

# *Tutorial on Statistics, Probability and Information Theory for Language Engineers*

*Prof. Ibrahim F. Imam*

Full Professor and Assistant Dean,  
College of Computing and Information Technology  
Arab Academy for Science, Technology & Maritime Transport, Cairo

Email: ifi05@yahoo.com

Phone: 012-2242929

# OUTLINE

1- Supporting Tools	3
2- Basic Concepts	13
3- Documents as Vectors	19
4- Text Mining Applications	32
5- Introduction to Probability	53
6- Preprocessing	60
7- Introduction to Statistics	73
8- Regression	91
9- Testing Measures	96
10- Test of Significance	103
11- The Information Theory	109
12- Association Rules	122
13- Decision Trees	131

# Tutorial on Text Mining

## Part 0

*Supporting Tools  
WordNet & SUMO*

# The WordNet

- WordNet is a semantic network encoding the words of a single (or multiple) language(s) using:
  - Synsets encoding the meanings for each word
  - Relations synonymy, antonymy, hypernymy, hyponymy, holonymy, meronymy, homonymy, troponymy, ...
  - The English WordNet (v3) encodes 155287 words

POS	Unique Strings	Synsets	Total Word-Sense Pairs
Noun	117798	82115	146312
Verb	11529	13767	25047
Adjective	21479	18156	30002
Adverb	4481	3621	5580
Totals	155287	117659	206941

- WordNet is organized by the concept of synonym sets (synsets), e.g.:
  - musician, instrumentalist, player
  - person, individual, someone

# The WordNet Relations

Relation	Definition	Example
Hypernym	From lower to higher concepts	breakfast → meal
Hyponym	From concepts to subordinates	meal → lunch
Has-Member	From groups to their members	faculty → professor
Member-Of	From members to their groups	copilot → crew
Has-Part	From wholes to parts	table → leg
Part-Of	From parts to wholes	course → meal
Antonym	Opposites	leader → follower

# The WordNet

Word: Cool

## Noun

S: (n) cool (the quality of being at a refreshingly low temperature) "*the cool of early morning*"

S: (n) aplomb, assuredness, cool, poise, sang-froid (great coolness and composure under strain) "*keep your cool*"

## Verb

S: (v) cool, chill, cool down (make cool or cooler) "*Chill the food*"

S: (v) cool, chill, cool down (loose heat) "*The air cooled considerably after the thunderstorm*"

S: (v) cool, cool off, cool down (lose intensity) "*His enthusiasm cooled considerably*"

## Adjective

S: (adj) cool (neither warm nor very cold; giving relief from heat) "*a cool autumn day*"; "*a cool room*"; "*cool summer dresses*"; "*cool drinks*"; "*a cool breeze*"

S: (adj) cool, coolheaded, nerveless (marked by calm self-control (especially in trying circumstances); unemotional) "*play it cool*"; "*keep cool*"; "*stayed coolheaded in the crisis*"; "*the most nerveless winner in the history of the tournament*"


S: (adj) cool ((color) inducing the impression of coolness; used especially of greens and blues and violets) "*cool greens and blues and violets*"

S: (adj) cool (psychologically cool and unenthusiastic; unfriendly or unresponsive or showing dislike) "*relations were cool and polite*"; "*a cool reception*"; "*cool to the idea of higher taxes*"

S: (adj) cool ((used of a number or sum) without exaggeration or qualification) "*a cool million bucks*"

S: (adj) cool (fashionable and attractive at the time; often skilled or socially adept) "*he's a cool dude*"; "*that's cool*"; "*Mary's dress is really cool*"; "*it's not cool to arrive at a party too early*"

# Sample Graph from The WordNet



# *Suggested Upper Merged Ontology (SUMO)*

Suggested S

It is large, open source, and formal

+      Upper U

Focusing on The most general and reusable terms and definitions


+      Merged M

Mapped with large multi-lingual lexicon

+      Ontology O      =      SUMO


Ontology is a set of term definitions in a formal language describing the world

# *Suggested Upper Merged Ontology (SUMO)*





Total Terms = 20399  
Total Axioms = 67108  
Rules = 2500

[www.ontologyportal.org](http://www.ontologyportal.org)



# *Suggested Upper Merged Ontology (SUMO)*



# *Suggested Upper Merged Ontology (SUMO)*

## SUMO Search Tool

This tool relates English terms to concepts from the [SUMO](#) ontology by means of mappings to [WordNet](#) synsets.

**English Word:** According to WordNet, the noun "**table**" has 6 sense(s).

[104379243](#) a piece of furniture having a smooth flat top that is usually supported by one or more vertical legs; "it was a sturdy table".

SUMO Mappings: [Table](#) (equivalent mapping)

[104379964](#) a piece of furniture with tableware for a meal laid out on it; "I reserved a table at my favorite restaurant".

SUMO Mappings: [Table](#) (subsuming mapping)

[107565259](#) food or meals in general; "she sets a fine table"; "room and board".

SUMO Mappings: [Food](#) (subsuming mapping)

[108266235](#) a set of data arranged in rows and columns; "see table 1".

SUMO Mappings: [ContentBearingObject](#) (subsuming mapping)

[108480135](#) a company of people assembled at a table for a meal or game; "he entertained the whole table with his witty remarks".

SUMO Mappings: [Meeting](#) (subsuming mapping)

[109351905](#) flat tableland with steep edges; "the tribe was relatively safe on the mesa but they had to descend into the valley for water".

SUMO Mappings: [Mesa](#) (equivalent mapping)

# *Suggested Upper Merged Ontology*



Table(table)

\_ [King Arthur's Round Table](#), [Lord's table](#), [Parsons table](#), [Round Table](#), [altar](#), [board](#), [booth](#), [breakfast table](#), [card table](#), [cocktail table](#), [coffee table](#), [communion table](#), [conference table](#), [console](#), [console table](#), [council board](#), [council table](#), [counter](#), [dining-room table](#), [dining table](#), [dinner table](#), [dresser](#), [dressing table](#), [drop-leaf table](#), [gaming table](#), [gueridon](#), [high table](#), [kitchen table](#), [operating table](#), [pedestal table](#), [pier table](#), [refectory table](#), [stand](#), [table](#), [tea table](#), [toilet table](#), [trestle table](#), [triclinium](#), [vanity](#), [work table](#), [worktable](#)

appearance as argument number 1

([documentation Table EnglishLanguage](#) "A piece of [Furniture](#) with four legs and a flat top. It is used either for eating, paperwork or meetings.")[Mid-level-ontology.kif 1328-1329%3\(externalImageTable](#) "[http://upload.wikimedia.org/wikipedia/commons/7/7a/Table\\_and\\_chairs.jpg](http://upload.wikimedia.org/wikipedia/commons/7/7a/Table_and_chairs.jpg)")

# BASIC MATHEMATICS

## Part 1

### *Basic Concepts*

# BASIC MATHEMATICS

$$\sum_{i=1}^n i = 1 + 2 + \dots + n$$


$$\prod_{i=1}^n i = 1 * 2 * \dots * n$$

$$\sum_{i=1}^n k i = k \sum_{i=1}^n i$$


$$\prod_{i=1}^n k i = k \prod_{i=1}^n i$$

# Introduction to Set Theory


- A set is a collection of distinct items (Example:  $A = \{1, 2, 3, 4, 5\}$ )




Intersection



Union



Sub-set & Super-set



$x \in A$ ;  $a \in A$ ;  $d \in A$ ; ...

# Introduction to Set Theory

- $A = \{a, c, e, d, x, y, z\}$        $B = \{b, c, d, y, m, n\}$        $C = \{c, d\}$

$$A \cap B = \{c, d, y\}$$

Intersection

$$A \cup B = \{a, b, c, d, e, m, n, x, y, z\}$$

Union

$$A \not\subset B \quad C \subset B \quad C \subset A$$

Sub-set & Super-set

$$x \in A; \quad x \notin B; \quad x \notin C$$

Belong Relationship

$\Phi/\emptyset$  is the empty set

$$\cap \cup \subset \not\subset \in \notin \neg \wedge \vee$$

# Introduction to Set Theory

- $A \cap (B \cap C) = (A \cap B) \cap C$       &       $A \cup (B \cup C) = (A \cup B) \cup C$
- $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$
- $\neg(\neg A) = A$
- $\neg(A \cap B) = \neg A \cup \neg B$

# Introduction to Propositional Logic

- It is also called the Zero Order Logic
- A sentence X can be either true or false (1 or 0)

X	Y
0	0
1	1

X	Y	$X \wedge Y$
0	0	0
0	1	0
1	0	0
1	1	1

X	Y	$X \vee Y$
0	0	0
0	1	1
1	0	1
1	1	1

X	Y	$X \rightarrow Y$
0	0	1
0	1	1
1	0	0
1	1	1

X	Y	$X \text{ XOR } Y$
0	0	1
0	1	0
1	0	0
1	1	1

$X \rightarrow Y = \neg X \vee Y$
$\neg(X \wedge Y) = \neg X \vee \neg Y$
$X \wedge X = X \quad \& \quad X \vee X = X$
$X \vee (Y \wedge Z) = (X \vee Y) \wedge (X \vee Z)$
$\neg(\neg X) = X$

## *Introduction to Vectors*

### *Part 2*

*Representing Documents  
As Vectors*

# Introduction to Vectors


Adding two vectors

$$(x_1, y_1) + (x_2, y_2) = (x_1 + x_2, y_1 + y_2)$$



Multiplying a vector by a constant and adding it to another vector

$$(x_1, y_1) + (2 \cdot x_2, 2 \cdot y_2) = (x_1 + 2x_2, y_1 + 2y_2)$$




Multiplying a vector by -1

$$-(x_1, y_1) = (-x_1, -y_1)$$

Multiplying a vector by a constant

$$2 \cdot (x_2, y_2) = (2x_2, 2y_2)$$




# Introduction to Vectors

Multiplying two orthogonal vectors equal to zero.

Examples:


$$V1 = (5, 0) \quad \& \quad V2 = (0, 4)$$

$$V1 \cdot V2 = 0$$




$$V1 = (5, 4) \quad \& \quad V2 = (-4, 5)$$

$$V1 \cdot V2 = 0$$



# Eigen Values & Eigen Vectors

- An eigenvector of a matrix  $\underline{A}$  is a nonzero vector  $\underline{x}$ ; where  $\underline{A}.\underline{x}$  is similar to applying a linear transformation  $\underline{\lambda}$  to  $\underline{x}$  which, may change in length, but not direction
- $\underline{A}$  acts to stretch the vector  $\underline{x}$ , not change its direction, so  $\underline{x}$  is an eigenvector of  $\underline{A}$



$$Ax - \lambda Ix = 0$$

$$(A - \lambda I)x = 0$$

if there exist an inverse  $(A - \lambda I)^{-1}$ , then  $x = 0$

$$\begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \lambda \begin{bmatrix} x \\ y \end{bmatrix}$$

we need  $\det(A - \lambda I) = 0$  to avoid the trivial solution  $x = 0$

$$\det(A - \lambda I) = 0$$

# Example on Eigen Values & Eigen Vectors

- Suppose  $A$  is 2x2 matrix

$$A = \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix}$$

$$\det \begin{bmatrix} 2-\lambda & 1 \\ 1 & 2-\lambda \end{bmatrix} = (2-\lambda)^2 - 1 = 0$$

$$\lambda = 1 \quad \text{or} \quad \lambda = 3$$

$$\text{for } \lambda = 3, \quad \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = 3 \begin{bmatrix} x \\ y \end{bmatrix}$$

$$\text{for } \lambda = 1, \quad \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = 1 \begin{bmatrix} x \\ y \end{bmatrix}$$

$$\begin{bmatrix} 2x+y \\ x+2y \end{bmatrix} = \begin{bmatrix} 3x \\ 3y \end{bmatrix}$$

$$\begin{bmatrix} 2x+y \\ x+2y \end{bmatrix} = \begin{bmatrix} x \\ y \end{bmatrix}$$

$$2x+y = 3x$$

$$x = y$$

$$2x+y = x$$


$$x = -y$$

The eigenvectors are:

$$\begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$\begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

# Representing Documents as Vectors




# *Documents as Vectors*


Suppose we have two documents containing three nouns only

	Term T <sub>1</sub>	Term T <sub>2</sub>	Term T <sub>3</sub>
Document D <sub>1</sub>	2	3	5
Document D <sub>2</sub>	3	7	1

$$\begin{array}{|c|} \hline D_1 & \\ \hline \boxed{2} \\ \boxed{3} \\ \boxed{5} \\ \hline \end{array} \quad | \quad \begin{array}{|c|} \hline D_2 & \\ \hline \boxed{3} \\ \boxed{7} \\ \boxed{1} \\ \hline \end{array}$$



# *Dimensionality Reduction*



## *Term Frequency & Inverse Document Frequency*

Usually a combination of the term frequency and the inverse document frequency

$$TFIDF = w_{ik} = tf_{ik} \times idf_{ik}$$

$$tf_{ik} = 1 + \log_2(tr_{ik}) \quad \text{and zero when log = 0}$$

$$idf_{ik} = \log_2\left(\frac{N}{n_{ik}}\right) \quad \text{and zero when log = 0}$$


$tf_{ik}$  is the term frequency of term  $i$  in document  $k$ ,  $tr_{ik}$  is the count of term  $i$  in document  $k$ ,  $idf_{ik}$  is the inverse document frequency of term  $i$  in document  $k$ ,  $N$  is the total number of documents in the collection,  $n_{ik}$  is the number of occurrence of term  $i$  in document  $k$ ,  $w_{ik}$  is the weight of term  $i$  in document  $k$ . Logarithm has been used to reduces the difference between the weight of high and low frequency terms. Logarithm of base 2 is used when vectors are full of binary TFIDF weights 0 and 1. Logarithm of base 10 is used when vectors are full of TFIDF weights except binary ones. TFIDF weights values are not normalized.

## *Term Frequency & Inverse Document Frequency*

$$tf_{ik} = 1 + \log_2(tr_{ik}) \quad \text{and zero when log = 0}$$

$$idf_{ik} = \log_2\left(\frac{N}{n_{ik}}\right) \quad \text{and zero when log = 0}$$

$$\log_2 x = \log_{10} x / \log_{10} 2$$



# *The Chi-Square Distribution*

$$\chi^2(t_k, c_i) = \frac{[P(t_k, c_i)P(\bar{t}_k, \bar{c}_i) - P(t_k, \bar{c}_i)P(\bar{t}_k, c_i)]^2}{P(t_k)P(\bar{t}_k)P(c_i)P(\bar{c}_i)}$$

$P(t_k, c_i)$  → probability document x contains term t and belongs to category c.

$P(\bar{t}_k, c_i)$  → probability document x does not contain term t and belongs to category c.

$P(t_k, \bar{c}_i)$  → probability document x contains term t and does not belong to category c.

$P(\bar{t}_k, \bar{c}_i)$  → probability document x does not contain term t and does not belong to category c.

$P(t)$  → probability of term t

$P(c)$  → probability of category c

# *The Information Gain*

It measures the classification power of a term

$$IG(t_k, c_i) = \sum_{c \in \{c_i, \bar{c}_i\}} \sum_{t \in \{t_k, \bar{t}_k\}} P(t, c) \log_2 \frac{P(t, c)}{P(t)P(c)}$$

$P(t_k, c_i)$  → probability document x contains term t and belongs to category c.

$P(\bar{t}_k, c_i)$  → probability document x does not contain term t and belongs to category c.

$P(t_k, \bar{c}_i)$  → probability document x contains term t and does not belong to category c.

$P(\bar{t}_k, \bar{c}_i)$  → probability document x does not contain term t and does not belong to category c.

$P(t)$  → probability of term t.

$P(c)$  → probability of category c.

# *The Gain Ratio*

$$GR(t_k, c_i) = \frac{\sum_{c \in \{c_i, \bar{c}_i\}} \sum_{t \in \{t_k, \bar{t}_k\}} P(t, c) \log_2 \frac{P(t, c)}{P(t)P(c)}}{- \sum_{c \in \{c_i, \bar{c}_i\}} P(c) \log_2 P(c)}$$

$P(t_k, c_i)$  → probability document x contains term t and belongs to category c.

$P(\bar{t}_k, c_i)$  → probability document x does not contain term t and belongs to category c.

$P(t_k, \bar{c}_i)$  → probability document x contains term t and does not belong to category c.

$P(\bar{t}_k, \bar{c}_i)$  → probability document x does not contain term t and does not belong to category c.

$P(t)$  → probability of term t.


$P(c)$  → probability of category c.

# Tutorial on Text Mining

## Part 3

*Text Mining Applications*

# Text Similarity



# Text Similarity

- Each Document is represented by a vector of terms
- Each Term is considered as a dimension in the space
- Terms in the space are uncorrelated so the dimensions are orthogonal on each other
- Each element of the vector has a value (Term Weight)


- Document A
  - “A dog and a cat.”

A	Dog	and	Cat	Frog
2	1	1	1	0

- Document B
  - “A frog.”

A	Dog	and	Cat	Frog
1	0	0	0	1

# Text Similarity



Weight indicates term importance either locally or globally

Similar Documents

frequency of term  $i$  in document  $k$ .

$t_{fi}$  is the inverse document frequency of term  $i$  in document  $k$ .

$df_{ik}$  is the number of documents containing term  $i$  in document  $k$ .

$N$  is the total number of documents.

$idf_{ik}$  is the inverse document frequency of term  $i$  in document  $k$ .

$w_{ik}$  is the weight of term  $i$  in document  $k$ .

Measuring Text Similarity between Document 1 & 2 vectors using Cosine Criterion

Document 1 ( $D1$ )

شن	قوى	أمريكا	حرب	ضري	طالب	مسا	هجم	طالب	أفغانستان
1	1	1	1	1	1	1	1	1	1

Document 2 ( $D2$ )

شن	قوى	أمريكا	حرب	ضري	طالب	مسا	هجم	طالب	أفغانستان
1	1	1	1	1	1	1	1	1	1

Weights:

$$w_{ik} = t_{fi} \cdot idf_{ik}$$

$$t_{fi} = \log \left( \frac{1 + f_{ik}}{N} \right)$$

$$idf_{ik} = \log \left( \frac{1}{df_{ik}} \right)$$

# Text Similarity

$$\text{Cosine}(D_j, D_k) = \frac{\sum_{i=1}^n w_{ij} \times w_{ik}}{\sqrt{\sum_{i=1}^n w_{ij}^2} \sqrt{\sum_{i=1}^n w_{ik}^2}}$$

$$\text{Euclidean}(D_j, D_k) = \sqrt{\sum_{i=1}^n (w_{i,j} - w_{i,k})^2 / n}$$

$$\text{Dice}(D_j, D_k) = \frac{2 \sum_{i=1}^n w_{i,j} \times w_{i,k}}{\sqrt{\sum_{i=1}^n w_{i,j}^2} + \sqrt{\sum_{i=1}^n w_{i,k}^2}}$$

$$\text{Overlap}(D_j, D_k) = \frac{\sum_{i=1}^n w_{i,j} \times w_{i,k}}{\min(\sqrt{\sum_{i=1}^n w_{i,j}^2}, \sqrt{\sum_{i=1}^n w_{i,k}^2})}$$

$$\text{Jaccard}(D_j, D_k) = \frac{\sum_{i=1}^n w_{i,j} \times w_{i,k}}{\sum_{i=1}^n w_{i,j}^2 + \sum_{i=1}^n w_{i,k}^2 - \sum_{i=1}^n w_{i,j} \times w_{i,k}}$$


Term Weight ( $w_{ik}$ ) =  $tf_{ik} \times idf_{ik}$ ,

Term Frequency ( $tf_{ik}$ ) =  $1 + \log(tr_{ik})$


Inverse Doc. Freq. ( $idf_{ik}$ ) =  $\log(N/n_{ik})$

( $tr_{ik}$ ) is the count of term  $i$  in doc.  $k$ .  
( $N$ ) is the total # of docs  
( $n_{ik}$ ) is the # of occur. of term  $i$  in doc.  $k$

# Text Summarization



# Text Summarization Approaches



# Microsoft Word Summarizer

**Selected Summary**

**Tutorial title**  
Text Mining and Link Analysis for Web Data

Presenter contact information including the e-mail address

Dunja Mladenic  
Address: J. Stefan Institute, Jamova 39, 1000 Ljubljana, Slovenia  
E-mail: [Dunja.Mladenic@ijs.si](mailto:Dunja.Mladenic@ijs.si)  
Phone: +386 1 4773 377

Marko Grobelnik  
Address: J. Stefan Institute, Jamova 39, 1000 Ljubljana, Slovenia  
E-mail: [Marko.Grobelnik@ijs.si](mailto:Marko.Grobelnik@ijs.si)  
Phone: +386 1 4773 778

Aims/Learning objectives;

The aim of this tutorial is to present topics from the areas of text mining and link analysis in the relationship to the web data. The goal is to show the whole list of nontrivial problems appearing in everyday life and occasionally in professional work with the web and to show how they can be approached using text mining and link analysis techniques and tools. The goal is to make an overview of the available approaches, which are potentially useful for solving interesting problems connected to the documents and their linkage coming from the web structure.

Duration (half or full day)  
Half day, but it could be scaled to full day

Scope (general topic area) and why it is relevant for WWW2004;

The tutorial's relevance for the WWW2004 is in the presentation of analytic approaches used on the web data (text+links). In particular, the tutorial will focus on the possibilities offered by two very active and relevant subfields of data mining: text mining and link analysis. The relevance of these topics to the WWW2004 public is in extending possible activities, which could be used in shaping, understanding and potentially predicting the static and dynamic nature of the web. Analysis of such data offers typically new insights in the nature of the complex web data. Suitability of the tutorial for the WWW2004

**Threshold**



# Example of Semantic Summarization

- Summarize the following article in 10 words

HOUSTON – The Hubble Space Telescope got smarter and better able to point at distant astronomical targets on Thursday as spacewalking astronauts replaced two major pieces of the observatory's gear. On the second spacewalk of the shuttle Discovery's Hubble repair mission, the astronauts, C. Michael Foale and Claude Nicollier, swapped out the observatory's central computer and one of its fine guidance sensors, a precision pointing device. The spacewalkers ventured into Discovery's cargo bay, where Hubble towers almost four stories above, at 2:06 p.m. EST, about 45 minutes earlier than scheduled, to get a jump on their busy day of replacing some of the telescope's most important components. . . .

Space News: [the shuttle Discovery's Hubble repair mission, the observatory's central computer]

# Example of Semantic Summarization

1. Input document is split into sentences
2. Each sentence is deep-parsed
3. Name-entities are disambiguated:
  - Determining that 'George Bush' == 'Bush' == 'U.S. president'
4. Performing Anaphora resolution:
  - Pronouns are connected with named-entities
5. Extracting of Subject-Predicate-Object triples
6. Constructing a graph from triples
7. Each triple in the graph is described with features for learning
8. Using machine learning train a model for classification of triples into the summary
9. Generate a summary graph from selected triples
10. From the summary graph generate textual summary document

Tom went to town. In a bookstore he bought a large book.

*NLPWin*

Tom went to town. In a bookstore he [Tom] bought a large book.

Tom ← go → town  
Tom ← buy → book

*WordNet*

book  
large

buy

Tom


go

town


# Example of Semantic Summarization (Cont.)

- A model was trained deciding which Subject-Predicate-Object triple belongs into the target summary
  - For training was used Support Vector Machine (SVM) on 400 statistic, linguistic and graph topological features

## Document Semantic network



## Summary semantic network



# Example of Arabic Summarization

Page 1/5

## انهيار البورصة المصرية بتصحيح أم هبوط.

انهيار أسعار أسهم البورصة المصرية.

للمرة الثانية خلال شهرين يتظاهر مستثمرو البورصة المصرية مطالبين بقالة رئيس البورصة، وجاءت الناظرة الثانية على أثر تراجع البورصة والانخفاض بقيمة أغلب الأسهم المتداولة بمنتصف هذا الشهر (مايو 2006) بنسبة 4%؛ وهو ما أعاد للذاكرة ما حدث يوم الثلاثاء الأسود بشهر مارس لنفس العام من هبوط شديد بمؤشر البورصة، والتي حدث بهذه سوق المال بايقاف التداول ذلك اليوم.

وتعد طفرة التعاملات خلال 2005 إلى تضخم السيولة بالسوق؛ نتيجة طرح الحكومة أسهم شركتي أموك وسيديك للجمهور، وتحقيق المشترين ل تلك الأسهم لأرباح وصلت إلى حوالي ضعف ثمن الشراء خلال أسبوع قليلة. وفي هذا الجو من توقع تكرار تلك الأرباح العالية من شراء الأسهم الحكومية، طرحت الحكومة نسبة 20% من أسهم الشركة المصرية للاتصالات، وهي الشركة الوحيدة المحتكرة لخطوط التليفونات الثابتة وكذلك الاتصالات الدولية؛ وهو ما جعل الجمهور يتكلّب عليها. أسباب طفرة 2005

وساهم تضخيم الشركة المروجة لأسهم الاتصالات لنسب الإقبال، وبمبالغة وسائل الإعلام الرسمية في التوقعات لقيمة السهم بعد طرحه. في حدوث إقبال كبير على شراء أسهم شركة الاتصالات من جانب فئات شعبية تدخل البورصة للمرة الأولى، وليس لديها أي ثقافة استثمارية. ومع تخصيص عدد محدود من الأسهم لطالبي الشراء اتجه هؤلاء الداخلون الجدد لتوجيه فوائض الاكتتاب لشراء أسهم أخرى أو لإعادة شراء أسهم الاتصالات بأسعارها المرتفعة توقعًا لارتفاع أسعارها.

وعلى صعيد المستثمرين العرب ساعدت الفوائض البترولية العربية في اتجاه كثريين منهم للشراء بالبورصة المصرية؛ وهو ما زاد من الطلب خاصة مع انخفاض سعر قيمة الأسهم المصرية النسبي بالنسبة للمستثمرين العرب والأجانب. وزاد دور المضاربين في توجيه السوق -والذي يخلو من وجود صانع سوق يمكنه ترشيد الطفرات السعرية-. وساعدت سياسة القطيع في الشراء دون الاستناد إلى المعلومات أو البيانات المالية للشركات أو للتحليل الأساسي أو الفني. حتى زادت أسعار شركات بنسبة عالية لا تناسب بالمرة مع أدائها، بل إن بعض أسهم شركات الواجه كانت تتجه للصعود رغم كارثة إنفلونزا الطيور التي شهدتها مصر.

وزاد عدد الأسهم المقيدة بالبورصة بنسبة 41% ليصل إلى 316.3 مليارات سهم. كما زاد رأس المال السوقي للشركات المقيدة بالبورصة بنسبة 95% ليصل إلى 456 مليار جنيه.

وببدأ التصحيح...

وبلغ عدد الشركات المقيدة عام 2005 بالبورصة 744 شركة بنقص 48 شركة عن العام السابق، وهي شركات محدودة التعامل تم شطبها لأسباب تتعلق بنقص شروط القيد، وهو أمر لم يؤثر على السوق التي تتميز بظاهرة تركز النشاط في نحو 50 شركة فقط. وارتفع مؤشر أسعار البورصة المصرية (CASE30) بنسبة 146%.

إلا أن الأسعار لم تأخذ نفس الاتجاه الصعودي بعد أن بلغت مستويات لا تتفق مع واقع الشركات التي تتنتمي إليها، ومن هنا فقد كان من الطبيعي أن تصحيح السوق نفسه. خاصة مع حدوث نفس التصحيح بالأسواق الخليجية التي كانت قد شهدت طفرة في أسعارها خلال العام الماضي. وتضافر ذلك مع عدم تنسيق هيئة سوق المال نزول عدد من الاكتتابات في زيادة رؤوس أموال الشركات في نفس الوقت، وهو ما أدى لزيادة العرض.

وتعد طفرة التعاملات خلال 2005 إلى تضخم السيولة بالسوق؛ نتيجة طرح الحكومة أسهم شركتي أموك وسيديك للجمهور، وتحقيق المشترين ل تلك الأسهم لأرباح وصلت إلى حوالي ضعف ثمن الشراء خلال أسبوع قليلة. وفي هذا الجو من توقع تكرار تلك الأرباح العالية من شراء الأسهم الحكومية، طرحت الحكومة نسبة 20% من أسهم الشركة المصرية للاتصالات، وهي الشركة الوحيدة المحتكرة لخطوط التليفونات الثابتة وكذلك الاتصالات الدولية؛ وهو ما جعل الجمهور يتكلّب عليها.

# Example of Arabic Summarization (Cont.)

Page 2/5

محاولات للإنعاش أسباب طفرة 2005.

كما استخدمت الحكومة سلطانها في توجيه محافظ الأوراق المالية الضخمة بالبنوك الحكومية العامة للشراء، ونفس الأمر لبعض صناديق الاستثمار التابعة للبنوك العامة. ومن هنا تماست السوق بل اتجهت للارتفاع بعض الوقت. إلا أن قوى السوق كان لا بد لها من أن تؤدي دورها فاستمرت الأسعار في التراجع.

حتى إنه مع إعلان وزير الاستثمار -الذي يشرف على السوق من قبل الحكومة- في احتفال كبير عن بدء إطلاق مؤشر داو جونز الخاص بالأسهم المصرية اتجهت الأسعار للتراجع في اليوم التالي مباشرة لإطلاق المؤشر. وحدث نفس الأمر للإعلان عن تكوين محافظ في أسواق دولية تستند محافظها إلى مكونات مؤشر البورصة الذي يضم الشركات الثلاثين الأكثر نشاطاً.

أسباب الانخفاض

وجاءت انفجارات مدينة دهب السياحية خلال شهر إبريل 2006 وكان من الطبيعي أن تؤثر على الأسعار بالبورصة. إلا أن الحكومة تدخلت أيضاً في إطار سياساتها التي تتجه إلى الدعوى بأن أحداث دهب لم تؤثر على حركة السياحة أو الطيران وبالتالي على البورصة رغم أن واقع الحال الحقيقي غير ذلك.

ومع عودة سياسة القمع الحكومية تجاه حركات المجتمع المدني كان من الطبيعي أيضاً أن تتأثر البورصة باعتبارها المرأة لكل ما يحدث بالمجتمع من مؤشرات على مناخ الاستثمار. وساهمت عدة عوامل في تراجع ثقة المستثمرين بالسوق. منها تراجع سعر أسهم المصرية للاتصالات لأقل من سعر الطرح الحكومي؛ وهو ما أحق خسائر كبيرة لحازيره، خاصةً لمن اشتراه بقيم عالية من السوق.

فذلك انخفاض سعر سهم هيرميس القابضة كسهم قائد للسوق، وزادت حالة التشاوم لدى صغار المتعاملين الذين أصبحت لهم النسبة الكبرى من التعامل بعد ابتعاد كثير من المؤسسات المالية عن السوق توقعاً لاستمرار حالة الهبوط السعري حتى شهر أكتوبر القادم.

دور بورصات الخليج  
وببدأ التصحيح.

وذكر هؤلاء أن كثيراً من المستثمرين الخليجين كانوا مقتربين جانباً من قيمة مشترياتهم من الأسهم، وأنه مع انخفاض الأسعار بأسواقهم طالبهم البنوك المقرضة لهم بسداد الفرق عن أسعار الأسهم المنخفضة. لذا اتجهوا لتسبييل محافظهم في مصر لتذليل سبولة لدفعها لتلك البنوك.

ولقد استمرت كثير من مؤشرات التعامل بالبورصة في النمو مع بداية العام الحالي 2006؛ ففي الثلث الأول من العام زادت قيمة التعامل بنسبة 207% لتصل إلى 119 مليار جنيه مقابل 39 مليار تحقق خلال الثلث الأول من 2005 وارتفع المتوسط اليومي لقيمة التعامل إلى 1.457 مليار جنيه مقابل 491 مليون جنيه عن نفس الفترة العام الماضي. كما زاد عدد الأوراق المالية المتداولة بنسبة 78% وارتفع عدد الصفقات بنسبة 117%. مع الأخذ في الاعتبار انخفاض مؤشرات التعامل تدريجياً من بنایير إلى إبريل.

توقفت حرج: جاء توقفت انهيار البورصة حرجاً للحكومة المصرية التي تبنت تماست الأسعار بالبورصة، والتي تستعد لافتتاح مؤتمر دافوس الشرق الأوسط بمدينة شرم الشيخ بعد 5 أيام من التظاهر في العشرين من مايو. وهو المؤتمر الذي ت يريد من خلاله الحكومة أن تؤكد ثقة المستثمرين العالميين بها خاصة بعد توالي أحداث العنف تجاه السياحة والشرطة وارتفاع حالة الاحتقان السياسي من جانب قطاعات من القضاة والصحفيين والأطباء ونقابات أخرى وبعض جمعيات حقوق الإنسان. ومن هنا تدخلت الحكومة لاتجاه الأسعار للارتفاع بشكل واضح في اليوم التالي للتظاهرة مباشرة.

وهذا التدخل الحكومي بسوق الأوراق المالية المصرية يمنع حركتها من التعبير الحقيقي عن آليات السوق، والبورصة الطبيعية تحررها قوى العرض والطلب والمعلومات. حتى تكون مرآة صادقة عن الاقتصاد. ونظراً لأن الاقتصاد المصري يعني من عجز مزمن بالميزان التجاري، وعجز مزمن بالموازنة العامة، ومن دين عام متزايد، ونسب عالية من البطالة والفقير وحالة من الغلاء، هذا بالإضافة إلى حالة احتقان سياسي غير مسبوق بالمجتمع المصري. فإن هذه العوامل لا بد أن تؤدي بظلها على البورصة في الأجل القصير على الأقل، ومهما تدخلت الحكومة فإن قوى السوق لا بد أن تؤدي دورها ويكون لها الكلمة الأخيرة.

# Example of Arabic Summarization (Cont.)

## انهيار البورصة المصرية

### انهيار أسعار أسهم البورصة المصرية .

للمرة الثانية خلال شهرين يتظاهر مستثمرى البورصة المصرية مطالبين بقالة رئيس البورصة، وجاءت التظاهرة الثانية على أثر تراجع البورصة والانخفاض بقيمة أغلب الأسهم المتداولة بمنتصف هذا الشهر (مايو 2006) بنسبة 4%؛ وهو ما أعاد للذاكرة ما حدث يوم الثلاثاء الأسود بشهر مارس لنفس العام من هبوط شديد بمؤشر البورصة، والتى حدت بهيئة سوق المال بایقاف التداول ذلك اليوم .

وزاد عدد الأسهم المقيدة بالبورصة بنسبة 41% ليصل إلى 146% وارتفع مؤشر أسعار البورصة المصرية (CASE30) بنسبة 146%.

وفي هذا الجو من توقع تكرار تلك الأرباح العالية من شراء الأسهم الحكومية، طرحت الحكومة نسبة 20% من أسهم الشركة المصرية للاتصالات، وهى الشركة الوحيدة المحتكرة لخطوط التليفونات الثابتة وكذلك الاتصالات الدولية؛ وهو ما جعل الجمهور يتکالب عليها .

ولقد استمرت كثير من مؤشرات التعامل بالبورصة في النمو مع بداية العام الحالي 2006؛ ففي الثلث الأول من العام زادت قيمة التعامل بنسبة 207% لتصل إلى 119 مليار جنيه مقابل 39 مليار تحققت خلال الثلث الأول من 2005

After Using Sentence-Base Summarization Algorithm:

Number of Pages in the Summary: ½ out of 5

Number of Paragraphs in the Summary: 7 out of 33

Number of Sentences in the Summary: 7 out of 73

# Example of Arabic Summarization (Cont.)

## بعض الجمل التي تم حذفها لعدم أهميتها


وتعود طفرة التعاملات خلال 2005 إلى تضخم السيولة بالسوق؛ نتيجة طرح الحكومة أسهم شركتي أموك وسيديك للجمهور، وتحقيق المشترين لتلك الأسهم لأرباح وصلت إلى حوالي ضعف ثمن الشراء خلال أسبوعين قليلة. وفي هذا الجو من توقع تكرار تلك الأرباح العالية من شراء الأسهم الحكومية، طرحت الحكومة نسبة 20% من أسهم الشركة المصرية للاتصالات، وهي الشركة الوحيدة المحتكرة لخطوط التليفونات الثابتة وكذلك الاتصالات الدولية؛ وهو ما جعل الجمهور يتكلّب عليها.

### أسباب طفرة 2005

وساهم تضخم الشركة المروجة لأسهم الاتصالات لنسب الإقبال، وبالمبالغة وسائل الإعلام الرسمية في التوقعات لقيمة السهم بعد طرحه. في حدوث إقبال كبير على شراء أسهم شركة الاتصالات من جانب فئات شعبية تدخل البورصة للمرة الأولى، وليس لديها أي ثقافة استثمارية. ومع تخصيص عدد محدود من الأسهم لطلابي الشراء اتجه هؤلاء الداخلون الجدد لتوجيهه فوائض الاكتتاب لشراء أسهم أخرى أو لإعادة شراء أسهم الاتصالات بأسعارها المرتفعة توقعاً لارتفاع أسعارها.


وعلى صعيد المستثمرين العرب ساعدت الفوائض البترولية العربية في اتجاه كثيرين منهم للشراء بالبورصة المصرية؛ وهو ما زاد من الطلب خاصة مع انخفاض سعر قيمة الأسهم المصرية النسبي بالنسبة للمستثمرين العرب والأجانب. وزاد دور المضاربين في توجيه السوق -والذي يخلو من وجود صانع سوق يمكنه ترشيد الطفرات السعرية- وسادت سياسة القطيع في الشراء دون الاستناد إلى المعلومات أو البيانات المالية للشركات أو للتحليل الأساسي أو الفني. حتى زادت أسعار شركات بنسب عالية لا تتناسب بالمرة مع أدائها، بل إن بعض أسهم شركات الدواجن كانت تتجه للصعود رغم كارثة إنفلونزا الطيور التي شهدتها مصر.

# Supervised Text Categorization



# Supervised Text Categorization

Text Categorization (TC) is the process of labeling electronic text documents with different labels




	$d_1$	$\dots$	$\dots$	$d_j$	$\dots$	$\dots$	$d_n$
$c_1$	$a_{11}$	$\dots$	$\dots$	$a_{1j}$	$\dots$	$\dots$	$a_{1n}$
$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$
$c_i$	$a_{i1}$	$\dots$	$\dots$	$a_{ij}$	$\dots$	$\dots$	$a_{in}$
$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$
$c_m$	$a_{m1}$	$\dots$	$\dots$	$a_{mj}$	$\dots$	$\dots$	$a_{mn}$

# Supervised Text Categorization

	Supervised	Semi-supervised	Unsupervised
Input Documents	Labeled documents	Labeled and Unlabeled Documents	Unlabeled documents
Method	Machine Learning / Statistical Approaches	Clustering / Machine Learning / Statistical Approaches	Clustering / SOM / Similarity
References	(Deng, Z. 2004) (Sebastiani F., 2003) (Yang, Y. & Pedrson, J. 1997)	(Zeng, et al. 2003) (Nigam, et al. 2000)	(Gliozzo, et al. 2005) (Zhao, Y. & Karypis, G. 2005)

# Learning Tree Categorization

Categorizing documents  
concerned with wheat



Document to categorize:  
CFP for CoNLL-2000

CoNLL-2000 CALL FOR PAPERS - Netscape

File Edit View Go Communicator Help

Back Forward Reload Home Search Netscape Print Security Stop

Bookmarks Location: <http://lcg-www.uia.ac.be/conll2000/cfp.html> What's Related

Google Instant Message WebMail People Yellow Pages Download New & Cool Channels RealPlayer

## CALL FOR PAPERS

# Fourth Computational Natural Language Learning Workshop

## CoNLL-2000

Lisbon, September 14, 2000

<http://lcg-www.uia.ac.be/conll2000/>

CoNLL is the yearly workshop organized by SIGNLL, the Association for Computational Linguistics Special Interest Group on Natural Language Learning.

The meeting will be held in conjunction with ICGI-2000, the International Conference on Grammar Inference (<http://vinci.inesc.pt/icgi-2000/>) and the Learning Language in Logic workshop (<http://www.iri.fr/~cn/LLL-2000>) in Lisbon on Thursday, September 14, 2000, and will feature a shared task competition about learning of chunking. There will be joint sessions with ICGI-2000 and the LLL workshop on topics of common interest. Previous CoNLL meetings were held in Madrid, Sydney, and Bergen.

We invite submissions of abstracts on all aspects of computational natural language learning, including

- Computational models of human language acquisition
- Computational models of the origins and evolution of language
- Machine learning methods applied to natural language processing tasks (speech processing, phonology, morphology, syntax, semantics, discourse processing, language engineering applications)
  - Symbolic learning methods (Rule Induction and Decision Tree Learning, Lazy Learning, Inductive Logic Programming, Analytical Learning, Transformation-based Error-driven Learning)
  - Biologically-inspired methods (Neural Networks, Evolutionary Computing)
  - Statistical methods (Bayesian Learning, HMM, maximum entropy, SNoW, Support Vector Machines )
  - Reinforcement Learning
  - Active learning, ensemble methods, meta-learning
- Computational Learning Theory analyses of language learning
- Empirical and theoretical comparisons of language learning methods
- Models of induction and analogy in Linguistics

A special session of the workshop will be devoted to a shared task: the identification of phrases (syntactic constituents) with machine learning methods, a task called chunking.

# Some predicted categories

Document Keywords - Netscape

File Edit View Go Communicator Help

Back Forward Reload Home Search Netscape Print Security Stop

Bookmarks Location: http://alchemist.ijz.si/yquint/yquint.exe What's Related

Google Instant Message WebMail People Yellow Pages Download New & Cool Channels RealPlayer

**Best Categories**

Rank	Prob.	Word [Weight]	Category Path
1.	1.00	LANGUAGE [0.0714]	/Computers_and_Internet/Software/Natural_Language_Processing/
		LANGUAGE [0.0714]	
		NATURAL [0.0714]	
2.	1.00	NATURAL LANGUAGE [0.0429]	/Computers_and_Internet/Internet/World_Wide_Web/Information_and_Documentation/
		PROCESSING [0.0286]	
		NATURAL [-0.0001]	
		PROCESSING [-0.0004]	
		LANGUAGE [-0.0014]	
3.	0.99	GROUP [0.0087]	/Computers_and_Internet/Supercomputing_and_Parallel_Computing/
		SEPTEMBER [0.0089]	
		PROCESSING [0.0041]	
4.	0.99	GROUP [0.0056]	/Computers_and_Internet/Mobile_Computing/
		SEPTEMBER [0.0087]	
		PROCESSING [0.0056]	
5.	0.99	GROUP [0.0056]	/Computers_and_Internet/Programming_Tools/Object_Oriented_Programming/Conferences/
		SEPTEMBER [0.0089]	
		PROCESSING [0.0041]	
6.	0.99	GROUP [0.0056]	/Computers_and_Internet/Information_and_Documentation/Product_Reviews/Buyer_s_Guides/Software/
		SEPTEMBER [0.0087]	
		PROCESSING [0.0041]	
7.	0.98	GROUP [0.0056]	/Computers_and_Internet/Graphics/
		SEPTEMBER [0.0087]	
		PROCESSING [0.0041]	
8.	0.98	GROUP [0.0055]	/Computers_and_Internet/Conventions_and_Conferences/
		SEPTEMBER [0.0087]	
		PROCESSING [0.0041]	
9.	0.97	GROUP [0.0055]	/Computers_and_Internet/Software/
		SEPTEMBER [0.0084]	
		PROCESSING [0.0041]	
10.	0.97	LEARNING [0.0022]	/Computers_and_Internet/Information_and_Documentation/
		SEPTEMBER [0.0084]	
		PROCESSING [0.0041]	
11.	0.95	SPECIAL [0.0121]	/Computers_and_Internet/Communications_and_Networking/Conferences/
		SEPTEMBER [0.0084]	
		PROCESSING [0.0041]	
12.	0.95	PROCESSING [0.0256]	/Computers_and_Internet/Internet/World_Wide_Web/Conferences/Past_Events/
		SPECIAL [0.0121]	
		SEPTEMBER [0.0084]	
13.	0.93	MAXIMUM [0.0019]	/Computers_and_Internet/Supercomputing_and_Parallel_Computing/Conferences/
		PROCESSING [0.0256]	
		SPECIAL [0.0121]	
14.	0.92	SUBMISSION [0.0857]	/Computers_and_Internet/Hardware/Peripherals/Modems/
		MAXIMUM [0.0019]	
		SUBMISSION [0.0857]	
15.	0.92	ANNOUNCEMENT [0.0019]	/Computers_and_Internet/Internet/World_Wide_Web/Announcement_Services/Robots/
		SUBMISSION [0.0857]	

Document Done

# PROBABILITY

## Part 4

- Introduction*
- Terminology*

# What Is Probability?

- A priori probability  $P(e)$ : The chance that e happens
- Conditional probability  $P(f | e)$ : The chance of f given e
- Joint probability  $P(e, f)$ : The chance of e and f both happening; If e and f are independent, then  $P(e, f) = P(e) * P(f)$ ; If e and f are dependent then  $P(e, f) = P(e) * P(f | e)$

For example, if e stands for “the first roll of the die comes up 5” and f stands for “the second roll of the die comes up 3,” then  $P(e, f) = P(e) * P(f) = 1/6 * 1/6 = 1/36$ .

$$\sum_e P(e) = 1$$

$$\sum_e P(e | f) = 1$$

# BASIC Probabilities

$$P(A \cup B) = \begin{cases} P(A) + P(B) & A \& B \text{ are not dependant} \\ P(A) + P(B) - P(A, B) & A \& B \text{ are dependant} \end{cases}$$

- For example, when drawing a single card at random from a regular deck of cards, the chance of getting a heart or a face card (J,Q,K) (or one that is both) is

$$\frac{13}{52} + \frac{12}{52} - \frac{3}{52} = \frac{22}{52}$$

A	$P(A) \in [0, 1]$
not A	$P(A') = 1 - P(A)$
A or B	$\begin{aligned} P(A \cup B) &= P(A) + P(B) - P(A \cap B) \\ &= P(A) + P(B) \quad \text{if A and B are mutually exclusive} \end{aligned}$
A and B	$\begin{aligned} P(A \cap B) &= P(A B)P(B) \\ &= P(A)P(B) \quad \text{if A and B are independent} \end{aligned}$
A given B	$P(A   B) = \frac{P(A \cap B)}{P(B)}$

# Inference Using Probability

	Toothache		¬Toothache	
	Catch	¬Catch	Catch	¬Catch
Cavity	0.108	0.012	0.072	0.008
¬Cavity	0.016	0.064	0.144	0.576

$$P(Cavity \vee Toothache) = 0.108 + 0.012 + 0.072 + 0.008 + 0.016 + 0.064 = 0.28$$

$$P(Cavity) = 0.108 + 0.012 + 0.072 + 0.008 = 0.2$$

$$P(Cavity | Toothache) = \frac{0.108 + 0.012}{0.108 + 0.012 + 0.016 + 0.064} = 0.6$$

$$P(\neg Cavity | Toothache) = \frac{0.016 + 0.064}{0.108 + 0.012 + 0.016 + 0.064} = 0.4$$




# Probability Density Function PDF

- Probability density function (pdf) is a function that represents a probability distribution in terms of integrals

$$\int_a^b f(x) dx$$



$$\int_{-\infty}^{\infty} f(x) dx = 1$$

$$\& \quad f(x) \geq 0$$



# Probability Density Function PDF

- The Summation is used with Discrete Data



# Conditional & Bayesian Probability

- Conditional probability is the probability of some event  $A$ , given the occurrence of some other event  $B$ ; it is written  $P(A|B)$ , and is read “the probability of  $A$ , given  $B$ ”

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

- Bayesian probability, the probability of a hypothesis given the data (the *posterior*), is proportional to the product of the likelihood times the prior probability (often just called the *prior*)
- The likelihood brings in the effect of the data, while the prior specifies the belief in the hypothesis before the data was observed

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

- If two variables  $A$  and  $B$  are independent

$$P(A \wedge B | C) = P(A | C)P(B | C)$$

# *Text Mining*

## *Part 5*

### *Preprocessing*

# Text Preprocessing

- Remove “fluff” if exists (e.g., ads, navigation bars, pictures, etc.)
  - Convert to plain text (i.e., from PDF, DOC, or other formats)
  - Check words correctness (in case of erroneous text or using OCR)
  - Handle tables, numbers, and equations

## • حذف التشكيل ( Removal of the Inflection )

## • حذف الرموز الخاصة ( / & # @ \$ \* % )

• حذف الأرقام

• تحويل همزات القطع إلى همزات وصل (أحمد احمد)

## • تحويل الألف اللينة إلى ألف العالية

## ● حذف الكلمات الزائدة Stop words

## Stop words

# Preprocessing: Sentence Splitter

## Sentence Splitting

- Sentences end with “.”, “!”, or “?”
- Difficult when a “.” do not indicate an EOS: “MR. X”, “3.14”, “Y Corp.”, etc.
- We can detect common abbreviations (“U.S.”), but what if a sentence ends with one? “... announced today by the U.S. The ...”

توجد نفس المشاكل في اللغة العربية:

● ”وقدم أ.د. إبراهيم إمام درس عن ...“

● الجمل في اللغة العربية تتدخل بصورة أكثر تعقيدا

Google n-gram corpus Statistics: <http://googleresearch.blogspot.com/2006/08/all-our-n-gram-are-belong-to-you.html#links> Size = 24 GB

Number of tokens:	1,024,908,267,229
Number of sentences:	95,119,665,584
Number of unigrams:	13,588,391
Number of bigrams:	314,843,401
Number of trigrams:	977,069,902
Number of fourgrams:	1,313,818,354
Number of fivegrams:	1,176,470,663

# Samples of Google n-gram Data

## 3-gram samples

## Freq.

ceramics collectables collectibles	55
ceramics collectables fine	130
ceramics collected by	52
ceramics collectible pottery	50
ceramics collectibles cooking	45
ceramics collection ,	144
ceramics collection .	247
ceramics collection </S>	120
ceramics collection and	43
ceramics collection at	52
ceramics collection is	68
ceramics collection of	76
ceramics collection	59
ceramics collections ,	66
ceramics collections .	60
ceramics combined with	46
ceramics come from	69
ceramics comes from	660
ceramics community ,	109
ceramics community .	212
ceramics community for	61
ceramics companies .	53
ceramics companies consultants	173
ceramics company !	4432
ceramics company ,	133
ceramics company .	92

## 4-gram samples

## Freq.

serve as the incoming	92
serve as the incubator	99
serve as the independent	794
serve as the index	223
serve as the indication	72
serve as the indicator	120
serve as the indicators	45
serve as the indispensable	111
serve as the indispensable	40
serve as the individual	234
serve as the industrial	52
serve as the industry	607
serve as the info	42
serve as the informal	102
serve as the information	838
serve as the informational	41
serve as the infrastructure	500
serve as the initial	5331
serve as the initiating	125
serve as the initiation	63
serve as the initiator	81
serve as the injector	56
serve as the inlet	41
serve as the inner	87
serve as the input	1323
serve as the inputs	189

# Preprocessing: Word Tokenizers

Tokenization is difficult: For example,

“John’s sick” shall we split “John’s” into one token or two?

If one ! problems in parsing (where’s the verb?)

If two ! what do we do with John’s house?

فى اللغة العربية توجد مشاكل أكثر تعقيدا من ذلك

مثلا:

- جملة “يلعبونها في الملاعب” عند حذف السوابق واللواحق يتبقى “لعب” وتم حذف الفاعل “هم” والمفعول به “هي”

أيضا إذا كان الكلام يحتوى على تركيبة كيميائية، أو هيكل خاصة بالعلوم:

1,4--xylanase II from Trichoderma reesei

When N-formyl-L-methionyl-L-leucyl-L-phenylalanine (fMLP) was injected. . .

Technetium-99m-CDO-MeB [Bis[1,2-cyclohexanedionedioximato(1)-O]-[1,2-cyclohexanedione dioximato(2)-O]methyl-borato(2)-

N,N0,N00,N000,N0000,N00000)-

chlorotechnetium) belongs to a family of compounds. . .

# Preprocessing: Morphological Analyzers

## Morphological Analyzer

- Reflects changes in case, gender, number, tense, etc.  
give → gives, gave, given
- Stemming reduce words to a base form
- Lemmatization reduce words to their lemma (root)

التحليل الصرفى لكلمة: الفلاحة

الكلمة	النوع	السوابق	اللواحق	الساق	الجذر	الوزن	الجنس	معرف	إنسانى
الفلاحة	مصدر	ال	ة	فلاح	فلح	فعال	مؤنث	✓	✓

## Advantages of Using the Stem as a Word Representative:

- Simple and Fast

## Disadvantages of Using the Stem as a Word Representative:

- Can create words that do not exist in the language, e.g., computers → comput
- Often reduces different words to the same stem, e.g., army, arm → arm;  
stocks, stockings → stock

# Preprocessing: Morphological Analyzers (Cont.)

## **Advantages of Using the Root as a Word Representative:**

- The root is an actual word
- Usually provide better accuracy than the stem

## **Disadvantages of Using the Root as a Word Representative:**

- Significantly complex
- Requires language dependent resources

Get a copy of Porter stemmer (For English) at:

<http://www.tartarus.org/~martin/PorterStemmer/>

# Preprocessing: Part of Speech Tagging (POS)

- A Tagger algorithm assigns a tag for each word statistically
- calculated based on different word order probabilities

part of speech	function or "job"	example words	example sentences
<u>Verb</u>	action or state	(to) be, have, do, like, work, sing, can, must	EnglishClub.com <b>is</b> a web site. I <b>like</b> EnglishClub.com.
<u>Noun</u>	thing or person	pen, dog, work, music, town, London, teacher, John	This is my <b>dog</b> . He lives in my <b>house</b> . We live in <b>London</b> .
<u>Adjective</u>	describes a noun	a/an, the, 69, some, good, big, red, well, interesting	My dog is <b>big</b> . I like <b>big</b> dogs.
<u>Adverb</u>	describes a verb, adjective or adverb	quickly, silently, well, badly, very, really	My dog eats <b>quickly</b> . When he is <b>very</b> hungry, he eats <b>really</b> quickly.
<u>Pronoun</u>	replaces a noun	I, you, he, she, some	Tara is Indian. <b>She</b> is beautiful.
<u>Preposition</u>	links a noun to another word	to, at, after, on, but	We went <b>to</b> school <b>on</b> Monday.
<u>Conjunction</u>	joins clauses or sentences or words	and, but, when	I like dogs <b>and</b> I like cats. I like cats <b>and</b> dogs. I like dogs <b>but</b> I don't like cats.
<u>Interjection</u>	short exclamation, sometimes inserted into a sentence	oh!, ouch!, hi!, well	<b>Ouch!</b> That hurts! <b>Hi!</b> How are you? <b>Well</b> , I don't know.

# Preprocessing: Part of Speech Tagging (POS)

Verb	Noun	Verb
work!	John	works.

Pronoun	Verb	Noun	Noun	Verb	Verb
He	loves	cats.	John	is	working.

Noun	Verb	Noun	Adverb	Noun	Verb	Adjective	Noun
Ahmed	speaks	French	well.	cats	like	nice	children.

Pronoun	Verb	Preposition	Adjective	Noun	Adverb
She	ran	to	the	station	quickly.


Pronoun	Verb	Adjective	Noun	Conjunction	Pronoun	Verb	Pronoun
She	likes	big	snakes	but	I	hate	them.

Interjection	Pronoun	Conjunction	Adjective	Noun	Verb	Prep.	Noun	Adverb
Well,	she	and	young	John	walk	to	school	Slowly.

# Preprocessing: Syntactic Analysis


- **Parsing:** generating a parse tree for the given sentence (needs a grammar, and a lexicon)
- **Chunking:** finding syntactic constituents like Noun Phrases (NPs) or Verb Groups (VGs) within a sentence

- Parse trees can help in determining relationships such as:  
Who invented X?  
What company created product Y?  
Which organism is this protein coming from?
- Chunks are very useful in finding named entities (NEs), e.g., Persons, Companies, Locations, Patents, Organisms,




A Parse Tree

# Another Example of a Parse Tree



# AL-IMAM Database



# AL-IMAM Database

Arabic-English Dictionary			Arabic Morphological Analysis							English Synonyms				
A_ID	A_Word	E_Trans.	A_ID	Type	Root	Stem	Prefix	Suffix	Weigh.	E_ID	Synonym			
247	الزراعة	Planting	247	مصدر	فلاح	فلاح	الـ	ةـ	فعل	978	Farming			
248	الفاكهة	Farmer	Arabic Categorization (Learned)							978	Cultivating			
249	الزراعة	Success	A_ID	Category	%	Disamb.	W_Code			978	Agriculture			
English-Arabic Dictionary			247	زراعة	70	5%	TBD			978	Tilling			
E_ID	E_Word	A_Trans.	247	إنسان	5	?	TBD			Arabic Synonyms				
978	Planting	زراعة	247	الريف	25	10%	TBD			A_ID	Synonym			
Word Path in English Tree			English-Tree Titles			Arabic Tree Titles			247	زراعة				
E_ID	Tree Key		E.T_ID	Title		A.T_ID	Title		247	زراعة				
978	1.4.11.33.76.128.591		1	Action		1	شيء		Arabic Tree Links					
Human Factors				4	Group Action		3	شيء معنوي		A_ID	Tree Key			
ID	Ani	ID	Gen.	11	Commerce Trans.		10	مأكولات		247	1.3.10.31.65.97.154			
274	Y	274	F	33	Industry		31	زراعة		SUMO Category				
Word Information				76	Production		65	محاصيل زراعية		Code	SUMO Categ.			
ID	S/D/P	ID	Def.	128	Cultivation		97	متطلبات زراعية		10837	Subsuming Mapping (Putting)			
274	S	274	Y	591	Farming		154	أشخاص		4773				
WordNet Meaning				978	Planting		WordNet Sense (Glosses)							
978	108374773	putting seeds or young plants in the ground to grow				978	the planting of com is hard work							

# STATISTICS

## Part 6

### *Introduction*

# Statistics

- Statistics is a Mathematical Science pertaining to the *collection, analysis, interpretation or explanation, and presentation* of data

# Statistical Terminologies

- Measures of Central Tendency (Mean, Median, Mode)
- Population Variance measures statistical dispersion of data points from the expected value (mean)
- Standard Deviation is a measure of the variability or dispersion of a population; Low SD indicates very close data points to the mean; High SD indicates spread out data points
- Covariance measures how much two variables change together
- Correlation (coefficient) indicates the strength and direction of a *linear* relationship between two random variables

$$\bar{x} = (1/n) \sum_{i=1}^n x_i$$

$$\begin{aligned}Var(X) &= E[(X - E(X))^2] \\&= (1/n) \sum_{i=1}^n (x_i - \bar{x})^2 = \sigma^2\end{aligned}$$

$$sd(X) = \sqrt{\sigma^2}$$

$$Cov(X, Y) = E[(X - E(X))(Y - E(Y))]$$

$$Corr(X, Y) = \frac{Cov(X, Y)}{sd(X) * sd(Y)} = \frac{\sigma_{xy}}{\sigma_x \sigma_y}$$


# Popular Distributions

Probability Distribution identifies the probability of each value of an unidentified random variable


- *Uniform Distribution*
- *Normal (Gaussian) Distribution*
- *Chi-Square Distribution*
- *Exponential Distribution*
- *Poisson Distribution*
- *T Distribution*
- *F Distribution*

# The Uniform Distribution

- The probability is equal for all outcomes
- Suppose a fair dice is thrown, the probability of getting any of its 6 faces equal to  $1/6$
- The area under the line equal to 1




# The Normal/Gaussian Distribution




$$P(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

# The Chi-Square Distribution




$$f(x; k) = \begin{cases} \frac{1}{2^{k/2} \Gamma(k/2)} x^{(k/2)-1} e^{-x/2} & \text{for } x > 0 \\ 0 & \text{for } x \leq 0 \end{cases}$$

# The Exponential Distribution




$$f(x; \lambda) = \begin{cases} \lambda e^{-\lambda x} & \text{for } x > 0 \\ 0 & \text{for } x \leq 0 \end{cases}$$

# The Poisson Distribution



$$f(k; \lambda) = \frac{\lambda^k e^{-\lambda}}{k!}$$


# The T Distribution



$$f(t) = \frac{\Gamma(\frac{v+1}{2})}{\sqrt{v\pi}\Gamma(\frac{v}{2})} \left(1 + \frac{t^2}{v}\right)^{-(v+1)/2}$$


$t$ -distribution arises in the problem of estimating the mean of a normally distributed population when the sample size is small

# The F Distribution



$$f(x) = \frac{\sqrt{\frac{(d_1 x)^{d_1} d_2^{d_2}}{(d_1 x + d_2)^{d_1 + d_2}}}}{x B\left(\frac{d_1}{2}, \frac{d_2}{2}\right)}$$

# Fitting Chi-Square



Vector  
a

15
14
11
11
6
5
5

$$\max \quad \chi^2 = \sum_{i=1}^n \frac{(a_i - E_i)^2}{E_i}$$

$$E_{ij} = (15 + 14 + 11 + 11 + 6 + 5 + 5) / 7 = 9.57$$

$$\begin{aligned} \chi^2 = & (1/9.57) * ((15-9.57)^2 + (14-9.57)^2 + (11-9.57)^2 + (11-9.57)^2 + \\ & (6-9.57)^2 + (5-9.57)^2 + (5-9.57)^2) = 107.71/9.57 = 11.26 \end{aligned}$$

# *Measuring Term-Category Correlation*

$$\chi^2(t_k, c_i) = \frac{[P(t_k, c_i)P(\bar{t}_k, \bar{c}_i) - P(t_k, \bar{c}_i)P(\bar{t}_k, c_i)]^2}{P(t_k)P(\bar{t}_k)P(c_i)P(\bar{c}_i)}$$

$P(t_k, c_i)$  → probability document x contains term t and belongs to category c.

$P(\bar{t}_k, c_i)$  → probability document x does not contain term t and belongs to category c.




$P(t_k, \bar{c}_i)$  → probability document x contains term t and does not belong to category c.

$P(\bar{t}_k, \bar{c}_i)$  → probability document x does not contain term t and does not belong to category c.

$P(t)$  → probability of term t

$P(c)$  → probability of category c

# Testing The Membership



$$\chi^2(t_k, c_i) = \frac{[P(t_k, c_i)P(\bar{t}_k, \bar{c}_i) - P(t_k, \bar{c}_i)P(\bar{t}_k, c_i)]^2}{P(t_k)P(\bar{t}_k)P(c_i)P(\bar{c}_i)}$$

$$\chi^2(t_1, Sports) = \frac{\left[ \frac{1}{9} * \frac{17}{18} - \frac{1}{18} * \frac{8}{9} \right]^2}{\frac{2}{27} * \frac{25}{27} * \frac{9}{27} * \frac{18}{27}}$$

# *Using Chi-Square for Categorization*

Another Example:

Term	Frequency per Category				Total
	Communication	Phone	Business	Army	
Link	15	6	2	12	35
Wire	10	12	0	8	30
<b>Total</b>	<b>25</b>	<b>18</b>	<b>2</b>	<b>20</b>	<b>65</b>

$$\chi^2(\text{link}, \text{phone}) = \frac{[6/65] * (18/65) - (29/65) * (12/65)]^2}{(35/65) * (30/65) * (18/65) * (47/65)}$$

## Using Chi-Square for Multiple sets of Terms

Group 1	Category		Total
	News	Sports	
Term 1	3	2	5
Term 2	0	4	4
Term 3	2	3	5
Total	5	9	14

Group 2	Category		Total
	News	Sports	
Term 5	1	3	4
Term 7	4	6	10
Total	5	9	14

$$\chi^2 = \sum_{i=1}^n \sum_{j=1}^m \frac{(a_{ij} - E_{ij})^2}{E_{ij}}$$

$$E_{ij} = \frac{(T_{ci} * T_{vj})}{T}$$

$$\begin{aligned}\chi^2(\text{Group 1}) &= (3-1.78)^2 / 1.78 + (2-3.21)^2 / 3.21 + (0-1.42)^2 / 1.42 \\ &\quad + (4-2.57)^2 / 2.57 + (2-1.78)^2 / 1.78 + (3-3.21)^2 / 3.21 = 3.62\end{aligned}$$

$$\begin{aligned}\chi^2(\text{Group 2}) &= (1-1.42)^2 / 1.42 + (3-2.57)^2 / 2.57 + (4-3.57)^2 / 3.57 \\ &\quad + (6-6.43)^2 / 6.43 =\end{aligned}$$

# *Attribute Selection Criteria: Chi-Square*

## Example

- T2 is quantized into two intervals  $\leq 21$  ( $T2 \leq 21$ ) and ( $T2 > 21$ )
- T3 is quantized into two intervals  $\leq 15$  ( $T3 \leq 15$ ) and ( $T3 > 15$ )

T2	Decision D		Total
	0	1	
$\leq 21$	1	3	4
$> 21$	4	6	10
Total	5	9	14

T1	Decision D		Total
	0	1	
1	3	2	5
2	0	4	4
3	2	3	5
Total	5	9	14

T3	Decision D		Total
	0	1	
$\leq 15$	1	4	5
$> 15$	4	5	9
Total	5	9	14

T4	Decision D		Total
	0	1	
A	3	3	6
B	2	6	8
Total	5	9	14

T1	T2	T3	T4	D
1	25	10	A	1
1	30	30	A	0
1	35	25	B	0
1	22	35	B	0
1	19	10	B	1
2	22	30	A	1
2	33	18	B	1
2	14	5	A	1
2	31	15	B	1
3	21	20	A	0
3	15	10	A	0
3	25	20	B	1
3	18	20	B	1
3	20	36	B	1

## Attribute Selection Criteria: Chi-Square

$$\chi^2(A) = \sum_{i=1}^n \sum_{j=1}^m \frac{(a_{ij} - E_{ij})^2}{E_{ij}}$$

where A is the attribute to be evaluated against the decision attribute, n is the number of distinct values of A, m is the number of distinct values of the decision attribute,  $a_{ij}$  is the correlation frequency of value number i from A and value number j from the decision attribute;

$$E_{ij} = \frac{(T_{ci} * T_{vj})}{T}$$

where  $T_{ci}$  is the total number of examples belonging to class  $c_i$ ,  $T_{vj}$  is the number of examples containing the value  $v_j$  of the given attribute

$$\begin{aligned}\chi^2(T1) &= (3-1.78)^2 / 1.78 + (2-3.21)^2 / 3.21 + (0-1.42)^2 / 1.42 \\ &\quad + (4-2.57)^2 / 2.57 + (2-1.78)^2 / 1.78 + (3-3.21)^2 / 3.21 = 3.62\end{aligned}$$

$$\begin{aligned}\chi^2(T4) &= (3-3.9)^2 / 3.9 + (3-2.1)^2 / 2.1 + (6-5.1)^2 / 5.1 \\ &\quad + (2-2.9)^2 / 2.9 = 1.1\end{aligned}$$

T1	D		Total
	0	1	
1	3	2	5
2	0	4	4
3	2	3	5
Total	5	9	14

T2	D		Total
	0	1	
$\leq 21$	1	3	4
$> 21$	4	6	10
Total	5	9	14

T3	D		Total
	0	1	
$\leq 15$	1	4	5
$> 15$	4	5	9
Total	5	9	14

T4	D		Total
	0	1	
A	3	3	6
B	2	6	8
Total	5	9	14

# STATISTICS

## Part 7

*Regression*

# Linear Regression


- The linear model states that the dependent variable is directly proportional to the value of the independent variable
- Thus if a theory implies that Y increases in direct proportion to an increase in X, it implies a specific mathematical model of behavior

$$y = ax + b$$

In case of two dimensions

$$a = \text{slope} = \frac{(y_2 - y_1)}{(x_2 - x_1)}$$

$$b = y_2 - \text{slope} * x_2$$




# Linear Regression

$$y = ax + b$$

$$8 = 6a + b \quad \& \quad 4 = 3a + b$$

$$\frac{8-b}{6} = a \quad \& \quad 4 = 3 * \frac{8-b}{6} + b$$

$$b = 0 \quad \& \quad a = \frac{4}{3} = 1.333$$



$$b = 4 - \frac{4}{3} * 3 = 0$$


# Linear Regression

$$y = ax + b$$

$$6 = a + b \quad \& \quad 2 = 3a + b$$

$$6 - b = a \quad \& \quad 2 = 3*(6 - b) + b$$


$$b = 8 \quad \& \quad a = 6 - 8 = -2$$



$$\text{Slope} = \frac{6-2}{1-3} = \frac{4}{-2} = -2$$

$$b = 2 + 2 * 3 = 8$$

# Linear Regression





# Statistics and Testing

## Part 8

*Testing Samples &  
Calculating Accuracy*

# *Training & Testing*




# Testing Approaches

## ● Two-Cross-Fold

Train on 2/3<sup>rd</sup>

Test on 1/3<sup>rd</sup>



## ● Ten-Cross-Fold

Train on 9/10<sup>th</sup>


Test on 1/10<sup>th</sup>

Repeat 10 times

## ● Hold-One-Out

Train on all data but one

Test on the selected one




## ● Learning Evaluation vs. Testing

Train on Training Data

Evaluate on Evaluation Data

Test on Testing Data



# Accuracy & Error

Example: Suppose you have a classification model C, and 100 testing records from two classes (P & N). Suppose the following are the classification results:

## ● Accuracy vs. Error Rate

- Accuracy =  $(40+45)/100 = 85\%$
- Error Rate =  $(10+5)/100 = 15\%$

		Actual	
		P	N
Obtained	P	TP	FP
	N	FN	TN

## ● True vs. False Classification

- True Positive: = 88.88%
- True Negative: = 81.82%
- False Positive: = 11.12%
- False Negative: = 18.18%

		Actual	
		P	N
Obtained	P	40	10
	N	5	45

## ● Flexible Matching

- *Using Nearest Neighbors (e.g., majority of nearest 3 neighbors)*
- Using Fuzzy rules (assigning probability for each decision and taking it into consideration when calculating the accuracy)
- Assigning small weights for the false positive and false negative results (not zero)

## ● Testing for Multiple Classes ????

# *Precision, Recall, and F-Measure*

Accuracy: is the percentage of correct results

Error: is the percentage of wrong results

Accuracy only reacts to real errors, and doesn't show how many correct results have been found as such

## Precision:

Precision shows the percentage of correct results within an answer:

$$\text{Precision} = (tp) / (tp + fp)$$

## Recall:

Recall is the percentage of the correct system results over all correct results:

$$\text{Recall} = (tp) / (tp + fn)$$

*Makhoul, John; Francis Kubala; Richard Schwartz; Ralph Weischedel: [Performance measures for information extraction](#). In: Proceedings of DARPA Broadcast News Workshop, Herndon, VA, February 1999*

## *Precision, Recall, and F-Measure*

Precision and Recall can be defined differently for different tasks

For example: In Information Retrieval,

- Recall =  $|\{\text{relevant documents}\} \cap \{\text{documents retrieved}\}| / |\{\text{relevant documents}\}|$
- Precision =  $|\{\text{relevant documents}\} \cap \{\text{documents retrieved}\}| / |\{\text{documents retrieved}\}|$

# *Precision, Recall, and F-Measure*

F-Measure (harmonic mean):

$F_\beta$  “measures the effectiveness of  $\beta$  times as much importance to recall as precision”. The general form of F-Measure:

$$F_\beta = \frac{(1 + \beta^2) * (\text{precision} * \text{recall})}{(\beta^2 * \text{precision} + \text{recall})}$$

when  $\beta=1$ ,

$$F_1 = \frac{2 * (\text{precision} * \text{recall})}{(\text{precision} + \text{recall})}$$

# STATISTICS

## Part 9


*Test of Significance*

# Test of Significance (1/5)

- The probability that a result is not due to chance; or Is the observed value differs enough from a hypothesized value?
- The hypothesized value is called the null hypothesis
- If this probability is sufficiently low, then the difference between the parameter and the statistic is said to be "statistically significant"
- Just how low is sufficiently low? The choice of 0.05 and 0.01 are most commonly used

- Suppose your algorithm produced error rate of 1.5 and another algorithm produced an error of 2.1 on the same data set; are the two algorithms similar?

## Test of Significance (2/5)



- The top ends of the bars indicate observation means
- The red line segments represent the confidence intervals surrounding them
- The difference between the two populations on the left is significant
- However, it is a common misconception to suppose that two parameters whose 95% confidence intervals fail to overlap are significantly different at the 5% level

## Test of Significance (3/5)


- The system you are comparing against reported results of 250; the value reported is considered as a random variable X; the distribution of X is assumed as normal distribution with unknown mean and standard deviation  $\sigma=2.5$ ; You ran your system 25 times; it reported values ( $x_1, x_2, \dots, x_{25}$ ); the average of these values is 250.2.

$$\hat{\mu} = \bar{X} = \frac{1}{n} \sum_{i=1}^{25} x_i = 250.2 \quad \text{Sample Mean}$$

$$\text{Standard Error} = \sigma / \sqrt{n} = 2.5 / \sqrt{25} = 0.5 \quad n \text{ is the sample size}$$

$$Z = \frac{\bar{X} - \mu}{\sigma / \sqrt{n}} = \frac{\bar{X} - \mu}{0.5} \quad \mu \text{ is not known}$$

## Test of Significance (4/5)



$$P(-z \leq Z \leq z) = 1 - \alpha = 0.95$$

$$\Phi(z) = P(Z \leq z) = 1 - \frac{\alpha}{2} = 0.975$$

From Tables

$$z = \Phi^{-1}(\Phi(z)) = \Phi^{-1}(0.975) = 1.96$$

$$0.95 = 1 - \alpha = P(-z \leq Z \leq z) = P\left(-1.96 \leq \frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \leq 1.96\right)$$

## Test of Significance (5/5)

$$P(-z \leq Z \leq z) = P(\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + 1.96 \frac{\sigma}{\sqrt{n}})$$

$$P(-z \leq Z \leq z) = P(\bar{X} - 1.96 * 0.5 \leq \mu \leq \bar{X} + 1.96 * 0.5)$$

$$P(-z \leq Z \leq z) = P(\bar{X} - 0.98 \leq \mu \leq \bar{X} + 0.98)$$

$$\text{Our Interval} = (250.2 - 0.98; 250.2 + 0.98)$$

$$\text{Our Interval} = (249.22; 251.0)$$

- Any value within this interval is not significant

# The Information Theory

## Part 9

*Introduction  
Entropy*

# The Information Theory

The information conveyed by a message can be measured in bits by its probability

# *The Information Theory: Given Data*

*Attributes:*

$D1, D2, D3, D4$

$Domain(D1)=\{1,2,3\}$

$Domain(D2)=\{1,2\}$

$Domain(D3)=\{1,2\}$

$Domain(D4)=\{A,B\}$

D1	D2	D3	D4	D5
1	2	1	A	1
1	2	2	A	0
1	2	2	B	0
1	2	2	B	0
1	1	1	B	1
2	2	2	A	1
2	2	2	B	1
2	1	1	A	1
2	2	1	B	1
3	1	2	A	0
3	1	1	A	0
3	2	2	B	1
3	1	2	B	1
3	1	2	B	1

*Decision Attributes: D5*

$Domain(D5)=\{0,1\}$

*Two Decisions: 0, 1*

# The Information Theory: Given Data

		D1		2		3	
		1		2		3	
D4	D3\ D2	1	2	1	2	1	2
A	1		1	1		0	
	2		0		1	0	
B	1	1	1		1		
	2	0		1		1	

D1	D2	D3	D4	D5
1	2	1	A	1
1	2	2	A	0
1	2	1	B	0
1	2	2	B	0
1	1	1	B	1
2	2	2	A	1
2	2	2	B	1
2	1	1	A	1
2	2	1	B	1
3	1	2	A	0
3	1	1	A	0
3	2	2	B	1
3	1	1	B	1
3	1	2	B	1

## *The Information Theory: Entropy*

THE INFORMATION THEORY: information conveyed by a message depends on its probability and can be measured in bits as minus the logarithm (base 2) of that probability

suppose  $D_1, \dots, D_m$  are  $m$  attributes and  $C_1, \dots, C_n$  are  $n$  decision classes in a given data. Suppose  $S$  is any set of cases, and  $T$  is the initial set of training cases  $S \subset T$ . The frequency of class  $C_i$  in the set  $S$  is:

$$freq(C_i, S) = \text{Number of examples in } S \text{ belonging to } C_i$$

If  $|S|$  is the total number of examples in  $S$ , the probability that an example selected at random from  $S$  belongs to class  $C_i$  is

$$freq(C_i, S) / |S|$$

The information conveyed by the message that “a selected example belongs to a given decision class,  $C_i$ ”, is determined by

$$-\log_2(freq(C_i, S) / |S|) \text{ bits}$$

# *The Information Theory: Entropy*

The information conveyed by the message “a selected example belongs to a given decision class,  $C_i$ ”

$$-\log_2(freq(C_i, S) / |S|) \text{ bits}$$

**The Entropy:** The expected information from a message stating class membership is given by

$$Info(S) = -\sum_{i=1}^k (freq(C_i, S) / |S|) * \log_2(freq(C_i, S) / |S|) \text{ bits}$$

$info(S)$  is known as the **entropy** of the set  $S$ . When  $S$  is the initial set of training examples,  $info(S)$  determines the average amount of information needed to identify the class of an example in  $S$ .

# The Information Theory: The Gain Ratio

S

## Example

$$freq(0, S) = 5$$

$$freq(1, S) = 9$$

$$freq(0, S) / |S| = 5/14$$

$$freq(1, S) / |S| = 9/14$$

The Entropy: the average amount of information needed to identify the class of an example in S

$$Info(S) = -9/14 * \log_2(9/14) - 5/14 * \log_2(5/14) = 0.94 \text{ bits}$$

Using D<sub>1</sub> to Split the data provide 3 subsets of data

$$Info_{D_1}(S_1) = -3/5 * \log_2(3/5) - 2/5 * \log_2(2/5) = 0.94$$

$$Info_{D_1}(S_2) = -4/4 * \log_2(4/4) = 0.94$$

$$Info_{D_1}(S_3) = -2/5 * \log_2(2/5) - 3/5 * \log_2(3/5) = 0.94$$

$$Info_{D_1}(S) = (5/14) * Info_{D_1}(S_1) + (4/14) * Info_{D_1}(S_2) + (5/14) * Info_{D_1}(S_3) = 0.694$$

D1	D2	D3	D4	D5
1	2	1	A	1
1	2	2	A	0
1	2	2	B	0
1	2	2	B	0
1	1	1	B	1
2	2	2	A	1
2	2	2	B	1
2	1	1	A	1
2	2	1	B	1
3	1	2	A	0
3	1	1	A	0
3	2	2	B	1
3	1	2	B	1
3	1	2	B	1

## *The Information Theory: The Gain Ratio*

Suppose attribute  $D_i$  is selected to be the root and it has  $k$  possible values. The expected information of selecting  $D$  to partition the training set  $S$ ,  $\text{info}_{D_i}(S)$ , can be calculated as follows:

$$\text{Info}_{D_i}(S) = \sum_{i=1}^k \left( \frac{|S_i|}{|S|} \right) * \text{Info}(S_i)$$

$S_i$  is the subset number  $i$  of the data;  $k$  is the number of values of  $D_i$

The information gained by partitioning the training examples  $S$  into subset using the attribute  $D_1$  is given by

$$\text{Gain}(D_i) = \text{Info}(S) - \text{Info}_{D_i}(S)$$

## *The Information Theory: The Gain Ratio*

The attribute to be selected is the attribute with maximum gain value. Quinlan found out that a key attribute will have the maximum gain. This is not good!

$$Split\_Info(S) = - \sum_{i=1}^k (|S_i| / |S|) * \log_2(|S_i| / |S|)$$

The gain ratio is given by:

$$Gain\_Ratio(D_i) = Gain(D_i) / Split\_Info(D_i)$$

# The Information Theory: The Gain Ratio

## Example Cont.

$$\begin{aligned} Info_{D_1}(S) &= \left(\frac{5}{14}\right) * Info_{D_1}(S_1) + \left(\frac{4}{14}\right) * Info_{D_1}(S_2) \\ &\quad + \left(\frac{5}{14}\right) * Info_{D_1}(S_3) = 0.694 \end{aligned}$$

$$Gain(D_1) = 0.94 - 0.694 = 0.246$$

$$\begin{aligned} Split\_Info(S) &= -\frac{5}{14} \log_2(5/14) - \frac{4}{14} \log_2(4/14) \\ &\quad - \frac{5}{14} \log_2(5/14) = 1.577 \text{ bits} \end{aligned}$$

$$Gain\_Ratio(D_1) = 0.246 / 1.577 = 0.156$$

**S**

D1	D2	D3	D4	D5
1	2	1	A	1
1	2	2	A	0
1	2	2	B	0
1	2	2	B	0
1	1	1	B	1
2	2	2	A	1
2	2	2	B	1
2	1	1	A	1
2	2	1	B	1
3	1	2	A	0
3	1	1	A	0
3	2	2	B	1
3	1	2	B	1
3	1	2	B	1

# *Information Gain: Term vs. Category*

It measures the classification power of a term

$$IG(t_k, c_i) = \sum_{c \in \{c_i, \bar{c}_i\}} \sum_{t \in \{t_k, \bar{t}_k\}} P(t, c) \log_2 \frac{P(t, c)}{P(t)P(c)}$$

$P(t_k, c_i)$  → probability document x contains term t and belongs to category c.

$P(\bar{t}_k, c_i)$  → probability document x does not contain term t and belongs to category c.

$P(t_k, \bar{c}_i)$  → probability document x contains term t and does not belong to category c.


$P(\bar{t}_k, \bar{c}_i)$  → probability document x does not contain term t and does not belong to category c.

$P(t)$  → probability of term t.


$P(c)$  → probability of category c.

# Testing The Membership


Sports



Economy



Military



$$IG(t_k, c_i) = \sum_{c \in \{c_i, \bar{c}_i\}} \sum_{t \in \{t_k, \bar{t}_k\}} P(t, c) \log_2 \frac{P(t, c)}{P(t)P(c)}$$

$$IG(t_1, sport) = \frac{1}{9} * \log_2 \frac{1/9}{(2/27)*(9/27)} + \frac{8}{9} * \log_2 \frac{8/9}{(25/27)*(9/27)} \\ + \frac{1}{18} * \log_2 \frac{1/18}{(2/27)*(18/27)} + \frac{17}{27} * \log_2 \frac{17/27}{(25/27)*(18/27)}$$

# The Gain Ratio

$$GR(t_k, c_i) = \frac{\sum_{c \in \{c_i, \bar{c}_i\}} \sum_{t \in \{t_k, \bar{t}_k\}} P(t, c) \log_2 \frac{P(t, c)}{P(t)P(c)}}{- \sum_{c \in \{c_i, \bar{c}_i\}} P(c) \log_2 P(c)}$$

$P(t_k, c_i)$  → probability document x contains term t and belongs to category c.

$P(\bar{t}_k, c_i)$  → probability document x does not contain term t and belongs to category c.

$P(t_k, \bar{c}_i)$  → probability document x contains term t and does not belong to category c.

$P(\bar{t}_k, \bar{c}_i)$  → probability document x does not contain term t and does not belong to category c.

$P(t)$  → probability of term t.

$P(c)$  → probability of category c.

## STATISTICAL ASSOCIATIONS

### Part II

*Association Rules*  
*<http://giwebb.com/>*

# The Magnum Opus System

M Magnum Opus - Tutorial.data

File Edit Modes Action Preferences View Help

Search for: RULES      Search by: LEVERAGE      Filter out: INSIGNIFICANT

Maximum no.: 100      Maximum size: 4

Minimum leverage: -1.0      Minimum strength: 0.0

Minimum coverage: 0.0      Minimum lift: 0.0

Minimum support: 0.0       Use m-estimate

Tutorial.data: 500 cases / 500 holdout cases / 39 values

Values allowed on LHS:

- Profitability99<438
- 438<=Profitability99<=931
- Profitability99>931
- Profitability98<368
- 368<=Profitability98<=754
- Profitability98>754
- Spend99<2200
- 2200<=Spend99<=4464
- Spend99>4464
- Spend98<1927
- 1927<=Spend98<=4088
- Spend98>4088
- NoVisits99<37
- 37<=NoVisits99<=69
- NoVisits99>69
- NoVisits98<33
- 33<=NoVisits98<=66
- NoVisits98>66
- Dairy<250

Values allowed on RHS:

- Profitability99<438
- 438<=Profitability99<=931
- Profitability99>931
- Profitability98<368
- 368<=Profitability98<=754
- Profitability98>754
- Spend99<2200
- 2200<=Spend99<=4464
- Spend99>4464
- Spend98<1927
- 1927<=Spend98<=4088
- Spend98>4088
- NoVisits99<37
- 37<=NoVisits99<=69
- NoVisits99>69
- NoVisits98<33
- 33<=NoVisits98<=66
- NoVisits98>66
- Dairy<250

Ready

Attributes and their values for the Tutorial database

- Profitability99: numeric 3
- Profitability98: numeric 3
- Spend99: numeric 3
- Spend98: numeric 3
- NoVisits99: numeric 3
- NoVisits98: numeric 3
- Dairy: numeric 3
- Deli: numeric 3
- Bakery: numeric 3
- Grocery: numeric 3
- SocioEconomicGroup: categorical
- Promotion1: t, f
- Promotion2: t, f

# *The Magnum Opus System: Example*

bananas  
plums, lettuce, tomatoes  
celery, confectionery  
confectionery  
apples, carrots, tomatoes, potatoes  
potatoes  
confectionery  
carrots  
confectionery  
apples, oranges, lettuce, tomatoes  
peaches, oranges, celery, potatoes, confectionery  
beans  
oranges, lettuce, carrots, tomatoes  
apples, bananas, plums, carrots, tomatoes, onions,  
confectionery  
apples, potatoes  
lettuce, peas, beans  
carrots, tomatoes  
grapes, plums, lettuce, beans, potatoes, onions  
confectionery  
confectionery  
carrots, peas, potatoes, onions, confectionery  
tomatoes  
confectionery  
carrots, potatoes  
peaches, apples, bananas  
lettuce, beans, tomatoes, potatoes, confectionery  
grapes, lettuce, tomatoes, confectionery  
oranges

oranges, lettuce, confectionery  
tomatoes  
lettuce, carrots, tomatoes, confectionery  
celery, potatoes, confectionery  
oranges, carrots, beans, potatoes  
peaches, oranges, bananas  
lettuce, carrots, tomatoes, potatoes, onions  
onions  
peaches, apples, lettuce, peas, potatoes, onions  
oranges, carrots, confectionery  
bananas  
lettuce, carrots, tomatoes, potatoes  
carrots, confectionery  
oranges, plums  
peaches, oranges, lettuce, peas  
lettuce, carrots, beans, tomatoes  
plums, lettuce, peas, tomatoes, potatoes  
carrots, tomatoes  
bananas, lettuce, onions, confectionery  
oranges, tomatoes  
oranges, potatoes  
confectionery  
oranges, plums, potatoes  
bananas, lettuce, carrots, tomatoes, potatoes  
potatoes  
lettuce, tomatoes, onions  
lettuce, onions  
apples, oranges, beans  
corn

# The Magnum Opus System

carrots -> tomatoes

[Coverage=0.175 (175); Support=0.085 (85);  
 Strength=0.486; Lift=1.85; Leverage=0.0390 (39.0);  
 p=1.83E-012]

bananas -> peaches

[Coverage=0.127 (127); Support=0.040 (40);  
 Strength=0.315; Lift=2.42; Leverage=0.0235 (23.5);  
 p=2.74E-009]

carrots -> potatoes

[Coverage=0.175 (175); Support=0.068 (68);  
 Strength=0.389; Lift=1.37; Leverage=0.0185 (18.5);  
 p=0.000575]

apples -> peaches

[Coverage=0.221 (221); Support=0.044 (44);  
 Strength=0.199; Lift=1.53; Leverage=0.0153 (15.3);  
 p=0.000635]

bananas & apples -> peaches


[Coverage=0.029 (29); Support=0.017 (17); Strength=0.586; Lift=4.51; Leverage=0.0132 (13.2); p=0.000540]

apples -> lettuce

[Coverage=0.221 (221); Support=0.058 (58); Strength=0.262; Lift=1.21; Leverage=0.0100 (10.0); p=0.0404]

carrots & beans -> potatoes

[Coverage=0.010 (10); Support=0.007 (7); Strength=0.700; Lift=2.47; Leverage=0.0042 (4.2); p=0.0420]



# *The Magnum Opus System: Example*

ID001, bananas	ID00e, apples
ID002, plums	ID00e, bananas
ID002, lettuce	ID00e, plums
ID002, tomatoes	ID00e, carrots
ID003, celery	ID00e, tomatoes
ID003, confectionery	ID00e, onions
ID004, confectionery	ID00e, confectionery
ID005, apples	ID00f, apples
ID005, carrots	ID00f, potatoes
ID005, tomatoes	ID010, lettuce
ID005, potatoes	ID010, peas
ID006, potatoes	ID010, beans
ID007, confectionery	ID011, carrots
ID008, carrots	ID011, tomatoes
ID009, confectionery	ID012, grapes
ID00a, apples	ID012, plums
ID00a, oranges	ID012, lettuce
ID00a, lettuce	ID012, beans
ID00a, tomatoes	ID012, potatoes
ID00b, peaches	ID012, onions
ID00b, oranges	ID013, confectionery
ID00b, celery	ID014, confectionery
ID00b, potatoes	ID015, carrots
ID00b, confectionery	ID015, peas
ID00c, beans	ID015, potatoes
ID00d, oranges	ID015, onions
ID00d, lettuce	ID015, confectionery
ID00d, carrots	ID016, tomatoes
ID00d, tomatoes	ID017, confectionery

# The Magnum Opus System

carrots -> tomatoes

[Coverage=0.175 (175); Support=0.085 (85);  
 Strength=0.486; Lift=1.85; Leverage=0.0390 (39.0);  
 p=1.83E-012]

bananas -> peaches

[Coverage=0.127 (127); Support=0.040 (40);  
 Strength=0.315; Lift=2.42; Leverage=0.0235 (23.5);  
 p=2.74E-009]

carrots -> potatoes

[Coverage=0.175 (175); Support=0.068 (68);  
 Strength=0.389; Lift=1.37; Leverage=0.0185 (18.5);  
 p=0.000575]

apples -> peaches

[Coverage=0.221 (221); Support=0.044 (44);  
 Strength=0.199; Lift=1.53; Leverage=0.0153 (15.3);  
 p=0.000635]

bananas & apples -> peaches


[Coverage=0.029 (29); Support=0.017 (17); Strength=0.586; Lift=4.51; Leverage=0.0132 (13.2); p=0.000540]

apples -> lettuce

[Coverage=0.221 (221); Support=0.058 (58); Strength=0.262; Lift=1.21; Leverage=0.0100 (10.0); p=0.0404]

carrots & beans -> potatoes

[Coverage=0.010 (10); Support=0.007 (7); Strength=0.700; Lift=2.47; Leverage=0.0042 (4.2); p=0.0420]



# *The Magnum Opus System: Example*

829, 709, 5250, 6560, 70, 82, 1074, 390, 878, 1995, C, f, f  
141, 118, 722, 928, 19, 16, 15, 155, 139, 404, C, f, f  
1044, 783, 3591, 4026, 63, 61, 81, 218, 232, 2908, D2, f, t  
78, 63, 331, 336, 7, 8, 54, 68, 63, 167, D1, t, f  
511, 419, 2142, 1947, 34, 33, 59, 106, 239, 1477, C, f, f  
987, 1402, 4032, 5376, 56, 64, 891, 681, 995, 1411, C, f, f  
313, 286, 1137, 1008, 22, 18, 153, 63, 146, 762, D1, t, f  
1800, 859, 7350, 3159, 75, 81, 441, 2315, 1433, 1837, D1, f, f  
226, 126, 1034, 612, 11, 6, 351, 377, 259, 196, C, f, f  
58, 28, 343, 140, 24, 14, 24, 18, 35, 248, A, t, f  
1136, 597, 4602, 3068, 59, 59, 554, 870, 949, 2623, D1, f, f  
376, 274, 1980, 1675, 22, 25, 356, 261, 344, 792, C, f, f  
223, 172, 1656, 1400, 18, 14, 355, 430, 323, 579, C, f, f  
1808, 976, 7600, 7396, 80, 86, 501, 718, 852, 5928, C, f, f  
114, 180, 462, 1008, 14, 16, 4, 28, 27, 364, D2, f, f  
1169, 1125, 4356, 3723, 45, 51, 359, 427, 134, 2107, D1, t, f  
226, 235, 1230, 1575, 15, 15, 414, 284, 267, 418, D1, f, f  
493, 189, 2408, 1035, 28, 23, 318, 503, 344, 1083, D1, f, f  
915, 842, 4260, 5487, 71, 59, 1265, 796, 1148, 1917, C, f, t  
1263, 739, 6136, 4277, 52, 47, 903, 1060, 589, 2208, B, f, f  
668, 429, 4992, 5841, 78, 59, 988, 955, 593, 1697, B, f, f  
259, 187, 1069, 930, 12, 10, 329, 182, 76, 481, B, t, f  
1021, 778, 4118, 3127, 58, 53, 432, 467, 432, 2388, D1, f, f  
751, 425, 3159, 1896, 27, 24, 262, 147, 542, 1516, C, f, f  
1397, 929, 6210, 5162, 54, 58, 1630, 2329, 1676, 1552, C, f, t  
336, 526, 1620, 3534, 60, 57, 211, 272, 183, 939, B, f, f  
38, 52, 182, 518, 14, 14, 16, 17, 9, 131, C, f, t  
578, 869, 1960, 3555, 70, 79, 219, 185, 212, 1274, D2, f, t

Profitability99: numeric 3  
Profitability98: numeric 3  
Spend99: numeric 3  
Spend98: numeric 3  
NoVisits99: numeric 3  
NoVisits98: numeric 3  
Dairy: numeric 3  
Deli: numeric 3  
Bakery: numeric 3  
Grocery: numeric 3  
SocioEconomicGroup: categorical  
Promotion1: t, f  
Promotion2: t, f

# The Magnum Opus System

Spend98<1782 -> NoVisits98<31

[Coverage=0.331 (331); Support=0.277 (277);  
 Strength=0.837; Lift=2.57; Leverage=0.1694 (169.4);  
 p=1.64E-136]

Spend99<2030 -> Grocery<873

[Coverage=0.333 (333); Support=0.278 (278);  
 Strength=0.835; Lift=2.51; Leverage=0.1671 (167.1);  
 p=1.13E-130]

Profitability99<419 -> Grocery<873

[Coverage=0.333 (333); Support=0.277 (277);  
 Strength=0.832; Lift=2.50; Leverage=0.1661 (166.1);  
 p=6.14E-129]

Profitability99<419 & Spend99<2030 -> Grocery<873

[Coverage=0.302 (302); Support=0.265 (265);  
 Strength=0.877; Lift=2.64; Leverage=0.1644 (164.4);  
 p=2.52E-008]

Spend99<2030 -> NoVisits99<35


[Coverage=0.333 (333); Support=0.272 (272); Strength=0.817; Lift=2.48; Leverage=0.1624 (162.4); p=2.42E-123]

Spend98<1782 -> NoVisits99<35

[Coverage=0.331 (331); Support=0.271 (271); Strength=0.819; Lift=2.49; Leverage=0.1621 (162.1); p=4.58E-123]

Spend99<2030 & Spend98<1782 -> NoVisits99<35

[Coverage=0.259 (259); Support=0.246 (246); Strength=0.950; Lift=2.89; Leverage=0.1608 (160.8); p=7.04E-027]



Statistical Association

Magnum Opus

*DEMO*


## DECISION TREES

### Part 12


*Using Statistical &  
Information Theory  
<http://rulequest.com/>*

# *Learning Decision Trees*


- A Tree is a Directed Acyclic Graph (DAG) + each node has one parent at most
- A Decision Tree is a tree where nodes associated with attributes, edges associated with attribute values, and leaves associated with decisions



Example:




# *Learning Decision Trees*



# Information Theory



## Example

- T2 is quantized into two intervals at 21 ( $T2 \leq 21$ ) and ( $T2 > 21$ )
- T3 is quantized into two intervals at 15 ( $T3 \leq 15$ ) and ( $T3 > 15$ )



T1	T2	T3	T4	D
1	25	10	A	1
1	30	30	A	0
1	35	25	B	0
1	22	35	B	0
1	19	10	B	1
2	22	30	A	1
2	33	18	B	1
2	14	5	A	1
2	31	15	B	1
3	21	20	A	0
3	15	10	A	0
3	25	20	B	1
3	18	20	B	1
3	20	36	B	1

# C5



## Decision Trees

C5



*DEMO*

## NEURAL NETWORKS

### Part 13

*How It Works?*


# Learning Neural Networks



Test Data


A	B	C	Decision
0	0	0	
0	0	1	
0	1	0	
0	1	1	1
1	0	0	
1	0	1	
1	1	0	
1	1	1	

# *Learning Neural Networks*




## The Sigmoid Function

To avoid setting the threshold:



# Learning Neural Networks



# MACHINE TRANSLATION


## Part 14

*Statistical Machine Translation*

# Statistical Machine Translation

- For each English sentence “e”, we need the Arabic sentence “a” which maximize  $P(a|e)$

$$P(a|e) = P(a) * P(e|a) / P(e)$$



# Language Model

- A statistical language model assigns a probability to a sequence of  $m$  words by means of a probability distribution
- Record every sentence that anyone ever says in Arabic; Suppose you record a database of one billion utterances; If the sentence “كيف حالك؟” appears 76,413 times in that database, then we say  $P(\text{كيف حالك?}) = 76,413/1,000,000,000 = 0.000076413$
- One big problem is that many perfectly good sentences will be assigned a  $P(a)$  of zero

Arabic Sentence	Probability
كيف حالك	0.000076413
الولد سعيد	0.000066392

# N-Grams

- An n-word substring is called an n-gram
- If  $n=2$ , we say bigram. If  $n=3$ , we say trigram
- Let  $P(y | x)$  be the probability that word  $y$  follows word  $x$

$P(y | x) = \text{number-of-occurrences}(\text{"xy"}) / \text{number-of-occurrences}(\text{"x"})$

$P(z | x y) = \text{number-of-occurrences}(\text{"xyz"}) / \text{number-of-occurrences}(\text{"xy"})$

→  $P(\text{ذهب الولد إلى المدرسة} | \text{ذهب}) = P(\text{ذهب الولد إلى المدرسة} | \text{start-of-sentence}) *$

$* (\text{إلى} | \text{المدرسة}) P(\text{المدرسة} | \text{إلى}) * P(\text{ذهب} | \text{الولد}) P(\text{الولد} | \text{ذهب})$   
 $P(\text{المدرسة} | \text{الولد})$

→  $P(\text{ذهب الولد إلى المدرسة} | \text{ذهب}) = P(\text{ذهب الولد إلى المدرسة} | \text{start-of-sentence}) *$

$* (\text{ذهب}, \text{الولد} | \text{إلى}) P(\text{إلى} | \text{ذهب}, \text{الولد}) * P(\text{الولد}, \text{إلى} | \text{ذهب}) P(\text{ذهب} | \text{الولد}, \text{إلى})$   
 $* (\text{إلى}, \text{المدرسة} | \text{الولد}, \text{إلى}) P(\text{الولد}, \text{إلى} | \text{المدرسة}) P(\text{المدرسة} | \text{إلى}, \text{المدرسة})$   
 $P(\text{المدرسة}, \text{إلى} | \text{المدرسة}, \text{إلى})$

# N-Grams Language Model

$$P(w_1, \dots, w_m) = \prod_{i=1}^m P(w_i | w_1, \dots, w_{i-1}) \approx \prod_{i=1}^m P(w_i | w_{i-(n-1)}, \dots, w_{i-1})$$

$$P(w_i | w_{i-(n-1)}, \dots, w_{i-1}) = \frac{\text{count}(w_{i-(n-1)}, \dots, w_i)}{\text{count}(w_{i-(n-1)}, \dots, w_{i-1})}$$

## Example:

In a bigram ( $n=2$ ) language model, the approximation looks like

$$P(I, \text{saw}, \text{the}, \text{red}, \text{house}) \approx P(I)P(\text{saw} | I)P(\text{the} | \text{saw})P(\text{red} | \text{the})P(\text{house} | \text{red})$$

In a trigram ( $n=3$ ) language model, the approximation looks like

$$P(I, \text{saw}, \text{the}, \text{red}, \text{house}) \approx P(I)P(\text{saw} | I)P(\text{the} | I, \text{saw})P(\text{red} | \text{saw}, \text{the})P(\text{house} | \text{the}, \text{red})$$

# Translation Model

- $P(e | a)$ , the probability of an English string “e” given an Arabic string “a”; This is called a translation model
- $P(e | a)$  will be a module in overall English-to-Arabic machine translation system; When we see an actual English string e, we want to reason backwards ... What Arabic string a is likely to be expressed, and likely to subsequently translate to e? We're looking for the a that maximizes  $P(a) * P(e | a)$

Arabic Sentence	English Sentence	$P(a e)$
ذهب الولد إلى المدرسة	The boy went to School	0.0034
انخفاض البورصة اليوم	Today, the stock market went down	0.00021
:	:	

- Example, BuckWalter

# Translation Model

- For each word  $a_i$  in an Arabic sentence ( $i = 1 \dots l$ ), we choose a fertility  $\phi_i$ . The choice of fertility depends on the Arabic word in question. It is not dependent on the other Arabic words in the Arabic sentence, or on their fertilities
- For each word  $a_i$ , we generate  $\phi_i$  English words. The choice of English word depends on the Arabic word that generates it. It is not dependent on the Arabic context around the Arabic word. It is not dependent on other English words that have been generated from this or any other Arabic word
- All those English words are permuted. Each English word is assigned an absolute target “position slot.” For example, one word may be assigned position 3, and another word may be assigned position 2 -- the latter word would then precede the former in the final English sentence. The choice of position for a English word is dependent solely on the absolute position of the Arabic word that generates it

# REFERENCES

- W. Weaver (1955). Translation (1949). In: *Machine Translation of Languages*, MIT Press, Cambridge, MA.
- P. Brown, S. Della Pietra, V. Della Pietra, and R. Mercer (1993). The mathematics of statistical machine translation: parameter estimation. *Computational Linguistics*, 19(2), 263-311.
- S. Vogel, H. Ney and C. Tillmann. 1996. HMM-based Word Alignment in Statistical Translation. In COLING '96: The 16th International Conference on Computational Linguistics, pp. 836-841, Copenhagen, Denmark.
- F. Och and H. Ney. (2003). A Systematic Comparison of Various Statistical Alignment Models. *Computational Linguistics*, 29(1):19-51
- P. Koehn, F.J. Och, and D. Marcu (2003). Statistical phrase based translation. In *Proceedings of the Joint Conference on Human Language Technologies and the Annual Meeting of the North American Chapter of the Association of Computational Linguistics (HLT/NAACL)*.
- D. Chiang (2005). A Hierarchical Phrase-Based Model for Statistical Machine Translation. In *Proceedings of the 43rd Annual Meeting of the Association for Computational Linguistics (ACL'05)*.
- F. Och and H. Ney. (2003). A Systematic Comparison of Various Statistical Alignment Models. *Computational Linguistics*, 29(1):19-51
- P. Koehn, H. Hoang, A. Birch, C. Callison-Burch, M. Federico, N. Bertoldi, B. Cowan, W. Shen, C. Moran, R. Zens, C. Dyer, O. Bojar, A. Constantin, E. Herbst. 2007. Moses: Open Source Toolkit for Statistical Machine Translation. ACL 2007, Demonstration Session, Prague, Czech Republic
- Q. Gao, S. Vogel, "Parallel Implementations of Word Alignment Tool", Software Engineering, Testing, and Quality Assurance for Natural Language Processing, pp. 49-57, June, 2008
- W. J. Hutchens and H. Somers. (1992). An Introduction to Machine Translation, 18.3:322. ISBN 0-12-36280-X

# REFERENCES

- W. The Sage Dictionary of Statistics, pg. 76, Duncan Cramer, Dennis Howitt, 2004, [ISBN 076194138X](#)
- E.L. Lehmann and Joseph P. Romano (2005). *Testing Statistical Hypotheses* (3E ed.). New York, NY: Springer. [ISBN 0387988645](#)
- D.R. Cox and D.V.Hinkley (1974). *Theoretical Statistics*. [ISBN 0412124293](#).
- [Fisher, Sir Ronald A.](#) (1956) [1935]. "[Mathematics of a Lady Tasting Tea](#)". in James Roy Newman. *The World of Mathematics, volume 3*.  
<http://books.google.com/books?id=oKZwtLQTmNAC&pg=PA1512&dq=%22mathematics+of+a+lady+tasting+tea%22&sig=8-NQlCLzrh-oV0wjfwa0EgspSNU>
- R.A. Fisher, the Life of a Scientist, Box, 1978, p134
- McCloskey, Deirdre (2008). *The Cult of Statistical Significance*. Ann Arbor: University of Michigan Press. [ISBN 0472050079](#)
- *What If There Were No Significance Tests?*, Harlow, Mulaik & Steiger, 1997, [ISBN 978-0-8058-2634-0](#)
- Rosnow, R.L. & Rosenthal, R. (1989). Statistical procedures and the justification of knowledge in psychological science. *American Psychologist*, 44, 1276-1284
- Loftus, G.R. 1991. On the tyranny of hypothesis testing in the social sciences. *Contemporary Psychology* 36: 102-105
- [Cohen, J.](#) 1990. Things I have learned (so far). *American Psychologist* 45: 1304-1312. ^ *Introductory Statistics*, Fifth Edition, 1999, pg. 521, Neil A. Weiss, [ISBN 0-201-59877-9](#)
- Ioannidis JP (July 2005). "Contradicted and initially stronger effects in highly cited clinical research". *JAMA* 294 (2): 218-28.

# *Tutorial on Statistics, Probability and Information Theory for Language Engineers*

*Prof. Ibrahim F. Imam*

Full Professor and Assistant Dean,  
College of Computing and Information Technology  
Arab Academy for Science, Technology & Maritime Transport, Cairo

Adjunct Professor, Computer Science Department,  
College of Engineering, Virginia Tech. University, VA, USA

Email: ifi05@yahoo.com

Phone: 012-2242929

# Contents of the Tutorial

1- Main Presentation in PDF Slides

2- Presentation on Statistics in Excel in PDF Slides

3- Statistical Machine Translation File “SMT.rtf”

4- Three Files on How to Apply Statistics in Excel

5- Two Machine Learning Demo Programs C5 & Opus

6-

# OUTLINE

1- Basic Concepts	4
2- Introduction to Vectors	10
3- Probability	18
4- Statistics	24
5- Regression	50
6- Statistics & Testing	55
7- Test of Significance	62
8- Information Theory	68
9- Basics for Language Engineers	81
10- Statistical Association	84
11- Statistical Machine Translation	101
12- Analysis of Variance	109
13- Bayesian Networks	124

# BASIC MATHEMATICS

## Part 0

*Basic Concepts*

# BASIC MATHEMATICS

$$\sum_{i=1}^n i = 1 + 2 + \dots + n$$


$$\prod_{i=1}^n i = 1 * 2 * \dots * n$$

$$\sum_{i=1}^n k i = k \sum_{i=1}^n i$$


$$\prod_{i=1}^n k i = k \prod_{i=1}^n i$$

# Introduction to Set Theory


- A set is a collection of distinct items (Example:  $A = \{1, 2, 3, 4, 5\}$ )




Intersection



Union



Sub-set & Super-set



# Introduction to Set Theory

$$\bullet \quad A = \{a, c, e, d, x, y, z\}$$

$$B = \{b, c, d, y, m, n\}$$

$$C = \{c, d\}$$

$$A \cap B = \{c, d, y\}$$

Intersection

$$A \cup B = \{a, b, c, d, e, m, n, x, y, z\}$$

Union

$$A \not\subset B \quad C \subset B \quad C \subset A$$

Sub-set & Super-set

$$x \in A; \quad x \notin B; \quad x \notin C$$

Belong Relationship

$\Phi/\emptyset$  is the empty set

$\cap \cup \subset \not\subset \in \notin \neg \wedge \vee$

# Introduction to Set Theory

- $A \cap (B \cap C) = (A \cap B) \cap C$       &       $A \cup (B \cup C) = (A \cup B) \cup C$
- $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$
- $\neg(\neg A) = A$
- $\neg(A \cap B) = \neg A \cup \neg B$

# Introduction to Propositional Logic

- It is also called the Zero Order Logic
- A sentence X can be either true or false (1 or 0)

X	Y
0	0
1	1

X	Y	$X \wedge Y$
0	0	0
0	1	0
1	0	0
1	1	1

X	Y	$X \vee Y$
0	0	0
0	1	1
1	0	1
1	1	1

X	Y	$X \rightarrow Y$
0	0	1
0	1	1
1	0	0
1	1	1

X	Y	$X \text{ XOR } Y$
0	0	1
0	1	0
1	0	0
1	1	1

$X \rightarrow Y = \neg X \vee Y$
$\neg(X \wedge Y) = \neg X \vee \neg Y$
$X \wedge X = X \quad \& \quad X \vee X = X$
$X \vee (Y \wedge Z) = (X \vee Y) \wedge (X \vee Z)$
$\neg(\neg X) = X$

## *Introduction to Vectors*


### *Part I*

*Representing Documents  
As Vectors*

# Introduction to Vectors


Adding two vectors

$$(x_1, y_1) + (x_2, y_2) = (x_1 + x_2, y_1 + y_2)$$




Multiplying a vector by a constant and adding it to another vector

$$(x_1, y_1) + (2 \cdot x_2, 2 \cdot y_2) = (x_1 + 2x_2, y_1 + 2y_2)$$



Multiplying a vector by -1

$$-(x_1, y_1) = (-x_1, -y_1)$$



Multiplying a vector by a constant

$$2 \cdot (x_2, y_2) = (2x_2, 2y_2)$$


# Introduction to Vectors

Multiplying two orthogonal vectors equal to zero.

Examples:


$$V1 = (5, 0) \quad \& \quad V2 = (0, 4)$$

$$V1 \cdot V2 = 0$$




$$V1 = (5, 4) \quad \& \quad V2 = (-4, 5)$$

$$V1 \cdot V2 = 0$$



# Eigen Values & Eigen Vectors

- An eigenvector of a matrix  $\underline{A}$  is a nonzero vector  $\underline{x}$ , where  $\underline{A}.\underline{x}$  is similar to applying a linear transformation  $\lambda$  to  $\underline{x}$  which, may change in length, but not direction
- $\underline{A}$  acts to stretch the vector  $\underline{x}$ , not change its direction, so  $\underline{x}$  is an eigenvector of  $\underline{A}$



$$\begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \lambda \begin{bmatrix} x \\ y \end{bmatrix}$$

*if there exist an inverse  $(A - \lambda I)^{-1}$ , then  $x = 0$*

*we need  $\det(A - \lambda I) = 0$  to avoid the trivial solution  $x = 0$*

$$\det(A - \lambda I) = 0$$

## Example on Eigen Values & Eigen Vectors

- Suppose  $A$  is 2x2 matrix

$$A = \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix}$$

$$\det \begin{bmatrix} 2-\lambda & 1 \\ 1 & 2-\lambda \end{bmatrix} = (2-\lambda)^2 - 1 = 0$$

$$\lambda = 1 \quad \text{or} \quad \lambda = 3$$

for  $\lambda = 3$ ,  $\begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = 3 \begin{bmatrix} x \\ y \end{bmatrix}$

for  $\lambda = 1$ ,  $\begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = 1 \begin{bmatrix} x \\ y \end{bmatrix}$

$$\begin{bmatrix} 2x+y \\ x+2y \end{bmatrix} = \begin{bmatrix} 3x \\ 3y \end{bmatrix}$$

$$\begin{bmatrix} 2x+y \\ x+2y \end{bmatrix} = \begin{bmatrix} x \\ y \end{bmatrix}$$

$$2x+y = 3x$$

$$x = y$$

$$2x+y = x$$


$$x = -y$$

The eigenvectors are:

$$\begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$\begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

# *Representing Documents as Vectors*




# Documents as Vectors


Suppose we have two documents containing three nouns only

	Term T <sub>1</sub>	Term T <sub>2</sub>	Term T <sub>3</sub>
Document D <sub>1</sub>	2	3	5
Document D <sub>2</sub>	3	7	1

$$\begin{matrix} D_1 \\ \left[ \begin{matrix} 2 \\ 3 \\ 5 \end{matrix} \right] \end{matrix} \quad | \quad \begin{matrix} D_2 \\ \left[ \begin{matrix} 3 \\ 7 \\ 1 \end{matrix} \right] \end{matrix}$$



# *Dimensionality Reduction*



# PROBABILITY

## Part 2

- Introduction*
- Terminology*

# What Is Probability?

- A priori probability  $P(e)$ : The chance that e happens
- Conditional probability  $P(f | e)$ : The chance of f given e
- Joint probability  $P(e, f)$ : The chance of e and f both happening; If e and f are independent, then  $P(e, f) = P(e) * P(f)$ ; If e and f are dependent then  $P(e, f) = P(e) * P(f | e)$

For example, if e stands for “the first roll of the die comes up 5” and f stands for “the second roll of the die comes up 3,” then  $P(e, f) = P(e) * P(f) = 1/6 * 1/6 = 1/36$ .

$$\sum_e P(e) = 1$$

$$\sum_e P(e | f) = 1$$

# BASIC Probabilities

$$P(A \cup B) = \begin{cases} P(A) + P(B) & A \& B \text{ are not dependant} \\ P(A) + P(B) - P(A, B) & A \& B \text{ are dependant} \end{cases}$$

- For example, when drawing a single card at random from a regular deck of cards, the chance of getting a heart or a face card (J,Q,K) (or one that is both) is

$$\frac{13}{52} + \frac{12}{52} - \frac{3}{52} = \frac{22}{52}$$




A	$P(A) \in [0, 1]$
not A	$P(A') = 1 - P(A)$
A or B	$P(A \cup B) = P(A) + P(B) - P(A \cap B)$ $= P(A) + P(B)$ if A and B are mutually exclusive
A and B	$P(A \cap B) = P(A B)P(B)$ $= P(A)P(B)$ if A and B are independent
A given B	$P(A   B) = \frac{P(A \cap B)}{P(B)}$

# Probability Density Function PDF

- Probability density function (pdf) is a function that represents a probability distribution in terms of integrals



$$\int_a^b f(x) dx$$

$$\int_{-\infty}^{\infty} f(x) dx = 1 \quad \& \quad f(x) \geq 0$$



# Probability Density Function PDF

- The Summation is used with Discrete Data



# Conditional & Bayesian Probability

- Conditional probability is the probability of some event  $A$ , given the occurrence of some other event  $B$
- Conditional probability is written  $P(A|B)$ , and is read “the probability of  $A$ , given  $B$ ”

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

- Bayesian probability, the probability of a hypothesis given the data (the *posterior*), is proportional to the product of the likelihood times the prior probability (often just called the *prior*)
- The likelihood brings in the effect of the data, while the prior specifies the belief in the hypothesis before the data was observed

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

# STATISTICS

## Part 3

### *Introduction*

# Statistics

- Statistics is a Mathematical Science pertaining to the collection, analysis, interpretation or explanation, and presentation of data

# Statistical Terminologies

- Measures of Central Tendency (Mean, Median, Mode)
- Population Variance measures statistical dispersion of data points from the expected value (mean)
- Standard Deviation is a measure of the variability or dispersion of a population; Low SD indicates very close data points to the mean; High SD indicates spread out data points
- Covariance measures how much two variables change together
- Correlation (coefficient) indicates the strength and direction of a *linear* relationship between two random variables

$$\bar{x} = (1/n) \sum_{i=1}^n x_i$$

$$\begin{aligned}Var(X) &= E[(X - E(X))^2] \\&= (1/n) \sum_{i=1}^n (x_i - \bar{x})^2 = \sigma^2\end{aligned}$$

$$sd(X) = \sqrt{\sigma^2}$$

$$Cov(X, Y) = E[(X - E(X))(Y - E(Y))]$$

$$Corr(X, Y) = \frac{Cov(X, Y)}{sd(X) * sd(Y)} = \frac{\sigma_{xy}}{\sigma_x \sigma_y}$$

# STATISTICS

## Part 4

*Permutations &  
Computations*

# Introduction to Permutations & Computations

## Plain Bob Minor

The figure consists of three separate 10x10 grid diagrams, each showing a path from the top-left corner to the bottom-right corner. The paths are composed of red and blue hexagonal cells. In each diagram, the path starts at the top-left corner (labeled 1) and ends at the bottom-right corner (labeled 6). The paths are as follows:

- Diagram 1 (Left):** The path starts at (1,1), moves right to (2,1), then down to (2,2), then right to (3,2), then down to (3,3), then right to (4,3), then down to (4,4), then right to (5,4), then down to (5,5), then right to (6,5), then down to (6,6), then right to (7,6), then down to (7,7), then right to (8,7), then down to (8,8), then right to (9,8), then down to (9,9), then right to (10,9), then down to (10,10).
- Diagram 2 (Middle):** The path starts at (1,1), moves right to (2,1), then down to (2,2), then right to (3,2), then down to (3,3), then right to (4,3), then down to (4,4), then right to (5,4), then down to (5,5), then right to (6,5), then down to (6,6), then right to (7,6), then down to (7,7), then right to (8,7), then down to (8,8), then right to (9,8), then down to (9,9), then right to (10,9), then down to (10,10).
- Diagram 3 (Right):** The path starts at (1,1), moves right to (2,1), then down to (2,2), then right to (3,2), then down to (3,3), then right to (4,3), then down to (4,4), then right to (5,4), then down to (5,5), then right to (6,5), then down to (6,6), then right to (7,6), then down to (7,7), then right to (8,7), then down to (8,8), then right to (9,8), then down to (9,9), then right to (10,9), then down to (10,10).

# Permutations

- Suppose an ordered set of  $n$  different objects
- For ordered selection of  $r$  objects from a set of  $n$  ( $n \geq r$ ) different objects, the number of permutations of  $r$  from  $n$ , i.e. the number of different possible ordered selections, is usually denoted by  $P_r^n$

$$P_r^n = \frac{n!}{(n-r)!}$$

لدينا ثلاثة أرقام، ب، ج. يتم اختيار أول رقم وضربه في 10، ويتم ضرب الرقم الثاني في 100، ويتم ضرب الرقم الثالث في 1000، ثم يتم جمع الثلاثة أرقام الجديدة. كم رقم يمكن إستنتاجه من هذه الأرقام الثلاثة.

مثال: 1، 2، 3، ...  
الحل: ?

$$P_0^n = 1$$

$$P_1^n = n$$

$$P_n^n = n!$$

# Permutations

Example:

r	g	b	y
---	---	---	---

Suppose we have 4 elements and need to select 3 elements in order; there are 24 different combinations

$$P_3^4 = \frac{4!}{(4-3)!} = \frac{4!}{1!} = 4 * 3 * 2 = 24$$

r	g	b
---	---	---

r	b	g
---	---	---

g	r	b
---	---	---

g	b	r
---	---	---

b	g	r
---	---	---

b	r	g
---	---	---

r	g	y
---	---	---

r	y	g
---	---	---

g	r	y
---	---	---

g	y	r
---	---	---

y	r	g
---	---	---

y	g	r
---	---	---

r	b	y
---	---	---

r	y	b
---	---	---

b	r	y
---	---	---

b	y	r
---	---	---

y	r	b
---	---	---

y	b	r
---	---	---

g	b	y
---	---	---

g	y	b
---	---	---

b	g	y
---	---	---

b	y	g
---	---	---

y	g	b
---	---	---

y	b	g
---	---	---

# Permutations

- Suppose a set {A, B, C}, we have 6 ( $=3!$ ) permutations of {A, B, C} are ABC, ACB, BAC, BCA, CAB and CBA
- Suppose a set {A, B, C, D}, there are  $24 = P_3^4 = (4 \times 3 \times 2)$  permutations of 3 letters from {A, B, C, D}
- If the  $n$  objects are not all different, and there are  $n_1$  objects of type 1,  $n_2$  objects of type 2, ...,  $n_k$  objects of type  $k$ , where  $n_1+n_2+\dots+n_k=n$ , then the number of different ordered arrangements is

$$\frac{n!}{n_1!n_2!n_3!\dots n_k!}$$

a	a	a	b	b	b	c	c	c	c	d	d	d	d
---	---	---	---	---	---	---	---	---	---	---	---	---	---

$$\frac{14!}{3!*3!*4!*4!}$$



# Computations

The number of ways of picking k unordered outcomes from n possibilities. Also known as the binomial coefficient or choice number and read “n choose k,”

$$C_k^n = \binom{n}{k} = \frac{n!}{k!(n-k)!}$$

لدينا ثلاثة كرات حمراء و كرتان زرقاء. كم طريقة يمكن بها ترتيب الخمس كرات.

مثال: (ح،ح،ح،ز،ز)، (ح،ح،ز،ح،ز)  
الحل:



# Computations

For example: suppose we have the set  $\{1, 2, 3, 4\}$ , we need to calculate the number of combinations of selecting two elements out of the set

$$C_2^4 = \binom{4}{2} = \frac{4!}{2!*2!} = 6$$

namely  $\{1,2\}$ ,  $\{1,3\}$ ,  $\{1,4\}$ ,  $\{2,3\}$ ,  $\{2,4\}$ , and  $\{3,4\}$ .

Suppose we have 4 places and filled only 2 of them. The combination to fill the other two cells with the other two numbers equal to 1. Muir (1960) uses the nonstandard notations

$$\bar{C}_k^n = \binom{n-k}{k} \quad \bar{C}_2^4 = \binom{2}{2} = \frac{2!}{2!*0!} = 1$$

$C_0^n = 1$	$C_1^n = n$	$C_n^n = 1$
-------------	-------------	-------------

# STATISTICS

## Part 5

*Popular Distributions*


# Popular Distributions

Probability Distribution identifies the probability of each value of an unidentified random variable


- *Uniform Distribution*
- *Normal (Gaussian) Distribution*
- *Chi-Square Distribution*
- *Exponential Distribution*
- *Poisson Distribution*
- *T Distribution*
- *F Distribution*

# The Uniform Distribution

- The probability is equal for all outcomes
- Suppose a fair dice is thrown, the probability of getting any of its 6 faces equal to  $1/6$
- The area under the line equal to 1




# The Normal/Gaussian Distribution




$$P(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

# The Chi-Square Distribution




$$f(x; k) = \begin{cases} \frac{1}{2^{k/2} \Gamma(k/2)} x^{(k/2)-1} e^{-x/2} & \text{for } x > 0 \\ 0 & \text{for } x \leq 0 \end{cases}$$

# The Exponential Distribution




$$f(x; \lambda) = \begin{cases} \lambda e^{-\lambda x} & \text{for } x > 0 \\ 0 & \text{for } x \leq 0 \end{cases}$$

# The Poisson Distribution



$$f(k; \lambda) = \frac{\lambda^k e^{-\lambda}}{k!}$$


# The T Distribution



$$f(t) = \frac{\Gamma(\frac{v+1}{2})}{\sqrt{v\pi}\Gamma(\frac{v}{2})} \left(1 + \frac{t^2}{v}\right)^{-(v+1)/2}$$


$t$ -distribution arises in the problem of estimating the mean of a normally distributed population when the sample size is small

# The F Distribution



$$f(x) = \frac{\sqrt{\frac{(d_1 x)^{d_1} d_2^{d_2}}{(d_1 x + d_2)^{d_1 + d_2}}}}{x B\left(\frac{d_1}{2}, \frac{d_2}{2}\right)}$$

## Fitting Chi-Square



Vector  
a

15
14
11
11
6
5
5

$$\max \quad \chi^2 = \sum_{i=1}^n \frac{(a_i - E_i)^2}{E_i}$$

$$E_{ij} = (15 + 14 + 11 + 11 + 6 + 5 + 5) / 7 = 9.57$$

$$\begin{aligned} \chi^2 = & (1/9.57) * ((15-9.57)^2 + (14-9.57)^2 + (11-9.57)^2 + (11-9.57)^2 + \\ & (6-9.57)^2 + (5-9.57)^2 + (5-9.57)^2) = 107.71/9.57 = 11.26 \end{aligned}$$

## *Measuring Term-Category Correlation*

$$\chi^2(t_k, c_i) = \frac{[P(t_k, c_i)P(\bar{t}_k, \bar{c}_i) - P(t_k, \bar{c}_i)P(\bar{t}_k, c_i)]^2}{P(t_k)P(\bar{t}_k)P(c_i)P(\bar{c}_i)}$$

$P(t_k, c_i)$  → probability document x contains term t and belongs to category c.

$P(\bar{t}_k, c_i)$  → probability document x does not contain term t and belongs to category c.




$P(t_k, \bar{c}_i)$  → probability document x contains term t and does not belong to category c.

$P(\bar{t}_k, \bar{c}_i)$  → probability document x does not contain term t and does not belong to category c.

$P(t)$  → probability of term t

$P(c)$  → probability of category c

## Testing The Membership



$$\chi^2(t_k, c_i) = \frac{[P(t_k, c_i)P(\bar{t}_k, \bar{c}_i) - P(t_k, \bar{c}_i)P(\bar{t}_k, c_i)]^2}{P(t_k)P(\bar{t}_k)P(c_i)P(\bar{c}_i)}$$

$$\chi^2(t_1, Sports) = \frac{\left[ \frac{1}{9} * \frac{14}{16} - \frac{1}{16} * \frac{8}{9} \right]^2}{\frac{2}{27} * \frac{25}{27} * \frac{9}{27} * \frac{18}{27}}$$

## *Using Chi-Square for Categorization*

Another Example:

Term	Frequency per Category				Total
	Communication	Phone	Business	Army	
Link	15	6	2	12	35
Wire	10	12	0	8	30
<b>Total</b>	<b>25</b>	<b>18</b>	<b>2</b>	<b>20</b>	<b>65</b>

$$\chi^2(\text{link}, \text{phone}) = \frac{[6/65] * (18/65) - (29/65) * (12/65)]^2}{(35/65) * (30/65) * (18/65) * (47/65)}$$

## Using Chi-Square for Multiple sets of Terms

Group 1	Category		Total
	0	1	
Term 1	3	2	5
Term 2	0	4	4
Term 3	2	3	5
Total	5	9	14

Group 2	Category		Total
	0	1	
Term 5	1	3	4
Term 7	4	6	10
Total	5	9	14

$$\chi^2 = \sum_{i=1}^n \sum_{j=1}^m \frac{(a_{ij} - E_{ij})^2}{E_{ij}}$$

$$E_{ij} = \frac{(T_{ci} * T_{vj})}{T}$$

$$\begin{aligned}\chi^2(\text{Group 1}) &= (3-1.78)^2 / 1.78 + (2-3.21)^2 / 3.21 + (0-1.42)^2 / 1.42 \\ &\quad + (4-2.57)^2 / 2.57 + (2-1.78)^2 / 1.78 + (3-3.21)^2 / 3.21 = 3.62\end{aligned}$$

$$\begin{aligned}\chi^2(\text{Group 2}) &= (1-1.42)^2 / 1.42 + (3-2.57)^2 / 2.57 + (4-3.57)^2 / 3.57 \\ &\quad + (6-6.43)^2 / 6.43 =\end{aligned}$$

## *Attribute Selection Criteria: Chi-Square*

### Example

- T2 is quantized into two intervals  $\leq 21$  ( $T2 \leq 21$ ) and ( $T2 > 21$ )
- T3 is quantized into two intervals  $\leq 15$  ( $T3 \leq 15$ ) and ( $T3 > 15$ )

T2	Decision D		Total
	0	1	
$\leq 21$	1	3	4
$> 21$	4	6	10
Total	5	9	14

T1	Decision D		Total
	0	1	
1	3	2	5
2	0	4	4
3	2	3	5
Total	5	9	14

T3	Decision D		Total
	0	1	
$\leq 15$	1	4	5
$> 15$	4	5	9
Total	5	9	14

T4	Decision D		Total
	0	1	
A	3	3	6
B	2	6	8
Total	5	9	14

T1	T2	T3	T4	D
1	25	10	A	1
1	30	30	A	0
1	35	25	B	0
1	22	35	B	0
1	19	10	B	1
2	22	30	A	1
2	33	18	B	1
2	14	5	A	1
2	31	15	B	1
3	21	20	A	0
3	15	10	A	0
3	25	20	B	1
3	18	20	B	1
3	20	36	B	1

## Attribute Selection Criteria: Chi-Square

$$\chi^2(A) = \sum_{i=1}^n \sum_{j=1}^m \frac{(a_{ij} - E_{ij})^2}{E_{ij}}$$

where A is the attribute to be evaluated against the decision attribute, n is the number of distinct values of A, m is the number of distinct values of the decision attribute,  $a_{ij}$  is the correlation frequency of value number i from A and value number j from the decision attribute;

$$E_{ij} = \frac{(T_{ci} * T_{vj})}{T}$$

where  $T_{ci}$  is the total number of examples belonging to class  $c_i$ ,  $T_{vj}$  is the number of examples containing the value  $v_j$  of the given attribute

$$\begin{aligned}\chi^2(X1) &= (3-1.78)^2 / 1.78 + (2-3.21)^2 / 3.21 + (0-1.42)^2 / 1.42 \\ &\quad + (4-2.57)^2 / 2.57 + (2-1.78)^2 / 1.78 + (3-3.21)^2 / 3.21 = 3.62\end{aligned}$$

$$\begin{aligned}\chi^2(X4) &= (3-3.9)^2 / 3.9 + (3-2.1)^2 / 2.1 + (6-5.1)^2 / 5.1 \\ &\quad + (2-2.9)^2 / 2.9 = 1.1\end{aligned}$$

---

Mingers, J., (1989a). "An Empirical Comparison of selection Measures for Decision-Tree Induction", *Machine Learning*, Vol. 3, No. 3, (pp. 319-342), Kluwer Academic Publishers.

D1	Decision D5		Total
	0	1	
1	3	2	5
2	0	4	4
3	2	3	5
Total	5	9	14

D2	Decision D5		Total
	0	1	
$\leq 21$	1	3	4
$> 21$	4	6	10
Total	5	9	14

D3	Decision D5		Total
	0	1	
$\leq 15$	1	4	5
$> 15$	4	5	9
Total	5	9	14

D4	Decision D5		Total
	0	1	
A	3	3	6
B	2	6	8
Total	5	9	14

# STATISTICS

## Part 6

*Regression*

# Linear Regression


- The linear model states that the dependent variable is directly proportional to the value of the independent variable
- Thus if a theory implies that Y increases in direct proportion to an increase in X, it implies a specific mathematical model of behavior

$$y = ax + b$$

In case of two dimensions

$$a = \text{slope} = \frac{(y_2 - y_1)}{(x_2 - x_1)}$$

$$b = y_2 - \text{slope} * x_2$$




# Linear Regression

$$y = ax + b$$

$$8 = 6a + b \quad \& \quad 4 = 3a + b$$

$$\frac{8-b}{6} = a \quad \& \quad 4 = 3 * \frac{8-b}{6} + b$$

$$b = 0 \quad \& \quad a = \frac{4}{3} = 1.333$$



$$b = 4 - \frac{4}{3} * 3 = 0$$


# Linear Regression

$$y = ax + b$$

$$6 = a + b \quad \& \quad 2 = 3a + b$$

$$6 - b = a \quad \& \quad 2 = 3 * (6 - b) + b$$


$$b = 8 \quad \& \quad a = 6 - 8 = -2$$



$$\text{Slope} = \frac{6-2}{1-3} = \frac{4}{-2} = -2$$

$$b = 2 + 2 * 3 = 8$$

# Linear Regression





## Statistics and Testing

### Part 7

*Testing Samples &  
Calculating Accuracy*

## *Training & Testing*




# *Testing Approaches*

- Two-Cross-Fold

Train on 2/3<sup>rd</sup>

Test on 1/3<sup>rd</sup>



- Ten-Cross-Fold

Train on 9/10<sup>th</sup>


Test on 1/10<sup>th</sup>

Repeat 10 times

- Hold-One-Out

Train on all data but one

Test on the selected one




- Learning Evaluation vs. Testing

Train on Training Data

Evaluate on Evaluation Data

Test on Testing Data



# Accuracy & Error

Example: Suppose you have a classification model C, and 100 testing records from two classes (P & N). Suppose the following are the classification results:

- Accuracy vs. Error Rate

- Accuracy =  $(40+45)/100 = 85\%$
- Error Rate =  $(10+5)/100 = 15\%$

		Actual	
		P	N
Obtained	P	TP	FP
	N	FN	TN

- True vs. False Classification

- True Positive: = 88.88%
- True Negative: = 81.82%
- False Positive: = 11.12%
- False Negative: = 18.18%

		Actual	
		P	N
Obtained	P	40	10
	N	5	45

- Flexible Matching

- *Using Nearest Neighbors (e.g., majority of nearest 3 neighbors)*
- Using Fuzzy rules (assigning probability for each decision and taking it into consideration when calculating the accuracy)
- Assigning small weights for the false positive and false negative results (not zero)

- Testing for Multiple Classes ????

# *Precision, Recall, and F-Measure*

Accuracy: is the percentage of correct results

Error: is the percentage of wrong results

Accuracy only reacts to real errors, and doesn't show how many correct results have been found as such

## Precision:

Precision shows the percentage of correct results within an answer:

$$\text{Precision} = (tp) / (tp + fp)$$

## Recall:

Recall is the percentage of the correct system results over all correct results:

$$\text{Recall} = (tp) / (tp + fn)$$

*Makhoul, John; Francis Kubala; Richard Schwartz; Ralph Weischedel: [Performance measures for information extraction](#). In: Proceedings of DARPA Broadcast News Workshop, Herndon, VA, February 1999*

## *Precision, Recall, and F-Measure*

Precision and Recall can be defined differently for different tasks

For example: In Information Retrieval,

- Recall =  $|\{\text{relevant documents}\} \cap \{\text{documents retrieved}\}| / |\{\text{relevant documents}\}|$
- Precision =  $|\{\text{relevant documents}\} \cap \{\text{documents retrieved}\}| / |\{\text{documents retrieved}\}|$

## *Precision, Recall, and F-Measure*

### F-Measure (harmonic mean):

$F_\beta$  “measures the effectiveness of  $\beta$  times as much importance to recall as precision”. The general form of F-Measure:

$$F_\beta = \frac{(1 + \beta^2) * (\text{precision} * \text{recall})}{\beta^2 * \text{precision} + \text{recall}}$$

when  $\beta=1$ ,

$$F_1 = \frac{2 * (\text{precision} * \text{recall})}{\text{precision} + \text{recall}}$$

# STATISTICS

## Part 8


*Test of Significance*

## Test of Significance (1/5)

- The probability that a result is not due to chance; or Is the observed value differs enough from a hypothesized value?
- The hypothesized value is called the null hypothesis
- If this probability is sufficiently low, then the difference between the parameter and the statistic is said to be "statistically significant"
- Just how low is sufficiently low? The choice of 0.05 and 0.01 are most commonly used

- Suppose your algorithm produced error rate of 1.5 and another algorithm produced an error of 2.1 on the same data set; are the two algorithms similar?

## Test of Significance (2/5)



- The top ends of the bars indicate observation means
- The red line segments represent the confidence intervals surrounding them
- The difference between the two populations on the left is significant
- However, it is a common misconception to suppose that two parameters whose 95% confidence intervals fail to overlap are significantly different at the 5% level

## Test of Significance (3/5)

- The system you are comparing against reported results of 250; the value reported is considered as a random variable  $X$ ; the distribution of  $X$  is assumed as normal distribution with unknown mean and standard deviation  $\sigma=2.5$ ; You ran your system 25 times; it reported values ( $x_1, x_2, \dots, x_{25}$ ); the average of these values is 250.2.

$$\hat{\mu} = \bar{X} = \frac{1}{n} \sum_{i=1}^{25} x_i = 250.2$$


Sample Mean

$$\text{Standard Error} = \sigma / \sqrt{n} = 2.5 / \sqrt{25} = 0.5 \quad n \text{ is the sample size}$$

$$Z = \frac{\bar{X} - \mu}{\sigma / \sqrt{n}} = \frac{\bar{X} - \mu}{0.5}$$

$\mu$  is not known

## Test of Significance (4/5)



$$P(-z \leq Z \leq z) = 1 - \alpha = 0.95$$

$$\Phi(z) = P(Z \leq z) = 1 - \frac{\alpha}{2} = 0.975$$

From Tables

$$z = \Phi^{-1}(\Phi(z)) = \Phi^{-1}(0.975) = 1.96 \leftarrow$$

$$0.95 = 1 - \alpha = P(-z \leq Z \leq z) = P\left(-1.96 \leq \frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \leq 1.96\right)$$

## Test of Significance (5/5)

$$P(-z \leq Z \leq z) = P(\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + 1.96 \frac{\sigma}{\sqrt{n}})$$

$$P(-z \leq Z \leq z) = P(\bar{X} - 1.96 * 0.5 \leq \mu \leq \bar{X} + 1.96 * 0.5)$$

$$P(-z \leq Z \leq z) = P(\bar{X} - 0.98 \leq \mu \leq \bar{X} + 0.98)$$

$$\text{Our Interval} = (250.2 - 0.98; 250.2 + 0.98)$$

$$\text{Our Interval} = (249.22; 251.0)$$

- Any value within this interval is not significant

## *The Information Theory*

### *Part 9*

*Introduction  
Entropy*

## The Information Theory

The information conveyed by a message can be measured in bits by its probability

# *The Information Theory: Given Data*

*Attributes:*

$D1, D2, D3, D4$

$Domain(D1) = \{1, 2, 3\}$

$Domain(D2) = \{1, 2\}$

$Domain(D3) = \{1, 2\}$

$Domain(D4) = \{A, B\}$

D1	D2	D3	D4	D5
1	2	1	A	1
1	2	2	A	0
1	2	2	B	0
1	2	2	B	0
1	1	1	B	1
2	2	2	A	1
2	2	2	B	1
2	1	1	A	1
2	2	1	B	1
3	1	2	A	0
3	1	1	A	0
3	2	2	B	1
3	1	2	B	1
3	1	2	B	1

*Decision Attributes: D5*

$Domain(D5) = \{0, 1\}$

*Two Decisions: 0, 1*

## The Information Theory: Given Data

		D1						
		1	2	1	2	1	2	
D4		D3\ D2	1	2	1	2	1	2
A	1		1	1		0		
	2		0		1	0		
B	1	1	1		1	1		
	2		0		1	1	1	

D1	D2	D3	D4	D5
1	2	1	A	1
1	2	2	A	0
1	2	1	B	0
1	2	2	B	0
1	1	1	B	1
2	2	2	A	1
2	2	2	B	1
2	1	1	A	1
2	2	1	B	1
3	1	2	A	0
3	1	1	A	0
3	2	2	B	1
3	1	1	B	1
3	1	2	B	1

## *The Information Theory: Entropy*

THE INFORMATION THEORY: information conveyed by a message depends on its probability and can be measured in bits as minus the logarithm (base 2) of that probability

suppose  $D_1, \dots, D_m$  are  $m$  attributes and  $C_1, \dots, C_n$  are  $n$  decision classes in a given data. Suppose  $S$  is any set of cases, and  $T$  is the initial set of training cases  $S \subset T$ . The frequency of class  $C_i$  in the set  $S$  is:

$$freq(C_i, S) = \text{Number of examples in } S \text{ belonging to } C_i$$

If  $|S|$  is the total number of examples in  $S$ , the probability that an example selected at random from  $S$  belongs to class  $C_i$  is

$$freq(C_i, S) / |S|$$

The information conveyed by the message that “a selected example belongs to a given decision class,  $C_i$ ”, is determined by

$$-\log_2(freq(C_i, S) / |S|) \text{ bits}$$

## *The Information Theory: Entropy*

The information conveyed by the message “a selected example belongs to a given decision class,  $C_i$ ”

$$-\log_2(freq(C_i, S) / |S|) \text{ bits}$$

**The Entropy:** The expected information from a message stating class membership is given by

$$Info(S) = -\sum_{i=1}^k (freq(C_i, S) / |S|) * \log_2(freq(C_i, S) / |S|) \text{ bits}$$

$info(S)$  is known as the **entropy** of the set  $S$ . When  $S$  is the initial set of training examples,  $info(S)$  determines the average amount of information needed to identify the class of an example in  $S$ .

## The Information Theory: The Gain Ratio

S

### Example

$$freq(0, S) = 5$$

$$freq(1, S) = 9$$

$$freq(0, S) / |S| = 5/14$$

$$freq(1, S) / |S| = 9/14$$

The Entropy: the average amount of information needed to identify the class of an example in S

$$Info(S) = -9/14 * \log_2(9/14) - 5/14 * \log_2(5/14) = 0.94 \text{ bits}$$

Using D<sub>1</sub> to Split the data provide 3 subsets of data

$$Info_{D_1}(S_1) = -3/5 * \log_2(3/5) - 2/5 * \log_2(2/5) = 0.94$$

$$Info_{D_1}(S_2) = -4/4 * \log_2(4/4) = 0.94$$

$$Info_{D_1}(S_3) = -2/5 * \log_2(2/5) - 3/5 * \log_2(3/5) = 0.94$$

$$Info_{D_1}(S) = (5/14) * Info_{D_1}(S_1) + (4/14) * Info_{D_1}(S_2) + (5/14) * Info_{D_1}(S_3) = 0.694$$

D1	D2	D3	D4	D5
1	2	1	A	1
1	2	2	A	0
1	2	2	B	0
1	2	2	B	0
1	1	1	B	1
2	2	2	A	1
2	2	2	B	1
2	1	1	A	1
2	2	1	B	1
3	1	2	A	0
3	1	1	A	0
3	2	2	B	1
3	1	2	B	1
3	1	2	B	1

## *The Information Theory: The Gain Ratio*

Suppose attribute  $D_i$  is selected to be the root and it has  $k$  possible values. The expected information of selecting D to partition the training set S,  $\text{info}_{D_i}(S)$ , can be calculated as follows:

$$\text{Info}_{D_i}(S) = \sum_{i=1}^k \left( \frac{|S_i|}{|S|} \right) * \text{Info}(S_i)$$

$S_i$  is the subset number i of the data; k is the number of values of  $D_i$

The information gained by partitioning the training examples S into subset using the attribute  $D_1$  is given by

$$\text{Gain}(X_i) = \text{Info}(S) - \text{Info}_{D_i}(S)$$

## *The Information Theory: The Gain Ratio*

The attribute to be selected is the attribute with maximum gain value. Quinlan found out that a key attribute will have the maximum gain. This is not good!

$$Split\_Info(S) = -\sum_{i=1}^k (|S_i| / |S|) * \log_2(|S_i| / |S|)$$

The gain ratio is given by:

$$Gain\_Ratio(D_i) = Gain(D_i) / Split\_Info(D_i)$$

## *The Information Theory: The Gain Ratio*

Example Cont.

$$\begin{aligned} Info_{D_1}(S) &= \left(\frac{5}{14}\right) * Info_{D_1}(S_1) + \left(\frac{4}{14}\right) * Info_{D_1}(S_2) \\ &\quad + \left(\frac{5}{14}\right) * Info_{D_1}(S_3) = 0.694 \end{aligned}$$

$$Gain(D_1) = 0.94 - 0.694 = 0.246$$

$$\begin{aligned} Split\_Info(S) &= -\frac{5}{14} \log_2(5/14) - \frac{4}{14} \log_2(4/14) \\ &\quad - \frac{5}{14} \log_2(5/14) = 1.577 \text{ bits} \end{aligned}$$

$$Gain\_Ratio(D_1) = 0.246 / 1.577 = 0.156$$

S

D1	D2	D3	D4	D5
1	2	1	A	1
1	2	2	A	0
1	2	2	B	0
1	2	2	B	0
1	1	1	B	1
2	2	2	A	1
2	2	2	B	1
2	1	1	A	1
2	2	1	B	1
3	1	2	A	0
3	1	1	A	0
3	2	2	B	1
3	1	2	B	1
3	1	2	B	1

## *Information Gain: Term vs. Category*

It measures the classification power of a term

$$IG(t_k, c_i) = \sum_{c \in \{c_i, \bar{c}_i\}} \sum_{t \in \{t_k, \bar{t}_k\}} P(t, c) \log_2 \frac{P(t, c)}{P(t)P(c)}$$

$P(t_k, c_i)$  → probability document x contains term t and belongs to category c.

$P(\bar{t}_k, c_i)$  → probability document x does not contain term t and belongs to category c.




$P(t_k, \bar{c}_i)$  → probability document x contains term t and does not belong to category c.

$P(\bar{t}_k, \bar{c}_i)$  → probability document x does not contain term t and does not belong to category c.

$P(t)$  → probability of term t.

$P(c)$  → probability of category c.

## Testing The Membership



$$IG(t_k, c_i) = \sum_{c \in \{c_i, \bar{c}_i\}} \sum_{t \in \{t_k, \bar{t}_k\}} P(t, c) \log_2 \frac{P(t, c)}{P(t)P(c)}$$

$$IG(t_1, sport) = \frac{1}{9} * \log_2 \frac{1/9}{(2/27)*(9/27)} + \frac{8}{9} * \log_2 \frac{8/9}{(25/27)*(9/27)} \\ + \frac{1}{18} * \log_2 \frac{1/18}{(2/27)*(18/27)} + \frac{17}{27} * \log_2 \frac{17/27}{(25/27)*(18/27)}$$

## The Gain Ratio

$$GR(t_k, c_i) = \frac{\sum_{c \in \{c_i, \bar{c}_i\}} \sum_{t \in \{t_k, \bar{t}_k\}} P(t, c) \log_2 \frac{P(t, c)}{P(t)P(c)}}{- \sum_{c \in \{c_i, \bar{c}_i\}} P(c) \log_2 P(c)}$$

$P(t_k, c_i)$  → probability document x contains term t and belongs to category c.

$P(\bar{t}_k, c_i)$  → probability document x does not contain term t and belongs to category c.

$P(t_k, \bar{c}_i)$  → probability document x contains term t and does not belong to category c.

$P(\bar{t}_k, \bar{c}_i)$  → probability document x does not contain term t and does not belong to category c.

$P(t)$  → probability of term t.

$P(c)$  → probability of category c.

# Basics for Language Engineers

## Part 10

### *Evaluating Documents*

## *Term Frequency & Inverse Document Frequency*

Usually a combination of the term frequency and the inverse document frequency

$$TFIDF = w_{ik} = tf_{ik} \times idf_{ik}$$

$$tf_{ik} = 1 + \log_2(tr_{ik}) \quad \text{and zero when log = 0}$$

$$idf_{ik} = \log_2 \left( \frac{N}{n_{ik}} \right) \quad \text{and zero when log = 0}$$


$tf_{ik}$  is the term frequency of term  $i$  in document  $k$ ,  $tr_{ik}$  is the count of term  $i$  in document  $k$ ,  $idf_{ik}$  is the inverse document frequency of term  $i$  in document  $k$ ,  $N$  is the total number of documents in the collection,  $n_{ik}$  is the number of occurrence of term  $i$  in document  $k$ ,  $w_{ik}$  is the weight of term  $i$  in document  $k$ . Logarithm has been used to reduces the difference between the weight of high and low frequency terms. Logarithm of base 2 is used when vectors are full of binary TFIDF weights 0 and 1. Logarithm of base 10 is used when vectors are full of TFIDF weights except binary ones. TFIDF weights values are not normalized.

## *The Magical Recipe*

$$tf_{ik} = 1 + \log_2(tr_{ik}) \quad \text{and zero when log = 0}$$

$$idf_{ik} = \log_2\left(\frac{N}{n_{ik}}\right) \quad \text{and zero when log = 0}$$

$$\log_2 x = \log_{10} x / \log_{10} 2$$



## STATISTICAL ASSOCIATIONS

### Part II

*Association Rules*

# Learning Term-Association

T1	T2	T3	T4	T5	T6	T7	
1	1	1	1	1	1	1	D1
2	1	2	1	1	1	2	D2
1	2	3	1	1	1	3	D3
2	2	1	2	1	2	4	D4
1	1	2	2	1	1	5	D5
2	1	3	2	1	2	6	D6
1	2	1	3	2	2	7	D7
2	2	2	3	2	2	8	D8
1	1	3	3	2	2	9	D9
2	1	1	1	2	1	1	D10
1	2	2	1	2	2	2	D11
2	2	3	1	2	1	3	D12
1	1	1	2	3	1	4	D13
2	1	2	2	3	1	5	D14
1	2	3	2	3	1	6	D15
2	2	1	3	3	1	7	D16
1	1	2	3	3	2	8	D17
2	1	3	3	3	1	9	D18

D1	D2	D3	D4	D5	D6	D7	
1	1	1	1	1	1	1	T1
2	1	2	1	1	1	2	T2
1	2	3	1	1	1	3	T3
2	2	1	2	1	2	4	T4
1	1	2	2	1	1	5	T5
2	1	3	2	1	2	6	T6
1	2	1	3	2	2	7	T7
2	2	2	3	2	2	8	T8
1	1	3	3	2	2	9	T9
2	1	1	1	2	1	1	T10
1	2	2	1	2	2	2	T11
2	2	3	1	2	1	3	T12
1	1	1	2	3	1	4	T13
2	1	2	2	3	1	5	T14
1	2	3	2	3	1	6	T15
2	2	1	3	3	1	7	T16
1	1	2	3	3	2	8	T17
2	1	3	3	3	1	9	T18

# Learning Term-Association

AR Syntax:

(condition 1) (condition 2) ... (condition n) strength of association

Suppose we quantized the term weights

Drive two association rules with two  
Conditions and frequency greater than 0.25.

$(T1 = 1) (T6 = 1)$

5/18

$(T1 = 2) (T2 = 1)$

5/18

Question:

Drive association rules with two conditions  
and frequency greater than 0.38.

T1	T2	T3	T4	T5	T6	T7	T8
1	1	1	1	1	1	1	1
2	1	2	1	1	1	2	2
1	2	3	1	1	1	3	3
2	2	1	2	1	2	4	4
1	1	2	2	1	1	5	5
2	1	3	2	1	2	6	6
1	2	1	3	2	2	7	1
2	2	2	3	2	2	8	2
1	1	3	3	2	2	9	3
2	1	1	1	2	1	1	4
1	2	2	1	2	2	2	5
2	2	3	1	2	1	3	6
1	1	1	2	3	1	4	1
2	1	2	2	3	1	5	2
1	2	3	2	3	1	6	3
2	2	1	3	3	1	7	4
1	1	2	3	3	2	8	5
2	1	3	3	3	1	9	6

# Learning Term-Association

The strength of an association rule can be measured by:

- Leverage
- Coverage
- Support
- Strength
- Lift

## 1. Calculating LEVERAGE for the rule.

$$(T1 = 2) \quad (T2 = 1)$$

- Number of records = 16
- Records having ( $T1 = 2$ ) = 8
- Records having ( $T2 = 1$ ) = 9
- Records having ( $T1 = 2$ ) ( $T2 = 1$ ) = **4**
- % of the cover ( $T1 = 2$ ) ( $T2 = 1$ ) =  $4/16$
- Records expected to be covered by ( $T1 = 2$ ) ( $T2 = 1$ ) if they were independent =  $(8 * 9) / 16 = \text{4.5}$
- Leverage Count =  $4.5 - 4 = 0.5$
- Leverage Proportion =  $0.5 / 16 = 1/32$

T1	T2	T3	T4	T5
1	1	1	1	1
2	1	2	1	1
1	2	3	1	1
2	2	1	2	1
1	1	2	2	1
2	1	3	2	1
1	2	1	3	2
2	2	2	3	2
1	1	3	3	2
2	1	1	1	2
1	2	2	1	2
2	2	3	1	2
1	1	1	2	3
2	1	2	2	3
1	2	3	2	3
2	1	1	3	3

# *Learning Term-Association*

## 2. Calculating COVERAGE for the rule:

(T1 = 2) (T2 = 1)

- The coverage count for all conditions but the last one (T2=1) = 8
- The coverage proportional = 8/16 = 1/2

## 3. Calculating SUPPORT for the rule:

(T1 = 2) (T2 = 1)

- The support count for all conditions = 4
- The support proportional = 4/16 = 1/4

## 4. Calculating STRENGTH for the rule:

(T1 = 2) (T2 = 1)

- The strength count for all conditions but the last one (T2=1) = 8
- The last condition covers 4 out of those 8
- The strength proportional = 4/8 = 1/2

T1	T2	T3	T4	T5
1	1	1	1	1
2	1	2	1	1
1	2	3	1	1
2	2	1	2	1
1	1	2	2	1
2	1	3	2	1
1	2	1	3	2
2	2	2	3	2
1	1	3	3	2
2	1	1	1	2
1	2	2	1	2
2	2	3	1	2
1	1	1	2	3
2	1	2	2	3
1	2	3	2	3
2	1	1	3	3

# *Learning Term-Association*

## 5. Calculating LIFT for the rule:

(T1 = 2) (T2 = 1)

- Total number of examples = 16
- Records covered by all conditions but the last condition (T2=1) = 8
- Records covered by the last condition = 8
- Records covered by all conditions = 4
- Strength =  $4 / 8 = 1/2$
- Cover proportion of all conditions but the last one (T2=1) =  $8 / 16 = 1/2$
- LIFT = strength / (cover proportion of all condition but the last) =  $(1/2) / (1/2) = 1$

T1	T2	T3	T4	T5
1	1	1	1	1
2	1	2	1	1
1	2	3	1	1
2	2	1	2	1
1	1	2	2	1
2	1	3	2	1
1	2	1	3	2
2	2	2	3	2
1	1	3	3	2
2	1	1	1	2
1	2	2	1	2
2	2	3	1	2
1	1	1	2	3
2	1	2	2	3
1	2	3	2	3
2	1	1	3	3

# The Magnum Opus System

**M Magnum Opus - Tutorial.data**

File Edit Modes Action Preferences View Help

Tutorial.data: 500 cases / 500 holdout cases / 39 values

Search for: RULES    Maximum no.: 100    Maximum size: 4  
 Search by: LEVERAGE    Proportion    Count  
 Filter out: INSIGNIFICANT    Minimum leverage: -1.0    -2147483647    Minimum strength: 0.0  
 Minimum coverage: 0.0    1    Minimum lift: 0.0  
 Minimum support: 0.0    0     Use m-estimate

Values allowed on LHS:  
 Profitability99<438  
 438<=Profitability99<=931  
 Profitability99>931  
 Profitability98<368  
 368<=Profitability98<=754  
 Profitability98>754  
 Spend99<2200  
 2200<=Spend99<=4464  
 Spend99>4464  
 Spend98<1927  
 1927<=Spend98<=4088  
 Spend98>4088  
 NoVisits99<37  
 37<=NoVisits99<=69  
 NoVisits99>69  
 NoVisits98<33  
 33<=NoVisits98<=66  
 NoVisits98>66  
 Dairy<250

Values allowed on RHS:  
 Profitability99<438  
 438<=Profitability99<=931  
 Profitability99>931  
 Profitability98<368  
 368<=Profitability98<=754  
 Profitability98>754  
 Spend99<2200  
 2200<=Spend99<=4464  
 Spend99>4464  
 Spend98<1927  
 1927<=Spend98<=4088  
 Spend98>4088  
 NoVisits99<37  
 37<=NoVisits99<=69  
 NoVisits99>69  
 NoVisits98<33  
 33<=NoVisits98<=66  
 NoVisits98>66  
 Dairy<250

Ready

Attributes and their values for the Tutorial database

- Profitability99: numeric 3
- Profitability98: numeric 3
- Spend99: numeric 3
- Spend98: numeric 3
- NoVisits99: numeric 3
- NoVisits98: numeric 3
- Dairy: numeric 3
- Deli: numeric 3
- Bakery: numeric 3
- Grocery: numeric 3
- SocioEconomicGroup: categorical
- Promotion1: t, f
- Promotion2: t, f

*Statistical Association*

*Magnum Opus*

*DEMO*


## DECISION TREES

### Part 12


*Using Statistical &  
Information Theory*

# *Learning Decision Trees*


- A Tree is a Directed Acyclic Graph (DAG) + each node has one parent at most
- A Decision Tree is a tree where nodes associated with attributes, edges associated with attribute values, and leaves associated with decisions



Example:




# *Learning Decision Trees*



# Information Theory

## Example

- T2 is quantized into two intervals at 21 ( $T2 \leq 21$ ) and ( $T2 > 21$ )
- T3 is quantized into two intervals at 15 ( $T3 \leq 15$ ) and ( $T3 > 15$ )



T1	T2	T3	T4	D
1	25	10	A	1
1	30	30	A	0
1	35	25	B	0
1	22	35	B	0
1	19	10	B	1
2	22	30	A	1
2	33	18	B	1
2	14	5	A	1
2	31	15	B	1
3	21	20	A	0
3	15	10	A	0
3	25	20	B	1
3	18	20	B	1
3	20	36	B	1

## Decision Trees

C5



*DEMO*

## NEURAL NETWORKS


Part 13

*How It Works?*

# Learning Neural Networks




# *Learning Neural Networks*




## The Sigmoid Function

To avoid setting the threshold:



# Learning Neural Networks




# MACHINE TRANSLATION

## Part 14

*Statistical Machine Translation*

# Statistical Machine Translation

- For each English sentence “e”, we need the Arabic sentence “a” which maximize  $P(a|e)$   
$$P(a|e) = P(a) * P(e|a) / P(e)$$



# Language Model

- A statistical language model assigns a probability to a sequence of  $m$  words by means of a probability distribution
- Record every sentence that anyone ever says in Arabic; Suppose you record a database of one billion utterances; If the sentence “كيف حالك؟” appears 76,413 times in that database, then we say  $P(\text{كيف حالك}?) = 76,413/1,000,000,000 = 0.000076413$
- One big problem is that many perfectly good sentences will be assigned a  $P(e)$  of zero

Arabic Sentence	Probability
كيف حالك	0.000076413
الولد سعيد	0.000066392

# N-Grams

- An n-word substring is called an n-gram
- If n=2, we say bigram. If n=3, we say trigram
- Let  $P(y | x)$  be the probability that word y follows word x

$P(y | x) = \text{number-of-occurrences}(\text{"xy"}) / \text{number-of-occurrences}(\text{"x"})$

$P(z | x y) = \text{number-of-occurrences}(\text{"xyz"}) / \text{number-of-occurrences}(\text{"xy"})$

- ➔  $P(\text{ذهب} | \text{الولد} | \text{إلى} | \text{المدرسة}) = (\text{ذهب} | \text{الولد} | \text{إلى} | \text{المدرسة}) * (\text{إلى} | \text{المدرسة}) * (\text{الولد} | \text{ذهب}) * (\text{المدرسة} | \text{نهاية الجملة})$
- ➔  $P(\text{ذهب} | \text{الولد} | \text{إلى} | \text{المدرسة}) = (\text{ذهب} | \text{الولد} | \text{إلى} | \text{المدرسة}) * (\text{ذهب}, \text{الولد} | \text{إلى}) * (\text{ذهب}, \text{الولد} | \text{نهاية الجملة}) * (\text{إلى}, \text{المدرسة} | \text{نهاية الجملة}) * (\text{المدرسة}, \text{نهاية الجملة} | \text{نهاية الجملة})$

# N-Grams Language Model

$$P(w_1, \dots, w_m) = \prod_{i=1}^m P(w_i | w_1, \dots, w_{i-1}) \approx \prod_{i=1}^m P(w_i | w_{i-(n-1)}, \dots, w_{i-1})$$

$$P(w_i | w_{i-(n-1)}, \dots, w_{i-1}) = \frac{\text{count}(w_{i-(n-1)}, \dots, w_i)}{\text{count}(w_{i-(n-1)}, \dots, w_{i-1})}$$

Example:

In a bigram ( $n=2$ ) language model, the approximation looks like

$$P(I, \text{saw}, \text{the}, \text{red}, \text{house}) \approx P(I)P(\text{saw} | I)P(\text{the} | \text{saw})P(\text{red} | \text{the})P(\text{house} | \text{red})$$

In a trigram ( $n=3$ ) language model, the approximation looks like

$$P(I, \text{saw}, \text{the}, \text{red}, \text{house}) \approx P(I)P(\text{saw} | I)P(\text{the} | I, \text{saw})P(\text{red} | \text{saw}, \text{the})P(\text{house} | \text{the}, \text{red})$$

# Translation Model

- $P(a | e)$ , the probability of an Arabic string “a” given an English string “e”. This is called a translation model
- $P(a | e)$  will be a module in overall English-to-Arabic machine translation system; When we see an actual English string  $e$ , we want to reason backwards ... What Arabic string  $a$  is (1) likely to be uttered, and (2) likely to subsequently translate to  $e$ ? We're looking for the  $a$  that maximizes  $P(a) * P(e | a)$

Arabic Sentence	English Sentence	$P(a e)$
ذهب الولد إلى المدرسة	The boy went to School	0.0034
انخفاض البورصةاليوم	Today, the stock market went down	0.00021
:	:	

## Translation Model


- For each word  $a_i$  in an Arabic sentence ( $i = 1 \dots l$ ), we choose a fertility  $\phi_i$ . The choice of fertility depends on the Arabic word in question. It is not dependent on the other Arabic words in the Arabic sentence, or on their fertilities
- For each word  $a_i$ , we generate  $\phi_i$  English words. The choice of English word depends on the Arabic word that generates it. It is not dependent on the Arabic context around the Arabic word. It is not dependent on other English words that have been generated from this or any other Arabic word
- All those English words are permuted. Each English word is assigned an absolute target “position slot.” For example, one word may be assigned position 3, and another word may be assigned position 2 -- the latter word would then precede the former in the final English sentence. The choice of position for a English word is dependent solely on the absolute position of the Arabic word that generates it

# STATISTICS

## Part 15

*Analysis of Variance*  
ANOVA

# Analysis of Variance ANOVA




# ONE WAY ANOVA

- Evaluate the difference among the means of three or more populations
- **Assumptions**

Populations are normally distributed

Populations have equal variances

Samples are randomly and independently drawn



$$H_0 : \mu_1 = \mu_2 = \mu_3 = \dots = \mu_k$$

$$H_A : \text{Not all } \mu_i \text{ are the same}$$


All Means are the same:  
The Null Hypothesis is True

# ONE WAY ANOVA


$$H_0 : \mu_1 = \mu_2 = \mu_3 = \dots = \mu_k$$

$$H_A : \text{Not all } \mu_i \text{ are the same}$$

At least one mean is different:  
The Null Hypothesis is NOT true  
(Treatment Effect is present)



or



$$\mu_1 = \mu_2 \neq \mu_3$$

$$\mu_1 \neq \mu_2 \neq \mu_3$$

## Partitioning the Variations

$$SST = SSB + SSW$$

SST = Total Sum of Squares

SSB = Sum of Squares Between


SSW = Sum of Squares Within

**Total Variation** = the aggregate dispersion of the individual data values across the various factor levels (SST)

**Between-Sample Variation** = dispersion among the factor sample means (SSB)

**Within-Sample Variation** = dispersion that exists among the data values within a particular factor level (SSW)

# Partition of Total Variation



# Total Sum of Squares

$$\boxed{\text{SST} = \text{SSB} + \text{SSW}}$$

$$\boxed{\text{SST} = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{\bar{x}})^2}$$

Where:

SST = Total sum of squares

k = number of populations (levels or treatments)

$n_i$  = sample size from population i


$x_{ij}$  = j<sup>th</sup> measurement from population i

$\bar{\bar{x}}$  = grand mean (mean of all data values)

# Total Variation

(continued)

$$SST = (x_{11} - \bar{\bar{x}})^2 + (x_{12} - \bar{\bar{x}})^2 + \dots + (x_{kn_k} - \bar{\bar{x}})^2$$



# Sum of Squares Between

$$SST = SSB + SSW$$

$$SSB = \sum_{i=1}^k n_i (\bar{x}_i - \bar{\bar{x}})^2$$

Where:

SSB = Sum of squares between

k = number of populations

$n_i$  = sample size from population i


$\bar{x}_i$  = sample mean from population i

$\bar{\bar{x}}$  = grand mean (mean of all data values)

# Between-Group Variation

$$SSB = \sum_{i=1}^k n_i (\bar{x}_i - \bar{\bar{x}})^2$$

Variation Due to  
Differences Among Groups




$$MSB = \frac{SSB}{k - 1}$$

Mean Square Between =  
SSB/degrees of freedom

# Between-Group Variation

(continued)

$$SSB = n_1(\bar{x}_1 - \bar{\bar{x}})^2 + n_2(\bar{x}_2 - \bar{\bar{x}})^2 + \dots + n_k(\bar{x}_k - \bar{\bar{x}})^2$$



# Sum of Squares Within

$$SST = SSB + SSW$$

$$SSW = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2$$

Where:

SSW = Sum of squares within

k = number of populations

$n_i$  = sample size from population i


$\bar{x}_i$  = sample mean from population i

$x_{ij}$  = j<sup>th</sup> measurement from population i

# Within-Group Variation

$$SSW = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2$$

Summing the variation within each group and then adding over all groups




$$MSW = \frac{SSW}{N - k}$$

Mean Square Within =  
SSW/degrees of freedom

# Within-Group Variation

(continued)

$$SSW = (x_{11} - \bar{x}_1)^2 + (x_{12} - \bar{x}_2)^2 + \dots + (x_{kn_k} - \bar{x}_k)^2$$



# One-Way ANOVA Table


Source of Variation	SS	df	MS	F ratio
Between Samples	SSB	k - 1	$MSB = \frac{SSB}{k - 1}$	$F = \frac{MSB}{MSW}$
Within Samples	SSW	N - k	$MSW = \frac{SSW}{N - k}$	
Total	$SST = SSB + SSW$	N - 1		

k = number of populations

N = sum of the sample sizes from all populations

df = degrees of freedom

# Tukey-Kramer in PHStat



Probability

Part 16

*Bayesian Networks*

# Bayesian Networks (Watch Me!)

# Conclusion

1- Basic Concepts

2- Introduction to Vectors

3- Probability

4- Statistics

5- Regression

6- Statistics & Testing

7- Test of Significance

8- Information Theory

9- Basics for Language Engineers

10- Statistical Association

11- Statistical Machine Translation

12- Analysis of Variance

13- Bayesian Networks

# REFERENCES

- W. Weaver (1955). Translation (1949). In: *Machine Translation of Languages*, MIT Press, Cambridge, MA.
- P. Brown, S. Della Pietra, V. Della Pietra, and R. Mercer (1993). The mathematics of statistical machine translation: parameter estimation. *Computational Linguistics*, 19(2), 263-311.
- S. Vogel, H. Ney and C. Tillmann. 1996. HMM-based Word Alignment in Statistical Translation. In COLING '96: The 16th International Conference on Computational Linguistics, pp. 836-841, Copenhagen, Denmark.
- F. Och and H. Ney. (2003). A Systematic Comparison of Various Statistical Alignment Models. *Computational Linguistics*, 29(1):19-51
- P. Koehn, F.J. Och, and D. Marcu (2003). Statistical phrase based translation. In *Proceedings of the Joint Conference on Human Language Technologies and the Annual Meeting of the North American Chapter of the Association of Computational Linguistics (HLT/NAACL)*.
- D. Chiang (2005). A Hierarchical Phrase-Based Model for Statistical Machine Translation. In *Proceedings of the 43rd Annual Meeting of the Association for Computational Linguistics (ACL'05)*.
- F. Och and H. Ney. (2003). A Systematic Comparison of Various Statistical Alignment Models. *Computational Linguistics*, 29(1):19-51
- P. Koehn, H. Hoang, A. Birch, C. Callison-Burch, M. Federico, N. Bertoldi, B. Cowan, W. Shen, C. Moran, R. Zens, C. Dyer, O. Bojar, A. Constantin, E. Herbst. 2007. Moses: Open Source Toolkit for Statistical Machine Translation. ACL 2007, Demonstration Session, Prague, Czech Republic
- Q. Gao, S. Vogel, "Parallel Implementations of Word Alignment Tool", Software Engineering, Testing, and Quality Assurance for Natural Language Processing, pp. 49-57, June, 2008
- W. J. Hutchens and H. Somers. (1992). An Introduction to Machine Translation, 18.3:322. ISBN 0-12-36280-X

# REFERENCES

- W. The Sage Dictionary of Statistics, pg. 76, Duncan Cramer, Dennis Howitt, 2004, [ISBN 076194138X](#)
- E.L. Lehmann and Joseph P. Romano (2005). *Testing Statistical Hypotheses* (3E ed.). New York, NY: Springer. [ISBN 0387988645](#)
- D.R. Cox and D.V.Hinkley (1974). *Theoretical Statistics*. [ISBN 0412124293](#).
- [Fisher, Sir Ronald A.](#) (1956) [1935]. "[Mathematics of a Lady Tasting Tea](#)". in James Roy Newman. *The World of Mathematics, volume 3*.  
<http://books.google.com/books?id=oKZwtLQTmNAC&pg=PA1512&dq=%22mathematics+of+a+lady+tasting+tea%22&sig=8-NQlCLzrh-oV0wjfwa0EgspSNU>
- R.A. Fisher, the Life of a Scientist, Box, 1978, pl34
- Mccloskey, Deirdre (2008). *The Cult of Statistical Significance*. Ann Arbor: University of Michigan Press. [ISBN 0472050079](#)
- *What If There Were No Significance Tests?*, Harlow, Mulaik & Steiger, 1997, [ISBN 978-0-8058-2634-0](#)
- Rosnow, R.L. & Rosenthal, R. (1989). Statistical procedures and the justification of knowledge in psychological science. *American Psychologist*, 44, 1276-1284
- Loftus, G.R. 1991. On the tyranny of hypothesis testing in the social sciences. *Contemporary Psychology* 36: 102-105
- [Cohen, J.](#) 1990. Things I have learned (so far). *American Psychologist* 45: 1304-1312. ^ *Introductory Statistics*, Fifth Edition, 1999, pg. 521, Neil A. Weiss, [ISBN 0-201-59877-9](#)
- Ioannidis JP (July 2005). "Contradicted and initially stronger effects in highly cited clinical research". *JAMA* 294 (2): 218-28.

# REFERENCES

