

最初は他の論文でも紹介しようと思ってて....

The Scalable Commutativity Rule: Designing Scalable Software for Multicore Processors (SOSP '13)

結局表題のこちらにしました

<https://www.usenix.org/conference/atc14/technical-sessions/presentation/hu>

この文書の諸注意

柏原はストリーム処理系の専門家ではない。

説明の不足やミスがあってもご了承ください。

あらすじ

読むモチベーション

ストリーム処理系というのと、decentralized, DHTなどのキーワードに惹かれて。

この研究のチャレンジ

jobごとにdecentralizedな “many masters”アーキテクチャの構成でスケールさせる
メモリ効率の良い compressed buffer tree (CBT)にtemporaryデータを格納する
worker processでの集約 (aggregation) にはshared reducer trees(SRT)というテクニックが使われる

論文の結論

- good performance and scalability
- future work: explore task isolation

イントロ 背景+ストーリー

ストリーム処理が流行っている
ビジネスマーケティングでの意思決定
SNSにおけるスパム検知
などがストリーム処理でやりたいこと。

具体的な例として(product, click) pair の列からtop-k求めたい、とか

イントロ その2: ストリーム処理系で求められるもの

- flexibility
- 既存のシステムには柔軟さが無い
Spark Streamingなどはある種のバッチ計算の連続を扱う
Stormだとデータフローのグラフ(頂点)ごとに非同期処理を行ったりする
これらはcomposableでないらしい

私の観点からすると、アプリケーションの開発者はストリーム処理系とそのAPIにあわせてシステムを構築するものだと思っていたが、著者の主張ではストリーム処理系自体にもうちょっと柔軟性を持たせたい模様。

- scaling with job diversity

MapReduceだとsingle master/-many workers スタイル。centralized。中央集権型。
中央集権型だと、複雑なpipeline/cyclic dataflowだとボトルネックになりがちだよー

- obtaining high performance for incremental updates

既存のシステムでは困難らしい

インメモリでのhashtableのようなデータ構造では、過去の状態と新しい状態を持つのが...

TODO: 具体的にどんなデータ構造がよくわからん

- ELF: Efficient, Lightweight, Flexible stream processing system

FがFastからFlexibleに変わった？

figure 2

DHTのPastryを使う。

Design

Overview

Figure 3

level1: webserver + Agent

level2: master and set of workers (ここでDHTのオーバーレイネットワーク構築してる？)

level3: ELF API, プログラムのbatch/streaming analysis, interactive queries向け

CBT-based Agent

DHT-based SRT

Implementation

System Architecture

Figure 8

Agentの役割

Job master

- Job builder:
- Job tracker:
- Job feedback:
- Job coordinator:

Job worker

- Input receiver:
- Job parser:
- PAOs execution:

Consistency

複数のノードをまたいで計算をしたとき、一貫性の問題がある。どうやって解決しているか。
他のシステムだと、Borealisはノード間の同期で、Stormは一貫性無視らしいが。。？

CBT + timestampで担保しているような記述に見えるが。

Fault Recovery

ELFは次の2つの障害に対応している。

- transmission faults
- agent failures

transmissionについてはXOR protocolで検出、recordのintegrityチェックして、エラーがあれば再送する。

XOR protocolとは何なのか、実装は読んでいてよくわからない。XORで通信データなどのチェックサムを取っているのかもしれない。

agent failuresについては、CBTとP2Pで対処。障害が発生するとキャッシュしていたCBTからSRTが再構築される。すべてのPAOIはチェックポイントから新しく再計算される。

翻訳したが、よくわからん。

Straggler Mitigation

1st “mirroring straggler” 遅いと推測されるタスクのコピーを近傍のagentで実行

2nd “leaping straggler” 遅延のあるスナップショットの計算はスキップし、次の期間になったらストリームの計算を再開する

論文の見所

decentralized (中央集権でない) architecture for scalable streaming procesing

論文に関するツッコミ所(質問したい、確認したい所)

- どうやってdecentralizedを実現しているのか？
 - CBT based agentに書いてあるように
- ジョブ(タスク)はどうやって管理してるのか？
 - Job master(agent)が管理していると思われる
- 本当にスケールするのか？
 - DHTなのでしそうな気はする
 - DC内で1280台で実験している
- 実装は？
 - OSSではない
 - 研究のためのプロトタイプ

Keywords

CBT: Compressed Buffer Tree

<http://www.pdl.cmu.edu/PDL-FTP/HECStorage/git-cercs-12-08.pdf>

hash-based aggregator

buffer: key/pair単体で圧縮するのは計算/空間効率が悪いので、バッファ単位で圧縮する
CBTの中でPAOを扱う

PAO: Partial Aggregation Object

CBTの論文中で定義されている。

SRT: Shared Reducer Tree

総評

2014年の資料ということもあって、比較的新しめの論文(GoogleのMilwheelなど)や処理系(Spark Streaming等)にもRelated Workなどで言及できている様子はある。他システムと比べた評価実験もやっている。

インメモリのデータ構造であるCBTと、その中で扱っているPAOの概念については、CBTの論文を読まないとほとんど中身がわからない(読めていない)。

DHTのアルゴリズムになぜPastryを使ったのかは書いていない。しかし、many-mastersと呼ぶアーキテクチャでDHTを使ったストリーム処理系を構築したという点では独創的である。

動画のメモ

6:25 既存手法、1 master, multi workers

7:21 propose: DHT based

8:36 DHT hashingの説明

9:36 many masters, many workers

9:54 software architecture

1st layer: located in each Web server, DHT

2nd layer: key-value pairs stored.

3rd layer: Open to programmer. Programmer can implement different job/data flow and so on.

10:49 ELF Design - ELF have ELF QL

example: micro promotion. product and clicks key/value pairs.

Compressed Buffer Tree: (1) insert, (2) flush, (3) empty actions

stateful, asynchronous, and synchronous execution

12:48 ELF Design - SRT (Shared reduced tree)

よくわからん

15:05 Pipeline, cyclic dataflow, and cross-job coordination

15:20 Using Elfexample

15:30 Evaluation

- latency

related work: Storm and Muppet

17:36 ZConclusion

- good performance and scalability

- future work: explore task isolation

Muppet: MapReduce-Style Processing of Fast Data

http://vldb.org/pvldb/vol5/p1814_wanglam_vldb2012.pdf