

大型风电机组电动变桨系统变桨角度故障诊断

高 峰, 邓星星, 刘 强, 杨锡运, 吴小江

(华北电力大学控制与计算机工程学院, 北京 102206)

摘 要: 为提高大型风电机组电动变桨系统变桨角度故障的判别准确性, 结合模糊粗糙集特征量约简和基于粒子群算法优化的支持向量机进行变桨角度故障诊断分析研究。首先基于模糊粗糙集理论建立变桨系统特征参数约简的数学模型, 通过对变桨相关运行数据进行约简, 确定对故障诊断贡献率较高的参数; 再利用实际运行数据训练经粒子群优化的支持向量机, 从而获得高精度诊断模型; 然后设计基于双层支持向量机的故障程度判别模型, 可对故障进行进一步分类。最后通过实际运行数据对变桨角度故障进行诊断实验, 实验结果表明, 该诊断方法能准确地快速地判别故障并可进行故障程度分类。

关键词: 风电机组; 故障分析; 模糊集合论; 电动变桨系统; 支持向量机

中图分类号: TM614

文献标志码: A

0 引 言

近年来, 越来越多的风电机组选择电动变桨系统, 电动变桨系统采用伺服电机配合减速器对叶片进行变桨控制, 具有调速稳定、易控制、便于气动刹车等优点, 但其控制系统相对复杂而且需要备用电源。这样, 外界风况的复杂多变加上内部复杂的结构, 使其成为风电机组结构中故障频发的部分。而且一旦发生故障, 很有可能导致输出功率异常、叶片损坏, 甚至机组倒塌等严重事故。另外, 电动变桨系统监控参数众多, 且各参数与运行状态之间关系复杂, 使得机组维护人员很难准确掌握实际运行情况。而变桨系统的常规故障报警参数单一, 报警阈值一般也统一设置, 缺乏合理性, 往往造成误报或报警不及时。因此, 对于电动变桨系统故障特征参数的甄别选取和故障判别方法的有效设计至关重要。

因此, 为了进一步提高电动变桨系统故障诊断的准确性以及能够对故障程度进行分类, 本文利用模糊粗糙集建立的特征量约简模型对实际机组变桨相关参数进行有效约简, 得到对于故障诊断贡献率较高的参数, 然后利用基于粒子群算法优化的支持向量机进行数据训练, 得到判别精度较高的故障诊断模型, 进一步运用双

层支持向量机对故障程度进行分类, 最后应用实际机组运行数据进行实例验证。

1 电动变桨系统工作原理及相关参数

1.1 电动变桨系统工作原理

图 1 为典型风电机组电动变桨系统工作原理图。该系统由位置环、转速环、电流环组成三闭环控制系统, 主控系统给定桨距角设定值 β^* 与测得实际变桨角度 β 相比较完成位置调节, 测速机得到实际驱动电机转速度 n , 由转速调节器完成转速调节。电流调节器完成电流调节, 最终得到驱动电机的电枢电压指令, 驱动电机通过减速器完成变桨动作, 使变桨角度稳定在桨距角设定值。电动变桨系统驱动电机由外部电源供电, 驱动变桨机构运行; 而当外部电源故障时, 备用电池马上投入运行, 确保机组叶片快速、安全地完成顺桨指令^[1-2]。

1.2 电动变桨系统相关参数

为了使风电机组变桨系统更加安全、稳定地运行, 实际风电机组变桨系统会采用较多的监测参数, 如三叶片变桨角度、主控制器给出的变桨角度设定值、三叶片变桨速率、备用电池电压、驱动电机温度

收稿日期: 2017-10-24

基金项目: 国家自然科学基金(51677067); 中央高校基本科研业务费(2015MS24)

通信作者: 高峰(1976—), 男, 博士、讲师, 主要从事风力发电机组性能评估与控制优化方面的研究。gaofeng@ncepu.edu.cn

等。为了更好地识别变桨系统的运行状态,还需考虑外界实时风速、发电机转速、有功功率等参数。可见在实际风电机组中与变桨运行相关的参数众多,不利

于故障的判别与诊断,因此有必要将与变桨相关的参数进行统计分类,并进一步找出其中关联性强的参数去进行故障诊断。

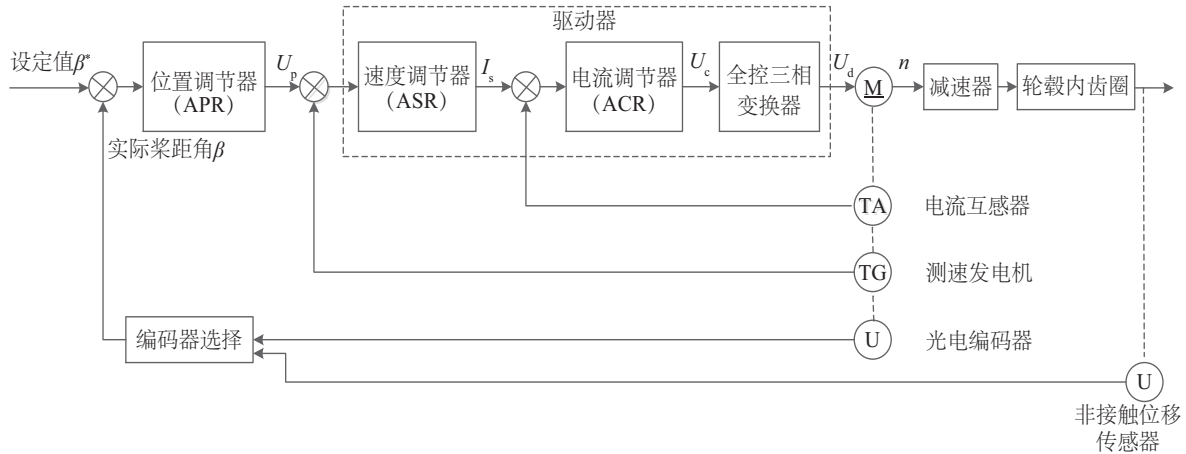


图1 电动变桨系统工作原理图

Fig. 1 Working principle of electric pitch system

1.3 电动变桨系统故障诊断研究现状

近年来,国内外学者针对电动变桨系统故障诊断问题进行了一系列研究。文献[3]提出一种采用基于先验知识的自适应神经模糊推理系统(ANFIS)的变桨故障诊断方法,建立风速、转速、功率、变桨电机扭矩等参数间的关系模型,通过先验知识的融合提高了诊断的有效性;文献[4-5]提出基于变遗忘因子结合最小二乘算法以及间隔预测的模型预测故障诊断方法;文献[6-7]基于相似性原理,利用非线性状态评估方法,建立变桨系统正常运行的健康模型。当变桨系统发生故障时,模型预测值与正常状态会出现偏差,根据特征参数对偏差的影响来确定故障的原因。文献[8]建立变桨系统物理模型,并将模型输出与实际系统输出进行比较产生残差,随后采用残差范数的均值作为故障判别函数进行故障检测;文献[9]应用Fisher分析法求解出故障数据的偏离方向以及各变量对该方向的贡献率,生成Fisher判别分析(FDA)贡献图,以最大贡献率对应的变量确定引起故障的主要因素,辨识出故障源,进而实现故障定位;文献[10]应用最小二乘支持向量机建立用于故障诊断的变桨系统回归多输入多输出模型,然后采用高斯混合模型拟合多维观测值(系统特征向量实测值与模型计算结果偏离)的分布,通过计算系统劣化指数实现变桨系统状态的在线辨识与诊断。文献[11]提出基于模糊推理系统和故障树方法结合的变桨系统故障诊断方法,根据运维人员和专家的经

验建立较高精度的判别模型。上述文献主要通过建立模型获得预测值,根据预测值与实际值的差值去判断故障信息,也属于阈值报警,而且大多未给出具体的报警阈值和讨论阈值的确定方法,实际应用中往往导致其在不同风场或对不同机组在线监测与诊断时偏差较大。

另外,实际数据采集与监视控制(SCADA)系统数据中本身就包含一定的变桨系统故障信息,但由于其运行参数众多且各参数之间关系复杂,所以需要对这些参数进行处理,然后再进行故障判别。针对上述问题文献[12]提出基于Relief方法的变桨特征参数选取方案以及基于多特征参量距离的变桨系统运行状态异常识别方法,并对其基于支持向量机(support vector machine, SVM)方法的特征参量回归模型和距离阈值进行了分析,该文献变桨系统故障诊断方案较为完善,并且讨论了阈值的确定,但其阈值计算仍需根据具体机组数据进行训练和设定,并且无法根据阈值对故障程度进行分类。

本文针对上述故障判别方案存在的问题,建立基于粒子群优化的支持向量机故障判别模型,以某些实际机组变桨相关参数的差值作为模型输入,对模型输入的预处理与模型参数的优化可提高判别准确度;并且通过建立双层支持向量机模型进行故障程度的分类,对于轻微的、短时的故障以及严重的、长时的故障进行精确的分类,能够给运维人员提供更多的故障信息,减少了工作量。

2 电动变桨系统故障特征参数的约简

2.1 基于模糊粗糙集的特征量约简

给定的决策系统 $S = \langle U, C \cup D, V, f \rangle$, 其中, U —— 对象集合, $U = \{u_1, u_2, \dots, u_n\}$; C —— 实例包含的条件属性集合, 即与所研究事件有关的特征集, 每个实例有 m 个属性, 每个特征属性可取值的集合为 $V = \{V_1, V_2, \dots, V_n\}$; D —— 决策属性, $D = \{d_1, d_2, \dots, d_n\}$, 即条件属性所决定的判别结果; f —— 信息函数, 该函数为某个数据的某个属性赋予一个特定的值^[13]。

任意 2 个实例 u_i 和 u_j 的相似度用直接距离法定义为:

$$S_B(u_i, u_j) = 1 - \sqrt{\frac{1}{k} \sum_{m=1}^k (u_{im} - u_{jm})^2} \quad (1)$$

式中, k —— 该实例包含的条件属性总数。则 $R_B = S_B(u_i, u_j)$, $i, j = 1, 2, 3, \dots, n$ 可表示为一个模糊相似矩阵。 R_B 中元素同时满足:

$$\begin{cases} r_{ij} = 1, i = j \\ r_{ij} = r_{ji}, i \neq j, i, j = 1, 2, \dots, n \end{cases} \quad (2)$$

可根据具体研究的问题, 设定 $\lambda \in [0, 1]$, 如果 $r_{ij} \geq \lambda$, 则实例 u_i 与 u_j 相似, 否则不相似。则 R_B 转换为:

$$R_B = \begin{cases} r_{ij} = 1, r_{ij} \geq \lambda \\ r_{ij} = 0, r_{ij} < \lambda \end{cases} \quad (3)$$

决策属性 D 对条件属性 C 的依赖度定义为:

$$\gamma_c(D) = \frac{|POS_c(D)|}{|U|} \quad (4)$$

式中 $POS_c(D)$ —— 根据 C 的知识所进行 U/C 类的划

分, 能够确切地划入根据决策属性划分的 U/D 类的对象集合。根据求出的依赖度, 可求出其他条件属性关于 D 的依赖度:

$$\gamma_a(D) = \gamma_c(D) - \gamma_c^*(D) \quad (5)$$

式中, $\gamma_c^*(D)$ —— C 中缺少条件属性 C_i 后, D 对于它的依赖度。当 $\gamma_c(D) = 0$ 时, 则属性 C_i 可从属性集中约简。得到约简后的决策表矩阵, 其列向量值均为 0 的条件属性即为约简属性^[14]。

2.2 基于模糊粗糙集的变桨参数约简与处理

如表 1 所示, 本文初选了 26 个与变桨系统相关的运行参数, 其中各个叶片桨距角的实际值最直接反映了变桨系统工作状态, 而两两叶片实际值差值又直接反映了变桨系统 3 个叶片的一致性及整个风轮气动平衡程度, 因此是监控系统监测的重要参数, 当两两偏差过大时机组安全系统一般会直接报警, 但由于实际机组运行环境和气动特性的差异, 采用单一报警阈值往往会导致误报或迟报, 也无法给出具体故障原因, 实际运行效果不理想。由控制理论可知, 各叶片设定值与实际值之间应由如图 1 控制环决定, 受风力发电系统的气动非线性以及执行机构的传动间隙等因素影响, 将二者之间的关系简化为一阶惯性加纯延时环节(式(6))或高阶线性环节(式(7)), 均不能精确描述其动态特性, 因此运用这种简化模型也无法进行精确的故障诊断。

$$\beta_1(s) = \frac{1}{1 + Ts} e^{-\tau s} \quad (6)$$

$$\beta_2(s) = \frac{s^m + b_{m-1}s^{m-1} + \dots + b_1s + b_0}{s^n + a_{n-1}s^{n-1} + \dots + a_1s + a_0}, \quad n > m \quad (7)$$

为使各个桨叶设定值与实际值能更直接反映故障状态且易于判别模型的训练和故障判别, 本文需对这

表 1 用于故障判别的初选参数

Table 1 Used for primary selection of fault diagnosis parameters

序号	初选参数	序号	初选参数	序号	初选参数
1	叶片 1 实际值与设定值差值	10	叶片 3 变桨速率	19	叶片 3 备用电池电压
2	叶片 2 实际值与设定值差值	11	叶片 1 变频器箱温度	20	发电机转子转速
3	叶片 3 实际值与设定值差值	12	叶片 2 变频器箱温度	21	变桨电机电流 1
4	叶片 1 与叶片 2 实际值差值	13	叶片 3 变频器箱温度	22	变桨电机电流 2
5	叶片 1 与叶片 3 实际值差值	14	叶片 1 驱动电机温度	23	变桨电机电流 3
6	叶片 2 与叶片 3 实际值差值	15	叶片 2 驱动电机温度	24	叶片 1 电池箱温度
7	外界风速	16	叶片 3 驱动电机温度	25	叶片 2 电池箱温度
8	叶片 1 变桨速率	17	叶片 1 备用电池电压	26	叶片 3 电池箱温度
9	叶片 2 变桨速率	18	叶片 2 备用电池电压	—	—

些数据进行简单处理,即用两两叶片实际值差值以及各叶片实际值与设定值的差值代替各个叶片桨距角的设定值与实际值,具体参数见表1。

1)对这些条件属性根据模糊隶属度范围转换成离散量。叶片变桨角度实际值与设定值之差定义为正常值0和故障值1,设为 $u_1\sim u_3$;同理,叶片变桨角度两两差值也分为正常值0和故障值1,设为 $u_4\sim u_6$;由于机组功率调节在低于额定风速时不进行变桨以及介于额定风速和切出风速之间时进行变桨控制,因此低于额定风速为0,高于额定风速且低于切出风速为1,设为 u_7 ;叶片变桨速率根据数值正负分别定义非正为0和正为1,设为 $u_8\sim u_{10}$;变频器箱温度正常值为0,故障值为1,设为 $u_{11}\sim u_{13}$;驱动电机温度正常值为0,故障值为1,设为 $u_{14}\sim u_{16}$;备用电池电压正常值为0,故障值为1,设为

$u_{17}\sim u_{19}$;发电机转子转速低于额定转速为0,高于它为1,设为 u_{20} ;变桨电机电流正常值为0,故障值为1,设为 $u_{21}\sim u_{23}$;电池箱温度正常值为0,故障值为1,设为 $u_{24}\sim u_{26}$;因此初选参数定义为 $u_1\sim u_{26}$ 。 D 为决策属性。表2为变桨系统故障诊断决策表。

2)根据模糊粗糙集属性约简理论模型对上述变桨系统相关参数进行分析。表2为从运行数据中提取的变桨系统故障诊断决策表,约简后的决策表矩阵为表3,包含条件属性26个、决策属性1个、故障实例188个,变桨角度故障类别根据故障特征分为3大类,即设定值与实际值偏差过大,此类故障多由传感器故障导致;叶片变桨角度两两相差过大,此类故障主要是由变桨执行机构机械故障或叶片本身故障导致;叶片卡顿故障,这类故障大多由电机故障、备用电池故障和异物卡涩导致。

表2 变桨系统故障诊断决策表
Table 2 Fault diagnosis decision table of pitch system

u_1	u_2	u_3	u_4	u_5	u_6	u_7	u_8	u_9	...	u_{18}	u_{19}	u_{20}	u_{21}	u_{22}	u_{23}	u_{24}	u_{25}	u_{26}	D
1	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	1
1	0	0	0	0	0	1	0	0	...	0	0	0	0	0	1	1	1	1	1
1	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	1
1	0	0	0	0	0	1	0	0	...	0	0	0	0	0	1	1	1	1	1
0	1	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1	1	1	0	0	0	0	1	1	...	1	1	0	0	0	1	1	1	1	188
1	1	1	0	0	0	1	1	1	...	1	1	0	0	0	0	0	0	0	188
1	1	1	0	0	0	1	1	1	...	1	1	0	0	0	1	1	1	1	188
1	1	1	0	0	0	0	1	1	...	0	0	1	1	1	1	1	1	1	188

表3 约简后的变桨系统故障诊断决策表
Table 3 Decision table for fault diagnosis of pitch system after reduction

u_1	u_2	u_3	u_4	u_5	u_6	u_7	u_8	u_9	...	u_{17}	u_{18}	u_{19}	u_{20}	u_{21}	u_{22}	u_{23}	u_{24}	u_{25}	u_{26}
1	1	1	1	1	0	0	0	0	...	0	0	1	0	0	1	0	0	0	0
1	1	1	1	0	1	0	0	0	...	0	0	0	0	0	0	0	0	0	0
1	1	1	1	0	1	0	0	0	...	0	0	1	0	0	1	0	0	0	0
1	1	1	1	1	0	0	0	0	...	0	1	0	0	1	0	0	0	0	0
1	1	1	1	1	0	0	0	0	...	0	1	1	0	1	1	0	0	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1	1	1	1	0	1	0	0	0	...	1	1	1	0	1	1	0	0	0	0
1	1	1	0	1	1	0	0	0	...	1	0	0	0	0	0	0	0	0	0
1	1	1	0	1	1	0	0	0	...	1	0	1	0	0	1	0	0	0	0
1	1	1	0	1	1	0	0	0	...	1	1	0	0	1	0	0	0	0	0

根据故障所在的具体叶片分为 24 小类。根据约简理论可以分析得出外界风速 u_7 、三叶片变桨速率 $u_8 \sim u_{10}$ 、转子转速 u_{20} 这 3 个条件属性对变桨系统故障诊断贡献率较低,故可舍弃。

3 基于支持向量机的变桨角度故障诊断

由上述模糊粗糙集得出的变桨系统约简参数作为支持向量机模型的训练、验证数据。通过对故障数据和正常数据的训练,得到判别故障模型,为提高故障判别的准确性,利用粒子群优化算法对支持向量机核函数关键参数进行寻优。

3.1 支持向量机故障诊断模型

SVM 的机理是寻找到一个满足分类要求的最优分类超平面,使得该平面具有较高的精度,同时使平面两侧空白区域最大化,理论上,支持向量机能够得到对线性类型数据的最优分类^[15]。

本文以两类数据分类为例介绍 SVM 的工作原理。给定训练集样本:

$$(x_i, y_i), i = 1, 2, \dots, l, x \in \mathbf{R}^n, y \in \{\pm 1\} \quad (8)$$

超平面记做 $(\omega \cdot x) + b = 0$, 为了使分类超平面得到正确的分类结果并且具备较好的分类间隔,规定如下约束条件:

$$y_i[(\omega \cdot x_i) + b] \geq 1, i = 1, 2, \dots, l \quad (9)$$

得到分类间隔为 $2/\|\omega\|$, 因此构造最优超平面就相当于在约束条件下求:

$$\min \phi(\omega) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l \xi_i \quad (10)$$

式中, C ——惩罚因子, C 值越大表示对错分样本的约束就越强, ξ_i ——松弛变量, 用来测量样本分类误差的程度。

为解决约束最优化问题,引入 Lagrange 函数:

$$L(\omega, b, a) = \frac{1}{2} \|\omega\|^2 - a \{y[(\omega \cdot x) + b] - 1\} \quad (11)$$

式中, a ——Lagrange 乘数。Lagrange 函数的鞍点决定了最优化的解,并且在鞍点处最优解对 ω 和 b 的偏导均为 0。

$$\begin{aligned} \max Q(a) &= \sum_{j=1}^l a_j - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l a_i a_j y_i y_j (x_i \cdot x_j) \\ \sum_{j=1}^l a_j y_j &= 0, j = 1, 2, \dots, l, a \geq 0, j = 1, 2, \dots, l \end{aligned} \quad (12)$$

定义核函数为:

$$K(x_i, x_j) = \phi^T(x_i) \phi(x_j) \quad (13)$$

将式(10)代入式(9)可得:

$$\max Q(a) = \sum_{j=1}^l a_j - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l a_i a_j y_i y_j K(x_i \cdot x_j) \quad (14)$$

核函数是一种特定的非线性映射,将样本空间映射到高维特征空间,使其线性可分,常见的核函数类型有多项式函数、RBF 函数、Sigmoid 函数等。

对式(11)进行迭代求解,从而得到最优解为: $a^* = (a_1^*, a_2^*, \dots, a_l^*)^T$ 。

计算最优权值向量 ω^* 和最优偏置 b^* , 分别为:

$$\omega^* = \sum_{j=1}^l a_j^* y_j x_j \quad (15)$$

$$b^* = y_i - \sum_{j=1}^l y_j a_j^* (x_j \cdot x_i) \quad (16)$$

式中, 下标 $j \in \{j | a_j^* > 0\}$ 。因此得到最优分类超平面 $(\omega^* \cdot x) + b^* = 0$, 而最优分类函数为:

$$\begin{aligned} f(x) &= \text{sgn}[(\omega^* \cdot x) + b^*] \\ &= \text{sgn} \left\{ \left[\sum_{j=1}^l a_j^* y_j (x_j \cdot x_i) \right] + b^* \right\}, x \in \mathbf{R}^n \end{aligned} \quad (17)$$

针对于线性不可分的数据,支持向量机通过将其输入向量映射到一个高维度的特征向量空间,然后在该空间构造最优分类平面。将线性不可分样本集 x 做变换,以映射到特征空间:

$$x \rightarrow \phi(x) = [\phi_1(x), \phi_2(x), \dots, \phi_t(x)]^T \quad (18)$$

以特征向量 $\phi(x)$ 代替 x , 则可得到最优分类函数:

$$\begin{aligned} f(x) &= \text{sgn}(\omega \cdot \phi(x) + b) \\ &= \text{sgn} \left[\sum_{i=1}^l a_i y_i \phi(x_i) \cdot \phi(x) + b \right] \end{aligned} \quad (19)$$

由以上推导公式可见, SVM 只涉及到训练样本之间的内积运算,避免了高维度的复杂运算。

3.2 基于粒子群优化算法的 SVM 参数选择

从前面分析可知,训练一个支持向量机模型就是选择参数 C 和核函数固有参数,使式(11)得到最优解 a 和 b 。参数选择的问题归根结底就是最小化推广的估计值估算问题。由此得到 SVM 参数选择的最优化方法。

- 1) 为常数 C 和核函数参数赋初值;
- 2) 最大化式(11), 得到 a 和 b 的值;
- 3) 更新 SVM 的 2 个参数, 得出最小化推广能力的估计值;
- 4) 如果估计值满足要求, 则结束运算; 否则继续执行步骤 2)。具体步骤如图 2。

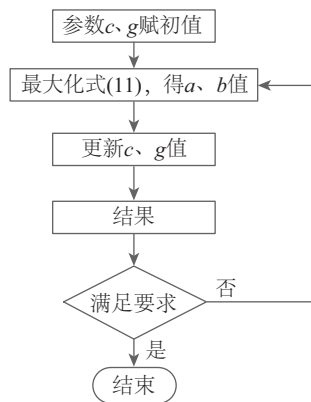


图2 SVM参数选择流程图

Fig. 2 Parameter selection flow chart

本文 SVM 核函数采用 RBF 核函数,该核函数关键参数为 g 值,应用粒子群优化算法进行参数的寻优,其算法基本流程如下:

- 1)初始化粒子群,包括群体规模 N 、每个粒子的位置 x_i 和速度 v_i ;
- 2)计算每个粒子的适应度 $Fit[i]$;
- 3)对每个粒子,用它的适应度 $Fit[i]$ 和个体极值 $P_{best}(i)$ 比较,如果 $Fit[i] > P_{best}(i)$,则用 $Fit[i]$ 替换

掉 $P_{best}(i)$;

4)对每个粒子,用它的适应度 $Fit[i]$ 和全局极值 $G_{best}(i)$ 比较,如果 $Fit[i] > G_{best}(i)$,则用 $Fit[i]$ 替换掉 $G_{best}(i)$;

5)更新粒子位置和速度值;

6)若满足结束条件,退出。否则返回步骤 2)^[16]。

4 算例分析

为验证本文所提方法的准确性,选择某 2 MW 风电机组故障运行相关数据作为初选数据,利用模糊粗糙集理论筛选出对于故障判别贡献率较高的运行数据作为模型的训练数据,建立基于 SVM 的变桨系统 3 类故障诊断模型。然后针对风电机组实际运行数据进行在线的实时监测识别,最后将普通 SVM 模型判别结果和基于离子群优化后的 SVM 模型判别结果进行对比分析。

表 4 列出了机组部分案例诊断结果,通过表 4 可明显看出,在第 7~10 组样本数据中,普通 SVM 出现故障判别失误的现象,而经过粒子群优化后的 SVM 模型(PSVM)判别正确。而表 5 列出了表 4 第 8 组样本前后 6 s 诊断结果,由表 5 可知优化后的 SVM 判别模型能更早的发现故障。

表4 部分案例诊断结果

Table 4 Part of case diagnosis results

序号	$u_1/$ (°)	$u_2/$ (°)	$u_3/$ (°)	...	$u_{11}/$ ℃	$u_{12}/$ ℃	$u_{13}/$ ℃	SVM 故障	PSVM 故障	故障 类型	故障 定位
1	0.057	0.073	0.066	...	30.35	31.32	31.26	正常	正常	1	叶片1
2	0.059	0.071	0.063	...	30.76	30.67	30.51	正常	正常	1	叶片1
3	0.059	0.070	0.060	...	30.69	31.84	30.82	正常	正常	2	叶片1
4	0.066	0.168	0.058	...	30.82	31.68	31.30	故障	故障	2	叶片2
5	0.066	0.166	0.057	...	30.84	30.19	30.72	故障	故障	2	叶片3
6	0.076	0.070	0.164	...	30.38	30.98	31.24	故障	故障	1	叶片1
7	0.098	0.074	0.104	...	30.35	30.78	30.86	正常	故障	1	叶片3
8	0.102	0.061	0.066	...	30.37	31.76	31.28	正常	故障	1	叶片1
9	0.066	0.068	0.067	...	30.64	31.82	30.58	正常	故障	2	叶片2
10	0.097	0.075	0.066	...	30.43	30.15	31.14	故障	正常	2	叶片3
11	0.138	0.081	0.065	...	30.53	31.38	30.46	故障	故障	3	叶片1
12	0.082	0.081	0.129	...	30.64	30.38	30.28	故障	故障	3	叶片3
13	0.159	0.082	0.073	...	30.40	30.04	30.02	故障	故障	1	叶片1
14	0.162	0.077	0.074	...	30.40	30.04	30.12	故障	故障	1	叶片1

表5 机组连续数据诊断结果

Table 5 Unit continuous data diagnosis results

序号	$u_1/$ ($^{\circ}$)	$u_2/$ ($^{\circ}$)	$u_3/$ ($^{\circ}$)	...	$u_{11}/$ $^{\circ}\text{C}$	$u_{12}/$ $^{\circ}\text{C}$	$u_{13}/$ $^{\circ}\text{C}$	SVM 故障	PSVM 故障	故障 类型	故障 定位
1	0.097	0.068	0.067	...	30.35	31.32	31.26	正常	正常	1	叶片1
2	0.098	0.075	0.076	...	30.76	30.67	30.51	正常	正常	1	叶片1
3	0.055	0.07	0.068	...	30.69	31.84	30.82	正常	正常	1	叶片1
4	0.061	0.068	0.064	...	30.82	31.68	31.30	正常	正常	1	叶片1
5	0.061	0.061	0.062	...	30.84	30.19	30.72	正常	正常	1	叶片1
6	0.086	0.06	0.067	...	30.38	30.98	31.24	正常	正常	1	叶片1
7	0.102	0.071	0.06	...	30.37	31.76	31.28	正常	故障	1	叶片1
8	0.101	0.071	0.07	...	30.37	31.76	31.28	正常	故障	1	叶片1
9	0.101	0.068	0.067	...	30.64	31.82	30.58	正常	故障	1	叶片1
10	0.118	0.075	0.076	...	30.43	30.15	31.14	故障	故障	1	叶片1
11	0.128	0.082	0.075	...	30.53	31.38	30.46	故障	故障	1	叶片1
12	0.139	0.084	0.089	...	30.64	30.33	30.28	故障	故障	1	叶片1
13	0.149	0.083	0.083	...	30.40	30.04	30.12	故障	故障	1	叶片1

表6为SVM和PSVM对于3类故障的判别结果,结果表明普通SVM故障判别模型本身的判别精度已较高,但也有部分样本判别错误,而通过粒子群算法优化后的模型判别精度得到进一步提高。

表6 部分判别结果及比较

Table 6 Partial discrimination results and comparison

故障 类型	样本 数量	SVM		PSVM	
		判正数量	正确率/%	判正数量	正确率/%
1	200	189	94.5	196	98.0
2	200	197	98.5	198	99.0
3	300	253	84.3	277	92.3

同时,本文针对当前对于变桨系统故障程度分类不完善的情况,基于模糊域规则对故障程度进行分类,将变桨角度故障分为正常、轻微、严重3类,具体分类情况见表7。首先,对于运行数据采用第1层SVM故障判别模型,把正常状态和故障状态区分开,然后利用第2层SVM故障判别模型区分故障程度是轻微还是严重。流程图如图3。

表8列出了12例第1类故障程度诊断结果,由表8可以看出,双层SVM判别模型可以很好地区分故障程度,为运维人员提供更加精确的故障信息。

表7 3类故障程度分类

Table 7 Classification of three types of fault

故障类型	范围	程度分类
故障类型1	$0^{\circ}\sim 0.1^{\circ}$	正常
	$0.1^{\circ}\sim 1^{\circ}$	轻微
	$1^{\circ}\sim 10^{\circ}$	严重
故障类型2	$0^{\circ}\sim 2^{\circ}$	正常
	$2^{\circ}\sim 10^{\circ}$	轻微
	$10^{\circ}\sim 20^{\circ}$	严重
故障类型3	$0\sim 1\text{ s}$	正常
	$1\sim 5\text{ s}$	轻微
	$5\sim 30\text{ s}$	严重




图3 双层SVM故障程度分类流程

Fig. 3 Double layer SVM fault classification process

表8 故障程度诊断结果
Table 8 Part of case diagnosis results

序号	$u_1/(^{\circ})$	$u_2/(^{\circ})$	$u_3/(^{\circ})$...	$u_{11}/^{\circ}\text{C}$	$u_{12}/^{\circ}\text{C}$	$u_{13}/^{\circ}\text{C}$	SVM1	SVM2
1	0.047	0.053	0.056	...	30.357	31.325	31.263	正常	正常
2	0.049	0.051	0.043	...	30.763	30.677	30.510	正常	正常
3	0.054	0.060	0.055	...	30.697	31.843	30.822	正常	正常
4	0.048	0.057	0.051	...	30.825	31.689	31.301	正常	正常
5	0.170	0.066	0.057	...	30.849	30.191	30.721	故障	轻微
6	0.146	0.051	0.054	...	30.381	30.987	31.247	故障	轻微
7	0.098	0.074	0.052	...	30.358	30.781	30.867	正常	正常
8	0.072	0.071	0.065	...	30.373	31.769	31.285	正常	正常
9	0.071	0.068	0.057	...	30.640	31.826	30.583	正常	正常
10	0.297	0.075	0.056	...	30.437	30.152	31.143	故障	轻微
11	0.338	0.081	0.085	...	30.531	31.383	30.466	故障	轻微
12	1.549	0.085	0.079	...	30.644	30.338	30.283	故障	严重

5 结 论

1)通过建立基于模糊粗糙集方法的变桨系统特征参数约简模型,得出叶片实际值与设定值差值、叶片两两角度差值、驱动电机温度、备用电池电压等与变桨故障相关度较大的运行参数。降低了故障判别的复杂度,减少了处理的数据量。

2)经风场实际运行数据训练的支持向量机变桨角度故障判别模型,对于实际故障具有较好的判别能力,通过进一步利用粒子群优化算法对模型进行优化,相比于普通 SVM 模型,该优化模型提高了判别精度。

3)基于双层 SVM 模型的电动变桨系统故障程度分类判别,可给出故障程度,从而提高了故障判别的分类精度,更有利于实际风场维护人员了解风力机运行状态,采取相应的措施。

【参考文献】

[1] 李辉,杨超,赵斌,等.风电机组电动变桨系统建模及运行特性评估与测试[J].电力系统自动化,2013,37(11):20-25.
LI H, YANG C, ZHAO B, et al. Modeling and operation performance evaluation and test of electric pitch system in wind turbine generator system[J]. Automation of electric power systems, 2013, 37(11): 20-25.

[2] CIVELEK Z, LUY M, CAM E, et al. A new fuzzy logic proportional controller approach applied to individual pitch angle for wind turbine load mitigation[J]. Renewable energy, 2017, 111: 708-717.
[3] CHEN B, MATTHEWS P C, TAVNER P J. Wind turbine pitch faults prognosis using a-priori knowledge-based ANFIS [J]. Expert systems with applications, 2013, 40(17): 6863-6876.
[4] WU D G, LIU W. A new fault diagnosis approach for the pitch system of wind turbines [J]. Advances in mechanical engineering, 2017, 9(5): 1-9.
[5] 吴定会,翟艳杰,李意扬,等.基于辨识算法的风力机桨距执行器故障诊断[J].控制工程,2016,23(6):795-799.
WU D H, ZHAI Y J, LI Y Y, et al. Fault diagnosis for pitch actuators of wind turbines based on identification algorithm [J]. Control engineering of China, 2016, 23 (6):795-799.
[6] 尹诗,余忠源,孟凯峰,等.基于非线性状态估计的风电机组变桨控制系统故障识别[J].中国电机工程学报,2014,34(z1):160-165.
YIN S, YU Z Y, MENG K F, et al. Fault identification of pitch control system of wind turbine based on nonlinear state estimation[J]. Proceedings of the CSEE, 2014, 34 (z1): 160-165.
[7] 姚万业,李新丽.基于状态监测的风电机组变桨系统

- 故障诊断[J]. 可再生能源, 2016, 34(3): 437-440.
- YAO W Y, LI X L. Pitch system fault diagnosis for wind turbine based on condition monitoring [J]. Renewable energy resources, 2016, 34(3): 437-440.
- [8] 赵洪山, 连莎莎, 邵玲, 等. 基于模型的风电机组变桨距系统故障检测[J]. 电网技术, 2015, 39(2): 440-444.
- ZHAO H S, LIAN S S, SHAO L, et al. A model-based fault detection for variable-pitch system of wind turbines [J]. Power system technology, 2015, 39(2): 440-444.
- [9] 董兴辉, 闫慧丽, 张晓亮, 等. 基于FDA贡献图的风电机组变桨系统故障定位[J]. 可再生能源, 2017, 35(1): 93-100.
- DONG X H, YAN H L, ZHANG X L, et al. Fault location of pitch system based on FDA contribution diagram [J]. Renewable energy resources, 2017, 35(1): 93-100.
- [10] 郭慧东, 王玮, 夏明超. 基于数据挖掘的风电机组变桨系统劣化状态在线辨识方法[J]. 中国电机工程学报, 2016, 36(9): 2389-2397.
- GUO H D, WANG W, XIA M C. On-line identification for wind turbine pitch system degradation based on data mining technology [J]. Proceedings of the CSEE, 2016, 36(9): 2389-2397.
- [11] LIU H, XING H D, YANG Z L, et al. The application of intelligent fuzzy inference to the fault diagnosis in pitch-controlled system [J]. Energy procedia, 2012 (16): 1839-1844.
- [12] 李辉, 杨超, 李学伟, 等. 风机电动变桨系统状态特征参量挖掘及异常识别[J]. 中国电机工程学报, 2014, 34(12): 1922-1930.
- LI H, YANG C, LI X W, et al. Conditions characteristic parameters mining and outlier identification for electric pitch system of wind turbine [J]. Proceedings of the CSEE, 2014, 34(12): 1922-1930.
- [13] MI J S, LEUNG M Y, ZHAO H Y, et al. Generalized fuzzy rough sets determined by a triangular norm [J]. Information sciences, 2008, 178(16): 3203-3213.
- [14] 刘靖, 陈福生, 张勤, 等. 基于粗糙集和模糊集的属性约简算法[J]. 计算机工程与科学, 2005, 27(2): 42-44.
- LIU J, CHEN F S, ZHANG Q, et al. A reduction algorithm based on rough and fuzzy sets [J]. Computer engineering and science, 2005, 27(2): 42-44.
- [15] SINDHWANI V, RAKSHIT S, DEODHARE D, et al. Feature selection in MLPs and SVMs based on maximum output information [J]. IEEE transactions on neural networks, 2004, 15(4): 937-948.
- [16] HASANIPANAH M, ARMAGHANI D J, HASSAN B A, et al. Application of PSO to develop a powerful equation for prediction of flyrock due to blasting [J]. Neural computing & applications, 2017, 28 (Sup1): 1043-1050.

FAULT DIAGNOSIS OF ELECTRIC PITCH SYSTEM FOR MW WIND TURBINE

Gao Feng, Deng Xingxing, Liu Qiang, Yang Xiyun, Wu Xiaojiang

(School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: In order to improve the angle fault diagnosis accuracy of electric pitch system for large-scale wind turbines, the feature reduction based on the fuzzy rough set and the support vector machine (SVM) based on particle swarm optimization algorithm were combined to analyze the failure of the electric pitch system. According to the fuzzy rough set theory, the mathematical model of the electric pitch system with the characteristic parameter reduction was established firstly. By reducing the pitch-related operation data, the parameters with high contribution rate to the fault diagnosis were determined. So as to get the high accuracy diagnosis model, the SVM based on particle swarm optimization algorithm was trained by the actual operating data. Then the fault diagnosis model based on the double-layer support vector machine was designed, and the fault can be further classified. Finally, a pitch angle fault diagnosis experiment was carried out by the actual operation data. The experimental results show that the diagnosis method can identify and classify the pitch angle fault accurately and quickly.

Keywords: wind turbines; failure analysis; fuzzy set theory; electric pitch system; SVM