





d.a.t. 株式会社主催セミナー

今日から分かる スパースモデリングと深層学習

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



自己紹介

▶ 大関真之

- ▶ 京都大学大学院情報学研究科システム科学専攻助教
 - ▶ 理論物理学：統計力学、量子アニーリング
 - ▶ 機械学習：深層学習、ボルツマン機械学習



Sparse Modeling

CREST

今日から分かるスパースモデリングと深層学習

テクニカルな内容を知りたいけば


検索：大関 真之 > TopないしはPublish (Article)


講義ノート

直接メール

mohzeki@i.kyoto-u.ac.jp


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





書籍等にある表現の意味


- ▶ 出力 (y)を説明するために入力(x)とどういう関係にあるかを図示




$$y = ax + b \text{ だと思っている}$$

- ▶ いくつもあるデータ (x) を入力して出力 (y) と近くなるように学習


複雑になったら??






直線？曲線？何次関数？？

- 出力 (y)を説明するために入力(x)とどういう関係にあるかを図示







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

応用すると…??

- ▶ 出力 (y)を説明するために入力(x)ととにかくどんな関係にあるか？




出力を参考にすれば識別ができる




回帰から識別問題への拡張＝ニューラルネットワーク


- ▶ 出力 (y)を説明するために入力(x)ととにかくどんな関係にあるか？



有りそうか？



- ▶ 出力 (y) がどれだけ生じやすそうか？ (不確実性を加味)






こんなことができます：ボルツマン機械学習


Collaboration with Utako Yamamoto (Kyoto University)

専門的知識の学習


FA画像





MD画像



RD画像



DWI画像








こんなことができます：ボルツマン機械学習

Collaboration with Utako Yamamoto (Kyoto University)

専門的知識の学習



QUANTUM
ANNEALING



MACHINE
LEARNING





Sparse Modeling

CREST

こんなことができます：ボルツマン機械学習

Collaboration with Utako Yamamoto (Kyoto University)

専門的知識の学習



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


猫か犬かを識別する

猫か犬かを識別する
できそうでしょ？

どこに注目すればええねん！！

中間層の導入=多層ニューラルネットワーク

- ▶ 入力 (y) を抽象化する **中間層** の導入



多層ニューラルネットワークの失敗の歴史


- ▶ 入力 (y)を抽象化する**中間層**の導入
 - ▶ 中間層の導入による学習にかかる**最適化問題**の困難
 - ▶ (本質的な理由) 勾配消失問題
 - ▶ **中間層**の役割？
 - ▶ **提案当初**の計算機的能力
 - ▶ **提案当初**の貧弱なデータ数

多層ニューラルネットワークの失敗の歴史

- ▶ 入力 (y)を抽象化する**中間層**の導入
 - ▶ 中間層の導入による学習にかかる**最適化問題**の困難
 - ▶ (本質的な理由) 勾配消失問題
 - ▶ **中間層**の役割？
 - ▶ **提案当初**の計算機的能力
 - ▶ **提案当初**の貧弱なデータ数
 - ▶ 現代においては中間層が豊富でも最適化が可能
 - ▶ **現代**の計算機資源の豊富さ
 - ▶ **現代**のデータ数の規模・高次元化
 - ▶ **現代**の学習方法の革命・**自己符号化**の提案＝中間層の解釈が可能に


中間層の学習＝何かしらの変換

- ▶ 入力 (x)を復元する変換となるようにする＝自己符号化




中間層の学習＝何かしらの変換

- ▶ 入力 (x)を復元する変換となるようにする＝自己符号化




中間層の学習＝何かしらの変換

- ▶ 入力 (x)を復元する変換となるようにする＝自己符号化




中間層の学習＝何かしらの変換

- ▶ 入力 (x) を復元する変換となるようにする＝自己符号化




中間層の学習＝何かしらの変換

- ▶ 入力 (x)を復元する変換となるようにする＝自己符号化




中間層の学習=何かしらの変換

- ▶ 入力 (x)を復元する変換となるようにする=自己符号化




中間層の学習＝何かしらの変換

- ▶ 入力 (x)を復元する変換となるようにする＝自己符号化




中間層の学習＝何かしらの変換

- ▶ 入力 (x) を復元する変換となるようにする＝自己符号化



中間層＝何かしらの変換

- ▶ 出力 (y)を再現するように結合を再度チューニングする



深層学習とは…

本質部分の抽出を自動化した学習

深層学習とは…

本質部分の抽出を自動化した学習
でもどこが本質か？

深層学習とは…


本質部分の抽出を自動化した学習


でもどこが本質か？

モデリングの放棄


スパースモデリング

どこが本質かを自動的に判別する技術






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



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



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

スパースモデリング

どこが零かを自動的に判別する技術


分かりやすい例として

多くの答案から生徒のカンニングを検出する


“Detection of cheating by decimation algorithm”


J. of Phys. Soc. of Jpn., 84 (2015) 024801.

有りそうか？
= 正解しそうか




有りそうか？
= 正解しそうか






どんな出力が
ふさわしいか？

- ▶ 正解・不正解はどんな要素が関わるのか??
 - ▶ 通常の教育環境



- ▶ 正解・不正解はどんな要素に関わるのか？


- ▶ **カンニングが疑われる**教育環境



あらゆる関係性を考えればよいか？


- ▶ 正解・不正解はどんな要素が関わるのか？

- ▶ **カンニングが疑われる** 教育環境



- ▶ 正解・不正解はどんな要素が関わるのか？

- ▶ **カンニングが疑われる**教育環境




全員カンニング？！

カンニングはスパース（稀、疎）

- ▶ 正解・不正解はどんな要素に関わるのか？


- ▶ **カンニングが疑われる** 教育環境



理想的なカンニング


デシメーションアルゴリズム

- 基本的にはカンニング係数を零とする
 - 繰り返し重みの学習をする




デシメーションアルゴリズム

- 基本的にはカンニング係数を零とする
 - 繰り返し重みの学習をする




デシメーションアルゴリズム

- 基本的にはカンニング係数を零とする
 - 繰り返し重みの学習をする




デシメーションアルゴリズム

- 基本的にはカンニング係数を零とする
 - 繰り返し重みの学習をする



デシメーションアルゴリズム


- 基本的にはカンニング係数を零とする
 - 繰り返し重みの学習をする



従来法の利用

デシメーションアルゴリズム

- 基本的にはカンニング係数を零とする
 - 繰り返し重みの学習をする



スパースモデリング

(適切にモデル化したのち)

どこが**本質**かを**自動的に**判別する技術



ビジネスへの応用の方向性

- ▶ スパースモデリングと深層学習というふたつの現代の魔法
 - ▶ 深層学習
 - ▶ 何かが何でも自動的に、回帰、（その結果を用いた）予測、識別を行う
 - ▶ その結果に基づき、**トップやユーザーの判断**を支援
 - ▶ **Web上、クラウド上等**での**ユーザー向けサービス**への利用
 - ▶ ライブラリが整い、**誰でもできる**
 - ▶ スパースモデリング
 - ▶ **何が重要**なのか、**データの分析**をする処方箋
 - ▶ 重要ではない要素は何か、重要な要素は何か＝人間の**直感との比較**が可能
 - ▶ **分析結果の共有**による**独自の知識の蓄積**が可能
 - ▶ 社内独自の知見の検証が可能



Sparse Modeling

CREST

スパースモデリングのもうひとつの側面


計測革命


中学生の頃の思い出


中学生の頃の思い出
連立方程式

$$2x_1 + x_2 = 1$$

を満たす解を求めよ









劣決定系の方程式も解がスパースなら解ける


劣決定系の方程式も解がスパースなら解ける
スパース = 0 ばかりだよ




劣決定系の方程式も解がスパースなら解ける
情報を減らしても大丈夫



MRI画像の例



少ないデータ



圧縮センシング利用





Fig. 5. Simulated UV coverage of M87 with six-station sub-mm VLBI array of EHT. Here it is assumed that observations are conducted at an elevation larger than 20° at each station.



ブラックホール撮像の例

M. Honma et al. Publ. Astron. Soc. Jpn. (2014)





Fig. 5. Simulated UV coverage of M87 with six-station sub-mm VLBI array of EHT. Here it is assumed that observations are conducted at an elevation larger than 20° at each station.



ブラックホール撮像の例

M. Honma et al. Publ. Astron. Soc. Jpn. (2014)







Fig. 5. Simulated UV coverage of M87 with six-station sub-mm VLBI array of EHT. Here it is assumed that observations are conducted at an elevation larger than 20° at each station.



ブラックホール撮像の例

M. Honma et al. Publ. Astron. Soc. Jpn. (2014)

不足した観測情報 + 推定方法
圧縮センシング




スパース解推定

- ▶ L0ノルム最小化によるスパース解推定
 - ▶ 以下の最小化問題でスパース解を探索しよう！

$$\min_{\mathbf{x}} \|\mathbf{x}\|_0 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$


- ▶ L0ノルム最小化によるスパース解推定
 - ▶ 以下の最小化問題でスパース解を探索しよう！

$$\min_{\mathbf{x}} \|\mathbf{x}\|_0 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$



- ▶ L0ノルム最小化によるスパース解推定
 - ▶ 以下の最小化問題でスパース解を探索しよう！


$$\min_{\mathbf{x}} \|\mathbf{x}\|_0 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$



- ▶ L0ノルム最小化によるスパース解推定
 - ▶ 以下の最小化問題でスパース解を探索しよう！


$$\min_{\mathbf{x}} \|\mathbf{x}\|_0 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$

- ▶ 非零成分の個数が小さい（スパース）もので方程式を満たすものを探す
- ▶ 残念ながら計算量的に困難（組み合わせ最適化問題）



- ▶ **L1** ノルム最小化によるスパース解推定
 - ▶ 代わりに次の最小化問題で探索しよう！

$$\min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$




$$\|\mathbf{x}\|_1 = |x_1| + |x_2| + \cdots + |x_N|$$

スパース解推定

- ▶ **L1** ノルム最小化によるスパース解推定
 - ▶ 代わりに次の最小化問題で探索しよう！


$$\min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$



$$\|\mathbf{x}\|_1 = |x_1| + |x_2| + \cdots + |x_N|$$

- ▶ **L1** ノルム最小化によるスパース解推定
 - ▶ 代わりに次の最小化問題で探索しよう！

$$\min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$




$$\|\mathbf{x}\|_1 = |x_1| + |x_2| + \cdots + |x_N|$$

- ▶ **L1** ノルム最小化によるスパース解推定
 - ▶ 代わりに次の最小化問題で探索しよう！

$$\min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$

- ▶ 零が多ければ小さくなる + **大きさも小さくなりがち**
- ▶ 計算量は非常に軽い (**Nの3乗程度**)




$$\|\mathbf{x}\|_1 = |x_1| + |x_2| + \cdots + |x_N|$$

- ▶ L2ノルムでは??
 - ▶ 代わりに次の最小化問題で探索しよう!



$$\min_{\mathbf{x}} \|\mathbf{x}\|_2 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$

- ▶ 零が多ければ小さい+大きさがかなり小さくなりがち
+ **小さいかすが残る**
- ▶ 計算量は非常に軽い (**Nの2~3乗程度**)




$$\|\mathbf{x}\|_2 = \sqrt{x_1^2 + x_2^2 + \cdots + x_N^2}$$


- ▶ $M=100, N=1000, K=20$, ガウスランダム観測行列の場合



▶ L2ノルムを利用した場合



▶ L1ノルムを利用した場合





そもそも解はスパースなの？

- ▶ 観測したいものは本当にスパースだろうか？



Sparse Modeling

CREST

そもそも解はスパースなの？

- ▶ 観測したいものは本当にスパースだろうか？

- ▶ 実空間でのスパース性

$$\|\mathbf{x}\|_1$$

- ▶ 隣接間差分のスパース性

$$\|\mathrm{TV}(\mathbf{x})\|_1$$

original image



自然画像の例

そもそも解はスパースなの？

- ▶ 観測したいものは本当にスパースだろうか？

- ▶ 実空間でのスパース性

$$\|\mathbf{x}\|_1$$

- ▶ 隣接間差分のスパース性

$$\|\text{TV}(\mathbf{x})\|_1$$

- ▶ ウェーブレット変換によるスパース性

$$\|W(\mathbf{x})\|_1$$



自然画像の例

そもそも解はスパースなの？

- ▶ 観測したいものは本当にスパースだろうか？

- ▶ 実空間でのスパース性

$$\|\mathbf{x}\|_1$$


- ▶ 隣接間差分のスパース性

$$\|\text{TV}(\mathbf{x})\|_1$$

- ▶ ウェーブレット変換によるスパース性

$$\|W(\mathbf{x})\|_1$$

reconstructed image




自然画像の例


そもそも解はスパースなの？

▶ 実践例 (L1 ノルム利用)


original image





reconstructed image($\lambda=1$)



reconstructed image($\lambda=10$)




reconstructed image($\lambda=100$)



そもそも解はスパースなの？

▶ 実践例 (TVのL1ノルム利用)



圧縮センシング実践編

お手軽に圧縮センシング？！

- ▶ 各種ライブラリが勢揃い
 - ▶ Matlab、Python用の最適化ライブラリ
 - ▶ CVX for Matlab, CVXPY for python, Convex.jl for Julia

```
M = 20;
N = 100;
K = 5;%非ゼロ要素の数
A = randn(M,N);%Aを適当に生成
x0 = [ones(K,1); zeros(N-K,1)];
x0 = x0(randperm(N));%どこかわからないようにばらまく
y = A*x0;%出力データの生成

cvx_begin%ここからcvxのお作法
variable x(N)%解きたい変数をかく
minimize(norm(x,1))%最小化したい関数を書く
subject to
norm(A*x-y,2) <= 0.00001;%制約条件. ここでは不等式で押さえた.
cvx_end
```

- ▶ http://stanford.edu/~boyd/papers/cvx_short_course.html

何をすれば良いのか??

- ▶ 最適化問題を解けば良い！
 - ▶ 解きたい最適化問題

$$\min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$

- ▶ ラグランジュ未定乗数法により等価な最適化問題


$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 + \lambda \|\mathbf{x}\|_1 \right\}$$

- ▶ LASSO (Least Absolute Shrinkage and Selection Operators) と呼ぶ

何をすれば良いのか??

- ▶ 実は簡単に解ける
 - ▶ 最適化問題の基本は、山下り


$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 \right\}$$



何をすれば良いのか??

- ▶ 実は簡単に解ける
 - ▶ 最適化問題の基本は、山下り


$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 \right\}$$



何をすれば良いのか??

- ▶ 実は簡単に解ける
 - ▶ 最適化問題の基本は、山下り


$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 \right\}$$



何をすれば良いのか??

- ▶ 実は簡単に解ける
 - ▶ 最適化問題の基本は、山下り


$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 \right\}$$



何をすれば良いのか??

- ▶ 実は簡単に解ける
 - ▶ 最適化問題の基本は、山下り


$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 \right\}$$



何をすれば良いのか??

- ▶ 実は簡単に解ける
 - ▶ 最適化問題の基本は、山下り


$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 \right\}$$



何をすれば良いのか??

- ▶ 実は簡単に解ける
 - ▶ 最適化問題の基本は、山下り


$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 \right\}$$



暫定解をビビらせる

- ▶ 軟判定しきい値関数の導入

$$S_{\lambda}(x) = \begin{cases} x - \lambda & (\lambda < x) \\ 0 & (-\lambda < x < \lambda) \\ x + \lambda & (x < -\lambda) \end{cases}$$



暫定解をビビらせる

▶ 従来の最適化手法 + 軟判定しきい値関数 = **スパース解**

- ▶ 1. 初期条件を適当に決める
- ▶ 2. 勾配法（山下り）で

L1 ノルム以外の最適化問題の解へとりあえず向かう（**従来法**）

$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 \right\}$$

- ▶ 3. 軟判定しきい値関数で暫定解をビビらせて、**スパース化**

$$S_{\lambda}(x) = \begin{cases} x - \lambda & (\lambda < x) \\ 0 & (-\lambda < x < \lambda) \\ x + \lambda & (x < -\lambda) \end{cases}$$

- ▶ 4. 以降、収束するまで繰り返す

更なる戦略
低ランク性

データは行列（EXCEL）的に表現される

列

2	4	2	1	0	2	4
4	5	1	4	1	2	3
	...					

行

A

単純な行列もある

1	1	1	1	1	1	1
2	2	2	2	2	2	2
3	3	3	3	3	3	3
	...					

1	2	1	2	1	2	1
2	4	2	4	2	4	4
3	6	3	6	3	6	3
	...					

なぜ単純に見えるか？

なぜ単純に見えるか？
低ランク性

1	1	1	1	1	1	1
2	2	2	2	2	2	2
3	3	3	3	3	3	3
	...					

||

1
2
3
4
5
...

×

1	1	1	1	1	1	1
---	---	---	---	---	---	---

1	2	1	2	1	2	1
2	4	2	4	2	4	2
3	6	3	6	3	6	3
	...					

II

1
2
3
4
5
...

×

1	2	1	2	1	2	1
---	---	---	---	---	---	---

行列はいくつかのベクトルの積と
その組み合わせから決まる

列

2
4

4
5
...

2
1

1
4


0
1

2
2

4
3

行

A



被験者ラベル


2	4	2	1	0	2	4
4	5	1	4	1	2	3
	...					

問題ラベル


A

被験者ラベル

問題ラベル



行列型の回答データから
被験者の回答パターンが抽出可能ではないか？




完全な行列型の回答データから
被験者の回答パターンは抽出可能
特異値分解

不完全な行列型の回答データから
被験者の回答パターンは抽出可能か？

不完全な行列型のデータから
特徴的なパターンは抽出可能か？
特異値分解＋スパース性

Figure 2





まとめ

- ▶ スパースモデリングと深層学習というふたつの現代の魔法
 - ▶ 深層学習
 - ▶ 何かが何でも自動的に、回帰、（その結果を用いた）予測、識別を行う
 - ▶ ライブラリが整い、誰でもできる
 - ▶ スパースモデリング
 - ▶ 何が重要なのか、データの分析をする処方箋
 - ▶ 重要ではない要素は何か、重要な要素は何か＝人間の直感との比較が可能
- ▶ スパース性がもたらす計測革命・圧縮センシングetc
 - ▶ 足りない情報からの復元が可能
 - ▶ 従来の最適化手法＋軟判定式値関数で実装可能
 - ▶ 低ランク性を用いた欠損データ推定も可能