

mdx:データ活用社会創成プラットフォームの紹介



小林博樹
東京大学



Hokkaido University



Cyberscience Center




CENTER FOR ARTIFICIAL INTELLIGENCE RESEARCH



GSIC
Global Scientific Information and Computing Center

小林博樹 名古屋大学 情報基盤センター




Cybermedia Center
Osaka University



自己紹介

- 現職 東京大学
 - (本務) 情報基盤センター データ科学研究部門 部門長
 - (兼任) 空間情報科学研究センター (本務 ~2020/3)
- 専門分野
 - 情報デザイン、センサネットワーク (動物向け)、サウンドスケープ
- 趣味
 - 環境音を聴いて、動物の表情を見て、(面白い) 吹き出しを考えること。



東京大学情報基盤センター



- 4研究部門
 - 情報メディア教育
 - データ科学
 - ネットワーク
 - スーパーコンピューティング
- 全学・全国ミッション
 - キャンパスネットワーク
 - セキュリティ
 - 高性能計算機
 - 教育用環境




全国の大学の情報基盤（的）センター について

- 多くのセンターが
 1. 情報（主に基盤的）分野の研究
 2. 学内利用の情報基盤（ネットワーク、教育など）
 - 例えばオンライン授業のためのIT導入...
 3. 全国利用の情報基盤（スパコンなど）、それをハブにした学際研究（情報 x ○○学）を三軸とする点で共通
- 3. のため国の「**共同利用・共同研究拠点**」という仕組みで8大学のセンターが共同して拠点を運営している

8大学が連携して運営する共同利用・共同研究拠点（JHPCN）について


- 8大学の基盤センターで共同運営する共同研究の基盤
 - 北大、東北大、東大、東工大、名大、京大、阪大、九大
- 全国から共同研究を募集
 - 採択された課題に計算設備利用時間（主にスパコン利用時間）を割り当て
 - 現在シミュレーション中心の計算科学分野が多く集まる
 - 企業利用も受け付けています



基盤センターと拠点の使命


- 情報の専門家と情報基盤を提供
- 情報学 x ○○学 (学際貢献)
- コミュニティ形成

今日の話はこの思想をこれまでのシミュレーション中心・計算科学から、**分野も基盤もセクターも**「データ中心」に広げるための**構想の紹介**




データ科学・利活用を取り巻く状況

- データが重要な資産（研究、ビジネス、公共政策、など様々なセクターで）




データ科学・活用の潮流・ドライバ

- 機械学習 (ML) ・ AI、ツールの発展 (MLの「民主化」)




- 社会応用に直結するデータの整備



- センサ (IoT) データ、実時間応用



- シミュレーション+AI (計算手法)



必要なこと

- データ科学・活用は常に分野やセクタをまたがる横断的な活動
- 1-1の共同では済まないこともしばしば

このデータでこんなことがわかるはずだがプログラミングできる学生が...

このデータ、価値を生みそうだけど具体的には?

これらを触媒する仕組み

とある分野研究者A

とある企業事業部

アルゴリズムはできたけど問題
定これでいいのかな?

年OPBのデータを蓄積・バックアップするストレージの運用とかどうする?


実データはどこ? このフィールドの意味は?

とある分野研究者B

とある情報研究者

研究事例の例：電源・情報・道路インフラが存在しない未除染・高線量地帯に生息する野生動物IoTを用いた環境・健康情報センシング（帰還困難区域内）

<http://www.town.namie.fukushima.jp/soshiki/2/namie-factsheet.html>




被曝動物の健康情報（鳴き声）の変化の可視化9000時間分



プロジェクト用に整備されたシンクノード基盤・電柱・通信回線
NII SINET広域データ収集基盤 実証実験



野生動物IoTの評価実験中の様子




収集・通信・解析

モバイル

ビッグデータ

リアルタイム（+安定性）



今この瞬間の帰還困難区域の音が聴こえるWEBサイト

以降の話

- データ活用社会創成プラットフォーム
- mdx
- mdxのシステムとしての特徴
- 利用・共同研究・産官学連携の進め方
- パイロットプログラム

(政策的文脈) データ活用社会創成プラットフォーム

- データ科学・データ活用の {研究、産官学連携、社会実装} を進めるための取り組み
- 有識者会合による方向付け
- 2研究所 (NII,AIST) + 9大学 (北大、東北大、筑波大、東大、東工大、名古屋大、京大、阪大、九大) で離陸
- JHPCNが中心的役割を果たすが、それ以上にコミュニティ (ユーザ・基盤側とも) を広げる



大学・研究機関等の情報基盤インフラ整備・活用例

データ活用社会創成プラットフォーム

- ◆ SINETを通じて、全国のデータ収集・通信・解析環境をオンデマンドで活用。
- ◆ 高度・多様なデータ利活用により新たな価値を創出。

国際連携

国際連携施設

SINET
国際回線



大型実験施設・観測器等



スパコン・研究基盤群




実験施設等共同利用

学術情報

学術情報クラウド基盤

オープンアクセス

オープンサイエンス



情報発信・共有

クラウド



各研究分野の連携力強化

地方創成・産学連携

SINET専用仮想網

SINET結合VPN設定機能

自然保護 地域 広範囲
地域 コミュニティ エリア
遠隔地 海上


- : SINETノード
- : 400Gbps (2019年12月運用開始)
- : 100Gbps(国内)
- : 100Gbps(海外)

	国立 大学	公立 大学	私立 大学	短期 大学	高等専門 学校	大学共同 利用機関	その他	合計
加入 機関数	86 (100%)	83 (90%)	398 (66%)	80 (25%)	56 (99%)	16 (100%)	191	910

(2019年3月31日現在)

コミュニティ形成・発展

- プラットフォーム = コミュニティ
 - マシンやデータレポジトリ（だけ）のことではない！
- データ科学・活用での、分野・セクタを横断した連携を触媒するハブとなることを目指す



以降の話

- データ活用社会創成プラットフォーム
- mdx
- mdxのシステムとしての特徴
- 利用・共同研究・産官学連携の進め方
- パイロットプログラム

mdx とは

データ{活用・科学}のための基盤

- 「単一OS環境 + バッチスケジューラ」では済まない
 - 分野データプラットフォームのホスティング（連続稼働）
 - 多様なソフトウェア構成の許容
 - 長年にわたるデータの蓄積・利用
 - 高いデータセキュリティ・隔離への要求
- ユーザが標準（常識）と考える環境も異なる
 - 機械学習フレームワーク、コンテナ
 - JupyterLabなどWebベース対話的利用（AI, 機械学習）
 - データ検索・発見のための利用
 - IoT・ストリーム・データ収集など広域・実時間処理
- 多数のデータ・システムの連携が前提（1システムでは完結しない）



mdx 特徴



- 2020年度内（末）稼働 @ 東大 柏IIキャンパス
- 仮想化された（複数テナント）環境
- 計算ノード
 - 350+ CPUノード
 - 300+ GPUs
- ストレージ
 - 15+PB（含 NVMe SSD 1PB）ファイルシステム Lustre Multi-tenant拡張
 - 10PB S3オブジェクトストレージ
- 高性能な仮想化されたネットワーク
 - SR-IOV, PVRDMA



mdx

仮想プラット
フォーム




モバイル
SINET

パブリック
クラウド



インターネット



共有オブジェク
トストレージ

セキュア・
高速ストレージ
小林博樹




AIST ABCI



Supercomputers
(BDEC etc.)


仮想プラットフォーム

- 仮想マシンとVPNを用いて互いに隔離された「疑似占有環境」
- 柔軟性
 - 各プラットフォームごとに自由に（管理者権限で）環境設定可能
 - 常時稼働が必要なデータ公開サービスなどを運用可能
- セキュリティ
 - ひとつの仮想プラットフォームが侵入を受けても他へ影響しない




SINET・モバイルSINETとの接続

- 仮想プラットフォーム用のVPNをSINETへ延伸可
- 他のSINETサイト（大学・研究機関）やモバイルSINETとセキュアに接続可能
- とくにIoTデバイスのセキュリティ確保に有用



資源の割り当て方

- 各機関（9大学+2研究所）に一定量の資源配分権を割り当て
- 各機関でそれを利用したユーザ獲得に使っていただく



データ連携

-  **GakuNin** 学認
 - 大学をまたがる認証基盤
-  **GakuNin RDM** GakuNin RDM
 - 研究データ管理
 - データのカタログ化、共有・公開設定
 - 外部クラウド・S3ストレージとの連携機能
-  **mdx** 両者を用いて
 - 研究者がサインアップし、**すぐに**使い始められる環境
 - データの検索から、ブラウザベース処理、高性能処理までをシームレスに実行できる環境

様々な関わりレベル利用者・利用法


- データ検索レポジトリとしての利用
- Webブラウザベースのお手軽データ解析・AI環境としての利用 (cf. Kaggle, Tellus)
- 高性能計算・データ処理環境としての利用
- (主に個人研究者・小規模グループ) 中規模データや学習モデル共有ストレージとしての利用
- (主に組織) 大規模データ収集&データプラットフォームホスティング環境としての利用 (cf. DIAS)
- システム研究のための (仮想化を生かした) 自由度の高い環境

利用募集の外形・運用について

- データ検索や少数ノード利用：統一認証基盤などを用い申請書なし・迅速な利用を可能に
- 大規模、本格的な利用：一定の審査
 - ただし新しいユーザ層・分野にリーチする必要性などから当初は現行のJHPCN課題申請ほど厳格な審査は行わない予定
 - 審査基準も現行とは変える必要がある
 - 複数年での利用を可能に
- 戦略的なパートナーシップに基づく利用
 - mdx参画の各機関の裁量を重んじつつ全体で決定・承認
- 当初は（おそらく）課金はしない
 - 並行して将来的な新しい課金モデルを検討
 - 「ストレージの占有量に応じて」というモデルは再考

多様な利用・連携を歓迎・追及

- データ活用課題持ち込み（分野の、地方の、企業の、...）
- 分野データの整備・プラットフォーム構築
- データ提供・サービス（収益）化模索（⇒ 商用クラウドへ展開）
- 高性能AI・機械学習
- 基盤技術・システム研究・開発
- ...



目指すのはセンターマシンの新しい標準形

- データがシステムを横断して検索でき、見つかったデータがどのマシンでもすぐに処理可能
 - 個々のセンター = マシン + データ
 - データは（たとえばGakuNin RDMで）見つかる
 - データを特定の人、グループと共有できる
 - ストレージやアクセス方法に依存する（チャレンジ）
 - 見つかったデータがどのセンターマシンでも処理できる
 - SINETの広帯域を生かす
 - ストレージの耐負荷性能、長距離広帯域ネットワーク上のストレージ性能などチャレンジ

まとめ

- データ科学・データ活用の {研究、産官学連携、社会実装} を進めるための取り組み。mdxはそのための基盤
- NII, AISTと9大学 (北大、東北大、筑波大、東大、東工大、名大、京大、阪大、九大) は共同で、
 - データ科学・活用のための基盤 mdx を導入
 - 共同研究・産官学連携の仕組みを運用
- mdx ≈
 - 仮想プラットフォーム
 - VPNでの隔離
 - セキュアIoT (モバイルSINET)
 - 高性能計算機・ストレージ
- 共同研究・連携募集 ≈
 - 課題持ち込み
 - 分野プラットフォーム構築
 - データ提供
 - 基盤技術研究
 - etc. など広く募集

多くの方々 (情報系・非情報系・産・官・学) の参加・協力をあおぎながら進めていきます
データを持つ人
活用する人
システムを作る人

ご清聴ありがとうございました

- 以下は参考情報

SINET 5・モバイルSINET

- SINET 5（有線）
 - 全都道府県にノード
 - ノード間は $\geq 100\text{Gbps}$
 - 冗長経路
 - 広域VPN（L3/L2）
- モバイルSINET（広域データ収集基盤）
 - SINET VPNに直結できるモバイル環境

