

TSUBAMEシリーズにおける ブラウザベース利用機能の導入

野村 哲弘

東京科学大学 情報基盤センター




この発表の概要

- 東工大/科学大のスパコンTSUBAMEシリーズにおいて提供してきたブラウザ経由利用について、そのモチベーションと独自実装、Open OnDemandへの乗り換えまでの流れを報告する
 - SWoPP2020でTSUBAME3導入直後に発表しており、その内容を多く含みます
- 本発表における禁句: それ、Open OnDemandでできます (当時は存在を知らなかった)

- 野村 哲弘 / Akihiro Nomura / Science Tokyo(東京科学大学) 情報基盤センター
- TSUBAMEの中の人之一人
 - 2011年より東工大(現: 東京科学大)
 - TSUBAME2以降の運用・3以降の仕様策定に従事
 - スパコンに新しいモノを入れて使えるようにするのが趣味
 - TSUBAME2: Caffe, ~~TensorFlow~~ (DLL Hellに敗北), Score-P
 - TSUBAME3: Jupyter Notebook / Lab 起動スクリプト→2020/4にWebサービス化
 - その他: Vim, CMake, OpenACC対応GCC, CUDAなどの新しいバージョン
 - TSUBAMEシリーズの各種運用の黒幕(大抵の場合)
 - このスパコン使いにくいという声は極力拾っていきたい所存
(とはいえ、何かとのトレードオフで仕方なく使いづらくしている面もあり)
 - Xの @TSUBAME_sc やWebサイト・マニュアル類も担当

東工大/科学大 TSUBAMEシリーズの歴史

- TSUBAME1.0～1.2 (2006-2010)
 - 655ノード
 - 1.2はGPUを用いた世界初の大規模スパコン
- TSUBAME2.0/2.5 (2010-2017)
 - 1408ノード(+ α)
 - 1ノード3GPU, 2 IB HCA (QDR, 40Gbps)
- TSUBAME3.0 (2017-2024)
 - 540ノード
 - 1ノード4GPU, 4 Omnipath HFI (100Gbps)
- TSUBAME4.0 (2024-2030)
 - 240ノード
 - 1ノード4GPU, 4 IB HCA (NDR200, 200Gbps)



登壇者が関与した範囲




以下、TSUBAMEN.x系をまとめてTSUBAMENもしくはTNと表記します (例: TSUBAME2.0/2.5 → T2)

TSUBAME4.0

データ・計算科学・AI融合のためのもっとみんなのスパコン



対話的データ解析



深層学習との融合による
シミュレーション革新




SNSのフォロー関係解析

ビッグデータ解析

計算科学・
シミュレーション

AI・深層学習



シミュレーションと
リアルタイム可視化



深層学習による
画像認識・生成AI



TSUBAME4.0
2024/4運用開始

TSUBAME4.0の概要

計算ノード (**単一構成**):

HPE Cray XD665 × **240台**

H100 GPU 計960台 ← 全ノードにGPU

総演算性能:

- **66.8 PFlops** (倍精度)
- **952 PFlops** (半精度)

共有ストレージ:

HPE Cray ClusterStor E1000

総容量:

- 44 PByte (ハードディスクベース)
- 327 TByte (SSDベース)

30ラックに格納

- 計算ノード 23ラック
- ストレージ・管理 7ラック

東工大(現: 東京科学大)

すずかけ台キャンパスG4-A棟に設置

構築業者: Hewlett Packard Enterprise

2024/11 ランキング

Top500: No. 36 (39.42PFlops)

Green500: No. 30 (48.56GFlops/W)

TSUBAME4.0でのリソース分割

- いろいろなTSUBAMEのユーザ
 - CPUもGPUもあるだけ使う
 - GPUはあるだけ、CPUは最低限
 - CPUしか使わない
 - TSUBAME4の計算ノードは「パワフル」すぎる
 - GPUが4台、各GPUも強力
 - CPUコア数 計192コア
 - けど、台数が少ない
 - TSUBAME2の頃は1400台
 - TSUBAME4では240台
- 動的に分割してみんなで使う
- AltairとHPEが頑張りました


資源タイプ	CPUコア数	メモリ(GB)	GPU数	ローカルSSD容量(GB)
node_f	192	768	4	1920
node_h	96	384	2	960
node_q	48	192	1	480
node_o	24	96	1/2	240
gpu_1	8	96	1	240
gpu_h	4	48	1/2	120
cpu_160	160	368	0	960
cpu_80	80	184	0	480
cpu_40	40	92	0	240
cpu_16	16	36.8	0	96
cpu_8	8	18.4	0	48
cpu_4	4	9.2	0	24

ユーザは自分にあったサイズの資源タイプを使う
(費用負担も使ったサイズに比例)

スパコン初学者にとっての壁

- スパコンTSUBAMEシリーズのユーザ層
 - 科学大 学内ユーザ(教員・学生) - 「みんなのスパコン」
 - 共同研究等に基づく他機関・企業の研究者
 - TSUBAME共同利用・HPCI/JHPCN等の学外利用プログラムによる学術利用・産業利用ユーザ
- スパコンの計算ノードで何かをするために必要な知識
 - SSHおよび公開鍵認証 ← 教育コスト超高 Zoomでトラブルシューティングできますか？
 - X転送・ポートフォワーディング (可視化・Jupyterなどを利用する場合)
 - Linuxの基本的なコマンド
 - ジョブスケジューラ の概念・ジョブスクリプト
 - アクセラレータ (GPU) や並列処理 (MPI, OpenMP, OpenACC)
 - ドメイン・実際に動かすアプリの知識
 - 本質的には、オレンジ色の箇所の知識しか要らないはず
 - あるには越したことないけど、後からでよい

TSUBAME3のWebアプリ実行機能(2020)



SSHを知らなくてもいつでも
TSUBAMEを使える

- 利用者ポータルからジョブ投入に必要な情報を入れるとジョブが作られる
- ジョブで確保された計算ノード内でJupyter Labが起動し、リバースプロキシ経由でユーザのブラウザに表示されえる
- Jupyterで何かやると計算ノードのCPU/GPUで計算が走る

SSHやジョブスクリプトは操作
に出てこない


ネタバレ: 当時Open OnDemand[2013]を知っていれば...

さて、これを手で実現するとどうなる？

- 一切システムの助けなしにやるには、こんな感じ
 - Jupyterのインストール (`pip install --user jupyterlab`)
 - 計算ノード確保
 - Jupyterの起動(を、ジョブスクリプト内で行う)
 - Jupyterが待ち受けている計算ノードまで、SSHポートフォワードを設定
 - 理屈はわかるが、正直面倒すぎてやって(調べて)られない
- Jupyter起動自動化コマンド `jupytterrunc` (2019公開, T4でも利用可能)
 - ユーザは `jupytterrunc` を、AGEの`qrsh`と同じオプションで起動するだけ
 - 実行すると以下のようなメッセージが表示されるので、別ターミナルへコピー
To enable port forwarding, execute this command in another terminal:
`ssh -l username -L 8888:r0i1n2:12345 login.t3.gsic.titech.ac.jp`
Then, you can connect to `http://localhost:8888/`
 - `http://localhost:8888/` につなぐと、計算ノードで動くJupyterが待っている
 - 約40行のスクリプトでだいぶ省力化できた
 - この自動化を突き詰めるとどこまでできるか → 実装してみた

TSUBAME3 Webアプリ実行機能の設計

- ユーザはTSUBAMEの利用者ポータルからWebアプリケーション(Jupyter, Code Server, NoVNC)を起動、裏でジョブの管理等を行い、HTTPSリバースプロキシ経由でWebアプリの画面をユーザに提示



この図のどこにも
SSH・公開鍵が
出てきていないのが
ポイント

Webサービス利用受付

Webサービスの起動

Webアプリケーション	Jupyter Notebook ▼
☐ インタラクティブ利用専用キュー	
利用時間	24:00:00
☒ 有償サービス利用	
グループ選択	tga- ▼
☒ 通常ノード利用	
資源タイプ	f_node[F] ▼
利用時間	00:10:00
☐ 予約ノード利用	
ARID	
資源タイプ	f_node[F] ▼
利用時間	00:10:00
☐ お試し利用	
資源タイプ	s_core[C1] ▼
利用時間	00:10:00
ノード確保失敗時	☒ キャンセル ☐ 空くまで待機
起動	

- qsubコマンドのオプションをWeb UIで指定する
- 後述のインタラクティブジョブ専用キューも指定可能
- リソース不足(ノードが空いてない)時にジョブをキャンセルする動作がデフォルト
 - AGEのqsubにおける `-now y` に相当
 - ノードが空くまで待つこともできる

t3jpttools Pythonモジュール

- Jupyter LabのUIだけではできない各種調整用の独自モジュール
- `create_kernel`(カーネル名, Environment moduleのリスト)
 - 実行するとJupyterのカーネル(環境)設定ファイルを作成
 - Jupyterの機能でカーネルを切り替えることで、指定したEnvironment moduleに対応する環境変数が設定されるので、CUDA等を利用可能に
- TSUBAME3ではできていなかったこと
 - `virtualenv`, `pyenv`, `Anaconda`等のPython仮想環境への対応
 - どこまで面倒を見るべきか… 現状はこの辺を使える人は`jupyterlab`も使えるのでそっちで対応
 - 任意のPythonバージョンの選択機構(部分的に対応済み)

T3で対応したWebアプリケーション

- 最初はJupyterのみから始め、1年に1個ずつ対応アプリを増やした
 - Jupyter Lab
 - Pythonだけかとおもったら簡易的なエディタ・ターミナルもあって意外と使えた
 - Code Server (VS CodeのWeb対応クローン)
 - ログインノードでVS Code Remoteのプロセスが異常生成される事態が頻発していた
 - NoVNC (VNCのブラウザ実装)
 - X11使えたらよいのではと探してみたらあった
 - ユーザからのX転送・可視化関係の問い合わせでX11実装との相性問題が疑われるものが多く、標準的なものを用意したかった
 - VirtualGLを使った計算ノードGPUを使っでの描画アクセラレーションにも対応 (T4 OODではデフォルトで有効に)
→ X11関係の問い合わせの大半を「Webブラウザ使え」で一蹴できるようになった
 - 余談: MobaXTermのX11もわりと相性問題起こさないし、導入楽なのでおすすめ

```
File Edit View Terminal Tabs Help
1745 frames in 5.0 seconds = 348.942 FPS
2015 frames in 5.0 seconds = 402.922 FPS
2547 frames in 5.0 seconds = 509.255 FPS
2488 frames in 5.0 seconds = 497.351 FPS
2802 frames in 5.0 seconds = 560.183 FPS
3031 frames in 5.0 seconds = 606.093 FPS
2700 frames in 5.0 seconds = 539.787 FPS
```


R-CCS Cloud FX700 (GPUないマシン)

```
File Edit View Terminal Tabs Help
[uh02018@r4n11 ~]$ glxgears
13385 frames in 5.0 seconds = 2676.957 FPS
13029 frames in 5.0 seconds = 2605.789 FPS
12676 frames in 5.0 seconds = 2535.193 FPS
12614 frames in 5.0 seconds = 2522.587 FPS
13455 frames in 5.0 seconds = 2690.991 FPS
13479 frames in 5.0 seconds = 2695.688 FPS
```

TSUBAME4 Interactive Queue w/ VirtualGL

インタラクティブジョブ専用キュー

- Webブラウザを用いた対話的利用をやるうえで、計算ノードをいつでも確保できる環境は必須
- TSUBAME3, 4は混み過ぎていて、このような条件を通常ジョブでは満たせない
- 計算ノードの1%を対話利用専用として切り出して、「性能度外視」キューを構築
 - ノード内に多数のユーザを詰め込むことを前提、GPUは共用、CPUも1人当たり2コア程度
 - CPUメモリはSSD上のswapfileで水増し
 - 1人1ジョブまで、複数ジョブ同時実行や複数ノードジョブは走らない
 - 最大実行時間は24h、Web UIのデフォルトは2h
 - 忘れられたところに掃除される
 - その代わりに、100人以上が待ち時間なしで即時実行できる
 - 科学大におけるHPC分野の専門科目講義を1クラス分収容できる
 - Jupyter Notebookを読んで簡単なサンプルを実行する・ファイル編集するにはこれぐらいで充分




TSUBAME4.0 Open OnDemandへ移行

- TSUBAME3のものは独自実装、TSUBAME利用者ポータルへの作りこみ
 - TSUBAMEにべったりで他のシステムへ移植不可能
 - システム提供ベンダが変われば東工大(当時)ですら活用不能になる
- TSUBAME4導入時には国内でもOpen OnDemandが普及し始めてきた
 - では、乗り換えましょう
- まずはTSUBAME3でできていたことの再現
 - Jupyter
 - Code Server
 - X11
- ログインノードの仮想コンソール・ファイル転送
- まだできていないこと
 - スケジューラ周り (Jub Submitter, Active Jobs)
 - ジョブ簡易投入
 - 非OODジョブの管理(状態確認etc)
 - (あるけどあまりうまく動いてないので隠してる)
 - ウィジェット関係
 - ストレージの混み具合はできるだけ早期に対応したい
- ログインはメール認証(ポータルと独立)
 - 4月にPassKey(FIDO2)対応予定!!


サーバスペック (AMに話題になったので)

AMD EPYC 7443 (2.85GHz, 24core, 200W) x 2
Mem 256GiB, SSD 1.6TB, IB HDR 200Gbps, Ethernet 10Gbps
(一部は認証用のKeycloak VMに使ってる)



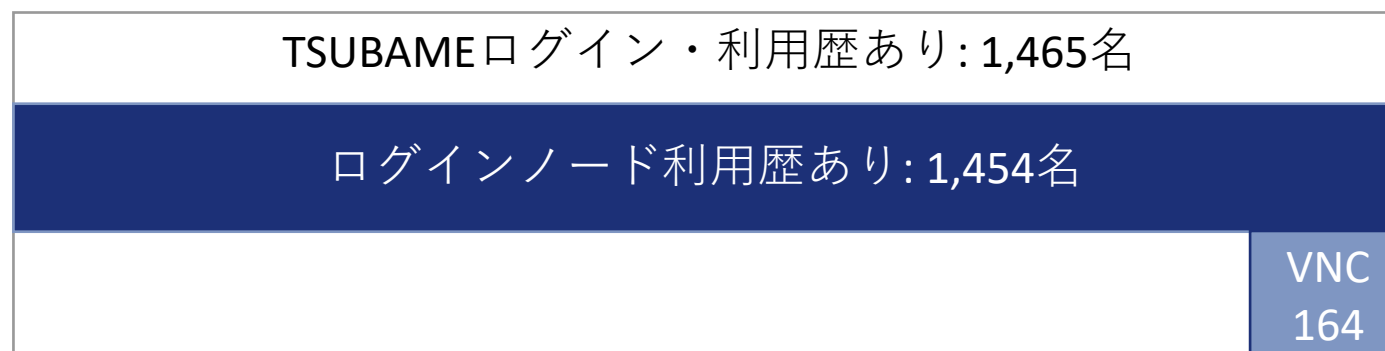
Web経由の利用でユーザは増えた？

- 端的に言えば、Yes
- TSUBAME3に導入後3か月のユーザ動向: シェア14.5%, 新規発掘ユーザ6%



53名
新規発掘 (SSHしたことがない人)

- TSUBAME4運用開始後8か月(11月末まで)のユーザ動向:



- OOD経由でもログインノードを使えるようになった
- OOD自体のログイン人数の統計を取っていない(今後の課題)
- ユーザの絶対数が増えている

- TSUBAME4のOpen OnDemandに至るまでの「前史」(TSUBAME3時代)
 - Jupyter Labを簡単につかいたいな から始まる独自実装の旅
 - Code Server・NoVNC、欲しかったので追加
 - Jupyterの段階で何かが欲しくなるのは読めていたので、追加できるような構造に
- TSUBAME4でのOOD利用状況
 - 思ったほどユーザは広がっていない
 - 現状提供している物がビギナー向けなものが多く、スパコン使い倒す勢には不十分?
 - カスタマイズ性に難ありか
 - JupyterのPython環境切り替えなど、T3時代にできていた一部の機能を取りこぼしている
 - 現状はjupyterrunスクリプトに丸投げ、そちらではVirtualEnvなども利用可能
 - バージョンアップ・アプリを増やすことができる環境を準備中
 - いまのところセンター教員が触れる検証環境がない → 準備中(年度末)