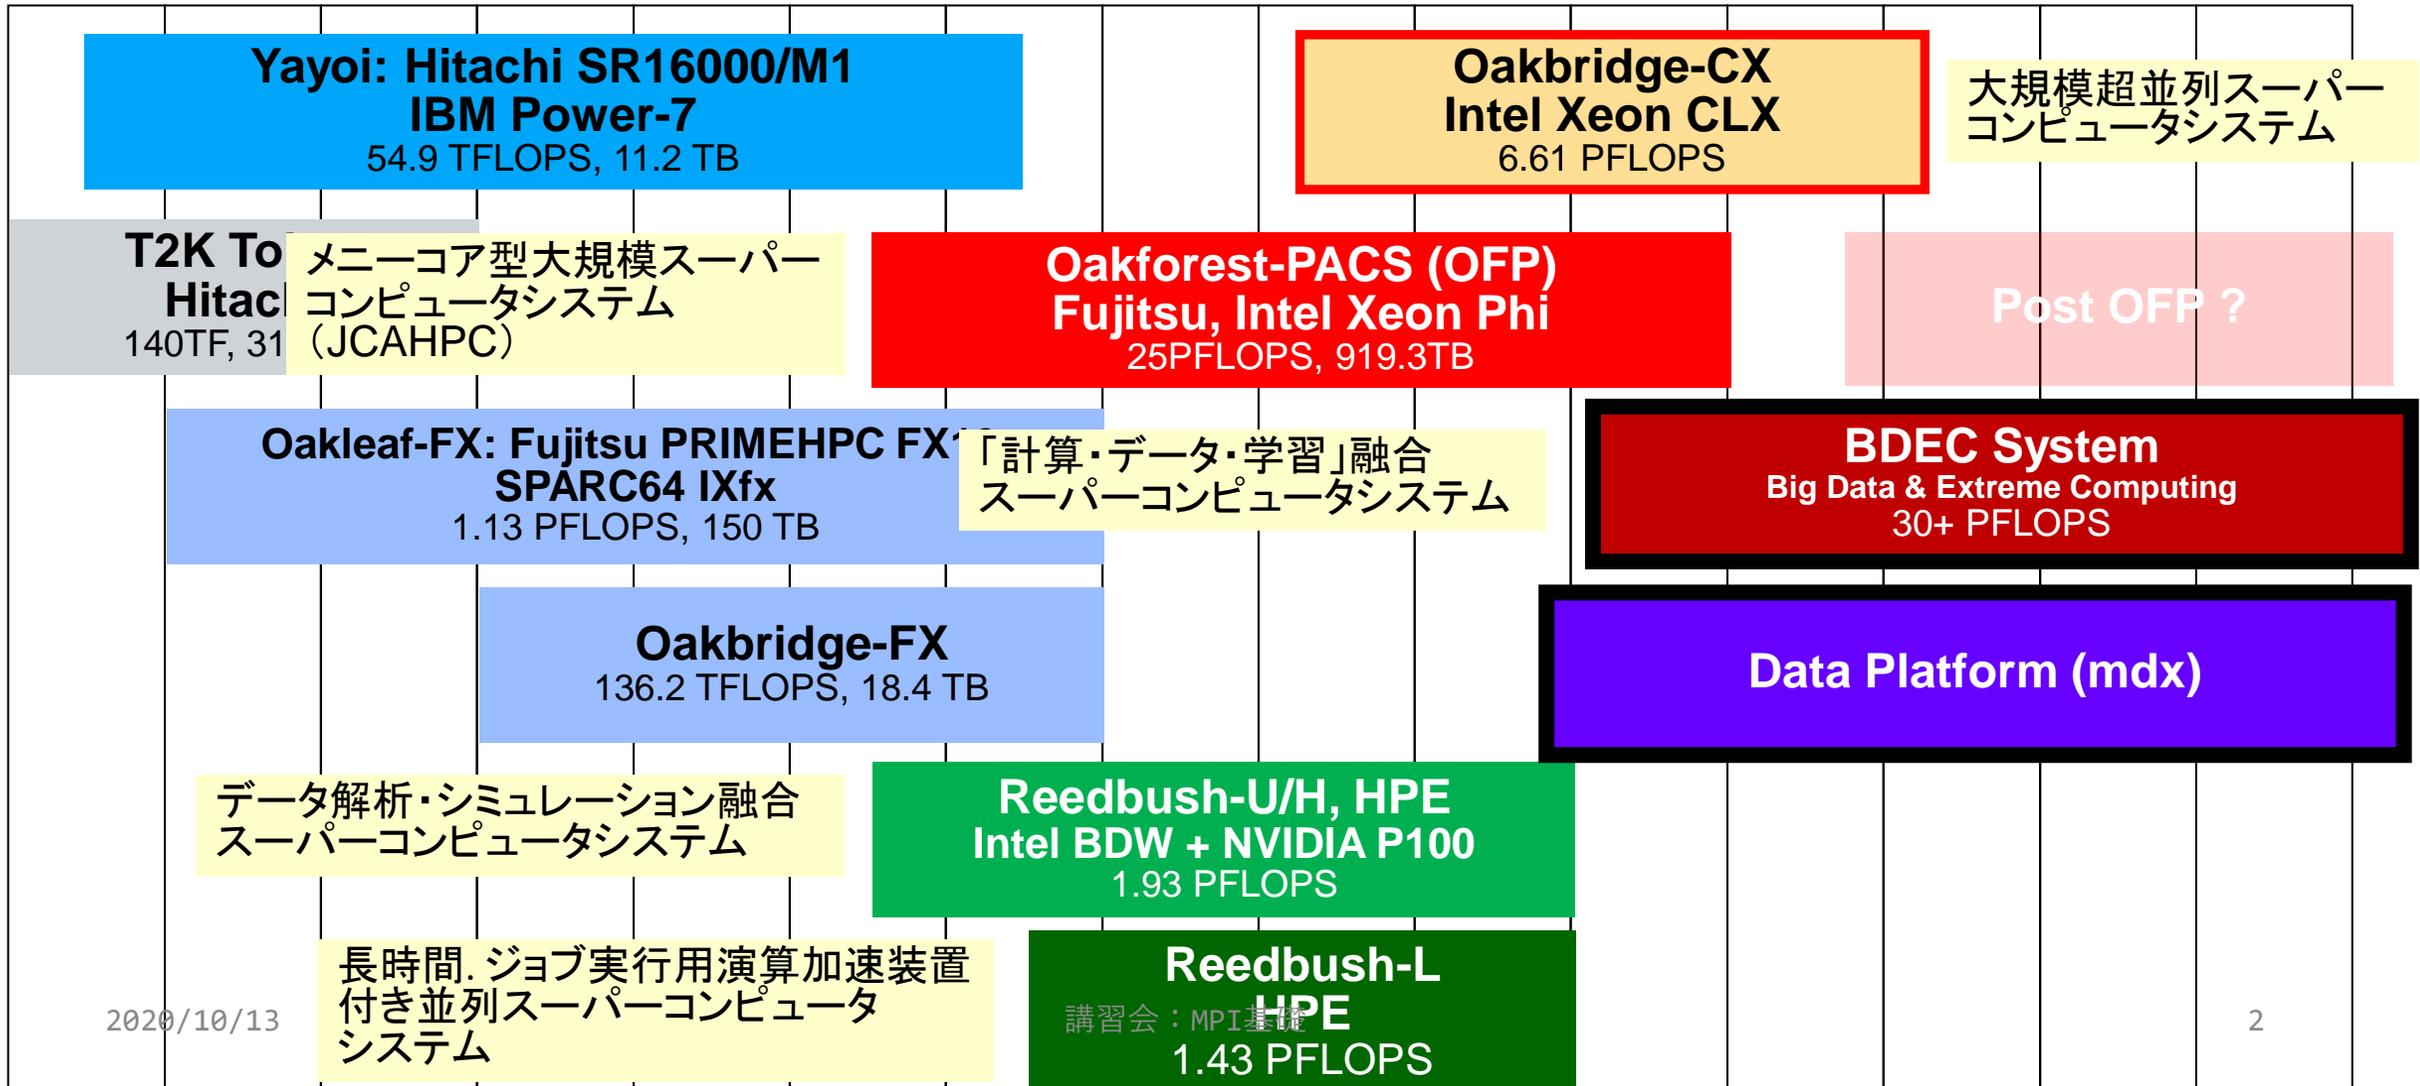


第141回 お試しアカウント付き  
並列プログラミング講習会  
「MPI基礎：並列プログラミング入門」

東京大学 情報基盤センター  
三木 洋平

# 東大情報基盤センターのスパコン

FY11 12 13 14 15 16 17 18 19 20 21 22 23 24 25



# 3システム：利用者2600+, 学外55+%

- Reedbush (HPE, Intel BDW + NVIDIA P100 (Pascal)) (本郷)
  - データ解析・シミュレーション融合スーパーコンピュータ
  - 3.36 PF, 2016年7月～2021年3月末 (予定)
    - Reedbush-U (CPU only, 2020年6月30日で退役)
    - Reedbush-H (2GPU's/n), Reedbush-L (4GPU's)
  - 東大ITC初GPUクラスター (2017年3月より), DDN IME (Burst Buffer)
- Oakforest-PACS (OFP) (富士通, Intel Xeon Phi (KNL)) (柏)
  - JCAHPC (筑波大CCS & 東大ITC)
  - 25 PF, TOP500で18位 (日本3位) (2020年6月)
  - Omni-Path アーキテクチャ, DDN IME (Burst Buffer)
- Oakbridge-CX (富士通, Intel Xeon Platinum 8280) (柏)
  - 大規模超並列スーパーコンピュータシステム
  - 6.61 PF, 2019年7月～2023年6月, TOP500で60位 (2020年6月)
  - 全1,368ノードの内128ノードにSSDを搭載



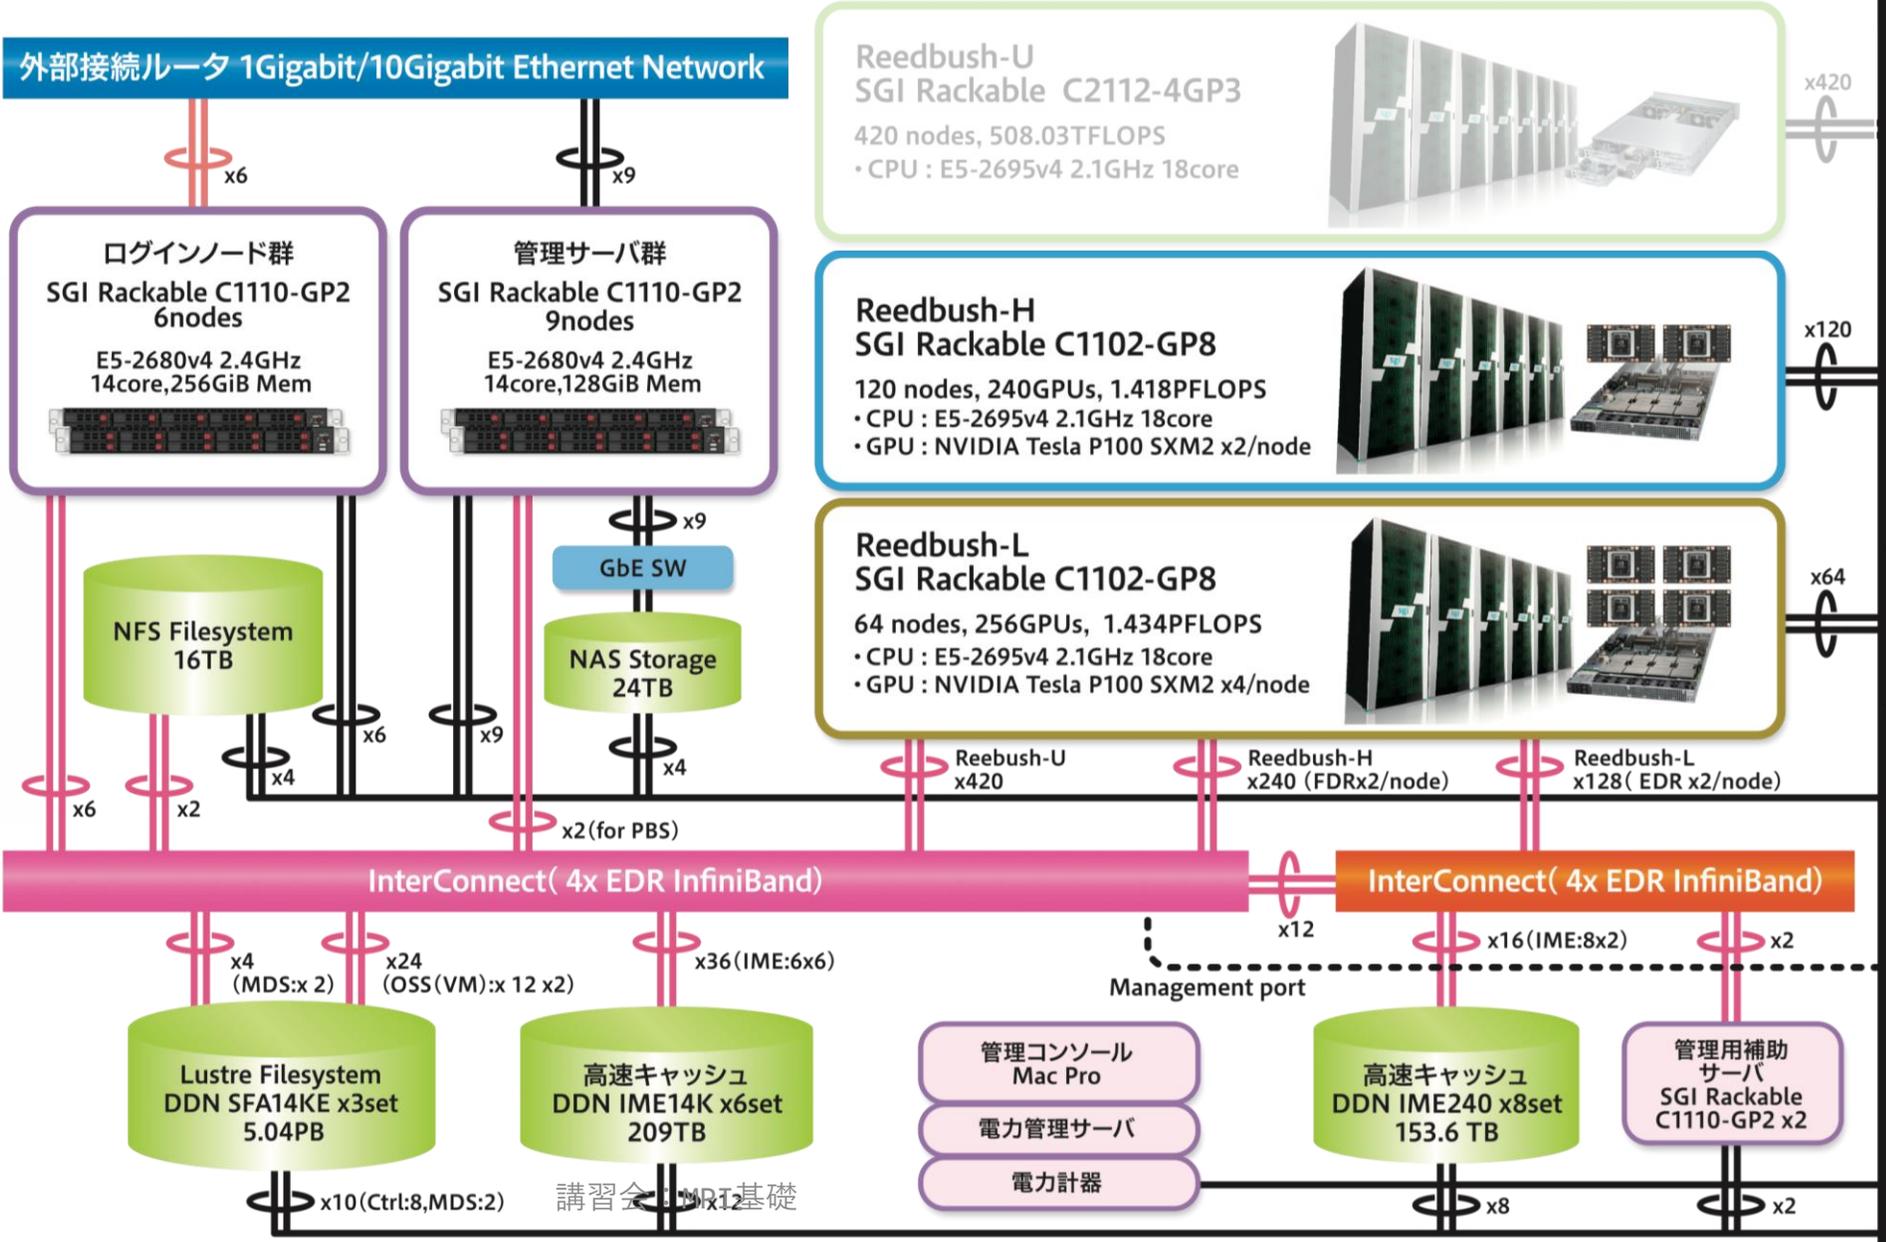
# Reedbush

## GPU クラスタ

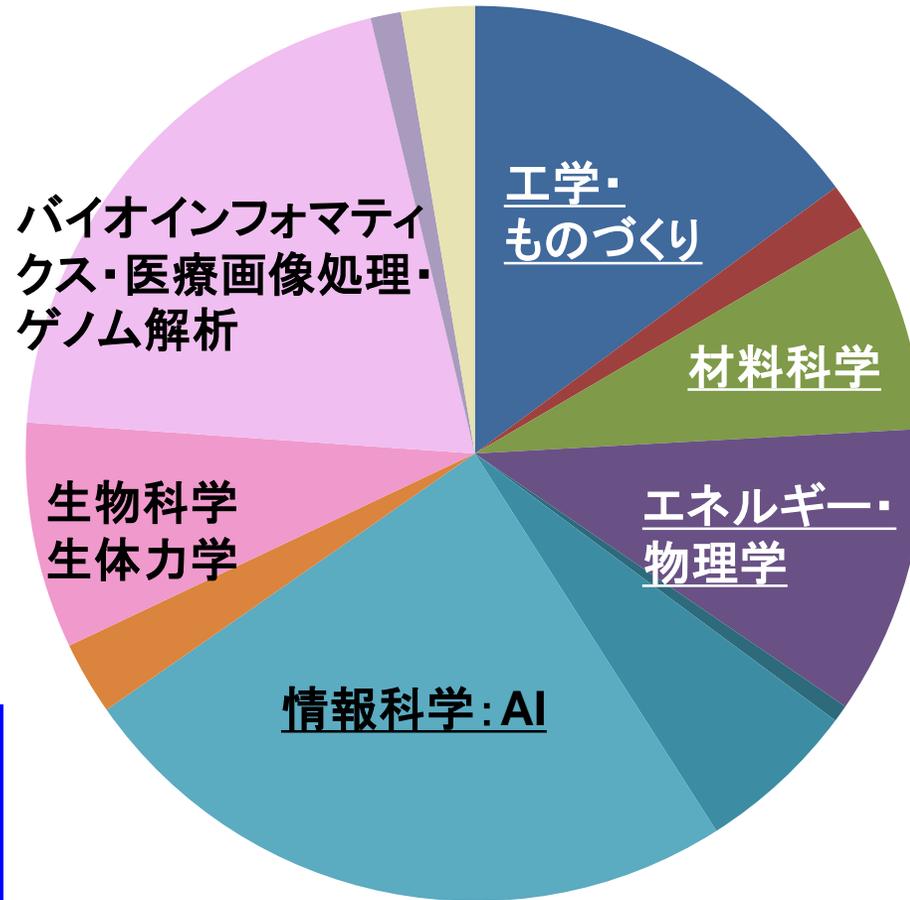


NVIDIA Tesla P100 SXM2

SGI C1102-GP8



# 研究分野別利用CPU時間割合 (2019年度)



- 工学・ものづくり
- 地球科学・宇宙科学
- 材料科学
- エネルギー・物理学
- 情報科学: システム
- 情報科学: アルゴリズム
- 情報科学: AI
- 教育
- 産業利用
- 生物科学・生体力学
- バイオインフォマティクス
- 社会科学・経済学
- データ科学・データ同化

従来からの工学・材料・物理学の研究に加えて、機械学習・AI, 医用画像解析・ゲノム解析などの研究にも多く利用

Reedbush-H  
Intel BDW+ NVIDIA P100 x2 / node

# 最先端共同HPC基盤施設 JCAHPC

Joint Center for Advanced High Performance Computing

- 2013年3月，筑波大学と東京大学は「計算科学・工学及びその推進のための計算機科学・工学の発展に資するための連携・協力推進に関する協定」を締結

- 筑波大学計算科学研究センター
- 東京大学情報基盤センター



東京大学  
THE UNIVERSITY OF TOKYO



筑波大学  
University of Tsukuba

- 東京大学柏Iキャンパスの東京大学情報基盤センター内に，両機関の教職員が中心となって設計するスーパーコンピュータシステムを設置し，最先端の大規模高性能計算基盤を構築・運営するための組織

- <http://jcahpc.jp>



# Oakforest-PACS (OFP)

- Top500: 世界第18位
- HPCG: 世界第11位 (2020年6月現在)

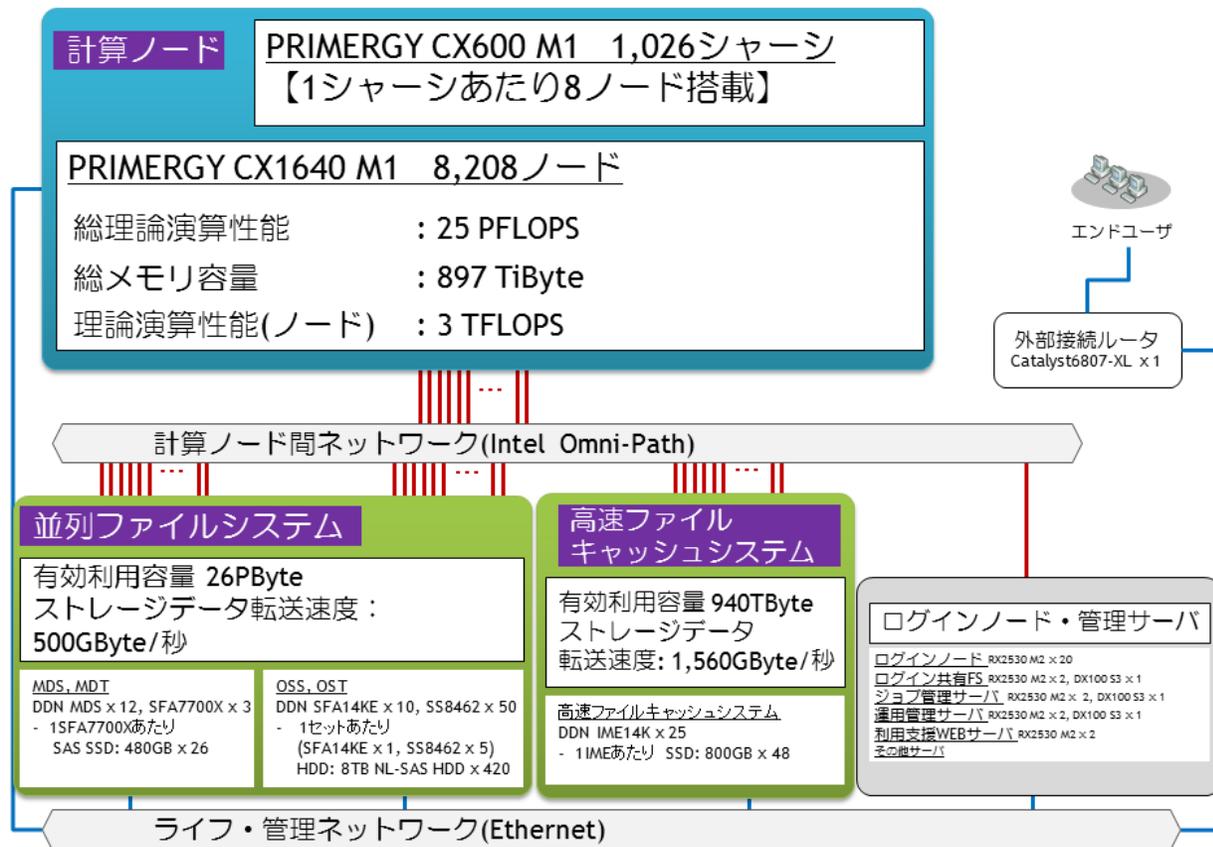


Fujitsu  
PRIMERGY CX1640 M1



Fujitsu PRIMERGY CX600 M1  
シャーシあたりCX1640 M1 × 8搭載

2020/10/13

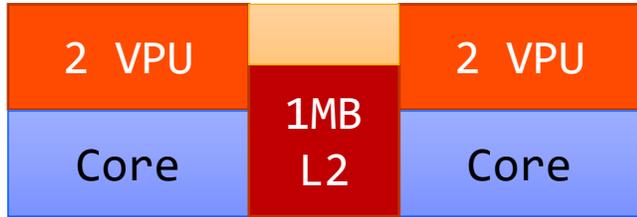


講習会: MPI基

# Oakforest-PACS計算ノード



HotChips27  
KNLスライドより



## Intel Xeon Phi 7250 (Knights Landing)

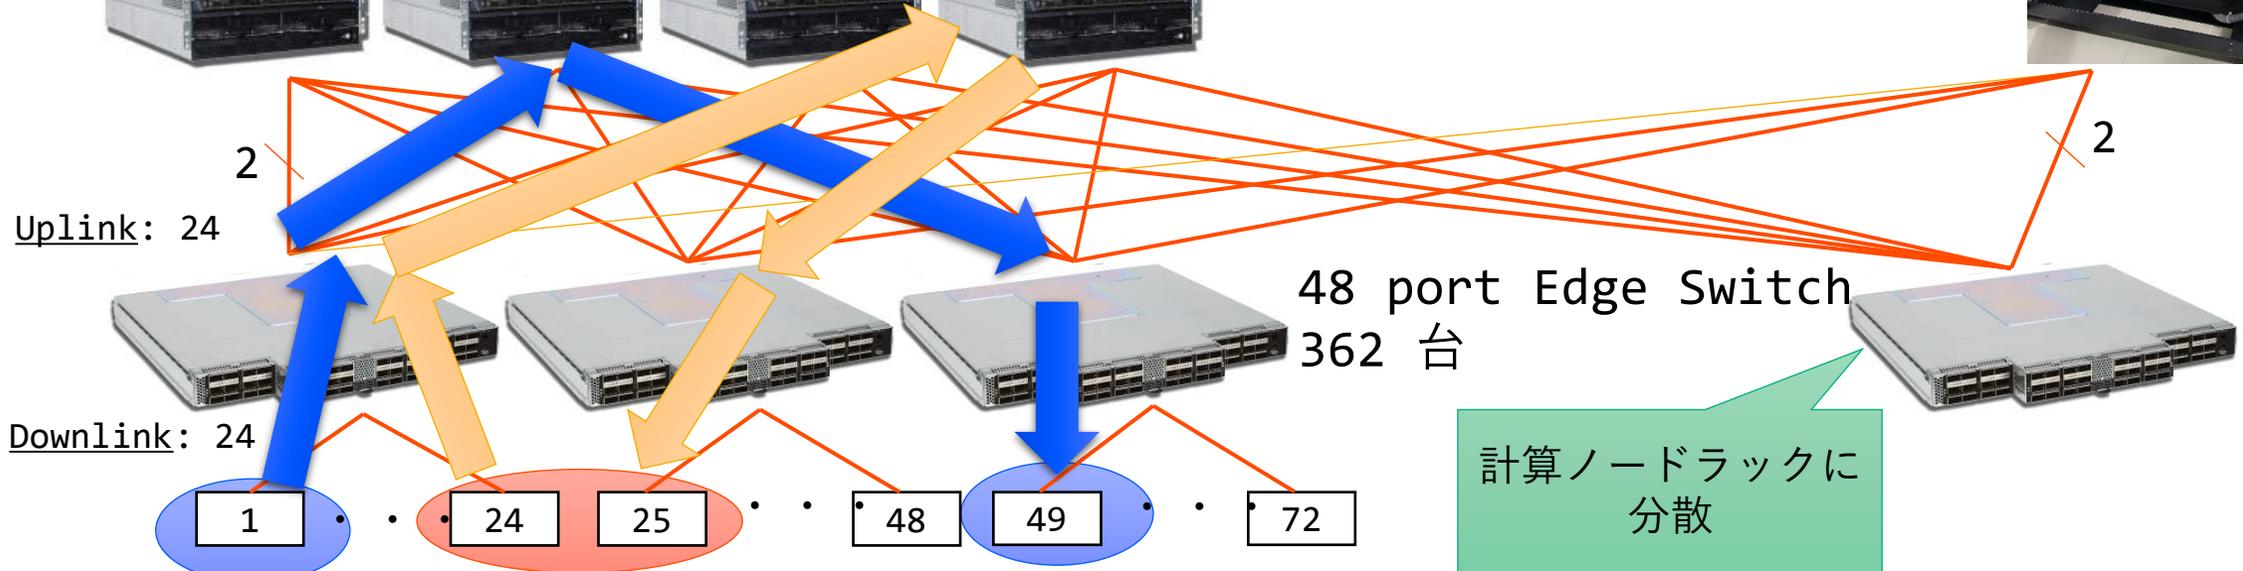
- 1CPU (1ノード) 当たり68コアの  
メニーコアプロセッサ
- 1.4 GHz, クロック当たり32回の倍精度  
実数演算 (Double Precision, DP)
  - コア当たり最大性能⇒ $1.4 \times 32 = 44.8$   
GFLOPS  
(1秒間に448億回の倍精度実数演算)
  - 1CPU 56コア,  $3,046.4$  GFLOPS= $3.046$   
TFLOPS (1秒間に3兆464億回演算)
- MCDRAM: オンパッケージ高バンド幅メモ  
リ搭載 16 GB, 490 GB/秒以上(実測)
  - DDR4 96 GB, 85 GB/秒 (実測)
- 全系 8,208ノード :  $25.004$  PFLOPS (1  
秒間に2京5,004兆回演算)



# Intel Omni-Path Architectureによるフルバイセクションバンド幅Fat-tree網



768 port Director Switch  
12台  
(Source by Intel)



## フルバイセクションバンド幅を維持

- フルバイセクションバンド幅：全ての計算ノードから同時に異なる計算ノードに通信しても性能が低下しない



計算ノードの物理配置を気にせずに必要な数の計算ノードを確保できる

# ファイルシステム（ストレージ）

並列ファイルシステム：Lustreファイルシステム

- 容量：26.2 PB
- バンド幅性能：500 GB/秒
  - サーバ当たり 50 GB/秒 x 10台
- 全10セット+メタデータ（管理）サーバで構成
  - 1セット当たり、サーバ兼コントローラ+5エンクロージャ
- 合計 4,200個の 8TB ハードディスク，20%冗長化（8D2P）

IO500 9位（2018年11月），15位（2019年6月）

高速ファイルキャッシュ（バーストバッファ）：Infinite Memory Engine (IME)

- 容量：940 TB
- バンド幅性能：1.56 TB/秒 = 1,560 GB/秒
- NVMe接続SSDを使用
  - 合計1,200枚の 800 GB SSD，冗長化（Erasure coding）
  - 単体 1.3 GB/s x 48本 x 25台 = 1,560 GB/s

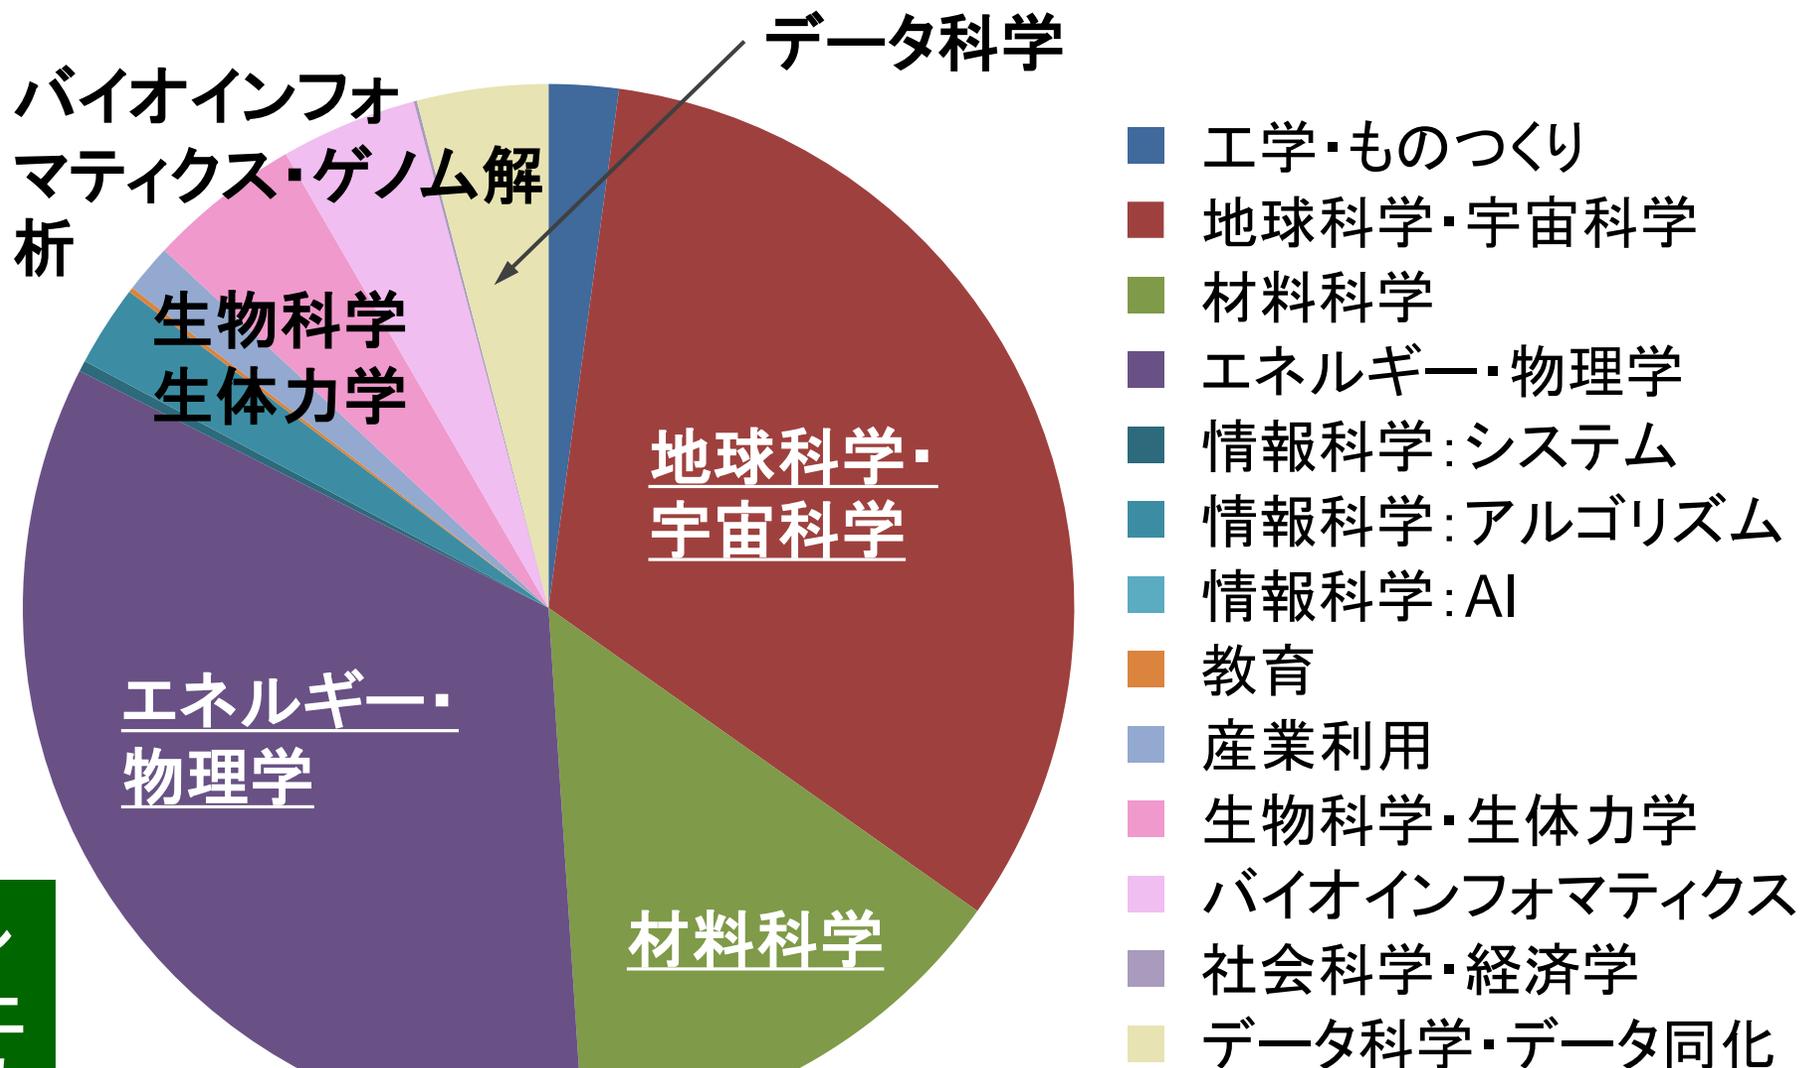
IO-500 1位（2017年11月、2018年6月）  
4位（2018年11月），3位（2019年6月）



# Oakforest-PACS全景

- 全体：102ラック  
(6列：計算x4列 + 他x2列)
- 計算ノード：69ラック
  - 2ラックで1単位  
(1箇所だけ3ラックで1単位)
- インタコネク特(OmniPath)  
Director スイッチ：12ラック
- ファイルシステム：16ラック
  - メタデータ (管理情報)：1ラック
  - 並列ファイルシステム：10ラック
  - ファイルキャッシュ：5ラック
- その他：5ラック
  - 管理ネットワーク機器：2ラック
  - ログインノード+プリポスト+Webポータル：1ラック
  - 管理サーバ：1ラック
  - 外部接続ルータ：1ラック
- 消費電力：**3.37 MW**  
冷却含め **4.24 MW**
  - 水冷 3.0 MW分程度,  
残り 0.4 MW分程度は空冷<sup>1</sup>

# 研究分野別利用CPU時間割合（2019年度）



地球・宇宙科学とエネルギー・物理学で半分以上を占める一方、データ解析にも利用

2020/10/13

講習会：MPI基礎

# Oakbridge-CX

- 世界第60位  
(2020年6月現在)



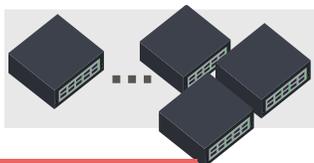
Fujitsu PRIMERGY CX2550 M5



Fujitsu PRIMERGY CX400 M1  
シャーン当たりCX2550 M5×4搭載

## 計算ノード

Chassis: PRIMERGY CX400 M4 x342 <4node / Chassis>  
Node: PRIMERGY CX2550 M5 x1,240, CX2560 M5 x128



x1,368 node

### 全体性能

理論演算性能: 6.61PF  
主記憶容量: 256.5TiB  
メモリバンド幅: 385.1TB/s  
ラック数: 21ラック  
SSD搭載: 128ノード

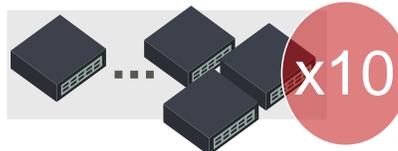
### ノード単体

理論演算性能: 4.8384 TF  
手記憶容量: 192GiB  
メモリバンド幅: 281.6GB/s



## 計算ノード間ネットワーク (Omni-Path Architecture) 通信性能 100Gbps

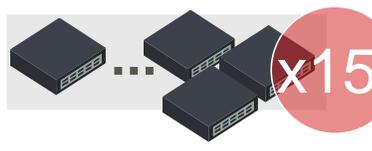
### ログインノード



x10

FUJITSU Server  
PRIMERGY CX2560 M5 x 10

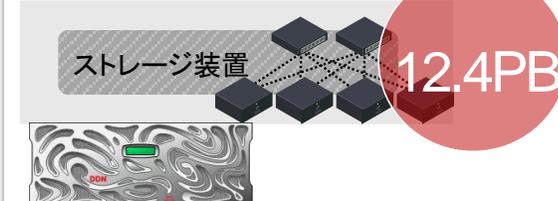
### 管理サーバ群



x15

FUJITSU Server  
PRIMERGY RX2530 M4 x 15  
(ジョブ、運用、認証、Web、  
セキュリティログ保存)

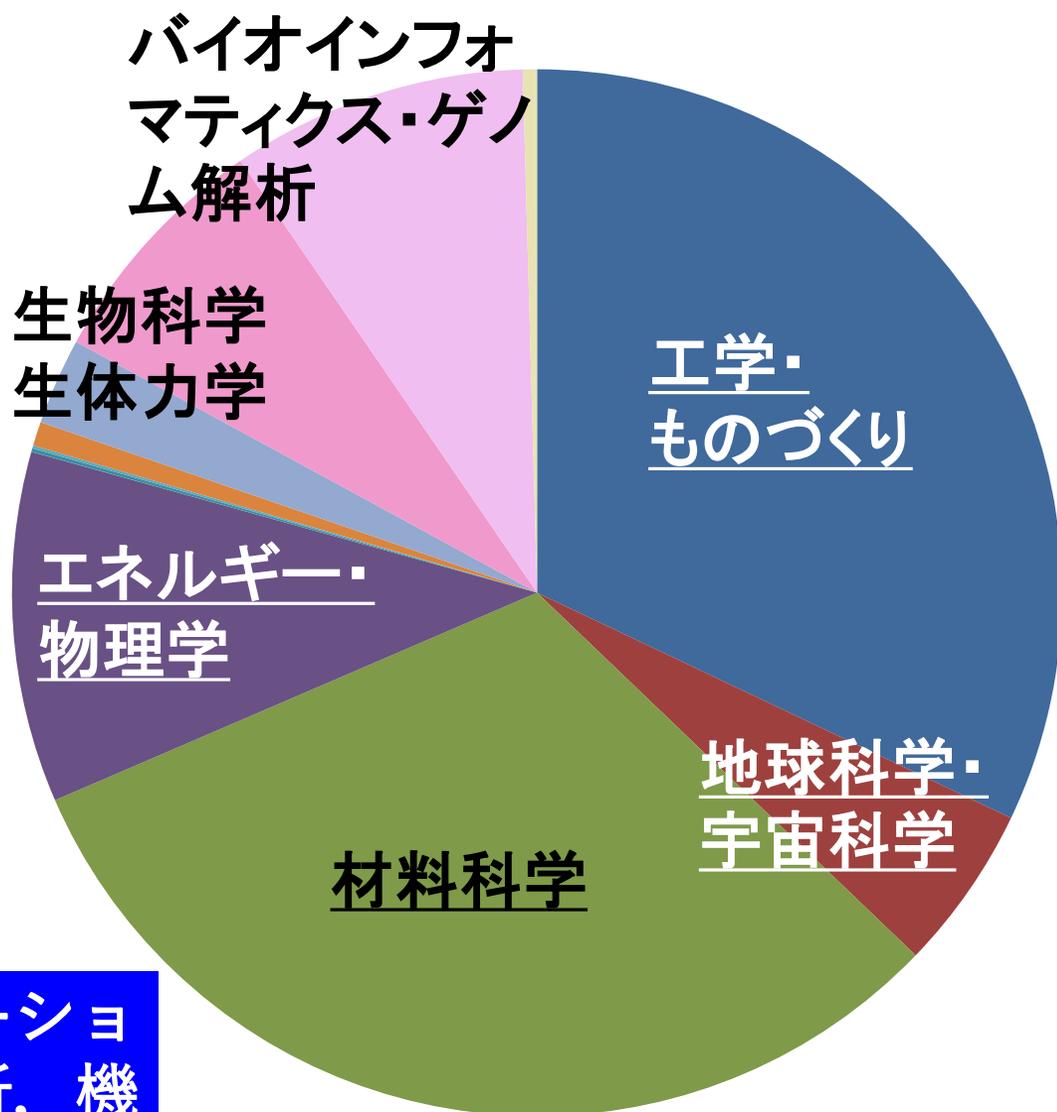
### 並列ファイルシステム



12.4PB

ストレージ装置: DDN ES18KE x2セット  
ファイルシステム: DDN ExaScaler  
(Lustreベースファイルシステム) 13

# 研究分野別利用CPU時間割合 (2019.10~2020.9)

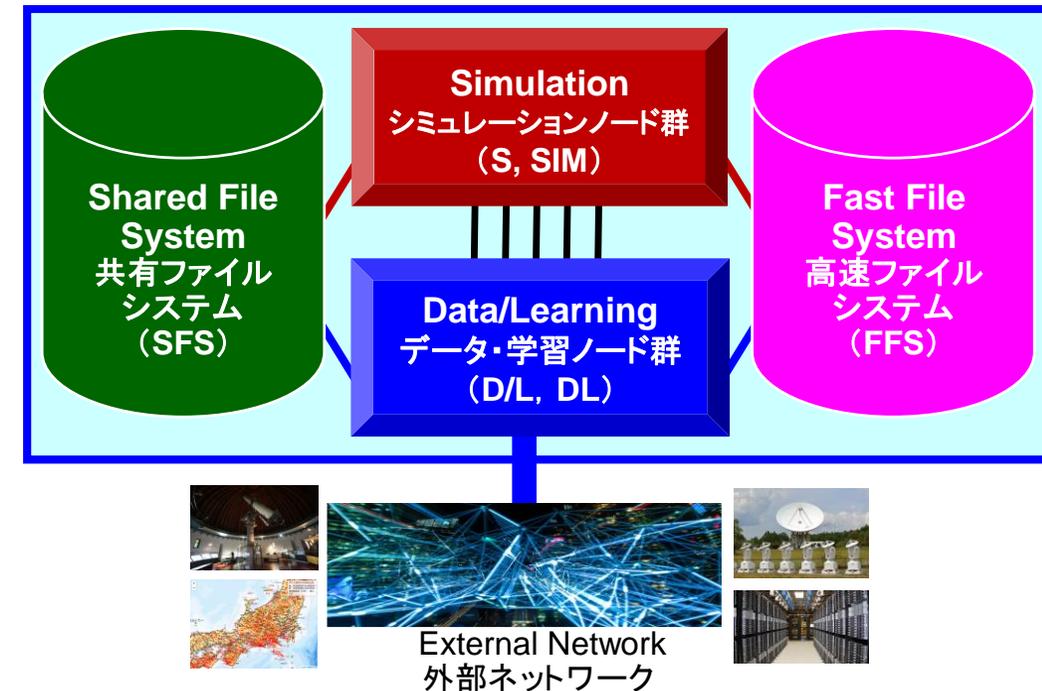


- 工学・ものづくり
- 地球科学・宇宙科学
- 材料科学
- エネルギー・物理学
- 情報科学:システム
- 情報科学:アルゴリズム
- 情報科学:AI
- 教育
- 産業利用
- 生物科学・生体力学
- バイオインフォマティクス
- 社会科学・経済学
- データ科学・データ同化

計算科学シミュレーションの他, データ解析, 機械学習分野にも利用

# BDEC: Big Data & Extreme Computing

- **BDEC (Big Data & Extreme Computing)**
  - 2021年5月（以降）運用開始予定
  - 30+ PF, ~4.5 MVA（空調込み）, ~360m<sup>2</sup>
  - **(D+L) による (S) の高度化 AI for HPC**
- 「**シミュレーション・データ・学習 (S+D+L)**」  
融合, 2種類のノード群
  - **シミュレーションノード群 (S, SIM)**
    - 従来のスパコン
    - CPU with HBM, 25+PF, 2+PB/sec（最大9.0）
  - **データ・学習ノード群 (D/L, DL)**
    - データ解析, 機械学習
    - GPU Cluster, 5+PF, 575TB/sec
    - データ・学習ノード群の一部は外部リソース（ストレージ, サーバー, センサーネットワーク他）に直接接続
  - **Hierarchical, Hybrid, Heterogeneous (h3)**
- **ファイルシステム：共有（大容量） + 高速**



# 55th TOP500 List (June 2020)

<https://www.top500.org/lists/top500/>

|    | Name                        | Computer Site   | Cores    | Rmax (Tflop/s)          | Rpeak (Tflop/s) | Power (kW) |
|----|-----------------------------|---|----------|-------------------------|-----------------|------------|
| 1  | <b>Supercomputer Fugaku</b> | Supercomputer Fugaku, A64FX 48C 2.2GHz, Tofu interconnect D<br>RIKEN Center for Computational Science   | 7299072  | 415530<br>(=415.5 PF)   | 513854.67       | 28334.5    |
| 2  | <b>Summit</b>               | IBM Power System AC922, IBM POWER9 22C 3.07GHz, NVIDIA Volta GV100, Dual-rail Mellanox EDR Infiniband<br>DOE/SC/Oak Ridge National Laboratory | 2414592  | 148600<br>(=148.6 PF)   | 200794.88       | 10096      |
| 3  | <b>Sierra</b>               | IBM Power System AC922, IBM POWER9 22C 3.1GHz, NVIDIA Volta GV100, Dual-rail Mellanox EDR Infiniband<br>DOE/NNSA/LLNL                         | 1572480  | 94640<br>(= 94.6 PF)    | 125712          | 7438.28    |
| 4  | <b>Sunway TaihuLight</b>    | Sunway MPP, Sunway SW26010 260C 1.45GHz, Sunway<br>National Supercomputing Center in Wuxi   | 10649600 | 93014.59<br>(= 93.0 PF) | 125435.9        | 15371      |
| 5  | <b>Tianhe-2A</b>            | TH-IVB-FEP Cluster, Intel Xeon E5-2692v2 12C 2.2GHz, TH Express-2, Matrix-2000<br>National Super Computer Center in Guangzhou                 | 4981760  | 61444.5<br>(= 61.4 PF)  | 100678.66       | 18482      |
| 6  | <b>HPC5</b>                 | PowerEdge C4140, Xeon Gold 6252 24C 2.1GHz, NVIDIA Tesla V100, Mellanox HDR Infiniband<br>Eni S.p.A.  | 669760   | 35450<br>(= 35.5 PF)    | 51720.76        | 2252.17    |
| 7  | <b>Selene</b>               | DGX A100 SuperPOD, AMD EPYC 7742 64C 2.25GHz, NVIDIA A100, Mellanox HDR Infiniband<br>NVIDIA Corporation                                      | 272800   | 27580<br>(= 27.6 PF)    | 34568.6         | 1344.19    |
| 8  | <b>Frontera</b>             | Dell C6420, Xeon Platinum 8280 28C 2.7GHz, Mellanox InfiniBand HDR<br>Texas Advanced Computing Center/Univ. of Texas                          | 448448   | 23516.4<br>(= 23.5 PF)  | 38745.91        |            |
| 9  | <b>Marconi-100</b>          | IBM Power System AC922, IBM POWER9 16C 3GHz, Nvidia Volta V100, Dual-rail Mellanox EDR Infiniband<br>CINECA                                   | 347776   | 21640<br>(= 21.6 PF)    | 29354           | 1476       |
| 10 | <b>Piz Daint</b>            | Cray XC50, Xeon E5-2690v3 12C 2.6GHz, Aries interconnect , NVIDIA Tesla P100<br>Swiss National Supercomputing Centre (CSCS)                   | 387872   | 21230<br>(= 21.2 PF)    | 27154.3         | 2384.24    |
| 18 | <b>Oakforest-PACS</b>       | PRIMERGY CX1640 M1, Intel Xeon Phi 7250 68C 1.4GHz, Intel Omni-Path<br>Joint Center for Advanced High Performance Computing                   | 556104   | 13554.6<br>(= 13.6 PF)  | 24913.46        | 2718.7     |

# Green500 List (June 2020)

<https://www.top500.org/lists/green500/>

|    | Name                 | Accelerator/Co-Processor | GFlops/Watts | Power (kW) | Rmax (TFlop/s) | TOP500 Rank |
|----|----------------------|--------------------------|--------------|------------|----------------|-------------|
| 1  | MN-3                 | MN-Core                  | 21.10807292  | 76.8       | 1621.1         | 393         |
| 2  | Selene               | NVIDIA A100              | 20.51793273  | 1344.19    | 27580          | 7           |
| 3  | NA-1                 | PEZY-SC2 700Mhz          | 18.433       | 80.17      | 1303.22        | 468         |
| 4  | A64FX prototype      |                          | 16.87626604  | 118.48     | 1999.5         | 204         |
| 5  | AiMOS                | NVIDIA Volta GV100       | 16.28456491  | 512.08     | 8339           | 26          |
| 6  | HPC5                 | NVIDIA Tesla V100        | 15.74037484  | 2252.17    | 35450          | 6           |
| 7  | Satori               | NVIDIA Tesla V100 SXM2   | 15.57446809  | 94         | 1464           | 421         |
| 8  | Summit               | NVIDIA Volta GV100       | 14.71870048  | 10096      | 148600         | 2           |
| 9  | Supercomputer Fugaku |                          | 14.66516085  | 28334.5    | 415530         | 1           |
| 10 | Marconi-100          | Nvidia Volta V100        | 14.66124661  | 1476       | 21640          | 9           |
| 20 | Reedbush-L           | NVIDIA Tesla P100        | 10.167       | 79         | 805.6          | June'18     |
| 28 | Reedbush-H           | NVIDIA Tesla P100        | 8.576        | 94         | 802.4          | June'18     |

# (理論) ピーク性能

- OFPに搭載されているXeon Phi 7250のピーク性能：
  - コア数： **68**コア
  - コア当たりのAVX-512 ユニット： **2**
  - AVX-512ユニット当たりの同時演算数（倍精度）： **8** (= 512 / 64)
  - 積和演算（Fused Multiply Add: FMA）： **2** に換算
  - クロック周波数： **1.40** GHz
- ノード当たりピーク性能：  $68 * 2 * 8 * 2 * 1.40 = 3046.4 \text{ GFlop/s}$
- しかし、AVX-512ユニットは実は**1.40 GHz**では動作しない（より低い周波数）
  - ピークに近い性能が得られるはずのもの（OFPでの実測値）
    - DGEMM（倍精度の行列積）： **2200** GFlop/s（ピーク比：72%）
    - HPL： **2000** GFlop/s（ピーク比：66%）
  - Top500におけるOFPの登録値は理論ピークの54.4%
- 「ピーク性能」の定義を正しく把握しておくことが重要！！
  - CPUメーカーによって定義の仕方も異なる

# 利用制度の紹介

- 一般利用
  - 大学・公共機関に在籍の方（大学院生は代表者としては申し込めません）
  - 電気代相当料金の利用負担金支払いが必要
- 企業利用
  - 企業に在籍の方
  - 利用負担金は一般利用の約1.2倍
  - 書面・ヒアリング審査あり，成果報告（公開）義務あり
- 若手・女性利用
  - 大学・公共機関に在籍の方
  - 4月1日現在40歳以下の若手，または女性，または学生
  - 利用負担金なし
  - 書類審査あり，成果報告義務あり
- 学際大規模情報基盤共同利用・共同研究拠点（JHPCN）への課題申請
- HPCI課題への課題申請

# 東大情報基盤センターOakforest-PACSスーパーコンピュータシステムの料金表（2020年4月1日）

- <https://www.cc.u-tokyo.ac.jp/guide/application/>
  - 「利用負担金」を参照
- パーソナルコース
  - 基本セット 50,000円： 6セットまで、最大2048ノードまで  
トークン：1ノード x 24時間 x 360日分 = 8640ノード時間（1セット）
- グループコース
  - 基本セット 50,000円（企業 60,000円）： 最大2048ノードまで  
トークン：1ノード x 24時間 x 360日分 = 8640ノード時間（1セット）
- 以上は、「トークン制」で運営
  - 大学等のユーザはOakbridge-CX, Reedbushとの相互トークン移行も可能

# GFLOPS (ピーク性能換算) あたり負担金 (~W)

| System   | JPY/GFLOPS |
|--|------------|
| Reedbush-U (HPE)<br>(Intel BDW)                              | 61.9       |
| Reedbush-H (HPE)<br>(Intel BDW+NVIDIA P100x2/node)           | 15.9       |
| Reedbush-L (HPE)<br>(Intel BDW+NVIDIA P100x4/node)           | 13.4       |
| Oakforest-PACS (Fujitsu)<br>(Intel Xeon Phi/Knights Landing) | 16.5       |
| Oakbridge-CX (Fujitsu)<br>(Intel Cascade Lake (CLX))         | 20.7       |

# トライアルユース制度について

- 安価に当センターのシステムが使える「**無償トライアルユース**」および「**有償トライアルユース**」制度があります
  - **アカデミック利用**
    - パーソナルコース、グループコースの双方（1ヶ月～3ヶ月）
  - **企業利用**
    - パーソナルコース（1ヶ月～3ヶ月）（RB-H, L: 最大4ノード、OFP: 最大16ノード、OBCX: 最大8ノード）  
**本講習会の受講が必須、審査無**
    - グループコース
      - 無償トライアルユース：（1ヶ月～3ヶ月）：無料（RB-H: 最大32ノード、RB-L: 最大16ノード、OFP: 最大2048ノード、OBCX: 最大256ノード）
      - 有償トライアルユース：（1ヶ月～最大通算9ヶ月）、有償（計算資源は無償と同等）
      - **スーパーコンピュータ利用資格者審査委員会の審査が必要（年2回実施）**
  - **双方のコースともに、簡易な利用報告書の提出が必要**
- **トライアルユース(無料体験):** 利用申請するシステムを初めて使う場合
  - **1ヶ月間、講習会アカウントと同条件**
  - **一般利用、有償トライアルユースへの移行も可能**

# スーパーコンピュータシステムの詳細

- <https://www.cc.u-tokyo.ac.jp/guide> をご覧ください
  - 利用申請方法
  - 運営体系
  - 料金体系
  - 利用の手引き