



東大情報基盤センターの目指す 『計算・データ・学習』の融合による 革新的スーパーコンピューティング



中島 研吾
東京大学情報基盤センター



PCCC22「HPCシステム技術の最前線」
2022年12月5日

東京大学情報基盤センター



東京大学情報基盤センター
INFORMATION TECHNOLOGY CENTER, THE UNIVERSITY OF TOKYO



東京大学
THE UNIVERSITY OF TOKYO

- 東京大学大型計算機センター(1965年)
- 東京大学情報基盤センター(1999年～)
 - 全国共同利用施設
 - 学際大規模情報基盤共同利用・共同研究拠点 中核拠点(2010年～)
 - 革新的ハイパフォーマンス・コンピューティング・インフラ(HPCI) 構成機関(2010年～)
 - 最先端共同HPC基盤施設(JCAHPC)(2013年～)
 - 筑波大学計算科学研究センター・東大情報基盤センター: OFP
- 2022年11月現在
 - 2式のスパコンシステムを運用
 - Oakbridge-CX(OBCX): 2023年9月末運用終了
 - Wisteria/BDEC-01(「計算・データ・学習」融合スーパーコンピュータシステム): 2021年5月運用開始
 - 大規模共通ストレージ「Ipomoea-01」: 2022年1月運用開始
 - データ活用社会創成プラットフォーム(mdx): 2021年3月設置



2001-2005	2006-2010	2011-2015	2016-2020	2021-2025	2026-2030
-----------	-----------	-----------	-----------	-----------	-----------

Hitachi SR8000
1,024 GF

Hitachi SR11000
J1, J2
5.35 TF, 18.8 TF

Hitachi SR16K/M1
Yayoi
54.9 TF

Hitachi SR2201
307.2GF

Hitachi SR8000/MPP
2,073.6 GF

OBCX
(Fujitsu)
6.61 PF

Hitachi HA8000
T2K Today
140 TF

Oakforest-PACS (Fujitsu)
25.0 PF

OFP-II
200+ PF

Fujitsu FX10
Oakleaf-FX
1.13 PF

Wisteria BDEC-01 Fujitsu
33.1 PF

BDEC-02
250+ PF


東京大学情報基盤
センターのスパコン
利用者2,600+名
55%は学外

Reedbush-U/H/L (SGI-HPE)
3.36 PF

Ipomoea-01 25PB

Ipomoea-03

Ipomoea-02




疑似ベクトル
汎用CPU
加速装置付

Ipomoea-02



Platform for Integration of (S+D+L)
Big Data & Extreme Computing



External Resources



External Network



External Resources



Simulation Nodes (Odyssey)



Data/Learning Nodes (Aquarius)



東京大学
THE UNIVERSITY OF TOKYO



東京大学情報基盤センター
INFORMATION TECHNOLOGY CENTER, THE UNIVERSITY OF TOKYO

Reedbush (HPE, Intel BDW + NVIDIA P100 (Pascal))

- 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
- 2016年7月～2021年11月末
- 東大ITC初のGPUクラスタ, ピーク性能3.36 PF (Reedbush-H/L)

Oakforest-PACS (OFP) (Fujitsu, Intel Xeon Phi (KNL))

- JCAHPC (筑波大CCS・東大ITC), 2016年10月～2022年3月末
- 25 PF, #39 in 58th TOP 500 (November 2021)

Oakbridge-CX (OBCX) (Fujitsu, Intel Xeon CLX)

- 2019年7月～2023年9月末 (予定)
- 6.61 PF, #129 in 60th TOP500 (November 2022)

Wisteria/BDEC-01 (Fujitsu)

- シミュレーションノード群 (Odyssey) : A64FX (#23)
- データ・学習ノード群 (Aquarius) : Intel Icelake + NVIDIA A100 (#125)
- 33.1 PF, 2021年5月14日運用開始
- 「計算・データ・学習 (S+D+L)」融合のためのプラットフォーム
- 革新的ソフトウェア基盤「h3-Open-BDEC」
(科研費基盤 (S) 2019年度～2023年度)



Reedbush



Oakforest-PACS




Oakbridge-CX

SC22における諸ランキング (2022年11月)



	Odyssey	Aquarius
TOP 500	23	125
Green 500	45	28
HPCG	12	68
Graph 500 BFS	4	-
HPL-MxP (HPL-AI)	10*	-

*) ISC 2022 (June 2022)



GFLOPS (ピーク性能) 当たり利用負担 (円) : 電気代 GFLOPS/W (Green 500) (2023年度から値上げ予定)

System	JPY/GFLOPS Small is Good	GFLOPS/W Large is Good
Oakleaf-FX/Oakbridge-FX (Fujitsu) (Fujitsu SPARC64 IXfx)	125	0.866
Reedbush-U (HPE) (Intel Xeon Broadwell (BDW))	61.9	2.310
Reedbush-H (HPE) (Intel BDW+NVIDIA P100x2/node)	15.9	8.575
Reedbush-L (HPE) (Intel BDW+NVIDIA P100x4/node)	13.4	10.167
Oakforest-PACS (Fujitsu) (Intel Xeon Phi/KNL)	16.5	4.986
Oakbridge-CX (Fujitsu) (Intel Xeon Cascade Lake)	20.7	5.076
Wisteria-Odyssey (Fujitsu/Arm A64FX)	17.8	15.069
Wisteria-Aquarius (Intel Xeon Ice Lake + NVIDIA A100x8)	9.00	24.058

2001-2005

2006-2010

2011-2015

2016-2020

2021-2025

2026-2030

Hitachi SR8000
1,024 GFHitachi SR11000
J1, J2
5.35 TF, 18.8 TFHitachi SR16K/M1
Yayoi
54.9 TFHitachi
SR2201
307.2GFHitachi
SR8000/MPP
2,073.6 GFOBCX
(Fujitsu)
6.61 PFHitachi HA8000
T2K Today
140 TFOakforest-
PACS (Fujitsu)
25.0 PFOFP-II
200+ PFFujitsu FX10
Oakleaf-FX
1.13 PFWisteria
BDEC-01 Fujitsu
33.1 PFBDEC-
02
250+ PFReedbush-
U/H/L (SGI-HPE)
3.36 PF

Ipomoea-01 25PB

Ipomoea-
03

Ipomoea-02

東京大学情報基盤
センターのスパコン
利用者2,600+名
55%は学外


大規模共通ストレージシステム「Ipomoea」

- スーパーコンピュータの処理能力の向上に伴い、扱うデータ量も増加の一途
- 東大センターでは従来ストレージは各システムに附属して導入され、各システムのストレージは独立
- このような状況（注：ストレージがシステム毎に独立）は利用者に多大な不便を強いることになり、東大センターの全システムからアクセス可能な共通ストレージの導入が強く求められていた
- 各システムからアクセスできる「大規模共通ストレージ（Ipomoea）」導入決定
 - OFP運用終了が契機
 - 1システムを約5-6年使用し、約3年ごとに新しいストレージシステム（25+PB）を導入し、入れ替えることを想定している



- 2022年1月運用開始・6月より一般に公開, 25+PB, 富士通製
 - 2022年5月末までにOFPのLustre領域の必要ファイルの移行完了
- 割当容量
 - 東大センターのシステムに利用者番号(教育利用, 講習会除く)を有する場合
 - 各利用者ごとに5TB
 - 各グループごとに登録システムで付与されている容量の15%を無償で付与
 - 追加負担金(企業はこの2割増し)
 - 7,200円/TB/年, 2,100,000円/PB/年
 - Ipomoea-01のみの利用申込みも可能

Ipomoea-01



mdx データ活用社会創成プラットフォーム

超スマート社会 Society 5.0 : AI, IoT, ビッグデータなどの革新技术を社会全体に活用し、サイバー空間（仮想）とフィジカル空間（現実）を高度に融合させた社会

持続可能な開発目標(SDGs) : 経済発展と社会的課題解決の両立



用途に応じてオンデマンドで短時間に**構築・拡張・融合**できるデータ収集・集積・解析機能を提供するプラットフォーム



3本柱

1 高性能計算環境によるデータ科学と計算科学の融合

データ科学、計算科学の手法を融合し、さらに国内最高の計算環境を用いて他に無い高精度の予測を行えるようにする

2 SINETを活かしたリアルタイム収集・集積・解析環境の動的な構築


遠隔地のセンサーやストレージ、データプラットフォームの計算資源、ストレージをつないで、リアルタイムに入力から出力を得られるアプリケーションごとの収集・集積・解析環境を、使いたいときに即時に構築する SINETモバイル基盤によりセンサー等のデータを安定してセキュアにつなぐ

3 異種データ・異種知識の融合活用の推進

様々な分野のデータ保持者、解析者、利用者が産学にまたがって連携するコミュニティーを形成し、新たな価値創造につなげる。

mdx データ活用社会創成プラットフォーム

- データ利活用・セキュリティを重視したクラウド型の高性能仮想化環境
- 9大学2研究所が共同運営し、全国共同利用



ネットワーク
 12つのネットワーク 外部接続ネットワーク
 SINET6と400G x2で接続
 内部高速ネットワーク RDMA
 ストレージ

汎用CPUノード
 Intel IceLake x2ソケット x368ノード
 理論ピーク性能(FP64): 2.1PFLOPS
 総メモリバンド幅: 150.7 TB/s

GPU 演算加速ノード
 Intel IceLake x2ソケット+NVIDIA A100 x8 x40ノード
 理論ピーク性能(FP64): 6.4PFLOPS
 理論ピーク性能(FP16): 100.7PFLOPS
 総メモリバンド幅: 496.3 TB/s

高速 NVMe ストレージ
 Lustre Filesystem
 1.0 PB (NVMe SSD)
 252 GByte/sec

大容量HDDストレージ
 Lustre Filesystem
 16.3 PB (HDD)
 157.5 GByte/sec

外部共有オブジェクトストレージ
 S3 Data Service
 10.3 PB (HDD)
 63.0 GByte/sec

スーパーコンピューティングの今後

ワークロードの多様化

- 計算科学, 計算工学: Simulations
- 大規模データ解析
- AI, 機械学習



(シミュレーション(計算) + データ + 学習) 融合

⇒ Society 5.0 実現に有効

- フィジカル空間とサイバー空間の融合

- S: シミュレーション(計算) (Simulation)
- D: データ(Data)
- L: 学習(Learning)

- Simulation + Data + Learning = S+D+L



(シミュレーション(計算)+データ+学習)融合(S+D+L)


- 東大情報基盤センターでは、2015年頃から「(S+D+L)融合」の重要性に注目し、それを実現するためのハードウェア、ソフトウェア、アプリケーション、アルゴリズムに関する研究開発を開始
 - BDEC計画(Big Data & Extreme Computing)
 - 「データ+学習」による、より高度な「シミュレーション」
 - AI for HPC, AI for Science
 - 地球科学関連では自然な発想(すでに実施されている)
- 2021年5月に運用を開始した「Wisteria/BDEC-01」は「BDEC計画」の1号機
 - Reedbush, Oakbridge-CXは「BDEC」のプロトタイプと位置づけられる
 - 「計算・データ・学習(S+D+L)」融合を実現する、世界でも初めてのプラットフォーム



Wisteria/BDEC-01

- 2021年5月14日運用開始
 - 東京大学柏Ⅱキャンパス
- 33.1 PF, 8.38 PB/sec., **富士通製**
 - ~4.5 MVA(空調込み), ~360m²
- Hierarchical, Hybrid, Heterogeneous (h3)
- 2種類のノード群**
 - シミュレーションノード群(S, SIM) : Odyssey**
 - 従来のスパコン
 - Fujitsu PRIMEHPC FX1000 (A64FX), 25.9 PF**
 - 7,680ノード(368,640コア), 20ラック, Tofu-D
 - データ・学習ノード群(D/L, DL) : Aquarius**
 - データ解析, 機械学習
 - Intel Xeon Ice Lake + NVIDIA A100, 7.2 PF**
 - 45ノード(Ice Lake:90基, A100:360基), IB-HDR
 - 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
- ファイルシステム: 共有(大容量) + 高速

BDEC:「計算・データ・学習(S+D+L)」
融合のためのプラットフォーム
(Big Data & Extreme Computing)



Wisteria
BDEC-01

Wisteria/BDEC-01

- 2021年5月14日運用開始
 - 東京大学柏Ⅱキャンパス
- 33.1 PF, 8.38 PB/sec., **富士通製**
 - ~4.5 MVA(空調込み), ~360m²
- Hierarchical, Hybrid, Heterogeneous (h3)
- 2種類のノード群**


シミュレーションノード群 (S, SIM) : Odyssey

- 従来のスパコン
- Fujitsu PRIMEHPC FX1000 (A64FX), 25.9 PF**
 - 7,680ノード(368,640コア), 20ラック, Tofu-D

データ・学習ノード群 (D/L, DL) : Aquarius

- データ解析, 機械学習
- Intel Xeon Ice Lake + NVIDIA A100, 7.2 PF**
 - 45ノード(Ice Lake:90基, A100:360基), IB-HDR
 - 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
- ファイルシステム: 共有(大容量) + 高速

BDEC:「計算・データ・学習(S+D+L)」
融合のためのプラットフォーム
(Big Data & Extreme Computing)



**Wisteria
BDEC-01**


Wisteria/BDEC-01

- 2021年5月14日運用開始
 - 東京大学柏Ⅱキャンパス
- 33.1 PF, 8.38 PB/sec., **富士通製**
 - ~4.5 MVA(空調込み), ~360m²
- Hierarchical, Hybrid, Heterogeneous (h3)
- 2種類のノード群**

- シミュレーションノード群(S, SIM) : **Odyssey**
 - 従来のスパコン
 - Fujitsu PRIMEHPC FX1000 (A64FX), 25.9 PF**
 - 7,680ノード(368,640コア), 20ラック, Tofu-D

- データ・学習ノード群(D/L, DL) : **Aquarius**
 - データ解析, 機械学習
 - Intel Xeon Ice Lake + NVIDIA A100, 7.2 PF**
 - 45ノード(Ice Lake:90基, A100:360基), IB-HDR
 - 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
- ファイルシステム: 共有(大容量) + 高速

BDEC:「計算・データ・学習(S+D+L)」
融合のためのプラットフォーム
(Big Data & Extreme Computing)



Wisteria
BDEC-01

Simulation Nodes

Odyssey

25.9 PF, 7.8 PB/s

Fast File System (FFS)
1.0 PB, 1.0 TB/s

Shared File System (SFS)
25.8 PB, 0.50 TB/s

Data/Learning Nodes

Aquarius

7.20 PF, 578.2 TB/s

計算科学コード

シミュレーション
ノード群, Odyssey

最適化されたモデル,
パラメータ

計算結果

Wisteria/BDEC-01

機械学習, DDA

データ・学習ノード群
Aquarius

観測データ

データ同化
データ解析



Wisteria
BDEC-01

サーバー
ストレージ
DB
センサー群
他



外部ネットワーク



外部
リソース

Simulation Nodes

Odyssey

25.9 PF, 7.8 PB/s


Fast File System (FFS)
1.0 PB, 1.0 TB/s

Shared File System (SFS)
25.8 PB, 0.50 TB/s

Data/Learning Nodes

Aquarius

7.20 PF, 578.2 TB/s



シミュレーションのためのモデル・パラメータのデータ解析, AI/機械学習による最適化 (S+D+L)



Wisteria
BDEC-01

h3-Open-BDEC


「計算+データ+学習」融合を実現する革新的ソフトウェア基盤
科研費基盤研究(S)(2019年度~23年度, 代表: 中島研吾)

<https://h3-open-bdec.cc.u-tokyo.ac.jp/>

Hierarchical,
Hybrid,
Heterogeneous

Big Data &
Extreme
Computing

- ① 変動精度演算・精度保証・自動チューニングによる新計算原理に基づく革新的数値解法
- ② 階層型データ駆動アプローチ等に基づく革新的機械学習手法
- ③ ヘテロジニアス環境 (e.g. Wisteria/BDEC-01) におけるソフトウェア, ユーティリティ群



AI for HPC, AI for Science の実現へ向けて



Odyssey-Aquarius連携

– MPIによる通信は不可

• O-Aを跨いでMPIプログラムは動かない

– Odyssey-Aquarius間はInfiniband-EDR (2TB/sec)で結合されている


ソフトウェア開発

– 高機能カプラー: h3-Open-UTIL/MP

– O-A間通信: h3-Open-SYS/WaitIO

• IB-EDR経由 (WaitIO-Socket)

• 高速ファイルシステム (FFS) 経由連携 (WaitIO-File)



External Resources

外部リソース

External Network
外部ネットワーク

h3-Open-BDEC

新しい計算原理
数値アルゴリズム・ライブラリ

シミュレーション+データ
+学習 (S+D+L)
アプリ開発フレームワーク

統合+通信+
ユーティリティ
制御 & ユーティリティ

h3-Open-MATH
高性能・高信頼性・
混合/変動精度アルゴリズム

h3-Open-APP:
Simulation
計算科学アプリケーション

h3-Open-SYS
制御 & 統合

h3-Open-VER
精度保証

h3-Open-DATA: Data
データ科学

h3-Open-UTIL
大規模計算向け
ユーティリティ群

h3-Open-AT
自動チューニング

h3-Open-DDA:
Learning
データ駆動・機械学習



h3-Open-SYS/WaitIO

データ受け渡しライブラリ[松葉, 2020]

[住元他, HPC-181, 2021]

- ヘテロジニアス環境下での異なるコンポーネント間ファイル経由連携ライブラリとして考案

機能

- ✓ Odysseus～Aquarius間連携
 - IB-EDR経由通信 (WaitIO-Socket)
 - ファイル経由 (WaitIO-File)
- ✓ 外部からのデータ取得 (観測データ等)
- ✓ 読み込み・書き出しの同期


- API: C/C++, Fortranから呼び出し可能

- ✓ MPIライクなインタフェースを提供



API of h3-Open-SYS/WaitIO-Socket PB (Parallel Block): Each Application

WaitIO API	Description
<code>waitio_isend</code>	Non-Blocking Send
<code>waitio_irecv</code>	Non-Blocking Receive
<code>waitio_wait</code>	Termination of <code>waitio_isend/irecv</code>
<code>waitio_init</code>	Initialization of WaitIO
<code>waitio_get_nprocs</code>	Process # for each PB (Parallel Block)
<code>waitio_create_group</code> <code>waitio_create_group_wranks</code>	Creating communication groups among PB's
<code>waitio_group_rank</code>	Rank ID in the Group
<code>waitio_group_size</code>	Size of Each Group
<code>waitio_pb_size</code>	Size of the Entire PB
<code>waitio_pb_rank</code>	Rank ID of the Entire PB





[Sumimoto et al. 2021]

連成シミュレーションのためのカプラー 〔荒川, 八代〕



- 従来のカプラー (Coupler) : ppOpen-MATH/MP
 - 複数 (通常2つ: 大気 (NICAM) + 海洋 (COCO)) のアプリケーションの弱連成 (Weak Coupling) をサポート
 - 各アプリケーションは1種類の計算をやる




「計算+データ+学習」融合を支援する 多機能カプラーh3-Open-UTIL/MP



- 異なる物理モデル連成のアンサンブル実行を支援・統合するための機能
 - MPI通信、時刻同期、格子系間マッピング等の管理機能の他、従来のカプラーには無い、複数の弱連成結合シミュレーションのアンサンブル実行、片側のモデルのみをアンサンブル実行する多対1の弱連成結合が可能
 - スパコン上で、全地球大気海洋連成シミュレーションによって動作検証済み
- Fortran/Cコード(物理モデル)とPythonコードの弱連成を実現する機能

FortranやCで記述されたプログラム同士の連成計算に限って開発を行ってきたカプラーを、Pythonによって記述されたAI・機械学習、可視化処理系のワークロードから活用できるように機能拡充。




Fortran/CアプリとPythonアプリの連成計算の模式図
〔八代・荒川 2020〕

h3-Open-UTIL/MP (h3o-U/MP) + h3-Open-SYS/WaitIO-Socket



ARM: A64FX



A huge amount of
simulation data
output

HPC App
(Fortran)

h3o-U/MP

IceLake+A100

Analysis/ML
App
(Python)

F<->P adapter

h3o-U/MP

Surrogate
Model

Visualization

Statistics

Coupling

IB-EDR



**Wisteria
BDEC-01**

Odyssey



**Wisteria
BDEC-01**

Aquarius

h3-Open-UTIL/MP




h3-Open-SYS/WaitIO-Socket連携

2022年6月から利用可能

2022年度はFS経由のWaitIO-File整備: 名大



**Wisteria
BDEC-01**



2021年4月: MPI通信可能な環境を前提

2022年6月: Coupler + WaitIO

解説記事 : h3-Open-UTIL/MP・ h3-Open-SYS/WaitIO-Socket



- h3-Open-UTIL/MP


- https://www.cc.u-tokyo.ac.jp/public/VOL24/No3/13_202205-Wisteria-2.pdf
- <http://nkl.cc.u-tokyo.ac.jp/files/202207UtilMPfinal.pdf>





- h3-Open-SYS/WaitIO-Socket

- https://www.cc.u-tokyo.ac.jp/public/VOL24/No2/10_202203Wisteria-1.pdf
- https://www.cc.u-tokyo.ac.jp/public/VOL24/No3/12_202205-Wisteria-1.pdf






リアルタイムデータ同化＋ 3D強震動シミュレーション融合 JDXnetによるリアルタイム観測データ活用



[c/o Prof. T.Furumura (ERI/U.Tokyo)]

長周期地震動シミュレーション＋観測データ同化



Communications by WaitIO-Socket

[Kasai et al. 2021]


Aquarius: SEND

```
program dmy_filter
<省略: 型宣言等>
call mpi_init (ierr)
call mpi_comm_size (MPI_COMM_WORLD, nprocs, ierr)
call mpi_comm_rank (MPI_COMM_WORLD, myrank, ierr)
call WAITIO_CREATE_UNIVERSE (WAITIO_COMM_UNIVERSE, ierr)

if (myrank==0) then
open(100,file='./obsfile_list.txt', form='formatted', status='old', iostat=ierr)
do i=1,300
<省略: obsデータ読み込み処理>
print *, "Send obs data ....."
call WAITIO_MPI_ISEND (NTMAX1_o, 1, WAITIO_MPI_INTEGER, 2,1, WAITIO_COMM_UNIVERSE, req(1,1), ierr)
call WAITIO_MPI_ISEND (DT_o, 1, WAITIO_MPI_FLOAT, 2,2, WAITIO_COMM_UNIVERSE, req(1,2), ierr)
call WAITIO_MPI_ISEND (NST_o, 1, WAITIO_MPI_INTEGER, 2,3, WAITIO_COMM_UNIVERSE, req(1,3), ierr)
call WAITIO_MPI_ISEND (AT_o, 1, WAITIO_MPI_INTEGER, 2,4, WAITIO_COMM_UNIVERSE, req(1,4), ierr)
call WAITIO_MPI_ISEND (T0_o, 1, WAITIO_MPI_FLOAT, 2,5, WAITIO_COMM_UNIVERSE, req(1,5), ierr)
call WAITIO_MPI_ISEND (ISO_X_o, NSMAX, WAITIO_MPI_INTEGER, 2,6, WAITIO_COMM_UNIVERSE, req(1,6), ierr)
call WAITIO_MPI_ISEND (ISO_Y_o, NSMAX, WAITIO_MPI_INTEGER, 2,7, WAITIO_COMM_UNIVERSE, req(1,7), ierr)
call WAITIO_MPI_ISEND (ISO_Z_o, NSMAX, WAITIO_MPI_INTEGER, 2,8, WAITIO_COMM_UNIVERSE, req(1,8), ierr)
call WAITIO_MPI_ISEND (ISTX_o, NST, WAITIO_MPI_INTEGER, 2,9, WAITIO_COMM_UNIVERSE, req(1,9), ierr)
call WAITIO_MPI_ISEND (ISTY_o, NST, WAITIO_MPI_INTEGER, 2,10, WAITIO_COMM_UNIVERSE, req(1,10), ierr)
call WAITIO_MPI_ISEND (ISTZ_o, NST, WAITIO_MPI_INTEGER, 2,11, WAITIO_COMM_UNIVERSE, req(1,11), ierr)
call WAITIO_MPI_ISEND (STC_o, 6*NST, WAITIO_MPI_INTEGER, 2,12, WAITIO_COMM_UNIVERSE, req(1,12), ierr)
call WAITIO_MPI_ISEND (VxAll_obs, NST*NOBS_LEN, WAITIO_MPI_FLOAT, 2,13, WAITIO_COMM_UNIVERSE, req(1,13), ierr)
call WAITIO_MPI_ISEND (VyAll_obs, NST*NOBS_LEN, WAITIO_MPI_FLOAT, 2,14, WAITIO_COMM_UNIVERSE, req(1,14), ierr)
call WAITIO_MPI_ISEND (VzAll_obs, NST*NOBS_LEN, WAITIO_MPI_FLOAT, 2,15, WAITIO_COMM_UNIVERSE, req(1,15), ierr)
call WAITIO_MPI_WAITALL (15, req, status, ierr)
call sleep(1)
enddo
close (100)
endif
call WAITIO_FINALIZE (ierr)
call mpi_finalize (ierr)
end
```

Odyssey: RECV



```
call WAITIO_MPI_RECV (NTMAX1_o, 1, WAITIO_MPI_INTEGER, 0,1, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (DT_o, 1, WAITIO_MPI_FLOAT, 0,2, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (NST_o, 1, WAITIO_MPI_INTEGER, 0,3, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (AT_o, 1, WAITIO_MPI_FLOAT, 0,4, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (T0_o, 1, WAITIO_MPI_INTEGER, 0,5, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (ISO_X_o, NSMAX, WAITIO_MPI_INTEGER, 0,6, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (ISO_Y_o, NSMAX, WAITIO_MPI_INTEGER, 0,7, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (ISO_Z_o, NSMAX, WAITIO_MPI_INTEGER, 0,8, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (ISTX_o, NST, WAITIO_MPI_INTEGER, 0,9, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (ISTY_o, NST, WAITIO_MPI_INTEGER, 0,10, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (ISTZ_o, NST, WAITIO_MPI_INTEGER, 0,11, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (STC_o, 6*NST, WAITIO_MPI_INTEGER, 0,12, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (VxAll_obs, NST*NOBS_LEN, WAITIO_MPI_FLOAT, 0,13, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (VyAll_obs, NST*NOBS_LEN, WAITIO_MPI_FLOAT, 0,14, WAITIO_COMM_UNIVERSE, ...)
call WAITIO_MPI_RECV (VzAll_obs, NST*NOBS_LEN, WAITIO_MPI_FLOAT, 0,15, WAITIO_COMM_UNIVERSE, ...)
```



Atmosphere-ML Coupling

[Yashiro (NIES), Arakawa (ClimTech/U.Tokyo)]


- Motivation of this experiment
 - Two types of Atmospheric models: Cloud resolving VS Cloud parameterizing
 - Cloud resolving model is difficult to use for climate simulation
 - Parameterized model has many assumptions
 - Replacing low-resolution cloud processes calculation with ML!



Experimental Design


- Atmospheric model on Odyssey
 - NICAM : global non-hydrostatic model with an icosahedral grid
 - Resolution : horizontal : 10240, vertical : 78
- ML on Aquarius
 - Framework : PyTorch
 - Method : Three-Layer MLP
 - Resolution : horizontal : 10240, vertical : 78
- Experimental design
 - Phase1: PyTorch is trained to reproduce output variables from input variables of cloud physics subroutine.
 - Phase2: Reproduce the output variables from Input variables and training results
- Training data
 - Input : total air density (ρ), internal energy (e_{in}), density of water vapor (ρ_q)
 - Output : tendencies of input variables computed within the cloud physics subroutine

$\frac{\Delta \rho}{\Delta T}$	$\frac{\Delta e_{in}}{\Delta T}$	$\frac{\Delta \rho_q}{\Delta T}$
--------------------------------	----------------------------------	----------------------------------



Test calculation

- Compute output variables from input variables and PyTorch
 - The rough distribution of all variables is well reproduced
 - The reproduction of extreme values is no good



Examples of Scripts [Sumimoto, Arakawa]

Odyssey for Simulation

```
#!/bin/bash
#PJM -N "test_waitio"
#PJM -L rscgrp=coupler-lec-o
#PJM -L node=10:noncont
#PJM --mpi proc=80
#PJM -L elapse=00:10:00
#PJM -g gt00
#PJM -j
#PJM -e err

module load fj
module load fjmpi
module load waitio

export WAITIO_MASTER_HOST=`hostname`
export WAITIO_MASTER_PORT=7100
export WAITIO_PPID=0
export WAITIO_NPB=2

hostname
waitio-serv-a64fx -d -m $WAITIO_MASTER_HOST

#mpiexec -oferr-proc errnicam -np 160 ./nicam
mpiexec -np 80 ./nicam
```

Aquarius for AI

```
#!/bin/bash
#PJM -N "test_waitio"
#PJM -L rscgrp=coupler-lec-a
#PJM -L node=1
#PJM --mpi proc=10
#PJM -L elapse=00:10:00
#PJM -g gt00
#PJM -j
#PJM -e err

module unload aquarius
module unload gcc omp
module load intel
module load impi
module load waitio

export WAITIO_MASTER_HOST=`waitio-serv -c`
export WAITIO_MASTER_PORT=7100
export WAITIO_PPID=1
export WAITIO_NPB=2

module unload intel
module unload impi
module load gcc omp

mpiexec -n 10 ./ada
```

Lessons Learned & Future

SC22 BoF 131

Disaggregated Heterogeneous Architectures




- **Software (h3-Open-BDEC: WaitIO, Coupler) enabled integration of (S+D+L) on Odyssey-Aquarius**
 - **WatiIO-Socket/File**
 - **Job Submission System**
- Policy for Operation
 - Current status is preliminary, Very few workloads for (S+D+L)
 - More flexible (& complicated) policy needed
- **Please contact us at nakajima@cc.u-tokyo.ac.jp if you are interested in installing and using our software on your systems !**
 - **to be installed at systems of Nagoya U. and Kyushu U.**
- Publication
 - Shinji Sumimoto, et al. PDCAT'22, Dec.7-9, 2022 (in press)
 - <https://www.hpc.is.tohoku.ac.jp/pdcat2022/>




h3-Open-SYS/WaiIO-Socket

- Wisteria/BDEC-01
 - Aquarius (GPU: NVIDIA A100)
 - Odyssey (CPU: A64FX)
- Combining Odyssey-Aquarius
 - Single MPI Job over O-A is impossible
- **Connection between Odyssey-Aquarius**
 - **IB-EDR with 2TB/sec.**
 - **Fast File System**
 - **h3-Open-SYS/WaiIO-Socket**
 - Library for Inter-Process Communication through IB-EDR with MPI-like interface



h3-Open-SYS/WaiIO-File


- Wisteria/BDEC-01
 - Aquarius (GPU: NVIDIA A100)
 - Odyssey (CPU: A64FX)
- Combining Odyssey-Aquarius
 - Single MPI Job over O-A is impossible
- **Connection between Odyssey-Aquarius**
 - **IB-EDR with 2TB/sec.**
 - **Fast File System**
 - **h3-Open-SYS/WaiIO-File**
 - **Library for Inter-Process Communication through FFS with MPI-like interface**



Preliminary Evaluation: WaitIO-Socket, -File

- Odyssey-Aquarius, Flow (Nagoya University)
- Test Cases
 - Model A: 160 proc's/40 nodes: A64FX (Odyssey, Flow I)
 - Model B: 20 proc's/1 node: Intel Xeon (Aquarius, Flow II)
 - Waitio_isend/irecv/wait


Case	Grid #	Total Size
C0	81,920	26,214,400
C1	163,840	52,428,800
C2	327,680	104,857,600
C3	655,360	209,715,200
C4	1,310,720	419,430,400




Results

- “Socket” is better for small cases, “File” is better for large ones
- “Flow” with WaitIO-Files is 2x slower than Odyssey-Aquarius
 - Reasonable Number


Down is good!



長周期地震動シミュレーション＋観測データ同化



Webベース シミュレーション体験・ データ利活用システム mdxとの連携事例





- 「3D長周期地震動+リアルタイムデータ同化」融合シミュレーションシステムの「防災・減災」啓蒙・教育へ向けた利用・展開を図るため、Webベースのシミュレーション体験・データ利活用環境を構築(2022年度)
- 利用者はWeb Server(mdx上)にアクセスし、スパコン(Wisteria/BDEC-01)上でのシミュレーションの実施、計算結果、観測結果の可視化処理、表示等を行う。
- Web経由でデータ群をスパコン上で処理するフレームワークは様々なアプリケーションへの転用が可能



mdxからWeb経由で大規模シミュレーション・データ同化をインタラクティブに実行

(A+S) Assimilation+Simulation

(Pure S) Pure Simulation/Forecast





Chuetsu offshore earthquake, 2007



将来構想: OFP-II, Mercury

- スパコンへの性能要求, 省電力, 脱炭素化⇒演算加速器搭載は不可避
- Wisteria-Mercury (2023年11月～)
 - GPUクラスタ
 - OFP-IIプロトタイプ
- OFP-II (2024年4月)
 - OFP後継機 (JCAHPC: 筑波大学と共同), 200+PF
 - GPUクラスタ
 - Mercuryと同じ, もしくはその後継GPU
 - CPU Onlyノード群あり (GPUホストと異なる可能性)
- アプリケーションの移植が必要 (3,000人)
 - 講習会, GPUミニキャンプによる対応



2001-2005

2006-2010

2011-2015

2016-2020

2021-2025

2026-2030

Hitachi SR8000
1,024 GFHitachi SR11000
J1, J2
5.35 TF, 18.8 TFHitachi SR16K/M1
Yayoi
54.9 TFHitachi
SR2201
307.2GFHitachi
SR8000/MPP
2,073.6 GFHitachi HA8000
T2K Today
140 TFOBCX
(Fujitsu)
6.61 PFOakforest-
PACS (Fujitsu)
25.0 PFOFP-II
200+ PFFujitsu FX10
Oakleaf-FX
1.13 PFWisteria
BDEC-01 Fujitsu
33.1 PFBDEC-
02
250+ PFReedbush-
U/H/L (SGI-HPE)
3.36 PF

Mercury

Ipomoea-01 25PB

Ipomoea-
03

Ipomoea-02

東京大学情報基盤
センターのスパコン
利用者2,600+名
55%は学外

スケジュール概要



筑波大学
University of Tsukuba



東京大学
THE UNIVERSITY OF TOKYO

Mercury & OFP-II

- GPU移行のための諸作業は遅くとも、2022年秋に始める必要がある
- それ以前にMercury・OFP-IIに搭載するGPU(両者は同じ)を決める必要あり
- 2022年2月～3月
 - プリベンチマークを各社に依頼(計算科学系7種類, Fortran, C)
- 2022年6月
 - GPUベンダーを決定
 - ポイント:性能, ポーティングのしやすさ, サポート体制, Fortranへの対応
- 2022年秋～
 - ポーティング開始, 当初はAquariusをプラットフォームとして使用(多分12月頃)
 - OFP-II資料招請開始(2022年11月8日:導入説明会)
- 2023年秋～
 - Mercuryを使用した最適化, 評価
- 2024年4月:OFP-II運用開始

MPI+OpenMPで並列化されたFortranプログラムのGPUへの移行手法(オンライン)

<https://www.cc.u-tokyo.ac.jp/events/lectures/196/>

趣旨

- 本講習会ではOFP-IIへのプログラム移植に向け、既存のMPI+OpenMPでCPU向けに並列化されたFortranプログラムのGPU環境への移植手法を学ぶ
- 受講料は無料
- GPUへの移行は基本的にOpenMP(CPU向け)で並列化されたループを対象として実施
- GPU向けのループ並列化の手段としてはOpenACC, OpenMP 5.x, do concurrent, CUDA Fortranなど様々であるため、それぞれの特徴や使い方を学ぶ
- Wisteria/BDEC-01(Aquarius)を活用し、OpenMPでCPU向けに並列化された有限要素法のプログラムを題材とした、GPUへの移植の演習を行う

12月7日午後開催(オンライン)(申込締切:11月30日!!)

GPUミニキャンプ(オンライン)(1/2)

<https://www.cc.u-tokyo.ac.jp/events/lectures/197/>

• ミニキャンプとは？

- 参加者がコードやデータセットを持ち込み、CUDA、OpenACC、Deep Learning など、GPUに関連した課題に対して、メンターからの助言を受けながら、その課題解決に取り組みます。

• メンター

- エヌビディア合同会社、東大情報基盤センターなどから参加し、参加者の課題解決にご協力します。



• 次回は12月12日～19日に実施(申込締切:11月30日!!)

- 各チームで実践中は、ベストエフォートでメンターがQ&A対応
- 年度内にもう1回、来年度は4回以上実施の予定

GPUミニキャンプ(オンライン)(2/2)

<https://www.cc.u-tokyo.ac.jp/events/lectures/197/>

- 実施形式
 - Zoom と Slack を使ったオンライン形式
- 参加資格
 - 国公立大学・高専の教員・学生・研究生
 - 研究機関研究員
 - 企業に所属する研究者・技術者(非営利目的に限る)
 - 作業に必要なコードおよびデータセット等をセンターに持ち込める方。
 - コマンドラインによるLinux上での作業やエディタ利用に支障のない方
- 2022年度は、企業利用に発展した事例もあり