

# 基于 Stacking 元学习策略的电力系统暂态稳定评估

叶圣永, 王晓茹, 刘志刚, 钱清泉

(西南交通大学电气工程学院, 四川 成都 610031)

**摘要:** 为提高电力系统暂态稳定评估单个模型的准确率, 研究了基于元学习策略的暂态稳定评估问题, 提出了支持向量机、决策树、朴素贝叶斯和 K 最近邻法作为基学习算法, 线性回归为元学习算法的 Stacking 评估模型。该模型将上述基学习算法的概率输出作为新训练数据的输入特征, 同时保留原始的类标识。线性回归算法在新训练集上学习得到最终暂态稳定评估结果。新英格兰 39 节点测试系统和 IEEE50 机测试系统上仿真实现了该模型, 仿真结果证明所提模型比单个模型的评估性能更好, 为电力系统暂态稳定评估提供了新的思路。

**关键词:** 暂态稳定评估; 朴素贝叶斯; 支持向量机; 决策树; K 最近邻法; Stacking 算法

## Power system transient stability assessment based on Stacking meta-learning strategy

YE Sheng-yong, WANG Xiao-ru, LIU Zhi-gang, QIAN Qing-quan

(School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

**Abstract:** In order to increase single model's accuracy in transient stability assessment of power systems, the transient stability assessment based on meta-learning strategy is studied, and a Stacking assessment model is presented. The base learning includes support vector machines, decision trees, naive Bayesian and K-nearest neighbor classifier. Linear regression is adopted as Stacking assessment model of meta-learning. The model uses the probabilistic output of base learning algorithm as input attributes in a new training set, and keeps the original class labels. The final transient stability assessment result is acquired after learning in the new training set by linear regression. The simulations on New England 39-bus and IEEE 50-machine test systems show that the assessment performance of the proposed approach is better than that of the single models and provides a new way to assess power system transient stability.

This work is supported by National Natural Science Foundation of China (No. 90610026).

**Key words:** transient stability assessment; naive Bayesian; support vector machines; decision trees; K- nearest neighbor classifier; Stacking algorithm

中图分类号: TM712 文献标识码: A 文章编号: 1674-3415(2011)06-0012-05

## 0 引言

机器学习为电力系统暂态稳定评估提供了新的途径, 已用于暂态稳定评估的机器学习包括: 人工神经网络(常采用 Multilayer Perception, MLP)<sup>[1]</sup>、决策树(Decision Tree, DT)<sup>[2]</sup>、K最近邻法(K Nearest Neighbor, KNN)<sup>[3]</sup>和支持向量机(Support Vector Machines, SVM)<sup>[4]</sup>。给定隐含层数和各层所含的

神经元, MLP 可得到输入和输出间的任意函数映射。由于是“黑匣子”, 使得其解释性较差, 且存在过拟合现象, 推广能力较差<sup>[5]</sup>。DT 通过检视最好测试特征及门槛值, 逐层逐节点对测试特征分裂, 直到可以正确将输入数据分类。DT 的优点是速度快、结果相对容易解释; 但缺点是不稳定、树过大容易出现过拟合现象。KNN 是基于实例的学习方法, 通过距离该数据的 K 个最邻近数据中的大多数类别来确定该点的类别。通常 KNN 分类准确率较低, 常和 DT 和 MLP 等其他方法配合<sup>[5]</sup>。SVM 作为统计学习理论的实现方法, 受到广大研究者的关注, 已成为最广泛使用的分类算法<sup>[6-7]</sup>。文献[6]对多组不同输入特征的 SVM 信息融合来提高电力系统暂态稳

**基金项目:** 国家自然科学基金项目 (No. 90610026); 教育部新世纪优秀人才支持计划 (NECT-08-0825); 中央高校基本科研业务费专项资金资助 (SWJTU09ZT10); 教育部霍英东青年教师基金 (101060)

定评估正确率。SVM 具有良好的推广性能, 但依赖于所采用的核函数及模型参数, 有研究表明, SVM 的分类性能并不能令人满意<sup>[8]</sup>, 在新英格兰 39 节点测试系统上分类准确率为 87%, 在某 479 节点测试系统上的分类准确率为 84.5%。

针对单个暂态稳定评估模型的不足, 研究人员将多个同类评估模型如朴素贝叶斯 (Naive Bayesian, NB) 利用 AdaBoost 算法进行组合<sup>[9]</sup>, 或者利用 Bagging 算法将多个 SVM 进行组合<sup>[7]</sup>, 在一定程度上提高了暂态稳定评估的准确率。本文在 Stacking 元学习框架下, 提出了一种融合多种分类算法的电力系统暂态稳定评估模型。新英格兰 39 节点和 IEEE50 机测试系统的仿真结果证明, 该方法的暂态稳定评估准确率比单个分类算法更高。

## 1 Stacking 原理

1992年Worlpert提出了Stacked Generalization的学习框架<sup>[10]</sup>, 简称Stacking算法。Stacking算法通过组合多种分类算法, 在学习结果的基础上进行再次学习或多次学习而得到最终结果<sup>[11]</sup>, 并成功地运用在中文组块分析、图像分类等方面。Stacking算法原理如图1所示, 利用基学习算法 (Base-Learner) 的输出结果作为元学习算法 (Meta-Learner) 的输入信息, 使低层学习能够充分用于高层的归纳过程中, 发现并纠正基学习算法中的分类偏差。即通过元学习算法来揭示怎样才能最好地组合基学习算法的输出。

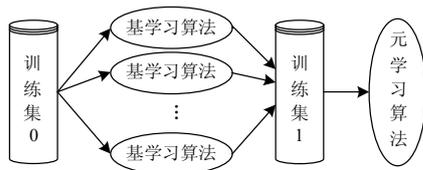


图 1 Stacking 组合模型示意图

Fig.1 Illustration of Stacking model

假定一组训练集0, 即  $L_0 = \{(y_n, \mathbf{x}_n), n = 1, \dots, N\}$ , 其中  $y_n$  为类属性,  $\mathbf{x}_n$  为输入特征向量。K 个基学习算法通过训练集0上 J 折 (J 取 5~10) 交叉验证得到 K 个分类模型  $M_k, k = 1, \dots, K$ 。令  $z_{kn}$  表示第 k 个分类模型训练集中第 n 个数据的类属性输出, 与实际类属性  $y_n$  一起得到训练集1, 即

$$L_1 = \{(y_n, z_{1n}, \dots, z_{Kn}), n = 1, \dots, N\}。$$

进一步利用元学习算法从训练数据集1获得最终分类模型  $\tilde{M}$ , 由  $\tilde{M}$  给出最终类别属性。

## 2 暂态稳定评估元学习模型的构建

### 2.1 暂态稳定评估的输入特征

本文综合现有文献<sup>[12-14]</sup>, 构造了一组与系统规模无关的暂态稳定评估原始特征集, 特征的介绍如表 1 所示, 表中  $t_0$  为故障初始时刻,  $t_{cl}$  为故障切除时刻。特征  $x_{23} = \sum_{i=1}^n P_{ai} \delta_{di}$ , n 为发电机的台数,  $P_{ai}$  为第 i 台发电机在  $t_0$  时刻加速功率,  $\delta_{di} = (\delta_i - \delta_{cor})|_{t_{cl}}$  为第 i 台发电机在  $t_{cl}$  时刻的相对转子角度。

表 1 暂态稳定评估原始特征集

Tab.1 Original feature set in transient stability assessment

$x_1$ : 系统中的负荷水平	$x_2$ : 系统中所有发电机机械功率的平均值
$x_3$ : $t_0$ 时刻发电机转子初始相对加速度的最大值	$x_4$ : $t_0$ 时刻发电机转子初始相对加速度的最小值
$x_5$ : $t_0$ 时刻发电机初始加速度的均方根误差	$x_6$ : $t_0$ 时刻最大加速度发电机初始相对转子角度
$x_7$ : $t_0$ 时刻发电机初始加速功率的平均值	$x_8$ : $t_0$ 时刻发电机转子角度最大值与最小值差
$x_9$ : $t_0$ 时刻发电机角速度最大值与最小值差	$x_{10}$ : $t_0$ 时刻发电机角加速度中最大值与最小值差
$x_{11}$ : $t_0$ 时刻发电机转子动能最大值与最小值差	$x_{12}$ : $t_0$ 时刻发电机转子动能中的最大值
$x_{13}$ : $t_0$ 时刻发电机最大的有功功率冲击	$x_{14}$ : $t_0$ 时刻发电机中最小的有功功率冲击
$x_{15}$ : $t_{cl}$ 时刻发电机转子动能的最大值	$x_{16}$ : $t_{cl}$ 时刻最大动能发电机的相对转子角
$x_{17}$ : $t_{cl}$ 时刻系统中最大相对转子角	$x_{18}$ : $t_{cl}$ 时刻最大相对转子角的发电机的动能
$x_{19}$ : $t_{cl}$ 时刻发电机转子角度最大值与最小值差	$x_{20}$ : $t_{cl}$ 时刻发电机角速度最大值与最小值差
$x_{21}$ : $t_{cl}$ 时刻发电机角加速度最大值与最小值差	$x_{22}$ : $t_{cl}$ 时刻发电机转子动能最大值与最小值差
$x_{23}$ : 系统的总能量调整	$x_{24}$ : $t_{cl}$ 时刻系统所有转子动能的平均值
	$x_{25}$ : 发电机从 $t_0$ 到 $t_{cl}$ 转子角度变化的最大值

### 2.2 基学习算法

研究表明, 基学习算法输出为每个类别的概率时, 生成训练集 1 能改进 Stacking 元学习方法的性能<sup>[15]</sup>。针对电力系统暂态稳定评估二分类问题, Stacking 框架下的第 k 个基学习算法对第 n 个数据的类属性的概率:  $P_{kn} = (p_{k1}(\mathbf{x}_n), p_{k2}(\mathbf{x}_n))$ , 其中 1 和 2 表示暂态稳定和不稳定。进一步构建训练集 1:  $L_1 = \{(y_n, P_{11}(\mathbf{x}_n), P_{12}(\mathbf{x}_n), \dots, P_{K1}(\mathbf{x}_n), P_{K2}(\mathbf{x}_n)), n = 1, \dots, N\}$ 。

本文采用 SVM、KNN、DT 和 NB 等作为基学习算法，各基学习算法的类别概率输出如下：

SVM：核函数为径向基核，模型参数通过网格搜索得到，类属性概率输出为<sup>[16]</sup>：

$$P(y_i | \mathbf{x}) = \frac{1}{1 + e^{Af(\mathbf{x})+B}} \quad (1)$$

式中： $f(\mathbf{x})$ 为决策函数； $A, B$ 为控制 $f(\mathbf{x})$ 形状的参数。

KNN：设定初始 $K$ 值为3，设数据 $\mathbf{x}$ 的3个最近邻点，用 $\{(y_s, \mathbf{x}_s), s=1, 2, 3\}$ 来表示，那么类属性概率输出为

$$P_i(\mathbf{x}) = \frac{\sum_{s=1}^3 f(y_s)/d(\mathbf{x}, \mathbf{x}_s)}{\sum_{s=1}^3 1/d(\mathbf{x}, \mathbf{x}_s)} \quad (2)$$

式中：当数据 $\mathbf{x}$ 的类别 $i=y_s$ 时， $f(y_s)=1$ ，否则 $f(y_s)=0$ ； $d(\mathbf{x}, \mathbf{x}_s)$ 为欧几里德距离函数。

DT：采用 C4.5 算法<sup>[17]</sup>，考虑数据 $\mathbf{x}$ 分在决策树的叶上，令 $m_i$ 为该叶上具有类别 $i$ 的样本数，假定该叶上的多数类为 $\hat{I}$ ，令 $E = \sum_{i \neq \hat{I}} m_i$ ，那么类别属性概率为

$$P_i(\mathbf{x}) = 1 - \frac{E+1}{\sum_i m_i + 2} \quad (3)$$

$$\text{当 } i \neq \hat{I} \text{ 时, } P_i(\mathbf{x}) = (1 - P_{\hat{I}}(\mathbf{x})) \times \frac{m_i}{E} \quad (4)$$

NB：给定数据 $\mathbf{x}$ ，类别属性 $i$ 的后验概率为

$$P_i(\mathbf{x}) = \frac{P(i | \mathbf{x})}{\sum_i P(i | \mathbf{x})} \quad (5)$$

NB 使用拉普拉斯估计得到 $P(i | \mathbf{x})$ ，对连续值进行有监督的离散化。

### 2.3 元学习算法

元学习算法采用线性回归 (Linear Regression, LR)<sup>[15]</sup>，核心思想是利用预定的权值将属性进行线性组合来表示类属性。

$$y = w_0 + w_1 x_1 + w_2 x_2 + \dots + w_{2k} x_{2k} \quad (6)$$

式中： $y$ 为类属性； $(w_0, w_1, w_2, \dots, w_{2k})$ 为权向量； $(x_0, x_1, x_2, \dots, x_{2k})$ 为训练集1的输入特征向量。其中权向量从训练数据中计算得到，LR 选择 $2k+1$ 个系数使训练数据的预测值和真实值之差的平方和最小。假定 $n$ 个训练数据，预测值和真实值之差的平方和为

$$\sum_{i=1}^n (y^{(i)} - \sum_{j=0}^{2k} w_j x_j^{(i)})^2 \quad (7)$$

式中： $y^{(i)}$ 为第 $i$ 个数据的真实类属性； $\sum_{j=0}^{2k} w_j x_j^{(i)}$ 为类预测值。

## 3 算例分析

### 3.1 新英格兰 39 节点系统

新英格兰 39 节点系统的单线结构图如图 2 所示<sup>[18]</sup>。这个系统由 10 台发电机、39 条母线和 46 条线路组成，代表美国新英格兰州的一个 345 kV 电力网络，其中 39 号母线上的发电机是一个等值机，代表了与这个系统相连的加拿大部分的电力网络。系统基准功率为 100 MVA，基准电压为 345 kV。

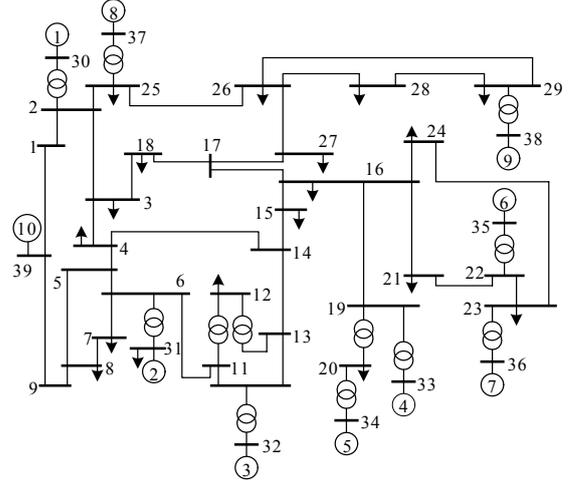


图 2 新英格兰 10 机 39 节点系统

Fig.2 New England 10-generator 39-bus test system

80%，85%，…，130%的基准负荷水平下，相应改变发电机出力。假定每条线路发生三相短路故障，故障位置位于线路的 0，0.2，0.5 和 0.8 四个点上。系统在 0.1 s 发生故障，0.15 s 切除近端故障，0.2 s 切除远端故障，或者 0.17 s 切除近端故障，0.22 s 切除远端故障；以及考虑后备保护动作时，0.35 s 切除近端故障，0.40 s 切除远端故障，或 0.45 s 切除近端故障，0.50 s 切除远端故障。发电机为 4 阶模型，除发电机 1 外，剩余 9 台发电机配置了 IEEE DC1 型励磁系统，负荷为恒阻抗模型，仿真时长为 4 s，并用 4 s 末任意两台发电机的相对功角差是否大于 $360^\circ$ 来判定系统稳定性。仿真软件为 PST2.0<sup>[19]</sup>，仿真生成 8 096 个样本，随机选择 5 343 个进行训练，剩余用于测试。

为验证所提方法的有效性，与单个暂态稳定评估模型进行比较。通过 10 折交叉验证在训练集上得到 SVM、KNN、DT 和 NB 的最优模型，其中，SVM 的惩罚参数 $C$ 的取值：0.1，1，10，100，1 000，10 000； $\gamma$ 的取值：0.5，1，2，4，8，16，32。KNN 设定初始 $K$ 值为 3，通过交叉验证得到最优 $K$ 值。DT 的置信参数 $\theta$ 范围为 (0.05, 0.30)，步长为 0.05，该值越低则会导导致更“猛烈”地对树进行修剪；叶

节点上最少实例数  $\rho$  的范围为 (2, 5), 步长为 1。上述单暂态稳定评估模型的测试结果见表 2。综合考虑测试正确率、Kappa 统计值和接受者操作特征曲线 (Receiver Operating Characteristic Curve, ROC) 下方面积的平均指标  $\lambda'$ , 计算公式为:

$$\lambda' = \frac{\alpha + K_a + \beta}{3}$$

其中:  $\alpha$  为测试正确率;  $K_a$  为 Kappa 统计值;  $\beta$  为 ROC 下方面积。

表 2 新英格兰 39 节点系统单模型测试结果

Tab.2 Test results of single model in New England 39-bus test system

评估模型	最优模型参数	测试正确率/%	Kappa 统计值	ROC 下方面积	平均指标
SVM	$C=1\ 000, \gamma=4$	98.47	0.965	0.982	0.977
KNN		97.89	0.952	0.979	0.970
DT	$\theta=0.25, \rho=2$	98.32	0.962	0.982	0.975
NB		90.99	0.805	0.982	0.899

Stacking 融合 SVM、KNN、DT 和 NB 的最优模型, 不同 Stacking 组合模型测试结果见表 3。其中, Stacking (SVM, KNN, DT, NB) 表示融合 SVM、KNN、DT 和 NB 等四种基分类算法。

表 3 新英格兰 39 节点 Stacking 模型测试结果

Tab.3 Test results of Stacking model in New England 39-bus test system

Stacking 模型	测试正确率/%	Kappa 统计值	ROC 下方面积	平均指标
Stacking (SVM, KNN, DT, NB)	98.61	0.969	0.998	0.984
Stacking (SVM, KNN, DT)	98.61	0.969	0.998	0.984
Stacking (SVM, DT, NB)	98.47	0.965	0.982	0.977
Stacking (SVM, KNN, NB)	98.47	0.965	0.982	0.977
Stacking (KNN, DT, NB)	98.47	0.965	0.982	0.977

比较表 2 和表 3 结果可知, Stacking 模型的电力系统暂态稳定评估性能至少与最好的单个模型相同。从 Stacking (SVM, KNN, DT, NB) 的四个基学习算法中剔除其中一个, 如 NB, 评估性能没有改变, 说明 NB 在 Stacking (SVM, KNN, DT, NB) 中的影响较小, 剔除 SVM、KNN 和 DT 的任何一个, 评估性能均有下降。

### 3.2 IEEE50 机测试系统

IEEE50 机测试系统由 50 台发电机, 145 条母线和 453 条传输线构成<sup>[20]</sup>。100%, 105%, ..., 120% 的基准负荷水平下, 相应改变发电机出力。假定每条线路发生三相短路故障, 故障位置位于线路的 0, 0.2, 0.5 和 0.8 四个点上。系统在 0.1 s 发生故障, 0.15 s 切除近端故障, 0.2 s 切除远端故障, 或者 0.17 s 切除近端故障, 0.22 s 切除远端故障; 以及考虑后备保护动作时, 0.35 s 切除近端故障, 0.40 s 切除远端故障, 或 0.45 s 切除近端故障, 0.50 s 切除远端故障。50 台发电机中, 发电机 1~6 和发电机 23 为 6 阶模型, 其中发电机 1、2、5、6 和 23 配置了简单励磁模型且配有 IEEE 1 型电力系统稳定器, 发电机 3、4 配置了 IEEE DC1 型励磁系统。剩余 43 台发电机为经典模型, 负荷模型为恒阻抗。仿真时长为 4 s, 暂稳判据同新英格兰 39 母线测试系统。仿真生成 36 220 个样本, 随机选择 23 905 个进行训练, 剩余样本用于测试。单个评估模型的优化过程同新英格兰 39 节点测试系统, 测试结果如表 4。

表 4 IEEE 50 机测试系统单模型测试结果

Tab.4 Test results of single model in IEEE 50-machine test system

评估模型	最优模型参数	测试正确率/%	Kappa 统计值	ROC 下方面积	平均指标
SVM	$C=10\ 000 \gamma=32$	94.62	0.872	0.929	0.916
KNN		95.24	0.888	0.947	0.929
DT	$\theta=0.25 \rho=2$	96.42	0.916	0.962	0.947
NB		91.28	0.801	0.97	0.895

不同 Stacking 组合模型测试结果见表 5。比较表 4 和表 5 的结果, Stacking (SVM, KNN, DT, NB) 比最好的单个模型 (DT) 的评估性能较好。从 4 个基学习算法中剔除一个, 评估性能均有下降。

表 5 IEEE 50 机测试系统 Stacking 模型测试结果

Tab. 5 Test results of Stacking model in IEEE 50-machine test system

Stacking 模型	测试正确率/%	Kappa 统计值	ROC 下方面积	平均指标
Stacking (SVM, KNN, DT, NB)	96.83	0.926	0.992	0.962
Stacking (SVM, KNN, DT)	96.74	0.924	0.991	0.961
Stacking (SVM, DT, NB)	96.55	0.919	0.990	0.958
Stacking (SVM, KNN, NB)	96.08	0.908	0.990	0.953
Stacking (KNN, DT, NB)	96.57	0.920	0.992	0.959

3.1 节和 3.2 节的结果表明, 在新英格兰 39 节点测试系统和 IEEE50 机测试系统上, Stacking (SVM, KNN, DT, NB) 均能改善单个模型的评估性能。

### 3.3 与其他暂态稳定评估组合模型的比较

进一步验证本文所提组合模型的有效性, 与文献[7]组合多个 SVM 的 Bagging 算法和文献[9]组合多个 NB 的 AdaBoost 算法进行比较。其中, 新英格兰 39 节点测试系统上, Bagging 和 AdaBoost 算法的迭代次数为 100, IEEE50 机测试系统上, Bagging 算法的迭代次数为 30, AdaBoost 算法的迭代次数为 100, SVM 的最优参数同 3.1 和 3.2 节, 测试结果如表 6 所示。比较表 3、表 5 和表 6, 可知 Stacking (SVM, KNN, DT, NB) 在上述两个测试系统上, 评估性能较好。

表 6 其他组合模型测试结果

Tab.6 Test results of other combining multiple models

测试系统	评估模型	测试 正确 率/%	Kappa 统计值	ROC 下方面积	平均 指标
新英格兰 39 节点	Bagging (SVM)	98.61	0.969	0.998	0.984
	AdaBoost (NB)	97.20	0.937	0.991	0.966
IEEE50 机	Bagging (SVM)	94.69	0.873	0.97	0.930
	AdaBoost (NB)	94.57	0.873	0.987	0.935

## 4 结论

研究了一种基于 Stacking 元学习策略的暂态稳定评估模型, 即利用线性回归函数融合四种评估方法, 包括支持向量机、K 最近邻法、决策树和朴素贝叶斯, 表示为 Stacking (SVM, KNN, DT, NB)。新英格兰 39 节点和 IEEE50 机测试系统上进行了大量仿真, 仿真结果证明: Stacking (SVM, KNN, DT, NB) 模型比单个评估模型、组合模型 Bagging (SVM) 和 AdaBoost (NB) 的性能要好, 为电力系统暂态稳定评估提供了新的研究思路。

### 参考文献

[1] Sobajic D J, Pao Y. Artificial neural-net based dynamic security assessment for electric power systems[J]. IEEE Transactions on Power Systems, 1989, 4 (1) : 220-228.

[2] Rovnyak S, Kretsinger S, Thorp J, et al. Decision trees for real-time transient stability prediction[J]. IEEE Transactions on Power Systems, 1994, 9(3): 1417- 1426.

[3] 王同文, 管霖, 章小强, 等. 基于扩展k阶近邻法的电力系统稳定评估新算法[J]. 电力系统自动化, 2008, 32 (3) : 18-21, 75.

WANG Tong-wen, GUAN Lin, ZHANG Xiao-qiang,

et al. A new method for power system stability assessment based on extended k-nearest neighbor classifier[J]. Automation of Electric Power Systems, 2008, 32 (3) : 18-21, 75 .

[4] 向丽萍, 王晓红, 王建, 等. 基于支持向量机的暂态稳定分类中的特征选择[J]. 继电器, 2007, 35(9): 17-21. XIANG Li-ping, WANG Xiao-hong, WANG Jian, et al. Feature selection for SVM based transient stability classification [J]. Relay, 2007, 35(9): 17-21.

[5] Pavella M. Power system transient stability assessment-traditional vs modern methods[J]. Control Engineering Practice, 1998, 6 (10) : 1233-1246.

[6] 马骞, 杨以涵, 刘文颖, 等. 多输入特征融合的组合支持向量机电力系统暂态稳定评估[J]. 中国电机工程学报, 2005, 25 (6) : 17-23.

MA Qian, YANG Yi-han, LIU Wen-ying, et al. Power system transient stability assessment with combined SVM method mixing multiple input features[J]. Proceedings of the CSEE, 2005, 25 (6) : 17-23.

[7] 许涛, 贺仁睦, 王鹏, 等. 基于统计学习理论的电力系统暂态稳定评估[J]. 中国电机工程学报, 2003, 23 (11) : 51-55.

XU Tao, HE Ren-mu, WANG Peng, et al. Power system transient stability assessment based on statistical learning theory[J]. Proceedings of the CSEE, 2003, 23 (11) : 51-55.

[8] Jayasekara B, Annakkage U D. Transient security assessment using multivariate polynomial approximation[J]. Electric Power Systems Research, 2007, 77 (5-6) : 704-711.

[9] 卢锦玲, 朱永利, 赵洪山, 等. 提升型贝叶斯分类器在电力系统暂态稳定评估中的应用[J]. 电工技术学报, 2009, 24 (5) : 177-182.

LU Jin-ling, ZHU Yong-li, ZHAO Hong-shan, et al. Power system transient stability assessment based on boosting bayesian classifier[J]. Transactions of China Electrotechnical Society, 2009, 24 (5) : 177-182.

[10] Wolpert D H. Stacked generalization[J]. Neural Networks, 1992, 5 (2) : 241-259.

[11] 王浩畅, 赵铁军, 郑德权, 等. 基于元学习策略的分类器融合方法及应用[J]. 通信学报, 2007, 28 (10) : 7-13.

WANG Hao-chang, ZHAO Tie-jun, ZHENG De-quan, et al. Meta-learning based classifier ensemble strategy and application[J]. Journal on Communications, 2007, 28 (10) : 7-13 .

[12] 李亦宁, 王晓茹, 向丽萍, 等. 利用自组织映射SOM实现电力系统暂态稳定评估结果可视化[J]. 电力系统保护与控制, 2009, 37(5): 41-46.

( 下转第 23 页 continued on page 23 )

- Journal of Beijing University of Posts and Telecommunications, 2008, 31(3): 84-88.
- [15] 郭华伟, 施文康, 刘清坤, 等. 一种新的证据组合规则[J]. 上海交通大学学报, 2006, 40(11): 1895-1900.  
GUO Hua-wei, SHI Wen-kang, LIU Qing-kun, et al. A new combination rule of evidence[J]. Journal of Shanghai Jiaotong University, 2006, 40(11): 1895-1900.
- [16] 李鹏, 颜艳, 郑武军, 等. 证据理论融合量子神经网络的短期负荷预测[J]. 电力系统保护与控制, 2010, 38(16): 49-53.  
LI Peng, YAN Yan, ZHENG Wu-jun, et al. Short-term load forecasting based on quantum neural network by evidential theory[J]. Power System Protection and Control, 2010, 38(16): 49-53.
- [17] 孙即祥. 现代模式识别[M]. 二版. 北京: 高等教育出版社, 2008.  
SUN Ji-xiang. Modern pattern recognition[M]. Second edition. Beijing: Higher Education Press, 2008.
- [18] 徐岩, 刘金生, 张亚刚, 等. 聚类算法在电网故障元件定位应用中的研究[J]. 电力系统保护与控制, 2010, 38(12): 13-18.  
XU Yan, LIU Jin-sheng, ZHANG Ya-gang, et al. Study of application of hierarchical cluster analysis in power net fault location[J]. Power System Protection and Control, 2010, 38(12): 13-18.
- [19] 彭春华. 基于免疫BPSO算法与拓扑可观性的PMU最优配置[J]. 电工技术学报, 2008, 23(6): 119-124.  
PENG Chun-hua. Optimal PMU placement based on immune BPSO algorithm and topology observability[J]. Transactions of China Electrotechnical Society, 2008, 23(6): 119-124.

---

收稿日期: 2010-03-08; 修回日期: 2010-09-27

作者简介:

高振兴 (1984-), 男, 硕士研究生, 研究方向为智能信息处理技术在电力系统中的应用、设备状态检修技术;  
E-mail: xingge555@yahoo.com.cn

郭创新 (1969-), 男, 教授, 博士生导师, 研究方向为智能电网和分布式能源并网、智能信息处理技术及其在电力系统中的应用;

俞斌 (1986-), 男, 博士研究生, 研究方向为电力系统故障诊断、智能电网相关应用研究等。

---

(上接第 16 页 continued from page 16)

- LI Yi-ning, WANG Xiao-ru, XIANG Li-ping, et al. SOM based visualization of power system transient stability assessment results[J]. Power System Protection and Control, 2009, 37(5): 41-46.
- [13] 王海燕, 刘天琪, 李兴源, 等. 基于蚁群优化算法的电力系统暂态稳定评估特征选择[J]. 电力系统保护与控制, 2008, 36(21): 1-6.  
WANG Hai-yan, LIU Tian-qi, LI Xing-yuan, et al. Feature selection based on ant colony optimization for power system transient stability assessment[J]. Power System Protection and Control, 2008, 36(21): 1-6.
- [14] 向丽萍, 王晓茹, 王晓红. 电力系统暂态稳定评估的特征选取[J]. 继电器, 2008, 36(6): 26-31.  
XIANG Li-ping, WANG Xiao-ru, WANG Xiao-hong. Feature selection for transient stability evaluation in power system [J]. Relay, 2008, 36(6): 26-31.
- [15] Witten I H, Frank E. Data mining: practical machine learning tools and techniques[M]. 2nd edition. Singapore: Elsevier, 2005.
- [16] Platt J. Probabilities for SV machines[M]. Advances in Large Margin Classifiers, MIT Press, 2000: 61-74.
- [17] Quinlan J R. C4. 5: Programs for machine learning[M]. Morgan Kaufmann Publishers, 1993.
- [18] Pai M A. Energy function analysis for power system stability[M]. Boston: Kluwer Academic Publishers, 1989.
- [19] Rogers G. Power system oscillations[M]. Boston: Kluwer Academic Publishers, 2000.
- [20] Vittal V. Transient stability test systems for direct stability methods[J]. IEEE Transaction on Power Systems, 1992, 7 (1): 37-43.

---

收稿日期: 2010-04-07; 修回日期: 2010-04-29

作者简介:

叶圣永 (1974-), 男, 博士研究生, 主要研究方向为数据挖掘、电力系统稳定与控制; E-mail: yeshengyong410@126.com

王晓茹 (1962-), 女, 博士, 教授, 博士生导师, 主要研究方向为电力系统保护和安全稳定控制、变电站自动化技术;

刘志刚 (1975-), 男, 博士, 教授, 博士生导师, 主要研究方向为现代信号处理及其在电力系统中的应用。