

情報意味論(1)

慶應義塾大学工学部
櫻井 彰人

この講義では

- 機械学習のいくつかの代表的な手法を知る
 - 基本原理
 - 基本アルゴリズム
 - 実際に使ってみよう
 - 少しアルゴリズムに触ってみる

アルゴリズムの分類 学習の形式

- 教師付学習
- 教師なし学習
- 半教師付学習
- 強化学習

アルゴリズムの分類 似たもの

- 回帰
- 事例ベース
- 正則化
- 決定木
- 統計的分類
- カーネル法
- クラスタリング
- 相関規則
- ニューラルネットワーク
- ディープラーニング
- 次元圧縮
- アンサンブル法

回帰 regression


- Regression: 回帰と訳すが
 - 後戻り, 復帰, 後退, 退歩, 退化, 退行
 - もともとは、今の意味とは異なる、「平均への回帰」の意味で使われた
- 説明変数のある関数で、被説明変数の値を近似する。次のものに依存する
 - 関数の形
 - 誤差の形
- 学習: 訓練データで、回帰関数を作る
- 推測: 未知データを回帰関数に入れ、出力値を予測値とする

事例ベース instance-based

- 丸暗記+類推
- 学習: 事例をすべて記憶する
- 推測: 新規データに最も近い事例を取り出す
 - 「近い、遠い」の決め方にいろいろ
 - 「近い、遠い」を学習する手法もある

決定木 decision tree

- 「木」を使って、学習結果を表現する
- 分類が主であるが、回帰もできる
- 学習：ヒューリスティックな構築方法
 - 各ノードには属性1個に関する値のテスト
- 推測：未知データに決定木を適用する




統計的分類

- 尤度最大化や事後確率最大化を図る。
 - その際、ベイズの定理を利用
- 学習：説明変数を確率変数と考え、その分布のモデルを作成する
 - モデルは、単純化する。
 - Naïve Bayes
 - 判別分析
- 推測：非説明変数の値の分布を求める。


クラスタリング clustering

- 非説明変数に対する教師データはない。
 - 非説明変数はない、と言ってもよい
- 説明変数値の分布を用いて、各データをいくつかのグループ・塊り(クラスタ)に分ける
- 統計的には、隠れ変数のある統計モデルの推定問題として扱われる



相関規則 association rule

- 買い物籠1個がデータ1個
- 相関規則: If AとBを買う then Cも買う
- 発掘: 大量の買い物籠データから、信頼性と精度が高い相関規則を抽出




カーネル法

- 特徴量を、ある非線形関数を用いて高次元空間に写像し、そこで、線形関数を用いた分類や回帰を行う
 - 元になる手法(線形関数を用いる手法)が、カーネルトリックが有効となるような手法であるべき
 - 例: SVM
- 学習: 学習データでパラメータを推定。
 - カーネル関数は事前知識に基づいて選ぶ。ただし、情報量基準やCVを用いて選択するも可
- 推測: 未知データを入力
 - カーネルトリックを用いる故、計算量は(次元を高くしても)多くならない


ニューラルネットワーク

- 単純な機能を持った素子(神経素子の単純なモデル)を多数結合したもの
- 学習: コスト(誤差等)が最小となるよう素子間の結合荷重を調節する
- 推測: 説明変数値を入力し、出力値を推定値とする



ディープラーニング

- 中間層数が多い(2以上)のニューラルネットワーク
- 基本的にはニューラルネットワーク
- 学習アルゴリズムに本質的な工夫がある



正則化 regularization

- 過学習を抑えるため、最小化すべきコストに、モデルが複雑になるほど大きくなるペナルティ項を加える
- コスト関数 = 本来のコスト + λ ペナルティ項
- λ の決め方に恣意性が残る

$$\min_f \sum_{i=1}^n |Y_i - f(X_i)|^2$$




$$\min_f \sum_{i=1}^n |Y_i - f(X_i)|^2 + \lambda \|f\|^2$$

次元圧縮

- 説明変数の個数を減らす
 - 非説明変数がある場合、ない場合
 - 手法は多数あり
 - 主成分分析 (PCA)
 - 因子分析
 - 多次元尺度法 (MDS)
 - 潜在意味分析 (LSA, LSI)
 - 確率的潜在意味分析 (pLSA, pLSI)
 - Latent Dirichlet Allocation
 - 非負行列分解 (non-negative matrix factorization)
 - LASSO (least absolute shrinkage and selection operator)

アンサンブル法

- 複数の(多数の)学習器を組み合わせる
- 多数
 - ブースティング
 - バッグイング
 - AdaBoost
 - Random Forest



The top 10 algorithms in DM

- the IEEE International Conference on Data Mining (ICDM) in December 2006 で決めたもの
 - C4.5
 - k-means
 - SVM
 - A priori
 - EM
 - PageRank
 - AdaBoost
 - k-Nearest Neighbor
 - Naïve Bayes
 - CART

講義形態

- 普通の講義形態
- できるだけ、動作例を見てもらう
- シラバスから順序等多少変更あるかも
- 確率・統計の基礎はできるだけ省略
- Weka と R は道具として使うが概説のみ

評価方法

- 3回～4回のレポートに基づく

2014年度予定

1	9月22日	月	情報と意味と機械学習
2	9月29日	月	RとWeka
3	10月6日	月	決定木と過学習
4	10月20日	月	コネクショニズム
5	10月27日	月	多層神経回路網
6	11月3日	月	ベイズ学習
7	11月10日	月	モデル選択
8	11月17日	月	EMアルゴリズム
9	12月1日	月	ベイジアンネットワーク
10	12月8日	月	SVM
11	12月15日	月	Boosting
12	12月22日	月	事例ベース学習/相関規則
13	1月14日	水	Deep Learning
14	1月19日	月	強化学習

機械学習

- データから意味を抽出する作業を、従来から、機械学習とよんできた
- 機械学習 (machine learning) :
 - データ間の規則性(意味)の抽出(学習)を計算機に行なわせる
 - これは「学習」か? yes!
 - 知識獲得ともいう
 - 規則性が知識だった?
 - 適応 (adaptation) でもある。
- データを集めて情報となすことにはかわりない

学習



- 少しずつ異なった意味で用いられるが
 - 外界と自分があるときに、自分を少しずつ変化させて、外界に適応する(よりよいメリットを得る)こと
 - すなわち、対象とする系の表現・表出に基づき、最適行動を計画・実行する
 - そのために、ある系の振舞い(データ)をもとに、その系を表現する(本質をとらえた一般記述)ことが必要

学習

- もっと一般化して考えると、学習とは
- 具体例を知り、具体例を一般化すること
 - 丸暗記という学習もある。
- 具体例 (instance) を一般化する。
 - りんご1が落ちた、栗2が落ちた、、、
⇒ 物体は支えがなくなれば落ちる
 - 叩いたら痛かった: 一週間前、昨日、今日、、、
⇒ 叩くと(いつでも)痛い
 - 隣のAさんはケイタイを持っている、会社のBさんも、、、
⇒ みんなケイタイを持っている
- 特徴: 間違っているかもしれない
 - わずか(有限個の)具体例に基づくので当然。

機械学習

最近の、半構造データを対象とした研究の発展に伴い、このアイデアに近い学習モデルが復活している。

- 「機械学習」はこの「一般化」を理論化するにあたり、結果の正しさ(という評価基準は常に必要)を、
 - 具体例が無限個になれば、正解が得られる、すなわち、
 - 具体例が無限個になれば、モデルが同定できるような一般化を求めることにした。
 - 後に、この「モデル同定」でない、機械学習の特徴づけ(PAC)がなされ、機械学習のさらなる発展が起こることになる
- データ(対象とする系の動作の具体例 (instance))をもとに、その系の記述を得る、その系を同定する。
 - 2, 4, 6, 8, 10, 12, ... ⇒ 偶数
 - 1, 2, 4, 8, 16, 32, ... ⇒ 2 の冪乗

機械学習

- まずは「学習」から離れるかもしれないが、「学習」の本質は捉えている

学習：経験(具体例)をもとにパフォーマンスを上げる

(パフォーマンスを上げるには、未経験の事例に対しても、うまく動作する必要がある)

学習：経験(具体例)をもとに未知の(類似の)事態に対応すること

そのためには、相手(外界)を知ることが必要。知るとは記述できること。

本質：経験から(相手の)記述を帰納すること。未知事例に対して適用する。

機械学習

Study of algorithms that

- improve their performance P
- at some task T
- with experience E

(Tom Mitchell)

学習の実例1 実世界



ロボットにペナルティキックをさせたい。もし関与するすべての物体の力学的性質が分かり、数値が測定可能かつ天候・芝の状態、キーパーの癖等がわかれば、最適なキック方法が選択できる。しかしそのようなことはない。どうするか？

自動清掃ロボットを作りたい。顧客ごとに部屋の配置を入力させるのは(入力するのは)大変だ。ロボット自身に「学習」させたい。どうしたらよいか？




ルンバは学習しない。Brooksの基本的考え

学習の実例2 パターン認識

郵便番号(宛先)自動読み取り装置:
郵便番号・住所として書かれた文字のデータが10000組ある。これをもとに、宛先を読みとり分配するシステムを作るにはどうしたらよいか？

血液像自動分類装置: (診断に必要な)白血球・赤血球の画像とその分類例が10000枚ある。これをもとに、血球を自動分類しその個数を数える装置を作るにはどうしたらよいか。



学習の実例3 膨大なデータ

世界中にあるWWWページを自動的に収集・分類し、ユーザが指定した観点から自動的に類似性を判定し、関連性・塊を表示するシステムを作りたい。どうしたらよいか？

3TBあるアクセスログから、注文につながる、また離脱するユーザの行動に基づいて、うまくリコメンドし、注文につなげたい。

50TBある(実世界での)行動記録に基づき、ユーザ群の行動を予測し、店舗の立地を評価する。

学習の実例4 IBM's Watson

- 米国のクイズ番組Jeopardy!(ジョバディ!)に挑戦し、2ゲームを通じて、最高金額を獲得した(2011年2月16日(米国時間))。
- 知識は学習手法を用いて蓄積
 - 100万冊の本を読むのに相当する自然言語で書かれた情報
- ラック10本分、総メモリー容量15TB、総プロセッサ・コア数は2,880個
- ビジネス応用を推進中



ところで、何故情報意味論？

- もともと、データと情報と意味を議論する講義であった (にしたかった)
 - データから意味・情報をとります
 - 考え方と方法
 - 取り出し方
 - 学習理論とアルゴリズム
 - 2つの方法: 記号的な方法、統計的な方法
 - 応用
 - 様々な adaptation
 - データマイニング
- その中でも「学習」に重点を置くことにした


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.vttria.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るとよい
 - 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 の基礎的取扱い+データマイニング/機械学習
 - 多くはこちら。

Parallelization: platform choices

Platform	Communication Scheme	Data size
Peer-to-Peer	TCP/IP	Petabytes
Virtual Clusters	MapReduce / MPI	Terabytes
HPC Clusters	MPI / MapReduce	Terabytes
Multicore	Multithreading	Gigabytes
GPU	CUDA	Gigabytes
FPGA	HDL	Gigabytes

Big Data Research Progress. Chao. Jan 22, 2013.

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 バリアフリー情報	<ul style="list-style-type: none"> ● 工事状況やバ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	<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。
地域で受けられる医療検診の情報 国民健康・栄養調査	<ul style="list-style-type: none"> ● 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

(平成24年4月25日電子行政タスクフォース コンテンツ流通推進協議会事務局提出資料)

情報とは何か？

- 英語では information
 - Inform がもとの動詞。どう使う？
- 日本語: いろいろ訳したか？
 - 情とは
 - 報とは

(小野厚夫, "情報という言葉を探る" (1)~(3), 情報処理(2005)を参照)
(インフォーマルメーションで調べてみよう)

意味とは何か

- ①記号・表現によって表される内容またはメッセージ。②物事が他との連関において持つ価値や重要性。(広辞苑)
- 動作で考えてみよう。例えば、「意味がある」行動とは？
- 次に、表現と意味との関係を考えてみよう。
 - 現実世界における「表現」は常に、冗長である。では、徹底して冗長性を排除したらどうなるか？
 - なぜ、冗長なのかも考えてみよう

情報理論における情報

- データを生み出す「データ源」の記述
 - 例1: 0は確率1/4で, 1は確率3/4でランダムに生成する
 - 例2: n番目には, n番目の素数の10進第一位を生成する

データ源の記述ができると

- データ源の記述ができると何がよいか？
 - 予測ができる
 - もしそれがノイズ源であれば、ノイズを効果的に低減することができる
 - (もっと一般的には)制御することができる

例えば、

- 一つの音源の音を正確に採取するために、複数のマイクを使う。
 - 2つのデータ中の相関の大きな成分が当該音源の音である(ノイズには相関がない)
- 経済予測: 株価予測、売上予測
 - 潜在需要の発見とその利用(刺激して新市場創造)
- 物理現象・化学現象・社会現象の記述と予測

つまり、機械学習

- 要は、
 - 目的、方法、評価方法は様々であれ、
 - データから意味(これって、目的によって変わります)をとりだすこと
- が機械学習

データマイニングとは？

- データマイニング(データベースからの知識発見):
 - 興味深い(当たり前でない、潜在的、これまで知られていなかった、しかも、役に立つと思われる)情報あるいはパターンを大規模データベースから抽出すること
- データマイニングの別名
 - データマイニング: 命名を間違えた?
 - データベースからの知識発見(Knowledge discovery in databases, KDD)、知識抽出、データ/パターン解析、データ考古学、情報収穫、ビジネスインテリジェンス、など
- データマイニングでないのは何か?
 - (演繹)質問応答処理
 - エキスパートシステムあるいは小規模な機械学習システム/統計パッケージ

データマイニングの応用例

- データベース解析と意思決定支援システム
 - マーケット分析とマネジメント
 - ターゲット・マーケティング、CRM(customer relation management)、購入品目分析 (market basket analysis)、マーケット区分 (market segmentation)
 - 危機分析とマネジメント
 - 予測、顧客維持、保険の査定上の改善、品質管理、競争力分析
 - 不正検知と管理: アクセスログ解析
- 他の応用
 - テキストマイニング(電子メール、webドキュメント、ブログ)
 - Web アクセスログ解析
 - 遺伝子解析(文献解析含む)

これはデータマイニング？


- 経済学? yes.
 - 経済的インセンティブを取り扱っている
- データマイニング? yes
 - 多量データの分析結果に基づく




蛇足: なぜ機械学習か？

- 様々な意味で「計算能力が向上」
 - データベースマイニング: データを知識に
 - 自動カスタマイズプログラム: ニュースのフィルタ、適応的な監視カメラ
 - 行動の学習: ロボットの計画、制御の最適化、決定支援
 - プログラム困難なアプリケーション: 自動運転、音声認識
- 人間の学習や教育のよりよい理解を求めて
 - 認知科学: 知識獲得の理論 (e.g., 実践を通じて)
 - パフォーマンス向上: 推論・推測、推薦システム
- 時は今、、、
 - 学習アルゴリズムや理論の最近の進歩は目覚ましい
 - 様々なソースから大量のオンラインデータが提供される
 - 計算機は安価・高速
 - 機械学習を用いた事業が発生・成長 (e.g., データマイニング/KDD)


予測と推測・推定



予測と推定・推測



<http://heavenawaits.wordpress.com/god-man-and-stock-market-wave-theories/>



<http://www.safehaven.com/article/17497/why-bullion-is-outperforming-mining-stocks>


ランダムウォーク S が $2n$ 歩後に $2l$ ($-n \leq l \leq n$ とする) の地点にいる確率は

$$P(S_{2n} = 2l) = \binom{2n}{n+l} \frac{1}{2^{2n}} = \frac{(2n)!}{(n+l)!(n-l)!} \frac{1}{2^{2n}}$$

ランダムウォーク S が $2n$ 歩後に $a\sqrt{2n}$ 以上 $b\sqrt{2n}$ 以下である確率は

$$P(a\sqrt{2n} \leq S_{2n} \leq b\sqrt{2n}) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{1}{2}y^2} dy$$

ただし、 $-\sqrt{2n} \leq a \leq b \leq \sqrt{2n}$



```
set.seed(123)
rep <- 10000
N <- 1000
br <- 100
h <- numeric(rep)
for (i in 1:rep) h[i] <- sum(rnorm(N))
hc <- hist(h, freq=F, breaks=br)$density
ymax <- max(hc)
hist(h, freq=F, breaks=br, ylim=c(0,ymax), xlim=c(-3.5*sqrt(N), 3.5*sqrt(N)))
par(new=T)
plot(function(x) dnorm(x,0,sqrt(N)), col=2, ylim=c(0,ymax),
      xlim=c(-3.5*sqrt(N), 3.5*sqrt(N)), xlab="", ylab="")
```

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

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


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

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

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




```
set.seed(123)
rep <- 50000
N <- 1000
br <- 100
h <- numeric(rep)
for (i in 1:rep) {
  t <- cumsum(rnorm(N))
  h[i] <- length(t[t >= 0])/N
}
hc <- hist(h, freq=F, breaks=br)$density
ymax <- max(hc[1], hc[length(hc)])
hist(h, freq=F, breaks=br, ylim=c(0,ymax))
par(new=T)
plot(function(x) {(1/pi)/sqrt(x*(1-x))}, col=2,
      xlim=c(0,1), ylim=c(0,ymax), xlab="", ylab="")
```




```
set.seed(123)
for (i in 1:10) {
  plot(cumsum(rnorm(1000)), col=i, type="l", ylim=c(-40,40)); par(new=T)
}
```

正規分布でない世界なら



In the markets, the probability of outsized events is much higher than predicted by a Normal Probability Distribution
Fat Tails


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



安定分布(stable distribution)がよくフィットするとされている。しかし、実データは安定分布より早く裾が落ちる。そこで、切断安定分布(truncated stable distribution)を考えることがある。しかし、今度はきりすぎになりやすい。

<http://www18.tok2.com/home/kabutaroeconophysics/N225perMinDistribution.htm>

例えば、地震




全世界で2000年1月1日～2012年8月30日間に検知された地震のマグニチュードに対する積算度数
全世界で2000年1月1日～2012年8月31日間に検知された地震のマグニチュードに対する度数

http://earthquake.usgs.gov/earthquakes/eqarchives/epic/epic_global.php

1949～1998年の50年間に日本周辺で検知された地震のM別頻度分布(気象庁データによる)

http://www.hinet.bosai.go.jp/about_earthquake/sec1.2.html




直線は $\log(\text{frequency}) = 8.7 - 1.02 \text{ magnitude}$.


直線は $\log(\text{frequency}) = 8.7 - 1.02 \text{ magnitude}$. なお、USBSのデータを用いているため、マグニチュードはモントマグニチュードである。いわゆるエネルギーの対数の線形関数である

直線は $\log(\text{frequency}) = 8.7 - 1.02 \text{ magnitude}$. なお、USBSのデータを用いているため、マグニチュードはモントマグニチュードである。いわゆるエネルギーの対数の線形関数である

地震の規模と発生頻度との関係




データは理科年表(国立天文台編)2005の693ページのデータを使用。(北緯25～40°、東経125～150°の範囲[日本列島を囲む範囲]で、1961年から1999年の間に気象庁が決めたM5以上の地震)ただし、M8.0の地震の頻度が0であるためにM8.0以上の2個のデータを除外している。採用したデータが示す直線はグーテンベルグ-リッターの関係を示しており、式は $\log n(M) = 7.490 - 0.919M$ で表される。



マグニチュードの度数分布。b値は0.81程度と推定された。1997年5月13日の鹿児島県北西部地震前の地震

べき分布




はやぶさの分裂破片のサイズ分布

<http://pholus.mtk.nao.ac.jp/~satomk/hayabusa/result/>

英単語の出現頻度の Zipf 則。横軸が(wikipedia に書かれている)単語の出現数の順位、縦軸が出現数。

http://en.wikipedia.org/wiki/Zipf%27s_law

べき分布(続)




日本の企業の年間の収益量の分布。べきのべき分布がきれいに見えている。 (著者: 東京大学大学院工学系研究科 高橋 浩一, Masako Takayasu and Hiroshi Takayasu) To appear in Encyclopedia of Complexity and Systems Science, S. Havlin (Eds.), Springer Fractals and Economics.

<http://www.gakushuin.ac.jp/~881791/modphys/08/>

過去20年間の日経平均の騰落率(終値から終値まで1日間の)のグラフに指数べき分布を重ね合わせたグラフです。(度数と分数が同じになるように調整した後、pを調整して相関係数が高くなるように調整してあります。 $p=1.278$ 。

<http://reiko0309.blog41.fc2.com/blog-entry-486.html>

べき分布(続)




世界の長者番付データ(Forbes 2007, Wikipedia 2007年度世界長者番付)をもとにした。富豪の資産の順位

<http://www.pitecan.com/articles/WiredVision/wv06/index.html>

増井俊之氏のホームページレトリに入っているファイルを大きさ対順位

べき分布(続)



http://hiroshi-kobayashi.at.wabry.info/2008/05/article_27.html

現実のデータ

- 正規分布に従わないものがある
 - 冪分布に従うと、fat tail である。
 - その結果、大きく外れる予測誤り率が大きい
- しかも、現実にはデータ量が少ない
 - 絶対量が少ない場合
 - 相対量が少ない場合

世の中ビッグデータだと騒いでいるのに？

Swan and Black Swan



<http://akkesi1946.kilaguni.tv/e456896.html>

<http://journal.myc.com.co/articles/2009/07/21/blackswan/>

<http://ermbooks.wordpress.com/2008-reading-groups/the-black-swan/>

<http://photo.digitita.com/article/31020086.html>

Swan and Black Swan

- "Black Swan" はTalebの極めて有名な著書
 - 最近、"Black Swan" とgoogleで引くと、別のものが大量に出てきて困ります。
 - 大分とよくなりましたと言いたいが、そうでもなし
- Swanは白い鳥だと誰もが信じていた。Black Swan が発見されるまでは。
 - 「これはバブルではない、わが国経済の実力である」と誰もが信じていた。バブルが崩壊するまでは。

関連領域

- 認知科学: 言語獲得、推論の学習
- 統計学: バイアス vs. 分散, 信頼区間, 仮説検定
- ベイズの方法: ベイズの定理、欠測値の推定
- 人工知能: 記号表現、計画、知識を用いた学習
- 計算の複雑さの理論: PAC 学習、VC次元、誤差限界
- 制御理論: 最適化、動的計画、予測の学習
- 情報理論: エントロピー, MDL, 情報源符号化
- 神経科学: 人工神経回路網、脳(大脳、小脳、視床下部)
- 哲学: オッカムの剃刀, 帰納的一般化
- 心理学: 練習の冪法則(Power Law of Practice) 発見的学習

機械学習環境

- Weka: Waikato大学開発
 - <http://www.cs.waikato.ac.nz/ml/weka/>
- RapidMiner:
 - <http://rapid-i.com/content/blogcategory/10/69/>
 - 旧名: Yale: yet another learning environment
 - <http://www-ai.cs.uni-dortmund.de/SOFTWARE/YALE/index.html>
- R: 統計計算用言語・パッケージ
 - <http://www.r-project.org/>
 - Rattle: <http://rattle.togaware.com/>
- Python: 機械学習用ツールがある
- 掲示板
 - <http://www.kdkeys.net/forums/>

参考書等



- **パターン認識と機械学習**
- **Thomas Mitchell, Machine Learning, McGraw-Hill.**
- **Stuart Russell, Peter Norvig, エージェントアプローチ人工知能, 共立出版**
 - Artificial Intelligence: A Modern Approach (3rd edition), Prentice Hall
- <http://www.sakurai.comp.ae.keio.ac.jp/>