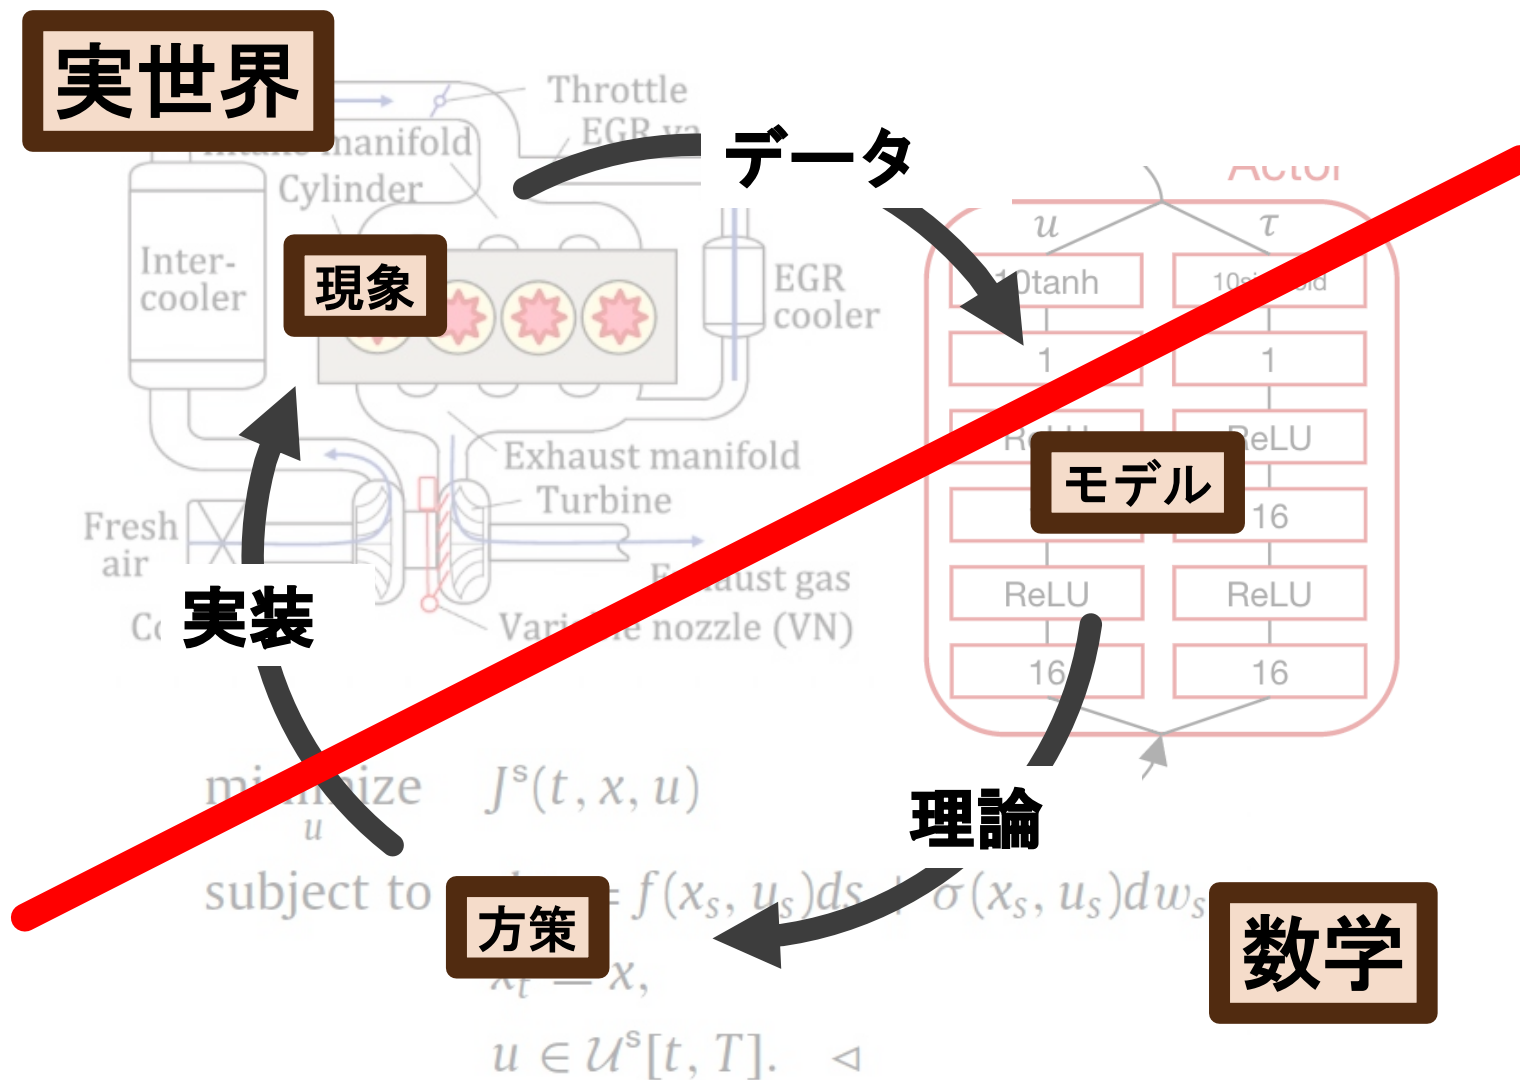


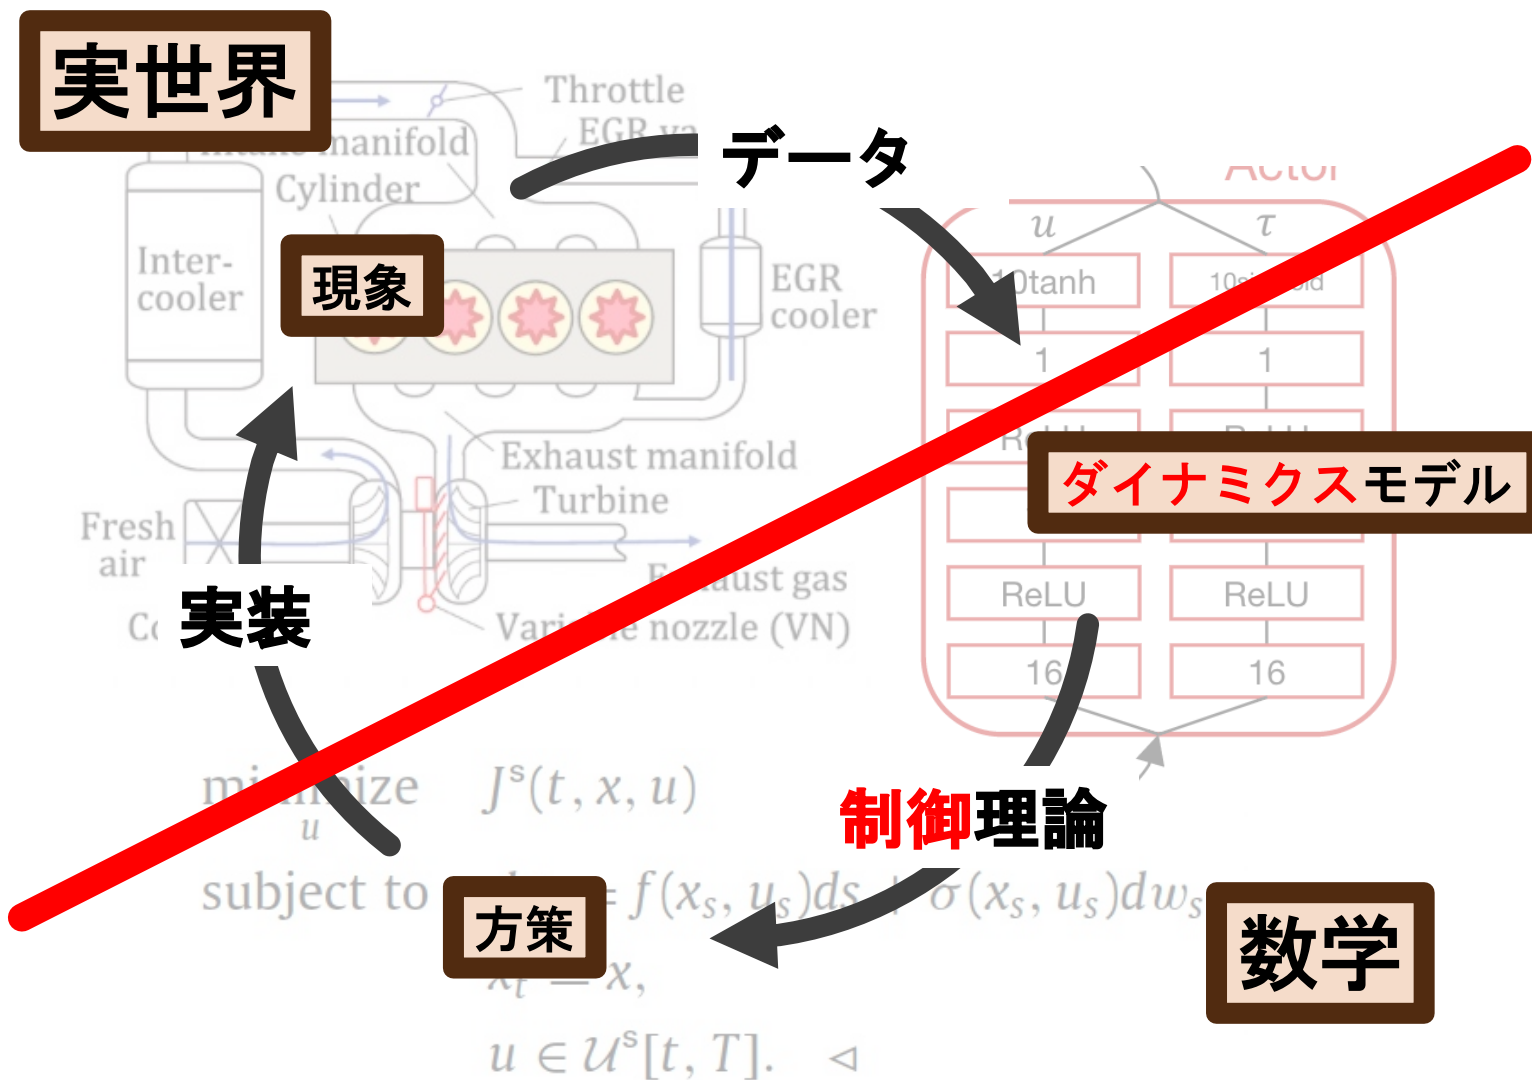
システム制御に使ってみたい 統計的学習の理論と手法

京都大学 情報学研究科 数理工学専攻 加嶋 健司

2022/12/10 Computational Intelligence フォーラム



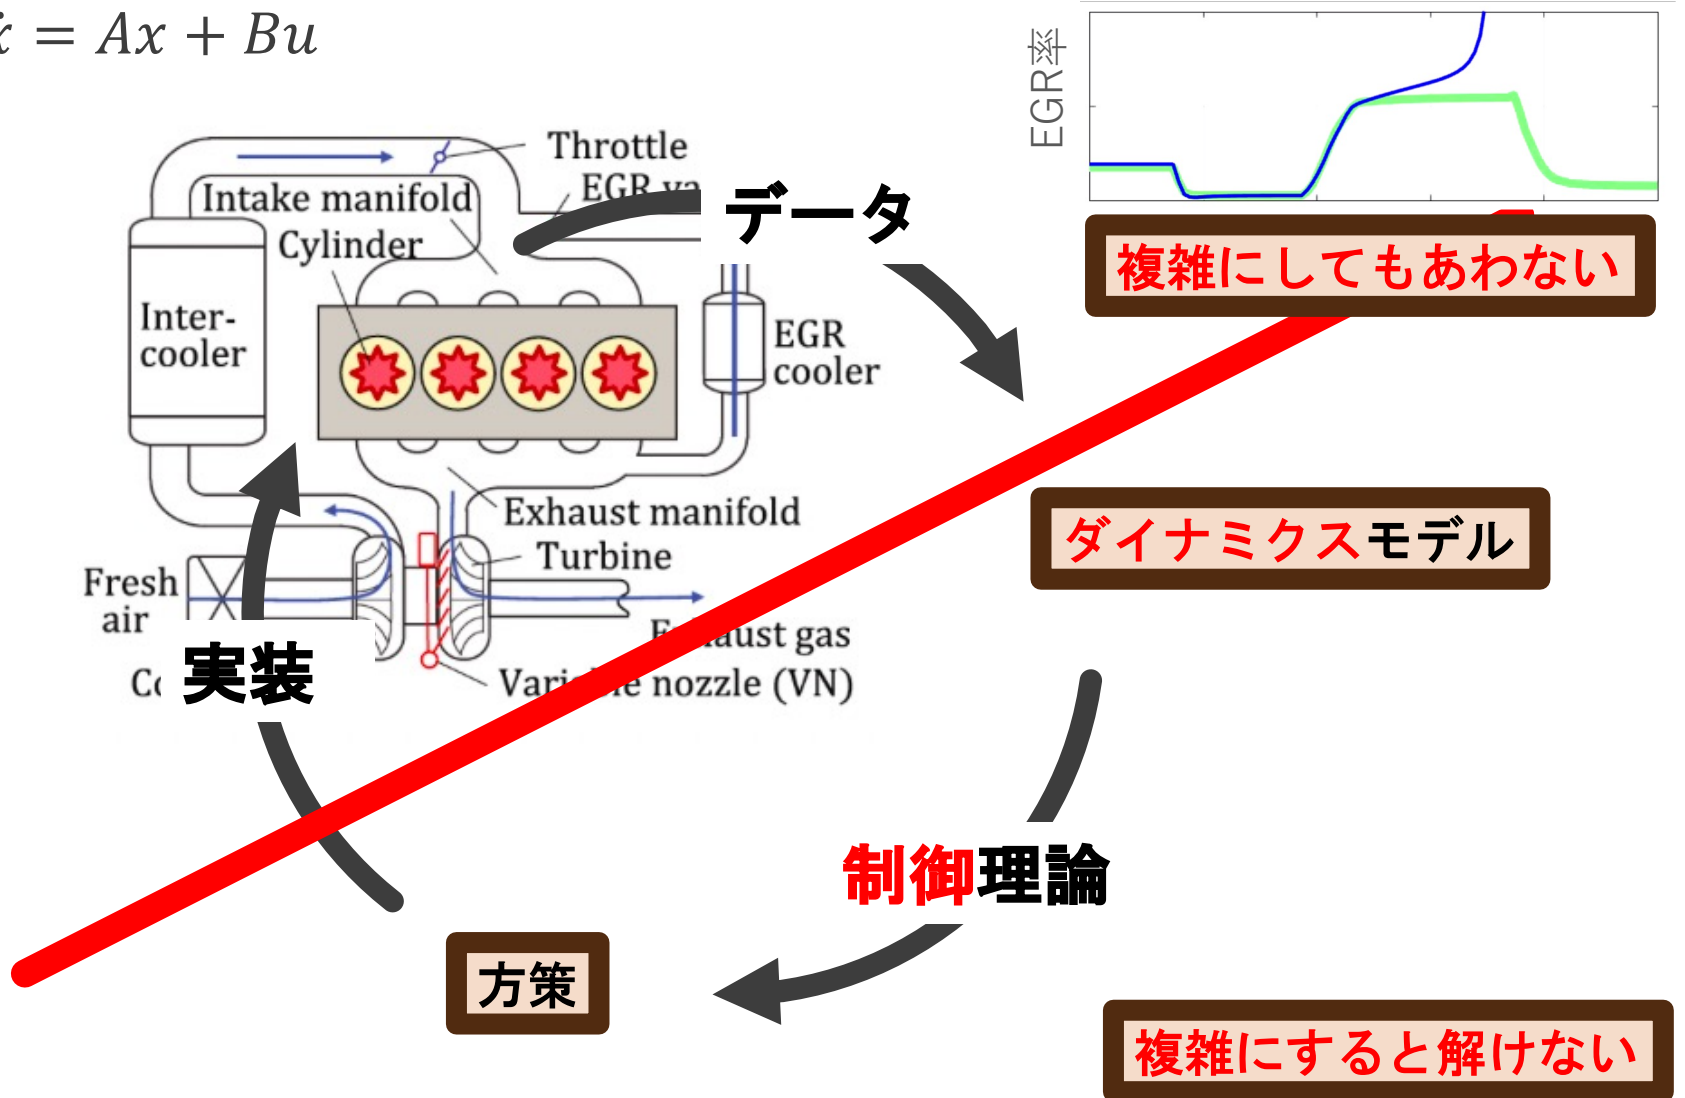
■ 時々刻々と変化する現象



具体例 (エンジン)

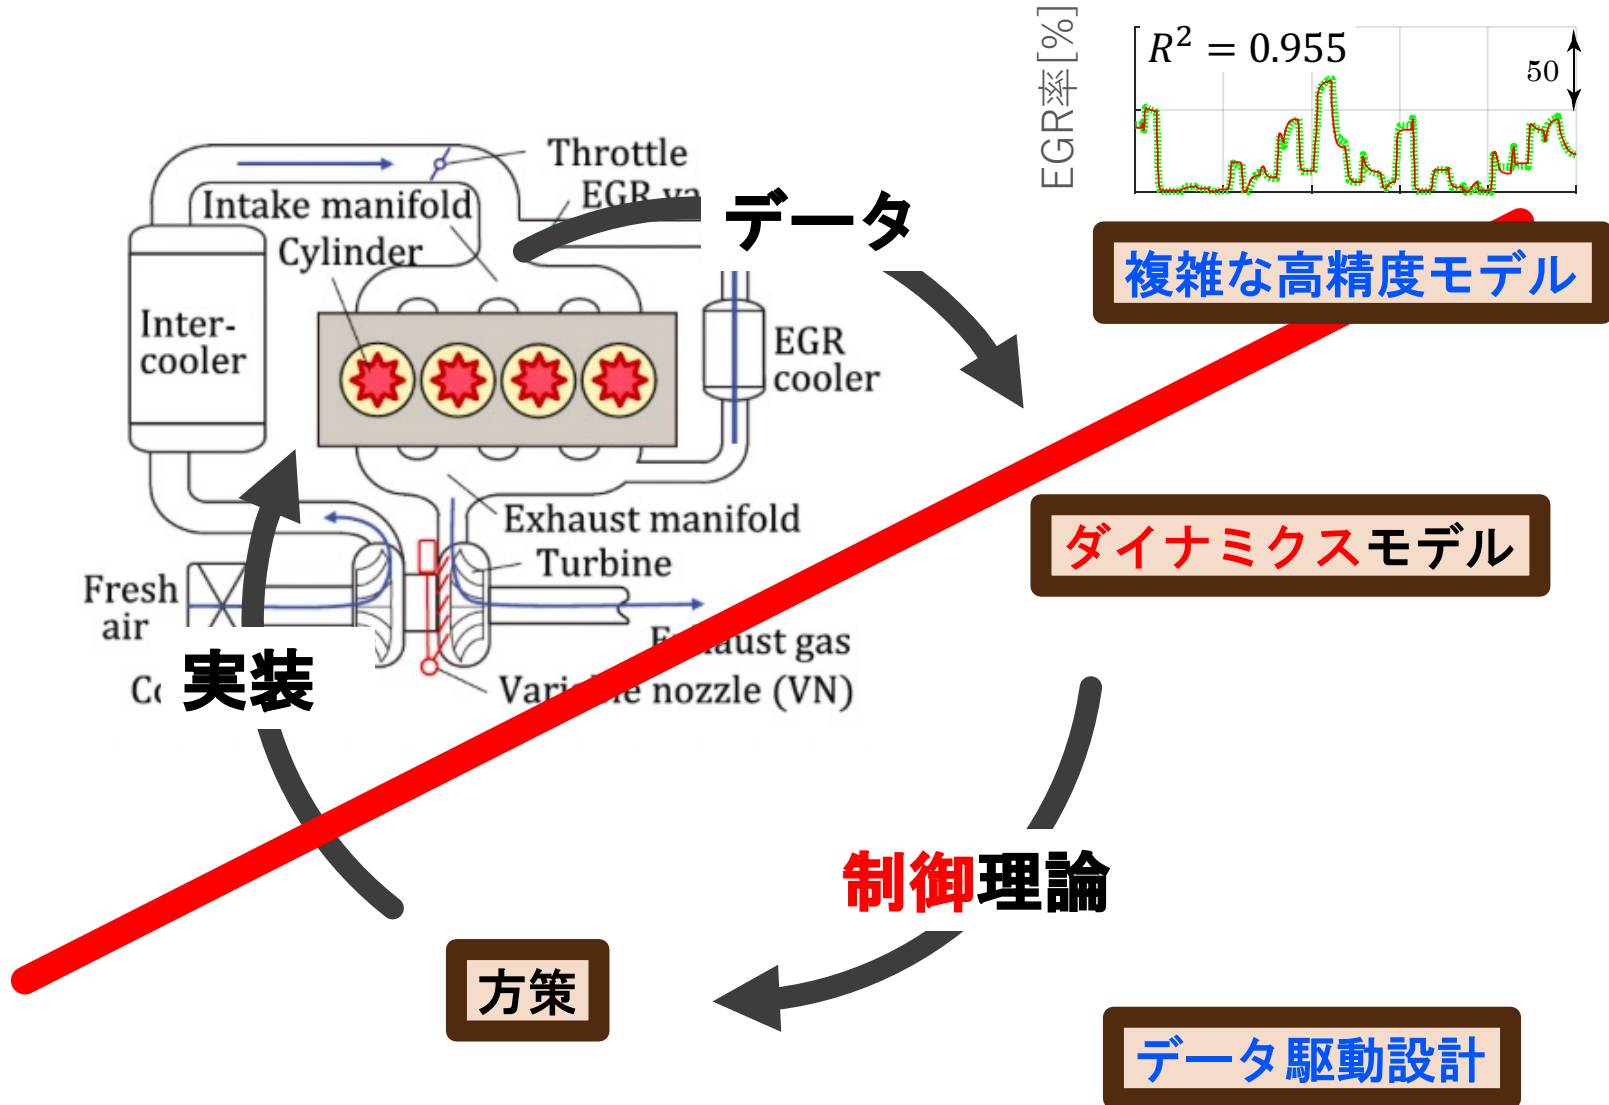
- 簡単なモデルに限らざるを得ないことが多い

➤ $\dot{x} = Ax + Bu$



人工知能ならやってくれるはず...

- ビッグデータと計算機パワーが解決してくれる



■ モデリング

- 誤差最小化問題を定式化し，GPUで勾配法を**実装できる**

■ データ駆動設計

- 最適制御問題を定式化し，GPUで勾配法（強化学習手法）を**実装できる**

■ 個人的な感想

- 期待する結果には程遠い
 - ✓ 対象が線形であっても難しい
 - ✓ 局所最適なのかデータ不足なのか不明
- セイフティクリティカルな応用には受け入れられない
 - ✓ モデルが担保していた安定性・最適性

- それでも私は肯定派です

- 新しい強力なツールとしての機械学習
 - 事前知識やモデルベースト設計の積極的活用
 - **構造付きダイナミクス学習**

- 統計的学習と融合し深化する制御理論
 - 「情報」を陽に扱うことで生まれる異分野との接点
 - **最適輸送と最適制御**

- まとめ

データ以外の情報をいかに取り入れるか

- Physics-informed, Stability-aware, Optimization-oriented

勾配法でぶん殴る

コスト関数
(精度や制御性能)


ドメイン知識の注入

最適解は
ここやで。

ここのは
便利やで。

決定変数



(モデルや制御則のパラメータ)




■ 探索範囲の限定

- グレイボックスモデリング
- 『動的な性質』：安定性、単調性
- 『使い勝手』：凸性
- 『陰関数』：模倣学習

$$x_{k+1} = f(x_k, u_k), y_k = g(x_k)$$




決定変数
(モデルや制御則のパラメータ)



結果①


..... 正解値 — 予測値

Moriyasu, et. al.
(2019)



基本的には良好に予測できるが...

結果②



中には
発散する
条件もある

エンジンは **物理的には安定** だが、その **性質が保存されない**

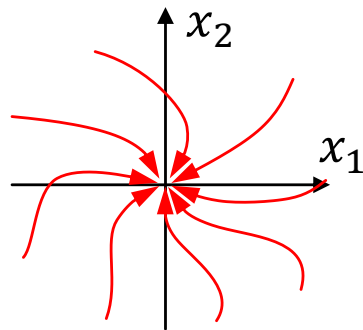
工夫1：ドメイン知識チート

■ 線形モデル & **大変な努力** で高精度モデル

■ 軌道の位相的性質

➤ データから獲得する必要はない

■ 漸近安定 (単一平衡点)




エンジン



その他
大部分の
工業製品


■ 周期変動 (リミットサイクル)



メトロノーム 生物リズム




Badajoz, España




@yb_woodstock


■ 多安定 (複数平衡点)



細胞分化



遺伝子スイッチ





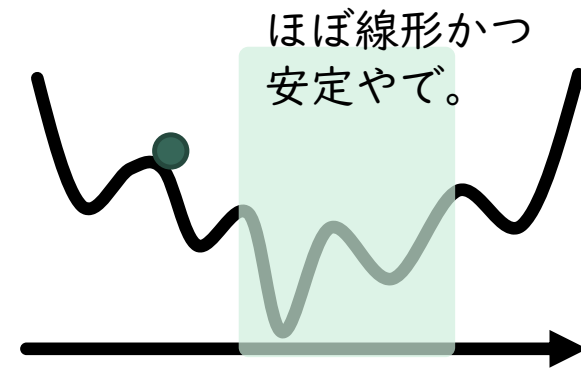
Hall, T.M., et. al. (1995)

■ 線形モデル&座標変換

- 漸近安定性は検証不要，多少の外挿には耐える

■ 微分同相写像のみ深層学習

- Normalizing flowなど



モデル予測制御による実時間最適制御

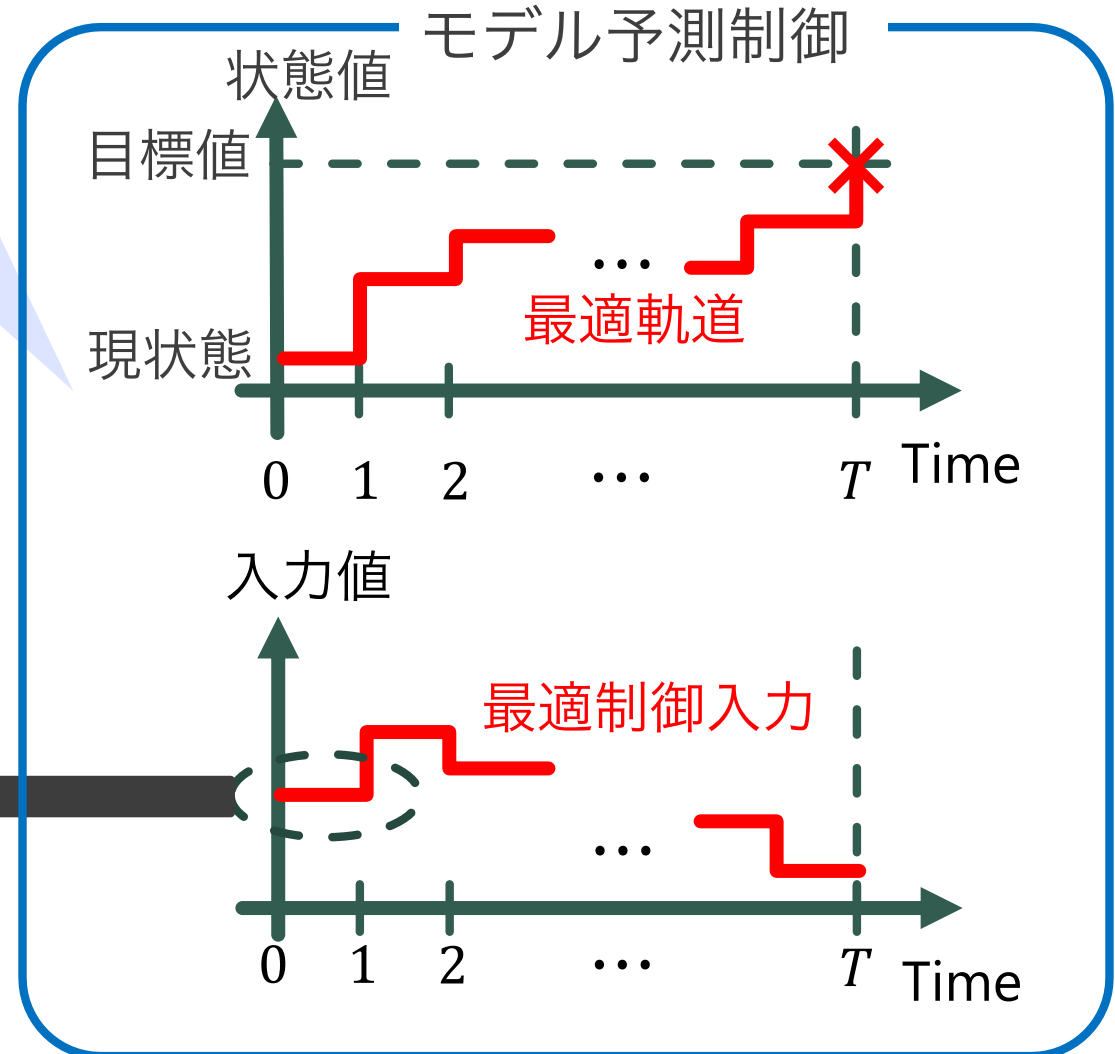
モデル予測制御 (Model predictive control; MPC)

- 「有限時間先の未来までの最適化」を毎時刻行う

$$\begin{aligned} \min_u \quad & \sum_{k=0}^T \ell(x(k), u(k)) \\ \text{s. t.} \quad & x(0) = x^0, \\ & x(k+1) = Ax(k) + Bu(k) \\ & x \in \mathbb{X}, u \in \mathbb{U} \end{aligned}$$



最適系列の初期値を入力

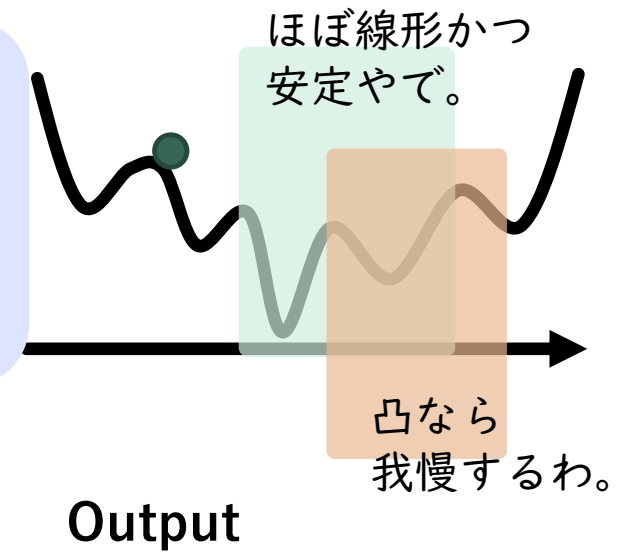


工夫2：モデル予測制御への援護射撃

■ 線形システムの制御問題への変換


- 凸制約であればオンライン最適化可 (数ms)

$$\begin{aligned} \min_u \quad & \sum_{k=0}^T \ell(x(k), v(k)) \\ \text{s. t.} \quad & x(0) = x^0, x \in \mathbb{X}, v \in \mathbb{V} \end{aligned}$$



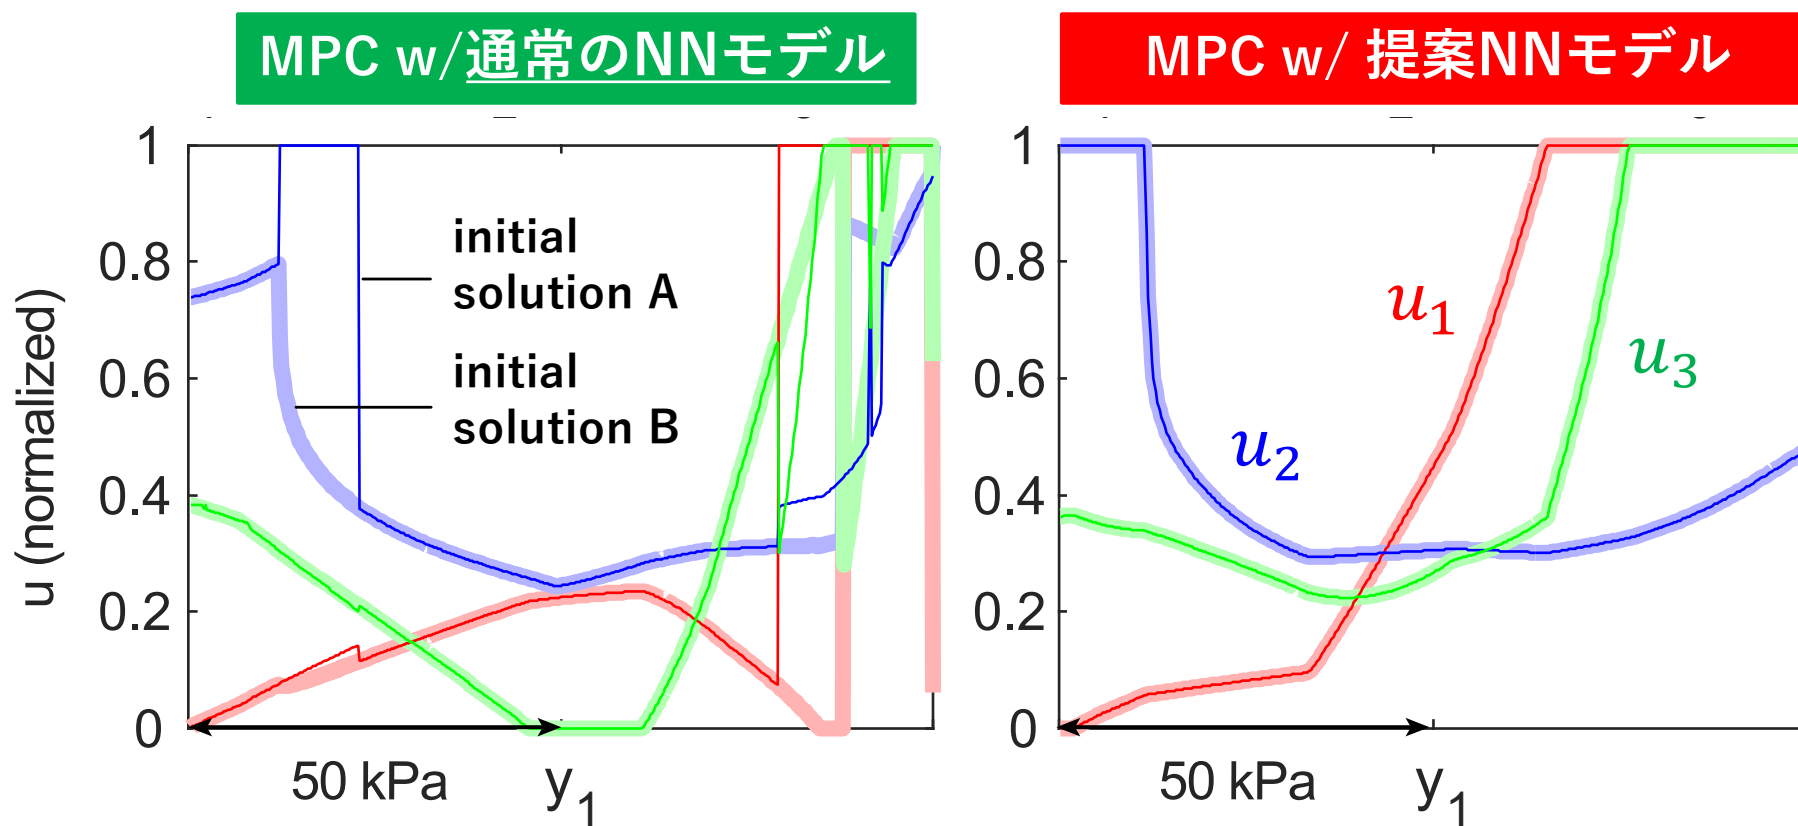
■ 同相写像を凸関数に限定

- Partially Input Convex NN



- 各状態に対して最適制御入力値は一意的かつ連続

現時刻の状態が y のときに、入力すべき u の値

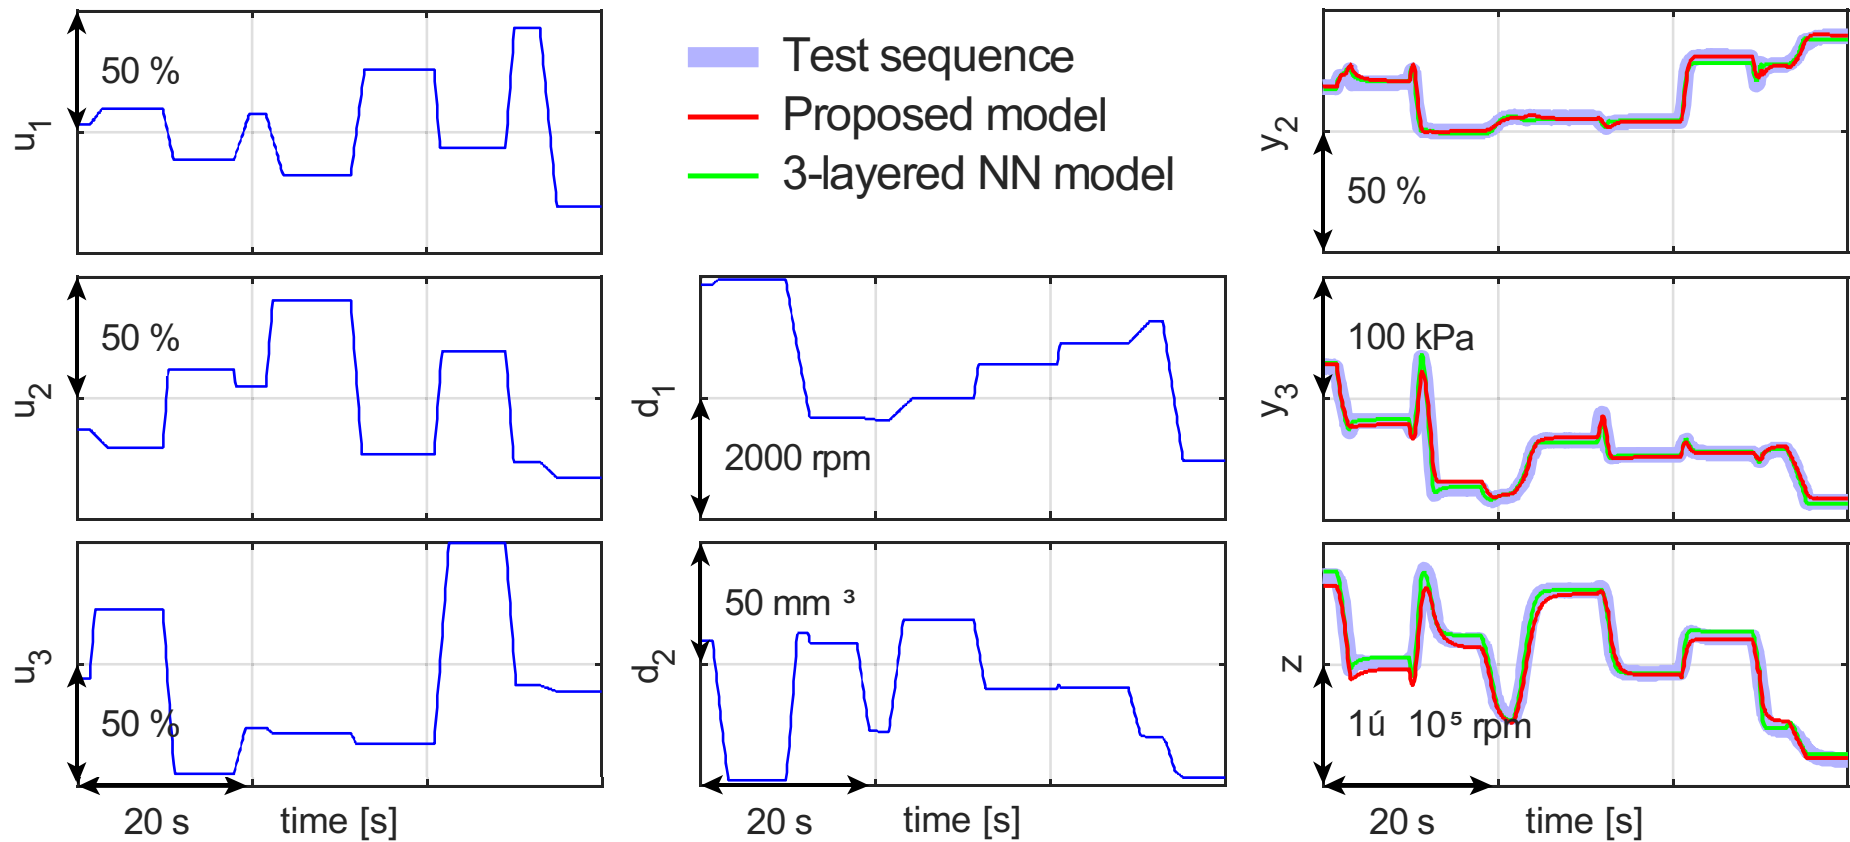


■ モデル精度

➤ おおむね同等

✓ 平均 $R^2 = 0.964$ (3層NN) , 0.967 (提案)

➤ 表現力 VS 正則化



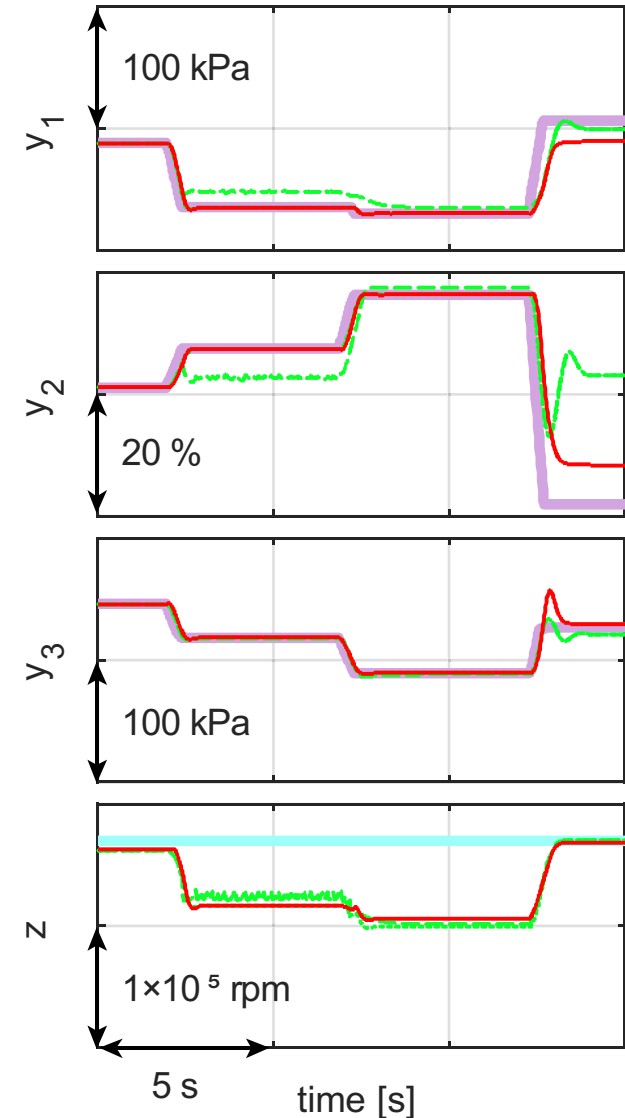
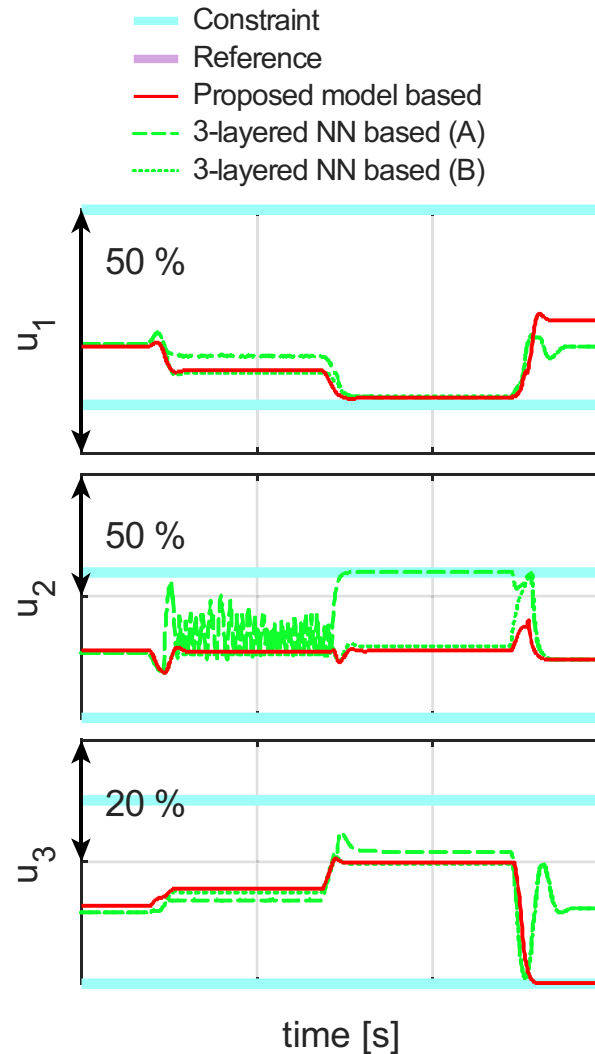
■ 制御シミュレーション

MPC w/ 通常のNNモデル

- ・ 毎時刻解く問題に解の一
意性や滑らかさが保証され
ていないためバタつく


MPC w/ 提案NNモデル

- ・



- 最適制御則からモデルとコストを決定する

線形プラント: 直列MCK系 (2入力2出力)



熟練者


$$U^{\text{expert}} = \underset{U}{\operatorname{argmin}} \sum_{i=1}^2 \left(q_i^e \left(y_{\text{final}}^{(i)} \right)^2 + r_i^e \sum_k \left(u_k^{(i)} \right)^2 \right)$$

最終時刻での原点からの偏差 (最終時刻での原点からの偏差)

入力コスト (入力コスト)



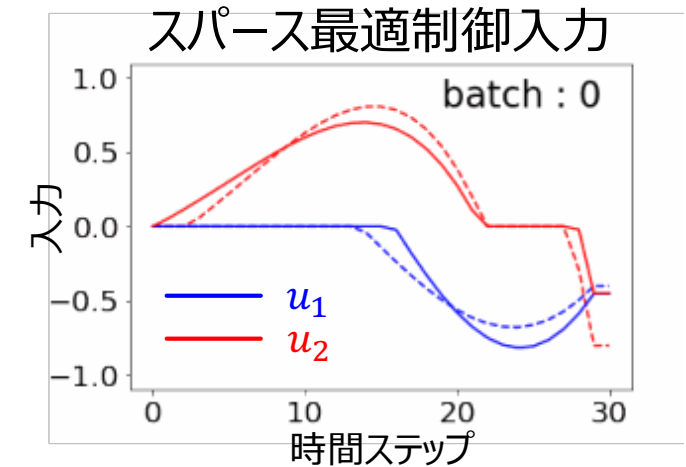

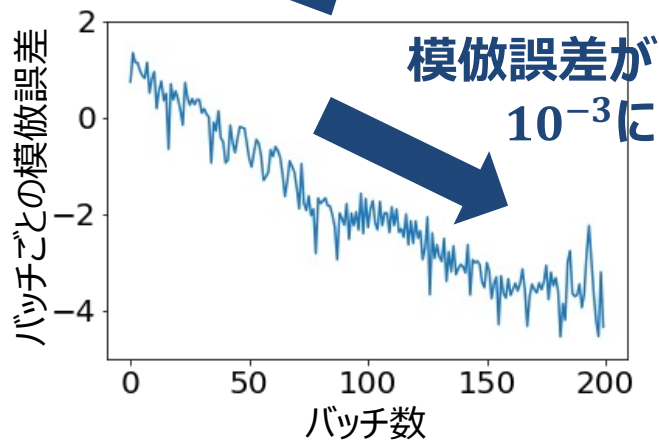
誤差最小化

最適性条件
(リッカチ・KKT)



- ・教師データ100個
(初期状態をランダム生成)
- ・Adamにより最適化
- ・バッチサイズ10, エポック数20
- ・初期値 [10; 10; 1; 1]
(教師 : [60; 30; 2; 1])

教師制御を模倣できている



【玄人向け】

■ リアプノフ関数でダイナミクスをパラメトライズ


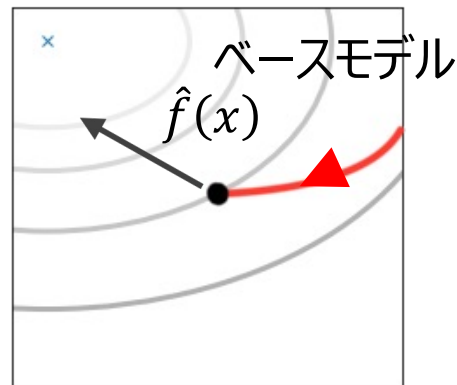
➤ $\dot{x} = f_{\text{model}}(x) := \hat{f}(x) + \hat{l}(x)$

✓ $\hat{l}(x) := \begin{cases} 0, & \text{if } \nabla V^\top \hat{f} < 0 \\ -\frac{\nabla V^\top \hat{f}}{\nabla V^\top \nabla V} \nabla V, & \text{otherwise} \end{cases}$

➤ V はいつでもリアプノフ関数 (モデルに沿って $\dot{V} \leq 0$)

➤ $\min_{V, \hat{f}} \sum_t \|x^*(t + \tau) - x^*(t) - \tau f_{\text{model}}(x^*(t))\|^2$


✓ $x^*(t)$: 学習用軌道データ




【玄人向け】

- モデルとリアプノフ関数が同時に求まる
- 不安定システムへの拡張
 - 可安定性の仮定のもと、モデル・制御リアプノフ関数・安定化制御則が求まる

$$\dot{x} = f^*(x)$$

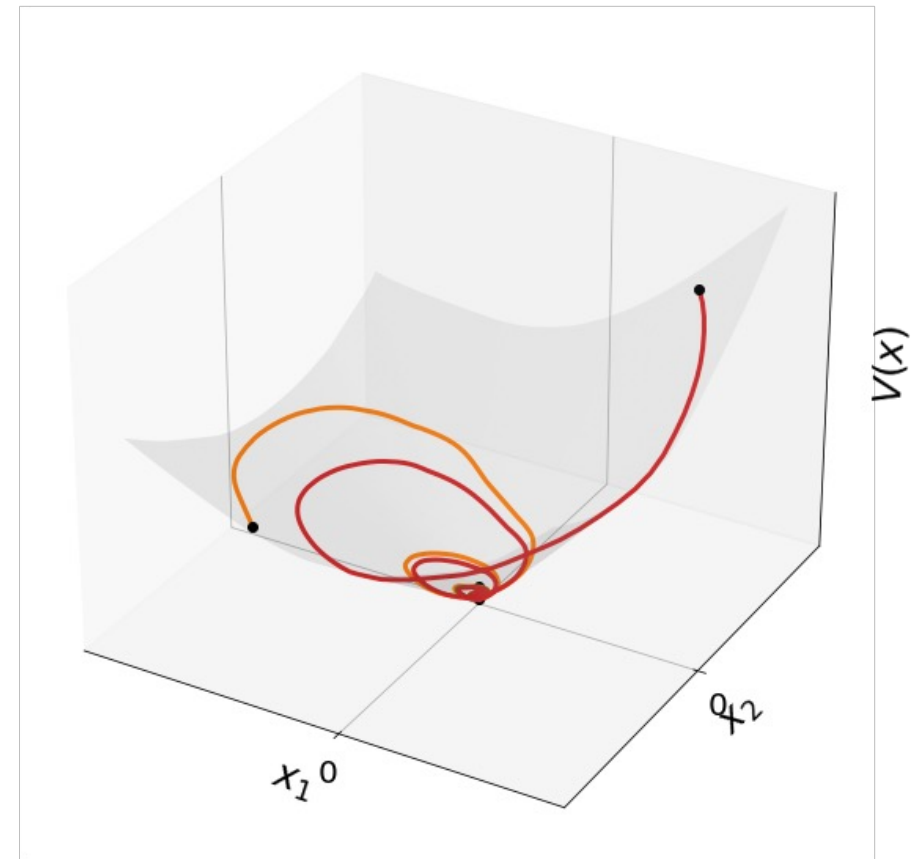



$$\dot{x} = f_{\text{model}}(x) := \hat{f}(x) + \hat{l}(x)$$



【玄人向け】

- モデルとリアプノフ関数が同時に求まる
- 不安定システムへの拡張
 - 可安定性の仮定のもと、モデル・制御リアプノフ関数・安定化制御則が求まる



真のシステム・モデルともに漸近安定化される

- 新しい強力なツールとしての機械学習
 - 事前知識やモデルベースト設計の積極的活用
 - **構造付きダイナミクス学習**

- 統計的学習と融合し深化する制御理論
 - 「情報」を陽に扱うことで生まれる異分野との接点
 - **最適輸送と最適制御**

- まとめ

制御と学習のギャップを埋める「分布の制御」

➤ Optimal transport, Maximum-Entropy

■ モビリティ基盤数理研究ユニット

- これからの移動と新たな社会のあり方を、数理の視点から構想する

クルマや移動そのものの概念が多様化してきているなか、未来のモビリティ社会の本質をつかみ、次世代の基盤をつくるために、すべてのモノや情報が動くシステムの根本にある「数理の力」は不可欠です。

世界的に活躍する数理研究者とモビリティ・カンパニーが手を取りあい、数理の視点から、これからの移動と新たな社会のあり方を構想します。

<https://mobility.amp.i.kyoto-u.ac.jp/>





IoT, センシング技術の発展

- 超スマート社会実現にむけた**大規模システム**への期待
(群ロボット, 交通システム, 電力ネットワーク...)

大規模システムの制御

■ 例：群ロボットの協調運搬, 効率的な配車



★ : エージェント, ○ : 目標状態

- 最適制御：最小コストで制御目標を達成せよ

コスト $\sum_{k=0}^{N-1} L(x_k, u_k) \rightarrow \{u_k\}$ について最小化



→ $\times x_N = (\text{目標状態})$

$$x_{k+1} = f(x_k, u_k)$$

x_k : 状態変数, u_k : 制御入力

- 最適輸送：物資を目標分布に最小コストで輸送せよ

最適制御 & 最適輸送

- 最適制御：最小コストで制御目標を達成せよ

コスト $\sum_{k=0}^{N-1} L(x_k, u_k) \rightarrow \{u_k\}$ について最小化



→ $\times x_N = (\text{目標状態})$


$$x_{k+1} = f(x_k, u_k)$$

x_k : 状態変数, u_k : 制御入力

- 最適輸送：物資を目標分布に最小コストで輸送せよ

総輸送コスト minimize $\sum_{i=1}^n c(x_i, y_{\sigma(i)})$, 置換 σ

\mathbb{R}^n



$C_{ij} := c(x_i, y_j)$: $x_i \rightarrow y_j$ の単位輸送コスト
例) $c(x_i, y_j) = \|x_i - y_j\|^2$



所与の目標値に効率よく収束(安定化)させる

最適制御問題 (エージェントの安定化)

$$\text{minimize}_{u_i} \sum_{k=0}^{\infty} \ell(x_i(k), u_i(k))$$

$$\text{subject to } \begin{aligned} x_i(k+1) &= Ax_i(k) + Bu_i(k), \quad k \geq 0, \\ x_i(0) &= x_i^0, \quad \lim_{k \rightarrow \infty} x_i(k) = y_j \end{aligned}$$

($x_i(k)$: 時刻 k での状態, $u_i(k)$: 制御入力)

最適制御が輸送方法, 最小値が輸送コスト

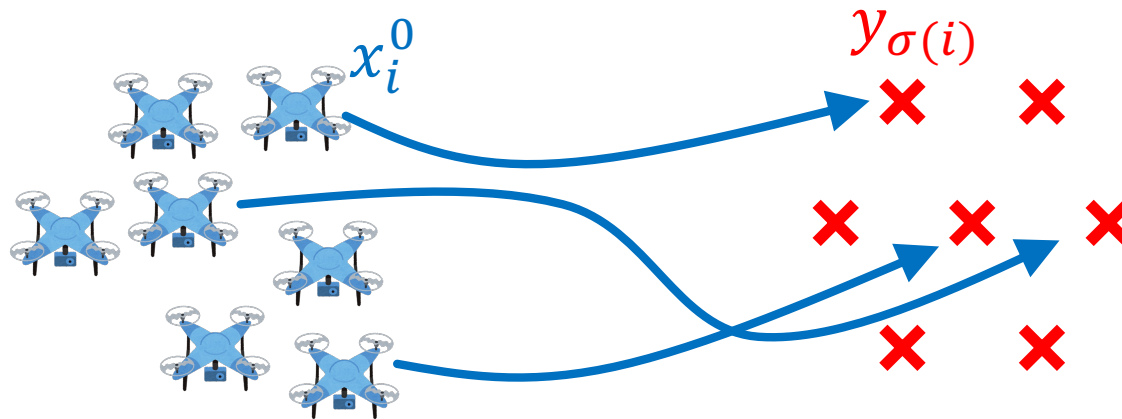
動的な最適輸送の定式化

初期状態 $\{x_i^0\}_{i=1}^N$, 目標状態 $\{y_j\}_{j=1}^N$

動的システム上の最適輸送 (エージェント分布の安定化)

$$\begin{aligned} & \underset{\{u_i\}_i, \sigma}{\text{minimize}} && \sum_{i=1}^N \sum_{k=0}^{\infty} \ell(x_i(k), u_i(k)) \quad (\text{総輸送コスト}) \\ & \text{subject to} && x_i(k+1) = Ax_i(k) + Bu_i(k), \quad k \geq 0, \quad \forall i \\ & && x_i(0) = x_i^0, \quad x_i(\infty) = y_{\sigma(i)}. \end{aligned}$$

$x_i \in \mathbb{R}^n$: 状態, $u_i \in \mathbb{R}^m$: 制御入力, σ : 置換




MPCをそのまま適用

$c(x_i(k), y_j)$
: 現状態 $x_i(k)$ と目標 y_j の輸送コスト

$$\text{minimize}_{\sigma} \sum_{i=1}^N c(x_i(k), y_{\sigma(i)}),$$

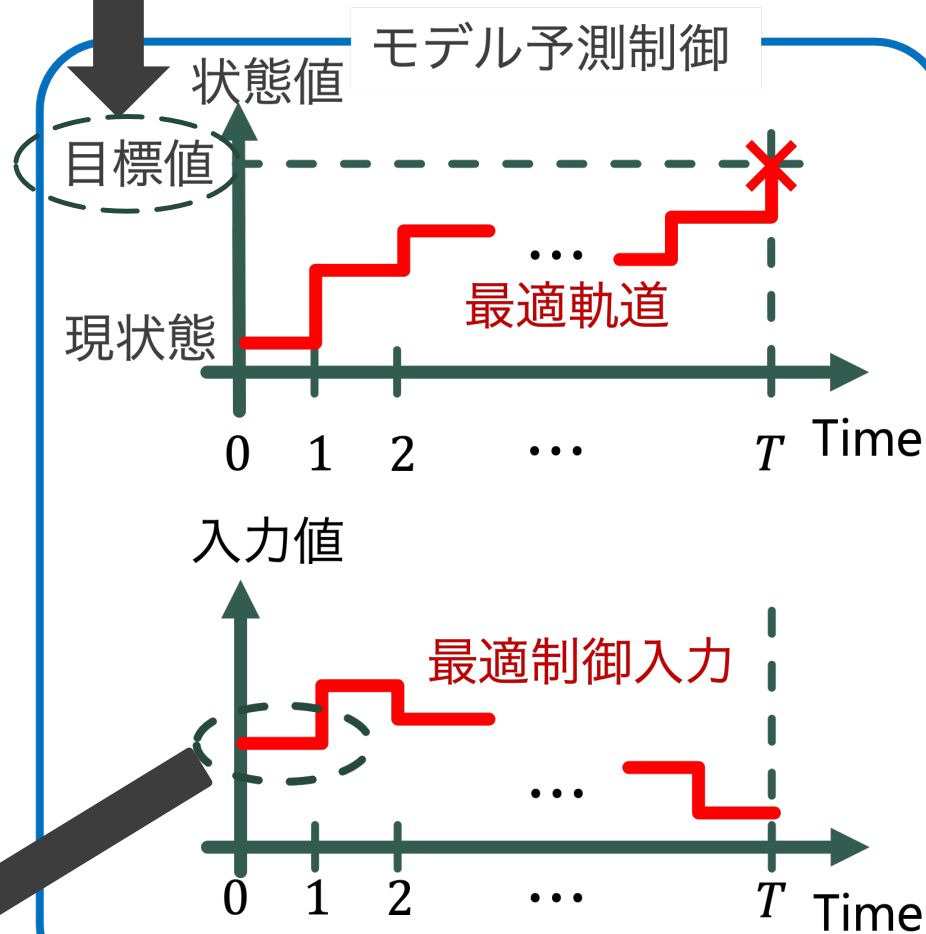
を解き, 現時刻での輸送先(暫定)
を決定 ← 計算コスト大!

↑ 現状態 $\{x_i(k)\}$



↑ 制御入力印加

σ^* から
暫定目標値決定



アイデア：MPC+エントロピー正則化

$C(x(k)) : \{x_i(k)\}$ と目標間の
輸送コスト行列

エントロピー正則化最適輸送

$$\sum_{i,j} C_{ij}(x(k)) P_{ij} - \varepsilon(\text{エントロピー})$$

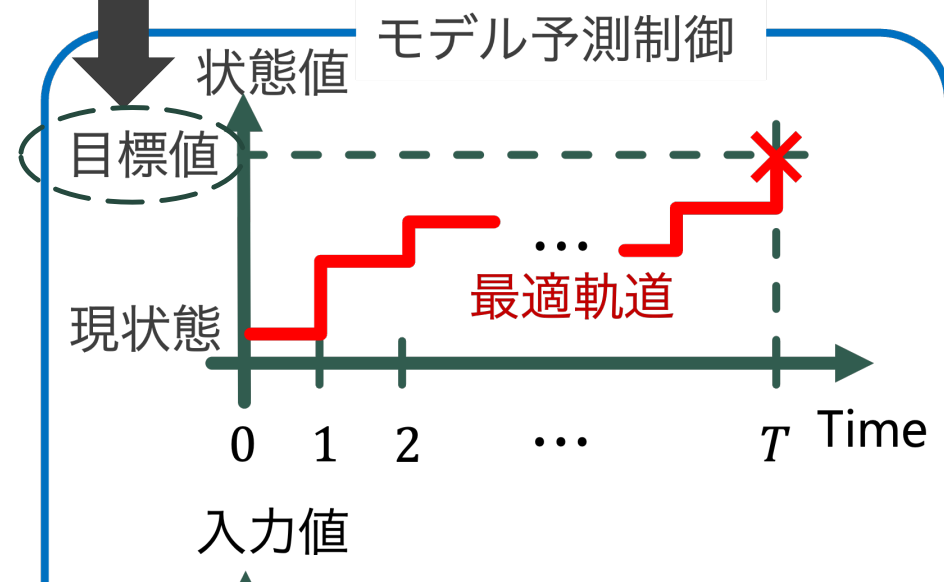
→ minimize

の最適解 $P^*(x(k))$ を計算

↑ 現状態 $\{x_i(k)\}$



$P^*(x(k))$ から
暫定目標値決定

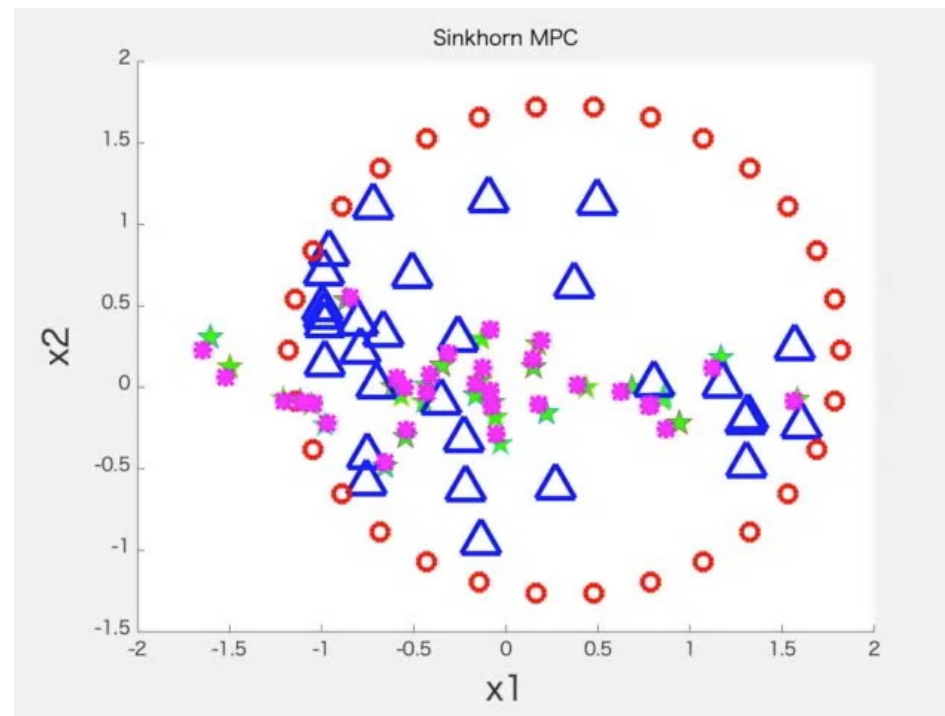



制御と共に輸送計画 P が改善される
「制御しながら最適輸送計画を考える」

■ 安定性などを数学的に証明

➤ 条件を満たさない場合

Magenta: エージェント初期配置, Green: エージェント
Red: ターゲット, Blue: 暫定ターゲット





★ : エージェント, ○ : 目標状態

Sinkhorn1反復の計算時間

0.21 ms (エージェント数 $N = 500$)

0.83 ms ($N = 1000$)

3.0 ms ($N = 3000$)

※収束には400反復

- $A = \begin{bmatrix} 1.2 & 0.13 \\ -0.05 & 1.1 \end{bmatrix}$, $B = 0.1I$
- 正則化の強さ : $\varepsilon = 0.5$
- MPCの予測時間 : $T = 50$
- 各時刻のSinkhorn反復回数
 $S_{\text{iter}} = 15$

ハンガリアン法

0.6 s ($N = 500$)


VS. 3.0 s ($N = 1000$)

57.0 s ($N = 3000$)



↓
急激に増大

分布制御＝深層生成モデル


■ 分布の制御




■ 深層生成モデル




a)



b)



c)




d)

ダークサイドに堕ちた？

- せっかく綺麗な理論をやったのに、
とうとう**そっち側**にってしまったんですね。。

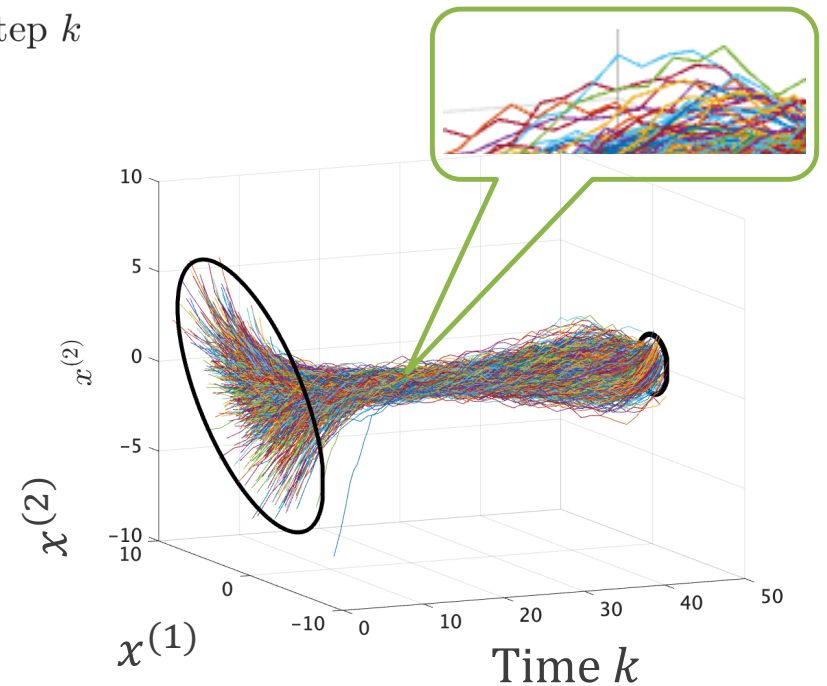
エントロピー正則化つき動的最適輸送



MaxEnt分布制御：

入力に雑音入れたら
ボーナスあげるで。

$$\begin{aligned} & \underset{\{\pi_k\}_{k=0}^{N-1}}{\text{minimize}} \quad \mathbb{E} \left[\sum_{k=0}^{N-1} \left(L(x_k, u_k) - \varepsilon H(\pi_k(\cdot | x_k)) \right) \right] \\ & \text{subject to} \quad x_{k+1} = Ax_k + Bu_k, \quad u_k \sim \pi_k(\cdot | x_k) \\ & \quad \quad \quad x_0 \sim \mathcal{N}(0, \bar{\Sigma}_0), \quad x_N \sim \mathcal{N}(0, \bar{\Sigma}_N) \end{aligned}$$



最大エントロピー(MaxEnt)制御

$$\mathbb{E}\left[\sum_{k=0}^{N-1} L(x_k, u_k) - \varepsilon H(\pi_k(\cdot | x_k))\right]$$

→ 制御方策 $\{\pi_k\}$ について最小化

■ なぜエントロピー正則化？

➤ 強化学習

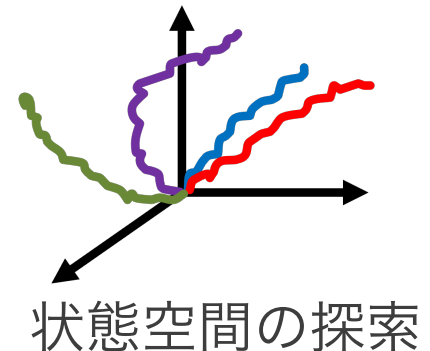
- ✓ 学習用データのランダム探索効果^[TH]
- ✓ 雑音へのロバスト性

➤ プライバシー保護

- ✓ 信号のランダム性を増大させて推定を困難に

➤ 通常的最適制御の近似解法


- ✓ **きれいな解が得られる**
- ✓ **モデルフリー設計との相性もよい**






数値例

$$A = \begin{bmatrix} 0.9 & 0.1 \\ 0.05 & 1.2 \end{bmatrix}, B = \begin{bmatrix} 0 \\ 0.22 \end{bmatrix}$$

最適状態軌道の1000サンプル



制御過程のサンプル



- Structured Hammerstein-Wiener model learning for model predictive control,
 - Moriyasu, Ikeda, Kawaguchi, Kashima, IEEE L-CSS
- スパース最適制御問題をモデルとする模倣学習,
 - 島, 森安, 川口, 加嶋, 自動制御連合講演会
- Learning stabilizable deep dynamics,
 - Kashima, Yoshiuchi, Kawano, arXiv
- Bayesian differential privacy for linear dynamical systems,
 - Sugiura, Ito, Kashima, L-CSS
- Multiple sparsity constrained control node scheduling with application to rebalancing of mobility networks,
 - Ikeda, Sakurama, Kashima, IEEE TAC
- Observability Gramian for Bayesian inference in nonlinear systems with its industrial application,
 - Lee, Umezu, Konno, Kashima, IEEE L-CSS, Early Access
- Entropic model predictive optimal transport over dynamical systems,
 - Ito, Kashima, submitted to Automatica
- Resilience evaluation of entropy regularized logistic networks with probabilistic cost,
 - Oishi, Hashizume, Jimbo, Kaji, Kashima, arXiv

- 新しい強力なツールとしての機械学習
 - 事前知識やモデルベースト設計の積極的活用
 - **構造付きダイナミクス学習**

- 統計的学習と融合した深化した制御理論
 - 「情報」を陽に扱うことで生まれる異分野との接点
 - **最大エントロピー分布制御**

- 謝辞
 - 森安竜大様（豊田中研），伊藤海斗君（東工大）
 - 科研費 21H04875 「情報の取得を包含した制御理論と統計的学習理論の融合数理基盤」

ご意見、雑談、講演、共同研究、入学相談、なんでも歓迎いたします。

kk@i.kyoto-u.ac.jp