

DOI: 10.7652/xjtuxb201402006

采用限定记忆极限学习机的过热汽温逆建模研究

王万召, 王杰

(郑州大学电气工程学院, 450001, 郑州)

摘要: 针对常规极限学习机随着学习次数增加增益矩阵慢慢趋于零、学习算法逐渐失去修正能力而出现“数据饱和”的问题,提出了限定记忆极限学习机算法。该算法在学习过程中每增加一个新数据信息,就去掉一个旧数据信息,权值的学习只依赖于限定个数的最新数据信息,从而避免出现“数据饱和”。通过分析隐含层数据矩阵的特点,利用分块矩阵计算方法推导了限定记忆极限学习机在线学习算法。将该算法应用于参数时变的过热汽温对象逆模型的辨识,仿真实验结果表明:该算法能有效克服“数据饱和”问题,提高计算精度,是一种实用有效的过热汽温对象逆建模算法。

关键词: 单隐含层前馈神经网络;限定记忆极限学习机;数据饱和;在线逆建模;过热汽温

中图分类号: TP273 **文献标志码:** A **文章编号:** 0253-987X(2014)02-0032-05

Inverse Modeling for Superheated Steam Temperature Based on Restricted Memory Extreme Learning Machine

WANG Wanzhao, WANG Jie

(School of Electrical Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: A restricted memory extreme learning machine is proposed to improve the data saturation problem in the conventional extreme learning machine that is caused by the gain matrix gradually approaching zero as the sampled data increase and the weight values can't be modified by new sampled data. In the proposed algorithm, the neural network's weight values learning only depends on a limited number of new sample data by deleting an old data when a new data is received, and the data saturation is avoided. The characteristics of the hidden layer matrix are analyzed, and the calculation formula of block matrices is used to derive the proposed algorithm. Then the learning algorithm is applied to identify the inverse model of the superheated steam temperature plant. Simulation results show that the proposed learning algorithm overcomes the data saturation problem effectively, and improves the precision of the weight values learning.

Keywords: single-hidden layer feed forward neural network; restricted memory extreme learning machine; data saturation; inverse modeling online; superheated steam temperature

自适应逆控制是由美国斯坦福大学 Widrow 教授于 1986 年首次提出来的,现已成为解决参数时变、非线性的热工对象控制问题的一个研究热点^[1-3]。如何利用生产现场采样数据来实时在线辨识被控热工对象的逆模型,成为实现自适应逆控制

方案的关键问题^[4-7]。

针对神经网络传统梯度学习算法存在的训练速度慢,容易陷入局部极小点等问题,Huang 等提出了一种新学习算法——极限学习机(Extreme Learning Machine, ELM)^[8-9],凭借其卓越的学习能力,受到

收稿日期: 2013-07-18。 作者简介: 王万召(1972—),男,博士生;王杰(通信作者),男,教授,博士生导师。 基金项目: 国家自然科学基金资助项目(60974005)。

网络出版时间: 2014-01-15

网络出版地址: <http://www.cnki.net/kcms/doi/10.7652/xjtuxb201402006.html>

国内外研究者的广泛重视,并已在模式识别和函数估计领域得到了广泛应用^[10-12]。近年来一些学者又提出了极限学习机在线学习算法^[13-14],但随着学习时间的推移,这些在线算法的增益矩阵将渐渐趋于零,导致在线学习算法慢慢失去权值修正能力,并最终出现“数据饱和”现象。

本文提出一种新的极限学习机在线学习算法,该算法中神经网络权值仅依赖于有限个新采样数据,每增加一个新采样数据,就去掉一个旧采样数据,学习数据长度始终保持不变,因此该算法可称为限定记忆法在线学习算法。随后,将该算法应用于参数时变的过热汽温对象的逆模型建模过程,仿真结果表明,该算法能有效地克服“数据饱和”现象,提高学习精度,是一种先进的过热汽温对象在线逆建模方法。

1 极限学习机批量式学习算法

典型的具有 N 个隐含层节点的单隐层前馈神经网络的输出可以表示为

$$f_N(\mathbf{x}) = \sum_{i=1}^N \beta_i G(\mathbf{a}_i, b_i, \mathbf{x}) \quad \mathbf{x} \in R^n, \quad \mathbf{a}_i \in R^n \quad (1)$$

式中: $\mathbf{a}_i$ 为输入层对隐含层第 i 个神经元的连接权值; b_i 为隐含层第 i 个神经元的阈值; β_i 为隐含层第 i 个神经元到输出的连接权值; $G(\mathbf{a}_i, b_i, \mathbf{x})$ 为隐含层的激活函数; $\mathbf{x}$ 为输入向量。

假设从 k 时刻到 $k+L-1$ 时刻的时间段内具有 L 个样本的训练集输入矩阵 $\mathbf{X}_0$ 和输出向量 $\mathbf{Y}_0$ 分别为

$$\mathbf{X}_0 = [\mathbf{x}_k \ \mathbf{x}_{k+1} \ \cdots \ \mathbf{x}_{k+L-1}] \quad (2)$$

$$\mathbf{Y}_0 = [y_k \ y_{k+1} \ \cdots \ y_{k+L-1}] \quad (3)$$

当激活函数 $G(\mathbf{a}_i, b_i, \mathbf{x})$ 无限可微时, SFLN 的参数不需要全部进行调整, $\mathbf{a}_i$ 和 b_i 可以在学习前随机选择,且在训练过程中保持恒定,而隐含层与输出的连接权值 $\boldsymbol{\beta}^{(0)}$ 可通过求解以下方程的最小二乘解^[12]得到

$$\min_{\boldsymbol{\beta}^{(0)}} \|\mathbf{H}_0 \boldsymbol{\beta}^{(0)} - \mathbf{Y}_0\| \quad (4)$$

式中: $\mathbf{H}_0$ 是包含 k 至 $k+L-1$ 时刻间共 L 个采样数据的隐含层数据矩阵

$$\mathbf{H}_0 = \begin{bmatrix} G(\mathbf{a}_1, b_1, \mathbf{x}_k) & \cdots & G(\mathbf{a}_N, b_N, \mathbf{x}_k) \\ \vdots & & \vdots \\ G(\mathbf{a}_1, b_1, \mathbf{x}_{k+L-1}) & \cdots & G(\mathbf{a}_N, b_N, \mathbf{x}_{k+L-1}) \end{bmatrix} =$$

$$\begin{bmatrix} \mathbf{h}^T(k) \\ \vdots \\ \mathbf{h}^T(k+L-1) \end{bmatrix} \quad (5)$$

其解为

$$\boldsymbol{\beta}^{(0)} = \mathbf{K}_0^{-1} \mathbf{H}_0^T \mathbf{Y}_0 \quad (6)$$

其中

$$\mathbf{K}_0 = \mathbf{H}_0^T \mathbf{H}_0 \quad (7)$$

显然,批量式学习算法的特点是一次注入所有的训练样本进行学习,因此只能离线应用,如果学习样本是在线采集的话,就必须使用在线学习算法。

2 极限学习机限定记忆学习算法

2.1 增长记忆极限学习机算法

假设随着采样过程的进行,增加一组新的采样数据 $(\mathbf{x}_{k+L}, y_{k+L})$,这时包含 k 至 $k+L$ 时刻共 $L+1$ 个采样数据的隐含层数据矩阵为

$$\mathbf{H}_1 = \begin{bmatrix} G(\mathbf{a}_1, b_1, \mathbf{x}_k) & \cdots & G(\mathbf{a}_N, b_N, \mathbf{x}_k) \\ \vdots & & \vdots \\ G(\mathbf{a}_1, b_1, \mathbf{x}_{k+L-1}) & \cdots & G(\mathbf{a}_N, b_N, \mathbf{x}_{k+L-1}) \\ G(\mathbf{a}_1, b_1, \mathbf{x}_{k+L}) & \cdots & G(\mathbf{a}_N, b_N, \mathbf{x}_{k+L}) \end{bmatrix} = \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{h}^T(k+L) \end{bmatrix} \quad (8)$$

采用批量学习算法,则包含 k 至 $k+L$ 时刻共 $L+1$ 个采样数据信息的隐含层与输出连接权值向量 $\boldsymbol{\beta}^{(1)}$ 可通过求解以下方程的最小化获得

$$\min_{\boldsymbol{\beta}^{(1)}} \|\mathbf{H}_1 \boldsymbol{\beta}^{(1)} - \mathbf{Y}_1\| \quad (9)$$

$$\text{式中} \quad \mathbf{Y}_1 = [y_k \ y_{k+1} \ \cdots \ y_{k+L-1} \ y_{k+L}] \quad (10)$$

则有

$$\boldsymbol{\beta}^{(1)} = \mathbf{K}_1^{-1} \mathbf{H}_1^T \mathbf{Y}_1 \quad (11)$$

其中

$$\begin{aligned} \mathbf{K}_1 &= \mathbf{H}_1^T \mathbf{H}_1 = [\mathbf{H}_0^T \ \mathbf{h}(k+L)] \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{h}^T(k+L) \end{bmatrix} = \\ &= \mathbf{H}_0^T \mathbf{H}_0 + \mathbf{h}(k+L) \mathbf{h}^T(k+L) = \\ &= \mathbf{K}_0 + \mathbf{h}(k+L) \mathbf{h}^T(k+L) \end{aligned} \quad (12)$$

可得

$$\begin{aligned} \boldsymbol{\beta}^{(1)} &= \mathbf{K}_1^{-1} \mathbf{H}_1^T \mathbf{Y}_1 = \mathbf{K}_1^{-1} \sum_{i=k}^{k+L} \mathbf{h}(i) y(i) = \\ &= \mathbf{K}_1^{-1} [\mathbf{H}_0^T \mathbf{Y}_0 + \mathbf{h}(k+L) y(k+L)] = \\ &= \mathbf{K}_1^{-1} [\mathbf{K}_0 \boldsymbol{\beta}^{(0)} + \mathbf{h}(k+L) y(k+L)] = \\ &= \mathbf{K}_1^{-1} \{ [\mathbf{K}_1 - \mathbf{h}(k+L) \mathbf{h}^T(k+L)] \boldsymbol{\beta}^{(0)} + \\ &\quad \mathbf{h}(k+L) y(k+L) \} = \\ &= \boldsymbol{\beta}^{(0)} + \mathbf{K}_1^{-1} \mathbf{h}(k+L) [y(k+L) - \mathbf{h}^T(k+L) \boldsymbol{\beta}^{(0)}] \end{aligned} \quad (13)$$

由式(12),利用矩阵反演公式得

$$\begin{aligned} \mathbf{K}_1^{-1} &= \mathbf{K}_0^{-1} - \mathbf{K}_0^{-1} \mathbf{h}(k+L) [\mathbf{I} + \mathbf{h}^T(k+L) \cdot \\ &\quad \mathbf{K}_0^{-1} \mathbf{h}(k+L)]^{-1} \mathbf{h}^T(k+L) \mathbf{K}_0^{-1} = \\ &\quad \left[\mathbf{I} - \frac{\mathbf{K}_0^{-1} \mathbf{h}(k+L) \mathbf{h}^T(k+L)}{1 + \mathbf{h}^T(k+L) \mathbf{K}_0^{-1} \mathbf{h}(k+L)} \right] \mathbf{K}_0^{-1} \quad (14) \end{aligned}$$

由式(13)、(14),基于第一步的辨识结果 $\beta^{(0)}$ 、 $\mathbf{K}_0^{-1}$ 加上第 $k+L+1$ 时刻的采样信息 $(\mathbf{x}_{k+L}, \mathbf{y}_{k+L})$, 可以通过递推运算,获得包含 k 至 $k+L$ 时刻共 $k+L+1$ 个采样数据信息的隐含层与输出连接权值向量 $\beta^{(1)}$ 。这样能够充分利用以前的辨识结果,避免重复计算^[15]。但是,如果仅采用上述增加新采样数据信息的方法进行迭代运算,就会带来“数据饱和”问题。

由式(7)、(12)可知, $\mathbf{K}_0$ 、 $\mathbf{K}_1$ 均是正定的,则 $\mathbf{K}_0^{-1}$ 、 $\mathbf{K}_1^{-1}$ 也是正定的,由式(14)可知

$$\mathbf{K}_1^{-1} < \mathbf{K}_0^{-1} \quad (15)$$

可见,增量记忆极限学习机中的增益矩阵是随着采样时间 k 的增加而递减的正定阵。令 $\mathbf{K}^{-1}$ 表示增量记忆极限学习机的增益矩阵,则当 $k \rightarrow \infty$ 时, $\mathbf{K}^{-1} \rightarrow \mathbf{0}$ 。当增益矩阵 $\mathbf{K}^{-1}$ 趋近于零矩阵,由式(13)可知修正项不再起作用,递推算去失去修正能力,并最终出现“数据饱和”问题。

2.2 限定记忆极限学习机算法

产生“数据饱和”的原因是学习算法对新、老采样数据给予相同的信任度,这样随着从新采样数据中获得的信息量相对下降,学习算法就会渐渐失去修正能力。克服“数据饱和”最有效的方法是确保权值 β 始终只依赖于有限个最新采样数据所提供的信息,每增加一个新采样数据,就去掉一个最旧的采样数据,学习数据长度始终保持不变。因此,每当增加一组新的 $k+L$ 时刻采样数据 $(\mathbf{x}_{k+L}, \mathbf{y}_{k+L})$,为保持辨识信息数据长度 L 不变,就需要去掉 k 时刻信息 $(\mathbf{x}_k, \mathbf{y}_k)$ 的影响。仅考虑包含 $k+1$ 至 $k+L$ 时刻共 L 个采样数据信息,与此对应的隐含层数据矩阵为

$$\mathbf{H}_2 = \begin{bmatrix} G(\mathbf{a}_1, \mathbf{b}_1, \mathbf{x}_{k+1}) & \cdots & G(\mathbf{a}_N, \mathbf{b}_N, \mathbf{x}_{k+1}) \\ \vdots & & \vdots \\ G(\mathbf{a}_1, \mathbf{b}_1, \mathbf{x}_{k+L-1}) & \cdots & G(\mathbf{a}_N, \mathbf{b}_N, \mathbf{x}_{k+L-1}) \\ G(\mathbf{a}_1, \mathbf{b}_1, \mathbf{x}_{k+L}) & \cdots & G(\mathbf{a}_N, \mathbf{b}_N, \mathbf{x}_{k+L}) \end{bmatrix} \quad (16)$$

采用批量学习算法,则包含 $k+1$ 至 $k+L$ 时刻共 L 个采样数据信息的隐含层与输出连接权值向量

$$\beta^{(2)} = \mathbf{K}_2^{-1} \mathbf{H}_2^T \mathbf{Y}_2 \quad (17)$$

式中

$$\mathbf{K}_2 = \mathbf{K}_1 - \mathbf{h}(k) \mathbf{h}^T(k) \quad (18)$$

$$\mathbf{Y}_2 = [\mathbf{y}_{k+1} \cdots \mathbf{y}_{k+L-1} \mathbf{y}_{k+L}] \quad (19)$$

$$\beta^{(2)} = \mathbf{K}_2^{-1} \mathbf{H}_2^T \mathbf{Y}_2 = \mathbf{K}_2^{-1} \sum_{i=k+1}^{k+L} \mathbf{h}(i) \mathbf{y}(i) =$$

$$\mathbf{K}_2^{-1} [\mathbf{K}_1 \beta^{(1)} - \mathbf{h}(k) \mathbf{y}(k)] =$$

$$\mathbf{K}_2^{-1} \{ [\mathbf{K}_2 + \mathbf{h}(k) \mathbf{h}^T(k)] \beta^{(1)} - \mathbf{h}(k) \mathbf{y}(k) \} =$$

$$\beta^{(1)} + \mathbf{K}_2^{-1} \mathbf{h}(k) \mathbf{h}^T(k) \beta^{(1)} - \mathbf{K}_2^{-1} \mathbf{h}(k) \mathbf{y}(k) =$$

$$\beta^{(1)} - \mathbf{K}_2^{-1} \mathbf{h}(k) [\mathbf{y}(k) - \mathbf{h}^T(k) \beta^{(1)}] \quad (20)$$

由式(18),利用矩阵反演公式可得

$$\mathbf{K}_2^{-1} =$$

$$\mathbf{K}_1^{-1} + \mathbf{K}_1^{-1} \mathbf{h}(k) [\mathbf{I} - \mathbf{h}^T(k) \mathbf{K}_1^{-1} \mathbf{h}(k)]^{-1} \mathbf{h}^T(k) \mathbf{K}_1^{-1} =$$

$$\left[\mathbf{I} + \frac{\mathbf{K}_1^{-1} \mathbf{h}(k) \mathbf{h}^T(k)}{1 - \mathbf{h}^T(k) \mathbf{K}_1^{-1} \mathbf{h}(k)} \right] \mathbf{K}_1^{-1} \quad (21)$$

由式(21),基于第二步的辨识结果 $\beta^{(1)}$ 、 $\mathbf{K}_1^{-1}$ 消去第 k 时刻的采样信息 $(\mathbf{x}_k, \mathbf{y}_k)$, 可以通过递推运算获得包含 $k+1$ 至 $k+L$ 时刻共 L 个采样数据信息的隐含层与输出连接权值向量 $\beta^{(2)}$ 。

根据以上的推导过程,限定记忆极限学习机算法主要包括以下几个具体学习步骤。

步骤1 确定隐含层神经元的数目,随机选择输入层与隐含层的连接权值 $\mathbf{a}_i$ 和隐含层神经元的阈值 $\mathbf{b}_i$ 。

步骤2 选择一个无限可微的函数作为隐含层神经元的激活函数 $G(\mathbf{a}_i, \mathbf{b}_i, \mathbf{x})$, 并计算隐含层输出矩阵。

步骤3 根据一批采样数据,利用极限学习机批量算法,预先求得 $\beta^{(0)}$ 、 $\mathbf{K}_0^{-1}$,为了减少计算量,数据长度 L 不宜取太大。

步骤4 每获得一组新的采样数据 $(\mathbf{a}_{k+L}, \mathbf{y}_{k+L})$,先利用式(13)、(14)计算 $\beta^{(1)}$ 、 $\mathbf{K}_1^{-1}$,增加新数据的信息;再利用式(20)、(21)计算 $\beta^{(2)}$ 、 $\mathbf{K}_2^{-1}$,去掉老数据的信息。

不断迭代,始终保持着固定不变的数据长度,可以防止出现“数据饱和”现象,最终获得隐含层与输出层连接权值的理想值。

3 仿真实验及分析

为比较验证本文所提限定记忆极限学习机算法与文献[15]中的数据长度随采样进行不断增长的增量记忆极限学习机算法的性能,将这两种算法同时应用于参数时变的过热汽温对象逆模型的学习过程。文献[2,16]给出了某台超临界压力锅炉在不同负荷时的传递函数,如表1所示。

过热汽温对象的输入 u 为减温水流量的变化,单位为 kg/s,输出 y 为锅炉过热汽温的变化,单位

表 1 过热汽温的动态特性(传递函数)

负荷	传递函数	
	导前区	惯性区
50%	$-\frac{3.067}{(1+25s)^2}$	$\frac{1.119}{(1+42.1s)^7}$
75%	$-\frac{1.657}{(1+20s)^2}$	$\frac{1.202}{(1+27.1s)^7}$
100%	$-\frac{0.815}{(1+18s)^2}$	$\frac{1.276}{(1+18.4s)^6}$

为℃。取逆动力学模型的输入向量为

$$\boldsymbol{x}(k)=[u(k-1),y(k-1),y(k),y(k+1)] \tag{22}$$

为了检验所提算法对于时变对象逆模型的学习能力,这里以输入函数

$$u(k)=0.4\sin(\pi k/300)+\sin(\pi k/250)+0.6\sin(\pi k/200) \tag{23}$$

在大负荷变化范围内驱动过热汽温对象,对象在 0~500 s 位于 100% 负荷,500~1 000 s 位于 75% 负荷,1 000~1 500 s 位于 50% 负荷。采样时间取 1 s,获得 1 500 组采样数据 $[u(k),y(k)]$ 。利用这些采样数据,根据式(22)获得辨识逆模型所需的输入向量。采用单隐含层前馈神经网络来逼近逆模型,网络结构为 4-5-1,隐含层的激活函数选用 Sigmoid 函数,输出层为纯线性函数,网络的输入为 $x(k)$,输出为 $u(k)$ 。在仿真中比较本文所提出的限定记忆 ELM 学习算法与文献[15]所提到的增长记忆 ELM 学习算法,初始值 $\boldsymbol{\beta}^{(0)}$ 、 $\boldsymbol{K}_0^{-1}$ 使用批量极限学习机离线事先求得,增长记忆 ELM 学习算法的仿真结果分别如图 1、图 2 所示,限定记忆 ELM 学习算法的仿真结果分别如图 3、图 4 所示。

图 1、图 3 上面子图中的虚线表示过热汽温对象的输入 $u(k)$ (逆模型学习网络的期望输出),实线表示逆模型学习网络的实际输出 $u_m(k)$;下面的子图表示逆模型实际输出与期望输出的误差曲线。图 2、图 4 中曲线表示神经网络隐含层与输出连接权值向量 $\boldsymbol{\beta}$ 的 5 个分量(隐含层有 5 个节点)的学习过程。

为比较精度,本文采用式(24)的性能指标来衡量所建逆模型的精度

$$R_{MSE}=(\sum_{k=1}^l e^2(k)/l)^{1/2}= (\sum_{k=1}^l [u(k)-u_m(k)]^2/l)^{1/2} \tag{24}$$

式中: l 为总的采样点数; $u(k)$ 为过热汽温对象的实际输入; $u_m(k)$ 为过热汽温对象逆模型的输出; $e(k)$ 为过热汽温对象逆模型的输出与对象实际输入的差值,即逆模型建模误差。




图 1 增长记忆在线极限学习机的仿真结果
($R_{MSE}=0.0010$)




图 2 增长记忆在线极限学习机权值学习过程




图 3 限定记忆在线极限学习机的仿真结果
($R_{MSE}=4.176\times10^{-6}$)

由图 1、图 3 比较可以看出,相比于增长记忆学习算法,限定记忆学习算法的学习精度有了很大的提高。由图 2、图 4 比较可以看出,当时间 $t>500$ s 以后,常规增长记忆学习算法就丧失了权值修正能力,继续递推下去也不会改善学习结果,即出现了“数据饱和”现象。而限定记忆极限学习机随着时间的增长权值会不断改善,说明它具有克服“数据饱




图4 限定记忆在线极限学习机权值学习过程

和”的能力,这也说明了为何限定记忆极限学习机具有更高的学习精度。

4 结 论

本文提出的限定记忆极限学习机在线学习算法能有效克服“数据饱和”现象,可以在递推计算中不断改善权值学习结果。尤其对于时变对象逆建模来说,可以保证权值学习,及时跟踪对象特性参数的变化,相对于常规的增量记忆学习算法具有更高的学习精度。利用本文所提出的学习算法对过热汽温对象在线逆建模,结果显示了该方法的有效性和优越性,是一种实用的参数时变对象在线逆建模技术。

参考文献:

- [1] 韩璞,张海琳,张丽静. 神经网络自适应逆控制的仿真研究[J]. 华北电力大学学报, 2001, 28(3): 26-30.
HAN Pu, ZHANG Hailin, ZHANG Lijing. Simulation study of neural network based adaptive inverse control[J]. Journal of North China Electric Power University, 2001, 28(3): 26-30.
- [2] 党映农,韩崇昭. 基于 Volterra 基函数网络的自适应逆控制方法[J]. 西安交通大学学报, 2000, 34(9): 8-12.
DANG Yingnong, HAN Chongzhao. Adaptive inverse control based on Volterra polynomial basis function neural networks[J]. Journal of Xi'an Jiaotong University, 2000, 34(9): 8-12.
- [3] 王广军,邓良才,陈红. 锅炉汽温对象逆动力学过程模糊辨识[J]. 中国电机工程学报, 2007, 27(20): 76-80.
WANG Guangjun, DENG Liangcai, CHEN Hong. Fuzzy identification on inverse dynamic process of steam temperature object of boiler[J]. Proceedings of the Chinese Society for Electrical Engineering, 2007, 27(20): 76-80.
- [4] GELFAND S B, GMEIER J V. The stability of variable step-size LMS algorithms[J]. IEEE Transactions on Signal Processing, 1999, 47(12): 3277-3288.
- [5] 罗小东,贾振红,王强. 一种新的变步长 LMS 自适应滤波算法[J]. 电子学报, 2006, 34(6): 1123-1126.
LUO Xiaodong, JIA Zhenhong, WANG Qiang. A new variable step size LMS adaptive filtering algorithm[J]. Acta Electronica Sinica, 2006, 34(6): 1123-1126.
- [6] 刘亚秋,马广富,石忠. NARX 网络在自适应逆控制动态系统辨识中的应用[J]. 哈尔滨工业大学学报, 2005, 37(2): 173-176.
LIU Yaqiu, MA Guangfu, SHI Zhong. NARX network for dynamic system identification in adaptive inverse control[J]. Journal of Harbin Institute of Technology, 2005, 37(2): 173-176.
- [7] 钟伟民,皮道映,孙优贤. 基于支持向量机的直接逆模型辨识[J]. 控制理论与应用, 2005, 22(2): 307-310.
ZHONG Weimin, PI Daoying, SUN Youxian. Support vector machine based direct inverse-model identification[J]. Control Theory and Application, 2005, 22(2): 307-310.
- [8] HUANG Guangbin, SIEW C K. Extreme learning machine: RBF network case[C]//Proceedings of the 8th International Conference on Control, Automation, Robotics and Vision. Piscataway, NJ, USA: IEEE, 2004: 1029-1036.
- [9] HUANG Guangbin, SIEW C K. Extreme learning machine with randomly assigned RBF kernels[J]. International Journal of Information Technology, 2005, 11(1): 16-25.
- [10] HANDOKO S D, KEONG K C, SOON O Y, et al. Extreme learning machine for predicting HLA-peptide binding[C]//Proceedings of the Advances in Neural Networks. Berlin, Germany: Springer-Verlag, 2006: 716-721.
- [11] LIANG Nanying, SARATCHANDRAN P, HUANG Guangbin. Classification of mental tasks from EEG signals using extreme learning machine[J]. International Journal of Neural Systems, 2006, 16(1): 29-38.
- [12] HUANG Guangbin, ZHU Qinyu, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1): 489-501.
- [13] LIANG Nanying, HUANG Guangbin, SARATCHANDRAN P, et al. A fast and accurate online sequential learning algorithms for feedforward networks[J]. IEEE Transactions on Neural Networks, 2006, 17(6): 1411-1423.

- [14] HUANG Guangbin, SARATCHANDRAN P, SUN-DARAAJAN N. An efficient sequential learning algorithm for growing and pruning RBF (GAP-RBF) networks [J]. IEEE Transactions on System, Man, and Cybernetics, 2004, 34(6): 2284-2292.
- [15] FENG Guorui, HUANG Guangbin, LIN Qingping, et al. Error minimized extreme learning machine with growth of hidden nodes and incremental learning [J]. IEEE Transactions on Neural Networks, 2009, 20(8): 1352-1357.

- [16] 范永胜, 徐治皋, 陈来久. 基于动态特性机理分析的锅炉过热汽温自适应模糊控制系统研究 [J]. 中国电机工程学报, 1997, 7(1): 23-28.
- FAN Yongsheng, XU Zhigao, CHEN Laijiu. Study of adaptive fuzzy control of boiler superheated steam temperature based on dynamic mechanism analysis [J]. Proceedings of the Chinese Society for Electrical Engineering, 1997, 7(1): 23-28.

(编辑 武红江)

(上接第 13 页)

- [9] SHOKRI R, THEODORAKOPOUS G, BOUDEC J-Y L, et al. Quantifying location privacy [C]// Proceedings of the 32nd IEEE Symposium on Security and Privacy. Piscataway, NJ, USA: IEEE, 2011: 247-262.
- [10] CHEN Xihui, PANG Jun. Measuring query privacy in location-based services [C]// Proceedings of the Second ACM Conference on Data and Application Security and Privacy. New York, USA: ACM, 2012: 49-60.
- [11] SHIN H, ATLURI V, VAIDYA J. A profile anonymization model for privacy in a personalized location base service environment [C]// Proceedings of the 9th International Conference on Mobile Data Management. Piscataway, NJ, USA: IEEE, 2008: 73-80.

- [12] BRINKHOFF T. A framework for generating network-based moving objects [J]. GeoInformatica, 2002, 6(2): 153-180.

(编辑 武红江)

(上接第 24 页)

- [8] 张洪超, 张磊, 黄华. 基于跨时空域相似邻接图的视频分割方法 [J]. 图学学报, 2012, 33(2): 83-88.
- ZHANG Hongchao, ZHANG Lei, HUANG Hua. Video cutout method based on spatio-temporal similarity neighboring graph [J]. Journal of Graphics, 2012, 33(2): 83-88.
- [9] BERGE C. Graph and hypergraph [M]. Amsterdam, Holland: North-Holland Publishing Company, 1973.
- [10] COMANICIU D, MEER P. Mean shift: a robust approach toward feature space analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(5): 603-619.
- [11] SHI J, MALIK J. Normalized cuts and image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(8): 888-905.
- [12] 汪艮波, 郭延文, 夏天辰, 等. 样本驱动的半自动图像集前背景分割 [J]. 计算机辅助设计与图形学学报, 2013, 25(6): 794-801.
- WANG Linbo, GUO Yanwen, XIA Tianchen, et al. Example-driven semi-automatic image collection segmentation [J]. Journal of Computer-Aided Design & Computer Graphics, 2013, 25(6): 794-801.

[本刊相关文献链接]

- 郝红侠, 刘芳, 焦李成, 等. 采用结构自适应窗的非局部均值图像去噪算法. 2013, 47(12): 71-76. [doi: 10. 7652/xjtuxb201312013]
- 刘光辉, 任庆昌, 孟月波, 等. 自适应先验马尔可夫随机场模型的图像分割算法. 2013, 47(10): 62-67. [doi: 10. 7652/xjtuxb201310011]
- 侯兴松, 张兰, 肖琳. 合成孔径雷达图像的贝叶斯压缩感知重构算法. 2013, 47(8): 74-79. [doi: 10. 7652/xjtuxb201308013]
- 穆为磊, 高建民, 王昭, 等. 考虑人眼视觉特性的射线检测数字图像质量评价方法. 2013, 47(7): 91-95. [doi: 10. 7652/xjtuxb201307017]
- 赵军, 赵继, 张雷. 焊缝结构光图像处理与特征提取方法. 2013, 47(1): 114-119. [doi: 10. 7652/xjtuxb201301022]
- 王梦琪, 曹良志, 吴宏春, 等. 三维任意几何光子成像系统的散射修正及图像重建方法. 2012, 46(11): 86-90. [doi: 10. 7652/xjtuxb201211017]
- 李玉花, 齐春. 利用位置字典对的人脸图像超分辨率方法. 2012, 46(6): 7-11. [doi: 10. 7652/xjtuxb201206002]
- 史金钢, 齐春. 一种双约束稀疏模型图像修复算法. 2012, 46(2): 6-10. [doi: 10. 7652/xjtuxb201202002]

(编辑 刘杨)