

一种基于支持向量机的图像数字水印算法

李春花 卢正鼎

(华中科技大学计算机学院 , 武汉 430074)

摘要 为了使数字水印综合性能更好, 根据图像邻域像素之间具有很强的相关性这一特点, 提出了一种基于支持向量机的图像水印算法。该算法将支持向量机的思想用于数字水印, 并取得了较好的效果。由于支持向量机在有限训练样本的情况下具有很好的学习和泛化能力, 因此, 可以首先利用回归型支持向量机较好地建立图像邻域像素之间的关系模型, 然后, 通过调整模型的输出值与中心像素值之间的大小关系来嵌入或提取水印。实验表明, 用该技术嵌入水印后的图像不仅具有很好的图像感知质量和较强的鲁棒性, 对图像增强、JPEG 压缩、噪声、几何剪切等抵抗强, 而且安全性好、实用性较强。

关键词 数字水印 鲁棒性 支持向量机 支持向量回归

中图法分类号: TP309 文献标识码: A 文章编号: 1006-8961(2006)09-1322-05

An Image Digital Watermarking Based on Support Vector Machine

LI Chun-hua , LU Zheng-ding

(College of Computer Science and Technology , Huazhong University of Science and Technology , Wuhan 430074)

Abstract Considering the coherence among neighborhood pixels in an image, a kind of spatial domain watermarking scheme based on support vector machine is proposed. It uses support vector machine to embed the watermark and gains satisfied results. Due to the good learning ability and generalization ability of SVM with limited training samples, it can learn the relationship between the selected pixel and its neighboring pixels well with support vector regression. Then, a bit of the watermark is embedded or extracted by adjusting the value between the selected pixel (i. e. desired output) and the actual output of the trained SVR. Experimental results show that the proposed algorithm has good image perceptual quality and high watermark robustness to common image processing operation and the JPEG compression, which also possesses good security and practicability.

Keywords digital watermarking , robustness , support vector machine (SVM) , support vector regression (SVR)

1 引言

数字水印作为数字媒体版权保护和数据安全维护的有效办法, 近年来在国际上引起了人们极大的兴趣与注意。水印算法归结起来主要有空域法和变换域法两大类, 其中空域算法中最有代表性的是 Schyndel 提出的 LSB (least significant bits) 法^[1] 和 Patchwork 算法^[2]。LSB 方法是首先通过把一个密钥输入到一个 m -序列 (maximum-length random

sequence) 发生器来产生水印信号, 然后此 m -序列被重新排列成 2 维水印信号, 并按像素点逐一插入到原始图像像素值的最低位, 以保证水印的不可见性, 而对这种水印的检测则是通过计算 m -序列和水印图像行的相关函数来判断的。该算法的优点是简单易行、有较大的信息隐藏量, 但该算法实质上相当于在图像中添加一些高频噪声, 由于其对图像的几何变形和信号处理, 如滤波、压缩、加噪声等抵抗能力差, 鲁棒性不好, 因此不能应用于实际的图像安全维护。Patchwork 算法是通过改变图像数据的统计特

基金项目: 中小型企业创新基金项目 (04C26214201284)

收稿日期: 2005-01-04 改回日期: 2005-09-13

第一作者简介: 李春花 (1971 ~) , 女, 1997 年于华中科技大学获工学硕士学位, 现为华中科技大学计算机学院讲师, 在职博士研究生。主要研究方向为数字图像处理、信息安全等。E-mail: li.chunhua@163.com

性来将信息嵌入到像素的亮度值中。该算法是先通过随机选取图像的 N 对像素点来进行水印嵌入,这些随机选取的两个像素点的差值呈以 0 为中心的高斯分布,然后通过增加其中一个点的亮度值,同时相应降低另一个点的亮度值来改变分布的中心,并且使得整个图像的平均亮度保持不变,最后采用统计的方法来对水印进行检测。为了抵抗诸如无损压缩以及滤波处理对水印的攻击,该算法先将像素点扩展成小块的像素区域(patch),并增加一个 patch 中的所有像素点的亮度值,同时减少对应另外一个 patch 中所有像素点的亮度值。这种算法对抵御无损压缩编码(JPEG)和剪裁攻击非常有效,但由于嵌入的水印信息少,且对仿射变换敏感,所以对多拷贝联合攻击的抵抗力比较脆弱。

变换域算法中最典型的是 Cox 等人提出的一种 DCT(discrete cosine transform)域内基于扩频通信原理的水印算法^[3],该算法将扩频通信的理论应用到数字水印系统中,被认为是数字水印技术飞跃性的发展,该算法在数字水印算法中占有重要的地位,后来的许多算法都是在此基础上改进的。其实现方法是:首先以密钥为种子产生伪随机高斯分布序列,该密钥一般由作者的标识码和图像的哈希值组成;然后对图像做 DCT 变换,并用伪随机高斯序列来调制(叠加)该图像除直流(DC)分量外的 N 个最大的 DCT 系数。实践表明,该算法具有较强的鲁棒性、安全性、透明性等。

由于小波变换(discrete wavelet transform, DWT)具有良好的主频分解特性,并且嵌入式零树小波编码在新一代的压缩标准(JPEG2000, MPEG4/7 等)中被采用,也迎合国际压缩标准,所以近年来出现了许多基于小波变换的水印算法,如 Hsu 和 Wu 首先提出了基于多分辨率分析的水印算法^[4],该算法首先对水印和原始图像同时进行多分辨率分析,然后将水印在多分辨率下的分析系数嵌入到具有相应分辨率的图像块中,这样,即使含水印的图像质量因受到了攻击的影响而丢失了部分信息,则由于较低分辨率的水印仍然保存在较低分辨率的图像块中,因此水印具有较高的稳健性。

一般来说,空域水印算法简单、嵌入信息量大,而变换域水印虽一般较复杂,但水印的鲁棒性较好。为了更好地满足水印的不可感知性或鲁棒性,或者同时满足水印的这两大特性,近年来一些学者利用数学分析或机器学习的方法来最优化水印嵌入的位

置、容量和强度。如 Lou 等使用神经网络,结合人眼视觉系统(human visual system, HVS)模型^[5]来对图像不同区域的亮度、频率、纹理和平均信息熵 4 个特征值进行训练,以确定图像不同区域的最佳水印嵌入强度和嵌入容量。Davis 等在使用小波变换进行水印嵌入的基础上,再使用神经网络技术来产生自适应于图像内容的最大水印嵌入强度^[6]。Shieh 等利用遗传算法来同时优化由鲁棒性和不可感知性组成的目标函数^[7]。Pereira 等把水印作为一个线性规划问题,在一系列像素失真的线性约束下,期望将水印的强度最大化^[8]。张军等提出了一种用于图像认证的基于神经网络的水印技术^[9]。虽然这些方法取得了一定的效果,但都存在一定的局限性,如神经网络易产生过学习现象,且隐层节点数往往需要根据经验来确定,尚缺乏一种统一的数学理论。为此,笔者设想,如能利用图像邻域像素之间具有很强的相关性这一内在特征来寻找一种能描述这种关系的最佳模型,那么据此在图像中嵌入水印,并提取水印,也许能大大提高水印的性能。

基于上述思想,本文将支持向量机的思想用于数字水印,提出一种基于支持向量机的空域水印技术,有关这方面的研究国内外鲜见报道。大量的实验结果表明,本文提供的技术能在保持较高图像质量的前提下,对多种图像处理都具有很好的鲁棒性。

2 支持向量机的优势分析

支持向量机是一种基于统计学习理论的新的通用学习方法,由于其具有较为完备的理论基础和较好的学习性能,因此它既可用于分类,也可用于回归问题。

对于式(1)所示的拟合问题,

$$(y_1, x_1) (y_2, x_2) \dots (y_l, x_l) \quad x \in \mathbf{R}^n, y \in \mathbf{R} \quad (1)$$

为了得到输入 x_i 和输出 y_i 之间的关系,传统的回归学习方法(如神经网络)是在经验风险最小化原则,即最小化

$$R_{\text{emp}}[f] = \frac{1}{l} \sum_{i=1}^l \mathcal{L}(f(x_i) - y_i) \quad (2)$$

的条件下求最佳的回归函数 $y = f(x)$,其中 $\mathcal{L}(f(x_i) - y_i)$ 表示用回归函数 $f(x)$ 来对 y 进行预测所造成的损失。

而统计学习理论指出,在有限样本的情况下,经验风险最小化并不能保证实际风险最小,其典型的情况是神经网络的过学习现象。由于支持向量回归是

基于结构风险最小化原理的学习方法,它可同时最小化经验风险和模型复杂度,因此能保证在有限样本的情况下模型的最佳推广能力和输出函数的平滑性。

非线性问题的支持向量回归可表示如下^[10]:

$$\begin{aligned}
 f(x) &= \sum_{i=1}^l (\alpha_i^* - \alpha_i) K(x_i, x) + b \\
 &= \sum_{i=1}^l (\alpha_i^* - \alpha_i) \varphi(x_i) \varphi(x) + b \\
 &= w \varphi(x) + b \quad (3)
 \end{aligned}$$

其中 α_i^* 和 $\alpha_i (i=1, 2, \dots, l)$ 为不小于零的 Lagrange 乘子,与不等于零的项对应的 x_i 才对函数拟合起作用,这类样本称之为支持向量。 $K(x_i, x) = \varphi(x_i) \cdot \varphi(x)$ 表示将非线性问题映射为某高维特征空间中的线性问题所采用的点积核函数,权值向量 $w = \sum_{i=1}^l (\alpha_i^* - \alpha_i) \varphi(x_i)$, b 表示偏差。

求解系数 α_i^* , α_i 和 b 的过程即为最小化式(4)的过程,

$$\frac{1}{2} \|w\|^2 + C \cdot R_{emp}[f] \quad (4)$$

式(4)中,第1项定义了模型复杂度,第2项表示经验损失函数; $C > 0$ 是一个自定义的惩罚因子,它表示对超出误差的样本的惩罚程度。当损失函数采用不敏感函数 ε 时,

$$L(f(x_i) - y_i) = |y_i - f(x)|_{\varepsilon} = \max\{0, |y_i - f(x)| - \varepsilon\} \quad (5)$$

在引入一对松弛变量 ξ 和 ξ^* 后,则式(4)可表示为

$$\min \pi(w, \xi, \xi^*) = \frac{1}{2} \|w\|^2 + C \frac{1}{l} \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (6)$$

$$\text{s. t. } \begin{cases} (w \cdot x_i) + b - y_i \leq \varepsilon + \xi_i \\ y_i - (w \cdot x_i) - b \leq \varepsilon + \xi_i^* \\ \xi_i > 0, \xi_i^* > 0, \varepsilon > 0 \end{cases} \quad (7)$$

引入 Lagrange 乘子 α_i 和 α_i^* 后,根据 Wolfe 对偶原理,式(7)可等价于如下的优化问题:

$$\begin{aligned}
 \max W(\alpha, \alpha^*) &= -\varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l (\alpha_i^* - \alpha_i) y_i - \\
 &\quad \frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) K(x_i, x_j) \quad (8)
 \end{aligned}$$

$$\text{s. t. } \sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0, \alpha_i \in [0, \frac{C}{l}], \alpha_i^* \in [0, \frac{C}{l}] \quad (9)$$

通过求解上式得到最优的 α 和 α^* 后,再利用任

意训练数据,由 $y_i = w \varphi(x_i) + b$ 就可求得参数 b ,然后就可由式(3)来对新输入的数据进行预测。

3 水印的嵌入与提取策略

由上面的分析可知,基于结构风险最小化的支持向量机,在有限样本的情况下,不仅能够保证模型的最佳推广能力和输出函数的平滑性,而且具有很好的学习和泛化能力,由此可见,只需要在拥有大量数据的载体图像中选择一定数量的像素点及其邻域作为训练样本,就可以通过支持向量回归方法(support vector regression, SVR)较好地建立它们的关系模型,然后就可通过调整模型的实际输出值与中心像素值之间的大小关系来嵌入水印信息。提取水印时,这种算法不需要原始图像和原始水印,只需要比较它们的关系即可。

设载体图像为 I , 水印图案为 W 。 $I = \{I_{i,j} | 1 \leq i \leq M, 1 \leq j \leq N\}$, $I_{i,j}$ 代表 (i, j) 位置像素点的灰度值。 $W = \{W_{i,j} | 1 \leq i \leq P, 1 \leq j \leq Q\}$, $W_{i,j} \in \{0, 1\}$ 。 水印的嵌入与提取算法步骤如下:

(1) 选取 SVR 的训练样本。根据密钥 k_1 随机选取图像 I 中的若干个互不相同的像素点 (i, j) 及其 3×3 邻域 $U_{i,j}$ 来形成学习样本集 S , 即

$$\begin{aligned}
 S = \{ & I_{i-1,j-1}, I_{i-1,j}, I_{i-1,j+1}, I_{i,j-1}, I_{i,j}, I_{i,j+1}, \\ & I_{i+1,j-1}, I_{i+1,j}, I_{i+1,j+1}, I_{i,j} \} = \{U_{i,j}, I_{i,j}\} \quad (10)
 \end{aligned}$$

其中,中心像素点灰度值 $I_{i,j}$ 为支持向量机的目标输出值, $U_{i,j}$ 为支持向量机的输入。

(2) 建立邻域像素关系的 SVR 模型。选择合适的 SVR 核函数和学习参数,并运用支持向量回归方法建立中心像素与其邻域像素之间的关系模型。

(3) 嵌入水印。若根据密钥 k_2 从图像 I 中选取 $P \times Q$ 个 3×3 邻域互不重叠的像素点 (i, j) 及其邻域 $U_{i,j}$, 则嵌入水印的数据集 X 为

$$\begin{aligned}
 X = \{ & I_{i-1,j-1}, I_{i-1,j}, I_{i-1,j+1}, I_{i,j-1}, I_{i,j}, I_{i,j+1}, \\ & I_{i+1,j-1}, I_{i+1,j}, I_{i+1,j+1} \} = \{U_{i,j}\} \quad (11)
 \end{aligned}$$

根据式(3)计算出数据集 X 的中心像素 $I_{i,j}$ 的模型的实际输出值 $y_{i,j}$ 。

若与位置 (i, j) 对应的水印系数 $W_{i,j}$ 为 1, 则调整 $I_{i,j}$, 使之大于 $y_{i,j}$, 否则, 调整 $I_{i,j}$, 使之小于 $y_{i,j}$, 即

$$I_{i,j} = \begin{cases} \max(I_{i,j}, y_{i,j} + \theta) & \text{if } W_{i,j} = 1 \\ \min(I_{i,j}, y_{i,j} - \theta) & \text{else} \end{cases} \quad (12)$$

其中 θ 为水印嵌入强度因子,其值越大,水印越鲁棒,但视觉质量越差。 θ 的取值可针对不同的图像,

结合人眼视觉特征确定^[5]。根据 SVR 学习结果发现,在合适的参数训练下,对于纹理不太复杂的图像,SVR 模型的实际输出值与目标值之差的绝对值平均值(mean absolute error, MAE)均可限制在 3 个像素范围内(见表 1),对于纹理细密的图像(如 Baboon),MAE 值虽超过 10pixels,但这主要是由于图像自身的特点引起的。因此说,SVM(support vector machine)回归方法能够很好地刻画图像中像素点与其邻域像素点之间的映射关系,即使 θ 取值在 10pixels 左右,嵌入水印位信息的像素灰度值的修改量也较小,故而,此技术不仅能够保证较好的可感知性,而且能够提高水印的鲁棒性。后面的实验结果也证明了这一点。

表 1 模型输出值与目标值之差绝对值的平均值

Tab.1 MAE between actual output and desired output

算法	不同图像的 MAE			
	Lena	Airplane	Pepper	Baboon
本文方法	2.728 5	2.932 5	2.677 5	11.041 5
文献 9]方法	3.448 6	3.472 7	3.876 5	/

(4)提取水印。先由密钥 k_2 从待测试图像 \tilde{I} 中重新选取嵌入水印信息后的像素值 $\tilde{I}_{i,j}$ 及其邻域 $\tilde{U}_{i,j}$,再根据式(3)计算出邻域 $\tilde{U}_{i,j}$ 的中心像素点的模型输出值 $\tilde{y}_{i,j}$, $\tilde{y}_{i,j} = f(\tilde{U}_{i,j})$,然后按照与嵌入水印时的逆过程即可恢复出水印系数 $\tilde{W}_{i,j}$,即

$$\tilde{W}_{i,j} = \begin{cases} 1 & \text{if } \tilde{I}_{i,j} > \tilde{y}_{i,j} \\ 0 & \text{else} \end{cases} \quad (13)$$

由于提取水印时只需要密钥 k_2 和 SVR 模型参数,而无需原始图像和原始水印,所以它是一种盲水印技术。

本文采用以下提取水印与原水印之间的位错误率(bit error ratio, BER)BER 来度量水印的鲁棒性:

$$BER = \sum_i \sum_j |W_{i,j} - \tilde{W}_{i,j}| / (P \times Q) \quad (14)$$

4 实验结果及分析

为验证本文算法的效果,对多幅图像进行了实验,均获得了满意的结果。本文主要讨论对 4 幅典型图像的实验结果,它们是:512 × 512 大小的 256 级灰度图像 Lena、Pepper、Airplane 和 Baboon,原始水印是一幅 32 × 32 大小的二值图像。整个实验分以下几步进行:

(1)邻域像素关系的学习。本实验中,SVR 的

学习参数^[11]如下:核函数 K 采用径向基函数(radius based function, RBF),基函数宽度 σ 取 10,最小允许误差 ε 取 0.008,惩罚因子 C 取 1。

表 1 列出了在上述参数下对 4 幅典型的图像进行回归学习的结果,同时将它与文献[9]方法的学习结果进行了对比。

由表 1 可看出,对于纹理复杂程度不同的图像,SVM 均能较好地逼近像素点与其邻域点之间的关系,其平均误差比用神经网络训练的结果都要小。这说明支持向量回归方法比神经网络方法更适合于描述图像邻域像素之间的关系。

(2)水印的嵌入。为增强水印的鲁棒性,实验中,水印嵌入强度因子 θ 取 12,并按照式(12)方法进行水印的嵌入。图 1 给出了嵌入水印前后的 Lena 图像和水印图像,表 2 给出了嵌入水印后各图像的峰值信噪比(peak signal noise ratio, PSNR)。由表 2 可以看出,即使嵌入强度达到 12pixels,嵌入水印后图像的峰值信噪比均在 45dB 以上,其值高于文献[9]中 $\theta = 1$ 情况下的 1dB 左右。由此可说明,本文技术在提高水印鲁棒性的同时,其嵌入水印的不可感知性也非常好。



(a) 原始图像 (b) 水印图像 (c) 嵌入水印后的图像

图 1 水印嵌入前后的 Lena 图像及原始水印图像

Fig. 1 Original image and watermarked image

表 2 嵌入水印后图像的峰值信噪比值

Tab.2 PSNR between original image and watermarked image

算法	不同图像的 PSNR(dB)			
	Lena	Airplane	Pepper	Baboon
本文方法	49.223 1	47.911 2	48.403 8	45.959 8
文献 9]方法	47.675 8	47.320 6	47.458 4	/

(3)鲁棒性和不可感知性的测试。表 3 列出了采用本文方法对嵌入水印后的 Lena 图像进行多种常规图像处理的实验结果,同时,也给出了采用文献[9]方法的部分结果。其中,攻击软件主要采用 PhotoShop7.0,实验平台为 Matlab6.5。

表 3 对 Lena 图像的攻击实验比较结果

Tab. 3 Experimental results on "Lena"

图像处理	本文方法		文献 [9] 方法	
	BER	PSNR (dB)	BER	PSNR (dB)
高斯随机分布 (5%)	0.089	27.526	0.118	23.436
均匀分布 (5%)	0.026	29.489	0.060	26.683
椒盐噪声 (方差 0.04)	0.090	18.933	/	/
两次锐化	0	28.391	0	25.156
亮度增加 50%	0	13.645	0.003	9.425
对比度增加 50%	0.027	16.503	0.032	13.121
高斯低通滤波 (3 × 3)	0	41.645	0.003	37.534
中值滤波	0.214	41.064	/	/
质量因子 90	0.009	41.916	0.021	38.114
质量因子 75	0.088	39.273	0.126	36.723
质量因子 50	0.255	36.939	0.325	31.892
剪切 1/4	0.079	11.341	0.107	9.425
切变	0	41.228	0	38.183
高斯模糊 (r = 1)	0.133	32.495	/	/

从表 3 可以看出, 本文算法对一系列图像处理操作都具有较好的鲁棒性和图像感知质量, 其结果明显优于文献 [9] 的算法。对于图像增强处理, 除中值滤波外, 本文算法均具有很强的抵抗力, 并能够完全正确地提取水印; 对于附加噪声, 本文算法所提取的水印视觉效果都较好, 且位错误率也较小; 对于切变和四分之一剪切, 本文算法具有很好的抵抗能力; 对于高斯模糊处理, 本文算法也具有较好的抵抗力。

此外, 对于 JPEG 有损压缩, 本文算法也具有较好的鲁棒性, 但位错误率下降明显。这是由于经过压缩过程的量化处理后, 高质量的压缩对原始图像的邻域像素关系的破坏较小, 而低质量的压缩对邻域像素关系的破坏较大的缘故, 因此, 随着压缩质量的降低, 所提取水印的位错误率明显上升。即使这样, 当质量因子降到 50% 时, 水印的不可感知性仍较好。嵌入水印后图像的峰值信噪比 PSNR 仍达到 36.939 2dB, 这说明本文技术不仅具有较好的抵抗 JPEG 压缩的能力, 而且图像感知质量较好。

5 结 论

本文用支持向量回归的方法来进行数字图像水印的嵌入与提取, 取得了较好的效果, 其主要表现在: 首先, 它较好地解决了空域水印技术鲁棒性普遍较差的问题, 同时具有水印嵌入算法简单、高效、易于实现等优点; 其次, 水印系统的安全性高, 盗版者在不知道

建模方法和模型参数以及随机选择的水印嵌入位置的情况下, 很难检测和恢复水印; 另外, 通过密钥调整水印嵌入的位置, 还可以对图像中某些特定内容进行保护, 尤其是, 提取水印时, 不需要原始载体图像和水印图像, 这样就大大扩展了其应用范围。

大量的实验结果表明, 本文方法在较好保持图像感知质量的前提下, 由于对多种图像处理不仅具有很好的鲁棒性, 而且比传统的神经网络学习方法更有效, 因此具有较高的实用价值和很好的应用前景。此外, 本文更多的意义在于为水印技术的研究提供了一种新思路。

参考文献 (References)

- van Schyndel R G, Tirkel A Z, Osborne C F. A digital watermark [A]. In: Proceedings of the IEEE International Conference on Image Processing [C], Austin, Texas, USA, 1994, 2: 86 ~ 90.
- Nikolaidis N, Pitas I. Copyright protection of images using robust digital signatures [A]. In: Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing [C], Atlanta, Georgia, USA, 1996, 4: 2168 ~ 2171.
- Cox I J, Kilian J, Leighton F T, et al. Secure spread spectrum watermarking for multimedia [J]. IEEE Transactions on Image Processing, 1997, 6(12): 1673 ~ 1687.
- Hsu Chion-ting, Wu Ja-ling. Multiresolution watermarking for digital image [J]. IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing, 1998, 45(8): 1097 ~ 1101.
- Lou Der-chyuan, Liu Jiang-lung, Hu Ming-chiang. Adaptive digital watermarking using neural network technique [A]. In: Proceedings of the IEEE International Carnahan Conference on Security Technology [C], Taipei, Taiwan, 2003: 325 ~ 332.
- Davis K J, Najarian K. Maximizing strength of digital watermarks using neural networks [A]. In: Proceedings of the International Joint Conference on Neural Networks [C], Washington DC, USA, 2001, 4: 2893 ~ 2898.
- Shieh C S, Huang H C, Wang F H, et al. Genetic watermarking based on transform-domain techniques [J]. Pattern Recognition, 2004, 37(3): 555 ~ 565.
- Pereira S, Voloshynskiy S, Pun T. Optimal transform domains watermark embedding via linear programming [J]. Signal Processing, 2001, 81(6): 1251 ~ 1260.
- Zhang Jun, Wang Neng-chao. Neural network based watermarking for image authentication [J]. Journal of Computer-Aided Design & Computer Graphics, 2003, 15(3): 307 ~ 312. [张军, 王能超. 用于图像认证的基于神经网络的水印技术 [J]. 计算机辅助设计与图形学学报, 2003, 15(3): 307 ~ 312.]
- Vapnik V N. ZHANG Xue-gong, Translate. The natural of statistical learning theory [M]. New York: Springer-Verlag, 2000. [[美] Vapnik V N 著, 张学工译. 统计学习理论的本质 [M]. 北京: 清华大学出版社, 2000.]
- Li Chun-hua, Lu Zheng-ding, Zhou Ke. SVR-Parameters Selection for Image watermarking [A]. In: Proceedings of 17th IEEE International Conference on Tools with Artificial Intelligence [C], Hongkong, China, 2005: 466 ~ 470.