

分散KVSにおけるメニーコアを活用した プロキシによるクエリ集約及び排他制御

○三輪 竜也¹ 川浪 大知^{1,2} 川島 龍太¹ 松尾 啓志¹

¹ 名古屋工業大学

² 現在, 株式会社ボスコ・テクノロジーズ

- 分散キーバリューストア (KVS)
 - キーとバリューからなる単純なデータ構造
 - 複数のノードでデータを分散管理

通信処理における問題点

排他制御における問題点

プロキシを用いたクエリ集約

クエリ集約の有効性を確認[†]

提案手法


- プロキシの高速化
- プロキシによる排他制御

[†] Daichi Kawanami et al. "A Proxy-Based Query Aggregation Method for Distributed Key-Value Stores", Proc. 6th International Conference on Future Internet of Things and Cloud Workshops (FiCloudW), 2018

リングアーキテクチャ


3

- コンシステントハッシングによってデータを分散
- クエリのルーティング



通信処理における問題点

排他制御における問題点




クエリ転送で発生するパケット数を削減し、ネットワークの処理負荷を軽減することが必要

□ Data Plane Development Kit (DPDK)

- ユーザ空間からNICをポーリングすることで
コンテキストスイッチを回避

□ ScyllaDB

- ネットワークスタックにDPDKを使用
- Cassandra互換な分散KVS
- Cassandraの10倍のスループットを達成^{†1}




DPDKを用いることで分散KVSの性能が向上

**DPDKを用いるだけではショートパケットを
ワイヤレートで処理できない^{†2}**

^{†1} <https://www.scylladb.com/product/benchmarks/>

^{†2} R. Kawashima et al., "Evaluation of Forwarding Efficiency in NFV-nodes toward Predictable Service Chain Performance," IEEE Trans. on Network and Service Management, 2017.


□ クエリ集約によりパケット数を削減



† Daichi Kawanami et al. "A Proxy-Based Query Aggregation Method for Distributed Key-Value Stores", Proc. 6th International Conference on Future Internet of Things and Cloud Workshops (FiCloudW), 2018

排他制御における問題点

7




排他制御のための通信が増加

プロキシによる排他制御

8


- プロキシ上で排他制御することで一貫性制御の通信を削減

従来手法



**KVSノード間で
一貫性制御が必要**


提案手法



**KVSノード間で
一貫性制御が不要**

クエリ集約の有効性

9



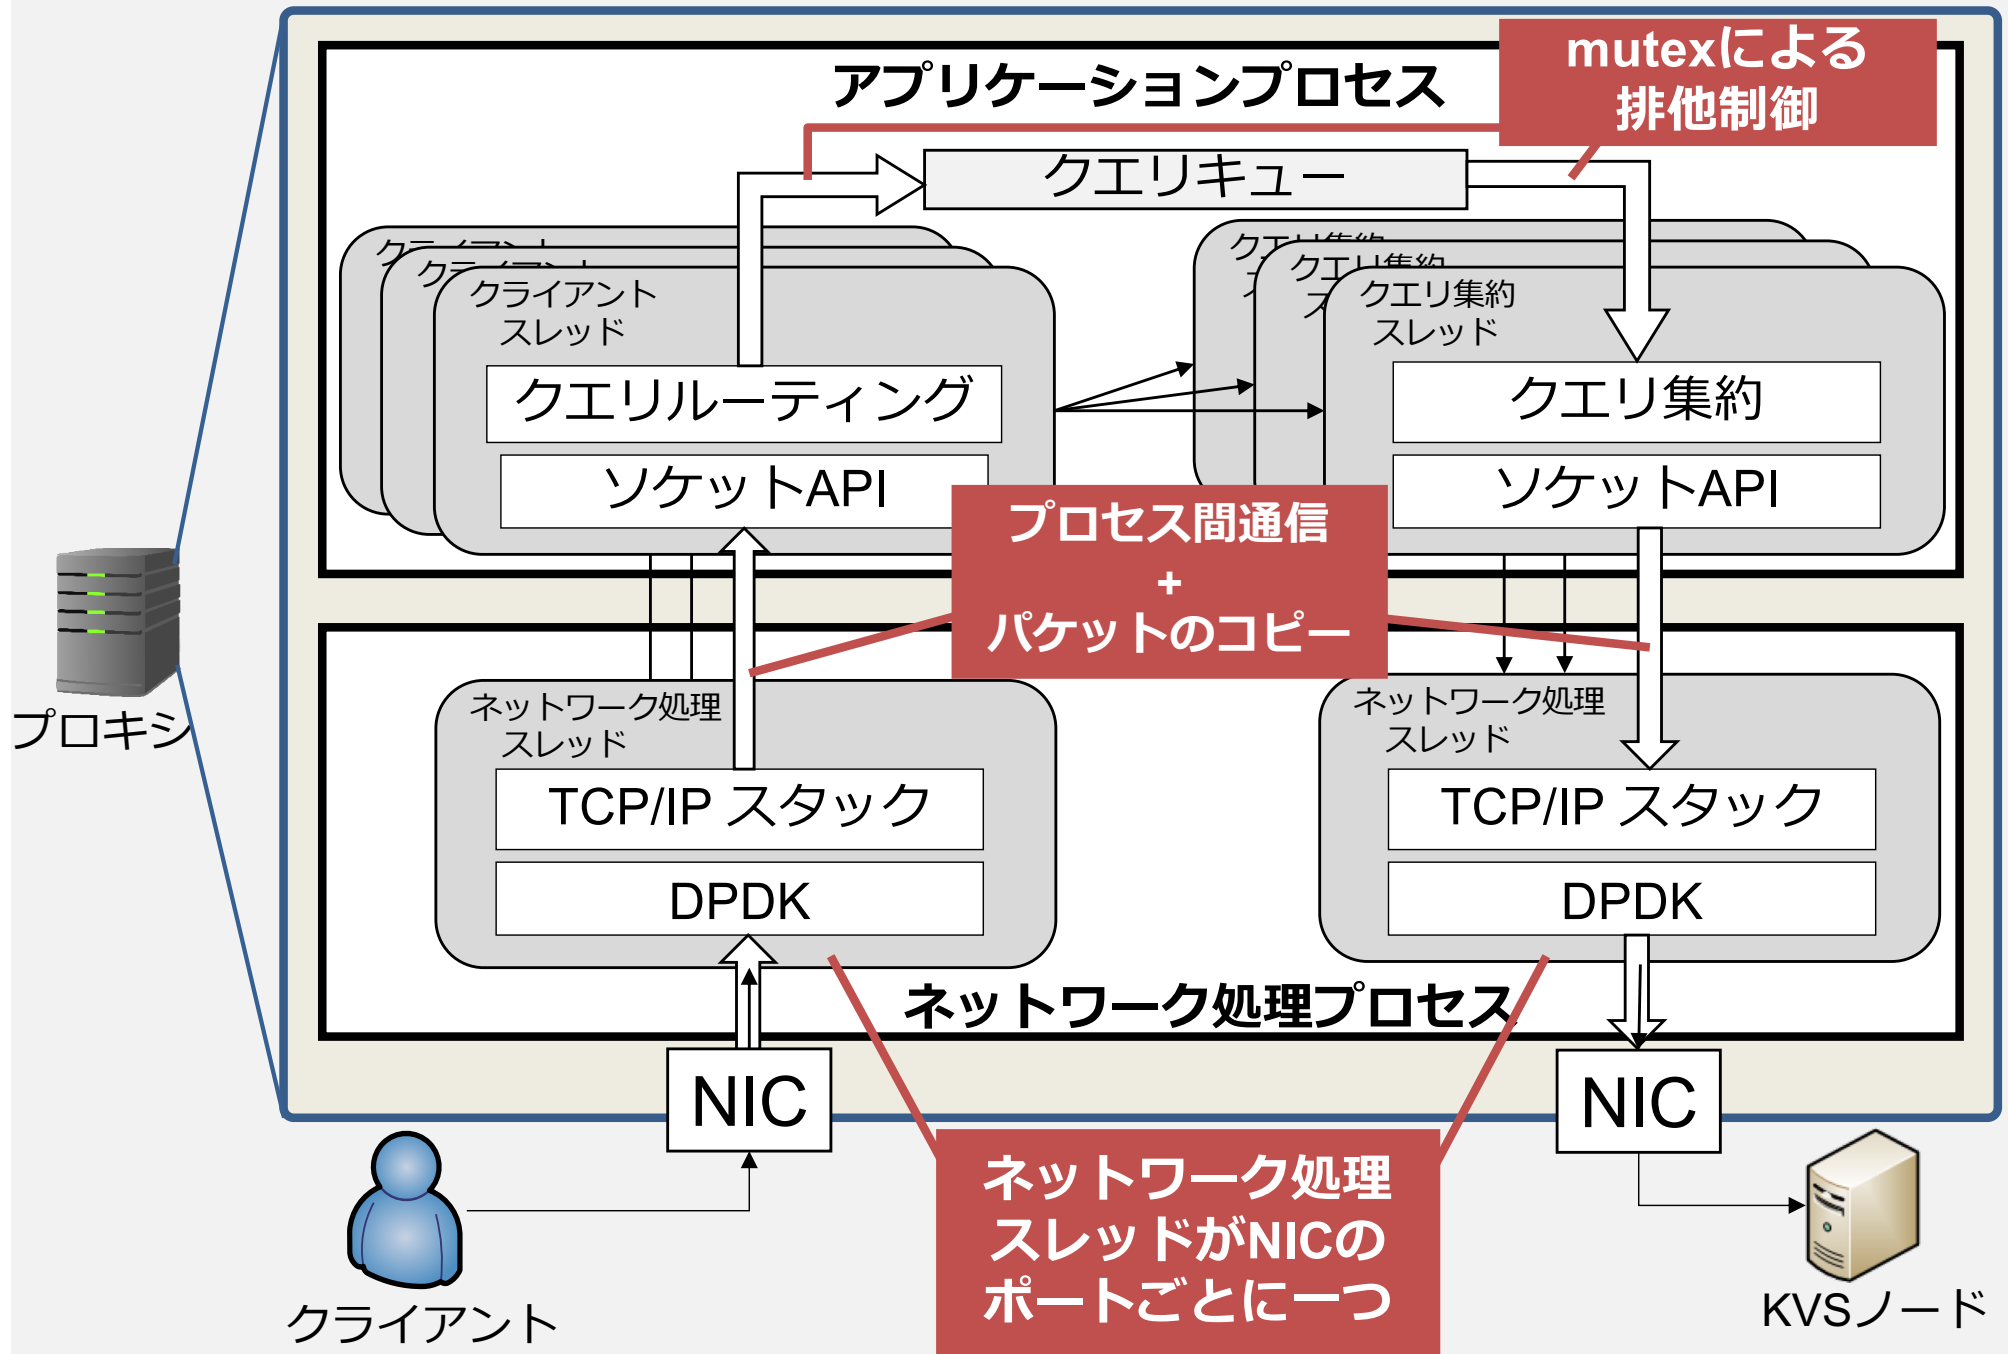
提案手法

- プロキシの高速化
- プロキシによる排他制御

した場合

初期のプロキシの実装における問題点


10



プロキシの高速化実装


CAS命令を用いた
排他制御

11



プロキシによる排他制御



12



排他制御のための通信を削減

プロキシ内部の各コンポーネントの役割

13



□ KVSノード


- DPDKを利用
- クエリの受信と結果の送信処理
- 少数ノードで実験を行うため、データの永続化は行わない

□ クライアント

- DPDKを利用
- 2種類の動作

プロキシなし：直接KVSノードに送信 (1 hop)


プロキシあり：プロキシにクエリを送信 (2 hop)



□ KVSノード

■ Cassandraを使用

□ 2通りの環境でロック獲得レイテンシを評価



□ マシンスペック

マシン性能 (プロキシ)

CPU	Core i9-7980XE 2.6 GHz, 18 cores / 36 threads
RAM	64 GB
NIC	Intel X550T (10 GbE, dual port)
OS	Ubuntu 16.04

□ プロキシ性能評価

■ マシン台数

- クライアント:3台
- KVSノード:5台
- プロキシ:1台

■ ワークロード

- キーバリュースサイズ 10bytes
- 書き込みクエリ
- 10万種類のキーを一様に生成

マシン性能 (クライアント,KVSノード,Cassandraノード)

CPU	Core i5-4460 3.2 GHz, 4 cores / 4 threads
RAM	16 GB
NIC	Intel X540-T2(10 GbE, dual port)
OS	Ubuntu 16.04

□ ロック獲得評価

■ マシン台数


- クライアント:1台
- Cassandraノード
5台(プロキシあり)
3~9台(プロキシなし)
- プロキシ:1台

■ ワークロード

- キーバリュースサイズ 10bytes
- ロック獲得クエリ
- 100万種類のキーを一様に生成

プロキシの性能評価


17



レイテンシ	最小値(ms)	中央値(ms)	平均値(ms)	最大値(ms)
プロキシあり	0.051	217	412	9995
プロキシなし	0.035	0.48	1.6	2328


スケーラビリティの評価

18




1. キュー操作の競合
2. ハイパースレッディングを使用

スループット (M que)



ロック獲得レイテンシの評価

19



□ まとめ

■ クエリ集約を行うプロキシの性能を改善

- マルチキューへの対応
- プロセス統合による、プロセス間通信の削減
- CAS命令によるスレッド間の通信コストの削減
- 10 Gbpsのスループットを持つプロキシを実現

■ プロキシに排他制御機能を追加

- KVS間での排他制御のための通信を削減

□ 今後の課題

■ トランザクション処理機能の実現

■ プロキシの単一故障点解消