



データマイニング (Data Mining)

神鳥 敏弘



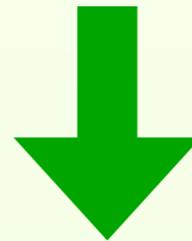
データマイニング

社会の高度情報化 & 情報発信の低コスト化

大量のデータが常に生成されている

記憶媒体の大容量化 & 通信の高速化

膨大なデータの蓄積や流通が可能になった

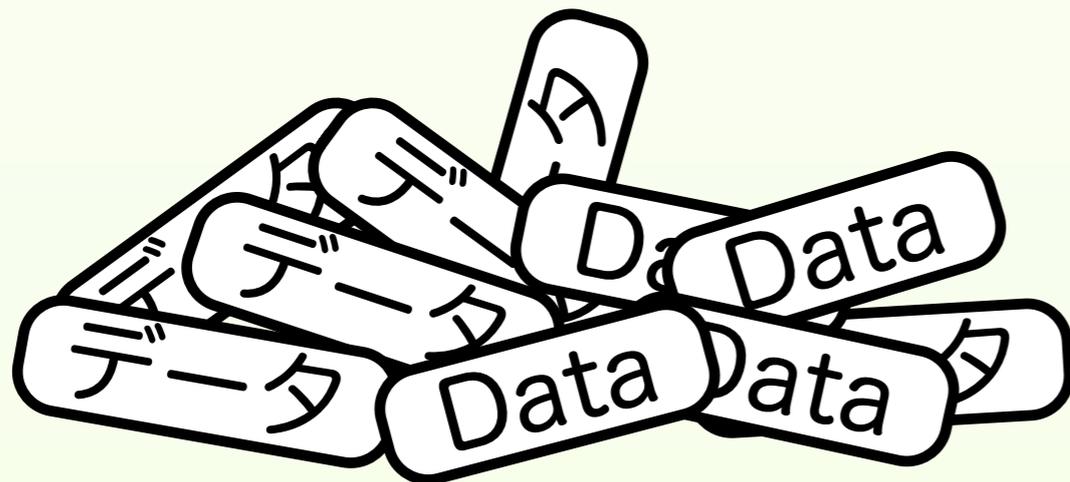


整理されていない膨大なデータの蓄積


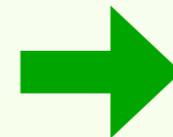
データマイニング

データマイニング

整理されていないデータから、予期されていないが、再利用可能な知識を掘り起こす(マイニングする)



整理されていないデータ



再利用可能な知識

関連技術： 機械学習(人工知能), 統計, データベース
アルゴリズム, 分散システム, 並列計算機

データマイニング

有効性(Effectiveness)

機械学習(人工知能)

データ
マイニング

統計

正当性(Validity)

データベース

効率性(Efficiency)



みんな大切！ バランスよく！

データマイニング

実用性を重視し，データ解析技術の探索的な側面を強調

1. 大規模データ

DBアクセス頻度，メモリ効率，計算量は線形

2. データ収集が計画的や静的ではない

はずれ値，欠損値，ストリームデータの処理

3. 新しい種類のデータやパターン

時系列，木，グラフ，順序データ，相関ルール

4. 人間による知識の新規性や有用性の判断

データの可視化，補助情報や制約の利用

データマイニング

相関ルール (Association Rule)

(頻出パターンマイニングの代表的問題)

Apriori, PrefixSpan, AprioriAll

回帰分析 (Regression Analysis)

線形回帰, ロジスティック回帰, 回帰木

クラス分類 (Classification)

決定木, 判別分析, サポート・ベクトル・マシン

クラスタリング (Clustering)

k-means法, 群平均法, BIRCH

相関ルール

相関ルール

Association Rule

$X \Rightarrow Y$

X : 前提部 (antecedent)

Y : 結論部 (consequent)

X と Y は互いに同じものを含まないアイテムの集合
(アイテム : 商品などの「もの」)

X という条件が満たされる場合には、同時に Y という条件が満たされる場合も頻繁に生じる

例 : { 牛乳, パン } \Rightarrow { 卵 }

牛乳とパン (Xに相当) を同時に買う人は、高い頻度で卵 (Yに相当) を買う

相関ルール

バスケット データ | Basket Data

一度のトランザクション(ひとまとめの取引)ごとに、同時に購入された商品の一覧をまとめたデータ

例： $T_1 = \{\text{牛乳, サンドウィッチ, ハンバーガー}\}$
 $T_2 = \{\text{焼肉弁当, ポテトサラダ}\}$
⋮
 $T_N = \{\text{パスタセット, 牛乳}\}$

トランザクション T_1 は、今日の最初の客との取引。
その客の買い物かご(バスケット)には牛乳、サンドウィッチ、ハンバーガーが入っていた

相関ルール

条件Xがトランザクションiを満たす



Xがトランザクションiの部分集合

例：条件 $X = \{\text{牛乳, ハンバーガー}\}$

$T_1 = \{\text{牛乳, サンドウィッチ, ハンバーガー}\}$

$T_2 = \{\text{パスタセット, 牛乳}\}$

条件 $X \subseteq$ 取引1 \rightarrow トランザクション1を満たす

条件 $X \not\subseteq$ 取引2 \rightarrow トランザクション2を満たさない

バスケットデータ分析

XとYが共に頻繁に満たされる相関ルールを抽出

相関ルール

利用例 X と Y を組み合わせてセット商品作る

{ 緑茶, ツナおにぎり } ⇒ { タラコおにぎり }
{ 緑茶, ツナおにぎり } ⇒ { コンブおにぎり }

このような相関ルールが共に見つかったとする

緑茶, ツナ, タラコ, コンブおにぎり

このようなセットメニューを作り、単体で買うより少し価格を下げおくと、顧客あたりの購入単価の向上に役立つだろう

相関ルール

利用例

- ▶ X と Y を近くに並べて同時購入を促す

{インスタントラーメン} ⇒ {チャーシュー}

インスタントラーメン売り場にチャーシューを並べると同時購入が増えるだろう

- ▶ Xの販売数が増加する場合にYの在庫を増やしておく

{牛乳} ⇒ {パン}

牛乳の特売をすると、牛乳の販売数が増えると、パンの販売数も増えると予測される
よって、パンの仕入れ数を増やしておく

相関ルール

Apriori

IBMのRakesh Agrawalが中心になり開発
大規模なバスケットデータから次の条件を満たす相関
ルールをすべて発見する

- ▶ XUY を満たすトランザクション数は多い
- ▶ Xが満たされるときYも高頻度で満たされる

PrefixSpan, AprioriAll

時間的な変化も考慮する Aprioriアルゴリズムの拡張

例：「以前デジタルカメラを購入」し，その後「ケースを購入」した
顧客は，さらにその後に高い頻度で「メモ리카ード」購入する

回帰分析

回帰分析 Regression Analysis

入力：事例 (y_i, x_i) とは対象を表す変数 X の値が x_i の場合に，結果を表す変数 Y の値が y_i であったという具体例

事例集合 $(y_1, x_1), (y_2, x_2), \dots, (y_N, x_N)$

様々な対象 X に対応する Y の値との組である事例を N 個集めたもの

出力：変数 X と Y との関数関係 f

$$Y = f(X)$$

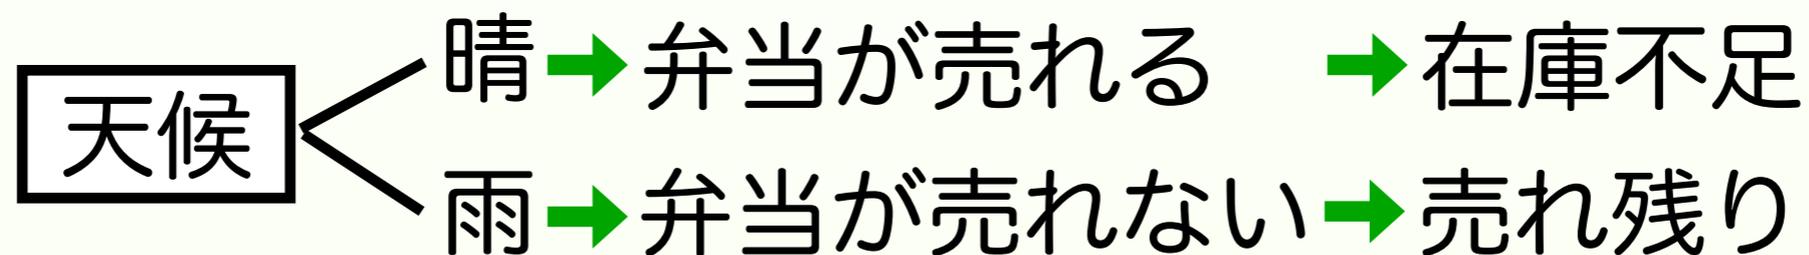
X ：説明変数，独立変数，属性，特徴

Y ：被説明変数，従属変数

f ：回帰直線(曲線)

回帰分析

利用例



明日の降水確率から弁当が売れる数を予測する

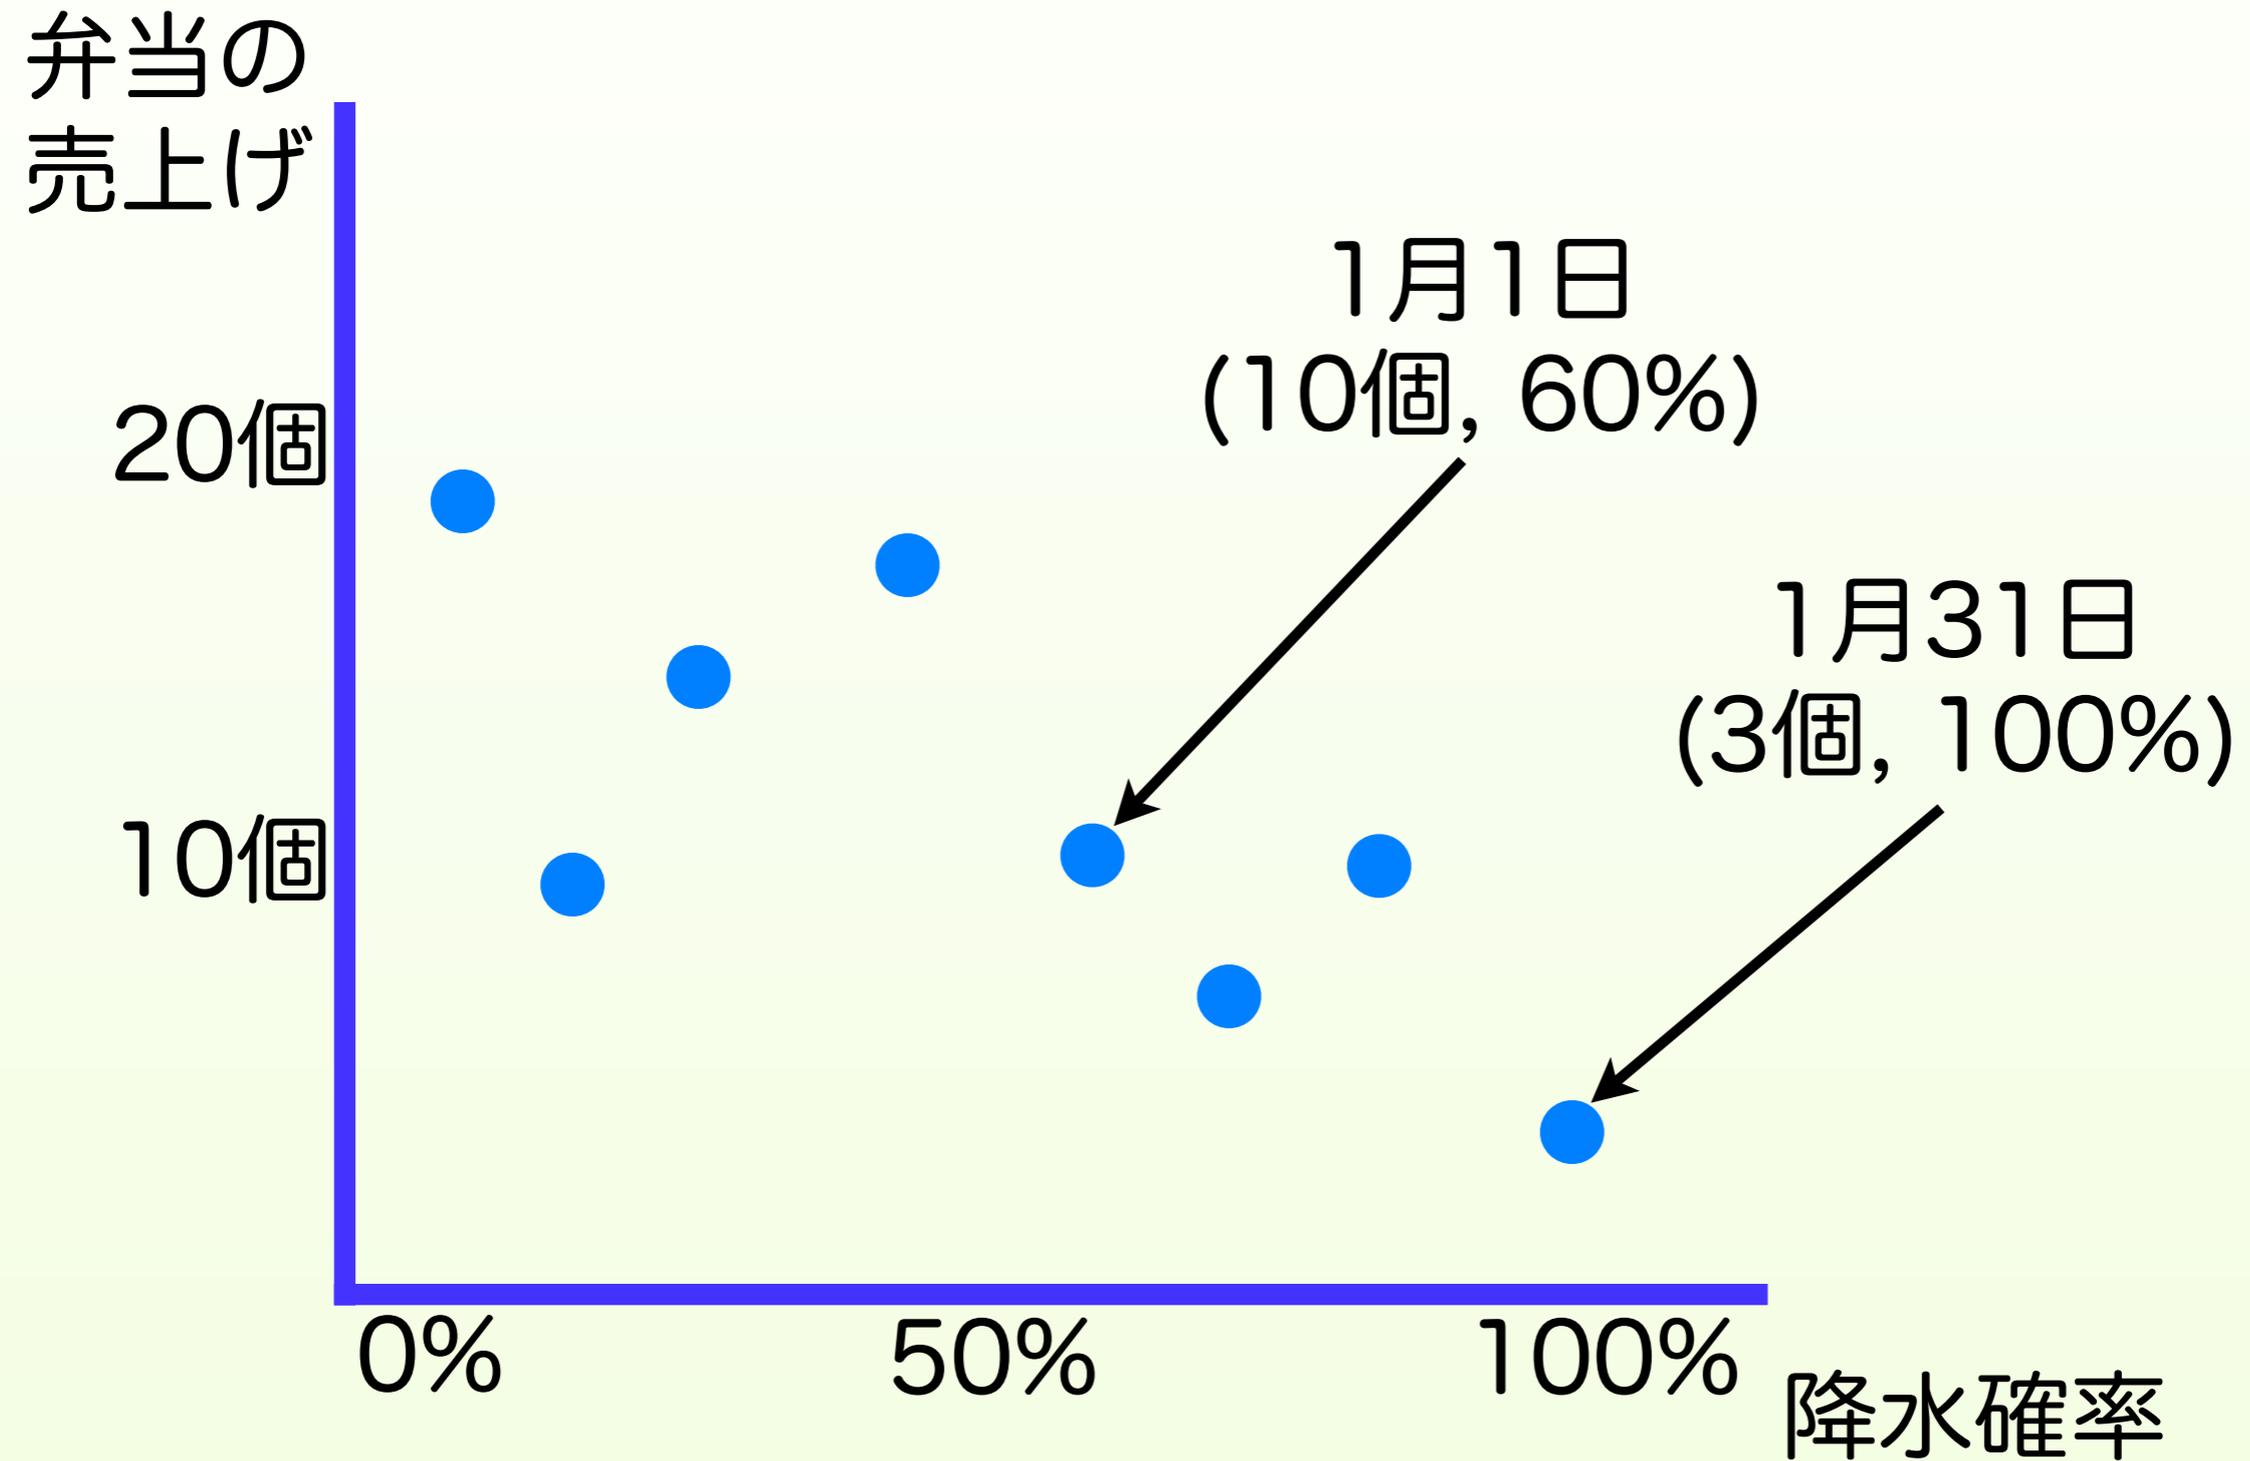
説明変数 X : 明日の降水確率
被説明変数 Y : 弁当の売れる数

事例集合 : 過去の降水確率と売り上げのデータ

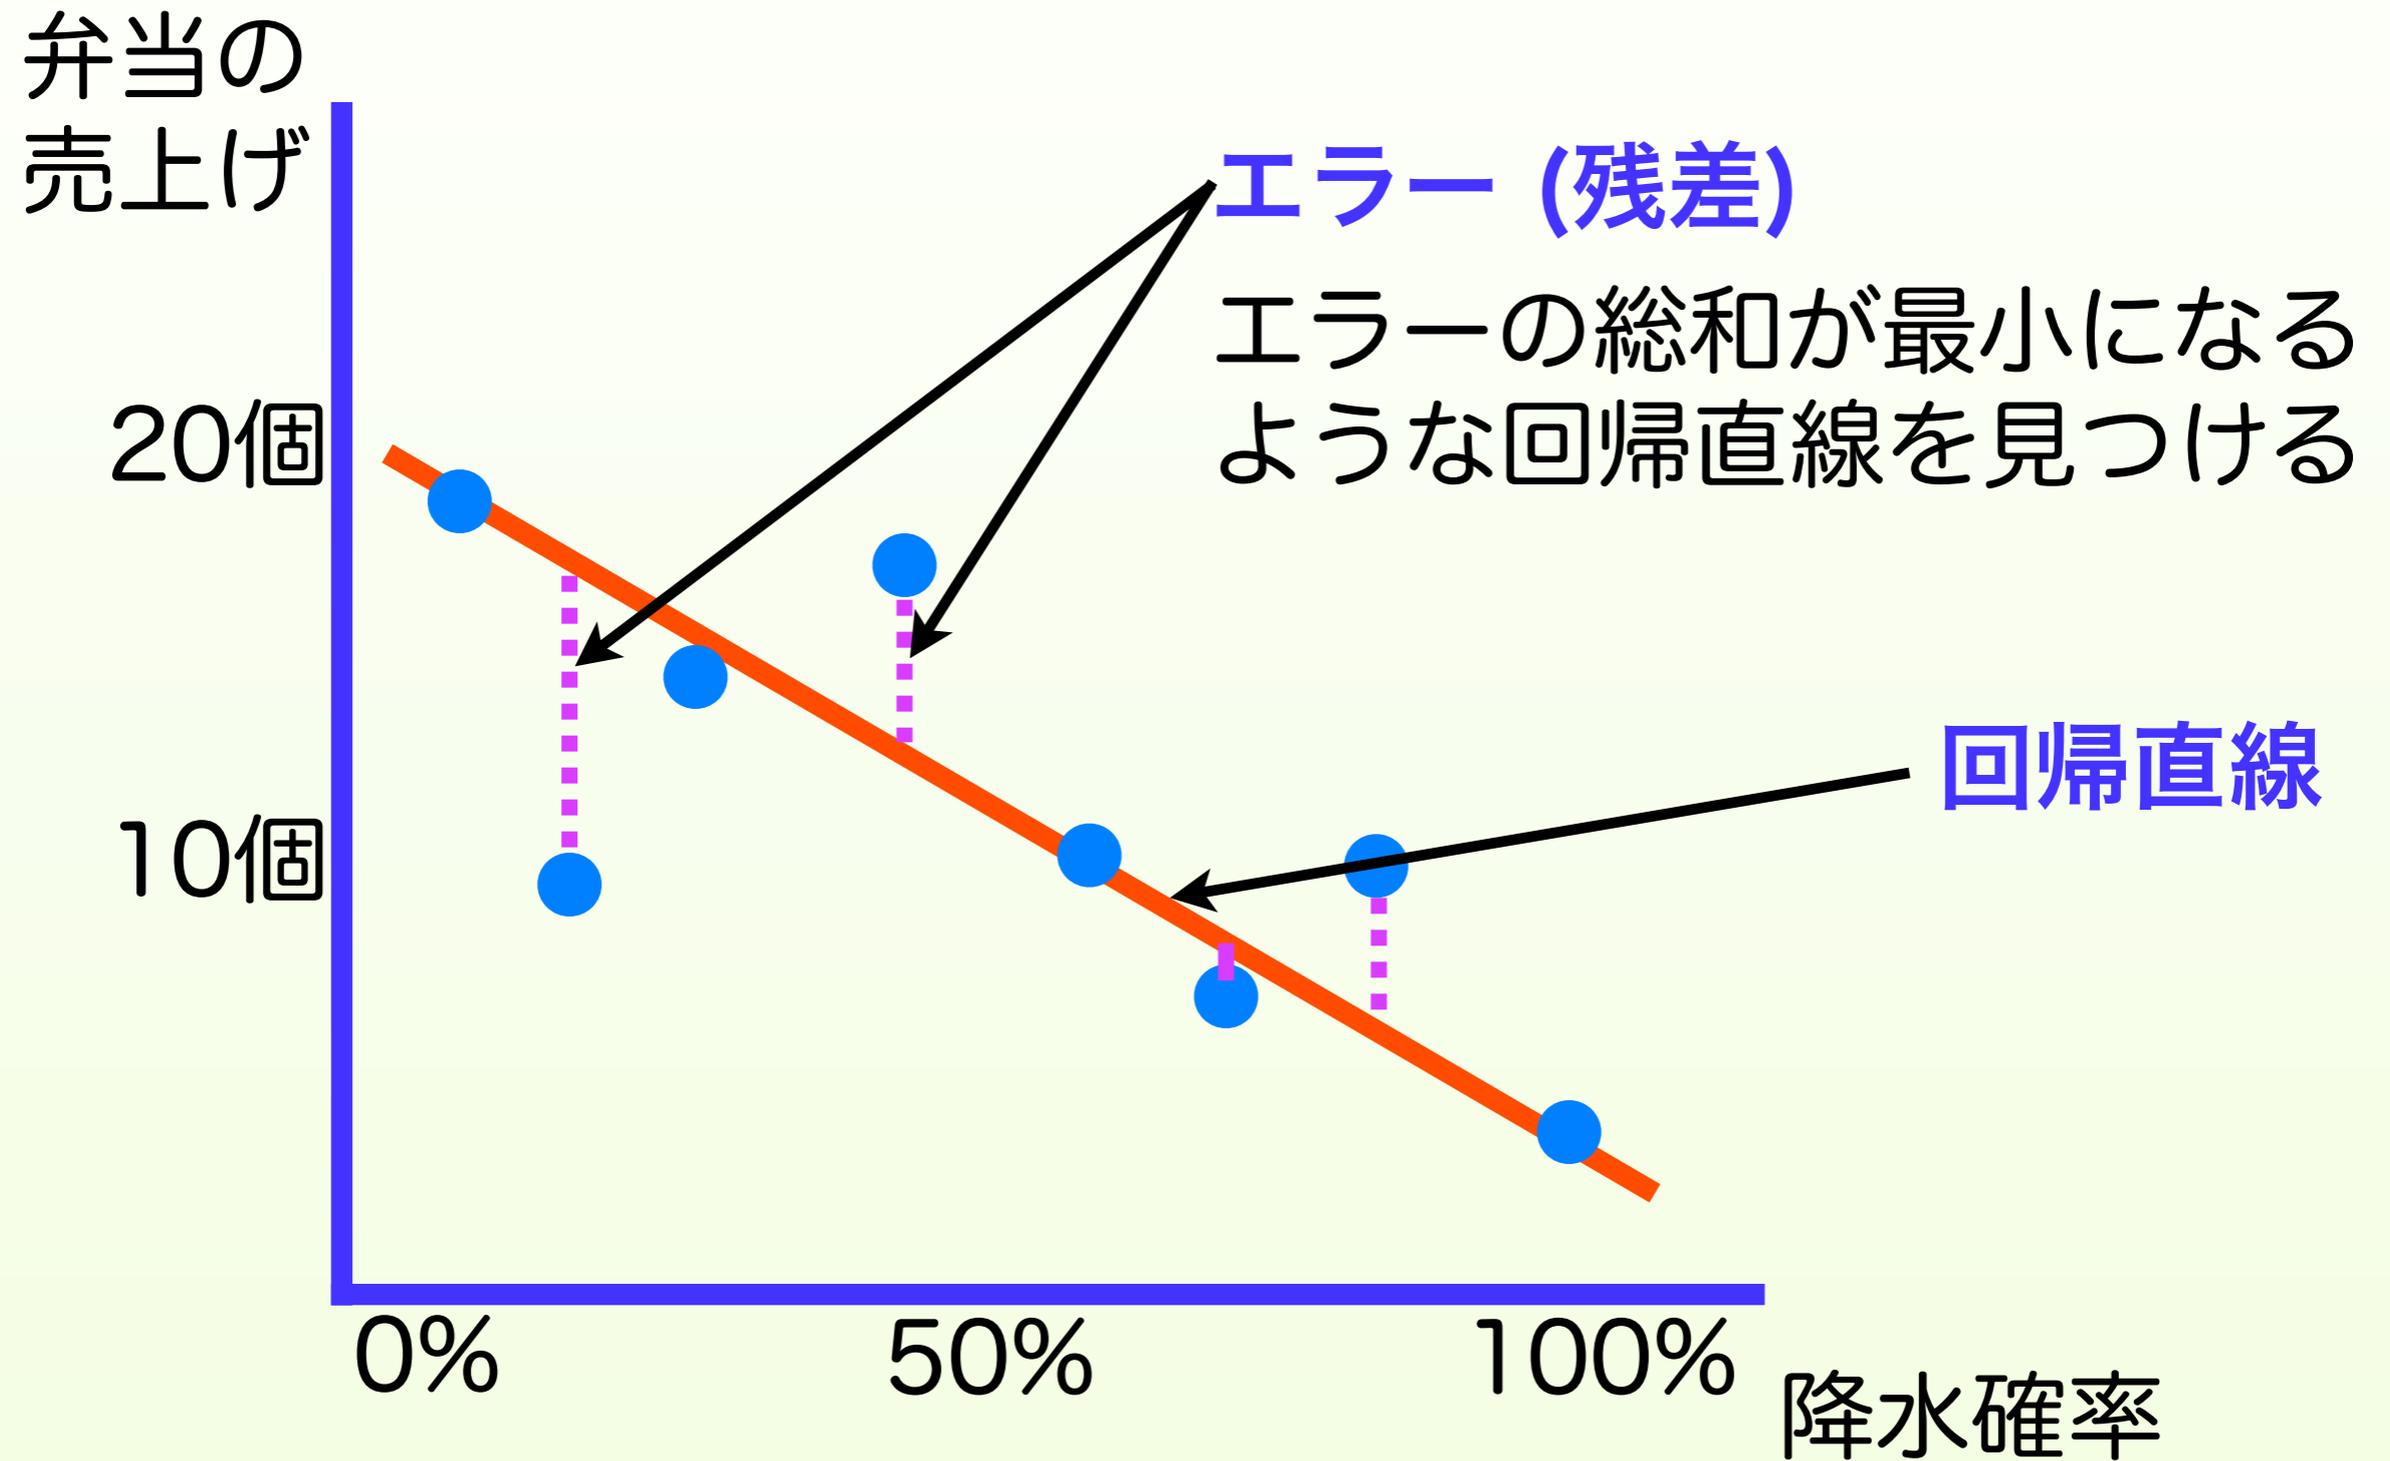
1月1日 (10個, 60%) 1月2日 (20個, 0%)

... 1月31日 (3個, 100%)

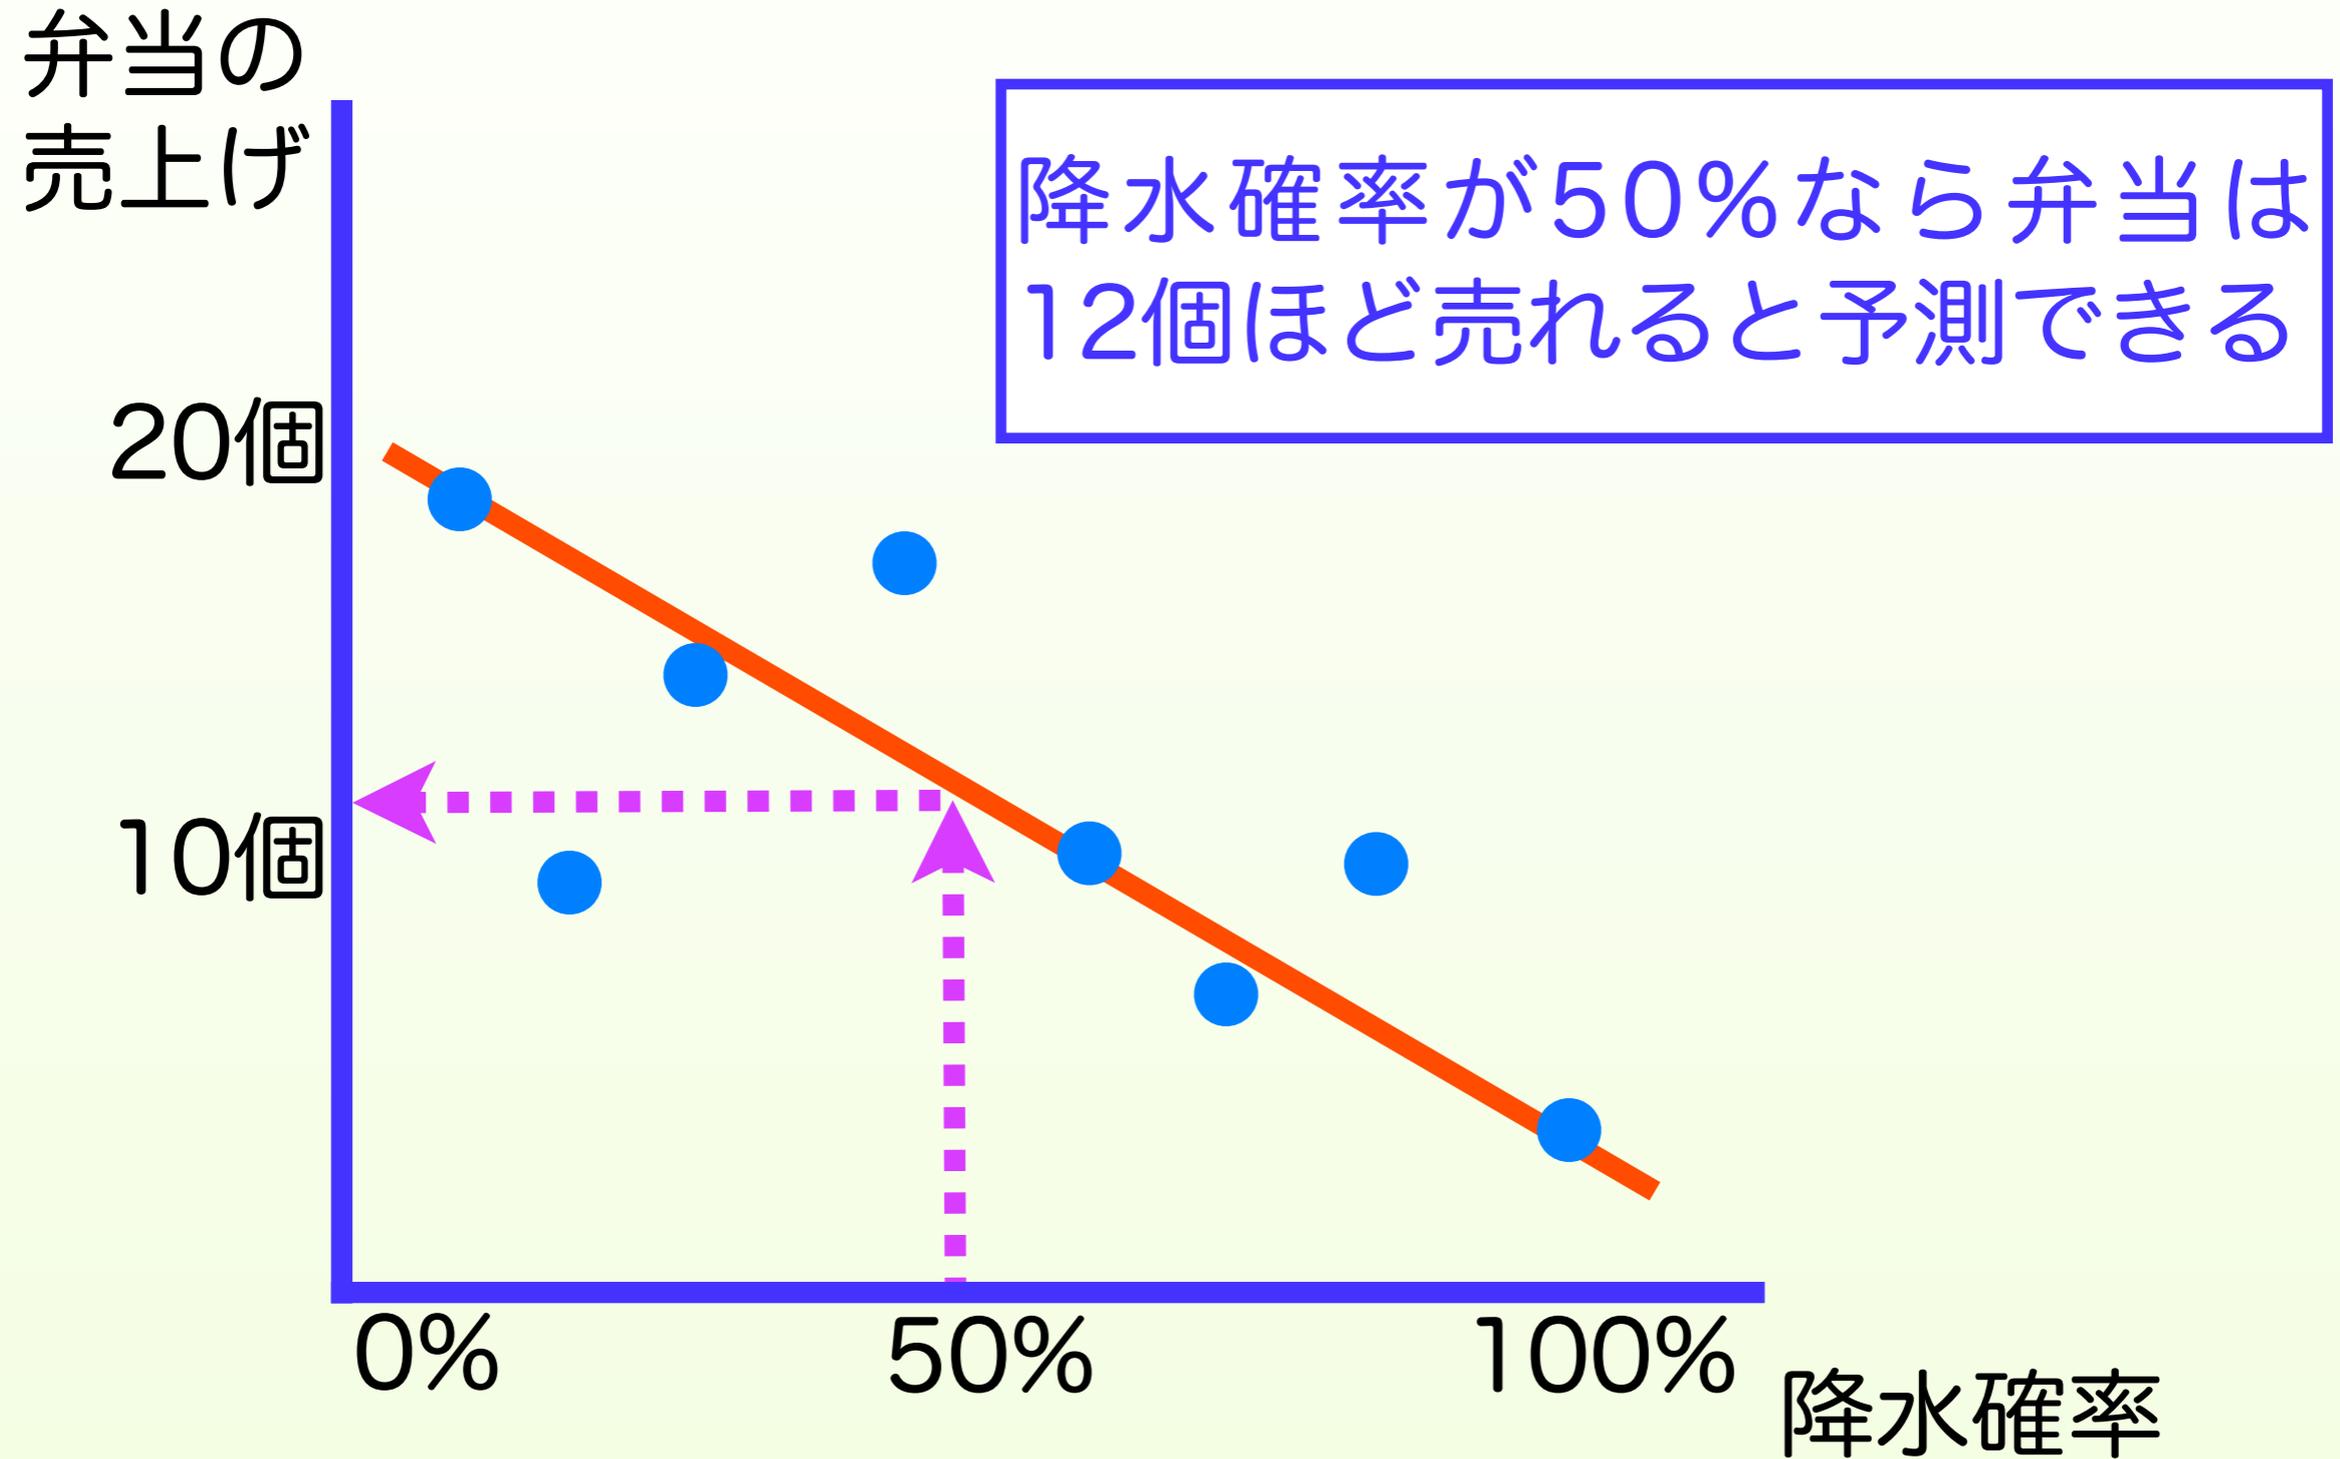
回帰分析



回帰分析



回帰分析



回帰分析

回帰直線

$$Y = -0.2X + 3$$

説明変数 X : 明日の降水確率
被説明変数 Y : 弁当の売れる数



弁当の売上げは降水確率以外のの要因にも影響される

説明変数 X_1 : 明日の降水確率
 X_2 : 平日は1, 土日祝は0
被説明変数 Y : 弁当の売れる数

$$Y = -0.2X_1 + 2.2X_2 + 3$$

統計では説明変数が2個以上なら**重回帰分析**と呼ぶ

回帰分析

非線形回帰

売上げ

20個

10個

0%

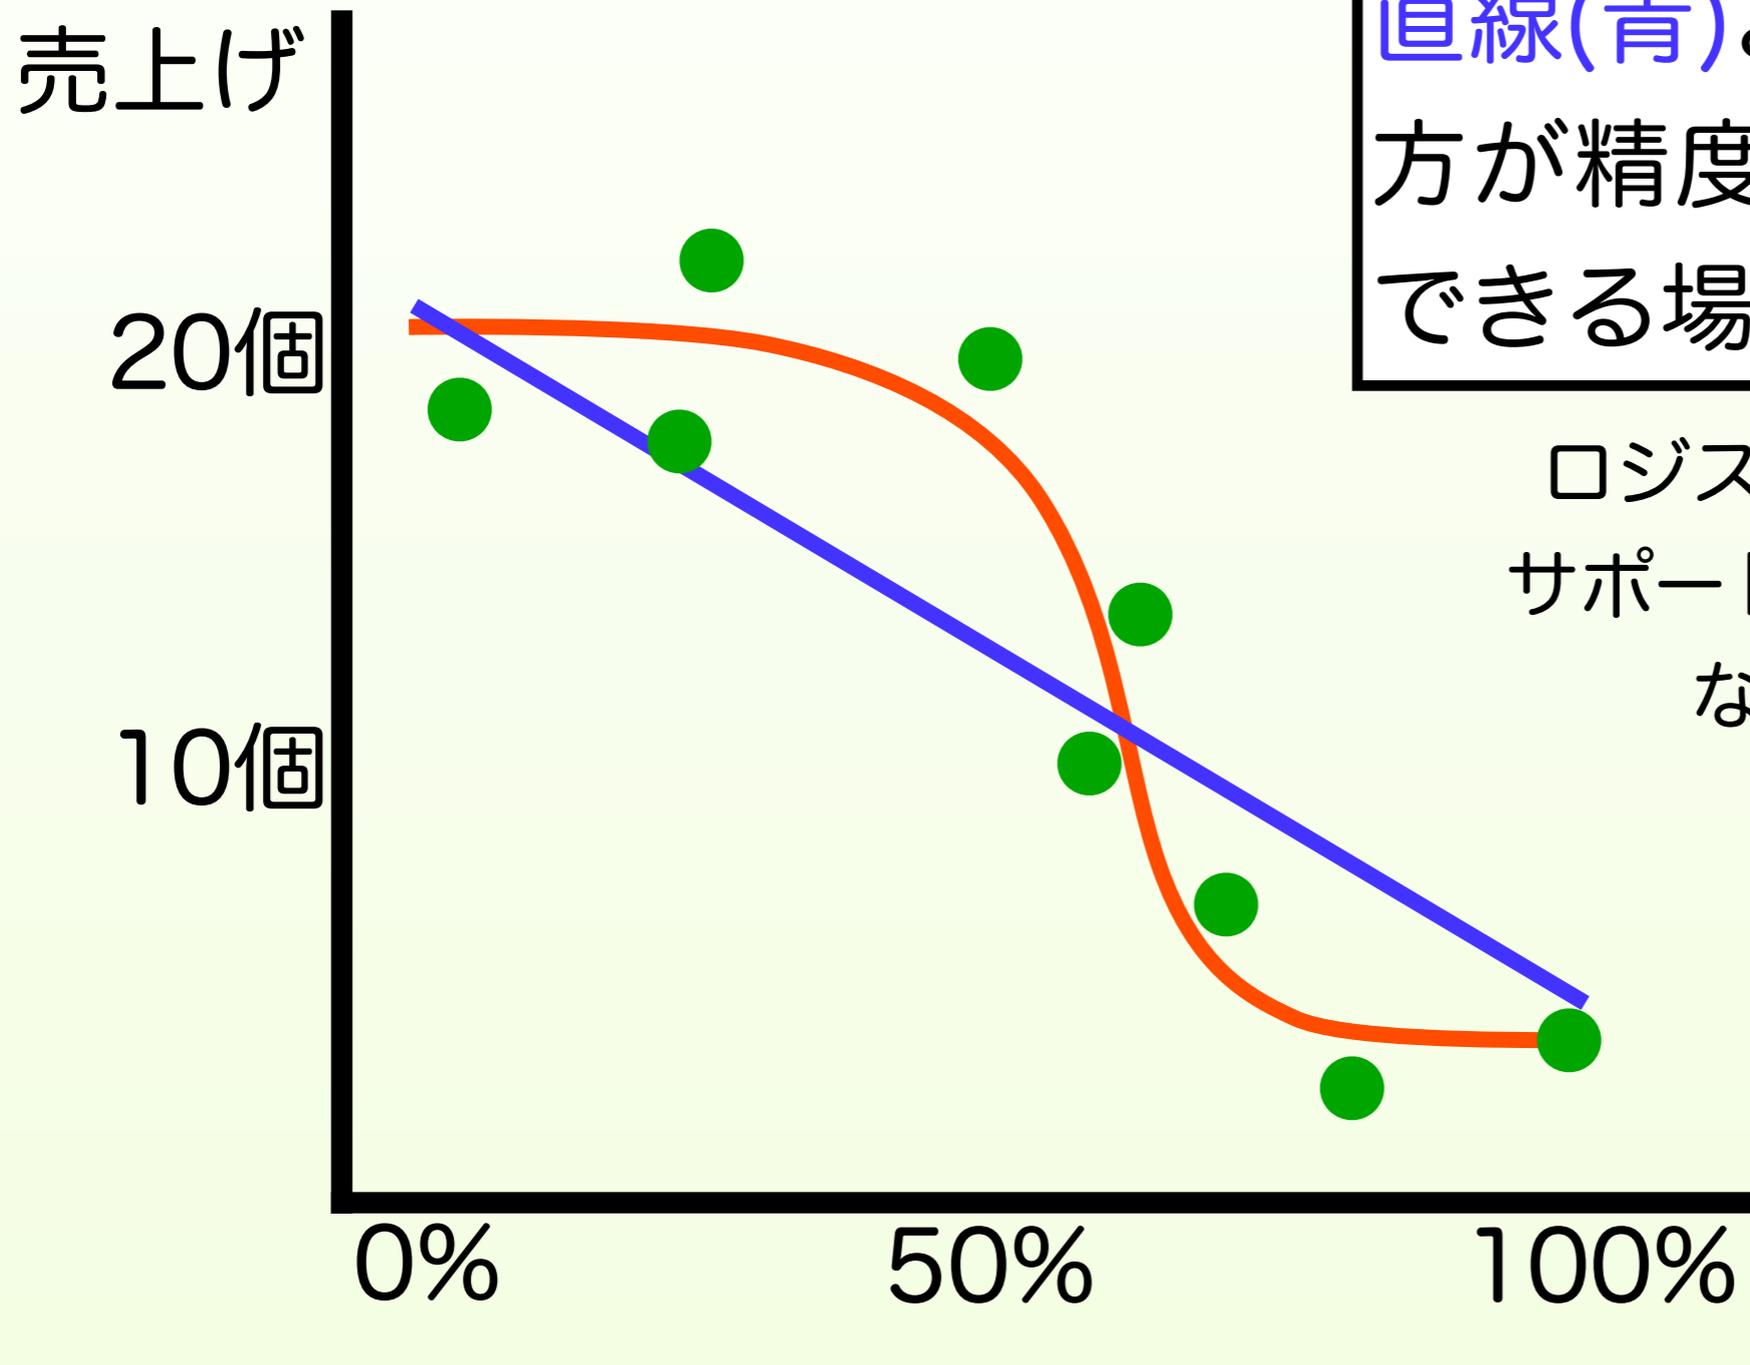
50%

100%

降水確率

直線(青)より曲線(赤)の方が精度の高い予測ができる場合もある

ロジスティック回帰
サポートベクトル回帰
などの手法



クラス分類

クラス分類 Classification

入力：事例 (c_i, x_i) とは対象を表す変数 X の値が x_i の場合に、変数 C の表すクラスが c_i であったという具体例

事例集合 $(c_1, x_1), (c_2, x_2), \dots, (c_N, x_N)$

様々な対象 X に対応するクラス C の状態の事例を N 個集めたものが事例集合

出力：分類規則(識別規則)



対象 X に対応するクラス C を予測するのが分類規則

クラス分類

クラス

事前に定めた有限個の集合中のいずれかの値をとる

例：おすすめ商品に {関心あり, 関心なし}

天気クラス {晴, 曇, 雨, 雪}

競馬で1位の馬のクラス {1番~15番}

利用例

スーパーのポイント会員にバーゲンの案内状を送る
バーゲンに来ない客に送ると余分な郵送費がかかる
できるだけ来てくれそうな客を選びたい

例：

対象 X：会員

クラス C：バーゲンに {来る, 来ない}

クラス分類

対象 X は幾つかの **属性 (特徴)** で表現する
これらの属性を並べたものを **属性ベクトル** という

$$i \text{ 番目の対象 } X_i = \langle X_{i1}, X_{i2}, \dots, X_{im} \rangle$$

例：ポイント会員の属性
バーゲンに来る可能性に影響しそうなものを選ぶ

第1属性 X_{i1} : 先月の購入額
第2属性 X_{i2} : 先月の来店回数
第3属性 X_{i3} : 店舗から住所までの距離

例：会員3番 $x_3 = \langle 4\text{万円}, 25\text{回}, 1.5\text{km} \rangle$
前回のバーゲンでは来店 クラス $c_3 = \text{はい}$
事例3 $(c_3, x_3) = (\text{はい}, \langle 4\text{万円}, 25\text{回}, 1.5\text{km} \rangle)$

クラス分類

分類規則の例

決定木

先月の購入額は5万円以上？

$$X_{i1} \geq 50000\text{円}$$

Yes

No

2kmより近くに住んでいる

$$X_{i3} < 2\text{km}$$

Yes

No

予測されるクラス

はい

はい

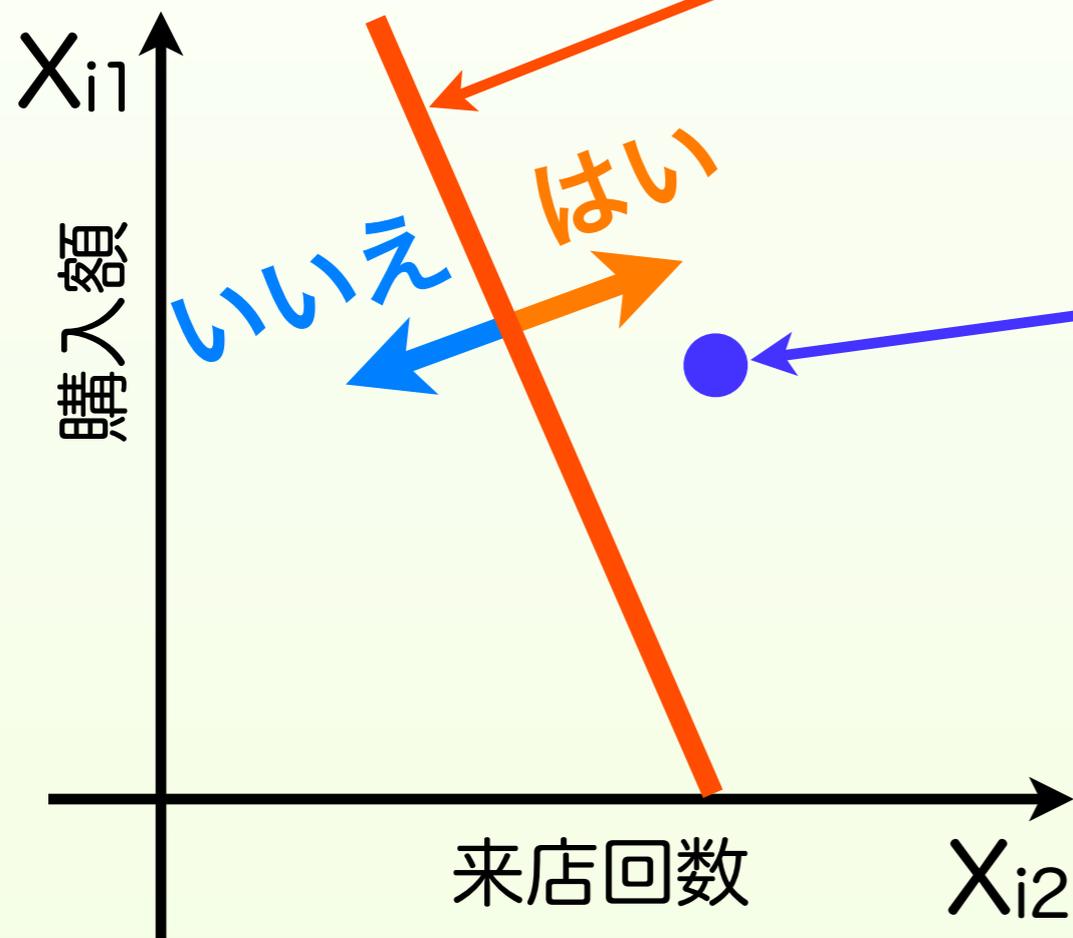
いいえ

例：購入額が5万円未満で2kmより近くに住んでいる会員はバーゲンに来店する

クラス分類

分類規則の例

識別境界面



会員5番は来店する
($X_{i1}=6$ 万, $X_{i2}=20$ 回)

識別境界面のどちらに対象があるかでクラスを決定

クラス分類

分類規則の主な学習手法

▶ Fisher判別分析

最も古くに考案された基本的な方法

▶ 決定木学習 (ID3, CARTなど)

結果の解釈が容易, 比較的高速

▶ サポートベクトルマシン

高次元で有利, 複雑な分類規則を学習可能

▶ k -近隣法

分類規則を作らず, 事例そのものを使って分類

▶ ベイズ推定

理論的な背景が堅固, 計算は大変, ノイズに強い

回帰分析とクラス分類の相違点

回帰分析

事例： (y_i, x_i)

説明変数 x_i の値に対応する被説明変数 y_i の値

被説明変数 y_i の値を予測する回帰曲線

クラス分類

事例： (c_i, x_i)

属性 x_i の値に対応するクラス c_i の値

クラス c_i の値を予測する分類規則

被説明変数は数値変数だがクラスはカテゴリ変数

数値変数：実数や整数などの数値をとる

カテゴリ(名義)変数：有限集合中のいずれかの値をとる

クラスタリング

クラスタリング Clustering

クラスタ分析 (Cluster Analysis) ととも呼ぶ

入力： 対象集合 x_1, x_2, \dots, x_N

対象 x は属性ベクトルで記述

任意の対象 x_1 と x_2 の似ている度合いを数値化した類似度

出力： クラスタ と呼ぶ次のような部分集合に分割

内的結合 (internal cohesion)

同じクラスタ内の対象は互いに似ている

外的分離 (external isolation)

違うクラスタにある対象は似ていない

クラスタリング

利用例

スーパーのポイント会員を，その購買の傾向が似ているクラスタに分割する

i 番目の会員 X_i を次のような属性ベクトルで表現

第1属性 X_{i1} : 先月の弁当・総菜の購入額
第2属性 X_{i2} : 先月の清涼飲料の購入額
⋮
第 m 属性 X_{im} : 先月の野菜類の購入額

例：会員3番 $x_3 = \langle 3000\text{円}, 1200\text{円}, \dots, 0\text{円} \rangle$

クラスタリング

見つかるクラスタの例

- ▶ クラスタ1：主に生鮮食料品を購入する顧客
- ▶ クラスタ2：主に中食製品を購入する顧客

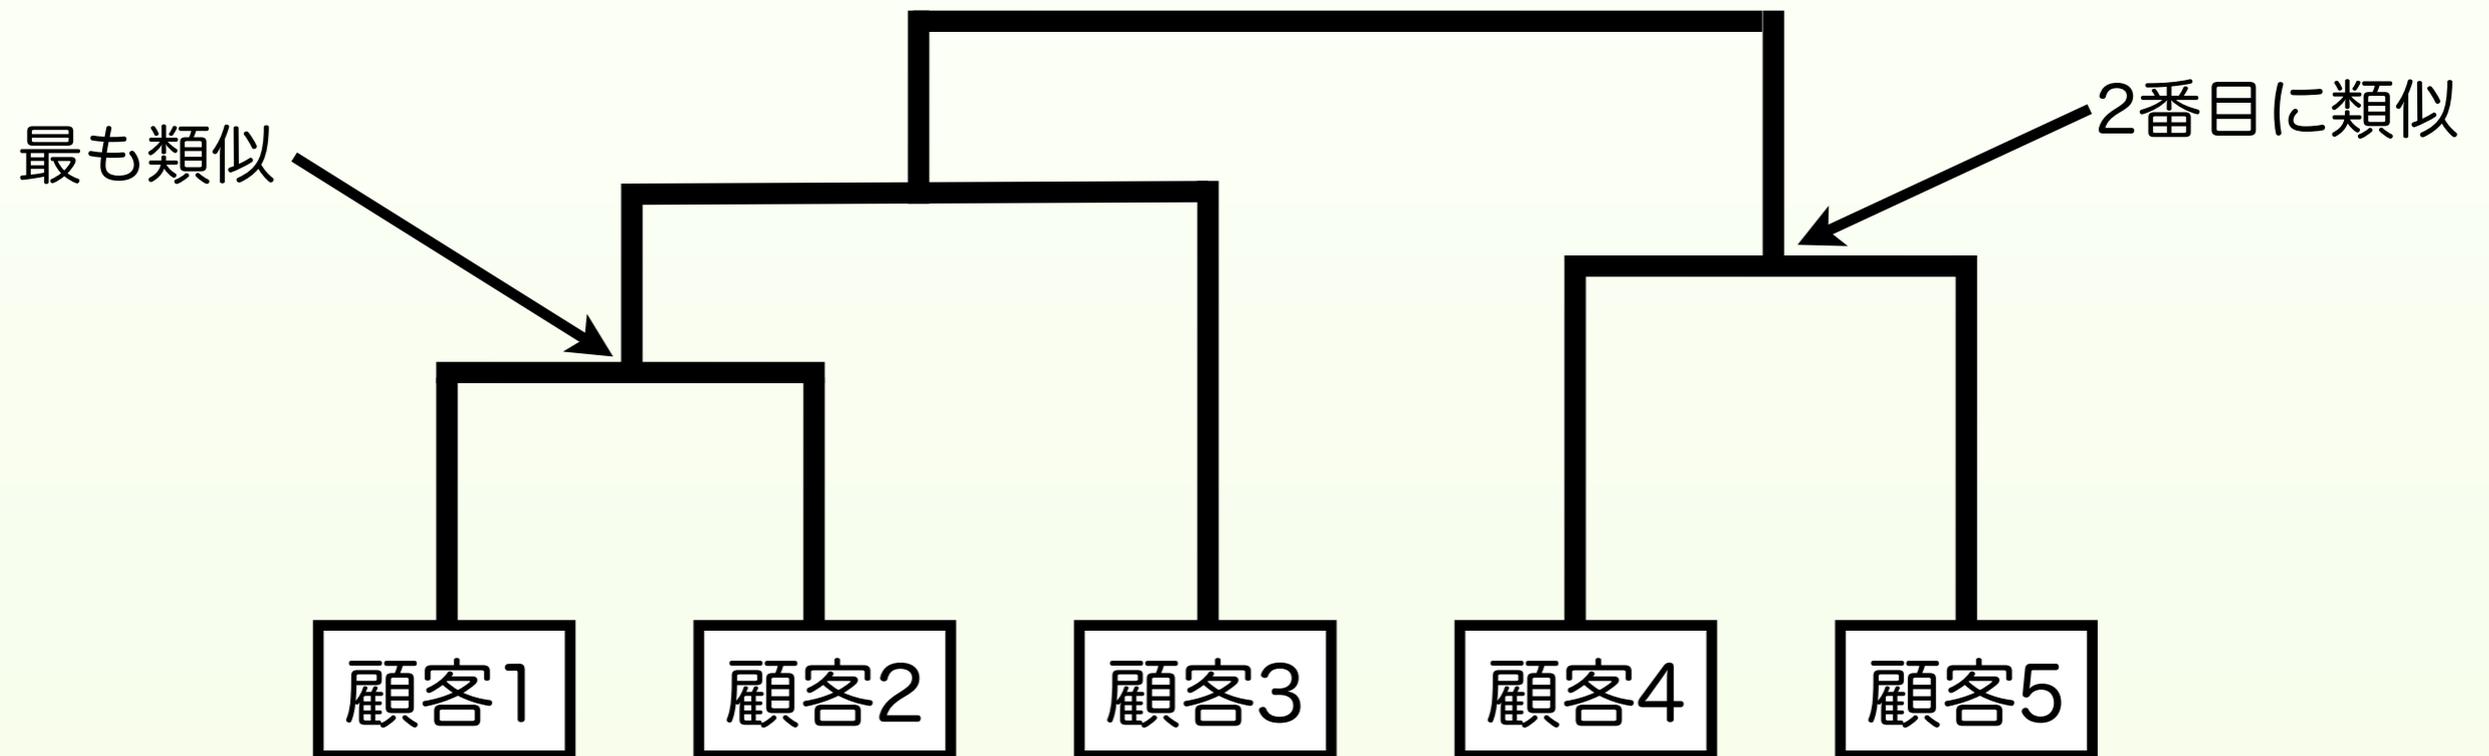
見つかったクラスタの利用例

- ▶ バーゲンなどでまとめ買いをするので、ダイレクトメールなどの販促策はクラスタ1の顧客を中心に
- ▶ その場で購入するものを決めるクラスタ2の顧客にはセットメニューによる客単価の向上などを中心に

クラスタリングは、データを大まかに要約し、その全体像を把握するための探索的手法

クラスタリング

階層的クラスタリング



最も似ている顧客から順にクラスタにまとめる

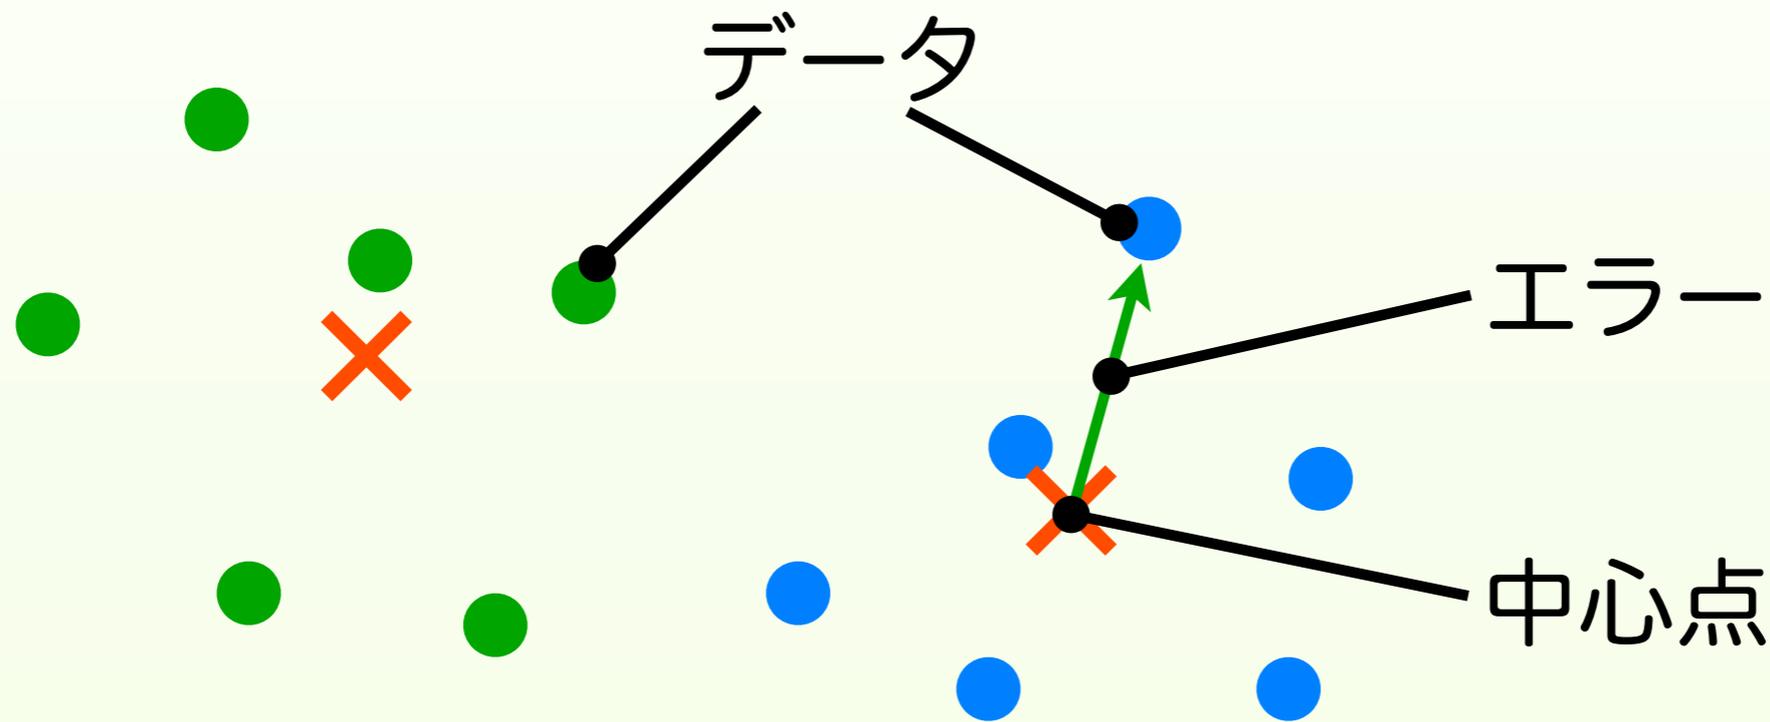
このような図を **デンドログラム**

代表的な手法：最短距離法，最長距離法，群平均法，
Ward法

クラスタリング

分割最適化クラスタリング (非階層的クラスタリング)

クラスタの良さの基準を最適化するように分割



K-means法 代表的な分割最適化手法

中心点とデータの間エラーが最小になるように中心点とデータの分割を決める

クラスタリング

最新の研究課題

▶ 大規模データへの対応

データの管理を工夫 (BIRCHアルゴリズム等)

▶ 時系列やグラフなどのクラスタリング

属性ベクトル以外で記述されたデータを扱う

▶ スペクトラルクラスタリング

類似度に基づく分割の新手法

▶ カーネルの利用

複雑な形状のクラスタの抽出など

▶ 半教師ありクラスタリング

分割を決めるときにヒントを利用

教師あり学習と教師なし学習

教師あり学習 回帰分析, クラス分類

データに加えて予測すべきものの正解も与える

対象 x_i に対応する, クラスの値 c_i や被説明変数の値 y_i が必要

教師信号 データと共に与えた, クラスや被説明変数の具体例

教師なし学習 クラスタリング, 相関ルール

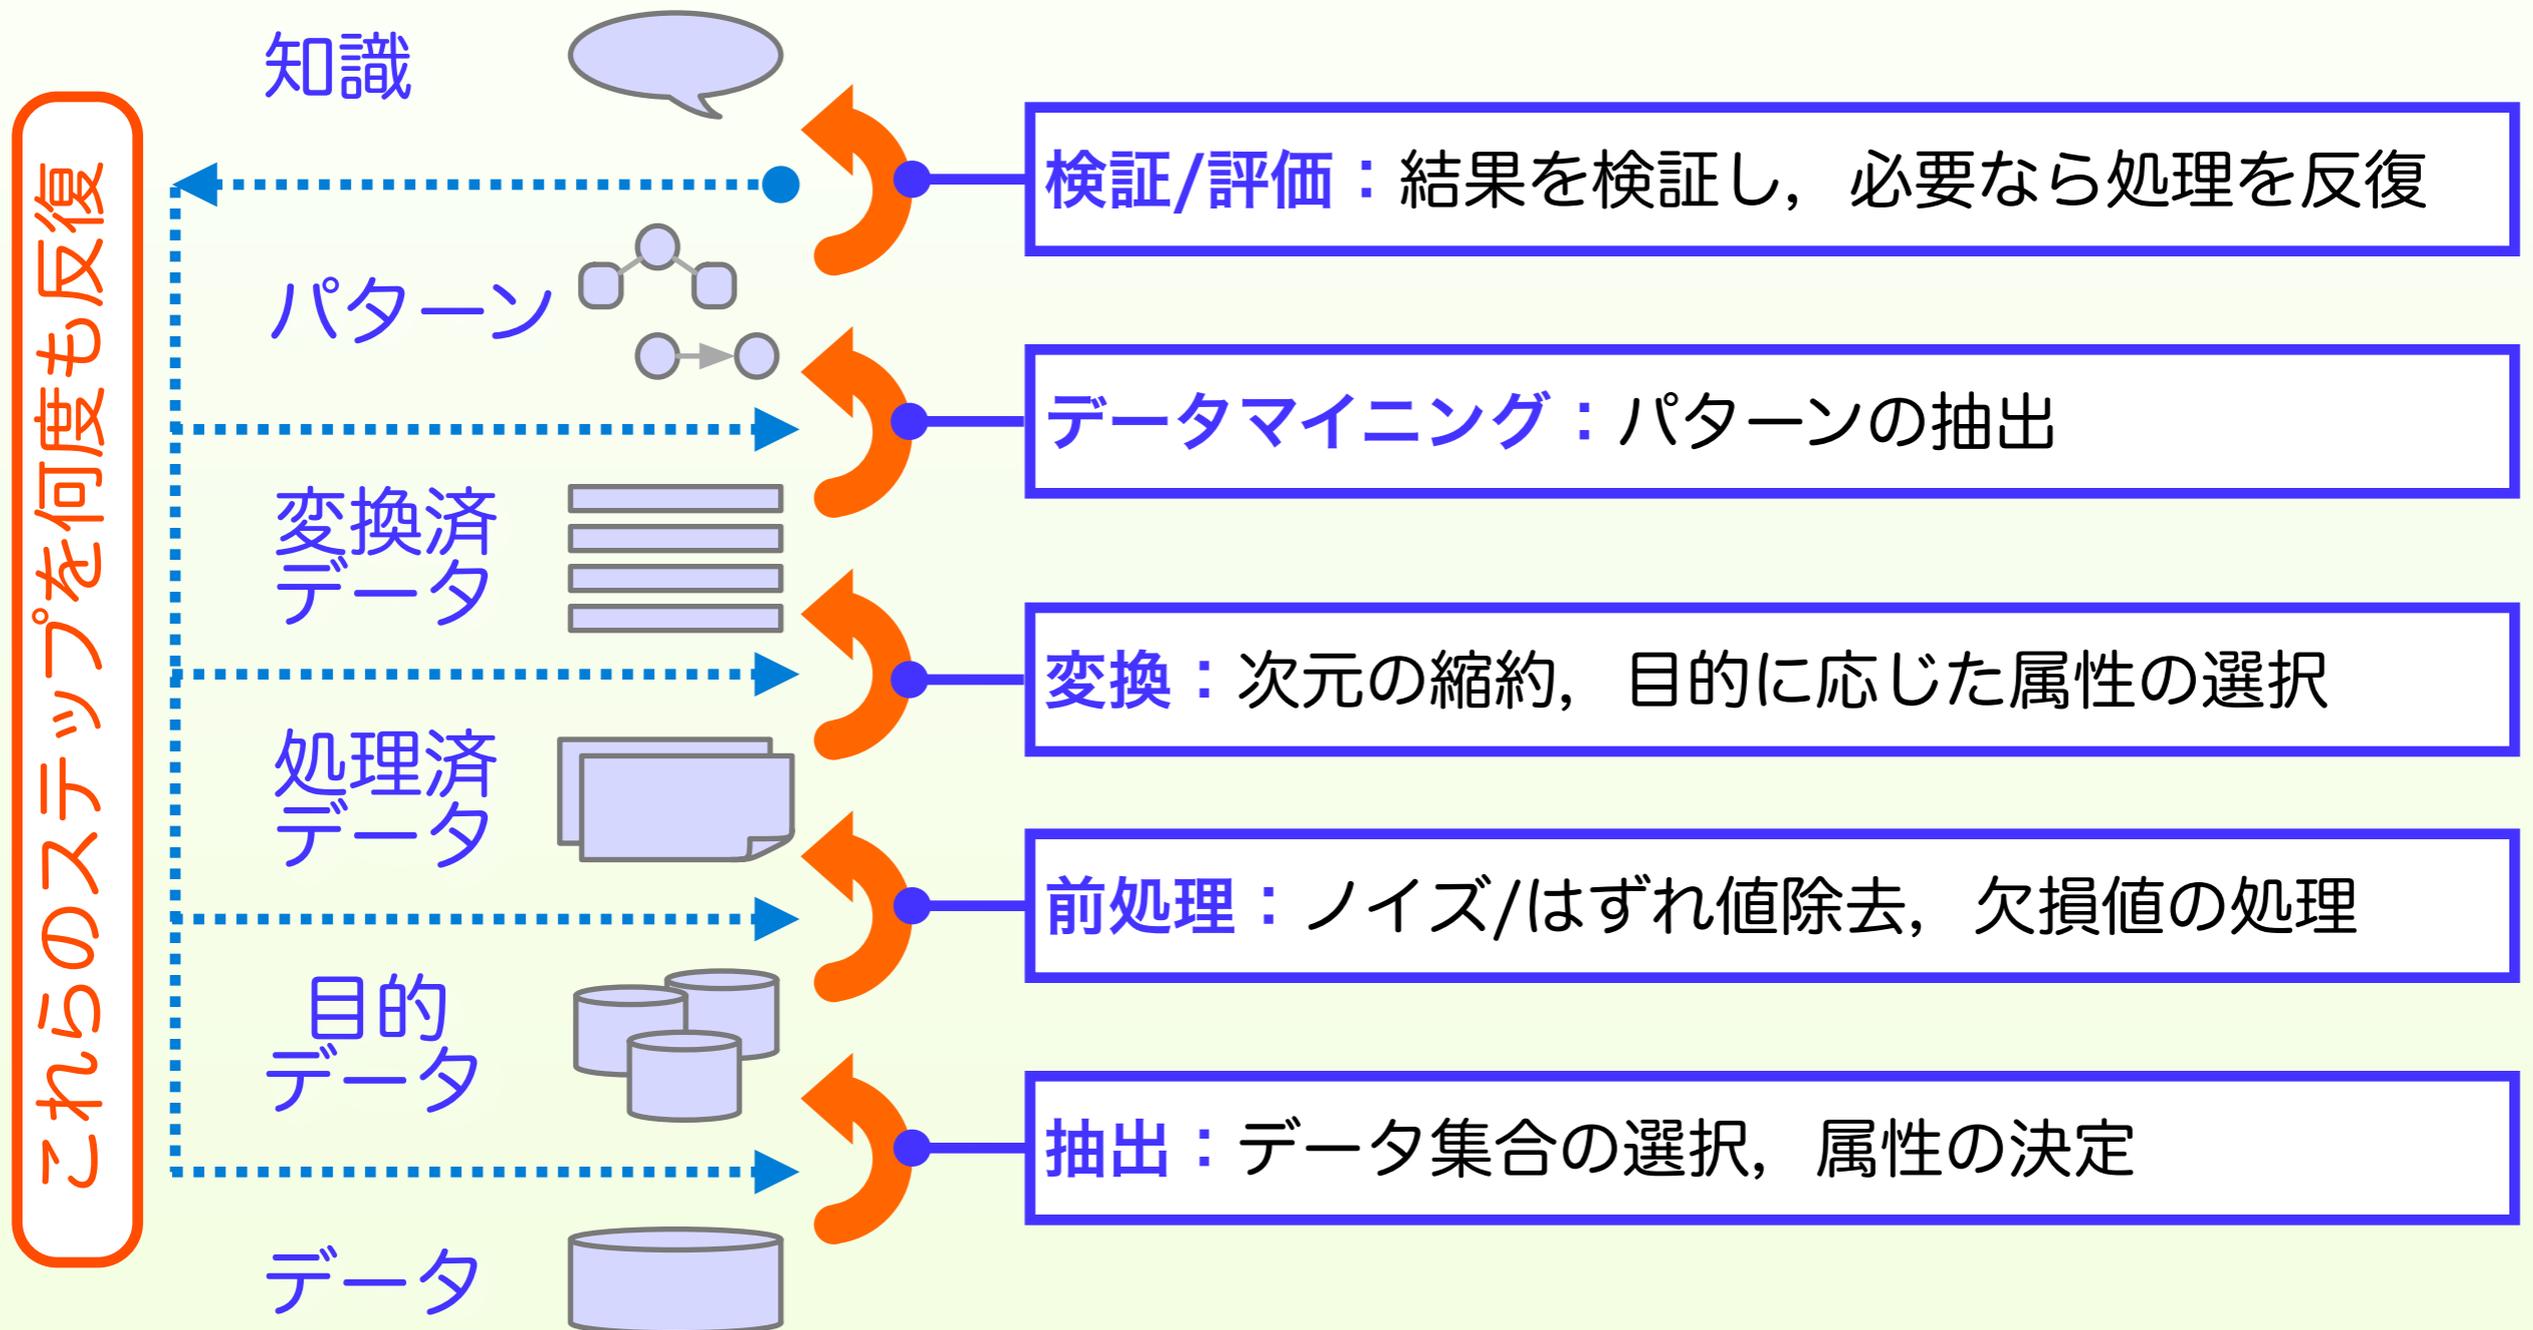
データだけを与える

分類する対象 x_i やトランザクション T_i のデータだけ

知識発見の過程

知識発見(=広義のデータマイニング)

KDD Process: Knowledge Discovery and Data Mining



知識発見の過程

抽出

例：スーパーマーケットの場合

データ集合の選択 どのデータベースを使うのか
顧客との取引(POS)データ, ポイント会員登録データ,
天候のデータ, 周辺の地図データ ……

属性の決定 データベースのどの項目を使うのか
クラス分類の例題で, 自宅までの距離は関係ありそうだが,
電話番号はあまり関係ないだろう

あとでデータの削減をするので, この段階では多めに
データを保持しておく方がよい

知識発見の過程

前処理

ノイズ/はずれ値の除去 非現実的な値の除去

計測の誤り：計測機器の誤差

誤入力：位の誤り，データの変換ミス

意図的な誤り：年齢のサバよみ，プライバシー問題

欠損値の処理 不足したデータの補完

欠損値：入力されていないデータ

- ▶ 同じ項目の，入力済みの値の平均値等を使う
- ▶ データ解析に影響を及ぼさない値にする

知識発見の過程

変換

次元削減 主成分分析

データを関数で変換して少ない属性数で表現

目的に応じた属性の選択 ラッパー法とフィルター法

問題の解決に関連がありそうな属性以外は削除

次元の呪い

属性が多すぎると適切なパターンを発見できなくなる

- ▶ データの分布が均一に近づき、データ間の類似の度合いが均一になる
- ▶ パターンがあるかどうかを、少ないデータ量では検証できなくなる

知識発見の過程

検証/評価 結果を検証し，必要なら処理を反復

データ，前処理，属性，データマイニング手法の適切さを，解析している問題についての知識を使って検証

例：相関ルール抽出

{レトルトカレー} ⇒ {洗濯用洗剤}

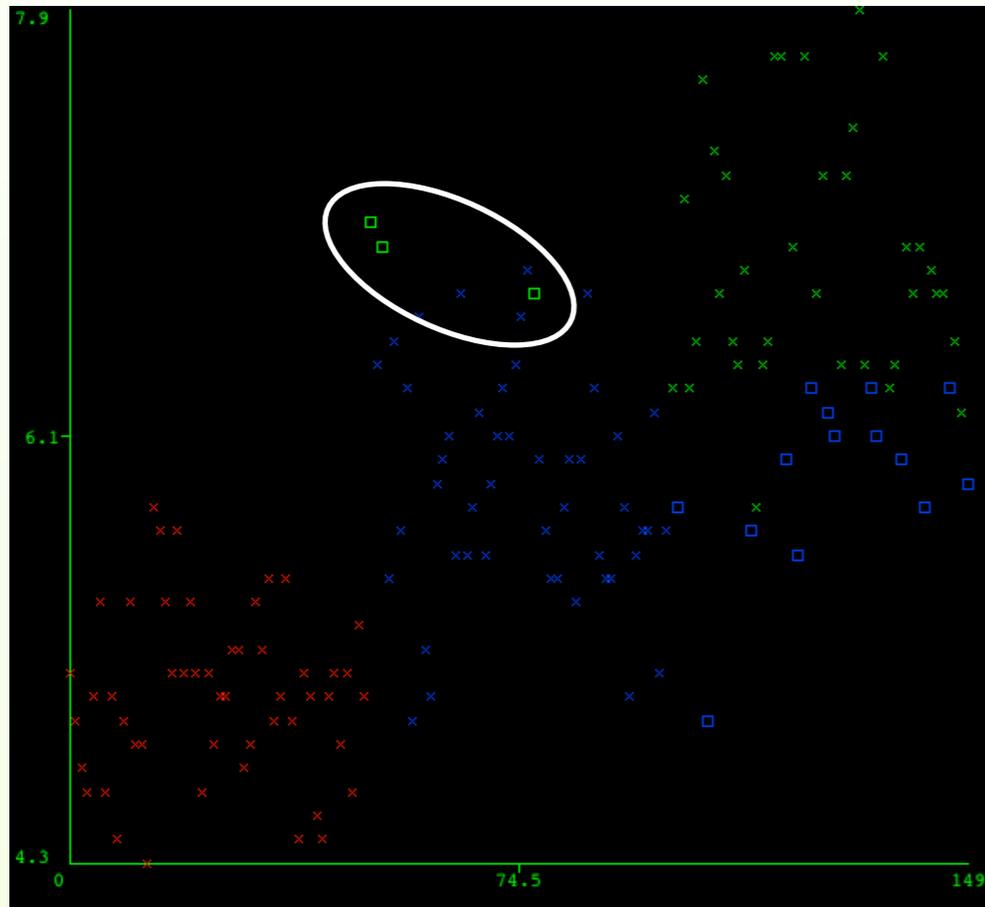
× カレーを食べると服が汚れるから

○ たまたま，カレーと洗剤を同じ日に特売した

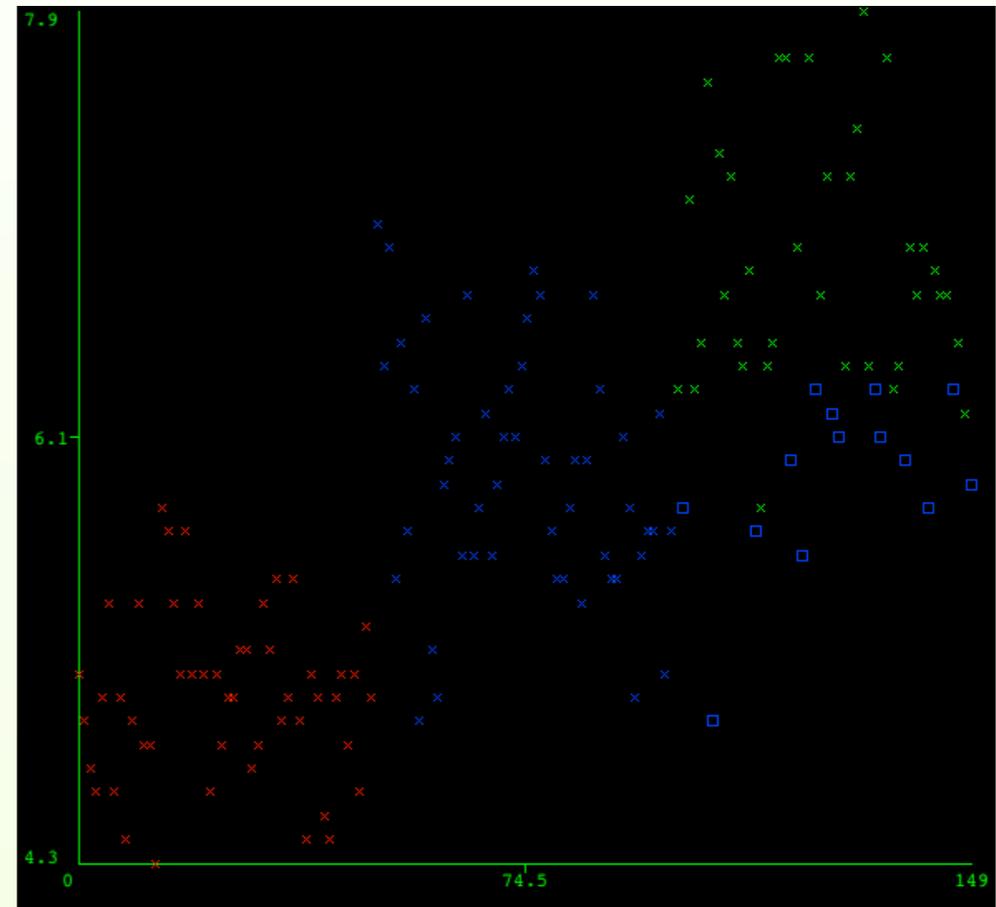
見つけた知識の合理性は必ず検証

知識発見の過程

例：データマイニング手法の「クセ」に由来する場合
同じデータでも手法が違くと……



K-means法



混合ガウスモデル+EMアルゴリズム

「似ている」ことの基準が違う

データマイニング手法の解析の前提を理解すること

まとめ

▶ データマイニングとは？

整理されていデータから， 予期されていないが，
再利用可能な知識を見つける

▶ 代表的なデータマイニング手法

相関ルール：X が起きるときには Y も起きやすい

回帰分析：X の属性から， 数値変数 Y を予測

クラス分類：X の属性から， そのクラス C を予測

クラスタリング：似ているものどうしをまとめる

▶ 知識発見の過程

見つけた知識は， 無条件に受け入れずに必ず検証
し， より妥当な知識を見つけるよう試行錯誤

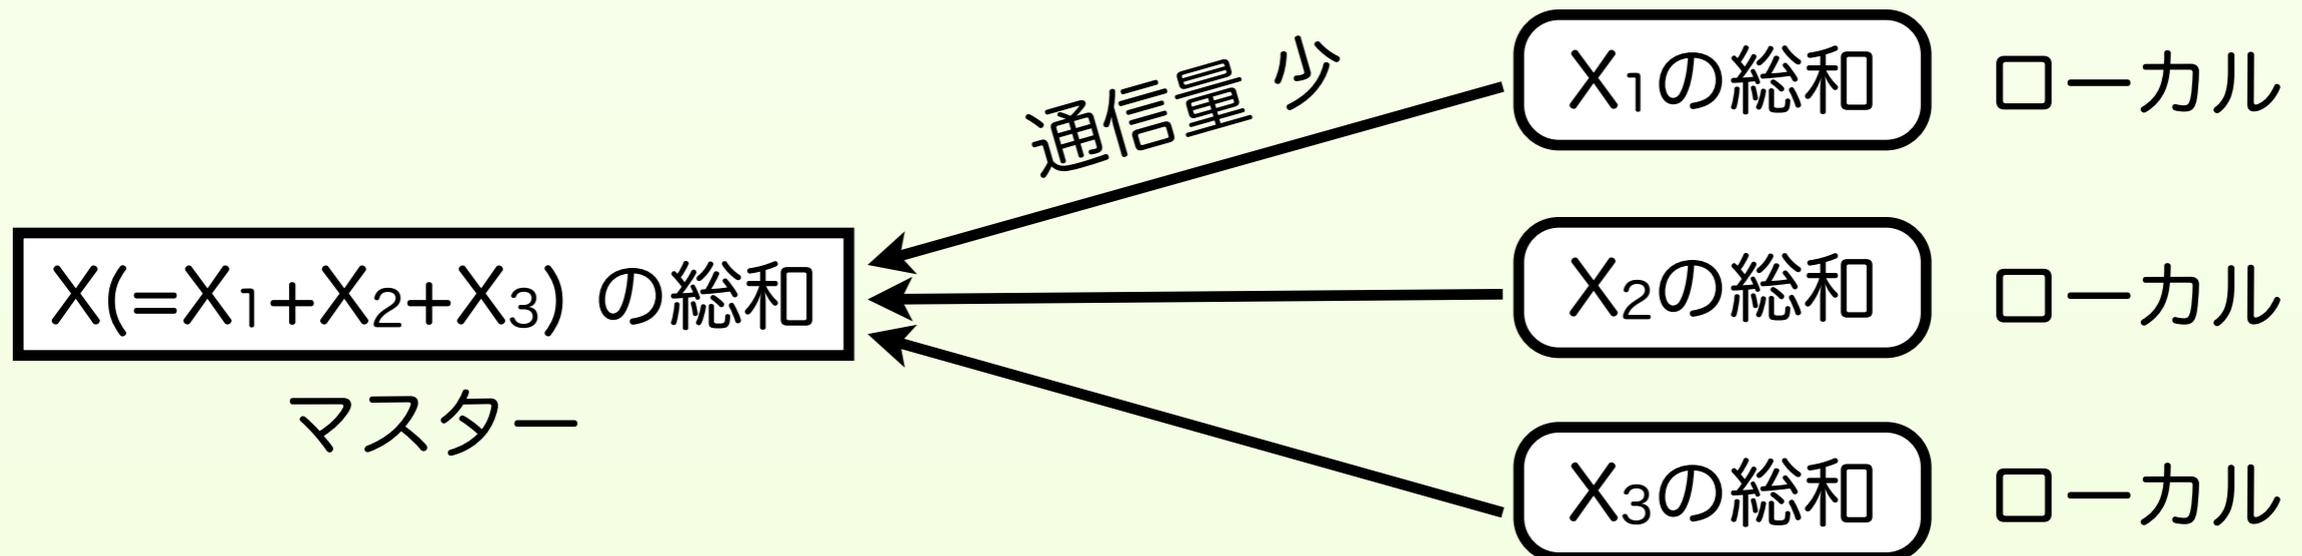
分散データマイニング

- ▶ 複数の計算機を利用して計算を高速化
- ▶ データが地理的に離れた場所 (支社・部署ごと) で保持されている



分散データマイニング

- ▶ データ全体を分割してローカル計算機で保持
- ▶ 担当データの**主な計算はローカル計算機内**で実行
- ▶ **ローカル計算機間の通信量は少なく保つ**




プライバシー保護データマイニング

一見，無関係な情報も……

プライバシー侵害の問題

性別 + 誕生日 + 5桁郵便番号 → 87%の米国人は一意に特定可能

個々のデータ
プライバシー



全体の傾向
プライバシー

個々のデータは秘密のままマイニング
プライバシー保護データマイニング

水平分割型

垂直分割型

	特徴1	特徴2	特徴3
Aさん			
Bさん			
Cさん			

	特徴1	特徴2	特徴3
Aさん			
Bさん			
Cさん			

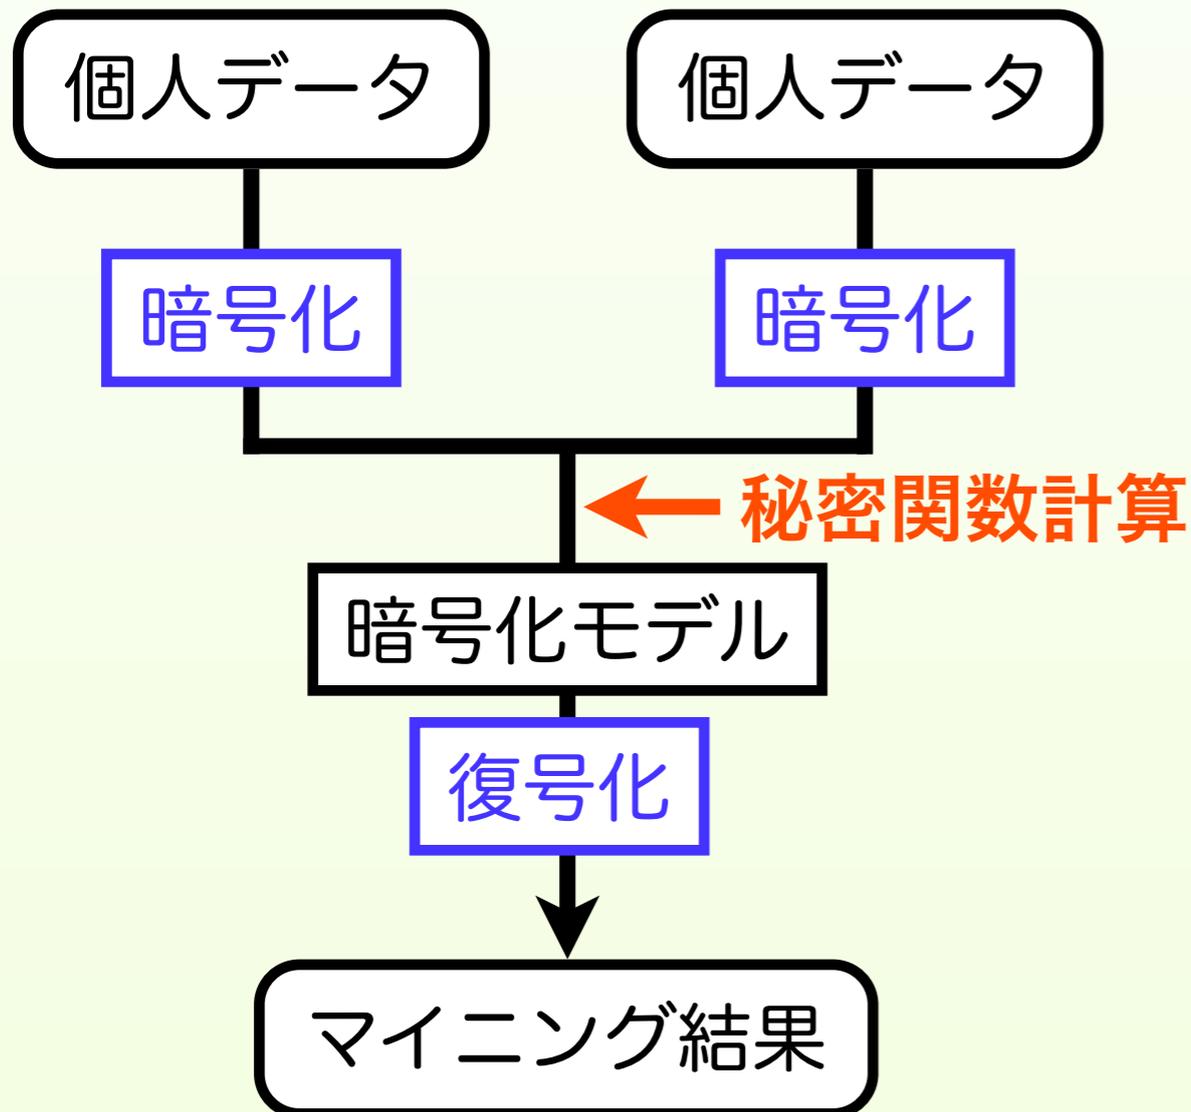
個人間でデータは秘密

各人の異なる特徴が秘密

プライバシー保護データマイニング

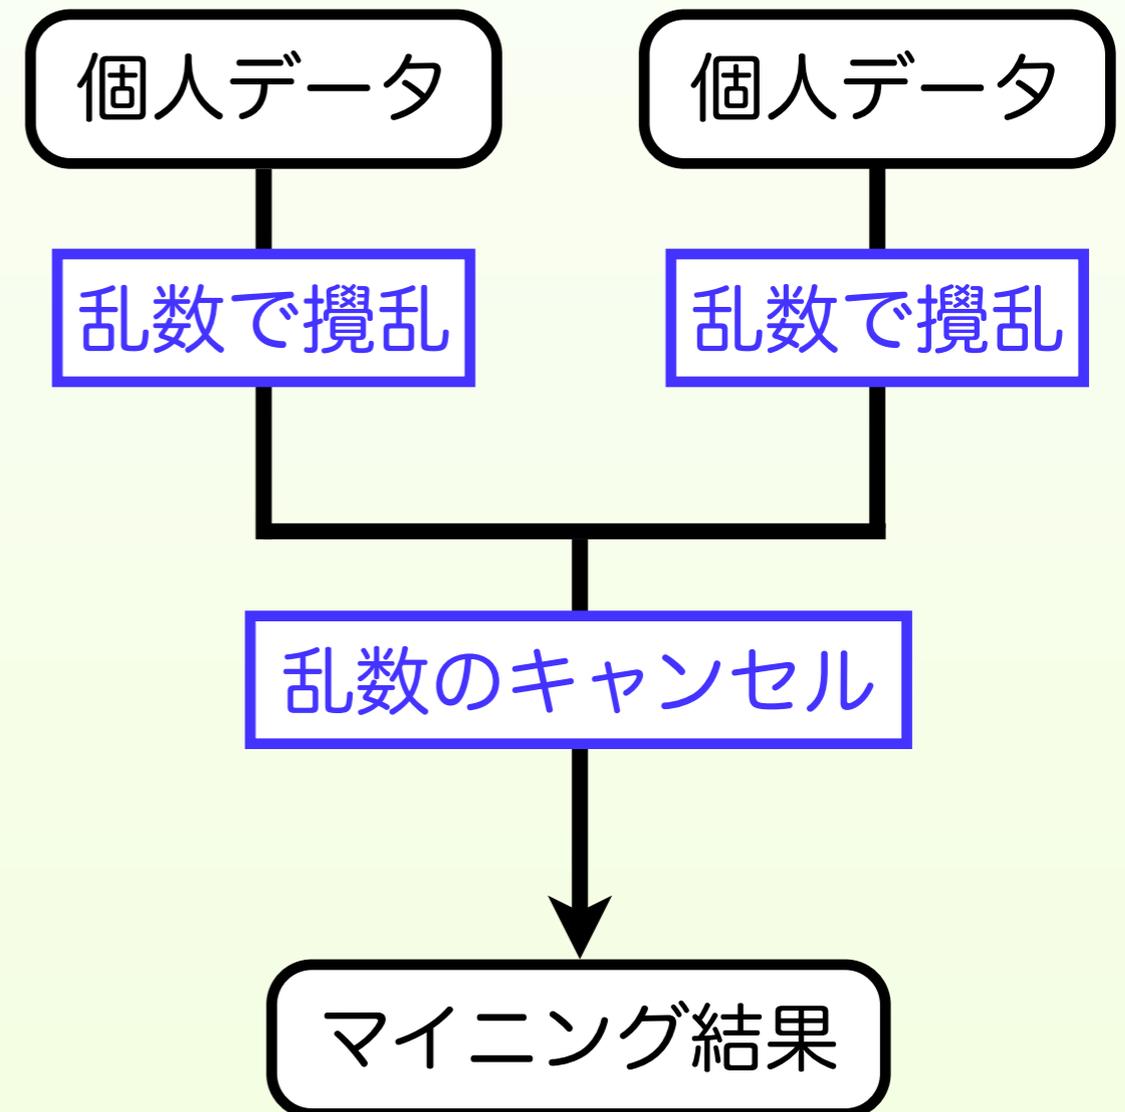
秘密関数計算

データを暗号化し，暗号化したまま秘密に結果を計算



ランダム化

計算過程で，互いに打ち消し合うような乱数で元データを攪乱



時系列データ

時系列データ：時間軸上で反復的に計測された値の系列

例：株式市場分析，経済・販売予測，負荷予測，生産・品質管理，気象・地質データ，科学・技術実験，医療

処理の種類

▶ 類似度検索，索引付け

クエリ時系列 Q と類似度に基づき，時系列DBから類似した系列を見つける

▶ クラスタリング

類似度を元に，時系列DB中の時系列を類似したグループに分割

▶ クラス分類

ラベルのない時系列 Q を，事前に定めたクラスに分類

▶ セグメンテーション，トレンド分析

長さ N の時系列 Q を， $K \ll N$ 個の部分に分ける

Webマイニング

Webマイニング : Webの文書やサービスから情報を自動的に発見したり抽出したりするためのデータマイニング技術の利用

▶ Web内容マイニング (Web content mining)

Webの内容/データ/文書から有用な情報を発見

自然言語処理や情報検索の技術がほぼそのまま適用される

▶ Web構造マイニング (Web structure mining)

Webのリンク構造に内在するモデルの発見

リンクの参照関係から, Webに反映された社会コミュニティの発見

▶ Web利用マイニング (Web usage mining)

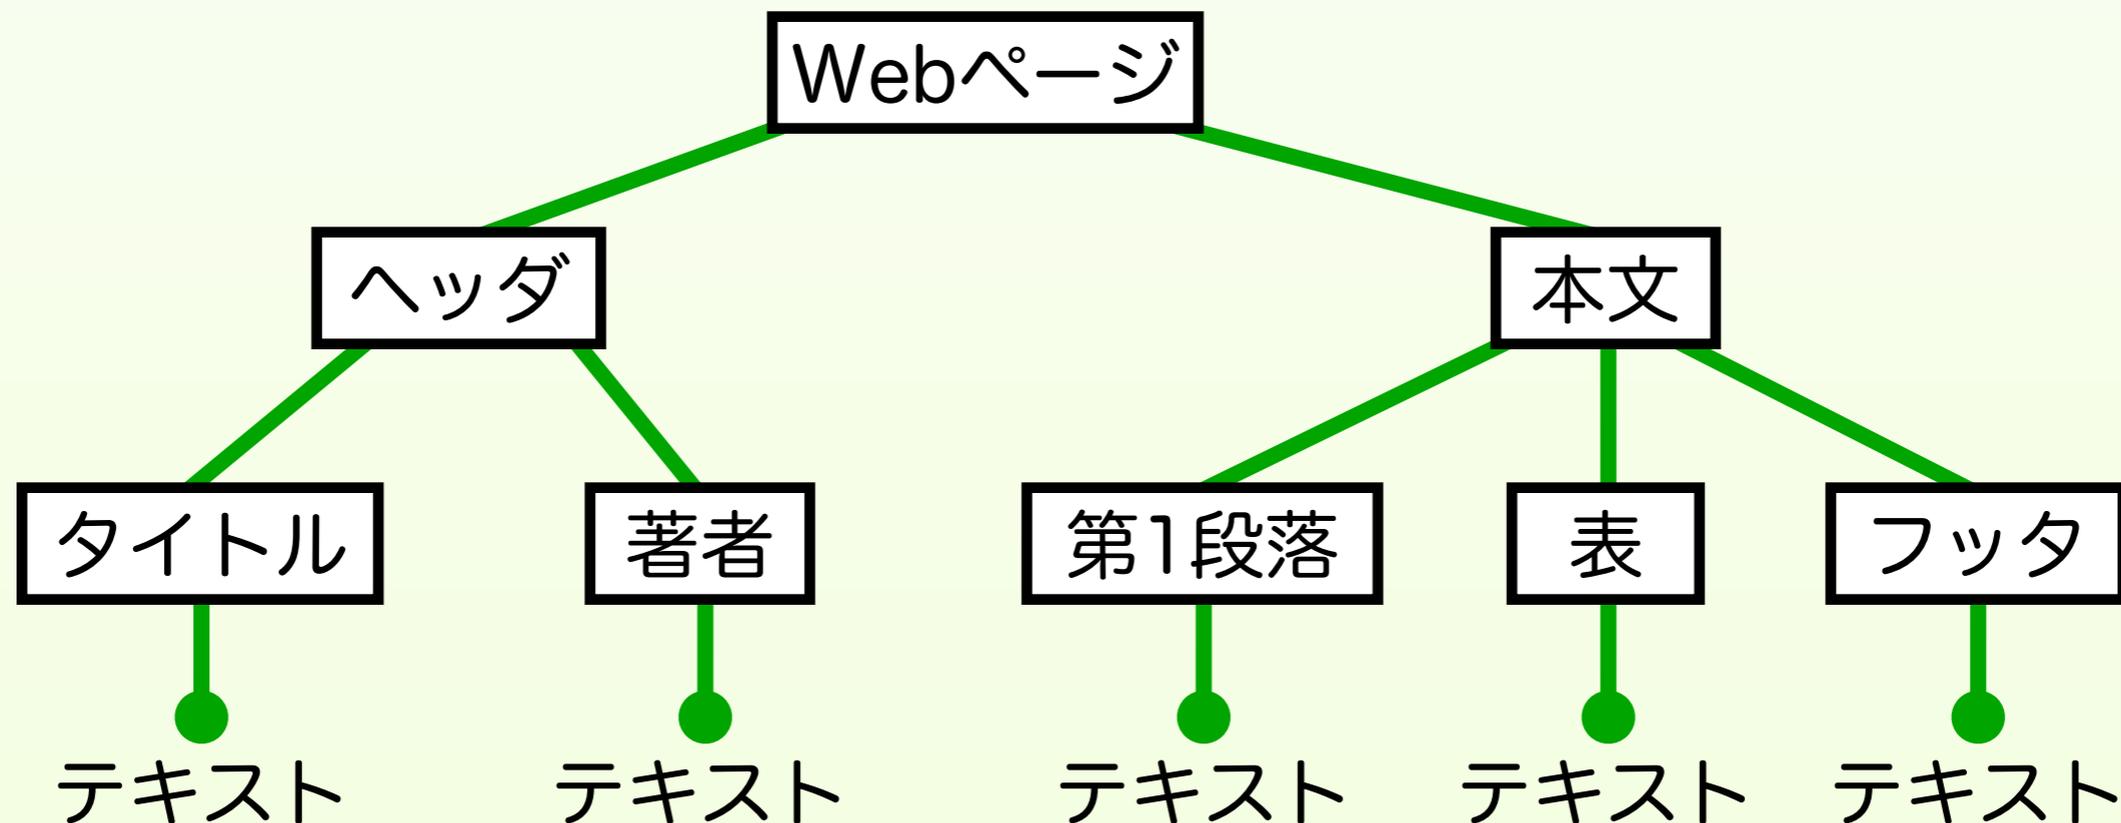
Web閲覧者のセッションや行動で生成されたデータの理解

Webの閲覧ログを利用した利用者行動の予測

半構造データ

半構造データ：構造のないテキストを構造化された枠組みに格納したもの

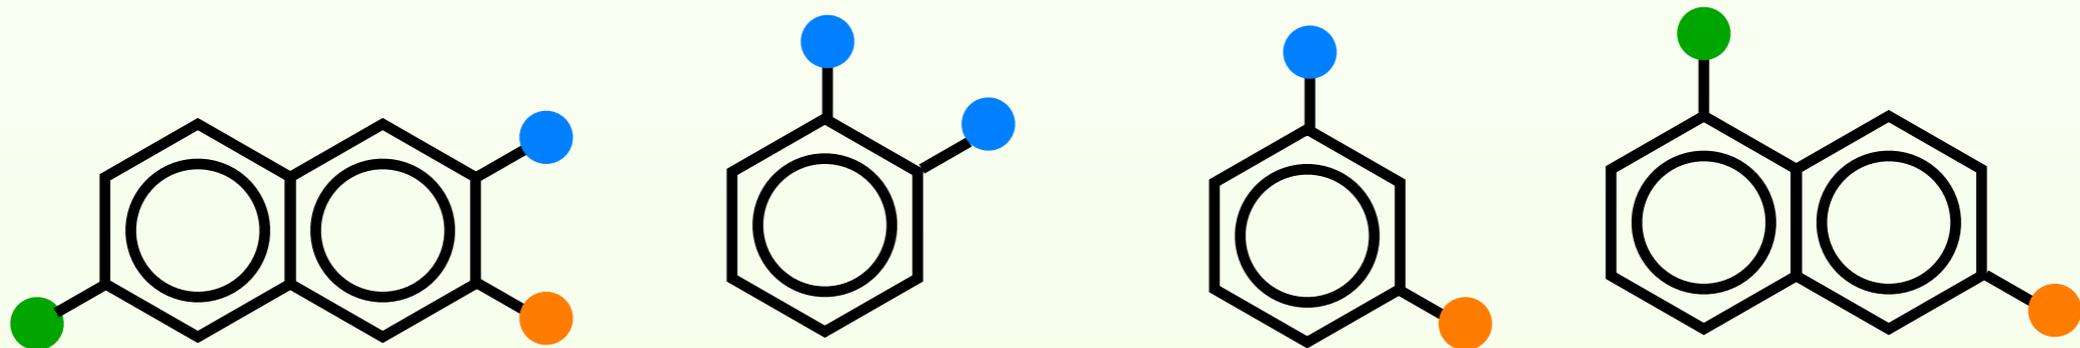
例：Webページ, XMLデータ (タグで表された構造とテキスト)
定型化されたテキスト (タイトルやアブストなどの構造にテキストが格納されている)



グラフマイニング

グラフマイニング：グラフで表現されたデータからのマイニング

例：回路，化合物，タンパク構造，生物学的ネットワーク，社会ネットワーク，Web，ワークフロー，XMLデータ



化合物のグラフ：結合が辺，分子や基がノード

このグラフの中から，頻出する部分グラフを抽出

➡ 特定の性質・薬効をもつパターンに相当

- ▶ グラフは同一性の判定が難しいので特殊な索引付け技術が必要
- ▶ カーネルを使う方法もある

参考文献

- ▶ 朱鷺の杜Wiki : <http://ibisforest.org/index.php?FrontPage>
データマイニング・機械学習の情報をまとめています
- ▶ C.M.Bishop “Pattern Recognition and Machine Learning”
Springer (2006)
日本語版「パターン認識と機械学習 上下 - ベイズ理論による統計的予測」シュプリンガー・ジャパン (2007-2008)
<http://ibisforest.org/index.php?PRML>
最近の機械学習手法を俯瞰できる本
- ▶ 元田 浩 他「データマイニングの基礎」オーム社 (2006)
機械学習手法の基礎とルールの検証
- ▶ J.Han and M.Kamber “Data Mining: Concepts and Techniques”second edition, Morgan Kaufmann (2006)
多種多様な技法を網羅した本