

컨테이너 환경에서의 RDMA NIC 마이크로아키텍처 자원 고갈 영향 분석



김건우¹, 김진우^{2,†}, 박병준²

^{1,2}광운대학교 (대학원생, 교수)

RDMA


- **Remote Direct Memory Access (RDMA)**

- Network Interface Card (NIC)을 통해 호스트 메모리에 커널을 우회하여 직접 접근하는 기술
- Host CPU 적은 소모, 빠른 데이터 교환 등등... 클라우드 환경에 널리 도입되고 있다



<https://www.fibermall.com/ko/blog/rdma-key-technology-for-arithmetic-networks.htm>

RDMA



- **Verbs**

- Control Verbs
- Data Verbs


- **초기화 과정**

- QP, CQ와 같은 필요한 객체 생성
- 신뢰, 비신뢰 연결 설정
- 호스트의 DRAM 영역을 할당하고 가상 주소에서 물리적 주소로의 매핑 수행

- **Mellanox API**

- `ibv_create_qp`, `ibv_alloc_pd`, ETC.
- `rdma_create`, `rdma_bind`, ETC.

RDMA



- **RDMA 작업 수행**

- SEND/RECV
- WRITE/READ
- ATOMIC

- **Mellanox API**

- `ibv_post_send`, `ibv_post_recv`, `ibv_get`, ETC.
- `rdma_read`, `rdma_write`, ETC.


SmartNIC

- **Network Interface Card (NIC)**
 - 컴퓨터를 네트워크에 연결하여 통신하기 위해 사용하는 전통적인 하드웨어 장치
- **Smart NIC (RDMA NIC, RNIC)**
 - 다양한 네트워크 관련 작업을 하드웨어로 오프로드하고 가속화하여 처리하는 장치
 - RoCEv2(RDMA over Converged Ethernet version 2)

Traditional
NIC




NIC



Smart NIC


Smart
NIC
Storage
Security
Networking

マイクロアキテ처 리소스



- RDMA NIC 내부에서 동작하는 하드웨어 자원
- 데이터 전송, 메모리 관리, 프로토콜 처리 등과 같은 작업을 하드웨어 수준에서 최적화.
- TX/RX Pipeline
 - 패킷 처리(패킷 분류, 스케줄링, 헤더 처리 등)를 담당
- MTT/MPT
 - 메모리 관리
- Workload Acceleration Engine
 - 데이터 작업을 가속화하기 위한 하드웨어 엔진

성능 격리 문제 [1]






- **Multi-tenant**

- 여러 테넌트가 동일한 하드웨어 자원을 공유하여 독립적으로 운영되는 환경

[1] Grant, Stewart, et al. "SmartNIC Performance Isolation with FairNIC: Programmable Networking for the Cloud", ACM, July, 2020

성능 격리 문제 [1]



경쟁에 따른 Bandwidth 변화

- **Multi-tenant**


- 여러 테넌트가 동일한 하드웨어 자원을 공유하여 독립적으로 운영되는 환경

- **자원 격리 문제**

- 악의적인 의도를 가지거나 의도치 않은 행동을 한 테넌트가 있을 때
 - 자원을 고갈시키거나 경쟁하여 다른 테넌트의 성능을 저하시킨다.

관련 연구 및 동향

- RDMA의 성능 격리 문제는 여러 이전 연구에서 다루어졌다 [1].
 - 이들은 대부분 가상머신 또는 베어메탈 환경에서 분석되었다는 한계점이 있다.
- 최근 클라우드의 동향
 - 컨테이너를 사용한 클라우드 네이티브 아키텍처를 지향하기 때문에 RDMA 또한 컨테이너에 맞게 도입하려는 움직임을 보이고 있다.



Alibaba Cloud supports Super Computing Cluster (SCC), RoCE, and Virtual Private Cloud (VPC). RoCE is dedicated to RDMA communication. SCC is mainly used in high-performance computing, artificial intelligence, machine learning, scientific computing, engineering computing, data analysis, audio and video processing, and other scenarios.


Using RDMA on Container Service for Kubernetes




[1] Grant, Stewart, et al. "SmartNIC Performance Isolation with FairNIC: Programmable Networking for the Cloud", ACM, July, 2020

연구 목적

- 컨테이너 환경에서 RNIC의 마이크로아키텍처 자원이 고갈되었을 때의 영향을 분석한다.



위협 모델



- 위협 모델

- 공격자는 특정 Control/Data Verbs 남용할 수 있다고 가정한다.
 - 과도한 큐 페어(QP) 및 완료 큐(CQ) 생성.
 - 새로운 메모리 위치에 접근하여 연산 수행 가능.
- 의도적으로 예외 상황을 유발시킴으로써 RDMA서비스 불능으로 만들 수 있음을 가정한다.

공격 시나리오





- 공격 시나리오

- 1) 큐 플러딩 공격


다수의 큐 페어(QP) 또는 완료 큐(CQ)를 통해 RNIC의 TX/RX PU의 처리 능력 초과.

- 2) 캐시 소진 공격

새로운 메모리 위치에 접근하는 RDMA 연산 수행을 통해 캐시 처리 능력 초과.




공격 시나리오 : 1) 큐 플러딩 공격




- 정상 작업 요청
 - TX Pipeline, QP.

공격 시나리오 : 1) 큐 플러딩 공격



- 정상 작업 요청
 - TX Pipeline, QP.
- 공격 방식
 - 다수의 큐 페어(QP) 또는 완료 큐(CQ)를 통해 지속적인 데이터 송수신.
- 공격 영향
 - TX/RX PU의 처리 능력을 초과시킨다.
 - 정상적인 데이터 전송 작업의 지연을 유발시켜 전체 대역폭을 감소시킨다.


공격 시나리오 : 2) 캐시 소진 공격



- 정상 작업 요청

- Cache Translation, Cache Connection.
- 메모리 접근 및 관리.

공격 시나리오 : 2) 캐시 소진 공격



- 정상 작업 요청

- Cache Translation, Cache Connection.
 - 메모리 접근 및 관리.

- 공격 방식




- 지속적으로 새로운 메모리 위치에 접근하는 RDMA 연산 수행.

- 공격 영향

- 캐시 히트율을 낮추고 Cache Translation을 처리하는 캐시를 고갈 시킨다.
 - 이를 통해 Latency와 Cache Miss가 증가하게 된다.

실험 환경

- 성능 측리 시뮬레이션 환경
 - Bluefield-3 RNIC
 - RoCEv2 프로토콜 기반 RDMA 통신
 - SR-IOV
 - VF를 통해, 독립된 큐 페어, 완료큐 사용
 - Docker
 - Container
- 성능 벤치마킹 도구
 - Perftest (ib_write_bw, ib_read_lat 등)
 - Perf



공격 영향 분석 : 1) 큐 플러딩 공격

- 공격자가 5초마다 QP 및 CQ 자원을 과도하게 사용함.
- Victim의 대역폭이 26.61 Gbit/sec에서 1.64 Gbit/sec으로 약 93.9% 급격히 감소.
- 이는 TX/RX 처리 유닛이 점진적으로 과부하되며 대역폭이 크게 저하됨을 의미.




Fig. 3 Bandwidth changes due to TX/RX processing unit overload

공격 영향 분석 : 2) 캐시 소진 공격

- 공격자가 연산에서 새로운 메모리 위치에 지속적으로 접근하여 캐시 고갈 유도.
- 초기 지연 시간 $1.56\mu\text{s}$ 에서 $1,746.34\mu\text{s}$ 로 약 1,117배 급격히 증가.
- 캐시 미스 비율 14.48%에서 31.07%로 약 115% 증가하였다.






Fig. 4 Latency and cache miss change rates due to resource depletion

공격 탐지의 어려움

- 기존 일반적인 모니터링 방식으로는 공격을 탐지하는데 한계가 있다.
 - 호스트의 CPU, 메모리를 우회하여 NIC 자원에 접근하기 때문.



HT-verbs: Threshold 기반 자원 관리



- **HT-verbs**
 - 자원 고갈 공격을 완화하기 위해 Threshold 기반 자원 관리 방식을 제시.
 - RDMA Verbs를 Hot, Warm, Cold로 분류.
- **흐름**
 - 분류 전, RDMA Verbs의 호출 기록을 주기적으로 집계한다.
 - 특정 캐시 접근과 소모율에 대한 패턴을 분석한다.
 - 과거/현재 패턴 변화를 분석하여 분류 기준을 업데이트 한다.
- **주기적으로 분류에 맞는 동작 수행**
 - Hot : 우선 순위가 낮은 컨테이너 접근 시 지연을 유도하거나 제한한다.
 - Warm : 자원 접근 시 동일한 격리 제공한다.
 - Cold : 높은 성능을 제공한다.

결론

- **연구 목적**
 - 컨테이너에서 RoCEv2 기반 BlueField-3 RNIC의 성능 격리 문제를 실험적 분석하였다.
- **실험 결과**
 - TX/RX Processing Unit 과 내부 Cache 자원 고갈.
 - 대역폭: 약 93.9% 감소, 지연 시간: 약 1,117배 증가, 캐시 미스: 115% 증가.
- **해결 방안 제시**
 - HT-verbs : Threshold 기반 자원 관리.
 - RDMA verbs 사용 패턴을 기준으로 Hot, Warm, Cold 분류 및 동작.
- **향후 연구**
 - RDMA Verbs 관점에서 RNIC의 마이크로아키텍처에 미치는 영향 분석.
 - HT-verbs 시스템을 구축하여 실제 환경에서 적용 가능성 검증.

감사합니다.