

INHALT **V5: Proteinstruktur: Sekundärstruktur**

- Hierarchischer Aufbau der Proteinstruktur
- **Ramachandran-Plot**
- Vorhersage von Sekundärstrukturelementen aus der Sequenz
- Membranproteine
- Distanzmatrix, Strukturvergleich (DALI)

LERNZIELE

- lerne Prinzipien der Proteinstruktur kennen
- stelle Proteinstrukturen graphisch dar (Übung)

WOZU IST DAS GUT?

- Verständnis der dreidimensionalen Proteinstruktur macht erst deutlich, was die **Funktion** vieler Proteine ist.
- viele interessante **Strukturmotive** können bereits aus der Sequenz mit Bioinformatik-Methoden vorhergesagt werden

Funktion von Proteinen

Strukturproteine (Hüllenproteine von Viren, Cytoskelett)

Enzyme, die chemische Reaktionen katalysieren

Transportproteine und **Speicherproteine** (Hämoglobin)

Regulatoren wie Hormone und **Rezeptoren/Signalübertragungsproteine**

Proteine, die die Transkription kontrollieren
oder an Erkennungsvorgängen beteiligt sind:

Zelladhäsionsproteine, Antikörper

Warum sind Proteine so groß?

Proteine sind große Moleküle.

Ihre **Funktion** ist oft in einem kleinen Teil der Struktur, dem **aktiven Zentrum**, lokalisiert.

Der Rest?

- Korrekte **Orientierung** der Aminosäuren des aktiven Zentrums
- **Bindungsstellen** für Interaktionspartner
- Konformationelle **Dynamik**

Evolution der Proteine: Veränderungen der Struktur, die durch Mutationen in ihrer Aminosäuresequenz hervorgerufen werden.

Hierarchischer Aufbau

Primärstruktur – Sekundärstruktur – Tertiärstruktur – Quartärnere Struktur – Komplexe




Figure 2.1

Simple schematic showing the different levels of protein structure. From the sequence alone (the primary structure) to secondary structure (which contains local structural elements), to tertiary structure (where the structural elements fold to give a three-dimensional structure), to finally quaternary structure found when several tertiary structures form a multisubunit complex.

Hierarchischer Aufbau

Welche „Kräfte“ sind für die Ausbildung der verschiedenen „Strukturen“ wichtig?

Lösliche Proteine: wichtigstes Prinzip ist der **hydrophobe Effekt**.

Der Beitrag hydrophober WW zur Freien Enthalpie bei der Proteinfaltung und der Protein-Liganden-Wechselwirkung kann als proportional zur Grösse der während dieser Prozesse vergrabenen hydrophoben Oberfläche angesehen werden.

Membranproteine: sind im **Transmembranbereich** außen hydrophober als innen.

Man bezeichnet sie daher auch als „inside out“ Proteine.

Die wasserlöslichen Bereiche von Membranproteinen ähneln in ihrer Zusammensetzung den löslichen Proteinen.


Hydrophober Effekt

Beobachtung, dass die Überführung einer unpolaren Substanz/Oberflächenbereichs aus einem organischen bzw. Unpolaren Lösungsmittel nach Wasser

- (a) energetisch stark ungünstig ist
- (b) bei Raumtemperatur zu einer Abnahme der Entropie führt
- (c) zu einer Zunahme der Wärmekapazität führt.


Eisberg-Modell

W. Kauzman 1959



Wassermoleküle an einer hydrophoben Oberfläche sind in ihren möglichen Orientierungen stark eingeschränkt -> dies ist entropisch ungünstig.

Anwendungen der Hydrophobizität



Lesk-Buch

5.4 a) Hydrophobizitätsprofil des Lysozyms aus Hühnereiweiß (erzeugt mithilfe der „Primary Structure Analysis“-Werkzeuge unter <http://www.expasy.ch>). b) Struktur des gleichen Enzyms. Abschnitte, die den Minima im Hydrophobizitätsprofil entsprechen, sind durch etwas dickere Linien gekennzeichnet.

Peptidbindung



In Peptiden und Proteinen sind die Aminosäuren miteinander als lange Ketten verknüpft.

Ein Paar ist jeweils über eine „**Peptidbindung**“ verknüpft.

Die Aminosäuresequenz eines Proteins bestimmt seinen „**genetischen code**“.

Die Kenntnis der Sequenz eines Proteins allein verrät noch nicht viel über seine Funktion.

Entscheidend ist seine **drei-dimensionale Struktur**.



Eigenschaften der Peptidbindung

E.J. Corey und **Linus Pauling** studierten die Peptidbindung in den 1940'ern und 1950'ern.




Sie fanden: die C-N Länge ist 1.33 Å.
Sie liegt damit zwischen 1.52 Å und 1.25 Å,
was die Werte für eine Einfach- bzw.
Doppelbindung sind.

Die benachbarte C=O Bindung hat eine Länge
von 1.24 Å, was etwas länger als eine typische
Carbonyl- C=O Doppelbindung ist (1.215 Å).

→ die Peptidbindung hat einen teilweise
konjugierten Charakter und ist nicht frei drehbar.

Es bleiben damit pro Residue 2 frei drehbare
Diederwinkel des Proteinrückgrats übrig.


Linus Pauling
Nobelpreise für
Chemie 1954 und
Frieden 1963



Diederwinkel des Proteinrückgrats

Die dreidimensionale Faltung des Proteins wird vor allem durch die **Diederwinkel** bzw. Dihedralwinkel des Proteinrückgrats bestimmt.

Pro Residue gibt es 2 frei drehbare Diederwinkel, die als Φ und Ψ bezeichnet werden.



Definition der Konformationswinkel im Polypeptidrückgrat.

Lesk-Buch

Sekundärstrukturelemente



Wie seit den 1950'er Jahren bekannt,
können Aminosäure-Stränge

Sekundärstrukturelemente

bilden:

(aus Stryer, Biochemistry)

α -Helices



und β -Stränge.

In diesen Konformationen
bilden sich jeweils

Wasserstoffbrückenbindungen

zwischen den C=O und N-H
Atomen des Rückgrats.

Daher sind diese Einheiten
strukturell stabil.

DSSP

Der DSSP-Algorithmus geht zurück auf Wolfgang Kabsch & Chris Sander (1983).

DSSP steht für *Define Secondary Structure of Proteins*.

DSSP benutzt eine elektrostatische Energiefunktion um H-Bindungen zwischen Atomen des Proteinrückgrats zu identifizieren.

Man unterscheidet dann 3 **helikale Konformationen**:

3_{10} Helix (DSSP-Symbol **G**) – mehrere H-Bindungen zwischen Residuen i und $i+3$

α Helix (**H**) – mehrere H-Bindungen zwischen Residuen i und $i+4$

π Helix (**I**) – mehrere H-Bindungen zwischen Residuen i und $i+5$

2 Typen von **Beta-Faltblatt-Strukturen**:

beta Brücken (**B**) bzw. längere Abfolgen von H-Bindungen (**E**)

Turns (**T**)

S : sehr gekrümmte Abschnitte

C: sonstige – meist Loops (Schleifen) an der Proteinoberfläche

Stabilität und Faltung von Proteinen


PROCHECK summary for 1cse

Die gefaltete Struktur eines Proteins ist die Konformation, die die günstigste freie Enthalpie ΔG für diese Aminosäuresequenz besitzt.

Der **Ramachandran-Plot** charakterisiert die energetisch günstigen Bereiche des Aminosäurerückgrats.

Die einzige Residue, die außerhalb der erlaubten Bereich liegt, also alle möglichen Torsionswinkel annehmen kann, ist **Glycin**.

Grund: es hat keine Seitenkette.



Domänen


Kompakter Bereich im Faltungsmuster einer Molekülkette, der den Anschein hat, “er könnte auch unabhängig von den anderen stabil sein”.



cAMP-abhängige Proteinkinase



SERCA Calcium-Pumpe



Lesk-Buch


Modular aufgebaute Proteine

Modular aufgebaute Proteine bestehen aus mehreren Domänen.

Anwendung von SMART (www.smart.embl-heidelberg.de) für die Src-Kinase Hck ergibt


Sequenz:

MGGRSSCEDP	GCPRDEERAP	RMGCMKSKFL	QVGGNTFSKT	ETSASPHCPV
YVPDPTSTIK	PGPNSHNSNT	PGIREAGSED	IIVVALYDYE	AIHHEDLSFQ
KGDQMVVLEE	SGEWWKARSL	ATRKEGYIPS	NYVARVDSLE	TEEWFFKGIS
RKDAERQLLA	PGNMLGSFMI	RDSETTKGSY	SLSVRDYDPR	QGDTVKHYKI
RTLDNNGGFYI	SPRSTFSTLQ	ELVDHYKKGN	DGLCQKLSVP	CMSSKPQKPW
EKDAWEIPRE	SLKLEKKLGA	GQFGEVWMAT	YNKHTKVAVK	TMKPGSMSVE
AFLAEANVMK	TLQHDKLVKL	HAVVTKEPIY	IITEFMAKGS	LLDFLKSDEG
SKQPLPKLID	FSAQIAEGMA	FIEQRNYIHR	DLRAANILVS	ASLVCKIADF
GLARVIEDNE	YTAREGAKFP	IKWTAPEAIN	FGSFTIKSDV	WSFGILLMEI
VTYGRIPYPG	MSNPEVIRAL	ERGYRMPRPE	NCPEELYNIM	MRCWKNRPEE
RPTFEYIQSV	LDDFYTATES	QYQQQP		



SMART identifiziert Domänen durch deren HMM-Signatur (für > 1300 verschiedene Domänen).

Beispiel: Src-Kinase Hck



<http://jkweb.berkeley.edu/>

Klassifikation von Proteinen

Die Klassifikation von Proteinstrukturen nimmt in der Bioinformatik eine Schlüsselposition ein, weil sie das Bindeglied zwischen Sequenz und Funktion darstellt.

Scop Classification Statistics

SCOP: Structural Classification of Proteins. 1.69 release
25973 PDB Entries (1 Oct 2004). 70859 Domains. 1 Literature Reference
(excluding nucleic acids and theoretical models)

Class	Number of folds	Number of superfamilies	Number of families
All alpha proteins	218	376	608
All beta proteins	144	290	560
Alpha and beta proteins (a/b)	136	222	629
Alpha and beta proteins (a+b)	279	409	717
Multi-domain proteins	46	46	61
Membrane and cell surface proteins	47	88	99
Small proteins	75	108	171
Total	945	1539	2845


Die allgemeinste Einteilung in Familien von Proteinstrukturen stützt sich auf die Sekundär- und Tertiärstrukturen:

Klasse	Merkmale
α -helikal	Sekundärstruktur ausschließlich oder fast ausschließlich α -Helix
β -Faltblatt	Sekundärstruktur ausschließlich oder fast ausschließlich β -Faltblatt
$\alpha + \beta$	α -Helix und β -Faltblatt getrennt in verschiedenen Molekülteilen; kein β - α - β als Supersekundärstruktur
α/β	Helices und Faltblätter aus β - α - β -Einheiten zusammengesetzt
– α/β -linear	Mittellinie von Strängen der Faltblätter ungefähr linear
– α/β -Tonnen (<i>barrels</i>)	Mittellinie von Strängen der Faltblätter ungefähr kreisförmig
wenig oder gar keine Sekundärstruktur	

Lesk-Buch

Sekundärstruktur-Vorhersage

- Sekundärstrukturvorhersage für lösliche Proteine
- Sekundärstrukturvorhersage für Membranproteine




Flow Diagram 11.1


The key concept introduced in this section is that many different approaches have been taken in deriving methods for predicting protein secondary structure.

Literatur:
Kapitel 11 und 12 in
Understanding Bioinformatics
Zvelebil & Baum


am häufigsten auftretende Sekundärstrukturen



Die 20 natürlichen Aminosäuren




Sekundärstruktur-Auftreten in löslichen Proteinen



Längenverteilung von Sekundärstrukturelementen.

Statistische Daten für eine große Menge an Proteinen mit bekannter Struktur.

Rückgratwinkel in Sekundärstrukturelementen



Chou & Fasman Propensities

Amino Acid	helix			
	Designation	<i>P</i>	Designation	<i>P</i>
Ala	F	1.42	b	0.83
Cys	I	0.70	f	1.19
Asp	I	1.01	B	0.54
Glu	F	1.51	B	0.37
Phe	f	1.13	f	1.38
Gly	B	0.61	b	0.75
His	f	1.00	f	0.87
Ile	f	1.08	F	1.60
Lys	f	1.16	b	0.74
Leu	F	1.21	f	1.30
Met	F	1.45	f	1.05
Asn	b	0.67	b	0.89
Pro	B	0.57	B	0.55
Gln	f	1.11	h	1.10
Arg	I	0.98	I	0.93
Ser	I	0.77	b	0.75
Thr	I	0.83	f	1.19
Val	f	1.06	F	1.70
Trp	f	1.08	f	1.37
Tyr	b	0.69	F	1.4

F : starke Tendenz


f : schwache Tendenz

B : starker (Unter-) Brecher

b : schwacher (Unter-) Brecher


I : indifferent

Prolin: stärkster Helixbrecher sowie für Betastränge




Vorhersage mit Neuronalen Netzwerken

zweilagiges Neuronales Netzwerk



Feed-forward NN zur Vorhersage von Sekundärstrukturen



PSIPRED

Benutze Profil aus PSIBLAST.

Skaliere Werte auf Intervall [0.0;1.0].

A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V
-3	-4	-4	-4	-3	-4	-4	-4	-2	-1	-1	-4	-1	8	-5	-3	-3	0	2	-2
0	-1	-1	3	-4	3	4	1	-1	-4	-4	0	-3	-4	-2	-1	-2	-4	-3	-3
0	-1	2	1	-3	4	0	-1	-2	-4	-3	1	-2	-4	-2	2	0	-4	-3	-3
-2	-3	-4	-5	-2	-3	-4	-6	-4	0	6	0	0	-1	4	-2	2	0	-4	-2
0	-3	-1	-2	0	-2	4	-3	0	-2	-2	-4	-3	3	1	-4	-4	-4	-3	-2
0	2	0	4	-4	1	2	1	-2	-3	-4	0	-3	-4	-3	1	-2	-5	-4	-4
-1	5	3	-2	-4	-1	-1	1	-2	-1	-4	1	-3	-4	-3	1	-2	-5	-4	-4
-2	-3	-4	-5	-3	-3	-4	-5	-4	3	4	-1	1	2	-4	-3	-2	-3	-1	0
-2	3	2	-3	-4	2	1	-3	-2	-3	-3	1	1	-4	-3	2	1	-4	-3	-1
0	2	3	1	-4	0	0	0	-2	-4	-4	1	-2	0	-5	-4	0	0	-4	-4
5	-3	-3	-3	-2	-3	-3	-2	-3	1	-2	-3	-2	1	-3	0	1	-4	-2	0
-1	-4	-5	-5	-3	-4	-4	-5	-4	3	3	-4	2	3	-5	-3	-2	5	-1	2
0	3	3	0	-4	3	0	1	-2	-4	-4	1	-3	-4	-3	1	-1	-4	-3	-4
0	3	3	0	-4	3	0	1	-2	-4	-4	1	-3	-4	-3	1	-1	-4	-3	-3
-1	0	1	0	-4	1	-1	-2	-4	-3	5	-2	0	-3	0	-2	-1	0	0	-3
-1	1	3	-2	-4	0	-2	4	-2	-4	-4	0	-3	0	0	-3	0	-3	0	-4

window of 15 rows

A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V
0.4	0.3	0.3	0.3	0.2	0.9	0.3	0.3	0.4	0.4	0.4	0.4	0.4	0.9	0.1	0.4	0.4	0.5	0.7	0.4
0.3	0.2	0.3	0.8	0.4	0.3	0.7	0.1	0.6	0.2	0.3	0.3	0.5	0.2	0.1	0.4	0.8	0.2	0.3	0.2
0.1	0.1	0.4	0.3	0.5	0.1	0.1	0.3	0.1	0.1	0.4	0.2	0.4	0.9	0.3	0.4	0.4	0.9	0.3	0.6
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...

15 x 20 scaled inputs to 1st network


1st network
315 input units
75 hidden layers
3 outputs

H, E, L

2nd network
60 input units
60 hidden layers
3 outputs



H, E, L

Qualität der Sekundärstruktur-Vorhersagen




1B8C

all α protein



1CJW

α + β protein





Die besten aktuellen Vorhersagemethoden erreichen etwa 85% Genauigkeit.

Jiang et al. J Mol Graph Model. (2017) 76:379-402



Softwarewerkzeuge

Topologie von Membranproteinen

Im Inneren der Lipidschicht kann das Proteinrückgrat keine Wasserstoffbrücken-Bindungen mit den Lipiden ausbilden →
die Atome des Rückgrats müssen miteinander Wasserstoffbrückenbindungen ausbilden,
sie müssen entweder helikale oder β -Faltblattkonformation annehmen.



Topologie von Membranproteinen



Die hydrophobe Umgebung erzwingt, dass (zumindest die bisher bekannten) Strukturen von Transmembranproteinen entweder reine β -Barrels (links) oder reine α -helikale Bündel (rechts) sind.

Vorhersage von Transmembranhelices

Einfaches Kriterium: Hydrophobizitäts-Skalen wie die von Kyte & Doolittle
TMHs sind meistens apolar und 12-35 Residuen lang,

Jede Aminosäure erhält Hydrophobizitätswert zugeordnet.

Um TM-Helices zu finden, addiere alle
Werte in einem **Sequenzfenster** der
Länge w .



Alle Fenster oberhalb einer Schranke T
werden als TM-Helix vorhergesagt.

Beobachtung:

Gute Parameter sind $w = 19$ und $T > 1.6$.

Hydrophobicity Scales		
	Kyte-Doolittle	Hopp-Woods
Alanine	1.8	
Arginine	-4.5	
Asparagine	-3.5	
Aspartic acid	-3.5	
Cysteine	2.5	
Glutamine	-3.5	
Glutamic acid	-3.5	
Glycine	-0.4	
Histidine	-3.2	
Isoleucine	4.5	
Leucine	3.8	
Lysine	-3.9	
Methionine	1.9	
Phenylalanine	2.8	
Proline	-1.6	
Serine	-0.8	
Threonine	-0.7	
Tryptophan	-0.9	
Tyrosine	-1.3	
Valine	4.2	

Helikale Räder



Key:

Group Coloring Key

Nonpolar:

Polar, Uncharged:

Acidic:

Basic

Helikale Räder dienen zur Darstellung von Helices.

Man kann so leicht erkennen, welche Seite der Helix einen polaren bzw. hydrophoben Charakter hat.


Bei amphipathischen Helices (die flach auf der Membranoberfläche liegen) zeigt die hydrophobe Seite in die Lipidschicht der Membran und die polare Seite ins Wasser.

<http://cti.itc.Virginia.EDU/~cmg/Demo/wheel/wheelApp.html>

TM-Vorhersage mit Hidden Markov Modellen

HMMTOP: verwendet ein Hidden Markov-Modell um 5 strukturelle Zustände zu unterscheiden:

- Nicht-Membran Region innen
- TMH-Ende innen
- Membranelix
- TMH-Ende außen
- Nicht-Membran Region außen



HMMTOP Vorhersage

amino acid sequence	MGDVCDTEFGILVA...SVALRPRKHGRWIV...FWVDNGTEQ...PEHMTKLHMM...
state sequence	ooooooooohhhhh...hhhhiiiiiihhh...hhhoooo00...000oooohhh...
topology	

Vergleich von 2 Proteinstrukturen: DALI (Distance-matrix Alignment)

L. Holm & C. Sander


Während der Evolution eines Proteins verändert sich seine Sequenz.

Was häufig erhalten bleibt, ist die Verteilung der Kontakte zwischen den Aminosäuren.

→ Konstruiere Kontaktmatrizen für beide Proteine (leicht)

→ finde maximal übereinstimmende Untermatrizen der Kontaktmatrizen (schwierig)

<http://www.ebi.ac.uk/dali>



5.7 Abschnitte mit gemeinsamen Faltungsmustern, ermittelt mit dem Programm DALI von L. Holm und C. Sander. Es handelt sich um zwei Proteine mit TIM-barrels, die Adenosindesaminase der Maus [1FKX] (durchgezogene Linien) und die Phosphotriesterase aus *Pseudomonas diminuta* [1PTA] (gestrichelte Linien). Nach dem hier gezeigten Alignment stimmen die Ketten nur in 13 Prozent ihrer Aminosäuren überein – ein Wert, der eher im mitternächtlichen Dunkel denn in der Grauzone liegt.

Bedeutung von struktureller Äquivalenz

Beim Strukturvergleich sollen äquivalente Strukturblöcke zweier Proteine einander zugeordnet werden.


Darstellung

- in 3D als Überlagerung (superimposition) starrer Körper
- in 2D als ähnliche Muster in Distanz-Matrizen
- in 1D als Sequenzalignment

Rechts: Strukturvergleich von zwei **Zinkfinger-Proteinen**, tramtrack und MBP-1 [1bbo].

Holm, Sander Science 273, 5275 (1996)

A



3D-Überlagerung: finde Translation und Rotation eines Moleküls (rot: 1bbo), so dass es optimal auf das andere Molekül passt (blau: 2drpA).

Das Problem ist hier, dass die zwei Domänen der beiden Proteine unterschiedlich gegeneinander verdreht sind (vgl. parallele Lage der beiden roten Helices bzw. senkrechte Lage der beiden blauen Helices).

Überraschende Ähnlichkeit zwischen papD und CD4 T-Zellrezeptor



Fig. 2. Structure alignment of papD and CD4. Structural alignment and optimal superposition of papD protein (3DPA) and CD4 T-cell receptor (1CD4). The C $^{\alpha}$ -rmsd after optimal superposition is 1.5 Å for 41 aligned residues. PDB residue numbers of the aligned fragments follow. For 3DPA: 16–38, 85–94, 105–112. For 1CD4: 111–133, 154–163, 166–173. The alignment was generated using the Suppos algorithm.

Holm et al. Prot Sci 1, 1691 (1992)

Überraschende Ähnlichkeit zwischen Flavodoxin und Malat-Dehydrogenase




Fig. 3. Structure alignment of arabinose binding protein (ABP) with flavodoxin (FXN) and malate dehydrogenase (MDH). **A:** Structural alignment and optimal superposition of 1ABP and 4FXN. The C α -rmsd after optimal superposition is 2.7 Å for 78 aligned residues. PDB residue numbers of the aligned fragments follow. For 1ABP: 5–15, 17–40, 49–54, 59–64, 73–79, 83–89, 253–269. For 4FXN: 1–35, 39–44, 47–52, 72–78, 80–86, 122–138. **B:** Structural alignment and optimal superposition of 1ABP and 4MDH. The C α -rmsd after optimal superposition is 3.4 Å for 97 aligned residues. Residue numbers of the aligned fragments follow. For 1ABP: 2–27, 31–41, 45–53, 59–66, 73–94, 103–106, 254–270. For 4MDH (chain A): 1–26, 31–41, 72–88, 113–130, 135–138, 151–154, 240–256. The alignments were generated using the Comp3D algorithm.

Holm et al. Prot Sci 1, 1691 (1992)

Überraschende Ähnlichkeit zwischen Tryptophansynthase und Flavocytochrom b2




Fig. 4. Structure alignment of $(\alpha\beta)_8$ barrels. Structural alignment and optimal superposition of tryptophan synthase (1WSY) and flavocytochrome b2 (1FCB). The C^α -rmsd after optimal superposition is 3.1 Å for 198 aligned residues. PDB residue numbers of the aligned fragments follow. For 1WSY (chain A): 3–8, 17–28, 29–43, 44–53, 84–92, 93–105, 108–130, 131–144, 148–159, 162–177, 192–201, 202–243, 250–265. For 1FCB (chain A): 182–187, 190–201, 205–219, 221–230, 234–242, 245–257, 259–281, 330–343, 344–355, 356–371, 387–396, 400–441, 442–457. The alignment was generated using the Dali algorithm.

Holm et al. Prot Sci 1, 1691 (1992)

Distanzmatrix für Proteinstrukturen



Distanzmatrix:

Auf beiden Achsen wird jeweils die Proteinsequenz aufgetragen.

Die Einträge der Matrix enthalten die Abstände zwischen den C_{α} -Atomen der Aminosäuren i und j dieses Proteins in der 3D-Struktur.


In einer **α -Helix** liegt Aminosäure i jeweils nah bei AS $i + 4$

→ In der Distanzmatrix ergeben diese Kontakte eine um 4 verschobene Linie parallel zur Diagonalen.



Parallele β -Stränge : ihre Kontakte ergeben ebenfalls eine verschobene Linie parallel zur Diagonalen.

Antiparallele β -Stränge : ihre Kontakte ergeben um 90° gekippte Linien.



Choi et al. PNAS 101, 3797 (2004)

Distanzmatrix bzw. Kontaktmatrix

(B) Distanzmatrix: schwarze Punkte markieren Paare von Residuen in 1bbo (unten) und 2drpA (oben) mit Abstand unter 12 Å.


Links: ohne Alignierung, schlechte Übereinstimmung der Kontakte.

Rechts: nach Alignierung, wenn nur die Spalten und Reihen für sich strukturell entsprechende Residuen behalten werden.

(C) 1D Sequenzalignment.

Die die Zinkatome koordinierenden Histidin-Residuen werden aligniert.

Unterstrichen: Sekundärstrukturelemente.



Holm, Sander Science 273, 5275 (1996)

DALI verwendet einen branch-and-bound Algorithmus

(B) A branch-and-bound algorithm is guaranteed to yield the global optimum but may, in the worst case, need an exponential number of steps to do so.

First, protein structures A and B are represented by distance matrices (bottom left and right; each point in a matrix is a residue-residue distance; an internal square is a set of contacts made by two segments; the secondary structure segments are β , β , and α).


The problem of shape comparison becomes one of finding a best subset of residues in each matrix (subsets of rows and columns) such that the set of residues in protein A has a similar pattern of intramolecular distances as the set in protein B.

A single solution to the problem is given in terms of the two sets of equivalent residues (an alignment). The solution space consists of all possible placements of residues in protein B relative to the segments of residues of protein A. The key algorithmic idea is to recursively split the solution subspace (schematically shown as a circle at upper left, in which each point is a solution to the problem and the lines divide subsets of solutions) that yields the highest upper bound until there is a single alignment trace left:


start with the entire circle; calculate the upper bound for the left (9) and right (17) half; choose the right half and split it into top (upper bound 10) and bottom (upper bound 16) quarters; choose the bottom part and split it (left: 14; right: 12); choose the right part; and so on until the area of solution space has shrunk to a single solution (shown as the residue-residue alignment matrix enlarged at right). The upper bound for each part of the solution space is estimated in terms of a simplified subproblem that asks for the best match of residues in protein B onto a predefined set of residues in protein A (the match is illustrated by the circle-ended line connecting the single square in matrix A with a set of candidate squares in matrix B). The best match is the one with the maximal pair score (sum of similarities of distances between the square in A and the square in B). The predefined set corresponds to residues in secondary structure elements. The upper bound for each of the segment-segment submatrices of matrix A is found by calculating the similarity scores between the submatrix in A and all accessible submatrices in B. An upper bound of the total similarity score (sum over all segment-segment submatrices in A) for one set of solutions is given by the sum of separately calculated upper bounds for each segment-segment pair of matrix A.

B

Branch-and-bound search



Estimate upper bound using distance matrices



Holm, Sander Science 273, 5275 (1996)

Folie nicht klausurrelevant

Zusammenfassung

- Proteinstrukturen sind hierarchisch aufgebaut
- Die Kenntnis der 3D-Struktur erlaubt es, die Proteinfunktion mechanistisch zu verstehen, z.B. von Enzymen katalysierte chemische Umwandlungsschritte.
- die strukturelle Bioinformatik beschäftigt sich u.a. mit der Vorhersage von 2D- und 3D-Struktur aus der 1D-Struktur (Sequenz)
- Vorhersagen von 2D-Strukturelementen sind ca. 80% genau
- Die Aminosäurezusammensetzung der Membranregionen von Membranproteinen ist sehr verschieden von der löslicher Proteine.
- Dadurch kann man Transmembranregionen recht zuverlässig identifizieren
- Der Vergleich mehrerer Proteinstrukturen ist nicht trivial.