

雷达高度表延时多普勒匹配定位网络

刘 丛¹, 鲁彦希², 刘高正², 谭龙龙², 李 芳², 杨 磊¹

(1. 中国民航大学天津市智能信号与图像处理重点实验室, 天津 300300;
2. 中国工程物理研究院电子工程研究所, 四川绵阳 621000)

摘要: 由合成孔径雷达高度表获得的延迟多普勒图像(Delay Doppler Map, DDM)因具有近垂直耦合的特点,易造成相邻地形DDM相似度高,进而导致图像匹配成功率低。针对该问题,本文提出了一种雷达高度表延时多普勒匹配定位网络(Delay Doppler Map Matching and Positioning Network, DDM-MPN),首次通过对DDM实测基准图像对进行匹配,实现飞行器的实时位置定位。首先,该方法采用浅层卷积神经网络架构,在保持较高匹配成功率的基础上降低了模型的复杂度和参数量,有效地节约了资源成本;其次,在传统图像匹配网络的基础上加入了坐标定位模块,使网络在完成图像匹配的同时实现对飞行器当前位置的三维坐标定位;最后,该方法通过对三元组损失函数、中心损失函数、交叉熵损失函数以加权的方式对网络参数进行协同优化,提高了匹配成功率和定位精度。模拟仿真实验的测试结果表明:沿航向水平面平均定位误差在30 m左右,垂直航向平均定位误差在60 m左右,三维总体平均定位误差在70 m左右,匹配成功率达到80%以上,在GPS拒止的情况下,该自主定位精度对大型飞行平台是可用的。

关键词: 合成孔径雷达高度表; 神经网络; 图像匹配; 坐标定位

中图分类号: TN958; TN957.52

文献标志码: A

文章编号: 1672-2337(2024)04-0454-10

引用格式: 刘丛, 鲁彦希, 刘高正, 等. 雷达高度表延时多普勒匹配定位网络[J]. 雷达科学与技术, 2024, 22(4): 454-463.

LIU Cong, LU Yanxi, LIU Gaozheng, et al. Radar Altimeter Delay Doppler Map Matching and Positioning Network[J]. Radar Science and Technology, 2024, 22(4): 454-463.

Radar Altimeter Delay Doppler Map Matching and Positioning Network

LIU Cong¹, LU Yanxi², LIU Gaozheng², TAN Longlong², LI Fang², YANG Lei¹

(1. Tianjin Key Laboratory for Advanced Signal Processing, Civil Aviation University of China, Tianjin 300300, China;

2. Institute of Electronic Engineering, China Academy of Engineering Physics, Mianyang 621000, China)

Abstract: Due to the characteristics of near vertical coupling, the delay Doppler map (DDM) obtained from the synthetic aperture radar altimeter is easy to cause high similarity of DDM between adjacent terrains, which leads to low success rate of image matching. Aiming at this problem, a radar altimeter delay Doppler map matching and positioning network (DDM-MPN) is proposed, which for the first time realizes the real-time positioning of aircraft by matching the DDM measured reference image pair. Firstly, a shallow convolutional neural network architecture is employed, which can reduce the complexity and parameter number of the model while maintaining a high matching success rate, and effectively saves the resource costs. Secondly, a positioning module is added on the basis of the traditional image matching network, so that the network can realize the three-dimensional coordinate positioning of the current position of the aircraft while completing the image matching. Finally, the proposed method optimizes the network parameters in a weighted way by triplet loss function, center loss function and cross-entropy loss function, which improves the matching success rate and positioning accuracy. According to the test results of simulation experiments, the average positioning error in the horizontal plane is about 30 meters, the average positioning error in the vertical plane is about 60 meters, the overall average positioning error in 3D is about 70 meters, and the matching success rate is more than 80%. In the case of GPS rejection, the autonomous positioning accuracy is available for large flight platforms.

Key words: synthetic aperture radar altimeter; neural network; image matching; coordinate positioning

收稿日期: 2023-12-21; 修回日期: 2024-03-23

基金项目: 国家自然科学基金(No.62271487)

0 引言

目前,利用遥感技术进行飞行器自主导航定位常用光学图像和SAR(Synthetic Aperture Radar)图像或二者的数据融合,然而,光学图像易受到光照及天气的影响,SAR图像易受到大气湍流等影响而产生方位向散焦。相较于光学图像,由雷达高度表获得的DDM图像因不受光照条件限制而具有全天时、全天候的工作能力,且不同于依赖侧视长时相干积累形成的SAR图像,由SARAL(Synthetic Aperture Radar Altimeter)正下视得到的DDM图像相干积累时间短,所需脉冲数少。同时,合成孔径雷达高度表在方位向引入合成孔径思想,通过同时发送多个脉冲并接收多个回波信号,利用多普勒延时技术获得比实孔径雷达更高的分辨率。因此,在起伏地形下获取机载合成孔径雷达高度表机下点照射区域的DDM成像结果,实现对大型飞行平台可用精度的图像匹配定位,对GPS拒止情况下飞行器自主定位导航具有重要意义。

然而在实际应用中,SARAL的正下视工作方式使得所成DDM图像具有近垂直耦合的特点,即由于天线波束具有一定宽度,波束向下照射时,可能会面临与飞行器相距较近的回波信号先被接收,而天底点的信号后被接收的情况,易导致相邻位置的雷达图像差异极小,且由于SARAL的短时观测特性,易导致所成图像缺少全局特征。同时,由于左右两侧散射点的信息混叠于图像中心,以及散斑噪声的影响,在一定程度上降低了图像的质量。此外,对于同一区域地形来说,当飞行器的飞行状态不同时,所成DDM图像的形态也不同,正确匹配的难度较大。

目前,图像匹配方法可以分为基于图像灰度信息^[1]的方法和基于图像特征^[2]的方法^[3-5]。基于灰度信息方法的核心思想是利用图像的灰度信息来完成图像的匹配,该类方法虽无需分割图像及提取图像特征的特性就可以将预处理所造成的精度损失降到最低^[6],但对成像条件、图像形变以及噪声极其敏感,同时具有较高的计算复杂度,从而限制了其应用能力^[7]。基于特征方法的核心思想是利用图像中点、线、面等能够表示图像特征的信息来完成图像的匹配^[8-9],特征是对局部信息的抽

象描述,在保留图像关键信息的同时又大大减少了数据量,很好地弥补了基于灰度方法匹配的缺点,对各种变化的鲁棒性很好^[10],计算速度快同时具有较好的匹配精度^[11],因此在图像匹配领域被广泛应用。

早期图像匹配方法以特征点检测为主,如加拿大教授Lowe提出的经典尺度不变特征变换方法SIFT^[12]等,该方法对旋转、尺度缩放、亮度变化等保持不变性^[13-14],但随着系统对实时性、精确性和鲁棒性要求的日益提高,以SIFT为代表的人工定义的特征算子已无法满足需求^[15]。随着人工智能深度学习技术的兴起,使用卷积神经网络的方法进行局部特征点提取的性能已经远超SIFT特征,如Yi等提出的LIFT^[16]网络,但由于点特征类算法对图像质量要求较高,通常情况下不适用于图像质量较低的DDM图像匹配。针对输入数据的特殊性,近年来将具有双输入数据特点的孪生网络^[17]结构搭配对比损失函数协同使用的方法成为图像匹配的主流,但对比损失中负样本是依靠弱先验性均匀随机选取的,在相似度较高的DDM匹配任务中性能表现较差。


针对上述问题,本文提出了一种基于DDM-MPN的飞行器匹配定位方法,该方法使用浅层卷积神经网络对DDM图像进行特征提取,同时使用三元组损失、交叉熵损失与中心损失函数以加权的方式协同优化网络参数,充分利用正负样本关注图像的细粒度区别,以提高匹配成功率。此外,由于传统图匹配网络的最终输出为相似度,并不能实现飞行器的坐标定位,故在图匹配神经网络的基础上增加坐标输出模块。最后针对所提网络在不同航迹点下进行模拟仿真实验,地形数据选用湖北十堰市飞行场景,平台模拟为机载平台,雷达频段为Ka波段,雷达口径为0.3 m,并通过与传统孪生网络搭配对比损失方法及ResNet18、VGG16等深层卷积神经网络进行数据对比,验证了所提网络对SARAL所成DDM匹配的有效性、鲁棒性、优越性与高效性。

1 机载SARAL几何与信号模型


1.1 几何模型

机载SARAL的几何模型如图1所示。如图1

(a)所示,机载SARAL沿一直线进行飞行运动,在一段较短的飞行距离内对同一地物目标的回波信号进行接收并进行解线性调频及RVP(Residual Video Phase)校正等处理^[18]。根据波束区域内不同角度的地物会产生不同多普勒频率的基本原理,利用多普勒波束锐化技术(Doppler Beam Sharpening, DBS)将一个真实天线波束进一步细分为若干个子波束,即所谓的锐化^[19],以获得比真实波束更精细的方位向分辨能力。图1(b)表示根据多普勒频率对同心圆形式的脉冲足迹添加等距线和多普勒线进行细分,细分后的脉冲足迹均代表一回波信号^[20]。其中,方位向为飞行器的飞行方向,距离向为观测表面垂直于飞行方向的方向。



(a) 机载SARAL几何模型



(b) 多普勒脉冲足迹

图1 合成孔径雷达高度表工作原理示意图

1.2 信号模型

如图1(a)所示,机载SARAL以恒定速度 V_s 沿高度为 h_0 ,方向为 X 轴的航迹飞行,地面散射点目标 T 的坐标设置为 (x_0, y_0, z_0) 。当机载SARAL经过点目标 T 正上方时,垂直距离 $h = |h_0 - z_0|$,经时延后接收到的回波信号如下:

$$s(t, t_s) = A_0 \exp \left\{ j \left[2\pi f_c \left(t - \frac{2R(t_s)}{c} \right) + \pi K_r \left(t - \frac{2R(t_s)}{c} \right) \right] \right\} \quad (1)$$

式中, t 和 t_s 分别为距离向快时间和方位向慢时间, A_0 为散射系数, $R = \sqrt{h_{\text{ref}}^2 + (V_s t_s)^2}$ 为SARAL与地面目标 T 之间的斜距, h_{ref} 为SARAL到目标表面高度的粗略估计, f_c 为载波频率, K_r 为调制频率, c 为光速。接收到的回波信号经解线性调频后可得式(2)。

$$s(t, t_s) = A_0 \exp \left[-j \frac{4\pi}{c} K_r (R - h_{\text{ref}}) t \right] \cdot \exp \left[j \frac{4\pi}{c} (f_c + K_r t) \frac{x_0}{h_{\text{ref}}} V_s t_s \right] \quad (2)$$

沿航向对式(2)通过FFT进行DBS处理,即可得到DDM图像 X 的表示式(3)。其中 $f_d(m)$ 为SARAL产生的第 m 个多普勒频率。

$$X = s(t, f_d(m)) = A_0 \exp \left[-j \frac{4\pi}{c} K_r (R - h_{\text{ref}}) t \right] \cdot \text{sinc} \left\{ T_s \left[\frac{2x_0}{\lambda h_{\text{ref}}} V_s - f_d(m) \right] \right\} \quad (3)$$

回波经上述处理后获得DDM图像 X ,其示意图如图2所示。其中,横坐标代表距离门,纵坐标代表多普勒频率。




图2 DDM示意图

2 延时多普勒匹配定位网络

基于延时多普勒图像的匹配定位方法流程图如图3所示。网络输入为实时图像和预存的匹配基准图像,将输入图像分别输入到经训练的卷积

神经网络进行特征提取,以获得其特征嵌入表征向量,同时利用 ℓ_1 正则化对网络进行模型约束,以缓解模型过拟合。再将实时图像的特征嵌入表征向量与预存的匹配基准图像的特征嵌入表征向量集合进行相似度的遍历计算,对不同地形数据重复匹配步骤可得到相似度列表,将相似度列表降序排列,取相似度最高处坐标或相似度前三处坐标平均值作为飞行器当前的定位坐标。




图3 基于延时多普勒图像的匹配定位方法流程图

2.1 基于卷积神经网络的特征提取网络

本文的特征提取框架采用计算机视觉和图像处理问题中常用的卷积神经网络,区别于Res-Net18、VGG16等经典深层卷积网络,本实验搭建了一个7层卷积的浅层卷积网络,用更少的参数和训练时间可达到与重量级神经网络相当甚至更高的定位精度和匹配成功率。

所用卷积神经网络的具体网络参数如图4所示。网络的输入为 201×201 大小的灰度图。其中,“ $3 \times 3 \text{ conv}, 32$ ”表示卷积核大小为 3×3 ,卷积核个数为32的卷积层,不加“/2”的层默认卷积步长为1,否则为2。除最后一层外其余各层之后的激活函数均为ReLU函数。输入图像共经过7层卷积,后经最大池化和展开后得到输出的特征嵌入表征向量。




图4 特征提取网络

2.2 损失函数

通常,图像匹配任务的损失函数构建在样本对或者样本三元组之上,因而样本空间的量级非常大。基于样本对的损失函数称为对比损失函数^[17],基于样本三元组的损失函数称为三元组损失函数^[21],三元组损失函数因考虑了正负样本与锚点之间的距离关系而在细节区分上有明显的优势,在相邻地形极为相似的DDM图像上匹配成功率明显优于对比损失函数,故在实验中采用三元组损失函数。但模型在训练过程中很难穷举学习所有的样本三元组,且大多数样本三元组在模型训练的后期信息量很小,使得其梯度值几乎为0。若不采取有针对性的样本选取策略,网络的收敛速度会很慢,且易陷入局部最优,因此,常配合困难样本挖掘的学习策略一起使用,且大多数情况下会与分类损失结合使用。本实验共采用了3种损失函数,分别为困难样本三元组损失函数、中心损失函数和交叉熵损失函数,3种损失函数协同作用优化网络参数。网络损失函数可表示为

$$L = L_{\text{triplet}} + \beta L_{\text{center}} + L_{\text{EN}} \quad (4)$$

式中, L_{triplet} 为三元组损失函数, L_{center} 为中心损失函数, β 为中心损失权重,实验中设置 $\beta = 0.001$, L_{EN} 为交叉熵损失函数。

三元组损失函数的基本思想如图5所示,设定一个样本三元组分别为基准样本(Anchor)、正样本(Positive)和负样本(Negative),其中,基准样本和正样本为同类的不同样本,基准样本与负样本为异类样本。三元组损失函数试图学习到一个特征空间,使得在该空间中相同类别的基准样本与正

样本的距离尽可能接近,不同类别的基准样本与负样本的距离尽可能拉远^[21]。




图5 三元组损失函数基本原理

根据上述原理,假设 x_i^a, x_i^p, x_i^n 作为一组数据输入到卷积神经网络中,并得到对应的特征映射 $f(x_i^a), f(x_i^p), f(x_i^n)$,其中下缀 i 表示第 i 个批次, $f(\cdot)$ 表示网络等效的函数,上缀 a, p, n 表示对应的三元组样本,则三元组损失函数的思想用欧氏距离形式化可以表示为

$$\|f(x_i^a) - f(x_i^p)\|_2^2 + \alpha < \|f(x_i^a) - f(x_i^n)\|_2^2, \quad \forall (f(x_i^a), f(x_i^p), f(x_i^n)) \in T \quad (5)$$

式中 α 为间隔参数 margin, T 是训练集中所有可能三元组的集合,基数为 N 。此时,三元组损失函数可以表示为

$$L = \sum_i^N \left[\|f(x_i^a) - f(x_i^p)\|_2^2 - \|f(x_i^a) - f(x_i^n)\|_2^2 + \alpha \right]_+ \quad (6)$$

其中下标“+”表示:当中括号中的式子的值大于零时,即不满足不等式(5)时,此时损失大于零,网络通过反向传播更新参数;当中括号中的式子的值小于零时,即满足不等式(5)时,表示样本已满足训练要求,此时不产生梯度,网络参数不更新。而我们的目标就转变为训练网络模型使得式(6)的损失函数不断变小。

然而,三元组损失函数只考虑了样本间的相对距离,而没有考虑样本间的绝对距离。为了在保持类间特性可分离的同时最小化类内间距,引入中心损失函数,中心损失为每个类别提供了相应的类别中心,即一个与特征嵌入表征向量具有相同维度的向量^[22]。该损失函数通过学习每个类别的中心,使得类内的距离变得更加紧凑,弥补了三元组损失函数的缺点,表达式如式(7)所示。

$$L_{\text{center}} = \frac{1}{2} \sum_{i=1}^B \|x_i - c_{y_i}\|_2^2 \quad (7)$$

式中, x_i 为全连接层前的特征嵌入表征向量, y_i 为一个批量中的第 i 个图像的标签, $c_{y_i} \in R^d$ 为特征的第 y_i 个类中心, B 为批大小。

同时,参考行人重识别任务中常用的身份损失(ID Loss),实验采用交叉熵损失函数对网络进行协同约束,其中每一个类别为一个地形坐标值。

标准交叉熵损失函数原理如下。对于每个样本 x 计算归属每个标签 $i \in \{1, 2, \dots, N\}$ 的预测概率为

$$p_i = \frac{\exp(z_i)}{\sum_{k=1}^N \exp(z_k)} \quad (8)$$

式中, z_i 为神经网络的输出,称为逻辑分数或未归一化的对数概率。设该样本标准化的真实标签分布为 q_i ,那么有 $\sum_i q_i = 1$ 。简洁起见,忽略 p 和 q 对样本 x 的依赖关系,设 y 为真值标签,定义交叉熵损失函数如下:

$$L_{\text{EN}} = - \sum_{i=1}^N q_i \log(p_i) \begin{cases} q_i = 0, i \neq y \\ q_i = 1, i = y \end{cases} \quad (9)$$

2.3 样本选取策略

采用三元组损失函数的一个问题是训练集中生成的所有可能三元组中,可能生成许多容易满足约束式(5)的三元组。这些三元组称为简单样本三元组,对训练并没有实际帮助,并且会导致更慢的收敛速度和更差的泛化性能,因为它们仍然会通过网络。所以使用三元组损失函数的一个关键是尽可能选择难训练的三元组样本,即尽可能满足式(10),它们是活跃的,因此可以帮助改进模型,称为困难样本三元组。

$$d(a, n) < d(a, p) \quad (10)$$

式(10)表示负样本与基准样本间的距离小于正样本与基准样本间的距离,这是网络最难学习的样本组。但此时的损失值会出现较大的震荡,易出现网络难收敛和模型崩溃的问题。

故本实验采用半难样本三元组。半难样本三元组满足式(11),即负样本比正样本距离基准样本更远,但是距离差没有达到设定间隔,如图6所示,此时网络通过恰当的学习可以不断降低损失值,模型既可以学习到样本之间的差异,又较容易收敛。

$$d(a, p) < d(a, n) < d(a, p) + \text{margin} \quad (11)$$




图6 困难样本三元组与半难样本三元组对比

从一个批量的 B 个特征向量中挖掘半难三元组的方法如下。假设索引 $i, j, k \in [1, B]$, 其中 i 和 j ($i \neq j$) 具有相同的标签, k 具有不同标签, 此时 (i, j, k) 被称为是一个有效三元组。假设一个批数据, 由 P 个坐标点、每个坐标点下 K 张增强DDM图像构成, 即批大小 $B = P \times K$ 。此时可能产生 $PK(K-1)(PK-K)$ 个合规的三元组, 其中基准样本有 PK 个, 正样本有 $(K-1)$ 个, 负样本有 $(PK-K)$ 个。对于每个基准样本, 挑选一个最难正样本和最难负样本, 即最小相似度正样本与最大相似度负样本, 这个过程共产生了 PK 个三元组, 此时三元组损失可表示为

$$L_{\text{triplet}} = \frac{1}{P \times K} \sum_{a \in B} \left(\max_{p \in B} d_{a,p} - \min_{n \in B} d_{a,n} + \alpha \right)_+ \quad (12)$$

总的来说, 延时多普勒匹配定位网络的训练通用流程共包含3个部分, 即为特征提取网络、样本选取策略及损失函数, 如图7所示。




图7 DDM-MPN训练通用流程图

3 实验验证

基于延时多普勒图像的匹配定位算法由训练过程与测试过程构成, 其训练过程流程图如图8所示。训练过程包括5个主要部分: 首先将训练集设置为不同坐标点下的基准仿真DDM图像数据集, 并对其进行数据增强; 训练时从上述数据

集中的不同坐标位置随机抽取批量大小的图像, 并输入到卷积神经网络中进行特征提取; 根据特征嵌入表征向量的距离度量选取三元组样本; 锚样本、与锚样本标签一致的正样本对和与锚样本标签不一致的负样本对的相应特征用于三元组损失函数及中心损失函数的计算, 再通过分类器后得到分类结果, 用于交叉熵损失函数的计算; 再经反向传播对网络参数进行优化, 最后得到较好的网络模型。




图8 DDM-MPN训练过程

其测试过程流程图如图9所示, 包括5个主要部分: 首先将测试集设置为与训练集数据隔离的实测DDM图像数据集和预存的网格点仿真DDM图像数据集, 并且对数据集图像进行预处理; 将测试集中所有的实测DDM图像及预存仿真DDM图像输入训练后的网络中进行特征提取得到相应的特征嵌入表征向量; 之后, 利用某地形下的实测图与预存在飞行器基准图库中的所有图像进行遍历匹配; 接着将网络输出转换为余弦相似度, 得到匹配相似度列表; 最后将相似度列表降序排列, 取出相似度最高值或相似度前三对应的基准图索引, 该基准图的坐标或3个基准图的坐标平均即为网络预测的当前飞行器的实时坐标。




图9 DDM-MPN测试过程

基于以上的匹配算法进行模型训练,测试匹配的精度和成功率,并与传统的基于对比损失的孪生网络匹配方法进行比较。实验采用的深度学习框架为 Pytorch,评价指标为定位精度和匹配成功率。定位精度采用均方根误差(RMSE)衡量,公式如下:

$$RMSE_{AS} = \sqrt{\Delta_x^2 + \Delta_y^2 + \Delta_z^2} \quad (13)$$

$$RMSE_{HS} = \sqrt{\Delta_x^2 + \Delta_y^2} \quad (14)$$

$$RMSE_{VS} = |\Delta_z| \quad (15)$$

式中, $RMSE_{AS}$ 、 $RMSE_{HS}$ 和 $RMSE_{VS}$ 分别表示三维总体误差、水平面内误差和垂直航向误差,单位为m, Δ_x 、 Δ_y 和 Δ_z 分别表示 x 方向、 y 方向和 z 方向上的坐标误差。

由于垂直航向上高度几乎不变,默认平飞,故本实验将单次匹配中 $RMSE_{HS} \leq 50$ m的匹配结果视为匹配成功,自定义匹配成功率的计算公式如下:

$$ACC = \frac{N}{M} \quad (16)$$

式中, N 为匹配成功的次数, M 为总匹配次数。

3.1 数据集制备

该方法适用于复杂地形场景,故实验中选用湖北十堰市飞行场景,如图 10 所示,横向延伸 55 km,纵向延伸 37 km。数据集的制备方式为在地图中随机选取 5 000 个坐标点,并在每个坐标点下生成对应的 DDM 图像,均为灰度图像,图像尺寸为 201×201。前 4 000 个坐标点作为训练集坐标库,从中抽取 2 000 个坐标点作为训练数据集,后 1 000 个坐标点作为验证集坐标库,从中抽取 200 个坐标点作为验证数据集。与传统中心裁剪、翻转、随机擦除等数据增强方式不同,本实验对 DDM 图像以




图 10 湖北十堰市飞行场景

直方图均衡、加乘性噪声、加加性噪声、边缘增强等方法进行数据增强。通过正负样本对的组合,生成 24 000 张训练图像和 2 400 张验证图像。

测试集由与训练集数据隔离的预设航迹上的实测 DDM 图像数据集构成,如图中航迹 F1-F2、G1-G2、K1-K2 等。网格点的划分采用离线划分的方式,如图 11 所示,即假设飞行器出发和到达的时间地点是确定的,那么大致飞行方向以及飞行速度可以假设处于一个较小且可以忽略的置信区间,离线在已有轨迹的 9 km 范围内,建立 100 个坐标点当作测试基准点,以 100 m 为间隔上下左右划分网格坐标点,并依照预定的速度状态生成参考基准图像。




图 11 离线网格划分示意图

3.2 模型训练

训练参数设置如下:批大小为 32,训练总轮次为 120,模型梯度优化算法使用 Adam,学习率为 0.000 35,权重衰减为 0.000 1,中心点的更新独立于模型更新,梯度优化算法使用随机梯度下降,学习率为 0.5。

因三元组损失函数增加了模型的复杂度,同时引入 ℓ_1 范数正则化对网络进行模型约束以缓解模型过拟合现象。该方法通过向损失函数中添加 ℓ_1 范数,从而产生稀疏权重矩阵,即产生一个稀疏模型,使得学习得到的特征满足稀疏化,便于进行特征的选择,故 ℓ_1 正则化可以看作损失函数的惩罚项。 ℓ_1 正则化是指权重向量 w 中各个元素的绝对值之和,通常表示为 $\|w\|_1$ 。加入 ℓ_1 正则化的损失函数可表示为

$$L = L(w) + \lambda \sum_{i=1}^n |w_i| \quad (17)$$

式中, $L(w)$ 为模型原始损失函数, λ 为正则化系数,

用于控制正则化的强度,实验中设置 $\lambda=0.000\ 3$ 。最终模型在训练过程中的损失函数曲线如图12所示,可以看出,在第40个轮次左右神经网络对训练集的损失均已达到较稳定数值。




图12 损失曲线

3.3 性能分析

为了验证模型的有效性,选取湖北十堰市飞行场景中G1-G2航段对模型进行测试。首先,将本实验所用基于3种损失函数的DDM-MPN网络与图像匹配任务常用基于对比损失的双输入孪生网络进行对比测试,测试结果如表1所示。3个衡量性能的指标分别为水平面平均定位误差、垂直航向平均定位误差及三维总体平均定位误差。可以看出,传统基于对比损失的孪生网络所得定位误差较大,无法满足水平面误差小于50 m的要求,而本实验所提匹配算法有更高的定位精度和更稳定的匹配性能。

表1 不同方法对比

网络	单点匹配定位			多点加权匹配定位		
	RMSE _{HS} /m	RMSE _{VS} /m	RMSE _{AS} /m	RMSE _{HS} /m	RMSE _{VS} /m	RMSE _{AS} /m
Siamese Network	2 639.544	178.085	2 658.816	2 347.284	88.142	2 355.248
DDM-MPN	42.920	65.756	90.444	35.665	57.764	72.014

为了验证模型在不同飞行场景下的鲁棒性,在湖北十堰市飞行场景中选取F1-F2、G1-G2及K1-K2航段对模型进行测试,测试结果如表2所示。从表中可以看出,不同航迹下利用多点加权匹配

定位所得定位误差基本稳定在100 m及以下,匹配成功率均在80%及以上,即训练完成的DDM-MPN网络具备一定的飞行场景泛化能力。

表2 不同飞行场景对比

航段	单点匹配定位				多点加权匹配定位			
	RMSE _{HS} /m	RMSE _{VS} /m	RMSE _{AS} /m	ACC/%	RMSE _{HS} /m	RMSE _{VS} /m	RMSE _{AS} /m	ACC/%
F1-F2	38.769	95.563	114.949	77	33.271	93.106	103.573	87
G1-G2	42.920	65.756	90.444	73	35.665	57.764	72.014	80
K1-K2	34.092	70.311	86.502	79	44.990	70.876	94.360	85

本实验共试验了3种网络骨干模型,其中包括计算机视觉任务常用的网络ResNet18、VGG16及本实验所用网络DDM-MPN。3个网络模型的定位表现如表3所示。从表中可以看出,VGG16和

DDM-MPN的定位表现较为良好,其中,DDM-MPN的单点匹配和多点加权匹配的水平面平均定位误差、垂直航向平均定位误差及三维总体平均定位误差均较低。

表3 不同模型定位误差对比

网络名称	单点匹配定位				多点加权匹配定位			
	RMSE _{HS} /m	RMSE _{VS} /m	RMSE _{AS} /m	ACC/%	RMSE _{HS} /m	RMSE _{VS} /m	RMSE _{AS} /m	ACC/%
ResNet18	52.872	73.944	103.958	61	97.671	70.259	139.572	64
VGG16	37.931	112.550	131.184	78	37.396	91.879	104.216	86
DDM-MPN	42.920	65.756	90.444	73	35.665	57.764	72.014	80

3种网络的模型复杂度对比如表4所示,其中,Flops表征浮点运算数,可以理解为计算量,用来衡


量模型的复杂度,Params表征模型参数量。可以看出,本文所用网络DDM-MPN的模型复杂度中

等,模型参数量最少,且训练所用时间最短。


表 4 模型复杂度和参数量对比

网络名称	Flops/次	Params/个	训练时间
ResNet18	309.618 2G	2.907 3M	1 051 min49.059 5 s
VGG16	11 442.885 3G	4.824 1M	662 min10.529 2 s
DDM-MPN	1 444.646 7G	1.997 8M	310 min21.946 4 s

DDM-MPN 匹配定位误差可视化如图 13 所示。当取相似度最高的网格点坐标作为最终定位坐标时,测试结果如图 13(a)所示,称为单点匹配。当取相似度前三的网格点坐标平均作为最终定位坐标时,测试结果如图 13(b)所示,称为多点加权匹配。其中,虚线代表水平面误差,即最终定位坐标的 x 轴、 y 轴坐标与基准点 x 轴、 y 轴坐标之间的欧式距离,点线代表垂直航向误差,即最终定位坐标的 z 轴与基准点的 z 轴坐标的距离绝对值,实线代表三维总体定位误差,最终定位坐标与基准点的三维坐标之间的欧氏距离。



(a) 单点匹配定位



(b) 多点加权匹配定位

图 13 DDM-MPN 匹配定位误差可视化

由图中可以看出,基于多点加权匹配的定位结果明显好于基于单点匹配的定位结果,且水平面平均定位误差在 30 m 左右,垂直航向平均定位误差在 50 m 左右,总体平均定位误差在 70 m 左右,对于常见的大型飞行平台,此定位精度在 GPS 拒止情况下的可用性较高。

同时,本实验共试验了 4 种损失函数,其中包括三元组损失与交叉熵损失(记为损失 A)、中心损失与交叉熵损失(记为损失 B)、三元组损失与中心损失(记为损失 C)、三元组损失中心损失与交叉熵损失三者协同作用(记为损失 D)。分别应用这 4 种损失函数时,模型的定位性能对比如表 5 所示。可以看出,采用三元组损失中心损失和交叉熵损失协同优化的方式时,单点匹配定位及多点加权匹配定位的定位误差均最小,且匹配成功率均较高。

表 5 不同损失函数定位误差对比

损失函数	单点匹配定位				多点加权匹配定位			
	RMSE _{HS} /m	RMSE _{VS} /m	RMSE _{AS} /m	ACC/%	RMSE _{HS} /m	RMSE _{VS} /m	RMSE _{AS} /m	ACC/%
损失 A	104.018	119.922	193.932	62	90.614	66.477	130.676	69
损失 B	4 856.279	173.565	4 861.567	0	2 520.656	40.755	2 520.656	1
损失 C	46.794	79.878	105.761	64	39.642	64.144	79.959	81
损失 D	42.920	65.756	90.444	73	35.665	57.764	72.014	80

最后,实验对设定阈值 margin 的选取进行了对比测试,测试性能如表 6 所示。实验表明,选取 margin=0.8 时,模型的定位精度可以保持在较高水平,且定位误差可以保持在较低范围内。

4 结束语

本文针对相邻地形 DDM 相似度高,利用神经

网络对其进行匹配时成功率低的问题,搭建了适用于雷达高度表延时多普勒的匹配定位网络 DDM-MPN,该网络选取三元组损失、中心损失和交叉熵损失作为目标损失函数,通过对实时 DDM 图像和基准 DDM 图像进行相似度度量,最终实现了对飞行器的实时坐标定位。实验结果表明,该网络的定位精度和匹配成功率相较传统基于对比损失的

表6 不同阈值选取的对比

margin	单点匹配定位				多点加权匹配定位			
	mean_HS/m	mean_VS/m	mean_AS/m	匹配成功率/%	mean_HS/m	mean_VS/m	mean_AS/m	匹配成功率/%
0.2	47.496	94.753	118.506	68	49.634	53.526	82.803	79
0.5	44.807	95.653	118.547	66	38.599	57.995	74.337	79
0.8	42.920	65.756	90.444	73	35.665	57.764	72.014	80
1.0	44.408	97.494	119.569	69	42.898	51.713	74.103	83

孪生网络有较为明显的提升,且训练时间相较深层卷积神经网络较短。

参考文献:

[1] 牟金明. 异源图像的深度学习匹配方法研究[D]. 西安:西安电子科技大学,2022.

[2] 王茂琴. 基于图像匹配的无人机定位技术[D]. 西安:西北大学,2022.

[3] MA Jiayi, JIANG Xingyu, FAN Aoxiang, et al. Image Matching from Handcrafted to Deep Features: A Survey [J]. International Journal of Computer Vision, 2020, 129 (1):23-29.

[4] 徐梦莹,刘文波,郑祥爱,等. 基于深度学习的图像特征匹配方法[J]. 传感器与微系统, 2022, 41(7):61-64.

[5] 刘海桥,刘萌,龚子超,等. 基于深度学习的图像匹配方法综述[J]. 航空学报, 2024, 45(3):82-95.

[6] 贺迅,方敏,郭龙飞,等. 基于深度学习的图像匹配方法:中国,CN113111937A[P]. 2021-07-13.

[7] 胡玉珍. 基于深度学习的航拍图像匹配方法研究[D]. 吉林:吉林大学, 2023.

[8] 刘瑞. 基于深度学习的飞行器图像自主导航算法研究[D]. 南京:南京航空航天大学, 2023.

[9] 杨济瑞,张晓燕,罗攀. 基于图像匹配的特征点检测方法综述[J]. 电子测试, 2021(6):53-54.

[10] 廖明哲. 基于深度学习的遥感图像匹配方法研究[D]. 武汉:武汉科技大学, 2021.

[11] 张源峰. 基于图像特征与灰度值的快速匹配算法研究[D]. 兰州:兰州理工大学, 2018.

[12] LOWE D G. Distinctive Image Features from Scale-Invariant Keypoints [J]. International Journal of Computer Vision, 2004, 60(2):91-110.

[13] 睦海刚,刘畅,干哲,等. 多模态遥感图像匹配方法综述[J]. 测绘学报, 2022, 51(9):1848-1861.

[14] 于秋则,周珊,雷震,等. 基于非线性SIFT框架SAR图像匹配[J]. 雷达科学与技术, 2019, 17(3):237-245.

[15] 贾迪,朱宁丹,杨宁华,等. 图像匹配方法研究综述[J].

中国图象图形学报, 2019, 24(5):677-699.

[16] YI K M, TRULLS E, LEPETIT V, et al. LIFT: Learned Invariant Feature Transform [C]// European Conference on Computer Vision, Amsterdam, Netherlands: [s. n.], 2016:457-483.

[17] CHEN Xinlei, HE Kaiming. Exploring Simple Siamese Representation Learning [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, TN, USA:IEEE, 2021:15750-15758.

[18] 杨双宝,翟振和,许可,等. 合成孔径雷达高度计数据处理方法[J]. 遥感技术与应用, 2017, 32(6):1083-1092.

[19] 刘少强,姜军. 现代机载火控雷达功能模式[J]. 移动信息, 2015(2):24.

[20] 杨磊,周弘昊,黄博,等. 机载合成孔径雷达高度计高程参数贝叶斯估计[J]. 电子与信息学报, 2023, 45(4): 1254-1264.

[21] SCHROFF F, KALENICHENKO D, PHILBIN J. Face-Net: A Unified Embedding for Face Recognition and Clustering [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA, USA: IEEE, 2015:815-823.

[22] WEN Yandong, ZHANG Kaipeng, LI Zhifeng, et al. A Discriminative Feature Learning Approach for Deep Face Recognition [J]. European Conference on Computer Vision, Amsterdam, Netherlands: [s. n.], 2016:499-515.

作者简介:

刘丛女,硕士研究生,主要研究方向为合成孔径雷达高度表深度学习地形匹配定位。

鲁彦希男,中级,主要研究方向为雷达探测技术。

刘高正男,中级,主要研究方向为雷达探测技术。

谭龙龙男,中级,主要研究方向为雷达探测技术。

李芳女,中级,主要研究方向为雷达探测技术。

杨磊男,教授、硕士生导师,主要研究方向为高分辨SAR成像及机器学习理论应用。