

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

2012.12.18.

1.

gp.

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

- ✓ **Biologie**
- ✓ **Biotechnologie**
- ✓ **Entwicklungslehre**
- ✓ **Physiomek* (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>

2012.12.18.

2.

gp.

Themen:

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

2012.12.18.

3.

gp.

Begriff und Maß der Information



2012.12.18.

4.

gp.

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.“



5.

2012.12.18.

gp.

Information als Begriff der Informatik:

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



7.

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 beigemessen werden kann – besitzt Bedeutungsgehalt;
- treibt den Empfänger/Adressat zu einem bestimmten Verhalten, einer Bewegung an

2012.12.18.

gp.

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;

2012.12.18.


gp.

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

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

8.

Wie kann man Informationen erwerben?



2012.12.18.

gp.

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



2012.12.18.

gp.

Zahlensysteme:

Dezimal: 0,...,9; Binär: 0,1

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

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

$2^0=1$	Rest	Potenz(n)	2^n	Multiplikator
$2^1=2$	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

2012.12.18.

gp.

Quelle und Speicherung der Informationen

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

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;

2012.12.18.


gp.

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

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

SI: 1kbit=10³ bit; (meistens) in Informatik: 1kbit = 1024 bit


Code



2012.12.18.

gp.

Codierung – Decodierung (Ver/Ent-schlüsselung)



13.

gegenseitig-eindeutige Zuordnung zwischen den Elementen zwei Mengen

Sender: sendet/speichert /codiert Informationen in verschlüsselter Form;
Empfänger: empfängt und entschlüsselt die übertragenen Informationen

2012.12.18.

gp.

Die Rolle und Funktion der Codierung


14.

✓ Speicherung und Übertragung der Informationen durch Anwendung ein bestimmtes Zeichensystem

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;

2012.12.18.

gp.



Zusammenfassung I.

15.

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 (Informations-übertragung/fluss)*
 ↔ *die Information existiert nicht allein/selbstständig*

2012.12.18.

gp.

Fragen

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



16.

2012.12.18.

gp.

Informationsgehalt

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


Welche dieser Informationen weist größeren Gehalt auf?

Auf Grund Gefühle, Eingebung:

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

2012.12.18.

17.

gp.

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

2012.12.18.

18.

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:

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

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

2012.12.18.

19.

gp.

$I(p=1) = -\log_2(1) = 0$ \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?

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

2012.12.18.

20.

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 (= n₁+n₂+...+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:
 „abrakadabra“

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

2012.12.18.

21.



N=1
 m=5

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		
			ΣI= 22.444

Eine effiziente Übertragung benötigt 23 bit für "Abrakadabra"

22.

Wie kann man effizient kodieren?

Ziel:
 der minimale Aufwand an Zeit, Energie,...
 ✓ Speicherung
 ✓ Übertragung



Lösung:

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

2012.12.18.

gp.

24.

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 Man)

Konsequenzen:

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

2012.12.18.

gp.

25.

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

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

2012.12.18.

26.

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 $n_k = N/4 = n$

$$I = \sum_{k=1}^4 n_k I_k = nI_1 + nI_2 + nI_3 + nI_4 = 4 \cdot n \cdot I_b$$

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

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

N=10 → ~16 bit

N=10⁶ → ~1,6 · 10⁶ bit

2012.12.18.

gp.

Informationsgehalt der genetischen Codes

27.




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



2012.12.18.

gp.

28.

Zusammenfassung II.



29.

- 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.

2012.12.18.

gp.

Bioinformatische Datenbanken



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.

2012.12.18.

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

2012.12.18.

31.

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.

2012.12.18.

gp.

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,...

2012.12.18.

gp.

33.

Innerhalb der Universität:

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

Quellen

Datenbanken

Wissenschaftliche Artikel

Bücher

szientometrische/bibliometrische Datenbanken

pharmazeutische Datenbanken



C. Shannon (1916-2001)