



集団運動におけるデータ駆動科学


藤井 慶輔

名古屋大学大学院 情報学研究科
理化学研究所 革新知能統合研究センター



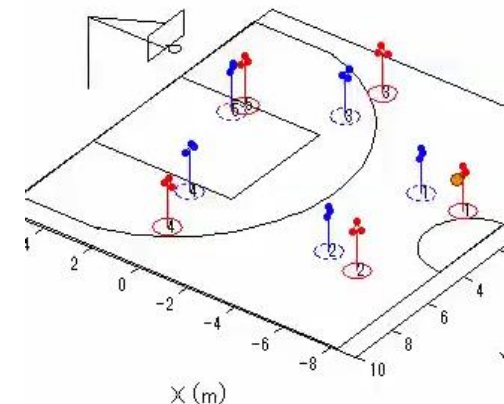

研究略歴： ヒト集団身体運動の原理理解と応用技術の開発

年	所属	対象	アプローチ
2008-14	京大人環(DC1)	個人・対人運動 (1対1)を計測	モデリング・ データ解析
2014-17	名大保体 センター(PD)	運動制御モデル 集団運動(1対1 ～多対多)を計測	モデリング・ データ解析
2017-19	理研AIP (研究員)	集団運動 (提供された データを利用)	機械学習・ データ駆動的 モデリング
2019-	名大情報(助教) 理研AIP(客員)		



対人動作分析(2012)

NBAのゲームデータ
(SportVU)



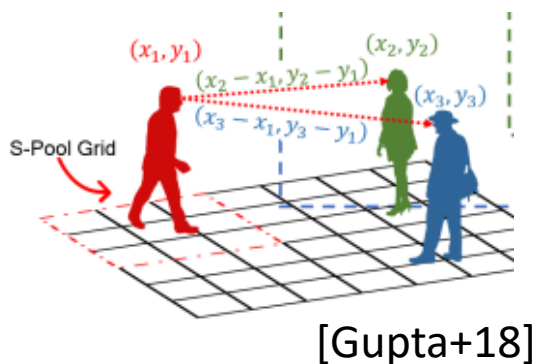
体育館での計測(2015)

本日の話

1. 自己紹介
2. 集団運動の科学の背景
3. 従来のアプローチ
4. 機械学習を用いたアプローチ
5. まとめ

集団運動 (collective motion)

歩行者




動物行動



子どもの
遊び




スポーツ




社会的相互作用や協力的問題解決の原理の解明、
およびこれらの応用技術(評価・予測等)は未発達

より多様な空間スケールの例（物理学、生物学など）




Molecule phase transition
[Kawasaki+10]



Cell repairing
[Cohen+10]



Human interaction
[Fujii+16]



Ecology in animals
[Ye+2015]

10^{-9}

10^{-4}

10^1

10^6

(m)

問題点：要素間の相互作用の規則が不明なので、データ解析・モデリングにおいて、その構造が利用できない

- ✓ 従来の経験科学、理論科学、計算科学では解明できない部分があるため計測データからその性質を推定するデータ駆動科学が有効？
- ✓ 例：従来手法は①動的システム②マルチスケール性の観点から難しい

1. (物理学的な) 動的システムとしての理解

$$\mathbf{x}_{t+1} = f(\mathbf{x}_t)$$



\mathbf{x} : 状態ベクトル
 f : 遷移関数

1. f が既知で解析的に解ける
2. f が既知だが解析的に解けない
 (例: 流体、多リンク運動など)
3. f が未知で解けない
 (例: 一般的な集団運動、生物の多リンク運動)

(数理) モデルベースの科学

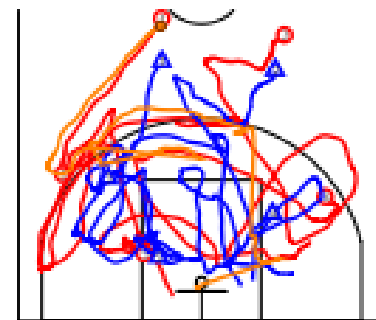
データ駆動科学

歩行者のモデル [Helbing+00]



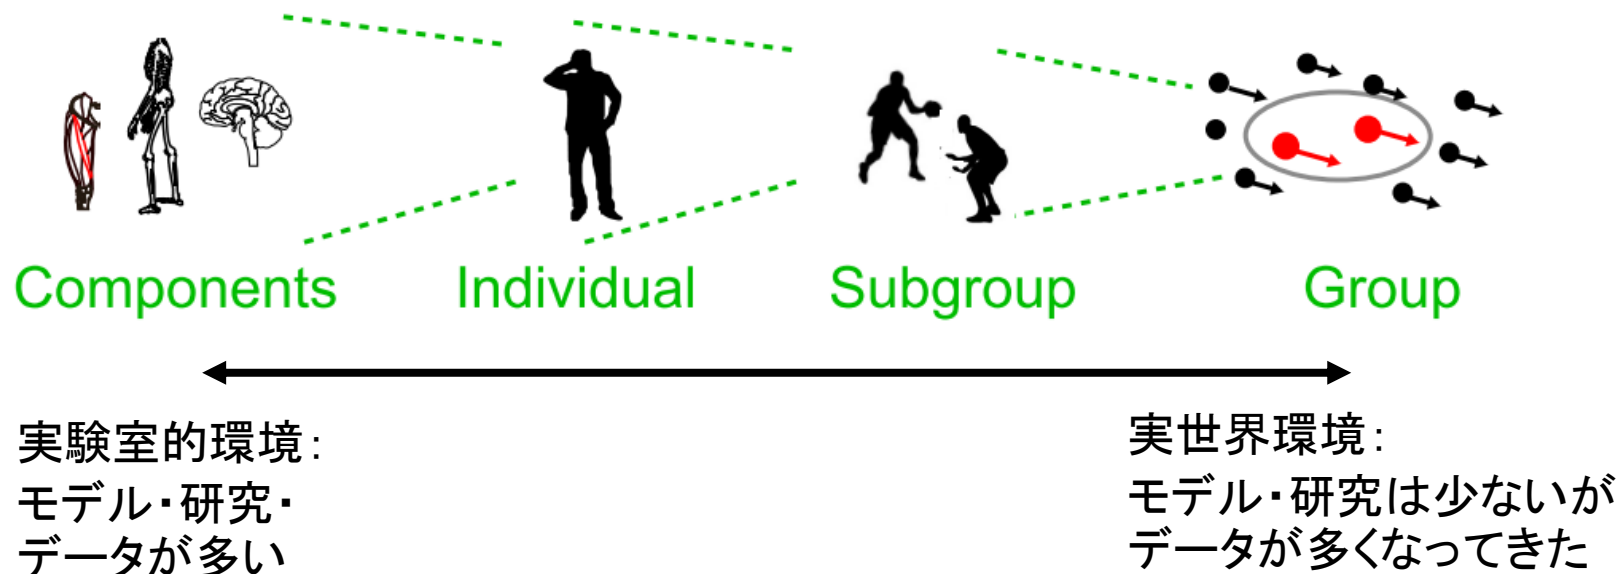
$$m_i \frac{d\mathbf{v}_i}{dt} = m_i \frac{\mathbf{v}_i^0(t) \mathbf{e}_i^0(t) - \mathbf{v}_i(t)}{\tau_i} + \sum_{j(\neq i)} \mathbf{f}_{ij} + \sum_W \mathbf{f}_{iW}$$

支配方程式が不明



$$\dot{\mathbf{x}} = f(\mathbf{x}) ?$$

2. (生物などの) マルチスケールな原理の理解




集団運動は、階層性・非線形性のある実環境での理解が難しい

→問題を絞れば従来科学でも解決可能だが、集団スポーツのチーム戦術などの解明に、データ駆動的な手法を使いたい



応用技術的な観点(個人的動機:スポーツの場合)

近年では計測技術が発達してきたが、現場での戦術的な分析は多くがビデオに基づく




選手・ボール位置推定(SportVU)

自動化



導入



ビデオ編集ソフトウェア
(Sportscode)

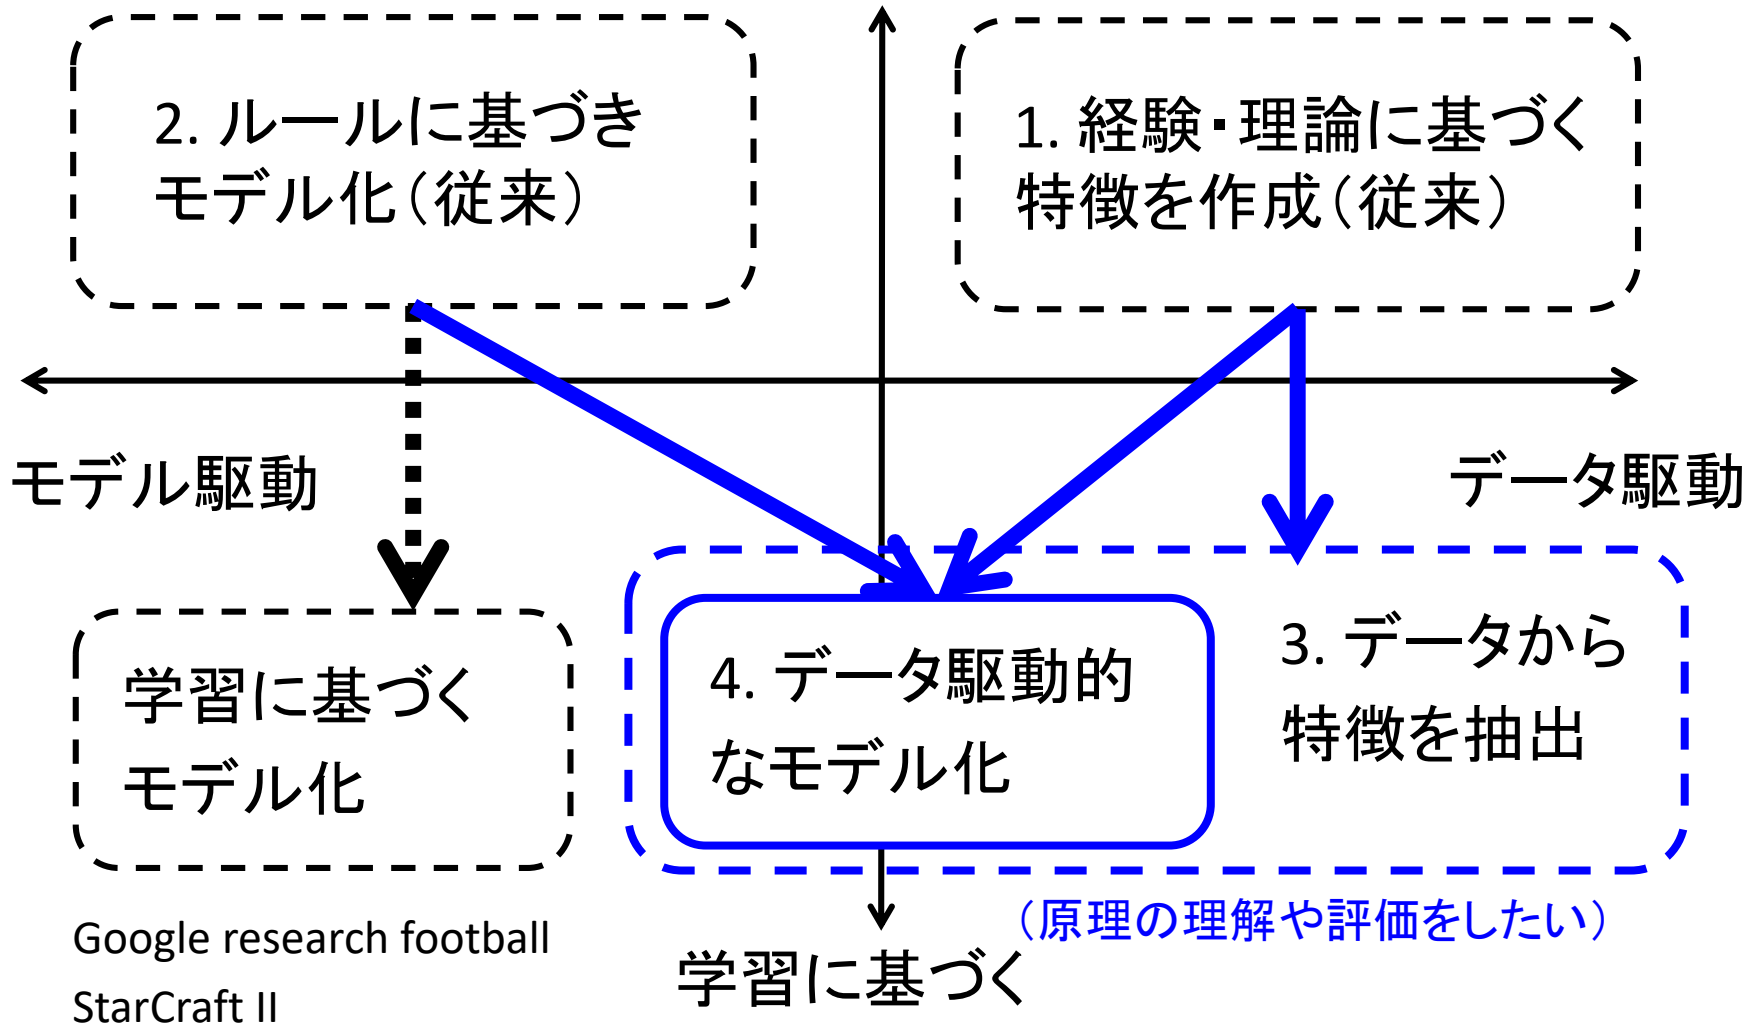
Play Types	% Time	Poss
Off Screen	38.7%	404
Hand Off	18.5%	193
Spot Up	16.6%	173
Transition	12.2%	127
P&R Ball Handler	5.5%	57
Isolation	2.5%	26
Cut	1.4%	15
P&R Roll Man	0.5%	5

プレイ頻度分析
(Synergy)

集団および集団を監督・観察する人(その領域の知識がある/ない人)の負担軽減/理解促進などが期待(企業も注目)

手法をモデル-データ / 経験・理論-学習の2軸で整理

経験・理論に基づく(従来)




本日の話

1. 自己紹介
2. 集団運動の科学の背景
3. 従来のアプローチ
4. 機械学習を用いたアプローチ
5. まとめ


1. データから経験・理論に基づく特徴を作成(従来)

その領域での経験・理論に基づいた特徴を作成し仮説を検証



集団運動での例:

- ✓ 入力データ: 本日は個体の位置情報(画像の研究も多い)
- ✓ 特徴1: (経験)角度、距離、速度など
- ✓ 特徴2: (理論)ネットワーク性、フラクタル性など

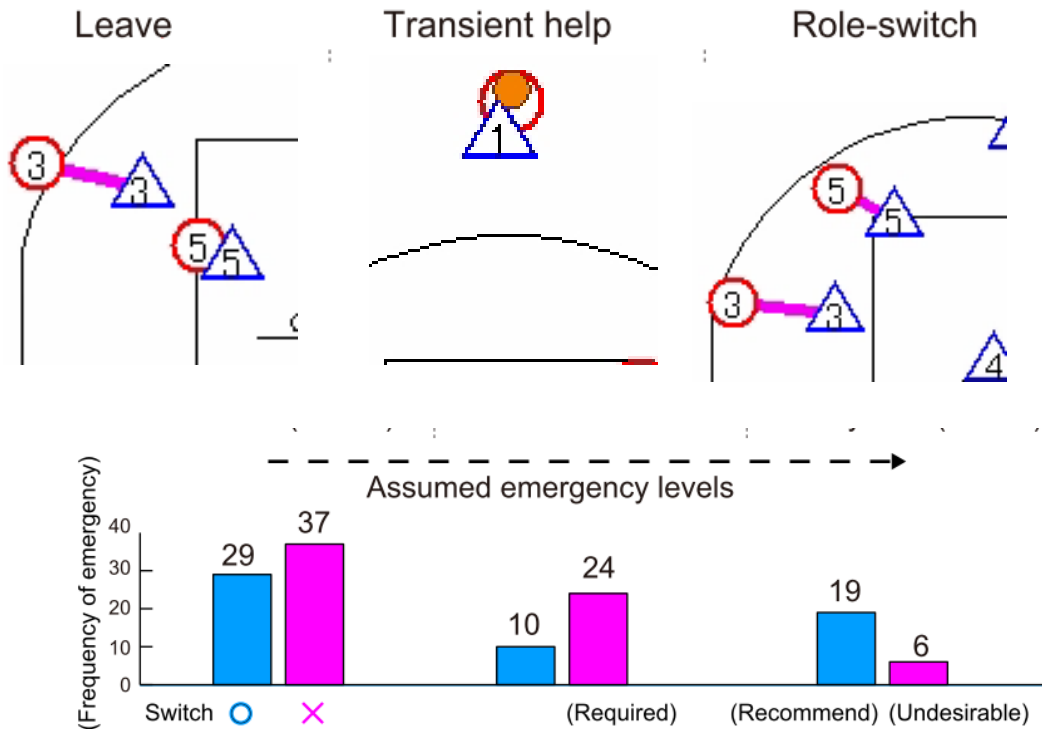


- 😊 解釈しやすい、スモールデータにも適用できる
- 😞 複雑なモデル化ができない

1. データから経験に基づく特徴を作成(例: 評価)

チームワークの評価

危機のレベルに応じた柔軟性を評価
[Fujii+16] (分類はルールベース+目視)

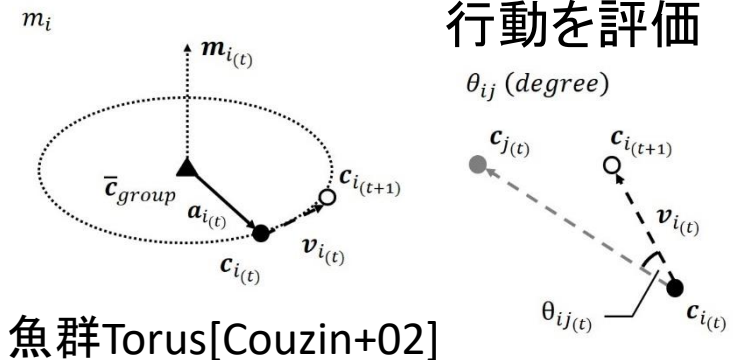


子どもの集団遊び

[Ichikawa+18]

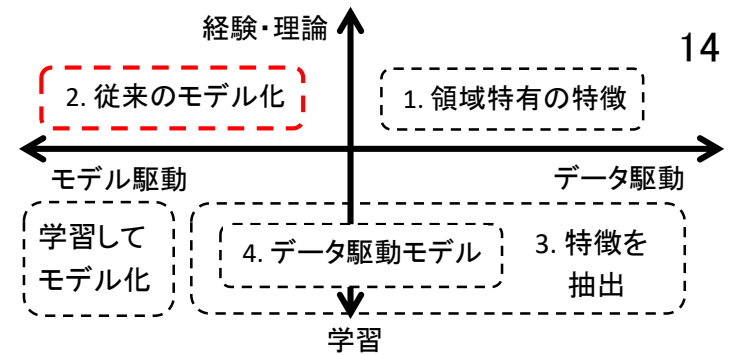


回転運動中、他者に近づく
行動を評価



😊 領域内で解釈しやすい ☹️ 領域特有で一般化しない

2. ルールに基づくモデル化 (従来)



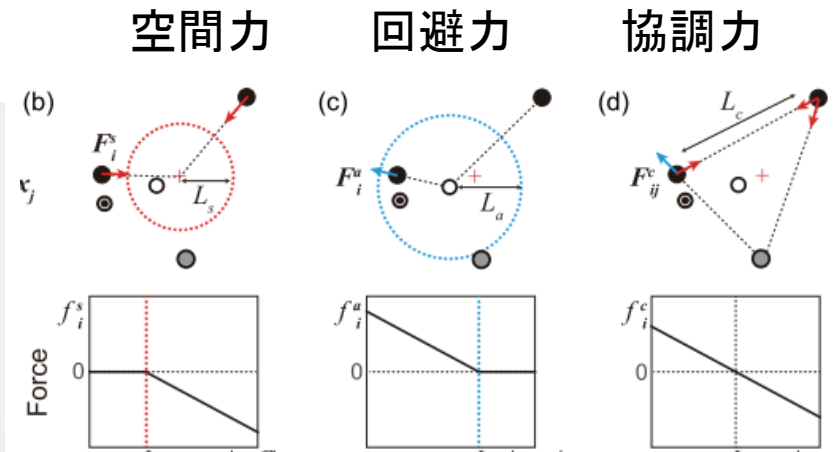
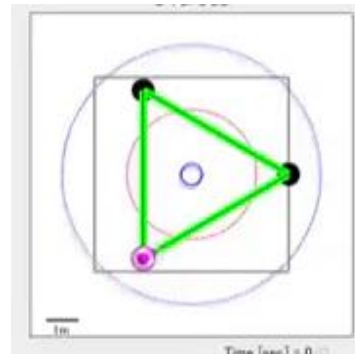
初期条件・パラメータ
(経験・領域の理論に
基づき事前に設定)



仮説検証
軌道生成など

集団運動の例: トイモデル、ビデオゲーム、RoboCupなど





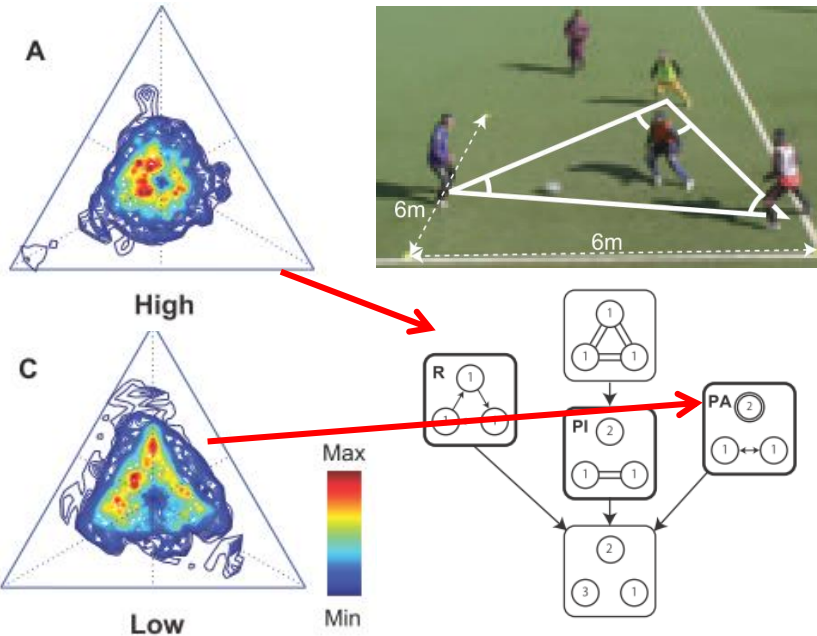
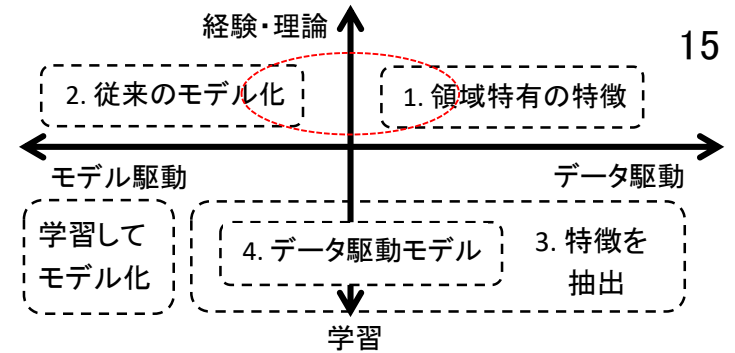
具体例: Social force model [Yokoyama+18]



😊 原理に基づいているため、理解・説明しやすい

😞 より複雑な動きに関して、実際の動きと異なる場合が多い

1.5. データから数学モデルに基づく特徴を作成



時空間対称性の破れから三者のチームワークを説明[Yokoyama & Yamamoto 2011 Plos CB]

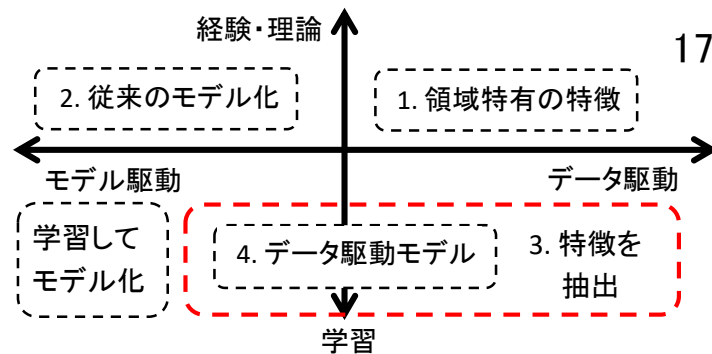
支配領域を用いて集団行動に自己相似性があることを発見[Kijima et al. 2014 EPJB]

- 😊 集団運動の普遍的性質を解明した点に科学的意義
- 😞 複雑な相互作用の詳細を表現できない

本日の話

1. 自己紹介
2. 集団運動の科学の背景
3. 従来のアプローチ
4. 機械学習を用いたアプローチ
5. まとめ

3. データから特徴抽出 (学習)



主に時空間的に大域的な特徴をデータから抽出



集団運動の例 (詳細は次スライド)

- ✓ 入力データ: 本日は個体の位置情報について (画像の研究も多い)
 1. クラスタリング: 時系列類似度、CNNベース、トピックモデリング
 2. (教師あり)分類: 因子分解、RNNベースなど
 3. 回帰 (軌道生成含む): RNNベース、強化学習ベース、GANなど

☺ 領域の知識が少なくても済む、より汎用的

3. データから特徴抽出 (学習): スポーツの例

✓ クラスタリング (教師なし学習)

- DTW [Decroos+18], various metrics [Sha+16], hierarchical-[Hobbs+18]
- 1D-CNN [Mehrasa+18], CAE[Nistala+19]
- LDA [e.g. Miller+17], specified topic model [Wang+15]

✓ 分類 (教師あり学習・ラベル予測)

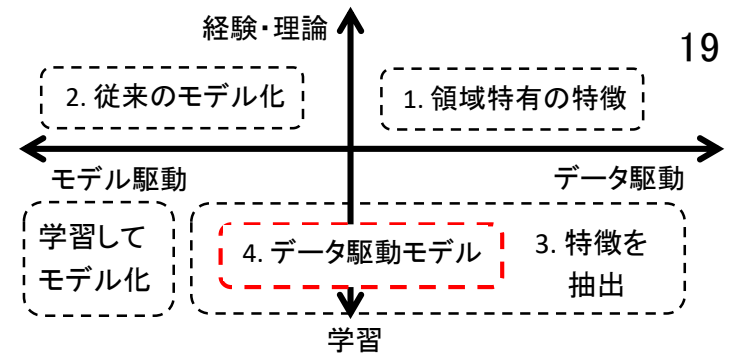
- (individual) Latent factor model [Yue+14; Miller+14; Zheng+18]
- (team) RNN-based [Wang+16], **DMD (動的モード分解)** [Fujii+17,+19]
- (winning) FCN [Ganguly+18], Poisson factorization [Ruiz+15]

✓ 回帰 (軌道生成を含む: 詳細は後ほど)

- (score) Logistic regression [Lucey+14]
- (team trajectory) Imitation [Zheng+16, Li+17, Liu+18,19], GAN [Chen+18, Hsieh+19], Other deep generative model [Zhan+18,19, Yeh+19, Ivanovic+18]

→よくある問題設定に落とし込み、改善手法を提案していく

4. データ駆動的なモデル化 (による集団運動の理解)



集団運動モデルのパラメータや規則を、計測データから学習

※単なる学習でも機械学習モデル

科学として有用なデータ駆動モデル(深層学習と認知科学[Cichy & Kaiser, 19])

1. 現象の予測
2. 現象の説明
3. 新しい理論への出発点

集団運動とある種の機械学習モデル
にも当てはまる？

集団運動：既存モデルがほとんどない(比較対象がない)

→議論しにくいので理解のための工夫(色々ある):

1. 背後の数学的な構造を抽出
 2. 学習した表現などを可視化
 3. 構成要素をモデル化して運動を再現 など
- (例: DMD)

DMDの背景理論: クープマン作用素のスペクトル分析

目的: 非線形動的システムの解析 (基本的には難しい)

$$\mathbf{x}_{t+1} = \mathbf{f}(\mathbf{x}_t), \quad \mathbf{x} \in \mathcal{M}(\text{state space}).$$

クープマン作用素 [Koopman 31, Mezić 05] :

観測関数 $g: \mathcal{M} \rightarrow \mathbb{C}$ の時間発展を表す線形作用素。つまり、

$$\mathcal{K}g(\mathbf{x}) = g \circ \mathbf{f}(\mathbf{x}).$$

☺ 解析困難な \mathbf{f} を関数空間上で線形に取り扱える

クープマンモード分解

1. \mathcal{K} のスペクトル分解 $\mathcal{K}\varphi_j(\mathbf{x}) = \lambda_j\varphi_j(\mathbf{x})$ (解の挙動の情報を得る)
2. $g(\mathbf{x}) = \sum_{j=1}^{\infty} \varphi_j(\mathbf{x})v_j$ を仮定
3. 上の定義に基づき、 g の時間発展は次のように表される

$$g(\mathbf{x}_t) = g \circ \mathbf{f} \circ \cdots \circ \mathbf{f}(\mathbf{x}_0) = \sum_{j=1}^{\infty} \lambda_j^t \varphi_j(\mathbf{x}_0)v_j. \quad (\text{DMDはこの実装})$$

Koopman mode w_j

例: $\dot{x}_1 = \mu x_1$
 $\dot{x}_2 = \rho(x_2 - x_1^2)$

$$\frac{d}{dt} \begin{bmatrix} x_1 \\ x_2 \\ x_1^2 \end{bmatrix} = \begin{bmatrix} \mu & 0 & 0 \\ 0 & \rho & -\rho \\ 0 & 0 & 2\mu \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_1^2 \end{bmatrix}$$

$\mathcal{K} \quad g$

集団運動解析のためのグラフDMD [Fujii+19, arXiv]

これまで: 動的性質が時間変化する集団運動に、RKHSでのDMD [Kawahara 16, NIPS] を適用して、特徴空間で分解して得られたスペクトルの類似度を表すカーネル[Fujii+17, ECML-PKDD]を用いた分類手法を開発

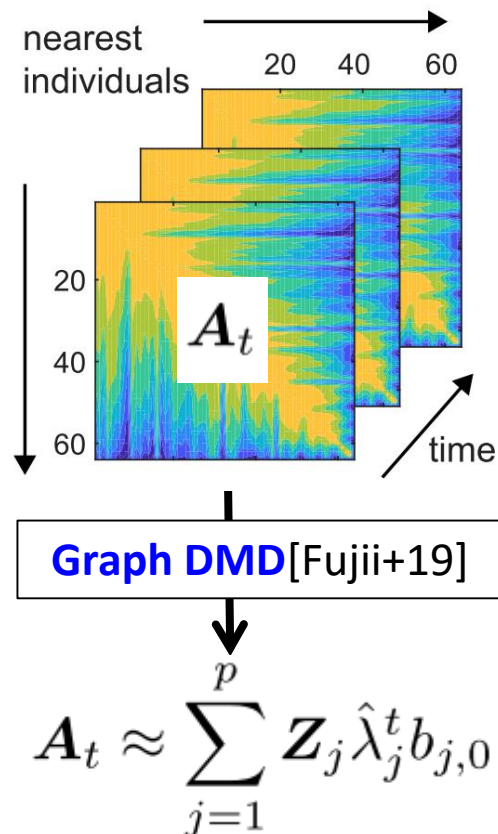
問題① カーネル法は表現力が高いが、特徴空間での分解のため、**モードの可視化・解釈**が難しい

問題② 集団運動は**個体間に依存構造**をもつと考えられるが、従来のDMDはその構造を反映していない

→そこで、観測量間の依存構造、つまり

1. ベクトル値観測関数 g_1, \dots, g_m (m: 個体)
2. 行列値観測関数 $[G(\mathbf{x})]_{i,j} = h(g_i(\mathbf{x}), g_j(\mathbf{x}))$


に基づくクーブマン分析、その実装としてグラフDMDを提案[Fujii+19] (詳細は本日のポスター039)



グラフDMDの集団運動への適用(概要) [Fujii+19, arXiv]

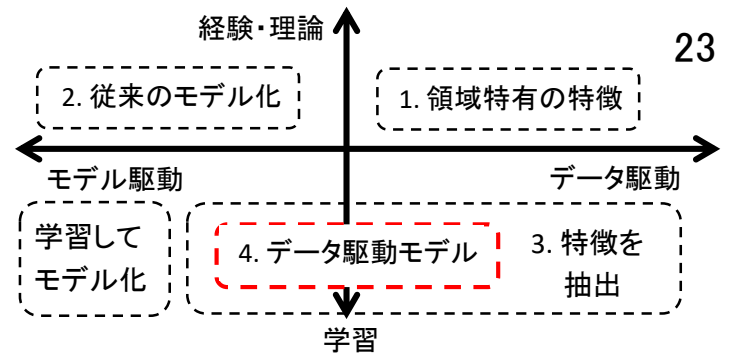
隣接行列系列をテンソルレイン分解で得られた直交方向へ射影してDMD

[Fujii & Kawahara 19, Neural Networks]



☺ 一般的な集団運動の動的情報抽出、大域的な運動の分類

4. データ駆動的なモデル化 (としてのグラフDMDの解釈)



集団運動モデルのパラメータや規則を、実測データから学習

グラフDMD:
[Fujii+19]

隣接行列(データ)


$$A_t \approx \sum_{j=1}^p Z_j \hat{\lambda}_j^t b_{j,0}$$

観測


$$G(x)$$

背後の力学系



$$x_{t+1} = f(x_t)$$



地域を守る



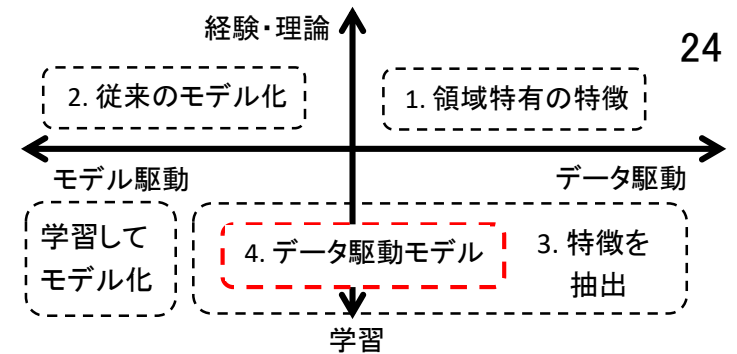
人を守る



(詳細は本日のポスター039)

個体間のダイナミクスモデル化と解釈可能な可視化により理解


4. データ駆動的なモデル化 (運動を再現するモデルの例)



エージェントをモデル化して軌道予測などの性能を向上
軌道予測のベンチマーク的な課題にも (通行人・車などが多い)

集団スポーツへの適用例

- ✓ Imitation learning [Zheng+16, Li+17], GAIL [Liu+18,19]
- ✓ GAN [Chen+18, Hsieh+19]
- ✓ Graph NN [Kiph+18, Yeh+19]
- ✓ Deep generative model:
 - VRNN-based [Zhan+18,19, Liu+19, Yeh+19]
 - Other RNN-based [Ivanovic+18, Liu+18]



[Li+17, ICML]


😊 詳細なモデル化による、行動規則の理解

4. データ駆動的なモデルの科学への応用例


1対1追跡-逃避課題における二者のデータ駆動的モデリング

[Tsutsui, Fujii & Takeda, in prep.]

従来の追跡者モデル



従来の逃避者モデル



従来のルールに基づくモデルでは、多様な(特に逃避)行動を説明できない


RNNをベースに、「予測されまい」として方向転換して逃避するヒト行動をモデル化できた

(ヒトの複雑な切返しの特徴をデータから学習)

	Attacker**		Defender**	
	Linear	LSTM	Linear	LSTM
Avg. disp. error	1.03	0.19	0.05	0.20
Avg. non-linear disp. error*	1.17	0.32	1.07	0.34

(例1) Linear ○
LSTM ○

(例2) Linear ×
LSTM ○



赤:OF, 青:DF, 緑:予測

まとめ・謝辞

目的：集団運動の原理を理解したい

✓ モデル駆動手法とデータ駆動手法を橋渡ししたい

1. (従来)データから特徴を手作りして統計処理する
2. (従来)ルールに基づいて簡略化してモデル化する
3. 計測データから特徴を機械学習などで抽出する
4. データ駆動的にモデル化して原理理解に役立てる

例：個体間相互作用をモデル化するグラフDMD, 軌道予測モデル

✓ 謝辞：これらの研究では、以下の方々にご協力頂きました(敬称略)

河原吉伸(九大・理研)・武石直也(理研)・筒井和詩(名大)・武田一哉(名大)・
稲葉優希(JISS)・方城素和(前・理研)・山本裕二(名大)・横山慶子(名大)

科研費：18K18116(若手), 19H04941(新学術領域「生物移動情報学」公募研究)

発表資料はダウンロードできます → <https://bit.ly/2OsiKaK>