衛星熱･構造設計へのデータ同化の適用試行

高木　亮治（JAXA）、秋田剛（千葉工大）

本日の内容

- 背景
  - ものづくりの革新
  - 衛星熱（・構造）設計
  - データ同化の役割
- 衛星設計への適用試行
  - 熱
  - 構造
- HPC技術
  - GPGPUの利用

数値シミュレーション技術の新たな方向性

新たな方向性
数値シミュレーション技術を利用した新たな可能性

- データ同化技術
- 最適化技術

従来の計算機資源では計算コストの面で実現が困難であった計算技術を宇宙機（特に衛星）の開発に導入する。

スパコンを代表とする膨大な計算機資源

CFD解析技術の開発への応用

- ロケットエンジン解析技術
- 射場音響解析技術
- プラズマ解析技術
- 他

HPCの利用

- 計算機能力の向上に伴いより高度な利用（数値シミュレーション）が実施可能に
  - 2D、簡易形状、要素 → 3D、複雑形状、実機
  - 簡易モデル → 複雑現象を直接解析（第一原理解析）
- 設計・開発（・運用）での利用
  - 「解析可能」＋「大規模パラスタ」＝設計で使える。
  - 「解析可能」＋「大規模パラスタ」が「実時間より速くできる」＝運用で使える。

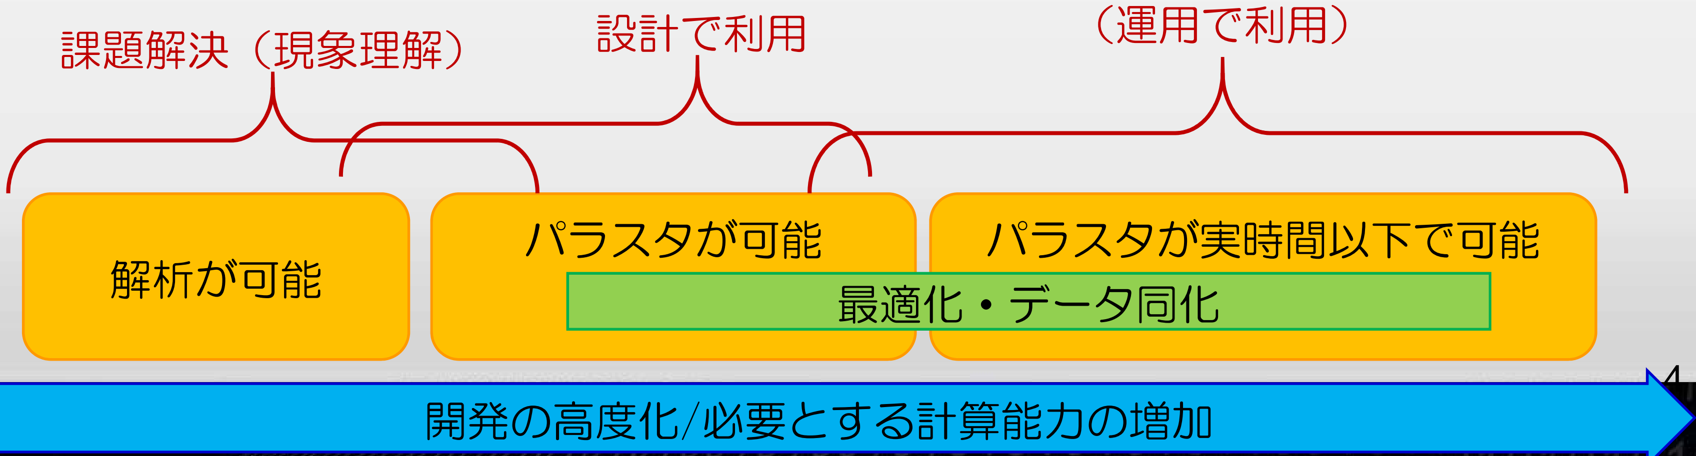

宇宙機の熱設計

- 宇宙空間における過酷な熱環境でも宇宙機が正常に動作するように保証する。
- 要求された運用期間内で、搭載機器や構体の温度分布が許容範囲に収まるように熱設計を行う。
- 軌道上での宇宙機の温度を精度良く予測する熱数学モデルを構築する。
- 温度予測値が熱試験の実測値と一致するように手動で熱数学モデルのパラメータ調整を行う。

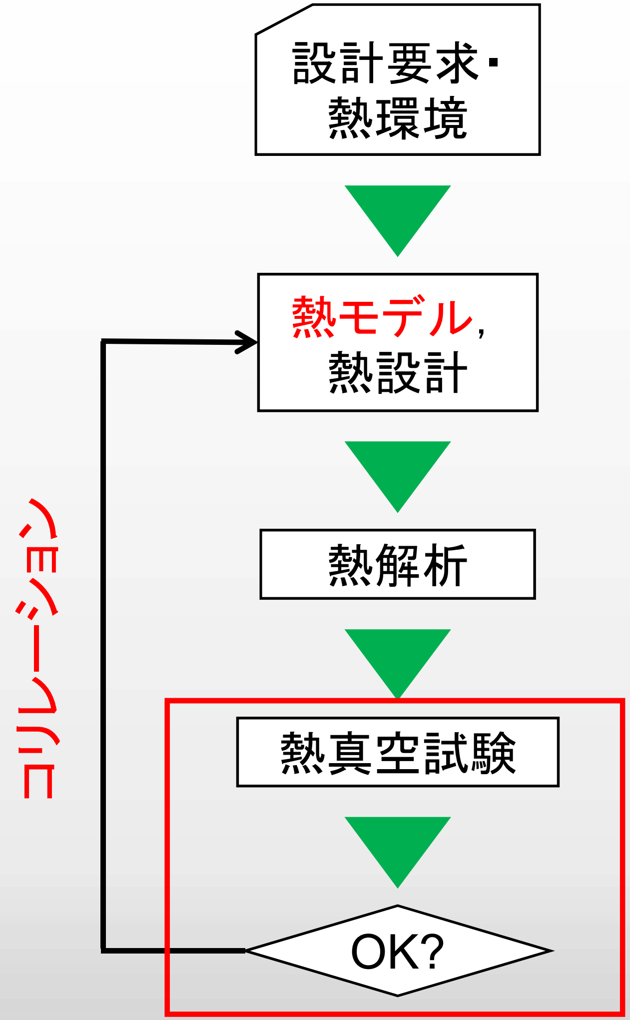

宇宙機の熱数学モデル

宇宙空間では伝導と放射によって熱交換

熱数学モデル

衛星温度

熱入力

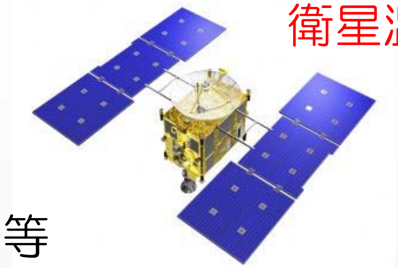

熱出力

・太陽光，機器の発熱等

・宇宙空間への放射

熱数学モデルに必要な物性値

- 熱特性：
  - 熱容量、放射率、太陽光吸収率等
- 伝導：
  - 熱伝導係数、接触熱伝導率
- 放射：
  - 放射係数

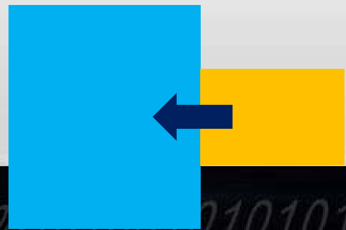

材料ごとに固有の値

接触圧や接触面積に依存

実験データから値を決定

幾何学的な配置から決定

現状の課題

- 数値シミュレーションの限界
  - 衛星の熱数学モデルの様に物理モデルだけでは限界がある。
  - 理論だけでは物理パラメータを決められない。
    - 製作工程、外的要因、経年変化、不確定性、…
    - 統計処理・確率論的な扱いが必要か？

【熱にかぎらず一般的に】

- 物理モデルと現実世界を繋ぐ方法論が必要
  - モデルの導入とモデルパラメータの推定（特に現物合わせ的なパラメータ推定）が必要
    - ある種の最適化問題とも考えられる
- データ同化手法の適用

データ同化とは？

- 数値シミュレーションモデルと実際の観測・実験データを統合する手法
  - 気象・海洋分野で発達：天気予報
  - 観測・実験データは物理的・社会的制約による限界がある
    - 衛星のテレメトリデータ、試験データも同じ
  - 数値シミュレーションのみでは実際の物理現象を再現できない
    - シミュレーションモデルの不完全性
- データ同化のメリット：
  - より正しい解の予測
  - より良いモデル、初期条件、境界条件の構築
  - 観測値の補間、ある種の感度解析

何に使えるか？

- 衛星の熱解析への適用
  - 熱モデル、境界条件の不確定性の克服に適用
    - 観測データ：熱真空試験・運用時テレメトリデータ
  - データ同化の利用：
    - 熱モデルの高度化・効率化
    - 異常監視診断の高度化
      - 衛星シミュレータ
    - テレメトリデータの補間
    - センサーがない部位の監視
      - センサー配置の提案
- 将来的には衛星運用への適用

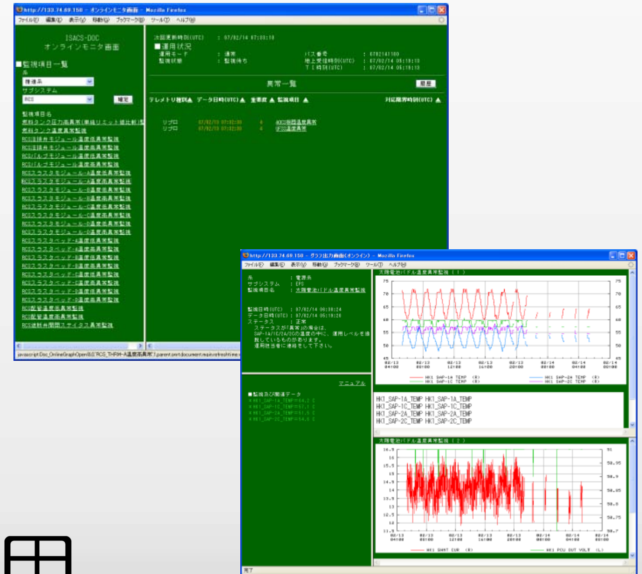

例）ISACS-DOC
（科学衛星異常監視・診断システム）

衛星熱設計へのデータ同化手法の適用

- 衛星熱設計における熱数学モデルの不確定パラメータの推定にデータ同化を適用
  - 熱数学モデルとして節点法
  - データ同化手法として
    - アンサンブルカルマンフィルター
    - 粒子フィルター（PF）
- 適用例
  - 小型衛星での双子実験
  - トラス部材、SDS-1

衛星熱設計へのデータ同化の適用

- 熱数学モデル：節点法による温度に関する常微分方程式を離散化

$$C_i \frac{dT_i}{dt} = Q_i - \sum_{j=1}^{N_n} C_{ij}\left(T_i - T_j\right) - \sum_{j=1}^{N_n} \sigma R_{ij}\left(T_i^4 - T_j^4\right)$$

離散化

$$\begin{aligned} T_i(t+1) = T_i(t) + \frac{dt}{C_i}\Big[Q_i(t+1) &- \sum_{j=1}^{N_n} C_{ij}\left(T_i(t+1) - T_j(t+1)\right) \\ &- \sum_{j=1}^{N_n} \sigma R_{ij}\left(T_i^4(t+1) - T_j^4(t+1)\right)\Big] \end{aligned}$$

衛星熱設計へのデータ同化の適用

- データ同化では状態変数の条件付き確率分布を求める。
  - 決定論的→確率論的： $x_t \longrightarrow p(x_t)$
  - 条件付き確率分布：ベイズの定理を利用

X ：モデル
Y ：観測値

$$\underset{\text{事後分布}}{\boxed{p(X|Y)}} = \frac{\overset{\text{尤度}}{\boxed{p(Y|X)}} \cdot \overset{\text{事前分布}}{\boxed{p(X)}}}{p(Y)}$$

  - 予測分布とフィルター分布：

$p(x_t|y_{1:t-1})$ $\qquad$ $p(x_t|y_{1:t})$

  - PF：分布を粒子で表現

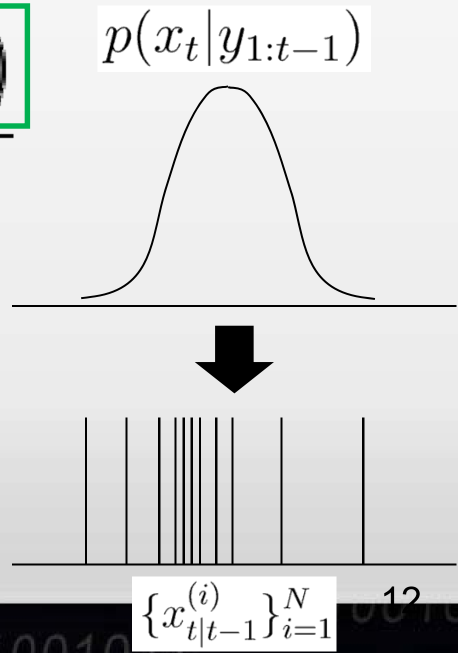

小型衛星で双子実験

- 状態変数：20（=16+4）
- 節点数：16
- 未知パラメータ数：4
  - edge2,9,21,24
- 観測点：5
  - node2,5,10,14,15

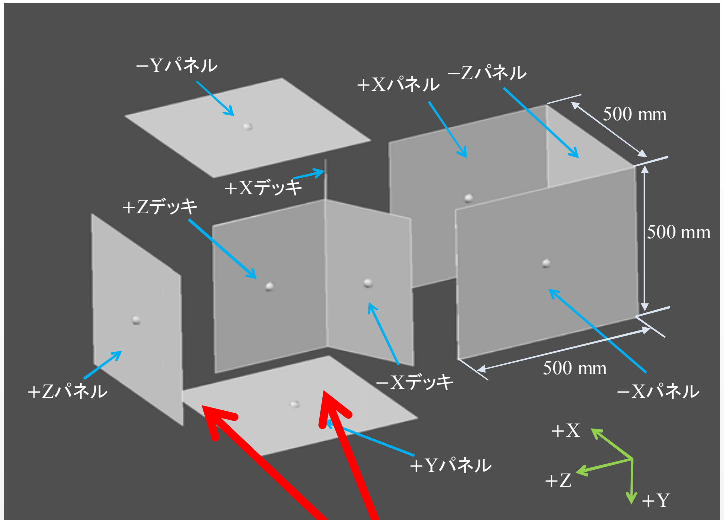

内部デッキと構体の接触部の接触熱伝導率を推定.

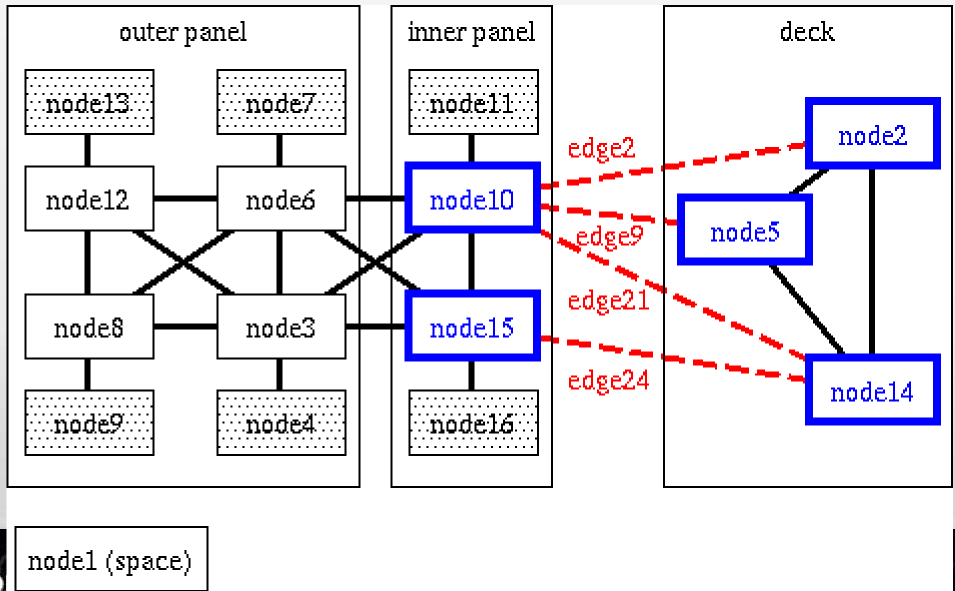

- 1周期：6052.4秒
- 50,000秒（8周期分）
- MPI+OpenMP
- 10^4粒子/CPUで4.5時間

小型衛星で双子実験

- 双子実験：
  - 正しいパラメータの値を用いて数値シミュレーションを行う。
  - 上記の数値シミュレーション結果に観測誤差を加えることで観測データを表現
  - 偽のパラメータの値からパラメータ推定を実施

温度履歴（シミュレーション結果）

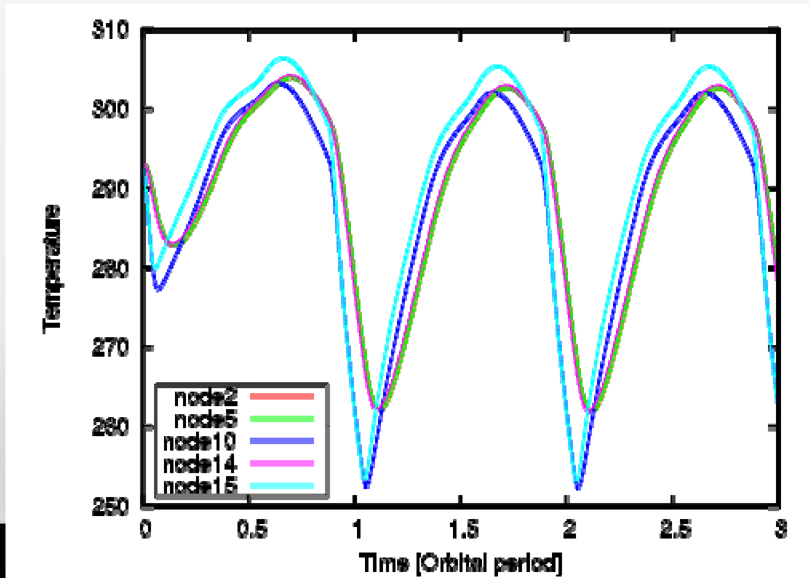

真値と観測値

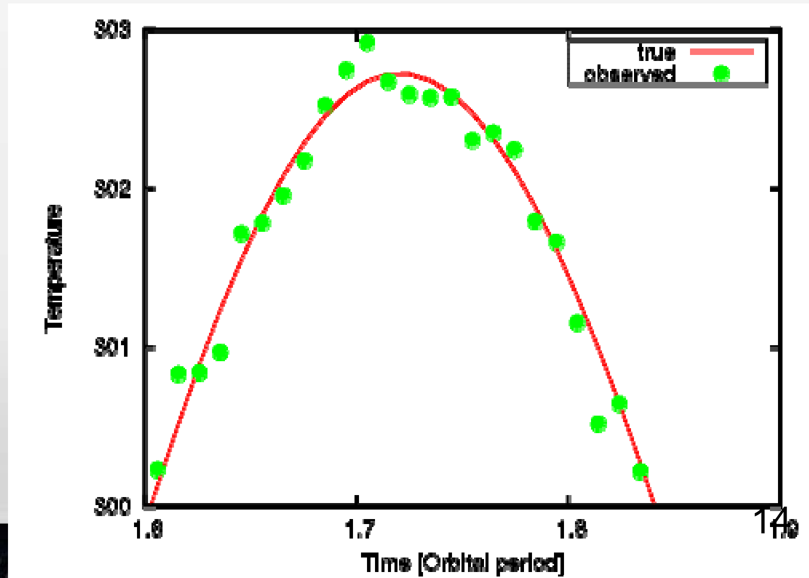

小型衛星で双子実験

- パラメータの推定状況

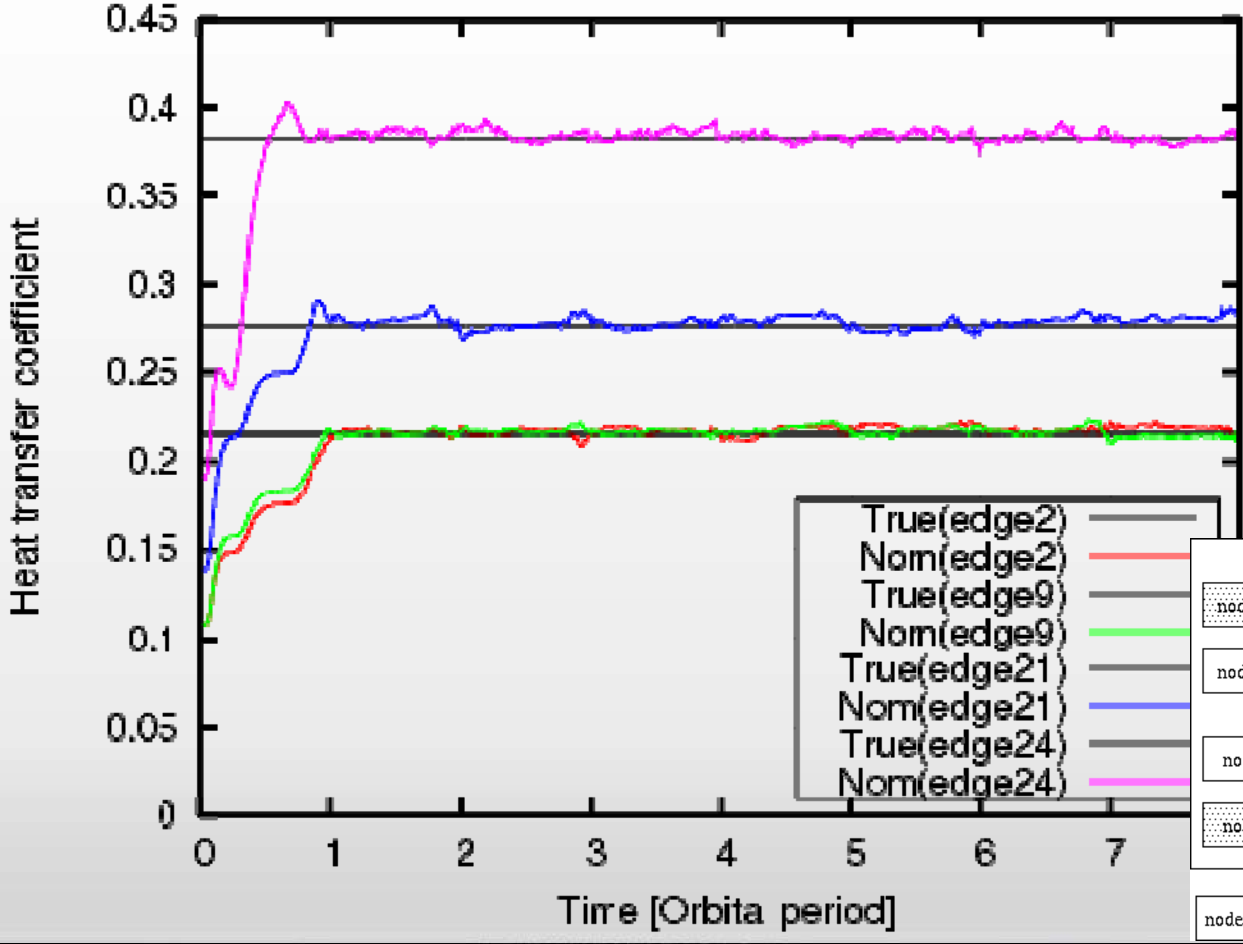

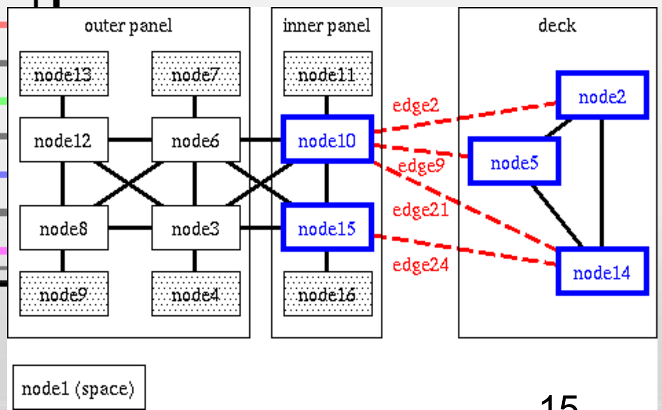

トラス部材の適応シミュレーション実験

適応シミュレーション

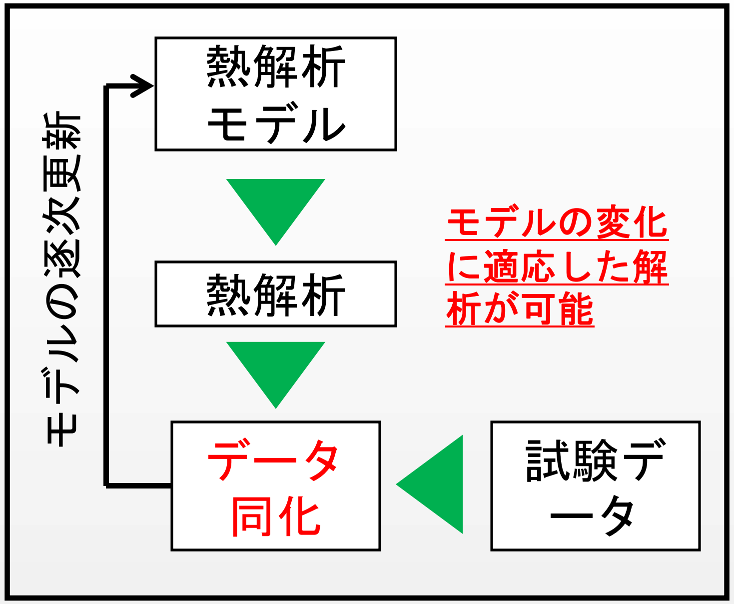

CASE A: 適応シミュレーション（モデルを逐次更新）

CASE B: モデルを不変とした解析

- EnKFを利用

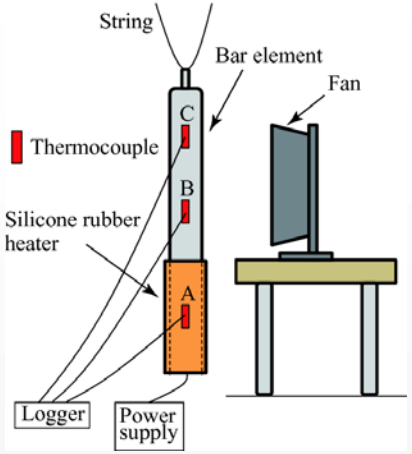

実験モデル

実験手順

- ステップ１：ヒータで部材を定常状態まで加熱
- ステップ２：定常状態の部材をファンで冷却
- ステップ3：ファンを停止

ステップごとに対流熱伝達係数が大きく変化するA,Bの温度を計測し，対流熱伝達を推定パラメータとしてデータ同化を行う.

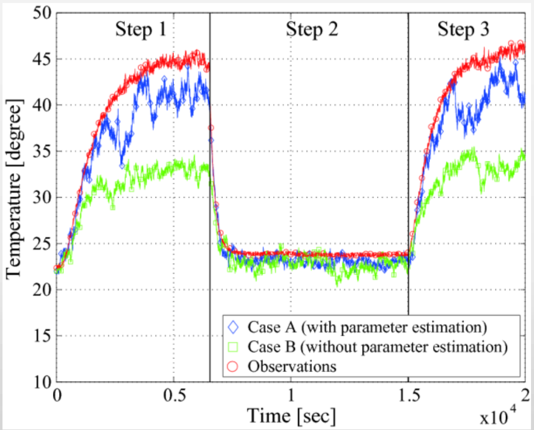

適応シミュレーションによるCの温度

RMS誤差（Cの温度）

	Step1	Step2	Step3
Case A	3.39	0.86	2.81
Case B	9.53	1.50	7.73

将来的な適用構想

- リアルタイム（RT）可視化
  - 衛星全体及び局部の温度分布や熱の流れを直感的にかつリアルタイムに把握できる可視化システム。
    - センサーデータ、解析データ、リアルタイムコリレーション結果の3次元RT表示
    - センサーデータ（500点）の解析ノード（20,000点）へのマッピング
- 遷移状態でのデータを用いたコリレーション
  - 試験期間の大幅な短縮

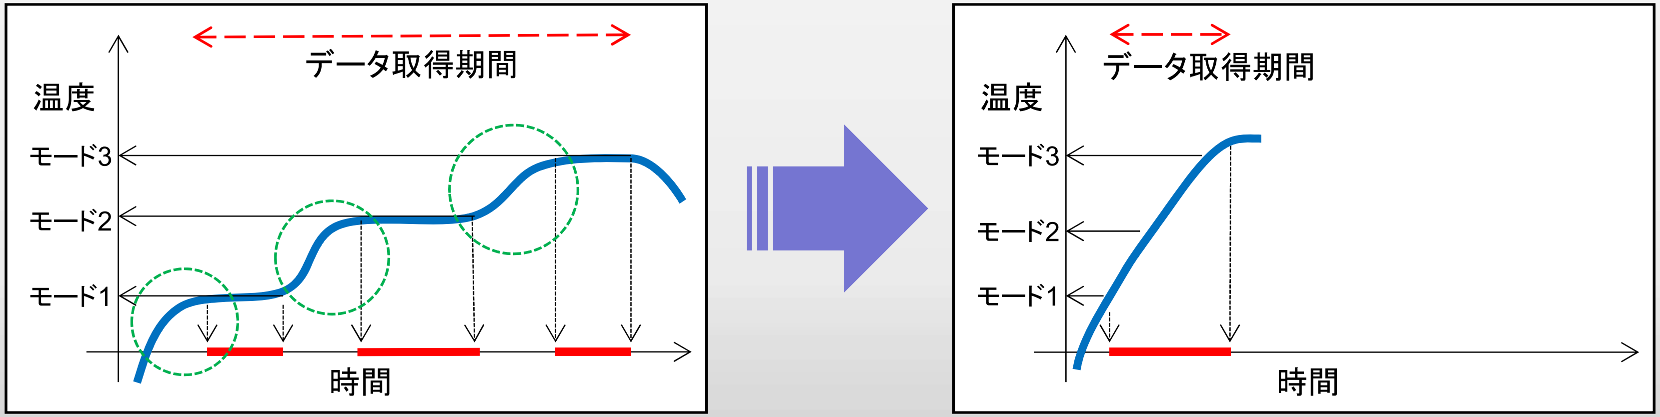

構造系の事例

先進宇宙機設計における数値シミュレーション

- 軌道上での構造性能を数値シミュレーションにより評価（地上試験が困難）．パラメトリックスタディにより不確定要因に対する構造性能を評価

与えられた条件（パラメータ）に対して、応答を求めるツール

- 現在までの測定データの情報を使ってパラメータを推定したい.
- 軌道上での測定データと数値予測が異なった場合の原因が知りたい.
- 測定点以外の状態を測定データを加味した上で数値シミュレーションにより評価したい.

EnKFによる状態推定

$$\mathbf{x}_{t|t}^{(i)} = \boxed{\mathbf{x}_{t|t-1}^{(i)}} + \boxed{\mathbf{K}_t \left(\mathbf{y}_t - \mathbf{H}_t \mathbf{x}_{t|t-1}^{(i)} + \mathbf{w}_t^{(i)} \right)}$$

数値シミュレーション予測

測定データによる補正

変位ベクトル

$$\mathbf{x}_t = \begin{bmatrix} \mathbf{u}_t \\ \mathbf{s}_t \end{bmatrix}$$

モデルパラメータベクトル

モデルパラメータを同時推定する

片持ちはりの振動

- 先端のｙ変位を計測
- 減衰比をモデルパラメータ（真値の2倍の値を設定）
- 疑似観測データを作成してデータを逐次取り入れながら変位を推定
- システムノイズ・観測ノイズの設定で推定結果が大きく変わる

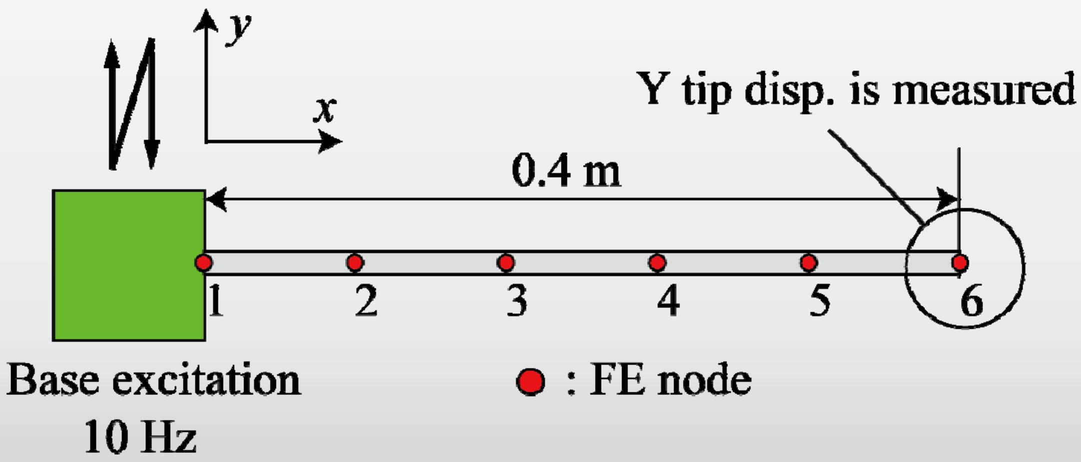

減衰比の推定誤差と信頼区間

$$\sigma_{s,1}^{2(0)} = 6.3\times10^{-8}, \sigma_{obs}^{2(0)} = 10^{-4}$$

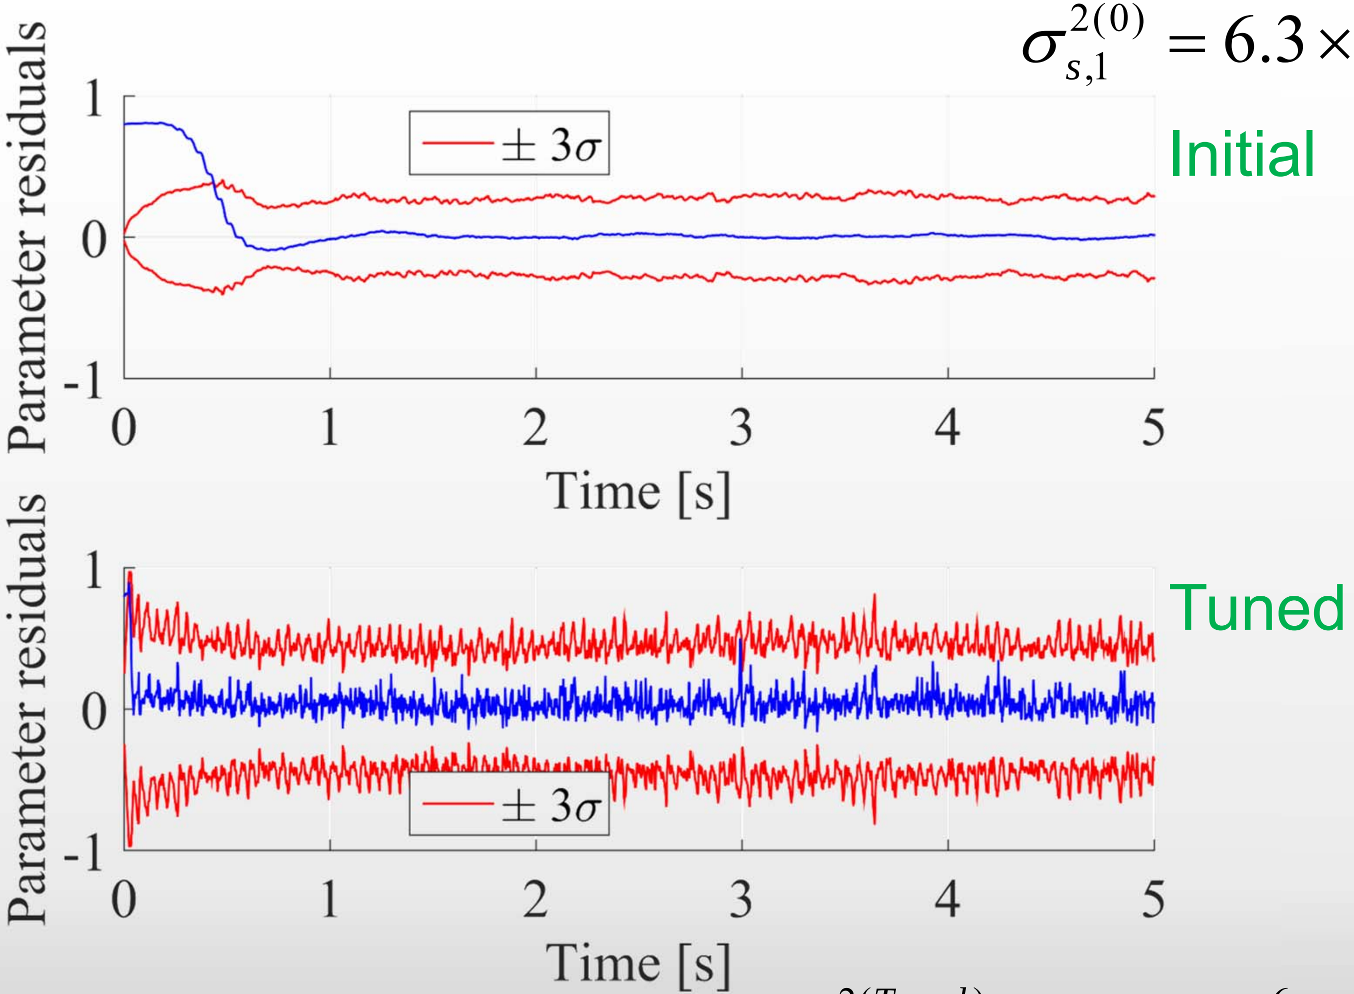

$$\sigma_{s,1}^{2(Tuned)} = 4.4\times10^{-6}, \sigma_{obs}^{2(Tuned)} = 6.6\times10^{-9}$$

Y変位の推定誤差

節点４

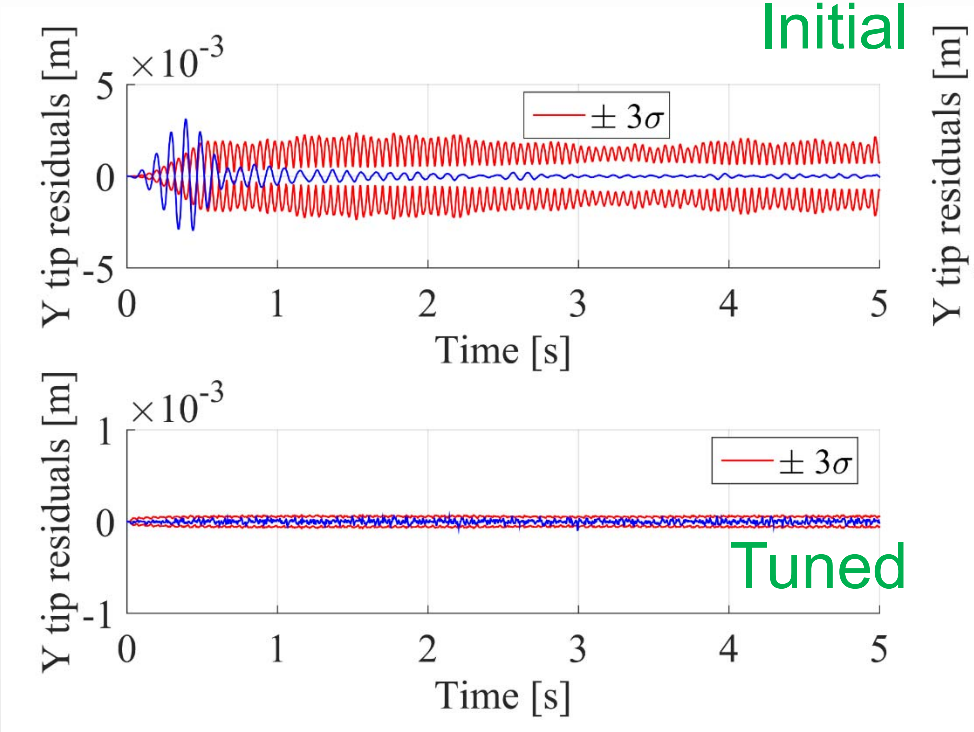

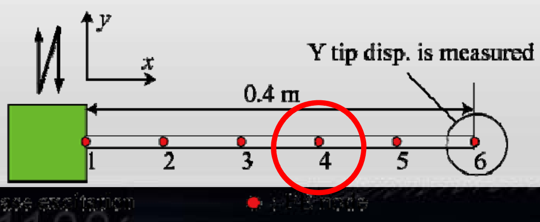

節点６

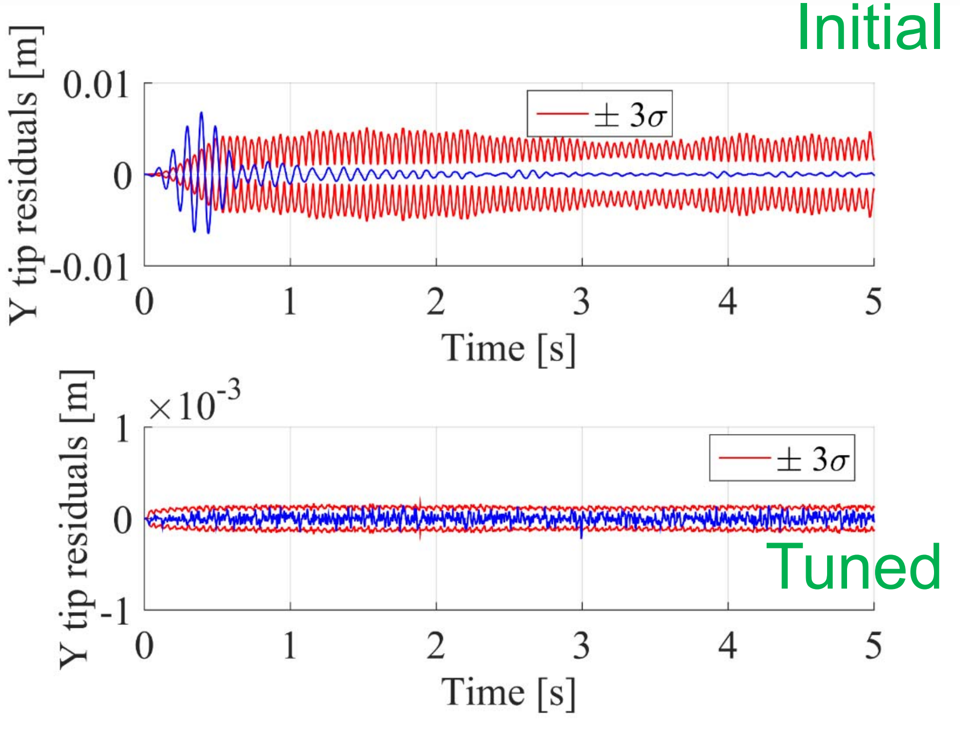

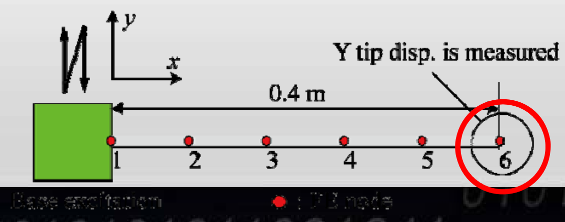

GPGPUによる高速化

性能評価

- 性能計測：
  - 小型模擬衛星(eATOMS1)で計測。
    - 16節点程度、1,000秒の計算
- 結果例1：
  - 総粒子数の違う2ケース

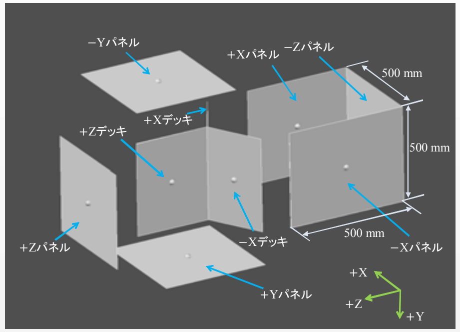

	ブロック数	スレッド数	粒子数/スレッド	総粒子数	計算時間 [秒]
GPU	558	16/ブロック	1	8298	5.754
1CPU	–	6	1488	8928	13.04
2CPU	–	12	744	8928	6.570
GPU	1008	16/ブロック	1	16128	10.33
1CPU	–	6	2688	16128	23.60
2CPU	–	12	1344	16128	11.87

GPGPUの試験利用3

- ●結果例2a：総粒子数を同じにして
  - ① GPUだけで計算（粒子数：22,016）
  - ② GPU+CPUx1で計算（粒子数：22,008）
    - OMPスレッド#0：GPUでの処理
    - OMPスレッド#1-#11：CPUでの計算
  - ② CPUx1だけで計算（粒子数：22,008）
    - OMPスレッド×12

		ブロック数	スレッド数	粒子数/スレッド	総粒子数	計算時間 [秒]
①	GPU	1,376	16/ブロック	1	22,016	14.57
②	GPU CPU	1,008 –	16/ブロック 5	1 1,176	16,128 5,880	10.32 10.32
③	CPU	–	6	3,668	22,008	32.27

GPGPUの試験利用3

- 結果例2b：総粒子数を同じにして
  - ① GPUだけで計算（粒子数：29,056）
  - ② GPU+CPUx2で計算（粒子数：29,064）
    - OMPスレッド#0：GPUでの処理
    - OMPスレッド#1-#11：CPUでの計算
  - ② CPUx2だけで計算（粒子数：29,064）
    - OMPスレッド×12

		ブロック数	スレッド数	粒子数/スレッド	総粒子数	計算時間 [秒]
①	GPU	1,816	16/ブロック	1	29,056	19.08
②	GPU	1,008	16/ブロック	1	16,128	10.34
	CPU	–	11	1,176	12,936	10.36
③	CPU	–	12	2,422	29,064	21.38

まとめ

- データ同化の衛星熱・構造設計への適用試行について紹介
  - 物理シミュレーションの限界の打破
  - リアルワールドの予測技術
- 双子実験、実データにより有効性を確認
  - 新たな設計開発・運用での利用を模索
  - HPC技術の利用

基礎検証

Lorenz63モデル

Lorenz63モデルで双子実験

- 双子実験：観測データをシミュレーション結果＋ノイズで表現
- Lorenz63モデル：非線形性が強い

$$\frac{dx_1}{dt} = -s(x_1 - x_2)$$
$$\frac{dx_2}{dt} = rx_1 - x_2 - x_1x_3$$
$$\frac{dx_3}{dt} = x_1x_2 - bx_3$$

(s=10, r=28, b=8/3)

尤度の定義：

$$l_t = p\left(\mathbf{y_t}|\mathbf{x_{t|t-1}}\right) = \frac{1}{\left(\sqrt{2\pi\sigma}\right)^3}\exp\left[-\frac{\left\|\mathbf{y_n}-\mathbf{x_{t|t-1}}\right\|^2}{2\sigma^2}\right]$$

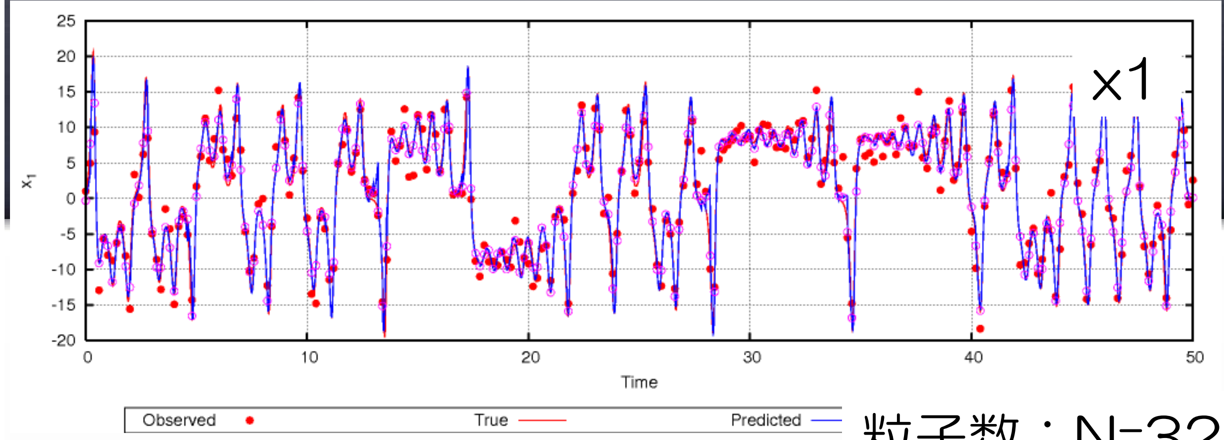
x1
Time
Observed
True
Predicted

粒子数：N=32

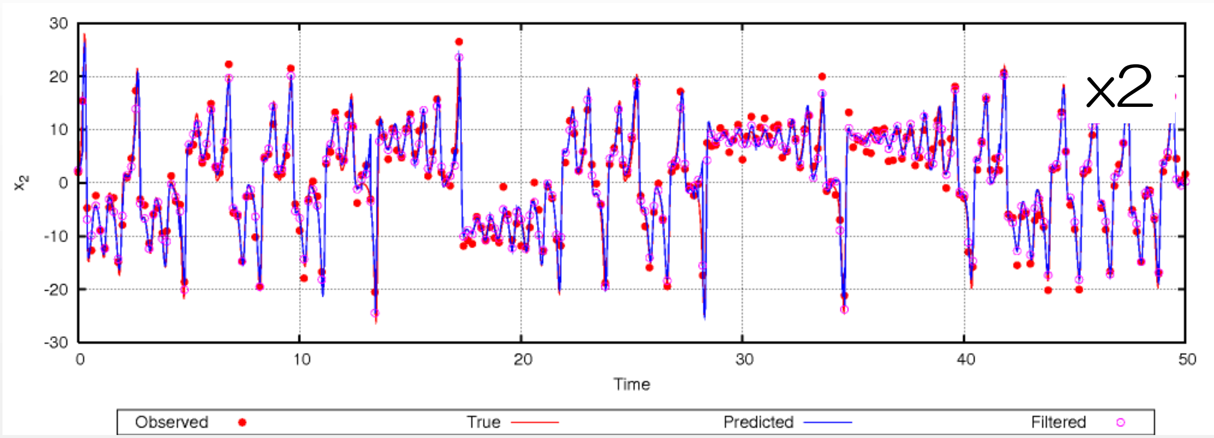
x2
Time
Observed
True
Predicted
Filtered

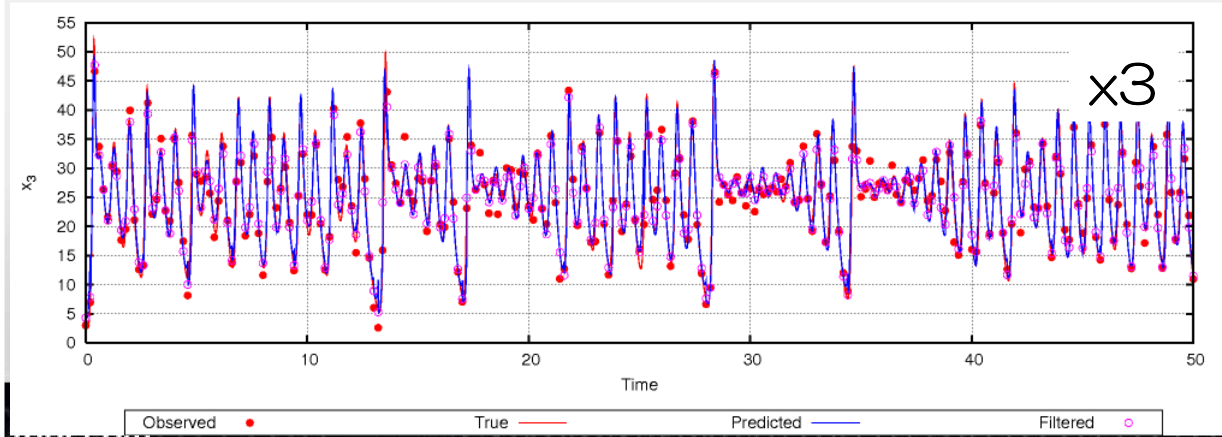
x3
Time
Observed
True
Predicted
Filtered

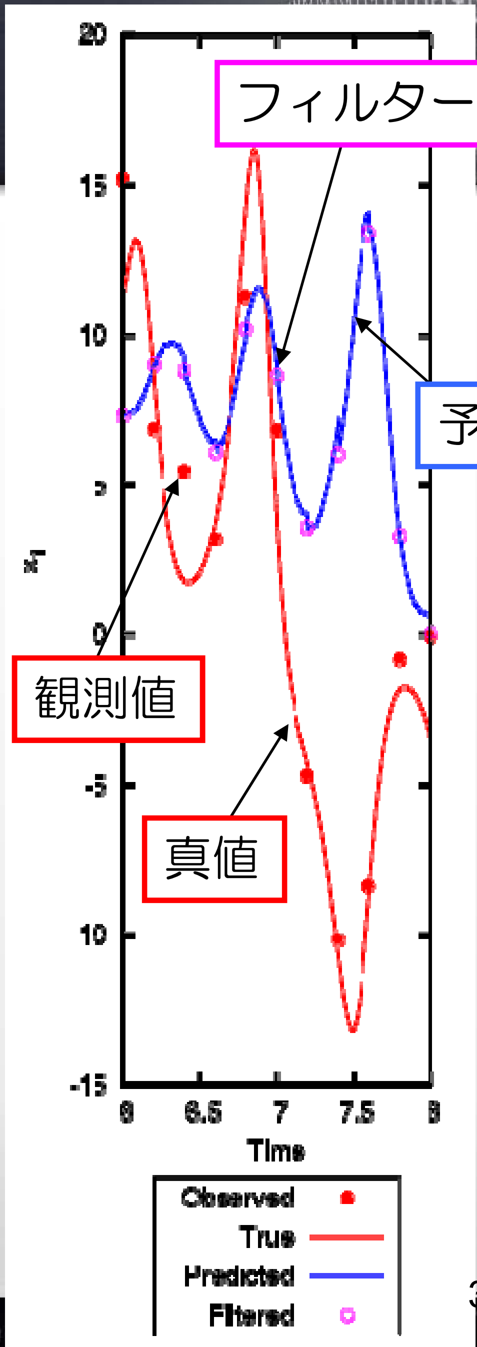
フィルター値
予測値
観測値
真値
Time
Observed
True
Predicted
Filtered

x1 N=8 誤差

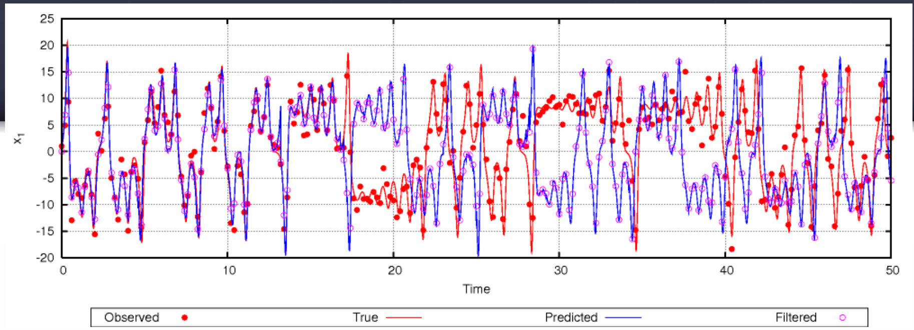

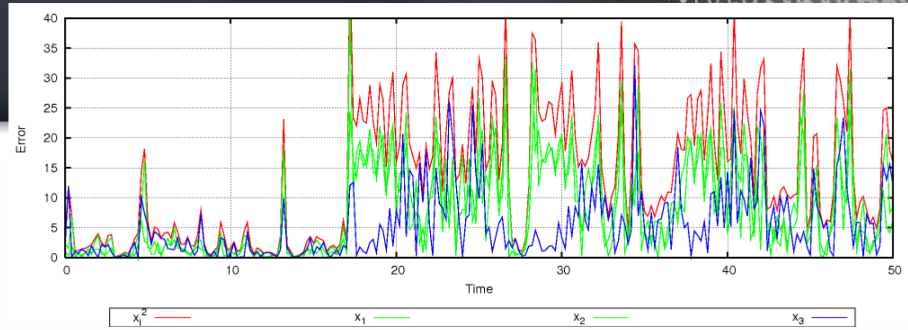

N=32

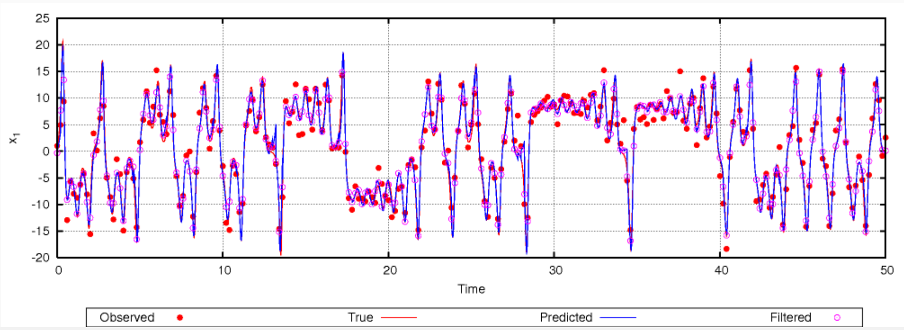

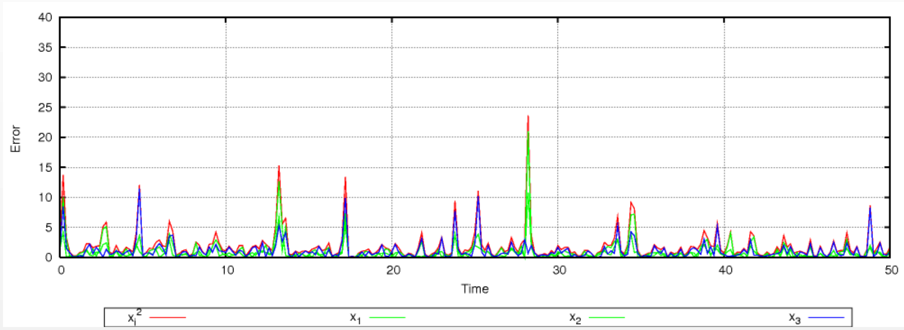

N=4096

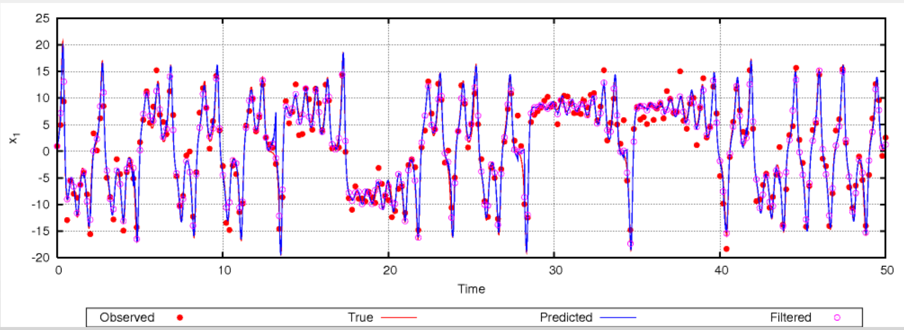

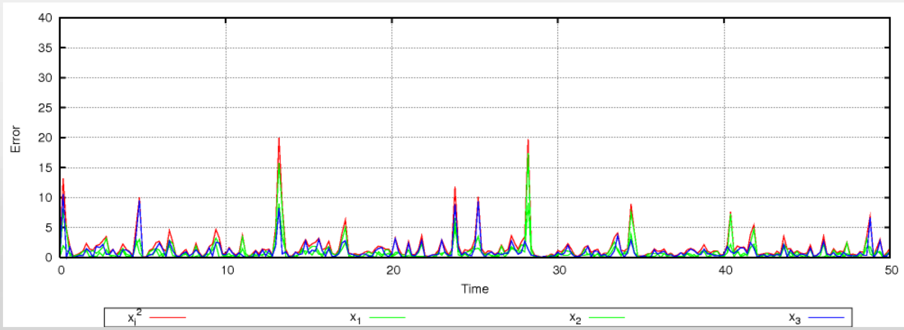

T=25.0, x1の分布

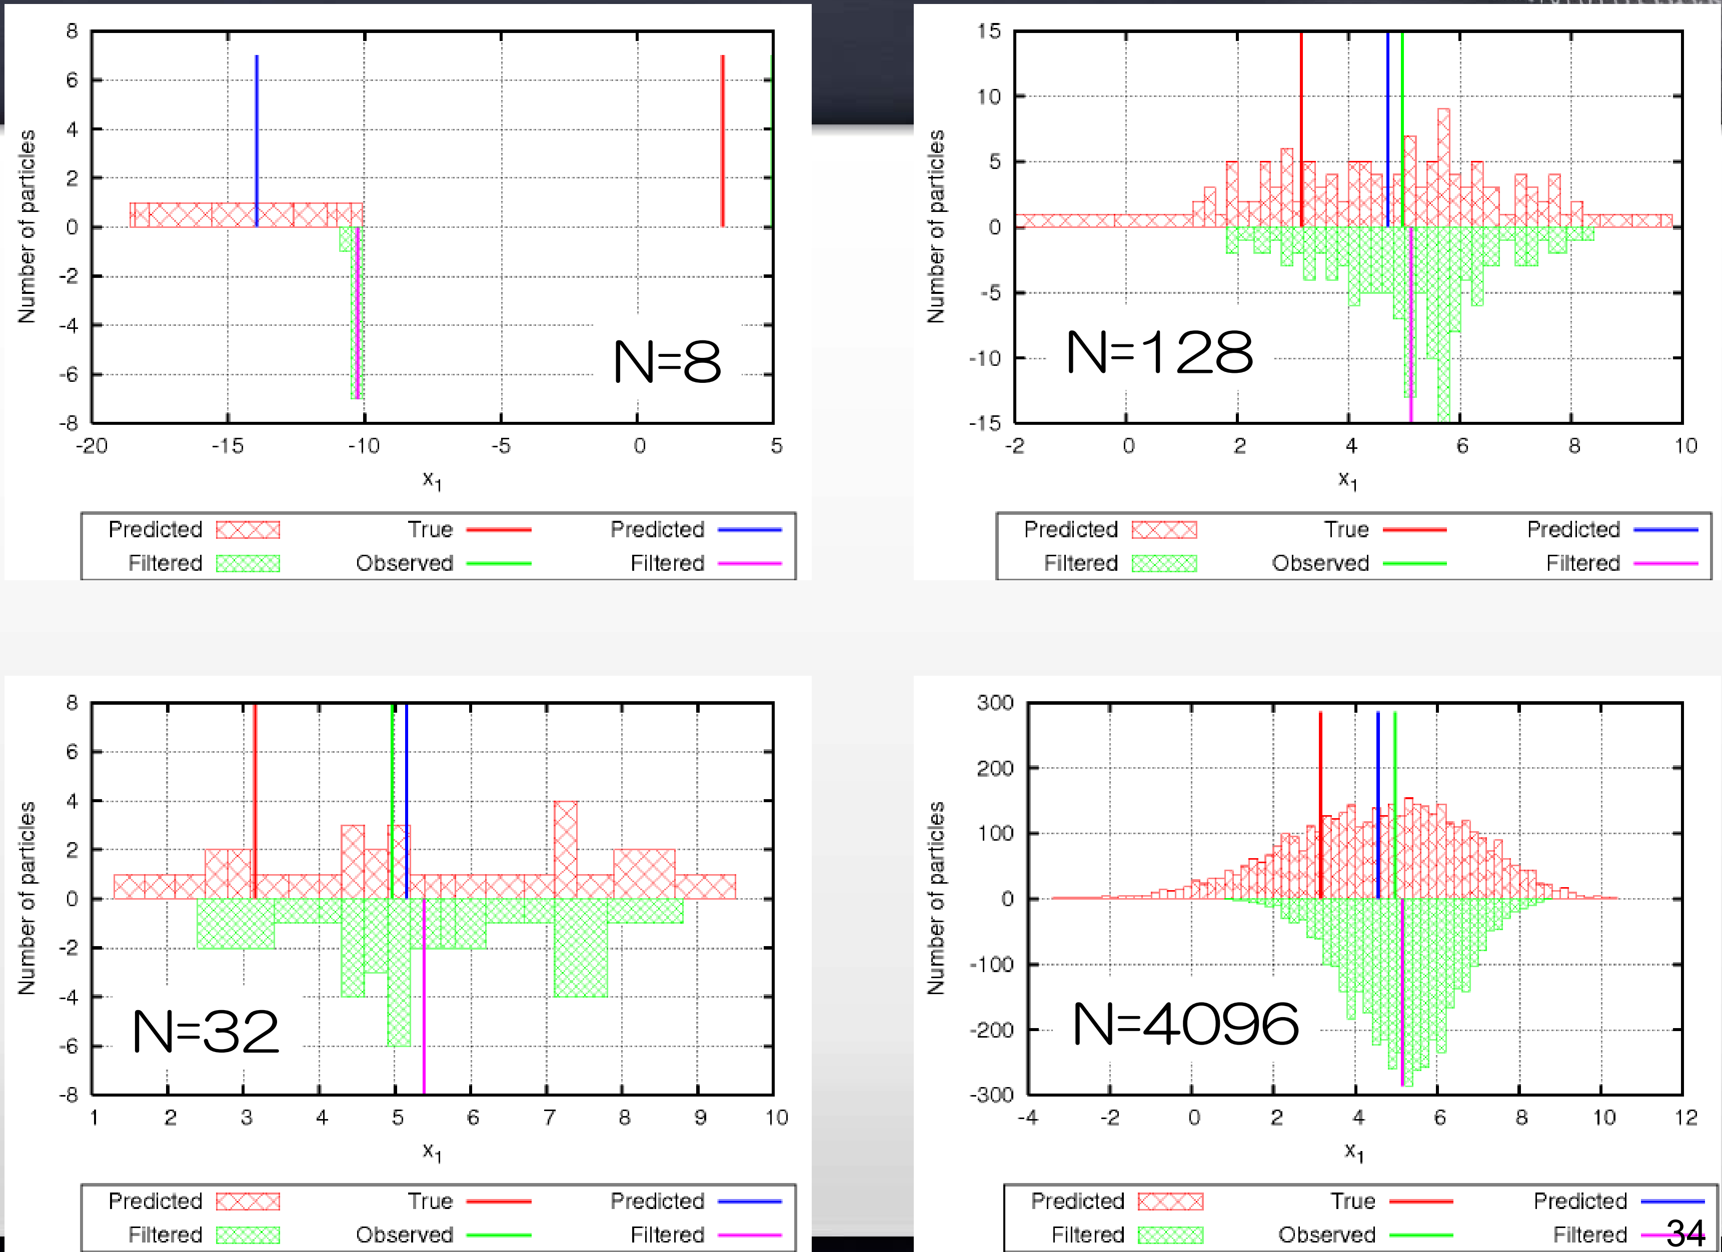
N=8
N=128
N=32
N=4096
Number of particles
x_1
Predicted
True
Predicted
Filtered
Observed
Filtered

解の分岐

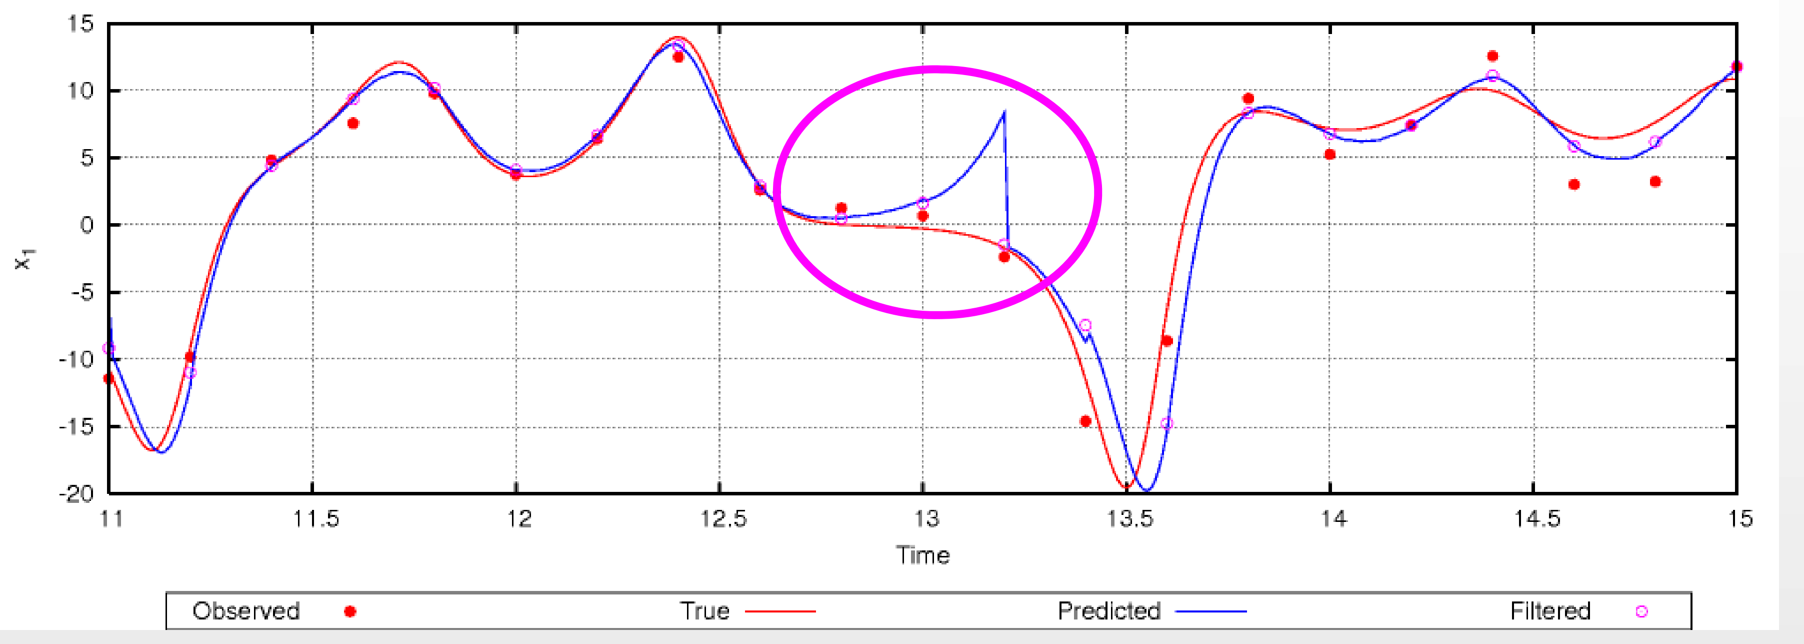

15
10
5
0
-5
-10
-15
-20
x_1
11
11.5
12
12.5
13
13.5
14
14.5
15
Time
Observed
True
Predicted
Filtered

Lorenz63モデルで双子実験

$$\frac{dx_1}{dt} = -s(x_1 - x_2)$$
$$\frac{dx_2}{dt} = rx_1 - x_2 - x_1x_3$$
$$\frac{dx_3}{dt} = x_1x_2 - bx_3$$

- x3のみ観測した場合(N=4096)
  - x1の精度が悪化

解の分岐

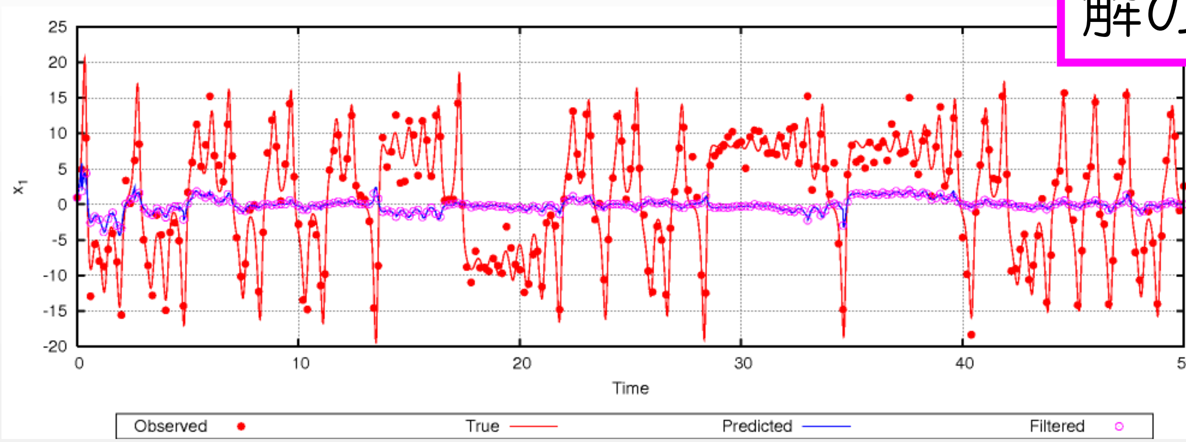

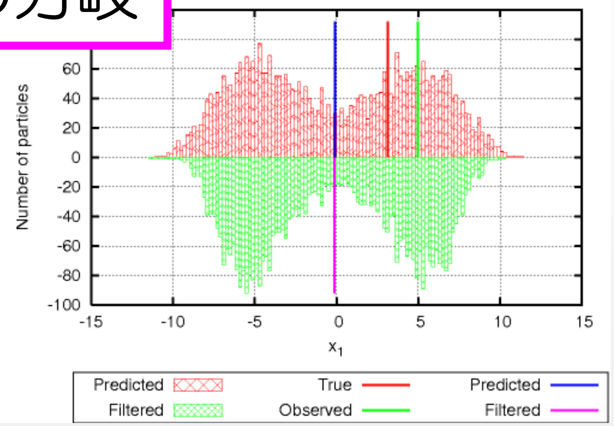

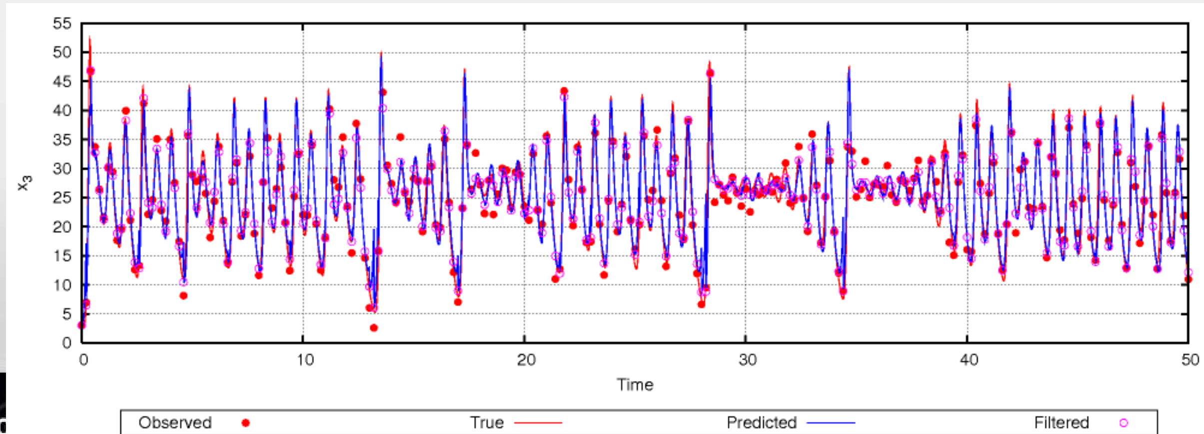

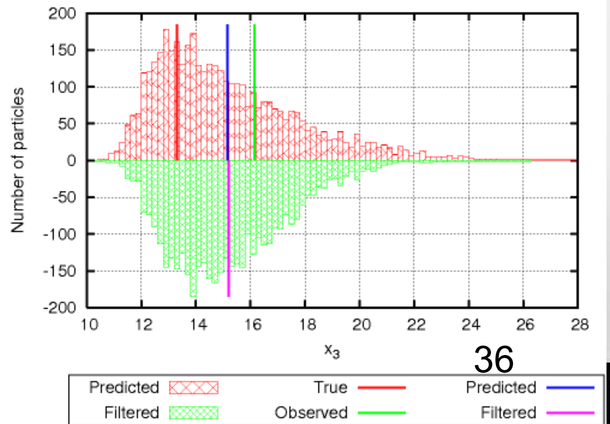

データ同化のさわり

データ同化のさわり

- 状態空間モデル
- 確率分布
- 逐次データ同化手法
  - カルマンフィルター：KF
  - アンサンブルカルマンフィルター：EnKF
  - 粒子フィルター：PF

状態空間モデル

- シミュレーションモデルに「遊び」を許し、観測データの情報を取り込む自由度を持ったものへ拡張する：システムモデル

$$x_t = f_t\left(x_{t-1}\right)$$

- シミュレーションモデルと観測データの間にも自由度を持った関係を構築する：*観測モデル*

$$y_t = h_t\left(x_t\right)$$

- 上記の*システムモデル*＋*観測モデル*を合わせて*状態空間モデル*と言う。

状態空間モデル

- データ同化：状態変数 x_t を推定する問題
- 状態空間モデル：システムモデル＋観測モデル

$$x_t = f_t(x_{t-1}) \rightarrow x_t \sim f_t(x_{t-1}) \rightarrow x_t = f_t(x_{t-1}) + v_t$$

$$y_t = h_t(x_t) \rightarrow y_t \sim h_t(x_t) \rightarrow y_t = h_t(x_t) + w_t$$

x_t ： 状態変数

y_t ： 観測値

v_t ： システムノイズ（シミュレーションの不確定部分）

w_t ： 観測ノイズ（観測とモデルの差：$y_t - h_t(x_t)$）

利用する概念

- 確率分布

$p(A)$	:	A が起きる確率
$p(A\|B)$	:	B が起こったもとで A が起きる確率 (条件付確率)
$p(A, B)$	:	A と B が同時に起きる確率

- ベイズの定理： $p(B|A) = p(A|B) \cdot p(B)/p(A)$

$$p(A, B) = p(A|B) \cdot p(B) = p(B|A) \cdot p(A)$$

ガウス（正規）分布： $p(x; \mu, \sigma^2)$

- マルコフ性：時間発展において確率が遠い過去には影響しない
  - 直近過去の状態だけに依存する。

ベイズの定理

- あるデータが得られた時、そのデータを反映した下での事後確率（分布）を与える。

事後分布

$$p(X|Y) \equiv \frac{p(Y|X)\cdot p(X)}{p(Y)}$$

事前分布

データが生じる確率

データ分布
（尤度関数）

$$= \frac{p(Y|X)\cdot p(X)}{\int p(Y|X)\cdot p(X)dX}$$

規格化

同時分布

X：表現したい対象
Y：データ

$$\propto \quad p(Y|X)\cdot p(X) = p(Y,X)$$

周辺化

$$p(Y) = \int p(X,Y)dX = \int p(Y|X)\cdot p(X)dX$$

確率分布の導入

- シミュレーションモデル： $x_t = f_t\left(x_{t-1}\right)$
  - 初期状態を $x_0 = x_0^{(1)}$ とする

$$x_1^{(1)} = f_1(x_0^{(1)}), \quad x_2^{(1)} = f_2(x_1^{(1)}), \ldots$$

- 初期状態、モデルが不確かな場合、近似記号でしか表せられない。
  - 初期状態を $x_0 \sim p(x_0)$ とする。

$$x_1 \sim f_1(x_0), \quad x_2 \sim f_2(x_1), \ldots$$

確率分布の導入

- 初期状態、モデルが不確かな場合、確率分布で表現する。$x_t \rightarrow p(x_t)$
  - 決定論的：確率論的にはδ関数で表現でき

$$x_t = f_t\left(x_{t-1}\right) \rightarrow \quad p(x_t|x_{t-1}) = \delta(x_t - f_t(x_{t-1}))$$

  - 初期状態を $x_0 \sim p(x_0)$、シミュレーションモデルによる状態遷移の確率分布を $p(x_t|x_{t-1})$ とすると

$$p(x_1) = \int p(x_0, x_1)dx_0 = \int p(x_1|x_0)p(x_0)dx_0, \ldots$$

$$p(x_t) = \int p(x_t|x_{t-1})p(x_{t-1})dx_{t-1}$$

確率分布の導入

- モデルと観測の比較：$y_t = h_t(x_t)$
  - 点と点の突合せ
  - 点と分布の突合せ

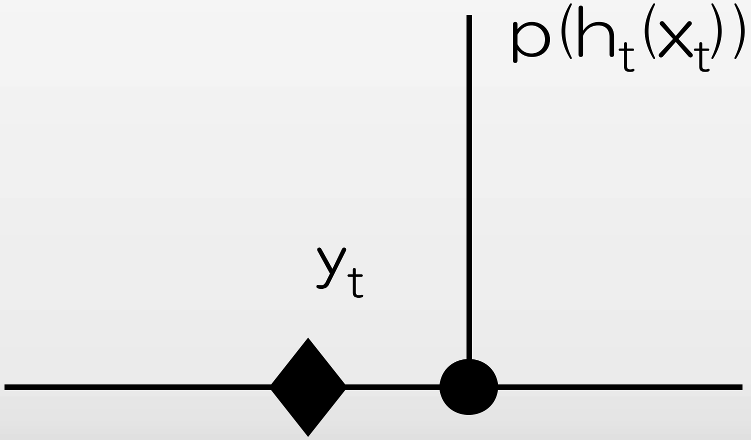

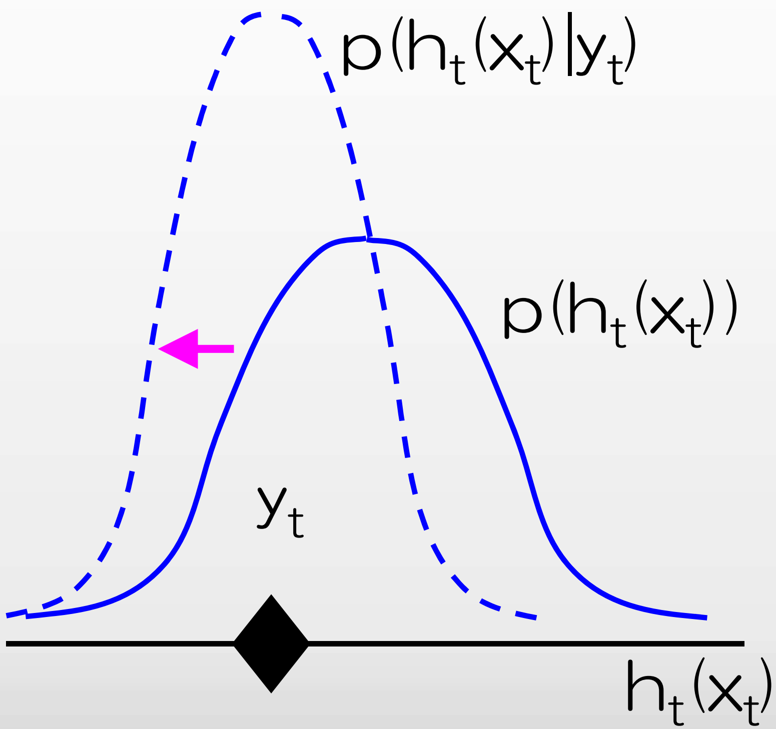

$h_t(x_t)$の確率分布はy_tと整合的か？
$h_t(x_t)$の確率分布にy_tを反映して推定精度を上げる

(一般)状態空間モデルと確率分布

$$x_t = f_t(x_{t-1}) + v_t : \text{システムモデル}$$

$$y_t = h_t(x_t) + w_t : \text{観測モデル}$$

- マルコフ性により確率分布が簡略化
  - 逐次解析の場合便利

$$p(x_t | x_{1:t-1}, y_{1:t-1}) \Rightarrow p(x_t | x_{t-1}) : \text{システムモデル}$$

$$p(y_t | x_{1:t}, y_{1:t-1}) \Rightarrow p(y_t | x_t) : \text{観測モデル}$$

利用する確率分布

$$p(x_j|y_{1:i}) \Rightarrow (j|i)$$

- 予測分布：$p(x_t|y_{1:t-1})$
  - 昨日までのデータに基づく今日の状態
- フィルタ分布：$p(x_t|y_{1:t})$
  - 今日までのデータに基づく今日の状態
- 平滑化分布：$p(x_t|y_{1:T})$
  - 数年後のデータに基づく今日の状態

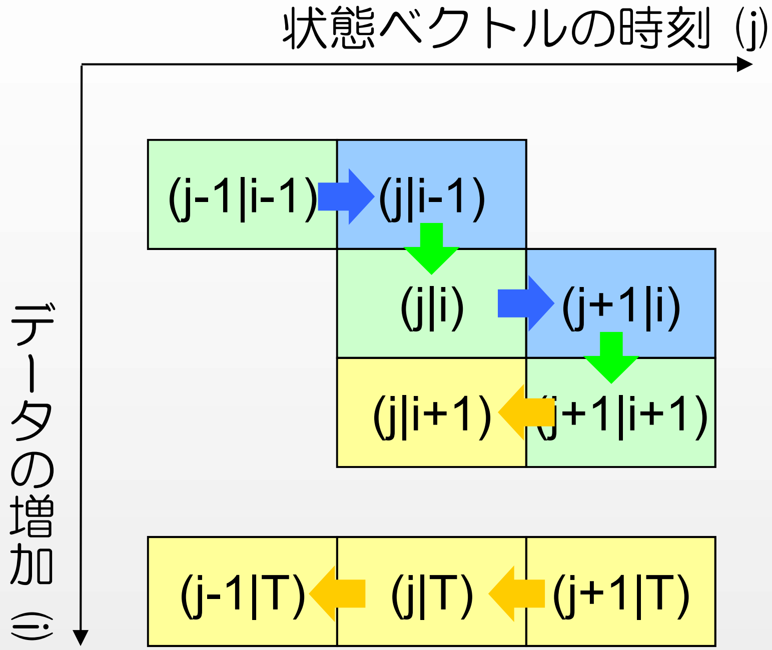

データ同化とは
上記を求めること

$$
\begin{aligned}
\boxed{p(x_t|y_{1:t-1})} &= \int p(x_t, x_{t-1}|y_{1:t-1})\, dx_{t-1} \\
&= \int p(x_t|x_{t-1}, y_{1:t-1})\, p(x_{t-1}|y_{1:t-1})\, dx_{t-1} \\
&= \int p(x_t|x_{t-1})\, \boxed{p(x_{t-1}|y_{1:t-1})}\, dx_{t-1}
\end{aligned}
$$

カルマンフィルタ

- 線形・ガウス状態空間モデル：
$$\begin{aligned} x_t &= F_t x_{t-1} + G_t v_t \\ y_t &= H_t x_t + w_t \end{aligned}$$
  - 以下の仮定が成立する場合
    - システムモデル、観測モデルが線形
    - システムノイズ、観測ノイズがガウス分布
    - 初期のフィルター分布もしくは一期先予測分布がガウス分布
  - 予測分布、フィルター分布が全てガウス分布
    - ガウス分布の平均と分散共分散行列の逐次更新
  - カルマンフィルタ、カルマンスムーザ
    - 線形・ガウス状態空間モデルに対する、予測分布、フィルター分布、平滑化分布を計算するアルゴリズム

アンサンブルカルマンフィルタ

- 非線形状態空間モデル
  - システムモデルが非線形
  - 観測モデルは線形
    - 状態ベクトルの定義を工夫することで非線形観測モデルにも対応可能

$$\begin{aligned} x_t &= f_t(x_{t-1}, v_t) \\ y_t &= H_t x_t + w_t \end{aligned}$$

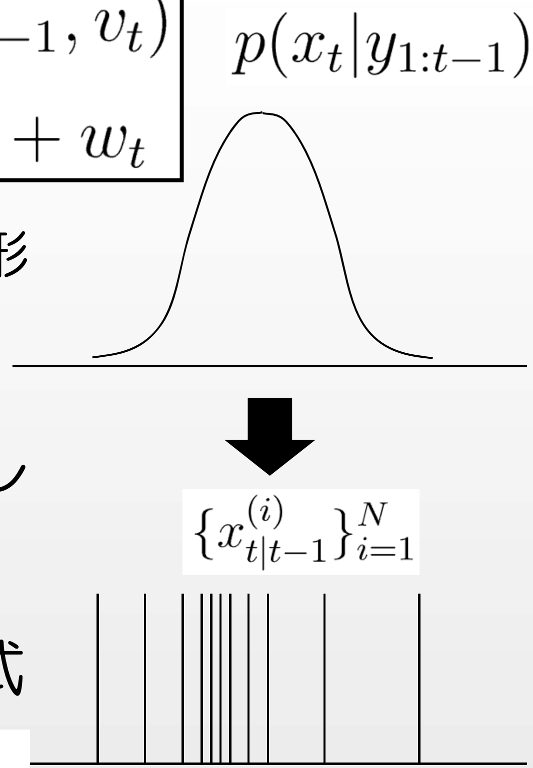

- アンサンブルカルマンフィルタ
  - 条件付分布を実現値のアンサンブルとして近似
    - δ関数を使った近似
  - フィルタリングはカルマンフィルタの式を利用

$$x_{t|t-1}^{(i)} \sim p(x_t|y_{1:t-1}) \sim \frac{1}{N}\sum_{i=1}^{N}\delta(x_t - x_{t|t-1}^{(i)})$$

$$x_{t|t}^{(i)} \sim p(x_t|y_{1:t}) \sim \frac{1}{N}\sum_{i=1}^{N}\delta(x_t - x_{t|t}^{(i)})$$

粒子フィルター(PF)

- より一般的な対象に適用できる。
- フィルタ分布 $p(x_t|y_{1:t})$ のアンサンブルの計算がEnKFと違う
  - 尤度に従って予測アンサンブル $p(x_t|y_{1:t-1})$ を抽出しフィルタアンサンブル $p(x_t|y_{1:t})$ を構成する。：リサンプリング
  - GAと手続き的には同じ
    - GAは最適なx_{opt}を得るのが目的だが、PFは確率分布p(x)の計算を目的とする。
- 並列計算向き
  - 分散共分散行列の計算が不要のため
- システムモデルが巨大な場合は不向き

PF:確率密度分布

- 状態の確率密度分布をアンサンブル（粒子）で近似する

$$x_{t|t-1}^{(i)} \sim p(x_t | y_{1:t-1}) \sim \frac{1}{N} \sum_{i=1}^{N} \delta(x_t - x_{t|t-1}^{(i)})$$

$$x_{t|t}^{(i)} \sim p(x_t | y_{1:t}) \sim \frac{1}{N} \sum_{i=1}^{N} \delta(x_t - x_{t|t}^{(i)})$$

粒子フィルター（PF）の手順

1. 初期粒子を作成 $\left\{x_{0|0}^{(i)}\right\}_{i=1}^{N}$

くりかえし

2. 一期先予測 $\left\{x_{t|t-1}^{(i)}\right\}_{i=1}^{N}$
   ① システムノイズの作成
   ② 時間発展の計算（予測分布）
   $$x_{t|t-1}^{(i)} = f\left(x_{t-1|t-1}^{(i)}\right) + v_t^{(i)}$$

3. フィルタリング　←　EnKFとの差異
   ① 尤度の計算
   $$l_t^{(i)} = p\left(y_t | x_{t|t-1}^{(i)}\right)$$
   ② リサンプリング（フィルタ分布）$\left\{x_{t|t}^{(i)}\right\}_{i=1}^{N}$