遥感图像配准中的群智汇聚方法

武越^{1,2†}, 白壮飞^{1,2†}, 公茂果^{3*}, 曲博艺婷¹, 李豪³, 张明阳³, 马文萍⁴, 苗启广^{1,2}

1. 西安电子科技大学计算机科学与技术学院, 西安 710071;
2. 西安电子科技大学西安市大数据与视觉智能重点实验室, 西安 710071;
3. 西安电子科技大学工程学院, 西安 710071;
4. 西安电子科技大学人工智能学院, 西安 710071

† 同等贡献

* E-mail: gong@ieee.org

收稿日期: 2021-05-08; 接受日期: 2021-06-21; 网络版发表日期: 2022-04-07

上海航天科技创新基金(编号: SAST2019-090)和国家自然科学基金(批准号: 62036006)资助项目

摘要 遥感图像配准是遥感图像处理的一个重要的环节, 在智能化遥感信息处理领域具有重要的研究意义和应用价值. 本文主要对群智能在遥感图像配准中的应用进行了综述, 并对进化算法和深度学习在遥感图像中的应用进行了介绍. 首先介绍了遥感图像配准中常用的原理和优点. 然后, 对群智能算法在遥感图像配准中的应用进行了详细的介绍和总结, 紧接着对进化算法在遥感图像配准中的应用进行详细介绍, 其次对深度学习在遥感图像配准中的应用进行归纳, 并且就遥感图像配准目前存在的难点以及深度学习在解决这些难点时所存在的优势进行了详细的讨论. 最后, 针对遥感图像配准中存在的 key 问题进行了讨论与展望.

关键词 群智能, 进化算法, 深度学习, 遥感, 图像配准

1 引言

图像配准是指将相同区域的由不同传感器、不同视角、不同时间以及不同拍摄条件下获取的两幅或者两幅以上的图像进行匹配的过程, 其目的是将待配准图像与参考图像对齐, 从而对图像进行进一步处理^[1~21]. 随着人类对地球观测技术的不断进步, 我们可以获得的遥感图像的数量和质量都有着巨大的飞跃^[3], 遥感已广泛应用于农业^[5]、林业^[5]、地质矿产^[7]、海洋研究^[8]、环境监测^[9]等领域, 且应用领域仍在不断扩展. 遥感图像配准在遥感图像处理中有着重要应用, 是

计算机视觉在遥感图像处理领域的基础性问题. 在遥感领域的实际应用中, 遥感图像配准是遥感图像融合^[9,11]、遥感图像变化检测^[11,13]、遥感图像目标检测^[13,15]、遥感图像拼接^[15,17]、遥感图像分割^[17,19]、遥感图像分类^[19,21]等遥感图像处理任务中不可或缺的一步. 遥感图像配准主要分为5步^[1], 包括图像预处理、特征选择、特征匹配、确定变换函数和重采样.

图像配准技术起源于20世纪70年代, 美国军方在研究导弹的末端制导技术时提出了图像配准技术^[21], 并且由于使用图像配准技术可以有效地提高导弹的命中率, 因此在资金和人才方面得到美国军方的大力支持.

引用格式: 武越, 白壮飞, 公茂果, 等. 遥感图像配准中的群智汇聚方法. 中国科学: 技术科学, 2023, 53: 147–166

Wu Y, Bai Z F, Gong M G, et al. Application of swarm intelligence and a bioinspired computing algorithm in remote sensing image registration (in Chinese). Sci Sin Tech, 2023, 53: 147–166, doi: [10.1360/SST-2021-0193](https://doi.org/10.1360/SST-2021-0193)

持. 与其他技术的发展模式相同, 当军事应用已经成熟之后开始逐渐向民用技术领域下沉, 80年代开始越来越多的图像领域的研究者开始关注图像配准技术^[22]. 90年代初Brown^[23]发表了一篇图像配准的综述, 详细介绍了图像配准的三大应用领域, 即遥感图像配准、医学图像配准、计算机视觉与模式识别. Zitova和Flusser^[1]在21世纪初发表了一篇图像配准的综述, 对图像配准方法以及应用进行详细总结, 为图像配准之后的大发展奠定了基础. 目前图像配准方法主要分为三类: 基于灰度梯度的图像配准、基于特征的图像配准、基于变换域的图像配准^[24]. 国外对图像配准的研究起步较早, 并且针对图像配准在遥感领域的应用做了大量实验, 提出了很多适用于遥感领域的技术, 例如Hausdroff距离^[25]、互信息^[26]、多分辨小波变换分析^[27]等.

国内对于图像配准技术的研究起步较晚, 20世纪90年代初才开始涉足图像配准领域, 但是经过无数科研人员的努力也取得了迅速的发展. Su等人^[28]在2010年发表了一篇关于遥感图像配准的综述, 对遥感图像配准领域的新方法以及新思想进行总结. 赵夫群^[29]在2016年发表了一篇关于图像配准的综述, 从图像配准的具体步骤以及应用方向对图像配准进行总结分析. 近些年来随着国家对遥感领域的重视, 遥感图像配准得到了长足的发展. 国内的科研人员通过大量的研究实验, 对传统的配准方法进行改进并且根据实际的需求提出了许多新颖的遥感图像配准方法.

与自然图像的成像方式相比, 遥感图像一般都是由上到下的成像方式, 包含的范围更大, 所包含的信息更加丰富. 由于遥感图像的特征更为复杂, 遥感图像配准往往具有更大的难度和挑战性^[30]. 传统的图像配准方法难以满足遥感图像配准的精度和效率的要求, 主要是以下几点原因.

(1) 传统方法的全局优化能力较差从而导致配准结果易陷入局部最优^[31]. 遥感图像配准问题通常转化为对目标函数的优化问题, 因此所使用的优化器的性能决定了最终图像配准的结果, 传统优化方法如梯度下降法本质上仍然是一种局部搜索算法, 易陷入局部最优, 难以获得遥感图像配准的全局最优解.

(2) 传统方法的鲁棒性较差. 传统方法过于依赖先验信息, 算法缺乏自学习的能力. 在实际应用中, 如果遥感图像的数据分布满足算法的假设条件, 则能够取

得令人满意的配准结果, 但是如果遥感图像的数据分布不满足预设条件的话, 最终的配准结果都不尽人意.

从本质上来说, 遥感图像配准的核心问题就是在变换空间中找到某种最优的变换方式, 使得待配准图像经过这样的变化之后能够在某种意义上与参考图像匹配. 从数学定义上来说, 图像就是用一个二维矩阵表示, $I_1(x, y)$ 和 $I_2(x, y)$ 分别表示待配准图像和参考图像在点 (x, y) 处的像素值, 因此 I_1 和 I_2 的配准关系可以表示为

$$I_2(x, y) = g(I_1(f(x, y))),$$

其中, f 代表集合变换函数, g 表示灰度(或其他度量值)变换函数, 在实际应用中, 灰度的变化可以使用传感器参数进行校正, 因此 g 变换的求解不是必须的, 所以寻找最佳的空间变换关系 f 才是配准的关键. 上式可以简化为

$$I_2(x, y) = I_1(f(x, y)).$$

由此可见, 遥感图像配准问题就是对待配准图像 I_1 做空间变换 f , 得到一幅新图像 I_1 , 使得 I_1 与参考图像 I_2 的相似度达到最高, 此时变换 f 的参数就是所求的最优配准变换参数. 在现有的图像配准框架和模型下, 在搜索空间中寻找最优的变换参数可以直接建模为一个最优化问题.

目前人工智能领域最常见的方法主要包括以下几种: 群智能算法、进化算法、神经网络和模糊系统^[31]. 模糊系统是一种将输入、输出和状态变量定义在模糊集上的系统, 是确定性系统的一种推广, 但由于模糊系统的设定, 其并不适合应用到遥感图像配准任务中. 本文主要从群智能算法、进化算法和深度学习三部分来介绍生物启发计算方法在遥感图像配准中的应用.

群智能算法最早是人类受到鸟类和蜜蜂的启发所提出的一类算法^[32], 人类通过对自然界的观察, 发现当社会性的群居动物以一个统一的动态系统集体工作时, 解决问题和做决策时的表现会超越大多数单独成员. 群智能算法主要用于解决分布式问题, 群智能中的“群”是指一组互相之间能够直接通信或者间接通信的主体, 这些主体可以通过合作的方式进行分布式问题的求解. 例如蚂蚁觅食和蜜蜂采蜜等社会性行为, 都需要依靠群体的力量, 这种利用群体解决问题的能力要优于彼此分离的个体. 目前, 群智能已经被广泛

地应用到多目标优化^[33,34]、信号处理^[35]、机器人控制^[36]等领域. 受到群智能的启发, 陆续有大量的基于群智能的性能优异的优化算法被提出.

进化算法是模拟自然环境中生物优胜劣汰的进化过程而衍生出的一种启发式的全局优化概率搜索算法^[37]. 进化算法是一种应用广泛、高效的优化搜索算法. 目前有大量的基于进化算法的遥感图像配准方法被提出, 并且都可以取得优异的性能, 进一步证实了将进化算法应用于遥感图像配准是可行的. 在自然图像配准^[38~42]和医学图像配准^[43~47]领域中已经诞生了许多新颖的基于进化算法的方法. 尽管遥感图像的成像方式与自然图像和医学图像不尽相同, 但是实践证明进化算法在遥感图像配准中亦可取得令人满意的性能.

深度神经网络模拟动物视觉皮层组织中神经元之间的连接模式, 是多层前馈人工神经网络的一种深度学习结构^[48]. 深度学习因其强大的学习能力而被广泛地应用到各类计算机视觉任务中^[49], 深度学习已经在图像配准^[50]、目标检测^[51,52]、图像分类^[53]、语义分割^[54,55]以及图像融合^[9]等常见的视觉任务中取得了令人瞩目的成果, 与此同时有许多性能卓越的深度神经网络模型被提出, 例如ResNet^[56], VGGNet^[57]以及GoogleNet^[58]等. 与自然图像相比, 遥感图像的获取方式多种多样, 图像内容难以理解, 特征不明显. 人工设计特征的方法在遥感图像中的应用范围较窄^[59]. 在传统的方法中, 特征提取和特征匹配之间没有信息反馈. 卷积神经网络强大的特征提取和表达能力可以克服低维特征的不稳定性, 提高配准的可靠性. 深度学习的引入进一步提高了遥感图像配准的精度和鲁棒性^[60].

群智能算法和其他生物启发计算方法具有智能^[61]、并行^[62]、鲁棒^[63]的特点, 不依赖于问题本身的特性. 基于生物启发计算方法的算法基本上是以群体协作的方式实现优化求解, 非常适合完成大规模并行处理任务. 除此之外, 基于生物启发计算方法的算法具有良好的容错性, 对初始条件不敏感, 可在不同的条件下找到最优解.

本文主要讨论群智能和其他生物启发计算方法在遥感图像配准中的应用, 分别从群智能算法^[64]、进化算法^[65]和深度学习^[66,67]三个方面进行讨论, 希望能够为更多的研究者和从业者提供一份群智能和其他生物

启发计算方法在遥感图像配准领域应用的介绍.

2 遥感图像配准中的常用方法

2.1 群智能算法

群智能算法^[68~70]是一种代表性的生物启发算法, 也是一种概率搜索算法, 但是与进化计算相比, 群智能算法的信息共享机制不同. 在进化计算中, 利用染色体实现互相共享信息, 所以整个种群比较均匀地向最优区域移动. 在群智能算法中, 只有当前最优粒子把信息传递给其他粒子, 这是单向的信息流动, 整个搜索过程都在跟随当前最优解. 因此与进化算法相比, 在大多数情况下, 群智能算法可能更快地收敛到最优解. 传统的优化算法一般是基于梯度信息的, 例如梯度下降法、牛顿法等, 这些算法要求函数必须是连续可导的, 并且多用于凸优化问题的求解. 综上所述, 群智能算法的优点如下.

(1) 群体中能够互相影响的个体是分布的, 能够很好地适应当前网络状态下的工作状态.

(2) 能够摆脱中心的控制, 这样的方法更加鲁棒, 不会因为某一个或者某几个个体的因素而导致整个优化过程的失败.

(3) 算法中个体的增加导致的个体之间的通信开销增加比较小, 每个个体的构成十分简单, 因此每个个体的执行时间比较短, 实现也比较简单.

目前遥感图像配准中得到广泛使用的粒子群算法主要包括以下两种: ① 粒子群算法^[71~76](particle swarm optimization, PSO); ② 蚁群算法^[77](ant colony optimization, ACO).

粒子群算法是Kennedy和Eberhart^[78]于1995年提出的. 粒子群优化算法是一种模拟鸟类觅食活动的群优化算法^[78~80]. 粒子群算法在对动物集群活动的行为观察基础上, 利用群体中个体对信息的共享使整个群体的运动在问题求解空间中产生无序到有序的演化过程, 从而获得最优解. 粒子群算法从随机解出发, 通过迭代寻找最优解, 与遗传算法类似, 它也是通过适应度来评价解的优劣, 但比遗传算法规则更为简单, 没有遗传算法的“交叉”和“变异”操作, 而是通过追随当前搜索到的最优解来寻找全局最优. 粒子群算法中粒子只是通过内部速度进行更新, 与进化算法相比, 具有参数更少、实现起来更容易的优点. 经典的粒子群的更

新规则如下:

$$V_i(t+1) = \omega V_i(t) + c_1 r_1 (Pbest_i - X_i(t)) + c_2 r_2 (Gbest_i - X_i(t)), \quad (1)$$

$$X_i(t+1) = X_i(t) + V_i(t), \quad (2)$$

其中, $Pbest_i$ 表示第*i*个粒子迄今为止搜索到的最优解, $Gbest_i$ 表示整个粒子群目前搜索到的最优解, $X_i(t)$ 和 $V_i(t)$ 表示第*i*个粒子在第*t*次迭代时的位置和速度, c_1 和 c_2 表示两个学习率权重, r_1 和 r_2 表示两个均匀分布在0到1之间的随机参数, ω 为惯性权重.

蚁群算法最早是由意大利研究人员Dorigo等人^[81]在20世纪90年代提出的, 其灵感来自于蚂蚁的觅食行为, 研究人员发现蚂蚁会在其经过的路径上释放一种可以称为“信息素”的物质, 蚁群内的蚂蚁对“信息素”具有感知能力, 它们会沿着“信息素”浓度较高路径行走, 而每只路过的蚂蚁都会在路上留下“信息素”, 这就形成一种类似正反馈的机制, 这样经过一段时间后, 整个蚁群就会沿着最短路径到达食物源. 蚁群算法具有分布计算、信息正反馈和启发式搜索的特征, 本质上是一种启发式全局优化算法.

2.2 进化算法

进化算法是生物启发计算方法中涉及组合优化问题的一个子领域, 它是一类自适应的全局优化算法, 通过模拟生物进化过程中的自然选择机制和遗传信息的传递规律, 利用程序迭代模拟这一过程, 把要解决的问题看作环境, 在一些可能的解组成的种群中, 通过自然演化寻求最优解^[82].

进化算法主要由种群初始化、适应度评价、选择、交叉、变异等基本操作组成, 进化算法的基本流

程框架如图1所示. 与传统的基于梯度信息的优化方法相比, 进化算法具有以下优点.

(1) 进化算法不需要通过严格定义数学模型来解决问题^[83]. 将实际应用需求抽象为优化问题时, 进化算法可以在不依赖其他信息的情况下, 充分利用相应的适应度函数找到近似最优解以满足实际应用需求.

(2) 在优化过程中, 传统的优化策略是从一个初始值开始, 而后逐步迭代寻找最优解, 而进化算法是从包含多个点的种群出发, 通过种群的进化迭代寻找最优或次优解^[84], 进化算法能够不受问题性质的限制, 有效地求解不连续、不可导或者非凸的复杂优化问题.

(3) 进化算法的鲁棒性和嵌入式并行性使得算法在寻找全局最优解时非常有效, 不易陷入局部最优解的困境, 是一种具有广泛适用性的全局优化算法, 实现概率意义上的全局优化^[85].

通过建立合理的模型, 可以将遥感图像配准任务视为一个优化问题, 而进化算法可以有效地解决优化问题, 因此进化算法在遥感图像配准任务中有着巨大的应用潜力^[63]. 遥感图像配准中目前得到广泛使用的进化计算方法主要包括以下两种: ① 遗传算法^[86~91] (genetic algorithm, GA); ② 差分进化算法^[92~94] (differential evolution, DE).

遗传算法最初是由密歇根大学的Holland^[95]提出的, 它是一个模拟达尔文生物学进化的自然选择和遗传机制的计算模型, 并且是一种通过模拟自然进化来寻找最优解的方法^[96]. 遗传算法具有高效、并行、可实现全局搜索的优点, 能在搜索过程中自动获取和积累有关搜索空间的知识, 并自适应地控制搜索过程以求得最优解.

差分进化算法是由Storn和Price^[97]于1995年提出

图1 (网络版彩图)进化算法的基本流程框架

Figure 1 (Color online) The basic process framework of evolutionary algorithm.

的,与其他进化算法类似,差分进化算法也是一种模拟生物进化的随机模型,通过反复迭代,使得那些适应环境的优秀个体被保存下来.差分进化算法保留了基于种群的全局搜索策略,采用实数编码、基于差分的简单变异操作和一对一的竞争生存策略,降低了遗传操作的复杂性.同时,差分进化算法特有的记忆能力使其可以动态跟踪当前的搜索情况,以调整其搜索策略,具有较强的全局收敛能力和鲁棒性,且不需要借助问题的特征信息,适于求解一些利用常规的数学规划方法所无法求解的复杂环境中的优化问题^[98~100].

2.3 深度学习

深度学习是机器学习的一个重要分支,其概念源于人工神经网络的研究,含有多个隐藏层的多层感知机就是一种简单的深度学习结构.深度学习通过组合低层特征形成更加抽象的高层表示属性类别或特征,以达到发掘数据抽象特征表示的目的.深度学习的动机是建立模拟人脑进行分析学习的神经网络,它可以模仿人脑的机制来解释数据.深度学习模型由许多将输入转换为特定输出的网络层组成,输入层和输出层之间的层通常称为“隐藏层”,一般来说,深度超过8层的神经网络才称为深度学习.含有多个隐藏层的多层学习模型是深度学习的架构.深度学习可以通过组合低层特征形成更加抽象的高层表示属性、类别或特征,以发现数据的分布式特征表示.与传统模型相比,深度学习具有以下优点.

(1) 深度学习具有强大的学习能力.传统的机器学习算法学习能力有限,数据量的增加并不能持续增加学到的知识总量,而深度学习可以通过访问更多的数据量来提升性能.

(2) 深度学习覆盖范围广,具有更好的适应性.深度学习的神经网络层数很多,宽度很广,理论上可以映射到任意函数,所以能解决很复杂的问题.

(3) 深度学习由数据驱动,上限更高.深度学习高度依赖数据,数据量越大,它的表现就越好,并且可以通过调参进一步提高它的上限.

卷积神经网络(CNN)在计算机视觉领域掀起了一场新的革命,基于卷积神经网络的算法往往比传统方法性能更好、更加鲁棒.神经网络的层越深,最终提取的特征中包含的信息就越丰富.卷积神经网络适用于处理像素排列整齐的图像数据.具体来说,它主要

由卷积层、池化层和全连接层组成^[101].每次输入图像经过一个卷积层时,它将与一组卷积内核进行卷积,每个内核都会生成一个新的特征图^[102].与传统的多层感知器相比,卷积神经网络通常使用置换不变函数(最大池化、平均池化等)来聚合本地信息^[103,104].

卷积神经网络能够有效将大数据量的图片降维成小数据量,从而解决图像处理所需的数据量太大、成本过高、效率低下的问题.除此之外,卷积神经网络能够有效保留图像特征,并且更加符合图像处理的要求,能够有效提升图像处理的准确性.

2.4 小结

群智能算法、进化算法和深度学习都是目前已经被广泛地应用到遥感图像配准任务中,三者均是以数据为基础,以计算为手段建立功能上的联系,从而进行问题求解,以实现智能的模拟和认识.基于群智能算法、进化算法、深度学习的遥感图像配准均可以实现卓越的配准性能,文章接下来的部分将分别从群智能算法、进化算法和深度学习在遥感图像配准中的应用三个方面进行讨论.

3 群体智能在遥感图像配准中的应用

群体智能算法^[105~107]由于其强大的优化能力被广泛应用于遥感图像配准中.通过总结整理现有的参考文献,粒子群算法和蚁群算法目前已经在遥感图像配准中有重要的应用,本节主要从粒子群算法和蚁群算法在遥感图像配准中的应用进行详细讨论.表1总结了群智能算法在遥感图像配准中的应用^[71~77,108~110].

3.1 粒子群算法的应用

在群体智能算法中,粒子群优化算法具有收敛速度快、算法本身简单、调优参数少等优点,已被广泛应用于遥感图像配准中.

Lu等人^[71]采用了一种由粗到精的配准策略.在粗配准阶段,采用粒子群优化算法搜索最佳刚性参数,以获得全局最优互信息.在精配准阶段,使用Harris检测器对粗配准结果进行精配准.该方法具有很强的自动配准能力,可以快速、稳定地处理遥感图像之间的大位移.Zhang等人^[72]为了避免多传感器遥感图像配准过程中陷入局部极小值的问题,提出将PSO算法与

表 1 群体智能算法在遥感图像配准中的应用

Table 1 Application of swarm intelligence algorithm in remote sensing image registration

序号	文献	方法改进
1	Lu等人 ^[71]	将使用粒子群的粗配准和使用Harris检测器的精配准结合起来, 可以快速处理图像之间的大位移
2	Zhang等人 ^[72]	将PSO算法与Powell方向集算法结合在一起, 有效避免局部优化, 实现更高精度的配准
3	An等人 ^[73]	创新性地改进的粒子群算法应用到遥感图像配准, 控制计算量, 确保种群多样性
4	杨绪超等人 ^[108]	改进蚂蚁在每层节点间的转移准则以及全局信息素的更新策略, 不需要人工干预, 对参数初始化不敏感
5	Gharbia等人 ^[74]	互信息与薄板样条插值法相结合, 对于大规模变化, 旋转和强度变化具有更好的性能
6	Yavari等人 ^[75]	使用有理函数模型和粒子群算法进行遥感图像配准, 提高配准准确性, 减少系统错误和所需的控制信息量
7	Wu等人 ^[76]	相对于RANSAC, 直接对模型转换参数进行采样, 而不是随机选择进行模型匹配
8	Wu等人 ^[77]	结合蚁群算法和局部搜索算法进行遥感图像配准, 避免陷入局部优化并且减少计算量
9	Chen等人 ^[109]	通过量子行为粒子群优化(SC-ARID-QPSO)对光学遥感图像进行空间一致性和平均区域信息散度最小化
10	Li等人 ^[110]	粒子群算法用于多模态图像配准, 使用多种优化模式进行全局优化

Powell方向集算法相结合. PSO用于计算遵循Powell方向集方法(PDSM)的良好初始预测. 同时, PSO算法和Powell算法的结合有效地避免了目标函数梯度的计算, 降低了计算复杂度. An等人^[73]提出了一种基于互信息的改进粒子群算法进行配准. 该算法放弃了固定种群规模, 并使用自适应可变种群规模来优化目标函数. 因此, 该算法不仅可以控制计算量, 而且可以保证种群的多样性, 提高粒子的搜索能力. 但是与传统的基于互信息的穷举法相比, 准确性大大降低. Gharbia等人^[74]提出了互信息和薄板样条插值的方法进行遥感图像配准. 在薄板样条插值提供对应地标的相对位置的几何表示之后, 粒子群优化算法主要用于改善地标之间的对应关系, 实现最大的互信息系数. 与以前的方法相比, 该方法在大范围变化、旋转和强度变化方面具有更好的性能. Yavari等人^[75]提出了一种基于线性特征的有理函数优化模型用于高分辨率卫星图像配准. 有理函数模型具有通用性和与传感器无关的特性, 因此适合于配准, 但是有理函数中的过参数化和有理函数中项的数量和顺序不正确的结合是需要解决的关键问题. 粒子群优化算法具有出色的全局搜索能力, 可用于查找无关项目的最佳组合. Wu等人^[76]提出了一种粒子群样本优化算法. 该算法的优点是放弃传统的随机样本的匹配方法, 而直接使用粒子群算法对转换模型进行采样. 该算法在处理低精度和获取更多匹配点方面具有非凡的性能. Chen等人^[109]提出了一种利用空间一致性和平均区域信息散度的配准方法, 即通过

量子行为粒子群优化(SC-ARID-QPSO)对光学遥感图像进行空间一致性和平均区域信息散度最小化. Li等人^[110]利用粒子群算法的全局优化能力, 将其应用到多模态图像配准中, 并提出了多种粒子群优化模式.

粒子群优化的特点是种群个体可以彼此交换信息. 粒子群算法的优点是收敛速度快, 但容易陷入局部搜索而失去粒子群的多样性, 导致了粒子群算法的局部搜索能力较弱. 因此, 利用粒子群算法提高种群多样性, 提高粒子群算法的搜索能力, 结合粒子群算法与局部搜索策略, 提高其局部搜索能力, 仍然是一个值得深入研究的方向.

3.2 蚁群算法的应用

蚁群算法已被广泛应用于自然图像配准^[111~113]和其他计算机视觉任务^[114~116], 它能够有效地解决复杂的多峰问题, 避免陷入局部最优, 但是在遥感图像配准中, 目前仍处于探索阶段.

Wu等人^[77]提出了一种用于多传感器遥感图像配准的多峰连续蚁群优化算法. 蚁群算法的引入主要是避免陷入局部最优, 提高全局搜索能力. 同时, 为了降低计算复杂度, 引入局部搜索以显著提高搜索效率. 与传统方法相比, 该方法更加有效、鲁棒. 杨绪超等人^[108]提出了一种用于多光谱遥感图像配准的改进蚁群算法, 改进蚂蚁在每层节点间的转移准则以及全局信息素的更新策略, 这种改进的蚁群算法不需要人工干预, 对参数的初始化值不敏感, 能够实现较高精度

的配准。

与其他启发式算法相比, 蚁群算法在求解性能上具有很强的鲁棒性, 对基础的蚁群算法模型简单修改之后就可以应用到各种各样的组合优化问题中, 并且蚁群算法具有较强的搜索全局最优解的能力。除此之外, 蚁群算法易与多种启发式优化算法结合, 以达到改善算法性能的目的。因此, 将蚁群算法与其他启发式的优化算法结合应用到遥感图像配准任务中是一个非常好的思路。

3.3 其他群智能算法介绍

除了粒子群算法和蚁群算法之外, 近些年来有许多群智能方法被提出, 但是这些算法并未在遥感图像配准中得到广泛使用, 与之相反的是这些算法在医学图像配准领域得到广泛应用, 以下对这些算法进行简要介绍。

(1) 人工蜂群算法^[117]。该算法是受蜜蜂群体的启发所提出的一种算法, 在蜜蜂群体中, 每一只蜜蜂会根据自己的分工不同参与不同的社会活动, 并实现群中个体的交流和通信, 从而找到最优解。目前人工蜂群算法并未广泛地应用到遥感图像配准中, 但是在医学图像配准领域目前得到了较多的应用。例如Wen等人^[118]将人工蜂群算法应用到医学图像配准中, 并依托计算平台搭建了对应的系统。

(2) 菌群算法^[119]。该算法是一种随机搜索算法, 主要是受到了人类肠道中大肠杆菌觅食行为的启发而衍生出的一种算法。目前菌群算法也被广泛地应用到医学图像配准中, 例如Bermejo等人^[120]将菌群算法应用到基于强度的医学图像配准优化中, 实现了优异的性能。

(3) 人工鱼群算法^[121]。该算法的主要思想是一片水域中鱼群聚集最密集的地方就是该水域中营养最丰富的地方, 根据这个思想模仿鱼群的觅食行为, 从而实现求解全局最优解。目前人工鱼群算法在遥感图像配准中的应用仍然处于探索阶段, 并未得到广泛地应用。但是在医学图像配准领域同样有着重要地应用。例如Zhao等人^[122]将人工鱼群算法应用到多分辨率医学图像配准中, 实现了令人满意的配准性能。

目前, 有许多新颖的群智能算法被提出, 但是在遥感图像配准中的应用仍然较少, 根据其在医学图像配准中的应用, 可以将其思想借鉴到遥感图像配准中。

3.4 小结

目前, 粒子群算法以及蚁群算法由于其优异的性能被广泛地应用于遥感图像配准任务中, 除了这几种常见的进化计算方法之外, 也陆续地有基于其他进化计算方法的遥感图像配准算法被提出, 例如用于遥感图像配准的模拟退火算法^[123]。然而, 由于模拟退火算法的局限性, 近年来在遥感图像配准中对模拟退火算法的应用并不常见。用于医学图像配准任务中的进化计算方法, 如人工免疫系统^[45]、萤火虫算法^[124]、协进化算法^[125]等, 我们目前也在尝试将这些算法应用于遥感图像配准任务中。当然, 还有一些流行的群体智能方法在遥感图像配准中目前还未得到广泛地应用, 例如蝙蝠算法^[126]、脑风暴优化算法^[127]等。这些方法应用于遥感图像配准也是一个值得研究的方向。

4 进化计算在遥感图像配准中的应用

进化计算的灵感来自生物进化和遗传理论^[98]。通过对大量的相关文献的研究整理, 我们发现目前遗传算法和差分进化算法被广泛地应用到遥感图像配准中。表2总结了进化计算在遥感图像配准中具有代表性的方法^[86-94, 128]。

4.1 遗传算法的应用

目前提出的方法中, 遗传算法的应用^[95, 129]相对更加纯熟, 因此目前遗传算法在遥感影像配准中的应用更为广泛。将遗传算法应用于特征匹配的流程如下: 首先, 使用现有方法对参考图像和待配准图像的信息进行粗略匹配; 其次, 在粗匹配之后对信息进行编码以构造初始种群; 然后, 根据适应度函数值随机选择种群, 并通过交叉和变异种群编码更新种群个体。计算适应度函数并判断是否满足收敛条件。如果满足收敛条件, 则输出最优解, 否则将再次执行交叉和变异操作, 接下来, 估计变换模型, 最后获得配准图像。除此之外, 遗传算法同样可以应用于变化参数估计, 即利用遗传算法求解变换模型中的最优解。

(1) 遗传算法用于特征匹配

Inglada等人^[86]提出了利用遗传算法通过边缘匹配自动进行多传感器遥感图像配准。在提出的最小化测量方法的基础上, 使用遗传算法通过最小化距离找

表 2 进化计算在遥感图像配准中的应用

Table 2 Application of evolutionary computation in remote sensing image registration

序号	文献	方法改进
1	Inglada等人 ^[86]	在粗配准阶段运用遗传算法为精配准寻找最优初始匹配点集, 避免陷入局部最优解
2	Makrogiannis等人 ^[87]	将粗配准与遗传算法相结合, 将精配准与比例光流方法相结合, 既可以避免计算量过高, 又可以实现高精度的配准
3	De Falco等人 ^[128]	使用差分进化算法进行遥感图像配准, 避免优化过程中陷入局部最优
4	De Falco等人 ^[92]	将分布式差分进化算法应用于遥感图像配准, 降低种群中粒子停滞的风险, 同时避免陷入局部最优
5	Hu等人 ^[93]	采用自适应差分进化策略, 结合概率匹配和多分辨率技术进行遥感图像配准
6	Ma等人 ^[94]	正交学习策略应用于遥感图像配准, 使用更少的实验样本寻找因子层面的最佳组合
7	Zhang等人 ^[88]	应用遗传算法将粗配准与网格匹配, 精配准与三角形映射相结合, 减少计算量并避免手工决策引入错误
8	Gou等人 ^[89]	通过Delaunay三角剖分构造图, 并通过遗传算法求解图相似度, 找到最佳匹配点, 可以适用于灰度差异较大的情况
9	Li等人 ^[90]	遗传算法主要校正图像旋转以对图像进行预处理, 获得更多的正确的初始匹配点
10	Yavari等人 ^[91]	使用遗传算法获得分布最好的初始匹配信息的最佳数量和最佳组合, 避免手工操作, 提高准确率

到最佳控制点集. 该方法不需要太高的提取精度就可以实现很高的配准精度, 同时, 遗传算法的使用避免了局部最优解的问题. 为了将航空图像与卫星图像或地图图像进行配准, Zhang等人^[88]提出了一种基于遗传算法的具有位置和相似性约束的图像配准方法. 其中引入遗传算法的主要目的是使两个网格的均方误差最小, 并使网格点的总形变最小. 与过去的类似方法相比, 该方法的主要优点是避免了人工操作和决策过程中的错误. Gou和Ma^[89]提出了一种基于Delaunay三角剖分和遗传算法进行多源遥感图像配准的方法. 遗传算法主要用于求解图相似度的最优解, 从而获得最优的控制点集来求解变换模型. 该方法的一个突出特点是利用遗传算法消除不匹配, 找到对应点的最佳集合, 从而提高配准的准确性. Yavari等人^[91]提出了一种基于遗传算法的最优初始匹配信息分配和选择方法, 以提高配准的准确性. 与过去的方法相比, 该方法在减少由提取过程引起的误差并实现亚像素精度配准方面具有重要意义.

(2) 遗传算法用于变化参数估计

Makrogiannis等人^[87]提出了一种基于随机优化的仿射映射方案, 以解决遥感图像中时间、视点和地形变化引起的失真. 遗传算法用于在粗配准阶段搜索由仿射变换参数定义的搜索空间. 为了实现亚像素级配准并避免遗传算法的高成本计算, 配准方案通过分层光流法来完成. 粗配准和精配准的组合降低了计算复

杂度, 同时确保了配准精度. Li等人^[90]提出了一种基于遗传优化的多角度归一化互相关方法. 该方法可以通过遗传算法确定两幅图像之间相关系数的最大值, 从而检测出目标图像与参考图像之间的角度偏移, 从而完成旋转偏移校正. 这种新添加的预处理操作的优点是可以获得更多的匹配点, 从而提高配准的准确性. 使用遗传算法对配准图像进行预处理, 为我们解决图像配准问题提供了新的思路.

当使用遗传算法解决遥感图像配准问题时, 需要制定染色体的编码规则、适应度函数的选择、遗传算子的设计以及算法参数的确定. 这同样也是使用遗传算法解决实际问题的难点所在. 目前已经提出的基于遗传算法的遥感图像配准方法对未来的研究具有重要的借鉴意义.

4.2 差分进化算法的应用

差分进化算法是一种基于种群差异的启发式随机搜索算法. 该算法主要用于求解切比雪夫多项式^[84,97,130]. 根据现有参考文献, 差分进化算法目前多用于变换模型的参数估计. 基于差分进化算法的遥感图像配准流程如下, 输入参考图像和待配准的图像, 并且在变换参数的搜索空间中随机初始化变换模型的参数, 然后, 根据适应度函数执行选择、变异和交叉操作, 直到满足输出条件为止. 最后, 根据最佳的变换参数, 将待配准的图像与参考图像进行匹配, 以获得最终

的图像配准结果.

De Falco等人^[128,131]提出了一种用于遥感图像配准的差分进化方法, 创新地将差分进化算法应用到遥感影像配准中, 从而有效避免了局部优化问题, 提高了找到最优值的可能性. De Falco等人^[92,132]将分布式差分算法应用于遥感图像配准. 该算法降低了差分进化算法的亚群停滞风险. 分布式差分算法用于求解仿射变换的全局最优参数, 以使互信息最大化. Hu等人^[93]提出了一种基于差分进化算法和自适应策略选择的遥感图像配准算法, 该方法主要解决了用于遥感图像配准的传统差分进化算法计算量大、收敛速度慢的缺点. 与传统的差分进化算法相比, 该算法可以实现亚像素级配准. Ma等人^[94]提出了一种基于正交学习差分进化的遥感图像配准算法. 该方法的重点是, 采用正交学习策略优化差分进化中的交叉过程, 从而使用较少的实验样本找到各个因子水平之间的最佳组合. 与传统的启发式算法相比, 该方法具有更快的收敛速度和更鲁棒的结果.

差分进化算法作为进化算法家族中性能最好的优化算法, 将遥感图像配准问题建模为一个组合优化问题, 利用差分进化算法全局搜索能力强、稳定好、收敛速度快的优点进行全局优化求得最终变换参数. 将差分进化算法应用到遥感图像配准中目前已经成为一个研究热点, 基于差分进化算法的遥感图像配准方法能够在保证解集多样性的前提下, 可以大大提高算法的收敛速度以及结果的鲁棒性.

4.3 其他进化计算方法介绍

除了遗传算法和差分进化算法之外, 还有许多进化算法近些年来广泛地应用到各个领域. 进化算法主要可分为遗传算法^[95]、遗传规划^[133]、进化规划^[134]和进化策略^[135]四个主要的研究方向. 这些方法的算法框架基本一致, 但是在进化的方式上存在较大的差异, 主要体现在选择、交叉、变异以及种群控制上. 其中遗传算法对交叉操作要看重一些, 认为变异操作只是可以作为算法的辅助操作, 而进化规划和进化策略认为交叉操作不是必须的, 一般情况下交叉操作并不优于变异操作, 甚至有时候可以不要交叉操作. 目前, 遗传规划、进化策略以及进化规划在遥感图像配准领域应用并不广泛.

总体来说, 遗传算法、遗传规划、进化规划和进

化策略本质上都是基于达尔文进化理论的生物启发进化算法, 仅仅是算法流程对交叉和变异操作各有侧重. 因此这些方法与遗传算法在遥感图像配准中的应用基本相同, 都可以用于特征匹配和变化参数估计.

4.4 小结

进化计算是生物启发计算方法的一个重要分支, 其主要思想来源于达尔文进化论和遗传定律. 目前进化计算已经被广泛地应用到图像配准领域, 尤其是自然图像配准. 虽然与自然图像相比遥感图像的成像范围更大, 特征更加复杂, 但是遥感图像本质上来讲仍然是一种图像, 因此许多自然图像配准方法可以被借鉴到遥感图像配准任务中. 目前, 基于进化计算的遥感图像配准算法主要还是受到了自然图像配准的启发, 然后再基于遥感图像的特性对算法进行改进, 使其能够更加适用于遥感图像配准任务.

5 深度学习在遥感图像配准中的应用

基于SIFT特征的图像配准方法是图像配准领域的经典之作^[136], 它是基于特征的图像配准方法的代表, 在自然图像处理任务中具有良好的性能, 因为生成的特征描述符具有旋转、缩放和平移不变性. 但是由于遥感图像的成像机制复杂, 其外观取决于辐射特征、对象的几何特征以及传感器的发送或接收装置. 因此, 直接把在自然图像配准中性能卓越的SIFT应用到遥感图像配准任务中可能并不能取得令人满意的性能. 深度神经网络用于遥感图像配准的第一种方式是利用深度神经网络进行特征提取, 它可以通过学习获得更加复杂的图像特征. 除此之外, 深度神经网络还可以用于特征匹配, 众所周知, 在图像配准的几个步骤中, 能够获得正确的匹配对图像配准的精度至关重要. 同时深度神经网络也可以直接用于变化参数的估计, 这可以一定程度上提高算法的鲁棒性. 表3总结了将深度神经网络应用于遥感图像配准任务上的一些优秀的算法^[60,137~146].

5.1 深度学习用于特征提取

由于遥感图像的特性, 自然图像中使用的SIFT, HOG^[147]等手工特征在某些情况下不能满足遥感图像配准任务的需求, 但是深度神经网络可以获得更特

表 3 深度学习在遥感图像配准中的应用

Table 3 Application of deep learning in remote sensing image registration

序号	作者	方法改进
1	Ye等人 ^[60]	整合CNN提取的深度特征和局部特征, 并将获得的特征融合到PSO-SIFT算法中
2	Wang等人 ^[141]	提出了一种端到端配准深度神经网络, 主要包括两个阶段: (1) 学习映射函数; (2) 进行图像配准, 应用迁移学习降低训练成本
3	Quan等人 ^[142]	生成对抗网络用于自动创建更多的训练数据而无需手动标准化数据, 并且使用了双通道深度神经网络作为匹配网络
4	Ma等人 ^[137]	使用卷积神经网络获得图像的空间关系, 然后将考虑空间关系的匹配策略应用于基于局部特征的方法
5	Dong等人 ^[138]	设计DescNet网络模型以提取图像的深度特征, 并通过增加卷积滤波器的步幅大小来代替最大池化操作, 对较大灰度差异的图像更鲁棒
6	Kim等人 ^[143]	提出了一种端到端的深度神经网络, 用于估计航空图像之间的变换矩阵, 进而估计图像之间的旋转和仿射变换参数, 有效降低了参数估计的误差
7	Yang等人 ^[140]	使用预训练的VGG网络层来生成一个特征描述符, 同时保留卷积信息和局部特征
8	Park等人 ^[144]	提出了一种三输入双向架构, 以估计参考图像和目标图像之间的转换矩阵
9	Merkle等人 ^[139]	在孪生架构的基础上, 提出了一个网络来匹配大小不同的多传感器图像, 并使用点积来计算相似度, 适用于多传感器和多分辨率图像
10	Hughes等人 ^[145]	设计了伪孪生卷积网络以匹配SAR和光学遥感图像, 可以准确地预测匹配的图像块
11	Zhang等人 ^[146]	设计了一种基于孪生网络架构的匹配神经网络, 用于匹配SAR和光学遥感图像, 并利用相似度得分去除错误的匹配点

殊、更高维度的特征. 通过学习, 卷积神经网络可以自动获得比统计方法更多的表达特征^[148]. 因此, 许多方法选择将遥感图像直接输入到神经网络, 通过神经网络以学习的方式获得特征描述符, 然后将获得的特征描述符与传统方法结合用于配准任务. 与传统的手工特征相比, 利用深度学习学习到的特征进行配准可以有效提高配准任务的精度.

Ma等人^[137]提出了一种基于深度和局部特征区域的两步配准新方法, 该方法包括基于由深度学习学习到的特征描述符的匹配方法和基于点匹配策略的遥感图像配准方法. 该方法以VGG16模型作为骨干网络来提取图像的深度特征, 为了消除由于最大池化而导致的位置信息丢失, Ma等人采用了位置调整策略, 并使用了基于局部特征的匹配策略来获得最终的匹配点. 该方法不仅对SAR图像配准有很好的效果, 而且可以应用于其他类型的遥感图像. Ye等人^[60]选择VGG16作为深度特征提取器, 他们将获得的深度特征和SIFT特征融合为一个特征向量, 然后将其与PSO-SIFT^[149]算法结合, 与传统的PSO-SIFT算法相比, 该方法可以有效提高配准精度. Dong等人^[138]提出了一种可以有效处理灰度差异较大的图像的网络(DescNet), 与其他网络相比, 该网络可以获得更多匹配的特征点, 可以

解决由于匹配点数量不足而导致估计的变换模型出现偏差甚至误差的问题^[150,151]. 卷积神经网络中的最大池化操作会影响最终输出特征描述符的性能^[152,153], Dong等人通过增加步幅来代替最大池化操作从而消减最大池化对特征描述符性能的影响. Yang等人^[140]使用VGG16作为特征提取器, 在配准的初始阶段, 使用最可靠的特征点快速确定粗匹配, 然后通过逐渐增加特征点的数量来优化配准细节, 并根据几何局部信息约束错误的配准点.

综上所述, 利用深度学习学习得到的特征描述符往往比传统的特征描述符更加鲁棒, 并且能够获得更多正确的匹配用来进行变换参数估计, 在实际的遥感图像配准任务中能够取得更高的配准精度.

5.2 深度学习用于特征匹配

在图像配准任务中, 特征匹配是整个配准流程中至关重要的一环, 特征匹配的准确性直接影响最终的配准结果. 在图像配准任务中, 特征匹配的目的是为了找到图像中具有代表性的部分, 该区域必须具有可重复性、可区别性、本地性. 其中可重复性是指相同的区域可以在不同的图像中被找到, 可区别性是指不同的区域经过变换之后必须具有不同的表达, 本地性

是指所获得的图像的特征仅与一小片图像区域有关. 深度学习由于其强大的性能目前被广泛地应用于遥感图像配准过程中的特征匹配. 图2展示了一种常见的深度学习用于特征匹配的框架.

Wang等人^[141]提出了一种新颖的网络结构来选择匹配点, 他们使用传统的局部特征提取方法来提取特征点, 围绕这些特征构造相应的局部区域, 并使用深度神经网络匹配这些补丁对. 整个网络框架分为两个阶段: 映射函数学习和图像配准. 映射函数学习阶段主要通过使用未配准图像及其仿射变换图像来学习映射函数, 配准阶段使用上述训练过的深度神经网络从待配准图像和参考图像中预测补丁对的匹配标签. 如果标签为1, 则匹配对的中心点将用作图像配准的初始关键点. 使用局部约束和全局约束来弱化匹配误差, 并引入自学习来解决用于训练的遥感图像的小数据问题. Quan等人^[142]使用生成对抗网络自动创建更多的训练数据而无需手动标准化数据, 此方法可以提高匹配的准确性. 使用双通道深度网络作为特征匹配网络, 这两个通道具有相同的结构, 但不共享参数. 这种网络有助于提取更加多样性的特征用于特征匹配, 同时使用卷积神经网络作为特征提取器来保留图像的空间信息.

综上所述, 利用深度神经网络进行特征匹配可以在保证可重复性、可区别性、本地性的前提下找到待配准图像对中更多精确的匹配点, 为后续的变换参数估计奠定坚实的基础. 深度神经网络用于特征匹配不但可以获得更多正确的匹配对, 而且获得的匹配对的数量也比利用传统方法获得的要多, 精度更高并且数量更多的正确匹配对往往能够直接影响配准的精度.

根据目前最新的方法, 利用深度神经网络进行特征匹配要比利用传统方法进行特征匹配具有更加优越的性能.

5.3 深度学习用于变化参数估计

深度神经网络同样可以用于变换参数估计. 变换参数估计指根据待配准图像与参考图像之间的几何畸变的情况, 选择能最佳拟合两幅图像之间变化的几何变换模型, 可以分为全局映射模型和局部映射模型. 其中, 全局映射模型利用所有控制点信息进行全局参数估计; 局部映射模型利用图像局部的特征分别进行局部参数估计. 常见的变换模型包括仿射变换、透视变换、多项式变换等, 其中最常用的是仿射变换和多项式变换. 图3展示了一种深度学习用于变换参数估计的通用框架.

Kim等人^[143]提出了一种端到端变换参数估计网络, 以估计航空影像对之间的旋转和仿射变换参数, 每个参数估计阶段包括: 特征提取、特征匹配、渐进掩蔽和变换估计. 为了准确估计变换参数, 使用了渐进掩蔽法来减少无关特征点的影响. Vakilopoulou等人^[154]提出了一种用于估计高分辨率卫星图像对之间的刚性变换参数的网络, 使用神经网络估计变换参数将源图像与目标图像对齐. Park等人^[144]提出了一种具有双流架构和双向训练架构的端到端可扩展网络, 用于估计航空影像对的变换参数. 添加了一组内部增强的目标图像数据, 这可以使训练后的模型对环境变化更鲁棒, 双向训练架构可以使结果更准确.

综上所述, 深度神经网络能够通过学习的方式有效捕获待配准遥感图像的数据分布, 利用深度神经网络

图2 (网络版彩图)基于深度学习的特征匹配方法

Figure 2 (Color online) Feature matching method based on deep learning.

图3 (网络版彩图)深度学习用于变换参数估计的通用框架

Figure 3 (Color online) A general framework for deep learning to estimate transformation parameters.

络估计变换参数, 能够适应遥感图像配准中数据分布差异较大的场景, 自适应地根据不同数据的分布进行配准任务。

5.4 深度学习用于多源遥感图像配准

多源遥感图像配准是遥感图像配准问题中的一个难点。由于多源遥感图像中待配准图像的成像方式差异较大, 二者的特征难以捕获, 传统方式的特征描述符很难应用到多源遥感图像配准中。大多数文献将孪生网络^[155]及其变体用于多源遥感图像配准。

Hughes等人^[145]为了解决光学遥感图像与SAR图像的匹配问题, 提出了一种伪孪生网络。全连接层用于融合两个网络学习到的特征。两个网络之间没有参数共享, 在最终决策阶段仅融合了特征信息。最终网络输出0, 1作为输入图像对的匹配预测。Zhang等人^[146]采用孪生全卷积网络结构来匹配多个传感器捕获的图像对。网络分支的结构类似于HardNet^[156], 并且为了确保空间特征的准确性, 在每个卷积层上将步幅值设置为1。在两个分支之间共享参数以解决训练数据集少的问题, 通过卷积运算将两个网络分支合并。使用Harris角点检测器^[157]选择本地候选图像补丁, 然后将这些补丁输入网络, 最终分数图的响应表明主补丁和从子补丁在每个位置的相似性。搜索补丁较大时, 相似度最高的点可以视为匹配点。该模型简单, 准确率高, 适合处理由多个不同传感器捕获的图像。Merkle等人^[139]利用孪生结构解决了光学遥感图像和SAR图像的配准问题, 通过卷积神经网络获得了与光学图像相对应的特征向量和与SAR图像相对应的特征矩阵。然后, 点

积层^[158]计算特征向量与特征矩阵中每个元素的相似度, 最后得到一个得分图, 搜索空间中具有最高值的点用于获取匹配对。

多源遥感图像配准的难点在于如何捕获通过不同的成像方式所获取的图像的数据分布, 并从数据分布中获取到可用于多源遥感图像配准的信息。深度学习通过学习的方式来捕获多源遥感图像数据的分布, 能够在差异较大的数据中获取有用的信息, 因此深度神经网络为解决多源遥感图像配准的难题提供了一种新思路。

5.5 小结

近些年来, 深度学习被广泛地应用到计算机视觉任务中, 并且取得了巨大的成功。在遥感图像配准领域, 深度学习同样有着巨大的应用潜力, 与传统方法相比(如SIFT, SURF^[159], ASIFT^[160]), 深度学习由数据驱动, 能够通过学习来捕获图像之间的数据分布, 基于深度学习的遥感图像配准方法能够实现更高精度的配准, 并且具有更高的可移植性。基于深度学习的遥感图像配准目前是遥感图像配准领域的一个焦点。

6 结论

经过几十年的发展, 关于遥感图像配准的研究在某些方面已经取得了巨大的突破, 但是遥感图像配准作为一个开放性的问题, 仍然有许多亟待解决的问题和值得深入研究的内容, 结合当前的研究进展, 本节重点讨论遥感图像配准中目前存在的难点以及未来的

研究方向.

6.1 挑战与展望

群智能算法和其他生物启发计算方法具有一些良好的特性,正是由于这些特点,群智能算法和其他生物启发计算方法才能很好地与遥感图像配准任务相结合,但是如何更好地发挥群智能算法和其他生物启发计算方法的优点,提高遥感图像配准的精度和速度仍然是重中之重,以下几个方面可能会是有益的探索.

(1) 遥感图像配准效率低^[161]. 在实际的工程应用中,往往对遥感图像配准的速度有较高的要求,基于生物启发计算方法的算法普遍要经过多次迭代,耗时较多,不能满足有实时性和应急需求的遥感图像配准任务.并且近些年来随着人类对地球观测能力的不断提升,人类所能获得的遥感图像的空间分辨率和光谱分辨率越来越高,遥感图像的数据量将会成倍增加,数据处理需要花费的时间将越来越长,因此如何提高基于生物启发计算方法的遥感图像配准算法的效率已经变得越来越重要.

(2) 生物启发计算方法与并行计算技术结合^[162]. 近些年来,随着计算机硬件的发展以及并行计算和网格计算技术的发展,可以为解决基于生物启发计算方法的遥感图像配准方法耗时较多、不能满足实时性要求的问题提供较好的解决方案,有许多研究者已经开始这方面的尝试.因此将生物启发计算方法与并行计算技术相结合的遥感图像配准方法必然会成为未来一个重要的研究方向.

(3) 多源遥感图像配准的问题^[68]. 对不同类型传感器获取的图像进行配准时,由于噪声性质差异和成像方式的差异,像元的表现形式不同,最终导致图像数据分布的巨大差异.这就直接导致了将传统的遥感图像配准方法直接用于多源遥感图像配准精度很低,甚

至是匹配失败.目前很多针对多源遥感图像配准的方法基本上都是针对有明显地物特征的图像(道路、建筑、河流等),目前仍然没有统一的框架,尚未形成成熟的方法及处理流程.因此,如何利用生物启发计算方法解决多源遥感图像配准仍然是一个待解决的难题.

(4) 非刚性匹配问题^[163]. 根据实际应用,图像配准可以分为刚性匹配和非刚性匹配.与非刚性匹配相比,刚性匹配涉及的模型参数较少,相关的研究工作也更加成熟.非刚性匹配问题由于其变换难以把握、复杂且建模困难而成为一个图像配准中的难点,但是在遥感图像配准中非刚性匹配非常重要,是一道必须要解决的难题.利用生物启发计算方法的优点,建立合理的解决非刚性匹配问题的模型是下一步需要重点探索的方向.

6.2 总结

遥感图像配准在各种遥感图像处理应用中发挥了重要作用,并引起了广泛的关注.在过去的几十年中,研究人员在该领域也取得了重大进展.因此,我们对现有遥感图像配准算法进行全面的讨论.本文综述了群智能算法、进化算法以及深度学习在遥感图像配准中的应用,并根据不同的算法进行详细地分类讨论,结合不同算法的流程和遥感图像配准的基本流程分别对群智能算法、进化算法和深度学习在配准任务中所起到的作用以及创新性进行阐述.最后本文进一步介绍了遥感图像配准现存方法所面临的挑战以及未来的研究趋势,包括多源遥感图像配准、图像非线性配准、遥感图像实时配准等热门研究方向.随着未来群智能算法、进化算法以及深度学习的发展,一定会有精度更高、速度更快、鲁棒性更好的遥感图像配准方法出现,一定能够满足人类的生产生活需求.

参考文献

- 1 Zitová B, Flusser J. Image registration methods: A survey. *Image Vision Comput*, 2003, 21: 977–1000
- 2 Yu X C, Lv Z H, Hu D. Review of remote sensing image registration techniques (in Chinese). *Opt Precis Eng*, 2013, 21: 2960–2972 [余先川, 吕中华, 胡丹. 遥感图像配准技术综述. *光学精密工程*, 2013, 21: 2960–2972]
- 3 Ma L F, Luo F, Yan J P, et al. Research progress of deep medical image registration: Towards unsupervised learning (in Chinese). *J Image Graph*, 2021, 26: 2037–2057 [马露凡, 罗凤, 严江鹏, 等. 深度医学图像配准研究进展: 迈向无监督学习. *中国图象图形学报*, 2021, 26: 2037–2057]
- 4 Du J, Jiang C, Guo Q, et al. Cooperative earth observation through complex space information networks. *IEEE Wireless Commun*, 2016, 23: 136–144

- 5 Chen Z X, Ren J Q, Tang H J, et al. Progress and prospect of agricultural remote sensing research and application (in Chinese). *J Remote Sens*, 2016, 20: 748–767 [陈仲新, 任建强, 唐华俊, 等. 农业遥感研究应用进展与展望. 遥感学报, 2016, 20: 748–767]
- 6 Iglhaut J, Cabo C, Puliti S, et al. Structure from motion photogrammetry in forestry: A review. *Curr Forry Rep*, 2019, 5: 155–168
- 7 Wu C, Li X, Chen W, et al. A review of geological applications of high-spatial-resolution remote sensing data. *J Circuit Syst Comp*, 2020, 29: 2030006
- 8 El Mahrad B, Newton A, Icely J D, et al. Contribution of remote sensing technologies to a holistic coastal and marine environmental management framework: A review. *Remote Sens*, 2020, 12: 2313
- 9 Xiang J G, Kui M S. Application of remote sensing technology in environmental monitoring (in Chinese). *Surv Mapp Explor*, 2019, 564: 283–284 [向京郭, 奎明邵. 环境监测中遥感技术的应用. 测绘与勘探, 2019, 564: 283–284]
- 10 Liu Y, Chen X, Wang Z, et al. Deep learning for pixel-level image fusion: Recent advances and future prospects. *Inf Fusion*, 2018, 42: 158–173
- 11 Ge Z R, Wang B, Zhang L M. Remote sensing image fusion based on Bayes linear estimation (in Chinese). *Sci Sin Tech*, 2007, 37: 501–513 [葛志荣, 王斌, 张立明. 基于Bayes线性估计的遥感图像融合. 中国科学: 技术科学, 2007, 37: 501–513]
- 12 Wu Y, Bai Z, Miao Q, et al. A classified adversarial network for multi-spectral remote sensing image change detection. *Remote Sens*, 2020, 12: 2098
- 13 Liu H C, Zhang L. Remote sensing image change detection based on adaptive threshold based on land cover type characteristics (in Chinese). *J Remote Sens*, 2018, 24: 728–738 [刘红超, 张磊. 基于土地覆盖类型特征的自适应阈值遥感影像变化检测. 遥感学报, 2018, 24: 728–738]
- 14 Wu Y, Ma W, Gong M, et al. A coarse-to-fine network for ship detection in optical remote sensing images. *Remote Sens*, 2020, 12: 246
- 15 Zhou M F, Wang X L. Object detection models of remote sensing images using deep neural networks with weakly supervised training method (in Chinese). *Sci Sin Inform*, 2018, 48: 1022–1034 [周明非, 汪西莉. 弱监督深层神经网络遥感图像目标检测模型. 中国科学: 信息科学, 2018, 48: 1022–1034]
- 16 Li X, Feng R, Guan X, et al. Remote sensing image mosaicking: Achievements and challenges. *IEEE Geosci Remote Sens Mag*, 2019, 7: 8–22
- 17 Wang R L, Pan W B, Cao W J. Navigation mosaic method driven by image local area matching (in Chinese). *J Comput Aided Design Comput Graph*, 2020, 32: 113–122 [王若兰, 潘万彬, 曹伟娟. 图像局部区域匹配驱动的导航式拼图方法. 计算机辅助设计与图形学学报, 2020, 32: 113–122]
- 18 Chen Y, Ming D, Zhao L, et al. Review on high spatial resolution remote sensing image segmentation evaluation. *Photogramm Eng Remote Sens*, 2018, 84: 629–646
- 19 Chen J Y, Pan D L, Mao Z H. Optimal segmentation of simple objects in high-resolution coastal remote sensing images (in Chinese). *Sci China Ser D-Earth Sci*, 2006, 36: 1044–1051 [陈建裕, 潘德炉, 毛志华. 高分辨率海岸带遥感影像中简单地物的最优分割问题. 中国科学D辑: 地球科学, 2006, 36: 1044–1051]
- 20 Li Y, Zhang H, Xue X, et al. Deep learning for remote sensing image classification: A survey. *WIREs Data Min Knowl Discov*, 2018, 8: e1264
- 21 Wang K, Gu X F, Yu T, et al. Hyperspectral remote sensing image classification method based on spectral similarity (in Chinese). *Sci Sin Tech*, 2013, 43: 407–416 [王珂, 顾行发, 余涛, 等. 基于频谱相似性的高光谱遥感图像分类方法. 中国科学: 技术科学, 2013, 43: 407–416]
- 22 Zeng Q, Liu L, Li J. Image registration method based on improved Harris corner detector. *Chin Opt Lett*, 2010, 8: 573–576
- 23 Brown L G. A survey of image registration techniques. *ACM Comput Surv*, 1992, 24: 325–376
- 24 Zhao S, Yu G. A new image registration algorithm using SDTR. *Neurocomputing*, 2017, 234: 174–184
- 25 Hrkač T, Kalafatić Z, Krapac J. Infrared-visual image registration based on corners and Hausdorff distance. In: *Scandinavian Conference on Image Analysis*. Berlin, Heidelberg: Springer, 2007. 383–392
- 26 Wyawahare M V, Patil P M, Abhyankar H K. Image registration techniques: An overview. *Int J Signal Process, Image Process Pattern Recognit*, 2009, 2: 11–28
- 27 Li L J, Liu X H, Huang X X. A multi-spectral image registration method based on symmetric edge (in Chinese). *Semicond Optoelectr*, 2019, 40: 395–400 [李良骥, 刘晓华, 黄小仙. 一种基于对称性边缘的多光谱图像配准方法. 半导体光电, 2019, 40: 395–400]
- 28 Su Q H, Cheng H, Sun W B. Research on remote sensing image registration methods—Summary (in Chinese). *Infrared*, 2010, 31: 1–6, 39 [苏清贺, 程红, 孙文邦. 遥感图像配准方法研究——综述. 红外, 2010, 31: 1–6, 39]
- 29 Zhao F Q. Review of image registration technology (in Chinese). *Digital Tech Appl*, 2016, 6: 245–245 [赵夫群. 图像配准技术研究综述. 数字技术与应用, 2016, 6: 245–245]
- 30 Le Moigne J. Introduction to remote sensing image registration. In: *IEEE International Geoscience and Remote Sensing Symposium*. Fort

- Worth, 2017. 2565–2568
- 31 Gong J Y, Zhong Y F. Research progress of intelligent processing of optical remote sensing images (in Chinese). *J Remote Sens*, 2016, 20: 733–747 [龚健雅, 钟燕飞. 光学遥感影像智能化处理研究进展. *遥感学报*, 2016, 20: 733–747]
 - 32 Cheng X Q, Mei H, Zhao W, et al. Data science and swarm intelligence and biological heuristic computing methods: Connotation, paradigm and opportunity (in Chinese). *J Chin Acad Sci*, 2020, 35: 1470–1481 [程学旗, 梅宏, 赵伟, 等. 数据科学与群智能和生物启发计算方法: 内涵, 范式与机遇. *中国科学院院刊*, 2020, 35: 1470–1481]
 - 33 Kennedy J. *Swarm Intelligence. Handbook of Nature-Inspired and Innovative Computing*. Boston: Springer, 2006. 187–219
 - 34 Gong M G, Jiao L C, Yang D D, et al. Research on evolutionary multi-objective optimization algorithms (in Chinese). *J Software*, 2009, 20: 271–289 [公茂果, 焦李成, 杨咚咚, 等. 进化多目标优化算法研究. *软件学报*, 2009, 20: 271–289]
 - 35 Duan H, Luo Q. New progresses in swarm intelligence-based computation. *Int J Bio-Ins Comput*, 2015, 7: 26–35
 - 36 Duan H B, Qiu H X, Chen L, et al. Research prospect of UAV autonomous cluster technology (in Chinese). *Sci Tech Rev*, 2018, 36: 90–98 [段海滨, 邱华鑫, 陈琳, 等. 无人机自主集群技术研究展望. *科技导报*, 2018, 36: 90–98]
 - 37 Zhou A, Zhang Q, Jin Y, et al. A model-based evolutionary algorithm for bi-objective optimization. In: 2005 IEEE Congress on Evolutionary Computation. Edinburgh, 2005. 2568–2575
 - 38 Al-Sahaf H, Zhang M, Al-Sahaf A, et al. Keypoints detection and feature extraction: A dynamic genetic programming approach for evolving rotation-invariant texture image descriptors. *IEEE Trans Evol Computat*, 2017, 21: 825–844
 - 39 Albukhanajer W A, Briffa J A, Yaochu Jin J A. Evolutionary multiobjective image feature extraction in the presence of noise. *IEEE Trans Cybern*, 2014, 45: 1757–1768
 - 40 Pramanik J, Dalai S, Rana D. Image registration using discrete wavelet transform and particle swarm optimization. *Int J Comput Sci Inform Tech*, 2015, 6: 1521–1525
 - 41 Tian Y, Ma H D. Image registration based on improved ant colony algorithm. *Adv Mater Res*, 2013, 765–767: 683–686
 - 42 Santamaría J, Damas S, Garcia-Torres J M, et al. Self-adaptive evolutionary image registration using differential evolution and artificial immune systems. *Pattern Recognition Lett*, 2012, 33: 2065–2070
 - 43 Ingole V T, Deshmukh C N, Joshi A, et al. Medical image registration using genetic algorithm. In: 2009 Second International Conference on Emerging Trends in Engineering & Technology. Nagpur, 2009. 63–66
 - 44 Wang X, Adjouadi M. Automatic registration of FDGCT and FLTCT images integrating Genetic Algorithm, Powell method and wavelet decomposition. In: IEEE Signal Processing in Medicine and Biology Symposium. Philadelphia, 2015. 1–5
 - 45 Schwab L, Schmitt M, Wanka R. Multimodal medical image registration using particle swarm optimization with influence of the data's initial orientation. In: IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology. Niagara Falls, 2015. 1–8
 - 46 Abdel-Basset M, Fakhry A E, El-Henawy I, et al. Feature and intensity based medical image registration using particle swarm optimization. *J Med Syst*, 2017, 41: 1–5
 - 47 Delibasis K K, Asvestas P A, Matsopoulos G K. Automatic point correspondence using an artificial immune system optimization technique for medical image registration. *Computized Med Imag Graphics*, 2011, 35: 31–41
 - 48 Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks. In: Proceedings of the 25th International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2012. 1097–1105
 - 49 Voulodimos A, Doulamis N, Doulamis A, et al. Deep learning for computer vision: A brief review. *Comput Intell Neurosci*, 2018, 2018: 1–13
 - 50 de Vos B D, Berendsen F F, Viergever M A, et al. End-to-end unsupervised deformable image registration with a convolutional neural network. In: Cardoso M, et al., ed. *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. Cham: Springer, 2017. 204–212
 - 51 Zhao Z Q, Zheng P, Xu S T, et al. Object detection with deep learning: A review. *IEEE Trans Neural Netw Learn Syst*, 2019, 30: 3212–3232
 - 52 Singh B, Najibi M, Davis L S. Sniper: Efficient multi-scale training. arXiv: [1805.09300](https://arxiv.org/abs/1805.09300)
 - 53 Gong M, Yang H, Zhang P. Feature learning and change feature classification based on deep learning for ternary change detection in SAR images. *ISPRS J Photogramm Remote Sens*, 2017, 129: 212–225
 - 54 Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation. In: 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, 2015. 3431–3440
 - 55 Chen L C, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation. In: Ferrari V,

- Hebert M, Sminchisescu C, et al., ed. Computer Vision—ECCV 2018. Lecture Notes in Computer Science, vol 11211. Cham: Springer, 2018. 801–818
- 56 He K, Zhang X, Ren S, et al. Deep residual learning for image recognition. In: 2016 IEEE Computer Vision and Pattern Recognition. Las Vegas, 2016. 770–778
- 57 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv: [1409.1556](#)
- 58 Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions. In: 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, 2015. 1–9
- 59 Xu F, Hu C, Li J, et al. Brief introduction of deep learning in remote sensing image processing (in Chinese). *Sci Sin Inform*, 2020, 50: 619–620 [徐丰, 胡程, 李军, 等. 遥感图像处理中的深度学习专题简介. 中国科学: 信息科学, 2020, 50: 619–620]
- 60 Ye F, Su Y, Xiao H, et al. Remote sensing image registration using convolutional neural network features. *IEEE Geosci Remote Sens Lett*, 2018, 15: 232–236
- 61 Iqbal R, Doctor F, More B, et al. Big data analytics: Computational intelligence techniques and application areas. *Tech Forecast Soc Change*, 2020, 153: 119253
- 62 Chen Y S. Performance identification in large-scale class data from advanced facets of computational intelligence and soft computing techniques. *Int J High Perform Comput Netw*, 2019, 13: 283–293
- 63 Zhong Y, Ma A, Ong Y, et al. Computational intelligence in optical remote sensing image processing. *Appl Soft Comput*, 2018, 64: 75–93
- 64 Liu H, Xiao G F. Remote sensing image registration based on improved KAZE and BRIEF descriptor. *Int J Autom Comput*, 2020, 17: 588–598
- 65 Ramson S R J, Raju K L, Vishnu S, et al. Nature inspired optimization techniques for image processing—A short review. In: Hemanth D J, Balas V E, eds. Nature Inspired Optimization Techniques for Image Processing Applications. Cham: Springer, 2019. 113–145
- 66 Ma L, Liu Y, Zhang X, et al. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS J Photogramm Remote Sens*, 2019, 152: 166–177
- 67 Liu H, Xiao G F, Tan Y L, et al. Multi-source remote sensing image registration based on contourlet transform and multiple feature fusion. *Int J Autom Comput*, 2019, 16: 575–588
- 68 Lin S J, Dong C, Chen M Z, et al. Overview of new swarm intelligence optimization algorithms (in Chinese). *Comput Eng Appl*, 2018, 54: 1–9 [林诗洁, 董晨, 陈明志, 等. 新型群智能优化算法综述. 计算机工程与应用, 2018, 54: 1–9]
- 69 Mavrouniotis M, Li C, Yang S. A survey of swarm intelligence for dynamic optimization: Algorithms and applications. *Swarm Evolary Computat*, 2017, 33: 1–17
- 70 Yang F, Wang P, Zhang Y, et al. Survey of swarm intelligence optimization algorithms. In: 2017 IEEE International Conference on Unmanned Systems (ICUS). Beijing, IEEE, 2017: 544–549
- 71 Lu Y, Liao Z W, Chen W F. An automatic registration framework using quantum particle swarm optimization for remote sensing images. In: International Conference on Wavelet Analysis and Pattern Recognition. Beijing, 2007. 484–488
- 72 Zhang Y, Guo Y, Gu Y, et al. Particle swarm optimization with Powell's direction set method for remote sensing image registration. In: International Conference on Natural Computation. Tianjin, 2009. 388–392
- 73 Ru A, Chunye C, Huilin W. An improved particle swarm optimization algorithm for image matching. In: International Forum on Computer Science-Technology and Applications. Chongqing, 2009. 7–10
- 74 Gharbia R, Ahmed S A, ella Hassanien A. Remote sensing image registration based on particle swarm optimization and mutual information. In: Information Systems Design and Intelligent Applications. Kalyani, 2015. 399–408
- 75 Yavari S, Valadan Zoj M J, Sahebi M R, et al. Accuracy improvement of high resolution satellite image georeferencing using an optimized line-based rational function model. *Int J Remote Sens*, 2018, 39: 1655–1670
- 76 Wu Y, Miao Q, Ma W, et al. PSOSAC: Particle swarm optimization sample consensus algorithm for remote sensing image registration. *IEEE Geosci Remote Sens Lett*, 2017, 15: 242–246
- 77 Wu Y, Ma W, Miao Q, et al. Multimodal continuous ant colony optimization for multisensor remote sensing image registration with local search. *Swarm Evolary Computat*, 2019, 47: 89–95
- 78 Kennedy J, Eberhart R. Particle swarm optimization. In: Proceedings of ICNN'95—International Conference on Neural Networks. Perth, 1995. 1942–1948
- 79 Bai Q. Analysis of particle swarm optimization algorithm. *Comput Inform Sci*, 2010, 3: 180

- 80 Rini D P, Shamsuddin S M, Yuhaziz S S. Particle swarm optimization: Technique, system and challenges. *Int J Comput Appl*, 2011, 14: 19–26
- 81 Dorigo M, Maniezzo V, Colomi A. Ant system: Optimization by a colony of cooperating agents. *IEEE Trans Syst Man Cybern B*, 1996, 26: 29–41
- 82 Eiben A E, Schoenauer M. Evolutionary computing. *Inf Process Lett*, 2002, 82: 1–6
- 83 De Jong K. Evolutionary computation: A unified approach. In: *Genetic and Evolutionary Computation Conference Companion*. Denver, 2016. 185–199
- 84 Opara K R, Arabas J. Differential evolution: A survey of theoretical analyses. *Swarm Evolary Computat*, 2019, 44: 546–558
- 85 He Z, Yen G G, Lv J. Evolutionary multiobjective optimization with robustness enhancement. *IEEE Trans Evol Computat*, 2019, 24: 494–507
- 86 Inglada J, Adragna F. Automatic multi-sensor image registration by edge matching using genetic algorithms. *Scann Present Resolv Future*, 2001, 5: 2313–2315
- 87 Makrogiannis S K, Bourbakis N G, Borek S. A stochastic optimization scheme for automatic registration of aerial images. In: *IEEE International Conference on Tools with Artificial Intelligence*. Boca Raton, 2004. 328–336
- 88 Zhang Q, Wen G, Zhang C, et al. Image registration with position and similarity constraints based on genetic algorithm. In: *International Conference on Natural Computation*. Xiamen, 2014. 568–572
- 89 Gou Z, Ma H. An automatic registration based on genetic algorithm for multi-source remote sensing. In: *International Conference on Control, Automation and Robotics*. Hong Kong, 2016. 318–323
- 90 Li Y, Liu Q, Jing L, et al. A genetic-optimized multi-angle normalized cross correlation SIFT for automatic remote sensing registration. In: *IEEE International Geoscience and Remote Sensing Symposium*. Beijing, 2016. 2586–2589
- 91 Yavari S, Valadan Zoej M J, Salehi B. An automatic optimum number of well-distributed ground control lines selection procedure based on genetic algorithm. *ISPRS J Photogramm Remote Sens*, 2018, 139: 46–56
- 92 De Falco I, Della Cioppa A, Maisto D, et al. Distributed differential evolution for the registration of satellite and multimodal medical imagery. In: Cagnoni S, ed. *Evolutionary Image Analysis and Signal Processing*. Studies in Computational Intelligence, vol 213. Berlin, Heidelberg: Springer, 2009. 153–169
- 93 Hu Z, Gong W, Cai Z. Multi-resolution remote sensing image registration using differential evolution with adaptive strategy selection. *Opt Eng*, 2012, 51: 101707
- 94 Ma W, Fan X, Wu Y, et al. An orthogonal learning differential evolution algorithm for remote sensing image registration. *Math Problems Eng*, 2014, 2014: 1–11
- 95 Holland J H. *Adaptation in Natural and Artificial Systems*. Michigan: The University of Michigan Press, 1975
- 96 Yadav P K, Prajapati N L. An overview of genetic algorithm and modeling. *Int J Sci Res Publ*, 2012, 2: 1–4
- 97 Storn R, Price K. Differential evolution—A simple and efficient heuristic for global optimization over continuous spaces. *J Glob Optimiz*, 1997, 11: 341–359
- 98 Sharma P, Sharma H, Bansal J C. Effective competency based differential evolution algorithm. *J Stat Manage Syst*, 2019, 22: 1223–1238
- 99 Kachitvichyanukul V. Comparison of three evolutionary algorithms: GA, PSO, and DE. *Industrial Eng Manage Syst*, 2012, 11: 215–223
- 100 Das S, Mullick S S, Suganthan P N. Recent advances in differential evolution—An updated survey. *Swarm Evolary Computat*, 2016, 27: 1–30
- 101 Gu J, Wang Z, Kuen J, et al. Recent advances in convolutional neural networks. *Pattern Recognit*, 2018, 77: 354–377
- 102 Murugan P. Feed forward and backward run in deep convolution neural network. arXiv: 1711.03278
- 103 Giusti A, Masci J, et al. Fast image scanning with deep max-pooling convolutional neural networks. In: *IEEE International Conference on Image Processing*. Melbourne, 2013. 4034–4038
- 104 Ma W, Lu J. An equivalence of fully connected layer and convolutional layer. arXiv: 1712.01252
- 105 Parpinelli R S, Lopes H S. New inspirations in swarm intelligence: A survey. *Int J Bio-Inspired Computat*, 2011, 3: 1–6
- 106 Kolias C, Kambourakis G, Maragoudakis M. Swarm intelligence in intrusion detection: A survey. *Comput Security*, 2011, 30: 625–642
- 107 Fister Jr. I, Yang X S, Fister I, et al. A brief review of nature-inspired algorithms for optimization. arXiv: 1307.4186
- 108 Yang X C, Wang J D, Li P. Multi-spectral image registration based on improved ant colony algorithm and mutual information (in Chinese). *Infrared Tech*, 2010, 32: 41 [杨绪超, 王敬东, 李鹏. 基于改进蚁群算法和互信息的多光谱图像的配准. 红外技术, 2010, 32: 41]
- 109 Chen S, Xue B, Yang H, et al. Optical remote sensing image registration using spatial-consistency and average regional information divergence minimization via quantum-behaved particle swarm optimization. *Remote Sens*, 2020, 12: 3066

- 110 Li Q, Sato I. Multimodality image registration by particle swarm optimization of mutual information. In: International Conference on Intelligent Computing. Berlin, Heidelberg: Springer, 2007. 1120–1130
- 111 Peng W, Tong R, Qian G, et al. A constrained ant colony algorithm for image registration. In: International Conference on Intelligent Computing. Berlin, Heilberg: Springer, 2006. 1–11
- 112 Yang F, Zhang H. Multiresolution 3D image registration using hybrid ant colony algorithm and Powell's method. *J Electron Inform Tech*, 2007, 29: 622–625
- 113 Rezaei H, Shakeri M, Azadi S, et al. Multimodality image registration utilizing ant colony algorithm. In: International Conference on Machine Vision. Montreal, 2009. 49–53
- 114 Raghtate G S, Salankar S S. Modified fuzzy C means with optimized ant colony algorithm for image segmentation. In: International Conference on Computational Intelligence and Communication Networks. Jabalpur, 2015. 1283–1288
- 115 Khorram B, Yazdi M. A new optimized thresholding method using ant colony algorithm for MR brain image segmentation. *J Digit Imag*, 2019, 32: 162–174
- 116 Zou G. Ant colony clustering algorithm and improved Markov random fusion algorithm in image segmentation of brain images. *Int J Bioautom*, 2016, 20: 505
- 117 He Y, Liu J H, Yang R H. Survey of artificial bee colony algorithm (in Chinese). *Comput Appl Res*, 2018, 35: 1281–1286 [何尧, 刘建华, 杨荣华. 人工蜂群算法研究综述. *计算机应用研究*, 2018, 35: 1281–1286]
- 118 Wen T, Liu H, Lin L, et al. Multiswarm Artificial Bee Colony algorithm based on spark cloud computing platform for medical image registration. *Comput Methods Programs Biomed*, 2020, 192: 105432
- 119 Dong H, Qi X N. Emotional bacterial foraging algorithm based on non-uniform elimination-diffusion probability distribution (in Chinese). *Comput Appl*, 2020, 40: 1731–1737 [董海, 齐新娜. 基于非均匀消除-扩散概率分布的情绪化细菌觅食算法. *计算机应用*, 2020, 40: 1731–1737]
- 120 Bermejo E, Valsecchi A, Damas S, et al. Bacterial foraging optimization for intensity-based medical image registration. In: 2015 IEEE Congress on Evolutionary Computation (CEC). Sendai, IEEE, 2015. 2436–2443
- 121 Chen J J, Liu S. Adaptive artificial fish swarm optimization algorithm based on tabu search (in Chinese). *Comput Tech Devel*, 2021, 31: 8–13 [陈静静, 刘升. 基于禁忌搜索的自适应人工鱼群优化算法. *计算机技术与发展*, 2021, 31: 8–13]
- 122 Zhao H, Yao L, Luo B. Registration of multi-resolution medical images using a modified artificial fish-swarm algorithm combined with Powell's method. *J Xi'an Jiaotong Univ*, 2011, 45: 46–52
- 123 Rellier G, Descombes X, Zerubia J. Local registration and deformation of a road cartographic database on a SPOT satellite image. *Pattern Recognit*, 2002, 35: 2213–2221
- 124 Du X G, Dang J, Wang Y P, et al. An algorithm multi-resolution medical image registration based on firefly algorithm and powell. In: International Conference on Intelligent System Design and Engineering Applications. Zhangjiajie, 2013. 274–277
- 125 Zhang J, Hu J. A novel registration method based on coevolutionary strategy. In: IEEE Congress on Evolutionary Computation. Vancouver, 2016. 2375–2380
- 126 Yang X S, He X. Bat algorithm: Literature review and applications. *Int J Bio-inspired Computat*, 2013, 5: 141–149
- 127 Shi Y. Brain storm optimization algorithm. In: International Conference in Swarm Intelligence. Chongqing, 2011. 303–309
- 128 De Falco I, Della Cioppa A, Maisto D, et al. Differential evolution for the registration of remotely sensed images. In: Saad A, Dahal K, Sarfraz M, et al., eds. *Soft Computing in Industrial Applications. Advances in Soft Computing*, vol 39. Berlin, Heidelberg: Springer, 2007. 40–49
- 129 Saini N. Review of selection methods in genetic algorithms. *Int J Eng Comput Sci*, 2017, 6: 22261–22263
- 130 Al-Dabbagh R D, Neri F, Idris N, et al. Algorithmic design issues in adaptive differential evolution schemes: Review and taxonomy. *Swarm Evolary Computat*, 2018, 43: 284–311
- 131 De Falco I, Della Cioppa A, Maisto D, et al. Differential evolution as a viable tool for satellite image registration. *Appl Soft Comput*, 2008, 8: 1453–1462
- 132 De Falco I, Maisto D, Scafuri U, et al. Distributed differential evolution for the registration of remotely sensed images. In: EUROMICRO International Conference on Parallel, Distributed and Network-Based Processing. Napoli, 2007. 358–362
- 133 Nguyen S, Mei Y, Zhang M. Genetic programming for production scheduling: A survey with a unified framework. *Complex Intell Syst*, 2017, 3: 41–66

- 134 Porto V W. Evolutionary Programming. *Evolutionary Computation* 1. Boca Raton: CRC Press, 2018. 127–140
- 135 Liu K, Zhang J. Nonlinear process modelling using echo state networks optimised by covariance matrix adaption evolutionary strategy. *Comput Chem Eng*, 2020, 135: 106730
- 136 Lowe D G. Distinctive image features from scale-invariant keypoints. *Int J Comput Vision*, 2004, 60: 91–110
- 137 Ma W, Zhang J, Wu Y, et al. A novel two-step registration method for remote sensing images based on deep and local features. *IEEE Trans Geosci Remote Sens*, 2019, 57: 4834–4843
- 138 Dong Y, Jiao W, Long T, et al. Local deep descriptor for remote sensing image feature matching. *Remote Sens*, 2019, 11: 430
- 139 Merkle N, Luo W, Auer S, et al. Exploiting deep matching and SAR data for the geo-localization accuracy improvement of optical satellite images. *Remote Sens*, 2017, 9: 586
- 140 Yang Z, Dan T, Yang Y. Multi-temporal remote sensing image registration using deep convolutional features. *IEEE Access*, 2018, 6: 38544–38555
- 141 Wang S, Quan D, Liang X, et al. A deep learning framework for remote sensing image registration. *ISPRS J Photogramm Remote Sens*, 2018, 145: 148–164
- 142 Quan D, Wang S, Liang X, et al. Deep generative matching network for optical and SAR image registration. In: *IEEE International Geoscience and Remote Sensing Symposium*. Valencia, 2018. 6215–6218
- 143 Kim D G, Nam W J, Lee S W. A robust matching network for gradually estimating geometric transformation on remote sensing imagery. In: *IEEE International Conference on Systems, Man and Cybernetics*. Bari, 2019. 3889–3894
- 144 Park J H, Nam W J, Lee S W. A two-stream symmetric network with bidirectional ensemble for aerial image matching. *Remote Sens*, 2020, 12: 465
- 145 Hughes L H, Schmitt M, Mou L, et al. Identifying corresponding patches in SAR and optical images with a pseudo-siamese CNN. *IEEE Geosci Remote Sens Lett*, 2018, 15: 784–788
- 146 Zhang H, Ni W, Yan W, et al. Registration of multimodal remote sensing image based on deep fully convolutional neural network. *IEEE J Sel Top Appl Earth Observ Remote Sens*, 2019, 12: 3028–3042
- 147 Dalal N, Triggs B. Histograms of oriented gradients for human detection. In: *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. San Diego, 2005. 886–893
- 148 Alshehhi R, Marpu P R, Woon W L, et al. Simultaneous extraction of roads and buildings in remote sensing imagery with convolutional neural networks. *ISPRS J Photogramm Remote Sens*, 2017, 130: 139–149
- 149 Ma W, Wen Z, Wu Y, et al. Remote sensing image registration with modified SIFT and enhanced feature matching. *IEEE Geosci Remote Sens Lett*, 2016, 14: 3–7
- 150 Sedaghat A, Mokhtarzade M, Ebadi H. Uniform robust scale-invariant feature matching for optical remote sensing images. *IEEE Trans Geosci Remote Sens*, 2011, 49: 4516–4527
- 151 Sedaghat A, Ebadi H. Remote sensing image matching based on adaptive binning SIFT descriptor. *IEEE Trans Geosci Remote Sens*, 2015, 53: 5283–5293
- 152 Springenberg J T, Dosovitskiy A, Brox T, et al. Striving for simplicity: The all convolutional net. arXiv: [1412.6806](https://arxiv.org/abs/1412.6806)
- 153 Han X, Leung T, Jia Y, et al. Matchnet: Unifying feature and metric learning for patch-based matching. In: *Computer Vision and Pattern Recognition*. Boston, 2015. 3279–3286
- 154 Vakalopoulou M, Christodoulidis S, Sahasrabudhe M, et al. Image registration of satellite imagery with deep convolutional neural networks. In: *IEEE International Geoscience and Remote Sensing Symposium*. Yokohama, 2019. 4939–4942
- 155 Bromley J, Guyon I, LeCun Y, et al. Signature verification using a “siamese” time delay neural network. In: *Advances in Neural Information Processing Systems*. Denver, 1994. 737–737
- 156 Mishchuk A, Mishkin D, Radenovic F, et al. Working hard to know your neighbor’s margins: Local descriptor learning loss. arXiv: [1705.10872](https://arxiv.org/abs/1705.10872)
- 157 Harris C G, Stephens M. A combined corner and edge detector. In: *Proceedings of the 4th Alvey Vision Conference*. 1988
- 158 Luo W, Schwing A G, Urtasun R. Efficient deep learning for stereo matching. In: *Computer Vision and Pattern Recognition*. 2016. 5695–5703
- 159 Bay H, Tuytelaars T, van Gool L. Surf: Speeded up robust features. In: *European Conference on Computer Vision*. 2006. 404–417
- 160 Morel J M, Yu G. ASIFT: A new framework for fully affine invariant image comparison. *SIAM J Imag Sci*, 2009, 2: 438–469
- 161 Ye Y, Bruzzone L, Shan J, et al. Fast and robust matching for multimodal remote sensing image registration. *IEEE Trans Geosci Remote Sens*,

2019, 57: 9059–9070

- 162 James C D, Aimone J B, Miner N E, et al. A historical survey of algorithms and hardware architectures for neural-inspired and neuromorphic computing applications. *Biolly Inspired Cognitive Architectures*, 2017, 19: 49–64
- 163 Ji H Z, Jia D Y, Dong E Q, et al. Non-rigid registrations based on image characteristics and optical flows (in Chinese). *Opt Precis Eng*, 2017, 25: 2469–2482 [纪慧中, 贾大宇, 董恩清, 等. 基于图像特征和光流场的非刚性图像配准. 光学精密工程, 2017, 25: 2469–2482]

Application of swarm intelligence and a bioinspired computing algorithm in remote sensing image registration

WU Yue^{1,2}, BAI ZhuangFei^{1,2}, GONG MaoGuo³, QU BoYiTing¹, LI Hao³, ZHANG MingYang³, MA WenPing⁴ & MIAO QiGuang^{1,2}

¹ School of Computer Science and Technology, Xidian University, Xi'an 710071, China;

² Key Laboratory of Big Data and Intelligent Vision, Xidian University, Xi'an 710071, China;

³ School of Electronic Engineering, Xidian University, Xi'an 710071, China;

⁴ School of Artificial Intelligence, Xidian University, Xi'an 710071, China

Remote sensing image registration is a major part of remote sensing image processing and has important research significance and application value in the field of intelligent remote sensing information processing. This paper mainly reviews the application of swarm intelligence in remote sensing image registration and introduces the application of evolutionary algorithms and deep learning in remote sensing images. First, the principles and advantages of evolutionary algorithms, swarm intelligence algorithms, and deep learning are introduced. Second, the application of evolutionary computing in remote sensing image registration is provided and summarized in detail. Consequently, the application of the swarm intelligence algorithm in remote sensing image registration is introduced in detail. Then, we generalize the application of deep learning in remote sensing image registration; in addition, we also give a comprehensive discussion of the current difficulties in remote sensing image registration and the advantages of deep learning in solving these difficulties. Finally, the key issues of swarm intelligence and bioinspired computing algorithm in remote sensing image registration are delivered and prospected.

evolutionary computation, swarm intelligence, deep learning, remote sensing, image registration

doi: [10.1360/SST-2021-0193](https://doi.org/10.1360/SST-2021-0193)