

8-13-2020

Neural Network Inverse Control for the Output Voltage of Energy Storage Inverter in Micro-grid

Weiliang Liu

Automation Department of North China Electric Power University, Baoding 071003, China;

Yongjun Lin

Automation Department of North China Electric Power University, Baoding 071003, China;

Changliang Liu

Automation Department of North China Electric Power University, Baoding 071003, China;

Wenying Chen

Automation Department of North China Electric Power University, Baoding 071003, China;

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Neural Network Inverse Control for the Output Voltage of Energy Storage Inverter in Micro-grid

Abstract

Abstract: In order to improve the output voltage waveform quality of energy storage inverter in micro-grid, an inverse control method was proposed based on BP neural network. *Mathematical model of the energy storage inverter was established, and the main factors affecting the output voltage were analyzed, and then the expansion inverse model of the system was established based on BP neural network. In order to overcome the local optimum disadvantage in BP training algorithm, gravity algorithm was adopted to optimize the network initial parameters. The neural network inverse model was put in series with its original model to form a pseudo linear system, and then PI controller was selected to perform the single loop control.* The simulation results show that the proposed control method can effectively improve the dynamic response speed of the inverter output voltage and reduce the harmonic content. Experiment is performed on 10 kW inverter prototype, which proves the proposed method feasibility and effectiveness.

Keywords

energy storage inverter, inverse model, neural network, harmonic content

Authors

Weiliang Liu, Yongjun Lin, Changliang Liu, Wenying Chen, and Liangyu Ma

Recommended Citation

Liu Weiliang, Lin Yongjun, Liu Changliang, Chen Wenying, Ma Liangyu. Neural Network Inverse Control for the Output Voltage of Energy Storage Inverter in Micro-grid[J]. Journal of System Simulation, 2016, 28(11): 2813-2822.

基于神经网络逆控制的微网储能逆变器输出电压研究

刘卫亮, 林永君, 刘长良, 陈文颖, 马良玉

(华北电力大学自动化系, 保定 071003)

摘要: 为改善微网中储能逆变器的输出电压波形质量, 提出了一种基于神经网络的逆模型控制方法。建立了储能逆变器的数学模型, 分析了影响其输出电压的主要因素, 利用前向神经网络建立了系统的扩展逆模型; 针对 BP 训练算法容易陷入局部最优的问题, 通过万有引力算法进行了网络初始参数优化; 将神经网络逆模型与原模型串联后, 采用 PI 控制器实施闭环控制。仿真结果表明, 该方法可以有效地提高储能逆变器的动态响应速度, 并降低输出电压的谐波含量。制作了 10 kW 储能逆变器样机进行试验, 结果表明了所提方法的可行性与有效性。

关键词: 储能逆变器; 逆模型; 神经网络; 谐波含量

中图分类号: TM85 文献标识码: A 文章编号: 1004-731X (2016) 11-2813-10

DOI: 10.16182/j.issn1004731x.joss.201611024

Neural Network Inverse Control for the Output Voltage of Energy Storage Inverter in Micro-grid

Liu Weiliang, Lin Yongjun, Liu Changliang, Chen Wenyong, Ma Liangyu


(Automation Department of North China Electric Power University, Baoding 071003, China)

Abstract: In order to improve the output voltage waveform quality of energy storage inverter in micro-grid, an inverse control method was proposed based on BP neural network. *Mathematical model of the energy storage inverter was established, and the main factors affecting the output voltage were analyzed, and then the expansion inverse model of the system was established based on BP neural network. In order to overcome the local optimum disadvantage in BP training algorithm, gravity algorithm was adopted to optimize the network initial parameters. The neural network inverse model was put in series with its original model to form a pseudo linear system, and then PI controller was selected to perform the single loop control.* The simulation results show that the proposed control method can effectively improve the dynamic response speed of the inverter output voltage and reduce the harmonic content. Experiment is performed on 10 kW inverter prototype, which proves the proposed method feasibility and effectiveness.

Keywords: energy storage inverter; inverse model; neural network; harmonic content

引言

近年来, 随着传统能源的日益短缺, 由风力



收稿日期: 2015-07-10 修回日期: 2015-11-26;
基金项目: 华北电力大学中央高校科研业务费
(2015ZD17, 2014MS143);
作者简介: 刘卫亮(1983-), 男, 河北衡水, 博士生,
讲师, 研究方向为新能源与微电网技术; 林永君
(1965-), 男, 山东莱西, 博士, 教授, 研究方向为新
能源控制技术。

发电、光伏发电等新能源发电结合蓄电池、超级电容等储能单元构成的微电网成为了各国学者研究的热点^[1-2]。微电网可工作于并网模式与独立运行模式。并网模式下, 大电网可提供电压支撑; 独立运行模式下, 则需要借助于储能逆变器提供电压支撑。相对大电网而言, 微电网容量较小, 储能水平和负载的变化容易影响系统电压的波形

<http://www.china-simulation.com>

• 2813 •

质量, 尤其是非线性负载, 不仅恶化系统电压的波形质量, 甚至还会导致系统不稳定。随着用户对电能质量要求的不断提高, 这一问题成为当前亟待解决的难点。

现有的逆变器电压控制方法包括单闭环控制、双闭环控制、无差拍控制、重复控制等^[3-5]。单闭环控制具有结构简单的特点, 但是动态响应特性较差。双闭环控制具有较快的动态响应特性, 但是控制器参数不容易整定。无差拍控制与重复控制在理论上具有控制偏差小的优点, 但是对模型的依赖性较高。文献[6]考虑控制对象的非线性特点, 采用反馈精确线性化的方法进行分析和控制器设计。文献[7]提出了一种将带积分状态反馈与重复控制相结合的输出电压控制方案。文献[8]提出了一种模糊-重复混合控制方案。文献[9]提出一种基于在线自整定 PID 控制和改进重复控制相结合的综合控制策略。

逆系统方法是非线性系统控制理论的一次重要突破。基本思想为: 首先建立被控对象的逆系统, 将被控对象补偿为具有线性传递函数的系统, 再用线性系统的设计理论来完成系统的控制。该方法具有物理概念清晰、简单直观的特点。然而, 由于实际工程中被控对象较为复杂, 往往难于或无法精确建模, 逆系统的求解存在很大的困难, 使得该方法在实际应用中受到较大的限制。

人工神经网络由于对复杂非线性系统具有出色的逼近与学习功能, 在工业过程的建模和控制中获得了广泛应用。将能够实现系统线性化的逆系统方法与具有对未知非线性系统逼近能力的神经网络结合, 构建适合于工程应用的神经网络逆系统, 可充分发挥二者之长。为改善微网中储能逆变器的输出电压波形质量, 本文提出了一种基于神经网络的逆模型控制方法, 并通过仿真与样机试验对所提方法的控制效果进行验证。

1 储能逆变器输出电压影响因素分析

1.1 储能逆变器数学模型

单相 LCL 型储能逆变器拓扑结构如图 1 所示。

图中: u_{dc} 为储能单元端口电压; u_i 为逆变器输出的 PWM 脉冲序列电压; i_1 为逆变器输出电流; u_c 为滤波电容电压; i_c 为滤波电容电流; i_o 为滤波电感 L_2 上的电流(负载电流); r 为考虑各种阻尼因素的综合等效电阻; u_o 为逆变器输出电压; Z 为系统等效负载; 理想功率开关器件 IGBT 模块 $S_1 \sim S_4$ 组成逆变桥, 采用单极性脉宽调制方式, d 为 PWM 控制信号占空比。当开关频率足够高时, 依据平均状态模型, 有 $d=u_{iA}/u_{dc}$, 其中, u_{iA} 为 u_i 的平均值。




图 1 单相储能逆变器拓扑结构

取逆变器输出电流 i_1 , 电感电流(负载电流) i_o 和滤波电容电压 u_c 作为状态变量, 根据基尔霍夫定律的电压和电流方程, 可列出系统状态方程:

$$\begin{bmatrix} \dot{i}_1 \\ \dot{i}_o \\ \dot{u}_c \end{bmatrix} = \begin{bmatrix} -\frac{r}{L_1} & 0 & -\frac{1}{L_1} \\ 0 & -\frac{Z}{L_2} & \frac{1}{L_2} \\ \frac{1}{C} & -\frac{1}{C} & 0 \end{bmatrix} \begin{bmatrix} i_1 \\ i_o \\ u_c \end{bmatrix} + \begin{bmatrix} \frac{1}{L_1} \\ 0 \\ 0 \end{bmatrix} u_i \quad (1)$$

$$u_o = \begin{bmatrix} 0 & Z & 0 \end{bmatrix} \begin{bmatrix} i_1 \\ i_o \\ u_c \end{bmatrix} \quad (2)$$

由式(1)(2)可得出逆变器输出电压 u_o 与 PWM 控制信号占空比 d 之间的传递函数 $G(s)$, 为:

$$G(s) = \frac{u_{dc} \times}{L_1^2 L_2 C s^3 + (Z C L_1^2 + r C L_1 L_2) s^2 + \frac{Z L_2}{(r Z C L_1 + L_1^2 + L_1 L_2) s + L_1 Z + L_1 r}} \quad (3)$$

显然, 系统的相对阶为 3, 满足可逆性条件^[10]。

1.2 影响因素分析

依据储能逆变器数学模型, 对影响其输出电压的主要因素分析如下:

(1) 负载 Z 。依据式(3)可知, 负载 Z 直接影响系统的开环传递函数。当负载 Z 为 RLC 型负载时, 可认为系统呈线性, 但 Z 的大小对传递函数的特性有较大影响。以电阻负载型为例, 依据表 1 中的参数绘制不同 R 时系统的开环传递函数伯德图, 如图 2 所示。可知, 伯德图的相角裕量均为负值, 系统不稳定, 且 R 的大小对相角裕量有显著影响, R 越大, 相角裕量也越大; 当 Z 为非线性负载时, 系统为非线性系统。整流性负载是最常见的非线性负载, 对应整流桥导通与关断, 可以将其看做为空载与等效重载的周期性切换, 因而容易造成逆变器输出电压的畸变^[11]。负载电流 i_o 的变化可代表负载 Z 的变化, 因此可将 i_o 做为扰动量, 引入逆变器输出电压的控制中进行补偿。

表 1 系统主要参数

参数名称	参数值	参数名称	参数值
滤波电感 $L1/mH$	4.7	开关频率 f_c/kHz	20
滤波电容 $C/\mu F$	6.8	储能单元端口电压/V	400
滤波电感 $L2/mH$	1.2	逆变器输出电压/V	220
线路等效电阻 r/Ω	0.05	逆变器容量/kW	10




图 2 伯德图

(2) 储能单元端口电压 u_{dc} : 其大小与储能单元的荷电状态有关, 储能逆变器长时间工作时, u_{dc} 将会有较大的变化。由(3)式可知, u_{dc} 的大小直接影响系统开环传递函数的增益, 进而影响逆变器输出电压的稳态值。

(3) 滤波电容电压 u_c : 做为系统的状态变量, 可反映滤波器的工作状态, 从而影响逆变器输出电

压的动态变化过程。

(4) PWM 控制信号占空比 d : 做为逆变器的控制量, 直接影响输出电压的稳态值。

2 神经网络逆模型结构

2.1 人工神经网络简介

人工神经网络(Artificial Neural Network, ANN)的基本组成单位为神经元, 通过神经元间广泛互联, 实现信息的并行分布式处理。按结构划分, 可分为静态网络和动态网络。多层前向网络是最为典型的一种静态网络, 因其结构简单, 在控制领域得到了普遍应用。由于网络训练时常采用误差反向传播(Back Propagation)算法, 因此也称为 BP 网络。BP 网络包括输入层(input layer)、若干隐含层 (hide layer)和输出层(output layer), 典型的 3 层 BP 网络结构如图 3 所示。




图 3 典型的 3 层 BP 网络结构

令 $X=(x_1, x_2, \dots, x_i)^T$ 与 $Y=(y_1, y_2, \dots, y_m)^T$ 分别网络的输入和输出, 则输入层神经元与输出层神经元的输出分别为:

$$s_j = f\left(\sum_{i=1}^l w_{ji}x_i + b_j\right), 1 \leq j \leq h \quad (4)$$

$$y_k = f\left(\sum_{j=1}^h w_{kj}s_j + b_k\right), 1 \leq k \leq m \quad (5)$$

式中: f 是神经元转移函数; w_{ji} 为输入层神经元与隐含层神经元之间的连接权值; w_{kj} 为隐含层神经元与输出层神经元之间的连接权值; b_j 和 b_k 分别表示隐含层神经元与输出层神经元的阈值。

采用 BP 算法训练神经网络时,受初始权值和阈值随机性选择的影响,容易陷入局部最优。借助于具有全局寻优能力的智能优化算法确定神经网络的初始权值和阈值,能够有效的弥补 BP 算法的上述缺陷^[12-13]。万有引力算法(Gravitation Search Algorithm, GSA)是新近出现的一种启发式智能优化算法,能够有效的获取全局最优解。文献[14]验证了 GSA 的全局优化能力明显优于粒子群等常规随机搜索算法。本文利用万有引力算法确定神经网络的初始权值和阈值,再利用 BP 算法开展网络训练,以提高模型的训练精度。

2.2 神经网络逆系统结构

对典型的单输入单输出非线性系统 $y=f(u)$, 通过在原系统前串联神经网络逆系统模型 $u=f^{-1}(y^*)$, 可实现系统的伪线性化处理。为充分利用原系统的相关信息,增强逆系统的泛化能力,拓宽其适用范围,可以进一步将原系统中的重要状态变量及干扰量等引入神经网络输入端,从而构建出扩展结构的神经网络逆系统模型^[10],如图 4 所示。

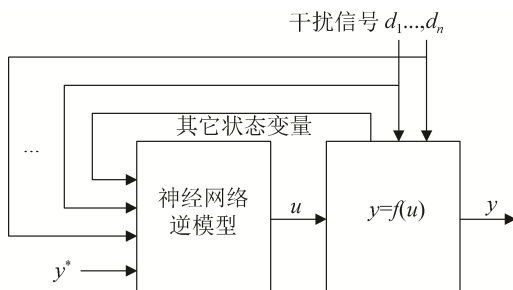


图 4 扩展结构的神经网络逆系统模型

2.3 输出电压的神经网络逆模型结构

对于储能逆变器的第 k 个控制周期,记 $d(k)$ 为该周期的 PWM 控制信号占空比,并在该周期即将结束时进行储能单元端口电压 u_{dc} 、滤波电容电压 u_c 、负载电流 i_o 、逆变器输出电压 u_o 的采样,记为 $u_{dc}(k)$, $u_c(k)$, $i_o(k)$, $u_o(k)$ 。依据对储能逆变器输出电压影响因素的分析,为了更好的反映出系统的动态特性,选取逆变器输出电压 u_o 、负载电流 i_o 的当前周期采样值 $u_o(k)$, $i_o(k)$ 和前一周期的采样

值 $u_o(k-1)$, $i_o(k-1)$, 储能单元端口电压 u_{dc} 、滤波电容电压 u_c 的前一周期的采样值 $u_{dc}(k-1)$ 、 $u_c(k-1)$, 以及前一周期的 PWM 控制信号占空比 $d(k-1)$ 做为输入,当前周期的 PWM 控制信号占空比 $d(k)$ 做为输出,构建一个包含 7 个输入和 1 个输出的动态 BP 网络。选取隐含层神经元个数为 5, 隐含层神经元转移函数采用 sigmoid 函数,输出层转移函数采用 purlin 函数。神经网络逆模型的结构见图 5。




图 5 神经网络逆模型结构

3 神经网络逆模型训练

3.1 样本收集

为提高神经网络逆模型的性能,在所建立的 10 kW 逆变器仿真模型上,收集储能单元端口电压变化以及带不同负载时的逆变器运行数据。其中,对于储能单元端口电压,共选取 6 种不同水平(以 20 V 为间隔,最低 340 V,最高 440 V),每一水平下,考虑系统带线性和非线性负载以及负载切换时的 43 种工况,如表 2 所示,共有 258 种工况。为了保证样本数据充分包含系统的动、静态信息,分别通过开环和单闭环两种控制方式进行样本收集。开环控制方式下,选取不同幅值的正弦信号和常值信号,再叠加随机信号后作为系统的 PWM 占空比信号,使其在[0,1]之间变化,采集系统的相关输出;单闭环控制方式下,通过 PI 控制器计算 PWM 占空比信号,然后采集系统的相关输出。对于每种工况,两种方式下均设定逆变桥开关频率为 20 kHz,以 50 us 为采样周期进行一个周波的样本采集,所

有工况共构成 206 400 个样本。均匀抽取其中的 185 760 个样本做为逆模型训练样本, 剩余 20 640 个样本做为逆模型精度检验样本。

3.2 万有引力算法优化 BP 网络初始参数

万有引力搜索算法是 Rashedi 等人首先提出的一种基于万有引力定律进行寻优的智能优化方法。该方法将优化问题的解视为一组在空间运行的粒子, 粒子之间通过万有引力作用相互吸引, 粒子运动遵循动力学规律, 万有引力的作用使得粒子朝着质量最大的粒子移动, 而质量最大的粒子占据最优位置, 从而可求出优化问题的最优解。算法通过个体间的万有引力相互作用实现优化信息的共享, 引导群体向最优解区域搜索^[14]。

在 D 维的搜索空间中, 设有 N 个粒子, 定义第 i 个粒子位置为 $P_i=(p_i^1, \dots, p_i^d, \dots, p_i^D)$, $i=1, 2, \dots, N$, 第 t 次迭代时, 粒子 j 对粒子 i 的万有引力定义为

$$F_{ij}^d(t) = G(t) \frac{M_{pi}(t)M_{aj}(t)}{\|P_i(t), P_j(t)\|_2} (x_j^d(t) - x_i^d(t)) \quad (6)$$

式中: $G(t)$ 为引力时间常数; $M_{pi}(t)$ 和 $M_{aj}(t)$ 分别为粒子 i 的被动惯性质量和粒子 j 的主动惯性质量。

假设引力质量与惯性质量相等, 根据每个粒子的适应度函数值计算粒子惯性质量:

$$M_{ai} = M_{pi} = M_i \quad (7)$$

$$m_i = \frac{f_i - f_{\text{worst}}}{f_{\text{best}} - f_{\text{worst}}} \quad (8)$$

$$M_i = \frac{m_i}{\sum_{j=1}^N m_j} \quad (9)$$

对于极大化问题, $f_{\text{best}} = \max f_j$, $f_{\text{worst}} = \min f_j$ 。

对于第 i 个粒子, 受到来自其它粒子引力的合力可用引力的随机加权和表示为

$$F_i^d(t) = \sum_{j \neq i} \text{rand}_j F_{ij}^d(t) \quad (10)$$

基于牛顿第二定律, 粒子 i 产生的加速度为

$$a_i^d(t) = \frac{F_i^d(t)}{M_i(t)} \quad (11)$$

则粒子的速度和位置可以更新为

$$v_i^d(t+1) = \text{rand}_i \times v_i^d(t) + a_i^d(t) \quad (12)$$

$$p_i^d(t+1) = p_i^d(t) + v_i^d(t+1) \quad (13)$$

式中: $p_i^d(t)$ 为第 i 个粒子的第 d 维的位置; $v_i^d(t)$ 为第 i 个粒子的第 d 维的速度; $a_i^d(t)$ 第 i 个粒子的第 d 维的加速度; rand_i 为 $[0, 1]$ 之间的随机数。

用万有引力算法进行 BP 神经网络的初始权值与阈值的优化, 则第 i 个粒子的位置可编码为

$$P_i=[w_{lh}, b_h, w_{hm}, b_m] \quad (14)$$

其中, $w_{lh}=\{w_{jl} \mid j=1, \dots, l, i=1, \dots, h\}$ 为输入层神经元与隐含层神经元之间的连接权值集合, $w_{hm}=\{w_{kj} \mid k=1, 2, \dots, m, j=1, \dots, h\}$ 为隐含层神经元与输出层神经元之间的连接权值集合, b_h 和 b_m 分别表示隐含层神经元与输出层神经元的阈值向量。由于所建立的 BP 网络为 7-5-1 结构, 故 $l=7, h=5, m=1$, 粒子编码长度即搜索空间维数, 为 46 维。某粒子的初始编码示意图如表 3 所示。

表 2 工况类型

工况类型	负载类型	种类	参数选取
带线性负载	电阻负载	5 种	阻值分别对应 10%, 25%, 50%, 75%, 100%额定功率 整流性负载分别对应 25%, 50%, 75%额定功率
带非线性负载	电阻负载+整流性负载	30 种	电阻负载对应 50%额定功率 整流性负载分别对应 25%, 50%额定功率 整流性负载对应 25% 额定功率
负载切换	电阻负载	8 种	空载-满载, 满载-空载, 负载突增: 10%, 25%, 50%额定功率工作条件下阻值突减 50%, 负载突减: 100%, 75%, 50%额定功率工作条件下阻值突增 50%

表 3 粒子编码示意图

$i \backslash j$	$w_{ih} = \{w_{ij} j=1, \dots, 7, i=1, \dots, 5\}$					b_{h1}	w_{hm}	b_m	
-3.48	0.41	2.10	-0.29	2.86	-0.47	-0.72	-0.30	-0.15	
0.24	-2.10	1.51	0.07	3.29	-0.62	2.74	1.85	-1.47	
-0.60	-0.30	1.87	-0.56	1.63	-1.86	1.06	0.38	-0.50	1.02
-0.42	1.66	-0.43	-0.44	0.50	-0.31	-0.33	0.55	-1.35	
-0.79	0.23	2.76	-0.57	2.35	-1.08	-4.55	-1.75	1.36	

定义粒子的适应度函数 f_i 为在训练样本上的均方差的负值:

$$f_i = -\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x})^2 \quad (15)$$

其中, n 为训练样本的个数, x_i 为期望输出(占空比 d), \hat{x} 为 BP 网络的实际输出(d 的预测值)。

优化的算法流程为:

Step 1: 初始化群体。设置粒子群体规模以及各粒子初始位置;

Step 2: 依据式(15)计算各粒子适应度函数值 f_i ;

Step 3: 更新群体中的 f_{best} 与 f_{worst} , 按照式(9)计算各粒子的质量 M_i ;

Step 4: 按照式(10)(11)计算各粒子的引力合力 F_i 与加速度 a_i ;

Step 5: 按照式(12)(13)更新各粒子的速度 v_i 与位置 P_i ;

Step 6: 返回 step2, 达到最大迭代次数后停止迭代, 此时 f_{best} 所对应的粒子位置即为优化后的 BP 神经网络初始权值与阈值。

本文设置粒子群体规模为 50 个, 最大迭代次数为 1000 次。当迭代结束后, 基于获取的网络初始权值与阈值, 利用 BP 算法进一步对网络进行训练, 得到的权值与阈值即为全局最优值。为了证明 GSA-BP 训练算法的有效性, 将其与普通 BP 算法进行了训练误差的比较, 如图 6 所示。可知, GSA-BP 训练算法可明显降低训练过程的迭代次数, 快速达到全局最优。

为进一步验证模型的精度, 计算在检验样本上的均方差 MSE, 得出 $MSE=0.0033$, 说明模型具有较高的精度。部分检验样本的误差曲线见图 7。




图 6 GSA-BP 算法与普通 BP 算法比较




图 7 部分检验样本的误差曲线

4 神经网络逆模型控制方法

理论上可以利用神经网络逆模型作为控制器直接对逆变器系统进行控制, 如图 8 所示。




图 8 神经网络逆控制器

已知当前周期的 $u_{dc}(k)$, $u_c(k)$, $u_o(k)$, $i_o(k)$, $d(k)$, $k+1$ 时刻的逆变器输出电压 u_o 的设定值 u_o^*

($k+1$), 以及下一控制周期负载电流 i_o 的估计值 $\hat{i}_o(k+1)$, 则可通过逆模型估计出下一周期的 PWM 占空比控制信号 $d(k+1)$ 。其中, $\hat{i}_o(k+1)$ 可按照下式计算:

$$\hat{i}_o(k+1) = 2i_o(k) - i_o(k-1) \quad (16)$$

但是这种控制策略过于依赖神经网络逆系统模型的精度。为了提高系统的鲁棒性, 将训练好的神经网络逆系统模型串联在原系统之前构成伪线性系统, 然后设计 PI 控制器对伪线性系统进行闭环控制, 如图 9 所示。较原系统而言, 由于伪线性系统具有较低的阶次, 从而有助于改善控制品质。

5 仿真与试验

为了验证所提逆模型控制方法的控制效果, 基于 Matlab/Simulink 环境建立了储能逆变器控制系统仿真模型。其中, 系统主要参数与表 1 一致。

分别在电阻负载与整流性负载条件下(储能单元端口电压为 400 V), 对所提逆模型控制方法与 PI 控制方法进行对比。带电阻负载(2.5 kW)时, 常规 PI 控制方法的逆变器输出电压波形和电流波形

(10 倍放大)如图 10(a)所示, 采用所提逆模型控制方法的逆变器输出电压波形和电流波形(10 倍放大)如图 10(b)所示。

可知两种控制方法都能够保证输出电压具有较高的正弦度, 进一步计算两种控制方法的逆变器输出电压总谐波畸变率 THD, 分别为 3.94%与 2.25%, 说明稳态工况下所提逆模型控制方法能够有效地降低谐波含量。

带电阻负载与整流性负载时(电阻负载 3 kW, 整流性负载 2.5 kW, 全波可控, 正负半周晶闸管触发角 $\alpha=60^\circ$), 采用常规 PI 控制方法的逆变器输出电压波形和整流性负载电流波形(10 倍放大)如图 11(a)所示; 采用所提逆模型控制方法的逆变器输出电压波形和整流性负载电流波形(10 倍放大)如图 11(b)所示。可知, 当整流桥导通与关断的瞬间, 采用两种控制方法的逆变器输出电压均发生了振荡, 其中采用所提逆模型控制方法的逆变器输出电压的振荡幅度较常规 PI 控制方法明显降低, 说明其具有抗电流扰动能力强的优点。

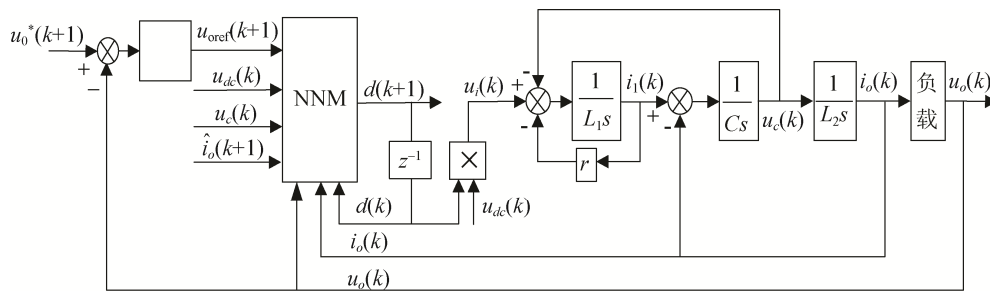


图 9 串联结构逆模型控制框图




图 10 线性负载下仿真波形对比

<http://www.china-simulation.com>




图 11 整流性负载下仿真波形

为了进一步比较上述两种控制方法下逆变器对负载切换的适应能力，令逆变器工作在满载-空载-满载切换工况，具体做法是逆变器首先满载运行， t_1 时刻突减负载，使逆变器工作在空载模式， t_2 时刻突加负载，使逆变器工作在满载模式。采用两种控制方法的逆变器输出电压、电流波形分别见图 12~13。




图 12 PI 控制下仿真波形




图 13 逆模型控制方法仿真波形

由图 12 可知，采用常规 PI 控制方法时，逆变

器由满载切换为空载后，输出电压与输出电流发生了明显振荡，大约经过 0.7 个电网周波后输出电压才能跟踪参考电压； t_2 时刻逆变器切换为满载工作，切换瞬间输出电流突然增大，输出电压明显被拉低。由图 13 可知，采用所提逆模型控制方法时，逆变器由满载切换为空载后，输出电压仅仅需要 0.1 个周波就能很好的跟踪参考电压，调节时间明显缩短； t_2 时刻逆变器切换为满载工作，切换瞬间逆变器输出电压虽然也有降低，但降低的幅度明显小于 PI 控制方法，说明逆模型控制方法较 PI 控制方法对负载切换具有更好的适应能力。

为了对所提控制方法的有效性进行验证，依据表 1 中主要参数搭建了 10 kW 储能逆变器实验样机，如图 14 所示。




图 14 储能逆变器样机

为了保证控制算法的实时性，逆变器主控制芯片选取 dsPIC33FJ16GS504 微处理器，神经网络逆模型的运算由 FPGA 实现，型号为 CycloneIV 系列的 EP4CE22F17。采用泰勒级数展开的方法对神经元 Sigmoid 转移函数中的 e^{-x} 项进行近似计算，试验发现，当展开阶数为 10 阶时，FPGA 计算的神

神经网络逆模型输出占空比的绝对误差均低于 0.02, 满足精度要求。部分样本上的 FPGA 计算的占空比误差如图 15 所示。




图 15 FPGA 计算的占空比误差

在储能单元端口电压为 400 V 时, 开展电阻负载突增、突减以及整流性负载试验。图 16 为电阻负载突增试验曲线, 开始时电阻负载为 3 kW, 某一时刻电阻负载突增为 4.5 kW。图 17 为电阻负载突减试验曲线, 开始时电阻负载为 4.5 kW, 某一时刻电阻负载突减为 3 kW。可以看出, 突增和突减负载时逆变器输出电压 u_o 波形均未发现明显失真, 说明逆模型控制方法能够有效抑制负载变化时的电压畸变。计算电阻负载为 3 kW 与 4.5 kW 工况下的电压总谐波畸变率 THD, 分别为 3.16% 与 3.64%。

图 18 为带电阻性负载与整流性负载(阻性负载 3 kW, 整流性负载 3 kW, 晶闸管触发角 $\alpha=60^\circ$) 的逆变器输出电压试验曲线, i_o 为整流性负载电流, 可以看出, 逆变器输出电压波形具有较高的正弦度, 计算该工况下的电压总谐波畸变率 THD=4.43%。




图 16 电阻负载突增




图 17 电阻负载突减




图 18 整流性负载

为了验证所提逆模型控制方法对储能单元端口电压变化的适应能力, 选取不同电压水平的四种工况进行带电阻性负载与整流性负载(电阻性负载 3 kW, 整流性负载 3 kW, 晶闸管触发角 $\alpha=60^\circ$) 试验, 并计算电压总谐波畸变率 THD, 如表 4 所示, 可知, 4 种工况下的电压总谐波畸变率较为接近, 均满足国家电网规定的 THD<5% 的电能质量要求, 说明所提逆模型控制方法对储能单元端口电压变化也具有较强的适应能力。

表 4 不同储能单元端口电压水平下逆变器输出电压 THD

储能单元端口电压/V	THD/%
355	4.71
382	4.56
415	4.32
438	3.96

6 结论

提出了一种微网储能逆变器输出电压的逆模型控制方法。通过分析主要影响因素, 利用前向神经网络建立了系统的扩展逆模型; 针对 BP 训练算法容易陷入局部最优的问题, 通过万有引力算法进行了网络初始参数优化; 将神经网络逆模型与原模

型串联后, 采用 PI 控制器实施闭环控制。仿真与样机试验结果表明, 该方法可以有效的提高储能逆变器的抗负载扰动能力, 从而降低输出电压的谐波含量。本文的下一步工作包括两方面: 一是考虑收集更多不同负载工况下的逆变器运行数据, 从而丰富逆模型的训练样本, 提高逆模型精度; 二是考虑在试验系统上进行逆模型的在线训练与更新, 从而进一步提高控制品质。

参考文献:

- [1] Chris Marnay, Owen C. The CERTS Micro-grid and the Future of the Micro-grid [DB/OL]. (2004-08-01) [2015-01-08]. <http://certs.lbl.gov/pdf/55281.pdf>.
- [2] 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, (1): 57-70.
- [3] 郭卫农, 陈坚. 基于状态观测器的逆变器数字双环控制技术研究 [J]. 中国电机工程学报, 2002, 22(9): 64-68.
- [4] Buso S, Fasolo S, Mattavelli P. Uninterruptible power supply multi-loop control employing digital predictive voltage and current regulators [J]. IEEE Transactions on Industrial Applications (S0093-9994), 2001, 37(6): 1846-1854.
- [5] Mattavelli P. An improved deadbeat control for UPS using disturbance observers [J]. IEEE Transactions on Industrial Electronics (S0278-0046), 2005, 52(1): 206-212.
- [6] 刘新民, 邹旭东, 康勇, 等. 带状态观测器的逆变器增广状态反馈控制和重复控制 [J]. 电工技术学报, 2007, 22(1): 91-95.
- [7] 张凯, 彭力, 熊健, 等. 基于状态反馈与重复控制的逆变器控制技术 [J]. 中国电机工程学报, 2006, 26(10): 56-62.
- [8] 吴忠强, 王子洋, 邬伟扬. 基于模糊自整定 PI 控制和重复控制的单相正弦脉宽调制逆变电源复合控制方案 [J]. 电网技术, 2005, 29(14): 30-34.
- [9] Zhang K, Peng L, Kang Y, et al. State-feedback-with-integral control plus repetitive control for UPS inverters [C]// IEEE Applied Power Electronics Conference and Exposition. Austin, USA: IEEE, 2005: 553-559.
- [10] 戴先中, 陈珩, 何丹, 等. 神经网络逆系统及其在电力系统控制中的应用 [J]. 电力系统自动化, 2001, 25(3): 11-17, 29.
- [11] 陈敏, 姚玮, 邱智勇, 等. 应用整流性负载模型的单相逆变器特性分析 [J]. 中国电机工程学报, 2008, 28(15): 44-48.
- [12] 王志斌, 孔亚楠, 刘永成, 等. 遗传算法优化 BP 神经网络的大功率 LED 结温预测 [J]. 光电子·激光, 2014, 25(7): 1303-1309.
- [13] 王改革, 郭立红, 段红, 等. 基于萤火虫算法优化 BP 神经网络的目标威胁估计 [J]. 吉林大学学报(工学版), 2013, 168(4): 1064-1069.
- [14] 孟超, 刘三民, 孙知信. 中心引力算法收敛分析及在神经网络中的应用 [J]. 软件学报, 2013, 24(10): 2354-2365.