

DOI:10.16136/j.joel.2022.08.0811

基于循环生成对抗策略的遥感图像匹配算法

唐浩漾^{1*}, 肖佳欣¹, 翟玉翔¹, 杨东方²

(1. 西安邮电大学 自动化学院, 陕西 西安 710000; 2. 火箭军工程大学 导弹工程学院, 陕西 西安 710025)

摘要:针对异源遥感影像成像模式、时相、分辨率等不同导致的图像匹配困难问题,提出了一种基于循环生成对抗策略的遥感图像匹配算法。构建了跨数据域图像特征迁移的循环生成对抗网络(generative adversarial network, GAN),设计 SmoothL₁ 损失函数对网络进行优化,提高遥感图像特征提取精度,并基于图像特征迁移结果,建立三元组距离排序损失函数(triplet margin ranking loss, TMRL)降低遥感图像的误匹配点数,实现异源遥感图像的准确匹配。实验结果表明,本文方法将异源遥感图像匹配平均准确率提升了 33.51%,与 CMM-Net(cross modality matching net)方法相比,具有更好的遥感图像匹配效果。此外,本文方法不需要目标域图像的标注信息,匹配时间缩短了 0.073 s,能快速准确实现异源遥感图像匹配。

关键词:图像匹配;特征提取;生成对抗;风格迁移

中图分类号: TP751.2 **文献标识码:** A **文章编号:** 1005-0086(2022)08-0824-07

Remote sensing image matching algorithm based on cycle generative adversarial strategy

TANG Haoyang^{1*}, XIAO Jiaxin¹, ZHAI Yuxiang², YANG Dongfang²

(1. College of Automation, Xi'an University of Posts and Telecommunications, Xi'an, Shaanxi 710000, China;

2. College of Missile Engineering, Rocket Force University of Engineering, Xi'an, Shaanxi 710025, China)

Abstract: Aiming at the difficulty of image matching caused by different imaging modes, time phases and resolutions of heterogeneous remote sensing images, a remote sensing image matching algorithm based on cycle generative adversarial strategy is proposed. A cross-data domain image feature migration cycle generative adversarial network (GAN) was constructed, a SmoothL₁ loss function was designed to optimize the network, the accuracy of remote sensing image feature extraction was improved, and based on the result of image feature migration, triplet margin ranking loss function (TMRL) was established to reduce remote sensing image mismatched points, to achieve accurate matching of heterogeneous remote sensing images. The test results show that the method in this paper improves the average accuracy of heterogeneous remote sensing image matching by 33.51%, and has a better remote sensing image matching effect than the cross modality matching net (CMM-Net) method. In addition, this method not require the annotation information of the target domain image, and the matching time is shortened by 0.073 s, which can quickly and accurately achieve heterogeneous remote image matching.

Key words: image matching; feature extraction; generative adversarial; style migration

1 引言

近年来,空基对地观测平台的种类、数量急速增加,遥感数据的空间分辨率和光谱率等性能不

断提升,如何从无人机、卫星等无人平台获取的海量、多模态遥感数据中,实现对异源遥感影像之间的匹配,是遥感图像领域亟需解决的关键问题^[1]。

国内外学者针对这一问题提出了多种匹配方

* E-mail: tanghaoyang@xupt.edu.cn

收稿日期:2021-12-04 修订日期:2021-01-10

基金项目:国家自然科学基金(61673017,61403398)、国家博士后基金面上项目(2019M3643)和西安市科技局项目(21RGZN0020)资助项目

法,主要分为基于特征的匹配方法和基于模板的匹配方法。基于特征的匹配算法中最著名的是尺度不变特征变换算法(scale invariant feature transformation, SIFT)。该算法在图像的不变特征提取方面具有较高的优势,但是对于模糊和边缘平滑的图像, SIFT方法检测到的特征点数量较少,很难获得良好的效果^[2]。国内外学者针对 SIFT 算法提出了很多改进方法,例如 SURF 算法^[3](speeded up robust feature)提高了特征点检测速度, GLOH 算法^[4](gradient location and orientation histogram)增强了特征描述子的特性。与基于特征的匹配方法相比,基于模板的匹配可以获得更加稳定的特征。2018年, YAN等^[5]提出了一种结合灰度和梯度信息的多模态影像配准算法,能够实现多模态图像的自动配准。本文算法在利用互信息进行相似性测度时,需要计算待配准影像之间的联合概率分布,对于具有显著旋转、尺度变化的多模态遥感影像数据,配准精度不高。2020年, LI等^[6]提出了基于相位一致性和最大索引图的辐射不变特征匹配方法,都取得很好的匹配效果。

2016年以后,学习型关键点特征检测和描述算法得到了迅猛发展,相继提出了 LIFT(learned invariant feature transform)^[7]、SuperPoint(self-supervised interest point)^[8]、DELF(deep local features)^[9]、D2-Net(description and detection of local features)^[10]、CMM-Net(cross modality matching net)^[11]等算法。其中 CMM-Net 通过卷积神经网络(convolution neural network, CNN)提取高层语义局部特征,自动学习和寻找异源影像同名点之间的几何和辐射不变量,形成一种稳健的端对端异源遥感影像匹配方法。对于异源遥感图像匹配任务而言,地理区域变化、季节、气候的不同,甚至光照条件、传感器等硬件设备的差异,都会使得应用场合的新图像与训练样本有所不同,导致同一区域、不同数据源的异源遥感影像匹配结果发生较大变化,而事先让网络模型学习地球上所有地表特征也是不可能的。因此,异源遥感影像匹配的关键问题是如何减小异源影像辐射和几何差异带来的影响,找到稳定特征表示方法。

无监督域适应是目前解决域差异问题,实现跨数据域应用的一类迁移学习方法,其核心思想是最小化源域与目标域特征分布之间的差异,即学习域不变特征。2014年, GOODFELLOW等^[12]提出生成对抗网络(generative adversarial network, GAN)。GAN由生成网络和判别网络组成,生成网络用来生成图像,判别网络用来区分生成样本与真实样本,其训练过程是一个生成网络

和判别网络相互对抗的过程^[13]。GAN在跨数据域图像迁移任务上显示出良好的视觉效果,但是该方法需要成对训练数据,使用条件较为苛刻。随着 CycleGAN(cycle consistent adversarial network)^[14]、DiscoGAN(discover cross-domain relations with generative adversarial network)^[15]和 DualGAN(dual channel-wise alignment network)^[16]的出现,这几个具有相似的体系结构的 GAN 框架,能够在训练数据不成对的情况下,完成图像到图像的迁移^[17]。

为减小异源遥感影像辐射和几何差异带来的影响,本文引入 CycleGAN 将可见光遥感图像特征空间映射到语义信息丰富的标准地图中,训练特征迁移模型能够对不同模态遥感数据地表类型进行准确分类,以提取遥感图像的稳定特征。为提高特征迁移模型泛化能力,提出鲁棒性更强的 SmoothL₁ 损失函数代替均方误差(mean square error, MSE)损失函数,提高迁移模型对不同模态遥感数据的抗干扰能力。此外,本文采用三元组距离排序损失函数(triplet margin ranking loss, TM-RL)作为匹配算法的损失函数,通过惩罚导致错误匹配的任何不相关描述符来降低图像误匹配点数,从而提高异源遥感图像匹配的精度和泛化能力。

2 基本原理

2.1 异源遥感图像匹配算法原理

异源遥感影像匹配算法原理如图1所示,该算法包括特征迁移和图像匹配两个模块。本文采取“先特征迁移再进行匹配”的策略,将不同模态的遥感影像数据迁移到同一模态下,减小异源影像辐射和几何差异带来的影响,再利用包含丰富语义边缘信息的稳定特征进行匹配,提高匹配准确率。为提高原始 CycleGAN 网络的泛化能力,采用 SmoothL₁ 损失替代 MSE 损失,通过对于符合特征分布的样本数据以及不符合特征分布的离群样本数据采取不同的梯度计算方式,降低离群样本迁移模型的影响,提高网络模型的抗干扰能力与泛化能力。

本文改进后的特征迁移网络模型记为 SCycleGAN,特征迁移具体过程如下:假设 X 是某城市遥感图像数据集; Y 是由人工地物标注的标准地图数据集。在训练阶段,分别从 X 、 Y 中随机采样一对遥感图像 x 和标准地图 y ,生成网络 G 和 F 分别是从 X 域向 Y 域以及 Y 域向 X 域的一对生成网络,二者共享权重参数。SCycleGAN 模型将来自 X 域的图像 x 传递到生成网络 G ,生成图像 $F(G(x))$,然后再将图像 $G(x)$ 输入到另一个生成网络 F ,通过 F 实现

将 x 再迁移回符合 X 域特征分布的图像 $F(G(x))$ 。此外,SCycleGAN 模型中还设置了两个相应的判别网络 D_X 和 D_Y 进行对抗训练;其中, D_X 判别图像是来自 X 域的真实图像 x 还是由生成网络所生成的图像 $F(G(x))$ 。当 $F(G(x)) \approx x$ 时,即生成图像越来越逼近真实图像,判别网络达到纳什均衡点。随着网络不断训练,SCycleGAN 网络的特征迁移能力越强,即 SCycleGAN 网络能够准确地将遥感图像中同一类地物用相同颜色标识,不同类地物用不同颜色标识,同理,如果是将 Y 域图像迁移到 X 域,过程与前面类似。通过特征迁移,帮助网络提取到更高层、

更稳定的语义边缘特征。

在图像匹配模块中,对于特征迁移后的图像先提出随机采样一致性(random sample consensus, RANSAC)约束进行图像误匹配点剔除,再采用快速最近邻搜索(fast nearest-neighbor search, FLANN)算法实现特征匹配,并将 TMRL 作为匹配算法的损失函数, TMRL 中所有匹配项的检测得分用来生成距离因子的加权平均值。为了使损失最小化,具有较低的距离因子的最相关的对应关系,将获得较高的相对得分,并让具有较高相对得分的对应关系与其余特征不同的相似描述符,提高匹配的稳健性。




图 1 异源遥感影像匹配算法原理示意图

Fig. 1 Schematic diagram of the principle of heterogeneous remote sensing image matching algorithm

2.2 损失函数

本文特征迁移模型由损失函数生成对抗损失和循环一致性损失两部分构成,生成对抗损失函数主要用于欺骗判别网络,使生成的图像与原图尽可能相似;循环一致性损失防止生成网络所学习到的映射关系相互矛盾。

原始 CycleGAN 生成网络所采用的内容损失是 MSE 损失函数,当训练数据中存在离群样本时, MSE 会导致反向传播梯度更新较大,造成网络模型收敛困难、稳定性差的问题。因此本文选用 SmoothL₁ 损失^[18]代替 MSE 损失,作为 SCycleGAN 生成网络 G, F 的图像内容损失函数。SmoothL₁ 损失函数定义如下:

$$\text{SmoothL}_1(x, y) = \begin{cases} a(x - y)^2, & \text{当 } |x - y| < 1 \\ |x - y| - b, & \text{其他} \end{cases}, \quad (1)$$

式中, x 为真实样本, y 为预测样本。在训练开始时,

网络梯度更新较大, SmoothL₁ 损失函数给予梯度变量一定约束 α , 提高网络模型稳定性;当梯度更新趋于平缓时, SmoothL₁ 损失函数调整参数 β 适当放大梯度变量,加速网络收敛。 α, β 取值范围是 $(0, 1)$, 本文设置 $\alpha = \beta = 0.5$ 。

生成网络 G 和其相应的判别网络 D_Y 生成对抗损失可表示为:

$$L_{\text{SmoothL}_1 \text{GAN}}(G, D_Y, X, Y) = E_{y \sim P_{\text{data}}(Y)} [\log D_Y(y)] + E_{x \sim P_{\text{data}}(X)} [\log(1 - D_Y(G(x)))] \quad (2)$$

生成网络 G 用来生成图像 $G(x)$, 判别网络 D_Y 用来区分生成图像 $G(x)$ 与 Y 域中真实样本 y 。 D_Y 输出为 1 时,代表判别网络认为图像来自 Y ; D_Y 输出为 0 时,代表判别网络认为图像来自 X 域。

同理生成网络 F 和其相应的判别网络 D_X 生成对抗损失可表示为:

$$L_{\text{SmoothL}_1 \text{GAN}}(F, D_X, X, Y) = E_{x \sim P_{\text{data}}(X)} [\log D_X(x)] + E_{y \sim P_{\text{data}}(Y)} [\log(1 - D_X(F(y)))] \quad (3)$$

由于单向训练生成网络 G, F 并不稳定, 为了更好地获得 $X \rightarrow Y, Y \rightarrow X$ 的映射, 借鉴了原始 CycleGAN 的思路, 在训练中增加循环一致性损失约束, 定义循环一致性损失如下:

$$L_{\text{cyc}}(G, F) = E_{x \sim P_{\text{data}}(x)} [\|F(G(x)) - x\|_1] + E_{y \sim P_{\text{data}}(y)} [\|G(F(y)) - y\|_1]. \quad (4)$$

对于样本 x , 需要满足式 $F(G(x)) \approx x$; 同理, 对于样本 y , 则需要满足式 $G(F(y)) \approx y$ 。

综上, SCycleGAN 的整体损失函数表示为:

$$L(G, F, D_X, D_Y) = L_{\text{SmoothL}_1 \text{GAN}}(G, D_Y, X, Y) + L_{\text{SmoothL}_1 \text{GAN}}(F, D_X, X, Y) + \lambda L_{\text{cyc}}(G, F), \quad (5)$$

式中, λ 表示 G 和 F 的相对重要性的平衡参数, 取值范围是 $(0, 1)$, 本文设置为 0.05。最终, SCycleGAN 网络模型的对抗训练的优化目标如下式所示:

$$G^*, F^* = \arg \min_{G, F} \max_{D_X, D_Y} L(G, F, D_X, D_Y), \quad (6)$$

式中, G^* 和 F^* 分别表示对 SCycleGAN 网络模型进行训练得到的结果。

2.3 三元组距离排序损失函数

在无监督学习中, 使用较多的是对比损失作为排序函数。对比损失的核心是使得待匹配图像对 (I_1, I_2) 的相似点 A 和不同点 B 之间的欧式距离 $c: A \leftrightarrow B$ 分别达到最小和最大, 其中 $A \in I_1, B \in I_2$ 。如果两个点是不同的, 对比损失会将两个点推向相反的方向。一旦其中一个点已经处于集群的中心, 那么由对比损失计算得到的解决方案自然也不是最优的。

为保证提取的特征能够减小多模态遥感图像造成的差异, 需要特征尽可能具有独特性, 以便寻找同一区域不同模态遥感图像的同名像点, 本文采用了 TMRL^[10] 作为匹配算法的损失。定义一个三元组

(A, B, N) , 其中 (A, B) 属于正类描述符, (A, N) 属于负类描述符。正类描述符距离 $p(c)$ 计算式如下:

$$p(c) = \|\hat{d}_A^{(1)} - \hat{d}_B^{(2)}\|_2. \quad (7)$$

负类描述符距离 $n(c)$ 计算式如下:

$$n(c) = \min(\|\hat{d}_A^{(1)} - \hat{d}_{N_2}^{(2)}\|_2, \|\hat{d}_{N_1}^{(1)} - \hat{d}_B^{(2)}\|_2). \quad (8)$$

综上, TMRL 定义如下:

$$L(I_1, I_2) = \sum_{c \in C} \frac{s_c^{(1)} s_c^{(2)}}{\sum_{q \in C} s_q^{(1)} s_q^{(2)}} m(p(c), n(c)), \quad (9)$$

式中, $s_c^{(1)}$ 和 $s_c^{(2)}$ 为在影像 I_1 和 I_2 上 A, B 两个点处得到的特征检测得分; C 是影像 I_1 和 I_2 上所有同名像点的集合。TMRL 所有匹配项的检测得分用来生成距离因子 m 的加权平均值。

3 实验结果与分析

3.1 实验平台设置与数据集说明

本文实验平台为配备了 3 块英伟达 GTX1080Ti GPU 的深度学习服务器, 操作系统为 ubuntu16.04, 采用开源深度学习框架 PyTorch1.7, CUDA 版本是 8.0。

实验选用了原始 CycleGAN 中的风格迁移数据集^[14], 由纽约城市的航拍图像和谷歌标准地图组成, 记为 trainA 和 trainB。trainA 包含 1 098 张图像, trainB 是一一对应的纽约城市谷歌标准地图, 同为 1 098 张, 每张图片的大小为 256×256 pixel, 由于两种图像特征差异较大, 因此适用于本文的异源遥感图像特征迁移与匹配实验。图像示例如图 2 所示。




图2 实验数据集: 第一行是纽约城市可见光航拍图像, 第二行是与之对应的谷歌标准地图
Fig. 2 Experimental dataset: The first row is a visible light aerial image of a certain area in New York City, and the second row is the corresponding Google standard map

3.2 评价指标

实验采用正确匹配点数量(number of correct match, NCM)、匹配准确率(SR)来评价算法性能^[11]。各项指标说明如下。

1) NCM

参考图像上通过算法匹配算出特征点坐标 x_i , 与真实图像的理论点坐标 y_i 之间像素距离如果小于给定的精度阈值 ϵ , 则认为是正确匹配点, 本文 ϵ 设置为 3 个像素。正确匹配点判断如下所示:

$$\text{Corr}(x): \|x_i - y_j\| \leq \epsilon. \quad (10)$$

正确匹配点的数量为整幅遥感图像上满足上述条件的所有匹配点对的数量。影像配准等其他应用对正确匹配点的数量都有一定要求, 该指标可以反

映匹配算法的性能。

2) SR

准确率表达为满足式(10)的正确匹配点数占算法给出的所有匹配点数(NTP)的百分比, 这个指标可以反映出算法得到的匹配点对成功率。

3.3 实验结果

为验证 SCycleGAN 网络的异源遥感图像特征迁移性能, 本文设置原始 CycleGAN 和 SCycleGAN 分别对同一组遥感图像进行特征迁移, 结果如图 3 所示: 第 1 列是遥感图像, 第 2 列是谷歌标准地图, 第 3 列和第 4 列分别是原始 CycleGAN 和 SCycleGAN 的特征迁移结果。

对比图 3 的特征迁移结果, 可以看出本文改进




图 3 CycleGAN 损失函数改进前后特征迁移结果对比

Fig. 3 Comparison of feature migration results before and after the improvement of CycleGAN loss function

后的 SCycleGAN 模型能够将遥感图像中显著的地表区域, 如建筑、道路、草地等具有语义信息的地表边缘清晰、准确地表示出来, 大幅提高了特征迁移结果的精度。SCycleGAN 在迁移过程中没有特定保留某一特定类别(道路、水体、建筑等类别)的边缘信息, 而是训练网络模型自主学习遥感图像中鲁棒性较强的语义边缘特征, 从而实现准确、有效的异源遥感图像地表边缘等稳定特征提取, 为后续的匹配工作奠定基础。

本文还进行了异源遥感影像匹配实验, 通过对比 CMM-Net 方法^[11]与本文方法在 NTP、NCM、SR 以及匹配耗时的 4 个指标结果, 进行匹配性能分析, 匹配精度如表 1 所示。从实验数据集中随机采样得到 500 张遥感图像, 并将其分为 5 个小组, 每组 100

张图像, 编号为 1-5。通过设置 CMM-Net 方法对 5 组遥感图像不进行特征迁移, 直接与标准地图进行异源遥感图像匹配; 而本文方法对 5 组遥感图像先采取 SCycleGAN 网络模型进行特征迁移, 再采用 FLANN 方法进行匹配, 并对比两种方法的匹配结果。

对比分析表 1 数据可知, 本文方法在降低图像平均所需匹配点数的同时, 将平均匹配准确率从 32.13% 提高到 65.64%, 同时将匹配时间从 0.654 s 缩短为 0.581 s, 图 4 直观显示了 CMM-Net 与本文方法的匹配效果。异源遥感影像差异较大, CMM-Net 采取“以多求可靠”的策略, 训练网络模型提取较多的候选特征提升匹配的准确率, 同时也造成了匹配时间较长, 单次无法处理大幅影像的问题, 对 GPU

(graphic processing unit)要求较高。而本文方法不仅将匹配时间缩短了 11.17%,提高匹配效率,还通过 SCycleGAN 将不同模态的遥感图像迁移到同一

模态下,有效提取异源遥感影像中的包含丰富语义信息的显著边缘特征,降低误匹配点数,进一步提高异源遥感图像的匹配准确率。

表 1 异源遥感影像匹配精度对比
Tab.1 Comparison of matching accuracy of heterogeneous remote sensing images

	CMM-Net matching result						Ours matching result					
	1	2	3	4	5	Mean	1	2	3	4	5	Mean
NCM	263	78	185	187	257	194	71	16	59	56	55	51 ↓
NTP	584	393	676	640	648	588	95	25	87	87	96	78 ↓
SR/%	45.03	19.84	27.37	28.75	39.66	32.13	74.73	64.0	67.82	64.37	57.29	65.64 ↑
Time consuming/s	0.694	0.565	0.656	0.677	0.676	0.654	0.578	0.561	0.578	0.616	0.574	0.581 ↓




图 4 异源遥感影像匹配结果
Fig.4 Heterogeneous remote sensing image matching results

4 结 论

本文提出一种基于循环生成对抗策略的遥感图像匹配算法,设计 SmoothL₁ 损失替代原始 CycleGAN 中 MSE 损失,提高网络模型对于离群样本的抗干扰能力和泛化能力;在匹配算法中加入 TM-RL 损失函数,降低误匹配点数,提高匹配算法的准确率。实验结果表明,本文方法对异源遥感图像中不同地表类型的语义边缘特征保留更加完整,有效提取异源遥感影像中的包含丰富语义信息的显著边缘特征,从而降低误匹配点数,实现异源遥感影像的有效匹配。本文方法在智能飞行器对地认知、地表智能监测、区域变化等领域具有重要应用价值。

参考文献:

[1] QU Y,LI A G,XU W,et al. Research on multi sensor hybrid tracking registration for ArGIS[J]. Geomatics & Spatial Information Technology,2017,40(3):114-117.
曲毅,李爱光,徐旺,等.面向 ArGIS 的多传感器混合跟踪注册研究[J].测绘与空间地理信息,2017,40(3):114-117.

[2] CHI Y P,LIU C. An improved SIFT algorithm for SAR image registration[J]. Journal of University of Chinese Academy of Sciences,2019,36(2):259-266.
迟英朋,刘畅.一种适用于 SAR 图像配准的改进 SIFT 算法[J].中国科学院大学学报,2019,36(2):259-266.

[3] WU Q H. Template matching algorithm based on improved

- SURF feature points[J]. *Mechatronic Engineering Technology*, 2021, 50(6): 208-211.
- 吴清辉. 基于改进 SURF 特征点的模板匹配算法[J]. *机电工程技术*, 2021, 50(6): 208-211.
- [4] LIANG Y, LIU L, YING X, et al. Multi-task GLOH feature selection for human age estimation [C]//International Conference on Image Processing, September 11-14, 2011, Brussels, Belgium. New York: IEEE, 2011: 565-568.
- [5] YAN L, WANG Z Q, YE Z Y. Multimodal image registration algorithm considering grayscale and gradient information [J]. *Acta Geodaetica et Cartographica Sinica*, 2018, 47(1): 71-81.
- 闫利, 王紫琦, 叶志云. 顾及灰度和梯度信息的多模态影像配准算法[J]. *测绘学报*, 2018, 47(1): 71-81.
- [6] LI J, HU Q, AI M. RIFT: Multi-modal image matching based on radiation-variation insensitive feature transform [J]. *IEEE Transactions on Image Processing*, 2020, 29: 3296-3310.
- [7] YI K M, TRULLS E, LEPETIT V, et al. LIFT: learned invariant feature transform [C]//European Conference on Computer Vision. October 8-16, 2016, Amsterdam, The Netherlands. Cham, Switzerland: Springer, 2016: 467-483.
- [8] DETONE D, MALISIEWICZ T, RABINOVICH A. SuperPoint: self-supervised interest point detection and description [EB/OL]. (2017-12-20) [2021-12-03]. <https://arxiv.org/abs/1712.07629>.
- [9] NOH H, ARAUJO A, SIM J, et al. Large-scale image retrieval with attentive deep local features [EB/OL]. (2016-12-19) [2021-12-04]. <https://arxiv.org/abs/1612.06321>.
- [10] DUSMANU M, ROCCO I, PAJDLA T, et al. D2-Net: a trainable CNN for joint description and detection of local features [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE, 2019: 8084-8093.
- [11] LAN C Z, LU W J, YU J M, et al. Deep learning algorithm for feature matching of cross modality remote sensing images [J]. *Acta Geodaetica et Cartographica Sinica*, 2021, 50(2): 189-202.
- 蓝朝桢, 卢万杰, 于君明, 等. 异源遥感影像特征匹配的深度学习算法[J]. *测绘学报*, 2021, 50(2): 189-202.
- [12] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. *Advances in Neural Information Processing Systems*, 2014, 3: 2672-2680.
- [13] JOHNSON J, ALAHI A, FEI-FEI L. Perceptual losses for real-time style transfer and super-resolution [C]//European Conference on Computer Vision (ECCV), October 11-14, 2016, Amsterdam, The Netherlands. Cham: Springer, 2016: 694-711.
- [14] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C]//IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE, 2017: 2242-2251.
- [15] KIM T, CHA M, KIM H, et al. Learning to discover cross-domain relations with generative adversarial networks [C]//33th International Conference on Machine Learning (ICML), August 6-11, 2017, Sydney, NSW, Australia. Princeton: IMLS, 2017: 1857-1865.
- [16] WU Z, HAN X, LIN Y L, et al. DCAN: dual channel-wise alignment networks for unsupervised scene adaptation [C]//European Conference on Computer Vision (ECCV), September 8-14, 2018, Munich, Germany. Cham, Switzerland: Springer, 2018: 535-552.
- [17] LIU Z D, DAI Z X, LI C M, et al. A fast fusion object determination method for multi-path video and three-dimensional GIS scene [J]. *Acta Geodaetica et Cartographica Sinica*, 2020, 49(5): 632-643.
- 刘振东, 戴昭鑫, 李成名, 等. 三维 GIS 场景与多路视频融合的对象快速确定法 [J]. *测绘学报*, 2020, 49(5): 632-643.
- [18] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149.

作者简介:

唐浩漾 (1975—), 男, 博士, 副教授, 硕士研究生导师, 主要从事智能信息处理、计算机视觉与机器学习、智能仪器与传感器技术等方面的研究。