

DOI:10.3969/j.issn.1003-5060.2026.06.013

基于 UNet、UNet++、Attention-UNet 网络的 遥感影像建筑物提取研究

黄敏儿, 李振轩, 高飞, 陶庭叶, 朱勇超, 袁啸宇

(合肥工业大学 土木与水利工程学院, 安徽 合肥 230009)

摘要:文章选择 UNet、UNet++ 和 Attention-UNet 3 种卷积神经网络,研究该系列网络在建筑物提取中的性能差异。基于 WHU 建筑物数据集,通过实验和定量评估深入分析上述网络模型在遥感影像建筑物提取中的有效性和适用性。结果表明:UNet++ 的提取精度最高,其次是 Attention-UNet、UNet,分别为 0.987、0.983、0.979;UNet++ 的边缘提取能力和建筑物正确分割比例优于其他 2 种网络;针对中小型建筑物,Attention-UNet 的提取效果显著,但易出现非建筑物误提的情况,UNet++ 的提取效果良好,偶尔出现漏提现象,UNet 的提取效果欠佳。

关键词:建筑物提取;高分辨率遥感影像;UNet 网络;UNet++ 网络;Attention-UNet 网络

中图分类号:P237

文献标志码:A

文章编号:1003-5060(2026)06-0805-08

High-resolution remote sensing image building extraction based on UNet, UNet++, and Attention-UNet networks

HUANG Miner, LI Zhenxuan, GAO Fei, TAO Tingye, ZHU Yongchao, YUAN Xiaoyu

(School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: This study selects three convolutional neural networks(CNNs), namely UNet, UNet++, and Attention-UNet, aiming to investigate the performance differences of this network series in building extraction. Based on the WHU building dataset, through experiments and quantitative evaluations, this research explores the effectiveness and applicability of the aforementioned network models in remote sensing image building extraction. The experimental results indicate that UNet++ achieves the highest extraction accuracy, followed by Attention-UNet and UNet, with accuracies of 0.987, 0.983, and 0.979, respectively. UNet++ exhibits superior edge extraction capabilities and correct building segmentation ratios compared to the other two networks. For small to medium-sized buildings, Attention-UNet demonstrates significant extraction effectiveness, but it is prone to false positives. UNet++ performs well with occasional instances of missed extractions, while the extraction effectiveness of UNet is subpar.

Key words: building extraction; high-resolution remote sensing image; UNet; UNet++; Attention-UNet

随着遥感技术的蓬勃发展,高分辨率遥感影像可提供丰富的纹理和细节信息^[1],有助于掌握城市的建筑物现状规模布局。高分辨率遥感影像建筑物的自动检测和提取对于人口密度估计、违

规监测、城市规划及地形图的制作和更新具有非常重要的意义。

高分辨率遥感影像城市场景下建筑光谱、形状纹理、尺度差异大^[2],且存在相似地物干扰以及

收稿日期:2024-01-12;修回日期:2024-02-29

基金项目:国家自然科学基金资助项目(42104019);安徽省自然科学基金资助项目(2208085QD105)和中央高校基本科研业务费专项资金资助项目(JZ2021HGTA0167)

作者简介:黄敏儿(2001—),女,安徽马鞍山人,合肥工业大学硕士生;

李振轩(1991—),男,山东汶上人,博士,合肥工业大学讲师,硕士生导师,通信作者,E-mail:zxli2019@hfut.edu.cn;

高飞(1962—),男,安徽天长人,合肥工业大学教授,博士生导师。

建筑分布密集、边界线模糊等问题,以上情况限制了各类方法在高分辨率遥感影像建筑物提取中的应用。传统建筑物提取方法包括基于特征、面向对象和结合辅助信息。基于特征提取的建筑物提取方法是一种常见的遥感图像建筑物提取方法,其基本思想是通过提取遥感图像中的特征来识别和提取建筑物,通常采用传统的分类方法,如最大似然分类法^[3]、支持向量机分类法^[3-4]、随机森林^[5]、决策树^[6]等,通过对特征的学习来实现建筑物的分类。传统的基于特征提取建筑物的方法通常只能提取出建筑物的轮廓或部分特征,且适用范围较局限,通常适用于简单的建筑物提取任务,如提取城市中的建筑物轮廓等。面向对象的提取方法^[7]是直接对高分辨率遥感图像进行分割,将图像分割成若干个对象,对每个对象进行分类,从而实现建筑物的提取,通常采用基于机器学习或深度学习的分类方法,通过对对象的特征进行学习来实现建筑物的分类。文献[8]采用基于规则的面向对象方法实现建筑物单体信息精提取;文献[9]提出一种半自动信息提取构建分类规则方法用于高精建筑物识别,所提取建筑物错分漏分现象得到缓解。结合辅助信息提取方法通过结合遥感图像和其他辅助信息来提高建筑物提取的准确性和可靠性,主要包括结合 LiDAR 数据^[10]、DSM 数据^[11]或利用无人机拍摄的高分辨图像^[12]辅助建筑物提取。结合辅助信息提取建筑物可提高提取精度,但数据获取成本较大,需要更多的时间和计算资源。总体而言,传统建筑物提取方法或多或少存在一些缺点,急需更高效、准确的方法满足不断增长的对建筑物精准识别需求。

目前,由于卷积神经网络(convolutional neural network,CNN)在图像处理问题上的优越性,基于深度学习的建筑物提取方法逐渐成为主流。

现有的深度学习模型主要有 AlexNet^[13]、PSP-Net^[14]、DeepLab^[15]等。然而并非每种模型都适用于建筑物的提取,常会出现提取的建筑物图斑边界不规则、存在对部分纹理特征类似建筑物的非建筑物误提情况。UNet 网络结构简洁明了,具有较强的语义分割能力,可对建筑物进行精准的分割和提取,且具有较高的泛化能力,可以适应不同的数据集和任务。基于 UNet 网络衍生出的相关系列网络也具有较强的图像分割能力。文献[16]提出一种基于空洞卷积的 E-Unet 网络,解决了建筑物颜色各异、形状大小不同、细节繁多导致的提取结果普遍存在的边缘模糊、转角圆滑和细节丢失等问题;文献[17]提出一种不同骨架模块、UNet++网络和真实性检验的建筑物遥感提取功能模块嵌合的深度学习业务化应用技术体系;文献[18]提出一种综合 ResBlock 残差模块和 Attention 注意力机制的改进型 UNet 网络,有效提高了建筑物的提取精度。本文选用最为成熟的 UNet 模型及在 UNet 模型基础上对网络进行优化改进的 UNet++模型和 Attention-UNet 模型,利用同一组高分辨率遥感影像数据源进行建筑物提取任务,比较这 3 种在 UNet 系列中具有代表性的网络在提取过程中各自的特点,分析其不同建筑物提取细节上的优势和不足,为深度学习在高分辨率遥感影像建筑物提取任务中的应用提供更全面的认识。

1 原理与方法

CNN 具有多层网络结构,其基本结构主要包括输入层、卷积层、池化层、全连接层、输出层^[19]。每层由多个二维向量组成,每个向量由多个独立的神经元组成。CNN 的工作原理如图 1 所示。




图 1 CNN 原理

首先将输入的图像转换成数字矩阵,使用多个卷积核从图像中提取特征;然后用非线性激活函数处理提取的特征;再进行池化操作,以保留最

显著的特征,提高模型的畸变容忍能力。经过多个卷积层和池化层后,将通过整个连接层获得显著特征,得到预测值。损失函数用于计算预测值

与真实值(损失值)之间的差异,用作反馈信号。使用优化器更新权重参数,降低样本预测的损失值。损失值越小,预测结果与实际结果之间的匹配程度就越高。

1.1 UNet 网络

UNet 是 2015 年 Ronneberger 等提出的最初应用于医学影像二值分割问题的语义分割网络,网络结构如图 2 所示。




图 2 UNet 网络基本结构

该网络的主要特点是 U 型结构和逐尺度跳跃连接。UNet 模型有非常规整的编解码网络结构,左侧是编码器,多次下采样获取全局语义特征,右侧是解码器,上采样恢复特征图大小并逐层融合来自编码器浅层的多尺度局部特征,以逐像素分类。本研究采取的 UNet 网络(图 2),在编码阶段,存在 5 个尺度。每个尺度都使用了 2 层步长为 1、有填充的 3×3 卷积层,并采用 ReLU 激活函数。随后,通过 2×2 最大池化层进行下采样,以进入下一个尺度。其中,第 5 个尺度不做下采样,卷积层之后接编码器中的上采样。编码器中第 1 个尺度所有卷积层的通道数为 64,下一个尺度卷积层通道数加倍。在解码阶段,在第 5 个尺度卷积层之后使用多个步长为 2 的 4×4 大小的上采样层恢复特征图大小。

为了缓解编码器多次下采样导致的局部细节信息丢失问题,采用了跳跃连接的方法,将编码阶段各尺度卷积层之后的特征图传递到解码器。通过上采样将特征图放大到上一尺度,并与跳跃连接送来的编码器同尺度特征图进行融合。每个尺度特征融合后采用 2 层步长为 1、有填充的 3×3 的卷积层,卷积通道数与编码器同尺度卷积层通道数一致,同样采用 ReLU 激活。

编码器特征图上采样恢复到原输入大小后,

在 2 层卷积层后使用 1 层步长为 1、 3×3 的卷积层将特征图 64 个通道数转变成期望的类别数。

1.2 UNet++ 网络

UNet++ 网络为提高分割的准确性,在编码器与解码之间添加密集连接块和卷积层。UNet++ 网络基本结构如图 3 所示,UNet++ 网络在最初的 UNet 上增加了重新设计的跳跃路径(绿色)、密集跳跃连接(蓝色)和深度监督(红色)。经过重新设计的跳跃路径不再是简单地将编码器的特征图直接传递给解码器,而是通过一个卷积层先对编码器的特征图进行处理,再传递给解码器,使其可以有效地融合编码器与解码器之间的特征信息。密集跳跃连接使解码器的每一层都与编码器的相应层进行跳跃连接,而不仅仅是在最高层与最低层之间进行跳跃连接。深度监督不仅在最终的输出层进行监督,还在编码器与解码器的中间层进行监督,并通过修剪模型来调整模型的复杂性。

本研究使用的 UNet++ 网络通过利用 ContinusParallelConv 类来更灵活地构建卷积层,并在训练过程中对特征进行归一化和激活处理,提高了网络的性能和泛化能力。在上采样的过程中采用步长为 2、 4×4 的卷积层,最后采用 3×3 大小的卷积层将特征图转化为分割结果,并保持特征图大小不变。




图 3 UNet++网络基本结构

1.3 Attention-UNet 网络

Attention-UNet 的基本结构与 UNet 相似,如图 4 所示。在网络的编码部分,输入图像通过 2 层 3×3 的卷积层进行逐步滤波和降采样。Attention Gates (AGs) 用于过滤通过跳跃连接传播的特征。AGs 的特征选择是通过使用粗尺度提取的上下文信息(门控)来实现的。Attention-

Unet 的主要思想是提出了 Attention Gate 模块,通过使用 Soft-Attention 将注意力机制集成到 UNet 的跳跃连接和上采样模块中,从而实现空间上的注意力机制。通过注意力机制,抑制图像中的无关信息,突出局部的重要特征。

Attention Gate 模块的具体操作流程如图 5 所示。




图 4 Attention-UNet 基本结构




图 5 Attention Gate 原理

编码器下采样特征图 x_i^l , 尺寸为 $F_g \times H_g \times W_x \times D_x$, F_g 代表批量大小, H_g 代表特征图高度, W_x 代表特征图宽度, D_x 代表通道数。经过 $1 \times 1 \times 1$ 卷积后得到 $W_x^@ x_i^l$, 上采样中上一层特征图为 g_i , 尺寸为 $F_g \times H_g \times W_g \times D_g$, 经过 $1 \times 1 \times 1$ 卷积

后得到 $W_g^@ g_i$, 再将 $W_x^@ x_i^l$ 和 $W_g^@ g_i$ 相加后进行 ReLU 激活函数处理得到 $\sigma_1(W_x^@ x_i^l + W_g^@ + b_g)$, 然后经过 $1 \times 1 \times 1$ 卷积计算后得到特征图 q_{att}^l , 最后对 q_{att}^l 进行 Sigmoid 激活处理后即可得到最终的注意力得分 α_i^l 。 q_{att}^l 和 α_i^l 的计算表达式为:

$$\mathbf{q}_{\text{att}}^l = \boldsymbol{\varphi}^T [\sigma_1 (\mathbf{W}_x^T \mathbf{x}_i^l + \mathbf{W}_g^T \mathbf{g}_i + \mathbf{b}_g)] + \mathbf{b}_\varphi \quad (1)$$

$$\boldsymbol{\alpha}_i^l = \sigma_2 [\mathbf{q}_{\text{att}}^l (\mathbf{x}_i^l; \mathbf{g}_i; \boldsymbol{\theta}_{\text{att}})] \quad (2)$$

2 实验与分析

2.1 数据集

实验使用新西兰土地信息服务网站的 WHU 建筑物数据集,以分析本文中 3 种网络的有效性。

该数据集的地面分辨率降采样为 0.3 m,其中包含大约 2.1×10^4 栋位于克赖斯特彻奇的独立建筑物。数据集提供了建筑物的 shapefile 格式数据和栅格化数据。区域内影像被裁剪成 8 189 块 512×512 像素的图像,并将样本分为训练集(4 736 幅)、验证集(1 036 幅)和测试集(2 416 幅)。数据集样例如图 6 所示。




图 6 数据集样例

2.2 实验环境

本实验的硬件环境为 Intel(R) Core(TM) i5-9300H CPU, 8 GiB RAM, NVIDIA GeForce GTX1650, 操作系统为 Windows 10, 深度学习框架是 PyTorch。在训练过程中,3 种网络均设置相同的参数:batch size 设置为 2, 初始学习率为 0.001, epoch 设置为 50。使用多分类交叉熵损失函数和 Adam 算法进行优化。交叉熵损失函数表达式为:

$$L = -[y \ln p + (1 - y) \ln(1 - p)] \quad (1)$$

其中: $y \in \{0, 1\}$ 表示地面真实标签, 建筑物用 1 表示, 背景用 0 表示; $p \in [0, 1]$ 表示模型预测的正类的概率值。

2.3 评价指标

为定量评价网络分割性能, 本实验根据训练

损失值、训练精度和测试精度指标评价分类结果。训练损失值是在模型训练过程中计算得到的, 表示模型在训练数据的拟合误差。通过最小化损失函数值, 模型可以学习到从训练数据中提取模式和特征, 并尝试对训练数据进行准确的预测。训练精度和测试精度是用来衡量模型在训练数据集和测试数据集上的准确性指标。

训练精度是指模型在训练数据集中正确预测的样本数量与训练数据集中总样本数量的比例, 而测试精度是指模型在测试数据集中正确预测的样本数量与测试数据集中总样本数量的比例。

UNet、UNet++ 和 Attention-UNet 的训练损失值、精度变化情况如图 7 所示。




图 7 3 种网络训练损失值、精度变化情况

从图 7 可以看出, 随着迭代次数的增加, 3 种

网络的准确率均逐步上升, 约在第 40 次后训练精

度和测试精度趋于稳定,损失值也逐渐减少且趋于稳定。其中 UNet 网络损失值和精度曲线变化表现最为稳定。

2.4 实验结果分析

在 WHU 建筑物数据集上,本研究对 UNet、UNet++ 和 Attention-UNet 的建筑物提取结果进行了可视化分析,结果如图 8 所示,特别在网络边缘提取能力、中小型建筑物提取和非建筑物误提 3 个方面。

1) 边缘提取能力。第 1 个场景中由 3 种网络相同位置红色方框中的提取结果可以看出,UNet++ 的建筑物轮廓提取结果比其他 2 种网

络更清晰,3 种网络蓝色方框中提取的建筑物边界均较为模糊;第 2 个场景中红色方框里的建筑物轮廓提取结果,UNet 和 UNet++ 的分割结果相似、效果较好,Attention-UNet 无法准确分割出建筑物棱角、效果较差;第 3 个场景中红色方框中 UNet++ 的提取结果明显优于另外 2 种,其建筑物边缘提取更准确、平滑,蓝色方框中 UNet++ 对于建筑物边缘把控更好,UNet 和 Attention-UNet 提取的建筑物边缘粘连;第 4 个场景和第 5 个场景红色方框中的提取结果可看出,UNet++ 较其他 2 种网络的建筑物边缘提取效果更好,边缘更清晰平滑。




图 8 3 种网络建筑物提取可视化结果

2) 中小型建筑物提取。第 1 个场景中由蓝色方框中的提取结果可知,UNet、UNet++ 与 Attention-UNet 均有检测中小型建筑物的能力;第 2 个场景中由蓝色方框中的分割结果可看出,

Attention-UNet 是唯一提取出相应位置小型建筑物的网络,UNet 和 UNet++ 均未识别出图中的中小型建筑物;第 4 个场景中只有 UNet++ 准确提取出了原标签蓝色方框中的小型建筑物,

UNet 未能识别图中的小型建筑物, Attention-UNet 漏提了正确位置的小型建筑物。

3) 非建筑物误提。第1个场景中由 Attention-UNet 提取结果可视化图右侧红色方框可知, Attention-UNet 存在非建筑物的误提情况;第3个场景中蓝色方框中 UNet++ 不存在非建筑物的误分割情况, UNet 和 Attention-UNet 提取结果中均存在误分割情况;第4个场景中 Attention-UNet 误提了在蓝色方框中的小型非建筑物。

由以上分析可以看出:① UNet 的建筑物边缘提取效果一般, 且存在较多中小型建筑物漏提的情况;② Attention-UNet 得益于增加的注意力机制对数据中的中小型物体较敏感, 但容易出现非建筑物误提的情况, 且其建筑物边缘提取能力较差, 经常出现提取边缘模糊不清的问题;③ 与 UNet 和 Attention-UNet 相比, UNet++ 由于重新设计的跳跃路径和密集跳跃连接能更好地去除背景信息, 保留目标信息, 使得建筑物边缘提取得更准确、平滑, 但也会出现小概率中小型建筑物漏提的情况。

本研究对 WHU 数据集中建筑物的提取结果进行定量评估, 结果见表1所列。

从表1可以看出, 在 UNet 基础上, 对于跳跃连接部分优化的 UNet++ 和普通 UNet, 与添加了注意力机制的 Attention-UNet 相比, 本文模型的3个定量评价指标均表现最优, 训练损失值为0.032, 训练集精度为0.987, 测试集精度为0.985; 相较于 UNet 和 Attention-UNet 模型, UNet++ 模型的训练损失值分别降低了0.019、0.110, 训练精度分别增加了0.008、0.004, 测试精度分别提升了0.012、0.020。

表1 3种模型定量评价结果

模型	损失值	训练精度	测试精度
UNet	0.051	0.979	0.973
UNet++	0.032	0.987	0.985
Attention-UNet	0.043	0.983	0.965

3 结 论

卷积神经网络在建筑物语义分割方面具有巨大潜力, 本文基于 WHU 建筑物数据集比较了 UNet、UNet++ 和 Attention-UNet 3种卷积神经网络模型的效果。通过实验和定量评估, 3种网络在建筑物提取上均有较高的精度, 但在边缘

提取和中小型建筑物识别方面的性能有所差异, 本文分析了3种网络的优势和局限性, 并提供了相应的结论和建议。结合可视化分割结果和定量评价数据, 可得出以下结论。

1) UNet++ 在 WHU 建筑物数据集上预测结果表现良好, 提取精度最高, 其次是 Attention-UNet、UNet。同时, UNet++ 的边缘提取能力和建筑物正确分割比例均优于其他2种网络模型, 所提取大、小型建筑物边界较准确、平滑, 且误分割和欠分割现象较少。UNet++ 的建筑物提取结果在各方面的表现均比 UNet 更理想, 说明 UNet++ 在 UNet 基础上重新设计的跳跃路径、密集跳跃连接和深度监督在建筑物提取上发挥了积极作用。

2) 在处理中小型建筑物的提取任务时, Attention-UNet 提取效果显著, 但偶尔会出现将非建筑物误识别的情况; UNet++ 模型的提取效果较好, 但有时会出现漏检的现象; 相比之下, UNet 模型的表现最差。说明 Attention-UNet 通过将注意力机制集成到 UNet 的跳跃连接和上采样模块中, 实现了空间上的注意力机制, 提高了对中小型物体的提取能力, 但同时也增加了小型非建筑物的误提比例。

3) 通过对比实验可知, UNet++ 运行时间与 UNet、Attention-UNet 相差较大, 因此模型效率方面需要改善。

[参 考 文 献]

- [1] 范荣双, 陈洋, 徐启恒, 等. 基于深度学习的高分辨率遥感影像建筑物提取方法[J]. 测绘学报, 2019, 48(1): 34-41.
- [2] 张亚一, 费鲜芸, 王健, 等. 基于高分辨率遥感影像的建筑物提取方法综述[J]. 测绘与空间地理信息, 2020, 43(4): 76-79.
- [3] 孙琳, 宋爱红, 高文秀. 基于最大似然法和 SVM 法的太湖流域 HJ-1B 影像分类[J]. 测绘信息与工程, 2012, 37(3): 30-33.
- [4] 纪雪, 唐秋华, 陈义兰, 等. 联合支持向量机和增强学习算法的多波束声学底质分类[J]. 测绘学报, 2021, 50(7): 972-981.
- [5] PANG Y, XU F, LIU J, et al. Seabed sediment classification based on multifeatures fusion and feature selection framework[C]//2021 OES China Ocean Acoustics(COA). Harbin: IEEE, 2021: 378-381.
- [6] DARTNELL P, GARDNER J. Predicted seafloor facies of central santa monica bay: Open-File Report 2004-1081[R]. California: U. S. Geological Survey, 2004.
- [7] 邢云飞, 刘萍, 谢育珽, 等. 基于高分辨率遥感影像的面向对

- 象建筑物分级提取方法[J]. 航天返回与遥感, 2023, 44(4): 88-102.
- [8] 韩东成, 杨世植, 赵强, 等. 面向对象的高分辨率遥感影像建筑物信息提取[J]. 大气与环境光学学报, 2021, 16(4): 358-364.
- [9] 杨杰, 高伟, 段茜茜, 等. 面向对象的特征自动选择的建筑物信息提取[J]. 遥感信息, 2021, 36(2): 130-135.
- [10] HUI Z, LI Z, CHENG P, et al. Building extraction from airborne LiDAR data based on multi-constraints graph segmentation[J]. Remote Sensing, 2021, 13(18): 3766.
- [11] WU B, WU S, LI Y, et al. Automatic building rooftop extraction using a digital surface model derived from Aerial-Stereo images[J]. Journal of Spatial Science, 2022, 67(1): 21-40.
- [12] 胡同喜, 牛雪峰, 谭洋, 等. 基于 SURF 算法的无人机遥感影像拼接技术[J]. 测绘通报, 2015(1): 55-58, 74.
- [13] SANDEEP K, SURESH N L S. Remote sensing scene type classification using multi-trial vector-based differential evolution algorithm and multi-support vector machine classifier[J]. International Journal of e-Collaboration (IJEC), 2022, 18(1): 1-20.
- [14] YUAN W, WANG J, XU W B. Shift Pooling PSPNet: rethinking PSPNet for building extraction in remote sensing images from entire local feature pooling[J]. Remote Sensing, 2022, 14(19): 4889-4889.
- [15] WANG Y H, GAO L R, HONG D F, et al. Mask DeepLab: end-to-end image segmentation for change detection in high-resolution remote sensing images[J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 104: 102582.
- [16] 何直蒙, 丁海勇, 安炳琪. 高分辨率遥感影像建筑物提取的空洞卷积 E-Unet 算法[J]. 测绘学报, 2022, 51(3): 457-467.
- [17] 古煜民, 阎福礼. 基于不同骨架 UNet++ 网络的建筑物提取[J]. 中国科学院大学学报, 2022, 39(4): 512-523.
- [18] 李传林, 黄风华, 胡威, 等. 基于 Res.AttentionUnet 的高分辨率遥感影像建筑物提取方法[J]. 地球信息科学学报, 2021, 23(12): 2232-2243.
- [19] 李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508-2515, 2565.

(责任编辑 吴 亮)

(上接第 804 页)

- [6] HUERTAS MÉNDEZ N D J, VARGAS CASANOVA Y, GÓMEZ CHIMBI A K, et al. Synthetic peptides derived from Bovine Lactoferricin exhibit antimicrobial activity against *E. coli* ATCC 11775, *S. maltophilia* ATCC 13636 and *S. enteritidis* ATCC 13076[J]. Molecules, 2017, 22(3): 452.
- [7] XU R, ZHAO X Y, GUO S, et al. Effect of loop structure of Bovine Lactoferricin on *Escherichia coli* [J]. Advances in Food Science and Engineering, 2018, 2(4): 110-114.
- [8] YAN W, HO J, MING T, et al. Bovine Lactoferrampin, human lactoferricin, and lactoferrin 1-11 inhibit nuclear translocation of HIV integrase[J]. Applied Biochemistry and Biotechnology, 2016, 179(7): 1202-1212.
- [9] SADIQ I Z, BABAGANA K B, DANLAMI D, et al. Molecular therapeutic cancer peptides: a closer look at Bovine Lactoferricin[J]. Asian Journal of Biochemistry, Genetics and Molecular Biology, 2018, 1(2): 1-9.
- [10] JIANG R L, LÖNNERDAL B. Bovine lactoferrin and lactoferricin exert antitumor activities on human colorectal cancer cells (HT-29) by activating various signaling pathways[J]. Biochemistry and Cell Biology, 2017, 95(1): 99-109.
- [11] 霍桂桃, 吕建军, 屈哲, 等. 果蝇在肿瘤学研究中的优势及应用前景[J]. 遗传, 2014, 36(1): 30-40.
- [12] DING G, XIANG X, HY Y, et al. Coordination of tumor growth and host wasting by tumor-derived Upd3[J]. Cell Reports, 2021, 36(7): 109553.

(责任编辑 闫杏丽)