

# FireDucks

## Compiler Accelerated DataFrame Library with pandas API

2024/07/18  
石坂一久

みんなのPython勉強会#106

# はじめに

FireDucksを使うために，本発表を聞く必要はありません

```
import fireducks.pandas as pd
```

あとはpandasだと思って使えば，数倍速いです。

※マシン環境やプログラムに依存します

本発表では，FireDucksがなぜ速いかをご紹介します。

本発表を聞いて，**FireDucksを使ってみようかな**と思って頂ければ幸いです

# 自己紹介

石坂 一久

(NEC セキュアシステムプラットフォーム研究所所属)


<これまでの関わってきた主な領域>

自動並列化コンパイラ

並列処理・ベクトル処理

→ **DataFrameコンパイラ**を作って、  
**pandas**を速くしよう！

Intel Xeon Phi  
(メニコア)



NEC SX-Aurora TSUBASA  
(スパコン)



<https://pc.watch.impress.co.jp/docs/news/yajiuma/1238340.html>  
<https://jpn.nec.com/hpc/sxauroratsubasa/specification/index.html>

# Demo

```
pd.read_csv("data.csv").rolling(60).mean()["close"].tail(1000).plot()
```

**pandas** (違いはimport文だけ) **FireDucks**

実行開始  
ボタン

import pandas as pd

```
import pandas as pd
```

```
%%time
```

```
pd.read_csv("data.csv").rolling(60).mean()["close"].tail(1000).plot()
```

import fireducks.pandas as pd

```
import fireducks.pandas as pd
```

```
%%time
```

```
pd.read_csv("data.csv").rolling(60).mean()["close"].tail(1000).plot()
```


移動平均を  
計算する  
プログラム

pandas: 4.06s

↓ 約**15倍**

FireDucks: 275ms

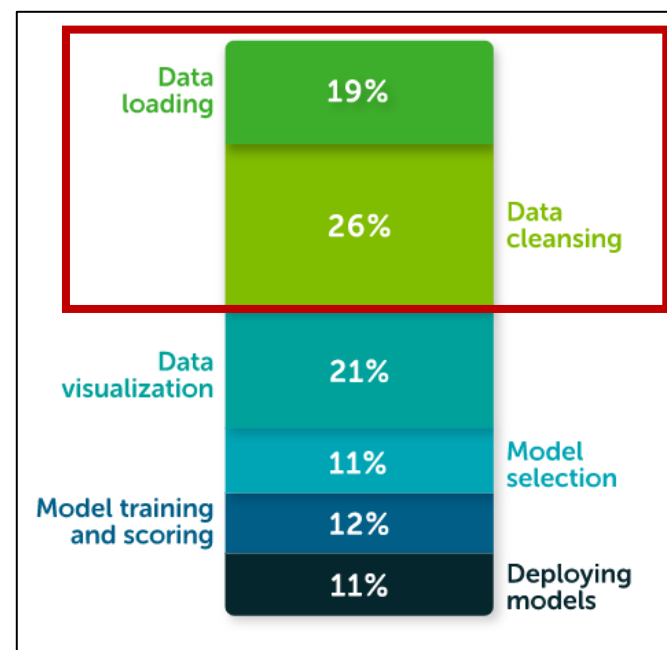
# pandas高速化のニーズ



## pandasが良く使われるデータ整備がデータ分析のボトルネックに

- 探索的データ解析, 学習用データの作成などの前処理
- 単純な整形だけでなく, 複雑なアルゴリズムも登場

データサイエンティストの時間の40%以上



Anaconda The State of Data Science 2020

実務で使えるデータ分析講座 [データの前処理とコーディング]

+ 連載をフォロー

第1回


データ分析は前処理が8割、「毒抜き」しないと危険

<https://xtech.nikkei.com/atcl/learning/lecture/19/00110/00001/>

# 大量のデータを使えるようになったけど...

扱うデータ量や処理の複雑化に伴い速度課題が顕在化

クラウドサーバーのメモリ容量



コモディティサーバーでも  
数百GBのメインメモリ

[5] Ogleari, M. et al.: String figure: A scalable and elastic memory network architecture, *2019 IEEE International Symposium on High Performance Computer Architecture (HPCA)*, IEEE, pp. 647-660 (2019)

# pandasはなぜ遅い？

ほとんどの処理は  
シングルスレッド  
実行



**Eager実行**

(SQLのクエリプランナーが行うような最適化がされない)



遅い書き方ができ  
てしまう

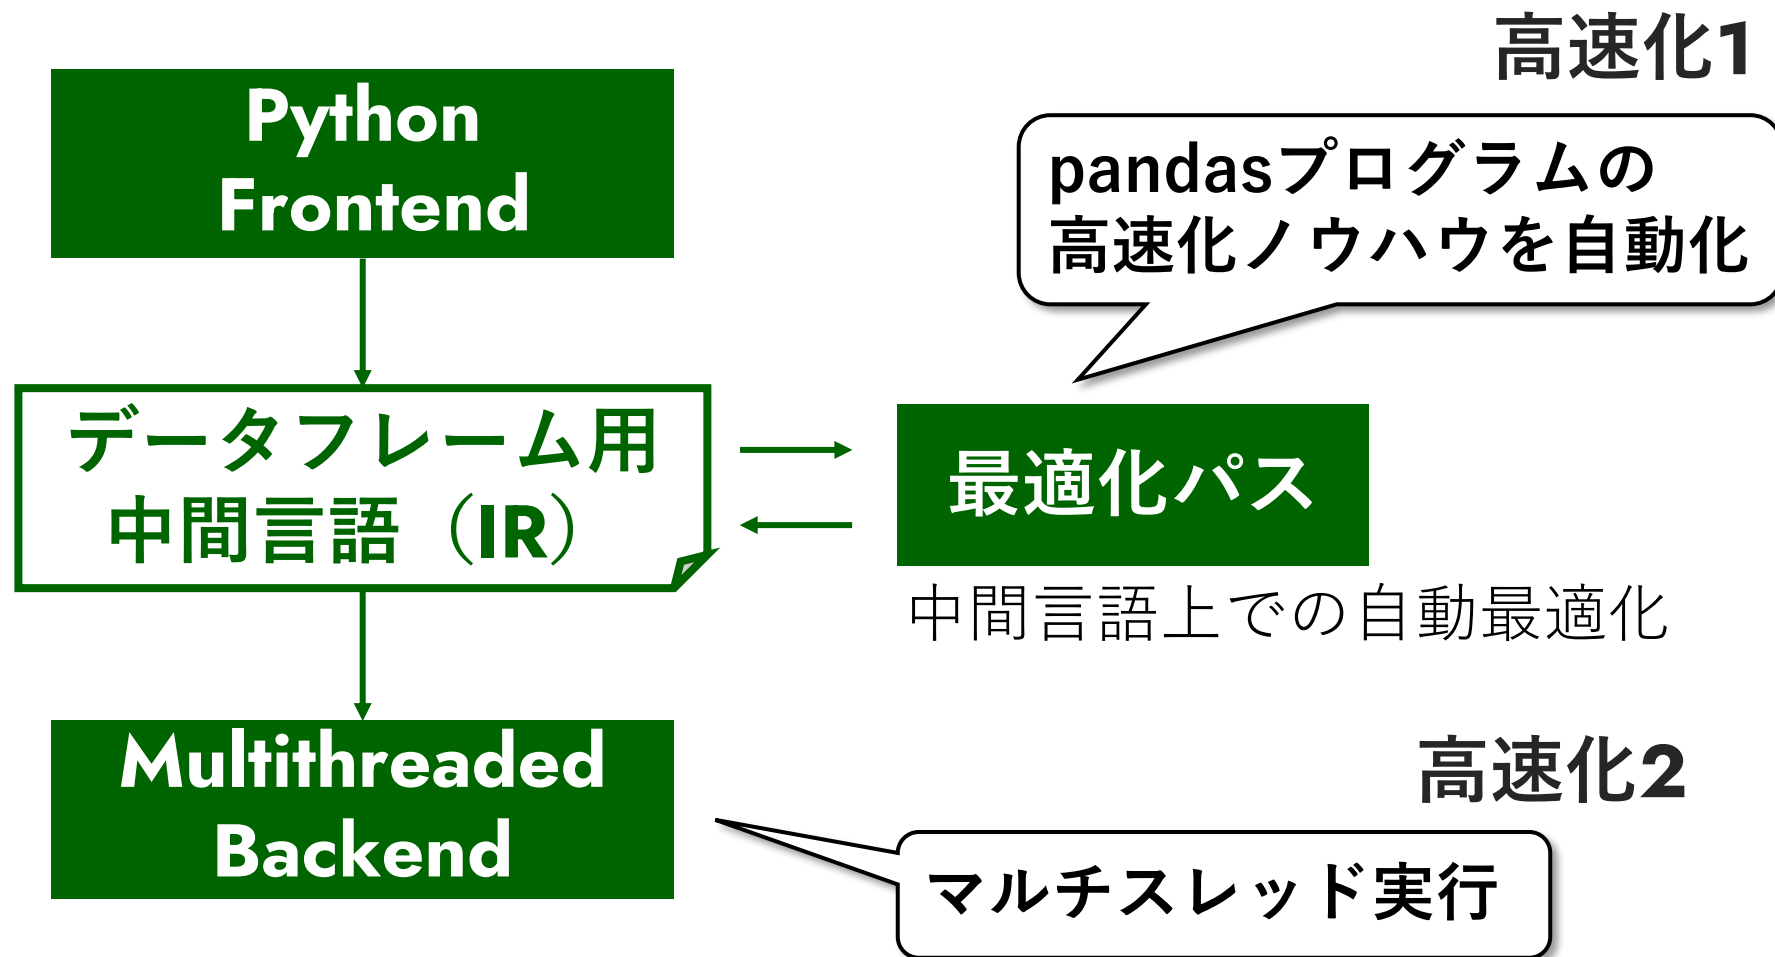


# FireDucksのアプローチ

中間言語（IR）を介することで，APIの変更なく，最適化や実行を改善

ユーザープログラムを一度中間言語に変換

ユーザーAPIとは独立したバックエンドで実行



高速化1  
pandasプログラムの  
高速化ノウハウを自動化

最適化パス

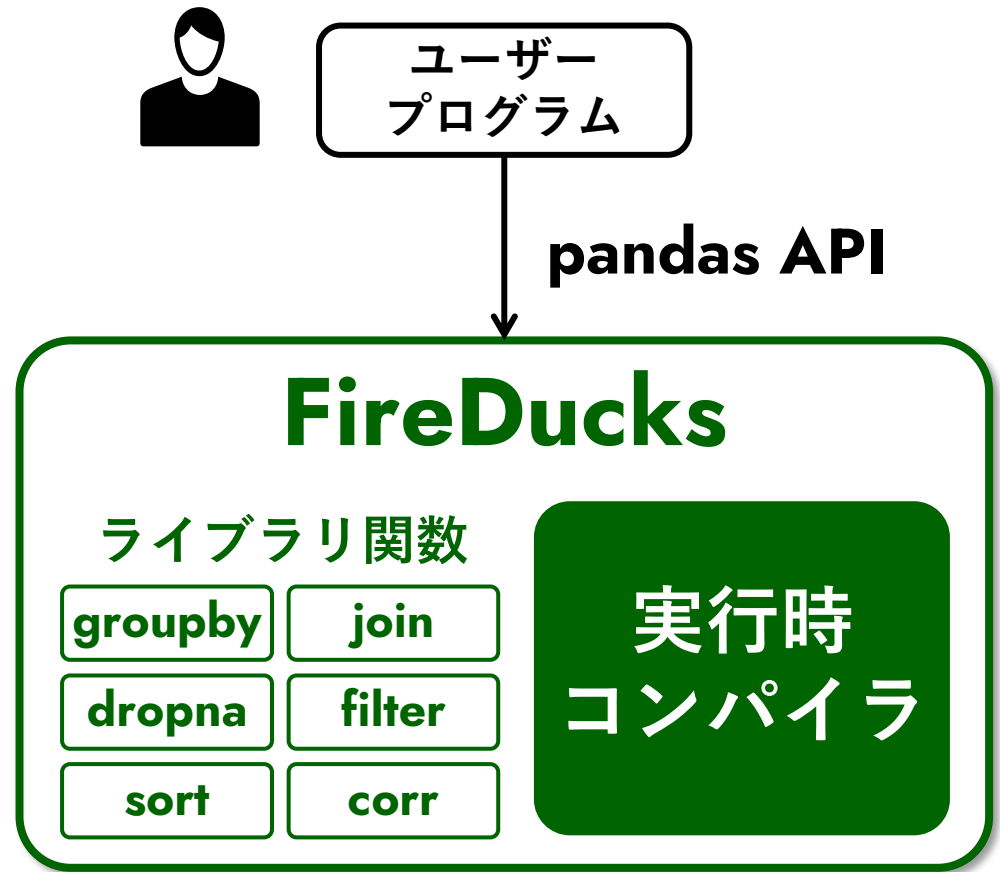
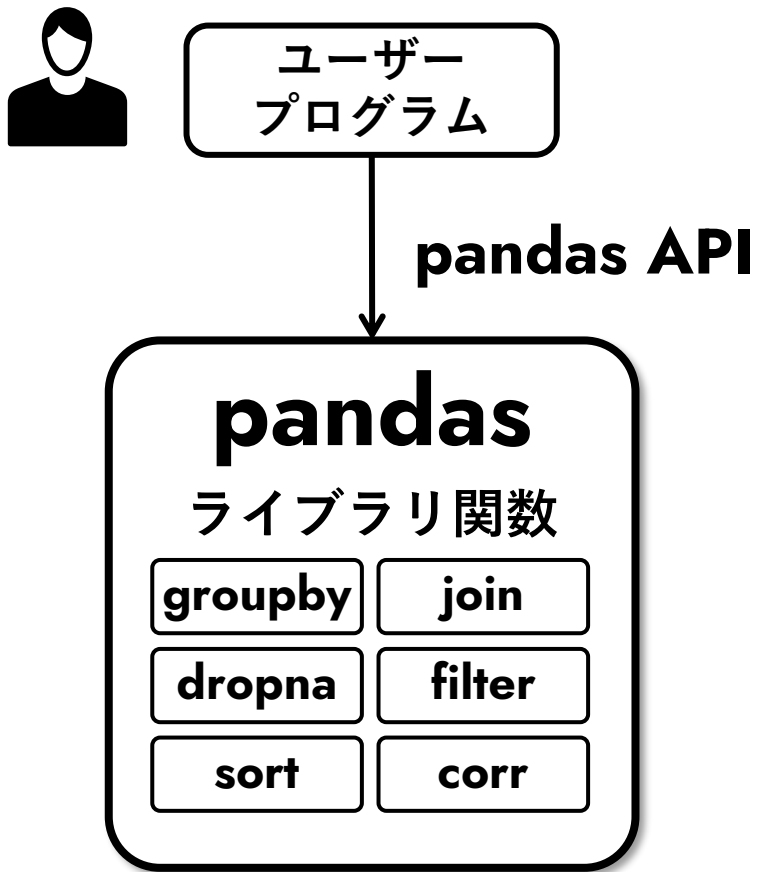
中間言語上での自動最適化

高速化2  
マルチスレッド実行



# 実行時コンパイラで実現

ライブラリ中に埋め込まれた実行時コンパイラで，使い勝手やAPIを変えずに高速化



# データフレーム用中間言語

データフレームの要素処理を命令としたドメイン特化型の中間言語 (IR)

pythonプログラム

```
pd.read_csv("data.csv")  
.rolling(60).mean()  
["close"]  
.tail(1000)  
.plot()
```

FireDucks IR

```
%t1 = read_csv('data.csv', %arg0)  
%t2 = rolling_aggregate(%t1, 60, 60, 'mean')  
%t3 = project(%t2, 'close')  
%t4 = slice(%t3, -1000, None, 1)
```

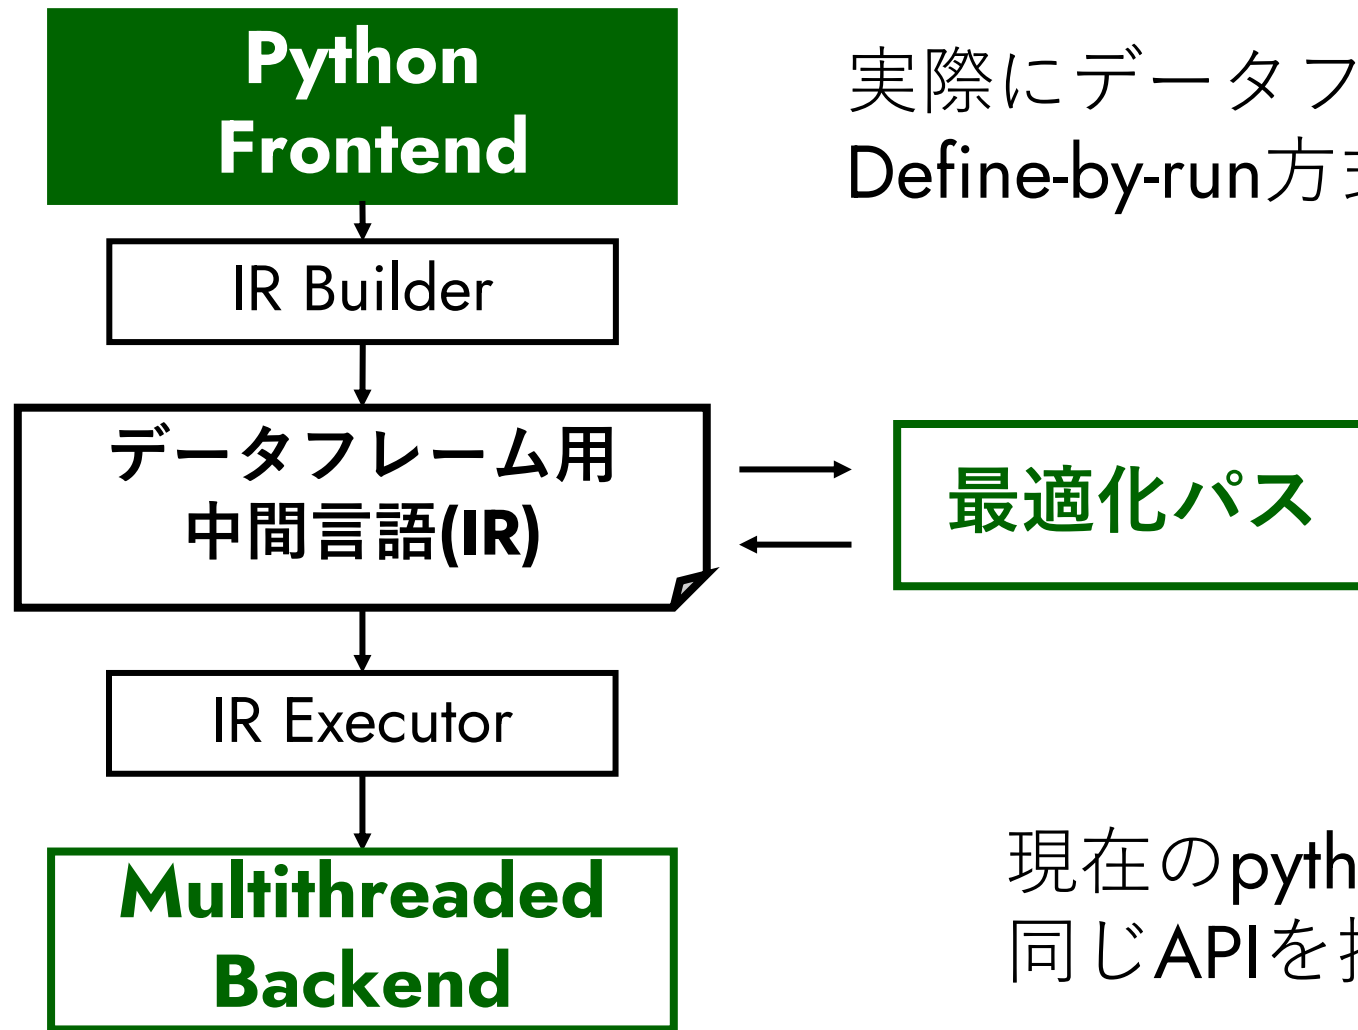
※: 最適化に適したSSA形式

1命令がデータフレーム操作の意味を持つので、  
データフレーム特化の最適化を行いやすい



独自の中間言語を定義できるコンパイラフレームワークを利用  
(LLVMのサブプロジェクト)

# Python Frontend



実際にデータフレーム処理をするのではなく、Define-by-run方式で中間言語の生成を行う

現在のpython frontendはpandasと同じAPIを持つ

FireDucksの構造

# Define-by-runによる中間言語生成

read\_csvを実行

```
pd.read_csv("data.csv")  
  .rolling(60).mean()  
  ["close"]  
  .tail(1000)  
  .plot()
```

FireDucks内部でread\_csv opが生成される

```
%t1 = read_csv('data.csv', %arg0)
```

この時点では実際のcsvファイルの読み込みは行われない

# Define-by-runによる中間言語生成

read\_csvを実行

```
pd.read_csv("data.csv")  
.rolling(60).mean()  
["close"]  
.tail(1000)  
.plot()
```

FireDucks内部でread\_csv opが生成される

```
%t1 = read_csv('data.csv', %arg0)
```

この時点では実際のcsvファイルの読み込みは行われない

FireDucksのread\_csvの実装 (簡略版)

```
def read_csv(filename):  
    value = irbuilder.build_op(OP_read_csv, filename)  
    return DataFrame(value)
```

# Define-by-runによる中間言語生成

rolling.meanを実行

```
pd.read_csv("data.csv")  
.rolling(60).mean()  
["Close"]  
.tail(1000)  
.plot()
```

rolling\_aggregate opが生成される

```
%t1 = read_csv('data.csv', %arg0)  
%t2 = rolling_aggregate(%t1, 60, 60, 'mean')
```

# Define-by-runによる中間言語生成

`__getitem__` を実行  
(列の取り出し)

```
pd.read_csv("data.csv")  
  .rolling(60).mean()  
  ["Close"]  
  .tail(1000)  
  .plot()
```

rolling\_aggregate opが生成される

```
%t1 = read_csv('data.csv', %arg0)  
%t2 = rolling_aggregate(%t1, 60, 60, 'mean')  
%t3 = project(%t2, 'Close')
```

# Define-by-runによる中間言語生成

tailを実行

```
pd.read_csv("data.csv")  
  .rolling(60).mean()  
  ["Close"]  
  .tail(1000)  
  .plot()
```

slice opが生成される

```
%t1 = read_csv('data.csv', %arg0)  
%t2 = rolling_aggregate(%t1, 60, 60, 'mean')  
%t3 = project(%t2, 'Close')  
%t4 = slice(%t3, -1000, None, 1)
```



# 中間言語の実行開始

特定のAPIが実行されると、中間言語の実行を開始（まとめて遅延実行）

plotを実行

```
pd.read_csv("data.csv")  
  .rolling(60).mean()  
  ["Close"]  
  .tail(1000)  
  .plot()
```

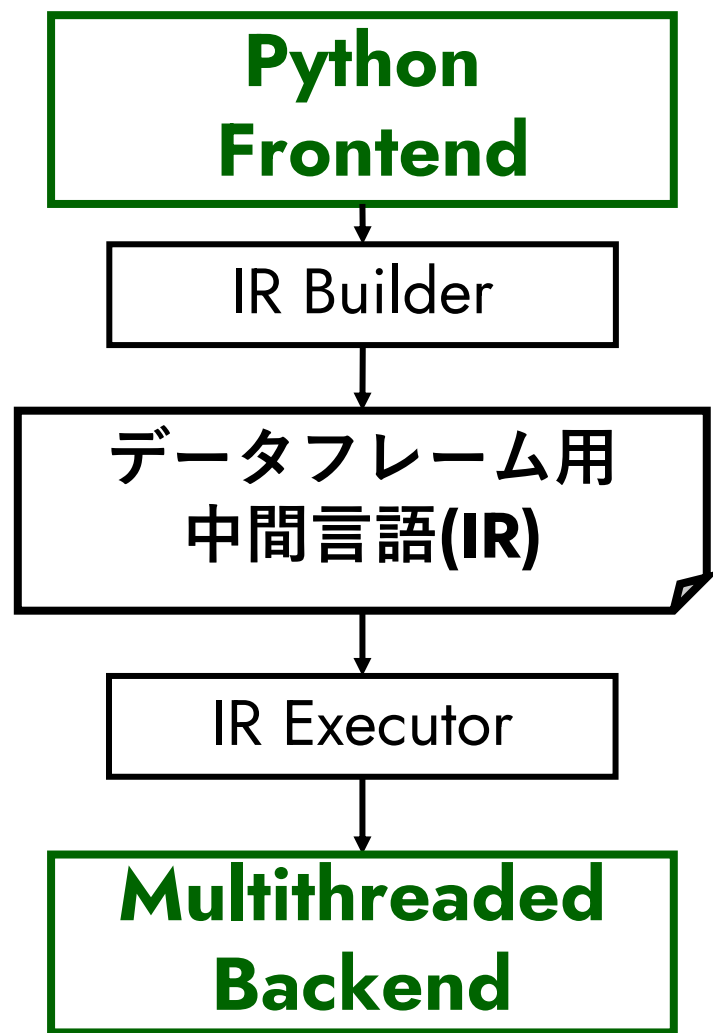
```
%t1 = read_csv('data.csv', %arg0)  
%t2 = rolling_aggregate(%t1, 60, 60, 'mean')  
%t3 = project(%t2, 'Close')  
%t4 = slice(%t3, -1000, None, 1)
```

plotはいくつかある評価ポイントの一つ（他には`\_\_repr\_\_`など）

`print(df)`

`__repr__`はprint内で利用される

# 最適化パスでの自動最適化



FireDucksの構造

最適化パスがIRをより良いIRに変換

- IR変換として, 各種のデータフレーム高速化テクニックを実装

最適化パス

現在も鋭意拡充中

# 1) projection pushdowns最適化

projection（列の抽出）を前出しすることで、中間データを削減

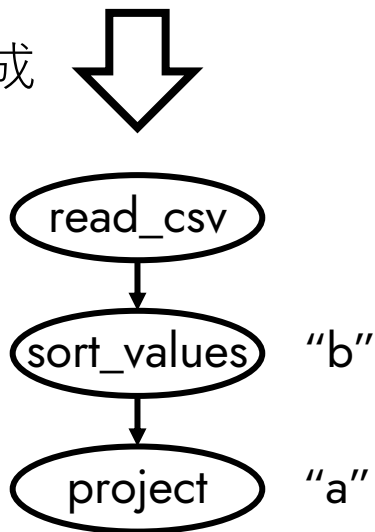
ユーザーが書いたプログラム

```
df = pd.read_csv("sample.csv")
sorted = df.sort_values("b")
result = sorted[["a"]]
```


実際に実行される処理

```
df = pd.read_csv("sample.csv")
df2 = df[["a", "b"]]
sorted = df2.sort_values("b")
result = sorted[["a"]]
```

中間言語生成

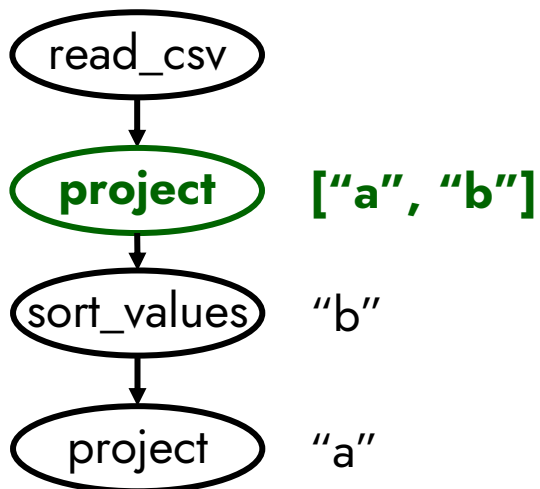


入力IR




projection  
pushdown

追加



出力IR



実行

## 2) パターン最適化

特定の命令の組み合わせをより良い組み合わせに変換する

```
df[~df["a"].isnull()] # a列がnulのl行を削除
```

➡ `df.dropna("a")`

```
df["timestamp"].dt.strftime("%Y").astype(int) # timestamp列から年の取り出し
```

➡ `df["timestamp"].dt.year`

```
groupby("a").sum().sort_values("b")
```

➡ `groupby("a", sort=False).sum().sort_values("b")`

# sort=Falseを追加

# 3) 集約特徴量計算向けの最適化

集約特徴量計算の例

```
df_encoded, new_cols = xfeat.aggregation(  
    df,  
    group_key = 'hour',  
    group_values = df.drop('hour', axis=1).columns,  
    agg_methods = ['mean', 'max'],  
)
```

一時間単位の平均と最大値を元のテーブルに新しい列として追加する

追加

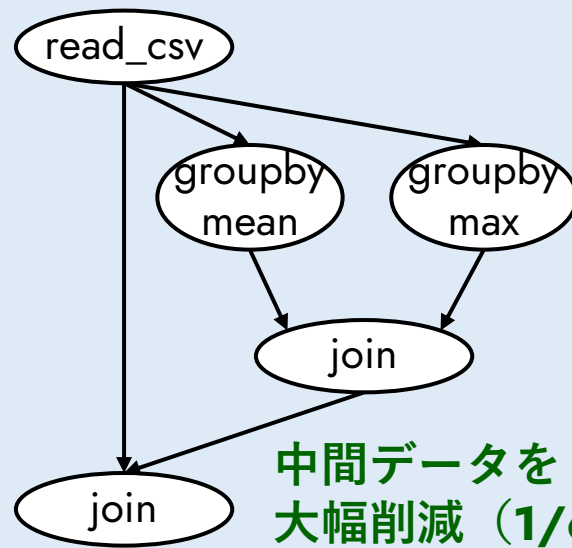
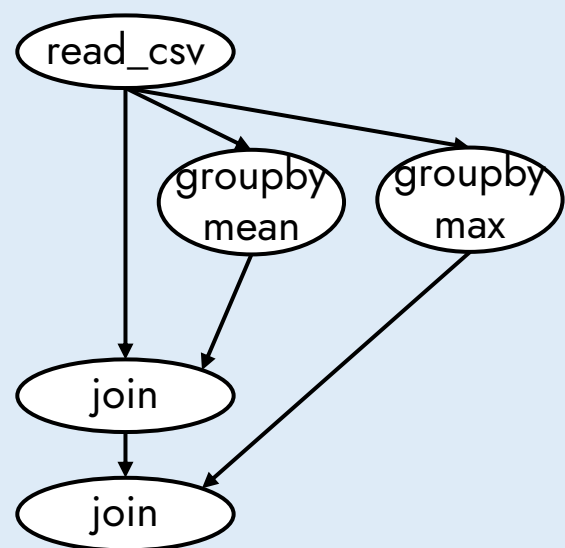
time	val
10:20	100
10:30	120



time	val	val_mean	val_max
10:20	100	110	120
10:30	120	110	120

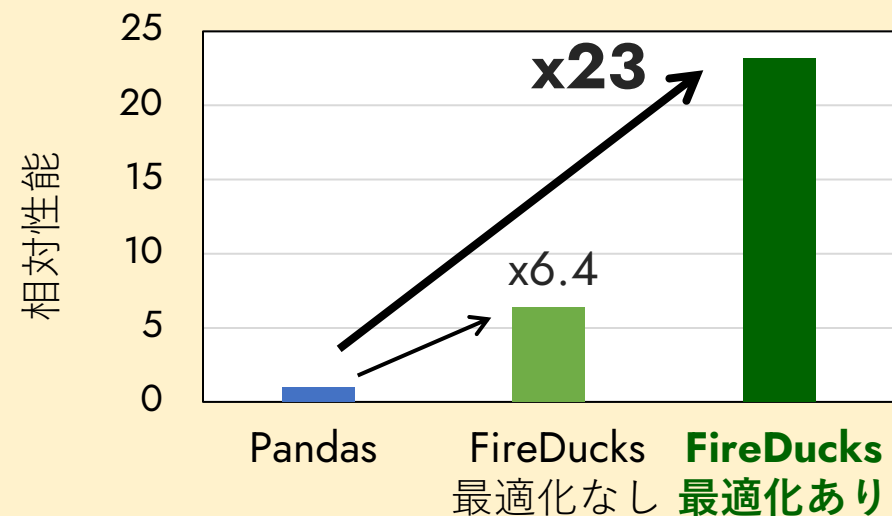
元の計算フロー

最適化後のフロー

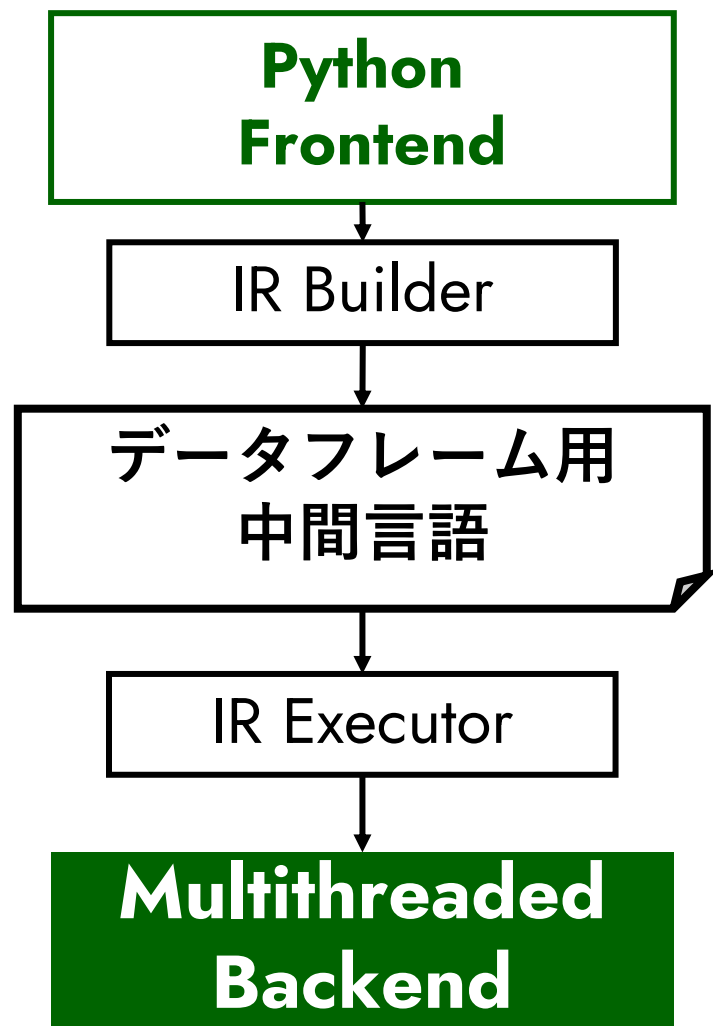


中間データを大幅削減 (1/60)

性能例 (31列 x 2集約関数)



# Backend



FireDucksの構造

中間言語中の各命令を実行するカーネルの集合

CPU用のマルチスレッドバックエンド (C++)

- データ構造にApache Arrowを利用
- Arrowが提供するカーネルに加えて、並列化・最適化を強化したカーネルを追加



# Backendでの最適化例: groupby

```
df.groupby("x").sum()
```

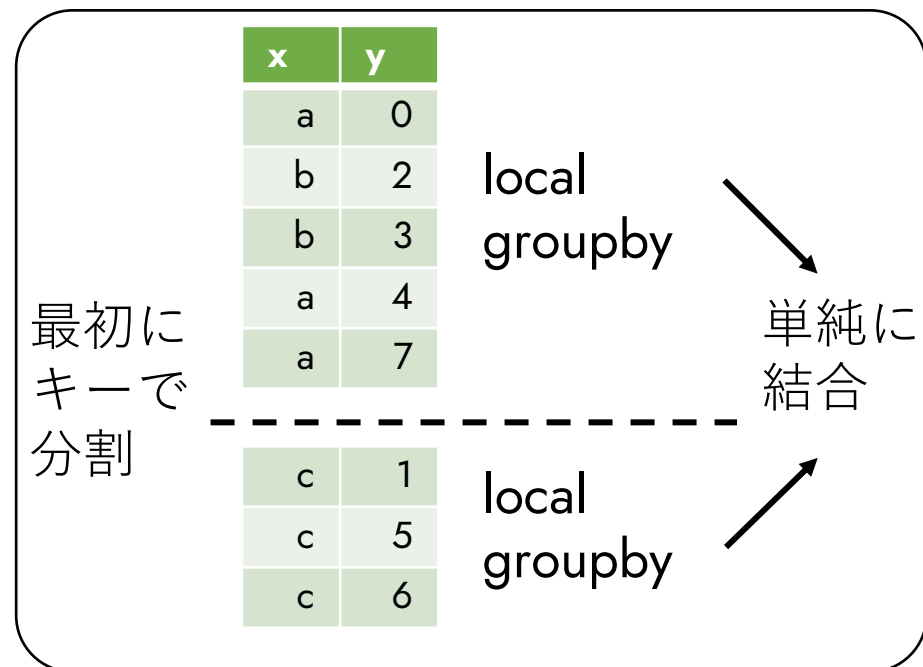
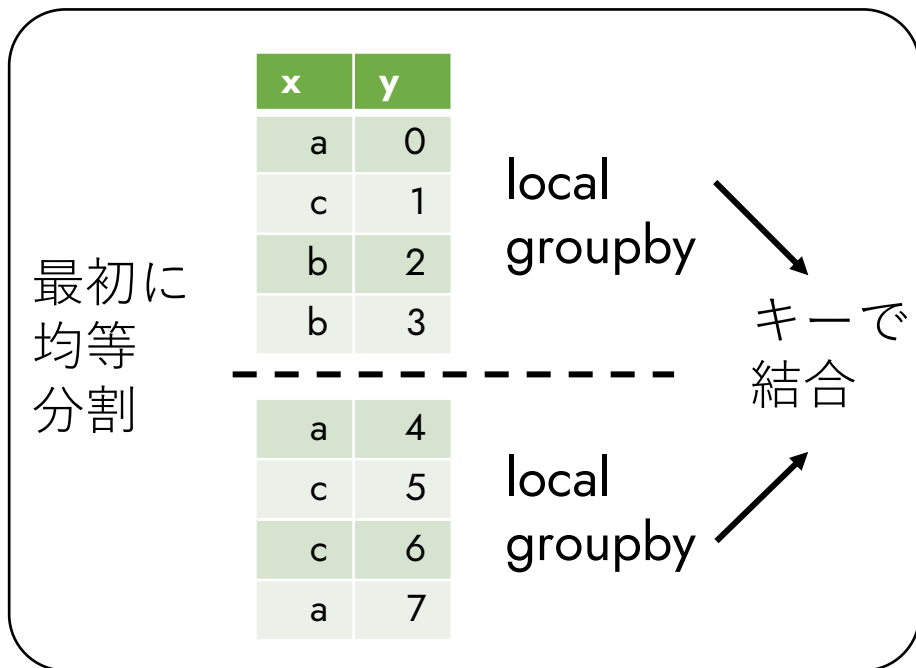
## グループ数推定

グループ数が少ないときに向けた  
並列groupbyアルゴリズム

グループ数が多いときに向けた  
並列groupbyアルゴリズム

元データ

x	y
a	0
c	1
b	2
b	3
a	4
c	5
c	6
a	7



# 互換性向上の仕組み: Fallback



互換性は上がるけど, 性能は上がらない (FireDucksで速くならないときはほぼこれ)

```
$ FIREDUCKS_FLAGS="-wfallback" python -mfireducks.imhook demo.py  
demo.py:4: FallbackWarning: series.plot 0.201566 sec ...
```

※ Warningを出すことは可能 (ご報告して下さい)



## applyやループを利用しない

(A列が2より大きい行のB列の合計)

ループ

```
s = 0
for i in range(len(df)):
    if df["A"][i] > 2:
        s += df["B"][i]
```

apply

```
s = 0
def func(row):
    if row["a"] > 2:
        s += row["B"]
df.apply(func)
```



```
s = df[df["A"] > 2]["B"].sum()
```

## 時間計測の注意

```
t0 = time.time()
df.sort_values("a")
t1 = time.time()
print(t1 - t0)
```

正しい時間計測ができない (遅延実行)



```
df._evaluate()
t0 = time.time()
df.sort_values("a")._evaluate()
t1 = time.time()
print(t1 - t0)
```

明示的な実行の指示

# FireDucksの性能 (要素処理 groupby, join)

Database-like ops benchmark (<https://duckdblabs.github.io/db-benchmark>)

groupby join groupby2014

0.5 GB 5 GB 50 GB

basic questions

Input table: 1,000,000,000 rows x 9 columns ( 50 GB )

1位

FireDucks	0.12.1	2024-06-17	14s
duckdb-latest	0.9.1.1	2023-10-26	24s
DuckDB	0.8.1.3	2023-10-26	25s
ClickHouse	23.10.4.25	2023-11-30	29s
Polars	0.19.8	2023-10-17	32s
DataFrames.jl	1.6.1	2023-10-17	84s
data.table	1.14.9	2023-10-17	89s
Datafusion	31.0.0	2023-10-24	133s
InMemoryDataSets	0.7.1	2023-10-17	218s
collapse	2.0.3	2023-10-26	233s
spark	3.5.0	2023-10-24	297s
R-arrow	13.0.0.1	2023-10-17	511s
dask	2023.10.0	2023-11-29	544s
pandas	2.1.1	2023-10-17	773s
(py)datatable	1.1.0a0	2023-10-17	993s
dplyr	1.1.3	2023-10-17	1022s
Modin		see README	pending

Groupby

groupby join groupby2014

0.5 GB 5 GB 50 GB

basic questions

Input table: 100,000,000 rows x 7 columns ( 5 GB )


3位

DuckDB	0.8.1.3	2023-10-20	8s
duckdb-latest	0.9.1.1	2023-10-25	8s
FireDucks	0.12.1	2024-06-17	8s
Polars	0.19.8	2023-10-20	14s
Datafusion	31.0.0	2023-10-25	22s
InMemoryDataSets	0.7.1	2023-10-20	25s
ClickHouse	23.10.4.25	2023-11-30	42s
data.table	1.14.9	2023-10-20	55s
collapse	2.0.3	2023-10-26	65s
DataFrames.jl	1.6.1	2023-10-20	71s
spark	3.5.0	2023-10-24	129s
dask	2023.10.0	2023-11-29	179s
dplyr	1.1.3	2023-10-20	225s
pandas	2.1.1	2023-10-20	265s
(py)datatable	1.1.0a0	2023-10-20	5699s
R-arrow	13.0.0.1	2023-10-20	out of memory
Modin		see README	pending


Join

# FireDucksの性能 (TPC-Hベンチマーク Scale Factor=10)

pandas比: 最大104倍, 平均25倍



Polars比: 最大12倍, 平均1.9倍



評価環境

インテル® Xeon® Gold  
5317 プロセッサ  
(12コア x 2ソケット)

メモリ: 256GB

OS: Linux

pandas 2.2.0

polars 0.20.7

FireDucks 0.10.1


ベンチマークコード

<https://github.com/fireducks-dev/polars-tpch/tree/fireducks>

# FireDucksの性能 (TPCx-BBベンチマーク)

ETL(抽出、変換、ロード)および機械学習のワークフロー

FireDucks speedup from pandas



- pandas-2.1.4
- fireducks-0.9.3

- CPU: Intel(R) Xeon(R) Gold 5317 CPU @ 3.00GHz x 2sockets (合計48HWスレッド)
- メインメモリ: 256GB

# DataFrameライブラリの比較

	pandas 互換性	シングルノード 性能	マルチノード 性能
<b>FireDucks</b>	○	○	×
Polars	×	○	×
Modin	○	△	○
Dask/Vaex	△	△	○
Pandas	○	×	×

# FireDucksの利用

pipコマンドでインストール可能 (BSDライセンス)

```
$ pip install fireducks
```

※ 現在はLinuxのみサポート (WSL可)

import文の書き換えだけでなく, pandasからの自動変換も可能

pythonコマンドの引数で指定

```
$ python3 -m fireducks.pandas program.py
```

jupyter notebookではマジックコマンド

```
%load_ext fireducks.pandas  
import pandas
```

# Resource

## Webサイト

<https://fireducks-dev.github.io/ja/>

(ユーザーガイド, ベンチマークなど)



## github (issue report)

<https://github.com/fireducks-dev/fireducks>



## slack (Q&A, 雑談)



## twitter/X (リリース情報)

<https://x.com/fireducksdev>



# おわりに

FireDucksは、pandasのdrop-in replacementで使える高速データフレームライブラリです

実行時コンパイラ技術の活用により、pandasの弱点であるマルチスレッド実行、自動最適化を行います

ぜひご活用下さい