

## 7. vaja: Naloge in odgovori

### V07-01

#### TOČKOVNI DIAGRAM


V Excel-u (datoteka "V07 – Naloge.xlsx") izdelajte prileganje dveh zaporedij po metodi točkovnega diagrama.

Kot vhodni podatek imate podane pare zaporedij (npr. par A sestavljata zaporedji A1 in A2, ki ju primerjate med seboj). Tabelo za primerjanje izdelajte tako, da boste v dve celici nad točkovnim diagramom oz. matriko prilepili zaporedji iz posameznega para (npr. A1 in A2, B1 in B2, ...). Uporabite funkciji MID in IF; kot velikost okna upoštevajte vrednost 1 (to pomeni, da direktno primerjate posamezne nukleotide).


Oglejte si točkovne diagrame, ki pri tem nastanejo, identificirajte insercije/delecije, ponovitve, ... v zaporedjih in si oglejte, kako se odražajo v točkovnem diagramu.

#### Odgovor


Zaporedje A1 ima interne direktne ponovitve motiva AGTCGA, ki se v točkovnem dirgramu kažejo kot vzporedne diagonalne črte. Zaradi kratke obrnjene ponovitve (AG na začetku oz GA na koncu motiva) vidimo še pravokotne prekinjene črte.




Zaporedje B1 vsebuje obrnjeno ponovitev (sestavljen je torej iz zaporedja AGATCGATACTGAGT in obrnjene ponovitve le-tega), kar se v točkovnem diagramu kaže kot prekrivani diagonali.



Ponovitev enega nukleotida v zaporedju C1 se kaže kot navpične in vodoravne črte tik ob/na diagonali (ki tvorijo pravokotnik na diagonali) ter še izvendiagonalne vodoravne in navpične črte na mestih, kjer se v zaporedju pojavi tisti nukleotid, ki se ponavlja.



Insersija/delecija (indel), ki je prisotna v zaporedjih skupine D, se kaže kot prelomljena diagonala.



## V07-02

### TOČKOVNI DIAGRAM

Primerjajte aminokislinski zaporedji človeškega proteina N-CAM-1 (Neural cell adhesion molecule 1) in miotilina (myotilin). Uporabite spletno orodje DotMatcher (<http://emboss.bioinformatics.nl/cgi-bin/emboss/dotmatcher>), primerjavo zaporedij pa naredite pri različnih vrednostih za velikost okna. Kot matrico zamenjav uporabite EBLOSUM62, kar je privzeta matrika za aminokislinska zaporedja.

Kako se spreminja občutljivost in količina šuma pri različnih vrednostih okna?


Ali v točkovnem diagramu opazite kakšen izrazit vzorec? Razložite!

### Odgovor

Zaporedji za omenjena proteina najdemo v UniProt pod kodo:

- P13591 za N-CAM-1: <http://www.uniprot.org/uniprot/P13591>
- Q9UBF9 za miotilin: <http://www.uniprot.org/uniprot/Q9UBF9>

Z uporabo privzetih nastavitev (velikost okna – window size 10; mejna vrednost za prikaz - threshold 23) lahko opazimo največ vzporednih diagonal, ki nakazujejo podobnost med N-končno polovico NCAM-1 in C-končno polovico miotilina. Pri ogledu anotacij v bazi UniProt (Sequence Annotations (Features) --> Regions) za ta proteina (povezavi zgoraj) vidimo, da ima v tem delu NCAM-1 5 ponovitev domene imunoglobulinskega tipa (Ig-like C2-type), miotilin pa v omenjenem delu dve taki ponovitvi. Za detekcijo takih podobnosti oz. ponovitev domen ali pa homolognih domen ponavadi nastavimo velikost okna na vrednost, ki je približno enaka velikosti ponovitve. Če torej nastavimo velikost okna na npr. 90, dobimo naslednji diagram (ob privzeti vrednosti za threshold):



Z večanjem velikosti okna tako zmanjšamo šum, a hkrati tudi občutljivost, saj ne detektiramo več krajsih podobnih segmentov.

---

### V07-03

#### ALGORITEM NEEDLEMAN-WUNSCH

V Excel-u „sprogramirajte“ globalno prileganje dveh zaporedij po osnovnem algoritmu Needleman-Wunsch. Pomagajte si slikami z uvoda v vajo (pdf).

#### Odgovor

Rešitev naloge je v datoteki „V07 - Naloge - RESENO.xlsx“.

---

### V07-04

#### GLOBALNO IN LOKALNO PRILEGANJE

Kateri tip prileganja (globalno ali lokalno) je primernejši za primerjavo aminokislinskih zaporedij iz posameznega para?

Par A: izoblik 1 in 2 človeške karbonske anhidraze

Par B: človeška proteina nidogen-2 in IGFBP-1 (Insulin Growth Factor-Like Binding Protein 1)

Par C: človeški fibronektin in podenota beta mišjega receptorja za interleukin 6

Namig: Zaporedja omenjenih proteinov poiščite v bazi UniProt, oglejte si anotacije v tej bazi (regije oz. domene!), nato pa analizirajte zaporedja še s Prosite.

Za par B izdelajte tako lokalno (Smith-Waterman oz. Water (EMBOSS)) kot tudi globalno prileganje (Needleman-Wunsch oz. Needle (EMBOSS)). Orodja so na tej povezavi: <http://www.ebi.ac.uk/Tools/psa/>. V ustrezna okanca prilepite zaporedja v formatu FASTA, pri tem pa v naslovno vrstico zaporedja (za znak >) vpisite kratko ime proteina. Oglejte si „izhod“ (output) obeh programov – zgoraj so navedeni uporabljeni parametri, spodaj pa na kratko lastnosti prileganja (dolžina, identičnost, podobnost, vrzeli). Mimogrede: EMBOSS pomeni European Molecular Biology Open Software Suite. Oglejte si „izhod“ (output) obeh programov – zgoraj so navedeni uporabljeni parametri, spodaj pa na kratko lastnosti prileganja (dolžina, identičnost, podobnost, vrzeli).

#### Odgovor

**Par A:** uporabimo **globalno** zaporedje, saj sta zaporedji skoraj enako dolgi (to vidimo v UniProt), prav tako pričakujemo precejšnjo podobnost vzdolž celotnih zaporedij, saj gre za izobliko istega encima; podobnost preverimo tako, da dejansko naredimo globalno prileganje.

Dolžino zaporedij razberemo, kot omenjeno, iz njunih zapisov v bazo UniProt, ki vsebuje še ostale podatke, ki nakazujejo na veliko podobnost med proteinoma:

- karbonska anhidraza 1: <http://www.uniprot.org/uniprot/P00915>
- karbonska anhidraza 2: <http://www.uniprot.org/uniprot/P00918>

#### Par B:

V UniProt poiščemo zapisa:

- nidogen-2: <http://www.uniprot.org/uniprot/Q14112>

- IGFBP-1: <http://www.uniprot.org/uniprot/P08833>

Že iz UniProt zapisov oz. anotacij vidimo, da oba proteina vsebujeta tiroglobulinsko domeno tipa 1 (thyroglobulin type-1), ki se v nidogenu pojavi dvakrat, v IGFBP-1 pa enkrat; ostale domene/regije so različne. V tem primeru je bolj smiselno uporabiti **lokalno** prileganje; zaporedji sta namreč različno dolgi, prav tako pa pričakujemo znatno podobnost zgolj v eni regiji, ki ustreza tiroglobulinski domeni.

### Par C:

V UniProt poiščemo zapisa:

- fibronektin: <http://www.uniprot.org/uniprot/P02751>
- podenota beta mišjega receptorja za interleukin 6: <http://www.uniprot.org/uniprot/Q00560>

Podobno kot v primeru C gre za proteina z zelo različno dolgimi zaporedji, ki vsebujeta različne domene, nekatere od teh a so podobne – gre za fibronektinsko domeno tipa III, ki se v fibronektinu ponovi 16-krat (ponovitve so oštevilčene), v receptorju za interleukin 6 pa 5-krat, pričakujemo pa lahko tudi oločeno podobnost med fibronektinskimi domenami tipa III receptorja za interleukin 6 ter fibronektinskimi domenami tipa I in II v fibronektinu. Za ta primer je torej prav tako primernejše **lokalno** prileganje.

### Prileganje za par B:

#### LOKALNO

```
#=====
# 
# Aligned_sequences: 2
# 1: nidogen2
# 2: IGFBP1
# Matrix: EBLOSUM62
# Gap_penalty: 10.0
# Extend_penalty: 0.5
#
# Length: 237
# Identity:      54/237 (22.8%)
# Similarity:    73/237 (30.8%)
# Gaps:          69/237 (29.1%)
# Score:         110.0
#
#=====
nidogen2      812 CGPNCSV-CINLPGSYRCECRSGYEFADDRHTCILITPPANPCEDGSHTCA   860
                |.|..| ..|...|.|..| |:...|... .|.
IGFBP1        41 CPPVSASCSEVTRSRAGCGC-----CPMCALPLGA-----ACG   72
nidogen2      861 PAGQARCVHHGGSTFSCACLPGYAGDGHQCTD----VDECSENRCHPAA   905
                .| .|||.. ..|||.|||....|..|. |.|...:..| |||
IGFBP1        73 VA-TARCAR---GLSCRALPGEQQPLHALTRGQQGACVQESDASAPH-AA 116
nidogen2      906 TCYNTPGSFSCRCQPGYYGDGFQCIP-----DSTSSL-- 937
                ...:....|.....|.|...:| .|.:| |
IGFBP1        117 EAGSPESPTEITEELLDNFHLMAPSEEDHSILWDAISTYDGSKALHV 166
nidogen2      938 -----TPCE-----QQQRHAQAQYAYPGARFHIPQCDEQGNFLPLQ 973
                .||. :....| |.....:|:|.|:..|.:..| .|:..|
IGFBP1        167 TNIKKWKEPCRIELYRVVESLAKAQETSGEEISKFYLPNCNKNGFYHSRQ 216
nidogen2      974 CH----GSTGFCWCVDP-DGHEVPGTQTPPGSTPPHC  1005
                |. |..| |||.| :|..:|||:....|. |:|
IGFBP1        217 CETSMGEAGLCWCVYPWNGKRIPGSPEIRGD--PNC   251
#-----
#-----
```

#### GLOBALNO

```
#=====
# 
# Aligned_sequences: 2
# 1: nidogen2
# 2: IGFBP1
# Matrix: EBLOSUM62
# Gap_penalty: 10.0
# Extend_penalty: 0.5
#
# Length: 1414
# Identity:      61/1414 ( 4.3%)
# Similarity:    98/1414 ( 6.9%)
# Gaps:          1194/1414 (84.4%)
# Score:         90.5
#
#=====
nidogen2      1 MEGDRVAGRVLSSLPVLLLPLMLRAAALHPDELPHGESWDQLLQE   50
```

**7. vaja – Prileganje zaporedij (Miha Pavšič / april 2014)**

IGFBP1	1 -----	0
nidogen2	51 GDDESSAVVKLANPLHFYEARFSNLVVGNTNGIISTQDFPRETQYVDYDFP	100
IGFBP1	1 -----	0
nidogen2	101 TDFPAIAPFLADIDTSHGRGRVLYREDTSPAVLGLAARYVRAGFPRSAF	150
IGFBP1	1 -----	0
nidogen2	151 TPTHAFLATWEQVGAYEEVKRGALPSGELNTFQAVLASDGSDSYALFLYP	200
IGFBP1	1 -----	0
nidogen2	201 ANGLQFLGTRPKESYNVQLQLPARVGFCRGEADDLKSEGPyFSLTSTEQS	250
IGFBP1	1 -----	0
nidogen2	251 VKNLYQLSNLGIPGVWAFHIGSTSPLDNVRPAVGDLAAHSSVPLGRSF	300
IGFBP1	1 -----	0
nidogen2	301 SHATALESDYNDENLDYYDVNEEEAEYLPGEPEEALNGHSSIDVSFQSKV	350
IGFBP1	1 -----	0
nidogen2	351 DTKPLEESSTLDPHTKEGTSLGEVGGPDLKQQVEPWDERETRSPAPPEVD	400
IGFBP1	1 -----	0
nidogen2	401 RDSSLAPSWEPPPYPENGSIQPYPDGGPVSEMDVPPAHPEEEIVLRSYP	450
IGFBP1	1 -----	0
nidogen2	451 ASGHTTPLSRGTYEVGLENDIGNSNTEVFTYNAANKETCEHHNRQCSRHA	500
IGFBP1	1 -----	0
nidogen2	501 CTDYATGFCCCHCQSKFYGNNGKHLPEGAPHRVNGKVSGHLHVGHTPVHFT	550
IGFBP1	1 -----	0
nidogen2	551 DVDLHAYIVGNDGRAYTAISHIPQPAQQALLPLTPIGGLFGWLFALEKPG	600
IGFBP1	1 -----	0
nidogen2	601 SENGFSLAGAAFTHDMEVTFYFGEETVRITQTAEGLD PENYLSIKTNQG	650
IGFBP1	1 -----	0
nidogen2	651 QVPYV SANFTA HIS PYKELYHYSDSTVTSTSSRDYSLTFGAINQTWSYRI	700
IGFBP1	1 -----	0
nidogen2	701 HQNITYQVCRHAPRHPSFPTTQQLNVDRV FAL YNDEERVLRF AVTNQIGP .....  .: :...: . :	750
IGFBP1	1 -----MSEVPVARVW-----LVLLLTVQVG-	21
nidogen2	751 VKE DSDPTPGNP CYDGSHMC DTTAR CHPGTGV DYTCECASGYQGDGRNCV .  .  .    .  .   .  .  :    .  .	800
IGFBP1	22 -----V TAGAPWQCAPCSAEKLALC P P-----VSASCSEVTRSAGCGCC	60
nidogen2	801 D-----ENE CATGFHRCGPNSVCINLPGSYRCECRSGYE FADDRHTCIL .  .  .  .  .  .   .  .  :  .  .	844
IGFBP1	61 PMCALPLGAACGVATARCARGLSCR ALPG---EQQPLHALTRGQGACVQ	106
nidogen2	845 I TPPANP--CEDGS-----HTCAPAGQARCVHHGG-S .  .  .  .  .   .  .  :  .  .	873
IGFBP1	107 ESDASAPHA AEAGSPESPESTEITEELLDNFHLMAPSEEDHSILDAIS	156
nidogen2	874 TFSCACLPGYAGDGHQCTDVDECSEN RCHPAATCYNTPGSFSCRCQPGYY  :  .  .  .  .   .  .  .  .	923
IGFBP1	157 TY-----DGSKALHVTNIKK-----WKEP-----CRIE---	179
nidogen2	924 GDGFQCIPD STSS LTPCEQQQR HAQAQYAYPGARFHIPQCDEQGNFLPLQ   .  .  .  .  .  .  .  .  .  .  .	973
IGFBP1	180 -----LYRVVESLAKAQETSGEEISKFYLPNCNKNGFYHSRQ	216
nidogen2	974 CH----GSTGFCWC VDP-DGHEVPGTQTPPGSTPPHC-----GPSPEP .  .  .  .  .  .  .  .  .  .  .	1011
IGFBP1	217 CETSM DGEAGLCWC VYPWNGKRIPGSPEIRGD--PNCQIYFNVQN----	259
nidogen2	1012 TQRPTTICERWREN LLEHYGGTP RDDQYVPQCDDLGHFIPLQCHGKSDFC	1061
IGFBP1	260 -----	259
nidogen2	1062 WCVDKDGREVQGTRSQPGTT PACIPTVAPP MVRPTPRPDVTPPS VGT FLL	1111

IGFBP1	260 -----	259
nidogen2	1112 YTQQQQIGYPLPLNGTRLQKDAAKTLLSLHGSIVGIDYDCRERMVYWTDV	1161
IGFBP1	260 -----	259
nidogen2	1162 AGRTISRAGLELGAEPETIVNSGLISPEGLAIDHIRRTMYWTDNSVLKIE	1211
IGFBP1	260 -----	259
nidogen2	1212 SALLDGSERKVLFYTDLVNPRAIAVDPIRGNLYWTDWNREAPKIETSSL	1261
IGFBP1	260 -----	259
nidogen2	1262 GENRRILINTDIGLPNGLTDFPFSKLLCWADAGTKKLECTLPDGTGRRVI	1311
IGFBP1	260 -----	259
nidogen2	1312 QNNLKYPFSIVSYADHFYHTDWRRDGVVSVNKHSGQFTDEYLPEQRSHLY	1361
IGFBP1	260 -----	259
nidogen2	1362 GITAVYPYCPTGRK	1375
IGFBP1	260 -----	259

#-----  
#-----

Iz primerjave obeh prileganj vidimo, da je delež identičnosti oz. podobnosti pri lokalnem prileganju (22,8 % oz. 30,8 %) večji kot pri globalnem prileganju (4,3 % oz. 6,9 %), kar potrjuje naše predvidevanje, da sta proteina podobna samo lokalno (v konkretnem primeru v eni domeni, to je tiroglobulinski domeni), vzdolž celotne polipeptidne verige pa niti ne. Tako tudi vrzeli (gaps) predstavljajo kar 84,4 % globalnega prileganja, pri lokalnem prileganju, kjer imamo prikazan le najbolj podoben del, pa je ta delež 29,1 %. Odsek zaporedij, prikazan pri lokalnem prileganju, oz. dolžina lokalnega prileganja je odvisna od parametrov, ki jih nastavimo (pod "More options" pod okenci za vnos zaporedij na začetni strani).

## V07-05

### LOKALNE PODOBNOSTI

S programom LALIGN za aminokislinska zaporedja (<http://www.ebi.ac.uk/Tools/psa/lalign>) primerjajte zaporedje človeškega kalmodulina s samim seboj. Kaj opazite? Komentirajte/razložite rezultat!


#### Odgovor

V UniProt poiščemo zapis za človeški kalmodulin; pravilen zadetek iskanja po bazi je ta:

<http://www.uniprot.org/uniprot/P62158>

(Pri iskanju dombimo še več drugih zadetkov, med drugim tudi kalmodulinu podobne proteine (Calmodulin-like protein), ki pa niso kalmodulin, zato moramo biti pri izbiri zadetka za nadaljnje delo zelo pozorni, saj ni vedno ta prvi zadetek tisti pravi!)

Že pri pregledu anotacij v bazi UniProt ugotovimo, da je kalmodulin sestavljen iz štirih onovitev t.i. rok EF (EF-hand, ki so oštevilčene od 1 do 4):



Hkrati vidimo, da so te štiri roke EF, ki pravzaprav zaobsegajo celoten protein, približno enako dolge (~35 aminokislinskih ostankov).

Pri primerjavi ak-zaporedja kalmodulina s samim seboj kot rezultat dobimo več različnih lokalnih prileganj, ki jih lahko vizualiziramo s klikom na "Visual Output" blizu zgornjega dela strani z rezultati. Ta prikaz nekako spominja na točkovni diagram, čeprav to ni, ampak prikazuje, katere regije enega zaporedja so podobne drugi regiji (tam so narisane črte) ter kolikšna je podobnost (barva črte, ki je povezana z lestvico točk za prileganje). Vidimo naslednje:

- diagonalo, ki ustreza prileganju zaporedja s samim seboj, 100% identičnost --> visok score (>200),
- trikotni področji desno pod in levo nad diagonalo sta seveda simetrični, saj zaporedje primerjamo samega s seboj,
- dodatne diagonalne linije predstavljajo primerjavo oz. prileganje posameznih rok EF (oz. dveh ali treh rok EF) s drugimi v istem proteini – glej priloženo sliko.

Omenjene ponovitve rok EF se torej v tem diagramu, ki grafično ponazarja lokalna prileganja, kažejo kot dodatne diagonale (zraven glavne diagonale), podobno, kot se ponovitve kažejo v točkovnem diagramu.

**Slika 1**

### Kalmodulin – lokalno prileganje / Visual Output

