应用于电力系统的建模分析。文献[15]利用基于粒子群优化算法的ELM进行电力变压器的故障诊断,具有较高的诊断准确率。文献[16]利用ELM进行风力发电系统的负载裕度预测,以母线的有功和无功功率作为输入、负载裕度作为输出,具有较高的预测精度。文献[17]利用ELM进行光伏发电系统的短期功率预测,通过分析预测的误差分布,将数据分为2个数据集分别进行训练,所得结果具有更高的预测精度。

本文以风/光/储/燃气轮机组成的直流微电网为研究对象,利用ELM对直流微电网进行等效建模。采用鲨鱼气味优化SSO(Shark Smell Optimization)算法对ELM的输入权值和隐层阈值进行优化,进一步提高了模型的逼近能力。SSO算法是一种新型的智能优化算法,许多应用表明其具有极高的优化效率^[18-19]。利用二者结合进行微电网的等效建模,建模精度和收敛速度都有很大提升。通过与微电网的实际仿真模型进行对比,结果表明所提方法具有很高的精度和实际应用价值。

收稿日期:2019-05-08;修回日期:2020-03-26

基金项目:河北省自然科学基金资助项目(F2016203006)

Project supported by the Natural Science Foundation of Hebei Province(F2016203006)

1 ELM

本文采用ELM建立直流微电网的等效模型,提高建模的精度和训练速度。ELM是一种新型的单隐层前向神经网络。与传统的神经网络相同,ELM由输入层、隐层和输出层组成^[20],其结构如图1所示。




图1 ELM结构图

Fig.1 Structure diagram of ELM

ELM的最大优点是训练速度极快,并且具有较强的泛化能力。将直流微电网并网点电压作为ELM的输入、功率作为ELM的输出。ELM的输入层有 N 个节点, $\mathbf{X}_s$ 为输入样本集, $\mathbf{x}_l = [x_1^l, \dots, x_i^l, \dots, x_N^l]^T$ 为样本 l 的 N 维输入向量, x_i^l 为样本 l 的第 i 个输入;隐层有 L 个节点;输出层有 H 个节点, $\mathbf{Y}_s$ 为输出样本集, $\mathbf{y}_l = [y_1^l, \dots, y_i^l, \dots, y_H^l]^T$ 为样本 l 的 H 维输出向量, y_i^l 为样本 l 的第 i 个输出。 $\mathbf{W} = [\mathbf{w}_1^T, \dots, \mathbf{w}_i^T, \dots, \mathbf{w}_L^T]^T$ 为输入权值矩阵, $\mathbf{w}_i = [w_{i,1}, \dots, w_{i,j}, \dots, w_{i,N}]$ 为输入层节点和隐层节点 i 的输入权值向量, $w_{i,j}$ 为隐层节点 i 和输入节点 j 的输入权值; $\mathbf{B} = [b_1, \dots, b_j, \dots, b_L]^T$ 为隐层阈值向量, b_j 为隐层节点 j 的阈值; $\mathbf{F} = [f_1^T, \dots, f_i^T, \dots, f_H^T]^T$ 为输出权值矩阵, $\mathbf{f}_i = [f_{i,1}, \dots, f_{i,j}, \dots, f_{i,L}]$ 为输出层节点 i 和隐层节点的权值向量, $f_{i,j}$ 为输出节点 i 和隐层节点 j 的连接权值。ELM的基本方程为:

$$y_i^l = \sum_{j=1}^L f_{i,j} g(\mathbf{w}_j \mathbf{x}_l + b_j) \quad (1)$$

其中, $g(\cdot)$ 为ELM的隐层激励函数。式(1)可表示为:

$$\mathbf{Y}_s = \mathbf{F} \mathbf{P} \quad (2)$$

$$\mathbf{P} = \begin{bmatrix} g(\mathbf{w}_1 \mathbf{x}_1 + b_1) & \dots & g(\mathbf{w}_1 \mathbf{x}_l + b_1) & \dots & g(\mathbf{w}_1 \mathbf{x}_s + b_1) \\ \vdots & & \vdots & & \vdots \\ g(\mathbf{w}_j \mathbf{x}_1 + b_j) & \dots & g(\mathbf{w}_j \mathbf{x}_l + b_j) & \dots & g(\mathbf{w}_j \mathbf{x}_s + b_j) \\ \vdots & & \vdots & & \vdots \\ g(\mathbf{w}_L \mathbf{x}_1 + b_L) & \dots & g(\mathbf{w}_L \mathbf{x}_l + b_L) & \dots & g(\mathbf{w}_L \mathbf{x}_s + b_L) \end{bmatrix} \quad (3)$$

$$\mathbf{F} = \begin{bmatrix} f_{1,1} & \dots & f_{1,j} & \dots & f_{1,L} \\ \vdots & & \vdots & & \vdots \\ f_{i,1} & \dots & f_{i,j} & \dots & f_{i,L} \\ \vdots & & \vdots & & \vdots \\ f_{H,1} & \dots & f_{H,j} & \dots & f_{H,L} \end{bmatrix} \quad (4)$$

$$\mathbf{Y}_s = [\mathbf{y}_1, \dots, \mathbf{y}_l, \dots, \mathbf{y}_s] \quad (5)$$

其中, $\mathbf{P}$ 为隐层输出矩阵; s 为样本总数。输出权值矩阵 $\mathbf{F}$ 的计算公式为:

$$\mathbf{F} = \mathbf{Y}_s \mathbf{P}^* \quad (6)$$

其中, $\mathbf{P}^*$ 为矩阵 $\mathbf{P}$ 的广义逆矩阵。

综上所述,ELM的学习过程如下:①确定隐层节点总数 L ,并选择隐层激励函数 $g(\cdot)$;②随机初始化输入权值 $\mathbf{W}$ 和隐层阈值向量 $\mathbf{B}$;③根据式(3)计算出隐层输出矩阵 $\mathbf{P}$;④根据式(6)计算出输出权值矩阵 $\mathbf{F}$ 。

2 ELM的参数优化

本文利用SSO算法优化ELM,使所建直流微电网模型更加精确,并具有一定的泛化能力。

2.1 SSO算法

SSO算法是一种新型的智能优化算法,通过模拟鲨鱼觅食行为进行寻优。首先,在搜索域内生成一组初始气味粒子,优化问题可行解的初始值为 $[\mathbf{X}_1^1, \dots, \mathbf{X}_i^1, \dots, \mathbf{X}_M^1]$,其中 M 为气味粒子总数, $\mathbf{X}_i^1 = [x_{i,1}^1, \dots, x_{i,j}^1, \dots, x_{i,n}^1]$ 为第 i 个初始气味粒子的位置向量,其中 n 为优化问题的决策变量个数, $x_{i,j}^1$ 为初始位置坐标即决策变量。设鲨鱼进行搜索时的初始位置为任意气味粒子的位置。气味粒子的浓度表示鲨鱼与猎物的距离,气味越浓则鲨鱼与猎物的距离越近,在算法中以适应度函数表示。鲨鱼优先靠近气味浓度比较高的粒子,即SSO算法的寻优过程为向气味浓度更高的粒子移动的过程。定义 M 维最初速度矢量为 $[\mathbf{V}_1^1, \dots, \mathbf{V}_i^1, \dots, \mathbf{V}_M^1]$,其中 $\mathbf{V}_i^1 = [v_{i,1}^1, \dots, v_{i,j}^1, \dots, v_{i,n}^1]$, $v_{i,j}^1$ 为第 j 维气味粒子的速度。

当鲨鱼跟踪气味时,速度 $\mathbf{V}_i^k$ 会随着气味浓度的增加而增大,即:

$$\mathbf{V}_i^k = \eta_k R_1 \nabla(O_F) \Big|_{\mathbf{X}_i^k} \quad (7)$$

其中, η_k, R_1 为在 $(0, 1)$ 范围内均匀分布的随机数; $\nabla(O_F)$ 为适应度函数 O_F 的梯度; k 为迭代次数。由式(7)可得鲨鱼在各个坐标下的速度:

$$v_{i,j}^k = \eta_k R_1 \frac{\partial(O_F)}{\partial x_{i,j}^k} \quad (8)$$

由于鲨鱼在前进过程中是有加速度的,鲨鱼速度应取决于前一个阶段的速度。鲨鱼的每个维度的速度变为:

$$v_{i,j}^k = \eta_k R_1 \frac{\partial(O_F)}{\partial x_{i,j}^k} + \alpha_k R_2 v_{i,j}^{k-1} \quad (9)$$

其中, $\alpha_k \in (0, 1)$ 为第 k 次迭代的惯性系数; R_2 为在 $(0, 1)$ 范围内均匀分布的随机数。在寻优过程中,由于不断地迭代,鲨鱼的速度会不断增加,鲨鱼的速度

增长的限制条件为:

$$|v_{i,j}^k| = \min \left(\left| \eta_k R_1 \frac{\partial(O_F)}{\partial x_{i,j}^k} + \alpha_k R_2 v_{i,j}^{k-1} \right|, |\beta_k v_{i,j}^{k-1}| \right) \quad (10)$$

其中, β_k 为第 k 次迭代的速度限制比。在寻优过程中鲨鱼的运动方式有前进运动和旋转运动。鲨鱼因前进运动产生的新位置为:

$$Y_i^{k+1} = X_i^k + V_i^k \Delta t_k \quad (11)$$

其中, Δt_k 为第 k 次迭代的时间。除了前进运动外, 鲨鱼还会在路径上进行旋转运动, 即:

$$Z_i^{k+1,m} = Y_i^{k+1} + R_3 Y_i^{k+1} \quad (12)$$

其中, $m=1, 2, \dots, c$ 为搜索点编号, c 为搜索点总数; $Z_i^{k+1,m}$ 在 Y_i^{k+1} 附近通过连接点可以得到一个类似鲨鱼旋转运动的闭合轮廓; R_3 为在 $[-1, 1]$ 范围内均匀分布的随机数。在旋转运动过程中鲨鱼向气味浓度更强的方向前进, 持续搜索。为得到更好的优化结果, 应使适应度函数值最大化, 即:

$$X_i^{k+1} = \operatorname{argmax} \{O_F(Y_i^{k+1}), O_F(Z_i^{k+1,1}), \dots, O_F(Z_i^{k+1,m})\} \quad (13)$$

其中, $\operatorname{argmax} \{\cdot\}$ 为满足函数为最大值的自变量集合。

SSO算法通过鲨鱼的前进运动和旋转运动分别得到了位置 Y_i^{k+1} 和 $Z_i^{k+1,m}$, 因此通过式(13)得到二者的适应度值, 更大值所对应的位置作为鲨鱼下一个搜索过程的起始点, 鲨鱼的前进运动和旋转运动一直循环, 直到迭代次数 k 达到最大迭代次数 $k_{\max}$ 。

2.2 ELM的参数优化

在训练过程中ELM的输入权值和隐层节点阈值随机选取且固定不变, 而输出权值由式(6)调整。由于输出权值采用广义逆方法得到, ELM的训练速度快且泛化能力强, 但该过程中输入权值和隐层节点阈值固定不变, 导致ELM的逼近能力不能达到最优。本文采用SSO算法优化ELM的输入权值和阈值, 建模精度更高。相较于其他网络(如神经网络), 基于SSO算法的ELM(SSO-ELM)可有效避免陷入局部极小的问题(如基于梯度法的神经网络), 并且具有训练速度快、建模精度高的优势。相比于传统优化算法的单一寻优方式, SSO算法在寻优过程中存在2种方式, 可以得到更加精确的寻优结果, 避免陷入局部最优。

本文将ELM的输入权值 W 和隐层节点阈值 B 作为SSO算法的优化对象。通过对ELM进行训练计算其适应度值, 作为鲨鱼运动位置的更新依据。SSO算法中气味粒子的位置代表ELM的输入权值和隐层阈值。本文选取ELM训练的均方根误差作为适应度的判断依据, 即:

$$E = \sqrt{\frac{\sum_{i=1}^H (y_i^l - y_i^{ls})^2}{H}} \quad (14)$$

其中, y_i^{ls} 为训练样本。

个体的适应度值越大, 此粒子的气味浓度越强, 结果越优。因此选择均方根误差的倒数构造SSO算法的适应度函数, 其值越大则ELM网络的训练误差越小。定义SSO算法的适应度函数为:

$$O_F = 1/E \quad (15)$$

SSO-ELM算法的具体步骤如下: ①在特定解空间内随机产生气味粒子群, 设定每个粒子的初始速度矢量及最大迭代次数; ②训练ELM, 得出种群的适应度值 O_F , 根据式(9)更新鲨鱼寻优过程中的速度, 并由式(11)产生前进运动过程中的新位置, 在前进路径上鲨鱼同时进行旋转运动, 其搜索方式根据式(12)进行; ③完成一次迭代后, 根据式(13)在由鲨鱼的前进运动和旋转运动所产生的若干个寻优结果中得出最优解; ④以所得最优解作为ELM的输入权值和隐层阈值, 同时训练ELM, 检验结果是否满足条件, 若满足则输出最优解, 若不满足则继续执行步骤②, 不断循环直至达到最大迭代次数。

3 微电网建模分析和讨论

3.1 微电网模型

微电网内部各分布式发电系统、负荷和储能系统通过变流器实现并网运行。交流设备通过转换器接入微电网的直流母线, 直流设备直接接入微电网的直流母线。直流微电网并网逆变器采用最大功率点跟踪控制, 控制直流母线电压恒定, 减少入网的电流谐波含量, 实现网侧单位功率因数运行, 保证能量的双向流动。

直流微电网系统结构如图2所示, 主要由光伏发电、风力发电和微型燃气轮机、储能装置及负荷构成。光伏、风力、微型燃气轮机的额定电压和功率分别为0.45、0.45、0.45 kV 和 1.5、2、3.5 MW。光伏发电采用单相双极式并网系统, 经DC/DC变流器接入直流母线, 采用最大功率点跟踪控制方式; 风力发电




图2 直流微电网结构

Fig.2 Structure of DC microgrid

系统采用双馈变速恒频风电机组,发电机转子通过AC/DC变流器并网,采用最大功率点跟踪控制方式;蓄电池系统中2个蓄电池容量均为500 A·h;负荷为三相串联阻抗负荷,其功率为3 MW。微型燃气轮机发电系统采用分轴结构,通过AC/DC变流器转换与电网相连,本文中微型燃气轮机变换器采用比例积分控制策略,维持公共母线电压稳定。

3.2 直流微电网的并网建模数据及SSO-ELM模型

利用MATLAB/Simulink软件搭建直流微电网系统,得到直流微电网在各种状态下的数据。直流微电网结构复杂,在运行过程中,并网电压和电流数据更能体现微电网的整体特性,因此,将交流配电网故障情况下微电网交流侧的实测电压数据作为输入数据、功率数据作为输出数据,对ELM进行训练。仿真时间为1 s,故障时间持续为0.1 s。若当前时刻为 t ,采用 $t-4$ 、 $t-3$ 、 $\dots$ 、 t 这5个时刻电压数据的实部和虚部作为ELM的输入数据, t 时刻的功率数据作为ELM的输出数据进行训练。其中,训练数据为6000组,测试数据为2000组。

ELM的初始化过程为随机初始化输入权值矩阵和隐层阈值向量,隐层节点个数为30;隐层激励函数 $g(\cdot)$ 为sigmoid函数, $g(x)=1/(1+e^{-x})$ 。

SSO算法的初始化过程为对100个气味粒子群进行初始化,期望误差 $E=3.5 \times 10^{-3}$,最大迭代次数为150次。

3.3 建模结果及分析

SSO-ELM模型在交流配电网发生单相接地短路、两相短路和三相短路故障下的拟合结果如图3所示。为了说明SSO-ELM模型的仿真效果,将其与RBF神经网络和ELM模型的仿真结果以及微电网的实际仿真结果进行对比分析。

3种神经网络等效建模拟合后的平均均方根误差结果如下:SSO-ELM模型为0.0769,RBF神经网络模型为0.6573,ELM模型为0.2857。虽然ELM所建模型的误差变小,模型精度有了很大提高,但仍需优化使精度进一步提高。相比于ELM模型,SSO-ELM模型的精度又有了极大改善,所建模型的误差下降了一个数量级,误差更小,跟踪效果更好,模型更加精确,更加符合建模要求。SSO-ELM模型可以很好地拟合实际仿真模型,可以替代复杂的微电网实际模型进行数据计算和预报,同时降低了计算难度。

直流微电网并网运行时,其内部各分布式发电单元和负载很可能出现不同的运行状况,为了使所建模型能更好地描述直流微电网的并网运行状态,提高建模的适用性,本文考虑负荷变化的情况,以直流微电网在负荷变化情况下的并网点的电压和功率数据分别作为SSO-ELM模型的输入和输出,建立




图3 不同故障下直流微电网并网的功率对比
Fig.3 Power comparison of parallel branches of DC microgrid under different faults

SSO-ELM模型。将负荷变化作为模型训练集,当负荷变化较大时,SSO-ELM模型的训练过程较为复杂;当负荷变化较小时,SSO-ELM模型的训练过程较为简单。训练后的SSO-ELM模型可模拟负荷变动的情况,当所建模型应用于配电网仿真时,测试集即为训练集,模型已训练好,无实时性问题。

附录中图A1给出了3种负荷发生变化时,交流配电网发生三相短路故障时的SSO-ELM拟合情况。将其与RBF神经网络模型和ELM模型的仿真结果以及直流微电网的实际仿真结果进行比较。由图A1可知,当直流微电网内部负荷发生变化时,等效模型依然可以很好地拟合微电网的运行状态。由图A1(a)可知,当微电网内部负荷均减小20%时,直流微电网的输出功率由2.1 MW提高到3.0 MW,在保证输出功率不变的同时可再向配电网提供0.9 MW的电能;由图A1(b)可知,当微电网内部负荷均增大20%时,直流微电网的输出功率由2.1 MW减少到1.3 MW,即向配电网输出的功率减少了0.8 MW。以上2种情况下直流微电网输出功率均为正。由图A1

(c)可知,当直流微电网内部负荷均增加50%时,直流微电网内部产生的电能不能满足负荷要求,需要吸收一部分配电网的电能来维持电源与负荷的平衡,此时直流微电网的输出功率为负。由图A1可知,SSO-ELM的拟合情况最优,可以实现对微电网运行状态的准确描述。

除本文提到的负荷变化外,本文所提出的建模方法同样可以拟合其他内部变化(如风机的出力变化,蓄电池控制方式的变化)时微电网的并网运行状态。本文所研究直流微电网并网接入的整体动态等效建模问题不考虑孤网运行模式,所建模型可用于配电网的仿真分析和改进设计,可提高电力系统的仿真速度。

4 结论

直流微电网的内部结构复杂,在微电网内部元件参数缺乏的情况下,建模过程极为困难。本文基于ELM对直流微电网的并网过程进行等效建模,描述直流微电网的并网运行动态特性。以SSO算法优化ELM的输入权值和隐层阈值,增强了所建模型的拟合能力,提高了模型的精确度。通过交流配电网在不同故障下的仿真算例,验证了所建模型的合理性和可靠性。所建模型能够准确地描述微电网的各种运行状态,为微电网的并网运行提供了有效的验证方式。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 沈鑫,曹敏. 分布式电源并网对于配电网的影响研究[J]. 电工技术学报,2015,30(增刊1):346-351.
SHEN Xin, CAO Min. Research on the influence of distributed power grid for distribution network[J]. Transactions of China Electrotechnical Society, 2015, 30(Supplement 1): 346-351.
- [2] 李蕊,李跃,郭威,等. 分布式电源接入对配电网可靠性影响的仿真分析[J]. 电网技术,2016,40(7):2016-2021.
LI Rui, LI Yue, GUO Wei, et al. Simulation analysis of the influence of distributed generation on the reliability of distribution network[J]. Power System Technology, 2016, 40(7): 2016-2021.
- [3] 杨珮鑫,张沛超. 分布式电源并网保护研究综述[J]. 电网技术,2016,40(6):1888-1895.
YANG Peixin, ZHANG Peichao. A survey on interconnection protection of distributed resource[J]. Power System Technology, 2016, 40(6): 1888-1895.
- [4] OLIVARES D E, MEHRIZI S A, ETEMADI A H, et al. Trends in micro-grid control[J]. IEEE Transactions on Smart Grid, 2014, 5(4): 1905-1919.
- [5] 张丹,王杰. 国内微电网项目建设及发展趋势研究[J]. 电网技术,2016,40(2):451-458.
ZHANG Dan, WANG Jie. Research on construction and development trend of micro-grid in China[J]. Power System Technology, 2016, 40(2): 451-458.
- [6] 杨新法,苏剑,吕志鹏,等. 微电网技术综述[J]. 中国电机工

程学报,2014,34(1):57-70.

- YANG Xinfu, SU Jian, LÜ Zhipeng, et al. Overview on micro-grid technology[J]. Proceedings of the CSEE, 2014, 34(1): 57-70.
- [7] 赵志宇,汪可友,李国杰,等. 含有电力弹簧的微电网能量优化模型[J]. 电力自动化设备,2019,39(10):24-31.
ZHAO Zhiyu, WANG Keyou, LI Guojie, et al. Energy optimization model for microgrid with electric spring[J]. Electric Power Automation Equipment, 2019, 39(10): 24-31.
- [8] 陈昕,张昌华,黄琦. 引入功率微分项的并网上下垂控制逆变器小信号建模与分析[J]. 电力自动化设备,2017,37(2):151-156.
CHEN Xin, ZHANG Changhua, HUANG Qi. Small-signal modeling with power differential term for droop control inverter and analysis[J]. Electric Power Automation Equipment, 2017, 37(2): 151-156.
- [9] 徐意婷,艾芊. 含微电网的主动配电网协调优化调度方法[J]. 电力自动化设备,2016,36(11):18-26.
XU Yiting, AI Qian. Coordinated optimal dispatch of active distribution network with microgrids[J]. Electric Power Automation Equipment, 2016, 36(11): 18-26.
- [10] 周围,韩礼冬,李钢,等. 基于PSCAD/EMTDC的微电网永磁直驱风力发电系统建模与仿真研究[J]. 电气技术,2016,17(2):52-57.
ZHOU Wei, HAN Lidong, LI Gang, et al. Modeling and simulation of the direct-drive permanent-magnetic wind power system in microgrid based on PSCAD/EMTDC[J]. Electrical Technology, 2016, 17(2): 52-57.
- [11] 韩洲,任永峰. 基于分布式电源的微电网建模与仿真[J]. 计算机仿真,2014,31(5):120-124.
HAN Zhou, REN Yongfeng. Modeling and simulation of micro-grid based on distributed power supply[J]. Computer Simulation, 2014, 31(5): 120-124.
- [12] BROVONT A D, PEKAREK S D. Derivation and application of equivalent circuits to model common-mode current in micro-grids[J]. IEEE Journal of Emerging & Selected Topics in Power Electronics, 2017, 5(1): 297-308.
- [13] 蔡昌春,程述成,邓志祥,等. 基于模糊RBF神经网络的直流微电网并网等效建模[J]. 电网技术,2016,40(11):3446-3452.
CAI Changchun, CHENG Shucheng, DENG Zhixiang, et al. DC microgrid equivalent modeling based on fuzzy-RBF artificial neural network[J]. Power System Technology, 2016, 40(11): 3446-3452.
- [14] 蔡昌春,邓立华,江冰,等. 基于PSO-RBF神经网络的微电网等效建模[J]. 太阳能学报,2016,37(1):76-83.
CAI Changchun, DENG Lihua, JIANG Bing, et al. Microgrid dynamic equipment modeling based on particle swarm optimization algorithm and RBF artificial neural network[J]. Acta Energiae Solaris Sinica, 2016, 37(1): 76-83.
- [15] 袁海满,吴广宁,高波. 基于DGA的粒子群极限学习机电力变压器故障诊断[J]. 高压电器,2016,52(11):176-180,187.
YUAN Haiman, WU Guangning, GAO Bo. Fault diagnosis of power transformer based on DGA particle swarm limit learning machine[J]. High Voltage Apparatus, 2016, 52(11): 176-180, 187.
- [16] DURAI PANDY P, DEVARAJ D. Development of extreme learning machine for online voltage stability assessment incorporating wind energy conversion system[C]//IEEE International Conference on Intelligent Techniques in Control, Optimization and Signal Processing. Srivilliputhur, India: IEEE, 2017: 1-7.
- [17] JING Bo, QIAN Zheng, PEI Yan, et al. Ultra short-term PV power forecasting based on ELM segmentation model[J]. The Journal of Engineering, 2017, 17(13): 2564-2568.
- [18] AHMADIGORJI M, AMJADY N. A multiyear DG-incorporated framework for expansion planning of distribution networks

using binary chaotic shark smell optimization algorithm[J]. Energy, 2016, 102(5): 199-215.

- [19] YA Wei, RUSSELL J S. Parameter identification of solid oxide fuel cell by chaotic binary shark smell optimization method [J]. Energy, 2019, 188(12): 73-79.

- [20] 陆思源, 陆志海, 王水花, 等. 极限学习机综述[J]. 测控技术, 2018, 37(10): 3-9.

LU Siyuan, LU Zhihai, WANG Shuihua, et al. Review of extreme learning machine[J]. Measurement and Control Technology, 2018, 37(10): 3-9.

作者简介:



吴忠强

吴忠强(1966—),男,上海人,教授,博士研究生导师,博士,主要研究方向为新能源发电系统的建模与控制(E-mail: mewzq@163.com);

戚松岐(1992—),男,辽宁大连人,硕士,主要研究方向为新能源发电系统的建模与控制(E-mail: 824067656@qq.com)。

(编辑 王欣竹)

Grid-connected equivalent modeling of DC microgrid based on optimized extreme learning machine

WU Zhongqiang, QI Songqi, SHANG Mengyao, SHEN Dandan

(School of Electrical Engineering, Yanshan University, Qinhuangdao 066004, China)

Abstract: Aiming at the grid-connected modeling problem of DC microgrid, a grid-connected equivalent modeling method of DC microgrid based on optimized extreme learning machine is proposed. The voltage and power data of the grid-connected point of DC microgrid are taken as the input and output of the extreme learning machine respectively, the grid-connected equivalent model of DC microgrid based on extreme learning machine is constructed. In the initialization process of extreme learning machine, input weight and hidden layer node bias are randomly set without any change later, which leads to the lack of adaptability in modeling and affects the modeling accuracy. The shark smell optimization algorithm is used to optimize the input weight and hidden layer node bias of the extreme learning machine, so as to improve the modeling accuracy. Shark smell optimization algorithm is a highly efficient optimization algorithm, which can simulate the hunting process of sharks for optimization, and the concentration of smell particles guides the updating of shark position. By comparing with the actual simulation model of microgrid, the rationality and accuracy of the modeling method are verified, indicating that the model has good practical application value.

Key words: DC microgrid; extreme learning machine; equivalent modeling; shark smell optimization algorithm; optimization

(上接第28页 continued from page 28)

Optimal multi-stage dual-Q selection for distribution network planning projects considering benefit coupling and timing correlation characteristics

SHEN Meiyang¹, HU Zhesheng², LIU Zhaoyu², DAI Pan², HUANG Jingjing², YANG Li¹


(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China;

2. State Grid Zhejiang Economic Research Institute, Hangzhou 310020, China)


Abstract: Optimal selection of distribution network planning projects for power grid enterprises under limited budget is the key for accurate investment of distribution network, but the impact of the correlation between projects on the performance improvement of distribution network is seldom quantitatively considered in current optimal selection of planning projects. The relationship of benefit coupling and timing correlation between distribution network planning projects is defined. On the basis of dual-Q planning method of distribution network and combined with different requirements of power supply reliability in different regions, the reduction of power outage loss is adopted to measure the upgrading reliability benefit of distribution network project, and an optimal multi-stage multi-area distribution network planning project selection model is built, which considers the benefit coupling and timing correlation. The case results of planning project database of distribution network with multiple power supply areas verify the reasonability and effectiveness of the proposed model.

Key words: distribution network planning; dual-Q theory; benefit coupling; timing correlation; power supply regional difference; optimal project selection


附录



(a) 直流微电网内部负荷均减小 20%



(b) 直流微电网内部负荷均增加 20%



(c) 直流微电网内部负荷均增加 50%

— 实际仿真模型, — RBF神经网络模型
 ELM模型, - - - SSO-ELM模型

图 A1 不同等效模型在直流微电网负荷变化时的功率对比

Fig.A1 Power comparison of different equivalent models when the load of DC micro-grid changes