

基于多核最大均值差异迁移学习的WLAN室内入侵检测方法

周牧^① 李焱铨^{*①} 谢良波^① 蒲巧林^② 田增山^①

^①(重庆邮电大学通信与信息工程学院 重庆 400065)

^②(香港浸会大学计算机系 香港 999077)

摘要: 无线局域网(WLAN)室内入侵检测技术是目前智能检测领域的研究热点之一, 而传统基于数据库构建的入侵检测技术没有考虑复杂室内环境中WLAN信号的时变性, 从而导致WLAN室内入侵检测系统的鲁棒性较差。为了解决这一问题, 该文提出一种基于多核最大均值差异(MKMMMD)迁移学习的WLAN室内入侵检测方法。该方法首先利用离线有标记和在线伪标记的接收信号强度(RSS)特征来分别构建源域和目标域; 其次, 通过构造最优迁移矩阵以最小化源域和目标域RSS特征混合分布之间的MKMMMD; 再次, 利用迁移后的源域RSS特征与对应标签来训练分类器, 并将其用于对迁移后的目标域RSS特征进行分类以得到目标域标签集; 最后, 迭代更新目标域标签集直至算法收敛, 进而实现对目标环境的入侵检测。实验结果表明, 该文所提方法在保证较高检测精度的同时, 能够有效克服信号时变性对检测性能的影响。

关键词: 室内入侵检测; 多核最大均值差异; 迁移学习; 最优迁移矩阵; 无线局域网

中图分类号: TN911.23

文献标识码: A

文章编号: 1009-5896(2020)05-1149-09

DOI: 10.11999/JEIT190358

WLAN Indoor Intrusion Detection Approach Based on Multiple Kernel Maximum Mean Discrepancy Transfer Learning

ZHOU Mu^① LI Yaoping^① XIE Liangbo^① PU Qiaolin^② TIAN Zengshan^①

^①(School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

^②(Department of Computer Science, Hong Kong Baptist University, Hong Kong 999077, China)

Abstract: Wireless Local Area Network (WLAN) indoor intrusion detection technique is one of the current research hotspots in the field of intelligent detection, but the conventional database construction based intrusion detection technique does not consider the time-variant property of WLAN signal in the complicated indoor environment, which results in the low robustness of WLAN indoor intrusion detection system. To address this problem, a Multiple Kernel Maximum Mean Discrepancy (MKMMMD) transfer learning based WLAN indoor intrusion detection approach is proposed. First of all, the offline labeled and online pseudo-labeled Received Signal Strength (RSS) features are used to construct source and target domains respectively. Second, the optimal transfer matrix is constructed to minimize the MKMMMD of the joint distributions of RSS features in source and target domains. Third, a classifier trained from the transferred RSS features and the corresponding labels in source domain is used to classify the transferred RSS features in target domain, and meanwhile the label set corresponding to target domain is obtained. Finally, the label set corresponding to target domain is updated in an iterative manner until the proposed algorithm converges, and then the intrusion detection in target environment is achieved. The experimental results indicate that the proposed approach is able to preserve high detection accuracy as well as overcome the impact of time-variant signal property on the detection performance.

Key words: Indoor intrusion detection; Multiple Kernel Maximum Mean Discrepancy (MKMMMD); Transfer learning; Optimal transfer matrix; Wireless Local Area Network (WLAN)

收稿日期: 2019-05-21; 改回日期: 2019-11-27; 网络出版: 2019-12-18

*通信作者: 李焱铨 liyaopingna@foxmail.com

基金项目: 国家自然科学基金(61771083), 重庆市基础与前沿研究计划基金(cstc2017jcyjAX0380), 重庆市研究生科研创新项目(CYS18240)

Foundation Items: The National Natural Science Foundation of China (61771083), The Fundamental and Frontier Research Project of Chongqing (cstc2017jcyjAX0380), The Postgraduate Scientific Research and Innovation Project of Chongqing (CYS18240)

1 引言

随着人们对室内位置服务(Location-Based Service, LBS)需求的不断增加,室内入侵检测技术在智能安防、老年看护和灾后救援等领域起着不可或缺的作用。现有的室内入侵检测技术主要基于视频监控^[1]、红外探测^[2]、传感器网络^[3]和无线局域网(Wireless Local Area Network, WLAN)感知^[4]等。基于视频监控的室内入侵检测技术对光照条件有较高要求,其在夜晚或恶劣光照条件下的检测性能较差;基于红外探测的室内入侵检测技术不受光照条件的影响,但其检测性能依赖于发射机与接收机之间视距(Line-Of-Sight, LOS)路径的可靠性;基于传感器网络的室内入侵检测技术需要在目标环境中部署大量传感器节点,其较高的部署和维护成本限制了该技术的推广应用;相比而言,基于WLAN感知的室内入侵检测技术具有易部署、覆盖范围广且无需特殊硬件设备等优势,将逐渐成为室内入侵检测技术的研究热点。

马里兰大学Youssef等人^[5]于2007年首次提出了基于WLAN感知的室内入侵检测的概念,其在检测过程中无需被检测目标携带任何特殊设备^[6]且检测过程包括离线和在线两个阶段。在离线阶段,系统根据每个监测点(Monitor Point, MP)处采集来自不同接入点(Access Point, AP)的RSS数据构建离线数据库;而在线阶段,则将新采集的RSS数据与离线数据库进行匹配,以判断环境中是否存在目标入侵。基于此,文献^[7]利用非参数核密度估计方法来计算离线静默数据的检测门限,使得当在线数据特征超过该检测门限时系统判断为存在目标入侵。考虑单一数据特征在分类器训练方面存在的局限性,文献^[8]利用基于多特征的概率神经网络(Probabilistic Neural Network, PNN)来提高入侵检测的精度。为了实现多目标入侵检测,文献^[9]通过对不同数目入侵者入侵不同区域的RSS数据进行主成分分析(Principal Component Analysis, PCA),同时利用数据主成分对模式识别神经网络(Pattern Recognition Neural Network, PRNN)进行训练并将其用于多目标入侵检测与定位。考虑不同人体运动姿态所导致入侵检测性能下降的问题,文献^[10]利用信道状态信息(Channel State Information, CSI)波动特征来训练用于人体目标入侵及运动姿态检测的隐马尔可夫模型(Hidden Markov Model, HMM)。文献^[11]通过提取细粒度的CSI特征来构建一种新的频域指纹,并将其用于刻画室内静默和入侵状态的特征差异性。

不同于上述方法,本文提出了一种基于多核最

大均值差异(Multiple Kernel Maximum Mean Discrepancy, MKMMD)迁移学习的WLAN室内入侵检测方法。该方法通过考虑实际环境中WLAN信号的时变性,首先利用离线有标记和在线伪标记的RSS特征来分别构建源域和目标域;其次,通过构造最优迁移矩阵以最小化源域和目标域RSS特征混合分布(包含边缘和条件分布)之间的MKMMD;再次,利用迁移后的源域RSS特征与对应标签来训练分类器,并将其用于对迁移后的目标域RSS特征进行分类以得到目标域标签集;最后,迭代更新目标域标签集直至算法收敛,进而实现对目标环境的入侵检测。本文的创新点如下:

(1) 考虑MKMMD在降低第2类错误概率(即当数据分布不同时,错误接受数据分布相同的零假设的概率)方面的优势^[12],将传统迁移学习修正为基于MKMMD的迁移学习;

(2) 考虑复杂室内环境中WLAN信号的时变性,通过最小化源域和目标域RSS特征分布间的MKMMD来增强WLAN室内入侵检测系统的鲁棒性;

(3) 在复杂室内环境中采集数据验证本文所提方法,结果表明,训练不同的分类器进行入侵检测均能实现高精度的入侵检测。

本文结构安排如下:第2节给出了基于MKMMD迁移学习的WLAN室内入侵检测方法的实现过程;第3节通过真实环境中的实测数据来验证本文所提方法相比于现有室内入侵检测方法的性能优势;第4节总结全文并给出下一步工作。

2 系统设计

2.1 系统框图

图1给出了本文所提方法的系统框图。具体而言,在离线阶段,提取在每个MP处采集的RSS特征,且根据其对应的静默或入侵状态进行标签标记以构建源域;在在线阶段,提取在线RSS特征且对其进行伪标签标记以构建目标域,同时通过构造最优迁移矩阵来最小化源域和目标域RSS特征混合分布之间的MKMMD,并由此训练分类器以对在线RSS特征进行分类,进而得到目标域标签集。基于此,通过对上述过程的迭代运算,算法收敛时的目标域标签集即为目标环境的入侵检测结果。

2.2 源域和目标域构建

在离线阶段,选取滑窗长度 L 并提取每个滑窗内离线RSS数据的8个特征(即RSS均值、RSS方差、RSS最大值、RSS最小值、RSS最值差、RSS中值、最大概率RSS和RSS过均值概率),构建离线RSS特征矩阵 $\mathbf{X}_S = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{n_s})^T \in \mathbb{R}^{n_s \times p}$,

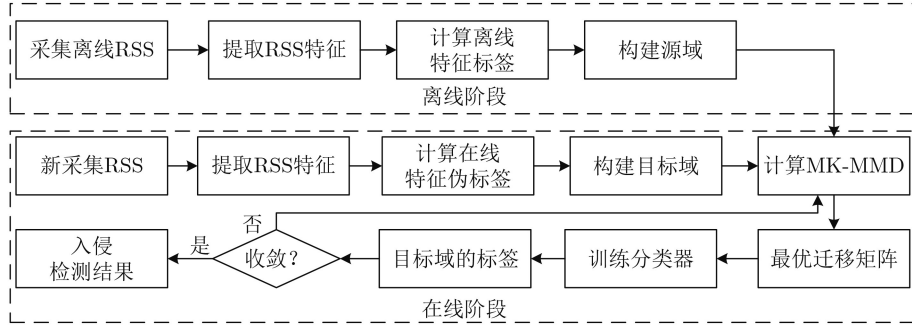


图1 系统框图

其中, $\mathbf{x}_s = (x_1^s, x_2^s, \dots, x_p^s)$ ($s = 1, 2, \dots, n_s$)为第 s 个离线RSS特征向量, n_s 为离线滑窗数, $p (= 8nm)$ 为RSS特征数, n 和 m 分别为MP和AP数。当目标环境中存在 K 种状态(即1种静默和 $K - 1$ 种入侵状态)时, 第 s 个离线RSS特征向量对应第 k ($k = 1, 2, \dots, K$)种状态的标签为 $y_s = k$, 进而可得离线RSS特征的标签集 $\mathbf{y}_s = (y_1, y_2, \dots, y_{n_s})^T$, 并由此构建源域 $\mathcal{D}_s = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_{n_s}, y_{n_s})\}$ 。

在在线阶段, 同样选取长度为 L 的滑窗对在线RSS数据进行特征提取, 得到在线RSS特征矩阵 $\mathbf{X}_T = (\mathbf{x}'_1, \mathbf{x}'_2, \dots, \mathbf{x}'_{n_t})^T \in \mathbb{R}^{n_t \times p}$, 其中, $\mathbf{x}'_t = (x'_1, x'_2, \dots, x'_p)$ ($t = 1, 2, \dots, n_t$)为第 t 个在线RSS特征向量, n_t 为在线滑窗数。为了计算源域和目标域RSS特征混合分布之间的MKMMD, 对在线RSS特征进行伪标签标记 $\tilde{\mathbf{y}}_T = (y'_1, y'_2, \dots, y'_{n_t})^T$ [13], 并由此构建目标域 $\mathcal{D}_T = \{(\mathbf{x}'_1, y'_1), (\mathbf{x}'_2, y'_2), \dots, (\mathbf{x}'_{n_t}, y'_{n_t})\}$ 。

2.3 MKMMD最小化

在基于数据库构建的室内入侵检测方法中, 目标环境中是否存在入侵可利用源域RSS特征学习得到的分类器对目标域RSS特征分类来进行判断。然而, 复杂室内环境中WLAN信号的时变性可能造成同一位置处源域和目标域RSS特征分布具有较大差异性, 从而导致WLAN室内入侵检测系统的鲁棒性较差, 于是选择一种合适的度量方法来减小同一位置处源域和目标域RSS特征分布的差异性是保证WLAN室内入侵检测性能的关键。为此, 文献[14]提出利用参数方法(如Kullback-Leibler散度)来度量任意两个分布之间的差异性, 但该方法需对数据进行密度估算, 而密度估算的准确性在实际环境中难以得到保证。于是, 文献[15]提出利用非参数方法(如MMD)来对不同分布之间的差异性进行度量, 相比于参数方法, 该方法通过计算再生核希尔伯特空间(Reproducing Kernel Hilbert Space, RKHS)中来自不同分布的数据均值距离来度量对应分布之间的差异性。基于此, 本文同时考虑MKMMD在

降低第2类错误概率(即当数据分布不同时, 错误接受数据分布相同的零假设的概率)方面的优势[12], 通过最小化源域和目标域RSS特征分布之间的MKMMD来增强WLAN室内入侵检测系统的鲁棒性。该方法的具体过程描述如下:

令 $P(\mathbf{X}_S)$ 和 $P(\mathbf{X}_T)$ 分别为源域和目标域RSS特征的边缘分布, 其MMD可表示为

$$D(P(\mathbf{X}_S), P(\mathbf{X}_T)) = \left\| \mathbb{E}_{P(\mathbf{X}_S)}(\phi(\mathbf{X}_S)) - \mathbb{E}_{P(\mathbf{X}_T)}(\phi(\mathbf{X}_T)) \right\|_{\mathbb{H}}^2 \quad (1)$$

其中, “ $\mathbb{E}_{P(\mathbf{X}_S)}(\cdot)$ ”和“ $\mathbb{E}_{P(\mathbf{X}_T)}(\cdot)$ ”分别表示 \mathbf{X}_S 和 \mathbf{X}_T 的边缘分布为 $P(\mathbf{X}_S)$ 和 $P(\mathbf{X}_T)$ 时的期望运算, “ $\|\cdot\|_{\mathbb{H}}^2$ ”表示RKHS中的2-范数运算, ϕ 为将RSS特征矩阵映射到RKHS的映射函数。由于无法计算源域和目标域所有RSS的总体均值(即期望运算), 本文通过计算源域和目标域RSS的样本均值来将式(1)近似为

$$D(P(\mathbf{X}_S), P(\mathbf{X}_T)) \approx \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \phi(\mathbf{x}_i) - \frac{1}{n_t} \sum_{i=1}^{n_t} \phi(\mathbf{x}'_i) \right\|_{\mathbb{H}}^2 \quad (2)$$

虽然减小源域和目标域RSS特征边缘分布之间的MMD能够降低源域和目标域RSS特征的整体差异性, 但其忽略了不同类RSS特征的相关性, 于是, 本文将同时考虑源域和目标域RSS特征条件分布之间的MMD。为此, 分别将源域和目标域中标签相同的RSS特征归为一类, 各得到 K 类RSS特征, 然后考虑后验概率 $P(\mathbf{y}_s | \mathbf{X}_S)$ 和 $P(\tilde{\mathbf{y}}_T | \mathbf{X}_T)$ 计算的复杂性, 将 $P(\mathbf{X}_S | \mathbf{y}_s)$ 和 $P(\mathbf{X}_T | \tilde{\mathbf{y}}_T)$ 分别作为源域和目标域RSS特征的条件分布, 并由此近似计算其MMD为

$$D(P(\mathbf{X}_S | \mathbf{y}_s), P(\mathbf{X}_T | \tilde{\mathbf{y}}_T)) \approx \sum_{k=1}^K \left\| \frac{1}{n_s^k} \sum_{i=1}^{n_s^k} \phi(\mathbf{x}_i) - \frac{1}{n_t^k} \sum_{i=1}^{n_t^k} \phi(\mathbf{x}'_i) \right\|_{\mathbb{H}}^2 \quad (3)$$

其中, $\mathbf{x}_i \in \mathbf{x}_s^k$, $\mathbf{x}'_i \in \mathbf{x}_t^k$, \mathbf{x}_s^k 和 \mathbf{x}_t^k 分别为源域和目标

域中类别为 k 的RSS特征向量, n_s^k 和 n_t^k 分别为源域和目标域中类别为 k 的RSS特征向量数。

根据式(2)和式(3), 可构造源域和目标域RSS特征混合分布之间的MMD为

$$\begin{aligned} D(\mathbf{X}_S, \mathbf{X}_T) &= D(P(\mathbf{X}_S), P(\mathbf{X}_T)) \\ &\quad + D(P(\mathbf{X}_S | \mathbf{y}_S), P(\mathbf{X}_T | \tilde{\mathbf{y}}_T)) \\ &\approx \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \phi(\mathbf{x}_i) - \frac{1}{n_t} \sum_{i=1}^{n_t} \phi(\mathbf{x}'_i) \right\|_{\mathbb{H}}^2 \\ &\quad + \sum_{k=1}^K \left\| \frac{1}{n_s^k} \sum_{i=1}^{n_s^k} \phi(\mathbf{x}_i) - \frac{1}{n_t^k} \sum_{i=1}^{n_t^k} \phi(\mathbf{x}'_i) \right\|_{\mathbb{H}}^2 \end{aligned} \quad (4)$$

此时, 为使式(4)取值最小化的映射函数 ϕ 的最优化问题可描述为

$$\begin{aligned} \min_{\phi} D(\mathbf{X}_S, \mathbf{X}_T) &= \min_{\phi} (D(P(\mathbf{X}_S), P(\mathbf{X}_T)) \\ &\quad + D(P(\mathbf{X}_S | \mathbf{y}_S), P(\mathbf{X}_T | \tilde{\mathbf{y}}_T))) \\ &\approx \min_{\phi} \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \phi(\mathbf{x}_i) - \frac{1}{n_t} \sum_{i=1}^{n_t} \phi(\mathbf{x}'_i) \right\|_{\mathbb{H}}^2 \\ &\quad + \sum_{k=1}^K \left\| \frac{1}{n_s^k} \sum_{i=1}^{n_s^k} \phi(\mathbf{x}_i) - \frac{1}{n_t^k} \sum_{i=1}^{n_t^k} \phi(\mathbf{x}'_i) \right\|_{\mathbb{H}}^2 \\ &= \min_{\tilde{\mathbf{K}}} \left(\text{tr}(\tilde{\mathbf{K}}\mathbf{L}_0) + \sum_{k=1}^K \text{tr}(\tilde{\mathbf{K}}\mathbf{L}_k) \right) \\ &= \min_{\tilde{\mathbf{K}}} \sum_{k=0}^K \text{tr}(\tilde{\mathbf{K}}\mathbf{L}_k) \end{aligned} \quad (5)$$

其中, “tr”表示矩阵求迹运算, $\tilde{\mathbf{K}} \in \mathbb{R}^{(n_s+n_t) \times (n_s+n_t)}$ 的第 i 行第 j 列元素为 $(\tilde{\mathbf{K}})_{ij} = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$ ($1 \leq i \leq n_s + n_t$; $1 \leq j \leq n_s + n_t$; $\mathbf{x}_i, \mathbf{x}_j \in \mathbf{X}_S \cup \mathbf{X}_T$), \mathbf{L}_0 的第 i 行第 j 列元素为 $(\mathbf{L}_0)_{ij} = \begin{cases} 1/(n_s)^2, & \mathbf{x}_i, \mathbf{x}_j \in \mathbf{X}_S \\ 1/(n_t)^2, & \mathbf{x}_i, \mathbf{x}_j \in \mathbf{X}_T \\ -1/(n_s n_t), & \text{其它} \end{cases}$

\mathbf{L}_k ($1 \leq k \leq K$) 的第 i 行第 j 列元素为 $(\mathbf{L}_k)_{ij} = \begin{cases} 1/(n_s^k)^2, & \mathbf{x}_i, \mathbf{x}_j \in \mathbf{x}_s^k \\ 1/(n_t^k)^2, & \mathbf{x}_i, \mathbf{x}_j \in \mathbf{x}_t^k \\ -1/(n_s^k n_t^k), & \mathbf{x}_i \in \mathbf{x}_s^k \cup \mathbf{x}_j \in \mathbf{x}_t^k \text{ 或 } \mathbf{x}_i \in \mathbf{x}_t^k \cup \mathbf{x}_j \in \mathbf{x}_s^k \\ 0, & \text{其它} \end{cases}$

式(5)的求解通常采用具有较大计算开销的半定规划(Semi-Definite Program, SDP)方法[16]。为了降低计算开销, 本文利用核矩阵构建方法来求解式(5)。为此, 定义核矩阵 $\mathbf{K} \in \mathbb{R}^{(n_s+n_t) \times (n_s+n_t)}$ 为

$$\mathbf{K} = \begin{bmatrix} \mathbf{K}_{s,s} & \mathbf{K}_{s,t} \\ \mathbf{K}_{t,s} & \mathbf{K}_{t,t} \end{bmatrix} \quad (6)$$

其中, $\mathbf{K}_{s,s}, \mathbf{K}_{t,t}$ 和 $\mathbf{K}_{s,t}$ ($= \mathbf{K}_{t,s}^T$)分别为源域、目标域和混合域(包含源域和目标域)的格拉姆矩阵,

$\mathbf{K}_{s,s}, \mathbf{K}_{t,t}$ 和 $\mathbf{K}_{s,t}$ 的第 i 行第 j 列元素分别为 $(\mathbf{K}_{s,s})_{i,j} = \mathbf{x}_i \mathbf{x}_j^T$ ($\mathbf{x}_i, \mathbf{x}_j \in \mathbf{X}_S$), $(\mathbf{K}_{t,t})_{i,j} = \mathbf{x}_i \mathbf{x}_j^T$ ($\mathbf{x}_i, \mathbf{x}_j \in \mathbf{X}_T$)和 $(\mathbf{K}_{s,t})_{i,j} = \mathbf{x}_i \mathbf{x}_j^T$ ($\mathbf{x}_i \in \mathbf{X}_S, \mathbf{x}_j \in \mathbf{X}_T$)。利用经验核映射方法[17], 将 \mathbf{K} 分解为

$$\mathbf{K} = \left(\mathbf{K} \mathbf{K}^{-\frac{1}{2}} \right) \left(\mathbf{K}^{-\frac{1}{2}} \mathbf{K} \right) \quad (7)$$

令 $\mathbf{W} = \mathbf{K}^{-\frac{1}{2}} \tilde{\mathbf{W}}$, 其中, $\tilde{\mathbf{W}} \in \mathbb{R}^{(n_s+n_t) \times q}$ ($q \leq p$)为变换矩阵, 则 $\tilde{\mathbf{K}}$ 可表示为

$$\tilde{\mathbf{K}} = \left(\mathbf{K} \mathbf{K}^{-\frac{1}{2}} \tilde{\mathbf{W}} \right) \left(\tilde{\mathbf{W}}^T \mathbf{K}^{-\frac{1}{2}} \mathbf{K} \right) = \mathbf{K} \mathbf{W} \mathbf{W}^T \mathbf{K} \quad (8)$$

由此可将源域和目标域RSS特征混合分布之间的MMD改写为

$$\begin{aligned} D(\mathbf{X}_S, \mathbf{X}_T) &\approx \sum_{k=0}^K \text{tr}(\tilde{\mathbf{K}}\mathbf{L}_k) \\ &= \sum_{k=0}^K \text{tr}((\mathbf{K} \mathbf{W} \mathbf{W}^T \mathbf{K}) \mathbf{L}_k) \\ &= \sum_{k=0}^K \text{tr}(\mathbf{W}^T \mathbf{K} \mathbf{L}_k \mathbf{K} \mathbf{W}) \end{aligned} \quad (9)$$

此外, 考虑在多核架构下, 本文通过联合多个核函数的子空间映射来组合各个子空间不同的特征映射能力, 使得RSS特征在组合空间中具有更加准确、合理的表达能力[18]。为此, 定义正定核函数 $f = \sum_{g=1}^G \alpha_g f_g$, 其中, f_g 为第 g ($g = 1, 2, \dots, G$)个核函数, α_g (≥ 0)为第 g 个常数且 $\sum_{g=1}^G \alpha_g = 1$, G 为核函数的个数。令 $\mathbf{K}_g = \begin{bmatrix} \mathbf{K}_{s,s}^g & \mathbf{K}_{s,t}^g \\ \mathbf{K}_{t,s}^g & \mathbf{K}_{t,t}^g \end{bmatrix}$, $\mathbf{K}_{s,s}^g, \mathbf{K}_{t,t}^g$ 和 $\mathbf{K}_{s,t}^g$ 的第 i 行第 j 列元素分别为 $(\mathbf{K}_{s,s}^g)_{ij} = f_g(\mathbf{x}_i, \mathbf{x}_j)$ ($\mathbf{x}_i, \mathbf{x}_j \in \mathbf{X}_S$), $(\mathbf{K}_{t,t}^g)_{ij} = f_g(\mathbf{x}_i, \mathbf{x}_j)$ ($\mathbf{x}_i, \mathbf{x}_j \in \mathbf{X}_T$)和 $(\mathbf{K}_{s,t}^g)_{ij} = f_g(\mathbf{x}_i, \mathbf{x}_j)$ ($\mathbf{x}_i \in \mathbf{X}_S, \mathbf{x}_j \in \mathbf{X}_T$) ($= \mathbf{K}_{t,s}^g{}^T$)。基于此, 可构造源域和目标域RSS特征混合分布之间的MKMMD最小化目标函数为

$$\min_{\mathbf{W}} \sum_{k=0}^K \text{tr} \left(\mathbf{W}^T \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{L}_k \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{W} \right) \quad (10)$$

其中, $\mathbf{W}^T \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right)$ 为迁移后的RSS特征。可见, 式(5)中关于映射函数 ϕ 的最优化问题等价于式(10)中关于迁移矩阵 \mathbf{W} 的最优化问题, 但由于实际采集的信号中RSS方差往往大于噪声方差, 故最小化MKMMD会保留较多的噪声成分。于是, 为了在最小化MKMMD的同时保留RSS数据分布特性[16], 将式(10)改写为

$$\begin{aligned} \min_{\mathbf{W}} & \sum_{k=0}^K \text{tr} \left(\mathbf{W}^T \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{L}_k \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{W} \right) \\ & + \lambda \text{tr} (\mathbf{W}^T \mathbf{W}) \\ \text{s.t. } & \mathbf{W}^T \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \cdot \mathbf{H} \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{W} = \mathbf{I} \quad (11) \end{aligned}$$

其中, \mathbf{I} 为单位阵, $\mathbf{H} = \mathbf{I} - 1/(n_s + n_t) \mathbf{e} \mathbf{e}^T$ 为中心矩阵, \mathbf{e} 为全1列向量, $\lambda (> 0)$ 为权衡系数, $\text{tr}(\mathbf{W}^T \mathbf{W})$ 为正则项, $\mathbf{W}^T \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \cdot \mathbf{H} \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{W}$ 为迁移后的RSS特征散度矩阵。利用拉格朗日乘法, 可得

$$\begin{aligned} L(\mathbf{W}) &= \mathbf{W}^T \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \sum_{k=0}^K \mathbf{L}_k \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{W} \\ &+ \lambda \mathbf{W}^T \mathbf{W} - \left(\mathbf{I} - \mathbf{W}^T \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \right. \\ &\quad \left. \cdot \mathbf{H} \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{W} \right) \mathbf{Z} \quad (12) \end{aligned}$$

其中, \mathbf{Z} 为由拉格朗日乘子构成的对角阵。将 $L(\mathbf{W})$ 关于 \mathbf{W} 求偏导, 可得

$$\begin{aligned} \frac{\partial L(\mathbf{W})}{\partial \mathbf{W}} &= 2 \left(\mathbf{W}^T \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \right. \\ &\quad \left. \cdot \sum_{k=0}^K \mathbf{L}_k \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) + \lambda \mathbf{I} \right) \mathbf{W} \\ &\quad - 2 \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{H} \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{W} \mathbf{Z} \quad (13) \end{aligned}$$

令式(13)等于0并将其移项后同乘 \mathbf{W}^T , 可得

$$\begin{aligned} \mathbf{W}^T \left(\left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \sum_{k=0}^K \mathbf{L}_k \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) + \lambda \mathbf{I} \right) \mathbf{W} \\ = \mathbf{W}^T \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{H} \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{W} \mathbf{Z} = \mathbf{Z} \mathbf{I} \quad (14) \end{aligned}$$

由式(11)和式(14)可知, 最小化矩阵 \mathbf{Z} 中元素可最小化 $\text{tr} \left(\mathbf{W}^T \left(\left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \sum_{k=0}^K \mathbf{L}_k \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) + \lambda \mathbf{I} \right) \mathbf{W} \right)$, 从而, 最优迁移矩阵 \mathbf{W} 可由 $\left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \sum_{k=0}^K \mathbf{L}_k \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) + \lambda \mathbf{I}$ 关于 $\left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right) \mathbf{H} \left(\sum_{g=1}^G \alpha_g \mathbf{K}_g \right)$ 的 q 个非零最小广义特征值所对应的特征向量构成。利用最优迁

移矩阵最小化源域和目标域RSS特征混合分布之间的MKMMD, 使得迁移到同一子空间中的源域和目标域RSS特征具有较小的差异性, 同时在该子空间中, 利用迁移后的源域RSS特征与对应标签来训练分类器, 并将其用于对迁移后的目标域RSS特征进行分类以得到目标域标签集。

2.4 迭代迁移

为了得到可靠的目标域标签集以提高WLAN室内入侵检测的准确率, 本文通过迭代更新目标域标签集的方法将源域和目标域RSS特征迁移到同一子空间。具体而言, 首先, 利用离线有标记和在线伪标记的RSS特征来分别构建源域和目标域; 其次, 计算源域和目标域RSS特征混合分布之间的MKMMD, 并构造具有最小化MKMMD的最优迁移矩阵; 再次, 通过最优迁移矩阵将源域和目标域RSS特征迁移到同一子空间, 同时利用迁移后的源域RSS特征与对应标签来训练分类器, 并将其用于对目标域RSS特征进行分类以得到目标域标签集; 最后, 重复上述过程直至算法收敛以得到最终目标域标签集, 进而实现对目标环境的入侵检测。

2.5 算法复杂度分析

令算法迭代次数为 N , 则计算核矩阵 $\sum_{g=1}^G \alpha_g \mathbf{K}_g$ 和系数矩阵 \mathbf{L}_0 的时间复杂度为 $O(G(n_s + n_t)^2) + O((n_s + n_t)^2)$, 计算系数矩阵 $\sum_{k=0}^K \mathbf{L}_k$ 的时间复杂度为 $O(NK(n_s + n_t)^2)$, 计算广义特征值分解的时间复杂度为 $O(Nqp^2)$, 则算法的总体时间复杂度为 $O(G(n_s + n_t)^2) + O((n_s + n_t)^2) + O(NK(n_s + n_t)^2) + O(Nqp^2)$ 。

3 实验结果

3.1 实验场景

在图2所示实验环境中, 选择2个走廊区域a1和a3, 1个房间区域a2和1个大厅区域a4作为目标区域。利用自主开发的RSS信号采集软件对目标环境中静默和不同区域入侵状态下所有AP发送的RSS数据进行采集, 其中, 每种状态下的RSS数据采集时间为2 min且采样频率为1 Hz。此外, 选择以下5个核函数来构建核矩阵以验证本文所提多核MMD迁移学习方法的优势: 线性核 $f_1(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$ 、高斯核 $f_2(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2)$ 、拉普拉斯核 $f_3(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\sqrt{\gamma} \|\mathbf{x}_i - \mathbf{x}_j\|)$ 、反平方距离核 $f_4(\mathbf{x}_i, \mathbf{x}_j) = 1/(\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2 + 1)$ 和反距离核 $f_5(\mathbf{x}_i, \mathbf{x}_j) = 1/(\gamma \|\mathbf{x}_i - \mathbf{x}_j\| + 1)$ 。其中, γ 为源域中两两不同RSS特征距离的中值^[12]。




图2 实验环境结构图

3.2 参数讨论

为了分析不同权衡参数 λ 和迁移后的RSS特征维度 q 对所提方法性能的影响，在滑窗长度 $L = 20$ 的条件下，图3给出了当 λ 取值从0.0001增大到1000(为表示方便，将图中横坐标转换为 $\lg \lambda$)且 q 取值从20增大到100时所提方法的检测性能。可以看出，当 λ 取值较小(如 $\lambda < 0.001$)，即 \mathbf{W} 复杂度较大时，迭代迁移的性能受RSS特征变化的影响较大，

从而导致系统的泛化能力下降；当 λ 取值较大(如 $\lambda > 0.1$)，即 \mathbf{W} 复杂度较小时，迁移矩阵难以准确地将RSS特征迁移到RKHS，从而影响系统的检测性能；而当 $0.001 \leq \lambda \leq 0.100$ 时，所提方法能够在控制 \mathbf{W} 复杂度的同时达到较好的入侵检测性能。此外，由于增大 q 值可扩大迁移矩阵的维度，使其能够保留更多的RSS特征用于分类器训练以得到更加准确的分类结果，从而使得所提方法具有更加稳定的检测性能，但该过程会显著增大系统的计算开销。

图4给出了当 $\lambda = 0.1$ 且 $q = 40$ 时，不同 L 取值下的系统混淆矩阵，其中，第 i 行第 j 列元素表示第 i 个真实状态被判为第 j 个状态的概率。显然，随着 L 取值的增大，系统混淆矩阵的对角线元素值增大，即表示检测性能提升。为了进一步说明 L 取值对检测性能的影响，图5给出了所提方法的FP, FN和DA随 L 取值增大的变化情况。一方面， L 取值过小会导致提取的RSS




图3 不同 λ 和 q 取值下所提方法的检测性能

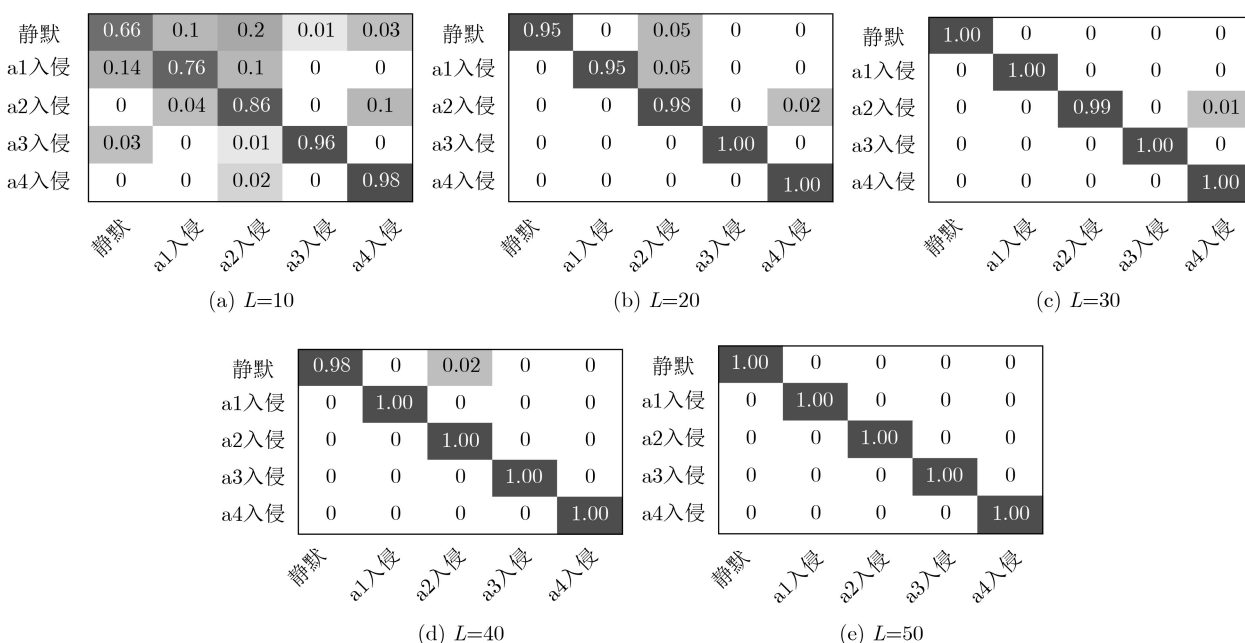


图4 不同 L 取值下的系统混淆矩阵




图 5 不同L取值下所提方法的检测性能

特征无法准确反映入侵目标对信号波动的影响，从而导致检测性能的下降；另一方面，L取值的增大虽然能够提升提取的RSS特征对于目标环境中静默和不同区域入侵状态的感知能力，但会造成较大的系统延迟。

图6给出了所提方法的FN和DA随迭代次数N增大的变化情况(不同分类器的FP均为0)。不失一般性，本文利用迁移后的RSS特征训练K-近邻(K-Nearest Neighbor, KNN)^[19]、随机森林(Random Forest, RF)^[20]和支持向量机(Support Vector Machine, SVM)^[21]3个分类器以进行入侵检测。可以看出，随着N取值的增大，分类器的检测性能在整体上呈收敛趋势。




图 6 不同N取值下所提方法的检测性能




图 7 不同核函数下所提方法的检测性能

图7给出了所提方法选择不同核函数来构建核矩阵的检测性能。可以看出，相比于单一核函数，多核方法在整体上具有更好的检测性能且检测结果更为稳定。

3.3 检测性能

表1对比了分别利用迁移前和迁移后的RSS特征训练分类器以进行入侵检测的FP, FN和DA。可以看出，利用迁移后的RSS特征训练分类器在整体上能够有效提升检测性能，从而说明所提方法训练得到用于入侵检测的分类器具有较强的鲁棒性。

此外，表2对比了所提方法与现有RASID^[7], PNN^[8]和PRNN^[9]方法的检测性能。可以看出，所提方法在整体上具有最优的检测性能，其DA相比于其它3种方法分别提高了6.32, 5.38和4.18个百分点，从而验证了所提方法能够通过减小源域和目标域RSS特征的整体差异性来提高系统的检测性能。

4 结束语

考虑复杂室内环境中WLAN信号的时变性问题，本文提出了一种基于MKMMD迁移学习的WLAN室内入侵检测方法。该方法通过最小化源域和目标域RSS特征混合分布之间的MKMMD来构造最优迁移矩阵，并利用最优迁移矩阵将源域和目标域

表1 不同分类器的检测性能(%)

类别	FP	FN	DA
KNN(迁移前)	35.92	0	75.60
KNN(迁移后)	0	0	99.78
RF(迁移前)	6.67	1.92	83.96
RF(迁移后)	0	0	98.90
SVM(迁移前)	18.02	0	93.85
SVM(迁移后)	0	1.10	98.02

表2 不同方法的检测性能(%)

指标	RASID	PNN	PRNN	本文方法
FP	6.72	3.42	0	0
FN	3.31	2.92	0	0
DA	93.46	94.40	95.60	99.78

RSS特征迁移到同一子空间以减小其在同一位置处的差异性。实验结果表明,所提方法可在一定程度上消除时变WLAN信号对RSS特征的干扰,进而有效增强用于入侵检测的分类器的鲁棒性。然而,如何保证所提方法在不同AP和MP设备差异性条件下的可靠性问题将作为下一步研究工作。

参考文献

- [1] 周培培, 丁庆海, 罗海波, 等. 视频监控中的人群异常行为检测与定位[J]. 光学学报, 2018, 38(8): 0815007. doi: [10.3788/AOS201838.0815007](https://doi.org/10.3788/AOS201838.0815007).
- [2] 程卫东, 董永贵. 利用热释电红外传感器探测人体运动特征[J]. 仪器仪表学报, 2008, 29(5): 1020–1023. doi: [10.3321/j.issn:0254-3087.2008.05.025](https://doi.org/10.3321/j.issn:0254-3087.2008.05.025).
- [3] WANG Hongpeng, LIU Jingtai, SUN Lei, *et al.* Indoor intrusion detection using an intelligent sensor network[C]. 2008 IEEE World Congress on Intelligent Control and Automation, Chongqing, China, 2008: 2396–2401. doi: [10.1109/WCICA.2008.4593298](https://doi.org/10.1109/WCICA.2008.4593298).
- [4] TIAN Zengshan, LI Yong, ZHOU Mu, *et al.* WiFi-based adaptive indoor passive intrusion detection[C]. 2018 IEEE 23rd International Conference on Digital Signal Processing, Shanghai, China, 2018: 1–5. doi: [10.1109/ICDSP.2018.8631613](https://doi.org/10.1109/ICDSP.2018.8631613).
- [5] YOUSSEF M, MAH M, and AGRAWALA A. Challenges: Device-free passive localization for wireless environments[C]. The 13th Annual ACM International Conference on Mobile Computing and Networking, Montréal, Canada, 2007: 222–229. doi: [10.1145/1287853.1287880](https://doi.org/10.1145/1287853.1287880).
- [6] ZHOU Rui, CHEN Jiesong, LU Xiang, *et al.* CSI fingerprinting with SVM regression to achieve device-free passive localization[C]. The 18th IEEE International Symposium on a World of Wireless, Mobile and Multimedia Networks, Macau, China, 2017: 1–9. doi: [10.1109/WoWMoM.2017.7974313](https://doi.org/10.1109/WoWMoM.2017.7974313).
- [7] KOSBA A E, SAEED A, and YOUSSEF M. RASID: A robust WLAN device-free passive motion detection system[C]. 2012 IEEE International Conference on Pervasive Computing and Communications, Lugano, Switzerland, 2012: 180–189. doi: [10.1109/PerCom.2012.6199865](https://doi.org/10.1109/PerCom.2012.6199865).
- [8] TIAN Zengshan, ZHOU Xiangdong, ZHOU Mu, *et al.* Indoor device-free passive localization for intrusion detection using multi-feature PNN[C]. 2015 International Conference on Communications and Networking in China, Shanghai, China, 2015: 272–277. doi: [10.1109/CHINACOM.2015.7497950](https://doi.org/10.1109/CHINACOM.2015.7497950).
- [9] DEAK G, CURRAN K, CONDELL J, *et al.* Detection of multi-occupancy using device-free passive localisation[J]. *IET Wireless Sensor Systems*, 2014, 4(3): 130–137. doi: [10.1049/iet-wss.2013.0031](https://doi.org/10.1049/iet-wss.2013.0031).
- [10] LV Jiguang, MAN Dapeng, YANG Wu, *et al.* Robust WLAN-based indoor intrusion detection using PHY layer information[J]. *IEEE Access*, 2018, 6: 30117–30127. doi: [10.1109/access.2017.2785444](https://doi.org/10.1109/access.2017.2785444).
- [11] TAN Qingqing, HAN Chong, SUN Lijuan, *et al.* A CSI frequency domain fingerprint-based method for passive indoor human detection[C]. 2018 IEEE International Conference on Trust, Security and Privacy in Computing and Communications/12th IEEE International Conference on Big Data Science and Engineering, New York, USA, 2018: 1832–1837. doi: [10.1109/TrustCom/BigDataSE.2018.00277](https://doi.org/10.1109/TrustCom/BigDataSE.2018.00277).
- [12] GRETTON A, SRIPERUMBUDUR B, SEJDINOVIC D, *et al.* Optimal kernel choice for large-scale two-sample tests[C]. The 25th International Conference on Neural Information Processing Systems, Lake Tahoe, USA, 2012: 1205–1213.
- [13] LONG Mingsheng, WANG Jianmin, DING Guiguang, *et al.* Transfer feature learning with joint distribution adaptation[C]. 2013 IEEE International Conference on Computer Vision, Sydney, Australia, 2013: 2200–2207. doi: [10.1109/ICCV.2013.274](https://doi.org/10.1109/ICCV.2013.274).
- [14] DUAN Lixin, TSANG I W, and XU Dong. Domain transfer multiple kernel learning[J]. *IEEE Transactions on Pattern*

- Analysis and Machine Intelligence*, 2012, 34(3): 465–479. doi: [10.1109/tpami.2011.114](https://doi.org/10.1109/tpami.2011.114).
- [15] BORGWARDT K M, GRETTON A, RASCH M J, *et al.* Integrating structured biological data by kernel maximum mean discrepancy[J]. *Bioinformatics*, 2006, 22(4): e49–e57. doi: [10.1093/bioinformatics/btl242](https://doi.org/10.1093/bioinformatics/btl242).
- [16] PAN S J, TSANG I W, KWOK J T, *et al.* Domain adaptation via transfer component analysis[J]. *IEEE Transactions on Neural Networks*, 2011, 22(2): 199–210. doi: [10.1109/TNN.2010.2091281](https://doi.org/10.1109/TNN.2010.2091281).
- [17] SCHOLKÖPF B, SMOLA A, and MÜLLER K R. Nonlinear component analysis as a kernel eigenvalue problem[J]. *Neural Computation*, 1998, 10(5): 1299–1319. doi: [10.1162/089976698300017467](https://doi.org/10.1162/089976698300017467).
- [18] 汪洪桥, 孙富春, 蔡艳宁, 等. 多核学习方法[J]. 自动化学报, 2010, 36(8): 1037–1050. doi: [10.3724/SP.J.1004.2010.01037](https://doi.org/10.3724/SP.J.1004.2010.01037).
WANG Hongqiao, SUN Fuchun, CAI Yanning, *et al.* On multiple kernel learning methods[J]. *Acta Automatica Sinica*, 2010, 36(8): 1037–1050. doi: [10.3724/SP.J.1004.2010.01037](https://doi.org/10.3724/SP.J.1004.2010.01037).
- [19] COVER T and HART P. Nearest neighbor pattern classification[J]. *IEEE Transactions on Information Theory*, 1967, 13(1): 21–27. doi: [10.1109/TIT.1967.1053964](https://doi.org/10.1109/TIT.1967.1053964).
- [20] BREIMAN L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5–32. doi: [10.1023/A:1010933404324](https://doi.org/10.1023/A:1010933404324).
- [21] CORTES C and VAPNIK V. Support-vector networks[J]. *Machine Learning*, 1995, 20(3): 273–297. doi: [10.1007/BF00994018](https://doi.org/10.1007/BF00994018).
- 周 牧: 男, 1984年生, 教授, 博士生导师, 主要研究方向为无线定位与导航技术、信号处理与检测技术、机器学习与信息融合技术等。
- 李焱鲟: 女, 1995年生, 硕士生, 研究方向为室内入侵检测技术。
- 谢良波: 男, 1986年生, 副教授, 主要研究方向为射频识别技术、室内定位技术等。
- 蒲巧林: 女, 1988年生, 助教, 主要研究方向为机器学习、室内定位技术等。
- 田增山: 男, 1968年生, 教授, 博士生导师, 主要研究方向为移动通信、个人通信、GPS及蜂窝网定位技术等。