

基于特征的模糊神经网络遥感图像目标分类识别

瞿继双, 瞿松柏, 王自杰

第二炮兵装备研究院 北京 100085

摘要: 特征是图像处理中用于辨识目标的最基本属性。提出了利用模糊神经网络方法, 针对舰船的几何特征、矩特征和纹理特征进行舰船目标识别处理。首先简单地描述了几何特征、矩特征尤其是 H^u 矩特征、一阶纹理特征和二阶纹理特征。然后分别对仿真数据、卫星观测数据中的舰船目标, 以及自动检测处理获取的舰船目标的几何特征、 H^u 矩特征和纹理特征进行了提取和分析。模糊神经网络方法可以综合模糊集理论和神经网络方法的优势, 有效地实现基于特征的图像目标分类识别处理。文章首先描述了一种主从神经元结构的模糊神经网络分类识别方法, 然后利用该方法对大型舰船进行分类识别, 包括基于单类舰船特征的分类识别和基于多源(时相)数据融合的分类识别。实验结果表明, 基于大型舰船的几何特征、矩特征和纹理特征, 利用模糊神经网络方法可以实现对大型舰船目标的有效分类识别。通过多源数据融合处理, 可以改善分类识别效果。

关键词: 模糊神经网络, 舰船目标, 分类识别, 特征提取

中图分类号: TP183/TP751.1 **文献标识码:** A

1 引言

特征是图像处理中用于辨识目标的最基本属性, 因此各种不同类型的特征被广泛地研究, 并应用于对图像中的目标进行分类与识别处理 (Theodoridis & Koutroumbas, 1999)。这些特征包括线特征 (Katsouris et al., 2001), 平面特征 (Pigeon et al., 2000), 纹理特征 (Hamalik et al., 1973; Luo & Savakis, 2001; Fukuda & Hirose, 1999; Xiong & Zhang, 1999) 等等。目标的特征通常可以分为 (Pohl, 1998):

- 几何特征, 如线, 边缘, 脊, 角, 区域, 相对定位等信息;
- 统计特征, 如目标表面的数目, 表面的周长, 矩特征以及纹理特征等;
- 谱特征, 包括目标的色彩, 温度, 谱信号等。

基于特征的目标分类识别 (Theodoridis & Koutroumbas, 1999) 是图像处理最广泛的应用之一, 已经有大量的方法被提出, 包括模糊集理论方法 (Blasch & Huang, 2000), 神经网络方法 (Bianchi et al., 2001) 等等。另外, 基于特征和决策融合的方法也得到了深入的研究和应用 (Roli et al., 2001)。

模糊神经网络方法可以有效地综合模糊集理论和神经网络方法的优势, 因此近来已经获得越来越深入的研究和应用 (Joshi et al., 1997; Tsao et al., 1992; Pal & Ghosh, 1996)。Pal 和 Mitra (1999) 系统地分析了模糊集理论与神经网络的集成, 在此基础上开发出了一系列的模糊多层感知器、模糊逻辑多层感知器、模糊 Kohonen 网络进行特征评估、模式识别、规则推理和决策生成。

2 典型目标特征

基于研究识别舰船目标, 分析了高分辨率卫星观测图像中大型舰船的几何特征、矩特征和纹理特征。

2.1 几何特征

几何特征是目标最基本最直观的轮廓形状特征, 因此可以很好地用于目标的检测与识别。在高分辨率卫星图像中, 典型舰船目标的几何特征可以较好地呈现出来。尽管会受到噪声等因素的影响, 但通过一定的特征提取方法还是可以有效地提取出这些目标几何特征。一般常用于目标识别的几何特征包括: 长度 L 、宽度 W 、周长、面积 A 、圆率 γ 、

收稿日期: 2007-07-16 修订日期: 2008-03-21
第一作者简介: 瞿继双 (1974—), 男, 副研究员。2002年毕业于国防科学技术大学, 博士。从事制导与控制、目标识别等方面研究, 已发表文章十余篇。E-mail: mika99@vip.sina.com

质心 ($\bar{X}$ $\bar{Y}$)。

2.2 矩特征

矩特征是目标外部轮廓形状及其像素强度分布的一种有效度量,对于大型舰船这类具有特定形状的目标,矩特征是一种有力的描述工具。标准中心矩具有平移和尺度不变性。进一步还可以利用标准中心矩定义具有旋转不变性的矩特征。 H_u 定义了7个矩特征来度量目标的矩特征,这7个矩特征具有平移、尺度和旋转不变性。

2.3 纹理特征

图像区域的纹理体现了图像灰度层次的分布特性,纹理特征反映了图像的精致与粗糙、平滑与不规则、一致与不一致等特性,是描述图像的一类重要特征。

最常用的中心矩纹理特征为 μ_2 、 μ_3 和 μ_4 。 μ_2 即为直方图的方差 σ^2 , μ_3 为直方图的倾斜度, μ_4 为直方图的峰度。其中 μ_3 和 μ_4 分别可以用 σ^3 和 σ^4 来标准化。

角度二阶矩 ASM 特征用于度量图像的平滑度,若图像中所有像素灰度层次均为 Level = k 则有 $ASM = 1$ 。图像越不平滑,ASM 值越小。对比度 CON 反映了图像的对比度,即局部灰度层次的变化特性。CON 越大,图像具有更高的对比度。倒数差分矩 DF 对于低对比度的图像具有更大的值。熵 H_s 体现了图像灰度层次分布的随机性,图像越平滑,其值越小。

3 舰船目标特征提取

本文分析的大型舰船目标分为4个级别,分别标识为舰船I级、舰船II级、舰船III级和舰船IV级。对大型舰船特征的提取将针对3类数据中的目标进行,即某型卫星仿真数据中的大型舰船,高分辨率卫星对地观测成像数据中的大型舰船,以及自动检测提取的大型舰船目标(瞿继双, 2002)。下面将分别对上述数据中的大型舰船目标进行几何特征、矩特征和纹理特征提取与分析。在特征提取过程中,大型舰船目标的方位姿态定位如下:包含大型舰船的最小椭圆的长轴处于垂直轴线上,舰船前端朝上。

舰船仿真数据的几何特征包括目标长度、宽度、面积、周长、甲板质心等特征;矩特征包括7个 H_u 矩特征;一阶纹理特征包括二阶中心矩,表示目

标直方图的方差,三阶中心矩为目标直方图的倾斜度,四阶中心矩为目标直方图的峰度,并进行标准化处理;二阶纹理特征分别是 0° 、 45° 、 90° 和 135° 的角度二阶矩、对比度、倒数差分矩和二阶纹理熵。

3.1 仿真舰船数据特征提取

在仿真数据特征提取时,我们将大型舰船分为3类,即舰船I级、舰船II级和舰船III级。分别对舰船I级的A型号、舰船II级的B型号、舰船III级的C型号和D型号进行特征提取和特征分析。

在大型舰船特征提取过程中,舰船目标是通过目标边缘提取后进行人工介入处理获取的。在特征提取过程中,需要注意以下几个影响舰船特征的因素:

- 舰船升降机的状态对其各类特征均有较大影响。
- 舰船上的各种设施将影响其特征。

针对升降机对舰船特征的影像,我们在提取舰船特征时,分别考虑各升降机不同状态的特征,假定每艘舰船拥有4个升降机,于是每艘舰船将有 $n = C_4^0 + C_4^1 + C_4^2 + C_4^3 + C_4^4 = 16$ 种状态。

经过对提取的仿真舰船特征数据进行分析,几何特征、矩特征、一阶纹理特征、二阶纹理特征均可以很好地区分出A型号、B型号、C型号和D型号舰船,因此利用这些特征可以对各舰船进行有效的分类识别应用处理。

3.2 卫星观测数据舰船目标特征提取

除了对仿真数据进行特征提取分析之外,还对某型卫星所成图像中的A型号、B型号和D型号舰船,以及RS1C图像数据中的C型号舰船进行特征提取和分析,这两种图像数据的分辨率分别为 $3m \times 3m$ 和 $5.8m \times 5.8m$,其中C型号舰船1和舰船2分别是不同时相下获取的数据。这里的目标也是通过提取目标边缘形状后进行人工处理获取的。在后面矩特征和纹理特征提取时也将使用相同的数据和人工获取目标方法。

3.3 自动检测目标特征提取

3.1和3.2中目标特征提取之前的目标获取介入了人工处理,这在自动目标检测和识别中是不可取的,数据处理的自主性是越来越多的图像数据处理及应用系统的一个基本要求。因此,下面对舰船目标特征进行自动特征提取处理。

图 1 为一种从卫星观测图像数据中自动检测、识别目标 (主要以大型舰船目标为识别对象) 系统的处理流程 (瞿继双, 2002)。首先使用阈值分割方法或模糊神经网络方法对目标进行初步检测 (瞿继双等, 2003 2004), 将目标从背景中突显分离出来, 然后对目标图像进行模板匹配处理, 从而检测、识

别目标, 确定出目标的基本类别, 例如机场、港口、大型舰船等。如果需要进一步确定目标的特性类别, 例如希望知道舰船是哪一种型号, 或者模板匹配方法无法识别出目标的类别属性时, 就需要通过对目标进行深入的特征提取和分析, 利用其特征进行目标识别处理, 准确地确定出目标属性。




图 1 大型舰船目标自动检测、识别目标系统处理流程

Fig 1 Processing procedure of auto target detection and recognition for large ships

3.3.1 几何特征

型号和 B 型号舰船进行自动特征提取处理, 表 1 中数据为该两艘舰船的几何特征。

利用图 1 所述自动目标检测、识别系统, 对 A

表 1 卫星观测数据中舰船目标自动提取的几何特征

Table 1 Geometric features extracted automatically from ships in satellite-observed data

特 征 目标舰船	长度	宽度	面积	周长	甲板质 心 X	甲板质 心 Y
A 型号	327.8	76.8	18839	678.3	42.7	176.2
B 型号	331.2	79.4	19259.5	655.5	42.2	176.5

3.3.2 矩特征

号和 B 型号舰船进行特征提取获得的 Hu 矩特征。

表 2 给出了利用自动特征提取方法对 A 型

表 2 卫星观测数据中各舰船自动特征提取的 Hu 矩特征

Table 2 Hu moment features extracted automatically from ships in satellite-observed data

特 征 目标舰船	φ_1	φ_2	φ_3	φ_4	φ_5	φ_6	φ_7
A 型号	0.43421	0.96169	3.1182	3.3463	6.5804	3.8174	7.6207
B 型号	0.4246	0.94062	3.1537	3.3737	6.6384	3.8629	7.8061

3.3.3 纹理特征

表 3 和表 4 分别为利用自动特征提取方法对 A 型号和 B 型号舰船进行特征提取获取的一阶纹理特征和二阶纹理特征, 其中一阶纹理特征中的倾斜度 μ_3 和峰度 μ_4 分别使用 σ^3 和 σ^4 进行标准化处理, 二阶纹理特征的角度二阶矩 ASM 利用式 $ASM = -\log_{10} ASM$ 进行对数处理。

表 3 卫星观测数据自动检测舰船目标的一阶纹理特征

Table 3 1-order texture features extracted automatically from ships in satellite-observed data

特 征 目标舰船	μ_2	μ_3/σ^3	μ_4/σ^4
A 型号	2885.1427	1.1561	1.3366
B 型号	2829.5945	1.1578	1.3405

表 4 卫星观测数据自动检测舰船目标的二阶纹理特征

Table 4 2-order texture features extracted automatically from ships in satellite-observed data

特征 目标舰船	ASM				CON			
	0°	45°	90°	135°	0°	45°	90°	135°
A型号	2 9201	2 9598	2 8957	2 973	542 5188	605 3964	268 274	653 6609
B型号	2 919	2 9591	2 8532	2 9593	576 2829	644 9583	215 0855	627 6771
	IDF				H _{ST}			
	0°	45°	90°	135°	0°	45°	90°	135°
A型号	0 15843	0 13988	0 1985	0 13115	7 2007	7 2614	7 1255	7 2887
B型号	0 16557	0 1372	0 19584	0 12743	7 1498	7 2088	7 0077	7 1959

4 模糊神经网络分类识别方法

4.1 特征向量加权成员函数

对于目标特征集 Ω 中的任一特征向量 $F = F_1, \dots, F_n$ 构成的模式 F (本文中模式指具体用于训练或测试的特征向量), 设 $C = C_1, \dots, C_k$; C_k 为已知的模式可能所属类别, 定义 F 与 C_k 的距离为:

$$d_k(F) = \left[\sum_{i=1}^n \left(\frac{F_i - m_{ki}}{\lambda_{ki}} \right)^{r_k} \right]^{\frac{1}{r_k}}, \quad r_k > 0 \quad (1)$$

式中, $\lambda_{ki} = 2 \max_{F_i \in C_k} |F_i - m_{ki}|$ (2)

式 (1) 和 (2) 中的 m_{ki} 在具备先验知识时由先验知识确定, 在不具备先验知识时由下式确定:

$$m_{ki} = \frac{\sum_{F_i \in C_k} F_i}{|C_k|} \quad (3)$$

于是利用 π 函数定义特征 F 在 C_k 中的模糊成员函数为:

$$\mu_{C_k}(F) = \begin{cases} 1 - 2d_k(F) & 0 \leq d_k(F) < \frac{1}{2} \\ 2[1 - d_k(F)]^2 & \frac{1}{2} \leq d_k(F) < 1 \\ 0 & \text{其他} \end{cases} \quad (4)$$

4.2 成员函数输出

利用神经网络方法来选择评估特征向量 F 中的各分量 $F_i, i = 1, \dots, n$ 如图 2 网络包括输入层和输出层, 特征向量分量 $F_1, \dots, F_n$ 在输入层输入, 每个特征分量对应一个神经元, 网络输出层每个节点对应一类目标, 每个节点拥有两个神经元, 即一个主神经元 (白色) 与一个辅助神经元 (灰色) (Pal& Mitra 1999)。辅助神经元用于控制激活主神经元, 使其在只有辅助神经元被激活时才能激活生成输出。辅助神经元与输入神经元进行反馈连接, 第 k 个输出类别至第 i 个特征分量的连接权值为 $-m_{ki}$ 。输入神经元与输出神经元之间连接

权值则是 ω 的函数, 由下式给出:

$$W_{ki} = \left(\frac{\omega_i}{\lambda_{kj}} \right)^{r_k} \quad (5)$$




图 2 基于模糊神经网络的特征分类与识别
Fig. 2 Feature classification and recognition based on fuzzy neural network

当模式 F 输入时, 依次激活辅助神经元, 而其他的辅助神经元则处于不激活状态, 这意味着每次只有一个主神经元产生输出结果。

当第 k 个辅助神经元被激活时, 输入节点 i 的输入激励值为:

$$u_{ik} = (x_k)^{r_k} \quad (6)$$

式中 $x_{ik} = F_i - m_{ki}$ (7)

于是 k 个主神经元的输入为:

$$y_k = \left[\sum_{i=1}^n u_{ik} \times \left(\frac{\omega_i}{\lambda_{kj}} \right)^{r_k} \right]^{\frac{1}{r_k}} \quad (8)$$

通过激励函数 $g(\cdot)$, 可以得到该主神经元的输出为:

$$y_k = g(y_k) \quad (9)$$

y_k 即为模式 F 隶属于 C_k 类目标的隶属度。

对于特征向量 $F = \{F_1, F_2, \dots, F_n\}$ 构成的模式集 Ω 设 $F_i \in \Omega$ 为其中一个模式, 则定义其与第 k 类目标 C_k 的加权距离为:

$$z_k = \left[\sum_{i=1}^n \left(\frac{F_i - m_{ki}}{\lambda_{ki}} \right)^{r_k} \omega_{ki} \right]^{\frac{1}{r_k}}, \quad r_k > 0, \omega_{ki} \in [0, 1] \quad (10)$$

F相应于 C_k 的模糊成员值采用如下激励函数实现:

$$\mu_k(F_j) = \frac{1}{1 + \left(\frac{z_k}{f}\right)^2} \quad (11)$$

上式中的 f 和 f_k 均为正常量, 用于控制类成员集的模糊常量。

从 (11) 式可以看出, F 相应于 C_k 的模糊成员值 $\mu_k(F_j)$ 与加权距离 z_k 成反比, 即 z_k 越小, $\mu_k(F_j)$ 越大, 而当模式 F 与 C_k 的中心点完全重合时, $z_k=0$ 则 $\mu_k(F_j)=1$ 。当 $\mu_k(F_j)<0.5$ 时, 则一般认为 F 不属于 C_k 而当 $\mu_k(F_j)$ 接近 0.5 时, 表明目标在 C_k 与其他类目标的边缘区域, 是否属于 C_k 具有很大的模糊性和不确定性。只有在 $\mu_k(F_j)>0.5$ 时, 才能够认为 F 属于 C_k 的可能性比较大。

与传统神经网络输出单一的结果 (即在输出层对应于每个输入模式只有一个输出节点产生有效响应) 相比较, 模糊神经网络甚至允许模式 F 可以同时属于多类目标, 例如 C_{k_1} 和 C_{k_2} 此时将有 $\mu_{k_1}(F_j)$ 和 $\mu_{k_2}(F_j)$ 均大于 0.5。事实上, 在复杂的目标分类应用中会面临不同两类具有重叠区域的情况, 利用模糊集可以有效地描述这种情况。当有多个成员值大于 0.5 或成员值全部小于 0.5 时, 可以取 $\mu_k(F_j)$ 值较大的一类作为模式 F 的所属目标类别, 也可以进一步利用其他信息或方法对这两类进行进一步分析和判断, 从而确定出该模式所属最优的类别。

4.3 权值更新

传统神经网络方法将更大输出值作为有效输出响应, 并设置该节点输出值为 1, 而将其其他输出节点值设置为 0。这样可能会导致网络训练时出现震荡, 即导致近似相同的模式被分为不同的目标类别, 从而使如何终止算法训练产生困难。处于多类别重叠区域的模式矢量是造成这种震荡的根源, 尽管网络偏差的反向繁殖可以校正权值以使偏差趋于最小, 但是处于多类别重叠区域的模式的模糊性使得偏差在逐渐趋小的过程中产生震荡。

使用模糊神经网络方法可以利用期望的模糊输出作为目标函数, 约束偏差的校正, 并且那些明确地属于或不属于某些类的模式矢量, 即成员函数值趋向于 1 或 0 的模式矢量在权值校正过程中发挥更大的作用; 那些相对某些类在所属隶属度上比较模糊的模式矢量, 主要用于校正权值以区分具有重叠区域的类的边界区域。网络训练时不断通过训练样本学习来校正网络权值, 以使目标函数达到最小。

网络使用均方差偏差和正交熵偏差作为目标函数, 分别定义如下:

$$E = Mse = \left[\sum_{F \in \Omega_{train}} \sum_{k=1}^K (d_k - y_k^H)^2 \right] / (K \times |\Omega_{train}|) \quad (12)$$

$$E = Ce = \left[\sum_{F \in \Omega_{train}} \sum_{k=1}^K \{ -d_k \ln y_k^H - (1 - d_k) \times \ln(1 - y_k^H) \} \right] / (\ln 2 \times K \times |\Omega_{train}|) \quad (13)$$

上述两式中的 Ω_{train} 为模式的训练样本集, 它与测试样本集 Ω_{test} 共同构成特征矢量集 Ω , 即 $\Omega_{train} \cup \Omega_{test} = \Omega$ 。 d_k 为训练模式矢量相应于 C_k 的期望输出, 由式 (4) 给出, y_k^H 为第 k 个输出节点的测试输出值, K 为所有可能的目标类别数目, $|\Omega_{train}|$ 为训练样本集的模式数量。显而易见, 无论是 Mse 还是 Ce 均随着 y_k^H 趋近于 d_k 而减小, 反之亦然。

5 基于单类舰船特征的目标分类识别

下面应用第 4 部分介绍的模糊神经网络方法来对第 3 部分提取的大型舰船特征进行分类识别。识别过程中利用仿真数据训练网络, 利用卫星观测图像提取的目标特征数据以及自动检测提取的目标特征数据 (瞿继双等, 2002, 2003, 2004) 进行测试。目标特征模式分别依次编号为 1—7, 其中模式 1—4, 7 为卫星观测图像提取的目标特征数据, 模式 5 和 6 为自动检测提取的目标特征数据。目标类别分为舰船 I、II、III 和 IV 类, 其中 III 和 IV 类属于同一类别目标, 只是具体型号不同。

5.1 基于几何特征的分类识别

首先利用舰船的几何特征对其进行分类识别处理。根据训练模式样本的类别把目标分为 4 类, 学习步长 $\epsilon=10^{-4}$, $f_k=2$, $f=0.5$, $f=2$ 连接权值初始化为 0.2。对于特定的模式集 Ω 由于式 (12) 及式 (13) 中的 $K|\Omega_{train}|$ 是常量, 因此在计算过程中可以省略, 下面的分类识别也进行相同的处理。

表 5 给出了基于几何特征的测试数据分类识别结果和期望输出, 分别利用均方差偏差 Mse 和正交熵偏差 Ce 作为网络目标函数, 其中粗体数字格为测试模式所属类别。从分类识别结果可以看出, 基于几何特征的识别结果精度相当高, 达到 85.7%, 只有模式 2 在期望输出中属于 IV 类, 被本文方法识别成为 III 类目标。事实上, 如前所述, III 类和 IV 类属于同一类别目标, 因此从广义上说, 任何 III 类或 IV 类目标被识别为其中任何一类也可以认

为正确。模式样本的期望输出也说明了这一点,例如特征模式 1、2、5 和 6 相对于 II 类和 IV 类目标的模糊期望输出值均大于 0.5。在这种广义描述下大型

舰船目标分类识别的精度则达到了 100%。由于选取参数的差异,在使用 Mse 和 Ce 目标函数时各模式的输出期望值有一定的差异。

表 5 基于几何特征的大型舰船分类识别结果
Table 5 Classification and recognition results for large ships based on geometric features

测试模式 目标函数		1	2	3	4	5	6	7
Mse	I 类	0.43696	0.23097	0.51362	0.45739	0.44222	0.3137	0.84024
	II 类	0.31311	0.2303	0.56507	0.67025	0.28522	0.23948	0.29218
	III 类	0.41333	0.7691	0.094332	0.061484	0.60922	0.3425	0.048427
	IV 类	0.87378	0.63442	0.16511	0.13154	0.90566	0.94827	0.19795
期望输出	I 类	0.39003	0.2368	0.66102	0.27308	0.26597	0.59845	0.95542
	II 类	0.34691	0.18277	0.75534	0.83497	0.26358	0.26796	0.26097
	III 类	0.74536	0.78074	0.236	0.14781	0.69474	0.53287	0.067401
	IV 类	0.88093	0.86998	0.24093	0.086577	0.83204	0.84481	0.21948

值得注意的是,采用本文模糊神经网络对大型舰船目标进行分类识别时,一个模式对于目标类大于 0.5 的隶属度可能多于一个,例如模式 3 对于 II 类的隶属度为 0.56507,而对于 I 类的隶属度也为 0.51362。其他模式也有这种情况,尤其是特征模式 1、2、5 和 6 相对于 II 类和 IV 类目标出现这种现象的可能性相当大,这一点从表 5 数据中可以得到验证。另外,还可能出现一个模式相对于所有可能目标类别的识别结果隶属度均小于 0.5 的情况,例如利用 Ce 作为目标函数时模式 7 相对于 4 种舰船类别的识别结果最大隶属度仅为 0.30775,此时基于先验知识可以取其具有最大值的类别为模式所属类别,也可以根据其他特征作进一步判断。

5.2 基于二阶纹理特征的分类识别

下面利用舰船的二阶纹理特征对其进行分类识别处理,同样把目标分为 I、II、III 和 IV 类,算法参数初始化为:学习步长 $\epsilon = 10^{-3}$, $k = 3$, $2 - f =$

0.5, $f = 2$ 连接权值初始化为 0.2。这里首先对 16 个二阶纹理特征分量进行重要性分析(瞿继双, 2003),并根据 3 种分析结果的加权平均来确定其最终重要程度,选择其中前 10 个重要的特征分量(即前 10 个均值最大的特征分量)来对大型舰船目标进行分类识别处理。

表 6 给出了基于二阶纹理特征的测试数据分类识别结果和期望输出,目标函数为均方差偏差 Mse,其中粗体数字格为测试模式所属类别。从分类识别结果可以看出,基于二阶纹理特征的识别结果精度相比基于几何特征的要低,但仍然达到 71.4%,如果采用广义的 III 类和 IV 类目标分类标准,分类精度将达到 100%。

从表中数据可以看出,一个模式同样可能会出现相对于多个目标类别的隶属度大于 0.5 的情况,此时既可以取其最大值者为模式所属类别(本文中即采用此种判别模式),也可以进一步结合其他特征信息作分析判断。

表 6 基于二阶纹理特征的大型舰船分类识别结果
Table 6 Classification and recognition results for large ships based on 2-order texture features

测试模式 目标函数		1	2	3	4	5	6	7
Mse	I 类	0.45237	0.55084	0.35613	0.55441	0.48053	0.66294	0.8461
	II 类	0.52362	0.42011	0.58874	0.78684	0.54077	0.29162	0.42964
	III 类	0.52771	0.56105	0.55504	0.30489	0.37687	0.48037	0.56137
	IV 类	0.5998	0.52944	0.40526	0.55339	0.65125	0.68156	0.4574
期望输出	I 类	0.4884	0.50731	0.15846	0.38653	0.59299	0.52069	0.89577
	II 类	0.44688	0.29371	0.57965	0.84948	0.40461	0.21775	0.22264
	III 类	0.64527	0.68373	0.26128	0.31546	0.42842	0.65921	0.37725
	IV 类	0.59261	0.58896	0.20927	0.40802	0.74896	0.50966	0.4636

6 基于多源特征融合的目标识别

特征融合处理可以有效地综合多源(时相)数据中目标体现出的不同类别或不同度量的特征属性,从而构建更有区分性的特征空间,使基于特征的目标分类识别准确性得到显著改善(Blasch & Huang, 2000; Jorge et al, 1999)。

在前述基于几何特征或二阶纹理特征分类识别结果中,均出现了一个模式具有多个大于 0.5 的识别结果的情况。事实上,模式 3 和模式 4 分别是两景多时相图像中的大型舰船目标(瞿继双, 2002),因此也可以对其特征进行融合处理,以减小分类识别的模糊性。

对模式 3 和模式 4 的几何特征进行加权平均,所得特征模式作为模式 8,然后再次利用模糊神经网络方法对其进行分类识别处理。同样把目标分为 4 类,学习步长 $\epsilon=10^{-3}$, $k=2$, $\lambda=0.5$, $\beta=2$, 连接权值初始化为 0.2。

表 7 中数据为这种多时相几何特征融合处理分类识别结果,从中可见本来识别结果比较模糊的模式 3 与模式 4 进行特征融合后得到的模式 8,其分类识别结果达到 0.94901,而对其他目标类的隶属度也比较小,识别结论非常明晰。另外,由于多源特征融合处理使目标特征置信度趋于增加,因此也能够有效地减小系统模糊化处理的误差,从而使系统总的分类识别性能得到改善。例如表 7 中模式 1、3—7 的识别结论的模糊程度相当小,与表 5、表 6 中的识别结果比较均有了一定程度的改善,部分模式的识别改善相当显著。由此可见,特征融合处理能够有效地改善目标分类识别的性能。

表 7 基于多源(时相)特征融合的舰船分类识别结果

Table 7 Classification and recognition results for ships based on multi-source (temporal) features fusion

测试模式 目标函数		1	2	3	4	5	6	7	8
Mse	I 类	0.20579	0.09411	0.21464	0.17756	0.2163	0.13212	0.65963	0.20082
	II 类	0.25345	0.17666	0.41849	0.5083	0.23556	0.18985	0.20909	0.94901
	III 类	0.38495	0.66788	0.09767	0.06393	0.49414	0.30729	0.0502	0.25396
	IV 类	0.73433	0.65369	0.17176	0.10641	0.71436	0.82297	0.13888	0.22223
期望输出	I 类	0.25765	0.10081	0.42738	0.11604	0.14692	0.40661	0.93318	0.28901
	II 类	0.23734	0.06171	0.7329	0.82611	0.16584	0.08672	0.15568	0.97544
	III 类	0.64356	0.62839	0.19863	0.09206	0.51682	0.27746	0.0036	0.24916
	IV 类	0.71637	0.75014	0.14894	0.02387	0.57202	0.64914	0.11567	0.15278

7 结 论

几何特征、矩特征、纹理特征是描述图像中目标的几类重要特征,本文先后对仿真舰船数据、卫星观测舰船数据和自动检测舰船数据进行了几何特征、矩特征和纹理特征提取和分析。通过对仿真数据提取的几何特征、矩特征和纹理特征分析可以看出,这些特征集或其中的子特征集可以有效地用于识别分类舰船目标。

紧接着描述了一种主从神经元的模糊神经网络分类识别方法,然后利用该方法对大型舰船进行分类识别,包括基于单类舰船特征的识别和多源数据融合的识别。实验结果表明,基于大型舰船的几何特征、矩特征和纹理特征,利用模糊神经网络方法可以实现对大型舰船目标的有效识别。通过多源(时相)数据融合处理,可以改善识别效果。

REFERENCES

Binaghi E, Brio P A, Gallo J, et al. 2001. Robust recognition of urban patterns using a two stage soft-hard neural classification. *Proceedings of SPIE*, **4170**: 49—56.

Blasch E, Huang S. 2000. Multilevel feature-based fuzzy fusion for target recognition. *Proceedings of SPIE*, **4051**: 279—288.

Fukuda S, Hirose A H. 1999. A wavelet based texture feature set applied to classification of multifrequency polarimetric SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, **37**(5): 2282—2286.

Haralick R M, Shanmugam K, Dinstein I. 1973. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, **3**: 610—621.

Jorge E, Perez J, Come V, Jay K, Madisetti. 1999. Target detection via combination of feature-based target-measure images. *Proceedings of SPIE*, **3720**: 345—356.

Joshi N, Ramakrishnan, Houstis E N, Rice J R. 1997. On neurobiological neuro-fuzzy machine learning and statistical pattern recognition techniques. *IEEE Transactions on Neural Networks*, **8**: 18—31.

- Katzir A, Sahli H, Pizurica V, et al. 2001. A model based approach to the automatic extraction of linear features from airborne images. *IEEE Transactions on Geoscience and Remote Sensing*, **39**(9): 2073–2079
- Luo J, Savakis A E. 2001. Self-supervised texture segmentation using complementary types of features. *Pattern Recognition*, **34**: 2071–2082
- Pal S K, Mitra S. 1999. Neuro-fuzzy pattern recognition methods in soft computing. New York: John Wiley & Sons
- Pal S K, Ghosh A. 1996. Review: Neuro-fuzzy computing for image processing and pattern recognition. *International Journal of Systems Science*, **27**: 1179–1193
- Pigeon I, Soham B, Toutin T, et al. 2000. Linear planimetric feature domains modeling for multi-sensors fusion in remote sensing. *Proceedings of SPIE*, **4051**: 420–427
- Pohl C. 1998. Tools and method used in data fusion. *Gudmansen Future Trends in Remote Sensing*
- Qu J S, Wang C, Wang Z Z. 2003. A multi-threshold based morphological approach for extracting coastal line feature from remote sensed images. *Journal of Image and Graphics of China*, **8** (A) (7): 805–809
- Qu J S, Xu D K, Wang C. 2004. Structure context based fuzzy neural network approach for automatic target detection. *Journal of Image and Graphics of China*, **9** (10): 1169–1174
- Qu J S. 2002. Research on key technologies for on-board information fusion processing system. PH.D Thesis of National University of Defense Technology
- Roli F, Giacinto G, Serpico S B. 2001. Classifier fusion for multisensor image recognition. *Proceedings of SPIE*, **4170**: 103–110
- Theodoridis S, Koutroumbas K. 1999. *Pattern recognition*. San Diego: Academic Press
- Tsao F, Bezdek J C, Pal N R. 1992. Fuzzy Kohonen clustering networks. *Pattern Recognition*, **27**: 757–764
- Xiong H L, Zhang T X. 1999. Multiresolution texture features extraction and recognition based on translation and scale invariant adaptive wavelet transform. *Proceedings of SPIE*, **3718**: 305–312

附中文参考文献

- 瞿继双. 2002. 星上信息融合处理系统关键技术研究, 国防科学技术大学博士论文
- 瞿继双, 王超, 王正志. 2003. 一种基于多阈值的形态学提取遥感图像海岸线特征方法, *中国图象图形学报*, **8** (7): 805–809
- 瞿继双, 徐德坤, 王超. 2004. 基于结构上下文的模糊神经网络自动目标检测方法, *中国图象图形学报*, **9** (10): 1169–1174

Feature based fuzzy neural network approach for target classification and recognition in remote sensing images

QU Ji shuang, QU Song-bai, WANG Zi-jie

The Army Academy, Second Artillery, Beijing 100085, China

Abstract Feature is the most essential attribute for recognizing target in image processing. This paper proposes to recognize ship target by utilizing a fuzzy neural network processing on its geometry, moment and texture features. First, we simply depict geometry feature and moment feature especially Humoment. After that, we respectively extract and analyze geometry, Humoment and texture feature of ship target in simulated and satellite observed data as well as ship target acquired by automatic target detection. By analyzing the ship target's features, the feature set or subset, comprising geometry, Humoment and texture feature, can be used to recognize ship target. Fuzzy neural network method can combine fuzzy set's advantages with neural networks, by which feature-based classification and recognition for targets in images can be implemented validly. The paper depicts a fuzzy neural network method with principal subordinate neuro for classification and recognition at first, and then utilize the method to classify and recognize basing on single category feature and multi-source (multi-temporal) data fusion. Experiments' results indicates that classification and recognition for large ship can be implemented validly by utilizing fuzzy neural network methods based on large ships' geometry features, moment features and texture features. Furthermore, using multi-source data fusion, the classification and recognition effect can be improved.

Key words fuzzy neural network; ship target; classification and recognition; feature extraction