

モデル駆動型システムズエンジニアリングに基づくモデル管理 およびデータ解析 —Nano-JASMINEデータ解析への適用—

○初鳥陽一、宮下尚、清水淳也(日本IBM)、山田良透(京都大学)



研究背景

大規模・複雑化するデータ解析における問題点と、そのソリューション

科学者(user)の要求

- 膨大なデータの効率的な解析
- 複数の学問領域にまたがる解析
- 様々な解析手法の適用
- 他のプロジェクトへの応用



解析担当者(vendor)の作業

- 効果的なコードの実装
- 複雑なモデルの実装
- モデルの管理
- 汎用的なコードの生成



問題の大規模・複雑化に伴い
情報共有・分散処理が重要な課題

ソリューション

モデル駆動型システムズエンジニアリングによる管理および解析 Model-based System Identification Cloud (MbSIC) の提案



【ソリューション】
システムズモデルによる
モデル管理

コード生成

【ソリューション】
MapReduce & GPGPUによる
分散処理系の構築
特徴ごとに行列を分割・格納形式
の選択

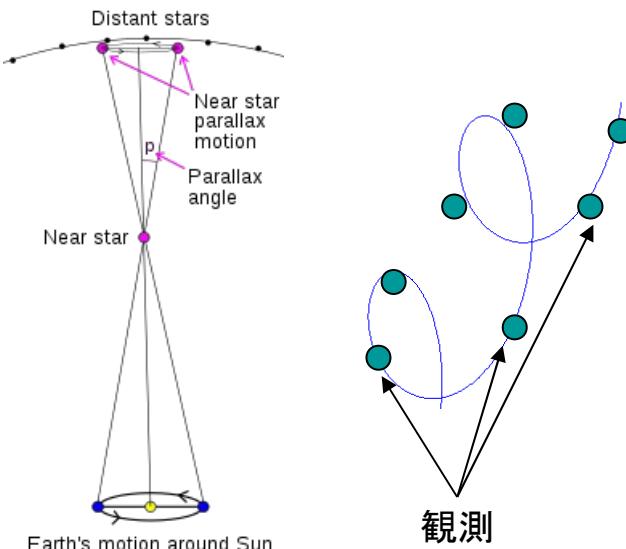
大規模・複雑なデータ解析の例

JASMINE計画(Japan Astrometry Satellite Mission for Infrared Exploration)

銀河系内の、特に銀河面、バルジなどのサーベイを行ない、数億個の星の位置・距離・固有運動を高精度に測定(位置天文学)

JASMINE計画では、3種類の衛星が検討・開発中

- Nano-JASMINE 口径5cm zw-band 全天を観測 フライトモデル完成 2013年打ち上げ
- Small-JASMINE 口径30cm Hw-band バルジ方向を観測 検討中
- JASMINE 口径80cm Kw-band バルジ方向を観測 検討中



JASMINE計画での観測のイメージ図
複数の観測結果から、螺旋のパラメータを推定

JASMINE計画でのデータ解析

星の固有運動と、地球の公転運動に起因する橈円運動により、天球上の星の動きは螺旋運動にみえる。

星を複数回観測することにより、螺旋のパラメータを推定

※Nano-JASMINEでは約14万個の星に対して推定を行う

推定すべきパラメータ

人工衛星に搭載された望遠鏡を用いて星を観測するため、星のパラメータ以外に観測機器、機器の劣化、衛星の姿勢パラメータなども同時に推定する必要がある

Nano-JASMINEで推定するパラメータの数

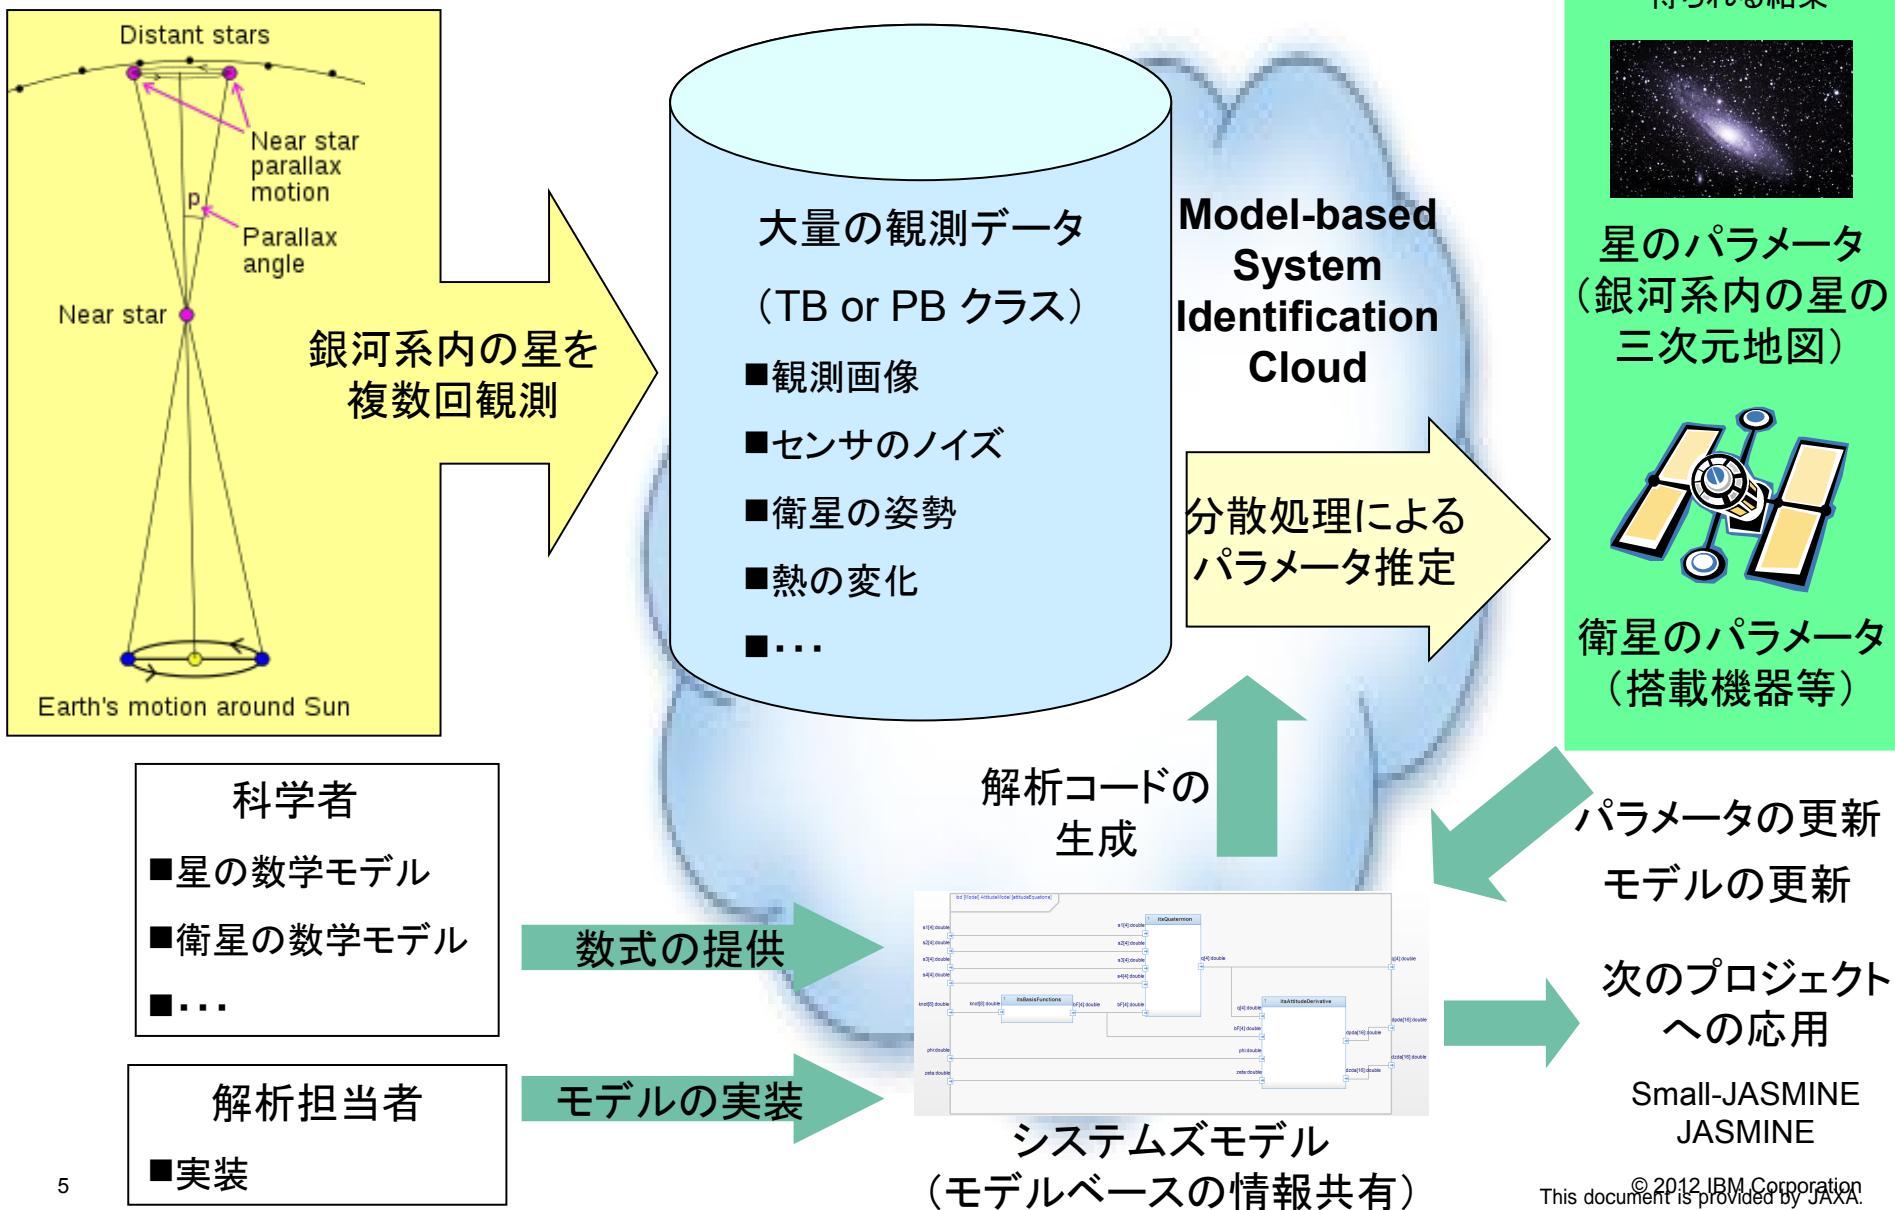
- 約14万個の星を観測。それぞれの星は5つの位置天文パラメータを持つ。
 - 星のパラメータ数 70万個 (7×10^5)
- 3次のスpline関数で衛星姿勢クオータニオンを近似。ミッション期間を2年間、スplineのknotの間隔を30秒とする
 - 姿勢のパラメータ数 840万個 (8.4×10^6)
- 星と姿勢のパラメータはカップリング項を持つため独立に解くことができない。そのため、約 10^7 のパラメータで構成される疎行列を解く必要がある。
 - 実際はカップリング項が最も情報量が多く、非対角項優位の大規模疎行列となる

← 星のパラメータより多い !

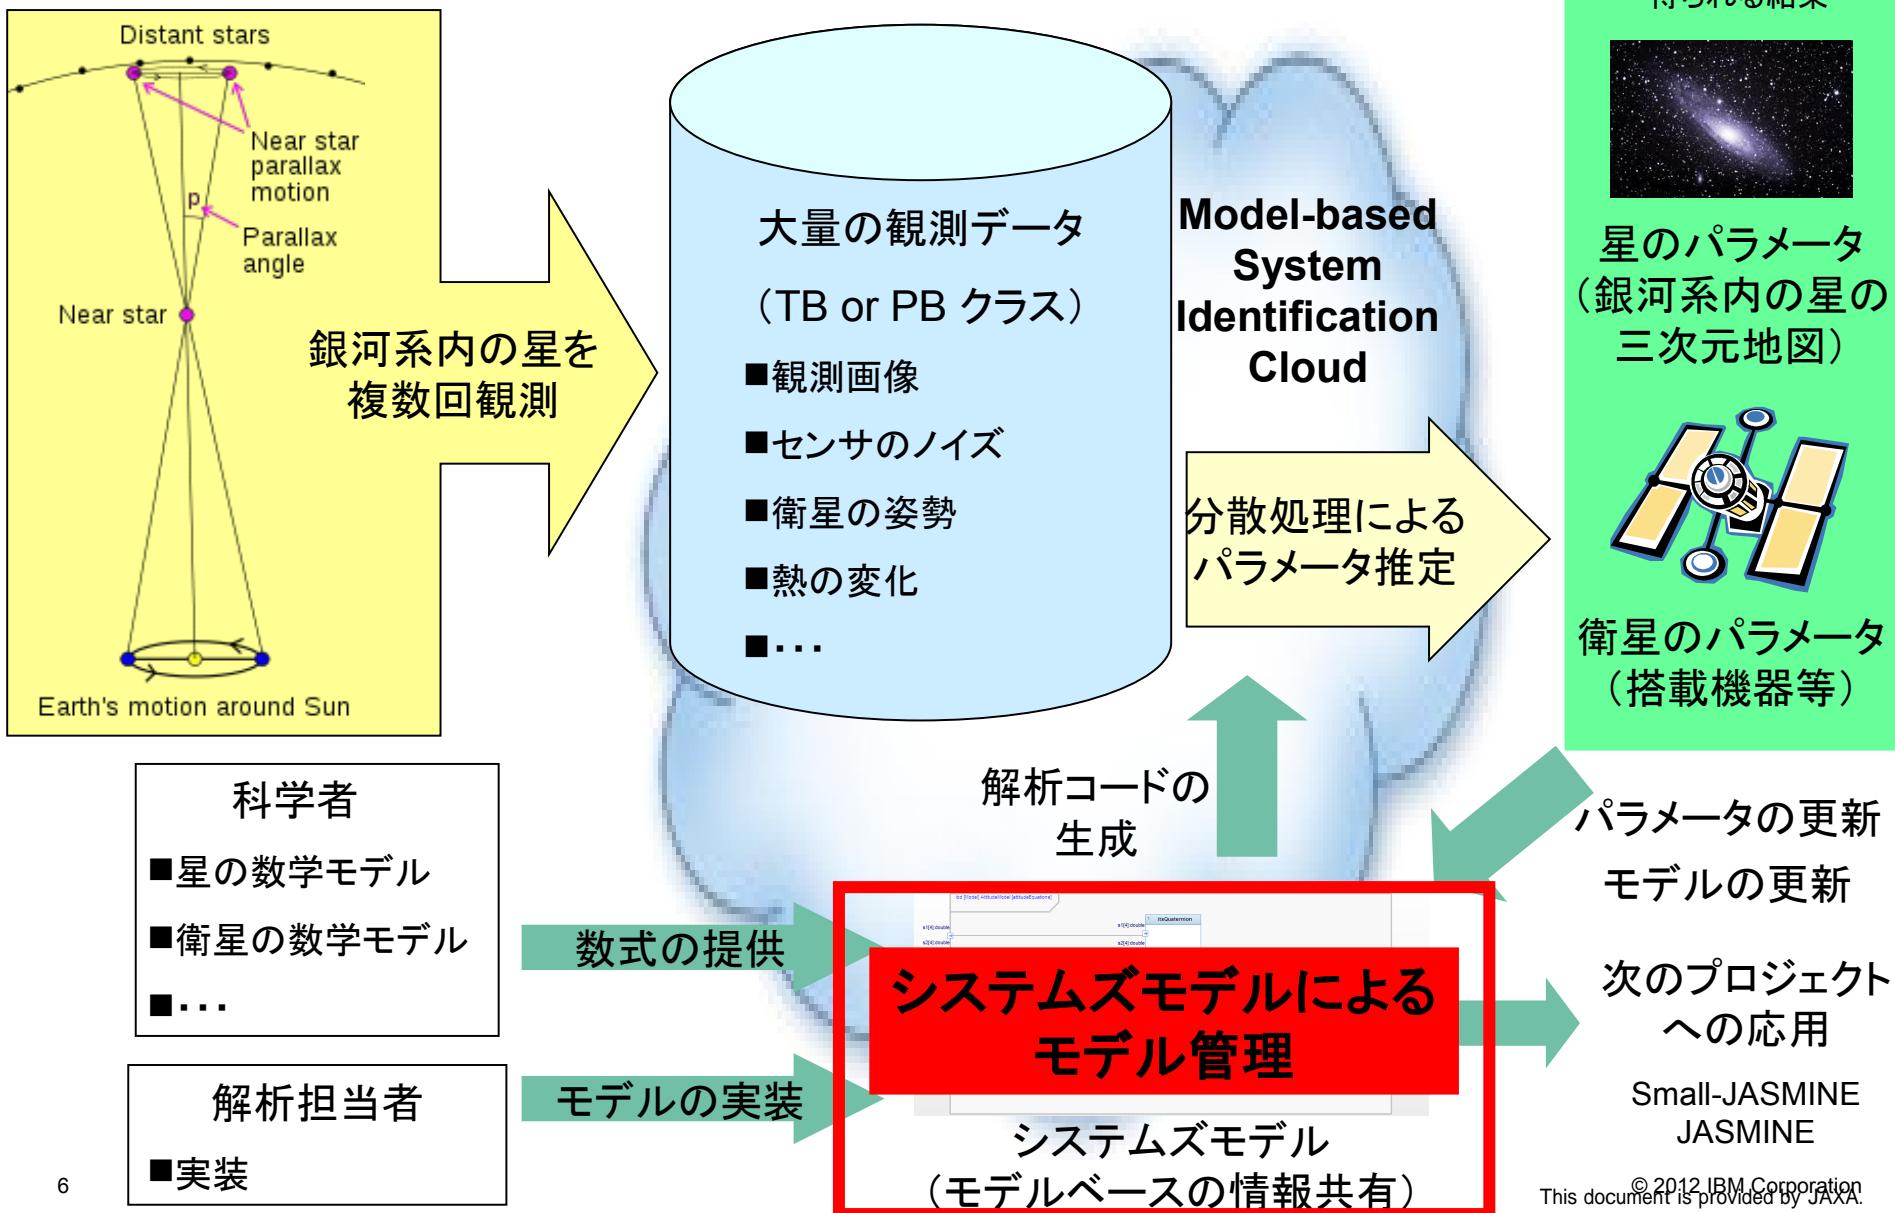
参考

- ESAが打ち上げ予定のGAIAプロジェクトではおよそ1億個(10^8)の星に対して位置天文パラメータを求める計画
 - パラメータ数はおよそ10億個(10^9)

Model-based System Identification Cloudの全体像

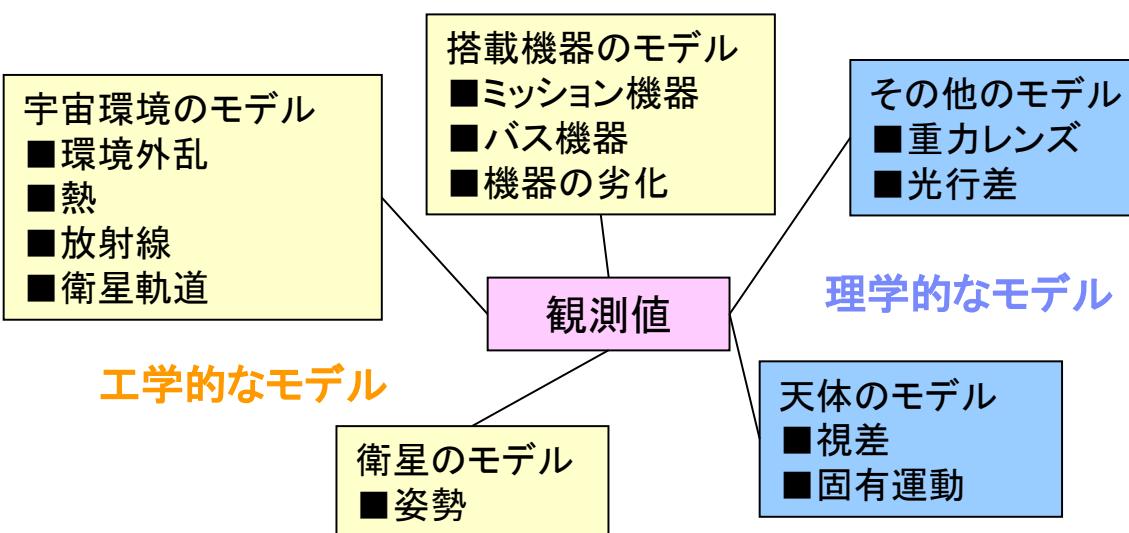


Model-based System Identification Cloudの全体像

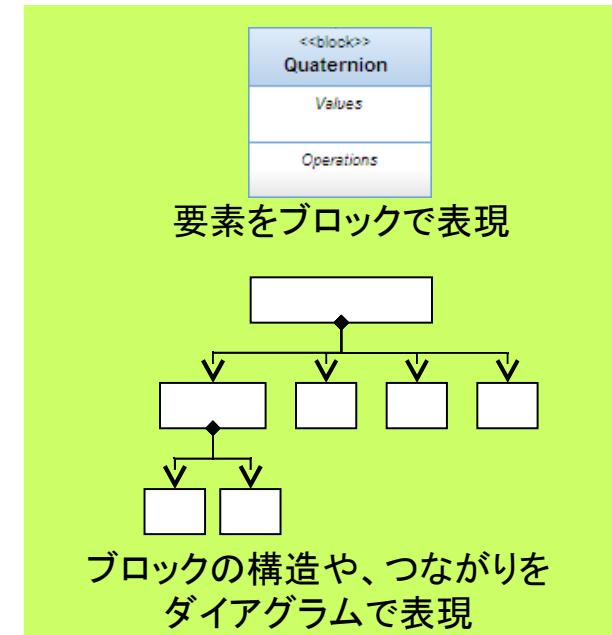


モデル駆動型システムズエンジニアリング Model Driven Systems Engineering (MDSE)

要求から設計まで、システム全体を形式的に記述し、表現するための新しい手法のひとつ



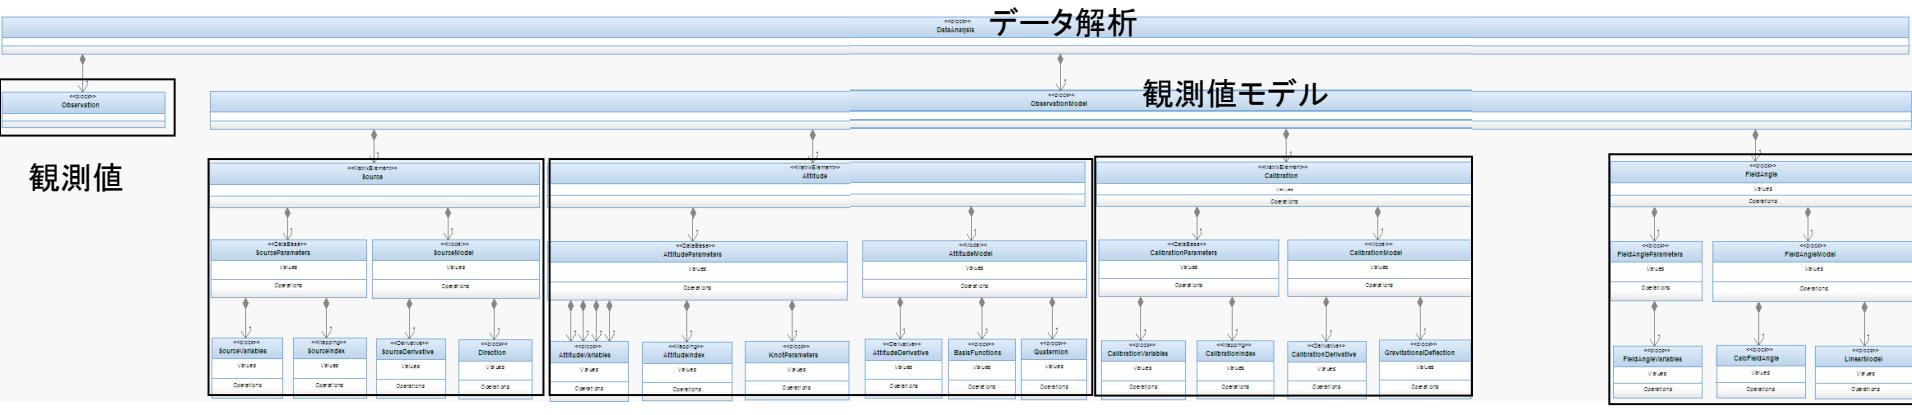
観測値に影響するさまざまな要素の例
(JASIMINEプロジェクトの例)



システムズモデル

理学、工学など様々な分野の研究者・開発者の間で、機能・制約・要求・振る舞いなどを共通理解しコミュニケーションするためのモデル

システムズモデル - ブロック定義図(Block Definition Diagram, BDD)



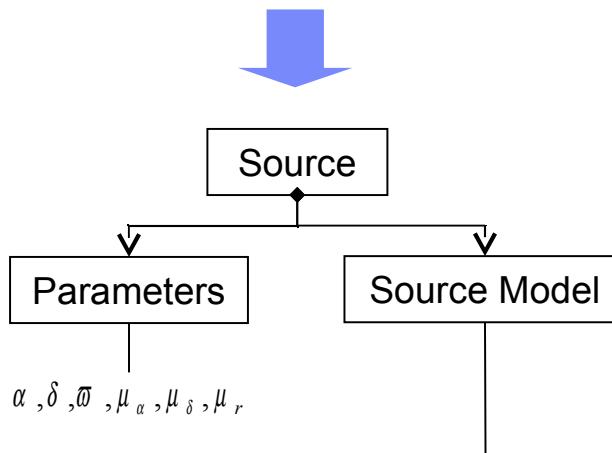
星のモデル

姿勢のモデル

較正のモデル

予測値

データ解析に用いるブロック定義図(全体像)



$$\mathbf{u}_i(t) = \langle \mathbf{r}_i + t \cdot (\mathbf{p}_i \mu_{\alpha} + \mathbf{q}_i \mu_{\delta} + \mathbf{r}_i \mu_{ri}) - \varpi \mathbf{b}_G(t)/A_u \rangle$$

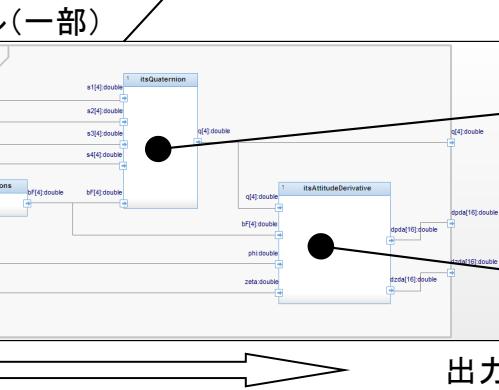
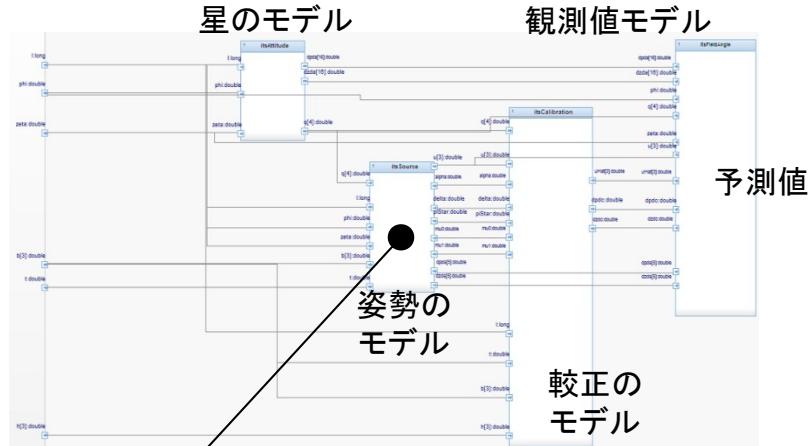
$$\mathbf{r}_i = [\cos \delta \cos \alpha \quad \cos \delta \sin \alpha \quad \sin \delta]^T$$

データ解析に必要な数式や同定すべきパラメータ、入力するパラメータなどの要素を、それぞれブロックとして定義し、全体の構成を記述する。

左図は星のモデルの一部で、星のモデルは星のもつ6個の位置天文パラメータと、星の位置を計算する数式から構成されていることがわかる

システムズモデル – 内部ブロック図(Internal Block Diagram, IBD)

- 観測値
- 衛星姿勢
- 位置
- 速度
- 時間
- 星の位置



$$B_{j,n}(t) = \frac{t - t_j}{t_{j+n} - t_j} B_{j,n-1}(t) + \frac{t_{j+n+1} - t}{t_{j+n+1} - t_{j+1}} B_{j+1,n-1}(t)$$

$$B_{j,0}(t) = \begin{cases} 1 & \text{if } t_j \leq t < t_{j+1} \\ 0 & \text{otherwise} \end{cases}$$

他のブロックから
のリンク

他のブロックへ
のリンク

ブロック
(数式)

入力ポート

出力ポート

数式を計算するためのパラメータは、
ブロックのポートとして定義

ブロック間のパラメータの受け渡しは
ポート間をリンクでつなげることで
表現

数式を提供する科学者(User)と解析担当者(Vendor)
の双方が共通理解することのできる形でモデルを管理

システムズモデル – Nano-JASMINEの解析モデル

データ解析



観測値

観測値モデル

データ解析

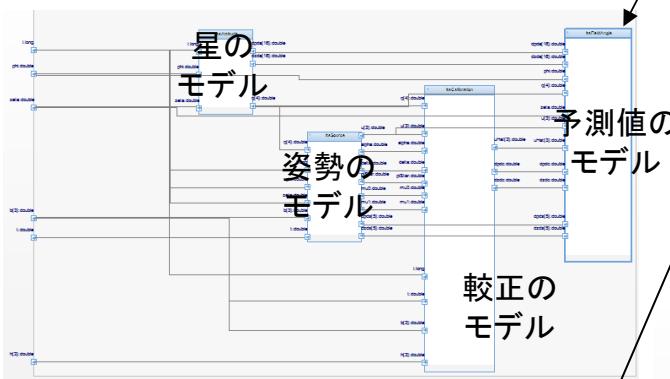
解析値モデル

星のモデル

姿勢のモデル

データ解析のBDD

観測値モデル

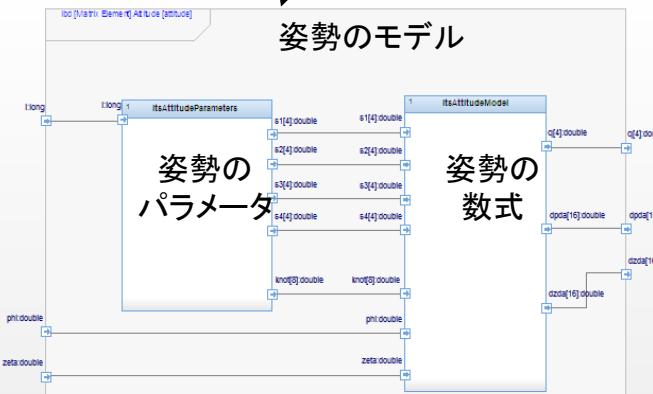


星のモデル



BDD(上図)により定義されたブロック同士の関係性をIBDにて記述する階層ごとにIBDを作成することで、系統的に解析モデルを取り扱う

姿勢のモデル



パラメータ推定のための連立方程式

$$B_{j,a}[t] = \begin{cases} 1 & \text{if } t_j \leq t \leq t_{j+1} \\ 0 & \text{otherwise} \end{cases}$$

$$B_{j,a}[t] = \frac{t - t_j}{t_{j+1} - t_j} B_{j,a-1}[t] + \frac{t_{j+1} - t}{t_{j+1} - t_j} B_{j-1,a-1}[t]$$

$$\bar{\eta}_l(t) = \langle \mathbf{r}_l + (t - t_l) (\mathbf{v}_l + \mathbf{a}_l) + \mathbf{r}_l \rangle - \bar{\eta}_l(t_l)/d_l$$

$$\left[\sum \frac{\partial R_l}{\partial p} \frac{\partial R_l}{\partial p'} W_l \right] d_i = - \sum \frac{\partial R_l}{\partial p} R_l W_l$$

$$R_l(\mathbf{s}, \mathbf{a}, \mathbf{c}) = \eta_{obs} - \eta_{predict}$$

$$\begin{bmatrix} \cos\eta \cos\delta \\ \sin\eta \cos\delta \\ \sin\eta \end{bmatrix} = f(\mathbf{q}) \begin{bmatrix} u_x \\ u_y \\ u_z \end{bmatrix}$$

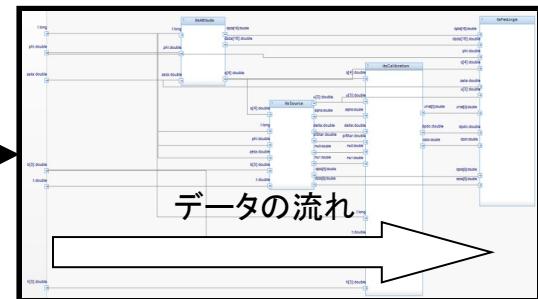
最小二乗法による定式化
(User側から提供)

システムズモデル
による管理

モデルさえ記述すれば、
解析コードは自動的に生成できる

観測値 η_{obs}

予測値 $\eta_{predict}$



システムズモデルの一部
(観測値が入力されると、観測値と
予測値との差分が計算される)

$$N \cdot \Delta x = b$$

Nはn×nの対称行列
nはパラメータ数

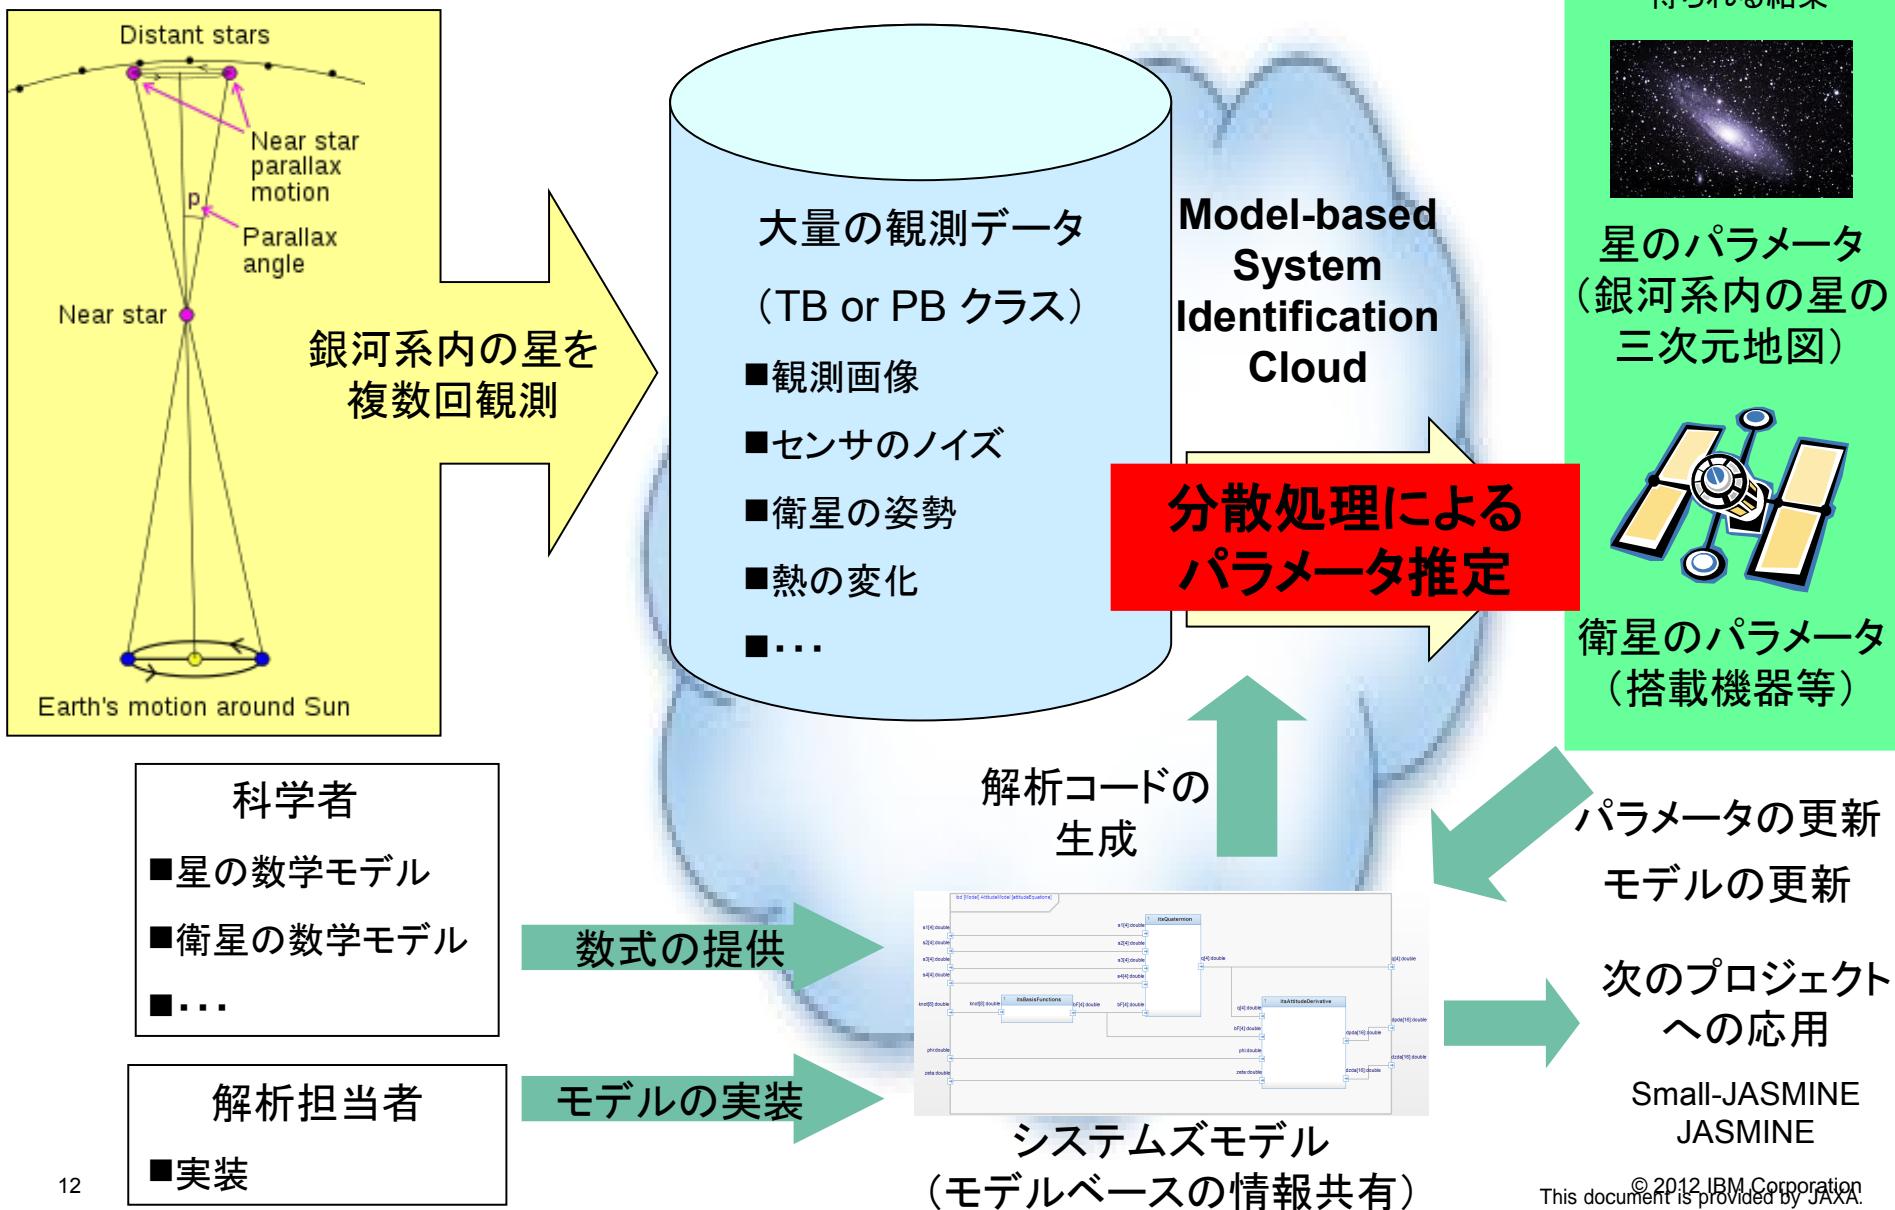
Δx を求めたいが、パラメータ数が多いため反復法で計算

パラメータ推定の流れ

- 行列N($10^7 \times 10^7$)の生成
- N $\Delta x = b$ の式より Δx を反復法により求める
- Δx によりパラメータを更新
- 行列N ($10^7 \times 10^7$)の生成
- ...

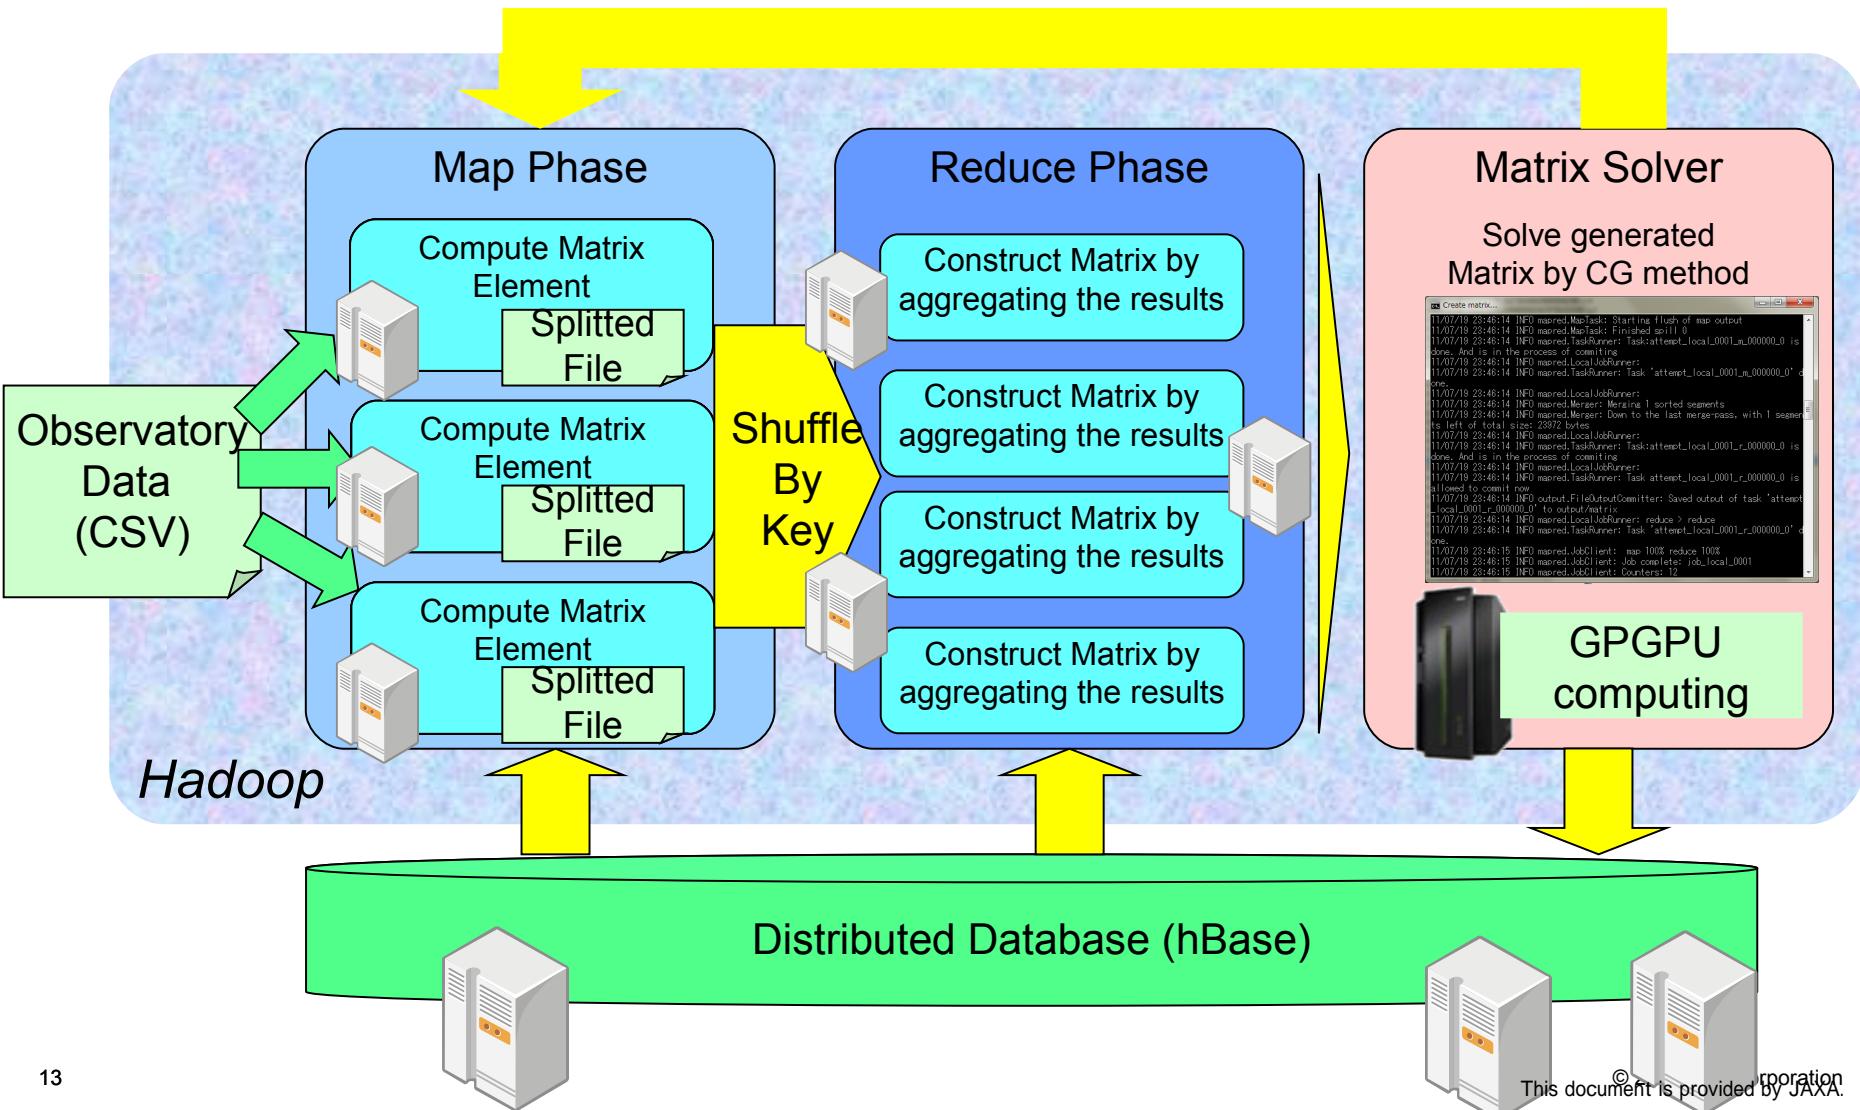
大規模なデータに対応するため
クラウドコンピューティングによる
分散処理を実装

Model-based System Identification Cloudの全体像



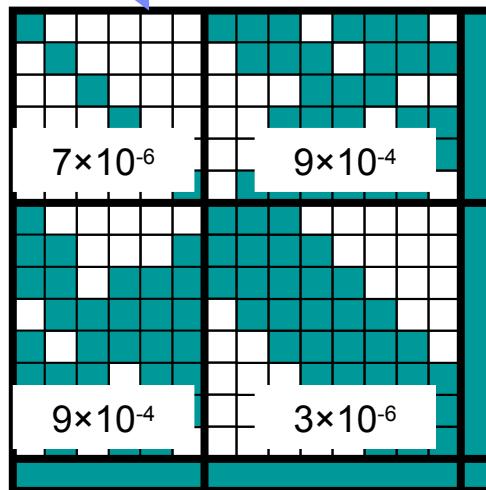
現在の構成

大規模疎行列の生成部分にはHadoop MapReduceを利用
反復法にてパラメータを解く部分にはGPGPUを利用

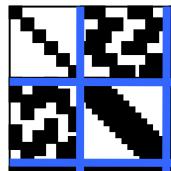


疎行列の分割と格納形式の選択

$$N \cdot \Delta x = b$$



星のパラメータ 姿勢のパラメータ 較正のパラメータ



分割生成された疎行列

} 星のパラメータ
} 姿勢のパラメータ
} 較正のパラメータ

星・姿勢・較正それぞれで疎行列の特性が大きく異なる

大規模疎行列を効率よく解くために

- 疎行列の分割
- それぞれに対して格納形式を選択

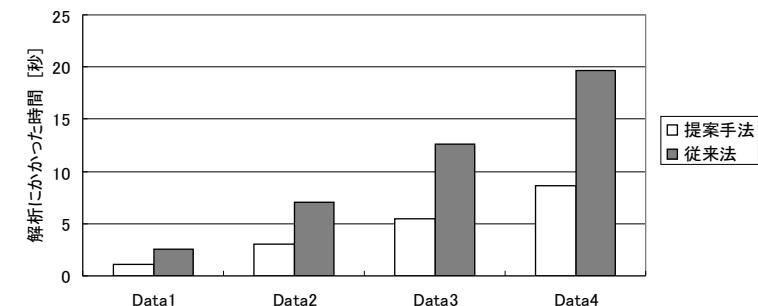
システムズモデルからは以下の情報が得られる

- パラメータの数
- パラメータ同士の関係性

疎行列の非ゼロ要素位置を導出

DIA	CSR	CSR
ELL	DIA	CSR
CSR	CSR	CSR

選択された格納形式
(比較したものは全てCSRで格納)



星の個数を3000,7000,15000,21000させたサンプルデータ解析の結果(toy model)

格納形式の判別に利用することで約2倍の効率化を実現

まとめ

- 科学者(User)の様々な要求に対応するため、モデル駆動型システムズエンジニアリングに基づくモデル管理、データ解析のフレームワークを提案
 - Model-based Systems Identification Cloud
- 大規模複雑なデータ解析の一例として、位置天文観測衛星Nano-JASMINEのデータ解析に適用
 - 解析モデルの生成
 - Hadoop MapReduceによる疎行列生成
 - GPGPUを用いた反復法によるパラメータ推定
- 現状は、別途数値解析により用意したサンプルデータを入力データとして、検証中
- 今後は実機から得られるデータの利用、Small-JASMINE等他のプロジェクトの検討への利用を検討
 - HILS(Hardware In the Loop Simulator)
 - 軌道上データ(2013年打ち上げ後)