mdx: データプラットフォームについて

東京大学 情報基盤センター 田浦健次郎

Hokkaido University
2020/09/01

スマートIoT推進フォーラム

名古屋大学 情報基盤センター
産総研 産学連携分科会

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

GPS 気象 衛星

公共交通 医療行為 道路・インフラ

- 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

以降の話

- データ活用社会創成プラットフォーム
- mdx
- 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

(背景) 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

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

「情報系アカデミア」の役割

- **ヒト**：情報系専門（特に若い研究者・学生）の知と腕を提供
- **ハコ**：研究開発・非営利目的への廉価な計算・ストレージ資源を提供
- **データ**：巨大パブリックデータや利用目的限定データへのアクセスを促進

mdx 参画機関の役割

- mdx参画機関 = 基盤センター + NII + AIST
 ◦ データ科学系アカデミア ◦ 情報系アカデミア
- 情報系研究者の参加（ヒト）をmdx参画機関外からも広く募る
- 将来：全国的なマッチングハブを目指す

データ{活用・科学}のための環境

- 「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 スペック

- 本年度内（末）稼働
- 詳細変更の可能性あり
- 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+ GPU_s
- 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

mdx

共有オブジェク
トストレージ

AIST ABCI

Supercomputers
(BDEC etc.)

セキュア・
高速ストレージ

2020/09/01

スマートIoT推進フォーラム
テストベッド分科会

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

データ連携の基盤

- **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

想定利用者・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

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
- ...

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
- 組織レベルの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

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

- NII, AISTと8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

- 以下は参考情報

参考

- データ活用社会創成プラットフォームについて
 - <https://www.itc.u-tokyo.ac.jp/wp-content/uploads/2019/06/45079c24b24f942f050753afe7383c6.pdf>
- データ活用社会創成プラットフォーム
 - <https://www.itc.u-tokyo.ac.jp/wp-content/uploads/2019/02/dd70658fb1895375ac996ec257181671.pdf>