

doi: 10.12068/j.issn.1005-3026.2019.12.001

基于 GM – ELM 的有杆泵抽油井故障诊断

侯延彬, 陈炳均, 高宪文  
(东北大学 信息科学与工程学院, 辽宁 沈阳 110819)

**摘 要:** 为了解决有杆泵抽油井故障诊断问题,提出了基于灰度矩阵极限学习机(gray matrix-extreme learning machine, GM – ELM)故障诊断方法. 首先用灰度矩阵对有杆泵抽油井进行故障特征提取;然后用数理统计的方法建立灰度矩阵的特征向量,将故障特征向量作为故障诊断模型的输入值;最后建立 GM – ELM 模型对有杆泵抽油井故障进行诊断. 仿真结果表明该方法与 GRNN(general regression neural network)方法、LS – SVM(least squares support vector machine)方法、BPNN(back propagation neural network)方法相比具有更高的故障诊断准确率.

**关 键 词:** ELM;特征提取;故障诊断;灰度矩阵;示功图

**中图分类号:** TP 29      **文献标志码:** A      **文章编号:** 1005 – 3026(2019)12 – 1673 – 06

Fault Diagnosis of Sucker Rod Pumping Wells Based on GM-ELM

HOU Yan-bin, CHEN Bing-jun, GAO Xian-wen  
(School of Information Science & Engineering, Northeastern University, Shenyang 110819, China. Corresponding author: CHEN Bing-jun, E-mail: 15776584468@163.com)

**Abstract:** Gray matrix-extreme learning machine (GM-ELM) was proposed to solve the fault diagnosis of sucker rod pumping wells. Firstly, the gray matrix method was applied to extract the fault features of sucker rod pumping wells. Secondly, the mathematical method was applied to establish eigenvectors of gray matrix, and the eigenvectors were used as the input value of the fault diagnosis model. Finally, the GM-ELM model was established to diagnose the fault of sucker rod pumping wells. The simulation results indicate that GM-ELM method has higher accuracy of fault diagnosis than GRNN (general regression neural network), LS-SVM (least squares support vector machine), BPNN(back propagation neural network).

**Key words:** ELM; feature extraction; fault diagnosis; gray matrix; dynamometer card

目前我国大多数的油田都是利用有杆泵抽油井采油,有杆泵抽油井往往安装在环境恶劣的野外,并且井下设备通常在数百米的地下作往复运动<sup>[1]</sup>.有杆泵抽油井工作原理如图1所示,分为地上和地下两部分.地上部分主要作用是抽油系统提供动力来源,将电能转化为机械能.电控柜中的变频调速设备用以控制电机转速,经过减速箱增大扭矩,曲柄通过连杆带动游梁上下摆动,驴头和悬绳器保证抽油杆垂直往复工作.地下部分主要作用是将机械能转化为石油的势能,把石油从地下输送至地上.随着油井开采的年头增加、开采技术的提升,抽油泵下泵深度越来越深,井下情况复杂,往往无法安装传感器,不能直接检测到井下工作状态.

有杆泵抽油井的井下设备出现故障时,不仅会造成油田的采油成本增加,还可能导致设备损坏或者发生安全事故.如果能够及时识别有杆泵抽油井的故障类型,就可以找出解决方案,减少故障带来的损失.文献[2]将专家系统引入到有杆泵抽油井的故障诊断中,通过将油田现场实测的示功图与标准示功图对比来判断有杆泵抽油井故障的类型.文献[3 – 4]将神经网络方法应用在有

杆泵抽油井故障诊断中,通过建立神经网络模型进行故障诊断.文献[5-6]将支持向量机的算法应用在有杆泵抽油井故障诊断中,通过对示功图的特征提取,进行支持向量机的故障分类.以上方法可以实现抽油井故障诊断,但训练时间长,模型参数设置复杂,需要建模人员有足够的经验.

ELM 算法<sup>[7]</sup>通过设置隐含层节点个数就可以一次训练得到全局最优解,不需要通过复杂的迭代得到,大大提升了算法的速度,节省了系统的时间,满足有杆泵抽油井故障诊断的实时性.ELM 的训练过程十分简单,在训练过程中不需要设置输入层权值和偏置.ELM 算法的学习速度很快,诊断准确性高.




图 1 有杆泵抽油系统结构图

Fig. 1 The diagram of sucker rod pumping system

为了减少由于经验不足导致模型参数确定困难、诊断精度低的问题,本文结合某油田有杆泵抽油井在运行过程中出现的故障问题,应用灰度矩阵的方法将示功图灰度化,利用数理统计方法计算出灰度矩阵的 6 个特征向量,根据不同的故障类型的特征向量的差异,构建基于 GM-ELM 的有杆泵抽油井故障诊断模型.通过仿真验证了基于 GM-ELM 的有杆泵抽油井故障诊断方法的可行性和有效性.

1 基于灰度矩阵的故障特征提取

1.1 灰度矩阵理论

对于有杆泵抽油井的故障的识别,应该规避柱塞位移与悬点载荷对故障诊断的影响.因此,将有杆泵抽油井位移与悬点载荷进行无量纲归一化处理,将无量纲归一化处理的示功图放在一个长度和宽度比为 2:1 的矩阵中,然后将长×宽为

64×32 的网格加入到归一化的示功图矩阵中.由于网格法只产生 0,1 值,特征矩阵无法识别示功图的细微变化.于是应用灰度矩阵方法将示功图灰度化.利用数理统计的方法计算出示功图灰度矩阵的 6 个特征向量.灰度矩阵方法的思想是:示功图轮廓线内部,灰度值与示功图轮廓线的距离成正比,即离轮廓线越近灰度值越低.示功图轮廓线外部,灰度值与轮廓线的距离成反比,即离轮廓线越近灰度值越高.对所得的灰度矩阵示功图进行特征提取,灰度矩阵示功图的统计特征如下.

灰度均值:

g1 = \sum\_{r=L}^Q (r \cdot p(r)). \tag{1}

灰度方差:

g2 = \sqrt{\sum\_{r=L}^Q ((r - g1)^2 \cdot p(r))}. \tag{2}

灰度偏差:

g3 = \frac{1}{g2} \sum\_{r=L}^Q ((r - g1)^3 \cdot p(r)). \tag{3}

灰度峰值:

g4 = \frac{1}{g2} \sum\_{r=L}^Q ((r - g1)^4 \cdot p(r)). \tag{4}

灰度能量:

g5 = \sum\_{r=L}^Q p(r)^2. \tag{5}

灰度熵:

g6 = - \sum\_{r=L}^Q ((1 - p(r)) \cdot \lg(1 - p(r))). \tag{6}

其中:灰度值为 r;灰度值最小为 L;灰度值最大为 Q;灰度值 r 的概率为 p(r).

1.2 故障特征提取

示功图可以记录抽油杆载荷和位移的变化,直接反映出井下抽油泵的工作状态,图 2 为有杆泵正常运行状态下的示功图.抽油井的井下设备容易出现故障,石油行业的专家根据力学行为将有杆泵抽油井的故障分为 10 类.其典型故障示功图如图 3 所示.

针对典型的故障示功图样本数据,利用灰度矩阵的方法对有杆泵抽油井的故障进行特征提取.灰度矩阵故障特征提取的步骤如下.

步骤 1 通过 MATLAB 将得到的有杆泵抽油井示功图进行归一化,去除悬点载荷和悬点位移对故障诊断的影响.

步骤 2 将示功图放在一个长度与宽度比为 2:1 的矩阵中,然后将长×宽为 64×32 的网格加入到归一化的示功图矩阵中.

步骤 3 通过优先深度搜索<sup>[8]</sup>的方法将示功图的边界灰度赋值为 1。




图 2 有杆泵运行正常的示功图  
Fig. 2 Normal dynamometer cards of the rod pumping wells

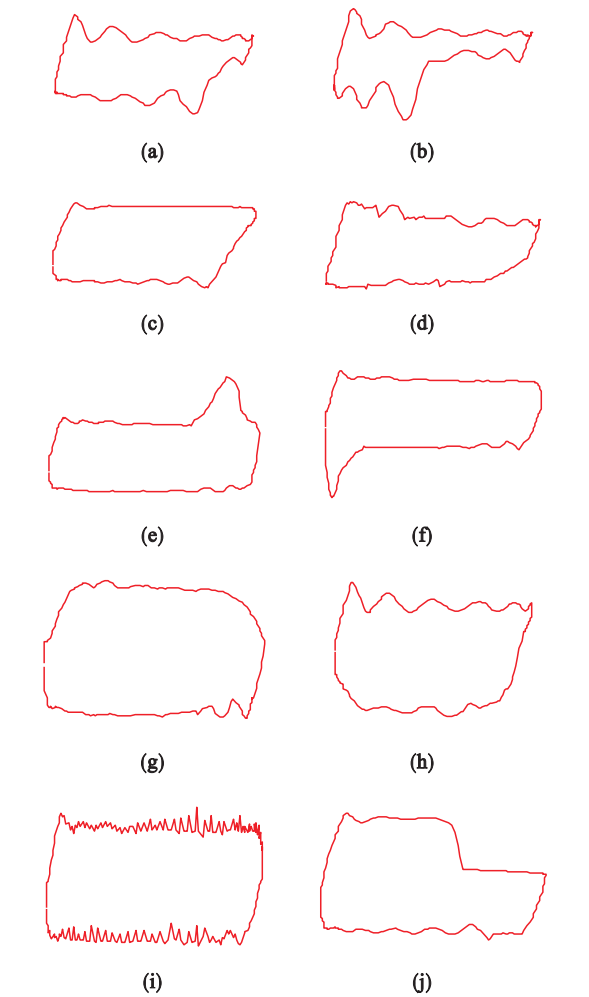


图 3 10 种故障典型示功图  
Fig. 3 Ten typical fault dynamometer cards  
(a)—气体影响；(b)—供液不足；(c)—抽油杆断脱；  
(d)—油稠；(e)—泵上碰；(f)—泵下碰；  
(g)—游动凡尔漏失；(h)—固定凡尔漏失；  
(i)—油井出砂；(j)—柱塞脱出工作筒。

步骤 4 示功图轮廓线内部，灰度值与示功

图轮廓线的距离成正比；示功图轮廓线外部，灰度值与轮廓线的距离成反比。

步骤 5 利用 MATLAB 编程计算出有杆泵抽油井的 6 种特征矩阵。

正常运行状态的灰度矩阵示功图如 4 所示，气体影响的灰度矩阵示功图如图 5 所示。




图 4 灰度矩阵示功图  
Fig. 4 Gray matrix dynamometer cards




图 5 气体影响灰度矩阵示功图  
Fig. 5 Gray matrix dynamometer cards of gas influence

通过 MATLAB 软件编程对 11 种有杆泵抽油井故障的示功图进行灰度矩阵特征提取。统计特征向量分别用  $G=[g_1,g_2,g_3,g_4,g_5,g_6]$  表示。结果如表 1 所示。不同故障的特征向量是不同的，例如供液不足时， $g_1$  为负值，其他类型工况  $g_1$  值均为正值。这是由于供液不足的示功图，右下部分缺失面积较大，导致灰度值出现较多负值。灰度特征向量可以很好地描述示功图曲线的变化特征，进而识别出有杆泵抽油井故障的类型。

## 2 基于 GM-ELM 的有杆泵抽油井故障诊断

### 2.1 ELM 原理

假设 ELM 算法的训练样本为  $(x_i, y_i) \in \mathbf{R}^m \times \mathbf{R}^n$ ，其中输入、输出向量为  $x_i=[x_1, x_2, \cdots, x_m]$ ， $y_i=[y_1, y_2, \cdots, y_n]$ 。则 ELM 的数学模型为<sup>[9]</sup>

表 1 示功图灰度矩阵统计特征向量的值  
Table 1 Statistical eigenvectors of gray matrix dynamometer

故障类型	$g_1$	$g_2$	$g_3$	$g_4$	$g_5$	$g_6$
正常	5.081	16.874	0.342	2.137	0.067	0.954
气体影响	1.480	26.063	-0.141	8.822	0.075	0.948
供液不足	-0.997	54.021	-1.053	4.192	0.060	0.872
抽油杆断落	4.254	19.396	0.193	2.675	0.065	0.952
固定凡尔漏失	4.024	18.870	0.025	2.088	0.078	1.000
游动凡尔漏失	4.380	18.944	0.180	2.378	0.063	0.958
泵上碰	1.789	33.885	-0.547	2.713	0.060	0.953
泵下碰	1.233	28.560	-0.174	2.404	0.072	0.954
油稠	2.950	17.752	0.266	2.571	0.064	0.911
油井出砂	1.324	21.699	0.012	2.506	0.090	0.927
柱塞脱落出工作筒	2.619	35.607	-0.669	3.605	0.058	0.960

$$t(x_i) = \sum_{j=1}^L \beta_j G(w_j \cdot x_i + b_j), i = 1, 2, \dots, m. \quad (7)$$
  
 $x_i \in \mathbf{R}^m, w_j \in \mathbf{R}^m, \beta_j \in \mathbf{R}^n, b_j \in \mathbf{R}.$

其中： $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jn}]^T$  为输出权值； $G(\cdot)$  为 ELM 模型激活函数； $w_j$  为隐含层权值； $b_j$  为偏差； $t(x_i)$  为输出值。

若  $L = m$ , 则无论  $w, b$  取何值,  $\sum_i \|y_i - t_i\| = 0, t_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T$ . 将式(7)代入上式中得

$$\sum_{j=1}^m \beta_j G(w_j \cdot x_i + b_j) = y_i, i = 1, 2, \dots, m. \quad (8)$$

将式(8)表示成矩阵的形式： $H\beta = Y$ . 其中：

$$H(w_j, x_i, b_j) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1)g(w_2 \cdot x_1 + b_2) \cdots g(w_L \cdot x_1 + b_L) \\ g(w_1 \cdot x_2 + b_1)g(w_2 \cdot x_2 + b_2) \cdots g(w_L \cdot x_2 + b_L) \\ \vdots \quad \quad \quad \vdots \quad \quad \quad \vdots \\ g(w_1 \cdot x_m + b_1)g(w_2 \cdot x_m + b_2) \cdots g(w_L \cdot x_m + b_L) \end{bmatrix}_{L \times m},$$
$$Y = \begin{bmatrix} y_1^T \\ y_2^T \\ \vdots \\ y_n^T \end{bmatrix}_{L \times n}, \beta = \begin{bmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_n^T \end{bmatrix}_{m \times n}.$$

由于  $w, x, b$  在初始的时刻都已经随机设置完成, 则  $H$  就为一个常值矩阵,  $\beta$  的值就是  $H\beta = Y$  的最小二乘解. 即  $\min_{\beta} \|H\beta - Y\| = \|H\bar{\beta} - Y\|$ , 解得的最小二乘解为： $\bar{\beta} = H^+T$ . 其中伪逆矩阵  $H^+ = (H^TH)^{-1}H^T$ . 为了使 ELM 算法具有较强的稳定性, 根据岭回归理论<sup>[10]</sup>, 需要将核中加入一个大于零的值, 则：

$$H^+ = (H^TH + 1/\lambda)^{-1}H^T.$$

2.2 GM-ELM 的有杆泵抽油井故障诊断

GM-ELM 的有杆泵抽油井故障诊断模型, 原理是将有杆泵抽油井的 11 类示功图的灰度特征向量映射到有杆泵抽油井的故障空间. 然后利用 ELM 模型对故障进行诊断.

GM-ELM 算法应用于有杆泵抽油井故障诊断流程如图 6 所示.

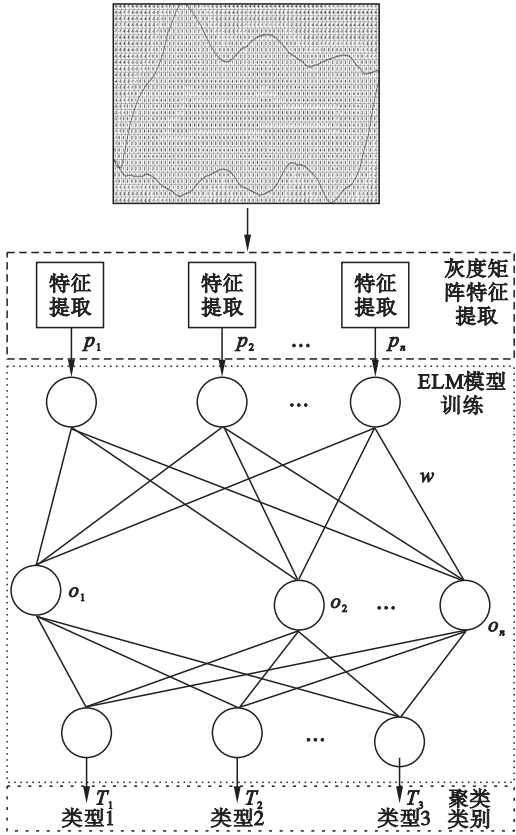


图 6 GM-ELM 算法应用于有杆泵抽油井故障诊断流程图

Fig. 6 Structure diagram based on GM-ELM of rod pumping well fault diagnosis



基于 GM - ELM 有杆泵抽油井故障诊断流程如下.

步骤 1 应用有杆泵抽油井现场采集到的有杆泵悬点载荷与位移绘制出实际示功图.

步骤 2 应用灰度矩阵的方法将示功图灰度化,根据得到的灰度矩阵计算出所需的统计值,将计算的 6 种统计值作为有杆泵抽油井故障的输入特征向量.

步骤 3 将极限学习机算法进行训练.

1)  $w, x, b$  在初始的时刻都已经随机设置完成. 设置隐含层节点个数  $M$ .

2) 选择激活函数的类型,对于有杆泵抽油井故障诊断选择 Sigmoid 函数,计算出输出矩阵  $H$ .

3) 计算出  $\beta$ ,其中  $\beta = (H^T H + 1/\lambda)^{-1} H^T T$ .

步骤 4 通过训练得出基于有杆泵抽油井故障诊断的 GM - ELM 模型.

步骤 5 利用 GM - ELM 模型对有杆泵抽油井故障进行诊断,分析基于 GM - ELM 算法对有杆泵抽油井故障诊断的准确率.

### 3 仿真结果

为了证明 GM - ELM 算法对有杆泵抽油井故障诊断的有效性,将 GM - ELM 算法和 GRNN 算法、LS - SVM 算法、BPNN 算法对有杆泵抽油井故障诊断进行了对比. 采用 110 组数据作为训练数据,每种故障样本为 10 组;44 组数据作为测试数据,每种故障样本为 4 组. GM - ELM 算法对抽油杆故障诊断结果如图 7 所示,GRNN 算法对抽油杆故障诊断结果如图 8 所示,LS - SVM 算法对抽油杆故障诊断结果如图 9 所示,BPNN 算法对抽油杆故障诊断结果如图 10 所示.




图 7 GM - ELM 诊断结果

Fig. 7 Diagnostic results of GM-ELM




图 8 GRNN 诊断结果

Fig. 8 Diagnostic results of GRNN




图 9 LS - SVM 诊断结果

Fig. 9 Diagnostic results of LS-SVM




图 10 BPNN 诊断结果

Fig. 10 Diagnostic results of BPNN

由表 2 可知,GM - ELM 算法的故障诊断准确率为 95.5%,仿真时间为 0.296 s. GRNN 的故障诊断准确率为 52.3%,仿真时间为 4.398 s. LS - SVM 的故障诊断准确率为 70%,仿真时间为 1.653 s. BP 的故障诊断准确率为 68.2%,仿真时间为 4.538 s. GRNN,BPNN 模型需要有足够数量的样本进行模型训练,在建模样本有限的情况下,GRNN,BPNN 的诊断精度较低;LS - SVM 适

用于小样本数据,但模型参数难以确定,需要足够的经验才能找出最优的模型参数,提高模型诊断精度.

LS – SVM 诊断精度高于 GRNN 与 BPNN,但由于模型参数的选取困难,导致精度仍然不高,且实际应用较难. GM – ELM 在训练过程中不需要设置输入层权值和偏置,采用最小二乘算法使优化过程为凸优化,训练一次就可以得到全局最优解,提高了故障诊断的准确性和训练时间.

表 2 ELM 与 GRNN,LS – SVM,BPNN 方法测试结果对比

Table 2 ELM test results were compared with GRNN, LS-SVM and BPNN methods

算法	训练时间/s	准确率/%
ELM	0. 296	95. 5
GRNN	4. 398	52. 3
LS – SVM	1. 653	70
BPNN	4. 538	68. 2

## 4 结 语

本文针对某油田有杆泵抽油井采油过程中的故障问题,提出了基于 GM – ELM 的有杆泵抽油井故障诊断方法,将灰度矩阵提取的故障特征向量作为 GM – ELM 模型的输入值,进行有杆泵抽油井的故障诊断. 最后将 GM – ELM 故障诊断方法与 GRNN 故障诊断方法,LS – SVM 故障诊断方法,BPNN 故障诊断方法进行仿真对比. 结果表明 GM – ELM 故障诊断效果明显优于 GRNN,LS – SVM,BPNN 故障诊断方法.

### 参考文献:

[ 1 ] Zheng B,Gao X. Diagnosis of sucker rod pumping based on

dynamometer card decomposition and hidden Markov model [ J ]. *Transactions of the Institute of Measurement and Control*,2018,40( 16 ):4309 – 4320.

[ 2 ] 袁文琪,胡敏. 基于示功图的油井故障诊断专家系统研究 [ J ]. 电子设计工程,2015,23( 18 ):119 – 122.  
( Yuan Wen-qi, Hu Min. The research of oil well fault diagnosis expert system based on dynamometer card [ J ]. *Electronic Design Engineering*,2015,23( 18 ):119 – 122. )

[ 3 ] Wu W,Sun W L,Wei H X. A fault diagnosis of suck rod pumping system based on wavelet packet and RBF network [ J ]. *Advanced Materials Research*,2011,189 ( 2 ):2665 – 2669.

[ 4 ] Zhang Y Y,Zhao J J, Liang W. The fault diagnosis of electric power metering system based on momentum BP neural network[ J ]. *Applied Mechanics and Materials*,2014,668/669( 12 ):724 – 728.

[ 5 ] Wu W,Zhou Y, Wei H X. A fault diagnosis of suck rod pumping system based on SVM[ J ]. *Applied Mechanics and Materials*,2013,307( 2 ):285 – 289.

[ 6 ] Feng J, Wang M, Yang Y. Fault diagnosis of sucker-rod pumping system using support vector machine [ J ]. *Communications in Computer & Information Science*,2012,289( 1 ):179 – 189.

[ 7 ] Huang G B,Zhou H,Ding X. Extreme learning machine for regression and multiclass classification [ J ]. *IEEE Transactions on Systems, Man and Cybernetics, Part B ( Cybernetics )*,2012,42( 2 ):513 – 529.

[ 8 ] 李训铭,周志权. 基于 BP 神经网络和灰色理论的示功图故障诊断[ J ]. 电子设计工程,2012,20( 17 ):23 – 25,31.  
( Li Xun-ming,Zhou Zhi-quan. Diagnosis of working drawing based on BP net and grey theory [ J ]. *Electronic Design Engineering*,2012,20( 17 ):23 – 25,31. )

[ 9 ] Luo M, Li C, Zhang X. Compound feature selection and parameter optimization of ELM for fault diagnosis of rolling element bearings[ J ]. *ISA Transactions*,2016,56( 11 ):556 – 566.

[ 10 ] Wang S, Chung F L, Wang J. A fast learning method for feedforward neural networks [ J ]. *Neurocomputing*, 2015,149:295 – 307.