

5. Ricerca di domini presenti in una sequenza

In questa attività utilizzeremo alcuni programmi basati su HMM che consentono di caratterizzare funzionalmente e strutturalmente una sequenza proteica attraverso l'identificazione di possibili domini e motivi presenti. Si noti come approcci diversi possano dare informazioni diverse e complementari. Come caso di studio prenderemo in esame la stessa sequenza utilizzata nell'esercitazione di previsione della struttura secondaria: **P98153**.

- Collegatevi al sito della banca dati **Pfam** (<http://pfam.sanger.ac.uk>). Ricordiamo che questa banca dati contiene allineamenti multipli di domini proteici caratterizzati funzionalmente e codificati sotto forma di HMM. Inserite nel campo *sequence search* la sequenza in formato FASTA e lanciate la ricerca (il risultato dovrebbe essere visibile in pochi minuti). La **Figura 1** riporta la schermata che restituisce Pfam. In posizione 29-66 della sequenza è stato riconosciuto il dominio del recettore delle lipoproteine a bassa densità di classe A.

The screenshot shows the Pfam website interface. At the top, there are navigation links: HOME | SEARCH | BROWSE | FTP | HELP | ABOUT. The main heading is "Sequence search results". Below this, there is a message: "We found 21 Pfam-A matches to your search sequence (1 significant and 20 insignificant) but we did not find any Pfam-B matches." A small icon in the sequence viewer is circled in red. Below the viewer, there is a table of significant Pfam-A matches.

Family	Description	Entry type	Clan	Envelope		Alignment		HMM		Bit score	E-value	Predicted active sites	Show/hide alignment
				Start	End	Start	End	From	To				
Ldl_recept_a	Low-density lipoprotein receptor domain class A	Repeat	n/a	28	66	29	66	2	37	40.1	1.8e-10	n/a	Hide
#HMM	tCkxneF-CangE..CipkswwCDyedDCadgDEkdC												
#MATCH	+C+p+++F C++g+ CIP w+CDg C+d sDE++C												
#PF	G*****												
#SEQ	[CNFSQFACRSGLqCIPLPWQCDGWATCEDESDEANG												

Figura 1 Risultato della ricerca in Pfam con la sequenza sonda. La presenza di un dominio identificato dal programma è evidenziata da un'icona rettangolare cliccabile posta all'interno dello schema della sequenza sonda (cerchio nella figura). In basso sono riportati i dettagli dei risultati della ricerca: in particolare l'E-value e l'allineamento tra la porzione della sequenza sonda e l'HMM del dominio.

- Un'ulteriore analisi può essere effettuata attraverso il sito **SMART** (<http://smart.embl-heidelberg.de>). Questa banca contiene una collezione di domini funzionalmente caratterizzati curata manualmente. Inserite la sequenza nel campo di immissione e lanciate la ricerca (il risultato dovrebbe essere visibile in pochi minuti). Nella schermata dei risultati viene riportata in forma schematica la sequenza con l'assegnazione dei domini riconosciuti (**Figura 2**).

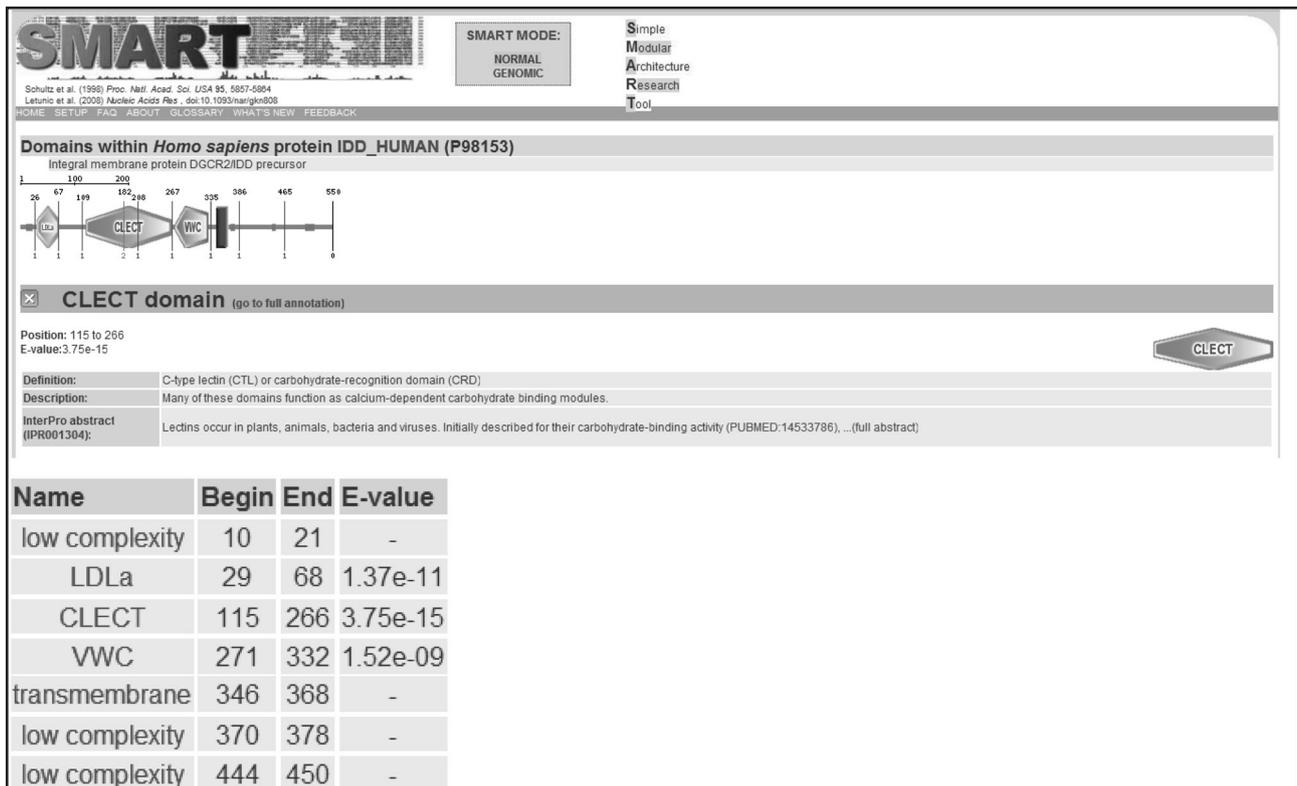


Figura 2 In alto: schermata con i risultati trovati da SMART. Sullo schema della sequenza sonda sono disegnate le icone che rappresentano i domini identificati; ciascuna icona è attivabile attraverso puntatore del mouse per visualizzare informazioni sul dominio relativo. In basso: elenco dei domini trovati lungo la sequenza con l'indicazione del relativo E-value e della posizione all'interno della sonda.

- Attraverso il sito **SUPERFAMILY** (<http://supfam.mrc-lmb.cam.ac.uk/SUPERFAMILY>) si possono effettuare ricerche di sequenza in una banca dati di HMM. Dalla pagina iniziale, attivate il collegamento a Sequence search e inserite nel campo apposito la sequenza. Si può scegliere se avere i risultati in tempo reale oppure attraverso notifica per posta elettronica (selezionare la scelta nella casella notification: browser o e-mail). In quest'ultimo caso è necessario inserire il proprio indirizzo di posta elettronica. Nel messaggio elettronico è contenuto un indirizzo attraverso il quale si può accedere direttamente ai risultati che vengono conservati sul sito per 15 giorni. La **Figura 3** riporta una porzione della schermata dei risultati. Si può verificare come siano stati identificati gli stessi domini che erano stati identificati da SMART.

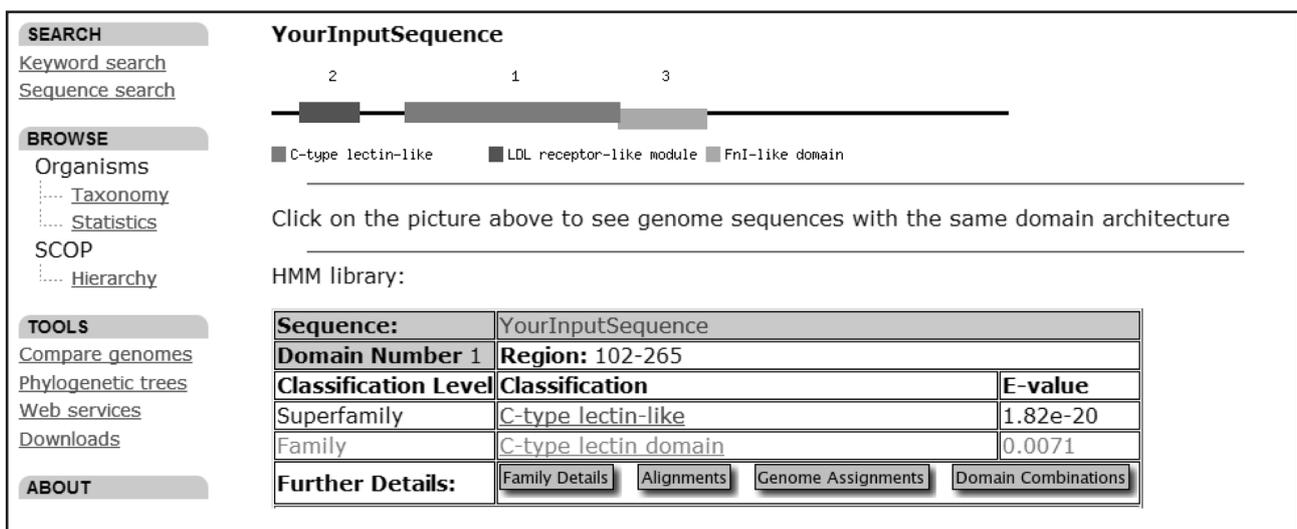


Figura 3 Parte della schermata dei risultati ottenuti con il server SUPERFAMILY. Nella parte superiore è mostrata l'assegnazione dei domini sulla sequenza immessa. Di seguito è riportato l'elenco dei domini con il relativo E-value. I collegamenti attivi consentono di recuperare informazioni strutturali e funzionali sui domini assegnati.

- Un sito che utilizza ricerche con HMM è **HHpred** (<http://toolkit.tuebingen.mpg.de/hhpred>). Questo sito offre la possibilità di cercare omologie remote tra una sequenza sonda e una libreria di HMM di proteine a struttura nota. L'algoritmo su cui è basato il metodo del sito dovrebbe essere considerato più propriamente un sistema di riconoscimento di fold. Nei risultati è riportata la lista dei domini mappati sulla sequenza (**Figura 4**). Scorrendo lo schermo verso il basso, si arriva alla sezione contenente la lista dettagliata dei domini (**Figura 5**) con le relative informazioni statistiche (per esempio E-value). Ancora più in basso sono riportati gli allineamenti di sequenza con la struttura secondaria prevista e osservata.

Figura 4 Finestra di ingresso al server HHpred. Nella parte inferiore dello schermo si può selezionare una o più collezioni di HMM derivate da banche dati strutturali (ovale a sinistra) o limitare la ricerca a proteine appartenenti a un particolare genoma (ovale a destra).



Figura 5 Prima parte della schermata che mostra i risultati della ricerca con HHpred. Sulla sequenza sonda vengono mappati i domini che sono risultati significativamente simili.

Al termine di questa serie di ricerche è possibile avere un quadro sufficientemente dettagliato dell'architettura e della probabile funzione della sequenza. In realtà questo tipo di indagine viene fatta preliminarmente quando la sequenza è inclusa nelle banche dati curate (come Uniprot/Swiss-prot). Le annotazioni della sequenza P98153 recuperata da www.uniprot.org, infatti, contengono l'assegnazione dei domini fin qui trovati e molte altre e dettagliate informazioni.