インターネット計測とデータ解析 第 10 回

長 健二朗

2015 年 6 月 22 日

前回のおさらい

第 9 回 トポロジーとグラフ (6/15)

- 経路制御
- グラフ理論
- 最短経路探索
- 演習: 最短経路探索

今日のテーマ

第 10 回 異常検出と機械学習

- 異常検出
- 機械学習
- スパム判定とベイズ理論
- 演習: 単純ベイズ分類器

異常とは

- トラフィック異常
- 経路異常、到達性異常
- DNS 異常
- 不正侵入
- CPU 負荷異常

異常原因

- アクセス集中
- 攻撃: DoS、ウィルス/ワーム
- 障害: 機器故障、回線故障、事故、停電
- メンテナンス

異常検出

- サービスの機能低下や停止による損失の回避と低減
- 個別項目の監視: 閾値を越えるとアラート
  - パッシブ
  - アクティブ
- 異常パターン検出:
  - 既知の異常とパターンマッチング
  - IDS: Intrusion Detection System
  - 未知の異常は検出できない
  - パターンを常に更新する必要
- 統計的手法による異常検出
  - 平常時からのずれを検出
  - 一般に「平常」の学習が必要

異常への対応

- 異常を管理者に知らせる
  - 警報通知など
- 異常タイプの識別
  - 運用者が異常原因を把握するための情報提示
  - 特に統計的手法の場合、異常の原因が分かり難い
- 対応の自動化
  - フィルタリングルールの自動生成、サービス切替えなど

異常の具体例

- Flash Crowd
  - サービスへのアクセス集中 (ニュース、イベント、etc)
- DoS/DDoS
  - 特定のホストにトラフィックを集中する攻撃
  - ゾンビ PC が使われる
- scan
  - 多くの場合、脆弱性を持つホストを発見する目的
- worm/virus
  - SQL Slammer, Code Red など多数の事例
- 経路ハイジャック
  - 他人の経路を広告 (多くは設定ミス)

YouTube 接続のハイジャック

- 2008 年 2 月 24 日 世界中の YouTube への接続がパキスタンにリダイレクトされた事件
- 原因
  - パキスタン政府の要請で、Pakistan Telecom が国内から YouTube へ接続できないよう、BGP に YouTube の偽の経路を広告
  - 大手 ISP PCCW が、その経路を外部に伝搬
  - 結果、世界中の YouTube への接続が偽経路によってパキスタンにリダイレクトされた

参考資料:
`http://www.renesys.com/blog/2008/02/pakistan_hijacks_youtube_1.shtml`

台湾沖地震による通信障害の発生

- 2006 年 12 月 26 日台湾南西沖で M7.1 の地震発生
- 海底ケーブルが損傷、アジア向けの通信に障害が発生
- インドネシアでは一時国際向けの通信容量が 20%以下に
- 各 ISP は迂回経路でサービス復旧

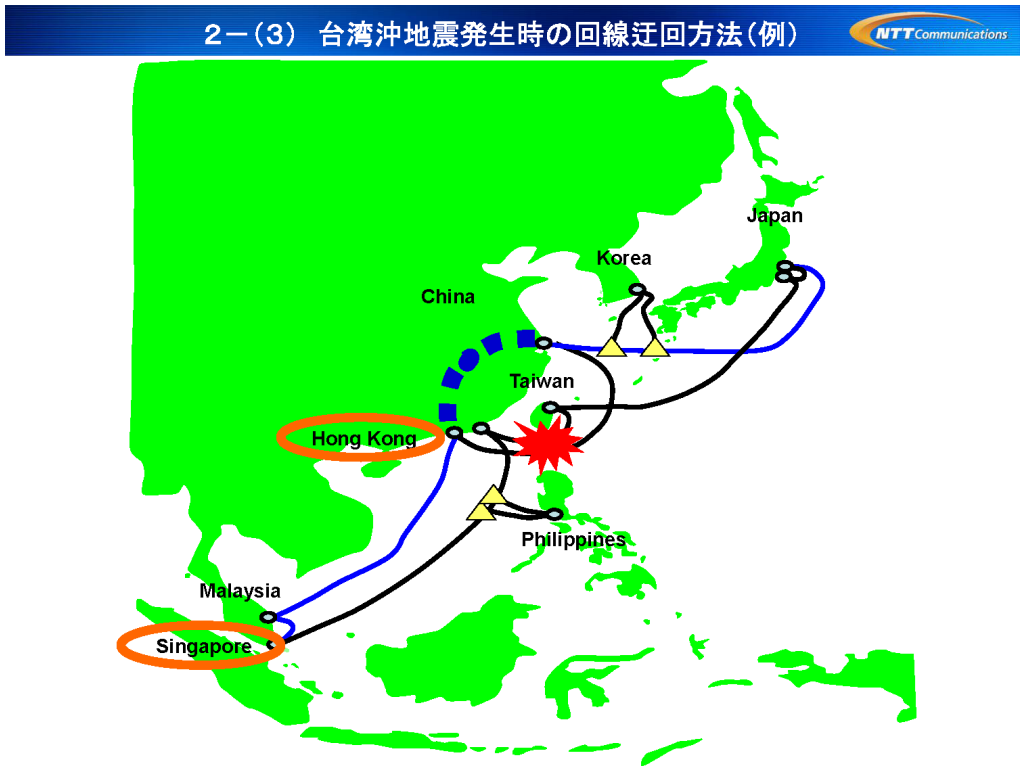

出典: JANOG26 海底ケーブル、構築と運用の深イイ話

http://www.janog.gr.jp/meeting/janog26/doc/post-cable.pdf

Great East Japan Earthquake

- a number of foreshocks and hundreds of aftershocks
- affected significant part of communications infrastructure

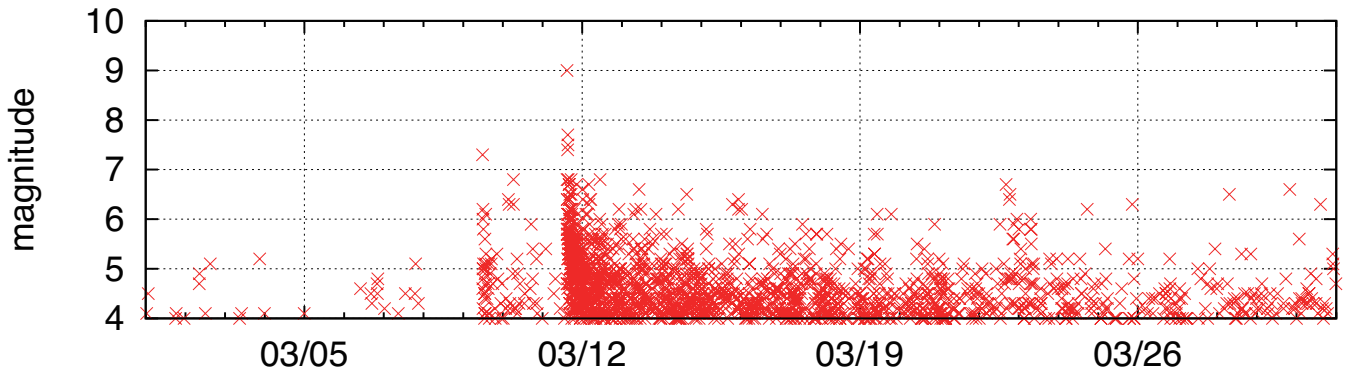

Earthquakes larger than Magnitude 4 in Japan for March 2011

Traffic at IX

- less impact in Osaka on March 11

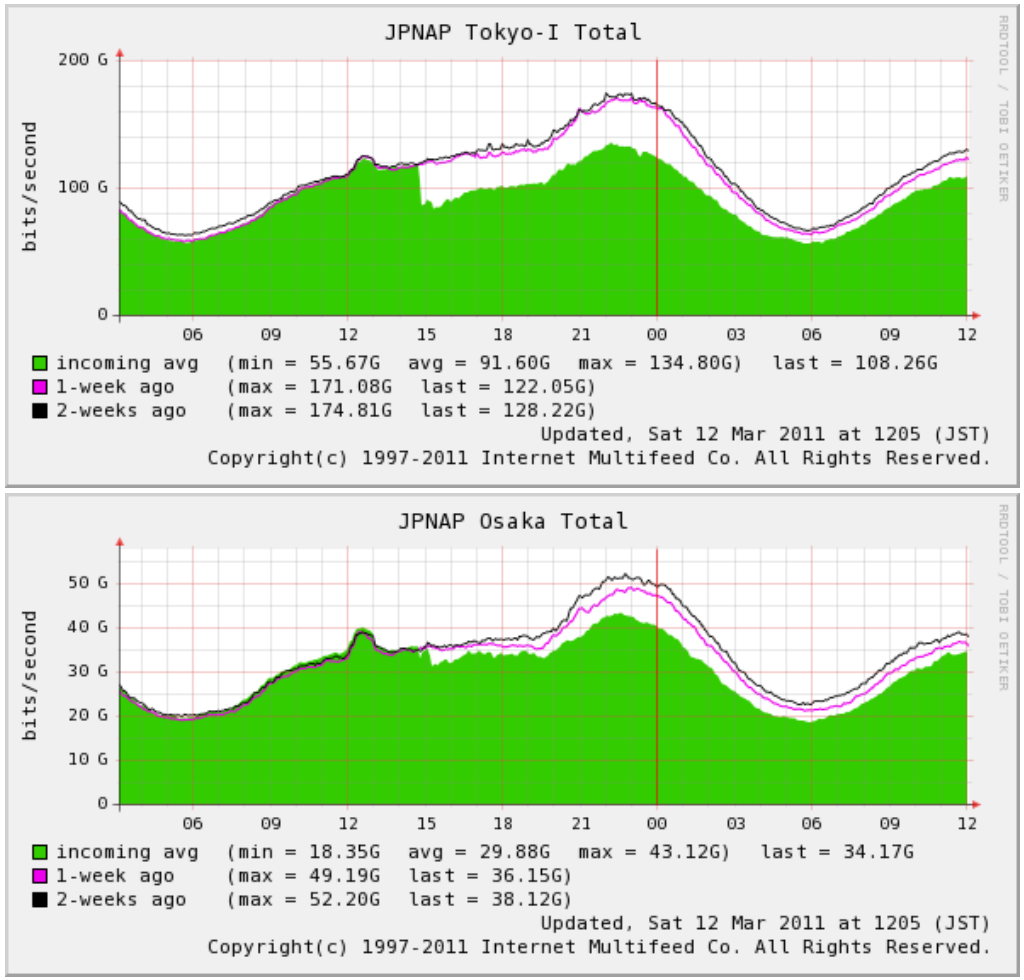

Traffic at JPNAP Tokyo1 (top) and Osaka (bottom) on 3.11

Summary of events at IIJ

March 11, Friday:

- M9.0 quake hit at 14:46, the tsunami first reached coastline in 20 min
- Sendai DC lost external power, switched to in-house power generator within 2 min
- 2 redundant backbone links to Sendai DC down, and lost connectivity to 6 prefectures in Tohoku
- From 23:00, undersea cables started failing. Some of the US links down, links to Asia down

March 12, Saturday:

- One backbone link to Sendai restored at about 6:00
- Sendai DC restored external power at around 11:30
- One of the damaged US-links recovered around 21:00

March 13, Sunday:

- The other backbone link to Sendai was up at around 21:30
- Most of the backbone connectivity was restored by then

March 14, Monday:

- Business started. Service restoration and rescue activities started.

Residential Broadband Traffic

- severe damage and gradual recovery in Miyagi
- but limited impact to the total traffic in Japan

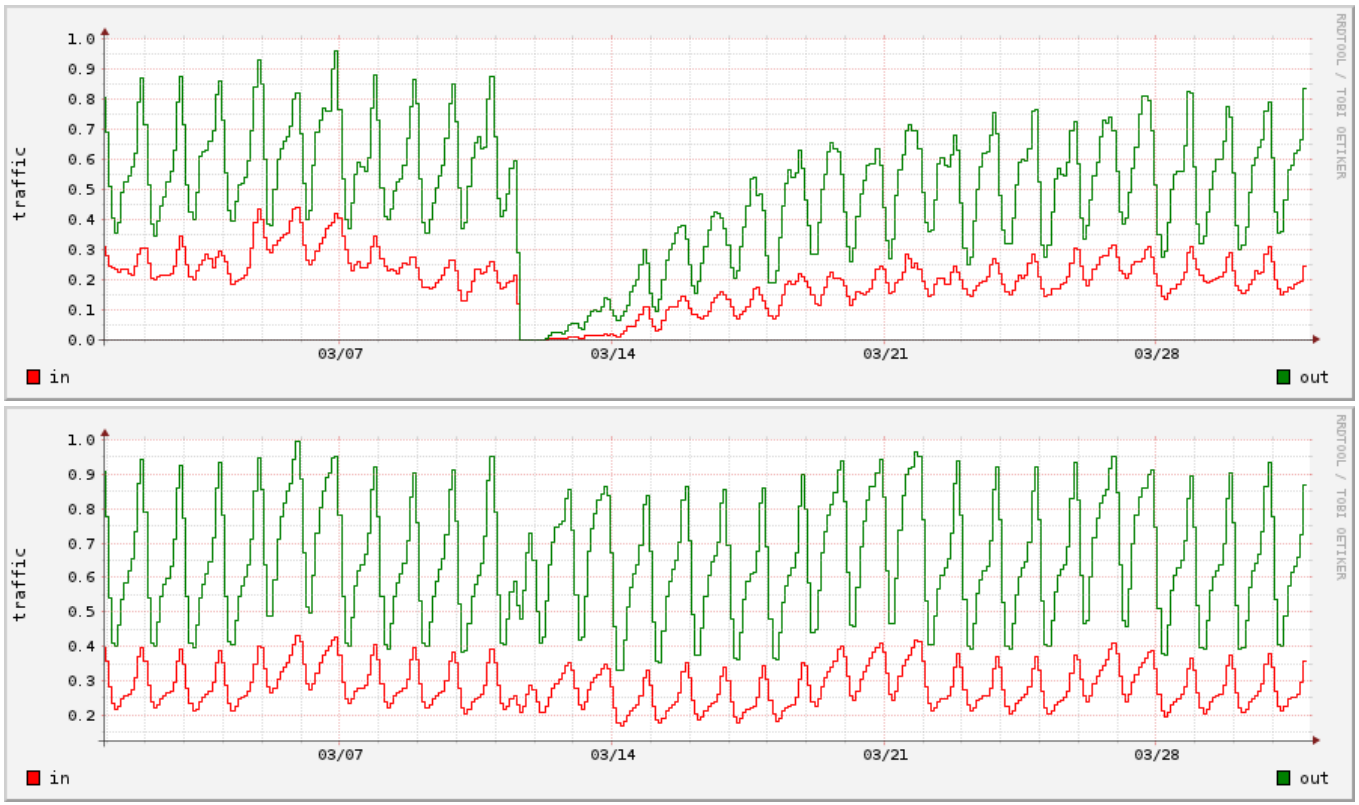

Residential traffic for March 2011, Miyagi prefecture (top) and nationwide (bottom)

JP-US links

- redundancy and over-provisioning worked

Traffic on 3 JP-US links for March 2011, damaged (top) not-damaged (middle) and rerouted (bottom)

統計的手法による異常検出

- 時系列
- 相関
- 主成分分析
- クラスタリング
- エントロピー

機械学習

- データから知識やルールを自動獲得
- 経験によって賢くなっていくアルゴリズム
  - 人間が知識やルールを明示的に与える方法の限界
- 学習の方法
  - 教師あり学習
    - 訓練データを用いて事前にトレーニングを行う
    - 分類や回帰分析など
  - 教師なし学習
    - 自動的に分類やパターン抽出を行うもの
    - トレーニングが不要
    - クラスター分析、主成分分析など

機械学習の応用

- 広い応用分野
  - 特徴ベクトルの作成: 入力データから特徴を抽出し特徴ベクトルを生成
  - 特徴抽出: 分野依存
    - 画像認識、手書き文字認識、顔認識、行動履歴、センサーデータなど
    - 従来は職人技にたよっていた部分
  - 特徴に対する学習、推論
    - 特徴ベクトルになれば、分野に依存せず、機械学習手法が適用可能
- 最近の傾向: 特徴抽出も機械学習で自動化: 表現学習
  - 雑多なデータから本質的な情報の抽出 (PCA など)
  - ディープラーニング

教師あり学習による分類器

- 単純パーセプトロン
  - 線形２値分類器
  - サポートベクタマシン、ニューラルネットワークなどに使われる
- 単純ベイズ分類器
  - 確率モデルによる分類器
  - スパム判定に広く使われている

単純パーセプトロン

- 神経細胞 (ニューロン) をモデル化
  - 線形識別器による２値分類
  - 複数入力に重み付けして、1/0 の出力判定を行う
- 線形分離問題: 入力値の空間を２つに分ける超平面を求める
  - 入力が線形分離可能であれば収束が保証できる
- 学習によって重みを調整
  - 判定結果が正しくなければ、各重みを微調整
- サポートベクタマシン (SVM): 線形識別手法のひとつ
  - マージン最大化アルゴリズム
  - カーネルトリック: 非線形入力を線形特徴空間へ写像する手法

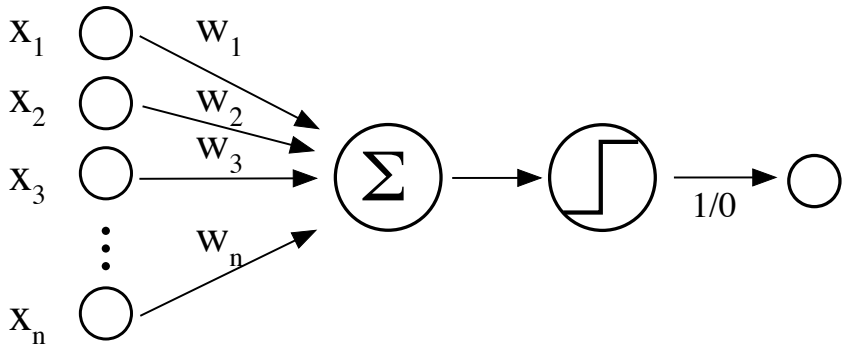

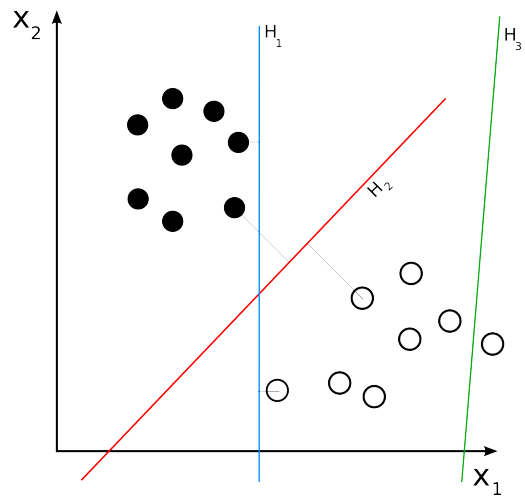

simple perceptron

ニューラルネットワーク

- ニューロンが相互結合する神経系をモデル化
- 多層パーセプトロン
  - 非線形な問題解決も可能になる
  - フィードフォワード型: 信号が出力方向にのみ伝搬
  - リカレント型: フィードバックが可能
- バックプロパゲーション: 誤差逆伝搬法による代表的学習方法
- 教師あり学習、教師なし学習、両方に使える
  - 教師なし学習: 特徴空間上の近さを学習させて自己組織化

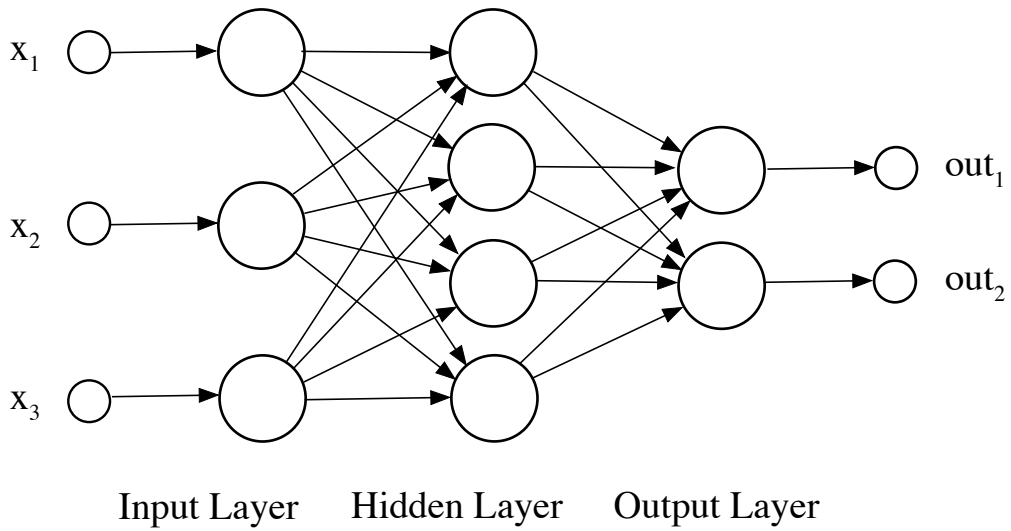

neural network

ディープラーニング

- ディープラーニング
  - 構造: 深い階層を持ったニューラルネットワーク
  - 機能: 特徴抽出 (表現学習) も自動化
- 2012 年ごろから目覚ましい成果
  - 多くの分野でのベンチマークで他の方式を圧倒
- 技術的に大きなブレイクスルーがあった訳ではない
  - 並列化できるため GPGPU や大規模クラスタの利用に向く
- 表現学習の部分も自動化しているので、雑多なデータを入力すれば、結果がでる

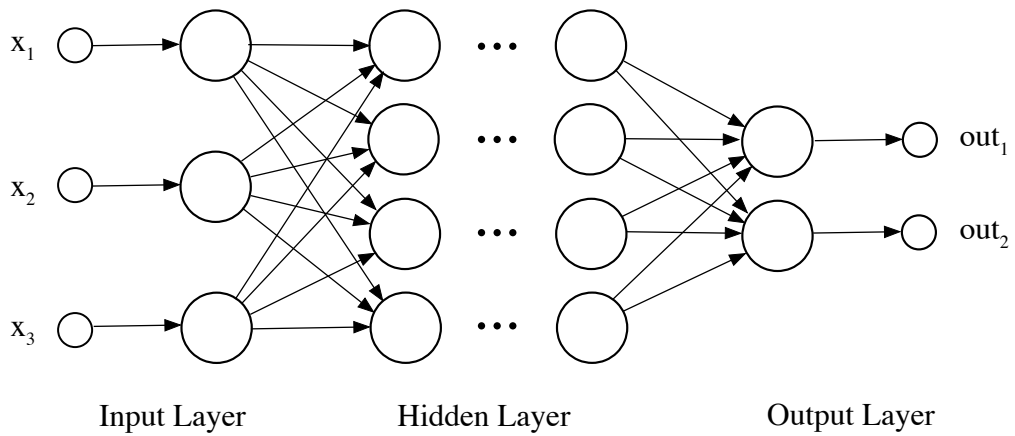

deep learning model

スパム判定

スパム: 迷惑メール
判定手法

- 送信者による判定
  - ホワイトリスト
  - ブラックリスト
  - グレーリスト
- コンテンツによる判定
  - ベイジアンフィルタ: スパム判定手法として広く普及
  - 迷惑メールの特徴を統計的な学習手法で分析し判定
  - 学習機能により精度が向上
  - メールからトークン (単語など) を抽出し、含まれるトークンからそのメールがスパムであるかどうか判定

条件付き確率

問題

- 5 回に 1 回の割合で帽子を忘れるくせのある K 君が、正月に A、B、C 軒を順に年始回りをして家に帰ったとき、帽子を忘れてきたことに気がついた。2 軒目の家 B に忘れてきた確率を求めよ。 (昭和 51 年 早稲田大入試問題)

条件付き確率

問題

- 5 回に 1 回の割合で帽子を忘れるくせのある K 君が、正月に A、B,C 軒を順に年始回りをして家に帰ったとき、帽子を忘れてきたことに気がついた。2 軒目の家 B に忘れてきた確率を求めよ。 (昭和 51 年 早稲田大入試問題)

解

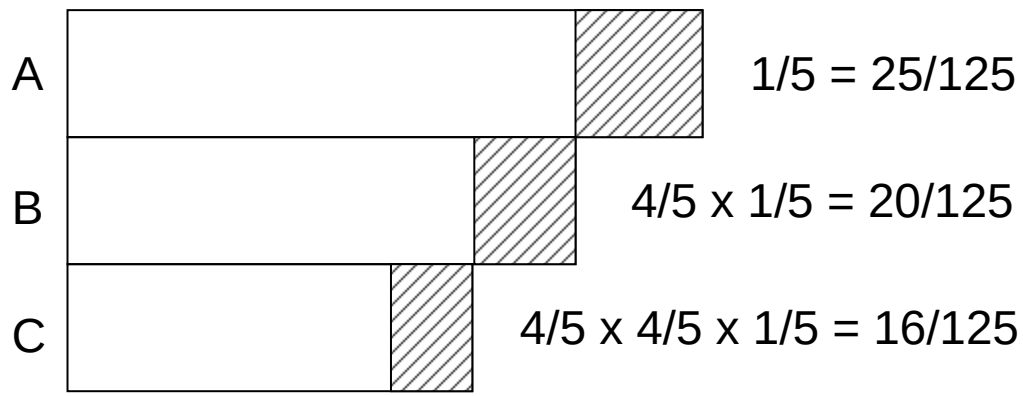

B で帽子を忘れた確率 / いずれかの場所で帽子を忘れた確率 $= 20/61$

ベイズ理論 (Bayes' theorem)

条件付き確率

- ある事象 A が起こるという条件の下で別の事象 B の起こる確率: $P(B|A)$
  - 全ての場合を事象 A として、そのうち B の起こる事象 $(A \cap B)$ を求める

$$P(B|A) = \frac{P(A \cap B)}{P(A)}$$

ベイズの定理

- 上記の例とは逆に、A という原因で B が起こったときに、その原因が起こる確率を求める: $P(A|B)$
  - $P(A)$: 原因 A の存在確率 (事前確率)
  - $P(A|B)$: B が起こった場合の原因 A の確率 (事後確率)

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} = \frac{P(A \cap B)}{P(B)}$$

ベイズ理論の応用

観測結果から原因の確率を推測する: 多くの工学的応用

- 通信: ノイズの加わった受信信号から送信信号を求める
- 医学: 検査結果から実際に疾患を持つ可能性を求める
- スパム判定: 届いたメールの文面から迷惑メールであるか求める

病気検査の例

問題

- ある病気に掛かっている人口割合は $50/1000$、この病気の検査は、この病気の患者の 90%が陽性が出るが、患者でない人も 10%は陽性反応がでる。
  あるひとがこの検査で陽性反応が出た場合、本当にこの病気にかかっている確率はいくらか？

病気検査の例

問題

- ある病気に掛かっている人口割合は $50/1000$、この病気の検査は、この病気の患者の 90%は陽性が出るが、患者でない人も 10%は陽性反応がでる。
  あるひとがこの検査で陽性反応が出た場合、本当にこの病気にかかっている確率はいくらか？

解

病気にかかっている確率: $P(D) = 50/1000 = 0.05$
陽性反応が出る確率: $P(R) = P(D \cap R) + P(\bar{D} \cap R)$
陽性反応が出た場合、病気である事後確率

$$\begin{aligned} P(D|R) &= \frac{P(D \cap R)}{P(R)} \\ &= (0.05 \times 0.9)/(0.05 \times 0.9 + 0.95 \times 0.1) = 0.321 \end{aligned}$$

迷惑メール判定

- 迷惑メール (SPAM) とそうでないメール (HAM) を用意
- 迷惑メールに多く含まれる単語について
  - SPAM がこの単語を含む条件つき確率
  - HAM がこの単語を含む条件つき確率
- を計算しておき、この単語を含む未知のメールが SPAM である事後確率を求める

例: ある単語 A に関して、$P(A|S) = 0.3$, $P(A|H) = 0.01$, $\frac{P(H)}{P(S)} = 2$ の場合に $P(S|A)$ を求める

$$
\begin{aligned}
P(S|A) &= \frac{P(S)P(A|S)}{P(S)P(A|S) + P(H)P(A|H)} \\
&= \frac{P(A|S)}{P(A|S) + P(A|H)P(H)/P(S)} \\
&= \frac{0.3}{0.3 + 0.01 \times 2} = 0.94
\end{aligned}
$$

単純ベイズ分類器 (naive Bayesian classifier)

- 実際には、複数のトークンを利用
  - トークン同士の組合せを考慮すると膨大なデータが必要
- 単純ベイズ分類器: 各トークンが独立と仮定
  - 独立でない場合でも、実際には有効な場合が多い
  - 学習ステップ:
    - 判定済み学習サンプルから各トークンがスパムに含まれる確率を推定
  - 予測ステップ:
    - 判定が未知のメールに対し、含まれるトークンの推定スパム確率からメールがスパムである事後確率を計算、判定
- 学習ステップはトークン毎に独立計算なので簡単
- トークンスパム確率から結合スパム確率の算出にベイズの結合確率を使う

単純ベイズ分類器 (もう少し詳しく)

トークンを $x_1, x_2, \ldots, x_n$ とする。 これらが出現したとき SPAM である事後確率は

$$P(S|x_1, \ldots, x_n) = \frac{P(S)P(x_1, \ldots, x_n|S)}{P(x_1, \ldots, x_n)}$$

分子の部分は、これらのトークンが出現し、かつ SPAM である同時確率なので、以下のように書け、条件つき確率の定義を繰り返し適用すると

$$\begin{aligned} P(S, x_1, \ldots, x_n) &= P(S)P(x_1, \ldots, x_n|S) \\ &= P(S)P(x_1|S)P(x_2, \ldots, x_n|S, x_1) \\ &= P(S)P(x_1|S)P(x_2|S, x_1)P(x_3, \ldots, x_n|S, x_1, x_2) \end{aligned}$$

ここで、各トークンが条件付きで他のトークンと独立だと仮定すると

$$P(x_i|S, x_j) = P(x_i|S)$$

すると上記の同時確率は

$$P(S, x_1, \ldots, x_n) = P(S)P(x_1|S)P(x_2|S)\cdots P(x_n|S) = P(S)\prod_{i=1}^{n} P(x_i|S)$$

したがって、各トークンが独立だとの仮定の下で、SPAM である事後確率は

$$P(S|x_1, \ldots, x_n) = \frac{P(S)\prod_{i=1}^{n} P(x_i|S)}{P(S)\prod_{i=1}^{n} P(x_i|S) + P(H)\prod_{i=1}^{n} P(x_i|H)}$$

今回の演習: スパム判定

- 単純ベイズ分類器を使ったスパム判定
  - 「集合知プログラミング 6 章」のコードから作成
  - 日本語を扱うには単語に分割する形態素解析が必要

```
% ruby naivebayes.rb
classifying "quick rabbit" => good
classifying "quick money" => bad
```

今回の演習: 演習に使う単純ベイズ分類器

出現単語により文書が特定のカテゴリに分類される確率を求める

$$P(C)\prod_{i=1}^{n}P(x_i|C)$$

- $P(C)$: カテゴリの出現確率
- $\prod_{i=1}^{n}P(x_i|C)$: カテゴリにおける各単語の条件付き確率の積

もっとも確率の高いカテゴリを選ぶ

- 閾値： 2 番目のカテゴリより $thresh$ 倍高い必要

今回の演習: スパム判定スクリプト

- トレーニングと判定

```
# create a classifier instance
cl = NaiveBayes.new

# training
cl.train('Nobody owns the water.','good')
cl.train('the quick rabbit jumps fences','good')
cl.train('buy pharmaceuticals now','bad')
cl.train('make quick money at the online casino','bad')
cl.train('the quick brown fox jumps','good')

# classify
sample_data = [ "quick rabbit", "quick money" ]

sample_data.each do |s|
  print "classifying \"#{s}\" => "
  puts cl.classify(s, default="unknown")
end
```

今回の演習: Classifier Class (1/2)

```
# feature extraction
def getwords(doc)
  words = doc.split(/\W+/)
  words.map!{|w| w.downcase}
  words.select{|w| w.length < 20 && w.length > 2 }.uniq
end

# base class for classifier
class Classifier
  def initialize
    # initialize arrays for feature counts, category counts
    @fc, @cc = {}, {}
  end

  def getfeatures(doc)
    getwords(doc)
  end

  # increment feature/category count
  def incf(f, cat)
    @fc[f] ||= {}
    @fc[f][cat] ||= 0
    @fc[f][cat] += 1
  end

  # increment category count
  def incc(cat)
    @cc[cat] ||= 0
    @cc[cat] += 1
  end

  ...
```

今回の演習: Classifier Class (2/2)

```
  def fprob(f,cat)
    if catcount(cat) == 0
      return 0.0
    end

    # the total number of times this feature appeared in this
    # category divided by the total number of items in this category
    Float(fcount(f, cat)) / catcount(cat)
  end

  # when the sample size is small, fprob is not reliable.
  # so, make it start with 0.5 and converge to fprob as the number grows
  def weightedprob(f, cat, weight=1.0, ap=0.5)
    # calculate current probability
    basicprob = fprob(f, cat)
    # count the number of times this feature has appeared in all categories
    totals = 0
    categories.each do |c|
      totals += fcount(f,c)
    end
    # calculate the weighted average
    ((weight * ap) + (totals * basicprob)) / (weight + totals)
  end

  def train(item, cat)
    features = getfeatures(item)
    features.each do |f|
      incf(f, cat)
    end
    incc(cat)
  end
end
```

今回の演習: NaiveBayes Class

```
# naive baysian classifier
class NaiveBayes < Classifier
  def initialize
    super
    @thresholds = {}
  end

  def docprob(item, cat)
    features = getfeatures(item)
    # multiply the probabilities of all the features together
    p = 1.0
    features.each do |f|
      p *= weightedprob(f, cat)
    end
    return p
  end

  def prob(item, cat)
    catprob = Float(catcount(cat)) / totalcount
    docprob = docprob(item, cat)
    return docprob * catprob
  end

  def classify(item, default=nil)
    # find the category with the highest probability
    probs, max, best = {}, 0.0, nil
    categories.each do |cat|
      probs[cat] = prob(item, cat)
      if probs[cat] > max
        max = probs[cat]
        best = cat
      end
    end
    # make sure the probability exceeds threshold*next best
```

debug: feature probabilities のダンプ

トレーニング後の内部状態:

```
fprob for "nobody":    good:0.333 bad:0.000
fprob for "owns":      good:0.333 bad:0.000
fprob for "the":       good:1.000 bad:0.500
fprob for "water":     good:0.333 bad:0.000
fprob for "quick":     good:0.667 bad:0.500
fprob for "rabbit":    good:0.333 bad:0.000
fprob for "jumps":     good:0.667 bad:0.000
fprob for "fences":    good:0.333 bad:0.000
fprob for "buy":       good:0.000 bad:0.500
fprob for "pharmaceuticals":   good:0.000 bad:0.500
fprob for "now":       good:0.000 bad:0.500
fprob for "make":      good:0.000 bad:0.500
fprob for "money":     good:0.000 bad:0.500
fprob for "online":    good:0.000 bad:0.500
fprob for "casino":    good:0.000 bad:0.500
fprob for "brown":     good:0.333 bad:0.000
fprob for "fox":       good:0.333 bad:0.000
```

課題 2: twitter データ解析

- ねらい: 大規模実データ処理の実践
- 課題用データ:
  - Kwak らによる 2009 年 7 月の twitter data、約 4000 万ユーザ分
    - 元データ: http://an.kaist.ac.kr/traces/WWW2010.html
  - twitter_degrees-10000.txt (135KB)
    - 10,000 人分のサンプルデータ
  - twitter_degrees.zip (164MB, 解凍後 550MB)
    - 約 4000 万人分のフルデータ
  - numeric2screen.zip (365MB, 解凍後 756MB)
    - ユーザ ID とスクリーン名のマッピング
- 提出項目
  1. twitter ユーザの following/follower 数散布図プロット
     - 10,000 人分のデータを使った散布図
  2. フルデータによる following/follower 数分布の CCDF プロット
     - X 軸に following/follower 数を取り log-log プロット
  3. フォローワ数の多いトップ 50 ユーザの表
     - ランク、ユーザ ID、スクリーン名、フォロー数、フォローワ数
  4. オプション: その他の解析
  5. 考察: データから読みとれることを記述
- 提出形式: PDF 形式のレポートを SFC-SFS から提出
- 提出〆切: 2015 年 6 月 24 日

課題データについて

twitter_degrees.zip (164MB, 解凍後 550MB)

```
# id followings followers

12      586     1001061
13      243     1031830
14      106     8808
15      275     14342
16      273     218
17      192     6948
18      87      6532
20      912     1213787
21      495     9027
22      272     3791
...
```

numeric2screen.zip (365MB, 解凍後 756MB)

```
# id screenname

12 jack
13 biz
14 noah
15 crystal
16 jeremy
17 tonystubblebine
18 Adam
20 ev
21 dom
22 rabble
...
```

課題 提出物

散布図

- 10,000 人分のデータを用いて、X 軸に following、Y 軸に follower 数を取り log-log プロット
- 対数グラフなので範囲は 1 から。(0 のデータはプロット不要)

CCDF プロット

- X 軸に following/follower 数を取り log-log プロット
- ここでも対数グラフなので範囲は 1 から。

フォローワ数の多いトップ 50 ユーザの表

- ランク、ユーザ ID、スクリーン名、フォロー数、フォローワ数

```
# rank   id           screenname   followings followers

1      19058681       aplusk          183     2997469
2      15846407       TheEllenShow    26      2679639
3      16409683       britneyspears   406238  2674874
4      428333         cnnbrk          18      2450749
5      19397785       Oprah           15      1994926
6      783214         twitter         55      1959708
...
```

sort コマンド

sort コマンド: テキストファイルの行をソートして並び替える

```
$ sort [options] [FILE ...]
```

- options (課題で使いそうなオプション)
  - -n : フィールドを数値として評価
  - -r : 結果を逆順に並べる
  - -k POS1[,POS2] : ソートするフィールド番号 (1 オリジン) を指定する
  - -t SEP : フィールドセパレータを指定する
  - -m : 既にソートされたファイルをマージする
  - -T DIR : 一時ファイルのディレクトリを指定する

例: file を第 3 フィールドを数値とみて逆順にソート、一時ファイルは”/usr/tmp”に作る

```
$ sort -nr -k3,3 -T/usr/tmp file
```

前回の演習: Dijkstra アルゴリズム

- トポロジファイルを読んで、最短経路木を計算する

```
$ cat topology.txt
a - b 5
a - c 8
b - c 2
b - d 1
b - e 6
c - e 3
d - e 3
c - f 3
e - f 2
d - g 4
e - g 5
f - g 4
$ ruby dijkstra.rb -s a topology.txt
a: (0) a
b: (5) a b
c: (7) a b c
d: (6) a b d
e: (9) a b d e
f: (10) a b c f
g: (10) a b d g
$
```

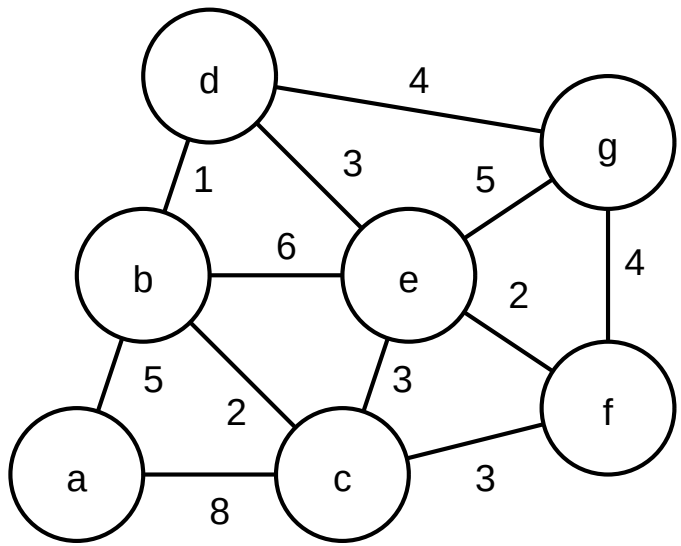

おまけ: JR の区間距離による最短経路検索

- 山手線、中央線と総武線の一部 (区間距離単位 100m)

```
$ cat jr.txt
# JR Yamanote line
Osaki - Gotanda 09
Gotanda - Meguro 12
Meguro - Ebisu 15
Ebisu - Shibuya 16
Shibuya - Harajuku 12
Harajuku - Yoyogi 15
...
Tamachi - Shinagawa 22
Shinagawa - Osaki 20
# JR Chuo line
Tokyo - Kanda 13
Kanda - Ochanomizu 13
Ochanomizu - Suidobashi 08
...
Sendagaya - Yoyogi 10
Yoyogi - Shinjuku 07
# JR Sobu line
Ochanomizu - Akihabara 09
Akihabara - Asakusabashi 11
$
$ ruby dijkstra.rb -s Shinagawa -d Ochanomizu jr.txt
Ochanomizu: (94) Shinagawa Tamachi Hamamatsucho Shinbashi Yurakucho Tokyo Kanda Ochanomizu
$ ruby dijkstra.rb -s Tokyo -d Shinjuku jr.txt
Shinjuku: (103) Tokyo Kanda Ochanomizu Suidobashi Iidabashi Ichigaya Yotsuya Shinanomachi Sendagaya Yoyog
$
```

sample code (1/4)

```
#!/usr/bin/env ruby
#
# dijkstra's algorithm based on the pseudo code in the wikipedia
# http://en.wikipedia.org/wiki/Dijkstra%27s_algorithm
# usage: dijkstra.rb -s source [-d destination] topologyfile
require 'optparse'

source = nil # source of spanning-tree
destination = nil  # destination

OptionParser.new {|opt|
  opt.on('-s VAL') {|v| source = v}
  opt.on('-d VAL') {|v| destination = v}
  opt.parse!(ARGV)
}

INFINITY = 0x7fffffff # constant to represent a large number
```

sample code (2/4)

```
# read topology file and initialize nodes and edges
# each line of topology file should be "node1 (-|->) node2 weight_val"
nodes = Array.new # all nodes in graph
edges = Hash.new # all edges in graph
ARGF.each_line do |line|
  s, op, t, w = line.split
  next if line[0] == ?# || w == nil
  unless op == "-" || op == "->"
    raise ArgumentError, "edge_type should be either '-' or '->'"
  end
  weight = w.to_i
  nodes << s unless nodes.include?(s) # add s to nodes
  nodes << t unless nodes.include?(t) # add t to nodes
  # add this to edges
  edges[s] ||= {}  # if edges[s] doesn't exit, initialize with empty hash
  edges[s][t] = weight
  # if this edge is undirected, add the reverse directed edge
  if (op == "-")
    edges[t] ||= {}
    edges[t][s] = weight
  end
end
# sanity check
if source == nil
  raise ArgumentError, "specify source_node by '-s source'"
end
unless nodes.include?(source)
  raise ArgumentError, "source_node(#{source}) is not in the graph"
end
```

sample code (3/4)

```
# create and initialize 2 hashes: distance and previous
dist = Hash.new # distance for destination
prev = Hash.new # previous node in the best path
nodes.each do |i|
  dist[i] = INFINITY # Unknown distance function from source to v
  prev[i] = -1 # Previous node in best path from source
end

# run the dijkstra algorithm
dist[source] = 0 # Distance from source to source
while (nodes.length > 0)
  # u := vertex in Q with smallest dist[]
  u = nil
  nodes.each do |v|
    if (!u) || (dist[v] < dist[u])
      u = v
    end
  end
  if (dist[u] == INFINITY)
    break # all remaining vertices are inaccessible from source
  end
  nodes = nodes - [u] # remove u from Q
  # update dist[] of u's neighbors
  edges[u].keys.each do |v|
    alt = dist[u] + edges[u][v]
    if (alt < dist[v])
      dist[v] = alt
      prev[v]  = u
    end
  end
end
```

sample code (4/4)

```
# print the shortest-path spanning-tree
dist.sort.each do |v, d|
  # if destination is specified, skip other destinations
  next if destination && destination != v

  print "#{v}: " # destination node
  if d != INFINITY
    print "(#{d}) " # distance
    # construct path from dest to source
    i = v
    path = "#{i}"
    while prev[i] != -1 do
      path.insert(0, "#{prev[i]} ") # prepend previous node
      i = prev[i]
    end
    puts "#{path}" # print path from source to dest
  else
    puts "unreachable"
  end
end
```

まとめ

第 10 回 異常検出と機械学習

- 異常検出
- 機械学習
- スパム判定とベイズ理論
- 演習: 単純ベイズ分類器

次回予定

第 11 回 データマイニング (6/29)

- パターン抽出
- クラス分類
- クラスタリング
- 演習: クラスタリング