

文章编号:1001-9081(2008)08-2036-04

基于离散 Hopfield 网络的测井曲线交叉线识别算法

刁 川, 余艳梅, 王蜀颖, 罗代升

(四川大学电子信息学院, 成都 610064)

(yanmei_yu@163.com)

摘要: 在石油测井工程图纸的曲线矢量化过程中, 由于背景网格与曲线、曲线与曲线存在大量交织, 致使曲线跟踪中断, 需要人工判断走向, 难于实现自动跟踪。提出一种基于离散型 Hopfield 神经网络(DHNN)的测井曲线交叉线识别方法。这个方法先设置 8 个标准方向样本, 对网络进行训练。在曲线跟踪的过程中, 当遇到交叉点, 就进入交叉线识别, 通过训练好的网络进行分支匹配, 再结合宽度匹配正确判断曲线走向。理论研究和实验分析表明, 采用该方法提高了交叉线识别的正确率, 抗干扰效果较好。

关键词: 离散 Hopfield 神经网络; 测井曲线; 曲线跟踪; 交叉线识别

中图分类号: TP391.4 文献标志码:A

Intersection recognition of well logging curve based on discrete hopfield neural network

DIAO Chuan, YU Yan-mei, WANG Shu-ying, LUO Dai-sheng

(College of Electronics and Information, Sichuan University, Chengdu Sichuan 610064, China)

Abstract: In the process of vector quantization of well logging curve, background grids and other forms of curve interference discontinue curve tracking and hardly to achieve automatic tracking, so manual direction judgment is needed. This article proposes a method for well log curves intersection recognition using Discrete Hopfield Neural Network (DHNN). This method presets 8 standard direction samples for network training. During curve tracking, entering recognition status if comes across intersection, the algorithm makes accurate prediction of curve direction through branch match of well-trained Hopfield network, in combination with width match. Theoretical analysis and experiment demonstrates that this method improves the precision of intersection recognition and has a good result of anti-interference.

Key words: Discrete Hopfield Neural Network (DHNN); well logging curve; curve tracking; intersection recognition

0 引言

早期的石油测井信息是以曲线形式绘制在工程图纸上的, 而测井曲线的矢量化和测井数据的数字化有利于信息的存储、管理、分析和共享, 因此其重要性日益凸显。过去的测井图纸曲线数字化, 采用手笔跟踪或者半机械手笔跟踪曲线的方式, 费力且效率不高。近年来, 已经有一些图纸曲线自动化的方法被提出, 处理步骤一般包括图像预处理、去除栅格、提取曲线、曲线自动跟踪以及曲线矢量化。在图纸上多种曲线相互交叉、曲线与网格相交的情况下, 如何正确识别与判断曲线走向, 是实现曲线自动跟踪的难点。传统的线跟踪是基于链码进行的^[1,2], 然而这种自动识别系统在遇到交叉线时, 通常只能通过人工交互式地来指导线的跟踪。孙贞寿等人提出一种基于连续型 Hopfield 神经网络的曲线识别算法^[3], 但连续型网络处理复杂、计算量大。左航提出一种自动曲线跟踪方法实现石油测井曲线自动数字化^[4], 但这种方法在多种曲线交织情况下容易出现错误跟踪。最近, 王玲璐等人提出一种基于 BP 网络的测井曲线自动提取方法^[5,6], 但 BP 算法存在麻痹现象和锯齿现象, 容易出现训练速度很慢的情况。

为此, 本文提出一种利用离散型 Hopfield 神经网络(模板

DHNN)进行交叉线识别的方法, 用于石油测井曲线图纸矢量化。在这个算法中, 设计了 8 个 8×8 的标准样本, 用于联想记忆的权值训练。当目标曲线跟踪到交叉点时, 就以该点为中心在原图上提取一个 31×31 的子图像, 对这个子图像进行细化, 在细化图中进行检测, 得到相应的交叉线进出的四条分支, 用 8×8 的模板对四条分支分别取特征线段数字矢量化, 再投影到已训练好的 Hopfield 网络中进行识别。将图像细化、去枝得到单像素宽的连通线, 这样既保留了分支特征, 又能避免网络太大, 收敛起来速度慢。将四个分支图像中的连通线用于训练好的 Hopfield 神经网络识别, 当网络的状态不再变化时, 此时的状态就是系统识别出来的结果。由于同一曲线上的分支的具有相似的方向、宽度特征, 将稳态一致的曲线分支两两匹配, 这样就可以把交叉线段分离开来, 完成目标曲线正确跟踪。

1 离散 Hopfield 神经网络

1982 年, 美国物理学家 J. J. Hopfield 提出了一种新的相互连接型神经网络模型, 可用于解决联想记忆问题。Hopfield 网络分离散型和连续型。对于连续型 Hopfield 神经网络, 网络的输入、输出均为模拟量, 采用模拟电子线路的结构实现,

收稿日期:2008-03-06;修回日期:2008-05-04。 基金项目:四川省科技攻关资助项目(05GG021-026-03)。

作者简介: 刁川(1984-), 男, 贵州赤水人, 硕士研究生, 主要研究方向: 智能系统与设计; 余艳梅(1975-), 女, 四川德阳人, 讲师, 博士研究生, 主要研究方向: 图像处理、模式识别; 王蜀颖(1982-), 女, 四川成都人, 硕士研究生, 主要研究方向: 图像处理、模式识别; 罗代升(1947-), 男, 四川成都人, 教授, 博士生导师, 主要研究方向: 图像处理、模式识别、信号处理、通信与系统工程。

更适用于优化问题的求解,但是由于采用模拟量和能量函数中积分项的引入,运算量和复杂度较大。而针对测井曲线交叉线识别要完成的分支匹配,属于联想记忆类问题,更适合采用离散 Hopfield 神经网络(DHNN),并且经过二值化处理的测井图像的像素对应了离散的状态值。对于 DHNN,节点的状态仅取二值 0 或 1 表示。首先引入一个能量函数,或称 Lyapunov 函数,即:

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j \neq i}^n w_{ij} x_i x_j + \sum_{i=1}^n \theta_i x_i \quad (1)$$

其能量在网络运行过程中不断地降低,网络能量极小状态即为网络的一个稳定平衡状态,又称为吸引子。能量极小点的存在为信息的分布式存储记忆、优化计算提供了基础。将记忆的样本信息存储于不同的能量极小点,当输入某一模式时,网络就能联想记忆与其相关的存储样本,实现联想记忆。

离散 Hopfield 网络是一个多输入、多输出、带阈值的二态非线性动力系统,能量函数在网络运行过程中不断降低、最后趋于稳定平衡状态,其拓扑结构如图 1 所示:

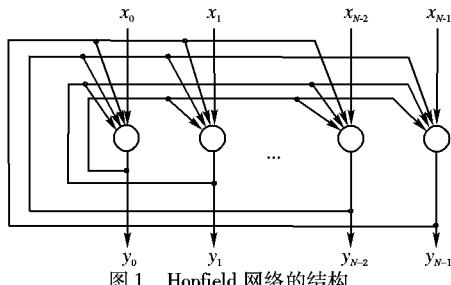


图 1 Hopfield 网络的结构

这是一种单层全反馈网络,共有 n 个神经元。其特点是任一神经元的输出 x_i 均通过连接权 w_{ij} 反馈至所有的神经元 x_j 作为输入,其目的是让任一神经元的输出都能受所有神经元输出的控制,从而使各神经元的输出能相互制约。每个神经元均有一个阈值 θ_i ,以反映对输入噪声的控制。DHNN 网的转移函数通常采用符号函数:

$$x_j = \text{sgn}(net_j) = \begin{cases} 1, & net_j \geq 0; j = 1, 2, \dots, n \\ -1, & net_j < 0; j = 1, 2, \dots, n \end{cases} \quad (2)$$

式中净输入为:

$$net_j = \sum_{i=1}^n (w_{ij} x_i - \theta_i), j = 1, 2, \dots, n \quad (3)$$

对于 DHNN,一般有 $w_{ii} = 0, w_{ij} = w_{ji}$ 。

当 $X(t + \Delta t) = X(t), \Delta t > 0$, 反馈网络稳定,各神经元的状态不再改变,此时的稳定状态就是网络的输出。

2 测井曲线交叉线识别算法介绍

本算法采用了单层全反馈的 Hopfield 网络结构,如图 1 所示。利用标准样本对网络进行训练,网络的学习规则采用了移动兴奋门限法,求得网络的权矩阵 w ,从而使该网络完成自联想记忆功能。

本算法将解决两个关键的问题:

1) 由于是工程图纸,几乎没有走势完全相同的曲线,标准样本如何获取。

2) 在计算权值矩阵 w 时,若需要学习记忆的模式数目较多,如何解决可能发生的“权值移动”和“交叉干扰”。

2.1 标准样本的获取

Hopfield 神经网络用于记忆联想,是受其记忆容量和样

本差异制约的。记忆的标准样本少,且样本之间差异较大,联想的结果就比较正确。对于由 N 个神经元构成的 DHNN,能够达到稳定的最大样本数目 k , R. J. McEliece 采用概率和统计的计算方法求得:

$$k \leq \frac{N}{2 \ln N} \quad (4)$$

因此,对于 8×8 的模板,利用式(4)可计算出容纳的标准样本数不能超过 8 个。根据经验结合工程图纸中曲线 y 坐标单向变化的特点,设定模板如图 2。

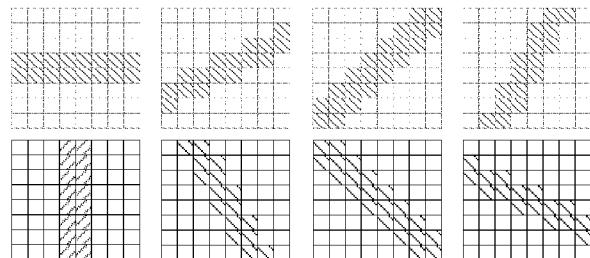


图 2 8 个标准样本

将图 2 中的标准样本在程序中矢量化为矩阵:

int Pattern[8][64] =

$$\left\{ \begin{array}{l} \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}, \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 & 0 \\ 0 & 1 & 1 & 1 & 1 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \\ \dots, \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \end{array} \right\}$$

稳定点的个数越多,网络的联想和识别的能力就越强。但是,随之而来的问题是,稳定点数目的增加可能会引起吸引域的减小,从而使联想功能减弱。稳定点空间分布得越均匀,吸引域就越大,那么,网络的容错能力和自适应能力就越强^[12]。图 2 中的 8 个标准样本,分别表征了沿逆时针方向与水平方向夹角呈 $0^\circ, 30^\circ, 45^\circ, 60^\circ, 90^\circ, 120^\circ, 135^\circ, 150^\circ$ 的交叉线,作为稳定点分布较均匀,基本上涵盖了曲线交叉线的走向,可作为联想记忆的模式,用于构造权值矩阵 w 。对于各样本吸引子,存在相应吸引域,可以将放入 DHNN 网络识别的 8×8 分支图像正确联想到标准样本。

2.2 求权值矩阵 w

网络的权值(包括阈值)决定了吸引子的分布,设计吸引子的核心是如何设计一组合适的权值。当网络规模 n 一定时,记忆的模式越多,联想时出错的可能性越大。提高网络存储容量有 2 个途径:改进网络拓扑结构和改进网络权值的设计方法。这里,采用移动兴奋门限法对 Hebb 学习规则进

行修改,改进了网络权值。

1) Hebb 学习规则。

最常用的权值设计方法是 Hebb 学习规则:设有 n 个神经元相互连接,每个神经元的激活状态 x_i 只能取 0 或 1,分别表示抑制和兴奋,学习过程中 w_{ij} 的调整原则是:若 i 和 j 两个神经元同时处于兴奋状态,那么它们之间的连接应该加强。具体操作采用外积和法:对多个模式的学习,给定一组向量 $\mathbf{M} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_m\}$, 外积规则 $W = \sum_{k=1}^m (\mathbf{X}_k \mathbf{X}_k^T - I)$, 其中 I 是 $n \times n$ 单位阵,且 $w_{ii} = 0$ 。

2) 移动兴奋门限法。

首先计算模式样本 $\{x^1, x^2, \dots, x^p\}$ 的均值:

$$\bar{x} = \frac{1}{pN} \sum_{k=1}^p \sum_{i=1}^n x_i^k$$

Hebb 规则可修改为:

$$w_{ij} = \frac{1}{N} \sum_{k=1}^p (x_i^k - \bar{x})(x_j^k - \bar{x}) ; i \neq j$$

$$w_{ii} = 0; i = 1, 2, \dots, n$$

用这个公式对模式进行记忆,相当于用原 Hebb 规则学习之后,在进行回忆时改变节点门限,而节点门限的改变量与训练模式集有关。使用这种方法可以较大地提高存储容量。本文采用这种方法训练权值,连接权值 w 是零主对角元素的对称矩阵,网络按串行异步方式更新,则网络必收敛于状态空间中某一个稳定状态。

2.3 交叉点搜索与子图像获取

在识别前,需要对图像进行预处理。预处理的关键就在于交叉点位置的确定。本文对于交叉点的定义:从某一点出发,除开本身进入的通路以外,有两个以上的通路,即为分支。而这些通路的交汇点,称为交叉点。按照这个定义,曲线与网格相交或同其他曲线相交,都是分支。

基于细化的思想,可以判断是否已找到交叉点,具体做法是:将整幅图像细化,处理得到曲线的骨架。按照八邻域算法,定义 3×3 窗口 Q ,如图 3 所示,对图像骨架进行扫描,扫描顺序从上到下,从左到右。

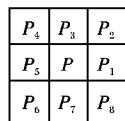


图 3 P 点八邻域

$$Q = \{P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8\}$$

$f(Q)$ 代表 Q 中 $P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8$ 值为“1”的点(黑点)的个数,则可分以下情况:

- 1) 末端点,当 $f(Q) = 1$ 时;
- 2) 内部点,当 $f(Q) = 2$ 时;
- 3) 交叉点,当 $f(Q) \geq 3$ 时。

通过检测细化图中相邻黑点个数就可以确定曲线是否到达了交叉点位置。

鉴于这种思路是细化整条曲线和背景,假如工程图纸较大,运算复杂度增加,花费的时间就会较长。为了克服这个问题,在不细化整条曲线的基础上如何得到交叉点及其周围点的信息也是本文的一个重点。具体算法如下:在一步一步进行微观跟踪时,因为曲线是连续地渐变的,所以曲线的宽度也

是连续地渐变的。如果突然遇到被搜索线段的当前宽度($nCurrentWidth$),与之前曲线的平均宽度($nAverWidth$)差值的绝对值变化超过一定门限(这里,定义该门限为 $nWidthThreshold$)那么很显然曲线到达了一个分支点,其判断公式:

$$|nAverWidth - nCurrentWidth| > nWidthThreshold \quad (5)$$

在找到宽度突变点后(图 5),该突变点还不是真正的交叉点,只是一个进入交叉点的接口。以该点为中心,获取一个 31×31 的子图像,然后对这个子图像进行细化,如图 5 所示,再通过八邻域算法寻找出两个细化交叉点。分别以两个细化交叉点 1、2 为起始点搜索具有单一连通区的 $4 \times 8 \times 8$ 的分支图像,这 4 个分支图像将依次被放入 Hopfield 网络进行识别。

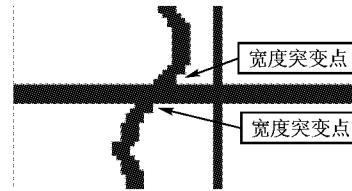


图 4 宽度检查法寻找分支点

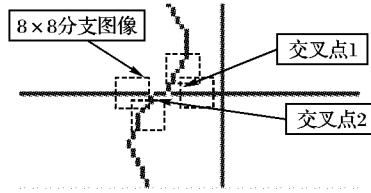


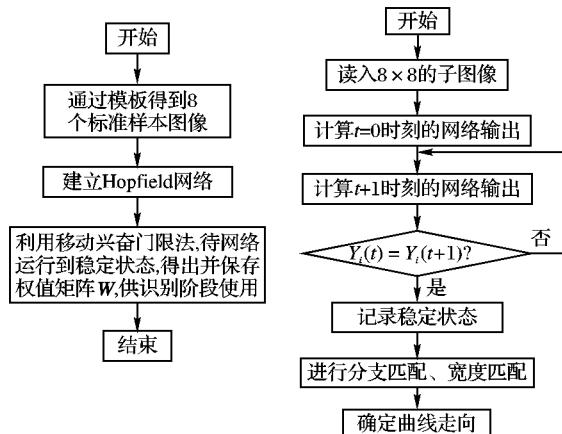
图 5 细化寻找交叉点和分支

2.4 待识别样本的初始化及迭代运算

细化图中得到了 4 个具有单一连通区的 8×8 的分支图像,分别代表交叉线的 4 条分支,矢量量化后,每一个神经元对应一个像素。初始化时,像素为黑点的神经元值为 1,否则为 0。

$$y_i(0) = x_i ; 0 \leq i \leq P-1 , x_i \in \{0,1\}$$

此外,还需记录进入交叉点前的 20 个点的坐标和平均宽度信息,用于跟踪结果判断。



(a) 训练阶段流程

(b) 识别阶段流程

图 6 基于 DHNN 交叉线识别流程

本算法采用串行工作方式,对于一个权值矩阵 w ,只要 w 对称,且对角线元素非负,那么网络演变的结果总要收敛于一个稳定点^[7]。

由公式 $y_i(t+1) = \text{sgn}[\sum_{j=0}^{P-1} w_{ij}y_j(t)]$ 得到下一时刻的输出,迭代运算,直到当 $y_i(t+1) = y_i(t)$ 时,即是网络所有神经元的状态都不再有所变化时,网络达到收敛。此时,该节点的输出将是 8 个训练样本中的一个,即是输入的交叉线分支与样本的最佳匹配结果。顺序完成 4 幅曲线分支图像的匹配运算,并将结果保存。

2.5 结合宽度判断

由于同一条交叉线的两条分支,应具有相似的曲线走向和曲线特征,所匹配的标准样本应该相同。将曲线跟踪进入交叉点分支,与其匹配结果相同的分支相连接,就完成了利用 DHNN 网络曲线在交叉点的方向判断。除了方向能判断曲线的走向外,还有一个重要的判决条件不能被忽略了,那就是曲线的宽度信息。

交叉点判断时记录了进入交叉点时曲线宽度信息 ($nCurrentWidth$) 和之前 20 个点跟踪点平均宽度信息 ($nAverWidth$)。在上一步判断的基础上,对所识别出来方向的曲线进行 20 个点的跟踪,同样得到它们的平均宽度信息 ($nAverWidth_later$),将 $nAverWidth$ 和 $nAverWidth_later$ 作比较,看是否满足宽度条件的限制。若 $|nAverWidth - nAverWidth_later| < traceThreshold$,平均宽度变化满足小于阈值 $traceThreshold$,则 DHNN 网络走向判断正确,继续跟踪下去。

3 结果与讨论

本文的算法思想采用 C++ 编码,在 VC++ 6.0 环境下实现(图 7),用一幅简化的曲线图纸进行模拟。在判断曲线宽度突变遇到了交叉点后,将含有交叉点的 31×31 的子图像先做预处理,为了看到预处理效果,故将细化去枝后子图像在交叉点右侧显示出来。从中分割出 4 个 8×8 的单连通线图像块,分别投影到 Hopfield 网络上进行识别。经过迭代运算,在识别出正确的方向结果后,将数据返回给进入原图的交叉点前的位置。依次进行,判定各个交叉点处的曲线走向,这样曲线就能够被跟踪完毕。

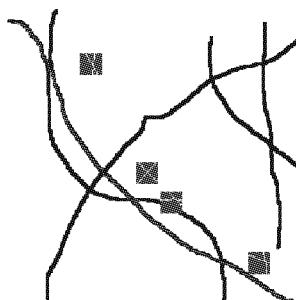


图 7 带预处理效果的简化曲线跟踪实验

我们再使用实际的含有交叉线的测井图作为实验对象。首先将图经过二值化处理得到黑白图像,再进行曲线自动跟踪识别,实验结果如图 8 所示。

实验表明,采用离散型 Hopfield 神经网络交叉线识别的方法,在处理目标曲线与网格相交,目标曲线与其他实线、虚线相交时完成了自动跟踪。然而,在处理与实线相交时,交叉点可能正好是曲线拐点,导致匹配错误,跟踪正确率仍然有待

提高。

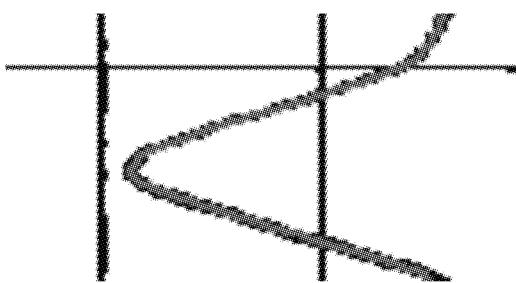


图 8 目标曲线与网格线连续相交

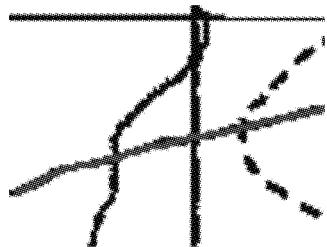


图 9 目标曲线与实线和虚线相交

4 结语

提出了一种应用离散型 Hopfield 神经网络进行测井曲线交叉线识别的算法。利用此方法对真实的测井曲线图像进行了提取,其可行性得到了证实,正确率较好,速度较快。通过该算法将目标曲线提取出来后,可将数据记录并载入数据库供以后参考、分析和管理,同时可以应用于其他的领域中。

参考文献:

- [1] 张幼明,万军,郑冬喜. 数控线切割机床图像矢量化的线跟踪算法改进研究[J]. 机械设计与制造, 2004(6): 109–111.
- [2] 王平,董玉德,罗皓帅. 一种优化的 Freeman 链码及其在工程图纸绘制中的应用[J]. 计算机工程, 2005, 4A(3): 261–264.
- [3] 孙贞寿,钱刚,黄琨. 基于 Hopfield 神经网络的交叉线识别算法 [J]. 中国图象图形学报, 1998, 3(8): 684–687.
- [4] 左航. 测井曲线的自动识别与提取[D]. 成都: 四川大学, 2003.
- [5] 王玲璐,余艳梅,罗代升. 一种基于 BP 网络的测井曲线自动提取方法[J]. 四川大学学报·自然科学版, 2008, 45(1): 85–90.
- [6] 曹爱军,史杏荣,孙贞寿. 基于多层神经网络的交叉线自动识别 [J]. 中国图象图形学报, 2000, 2(5): 149.
- [7] 魏海坤. 神经网络结构设计的理论与方法[M]. 北京: 国防工业出版社, 2005.
- [8] 张青贵. 人工神经网络导论[M]. 北京: 中国水利水电出版社, 2004.
- [9] 阎平凡,张长水. 人工神经网络与模拟进化计算[M]. 北京: 清华大学出版社, 2005.
- [10] 胡小峰,赵辉. Visual C++/Matlab 图像处理与识别实用案例精选[M]. 北京: 人民邮电出版社, 2004.
- [11] 许进,张强,马润年. 离散 Hopfield 神经网络的稳定性研究[J]. 电子学报, 2002, 30(7): 1089–1091.
- [12] 吴维,钟万勰. Hopfield 网络的改进方法[J]. 大连理工大学学报, 1995, 35(2): 137–140.
- [13] 曾黄麟. 基于改进的 Hopfield 离散神经网络的模式识别[J]. 电子技术, 1996, 36(2): 13–18.
- [14] IWATA H, AGUI T, NAGAHASHI H. Boundary detection of color images using neural networks[C]// Proceedings of ICNN'95. New York: IEEE, 1995, 3: 1426–1431.