

Lustre on OCTOPUS

Susumu Date

Applied Information Systems Research Division,
Cybermedia Center, Osaka University, Japan

大阪大学 サイバーメディアセンター
応用情報システム研究部門 伊達 進

Introduction

Osaka University

selected as a Designated National University on Oct.23 2018



*Under the motto "Live Locally, Grow Globally,"
Osaka University grapples with the challenges of education and research*



<http://www.osaka-u.ac.jp/en/index.html>

Organization

- 11 Schools with 10 Corresponding Graduate Schools
- 6 Independent Graduate Schools
- 6 Research Institutes
- 2 National Joint-Use Facilities
- 14 Joint -Use Education and Research Facilities
- University Library
- 2 University Hospitals
- World Premier International Research Center (WPI) Initiative
- Institute for Academic Initiatives
- Center for Education in Liberal Arts and Sciences

Faculty and staff 6,654

Students

- Undergraduate 15,250
- Graduate 8,054



Cybermedia Center



- a supercomputing center at Osaka University
 - <http://www.cmc.osaka-u.ac.jp/>
- has a responsibility of providing a powerful high-performance computing environment for university researchers across Japan as a national joint-use facilities.

2018年度
大規模計算機システム
新規利用受付中!

工学系 理学系 人文社会科学系 経済系
大学・企業を問わず
利用可能!

CALL FOR SUPERCOMPUTER USERS

大規模計算機システム 2018年度新規利用受付中

OCTOPUS (1.96 PFlop/s)

ベタフロップス型ハイブリッド型
スーパーコンピュータ

最先端のハードウェアとソフトウェアの組み合わせにより、大規模な計算を高速に実行できる。また、大規模なデータを高速に読み取り、大規模な計算を高速に実行できる。また、大規模なデータを高速に読み取り、大規模な計算を高速に実行できる。

VCC (100.13 TFlop/s)

動的再構成可能型
スーパーコンピュータ

計算資源を柔軟に再構成し、大規模な計算を高速に実行できる。また、大規模なデータを高速に読み取り、大規模な計算を高速に実行できる。また、大規模なデータを高速に読み取り、大規模な計算を高速に実行できる。


SX-ACE (403 TFlop/s)

ベクトル型
スーパーコンピュータ

最先端のハードウェアとソフトウェアの組み合わせにより、大規模な計算を高速に実行できる。また、大規模なデータを高速に読み取り、大規模な計算を高速に実行できる。また、大規模なデータを高速に読み取り、大規模な計算を高速に実行できる。

大阪大学サイバーメディアセンターの大規模計算機システムは、学内外を問わず本センターの利用資格を満たす皆様にご利用いただけます。理系の方はもちろん、大規模な統計処理を必要とする人文社会科学の方や経済・金融関係の方、企業で研究をされている方まで、多様な目的でご利用いただけます。お気軽にご相談ください。

<http://osku.jp/e0678>



• Vector-typed Supercomputer

- SX-ACE

• Scalar-typed Supercomputer

- PC cluster system for large-scale visualization (VCC)
- Osaka university Cybermedia cenTer Over-Petascale Universal Supercomputer

• Large-scale Visualization System

- 24-screen Flat Stereo Visualization System
- 15-screen Cylindrical Stereo Visualization System





Application example from High-performance Scientific News



Cosmology with Numerical Simulations

Prof. Kentaro Nagamine
Graduate School of Science, Osaka Univ.




HPSC vol.2 <http://www.hpc.cmc.osaka-u.ac.jp/en/hpsc-news/vol02/>

Application example from High-performance Scientific News




Numerical simulation of flow and water quality in Osaka Bay
Assit. Prof. Yusuke Nakatani
Graduate School of Engineering, Osaka Univ.




Simulation of cyclonic circulation Flow by changing lanform

Around 1930




Today




そのため湾奥部の水質がどんどん悪化してしまう
ということがあります

Phytoplankton change in amount



Around 1930



Today

そうした動きが変わることによって 植物プランクトンが
どこに集積しやすくなるか？どこで大量に発生するか？が変わってきます

HPSC vol.3 <http://www.hpc.cmc.osaka-u.ac.jp/en/hpsc-news/vol03/>

OCTOPUS

ペタフロップス級ハイブリッド型スーパーコンピュータ



1

全国の研究者が
利用可能

2

多様な計算
ニーズへの対応

3

ペタフロップス級
大規模計算能力

4

安定した
動作環境の提供

OCTOPUS

since Dec. 2017



- is short for **Osaka university Cybermedia cenTer Over-Petascale Universal Supercomputer**.
- We were really eager to obtain a Peta-Flops system.
- The CMC' system is difficult to remember. Not fun!
 - Vcc, Ace, Hcc.. , PCC.
- Many Japanese people associate TAKOYAKI with Osaka.

Takoyaki (たこ焼き or 蛸焼) is a ball-shaped Japanese snack made of a [wheat flour](#)-based [batter](#) and cooked in a special molded pan. It is typically filled with minced or diced [octopus](#) (*tako*), [tempura](#) scraps (*tenkasu*), [pickled ginger](#), and [green onion](#).^{[1][2]} Takoyaki are brushed with takoyaki sauce (similar to [Worcestershire sauce](#)) and [mayonnaise](#), and then sprinkled with green laver (*aonori*) and [shavings](#) of dried [bonito](#). There are many variations to the takoyaki recipe, for example, [ponzu](#) (soy sauce with [dashi](#) and citrus vinegar), goma-dare (sesame-and-vinegar sauce) or vinegared dashi.

Yaki is derived from "yaku" (焼く) which is one of the cooking methods in Japanese cuisine, meaning "to fry or grill", and can be found in the names of other [Japanese cuisine](#) items such as [okonomiyaki](#) and [ikayaki](#) (other famous Osakan dishes)

from wikipedia



OCTOPUS 概要

CPU nodes



NEC LX 2U Twin2 Server 406 Rh-2 (59: 236nodes)

Many-core nodes



NEC Express5800/HR110c-M (11: 44nodes)




NEC LX 4U-GPU server 108Th-4G (4 node)

Storage



DDN EXAScaler (3.1PB)

GPU nodes



NEC LX 1U 4GPU Server 102Rh-1G (37: 37 nodes)

Large-scale shared memory nodes



NEC LX 116Rg-7 (2: 2nodes)

Mellanox CS7500
648 port EDR InfiniBand Director
Switch


1.46 PFlops

OCTOPUS システム構成




汎用 CPU ノード		合計 : 236 ノード (471.24 TFlops)
CPU	Intel Xeon Gold 6126 (Skylake / 2.6 Ghz, 12 cores) x 2	
Memory	192 GB	
GPU ノード		合計 : 37 ノード (858.28 TFlops)
CPU	Intel Xeon Gold 6126 (Skylake / 2.6 Ghz, 12 cores) x 2	
Memory	192 GB	
Accelerator	NVIDIA Tesla P100 (NVLINK) x 4	
メニーコア ノード		合計 : 44 ノード (117.14 TFlops)
CPU	Intel Xeon Phi 7210 (KNL / 1.3 Ghz, 64 cores)	
Memory	192 GB	
大容量主記憶搭載 ノード		合計 : 2 ノード (15.38 TFlops)
CPU	Intel Xeon Platinum 8153 (Skylake / 2.0 Ghz, 16 cores) x8	
Memory	6TB	
大容量ストレージ		合計 : 3.1PB
File System	DDN EXAScaler(Lustre)	
Size	3.1 PB	

OCTOPUS Storage/File server



OCTOPUS Storage/File server



DDN製ExaScaler

- Lustreファイルシステムベース
- 1ラックに3PB収容

管理サーバ(1台)

NFSサーバ(2台)

MDS (Meta Data Server) (2台)

DDN EF4024 (Meta Data Target)

DDN ES14KX

RAIDコントローラ

+OSS (Object Server Storage)

DDN SS8462

ストレージ

エンクロージャ


(OST: Object Storage Target)

DDN SS8462: OST on OCTOPUS

- 4U筐体に最大で84本のドライブを収容する高密度なストレージエンクロージャ
- 全てのコンポーネントが冗長化




OCTOPUSでは、10 TB NL-SAS(7.2krpm) HDD × **82個** を1ラックに搭載




OCTOPUS ストレージ構成


- 5エンクロージャにまたがり、10ドライブごとにLUNを構成
- LUN内でRAID6(8D+2P)を構成




OCTOPUS: ファイルシステム構成



- MDSサーバ: 2サーバでActive/Standby冗長構成




- ファイルサーバ: RAIDコントローラごとに2VMを配備し、合計4VMでActive/Active構成



Lustreの運用 on OCTOPUS

OCTOPUS file system (1)

- /octfs: mount point as a single file system
 - Lutre storage is accessed at /octfs/ from all computing nodes and frontend nodes.



OCTOPUS file system (2)

- Design goal: Quota design/configuration **well-suitable for our user management method and storage charging policy.**

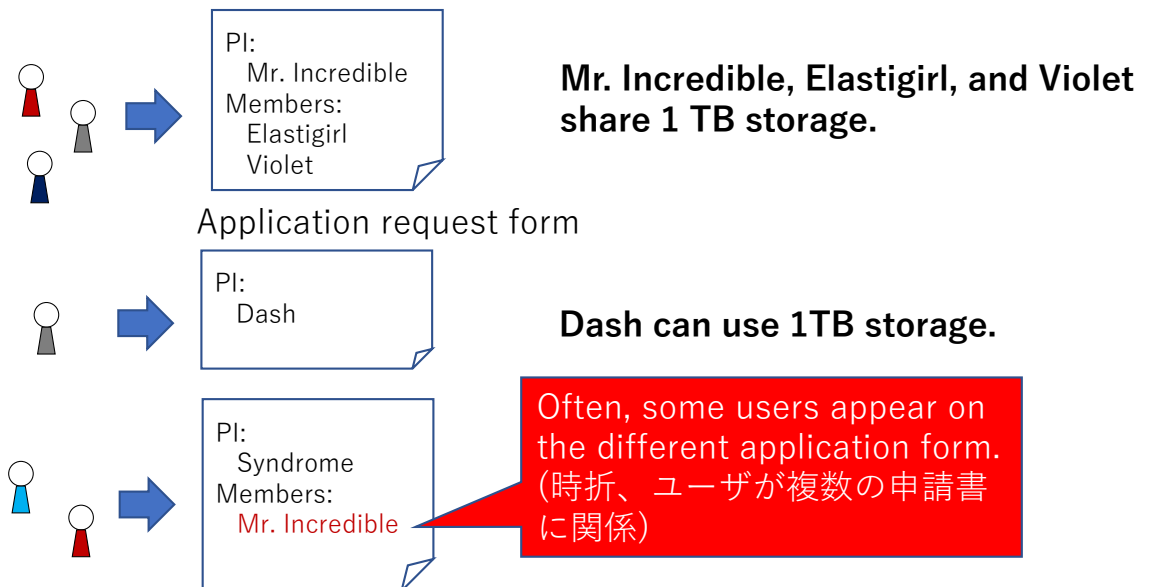
Storage-Charging Policy

- 1 TB disk space is allocated to each application request (ディスク容量は1申請単位で1TBを割り当てる。)
- 1 TB disk space can be added per 3000 JPY/year. (年間3000円で1 TBの追加ストレージを割り当て可能。)

User management

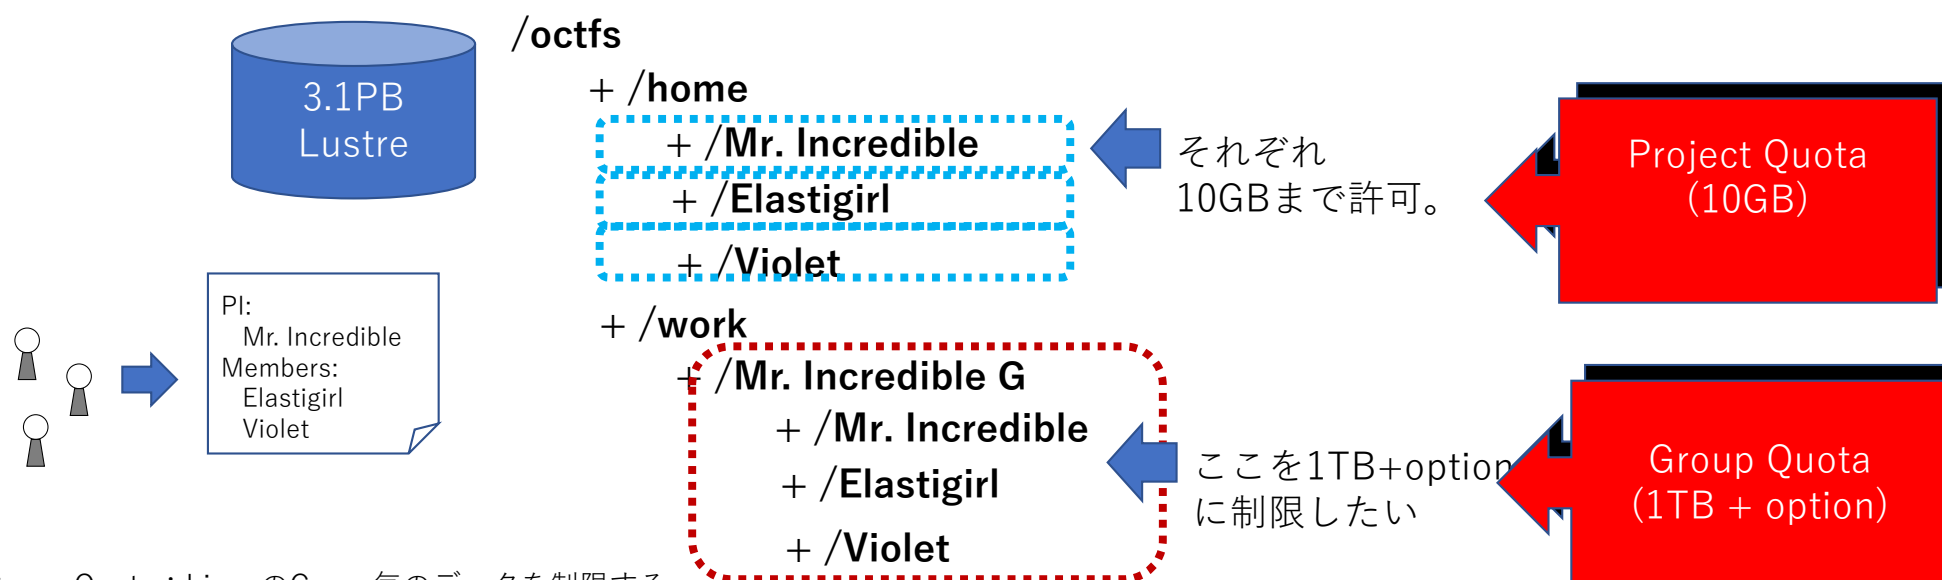
- Application request is done by an individual or group. (申請は個人あるいはグループ単位)
- Currently, different user-ids are issued to a user in the case that the user belongs to multiple application requests. (現在は、同一ユーザであっても申請グループごとにアカウント発行)
- In future, the same account for a user can be shared among different groups. (将来的に、1ユーザが複数のグループに所属できるようにしたい)

How can we use Lustre quota functions?
(どのようにクォータによってストレージ容量を制限すべきか?)



Partition and Quota Configuration on OCTOPUS

- Partitioning (パーティション設定)
 - ユーザhome領域: `/octfs/home/(user id)/`
 - グループwork領域: `/octfs/work/(group)/(user id) /`
- Quota Configuration(クォータ設定)



- ※Group Quota : LinuxのGroup毎のデータを制限する。
ファイルシステム単位で1つだけ設定可能。
- ※Project Quota : 特定のディレクトリ内のデータ容量を制限する。
ファイルシステム内に、ディレクトリ単位で複数設定可能

ファイルアクセス性能 on OCTOPUS

比較対象システム：VCC 2013年度導入



- Dynamically Reconfigurable Cluster System
using ExpEther, system virtualization technology from NEC

大規模計算機システム 2018年度 新規利用者受付中

1 全国の研究者が利用可能 2 多様な計算ニーズへの対応 3 ベタフロップス級大規模計算能力 4 安定した動作環境の提供

ご希望・ご用途に応じて、利用するスーパーコンピュータを自由にお選びいただけます ※下記は利用例です

生物系
膨大なゲノム情報のデータ解析・統計処理を高速に行いたい。

人文社会系
マルチエージェントシミュレーションにより、災害時における人の避難行動や経済活動のシミュレーションを行いたい。

理工系
気象予測、地球環境変動解析、流体解析、新薬開発などのシミュレーションを行いたい。

OCTOPUS
ベタフロップス級ハイブリッド型スーパーコンピュータ

VCC
動的再構成可能型スーパーコンピュータ

SX-ACE
ベクトル型スーパーコンピュータ

POINT 大規模計算機システムは10万円からご利用いただけます

本センターでは、大規模計算機システムの運転に必要な電気代相当を、利用者の皆様にご負担いただいております。ご利用を検討されている方を対象に、大規模計算機システムをお試し利用いただける「試用制度」を設けておりますので、ご利用を検討されている方は是非お申込みください。

CPUノード		合計：66ノード
CPU	Intel Xeon E5-2670v2(Ivy Bridge / 2.5 Ghz, 10 cores) x 2	
Memory	64GB	
増設ノード		合計：3ノード
CPU	Intel Xeon E5-2690v4 (Broadwell / 2.5 Ghz, 14 cores) x 2	
Memory	64 GB	
再構成可能資源		
Accelerator	NVIDIA Tesla K20	59基
Flush drive	ioDrive2 (365 GB)	4個
Storage	PCIe SAS (36TB)	9個
大容量ストレージ		
File system	NEC ScaTeFS (Scalable Technology File System)	
Size	2 PB	


<http://www.hpc.cmc.osaka-u.ac.jp/vcc-sys/>

NEC ScaTeFS for SX-ACE & VCC



- 複数のI/Oサーバにメタデータおよびデータを均等に分散させることで、高速な並列I/Oと大量のファイル操作に強いファイルシステムを実現するだけでなく、単一障害点の排除と自動リカバリによる高い耐障害性とデータ保護も同時に実現した高信頼性を確立したファイルシステム

NEC ScaTeFSで2PBのストレージをSX-ACE、VCCに提供



設置図



ScaTeFS (2PB) for SX-ACE and VCC



DDN Lustre (3PB) for OCTOPUS



IORによる性能評価

- 2018年10月18日(運用中:**中負荷時**)にスケジューラNQS IIよりジョブ投入して計測
 - `ior -w -r -b 8g -t m -C -Q 21-e -vv -F -o output`

			OCTOPUS
IOR 2.10.3	32 nodes 640 processes	write	30,405 MiB/sec
		read	30,392 MiB/sec
	16 nodes, 320 processes	write	28,995 MiB/sec
		read	29,631 MiB/sec
	8 nodes, 150 processes	write	26,443 MiB/sec
		read	20,772 MiB/sec
	4 nodes, 80 processes	write	20,896 MiB/sec
		read	13,861 MiB/sec

VCC
6,959 MiB/sec
10,224 MiB/sec
9,067 MiB/sec
6,805 MiB/sec
7,138 MiB/sec
8,443 MiB/sec
4,134 MiB/sec
4,284 MiB/sec



運用中でも調達当初の性能(read/write合算60GB/sec以上)を確認

(注)全く違う環境での評価なので、VCCのデータはあくまで参考データ。

IORによる性能評価



- 2018年10月18日(運用中:**高負荷時**)にスケジューラNQS IIよりジョブ投入して計測
 - *ior -w -r -b 8g -t m -C -Q 21-e -vv -F -o output*

			OCTOPUS
IOR 2.10.3	32 nodes 640 processes	write	25,037.06 MiB/sec
		read	15,908.67 MiB/sec
	16 nodes, 320 processes	write	19,870.49 MiB/sec
		read	10,768.68 MiB/sec
	8 nodes, 150 processes	write	14,859.89 MiB/sec
		read	17,179.97 MiB/sec
	4 nodes, 80 processes	write	12,588.92 MiB/sec
		read	4726.19 MiB/sec

ddによる性能評価



- 2018年10月18日の運用中にスケジューラNQS II よりジョブ投入して計測
- ブロックサイズ = 1 Mに固定して、256, 512, 1024MBのファイルをwrite/readした際のスループット計測
 - Write: `dd if=/dev/zero of=$LUSTERDIR/$FILE bs=1M count=??? conv=fsync`
 - Read: `dd if=$LUSTERDIR/$FILE of=/dev/null bs=1M count=???`

(注)全く違う環境での評価なので、VCCのデータはあくまで参考。

			OCTOPUS
dd	1 node, 1process	256MB write	1.2 GB/sec
		256MB read	1.6 GB/sec
		512MB write	1.2 GB/sec
		512MB read	1.5 GB/sec
		1024MB write	1.5 GB/sec
		1024MB read	1.5 GB/sec

VCC
0.33 GB/sec
0.98 GB/sec
0.43 GB/sec
1.00 GB/sec
0.57 GB/sec
1.00 GB/sec

MDTestによる性能評価



- 運用中にスケジューラNQS II よりジョブ投入して計測
 - Unique: 各プロセスが個別ファイル进行处理
 - Shared: 各プロセスが同一ファイル进行处理

(注)全く違う環境での評価なので、VCCのデータはあくまで参考。

		OCTOPUS
MDTest 1.9.3	32 nodes 64 processes	unique file creation
		75,963 op/sec
		unique file stat
		272,689 op/sec
		unique file read
		212,684 op/sec
		unique file removal
		106,531 op/sec
		shared file creation
		64,689 op/sec
		shared file stat
		139,334 op/sec
		shared file read
		131,328 op/sec
		shared file removal
		76,596 op/sec

VCC
33,528 op/sec
151,143 op/sec
271,262 op/sec
44,003 op/sec
2,703 op/sec
28,100 op/sec
278,557 op/sec
10,613 op/sec

Summary (まとめ)

- OCTOPUSを支えるLustreストレージについて報告・紹介
 - **DDN ExaScalerを基軸としたストレージサービス**の実現
 - DDN ES14KX, SS8462を活用
 - 3PBを1ラックに高密度搭載
 - 10 TB NL-SAS(7.2krpm) HDD 410個
 - 高信頼
 - 2017年12月より障害がほとんどない
 - Lustre運用の実際面
 - Partition & Quota Configuration
 - 性能評価
 - 運用中でも高性能を提供



2018年度
大規模計算機システム
新規利用者受付中!

理工系 芸術系 人文社会系 農畜系

大学・企業を問わず
利用可能!

**CALL FOR
SUPERCOMPUTER USERS**

大規模計算機システム 2018年度新規利用者受付中

OCTOPUS (15.46 PFlop/s)	VCC (1100.13 TFlop/s)	SX-ACE (420 TFlop/s)
ベタトップス超ハイブリッド型 スーパーコンピュータ	動的再構成可能型 スーパーコンピュータ	ベクトル型 スーパーコンピュータ
計算ノード数: 201,120ノード (Kubernetes) メモリ: 大規模なメモリ (1.5TB) 搭載 ストレージ: 大規模なストレージ (10PB) 搭載 ネットワーク: 高速なネットワーク (100GbE) 搭載	計算ノード数: 110,000ノード メモリ: 大規模なメモリ (1.5TB) 搭載 ストレージ: 大規模なストレージ (10PB) 搭載 ネットワーク: 高速なネットワーク (100GbE) 搭載	計算ノード数: 42,000ノード メモリ: 大規模なメモリ (1.5TB) 搭載 ストレージ: 大規模なストレージ (10PB) 搭載 ネットワーク: 高速なネットワーク (100GbE) 搭載

大阪大学サイバーメディアセンターの大規模計算機システムは、学内外を問わず本センターの利用資格を満たす皆様にご利用いただけます。専断の方ももちろん、大規模な統計処理を必要とする人文社会系の方や経済・金融関係の方、企業で研究をされている方まで、多様な目的でご利用いただけます。お気軽にご相談ください。

http://osku.jp/e0678



Expectation and Concern to Lustre (データ基盤?)



- **Expansion of functionalities or familiarities with other storage service? (機能拡張 & 他ストレージサービスとの親和性強化?)**
 1. User-Friendly Data Aggregation (データ集約機能)
 - Large data are still *immovable like a mountain*. “動かざること山の如し”
 2. Security/Data-protection functionality from not only technological but also ethical and regulation aspects. (セキュリティ/データ保護機能)
 - Security-sensitive data still sits in the outside of our supercomputer environment.
 3. For hybrid use of Cloud and on-premises environment
- **Continuous, prompt, and versatile support and information sharing (継続的、迅速かつ臨機応変なサポートと情報共有)**
 - For prompt feedback: Users and administrators can benefit from new technologies and functionalities.
 - For stable system operation: “Never waste researchers’ time and efforts.”