

一种适用于 WAMS 量测数据的系统暂态功角稳定评估方法

邵雅宁, 唐飞, 刘涤尘, 马志昊, 卞成志

(武汉大学电气工程学院, 湖北 武汉 430072)

摘要: 考虑 WAMS 量测数据刷新速率快, 数据量大的特点, 提出了一种适用于 WAMS 量测数据的暂态功角稳定评估方法。选取初始特征量集并用核主成分分析法对特征集进行降维, 过滤冗余特征并降低分类器输入向量的维度。构建训练样本集, 计算各样本的初始特征量集并进行降维。通过训练 ECVM 分类器对暂态功角稳定进行评估, 并用测试数据集验证分类器的准确率。在新英格兰 10 机 39 节点系统中的仿真表明, 所提算法有较高的分类准确率, 与传统分类算法相比降低了单个样本评估所需的时间, 具有工程使用价值。

关键词: WAMS 数据; 核主成分分析; ECVM 分类器; 暂态稳定评估

An approach of transient angle stability assessment in power system for WAMS measured data

SHAO Yaning, TANG Fei, LIU Dichen, MA Zhihao, BIAN Chengzhi

(School of Electrical Engineering, Wuhan University, Wuhan 430072, China)

Abstract: An approach of angle stability assessment is proposed considering the characteristics in fast refresh rate and large amount of WAMS data. First, initial set of features is selected and then reduced by kernel principal component analysis to filter redundant features. Then, training sample aggregation is constructed and initial set of features of each sample are calculated and reduced. Finally, the method is evaluated through training ECVM classifiers, the accuracy of which is validated by test data set. Simulations on New England 10-machine 39-node system show the proposed algorithm has higher classified accuracy, and compared to traditional methods it has lower evaluation time for a single sample and engineering application value.

This work is supported by the State Grid Corporation of China, Major Projects on Planning and Operation Control of Large Scale Grid (No. SGCC-MPLG029-2012) and National Natural Science Foundation of China (No. 51207113).

Key words: WAMS data; kernel principal component analysis; ECVM classifier; transient stability assessment

中图分类号: TM712 文献标识码: A 文章编号: 1674-3415(2015)06-0033-07

0 引言

电力系统的安全稳定运行直接关系到国民经济的发展, 系统发生故障后若不能及时有效地对故障加以控制而使电网失稳运行、甚至解列, 将引发大规模停电事故, 造成灾难性的后果^[1]。暂态稳定性破坏是造成电网灾难性事故的主因之一, 寻求快速、准确的暂态稳定评估方法对保证电网安全运行具有重要意义^[2]。

随着广域测量系统(Wide Area Measurement System, WAMS)在工程中的广泛应用, 基于 WAMS

量测数据的电网暂态稳定评估方法为暂态稳定评估提供了新思路。人工智能类方法由于具有不受模型约束, 评估速度快等特点, 已经被广泛应用于电力系统暂态稳定评估中^[3-5]。由于暂态功角失稳往往发生在故障后的极短时间内, 目前应用较广泛的人工智能分类方法, 如 ANN, SVM 等, 算法复杂度较高, 需要较长时间才能对当前系统的故障状态做出评估, 难以满足暂态功角稳定评估对时间的要求。

针对这一问题, 本文提出了一种适用于 WAMS 量测数据的暂态功角稳定评估方法。从 WAMS 数据中选择能够表征系统功角稳定状态的特征量组成特征量集, 使用核主成分分析法(Kernel Principal Component Analysis, KPCA)进一步降低特征量维度, 作为分类器的输入特征, 用于训练一种基于广

基金项目: 国家电网公司大电网重大专项资助项目课题(SGCC-MPLG029-2012); 国家自然科学基金(51207113)

泛内核的核向量机(Extensive Kernel Core Vector Machine, ECKVM)分类器。在 10 机 39 节点系统中的仿真验证了该方法的有效性。

1 KPCA 算法

1.1 初始特征量的选取原则

WAMS 系统利用计算机技术和现代高速数字化通信网络实现全网各节点数据的同步采集、实时记录,因此其数据量十分庞大。从特征集降维的角度考虑,由于 WAMS 量测数据维度极高,而且包含许多冗余特征量和彼此相关的特征量,直接对全部数据进行降维处理运算量十分巨大,且会给合理地分析系统稳定状态造成困难。基于上述原因,本文参考文献[6-8]中提出的特征量,经过筛选后选择了 24 维能够反映系统故障后实时运行特性的特征量,组成初始特征量集,如表 1 所示。并使用 KPCA 算法对其进行降维处理,以进一步降低特征集维度,降低计算量。

表 1 初始特征量集

Table 1 Initial feature set

特征	特征描述	特征	特征描述
1	机械输入功率平均值	13	相对加速度方差
2	加速功率的均值	14	相对加速度均值
3	加速功率的方差	15	最大转子角度发电机动能
4	相对加速功率的均值	16	发电机转子动能平均值
5	相对加速功率的方差	17	COI 坐标下的转速之和
6	加速度的均值	18	COI 坐标下的最大转速
7	最大加速度的相对角度	19	COI 坐标下的最小转速
8	最大相对角加速度	20	领先机与殿后机功角之差
9	最小相对角加速度	21	最大加速度之差
10	领先机和殿后机加速度差值	22	最大加速度变化率之差
11	加速度方差	23	最大最小转子动能之差
12	最大最小加速度转子角度差	24	最大转子动能变化率之差

1.2 传统主成分分析法

主成分分析法(Principal Component Analysis, PCA)是多元统计学中一种常用的降维方法,用对原有变量进行线性组合后得到的低维、互不相关的新变量,代替原有的高维、相关的变量。所得到的新变量被称为原变量的主成分,主成分的选取原则是在降低变量维度的同时尽可能保留原有变量中所包含的信息。

设 $X=(x_1, x_2, \dots, x_p)^T$ 为一个 p 维随机矢量,其主成分为 $Y_i (i=1, 2, \dots, k; k \leq p)$, 它满足如下条件^[9-10]:

(1) $Y_i = a_i^T X$, 其中 a_i 为 $p \times 1$ 维数字矢量;

(2) a_i 满足 $a_i^T a_i = 1$, 且它的取值满足使 Y_i 的方差达到最大;

(3) 各主成分 Y_1, Y_2, \dots, Y_k 之间是相互独立的。

将上述原则推广到含 n 个矢量的矢量集 $X_{n \times p}$, 设其协方差矩阵为 S , S 由式(1)求得。

$$S = \frac{\sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})'}{n} \quad (1)$$

设矩阵 S 的特征根分别为 $\lambda_1 \geq \dots \geq \lambda_p \geq 0$, 可证明矢量集 $X_{n \times p}$ 第 i 个主成分的方差就是 λ_i 。每一个主成分都是矢量集数据在某一个方向上的投影,在不同的方向上这些数据方差的大小由其特征值决定,与特征根对应的正则正交特征向量分别为 a_1, \dots, a_p , 则 $y_i = a_{i1}x_1 + \dots + a_{ip}x_p$ 为原矢量集的第 i 个样本主成分。

$\lambda_k / \sum_{i=1}^p \lambda_i$ 是第 k 个主成分 y_k 的贡献率,表示了第 k 个主成分所保留的原矢量集离散程度信息的比例, $\sum_{i=1}^k \lambda_i / \sum_{i=1}^p \lambda_i$ 是前 k 个主成分 (y_1, \dots, y_k) 的累积贡献率,表示前 k 个主成分保留的原矢量集离散程度信息的比例。

1.3 KPCA 算法

主成分分析法假设各个变量间满足线性相关关系,是一种有效的线性算法^[11]。然而电力系统是一个典型的非线性系统,故障发生后各电气变量间呈现较强的非线性关系,因此需要考虑非线性方法对电网故障后的电气变量进行降维处理。

KPCA 算法是一种非线性主成分分析方法,可以被看成是训练样本数据经过非线性映射后的一种主成分分析方法。其基本思想是对映射到高维特征空间后的矢量集进行主成分分析。首先,通过一个非线性映射 ϕ 将矢量集 X 映射到一个高维特征空间,如式(2)所示。

$$\phi: X^p \rightarrow F \quad (2)$$

同时映射后的数据已被中心化,即满足

$$\frac{1}{N} \sum_{i=1}^N \phi(x_i) = 0 \quad (3)$$

将原本非线性的问题线性化,再在高维度特征空间上进行线性主成分分析^[12],映射后的协方差矩阵如式(4)所示。

$$S = \frac{\sum_{i=1}^n (\phi(x_i) - \phi(\bar{x}))(\phi(x_i) - \phi(\bar{x}))'}{n} \quad (4)$$

KPCA 算法常用的核函数有多项核函数、Sigmoid 核函数以及高斯核函数,考虑高斯核函数

是一个归一化核,不需要再对样本数据进行归一化,因此可以使映射计算更加简便。此外,高斯核只有一个调整参数,便于对映射结果进行调节。且多项式核函数是高斯核函数的特殊形式,Sigmoid 核函数与高斯核函数在某些参数情况下具有相似的特性^[13]。综合高斯核函数的上述优势,因此本文选择高斯径向基函数作为 KPCA 算法的核函数,如式(5)所示。

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (5)$$

其中, σ 为核宽度。

2 ECVM 分类器

2.1 分类器设计原则

人工智能类稳定评估方法的基本思路是:依靠对大量训练样本的类比和学习,形成稳定评估知识,从而进行电网稳定状态的在线判别。电力系统暂态功角的稳定评估是一个模式识别问题,可通过构建分类器对功角暂态稳定性进行分类,使识别的结果与实际情况尽可能相符^[1]。首先,获取在故障状态下的学习样本,分为稳定和 unstable 两类,通过对样本的学习构建分类器,即暂态功角稳定评估模型。然后,将待分析的样本输入评估模型,即可评估该样本的稳定状态。由于暂态功角失稳往往发生于故障后的短时间内,因此对分类器的评估速度有很高的要求。为了实现快速、准确的暂态功角稳定判别,本文基于 ECVM 算法构建了分类器。

2.2 核向量机算法

对于某给定的样本集 $S = \{x_1, \dots, x_m\}$, 其中 $x_i \in \mathbf{R}^d$, d 是正整数, \mathbf{R} 为实数集, S 的最小闭包球指的是包含集合 S 中所有数据点的最小球,记为 $MEB(S)$ 。

对于 MEB 问题,假设子集 $Q \subset S$ 并且 $B(c, R) = MEB(Q)$, 如果 $S \subset B(c, (1 + \varepsilon)R)$, 则子集 Q 就称为集合 S 的核心集,其中 ε 为给定的一个较小数且满足 $0 \leq \varepsilon \leq 1$ 。

传统 CVM 算法的运算步骤如下。

(1) 初始化核心集 $S_0 = \{\varphi(z_0)\}$ 、并基于 S_0 计算球体的中心 c_0 和半径 R_0 , 其中 S_0 可以选择样本集中的任意一个点 $z \in S$ 。

(2) 进行迭代运算。在第 t 次迭代中,如果所有的训练样本 $\varphi(z)$ 点都落在球 $B(c_t, (1 + \varepsilon)R_t)$ 之内,则迭代结束;否则,找到离球体的中心最远的样本点 $\varphi(z_t)$, 并生成一个新的核心集 $S_{t+1} = S_t \cup \{\varphi(z_t)\}$ 。

(3) 求解新的 MEB 问题,即 $MEB(S_{t+1})$ 问题。

(4) 令迭代步长增 1, 并返回到第 2 步。

算法结束时,包含在核心集中的向量即为支持向量,设定的 ε 值越小,所得的解越精确。由于所求核集的规模远小于传统 SVM 算法训练样本集的规模,因此可以降低训练算法的复杂度,提高算法运行速度。

2.3 ECVM 算法

对于传统的 CVM 算法,其时间主要耗费在第(2)步,即获取一个新球心的 QP 问题。为了进一步降低算法的时间复杂度,优化迭代过程,本文拟用 ECVM 算法作为分类器进行电力系统暂态功角的稳定性评估。ECVM 算法步骤如下^[14]:

(1) 初始化核心集 $S_0 = \{P, Q\}$ 、设定球体的中

心 $c_0 = \frac{1}{2}(P + Q)$, 半径 $R_0 = \frac{1}{2}\|P - Q\|$ 。 P 为样本集中的随机点, Q 为样本集中离 P 最远的一点。

(2) 进行迭代运算。在第 t 次迭代中,如果所有的训练样本 $\varphi(z)$ 点都落在球体 $B(c_t, (1 + \varepsilon)R_t)$ 之内,则迭代结束;否则,找到离球 $B(c_t, (1 + \varepsilon)R_t)$ 的中心 c_t 最远的样本点 $\varphi(z_t)$, 并生成新的核心集 $S_{t+1} = S_t \cup \{\varphi(z_t)\}$ 。

(3) 利用 Lagrange 方法求 $MEB(S_{t+1})$ 的 c_{t+1} 和 R_{t+1} 。具体求解过程如参考文献[14]所示。

(4) 令迭代步长增 1, 并返回到第 2 步。

ECVM 算法的时间复杂度和空间复杂度分别为 $o\left(\frac{m}{\varepsilon^2} + \frac{1}{\varepsilon^3}\right)$ 和 $o\left(\frac{1}{\varepsilon^2}\right)$, 且 ECVM 核心集中核向量的数量也大大减少了,其算法效率明显高于 SVM 和 CVM, 基于 ECVM 算法构建分类器,经过训练后对样本进行暂态功角稳定评估,可以减少稳定评估所需的时间。

3 基于 ECVM 分类器的稳定评估方法

3.1 样本构建方法

基于 ECVM 分类器的稳定评估方法需要两个数据集,即训练数据集和测试数据集。上述两个数据集来源于系统在不同运行方式和故障模式下进行离线仿真产生的仿真样本,然后从中提取所需数据得到的^[15]。其中,训练数据集用于建立和学习评估模型,测试数据集用于检验评估模型的有效性及其适应性。数据集中的每个样本均由两部分组成,记为 \mathbf{X} 和 \mathbf{Y} 。 \mathbf{X} 是一个 24×1 矩阵,由 24 维初始特征量在故障切除时刻的瞬时值组成, \mathbf{Y} 则表示该样本的稳定状态类别,记为 0 和 1,其中 0 代表该样本稳

定, 1 代表该样本不稳定。

3.2 算法流程

本文参考文献[16]中的算法步骤, 提出基于 ECVM 分类器的电力系统暂态功角稳定评估算法步骤如下^[16]。

(1) 构建样本集: 在不同运行方式和故障下对系统进行离线仿真, 通过计算获得各样本的初始特征量集。

(2) 特征集降维: 采用 KPCA 算法对初始特征量集做降维处理, 消除冗余特征, 降低分类器输入特征维度, 以提高算法效率;

(3) ECVM 训练: 使用训练数据集对 ECVM 分类器进行训练, 建立输入特征与评估结果之间的映射关系;

(4) 模型测试: 使用测试数据集来测试 ECVM 分类器的有效性。

算法流程如图 1 所示。

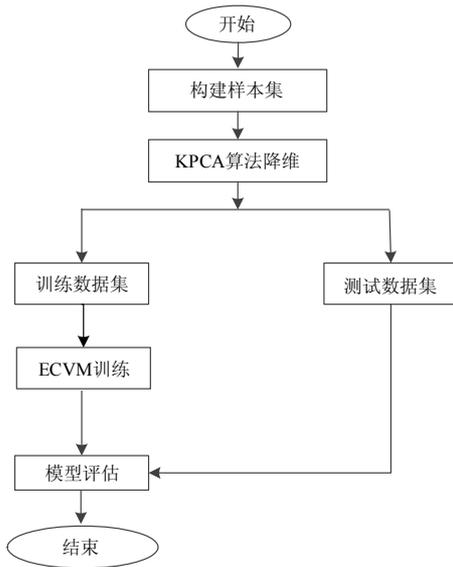


图 1 基于 ECVM 分类器的稳定评估算法流程

Fig. 1 ECVM based stability assessment algorithm process

3.3 模型测试

模型测试即使用测试数据集来评估所构建的 ECVM 分类器的有效性。用于测试分类器性能的指标有分类准确率、敏感度和特异度, 如式(6)~式(8)所示。

分类准确率为

$$TA = \frac{\sum_{i=1}^k T_i}{\sum_{i=1}^k T_i + \sum_{i=1}^k F_i} \quad (6)$$

敏感度为

$$SN_i = \frac{T_i}{T_i + F_i} \quad (7)$$

特异度为

$$TN_i = \frac{T_i}{T_i + F_{oi}} \quad (8)$$

其中: k 为状态数, 在本文中对应两种状态, 即稳定状态和不稳定状态进行分类; T_i 为第 i 种状态被分类器正确分类的样本数; F_i 为第 i 种状态被分类器错误分类的样本数; F_{oi} 为非 i 状态被分类到第 i 种状态中的样本数。准确率、敏感度和特异度越高, 样本被正确识别的机率越高, 分类器也就越准确。

4 实例分析

为验证本文所提算法的有效性和实用性, 在 PSASP 仿真平台下, 以 PSASP 仿真数据模拟实际 WAMS 量测数据, 基于新英格兰 10 机 39 节点系统进行仿真。为真实模拟实际系统中发生故障的场景, 考虑系统重载和轻载的情况, 在 80%~120%(以 10% 为变化步长)基准负荷下, 设置包括单相短路、单相断线以及三相短路故障在内的不同故障形式, 故障地点为系统中的随机位置, 故障切除时间分别设置为故障后的 0.05 s, 0.1 s 和 0.2 s, 根据仿真数据计算每个样本的初始特征量集, 共得到 1 600 个样本, 通过 PSASP 程序中提供的暂态功角稳定判别标准设定各个样本的稳定状态, 将全部样本按照各发电机间最大功角差是否超过 180° 分为稳定和不稳定两类, 其中稳定样本 1 235 个, 不稳定样本 365 个。抽取其中的 1 200 个样本组成训练集, 另外 400 个样本作为测试集。各个状态下的样本个数如表 2 所示。

表 2 各个状态下的样本数

Table 2 Number of samples of each state

类别	训练集	测试集
稳定	897	338
不稳定	303	62

4.1 特征集降维结果

应用 KPCA 算法对全部样本集进行降维, 通过计算协方差矩阵的特征根确定各主成分的贡献率, 如图 2 所示。由图 2 可知, 第 9 个主成分以后的各主成分贡献率都较低, 接近于零。

综合考虑降维效果以及保留信息的比例, 选择贡献率最大的 9 维主成分作为降维后的特征量集, 其累计贡献率达到了 90% 以上, 各主成分的贡献率如表 3 所示。在保留了原数据集 90% 以上信息的同

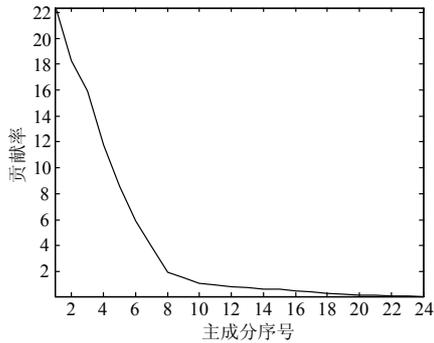


图 2 各主成分贡献率

Fig. 2 Contribution rate of each principal component

时, 将特征量维度从 24 维降低至 9 维, 降维效果明显, 可大幅提高算法效率。

表 3 各主成分贡献率

Table 3 Contribution rate of each principal component

主成分	贡献率
1	22.343
2	18.255
3	15.963
4	11.786
5	8.552
6	5.922
7	3.864
8	1.924
9	1.581

4.2 ECVM 分类结果及分析

在 Matlab 中, 用训练集样本对 ECVM 分类器模型进行训练, 并使用测试集验证算法的分类准确率 TA , 稳定状态和不稳定状态下的敏感度 SN 以及特异度 TN 。算法的分类准确率为 97%, 敏感度与特异度结果如表 4 所示。

表 4 两种状态下的算法敏感度和特异度

Table 4 SN and TN of two states

类别	稳定/%	不稳定/%
敏感度	97.3	95.2
特异度	99.1	86.8

对测试数据集的分类结果可以看出, ECVM 分类器对稳定状态下和不稳定状态下的样本都有较高的分类正确率, 达到了 95% 以上, 总体分类正确率达到 97%, 证明了本文所提的暂态功角稳定评估算法的有效性。根据分类器的训练原理, 通过加大训练集中的样本个数可以进一步提高分类的准确率, 同时考虑增加系统当前运行方式下的样本比例则可

以使分类更加准确, 满足实际工程应用的需要。

分类器对不稳定类样本分类的特异度为 86.8%, 但这一指标较低, 主要是由于测试集中不稳定样本的数量远低于稳定样本, 部分稳定样本被误分为不稳定一类导致了这一指标偏低, 并不影响 ECVM 分类器本身的准确性。

4.3 与传统稳定评估算法的比较

为验证本文所提的 KPCA+ECVM 暂态功角稳定评估算法的优越性, 基于表 1 中的原始特征量集, 使用传统的 SVM 算法和 ANN 算法对测试集样本进行稳定评估, 在分类准确率以及单个样本评估所需时间上与本文算法进行比较, 如表 5 所示。

表 5 KPCA+ECVM 算法与传统算法的比较

Table 5 Comparison of KPCA+ECVM algorithm and traditional algorithms

算法	准确率/%	单个样本评估所需时间/s
KPCA+ECVM	97	0.174
SVM	95.6	0.269
ANN	93.7	0.343

由表 5 可知, KPCA+ECVM 算法由于对输入特征进行了 KPCA 降维处理, 降低了输入分类器的特征维数, 同时过滤掉了部分冗余特征, 因此训练准确率比 SVM 算法和 ANN 算法有所提高。输入特征的降维同时缩短了识别样本所需的时间, 且由于 ECVM 分类器优化了算法的迭代过程, 其时间复杂度和空间复杂度相比于 SVM 算法大大降低了, 因此 KPCA+ECVM 算法的实时性得到了较大提高, 单个样本评估所需时间与 SVM 算法和 ANN 算法相比分别缩短了 35% 和 49%。仿真结果表明, 本文提出的暂态功角稳定评估算法由于进行了特征降维处理, 采用了计算效率更高的分类器, 从而提高了其计算时效性和稳定评估的精度, 能够满足电力系统在故障后迅速基于 WAMS 量测数据进行暂态功角稳定评估的需要。

4.4 训练样本增加对算法的影响

由于实际系统规模较大, 对其进行暂态功角稳定评估需要大量样本对分类器进行训练。在 IEEE 118 节点系统中设置故障并构建样本集, 验证本文算法在大规模系统中的适用性。

依照上文所述方法设置故障, 共获得 20 000 个样本, 抽取其中的 16 000 个组成训练集, 另外 4 000 个作为测试集。使用 KPCA 算法对样本进行降维处理, 并使用不同数量的训练样本对 ECVM 模型进行训练, 与 SVM 模型下所得结果进行比较, 如表 6 所示。

表 6 两种状态下的算法敏感度和特异度

Table 6 Comparison of KPCA+ECVM algorithm and SVM algorithms

训练集样本个数	准确率/%		支持向量数		单个样本评估所需时间/s	
	KPCA+ECVM	SVM	KPCA+ECVM	SVM	KPCA+ECVM	SVM
4 000	94.6	94.2	337	425	0.182	0.257
8 000	95.5	94.9	653	854	0.213	0.288
12 000	96.2	95.4	1 019	1 236	0.237	0.315
16 000	96.6	95.7	1 244	1 521	0.254	0.336

两种算法评估单个样本所需时间随训练样本数目增加的变化如图 3 所示。

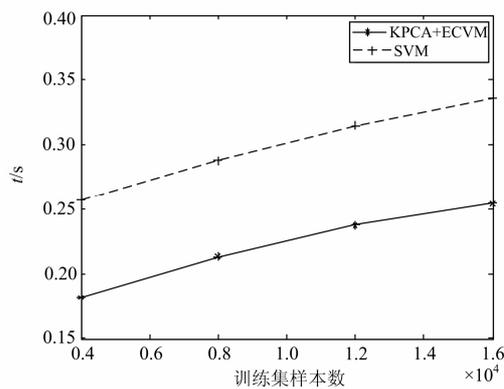


图 3 单个样本评估所需时间

Fig. 3 Time required for the assessment of one sample

从图 3 可以看出, 随着训练集的扩大, 评估单个样本所需的时间也增加了, 但是 KPCA+ECVM 算法耗时的增加量却始终小于 SVM 算法耗时的增加量。可见 KPCA+ECVM 算法的时间复杂度比传统 SVM 算法的要低, 训练样本越多, 其优势越明显, 可用于大规模系统中的暂态功角稳定评估。

5 结论

本文考虑 WAMS 系统量测数据刷新速率快, 数据量大的特点, 提出了一种基于 KPCA 算法和 ECVM 分类器的在线稳定评估方法, 在 New England 10 机 39 节点系统中进行了仿真验证, 得出如下结论:

(1) 基于 KPCA 算法的特征量降维方法, 可以有效降低分类器输入特征的维度, 同时过滤冗余信息, 有助于提升稳定评估的准确率且降低了计算量;

(2) 基于 ECVM 分类器的样本分类方法, 由于对迭代过程进行了优化, 对单个样本评估所需的时间比传统分类器(SVM, ANN)更短, 可基于 WAMS 量测数据对电力系统暂态功角稳定进行评估。

参考文献

- [1] 叶圣永. 基于机器学习的电力系统暂态稳定评估研究[D]. 成都: 西南交通大学, 2010.
YE Shengyong. Study on power systems transient stability assessment based on machine learning method[D]. Chengdu: Southwest Jiaotong University, 2010.
- [2] 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 Jinling, ZHU Yongli, ZHAO Hongshan, et al. Power system transient stability assessment based on boosting Bayesian classifier[J]. Transactions of China Electrotechnical Society, 2009, 24(5): 177-182.
- [3] 顾雪平, 李扬, 吴献吉. 基于局部学习机和细菌群体趋药性算法的电力系统暂态稳定评估[J]. 电工技术学报, 2013, 28(10): 271-279.
GU Xueping, LI Yang, WU Xianji. Transient stability assessment of power systems based on local learning machine and bacterial colony chemotaxis algorithm[J]. Transactions of China Electrotechnical Society, 2013, 28(10): 271-279.
- [4] 叶圣永, 王晓茹, 刘志刚, 等. 基于 Stacking 元学习策略的电力系统暂态稳定评估[J]. 电力系统保护与控制, 2011, 39(6): 12-16.
YE Shengyong, WANG Xiaoru, LIU Zhigang, et al. Power system transient stability assessment based on Stacking meta-learning strategy[J]. Power System Protection and Control, 2011, 39(6): 12-16.
- [5] 霍思敏, 王科, 陈震海, 等. 基于轨迹输入特征支持向量机的湖南电网暂态稳定在线识别[J]. 电力系统保护与控制, 2012, 40(18): 19-23.
HUO Simin, WANG Ke, CHEN Zhenhai, et al. Hunan power grid transient stability online detection based on support vector machine with trajectory input features[J]. Power System Protection and Control, 2012, 40(18): 19-23.
- [6] 刘玉田, 林飞. 基于相量测量技术和模糊径向基网络

- 的暂态稳定性预测[J]. 中国电机工程学报, 2000, 20(2): 19-23.
- LIU Yutian, LIN Fei. Application of PMU and fuzzy radial basis function network to power system transient stability prediction[J]. Proceedings of the CSEE, 2000, 20(2): 19-23.
- [7] 章小强. 智能稳定评估中的关键特征识别研究[D]. 广州: 华南理工大学, 2010.
- ZHANG Xiaoqiang. Studies on kernel feature recognition for intelligent stability assessment[D]. Guangzhou: South China University of Technology, 2010.
- [8] 唐飞, 王波, 查晓明, 等. 基于双阶段并行隐马尔科夫模型的电力系统暂态稳定评估[J]. 中国电机工程学报, 2013, 33(10): 90-97.
- TANG Fei, WANG Bo, ZHA Xiaoming, et al. Power system transient stability assessment based on two-stage parallel hidden markov model[J]. Proceedings of the CSEE, 2013, 33(10): 90-97.
- [9] 王静龙. 多元统计分析[M]. 北京: 科学出版社, 2008.
- [10] 张延松, 赵英凯. 基于 PCA 和粗糙集构建决策树的变电站故障诊断[J]. 电力系统保护与控制, 2010, 38(14): 104-109.
- ZHANG Yansong, ZHAO Yingkai. Fault diagnosis of substation by the constructed decision tree based on principal component analysis (PCA) and rough set[J]. Power System Protection and Control, 2010, 38(14): 104-109.
- [11] 张曦, 阎威武, 刘振亚, 等. 基于核主元分析和邻近支持向量机的汽轮机凝汽器过程监控和故障诊断[J]. 中国电机工程学报, 2007, 27(14): 56-61.
- ZHANG Xi, YAN Weiwu, LIU Zhenya, et al. Process monitoring and fault diagnosis of condenser using KPCA and PSVM[J]. Proceedings of the CSEE, 2007, 27(14): 56-61.
- [12] 唐炬, 谢颜斌, 周倩, 等. 基于最优小波包变换与核主分量分析的局部放电信号特征提取[J]. 电工技术学报, 2010, 25(9): 35-40.
- TANG Ju, XIE Yanbin, ZHOU Qian, et al. Feature extraction for partial discharge signals based on the optimal wavelet packet basis transform and kernel principal component analysis[J]. Transactions of China Electrotechnical Society, 2010, 25(9): 35-40.
- [13] 韩海涛, 马红光, 曹建福, 等. 基于非线性频谱特征及核主元分析的模拟电路故障诊断方法[J]. 电工技术学报, 2012, 27(8): 248-254.
- HAN Haitao, MA Hongguang, CAO Jianfu, et al. Fault diagnosis method of analog circuits based on characteristics of the nonlinear frequency spectrum and KPCA[J]. Transactions of China Electrotechnical Society, 2012, 27(8): 248-254.
- [14] 王奇安, 陈兵. 基于广泛内核的 CVM 算法的入侵检测[J]. 计算机研究与发展, 2012, 49(5): 974-982.
- WANG Qian, CHEN Bing. Intrusion detection system using CVM algorithm with extensive kernel methods[J]. Journal of Computer Research and Development, 2012, 49(5): 974-982.
- [15] 李迁, 李华强, 黄昭蒙, 等. 基于暂态能量函数混合法的电力系统脆弱性分析[J]. 电力系统保护与控制, 2013, 41(20): 1-6.
- LI Qian, LI Huaqiang, HUANG Zhaomeng, et al. Power system vulnerability assessment based on transient energy hybrid method[J]. Power System Protection and Control, 2013, 41(20): 1-6.
- [16] MOHAMMADI M, GHAREHPETIAN G B. On-line transient stability assessment of large-scale power systems by using ball vector machines[J]. Energy Conversion and Management, 2010, 51(4): 640-647.

收稿日期: 2014-06-19; 修回日期: 2014-08-21

作者简介:

邵雅宁(1990-), 女, 硕士研究生, 主要研究方向为电力系统运行与控制。E-mail: 13545079709@163.com

(编辑 周金梅)