

Project Tungsten

Bringing Spark Closer to Bare Metal

Reynold Xin @rxin
Spark Conference Japan
Feb 8, 2016



Hardware Trends

Storage

Network

CPU

Hardware Trends

2010

Storage 50+MB/s
(HDD)

Network 1Gbps

CPU ~3GHz

Hardware Trends

	2010	2016
Storage	50+MB/s (HDD)	500+MB/s (SSD)
Network	1Gbps	10Gbps
CPU	~3GHz	~3GHz

Hardware Trends

	2010	2016	
Storage	50+MB/s (HDD)	500+MB/s (SSD)	10X
Network	1Gbps	10Gbps	10X
CPU	~3GHz	~3GHz	☹️

On the flip side その一方で

Spark IO has been optimized

Spark のIOは最適化された

- Reduce IO by pruning input data that is not needed
不要な入力データを排除することによる IO の削減
- New shuffle and network implementations (2014 sort record)
新しいシャッフルとネットワークの実装 (2014年ソート記録)

Data formats have improved

データフォーマットが改善された

- E.g. Parquet is a “dense” columnar format
Parquet は「密」なカラムナフォーマット

Goals of Project Tungsten Project Tungsten のゴール

Substantially improve the **memory and CPU** efficiency of Spark backend execution and push performance closer to the limits of modern hardware.

Spark の「バックエンドの実行」のメモリとCPU効率を実質的に改善することと、性能をモダンなハードウェアの限界に近づけること

Note the focus on “execution” not “optimizer”: very easy to pick broadcast join that is 1000X faster than Cartesian join, but hard to optimize broadcast join to be an order of magnitude faster.

「最適化」ではなく「実行」に注目していることに注意: broadcast join を Cartesian join より 1000 倍早くするのはとても簡単だが、broadcast join をケタ違いに早くなるよう最適化するのは難しい

Phase 1

Foundation

立ち上がり

Memory Management

メモリ管理

Code Generation

コード生成

Cache-aware Algorithms

(ハードウェア)キャッシュを意識したアルゴリズム

Phase 2

Order-of-magnitude Faster

けた違いの高速化

Whole-stage Codegen

全ステージ
コード生成

Vectorization

ベクトル化

The background is a textured teal watercolor wash, with darker, more saturated areas at the top and lighter, more translucent areas at the bottom. The overall effect is soft and artistic.

Phase 1

Laying The Foundation

Optimized data representations

最適化されたデータ表現

Java objects have two downsides:

- Space overheads
- Garbage collection overheads

Java オブジェクトには2つのマイナス面がある

- 空間のオーバーヘッド
- ガベージコレクションのオーバーヘッド

Tungsten sidesteps these problems by performing its own manual memory management.

Tungsten はこれらの問題を、独自のメモリ管理を行うことで回避する

The overheads of Java objects

Java オブジェクトのオーバーヘッド

“abcd”

Native: 4 bytes with UTF-8 encoding

ネイティブ: UTF-8エンコーディングで4バイト

Java: 48 bytes

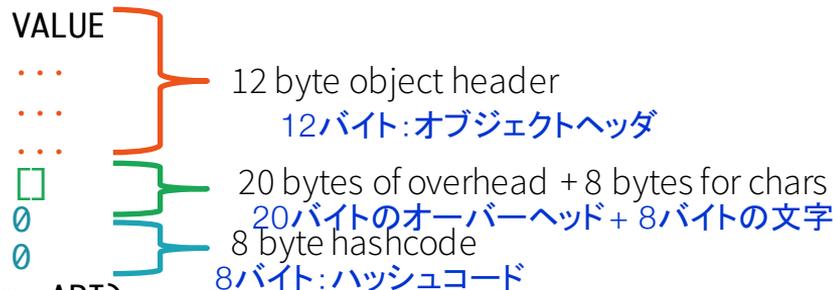
Java: 48バイト

java.lang.String object internals:

OFFSET	SIZE	TYPE	DESCRIPTION
0	4		(object header)
4	4		(object header)
8	4		(object header)
12	4	char[]	String.value
16	4	int	String.hash
20	4	int	String.hash32

Instance size: 24 bytes (reported by Instrumentation API)

インスタンスサイズ: 24バイト (Instrumentation APIによる)



sun.misc.Unsafe

安全性のチェックを行わずに直接的にメモリを操作する JVM 内部 API (すなわち “unsafe”)

on- と off-heap メモリの両方でデータ構造をビルドする際にこのAPIを利用している

JVM internal API for directly manipulating memory without safety checks (hence “unsafe”)

We use this API to build data structures in both on- and off-heap memory

Flat data structures

フラットなデータ構造



Data structures with pointers

ポインタを保持したデータ構造



Complex examples

複雑な例

Code generation

表現ロジックの汎用的な評価は JVM
上では非常にコストが高い

Generic evaluation of expression logic
is very expensive on the JVM

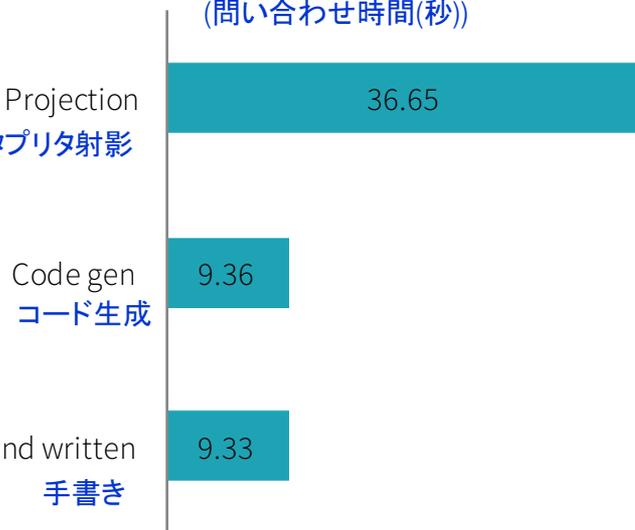
- Virtual function calls 仮想関数呼び出し
- Branches based on expression type インタプリタ射影
- Object creation due to primitive boxing 型表現に基づくブランチ
プリミティブのボクシングに起因する
- Memory consumption by boxed primitive objects オブジェクトの生成

Generating custom bytecode can
eliminate these overheads

カスタムバイトコードの生成によりこれ
らのオーバーヘッドを排除できる

Evaluating “a + a + a”
(query time in seconds)

“a + a + a” の評価
(問い合わせ時間(秒))



Code generation

Tungsten uses the Janino compiler to reduce code generation time

Tungsten はコードの生成時間を減らすために Janino コンパイラを利用する

Spark 1.5 added ~100 UDF's with code gen:

Spark 1.5 は code gen で ~100
の UDF を追加した:

AddMonths	DateDiff	FromUnixTime	Like	Second	StringSplit
ArrayContains	DateFormatClass	GetArrayItem	Lower	Sha1	StringTrim
Ascii	DateSub	GetJsonObject	MakeDecimal	Sha2	StringTrimLeft
Base64	DayOfMonth	GetMapValue	Md5	ShiftLeft	StringTrimRight
Bin	DayOfYear	Hex	Month	ShiftRight	TimeAdd
CheckOverflow	Decode	InSet	MonthsBetween	ShiftRightUnsig	TimeSub
CombineSets	Encode	InitCap	NaNvl	ned	ToDate
Contains	EndsWith	IsNaN	NextDay	SortArray	ToUTCTimestamp
CountSet	Explode	IsNotNull	Not	SoundEx	TruncDate
Crc32	Factorial	IsNull	PromotePrecision	StartsWith	UnBase64
DateAdd	FindInSet	LastDay	Quarter	StringInstr	Unhex
	FormatNumber	Length	RLike	StringRepeat	UnixTimestamp
	FromUTCTimestamp	Levenshtein	Round	StringReverse	
				StringSpace	

AlphaSort Cache-friendly Sorting

AlphaSort キャッシュフレンドリーなソート

Idea: minimize random memory accesses

アイデア: ランダムメモリアクセスの最小化

Naïve layout

単純なレイアウト



Cache friendly layout

キャッシュフレンドリーなレイアウト

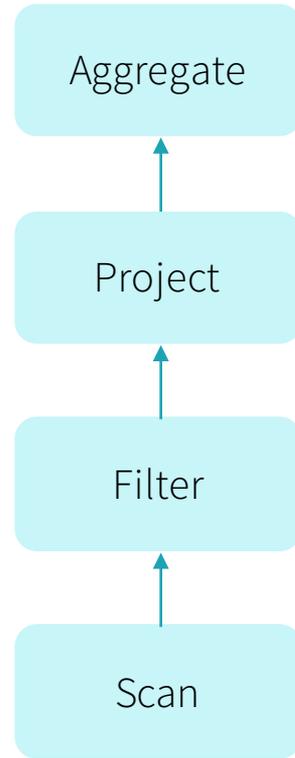


- Store prefixes of sort keys inside the sort pointer array
 - Short-circuit by comparing prefixes first
 - Swap only pointers and prefixes
- ソートのポインタ配列の中にソートキーのプレフィックスを格納
 - 先にプレフィックスを比較することによる短絡評価(ショートサーキット)
 - ポインタとプレフィックスのみのスワップ

Phase 2

Order-of-magnitude Faster

```
select count(*) from store_sales
where ss_item_sk = 1000
```



Volcano Iterator Model

Standard for 30 years: almost
all databases do it

30年間標準

ほぼすべてのデータベースが行っている

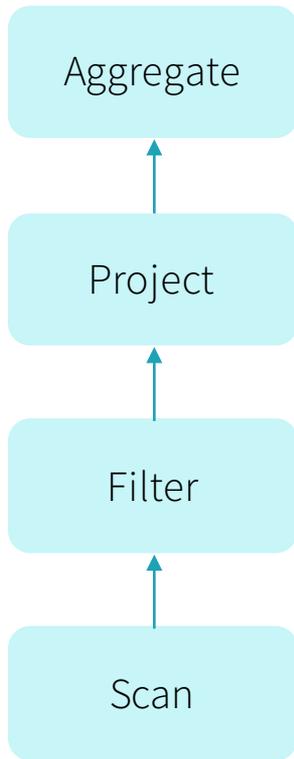
Each operator is an “iterator”
that consumes records from
its input operator

各オペレータは入力オペレータからの
レコードを消費する「イテレータ」

```
class Filter {  
  ...  
  def next(): Boolean = {  
    var found = false  
    while (!found && child.next()) {  
      found = predicate(child.fetch())  
    }  
    return found  
  }  
  
  def fetch(): InternalRow = {  
    child.fetch()  
  }  
  ...  
}
```

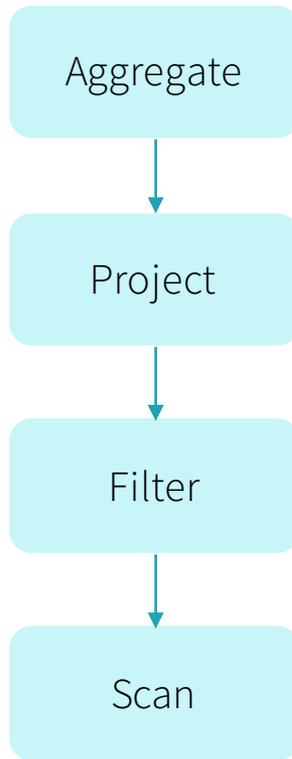
data flow

データフロー



call stack to process a row

一行を処理するためのコールスタック



Downside of the Volcano Model

ボルケーノモデルの欠点

1. Too many virtual function calls
 - at least 3 calls for each row in Aggregate
仮想関数呼び出しが多すぎる
Aggregateで少なくとも3回の呼び出し
2. Extensive memory access
 - “row” is a small segment in memory (or in L1/L2/L3 cache)
メモリアクセスが広範
「行」はメモリ(またはL1/L2/L3キャッシュ)中の小さな断片
3. Can't take advantage modern CPU features
 - SIMD, pipelining, prefetching...
モダンなCPUの機能の恩恵が受けられない
SIMD、パイプライン、プリフェッチ、...

What if we hire a college freshman to implement this query in Java in 10 mins?

もし10分間で Java でこのクエリを実装するために、大学1年生を雇ったら？

```
select count(*) from store_sales
where ss_item_sk = 1000
```

```
var count = 0
for (ss_item_sk in store_sales) {
    if (ss_item_sk == 1000) {
        count += 1
    }
}
```

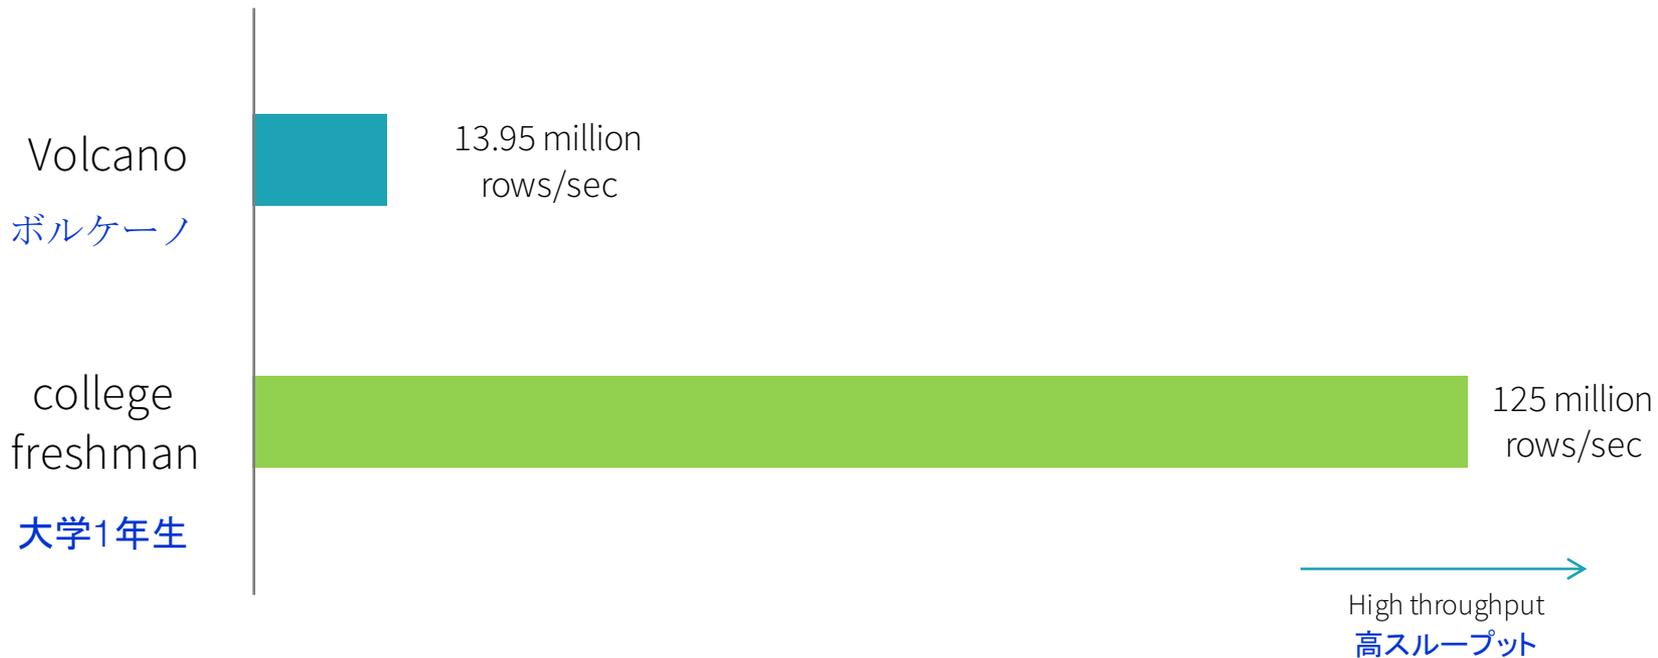
Volcano model
30+ years of database research

vs

college freshman
hand-written code in 10 mins

ボルケーノモデル
30年以上のデータベースの研究

大学1年生
10分間の手書きのコード



How does a student beat 30 years of research?

どうして学生が30年の研究に勝ったのか？

Volcano

1. Many virtual function calls
大量の仮想関数呼び出し
2. Data in memory (or cache)
データをメモリに(もしくはキャッシュに)
3. No loop unrolling, SIMD, pipelining
ループ展開、SIMD、パイプラインが無い

hand-written code

1. No virtual function calls
仮想関数呼び出しがない
2. Data in CPU registers
データを CPU のレジスタに
3. Compiler loop unrolling, SIMD, pipelining
コンパイラによるループ展開、SIMD、パイプライン

Whole-stage Codegen

全ステージコード生成

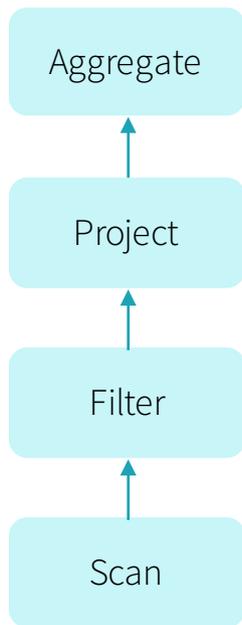
Fusing operators together so the generated code looks like hand optimized code:

複数のオペレータを一括で扱い結合することで、生成されたコードが手動で最適化されたコードのように見える

- Data stays in registers, rather than cache/memory
- Minimizes virtual function calls
- Compilers can unroll loops and use SIMD instructions
 - データはキャッシュ / メモリよりもレジスタの中に残る
 - 仮想関数呼び出しを最小化する
 - コンパイラがループを展開することができ、SIMD命令を使う

Whole-stage Codegen: Spark as a “Compiler”

全ステージコード生成 : 「コンパイラ」としての Spark



```
var count = 0
for (ss_item_sk in store_sales) {
  if (ss_item_sk == 1000) {
    count += 1
  }
}
```

But there are things we can't fuse

しかし結合させることができないものがある

Complicated I/O

- CSV, Parquet, ORC, ...

複雑な I/O

- CSV, Parquet, ORC, ...

External integrations

- Python, R, scikit-learn, TensorFlow, etc

外部とのインテグレーション

- Python, R, scikit-learn, TensorFlow, など

Don't want to compile a CSV reader inline for every query!

クエリごとに CSV reader をコンパイルしたくない！

Vectorization

ベクトル化

In-memory
Row Format
メモリ内の行フォーマット

1	john	4.1
2	mike	3.5
3	sally	6.4

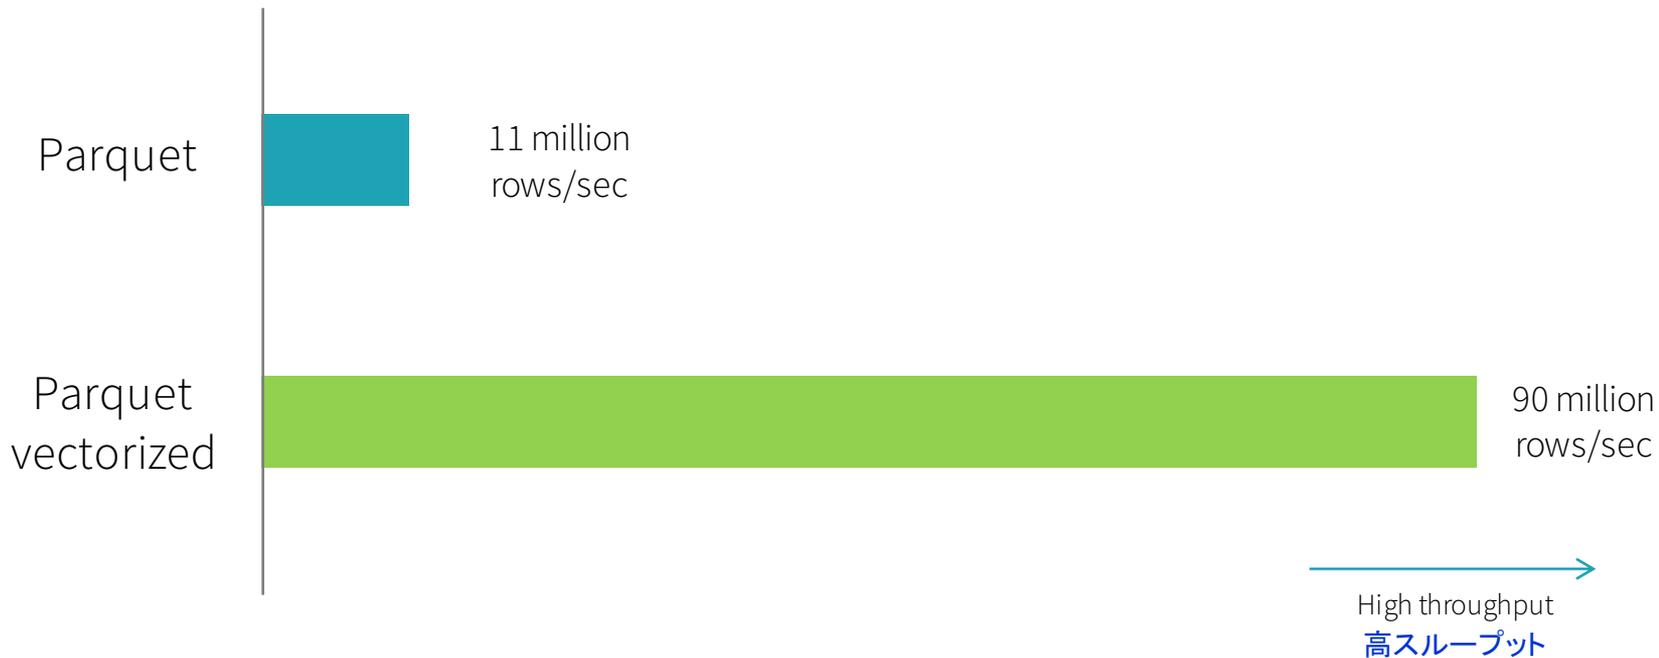
In-memory
Column Format
メモリ内の列フォーマット

1	2	3
john	mike	sally
4.1	3.5	6.4

Why Vectorization?

なぜベクトル化？

1. Modern CPUs are better at doing one thing over and over again (rather than N different things over and over again)
モダンな CPU はひとつのことを何度も何度も行うのが得意 (N 個の異なることを何度も何度も行うよりも)
2. Most high-performance external systems are already columnar (numpy, TensorFlow, Parquet) so it is easier to integrate with
ハイパフォーマンスな外部システムの多くは、既にカラムナ (numpy, TensorFlow, Parquet) であるため、インテグレートするのがより簡単



Phase 1

Spark 1.4 - 1.6

Memory Management

Code Generation

Cache-aware Algorithms

メモリ管理

コード生成

キャッシュを意識したアルゴリズム

Phase 2

Spark 2.0+

Whole-stage Codegen

Vectorization

全ステージ コード生成

ベクトル化

ありがとうございました

@rxin