

国立情報学研究所

今日からできる スパースモデリング

京都大学大学院情報学研究科システム科学専攻

大関 真之

QUANTUM
ANNEALING



MACHINE
LEARNING

Sparse Modeling


CREST





京都大学
KYOTO UNIVERSITY

ボルツマン機械学習編

機械学習とは
データに対する関数の自律的フィッティング








$$\min_{a,b} \sum_{i=1}^N \{y_i - (ax_i + b)\}^2$$


多くのデータから回帰する
ここでも最適化問題

$$\min_{a,b} \sum_{i=1}^N \{y_i - (ax_i + b)\}^2$$

多くのデータから識別をする
パーセプトロン・サポートベクターマシーン







多くのデータから識別をする
パーセプトロン・サポートベクターマシーン
ここでも最適化問題

多くのデータからその素性を明らかにする営み
機械学習


多くの実験データから関数関係を明らかにする
実験レポートでやらされたこと


多くの購買データから顧客の嗜好を明らかにする

AmOzon

多くのWeb訪問履歴から使用者の意思を明らかにする
GoOgle

多くのデータから確率分布を明らかにする
ボルツマン機械学習





統計的性質
平均？分散？


統計的性質
平均？分散？
分布を知りたい

- ▶ 多数の数値列、データからの分布の推定
 - ▶ 生成モデルの存在の仮定

$$P(\mathbf{x}|\mathbf{u}) = \frac{1}{Z(\mathbf{u})} \exp \{ -E(\mathbf{x}|\mathbf{u}) \}$$

- ▶ 例：Ising模型（グラフは任意）

$$E(\mathbf{x}|\mathbf{u}) = \sum_{i=1}^N \sum_{j \in \partial i} J_{ij} x_i x_j + \sum_{i=1}^N h_i x_i$$



- ▶ 多数の数値列、データからの分布の推定
 - ▶ 生成モデルの存在の仮定


$$P(\mathbf{x}|\mathbf{u}) = \frac{1}{Z(\mathbf{u})} \exp \{ -E(\mathbf{x}|\mathbf{u}) \}$$

- ▶ 例：Ising模型（グラフは任意）

$$E(\mathbf{x}|\mathbf{u}) = \sum_{i=1}^N \sum_{j \in \partial i} J_{ij} x_i x_j + \sum_{i=1}^N h_i x_i$$

- ▶ 利用例

- ▶ 相関検出
 - カンニング検出、ニューロンシグナル、因子推定



- ▶ 多数の数値列、データからの分布の推定
 - ▶ 生成モデルの存在の仮定


$$P(\mathbf{x}|\mathbf{u}) = \frac{1}{Z(\mathbf{u})} \exp \{ -E(\mathbf{x}|\mathbf{u}) \}$$

- ▶ 例：Ising模型（グラフは任意）

$$E(\mathbf{x}|\mathbf{u}) = \sum_{i=1}^N \sum_{j \in \partial i} J_{ij} x_i x_j + \sum_{i=1}^N h_i x_i$$

- ▶ 利用例

- ▶ 相関検出
 - カンニング検出、ニューロンシグナル、因子推定
- ▶ ハミルトニアン推定
 - 物理モデルの正当化、パラメータ推定



- ▶ 多数の数値列、データからの分布の推定
 - ▶ 生成モデルの存在の仮定


$$P(\mathbf{x}|\mathbf{u}) = \frac{1}{Z(\mathbf{u})} \exp \{ -E(\mathbf{x}|\mathbf{u}) \}$$


- ▶ 例：Ising模型（グラフは任意）

$$E(\mathbf{x}|\mathbf{u}) = \sum_{i=1}^N \sum_{j \in \partial i} J_{ij} x_i x_j + \sum_{i=1}^N h_i x_i$$

- ▶ 利用例

- ▶ 相関検出
 - カンニング検出、ニューロンシグナル、因子推定
- ▶ ハミルトニアン推定
 - 物理モデルの正当化、パラメータ推定
- ▶ 特徴抽出
 - 職人技の学習、自然の学習






専門的知識の学習

=3

$$E(\mathbf{x}|\mathbf{u}) = \sum_{i=1}^N \sum_{j \in \partial i} J_{ij} \delta(x_i - x_j) + \sum_{i=1}^N h_i \delta(x_i - \tau_i)$$



脳画像ラベリングの例
Collaboration with U. Yamamoto



ボルツマン機械学習の基礎

- ▶ データとモデルがどれだけ一致しているか？

- ▶ Kullback-Leibler divergence

$$D_{\text{KL}}(P|Q) = \int d\mathbf{x} P(\mathbf{x}) \log \left(\frac{P(\mathbf{x})}{Q(\mathbf{x})} \right)$$

- ▶ 非負
- ▶ 三角不等式を満たさない、非対称



- ▶ データとモデルがどれだけ一致しているか？

- ▶ Kullback-Leibler divergence

$$D_{\text{KL}}(P|Q) = \int d\mathbf{x} P(\mathbf{x}) \log \left(\frac{P(\mathbf{x})}{Q(\mathbf{x})} \right)$$

- ▶ 非負
- ▶ 三角不等式を満たさない、非対称

- ▶ データの経験分布とモデルの分布を合わせる.

- ▶ KL情報量の最小化

$$P_D(\mathbf{x}) = \frac{1}{D} \sum_{d=1}^D \delta(\mathbf{x} - \mathbf{x}^{(d)})$$

$$D_{\text{KL}}(P_D|P_{\mathbf{u}}) = \int d\mathbf{x} P_D(\mathbf{x}) \log \left(\frac{P_D(\mathbf{x})}{P(\mathbf{x}|\mathbf{u})} \right)$$



ボルツマン機械学習の基礎

▶ 最尤法

- ▶ データに対するモデルの尤もらしさ（対数尤度関数の経験平均）

$$L(\mathbf{u}) = \frac{1}{D} \sum_{d=1}^D \log P(\mathbf{x} = \mathbf{x}^{(d)} | \mathbf{u})$$



Sparse Modeling

CREST

▶ 最尤法

- ▶ データに対するモデルの尤もらしさ（対数尤度関数の経験平均）

$$L(\mathbf{u}) = \frac{1}{D} \sum_{d=1}^D \log P(\mathbf{x} = \mathbf{x}^{(d)} | \mathbf{u})$$

- ▶ 統計力学のエントロピー最大原理と等価

$$L(\mathbf{u}) = -\frac{1}{D} \sum_{d=1}^D E(\mathbf{x} = \mathbf{x}^{(d)} | \mathbf{u}) - \log Z(\mathbf{u})$$



ボルツマン機械学習の基礎

- ▶ 単純な勾配法の適用
 - ▶ 勾配方向に更新して最大値を求める

$$\mathbf{u}[t + 1] = \mathbf{u}[t] + \eta \frac{\partial L(\mathbf{u})}{\partial \mathbf{u}}$$

- ▶ η : 学習係数、更新幅を設定している





ボルツマン機械学習の基礎

- ▶ 単純な勾配法の適用
 - ▶ 勾配方向に更新して最大値を求める

$$\mathbf{u}[t + 1] = \mathbf{u}[t] + \eta \frac{\partial L(\mathbf{u})}{\partial \mathbf{u}}$$

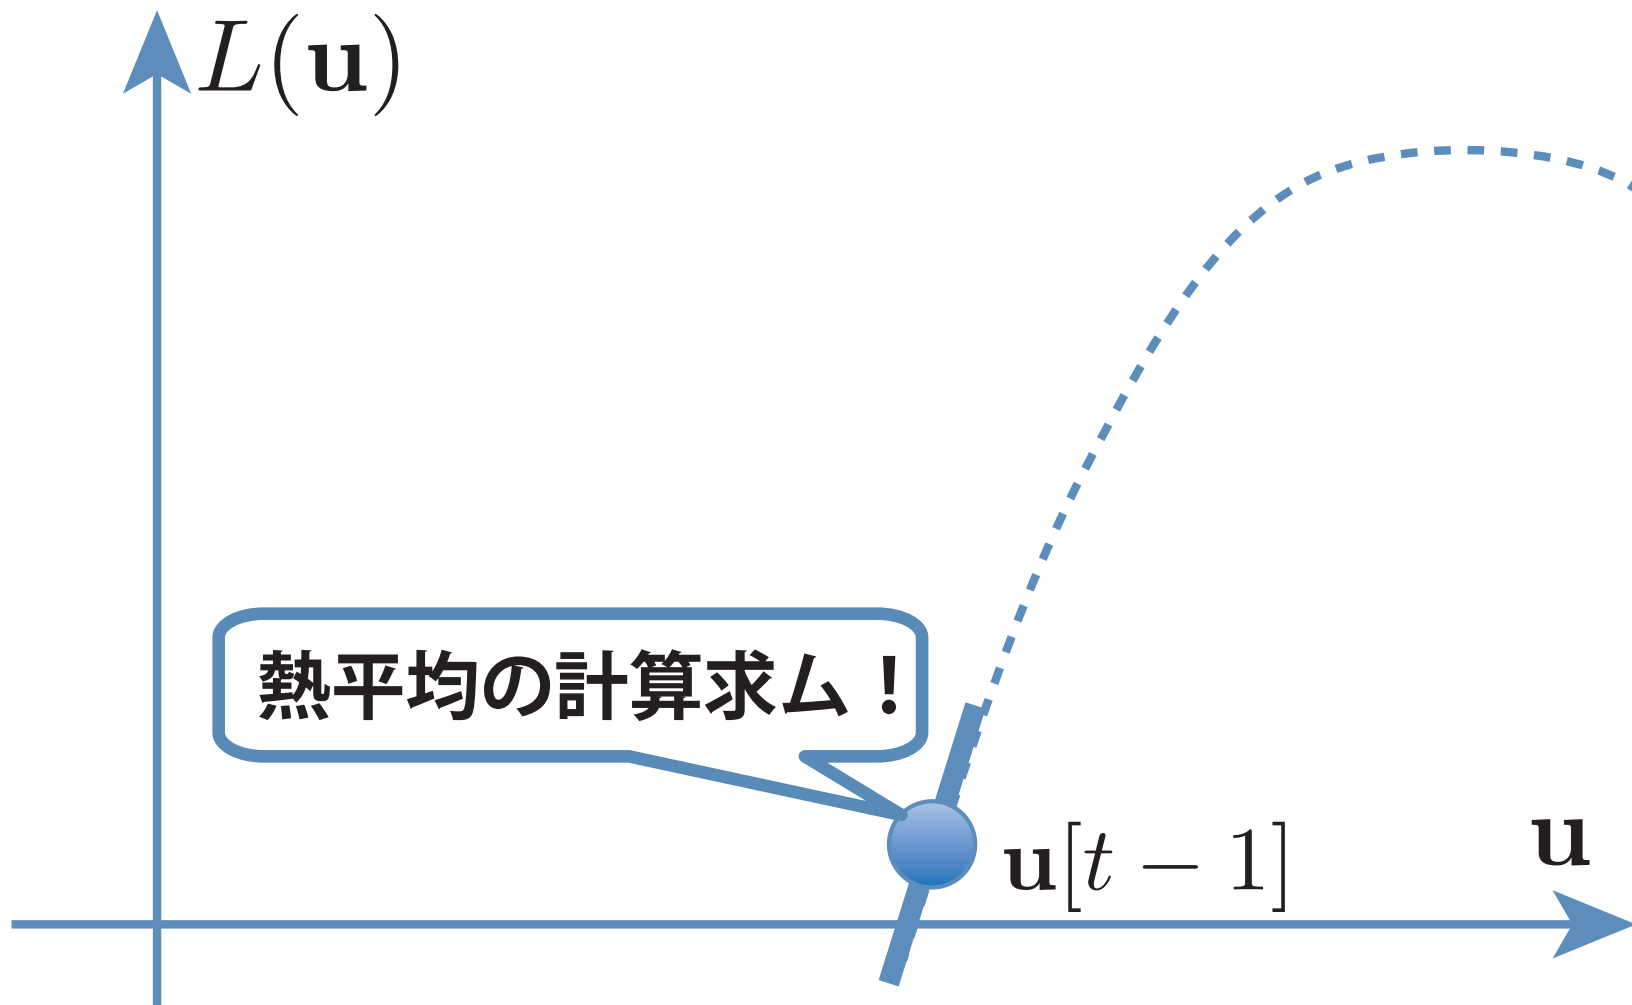
- ▶ η :学習係数、更新幅を設定している
- ▶ じゃあ勾配を計算してみよう！

$$\frac{\partial L(\mathbf{u})}{\partial \mathbf{u}} = -\frac{1}{D} \sum_{d=1}^D \frac{\partial E(\mathbf{x} = \mathbf{x}^{(d)} | \mathbf{u})}{\partial \mathbf{u}} + \left\langle \frac{\partial E(\mathbf{x} | \mathbf{u})}{\partial \mathbf{u}} \right\rangle_{\mathbf{u}}$$





ボルツマン機械学習の基礎



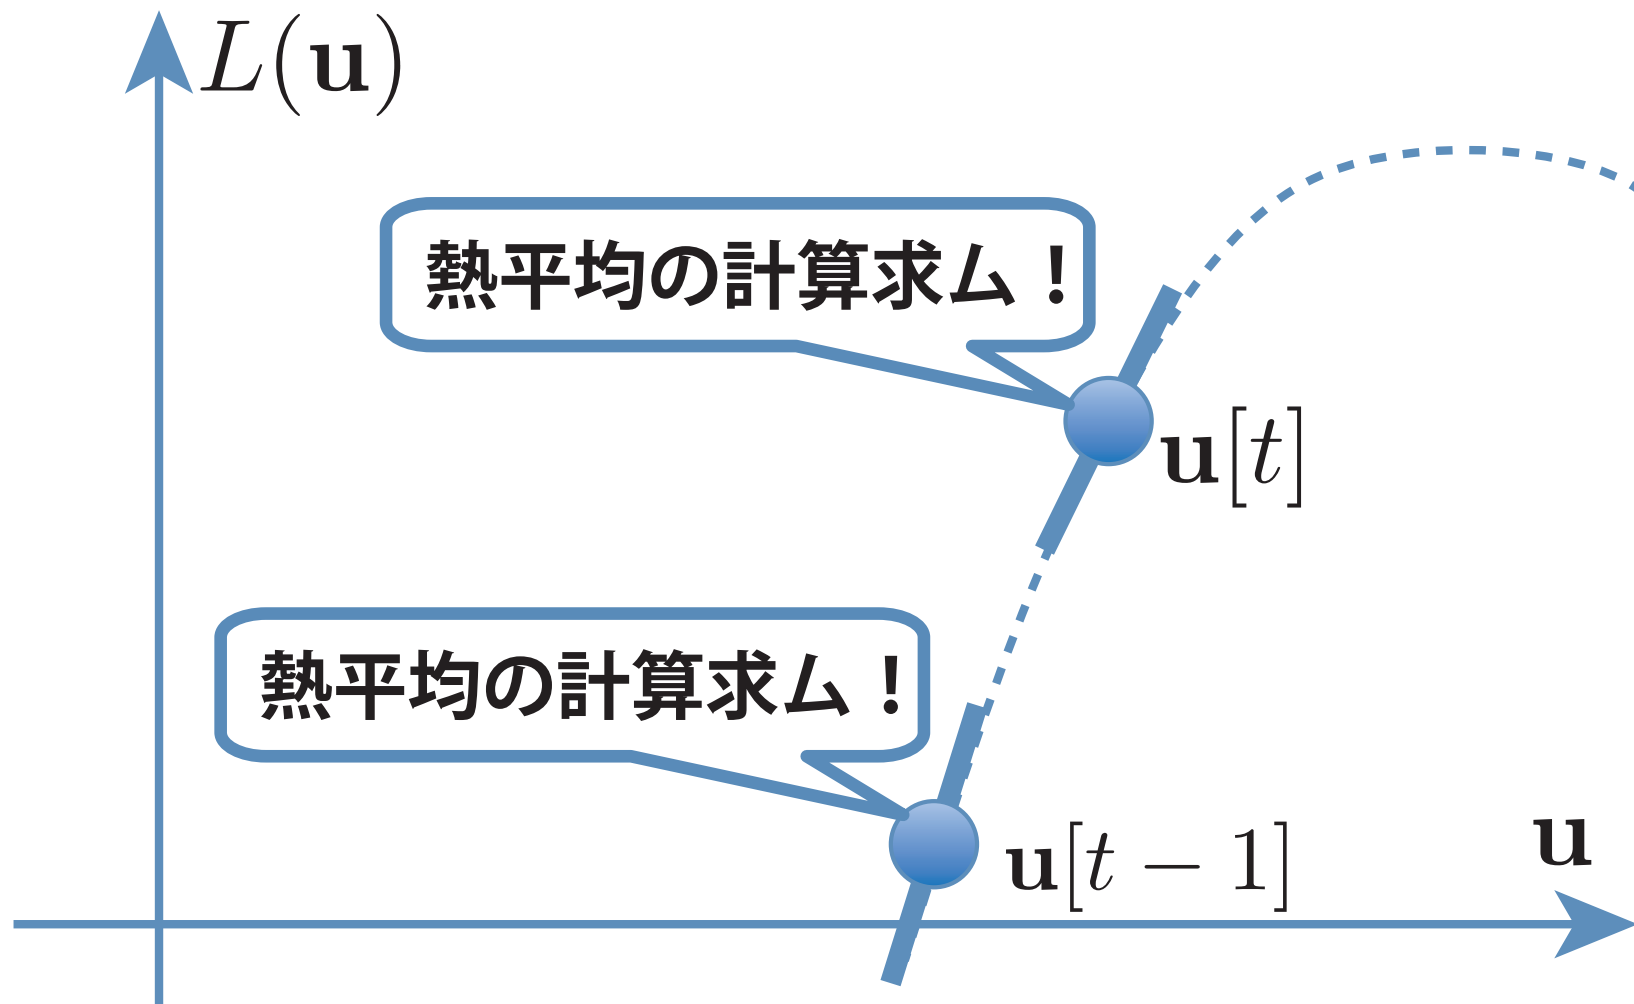
QUANTUM ANNEALING

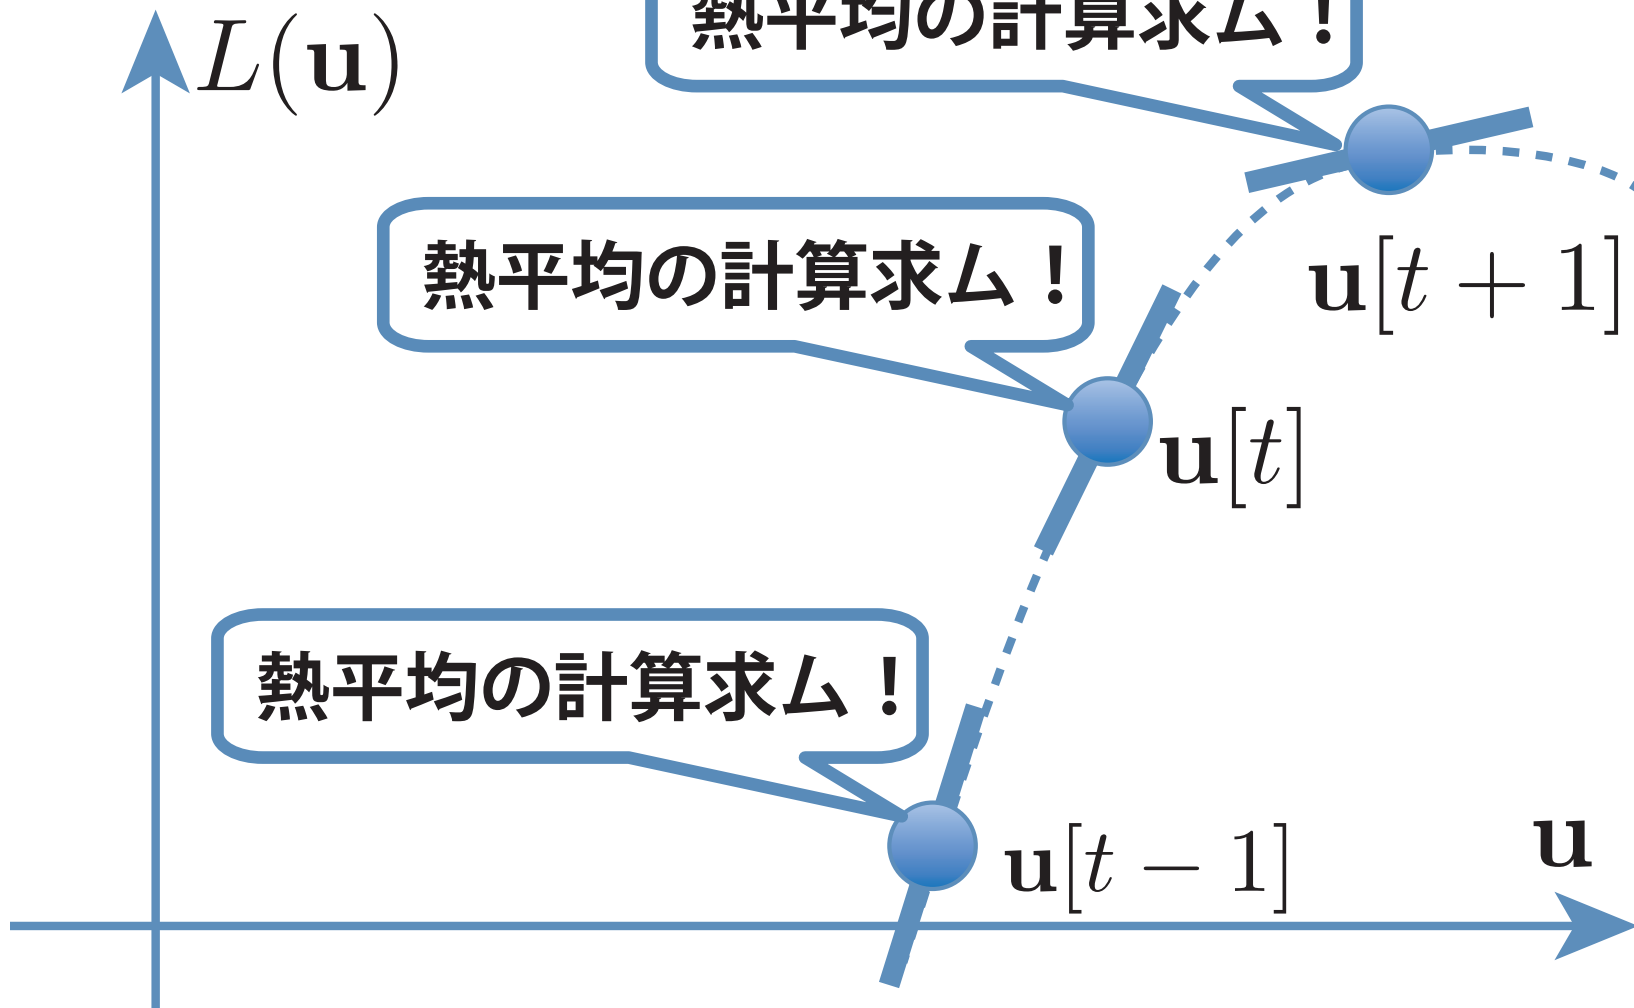


MACHINE LEARNING

Sparse Modeling

CREST





$$\left\langle \frac{\partial E(\mathbf{x}|\mathbf{u})}{\partial \mathbf{u}} \right\rangle_{\mathbf{u}}$$

ボルツマン機械学習の危機

$$\log Z(\mathbf{u})$$



ボルツマン機械学習

- ▶ 様々な手法（統計力学）が存在
 - ▶ 期待値計算に統計力学由来の手法
 - ▶ 高速だけど近似法
 - 平均場近似やその発展法 = 周囲の確率変数を期待値で置き換える

$$P(\mathbf{x}|\mathbf{u}) \approx \prod_{i=1}^N P(x_i|\mathbf{u})$$






ボルツマン機械学習

- ▶ 様々な手法（統計力学）が存在
 - ▶ 期待値計算に統計力学由来の手法
 - ▶ 高速だけど近似法
 - 平均場近似やその発展法 = 周囲の確率変数を期待値で置き換える

$$P(\mathbf{x}|\mathbf{u}) \approx \prod_{i=1}^N P(x_i|\mathbf{u})$$

- 例：Ising模型

$$J_{ij}x_i x_j = J_{ij}x_i m_j$$



- ▶ 様々な手法（統計力学）が存在
 - ▶ 期待値計算に統計力学由来の手法
 - ▶ 高速だけど近似法
 - 平均場近似やその発展法 = 周囲の確率変数を期待値で置き換える


$$P(\mathbf{x}|\mathbf{u}) \approx \prod_{i=1}^N P(x_i|\mathbf{u})$$

- 例：Ising模型

$$J_{ij}x_i x_j = J_{ij}x_i m_j$$

- ▶ 低速だけど厳密
 - 分配関数計算、マルコフ連鎖モンテカルロ法

$$P(\mathbf{x}|\mathbf{u}) \approx \prod_{t=0}^{T-1} \{P_{\mathbf{u}}(\mathbf{x}_{t+1}|\mathbf{x}_t)\} P(\mathbf{x}_0)$$



統計力学の敗北

- ▶ 様々な手法 (統計力学) が存在 + 計測技術 (データ) の向上

- ▶ 統計的機械学習

- ▶ 疑似最尤法 = 平均場近似? + データの利用

- ☐ 周囲を期待値ではなく、データの値そのものを入れる

$$P(\mathbf{x}|\mathbf{u}) \approx \prod_{i=1}^N P(x_i|\mathbf{x}_{-/i}, \mathbf{u})$$

- ☐ 例: Ising模型

$$J_{ij}x_i x_j = J_{ij}x_i x_j^{(d)}$$

- ▶ 最小確率流法

= 確率過程 + データの利用: ちょっと動かして定常性を探る

$$\min_{\mathbf{u}} \left\{ \sum_{\mathbf{x}} P_D(\mathbf{x}) \log \frac{Q_{\mathbf{u}}(\mathbf{x})}{P_D(\mathbf{x})} \right\} \quad Q_{\mathbf{u}}(\mathbf{x}') = \sum_{\mathbf{x}} P_{\mathbf{u}}(\mathbf{x}'|\mathbf{x}) P_D(\mathbf{x})$$



機械学習

統計力学 + データ

機械学習


統計力学 + データ

但し大量のデータが必要

非線形写像でデータを散らす
リザーブコンピューティング

リザーコンピュティング

- ▶ 複雑だけど適応的学習はしないフレームワーク
 - ▶ リカレント（再帰型）ニューラルネットワークの利用
 - ▶ 重みはランダムに与えたままで固定（中間層の学習はしない）



- ▶ 既存の非線形入出力関係を持つハードウェアの利用が可能
- ▶ 時系列の予測・判別
- ▶ データの増大をした上での線形識別


更なる複雑度への挑戦
深層学習

深層学習への挑戦

- ▶ 簡単に計算できるけど複雑なモデルを利用する

- ▶ **隠れ変数**有りボルツマン機械学習

- ▶ それぞれの層の変数間には相互作用がない (条件付き独立性)



□ 例: Ising模型
$$\sum_{k \in \partial i} J_{ik} v_i h_k = J_{ij}^{(\mathbf{h})} x_i x_j$$

- ▶ 物理の言葉で言うと実空間繰り込みで実効相互作用をもつ
- ▶ コントラストティヴ・ダイバージェンス

= (独立な) マルコフ連鎖モンテカルロ法 + データの利用

- ▶ 大量の高次元データの利用 = 経験平均ですら大変

- ▶ 確率勾配法 = 確率過程 + データの利用





確率勾配法：最近の発展

M. Ohzeki: to appear soon in arXiv

- ▶ 大量の高次元データに対する勾配計算をさぼる
 - ▶ 確率勾配法（最尤法の近似） [Robbins and Monro (1951)]
 - ▶ ランダムに選択されたデータのみによる勾配を利用

$$\frac{\partial L(\mathbf{u})}{\partial \mathbf{u}} = -\frac{1}{d} \sum_{k=1}^d \frac{\partial E(\mathbf{x} = \mathbf{x}^{(k)} | \mathbf{u})}{\partial \mathbf{u}} + \left\langle \frac{\partial E(\mathbf{x} | \mathbf{u})}{\partial \mathbf{u}} \right\rangle_{\mathbf{u}}$$

- ▶ 確率勾配Langevin法（サンプリング法へ） [Welling and The(2011)]
 - ▶ Langevin方程式を利用したノイズでパラメータ空間での平衡状態を生成

$$\mathbf{u}[t + 1] = \mathbf{u}[t] + \eta \frac{\partial L(\mathbf{u})}{\partial \mathbf{u}} + dW$$

- ▶ 詳細釣り合いの破れを利用して高速サンプリング法へと発展

[Ohzeki and Ichiki (2015)]

QUANTUM ANNEALING



MACHINE LEARNING

Sparse Modeling

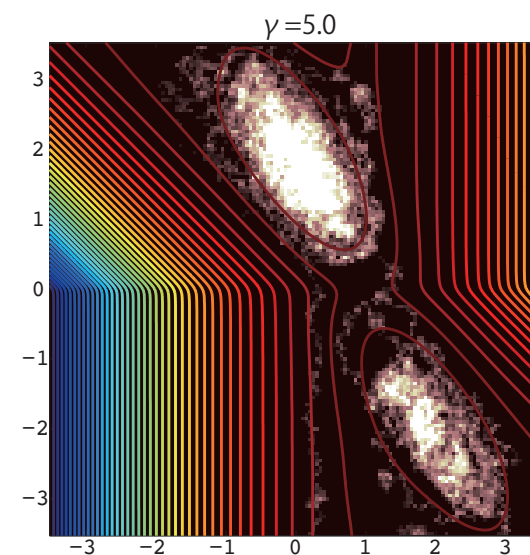

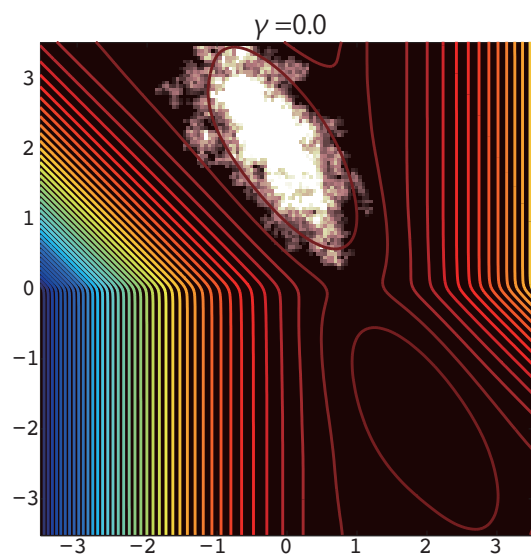
CREST




確率勾配法：最近の発展


M. Ohzeki: to appear soon in arXiv

- ▶ 利用例： γ = 詳細釣り合いの破れ度合い




機械学習とは
データに対する関数の自律的フィッティング






$$y = a_0 + a_1x + a_2x^2 + \cdots + a_Nx^N$$




$$y = a_0 + a_1x + a_2x^2 + \cdots + a_Nx^N$$



$$y = 0 + a_1x + a_2x^2 + 0 \times x^3 + \dots$$

本質の抽出
スパースモデリング



$$\min_{a_i} \left\{ \sum_{d=1}^D \left(y_d - \sum_{i=0}^N a_i x_d^i \right)^2 + \lambda \|a_i\|_1 \right\}$$



L1ノルムによる変数選択

M. Ohzeki: J. Phys. Soc. Jpn. 84, 054801 (2015)

- ▶ 基本は勾配法ベースの最尤法
 - ▶ コスト関数は様々に選べる
 - ▶ ボルツマン機械学習はデータが少ないと精度がでない
 - ビッグデータ時代だから大丈夫？
 - L1ノルムを使った正則化で解を選択

$$\min_{\mathbf{u}} \left\{ -L(\mathbf{u}) + \lambda \sum_{i < j} \|J_{ij}\|_1 \right\}$$

- ▶ メジャライザー最小化で実行可能！

$$f(\mathbf{u}) = \|\mathbf{u}\|_1 \quad g(\mathbf{u}) = -L(\mathbf{u})$$

$$\mathbf{u}[t + 1] = \arg \min_{\mathbf{u}} \left\{ f(\mathbf{u}) + (\nabla g(\mathbf{u}))^T (\mathbf{u} - \mathbf{u}[t]) + \frac{L}{2} \|\mathbf{u} - \mathbf{u}[t]\|_2^2 \right\}$$






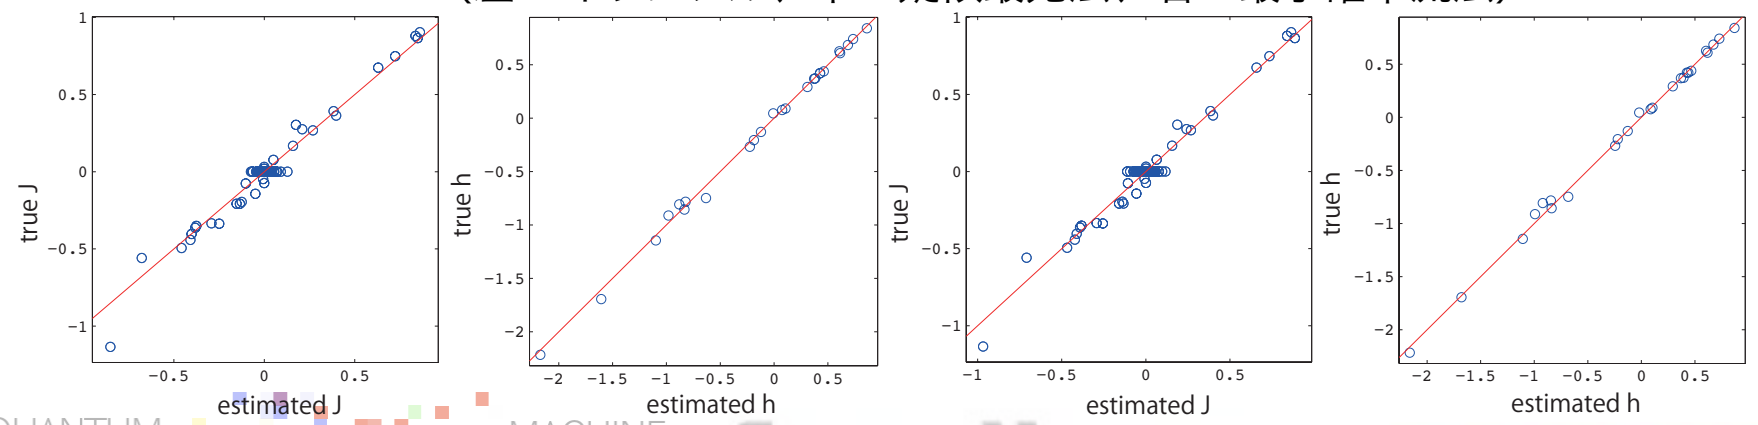
L1ノルムによる変数選択

M. Ohzeki: J. Phys. Soc. Jpn. 84, 054801 (2015)

- ▶ スパース相関推定：実験結果
 - ▶ N=25、D=5000
 - ▶ 相互作用に1割程度の非零成分（ガウスランダム）



(左：オリジナル、中：疑似最尤法、右：最小確率流法)



QUANTUM ANNEALING



MACHINE LEARNING

Sparse Modeling






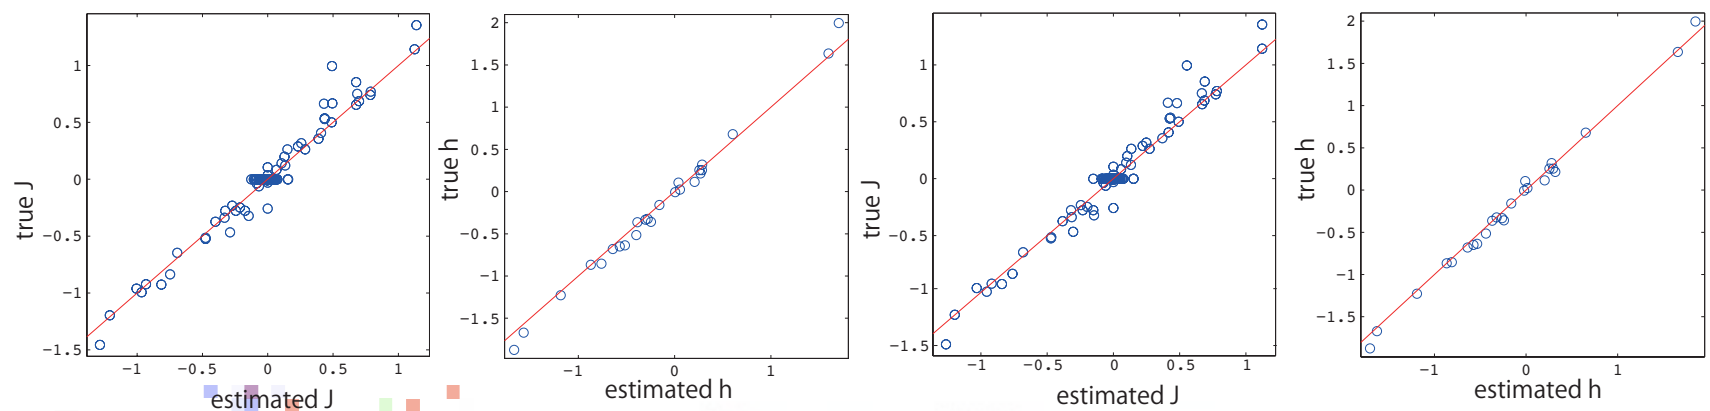
L1ノルムによる変数選択

M. Ohzeki: J. Phys. Soc. Jpn. 84, 054801 (2015)

- ▶ スパース相関推定：実験結果
 - ▶ N=25、D=5000
 - ▶ 相互作用を2次元最近接に限定、1割程度の非零成分（ガウスランダム）



(左：オリジナル、中：疑似最尤法、右：最小確率流法)



QUANTUM ANNEALING



MACHINE LEARNING

Sparse Modeling



多くの答案から生徒の能力を明らかにする
項目応答理論



項目応答理論

F. Baker: Item response theory : parameter estimation techniques(2004)

- ▶ 試験結果により得られるデータからパラメータ推定
 - ▶ 各種導入実績
 - ▶ テストの品質管理
 - 情報処理技術者試験
 - TOEFL、TOEIC
 - 医療系資格試験、etc
 - ▶ アンケート結果からの顧客の指向調査



Sparse Modeling

CREST



項目応答理論

F. Baker: Item response theory : parameter estimation techniques(2004)

- ▶ 1-パラメータロジスティックモデル
 - ▶ テストの品質管理に用いられる確率論的モデル

$$P(\mathbf{x}|\boldsymbol{\theta}, \mathbf{d}) = \frac{1}{Z(\boldsymbol{\theta}, \mathbf{d})} \prod_{j=1}^J \exp \left\{ \sum_{i=1}^I (\theta_i - d_j) x_{ij} \right\},$$

- ▶ $x_{ij} = \pm 1$: i 番目の被験者が j 番目の項目に正答したかどうか
 正答の場合 $x_{ij} = 1$ 誤答の場合 $x_{ij} = -1$
- ▶ θ_i : i 番目の被験者の能力
- ▶ d_j : j 番目の項目の難易度



- ▶ カンニングを想定した拡張
 - ▶ 被験者間の相関を考慮する

$$P(\mathbf{x}|\boldsymbol{\theta}, \mathbf{d}, \mathbf{w}) =$$


$$\prod_{j=1}^J \frac{1}{Z_j} \prod_{i=1}^I \exp \left\{ (\theta_i - d_j) x_{ij} + \sum_{k \in \partial(i)} w_{ik} x_{ij} x_{kj} \right\} \cdot$$


- ▶ カンニング係数の導入
 - w_{ik} : 被験者 i と被験者 k の協力関係
- ▶ 今回はレポート問題（全結合）で教え合う（対称的）状況を仮定


あらゆる**関係性**を考えればよいか？

L1ノルムによる推定結果


- ▶ L1ノルムによるスパース解推定
 - ▶ 問題数 $J=1000$ のとき







全員カンニング?!



理想的なカンニング

あるかないかはっきり言ってほしい！

あるかないかはっきり言ってほしい！

L0ノルムによる正則化

あるかないかはっきり言ってほしい！

L0ノルムによる正則化

組み合わせ最適化問題??

あるかないかはっきり言ってほしい！

L0ノルムによる正則化

~~組み合わせ最適化問題??~~

近似解法（貪欲法）



はっきりと零・非零を分けた推定：貪欲法の利用

A. Decelle and F. Ricci-Tersenghi: Phys. Rev. Lett. 112 (2014) 070603.

- ▶ デシメーションアルゴリズムの導入
 - ▶ 基本は尤度関数（うまく説明している度合い）の最大化

$$\max_{\mathbf{w}, \theta, \mathbf{d}} \{ \mathcal{L}(\mathbf{w}, \theta, \mathbf{d}) \}$$





はっきりと零・非零を分けた推定：貪欲法の利用

A. Decelle and F. Ricci-Tersenghi: Phys. Rev. Lett. 112 (2014) 070603.

- ▶ デシメーションアルゴリズムの導入
 - ▶ 基本は尤度関数（うまく説明している度合い）の最大化

$$\max_{\mathbf{w}, \theta, \mathbf{d}} \{ \mathcal{L}(\mathbf{w}, \theta, \mathbf{d}) \}$$

1. まず最尤推定を行う.

$$\mathbf{w} = (w_{12}, w_{23}, w_{24}, \dots, w_{I-1, I})$$





はっきりと零・非零を分けた推定：貪欲法の利用

A. Decelle and F. Ricci-Tersenghi: Phys. Rev. Lett. 112 (2014) 070603.

- ▶ デシメーションアルゴリズムの導入
 - ▶ 基本は尤度関数（うまく説明している度合い）の最大化

$$\max_{\mathbf{w}, \theta, \mathbf{d}} \{ \mathcal{L}(\mathbf{w}, \theta, \mathbf{d}) \}$$

1. まず最尤推定を行う.

$$\mathbf{w} = (w_{12}, w_{23}, w_{24}, \dots, w_{I-1, I})$$

2. 推定結果において、絶対値が小さいものを消す.

$$\mathbf{w} = (\boxed{0.002}, 0.78, \boxed{0.0001}, \dots, 0.3)$$





はっきりと零・非零を分けた推定：貪欲法の利用

A. Decelle and F. Ricci-Tersenghi: Phys. Rev. Lett. 112 (2014) 070603.

- ▶ デシメーションアルゴリズムの導入
 - ▶ 基本は尤度関数（うまく説明している度合い）の最大化

$$\max_{\mathbf{w}, \theta, \mathbf{d}} \{ \mathcal{L}(\mathbf{w}, \theta, \mathbf{d}) \}$$

1. まず最尤推定を行う。

$$\mathbf{w} = (w_{12}, w_{23}, w_{24}, \dots, w_{I-1, I})$$

2. 推定結果において、絶対値が小さいものを消す。

$$\mathbf{w} = (0.002, 0.78, 0.0001, \dots, 0.3)$$

3. 残った非零サポートのみで最尤推定を行う。

$$\mathbf{w} = (0, w_{23}, 0, \dots, w_{I, I-1})$$





はっきりと零・非零を分けた推定：貪欲法の利用

A. Decelle and F. Ricci-Tersenghi: Phys. Rev. Lett. 112 (2014) 070603.

- ▶ デシメーションアルゴリズムの導入
 - ▶ 基本は尤度関数（うまく説明している度合い）の最大化

$$\max_{\mathbf{w}, \theta, \mathbf{d}} \{ \mathcal{L}(\mathbf{w}, \theta, \mathbf{d}) \}$$

1. まず最尤推定を行う。

$$\mathbf{w} = (w_{12}, w_{23}, w_{24}, \dots, w_{I-1, I})$$

2. 推定結果において、絶対値が小さいものを消す。

$$\mathbf{w} = (0.002, 0.78, 0.0001, \dots, 0.3)$$


3. 残った非零サポートのみで最尤推定を行う。


$$\mathbf{w} = (0, w_{23}, 0, \dots, w_{I, I-1})$$

▶ 利点


- ▶ 零となるところをはっきりと零と指定する









従来の推定法（性悪説?!）




デシメーション (性善説)




従来の推定法（性悪説?!）



デシメーション (性善説)



従来の推定法（性悪説?!）



デシメーション (性善説)



はっきりと零・非零を分けた推定：貪欲法の利用

A. Decelle and F. Ricci-Tersenghi: Phys. Rev. Lett. 112 (2014) 070603.

- ▶ 直観的には…
 - ▶ 性善説にもとづく推定
 - ▶ カンニング係数の絶対値が小さいのだから、疑いが小さい
 - ▶ 疑いが小さい被験者をいつまでも疑わない
 - ▶ だってカンニングは基本的にはないものだから！！



Sparse Modeling

CREST



はっきりと零・非零を分けた推定：貪欲法の利用

A. Decelle and F. Ricci-Tersenghi: Phys. Rev. Lett. 112 (2014) 070603.

- ▶ 直観的には…
 - ▶ 性善説にもとづく推定
 - ▶ カンニング係数の絶対値が小さいのだから、疑いが小さい
 - ▶ 疑いが小さい被験者をいつまでも疑わない
 - ▶ だってカンニングは基本的にはないものだから！！

性善説で精度が向上

「ボルツマン機械学習は，もともと1つ1つの要素の相互作用を見つけるのが得意なプログラムです。それぞれの問題での正解，不正解のデータから，生徒




はっきりと零・非零を分けた推定：貪欲法の利用

A. Decelle and F. Ricci-Tersenghi: Phys. Rev. Lett. 112 (2014) 070603.

- ▶ 直観的には…
 - ▶ 性善説にもとづく推定
 - ▶ カンニング係数の絶対値が小さいのだから、疑いが小さい
 - ▶ 疑いが小さい被験者をいつまでも疑わない
 - ▶ だってカンニングは基本的にはないものだから！！





- ▶ どこまでデシメーションすればよいのか？
 - ▶ スパース性の仮定のもとでは、ほとんどのカンニング係数は0である
 - ▶ 非常に小さいカンニング係数を0としても尤度関数はほぼ変わらない



デシメーションアルゴリズム


- ▶ どこまでデシメーションすればよいのか？
 - ▶ スパース性の仮定のもとでは、ほとんどのカンニング係数は0である
 - ▶ 非常に小さいカンニング係数を0としても尤度関数はほぼ変わらない


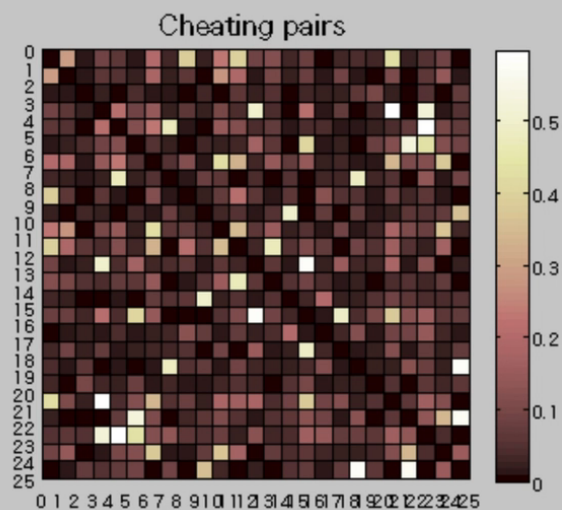



デシメーションアルゴリズム


- ▶ どこまでデシメーションすればよいのか？
 - ▶ スパース性の仮定のもとでは、ほとんどのカンニング係数は0である
 - ▶ 非常に小さいカンニング係数を0としても尤度関数はほぼ変わらない

$$\mathcal{L}_{\text{tilted}} = \mathcal{L} - x\mathcal{L}_{\text{max}} - (1 - x)\mathcal{L}_{\text{min}}$$





- ▶ カンニング係数の推定結果
 - ▶ $\mathcal{L}_{\text{tilted}}$ のピーク位置と推定誤差の最小値をとる位置が一致



被験者数 : $I = 30$
 ペア数 : $I(I-1)/2 = 435$
 カンニングをしている割合
 0.1
 項目数 : $J = 1000$


デシメーションされたペア数

数値計算結果

S. Yamanaka, M. Ohzeki, A. Decelle: JPSJ 84, 024801 (2015)

▶ カンニング係数の推定結果

▶ $\mathcal{L}_{\text{tilted}}$ のピーク位置でROC曲線の最良点にある



被験者数 : $I = 30$

ペア数 : $I(I-1)/2 = 435$

カンニングをしている割合
0.1

項目数 : $J = 1000$

真陽性率 :

カンニングをしていると推定されたペア
/実際にカンニングをしているペア

真陰性率 :

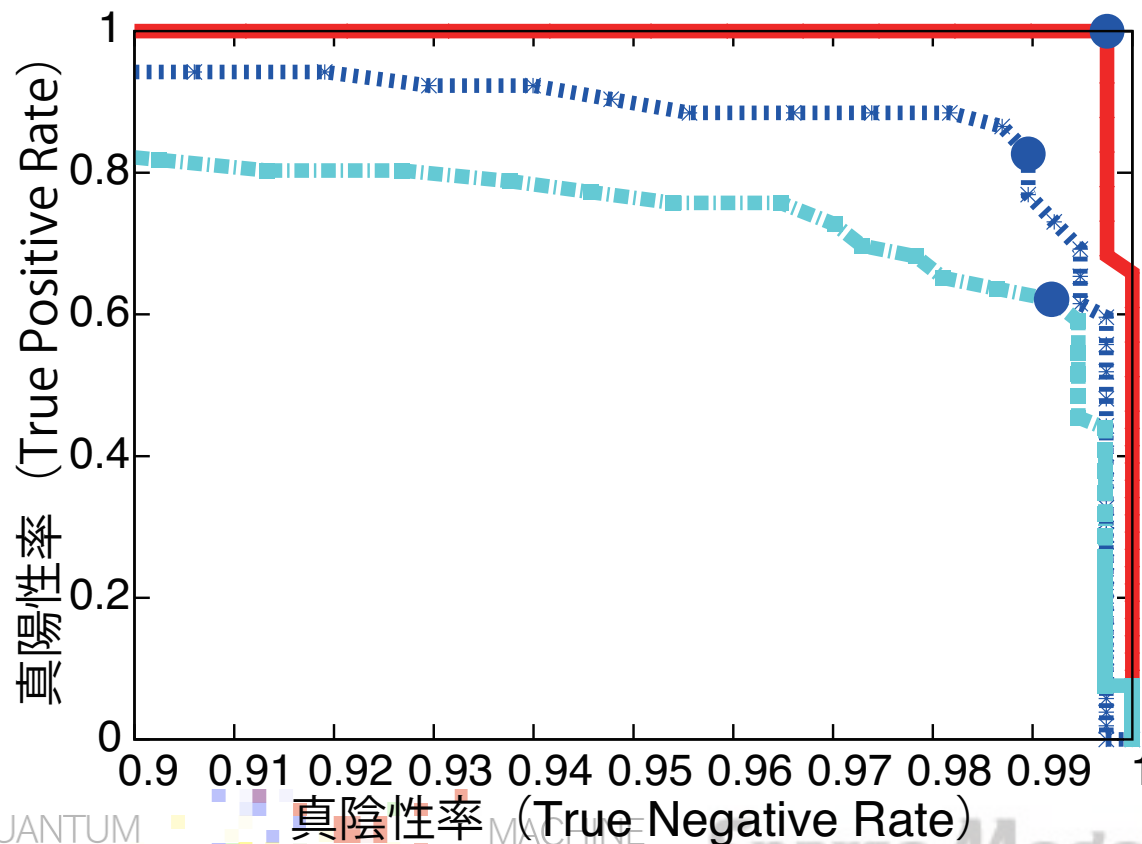
カンニングをしていないと推定されたペア
/実際にカンニングをしていないペア



スパース性との関係性

S. Yamanaka, M. Ohzeki, A. Decelle: JPSJ 84, 024801 (2015)

- ▶ カンニング係数の推定結果
 - ▶ ROC曲線が左下に後退、真陽性率が減少



被験者数 : $I = 30$
 ペア数 : $I(I-1)/2 = 435$
 カンニングをしている割合
0.1 -> 0.125 -> 0.15

項目数 : $J = 1000$
 真陽性率 :
 カンニングをしていると推定されたペア / 実際にカンニングをしているペア
 真陰性率 :
 カンニングをしていないと推定されたペア / 実際にカンニングをしていないペア



まとめ

- ▶ ボルツマン機械学習=データ駆動型の統計力学
 - ▶ 期待値計算を如何に**正確**に実行するか（マルコフ連鎖モンテカルロ法）
 - ▶ 期待値計算を如何に**高速**に実行するか（平均場近似等）
 - ▶ **大規模なデータ利用**を如何にさぼるか（確率勾配法）
 - ▶ 複雑度を増しても計算は容易なものが登場
 - 深層学習における隠れ変数ありボルツマンマシン
 - リザーブコンピューティング
- ▶ 本質部分の抽出=ビッグデータに対する対処策
 - ▶ 複雑になればなるほど、本質が**曖昧**に
 - ▶ スパースモデリングの導入により**クリアな理解**へ

