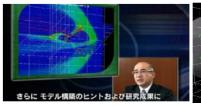
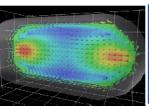
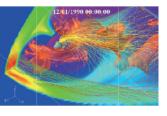
データ同化による エミュレータ・デザイン学の創設

樋口知之 (情報・システム研究機構 統計数理研究所)







1/28

新 統計数理研究所

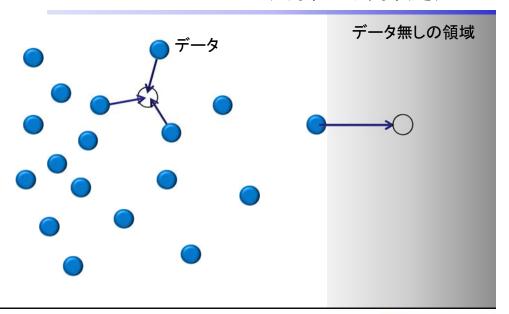
アウトライン

何度も講演

- 内挿と外挿
- データ同化
- 実例: 地震音波とバイオイメージング
- エミュレータ
- スパース回帰(気象予測)
- オンライン機械学習
- GPR: ガウス過程回帰

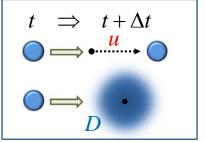
2/28

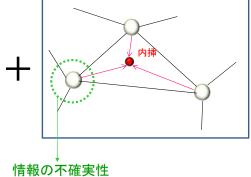
内挿と外挿問題



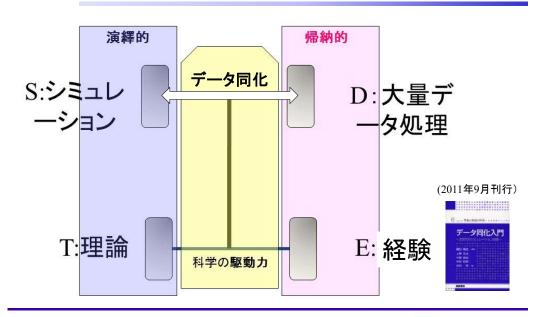
いろいろなビジネス展開が可能

移流と拡散 + クラウドソーシング = 予測能力 フォワード計算モデル 現況を捉える認識力 スマホ(とGPS)





つなぐ:データ同化



5/28

データ同化の目的:気象・海洋学の観点から

- [1] <u>予報を行うための最適な<mark>初期条件</u>を求める。これは既に、現業の天気予報で実用化されていることである。</u></mark>
- [2] シミュレーションモデルを構成する際の<u>最適な境界条件</u>を求める。連成現象を取り扱う際の適応的な境界条件設定もこの作業に含まれる。
- [3] スケールが異なるシミュレーションモデル間の橋渡しを行うスキーム内に含まれる<u>諸パラメータの最適な値</u>を求める。経験的に与えられるモデル内のパラメータ値の検証も一つの具体例である。
- [4] シミュレーション(物理)モデルにもとづいた、<u>観測されていない</u>時間・空間 点における<u>観測値の補間</u>を行う。この作業は<mark>再解析データセット</mark>の生成とも 呼ばれる。このデータセットから新しい科学的発見をもくろむ。 _{ダウンスケーリング}
- [5] 時間・経費を節約できる<mark>効率的な観測システムを構築</mark>するための<u>仮想観測</u> ネットワークシミュレーション実験や感度解析を行う。

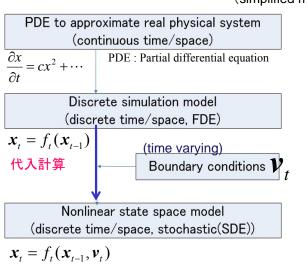
(参考文献: 蒲地 他、「統計数理」、54(2), 223-245, 2006.)

6/28

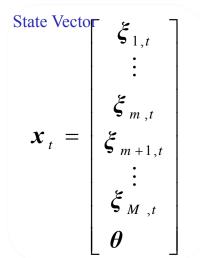
新計数理研究所

システムモデルとしてのシミュレーションモデル

(simplified meteorological model around Japan)



7/28



データ同化と一般状態空間モデル

State Vector (Simulation variables) $x_{t} = f_{t}(x_{t-1}, v_{t}), \quad v_{t} \sim p(v \mid \theta_{\text{sys}})$ $y_{t} = h_{t}(x_{t}, w_{t}), \quad w_{t} \sim p(w \mid \theta_{\text{obs}})$

気象・海洋のデータ $m{y}_t = m{H}_t m{x}_t + m{w}_t, m{w}_t \sim N(0, R_{
m obs})$ Δt : sampling time of observations

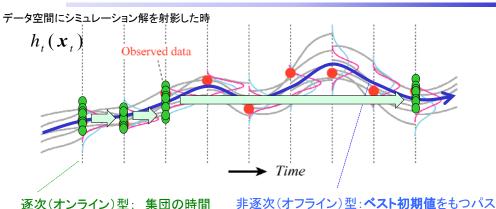
Observation model

Measurement model
観測モデル

 Δt : sampling time of observations δt : simulation time step $\Delta t = 1 >> \delta t$

time integration

逐次(アンサンブル) vs. 非逐次(最適パス)



逐次(オンライン)型:集団の時間 発展を追う。つまり、Swarm Filter

代表例: EnKF (Ensemble Kalman

代表例: 4次元变分法(Adjoint法)

9/28

Filter)

統計数理研究所

Our interest in a statistical inference by DA

■ State Estimation and forecasting $p(x_{t} | y_{1:t})$ or $p(x_{t} | y_{1:T})$

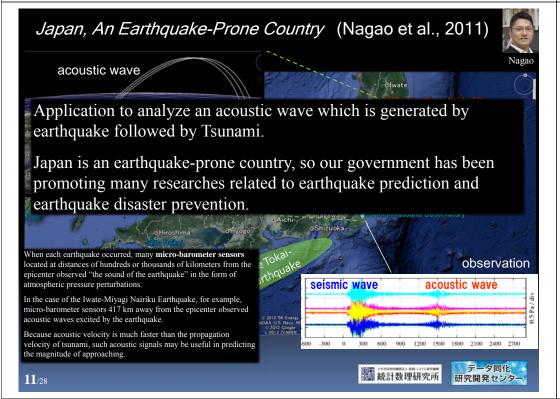
状態(時刻依存)変数の推定

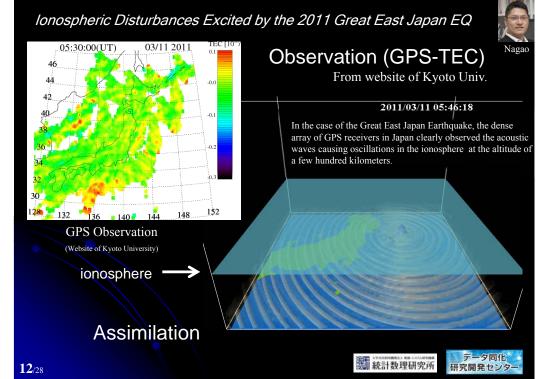
Parameter Estimation in a simulation model

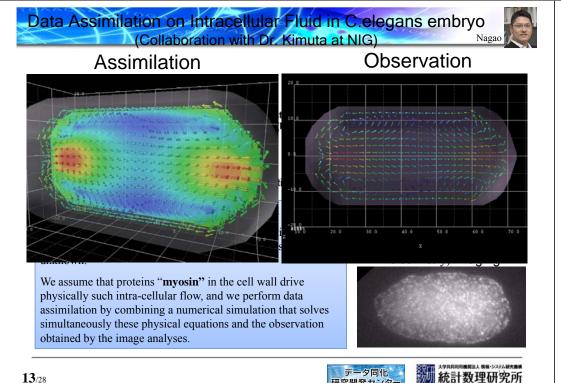
$$\frac{p(\theta \mid y_{1:T}) \propto p(y_{1:T} \mid \theta) \cdot p(\theta)}{$$
モデルパラメータの推定

 $\theta \Rightarrow \mathbf{x}_0$ 4DVar

10/28







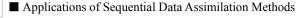
Video (10min) uploaded to YouTube Introduction to R&D Center for Data Assimilation



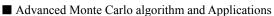
Research Projects

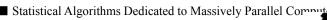
Methods:

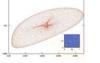




- Meteorology
- Space Science
- Life Science









Hardware:

Hardware Random Number Generators





Computational Services:

■ Statistical Analysis System for Massively Parallel Computing Enviro



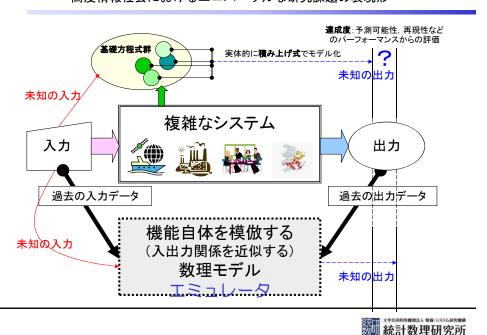
- Cloud Computing Services
- Visualization Software

14/28

機能のモデル化:エミュレータ

研究開発センター

高度情報社会におけるユニバーサルな研究課題の表現形



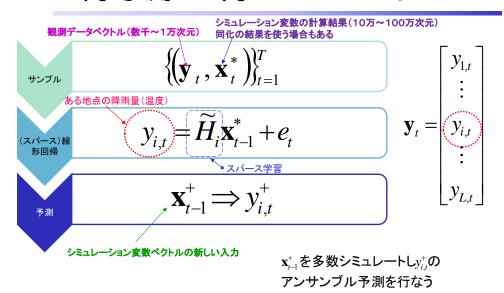
機能のモデル化: "見よう見まね"を科学する

- "見よう見まね"のプロセスを加速する。
 - 一体系化されていない研究分野において有効
- ・"見よう見まね"による完成の域がお手本を超える。
 - 一贋作が"本物"を超える

日本人は伝統的に"贋作"を心から嫌う傾向が強いが、同 じく漢字文化圏にある中国人で心ある人は、過去の文物に 目を転じるとき、それがたとえ"贋作"であろうと判断できて も、"本物"を超える出来栄えであるならば、自分の心と目 を満足させるため、"本物"以上にその"贋作"を尊重して手 に入れると伝えられている。

"贋作"と"本物"の、どちらが本物か実は分からない

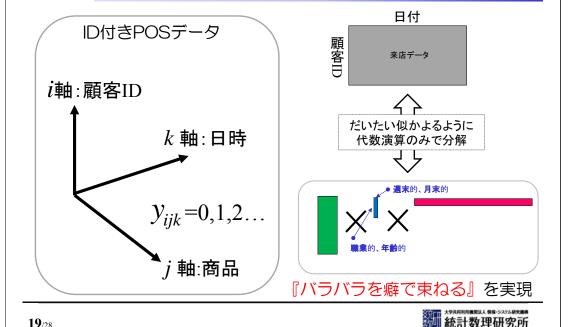
気象予測:気象エミュレータ



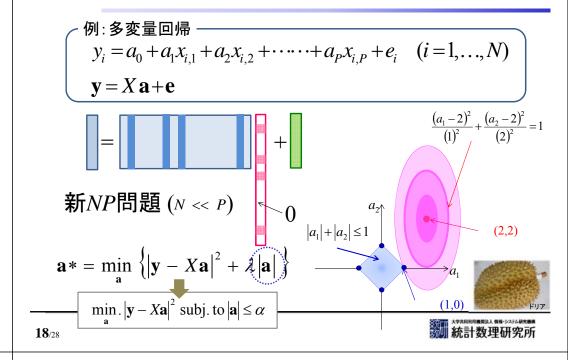
17/28

統計数理研究所

減らす2. 行列、テンソル分解



減らす1. スパース(疎性を利用した)最適化



ストリーミング計算



データは現場で産出。移動は困難。

Edge-Heavy Data (РFI, 丸山@ISM)

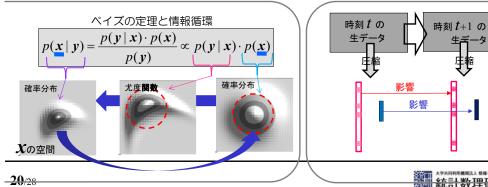


トラフィックの大渋滞

✓ パラメータ(w)オンライン学習法

✓ スパース学習

FOBOS: Forward Backward Splitting RDA: Regularized Dual Averaging

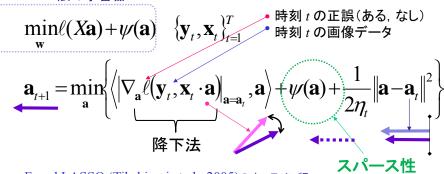


オンライン計算 in 機械学習

パラメータ(a)オンライン学習法

FOBOS: Forward Backward Splitting RDA: Regularized Dual Averaging

一般の学習器

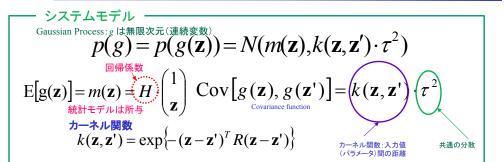


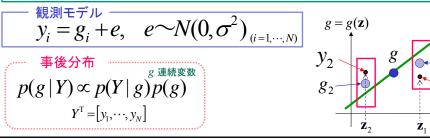
Fused LASSO (Tibshirani et al., 2005)のオンライン版

21/28

統計数理研究所

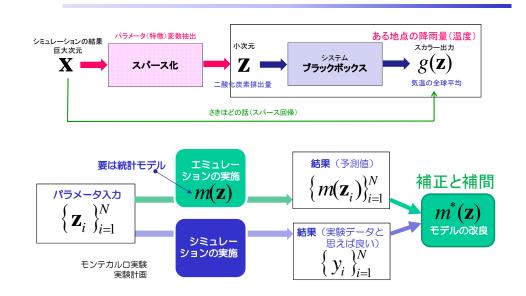
エミュレータ:統計モデル(要は、線形回帰モデル+GP)





エミュレータ:

シミュレーションパラメータを入力とする出力値を模倣

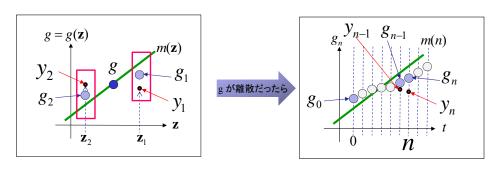


22/28

24/28

統計数理研究所

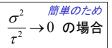
エミュレータ: 時系列のトレンドモデルとほぼ同じ



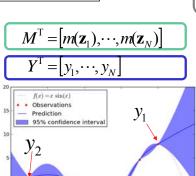
$$\begin{cases} g_n = m(n) + g_{n-1} + v_n, & v_n \sim N(0, \widetilde{\tau}^2) \\ y_n = g_n + e, & e \sim N(0, \sigma^2) \end{cases}$$

$$\begin{cases} y_n = g_n + e, & e \sim N(0, \sigma^2) \\ y_n = g_n + e, & e \sim N(0, \sigma^2) \end{cases}$$

エミュレータ:補正(キャリブレーション)と補間



$p(g(\mathbf{z})|Y) \sim N(m^*(\mathbf{z}), k^*(\mathbf{z}, \mathbf{z}')\tau^2)$



 $m^*(\mathbf{z}) = m(\mathbf{z}) + (Y - M)K^{-1}$

データと統計モデルの差グ

 $\mathbf{t}^{\mathrm{T}}(\mathbf{z}) = [k(\mathbf{z}, \mathbf{z}_{1}), \cdots, k(\mathbf{z}, \mathbf{z}_{N})]$ $k^*(\mathbf{z}, \mathbf{z}') = k(\mathbf{z}, \mathbf{z}') - \mathbf{t}^{\mathrm{T}}(\mathbf{z})K^{-1}\mathbf{t}(\mathbf{z}')$ データがもたらす情報により不確実性は必ず減少する

 $\begin{bmatrix} k(\mathbf{z}_1,\mathbf{z}_1) & \cdots & k(\mathbf{z}_1,\mathbf{z}_N) \end{bmatrix}$

 $k(\mathbf{z}_N, \mathbf{z}_1) \dots k(\mathbf{z}_N, \mathbf{z}_N)$

25/28

統計数理研究所

Tミコレータ: フルベイズへ

簡単のため $\frac{\sigma^2}{\tau^2} \rightarrow 0$ の場合

 $p(g(\mathbf{z})|Y,\tau^2,H) \sim N(m^*(\mathbf{z}),k^*(\mathbf{z},\mathbf{z}')\tau^2)$

 $p(g|Y) = \int p(g|Y,\tau^2,H)p(\tau^2)p(H)d\tau^2dH$ $p(\tau^2)$ $\propto \frac{1}{\tau^2}$, $p(H) \propto 1$

自由度 $N-\lambda$ のt分布

エミュレータ サンプル数 回帰モデル部分 $\lambda = \dim(\mathbf{z}) + 1$

J. Sacks et al., "Design and analysis of computer experiments," Statistical Science, 1989. M. C. Kennedy and A. O'hagan, "Bayesian calibration of computer models," J. Roy. Statist. Soc. Ser. B, 2001. 中野、樋口、"地球科学におけるシミュレーションとビッグデーターデータ同化とエミュレーションー、" 信学

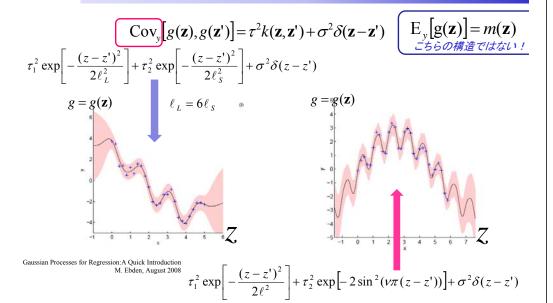
Rasmussen, C. and C. Williams, Gaussian Processes for Machine Learning, MIT Press, 2006

26/28

28/28

統計数理研究所

エミュレータ: カーネル関数の設計(問題毎に与える)



データ同化とエミュレータ

データ同化

- a. 行列分解
- b. ローカル化

機械学習を用いた内挿法

- I. スパース回帰
- II. オンライン学習
- III. カーネル法

ミニ特集「数理科学の展開とその体制」