

应用 ART2 人工神经网络自组织 形成焊缝图象中的典型空间模式

钱迎雪 黄石生 周其节

(华南理工大学机械工程二系·广州, 510641)

摘要: 应用 ART2 人工神经网络算法, 使采集到的焊缝横截面方向上的灰度分布数据自组织形成若干种空间模式, 并把它们作为典型空间模式存储在 ART2 人工神经网络的 LTM 中。对实时采样到的灰度分布进行空间模式匹配程度检验, 根据模式分布情况确定出焊缝位置。文中对梯度法检测结果进行了分析和比较, 结果表明基于 ART2 人工神经网络的焊缝位置检测方法具有更强的噪声抑制能力, 因而检测结果更准确、可靠。

关键词: 模式识别; 人工神经网络; 焊缝视觉跟踪

1 引言

用工业机器人实现弧焊过程自动化是当前工业机器人应用研究的重点领域。在金属制造业中, 焊接工程是仅次于装配和机械切削加工的第三大工程, 它具有如下特点: 1) 工作条件恶劣, 很多焊接工作需要在水下、窄小空间内、不便于操作和存在有害介质的环境中进行; 2) 工程量大, 特别是在造船、锅炉压力容器制造和海洋工程等行业里, 焊接是主要的制造工艺; 3) 质量要求高, 在上述行业里, 质量问题在很多情况下会造成灾难性后果。因此, 工业发达国家都在大力研究和推广焊接机器人的应用。

随着焊接机器人应用的日益增长, 焊缝自动跟踪系统的研制和应用显得越来越重要。智能型的眼睛控制系统由传感器、信息处理系统和跟踪执行机构组成。在焊接过程中传感器不断检测焊缝位置信息, 信息处理系统则对这些信息进行处理、分析, 得到焊缝中心位置, 然后输出控制信号使执行机构产生所需的运动, 实现焊接过程中的实时跟踪控制。可见, 从含有噪声的传感器信号中正确检测出焊缝位置信息是实现焊缝自动跟踪的关键。

本文工作中用 CCD 摄像机作为视觉传感器, 摄取包含焊缝位置信息在内的焊缝图象。文中重点介绍了应用 ART2 人工神经网络自组织形成焊缝横截面方向上的典型灰度空间模式, 并使其快速进入 ART2 人工神经网络的 LTM。在此基础上, 文中简要介绍了焊缝跟踪检测算法。实验证明, 这是一种能够在强烈的噪声环境中正确地检测出焊缝位置的新的焊缝检测算法。

2 焊缝图象灰度数据的获取

实验装置如图 1 所示。用 CCD 摄像机摄取弧焊区图象, 图象分辨率为 512×512 , 具有 256 个灰度级; 255 对应白色, 0 对应黑色。CCD 摄像机上装有带通滤光片, 通过选择特定的辐射频域, 使弧焊区各辐射源的光强达到一个合适的比例, 从而得到可见光波长内的

电弧、熔池和焊缝三者同时成像的清晰的弧焊区图象^[1]。图象灰度数据暂存在 vp32 图象处理机的帧存体中，可同时存储 4 帧图象。计算机再从帧存体中读取数据进行处理。

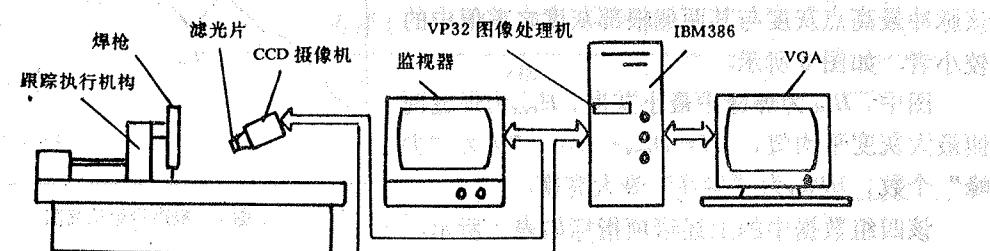


图 1 实验装置示意图

实验条件为：焊接方法 TIG，钨极材料钍钨极，焊接电流 55~65A，焊接电压 8~12V，焊接速度 3~6mm/s，氩气流量 10.5~13.5l/min，工件材料低碳钢，板厚 2mm，间隙 0.5~2mm。采集图象中熔池前端 10mm 范围内焊缝横截面方向上的 100 个象点灰度值作为一组原始数据。

3 焊缝图象灰度数据分析

从采集到的灰度数据中选取四组数据进行分析，相应的灰度分布曲线如下：

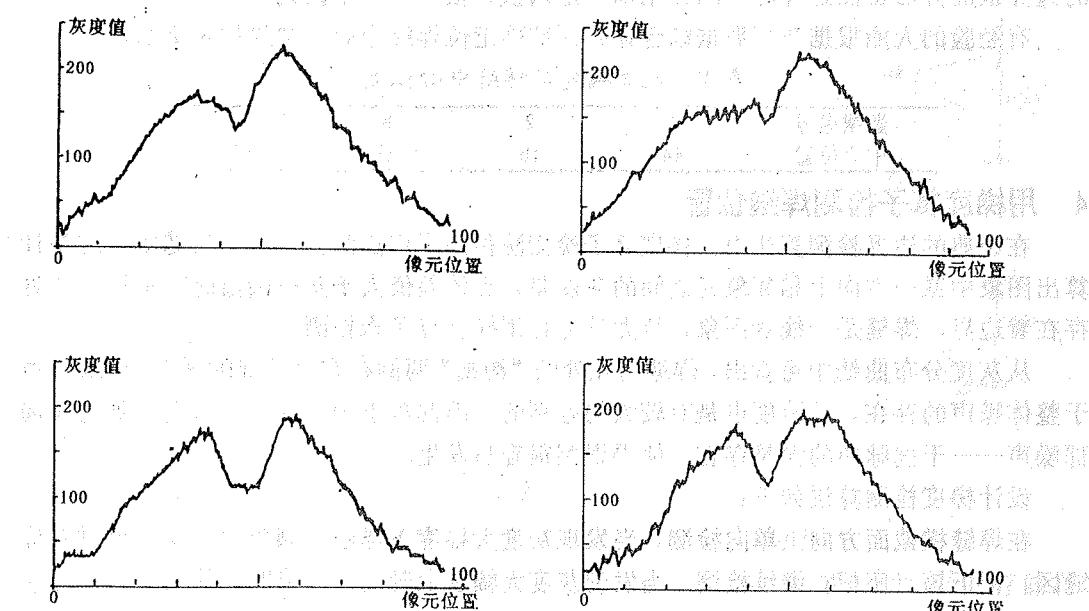


图 2 灰度分布曲线

从分析图象灰度数据可以看出，存在着两类噪声。一类是主要由工艺规范波动或弧光闪烁引起的使整体灰度值、空间灰度反差发生波动的整体噪声；另一类是主要由坡口附近工况不一（不够平整清洁）或摄像系统中的随机干扰造成的局部噪声。

取数据中的焊缝中最小灰度值（灰度曲线中的“沟底”）、焊缝两侧最大灰度值（灰度曲线中的“沟”两侧的“高峰”）以及它们的差值作为衡量整体噪声的指标；取数据中

干扰脉冲（灰度曲线中的“尖峰”）的个数及其中最大高度作为衡量局部噪声的指标，脉冲高度取该脉冲最高点灰度与其两侧根部灰度之差值中的较小者，如图 3 所示。

图中， H_{\min} 为焊缝中最小灰度， H_{\max} 为焊缝两侧最大灰度平均值， $\Delta H = H_{\max} - H_{\min}$ ， PN 为“尖峰”个数， HP_{\max} 为“尖峰”最大高度。

该四组数据中的上述诸项指标如表 1 所示。

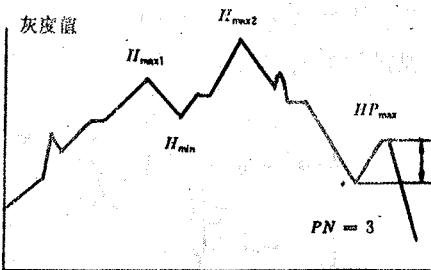


图 3 噪声指标示意图

表 1 噪声数据

| 组号 | H_{\min} | H_{\max} | ΔH | PN | HP_{\max} |
|----|------------|------------|------------|------|-------------|
| 1 | 138 | 172, 221 | 38, 85 | 7 | 8 (94) |
| 2 | 148 | 168, 217 | 20, 69 | 13 | 12 (30) |
| 3 | 116 | 173, 189 | 57, 73 | 10 | 8 (79) |
| 4 | 121 | 184, 196 | 63, 75 | 12 | 13 (8) |

可见噪声很强烈。由于整体强噪声的存在，如果先进行预处理二值化，阈值难以恰当地确定；由于局部强噪声的存在，如果采用梯度算子、Laplace 算子或 Sobel 算子等经典的边界检测方法检测边界时，同样难以确定阈值，很容易发生误判。

有经验的人能根据灰度数据综合评判而准确定位焊缝中心，结果如表 2 所示。

表 2 人工确定的焊缝中心位置

| 数据组号 | 1 | 2 | 3 | 4 |
|------|----|----|----|----|
| 中心位置 | 44 | 45 | 47 | 45 |

4 用梯度算子检测焊缝位置

在经典的边界检测算法中，梯度算子检测法得到了广泛的应用。它的基本原理是计算出图象中某一方向上相邻象元之间的灰度差，当该差值大于某一阈值时，就认为该处存在着边界。焊缝是一线状图象，故尤其适合用梯度算子来检测。

从灰度分布曲线中可看出，焊缝所在处的“沟槽”两侧存在着较陡的梯度，但是，由于整体噪声的存在，其陡度也是有较大的差别的，因此难于确定恰当的阈值；加之有局部噪声——干扰脉冲的大量存在，使得误判很容易发生。

设计梯度检测算法如下：

在焊缝横截面方向上单向检测，当发现灰度大幅度下降超过阈值时，认为已进入焊缝区，记下该点座标；继续检测，当发现灰度大幅度上升超过阈值时，认为又进入母材区，记下该点座标；取该两点中间值为焊缝中心位置座标；如果不存在超过阈值的上述两点（或其中一点），则示出“无法定位”的拒判信息。

对采集到的十组灰度数据取不同阈值时的梯度算子检测结果见表 3。表中，MK 为阈值（门坎值），“☆”表示正确，“×”表示错误，“—”表示无法确定其位置。

从表中可清楚地看出，阈值小则正确率较低，误判率高，拒判率低；阈值增大，则正确率高，误判率低，但是拒判率也明显增大。由此可见，梯度算子法难以取得理想

* 括号中的数字为“尖峰”所在象元位置。

的效果。如果用图象空间滤波或图象增强等方法预处理，用其它边界检测算子（如 Sobel 算子）检测边界，情况会有所改善，但由于这些方法无本质改进，因此效果不够明显。

表 3 不同阈值下的梯度算子检测结果

| MK | ☆ | × | - | MK | ☆ | × | - |
|----|---|---|---|----|---|---|---|
| 5 | 2 | 8 | 0 | 20 | 3 | 0 | 7 |
| 10 | 4 | 4 | 2 | 25 | 2 | 0 | 8 |
| 15 | 1 | 2 | 7 | 30 | 1 | 0 | 9 |

5 ART2 人工神经网络基本原理^[2,3]

ART(自适应共振理论, Adaptive Resonance Theory)由美国 Boston 大学的 A. Carpenter 和 S. Grossberg 提出，分别有 ART1, ART2 和 ART3 三种模型。其中，ART2 适用于模拟输入模式随机序列的自组织分类；由于本工作中摄取的是 256 个灰度级的焊缝图象，故采用 ART2 人工神经网络模型。

ART2 人工神经网络模型的结构如图 4 所示，主要由注意子系统 (Attention Subsystem) 和指向子系统 (Orienting Subsystem) 两部分组成，其纵向结构又分为三个层次： F_0 , F_1 , F_2 。注意子系统由输入表示区 F_1 和模式表示区 F_2 组成，指向子系统与注意子系统相互作用，进行内部控制的模式搜索。 F_1 和 F_2 构成了由下向上 (bottom-up) 和由上向下 (top-down) 的自适应滤波器。从 F_1 的第 i 个节点到 F_2 的第 j 个节点的联系为权值 z_{ij} ，称为长期记忆 LTM (Long Term Memory)。从 F_2 的第 j 个节点到 F_1 的第 i 个节点的联系为权值 z_{ji} 。 F_0 是预处理层， F_0 , F_1 和 F_2 都是具有对输入模式进行对比增强作用和正则化处理的并行竞争网络。

输入模式在 F_0 和 F_1 中进行相互间的合成和正则化，在进行这些运算时暂时存储在 F_0 和 F_1 中的经过处理的输入模式称为短期记忆 STM (Short Term Memory)。

下面具体阐述一个 M 维的输入模式 I 的处理过程。

输入模式 φ^0 中的较强部分在 F_0 中到“共振”加强，而其较弱部分则被抑制，输出为 u_i^0 。

$$w_i^0 = \varphi_i^0 + au_i^0, \quad (1)$$

式中， a 为一反馈常数； u_i^0 的初值为 0。

$$x_i^0 = w_i^0 / \| w_i^0 \|, \quad (2)$$

$$\| w_i^0 \| \text{ 为向量 } w_i^0 \text{ 的模.} \quad u_i^0 = f(x_i^0). \quad (3)$$

$f(x)$ 为一阈值函数，即当 $x > \theta$, $f(x) = x$ ；当 $x < \theta$, 则 $f(x) = 0$ 。这里， $0 < \theta < 1/\sqrt{M}$, M

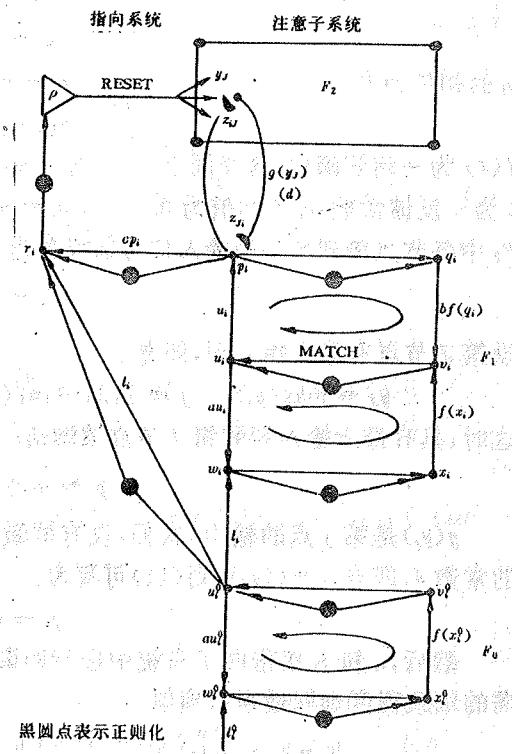


图 4 ART2 的结构

是 x 的维数。可见,只要输入 I 不是完全均匀的,则 M 维矢量 V^0 总不会为 0;如果 θ 取得略大于 $1/\sqrt{M}$,则只要输入模式接近于均匀,也将使得 V^0 为 0,从而不能进入 STM。

阈值函数 $f(x)$ 的非线性性质对于 F_0, F_1 层的对比增强和噪声抑制功能是至关重要的。小于阈值的输入信号被置为 0,而大于阈值的输入信号又在后续的正则化过程中得到增强,这就使得模式的主要特征被提取出来,而噪声则被抑制。

$$u_i^0 = v_i^0 / \| V \| . \quad (4)$$

F_1 层的输入 $i_i (= u_i^0)$ 与已存储在“长期记忆”LTM 中的原有模式在 F_1 中相互结合并“共振”,使其中较强部分得到加强而较弱部分被抑制,产生输出 p_i :

$$i_i = u_i^0, \quad (5)$$

$$w_i = i_i + au_i, \quad (6)$$

u_i 的初值为 0.

$$x_i = w_i / \| w \| , \quad (7)$$

$$v_{i0} = f(x_i). \quad (8)$$

$f(x)$ 为一阈值函数,含义同上. $v_i = v_{i0} + bf(q_i)$. (9)

b 为一反馈常数; q_i 的初值为 0. $u_i = v_i / \| V \| . \quad (10)$

F_2 中各节点得到的各路输入信号加权和为

$$y_j = \sum_i u_i z_{ij}. \quad (11)$$

设第 J 节点有最大输入和,即有

$$y_J = \max(y_j), \quad j = 1, 2, \dots, n; (n \text{ 为 } F_2 \text{ 中代表模式的节点的总数}); \quad (12)$$

这时,具有最大输入和的第 J 节点被激活。

$$p_i = u_i + \sum_j g(y_j) z_{ji}. \quad (13)$$

$g(y_j)$ 是第 j 点的输出,这里,仅有被激活的节点才能输出,输出值为一大于零小于 1 的常数 d ,即有: $d = g(y_J)$;则(11)可写为:

$$p_i = u_i + dz_J. \quad (14)$$

然后, i_i 和 p_i 在指向子系统中进行匹配程度(用 $\| R \|$ 度量)的阈值检验;根据分类所需的细致程度选取适当的阈值 ρ .

$$\| R \| = \frac{[\| I \|^2 + 2c \| I \| \cdot \| P \| \cos(I, P) + c^2 \| P \|^2]^{\frac{1}{2}}}{\| I \| + c \| P \|}. \quad (15)$$

这里, c 为一大于零的常数; $\cos(I, P) = \sum (i_i \cdot p_i) / (\| I \| \cdot \| P \|)$.

当 $\| R \| > \rho$,则指向子系统认为现输入模式与原模式“匹配”,同时指向该模式,并对该模式的 LTM 进行旨在更接近现输入模式的更新(Update),如(16),(17)式所示:

$$\frac{dz_{ji}}{dt} = p_i - z_{ji}, \quad (16)$$

$$\frac{dz_{Ji}}{dt} = p_i - z_{Ji}. \quad (17)$$

* 当 $\| R \| < \rho$,则指向子系统产生重置(reset,也译成“复位”)信号,在 F_2 中激活一个“未赋值”的新节点(uncommitted node),建立一个新模式及相应的长期记忆 LTM.

当 ρ 值比较小的时候,模式分类较粗略,分类的数目比较少;当 ρ 值比较大的时候,模式分类就比较细致,分类的数目就比较多.

由此可见,ART2 的主要特点是能自动实现对模拟输入模式随机序列在不同匹配程度上的自组织模式分类.

6 空间模式的自组织形成:

在 IBM386 计算机上用 Fortran 4.01 版编程实现 ART2 人工神经网络,利用其自组织功能对采样到的焊缝图象灰度数据进行自组织空间模式分类. 取 11 个象元(即以某一象元为中心,取其前后各五点)作为一个模式长度单位,取这连续 11 个点的灰度数据作为 ART2 人工神经网络的一个输入空间模式; 对四组数据中的每一组数据随机地选取 200 个点作为输入空间模式序列, 每个输入模式均进行 3 次训练,以便取得明显的“共振”效果. 由于 ART2 算法具有运算简单、运行速度快的优点,对四组数据进行一次自组织学习,仅需几十秒钟时间.

取不同的阈值 ρ ,对上述四组数据进行自组织空间模式分类,得到以下结果:

当 $\rho=0.981$ 时,自组织形成的模式如下:

表 4 自组织形成的模式 ($\rho=0.981$)

| | | | | | | | | | | |
|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| 0.0 | 0.0 | 0.0 | 0.0 | 0.324 | 0.333 | 0.341 | 0.355 | 0.340 | 0.258 | 0.355 |
| 0.490 | 0.468 | 0.450 | 0.408 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 |

形成了两个模式.

表 5 自组织形成的模式 ($\rho=0.982$)

| | | | | | | | | | | |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0.0004 | 0.0004 | 0.6396 | 0.0004 | 0.0004 | 0.0003 | 0.0 | 0.0 | 0.6567 | 0.0 | 0.0 |
| 0.490 | 0.4677 | 0.4507 | 0.0004 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 |
| 0.0 | 0.0 | 0.0 | 0.0 | 0.3241 | 0.3334 | 0.3406 | 0.3548 | 0.3397 | 0.2587 | 0.3548 |

形成了三个模式.

表 6 自组织形成的模式 ($\rho=0.983$)

| | | | | | | | | | | |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0.0 | 0.6365 | 0.0004 | 0.0004 | 0.0 | 0.0004 | 0.0 | 0.6497 | 0.0 | 0.0004 | 0.0 |
| 0.0 | 0.0 | 0.0 | 0.0 | 0.3398 | 0.3493 | 0.3428 | 0.3549 | 0.3398 | 0.3413 | 0.3373 |
| 0.0 | 0.0 | 0.0 | 0.0004 | 0.3998 | 0.4013 | 0.4282 | 0.4014 | 0.4017 | 0.0 | 0.0 |
| 0.490 | 0.4677 | 0.4507 | 0.4057 | 0.0004 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 |
| 0.0034 | 0.0038 | 0.6931 | 0.0034 | 0.0032 | 0.0031 | 0.0 | 0.0 | 0.5936 | 0.0 | 0.0 |

形成了五个模式.

表 7 自组织形成的模式 ($\rho=0.98275$)

| | | | | | | | | | | |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0.0 | 0.0 | 0.0 | 0.0 | 0.3398 | 0.3493 | 0.3428 | 0.3549 | 0.3398 | 0.3413 | 0.3373 |
| 0.0004 | 0.6288 | 0.0004 | 0.0004 | 0.0003 | 0.0 | 0.0 | 0.6574 | 0.0 | 0.0 | 0.0 |
| 0.0 | 0.0 | 0.0 | 0.0004 | 0.3996 | 0.4013 | 0.4282 | 0.4014 | 0.4017 | 0.0 | 0.0 |
| 0.490 | 0.4678 | 0.4507 | 0.4057 | 0.0004 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 |

形成了四个模式.

对上述自组织过程中形成的模式进行归纳和总结,得出如下结果,将焊缝横截面方向上的灰度分布归结为 4 种典型模式,即“上升”、“下降”、“凹”和“凸”,是比较恰当的. 如图

5 所示。

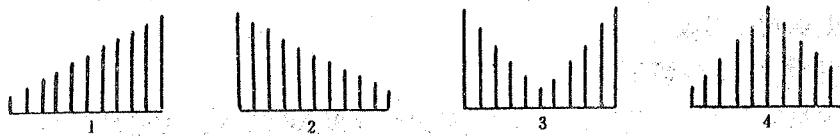


图 5 四种典型模式

如前所述,ART2 人工神经网络适用于无教师的自组织模式分类,但在对象模式类型已知的条件下,可对其进行类似于有教师学习方式的“诱导训练”,即有意识地提供典型模式供其学习分类,以使这些典型模式迅速进入长期记忆 LTM。现用图 4 所示的四种典型模式对其进行“诱导训练”,得到 LTM 中的典型模式数据如表 8 所示:

表 8 LTM 中的典型模式 ($\rho=0.98275$)

| | | | | | | | | | | |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.3124 | 0.3570 | 0.4016 | 0.4463 | 0.4909 |
| 0.4909 | 0.4463 | 0.4018 | 0.3570 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 |
| 0.4838 | 0.4233 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.4233 | 0.4838 |
| 0.0 | 0.0 | 0.0 | 0.3122 | 0.4371 | 0.4995 | 0.4371 | 0.3122 | 0.0 | 0.0 | 0.0 |

7 算法设计及实验结果

设计焊缝检测算法如下^[4]:

1) 从第 6 点起至第 95 点止,以被匹配检验的点及前后邻域内各 5 点(共 11 点)作为一个模式单元,逐个对典型模式 1 及模式 2 进行匹配检验,搜寻模式 2 至模式 1 的转变点,作为焊缝中心的候选点(大部分情况下仅有这一点);

2) 对候选点进行模式 3 的匹配程度检验,最佳匹配者获胜,确定为焊缝中心点。

对 3 个模式分两步进行模式匹配(先模式 1 和 2,后模式 3)检验,可以获得更强的噪声抑制能力和更快的计算速度;本工作中用 IBM386 进行计算处理,速度可达每秒 4 次,基本满足实时跟踪要求。

由于存储在 LTM 中的典型模式由 ART2 从多组数据中自组织产生,因此科学合理,有效地提高了焊缝检测的准确性。

对以上四组数据进行焊缝中心位置检验,结果如表 9 所示,可见与人工判断一致(见表 2)。

表 9 检测结果

| 组号 | 候选点及匹配度 | 中心点 |
|----|------------------------------------|-----|
| 1 | 44, 0.3576 | 44 |
| 2 | 32, 0.2870; 35, 0.2810; 45, 0.3387 | 45 |
| 3 | 47, 0.3011 | 47 |
| 4 | 45, 0.3526 | 45 |

对采集到的十组灰度数据进行检测,并与人工经验判断的结果比较,有八组一致(相差正负一),两组相差三个象元位置;但与灰度曲线对比可以看出,因为基于 ART2 人工神经网络的检测方法对模式特征进行整体匹配,所以它的检测结果更科学、合理。

8 结 论

应用 ART2 人工神经网络算法能够自组织形成灰度分布中的典型空间模式,根据这些典型模式的分布,即可确定焊缝位置。基于 ART2 人工神经网络理论的实时焊缝位置检测方法与梯度法相比,具有更强的噪声抑制能力,是一种实时检测焊缝位置的准确可靠方法。

参 考 文 献

- [1] 宋永伦. 弧焊区图象信息的光谱传感技术. 焊接学报, 1992, 13(2): 127—132
- [2] Carpenter, G. A. and Grossberg, S.. ART2: Self-Organization of Stable Category Recognition Codes for Analog Input Patterns. Applied Optics, 1987, 26(23): 4919—4930
- [3] Carpenter, G. A., Grossberg, S. and Rosen, D. B.. ART2-A: An Adaptive Resonance Algorithm for Rapid Category Learning and Recognition. Neural Networks, 1991, 4: 493—504
- [4] 黄石生, 钱迎雪. 基于 ART 人工神经网络的焊缝跟踪检测算法. 机械工程学报, 1994, 30(2): 93—98

The Self-Organization of Typical Space Patterns in Welding

Seam Tracking Image by Using ART2 Artificial Neural Networks

QIAN Yingxue, HUANG Shisheng and ZHOU Qijie

(2nd Department of Mechanical Engineering, South China University of Technology · Guangzhou, 510641, PRC)

Abstract: The algorithm based on the ART2 artificial neural networks is used to self-organize the grey level distribution data in the transversal direction of a welding seam and forms several typical space patterns and stores them in the LTM (long time memory) of the ART2 artificial neural networks. Then the grey level distribution data of a welding image obtained in real time is matched with these typical space patterns. The welding seam position can be determined according to the situation of pattern distributions. It is shown that this method can inhibit strong noises and work correctly in a very noisy circumstance.

Key words: pattern recognition; artificial neural networks; welding seam tracking

本文作者简介

钱迎雪 1957 年生。1982 年毕业于上海交通大学金属材料工程专业, 以后在华东船舶工程学院任教; 1991 年 9 月考入华南理工大学攻读博士学位, 1994 年 6 月获自动理论及应用工学博士学位。现在南京某研究所工作。对图象处理、视觉模式识别、人工神经网络等研究领域感兴趣。

黄石生 见本刊 1994 年第 2 期第 136 页。

周其节 见本刊 1994 年第 5 期第 575 页。