

基于结构上下文的模糊神经网络 自动目标检测方法

瞿继双¹⁾ 徐德坤¹⁾ 王超²⁾

¹⁾(第二炮兵装备研究院第三研究所,北京 100085) ²⁾(中国科学院遥感应用研究所,北京 100101)

摘要 提出了一种基于结构上下文的模糊神经网络(SCFNN)自动目标检测方法。模糊神经网络方法既具有神经网络的自适应性、并行性、鲁棒性、容错性、优化等优点,又集成了模糊集理论运用知识、规则描述解决系统不确定性的优点,因此成为图像处理和模式识别的一种强有力工具。使用模糊测度作为神经网络的目标函数可以有效地描述像素类别的不确定性,从而通过使其最小实现图像分类优化。对网络神经元加权过程进行结构上下文信息约束可以充分减小图像信息尤其是目标边缘等特性包含丰富信息的损失,有效地保持目标的轮廓和形状等属性,改善目标检测的误检率。针对目标遥感图像的实验,验证了SCFNN方法具有很好的自动目标检测能力,而相对于传统神经网络方法,具有有效的不确定性解决能力和更好的目标形状保持能力。

关键词 目标检测 模糊神经网络 模糊测度 权值校正 结构上下文

中图分类号: TP183 **文献标识码**: A **文章编号**: 1006-8961(2004)10-1169-06

Structure-context Based Fuzzy Neural Network Approach for Automatic Target Detection

QU Ji-shuang¹⁾, XU De-kun¹⁾, WANG Chao²⁾

¹⁾(The Third Research Institute of Arming Academy, Second Artillery, Beijing 100085)

²⁾(Institute of Remote Sensing Applications, Chinese Academy of Sciences, Beijing 100101)

Abstract This paper proposes a structure-context based fuzzy neural network (SCFNN) approach for automatic target detection. Fuzzy neural network methods not only possess advantages as adaptivity, parallelism, robustness, ruggedness, and optimality, but integrate advantages as depicting and solving system uncertainty by knowledge and rules of fuzzy set theory. Accordingly, they are powerful tools for image processing and pattern recognition. Use fuzziness measures as objective function of neural network can depict uncertainty of pixels' category validly so as to optimize image classification by minimizing the objective function. Putting information constraint of structure context on neurons' weighting process can reduce loss of image information, especially, the rich information comprised by target edges, by which target's attributes such as profile and shape can be retained validly, and the false detection rate can also be improved prominently. Experiments on remotely sensed images of target are executed to validate SCFNN approach. The results exhibit that SCFNN possesses good ability to automatic target detection, simultaneously, possesses valid abilities to eliminating uncertainty and retaining target shape compared with conventional neural network methods.

Keywords target detection, fuzzy neural network, fuzziness measure, weight correction, structure context

1 引言

目标检测和提取是图像分析的一个重要过程,也是进一步进行目标识别的前提。神经网络方法具

有自适应性、快速性、鲁棒性、优化等优点,因此已经越来越多地用于解决图像处理和模式识别中的问题和挑战^[1~5]。然而,神经网络方法同样面临着大多数方法共同存在的对图像处理、模式识别等实际应用中的不确定性问题无能为力的不足。为了解决这种

缺陷,神经网络与模糊集理论的集成被逐步提出,并获得了成功的应用^[6~11]。模糊集理论可以有效地运用知识、规则描述解决系统存在的某些不确定性问题,从而可以用于解决图像处理和模式识别过程中出现的不确定性^[12]。

图 1 示出了一种典型的模糊神经网络系统模型,神经网络的输出用于调节模糊系统的成员函数,从而影响决策制定。而决策结果又作为反馈信息来影响神经网络的学习算法,改变神经网络系统的状态(即神经元之间的连接权值)。神经网络与模糊系统的集成能够充分利用它们各自的优点,诸如可并行性、鲁棒性、自学习性、对非精确和不确定问题的描述解决等,从而建立更为智能的决策系统。




图 1 一种典型模糊神经网络系统模型

Ghosh 等人提出了一种使用模糊测度校正多层神经网络权值的方法以实现自组织目标提取^[13]。该方法用于目标提取时具有很好的检测正确率和漏检率,然而不幸的是,该方法对目标的误检率也比较高。

本文在 Ghosh 方法的基础上提出了一种基于目标结构上下文信息的模糊神经网络(SCFNN, structure-context based fuzzy neural network),利用模糊测度来描述多层前馈神经网络的输出目标函数,从而在偏差反向传播时制约网络权值的更新,实现非监督分类的目的,生成高度非线性的决策边界。在更新网络权值的过程中,利用基于目标结构的局部上下文信息,从而更好地保留目标的形状结构特性,有效地减小了目标检测的误检率,同时,漏检率尽管有所增加,但仍控制在较小的范围内。实验结果表明该方法在检测目标时误检率有了显著改善。

2 模糊测度

对于模糊集 A ,模糊测度用于度量确定元素是否属于 A 的模糊程度。模糊集 A 的模糊测度 $M(A)$ 具有以下性质:

- (1) $I(A) = \text{minimum}$ 当且仅当 $\mu_A(x_i) = 0$ 或 $1, \forall i$;
- (2) $I(A) = \text{maximum}$ 当且仅当 $\mu_A(x_i) =$

$0.5, \forall i$;

(3) $I(A) \geq I(A^*)$ 其中 A^* 为 A 的锐化,定义为

$$\mu_{A^*}(x_i) \begin{cases} \geq \mu_A(x_i) & \mu_A(x_i) \geq 0.5 \\ \leq \mu_A(x_i) & \mu_A(x_i) \leq 0.5 \end{cases}$$

(4) $I(A) = I(A^c)$ 其中 A^c 为 A 的补集。

其中, $\mu_A(x_i)$ 为 x_i 属于模糊集 A 的隶属度函数。

常用的几种模糊测度有:

(1) 线性指标测度

$$v_l(A) = \frac{2}{n} \sum_{i=1}^n |\mu_A(x_i) - \mu_{\underline{A}}(x_i)|$$

$$= \frac{2}{n} \sum_{i=1}^n [\min\{\mu_A(x_i), (1 - \mu_A(x_i))\}] \quad (1)$$

其中, $\mu_A(x_i) = \begin{cases} 0 & \mu_A(x_i) \leq 0.5 \\ 1 & \mu_A(x_i) > 0.5 \end{cases}$

(2) 二次指标测度

$$v_q(A) = \frac{2}{\sqrt{n}} \sqrt{\left[\sum_{i=1}^n \{\mu_A(x_i) - \mu_{\underline{A}}(x_i)\}^2 \right]} \quad (2)$$

(3) 对数熵测度

$$H(A) = -\frac{1}{n \ln(2)} \sum_{i=1}^n \{ \mu_A(x_i) \ln \mu_A(x_i) + (1 - \mu_A(x_i)) \ln (1 - \mu_A(x_i)) \} \quad (3)$$

(4) 指数熵测度

$$H(A) = \frac{1}{n(\sqrt{e} - 1)} \sum_{i=1}^n \{ \mu_A(x_i) e^{1 - \mu_A(x_i)} + (1 - \mu_A(x_i)) e^{\mu_A(x_i)} - 1 \} \quad (4)$$

3 SCFNN 网络结构及其权值校正

SCFNN 方法是一种使用后向传播偏差的前馈神经网络,但与传统 MLP (multi-layer perceptron: 多层感知器) 方法不同的是,由于利用了基于目标结构的局部上下文信息,并使用与输出相关的模糊测度作为目标函数校正神经元之间的连接权值,因此该方法具有自组织特性,不需要监督学习。这种特性对于自动目标检测是非常有用的。

3.1 SCFNN 结构

图 2 所示为 SCFNN 网络结构,该网络包括输入层、输出层和多个中间层,每一层的神经元阵列与输入图像对应,即每个神经元对应处理一个像素。除了输入层外,每一层中的神经元与它前一层对应的神经元以及该神经元的邻域连接,这些连接神经元对应的像素点以集合 N 表示。邻域区域与距离定义模式相关,例如对于 Euclidean 距离,距离 $d=1$ 的邻域为其

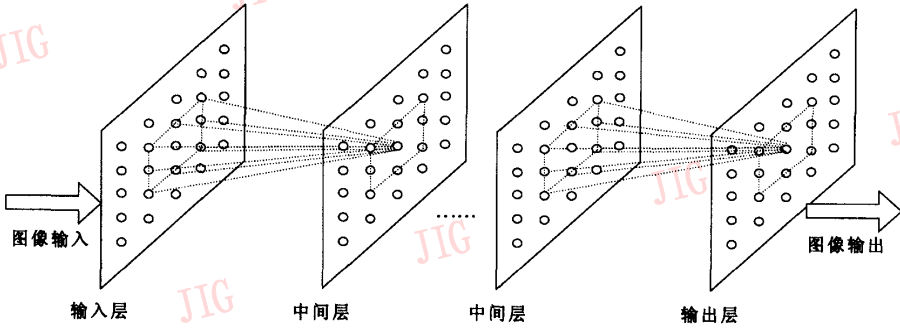


图 2 SCFNN 网络结构

周围 4 个距离为 1 的像素点,而使用栅格距离,距离 $d=1$ 的邻域则是其周围 8 个距离为 1 的像素点。

3.2 MLP 网络权值校正

MLP 通常包括输入层、输出层和一定数量的隐藏层,由简单的二值状态、激励函数作用的神经元组成,神经元之间由权值连接,每一层中的神经元之间相互不连接,而只是与前后层的神经元连接。

对于 SCFNN 网络的 $l+1$ 层,其第 j 个神经元的输入为

$$x_j^{(l+1)} = \sum_{i \in N} \omega_{ji}^{(l)} y_i^{(l)} - \theta_j^{(l+1)} \quad (5)$$

式中, $y_i^{(l)}$ 是 l 层第 i 个神经元的输出, $\omega_{ji}^{(l)}$ 是从神经元 i 到神经元 j 的连接权值, $\theta_j^{(l+1)}$ 是作用于神经元 j 的阈值。

除了输入层外,对于其他任意层的神经元具有激励功能,激励函数由以下单调非线性函数给出

$$y_j^{(l)} = \frac{1}{1 + e^{-x_j^{(l)}}} \quad (6)$$

对于特定的网络目标函数 $E(\omega)$,为了使 $E(\omega)$ 最小,可以采用梯度下降法,即使网络权值变化量为

$$\Delta \omega_{ji}^{(l)}(t+1) = -\epsilon \frac{\partial E}{\partial \omega_{ji}} + \alpha \Delta \omega_{ji}^{(l)}(t) \quad (7)$$

式中, ϵ 为控制下降速度的正常量, α 为衰减系数, $\alpha \Delta \omega_{ji}^{(l)}(t)$ 称为动量项,用于控制合理的收敛速度,同时使系统稳定。

由式(5)和式(6)有:

$$\frac{\partial E}{\partial \omega_{ji}} = \frac{\partial E}{\partial y_j} \frac{dy_j}{dx_j} \frac{dx_j}{d\omega_{ji}} = \frac{\partial E}{\partial y_j} y_j^{(l)} (1 - y_j^{(l)}) y_i^{(l-1)} \quad (8)$$

3.3 利用模糊测度校正网络权值

SCFNN 方法使用模糊测度作为网络的目标函数可以充分考虑到图像目标检测分类处理中像素分类的不确定性,从而使这种不确定性获得优化。

由式(1)可得网络的线性指标测度目标函数为

$$E(\omega) = g(v_i) = v_i = \frac{2}{n} \sum_{j=1}^n [\min\{y_j, 1 - y_j\}] \quad (9)$$

则由式(5)~式(9),有网络的权值校正为

$$\Delta \omega_{ji}(t+1) = \begin{cases} \text{如果 } 0 \leq y_j \leq 0.5 \\ -\frac{2}{n} \epsilon \frac{dy_j}{dx_j} y_j + \alpha \Delta \omega_{ji}(t) \\ \text{如果 } 0.5 < y_j \leq 1 \\ \frac{2}{n} \epsilon \frac{dy_j}{dx_j} y_j + \alpha \Delta \omega_{ji}(t) \end{cases} \quad (10)$$

同样,由式(2),有二次指标测度目标函数为

$$E(\omega) = g(v_q) = v_q^2 = \left[\frac{2}{\sqrt{n}} \sqrt{\left[\sum_{j=1}^n \{\min(y_j, 1 - y_j)\}^2 \right]} \right]^2 = \frac{4}{n} \left[\sum_{j=1}^n \{\min(y_j, 1 - y_j)\}^2 \right] \quad (11)$$

类似地,网络权值校正为

$$\Delta \omega_{ji}(t+1) = \begin{cases} \text{如果 } 0 \leq y_j \leq 0.5 \\ -\frac{8}{n} \epsilon y_j \frac{dy_j}{dx_j} y_j + \alpha \Delta \omega_{ji}(t) \\ \text{如果 } 0.5 < y_j \leq 1 \\ \frac{8}{n} \epsilon (1 - y_j) \frac{dy_j}{dx_j} y_j + \alpha \Delta \omega_{ji}(t) \end{cases} \quad (12)$$

由式(3),有对数熵测度的网络目标函数为

$$E(\omega) = g(H) = H = -\frac{1}{n \ln(2)} \times \sum_{j=1}^n \{y_j \ln y_j + (1 - y_j) \ln(1 - y_j)\} \quad (13)$$

于是有

$$\frac{\partial E}{\partial y_j} = -\frac{1}{n \ln(2)} \ln \frac{y_j}{1 - y_j} \quad (14)$$

考虑到

$$\Delta \omega_{ji} \propto -\frac{\partial E}{\partial y_j} \left| \frac{\partial E}{\partial y_j} \right|^q, q > 1 \quad (15)$$

式(15)中的分母部分相当于一个尺度因子,对权值校正的方向并不产生影响。取 $q=2$,网络权值校正为

$$\Delta\omega_{ji}(t+1) = \begin{cases} \text{如果 } 0 \leq y_j \leq 0.5 \\ -\epsilon \frac{1}{\ln\left(\frac{y_j}{1-y_j}\right)} \frac{dy_j}{dx_j} y_i + a\Delta\omega_{ji}(t) \\ \text{如果 } 0.5 < y_j \leq 1 \\ \epsilon \frac{1}{\ln\left(\frac{y_j}{1-y_j}\right)} \frac{dy_j}{dx_j} y_i + a\Delta\omega_{ji}(t) \end{cases} \quad (16)$$

对于指数熵测度有

$$E(\omega) = g(H) = H = \frac{1}{n(\sqrt{e} - 1)} \times \sum_{j=1}^n \{y_j e^{1-y_j} + (1-y_j)e^{y_j} - 1\} \quad (17)$$

经过类似式(14)、式(15)的处理,取 $q=2$,有网络权值校正为

$$\Delta\omega_{ji}(t+1) = \begin{cases} \text{如果 } 0 \leq y_j \leq 0.5 \\ -\epsilon \frac{1}{(1-y_j)e^{1-y_j} - y_j e^{y_j}} \frac{dy_j}{dx_j} y_i + a\Delta\omega_{ji}(t) \\ \text{如果 } 0.5 < y_j \leq 1 \\ \epsilon \frac{1}{(1-y_j)e^{1-y_j} - y_j e^{y_j}} \frac{dy_j}{dx_j} y_i + a\Delta\omega_{ji}(t) \end{cases} \quad (18)$$

4 结构上下文信息约束

在应用 FNN 方法进行目标检测时,从式(5)知计算神经元输入 $x_j^{(t+1)}$ 是通过对该神经元对应的像素集 N 进行加权得到的,因此该方法在检测目标时具有很好的漏检率,同时也具有良好的噪声免疫力。

图像的边缘往往包含丰富的特征属性,包括目标的轮廓结构和形状结构信息等,因此在检测目标时应充分考虑到这些边缘结构信息。上述加权处理也造成了图像真实信息尤其是目标边缘结构特性信息的损失,往往导致较大的误检率。

因此,在 FNN 方法的基础上,可以利用目标的结构上下文信息来约束加权处理,即对目标边缘附近的像素加权处理进行约束。图像的边缘检测可以通过效果较好的 Laplacian-Gaussian 算子或 Canny 算子来获取。

设图像的边缘像素集为 Ω ,则对边缘像素点进行加权处理可以通过如下约束实现。

$$x_j^{(t+1)} = \sum_{i \in N \cap \Omega} \omega_{ji}^{(t)} y_i^{(t)} - \theta_j^{(t+1)} \quad (19)$$

而对于非边缘像素,如图 3 所示,设白色像素为



图 3 边缘附近区域的非边缘像素约束

非边缘,黑色像素为边缘,则当非边缘像素对应的集合 N 中没有出现图 3 所示情形时,即非边缘像素在 N 区域中以 4 连通模式是连通的,其处理过程可以通过如下约束加权实现。

$$x_j^{(t+1)} = \sum_{i \in N \cap \bar{\Omega}} \omega_{ji}^{(t)} y_i^{(t)} - \theta_j^{(t+1)} \quad (20)$$

其中, $\bar{\Omega}$ 为边缘像素集 Ω 的补集。

若非边缘像素在集合 N 中以 4 连通模式是不连通的,即出现类似图 3 中任意情形,设被分离的非边缘像素集合为 Θ ,则该非边缘像素处理可以通过如下约束加权实现。

$$x_j^{(t+1)} = \sum_{i \in (N \cap \bar{\Omega}) \setminus \Theta} \omega_{ji}^{(t)} y_i^{(t)} - \theta_j^{(t+1)} \quad (21)$$

通过式(19)~式(21),利用目标结构上下文信息对像素加权处理进行约束,SCFNN 方法应用于目标检测时将具有更好的目标轮廓、形状等结构信息保持能力,从而显著改善目标检测的误检率。当然,这种误检率的改善是以增加目标漏检率为代价的。不过 SCFNN 方法的漏检率仍然是相当小的。

5 实验结果分析

对 SCFNN 方法进行针对目标遥感图像的实验验证分析。在图像数据输入网络之前,首先对数据进行正则化处理,使输入数据处于 $[0,1]$ 区间。

实验过程中,除了输入层和输出层外,网络使用 3 个中间层。算法中的参数 $\epsilon=0.1, \alpha=0.1$,邻域距离 $d=1$ 。

5.1 实验结果

实验结果如图 4 所示。从图中可以看出 FNN 方法和 SCFNN 方法均能有效地检测出图像中的目标,为进一步自动目标识别打下基础。这两种算法也都具有良好的噪声免疫力,在较恶劣的噪声干扰下仍然具有较好的检测效果。不过相对而言,由于 SCFNN 方法引入了边缘提取过程,因此 FNN 方法具有更好的噪声滤除特性。另外,从图 4 中还可看出,目标 1 左上方的目标 2 在 FNN 方法处理后与目标 1 连为一体,而在 SCFNN 方法处理后仍然可以

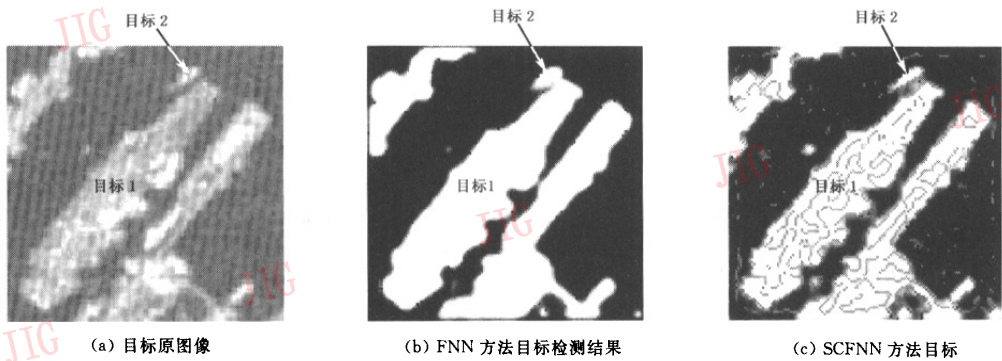


图 4 目标遥感图像实验结果(均使用指数熵模糊测度作目标函数)

清晰地二者区分开。

5.2 结果评估

设目标标准面积为 A_{ST} , 检测目标面积为 A_{DT} , 它们均通过在相应的图像中使用目标边缘提取方法提取目标轮廓后人工分析获取。定义以下检测指标:

正确检测面积 A_{AD} : 标准目标与检测结果目标重叠区域的面积;

$$\text{检测正确率: } \gamma = \frac{A_{AD}}{A_{ST}} \quad (22)$$

$$\text{误检率: } \xi = \frac{|A_{DT} - A_{AD}|}{A_{ST}} \quad (23)$$

$$\text{漏检率: } \zeta = \frac{|A_{ST} - A_{AD}|}{A_{ST}} \quad (24)$$

上述面积统计量均以像素为单位。

表 1 给出了 FNN 方法和 SCFNN 方法目标检测结果的定量评估及其比较。从表中可以得出结论, 无论是 FNN 方法, 还是 SCFNN 方法, 二次指标测度作为目标函数都具有最好的目标检测正确率和漏检率, 同时, 它的误检率也是最高的。对数熵测度作为目标函数则具有相对较低的检测正确率和较差的漏检率。指数熵测度作为目标函数则具有最好的误检率, 而其检测正确率和漏检率也是比较中性的。

另外, FNN 方法具有更高的检测准确率和漏检率, 两者分别接近 100% 和 0, 而 SCFNN 方法则稍低一些。但是 FNN 方法对目标的误检率是比较高的, 均达到 10% 左右, 而 SCFNN 方法则显著地改善了误检率, 而且具有可以接受的检测正确率和漏检率。

表 1 FNN 方法与 SCFNN 方法处理结果定量分析 ($A_{ST} = 2825$)

目标函数	FNN 方法				SCFNN 方法			
	线性指标测度	二次指标测度	对数熵测度	指数熵测度	线性指标测度	二次指标测度	对数熵测度	指数熵测度
A_{DT} (像素)	3135	3171	3087	3076	2971	3000	2971	2900
A_{AD} (像素)	2820	2820	2810	2815	2791	2794	2768	2776
γ (%)	99.82	99.82	99.47	99.65	98.80	98.90	97.98	98.27
ξ (%)	11.72	12.42	9.81	9.24	6.37	7.29	5.27	4.39
ζ (%)	0.18	0.18	0.53	0.35	1.20	1.10	2.02	1.73

6 结 论

基于结构上下文信息的模糊神经网络自动目标检测方法, 建立在模糊测度作为目标函数的基础上, 在对神经元进行加权计算处理时, 利用图像中目标的结构上下文信息对参与计算的神经元进行约束, 从而使目标检测结果保持了更好的轮廓和形状。

实验结果表明, 使用指数熵测度作为目标函数具有更低的误检率, 而 SCFNN 方法相对 FNN 方法

而言, 尽管目标检测正确率和漏检率性能略有下降, 但是它们仍然是可以接受的, 最重要的是, SCFNN 方法显著地改善了目标检测的误检率。

参 考 文 献

- Basak J, Murthy C A, Pal S K. Self-organizing network for mixed category perception[J]. Neurocomputing, 1996, 10(4): 341~358.
- Widrow B, Winter R. Neural network for adaptive filtering and adaptive pattern recognition[J]. IEEE Computer, 1988, 21(3): 25~39.

- 3 Carpenter G A, Grossberg S. The ART of adaptive pattern recognition by a self organizing neural network [J]. IEEE Computer, 1988, 21(3):77~88.
- 4 Huntsberger T L, Ajjimarangsee P. Parallel self-organizing feature maps for unsupervised pattern recognition [J]. International Journal of General Systems, 1990, 16(4):357~372.
- 5 桑农, 张天序. 基于 Hopfield 神经网络的 FLIR 图像分割[J]. 自动化学报, 2001, 27(3):303~309.
- 6 Pal S K, Mitra S. Neuro-Fuzzy Pattern Recognition-Methods in Soft Computing[M]. Now York, John Wiley & Sons, Inc, 1999.
- 7 Takagi H. Fusion technology of fuzzy theory and neural network-survey and future direction[A]. In: Proceedings of the 1990 International Conference on Fuzzy Logic and Neural Networks[C], Iizuka, Japan, 1990:13~26.
- 8 Tsao E, Bezdek J C, Pal N R. Fuzzy Kohonen clustering networks[J]. Pattern Recognition, 1994, 27(5):757~764.
- 9 Pal S K, Mitra S. Multi-layer perception, fuzzy sets and classification [J]. IEEE Transactions on Neural Networks, 1992, 3(5):683~697.
- 10 Pal S K, Ghosh A. Neuro-fuzzy computing for image processing and pattern recognition [J]. International Journal of Systems Science, 1996, 27(12):1179~1193.
- 11 Mitra S, Pal S K. Self-organizing neural network as a fuzzy classifier [J]. IEEE Transactions on Systems, Man and Cybernetics, 1994, 24(3):385~399.
- 12 Pedrycz W. Fuzzy sets in pattern recognition: Methodology and methods[J]. Pattern Recognition, 1990, 23(1):121~146.
- 13 Ghosh A, Pal N R, Pal S K. Self-organization for object extraction using multilayer neural network and fuzziness measures [J]. IEEE Transactions on Fuzzy Systems, 1993, 1(1):54~68.



瞿继双 1974 年生。助理研究员。1996、1999、2002 年在国防科学技术大学自动控制系分别获得学士、硕士和博士学位。主要感兴趣方向为飞行器控制与制导、图像处理与数据融合、模式识别与智能控制等。
E-mail: milan09@vip. sina. com



徐德坤 1964 年生。研究员。1986 年、1989 年在北京航空学院自动控制系陀螺与惯性导航专业分别获得学士和硕士学位。目前正在攻读国防科学技术大学博士学位。主要研究方向为飞行器控制与制导、精确制导与惯性器件。



王超 1963 年生。研究员、博士生导师。1989 年于南京大学获理学博士。主要研究领域为微波遥感、InSAR 测量技术等。