

文章编号 1004-924X(2012)02-0395-08

## 三角剖分以及径向基函数神经网络在星图识别中的应用

张少迪<sup>1,2</sup>, 王延杰<sup>1\*</sup>, 孙宏海<sup>1</sup>

(1. 中国科学院 长春光学精密机械与物理研究所, 吉林 长春 130033;

2. 中国科学院 研究生院, 北京 100039)

**摘要:**根据经典径向基函数(RBF)神经网络的优势,结合星图模式样本集的特点,设计了一种适合星图模式样本的网络训练算法。从提取星图模式入手,引入三角剖分理论,将可能出现在同一视场内的恒星以三角形的形式连接起来,提取连接的角距作为星图模式,建立了具有完备性、平移旋转不变性的星图模式样本集。然后,利用 RBF 神经网络做星图识别,研究顺序训练方法和批量训练方法,总结多种经典算法的优缺点,并设计了一种训练方法。通过实验证明了该方法较其他经典算法更为适合学习星图模式样本。最后,给出 RBF 神经网络相关的训练数据,并通过模拟星图软件获得若干模拟星图作为观测样本,利用已经训练好的神经网络进行识别。试验结果表明,测试网络能够正确识别这些星图。

**关键词:**星图识别;三角剖分;径向基函数(RBF)神经网络;ROLS 算法;GAP 算法

**中图分类号:**TP391.4;TP183 **文献标识码:**A **doi:**10.3788/OPE.20122002.0395

### Application of triangulation and RBF neural network to star pattern recognition

ZHANG Shao-di<sup>1,2</sup>, WANG Yan-jie<sup>1\*</sup>, SUN Hong-hai<sup>1</sup>

(1. *Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China;*

2. *Graduate University of Chinese Academy of Sciences, Beijing 100039, China)*

\* *Corresponding author, E-mail: wangyj@ciomp.ac.cn*

**Abstract:** A network training method for star pattern recognition was designed by combining a classic Radial Basic Function(RBF) neural network and star pattern samples. Firstly, the star pattern abstraction method was discussed and a triangulation based on star magnitudes was induced to connect the stars which probably appear in the same field of view. By taking extracted angular distances as the characteristic of star pattern, a star pattern sample set with completion, translation and rotation invariance was established. Then, RBF neural network was studied to recognize the star patterns. RBF network training method was classified as sequence learning and batch learning. Some typical algorithms that could represent the two methods were studied on their advantages and disadvantages, and a new training method was designed based on the specialty of above star pattern sample sets. Experiments indicate that the designed method is more appropriate than those typical algorithms. Several

收稿日期:2011-04-18;修订日期:2011-06-21.

基金项目:国家 863 高技术研究发展计划资助项目(No. 2006AA703405F)

star images were simulated through software, which was regarded as the observatory data and entered into the trained RBF neural network to test. The experiment results show that the network can recognize all the star patterns successfully.

**Key words:** star pattern recognition; triangulation; Radial Basic Function (RBF) neural network; ROLS algorithm; GAP algorithm

## 1 引言

航天器在飞行过程中需要实时校正自身的飞行姿态,星敏传感器因具有体积小、重量轻、精度高、无误差累积等优点,成为了航天器首选的姿态测量敏感器<sup>[1-3]</sup>。星敏传感器为了解决“Lost-In-Space”问题,采用自主星图识别算法,在没有任何先验姿态信息的指导下,通过识别当前视场内的观测星,确定当前光轴指向,完成姿态定位与调整。自主星图识别算法有很多种,常用的有三角形算法<sup>[4]</sup>、多边形算法<sup>[5]</sup>、匹配组算法、KMP 算法<sup>[6]</sup>等。它们都是将星图按照某个模式建模,通过查找导航星表,找到与该模式匹配的导航星,这些方法的缺点是需要重复查找星表,导致实时性不高,而且出现冗余信息等待筛选,增加了工作量。

随着神经网络技术在模式识别领域的发展,国内外学者已将其应用于星图识别。20 世纪 90 年代初出现的径向基函数(Radial Basic Function, RBF)神经网络可以根据输入输出数据来逼近复杂非线性系统映射,而且拥有收敛快,拟合精度高,结构紧凑等优点而越来越受到重视。批量训练算法的代表 ROLS(Regularization Orthogonal Least Squares)算法<sup>[7-8]</sup>,将全部输入数据作为中心,通过正交分解的方法逐个选择中心,直到得到符合预期要求的网络结构。顺序算法的代表是 MRAN 算法(Minimal-RAN),在增长消除准则中使用滑动数据窗来检验神经元对网络输出贡献的大小。Huang<sup>[9-10]</sup>提出隐单元“重要性”概念,只需判断与输入样本距离最近的隐单元重要性即可得知该隐单元是否应该被去除,称这种算法为 GAP(Growing and Pruning)<sup>[11-12]</sup>。由于星表中导航星随机分布,无法获得其分布概率密度函

数<sup>[13-15]</sup>,因此不能直接使用 GAP 算法。

根据以上总结得出了经典 RBF 神经网络训练算法的优缺点,结合星图模式样本集的特点,本文设计了一种适合星图模式样本的网络训练算法。

## 2 星图模式提取

导航星在星表中的排列可以看作无序点集,如果要描述导航星与其邻近导航星之间的拓扑连接关系,必须按照某种模式将他们组合起来。由于三角形剖分方法<sup>[16]</sup>可以很好地描述点集中离散点之间的关系,本文采用该方法建立星图描述模型。

### 2.1 基于星等的三角剖分算法

平面内顶点集合 $\{V_i\} i=1 \cdots n$ ,用不相交的直线段连接 $V_i$ 与 $V_j, 1 \leq i, j \leq n, i \neq j$ 使得 $n$ 个点的凸壳内的每一个区域是一个三角形,如图 1 所示,这个过程称为三角剖分,剖分后形成的三角网格 $T$ 也称为顶点集合 $\{V_i\}$ 的一个三角剖分。




图 1 三角剖分示意图

Fig. 1 Triangulation figure

一般来说,对离散点集的三角剖分不是唯一的,其中 Delaunay 三角剖分<sup>[17]</sup>为最优,它满足最

小内角最大准则。为了降低剖分算法复杂度并充分利用恒星的星等信息,本文提出基于星等的三角形剖分算法。

基于星等的三角形剖分(以下简称星三角剖分)步骤如下:

(1)将出现在星传感器视场中的恒星按照星等由高到低排列,并从 1 开始标记号码,如果有 2 颗或 2 颗以上的恒星星等相同时,则按照赤经坐标由小到大排序,如图 2(a)所示;

(2)以 1 号星为端点顺次连接其他星,如图 2(b);

(3)以 2 号星为端点,顺次连接比它星号大的星,由三角剖分的定义可知两两三角形之间三角形边不能相交,因此在连接两颗星过程中,如果与之前已经连接的线段相交,则取消本次连接,例如在连接线段  $P_{2j}, j > 2$  的过程中,要判断其与已经连接线端  $P_{1h}, (h > 1 \text{ 且 } h \neq 2, h \neq j)$  是否相交,其判断依据是两个不等式:

$$\begin{vmatrix} x_j - x_2 & y_j - y_2 \\ x_1 - x_2 & y_1 - y_2 \end{vmatrix} \begin{vmatrix} x_j - x_2 & y_j - y_2 \\ x_h - x_2 & y_h - y_2 \end{vmatrix} \leq 0, \quad (1)$$

$$\begin{vmatrix} x_h - x_2 & y_h - y_2 \\ x_1 - x_2 & y_1 - y_2 \end{vmatrix} \begin{vmatrix} x_h - x_1 & y_h - y_1 \\ x_j - x_1 & y_j - y_1 \end{vmatrix} \leq 0, \quad (2)$$

此恒星连接过程如图 2(c)所示;

(4)按照星号由小到大按照步骤(3)描述的连接过程依次连接,最后即可得到平面点集的三角剖分,如图 2(d)所示。




图 2 基于星等的三角剖分步骤示意图

Fig. 2 Triangulation steps based on star magnitude

飞行器的滚动会造成所拍摄的星图围绕着星敏感器的视轴产生转动,导致一些基于恒星在视场内坐标的星图模式提取算法对旋转过敏,如图 3 所示。由于本文提出的星三角剖分算法与恒星在视场内的坐标无关,只与剖分后提取的恒星之间的角距有关,因此只要恒星之间的相对位置不变,所提取的星图模式就不会改变,即本文提出的星三角剖分算法具有模式提取旋转、平移不变性。




图 3 视场旋转对星图模式提取的影响

Fig. 3 Impact of FOV rotation on star pattern abstraction

## 2.2 提取星图模式

建立完备的训练样本集是星图模式提取的基本工作,由于星传感器视场(本文视场为  $10^\circ \times 10^\circ$ )存在旋转,因此无法考虑所有可能的星图模式。当恒星集中在视场边缘时,由于镜头畸变导致恒星重心提取结果误差很大,因此只考虑当恒星分布在视场中心附近时提取星图模式。基于 SAO (Smithsonian Astrophysical Observatory) 星表的星图模式提取步骤如下:

(1)分别以每颗星为中心,以视场对角线长度为半径搜索星表,搜索到的恒星可能与中心星出现在同一视场,记为集合 A。图 4 所示为以 4 号星为中心的搜索结果,除 4 号星以外的其他恒星可能无法同时出现在同一视场。

(2)考虑所有可能与 4 号星同时出现在同一视场中的情况,并对每种情况应用星三角剖分算法,其结果如图 5 所示。

(3)分别提取每种情况星三角剖分后的角距作为神经网络的样本模式输入,并将集合 A 中最亮星的星号作为学习目标。

(4)所有恒星都按以上步骤进行搜索和提取,去除重复模式之后即可得到完备的训练样本集。

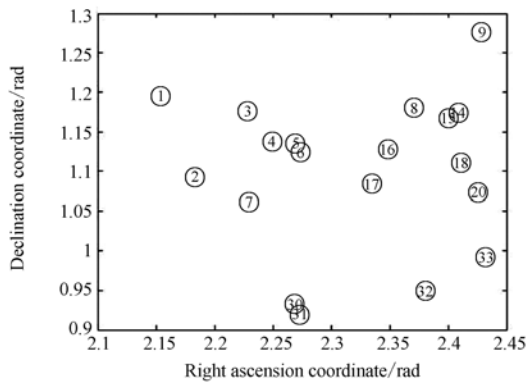


图 4 可能出现在同一视场的恒星分布

Fig. 4 Star distribution probably come up in the same field of view

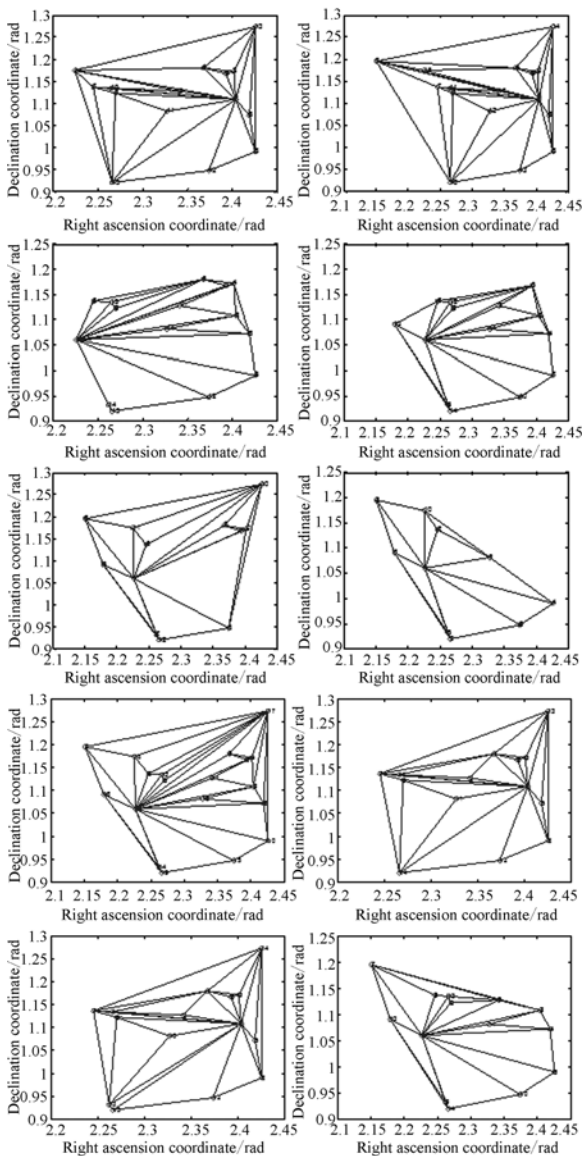


图 5 星三角剖分后的结果

Fig. 5 Results of triangulation

### 3 基于 RBF 神经网络的星图识别算法

#### 3.1 RBF 神经网络简介

RBF 神经网络每个隐单元都由 2 个参数组成,即中心向量  $\mu$  和函数宽度  $\sigma$ 。每个隐单元的基函数在输入空间都是径向对称的,其输出值是由输入向量  $x$  和中心向量  $\mu$  之间的径向距离决定的,假设网络存在  $K$  个隐单元。隐单元与输出单元之间由权值  $\alpha$  相连,相加即可得到整个网络的输出,即:

$$f(x) = \sum_{k=1}^K \alpha_k \phi_k(x), \quad (3)$$

$$\phi_k(x) = \exp\left(-\frac{1}{\sigma_k^2} \|x - \mu_k\|^2\right), \quad (4)$$

这里  $\phi_k(x)$  是第  $k$  个隐单元的响应,  $\alpha_k$  是与输出单元连接的权值。 $\mu_k$  和  $\sigma_k$  分别是第  $k$  个隐单元的中心和宽度。

#### 3.2 ROLS 算法的子集选择机制

RBF 网络的中心选择可以看作子集选择问题,正交最小二乘(OLS)算法从样本集合中选择中心子集,可以避免在随机选择中心方法中遇到的网络病态问题。针对 OLS 泛化能力弱的缺点,ROLS 引入零阶正规化方法计算网络的迭代误差,有效提高了泛化能力。

假设训练样本集中有  $N$  组样本数据,则式(3)的矩阵形式为:

$$F = \Phi A, \quad (5)$$

其中:

$$F = [f_1 \ f_2 \ \dots \ f_N]^T,$$

$$\Phi = [\phi_1 \ \phi_2 \ \dots \ \phi_K], \phi_i = [\phi_i(1) \ \phi_i(2) \ \dots$$

$\phi_i(N)]^T, A = [a_1 \ a_2 \ \dots \ a_K]^T$ 。矩阵  $\Phi$  可以分解为如下形式:

$$\Phi = WB, \quad (6)$$

其中  $B$  是一个  $K \times K$  的上三角矩阵,并且对角线元素全为 1,即:

$$B = \begin{bmatrix} 1 & \beta_{12} & \beta_{13} & \dots & \beta_{1K} \\ 0 & 1 & \beta_{23} & \dots & \beta_{2K} \\ 0 & 0 & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & \dots & 0 & 0 & 1 \end{bmatrix}, \quad (7)$$

而  $W$  是一个  $N \times K$  的矩阵,其列向量之间彼此正交,即:

$\mathbf{W}=[\mathbf{w}_1 \ \mathbf{w}_2 \ \cdots \ \mathbf{w}_k]$ ,  $\mathbf{w}_i^T \mathbf{w}_j=0(i \neq j)$ , (8)  
则公式(5)可以改写为:

$$\mathbf{F}=\mathbf{W}\mathbf{g}, \quad (9)$$

其中  $\mathbf{g}=\mathbf{B}\mathbf{A}$ , 为了防止最小平方准则的过度拟合, 定义零阶正规化误差准则:

$$\frac{\mathbf{e}^T \mathbf{e}+\lambda \mathbf{g}^T \mathbf{g}}{\mathbf{d}^T \mathbf{d}}=1-\sum_{i=1}^N \mathbf{g}_i^2 \frac{\mathbf{w}_i^T \mathbf{w}_i+\lambda}{\mathbf{d}^T \mathbf{d}}, \quad (10)$$

其中  $\lambda$  为正规化参数。在初始阶段, 设置隐单元数目为  $N$ , 即所有观测值均为隐单元中心向量, 并计算:

$$\left\{\begin{array}{l} \mathbf{w}_1^i=\phi_i \\ \mathbf{g}_1^i=\frac{\left(\mathbf{w}_1^i\right)^T \mathbf{F}}{\left(\mathbf{w}_1^i\right)^T \mathbf{w}_1^i} \\ \left[\text{err}\right]_1^i=\left(\mathbf{g}_1^i\right)^2 \frac{\left(\mathbf{w}_1^i\right)^T \mathbf{w}_1^i+\lambda}{\mathbf{d}^T \mathbf{d}} \end{array}\right., \quad (11)$$

找到  $[\text{err}]_1^i=\max\{[\text{err}]_1^i, 1 \leq i \leq N\}$  并选择  $\mathbf{w}_1=\mathbf{w}_1^i=\phi_{i_1}$ 。当进行到第  $k$  步时对于  $1 \leq i \leq N$  且  $i \neq i_1, i_2, \dots, i_{k-1}$  计算:

$$\left\{\begin{array}{l} \beta_{jk}^i=\frac{\mathbf{w}_j^T \phi_i}{\mathbf{w}_j^T \mathbf{w}_j}, 1 \leq j < k \\ \mathbf{w}_k^i=\phi_i-\sum_{j=1}^{k-1} \beta_{jk}^i \mathbf{w}_j \\ \mathbf{g}_k^i=\frac{\left(\mathbf{w}_k^i\right)^T \mathbf{F}}{\left(\mathbf{w}_k^i\right)^T \mathbf{w}_k^i} \\ \left[\text{err}\right]_k^i=\left(\mathbf{g}_k^i\right)^2 \frac{\left(\mathbf{w}_k^i\right)^T \mathbf{w}_k^i+\lambda}{\mathbf{d}^T \mathbf{d}} \end{array}\right., \quad (12)$$

找到

$$[\text{err}]_k^i=\max\{[\text{err}]_k^i, 1 \leq i \leq N, i \neq i_1, i_2, \dots, i_{k-1}\},$$

并选择  $\mathbf{w}_k-\mathbf{w}_k^i=\phi_{i_k}-\sum_{j=1}^{k-1} \beta_{jk}^i \mathbf{w}_j$ , 该算法停止的条件是判断是否满足:

$$1-\sum_{j=1}^k[\text{err}]_j<\epsilon. \quad (13)$$

这里  $\epsilon$  是理想精度。如果满足该判定条件, 则选择出  $k$  个隐单元; 如果不满足则算法继续进行。

### 3.3 GAP 算法中隐单元的重要性准则

在顺序训练过程中, 随着训练数据的不断输入, 某些已经增加的隐单元对于输出的贡献逐渐减弱, 为了获得更为紧凑的 RBF 网络结构, 这些贡献较小的隐单元应该被去除。GAP 算法提出隐单元的重要性规则用于判断隐单元对输出的贡献。假设当前 RBF 网络包含  $K$  个神经元, 网络输出为:

$$f_1\left(x_i\right)=\sum_{j=1}^K \alpha_j \phi_j\left(x_i\right), \quad (14)$$

当去掉第  $k$  个神经元时, 此时 RBF 网络剩余  $K-1$  个隐单元, 其输出为:

$$f_2\left(x_i\right)=\sum_{j=1}^{k-1} \alpha_j \phi_j\left(x_i\right)+\sum_{j=k+1}^K \alpha_j \phi_j\left(x_i\right), \quad (15)$$

因此对于某一观测向量  $x_i$ , 由于去掉隐单元  $k$  引起的网络输出变化为:

$$E(k, i)=\left|f_2\left(x_i\right)-f_1\left(x_i\right)\right|=|\alpha_k| \phi_k\left(x_i\right), \quad (16)$$

对于所有观测值由于去掉隐单元  $k$  引起的网络输出平均误差为:

$$E_{\text{ave}}(k)=\frac{\sum_{i=1}^N E(k, i)}{N}=\frac{\left|\alpha_k\right|}{N} \sum_{i=1}^N \phi_k\left(x_i\right). \quad (17)$$

如果式(17)结果小于网络训练的理想精度, 则说明该隐单元是不重要的可以去掉, 反之说明该隐单元是重要的。

### 3.4 基于星图模式样本的 RBF 训练方法

星图模式样本集在训练 RBF 网络之前建立, 适合批量训练法。但是星图模式样本集包含的星图模式数目多, 在训练过程中需要反复使用样本值, 计算量大。如果使用顺序训练法训练, 将星图模式逐个输入 RBF 网络训练, 虽然训练时间大大减少, 但训练得到的精度却无法达到理想要求。其主要原因是在顺序训练过程中, 每个样本只训练一次, 网络训练不充分, 而批量训练法每个样本都经过多次训练, 网络得到充分训练, 因此批量训练法的精度要求高。本文针对星图模式样本集的特点设计的 RBF 神经网络训练算法步骤如下:

(1) 将提取的星图模式样本集按输出星号的不同分成若干子集, 子集之间没有训练次序, 如果某些子集包含的样本数目少, 可以将其自由组合。

(2) 逐个学习每个子集, 从中选择隐单元中心。根据公式(5)计算隐单元输出矩阵, 并使用 ROLS 算法将矩阵分解, 获得隐单元的中心, 而隐单元的宽度为:

$$\sigma_s=\kappa \max _{n \in N_s}\left(\left\|x_n-\mathbf{C}_{n r}\right\|\right), \quad (18)$$

其中  $\kappa$  是重叠因子, 用于决定隐单元响应之间重叠程度。  $x_n$  代表样本子集  $N_s$  中的模式数据。  $\mathbf{C}_{n r}$  表示距离样本  $x_n$  最近的中心向量。

(3) 应用 LS 算法计算连接隐单元和输出单元之间的权值。

(4) 当所有子集训练完成后, 对检验每个隐单元重要性, 获得更为紧凑的网络结构。

## 4 实验与结果

本文对大熊星座内的恒星做星图识别。首先加载 SAO 星表, 赤经赤纬坐标采用 J2000 历元。大熊星座中星等高于 6 的恒星共有 124 颗, 利用第二节提出的方法以  $10^\circ \times 10^\circ$  为视场窗口搜索并三角剖分这些恒星, 构建模式样本集。将提取的样本集作为 RBF 神经网络的训练样本, 并按第三节提出的训练算法训练神经网络。

本文提出算法的特点是将训练样本集分为若干子集, 对于每个子集训练方式是批量训练, 而子集之间则是顺序训练。GAP 算法需要预先得到训练样本的概率密度, 由于星点分布的随机性因此不适合本文的实际情况, 将本文算法和 MRAN 算法作对比。实验机为 PC 机, CPU 为奔腾双核 E2220, 内存 2G。训练结束后从训练样本中抽出 20 组样本作为测试样本验证识别率, 其比较结果如表所示:

表 1 本文算法和 MRAN 算法的比较

Tab. 1 Difference between proposed method and MRAN

	训练时间/s	隐单元数目	识别成功率/%
MRAN 算法	43.153	76	60
本文算法	82.202	79	100

从训练时间来看, 由于本文算法子集训练为批量训练, 因此较 MRAN 算法训练时间要长; 从网络结构来看, 二者相差不多; 从识别成功率上看本文算法优势较大, 这是因为在隐单元重要性检验阶段 MRAN 算法只是检查窗口范围内的数据, 而本文着眼整个集合, 因此测试时识别成功率较高, 这也是本文算法训练时间长的主要原因。

在训练结束后, 只需要保存隐单元的中心、宽度以及连接隐单元和输出单元之间的权值即可。下面利用 HNSKY 2.3.0 模拟星空软件验证已经训练好的 RBF 神经网络实用性。如图 6 所示, 粗框内是大熊星座所有星等大于 6 的恒星, 细方框表示  $10^\circ \times 10^\circ$  CCD 视场窗口。

将 CCD 视场窗口在大熊星座范围内平移或旋转得到 3 组恒星数据, 如表 2 所示。



图 6 大熊星座星图

Fig. 6 Star image of Ursa Majoris

表 2 实验数据的赤经赤纬坐标

Tab. 1 Right ascension and declination coordinates for stars

	赤经赤纬坐标(J2000 历元)
第一幅星图	(11h03m43.7s, 61°45'03"); (10h51m23.7s, 69°19'12"); (11h01m50.5s, 56°22'57"); (10h51m11.1s, 56°34'56"); (10h43m43.3s, 57°11'57"); (10h35m9.7s, 57°04'58"); (10h53m34.4s, 54°35'6"); (10h30m37.6s, 55°58'50")
第二幅星图	(12h29m57.3s, 58°24'21") (12h20m50.8s, 57°51'50") (12h25m03.2s, 56°46'40") (12h27m35.1s, 55°42'46") (12h15m25.6s, 57°01'57") (12h17m29.5s, 53°11'28") (11h55m58.4s, 56°35'55") (11h53m49.8s, 53°41'41") (11h46m55.6s, 55°37'41") (11h35m04.9s, 54°47'07") (11h25m57.1s, 55°51'01")
第三幅星图	(10h43m04.1s, 69°04'34") (10h44m38.4s, 68°46'33") (10h41m48.3s, 68°26'36") (10h21m03.4s, 68°44'51") (10h41m56.6s, 65°42'59") (10h24m07.9s, 65°33'59") (10h30m26.5s, 64°15'28")

对这 3 幅星图应用星三角剖分, 结果如图 7 所示。

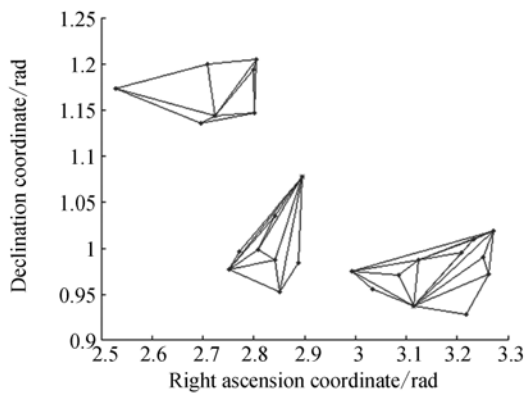


图 7 星图的三角剖分

Fig. 7 Triangulation of star image

将该 3 组星模式输入到已训练好的神经网络中,结果如表 3 所示。

表 3 试验结果

Tab. 2 Experimental results

识别时间/ms	识别目标 SAO 星号	是否成功
实验一	15 384	成功
实验二	28 179	成功
实验三	15 163	成功

## 参考文献:


- [1] 钟红军. 流水线并行处理提高星敏传感器数据更新率[J]. 光学精密工程, 2009, 17(9): 2230-2235.  
ZHONG H J. Increasing update rate for star sensor by pipelining parallel processing method [J]. *Opt. Precision Eng.*, 2009, 17(9): 2230-2235. (in Chinese)
- [2] 张磊. 快速全天自主星图识别[J]. 光学精密工程, 2009, 17(4): 909-915.  
ZHANG L. Fast all-sky autonomous star identification [J]. *Opt. Precision Eng.*, 2009, 17(4): 909-915. (in Chinese)
- [3] ZHANG S D, WANG Y J, SUN H H. Design of high accuracy star image locating method used in star sensor technology [C]. *CMCE IEEE*, 2010: 411-414.
- [4] 郑胜, 吴伟仁, 田金文, 等. 一种基于三角形几何结构的星图识别算法[J]. 光学技术, 2004, 30(1): 70-77.  
ZHENG SH, WU W R, TIAN J W, et al.. A novel geometric structure-based autonomous star pattern identification algorithm [J]. *Optical Technique*, 2004, 30(1): 30-77. (in Chinese)
- [5] 刘朝山, 黄欣, 刘光斌. 凸多边形星图识别算法[J]. 光电工程, 2004, 31(9): 7-9.  
LIU CH SH, HUANG X, LIU G B. A convex polygon star pattern identification algorithm for star sensor [J]. *Opto-Electronic Engineering*, 2004, 31(9): 7-9. (in Chinese)
- [6] 李葆华, 张迎春. 用 KMP 算法进行星敏传感器星图识别的方法[J]. 光电工程, 2004, 31(1): 9-11.  
LI B H, ZHANG Y CH. A star map recognition method of star sensor with KMP algorithm [J]. *Opto-Electronic Engineering*, 2004, 31(1): 9-11. (in Chinese)
- [7] YEE W W, KAH P S, LI-MINN A. Radial basis function neural network with incremental learning for face recognition [J]. *IEEE Trans.*, 2011, 2(2): 302-309.
- [8] CHEN S. Local regularization assisted orthogonal least squares regression [J]. *Neurocomputing*, 2005, 7: 559-585.
- [9] HUANG G B. A generalized growing and pruning RBF neural network for function approximation

- [J]. *IEEE Trans.*, 2005, 16(1): 57-67.
- [10] HUANG G B. An efficient sequential learning algorithm for growing and pruning RBF(GAP-RBF) Networks [J]. *IEEE*, 2004, 34(6): 2284-2292.
- [11] ZHANG R X. Improved GAP-RBF network for classification problems [J]. *Science Direct*, 2006, 70: 3011-3018.
- [12] LIAO Y X. Sequential growing and pruning learning for recurrent neural networks using unscented or extended Kalman filter [C]. *Proceedings of the 27th Chinese Control Conference*, 2008: 242-247.
- [13] BORTMAN M, ALADJEM M. A growing and pruning method for radial basis function networks [J]. *IEEE Trans.*, 2009, 20(6): 1039-1045.
- [14] LIANG N Y. A fast and accurate online sequential learning algorithm for feedforward networks [J]. *IEEE Trans.*, 2006, 17(6): 1411-1423.
- [15] 李斌, 赖晓平. 改进的 GGAP-RBF 算法及其在函数逼近中的应用 [J]. *模式识别与人工智能*, 2007, 20(2): 230-235.
- LI B, LAI X P. An improved GGAP-RBF algorithm and its application to function approximation [J]. *PR&AI*, 2007, 20(2): 230-235. (in Chinese)
- [16] 周知. 三角剖分算法研究 [D]. 哈尔滨: 哈尔滨理工大学, 2007.
- ZHOU ZH. *Research on triangulation algorithm* [D]. Harbin: Harbin University of Science and Technology, 2007. (in Chinese)
- [17] 房建成, 全伟, 孟小红. 基于 Delaunay 三角剖分的全天自主星图识别算法 [J]. *北京航空航天大学学报*, 2005, 31(3): 311-315.
- FANG J CH, QUAN W, MENG X H. All-sky autonomous star map identification algorithm based on Delaunay triangulation culling algorithm [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2005, 31(3): 311-315. (in Chinese)

#### 作者简介:



张少迪(1984—),男,吉林长春人,博士,2007年于吉林大学获得理学学士学位,主要从事实时数字图像处理、星图识别方面的研究。E-mail: zhangsd529@yahoo.com.cn



孙宏海(1980—),男,吉林长春人,研究员,主要从事图像处理、高速相机等方面的研究。E-mail: meredith\_2004@163.com

#### 导师简介:



王延杰(1963—),男,吉林长春人,研究员,博士生导师,主要从事图像处理、电视跟踪和自动目标识别技术的研究。E-mail: wangyj@ciomp.ac.cn