


どんな問題？



巨大データの調査は人間の目では無理なので、コンピュータにさせたい

- ・何をを見つけましょうか？ 何を計算しましょうか？
- 特徴は何か知りたいので、たくさんある構造を見つけよう

- 牛乳、パン、菓子
- お茶、弁当、味噌汁
- おにぎり、雑誌、お茶
- はさみ、のり、テープ
- おにぎり、お茶
- コップ、皿、箸
- 弁当、おにぎり、お茶
- 弁当、おにぎり
- ...



- ・生活習慣と病気の関係
- ・客の種類と売上げの関係
- ・文書の分類
- ・共通の趣味を持つグループ
- ...




- ・ある反応をする化合物の特徴
- ・組織図の特徴
- ・XMLデータの解析
- ・Webリンクの解析
- ・企業間取引の解析
- ...


関係性を持つ
問題設定も可能

何が難しいの？


- ① 組合せを全て調べると計算が終わらない
← 50個のものの組合せは1000兆通り！
 - ② 適当に探すと見つけ損ないが出るし、同じ物が何度も出てくる
← 全部メモリに取っておくと、手間がかかる
 - ③ たくさん現れるかどうかを調べるのも手間
← 1つにつき 1-10秒かかる。1万個なら1日！
- 計算方法を工夫して、困難を乗り越える



- ・{お茶、弁当、おにぎり}を買った人は、{お茶、弁当}の組合せも買っている
 - {お茶、弁当、おにぎり}がよく現れるなら、{お茶、弁当}もよく現れる
- ①② 何も無いところから、ものを1つずつ追加して、よく現れるものだけを探索できる
 - ② 小さい物から順に追加するようにすると、同じ物を2回見つけることが無くなる
 - ③ {お茶、弁当、おにぎり}を含む項目を調べるときは、{お茶、弁当}を含む項目だけ見ればよい
 - ③ さらに1つアイテムを追加するたびにデータから不要な部分を削ると、より深い探索が速くなる
- ② 隣接性があるデータ(グラフ)は、パターンを唯一的にコード化し、同じコードを持つ物を2回見つけないようにする(木のコード化)



1		3	4	5		
1	2		4		6	
		3	4			7
1	2		4		6	7
		3	4	5	6	7
2			4		6	7



巨大なデータから目立つものを見つける

情報学プリンシプル研究系 宇野 毅明



ほんとに速いの？

ダウンロード

<http://research.nii.ac.jp/~uno>

使い心地はどんなの？

国際コンテストで優勝 (FIMI04)



- ・100万項目を超えるようなデータでも、パソコン1台で数分で可能
- ・他の方法に比べ、解が増えても時間がさほど伸びず、メモリ使用量も一定
- ・多くの他分野の研究で使われている(参照件数50件以上)

- ・面白い解を見つけるには、解をたくさん見つけないといけない
→ 大きな解だけを出力
→ 含まれる項目が同じものは同一視(飽和パターン)
どちらも効率良く見つけられる
- ・「牛乳とパンを買う人はヨーグルトを買うことが多い」のような、データを説明するルールを見つけたい(アソシエーションルール)
→ ほぼ同じ時間で見つけられる
- ・正常なデータと異常なデータを区別するルールが知りたい(病気の人と健康な人の、習慣・遺伝子などの違い、など)
→ 異常なデータに多く含まれ、正常なデータにはあまり含まれないパターンを見つける

■ 応用研究 ■

- ・遺伝子を、働いている場面が共通している物で自動分類する研究
- ・遺伝子の典型的な相互作用の仕方を解析する研究
- ・画像の特徴的な要素に注目して画像を自動分類する研究
- ・遺伝的な病気を持つマウスの、原因となる遺伝子のパターンを見つける研究
- ・遺伝病のデータベースから、典型的な遺伝子異常の組合せを見つける研究

データ種別	POS	クリック	Web閲覧	顧客	単語
項目数	51万	99万	7.7万	8.8万	6万
データサイズ	330万	800万	31万	90万	23万
パターン数	460万	110万	53万	37万	100万
計算時間	80秒	34秒	3秒	3秒	6秒

事実上、パソコンに乗るデータなら短時間で計算できると思っていだらう