

基于支持向量机的暂态稳定评估双阶段特征选择

叶圣永, 王晓茹, 刘志刚, 钱清泉

(西南交通大学电气工程学院, 四川省 成都市 610031)

Dual-stage Feature Selection for Transient Stability Assessment Based on Support Vector Machine

YE Shengyong, WANG Xiaoru, LIU Zhigang, QIAN Qingquan

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

ABSTRACT: Regarding to high dimensionality in power system transient stability assessment, an original feature set was set up, which is irrelevant to system scale. A dual-stage feature selection method based on support vector machine was proposed. During the first stage, the original features are sorted using support vector machine recursive feature elimination method and removed of those behind. Then a group of dimension reduction features is gained. For the second stage, the wrapper method that uses radial basis function kernel support vector machine as classifier is adopted, and a near-optimal feature subset is obtained through best-first search. Finally, in New England 39-bus test system and IEEE 50-generator test system, the feature selection approach was applied in original feature sets and simulation results approved the approach's effectiveness. Meanwhile, the feature subsets obtained by the dual-stage feature selection, are also valid for other transient stability assessment models.

KEY WORDS: transient stability assessment; machine learning method; support vector machine; recursive feature element; wrapper; principal component analysis

摘要: 针对电力系统暂态稳定评估的高维性, 在构造一组与系统规模无关的原始特征集基础上, 提出一种支持向量机双阶段特征选择方法。第1阶段以支持向量机递归特征选择法对原始特征集进行排序, 消去对分类不重要的特征, 得到一组降维的特征集; 第2阶段以径向基核支持向量机为分类器的包装法, 用最佳优先搜索算法得到一组近似最优特征子集。最后, 在新英格兰39节点和IEEE 50机测试系统上,

对原始特征集使用所提的特征选择方法, 仿真结果证明所提方法的有效性。同时, 采用支持向量机双阶段特征选择法得到的特征子集对其他暂态稳定评估模型同样有效。

关键词: 暂态稳定评估; 机器学习; 支持向量机; 递归特征选择; 包装法; 主成分分析法

0 引言

机器学习方法为电力系统暂态稳定评估提供了新的途径^[1-6], 其中进行特征分析来降低原始特征维数是研究的问题之一, 因为较多的输入特征可能包含与稳定指标无关的特征, 特征之间的冗余使得模型训练时间长、权值难收敛及分类性能不理想。同时电力系统的高维性是理论研究和工程实践中重要难题, 研究电力系统特征选择有着重要的理论价值和实际意义^[7-14]。文献[7]探讨了大电力系统暂态稳定评估中的2类输入特征分析方法: 1) 特征子集的方法, 文中采用统计相关方法, 选择与输出相关性强的特征, 同时消去特征间相关性强的特征; 2) 特征空间的变换, 文中使用判别分析法。在新英格兰39母线和IEEE 50机测试系统的算例仿真结果发现第2种方法更有效。文献[8]提出一种基于神经网络的输入特征灵敏度分析的特征排序方法, 对一组暂态稳定评估输入特征进行排序。所提方法能发现对分类重要的输入特征组合, 但不能消除特征之间的冗余性。文献[9]采用Fisher识别和序列特征选择技术, 获得具有最优“价值”的特征子集。文献[10]根据矛盾样本的个数来确定特征选择的判据, 并利用Tabu搜索技术从维数较大的原始特征集中选出几组有效特征, 所提方法能有效地降低输入空间的维数。文献[11]提出了一种基于输

基金项目: 国家自然科学基金项目(90610026); 中央高校基本科研业务费专项资金项目(SWJTU09ZT10); 新世纪优秀人才支持计划项目(NECT-08-0825)。

Project Supported by National Natural Science Foundation of China (90610026); Project Supported by the Fundamental Research Funds for the Central Universities (SWJTU09ZT10); Project Supported by Program for New Century Excellent Talents in University (NECT-08-0825).

入空间的可分性评估的特征选择方法，通过发现样本中的不一致的算例，定义了输入空间中的可分离性指标。使用该指标作为判据，采用广度优先搜索寻找最优的特征子集。文献[12]将灵敏度指标、灵敏度分析和主成分分析法(principal component analysis, PCA) 3种特征降维方法用到暂态稳定评估中，大幅减少了输入特征。文献[13]将PCA法和遗传算法相结合用于暂态稳定评估的降维，PCA法的缺点是所得特征为原始特征的组合，不利于发现原始特征中对分类重要的特征。特征选择的理想方法是：将所有可能的特征子集作为学习机器的输入，然后选取能产生最好分类结果的子集^[15]。理想方法针对暂态稳定评估的 n 维原始特征集，其特征子集多达 2^n 个，直接采用穷尽的方法将耗费大量的机时。

本文提出一种新的暂态稳定评估的特征选择方法——支持向量机双阶段法。利用支持向量机递归特征选择(support vector machine recursive feature elimination, SVM-RFE)对原始特征进行排序，去掉一些排序靠后的特征，得到一组降维的特征集；然后以径向基核(radial basis function kernel, RBF)支持向量机为分类器的包装法(wrapper)，最佳优先搜索得到一组近似最优特征子集。

1 暂态稳定评估原始特征的构建

构建有效的原始特征能提高电力系统暂态稳定评估的正确率，研究人员主要从3个角度研究了暂态稳定评估的原始特征：

1) 从时间上分，原始特征可分为静态特征和动态特征。静态特征是有关故障前系统各种测量值或它们求出的组合指标^[16]，由于求取方便快捷，是最先用于暂态稳定评估的一类特征^[5,17-18]；动态特征是有关故障持续期间和故障后的一些测量值或由它们求出的组合指标，能提供故障对系统造成冲击的更充足和准确的信息。

2) 从空间上分，原始特征可分为电网参数特征和发电机参数特征^[1]。电网参数特征包括母线的有功负荷和无功负荷、母线电压幅值和相角、线路的有功和无功潮流、最靠近故障的发电机母线电压、系统总的有功负荷水平、系统总的无功负荷水平、系统总的有功出力、系统总的无功出力等；发电机参数特征包括发电机的转子角、发电机加速功率、发电机加速度、发电机加速能量、发电机转子动能等。

3) 从随系统规模变化上分，原始特征分为元

件特征和系统特征^[16]。元件特征是指单个元件的状态量，如发电机的有功功率、母线电压等，或基于某个单一元件的状态量计算得出的指标；系统特征是采用系统内许多元件的状态量进行计算得出的组合指标^[1,19]，特征维数不随系统规模变化。

本文综合现有文献，构造了一组与系统规模无关的暂态稳定评估原始特征集，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23为 $\sum_{i=1}^n P_{ai} \delta_{di}$ ， 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， $\delta_{di} = (\delta_i - \delta_{coi})|_{t_{cl}}$ 为第 i 台发电机在 t_{cl} 时刻的相对于系统惯量中心等值转子角 δ_{coi} 的转子角。

表 1 暂态稳定评估原始特征集
Tab. 1 Original feature set in transient stability assessment

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

2 支持向量机双阶段特征选择方法

2.1 第 1 阶段特征选择

支持向量机的递归特征选择由 Guyon 等首次提出^[20]，用于癌症分类的基因选择。SVM-RFE 的基本思想：采用原始特征作为输入，训练好 SVM，当消除其中的 1 个输入特征时，SVM 的权向量 w 将发生变化，根据 w 的变化大小确定相应特征的重要程度。每次去掉 1 个特征，将这一过程递归进行，

得到原始特征的排序列表。

根据 SVM 理论^[21], 给定一组训练数据 (\mathbf{X}_i, y_i) , $i=1, 2, \dots, l$, l 为样本量, $\mathbf{X}_i=(x_1, x_2, \dots, x_i, \dots, x_n) \in \mathbf{R}^n$ 为输入特征向量, $y_i \in \{-1, 1\}$ 为第 i 个样本的类别标识。满足约束 $0 \leq \alpha_i \leq C$ 和 $\sum_{i=1}^l y_i \alpha_i = 0$ 的前提下 (α_i 为与每个样本对应的拉格朗日乘子, C 为惩罚因子), SVM 的目标函数为

$$Q(\boldsymbol{\alpha}) = \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (\mathbf{X}_i \mathbf{X}_j) - \sum_{i=1}^l \alpha_i \quad (1)$$

或

$$Q(\boldsymbol{\alpha}) = \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(\mathbf{X}_i \mathbf{X}_j) - \sum_{i=1}^l \alpha_i \quad (2)$$

式(1)为线性情况, 式(2)为非线性情况。进一步可表达为 $Q = \frac{1}{2} \boldsymbol{\alpha}^T \mathbf{H} \boldsymbol{\alpha} - \mathbf{e} \boldsymbol{\alpha}^T$, 其中 \mathbf{H} 的元素为 $y_i y_j \mathbf{X}_i \mathbf{X}_j$ 或 $y_i y_j K(\mathbf{X}_i, \mathbf{X}_j)$, \mathbf{e} 是全 1 矢量。

为计算消去输入特征 x_i 后目标函数的改变, 假定 $\boldsymbol{\alpha}$ 不变只需重复计算 \mathbf{H} , 即对应着计算 $y_i y_j \mathbf{X}_i(-i) \mathbf{X}_j(-i)$ 或 $y_i y_j K(\mathbf{X}_i(-i), \mathbf{X}_j(-i))$, 生成矩阵 $\mathbf{H}(-i)$, 其中记号 $(-i)$ 表示特征 x_i 被消除。于是所有特征的排序标准为

$$\Delta Q(i) = \frac{1}{2} \boldsymbol{\alpha}^T \mathbf{H} \boldsymbol{\alpha} - \frac{1}{2} \boldsymbol{\alpha}^T \mathbf{H}(-i) \boldsymbol{\alpha} \quad (3)$$

消去对分类不重要(排序靠后)的一些特征, 得到一组最有前途的降维特征集。

降维特征集比原始特征集维数少, 且特征集中的特征均与分类有较大的相关性, 然而特征间仍有可能存在一定的冗余, 需要进一步消除冗余。

2.2 第 2 阶段特征选择

以 RBF-SVM 为分类器的包装法(wrapper), 将所选择的特征子集的分类性能作为评估判据反馈给 SVM, 并进行修正, 不断循环此过程就可获得近似最优特征子集^[22]。不单独采用第 2 阶段特征选择方法的理由是, 大量或冗余的原始特征集影响搜索时间和近似最优特征子集。第 1 阶段的初步筛选利于第 2 阶段较快能得到近似最优特征子集。第 2 阶段特征选择中, 采用 RBF-SVM 作为特征子集性能评估的分类器, 还要考虑整个特征空间的搜索算法, 因为尽管将原始特征降维, 仍然要避免彻底详尽的搜索。

本文利用最佳优先搜索算法在空间中寻找近似最优的特征子集, 由于不知道支持向量机在各特征子集上的实际正确率, 所以利用 5 折交叉验证的

正确率估计作为启发函数和评价函数。最佳优先算法具体步骤如下:

1) 给出候选列表 T 上的初始状态, 状态表示某一特征集, 令无效列表 D 为空集; 假定初始状态为原始特征集, 并赋给最佳特征集 B 。

2) 令 $v = A_{\max}\{f(t), t \in T\}$, 其中 $A_{\max}\{\cdot\}$ 表示从候选列表 T 中取评价函数 $f(t)$ 最大时对应的特征集, 评价函数 $f(t)$ 为特征集 t 的训练集上 5 折交叉验证支持向量机评估正确率的平均值, 其中支持向量机模型采用原始特征集上 5 折交叉验证得到的最优模型参数。

3) 将 v 从候选列表 T 中剔除, 并加入到无效列表 D 中。

4) 若 $f(v) - \varepsilon > f(B)$, 其中 ε 表示支持向量机 5 折交叉验证平均性能是否改进的阈值, 那么 v 赋于 B 。

5) 展开 v 得到其子女节点(即消除某个特征后的特征子集), 并得到各自的评价函数值; 若 v 的某个子女节点不在 T 和 D 列表中, 则加入到 T 表中。

6) v 向前展开 d 步, 若 B 改变, 则返回到步骤 2)。

7) 得到最佳特征集 B 。

上述搜索过程中, 为减少多次交叉验证的计算量, 设定评估正确率的标准差为 0.01, 若小于该阈值则停止后续的交叉验证, 避免了在大数据集合上的计算耗时。由于最佳优先搜索不舍弃节点, 在每一步评价中, 都将当前节点和以前节点的估价值进行比较, 因此能得到一个“最佳的节点”。

3 算例分析

3.1 新英格兰 39 节点系统

新英格兰 39 节点系统由 10 台发电机、39 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^[23], 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。

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, 故障位置位于线路首端的 0、20%、50% 和 80% 等处。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，0.50s 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 4s，并用 4s 末任意 2 台发电机的相对功角差是否大于 360° 来判定系统稳定性。仿真软件为 PST2.0^[24]，共生成 8 096 个样本，随机选择 5 343 个进行训练，剩余的用于测试。

构建 25 维原始特征集 A，首先利用 SVM-RFE 法排序，SVM 的核函数为 RBF 函数，即： $K(\mathbf{X}_i, \mathbf{X}_j) = \exp(-\gamma\|\mathbf{X}_i - \mathbf{X}_j\|^2)$ ， $\gamma > 0$ 。10 折交叉验证模型最优参数 $C=1000$ ， $\gamma=4$ 。按照特征的“价值”由高到低排序，得到特征集： $A_1 = \{x_{18}, x_{12}, x_9, x_{19}, x_7, x_1, x_6, x_{21}, x_3, x_{17}, x_{22}, x_{16}, x_8, x_{25}, x_{24}, x_5, x_2, x_{10}, x_4, x_{23}, x_{13}, x_{20}, x_{11}, x_{15}, x_{14}\}$ 。从特征集 A_1 的末尾逐一消去特征，采用原始特征集的最优参数构建对应的评估模型，比较 SVM 在不同特征数的训练准确率 a_{train} 、支持向量数目 n_{svm} 和测试准确率 a_{test} ，如图 1 所示，图中 n_f 为特征数。




图 1 新英格兰系统不同特征数的支持向量机性能指标
Fig. 1 Performance of RBF-SVM in different feature sets

特征排序与核函数的选择有较大关系，采用线性核函数 $K(\mathbf{X}_i, \mathbf{X}_j) = \mathbf{X}_i \mathbf{X}_j$ ，最优参数 $C=1000$ ，经过 SVM-RFE 排序得到特征集： $A'_1 = \{x_1, x_{20}, x_9, x_{16}, x_8, x_4, x_{10}, x_{12}, x_2, x_5, x_{21}, x_{23}, x_{13}, x_{25}, x_{24}, x_{18}, x_6, x_{19}, x_{17}, x_{22}, x_7, x_{14}, x_3, x_{11}, x_{15}\}$ 。特征集 A_2 逐一消去特征，所得支持向量数、训练和测试准确率如图 2 所示。比较




图 2 不同特征数的线性核函数支持向量机性能指标
Fig. 2 Performance of linear SVM in different feature sets

图 1、2，由分类准确率和向量的数目得出，线性核函数的评估性能较差，因此本文提出采用径向基核函数进行评估。

图 1 中，按照特征的“价值”由高到低排序取特征集 A_1 前面的 10—25 个特征数时，所得到的支持向量的数量变化很小，原始 25 个特征对应的支持向量个数为 304，前 10 维特征子集对应的支持向量个数为 294，且 SVM 分类性能相近。实例说明特征初步选择方法是有效的。据此，裁剪掉那些对性能指标影响不大的特征，并考虑一定的裕度。因此，选择前 10 个特征，即 $A_2 = \{x_{18}, x_{12}, x_9, x_{19}, x_7, x_1, x_6, x_{21}, x_3, x_{17}\}$ 。

进一步采用以 RBF-SVM 为分类器的包装法和最佳优先搜索法，寻找近似最优特征子集，后向搜索得到一组特征子集： $A_{21} = \{x_{18}, x_{19}, x_7, x_6, x_{21}, x_3, x_{17}\}$ 。搜索的停止判据是：若向前展开 5 个节点 ($d=5$) 没有改善性能就回溯，其中评估模型性能改善的阈值 $\varepsilon=0.1\%$ 。

为验证本文所提方法的有效性，与原始特征集 A、常用于暂态稳定评估的 PCA 法^[12-13]及任意选择的一组特征子集进行比较。PCA 方法将原始特征集降维为 9 维，即 PCA 子集 A_{22} 担负了原始数据集的 95% 的方差；任意选择的特征子集 $A_{23} = \{x_4, x_{14}, x_2, x_8, x_1, x_{15}, x_{12}, x_{11}\}$ 。

训练集上，利用 10 折交叉验证分别训练以 A、 A_{21} 、 A_{22} 和 A_{23} 为输入的 RBF-SVM 暂态稳定评估模型，模型参数 C 取为 0.1、1、10、100、1000 和 10000， γ 取为 0.5、1、2、4、8、16 和 32。在测试集上测试上述最优模型，测试结果如表 2 所示，表中平均指标 η 的计算公式为

$$\eta = \frac{a_{\text{test}} + K + r}{3} \tag{4}$$

式中： K 为 Kappa 统计值； r 为接受者操作特征曲线(receiver operating characteristic curve, ROC)的下方面积。

表 2 新英格兰 39 节点测试结果

Tab. 2 Test results in New England test system

输入特征集	维数	模型参数		测试正确率/%	K	r	η
		C	γ				
A	25	1000	4	98.47	0.965	0.982	0.977
A_{21}	7	1000	32	98.54	0.967	0.983	0.978
A_{22}	9	10000	32	98.25	0.960	0.980	0.974
A_{23}	8	1000	1	66.03	0.016	0.506	0.394

由表 2 的测试结果得出：采用 SVM 双阶段特征选择得到的特征子集 A_{21} ，能保持与原始特征相

近的分类性能,且维数减少为原始特征的1/3; A_{21} 比PCA子集 A_{22} 的分类性能略好,且维数较少;此外,任意选择的特征子集 A_{23} 上的评估性能最差,ROC下方面积约为0.5,可见与随机猜测分类性能相近。

3.2 IEEE 50机测试系统

IEEE 50机测试系统由50台发电机、145条母线和453条传输线构成^[25]。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,故障位置位于线路首端的0、20%、50%和80%等处。系统在0.1s发生故障,0.15s切除近端故障,0.2s切除远端故障,或者0.17s切除近端故障,0.22s切除远端故障;以及考虑后备保护动作时,0.35s切除近端故障,0.40s切除远端故障,或0.45s切除近端故障,0.50s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4s,暂稳判据同新英格兰39节点测试系统。仿真生成36220个样本,随机选择23905个进行训练,剩余样本用于测试。

构建25维的原始特征集 B ,采用SVM-RFE法排序($C=10000$, $\gamma=32$),得到特征集合: $B_1 = \{x_3, x_6, x_{16}, x_{15}, x_{22}, x_2, x_7, x_{25}, x_5, x_{11}, x_{20}, x_{19}, x_1, x_{18}, x_{17}, x_8, x_{10}, x_9, x_4, x_{12}, x_{24}, x_{23}, x_{21}, x_{13}, x_{14}\}$ 。从特征集 B_1 末尾逐一消去特征,不同特征数 n_f 的训练准确率 a_{train} 、测试准确率 a_{test} 和支持向量数 n_{svm} 如图3所示。特征数为15—25时,SVM分类性能相近,支持向量个数变化不大。选择 B_1 的前15维,即 B_2 ,然后以RBF-SVM为目标分类器的wrapper和最佳优先搜索获得近似最优特征子集,停止判据同新英格兰39




图3 不同特征数的支持向量机性能指标

Fig. 3 Performance of SVM in different feature sets

母线系统,得到特征子集: $B_{21} = \{x_3, x_{22}, x_2, x_7, x_{25}, x_5, x_{20}, x_{19}, x_1, x_{18}, x_{17}\}$ 。

为比较所选特征子集的有效性,用PCA法分析原始特征集,得到12维特征子集 B_{22} , B_{22} 担负了原始数据集的95%的方差。任意选择的特征子集 $B_{23} = \{x_1, x_2, x_4, x_5, x_8, x_{11}, x_{12}, x_{14}, x_{15}, x_{22}\}$ 。新英格兰39节点系统推荐特征集 $B_{24} = \{x_{18}, x_{19}, x_7, x_6, x_{21}, x_3, x_{17}\}$ 。模型训练同新英格兰39节点系统,测试结果如表3所示。

表3 IEEE 50机测试系统的测试结果

Tab. 3 Test results in IEEE 50-generator test system

输入特征集	维数	模型参数		测试正确率/%	K	r	平均指标
		C	γ				
B	25	10000	32	94.62	0.872	0.929	0.915
B_{21}	10	10000	32	95.12	0.884	0.933	0.923
B_{22}	12	10000	32	94.54	0.870	0.927	0.914
B_{23}	12	10000	8	73.12	0.226	0.592	0.516
B_{24}	7	10000	32	93.80	0.852	0.917	0.902

由表3测试结果可知,SVM双阶段特征选择得到的特征子集 B_{21} 比原始特征集 B 和PCA子集 B_{22} 分类性能较好,且维数减少为原始特征的1/2。任意选择的特征子集 B_{23} 分类性能最差,和随机猜测接近。算例1推荐特征子集 B_{24} 比 B_{21} 的评估平均指标下降约2%,说明系统规模增大,需要增加描述系统的动态特征。另一方面,特征子集 B_{24} 和 B_{21} 分别为7和10维,有5维特征相同,为 $\{x_{18}, x_{19}, x_7, x_3, x_{17}\}$,约占前者的70%、后者的50%。7维特征中剩余2维没有包含在10维特征中,可能是由构建样本时2个系统考虑的负荷水平不完全相同和最佳优先搜索得到的是近似最优特征子集等造成的。

3.3 其他暂态稳定评估模型的评估结果

为验证支持向量机双阶段特征选择方法的通用性,将上述特征子集作为已有的暂态稳定评估模型的输入,如多层感知器(multilayer perception, MLP)^[1,5]、 k 最近邻法(k nearest neighbor, KNN)^[26]和决策树(decision tree, DT)^[6]等。其中MLP的隐含层数为1,神经元数为10,采用反向传播算法来学习网络权值,学习率为0.7,动量因子为0.5;KNN的 k 初值为1,通过交叉验证得到最优 k 值,近邻之间的距离用欧几里德距离来度量,利用线性近邻搜索法得到最近邻;DT采用C4.5算法,置信因子设定为0.25,该值在绝大多数场合运行良好^[15]。

上述3种评估模型在新英格兰39节点和IEEE 50机测试系统上的仿真结果如表4所示。

MLP、KNN和DT在特征子集 A_{21} 和 B_{21} 上的分

表 4 两系统其他模型的测试结果

Tab. 4 Test results of other models in two test systems

测试系统	评估模型	输入特征集	测试正确率/%	K	r	平均指标
新英格兰 39 节点 系统	MLP	A	95.38	0.896	0.985	0.944
		A ₂₁	94.51	0.878	0.985	0.936
		A ₂₃	60.00	0.171	0.625	0.465
	DT	A	97.89	0.952	0.979	0.969
		A ₂₁	97.85	0.952	0.976	0.968
		A ₂₃	52.99	-0.136	0.584	0.325
IEEE 50 机测试 系统	MLP	A	98.32	0.962	0.982	0.975
		A ₂₁	97.85	0.952	0.99	0.973
		A ₂₃	65.74	0.048	0.608	0.437
	KNN	B	90.47	0.763	0.933	0.866
		B ₂₁	90.20	0.762	0.932	0.865
		B ₂₃	72.50	0.244	0.649	0.539
DT	MLP	B	95.24	0.888	0.947	0.929
		B ₂₁	94.46	0.870	0.939	0.917
		B ₂₃	75.17	0.368	0.808	0.642
	KNN	B	96.42	0.916	0.962	0.947
		B ₂₁	96.00	0.906	0.964	0.943
		B ₂₃	76.61	0.394	0.762	0.640

类性能基本和原始特征集相近，而上述评估模型在任意选择的特征子集 A_{23} 和 B_{23} 上的分类性能最差，说明本文所提方法可用于其他暂态稳定评估模型。

4 结论

针对电力系统暂态稳定评估的输入特征高维性，本文提出了一种支持向量机双阶段特征选择方法，在新英格兰 39 节点和 IEEE 50 机测试系统上进行了仿真研究，得到如下结论：

1) 在保持原始特征集分类性能情况下，所提方法能大幅降低维数，比常用于暂态稳定评估的主成分分析法较好，且能找出利于分类的特征子集；

2) 基于支持向量机的双阶段特征选择方法，同样适用于其他暂态稳定评估模型，如神经网络、决策树和 k 最近邻法等。

参考文献

- [1] 黄辉, 舒乃秋, 李自品, 等. 基于信息融合技术的电力系统暂态稳定评估[J]. 中国电机工程学报, 2007, 27(16): 19-23.
Huang Hui, Shu Naiqiu, Li Zipin, et al. Power system transient stability assessment based on information fusion technology[J]. Proceedings of the CSEE, 2007, 27(16): 19-23(in Chinese).
- [2] 吴琼, 杨以涵, 刘文颖. 基于最小二乘支持向量机的电力系统暂态稳定在线预测[J]. 中国电机工程学报, 2007, 27(25): 38-43.
Wu Qiong, Yang Yihan, Liu Wenying. Electric power system transient stability on-line prediction based on least squares support vector machine[J]. Proceedings of the CSEE, 2007, 27(25): 38-43(in Chinese).
- [3] 管霖, 王同文, 唐宗顺. 电网安全监测的智能化关键特征识别及稳定分区算法[J]. 电力系统自动化, 2006, 30(21): 22-27.
Guan Lin, Wang Tongwen, Tang Zongshun. Intelligent algorithm for kernel feature identification and stability-based system division in power grid security monitoring[J]. Automation of Electric Power Systems, 2006, 30(21): 22-27(in Chinese).
- [4] 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 Yihan, Liu Wenying, 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(in Chinese).
- [5] Moulin L S, Alves da Silva A P, El-Sharkawi M A, et al. Support vector machines for transient stability analysis of large-scale power systems[J]. IEEE Transactions on Power Systems, 2004, 19(2): 818-825.
- [6] 叶圣永, 王晓茹, 刘志刚, 等. 基于随机森林算法的电力系统暂态稳定性评估[J]. 西南交通大学学报, 2008, 43(5): 573-577.
Ye Shengyong, Wang Xiaoru, Liu Zhigang, et al. Transient stability assessment based on random forest algorithm[J]. Journal of Southwest Jiaotong University, 2008, 43(5): 573-577(in Chinese).
- [7] Muknahallipatna S, Chowdhury B H. Input dimension reduction in neural network training-case study in transient stability assessment of large systems[C]//Proceedings of the International Conference on Intelligent Systems Applications to Power Systems. Orlando: Institute of Electrical & Electronics Engineers, 1996: 50-54.
- [8] Bahbah A G, Girgis A A. Input feature selection for real-time transient stability assessment for artificial neural network (ANN) using ANN sensitivity analysis[C]//Proceedings of the 21st 1999 IEEE International Conference on Power Industry Computer Applications. Piscataway: Institute of Electrical & Electronics Engineers, 1999: 295-300.
- [9] Jensen C A, El-Sharkawi M A, Marks R J. Power system security assessment using neural networks: feature selection using Fisher discrimination[J]. IEEE Transactions on Power Systems, 2001, 16(4): 757-763.
- [10] 顾雪平, 张文朝. 基于 Tabu 搜索技术的暂态稳定分类神经网络的输入特征选择[J]. 中国电机工程学报, 2002, 22(7): 66-70.
Gu Xueping, Zhang Wenchao. Feature selection by Tabu search for neural-network based transient stability classification[J]. Proceedings of the CSEE, 2002, 22(7): 66-70(in Chinese).
- [11] Tso S K, Gu X P. Feature selection by separability assessment of input spaces for transient stability classification based on neural networks[J]. International Journal of Electrical Power & Energy Systems, 2004, 26(3): 153-162.
- [12] Sawhney H, Jeyasurya B. A feed-forward artificial neural network with enhanced feature selection for power system transient stability assessment[J]. Electric Power Systems Research, 2006, 76(12): 1047-1054.
- [13] 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 Liping, Wang Xiaohong, Wang Jian, et al. Feature selection for SVM based transient stability classification[J]. Relay, 2007, 35(9): 17-21(in Chinese).
- [14] 王皓, 孙宏斌, 张伯明, 等. 基于混合互信息的特征选择方法及其在静态电压稳定评估中的应用[J]. 中国电机工程学报, 2006, 26(7): 77-81.
Wang Hao, Sun Hongbin, Zhang Boming, et al. Hybrid mutual information based feature selection method as applied to static voltage

- stability assessment in power systems[J]. Proceedings of the CSEE, 2006, 26(7): 77-81(in Chinese).
- [15] Witten I H, Frank E. Data mining: practical machine learning tools and techniques[M]. The 2nd edition. Singapore: Elsevier, 2005: 198-199.
- [16] 顾雪平, 曹绍杰. 神经网络在暂态稳定评估中应用的研究述评[J]. 华北电力大学学报, 2003, 30(4): 11-16.
Gu Xueping, Cao Shaojie. Research overview of neural-network application to transient stability assessment of power systems[J]. Journal of North China Electric Power University, 2003, 30(4): 11-16(in Chinese).
- [17] Lotufo A D, Lopes M L, Minussi C R. Sensitivity analysis by neural networks applied to power systems transient stability[J]. Electric Power Systems Research, 2007, 77(7): 730-738.
- [18] Ferreira W P, Silveira M D, Lotufo A P, et al. Transient stability analysis of electric energy systems via a fuzzy ART-ARTMAP neural network[J]. Electric Power Systems Research, 2006, 76(6-7): 466-475.
- [19] Tso S K, Gu X P, Zeng Q Y, et al. An ANN-based multilevel classification approach using decomposed input space for transient stability assessment[J]. Electric Power Systems Research, 1998, 46(3): 259-266.
- [20] Guyon I, Weston J, Barnhill S, et al. Gene selection for cancer classification using support vector machines[J]. Machine Learning, 2002, 46(1): 389-422.
- [21] Vapnik V N. The nature of statistical learning theory[M]. New York: Springer-Verlag, 1995: 138-146.
- [22] Kohavi R, John G H. Wrappers for feature subset selection[J]. Artificial Intelligence, 1997, 97(1-2): 273-324.
- [23] Pai M A. Energy function analysis for power system stability[M]. Boston: Kluwer Academic Publishers, 1989: 223-227.
- [24] Chow J H, Cheung K W. A toolbox for power system dynamics and control engineering education and research[J]. IEEE Transactions on Power Systems, 1992, 7(4): 1559-1564.
- [25] Vittal V. Transient stability test systems for direct stability methods[J]. IEEE Transactions on Power Systems, 1992, 7(1): 37-43.
- [26] 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(03): 18-21, 75.
Wang Tongwen, Guan Lin, Zhang Xiaoqiang, 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(03): 18-21, 75(in Chinese).



叶圣永

收稿日期: 2010-06-15。

作者简介:

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

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

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

钱清泉(1936), 男, 教授, 博士生导师, 中国工程院院士, 研究方向为工业监控、铁道电气化和自动化以及电力系统自动化。

(责任编辑 谷子)