



## 自适应时空正则化的相关滤波目标跟踪

姜文涛, 孟庆姣

引用本文:

姜文涛, 孟庆姣. 自适应时空正则化的相关滤波目标跟踪[J]. 智能系统学报, 2023, 18(4): 754–763.

JIANG Wentao, MENG Qingjiao. Correlation filter tracking for adaptive spatiotemporal regularization[J]. *CAAI Transactions on Intelligent Systems*, 2023, 18(4): 754–763.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202202030>

## 您可能感兴趣的其他文章

### 区域损失函数的孪生网络目标跟踪

Regional loss function based siamese network for object tracking

智能系统学报. 2020, 15(4): 722–731 <https://dx.doi.org/10.11992/tis.201910005>

### 基于特征融合及自适应模型更新的相关滤波目标跟踪算法

Correlation filter target tracking algorithm based on feature fusion and adaptive model updating

智能系统学报. 2020, 15(4): 714–721 <https://dx.doi.org/10.11992/tis.201803036>

### 一种自适应模板更新的判别式KCF跟踪方法

Adaptive template update of discriminant KCF for visual tracking

智能系统学报. 2019, 14(1): 121–126 <https://dx.doi.org/10.11992/tis.201806038>

### 高斯核函数卷积神经网络跟踪算法

Convolutional neural network tracking algorithm accelerated by Gaussian kernel function

智能系统学报. 2018, 13(3): 388–394 <https://dx.doi.org/10.11992/tis.201612040>

### 基于改进型BP神经网络的手部动作识别

Hand-motion recognition based on improved BP neural network

智能系统学报. 2018, 13(5): 848–854 <https://dx.doi.org/10.11992/tis.201703018>

### 基于卷积特征和贝叶斯分类器的人脸识别

Face recognition based on convolution feature and Bayes classifier

智能系统学报. 2018, 13(5): 769–775 <https://dx.doi.org/10.11992/tis.201706052>

DOI: 10.11992/tis.202202030

网络出版地址: <https://kns.cnki.net/kcms/detail/23.1538.TP.20230317.1339.002.html>

# 自适应时空正则化的相关滤波目标跟踪

姜文涛, 孟庆姣

(辽宁工程技术大学软件学院, 辽宁 葫芦岛 125105)

**摘要:** 针对正则化滤波器预先定义正则化项, 但无法实时抑制非目标区域学习的缺点, 提出了一种自适应时空正则化的新方法, 从而提高算法在目标跟踪过程中适应外观变化的鲁棒性。首先在目标函数中引入空间局部响应变化量, 使滤波器专注于学习对象中值得信任的部分, 从而得到响应模型; 其次根据全局响应变化决定滤波器的更新率; 最后引入卷积神经网络进行深度特征提取, 为减少高维数据存储空间过大, 采用主成分分析算法进行降维处理, 既保留主要特征又加快计算速度。在数据集 OTB2013 和 OTB2015 上的平均精确率和平均成功率相较于时空正则化相关滤波器算法分别提高了 4.7% 和 12.7%。大量实验证明, 该算法在复杂背景、物体遮挡、快速运动等多种场景下基本满足实时性需求。

**关键词:** 时空自适应; 局部响应; 全局响应; 神经网络; 卷积神经网络; 特征提取; 降维; 主成分分析算法

**中图分类号:** TP391.4    **文献标志码:** A    **文章编号:** 1673-4785(2023)04-0754-10

中文引用格式: 姜文涛, 孟庆姣. 自适应时空正则化的相关滤波目标跟踪 [J]. 智能系统学报, 2023, 18(4): 754-763.

英文引用格式: JIANG Wentao, MENG Qingjiao. Correlation filter tracking for adaptive spatiotemporal regularization[J]. CAAI transactions on intelligent systems, 2023, 18(4): 754-763.

## Correlation filter tracking for adaptive spatiotemporal regularization

JIANG Wentao, MENG Qingjiao

(School of Software, Liaoning Technical University, Huludao 125105, China)

**Abstract:** The regularization filter defines the regularization term in advance, but it can not suppress the learning of non-target region in real time. Aiming at this shortcoming, a new adaptive spatiotemporal regularization method is proposed to improve robustness of the algorithm to adapt to appearance change in the process of target tracking. The method firstly introduces the spatial local response variation into the objective function, so that the filter can focus on the trusted part of the learning object, obtaining the response model. Then, the update rate of the filter is determined based on the change of global response. Finally, the convolutional neural network is introduced for deep feature extraction. In order to reduce the storage capacity of high-dimensional data, the principal component analysis algorithm is employed to reduce dimension, which not only retains the main features, but also speeds up the calculation. Comparing with the spatial-temporal regularized correlation filtering algorithms, the average accuracy and success rate of data sets OTB2013 and OTB2015 are respectively increased by 4.7% and 12.7%. A large number of experiments show that the algorithm basically meets the real-time requirements in complex background, object occlusion, fast motion and other scenes.

**Keywords:** spatiotemporal adaptation; local response; global response; neural network; convolutional neural network; feature extraction; dimension reduction; principal component analysis algorithm

视觉目标跟踪作为计算机视觉领域的一个重要研究问题<sup>[1]</sup>, 结合了数学经典算法<sup>[2]</sup>、人工智能、目标检测<sup>[3]</sup>等领域的先进思想, 已在现实生

活中得到广泛应用。近年来, 许多学者在相关滤波的速率和精度方面潜心钻研, 更优质高效的算法被广泛认可并加以应用。2010 年 Bolme 等<sup>[4]</sup>首次将相关滤波(correlation filters, CF)引入目标跟踪, 旨在利用相关的概念衡量信号的相似度, 将卷积算子由空域转换到频域, 提出了最小输出平方和误差滤波跟踪算法(minimum output sum of

收稿日期: 2022-02-28. 网络出版日期: 2023-03-19.

基金项目: 国家自然科学基金项目(61172144); 辽宁省自然科学基金项目(20170540426); 辽宁省教育厅基金项目(LJYL049).

通信作者: 姜文涛. E-mail: 704123343@qq.com.

squared error, MOSSE), 因为采用单通道的灰度特征, 只能局部提取部分信息, 不能跟踪完整的图像。2012年Henriques等<sup>[5]</sup>提出核循环结构算法, 使用循环矩阵作用于样本区域, 对图像进行循环采样, 提高了特征信息的完整性。2014年Henriques等<sup>[6]</sup>提出了核相关滤波算法(kernelized correlation filters, KCF), 采用梯度直方图特征, 并在岭回归中加入高斯核, 实现非线性到空间线性, 提高计算速率。2014年, Danelljan等<sup>[7]</sup>提出了判别型尺度空间跟踪算法, 利用2个独立的滤波器分别进行位置确定与尺度评估, 采用不同的特征种类, 自适应地实现目标定位。2016年, Bertinetto等<sup>[8]</sup>提出背景直方图目标跟踪算法(Staple算法), 该算法结合梯度直方图和颜色直方图2种特征, 但非刚性运动效果不好, 实用性较弱。综上所述, 跟踪目标的运动状态出现速度骤变和快速形变的状况时, 边界效应的问题随之产生。为解决上述问题, 2015年, Galoogahi等<sup>[9]</sup>提出有规定边界的相关滤波器算法, 用于训练和检测的图像块过大, 且训练样本有限, 过度拟和学习模型, 导致准确性降低。2015年, Danelljan等<sup>[10]</sup>提出固定空间正则化项的相关性过滤器(learning spatially regularized correlation filters for visual tracking, SRDCF), 设置空间权重系数, 给予目标区域较大权重和边缘区域较小权重, 但记录每一帧的样本信息, 并不适合实现目标的实时跟踪。2017年, Mueller等<sup>[11]</sup>提出上下文感知的相关滤波算法, 记录作为正样本的目标与4个方向作为负样本的背景块的信息, 实现改进相关滤波算法框架的目的。2018年, Li等<sup>[12]</sup>在SRDCF的基础上加入时间正则化, 提出了具有固定的时空正则化项的相关性过滤器(learning spatial-temporal regularized correlation filters for visual tracking, STRCF), 权重矩阵的引入使得该算法相较于其他跟踪算法, 在目标出现快速运动和形变时体现出良好的鲁棒性。

尽管STRCF已经取得了令人满意的性能, 但它确实有2个局限性: 固定的空间正则化无法适应跟踪场景中的外观变化, 不变的时间惩罚强度不适用于非目标区域。因此, 本文为解决上述问题, 在目标函数中, 根据相邻两帧局部变化的可信度判断滤波器学习的像素, 运动影响消除后结合空间惩罚缓解边界效应, 既可以在边界进行完整的信息采样, 又可以明确跟踪学习的特征信息, 实现利用局部和全局响应变化进行空间和时间同时正则化的目的, 重新设定自适应参数, 将

跟踪训练得到的响应模型作用于目标区域, 从而明确待学习的特征样本, 进而得到一个更加强壮的外观模型。在不同数据集上对本文算法进行精确率、成功率和实时性等多方面评估, 实验表明, 相较于其它主流的跟踪算法, 本文算法具有较高的鲁棒性。

## 1 时空正则化相关滤波算法原理

时空正则化相关滤波算法通过在目标函数中加入权重矩阵 $\mathbf{u}$ 和时间感知项, 结合空间和时间正则化, 能够在有效处理边界效应的同时, 提高跟踪的速度与性能。

通过最小化以下目标函数学习第 $t$ 帧中的最佳滤波器:

$$\varepsilon(H^t) = \frac{1}{2} \left\| \mathbf{y} - \sum_{k=1}^K \mathbf{x}'_k * \mathbf{h}'_k \right\|_2^2 + \frac{1}{2} \sum_{k=1}^K \|\mathbf{u} \cdot \mathbf{h}'_k\|_2^2 + \frac{\theta}{2} \sum_{k=1}^K \|\mathbf{h}'_k - \mathbf{h}'_{k^{t-1}}\|_2^2 \quad (1)$$

式中: 符号 $*$ 表示卷积运算;  $\mathbf{x}'_k \in \mathbf{R}^{T \times 1}$  ( $k = 1, 2, \dots, K$ ) 表示在 $t$ 帧中提取出的特征样本,  $K$ 为每帧图片的通道数;  $\mathbf{y} \in \mathbf{R}^{T \times 1}$ 为理想的相关响应值,  $T$ 代表矩阵维度;  $\mathbf{H} = [\mathbf{h}'_1 \mathbf{h}'_2 \dots \mathbf{h}'_K]$ ,  $\mathbf{h}'_k \in \mathbf{R}^{T \times 1}$ 为第 $t$ 帧训练的第 $k$ 通道的滤波器。STRCF算法引用SRDCF算法中的空间正则项 $\frac{1}{2} \sum_{k=1}^K \|\mathbf{u} \cdot \mathbf{h}'_k\|_2^2$ , 其中 $\mathbf{u}$ 为负高斯形状的空间权重向量, 使正则化权重从目标区域平稳地过渡到背景区域, 并且增加了权重矩阵在傅里叶域中的稀疏性。引入时间正则项, 其中 $\theta$ 为系数,  $\mathbf{h}'$ 和 $\mathbf{h}'^{t-1}$ 表示当前帧和上一帧训练的滤波器。

STRCF采用固定的空间权重向量, 有效地缓解了边界效应, 但负高斯形状忽视了边界区域样本信息的完整性。当跟踪目标被遮挡或者发生较大形变时, 是非目标区域无法实现自适应地分配权重, 就会导致跟踪失败。因此, 本文针对STRCF算法的空间权重问题, 提出了自适应时空正则化的相关滤波跟踪算法, 通过在目标函数中构造自适应时空正则项, 与样本信息建立联系, 从而提高算法的跟踪性能。

## 2 自适应时空正则化相关滤波算法

### 2.1 自适应时空正则化

在检测过程中, 响应图中的信息至关重要。因为其信息可以反映前一帧所学习到的外观模型和当前帧检测到的实际对象之间的相似性。所以, 本文采用响应变化来实现正则化。



首先,本文定义局部响应变化量,  $\sigma = (\sigma_1, \sigma_2, \dots, \sigma_i)$  用于对象边界框中的可视化。其第  $i$  个元素  $\sigma_i$  定义为

$$\sigma_i = \frac{R_i[\phi_\Delta] - R_i^{t-1}}{R_i^{t-1}} \quad (2)$$

式中:  $\phi_\Delta$  是在两个响应图  $R^t$  和  $R^{t-1}$  产生的两个峰值的位置差<sup>[13]</sup>,  $[\phi_\Delta]$  表示相邻峰值为达到高度相似而移动的距离。局部响应变化显示当前帧搜索区域中每个像素的可信度。当外观发生较大变化时导致  $[\phi_\Delta]$  的值变大, 因相似而移动的距离变大, 相似性低, 像素可信度低。在学习过程中, 应限制学习可信度低的像素, 本文通过将局部变化  $\sigma$  引入空间正则化参数  $\tilde{u}$  来实现这一点:

$$\tilde{u} = P^T \delta \log(\sigma + 1) + u \quad (3)$$

其中  $P^T \in \mathbf{R}^{T \times T}$  用于裁剪对象所在滤波器的中心部分, 将目标从背景模板中剪切出来, 从而提高样本质量并提高计算速度。  $\delta$  是一个常数, 用于调整局部响应变化的权重, 而  $u$  是从 STRCF 中继承来的权重向量, 用于缓解边界效应。局部响应变量反应了当前帧局部位置每个像素的可信度,  $\log(\sigma + 1)$

作为单调递增函数, 与  $\sigma$  的增减保持相同趋势, 放大  $\sigma$  的变化。通过式 (3), 将其引入到空间正则化参数中, 目标发生变化时, 滤波器将有选择地进行学习, 避免学习响应发生剧烈变化时的样本信息, 实现空间自适应。在 STRCF 中, 相邻两帧滤波器的变化率由一个固定参数  $\theta$  决定, 本文通过自适应确定参数的值, 进一步优化目标函数, 从而提高滤波器跟踪时的准确性, 定义参数  $\tilde{\theta}$  作为目标函数的全局响应:

$$\tilde{\theta} = \frac{1}{\|\sigma\|_2}, \quad \tilde{\theta} \leq \phi \quad (4)$$

引入欧几里德范数来比较  $R^t$  和  $R^{t-1}$  两个响应图的差异水平, 发生畸变时, 相似性会突然下降, 则  $\sigma_i$  的值会升高, 当全局响应变量高于阈值  $\phi$  时, 滤波器将停止学习。而当全局响应变量低于阈值时, 响应剧烈程度与  $\tilde{\theta}$  值成负相关, 进而判断是否进行滤波器的更新迭代, 实现时间自适应。如图 1, 利用空间局部和全局响应变化, 局部变化表示目标边界框中的局部可信度, 光照变化、部分遮挡和超出视野均会降低像素的可信度。




图 1 整体响应变化

Fig. 1 Global response variation

## 2.2 目标函数模型

STRCF 的函数模型在进行目标跟踪的过程中, 采取逐帧的方式更新外观模型和滤波器, 但在进行迭代的过程中, 无差别的学习将导致最终跟踪结果的不准确。针对上述问题, 本文采用更新后的目标函数模型。

$$\begin{aligned} \varepsilon(H^t, \theta_{\text{score}}^t) = & \frac{1}{2} \left\| y - \sum_{k=1}^K x_k^t * h_k^t \right\|_2^2 + \frac{1}{2} \sum_{k=1}^K \|\tilde{u} \cdot h_k^{t-1}\|_2^2 + \\ & \frac{\theta_{\text{score}}^t}{2} \sum_{k=1}^K \|h_k^t - h_k^{t-1}\|_2^2 + \frac{1}{2} \|\theta_{\text{score}}^t - \tilde{\theta}\|_2^2 \end{aligned} \quad (5)$$

式中:  $\theta$  和  $\theta_{\text{score}}^t$  分别表示参考和优化的时间正则化

参数,  $\tilde{u}$  表示通过式 (3) 计算得到的新的权重向量, 既缓解了边界效应, 又明确了样本中的学习区域, 实现了空间自适应的目的。外观变化时, 前后两帧的滤波器系数差别较大, 容易产生漂移, 被动地更新滤波器, 使其接近前一帧的滤波器系数, 达到减少漂移的目的。反之, 滤波器系数近乎一致, 可忽略最后一项, 主动地学习滤波器。本文通过局部响应和全局响应的迭代计算, 判断是否进行滤波器的更新, 从而实现了时间自适应性。

根据 Parseval 定理, 引入辅助变量,  $\hat{g}_k \in \mathbf{R}^{T \times K \times 1}$ ,  $\hat{G} = [\hat{g}_1 \ \hat{g}_2 \ \dots \ \hat{g}_K]$ , 符号  $\hat{\cdot}$  表示信号的离散傅里叶变

换,可将式(5)转化到频域:

$$\varepsilon(\mathbf{H}_k \theta'_{\text{score}} \hat{\mathbf{G}}_k) = \frac{1}{2} \left\| \mathbf{y} - \sum_{k=1}^K \hat{\mathbf{x}}_{k-1}^t \cdot \hat{\mathbf{h}}_k^{t-1} \right\|_2^2 + \frac{1}{2} \sum_{k=1}^K \left\| \tilde{\mathbf{u}} \cdot \mathbf{h}_k^{t-1} \right\|_2^2 + \frac{\theta'_{\text{score}}}{2} \sum_{k=1}^K \left\| \hat{\mathbf{g}}_k^t - \hat{\mathbf{g}}_{k-1}^{t-1} \right\|_2^2 + \frac{\theta}{2} \left\| \theta'_{\text{score}} - \tilde{\theta} \right\|_2^2 \quad (6)$$

式中:  $\hat{\mathbf{y}} = \sqrt{T} \mathbf{F} \mathbf{y}$ ,  $\hat{\mathbf{x}}_k = \sqrt{T} \mathbf{F} \mathbf{x}_k$ ,  $\hat{\mathbf{g}}_k = \sqrt{T} \mathbf{F} \mathbf{g}_k$  为傅里叶变换, 其中  $\mathbf{F} \in \mathbf{R}^{T \times T}$  为正交矩阵。

### 2.3 目标函数优化

式(6)为凸光滑可微函数, 可通过交替方向乘法法(ADMM)迭代求解, 降低算法复杂度的同时提高跟踪速度。方程的增广拉格朗日形式为

$$L_k(\mathbf{H}_k, \theta'_{\text{score}}, \hat{\mathbf{G}}_k, \hat{\mathbf{M}}_k) = \varepsilon(\mathbf{H}_k, \theta'_{\text{score}}, \hat{\mathbf{G}}_k) + \frac{\gamma}{2} \sum_{k=1}^K \left\| \hat{\mathbf{g}}_k^t - \sqrt{T} \mathbf{F} \mathbf{h}_k^t \right\|_2^2 + \sum_{k=1}^K (\hat{\mathbf{g}}_k^t - \sqrt{T} \mathbf{F} \mathbf{h}_k^t)^T \hat{\mathbf{m}}_k^t \quad (7)$$

式中:  $\hat{\mathbf{M}} = [\hat{\mathbf{m}}_1 \ \hat{\mathbf{m}}_2 \ \cdots \ \hat{\mathbf{m}}_K] \in \mathbf{R}^{T \times K}$  为拉格朗日乘子<sup>[14]</sup>,  $\gamma$  为步长参数, 上角标 $T$ 表示矩阵的共轭转置。

引入  $\mathbf{v}_k^t = \frac{1}{\gamma} \hat{\mathbf{m}}_k^t$ ,  $\mathbf{V} = [\mathbf{v}_1 \ \mathbf{v}_2 \ \cdots \ \mathbf{v}_K]$ , 式(7)可转化为

$$L'(\mathbf{H}_k, \theta'_{\text{score}}, \hat{\mathbf{G}}_k, \hat{\mathbf{M}}_k) = \varepsilon(\mathbf{H}_k, \theta'_{\text{score}}, \hat{\mathbf{G}}_k) + \frac{\gamma}{2} \sum_{k=1}^K \left\| \hat{\mathbf{g}}_k^t - \sqrt{T} \mathbf{F} \mathbf{h}_k^t + \hat{\mathbf{v}}_k^t \right\|_2^2 \quad (8)$$

通过使用 ADMM 算法<sup>[15]</sup>, 等式可被分解为  $\hat{\mathbf{G}}$ 、 $\theta'_{\text{score}}$ 、 $\mathbf{H}$  等 3 个子问题, 式(5)可通过对这 3 个子问题进行迭代解出最优解。

1) 求解  $\hat{\mathbf{G}}$ : 假设给定  $\mathbf{H}_k$ 、 $\theta'_{\text{score}}$ 、 $\hat{\mathbf{V}}_k$ 、 $\hat{\mathbf{G}} = [\hat{\mathbf{g}}_1 \ \hat{\mathbf{g}}_2 \ \cdots \ \hat{\mathbf{g}}_K]$ , 目标函数为

$$\hat{\mathbf{G}}^* = \arg \min \left\{ \frac{1}{2} \left\| \hat{\mathbf{y}} - \sum_{k=1}^K \hat{\mathbf{x}}_k^t \cdot \hat{\mathbf{g}}_k^t \right\|_2^2 + \frac{\theta'_{\text{score}}}{2} \sum_{k=1}^K \left\| \hat{\mathbf{g}}_k^t - \hat{\mathbf{g}}_{k-1}^{t-1} \right\|_2^2 + \frac{\gamma}{2} \sum_{k=1}^K \left\| \hat{\mathbf{g}}_k^t - \sqrt{T} \mathbf{F} \mathbf{h}_k^t + \hat{\mathbf{v}}_k^t \right\|_2^2 \right\} \quad (9)$$

由式(9)可以看出, 如果直接对  $\hat{\mathbf{g}}_k^t$  求导, 第 1 项的求和运算会增加较大的计算复杂度。由于  $\hat{\mathbf{x}}_k$  为稀疏带状变量, 并且  $\hat{\mathbf{y}}$  只依赖于  $\hat{\mathbf{x}}_k = [\hat{\mathbf{x}}_k^1 \ \hat{\mathbf{x}}_k^2 \ \cdots \ \hat{\mathbf{x}}_k^K]^T$  和  $\hat{\mathbf{g}}_k = [\text{conj}(\hat{\mathbf{g}}_k^1) \ \text{conj}(\hat{\mathbf{g}}_k^2) \ \cdots \ \text{conj}(\hat{\mathbf{g}}_k^K)]^T$  中的元素, 其中  $\text{conj}(\cdot)$  表示复共轭运算, 所以可以考虑通过单独计算  $\hat{\mathbf{y}}$  中的元素即  $\hat{\mathbf{y}}_k (k=1, 2, \dots, K)$  来简化计算。记  $\zeta_j(\hat{\mathbf{G}}) \in \mathbf{R}^{K \times 1}$ , 表示在像素  $j$  上  $\hat{\mathbf{x}}$  的所有  $K$  通道值的向量, 解:

$$\zeta_j^*(\hat{\mathbf{G}}^t) = \arg \min \left\{ \left\| \hat{\mathbf{y}}_j - \zeta_j(\hat{\mathbf{X}}^t) \zeta_j(\hat{\mathbf{G}}^t) \right\|_2^2 + \left\| \zeta_j(\hat{\mathbf{G}}^t) + \zeta_j(\hat{\mathbf{V}}^t) - \zeta_j(\sqrt{T} \mathbf{F} \mathbf{H}^t) \right\|_2^2 + \theta'_{\text{score}} \left\| \zeta_j(\hat{\mathbf{G}}^t) - \zeta_j(\hat{\mathbf{G}}^{t-1}) \right\|_2^2 \right\} \quad (10)$$

式(10)时间复杂度为  $O(TK^3)$ , 使用 Sherman-Morrison 公式推导后, 其解可以转化为

$$\zeta_j^*(\hat{\mathbf{G}}^t) = \frac{1}{\gamma T + \theta'_{\text{score}}} \left( I - \frac{\zeta_j(\hat{\mathbf{X}}^t) \zeta_j(\hat{\mathbf{X}}^t)^T}{\theta'_{\text{score}} + \gamma T + \zeta_j(\hat{\mathbf{X}}^t)^T \mathbf{v}_j(\hat{\mathbf{X}}^t)} \right) \rho$$

其中,  $\rho = \zeta_j(\hat{\mathbf{X}}^t) \mathbf{y}_j + \theta'_{\text{score}} \zeta_j(\hat{\mathbf{G}}^{t-1}) - \gamma \zeta_j(\hat{\mathbf{V}}^t) + \gamma \zeta_j(\sqrt{T} \mathbf{F} \mathbf{H}^t)$ 。此时的时间复杂度为  $O(TK)$ , 显著地缩短了程序计算的时间。

2) 求解  $\mathbf{H}$ : 假设给定  $\theta'_{\text{score}}$ 、 $\hat{\mathbf{G}}^t$ 、 $\hat{\mathbf{V}}^t$ 、 $\mathbf{H} \in \mathbf{R}^{T \times 1}$ , 其  $\mathbf{h}_k$  优化可以表示为

$$\arg \min \left\{ \frac{1}{2} \left\| \tilde{\mathbf{u}} \cdot \mathbf{h}_k^t \right\|_2^2 + \frac{\gamma}{2} \left\| \hat{\mathbf{g}}_k^t - \sqrt{T} \mathbf{F} \mathbf{h}_k^t + \hat{\mathbf{v}}_k^t \right\|_2^2 \right\} \quad (11)$$

$\mathbf{h}_k$  的封闭解为

$$\mathbf{h}_k^* = [\tilde{\mathbf{U}}^T \tilde{\mathbf{U}} + \gamma T]^{-1} \gamma (\sqrt{T} \mathbf{F})^T (\mathbf{v}_k^t + \mathbf{g}_k^t) = \frac{\gamma T (\mathbf{v}_k^t + \mathbf{g}_k^t)}{(\tilde{\mathbf{u}} \cdot \tilde{\mathbf{u}}) + \gamma T} \quad (12)$$

式中  $\tilde{\mathbf{U}} = \text{diag}(\tilde{\mathbf{u}}) \in \mathbf{R}^{T \times T}$ 。由式(12)可以看出对  $\mathbf{h}_k$  的求解过程仅需逐元相乘和快速傅里叶<sup>[15]</sup>逆变换得到, 即  $\mathbf{v}_k = \frac{1}{\sqrt{T}} \mathbf{F}^T \hat{\mathbf{v}}_k$ ,  $\mathbf{g}_k = \frac{1}{\sqrt{T}} \mathbf{F}^T \hat{\mathbf{g}}_k$ 。所以, 对  $\mathbf{H}$  进行求解的时间复杂度为  $O(KT \lg T)$ 。

3) 求解优化的时间正则化参数  $\theta'_{\text{score}}$ :

给定式(8)中的其他变量  $\mathbf{H}$ 、 $\hat{\mathbf{G}}$ 、 $\hat{\mathbf{V}}$ , 对  $\theta'_{\text{score}}$  采用 ADMM 算法求  $\theta'_{\text{score}}$  的最优解可确定为

$$\theta'_{\text{score}} = \arg \min \left\{ \frac{\theta}{2} \sum_{k=1}^K \left\| \hat{\mathbf{g}}_k^t - \hat{\mathbf{g}}_{k-1}^{t-1} \right\|_2^2 + \frac{1}{2} \left\| \theta'_{\text{score}} - \tilde{\theta} \right\|_2^2 \right\} = \frac{\sum_{k=1}^K \left\| \hat{\mathbf{g}}_k^t - \hat{\mathbf{g}}_{k-1}^{t-1} \right\|_2^2}{\tilde{\theta} - \frac{1}{2}}$$

4) 拉格朗日乘子更新:

$$\hat{\mathbf{V}}^{i+1} = \hat{\mathbf{V}}^i + \tau (\hat{\mathbf{G}}^{i+1} - \hat{\mathbf{H}}^{i+1})$$

式中:  $i$  和  $i+1$  表示迭代次数;  $\hat{\mathbf{G}}^{i+1}$  和  $\hat{\mathbf{H}}^{i+1}$  表示在第  $(i+1)$  次迭代中, 式(6)子问题  $\hat{\mathbf{G}}$  和式(11)子问题  $\hat{\mathbf{H}}$  的解;  $\tau$  为更新参数。

$$\tau^{i+1} = \min(\tau_{\max}, \beta \tau^i)$$

式中:  $\beta = 10$ ,  $\tau^{\max} = 10\,000$ 。

### 2.4 目标定位

$$\mathbf{R}^t = \mathbf{F}^{-1} \sum_{k=1}^K (\hat{\mathbf{Z}}_k^t \cdot \hat{\mathbf{g}}_k^{t-1})$$

式中:  $\mathbf{R}^t$  为  $t$  帧响应图,  $\mathbf{Z}_k^t$  为  $t$  帧提取的特征映射的傅里叶<sup>[16]</sup>形式,  $\mathbf{g}_k^{t-1}$  表示第  $t-1$  帧中训练好的相关滤波器的傅里叶形式。跟踪目标的中心所在位置就是响应值数值最大处。

### 3 特征提取

针对图像高维特征占用巨大存储空间的问题,由于部分特征本身存在相关性,考虑利用卷积神经网络,获取更多图像信息,但是通过卷积神经网络(convolutional neural network, CNN)<sup>[17]</sup>提取的图像特征维数过高,加大了计算难度,所以本文采用一种特殊的方式——主成分分析<sup>[18]</sup>(principal component analysis, PCA)来处理提取的 CNN<sup>[19-21]</sup>特征,从而在降低计算复杂度的同时,保持信息准确性。

原始数据经线性变换,成为一组新的向量,各维度线性无关,只提取主特征分量。在面对图像大量高维数据时,利用数据本身存在的相关性进行降维<sup>[22]</sup>操作。在保证主要特征准确性的前提下,虽丢失少量信息,但减少了计算成本,从而提高了速度。

**输入** 样本集  $D = \{x_1, x_2, \dots, x_n\} \in \mathbf{R}^{m \times d}$ ; 低维空间维数  $d'$ 。

**过程:**

1) 对所有样本<sup>[23-25]</sup>进行中心化:  $\mathbf{x} = \mathbf{x}_i - \frac{1}{m} \sum_{i=1}^m \mathbf{x}_i$ ,

为了方便计算投影点的方差,可以通过各点与原点间距离之和来计算。

2) 计算样本的协方差矩阵:  $\mathbf{E} = \mathbf{X}\mathbf{X}^T$ , 在坐标上点到原点的距离用映射所得点与点间的方差来表示,即对原向量和投影向量两个向量点积的绝对值求和。

3) 对协方差矩阵  $\mathbf{E}$  的特征值  $\lambda_1, \lambda_2, \dots, \lambda_m$  分解,取最大的  $d'$  个特征值所对应的特征向量  $\omega_1, \omega_2, \dots, \omega_{d'}$ 。

**输出** 投影矩阵  $\mathbf{W} = [\omega_1 \ \omega_2 \ \dots \ \omega_{d'}]$

将问题转化为求  $\max_{\omega_1} \frac{1}{m} \omega_1^T \mathbf{X}\mathbf{X}^T \omega_1$ , 求得一个向量  $\omega_1$ , 使得  $\frac{1}{m} \omega_1^T \mathbf{X}\mathbf{X}^T \omega_1$  得到最大化, 最大值为  $\mathbf{X}\mathbf{X}^T$  的最大特征值, 向量  $\omega_1$  即为该特征值对应的特征向量, 主成分分析后数据保留的成分比例为  $\sum_{i=1}^{d'} \lambda_i / \sum_{i=1}^d \lambda_i$ , 其中  $d'$  为主成分个数。降维效果如图 2 所示。图 2(a) 中, 星号为高维空间的样本点, 而圆点是经过降维后的样本点。通过图像可以清晰地看出降维后仍保留了大量的主成分样本特征。图 2(b) 所示, 样本标记可以清楚地看出不同特征在降维后仍保持原样本空间的数据, 因此在算法中降维从而保留数据集中有效的信息, 对滤波器学习的性能影响甚小。

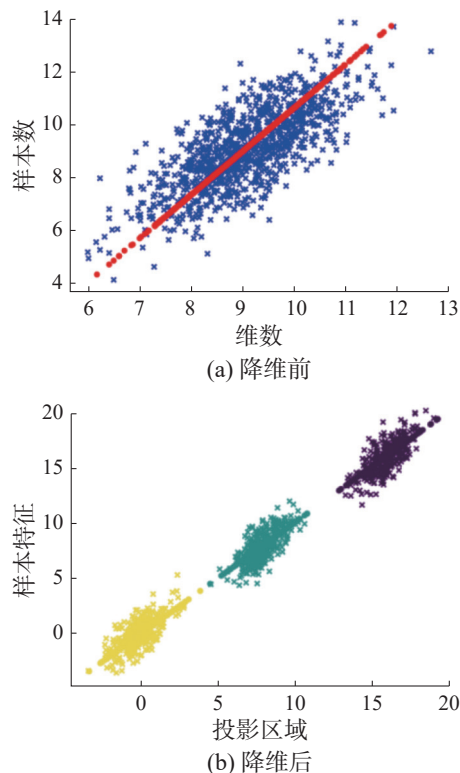


图 2 PCA 降维效果

Fig. 2 PCA dimension reduction effect diagram

### 4 算法步骤

自适应时空正则化的相关滤波目标跟踪算法步骤如下:

1) 初始帧建模: 初始帧中的目标区域经过裁剪得到, 使用 STRCF 算法中负高斯形状的权重对本文算法的空间正则项权重进行初始化。使用 CNN 提取特征, 训练相关滤波器, 建立目标模型和响应图模型。

2) 目标定位: 前一帧经过训练得到的相关滤波器, 作用于当前帧的目标区域, 提取特征的过程中, 使用 PCA 方法进行降维处理, 从而得到响应图, 目标中心位置即响应值最大处。

3) 权重更新: 采用式(3)更新自适应空间正则化, 并进行滤波器训练。

4) 模型更新: 对每一帧进行采样, 得到局部像素的可信度, 结合式(4)判定目标是否发生畸变, 选择是否学习, 采用式(6)动态更新目标模型和响应图模型。

5) 目标跟踪: 执行步骤 2), 针对下一帧图像进行滤波器训练并进行模型更新, 经过算法迭代即循环跟踪, 最终得到跟踪结果。

本文算法是基于时空正则化相关滤波算法进行改进, 因此选用 STRCF 算法作为基础框架。本文算法总体框架如图 3 所示。



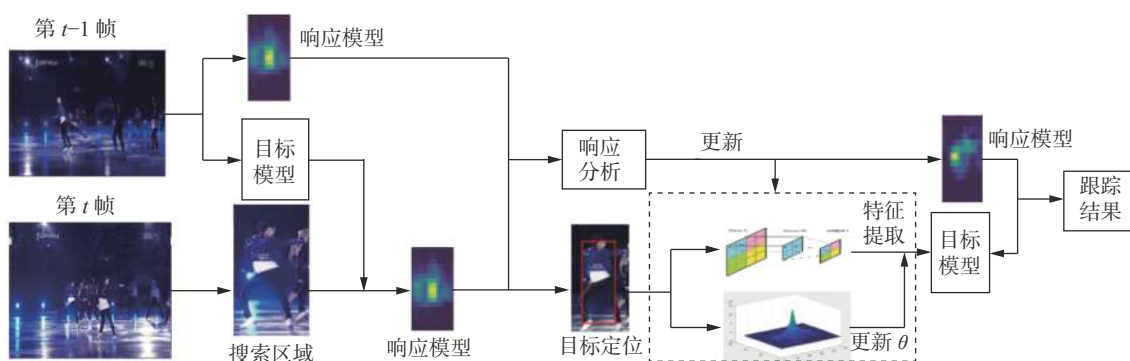


图3 算法总体框架示意

Fig. 3 Overall schematic diagram of the algorithm

## 5 实验验证与分析

本文所选用的编程软件为 Python.3.10, 实验操作系统为 mac OS Mojave 10.14.6, 处理器为 2.9 GHz Intel Core i7 CPU, 内存为 8 GB。

### 5.1 自适应时空正则化的相关滤波目标跟踪算法的对比实验

为了客观并且有针对性验证本文在 STRCF 基础上所提出的自适应时空正则化相关滤波目标跟踪算法框架的有效性, 本文与 6 种同类型算法进行对比实验, 分别是本文在目标函数中使用了预定义的基线算法 STRCF(2018), 以及引入高斯核提高计算速率并利用循环矩阵进行循环取样的 KCF(2014); 提高样本数量但减小搜索区域得到 BACF(2017); 引入时间正则项的 SRDCF(2016); 对于区域进行约束, 从而减少异常的 AR-

CF(2019); 采用局部响应减少对时间和空间限制的 AutoTrack(2020)。使用单次评价标准(OPE)综合衡量精确率、成功率和实时性等 3 项性能指标。在本实验中, 搜索区域选定边长为正方形区域, 使用 ADMM 算法进行迭代求解时, 迭代次数为 4; 在对自适应空间正则项权重初始化时, 参数  $\delta = 10$ ; 在模型更新时, 目标模型的学习参数  $\alpha$  为 0.02, 响应图模型的阈值  $\varphi = 3000$ 。其余参数与本文基线算法 STRCF 的参数设置相同。

### 5.2 定性分析

图 4 为数据集 OTB100 中具有遮挡和形变(DEF)、光影变化和背景杂乱(BC)、快速运动(FM)等不同属性视频序列的跟踪结果, 从图 4 中可以看出, 与其他对比算法相比, 本文算法的跟踪性能较优。



图4 各种算法在部分序列上的跟踪结果对比

Fig. 4 Comparison of tracking results of various algorithms on partial sequences

1) 遮挡和形变(DEF)。从图 4(a)可以看到, 在视频序列 Girl2\_1 中, 在第 105 帧之前各算法均可成功跟踪到目标, 在第 107~298 帧从出现遮挡到遮挡完全消失的过程中, SRDCF、KCF、AutoTrack 和 ARCF 算法均出现不同程度的漂移, 到第 358 帧时, 由于本文算法具有自适应的空间正则项, 背景区域的权重随目标变化而降低, 到第 717 帧仍可以进行有效跟踪。

2) 光照变化(IV)和背景杂乱(BC)。背景杂乱指背景信息与目标信息具有相对较高的相似度, 在进行信息特征提取时易混淆, 滤波器无法确定目标位置, 导致跟踪失败。从图 4(b)可以看到, 截止到第 458 帧, 7 种算法均可正确定位目标位置, 但第 458~509 帧由于背景信息相似度高和光照变化的同时影响, 导致 SRDCF、KCF、AutoTrack、BACF 和 ARCF 算法陆续跟踪失败。在第 517~518 帧时, 只有本文算法可以继续跟踪, 通过空间局部响应和全局响应的变化确定局部响应的

可信度, 有效地区分目标和背景信息, 有较高的精确率。

3) 快速运动(fast motion)。快速运动是目标在连续图像中运动区间大于 20 个像素。从图 4(c)序列明显发现, 面对跟踪目标快速运动时, 采用单一通道的 KCF 算法无法准确定位目标位置。在第 52~82 帧时, STRCF 出现漂移现象。到第 92 帧, BACF、ARCF 虽然采用多通道特征, 但由于跟踪目标在短时间内多次改变运动状态, 没有判定滤波器是否更新的权重, 导致跟踪失败。由于本文利用相邻两个峰值响应的相似度, 通过峰值的移位实现自适应降低目标模型更新率的目的, 使得该算法在快速运动的场景下具备较好的鲁棒性。

### 5.3 定量比较

7 种算法在不同数据集上的对比结果如表 1 所示, 加粗字体表示最优对比结果, 倾斜和下划线字体表示次优对比结果。

表 1 7 种算法在不同数据集上的对比实验结果

Table 1 Comparative experimental results of seven algorithms on different datasets

数据集	指标	本文算法	AutoTrack	STRCF	BACF	SRDCF	KCF	ARCF
OTB2013	成功率	<b>0.840</b>	0.766	0.810	<u>0.838</u>	0.757	0.623	0.768
	精确率	<b>0.861</b>	0.826	0.825	<u>0.860</u>	0.822	0.740	0.806
OTB2015	成功率	<b>0.786</b>	0.722	<u>0.783</u>	0.774	0.711	0.555	0.729
	精确率	<b>0.840</b>	0.794	<u>0.836</u>	0.823	0.779	0.701	0.782
DTB70	成功率	<b>0.438</b>	<u>0.436</u>	0.406	0.400	0.339	0.280	0.426
	精确率	<b>0.642</b>	0.631	0.587	0.593	0.435	0.468	<u>0.635</u>

从表 1 可以看出, 在数据集 OTB2013 和 OTB-2015 中, 本文算法的成功率和精确率均高于 STRCF 算法, 在数据集 DTB70 中, 该数据集为无人机拍摄, 本文算法的成功率和精确率也较高。本文算法是基于 STRCF 框架的算法, 通过表 2 和表 3 可

以看出其每种属性的精确率和成功率得分均高于 STRCF 算法。并且在数据集 OTB2013 和 OTB2015 上的平均精确率(0.87)和平均成功率(0.814)相比于 STRCF 算法的平均精确率(0.823)和平均成功率(0.787)分别提高了 4.7% 和 12.7%。

表 2 各种跟踪算法在数据集 OTB100 上各种属性的精确率得分

Table 2 Accuracy scores of various attributes of various tracking algorithms on dataset OTB100

OTB100	本文算法	STRCF	AutoTrack	BACF	SRDCF	KCF	ARCF
IV	<b>0.817</b>	0.717	0.737	<u>0.812</u>	0.725	0.728	0.740
SV	<b>0.794</b>	0.787	0.775	<u>0.791</u>	0.768	0.679	0.751
OCC	<u>0.842</u>	0.811	0.805	0.841	<b>0.843</b>	0.749	0.770
DEF	<b>0.899</b>	0.772	<u>0.860</u>	0.828	0.814	0.740	0.820
FM	<b>0.743</b>	<u>0.735</u>	0.720	0.708	0.727	0.602	0.706
IPR	<b>0.843</b>	0.785	0.787	<u>0.842</u>	0.732	0.725	0.750
OPR	<b>0.868</b>	0.801	0.816	<u>0.854</u>	0.797	0.729	0.782
OV	0.765	<u>0.802</u>	0.756	<b>0.811</b>	0.703	0.650	0.705
BC	<b>0.849</b>	0.712	0.795	<u>0.832</u>	0.747	0.753	0.777



表3 各种跟踪算法在数据集 OTB100 上各种属性的成功率得分

Table 3 Success rate scores of various attributes of various tracking algorithms on dataset OTB100

OTB100	本文算法	STRCF	AutoTrack	BACF	SRDCF	KCF	ARCF
IV	<b>0.759</b>	0.706	0.718	<u>0.756</u>	0.657	0.581	0.722
SV	<b>0.774</b>	0.763	0.692	<u>0.772</u>	0.697	0.479	0.681
OCC	<b>0.798</b>	0.796	0.752	<u>0.797</u>	0.785	0.618	0.740
DEF	<u>0.834</u>	0.766	<b>0.842</b>	0.822	0.761	0.671	0.800
MB	<b>0.754</b>	0.751	<u>0.753</u>	0.746	0.734	0.595	0.729
IPR	<b>0.788</b>	<u>0.783</u>	0.730	0.714	0.630	0.553	0.730
OPR	<b>0.817</b>	0.775	0.733	<u>0.811</u>	0.707	0.608	0.729
OV	<u>0.783</u>	<b>0.827</b>	0.748	0.694	0.708	0.650	0.711
BC	<b>0.796</b>	0.701	0.743	<u>0.794</u>	0.655	0.672	0.754

为了更清晰、更全面地将本文算法与各主流算法的跟踪性能进行比较,表2、表3分别给出了包括本文在内的各种算法在数据集 OTB100 上各种属性的跟踪成功率与跟踪精确率得分。从表2和表3中可知,本文算法由于具有空间正则项,当跟踪目标与背景颜色相近或模糊时,自适应地分配背景区域的权重大小,实现精准跟踪;减少搜索区域时,因为本文通过空间局部响应和全局响应的变化确定局部响应的可信度,当目标自身形态发生变化或运动状态骤变时,可信度较低,滤波器将停止更新,避免迭代

非必要信息导致跟踪失败。由于本文算法选取结合深度特征的提取方式,面对大量样本时,提取特征信息更准确,使得算法在处理光照变化、遮挡时有良好的处理效果。在处理超视野属性时,会成功将目标区域和背景区域区分开,所以本文算法的效果偏好。表4为不同算法在部分实验图像序列上的平均跟踪速度。结合表3,本文算法的整体跟踪效果与6种对比算法相比,能够在实时跟踪的前提下,具有较好的跟踪效果,并且在大多情况下均可以保持稳定的跟踪。

表4 不同算法在部分实验图像序列上的平均跟踪速度

Table 4 Average tracking speed of different algorithms on part of experimental image sequences

f/s

本文算法	STRCF	AutoTrack	BACF	SRDCF	KCF	ARCF
16.9	22.6	16.2	16.8	3.8	131.5	12.5

## 6 结束语

根据固定的正则化项无法抑制非目标区域学习的问题,本文提出了一种具有空间自适应性的目标跟踪算法。通过对自适应空间正则项权重进行初始化,引入欧几里德范数,结合图像信息为目标和背景区域分配不同的权重,训练相关滤波器。利用局部响应变化表明了像素可信度,当外观变化较大时限制了局部相关滤波器的学习,得到更强壮的外观模型和响应图模型,从而动态地更新学习率。选择PCA来处理提取的CNN特征,确保图像信息的准确性和高效性。通过在不同数据集上与目前主流算法,从精确率、成功率和实时性3项性能指标综合分析可以发现本文算法具有较高的鲁棒性。目标跟踪作为计算机视觉

领域中一个颇具挑战性的问题,还需要潜心钻研,下一步将围绕如何构建多个相关滤波器分别进行跟踪而展开深入研究。

## 参考文献:

- [1] 李馨,赵加清,张征明,等.基于数字图像相关的自适应应变场计算[J].光学学报,2021,41(23):125-132.  
LI Xin, ZHAO Jiaqing, ZHANG Zhengming, et al. Self-adaptive strain field calculation based on digital image correlation[J]. Acta optica sinica, 2021, 41(23): 125-132.
- [2] 刘万军,孙虎,姜文涛.自适应特征选择的相关滤波跟踪算法[J].光学学报,2019,39(6):242-255.  
LIU Wanjun, SUN Hu, JIANG Wentao. Correlation filter tracking algorithm for adaptive feature selection[J]. Acta

- optica sinica, 2019, 39(6): 242–255.
- [3] 孙德刚, 肖媛媛, 尹艳华, 等. 多特征联合时空正则化相关滤波目标跟踪鲁棒算法 [J]. *机床与液压*, 2021, 49(22): 67–75.  
SUN Degang, XIAO Yuanyuan, YIN Yanhua, et al. Correlation filtering target tracking algorithm with multi-feature joint spatio-temporal regularization[J]. *Machine tool & hydraulics*, 2021, 49(22): 67–75.
- [4] BOLME D S, BEVERIDGE J R, DRAPER B A, et al. Visual object tracking using adaptive correlation filters[C]//2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Francisco: IEEE, 2010: 2544–2550.
- [5] HENRIQUES J F, CASEIRO R, MARTINS P, et al. Exploiting the circulant structure of tracking-by-detection with kernels[C]//European Conference on Computer Vision. Berlin: Springer, 2012: 702–715.
- [6] HENRIQUES J F, CASEIRO R, MARTINS P, et al. High-speed tracking with kernelized correlation filters[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2015, 37(3): 583–596.
- [7] DANELLJAN M, HÄGER G, SHAHBAZ KHAN F, et al. Accurate scale estimation for robust visual tracking[C]//Proceedings of the British Machine Vision Conference. Nottingham: BMVA Press, 2014.
- [8] BERTINETTO L, VALMADRE J, GOLODETZ S, et al. Staple: complementary learners for real-time tracking[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 1401–1409.
- [9] GALOOGAHI H K, SIM T, LUCEY S. Correlation filters with limited boundaries[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE, 2015: 4630–4638.
- [10] DANELLJAN M, HÄGER G, KHAN F S, et al. Convolutional features for correlation filter based visual tracking[C]//2015 IEEE International Conference on Computer Vision Workshop. Santiago: IEEE, 2016: 621–629.
- [11] MUELLER M, SMITH N, GHANEM B. Context-aware correlation filter tracking[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 1387–1395.
- [12] LI Feng, TIANG Cheng, ZUO Wangmeng, et al. Learning spatial-temporal regularized correlation filters for visual tracking[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 4904–4913.
- [13] HUANG Ziyuan, FU Changhong, LI Yiming, et al. Learning aberrance repressed correlation filters for real-time UAV tracking[C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2020: 2891–2900.
- [14] 韦联福. 再谈拉格朗日函数非唯一性的物理意义: 广义规范变换和正则变换的等价性证明 [J]. *物理与工程*, 2021, 31(2): 31–35, 40.  
WEI Lianfu. Remarks on the non-uniqueness of Lagrange function: an equivalence proof between the gauge and canonical transformations[J]. *Physics and engineering*, 2021, 31(2): 31–35, 40.
- [15] 姜文涛, 刘晓璇, 涂潮, 等. 自适应空间异常的目标跟踪 [J]. *电子与信息学报*, 2022, 44(2): 523–533.  
JIANG Wentao, LIU Xiaoxuan, TU Chao, et al. Adaptive spatial and anomaly target tracking[J]. *Journal of electronics & information technology*, 2022, 44(2): 523–533.
- [16] 孙丽君, 黄志远, 陈天飞. 基于傅里叶变换的 Gamma 因子快速自标定方法 [J]. *光学学报*, 2021, 41(24): 116–127.  
SUN Lijun, HUANG Zhiyuan, CHEN Tianfei. Fast self-calibration method of gamma factor based on Fourier transform[J]. *Acta optica sinica*, 2021, 41(24): 116–127.
- [17] 李文健, 盖绍彦, 俞健, 等. 基于卷积神经网络的单帧复合图像绝对相位恢复 [J]. *光学学报*, 2021, 41(23): 113–124.  
LI Wenjian, GAI Shaoyan, YU Jian, et al. Absolute phase recovery of single frame composite image based on convolutional neural network[J]. *Acta optica sinica*, 2021, 41(23): 113–124.
- [18] 高宇, 夏志明, 刘欢. 非线性二维主成分分析方法 [J]. *纯粹数学与应用数学*, 2021, 37(4): 475–492.  
GAO Yu, XIA Zhiming, LIU Huan. Two-dimensional nonlinear principal component analysis: a nonlinear information compression method[J]. *Pure and applied mathematics*, 2021, 37(4): 475–492.
- [19] 梁霄, 李家伟, 赵小龙, 等. 基于深度学习的红外目标成像液位检测方法 [J]. *光学学报*, 2021, 41(21): 104–112.  
LIANG Xiao, LI Jiawei, ZHAO Xiaolong, et al. Infrared target imaging liquid level detection method based on

- deep learning[J]. *Acta optica sinica*, 2021, 41(21): 104–112.
- [20] 刘宗达, 董立泉, 赵跃进, 等. 视频中快速运动目标的自适应模型跟踪算法 [J]. *光学学报*, 2021, 41(18): 164–173.
- LIU Zongda, DONG Liqun, ZHAO Yuejin, et al. Adaptive model tracking algorithm for fast-moving targets in video[J]. *Acta optica sinica*, 2021, 41(18): 164–173.
- [21] 李天雄, 侯茂盛, 李丽娟, 等. 基于特征自适应的激光扫描投影图形控制点提取及优化方法 [J]. *光学学报*, 2021, 41(24): 98–109.
- LI Tianxiong, HOU Maosheng, LI Lijuan, et al. Control point extraction and optimization method of laser scanning projection graphics based on feature adaptation[J]. *Acta optica sinica*, 2021, 41(24): 98–109.
- [22] 尹宝才, 张超辉, 胡永利, 等. 基于图嵌入的自适应多视降维方法 [J]. *智能系统学报*, 2021, 16(5): 963–970.
- YIN Baocai, ZHANG Chaohui, HU Yongli, et al. An adaptive multi-view dimensionality reduction method based on graph embedding[J]. *CAAI transactions on intelligent systems*, 2021, 16(5): 963–970.
- [23] 王德文, 魏波涛. 基于孪生变分自编码器的小样本图像分类方法 [J]. *智能系统学报*, 2021, 16(2): 254–262.
- WANG Dewen, WEI Botao. A small-sample image classification method based on a Siamese variational auto-encoder[J]. *CAAI transactions on intelligent systems*, 2021, 16(2): 254–262.
- [24] 崔铁军, 李莎莎. 基于因素空间的人工智能样本选择策略 [J]. *智能系统学报*, 2021, 16(2): 346–352.
- CUI Tiejun, LI Shasha. Sample selection strategy of artificial intelligence based on factor space[J]. *CAAI transactions on intelligent systems*, 2021, 16(2): 346–352.
- [25] 石昌友, 孙强, 卢建平, 等. 基于深度融合卷积神经网络的图像边缘检测 [J]. *现代电子技术*, 2022, 45(24): 141–144.
- SHI Chagyou, SUN Qiang, LU Jianping, et al. Image edge detection based on deep fusion convolution neural network[J]. *Modern electronic technology*, 2022, 45(24): 141–144.

#### 作者简介:



姜文涛, 副教授, 博士, 主要研究方向为图像与视觉计算、模式识别与人工智能。主持国家自然科学基金项目 2 项, 发表学术论文 20 余篇。



孟庆姣, 硕士硕士生, 主要研究方向为图像与视觉计算、模式识别与人工智能。

[ 责任编辑: 刘冰洁 ]