

基于灵敏度特征决策的 GRNN 短路容量智能辨识

潘 睿, 刘俊勇, 郭晓鸣, 贺星棋, 刘友波, 方 涛

(四川大学电气信息学院, 四川 成都 610065)

摘 要:针对当前局部地区短路容量水平已接近现有设备额定值的情况, 提出一种短路容量智能辨识方法。利用基于潮流的短路计算方法计算系统各母线的最大短路容量, 通过对典型潮流下灵敏度的计算, 选择对短路容量贡献程度较大的发电机、负荷的有功出力作为输入特征向量, 建立训练样本, 对广义回归神经网络 (GRNN) 进行训练, 构成该电网结构下的短路容量辨识的人工神经网络。应用该模型对运行中电网的母线短路容量水平进行快速扫描, 为智能电网与智能调度中的故障识别快速仿真建模 (FSM) 提供了一种新思路。通过 IEEE 30 节点系统验证了该方法的可行性与有效性。

关键词:短路容量; 广义回归神经网络; 灵敏度; 智能辨识; 快速仿真建模

Abstract: Aiming at the situation that the level of short-circuit capacity is close to the rating of the existing equipment in local area at present, an intelligent identification approach of short-circuit capacity is proposed. Maximum short-circuit capacity of each bus is calculated using the short-circuit calculation method based on power flow. By calculating the sensitivity in typical power flow, the active efforts of generators and loads which have greater contribution to short-circuit capacity are selected as input eigenvectors, and the training samples are established to train general regression neural network (GRNN). Then an artificial neural network of short-circuit capacity identification is formed. The model is applied to fast scanning of short-circuit capacity of buses that are in operation in power grid, which is providing a new thought of fast simulation modeling (FSM) for fault recognition in smart grid and intelligent dispatch. Simulations on IEEE 30 system are performed to verify the feasibility and validity of the approach.

Key words: short-circuit capacity; general regression neural network (GRNN); sensitivity; intelligent identification; fast simulation modeling (FSM)

中图分类号: TM743 **文献标志码:** A **文章编号:** 1003-6954(2010)06-0001-05

0 引 言

随着中国电力系统的迅速发展, 电网联网进程的不断推进, 网络结构日趋复杂, 电网最大短路容量逐渐增加, 局部地区短路容量水平已接近现有设备额定值, 短路容量、短路电流超过设备额定值的问题日益突出。虽然电力设备更新很快, 但投资普遍很大, 有部分设备到目前已经使用二、三十年, 现有的部分电力系统的运行水平已经超过其额定值。以西南某省级电网 220 kV 等级为例: 截至到 2008 年年末, 运行在 20 年以上的输电线有 65 条, 总长度为 3 052.26 km; 运行在 20 年以上的变压器有 19 台/组; 有 9 个厂站的最大短路电流已经超过了开关开断电流能力。

智能电网是指一个完全自动化的供电网络, 其中

的每一个用户和节点都得到实时监控, 并保证从发电厂到用户端电器之间的每一点上的电流和信息的双向流动^[1]。根据 IBM 中国公司高级电力专家 Martin-Hauske 的解释, 智能电网有 3 个层面的含义^[2]。智能电网有个很重要的方面就是对电网可能出现的问题提出充分的告警。短路是现代电力系统的一种主要故障。短路容量辨识可以对电网中所有节点的短路容量进行实时监测, 对电网可能发生的短路故障进行预估分析, 成为未来智能电网的有效组成。

文献 [3-8] 介绍了一些比较精确的短路电流计算方法。这些方法虽然精度较高, 但计算速度都相对较慢, 不太适合实时要求, 无法进行在线监测扫描。文献 [7-8] 对于短路电流的预测进行了研究。文献 [9] 通过在最大运行方式下进行计算得出最大供电规模与 220 kV 电网短路电流间的关系。文献 [10] 虽然能够进行当前运行方式下的短路电流预测, 但是

基金项目: 国家自然科学基金项目 (No. 50977059)

没有考虑发电机组的出力分配变化,与实际运行情况存在较大差距,并且只对重要节点进行预测,不能实现对全网短路水平的有效监测。文献 [11] 虽然是实时在线计算短路电流,但是是快速获取故障后瞬间短路电流的基波准确参数,不是短路水平的辨识。

当前,电网中短路容量大都是在离线状态下根据电网的最大运行方式进行计算,但是对于快速变化的电网,其运行方式是不断变化的,不同的运行方式下电网的短路水平可能相差很大,为了及时掌握电网运行中最大短路容量位置及其水平,预防短路电流超过额定值,有必要进行短路容量的快速辨识。根据当前研究现状及以上分析,提出了一种短路水平智能辨识的方法,通过可对结构相对固定的电网在不同发电机出力分配、不同的负荷水平下进行短路容量水平的扫描,为智能电网与智能调度中的故障识别快速仿真建模 (fast simulation modeling FSM) 提供了一种新思路和技术支持。通过仿真结果可知,该方法在计算的精度和速度上都能达到比较满意的效果。

1 模型分析及设计

1.1 建模分析

短路容量是反映电力系统中某点电气性能的一个特征量。首先,短路容量是对电力系统的某点而言的,其次,短路容量也和整个系统的容量水平有关。随着电力系统容量的扩大,系统短路容量的水平也会增大。短路容量是系统电压强度的标志,短路容量大(对应于低阻抗),表明网络强,负荷、并联电容器或电抗器的投切不会引起电压幅值大的变化;相反,短路容量小表明网络弱^[12]。

在电力系统实际运行中,单相短路故障占全部故障的绝大部分,其次是两相接地和两相短路故障,出现三相对称故障的概率是很少的。但是,三相短路对于系统稳定的影响最大,通常用来校验电气设备的遮断能力。由于母线在运行中,有巨大的电能通过,短路时,将承受很大的发热和电动力效应,因此,母线短路容量的计算对电力系统影响巨大。

1.2 短路计算模型

传统短路电流计算是采用叠加原理的基于潮流的对称短路计算。其模型基于以下假设条件。

(1) 基于潮流的短路计算,所以突然短路前,三相交流系统是在对称状况下运行;

(2) 短路瞬间为纯金属性短路,不计导体之间或导体对地之间的电阻。

(3) 同步电机均采用次暂态电抗后电势恒定模型;转子结构完全对称;定子三相绕组结构完全相同;

(4) 电力系统各元件的磁路不计饱和,电气设备的参数不随电流大小发生变化;

(5) 在潮流方式基础上计算短路电流,所以是计及负荷(负荷采用恒阻抗模型表示)和发电机出力的;

(6) 负荷和发电机采用恒功率因数。

基于潮流的短路计算,短路电流主要和潮流结果的节点电压和故障节点的自阻抗相关。在一个结构固定的电网中,短路电流变化主要源于潮流的变化,而固定结构的电网中潮流主要是随发电机和负荷的变化而变化。所以在智能短路容量辨识中,把发电机和负荷的出力作为辨识模型的特征输入量。

1.3 GRNN 智能辨识模型

为实现短路容量智能辨识,选择神经网络进行辨识。广义回归神经网络 (general regression neural network GRNN) 是一种局部逼近网络,与传统神经网络不同^[13,14],模型具有明确理论基础,是一种建立在数理统计基础上的神经网络^[15]。其优点包括:①只要样本数据确定,则相应的网络结构和神经元之间的连接权值也随之确定;②训练过程不需要迭代;③当运行方式改变时,GRNN 网络只需相应修改训练样本并重构和训练网络^[16,17];④不必进行循环的训练过程,在训练过程中不调整神经元之间的连接权值;⑤即使样本数据较少,也可以收敛于样本量集聚最多的优化回归面;⑥网络训练过程实际上只是确定平滑参数的过程,网络的学习全部依赖数据样本,这个特点决定了网络得以最大限度地避免人为因素对辨识结果的影响。

广义回归神经网络的理论基础是根据样本数据逼近其中隐含的映射关系^[15]。设随机向量 x 和 y 随机变量的联合概率密度函数为 $f(x, y)$ 。如果 $f(x, y)$ 已知,容易得到 y 在 x_0 上的回归值 (y 对 x_0 的条件均值) 为

$$E(y | x_0) = y(x_0) = \frac{\int_{-\infty}^{\infty} y f(x_0, y) dy}{\int_{-\infty}^{\infty} f(x_0, y) dy} \quad (1)$$

对 $f(x_0, y)$ 进行泊松 (Parzen) 非参数估计,由于积分 $\int_{-\infty}^{\infty} x e^{-x^2} dx = 0$, 所以整理得

$$y(x) = \frac{\sum_{i=1}^n y_i \exp(-\sum_{j=1}^R (x_{0j} - x_{ij})^2 / 2\sigma^2)}{\sum_{i=1}^n \exp(-\sum_{j=1}^R (x_{0j} - x_{ij})^2 / 2\sigma^2)} \quad (2)$$

式中, n 为样本容量; p 为 x 的维数; σ 在此称为平滑参数(唯一需要人为设定的值, 值越小, 神经网络越逼近函数)。

GRNN 由一个径向基网络层和一个线性网络层组成, 网络结构如图 1 所示。第一层为径向基隐含层, P 表示输入样本数据; R 为训练样本输入的维数, 也就是该电网所有发电机和负荷的总个数; Q 表示每层网络中神经元的数目, 也就是训练样本的个数; a_i 表示第一层输出 a 的第 i 个元素; w_{i1} 表示第一层权值矩阵 w_{i1} 的第 i 行元素。此层的权值函数为欧几里德距离度量函数(用 $\| \text{dist} \|$ 表示)。

$$\| \text{dist} \| = \sqrt{\sum_{j=1}^R (x_j - w_{ji})^2} \quad (j=1, 2, 3, \dots, Q) \quad (3)$$

其作用是计算网络输入与第一层的权值 w_{i1} 之间的距离。 b 为隐含层阈值, $\| \text{dist} \|$ 的输出与阈值 b 的元素相乘, 将结果 n 传送到传递函数。传递函数常用高斯函数

$$R_i(x) = \exp(-\frac{\| x - c_i \|^2}{2s_i^2}) \quad (4)$$

网络的第二层为线性输出层, 其权函数为规范化点积权函数(用 nprod 表示), 计算出网络的向量 n' , 它的每个元素就是向量 a 与权值矩阵 W_{21} 每行元素的点积再除以向量 a 各元素之和的值, 并将结果 n' 送入线性传递函数 $a' = \text{purelin}(n')$, 计算网络输出。输出的是电网所有节点(母线)在该运行方式下的三相短路容量。




图 1 基于 GRNN 的短路容量辨识模型

2 算法设计

2.1 基于灵敏度的特征值选择

通过样本值训练人工神经网络, 一般来说训练样本数越多, 训练结果越能正确反映其内在规律, 但是, 当样本数多到一定程度时, 网络的精度也很难再提高, 并且, 样本数太多反而会造成训练时间过长, 工作

量过大。

在所提出的基于 GRNN 的短路容量辨识的神经网络中, 如果把所有的发电机和负荷的出力都作为网络的输入, 单个输入样本的输入量太多, 这样训练网络的样本量也就会随之增加。所以综合效率和精度的考虑, 采用灵敏度的方法来评价输入的特征量, 从而选择对短路容量影响较大的特征量作为输入。在典型运行方式下(最大、最小、随机运行方式)对各发电机、负荷节点进行灵敏度计算, 灵敏度分析可以表征特征参数(控制变量)对状态变量的敏感程度^[19]。

$$F(P_i + \Delta P_i, Q_i + \Delta Q_i) = S_i + \Delta S_i,$$

$$S_2 + \Delta S_2, \dots, S_m + \Delta S_m \quad (i=1, 2, \dots, n) \quad (5)$$

式中, F 表示基于潮流的短路容量计算; ΔP_i 是某台发电机或者某负荷的有功出力的增量; ΔQ_i 是某台发电机或者某负荷的无功出力的增量; ΔS_m 是该节点短路容量的增量; n 是发电机和负荷的总个数; m 是节点总个数。

利用式(6)左右两边的增量来求得状态参数(某节点短路容量)对控制参数(某节点有功出力)的灵敏度 $\xi(P_i | S_j)$ 。

$$\xi(P_i | S_j) = \frac{\Delta S_j}{\Delta P_i} = \frac{\partial S_j}{\partial P_i} \quad (6)$$

式中, $(i=1, 2, \dots, n); (j=1, 2, \dots, m)$ 。

通过灵敏度指标判断节点出力对电网各节点短路容量影响程度来选择训练网络的特征输入量。

$$\sum_{j=1}^m \frac{|\partial S_j / \partial P_i|}{m} \geq S_b \quad (j=1, 2, \dots, m) \quad (7)$$

式(7)左边为系统所有节点短路容量对某节点有功出力的平均灵敏度; S_b 为提取特征量的灵敏度特征的指标。

分别确立发电机节点和负荷节点的 S_b , 当在典型潮流下分别都满足式(7)时就把该点选为输入样本特征值。 S_b 的选择是自动的, 是根据灵敏度计算的结果的排序取靠前的一个比例的发电机和负荷的有功出力(这个百分比是人工定的, 根据网络情况确定)作为输入样本的特征值。

2.2 样本空间建立

训练样本不但要足够多以满足训练网络的精度, 而且为了使网络能够适应电网各种运行方式, 样本值的选取要尽可能全面的覆盖电网运行的所有方式。

电网所有运行方式都是在该电网最大运行方式和最小运行方式之间, 所以可以通过最大、最小运行

方式来确定样本值抽取空间。根据文献 [20] 的叙述:最大运行方式是指系统中投入运行的机组最多、容量最大时,通过继电保护装置的短路电流为最大数值的运行方式。反之为最小方式。在电网中最大运行方式可以从并网机组出力直接得到,而最小运行方式在算例中设定为零。对每个节点在最大和最小方式中均匀分布取点,并且输入样本一定要满足发电机出力和负荷出力在忽略网损下大约相等的条件。

$$\sum_{j=0}^m P_{Lj} \approx \sum_{i=0}^n P_{Gi} \quad (8)$$

为了便于样本值对神经网络进行训练,将数据归一化处理为区间 [0, 1] 之间的数据。设 x_{max} 和 x_{min} 分别代表训练样本集中有功输出的最大值和最小值, x 为实际值, X 为归一化后的输入值, 则 [9]

$$X = \frac{(x - x_{min})}{(x_{max} - x_{min})} \quad (9)$$

使输入数据能够在有效数据空间均匀分布开。

2.3 算法流程

整个算法的流程如图 2 所示。

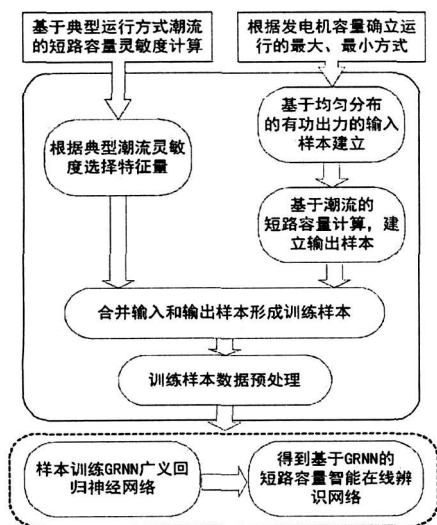


图 2 基于 GRNN 的短路容量智能辨识算法流程

3 算例

3.1 IEEE 30 算例样本构造

以 IEEE 30 节点系统作为算例,对该网络进行短路容量辨识。该系统有 6 台发电机,21 个负荷节点。如果不进行基于灵敏度的特征样本值选取,样本共有 26 个输入值(平衡节点的出力根据负荷和其他发电机的出力自动确定)。在典型运行方式下对各有功出力点进行灵敏度计算,确立发电机的 $S_b = 0.06$, 负

荷的 $S_b = 0.1$, 从而选择了 3 个发电机(发电机输入特征样本的选择比例是灵敏度排名的前 60%)和 15 个负荷节点的有功出力(负荷节点输入特征样本的选择比例是灵敏度排名的前 60%)为输入样本特征值。

由于是 IEEE 30 标准节点,所以设定各个发电机的额定容量,从而通过最大容量之和来确定系统最大运行方式(最小方式为发电机总的有功出力为零),在最大运行和最小运行方式之间对每个有功出力节点进行基于均匀分布的随机抽样。为了使平衡节点的有功出力在其最大容量之内,对随机样本进行选择处理。

$$0 \leq \sum_{j=0}^m P_{Lj} - \sum_{i=0}^{n-1} P_{Gi} \leq \max P_{Gp} \quad (10)$$

式中, m 是系统负荷总个数; n 是系统发电机总个数; $\max P_{Gp}$ 是平衡节点发电机最大有功出力。

通过满足均匀分布和有功出力条件的随机输入样本,进行基于潮流的短路容量计算,从而组成完整的输入输出样本,通过灵敏度指标建立 GRNN 网络的训练样本。在该算例中,随机产生 1 200 个样本,经过筛选有 329 个样本符合样本条件。

3.2 IEEE 30 短路容量智能辨识

用生成的 329 个样本值对 GRNN 广义回归神经网络进行训练,通过对平滑参数的调整比较选取合适的值(平滑参数选择为 0.05),可以快速得到训练后的网络。

随机产生测试样本输入,利用训练后的网络对随机测试样本输入进行短路容量辨识,得到结果,对比该测试样本输入通过基于潮流的短路精确计算方法计算出的短路容量值。

表 1 基于潮流的计算方法和基于 GRNN 智能辨识方法的计算结果对比(任选 9 个节点)

节点名	短路容量 /MVA		相对误差 /%
	基于潮流的 短路算法	GRNN 智能辨识	
BUS-10	109.24	105.98	-2.98
BUS-11	218.22	213.70	-2.07
BUS-12	309.58	299.85	-3.14
BUS-13	226.17	218.85	-3.24
BUS-14	404.62	387.89	-4.13
BUS-15	290.60	276.48	-4.59
BUS-16	857.46	837.51	-2.33
BUS-17	165.41	159.49	-3.58
BUS-18	101.32	97.42	-3.85

通过表 1 可以看到,通过 GRNN 智能辨识方法计

算的短路容量值相对于基于潮流的计算的结果, 相对误差基本都在 5% 以内, 结果比较精确。用平均绝对百分比误差 (式 (11)) 来评价 GRNN 辨识模型的辨识精度, 该算例的平均绝对百分比误差为 2.508%。

$$\left| \bar{\delta}_p \right| = \frac{\sum_{i=1}^n \left| y_i' - y_i / y_i \right|}{n} \times 100\% \quad (11)$$

从图 3、图 4 可以看到通过 GRNN 智能辨识方法计算的短路容量值相对于基于潮流计算结果的对比。




图 3 基于 GRNN 智能辨识方法和基于潮流的短路计算方法的误差




图 4 基于潮流的短路计算方法和基于 GRNN 智能辨识方法计算结果对比

从表 2 可以看到, 对于短路容量的计算, 基于潮流的短路电流计算时间的方法是先进行当前运行方式下的潮流计算, 根据潮流计算结果得到各节点电压, 然后根据节点电压和该网络的节点阻抗矩阵计算短路电流及短路容量, 每一次短路容量的计算都要进行当前运行方式下的潮流计算, 计算的绝对时间较大, 所以基于 GRNN 智能辨识方法计算时间远小于基于潮流的短路计算时间, 并且随着网络规模的扩大, GRNN 智能辨识方法的优势会更加明显。

表 2 基于潮流的短路计算方法和基于 GRNN 智能辨识方法单次全网短路容量水平扫描的时间对比

	基于 GRNN 智能辨识	基于潮流的计算
绝对时间 /s	0.009 72	0.062 5

注: 基于 GRNN 智能辨识的绝对时间是指采用训练之后的网络进行计算某个母线的短路电流的时间

3.3 对比分析

将前面的方法与传统 BP 神经网络 (隐含层 32 节点) 进行对比: 采用相同的样本数量和样本值; 用相同的测试值进行测试。误差和时间对比如下。

(1) 传统神经网络 (如 BP) 在确定权值时具有随机性, 导致每次训练后输入、输出间的关系不定, 输出结果存在差异, 并且样本太少会导致其不精确。而 GRNN 网络即使样本数据较少, 也可以收敛于样本量集聚最多的优化回归面。传统神经网络计算结果的平均绝对百分比误差为 2.124% (结果不稳定, 选择多次结果中较好的一次结果), 而 GRNN 方法的平均绝对百分比误差为 2.508% (结果稳定), 虽然该方法误差稍大, 但是结果稳定, 而传统神经方法虽然最好的结果稍好, 但是结果极其不稳定, 不适合进行辨识。

(2) 在训练时间上

$$t_{GRNN} = 0.242 \text{ s} \quad t_{BP} \geq 446 \text{ s}$$

GRNN 网络在训练时间上远远小于 BP 网络。主要是因为 GRNN 网络训练过程不需要迭代, 当运行方式改变时, 只需相应修改训练样本并重构和训练网络, 不必进行循环的训练过程, 在训练过程中不调整神经元之间的连接权值。

从上面分析可知, 综合速度与精度考虑, GRNN 网络的计算相对于传统的 BP 网络, 具有明显的优势, 适用于短路容量的智能辨识。

4 结 论

中国电力系统的发展目标是要建成坚强的智能电网, 随着电力系统规模增大, 传统的短路容量计算方法大都是基于潮流的计算, 速度较慢。所提出的短路容量辨识方法, 在电网结构不变的情况下, 通过对少量基于潮流的短路容量计算样本训练后, 对当前运行方式下电网母线的最大短路容量水平进行扫描, 通过算例验证, 该方法速度较快, 精度较高, 可以为电力部门及时掌握、了解电力系统实时运行状况, 及时采取应急措施提供了参考性的依据, 为智能监测和智能调度中快速仿真建模提供了一种新思路与技术支持。如何在考虑电网变结构、大系统边界适应性、辨识网络的实时更新的情况下实现快速辨识是未来工作的发展方向。

参考文献

(下转第 13 页)

DC/DC 升压变换器, 形成 Z 源型逆变器; 利用文献 [1] 的光伏阵列电路模型结合改进的电导增量法进行 MPPT 仿真; 设计了整套系统的控制策略, 对一套功率为 3 000 W 基于 Z 源的单相光伏并网系统进行仿真, 并对仿真波形进行了分析。证明改进的电导增量法跟踪速度和跟踪精度有所提高, 基于阻抗源的单相光伏并网装置节约成本的同时改善了系统的输出, 并增加了系统的可靠性。

参考文献

[1] 郑连清, 谢柱. 基于特性参数的太阳能电池和光伏阵列建模研究 [J]. 低压电器, 2010(8): 21-25.
[2] 吴理博. 光伏并网逆变系统综合控制策略研究及实现 [D]. 北京: 清华大学博士学位论文, 2006.
[3] 丁新平. Z 源变流器关键技术的研究 [D]. 杭州: 浙江大学博士学位论文, 2007.
[4] 蔡磊. Z 源逆变器并网应用研究 [D]. 杭州: 浙江大学

硕士学位论文, 2008.

[5] Jong-Hyoung Park, Heung-Geun Kim, Tae-Won Chun. A Control Strategy for the Grid-connected PV System Using a Z-Source Inverter [C]. 2nd IEEE International Conference on Power and Energy (PECon 08), December.
[6] Poh Chiang Loh, Vilathgamuwa D. M., Yue Sen Lai, Geok Tin Chua, Yunwei Li. 2004. Pulse-width Modulation of Z-source Inverters [J]. Industry Applications Conference 39th IAS Annual Meeting Conference Record Oct. 2004.
[7] 张超, 何湘宁. 一种用于光伏发电系统的新型高频逆变器 [J]. 电力系统自动化, 2005, 29(19): 51-53.

作者简介:

李 杨 (1962), 男, 硕士, 高级工程师, 研究方向为电力系统自动化及电力电子技术的应用。

(收稿日期: 2010-09-15)

(上接第 5 页)

[1] 余贻鑫, 栾文鹏. 智能电网 [J]. 电网与清洁能源, 2009, 25(1): 7-11.
[2] IBM 论坛. 2009, 点亮智慧的地球 [EB/OL] [D]. <http://www-900.ibm.com/cn/forum2009/wisdom.shtml>
[3] Giuseppe Parise. A New Approach to Calculate the Decaying AC Contributions to Short Circuit [J]. IEEE Transactions on Industry Application, 1995, 31(1): 214-221.
[4] 赵敏. 基于电流变化率的电网短路保护原理 [J]. 电网技术, 2008, 32(4): 105-108.
[5] 王建元, 师旭, 师耀林, 等. VB 与 Matlab 混合编程在电力系统短路计算中的应用 [J]. 电网技术, 2007, 32(2): 143-146.
[6] 罗庆跃, 李晓明. 变结构模型短路电流计算方法 [J]. 中国电机工程学报, 2005, 25(1): 77-80.
[7] 邵玉槐, 李肖伟, 程晋生. REI 等值法用于多节点配电系统短路电流计算的研究 [J]. 中国电机工程学报, 2000, 20(4): 64-67.
[8] 范忠, 张慧媛. 基于 GIS 数据平台的配电网短路电流计算 [J]. 电力系统自动化, 2005, 29(23): 76-79.
[9] 徐贤. 220 kV 电网短路电流预测的新方法及应用 [J]. 电力系统自动化, 2007, 31(16): 103-106.
[10] 刘波, 张焰, 陈煜. 基于 GA2 改进 BP 神经网络算法在大电网短路电流预测中的应用 [J]. 电工电能新技术, 2006, 25(4): 43-46.
[11] 刘俊, 马志瀛, 闫静, 等. 基于改进梯度校正法的短路电流在线实时计算 [J]. 电工技术学报, 2007, 22(10): 66-70.

[12] Carson W. Taylor 著, 王伟胜译. 电力系统电压稳定 [M]. 北京: 中国电力出版社, 2005.
[13] 王文成. 神经网络及其在汽车工程中的应用 [M]. 北京: 北京理工大学出版社, 1998.
[14] Carson W. Taylor 著, 王伟胜译. 电力系统电压稳定 [M]. 北京: 中国电力出版社, 2005.
[15] Specht D. F. A General Regression Neural Network [J]. IEEE Trans on Neural Networks, 1991, 2(6): 568-576.
[16] 张际先, 宓霞. 神经网络及其在工程中的应用 [M]. 北京: 机械工业出版社, 1996.
[17] 冯志鹏, 宋希庚, 薛冬新, 等. 基于广义回归神经网络的时间序列预测研究 [J]. 振动、测试与诊断, 2003, 23(2): 106-109.
[18] 谷志红, 牛东晓, 王会青. 广义回归神经网络模型在短期电力负荷预测中的应用研究 [J]. 中国电力, 2006, 39(4): 11-14.
[19] 王尔智, 赵玉环. 电力网络灵敏度分析与潮流计算 [M]. 北京: 机械工业出版社, 1991.
[20] 万千云等. 电力系统运行实用技术问答 [M]. 北京: 中国电力出版社, 2003.

作者简介

潘 睿 (1984), 男, 硕士研究生, 研究方向为电力系统稳定与控制。

刘俊勇 (1963), 男, 四川成都人, 教授, 博士生导师。研究方向为电力市场、分布式发电、灵活输电与电力系统可视化等方面的研究。

(收稿日期: 2010-10-06)