

文章编号:1007-5321(2021)02-0061-07

DOI:10.13190/j.jbupt.2020-131

支持泛洪攻击检测的命名数据网 PIT

彭 鹏¹, 李 卓¹, 梁纪峰², 马天祥², 刘开华¹

(1. 天津大学 微电子学院, 天津 300072;

2. 国网河北省电力有限公司 电力科学研究院, 石家庄 050021)

摘要: 针对命名数据网待定兴趣转发表中高效的变长名称数据索引、硬件可支持的存储消耗以及兴趣包泛洪攻击检测等问题,提出了基于字符卷积神经网络的认知索引模型(C&I),该模型能够支持路由由名称数据的分类、聚合,降低名称数据的存储消耗.同时,基于C&I提出了支持兴趣包泛洪攻击检测的待定兴趣转发表(PIT)存储结构C&I-PIT及其数据检索算法,通过多级存储器部署方式,分别在片上和片下的存储器中部署索引结构及存储空间.实验结果表明,C&I-PIT在名称数据聚合、存储消耗、泛洪攻击检测等方面具有良好的性能.

关键词: 命名数据网; 待定兴趣转发表; 名称数据索引; 字符卷积神经网络; 兴趣包泛洪攻击
中图分类号: TP393 **文献标志码:** A

Research on Pending Interest Table of Named Data Networking Supporting Interest Flooding Attack Detection

PENG Peng¹, LI Zhuo¹, LIANG Ji-feng², MA Tian-xiang², LIU Kai-hua¹

(1. School of Microelectronics, Tianjin University, Tianjin 300072, China;

2. Electric Power Research Institute, Hebei Electric Power Corporation, Shijiazhuang 050021, China)

Abstract: In order to solve the problems of efficient variable-length name lookup, hardware-supportable storage consumption, and detection of interest flooding attack in the pending interest table (PIT) of named data networking, an cognition and indexing model(C&I) based on character convolutional neural network is proposed. C&I can support the classification and aggregation of name data, and reduce the storage consumption of name data. At the same time, a pending interest table storage structure C&I-PIT based on C&I and its data retrieval algorithm, which supports the detection of interest flooding attack, is proposed. Through the deployment of multi-level memory, the index structure and storage space are respectively deployed on static random access memory and dynamic random access memory. Experiments show that C&I-PIT has good performance in name aggregation, memory consumption and interest flooding attack detection.

Key words: named data networking; pending interest table; name lookup; character convolutional neural network; interest flooding attack

收稿日期: 2020-08-20

基金项目: 河北省省级科技计划项目(20314301D); 天津市科技计划项目(20JCQNJC01490); 国家自然科学基金项目(61602346); 天津大学自主创新基金项目(2020XRG-0102)

作者简介: 彭 鹏(1995—), 男, 硕士生.

通信作者: 李 卓(1984—), 男, 副教授, 硕士生导师, E-mail: zli@tju.edu.cn.

随着“互联网+”时代的到来,网络信息化的逐渐普及和深化,大数据、边缘计算、云计算等重要技术在各行各业中的应用不断呈现^[1],传统的互联网架构开始无法满足新技术的高质量通信需求.为了适应当前互联网技术普适化、智能化等发展趋势^[2],国内外诸多研究团队对互联网架构的更新和改革展开了积极的研究,一种新型互联网架构的命名数据网(NDN, named data networking)于2010年被提出^[3].

NDN 通信过程中需要对待兴趣转发表(PIT, pending interest table)进行频繁的读写操作,记录 interest 包传入接口、传出接口以及转发信息.因此,PIT 的结构设计及其性能表现将极大地影响 NDN 通信效率,国内外诸多学者也提出了一系列行之有效的 PIT 方案.针对 PIT 中名称数据的快速检索和压缩存储问题,Huang 等^[4]提出混合检索名称标识的形状和内容检索方案(SACS, shape and content search framework),通过压缩数据存储来提高检索性能;Li 等^[5]提出了基于映射布鲁姆过滤器(MBF, mapping Bloom filter)的 PIT 方案,利用 Bloom filter 和位图实现联合索引,降低存储消耗;此外,Yan 等^[6]提出了基于神经网络的数据索引结构,初步验证了机器学习应用于数据索引的可能性.然而,以上经典方案均难以很好地兼顾名称数据的检索速度和存储消耗,而将机器学习应用于 NDN 转发平面路由数据索引的研究尚处于初步探索阶段.此外,兴趣包泛洪攻击(IFA, interest flooding attack)是针对 NDN 转发平面中 PIT 工作机理最典型、危害最大的安全威胁之一^[7],而当前在 PIT 上实现 IFA 检测的方案仅单独考虑 PIT 参数的统计,并未联合考虑 PIT 结构的设计.Wang 等^[8]通过监测 interest 包过期率来判断 IFA,Shinohara 等^[9]通过监测 PIT 占有率和 interest 包过期率来判断 IFA.此类方案在检测到 IFA 时,存在一定的延时性,而且不能准确地定位到恶意名称前缀.因此,如何联合考虑 PIT 的设计和 IFA 检测,快速判断 IFA 以及恶意名称前缀,是 PIT 的设计难点.

综上,当前 PIT 的设计仍面临着以下问题和挑战.1) NDN 变长无边界的名称结构^[3]将对索引结构的检索效率提出更高的要求;2) 当前互联网的数据量规模可达百万级别^[10],而名称数据相较于互联网协议地址更加复杂,PIT 存储名称数据需要更多的存储空间;3) NDN 中 PIT 的精确名称匹配机制

(ENM, exact name matching)和所有名称前缀匹配机制(ANPM, all name prefix matching)的检索算法仍是尚待解决的问题;4) PIT 的设计需要考虑到 IFA 的检测需求.为此,提出了基于字符卷积神经网络(Char-CNN, character convolutional neural network)的认知索引模型(C&I, cognition and indexing model)和高效 PIT 存储结构方案 C&I-PIT.

1 C&I 索引数据结构

1.1 C&I 基本结构

针对哈希表存储消耗大、映射冲突多等问题,Yan 等^[6]提出了 learning tree 索引结构,利用反向传播神经网络(BPNN, back propagation neural network)学习索引内容与逻辑地址间的映射关系及分布规律,实现了数据的均匀映射,提高了存储效率,但并未考虑实际应用场景的需要,对名称数据的按位异或处理时也并未利用名称数据的语义信息.同时,鉴于 Char-CNN 在自然语言处理应用上的独特优势,以字符为基本单元对文本数据进行处理,实现了更精确的数据分析^[11].因此,结合 PIT 设计需求以及 Char-CNN 模型优势,提出了新型数据结构的 C&I.

C&I 的基本结构包含数据映射单元和动态索引单元.

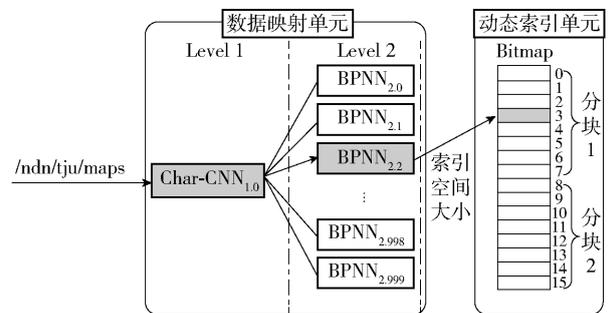


图1 C&I的基本结构

数据映射单元是由 Char-CNN 和小型 BPNN 组成的塔式2层结构,用于名称数据分布规律和累积分布函数(CDF, cumulative distribution function)的学习.塔式结构能够细化数据分布,学习出更精准的数据分布规律.该塔式2层结构包括1个 Char-CNN(第1层)、1 000个 BPNN(第2层).其中,第1层的 Char-CNN 能够学习到整体上的名称数据分布规律,将名称数据分成1 000类,具有相同前缀的名称数据将被聚合到同一分类中;第2层的每个 BPNN 能够学习到聚合后一类数据的具体分布规

律,根据该规律将其与存储器中的分布进行联系,输出其在存储器中的逻辑索引地址,即 CDF 值,其取值范围为(0,1).该塔式结构分布式模型的索引数据量由第 1 层 Char-CNN 的分类值及第 2 层每个 BPNN 的分类粒度决定.当第 1 层输出 1 000 个分类值,第 2 层每个 BPNN 的分类粒度为 0.001 时,C&I 的可索引数据量为 $1\ 000 \times 1/0.001 = 1\ 000\ 000$.因此,C&I 能够支持百万级别的数据量索引,满足当前互联网百万级别的数据分类索引需求^[10].动态索引单元则部署一个 Bitmap 结构,用于获得实际存储器索引地址.Bitmap 被均分为若干部分,每部分对应数据映射单元中学习出的一类数据规律.

1.2 C&I 数据映射单元模型参数选择

在 C&I 数据映射单元中,Char-CNN_{1,0} 卷积层、池化层、全连接层以及 BPNN_{2,k} 的各层都会直接影响到数据映射单元的分类准确率.同时,两级神经网络的各层参数共同影响着数据映射单元的存储消耗和检索速度.因此,为选择合适的参数,在 1 台配置为 Intel Xeon E5-1650 v2 3.50 GHz、DDR3 24 GB SDRAM 的小型工作站上搭建 pytorch 环境,训练 C&I 数据映射单元,并测试其性能.鉴于缺乏真实的 NDN 名称数据,且使用域名作为 NDN 的实验数据也已被业内认可^[3],故采用 1 亿个不同的域名作为实验数据集.

1) Char-CNN_{1,0} 参数选择实验

① 卷积层及池化层层数选择实验

卷积层及池化层的层数在一定程度上决定了对输入矩阵向量的特征提取深度和向量降维程度,卷积层及池化层的层数选择实验结果如图 2 所示.由图 2(a)可见,随着池化层层数的增加,Char-CNN_{1,0} 的分类准确率及模型存储消耗均不断下降,说明池化层层数的增加在一定程度上降低了模型的复杂度,但是也忽略了池化层在特征向量提取过程中的部分重要特征,影响了网络分类性能,且不同池化层层数之间的分类准确率相差较大.而分类准确率是模型的首要性能指标,因此池化层层数确定为 1 层.当卷积层为 2 时,其分类准确率最高,达到 95.51%,且不同卷积层层数之间的存储消耗相差较小,因此卷积层层数确定为 2,如图 2(b)所示.

② 全连接层层数选择实验

全连接层的作用是对经过卷积层及池化层得到的特征向量进行线性或者非线性组合,实现分类.随着全连接层层数的增加,模型存储消耗依次递增,

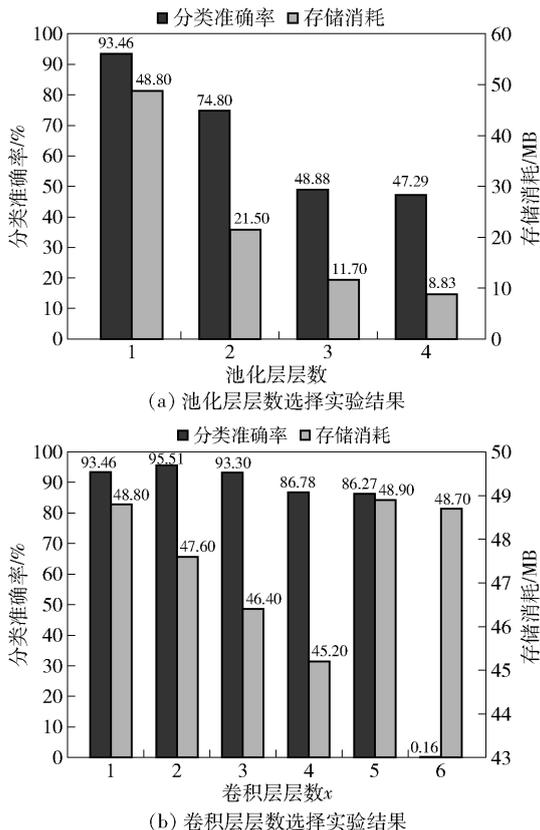


图 2 卷积层和池化层层数选择实验结果

在层数为 1 时模型存储消耗最小,如图 3 所示.同时,当全连接层层数为 2 时,模型分类准确率最高,可达到 95.51%,且其存储消耗与层数为 1 时的存储消耗相当.因此,为了权衡模型分类准确率和存储消耗,将全连接层层数确定为 2.

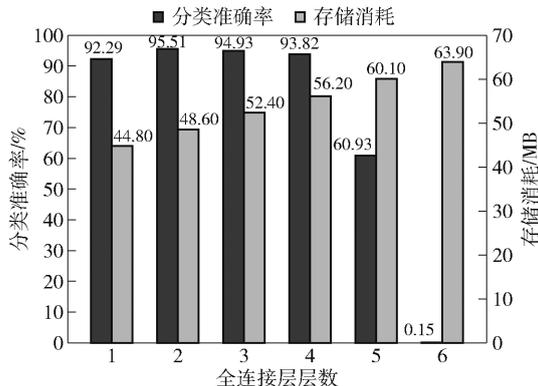


图 3 全连接层层数选择实验结果

③ 卷积核数量选择实验

卷积核的数量可以表示提取特征向量的个数.提取特征向量的个数过多会导致特征向量冗余,个数过少则会导致特征向量提取不完整,影响模型的性能.随着卷积核数量的增加,模型的存储消耗依次递增,且卷

积核数量越多,模型存储消耗越高,如图4所示,其中 x 为卷积核数量.由图4可见,当卷积核数量分别为128、256、512时,模型分类的准确率达到峰值,且变化较为平缓.因此,综合考虑模型分类准确率和存储消耗,当卷积核个数为128时,其准确率可达95.57%,且存储消耗适中,故将卷积核数量确定为128.

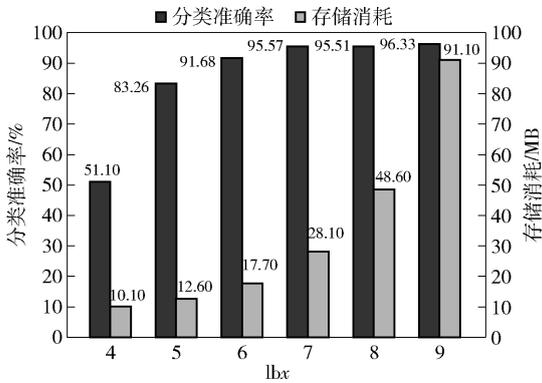


图4 卷积核数量选择实验结果

④ 全连接层神经元数量选择实验

全连接层神经元数量影响着模型的复杂度和运算量.其中,第1层全连接层的神经元数量由经过卷积层以及池化层后得到的张量决定,其余的全连接层神经元数量则可以通过实验进行适当调整,以优化模型的复杂度,降低模型的存储消耗.随着全连接层神经元数量的增加,模型的存储消耗不断增加;当全连接层神经元个数高于512时,模型分类的准确率在峰值上下变化,且幅度较小,如图5所示,其中 y 为全连接层神经元数量.因此,在保证分类准确率的基础上,尽可能地降低存储消耗,将全连接层神经元数量确定为512,此时的模型准确率为94.15%,存储消耗为13.5 MB.

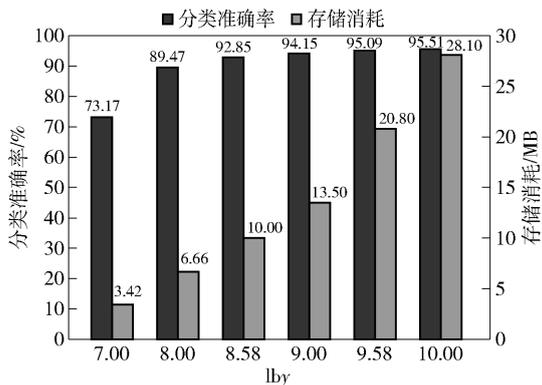


图5 全连接层神经元数量选择实验结果

2) BPNN_{2,k}模型的参数选择

BPNN_{2,k}模型共包含1000个不同的BPNN模

型,每个BPNN对应Char-CNN_{1,0}的一个分类输出,旨在学习出一类数据的具体分布规律及其分布函数. BPNN_{2,k}模型的训练集由1亿个实验数据集经过训练后的Char-CNN_{1,0}分类聚合成1000个不同的训练集,每个训练集对应一个BPNN.鉴于1000个不同BPNN的神经网络模型参数选择过于复杂,采用相同的BPNN模型、不同的训练集进行实验.借鉴learning tree中神经网络模型的参数选择^[6],将每个BPNN的模型参数确定为5个输入神经元、1层隐藏层、20个隐藏层神经元以及1个输出神经元.

2 C&I-PIT存储结构及数据检索算法

2.1 C&I-PIT存储结构

为了在未来实际应用中部署NDN,其转发平面中PIT的设计需支持高效的变长名称数据索引、硬件可支持的存储消耗以及IFA检测. C&I-PIT采用多级存储器部署方式,分别在片上存储单元和片下存储单元部署索引结构以及存储空间,其基本结构如图6所示.片上存储单元采用静态随机存取存储器(SRAM, static random access memory),其上部署C&I索引数据结构,可将具有相同名称前缀的转发信息聚合索引在同一个PIT Store中,加速对泛洪攻击检测参数的统计分析;片下存储单元采用动态随机存取存储器(DRAM, dynamic random access memory),其上部署多个与C&I输出单元一一对应的PIT Store,存储转发信息,并为每个PIT Store设置泛洪攻击检测参数,如PIT占有率、PIT过期率等. PIT Store中设置的实时更新的IFA检测参数则作为IFA检测的依据.此外,若多个不同的名称数据索引到片外存储空间的同一地址,则采用链地址法处理存储冲突.

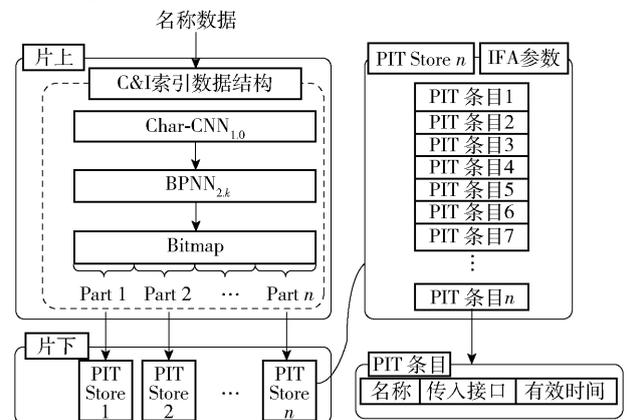


图6 C&I-PIT存储结构示意图

2.2 C&I-PIT 检索算法

NDN 数据包转发过程中, C&I-PIT 针对 interest 包和 data 包将采取不同的检索算法, 实现名称数据的高效检索. 当 interest 包到达 C&I-PIT 时, 首先根据 PIT Store 中的 IFA 检测参数判断是否发生攻击. 如果已发生攻击, 则根据攻击名称判断是否丢弃该 interest 包; 若该 interest 包是正常的, 则将 interest 包的名称输入 C&I, 得到映射后的索引地址; 然后根据索引地址找到所在的 PIT Store, 并进行精确名称匹配; 如果在 PIT Store 中有匹配条目, 则更新转发信息并丢弃该 interest 包; 否则, 为该 interest 包在该地址创建新的 PIT 条目, 存储转发信息, 并更新 IFA 检测参数.

当 data 包到达 C&I-PIT 时, 首先将 data 包的名称输入 C&I 中, 得到映射后的索引地址. 随后, 根据该索引地址在 PIT Store 中进行所有名称前缀匹配. 如果在 PIT Store 中有匹配条目, 则读取该地址中存储的 interest 包转发信息, 根据该转发信息回传 data 包. 如果在 PIT Store 中没有匹配条目, 则直接丢弃该 data 包.

3 C&I-PIT 性能评价

从名称数据聚合程度、恶意名称数据统计速度、存储消耗、吞吐量方面对 C&I-PIT 进行性能测试, 并通过与基于 CityHash256^[5] 和基于 Binary Patricia Trie^[12] 的 PIT 结构进行比较, 评估 C&I-PIT 性能.

3.1 实验设置

性能评估实验均在 1 台配置为 Intel Xeon E5-1650 v2 3.50 GHz, DDR3 24 GB SDRAM 的小型工作站上进行. 鉴于 C&I-PIT 采用 Python 语言实现, 为保证对比实验的公平性, Binary Patricia Trie-PIT 和 CityHash256-PIT 均使用 Python 语言实现. C&I-PIT 中, 其索引结构参数设置与 3.3 节相同, Bitmap 的每个槽大小设置为 2 byte. CityHash256-PIT 的每个索引值大小设置为 4 byte. 此外, 对比实验数据集均由不同数据量的域名组成.

3.2 C&I-PIT 名称数据聚合程度

为支持 IFA 的快速检测以及恶意名称前缀的精准定位, C&I-PIT 通过索引结构 C&I 将相同名称前缀的名称数据分类、聚合, 方便 PIT 参数的统计. 为验证 C&I-PIT 对相同名称前缀的聚合程度, 测试数据集以 /ndn/tju 为固定前缀, 随机生成了 50、100、150、200 万个不同域名, 并进行了实验测试, 实验结

果如图 7 所示. 鉴于 C&I 索引结构以字符为分类粒度, 名称数据集的分类结果主要分为 3 类. 可以看出, 不同数据量名称数据的分布大致相同, 相同名称前缀的名称数据被有效地聚合在一起. 其中, 不同数据量的名称数据集中约有 70% 的名称数据聚合到分类 1 中, 约 15% 的名称数据聚合到分类 2 中, 约 13% 的名称数据聚合到分类 3 中, 仅有 2% 的名称数据散布到其他分类中. 因此, C&I-PIT 能够有效地聚合相同名称前缀的名称数据, 当 IFA 发生时, 只需到特定的 PIT Store 中进行 PIT 参数的统计以及恶意前缀的精准检测.

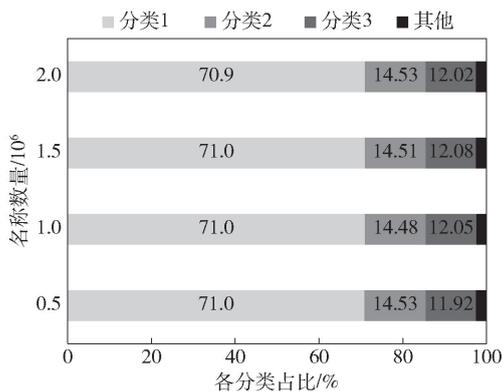


图 7 名称数据聚合的程度

3.3 恶意名称数据的统计速度

IFA 检测过程中, 需要对 PIT 占有率、interest 包过期率等 PIT 参数进行统计监测, 以判断 IFA 发生的概率^[9]. 而 PIT 参数的统计主要取决于对恶意名称数据的统计. 恶意名称数据的统计速度越快, 越能更及时地发现 IFA, 辨认出 IFA 攻击的名称空间. 因此, 以 /ndn/video/evil 为恶意名称前缀, 恶意名称数据与合法名称数据的比例为 1:1, 构建了 50、100、150、200 万个不同名称数据进行实验分析, 并与 Binary Patricia Trie-PIT 以及 CityHash256-PIT 进行对比分析.

表 1 所示为 3 种 PIT 结构的恶意名称数据统计时间. 当名称数量为 50、100、150、200 万个时, C&I-PIT 的恶意名称数据统计时间分别是 8.69、17.67、23.40、31.83 s, 均低于其他 2 种方案. 原因在于 C&I-PIT 能够聚集相同名称前缀的名称数据, 恶意名称数据被聚合到少数 PIT Store 中, 其信息统计仅需在特定的 PIT Store 中进行, 不仅极大地提高了检测效率, 而且能精准地确定具体的恶意名称前缀. 而 Binary Patricia Trie-PIT 以及 CityHash256-PIT 并没有聚合相同名称前缀的作用, 需要在整个 PIT 中

进行恶意名称前缀数量的统计,且无法确定恶意名称前缀.

表1 恶意名称数据的统计时间

名称数量/ 10 ⁶ 个	C&I-PIT/ s	Binary Patricia Trie-PIT/s	CityHash256- PIT/s
0.5	8.69	10.49	39.02
1.0	17.67	20.65	78.60
1.5	23.40	31.65	118.86
2.0	31.83	40.41	156.82

3.4 存储消耗

对于 C&I-PIT、Binary Patricia Trie-PIT 和 City-Hash256-PIT,存储相同数量的 interest 包转发信息的存储消耗是相同的,因此,不考虑转发信息的存储消耗,仅对各方索引结构的存储消耗进行实验对比.

C&I-PIT 中,C&I 存储消耗分为神经网络索引结构及 Bitmap 两部分.其中,神经网络索引模型共包含 1 个 Char-CNN_{1,0}和 1 000 个 BPNN_{2,k},参数设置与 3.3 节相同.Char-CNN_{1,0}存储消耗为 13.5 MB,每个 BPNN 存储消耗均为 $(20 \times 5 + 20 \times 1 + 1 \times 20 + 1 \times 1) \times 8 = 1\ 128$ byte,最终神经网络的索引结构存储消耗为 $13.5 + (1\ 000 \times 1\ 128) / 1\ 024^2 \approx 14.6$ MB. Bitmap 的存储消耗则由其误判率和槽的个数决定.

在误判概率低于 1% 的情况下^[6],通过实验测试了 C&I-PIT, Binary Patricia Trie-PIT 以及 City-Hash256-PIT 的存储消耗,实验结果如表 2 所示.实验结果表明,当名称数量为 50、100 万时,C&I-PIT 的存储消耗分别为 68.6、125 MB.相较于 City-Hash256-PIT,C&I-PIT 的存储消耗更低,其优势在于通过 C&I 索引模型得到了较为均匀的分布,存储空间的利用率更高.此外,一个 4 SRAM 线卡的最大存储空间可达 128.746 MB^[12],当数据量达到百万级别时,C&I-PIT 和 Binary Patricia Trie-PIT 的索引结构可部署在 SRAM 上,已满足 C&I-PIT 的存储设计需求.此外,C&I-PIT 存储结构支持高效的 IFA 检测,而其余 2 种 PIT 结构并不具备该性能.

表2 C&I-PIT 存储消耗性能

名称数量/ 10 ⁶ 个	C&I-PIT/ MB	Binary Patricia Trie-PIT/MB	CityHash256- PIT/MB
0.5	68.60	26.70	104
1.0	125.00	53.41	204

3.5 吞吐量

针对 3 种 PIT 结构的吞吐量,分别采用 50、100 万个名称数据进行实验,结果如表 3 所示.可以看出,C&I-PIT 和 Binary Patricia Trie-PIT 的吞吐量性能远远优于 CityHash256-PIT,因为在百万级别的数据量下,能够将索引结构部署在 SRAM 上,大大提高了吞吐量的性能.而 C&I-PIT 与 Binary Patricia Trie-PIT 的吞吐量则处于同一数量级,在百万级别的数据量下,C&I-PIT 的吞吐量达到了 1.42 MP/s,可以即时处理网络中百万级别的数据包请求,已满足 C&I-PIT 的吞吐量设计需求.

表3 C&I-PIT 吞吐量性能

名称数量/ 10 ⁶ 个	C&I-PIT/ (MP·s ⁻¹)	Binary Patricia Trie-PIT/(MP·s ⁻¹)	CityHash256- PIT/(MP·s ⁻¹)
0.5	1.40	6.81	0.013
1.0	1.42	6.60	0.013

4 结束语

针对命名数据网中高效的数据索引结构以及 PIT 结构设计,提出了基于字符卷积神经网络的 C&I 索引结构和 C&I-PIT 方案,且具有良好的实验效果.未来的工作是进一步将 C&I-PIT 部署在实际通信过程中,在真实环境下验证其 IFA 的检测效果和存储结构的性能.同时,根据其实际性能的表现调整模型参数和结构,进一步研究其实际部署方案.

参考文献:

- [1] 王莹,费子轩,张向阳,等.移动边缘网络缓存技术[J].北京邮电大学学报,2017,40(6):1-13.
Wang Ying, Fei Zixuan, Zhang Xiangyang, et al. Survey on caching technology in mobile edge networks[J]. Journal of Beijing University of Posts and Telecommunications, 2017, 40(6): 1-13.
- [2] 严坤,赵琰.“互联网+”时代物联网终端发展趋势探析[J].科技经济导刊,2020,28(2):24.
Yan Kun, Zhao Yan. Analysis of the development trend of IoT terminals in the “Internet +” era[J]. Technology and Economic Guide, 2020, 28(2): 24.
- [3] Zhang L, Estrin D, Burke J, et al. Named data networking (NDN) project NDN-0001 [EB/OL]. Palo Alto: Xerox Palo Alto Research Center, 2010-10-31 [2020-08-20]. <http://named-data.net/>.
- [4] Huang Kun, Wang Zhaohua. A hybrid approach to scalable name prefix lookup[C]//2018 IEEE/ACM 26th In-

- ternational Symposium on Quality of Service (IWQoS). Banff: IEEE, 2018: 1-10.
- [5] Li Zhuo, Liu Kaihua, Zhao Yang, et al. MaPIT: an enhanced pending interest table for NDN with mapping bloom filter [J]. IEEE Communications Letters, 2014, 18(11): 1915-1918.
- [6] Yan Liu, Li Zhuo, Liu Kaihua. Learning tree: neural network-based index for NDN forwarding plane [C] // ACM SIGCOMM 2019 Conference Posters and Demos. Beijing: ACM, 2019: 63-65.
- [7] Gasti P, Tsudik G, Uzun E, et al. DoS and DDoS in named data networking [C] // 2013 22nd International Conference on Computer Communication and Networks (ICCCN). Nassau: IEEE, 2013: 1-7.
- [8] Wang Kai, Bao Wei, Wang Yingjie, et al. Evaluating and mitigating malicious data aggregates in named data networking[J]. KSII Transactions on Internet and Information Systems, 2017, 11(9): 4641-4657.
- [9] Shinohara R, Kamimoto T, Sato K, et al. Cache control method mitigating packet concentration of router caused by interest flooding attack [C] // 2016 IEEE Trustcom/BigDataSE/ISPA. Tianjin: IEEE, 2016: 324-331.
- [10] Yi C, Afanasyev A, Wang L, et al. Adaptive forwarding in named data networking[J]. ACM SIGCOMM Computer Communication Review, 2012, 42(3): 62-67.
- [11] Zhang X, Zhao J, LeCun Y. Character-level convolutional networks for text classification[C] // Advances in Neural Information Processing Systems. Montreal: NIPS, 2015: 649-657.
- [12] Song Tian, Yuan H, Crowley P, et al. Scalable name-based packet forwarding: from millions to billions [C] // 2nd International Conference on Information-Centric Networking. San Francisco: ACM, 2015: 19.