DOI:10.16198/j.cnki.1009-640X.2016.06.002

戴波,何启.大坝变形监测统计模型与混沌优化 ELM 组合模型[J]. 水利水运工程学报,2016(6):9-15. (DAI Bo, HE Qi. A model combining with statistic model and chaos-optimized extreme learning machine for dam deformation monitoring[J]. Hydro-Science and Engineering, 2016(6):9-15.)

大坝变形监测统计模型与混沌优化 ELM 组合模型

戴 波^{1,2},何 启^{1,2}

(1. 河海大学 水文水资源与水利工程科学国家重点实验室, 江苏 南京 210098; 2. 河海大学 水资源高效利 用与工程安全国家工程研究中心, 江苏 南京 210098)

摘要:变形是反映大坝动态演化的重要效应量。为了提升统计模型预测能力,借助极限学习机(ELM)处理非 线性问题的优势,对大坝位移的统计模型残差进行数据挖掘。而极限学习机欠缺对混沌动力特性的考虑,为了 解决这个问题,采用混沌理论对统计模型残差进行了混沌动力学特性分析,揭示其混沌特性,并据此重构相空 间,从而为混沌优化极限学习机提供先验知识。基于统计模型,结合极限学习机和混沌理论的优点,建立统计 模型与混沌优化 ELM 的组合模型。将该组合模型应用于工程实例,由多个定量评估指标对模型进行性能评价, 结果表明,组合模型建模合理,预测精度高于统计模型、统计模型与混沌优化 BP 神经网络组成的组合模型,在 大坝变形监测中具有一定的应用价值。

关 键 词:大坝位移;大坝变形监测;统计模型;混沌;极限学习机

中图分类号: TV 698 文献标志码: A 文章编号:1009-640X(2016)06-0009-07

变形监测量直观可靠,国内外普遍作为最主要的监测量^[1]。大坝位移观测数据反映了大坝在荷载和环境作用下产生效应量的动态演化,承载了坝体性态的丰富信息^[2]。科学分析位移观测数据,对大坝变形实时预测模型的建立具有重要意义。传统的统计模型在大坝位移资料的分析中拟合精度高但预测精度效果欠佳。汪树玉等^[3]探讨了大坝位移观测数据中的混沌现象。在传统统计模型中增加残差预测项,并应用混沌理论预测残差,可提高预测精度^[4]。

混沌时间序列在内部有确定的非线性规律性,这种特性难以用解析方法进行表达,使得传统的预报方法 很难达到较好的预报结果。而神经网络法具有很强的自适应性和记忆功能,是分析非线性混沌时间序列的 适用方法。极限学习机(extreme learning machine, ELM)是由 Huang 等^[5]依据摩尔-彭罗斯(MP)的广义逆 矩阵理论提出的一种单隐层前馈神经网络的新机器学习算法。与 BP 神经网络等传统神经网络学习算法相 比,极限学习机简单易用,具有学习速度快,泛化性好,参数选取简单等优点^[6]。由于 ELM 的性能优越,近几 年在各个领域得到了广泛应用^[7-9],但目前缺乏在大坝变形监测中的应用研究。需要注意的是,极限学习机 方法并未考虑大坝的混沌动力学特性。作为以上研究的延伸,下面主要研究两个问题:一是位移观测数据的 混沌特性识别;二是利用混沌特性构建混沌优化极限学习机模型,与统计模型组成大坝变形实时预测模型。

1 位移观测数据的混沌特性识别

根据混沌理论,混沌时间序列包含着系统参与演化的所有变量的大量信息,可通过对原位观测数据进行

收稿日期: 2015-12-09

基金项目:国家自然科学基金重点项目(51139001,41323001);国家重点研究计划课题(2016YFC0401601);国家自然科学基金面上项目(51479054,51579086,51379068,51579083);国家自然科学基金资助项目(51279052,51579085)

作者简介:戴 波(1992—),男,江苏泰州人,博士研究生,主要从事水工结构与大坝安全监控研究。 E-mail:bo.dai@hhu.edu.cn 相空间重构,恢复其自身规律。

1.1 重构相空间

由于实测数据很可能含有噪声,现普遍采用坐标延迟法重构相空间。把一维位移观测时间序列 x(t) 嵌入到 m 维相空间中^[4]:

$$X(t) = (x(t), x(t+\tau), \cdots, x(t+(m-1)\tau))$$
(1)

式中: τ 为延迟时间, $\tau = h\Delta t$, h 是正整数, Δt 为时间序列的时间间隔。

由式(1)可知,相空间重构的质量取决于重构参数的确定,本文采用自相关法确定延迟时间 τ,在此基础上采用抗噪性较强的 Cao 算法选定嵌入维数 m。

1.2 Lyapunov 指数

1.2.1 Lyapunov 指数谱 Lyapunov 指数是表征混沌系统的重要特征量,不仅刻画了动力系统的稳定性,还能体现邻近轨道的发散或收敛程度。

设一个n维大坝动力系统具有如下形式:

$$\frac{dx_i}{dt} = f_i(x_1, x_2, \dots, x_n) \quad i = 1, 2, \dots, n$$
(2)

 (x_1, x_2, \dots, x_n) 组成的相空间轨道可描述动力系统的演化。若初始时刻为 t_0 ,相空间轨道上一点 $x_0 = (x_1(t_0), x_2(t_0), \dots, x_n(t_0))$ 有一小偏差 δx ,则由 $x_0 + \delta x$ 出发,形成另一个轨道。 δx 随时间演化规律取决于下列微分方程组:

$$\frac{\mathrm{d}\delta x_i}{\mathrm{d}t} = \sum_{j=1}^n A_{ij} \,\delta x_j \quad i = 1, 2, \cdots, n \tag{3}$$

式中:系数 A_{ii} 是式(2) $f_i(x_1, x_2, \dots, x_n)$ Jacobi 矩阵的元素,且

$$A_{ij} = \frac{\partial f_i(x_1, x_2, \cdots, x_n)}{\partial x_i} \Big|_{(x_1, x_2, \cdots, x_n)}$$
(4)

Jacobi 矩阵的特征值在一段相当长时间内的平均值,可按照大小依次排序:

$$\lambda_1 \ge \lambda_2 \ge \dots \ge \lambda_n \tag{5}$$

式中: λ_i (*i* = 1,2,…,*n*)为 Lyapunov 指数谱。

在 $\lambda_i < 0$ 的方向,相空间收缩,运动是稳定的;在 $\lambda_i > 0$ 的方向,轨道迅速分离,长时间行为对初始条件 敏感,运动呈混沌状态;在 $\lambda_i = 0$ 的方向,边界稳定,初始误差不放大,也不缩小^[10]。随着系统的进化,如果 包含至少一个正的 Lyapunov 指数,那么就认为该系统具有混沌特性^[11]。因此,在 Lyapunov 指数谱中,最大 Lyapunov 指数 λ_1 具有十分重要的意义。

1.2.2 最大 Lyapunov 指数 λ_1 的估计方法 Wolf 算法对数据的长度要求高,计算量较大,抗噪能力差。 Rosenstein 等提出的计算最大 Lyapunov 指数的算法对延迟时间、数据长度和噪声的变化等表现出较好的鲁 棒性(以下简称 Rosenstein 算法)^[10]。因此,选取 Rosenstein 算法计算最大 Lyapunov 指数 λ_1 ,具体计算步骤 如下:

(1)依据延迟时间 τ,嵌入维 m 和式(1)重构相空间。

(2)设 d(t) 为不同轨迹上相邻两点的距离,则:

$$d(t) = C\exp(\lambda_1 t) \tag{6}$$

式中:C为初始分岔。

找出相空间中一点 X(j) 的邻近点 $X(\hat{j})$,则:

$$C_{i} = d_{i}(0) = \min \| X(j) - X(\hat{j}) \|$$
(7)

式中: C_i 和 $d_i(0)$ 为第 j个点与其邻近点 j 的 Euclidean 距离。

(3)对相空间中的每一点 X(j),计算出该邻近点对的第 i 个离散时间步的距离:

$$d_{j}(i) = \min \| X(j+i) - X(\hat{j}+i) \|$$
(8)

由式(6)得:

$$d_i(i) = C_i \exp(\lambda_1(i \Delta t))$$
(9)

式中: $d_i(i)$ 为 $i \Delta t$ 时刻的分岔。

(4) $\ln d_i(i) \sim i \Delta t$ 曲线的斜率便是 λ_1 ,即:

$$\lambda_1 \approx \frac{1}{i \Delta t} < \ln d_j(i) > \tag{10}$$

式中: <·> 为求对所有 j 的平均。由此,计算得出最大 Lyapunov 指数 λ_1 。

2 统计模型与混沌优化 ELM 组合模型

2.1 统计模型

根据对大坝和坝基的力学和结构理论分析,用确定性函数和物理推断法,科学选择统计模型的因子及其 表达式,然后依据实测资料用数据统计法确定模型中各项因子的系数,建立回归模型^[1]。大坝变形测点的 统计模型为:

$$\delta = a_0 + \sum_{i=1}^n a_i H^i + \sum_{i=1}^2 \left(b_{1i} \sin \frac{2\pi i t}{365} + b_{2i} \cos \frac{2\pi i t}{365} \right) + c_1 \theta + c_2 \ln \theta$$
(11)

式中: a_0 为常数项; a_i 为水压因子回归系数, $i=1 \sim n$;H为坝前水深;重力坝时,n=3;拱坝时n=4,5;t为测值当天至起测日累计天数; b_{1i} , b_{2i} 为温度因子回归系数, $i=1 \sim 2$; c_1 , c_2 为回归系数; $\theta = t/100_{\circ}$

2.2 极限学习机

极限学习机(extreme learning machine, ELM)是一种针对单隐层前馈神经网络的新算法,该算法随机产 生输入层与隐含层间的连接权值及隐含层神经元的阈值,且在训练过程中只需设置隐含层神经元个数,便可 获得惟一的最优解^[12]。

设有 n 个不同样本 (x_i, t_i) ,其中 $x_i = (x_{i1}, x_{i2}, \dots, x_{in})^{\mathsf{T}} \in \mathbb{R}^n$, $t_i = (t_{i1}, t_{i2}, \dots, t_{im})^{\mathsf{T}} \in \mathbb{R}^m$,则一个具有 M 个隐含层节点以及激励函数 g(x) 的极限学习机形式如下:

$$\sum_{i=1}^{M} \beta_{i}g(\omega_{i}x_{i} + b_{i}) = \boldsymbol{o}_{j}, \, j = 1, 2, \cdots, N$$
(12)

式中: $\boldsymbol{\omega}_i = (\boldsymbol{\omega}_{1i}, \boldsymbol{\omega}_{2i}, \dots, \boldsymbol{\omega}_{mi})$ 为连接网络输入层节点和第 *i* 个隐含层节点的输入权值向量; $\boldsymbol{\beta}_i = (\boldsymbol{\beta}_{i1}, \boldsymbol{\beta}_{i2}, \dots, \boldsymbol{\beta}_{in})^T$ 为连接第 *i* 个隐含层节点与网络输出层节点的输出权值向量; $\boldsymbol{o}_j = (o_{j1}, o_{j2}, \dots, o_{jn})^T$ 为网络输出值向量。

极限学习机可以零误差逼近训练样本,即
$$\sum_{i=1}^{M} \| \boldsymbol{o}_{j} - \boldsymbol{t}_{j} \|$$
。因此,存在 $\boldsymbol{\beta}_{i}$, $\boldsymbol{\omega}_{i}$ 和 b_{i} 使得:
$$\sum_{i=1}^{M} \boldsymbol{\beta}_{i}g(\boldsymbol{\omega}_{i}x_{i} + b_{i}) = y_{j}, j = 1, 2, \cdots, N$$
(13)

式(13)可表示为:

$$H\beta = Y \tag{14}$$

式中:H 为极限学习机输出矩阵。

H 为一常数矩阵,极限学习机的学习过程等价于求解式(14)最小范数的最小二乘解 $\hat{\beta}^{[7]}$,计算式为: $\beta = H^+ Y$ (15)

式中: H^+ 为H的摩尔-彭罗斯(MP)广义逆矩阵。

2.3 统计模型与混沌优化 ELM 组合模型

极限学习机适合于非线性函数拟合,学习速度和泛化性能均优于传统的神经网络模型,可应用于回归、 拟合等问题的解决,但极限学习机只是一种智能算法,并未把大坝位移观测数据的混沌特性纳入考察范围。 极限学习机一定程度上脱离了坝工实际问题。因此,为提高模型的泛化能力和预测精度,利用位移观测数据 的混沌特性重构相空间,优化极限学习机的输入量,构建出混沌优化极限学习机模型。

大坝位移除了受库水压力(水位)影响外,还受到温度、时 效等因素的影响^[1]。统计模型考虑了力学和结构理论,混沌优 化极限学习机则对统计模型残差部分进行回归和拟合。建模的 具体步骤(见图 1)如下:

首先运用传统的统计模型对位移数据进行回归分析。据式 (11)对不同的坝型选取恰当的 n,然后逐步回归计算,获得回 归模型拟合值、预测值δ和模型残差值。

针对残差部分,结合嵌入参数将一维位移观测时间序列重 构为多维相空间,建立混沌优化极限学习机预报模型。根据前 面混沌分析部分的内容,可以选定合适的延迟时间 τ 和嵌入维 m,同时相点X(t)到X(t + T)的演化状态一般可由X(t)及其 之前的已知相点决定,可以建立如下函数关系:

 $X(t + T) = f_e(x(t), x(t - \tau), \dots, x(t - (m - 1)\tau))$ (16) 式中: f_e 为包括线性、混沌等成分的全局动力特性函数^[5],这里 利用极限学习机进行自学习,从而对该映射 f_e 进行表达;极限学 习机的输入为 ($x(t), x(t - \tau), \dots, x(t - (m - 1)\tau)$), X(t + T)为极限学习机的输出。





混沌优化 ELM 创建并训练后,仿真测试得到预测值 X(t + T),与统计模型预测值 δ 合并后得到组合模型预测值。

最后,通过计算测试集中预测值与真实值的误差(平均绝对误差 δ_{MAE} ,均方误差 δ_{MSE} 、归一化均方误差 δ_{MMSE} 和相关系数 R),可以评价 ELM 的泛化性能。另一方面,对比 ELM 与 BP 神经网络的运行时间,可对其 运算速度进行评价。

3 应用实例

某碾压混凝土重力坝最大坝高 113.0 m,坝顶全长 308.5 m,坝顶高程 179.0 m。以该大坝 5#坝段某测点水 平位移 X 方向(向左岸为正,向右岸为负)的实测数据(含 1 000个采样点)为分析对象(见图 2),建立起大坝变形监 测统计模型与混沌优化 ELM 组合模型。将该序列分为 训练集 F(序号 1~950)和测试集 T(序号 951~1 000)。 该序列为自动化监测数据,其完整性和规律性优于人工 监测数据,但其含有一定的环境噪声。





3.1 组合模型

3.1.1 统计模型 重力坝水压因子选取三次式,根据式(11),对训练集 *F*进行逐步回归计算,得到统计模型系数分别为 $a_0 = 0.74573$, $a_2 = 0.000069004$, $b_{11} = 0.23526$, $b_{21} = -0.25899$, $b_{12} = 0.026455$, $b_{22} = -0.040646$, $c_1 = 0.033723$, $c_2 = -0.050069$,其余系数为0。拟合值、残差和预测值分别见图3和4。可见,统计回归模型拟合精度较高但预测效果不佳,因此采用混沌优化 ELM 对残差部分进行拟合和预测。



图 3 训练集 F 的实测、统计模型拟合及残差曲线



3.1.2 混沌优化 ELM 关于残差部分,根据重构参数选取部分的理论,通过自相关法计算得到延迟时间 $\tau = 1$,由 Cao 算法得出 m = 6(见图 5),由于有限长大坝监测序列 不易判断 E_1 是缓慢变化还是渐趋稳定,因此补充了一个判断数值 E_2 ,对于确定序列,总存在一些 m 值使得 $E_2 \neq 1$ 。据此重构相空间。利用 Rosenstein 算法计算出该段数 据的最大 Lyapunov 指数 $\lambda_1 = 0.008 \ 2 > 0$,可知该位移数 据的最关 Lyapunov 指数 $\lambda_1 = 0.008 \ 2 > 0$,可知该位移数 据的我差具有混沌特性,同时允许最大预测时间为 $\lambda_1^{-1} \approx 121$ 。测试集 T 的数据长度为 50,在允许最大预测时间之内。

3.2 预测结果及性能评价

由组合模型的建模步骤,在 MATLAB 中极限学习机 开始仿真测试, $(x(t), x(t-1), \dots, x(t-5))$ 为极限学 习机的输入, X(t+T) 为极限学习机的输出,计算过程中 合理设置隐含层神经元个数。则统计模型与混沌优化 ELM 模型的预测值 $Y(t+T) = X(t+T) + \delta(t+T)$ (见图 6)。

为了对模型进行性能评价,选用 δ_{MAE} , δ_{MSE} , δ_{NMSE} 和 R 等4种性能定量评价指标。

$$\delta_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^{n} |y_i - \hat{y}_i|$$
(17)

$$\delta_{\rm MSE} = \frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2$$
(18)



图 4 测试集 T 的统计模型预测值

Fig. 4 Statistic model predictive values of test set T



图 5 Cao 算法确定嵌入维 m

Fig. 5 Embedding dimension *m* determined by Cao algorithm





Fig. 6 Measured values, mixed model predictive values and residual curves of test set *T*

$$\delta_{\text{NMSE}} = \frac{1}{n\sigma^2} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2$$
(19)

$$R = \sqrt{\sum_{i=1}^{n} (\hat{y}_i - \frac{1}{n} \sum_{i=1}^{n} y_i)^2 / \sum_{i=1}^{n} [y_i - \frac{1}{n} \sum_{i=1}^{n} y_i]^2}$$
(20)

式中: y_i 为实测值; \hat{y}_i 为预测值; n 为预测数据长度; σ^2 为测试集 T 的数据方差。

将统计模型-混沌优化 ELM 与统计模型、统计模型-混沌优化 BP 神经网络进行比较,从表 1 不难看出, 统计模型与混沌优化 ELM 的预测精度明显优于传统统计模型,极限学习机的泛化性能优于 BP 神经网络, 同时由计算过程可知极限学习机运行速度要快很多(0.019 27 s<2.337 s)。

Tab. 1 Comparisons of three prediction (methods) models				
评价指标	$\delta_{ m MAE}$	$\delta_{ m MSE}$	$\delta_{ m NMSE}$	R
统计模型	0.039 6	0.002 6	0.958 8	0.727 1
统计模型-混沌优化 BP 神经网络	0.0206	0.0007	0.261 5	0. 893 9
统计模型-混沌优化 ELM	0.011 9	0.000 2	0.082 5	0.982 2

表1 3种预测模型的比较

4 结 语

基于传统统计模型和大坝监测效应量混沌动力学特性的分析,构建了统计模型与混沌优化 ELM 大坝变 形预测模型。相比于同类方法,该模型具有更好的预测效果,且具有一定的抗噪能力。混沌优化 ELM 在大 坝变形监测中的应用并不广泛,通过应用实例说明 ELM 具有较优的运算速度和泛化性能,有一定的应用推 广价值。

参考文献:

- [1] 顾冲时,吴中如.大坝与坝基安全监控理论和方法及其应用[M].南京:河海大学出版社,2006.(GU Chong-shi, WU Zhong-ru. Safety monitoring of dams and dam foundations—theories & methods and their application [M]. Nanjing: Hohai University Press, 2006.(in Chinese))
- [2] 曹茂森, 邱秀梅, 夏宁. 大坝安全诊断的混沌优化神经网络模型[J]. 岩土力学, 2006, 27(8): 1344-1348. (CAO Maosen, QIU Xiu-mei, XIA Ning. A chaos-optimized neural network model for dam safety monitoring[J]. Rock and Soil Mechanics, 2006, 27(8): 1344-1348. (in Chinese))
- [3] 汪树玉, 刘国华, 杜王盖, 等. 大坝观测数据序列中的混沌现象[J]. 水利学报, 1999(7): 23-27. (WANG Shu-yu, LIU Guo-hua, DU Wang-gai, et al. Chaotic phenomenon in observation data of dam monitoring[J]. Journal of Hydraulic Engineering, 1999(7): 23-27. (in Chinese))
- [4] 包腾飞, 吴中如, 顾冲时. 基于统计模型与混沌理论的大坝安全监测混合预测模型[J]. 河海大学学报(自然科学版), 2003, 31(5): 534-538. (BAO Teng-fei, WU Zhong-ru, GU Chong-shi. Statistic model and chaos theory-based hybrid forecasting model for dam safety monitoring[J]. Journal of Hohai University(Natural Sciences), 2003, 31(5): 534-538. (in Chinese))
- [5] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70: 489-501.
- [6] 周超,殷坤龙,黄发明. 混沌序列 WA-ELM 耦合模型在滑坡位移预测中的应用[J]. 岩土力学, 2015, 36(9): 2674-2680.
 (ZHOU Chao, YIN Kun-long, HUANG Fa-ming. Application of the chaotic sequence WA-ELM coupling model in landslide displacement prediction[J]. Rock and Soil Mechanics, 2015, 36(9): 2674-2680. (in Chinese))
- [7] 高光勇, 蒋国平. 采用优化极限学习机的多变量混沌时间序列预测[J]. 物理学报, 2012, 61(4): 37-45. (GAO Guangyong, JIANG Guo-ping. Prediction of multivariable chaotic time series using optimized extreme learning machine [J]. Acta Physical Sinica, 2012, 61(4): 37-45. (in Chinese))
- [8] 杨易旻. 基于极限学习的系统辨识方法及应用研究[D]. 长沙: 湖南大学, 2013. (YANG Yi-min. Researches on extreme learning theory for system identification and applications[D]. Changsha: Hunan University, 2013. (in Chinese))
- [9] 朱创家,季昀,李同春,等.基于极限学习机的面板堆石坝施工期沉降预测模型及应用[J].水电能源科学,2014,32
 (6):69-71.(ZHU Chuang-jia, JI Yun, LI Tong-chun, et al. Settlement prediction model of CFRD during construction period based on extreme learning machine[J]. Water Resources and Power, 2014, 32(6):69-71.(in Chinese))
- [10] 徐洪钟. 大坝动力系统的安全监控非线性分析模型研究[D]. 南京: 河海大学, 2001. (XU Hong-zhong. Nonlinear analysis model for safety monitoring of large dam dynamic system[D]. Nanjing: Hohai University, 2001. (in Chinese))
- [11] 李新杰,胡铁松,郭旭宁,等. 不同时间尺度的径流时间序列混沌特性分析[J]. 水利学报, 2013, 44(5): 515-520. (LI Xin-jie, HU Tie-song, GUO Xu-ning, et al. Chaos analysis of runoff time series at different time scales[J]. Journal of Hydraulic

Engineering, 2013, 44(5): 515-520. (in Chinese))

[12] 王小川, 史峰, 郁磊. MATLAB 神经网络 43 个案例分析[M]. 北京: 北京航空航天大学出版社, 2013. (WANG Xiaochuan, SHI Feng, YU Lei. 43 Cases analysis of MATLAB neural network[M]. Beijing: Beihang University Press, 2013. (in Chinese))

A model combining with statistic model and chaos-optimized extreme learning machine for dam deformation monitoring

DAI Bo^{1,2}, HE Qi^{1,2}

(1. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China; 2. National Engineering Research Center of Water Resources Efficient Utilization and Engineering Safety, Hohai University, Nanjing 210098, China)

Abstract: Deformation is an important effect reflecting the dynamic evolution of a dam. In order to improve prediction precision of the statistic model, with the advantage of the extreme learning machine (ELM) to deal with the nonlinear problems, data mining for dam displacements residuals of the statistic model is conducted. Because ELM is short of the chaotic dynamic characteristics, in order to solve this problem, the chaotic dynamic characteristics of the statistic model are analyzed by the chaos theory, the results reveal its chaotic characteristics, and then the phase space is reconstructed, thus it can provide priori knowledge for the chaos-optimized ELM. Based on the statistic model, combined with the advantages of ELM, a combined model combining a statistic model with the chaos-optimized extreme learning machine(ELM) is developed. The combined model is reasonable, and the prediction precision is higher than the statistical model and the combined model combining the statistical model with the chaos-optimized BP neural network, which will be of application value to researchers in dam deformation monitoring.

Key words: dam displacement; dam deformation monitoring; statistic model; chaos; extreme learning machine