

基于代价敏感极端学习机的电力系统暂态稳定评估方法

陈 振,肖先勇,李长松,张 殷,胡清泉

(四川大学 电气信息学院,四川 成都 610065)

摘要:针对电力系统暂态稳定评估中稳定样本与不稳定样本误分类代价不同的特点,提出一种基于代价敏感极端学习机的电力系统暂态稳定评估方法。该方法在现有极端学习机的基础上,引入误分类代价的概念,以误分类代价最小为目标,构造代价敏感极端学习机,克服了现有极端学习机应用于暂态稳定评估时只追求高的分类准确率而忽略不稳定样本漏报率的缺点。新英格兰39节点系统和IEEE 145节点系统的仿真结果表明,所提方法的评估结果更倾向于将样本划分为误分类代价大的不稳定样本,以减小总的误分类代价。通过调整误分类代价矩阵,不仅可以使漏报率降为0,还能使稳定样本的误报率维持在较低的水平,保证了评估结果的可靠性。

关键词:电力系统;暂态稳定;评估;极端学习机;误分类代价;漏报率;稳定性

中图分类号: TM 712

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2016.02.019

0 引言

随着电力系统规模的不断增大,其动态特性愈加复杂,鲁棒性、复杂性与安全性之间的矛盾也越来越突出,对系统安全稳定评估提出了更高要求^[1-2]。作为动态安全评估的重要内容,深入研究电力系统暂态稳定评估方法具有重要意义^[3]。

现有暂态稳定评估方法可分为时域法^[4]、直接法^[5-6]以及模式识别法^[7-9]。其中,时域法适用于元件任意模型,结果准确可靠,但计算量大,在线应用困难;直接法能定量给出系统稳定裕度,计算速度快,但受元件模型限制,其准确性还需进一步提升;模式识别法的评估速度快,受系统规模和元件模型影响小,有良好的在线应用前景,但方法尚不够完善,工程应用还需进一步研究。

暂态稳定评估中已有的模式识别法主要有人工神经网络 ANN(Artificial Neural Network)、支持向量机 SVM(Support Vector Machine)、决策树 DT(Decision Tree)等。在这些方法中,ANN以其运算速度快、识别能力强的特点,深受国内外学者的关注^[10]。文献^[11]引入一种新型 ANN——极端学习机 ELM(Extreme Learning Machine)进行了暂态稳定在线评估的研究工作,其建立在稳定样本与不稳定样本误分类代价相同的假设上,并以误分率最小为训练目标^[12-13]。通过仿真,文献^[11]验证了 ELM 相对于其他模式识别方法具有更高的准确率和更快的运算速度,但无法消除漏报现象。

事实上,大规模复杂电力系统中,稳定样本与不稳定样本的误分类代价明显不同。若将稳定样本误分为不稳定样本,可能会造成某些控制装置的误动

作,但对整个系统的安全稳定运行影响小;而将不稳定样本误分为稳定样本,则可能导致系统的连锁崩溃甚至灾难性事故,其后果十分严重。若500个样本构成的测试集中,稳定和 unstable 样本分别为490个和10个,用 ELM 进行暂态稳定评估时,即使极端情况下将所有样本均划分为稳定样本,准确率也可达到98%,但误分类代价极大,使该评估结果失去实际意义。因此,在暂态稳定评估中,除了要关注评估结果的准确率,还必须考虑误分类代价,减少甚至消除不稳定样本的漏报率。

本文以现有 ELM 为基础,引入误分类代价的概念,研究稳定样本与不稳定样本误分类代价的差异,建立误分类代价矩阵,以误分类代价最小为目标,提出一种暂态稳定代价敏感极端学习机 CELM(Cost-sensitive Extreme Learning Machine)评估方法,并对暂态稳定分类性能测度指标进行了研究。在新英格兰39节点系统和IEEE 145节点系统上对所提方法进行仿真验证,结果表明,该方法不仅能满足漏报率为0的要求,还能使稳定样本的误报率维持在较低的水平,保证了评估结果的可靠性^[1],能更好地满足工程应用需求。

1 误分类代价及其定量刻画方法

电力系统长期处于稳定运行状态,不稳定事故的发生属于小概率事件。若系统遭受大的扰动后即将发生暂态不稳定,此时如果调度控制中心未能准确预测出系统将要失稳,进而没有采取必要的控制措施来缓解系统的压力,则势必会造成极其严重的后果,大量发电机可能被切除,大面积停电甚至会导致灾难性的后果;若系统遭受大扰动后,发电机间的相对功角在振荡后趋于平稳,系统将会保持暂态稳

定,如果此次扰动被误判为不稳定事故,调度运行人员则会根据相应的运行信息制定控制策略,通常情况下会采取切除少量发电机组或负荷等措施来维持系统稳定,所采取的措施虽然会造成少量的经济损失,但由于其在本质上是为了提高系统的暂态稳定性能,因而这种误判对整个系统的安全稳定运行影响较小。

因此,在电力系统暂态稳定分类过程中,稳定样本和不稳定样本的误分类所造成的代价明显不同,这种类间误分类代价的差异性可通过误分类代价矩阵定量刻画。

一般地,暂态稳定分类的代价混淆矩阵如表 1 所示。

表 1 暂态稳定分类代价混淆矩阵
Table 1 Cost confusion matrix of transient stability classification

真实状态	预测状态	
	稳定	不稳定
稳定	λ_{TS}	λ_{FS}
不稳定	λ_{FU}	λ_{TU}

其中, λ_{TS} 与 λ_{TU} 分别表示将稳定样本与不稳定样本正确划分为相应类所对应的代价,因此取值为 0; λ_{FS} 表示将稳定样本误分为不稳定样本所对应的代价; λ_{FU} 表示将不稳定样本误分为稳定样本所对应的代价。考虑到误分类代价的准确值难以获得,且引入误分类代价的目的是为了区分不同类在误分时严重程度上的差异性,因此可令 λ_{FS} 为 1, λ_{FU} 的取值则表示不稳定样本误分类代价与稳定样本误分类代价的比值。

在上述基础上,定义暂态稳定分类的误分类代价矩阵 C 为 N 阶对角矩阵,其中 N 为研究的样本数。对于矩阵 C 对角线上的任意元素 c_{ii} ,若 i 对应的样本为稳定样本,则令 $c_{ii}=\lambda_{\text{FS}}=1$;若 i 对应的样本为不稳定样本,则令 $c_{ii}=\lambda_{\text{FU}}$ 。

2 CELM 及其优化模型

2.1 ELM 的基本原理

ELM 是南洋理工大学黄广斌教授提出的一种新型单隐藏层前馈神经网络,具有训练速度极快以及泛化能力强的特点,因此在最近几年得到很大的关注和发展^[12-13]。

设训练样本集 $S=\{(x_i, y_i) | i=1, 2, \dots, N\}$,其中 $x_i=[x_{i1}, x_{i2}, \dots, x_{im}]^T$, $y_i=[y_{i1}, y_{i2}, \dots, y_{im}]^T$, n 和 m 分别表示输入维数和输出维数。给定隐含层节点数 L 和隐含层节点激励函数 $g(x)$,则 ELM 的数学模型可表示为:

$$\sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) = y_j \quad j=1, 2, \dots, N \quad (1)$$

其中, $w_i=[w_{i1}, w_{i2}, \dots, w_{in}]^T$ 表示连接输入节点与第 i 个隐含层节点的权值向量; $\beta_i=[\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 表示连接第 i 个隐含层与输出节点的权值向量; b_i 表示第 i 个隐含层节点的偏置。

式(1)的 N 个方程用矩阵的形式可表示为:

$$H\beta = Y \quad (2)$$

$$H = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{bmatrix} = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \cdots & g(w_L \cdot x_1 + b_L) \\ \vdots & & \vdots \\ g(w_1 \cdot x_N + b_1) & \cdots & g(w_L \cdot x_N + b_L) \end{bmatrix}_{N \times L} \quad (3)$$

其中, H 表示隐含层节点的输出矩阵; $\beta=[\beta_1, \beta_2, \dots, \beta_L]_{L \times m}^T$ 表示输出层权值矩阵; $Y=[y_1, y_2, \dots, y_N]_{N \times m}^T$ 表示样本输出矩阵。

黄广斌等^[12]严格证明了只要激励函数 $g(x)$ 无限可微,隐含层权值 w_i 以及隐含层节点偏置 b_i 可随机赋值,就能保证在 $L \leq N$ 的情况下,满足 $\|H\beta - Y\| < e$,其中 e 为任意小的正数。

在训练开始前,任意给定 w_i 和 b_i ,且在训练过程中保持不变,则可唯一确定隐含层输出矩阵 H 。此时,ELM 的训练过程等价于求解式(2)的最小二乘解,考虑到矩阵 H 可能为奇异矩阵,输出层权值可表示为:

$$\beta = H^+ Y \quad (4)$$

其中,矩阵 H^+ 表示矩阵 H 的 Moore-Penrose 广义逆。

在暂态稳定评估中,样本通常为单维输出($m=1$)。因此,在后文的研究过程中将以单维输出为例进行推导,但所得结论同样适用于多维输出的情况。

2.2 ELM 的优化模型

黄广斌等^[13]以最小训练误差和最小输出权值的模为目标函数,从优化的角度建立了 ELM 的数学模型。

$$\min f = \frac{1}{2} \|\beta\|^2 + \frac{M}{2} \sum_{i=1}^N \varepsilon_i^2 \quad (5)$$

$$\text{s.t. } h(x_i)\beta = y_i - \varepsilon_i \quad i=1, 2, \dots, N$$

其中, ε_i 表示第 i 个样本的误差; M 表示用以权衡最小误差和最小输出权值模的正则系数。

2.3 CELM 的优化模型

ELM 建立在类间误分类代价相等的假设上,并以误分率最小作为目标函数。而由前面的分析可知,暂态稳定分类时,不同类的误分类代价存在明显的差异性,若忽略此种差异性,则可能会造成评估结果失去实际意义。因此,在 ELM 优化模型的基础上计及误分类代价的影响,以误分类代价最小为目标函数,从而构造更适合暂态稳定评估的分类器。

CELM 的优化模型如下:

$$\min f = \frac{1}{2} \|\beta\|^2 + \frac{M}{2} \sum_{i=1}^N c_{ii} \varepsilon_i^2 \quad (6)$$

$$\text{s.t. } h(x_i)\beta = y_i - \varepsilon_i \quad i=1, 2, \dots, N$$

对上述优化模型引入拉格朗日乘子矢量 α , 得到拉格朗日函数:

$$L = \frac{1}{2} \|\beta\|^2 + \frac{M}{2} \sum_{i=1}^N c_{ii} \varepsilon_i^2 - \sum_{i=1}^N \alpha_i (\mathbf{h}(\mathbf{x}_i) \beta - y_i + \varepsilon_i) \quad (7)$$

其中, α_i 表示对应第 i 个样本的拉格朗日乘子。

式(7)的 KKT 一阶最优条件如下:

$$\frac{\partial L}{\partial \beta} = 0 \rightarrow \beta = H^T \alpha \quad (8)$$

$$\frac{\partial L}{\partial \varepsilon_i} = 0 \rightarrow \alpha_i = M c_{ii} \varepsilon_i \quad i = 1, 2, \dots, N \quad (9)$$

$$\frac{\partial L}{\partial \alpha_i} = 0 \rightarrow \mathbf{h}(\mathbf{x}_i) \beta - y_i + \varepsilon_i = 0 \quad i = 1, 2, \dots, N \quad (10)$$

联立上述三式可得:

$$\beta = \left(\frac{I}{M} + H^T C H \right)^{-1} H^T C Y \quad (11)$$

其中, I 表示 L 阶单位矩阵。

由式(11)可知, 在 CELM 的训练过程中, 权值向量 β 仍然无需迭代过程便可计算得到, 因此 CELM 同样具有很快的训练速度。

3 暂态稳定评估指标与算法

3.1 输入特征集的选取

输入特征集的选取是影响分类效果的重要因素。随着 PMU 技术在电力系统中的广泛应用, 调度中心涌入大量反映系统动态响应特性的信息, 充分利用这些实测轨迹信息能显著提高暂态稳定的分类性能。本文综合现有文献^[14], 并通过大量仿真, 分别利用故障前、故障发生瞬时 t_0 、故障切除时刻 t_{cl} 、故障切除后 3 个周期 t_{cl+3c} 、故障切除后 6 个周期 t_{cl+6c} 这 5 个时刻的轨迹量测值, 提出能刻画系统受扰特征的特征“维数灾”问题。特征的具体描述如表 2 所示。

3.2 暂态稳定分类性能测度指标

电力系统暂态稳定评估中存在明显的稳定样本多、不稳定样本少的特点。若采用传统的准确率指标作为评价暂态稳定分类性能的测度指标, 则可能会出现“大数吃小数”的现象, 使分类器对不稳定样本的分类性能被遮蔽, 而在实际运行中, 调度人员往往对不稳定样本的分类性能更感兴趣。因此, 应用传统准确率指标评估暂态稳定分类性能存在明显不足。

本文在重点关注不稳定样本分类性能的前提下, 引入全局准确率指标、漏报率指标、误报率指标和不稳定样本分类性能的综合测度指标(以下简称综合测度指标)^[15-16]来量化暂态稳定的分类效果, 4 种指标的具体描述如下。

a. 全局准确率指标是指测试集中稳定样本准确率与不稳定样本准确率的几何均值, 即:

表 2 输入特征集

Table 2 Input feature set

序号	特征描述
1	系统所有发电机机械功率的平均值
2	t_0 时刻发电机加速功率的平均值
3	t_0 时刻发电机加速度的最大值
4	t_{cl} 时刻系统总的能量调整
5	t_{cl} 时刻领前机和殿后机转角之差
6	t_{cl} 时刻发电机间角速度差的最大值
7	t_{cl} 时刻发电机间加速度差的最大值
8	t_{cl} 时刻发电机相对于惯性中心角度的最大值
9	t_{cl} 时刻最大相对转子角的发电机的动能
10	t_{cl+3c} 时刻领前机和殿后机转角之差
11	t_{cl+3c} 时刻发电机间角速度差的最大值
12	t_{cl+3c} 时刻发电机间加速度差的最大值
13	t_{cl+3c} 时刻发电机相对于惯性中心角度的最大值
14	t_{cl+3c} 时刻最大相对转子角的发电机的动能
15	t_{cl+3c} 时刻和 t_{cl} 时刻角度变化率绝对值的最大值
16	t_{cl+6c} 时刻领前机和殿后机转角之差
17	t_{cl+6c} 时刻发电机间角速度差的最大值
18	t_{cl+6c} 时刻发电机间加速度差的最大值
19	t_{cl+6c} 时刻发电机相对于惯性中心角度的最大值
20	t_{cl+6c} 时刻最大相对转子角的发电机的动能
21	t_{cl+6c} 时刻和 t_{cl+3c} 时刻角度变化率绝对值的最大值

$$G = \sqrt{A_s A_u} \quad (12)$$

其中, G 表示全局准确率; A_s 表示测试集中稳定样本的分类准确率; A_u 表示不稳定样本的分类准确率。可以看到, 全局准确率与稳定样本和不稳定样本的绝对数量无关, 只有当稳定样本和不稳定样本的分类准确率都比较高时, 全局准确率指标才会很大。

b. 漏报率指标是指测试集中被误分的不稳定样本数与不稳定样本总数的比值。

c. 误报率指标是指测试集中被误分的稳定样本与稳定样本总数的比值。

d. 综合测度指标是指测试集中不稳定样本查全率和查准率的加权调和均值, 即:

$$F = \frac{(1+\theta)RP}{R+\theta P} \quad (13)$$

其中, F 表示综合测度指标; R 表示测试集中不稳定样本的查全率, 定义为测试集中正确分类为不稳定样本的样本数与不稳定样本总数的比值; P 表示测试集中不稳定样本的查准率, 定义为测试集中正确分类为不稳定样本的样本数与被分类为不稳定样本的总数的比值; θ 表示度量查全率与查准率重要程度的权值, 一个高的综合测度指标可以确保查全率和查准率都较高^[16], 为了能充分体现不稳定样本查全率的重要性, 又不会造成对查准率的过度遮蔽, 本文中权值 θ 取 3。

3.3 暂态稳定评估的算法流程

基于本文所提的 CELM 进行暂态稳定评估时, 具体的算法流程如下:

a. 随机设置系统的初始运行状态和故障条件,

利用时域仿真得到的受扰轨迹模拟系统中 PMU 的实测轨迹;

b. 基于仿真获得的系统受扰轨迹,通过简单计算得到系统在不同时刻的动态特征,并将其与系统受扰后的稳定状态共同构成所要研究的样本;

c. 待样本集收集完毕,对所得样本集进行数据预处理,并将预处理后的样本集按一定比例随机分为训练集和测试集;

d. 给定误分类代价矩阵,首先通过交叉验证和网格搜索确定 CELM 的隐含层节点数和正则系数,然后利用训练集训练 CELM,得到输出层的权值向量;

e. 利用训练完毕的 CELM 对测试集进行分类测试,得到对应给定误分类代价矩阵的评估结果;

f. 保持训练集和测试集不变,改变误分类代价矩阵中不稳定样本误分类代价 λ_{FU} 的值,重复步骤 d、e,得到不同的误分类代价矩阵对暂态稳定评估性能的影响。

4 算例分析

4.1 新英格兰 39 节点系统

4.1.1 样本生成

新英格兰 39 节点系统包含 10 台发电机,39 条母线和 46 条线路^[14]。发电机采用经典模型,负荷采用恒阻抗模型,负荷水平在基准负荷的 80%~120% 范围内随机生成,并相应改变发电机出力,随机设置故障元件和故障位置,故障类型为永久性三相短路,故障发生时间为 0.1 s,近端故障切除时间为 0.2 s,远端故障切除时间为 0.22 s。仿真时长为 3 s,步长为 0.01 s,以 3 s 末任意 2 台发电机的功角差是否超过 360° 来判定系统是否失稳。

仿真软件采用 PST3.0^[17],共生成 1200 个样本,对所得样本进行归一化处理后,随机选择 800 个训练样本,另外 400 个为测试样本,测试集中包含 308 个稳定样本和 92 个不稳定样本。

4.1.2 参数确定

在训练过程中,通过调整 λ_{FU} 值的大小来改变误分类代价矩阵,进而影响 CELM 的分类性能。CELM 的核函数采用 Sigmoid 函数,不稳定样本误分类代价 λ_{FU} 在 [1, 2, ..., 12] 范围内逐一取值, λ_{FU} 值确定后,利用 5 折交叉验证和网格搜索的方法找出最佳正则化参数 M 以及隐含层节点数 L ,其中 M 和 L 的取值范围分别为 $[2^{-4}, 2^{-2}, \dots, 2^{16}]$ 和 $[50, 100, \dots, 500]$ 。

4.1.3 结果与讨论

对应于不同的误分类代价矩阵,当 CELM 训练完成后,对测试集进行分类测试,进而得到不稳定样本的漏报率、稳定样本的误报率与误分类代价 λ_{FU} 的关系如图 1 所示。

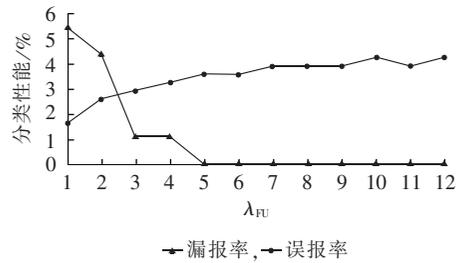


图 1 漏报率、误报率与误分类代价 λ_{FU} 的关系

Fig.1 Relationship among false dismissal rate, false alarm rate and misclassification cost λ_{FU}

由图 1 可见:当 $\lambda_{FU}=1$,即采用现有的 ELM 进行暂态稳定评估时,漏报率达到了 5.43%,尽管误报率很低,但评估结果面临巨大的风险,无法满足实际需求。随着误分类代价 λ_{FU} 的增大,漏报率减少,而误报率相应增加。当 λ_{FU} 取值为 5 时,所有的不稳定样本均被正确分类,漏报率为 0。误分类代价 λ_{FU} 继续增大,漏报数保持不变。上述结果表明,随着误分类代价 λ_{FU} 的增大,分类结果更倾向于将测试样本归类为不稳定,以减小总的误分类代价,从而使之前被误分类为稳定样本的不稳定样本得以正确划分。值得注意的是,当 $\lambda_{FU}=5$ 时,漏报率降为 0,此时的误报率为 3.57%,即稳定样本的分类准确率达到了 96.43%,证明了所提方法的优良性能。

为了验证 CELM 相较于传统模式识别方法在暂态稳定评估中的优越性,本文采用 SVM、DT 和 ELM 对数据集进行测试,并与 CELM ($\lambda_{FU}=5$) 的测试结果进行对比。其中,SVM 的核函数采用径向基函数,利用 5 折交叉验证和网格搜索得到最优的模型参数,惩罚因子 C 和核函数参数 γ 的取值范围分别为 $[2^{-4}, 2^{12}]$ 和 $[2^{-8}, 2^8]$;DT 采用 CART 算法;由于当 $\lambda_{FU}=1$ 时,CELM 便退化为 ELM,相应的测试结果可作为 ELM 的测试结果,仿真结果如表 3 所示。

表 3 新英格兰 39 节点系统测试结果
Table 3 Test results of New England 39-bus system

方法	全局准确率/%	漏报率/%	误报率/%	综合测度指标/%
SVM	96.7	4.35	2.24	94.9
DT	95.7	6.52	2.03	93.5
ELM	96.4	5.43	1.73	94.6
CELM	98.2	0	3.57	97.1

由表 3 可知:在进行对比的 4 种方法中,SVM、DT 以及 ELM 的漏报率均较高,从而使得暂态稳定评估的结果失去实际意义。CELM 不仅能使漏报率为 0,稳定样本的误报率也很低,并且其在全局准确率以及综合测度指标方面明显优于其他 3 种方法。

4.2 IEEE 145 节点系统

4.2.1 样本生成与参数确定

IEEE 145 节点系统包含 50 台发电机、145 条母

线和 453 条线路^[14]。发电机 1—6 和发电机 23 采用 6 阶模型,其余发电机为经典模型,负荷为恒阻抗模型。负荷水平在基准负荷的 95%~120% 范围内随机生成,并相应改变发电机出力,随机设置故障元件和故障位置,故障类型为永久性三相短路,故障发生时间为 0.1 s,近端故障切除时间为 0.2 s,远端故障切除时间为 0.22 s。仿真时长为 3 s,步长为 0.01 s,失稳判断条件和仿真软件与新英格兰 39 节点系统相同。仿真生成 6 000 个样本,归一化处理后,随机选择 4 000 个为训练样本,另外 2 000 个为测试样本。测试集中包含 1 578 个稳定样本和 422 个不稳定样本。

参数确定过程及参数取值范围与新英格兰 39 节点系统相同。

4.2.2 结果与讨论

不稳定样本的漏报率、稳定样本的误报率与误分类代价 λ_{FU} 的关系如图 2 所示。

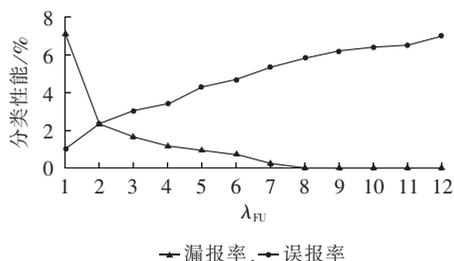


图 2 漏报率、误报率与误分类代价 λ_{FU} 的关系

Fig.2 Relationship among false dismissal rate, false alarm rate and misclassification cost λ_{FU}

由图 2 可见:当 $\lambda_{FU}=1$,即采用 ELM 进行暂态稳定评估时,漏报率高达 7.11%。随着误分类代价 λ_{FU} 值的增大,漏报率不断减少,当 λ_{FU} 取值为 8 时,漏报率减少到 0,此时误报率为 5.83%,表明此时稳定样本仍然具有较高的分类准确率,达到了 94.17%。这说明即使是对于规模较大的系统,CELM 也能使漏报率降为 0,并且其稳定样本的分类准确性仍维持在较高的水平。

同样地,将 CELM($\lambda_{FU}=8$)的测试结果与 SVM、DT 以及 ELM 的测试结果进行对比,结果如表 4 所示。

表 4 IEEE 145 节点系统测试结果

Table 4 Test results of IEEE 145-bus system

方法	全局准确率/%	漏报率/%	误报率/%	综合测度指标/%
SVM	94.5	9.24	2.24	91.5
DT	95.5	6.65	2.03	93.0
ELM	95.9	7.11	1.73	93.7
CELM	97.0	0	5.83	94.8

由表 4 可知:对于规模较大的系统,传统模式识别方法的漏报率均较大。而 CELM 通过调整误分类代价的大小,不仅能使评估结果的漏报率降为 0,还可以让稳定样本的误报率维持在较低的水平。另外,CELM 能获得比其他 3 种方法更高的全局准确率以

及综合测度指标。

4.3 评估模型时间复杂度的比较

仿真采用 MATLAB 软件,计算机配置为:Intel core i3,3.3GHz CPU 和 4G RAM。在上述 2 个测试系统中,4 种评估模型的时间复杂度对比如表 5 所示。

表 5 评估模型时间复杂度对比

Table 5 Comparison of time complexity among assessment models

测试系统	评估模型	训练时间/s	测试时间/s
新英格兰 39 节点 系统	SVM	0.203	0.094
	DT	0.091	0.033
	ELM	0.030	$<10^{-3}$
IEEE 145 节点系统	CELM	0.032	$<10^{-3}$
	SVM	1.194	0.187
	DT	0.472	0.078
	ELM	0.232	0.021
	CELM	0.248	0.026

由对比结果可知,CELM 和 ELM 的时间复杂度基本相同,且明显低于其余 2 种方法,因此,CELM 非常适合暂态稳定的在线分析。另外,由于 CELM 的训练时间很短,在应用 CELM 进行暂态稳定评估时,一旦系统的运行方式发生较大变化,可通过收集新的样本对 CELM 模型的参数进行实时刷新,动态跟踪系统运行状态的变化,从而增强评估模型的自适应能力。

5 结论

a. 随着误分类代价 λ_{FU} 的增大,不稳定样本的漏报率不断减少,直至为 0,满足暂态稳定评估的可靠性要求。

b. 通过与传统模式识别方法(SVM、DT 和 ELM)进行对比,CELM 能在保证暂态稳定评估的漏报率为 0 的前提下维持较低的误报率,而且其评估结果的全局准确率和综合测度指标方面优于传统的 3 种方法,因此在工程应用方面 CELM 更具优势。

c. CELM 的时间复杂度很低,不仅能满足暂态稳定的在线评估要求,还有利于动态跟踪系统运行状态的变化,提高评估模型的自适应能力。

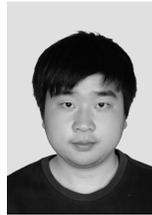
对于不同规模的电力系统,其稳定样本和不稳定样本的空间分布复杂程度不同。因此针对不同的系统,如何优化地选择误分类代价 λ_{FU} 的值,使评估结果在保证漏报率为 0 的前提下,尽可能地降低误报率是下一步需要研究的问题。

参考文献:

- [1] 白雪峰,倪以信. 电力系统动态分析综述[J]. 电网技术,2004,28(16):14-20.
BAI Xuefeng, NI Yixin. Survey on dynamic security assessment of power system[J]. Power System Technology, 2004, 28(16): 14-20.

- [2] 张保会,杨松浩,王怀远. 电力系统暂态稳定性闭环控制(一)——简单电力系统暂态不稳定判别原理[J]. 电力自动化设备, 2014,34(8):1-6.
ZHANG Baohui, YANG Songhao, WANG Huaiyuan. Closed-loop control of power system transient stability(1):transient instability detection principle of simple power system [J]. Electric Power Automation Equipment, 2014, 34(8):1-6.
- [3] 倪以信,陈寿孙,张宝霖. 动态电力系统的理论与分析[M]. 北京:清华大学出版社,2002:181-215.
- [4] TANG C K, GRAHAM C E, EI-KADY M. Transient stability index from conventional time domain simulation [J]. IEEE Transactions on Power Systems, 1994, 9(3):1524-1530.
- [5] 傅书邈,倪以信,薛禹胜. 直接法稳定分析[M]. 北京:中国电力出版社,1991:25-35.
- [6] 万秋兰,单渊达. 对应用直接法分析电力系统稳定性的再认识[J]. 电力系统自动化,1998,22(9):13-15.
WAN Qiulan, SHAN Yuanda. Re-understanding of the direct methods for power system transient stability analysis [J]. Automation of Electric Power Systems, 1998, 22(9):13-15.
- [7] 姚德全,贾宏杰,赵帅. 基于复合神经网络的电力系统暂态稳定评估和裕度预测[J]. 电力系统自动化,2013,37(20):41-46.
YAO Dequan, JIA Hongjie, ZHAO Shuai. Power system transient stability assessment and stability margin prediction based on compound neural network [J]. Automation of Electric Power Systems, 2013, 37(20):41-46.
- [8] 段青,赵建国,马艳. 基于稀疏贝叶斯学习的电力系统暂态稳定评估[J]. 电力自动化设备,2009,29(9):36-40.
DUAN Qing, ZHAO Jianguo, MA Yan. Power systems transient stability assessment based on sparse Bayesian learning [J]. Electric Power Automation Equipment, 2009, 29(9):36-40.
- [9] KANWA I, SAMANTARAY S R, JOOS G. Catastrophe prediction from ensemble decision tree learning of wide-area severity indices[J]. IEEE Transactions on Smart Grid, 2010, 1(2):144-158.
- [10] AI-MASRI A N, AB-KADIR M Z A, HIZAM H, et al. A novel implementation for generator rotor angle stability prediction using an adaptive artificial neural network application for dynamic security assessment [J]. IEEE Transactions on Power Systems, 2013, 28(3):2516-2525.
- [11] XU Y, DONG Z Y, MENG K, et al. Real-time transient stability assessment model using extreme learning machine [J]. IET Generation, Transmission & Distribution, 2011, 5(3):314-322.
- [12] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and application [J]. Neurocomputing, 2006, 70:489-501.
- [13] HUANG G B, ZHOU H M, DING X J. Extreme learning machine for regression and multiclass classification [J]. IEEE Transactions on System, Man, and Cybernetics-Part B: Cybernetics, 2012, 42(2):513-529.
- [14] 李扬,顾雪平. 基于改进最大相关最小冗余判据的暂态稳定评估特征选择[J]. 中国电机工程学报, 2013, 33(34):179-186.
LI Yang, GU Xueping. Feature selection for transient stability assessment based on improved maximal relevance and minimal redundancy criterion [J]. Proceedings of the CSEE, 2013, 33(34):179-186.
- [15] HE H, GARCIA E A. Learning from imbalanced data [J]. IEEE Transactions on Knowledge and Data Engineering, 2009, 21(9):1263-1284.
- [16] TAN P, STEINBACH M, KUMAR V. 数据挖掘导论[M]. 范明, 范宏建, 译. 北京:人民邮电出版社, 2006:180-182.
- [17] 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.

作者简介:



陈振

陈振(1991—),男,四川德阳人,博士研究生,研究方向为电力系统稳定与控制(E-mail:chenzhen5840@qq.com);

肖先勇(1968—),男,四川宜宾人,教授,博士研究生导师,博士,长期从事电能质量、智能电网研究(E-mail:xiaoxianyong@163.com);

李长松(1973—),男,四川德阳人,讲师,博士,长期从事电网安全防护与电能质量研究(E-mail:lcs21c@163.com)。

Power system transient stability assessment based on cost-sensitive extreme learning machine

CHEN Zhen, XIAO Xianyong, LI Changsong, ZHANG Yin, HU Qingquan

(School of Electrical Engineering and Information, Sichuan University, Chengdu 610065, China)

Abstract: Since the misclassification cost of stability sample is different from that of instability sample in the transient stability assessment, a method of transient stability assessment based on the cost-sensitive extreme learning machine is proposed, which introduces the concept of misclassification cost and takes the minimum misclassification cost as its objective to construct the cost-sensitive extreme learning machine, avoiding the demerit of existing extreme learning machine with higher classification accuracy and ignored false dismissal rate in the transient stability assessment. The simulative results of New England 39-bus system and IEEE 145-bus system show that, the proposed method inclines to classify the samples into instability case with higher misclassification cost to reduce the overall misclassification cost. By adjusting the misclassification cost matrix, the false dismissal rate can be decreased to zero and the false dismissal rate of stability samples kept at lower level, ensuring the reliability of assessment results.

Key words: electric power systems; transient stability; assessment; extreme learning machine; misclassification cost; false dismissal rate; stability