

文章编号: 2095-4980(2021)04-0589-07

面向电磁大数据的未知雷达辐射源智能识别

冯蕴天, 王国良, 韩 慧, 许 雄, 陈 翔, 吴若无, 邵 宁

(电子信息系统复杂电磁环境效应国家重点实验室, 河南 洛阳 471003)

摘 要: 基于人工智能的方法在雷达辐射源识别任务中已取得很好的效果。但随着电子信息技术的发展, 将会出现越来越多的未知辐射源, 其特征分布与类别都是未知的, 在缺少先验知识的情况下, 难以对人工智能模型进行充分的训练, 使得现有的大多数方法都无法很好地完成对未知雷达辐射源的识别。为了解决上述问题, 提出并阐述了可用于未知雷达辐射源识别的电磁大数据的解决方案, 重点研究了基于Flink的未知雷达辐射源快速比对检索识别算法。通过对比实验证明了该方法的有效性, 其识别准确率可达87.2%, 当并行度设置为6时, 整个互信息与K最近邻(MI-KNN)并行化算法耗时仅为4.7 s。

关键词: 电磁大数据; 未知雷达辐射源; 分布式流处理引擎

中图分类号: TN971.4

文献标志码: A

doi: 10.11805/TKYDA2021146

Intelligent recognition of unknown radar emitters for electromagnetic big data

FENG Yuntian, WANG Guoliang, HAN Hui, XU Xiong, CHEN Xiang, WU Ruowu, TAI Ning

(State Key Laboratory of Complex Electromagnetic Environment Effects on Electronics and Information System, Luoyang Henan 471003, China)

Abstract: At present, artificial intelligence-based methods have been able to achieve good results in radar emitter recognition task. However, with the development of electronic information technology, there will be more and more unknown emitters whose characteristic distribution and categories are unknown. In the absence of prior knowledge, it is difficult to fully train the artificial intelligence model, which makes most of the existing methods unable to well complete the recognition of unknown radar emitters. This paper proposes a big electromagnetic data solution that can be used for the recognition of unknown radar emitters, and then focuses on the Flink-based fast comparison retrieval and recognition algorithm for unknown radar emitters. Finally, a comparative experiment proves the effectiveness of the proposed method, and its recognition accuracy can reach 87.2%. When the parallelism is set to 6, the entire Mutual Information-K-Nearest Neighbor(MI-KNN) parallelization algorithm takes only 4.7 s.

Keywords: electromagnetic big data; unknown radar emitter; Flink

雷达辐射源识别是雷达对抗侦察中的关键环节,它是在分选的基础上提取雷达辐射源信号中的特征参数和工作参数,通过这些参数可获取目标辐射源的体制、用途、型号、载体平台等信息,进而能够对战场地态势、威胁等级、活动规律和战术意图等进行推理,为己方决策提供重要情报支持^[1]。目前,在雷达辐射源识别领域中,人工智能的相关理论方法已得到了广泛应用^[2],且取得很好的效果。但随着电子信息技术的发展,未知雷达辐射源识别问题是目前雷达辐射源识别领域最困难、也是最急需解决的问题。针对未知雷达辐射源识别的问题,研究者们主要采用了迁移学习、在线学习等方法应对。陆鑫伟等^[3]深入研究了领域匹配迁移学习理论,设计了基于迁移成分分析改进的神经网络分类器,通过迁移不同领域的数据辅助训练分类器,减小了系统的识别误差。李蒙等^[4]将迁移学习理论引入识别系统,提出一种基于迁移成分分析的雷达辐射源识别方法。通过设置统一的核函数将不同样本集映射到同一隐藏空间,在隐藏空间对支持向量机进行训练,并对测试样本进行识别。田昊等^[5]为了满足雷达辐射源识别系统实时处理数据的需求,研究了多种在线学习算法。

上述解决方案都是对传统的机器学习范式进行修正,能够取得一定的效果,但没有从本质上直接解决未知雷达辐射源识别这个问题。本文从电磁大数据的角度出发,针对传统机器学习范式的不足,依靠海量的数据以及大

数据计算集群强大的算力将分类问题转变为检索问题, 解决复杂电磁环境下未知雷达辐射源识别的问题。

1 电磁大数据的解决方案

本文的电磁大数据解决方案综合运用了边缘计算、人工智能、大数据和云存储等技术, 其详细架构如图1所示。

该方案以“检索”代替“分类”来完成未知雷达辐射源的识别任务, 其具体识别流程可分为5个部分。

1) 通过侦察接收机采集雷达辐射源信号, 并对辐射源信号进行参数测量和分选, 得到某一辐射源的所有脉冲的特征参数;

2) 在所有侦察接收机上都加装边缘计算终端, 实现对上述所有脉冲的特征参数进行特征表示与提取。具体地, 使用深度学习模型提取出辐射源信号的深层特征, 即一个高维实值特征向量, 该向量代表一个辐射源与信道环境无关的核心特征, 可用于辐射源的检索;

3) 通过 Flume, Kafka 等消息传递和处理中间件, 将上述边缘计算终端上深层网络输出的辐射源信号深层特征传输至基于 Flink 的大数据计算集群中, 同时需在基于 HBase 的分布式存储系统中进行数据持久化, 得到海量背景信号数据库;

4) 使用基于 Flink 的未知雷达辐射源快速比对检索识别算法, 在海量背景信号数据库中完成未知雷达辐射源的识别;

5) 将识别结果等信息实时同步至云存储服务器中, 实现全局的数据共享。

未知雷达辐射源的特征分布与类别都是未知的, 因此无法对其进行标注并构建可用的训练数据集, 也无法训练出传统的分类模型。但海量未标注的雷达辐射源信号数据可直接存入大数据数据库中用于检索, 当新出现一个辐射源信号时, 若能够在大数据数据库中检索到, 将该辐射源的信息合并入检索到的辐射源, 从而得到其历次出现的时间、方位等属性信息, 且能够进一步分析该辐射源的行为等特点。

在整个电磁大数据解决方案中, 最核心、最关键的部分是基于 Flink 的未知雷达辐射源快速比对检索识别算法, 其识别速度和识别准确率等指标直接决定整个解决方案的有效性和实用性。

2 基于 Flink 的未知雷达辐射源快速比对检索识别算法

2.1 基于互信息的雷达辐射源相似度计算方法

为了对雷达辐射源类别之间的相似度进行定量的分析计算, 可通过对上述深层网络输出的辐射源信号深层特征之间距离进行计算来实现, 距离的大小可代表辐射源之间的相似度。对于特征向量之间的距离进行度量, 最常用的方式为欧式距离、时间序列距离(Dynamic Time Warping, DTW)^[6]等。

上述这些距离度量方式, 直接用于雷达辐射源相似度计算时, 效果往往不太理想, 其主要原因在于雷达脉冲之间往往存在时序相关关系和信息交互关系, 而不是欧式空间结构关系等。因此, 为了能够准确计算雷达辐射源之间的相似度, 同时捕捉辐射源信号内的波动变化特性, 提出一种基于互信息(MI)^[7]的雷达辐射源相似度计算方法, 即使用信息论中的互信息代替传统的欧式距离对雷达辐射源之间的相似度进行计算。

互信息是 2012 年 Brown 提出的一种基于信息论的典型的特征选择方法, 其中涉及了熵的概念, 可用于度量随机变量的不确定性, 代表其所需的平均信息量^[8]。

随机变量 $X = (x_1, x_2, \dots, x_n)$ 的熵为 $H(X)$, 其计算公式为:

$$H(X) = -\sum_{i=1}^n p(x_i) \log_2(p(x_i)) \quad (1)$$

式中 $p(x_i)$ 为 X 的概率密度函数。

2 个随机变量 $X = (x_1, x_2, \dots, x_n)$ 和 $C = (c_1, c_2, \dots, c_m)$ 的联合熵的计算公式为:

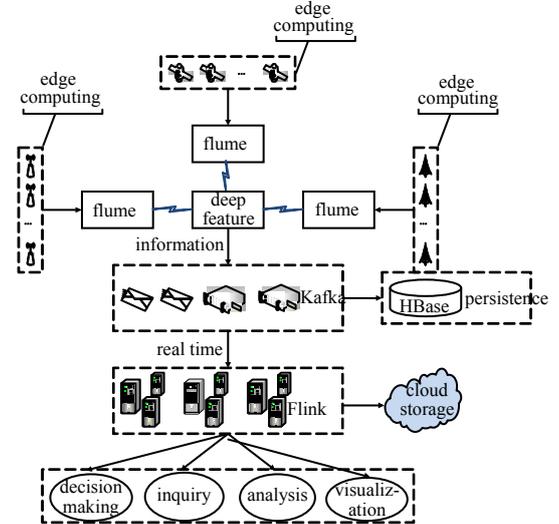


Fig.1 Electromagnetic big data solution

图1 电磁大数据解决方案

$$H(\mathbf{X}, \mathbf{C}) = -\sum_{j=1}^m \sum_{i=1}^n p(x_i, c_j) \log_2(p(x_i, c_j)) \quad (2)$$

式中 $p(x_i, c_j)$ 为 \mathbf{X} 和 \mathbf{C} 的联合概率密度函数。

条件熵是指引入随机变量 \mathbf{X} 后，随机变量 \mathbf{C} 中存在的 uncertainty，因此条件熵比 2 个随机变量的熵都要小。在已知随机变量 \mathbf{X} 的条件下，随机变量 \mathbf{C} 的条件熵为：

$$H(\mathbf{C} | \mathbf{X}) = -\sum_{j=1}^m \sum_{i=1}^n p(x_i, c_j) \log_2(p(c_j | x_i)) \quad (3)$$

联合熵和条件熵的关系为：

$$\begin{cases} H(\mathbf{X}, \mathbf{C}) = H(\mathbf{X}) + H(\mathbf{C} | \mathbf{X}) \\ H(\mathbf{X}, \mathbf{C}) = H(\mathbf{C}) + H(\mathbf{X} | \mathbf{C}) \end{cases} \quad (4)$$

互信息是指随机变量 \mathbf{X} 和 \mathbf{C} 之间的共享信息量，其定义为：

$$I(\mathbf{X}; \mathbf{C}) = H(\mathbf{C}) - H(\mathbf{C} | \mathbf{X}) \quad (5)$$

其具体含义为随机变量 \mathbf{X} 包含的降低随机变量 \mathbf{C} 的不确定性的信息量。互信息值越大，表示这 2 个变量之间的相关性越强。如果这 2 个变量是完全相互独立的，其互信息值为 0。

由式(5)可以看出，互信息的取值可能非常大，也可能非常小，易导致雷达辐射源相似度计算中的某些含义会被放大或者弱化。使用对称不确定性(Symmetric Uncertainty, SU)能够对互信息中多值特征的偏向进行一定程度的补偿，可避免幅值对互信息值的影响，同时可实现归一化，有利于进一步的模型处理。其主要方法为限制大熵的输入，将对称不确定性值限制在 0~1 之间。随机变量 \mathbf{X} 和 \mathbf{C} 的对称不确定性的计算公式为：

$$SU(\mathbf{X}; \mathbf{C}) = \frac{2I(\mathbf{X}; \mathbf{C})}{H(\mathbf{X}) + H(\mathbf{C})} \quad (6)$$

最终，辐射源之间的相似度可以通过用 1 减去对称不确定性来表示。相似度越小，表示 2 个深层特征向量之间的距离越大，即 2 个辐射源之间的差别越大；相似度越大，表示 2 个深层特征向量之间的距离越小，即 2 个辐射源的类别之间越相似。基于互信息的雷达辐射源相似度计算方法的具体步骤如算法 1 所示。

算法 1： 基于互信息的雷达辐射源相似度计算方法

输入：2 个 n 维的雷达辐射源信号深层特征向量 $\mathbf{X} = (x_1, x_2, \dots, x_n)$ 和 $\mathbf{Y} = (y_1, y_2, \dots, y_n)$

输出：2 个辐射源之间的相似度 $XSD(\mathbf{X}, \mathbf{Y})$

步骤 1：求 2 个深层特征向量 \mathbf{X} 和 \mathbf{Y} 之间的互信息： $I(\mathbf{X}; \mathbf{Y}) = H(\mathbf{Y}) - H(\mathbf{Y} | \mathbf{X})$ ；

步骤 2：求互信息值 $I(\mathbf{X}; \mathbf{Y})$ 的对称不确定性值： $SU(\mathbf{X}; \mathbf{Y}) = \frac{2I(\mathbf{X}; \mathbf{Y})}{H(\mathbf{X}) + H(\mathbf{Y})}$ ；

步骤 3：计算得到 2 个辐射源之间的相似度： $XSD(\mathbf{X}; \mathbf{Y}) = 1 - SU(\mathbf{X}; \mathbf{Y})$ 。

2.2 基于 MI-KNN 的未知雷达辐射源快速比对检索识别算法

将互信息(MI)与 K 最近邻(KNN)算法相结合，提出 MI-KNN 算法实现未知雷达辐射源的检索识别，同时进行辐射源威胁等级的判定。

传统的 KNN 分类算法基于样本之间的距离来进行类别的判定，本节使用对称不确定性来完成距离的计算，其本质上仍是一种有监督的机器学习方法。当一个未知的待分类样本出现时，首先将其与库中所有样本进行对称不确定性计算，找出与其相似的 k 个样本^[9]，当相似度达到 0.9 以上时，即可完成未知辐射源的检索识别，同时可根据这 k 个样本的威胁等级比例来判定该样本的威胁等级。

对于海量背景信号数据分布式存储系统中已知的辐射源数据，需结合情报等先验知识完成其威胁等级的判定，即把每个辐射源划分为不同的威胁等级，从而使样本空间中的部分辐射源深层特征数据带上了威胁等级标签，有助于基于 MI-KNN 的未知雷达辐射源快速比对检索识别算法同时完成待分类样本的威胁等级判定。

在电磁大数据的应用场景下，数据量太大会造成极大的计算负担^[10]，为保证流数据处理的实时性和准确性，其正常样本和故障样本数量可设置为 10。MI-KNN 算法的具体步骤如算法 2 所示。

算法 2： 基于 MI-KNN 的未知雷达辐射源快速比对检索识别算法

输入：一个未知的待分类的辐射源信号深层特征数据 \mathbf{X} ；海量辐射源信号深层特征数据集 $\mathbf{K} = (K_0, K_1, \dots, K_m)$ 及其对应的威胁等级标签 $T = (T_0, T_1, \dots, T_m)$ 。

输出： \mathbf{X} 的具体类别及其威胁等级 T'

步骤 1: 计算待分类的辐射源信号深层特征数据 X 与数据集 K 中所有样本数据的对称不确定性——相似度;

步骤 2: 按照计算得到的相似度对所有样本进行排序, 若存在超过一定相似度阈值的样本, 即可完成未知雷达辐射源的检索识别; 若所有样本都未超过所设定的相似度阈值, 则直接将 X 加入深层特征数据集 K 中;

步骤 3: 完成检索识别后, 取出与 X 最相似的 k 个样本, 计算 k 个样本的威胁等级比例, 所占比例最高的威胁等级可作为 X 的威胁等级判定结果。

2.3 基于 Flink 的 MI-KNN 算法

2.3.1 MI-KNN 算法的并行化策略

针对雷达辐射源信号流式数据的特点, 采用基于 Flink 大数据计算引擎对 MI-KNN 算法进行并行化, 克服了 MapReduce 难以实时处理, Spark 无法处理流式数据的问题。

整个并行化策略可分为 3 个阶段: 首先对深层特征数据集进行分割; 然后对相似度计算过程进行并行化; 最后对计算结果进行聚合。

1) 数据集分割

深层特征数据集被分为若干子集, 可作为后续并行化计算的数据源, 具体的分割步骤如下:

a) 利用数据集分区的方法把深层特征数据集 K 分割为 p 个部分, 每个部分分配至一个处理器(processor);

b) 主节点将 MI-KNN 算法中所选择的 k 值和相似度阈值广播至各个 processor。

Flink 计算架构主要的划分方式包括 Rebalance, Hash partition, Range partition, Sort partition 和 First-n 等。

2) 相似度计算并行化

Flink 计算架构并行化的对象主要包括任务、执行环境和系统等。本节的并行化策略是在使用 HDFS 对数据集进行自定义分区后, 对 MI-KNN 算法中的相似度计算进行任务并行化以实现加速。相似度计算并行化如图 2 所示。

Flink 计算架构的任务并行化采用了主从模型, JobManager 和 TaskManager 分别为主节点和从节点。JobManager 的主要任务为数据的划分与分配, 即完成数据集的分割, 并把分割结果广播至所有 TaskManager; TaskManager 的主要任务为并行化计算与反馈, 即计算待分类的辐射源信号深层特征数据与其他样本之间的相似度, 并把计算结果反馈至 JobManager。

3) 聚合

在分割后的所有数据子集上, 将并行化计算得到的与每个样本相似度以 key 值作为索引进行聚合, 选取超过相似度阈值的样本, 作为最终的检索识别结果。

2.3.2 MI-KNN 算法的并行化实现

Flink 计算架构中 TaskManager 的作用为在分布式计算集群上执行资源隔离(Slot), TaskManager 节点上 CPU 核的数量决定 Slot 的数量, 基于 Flink 的并行化程序可分为 3 部分: DataSource, Transformation Operators 和 DataSink。DataSource 指获取数据源, 通过数据集分区实现任务的并行化, 能够提升获取数据时的计算速率; Transformation Operators 指转换操作, 指通过 Map()、FlatMap()、GroupBy()和 KeyBy()来提升任务的计算速率; DataSink 指数据汇集。Flink 程序的每个部分都需要采用并行的线程, 每个并行的实例可接受一个数据子集作为输入, 并行度由线程的个数决定。

3 实验

3.1 实验环境

实验搭建了由 7 台高性能工作站组成的 Flink 大数据计算集群环境, 其中 1 台作为主节点 JobManager, 4 台作为从节点 TaskManager, 1 台作为 Kafka 中间数据源获取节点, 1 台作为 HDFS 存储节点。Flink 计算集群采用 Flink1.10.0 版本, Master 节点和 Slave 节点的内存均为 16 G。

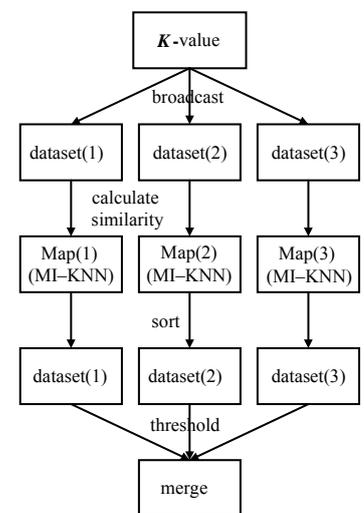


Fig.2 Similarity calculation parallelization
图 2 相似度计算并行化

3.2 数据集与计算指标

实际应用场景中应该通过侦查接收机收集信号，但在目前城市区域环境内无法采集到大量、丰富的雷达辐射源信号，而本文方法的验证需要海量的数据，因此实验通过仿真数据进行验证。

为了验证基于 Flink 的未知雷达辐射源快速比对检索识别算法的性能，仿真生成了海量辐射源信号数据集，仿真参数设置如表 1 所示。150 000 个雷达辐射源模式，每个模式就是一个脉冲组，即 150 000 个脉冲组，通常 40~200 个脉冲即可代表辐射源的一种模式。脉冲组由每个脉冲的常规特征组成，而未知雷达辐射源脉冲信号的常规特征参数可能会发生迅速变化。在海量辐射源信号数据集中，50%的脉冲组为已知类别的雷达辐射源信号，剩余 50%的脉冲组为未知雷达辐射源信号。

海量辐射源信号数据集经过深层网络处理后，即将每个辐射源信号通过特征表示与提取生成一个高维实值特征向量，从而得到海量辐射源信号深层特征数据集，可用于评估本文中的基于 Flink 的未知雷达辐射源快速比对检索识别算法。

实验使用每个类别雷达辐射源的识别准确率和雷达辐射源的整体识别准确率 2 个指标来衡量识别算法的性能，其计算公式为：

$$\begin{cases} P_r^i = \frac{N_r^i}{N^i}, i=1,2,\dots,m \\ P_r = \frac{N_r^1 + N_r^2 + \dots + N_r^m}{N^1 + N^2 + \dots + N^m} \end{cases} \quad (7)$$

式中： P_r^i 为第 i 类辐射源的识别准确率； P_r 为整体识别准确率； N_r^i 为第 i 类辐射源识别准确的个数； N^i 为第 i 类辐射源的总个数。

3.3 KNN 与 MI-KNN 算法性能对比

在上述数据集中对 KNN 与 MI-KNN 算法的性能进行验证，结果如图 3 所示。相比于传统的 KNN 算法，本文所提的 MI-KNN 算法针对未知雷达辐射源的识别准确率提升了 3.1%，达到了 87.2%。其主要原因为雷达脉冲之间不存在欧式空间结构关系，故传统 KNN 算法中直接使用欧式距离来进行相似度计算会影响算法的整体性能，而本文所提出的基于互信息的雷达辐射源相似度计算方法可以很好地表示雷达脉冲之间的时序相关关系和信息交互关系。

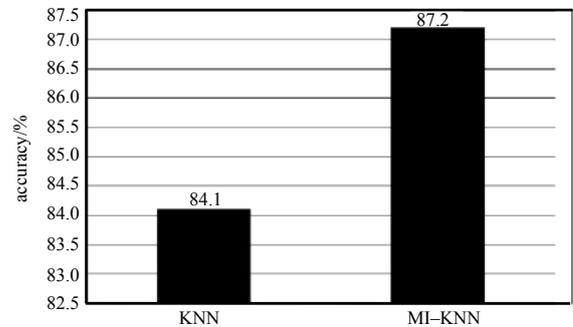


Fig.3 Performance comparison of KNN and MI-KNN algorithm
图 3 KNN 与 MI-KNN 算法性能对比

3.4 基于 Flink 的 MI-KNN 并行化性能测试

从并行化任务提交到任务完成过程中的各阶段来验证基于 Flink 的 MI-KNN 并行化加速效果。设置了 3 组对比实验，基于 Flink 的并行化任务具体分为 4 个阶段，其中获取数据的时间为 T_{Source} ，相似度计算的时间为 T_{MI-KNN} ，TaskManager 之间数据交换的时间为 $T_{Process}$ ，Slot 之间数据交换的时间为 T_{Thread} 。

3.4.1 各阶段的耗时占比

在海量辐射源信号深层特征数据集上，并行度设置为 10 时，对 MI-KNN 并行化算法中 T_{Source} 、 T_{MI-KNN} 、 $T_{Process}$ 和 T_{Thread} 进行统计，实验结果如图 4 所示。由统计结果可知，在 MI-KNN 并行化算法执行过程中， T_{Source} 占比为 43%，由于整个并行化过程是在分割后的所有数据子集上进行，前期的数据分割、数据获取等操作会消耗大量的时间； T_{MI-KNN} 最大，占比为 49%，该阶段为并行化算法运算执行的阶段，包括 Map 和 Reduce 等操作

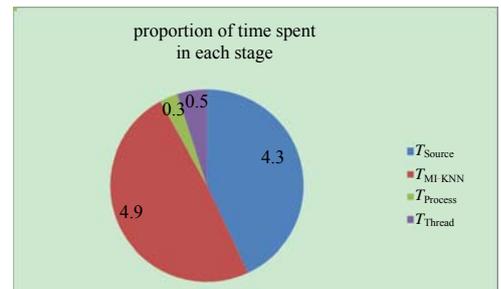


Fig.4 Time-consuming statistics of each stage of MI-KNN parallelization algorithm
图 4 MI-KNN 并行化算法各阶段耗时统计

作; $T_{Process}$ 和 T_{Thread} 较少, 占比分别为 3% 和 5%。

相比于传统的串行执行过程, 由于大量分布式计算节点的使用, MI-KNN 并行化算法的 T_{Source} 和 T_{MI-KNN} 会显著降低, 但分布式进程和线程之间大量的数据交换和通信会导致 $T_{Process}$ 和 T_{Thread} 有一定程度的增加。综合考虑上述各因素, 相比于串行执行过程, 基于 Flink 的 MI-KNN 并行化的整体耗时会有明显的下降。

3.4.2 不同并行度下 T_{Source} 对比

由于 MI-KNN 并行化算法执行过程中, T_{Source} 占据了近一半, 几乎接近了算法运算执行的耗时, 明显具有很大的优化空间。因此, 实验分别对并行度为 2,4,6,8,10 下的 T_{Source} 进行统计, 实验结果如图 5 所示。

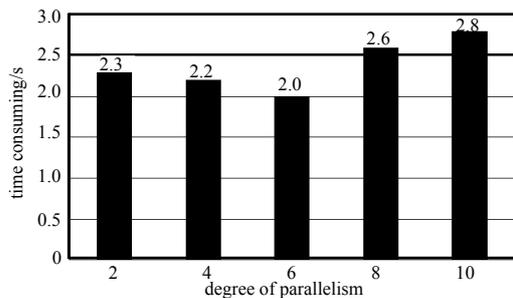


Fig.5 Time-consuming in the T(Source) phase under different parallelism

图 5 不同并行度下 T(Source)阶段耗时

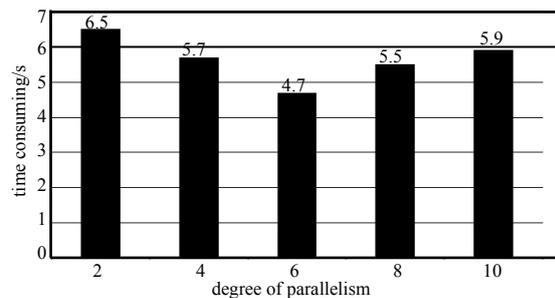


Fig.6 Time consuming of entire MI-KNN parallelization algorithm under different parallelism

图 6 不同并行度下整个 MI-KNN 并行化算法耗时

由统计结果可知, 当并行度设置为 6 时, T_{Source} 最小, 仅为 2.0 s, 表明该并行度为较合理的选择。并行度设置得过小或过大都会导致 T_{Source} 增加, 当并行度设置为 10 时, T_{Source} 最大, 达到了 2.8 s。

3.4.3 不同并行度下整个 MI-KNN 并行化算法耗时对比

最后在海量辐射源信号深层特征数据集上, 对不同并行度下整个 MI-KNN 并行化算法耗时进行统计, 实验结果如图 6 所示。由统计结果可知, 随着并行度的不断增加, 整个 MI-KNN 并行化算法耗时是先不断下降, 后慢慢升高, 其主要原因为当并行度设置得过小时, 算法运算执行的耗时会显著增加, 导致整体耗时很高; 当并行度设置为 6 时, 整个 MI-KNN 并行化算法耗时最少, 仅为 4.7 s; 当并行度设置得过大时, 虽然算法运算执行的耗时会有所降低, 但针对庞大数据集的数据分割、数据获取和数据交换等操作的耗时会增加, 故也会使整体耗时很高。因此, 针对整个 MI-KNN 并行化算法, 选取合适的并行度至关重要。

T_{Source} 和整个 MI-KNN 并行化算法在并行度设置为 6 时都耗时最少, 即在当前实验构建的仿真数据集的规模和 Flink 分布式集群大小的条件下, 整个算法能够在并行算法执行过程和并行数据交换过程中达到平衡。

4 结论

本文重点针对雷达辐射源识别领域的难点——未知雷达辐射源识别问题进行研究, 提出了面向电磁大数据的未知雷达辐射源智能识别方法, 阐述了一种电磁大数据的解决方案, 重点研究了其中基于 Flink 的未知雷达辐射源快速比对检索识别算法, 最后通过实验验证了本文所提方法的有效性。下一步工作将是在实际应用场景中对整个解决方案进行实现与部署。

参考文献:

- [1] WILEY Richard G. ELINT:the interception and analysis of radar signals[M]. Beijing:Publishing House of Electronics Industry, 2008.
- [2] CAIN L,CLARK J,PAULS E,et al. Convolutional neural networks for radar emitter classification[C]// 2018 IEEE 8th Annual Computing and Communication Workshop and Conference(CCWC). Las Vegas,NV,USA:IEEE, 2018:79-83.
- [3] 陆鑫伟. 基于迁移学习的雷达辐射源识别研究[D]. 西安:西安电子科技大学, 2012. (LU Xinwei. Research on radar emitter recognition based on transfer learning[D]. Xi'an,China:Xidian University, 2012.)
- [4] 李蒙,朱卫纲. 基于迁移成分分析的雷达辐射源识别方法研究[J]. 电子设计工程, 2017(20):52-55,60. (LI Meng,ZHU Weigang. Research on radar emitter recognition method based on migration component analysis[J]. Electronic Design Engineering, 2017(20):52-55,60.)
- [5] 田昊. 雷达辐射源特征选择和在线学习算法研究[D]. 西安:西安电子科技大学, 2011. (TIAN Hao. Research on radar emitter feature selection and online learning algorithm[D]. Xi'an,China:Xidian University, 2011.)

- [6] 李忠武. 时间序列分析与数据挖掘[J]. 电子商务, 2016(11):41-44. (LI Zhongwu. Time series analysis and data mining[J]. Electronic Commerce, 2016(11):41-44.)
- [7] BROWN G,POCOCK A,ZHAO M J,et al. Conditional likelihood maximisation:a unifying framework for information theoretic feature selection[J]. Journal of Machine Learning Research, 2012,13(1):27-66.
- [8] COVER T,THOMAS J,WILEY J. Elements of information theory[M]. Wiley-Blackwell:Tsinghua University Press, 2003.
- [9] 耿丽娟,李星毅. 用于大数据分类的 KNN 算法研究[J]. 计算机应用研究, 2014,31(5):1342-1344. (GENG Lijuan,LI Xingyi. Research on KNN algorithm for big data classification[J]. Application Research of Computers, 2014,31(5):1342-1344.)
- [10] 夏勇,丁岐鹏,尤路. 基于大数据的雷达健康管理系统[J]. 太赫兹科学与电子信息学报, 2019,17(4):686-690. (XIA Yong,DING Qijuan,YOU Lu. Radar prognostic and health management technology based on big data[J]. Journal of Terahertz Science and Electronic Information Technology, 2019,17(4):686-690.)

作者简介:

冯蕴天(1990-), 男, 河南省洛阳市人, 博士, 工程师, 主要研究方向为电磁大数据和智能博弈推演. email:fengyuntian2009@live.cn.

韩慧(1980-), 女, 云南省宣威市人, 副研究员, 主要研究方向为复杂电磁环境特性与模拟.

陈翔(1986-), 男, 河南省信阳市人, 助理研究员, 主要研究方向为复杂电磁环境特性与模拟.

王国良(1964-), 男, 黑龙江省双鸭山市人, 研究员, 主要研究方向为电子信息装备试验鉴定、雷达对抗仿真.

许雄(1985-), 男, 福建省莆田市人, 副研究员, 主要研究方向为复杂电磁环境特性与模拟.

吴若无(1987-), 男, 四川省广安市人, 助理研究员, 主要研究方向为复杂电磁环境特性与模拟.

郇宁(1989-), 男, 陕西省宝鸡市人, 助理研究员, 主要研究方向为复杂电磁环境特性与模拟.

(上接第 555 页)

- [29] 邓建辉,周侗. 多维度电磁态势展现方法研究[J]. 舰船电子工程, 2014(11):1-4,119. (DENG Jianhui,ZHOU Jie. Research on the method of multi-dimensional electromagnetic situation display[J]. Ship Electronic Engineering, 2014(11):1-4,119.)
- [30] 马良,张政. 复杂电磁环境三维态势展示方法研究[J]. 中国无线电, 2020(4):33-39. (MA Liang,ZHANG Zheng. Research on 3D situation display method of complex electromagnetic environment[J]. China Radio, 2020(4):33-39.)

作者简介:

李泓余(1991-), 男, 在读硕士研究生, 主要研究方向为太赫兹光电导器件. email:2018100209@mails.cust.edu.cn.

李婕(1992-), 女, 在读博士研究生, 副研究员, 主要研究方向为阵列信号处理、自适应信号处理、雷达抗干扰技术等.

况婷妍(1997-), 男, 在读硕士研究生, 主要研究方向为异常信号识别与监测、时频分析、深度学习.

韩路(1983-), 男, 硕士, 工程师, 主要研究方向为认知无线电、无线通信、频谱可视化.

唐磊明(1997-), 男, 在读硕士研究生, 主要研究方向为信号处理、张量补全.

丁国如(1986-), 男, 教授, 主要研究方向为认知无线电、统计信号处理、机器学习和无线网络大数据分析.