

DOI: 10.7667/PSPC160077

SVD 和神经网络在孤岛检测中的应用

陶维青, 王乐勤, 顾芝瑕, 李嘉茜

(合肥工业大学电气与自动化工程学院, 安徽 合肥 230009)

摘要: 针对传统被动式检测方法存在较大检测盲区(Non-detection Zone, NDZ)、阈值难以确定以及易受电能质量扰动影响的缺陷, 研究了一种基于奇异值分解(Singular Value Decomposition, SVD)和神经网络的被动式孤岛检测方法。该方法首先对公共连接点(Point of Common Coupling, PCC)处电压和逆变器输出电流进行 S 变换, 提取相应的谐波幅值后, 对其进行 SVD 并构成特征向量, 最后运用 BP 神经网络对孤岛以及非孤岛情况进行分类识别。仿真结果表明, 该方法可以有效检测出功率平衡情况下发生的孤岛, 而且能防止电能质量扰动对检测准确性的影响, 具有很高的准确性、可靠性和实用性。

关键词: 分布式发电; 孤岛检测; S 变换; 奇异值分解; 神经网络

Application of SVD and neural network in islanding detection

TAO Weiqing, WANG Leqin, GU Zhixia, LI Jiayi

(School of Electrical and Automation Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: Aiming to the existing defects of traditional passive islanding detection methods, such as large non-detection zone, thresholds difficult to determine and the results easily affected by power quality disturbances, a novel passive islanding detecting method based on singular value decomposition (SVD) and neural network for distributed generation (DG) is proposed. Initially, the voltage at point of common coupling (PCC) and output current of inverter are processed through S-transform to derive harmonic amplitudes matrixes. Then, the feature vector is formed by applying SVD to the matrixes. Further, it is determined by BP neural network whether there is an islanding phenomenon. The simulation results show that the method is faster than the traditional passive methods in islanding detection and can still accurately detect islanding in the state of power equilibrium, and is not easily affected by power quality disturbances, owning high accuracy, reliability and practicability.

Key words: distributed generation; islanding detection; S-transform; singular value decomposition; neural network

0 引言

随着能源问题的日益突出和电力电子技术的进步, 分布式发电(Distributed Generation, DG)技术得到了深入的研究, 在越来越多分布式并网发电系统投入使用的同时, 孤岛检测技术成为目前亟待解决的关键问题之一。

目前, 孤岛的本地检测方法分为被动式和主动式^[1-6]。其中, 被动式检测法根据 PCC 处的电压或频率等参数是否超过预设的阈值来判断是否发生孤岛, 不会影响电能质量, 但是存在较大的 NDZ, 而且阈值难以确定^[2-6]。主动式检测法是利用分布式发电装置内部的控制算法对其输出产生扰动, 然后根据系统对扰动的响应来判断是否发生孤岛, 虽

然能够有效缩小 NDZ, 但是会对电能质量产生负面影响^[2-3,7-8]。

为了不影响电能质量, 众多学者对被动式检测方法进行了大量的研究。他们主要以缩小 NDZ 和合理设定阈值为目标, 分别从特征的选择和判别方法两个角度进行了深入的分析与论证。文献[9]对 DG 的输出电流进行小波变换, 并把不同频段的小波能量组成特征向量, 分别利用支持向量机、神经网络和决策树等技术进行识别, 神经网络识别的准确率最高, 但是其成功率仅有 85%左右。文献[10]将 PCC 点的电压进行小波包分解及重构, 以提取特征向量, 并利用支持向量机对其进行识别分类, 但当特定负载使得电压的特征向量在孤岛与非孤岛情况下很接近时, 准确性降低。近年来, 更多信号处

理方法, 如 S 变换^[11]、Hilbert-Huang 变换^[12]等广泛应用在孤岛检测领域, 以便有效地提取孤岛与非孤岛的表征信息; 而由于无需人为设置阈值、且具有良好的分类能力等优点, 诸多的模式识别技术, 如支持向量机^[9-10]、神经网络^[9,13]等也被引入到孤岛检测领域。

本文提出一种基于 SVD 和神经网络的孤岛检测方法, 其主要思想是对 PCC 处电压和逆变器输出电流进行 S 变换, 提取相应的谐波幅值后, 对其进行 SVD 并构成特征向量, 然后运用 BP 神经网络对孤岛与非孤岛, 如电能质量扰动、电容器投切等进行分类识别。它克服了传统被动式检测方法在逆变器输出功率与负载功率匹配时存在较大 NDZ 的缺陷, 且不用人为设定阈值; 更重要的是可以在一定程度上防止电能质量扰动对检测准确性的影响。理论分析和仿真结果表明, 该方法能够准确地检测出孤岛与非孤岛情况, 且具有很高的准确性、可靠性和实用价值。

1 基于 S 变换和 SVD 的特征向量提取

本文方法需要对 PCC 电压和逆变器输出电流进行 S 变换, 获取其特征较为明显的 3,5,⋯,13,15 次谐波幅值所组成的时频矩阵, 对其进行 SVD, 并将这些奇异值与正常情况下的奇异值之比作为特征向量用于神经网络的识别分类。

1.1 S 变换

S 变换是一种基于可移动和可伸缩的高斯窗的时频变换, 是对短时傅里叶变换和连续小波变换的发展, 具有多分辨率分析和无损可逆性等优点。

连续信号 $h(t)$ 的 S 变换(ST)定义为

$$S(\tau, f) = \int_{-\infty}^{+\infty} h(t) \frac{|f|}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}(\tau-t)^2 f^2\right) \exp(-i2\pi ft) dt \quad (1)$$

式中: $\frac{|f|}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}(\tau-t)^2 f^2\right)$ 为高斯窗口; τ 为高斯窗口的位置参数; f 为频率; i 为虚数单位。

由上式可知, S 变换相较于短时傅里叶变换, 其高斯窗口的高度和宽度随频率而变化, 从而克服了短时傅里叶变换窗口高度和宽度固定的缺陷^[14]。利用傅里叶变换和卷积定理, 由式(1)可得

$$S(\tau, f) = \int_{-\infty}^{+\infty} H(\alpha + f) \exp\left(-\frac{2\pi^2 \alpha^2}{f^2}\right) \exp(i2\pi \alpha \tau) d\alpha \quad (2)$$

式中: $H(f)$ 是 $h(t)$ 的傅里叶变换; α 是窗口的平移频率。

若设采样间隔为 T , 则 $h(kT)(k=0, 1, 2, \dots, N-1)$

是对连续信号 $h(t)$ 采样得到的离散序列, 则该序列的离散 Fourier 变换为

$$H\left(\frac{n}{NT}\right) = \frac{1}{N} \sum_{k=0}^{N-1} h(kT) \exp\left(-\frac{2\pi i kn}{N}\right) \quad (3)$$

$n = 0, 1, 2, \dots, N-1$

令式(2)中 $f \rightarrow n/NT$, $\tau \rightarrow jT$, 则一维离散 S 变换为

$$S\left(jT, \frac{n}{NT}\right) = \sum_{m=0}^{N-1} H\left(\frac{n+m}{NT}\right) \exp\left(-\frac{2\pi^2 m^2}{n^2}\right) \exp\left(\frac{i2\pi jm}{N}\right) \quad (4)$$

$n \neq 0$

特别地, 当 $n=0$ 时

$$S(jT, 0) = \frac{1}{N} \sum_{m=0}^{N-1} h\left(\frac{m}{NT}\right) \quad (5)$$

由式(4)、(5)可知, 信号 $h(kT)$ 经过 S 变换得到的是一个二维时频矩阵(即 S 矩阵), 其行向量反映了该信号中某一频率分量在不同时刻的幅值、相位信息, 相邻行之间的频率间隔 $\Delta f=1/(NT)$; 而其列向量则描述了该信号某一时刻不同频率成分的幅值和相位信息, 相邻列之间的时间间隔为 $\Delta t=T$ 。

1.2 SVD 理论

根据奇异值理论^[15], 若矩阵 $A \in R^{m \times n}$, $\text{rank}(A)=r$, 则存在两个正交阵: $U=[u_1, u_2, \dots, u_m] \in R^{m \times m}$; $V=[v_1, v_2, \dots, v_n] \in R^{n \times n}$ 。

使得

$$A = U \Lambda V^T = U \begin{bmatrix} \Sigma & 0 \\ 0 & 0 \end{bmatrix} V^T = \sum_{k=1}^r \lambda_k u_k v_k^T \quad (6)$$

式中, $\Sigma = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_r)$, λ_k 按降序排列构成矩阵 A 的非零奇异值, 也是 $A \times A^T$ 或 $A^T \times A$ 的特征值平方根。

在本文中, A 包含有 PCC 电压和逆变器输出电流的时频信息, 相应的 u_k, v_k 分别为频率和时间信息, 而奇异值 λ_k 则反映了在该时频段信息量的大小。

1.3 特征向量提取

对于通过并网逆变器与电网相连的 DG 来说, 在并网时, DG 单元与电网一起向本地负载供电, PCC 电压受到电网的钳制, 其谐波含量很小。孤岛发生后, 由于失去电网支撑, DG 单元单独向本地负载供电, 受逆变单元和非线性负载的影响, PCC 电压的谐波分量凸显^[11]; 同时, 由于逆变器控制系统的作用, 其输出电流也会发生变化。因此, 从 PCC 电压和逆变器输出电流中可以提取有效反映孤岛与非孤岛的信息。

本文通过分析 PCC 电压和逆变器输出电流时频矩阵中的 3,5,⋯,13,15 次谐波幅值, 并对其进行 SVD, 进而构造用于孤岛检测的特征向量。首先,

由于电力系统中含有双向对称元件，其半波对称性使得电压、电流的偶次谐波较小，不同情况下变化不明显，可以不予考虑。其次，分析的谐波次数越多，S变换和SVD计算所消耗的时间越长，检测的快速性降低，同时会占用过多的硬件资源，不利于控制器执行其他任务，所选取的谐波在能够准确反映孤岛与非孤岛特性的同时，其数量不宜过多；最后，单独使用电压或者电流信息，可能会造成特定负载下的模态混淆，综合电压和电流信息能够有效减少模态混淆造成孤岛检测的误判。这样，当电压信号处于特定负载情况下而产生状态混淆时，可以通过电流信号构成的特征向量来提高孤岛与非孤岛状态的辨识度；当电流信号容易造成状态混淆时，则利用电压信号构成的特征向量来提高对系统运行状态识别的准确度。综上所述，本文决定从PCC电压和逆变器输出电流时频矩阵中的3,5,⋯,13,15次谐波提取信息构成特征向量。

如果直接将S变换时频矩阵中3,5,⋯,13,15次谐波用于神经网络识别分类，不但数据量较大，训练和分类过程计算复杂，而且过多的特征并不能保证分类的准确性^[16]。因此，需要对S变换后的谐波信息进行有效的提取。SVD可以将信号中的不同分量分解到各时频子空间之中，其信息量以奇异值的大小定量的描述，不仅能显著减少用于识别分类的数据，而且能有效提取特征信息。

本文孤岛检测特征向量提取步骤如图1所示。

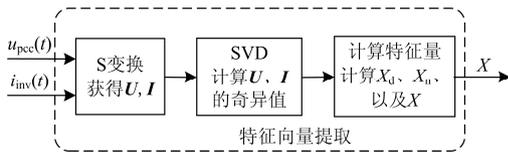


图1 特征向量提取示意图

Fig. 1 Schematic diagram of extracting feature vector

1) 采集PCC电压 u_{pcc} 和逆变器输出电流 i_{inv} ，分别对其进行S变换，并选取时频矩阵中的3, 5, ⋯, 13, 15次谐波对应的行向量组成新的矩阵 $U=[U_3, U_5, \dots, U_{15}]^T$ 和 $I=[I_3, I_5, \dots, I_{15}]^T$ ；

2) 对 U 和 I 进行SVD，得到14个奇异值，并将其组成向量 $X_d=[x_{d1}, x_{d2}, \dots, x_{d14}]$ ；

3) 以同样的方法计算正常并网情况下的向量 X_n ，取 $X=[x_{d1}/x_{n1}, x_{d2}/x_{n2}, \dots, x_{d14}/x_{n14}]$ 将其作为孤岛检测的特征量。

2 孤岛检测原理及其算法设计

通过S变换和SVD所获得的特征向量虽然能够反映孤岛发生与否，但是仍然难以通过人为设定

阈值进行识别分类；而且实际中特征向量还会受到电能质量扰动，如电压突升、突降、波动等因素的影响，人为设定的阈值容易使孤岛检测发生误判。人工神经网络的学习能力和分类功能，使其能够对非线性系统进行辨识，而其中的BP神经网络更是以其优秀的分类能力得到了广泛的应用与检验^[13]。因此，本文使用BP神经网络对提取的特征进行分类，以便提高孤岛检测的准确性和可靠性。

BP神经网络由输入层、隐含层和输出层三层组成，其主要思想是通过一边向后传递误差，一边修正误差的方法来调节网络的权值和阈值参数。本文孤岛检测方法中特征向量空间含有14个特征量，所以输入层节点数设为14个，输出只有当前系统运行状态一项，因此输出层神经元节点数为1。隐含层节点数的选择会影响分类的准确性和快速性，节点数过少会降低神经网络的容错性，节点数过多则会降低网络训练速度。通常，隐含层节点数按下式选取。

$$l = \sqrt{m+n} + \beta \quad (7)$$

式中： l 为隐含层节点数； n 、 m 分别表示输入层、输出层节点数； β 为1-10之间的常数。多次训练和测试结果说明当隐含层节点数设为12时，能达到较好的训练速度和识别效果。

基于SVD和神经网络的孤岛检测流程如图2所示，将图1提取的特征量作为神经网络的输入，判别其所属模式。实际中，电容器投切等事件容易对PCC电压和逆变器输出电流的谐波产生影响，降低该方法的准确性；但是在其暂态过程结束后，PCC

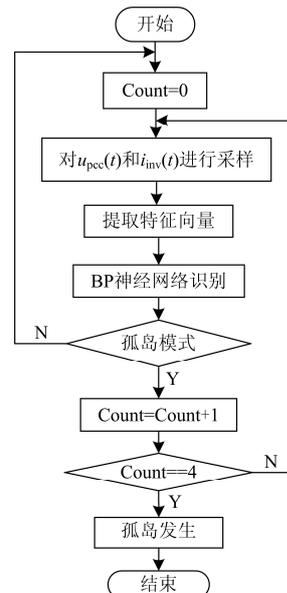


图2 孤岛检测流程图

Fig. 2 Islanding detection flow chart

电压和逆变器输出电流的谐波又将恢复正常。因此, 若在检测过程中检测到特征向量对应于孤岛模式, 则需连续多次检测予以确认, 从而避免电容器投切等事件导致的暂态过程对孤岛检测的干扰, 提高孤岛检测的准确性。如果经神经网络识别连续四次判断均为孤岛模式, 则判定孤岛发生。

3 仿真分析与验证

3.1 仿真系统模型

为了验证本文算法的有效性, 在 Matlab/Simulink 环境中搭建了如图 3 所示的仿真模型, 具体参数如下: 电网电压 220 V /50 Hz; 逆变器直流侧电压 $U_d=450$ V; 输出阻抗为: $R_f=0.01 \Omega$, $L_f=3$ mH; 额定有功功率 $P_n=3000$ W; 网侧阻抗为: $R_g=0.1$ m Ω ,

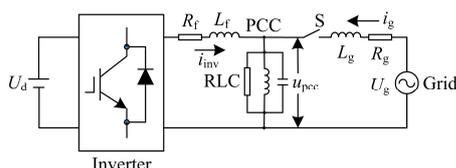


图 3 逆变器孤岛检测原理图

Fig. 3 Islanding detection principle diagram of inverter

$L_g=0.5$ mH。本地 RLC 负载: $R=16.13 \Omega$, $L=20.54$ mH, $C=493 \mu$ F。其中, 为了更加有效验证该算法, 正常并网情况下逆变器的输出功率与负载功率相等, 即两者功率平衡; RLC 负载的谐振频率为 50 Hz, 采样频率为 5 kHz。并网条件下, 逆变器工作在单位功率因数状态。

3.2 神经网络的训练与测试样本

本文主要针对功率平衡条件下的孤岛检测, 但为了减小电能质量扰动以及电容器投切等对孤岛检测准确性的影响, 除了获取正常情况和孤岛情况下的训练和测试样本外, 还仿真得到了四种单一电能质量扰动^[17](暂升、暂降、波动、谐波)以及电容器投切下的数据用于神经网络的训练和测试。在 5 kHz 采样频率下, S 变换提取 PCC 电压和逆变器输出电流的谐波幅值, 需要依次将每 100 个采样数据作为一个变换序列。所以, 孤岛、电能质量扰动以及电容器投切发生时刻所对应的采样点在一个序列中的位置会影响 S 变换结果, 从而影响特征向量。鉴于此, 测试和训练过程中, 每种情况均使上述事件发生在不同的时刻以形成训练和测试样本。样本详情见表 1。

表 1 神经网络训练与测试样本

Table 1 Training and testing samples of neural network

工况	训练样本数量($Q_f=2.0$)	算法测试次数($Q_t=2.5$)
正常	额定工况	额定工况
	$\eta=5\%, 10\%, \dots, 25\%, 30\%$	$\eta=3\%, 8\%, \dots, 23\%, 28\%$
孤岛	$\eta=0$, 即逆变器与本地负载功率匹配	$\eta=0$, 即逆变器与本地负载功率匹配
	$\eta=-5\%, -10\%, \dots, -25\%, -30\%$	$\eta=-3\%, -8\%, \dots, -23\%, 28\%$
暂升	$\gamma=0.05, 0.1, \dots, 0.25, 0.30$	$\gamma=0.03, 0.08, \dots, 0.23, 0.28$
暂降	$\gamma=-0.05, -0.1, \dots, -0.25, -0.30$	$\gamma=-0.03, -0.08, \dots, -0.23, -0.28$
波动	$\Omega=50\pi, M=0.5\%, 2.5\%, 5\%$, 单独加入或者一起加入 $m=6, 10, 14$	$\Omega=50\pi, M=0.3\%, 2.3\%, 4.5\%$, 单独加入或者一起加入 $m=6, 10, 14$
谐波	$n=3, 5, 7, 9, 11$: 单独以 3% 的含量扰动, 按 1.1%, 1.1%, 1%, 0.9%, 0.9% 一起扰动	$n=3, 5, 7, 9, 11$: 单独以 3.5% 的含量扰动, 按 1%, 1%, 1%, 1%, 1% 一起扰动
电容器投切	投入 2 kvar, 切除 0.8 kvar	投入 1.5 kvar, 切除 1 kvar

注: (1) $Q_f = R\sqrt{C/L}$ 为负载品质因数; (2) 不平衡度 $\eta=(P_{out}/P_{load}-1)\times 100\%$, P_{out} 为逆变器输出功率, P_{load} 为本地负载功率, 不同的不平衡度会导致孤岛后 PCC 点电压的不同变化; (3) 电压暂升暂降 $u(t)=U_m(1+\gamma(\varepsilon(t_1)-\varepsilon(t_2)))\sin(\omega t+\phi)$, U_m 为基波电压幅值, $\gamma=-0.9\sim+0.9$ 为升降幅度, $\varepsilon(t)$ 为阶跃函数, t_1 为扰动发生时间, t_2 为扰动结束时间; (4) 电压波动 $u(t)=U_m(1+Ma(t))\sin(\omega t+\phi)$, $M=0.5\%\sim 5\%$ 为调制幅度, $a(t)=\sum \sin(m\Omega t)/m$ 为调制信号, Ω 为调制信号的基波角速度(其频率在 0.01~25Hz 之间), m 为整数; (5) 谐波 $u(t)=\sum U_n \sin(n\omega t+\phi_n)$, U_n 为 n 次谐波幅值, ϕ_n 为初相角。

3.3 仿真结果

将训练好的具有识别分类能力的神经网络嵌入 Simulink 模型, 并对仿真数据进行分析后, 绘制了几种典型情况下的仿真曲线图以及孤岛和电压暂升暂降下的特征向量, 并统计了不同情况下该检测方法的准确率。

图 4 为逆变器运行在不同不平衡度时发生孤岛后的特征向量。孤岛发生后, 相对于 PCC 电压所对应的奇异值(x_1, x_2, \dots, x_7), 逆变器输出电流所对应的奇异值(x_8, x_9, \dots, x_{14})变化更加明显; 而且随着不平衡度 η 的增加, PCC 电压所对应的奇异值呈现增大的趋势。图 5 为不同不平衡度下发生孤岛的检测结

果, 其中, i_g 为网侧电流。在经过孤岛发生当前周期及之后的三个周期的时间被检测出来。从孤岛发生到其被检测出来的最大检测时间为 0.08 s, 快速性方面完全能够满足国标 GB/T19939-2005^[18]所规定的 2 s 内检测出孤岛的要求。

不同于图 4 所示的发生孤岛时的特征向量, 图 6 所示的电压暂升、暂降的特征向量中, PCC 电压所对应的特征向量的元素变化比逆变器输出电流所对应的更为显著一些。但是, 仍无法通过人为设定固定的阈值对孤岛和电压暂升、暂降加以区分; 而

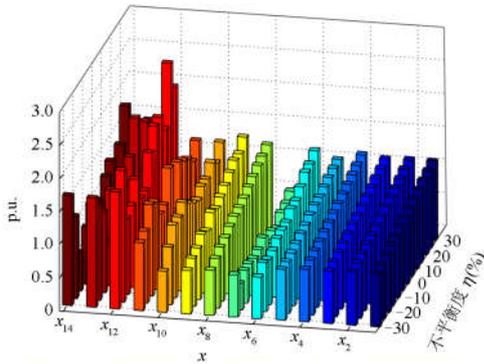
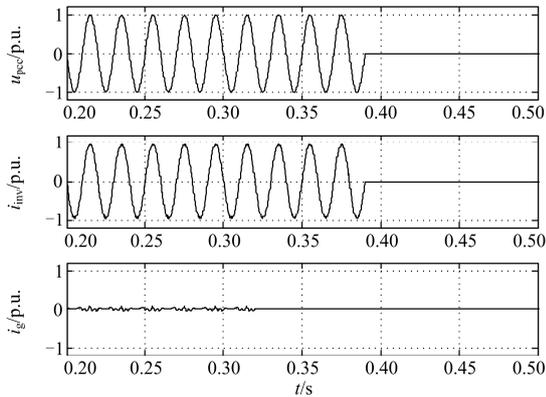
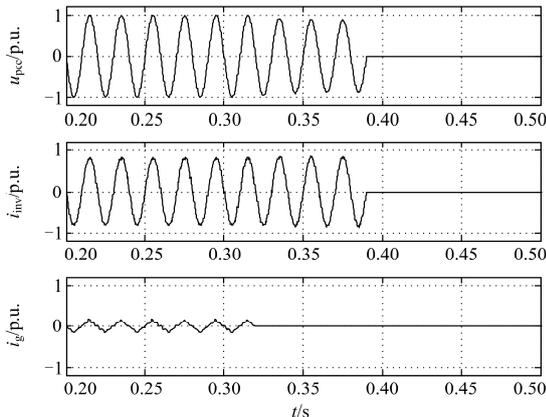


图 4 不同不平衡度工况下孤岛的特征向量

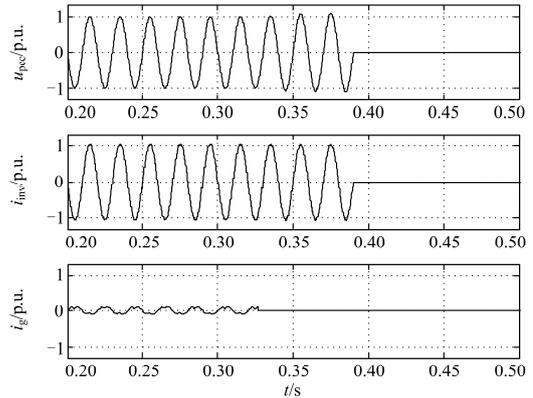
Fig. 4 Islanding feature vector under different unbalance condition



(a) $\eta=0$ 时孤岛发生的检测结果



(b) $\eta=-13\%$ 时发生孤岛的检测结果



(c) $\eta=8\%$ 时发生孤岛的检测结果

图 5 不同不平衡度下发生孤岛的检测结果

Fig. 5 Detection result in the case of islanding under different unbalance conditions

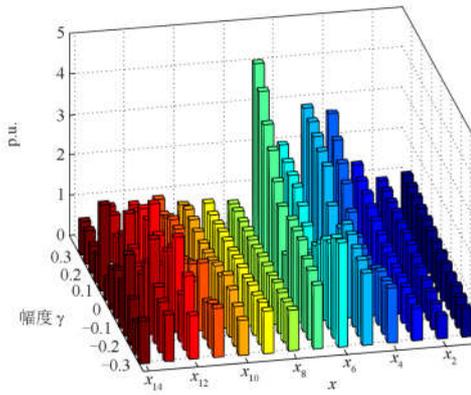


图 6 不同电压升降幅度下的特征向量

Fig. 6 Feature vector under voltage swell and sag

利用神经网络可以实现对两者的分类。如图 7 所示, 为电压暂降 $\gamma=-0.13$ 、暂升 $\gamma=0.18$ 时的检测结果, 由逆变器输出电流 i_{inv} 的波形可知, 图示两种情况下本文提出的检测算法没有发生误判。

图 8 展示了投入 1.5 kvar 电容器和切除 1 kvar 电容器所引起的暂态过程, 其对网侧电流影响较为明显, 而且 3 个周期后基本达到稳态。由于本文提出的算法需要连续 4 个周期将相应的状态判别为孤岛模式才会判定孤岛发生, 所以能够有效避免电容器投切引起的暂态过程对该方法准确性的影响。

为了更好地研究和评估基于 SVD 和神经网络的孤岛检测算法的整体可靠性和准确性, 表 2 统计了不同情况下该方法的正确率。可以看出, 谐波扰动对孤岛检测的准确性的影响较大, 这种情况下的准确率最低; 该方法基本不会将测试样本中的电容器投切情况误判为孤岛; 相对于谐波扰动来说, 电压暂升、暂降以及波动三种电能质量扰动对该方法的准确率影响更小, 其总体准确率达到了 99.36%, 相比于文献[9]的准确率有了显著的提高。

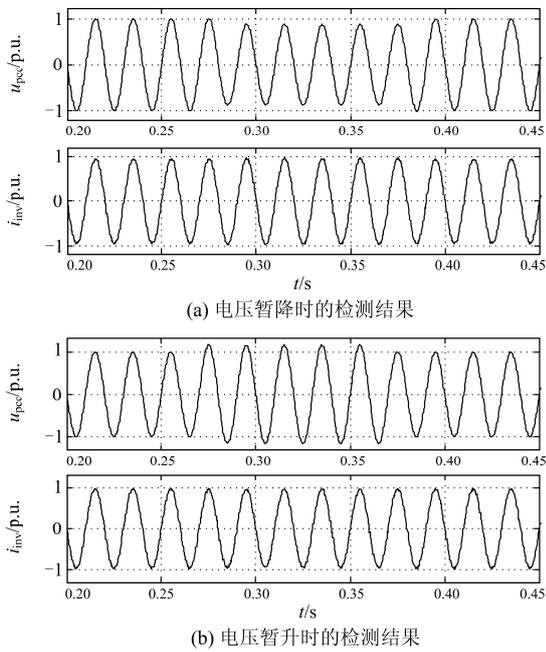


图 7 不同电压升降幅度下检测结果

Fig. 7 Detection result in the case of voltage swell and sag

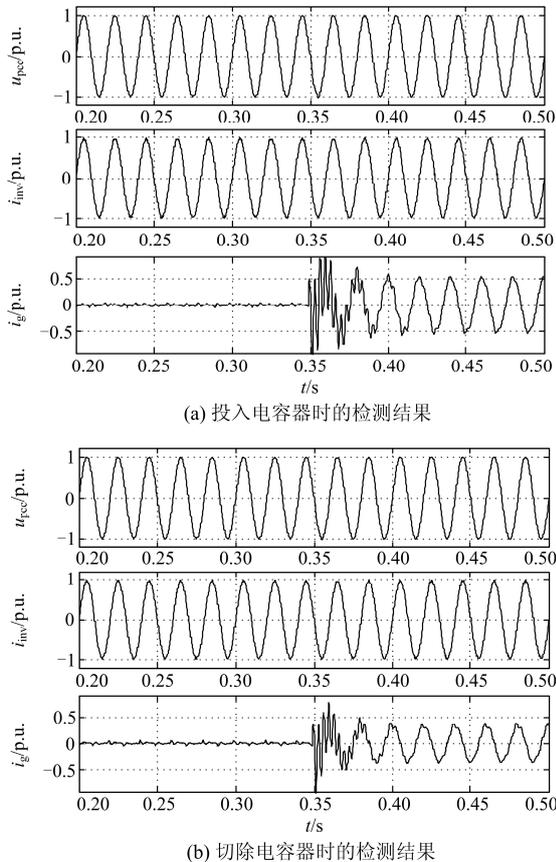


图 8 电容器投切时的孤岛检测结果

Fig. 8 Detection result in the case of capacitor switching-on and switching-off

表 2 孤岛检测算法正确率统计表

Table 2 Statistics of islanding detection algorithm accuracy

	样本数	误判数	正确率
正常	40	0	100%
孤岛	功率匹配	0	100%
	功率不匹配	240	2
暂升/暂降	240	1	99.58%
波动	240	1	99.58%
谐波	120	2	98.33%
电容器投切	40	0	100%
合计	940	6	99.36%

4 结论

本文提出一种基于 SVD 和神经网络的被动式孤岛检测方法, 并针对功率匹配、电能质量扰动以及电容器投切等情况进行了仿真验证。仿真结果表明, 该方法能够有效快速地检测出逆变器输出功率与本地负载功率匹配时发生的孤岛现象, 且不需人为设定阈值, 从而克服了传统被动式检测方法在功率匹配时存在较大 NDZ、阈值难以设定的缺点。另外, 该方法还能够有效地防止电能质量扰动对其准确性的影响。因此, 该孤岛检测方法具有速度快、NDZ 小、可靠性高的特点。此外, 本文提出的检测方法为被动式方法, 没有对逆变器输出进行扰动, 因而不会降低系统的电能质量。

参考文献

- [1] 程启明, 王映斐, 程尹曼, 等. 分布式发电并网系统中孤岛检测方法的综述研究[J]. 电力系统保护与控制, 2011, 39(6): 147-154.
CHENG Qiming, WANG Yingfei, CHENG Yinman, et al. Overview study on islanding detecting methods for distributed generation grid-connected system[J]. Power System Protection and Control, 2011, 39(6): 147-154.
- [2] 李少林, 王瑞明, 孙勇, 等. 分散式风电孤岛运行特性与孤岛检测试验研究[J]. 电力系统保护与控制, 2015, 43(21): 13-19.
LI Shaolin, WANG Ruiming, SUN Yong, et al. Analysis and experiment research on islanding behaviors and detection strategy for dispersed wind power[J]. Power System Protection and Control, 2015, 43(21): 13-19.
- [3] AHMAD K N E K, SELVARAJ J, RAHIM N A. A review of the islanding detection methods in grid-connected PV inverters[J]. Renewable & Sustainable Energy Reviews, 2013, 21(5): 756-766.
- [4] 王小立, 温靖华, 袁飞, 等. 基于频率-功率因数角组

- 合判据的新型孤岛检测法[J]. 电力系统保护与控制, 2015, 43(14): 100-105.
- WANG Xiaoli, WEN Jinghua, YUAN Fei, et al. A new anti-islanding detecting method based on combined criterion of frequency and power-factor angle[J]. Power System Protection and Control, 2015, 43(14): 100-105.
- [5] 朱时雨, 郑涛, 罗美玲, 等. 基于滤波装置短路的孤岛检测法在分布式发电系统中的应用[J]. 电力系统保护与控制, 2015, 43(19): 106-111.
- ZHU Shiyu, ZHENG Tao, LUO Meiling, et al. Islanding detection method based on short-filtering device for DG system[J]. Power System Protection and Control, 2015, 43(19): 106-111.
- [6] DE MANGO F, LISERRE M, AQUILA A D, et al. Overview of anti-islanding algorithms for PV systems. part I: passive methods[C] // 12th International Power Electronics and Motion Control Conference, Portoroz, Slovenia, 2006: 1878-1883.
- [7] DE MANGO F, LISERRE M, AQUILA A D. Overview of anti-islanding algorithms for PV systems. Part II: active methods[C] // 12th International Power Electronics and Motion Control Conference, Portoroz, Slovenia, 2006: 1884-1889.
- [8] 蒋翠, 祁新梅, 郑寿森. 带电压频率正反馈的主动移频式孤岛检测方法[J]. 电力系统保护与控制, 2014, 42(8): 95-100.
- JIANG Cui, QI Xinmei, ZHENG Shousen. Active frequency drift islanding detection with positive feedback of voltage frequency[J]. Power System Protection and Control, 2014, 42(8): 95-100.
- [9] LIDULA N W A, PERERA N, RAJAPAKSE A D. Investigation of a fast islanding detection methodology using transient signals[C] // Power & Energy Society General Meeting, Calgary, Canada, 2009: 1-6.
- [10] 朱艳伟, 但扬清, 陈东海, 等. 小波包变换和支持向量机在孤岛与扰动识别中的应用[J]. 高电压技术, 2014, 40(8): 2343-2347.
- ZHU Yanwei, DAN Yangqing, CHEN Donghai, et al. Application of wavelet packet transformation and SVM on classification of islanding and grid disturbance[J]. High Voltage Engineering, 2014, 40(8): 2343-2347.
- [11] 青桃, 江智军. S变换在孤岛检测中的应用[J]. 南昌大学学报(理科版), 2013, 37(1): 30-33.
- QING Tao, JIANG Zhijun. Application of S-transform in islanding detection[J]. Journal of Nanchang University (Natural Science), 2013, 37(1): 30-33.
- [12] 党震宇, 刘智铭, 张晓宇, 等. 基于HHT与BP网络的孤岛检测技术[J]. 电力系统保护与控制, 2011, 39(17): 103-108.
- DANG Zhenyu, LIU Zhiming, ZHANG Xiaoyu, et al. Islanding detection based on Hilbert-Huang transform and BP network[J]. Power System Protection and Control, 2011, 39(17): 103-108.
- [13] 谢东, 张兴, 曹仁贤. 基于小波变换与神经网络的孤岛检测技术[J]. 中国电机工程学报, 2014, 34(4): 537-544.
- XIE Dong, ZHANG Xing, CAO Renxian. Islanding detection based on wavelet transform and neural network[J]. Proceedings of the CSEE, 2014, 34(4): 537-544.
- [14] STOCKWELL R G, MANSINHA L, LOWE R P. Localization of the complex spectrum: the S transform[J]. IEEE Transactions on Signal Processing, 1996, 44(4): 998-1001.
- [15] KONSTANTINIDES K, Yao K. Statistical analysis of effective singular values in matrix rank determination[J]. IEEE Transactions on Acoustics, Speech and Signal Processing, 1988, 36(5): 757-763.
- [16] 张沛超, 谭啸风, 杨珮鑫. 孤岛检测的关键特征识别及元学习方法[J]. 电力系统自动化, 2014, 38(18): 72-78.
- ZHANG Peichao, TAN Xiaofeng, YANG Peixin. Critical feature identification and meta-learning method for islanding detection[J]. Automation of Electric Power Systems, 2014, 38(18): 72-78.
- [17] 冯宇, 唐轶, 吴夕科. 采用电量参数分析方法的电能质量扰动参数估计[J]. 中国电机工程学报, 2009, 29(16): 100-107.
- FENG Yu, TANG Yi, WU Xike. Parameter estimation method of power quality disturbances based on electrical parameters analysis[J]. Proceedings of the CSEE, 2009, 29(16): 100-107.
- [18] GB/T19939-2005. 光伏系统并网技术要求[S]. 北京: 中国标准出版社, 2005.

收稿日期: 2016-01-14; 修回日期: 2016-03-13

作者简介:

陶维青(1964-), 男, 副教授, 硕士生导师, 研究方向为主动配电网的运行、控制和保护;

王乐勤(1990-), 女, 通信作者, 硕士研究生, 研究方向为主动配电网的运行、控制和保护; E-mail: leqin_2014@163.com

(编辑 姜新丽)