UTILIZZO DI BLAST PER ALCUNE SEMPLICI APPLICAZIONI IN STUDI GENOMICI

- Come prima cosa diamo un'occhiata alla nostra sequenza di interesse, chiamata «unknown sequence»
- Con un doppio click possiamo visualizzarla
- Si tratta di una sequenza nucletidica lunga poco più di 800 nucleotidi, corrispondente ad un mRNA di ostrica la cui funzione è ignota



STEP 1: ANNOTAZIONE FUNZIONALE

- Per capire quale può essere la funzione del mRNA ignoto potrebbe essere utile capire prima di tutto quale sia la proteina da esso codificata
- Questo è possibile grazie ad il confronto con sequenze la cui funzione è nota che sono state precedentemente depositate in un database pubblicamente disponibile sul server dell'<u>NCBI</u>, un grande centro bioinformatico americano
- Possiamo collegarci all'indirizzo <u>https://blast.ncbi.nlm.nih.gov/Blast.cgi</u>
- Come prima cosa dobbiamo selezione il tipo di BLAST più appropriato, nel nostro caso <u>BLASTx</u> (la sequenza nucleotidica deve essere <u>tradotta</u> per essere confrontata con un database proteico)

marcogerdol My NCBI Sign Out

BLAST [®]

Home Recent Results Saved Strategies Help

Basic Local Alignment Search Tool

BLAST finds regions of similarity between biological sequences. The program compares nucleotide or protein sequences to sequence databases and calculates the statistical significance.

IgBLAST 1.8.0 released

A new version of IgBLAST is now available. Wed, 15 Nov 2017 16:00:00 EST

More BLAST news...

Web BLAST

EWS

BLAST Genomes



NIH U.S. National Library of Medicine NCBI National Center for Biotechnology Information	marcogerdol	My NCBI	Sign Out
BLAST [®] » blastx	Recent Results Saved	l Strategies	Help
Translated BLAST: blastx			
blastn blastp blastx tblastn tblastx			
Enter Query Sequence BLASTX search protein databases using a translated nucleotide query. more	Reset page	Bookmark	
Enter accession number(s), gi(s), or FASTA sequence(s) GTTATCACCCGCATTCCGGAACATTTATCGCAACTCGGTCTGGATATTATGTCTTTACGTGGTCCTTTAGGAT TCAAGGTAGATGACTCATATTTTCGACCGAACTCGTGGTAAATGACACGCCTAGAGGTACCGTTTACTATGACGCA ACAGAGAAACATACTAACTGAGGTGGGAACACTGGTGGGACGGTTGTCGTTCACGGTAAATGACCGCA ACAGAGAAACAATACTAACTATAACCTTGGTGGACACTTGTGGATAAACGCAGGAAGAACTTATTTTGGTGGTTG GCTTTTATCCTAA CIEar Query subrange From Io IO INCOLLIAMO LA SEQUENZA NUCL INCOLLIAMO LA SEQUENZA NUCL INCOLLIAMO LA SEQUENZA NUCL INCOLLIAMO LA SEQUENZA NUCL	<u>EOTIDICA NEL</u>		
Or, upload file Scegli file Scegli file Nessun file selezionato Genetic code Standard (1) Job Title			
Choose Search Set			
Database			
Organism Optional Non-redundant protein sequences (nr) Reference proteins (refseq_protein) Model Organisms (landmark)	<u>.RE DAL MENU'</u> TKB» CHE CONT	<u>A</u> TIENE	
Exclude Patented protein sequences(pat) e sequences SEQUENZE PROTEICHE LA CUILE	UNZIONE E'ST/	ΔΤΔ	
Optional Protein Data Bank proteins(pdb) Entrez Query Metagenomic proteins(env. pr)			
Optional Transcriptome Shotgun Assembly proteins (tsa_nr)			
POSSIAMO FIDA	<u>IRE</u>		
BLAST See the detenance UniDentif D'Swing Dept(swing Dept(swing Direct) using Directy (second protein detenance using a translated nucleotide query)			
CLICCHIAMO SUL TASTO «BLAST:	» PER LANCIAR	<u>E L</u> A	
Algorithm parameters Note: Parameter values that differ from the default are highlighted in yellow and marked with * sign RICERCA			



Nel giro di pochi secondi dovemmo ottenere i risultati, organizzati in tre sezioni

- 1) Una parte grafica con barre colorate
- 2) Una tabella con la lista dei risultati
- 3) Il detaglio degli allinementi ottenuti tra la sequenza query (input) e subject (quelle trovate nel database)

I risultati sono ordinati per e-value dal più significativo al meno significativo

Sequences producing significant alignments:

Select: All None Selected:0

AT	Alignments 📲 Download 🖂 <u>GenPept</u> <u>Graphics</u>								
	Description	Max score	Total score	Query cover	E value	Ident	Accession		
	RecName: Full=Complement C1q-like protein 3; AltName: Full=C1q and tumor necrosis factor-related protein 13; Short=C1q/TNF-related protein 13; Short=CTRP13; AltName: Full=Gliacolin; Flags: Precursor	43.1	43.1	38%	0.001	31%	Q9ESN4.1		
	RecName: Full=Complement C1q-like protein 3; AltName: Full=C1q and tumor necrosis factor-related protein 13; Short=C1q/TNF-related protein 13; Flags: Precursor	43.1	43.1	38%	0.001	31%	Q5VWW1.1		
	RecName: Full=Heavy metal-binding protein HIP	42.4	42.4	29%	0.001	29%	P83425.1		
	RecName: Full=Complement C1q-like protein 4; AltName: Full=C1q and tumor necrosis factor-related protein 11; Short=C1q/TNF-related protein 11; Short=C1qTNF11; Short=CTRP11; Flags: Precursor	42.4	42.4	42%	0.002	29%	Q4ZJM9.1		
	RecName: Full=C1q-related factor; AltName: Full=C1q and tumor necrosis factor-related protein 14; Short=C1q/TNF-related protein 14; AltName: Full=Complement component 1 Q subcomponent-like 1; Flags: Precu	41.6	41.6	38%	0.004	31%	<u>075973.1</u>		
	RecName: Full=Complement C1q-like protein 4; AltName: Full=C1q and tumor necrosis factor-related protein 11; Short=C1q/TNF-related protein 11; Flaqs: Precursor	41.2	41.2	42%	0.004	29%	Q86Z23.1		
	RecName: Full=C1q-related factor; AltName: Full=C1q and tumor necrosis factor-related protein 14; Short=C1q/TNF-related protein 14; Short=CTRP14; AltName: Full=Complement component 1 Q subcomponent-like	41.2	41.2	38%	0.004	31%	088992.2		
	RecName: Full=Complement C1g subcomponent subunit B; Flags: Precursor	40.4	40.4	49%	0.008	28%	P02746.3		
	RecName: Full=Complement C1q-like protein 2; AltName: Full=C1q and tumor necrosis factor-related protein 10; Short=C1q/TNF-related protein 10; Flags: Precursor	40.4	40.4	41%	0.008	29%	Q7Z5L3.2		
	RecName: Full=Complement C1q-like protein 2; AltName: Full=C1q and tumor necrosis factor-related protein 10; Short=C1q/TNF-related protein 10; Short=C1qTNF10; Short=CTRP10; Flags: Precursor	40.4	40.4	41%	0.010	29%	Q8CFR0.1		
	RecName: Full=Complement C1g subcomponent subunit A; Flags: Precursor	38.5	38.5	13%	0.037	47%	P02745.2		
	RecName: Full=Cerebellin-1; AltName: Full=Precerebellin; Contains: RecName: Full=Cerebellin; Short=CER; Contains: RecName: Full=[des-Ser1]-cerebellin; Flags: Precursor	37.7	37.7	28%	0.053	31%	P23435.1		
	RecName: Full=Cerebellin-1; AltName: Full=Precerebellin; Contains: RecName: Full=Cerebellin; Short=CER; Contains: RecName: Full=[des-Ser1]-cerebellin; AltName: Full=des-Ser(1)-cerebellin; Short=[des-Ser1]CE	37.7	37.7	28%	0.053	31%	P63182.2		
	RecName: Full=Cerebellin-1; AltName: Full=Brain protein D3; AltName: Full=Precerebellin; Contains: RecName: Full=Cerebellin; Short=CER; Contains: RecName: Full=[des-Ser1]-cerebellin; Short=des-Ser1-cerebellin;	37.4	37.4	28%	0.071	31%	Q9R171.1		
	RecName: Full=Multimerin-1; AltName: Full=EMILIN-4; AltName: Full=Elastin microfibril interface located protein 4; Short=Elastin microfibril interfacer 4; AltName: Full=Endothelial cell multimerin; Contains: RecName	36.6	36.6	25%	0.25	38%	<u>Q13201.3</u>		
	RecName: Full=Multimerin-1; Flags: Precursor	34.3	34.3	25%	1.3	32%	B2RPV6.2		
	RecName: Full=Complement C1g subcomponent subunit A; Flags: Precursor	32.3	32.3	13%	3.9	39%	Q69DL0.1		
	RecName: Full=Ammonium transporter Rh type C; AltName: Full=Rhesus blood group family type C glycoprotein; Short=Rh family type C glycoprotein; Short=Rh type C glycoprotein	31.6	31.6	14%	8.9	33%	Q95JD3.1		

I risultati migliori hanno e-value = 0,001, non eccezionali (tenderebbero a zero in caso di elevatissima similarità), ma comunque significativi. L'identità tra query e subject si aggira attorno al 30% (questo perché probabilmente non ci sono sequenze di ostrica o altri molluschi depositate nel database che abbiamo consultato

Tutti i risultati sembrano ricondurre a proteine legate a «C1q and TNF-related proteins», chiara indicazione che anche il mRNA ignoto di ostrica con ogni probabilità codifica una proteina con una funzione simile, che potrò certamente studiare grazie a dati di letteratura

STEP 2: ANNOTAZIONE STRUTTURALE

- La sequenza nucleotidica del mRNA può essere confrontata con il genoma di ostrica (se disponibile) per identificare su quale scaffold sia localizzato il gene che la codifica e da quanti esoni esso sia costituito
- Clicchiamo sul file nominato «oyster genome scaffolds»: si tratta del genoma di ostrica, che potremo utilizzare come database per un BLAST <u>locale</u> (cioè con il CLC Genomics Workbench e non più online come prima).
- Il genoma di ostrica consiste di 7659 scaffold identificate da un accession ID come evidenziato sotto, per una dimensione totale di circa 700 milioni di paia di basi



Selezioniamo la sequenza ignota con il tasto destro e lanciamo un BLAST selezionado Toolbox -> BLAST -> BLAST come mostrato sotto

Vogliamo confrontare la sequenza del mRNA con il genoma per trovare su quale scaffold è localizzato il gene e trovare la localizzazione precisa degli esoni

					un_oodooneo	gonon_gonom					
18				Rows:	7.659 Seque	ence list: ovster ae	enome scaff	olds			Filter
Y	- 📷 CLC_Data	NCT.									
3		ASI Main		Name Modified Description							Size
	= scalop_pro	ama cooffelde	a in	816267	7	Crassostrea gigas	unplaced o	enomic scaffold scaffold2.	whole genome shota	un sequence.	630
	·- Uyster_gen	onie_scanolus	i internet	817943	3	Crassostrea gigas	unplaced g	enomic scaffold scaffold4.	whole genome shota	un sequence.	678202
P		[→ Show	Ctrl-O			Crassostrea gigas	unplaced g	enomic scaffold scaffold6,	whole genome shotg	un sequence.	744290
	- Pa Frenkie	 Show)	Crassostrea gigas	unplaced g	enomic scaffold scaffold8, v	whole genome shotg	un sequence.	508
					2	Crassostrea gigas	unplaced g	enomic scaffold scaffold10,	whole genome shot	gun sequence.	63960
	Claudia	L† <u>N</u> ew			5	Crassostrea didas	unnlaced o	enomic scaffold scaffold12,	whole genome shot	gun sequence.	533373
		Toolbox		•	🕼 Launch		Ctrl+Shift-T	nomic scaffold scaffold14,	whole genome shot	gun sequence.	383
		🛠 Cut	Ctrl-X		🖗 Utilities		•	, nomic scaffold scaffold16	, whole genome shot	gun sequence.	494
			and a		C PDfold plugin			nomic scaffold scaffold18	whole genome shot	gun sequence.	39826
		Di Zobà	Ctri-C					nomic scaffold scaffold20,	whole genome shot	gun sequence.	858686
	Alua	[L] <u>P</u> aste	Ctrl-V		🐋 Classical Sequ	ence Analysis	•	nomic scaffold scaffold22	whole genome shot	gun sequence.	1964558
	ChiaraScap	🔀 <u>D</u> elete	Delete		🔯 Mo <u>l</u> ecular Biolo	ogy Tools	•	nomic scaffold scaffold25	whole genome shot	gun sequence.	253
C	enter search term	ale Rename	F2		🔁 BLAST		•	BLAST	Ctrl+Shift-L	gun sequence.	68620
		<u>х ноданно</u>			P NGS Core Tool	e .			Ctrl+Sbift-B	gun sequence.	30/53
Tool	box	Standard Import	Ctrl-I			5		BLAST against	sequences in the Na	vigation Area or a loc	al BLAST data
		[Ctrl-E		🛅 <u>T</u> rack Tools		•	Ma Downioad BLAST Data	pases	gan sequence.	14070
%_ S	RA Download (Done)	🕂 Local Search	Ctrl+S	hift-F	🚮 Resequencing	Analysis	•	🛚 🛃 Create BLAST Databas	e	gun sequence.	261196
		Sart Folder	Ctd+s	bitt-R	🚰 <u>R</u> NA-Seq Analy	sis	•	🛯 🛅 Manage BLAST Databa	ases	gun sequence.	1841
암의	earching SRA Databa	Sur Folder	Gurro		🖂 Microarray and	Small RNA Analysis	• •	homic scaffold scaffold41.	whole genome shot	aun sequence.	873
-		() Update Folder	F5		🚘 Microarray and	a official read Afficially of	· ·	nomic scaffold scaffold43.	whole genome shot	aun sequence.	682241
		R <u>e</u> store			Epigenomics A	naiysis		nomic scaffold scaffold45.	whole genome shot	qun sequence.	273
Imply Location Sequence Representation				🐻 De Novo Seque	encing	•	nomic scaffold scaffold47	whole genome shot	gun sequence.	48399	
				🗊 Workflows		Þ	nomic scaffold scaffold49,	whole genome shot	gun sequence.	351383	
		Location			homic scaffold scaffold51, whole genor		whole genome shot	gun sequence.	591		
		Sequence Representation	on	با∢	B Fedara 10012		anibiacoa A	-homic scaffold scaffold53,	whole genome shot	gun sequence.	1214666
			JH:	817479)	Crassostrea gigas	unplaced g	enomic scaffold scaffold55,	whole genome shot	gun sequence.	368
			- 1 S	010070		A 1 1		· · · · · · · · · · · · · · · · · · ·			053,005

Dobbiamo selezionare BLASTn dal menù a tendina (confronto di sequenza nucleotidica contro database nucleotidico)

Inoltre bisogna selezionare il database «oyster_genome_scaffolds» sotto «target» cliccando sull'icona indicata dal circolo

Navigation Area	🖣 🖬 unknown_sequence 🗙 🖽 🕻	yster_genome_scaffolds ×
▶ 脑色 O	Gx BLAST@labgenCLC	×
Image: Provide the second state Image: Provide the second state <	1. Select sequences of same type	Choose program and target
unknown_sequence	2. Choose program and target	
esempio	3. Set BLAST parameters	
 ► Caudia ► Claudia ► Caudia ► Caudia ► Caudia ► Caudia ► Caudia 	4. Result handling	
• 🚰 Domenico • 🖻 Aida		BLAST program
► ChiaraScap		Program: blastn: DNA sequence and database
Chiere Simoni Qr <enter search="" term=""></enter>	1	Target
	<u></u>	Sequences
SRA Download (Done) 100 %	5	oyster_genome_scaffolds
🗗 Searching SRA Database 100 %	G	O BLAST database
	0-10-0 	FATTO QUESTO, CLICCHIAMO SU «NEXT»
	Help Reset	Previous Next Einish Cancel

Gx BLAST@labgenCLC	
 Select sequences of same type 	Set BLAST parameters
2. Choose program and target	
3. Set BLAST parameters	
4. Result handling	
	- Choose parameters
	Number of threads: 24
	Choose filter: 🗹 Filter low Complexity
	Expect: 10.0
	Word size: 32
	Gon pacto: Evistance 5. Extension 2.
	Max number of hit sequences
» 	

Lasciamo questi parametri (il cui significato è stato accennato brevemente a lezione) con i valori di default Un word size = 32 andrà

Un word size = 32 andra bene in questo caso perché stiamo cercando una sequenza che deve essere identica al mRNA, quindi ci basta una bassa sensibilità, ma questo ci aiuterà a rendere la ricerca molto veloce

unknown_sequence	
gb JH816238 gb JH816238	
gb H816238	
gb JH816238 gb JH816238	
gb∥H816238 gb∥H816636	

Osserviamo i risultati... la parte grafica è simile a quella che abbiamo visto online, anche se va dal verde chiaro (molto significativo) al nero (poco significativo)

- 1) Gli hit di BLAST sono divisi in due sezioni rispetto alla nostra sequenza ignota, probabile indicazione che l'mRNA è codificato da un gene con due esoni
- 2) Tutti gli hit altamente significativi sono localizzati sulla stessa scaffold (JH816238), che possiamo andare a recuperare dal file «oyster_genome_scaffold» effettuando una ricerca testuale
- 3) Come mai troviamo tre hit con la stessa significatività sia per l'esone 1 che per l'esone 2? Questa potrebbe essere un'indicazione che il nostro gene di interesse è presente in 3 copie identiche (geni paraloghi) sulla stessa scaffold



Andiamo a vedere il dettaglio dei risultati dall'output tabulare cliccando sul simbolo evidenziato a fianco

Rows: 7 St	ummary of HSPs fro			Filter 루			
Hit	E-value	HSP start	HSP end	Query start	Query end	%Identity	HSP frame/stra
JH816238	0.00	165866	165416	366	816	100.00	Minus
JH816238	0.00	194947	194497	366	816	100.00	Minus
JH816238	0.00	188921	188478	372	816	99.10	Minus
JH816238	0.00	166473	166107	1	367	100.00	Minus
JH816238	0.00	195554	195188	1	367	100.00	Minus
JH816238	0.00	190208	189842	1	367	99.46	Minus

Per comodità sono mostrate soltanto alcune delle varie colonne che possono essere selezionate. Notiamo che:

- Tutti gli hit positivi sono sullo strand Minus (ultima colonna), HSP = High Scoring Pairs, cioè la regione di hit trovata nella scaffold. Questo significa che tutti e tre i geni sono localizzati sullo strand reverse e che quindi dovranno essere annotati da destra verso sinistra.
- 2) Query start/end indicano la posizione di hit nel mRNA, HSP start/end la posizione dove inzia e finisce l'hit nella scffold. Ovviamente posso supporre che l'esone 1 e 2 più vicini facciano parte dello stesso gene
- 3) Quindi il gene 1 comprenderà: esone 1 (166107-166473) + esone 2 (165416-165866)
- 4) Il gene due sarà distante circa 23 Kb ed inizierà in posizione 188478
- 5) Il terzo gene sarà più vicini al secondo (circa 4 Kb), iniziando in posizione 194497

Posso aprire la sequenza della scaffold di interesse con un doppio click e annotare a mano i due esoni del gene 1, come mostrato sotto

JH816238	TGAATAAATACTATATTAATGGTATAT	TGGCCTCAATTGAAATTTAACATC	ATAAATAAAAGGTTGAT	TCTTTTAAACAA				+
-	166,100	166,120	166,140	166,160	Off	set	Little offset	
JH816238	TCAGATATATATTTTCATTAGCTTAC	TTTTTCAGGAATTCCAGATCGTTT	AAAAGCCGAAGCTTTCT	TCATCTGGACAT	Lak	pel	Stacked	-
	166,180	166,200	166,220	166,240		Show arrows		
JH816238	TCATTGATGTGGGTTCGTTTAATATTG	ATGAATTTTTAATATTAGTTTTAC	ATGCGCGTTGGCGTTGC/	AAGTGCAATATT				
	166,260	166,280	166,300	166,320		Use gradients		
JH816238	TTTTCATCTTGAGTTTGAATCATAGTT	CGAAACTCTGCTATTTCTTCAGAT	TGCATAGCATTTTGTCT	CTCTAATGCCAG	R	estriction sites		Ľ
	166,340	166,360	166,380	166,400	M	otifs		Ľ
JH816238	TATTCTTTCATTTTGATCCAAAAGTAA	AGATTTTAGCTCAAAAATCATATT	TCGTAAATTGATTTCAT	CCTTTACATGTA	R	esidue coloring		Ľ
	166,420	166,440	166,460	166,480	a N	ucleotide info		Ľ
JH816238	TTTTTTCCTCAGTTTTGGCAGAACTAA	TTGAAAAATATCCAAAGAAGCAAA	CAATTGCGGCAAATAAA	TGCAT	Fi	nd		_
	166,500	166,520	166,540	166,560		16610716647	3	
JH816238	TCTTGCAGTGACAAGCGACAAACTGTG	TCCTTATCAATTACAATTCAAGGT	TTATTCGATACAATGAC	ATTTAAAGGGAG		Sequence		
	166,580	166,600	166,620	166,640		▶ Advanced s	earch parameters	
JH816238	AAAGACGTTTACCACGTGATCTTTCAG	ΑΑΤΑCΑΤGTTTAACATTAAAATAT	TAAACGAGAGAGAGAGA	GAGAGAGAGANN		Annotation		
	166,660	166,680	166,700	166,720		🔲 Include tra	anelatione	
JH816238	иииииииииииииииииииииииииииииииииииииии	иииииииииииииииииииииииииииииииииииииии	ทุกทุกทุกทุกทุกทุกทุกทุกทุก	ทุ่งทุ่งทุ่งทุ่งทุ่งทุ่งทุ่ง			ansialions	
	166,740	166,760	166,780	166,800		Position		
JH816238	ททพทพทพทพทพทพทพทพทพทพทพทพท	иииииииииииииииииииииииииииииииииииииии	ทุกทุกทุกทุกทุกทุกทุกทุกทุก	ииииииииии		F	Find	

Dal menù a destra cerchiamo «Find», quindi selezioniamo «position»

Scriviamo a mano le coordinate dell'esone 1 (166107 e 166473, cioè i nucleotidi inziali e finali di hit), attenzione a mettere prima il numero più basso

Clicchiamo si «Find» e la regione verrà automaticamente evidenziata

Clicchiamo sulla selezione con il tasto destro e selezioniamo «add annotation»

Dal menù a tendina su «Type» scegliamo exon

Come «name» indichiamo «exon1»

Ricordiamoci di selezionare «Minus per quanto riguarda lo strand!



Possiamo ripetere la stessa operazione per il secondo esone e, volendo, fare lo stesso per gli altri due geni. Allo stesso modo potremmo inserire le annotazioni degli introni o altri elementi di regolazione

STEP 3: ANALISI COMPARATA

- Quanti geni codificanti proteine appartenenti a uesta famiglia sono presenti in un altro mollusco bivalve?
- Verifichiamolo con un BLAST nella specie *Mizuhopecten yessoensis*
- Questo ci permetterà di verificare, grossolanamente, anche quanto le due specie siano divergenti tra loro
- Il proteoma completo di questa specie è contenuto nel file «scallop_protein», che potremo utilizzare come database per un altro BLAST locale, partendo dalla nostra sequenza ignota come query
- Attenzione al tipo di BLAST in questo caso, perché la combinazione è tra query nucleotidica e database proteico, quindi ci servirà un BLASTx

Gx BLAST@labgenCLC

Help

 Select sequences of same type 	choose pro
2. Choose program and target	
3. Set BLAST parameters	
4. Result handling	
	BLAST pro
	Target Seque Scallop_p
	O BLAST

Reset

BLAST program				
Program: blastx: Translate	d DNA sequence and pro	tein database	a 💌	
Tauaat				
Sequences				
scallop_protein		6		
U BLAST database				

Questi i settings da selezionare...

unknown_sequence			······	• ••• ••• •••	···•·· • ••••		
PY T14461	<u> </u>	·- ·	· · · · · · · · · · · ·	· ··· ··· •· ·	· · - · · · - · - · · ·		
PY_T16129				• ••• ••• •••	··· ·		
PY T19636				· ·- ··· ···	··-·· · - ·-·		
PY_T24515				• ••• ••• •••	··-·· · - ··	·	
PY_T20648							
PY_T19634		· <u> </u>	•····• •• ·• ·		··-·· · - ·-·	····	
PY_T22932	· · · ·		· ···· · · · ·	• ••• ••• •••	··-·· · - ·-·		=
PY_T18142							
PY_T22931					··-·· · -· -·		
PY_T16846				· ··· ·· ···			
PY_T14104			······	· · · · · · · · · · · · · · · · · · ·			
PY_T16848					··-·· · - · - ·		
PY_T14101				··· ··· •	··-·· · -· -·		
PY_T14616			····- ·· ·· ·				
PY_T22690			··· -·· -· ·· ·· ·	• ••• ••• •••	·· · ··		
PY_T19635	···		······	• ••• ••• •••	··-·· · -·-·		
PY_T19483			······	• ••• ••• •••	···•··		
PY_T16771					····· · -·· ·		
PY_T21371							
PY_T21373				• ••• ••• •••			
PY_T16803							
PY_T16542			· · · · · ·	• ••• ••• •••	··-·· · - ·-·		
PY_T22522							
PY_T24690					··-·· · - ···		
PY_T14102				·· ·· ·	··-·· · -···		
PY_T14015				··· ··· - ·	··-·· · -·-·	····	
PY_T04594					··-·· · -·-·		
PY_T22521							
PY_T23591				· ··· ··· ··	····· · - ···		
PY_T24684			·····	• ••• ••• •••			
PY_T19330					····· · - ···		
PY_T18563				··· ··· •··			
PY_T00976							
PY_T04595		· - · ·	· — · · · · · · · ·	· ··· ··· · ···	·····		
PY_T22689							
PY_T17325					····· · -···		
PY_T13403	·· ·		·····		····· · -·· ·		
PY_T13641			· - · ·	• ••• ••• •••	···•··		-
PV T14385				• ••• ••• • • •			•

Questa volta i risultati sono moltissimi

Notate gli accession ID, tutti diversi

Questo significa che sono molte le proteine, tutte diverse, a trovare similarità con quella di ostrica

La famiglia di proteine C1q è pertanto multigenica in *M. yessoensis*

Ma andiamo a vedere nel dettaglio la tabella...

Rows: 126	Summary of HSPs from query	: unknown_sequence	Filter =
	Hit	E-value	%Identity
PY_T14461		1.99E-17	25.90 🔺
PY T16129		8.36E-17	37.37
PY T19636		2.45E-15	27.53
PY_T24515		1.66E-14	36.25
PY_T20648		3.09E-14	35.04
PY_T19634		3.09E-14	27.98 🚍
PY_T22932		2.33E-13	29.29
PY_T18142		2.34E-13	38.66
PY_T22931		2.21E-12	30.77
PY_T16846		7.84E-12	38.24
PY_T14104		1.25E-11	30.15
PY_T16848		1.77E-11	42.68
PY_T14101		3.25E-11	34.93
PY_T14616		6.48E-11	26.81
PY_T22690		1.25E-10	27.57
PY_T19635		1.26E-10	22.27
PY_T19483		1.46E-10	28.16
PY_T16771		2.44E-10	35.00
PY_T21371		2.53E-10	33.06
PY_T21373		2.83E-10	33.02
PY_T16803		3.37E-10	29.77
PY_T16542		6.06E-10	26.72
PY_T22522		1.66E-9	31.30
PY_T24690		2.22E-9	30.71
PY_T14102		3.05E-9	35.42
PY_T14015		3.48E-9	43.28
PY_T04594		3.53E-9	35.71
PY_T22521		4.55E-9	28.68
PY_T23591		5.12E-9	25.35
PY_T24684		5.26E-9	24.36
PY_T19330		6.78E-9	35.37
PY_T18563		1.44E-8	31.08
PY_T00976		1.44E-8	34.29
PY_T04595		1.55E-8	22.01
PY_T22689		2.34E-8	31.30 🖕
D)(T1 700E		2.405.0	

L'e-value migliore è 1.99°-17, certamente significativo ma comuqnue abbastanza lontano da zero

Interessante è la % di identità, che ci dice che la proteina di M. yessoensis che più assomiglia a quella di ostrica è identica soltanto per il 25,9%!

Possimo concludere che la distanza evolutiva tra le due specie sia considerevole, forse più di quanto ci aspettassimo ALIGNMENTS >PY T14461 No definition line Length=281 Score = 80.1 bits (196), Expect = 2E-17 Identities = 65/251 (25%), Positives = 115/251 (46%), Gaps = 26/251 (10%) Frame = +1Query 115 ELKSLLLDQNERILALERQNAMQSEEIAEFRTMIQTQDEKILHLQ------R 252 +++ LL +I +L+R+NA E+ I T +EK+ L+ DIRLLLNKYGSQIESLQRENARLEEKTMTLEKKIMTLEEKVTTLEDQTPAFEDKTPMFEE Sbjct 37 Query 253 QRACKTNIKNSS-----ILNEPTSMNVQMKKASAFKRSGIPEKVIQTSAQQRIARAADTT 417 OR K+++ N++ IL P + + K+ + KR+ P++ ++ R+ D+ QREPKSDLVNNTKPGPDILGIPDGLAISDGKSQSRKRN--PDEAVK-KVNPRVDSTTDSI 153 Sbict 97 597 Query 418 IAFYAYSSHTFPRPSDHFILNFDTIITNLGNGYHPHSGTFIATRSGYYVFTWSFRIQGDA IAF+A SHT P+ I+ FD IITN+G Y +G F GYF+W + Sbjct 154 IAFHAILSHTVTDPAAEHIVTFDHIITNIGAHYSSKTGVFTCVEVGVYQF9MMIEVASVQ 213 Query 598 HISTELVVNDTPRGTVYYDATEKXXXXXXXXXXXXXQDDEVFIRTTNTNYNLGDILSDN 777 I+T+LV N G+ +++ + DEV++R T +++G ++ +Sbjct 214 WITTQLVRNGAVIGSA-ISGDDTYWTTGAASAITMLAPGDEVWVRLA-TGHSVGADITPT 271 Query 778 AGRTYFGGWLL 810 T F G+L+

Sbjct 272 --YTMFNGFLI 280

Nel dettaglio osservate l'allineamento tra le due proteine

Sebbene la similarità non sia particolarmente elevata, la lunghezza dell'allineamento è sufficiente per portare l'e-value a livelli di significatività piuttosto elevati

Ricordate che l'e-value dipende sia dalla similarità che dalla lunghezza dell'allineamento