

情報意味論(10)

(簡単に)事例ベースアプローチ

櫻井彰人
慶應義塾大学理工学部

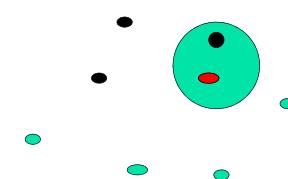
事例ベース学習

- キーアイデア
 - 訓練データ $\langle x_i, f(x_i) \rangle$ を全て憶えていよう(とりあえずは、何も、または、あまりしない)
 - 問い合わせがあったら、その時点で、しよう
- この類に属する方法
 - 最近傍法(Nearest neighbor)
 - k -Nearest neighbor
 - Locally weighted regression
 - Radial basis functions
- Lazy 対 eager

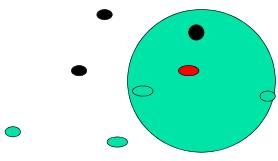
最近傍法

- 最近傍法(Nearest neighbor)
 - 問合せ x_q に対し、最近接の x_n を見つけ、 $f(x_q) \leftarrow f(x_n)$ とする
- k -Nearest neighbor
 - k 個の最近接データの間で、多数決
 - k 個の最近接データの間で、平均値

1-Nearest Neighbor

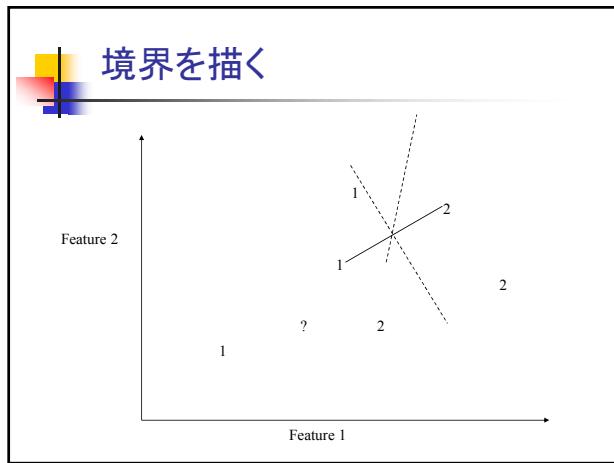
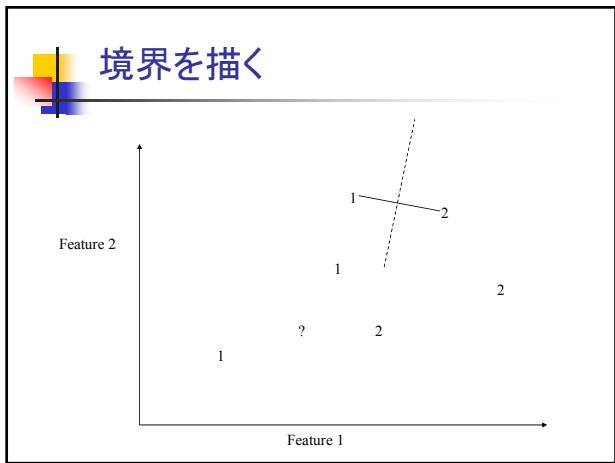
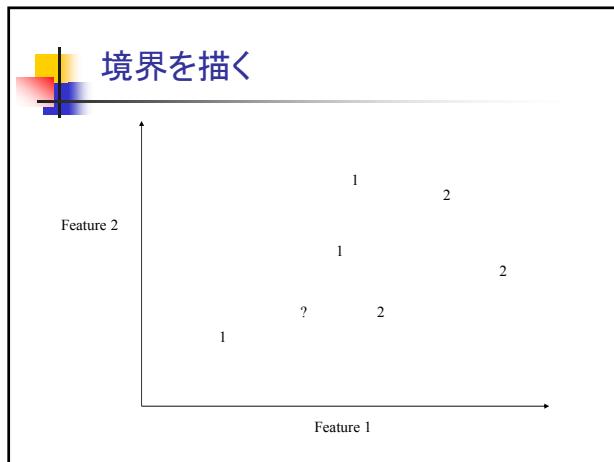
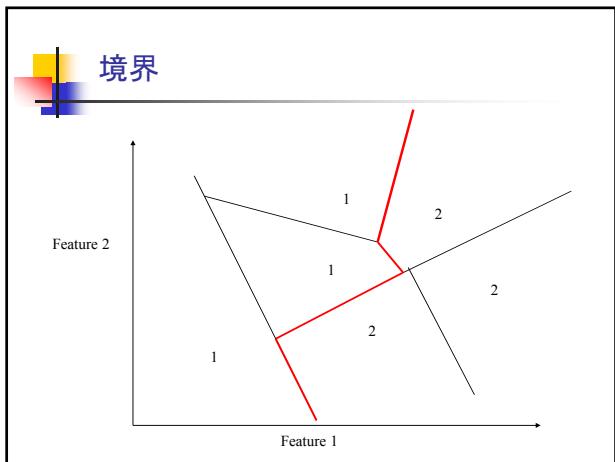
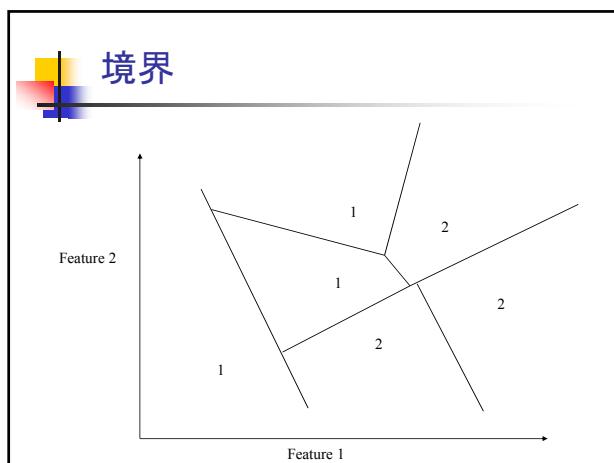
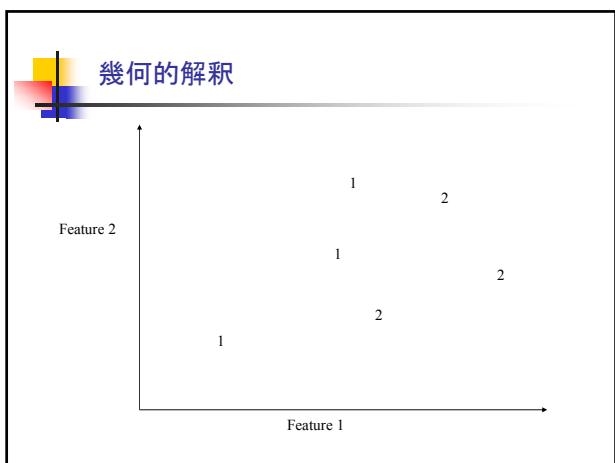


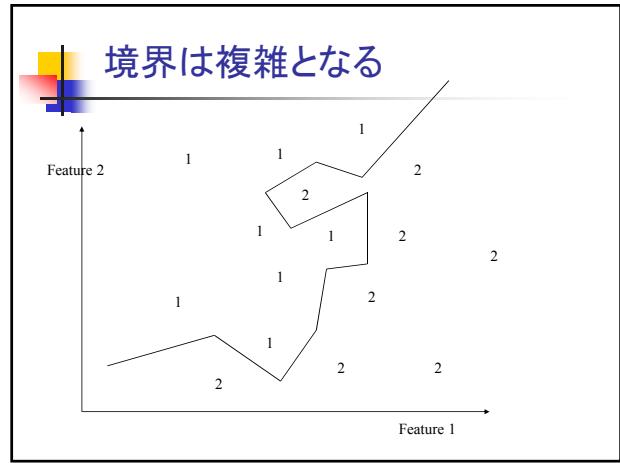
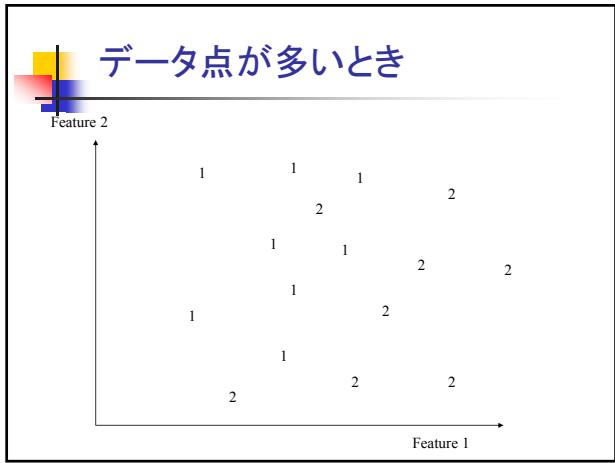
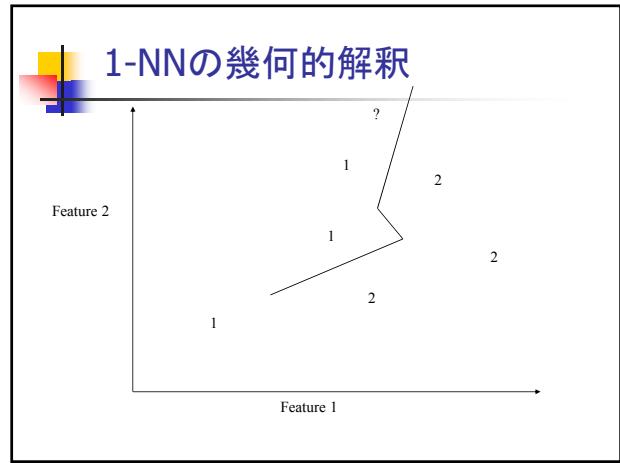
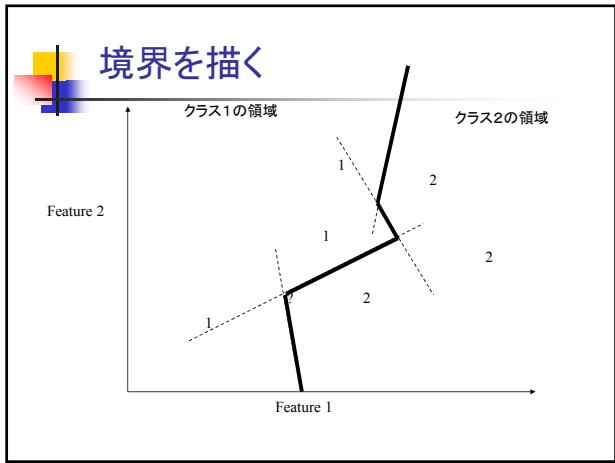
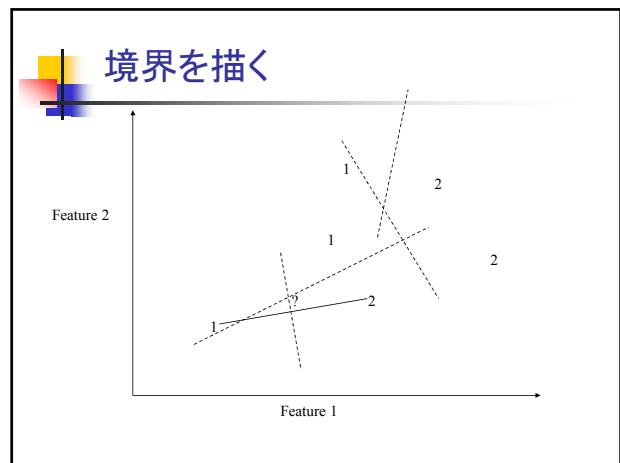
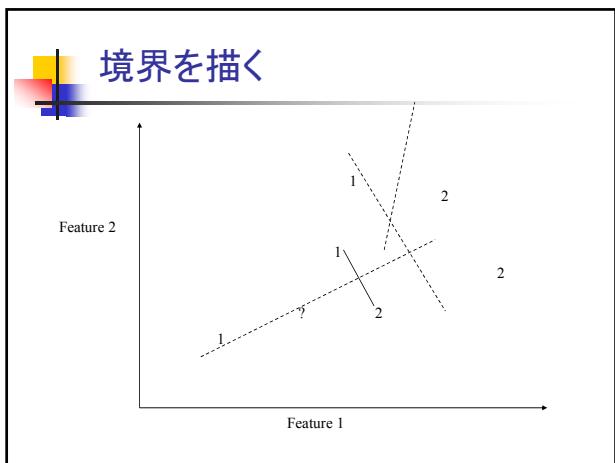
3-Nearest Neighbor



最近傍法の特徴

- いつ使うか
 - 属性が R^n の点とみなせる
 - 属性数はあまり多くない(数十個?)
 - 大量の訓練データ
- 長所
 - 学習が速い
 - 複雑な目標関数も表現可能
 - (訓練データがもつ)情報を失うことがない
- 短所
 - 問合せ時、遅い
 - 無関係な属性によって、簡単に、ごまかされる





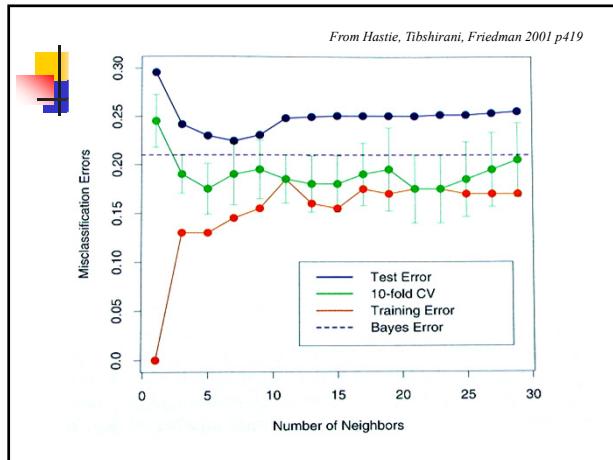
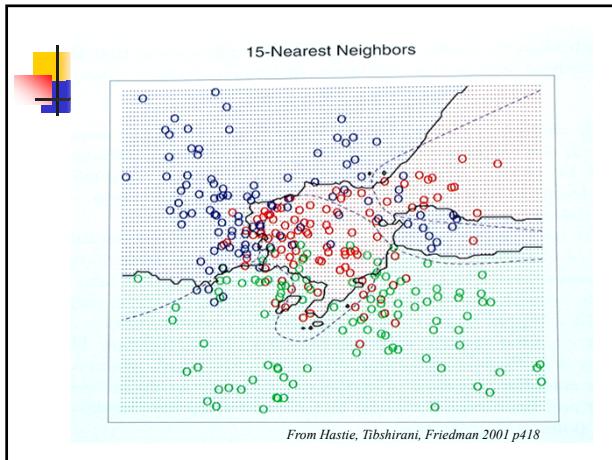
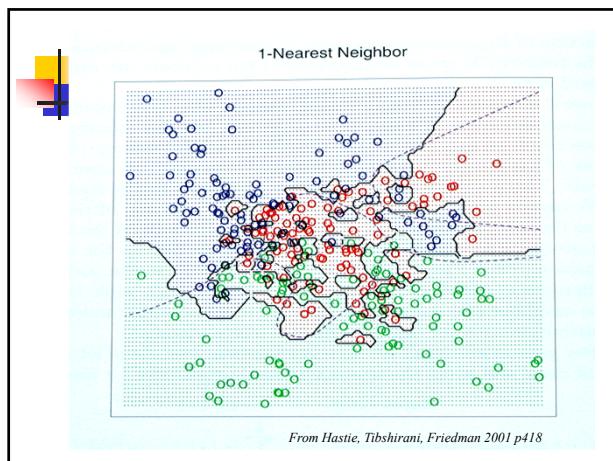


Table 6. Results summary of TC systems on Reuters versions 1-4.

System	Reuters version 1	Reuters version 2	Reuters version 3	Reuters version
WORD	—	.15 (Scut)	.31 (Peut)	.29 (Peut)
kNN	—	.69 (Scut)	.85 (Scut)	.82 (Scut)
LLSF	—	—	.85 (Scut)	.81 (Scut)
NNets.PARC (perceptron)	—	—	—	.82 (Peut)
CLASSI (perceptron)	—	—	.80	—
RIPPER (DNF)	—	.72 (Scut)	.80 (Scut)	—
SWAP-1 (DNF)	—	—	.79	—
DTree IND	—	.67 (Peut)	—	—
DTree C4.5	—	—	.79 (F_1)	—
CHARADE (DNF)	—	—	.78	—
EXPERTS (n-gram)	—	.75 (Scut)	.76 (Scut)	—
Rocchio	—	.66 (Scut)	.75 (Scut)	—
NaiveBayes	—	.65 (Peut)	.71	—
CONSTRUE (Exp. Sys.)	.90	—	—	—

Yiming Yang, An Evaluation of Statistical Approaches to Text Categorization, Information Retrieval, vol.1 69-90 (1999)

Table 6. Comparative results among different classifiers obtained on five different version of the Reuters collection. Unless otherwise noted, entries indicate the microaveraged breakeven point; within parentheses, "M" indicates macroaveraging and " F_1 " indicates use of the F_1 measure. Boldface indicates the best performer on the collection.

極限における振舞い

- $p(x)$: 事例xがラベル1(正)をもつ確率
 - Nearest neighbor:
 - 事例数 $\rightarrow\infty$ のとき、Gibbsアルゴリズムに漸近
 - Gibbs: 確率 $p(x)$ で1を予測
 - k -Nearest neighbor
 - 事例数 $\rightarrow\infty$ かつ k が大きくなると、Bayes最適
 - Bayes最適: $p(x)>0.5$ なら1、それ以外0

注: Gibbs の期待誤差は Bayes の倍以下

距離荷重つき k -NN

- 近い事例の判断を重視したい

$\hat{f}(x_q) \leftarrow \frac{\sum_{i=1}^k w_i f(x_i)}{\sum_{i=1}^k w_i}, \quad w_i \equiv \frac{1}{d(x_q, x_i)^2}$

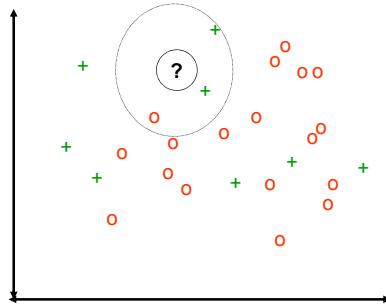
但し、 $d(x_q, x_i)$ は、 x_q と x_i の間の距離

 - これにより、 k 個のみならず全データを使うことに意味がでてくる⇒Shepardの方法

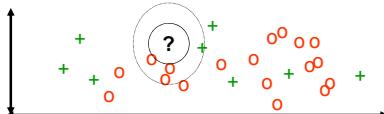
K-NN と不要な特徴

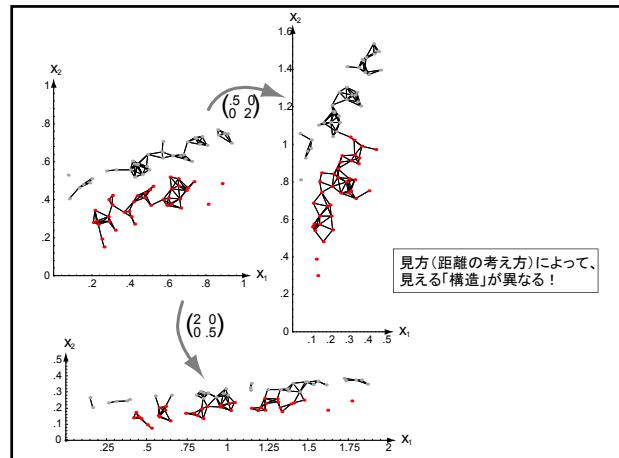
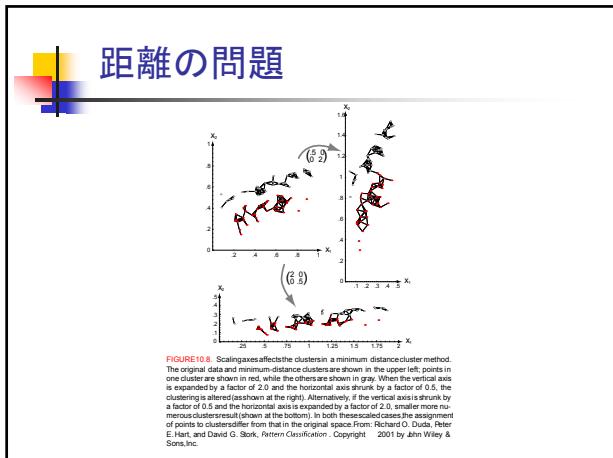


K-NN と不要な特徴



K-NN と不要な特徴



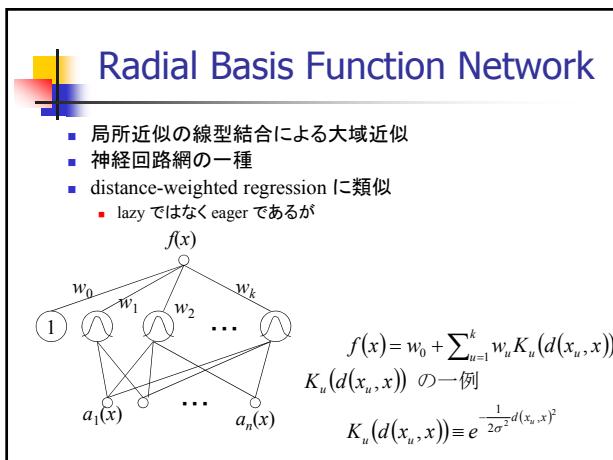


- ## 次元の呪い
- 20個の属性で記述されるが、その内、たった2属性のみが意味ある場合を考える
 - 次元の呪い:
 - k -NNなら、他の18属性の値でどんな結論も出る
 - 解決方法
 - j 番目の属性に z_j の荷重を。 z_j は予測誤差最小となるように選択
 - cross-validation を用いて自動的に z_j を決定

- ## Locally weighted regression
- k -NN は各問合せ x_q で f の局所近似を構成していた
 - x_q の周囲で $f(x)$ の近似関数を明示的に構成したらどうだろうか?
 - k -NN に線型回帰したら?
 - 2次回帰では?
 - 区分回帰したら?
 - 最小化すべき誤差にもいくつかの候補が

$$E_1(x_q) = \frac{1}{2} \sum_{x \in x_q \cap k\text{-NN}} (f(x) - \hat{f}(x_q))^2$$

$$E_2(x_q) = \frac{1}{2} \sum_{x \in D} (f(x) - \hat{f}(x_q))^2 K(d(x_q, x))$$



- ## RBFの学習
- $K_u(d(x_u, x))$ の x_u の定め方
 - 事例空間に一様にばら撒く
 - 事例を使用(事例の分布が反映)
 - 荷重の学習(K_u は正規分布とする)
 - 各 K_u の分散(と平均)を定める
 - 例えば、EMを使用
 - K_u を固定したまま、線型出力部分を学習
 - 線型回帰で高速に

Lazy 対 eager

- Lazy: 事例からの一般化をしないでいる。問合せがあったときに考える
 - k-Nearest Neighbor
- Eager: 問合せ前に予め一般化しておく
 - 「学習」アルゴリズム、ID3, 回帰, RBF,,,
- 違いはあるか?
 - Eager学習は全域的な近似を作成
 - Lazy学習は局所近似を大量に作成
 - 同じ仮説空間を使うなら、lazy の方が複雑な関数を作成
 - over-fitting の可能性
 - 柔軟(複雑なところと単純なところの組合せ)

まとめ

- 事例ベースアプローチ
 - 大域的な構造を仮定しない
 - どんな場合にも使える
 - 雑音に弱い(大域構造を用いた平滑化ができない)
 - 次元の呪い