

〈图像处理与仿真〉

## 层叠式 SOM 神经网络星图识别算法及 FPGA 验证

郑天宇<sup>1,2,3</sup>, 尹达一<sup>1,2</sup>, 赵玥皎<sup>1,2,3</sup>

(1. 中国科学院红外探测与成像技术重点实验室, 上海 200083;  
2. 中国科学院上海技术物理研究所, 上海 200083; 3. 中国科学院大学, 北京 100049)

**摘要:** 为了对空间天文望远镜精细导星仪获得的星图完成识别, 提出一种层叠式自组织映射 (SOM) 神经网络算法模型, 将该模型在硬件中实现星特征矢量匹配算法。首先, 针对精细导星仪的特点详细介绍了导航星库的建立、星特征矢量的构建和筛选方法; 其次, 建立层叠式 SOM 神经网络模型, 对其权值进行在线训练; 最后, 设计算法离线运行硬件电路并将其在 FPGA 中实现。仿真与测试结果表明, 基于层叠式自组织神经网络的星图识别算法识别率高、抗噪声能力强、识别速度快。星点位置噪声为 0.648", 星等噪声为 0.18 视星等条件下星图识别成功率在 80% 以上, 新算法在 FPGA 中运行速度是 PC 机上传统三角形法的 100 倍。对精细导星仪星图识别算法的优化设计提供了合理可行的参考依据。

**关键词:** 精细导星仪; 星图识别; 星特征矢量; SOM 神经网络; FPGA 验证

中图分类号: V19; TP391.4 文献标识码: A 文章编号: 1001-8891(2018)03-0246-07

## Star Pattern Recognition Algorithm and FPGA Verification of Stacked SOM Neural Network

ZHENG Tianyu<sup>1,2,3</sup>, YIN Dayi<sup>1,2</sup>, ZHAO Yuejiao<sup>1,2,3</sup>

(1. Key Laboratory of Infrared System Detection and Imaging Technology, Chinese Academy of Sciences, Shanghai 200083, China;  
2. Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 200083, China;  
3. University of Chinese Academy of Sciences, Beijing 100049, China)

**Abstract:** A stacked SOM neural network algorithm model is proposed for star identification, which is needed by fine guidance sensors, and the model is implemented in hardware to implement the star feature vector matching algorithm. Firstly, the method of establishment of the navigation star library and the construction of the star feature vector are introduced in detail. Then, the stacked SOM neural network model is put forward and the weights are trained online. Finally, the hardware circuits of the new algorithm are designed and implemented in the FPGA. The simulation and test results show that the star pattern recognition algorithm based on the stacked SOM neural network has a high recognition rate, strong anti-noise capacity, and fast recognition speed. The star map recognition success rate under harsh conditions is more than 80%, and the recognition speed is 100 times more than that of traditional methods that run in PCs. This research provides a reference for the design of fine guidance sensor star image recognition algorithms.

**Key words:** fine guidance sensor, star pattern recognition, star feature vector, SOM neural network, FPGA verification

### 0 引言

星图识别是将精细导星仪视场中的观测星组成的星模式与导航星库中导航星组成的星模式进行特

收稿日期: 2017-07-23; 修订日期: 2017-12-27.

作者简介: 郑天宇 (1990-), 男, 内蒙古赤峰人, 博士研究生。主要从事高速图像处理系统的研究。

基金项目: 国家自然科学基金资助项目 (40776100)。

征匹配以确定观测星与被测星之间的关系,进而得到其视场中某几颗星的经纬度信息<sup>[1]</sup>。传统的星图识别算法包括三角形以及改进算法<sup>[2-4]</sup>、栅格法<sup>[5]</sup>、基于神经网络的方法<sup>[6-7]</sup>。其中三角形法是应用最为广泛的算法,具有原理简单、易于实现的优点,同时其特征维数低、有误匹配现象。栅格法同样运算简单,可减小三角形误匹配问题,但视场中存在伪星及缺失星,有可能导致算法失效。三角形法和栅格法都涉及搜索过程,会降低算法实时性。神经网络经过训练,其连接权值包含了导航星的特征信息,无需查找导航星库就可以直接输出匹配结果。

自组织映射(self-organizing map, SOM)神经网络是一种类似人脑神经元侧抑制功能的通过自组织竞争学习实现聚类的神经网络模型,最早由芬兰科学家Kohonen提出<sup>[8]</sup>。自组织映射网络与竞争神经网络非常相似,神经元都具有竞争性,都采用无监督的学习方式。SOM神经网络由于其学习简单、有效、鲁棒性强的特点,被广泛应用于模式识别、数据挖掘、故障诊断等领域<sup>[9-10]</sup>。

目前星图识别算法大多在原型验证阶段,鲜有真实硬件的测试实例。神经网络算法是一种并行算法,通过适当的流水线设计,可以得到很高的运行频率和数据吞吐量。同时基于三角形的星图识别算法具有平移与旋转不变特性,将三角形算法与神经网络相结合,利用FPGA并行运算的特点,将图像获取、预处理以及星图匹配集成于一片芯片,提高系统集成度,降低功耗,对工程化应用有较大价值。

## 1 算法基本原理与实现

### 1.1 导航星库的构建和星三角的选取

视场内平均星数公式如式(1)所示:

$$N_{FOV} = 6.57 \cdot e^{1.08M} (1 - \cos(A/2)) / 2 \quad (1)$$

式中:  $A$  为精细导星仪视场,取 0.08 degree<sup>2</sup>;  $M$  为视星等。视场内平均星数大于 3 颗时,星等大于 12 等,这里取观测星等为 10~14 等。为了保证星图识别的准确率,对于 SOM 神经网络,构建唯一以及完备的样本集是关键。

星表中 8~16 等星有 1 亿颗,通过星库构建算法将变星、双星、亮星、自行较大的星剔除掉,同时应用均匀化算法得到分布均匀并且星等在 10~14 等范围内的导航星数为 3500 000 颗。

三角形星图识别算法具有平移和旋转不变性,实现简单的优点,但是其特征维数低,容易出现误匹配,将星等信息与星角距信息相结合,可以大幅度降低误识别率。

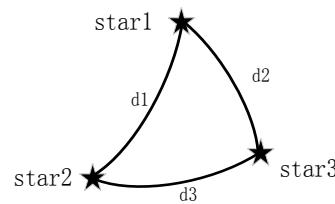


图 1 星三角 Fig.1 Tri-star

设导航星  $a, b$  的赤经赤纬为  $(\alpha_a, \delta_a)$  和  $(\alpha_b, \delta_b)$ , 则二者在天球坐标系下的角距定义为:

$$d_{ab} = \arccos \frac{\mathbf{v}_a \cdot \mathbf{v}_b}{|\mathbf{v}_a| |\mathbf{v}_b|} \quad (2)$$

式中:  $\mathbf{v}_a = \begin{pmatrix} \cos \alpha_a \cdot \cos \delta_a \\ \cos \alpha_a \cdot \sin \delta_a \\ \sin \delta_a \end{pmatrix}$ ,  $\mathbf{v}_b = \begin{pmatrix} \cos \alpha_b \cdot \cos \delta_b \\ \cos \alpha_b \cdot \sin \delta_b \\ \sin \delta_b \end{pmatrix}$ , 为

其在天球系中的单位方向矢量。

如图 1, 根据式(2)三颗导航星 star1, star2, star3 的 3 个角矩  $d_{12}, d_{13}, d_{23}$  构造出唯一球面三角形, 向量  $\mathbf{V} = (d_{12}, d_{13}, d_{23})^T$  作为神经网络的样本进行训练。为了增加特征矢量的维数, 加入星等信息, 可以提高分类的准确程度。但精细导星仪对星等的测量误差较大, 为了降低星等误差对分类的影响, 将星等信息乘以系数  $\varepsilon (0 < \varepsilon < 1)$ , 加入星等信息的星三角特征矢量为  $\mathbf{V} = (d_{12}, d_{13}, d_{23}, l_1, l_2, l_3)^T$ ,  $l$  如式(3)求得:

$$l = \varepsilon M_v \quad (3)$$

式中:  $M_v$  为视星等, 由探测器上星光能量得到。

在天球坐标系划分 0.25 degree<sup>2</sup> 的视场进行星库的构建。导航星库中构成的星三角有些角距过大超出视场, 有些三颗星近似在一条直线上, 有些三条边长度差较小, 建立导航星三角时添加如下约束:  $d_{12} > d_{13} > d_{23}$  且  $d_{12} - d_{13} > 0.2^\circ$ ,  $d_{13} - d_{23} > 0.2^\circ$ ,  $M_v \in [10, 14]$ ; 约束可保证导航星三角的唯一性以及完备性。

### 1.2 层叠式SOM神经网络模型

导航星库内星三角数量较多, 使用单级 SOM 神经网络训练计算量大, 且不容易收敛, 星图识别算法一般使用多级 SOM 网络的方法实现, 首先对导航星三角实现粗分类, 将相似的星三角归入一类; 第二级实现精确分类, 区分每一个星三角。两级 SOM 神经网络的星图识别算法示意图如图 2 所示。

SOM 神经网络的星图识别算法分为在线训练阶段和离线运行阶段。在线训练阶段通过输入样本训练权值,  $\mathbf{V}_i$  为星特征矢量,  $w_{ij}$  为星特征矢量与神经元之间的连接权值, 是网络训练的对象。各层权值的训练方法为:

1) 提供已知星特征矢量样本。任选导航星库  $Q$  个学习样本中的某个  $\mathbf{V}_k = (d_{12}, d_{13}, d_{23}, l_1, l_2, l_3)^T$ ,  $k = 1, 2, \dots, Q$  提供给网络作为输入。

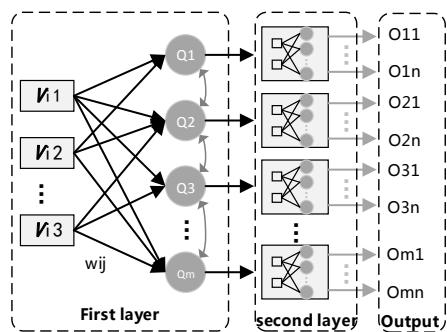


图2 两级 SOM 神经网络

Fig.2 Two layers SOM neural network

2) 距离计算。计算权值  $W_i = (w_{i1}, w_{i2}, \dots, w_{iR})$  与输入模式  $V_k$  之间的距离  $d_i$ , 计算公式如下:

$$d_i = \left[ \sum_{j=1}^R (V_j^k - w_{ij})^2 \right]^{1/2}, i = 1, 2, \dots, S \quad (4)$$

3) 最小距离选择。找出输入向量与权值的最小距离  $d_g$ , 确定获胜神经元  $g$ :

$$d_g = \min(d_i), i = 1, 2, \dots, S \quad (5)$$

4) 计算并调整权值  $w_{ij}$ 。确定邻域范围, 对获胜神经元邻域范围内的神经元进行权值调整, 调整公式如下所示:

$$w_{ij}(t+1) = w_{ij}(t) + \rho(t) \cdot (V_j^k - w_{ij}(t)), j = g \quad (6)$$

$$w_{ij}(t+1) = w_{ij}(t) + \frac{\rho(t)}{2} \cdot (V_j^k - w_{ij}(t)), j \in h \quad (7)$$

$$w_{ij}(t+1) = w_{ij}(t), \text{others} \quad (8)$$

式中:  $w_{ij}(t+1)$  为  $t+1$  时刻权值;  $h$  为获胜神经元  $g$  的邻域范围;  $\rho(t)(0 < \rho(t) < 1)$  为学习率。

5) 提供下一组输入样本。在样本集中随机抽取其它训练样本提供给网络作为输入, 重复步骤 2)、3)、4) 直到所有样本输入完, 训练完成。

网络的第二级的训练方法与第一级类似, 其输入为经过粗分类的满足一定相似性的星三角。

经过在线训练, 已经将输入测试向量聚类, 且  $w_{ij}$  与输入测试矢量较“相似”, 即满足式(9),  $\theta$  为某一较小阈值:

$$\|\mathbf{V} - \mathbf{W}_i\| = \sqrt{(\mathbf{V} - \mathbf{W}_i)^T (\mathbf{V} - \mathbf{W}_i)} < \theta \quad (9)$$

精细导星仪不同于传统星敏感器, 在低纬度天区视场内星数较多, 例如视轴指向为(175, 0)时视场内星数为 37 颗, 视轴指向为(85, 20)时视场内星数为 41 颗。在视场内选取星三角时有很大概率其不在导航星库内, 如果将其直接输入训练好的 SOM 神经网络, 将

会出现误分类的情况, 导致匹配失败。如图 3, 实际拍摄到星图中的星特征矢量  $\mathbf{V}_1, \mathbf{V}_2$  都与  $\mathbf{W}_1$  距离较近, 同属于第一类, 但是  $\mathbf{V}_1$  到  $\mathbf{W}_1$  的距离比  $\mathbf{V}_2$  到  $\mathbf{W}_1$  的距离小, 所以  $\mathbf{V}_1$  作为真实星特征向量的概率较大, 应将  $\mathbf{V}_1$  送入第二级。

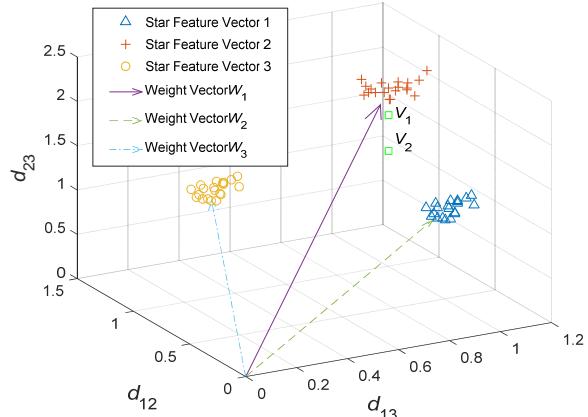


图3 SOM 网络分类示意图

Fig.3 Schematic of classification of SOM network

层叠式 SOM 神经网络的星图识别算法可以解决此问题, 基本原理为将训练好的第一级复制  $n$  层, 每一层都接受一个星三角输入, 第一层同时处理  $n$  个星特征矢量。设视场内的有效星特征矢量数为  $M$ , 则需要运算的次数为:

$$m = \left\lceil \frac{M}{n} \right\rceil \quad (10)$$

算式  $\lceil x \rceil$  表示对浮点数  $x$  取上限。

设视场内星特征矢量矩阵为  $\mathbf{V}_{MN}$ ,  $x$  为星特征矢量个数,  $N$  为星特征矢量维数; 权值矩阵为  $\mathbf{W}_{1NP}$ ,  $P$  为输出神经元个数。设向量  $D$  表示各星特征矢量与权值之间的最小距离, 则:

$$D_i = \max(\mathbf{L}_i) \quad (11)$$

$$\mathbf{L}_i = \mathbf{W}^T \cdot \mathbf{V}_i^T \quad (12)$$

式中: 向量  $\mathbf{L}_i$  表示性特征矢量  $\mathbf{V}_i$  与权值矩阵  $\mathbf{W}^T$  中各个向量的距离;  $\max(\mathbf{L}_i)$  表示取  $\mathbf{L}_i$  中元素的最大值, 值越大, 表示输入星特征矢量与某一权值越相似。

向量  $\mathbf{D}$  中各元素为星特征矢量矩阵  $\mathbf{V}_{MN}$  中各矢量对应的距离权值的最小值, 我们取  $\mathbf{D}$  中元素的最小值, 将其输入到第二层 SOM 网络进行细分, 第二层的输出即是该星三角的分类结果, 代表了导航星。该模型的优点是选取星图中与某一权值矢量最接近的星特征矢量作为候选导航星矢量输入网络, 可以最大程度的避免非导航星引起的误匹配; 并且每一层权值相同, 只需要训练一次权值即可部署在 FPGA 内部, 且各层同时运行, 可增大数据吞吐量, 减少算法运行时间, 星图匹配速度比一般方法提高了  $M/m$  倍, 层数

越多, 算法效率提升的越多。

图4为层叠式SOM神经网络的星图识别算法模型示意图, 该模型由3部分组成。第一部分由单级SOM神经网络形成层叠式结构, 每一层的权值及连接方式相同。最小距离计算单元负责计算当前值与上一次值的大小并保存最大值, 配合第一级SOM神经网络完成粗分类。第二级负责将符合相似性的星特征矢量进行细分类, 输出匹配结果。

算法流程如图5, 每次在星三角池选取n个星三角送入层叠式SOM的第一级, n为网络第一层的层叠数。最小距离计算单元内存储的是与权值距离最近的星三角向量及第二层SOM子分类。获胜的星三角向量被送入第二层激活的子单元并得到最终的激活单元, 从而得到给星三角包含三颗星经纬度信息。

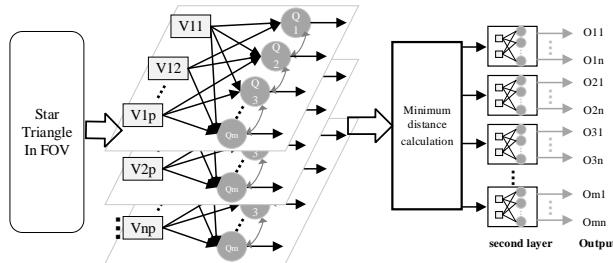


图4 层叠式自组织映射(SOM)神经网络算法模型

Fig.4 Model of stacked SOM neural network algorithm

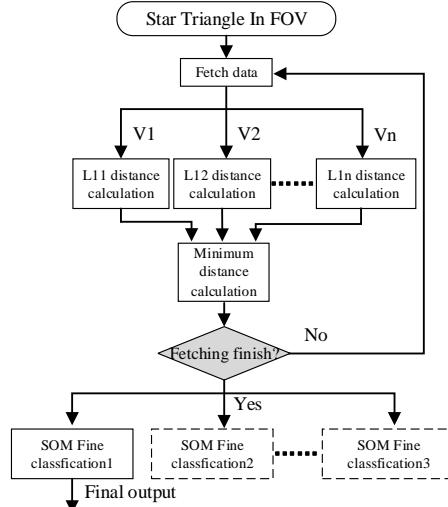


图5 算法流程图

Fig.5 Algorithmic flow diagram

## 2 算法FPGA硬件实现

### 2.1 算法硬件电路模块设计

计算输入星特征矢量与权值矩阵最小距离时, 采用曼哈顿距离。曼哈顿距离将欧几里得距离计算中的乘法及乘方操作简化为简单的加减过程, 且取绝对值

运算实现简单。

向量  $\mathbf{X}(x_{11}, x_{12}, \dots, x_{1n})$  与  $\mathbf{Y}(x_{21}, x_{22}, \dots, x_{2n})$  之间的曼哈顿距离  $d_{12}$  可以表示为:

$$d_{12} = \sum_{k=1}^n |x_{1k} - x_{2k}| \quad (13)$$

取绝对值电路如图6所示。

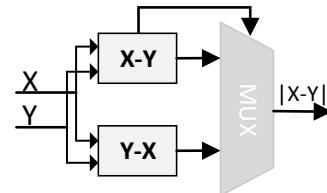


图6 曼哈顿距离计算电路

Fig.6 Manhattan distance calculation circuit

计算完星特征矢量与权值的距离后, Winner Take All (WTA)模块通过比较, 选择出距离最小者作为获胜神经元最终输出, 电路由级联多路比较器实现, 如图7所示, 每一个多路选择器输出为输入中最小者。由于比较器每次只能比较两个值的大小, 最长路径消耗时钟周期为  $\log_2^n$ , SOM第一层分类为8, 需要三级比较器级联。对于采用流水线的实现方式, 只会增加电路的延时, 对电路运行速度没有影响。

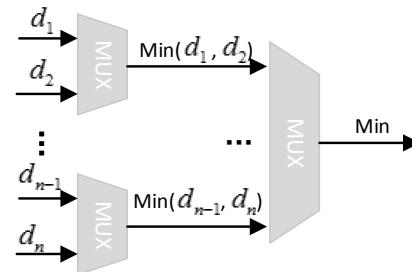


图7 级联比较器电路

Fig.7 Cascade comparator circuit

SOM单级神经网络的实现方式如图8所示, 输入星特征矢量与各权值计算曼哈顿距离, 经过WTA模块输出为该层获胜神经元对应的最小距离以及星特征矢量。

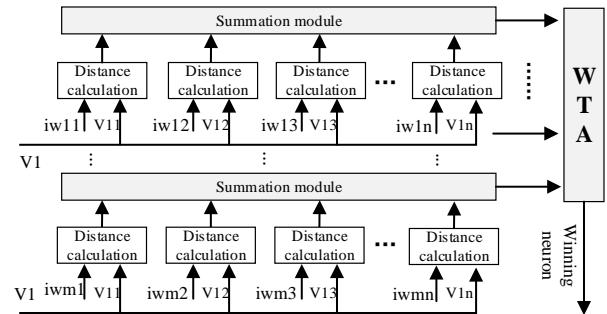


图8 单层SOM神经网络电路

Fig.8 Single layer SOM neural network circuit

最小距离计算单元电路如图 9 所示, 原理为输入与前一个值比较, 较大者替换较小者, 寄存器中保存的是最小距离及其对应的星特征矢量。

## 2.2 算法流水线划分

层叠式 SOM 神经网络第一级流水线模型如图 10 所示。识别算法划分为 5 级流水线:  $T_1$  阶段计算曼哈顿距离;  $T_2$ 、 $T_3$ 、 $T_4$  阶段逐次比较上一级计算的距离大小, 且各层同步进行;  $T_5$  阶段计算各层获胜神经元

的距离最小值, 并将其送到下一级进行细分类。

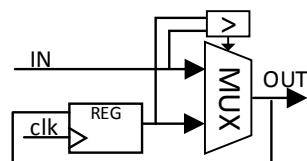


图 9 最小距离计算电路

Fig.9 Minimum distance calculation circuit

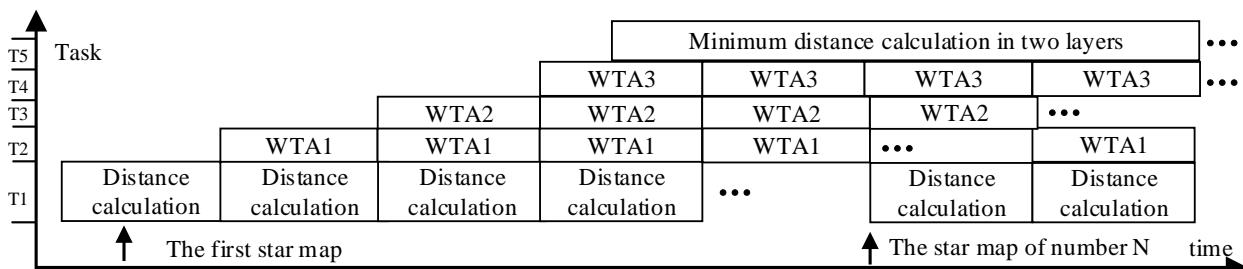


图 10 模型流水线划分

Fig.10 Design of the pipeline of the model

## 3 实验验证与算法稳定性分析

算法验证实验由 FPGA 为主的硬件平台完成, 平台硬件电路如图 11 所示。FPGA 通过以太网与上位机通信, 将星图匹配结果上传上位机进行匹配性能统计。实验平台结构框图如图 12 所示。

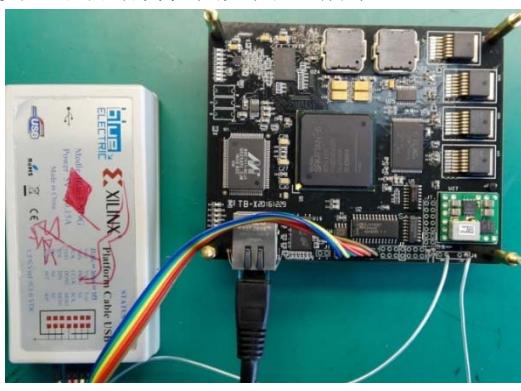


图 11 硬件验证平台

Fig.11 Hardware verification platform

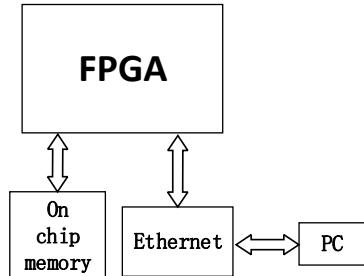


图 12 硬件框图

Fig.12 Hardware block diagram

神经网络在线训练: 首先在 PC 上对导航星库提

取星特征矢量, 并进行筛选, 剔除掉角距过大和近似处于同一直线的三颗星。以筛选完的星特征矢量作为训练样本对 SOM 神经网络进行训练, 当网络完全收敛后得到各层权值。将训练完的权值应用于硬件平台, 按照 1.2 节提出的模型构建层神经网络硬件电路。

设当前视轴指向天球经纬度为(175,0), 大小为  $0.25\text{degree}^2$  天区, 将该天区导航星按照 1.1 节的星特征矢量筛选条件构造出的星对角距为 75 个。天区星图和区域内星三角分布分别如图 13, 图 14 所示, 构造的导航星分布较为均匀。构建的星特征矢量如表 1 所示。

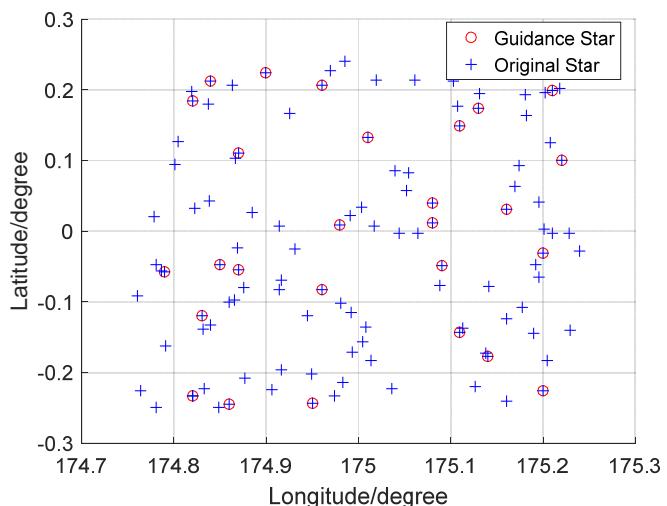


图 13  $0.25\text{degree}^2$  视场内恒星分布

Fig.13 The stars distribution of  $0.25\text{ degree}^2$  FOV

第一级的训练分类结果如图 15 所示。层叠式 SOM

神经网络将输入的 75 个导航星特征矢量比较均匀地粗分为 8 个类别。网络的第二级将第一级粗分类的结果进行细分类, 获胜神经元将精确到每一个星特征矢量。

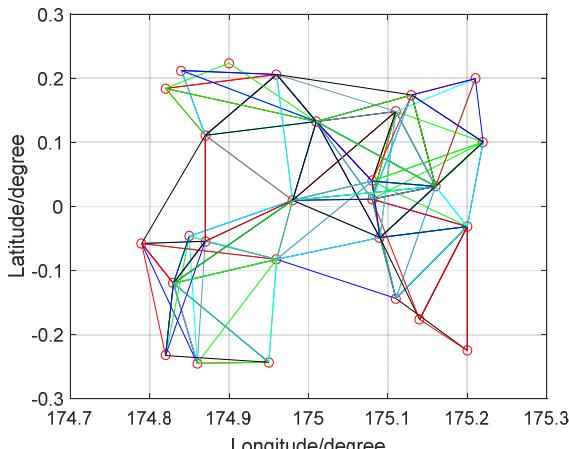


图 14 视场内星三角

Fig.14 Tri-star in the FOV

表 1 视场内星特征矢量

Table 1 Star feature vector in the FOV

	$d_{12}$	$d_{13}$	$d_{23}$	$l_1$	$l_2$	$l_3$
$V_1$	0.0900	0.1282	0.1720	0.0941	0.1038	0.1086
$V_2$	0.0900	0.1609	0.1904	0.0943	0.1038	0.1013
$V_3$	0.0738	0.1282	0.1994	0.0946	0.1081	0.1086
$V_4$	0.0759	0.1282	0.1981	0.0422	0.0803	0.1086
...	...	...	...	...	...	...
$V_{75}$	0.0759	0.1156	0.1352	0.0803	0.1086	0.1013

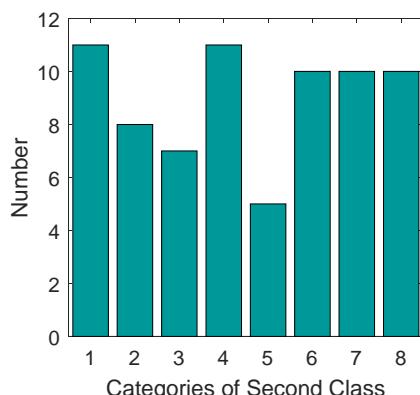


图 15 SOM 神经网络第一级分类结果

Fig.15 Classification result of SOM neural network first layer

神经网络离线运行: 在待测试天区随机产生视轴指向, 将视轴周围  $0.08\text{degree}^2$  区域内的 10-14 等星作为输入, 按照 2.1 节所述方法构建星特征矢量。将构建好的星特征矢量输入到 FPGA 实现的层叠式 SOM 神经网络星图匹配算法模型进行匹配, 并评估匹配是否成功。重复该过程 500 次, 计算识别成功率。然后

给待测试天区恒星加入星点位置噪声和星等噪声, 各测试 500 次, 计算识别成功率。

星点位置噪声和星等噪声对层叠式 SOM 神经网络星图匹配算法识别率的影响如图 16、17 所示。

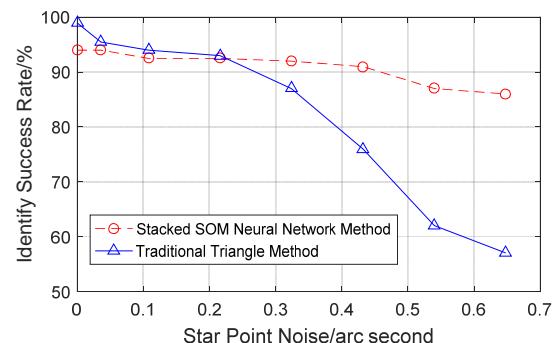


图 16 星点位置噪声对星图识别率的影响

Fig.16 Effect of star point noise on star recognitionrate

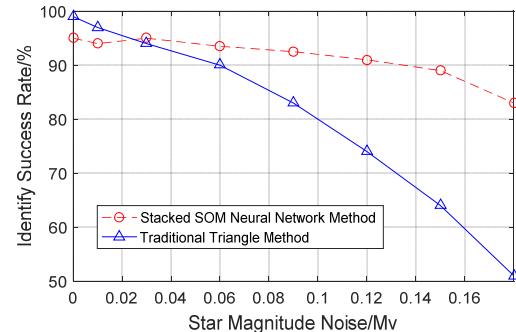


图 17 星等噪声对星图识别率的影响

Fig.17 Effect of star magnitude noise on star recognition rate

星图识别时间如图 18 所示。

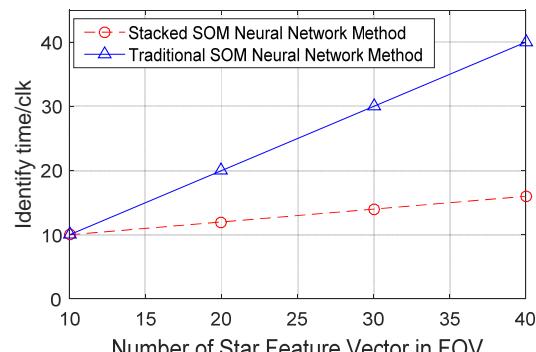


图 18 视场内星特征矢量数对星图识别时间的影响

Fig.18 Effect of the number of star feature vector in FOV on star recognition speed

由实验结果可知, 原始星图未加噪声情况下传统三角形星图识别算法识别率略高于层叠式 SOM 神经网络星图匹配算法。加入星点位置噪声和星等噪声后, 传统三角形算法识别率迅速减小, 而新算法则保持了较高的识别率, 在星点位置噪声为  $0.648''$ , 星等

噪声为 0.18 视星等情况下,传统三角形算法星图识别成功率分别为 57% 和 51%; 新算法星图识别成功率分别为 86% 和 83%, 高于三角形法, 算法鲁棒性较强。这是因为三角形法特征维数低, 存在冗余匹配; 而层叠式 SOM 神经网络星图匹配算法通过训练权值, 记忆了输入导航星特征矢量的模式分组, 不需要匹配, 直接计算输出结果。

在算法运行速度方面, 由于新算法第一级采用多层并行输入的方式, 层与层之间同步运行, 可以同时处理多个输入星特征矢量, 而传统 SOM 神经网络星图匹配算法每次只能处理一个星特征矢量, 而且极易出现误分类。在 FPGA 内部时钟频率为 10 MHz, 星特征矢量为 40 个的情况下, 新方法匹配一幅星图时间为 1.6  $\mu$ s, 比传统 SOM 神经网络算法快 2.5 倍; 星三角匹配算法在 PC 机上识别一幅星图的时间为 160  $\mu$ s, FPGA 中实现的新算法识别速度是其 100 倍。

不同纬度天区包含导航星的数量差别较大, 低纬度稠密, 高纬度较为稀疏; 为了验证算法的稳定性, 选取了不同纬度的天区星图来测试识别成功率。图 19 显示了在星点位置噪声为 0.5", 星等噪声为 0.1 视星等情况下星图识别成功率随天球纬度的变化。低纬度星数量多, 视场内星三角特征矢量数量巨大, 极易出现星特征矢量冗余的情况, 此时星图匹配成功率较低; 随着纬度的升高, 恒星分布变稀疏、均匀, 星图匹配率达到最大值; 当视场接近两极时, 有效星等的导航星数骤减, 但星图匹配成功率依然能够达到 60%, 算法的稳定性较强。

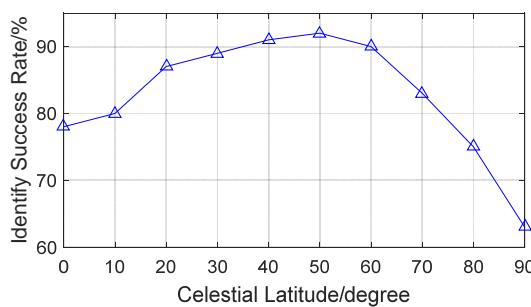


图 19 天球不同纬度星图识别率

Fig.19 Star recognition rate at different latitudes

#### 4 结束语

本文提出了一种层叠式 SOM 神经网络星图识别算法。该算法对比传统三角形法和神经网络算法在运行效率和匹配成功率上都有很大的改进, 且算法鲁棒性更强; 新算法充分利用了神经网络的拓扑结构及 FPGA 的并行运算特性, 设计了硬件数字电路, 充分发挥算法的实时性, 缩短了运算时间。在有噪声情况

下, 星图识别成功率较传统方法提高了 60%; 识别速度是传统方法的 100 倍。为后级姿态解算留出了更多时间, 对提高姿态输出数据更新率更为有利。

#### 参考文献:

- [1] 时圣革, 雷肖剑, 于长海. 星图识别三角形算法综述[J]. 光电技术应用, 2014, 29(5): 1-6.  
SHI Shengge, LEI Xiaojian, YU Changhai. Triangle algorithm overview of star pattern recognition[J]. *Electro-optic Technology Application*, 2014, 29(5):1-6.
- [2] Craig L. Cole, John L. Crassidis. Fast star pattern recognition using spherical triangles[J]. *Providence RI:AIAA*, 2004, 29(1): 64-71.
- [3] 张磊, 何昕, 魏仲慧, 等. 三角形星图识别算法的改进[J]. 光学精密工程, 2010, 18(2): 458-463.  
ZHANG Lei, HE Xin, WEI Zhonghui, et al. Modification of triangle identification algorithm[J]. *Optics and Precision Engineering*, 2010, 18(2): 458-463.
- [4] 李辉, 王安国, 张磊. 改进金字塔算法用于小视场星图识别[J]. 应用光学, 2013, 34(2):267-272.  
LI Hui, WANG Anguo, ZHANG Lei. Modified pyramid algorithm for small FOV star Image recognition[J]. *Journal of Applied Optics*, 2013, 34(2): 267-272.
- [5] 钱华明, 孙龙, 蔡佳楠, 等. 星图识别的一种扩充栅格算法[J]. 哈尔滨工业大学学报, 2015, 47(2):110-116.  
QIAN Huaming, SUN Long, CAI Jianan, et al. An extended grid algorithm in star identification field[J]. *Journal of Harbininstitute of Technology*, 2015, 47(2):110-116.
- [6] 张少迪, 王延杰, 孙宏海. 三角剖分以及径向基函数神经网络在星图识别中的应用[J]. 光学精密工程, 2012, 20(2): 395-402.  
ZHANG Shaodi, WANG Yanjie, SUN Honghai. Application of triangulation and RBF neural network to star pattern recognition[J]. *Optics and Precision Engineering*, 2012, 20(2): 395-402.
- [7] 江浩, 樊晓宇. 基于 FPGA 的局部天区星图识别技术[J]. 导弹与航天运载技术, 2013, 20(1): 68-70.  
Jiang Hao, Fan Xiaoyu. Local area star identification by FPGA[J]. *Missiles AND Space Vehicles*, 2013, 20(1): 68-70.
- [8] 王一木, 潘赟, 龙彦辰, 等. 基于自组织映射的手写数字识别的并行实现[J]. 浙江大学学报: 工学院版, 2014, 48(4): 742-747.  
WANG Yimu, PAN Yun, LONG Yanchen, et al. Parallel implementation of handwritten digit recognition system using self-organizing map[J]. *Journal of Zhejiang University: Engineering Science*, 2014, 48(4): 742-747.
- [9] 夏飞, 罗志疆, 张浩, 等. 混合神经网络在变压器故障诊断中的应用[J]. 电子测量与仪器学报, 2017, 31(1): 118-124.  
XIA Fei, LUO Zhijiang, ZHANG Hao, et al. Application of mixed neural network in transformer fault diagnosis[J]. *Journal of Electronic Measurement and Instrumentation*, 2017, 31(1): 118-124.
- [10] 邹瑜, 帅仁俊. 基于改进的 SOM 神经网络的医学图像分割算法[J]. 计算机工程与设计, 2016, 37(9):2533-1537.  
ZOU Yu, SHUAI Renjun. Improved segmentation algorithm of medical images based on SOM neural network[J]. *Computer Engineering and Design*, 2016, 37(9): 2533-1537.