

DOI:10.13364/j.issn.1672-6510.20190189

数字出版日期: 2020-12-17; 数字出版网址: <http://kns.cnki.net/kcms/detail/12.1355.N.20201216.2043.006.html>

融合位置估计的自适应尺度相关滤波跟踪

王中帅, 周聪玲, 王永强, 高鹏
(天津科技大学机械工程学院, 天津 300222)

摘要: 针对相关滤波跟踪算法中不能适应目标多尺度变化的问题, 提出了一种融合位置估计和尺度估计的自适应尺度相关滤波器. 通过提取当前图像中不同尺度大小的目标模板, 作为先验信息加到滤波器中学习, 训练滤波器. 对多尺度模板训练赋予新的权重定义, 重新定义了多尺度模板对应的标签. 提高了滤波器对目标尺度变化的敏感度. 通过在 CVPR 2015 数据集验证, 该方法的精准率为 0.803、成功率为 0.705. 特别是在多尺度环境影响下, 该算法结果优于其他算法, 达到了预期跟踪效果.

关键词: 自适应; 相关滤波; 尺度变化; 目标跟踪

中图分类号: TP391.41

文献标志码: A

文章编号: 1672-6510(2021)01-0062-06

Adaptive Scale Correlation Filtering Tracking Based on Fusion Position Estimation

WANG Zhongshuai, ZHOU Congling, WANG Yongqiang, GAO Peng

(College of Mechanical Engineering, Tianjin University of Science & Technology, Tianjin 300222, China)

Abstract: This paper proposed an adaptive scale correlation filter combining multi-scale supervision of position estimation and scale estimation aiming at the problem that the correlation filtering and tracking algorithm can not adapt to the target scale variation. The information about the target templates of different scales extracted from the current frame picture is added to the filter as priori information for the filter to learn and train the filter as well. A new weight definition is given to the multi-scale template training, and the corresponding label of the multi-scale template is redefined. As a result, the sensitivity of the filter to the change of target scale is improved. Verified in CVPR 2015 dataset, the accuracy rate of the new method is 0.803 and the success rate is 0.705. Especially under the influence of multi-scale environment, the results of this algorithm are better than those of other algorithms, and the expected tracking effect can be achieved.

Key words: adaptive; correlation filter; scale variation; object tracking

目标跟踪在计算机视觉领域中占有核心地位, 广泛应用于辅助驾驶、安防监控、无人机导航等领域. 近年来, 目标跟踪领域发展迅速. 其中相关滤波跟踪^[1-3]由于其强大的性能而备受广大科研人员关注. 目前, 在目标跟踪系统中, 仍然面临着尺度变化、遮挡、形变和快速运动等诸多挑战. 尤其是尺度变化导致跟踪精度降低, 甚至由于多尺度原因造成目标在跟踪过程中丢失^[4-5]. 2010年, Blome等^[6]将相关滤波原理应用到目标跟踪领域, 提出了MOSSE跟踪

器, 通过傅里叶变换将运算转到频域中, 降低了算法的运算量, 进一步对算法进行提速优化. 2012年, Henriques等^[7]提出了CSK跟踪器, 通过在目标位置采取一次样本, 其他样本均是基础样本循环偏移生成的虚拟样本, 这些样本所构成的样本矩阵是循环矩阵, 并利用了循环矩阵的性质, 但CSK跟踪器只使用图像中的灰度特征. 文献[8]在特征选择上进行改进, 使用了颜色特征, 提出了CN跟踪器. 文献[9]采用了多通道的HOG特征, 并引入了核方法, 提出了

收稿日期: 2019-07-09; 修回日期: 2020-04-23

作者简介: 王中帅(1989—), 男, 山东人, 硕士研究生; 通信作者: 周聪玲, 副教授, zhoucling@tust.edu.cn

KCF跟踪器. Galoogahi等^[10]提出的BACF算法通过将目标框以外的背景信息考虑进去,增加整个图像循环偏移矩阵,得到了一个更稳定的滤波器. Mueller等^[11]提出了上下文感知相关滤波跟踪(context-aware correlation filter tracking),该算法联合目标区域前后左右四块背景区域进行联合滤波器训练,既合理地利用了背景信息,提高了跟踪器的鲁棒性,又不太影响跟踪的速度.在此基础上,DCF_CA跟踪算法^[11]、SAMF跟踪算法^[12]、STAPLE跟踪算法^[13]在模型训练中加了背景约束后,性能上都有着显著性的提高.在对尺度变换问题方面,SAMF跟踪算法在KCF的基础上将单一特征扩展为多个特征,利用尺度池的方法实现目标自适应跟踪. Danelljan等^[13]提出DSST跟踪算法,通过使用位置滤波器和尺度滤波器,分别对目标定位和尺度评估.

现实世界中的目标往往出现尺度变换、光照变化、模糊、目标外形变化等,都会影响跟踪的性能.本文提出了针对目标尺度变化问题的解决方法,该方法首先根据先验知识获取不同尺度下的目标信息,然后在滤波器中对不同尺度下的目标模板赋值新的权重.令多尺度下的目标模板虽然是滤波器的正样本,但权重小于原始尺度目标模板,从而有效地跟踪不同尺度下的目标.

1 相关滤波跟踪

1.1 线性回归

假设训练样本集 (x_i, y_i) ,并将滤波器训练看成一个岭回归问题,可表示为

$$\min_w = \sum_i (f(x_i) - y_i)^2 + \lambda \|w\|^2 \quad (1)$$

其中 w 是滤波器.

对式(1)进行优化求得

$$w = (X^T X + \lambda I)^{-1} X^T Y \quad (2)$$

其中: X 是样本矩阵, Y 是标签矩阵, I 为便于计算的单位矩阵, λ 是正则化系数.

将式(2)转换到复数域情况下的解析解为

$$w = (X^H X + \lambda I)^{-1} X^H Y \quad (3)$$

其中: $X^H = (X^*)^T$, H 表示共轭转置,*表示复共轭.

1.2 循环矩阵

样本矩阵是一个循环矩阵,并利用循环矩阵傅里叶对角化的性质,简化算法,提高运算速度.

假设一个向量 $X = [x_1, x_2, x_3, \dots, x_n]$,那么由该向量循环偏移后的 $n \times n$ 的循环矩阵 $C(x)$ 表示为

$$X = C(x) = \begin{bmatrix} x_1 & x_2 & x_3 & \dots & x_n \\ x_n & x_1 & x_2 & \dots & x_{n-1} \\ x_{n-1} & x_n & x_1 & \dots & x_{n-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_2 & x_3 & x_4 & \dots & x_1 \end{bmatrix} \quad (4)$$

根据循环矩阵经傅里叶变换可相似对角化,将矩阵 X 进行如下转换

$$X = F \text{diag}(\hat{x}) F^H \quad (5)$$

其中: \hat{x} 为原向量 x 的傅里叶变换, F 是离散傅里叶变换矩阵,且满足 $F^H F = F F^H = I$.

利用循环矩阵的特性来化简公式(3)得

$$\hat{w} = \frac{\hat{x}^* \odot \hat{y}}{\hat{x}^* \odot \hat{x} + \lambda} \quad (6)$$

其中: \hat{w} 是 w 的傅里叶变换, \hat{y} 是 Y 的傅里叶变换, \odot 表示元素间的乘法运算.算法通过进行傅里叶变换,将运算转换到了频域中,由矩阵的运算转化为元素的点积运算,提高了算法的运算速度.

1.3 非线性岭回归

为了克服当样本线性不可分的情况,通过映射函数 $\phi(x)$,映射到高维空间,相关滤波器用样本的线性组合表示为

$$w = \sum_i \alpha_i \phi(x_i) \quad (7)$$

利用核方法,使其线性可分.将式(7)代入式(1)中,解得

$$\alpha = (K + \lambda I)^{-1} Y \quad (8)$$

其中 K 是核矩阵,且是循环矩阵.

根据循环矩阵的特性,求解为

$$\hat{\alpha} = \frac{\hat{y}}{\hat{k}^{xx} + \lambda} \quad (9)$$

其中: \hat{k}^{xx} 是 K^{xx} 的傅里叶变换, K^{xx} 是核矩阵的第一行向量.

1.4 上下文感知相关滤波器

上下文感知相关滤波器(CA-CF)通过增加一些背景信息对训练的滤波器进行约束,提高了跟踪器对目标区域和背景区域的辨别性.

CA-CF是在传统的相关滤波跟踪框架的基础上,将目标区域的上下左右四块背景信息加到了相关滤波器中去学习,式(1)可改为

$$\min_w = \|A_0 w - Y\|^2 + \lambda_1 \|w\|^2 + \lambda_2 \sum_i^k \|A_i w\|^2 \quad (10)$$

其中: $A_j (j \in [1, k])$ 是背景样本矩阵, k 是背景样本的个数.

对式(10)优化求解得

$$w = F^{-1} \left(\frac{F(a_0^*) \odot F(y)}{F(a_0^*) \odot F(a_0) + \lambda_1 + \lambda_2 \sum_{i=1}^k F(a_i^*) \odot F(a_i)} \right) \quad (11)$$

2 改进的相关滤波跟踪

在相关滤波算法中,使用基础样本偏移生成样本集,目标尺度变化使滤波器降低对目标的敏感度是导致跟踪失败的主要因素之一.本文通过多尺度监督的自适应尺度模型,将基础样本不同尺度大小的样本循环偏移生成的样本集加到滤波器学习过程中去.设 a^*b 表示基础样本的尺寸,提取的尺度样本的尺度表示为 Sa^*Sb . S 为尺度变化因子.为了便于训练滤波器,基础样本和尺度样本对应的标签矩阵也应该设置为相同尺度.为此 γ 表示为每一帧目标基础样本对应标签矩阵的高斯带宽.多尺度样本对应的高斯标签带宽应为 $\gamma_i = S\gamma$.在训练中,所有的尺度样本都是正样本.但它毕竟不是目标基础样本,因此多尺度监督中的样本集对应的标签矩阵的峰值应该设置为小于 1 的数值.为此,本文提出了一种新的标签矩阵峰值定义标准,以尺度样本和目标基础样本的重叠率来描述尺度样本标签和基础样本标签的峰值比,两者关系表示为

$$g_i^* = g_0^* \cdot \frac{Area_i \cap Area_0}{Area_i \cup Area_0} \quad (12)$$

其中: g_0^* 和 g_i^* 分别表示基础样本和第 i 尺度样本对应的高斯标签峰值; g_0^* 的值设置为 1; $Area_0$ 和 $Area_i$ 则分别表示基础样本和多尺度样本的尺度区域.

在训练滤波器过程,多尺度样本训练的对滤波器的权重影响应该小于目标基础样本的权重,为此制定了新的标准.假设多尺度样本对应的训练权重符合正态分布,因此多尺度样本对应的权重定义为

$$\delta_i = e^{-d_i^2/2} \quad (13)$$

其中: δ_i 表示第 i 尺度样本训练对应的权重值, d_i 表示尺度样本标签矩阵和目标基础样本标签矩阵峰值之差.

$$d_i = g_0^* - g_i^* \quad (14)$$

为了训练对尺度变化敏感的滤波器,所有的尺度样本都被转化为和目标基础样本一样大小.将模型优化,可将式(10)改为

$$\min_w = \|Cw - Y\|^2 + \lambda_1 \|w\|^2 \quad (15)$$

其中:

$$C = [A_0, \sqrt{\lambda_2}A_1, \dots, \sqrt{\lambda_2}A_k, \sqrt{\delta_1}B_1, \dots, \sqrt{\delta_n}B_n]$$

$$Y = [y_0, 0, \dots, 0, y_1, \dots, y_n] \quad (16)$$

n 表示多尺度模板数量.

与式(10)类似,对式(14)求解得

$$w = (C^T C + \lambda I)^{-1} C^T Y \quad (17)$$

类似于式(11)求解,将式(16)代入式(17),式(17)可改为

$$\hat{w} = \frac{\hat{a}_0^* \odot \hat{y}_0 + \sum_{j=1}^n \delta_j \hat{b}_j \odot \hat{y}_j}{\hat{a}_0^* \odot \hat{a}_0 + \lambda_1 + \lambda_2 \sum_{j=1}^k \hat{a}_j^* \odot \hat{a}_j + \sum_{j=1}^n \delta_j \hat{b}_j \odot \hat{b}_j} \quad (18)$$

3 实验与结果分析

为验证本文算法的优越性,在 CVPR 2015 Benchmark^[15]数据集上,将本文提出的算法与 8 种现有经典算法的成功率和精准率相比较.

3.1 实验环境配置

本文的实验电脑配置为: intel(R) core(TM) i5-7300 MQ CPU@ 2.50 GHz 处理器、8 G 系统内存.其选取的经典跟踪算法为: CSK、MOSSE_CA^[6]、DCF_CA^[11]、SAMF_CA、DSST^[14]、KCF^[9]、SAMF_AT^[16]、DCF_SC^[17].以下将给出本文提出的目标算法一系列的参数,其中:搜索框 padding = 2,正则化系数 $\lambda_1 = 10^{-4}$, $\lambda_2 = 8.7$,学习率 $\eta = 0.0046$,尺度变化因子 $S = [0.98, 0.985, 0.99, 0.995, 1.0, 1.005, 1.01, 1.015, 1.02]$.

3.2 实验结果

本文提出的算法与 8 种现有经典目标跟踪算法在测试集上的仿真实验结果为:图 1 横轴为中心位置误差,是指算法计算出目标中心位置与真实目标中心位置之间的欧式距离;图 1 纵轴为精准率,精准率是指算法跟踪目标的中心位置误差在阈值距离内的帧数与总帧数的比值.中心位置误差公式为

$$A_i = \sqrt{(x_i - X)^2 + (y_i - Y)^2} \quad (19)$$

式中: x_i 、 y_i 是算法计算出的中心位置坐标; X 、 Y 是真实目标中心位置坐标.

图 2 横轴为重叠度,是指算法计算出目标与真实目标之间的重叠度;图 2 纵轴为成功率,成功率是指重叠率大于阈值的帧数与总帧数的比值.成功率公

式为

$$S = H_x / N \quad (20)$$

式中: H_x 是重叠率大于阈值的帧数; N 是总帧数.

精准率和成功率可以作为评价跟踪算法性能的标准.




图1 不同算法的精准率比较结果

Fig. 1 Comparison of precision rate of different algorithms

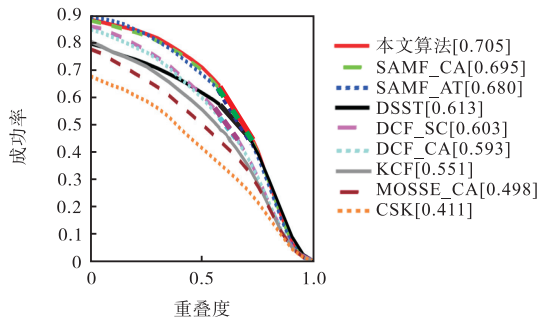


图2 不同算法成功率对比结果

Fig. 2 Comparison of success rate of different algorithms

由图 1、2 看出, 本文提出的算法精准率和成功率优于其他 8 种经典算法, 得分分别为 0.803 和

0.705. 在精准率上比基准算法 KCF (得分为 0.696) 高出了 0.107. 在成功率上比基准算法 KCF (得分为 0.551) 高出了 0.154.

相对于 CSK、MOSSE_CA、DCF_CA、KCF、DCF_SC 跟踪算法, 本文方法增加了尺度样本对滤波器的训练, 所以算法总体得出的精准率和成功率均优于这些方法. 在尺度自适应方面, DSST 跟踪算法有 33 个尺度, 但使用两个独立滤波器导致分布最优, 并不能保证位置最优. SAMF 跟踪算法对目标进行 7 个尺度计算, 得到一个尺度金字塔, 找出响应值最大的尺度即为目标. 这两种方法都是通过增加尺度样本来适应多尺度变化, 表 1 和表 2 分别为本文算法与 8 种经典算法在尺度变化(SV)、低分辨率(LR)、遮挡(OCC)、超出视野(OV)、平面旋转(OR)干扰下精准率和成功率的对比实验结果. 通过表 1 和表 2 可以看出, 尺度变化干扰时 SAMF 和 DSST 算法效果优于其他不加尺度样本的跟踪算法. 本文方法在增加尺度样本作为训练集时, 考虑到多尺度是由目标生成的样本, 在进行样本训练时考虑尺度样本对效果影响肯定不如目标样本, 即每个尺度样本对结果的影响肯定不一样, 所以对每个尺度样本与目标样本计算服从正分布交并比值作为新的权重后, 再对样本进行训练, 提高了滤波器对多尺度变化的敏感度. 由表 1、表 2 可见, 本文提出的算法充分体现了优异性能, 达到了设计算法的预期效果. 图 3 所示, 本文提出的算法在目标尺度变化的情况下, 可以较为准确地预测目标的尺度大小并能很好的跟踪目标. 这表明本文提出算法在目标尺度变化的情况下的可行性.

表 1 不同干扰下不同算法精准率对比实验结果

Tab. 1 Comparison of precision rate of different algorithms with different interference

干扰	精准率/%								
	本文算法	SAMF_CA	SAMF_AT	DSST	DCF_SC	DCF_CA	KCF	MOSSE_CA	CSK
尺度变化(SV)	0.772	0.755	0.742	0.653	0.724	0.694	0.635	0.504	0.452
低分辨率(LR)	0.706	0.703	0.693	0.602	0.584	0.594	0.560	0.538	0.422
遮挡(OCC)	0.760	0.745	0.744	0.602	0.699	0.669	0.632	0.515	0.433
超出视野(OV)	0.734	0.689	0.650	0.479	0.598	0.578	0.501	0.349	0.276
平面旋转(OR)	0.788	0.771	0.764	0.665	0.744	0.692	0.677	0.525	0.489

表 2 不同干扰下不同算法成功率对比实验结果

Tab. 2 Comparison of success rate of different algorithms with different interference

干扰	成功率/%								
	本文算法	SAMF_CA	SAMF_AT	DSST	DCF_SC	DCF_CA	KCF	MOSSE_CA	CSK
尺度变化(SV)	0.622	0.613	0.578	0.545	0.464	0.460	0.415	0.370	0.309
低分辨率(LR)	0.543	0.534	0.534	0.443	0.318	0.317	0.295	0.319	0.277
遮挡(OCC)	0.677	0.664	0.643	0.539	0.536	0.529	0.512	0.429	0.353
超出视野(OV)	0.605	0.587	0.610	0.498	0.498	0.587	0.457	0.311	0.274
平面旋转(OR)	0.690	0.687	0.648	0.569	0.573	0.556	0.527	0.425	0.378



图3 尺度变化下的对比实验

Fig. 3 Contrast experiments with scale variations

4 结 论

本文提出了一种改进的自适应尺度相关滤波跟踪算法. 该算法将位置估计和尺度估计融合为一, 将预先的尺度模板样本作为训练样本, 一起训练滤波器. 给不同尺度的模板在滤波器训练中赋予新的权重定义, 同时也赋予了尺度模板对应的标签矩阵新的定义, 提高了跟踪器对目标尺度变化的敏感度. 最后将本文提出的算法与当前经典 8 种跟踪算法在测试集进行仿真实验对比. 实验结果表明, 本文算法精准率为 0.803、成功率为 0.705, 高于对比算法, 达到了预期效果.

参考文献:

- [1] 高文, 朱明, 贺柏根, 等. 目标跟踪技术综述[J]. 中国光学, 2014, 7(3): 365–375.
- [2] 葛宝义, 左宪章, 胡永江. 视觉目标跟踪方法研究综述[J]. 中国图象图形学报, 2018, 23(8): 1091–1107.
- [3] 张微, 康宝生. 相关滤波目标跟踪进展综述[J]. 中国图象图形学报, 2017, 22(8): 1017–1033.
- [4] 刘波, 许廷发, 李相民, 等. 自适应上下文感知相关滤波跟踪[J]. 中国光学, 2019, 12(2): 265–273.
- [5] 江山, 张锐, 韩广良, 等. 复杂背景灰度图像下的多特征融合运动目标跟踪[J]. 中国光学, 2016, 9(3): 320–328.
- [6] Bolme D S, Beveridge J R, Draper B A, et al. Visual object tracking using adaptive correlation filters[C]// Proceedings of 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Francisco: IEEE, 2010: 2544–2550.
- [7] Henriques J F, Caseiro R, Martins P, et al. Exploiting the circulant structure of Tracking-by-detection with kernels[C]// Proceedings of the 12 th European Conference on Computer Vision. Florence: Springer, 2012: 702–715.
- [8] Danelljan M, Khan F S, Felsberg M, et al. Adaptive color attributes for real-time visual tracking[C]// Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus: IEEE, 2014: 1090–1097.
- [9] Henriques J F, Caseiro R, Martins P, et al. High-speed tracking with kernelized correlation filters[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(3): 583–596.
- [10] Galoogahi H K, Fagg A, Lucey S. Learning background-aware correlation filters for visual tracking[C]// Proceedings of 2017 IEEE International Conference on Computer Vision (ICCV). Venice: IEEE, 2017: 1144–1152.
- [11] Mueller M, Smith N, Ghanem B. Context-aware correlation filter tracking[C]// Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 1387–1395.
- [12] Li Y, Zhu J K. A scale adaptive kernel correlation filter tracker with feature integration[C]// Proceedings of the 12 th European Conference on Computer Vision. Zurich: Springer, 2014: 254–265.
- [13] Bertinetto L, Valmadre J, Golodetz S, et al. Staple: Complementary learners for real-time tracking[C]// Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 1401–1409.
- [14] Danelljan M, Hger G, Khan F S, et al. Accurate scale

estimation for robust visual tracking[C]// Proceedings of the British Machine Vision Conference 2014. London: BMVA Press: 65.1–65.11.

- [15] Wu Y, Lim J, Yang M H. Object tracking benchmark[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1834–1848.
- [16] Hu Q Y, Guo Y L, Chen Y J, et al. Correlation filter

tracking: Beyond an open-loop system[C]// Proceedings of the British Machine Vision Conference (BMVC). London: BMVA Press, 2017: 152.1–152.12.

- [17] Bibi A, Mueller M, Ghanem B. Target response adaptation for correlation filter tracking[C]// Proceedings of European Conference on Computer Vision (ECCV 2016). Amsterdam: Springer, 2016: 419–433.

责任编辑:周建军

(上接第 35 页)

- [13] 杨雪霞,陈洪章,李佐虎. 玉米秸秆氨化汽爆处理及其固态发酵[J]. 过程工程学报, 2001, 1(1): 86–89.
- [14] 冯彦洪,王端,肖和平,等. 螺秆蒸汽爆破预处理对稻秆结构及其无胶板性能的影响[J]. 林产化学与工业, 2018, 38(3): 69–74.
- [15] Herrera A, Téllez-Luis S J, Ramírez J A, et al. Production of xylose from sorghum straw using hydrochloric acid[J]. Journal of Cereal Science, 2003, 37(3): 267–274.
- [16] 许凤,孙润仓,詹怀宇. 木质纤维原料生物转化燃料乙醇的研究进展[J]. 纤维素科学与技术, 2004, 12(1): 45–54.
- [17] Pitarelo A P, Szczerbowski D, Ndiaye P M, et al. Steam explosion of cane bagasse using phosphoric acid as the pretreatment catalyst[J]. Journal of Biotechnology, 2010, 150(S): 206–207.
- [18] 林玲. 草酸强化竹材预水解组分溶出规律的研究[D]. 福州:福建农林大学, 2014.
- [19] Sluiter A, Hames B, Ruiz R, et al. Determination of

structural carbohydrates and lignin in biomass[R]. Colorado: National Renewable Energy Laboratory, 2008.

- [20] Chen L, Li J, Lu M, et al. Integrated chemical and multi-scale structural analyses for the processes of acid pretreatment and enzymatic hydrolysis of corn stover[J]. Carbohydrate Polymers, 2016, 141: 1–9.
- [21] 郑菲,罗海力,张伟东,等. 棉秆作为无胶纤维复合材料原料的特性分析[C]//中国林学会. 第九届中国林业青年学术年会论文摘要集. 成都:中国林学会, 2010: 220.
- [22] Dogaris I, Karapati S, Mamma D, et al. Hydrothermal processing and enzymatic hydrolysis of sorghum bagasse for fermentable carbohydrates production[J]. Biore-source Technology, 2009, 100(24): 6543–6549.
- [23] 张晓. 蒸汽爆破预处理对红麻纤维性能影响及微观机理研究[D]. 青岛:青岛大学, 2016.
- [24] 王堃,蒋建新,宋先亮. 蒸汽爆破预处理木质纤维素及其生物转化研究进展[J]. 生物质化学工程, 2006, 40(6): 37–42.

责任编辑:周建军