

LOSCHMIDT
LABORATORIES



Analýza proteinových sekvencí



EVROPSKÁ UNIE

esf



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenční schopnost



UNIVERSITAS
MASARYKIANA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Osnova

- Predikce fyzikálně-chemických vlastností
- Predikce membránových regionů
- Predikce motivů a domén
- Databáze motivů a domén
- Prohledávání databází motivů a domén

Predikce fyzikálně-chemických vlastností

- ExPASy (Expert Protein Analysis System)

Predikce fyzikálně-chemických vlastností

□ ExPASy (Expert Protein Analysis System)

- Molekulová hmotnost
- Izoelektrický bod
- Extinkční koeficient
- Postranslační modifikace
- Místa proteasové digesce
- Poločas rozkladu
- Nestabilita

Predikce fyzikálně-chemických vlastností

□ ExPASy (Expert Protein Analysis System)

Identification with isoelectric point, molecular weight and/or amino acid composition


- AACompIdent  - Identify a protein by its amino acid composition
- AACompSim  - Compare the amino acid composition of a UniProtKB/Swiss-Prot entry with all other entries
- TagIdent  - Identify proteins with isoelectric point (*pI*), molecular weight (*Mw*) and sequence tag, or generate a list of proteins close to a given *pI* and *Mw*
- Multident  - Identify proteins with isoelectric point (*pI*), molecular weight (*Mw*), amino acid composition, sequence tag and peptide mass fingerprinting data

Other prediction or characterization tools

- ProtParam  - Physico-chemical parameters of a protein sequence (amino-acid and atomic compositions, isoelectric point, extinction coefficient, etc.)
- Compute pI/Mw  - Compute the theoretical isoelectric point (*pI*) and molecular weight (*Mw*) from a UniProt Knowledgebase entry or for a user sequence
- GlycanMass  - Calculate the mass of an oligosaccharide structure
- PeptideCutter  - Predicts potential protease and cleavage sites and sites cleaved by chemicals in a given protein sequence
- PeptideMass  - Calculate masses of peptides and their post-translational modifications for a UniProtKB/Swiss-Prot or UniProtKB/TrEMBL entry or for a user sequence
- IsotopIdent  - Predicts the theoretical isotopic distribution of a peptide, protein, polynucleotide or chemical compound

Predikce membránových regionů


- Hydrofóbni segmenty v membránových proteinech



Predikce membránových regionů

□ ProtScale


- Predikce hydrofobicitního profilu ze sekvence



Predikce membránových regionů

□ TMHMM


- Predikce pravděpodobnostní metodou Skrytých Markovových Modelů



Predikce membránových regionů

□ TOPCONS

- Konsenzuální predikce topologie membránových proteinů



Predikce motivů a domén

- Konzervované **vzorce** sekvencí jsou spojené s konkrétní proteinovou **rodinou**, biologickými **vlastnostmi** nebo **funkcí**







Predikce motivů a domén



- Konzervované **vzorce** sekvencí jsou spojené s konkrétní proteinovou **rodinou**, biologickými **vlastnostmi** nebo **funkcí**
 - Klasifikace proteinových sekvencí
 - Identifikace strukturních a evolučních vztahů
 - Funkční anotace nových proteinů
 - Identifikace vazebných míst pro ligandy
 - Predikce postranslačních modifikací
 - Predikce sub-celulární lokalizace

Predikce motivů a domén


Name	Helix-loop-helix (Myc type)	Cys-His zinc finger	Leucine zipper
Sequence	[DENSTAP]-K-[LIVMWAGN]- {FYWCPHKR}-[LIVT]-[LIV]-x(2)- [STAV]-[LIVMSTAC]-x-[VMFYH]- [LIVMTA]-{P}-{P}-[LIVMSR]	C-x(2,4)-C-x(3)-[LIVMFYWC]- x(8)-H-x(3,5)-H	L-x(6)-L-x(6)-L-x(6)-L
Structure			
Function	DNA Binding	DNA Binding	DNA Binding
Example	 3CRO	 2DRP	 1YSA

Predikce motivů a domén

- Konzervované vzorce sekvencí jsou spojené s konkrétní proteinovou rodinou, biologickými vlastnostmi nebo funkcí
 - Motivy
 - Zpravidla krátké – 10-20 aminokyselinových zbytků
- CGDAEEGDACCDGA

Predikce motivů a domén

- Konzervované vzorce sekvencí jsou spojené s konkrétní proteinovou rodinou, biologickými vlastnostmi nebo funkcí
- Motivy
- Domény
 - Delší než motivy – 40-700 aminokyselinových zbytků
 - Nezávislé strukturní a funkční jednotky



Predikce motivů a domén




- Vytvářeny z multinásobného přiložení příbuzných sekvencí
- Uloženy v databázích ve formě konsenzuální sekvence

Predikce motivů a domén



- Vytvářeny z multinásobného přiložení příbuzných sekvencí
- Uloženy v databázích ve formě konsenzuální sekvenčí



Predikce motivů a domén



- Vytvářeny z multinásobného přiložení příbuzných sekvencí
- Uloženy v databázích ve formě konsenzuální sekvenční

	1	2	3	4	5	6	7	8	9	10
I	Y	D	G	G	A	V	-	E	A	L
II	Y	D	G	G	-	-	-	E	A	L
III	F	E	G	G	I	L	V	E	A	L
IV	F	D	-	G	I	L	V	Q	A	V
V	Y	E	G	G	A	V	V	Q	A	L
	y	d	g	g	A/I	V/L	v	e	a	l

Predikce motivů a domén



- Vytvářeny z multinásobného přiložení příbuzných sekvencí
- Uloženy v databázích ve formě konsenzuální sekvence
 - Regulární výrazy

Predikce motivů a domén

- Vytvářeny z multinásobného přiložení příbuzných sekvencí
- Uloženy v databázích ve formě konsenzuální sekvence
 - Regulární výrazy

E-X(2)-[FHM]-X(4)-{P}-L

Predikce motivů a domén

- Vytvářeny z multinásobného přiložení příbuzných sekvencí
- Uloženy v databázích ve formě konsenzuální sekvence
 - Regulární výrazy

E-X(2)-[FHM]-X(4)-{P}-L

zbytek E je následován **2 libovolnými zbytky**

Predikce motivů a domén



- Vytvářeny z multinásobného přiložení příbuzných sekvencí
- Uloženy v databázích ve formě konsenzuální sekvence
 - Regulární výrazy

E-X(2)-[FHM]-X(4)-{P}-L

zbytek E je následován 2 libovolnými zbytky

následovanými F nebo H nebo M zbytky

Predikce motivů a domén



- Vytvářeny z multinásobného přiložení příbuzných sekvencí
- Uloženy v databázích ve formě konsenzuální sekvence
 - Regulární výrazy

E-X(2)-[FHM]-**X(4)**-{P}-L

zbytek E je následován 2 libovolnými zbytky

následovanými F nebo H nebo M zbytky

následovanými **4 libovolnými zbytky**

Predikce motivů a domén



- Vytvářeny z multinásobného přiložení příbuzných sekvencí
- Uloženy v databázích ve formě konsenzuální sekvenčního řetězce
 - **Regulární výrazy**

E-X(2)-[FHM]-X(4)-{P}-L

zbytek E je následován 2 libovolnými zbytky

následovanými F nebo H nebo M zbytky

následovanými 4 libovolnými zbytky

následovanými **jakýmkoli zbytkem kromě P**

Predikce motivů a domén



- Vytvářeny z multinásobného přiložení příbuzných sekvencí
- Uloženy v databázích ve formě konsenzuální sekvence
 - Regulární výrazy

E-X(2)-[FHM]-X(4)-{P}-L

zbytek E je následován 2 libovolnými zbytky

následovanými F nebo H nebo M zbytky

následovanými 4 libovolnými zbytky

následovanými jakýmkoliv zbytkem kromě P

následovaným zbytkem L

Predikce motivů a domén



- Vytvářeny z multinásobného přiložení příbuzných sekvencí
 - Uloženy v databázích ve formě konsenzuální sekvence

Regulární výrazy	Počet přesných hitů
D-A-V-I-D	71
D-A-V-I-[DENQ]	252
[DENQ]-A-V-I-[DENQ]	925
[DENQ]-A-[VLI]-I-[DENQ]	2739
[DENQ]-[AQ]-[VLI]2-[DENQ]	51506

Predikce motivů a domén

- Vytvářeny z multinásobného přiložení příbuzných sekvencí
- Uloženy v databázích ve formě konsenzuální sekvence
 - Regulární výrazy
 - **Statistické modely** (profily, bloky, Skryté Markovovy Modely)

	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V	
1	Y	-2	-2	-2	-3	-2	-1	-2	-3	2	-1	-1	-2	-1	3	-3	-2	-2	2	7	-1
2	L	-1	-2	-3	-4	-1	-2	-3	-4	-3	2	4	-2	2	0	-3	-2	-1	-2	-1	1
3	P	-1	-2	-2	-2	-3	-2	-1	-2	-2	-3	-3	-1	-3	-4	8	-1	-1	-4	-3	-3
4	S	1	-1	0	-1	0	0	-1	-1	-3	-3	0	-2	-3	-1	5	1	-3	-2	-2	
5	C	-1	-4	-3	-4	9	-3	-4	-3	-3	-2	-2	-3	-2	-3	-3	-1	-1	-3	-3	-1
6	T	0	-1	0	-1	-1	-1	-1	-2	-2	-3	-1	-2	-3	-1	4	3	-3	-2	-2	
7	Y	-2	-3	-3	-4	-3	-2	-3	-4	1	-1	-1	-3	-1	5	-4	-2	-2	1	7	-2
8	Y	-1	-1	-1	-1	-2	0	-1	-2	6	-2	-1	-1	-1	1	-1	-1	-1	0	5	-2
9	V	-1	-2	-2	-2	-1	-2	-2	-2	1	2	-2	0	-1	-2	-2	-1	-2	-1	4	
10	S	-1	-1	-1	-1	-3	3	3	-2	-1	-2	1	0	-1	-2	-2	2	-1	-3	-2	-2

Databáze motivů a domén



□ Manuální

- Informativní díky kvalitním anotacím
- Nízký počet položek

□ Automatické

- Méně informativní
- Vysoký počet položek

Databáze motivů a domén



The Main Domain Collections			
Name	Web Address	Number of Domains	Generation
PROSITE-Profile (IP)	www.expasy.org/prosite	616	Manual
PfamA (IP)	www.sanger.ac.uk/Software/Pfam	7973	Manual
PRINTs (IP)	www.bioinf.man.ac.uk/dbbrowsers/PRINTS	1900	Manual
PRODOM (IP)	protein.toulouse.inra.fr/prodom/current/html/home.php	736000	Automatic
SMART (IP)	smart.embl-heidelberg.de	685	Manual
COGs	www.ncbi.nlm.nih.gov/COG/new/	4852	Manual
TIGRFAM (IP)	www.tigr.org/TIGRFAMs	2453	Manual
BLOCKS	blocks.fhcrc.org/	12542	Automatic



□ PROSITE

- Motivy navrženy **manuálně** kvalifikovanými odborníky
- Motivy často **krátké** pro zvýšení specifity
- Shody nutno interpretovat **opatrně!**

Databáze motivů a domén



□ PROSITE

- Hity *versus* hity s vysokým výskytem
- Rozpoznání hitů = délka vzorce, informace o organismu, identifikace podobných vzorců, konzervovanost vzorce v přiložení

hits by patterns: [6 hits (by 3 distinct patterns) on 1 sequence]

P12259
(FA5_HUMAN)



RecName: Full=Coagulation factor V; AltName: Full=Activated protein C cofactor; AltName: Full=Proaccelerin, labile factor;
Contains: RecName: Full=Coagulation factor V heavy chain; Contains: RecName: Full=Coagulation factor V light chain; Flags:
Precursor;. *Homo sapiens (Human)*

PS00079 MULTICOPPER_OXIDASE1 *Multicopper oxidases signature 1* : Hits on PDB 3D structures: [1FV4-H, 1FV4-L, 1Y61-H, 1Y61-L]

304 - 324: GkWiIIsS1TPkhLqAGMqayI

1880 - 1900: GwW1LnTeVGenQrAGMqtpF

Databáze motivů a domén



□ BLOCKs

- Bloky = segmenty multinásobného přiložení bez mezer korespondující s nejkonzervovanějšími regiony v proteinech

Family		Strand	Blocks	Combined E-value
IPB000639	Epoxide hydrolase signature	1	5 of 6	7.7e-22
IPB003089	Alpha/beta hydrolase fold signature	1	3 of 4	4.5e-07
IPB000073	Alpha/beta hydrolase fold	1	2 of 2	0.0041
IPB002410	Prolyl aminopeptidase (S33) family	1	1 of 3	0.032
IPB002828	Survival protein SurE	1	1 of 7	0.5

Databáze motivů a domén



□ BLOCKs

- Bloky = segmenty multinásobného přiložení bez mezer korespondující s nejkonzervovanějšími regiony v proteinech

Family		Strand	Blocks	Combined E-value
IPB000639	Epoxide hydrolase signature	1	5 of 6	7.7e-22
IPB003089	Alpha/beta hydrolase fold signature	1	3 of 4	4.5e-07
IPB000073	Alpha/beta hydrolase fold	1	2 of 2	0.0041
IPB002410	Prolyl aminopeptidase (S33) family	1	1 of 3	0.032
IPB002828	Survival protein SurE	1	1 of 7	0.5

>[IPB000639](#) 5/6 blocks Combined E-value= 7.7e-22: Epoxide hydrolase signature

Block	Frame	Location (aa)	Block E-value
IPB000639A	0	36-54	0.0002
IPB000639B	0	55-70	0.012
IPB000639C	0	104-117	0.032
IPB000639D	0	118-131	2.2
IPB000639F	0	267-289	0.0024

Databáze motivů a domén

□ Pfam

- Přiložení domén vytvořené ze sekvencí databáze UniProtKB
- Každá doména je reprezentována profilem Skrytých Markovových Modelů vytvořeným z mnohonásobného přiložení
- Obsahuje dvě části: Pfam-A z manuálního přiložení a Pfam-B z automatického přiložení

Databáze motivů a domén

□ Pfam

The screenshot shows the Pfam website interface. At the top, there is a navigation bar with links to HOME, SEARCH, BROWSE, FTP, and HELP. On the right side, there is a search bar labeled "Pfam keyword search" with a "Go" button. Below the navigation bar, there is a decorative header featuring a DNA double helix and various molecular structures.

The main content area is titled "Family: Abhydrolase domain". On the left, there is a sidebar with links to Summary, Domain organisation, Alignments (which is currently selected), Trees, Curation & models, Species, Interactions, and Structures. The "Alignments" section displays a list of protein IDs and their corresponding sequence alignments. A red box highlights the first 30 rows of the alignment table. The alignment table has two columns: protein IDs and their corresponding amino acid sequences. The sequences are color-coded according to standard bioinformatics conventions (e.g., hydrophobic residues in purple, polar uncharged in green, polar charged in blue, and aromatic in orange).

Protein ID	Sequence
P07000/82-321	FDVLIIDHRRGQGRSG.RLLAD.....
P53264/170-440	WCIHAIDLPGYGCFSSRPKFP.....
P65824/134-506	FDLVGFDPRGVASSR.PAIWCNSDADNDRLRAEPQVDYSREGVAHIENETKQFVGRCVDKMKGNFLAHVGTVNVAKDLD.....
P53750/56-285	FHIIAPDLPFGFITE.T.....
P53208/67-318	ADIFSVDWRNHGSDP.....
P27747/162-370	YTVVVALDLPGHGQSS.....
P42786/58-307	FRIVIIDQRGGRSH.P.....
P07383/63-269	KRYLALDLRGHGGTS.....
P65822/138-415	FDLVGFDPRGVGHST.PALRCRTDAEFDAYRRDPMADYSPAGVTHVEQVYRQLAQDCVDRMGSFLANIGTASVARDMDN.....
P46547/82-313	FRVLLLDQRGTGHST.PIHAELL.....
P24640/93-308	YHLIIPDLLGFGNIS.K.....
P26174/63-280	YRVIVPDLPGHGSR.S.....
P66777/56-296	FRIVRYDNRGWGRSSVP.....
P52705/31-252	HKVTALDMAASGIDP.R.....

Databáze motivů a domén

□ ProDom

- Databáze proteinových **domén** automaticky vytvořenými ze sekvencí databáze UniProtKB
- Navržena jako **vyčerpávající** sbírka domén i bez znalosti funkce




Databáze motivů a domén



□ InterPro

- Řeší problém **redundance** jednotlivých databází
- Zahrnuje téměř všechny dostupné sekundární databáze:
PROSITE, Pfam, PRINTS, ProDom, SMART,...



Prohledávání databází motivů a domén

- Simultánní prohledání **několika** databází
 - InterProScan
 - CD Server
 - Motif-Scan

Prohledávání databází motivů a domén


- Simultánní prohledání několika databází
 - InterProScan
 - CD Server
 - Motif-Scan
- Vysoké skóre a vysoká shoda = spolehlivá interpretace
 - Závěry téměř **vždy správné**
- Nízké skóre nebo částečná shoda = problematická interpretace
 - Závěry vyžadují další **podpůrná data**



Prohledávání databází motivů a domén

□ InterProScan


- Srovnání prohledávané sekvence s InterPro databází
- Hity a jejich umístění na sekvenci jsou vypsány **přehledně**



Prohledávání databází motivů a domén

□ CD Server

- Hity jsou vypsány s E-hodnotou
- prohledává menší počet databází než InterProScan



Prohledávání databází motivů a domén

□ Motif-Scan

- Hity jsou vypsány s E-hodnotou a normalizovaným skóre
- Relevantní hity jsou označeny “!”

Match details		
<u>match detail</u>	<u>match score</u>	<u>motif information</u>
 EEKRRVRRERNKLAAKCRNRRRELTDRLQAETDQLEEEKAELSEIAELQKEKERLEFVLVAH	Status: ! pos.: 155-218 raw-score = 989 N-score = 13.185 E-value = 1.4e-06	prf:BZIP <i>Basic-leucine zipper (bZIP) domain profile.</i> [entry] [graphics]

Reference

- ❑ Claverie, J-M., & Notredame, C. (2006). **Bioinformatics for Dummies** (2nd ed.). Wiley Publishing, Hoboken, p. 436.
- ❑ Xiong, J. (2006). **Essential Bioinformatics**, Cambridge University Press, New York, p. 352.

- ❑ **ExPASy:** <http://www.expasy.ch/>
- ❑ **ProtScale:** <http://www.expasy.org/cgi-bin/protscale.pl>
- ❑ **TMHMM:** <http://www.cbs.dtu.dk/services/TMHMM-2.0/>
- ❑ **TOPCONS:** <http://topcons.net/>
- ❑ **PROSITE:** <http://www.expasy.org/prosite/>
- ❑ **BLOCKs:** <http://blocks.fhcrc.org>
- ❑ **Pfam:** <http://pfam.sanger.ac.uk/>
- ❑ **ProDom:** <http://prodom.prabi.fr/prodom/current/html/home.php>
- ❑ **InterPro:** <http://www.ebi.ac.uk/interpro/>
- ❑ **InterProScan:** <http://www.ebi.ac.uk/Tools/InterProScan/>
- ❑ **CD Search:** <http://www.ncbi.nlm.nih.gov/Structure/cdd/wrpsb.cgi>
- ❑ **Motif-Scan:** http://myhits.isb-sib.ch/cgi-bin/motif_scan