

بسمه تعالیٰ

# بیوانفورماتیک

گروه بیوتکنولوژی دریا

کارشناسی ارشد



## معرفی پایگاه‌های اطلاعاتی اولیه و ابزارهای جستجو در آنها


### مقدمه

ما در دنیا بی‌زندگی می‌کنیم که در آن حدود یک و نیم میلیون موجود زنده شناخته شده است و حدود ده هزار گونه آنها در خشکی‌ها زندگی می‌کنند. البته تعداد کل گونه‌های روی کره زمین ۱۰ تا ۱۰۰ برابر آن تخمین زده می‌شود. برای هر یک از این موجودات می‌توان داده‌های زیادی را جمع‌آوری نمود که شامل داده‌های ژنومی، ژن‌ها، نحوه بیان آنها، ساخت پروتئین‌ها و توالی آنها و مانند آن می‌باشد. از پردازش این داده‌ها، اطلاعات فراوانی به دست می‌آید که خود حجم زیادی دارند. مجموعه این اطلاعات آن هم برای برخی از موجودات موضوع میلیون‌ها رکورد در انواعی از بانک‌های اطلاعاتی است. چگونگی بازیابی این اطلاعات و بهره‌برداری از آنها در آموزش و پژوهش زیست‌فناوری بسیار ارزشمند خواهد بود.




داده پردازی زیستی از اشتراک فعالیت‌های مرتبط با تولید هر گونه اطلاعات زیستی (از جمله پروژه‌های ژنوم)، ایجاد پایگاه‌های اطلاعاتی و ابزارهای مربوط، تولید نرم‌افزارها و ساخت سخت‌افزارهای مورد نیاز حاصل می‌شود. بازیابی اطلاعات حاصل، تجزیه و تحلیل و بالاخره تفسیر آنها نتیجه این فعالیت‌هاست که تاثیر عمیقی در رشد و پیشرفت علوم زیستی و رشته‌های مرتبط داشته است.

در حال حاضر، با تلاش‌های هماهنگ جهانی بیش از ۱۰۰۰ پروژه ژنوم در حال اجرا بوده و بیش از ۱۳۰ پروژه ژنوم خاتمه یافته است. در نتیجه سرعت تولید اطلاعات ژنتیکی به بیش از ۱۰۰۰ جفت باز در ثانیه رسیده است. گفته می‌شود در زمان کنونی حجم اطلاعات در GenBank هر ۱۰ ماه دو برابر می‌شود. به طوری که در سال ۱۹۷۷ میلادی تنها توالی یک ژن (گلوپین خرگوش) را می‌دانستیم. اکنون بیش از ۸۰ میلیون رکورد در این بانک وجود دارد. شمایی از رشد اطلاعات در این بانک در شکل زیر آورده شده است.




Year	Base Pairs	Sequences
1982	680338	606
1983	2274029	2427
1984	3368765	4175
1985	5204420	5700
1986	9615371	9978
1987	15514776	14584
1988	23800000	20579
1989	34762585	28791
1990	49179285	39533
1991	71947426	55627
1992	101008486	78608
1993	157152442	143492
1994	217102462	215273
1995	384939485	555694
1996	651972984	1021211
1997	1160300687	1765847
1998	2008761784	2837897
1999	3841163011	4864570
2000	11101066288	10106023
2001	15849921438	14976310
2002	28507990166	22318883

## رشد بانک ژن



شکل ۱. نمایشی از رشد اطلاعات در بیوانفورماتیک یا داده‌پردازی زیستی.

با کمی تاخیر زمانی، بهره‌برداری از این داده‌ها آغاز شده است. تشخیص مولکولی و زود هنگام بیماری‌ها در انسان، دام و حیوان، شناسایی ژن‌های مفید، طراحی موجوداتی با ویژگی‌های کیفی مورد نظر، اصلاح روش‌های زراعی و دامپروری مثال‌هایی از کاربردهای فعال این اطلاعات هستند. اما پیش‌بینی می‌شود در آینده نزدیک بهره‌برداری از این اطلاعات با مشابه سازی رایانه‌ای سامانه‌های زیستی وسعت بیشتری یابد. هم اکنون کشورهای پیشرفته با پایه‌گذاری رشته‌ای تحت عنوان نویست‌سامانه (System Biology) و تأسیس موسسات پژوهشی مرتبط درصداند تا سال ۲۰۱۵ به این هدف جامه عمل پوشانند. انتظار می‌رود با دسترسی به سامانه‌های زیستی رایانه‌ای بسیاری از طراحی‌های فناوری و بررسی اثربخشی و مخاطرات آنها با هزینه بسیار کمتر و با سرعتی بسیار بیشتر (۴ تا ۵ برابر) انجام شود. به عبارت دیگر، در مقطعی از زمان قرار گرفته‌ایم که سرنوشت زیست فناوری در آن رقم می‌خورد. بدیهی است در این حرکت بسیار پرستاب آشنایی با داده‌پردازی زیستی و پروژه‌های ژنوم مبنای ورود در این عرصه است



شکل ۲. نمایشی از رشد اطلاعات در بیوانفورماتیک.

## پایگاه داده چیست؟

پایگاه داده‌ها یا بانک اطلاعاتی به مجموعه‌ای از داده‌ها با ساختار منظم و سامانمند گفته می‌شود. به عبارت ساده‌تر، پایگاه اطلاعاتی مجموعه‌ای از اطلاعات رکوردهای مرتبط می‌باشد و این اطلاعات طوری تنظیم شده‌اند که توانایی دستیابی به هر یک از قسمت‌های اطلاعات مورد نظر امکان‌پذیر است (تعریف ارائه شده در سایت کتابخانه مک کونیل).

### پایگاه داده‌ها در علوم زیستی

به دلیل افزایش سریع داده‌های زیستی اعم از مقالات، ثبت اختراعات، گزارش‌ها، توالی‌های نوکلئوتیدی یا اسید آمینه‌ای، ساختارهای سه بعدی، بررسی‌های ژل الکتروفورز و... ایجاد پایگاه‌های زیستی ضرورت یافته است. یکی از اولین پایگاه‌ها GenBank بوده است که در سال ۱۹۸۲ م با تنها ۵ توالی شروع شد. این پایگاه هم اکنون میلیون‌ها رکورد در خود دارد.

دستجات مختلفی از پایگاه‌های اطلاعاتی زیستی وجود دارد. از جمله:

- پایگاه‌های اطلاعاتی اولیه شامل توالی‌های DNA و پروتئین،
- پایگاه‌های اطلاعاتی ثانویه شامل اطلاعات استخراج شده از پایگاه‌های اطلاعاتی اولیه،
- پایگاه‌های اطلاعات ژنوم‌ها،
- پایگاه‌های پلی مورفیسم/جهش،
- پایگاه‌های ساختمان‌های سه بعدی،
- پایگاه‌های ساختمان‌های سه بعدی پروتئین‌ها
- پایگاه‌های اطلاعاتی متابولیزم

### پایگاه اطلاعات اولیه داده‌های زیستی

این پایگاه‌ها حاوی اطلاعات توالی‌های DNA و پروتئین است که به طور مستقیم از نتایج آزمایشگاهی حاصل شده‌اند (داده‌های تجربی یا Experimental) و یا از تجزیه و تحلیل رایانه‌ای داده‌های موجود به دست آمده‌اند (داده‌های پیش‌بینی شده یا Predicted). در این نوع پایگاه‌ها مولکول‌های فوق با عالمی یک حرفری شاخص نوکلئوتیدها و اسید‌های آمینه نوشته می‌شوند (جداول زیر).

پایگاه‌های اطلاعات مربوط به کربوهیدرات‌ها و لیپیدها و اطلاعات ساختاری نیز گروهی دیگر از این پایگاه‌ها هستند که در حال توسعه هستند.

جدول کدهای نوکلئوتیدی

Code	Represents	Complement
A	Adenine	T
G	Guanine	C
C	Cytosine	G
T	Thymine	A
Y	Pyrimidine (C or T)	R
R	Purine (A or G)	Y
W	weak (A or T)	W
S	strong (G or C)	S
K	keto (T or G)	M
M	amino (C or A)	K
D	A, G, T (not C)	H
V	A, C, G (not T)	B
H	A, C, T (not G)	D
B	C, G, T (not A)	V
X/N	any base	X/N
-	Gap	-

جدول کد ژنتیکی استاندارد


		Second base							
		T		C		A		G	
F i r s t	T	TTT	Phe (F)	TCT	Ser (S)	TAT	Tyr (Y)	TGT	Cys (C)
	T	TTC	Phe (F)	TCC	Ser (S)	TAC	Tyr (Y)	TGC	Cys (C)
	T	TTA	Leu (L)	TCA	Ser (S)	TAA	STOP	TGA	STOP
	T	TTG	Leu (L)	TCG	Ser (S)	TAG	STOP	TGG	Trp (W)
b a s e	C	CTT	Leu (L)	CCT	Pro (P)	CAT	His (H)	CGT	Arg (R)
	C	CTC	Leu (L)	CCC	Pro (P)	CAC	His (H)	CGC	Arg (R)
	C	CTA	Leu (L)	CCA	Pro (P)	CAA	Gln (Q)	CGA	Arg (R)
	C	CTG	Leu (L)	CCG	Pro (P)	CAG	Gln (Q)	CGG	Arg (R)
b a s e	A	ATT	Ile (I)	ACT	Thr (T)	AAT	Asn (N)	AGT	Ser (S)
	A	ATC	Ile (I)	ACC	Thr (T)	AAC	Asn (N)	AGC	Ser (S)
	A	ATA	Ile (I)	ACA	Thr (T)	AAA	Lys (K)	AGA	Arg (R)
	A	ATG	Met (M) START	ACG	Thr (T)	AAG	Lys (K)	AGG	Arg (R)
G	G	GTT	Val (V)	GCT	Ala (A)	GAT	Asp (D)	GGT	Gly (G)
	G	GTC	Val (V)	GCC	Ala (A)	GAC	Asp (D)	GGC	Gly (G)
	G	GTA	Val (V)	GCA	Ala (A)	GAA	Glu (E)	GGG	Gly (G)
	G	GTG	Val (V)	GCG	Ala (A)	GAG	Glu (E)	GGG	Gly (G)

### پایگاه‌های اطلاعات اولیه توالی DNA

این پایگاه‌ها در یک مسیر کاملاً سازماندهی شده مقادیر قابل توجهی از اطلاعات توالی‌های نوکلئوتیدی که در آزمایشگاه‌های مختلف تولید می‌شود را جمع آوری کرده و ذخیره می‌کنند. هر پایگاه اطلاعاتی قالب خاص خود را داشته و روش جستجو در آن نیز در عین سادگی از اختصاصیت برخوردار است.

در جهان سه پایگاه اصلی برای حفظ، ذخیره و بازیابی اطلاعات نوکلئوتیدی (DNA و RNA) وجود دارد:  
پایگاه GenBank در آمریکای شمالی که توسط مرکز ملی اطلاعات بیوتکنولوژی (NCBI) سرپرستی می‌شود.  
پایگاه EMBL در اروپا که توسط آزمایشگاه زیست‌شناسی مولکولی اروپا (EBI) سرپرستی می‌شود.  
پایگاه DDBJ در آسیا که توسط ژاپن ایجاد شده است.

در حال حاضر، این سه پایگاه در قالب یک معاهده همکاری به طور روزانه داده‌های جدید خود را مبادله می‌کنند.



شكل ۳. نمایشی از سه پایگاه نوکلئوتیدی عمده جهان و ارتباط بین آنها.

البته پایگاه‌های بسیار متنوع دیگری وجود دارند که مشتمل بر اطلاعات نوکلئوتیدی هستند و معمولاً در سه پایگاه فوق نیز وجود دارند.

بانک‌های اطلاعاتی توالی حاوی تعداد زیادی فایل متنی (Text file) بسیار بلند هستند که اطلاعات مختلف مرتبط با توالی را در خود جای داده‌اند. حداقل اطلاعات موجود در یک فایل متنی عبارت است از:

- **Header**: اطلاعات ویژه یک توالی در آن قرار گرفته است;
- **Features**: در این بخش Annotation‌های یک رکورد نمایش داده می‌شود؛
- **Sequence**: توالی را نشان می‌دهد.

داههای بانک‌های اطلاعاتی نوکلئوتیدی خود به چند گروه تقسیم می‌شوند:

- داده‌های mRNA یا cDNA موجود در GenBank، EMBL، DDBJ و ...
- داده‌های DNA ژنومی: HTG، dbGSS و ...
- داده‌ها: dbEST، EST و ...
- سایر داده‌ها: dbSNP، dbSTS، uniSTS و ...

لازم به ذکر است که توالی‌های RNA نیز به صورت DNA ذخیره می‌شوند. در هر دو حالت تنها یک رشته ذخیره می‌شود که رشته مثبت نامیده می‌شود.

توجه: رشته مثبت لزو مأ حاوی توالی Sense نیست

### بانک ژن (GenBank)

NCBI GenBank مشهورترین پایگاه داده‌های توالی نوکلئوتیدی و مستندات مربوط است که به عنوان بخشی از کتابخانه ملی پزشکی (National Library of Medicine) در سال ۱۹۸۲ پایه‌گذاری شد. ابزارهای موجود برای دسترسی به داده‌های این پایگاه عبارتند از: BLAST (1990)، Entrez (1992)، PubMed (1997) و GenBank (1992). به دلیل تسلیم انواع داده‌های ژنومی، رشد اطلاعات در این بانک بسیار سریع بوده است (شکل ۱ و ۲). به طور میانگین، ماهانه ۳ میلیون توالی و ۱۴۰۰ گونه جدید به این بانک اطلاعاتی افزوده می‌گردد به طوری که تقریباً هر ۱۰ ماه حجم اطلاعات آن دو برابر می‌شود. همان طور که در بالا گفته شد، داده‌های این پایگاه با بانک داده‌های DNA ژاپن (DDBJ) و آزمایشگاه بیولوژی مولکولی اروپا (EMBL) در حال تبادل بوده و هر سه پایگاه اطلاعات خود را روزانه رد و بدل می‌کنند.

توجه: GenBank حاوی داده‌های تکراری و اضافی (مانند توالی‌های وکتوری) است. بخشی از آن به دلیل تسهیل ورود اطلاعات بوده است اما دلیل عدمه آن مجاز نمودن تسلیم توالی‌های مشابه تکراری از سوی آزمایشگاه‌های مختلف بوده است تا بتوان ذخیره‌ای از گوناگونی ژنتیکی (polymorphism) ایجاد نمود.

بخش های عمومی GenBank بر حسب نوع موجود که به بخش های تاکسونومیک مشهورند عبارتند از:

- BCT (Bacterial and Archeal)
- MAM (Mammalian)
- Inv (Invertebrate)
- PHG (Phage)
- PLN (Plant and Fungi)
- PRI (Primate)
- ROD (Rodent)
- SYN (synthetic=cloning vectors)
- VRL (Viral)
- VRT (other vertebrate)

همچنین به دلایل فنی (ماهیت حجم و با کیفیت پایین دادهها) بخشی از اطلاعات خود را در قسمت های اختصاصی GenBank زیر ذخیره می کند:

- PAT (patents)
- EST (Expressed sequence tag)
- STS (sequence tagged site)
- GSS (Genome survey sequence)
- HTG (High throughput genome)
- CON (Contig)

### جزای یک رکورد GenBank

هر رکورد معمولی GenBank از سه قسمت تشکیل شده است:

: اطلاعات ویژه یک توالی در آن قرار گرفته است؛

: در این بخش Annotation های یک رکورد نمایش داده می شود؛

: توالی رکورد را نشان می دهد.

### بخش عنوان یا Header

این بخش از رکورد حاوی اطلاعاتی نظیر نام لوکوس (که گاهی همان شماره دسترسی است)، نوع مولکول، زمان تسلیم اطلاعات، تعریف حاوی نام توالی، شماره دسترسی، شماره نسخه (شماره دسترسی به اضافه یک عدد برای نشان دادن دفعات اصلاح آن رکورد)، منشاء توالی و تاکسونومی موجود منشاء، کلید واژه‌ها، آدرس مقالات مربوط می‌باشد. شماره دسترسی مهمترین جزء این قسمت است زیرا تنها این شماره یگانه بوده و بهترین گزینه برای مراجعه مجدد به این رکورد می‌باشد.

## بخش ویژگی‌ها یا Features

در این بخش اطلاعاتی که در مورد ویژگی‌های توالی است می‌آید. طول توالی، محل توالی کدکننده پروتئین<sup>(۱)</sup> و اگزون‌ها (در صورت وجود)، گوناگونی در توالی (Variation)، توالی پروتئین رمز شده توسط آن توالی نوکلئوتیدی و مانند آنها در این بخش فهرست می‌شوند.


## توالی یا Sequence

با ارائه آماری از انواع نوکلئوتید و پس از کلمه Origin توالی شروع می‌شود. اعداد در سمت چپ توالی موقعیت باز کنار آن در طول توالی را نشان می‌دهد. توالی ممکن است به کوچکی یک اولیگونوکلئوتید (بیش از ۲۰ جفت باز) در قسمت STS تا به بزرگی میلیون‌ها باز (توالی‌های کروموزمهای به دست آمده از پروژه‌های زنوم) باشد.

## جستجوی متنی توالی نوکلئوتیدی

برای جستجوی متنی توالی‌ها مراحل زیر را انجام دهید:

وارد پایگاه NCBI شوید و بخش All Database>Nucleotide (<http://www.ncbi.nlm.nih.gov>) را انتخاب کنید.  
برای مثال واژه Chitinase را در محل جستجو بنویسید و روی دکمه Search کلیک کنید (شکل ۴).



شکل ۴. جستجوی متنی توالی. برای یافتن توالی نوکلئوتیدی ژن chitinase این نام را در بانک Nucleotide جستجو می‌کنیم.

به دلیل زیاد بودن نتایج جستجو می‌توانید نتیجه را برای توالی مورد نظر خود محدود کنید برای این کار به قسمت Advance Search وارد شوید. شما می‌توانید Title chitinase را در قسمت Title وارد کرده و اگر به دنبال توالی این ژن در یک نوع ماهی به نام *Danio rerio* Zebrafish می‌گردید، نام موجود مورد نظر را در قسمت Organism وارد کنید (شکل ۵).

<sup>۱</sup> Coding sequence

Nucleotide

Nucleotide chitinase

Save search Limit Advanced

Display Settings: Summary, 20 per page, Sorted by Default order

Results: 1 to 20 of 28099

Send to: Filter your results:

All (28099)

Bacteria (17667)

INSDC (GenBank) (16226)

mRNA (4520)

RefSeq (11841)

Manage Filters

**Allium sativum chitinase mRNA, 3' end**

- 1,085 bp linear mRNA  
Accession: M94105.1 GI: 166344  
[GenBank](#) [FASTA](#) [Graphics](#)
- 1,007 bp linear mRNA  
Accession: M94106.1 GI: 166342  
[GenBank](#) [FASTA](#) [Graphics](#)

Top Organisms [Tree]

- uncultured bacterium (1338)
- Vibrio cholerae (1317)
- Propionibacterium acnes (533)
- uncultured

### Nucleotide Advanced Search Builder

(chitinase[Title] AND zebrafish[Organism])

[Edit](#)

#### Builder

Title	chitinase	Show index list	
AND	Organism	zebrafish	Show index list
AND	All Fields		Show index list

[Search](#) or [Add to history](#)

شکل ۵. جستجوی پیشرفته در بانک نوکلئوتید.

برای محدود کردن موارد دیگر می‌توانید از AND یا OR یا NOT استفاده کنید. به عنوان مثال اگر بخواهید Chitinase را در موجود جستجو کنید به طوری که اطلاعات آن مربوط به بعد از سال ۲۰۱۲ باشد با استفاده از AND از پنجره مقابل گزینه Zebrafish Modification Date را انتخاب کرده و تایخ مورد نظر (در اینجا ۲۰۱۲) را تایپ کنید و عمل Search را انجام دهید (شکل ۶ و .(۷

### Nucleotide Advanced Search Builder

(((chitinase[Title]) AND ("zebrafish[Organism]")) AND ("2012"[Modification Date] : "3000"[Modification Date]))

**Builder**

- [Edit](#)
- Filter**
- [Gene Name](#)
- [Issue](#)
- [Journal](#)
- [Keyword](#)
- Modification Date**
- [Organism](#)
- [Page Number](#)
- [Primary Accession](#)
- [Primary Organism](#)

**AND**  [Show index list](#)

**AND**  [Show index list](#)

**AND**   to  [Show index list](#)

**AND**  [Show index list](#)

**Search** or [Add to history](#)

شکل ۶. محدود کردن جستجو به موارد دیگر. در این شکل جستجو به توالی هایی که از سال ۲۰۱۲ تاکنون در مورد chitinase در Zebrafish به بانک نوکلئوتیدی NCBI وارد شده، محدود شده است.

The screenshot shows the NCBI Nucleotide search interface. The search query is: (((chitinase[Title]) AND zebrafish[Organism]) AND ("2012"[Modification Date] : "3000"[Modification Date])). The results section displays 7 entries, all related to *Danio rerio chitinase, acidic.3 (chia.3), mRNA*. The first result is a 1,746 bp linear mRNA with accession NM\_213213.1 and GI 47086016. Below the results are links for GenBank, FASTA, Graphics, and Related Sequences. To the right, there are filter options for All (7), Bacteria (0), INSDC (GenBank) (1), mRNA (7), and RefSeq (6). A red arrow points to the 'Results: 7' link.

شکل ۷. نتیجه جستجوی محدود شده.

مشاهده می کنید که از ۲۸۰۹۹ مورد نتیجه جستجو در شکل ۵ به ۷ مورد نتیجه جستجو در شکل ۷ رسیدیم. اگر روی اولین نتیجه جستجو کلیک کنید صفحه مربوط به توالی نوکلئوتیدی مربوطه (شکل ۸) برای شما باز خواهد شد.



شكل ۸ صفحه نمایش یک توالی نوکلئوتیدی.

```
gene    1..1746
       /gene="chia.3"
       /gene_synonym="chioIb; wu:fd61a02; wu:fi13f01; zgc:55406;
zgc:77912"
       /note="chitinase, acidic.3"
       /db_xref="GeneID:406819"
       /db_xref="ZFIN:ZDB-GENE-040426-2891"
CDS     28..1443
       /gene="chia.3"
       /gene_synonym="chioIb; wu:fd61a02; wu:fi13f01; zgc:55406;
```

کدون آغاز


28

1 gaggtacccc agaaaattgg cattagaa**tg** gggagactta cacttatacg aggtttgagc  
61 ttgggtgcct gcctatgcgc cttttccatg gaaatggcc tctacttcac caacttgtcc  
121 caaatatagac ctgaaattgg aaaaatatact cctgcaa**atg** tcgaccctta cttttgcaca  
181 cacccatattc atgcttttc aatcatcaac caaaggaa**atg** agcttgtcac atatgagtgg  
241 aacgatgaaa ctctatacaa ggccctcaat gaactcaaga aaaaaatcc cactcttaag  
301 accctttgg ctgttggagg atgaaatttt gtttcggcac agttctccat catggtgcc  
361 aatccgtcaa accgtaaaac atttattcag tctaccatca aattccgtag aactcatgg  
421 tttgtatggac tggatctggc ctgggaatat cccggagcaa gggagatcc acctgttagac  
481 aaacaagat tcactctgtc gtgcaggaa ctgttgtcag cctatgaggc tgagagaaaa  
541 gccactggca atccctagct tatgtgtacc gctgtgtat cagctggcaa aggactatt  
601 gatgtatggat atgagattgc agagattgcc aagtacttgc aacctatcaa cgtcatgact  
661 tacgacttcc atggcacttg ggagcgttcc acaggacaca acagccctt gtaccaaggc  
721 tcaaaggatg agggagacct gatctacttc aacaccgact atgctatgcg ctactggagg  
781 gacaatggaa cccctgtggaa gaaaactcaga atgggctttc cagcatacgg tcgcactttc

CDS..... 28..1443 c cagcgttgg a cttccaggta ttggacatgc ttcagctgaa  
961 acacaattc agtggattga tgaccagaag gtgcctatg ccacaaaagaa cagcgagtgg  
1021 gttggattt acaccaaggag gaggatgaa acgaaggatcc gttatctgaa agacaagaat  
1081 ttgggtggag cttdcggttg ggcacttgc ctggatgact ttgtcgac gttctgtatg  
1141 caggggaaacc atccctctat ggccccatctt cgcaatcttc tggatattga attgcctcca  
1201 atgccttcaa ctaccactcc taaacctggc caaagcacca caaggccgac cacaaccaca  
1261 actaccacca ctcatgttcc aggaccaggag ttctgtatg ggaaggccaga tggactctat  
1321 gtcaccccta atgaccccaa caaatattac agctgtgtcg gaggtcatac ttctgtggaa  
1381 aaatgtgtcg taggcacccgt gtttgcgtac agctgcacgt gctgtgtttt gccccaaacct  
1441 tagtgtatcat gactcaagaa acattcagaaa aacatttgca aatagtggaa caagacactg  
1501 caaatttctt taaggccaaaa aatgacagc aaccgtttca tatataagaa cattatgtta  
1561 acctacattt atttactaaa ttgttattat gtcttttata catcttggcg acgtttatcc  
1621 tgtaagtgc a agtacccctt tttaaatgc tgacaaaaag ttgttctt gttcggtttt  
1681 ccttgcgtt gaaattaata aactgacatc atggagaggg gaaaaaaaaaaaaaaa  
1741 aaaaaaaaaaaaaaaa

1443

کدون پایان



#### قالب‌های (Formats) نمایش توالی

پس از جستجو، می‌توانید رکورد یا توالی مورد نظر را به اشکال مختلف نمایش دهید. این موضوع هنگامی اهمیت می‌یابد که می‌خواهید تجزیه و تحلیل بیشتر روی توالی به دست آمده با استفاده از نرم‌افزارهای دیگر انجام دهید. اکثر نرم‌افزارها قالب FASTA را می‌پذیرند. در این قالب، سطر اول با علامت < آغاز شده و یک متن حاوی نام توالی به دنبال آن می‌آید. سطرهای بعدی فقط توالی هستند. از گوشه سمت چپ بالای صفحه نمایش توالی می‌توان به فرمت FASTA مربوط به توالی جستجو شده دست پیدا کرد (شکل ۹). و مطابق شکل ۱۰ می‌توان یک توالی را با فرمت FASTA ذخیره کرد.

[Display Settings:](#)  GenBank

### Danio rerio chitinase, acidic.3 (chia.3), mRNA


NCBI Reference Sequence: NM\_213213.1

[FASTA](#) [Graphics](#)

Go to:

LOCUS	NM_213213	1746 bp	mRNA	linear	VRT	24-AUG-2013
DEFINITION	Danio rerio chitinase, acidic.3 (chia.3), mRNA.					
ACCESSION	NM_213213 NM_213498					
VERSION	NM_213213.1 GI:47086016					
KEYWORDS	RefSeq.					

شکل ۹. دستیابی به فرمت FASTA برای توالی جستجو شده در NCBI.



شکل ۱۰. ذخیره توالی جستجو شده به فرمت FASTA (گوشه سمت راست بالای صفحه نمایش توالی در NCBI).

### ساير انواع رکوردهای GenBank

#### ۱- داده های EST: <http://www.ncbi.nlm.nih.gov/dbEST/index>

قسمت برچسب های بیانی توالی ها (Expressed sequence tags) حاوی توالی های کوتاهی است که معمولاً یکبار توالی یابی شده اند و مشتمل بر بخشی از توالی یک ژن هستند. این توالی ها همچنین از آزمایش های نمایش متفاوت (differential display) و RACE به دست می آیند.

#### ۲- داده های GSS: <http://www.ncbi.nlm.nih.gov/dbGSS/index>

در این قسمت توالی های بررسی ژنومی (Genome Survey Sequences) ذخیره می شود. توالی های GSS کوتاه بوده و یکبار توالی یابی شده اند. این توالی ها تصادفی بوده و معمولاً از انتهای های کلون های کاسمیدی و BAC به دست می آیند. توالی های مذکور در ذخیره شده و از طریق قسمت GSS در dbGSS نیز قابل دسترسی است. توالی و شماره دسترسی موجود در دو منبع، مشابه بوده ولی شکل رکورد متفاوتی دارند.

#### ۳- داده های STS: <http://www.ncbi.nlm.nih.gov/dbSTS/index>

قسمت برچسب جایگاه توالی (Sequence tagged sites) حاوی توالی های کوتاه و یگانه در ژنوم است. از این توالی ها برای ایجاد نقشه های ژنتیکی استفاده می شود. این توالی ها از طریق dbSTS قابل دسترسی می باشند.

#### ۴- داده‌های HTG : <http://www.ncbi.nlm.nih.gov/HTG>

این قسمت حاوی توالی‌های ژنومی است که توسط مراکر توالی‌یابی ژنومی در مقیاس وسیع به دست آمده است. این توالی‌ها از فازهای اتمام نیافته (صفر و ۱ و ۲) و اتمام یافته (فاز ۳) هستند. از داده‌های موجود در این قسمت می‌توان برای جستجوی BLAST بر علیه بانک داده‌های HTGs استفاده کرد که توالی آن در هر ماه به GenBank فرستاده می‌شود.

#### ۵- داده‌های dbSNP : <http://www.ncbi.nlm.nih.gov/SNP>

این پایگاه پلی مورفیسم‌های تک نوکلئوتیدی را ذخیره می‌کند. حذف‌ها و تداخل‌های هر توالی، تکرارهای پلی‌مورفیک و تنوع میکروساتلیتی در این پایگاه قرار می‌گیرد.

#### ۶- داده‌های HTC : <http://www.ncbi.nlm.nih.gov/HTC>


در ماه می سال ۲۰۰۰ سه پایگاه اطلاعاتی EMBL، DDBJ و GenBank برای ایجاد یک پایگاه جدید موافقت کردند. در این بخش توالی‌های cDNA قرار دارد که به صورت high throughput تولید شده‌اند و دارای بخش‌های 5'UTR، 3'UTR و یا بخشی از ناحیه رمز شونده (coding sequence) می‌باشند. بعد از اتمام توالی‌یابی HTC‌ها، به بخش عمومی یا تاکسونومیک انتقال می‌یابند. توالی‌های HTC در ورود به بخش تاکسونومیک واژه کلیدی HTC را در ابتدای خود دارند. اما پس از ورود این واژه از ابتدای توالی حذف می‌شود.

#### پایگاه داده RefSeq

مجموعه توالی‌های مرجع استخراج شده از GenBank را گویند که تصحیح شده و غیر تکراری هستند. یعنی برخلاف RefSeq، در پایگاه RefSeq هر رکورد مربوط به یک ژن یا فرم پیرایش شده از یک ژن می‌باشد. در بانک داده‌های GenBank شماره دسترسی هر مولکول با دستوری ویژه تعیین می‌شود که در شکل زیر مشخص شده است.


Partial Accession Number List		
NM_123456	mRNA	
NP_123456	Protein	
NR_123456	RNA	Non-coding transcripts
NG_123456	Genomic	Incomplete genomic region
NT_123456	Genomic	BAC sequence assemblies
NW_123456	Genomic	WGS sequence assemblies
NC_123456	Genomic	Complete genomic molecules
XM_123456	mRNA	Genome Annotation
XR_123456	RNA	Genome Annotation
XP_123456	Protein	Genome Annotation

برای جستجوی مقالات می‌توان از بانک Pubmed، برای جستجوی توالی پروتئینی می‌توان از بانک پروتئین، برای داشتن اطلاعاتی در مورد موجود نظر می‌توان از بانک Taxonomy، برای دستیابی به اطلاعات ژنوم‌ها از بانک ژنوم، برای دسترسی به داده‌های بیان ژن از قسمت GEO یا EST یا Unigene، جستجو در قسمت Gene اطلاعات جالبی در مورد ژن از جمله شکل گرافیکی محدوده ژن، mRNA و پروتئین را نشان خواهد داد و محدوده اگزون‌ها و ایترون‌ها را نشان می‌دهد. شکل ۱۱ نمونه‌ای از این نوع جستجو را نشان می‌دهد.



شکل ۱۱. جستجو در پایگاه Gene.

برای دستیابی به توالی  
ژنومی روی GenBank  
کلیک کنید.



بانک مربوط به  
جهش‌های  
نقاطه‌ای  
SNP

شکل ۱۲. شکل گرافیکی حاصل از نتیجه جستجو در پایگاه Gene.

اگر بعد از جستجوی توالی در پایگاه Gene روی قسمت GenBank (شکل ۱۲) کلیک کنید به توالی ژنومی محدوده‌ای که مشخص شده دست پیدا خواهد کرد. در قسمت feature توالی‌های ژنومی نوکلئوتیدهایی که از اتصال آنها mRNA ایجاد می‌شود، مشخص شده است. به عنوان مثال در شکل ۱۲ قسمت mRNA مشخص می‌کند که از نوکلئوتید ۴۵۱ تا ۴۴۰ آگزون اول و از نوکلئوتید ۵۳۰ تا ۵۶۹ آگزون دوم وجود دارد و بنابراین نوکلئوتیدهایی ۴۴۰ تا ۵۲۹ ایترنون بوده‌اند که در mRNA حذف می‌شوند. همانطور که در شکل ۱۳ مشاهده می‌کنید mRNA از نوکلئوتید ۴۴۰ شروع می‌شود، در حالی که شروع CDS نوکلئوتید ۵۴۵ است و این بدان معناست که از نوکلئوتید ۴۴۰ تا ۵۴۴ رونویسی می‌شوند اما ترجمه نمی‌شوند. به این قسمت 5'UTR یا ناحیه بدون ترجمة سمت 5' گفته می‌شود که می‌توان جایگاه اتصال ریبوزوم (RBS) را به همراه داشته باشد. بر همین اساس محدوده 3'UTR بین نوکلئوتیدهای ۳۰۸۴ تا ۳۳۶۳ است.

```


gene          440..3363
/gene="chia.3"

mRNA         join(440..451,530..569,667..693,894..1098,1229..1285,
                1378..1543,1663..1787,1888..2011,2113..2295,2408..2524,
                2615..2747,2830..3363)
/gene="chia.3"

CDS          join(545..569,667..693,894..1098,1229..1285,1378..1543,
                1663..1787,1888..2011,2113..2295,2408..2524,2615..2747,
                2830..3083)
/gene="chia.3"

```

شکل ۱۳. نحوه نمایش ویژگی (Feature) mRNA و CDS در یک ژن حاوی اگزون و ایترون (توالی ژنومی).




محدوده نمایش توالی‌های ژنومی را می‌توان بر حسب نیاز مطابق شکل بالا تغییر داد تا به توالی‌های اطراف توالی مورد جستجو دست پیدا کرد.

## همردیفی دوگانه

### مقایسه دو توالی

در دهه ۸۰ یک محقق هیچ برنامه رایانه‌ای برای این که بتواند بین تعدادی توالی، توالی‌ای را پیدا کند که بیشترین مشابهت را به توالی موردنظر خود داشته باشد در اختیار نداشت. بنابراین زیده‌ترین دانشمندان آن روزگار نیز مجبور بودند این کار را به صورت دستی انجام دهند. به طور مثال، اگر قرار بود از بین چهار توالی زیر مشابه‌ترین توالی را به توالی خود انتخاب کنند، باید تک تک توالی‌ها را با توالی الگو مقایسه کرده و میزان شباهت‌ها را در هر مقایسه به دست می‌آورند. امروزه به این همردیفی دوگانه (Pairwise Alignment) می‌گویند.

ساده‌ترین راه برای مقایسه کردن دو توالی این است که هر بار دو توالی را در زیر هم قرار دهیم و یک به یک بازها را با هم مقایسه کنیم تا شبیه‌ترین توالی را پیدا کنیم (شکل ۱۴). ولی سوالی که پیش می‌آید این است که چگونه و با چه معیاری دو توالی مشابه‌تر را انتخاب کنیم؟ در این جاست که بحث امتیاز دهی (Scoring) مطرح می‌شود. به عنوان مثال، ساده‌ترین نوع امتیاز دهی این گونه می‌تواند باشد که اگر دو بازی که زیر هم قرار می‌گیرند یکسان باشند، امتیاز ۱ و اگر همسان نباشند، امتیاز صفر داده شود. با این روش می‌توان مشابه‌ترین توالی و درجه شباهت سایر توالی‌ها را با توالی الگو به دست آورد. حال توالی‌های بالا را با توالی الگوی داده شده، با همین روش، همردیفی دوگانه می‌کنیم. در شکل ۱۴ به نظر می‌رسد توالی که امتیاز ۹ گرفته است، همسانی بیشتری با توالی ما دارد.



شکل ۱۴. همردیفی دوگانه و امتیازدهی به روش صفر و یک.

در همردیفی دوگانه مساله این است که دو توالی چقدر به هم شبیه هستند. زمانی که ما برای همسانی از امتیازدهی و عدد استفاده می‌کنیم، در واقع از روش‌های ریاضی برای حل مسئله زیستی استفاده می‌کنیم. از آنجا که در دنیای زیست‌شناسی، پارامترهای دخیل بسیار زیاد و در بسیاری از موارد ناشناخته هستند، بنابراین برای حل مسئله‌های زیستی با استفاده از الگوریتم‌های ریاضی و

رایانه‌ای، همواره با مشکل عدم تطبیق کامل مدل ریاضی با واقعیت زیستی روبرو هستیم. تفاوت راه حل‌ها و الگوریتم‌ها با هم در این است که جواب کدام یک به واقعیت زیستی که مشاهده می‌شود نزدیک‌تر است و آن را بهتر توجیه می‌کند. اما همانطور که در شکل زیر دیده می‌شود، این دو توالی را به طریق دیگری هم می‌توان هم‌ردیف کرد. لذا سوالاتی هنوز باقی است مانند آن که آیا هم‌ردیفی دیگری ممکن است؟ کدام هم‌ردیفی بهتر است؟ هم‌ردیفی یعنی چه؟ کدام هم‌ردیفی گویای اتفاقات زیستی است؟ آیا در هم‌ردیفی‌ها روندهای تکاملی قابل رویابی است؟ تا چه حد؟ و چگونه می‌توان هم‌ردیفی‌ها را در این راستا به کار گرفت؟

اینها سوالات عمیقی است که پایه‌های اساسی داده‌پردازی زیستی را تشکیل می‌دهند. لکن در این قسمت سعی بر آن است که با اصول هم‌ردیفی تا اندازه‌ای آشنا شوید تا بتوان از آن برای جستجوی توالی‌های مشابه و قضاؤت در مورد میزان مشابهت و درک مفهوم خانواده‌های ژنی و پروتئینی استفاده نمود.



### روش Dot Plot

به عنوان راهی برای شناسایی تمامی هم‌ردیفی‌های ممکن محققین، روشی گرافیکی به نام دات پلات (dot plot) به کار بردن‌د. در این روش دو توالی به صورت عمود بر هم روی محور X‌ها و Y‌ها در یک صفحه قرار داده می‌شوند و در هر نقطه‌ای که شیوه هم باشند عدد یک قرار داده می‌شود. اگر دو توالی کاملاً شیوه باشند در نهایت، از اتصال نقاط، یک خط اوریب بدون شکستگی را می‌توان از انتهای بالای سمت چپ صفحه به انتهای پایین سمت راست صفحه رسم کرد. هم‌ردیفی در واقع مشخص کردن رابطه بین نوکلئوتیدهای یک توالی با توالی دیگر است. اگر دو توالی در مثال فوق را به صورت دات پلات در آوریم جدول زیر به دست خواهد آمد. اگر دور بیش از دو عدد ۱ به دنبال هم خط بکشیم، منظره زیر ظاهر خواهد شد. حال بر اساس این خطوط اریب می‌توان کلیه هم‌ردیفی‌های دو گانه را استخراج کرده و به صورت خطی نوشت. اگر در قسمتی از یکی از توالی‌هایی که تحت آنالیز دات‌پلات قرار گرفته است وارونگی قسمتی از توالی اتفاق افتاده باشد، آنگاه خط اریبی در قسمتی از توالی خواهیم داشت که در قطر مقابل این قطر اصلی قرار می‌گیرد.

## روش Dot Plot

	A	A	T	T	G	G	C	C	T	T	G	C
A	1	1	0	0	0	0	0	0	0	0	0	0
A	1	1	0	0	0	0	0	0	0	0	0	0
T	0	0	1	1	0	0	0	0	1	1	0	0
G	0	0	0	0	1	1	0	0	0	0	1	0
G	0	0	0	0	1	1	0	0	0	0	1	0
C	0	0	0	0	0	0	1	1	0	0	0	1
C	0	0	0	0	0	0	1	1	0	0	0	1
C	0	0	0	0	0	0	1	1	0	0	0	1
G	0	0	0	0	1	1	0	0	0	0	1	0
T	0	0	1	1	0	0	0	0	1	1	0	0
G	0	0	0	0	1	1	0	0	0	0	1	0
C	0	0	0	0	0	0	1	1	0	0	0	1


### مقایسه هم رده ای

در مثال های فوق روش امتیاز دهی صفر و یک را می توان یک نوع الگوریتم به حساب آورد که بر اساس آن هم رده ای با بالاترین امتیاز را به عنوان بهترین هم رده ای انتخاب کردیم. ولی در عمل می توان هم رده ای هایی را مثال زد که با وجود امتیاز مساوی یا حتی بالاتر صحیح نبوده و با دانسته های قبلی تطبیق نمی کنند. بنابراین تلاش زیادی برای طراحی و به کارگیری الگوریتم های دقیق تر صورت می گیرد که تا هر چه بیشتر در برگیرنده واقعیات زیستی و اصول حاکم بر حیات باشد.

به طور مثال، در هم رده ای توالی های نوکلئوتیدی می توان بین امتیازات جایگزینی های از نوع جانشینی (Substitution) و انتقال (Transition) تفاوت قائل شد. زیرا با توجه به ساختمنان دو رشتہ ای DNA احتمال جایگزینی بازه های پورینی با هم و بازه های پیریمیدینی با هم بیشتر است. در حالی که الگوریتم قبلی تفاوتی را بین این دو حالت قائل نبود. بنابراین جواب هایی هم که با الگوریتم قبلی به دست آمد کمتر به واقعیت نزدیک است.

این مشکل در توالی های پروتئینی به طور جدی تری مطرح است. در این توالی ها، همه جایگزینی ها اشکال ساختاری و عملکردی زیادی ایجاد نمی کنند. به عبارت دیگر، برخی اسید آمینه ها خواص فیزیکو شیمیایی مشابهی دارند (شکل بعد) و می توانند با حداقل تغییر خواص جایگزین یکدیگر شوند.

نکته دیگر این است که در هم رده‌ی های بالا فرض، برابر بودن طول توالی هاست. در حالی که در تکامل توالی‌ها هم پدیده‌ی اضافه شدن را داریم و هم پدیده حذف اتفاق می‌افتد. بنابراین ممکن است در بسیاری از موارد بخواهیم دو توالی را با هم مقایسه کنیم که دارای طول یکسانی نباشند.



جمع‌بندی این مقدمات نشان می‌دهد می‌توان با کمی نمودن (امتیازدهی) نتایج هم رده‌ی (امتیازدهی) آنها را با هم مقایسه نمود. البته برای کمی نمودن هم رده‌ی‌ها حداقل دو نوع امتیاز دهی را بایستی منظور کرد.

- امتیاز دهی جایگزینی‌ها

- امتیاز دهی حذف و اضافه شدن توالی‌ها

به این ترتیب، امتیاز هر هم رده‌ی جمع جبری کلیه امتیازات جایگزینی‌ها و حذف یا اضافه‌ها خواهد بود.

### امتیازدهی جایگزینی‌ها

با درک این که روش صفر و یک کفايت نمی‌کند و جایگزینی نوکلئوتیدها یا اسید آمینه‌ها با یکدیگر امتیاز منفی یا مثبت مساوی ندارند، متخصصین امر در پی تهیه جداول امتیازدهی جایگزینی‌ها (Substitution Scoring Matrices) بوده‌اند. به طوری که تا حد امکان واقعیت‌های زیستی را منعکس نماید.

برای توالی‌های نوکلئوتیدی کار چندان دشوار نیست زیرا هر گونه جایگزینی منجر به جهش می‌شود که اثر آن در رمزدهی پروتئین‌ها ممکن است مشاهده شود. یعنی در این مولکول‌ها بحث ساختار و عمل چندان مطرح نیست. البته با توجه به ساختمان دو رشته‌ای DNA متخصصین تکامل زیستی بین جانشینی نوکلئوتید پورین و پیرimidین و انتقال از پورین به پیرimidین یا بالعکس تفاوت قائلند. جدول زیر نمونه‌ای از جداول امتیازدهی برای هم‌ردیفی دو توالی نوکلئوتیدی را نشان می‌دهد. در این جدول به طور ساده‌ای کلیه همسانی‌ها امتیاز +5 و برای غیر جفت شدگی امتیاز -4 در نظر گرفته شده است. سایر حروف در صورت وجود انتخاب برای دو نوکلئوتید یا بیشتر در هر موقعیت از توالی کاربرد دارند.

A T G C				B	M	R	S	K	H	N	B	V	W	D	N
A	-2	-2	-2	-2	-2	1	-2	-2	1	-2	-1	-1	-1	-1	-2
T	-2	2	-2	-2	-2	2	-2	1	1	-2	-2	-2	-2	-2	-2
G	-2	-2	2	-2	1	-2	1	-2	1	-2	-1	-2	-1	-2	-2
C	-2	-2	-2	2	1	-2	-2	1	-2	1	-1	-1	-1	-2	-2
B	-2	-2	1	1	-3	-2	-2	-2	-2	-1	-1	-3	-3	-3	-3
M	1	1	-2	-2	-2	-2	-2	-2	-2	-2	-3	-1	-1	-1	-2
R	1	-2	2	-2	-2	-2	-2	-2	-2	-2	-3	-1	-3	-1	-2
S	-2	1	-2	1	-2	-2	-2	-2	-2	-2	-1	-3	-1	-3	-2
K	-2	1	1	-2	-2	-2	-2	-2	-2	-2	-1	-3	-3	-1	-2
H	1	-2	-2	1	-2	-2	-2	-2	-2	-2	-1	-3	-1	-3	-2
N	-2	-2	-2	-2	-2	-2	-2	-2	-2	-2	-2	-2	-2	-2	-2
B	-2	-1	-1	-1	-2	-3	-3	-1	-3	-2	-2	-2	-2	-2	-2
V	-1	-2	-1	-1	-1	-3	-1	-3	-2	-1	-2	-1	-2	-2	-2
W	-2	-1	-2	-1	-2	-3	-1	-3	-1	-2	-2	-3	-2	-2	-2
D	-1	-1	-1	-2	-3	-1	-3	-1	-3	-2	-2	-2	-2	-1	-2
N	-2	-2	-2	-2	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-2

- Simple match/mismatch scoring scheme:

Match	+ 5
Mismatch	- 4

- Assumes each nucleotide occurs 25% of the time

در تهیه جداول امتیازات جایگزینی توالی‌های پروتئینی خواص فیزیکوشیمیایی اسیدهای آمینه و تاثیر جایگزینی آنها در ساختار و عمل پروتئین‌ها مطرح است. در گذشته، پژوهشگران به گروه‌بندی اسیدهای آمینه بر اساس خواص آنها (شکل صفحه قبل) مراجعه کرده و میزان مشابهت را به صورت توصیفی (و نه عددی) بیان می‌کردند. در دو دهه اخیر روش‌های تهیه جداول امتیازدهی جایگزینی، مبتنی بر داده‌های موجود در طبیعت بوده است. با فرض بر این که اگر دو اسید آمینه دارای خواص فیزیکوشیمیایی مشابهی هستند باستی در طول تکامل جایگزینی آنها تحمل شده باشد، پژوهشگران نسبت به جمع‌آوری توالی‌ها، هم‌ردیفی آنها با هم و محاسبه فراوانی جایگزینی‌ها در بین پروتئین‌های همان‌نوع اقدام نمودند.

در اولین تلاش، هم‌ردیفی ۱۵۷۲ توالی پروتئینی در ۳۴ خانواده پروتئینی انجام و گروه‌بندی شد. سپس فراوانی جایگزینی یک اسید آمینه با اسید آمینه دیگر در فرمول زیر به کار گرفته شد:

$$\text{PAM}_n = \text{nlog Probability of one substitution/Probability of occurring by chance} * 100$$

در این فرمول یک واحد PAM (Point Accepted Mutation) معادل یک تغییر در یک توالی صفتایی از اسیدآمینه‌هاست. داده‌های حاصل در جدول PAM ثبت می‌شود. از آنجا که در طول تکامل ممکن است اسیدآمینه در یک موقعیت چندین بار جایگزین شود، جدول حاصل را چندین بار در خود ضرب می‌کنند. به طور مثال، برای تهیه جدول PAM100 ان را ۱۰۰ بار در خودش ضرب می‌کنند (جدول زیر).

## PAM point accepted mutation

	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V	B	Z	X	*
A	2	-2	0	0	-2	0	0	1	-1	-2	-1	-1	-3	1	1	1	-6	-3	0	0	0	0	-8	
R	-2	6	0	1	-1	-4	1	-1	-3	2	-2	-3	3	0	-4	0	-1	2	-4	-2	-1	0	-1	-8
N	0	0	2	2	-4	1	1	0	2	-2	-3	1	-2	-3	0	1	0	-4	-2	-2	2	1	0	-8
D	0	-1	2	4	-5	2	3	1	1	-2	-4	0	-3	-6	-1	0	0	-7	-4	-2	3	3	-1	-8
C	-2	-4	-4	-5	12	-5	-5	-3	-3	-2	-6	-5	-5	-4	-3	0	-2	-8	0	-2	-4	-5	-3	-8
Q	0	1	1	2	-5	4	2	-1	3	-2	-2	1	-1	-5	0	-1	-1	-5	-4	-2	1	3	-1	-8
E	0	-1	1	3	-5	2	4	0	1	-2	-3	0	-2	-5	-1	0	0	-7	-4	-2	3	3	-1	-8
G	1	-3	0	1	-3	-1	0	5	-2	-3	-4	-2	-3	-5	0	1	0	-7	-5	-1	0	0	-1	-8
H	-1	2	2	1	-3	3	1	-2	6	-2	-2	0	-2	-2	0	-1	-1	-3	0	-2	1	2	-1	-8
I	-1	-2	-2	-2	-2	-2	-3	2	5	2	-2	2	1	-2	-1	0	-5	-1	4	-2	-2	-1	-8	
L	-2	-3	-3	-4	-6	-2	-3	-4	-2	2	6	-3	4	2	-3	-3	-2	-2	-1	2	-3	-3	-1	-8
K	-1	3	1	0	-5	1	0	-2	0	-2	-3	5	0	-5	-1	0	0	-3	-4	-2	1	0	-1	-8
M	-1	0	-2	-3	-5	-1	-2	-3	-2	2	4	0	6	0	-2	-2	-1	-4	-2	2	-2	-2	-1	-8
F	-3	-4	-3	-6	-4	-5	-5	-5	-2	1	2	5	0	9	-5	-3	-3	0	7	-1	-4	-5	-2	-8
P	1	0	0	-1	-3	0	-1	0	0	-2	-3	-1	-2	-5	6	1	0	-6	-5	-1	-1	0	-1	-8
S	1	0	1	0	0	-1	0	1	-1	-3	0	-2	-3	1	2	1	-2	-3	-1	0	0	0	-8	
T	1	-1	0	0	-2	-1	0	0	-1	0	-2	0	-1	-3	0	1	3	-5	-3	0	0	-1	0	-8
W	-6	2	-4	-7	-8	-5	-7	-7	-3	-5	-2	-3	-4	0	-6	-2	-5	17	0	-6	-5	-6	-4	-8
Y	-3	-4	-2	-4	0	4	-4	-5	0	-1	-1	-4	-2	7	-5	-3	-3	0	10	-2	-3	-4	-2	-8
V	0	-2	-2	-2	-2	-2	-1	-2	4	2	-2	2	-1	-1	0	-6	-2	4	-2	-2	-1	-8		
B	0	-1	2	3	-4	1	3	0	1	-2	-3	1	-2	-4	-1	0	0	-5	-3	-2	3	-1	-8	
Z	0	0	1	3	-5	3	3	0	2	-2	-3	0	-2	-5	0	0	-1	-6	-4	-2	2	3	-1	-8
X	0	-1	0	-1	-3	-1	-1	-1	-1	-1	-2	-1	0	0	-4	-2	-1	-1	-1	-1	-1	-1	-8	
*	-8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	1	

بعد از جداول دیگری تدوین شدند که از یک نوع اصول پیروی می‌کردند. با این تفاوت که فراوانی جایگزینی‌ها تنها در مناطق حفاظت شده (Conserved Blocks) برای ساختن جدول، محاسبه می‌شدند. در آن هنگام، ۲۰۰۰ بلوک از ۵۰۰ خانواده پروتئینی در نظر گرفته شد. به طور مشابهی، فرمول زیر بکار رفت:

**BLOSUM% = log Probability of substitution in block / Probability of occurring by chance**

این جداول را BLOSUM نامیدند که از اصطلاح Block Substitution Matrix برگرفته شده است. شماره جدول به نوع بلوک مورد استفاده برای محاسبه فراوانی و احتمال وقوع جایگزینی بستگی دارد. مثلاً BLOSUM62 یعنی این جدول بر مبنای فراوانی جایگزینی‌ها در بلوک‌های حاوی توالی‌هایی با همسانی ۶۲ درصد یا بیشتر تشکیل شده است (جدول زیر).

# BLOSUM

## (BLOcks SUbstitution Matrix)

	Ala	Arg	Asn	Asp	Cys	Gln	Glu	Gly	His	Ile	Leu	Lys	Met	Phe	Pro	Ser	Thr	Trp	Tyr	Val
Ala	4																			
Arg	-1	5																		
Asn	-2	0	6																	
Asp	-2	-2	1	6																
Cys	0	-3	-3	-3	9															
Gln	-1	1	0	0	-3	5														
Glu	-1	0	0	2	-4	2	5													
Gly	0	-2	0	-1	-3	-2	-2	6												
His	-2	0	1	-1	-3	0	0	-2	8											
Ile	-1	-3	-3	-3	-1	-3	-3	-4	-3	4										
Leu	-1	-2	-3	-4	-1	-2	-3	-4	-3	2	4									
Lys	-1	2	0	-1	-3	1	1	-2	-1	-3	-2	5								
Met	-1	-1	-2	-3	-1	0	-2	-3	-2	1	2	-1	5							
Phe	-2	-3	-3	-3	-2	-3	-3	-3	-1	0	0	-3	0	6						
Pro	-1	-2	-2	-1	-3	-1	-1	-2	-2	-3	-3	-1	-2	-4	7					
Ser	1	-1	1	0	-1	0	0	0	-1	-2	-2	0	-1	-2	-1	4				
Thr	0	-1	0	-1	-1	-1	-1	-2	-2	-1	-1	-1	-1	-2	-1	1	5			
Trp	-3	-3	-4	-4	-2	-2	-3	-2	-2	-3	-2	-3	-1	1	-4	-3	-2	11		
Tyr	-2	-2	-2	-3	-2	-1	-2	-3	2	-1	-1	-2	-1	3	-3	-2	-2	2	7	
Val	0	-3	-3	-3	-1	-2	-2	-3	-3	3	1	-2	1	-1	-2	-2	0	-3	-1	4

## چند اصطلاح:

## ::Identity یا همسانی

وقتی به کار می‌رود که منظور هم‌ردیفی یک نوکلئوتید یا اسید‌آمینه با همانند آن منظور باشد.

## مشاهد:


وقتی، به کار می‌رود که منظور هم‌دیفعه، یک نوکلئوتید یا اسید‌آmine یا معادل آن منظور باشد.

همه له ڙي:

وقتی به کار می‌رود که منظور هم‌ردیفی یک نوکلئوتید یا اسید‌آmine با معادل آن منظور باشد و رابطهٔ نیاکانی بین توالی‌ها در نظر یاشد.

امتیازدهی حذف و اضافه نمودن توالی ها

ممکن است جهش به صورت اضافه شدن یا حذفی توالی باشد. بروز این جهش ها در توالی ها باعث تفاوت در طول توالی ها می شود. بنابراین، زمانی که می خواهیم دو توالی را در حالت بهینه هم ردیف کنیم، نیازمند استفاده از فواصل هستیم. این فواصل بایستی به طریقی در محاسبه امتیاز یک هم ردیفی لحاظ شوند.



یک مثال از سیستم امتیازدهی فرضی.

این که فواصل را در هم ردیفی چگونه محاسبه کنیم یکی از مهمترین مساله ها در هم ردیفی توالی ها است. به طور معمول، جریمه هایی را که برای فواصل در نظر می گیرند به صورت محلی اعمال می شود. یعنی جریمه استفاده از هر فاصله مستقل از فواصل دیگری است که ممکن است در جاهای دیگری از هم ردیفی اتفاق بیافتد. در همه برنامه ها، برای فواصل دو نوع امتیاز منفی در نظر گرفته می شود.

#### ۱. جریمه باز کردن توالی<sup>(۱)</sup>: (GOP)

در طبیعت، هر اضافه نمودن توالی مستلزم صرف انرژی بوده و مورد انتخاب طبیعی قرار خواهد گرفت. بنابراین در الگوریتم ها برای هم ردیفی بهینه توالی ها امتیاز منفی نسبتاً بزرگی (مثل ۱۱-۱۱) برای ایجاد فاصله در نظر گرفته می شود (در مثال بالا این امتیاز منفی ۳ در نظر گرفته شده بود).

<sup>۱</sup>Gap opening penalty

## ۲. جریمه بسط یک فاصله (GEP<sup>۱</sup>)

از این جریمه برای ورود نوکلئوتید یا اسیدآmine در محلی که قبلاً فاصله ایجاد شده است، استفاده می‌شود. میزان این جریمه از GOP کمتر فرض می‌شود ولی در تعداد آنها ضرب می‌شود (مثلاً ۱ - ضربدر تعداد). زیرا از دید زیستی جایی از توالی که شکافته شده است، استعداد ورود یک یا چند نوکلئوتید را دارد.

### انواع هم‌ردیفی

هم‌ردیفی‌ها به دو شیوه قابل تقسیم‌بندی هستند:

#### الف- از نظر تعداد توالی

##### ۱. هم‌ردیفی دوگانه (Pairwise Alignment)

هم‌ردیفی تنها دو توالی با یکدیگر در طول کامل آنها یا یک ناحیه خاص.

##### ۲. هم‌ردیفی چندگانه (Multiple Alignment)

هم‌ردیفی سه یا چند توالی که از هم‌ردیفی‌های دوگانه هر جفت آنها نتیجه می‌شود.

#### ب- از نظر طول توالی

##### ۳. هم‌ردیفی محلی (Local Alignment)

یافتن و هم‌ردیفی بهترین محل‌های جور شدن دو توالی.

##### ۴. هم‌ردیفی کامل (Global Alignment)

یافتن و هم‌ردیفی جور شدگی بین طول کامل دو یا چند توالی.

به طور خلاصه، اصول مطرح شده در صفحات قبل در تمامی انواع فوق استفاده می‌شوند. مثلاً هم‌ردیفی‌های چندگانه از جمع اطلاعات مربوط به کلیه هم‌ردیفی‌های دوگانه ممکن بین جفت توالی به دست می‌آید. از آنجا که بیان جزئیات بیشتر باعث دور شدن از مباحث اصلی می‌شود، در قسمت بعد تنها به آموزش برنامه جستجوی توالی‌ها در بانک‌های اطلاعاتی می‌پردازیم که بر مبنای هم‌ردیفی محلی دوگانه است.

### جستجوی یک توالی

جستجوی بانک‌های اطلاعات توالی‌ها با یک توالی بر مبنای الگوریتم‌های نوشته شده برای هم‌ردیفی دوگانه صورت می‌گیرد. اکنون، در بیشتر پایگاه‌ها از روش BLAST<sup>۲</sup> یا Basic Local Alignment Search Tools استفاده می‌شود.

<sup>1</sup> Gap extension penalty


## چگونه کار می‌کند BLAST

آنچه در برنامه BLAST انجام می‌شود پیدا کردن جفت قطعاتی مشابهی از توالی است که امتیاز هم‌ردیفی آنها از یک حد آستانه مشخصی بالاتر باشد. این قطعات (high-scoring segment pairs) HSPs نامیده می‌شوند. برای این کار برنامه BLAST از روش Dynamic Programming استفاده می‌کند.

در روش dynamic programming برای حل یک مشکل بزرگ، آن را به چند مشکل کوچک تجزیه می‌کنند. پس از یافتن پاسخ مناسب مشکلات کوچک، آنها را کنار هم چیده و راهی برای پاسخ به مشکل بزرگ پیدا می‌کنند. با توجه به طول بلند توالی‌ها و امکان جایگزینی و حذف و اضافه در آنها، جستجوی یک توالی در بین میلیون‌ها رکورد در بانک‌های اطلاعاتی نیازمند عملیات سنگینی است که از عهده ابرایانه‌های امروزی خارج است. در برنامه BLAST از روش dynamic programming برای حل این معضل استفاده شده است.

سه مرحله اصلی در الگوریتم BLAST وجود دارد که به شرح زیر هستند:

برنامه BLAST توالی مورد نظر (Query) را به قطعاتی با طول کوتاه یا کلمه (word) همپوشان تبدیل می‌کند. عموماً اندازه کلمات برای توالی‌های آمینو اسیدی ۳ و برای توالی‌های نوکلئوتیدی ۱۱ تنظیم شده است. سپس از بین این کلمات آنها بی انتخاب می‌شوند که در یک هم‌ردیفی دوگانه با توالی الگو دارای امتیاز بالایی از یک حد تعیین شده هستند (مانند LSS). قابل ذکر است که امتیاز دهنی بر اساس جداول PAM250 یا BLOSUM62 صورت می‌گیرد که توسط کاربر قابل تغییر است.



قطعات انتخاب شده برای جستجو در پایگاه توالی‌ها به کار رفته و توالی‌های مشابه ممکن (subjects) یافت می‌شوند.

### توالی‌های مشابه ممکن (subjects)

MNGPLSSSGQTSTSPH  
LSS  
PLSSSSGQ

برای هر کدام از جفت توالی‌های یافت شده با امتیاز بالا (HSP) هم‌ردیغی توالی از دو طرف کلمه ادامه پیدا می‌کند تا جایی که هم‌ردیغی جدیدی از امتیاز حد آستانه تعیین شده‌ای کمتر نشود. سپس اضافات توالی یافت شده حذف و هم‌ردیغی حاصل برای کاربر ارسال می‌شود.

PLSSSGQ  
| | | |  
PLSSSGQ

### انواع BLAST

بنا به نوع توالی مورد نظر و نوع پایگاه مورد جستجو، برنامه‌های BLAST طراحی شده‌اند که در زیر توضیح داده می‌شوند. البته برای هریک از این برنامه‌ها نیز زیربرنامه‌هایی که در آن تنظیمات، بهینه شده است معرفی شده‌اند، مانند BLASTN برای توالی‌های کوتاه.

#### BLASTN •

در این نوع BLAST، توالی مورد تقاضا نوکلئوتیدی است و جستجو در پایگاه توالی‌های نوکلئوتیدی انجام می‌شود. نتیجه جستجو جفت توالی‌های نوکلئوتیدی مشابه است که بر اساس شاخص‌های آماری میزان شباهت و یکسانی آنها نشان داده می‌شود.

#### BLASTP •

در این نوع BLAST، توالی مورد تقاضا، پروتئینی است و جستجو در پایگاه توالی‌های پروتئینی انجام می‌شود. نتیجه جستجو، توالی‌های پروتئینی مشابه با توالی الگو است که بر اساس شاخص‌های آماری، میزان شباهت و یکسانی آنها با توالی الگو نشان داده می‌شود.

**BLASTX**

در این نوع BLAST، توالی مورد تقاضا نوکلئوتیدی است که در ۶ قالب خواندنی (ORF) ترجمه شده و به صورت توالی پروتئینی در پایگاه توالی‌های پروتئینی جستجو می‌شود. نتیجه جستجو، توالی‌های مشابه با توالی الگو است که بر اساس آن می‌توانیم به توالی جدید خود قالب خواندنی و عملکرد نسبت بدهیم.

**tBLASTN**

در این نوع BLAST، توالی مورد تقاضا پروتئینی است و جستجو در پایگاه توالی‌های نوکلئوتیدی انجام می‌شود که در ۶ قالب خواندنی ترجمه شده است. نتیجه جستجو توالی‌های مشابه با توالی مورد تقاضاست که بر اساس آن می‌توانیم برای توالی پروتئینی خود توالی‌های رمز کننده آن را شناسایی کنیم.

**tBLASTX**

در این نوع BLAST، توالی مورد تقاضا، نوکلئوتیدی است که در ۶ قالب خواندنی به پروتئین ترجمه می‌شود و در پایگاه توالی‌های نوکلئوتیدی که آن نیز در ۶ قالب خواندنی به پروتئین ترجمه می‌شود مورد جستجو قرار می‌گیرد. این نوع جستجو به ویژه در مطالعات EST به کار می‌رود.

**وارد کردن توالی به منظور جستجو در صفحه BLAST**

به طور معمول در تحقیقات، ما دارای یک توالی اولیه هستیم که می‌خواهیم توالی‌های مشابه آن را از طریق جستجو در بانک‌های اطلاعاتی به دست آوریم.

مراحل استفاده از Blast برای هم رسانی کردن یا Align دو توالی را در شکل های زیر می بینید. این شکل ها مراحل هم رسانی کردن توالی نوکلئوتیدی Zebrafish با توالی Chitinase از انسان را نشان می دهند.

The screenshot shows the NCBI homepage at [www.ncbi.nlm.nih.gov](http://www.ncbi.nlm.nih.gov). The sidebar on the right lists "Popular Resources" including PubMed, Bookshelf, PubMed Central, PubMed Health, BLAST (with a red arrow pointing to it), Nucleotide, Genome, SNP, Gene, Protein, and PubChem. The main content area displays the "Welcome to NCBI" page with links to various databases and resources like NCBI Home, Resource List (A-Z), and Get Started.

The screenshot shows the NCBI BLAST search interface. At the top, it says "Basic Local Alignment Search Tool". Below that, it says "Choose a BLAST program to run." A red arrow points to the "nucleotide blast" link. To the right of the links, descriptions of each program are provided:

- nucleotide blast**: Search a nucleotide database using a nucleotide query. Algorithms: blastn, megablast, discontiguous megablast.
- protein blast**: Search protein database using a protein query. Algorithms: blastp, psi-blast, phi-blast, delta-blast.
- blastx**: Search protein database using a translated nucleotide query.
- tblastn**: Search translated nucleotide database using a protein query.
- tblastx**: Search translated nucleotide database using a translated nucleotide query.

## Danio rerio chitinase, acidic.3 (chia.3), mRNA

NCBI Reference Sequence: NM\_213213.1

[GenBank](#) [Graphics](#)

```
>gi|47086016|ref|NM_213213.1| Danio rerio chitinase, acidic.3 (chia.3), mRNA
GAGGTACCCAGAAAATTGGCATTAAGAATGGGAGACTTACCTTATAGCAGGTTGAGCTGGTGCCT
GCCATGTCGCTTTCCATGGAAATGGCTGCTACTTCACCACTGGCCAAATATAAGACCTGGAATTGG
AAAATATACTCTGCAAATGCGACCCCTACCTTGACACACCTTATCTATGCTTTCAATCATCAAC
CAAAGGAATGAGCTGTCAATATG
ACAAAAATCCCACCTTAAAGACCC
CATGGTGTCCAATCTGCAAACCGT
TTTGATGGACTGGATCTGGACTGG
TCACTCTGCTGTGCAAGGAATTGT
TATGCTGACCGCTGCTGTATCAGCT
AAGTACTTGAACCTCATCAAGCTCA
ACAGCCTCTGTACCAAGGCTCAA
CTACTGGAGGAGAACATGGAACCC
CGTCTGACATCTTCAGATACAGCG
CGGAAGCTGGATTCTGGTCTACTA
TGACCAGAAAGTGCCTATGCCACA
ACGAAGGTCGTTATCTGAAAGACA
TTGCTGGACAGTCTGTAGTCAGGG
ATTGCCCTCAAATGCCCTCAACCC
ACTACCACCATCATGTCAGGAGGAGGATTCTGTAATGGGAAGCCAGATGGACTCTATGTCACCC
ATGACCCCAAACAAATATTACAGCTGTGAGGTCAACTCTCGTGGAAAAATGTGCTGTAGGCAACCGT
GTTTGATGACAGCTGCAAGTGTGTTGGCCAAACCTTAGTGATCATGACTCAAGAAACTTCAGAAA
AACATTGCAAATAGTGAACAAAGACACTGCAAATTCTTAAGCCAAACAAATGACAGCAAACCGTTCA
TATATAAGAACATTAGTGTAAACCTACATTATTACTAAATTGTATTATGCTTTATTACATCTGGTG
ACGTTTAACTGTAAAGTCAAGTACCTTTAAATGACTGACAAAAAGTTGTTCTGTTCTGTTCT
CTTGCTGTGAAATTAAAAACTGACATCATGGAGAGGGAAAAAAAAAAAAAA
```

8 Search

Search With

Copy

Copy to Note

Speak

Dictionary

Encyclopedia

Translate

★ Go to Web Address

Send by Mail

## Homo sapiens chitinase 3-like 1 (cartilage glycoprotein-39) (CHI3L1), mRNA

NCBI Reference Sequence: NM\_001276.2

[GenBank](#) [Graphics](#)

```
>gi|144226250|ref|NM_001276.2| Homo sapiens chitinase 3-like 1 (cartilage glycoprotein-39)
(CHI3L1), mRNA
CACATAGCTAGTCCCATAAAGGGCTGGTTGCGCGTGGGGAGTGGAGTGGACAGGTATATAAG
GAAGTACAGGGCTGGGAAGAGGCCCTGTCTAGGTAGCTGGCACCCAGGGAGCGTGGCAAGGGAAAGGG
CCACACCTGCCCCCTGCTCTGCAAGCAGAATGGGTGTGAAGGGCTCTCAAACAGGCTTGTGTCCTG
GTGCTGCTCCAGTGCTGCTCTGATACAAACAGTGTCTGACTACACCCAGCTGCTCCAGTACCGGGAG
GCGATGGGAGCTGCTTCCCAGATGCCCTTGACCGCTTCTCTGTACCCACATCATACAGCTTGGCAA
TATAAGCAAGGATCACATGACACCTGGAGTGGAAATGATGTGACGCTC
AAGAACAGGAACCCAAACCTGAAAGACTCTCTGTGCTGAGGAGATGGA
CCAAGATAGCTTCAACACCCAGAGTCGGCGGAGCTTCATCAAGTCAGT
TGCTTGTGGCTGGACCTCTGCTGGCTTACCCCTGGAGGGAGAGAC
ATCAAGGAAATGAGGGCGAATTATAAGGAAGCCCAGCCAAGGGAAA
CACTGCTGGGGAGGGTACCCATTGACAGCAGCTATGACATTGCCAA
CATAGCATATGACCTACGATTTCATGGAGCCTGGCGTGGGACCAAC
CGAGGTCAAGGGAGGATGCAAGTCTGACAGATTCAAGAACACTGACTATG
TGGGGCTCTGCCAGTAAGCTGTGATGGCATCCCCACCTTGGGGAG
TGAGACTGGTGTGGAGGCCAACTCTGCAAGCGGGAGATCCAGGGCG
CTTGCTCTACTATGAGATCTGTGACTTCTCCGGAGGCCAGTCCATA
CCTATGCCACAAAGGGCAACCAAGTGGTAGGATACGACGACAGGAAAG
CCTGAAGGACAGGGCAAGCTGGGGCGCCATGGTATGGGCCCTGGACCTG
TGCGGCCAGGATGCGCTTCCCTCTCACCAATGCCATCAAGGATGCA
TTCTGCACACAGCACGGGGGCAAGGATGCCCTGGCCCTCTGGCTCC
CTTGCCCTGCTGAGTCCCAGGCTGAGCCTCAGTCTCCCTCCCTGGGGCCATATGCAAGGGTCCACAC
ACAGATTGAGGCTGAGCCCTGGGGAGAGAGTGGGGATGGGGATAGTGAGGCACTGCCAA
TGTAAGACTGGGATTAGTACACACTGTGTGATTAAATGGAATGTTACAGATCCCCAGGCTGGCAAGG
GAATTCTCAACTCCCTGCCCTCCAGCCCTCTTATCAAAGGACCCATTGGCAAGCTATCACCA
AGGAGCACAACATCCCTACAAAGACACAGTGAACCATACTAATTATACCCCTGCAAAAGCCCAGCTGAAAC
TTCACCTAGGAACGTAATCGTGTCCCCCTACTCTACTTCCCTCTAATTCCACAGCTGCTAATAAGT
ACAAGAGCTTAACAGTGAAGGAAAAAAAAAAAAAA
```

8 Search

Search With

Copy

Copy to Note

Speak

Dictionary

Encyclopedia

Translate

★ Go to Web Address

Send by Mail

► NCBI BLAST! blastn suite

Align

blast blast blast blast blast

Enter Query Sequence

Enter accession number(s), gi(s), or FASTA sequence(s) [?](#)

```
GTTTGATGACAGCTGCAAGTGCCTGTGTTGGCCAAAACCTTAGTGATCATGACTCAAGAACTTCAGAAA  
AACATTGGCAATATGTAACAGACACTGCAAAATTCTTAAAGCCACACAAATGACGCAACCGTTTC  
TATATANGAACATTAGTGTAACCTACATTATTTACTAAATTGGTATTATGCTTTATTACATCTTGGTG  
ACGTTTAACTGTAGTGCAAGTACCTCTTTTAAATGACTGCAAAAGTTGTTCTTGTCGTTCT  
CCTTGCTGTGAAATTAAATGACATCATGGAGGGGAAAAAARRRRRRRRRRRRRRRRRRRRRR
```

Clear

Query subrange [?](#)

From  To

Or, upload file  Choose... [?](#)

Job Title  gil4708016|ref|NM\_213213.1| Danio rerio cithbase...

Enter a descriptive title for your BLAST search [?](#)

Align two or more sequences [?](#)

Enter Subject Sequence

Enter accession number(s), gi(s), or FASTA sequence(s) [?](#)

```
TGTAAGACTCGGGATTAGTACACACTTGTGTTGATTAATGGAAATGTTACAGATCCCCAAGGCCCTGGCAAGG  
GAATTTCTCAACTCCCTGCCCCCAAGCCCTCCTTATEAAAGGACACCATTTGGCAAGCTCTATCACC  
AGGAGCCAAACATCCTACAGACAGACATGACCATCTTAATTATACCCCCCTGCAAAAGGCCAGCTTGGAAACC  
TTCACCTTAAAGAACGTAATCGTGTCCCCTATCCTACTTCCCTCTCTAAATTCCACAGCTGCTCAATAAGT  
ACAAGAGCTTAACTGAAARRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRRR
```

Subject subrange [?](#)

From  To

Or, upload file  Choose... [?](#)

Program Selection

Optimize for  Highly similar sequences (megablast)  More dissimilar sequences (discontiguous megablast)  Somewhat similar sequences (blastn)

Choose a BLAST algorithm [?](#)

**BLAST** Search nucleotide sequence using Blastn (Optimize for somewhat similar sequences)  Show results in a new window

[Algorithm parameters](#) Note: Parameter values that differ from the default are highlighted

BLAST® Basic Local Alignment Search Tool

Home Recent Results Saved Strategies Help My NCBI [Sign In] [Register]

NCBI/ BLAST/ blastn suite-2sequences/ Formatting Results - 6YPB1S9J11N

Edit and Resubmit Save Search Strategies ► Formatting options ► Download You Tube How to read this page Blast report description

Blast 2 sequences

gi|47086016|ref|NM\_213213.1| Danio rerio chitinase,...

RID 6YPB1S9J11N (Expires on 10-30 14:44 pm)

Query ID Id|14943  
Description gi|47086016|ref|NM\_213213.1| Danio rerio chitinase, acidic.3  
(chi.3), mRNA  
Molecule type nucleic acid  
Query Length 1746

Subject ID Id|14945  
Description gi|144226250|ref|NM\_001276.2| Homo sapiens chitinase 3-like 1  
(cartilage glycoprotein-39) (CHI3L1), mRNA  
Molecule type nucleic acid  
Subject Length 1867  
Program BLASTN 2.2.28+ ► Citation

Other reports: ► Search Summary [Taxonomy reports]

Graphic Summary

Distribution of 2 Blast Hits on the Query Sequence ⓘ

Mouse over to see the details, click to show alignments

Color key for alignment scores

Query	<40	40-50	50-80	80-200	>=200
1					
	300	600	900	1200	1500

Sequences producing significant alignments:

Select: All None Selected:0

Alignments	Download	Graphics	Description	Max score	Total score	Query cover	E value	Ident	Accession
			gi 144226250 ref NM_001276.2  Homo sapiens chitinase 3-like 1 (cartilage glycoprotein-39) (CHI3L1), mRNA	91.5	114	58%	9e-22	64%	30993

	Max score	Total score	Query cover	E value	Ident	Accession
	91.5	114	58%	9e-22	64%	30993

gi|144226250[ref|NM\_001276.2] Homo sapiens chitinase 3-like 1 (cartilage glycoprotein-39) (CHI3L1), mRNA  
Sequence ID: Icl|30993 Length: 1867 Number of Matches: 2

Range 2: 1729 to 1740 <a href="#">Graphics</a>			<a href="#">▼ Next Match</a>	<a href="#">▲ Previous Match</a>	<a href="#">▲ First</a>
Score	Expect	Identities	Gaps	Strand	
22.9 bits(24)	0.40	12/12(100%)	0/12(0%)	Plus/Minus	
Query 812 TGGGCTTTGCAG 823					
Shift 1740 TGGGCTTTGCAG 1729					

## مراحل استفاده از BLAST برای مقایسه یک توالی با سایر توالی‌های موجود در بانک اطلاعاتی

The screenshot shows the NCBI Standard Nucleotide BLAST search interface. The sequence 'GGTTTGTGAGGACTCGAGATGCTGATTTGGCCGAAACCTTAGTGATCATGACTCAAGAACCTTCAGAAA' is entered in the query sequence input area (1). Below it, there are 'From' and 'To' fields for a query subrange (2). A 'Choose...' button for uploading files is shown (3). A 'Job Title' input field is present (4). The 'Choose Search Set' section includes a 'Database' dropdown set to 'Human genomic + transcript' (5), an 'Organism' dropdown set to 'Nucleotide collection (nr/nnt)' (6), and an 'Exclude' checkbox. The 'Program Selection' section has an 'Optimize for' dropdown set to 'Somewhat similar sequences (blastn)' (7) and a 'Choose a BLAST algorithm' dropdown (8). Finally, the 'BLAST' search button is highlighted (9).

۱. در این قسمت توالی مورد نظر را با فرمت FASTA یا شماره دسترسی آن را در صورت دانستن وارد می‌نماییم.
۲. در این قسمت می‌توانیم قسمتی از توالی را مشخص کنیم که می‌خواهیم مورد جستجو قرار گیرد.
۳. با استفاده از این بخش می‌توانیم توالی را از جایی که ذخیره کردہ‌ایم upload کیم.
۴. در این بخش می‌توانیم برای جستجوی خود توضیح مختصری وارد کنیم.
۵. این بخش مربوط به نوع پایگاه داده است که می‌خواهیم توالی ما در آن جستجو شود. به صورت پیش فرض کلیه پایگاه‌های مشابه یا nr (nonredundant) مورد هدف است.
۶. این بخش مربوط به انتخاب نوع موجود زنده مورد نظر ماست که گزینه‌ای اختیاری است و در صورتی از آن استفاده می‌کنیم که بخواهیم فقط در موجود خاصی توالی ما جستجو شود.
۷. این بخش مربوط به جستجوی توالی ما در ENTREZ است که اختیاری است و می‌توانیم جستجو در مورد توالی خود را با کلید واژه محدود کنیم.
۸. در این بخش نوع الگوریتم BLAST را مشخص می‌کنیم.
۹. با کلیک بر روی نمایه BLAST جستجو آغاز می‌شود.

1

**Algorithm parameters**

**General Parameters**

Max target sequences	100	Select the maximum number of aligned sequences to display ⓘ
Short queries	<input checked="" type="checkbox"/> Automatically adjust parameters for short input sequences ⓘ	
Expect threshold	10	ⓘ
Word size	3	ⓘ
Max matches in a query range	0	ⓘ

**Scoring Parameters**

Matrix	BLOSUM62	ⓘ
Gap Costs	Existence: 11 Extension: 1	ⓘ
Compositional adjustments	Conditional compositional score matrix adjustment	ⓘ

**Filters and Masking**

Filter	<input type="checkbox"/> Low complexity regions ⓘ
Mask	<input type="checkbox"/> Mask for lookup table only ⓘ <input type="checkbox"/> Mask lower case letters ⓘ

**BLAST**

Search database Non-redundant protein sequences (nr) using Blastp (protein-protein BLAST)

Show results in a new window

2

3

- این بخش مربوط به تنظیم پارامترهای الگوریتم‌های مورد استفاده در BLAST است که شامل پارامترهای عمومی، امتیازدهی و فیلترگذاری می‌شود. در این بخش می‌توان تعداد توالی‌های نمایشی در یک صفحه، پارامترهای مربوط به توالی‌های کوتاه، میزان آستانه و اندازه کلمات مورد جستجو توسط BLAST را تنظیم کرد.
- این قسمت برای تنظیم پارامترهای امتیازدهی طراحی شده است. نوع ماتریس امتیازدهی، جریمه فواصل و فرض‌های مربوط به اعمال ماتریس‌های امتیازی را می‌توان به صورت دستی تنظیم کرد.
- در این بخش می‌توان الگوریتم را برای در نظر نگرفتن نواحی از توالی که ارزش تکاملی ندارند و یا دارای اشکال و ابهام هستند تنظیم کرد. با انتخاب فیلتر مربوطه بخش‌های موردنظر از توالی در جستجو لحاظ نمی‌شود.

## صفحه نتایج

بعد از وارد کردن توالی در جایگاه مربوطه و انتخاب پارامترهای مورد نظر، زمانی که کلید BLAST را می‌زنیم صفحه‌ای باز می‌شود که اطلاعات مختص‌سری را در مورد توالی ما می‌دهد و اعلام می‌کند که جستجوی ما در حال انجام است و نتایج، بعد از چند ثانیه نشان داده خواهد شد. در صورت شلوغ بودن، سرور سایت اعلام می‌کند که جستجوی خود را در زمانی دیگر دوباره انجام دهیم.

## صفحه نتایج شامل سه بخش است:

بخش اول شامل توضیحاتی در مورد در مورد الگوریتم BLAST و نویسنده‌گان این الگوریتم و ویرایش‌هایی است که در گذشته و حال مورد استفاده هستند. در این بخش جستجوی ما دارای یک ID است که در صورت لزوم (مثلًا بروز مشکل و درخواست کمک از مدیر پایگاه) می‌توانیم با این ID به جستجوی خود در NCBI دسترسی داشته باشیم. این بخش توضیحاتی در مورد پایگاه داده‌ای که ما برای جستجوی خود انتخاب کردی‌ایم نیز می‌دهد.


The screenshot shows the NCBI BLAST search results for the query sequence gil|47086016[ref]NM\_213213.1|Danio rerio. The top navigation bar includes links for Home, Recent Results, Saved Strategies, and Help. Below the navigation is a search bar with the query sequence. The main content area displays the following information:

RID	6YTSFNHN01R (Expires on 10-30 15:43 pm)
Query ID	lcl 98935
Description	gil 47086016[ref]NM_213213.1  Danio rerio chitinase, acidic.3 (chia.3), mRNA
Molecule type	nucleic acid
Query Length	1746
Database Name	nr
Description	Nucleotide collection (nt)
Program	BLASTN 2.2.28+ > Citation

Other reports: > Search Summary [Taxonomy reports] [Distance tree of results]

## بخش اول نتایج Blast

بخش دوم این صفحه نمایشی گرافیکی از نتایج BLAST است به طوری که در جستجوی ۱۰۰ توالی اولی که در جستجوی BLAST به دست آمده‌اند به صورت خطوط رنگی نشان داده می‌شوند، هر توالی بر اساس میزان شباهت خود دارای یک طیف رنگی است. کلید رمز رنگ‌ها بر اساس امتیاز هم‌ردی‌یافی در بالای آن آمده است. هر چه قدر جور شدن توالی یافت شده با توالی در حال جستجو بیشتر باشد با رنگ قرمز و هر چه کمتر باشد با رنگ‌های رو به مشکی نمایش داده می‌شود. بنابراین در این قسمت در یک نگاه کلی می‌توانیم میزان شباهت را مشاهده کنیم.



## بخش دوم نتایج Blast

### بخش سوم


در بخش سوم شماره دسترسی (شماره ۱) و نام (شماره ۲) توالی‌های به دست آمده فهرست شده‌اند. روبروی هر توالی اعدادی نوشته شده است. اولین عدد امتیاز هم‌دیفی دوگانه (شماره ۳) توالی یافت شده و توالی در حال جستجو است که کلیه اطلاعات بعدی بر اساس آنها مرتب می‌شوند و شامل Max Score (بیشترین امتیاز مربوط به یک قطعه از Subject) و Total Score (امتیاز کل یا مجموع امتیازات قطعات هم‌دیف شده از یک Subject). دومین شاخص، ارزش مورد انتظار یا E-value (شماره ۴) است.

تعریف این شاخص به صورت ساده این است:

- چه قدر احتمال دارد که توالی جفت شده با توالی الگوی ما به طور تصادفی جفت شده باشد و هیچ رابطه معنی‌داری بین آنها وجود نداشته باشد.

• طبیعی است که اگر E-Value صفر باشد، ایده‌آل ترین حالت ممکن است و در غیر این صورت هر چه به صفر نزدیک‌تر باشد اطمینان ما به نتیجه به دست آمده بیشتر می‌شود. نتایج BLAST بر اساس این دو شاخص مرتب می‌شوند و بنابراین توالی‌هایی که در اوائل لیست هستند توالی‌هایی هستند که اطمینان ما در شباهت آنها به توالی الگوی مورد نظرمان بیشتر است.

شماره ۵ درصد همسانی (Identity) و شماره ۶ Query cover یا درصدی از Subject را که توسط Query پوشش داده شده است، نشان می‌دهد.



### بخش سوم نتایج Blast

در بخش چهارم جزئیات هم‌ریفی تک توالی‌ها با توالی الگوی ما آورده شده است که شامل اطلاعاتی در مورد Score هم‌ریفی، میزان شباهت دو توالی و تعداد جایگاه‌های جفت‌شده و تعداد فواصل استفاده شده و ... است. ضمن اینکه بخشنی از توالی که هم‌ریف شده‌اند در این توضیحات می‌آید که می‌توان به راحتی مناطق مشترک بین دو توالی را مشاهده کرد.

## یکی از هم رده‌یافتهای نتیجه BLASTX



بخش چهارم نتایج Blast

## **Blastn نمونه‌ای از نتایج**

PREDICTED: *Oreochromis niloticus* acidic mammalian chitinase-like (LOC100703770), mRNA

Sequence ID: ref|XM\_003459030.2| Length: 1580 Number of Matches: 1

Range 1: 89 to 1506 GenBank Graphics					▼ Next Match	▲ Previous Match
Score	Expect	Identities	Gaps	Strand		
994 bits(1102)	0.0	1078/1424(76%)	24/1424(1%)	Plus/Plus		
Query 28		ATGGGGAGACTTACACTTATAGCAGGTTGAGCTTGGTGCTCTGCCATGTGCGCTTTCC			87	
Sbjct 89		ATGCCCAAGGCTCACAAATTCTAGCAGGTTGTGCCTGGTATAAGCCAGCTGGGATCTGCC			148	
Query 88		ATGGAAATGGCTGCTACTTCACCAACTGGTCCCAATATAGACCTGGAAATTGGAAAAATAT			147	
Sbjct 149		AGCAGGATGGAGTGCTACTTCACCAACTGGTCCCAAGTACAGGCTGGAGATGGAAAAGT--			206	مرت ہم گ

دو توالی به صورت هم  
جهت با یکدیگر  
هر دیف شده‌اند یا به  
عبارت دیگر هر دو روی  
رشته بالا (Sense) قرار  
گرفته‌اند

Range 5: 4543 to 4677 GenBank Graphics

Score	Expect	Identities	Gaps	Strand
244 bits(270)	2e-60	135/135(100%)	0/135(0%)	Plus/Minus
Query 1055	AGTCCGTTATCTGAAAGACAAGAATTGGTGGAGCTTCGTTGGCACTGATCTGG			1114
Sbjct 4677	AGTCCGTTATCTGAAAGACAAGAATTGGTGGAGCTTCGTTGGCACTGATCTGG			461
Query 1115	ATGACTTTGCTGGACAGTTCTGTAGTCAGGGGAACCATCCTCTCATGGCCCATCTTCGCA			صهورت غیر يكديگر
Sbjct 4617	ATGACTTTGCTGGACAGTTCTGTAGTCAGGGGAACCATCCTCTCATGGCCCATCTTCGCA			دهاند يا به ك
Query 1175	ATCTTCTGGATATTG	1189		
Sbjct 4557	ATCTTCTGGATATTG	4543		

دو توالی به صورت غیر  
همجهت با یکدیگر  
همردیف شده‌اند یا به  
عبارةت دیگر یکی روی  
رشته بالا (Sense) و  
دیگری روی رشته پایین  
قرار گرفته (anti-sense)  
است.

منبع:

ملبوبي، مع.، فيضي، ا.، لهراسيبي، ت. راهنمای عملی داده‌پردازی زیستی و پژوهش‌های ژنوم. انتشارات استاد ملبوبي.