

1.

## Grundbegriffe der Informatik Rolle/Funktion der medizinischen Datenbanken in Praxis und Forschung

2011.12.16.

gp.

2.

### Medizinische-/Bio-Informatik als inter-(multi-)disziplinäres Gebiet

- ✓ **Biologie**
- ✓ **Biotechnologie**
- ✓ **Entwicklungslehre**
- ✓ **Physiologie\* (ab Niveau der Gene bis Zusammenfunktion von Geweben, Organen)**
- ✓ **Genomik\***
- ✓ **Informationstechnologie**
- ✓ **Mathematik**
- ✓ **Molekülmodellierung**
- ✓ **Proteomik**
- ✓ **Statistik**

\*Empfohlen als wertvolles zu lesen  
<http://www.uni-heidelberg.de/presse/news/2106bartram.html>

#### Themen:

- I. Begriff und Maß der Information
- II. Codierung, Wirkungsgrad, Redundanz
- III. Genetischer Code, sein Informationsgehalt
- IV. Bio-Datenbanken

2011.12.16.

gp.

3.

### Begriff und Maß der Information



gp.

2011.12.16.

4.

Ein Zitat von Augustinus (\*354 — †430):

„Was ist also **die Zeit**? Wenn mich niemand danach fragt, weiß ich es, wenn ich es aber einem, der mich fragt, erklären sollte, weiß ich es nicht.“

„Was ist also **die Information**? Wenn mich niemand danach fragt, weiß ich es, wenn ich es aber einem, der mich fragt, erklären sollte, weiß ich es nicht.“

2011.12.16.

5.



Was ist die Information?



6.



“informatio”:

lat.: „bilden“, „eine Form, Gestalt, Auskunft geben.“

Information:

- Wissen (s. Wikipedia: von althochdeutsch *wizzan*; zur indogermanischen Perfektform *woida* "ich habe gesehen"), Kenntnis von jemandem/etwas;
- Kenntnis auf Grund Nachrichten;
- Kenntnis/Wissen von einem gegebenen Umstand/Prozess;

2011.12.16.

gp.

**Information als Begriff der Informatik:**

Information ist diejenige Bedeutung, welche durch eine Nachricht getragen ist.



7.

Information enthält – auf Grund einer anderen Definition - "**sinnvolle Daten**";

- besitzt mehreren Formen;
- kann auf unterschiedlichen Datenträgern gespeichert werden, vorhanden sein.

Wie kann man Informationen erwerben?



8.

weitere Definitionen:

**die Information:**

- eine neue Kenntnis, die die Ungewissheit/Unbestimmtheit vermindert.
- **Reihenfolge/Struktur der Zeichen**, worin die Zeichen mit bestimmten Wahrscheinlichkeiten auftreten;
- ihr Bedeutung beimessen werden kann – besitzt Bedeutungsgehalt;
- treibt den Empfänger/Adressat zu einem bestimmten Verhalten, einer Bewegung an

2011.12.16.

gp.

2011.12.16.

gp.

9.

**Reihenfolge/Struktur der Zeichen, worin die Zeichen mit bestimmten Wahrscheinlichkeiten auftreten**

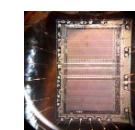
**Zeichen** (entsprechend der Bilder):

- ✓ Stimme, Worte(Wörter), Klang/Intonation;
- ✓ Buchstaben, Worte, Sätze, Kontext;
- ✓ die den physiologischen Zustand beschreibenden Eigenschaften, Charakteristiken



2011.12.16.

gp.



Speicherung (Z.B.):

bei Computern:

- ✓ magnetisch,
- ✓ optisch,
- ✓ integrierte Schaltkreise (ROM, RAM,... )
- ✓ usw.:

in medizinischer Praxis:

- die primäre Quelle ist der Patient;
- Speicherung der gewonnenen diagnostischen Testwerte;

2011.12.16.

gp.

### Zahlensysteme:

Dezimal: 0,...,9; Binär: 0,1

$$2008_{(10)} = 2 \cdot 10^3 + 0 \cdot 10^2 + 0 \cdot 10^1 + 8 \cdot 10^0 \quad 2008_{(10)} = ?_{(2)}$$

	Rest	Potenz(n)	$2^n$	Multiplikator
$2^0=1$				1
$2^1=2$	2008	10	1024	1
$2^2=4$	984	9	512	1
$2^3=8$	472	8	256	1
$2^4=16$	216	7	128	1
$2^5=32$	88	6	64	1
$2^6=64$	24	5	32	0
$2^7=128$	24	4	16	1
$2^8=256$	8	3	8	1
$2^9=512$	0	2	4	0
$2^{10}=1024$	0	1	2	0
$2^{11}=2048$	0	0	1	0

2011.12.16.

gp.

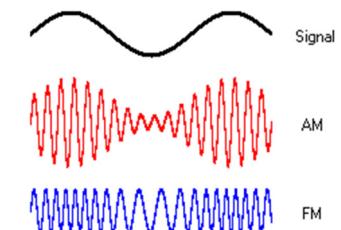
11.

$$2008_{(10)} = 11111011000_{(2)}$$

I bit: eine einzige Stelle für Datenspeicherung in Computern (Taschenrechnern);  
1 byte: acht bit

SI: 1kbit=10<sup>3</sup> bit; (meistens) in Informatik: 1kbit = 1024 bit

### Code



2011.12.16.

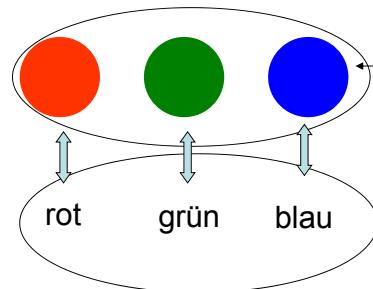
gp.

10.

### Quelle und Speicherung der Informationen

Als "sinnvolle Daten", kann die Information in unterschiedlichen Formen, auf verschiedenen Datenträgern gespeichert werden.

## Codierung – Decodierung (Ver/Ent-schlüsselung)



13.

**gegenseitig-eindeutige Zuordnung zwischen den Elementen zweier Mengen**

**Sender:** sendet/speichert /codiert Informationen in verschlüsselter Form

**Empfänger:** empfängt und entschlüsselt die bekommenen Informationen

2011.12.16.

gp.

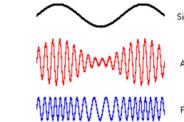
## Die Rolle und Funktion der Codierung

- ✓ Speicherung und Übertragung der Informationen durch Anwendung eines bestimmten Zeichensystems

z.B.: Morse-Code  
Pheromone  
DNS-Sequenzen  
Hologramm

### Zeichensysteme:

Daten;  
Zahlen;  
Zeichen (z.B: Piktogramme, Hieroglyphen);  
Buchstaben;  
Aminosäuren (im Aufbau von Proteinen);



**Bedingungen:**

- ✓ Vereinbarung zwischen dem Sender und Empfänger in den Formulierungen und Regeln (eingeschlossen die Übertragungsmethode) der Informationen z.B.: die Zeichenfolge "blau" muss zweiseitig das selbe bedeuten;
- ✓ die Zeichensätze müssen für den Sender und den Empfänger bekannt sein;

2011.12.16.

gp.



## Zusammenfassung I.

### Information — Codierung

- ✓ Beschreibung, Speicherung und Übertragung einer Erscheinung, Eigenschaft mit Hilfe eines Zeichensystems (Codierung);
- ✓ angenommen, dass der "Sender" und der "Empfänger" gleichzeitig oder nacheinander anwesend sind (Informationsübertragung/fluss)  
↔ die Information existiert nicht allein/selbstständig

15.

## Fragen

- Wie groß ist der Informationsgehalt einer Information?
- Wie kann man effizient Codieren?
- Wie wäre es möglich den Informationsübertrag im Allgemeinen zu beschreiben?



gp.

2011.12.16.

gp.

## Informationsgehalt

- der Patient hat einen lockeren Zahn
- alle Zähne eines Patienten sind locker

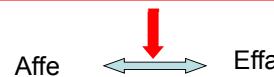
Welche dieser Informationen weist größeren Gehalt auf?

### Auf Grund Gefühle, Eingabeung:

eine Information mit geringerer Wahrscheinlichkeit weist größeren Informationsgehalt auf.

### Auf Grund einer Definition der Information:

- Reihenfolge/Struktur der Zeichen, worin die Zeichen mit bestimmten Wahrscheinlichkeiten auftreten



derselbe Informationsgehalt

2011.12.16.

gp.

### Definition 2.:

Der Informationsgehalt ist gleich der minimalen Anzahl der Bits (in sh-Einheiten), die benötigt sind um ein Zeichen der Wahrscheinlichkeit p, verschlüsselt mit minimalen Zeichensatz, effizient zu übertragen:

$$I(p) = -\log_2(p) \quad [I] = \text{bit v. sh}$$

Beispiel:

- $p = 0,5 \quad I(p) = -\log_2(0,5) = -\log_2(1/2) = \log_2(2) = 1;$   
➤  $p = 0,25 \quad I(p) = -\log_2(0,25) = -\log_2(1/2^2) = 2 * \log_2(2) = 2$

Je kleiner die Auftrittswahrscheinlichkeit eines Zeichens ist, desto größer ist sein Informationsgehalt.

17.

## Informationsgehalt der statistisch unabhängigen Ereignissen

Bezeichne  $p$  die Wahrscheinlichkeit eines gegebenen Ereignisses (d.h. jetzt Zeichen)

Der Informationsgehalt,  $I(p)$ , dieses Zeichens ist:

Definition 1.:

$$I(p) = \log_2\left(\frac{1}{p}\right) = -\log_2(p) \quad [I] = \text{bit oder sh}$$

sh; nach dem Namen Claude Shannon, der Begründer der Informationstheorie

2011.12.16.

gp.

19.

20.

$$I(p=1) = -\log_2(1) = 0 \quad \rightarrow$$

besteht die "Botschaft" nur aus einem einzigen Zeichen, ist sein Informationsgehalt gleich Null

Quiz: Wenn die relative Häufigkeit eines Zeichens  $p=0,0625$  ist, wie viele Bits sind nötig für die maximal-effiziente Übertragung?

$$I = -\log_2(0,0625) = -\lg(0,0625)/\lg(2) = 4 \text{ bit}$$

2011.12.16.

gp.

2011.12.16.

gp.

### Informationsgehalt einer Zeichenfolge

m: Anzahl der unterschiedlichen Ereignisse (m-Ausgänge eines Versuches; d. Anzahl der Buchstaben, usw...);  
 $p_k$ : relative Häufigkeit/Wahrscheinlichkeit eines Ereignisses;  
N: Anzahl der allen Ereignissen (=  $n_1+n_2+\dots+n_m$ ; Häufigkeiten)

#### Definition 3.:

$$I = \sum_{k=1}^m n_k I_k = -\sum_{k=1}^m [n_k \cdot \log_2(p_k)]$$

zu übertragen:  
„abradabra“

I=?; wie viele Bits ist, minimal, benötigt zu einer Übertragung?  
Wie kann man am effizientesten verschlüsseln, speichern?

2011.12.16.

gp.

Wie kann man effizient kodieren?

Ziel:  
der minimale Aufwand an Zeit, Energie,...

- Speicherung
- Übertragung

Lösung:

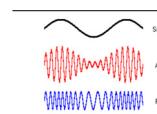
1. gemäß dem Informationsgehalt (d.h. mit minimaler Anzahl der benötigten Bits)
2. Zuteilung der kürzesten Codes zu Zeichen mit höchster Wahrscheinlichkeit.



N=1  
m=5

„Abra“  
1 2 3 4 5

Abrakadabra



Zeichen	$n_k$ (Häufigkeit)	$f_k$ (rel. Häufigkeit)	$I_k = -n_k * \log_2(f_k)$	
a	5	0.4545	5.688	
b	2	0.1818	4.919	
r	2	0.1818	4.919	
k	1	0.0909	3.459	
d	1	0.0909	3.459	
N=	11			
			$\Sigma I = 22.444$	

Eine effiziente Übertragung benötigt 23 bit für "Abra"

### die Rolle der Redundanz

Redundanz (nach Duden):

- das Vorhandensein von eigentlich überflüssigen, für die Information nicht notwendigen Elementen;
- Überladung mit Merkmalen

Redundanz ist diejenige Eigenschaft/Phänomen, wenn das Auftreten einiger Zeichen in einer Zeichenfolge, auf Grund früherer oder späterer Zeichen, vorhersagbar ist.

z.B.:

- „q“ ist verbunden mit einem folgenden Auftreten von „u“
- in früheren Zeiten (Ehepaar = Frau und Mann)

Konsequenzen:

- ✓ die Effizienz der Informationsübertragung nimmt ab
- ✓ Möglichkeit für Kontrolle/Korrektur/Reparatur der Kodierung/Übertragung (geräuschvolle Übertragungskanale, teilweise verlorene Signale, ...)

## der durchschnittliche Informationsgehalt – Entropie einer Information



$$\bar{x} = \frac{\sum x_i}{N}$$

**Definition 4.:**

$$\bar{I} = \frac{\sum_{k=1}^m n_k \cdot I_k}{N} = -\sum_{k=1}^m \left[ \frac{n_k}{N} \cdot \log_2(p_k) \right] = H$$

**H: Entropie einer Versuchsserie/Zeichenfolge; Einheit: bit**

$$H = \bar{I} = -\sum_{k=1}^m [p_k \cdot \log_2(p_k)]$$

26.

2011.12.16.

gp.



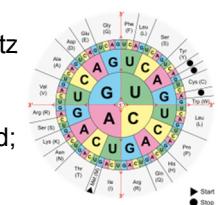
## Informationsgehalt der genetischen Codes

**Fragen:**

- 1. wie groß sei der minimale Zeichensatz (Anzahl der unterschiedlichen Nukleotiden Codon) für Kodierung der ~ 20 Aminosäuren?
- 2. Wie groß ist der Informationsgehalt einer DNS-Sequenz?

**Antworten 1.:** (wie es bekannt ist 4)

- ✓ Nukleotidpaare ermöglichen nur einen Variationssatz  $4^2=16$ ;
- ✓ NukleotidTriplets (Codons) –  $4^3 = 64$ ;
- Kodierung über Triplets ist minimal und ausreichend;
- einige Aminosäuren sind durch mehreren Codons kodiert;
- einige Triplets besitzen andere Funktionen



2011.12.16.

gp.

**Antwort 2:**

- ✓ sei angenommen, dass die Nukleotidbasen treten gleichwahrscheinlich auf
- ✓ —  $p_k=p=0,25$ ;  $I_1=I_2=I_3=I_4=I_b$
- ✓ Wenn die Länge der Sequenz N ist, dann ist  $n_k=N/4=n$

$$I = \sum_{k=1}^4 n_k I_k = n I_1 + n I_2 + n I_3 + n I_4 = 4 \cdot n \cdot I_b$$

$$I = 4 \cdot N / 4 \cdot I_b = N \cdot I_b = -N \cdot \log_2(p)$$

$$I = -N \cdot \log_2(0,25) = N \cdot 1,6021 \text{ bit}$$

$N=10$  → ~16 bit

$N=10^6$  → ~ $1,6 \cdot 10^6$  bit

28.



## Zusammenfassung II.

- der Informationsgehalt einer Information kann mit der Informationsentropie beschrieben werden;
- der maximale Wirkungsgrad, die größte Effizienz, einer Kodierung wird mit einer dem Informationsgehalt entsprechenden minimalen Zeichensatz erreicht.
- Die durch DNS- oder Proteinmoleküle getragenen Informationen kann auf Grund der Häufigkeiten der monomer Nukleotiden oder Aminosäuren berechnet werden.

2011.12.16.

gp.

2011.12.16.

gp.



30.

Zielsetzung, Aufgabe:

- Speicherung,
- Organisierung,
- Qualitätskontrolle,
- Analyse,
- der Öffentlichkeit zugänglich machen

der Daten, Wissen, Kenntnisse der biologischen, medizinischen Wissenschaften

Anforderungen:

- ✓ schnell und effizient Zugriff;
- ✓ Auffinden nur für die Benutzer wichtige, wesentliche Informationen.

2011.12.16.

gp.

spezialisierte Datenbanken:

Vorteil: kürzer Zugriffszeit, mehr detaillierte Daten

Nachteil: Mangel an Zusammenhängen

weniger spezialisierten Datenbanken:

Vorteil: auch die Zusammenhänge zwischen den Daten/Erscheinungen sind durchsuchbar.

Nachteil: mehrere Gesichtspunkte sind gebraucht für Auffinden einer Kenntnis

Z.B.: cholesterol — 182358  
 cholesterol transport — 9055  
 cholesterol transport pediatrics — 128

2011.12.16.

gp.

### **cholesterol transport pediatrics Chan T. — 2**

Jelinek D, Patrick SM, Kitt KN, **Chan T**, Francis GA, Garver WS.: Physiological and coordinate downregulation of the NPC1 and NPC2 genes are associated with the sequestration of LDL-derived cholesterol within endocytic compartments. J Cell Biochem. 2009 Sep 10. [Epub ahead of print]  
 PMID: 19746448

Sahoo D, Trischuk TC, **Chan T**, Drover VA, Ho S, Chimini G, Agellon LB, Agnihotri R, Francis GA, Lehner R. ABCA1-dependent lipid efflux to apolipoprotein A-I mediates HDL particle formation and decreases VLDL secretion from murine hepatocytes. J Lipid Res. 2004 Jun;45(6):1122-31. Epub 2004 Mar 1.

32.

**GenBank** from NCBI (National Center for Biotechnology Information) Genetic Sequence Databank;

**EMBL Nucleotide Sequence Database** (European Molecular Biology Laboratory);

**SwissProt** és **PROSITE** (protein sequence database );  
**EC-ENZYME** ;

**RCSB PDB** (3-D makromolekularer Aufbau);

**MEDLINE**: Medizin, Zahnmedizin, Veterinärmedizin, forschungsmedizinische Informationen,...

**PUBMed** (<http://www.ncbi.nlm.nih.gov/sites/entrez>):  
 Medizin, Biologie, Biochemie,...

2011.12.16.

gp.

2011.12.16.

gp.

31.

Innerhalb der Universität:

<http://www.lib.sote.hu/>

Quellen

Datenbanken

Wissenschaftliche Artikel

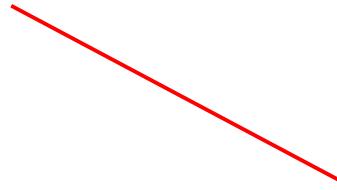
Bücher

szientometrische/bibliometrische Datenbanken

pharmazeutische Datenbanken

2011.12.16.

gp.



C. Shannon (1916-2001)

2011.12.16.

gp.