

# 脉冲 GTAW 熔池动态过程模糊神经网络建模与控制<sup>1)</sup>

陈善本<sup>1</sup> 娄亚军<sup>2</sup> 赵冬斌<sup>3</sup> 吴林<sup>2</sup>

<sup>1</sup>(上海交通大学焊接所 上海 200030)

<sup>2</sup>(哈尔滨工业大学焊接国家重点实验室 哈尔滨 150006)

<sup>3</sup>(清华大学焊接教研室 北京 100080)

(E-mail: sbchen@mail1.sjtu.edu.cn)

**摘要** 展示了模糊推理与神经网络结合在脉冲 GTAW 熔池动态过程智能控制中的应用研究成果. 建立了脉冲 GTAW 平板对接动态过程特征: 正反面熔池的最大宽度、长度与面积等参数的神经网络模型, 基于实验数据采用模糊辨识方法提取焊接过程的模糊控制规则, 进而设计了具有自学习适应能力的模糊神经网络控制器. 建立了脉冲 GTAW 熔池动态过程智能控制系统, 焊接实验验证了所设计的模糊神经网络控制器具有智能控制效果.

**关键词** 焊接熔池动态过程, 模糊神经网络, 建模与控制

**中图分类号** TP202, TH122

## FUZZY-NEURAL NETWORK MODELLING AND CONTROL OF POOL DYNAMIC PROCESS IN PULSED GTAW

CHEN Shan-Ben<sup>1</sup> LOU Ya-Jun<sup>2</sup> ZHAO Dong-Bin<sup>3</sup> WU Lin<sup>2</sup>

<sup>1</sup>(Welding Institute, Shanghai Jiaotong University, Shanghai 200030)

<sup>2</sup>(Harbin Institute of Technology, Harbin 150006)

<sup>3</sup>(Tsinghua University, Beijing 100080)

(E-mail: sbchen@mail1.sjtu.edu.cn)

**Abstract** This paper investigates practical application of intelligent control of the pulsed GTAW pool dynamic process by fuzzy logic inference and neural networks. Firstly, the neural network models for the flat butt joint pool character in pulsed GTAW dynamic process is established, such as the maximum width, length, area parameter models. And based on the experimental data, the fuzzy control rules for the welding process are built up by fuzzy identification algorithm. And then, the fuzzy-neural network controller with self-learning and adaptive ability is designed for the welding process. The experiment on the process shows that the fuzzy-neural network controller has effected some intelligent control results.

**Key words** Weld pool dynamic process, fuzzy neural networks, modeling and control

1) 国家自然科学基金(59635160, 59575057)和教育部国家重点实验室开放课题资助.

收稿日期 2000-09-25 收修改稿日期 2001-01-15

## 1 引言

焊接是制造业中重要的工艺之一. 随着现代高科技产品对焊接质量的要求越来越高对数量和品种的要求越来越多及先进制造技术的不断发展, 迫切要求焊接工艺实现自动化与智能化. 而实现焊接自动化与智能化的根本困难在于实现对焊接熔池动态行为, 如熔池的尺寸、熔深、熔透及焊缝成形的实时检测与有效控制. 电弧焊接是涉及材料、冶金、物理化学变化等多因素交互作用的复杂过程, 焊接质量(焊缝成形、接头组织及性能)与焊接工艺的多参数有关, 这些参数的作用相互关联, 既有动态过程的耦合, 又有静态效果的重叠<sup>[1]</sup>. 对于焊接动态过程这样的多变量、非线性、时变且含有诸多不确定因素和约束条件的复杂对象, 采用基于精确数学建模方法, 难以得到有效的可控制模型, 决定了对焊接熔池的动态变化亦即对焊接熔宽、熔透和焊缝成型等质量控制是非常困难的<sup>[2~4]</sup>. 采用经典及现代控制理论方法来解决同时受到理论上的质疑和应用上的挑战, 难以达到满意的结果, 从而使之成为多年来困扰焊接界与控制界的难题之一.

观察焊工在焊接过程中的操作行为可以得到对焊接动态过程实现有效控制的启示. 一个高水平的焊工通过观察接头的位置、熔池的行为、电弧形状和焊道外观感知焊接状态, 可以手动调节各种规范参数使之达到最佳, 以获得高质量的焊缝. 采用机械自动化装置模拟实现上述焊工行为可以归结到智能控制研究领域<sup>[5~8]</sup>. 由于焊接过程的复杂性, 焊接过程传感及有效控制方法的研究长期以来是实现自动化焊接的两个关键难点. 也是实现焊接过程智能化必须首先解决的问题. 国内外在此问题上的研究基本上局限于焊接过程的传感技术<sup>[4]</sup>, 曾经尝试过应用自适应控制策略的研究<sup>[9]</sup>, 但未获深入和实际的进展. 近年来, 虽有一些应用模糊逻辑和神经网络技术的应用, 但仅限于焊接规范的制定和静态参数的预测, 尚未有关于熔池动态过程这一本质问题的有效控制报道<sup>[2,6~8,10]</sup>.

本文以脉冲 GTAW (Gas Tungsten Arc Welding) 焊接过程为对象, 对基于被动式焊接区熔池直接视觉图像传感的焊接过程的建模和控制进行了深入的研究. 研究工作着重于智能控制方法与实际焊接过程的应用结合, 为提高机器人焊接智能制造水平奠定技术基础.

## 2 脉冲 GTAW 工艺过程及其熔池视觉传感系统

### 2.1 脉冲 GTAW 工艺过程简介

脉冲电流惰性气体钨极电弧焊 (Gas Tungsten Arc Welding) 简称脉冲 GTAW, 是焊接制造的基本工艺之一. 由于该工艺的热输入量较易于控制, 广泛用于航天、航空等部件的精密焊接制造, 特别适用于薄板精密焊接<sup>[1]</sup>. 随着高科技产品对精密制造要求的不断提高, 迫切要求焊接工艺实现自动化, 并对焊接过程稳定可控, 熔透及焊缝成形等质量提出了更高的要求.

### 2.2 脉冲 GTAW 熔池视觉传感系统

为了更好的认识焊接过程的动态特性, 设计了熔池正反双面同时同幅成像计算机视觉图像传感系统, 提取熔池动态特征信息以建立焊接过程动态模型. 图 1 为脉冲 GTAW 熔池正反视觉图像同时同幅传感和焊接质量控制系统硬件示意图<sup>[11]</sup>. 设计焊机的电流调节系



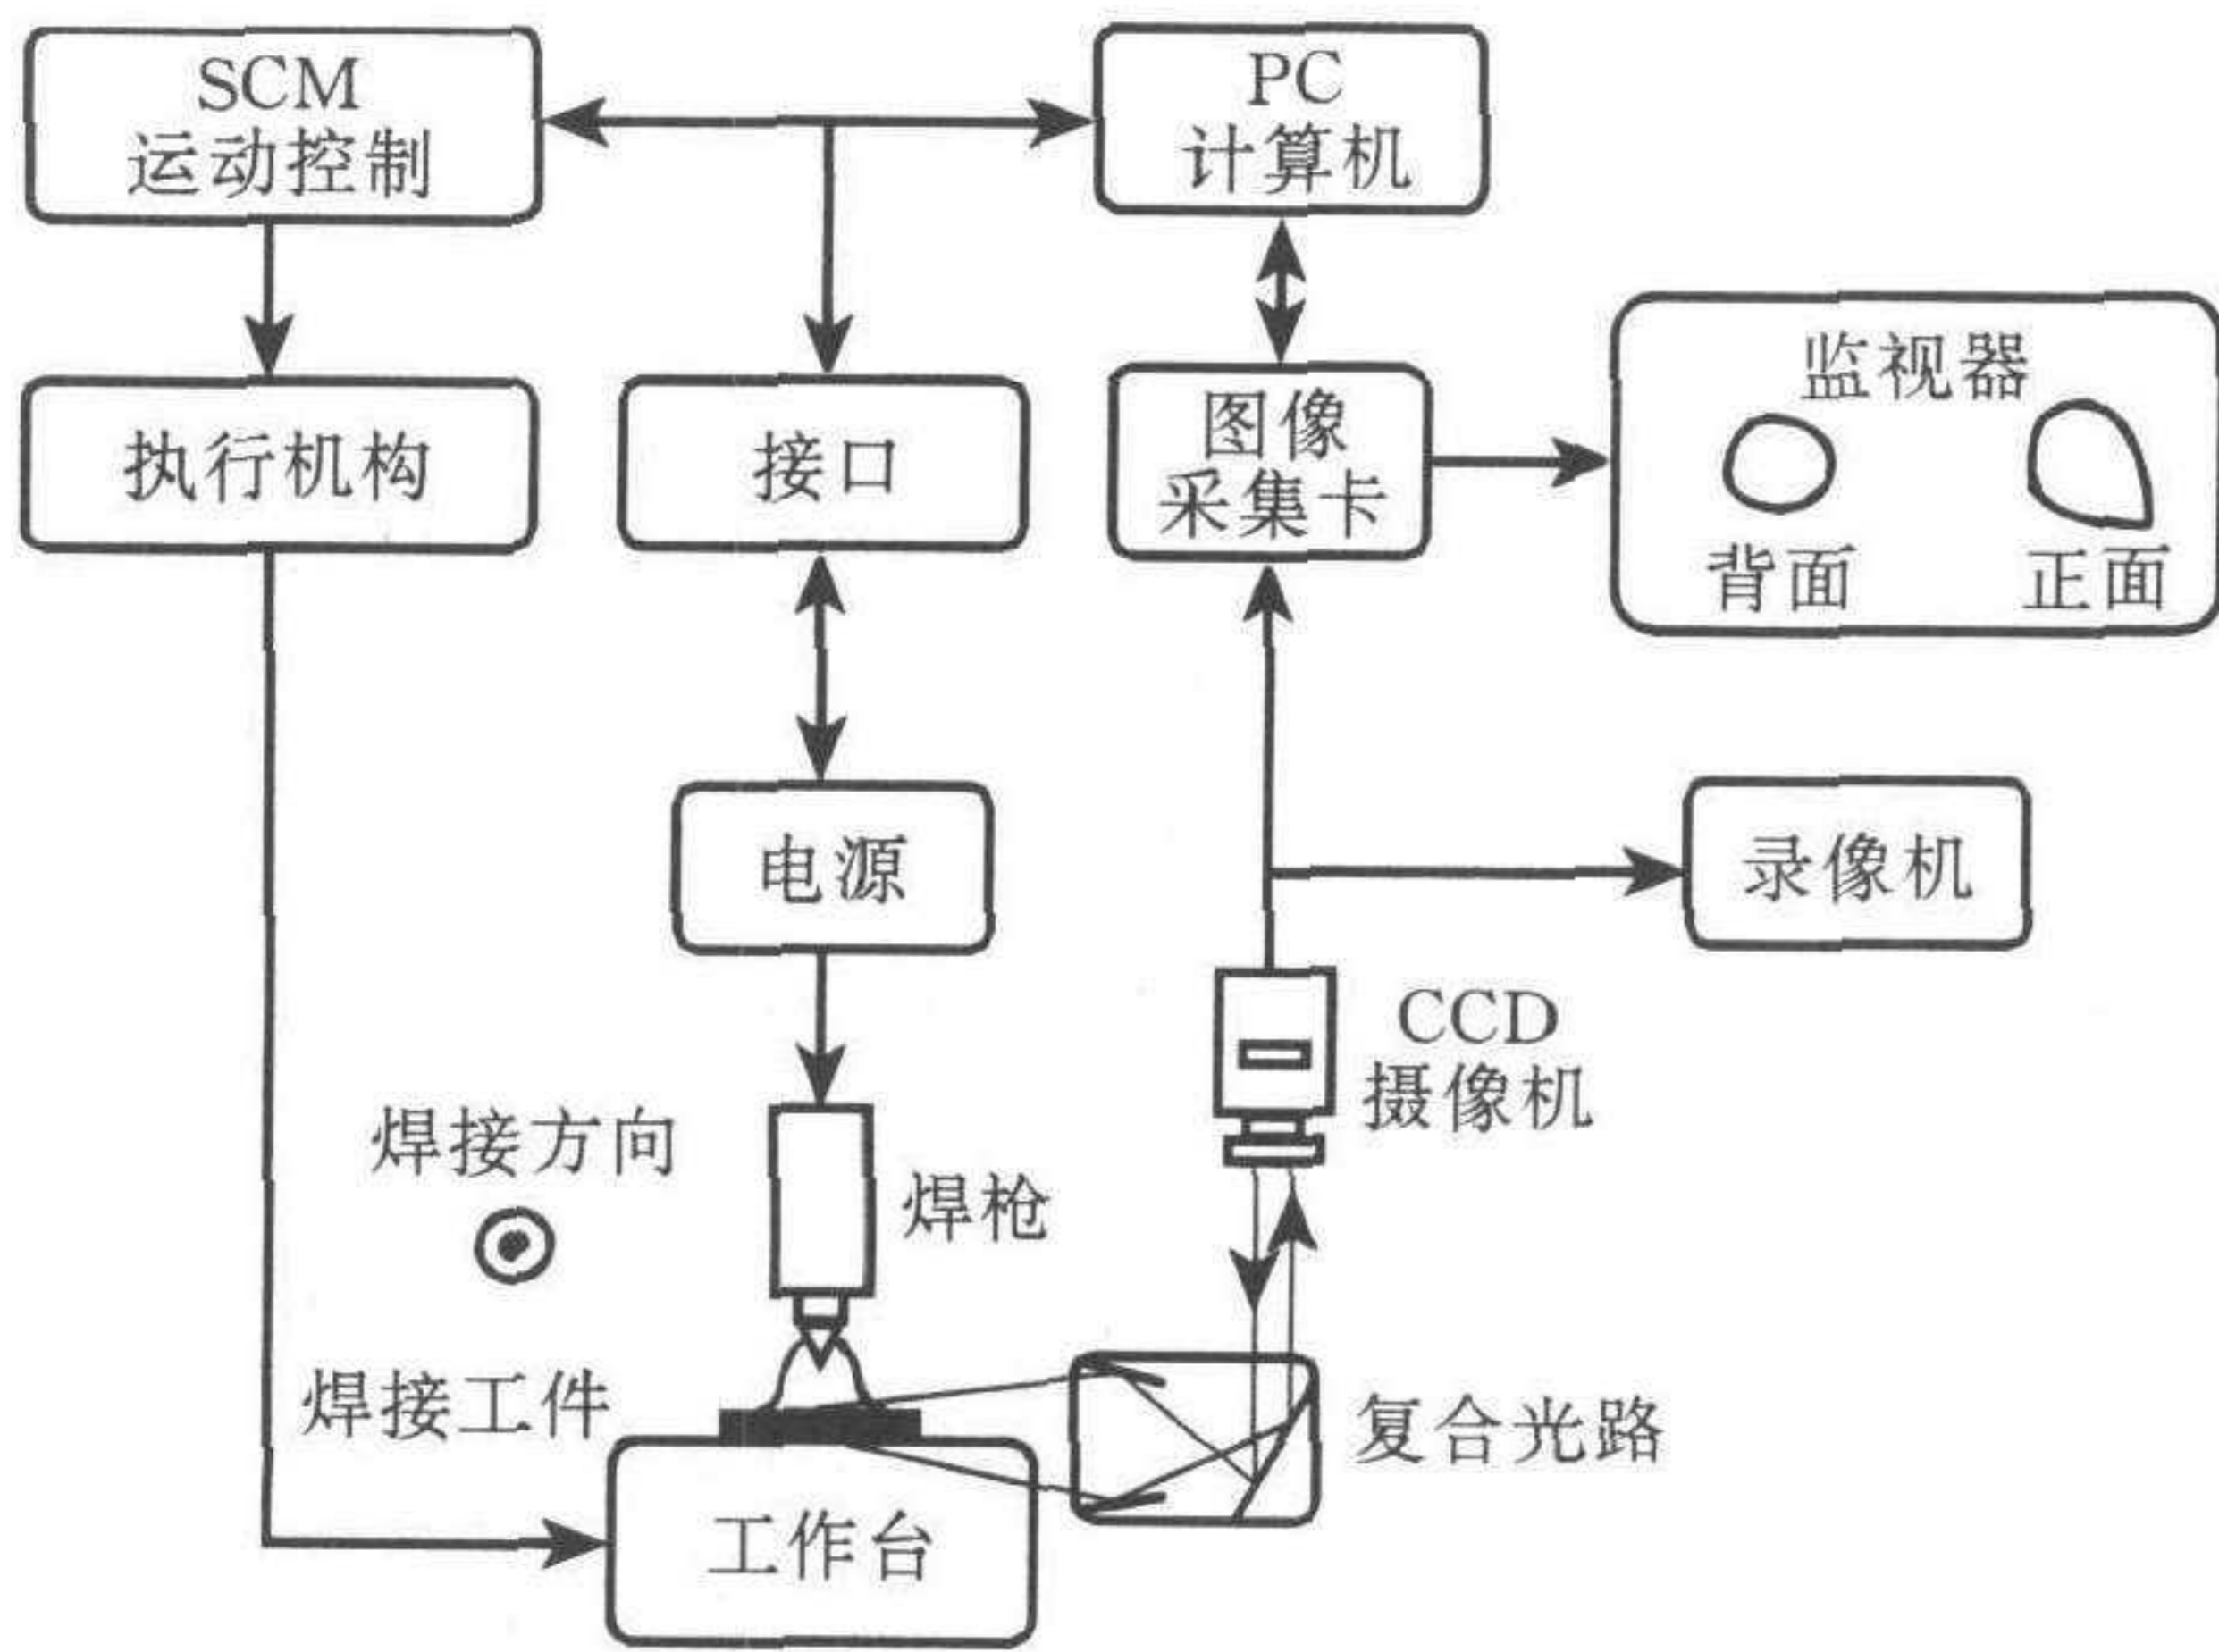


图 1 脉冲 GTAW 弧焊熔池控制系统硬件示意图  
注. SCM 为单片机

何尺寸. 利用自行开发的熔池正反两面视觉图像实时处理算法<sup>[11]</sup>, 在 PC-486 计算机上实现熔池正面视觉图像处理算法耗时不超过 50ms, 熔池反面视觉图像处理算法耗时不超过 30ms, 满足了焊接过程实时闭环反馈控制的要求.

统适应熔池图像信号的检测和控制的需要. 采用单片机控制步进电机驱动系统, 实现对焊接速度的控制.

### 2.3 熔池正反面同时同幅视觉图像

利用所设计的熔池正反面视觉图像同时同幅传感系统, 采用脉冲 GTAW 在低碳钢 A3 板上进行了平板堆焊实验, 焊接条件见文献[11]. 获得一帧完整的熔池正反面图像如图 2 所示, 由于采用了特定光谱的滤光系统, 熔池正面图像区域熔化的液态金属和已凝固的焊道等部分边界非常清晰, 所以非常适合采用图像分割方法提取熔池反面几





图 2 一帧完整的脉冲 GTAW 焊熔池图像

## 3 脉冲 GTAW 对接熔池动态过程模型

### 3.1 熔池几何特征尺寸参数定义



(a) 熔池正面 (b) 熔池反面

图 3 全熔透熔池特征尺寸参数的定义

针对脉冲 GTAW 平板对接情况, 建立熔池尺寸和形状参数联合的多参数脉冲 GTAW 神经网络模型. 由于熔池正反面尺寸和形状参数之间的复杂非线性关系, 采用神经网络可以提供较为理想的模型框架. 模型网络的输入向量由焊接规范参数(包括脉冲峰值电流、占空

为了建立脉冲 GTAW 焊熔池动态过程模型, 定义熔池正面特征参数如图 3: 最大宽度  $W_{fmax}$ , 最大半长  $L_{fmax}$ , 后半部面积  $S_{fmid}$  以及熔池形状扫描线上的宽度  $W_{fi}$ . 熔池反面特征参数: 最大宽度  $W_{bmax}$ , 最大长度  $L_{bmax}$  和面积  $S_b$ , 这些参数可以描述全熔透状态下焊接熔池的特征.

### 3.2 脉冲 GTAW 平板对接熔池多参数神经网络模型的辨识



比、焊接速度、电弧电压)、熔池正面尺寸参数(包括熔池后半部面积、最大半长、最大宽度)和形状参数(包括每条扫描线上的宽度)及其前两个时刻的历史值共 48 个变量组成,隐含层节点数为 30,熔池反面尺寸参数作为网络的输出,选择  $S$  函数作为神经元的非线性传递函数,形成的模型结构如图 4 所示,简称此模型为 SSNNM(Size and Shape Neural Network Model)模型.

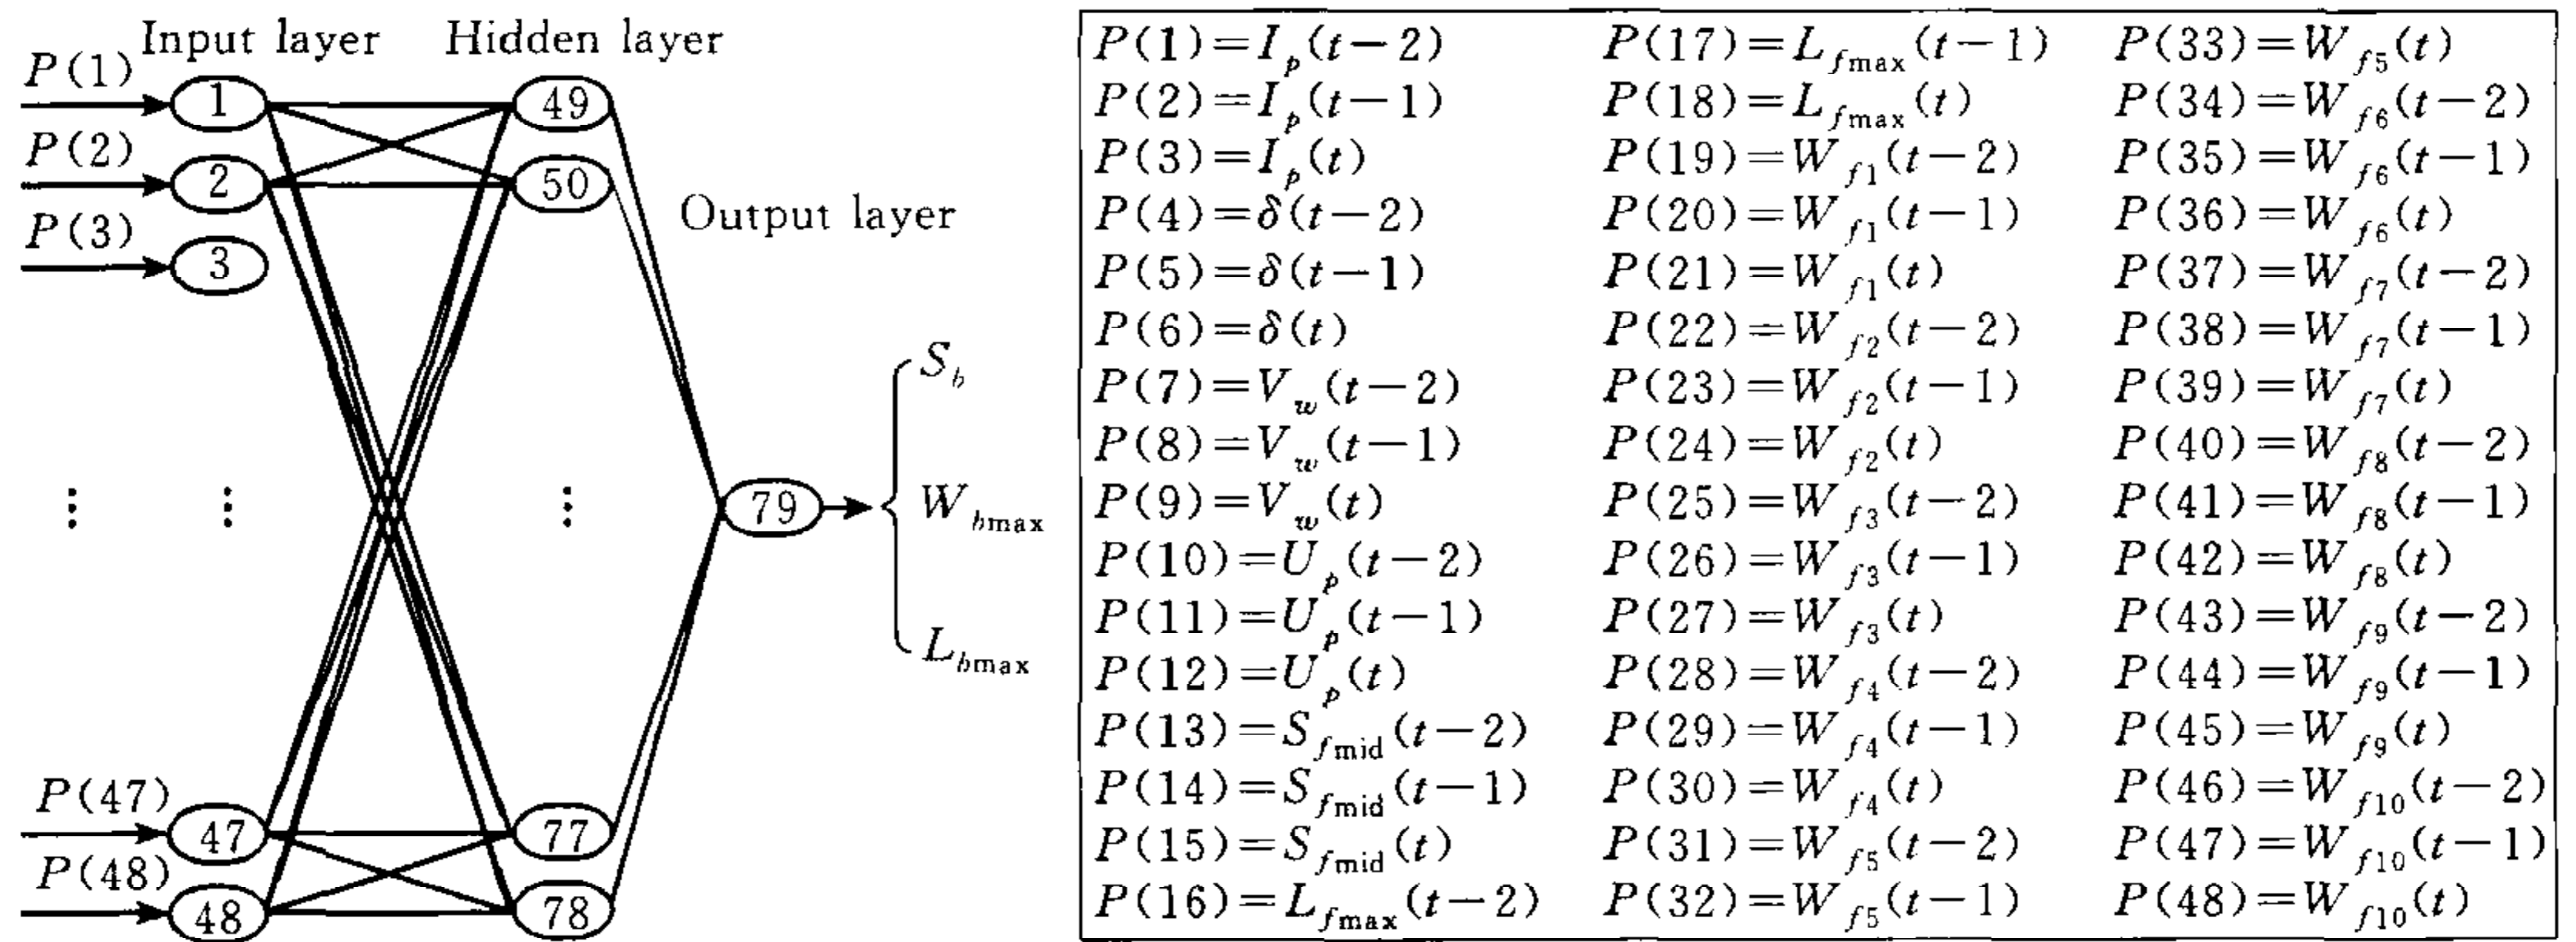


图 4 SSNNM 神经网络模型结构

## 4 脉冲 GTAW 对接过程模糊神经网络控制器设计

### 4.1 脉冲 GTAW 对接过程模糊控制规则的提取

周知,常规的模糊控制规则通常来源于经验的总结,就具体焊接工艺而言,焊工只有自己的经验,没有权威的操作规则可供控制器设计之用.因此,本文采用模糊辨识方法中  $C$ -均值动态聚类算法来提取脉冲 GTAW 对接过程模糊控制规则.

选定脉冲 GTAW 对接过程的被控变量为熔池反面最大熔宽  $W_{b_{max}}$ ,控制量为脉冲占空比  $\delta$ (峰值时间对脉冲周期比值的百分数),根据特别设计的实验结果,对脉冲占空比与熔池反面最大熔宽的关系进行分析和整理,得到 2 109 组归一化后的数据对.选择模糊控制系统的输入变量为  $W_{b_{max}}$  的误差  $E$  和误差变化  $CE$ ,输出变量为脉冲占空比  $CU$ ,

表 1 脉冲 GTAW 对接模糊控制规则

$CU \backslash CE$	NB	NM	NS	ZO	PS	PM	PB
NB	PB	PB	PB	PM	PS	ZO	ZO
NM	PB	PB	PM	PM	PS	ZO	ZO
NS	PB	PM	PM	PS	ZO	NS	NS
ZO	PM	PM	PS	ZO	NS	NM	NM
PS	PS	PS	ZO	NS	NM	NM	NB
PM	ZO	ZO	NS	NM	NM	NB	NB
PB	ZO	ZO	NS	NM	NB	NB	NB

每个模糊变量的模糊子集均为  $\{NB, NM, NS, ZO, PS, PM, PB\}$ ,即  $E, CE, CU$  分类个数均为七类.采用  $C$ -均值动态聚类方法<sup>[11]</sup>提取模糊控制规则如表 1 所示.

### 4.2 脉冲 GTAW 对接过程模糊神经网络控制器设计

周知,基本模糊逻辑控制器的缺点是各模糊语言变量隶属函数不易确定,模糊推理计算量大、控制律单一、无自学习和自适应能力.本文采用神经网络实现模糊控制器(Fuzzy Neural Network Controller, FNNC)以便克服上述缺点.

#### 1) FNNC 的结构

模糊系统和神经网络的融合在形态上可以将模糊系统由一等价结构的神经网络来表示,使神经网络每层、每个节点对应模糊系统的一部分,因此这里的神经网络不同于常规的黑箱型网络,它的所有节点和参数都具有一定的物理意义,对应于模糊系统的隶属函数和推理过程.




图 5 模糊神经网络构成的隶属函数

模糊语言变量各模糊子集的隶属函数采用正态形函数

$$f(x) = e^{-\frac{(x-a)^2}{b^2}} \quad (1)$$

用神经网络构成的各模糊子集的隶属函数模型如图 5 所示,图 5 中  $W_{si}$  表示

网络中 A 层到 B 层的连接权值,即精确量转化为模糊量的量化因子,B 层到 C 层的连接权值  $W_{ci}$  表示隶属函数的中心( $W_{ci}=a$ ),C 层到 D 层的连接权值  $W_{di}$  表示隶属函数的分布参数 ( $1/W_{di}=b$ ),  $f(\cdot)$  表示正态型神经元激活函数. 图 5 表示的输入输出关系为

$$\mu_j(x) = e^{-\left[\frac{(W_{si}x - W_{ci})^2}{(1/W_{di})^2}\right]} \quad (2)$$

上述结构的模糊系统可以采用图 6 所示的前向神经网络来表示,图 6 中未标出的网络节点间的连接权值为“1”. 此网络共有 8 层,其中 A~D 层将输入的精确量转换为控制规则前提部分的隶属度,E~F 层进行并行推理,G 层进行合成,H 层进行模糊判决,输出精确的控制量变化.




图 6 模糊神经网络控制器结构

设 FNNC 的第  $l$  层第  $j$  个节点的输入为  $I_j^l$ , 输出为  $O_j^l$ , 各层之间的输入输出关系可以表示如下

$$A \text{ 层: } I_j^a = x_j, O_j^a = I_j^a, j = 1, 2, x_1 = e, x_2 = ce; \quad (3)$$



$$\text{B 层: } I_j^b = W_{sj} \cdot O_j^a, O_j^b = I_j^b, j = 1, 2; \quad (4)$$

$$\text{C 层: } I_k^c = (O_j^b - W_{ck}), O_k^c = I_k^c, j = [(k-1)/7] + 1, k = 1, 2, \dots, 14; \quad (5)$$

$$\text{D 层: } I_i^d = O_i^c \cdot W_{di}, O_i^d = e^{-(I_i^d)^2}, i = 1, 2, \dots, 14; \quad (6)$$

$$\text{E 层: } I_k^e = O_i^d \cdot O_j^d, O_k^e = I_k^e, i = 1, 2, \dots, 7, j = 8, 9, \dots, 14, k = 7i + j - 14; \quad (7)$$

$$\text{F 层: 第一个节点 } I_1^f = \bigoplus_{k=1}^{49} O_k^e, O_1^f = (1/I_1^f), \quad (8)$$

$$\text{其它节点 } I_k^f = O_{k-1}^e, O_k^f = I_k^f, k = 2, 3, \dots, 50; \quad (9)$$

$$\text{G 层: } I_k^g = O_1^f \cdot O_{k+1}^f, O_k^g = I_k^g, k = 1, 2, \dots, 49; \quad (10)$$

$$\text{H 层: } I_1^h = \bigoplus_{k=1}^{49} O_k^g \cdot W_{bk}, O_1^h = I_1^h. \quad (11)$$

## 2) FNNC 的学习过程

FNNC 的学习过程分为离线学习和在线学习两部分. 网络的离线学习是为了得到输入语言变量各模糊子集初始的隶属函数, 确定 A~D 层各连接权值的初始值, 并且根据初始的模糊控制规则确定 G~H 层各节点间连接权的初始值, 以减少网络在线学习的任务. 网络的在线学习是为了通过调整网络各权值, 修改正态型隶属函数的各参数和控制规则, 使被控对象的输出逼近期望的输出值, 从而使 FNNC 能够适应对象特性的变化.

采用表 1 所示的脉冲 GTAW 对接过程 49 条模糊控制规则为模糊神经网络提供学习样本<sup>[11]</sup>. FNNC 的在线学习过程是在系统运行过程中完成的, 误差函数定义为

$$E^* = \frac{1}{2} \sum_{i=1}^n (y_i - y_d)^2 \quad (12)$$

式中  $n$  为学习样本数,  $y_i$  为被控对象的输出,  $y_d$  为给定的输出. 采用误差反传算法进行网络连接权的调整, 按梯度下降原则各层的反传误差和权值调整公式如下

H 层:

$$\delta_k^h = -\frac{\partial E^*}{\partial I_k^h} = \sum_{i=1}^n (y_i - y_d) \cdot \frac{\partial y_i}{\partial u} \cdot f'(I_k^h), \quad f'(I_k^h) = \frac{\partial O_1^h}{\partial I_k^h} = 1, \quad k = 1, 2, \dots, 49; \quad (13)$$

$$W_{bk}(t+1) = W_{bk}(t) + \eta \cdot \delta_k^h \cdot O_k^g + \alpha \cdot [W_{bk}(t) - W_{bk}(t-1)]; \quad (14)$$

G 层:

$$\delta_k^g = -\frac{\partial E^*}{\partial I_k^g} = \delta_k^h \cdot W_{bk}(t) \cdot f'(I_k^g), \quad f'(I_k^g) = \frac{\partial O_k^g}{\partial I_k^g} = 1, \quad k = 1, 2, \dots, 49; \quad (15)$$

F 层第一节点:

$$\delta_1^f = -\frac{\partial E^*}{\partial I_1^f} = \sum_{l=1}^{49} (\delta_l^g \cdot O_{l+1}^f) \cdot f'(I_1^f), \quad f'(I_1^f) = \frac{\partial O_1^f}{\partial I_1^f} = -(O_1^f)^2; \quad (16)$$

F 层其余节点:

$$\delta_k^f = -\frac{\partial E^*}{\partial I_k^f} = \delta_l^g \cdot O_1^f \cdot f'(I_k^f), \quad f'(I_k^f) = \frac{\partial O_k^f}{\partial I_k^f} = 1, \quad l = k-1, \quad k = 2, 3, \dots, 50; \quad (17)$$

E 层:

$$\delta_k^e = -\frac{\partial E^*}{\partial I_k^e} = (\delta_1^f + \delta_l^f) \cdot f'(I_k^e), \quad f'(I_k^e) = \frac{\partial O_k^e}{\partial I_k^e} = 1, \quad l = k+1, \quad k = 1, 2, \dots, 49; \quad (18)$$

D 层前七个节点:

$$\begin{cases} \delta_k^d = -\frac{\partial E^*}{\partial I_k^d} = \sum_{l=1}^7 (\delta_{7(k-1)+l}^e \cdot O_{l+7}^d) \cdot f'(I_k^d), \\ f'(I_k^d) = \frac{\partial O_k^d}{\partial I_k^d} = -2I_k^d \cdot O_k^d, \quad k = 1, \dots, 7; \end{cases} \quad (19)$$



D 层后七个节点:

$$\begin{cases} \delta_k^d = -\frac{\partial E^*}{\partial I_k^d} = \sum_{l=1}^7 (\delta_{7(l-1)+k-7}^e \cdot O_l^d) \cdot f'(I_k^d), \\ f'(I_k^d) = \frac{\partial O_k^d}{\partial I_k^d} = -2I_k^d \cdot O_k^d, k = 8, \dots, 14, \end{cases} \quad (20)$$

$$W_{dk}(t+1) = W_{dk}(t) + \eta \cdot \delta_k^d \cdot O_k^c + \alpha \cdot [W_{dk}(t) - W_{dk}(t-1)], k = 1, 2, \dots, 14; \quad (21)$$

C 层:

$$\delta_k^c = -\frac{\partial E^*}{\partial I_k^c} = \delta_k^d \cdot W_{dk}(t) \cdot f'(I_k^c), \quad f'(I_k^c) = \frac{\partial O_k^c}{\partial I_k^c} = 1, k = 1, 2, \dots, 14, \quad (22)$$

$$W_{ck}(t+1) = W_{ck}(t) + \eta \cdot \delta_k^c \cdot O_k^b + \alpha \cdot [W_{ck}(t) - W_{ck}(t-1)]; \quad (23)$$

B 层:

$$\delta_k^b = -\frac{\partial E^*}{\partial I_k^b} = \sum_{l=1}^7 \delta_{7(k-1)+l}^c \cdot f'(I_k^b), \quad f'(I_k^b) = \frac{\partial O_k^b}{\partial I_k^b} = 1, k = 1, 2, \quad (24)$$

$$W_{sk}(t+1) = W_{sk}(t) + \eta \cdot \delta_k^b \cdot O_k^a + \alpha \cdot [W_{sk}(t) - W_{sk}(t-1)]. \quad (25)$$

式(13)~(25)中,  $\delta_j^l$  为 FNNC 第  $l$  层第  $j$  节点的反传误差,  $\eta$  为学习率,  $\alpha$  为动量因子. 在 FNNC 系统运行过程中,  $\eta = 0.45$ ,  $\alpha = 0.20$ . 式(13)~(25)算法可以实现模糊神经网络权值的调整, 这是网络的一步学习算法. 在学习过程中, FNNC 中权值为 1 的连接关系不进行权值调整, 使得需要修正的权值数目大大降低. FNNC 一次学习过程中实际需要修正的权值数目只为 79 个, 耗时小于 50ms, 并且由于 FNNC 在运行之前已经进行了离线学习, 在线学习只是在初始状态附近的精细调整, 这样能更好地满足实时学习的要求.

## 5 脉冲 GTAW 对接过程控制实验

为验证所设计控制器的有效性, 在图 1 所示实验系统进行了实焊验证. 实验采用圆弧形试件模拟焊件的散热条件变化, 其几何尺寸见图 7 所示(焊接照片). 先采用恒规范焊接, 由于散热条件的变化, 在散热条件较差的中间段熔池尺寸有明显增大. 实际焊缝成形也反映了这一特点<sup>[11]</sup>.




图 7 圆弧形试件 FNNC 闭环控制焊道照片

针对圆弧形对接试件, 在给定熔池反面最大熔宽  $R$  为 6.0mm 情况下, 利用设计的 FNNC 控制器进行了闭环反馈控制实验, 占空比的最小调整单位为 1%, 脉冲 GTAW 动态过程闭环控制系统原理如图 8 所示. FNNC 控制器的输出为占空比, 脉冲 GTAW 过程输出为熔池正反面特征参数, 熔池反面最大宽度  $W_{bmax}$  为被控制量. 传感系统 MS 得到的特征信息有



$W_{fmax}, L_{fmax}, S_{fmid}, W_{fi}$  以及焊接电流、电弧电压和焊接速度等, 这些变量及其前两个脉冲的历史值共 48 个参数输入给神经网络模型 SSNNM (Size and Shape Neural Network Model), 模型输出为预测的熔池反面最大宽度  $W_{mbmax}$ ,  $W_{mbmax}$  与设定的  $W_{bmax}$  相比较得到误差  $e$ , 输入给 FNNC 控制器. 误差  $e$  根据上面介绍的误差反传学习算法修正 FNNC 控制器各层模糊神经元之间的权值, 达到控制器在线学习的目的, 实现脉冲 GTAW 过程的闭环控制.

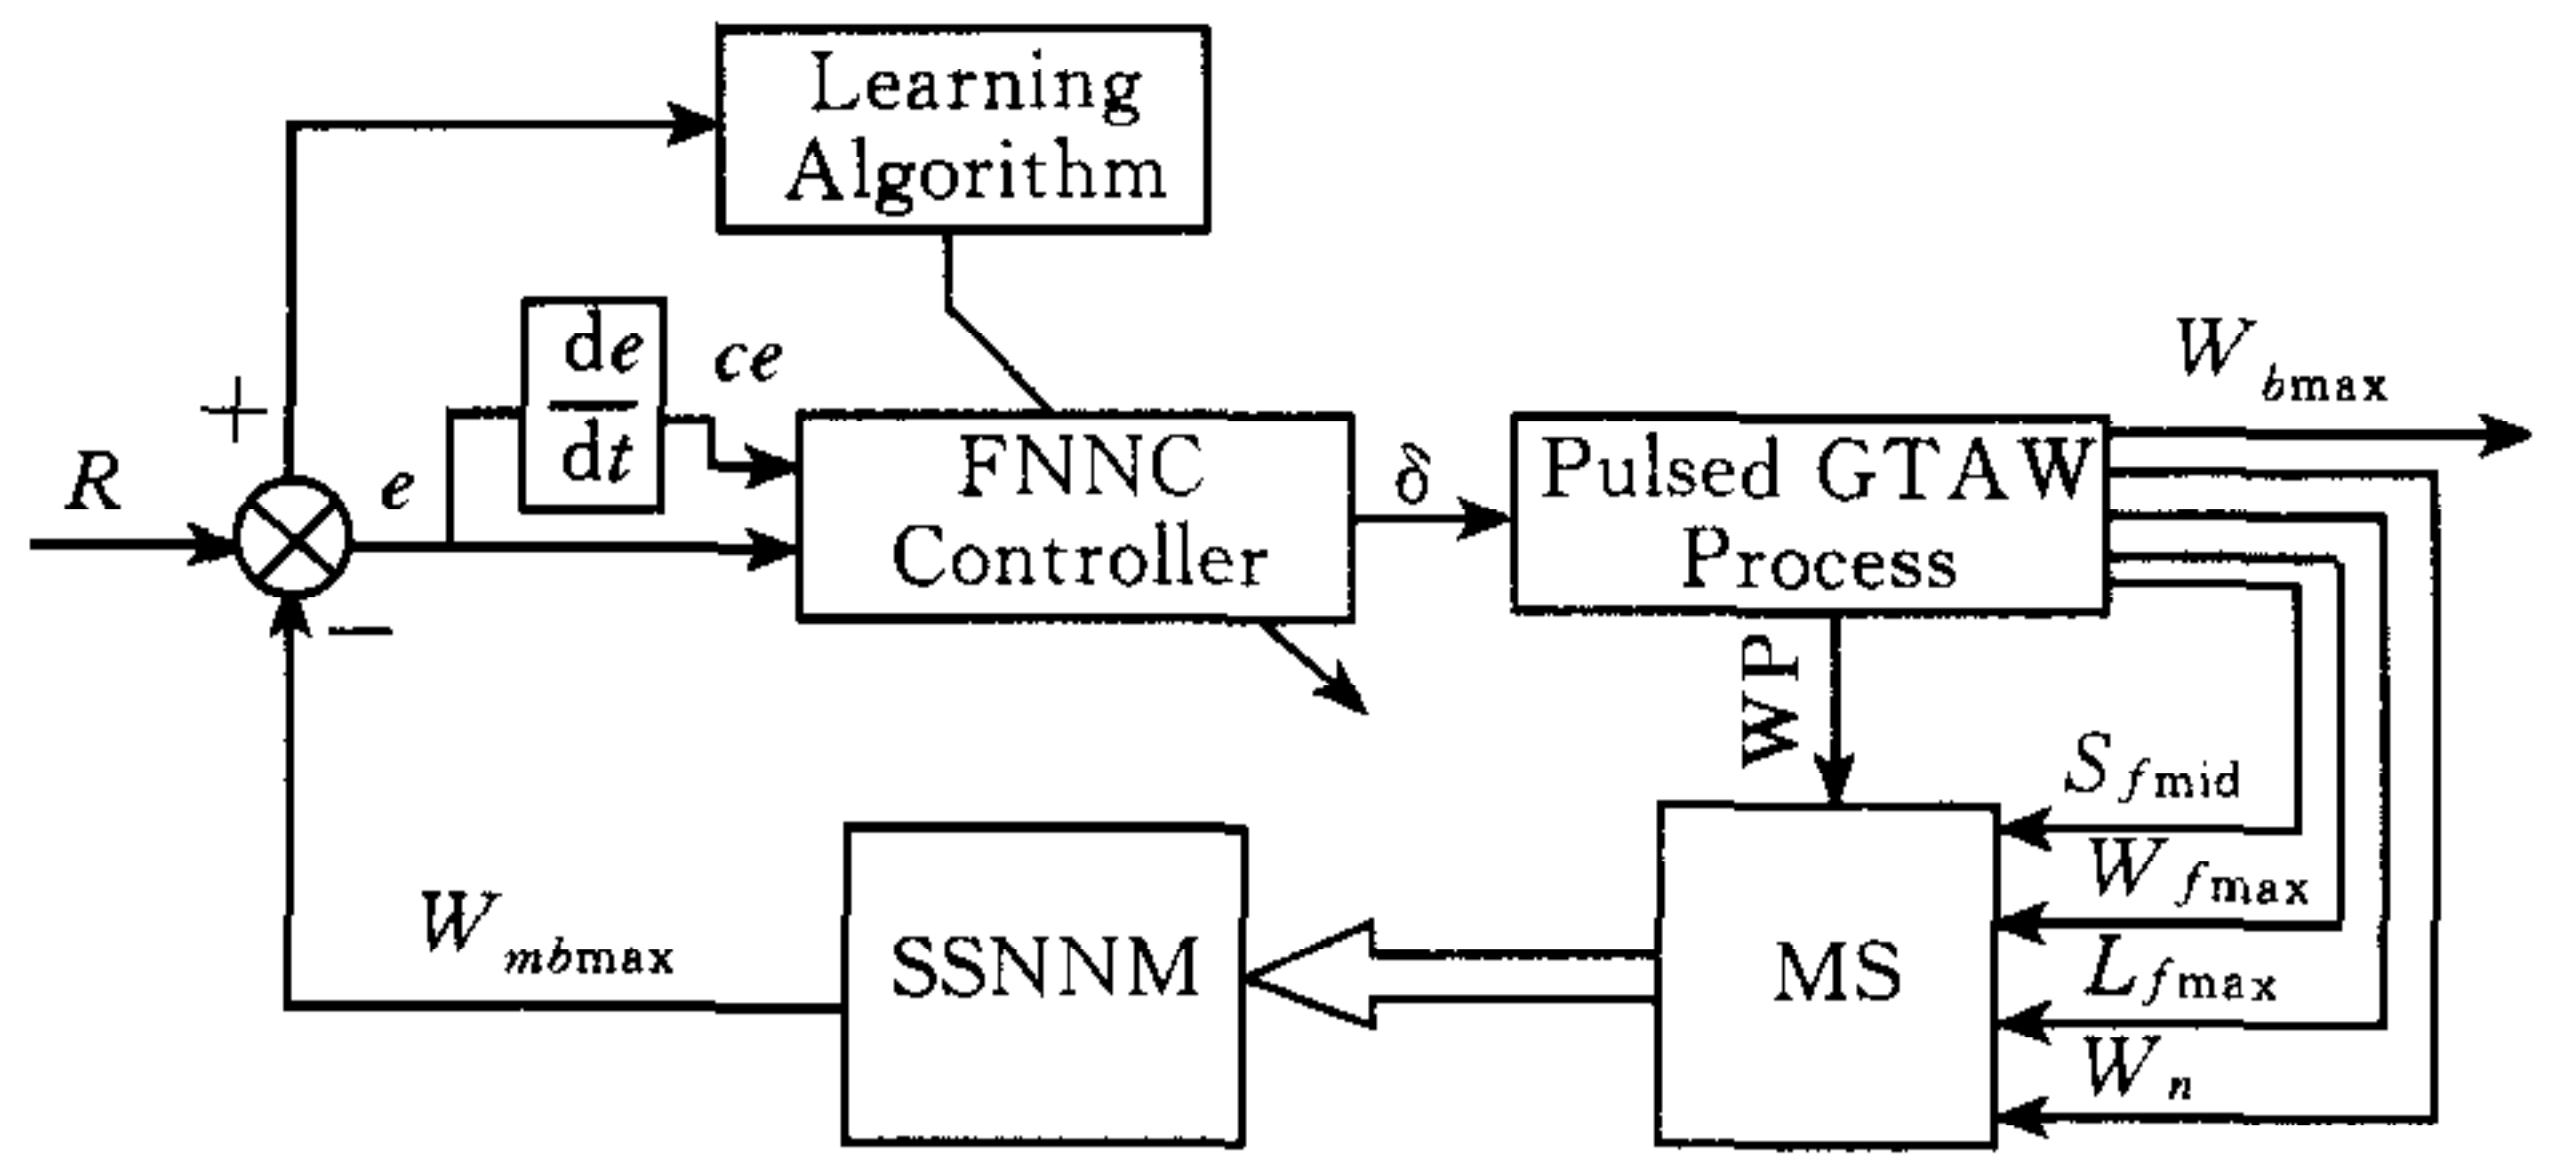


图 8 脉冲 GTAW 对接 FNNC 闭环控制系统原理图

图9为FNNC控制器得到的焊接过程曲线. 从占空比的变化过程可以看出, 由于散热条件的变化, FNNC 控制器的调整规律与有经验的焊工的焊接行为相似, 说明其具有自学习能力. 从图 9 中也可以发现由于控制器的调节作用, 熔池正面最大宽度  $W_{fmax}$  和反面最大宽度  $W_{bmax}$  基本维持在恒定值附近变化, 统计结果表明, 熔池反面熔宽最大误差为 0.46mm, 平均误差为 0.07mm, 均方根误差为 0.20mm, 这表明在脉冲 GTAW 对接过程中单独调节占空比能够保证熔池宽度方向尺寸的稳定. 而且神经网络模型 SSNNM 预测的熔池反面最

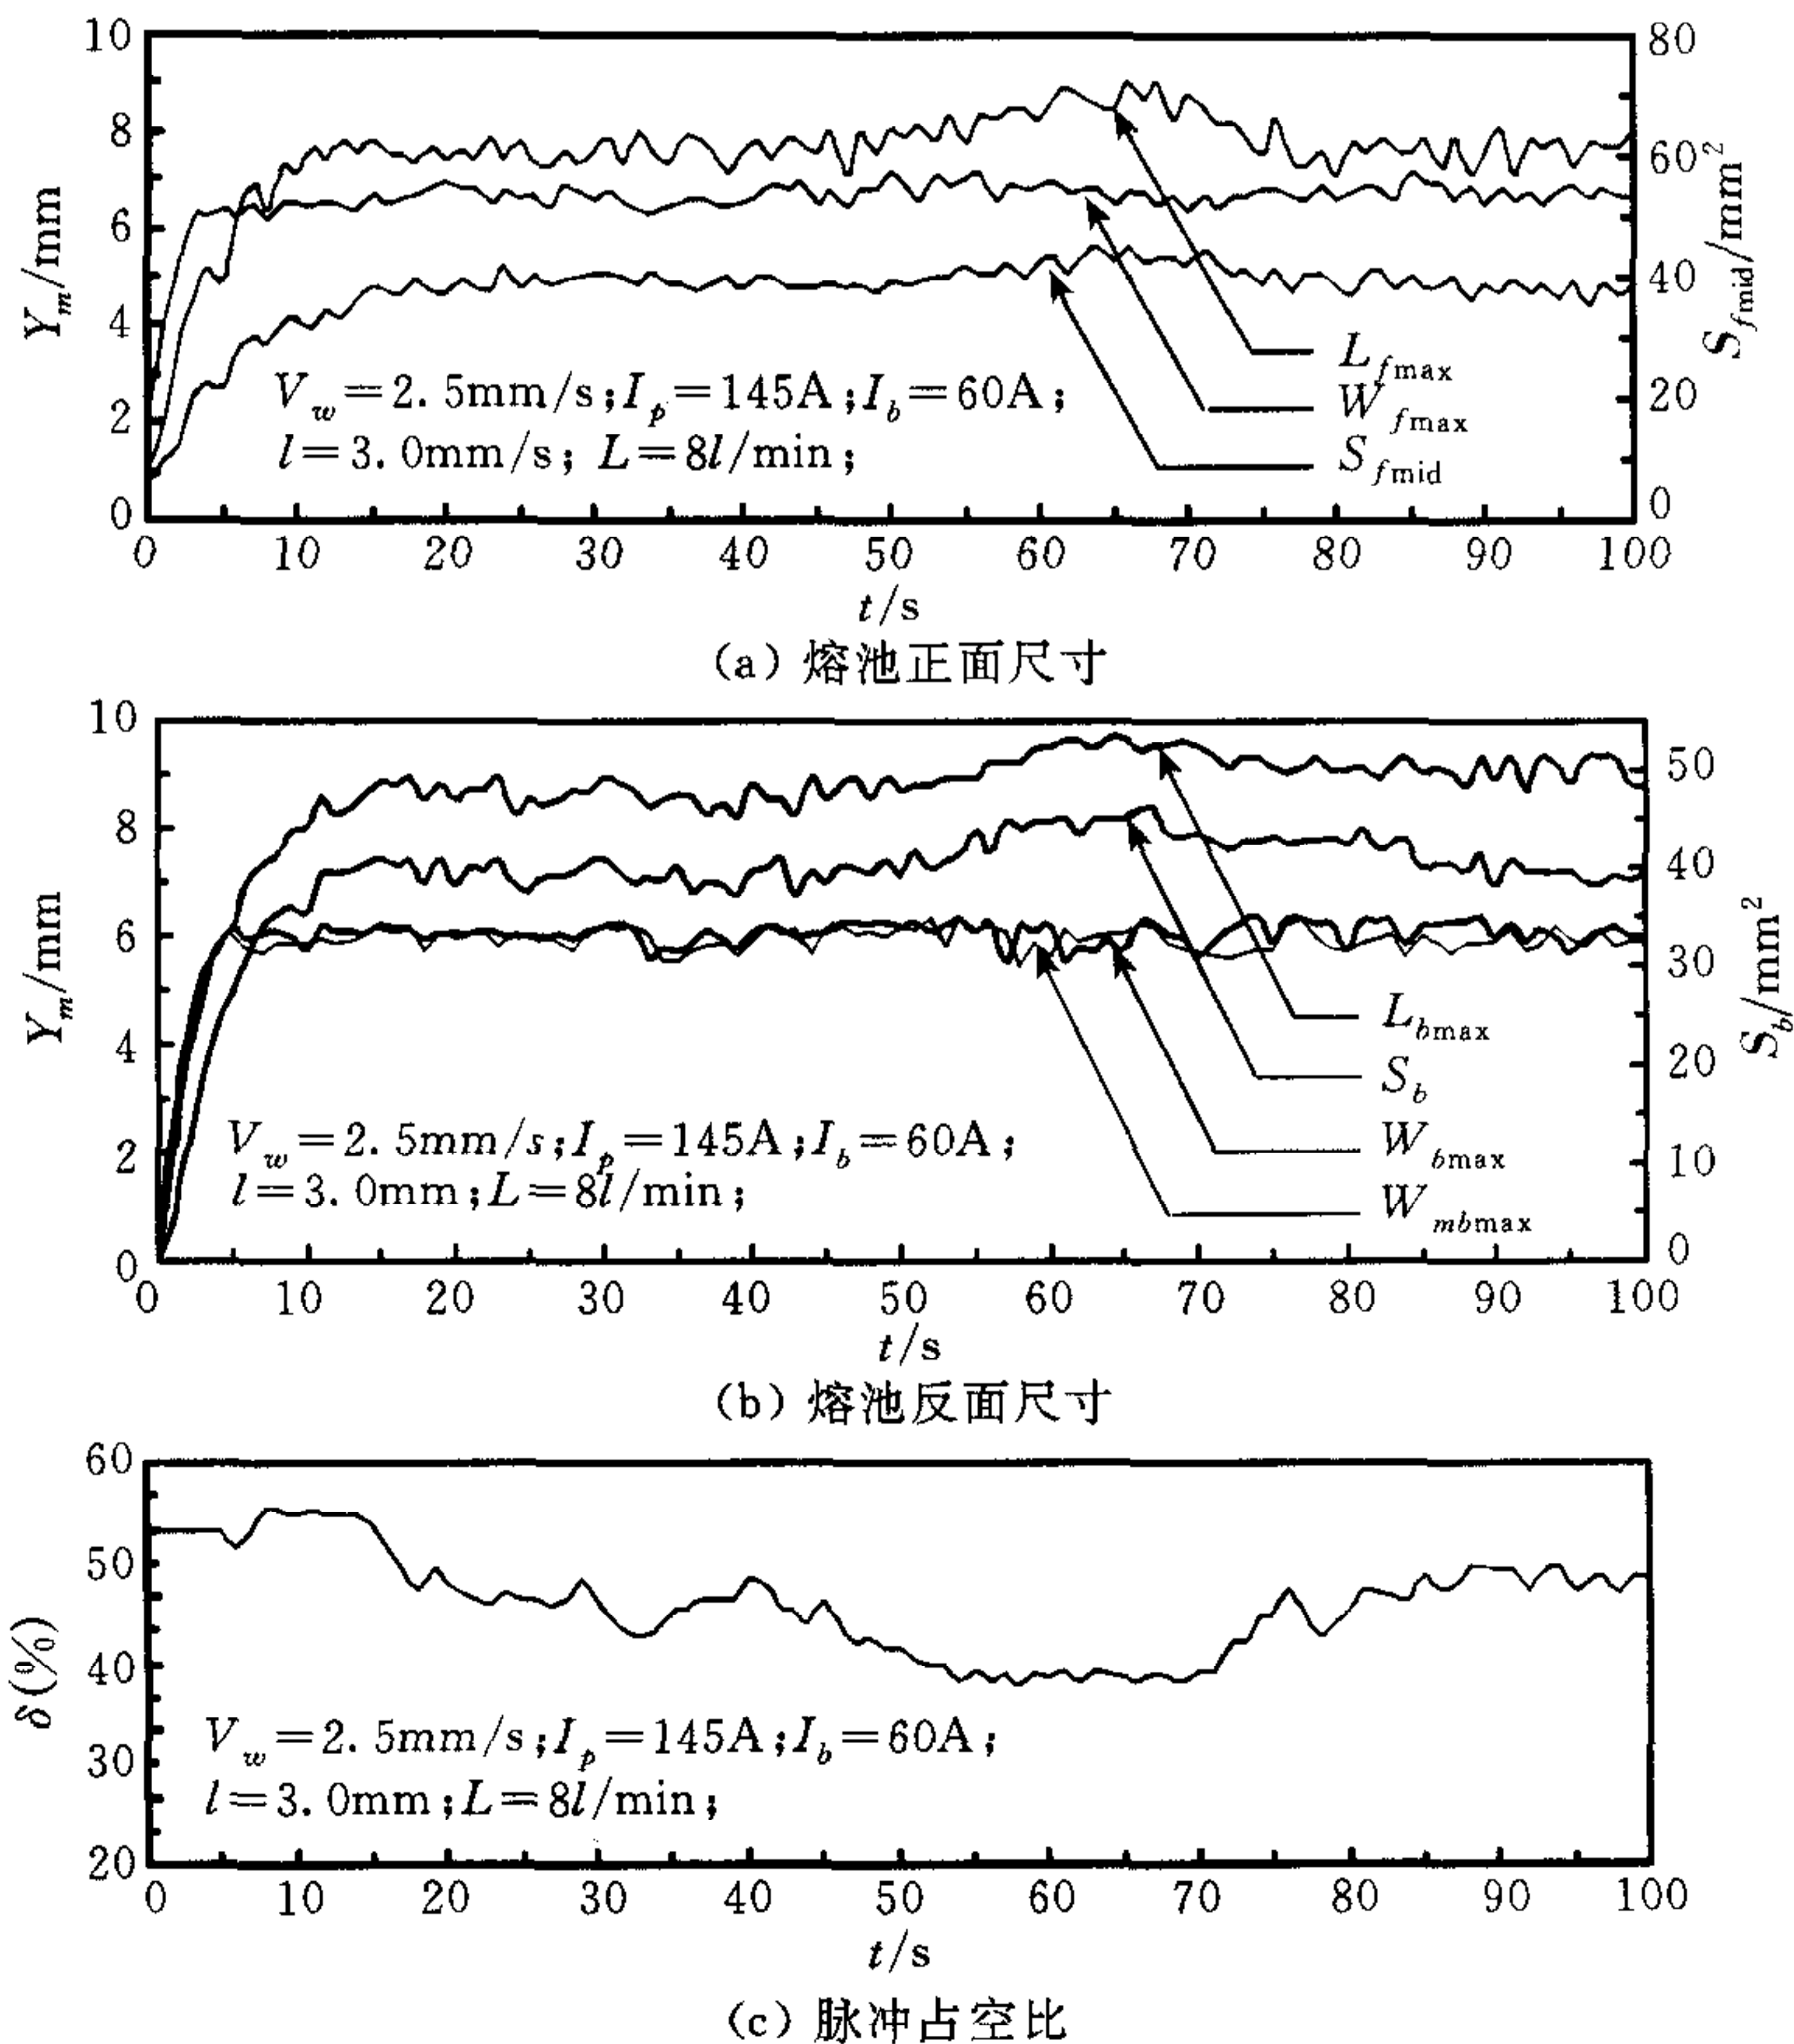


图 9 圆弧形试件脉冲 GTAW 过程 FNNC 闭环控制曲线



大宽度基本能够跟随实际的熔池反面宽度。

为了证明 FNNC 控制器的优越性,我们还进行了基本模糊控制器 FC 的脉冲 GTAW 动态过程的闭环控制实验<sup>[11]</sup>。两种控制器控制结果误差对比表明 FNNC 控制器的调节性能要优于 FC 控制器,并且观察焊道成形也发现, FNNC 控制器的成形质量要明显好于 FC 控制器。注意到图 7(b)焊道成形不够理想,这将在考虑焊速变化的多变量控制中解决。

实际焊接过程中 FNNC 控制器在线学习后得到的输入变量误差和误差变化的各模糊子集的隶属函数中心和分布参数都有一定的变化,完成了各隶属函数的在线修正问题,表明焊接过程中控制规则进行了自动修正,使 FNNC 的控制律更适应实际焊接过程的变化,从而起到智能控制的作用。

## 6 结束语

本文利用计算机视觉与图像处理技术提取焊接熔池动态特征,将模糊推理与神经网络进行了有机的结合,对脉冲 GTAW 平板对接熔池动态过程的建模与控制进行了成功地尝试。研究结果已部分地用于军用装备精密焊接制造,初步实践表明本文提出的建模与控制器设计方案在焊接精密制造以及其它复杂工业过程控制中将具有广阔前景。

## 参 考 文 献

- 1 潘际銮等. 焊选手册. 北京:机械工业出版社,1990. 130~240
- 2 Andersen K, Cook G E. Gas tungsten arc welding process control using artificial neural networks. In: Proceedings of the 3rd International Conference on Trends in Welding Research, Gatlinburg. USA: Tennessee, 1992. 135~142
- 3 Chen S B, Wu L, Wang Q L *et al.* Self-learning fuzzy neural networks and computer vision for control of pulsed GTAW. *Welding Journal*, 1997, **76**(5):201~209
- 4 Nakata S, Huang J, Tsuruha Y. Visual sensing system for in-process control of arc welding process. *Welding International*, 1988, **2**(12):1086~1090
- 5 Chen S B, Wu L. Fuzzy neural networks for control of uncertainty systems with time delays. In: Proceedings, Fifth IEEE Int. Conf. on Fuzzy Systems, FUZZ'96. USA; New Orleans, 1996. **2**:1171~1176
- 6 黄石生, 李迪. 焊接过程的神经网络建模及控制的研究. 机械工程学报, 1994, **30**(3):24~29
- 7 Kovacevic R, Zhang Y M. Neurofuzzy model-based weld fusion state estimation. *IEEE Transactions Control Systems Technology*, 1997, **5**(4):30~42
- 8 Lim T G, Cho H S. Estimation of weld pool sizes in GMA welding process using neural networks. *Journal of Systems and Control Engineering*, 1993, **207**(1):15~26
- 9 张裕明. TIG 焊熔透正面视觉自适应控制的研究[博士学位论文]. 哈尔滨:哈尔滨工业大学, 1990
- 10 Suga Y, Naruse M. Application of neural network to visual sensing of weld line and automatic tracking in robot welding. *Welding in the World*, 1994, **34**:275~284
- 11 娄亚军. 基于图像传感的脉冲 GTAW 熔池动态过程的智能控制方法研究[博士学位论文]. 哈尔滨:哈尔滨工业大学, 1999

**陈善本** 1991年3月获哈尔滨工业大学控制理论与应用专业博士学位。曾任哈尔滨工业大学教授、博士生导师。现为教育部“长江学者奖励计划”特聘教授,受聘于上海交通大学材料加工工程学焊接所。主要从事机器人焊接智能化技术、焊接过程智能控制和不确定系统鲁棒控制理论及其学科交叉领域的研究。