

数理情報学演習第二A
関係データの機械学習
- 行列と多次元配列の解析 -

かしま ひさし
鹿島 久嗣
情報理工学系研究科
数理情報学専攻 数理6研

kashima@mist.i.~



DEPARTMENT OF MATHEMATICAL INFORMATICS

* Some figures in the slides are taken from
T. G. Kolda and B. W. Bader. Tensor decompositions and applications. *SIAM Review*, 51(3):455–500, 2009.

機械学習による関係データの解析手法について紹介します

- 関係データとは
 - 関係データとは何か
 - 関係データにはどのようなものがあるか
 - 関係データ解析のタスク
- 関係データの表現
 - 行列と多次元配列
- 関係データの解析方法
 - 低ランク性の仮定
 - 特異値分解
 - テンソル分解
- 関係データ解析の応用

関係データ

3

THE UNIVERSITY OF TOKYO

近年、データ間の関係の解析が注目を浴びつつある

- 従来：「個々のデータを対象とした解析」



近年：「データの間関係の解析」

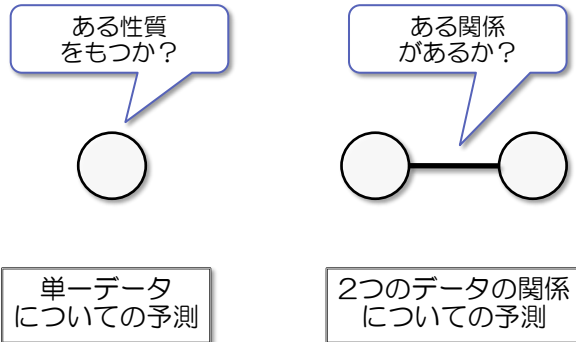
- データ間の関係に注目することで、
個々のデータに注目しているだけでは見えない性質が見えてくる
 - コンピュータネットワーク上のプロセス依存関係から異常を予測
 - 複数の脳波時系列の相関関係から思考を読みとる
- 関係の分析は様々な領域において盛んに行われつつある
 - ソーシャルネットワーク分析：人間関係
 - オンラインショッピング：顧客と商品の間の関係

4

THE UNIVERSITY OF TOKYO

関係データとは ものごとの関係を表現したデータ

- 通常のデータ解析では、ひとつのデータについて成り立つ性質を推論する
- 関係データとは：データの組についてのデータ
- 関係の成立や、関係のもつ性質についての推論を行う



5

THE UNIVERSITY OF TOKYO

関係データの例：マーケティング、Web、バイオ、...

- オンラインマーケティング
 - 顧客と商品との間の関係（購買、評価）
- ソーシャルネットワーク
 - SNS内の人間関係 (facebook, twitter, mixi, ...)
 - 企業間取引
- 生体ネットワーク
 - タンパク質相互作用ネットワーク
 - 化合物-タンパク質相互作用

6

THE UNIVERSITY OF TOKYO

関係データを用いたタスク：予測と発見

- 予測
 - 推薦システム（協調フィルタリング）
 - 顧客と商品との間の関係（購買、評価）を予測
 - 例：Netflix challenge
 - SNSの友人推薦
 - 新規薬剤候補の探索
- 発見
 - 顧客セグメンテーションの発見
 - 協調するタンパク質グループの発見
 - 例外の発見



7

THE UNIVERSITY OF TOKYO

関係データの形式的表現

8


THE UNIVERSITY OF TOKYO

関係データの表現：グラフや行列など

- 通常、データは表形式で与えられる

顧客番号	顧客氏名	年齢	性別	住所	...
0001	〇〇	40代	男性	東京都	...
0002	××	30代	女性	大阪府	...

- 関係データはこれらの間の関係を表す




- 数学的な表現
 - 行列／多次元配列
 - グラフ／ハイパーグラフ

9

THE UNIVERSITY OF TOKYO

2項関係の集合は行列として表現できる

- 2項関係は行列として表現できる
 - 行と列がデータの集合に対応
 - 各要素がデータ間の関係を表す
- グラフ（重みつき）の隣接行列としてもみることができる

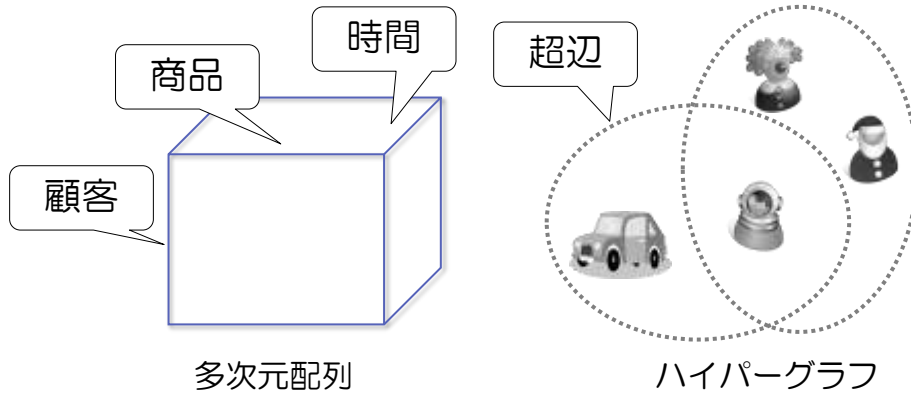


10

THE UNIVERSITY OF TOKYO

多項関係の集合は
多次元配列やハイパーグラフとして表現できる

- 多項関係の集合は多次元配列として表現できる
- ハイパーグラフとしても表現可能
 - こちらのほうがより一般的：関係に参加するデータの数が可変



11

THE UNIVERSITY OF TOKYO

行列データ（2項関係）の解析手法

12

THE UNIVERSITY OF TOKYO

行列データの解析手法

- 行列の補完問題を考える
- 協調フィルタリングの初等的手法：GroupLens
- 行列の低ランク分解
- トレースノルム

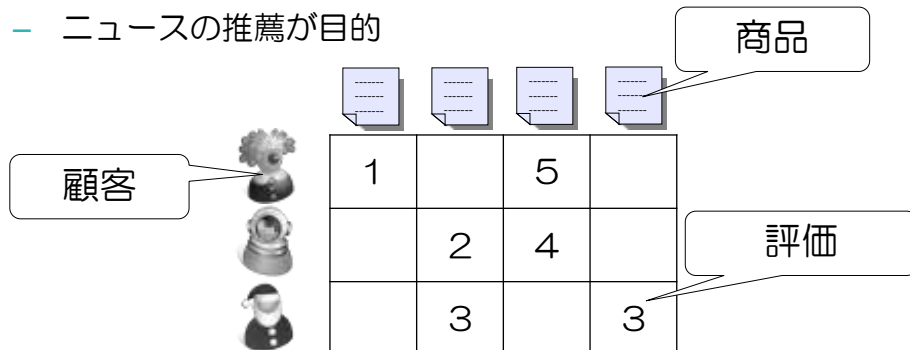
13

THE UNIVERSITY OF TOKYO

GroupLens：協調フィルタリングの初等的手法

- 推薦システム（協調フィルタリング）は、顧客と商品との間の関係（購買、評価）を予測する
- 値が分かっている部分から、わかっていない部分を予測したい
- GroupLens：初期の予測アルゴリズム

– ニュースの推薦が目的




14

THE UNIVERSITY OF TOKYO

GroupLensでは、ある顧客の評価を、似た顧客の評価を持ってきて予測する

- 予測したい顧客と似た顧客を集め、類似顧客の評価を用いて予測を行う
 - Aさんの未知要素を予測したいとする
 - Aさんと良く似た評価を行っている別の顧客を集めてきて、彼らの評価を用いて予測する



15


THE UNIVERSITY OF TOKYO

「似ている」の定義は 評価値の相関係数で測り、相関係数で重みづけして予測します

- 2人の顧客の類似度を（共に評価値が観測されている部分の）相関係数で測る
- 相関係数で重みづけし予測を行う

$$y_{i,j} = y_i + \sum_{k \neq i} \rho_{i,k} (y_{k,j} - y_k) / \sum_{k \neq i} \rho_{i,k}$$

- 同様に、商品間の類似度を用いることも可能



16

THE UNIVERSITY OF TOKYO

協調フィルタリングの初等的手法は 行列の低ランク性を暗に仮定している


- 行列の各行が、別の行の（相関係数で重み付けた）線形和によって表せるとしている
 - 線形従属
- 対象となる行列のランクがフルランクではない（⇒低い）ことを暗に仮定した方法ということになる
- 低ランク性の仮定は行列の穴埋めに有効であろう
 - データよりもパラメータが多い状況では、なんらかの事前知識を用いて解に制約を設ける必要がある
 - 低ランク性の仮定は、実質パラメータ数を減らす

17

THE UNIVERSITY OF TOKYO

低ランク性を仮定する

- 低ランク性の仮定：行列が2つの（薄い）行列の積で書ける



$$\text{minimize}_{\mathbf{Y}} \|\mathbf{X} - \mathbf{Y}\|_{\mathbb{F}}^2 \quad \text{s.t. rank}(\mathbf{Y}) \leq k$$


- 実効パラメータ数が減っている
- U (V) の各行：顧客（商品）の特徴を捉えた低次元の潜在空間にデータを配置
 - この空間で近いものが似た顧客（商品）：グループ構造

18

THE UNIVERSITY OF TOKYO

特異値分解もよく用いられる

- 行列分解 $X = UV^T$ の仮定だけでは、解の不定性があるので、制約を入れる
- 特異値分解



- 制約： $U^T U = I$ $V^T V = I$
- $X^T X$ の固有値問題になる
 - 固有値を大きい方から k 個とる

欠損値がある場合には特異値分解は使えない

- ランク制約をもった最適化問題は凸最適化問題ではない
 - ランク k 以下の行列は凸集合ではない
 - 目的関数 = 復元誤差 (凸関数) + ランク制約
- $$\text{minimize}_{\mathbf{Y}} \|\mathbf{X} - \mathbf{Y}\|_F^2 \text{ s.t. } \text{rank}(\mathbf{Y}) \leq k$$
- もしくは分解を UV^T と明示的におくと誤差項が非凸になってしまう
- $$\text{minimize}_{\mathbf{Y}} \|\mathbf{X} - UV^T\|_F^2$$
- 全データが観測されている場合には、固有値問題としてたまたま解ける
 - 欠損値がある場合には困る

欠損値がある場合には、EMアルゴリズムが用いられる

- ひとつの方法としては気にせず、勾配法などで適当に解く
 - データが大きいときにはこちら
- EMアルゴリズム：未観測部分には暫定的な推定値をあてはめ、完全観測として問題を解く
 1. 未観測部分を適当に初期化（平均など）
 2. 低ランク行列分解を適用
 3. 復元した値で未観測部分の値を置き換えるステップ 2~3を収束まで繰り返す

21

THE UNIVERSITY OF TOKYO

凸最適化としての定式化：トレースノルム正則化

- 行列のランク制約は凸集合ではないので、凸集合であり、ランク制約のよい近似となるような制約がほしい
- 行列の特異値の和を用いる

特異値

$$\|\mathbf{Y}\|_* = \sigma_1(\mathbf{Y}) + \sigma_2(\mathbf{Y}) + \dots$$

- 特異値の集合 $(\sigma_1(\mathbf{Y}), \sigma_2(\mathbf{Y}), \dots)$ に対する L_1 ノルム制約と等価であるため、疎になる \Rightarrow ランクが落ちる
- 一方、ランクは、非零の特異値の個数
- 目的関数 = 観測部分の復元誤差 + トレースノルム制約

$$\text{minimize}_{\mathbf{Y}} \|\mathbf{O}^*(\mathbf{X} - \mathbf{Y})\|_F^2 \quad \text{s.t.} \quad \|\mathbf{Y}\|_* \leq c$$

- 最適化は勾配法と特異値分解の組み合わせ

22

THE UNIVERSITY OF TOKYO

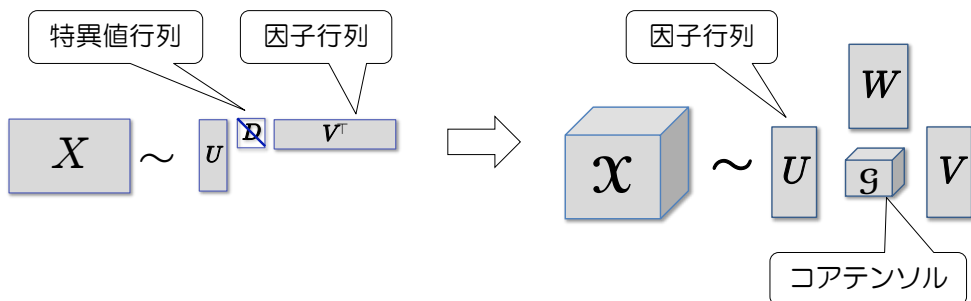
多次元配列（多項関係）の解析手法

23

THE UNIVERSITY OF TOKYO

行列分解は多次元配列（テンソル）の低ランク分解に一般化される

- 行列の低ランク分解の多次元配列への一般化
 - ちいさな（コア）テンソルと因子行列に分解する
- 近年、機械学習やデータマイニングで盛んに用いられている

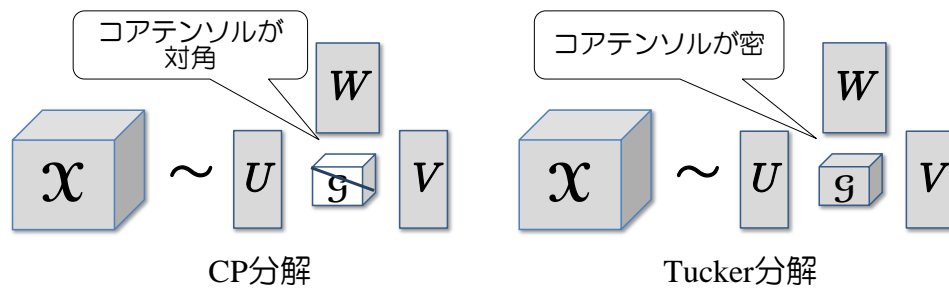


24

THE UNIVERSITY OF TOKYO

テンソル分解のタイプ：CP分解とTucker分解

- よく用いられるのがCP分解とTucker分解
- CP分解：特異値分解の自然な拡張（コアテンソルが対角；正方）
- Tucker分解：よりコンパクトな表現（みっちりコア；各モードの次数が異なる）

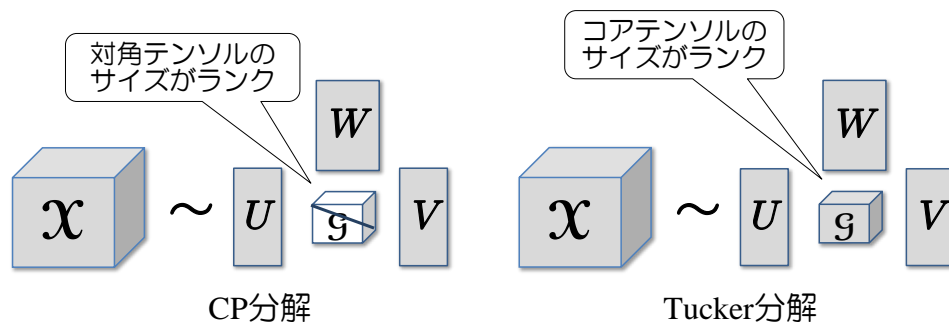


25

THE UNIVERSITY OF TOKYO

テンソルのランクは分解のタイプによって決まる

- 行列のランクはSVDの非零の特異値の数で決まった
- テンソル分解の場合には分解のタイプによって決まる
 - CP分解、Tucker分解それぞれでランクの定義がある



26

THE UNIVERSITY OF TOKYO

補足：テンソルの基本的演算

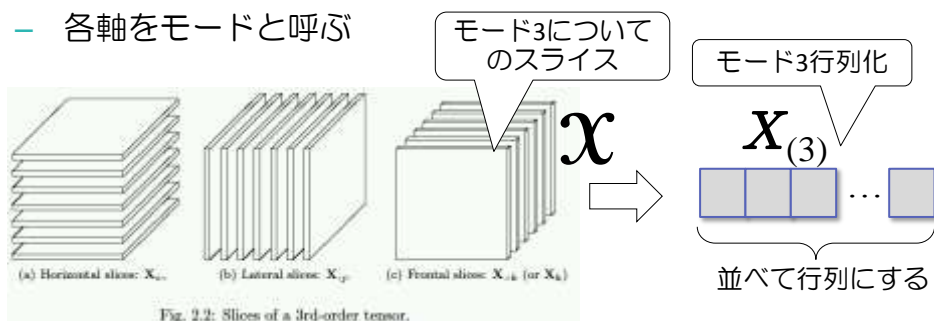
- いくつか特殊な操作が用いられる
 - 行列化：テンソルを行列に変換する操作
 - モード積：テンソルと行列の掛け算

27

THE UNIVERSITY OF TOKYO

補足：テンソルの行列化

- それぞれのモードに対してスライスが定義される
 - 各軸をモードと呼ぶ



- 行列化はそれぞれのモードについてスライスをつなげたもの
 - \mathcal{X} が3階テンソルなら、モードごとに $\mathbf{X}_{(1)}$, $\mathbf{X}_{(2)}$, $\mathbf{X}_{(3)}$ の3つの行列ができる (4階以上も同様に定義される)


* The figures are taken from T. G. Kolda and B. W. Bader. Tensor decompositions and applications. *SIAM Review*, 51(3):455–500, 2009.

28

THE UNIVERSITY OF TOKYO

補足：テンソルのモード積

- 各スライスのファイバー化
 - ベクトルの集合を取り出す



- モード積は各モードのファイバーに行列を掛けること
- $\mathcal{X} \times_3 U$ は 1-モード積の各ファイバーに行列 U を掛ける
 - $\mathcal{Y} = \mathcal{X} \times_n U \Leftrightarrow Y_{(n)} = UX_{(n)}$


* The figures are taken from T. G. Kolda and B. W. Bader. Tensor decompositions and applications. *SIAM Review*, 51(3):455–500, 2009.

29


THE UNIVERSITY OF TOKYO

CP分解はランク1テンソルの和として定義される

- 行列はランク1行列の和



- CP分解はランク1テンソルの和



外積

Fig. 3.1: CP decomposition of a three-way array.

$$\mathcal{X} \sim \sum_r \lambda_r \mathbf{a}_r \circ \mathbf{b}_r \circ \mathbf{c}_r \quad x_{ijk} = \sum_r \lambda_r a_{ri} b_{rj} c_{rk}$$

* The figures are taken from T. G. Kolda and B. W. Bader. Tensor decompositions and applications. *SIAM Review*, 51(3):455–500, 2009.


30

THE UNIVERSITY OF TOKYO

Tucker分解は小さいテンソルと行列によって定義される

- Tucker分解はコアテンソルと、因子行列によって定義される
 - モード積を使って定義される

$$\mathcal{X} \sim \mathcal{G} \times_1 U \times_2 V \times_3 W \quad (x_{ijk} = \sum_{pqr} g_{pqr} u_{ip} v_{iq} w_{ir})$$



- 多くの場合因子行列の列ベクトルが正規直交であると仮定
- CP分解はコアテンソルが対角であるようなTuckerの特殊ケース



31

THE UNIVERSITY OF TOKYO

テンソル分解の方法：繰り返し最適化による準最適化

- 基本的には与えられたテンソルを2乗誤差の意味で最適近似するような分解を求める

$$\text{minimize } \|\mathcal{X} - \mathcal{Y}\|_F^2 \quad \text{s.t. } \mathcal{Y} = \mathcal{G} \times_1 U \times_2 V \times_3 W$$

- 最適解を求めるのは難しい
 - 凸最適化ではない
 - 特異値分解などで都合よく解が求まったりしない
- 繰り返し最適化を行うのが一般的
 - 最小二乗回帰もしくは特異値分解の繰り返し

32

THE UNIVERSITY OF TOKYO

CP分解の方法：繰り返し最小二乗法（ALS）

- 解きたいのは

$$\text{minimize}_{\mathbf{y}} \|\mathbf{X} - \mathbf{y}\|_F^2 \text{ s.t. } \mathbf{y} = \mathbf{G} \times_1 \mathbf{U} \times_2 \mathbf{V} \times_3 \mathbf{W} = \mathbf{Z}_{(1)}$$
- \mathbf{U} について最適化する（ \mathbf{V}, \mathbf{W} についても同様）：

$$\mathbf{y} = \mathbf{Z} \times_1 \mathbf{U} \Leftrightarrow \mathbf{Y}_{(1)} = \mathbf{U} \mathbf{Z}_{(1)}$$
 を使って目的関数を書き換えると

$$\|\mathbf{X} - \mathbf{y}\|_F^2 = \|\mathbf{Y}_{(1)} - \mathbf{U} \mathbf{Z}_{(1)}\|_F^2$$
 これは最小二乗回帰
- \mathbf{G} は $\mathbf{U}, \mathbf{V}, \mathbf{W}$ に吸収してよい（単位テンソル）
- 繰り返し最小二乗法（ALS）と呼ばれる

33

THE UNIVERSITY OF TOKYO

Tucker分解の方法：固有値問題の繰り返し

- Tucker分解は直交条件が加わる：

$$\text{minimize } \|\mathbf{X} - \mathbf{y}\|_F^2 \text{ s.t. } \mathbf{y} = \mathbf{G} \times_1 \mathbf{U} \times_2 \mathbf{V} \times_3 \mathbf{W}$$

$$\text{s.t. } \mathbf{U}^\top \mathbf{U} = \mathbf{I}, \mathbf{V}^\top \mathbf{V} = \mathbf{I}, \mathbf{W}^\top \mathbf{W} = \mathbf{I}$$
- \mathbf{U} について最適化する（ \mathbf{V}, \mathbf{W} についても同様）：
 - $\max_{\mathbf{U}} \|\mathbf{X} - \mathbf{y}\|_F^2 = \max_{\mathbf{U}} \|\mathbf{Y}_{(1)} - \mathbf{U} \mathbf{Z}_{(1)}\|_F^2 = \max_{\mathbf{U}} \text{tr } \mathbf{Z}_{(1)} \mathbf{Y}_{(1)}^\top \mathbf{U}$
 - 2乗して $\max_{\mathbf{U}} \text{tr } \mathbf{U}^\top \mathbf{Y}_{(1)} \mathbf{Z}_{(1)}^\top \mathbf{Z}_{(1)} \mathbf{Y}_{(1)}^\top \mathbf{U}$ s.t. $\mathbf{U}^\top \mathbf{U} = \mathbf{I}$
 - これは固有値問題になる
- \mathbf{G} の最適解は $\mathbf{G} = \mathbf{X} \times_1 \mathbf{U}^\top \times_2 \mathbf{V}^\top \times_3 \mathbf{W}^\top$
- $\mathbf{U}, \mathbf{V}, \mathbf{W}$ について一回ずつ解いて、最後にを求めて終わるものが高階SVD（HOSVD）、収束するまで繰り返すものを高階直行反復（HOOI）と呼ぶ

34

THE UNIVERSITY OF TOKYO

凸最適化問題としてのテンソル分解： トレースノルムをテンソルに拡張する

- テンソル分解の最適化問題は凸では無い
- 行列の場合はトレースノルム（特異値の和）を用いることでランク制約を凸集合として入れることができた
- テリースノルムをテンソルに拡張する
 - 行列化したもののトレースノルムを入れる

$$\text{minimize } \| \mathbf{O}^*(\mathbf{X} - \mathbf{Y}) \|_{\mathbb{F}}^2 \quad \text{s.t. } \sum_n \| \mathbf{Y}_{(n)} \|_* \leq c$$

例えば： On the extension of trace norm to tensors. R.Tomioka, K.Hayashi, and H.Kashima, NIPS2010 Workshop: Tensors, kernels and machine learning, 2010.

35

THE UNIVERSITY OF TOKYO

テンソル分析の応用

36

THE UNIVERSITY OF TOKYO

ソフトウェア：Matlabでの実装が公開されている

- Matlabのツールボックスとして公開されている
 - Tensor Toolbox
 - N -way Toolbox

事例

- ソーシャルネットワーク分析
- Webリンク解析
- タグ推薦
- 脳みそ
- 画像認識

以下借り物のスライドなので省略

