

中南林业科技大学学报

Journal of Central South University of Forestry & Technology

ISSN 1673-923X，CN 43-1470/S

《中南林业科技大学学报》2026年第6期

Doi:10.14067/j.cnki.1673-923X.2026.06.017

论文标题： 深度卷积域适应的野生动物图像识别

作　　者： 赵恩庭，张长春，赵海涛，等

收稿日期： 2025-06-05

引文格式： 赵恩庭,张长春,赵海涛,等.深度卷积域适应的野生动物图像识别[J].中南林业科技大学学报,2026,46(6):174-183.

ZHAO E T, ZHANG C C, ZHAO H T, et al. Wildlife image recognition with deep convolution domain adaptation[J]. Journal of Central South University of Forestry & Technology,2026,46(6):174-183.

相关论文推荐

Recommended articles

基于偏好信息和改进YOLOv8n的油茶炭疽病图像识别

Recognition of *Camellia oleifera* anthracnose disease based on preference information and improved YOLOv8n

基于卷积神经网络的种苗病害识别方法

Method of seed disease recognition based on convolutional neural network

基于卷积神经网络的林火烟雾检测

Forest fire smoke detection based on convolutional neural network

面向对象结合卷积神经网络的GF-1影像遥感分类

Remote sensing image of GF-1 classification using object-oriented method and convolutional neural network

基于视觉变换网络的自监督森林火灾识别

Self-supervised forest fire recognition based on visual transformation network

基于深度图的相邻花朵图像分割方法

Adjacent flowers image segmentation method based on depth image

Doi:10.14067/j.cnki.1673-923x.2026.06.017 http: //qks.csuft.edu.cn

深度卷积域适应的野生动物图像识别

赵恩庭[1]，张长春[1, 2, 3]，赵海涛[4]，张军国[1, 2, 3]

（1. 北京林业大学 工学院，北京 100083；2. 林木资源高效生产全国重点实验室，北京 100083；
3. 北京林业大学生物多样性智慧监测研究中心，北京 100083；4. 陕西省动物研究所，陕西 西安 710032）

摘 要：【目的】野生动物是生物多样性保护的关键，其基础性工作是野外资源调查，而监测图像的高效识别是野生动物资源科学调查保护的重要前提。然而，由于不同光照、背景、拍摄尺度和物种差异等引发的域偏移问题，易导致识别模型性能下降。本研究旨在提高复杂野外环境下无标签野生动物物种识别的泛化性能，为开放环境野生动物分类研究提供关键技术支撑。【方法】本研究提出一种深度卷积域适应的野生动物图像识别模型，以提高模型在无标注场景下的跨域识别准确率。具体地，该模型以预训练的 ResNet50 网络作为特征提取器，通过最大均值差异约束来捕获野生动物图像的卷积层域不变特征，并设计基于 mixup 概率分布的特征对齐模块来实现全连接层语义空间映射，提升模型学习高层次语义信息的能力。最后，模型通过熵正则化约束与目标域关联关系挖掘，驱动类别间低密度分离的决策边界优化，进一步提高模型的泛化性和鲁棒性。【结果】在分别包含 8 类野生动物和 11 类野生动物数据集上进行了一系列实验来验证模型的有效性，实验结果表明，在 2 个野生动物数据集上获得的平均准确率分别为 98.3% 和 81.7%，与基于对抗学习的基线模型相比，本研究提出的模型对野生动物图像识别性能明显提升。【结论】本研究所提出的深度卷积域适应的野生动物图像识别模型能够有效减小因不同时空场景、物种差异引起的域偏移，进而提升跨域野生动物物种识别准确率。

关键词：野生动物；图像识别；域适应；特征对齐

中图分类号：S718.6；TP391.4 **文献标志码：**A **文章编号：**1673-923X(2026)06-0174-10

Wildlife image recognition with deep convolution domain adaptation

ZHAO Enting[1], ZHANG Changchun[1,2,3], ZHAO Haitao[4], ZHANG Junguo[1,2,3]

(1. School of Technology, Beijing Forestry University, Beijing 100083, China; 2. State Key Laboratory of Efficient Production of Forest Resources, Beijing 100083, China; 3. Research Center for Biodiversity Intelligent Monitoring, Beijing Forestry University, Beijing 100083, China; 4.Shaanxi Institute of Zoology, Xi'an 710032, Shaanxi, China)

Abstract:【Objective】Wildlife plays a pivotal role in biodiversity conservation, and field resource surveys form the fundamental basis. Efficient recognition of monitoring images is a critical prerequisite for scientific wildlife resource investigation and protection. However, domain shift issues caused by varying lighting conditions, backgrounds, shooting scales, and species differences often degrade recognition model performance. This study aims to enhance the generalization capability of wildlife species recognition under complex unlabeled field environments, providing key technical support for open-environment wildlife classification research. 【Method】This paper proposed a deep convolutional domain adaptation model for wildlife image recognition to enhance cross-domain accuracy in unannotated scenarios. Specifically, the model employs a pre-trained ResNet50 network as a feature extractor to capture domain-invariant convolutional features of wildlife images through maximum mean discrepancy (MMD) constraints. A mixup-based probabilistic distribution feature alignment module is designed to map semantic spaces in fully connected layers, enhancing the model's ability to learn high-level semantic information. Finally, entropy regularization constraints and target domain correlation mining are integrated to optimize low-density separation boundaries between categories, further improving the model's generalization and robustness. 【Result】A series of experiments were performed on two wildlife datasets, which contain 8 and 11 species respectively, to validate the model's effectiveness. The results demonstrate that the proposed model achieves average accuracies of 98.3% and 81.7% on the

收稿日期（Received）：2025-06-05 **修订日期**（Revised）：2025-08-08

基金项目：国家自然科学基金项目（32371874；32401569）；北京市自然科学基金项目（6244053）；陕西省创新能力支撑计划（2025JC-GXPT-037）；陕西省科学院基础计划项目（2023K-37）。

第一作者：赵恩庭（zhao_enting@163.com），博士研究生。

通信作者：张长春（zhangchangchun@bjfu.edu.cn），副教授，博士，硕士研究生导师；张军国（zhangjunguo@bjfu.edu.cn），教授，博士，博士研究生导师。

引文格式：赵恩庭 , 张长春 , 赵海涛 , 等 . 深度卷积域适应的野生动物图像识别 [J]. 中南林业科技大学学报 ,2026,46(6):174-183.

ZHAO E T, ZHANG C C, ZHAO H T, et al. Wildlife image recognition with deep convolution domain adaptation[J]. Journal of Central South University of Forestry & Technology,2026,46(6):174-183.

two datasets, significantly outperforming adversarial learning-based baseline models in wildlife image recognition.【Conclusion】The proposed deep convolutional domain adaptation-integrated wildlife image recognition model effectively mitigates domain shifts caused by spatiotemporal scenario variations and species differences, thereby enhancing cross-domain wildlife species recognition accuracy. This approach offers a robust technical framework for advancing wildlife conservation and ecological monitoring.
Keywords: wildlife; image recognition; domain adaptation; feature alignment

生物多样性在维持生态平衡、促进物种适应环境以及应对气候变化等方面具有重要作用 [1]。野生动物监测是生物多样性保护的重要组成部分。基于深度学习的野生动物图像智能监测方法通过分析监测图像中野生动物特征来识别物种，进而评估湿地生态系统的生物多样性，具有响应快、准确率高等优势，有利于实现长时期、自动化的野生动物监测，在物种识别 [2]、行为分析 [3]、生境评估 [4] 等研究领域发挥重要作用。然而，随着野生动物资源调查工作的开展与深入，同一类图像，不同的背景、不同的光照以及不同的拍摄尺度等因素都会造成特征分布发生改变，在识别不同数据集时现有方法自适应性欠佳，准确率得不到保障。因此，亟待研究未知场景下有效的野生动物监测图像自动识别方法，解决上述挑战，提升野生动物调查的自动化和智能化水平。

近年来，很多学者在基于域适应野生动物识别领域开展了一系列的研究工作。Zhang 等 [5] 提出相关对齐、条件对抗学习和 Transformer 联合约束野生动物识别模型，采用端到端的训练策略，提升了野生动物识别的精度，提高了模型的泛化性。Zhang 等 [6] 采用风格迁移来获取不同季节的稀有野生动物图像，基于残差网络进行训练，以提高小样本图像分类的准确性。WDCA-TLNet 模型利用 Wasserstein 距离来量化 2 个域之间的特征分布差异，并通过相关对齐技术将源域和目标域的图像特征映射到一个联合的特征空间，使其能够有效减轻域偏移，提高了模型的识别性能 [7]。赵恩庭等 [8] 采用野生动物图像的类别信息作为条件构建对抗学习网络并结合域适应方法，提高了识别精度。尽管上述方法在一定程度上提高了深度识别模型的泛化性能，但仍面临如下挑战：现有的域适应方法仅利用域对齐方法来减轻域差异，然而目标域样本被错误分类的情况仍会出现。此外，这些方法一般依赖于联合最小化域差异的距离度量 [9]、最大均值差异 [10] 或相关对齐 [11]。尽管这些方法已经取得了显著的成果，但是在深度网络模型的输出端附近进行任意约束实现域适应，忽略了基于深度网络模型的域适应方法在学习过程中知识迁移的不足，特别是在靠近网络的输入端附近，这在一定程度上也影响了域适应图像分类的准确率，限制了其可用性和可扩展性。为解决此问题，拟从两个方面进行考虑：一是在卷积层进行域适应迫使学习到更好的卷积特征表示来更好地支持全连接层的域对齐；二是保持源域目标域相同类别特征分布一致的情况下，在全连接层进行域适应以尽可能拉开不同类别的特征分布。

本研究的主要贡献有以下几个方面：1）采用最大均值差异约束对卷积特征进行对齐，迫使模型学习到更好的卷积特征表示来支持全连接层的域对齐；2）使用 mixup 概率分布的特征对齐模块，提升深度网络学习高层次语义信息的能力；3）引入熵正则化域适应与目标数据关联关系约束策略，促使类别间的低密度分离，进一步提高域适应方法识别性能；4）在 2 个野生动物域适应场景上进行了广泛的实验，结果表明本模型识别性能明显优于对比方法。此外，定量和定性结果验证了模型在实际应用中的潜力。

1　材料与方法

1.1　野生动物数据集构建

本研究构建了 2 个野生动物数据集（数据集样例如图 1 所示，分别命名为 RC 和 EN），并在数据集上进行了一系列实验，与多个现有方法进行对比，以验证方法的有效性。

1）RC 野生动物数据集：包含 8 类不同野生动物的 9 452 幅图像，由 DomainNet[12]、Snapshot Serengeti、NACTI[13] 和网络中选取的对焦准确且画质高清的图像样本采样构成。其中，Real 数据集是从 DomainNet 数据集和网络中选取的对焦准确且画质高清的图像样本构建；Camera_Trap 数据集主要从 Snapshot Serengeti 和 NACTI 等公开红外相机数据集采集。即 RC 野生动物数据集是由 Real（简称为 R）数据集和 Camera_Trap（简称为 C）数据集 2 个子数据集构成。本研究在 2 个迁移识别任务 R → C 和 C → R 上评估方法的识别性能。



图 1 野生动物数据集样例
Fig. 1 Example of wildlife dataset

2）EN 野生动物数据集：包含 11 类不同野生动物的 25 591 幅图像，来源于 2 个公开的野生动物数据集：ENA24[14]（简称 ES）和 NACTI（简称 NS）。这些图像数据是利用放置在不同地点和不同时间的红外摄像机陷阱拍摄，获取的图像样本在背景、野生动物姿态等方面存在差异，这种分布差异主要是光照条件、相机角度、背景、植被和颜色的变化引起的。本研究在 2 个迁移识别任务 ES → NS 和 NS → ES 上评估本模型的识别性能。

1.2 深度卷积域适应的野生动物图像识别模型

本研究提出的深度卷积域适应的野生动物图像识别模型的网络结构如图 2 所示，其核心由特征提取器和标签分类器构成，通过多重域适应实现跨域特征对齐。具体地，特征提取器基于深度残差网络构建，通过迁移学习策略获取具有强迁移能力的野生动物图像特征表示；域适应采用多重特征对齐策略，其中 mixup[15] 特征对齐方法，在源域与目标域之间建立高阶语义特征分布的一致性映射；基于最大均值差异的卷积特征对齐方式，通过跨源域和目标域卷积特征分布在最大均值差异约束中挖掘更具迁移性的特征；熵正则化域适应与目标数据关联关系约束策略，通过约束无标注目标数据的特征表示促使类别间的低密度分离，提升特征的迁移性能。最终通过标签分类器实现跨域条件下的野生动物精准识别。该模型通过特征迁移与域适应协同优化的方式，显著提升了野生动物图像在跨场景下的识别鲁棒性。

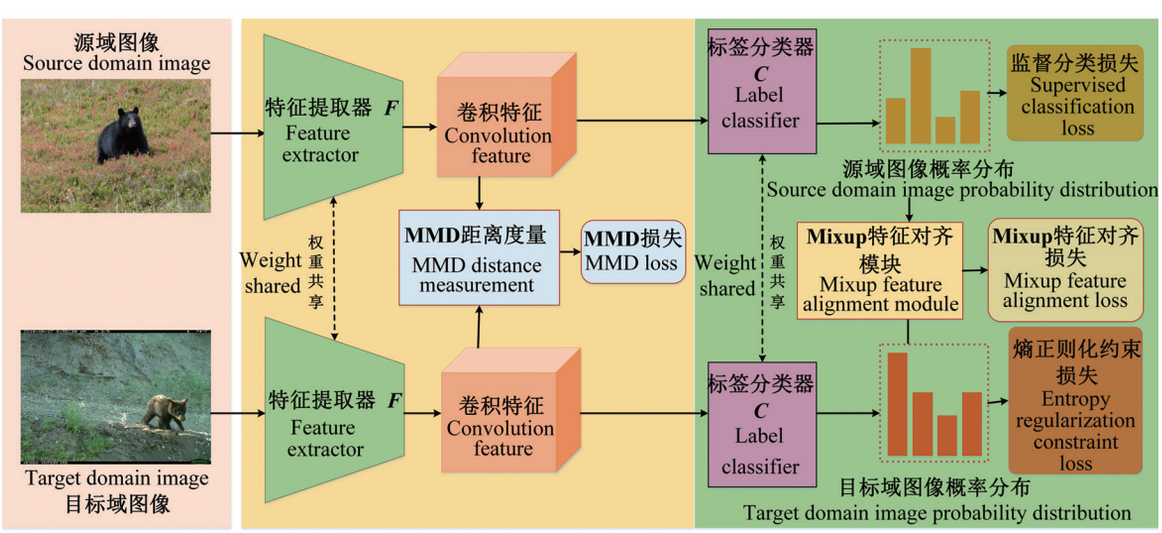


图 2 深度卷积域适应的野生动物图像识别方法网络结构
Fig. 2 Network diagram of wildlife image recognition with deep convolution domain adaptation

1.2.1　问题设定

本文研究的是野生动物图像无监督域适应识别场景，给定一个具有完全标注的源域 $D_s=\{(x_i^s,y_i^s)\}_{i=1}^{n_s}(x_i^s\in X^s,y_i^s\in Y^s)$ 和一个无标注的目标域 $D_t=\{(x_j^t)\}_{j=1}^{n_t}(x_j^t\in X^t)$，$x_i^s$ 和 x_j^t 分别表示源域样本和目标域样本；y_i^s 表示源域样本 x_i^s 对应的标签；n_s 和 n_t 分别表示源域 D_s 和目标域 D_t 中样本的数量。值得注意的是，源域 D_s 和目标域 D_t 分别服从不同的联合分布 $P(X^s,Y^s)$ 和 $Q(X^t,Y^t)$，并且 $P\neq Q$。假设源域标签空间 Y^s 和目标域标签空间 Y^t 是一致的，即均包含 C 个类别。深度卷积域适应的野生动物图像识别的目标是设计一个深度网络进行学习 2 个迁移标签分类器 $y=f_s(x)$ 和 $y=f_t(x)$ $y=f_t(x)$ 这 2 个标签分类器在最大均值差异约束、mixup 特征对齐约束和熵正则化约束的帮助下能够缩小源域 D_s 和目标域 D_t 间的差异，通过联合约束源域风险 $\varepsilon_s(f_s)=\mathrm{E}_{(x^s,y^s)\sim P}[f_s(x)\neq y]$ 和跨域差异以获得期望的目标域风险 $\varepsilon_t(f_t)=\mathrm{E}_{(x^t,y^t)\sim Q}[f_t(x)\neq y]$。

1.2.2　基于最大均值差异卷积特征学习

现有无监督域适应方法致力于全连接层的特征对齐，却忽视了卷积层特征的域适应。卷积层的域适应是必要的，因为全连接层的激活是在卷积层激活的基础上进行计算的。换句话说，如果卷积层未能采集到域可迁移的有用知识，则这些知识沿着深度网络传播到全连接层并不能呈现。因此，现有方法仅仅在全连接层进行域适应可能会出现不理想的结果。因此，本研究提出了基于最大均值差异（Maximum mean discrepancy，MMD）的卷积特征对齐方式，可以有效迫使模型学习到更好的卷积特征表示来支持全连接层的特征对齐。

具体地，MMD 特征对齐将卷积特征映射到再生核希尔伯特空间（Reproducing Kernel Hilbert Space，RKHS）（图 3），使用核函数计算内积来度量分布差异。假设用 H_k 表示具有特征核 k 的再生核希尔伯特空间，则分布的平均嵌入 p 在再生核希尔伯特空间 H_k 中代表一个独特的元素 $\mu_k(p)$，并且对于所有在 H_k 的变换 z 存在 $E_{x\sim p}z(x)=\langle z(x),\mu_k(p)\rangle_{H_k}$。在再生核希尔伯特空间中，源域和目标域分布的距离可以表达为：

$$\min_D L_{\mathrm{MMD}}=\left\|E_{x\sim P}\varphi(x_i^s)-E_{x\sim Q}\varphi(x_j^t)\right\|_{H_k}^2 \tag{1}$$

式中：$\varphi(\cdot)$ 表示特征空间到希尔伯特空间的一个映射，即 $k(x^s,x^t)=\langle\varphi(x^s),\varphi(x^t)\rangle$。$k(x^s,x^t)$ 定义为 I 个正定核。

1.2.3　基于 mixup 概率分布的特征学习

为了充分利用基于最大均值差异约束学习到的卷积特征来指导全连接层特征的学习，进一步减轻域偏移来提升野生动物识别方法的泛化性，本研究引入一种基于 mixup 概率分布的特征对齐模块（图 3）。与现有方法相比，基于类别分类器计算出的源域概率分布和目标域概率分布来构建 mixup 特征对齐损失约束，从而使得域适应图像识别准确率得到提升。具体地，野生动物图像输入到特征提取器 F，然后生成的特征被送到标签分类器 C，进而得到源域概率分布 p_i^s 和目标域概率分布 p_j^t。接下来，利用 mixup 参数 λ 计算 p_i^s 和 p_j^t 间的线性插值，该插值概率分布可以表达为 $\lambda*p_i^s+(1-\lambda)*p_j^t$。最后，mixup 特征对齐损失可以表达为：

$$L_M=-\sum_{i=1}^{n_s}\log(\lambda*p_i^s)-\sum_{j=1}^{n_t}\mathbf{1}(\max(p_j^t)>\tau)\log((1-\lambda)*p_j^t) \tag{2}$$

式中：n_s 和 n_t 分别表示源域和目标域中样本的数量。通过公式（2）使模型学习更鲁棒的特征表示，模型可以有效地减少域之间的域偏移，提高野生动物图像识别模型的泛化性能。

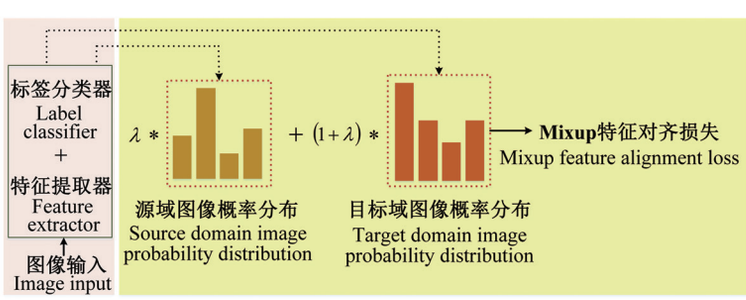


图 3　基于 mixup 概率分布的特征学习

Fig. 3　Feature learning based on mixup probability distribution

1.2.4 域适应 - 目标数据关联约束

由于目标域数据没有标注，因此保存数据结构对有效的知识迁移是很重要的。如果通过深度卷积域适应的野生动物图像识别网络生成的源域和目标域数据的特征空间分布差异是较小的，则可以直接利用优化好的类别分类器对目标域数据进行图像分类。本研究利用熵正则化原理 [16] 进一步约束目标域数据的特征表示来促使类别间的低密度分离：

$$L_R = \min_F \frac{1}{n_t} \sum_{j=1}^{n_t} H(C(F(x_j^t))) \quad (3)$$

式中：$H(\cdot)$ 表示信息熵函数。值得注意的是，与之前的方法不同的是，目标域熵最小化仅用于约束目标域数据的特征。与最大均值差异约束和 mixup 特征对齐约束一起，形成多域适应机制。这种多联合域适应能够进一步促进可迁移性强的特征学习，强化卷积特征学习和全连接层特征学习之间的互补性，从而有效避免负迁移，同时为域适应识别模型带来更多的迁移增益。

1.2.5 联合优化

本研究遵循与文献 [17] 类似的步骤，通过优化特征提取器 F 和标签分类器 C 的参数来训练源域可判别模型 $C(F(x))$ 实现野生动物图像分类任务。因此，源域数据的分类优化目标函数为：

$$L_C = \min_{F,C} \frac{1}{n_s} \sum_{i=1}^{n_s} L(C(F(x_i^s)), y_i^s) \quad (4)$$

式中：$L(\cdot)$ 表示交叉熵损失函数。

在卷积层上的域适应能够促使深度网络学习有效的滤波器来生成域不变的特征和具有判别性的卷积特征，同时有助于全连接层生成更好的特征表示。因此，除了在卷积层上应用域适应外，本研究也在全连接层上添加了 mixup 特征对齐约束来学习域不变的特征。此外，全连接层的域适应可能会惩罚一些不相关的神经元，反过来会促使卷积层减少对输入图像不相关模式的关注。因此，卷积层和全连接层的域适应会互相促进来最终提升模型的迁移性能，本模型的目标函数表达如下：

$$L_T = L_C + \alpha * L_{MMD} + \beta * L_M + \gamma * L_R \quad (5)$$

式中：α、β 和 γ 用来控制不同约束项之间的影响程度，本研究对上述 3 个参数通过实验验证方法来设定，参数具体选择过程将在实验结果分析中详述。

1.2.6 实验设置

实验细节：1）采用 50 层 ResNet[18] 作为基础网络模型，在 RC 和 EN 数据集上做实验。2）本研究所有实验是在 Pytorch 深度学习框架下完成的，所用的基础网络模型是在 ImageNet[19] 数据集上做预训练。3）本研究采用了动量为 0.9 的小批量随机梯度下降（Stochastic gradient descent，SGD），采用文献 [20] 中描述的学习率策略，即学习率 $\eta_p = \frac{\eta_0}{(1+ap)^b}$，其中 p 在训练阶段从 0 到 1 线性变化，η_0 为初始学习率，即任务相关全连接层从零开始训练，学习率是卷积层的 10 倍，即卷积层的学习率为 0.001，全连接层的学习率为 0.01。在 RC 和 EN 数据集图像域上进行实验时，a 均设置为 10，b 均设置为 0.75。4）在训练学习过程中，批的大小均设置为 28，而在测试时，批的大小是 4。此外，为了评估深度卷积域适应的野生动物图像识别方法的有效性，采用准确率作为评价准则。

2 结果与分析

2.1 对比实验

为了验证本模型的有效性和优势，本小节展示了本模型以及现有方法在 RC 和 EN 野生动物数据集上的迁移任务图像识别准确率与实验分析，实验结果如表 1 和表 2 所示。

表 1 RC 野生动物数据集上的实验结果
Table 1 Experimental results on the RC wildlife dataset

模型 Model	识别任务 Recognition task				平均准确率 Average accuracy /%
	R → C 准确率 Accuracy / %	R → C F1 /%	C → R 准确率 Accuracy / %	C → R F1 /%	
ResNet50[18]	81.9	77.4	68.8	68.1	75.4
MMD[11]	89.2	89.1	87.1	86.9	88.2
DCORAL[10]	89.5	88.9	84.0	84.3	86.8
CDAN[17]	88.3	88.4	91.0	90.9	89.7
DJAN[5]	92.7	92.7	93.8	92.7	93.3
ALDA[8]	97.8	97.7	95.3	94.8	96.6
本模型 Our model	99.3	99.3	97.2	97.1	98.3

在 RC 野生动物数据集上，本模型取得了最好的域适应野生动物图像识别准确率，如表 1 所示。在对比方法中，取得最高域适应野生动物图像识别准确率的是 ALDA[8] 方法，其引入样本标签信息构建对抗学习网络，融合 mixup 特征对齐和批光谱惩罚约束进一步提升模型对野生动物特征的判别能力，提升方法的识别准确率。与其相比，本模型取得了 1.7% 的提升（2 个迁移任务平均识

别准确率）。CDAN[17] 方法取得了 89.7% 的准确率，通过将类别信息作为条件融合到域判别器来实现跨域特征的细粒度匹配。此外，本模型与非对抗方法（MMD[11]，DCORAL[10]）相比，分别取得了 10.1% 和 11.5% 野生动物图像识别准确率的提升。此外，从 F1 评价准则分析，本模型依然取得了最好的性能。从上述定量分析上看，验证了本模型的有效性和优势，这主要是因为：1）本模型同样采用了最大均值差异约束对跨域特征进行对齐，与 MMD 不同的是，这里采用最大均值差异对卷积特征对齐使模型学习到更好的卷积特征；2）本研究提出了一个基于 mixup 概率分布的特征对齐网络模型，在全连接层特征上实现特征的对齐并在一定程度上提升深度网络学习高层次语义信息的能力；3）本模型联合考虑了最大均值差异约束、mixup 特征对齐约束和熵正则化域适应与目标数据关联关系约束策略，有效减轻了源域和目标域特征分布间的差异，提高了野生动物图像域适应识别性能。

此外，EN 野生动物数据集上的实验结果如表 2 所示，其趋势与 RC 野生动物数据集一致，本模型同样取得了最好的野生动物图像识别准确率。与对比方法中最好的 ALDA 方法相比，准确率有 9.5%（平均值：81.7% vs. 72.2%）的提升，进一步验证了本模型的有效性。进一步，表 3 展示了识别方法在 R → C 迁移任务上单个野生动物物种识别结果，其趋势与表 1 和表 2 实验结果一致，本模型取得了最好的野生动物单个物种识别结果，与对比方法中平均准确率最好的 DJAN 方法相比，在狮子的识别上，有 10.4%（97.3% vs. 86.9%）的提升，再次验证了本模型的有效性和优势。为了验证不同评价准则对识别的影响，本研究采用 F1 评价准则在 EN 野生动物数据集上的实验结果如表 4 所示，其趋势与表 2 一致，结合表 1 的实验结果，再次验证了本模型在不同的评价准则下依然取得了最优的识别性能。

表 2　在 EN 野生动物数据集上的实验结果
Table 2　Experimental results on the EN wildlife dataset

模型 Model	识别任务 Recognition task		平均准确率 Average accuracy /%
	ES → NS 准确率 Accuracy /%	NS → ES 准确率 Accuracy /%	
ResNet50[18]	41.4	55.4	48.4
DANN[20]	42.8	51.6	47.2
DCORAL[10]	44.1	55.1	49.6
CDAN[17]	45.5	56.2	50.9
DSAN[21]	41.5	53.7	47.6
BNM[22]	28.0	60.1	44.0
DALN[23]	41.2	52.5	46.9
DJAN[5]	48.8	67.5	58.2
ALDA[8]	65.9	78.5	72.2
本模型 Our model	78.4	85.0	81.7

2.2　消融实验

为进一步分析深度卷积域适应的野生动物图像识别方法，并评价本模型各个模块对整个模型的贡献程度，在 EN 和 RC 野生动物数据集上进行了消融实验，实验结果如表 5 所示。其中，“－ mmd”表示采用 mixup 特征对齐约束和熵正则化域适应与目标数据关联关系约束获得的结果；“－ mixup”是仅使用 MMD 特征对齐约束和熵正则化域适应与目标数据关联关系约束获得的结果；“－ entropy”表示仅引入 mixup 特征对齐约束和 MMD 特征对齐约束获得的结果。由表 5 可以看出，在模型中加入 mixup 特征对齐约束后，在 2 个野生动物数据集上识别准确率均有大幅的提升；当在模型卷积层引入 MMD 特征对齐约束后，在 2 个野生动物数据集上识别准确率均有一定的提升；当引入熵正则化域适应与目标数据关联关系约束策略后，在 2 个野生动物数据集上识别准确率能进一步提升。这些实验结果表明，本研究提出的特征对齐约束可以有效减轻域偏移带来的影响，提升模型的识别性能。

表 3　在 R → C 迁移任务上的实验结果
Table 3　Experimental results on the R → C transfer task　%

物种 Species	ResNet50[18]	MMD[11]	DCORAL[10]	CDAN[17]	DJAN[5]	本模型 Ours model
熊 Bear	93.2	91.2	79.7	93.5	93.2	99.5
象 Elephant	96.3	99.7	97.5	99.0	99.2	99.7
长颈鹿 Giraffe	98.3	96.2	95.8	96.0	98.1	99.4
狮子 Lion	60.0	87.5	81.3	79.7	86.9	97.3
浣熊 Raccoon	47.0	88.9	85.5	87.2	91.4	99.5
松鼠 Squirrel	65.5	89.3	81.8	96.2	96.0	99.7
虎 Tiger	54.9	61.3	94.8	55.3	77.5	99.8
斑马 Zebra	99.4	99.2	99.4	99.4	99.6	99.6

2.3 模型参数灵敏度分析

如图 4 所示，本实验研究了参数 α、β、γ 和 λ 在迁移识别任务 R→C 和 C→R 上的灵敏度。本研究采用的策略是：如果要测定参数 α 的灵敏度，则要固定参数 β、γ 和 λ 的数值，进而获得参数 α 的最优取值，反之亦然。蓝色曲线表示在 R→C 迁移任务上不同参数值的野生动物图像识别准确率，红色曲线表示在 C→R 迁移任务上不同参数值的野生动物图像识别准确率，从曲线图中可以观察到：1）参数 α、γ 和 λ 在一定范围内 [0.1, 0.9] 时，本模型的识别准确率在小范围内波动。2）当 α、γ 和 λ 三个参数进一步逐渐增大时本模型的识别性能会下降。3）参数 β 随着数值的逐渐增大时，本模型的识别性能先波动性增大而后逐渐趋于平稳。4）综上所述，参数 $\alpha \in (0.5,0.7)$、$\beta \in [0.3,0.4)$ $\gamma \in (0.4,0.5]$ 和 $\lambda \in (0.5,0.7)$ 是合理的取值范围，因此在本实验中，参数 α、β、γ 和 λ 分别取值为 0.6、0.3、0.5 和 0.6。

表 4 在 EN 野生动物数据集上 F1 评价准则实验结果
Table 4 Experimental results for F1 evaluation criteria on the EN wildlife dataset

模型 Models	识别任务 Recognition task				平均 F1 /%
	ES → NS	F1 /%	NS → ES	F1 /%	
ResNet50[18]	25.6		47.9		36.8
DCORAL[10]	33.7		43.8		38.8
CDAN[17]	35.4		43.2		39.3
DJAN[5]	35.4		61.6		48.5
ALDA[8]	46.9		60.2		53.6
本模型 Our model	61.5		77.1		69.3

表 5 在 EN 和 RC 野生动物数据集上的消融实验结果
Table 5 Ablation study results on the EN and RC wildlife datasets

模型 Models	识别任务 Recognition task		平均准确率 Average accuracy /%	识别任务 Recognition task		平均准确率 Average accuracy /%
	ES → NS 准确率 Accuracy /%	NS → ES 准确率 Accuracy /%		R → C 准确率 Accuracy /%	C → R 准确率 Accuracy /%	
− mmd	77.8	80.0	78.9	92.8	93.9	93.4
− mixup	39.7	54.6	47.2	91.6	80.5	86.1
− entropy	72.4	82.3	77.4	96.0	94.3	95.2
本模型 Our model	78.4	85.0	81.7	99.3	97.2	98.3

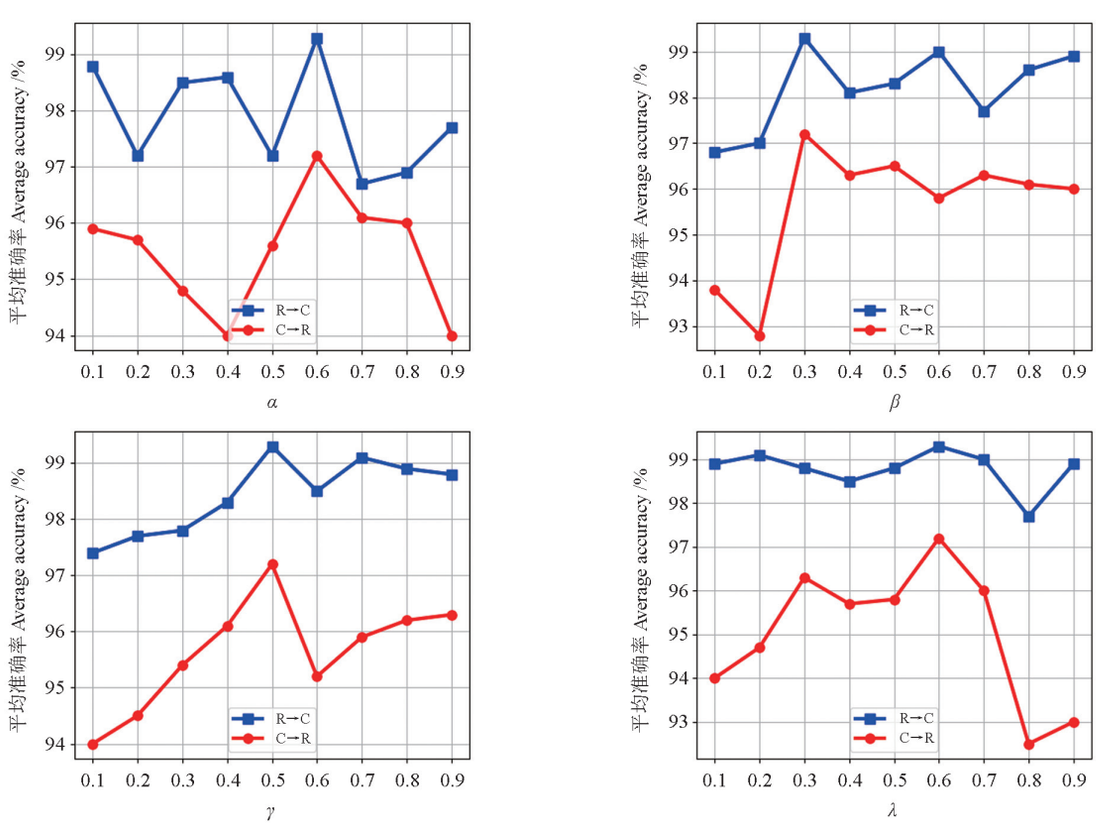


图 4 参数灵敏度实验分析
Fig. 4 Experiment analysis of parameter sensitivity

2.4　模型特征可视化结果分析

为了验证本模型在跨域提取特征方面的有效性，在Camera_Trap数据集上进行特征映射可视化，图 5 所示展示了 ResNet50、MMD 和本模型的可视化结果。

从图 5 中可以看出，本模型可以有效捕捉目标域中更具有判别性的语义特征，从定性的角度进一步验证了模型的有效性。这一发现从特征分布层面为模型的优越性提供了直观解释，与表 1 显示的定量评估结果形成相互印证。综上所述，本模型融合卷积特征对齐与全连接层特征对齐适配机制，在可迁移特征表示能力方面较基线模型取得显著提升。野生动物图像特征映射可视化分析与定量实验的共同验证结果表明，本模型在跨域视觉任务中具有较好的应用潜力，特别是在处理域间分布差异较大、语义信息复杂的场景时表现出明显优势。

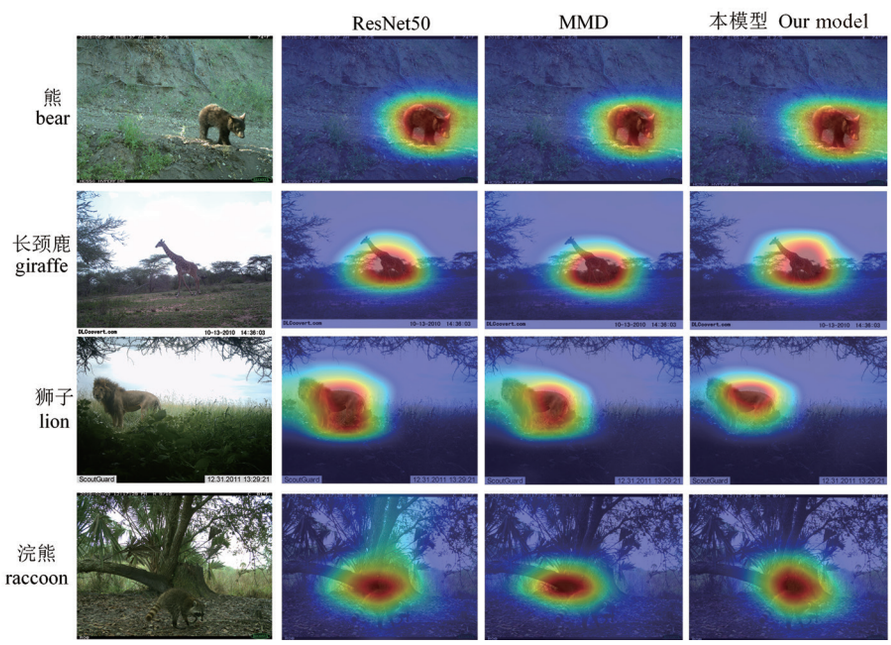


图 5　在 Camera_Trap 域上的特征映射可视化结果

Fig. 5　Visualization results of feature maps on Camera_Trap domain

3　结　论

针对野生动物图像识别的显著特点导致识别性能下降的问题，本研究提出了一种深度卷积域适应的野生动物图像识别模型，为提升野外环境下无标签野生动物物种识别的泛化性提供了有效的方法，具有重要的理论意义和应用价值。首先，引入了一种基于最大均值差异的卷积特征对齐方式，可以有效迫使模型学习到更好的卷积特征表示来支持全连接层的域对齐。其次，提出了一种基于 mixup 概率分布的特征对齐模块，提升深度网络学习高层语义信息的能力，且减少了无用背景信息的影响。最后，提出了熵正则化域适应与目标数据关联关系约束策略，促使类别间的低密度分离，进一步提高了域适应模型的迁移增益。本研究所提方法和现有方法在 RC 和 EN 两个野生动物数据集上进行了一系列的实验，实验结果表明，与基线模型相比，本文模型的野生动物图像识别准确率得到了显著提升。

4　讨　论

为了解决因光照、背景、拍摄尺度和物种差异等引起的域偏移易导致模型识别性能下降的问题，本研究提出了一种深度卷积域适应的野生动物图像识别模型。该模型基于 ResNet50 网络提取野生动物的图像特征，并引入最大均值差异约束来获取野生动物图像的卷积层域不变特征，然后采用 mixup 概率分布构建全连接层特征对齐模型，提升模型学习高层次语义信息的能力，同时利用熵正则化域适应与目标数据关联关系约束策略，促使类别间的低密度分离，最后构建深度卷积域适应的野生动物图像识别模型。在 2 个野生动物数据集上的实验结果表明，本模型在野生动物识别性能上明显优于基线模型，验证了通过卷积层域适应优化特征表示以增强全连接层对齐，同时在全连接层域适应中语义信息可以指导卷积层特征表示的域适应。

尽管本模型在野生动物图像识别任务中取得

了不错的效果，但仍有如下两方面需进一步开展研究：1）多模态特征融合。针对物种分布相似的野生动物物种识别问题，寻找其他具有物种差异性的特征，如结合图像、生境等信息以实现野生动物相似物种的有效区分；2）小样本学习[24]与域适应结合。在野生动物样本稀缺的场景下，通过小样本元学习框架构建跨域特征原型，耦合对抗域适应与对比度量学习，实现源域知识迁移与目标域稀疏样本的特征解耦，最终实现跨域小样本物种分类的泛化性。

参考文献：

[1] 吴慧 , 徐学红 , 冯晓娟 , 等 . 全球视角下的中国生物多样性监测进展与展望 [J]. 生物多样性 ,2022,30(10):196-210.
WU H, XU X H, FENG X J, et al. Progress and prospect of China biodiversity monitoring from a global perspective[J]. Biodiversity Science,2022,30(10):196-210.

[2] 陈建促 , 王越 , 朱小飞 , 等 . 融合多特征图的野生动物视频目标检测方法 [J]. 计算机工程与应用 ,2020,56(7):221-227.
CHEN J C, WANG Y, ZHU X F, et al. Wild animal video object detection method combining multi-feature map[J]. Computer Engineering and Applications,2020,56(7):221-227.

[3] 张军国 , 程浙安 , 胡春鹤 , 等 . 野生动物监测光照自适应 Retinex 图像增强算法 [J]. 农业工程学报 ,2018,34(15):183-189.
ZHANG J G, CHENG Z A, HU C H, et al. Adaptive image enhancement algorithm for wild animal monitoring based on Retinex theory[J]. Transactions of the Chinese Society of Agricultural Engineering,2018,34(15):183-189.

[4] 孙工棋 , 张明祥 , 雷光春 . 黄河流域湿地水鸟多样性保护对策 [J]. 生物多样性 ,2020,28(12):1469-1482.
SUN G Q, ZHANG M X, LEI G C. Wetland water bird biodiversity conservation strategies in the Yellow River basin[J]. Biodiversity Science,2020,28(12):1469-1482.

[5] ZHANG C C, ZHANG J G. DJAN: deep joint adaptation network for wildlife image recognition[J]. Animals,2023,13:3333.

[6] ZHANG Q Y, YI X L, GUO J L, et al. A few-shot rare wildlife image classification method based on style migration data augmentation[J]. Ecological Informatics,2023,77:102237.

[7] 张长春 , 李大方 , 张军国 . 基于 Wasserstein 距离和相关对齐迁移学习的野生动物图像识别方法 [J]. 林业科学 ,2024,60(8):25-32.
ZHANG C C, LI D F, ZHANG J G. Wildlife images recognition method based on Wasserstein distance and correlation alignment transfer learning[J]. Scientia Silvae Sinicae,2024,60(8):25-32.

[8] 赵恩庭 , 张长春 , 赵海涛 , 等 . 基于对抗学习的野生动物图像域适应识别方法 [J]. 林业科学 ,2025,61(4):1-8.
ZHAO E T, ZHANG C C, ZHAO H T, et al. A recognition method of domain adaptation for wildlife images based on adversarial learning[J]. Scientia Silvae Sinicae,2025,61(4):1-8.

[9] LONG M S, CAO Y, CAO Z J, et al. Transferable representation learning with deep adaptation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2018,41(12):3071-3085.

[10] SUN B C, SAENKO K. Deep coral: correlation alignment for deep domain adaptation[C]//Proceedings of the 14th European Conference on Computer Vision, Amsterdam, Oct 8th-16th, 2016. Amsterdam: Springer,2016:443-450.

[11] TZENG E, HOFFMAN J, ZHANG N, et al. Deep domain confusion: maximizing for domain invariance[J]. arXiv abs, 2014:1412.3474.

[12] PENG X C, BAI Q X, XIA X D, et al. Moment matching for multi-source domain adaptation. Proceedings of the 17th IEEE International Conference on Computer Vision, Seoul, Oct 27th-Nov 2nd, 2019. Seoul: IEEE, 2019:1406-1415.

[13] TABAK M A, NOROUZZADEH M S, WOLFSON D W, et al. Machine learning to classify animal species in camera trap images: applications in ecology[J]. Methods in Ecology and Evolution,2019,10:585-590.

[14] YOUSIF H, KAYS R, HE Z. Dynamic programming selection of object proposals for sequence-level animal species classification in the wild. IEEE Transactions on Circuits and Systems for Video Technology,2019,20.

[15] XU B R, ZENG Z G, LIAN C, et al. Few-shot domain adaptation via mixup optimal transport[J]. IEEE Transactions on Image Processing,2022,31:2518-2528.

[16] GRANDVALET Y, BENGIO Y, et al. Semi-supervised learning by entropy minimization[C]//Proceedings of the 18th Advances in Neural Information Processing Systems, Vancouver, Dec, 2005. Vancouver: MIT,2005:529-536.

[17] LONG M S, CAO Z J, WANG J M, et al. Conditional adversarial domain adaptation[C]//Proceedings of the 32nd Advances in Neural Information Processing Systems, Montreal, Dec 3rd-8th, 2018. Montreal: Springer,2018,31.

[18] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, Jun 26th-Jul 1st, 2016. Las Vegas: IEEE,2016:770-778.

[19] RUSSAKOVSKY O, DENG J, SU H, et al. ImageNet large scale visual recognition challenge[J]. International Journal of Computer Vision,2015,115:211-252.

[20] GANIN Y, LEMPITSKY V. Unsupervised domain adaptation by backpropagation[C]//Proceedings of the 32nd International

Conference on Machine Learning, Lile, Jul 6th-11st, 2015. Lile: PMLR,2015:1180-1189.

[21] ZHU Y C, ZHUANG F Z, WANG J D, et al. Deep subdomain adaptation network for image classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021,32(4):1713-1722.

[22] CUI S H, WANG S H, ZHUO J B, et al. Towards discriminability and diversity: batch nuclear-norm maximization under label insufficient situations[C]//Proceedings of the 31st IEEE Conference on Computer Vision and Pattern Recognition, Seattle, Jun 14th-19th, 2020. Seattle: IEEE,2020:3940-3949.

[23] CHEN L, CHEN H A, WEI Z X, et al. Reusing the task-specific classifier as a discriminator: discriminator-free adversarial domain adaptation[C]//Proceedings of the 33rd IEEE Conference on Computer Vision and Pattern Recognition, New Orleans, Jun 19th-24th, 2022. New Orleans: IEEE,2022:7171-7180.

[24] ZHENG Z J, WU H, LYU L S, et al. ICCL: independent and correlative correspondence learning for few-shot image classification[J]. Knowledge-Based Systems,2023,266:110412.

[本文编校：吴　彬]

（上接第 102 页）

[23] 单凯丽 . 基于气候变化下的杉木人工林优势木单木生长模型研究 [D]. 南昌 : 江西农业大学 ,2020.
SHAN K L. Study on individual tree growth model of dominant trees in Chinese fir plantation based on climate change[D]. Nanchang: Jiangxi Agricultural University,2020.

[24] 吴旭平 , 吕勇 , 张雄清 , 等 . 基于立地因子的杉木人工林断面积生长混合效应模型研究 [J]. 林业资源管理 ,2021(2):75-82.
WU X P, LYU Y, ZHANG X Q, et al. Research on growth mixed effect model for basal area of *Cunninghamia lanceolata* plantation based on site factors[J]. Forest Resources Management, 2021(2):75-82.

[25] ZHU G Y, HU S, CHHIN S, et al. Modelling site index of Chinese fir plantations using a random effects model across regional site types in Hunan Province, China[J]. Forest Ecology and Management,2019,446:143-150.

[26] FU L Y, LEI X D, SHARMA R P, ZHU G Y, et al. Comparing height-age and height-diameter modelling approaches for estimating site productivity of natural uneven-aged forests[J]. Forestry,2018,91:419-433.

[27] 汤维 , 黄朗 , 杨浩 , 等 . 基于平均优势木胸径的湖南杉木人工林立地质量评价模型 [J]. 中南林业科技大学学报 , 2024,44(5):26-34.
TANG W, HUANG L, YANG H, et al. Site quality evaluation model of Chinese fir plantation in Hunan based on the DBH of average dominant trees[J]. Journal of Central South University of Forestry & Technology,2024,44(5):26-34.

[28] 郭常酉 , 郭宏仙 , 王宝华 . 基于气候因子的杉木单木胸径生长模型构建 [J]. 南京林业大学学报 (自然科学版),2023,47(1): 47-56.
GUO C Y, GUO H X, WANG B H, Study on increment model of individual-tree diameter of *Cunninghamia lanceolata* in consideration of climatic factors[J]. Journal of Nanjing Forestry University (Natural Sciences Edition),2023,47(1):47-56.

[29] 张宁 , 张怀清 , 林辉 , 等 . 基于竞争指数的杉木林分生长可视化模拟研究 [J]. 林业科学研究 ,2013,26(6):692-697.
ZHANG N, ZHANG H Q, LIN H, et al. Visual simulation of growth process in *Cunninghamia lanceolata* based on competition index[J]. Forest Research,2013,26(6):692-697.

[30] 徐雪蕾 . 间伐对杉木人工林的生长调控作用研究 [D]. 北京 : 北京林业大学 ,2020.
XU X L. Regulation of thinning on the tree growth in Chinese fir plantations[D]. Beijing: Beijing Forestry University,2020.

[本文编校：吴　彬]