



UNIVERSIDAD NACIONAL DE COLOMBIA
INSTITUTO DE BIOTECNOLOGÍA

Centro de Bioinformática

ALINEAMIENTO MÚLTIPLE

EMILIANO BARRETO H.
Profesor Asociado D.E



Instituto de Biotecnología
Universidad Nacional de Colombia

ALINEAMIENTO MÚLTIPLE DE SECUENCIAS (AMS)



El alineamiento pareado permite establecer relaciones entre dos secuencias, un AMS puede mostrar como las secuencias de una familia se relacionan unas con otras y en la búsqueda de un ancestro común.

"Los cambios acumulados en una secuencia biológica se producen a una tasa relativamente constante e independiente de parámetros poblacionales

```
chite    ---ADKPKRPLSAYMLWLNSARESIKRENPDFK-VTEVAKKGELWRGLKD
wheat    --DPNPKRAPSAAFFVFMGEFREEFKQKNPKNKSVAAVGKAAGERWKSLS
trybr    KKDSNAPKRAMTSFMFFSSDFRS----KHSDSL-IVEMSKAAGAAWKELG
mouse    -----KPKRPRSAVINIYVSESFQ---EAKDDS-AQGKLKLVNEAWKNLSP
                    ***. ::: .: . . : . . * . *: *

chite    AATAKQNYIRALQEYERNNG-
wheat    ANKLKGEYNKAIAAYNKGESA
trybr    AEKDKERYKREM-----
mouse    AKDDRIRYDNEMKSWEEQMAE
                    * : . * . :
```



Centro de

Bioinformática

Instituto de Biotecnología
Universidad Nacional de Colombia

¿ PARA QUÉ ALINEAR SIMULTÁNEAMENTE VARIAS SECUENCIAS?

- Identificar residuos altamente conservados
 - Probables sitios esenciales para estructura/función
 - Mayor precisión a partir de múltiples secuencias
 - Mejor predicción de estructura/función, alineamientos pareados
- Construir familias de genes /proteínas
 - Usa regiones conservadas para guiar la búsqueda
- Base para análisis filogenético
 - Inferencia de relaciones evolutivas entre genes
- Desarrollo de cebadores y sondas
 - Uso de regiones conservadas para desarrollar
 - Cebadores para PCR
 - Sondas para microarreglos de DNA



CÓMO USAR UN ALINEAMIENTO MÚLTIPLE?

chite	---ADPKRPLSAYMLWLNSARESIKRENPDFK-VTEVAKKGELWRGLKD
wheat	--DPNKPKRAPS AFFVFMGEFREEFKQKNPKNSVAAVGKAAGERWKSLSE
trybr	KKDSNAPKRAMTSFMFFSSDFRS ---KHSDSL -IVEMSKAAGAAWKELG P
unknown	-----KPKRPRSA NYIYVSESFQ -----EAKDDS-AQGKLKL VNEAWKNLSP

***. ::: . : . . : . . * . * : *

chite	AATAKQNYIRALQEYERN GG-
wheat	ANKLGEYNKAIAAYNKGES A
trybr	AEKDKERYKREM-----
unknown	AKDDRIRYDNE MKSWE E QMAE

* : . * . :

Extrapolación

Homología?

Secuencia desconocida

SwissProt



Instituto de Biotecnología
Universidad Nacional de Colombia

CÓMO USAR UN ALINEAMIENTO MÚLTIPLE?

```
chite   ---ADKPKRPLSAYMLWLNSARESIKRENPDFK-VTEVAKKGELWRGLKD
wheat   --DPNPKPKRAPSAFFVFMGEFREEFKQKNPKNSVAAVGKAAGERWKSISE
trybr   KKDSNAPKRAMTSFMFSSDFRS---KHSDSL-IVEMSKAAGAAWKEIGP
mouse   -----KPKRPRSAVINIYVSESFQ---EAKDDS-AQGKLKLVNEAWKNLSP
               ***. ::: .: . . . : . . * . *: *
```

```
chite   AATAKQNYIRALQEYERNNG-
wheat   ANKLKGEYNKAIAAYNKGESA
trybr   AEKDKERYKREM-----
mouse   AKDDRIRYDNEMKSWEEQMAE
*     : . * . :
```

Extrapolación

Patrones Prosite

Apareamiento?

Secuencia desconocida

SwissProt

CÓMO USAR UN ALINEAMIENTO MÚLTIPLE?

chite	---	ADPKRPLSAYMLWLNSARESIKRENPDFK-	VTEVAKKGELW	R	GLKD
wheat	--	DPNKPKRAPS AFFVFMGEFREEFKQKNPKNKS	VAAVGKAAGERW	K	SLSE
trybr	KKDSNAPKRAMTSF	MFSSDFRS	-----	I	HESDL
mouse	-----	KPKRPRSAYNIYVSESFQ	-----	EAKDDS	-I QGKLKLVNEAW

***. ::: . : . . : . . : * . * ; *

chite	AATAKQNYIRALQEYERNGG-
wheat	ANKLKGEYNKAIAAYNKGESA
trybr	AEKDKERYKREM-----
mouse	AKDDRIRYDNE MKSWEEQMAE

* : . * . :

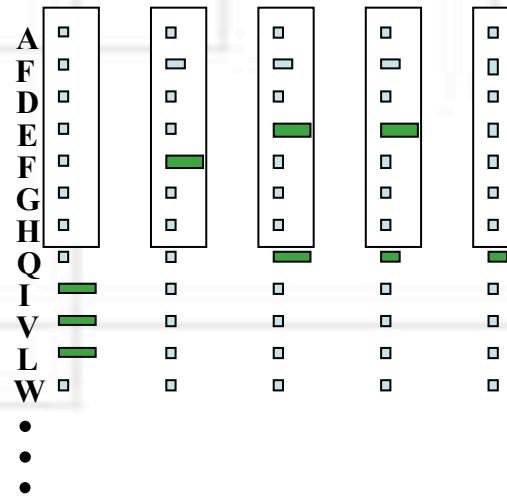
L?

K>R

Extrapolación

Patrones Prosite

Perfiles Prosite



-Mas Sensible

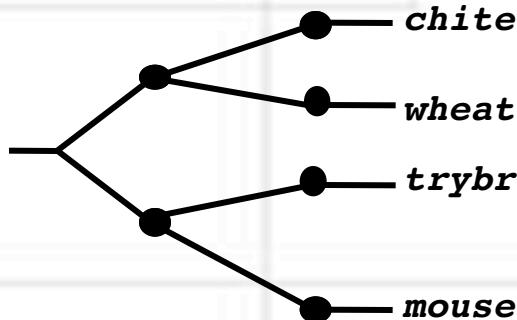
... -Mas Específico

CÓMO USAR UN ALINEAMIENTO MÚLTIPLE?

chite	---	ADKPKRPLSAYMLWLNSARESIKRENPDFK-VTEVAKKGELWRGLKD
wheat	--	DPNKPKRAPS AFFVFMGEFREEFKQKNPKNSVAAVGKAAGERWKS LSE
trybr		KKDSNAPKRAMTSFMFFSSDFRS----KHS DLS-IVEMS KAAGAAW KELGP
mouse	----	KPKRPRSA YNIYVSES FQ---EAK DDS-AQGKLKLVNEAWKNLSP
		***. ::: .: .. . : . . * . *: *

chite	AATAKQNYIRALQEYERN GG-
wheat	ANKLKGEYNKAIAAYNKGES A
trybr	AEKDKERYKREM-----
mouse	AKDDRIRYDNE MKSWEEQMAE
	* : . * . :

Filogenia



-Evolución
-Paralogía/Ortología

CÓMO USAR UN ALINEAMIENTO MÚLTIPLE?

```
chite   ---ADKPKRPLSAYMLWLNSARESIKRENPDFK-VTEVAKKGELWRGLKD
wheat   --DPNPKPKRAPSAFFVFMGEFREEFKQKNPKNSVAAVGKAAGERWKSLS
trybr   KKDSNAPKRAMTSFMFFSSDFRS----KHSDSL-----IVEMSKAAGAAWKE
mouse   -----KPKRPRSAVINIYVSESFQ----EAKDDS-AQGKLKLVNEAWKNLSP
                    ***. ::: .: .. . : . . * . *: *
```

```
chite   AATAKQNYIRALQEYERNGG-
wheat   ANKLKGEYNKAIAAYNKGES
trybr   AEKDKERYKREM-----
mouse   AKDDRIRYDNEMKSWEEQMAE
* : .* . :
```

Filogenia

Predicción Estruc.

PhD Para Predicción de
estructura secundaria:
75% precisión.

Threading: esta mejorando
Pero aún no es tan bueno.



Instituto de Biotecnología
Universidad Nacional de Colombia

CÓMO USAR UN ALINEAMIENTO MÚLTIPLE?

```
chite    ---ADKPKRPLSAYMLWLNSARESIKRENPDFK-VTEVAKKGELWRGLKD
wheat    --DPNKPKRAPS AFFVFMGEFREEFKQKNPKNKSVAAVGKAAGERWKSLS
trybr    KKDSNAPKRAMTS FMFFSSDFRS ---KHSDL -IVEMSKAAGAAWKELG P
mouse    -----KPKRPRRSAYNIYVSESFQ---EAKDDS-AQGKLKLVNEAWKNLSP
               ***. ::: .: . . : . . * . *: *
```

```
chite    AATAKQNYIRALQEYERNGG-
wheat    ANKLKGEYNKAIAYNKGES A
trybr    AEKDKERYKREM-----
mouse    AKDDRIRYDNE MKSWEEQMAE
               * : .* . :
```

Filogenia

Predictión Estruc.

Precaución!

Métodos automáticos de
alineamiento múltiple de secuencias
No son siempre perfectos...



EL PROBLEMA...

- Por qué es difícil computar un alineamiento múltiple?

Biología

Qué es **un buen** alineamiento?

```
chite   ---ADKPKRPLSAYMLWLNSARESIKRENPDFK-VTEVAKKGELWRGILKD
wheat   --DPNKPKRAPSAFFVFMGEFREEFKQKNPKNSVAAVGKAAGERWKSLSE
trybr   KKDSNAPKRAMTSFMFFSSDFRS---KHSDSL-IVEMSKAAGAAWKELGP
mouse   -----KPKRPRSAYNIYVSESFQ---EAKDDS-AQGKLKLVNEAWKNLSP
          ***. ::: .: .. . : . . * . *: *
```

Computación

Cual es **el** buen alineamiento?

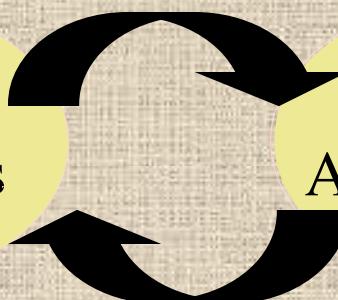
EL PROBLEMA...

- Por qué es difícil computar un alineamiento múltiple?

PROBLEMA CIRCULAR....

Buenas
secuencias

Buen
Alineamiento



Instituto de Biotecnología
Universidad Nacional de Colombia

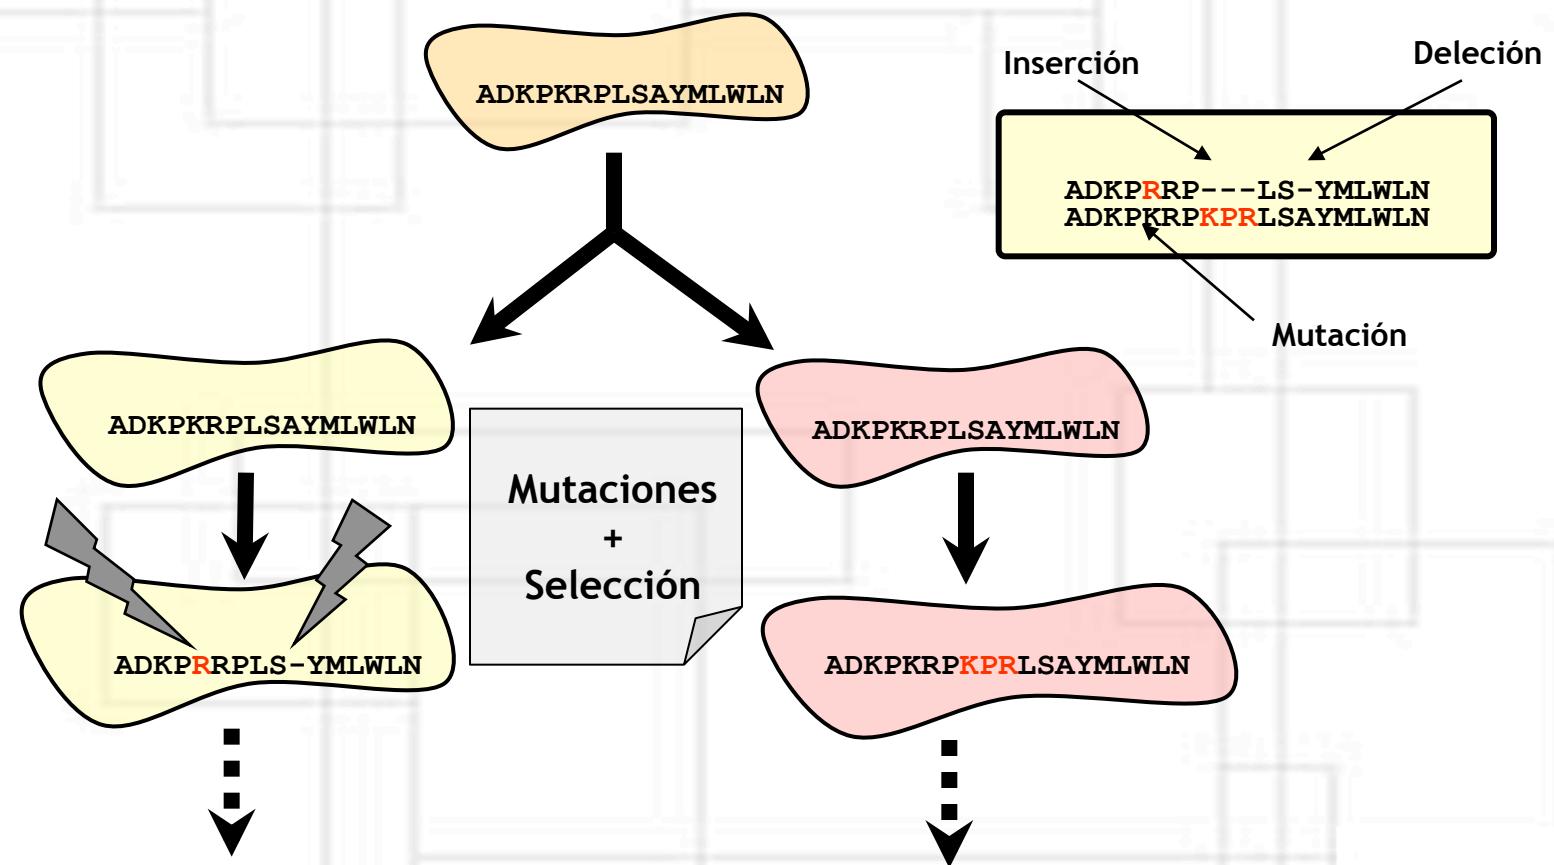
Qué se necesita conocer para hacer un buen alineamiento ?

- Cómo evolucionaron las secuencias?
- Cómo alinea las secuencias el computador?
- Cómo escoger las secuencias?
- Cual es el mejor programa?
- Cómo usar el alineamiento?



Instituto de Biotecnología
Universidad Nacional de Colombia

UN ALINEAMIENTO ES UNA HISTORIA

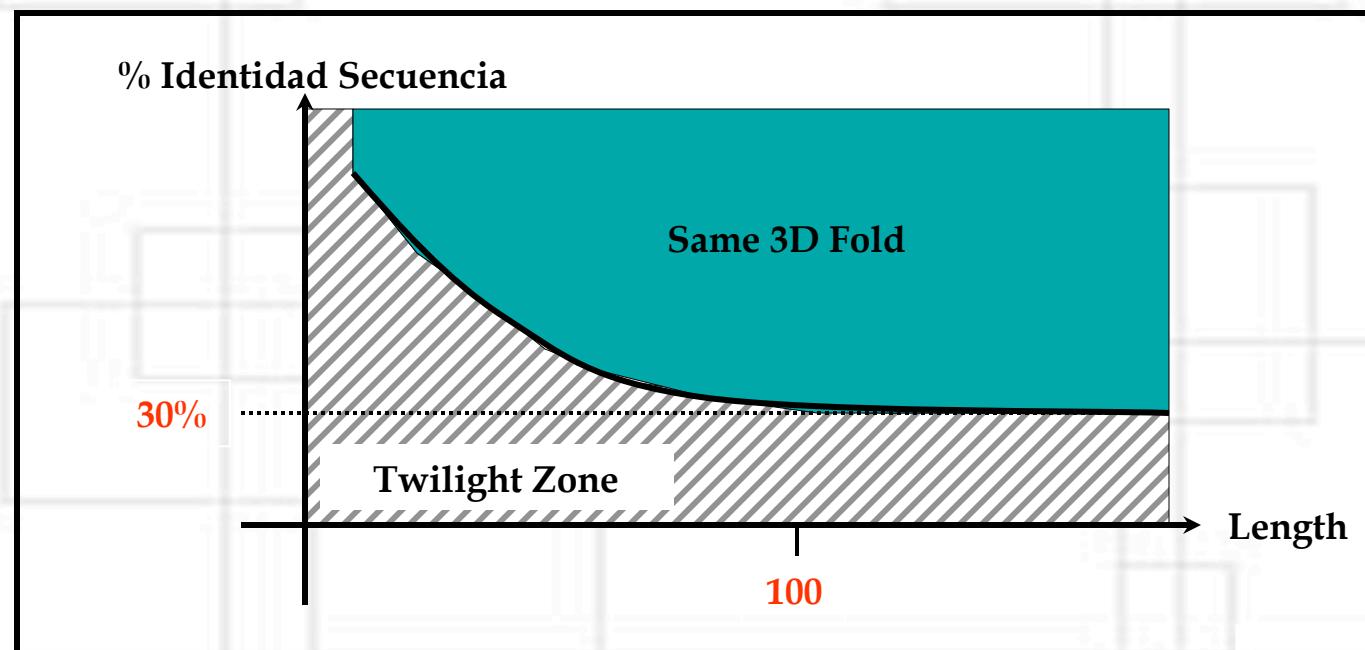


Centro de
Bioinformática

Instituto de Biotecnología
Universidad Nacional de Colombia

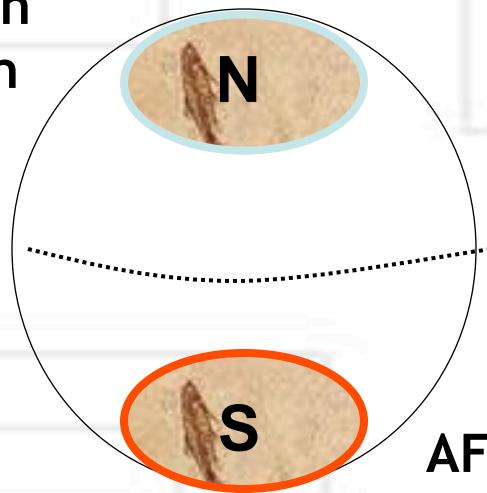
HOMOLOGÍA

- Secuencias Iguales -> Igual origen? -> Igual función? -> Igual plegamiento 3D?



Evolución Convergente

AFGP con (ThrAlaAla) n
Similar a Trypsinogen

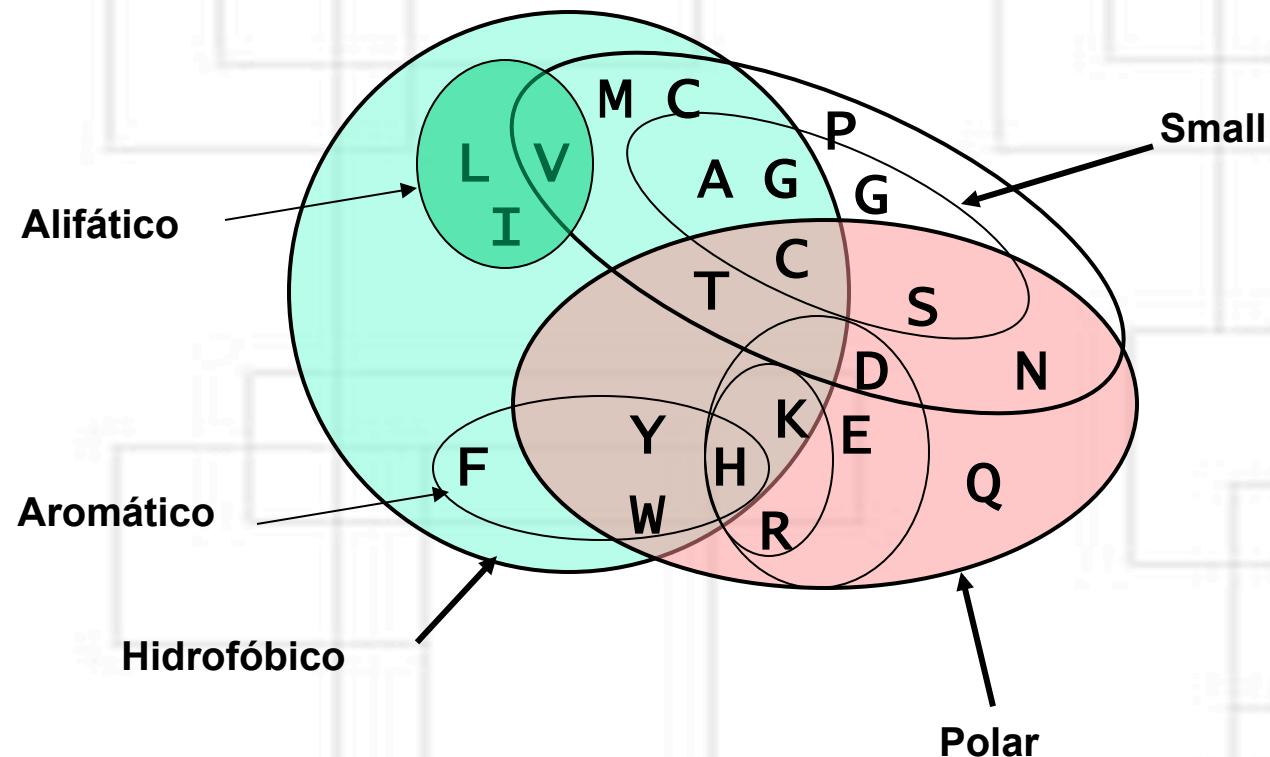


chen et al, 97, PNAS, 94, 3811-16

AFGP con (ThrAlaAla) n
NO
Similar a Trypsinogen

RESIDUOS Y MUTACIONES

- Todos los residuos son iguales, pero algunos mas que otros...



Centro de
Bioinformática

Instituto de Biotecnología
Universidad Nacional de Colombia

CÚAL ES LA MEJOR MATRIZ DE SUSTITUCIÓN?

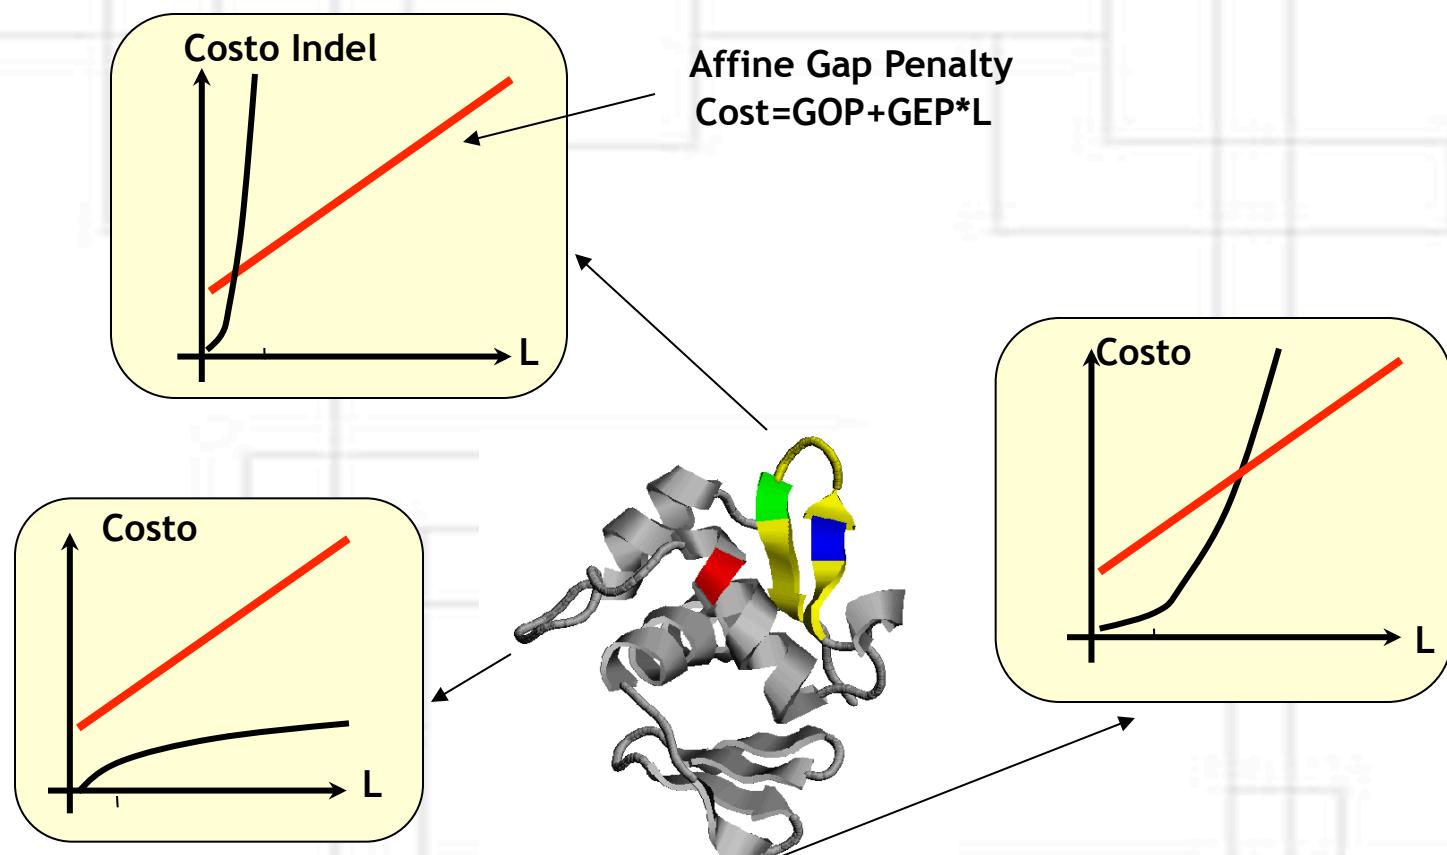
- Las tasas de mutación dependen de la familia proteíca

FAMILIA	S	N
Insulin	4.0	0.1
Interleukin I	4.6	1.4
α -Globin	5.1	0.6
Apolipoprot. AI	4.5	1.6
Interferon G	8.6	2.8
Histone3	6.4	0

Tasas en Substituciones/sitio/Billones de años para Ratón Vs Humano (0.08 Billones años)

- Escoger la matriz Correcta puede ser difícil
 - Gonnet250 > BLOSUM62 > PAM250
 - Depende de la familia, el programa usado y su configuración

INSERCIONES Y DELECCIONES?



CÓMO ALINEAR MUCHAS SECUENCIAS?

- Algoritmos exactos consumen mucho tiempo de cómputo
 - Needlemann & Wunsch
 - Smith & Waterman

2 Globinas => 1 segundo



Instituto de Biotecnología
Universidad Nacional de Colombia

3 Globinas => 2 mn



4 Globinas => 5 horas



5 Globinas => 3 semanas



6 Globinas => 9 años



7 Globinas => 1000 años



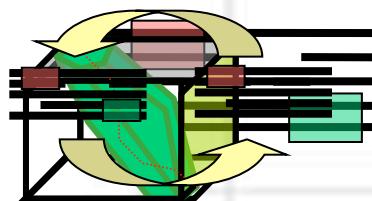
8 Globinas => 150 000 años

HEMO-WHAT?

-> Se requiere un heurístico!

MÉTODOS EXISTENTES

2-Basado en segmentos:



- HMMs, HMMER, SAM.
- MSA, DCA.
- Lento, Aligned MACAW
- Pocas secuencias cercanamente relacionadas
- Pueden Alinear pocos Residuos
- Crea largos perfiles

4-Progresivo:

- ClustalW, MUSCLE, t_Coffe, Pileup, Multalign...
- rápido y sensible



Instituto de Biotecnología
Universidad Nacional de Colombia

AMS global- Alineamiento Global Progresivo

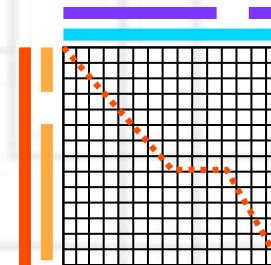
- Motivo:
 - Reducir el costo de construir un alineamiento global incrementalmente
- Método:
 1. Computar la distancia entre todos los pares de secuencias
 2. Construir un arbol guia simple reflejando las distancias entre secuencias
 - Usar UPGMA (PILEUP) o Neighbor-joining (CLUSTALW)
 3. Alinear secuencias siguiendo árbol guía, comenzando en las hojas
 - Alinear las secuencias consenso o perfiles
 - Usar algoritmos de alineamiento pareado heurísticos u óptimos
 - Tendrás que colocar gaps entre regiones conservadas



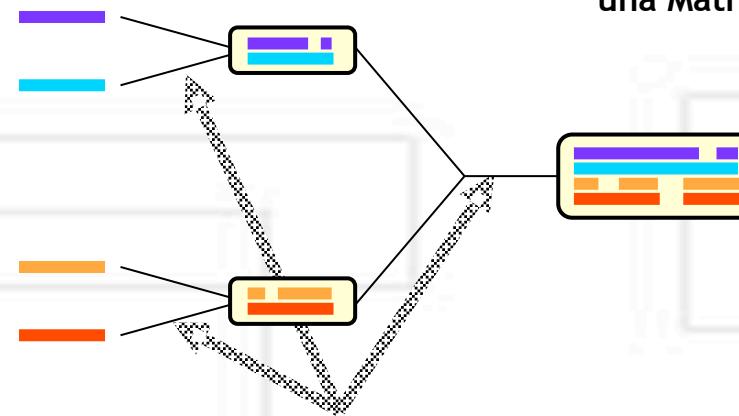
Feng y Dolittle, 1980; Taylor 1981

AMS global- Alineamiento Global Progresivo

- Depende de las secuencias **ESCOGIDAS**
- Depende del **ORDEN** de las secuencias (Arbol).
- Depende de los **PARAMETROS**
 - Matriz de Substitución.
 - Penalización (Gap, Gep).
 - Peso Secuencia.
 - Algoritmo construcción arbol.



Programación Dinámica Usando una Matriz de Substitución



•Problemas:

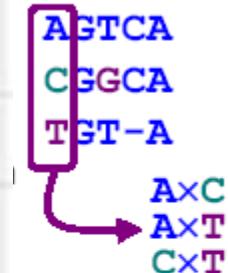
- Aproximación dependiente de alineamientos pareados iniciales
- No puede fijar errores iniciales (gaps no pueden ser removidos)

“once a gap, always a gap”

Feng y Dolittle, 1980; Taylor 1981

PUNTUACIÓN DEL ALINEAMIENTO MÚLTIPLE DE SECUENCIAS

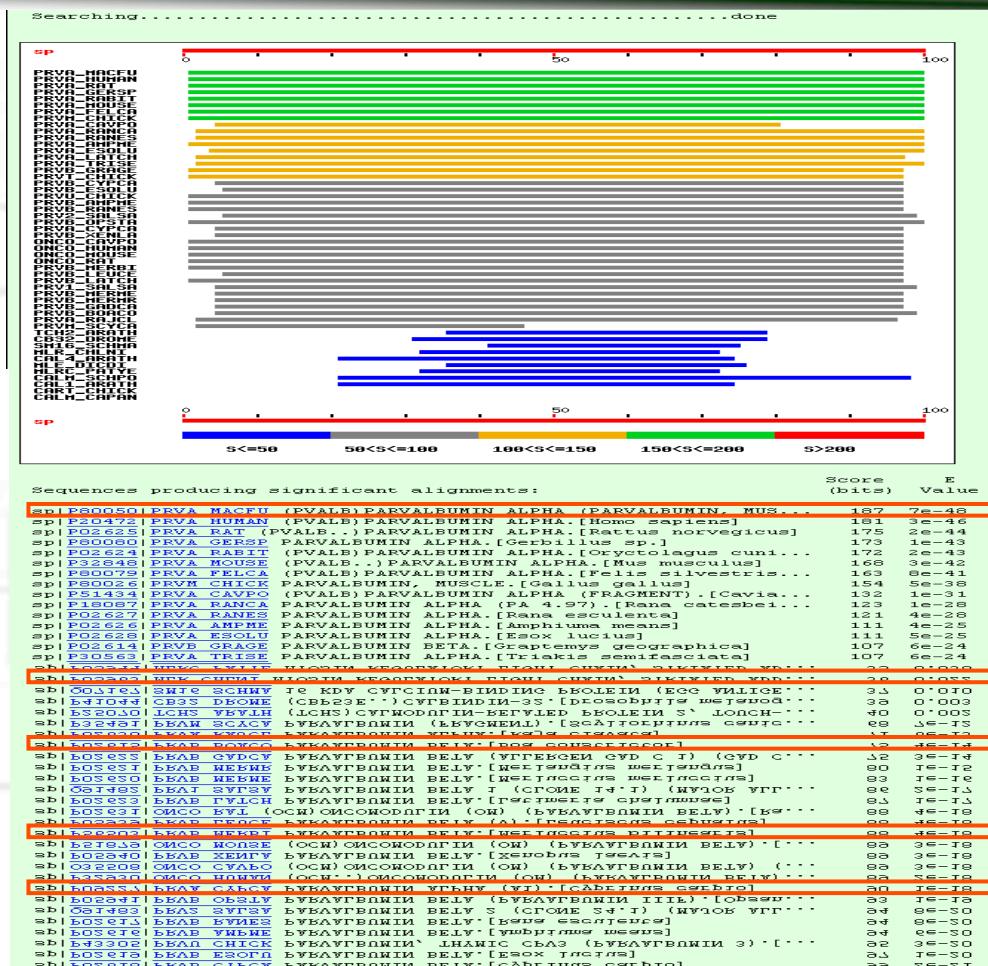
- Suma de pares (SP):
 - Secuencias Alineadas en columnas
 - Dar puntaje a todas las combinaciones pareadas en la columna
 - Requiere $\frac{N \times (N-1)}{2}$ comparaciones para N secuencias
 - Puntaje total = Σ puntaje de cada columna
- Condiciones:
 - Asume que cada secuencia desciende de N-1 secuencias
 - No hay justificación probabilistica para el puntaje SP
 - Penalización relativa para malos apareamientos disminuye, para mas apareamientos debe aumentar
 - Ejemplo: T mal apareada



$A \times A = 4$	A	A	A	A	A	A	A
	A	A	A	A	A	A	A
	12	4	24	12	40	24	

$A \times T = 0$	A	T	A	T	A	T	
	A	C	A	C	A	C	
	Δ=67%	Δ=50%	Δ=40%	Δ=40%			

SELECCIÓN DE SECUENCIAS A PARTIR DE UNA SALIDA BLAST



Instituto de Biotecnología
Universidad Nacional de Colombia

UN ERROR FRECUENTE...

- Secuencias cercanamente relacionadas

PRVA_MACFU	SMTDLLNAEDIKKAVGAFSAIDSFDHKFFQMVGLKKKSADDVKKVFHILDKDKGFI EE
PRVA_HUMAN	SMTDLLNAEDIKKAVGAFSATDSFDHKFFQMVGLKKKSADDVKKVFHMLDKDGFI EE
PRVA_GERSP	SMTDLLSAEDIKKAAIGAFAAAADSFDHKFFQMVGLKKKTPDDVKKVFHILDKDKGFI EE
PRVA_MOUSE	SMTDVLSAEDIKKAAIGAFAAAADSFDHKFFQMVGLKKKNPDEVKKVFHILDKDKGFI EE
PRVA_RAT	SMTDLLSAEDIKKAAIGAFATAADSFDHKFFQMVGLKKKSADDVKKVFHILDKDKGFI EE
PRVA_RABIT	AMTELLNAEDIKKAAIGAFAAAESFDHKFFQMVGLKKSTEDVKKVFHILDKDKGFI EE :***: * . ***** : ***: * ; ***** : ***** . . : ***** : *****
PRVA_MACFU	DELGFILKGSPDARDLSAKETKTLMAAGDKDGDKIGVDEFSTLVAES
PRVA_HUMAN	DELGFILKGSPDARDLSAKETKMLMAAGDKDGDKIGVDEFSTLVAES
PRVA_GERSP	DELGFILKGSSDARDLSAKETKTLLAAGDKDGDKIGVEEFSTLVSE S
PRVA_MOUSE	DELGSILKGSSDARDLSAKETKTLLAAGDKDGDKIGVEEFSTLVAES
PRVA_RAT	DELGSILKGSSDARDLSAKETKTLMAAGDKDGDKIGVEEFSTLVAES
PRVA_RABIT	EELGFILKGSPDARDLSVKETKTLMAAGDKDGDKIGADEFSTLVSE S :*** ***** . ***** . *** * ; ***** . ; ***** ; **

- Secuencias Idénticas no ofrecen información
- Alineamientos Múltiple de secuencias son valiosos por la diversidad de secuencias



Centro de
Bioinformática

Instituto de Biotecnología
Universidad Nacional de Colombia

SELECCIÓN DE SECUENCIAS DIVERSAS

PRVA_MACFU
PRVA_HUMAN
PRVA_GERSP
PRVA_MOUSE
PRVA_RAT
PRVA_RABIT
TPCC_MOUSE

-----	SMTDLLN---AEDIKKA
-----	SMTDLLN---AEDIKKA
-----	SMTDLLS---AEDIKKA
-----	SMTDVLS---AEDIKKA
-----	SMTDLLS---AEDIKKA
-----	AMTELLN---AEDIKKA
MDDIYKAAVEQLTEEQNEFKAADFIDIFVLGAEDGCISTKELGKVMRMLGQNPTPEELQEM	
	: :*. .*::::

PRVA_MACFU
PRVA_HUMAN
PRVA_GERSP
PRVA_MOUSE
PRVA_RAT
PRVA_RABIT
TPCC_MOUSE

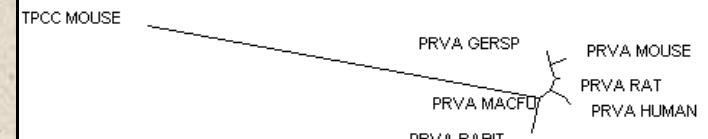
VGAFAIDS--FDHKFFQMVG	LKKKSADDVKKVFHILDKDKGFIIEDELGFI
VGAFSATDS--FDHKFFQMVG	LKKKSADDVKKVFHMLDKDKSGFIIEDELGFI
IGAFAAADS--FDHKFFQMVG	LKKKTPDDVKKVFHILDKDKGFIIEDELGFI
IGAFAAADS--FDHKFFQMVG	LKKKNPDEVKKVFHILDKDKGFIIEDELGSI
IGAFTAADS--FDHKFFQMVG	LKKKSADDVKKVFHILDKDKGFIIEDELGSI
IGAFAAAES--FDHKFFQMVG	LKKKSTEDVKKVFHILDKDKGFIIEEELGFI
IDEVDEDGSGTVDFDEFLVMMVRCKDDSKGKSEEELSDFRMFDKNADGYIDLDELKMM	
: . * . *.*: *: *: * . * . : : : : * : : * : * . * . * .	

PRVA_MACFU
PRVA_HUMAN
PRVA_GERSP
PRVA_MOUSE
PRVA_RAT
PRVA_RABIT
TPCC_MOUSE

LKGFPSPDARDLSAKETKTLMAAGDKDGDKIGVDEFSTLVAES-	
LKGFPSPDARDLSAKETKMLMAAGDKDGDKIGVDEFSTLVAES-	
LKGFSSDARDLSAKETKTLLAAGDKDGDKIGVEEFSTLVSSES-	
LKGFSSDARDLSAKETKTLLAAGDKDGDKIGVEEFSTLVAES-	
LKGFSSDARDLSAKETKTLMAAGDKDGDKIGVEEFSTLVAES-	
LKGFPSPDARDLSVKETKTLMAAGDKDGDKIGADEFSTLVSSES-	
LQ---ATGETITEDDIEELMKDGDKNNDRIDYDEFLEFMKGVE	
*: . . : : . : *: ***; . **; * . :** : :	

-Este alineamiento no es informativo acerca de la relación entre TPCC MOUSE y las otras secuencias.

-Una mejor extensión de las secuencias es necesaria



0.1

SELECCIÓN DE SECUENCIAS DIVERSAS

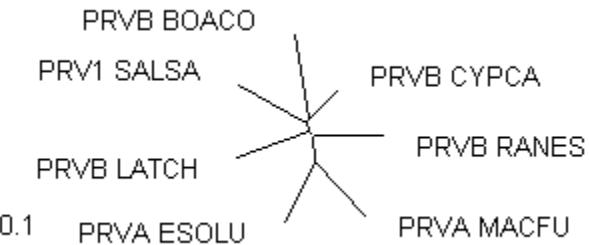
PRVB_CYPCA
PRVB_BOACO
PRV1_SALSA
PRVB_LATCH
PRVB_RANES
PRVA_MACFU
PRVA_ESOLU

-AFAGVLNDADIAAALEACKAADSFNHKAFFAKVGLTSKSADDVKKAFAIIDQDKSGFIE
-AFAGILSDADIAAGLQSCQAADSFSCKTFFAKSGLHSKSKDQLTKVFGVIDRDKSGYIE
MACAHLCKEADIKTALEACKAADTFSFKTFFHTIGFASKSADDVKKAFKVIDQDASGFIE
-AVAKLLAAADVTAALELEGCKADDSFNHKVFFQKTGLAKKSNEELEAIFKILDQDKSGFIE
-SITDIVSEKDIDALESVKAAGSFNYKIFFQKVGLAGKSAADAKKVFIELDRDKSGFIE
-SMTDLLNAEDIKKAVGAFSAIDSFDHKFFQMVGVLKKKSADDVKVFHILDQDKSGFIE
--AKDLLKADDIKKALDAVKAEGSFNHHKFALVGLKAMSANDVKVFKAIDADASGFIE
: * . : . * . * : * * * * : * : * . * * * * : **

PRVB_CYPCA
PRVB_BOACO
PRV1_SALSA
PRVB_LATCH
PRVB_RANES
PRVA_MACFU
PRVA_ESOLU

EDELKLFLQNFKADARALTDGETKTFLKAGDSDGDGKIGVDEFTALVKA-
EDELKKFLQNFDGKARDLTDKETAFLKEGDTDGDGKIGVEEFVVLTKG
VEELKLFLQNFCPKARELTDAAETKAFLKAGDADGDGMIGIDEFAVLVKQ-
DEEELFLQNFSAGARTLTKTETETFLKAGDSDGDGKIGVDEFQKLVKA-
QDELGLFLQNFRASARVLSAETSAFLKAGDSDGDGKIGVEEFQALVKA-
EDELGFILKGFSPDARDLSAKETKTLMAAGDKDGDKIGVDEFSTLVAES
EEELKFVLKSFAADGRDLTDAETKAFLKAADKDGDGKIGIDEFETLVHEA
: ** . * : * . * * : ** : : . * * * * * : ; ** * *

- Un modelo razonable existe ahora...
- Ir más allá : homólogos remotos.



ALINEAMIENTO DE HOMOLOGOS REMOTOS

PRVA_MACFU	-----	SMTDLLNA----EDIKKA
PRVA_ESOLU	-----	AKDLLKA----DDIKKA
PRVB_CYPCA	-----	AFAGVLND----ADIAAA
PRVB_BOACO	-----	AFAGILSD----ADIAAG
PRV1_SALSA	-----	MACAHLCKE----ADIKTA
PRVB_LATCH	-----	AVAKLLAA----ADVTAA
PRVB_RANES	-----	SITDIVSE----KDIDAA
TPCS_RABIT	-TDQQAEARSYLSEEMIAEFKAADFMDADGG-GDISVKELGTVMRMLGQTPTKEELDAI	
TPCS_PIG	-TDQQAEARSYLSEEMIAEFKAADFMDADGG-GDISVKELGTVMRMLGQTPTKEELDAI	
TPCC_MOUSE	MDDIYKAAVEQLTEEQKNEFKAAFDIRVLAEDGCISTKELGKVMRMLGQNPTPEELQEM	
		: : :
PRVA_MACFU	VGAFSAIDS--FDHKKFFQMVG-----LKKKSADDVKKV	FHILDKDKGFIIEDEI
PRVA_ESOLU	LDAVKAEGS--FNHKKFFALVG-----LKAMSANDVKKV	FAKAIDADASGFIEEEEI
PRVB_CYPCA	LEACKAADS--FNHKAFFAKVG-----LTSKSADDVKKFAAI	IDQDKSGFIEEDEI
PRVB_BOACO	LQSCQAADS--FSCKTFFAKSG-----LHSKSKDQLTKV	FGVIDRDKSGYIEEDEI
PRV1_SALSA	LEACKAADT--FSFKTFFHTIG-----FASKSADDVKA	FKVIDQDASGFIEVEEI
PRVB_LATCH	LEGCKADDS--FNHKVFFQKTG-----LAKKSNEELEAIF	KILDQDKSGFIEDEEIE
PRVB_RANES	LESVKAAGS--FNYKIFFQKVG-----LAGKSAADAKV	FEILD RDKGFIEQDEL
TPCS_RABIT	IEEVDEDGSGTIDFEEFLVMMVRQMKEAKGKSEEELAEC	FRIFDRNADGYIDAEEIAE
TPCS_PIG	IEEVDEDGSGTIDFEEFLVMMVRQMKEAKGKSEEELAEC	FRIFDRNMDGYIDAEEIAE
TPCC_MOUSE	IDEVDEDGSGTVDFDEFLVMMVRCKDDSKKGKSEEELS	DI
		*
PRVA_MACFU	LKGFSPDARDLSAKETKTLMAAGDKDGDKIGVDEF	STLVAES-
PRVA_ESOLU	LKSFAADGRDLTDAETKAFLKAADKDGDGKIGIDEF	FTLVHEA-
PRVB_CYPCA	LQNFKADARALTGETKFLKAGDSDGDGKIGVDEF	ITALVKA--
PRVB_BOACO	LQNFDGKARDLTDKETAEFLKEGDTDGDGKIGVEEF	VVLVTKG-
PRV1_SALSA	LQNFCPKARELTDAAETKAFLKAGDADGDGMIGIDE	FAVLVQ--
PRVB_LATCH	LQNFSAGARTLTKTETETFLKAGDSDGDGKIGVDEF	OKLVKA--
PRVB_RANES	LQNFRASARVLSDAETSFLKAGDSDGDGKIGVEEF	QALVKA--
TPCS_RABIT	FR---ASGEHVTDEEIESLMKDGDKNNDGRIDFDEF	I
TPCS_PIG	FR---ASGEHVTDEEIESIMKDGDKNNDGRIDFDEF	I
TPCC_MOUSE	LQ---ATGETITEDIELMKDGDKNNDGRIDYDEF	E
		FMKGVE
		..

IR MAS ALLÁ...

General information about the entry

Entry name **TPC_PATYE**

Primary accession number **P35622**

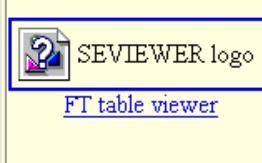
Comments

- FUNCTION:** TROPONIN IS THE CENTRAL REGULATORY PROTEIN OF STRIATED MUSCLE CONTRACTION. TN CONSISTS OF THREE COMPONENTS: TN-I WHICH IS THE INHIBITOR OF ACTOMYOSIN ATPASE, TN-T WHICH CONTAINS THE BINDING SITE FOR TROPOMYOSIN AND TN-C. THE BINDING OF CALCIUM TO TN-C ABOLISHES THE INHIBITORY ACTION OF TN ON ACTIN FILAMENTS.
- MISCELLANEOUS:** THIS PROTEIN Binds ONE CALCIUM ION PER MOLECULE.
- SIMILARITY:** TO OTHER EF-HAND CALCIUM BINDING PROTEINS.

Features

MOD_RES	1	1
DOMAIN	22	33
DOMAIN	58	69
DOMAIN	95	106
CA_BIND	131	142

ACETYLATION.
ANCESTRAL CALCIUM SITE 1.
ANCESTRAL CALCIUM SITE 2.
ANCESTRAL CALCIUM SITE 3.
SITE 4.



PRVI_SALSA	LQNFCPRAKELTDAETKAF	AGDAD	GDGMIGIDEFAVLVKQ	---
TPCS_RABBIT	FR---ASGEHVTDEEIESL	MKGDKNNDRIDF	DEFLKMMEGVQ	-
TPCS_PIG	FR---ASGEHVTDEEIESIM	KDGDKNNDRIDF	DEFLKMMEGVQ	-
TPCC_MOUSE	LQ---ATGETITEDDIEELM	KDGDKNNDRIDY	DEFLEFMKGVE	-
TPC_PATYE	LS---SLGDELTEEEIENMIA	EATDTDGGSGTV	DYEEFKCLMSSDA	
	:	.	:	
			*	
			...	
			*	
			..	
			:**	
			:	

--LKKKSADDVKKVFHLDKDKSGFIEEDELGFI
--LHSKSKDQLTKVFGVIDRDKSGYIEEDELKKF
--FASKSADDVKKAKFKVIDQDASGFIEVEELKLF
EDAKGKSEEELAECFRIFDRNADGYIDAEEELAEI
EDAKGKSEEELAECFRIFDRNMDGYIDAEEELAEI
DSKGKSEEELSDLFRMFDFKNADGYIDLDELKMM
LKEDLDERELKEAFRVLDKEKKGVIVDVLRWI
. : * : * : . * . : * .

:DGKIGVDEFSTLVAES--
GDGKIGVVEEFVVLVTKG--



UN BUEN ALINEAMIENTO...

- Las secuencias mas divergentes
- Muy pocos indels
- Bloques sin gaps separados con indels
- Diferentes clases de residuos dentro de un bloque:
 - Completamente conservado
 - Hidrofilicidad y Tamaño conservados
 - Hidrofilicidad o Tamaño conservados
- La ultima evaluación es cuestión de conocimiento y decisión personal

PARA EVITAR ERRORES...



Centro de
Bioinformática

Instituto de Biotecnología
Universidad Nacional de Colombia

CONSERVAR LA PERSPECTIVA BIOLÓGICA

```
chite   ---ADKPKRPLSAYMLWLNSARESIKRENPDFK-VTEVAKKGELWRGLKD  
wheat   --DPNPKRAPS AFFVFMGEFREEFKQKNPKNKSVAAVGKAAGERWKSLS  
trybr   KKDSNAPKRAMTSFMFFSSDFRS---KHSDSL-S-IVEMS KAAGAAWKELG  
mouse   -----KPKRPRRSAYNIYVSES FQ---EAKDD S-AQGKL KLVNEAWKNLSP  
          ***. ::: .: . . . : . . . * . *: *
```

```
chite  AATAKQNYIRALQEYERNGG-  
wheat  ANKLGEYNKAIAAYNKGESA  
trybr  AEKDKERYKREM-----  
mouse  AKDDRIRYDNE MKSWEEQMAE  
      * : .* . :
```

```
chite AD--K---PKR-PLYMLWLNS-ARESIKRENPDFK-VT-EVAKKGELWRGL-  
wheat -DPNK---PKRAP-FFVFMGE-FREEFKQKNPKNKSV-AVGKAAGERWKSLS  
trybr -K--KDSNAPKR-AMT-MFFSSDFR-S-KH-S-DLS-IV-EMS KAAGAAWKELG  
mouse ---K---PKR-PRYNIYVSES FQEA-K--D-D-S-AQGKL-KLVNEAWKNLSP  
      *     *** .: :... : * . . . : * . *: *
```

```
chite KSEWEAKAATAKQNY-I--RALQE-YERNG-G-  
wheat KAPYVAKANKLKGEY-N--KAIAA-YNK-GESA  
trybr RKVYEEMAEKDKERY----K--RE-M-----  
mouse KQAYIQLAKDDRIRYDNE MKSWEEQMAE-----  
      : : * : .* :
```

DIFERENTES
PARAMETROS



Centro de
Bioinformática

Instituto de Biotecnología
Universidad Nacional de Colombia

NO AFINAR!!!

```
chite ---ADKPKRPLSAYMLWLNSARESIKRENPDFK-VTEVAKKGELWRGLKD
wheat --DPNPKPKRAPSAFFVFMGEFREEFKQKNPKNKSVAAVGKAAGERWKSLSSE
trybr KKDSNAPKRAMTSFMFFSSDFRS----KHSDSLs-IVEMSKAAGAAWKELGPs
mouse ----KPKRPRRSAYNIYVSESFQ---EAKDDS-AQGKLKLVNEAWKNLSP
***. : : . : . : . * . * : *
```

```
chite AATAKQNYIRALQEYERNNG-
wheat ANKLKGEYNKAIAAYNKGESA
trybr AEKKDKERYKREM-----
mouse AKDDRIRYDNEMKSWEEQMAE
* : . * . :
```

```
chite ---ADKPKRPL-SAYMLWLNSARESIKRENPDFK-VTEVAKKGELWRGLKD
wheat --DPNPKPKRAP-SAFFVFMGEFREEFKQKNPKNKSVAAVGKAAGERWKSLSSE
trybr KKDSNAPKRAMTSFMFFSSDFRS----KHSDSLs-IVEMSKAAGAAWKELGPs
mouse ----KPKRPR-SAYNIYVSESFQ---EAKDDS-AQGKLKLVNEAWKNLSP
***. * . : . : . : . * . * : *
```

```
chite AATAKQNYIRALQEYERNNG-
wheat ANKLKGEYNKAIAAYNKGESA
trybr AEKKDKERYKREM-----
mouse AKDDRIRYDNEMKSWEEQMAE
* : . * . :
```

No juegue con los parámetros!
Si conoce el alineamiento que desea:
Hagalo usted mismo!



Centro de
Bioinformática

Instituto de Biotecnología
Universidad Nacional de Colombia

MÉTODOS DISPONIBLES

Fuente: BaliBase
Thompson et al, NAR, 1999

PROBLEMA	PROGRAMA	METODO
	ClustalW	
	ClustalW	
	MSA	
	DIALIGN II	
	DIALIGN II	



Centro de
Bioinformática
Instituto de Biotecnología
Universidad Nacional de Colombia

CONCLUSIÓN

- El Mejor Método De Alineamiento:
 - Su cerebro
 - Los datos correctos
- El Mejor Método De evaluación:
 - Sus ojos
 - Información Experimental (SwissProt)
- Que puede concluir?
 - Homología -> extrapolación de información
- Cómo ir más allá?
 - Patrones
 - Perfiles
 - HMMs
 - ...



Centro de
Bioinformática

Instituto de Biotecnología
Universidad Nacional de Colombia