

基于子网对抗的多源域适应辐射源个体识别方法

李 林¹ 王 闯¹ 杜文博¹ 俞 璐¹ 李 宁¹
 LI Lin WANG Chuang DU Wenbo YU Lu LI Ning

摘 要

基于迁移学习的辐射源个体识别方法近年来受到广泛关注和深入研究。然而, 这些方法通常假设存在一个已标记的源域和一个未标记的目标域, 往往忽视了源域之间分布的多样性和复杂性。文章旨在研究基于对抗的多源域适应辐射源个体识别方法, 提出了一种基于子网对抗的多源域适应辐射源个体识别算法, 并设计了一个多源子网对抗网络模型 (multi-source subnet adversarial network, MS-SAN)。结合生成对抗网络的博弈思想, 采用对抗手段对齐各个源域与目标域类别特征, 以最大程度提取与域相关的特征信息。根据各子网对抗训练后源域和目标域类别特征的相似程度, 赋予不同权重, 最后采用加权组合的方法对目标样本进行预测。通过使用 ORACLE 射频指纹数据集对多源子网对抗网络模型进行验证, 实验证明该方法相比其他方法具有更高的识别率。

关键词

迁移学习; 辐射源个体识别; 多源域适应; 生成对抗网络

doi: 10.3969/j.issn.1672-9528.2025.12.016

0 引言

辐射源个体识别 (special emitter identification, SEI), 也称为特定辐射源识别, 是快速精准识别敌方通信设备的一种侦察手段^[1-2], 通过提取接收信号上能够体现辐射源个体差异的射频指纹特征 (radio frequency fingerprint, RFF) 实现对目标辐射源个体的分类。

在复杂的现实电磁场景中, 获取源域信号时受到采集环境和接收设备等诸多条件的影响, 使得每次信号采集的环境无法始终保持一致, 从而导致各源域彼此之间的特征分布各不相同。当前已有研究将迁移学习的域适应方法引入辐射源个体识别任务中^[3-4], 但大部分关于域适应方法的研究主要集中在单源域适应, 即只考虑一个已标记的源域和一个未标记的目标域。直接使用现有的单源域适应方法在面临多个特征分布不同的源域时可能不适用, 因为这样训练出的模型往往难以充分学习到每个源域和目标域共有特征。

本文提出的基于对抗的多源域适应方法是通过对齐多个源域与目标域之间的类别特征, 使多个源域与目标域的类别特征分布尽可能接近, 以消除域偏移带来的负面影响, 从而减小目标泛化误差。基于对抗的思想是域适应方法中常用的特征对齐策略之一, 采用生成对抗网络 (generative adversarial network, GAN) 的原理来减小源域和目标域之间的分布差异^[5]。通过对抗性训练, 模型可以在源域和目标域

中提取出具有相似性的域不变特征, 即域判别器无法准确区分特征提取器提取到的域不变特征来自源域还是目标域。在这种情况下, 从源域和目标域提取到的域不变特征能够很好地对齐。训练模型的过程就是域判别器和特征提取器之间博弈的过程。

本文主要研究如何在不同特征分布条件下提取各个域的辐射源独特的类别特征, 并以此构建一种端到端的深度神经网络模型, 称为多源子网对抗网络 (multi-source subnet adversarial network, MS-SAN)。具体工作和主要创新点如下:

(1) 提出基于对抗的多源域适应辐射源个体识别算法, 并在深度网络 MS-SAN 模型中设计 3 个模块, 即特征提取模块、子网对抗模块和全域约束模块, 对齐各源域与目标域类别特征的同时, 尽可能提取域特征信息;

(2) 在 ORACLE 射频指纹标准数据集上验证本文提出的方法的有效性。

1 基于子网对抗的多源域适应算法

1.1 定义

多源域适应是指利用多个特征不同分布的样本训练泛化性能较强的模型, 并应用于具有相同任务的目标领域中。首先对多源域适应进行形式化定义, 对于第 j 个源域 $D_{s_j} = \{(x_i^{s_j}, y_i^{s_j})\}_{i=1}^{n_j}$, $x_i^{s_j}$ 为第 i 个输入样本; $y_i^{s_j}$ 为样本 $x_i^{s_j}$ 的真实标签; n_j 为第 j 个源域 D_{s_j} 的样本个数, 此外将源域的集合定义

1. 陆军工程大学 江苏南京 210007

为 $D_s, D_s = \{D_{s_1}, D_{s_2}, \dots, D_{s_N}\}$, N 为源域数, 所有源域共享标签空间并表示为 $y^s \in \mathcal{Y}$, 且 $|\mathcal{Y}| = K$, K 为样本的类数。在无监督域适应条件下, 目标域可定义为 $D_t = \{(x'_i)\}_{i=1}^{n_t}$, n_t 为目标域样本个数, 并与源域共享标签空间, 可表示为 $y' \in \mathcal{Y}$ 。多源域适应的目的是学习多个源域可迁移的知识, 对未标记的目标域样本 x'_i 进行预测, 得到置信度较高的预测标签 $\hat{y}'_i$ 。

1.2 整体思路

1.2.1 多源域间特征差异

由于各个源域和目标域样本的特征分布各不相同, 为研究其间的差异需要保证各域特征空间的一致, 因此需将所有域映射到同一特征空间 $\mathcal{Z}$ 上, 在特征空间 $\mathcal{Z}$ 内实现各域间的特征对齐。

1.2.2 多源域间域不变特征一致性

从特征解耦的角度分析, 映射到特征空间 $\mathcal{Z}$ 上的特征主要会受到两种因素的影响。一是样本本身具有的属性, 在所有域中该属性不会发生变化, 是在所有域中共有的特征, 也就是本文研究的辐射源固有的特征, 这种特征与分类相关, 主要作用于样本内部, 不会受到其他因素的影响, 当环境发生变化时这种属性也不会发生变化, 本文称这种特征为类别特征; 二是每个域都有不同于其他域的属性, 这种属性会造成样本在不同域下具有不同的特征分布, 即域的属性发生变化时样本会有不同的表现形式, 是每个域特有的特征, 这种特征与分类无关, 只作用于域本身, 域发生变化这种特征也会发生变化, 本文将这种受域变化影响的特征称之为域特征。本文设计不同的特定领域的特征提取器, 对两种特征进行提取, 并使得两种特征差异最大化。

1.2.3 多源域与目标域间域不变特征一致性

目标域依次与各个源域在其特定领域的类别空间上进行对齐, 并使用每个源域的类别特征训练各源域特定领域的分类器。此外, 为了保证目标域样本进入各分类器具有相同的预测, 各分类器之间也应进行对齐。

1.3 MS-SAN 网络结构

1.3.1 网络整体框架

本文提出一种多源子网对抗网络 (multi-source subnet adversarial network, MS-SAN), 设计相应多源域适应算法对辐射源个体进行分类。如图 1 所示, 对于 N 个已标记源域, 将每个源域与目标域组合形成一个子网, 共计 N 个子网。MS-SAN 网络架构由 3 个模块组成: 特征提取模块、子网对抗模块和全域约束模块。特征提取模块包含 1 个公共特征提取器 G 、 N 个源域类别特征提取器 $\{F_j^c\}_{j=1}^N$ 、1 个目标域类别特征提取器 F_t^c 、 N 个源域域特征提取器 $\{F_j^d\}_{j=1}^N$ 、1 个目标域域特征提取器 F_t^d 。

子网对抗模块包含 N 个子网判别器 $\{D_j\}_{j=1}^N$ 、 N 个子网分类器 $\{C_j\}_{j=1}^N$; 全域约束模块由 1 个全局域特征分类器 C_{global} 组成。




图 1 MS-SAN 网络框架图

1.3.2 特征提取模块

公共特征提取器: 公共特征提取器 G 的作用是通过学习一个 $g(\cdot)$ 将所有域从原始的特征空间映射到统一的特征空间, 用于提取多个源域和目标域的公共表示, 并使用 ResNet-50 模型作为特征提取器。

类别特征提取器: 为各个源域设计了 N 个源域类别特征提取器 $\{F_j^c\}_{j=1}^N$, 还为目标域设计 1 个目标域类别特征提取器 F_t^c 。目的是让目标域的类别特征混淆各源域的子网判别器, 因此目标域类别特征与各个源域类别特征尽可能保持一致, 保证类别特征不会受到其他外界因素的影响和干扰, 类别特征不会随着域变化而变化, 并以此作为辐射源个体识别分类的依据, 将类别特征的映射函数记为 $f^c(\cdot)$ 。

域特征提取器: 与类别特征提取器并列设置了 N 个源域域特征提取器 $\{F_j^d\}_{j=1}^N$ 、1 个目标域域特征提取器 F_t^d 。目的是提取各源域和目标域的域特征, 学习不同域独有的域信息, 即造成各域分布不同的主要原因, 不同的域具有不同的域特征, 将域特征的映射函数设为 $f^d(\cdot)$ 。

特征提取模块训练过程:

(1) 对于第 j 个源域 D_s 和目标域 D_t , 首先使用公共特征提取器提取源域样本 x^s 和目标域样本 x' 在统一空间上的源域特征 $g(x^s)$ 和目标域特征 $g(x')$;

(2) 分别将 $g(x^s)$ 和 $g(x')$ 进入各自领域的类别特征提取器和域特征提取器, 提取到 $f_j^c[g(x^s)]$ 、 $f_j^d[g(x^s)]$ 、 $f_t^c[g(x')]$ 和 $f_t^d[g(x')]$;

(3) 在每个子网的内部设置一个正则化项用来表示类别特征和域特征间的差异, 具体可由均方误差损失函数表示为:

$$\mathcal{L}_{\text{mse}} = \frac{1}{N+1} \left(\sum_{j=1}^N \|f_j^c(g(x^s)) - f_j^d(g(x^s))\|_2^2 + \|f_t^c(g(x')) - f_t^d(g(x'))\|_2^2 \right) \quad (1)$$

1.3.3 子网对抗模块

子网判别器：设计子网判别器 $\{D_j\}_{j=1}^N$ 的目的是通过学习来区分类别特征的来源是源域还是目标域，特征提取模块中的类别特征提取器通过学习具有相同类别特征来混淆子网判别器，将子网判别器输出记为 $d(\cdot)$ 。子网判别器与类别特征提取器相互博弈的训练过程即本文子网对抗阶段。

子网分类器：子网分类器 $\{C_j\}_{j=1}^N$ 用于对有标记源域样本的分类以及对无标记目标域样本的预测。训练后的子网对抗模块可以对类别特征进行区分，而且能够使所有源域的类别特征与目标域类别特征尽可能具有一致的特征表示。

子网对抗训练过程：赋予各源域和目标域类别特征提取器提取到 $f_j^c[g(x^{s_j})]$ 和 $f_j^c[g(x^t)]$ 域判别标签，所有源域的域判别标签设置为 $y_{disc}^{s_j}=1$ ，目标域的域判别标签设置为 $y_{disc}^t=0$ 。

(1) 分别将各自源域样本的类别特征 $f_j^c[g(x^{s_j})]$ 和目标域样本类别特征的 $f_j^c[g(x^t)]$ 进入各子网的子网判别器 D_j 和子网分类器 C_j ，各子网的对抗损失表示为：

$$\mathcal{L}_{adv}^j = \frac{1}{n_{s_j}} \sum_{i=1}^{n_{s_j}} \log[1 - d_j(f_j^c[g(x_i^{s_j})])] + \frac{1}{n_t} \sum_{i=1}^{n_t} \log[d_j(f_j^c[g(x_i^t)])] \quad (2)$$

所有 N 子网的总体对抗损失表示为：

$$\mathcal{L}_{adv} = \frac{1}{N} \sum_{j=1}^N \mathcal{L}_{adv}^j \quad (3)$$

(2) 每个子网判别器训练的过程引入结构梯度反转层 (gradient reversal layers, GRL)，在类别特征提取器和子网判别器之间，目的是在反向传播过程中梯度方向自动取反，在前向传播过程中保持恒等不变，实现了类似于 GAN 的对抗损失。

(3) 将每个子网分类器 C_j 设置为 softmax 分类函数，记为 $c(\cdot)$ ，每个子网类别特征提取器提取到的特征作为每个分类器的输入，使用交叉熵分类损失，即：

$$\mathcal{L}_{cls} = \frac{1}{n_{s_j} \times N} \sum_{j=1}^N \sum_{i=1}^{n_{s_j}} J[c_j(f_j^c[g(x_i^{s_j})]), y_i^{s_j}] \quad (4)$$

由于每个子网对应一个分类器，因此对目标域样本的最终预测可通过对所有分类器输出结果的加权组合得到，即：

$$p^t = \sum_{j=1}^N \omega_j p^{t_j} \quad (5)$$

式中： $p^{t_j} \in \mathbf{R}^K$ ，表示目标域样本在第 j 个子网分类器的预测概率向量； p^{t_j} 表示子网分类器 C_j 对目标域第 i 个样本 x_i^t 特征 $f_j^c[g(x_i^t)]$ 的预测概率，可表示为 $p^{t_j} = c_j(f_j^c[g(x_i^t)])$ ； ω_j 表示第 j 个子网预测权值，设置该权值的作用是判别第 j 个源域与目标域之间的相似程度，并以此计算每个样本的预测概率，最终输出准确的预测结果。 ω_j 的计算方法为：

$$\omega_j = \frac{\omega_j^{\text{sim}}}{\sum_{i=1}^N \omega_i^{\text{sim}}} \quad (6)$$

式中： ω_j^{sim} 表示第 j 个源域与目标域之间的相似程度，二者越相似， ω_j^{sim} 值越大。具体计算方法为：

$$\omega_j^{\text{sim}} = \frac{\mathcal{L}_{adv}^j}{\sum_{i=1}^N \mathcal{L}_{adv}^i} \quad (7)$$

1.3.4 全局约束模块

全局域特征分类器：1个全局域特征分类器 C_{global} 主要用于对域特征进行判别。每个样本不仅具有类标记，同样具有域标记，使用域标记对域特征分类，使得域特征提取器能够充分提取到相关域的特征。

全局约束模块训练过程：

(1) 在域特征提取器后，赋予源域样本和目标域样本域标记，将目标域的域标记设置为 $y_{\text{domain}}^t=0$ ，第 j 个源域的域标记设置为 $y_{\text{domain}}^{s_j}=j$ 。

(2) 全局约束模块对所有域的分类损失可表示为：

$$\mathcal{L}_{\text{domain}} = \frac{1}{N+1} \left(\frac{1}{n_{s_j}} \sum_{j=1}^N \sum_{i=1}^{n_{s_j}} J[c_{\text{global}}(f_j^d[g(x_i^{s_j})]), y_{\text{domain}}^{s_j}] + \frac{1}{n_t} \sum_{i=1}^{n_t} J[c_{\text{global}}(f_t^d[g(x_i^t)]), y_{\text{domain}}^t] \right) \quad (8)$$

1.3.5 深度网络总体损失

本文为解决存在多个不同分布的辐射源个体识别问题，提出一种多源子网对抗网络，设计了深度网络架 MS-SAN。该模型共有 3 个模块，即特征提取模块、子网对抗模块和全域约束模块，结合各模块的训练流程公式 (1) (3) (4) (8)，具体损失函数包含 4 部分：

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{cls}} - \lambda \mathcal{L}_{\text{adv}} - \gamma \mathcal{L}_{\text{mse}} + \beta \mathcal{L}_{\text{domain}} \quad (9)$$

式中： λ 、 γ 和 β 为平衡超参数。最小化分类损失 $\mathcal{L}_{\text{cls}}$ 的目的是使深度网络可以准确地对源域样本进行分类，最大化对抗损失 $\mathcal{L}_{\text{adv}}$ 可以使各子网判别器能够辅助类别特征提取器提取到域不变特征，最大化各子网络的类别特征和域相关特征的差异 $\mathcal{L}_{\text{mse}}$ 可以减小二者中间的冗余和重复，最小化域特征分类器之间的差异损失 $\mathcal{L}_{\text{domain}}$ 保证样本域特征能够被准确分类。

1.3.6 算法流程

本节根据上一小节的深度模型设计，介绍基于子网对抗的多源域适应辐射源个体识别算法的训练步骤和测试步骤，具体算法流程如表 1 所示。

步骤 1：建立深度神经网络模型，MS-SAN 网络架构由 3 个模块组成：特征提取模块、子网对抗模块和全域约束模块；

步骤 2：输入 N 个源域样本集合 $\{(X^{s_j}, Y^{s_j})\}_{j=1}^N$ 和目标域样本 (X^t) ；步骤 3~16 为迭代训练过程。

表 1 算法流程

基于子网对抗的多源域适应算法

1. 建立 MS-SAN 网络
2. 输入 N 个源域 $\{(X^{s_j}, Y^{s_j})\}_{j=1}^N$ 和目标域 (X^T)
3. 迭代次数 T
4. for t in $1:T$ do
5. 对于每个源域随机选取 k 个样本 $\{(x_i^{s_j}, y_i^{s_j})\}_{i=1}^k$;
6. 选取 k 个目标域样本 $(x_i^t)_{i=1}^k$;
7. 将 x^{s_j} 和 x^t 输入 G , 映射到同一特征空间后得到特征 $g(x^{s_j})$ 和 $g(x^t)$;
8. 将 $g(x^{s_j})$ 输入 F_j^c 和 F_j^d , 得到类别特征 $f_j^c[g(x^{s_j})]$ 、域特征 $f_j^d[g(x^{s_j})]$;
9. 将 $g(x^t)$ 输入 F_t^c 和 F_t^d , 得到类别特征 $f_t^c[g(x^t)]$ 和域特征 $f_t^d[g(x^t)]$;
10. 使用式 (1) 最大化 $f_j^c[g(x^{s_j})]$ 与 $f_j^d[g(x^{s_j})]$ 、 $f_t^c[g(x^t)]$ 与 $f_t^d[g(x^t)]$ 之间差异;
11. $f_j^c[g(x^{s_j})]$ 、 $f_t^c[g(x^t)]$ 进入子网判别器, 使用 GRL 辅助训练各类别特征提取器, 使用式 (3) 计算对抗损失;
12. 类别特征 $f_j^c[g(x^{s_j})]$ 进入第 j 个子网分类器得到 $c_j(f_j^c[g(x^{s_j})])$, 使用式 (4) 计算分类损失;
13. 赋予 $f_j^d[g(x^{s_j})]$ 和 $f_t^d[g(x^t)]$ 域标记 $y_{\text{domain}}^{s_j} = j$ 、 $y_{\text{domain}}^t = 0$, 使用 C_{global} 对 $f_j^d[g(x^{s_j})]$ 和 $f_t^d[g(x^t)]$ 进行分类, 使用式 (8) 计算域特征分类损失;
14. 使用式 (5) 计算预测向量, 采取加权组合的策略完成对目标域样本的预测;
15. 使用公式 (9) 最小化整体损失, 更新 G 、 $\{F_j^c\}_{j=1}^N$ 、 F_t^c 、 $\{F_j^d\}_{j=1}^N$ 、 F_t^d 、 $\{D_j\}_{j=1}^N$ 、 $\{C_j\}_{j=1}^N$ 和 C_{global} ;
16. end for

2 实验与分析

2.1 实验条件

实验的硬件环境配置: CPU 为 Inter (R) Xeon (R) Silver 4210R CPU @2.40 GHz, GPU 为 Nvidia Geforce RTX 3090, 内存为 DDR60 G×2 000。

实验的软件环境配置: Python 版本为 3.9, Torch 版本为 2.0, CUDA 版本为 12.0。

2.2 数据处理

信噪比是衡量信号质量的重要指标, 原始信号在不同信噪比的信道下传输往往存在较大差异。在辐射源个体识别领域中, 信噪比的值越高, 表示信号相对于噪声更强, 更加接近于原始信号, 更容易被正确识别和处理。为了验证本文提出方法的有效性, 对 ORACLE 射频指纹数据集的原始 IQ 信

号分别添加 4 dB、8 dB 和 12 dB 的高斯白噪声, 模拟出不同信噪比的传输信道, 并将对应的 IQ 数据分别记为 $D_{4\text{ dB}}$ 、 $D_{8\text{ dB}}$ 和 $D_{12\text{ dB}}$, 将原始 IQ 数据记为 D_{RAW} 、 $D_{4\text{ dB}}$ 、 $D_{8\text{ dB}}$ 、 $D_{12\text{ dB}}$ 与 D_{RAW} 数据集的样本设置相同, 分别具有 16 类 IQ 数据, 标签设置为 0~15; 而后, 对每类的 IQ 数据进行截取, 每个截取后的样本维度设为 2×256 , 其中 2 代表 IQ 两路信号, 256 表示截取后的样本长度, 每类保留 2 000 个样本, $D_{4\text{ dB}}$ 、 $D_{8\text{ dB}}$ 、 $D_{12\text{ dB}}$ 与 D_{RAW} 分别具有 32 000 个样本。结合本文提出的多源域适应方法, 设置 4 个辐射源个体识别任务: $D_{4\text{ dB}}$ 、 $D_{8\text{ dB}}$ 、 $D_{12\text{ dB}} \rightarrow D_{\text{RAW}}$; $D_{4\text{ dB}}$ 、 $D_{8\text{ dB}}$ 、 $D_{\text{RAW}} \rightarrow D_{12\text{ dB}}$; $D_{4\text{ dB}}$ 、 $D_{12\text{ dB}}$ 、 $D_{\text{RAW}} \rightarrow D_{8\text{ dB}}$; $D_{8\text{ dB}}$ 、 $D_{12\text{ dB}}$ 、 $D_{\text{RAW}} \rightarrow D_{4\text{ dB}}$ 。左侧数据集作为多源域适应方法的源域, 训练时使用其真实标签; 右侧数据集作为目标域, 训练和测试时均不使用其真实标签, 用于训练和测试的目标域样本比值为 1:3。

2.3 参数设置

本节对 MS-SAN 网络训练时主要参数进行阐述。迭代次数 Iteration Count 为 10 000, 批量大小为 100, 优化器选择 Adam, 初始学习率设置为 0.001, 而后根据公式进行变化。

$$l_u = \frac{l_0}{(1 + \alpha \times u)^\eta} \quad (10)$$

式中: l_0 为初始学习率; l_u 为当前学习率; u 为当前迭代次数与总迭代次数的比值, $\alpha=10$, $\eta=0.75$ 。

式 (9) 中, 损失函数中的超参数 λ 、 γ 和 β 根据式 (11) 进行变化。

$$\lambda_u = \gamma_u = \beta_u = \frac{2}{\exp(-\alpha u)} - 1 \quad (11)$$

2.4 实验结果

当前, 很少有研究将多源域适应方法应用到辐射源个体识别任务中, 因此选取在其他领域均具有较好表现的单源域适应和多源域适应的代表性方法。单源域适应方法有: 基于分布差异的包括深度自适应网络 (deep adaptation network, DAN) [6]、基于关联对齐距离方法 (deep correlation alignment, D-CORAL) [7]、深度子领域自适应网络 (Deep subdomain adaptation network, DSAN) [8] 和多表示领域自适应网络 (multi-representation adaptation network, MRAN) [9], 以及基于对抗的领域对抗神经网络 (domain adversarial neural network, DANN) [10]、动态对抗适应网络 (dynamic adversarial adaptation network, DAAN) [11]。多源域适应方法有: 文献 [12] 提出的对齐分布和分类器的多源领域自适应方法 (multiple feature spaces adaptation network, MFSAN) 和文献 [13] 提出的深度鸡尾酒网络 (deep cocktail network, DCTN)。为了便于比较各种方法在本文数据上的识别准确率, 以及多源域

企业级场景中大模型应用开发工具的选型分析

杨 赛¹
YANG Sai

摘 要

2025 年，大模型技术已从概念走向量产，企业关注点不再是“能否用上大模型”，而是聚焦“如何快速、安全、低成本地实现落地”。当前低代码平台、云原生框架与模块化引擎三条技术路线并行，决策者亟需一份兼顾交付速度、治理成熟度与性能天花板的选型指南。文章通过对比 Dify、Spring AI Alibaba 与 LangChain4j 在全链路开发中的真实表现——从拖拽式模板、单 JAR 云原生到模块组件自由组合，逐一拆解三款工具在开发、治理、性能、观测及扩展维度的优缺点，旨在为中小型企业快速验证、中大型在线业务部署及超高并发场景深度定制三类需求，提供清晰的技术选型路径，帮助企业在有限资源内做出最优技术决策。

关键词

大模型开发工具；Java 生态；Dify；Spring AI Alibaba；LangChain4j

doi: 10.3969/j.issn.1672-9528.2025.12.017

0 引言

如今，人工智能已从概念验证阶段迈入深度应用时代。随着算力突破、算法革新与数据生态的协同发展，大模型技术快速应用到医疗、教育、制造等核心领域。这些拥有千亿级参数的智能系统，不仅能够通过自然语言交互完成复杂任务，更展现出解决现实问题的实际能力^[1]。

在面向企业级的应用场景中，Java 作为一种广泛采用的编程语言，凭借其稳定性和丰富的生态系统，成为了开发复杂业务逻辑和服务端应用的首选语言，目前 Java 语言仍是企

业开发语言的首选，这一现状为 AI 大模型的落地提供了广阔场景。近年来，随着 AI 技术的不断成熟及硬件成本的有效降低，AI 大模型在企业级应用中的普及成为必然趋势^[2]。因此，构建适用于 Java 生态系统的 AI 框架，满足企业级开发的需求，已成为亟待解决的关键问题。

然而，现有大模型开发工具的研究与实践仍存在多方面局限，难以支撑 Java 生态企业的科学选型：

一是研究聚焦国外非 Java 生态工具，Java 专属工具分析存在空白。当前学界对大模型开发工具的讨论多围绕 Python 生态的 LangChain、LlamaIndex 展开，极少涉及 Java 生态工具，这种“重 Python、轻 Java”的研究现状，导致 Java 技术型企

1. 浪潮软件股份有限公司 山东泰安 260000

[12] ZHU Y C, ZHUANG F Z, WANG D Q. Aligning domain-specific distribution and classifier for cross-domain classification from multiple sources[C]//AAAI'19/IAAI'19/ EAAI'19: Proceedings of the 33rd AAAI Conference on Artificial Intelligence and 31st Innovative Applications of Artificial Intelligence Conference and Ninth AAAI Symposium on Educational Advances in Artificial Intelligence. Palo Alto: AAAI Press, 2019: 5989-5996.

[13] XU R J, CHEN Z L, ZUO W M, et al. Deep cocktail network: multi-source unsupervised domain adaptation with category shift[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway: IEEE, 2018: 3964-3973.

【作者简介】

李林（1992—），男，黑龙江佳木斯人，硕士研究生，研究方向：深度学习、迁移学习。

王闯（1995—），男，安徽滁州人，硕士研究生，研究方向：迁移学习、模式识别。

杜文博（2002—），男，河南驻马店人，硕士研究生，研究方向：无线网络、机器学习。

俞璐（1973—），女，吉林长春人，博士，副教授，研究方向：多媒体信息处理、模式识别、图像处理等。

李宁（1991—），男，江苏连云港人，硕士研究生，研究方向：智能化训练。

（收稿日期：2025-07-03 修回日期：2025-12-16）