

知的情報処理

1. 導入

櫻井彰人

慶應義塾大学理工学部

本講義の目的

- データに基づき未知を予測・推測する方法の基礎を知る
 - 「未来」の予測とは限らない
 - 「未知」の推測もある
- その基礎である機械学習を知る
 - 統計的手法も知る
- 道具として用いる R を知る

目次

- 第一部
 - 予測と推定
 - 機械学習とは、(アルゴリズムを用いた)穴埋めである
 - クラスタリング
 - 教師付、半教師付、教師なし
- 第二部
 - 予測
 - Random walk - ランダムな時系列
 - べき分布とBlack swan
 - 機械学習の位置づけ
- この講義について

本日の第一部

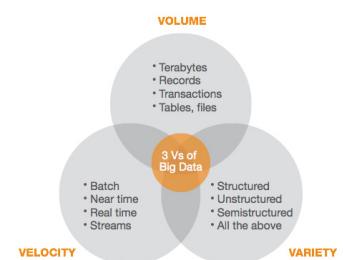
Big Data

Big Data is a **loosely defined term** used to describe data sets so **large and complex** that they become **awkward** to work with using **standard statistical software**.

Snijders, C., Matzat, U., & Reips, U.-D. (2012). 'Big Data': Big gaps of knowledge in the field of Internet. International Journal of Internet Science, 7, 1-5.

従来のデータベース管理システムなどでは記録や保管、解析が難しいような巨大なデータ群。明確な定義があるわけではなく、企業向け情報システムメーカーのマーケティング用語として多用されている。

Three V's of Big Data



Big Data Analytics Challenges Facing All Communications Service Providers
<http://blog.vitrina.com/bid/87945/Big-Data-Analytics-Challenges-Facing-All-Communications-Service-Providers>

Big Data の取り扱い

- Big のまま扱う
 - これこそ、本道。実際、技術開発が行われている。
 - これまでのデータマイニングとは別種と考えてよい
 - データマイニングも、その当時のビッグデータを取り扱うことからスタートした
 - 解析方法を0から考えることになる
- Big data からある程度情報を抽出して、それを分析する
 - Big data の基礎的取り扱い+データマイニング/機械学習
 - 多くはこちら。

補足: 公共データ

| 公共データ | サービスアイデア |
|---|--|
| 事業許認可情報 学校情報 工事情報 イベント情報 パリアフリー情報 | <ul style="list-style-type: none"> • 工事状況やパリアフリーなども考慮に入れて、目的地へ誘導するナビゲーションシステムの高度化 • 買物客や観光客を案内するシステム |
| 事業許認可情報 学校、公共施設 | <ul style="list-style-type: none"> • ビッグデータ解析による出店や商品展開における高度マーケティング |
| 事故発生情報 | <ul style="list-style-type: none"> • 事故多発の場所に近づいた際、注意を促すアプリケーション。 • 子供が近づいた際に、近親者に連絡が行く見守りアプリケーション |
| 気象情報 | <ul style="list-style-type: none"> • 農業の高度化 • 流通における仕入調整等への利用 |
| 大気汚染度情報 水汚染度情報 | <ul style="list-style-type: none"> • 高付加価値な住宅情報サービス |
| ハローワークに登録された求人情報 | <ul style="list-style-type: none"> • 求職者のニーズに合致した求人情報を探し出す、高度なジョブマッチングサービス |
| 製品安全・事故・リコール情報 地域で受けられる医療検診の情報 | <ul style="list-style-type: none"> • 事故情報のビッグデータ解析による、事故発生の傾向分析。 • 住民の健康を促進する情報サービス。ヘルスケアサービスの紹介等 |
| 国民健康・栄養調査 | |

(平成24年4月25日電子行政スクワース オンランクリオバウム会議会議室提出資料)

予測

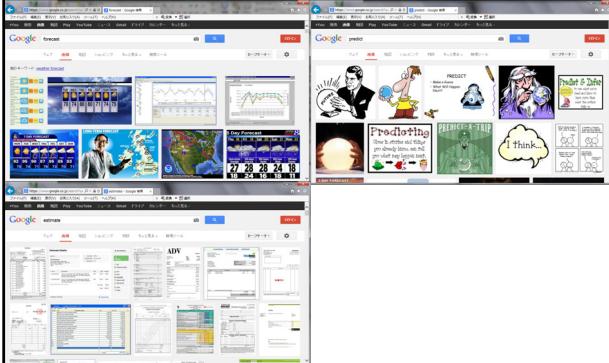
- 事の成り行きや結果を**前もって**おしはかること。また、その内容。(デジタル大辞泉)
例文: 10年後の人口を予測する
- **将来の出来事や状態を前もって**おしはかること。また、その内容。**科学的根拠**が重んじられる。(大辞林)
- **将来**どうなるかを得られた情報などに基づいておしはかること。また、そのようにして得たもの。「予想」は将来を推測する意で広く使い、「予測」は**具体的なデータ**などに基づく意で使うことが多い。(明鏡国語辞典)
- Predict: prae "before" + dicere "to say"

「予言=予め言う」にそっくり！

推定

- ①周囲の状況や情報に基づいて、おしはかって決める。②推測決定すること。また、そのようにして得たもの。③法律で、明瞭でない法律関係または事実関係について、否定する反証が成立つまで、それを正当なものとして扱うこと。(明鏡国語辞典)
- (1)はっきりとはわからないことをいろいろな根拠をもとに、あれこれ考えて決める。 (2)[法] 明瞭でない法律関係・事実関係について一応の判断を下すこと。 (3)[数] 統計で、ある母集団から取り出された標本をもとにその母集団の平均・分散などを算出すること。 (4)文法 … (大辞林)

Forecast, predict, and estimate



推測

- ある事柄をもとにして推量すること。(デジタル大辞泉)

と、まあ、言ったが

- 我々が(理工学的に)できることは、
穴埋め
です。

目次

- 第一部
 - 予測と推定
 - 機械学習とは、(アルゴリズムを用いた)穴埋めである
 - クラスタリング
 - 教師付、半教師付、教師なし
- 第二部
 - 予測
 - Random walk - ランダムな時系列
 - べき分布とBlack swan
 - 機械学習の位置づけ
- この講義について

例1

- 解けますか？
 - コンピュータに解かせるには何が必要ですか？
- 一期〇会
三〇一体
無〇乾燥
〇面楚歌
八面〇臂
無我〇中
我〇引水
支離〇裂
單〇直入
- そうです、「答え」が必要です。
なぜなら、規則性がない、から
人間だって、覚えていなければ答えられません。
ましてや、コンピュータも覚えていなければ答えられません。
しかし、覚えれば答えられる

例2

| | | | | | | |
|-----|----|----|----|---|----|----|
| 1 | 3 | 8 | 11 | 5 | 5 | 1 |
| 2 | 1 | 10 | 11 | 5 | 2 | 0 |
| 4 | 3 | 1 | 4 | 8 | 6 | 1 |
| 8 | 7 | 4 | 11 | 5 | 9 | 1 |
| ?? | 6 | 3 | ?? | 9 | 5 | ?? |
| 32 | 6 | 4 | 10 | 6 | 2 | 0 |
| 64 | 10 | 5 | 15 | 7 | 10 | 1 |
| 128 | 8 | 2 | 10 | 5 | 8 | 1 |

違いは、何でしょうか？

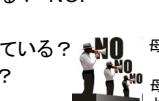
例3

星新一「ぼろ家の住人」より

- 以下、空欄に「は」か「が」を入れて、文法的に正しい日本語文にしなさい。
- それでまた金をむだ使いし、あとにはさらに大きなむなしさ（ ）残る。
 - 現実に形となって残るの（ ）、ふえてゆく借金ばかり。
 - 世の中（ ）太平ムードで好景気というのに、おれだけ（ ）例外。
 - 番組にのせる、なにかいい題材（ ）ないものかと考えながら。
 - ごみごみと、古くさない家々（ ）密集している地域だった。
 - うむ、この経過（ ）いいテーマかもしれない。
 - 都市（ ）再開発されてゆくのを、具体的にとらえるのだ。
 - 「それ（ ）ありがたい。あわれてあればあるほど、びったりです。で、それどこにですか。」
 - このへんの建物（ ）どれもぼろだが、そのなかでも最もぼろで最も小さく、建物というより小屋に近い。
 - ひとりの老人（ ）いた。
 - 同情（ ）視聴者のすることであり、テレビ関係者（ ）まず番組のことを考える。
 - 「生活保護（ ）受けていますか」
 - 「そんなもの（ ）知らん。」
 - 会話をしているうちに、この老人だけで番組（ ）一つできると思った。

例3 補足

- 日本語を母語とする人なら、まず、正解する。
 - どうしてだろうか？
- 記憶している？ NO! 次のスライドのような説明ができますか？
- 規則を知っている？ NO! 母語は、生まれ育った環境に依存する
- 生まれつき知っている？ NO! 母語教育はあるが、大抵は、かなりできるようになってから行われる
- では、教わった？
- つまり、
 - 生後、自力で学習した
 - 丸暗記ではない
 - 学習結果(規則)を口頭で表現することはできない。



<http://techieminx.com/listen-no-one-can-tell-you-who-is-looking-at-your-twitter-profile.html>

説明できますか？

例3の説明

文1. それでまた金をむだ使いし、あとにはさらに大きなむなしさ（ ）残る。

この文は出来事を表す「現象文」である。「残る」は自動詞である。
「現象文」の中では、主語に「が」をつけるのが普通である。
そして、「あとには」の中に取立ての「は」が入っているので、主語に対して
もう一つの取立ての「は」が入りにくい。
これにより、この文には「が」しか使えない。

文2. 現実に形となって残るの（ ）、ふえてゆく借金ばかり。

この文は名詞述語の「判断文」である。
文末に「である」が省略されているが、「判断文」という性質に変わりはない。
「判断文」の主語に「は」をつけるのが普通である。

説明できなくても正解できますよね？

ある日本語研究・教育用テキストから

例3. 本題に戻ろう



- コンピュータでできるか？
- もし、人間が行うように、生後聞いた母語をすべて与えたらできるかもしれない。
 - なぜなら人間は皆そうして学習しているから
- (脱線)「生まれる前から知識を持っている」と主張する人と「まったくの白紙から学習する」と主張する人がいる
- つまり、



つまり

- 人間であれば、
データ + 学習(の結果) ⇒ 穴埋め
- コンピュータであれば、
データ + アルゴリズム ⇒ 穴埋め

ということを期待してよいだろうか？



http://hararie-japan-tokyo-tokyo.com/japanese_alphabet/japanese-study/various-expressions-of-yes/

つまり

人間の学習

- 人間であれば、
データ + 学習(の結果) ⇒ 穴埋め
 - コンピュータであれば、
データ + アルゴリズム ⇒ 穴埋め
- コンピュータの学習
すなわち
機械学習

整理しよう

穴埋め1 穴埋め2-1 穴埋め2-2 穴埋め2-3 穴埋め3

| | | | | |
|------|-----|---------|--------|----------------|
| 一期〇会 | 1 | 6 9 15 | 8 8 1 | 1. それでまた金をむだ使 |
| 三〇一体 | 2 | 5 1 6 | 6 7 1 | 2. 現実に形となって残る |
| 無〇乾燥 | 4 | 5 2 7 | 4 7 1 | 3. 世間の言葉 |
| 〇面楚歌 | 8 | 4 10 14 | 1 3 0 | 4. 誰かにのせる。古くから |
| 八面〇脅 | ?? | 6 10 ?? | 8 6 ?? | 5. うむ、この経過（ ） |
| 無我〇中 | 32 | 7 6 13 | 10 1 1 | 6. 都市（ ）再開発され |
| 我〇引水 | 64 | 10 7 17 | 3 7 1 | 7. 「それ（ ）ありがた |
| 支離〇製 | 128 | 10 9 19 | 6 6 1 | 8. このへの建物（ ） |
| 単〇直入 | | | | 9. ひとりの老人（ ） |
| | | | | 10. おじいちゃん |
| | | | | 11. おじさん |
| | | | | 12. 「生活保護（ ）」受 |
| | | | | 13. 「そんなもの（ ）」 |
| | | | | 14. 会話をしているうち |

同一 一次元系列 連続関数 不連続関数 文字列

整理しよう

| | | | |
|------|--------|--------|--------|
| 穴埋め1 | 穴埋め2-1 | 穴埋め2-2 | 穴埋め2-3 |
|------|--------|--------|--------|

| | | | |
|--|---|--|--|
| 一期一會 三位一体 無歌乾燥 四面楚歌 八面六臂 無我夢中 狹目引水 支那威震 解力道人 | 1 2 4 8 ?? 32 64 128 | 6 9 15 5 1 6 5 2 7 4 10 14 6 10 ?? 7 6 13 10 7 17 10 9 19 | 8 8 1 6 7 1 4 7 1 1 3 0 8 6 ?? 10 1 1 3 7 1 6 6 1 |
|--|---|--|--|

| | | | | | |
|------------------------------|----|-------|------|-------|-----|
| 一期〇会 三〇一体 無〇乾燥 〇面楚歌 | 同一 | 一次元系列 | 連続関数 | 不連続関数 | 文字列 |
|------------------------------|----|-------|------|-------|-----|

目次

- 第一部
 - 予測と推定
 - 機械学習とは、(アルゴリズムを用いた)穴埋めである
 - クラスタリング
 - 教師付、半教師付、教師なし
- 第二部
 - 予測
 - Random walk - ランダムな時系列
 - べき分布とBlack swan
 - 機械学習の位置づけ
- この講義について

穴埋めではないが、類似

0.23 -0.05
-0.8 -0.06
0.54 0.2
-0.15 0.57
-0.12 0.21
-0.21 0.81

1.54 0.85 1
0.92 0.92 1
1.11 0.26 2
1.11 0.87 2
0.7 1.85 2
0.95 -1.1 2

0.23 -0.05 1
-0.8 -0.06 1
0.54 0.2 1
-0.15 0.57 1
-0.12 0.21 1
-0.21 0.81 1

1.54 0.85 2
0.92 0.92 2
1.11 0.26 2
1.11 0.87 2
0.7 1.85 2
0.95 -1.1 2

0.23 -0.05 1
-0.8 -0.06 1
0.54 0.2 1
-0.15 0.57 1
-0.12 0.21 1
-0.21 0.81 1

1.54 0.85 2
0.92 0.92 2
1.11 0.26 2
1.11 0.87 2
0.7 1.85 2
0.95 -1.1 2

クラスタリングという

クラスタリングとは
「いくつか」の「かたまり」に分けること

課題
「かたまり」?
「いくつ」?

応用はあるの?
はい！

こんな風に考えては、悪いのか？

目次

- 第一部
 - 予測と推定
 - 機械学習とは、(アルゴリズムを用いた)穴埋めである
 - クラスタリング
 - 教師付、半教師付、教師なし
- 第二部
 - 予測
 - Random walk - ランダムな時系列
 - べき分布とBlack swan
 - 機械学習の位置づけ
- この講義について

教師

整理しよう

「教師付き」

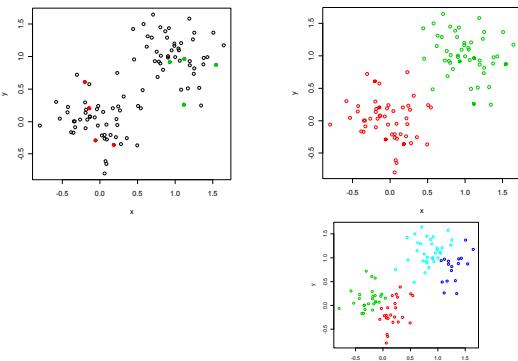
穴埋めではないが、類似

「教師なし」

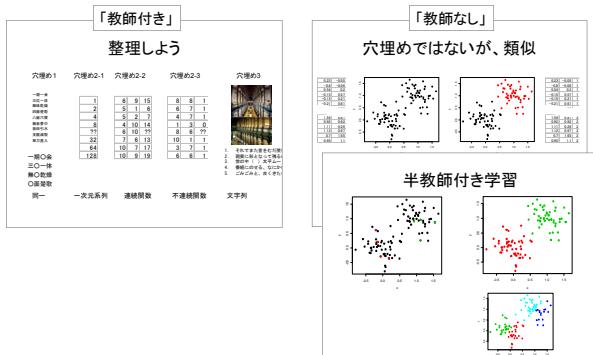
教師なしデータの有用性

- 教師データ作成コストは高い
- 例えば次のアプリを考えよう(実問題)
 - バイオ系の論文で、化合物・タンパク質間の相互作用について記述した論文を選び出した。
 - この「相互作用」の表現をリストアップすることができない(googleの検索(つまり全文検索)では見つけられない)。
 - 専門家が論文を読んで、その表現を探し出す必要がある。
- ならば、その少數例(教師データ)と、多数の文から、仮の(間違っているかもしれない)教師データを作れないか?
 - 実は、この問題は、この方法では難しい。しかし、雰囲気は分ろう

半教師付き学習



もう一度、整理

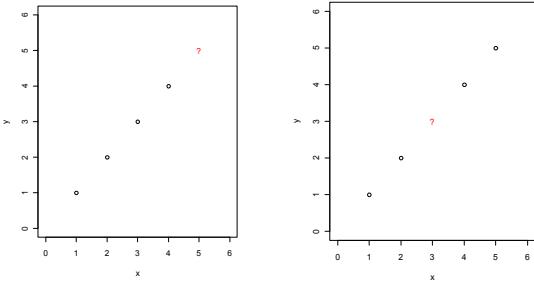


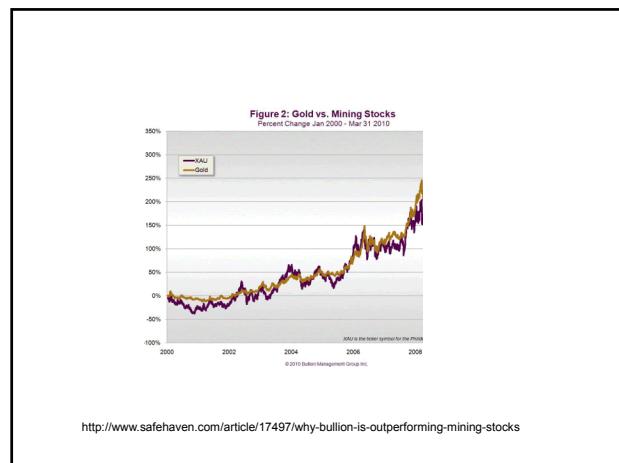
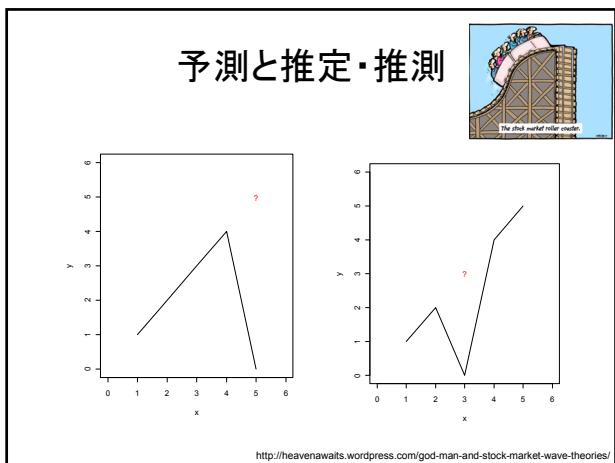
目次

- 第一部**
 - 予測と推定
 - 機械学習とは、(アルゴリズムを用いた)穴埋めである
 - クラスタリング
 - 教師付、半教師付、教師なし
- 第二部**
 - 予測**
 - Random walk - ランダムな時系列
 - べき分布とBlack swan
 - 機械学習の位置づけ
 - この講義について

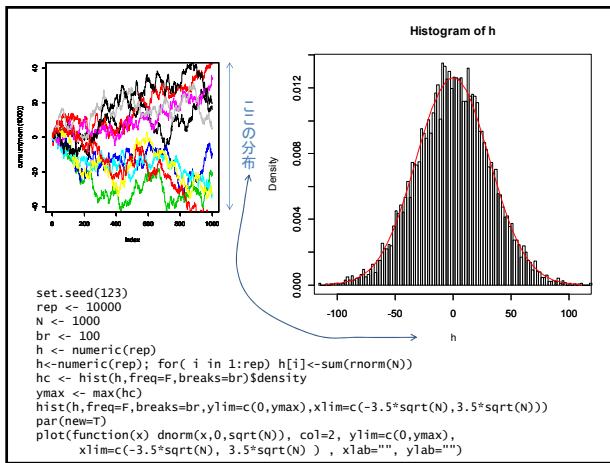
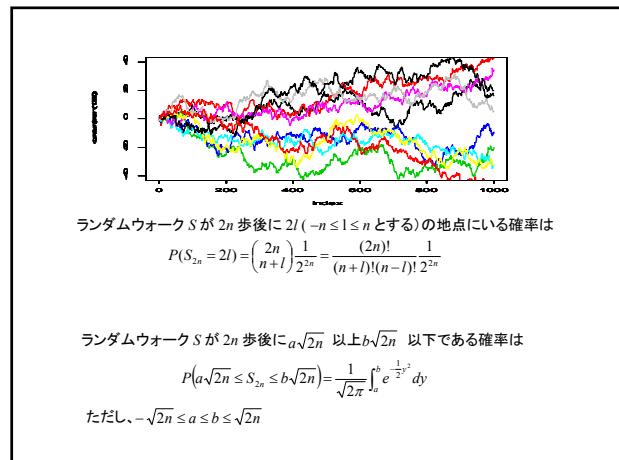
本日の第二部

予測と推測・推定





- ## 目次
- 第一部
 - 予測と推定
 - 機械学習とは、(アルゴリズムを用いた)穴埋めである
 - クラスタリング
 - 教師付、半教師付、教師なし
 - 第二部
 - 予測
 - Random walk - ランダムな時系列
 - べき分布とBlack swan
 - 機械学習の位置づけ
 - この講義について



逆正弦定理

定理(逆正弦法則) ランダムウォーク S が $2n$ までの間に正の側で $2k$, 負の側で $2n-2k$ 過ごす確率 $P(n, k)$ は

$$P(n, k) = u_k u_{n-k}$$

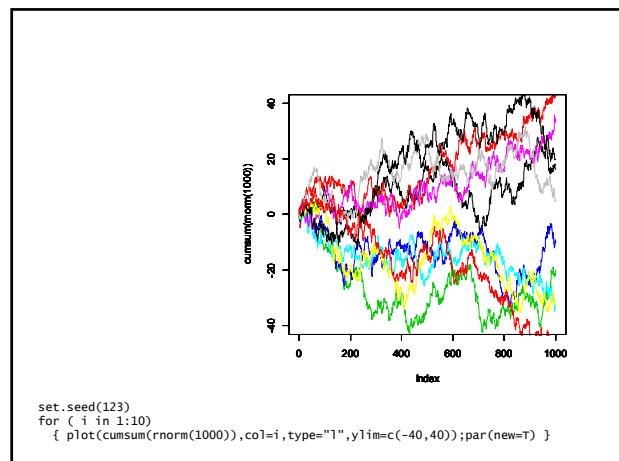
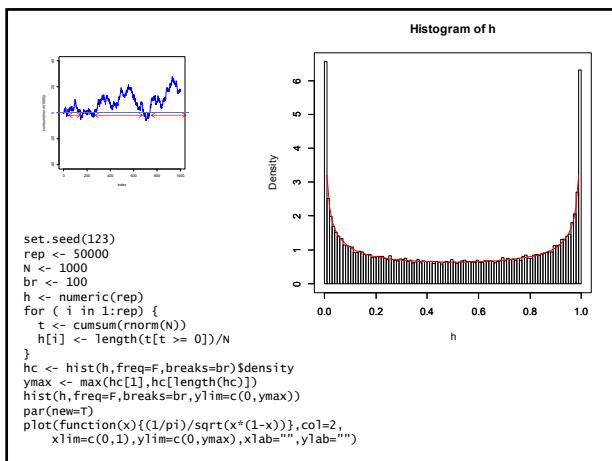
である

定義 $u_0 = 1, u_n = \binom{2n}{n} \frac{1}{2^{2n}} = \frac{(2n)!}{n!n!2^{2n}}$

$P(\text{ランダムウォーク } S \text{ が } 2n \text{ までの間に正の側にいる割合} \leq \alpha)$

$$= \sum_{k \leq \alpha n} P(n, k) \approx \sum_{0 \leq k \leq \alpha n} \frac{1}{\pi \sqrt{k(n-k)}} = \sum_{0 \leq k \leq \alpha n} \frac{1}{\pi \sqrt{k(n-k)}} = \frac{1}{\pi} \sum_{0 \leq k \leq \alpha n} \frac{n}{\sqrt{k(1-\frac{k}{n})}} \approx \frac{1}{\pi} \int_0^\alpha \frac{dx}{\sqrt{x(1-x)}} = \frac{2}{\pi} \arcsin \alpha^{\frac{1}{2}}$$

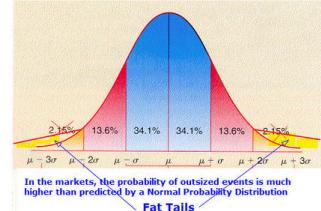
<http://elis.sigmath.es.osaka-u.ac.jp/~nagahata/20070816/arcsin.pdf>



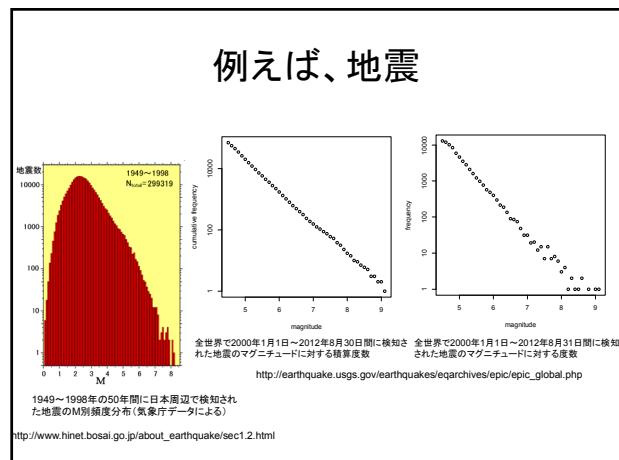
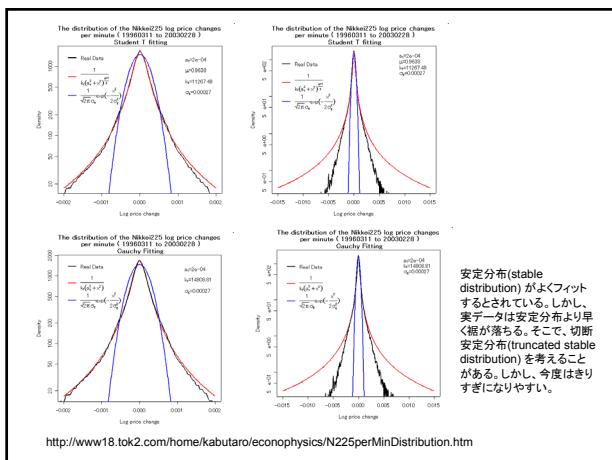
目次

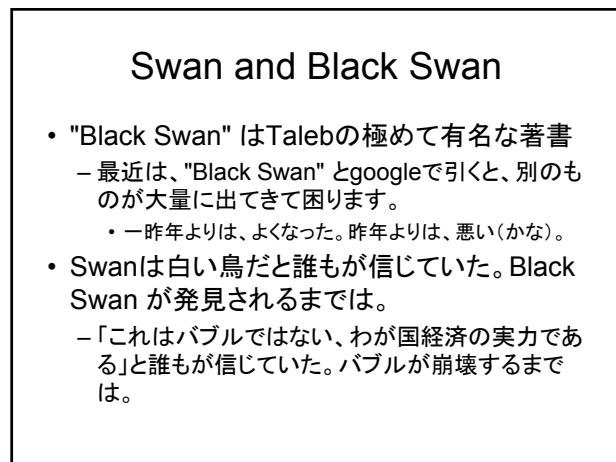
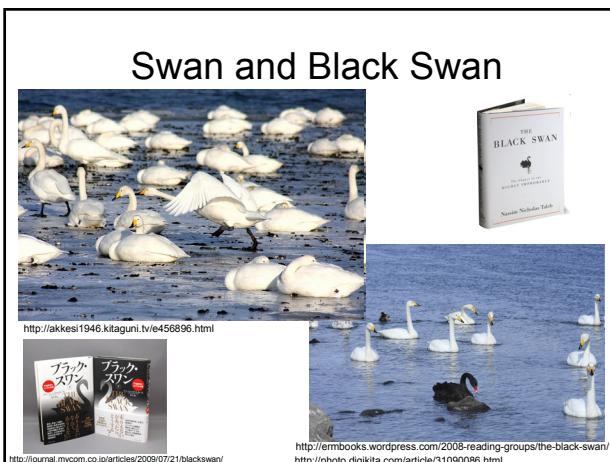
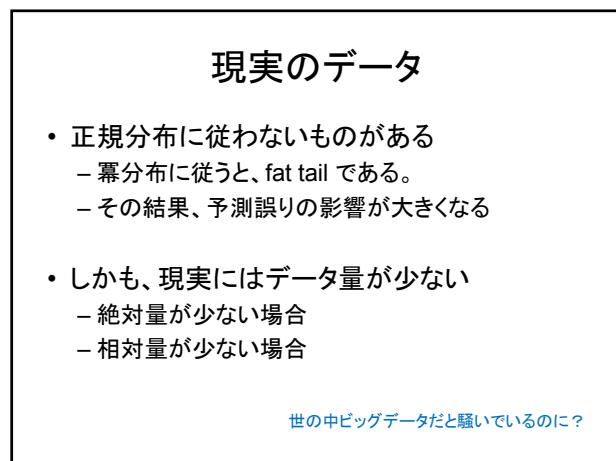
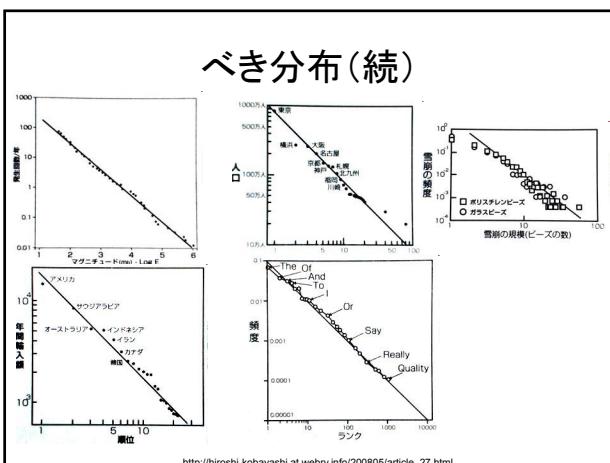
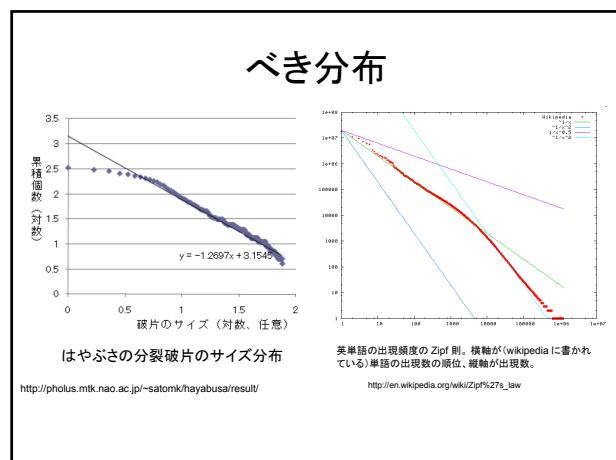
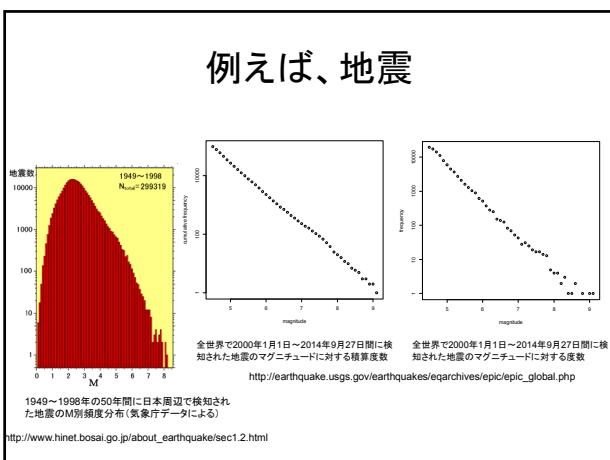
- 第一部
 - 予測と推定
 - 機械学習とは、(アルゴリズムを用いた)穴埋めである
 - クラスタリング
 - 教師付、半教師付、教師なし
- 第二部
 - 予測
 - Random walk - ランダムな時系列
 - べき分布とBlack swan
 - 機械学習の位置づけ
 - この講義について

正規分布でない世界なら



<http://stephenvita.typepad.com/alchemy/2010/08/adjustments-8312010.html>





目次

- 第一部
 - 予測と推定
 - 機械学習とは、(アルゴリズムを用いた)穴埋めである
 - クラスタリング
 - 教師付、半教師付、教師なし
- 第二部
 - 予測
 - Random walk - ランダムな時系列
 - べき分布とBlack swan
 - 機械学習の位置づけ
- この講義について

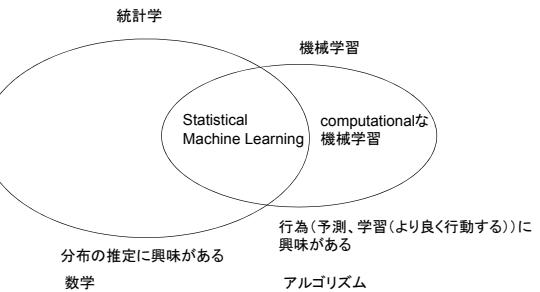
統計学との違い

- 統計では、分布の推定や(ほぼ同じことであるが)パラメータの推定を目指す。
- 機械学習では、「論理・ロジック」と組み合わせた知識表現(記号表現)も推定対象に入る。
- 統計で目的とする分布は、数式で書ける分布が多い。
 - モデルを単純にし、理論的に正確に。ノンパラメトリックという手法はある
- 機械学習では、数式で書けないような分布を対象とする
 - モデルは複雑(かどうかは分からぬが)に、予測結果は正確に。
 - 機械学習でも「分布の推定」ということを行うし、研究ではその評価式がたくさん出てくるのですが、実用上は、その推定精度は大したことはない。結果としての予測精度が重要。
 - 分布の推定精度が測れるほどのデータ量が、実は、ないのが原因。
 - モデルパラメータが多すぎるのが原因。
- 融合が進んでいますが、相変わらず、違いがある

PAC学習可能

- Probably Approximately Correct 学習可能
 - 大抵の場合、近似的に、正しく学習できる
- 大抵の場合:
(e.g.) 100回学習すると、そのうちの95回
- 近似的に正しい:
(e.g.) 真の解との誤差は 5% 以内で

統計学と機械学習



目次

- 第一部
 - 予測と推定
 - 機械学習とは、(アルゴリズムを用いた)穴埋めである
 - クラスタリング
 - 教師付、半教師付、教師なし
- 第二部
 - 予測
 - Random walk - ランダムな時系列
 - べき分布とBlack swan
 - 機械学習の位置づけ
- この講義について

この講義の目的

- 知的な情報処理を実現する技術の一つである「機械学習・データマイニング」技術の基礎を知る
- Rという統計パッケージに慣れておこう
 - きっと卒論で役に立つよ

講義の進め方

- 講義中心、しかし、手を動かす。
- R を使用します(ほどほどに)

Rとは

- (元は)統計計算とその結果表示のための言語・環境
 - いろいろな統計手法が、パッケージ(オープンソース)とされ、簡単に組み込める
- ところが、今では、様々な機械学習手法も入っている。
 - そのため、機械学習の手法の学習には使えない。
 - しかし、使い方の学習にはもってこい！
- フリーソフト

評価他

- レポート(3回ほど)と試験(またはレポート(4回ほど))に基づく
 - 講義の進行状況に依存して決める。
 - レポート採点は、考察重視
 - 出席はとらない予定
 - ただし、たいていは、簡単な即レポで代替するので、ご注意ください
- 講義資料は、櫻井研究室 website に掲載予定
(google で 櫻井研究室 で検索すればよい)
<http://www.sakurai.comp.ae.keio.ac.jp/>

予定

| | | | |
|----|--------|---|------------------------|
| 1 | 9月30日 | 火 | 予測と推測と機械学習 |
| 2 | 10月7日 | 火 | R超入門 |
| 3 | 10月14日 | 火 | 最近傍法 - 近さの利用 |
| 4 | 10月21日 | 火 | ナイーブベイズ法 |
| 5 | 10月28日 | 火 | ナイーブベイズと自然言語処理 |
| 6 | 11月4日 | 火 | 決定木 - 生成と剪定 |
| 7 | 11月11日 | 火 | オッカムの剃刀と過学習 |
| 8 | 12月2日 | 火 | 演習 |
| 9 | 12月9日 | 火 | ニューラルネットワーク - 夢と限界と広がり |
| 10 | 12月16日 | 火 | 実用的なニューラルネットワーク |
| 11 | 12月26日 | 金 | SVM - 強力な分類法 |
| 12 | 1月6日 | 火 | クラスタリング |
| 13 | 1月13日 | 火 | モデル選択・Deep Learning |
| 14 | 1月20日 | 火 | 最終課題 |