

Docente: **Matteo Re**
re@di.unimi.it
matteo.re@unimi.it

Università degli
studi di milano



Banche dati biologiche

A.A. 2014-2015 semestre I

4

INTRODUZIONE, STRUMENTI WEB

bioinformatica:

Come mai esistono numerosi strumenti web dedicati in modo specifico alla manipolazione ed elaborazione di dati di tipo biomolecolare e biotecnologico?

Lo sviluppo di questi strumenti è iniziato a metà degli anni ottanta del secolo scorso per rispondere all'esigenza di rendere possibile l'estrazione di informazioni da collezioni di schede testuali che descrivevano molecole presenti nelle cellule di diversi organismi.

Lo sviluppo di questi strumenti di estrazione e di metodi per confrontare biomolecole ha portato alla nascita di una disciplina che prende il nome di bioinformatica.

Bioinformatica è l'**applicazione** di strumenti propri delle scienze dell'informazione (es. algoritmi, intelligenza artificiale, databases) a problemi di interesse biologico, biotecnologico e biomedico.

Banche dati biologiche e bioinformatica:

Attualmente la bioinformatica suscita grande interesse perché:

- La creazione di nuove biotecnologie ha permesso di ridurre il costo ed il tempo necessario per l'acquisizione di informazioni sulle biomolecole. → **esistono banche dati contenenti informazioni riguardanti milioni di biomolecole,**
 - La dimensione dei problemi biologici è sufficiente a motivare lo sviluppo di algoritmi efficienti
 - I problemi sono accessibili (elevata quantità di dati pubblici e letteratura inerente) ed interessanti
 - Le scienze biologiche si avvalgono sempre più spesso di strumenti computazionali
-

Bioinformatica: Scienze dell'Informazione o Biologia? (I)

Gli sviluppi delle scienze biomediche, (in particolare per quanto riguarda la biologia molecolare) si verificano ad un ritmo tale da porre seri problemi:

La nostra capacità tecnologica di acquisire nuovi dati (spesso in quantità elevate) rende impossibile la loro analisi **in assenza di strumenti efficienti.**

Bioinformatica:

Scienze dell'Informazione o Biologia? (II)

Cosa hanno **in comune** scienze biologiche e scienze dell'informazione?

La **biologia**, ed in particolare la biologia molecolare, si occupa dei fenomeni che avvengono nei viventi a livello di atomi e molecole. L'unità di base dei viventi è la **cellula**. La costruzione di una cellula richiede la lettura e la manipolazione di informazioni ...

Scienze dell'informazione è la disciplina che si occupa di calcolo (in senso generico) e delle sue applicazioni. Essa si basa sullo studio sistematico di fattibilità, struttura e automatizzazione di metodi che permettono l'acquisizione, accesso e manipolazione ~~dell'informazione (intesa in senso generico)~~.

Bioinformatica: Scienze dell'Informazione o Biologia? (III)

Cosa hanno **in comune** scienze biologiche e scienze

Scienze dell'informazione

Dati di input

Lettura

Elaborazione

Dati di output

Biologia

DNA

copiatura (trascrizione)

traduzione

PROTEINA

Bioinformatica: Scienze dell'Informazione o Biologia? (IV)

Cosa hanno **in comune** scienze biologiche e scienze

Scienze dell'informazione

Biologia

STUDIANO ENTRAMBE:

- **Flussi di informazione** (biologia nei viventi, scienze dell'informazione all'interno di processi di calcolo)
- **Manipolazione dell'informazione** (biologia nei viventi, scienze dell'informazione all'interno di processi di calcolo)
- **Organizzazione e rappresentazione dell'informazione** (biologia nei viventi, scienze dell'informazione all'interno di processi di calcolo)

L'INFORMAZIONE NEI VIVENTI

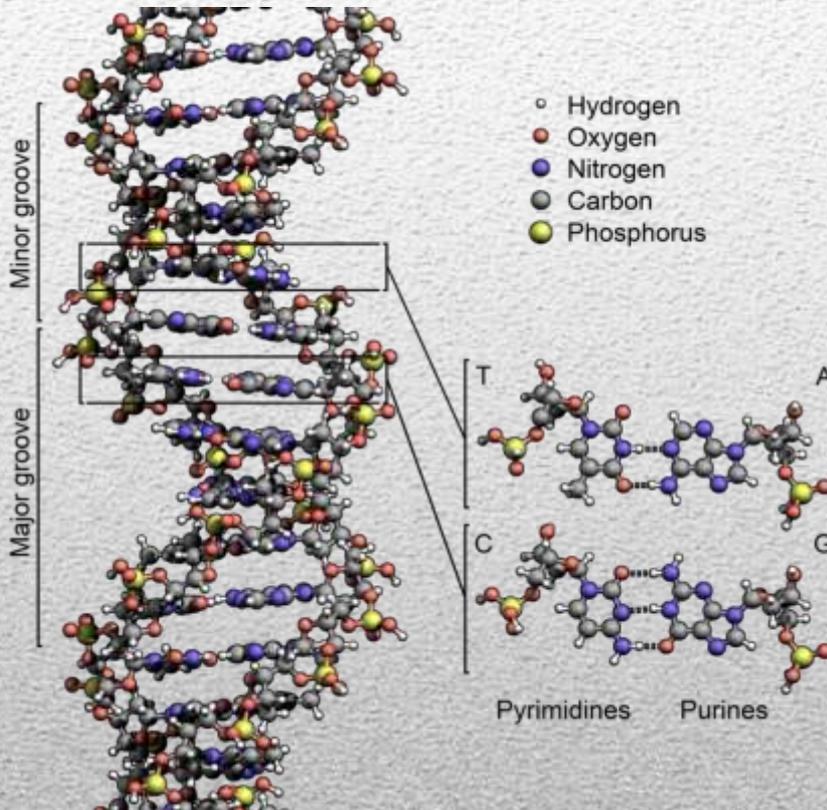
I viventi sono formati da un numero estremamente ampio di molecole. Ognuna di esse è funzionalmente unica e costruita rispettando criteri ben definiti.

Se ogni molecola è costruita seguendo un «progetto» questo implica che, nei viventi, **deve** esistere un luogo il cui ruolo è quello di immagazzinare e rendere disponibili al momento del bisogno le informazioni relative ai «progetti» delle molecole.

A livello biomolecolare come sono realizzate l'**organizzazione** e la manipolazione dell'informazione?

Depositario informazione: DNA

- **Doppia elica**: ognuna delle due eliche può essere ricostruita a partire dall'informazione presente nell'altra (banca dati con sistema di «backup» incorporato)
- **Informazione**: ogni elica è una lunga catena formata da una **sequenza** di 4 elementi : adenina (**A**), Timina (**T**), citosina (**C**) e guanina (**G**). Essi vengono detti **nucleotidi**.

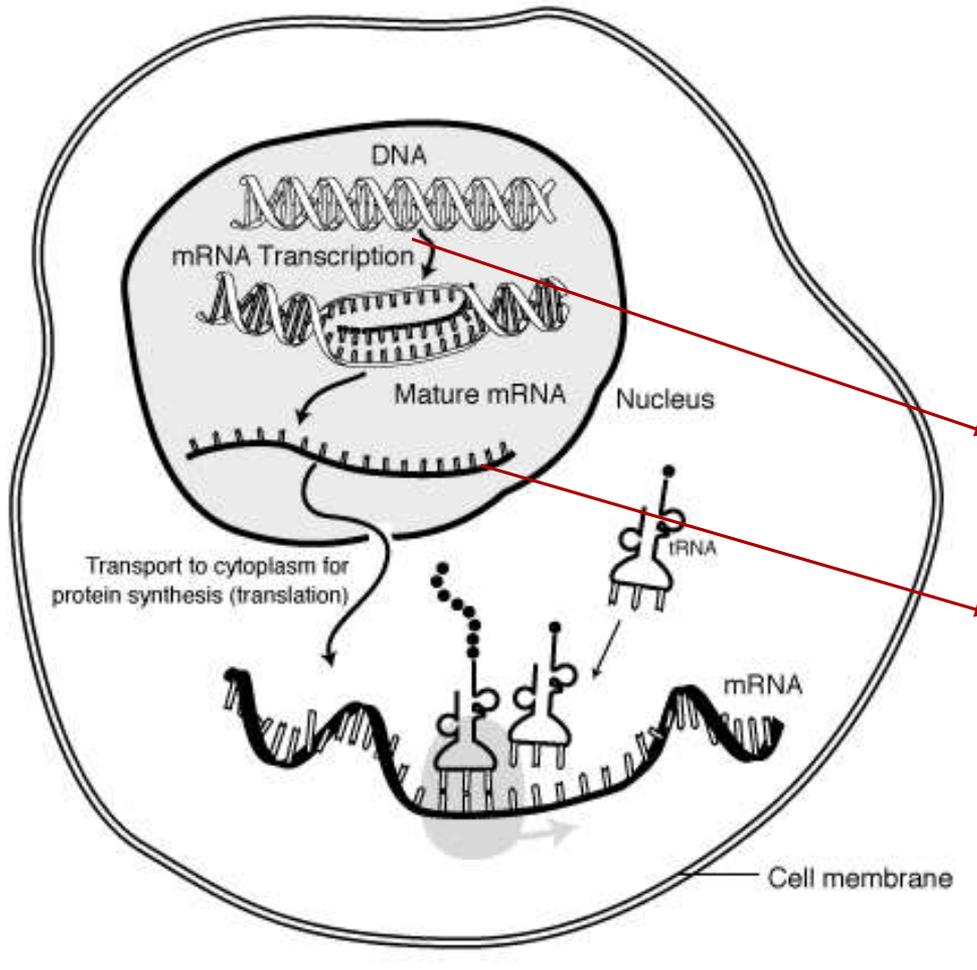


...AGCGGAGGAGCATGCGGATTAGGCTTCGGATCGGAT...

...TCGCCTCCTCGTACGCCTAATCCGAAGCCTAGCCTA...

Lunghezza DNA umano? ... più di 3 miliardi di caratteri.

A livello biomolecolare come sono realizzate l'organizzazione e la **manipolazione** dell'informazione?

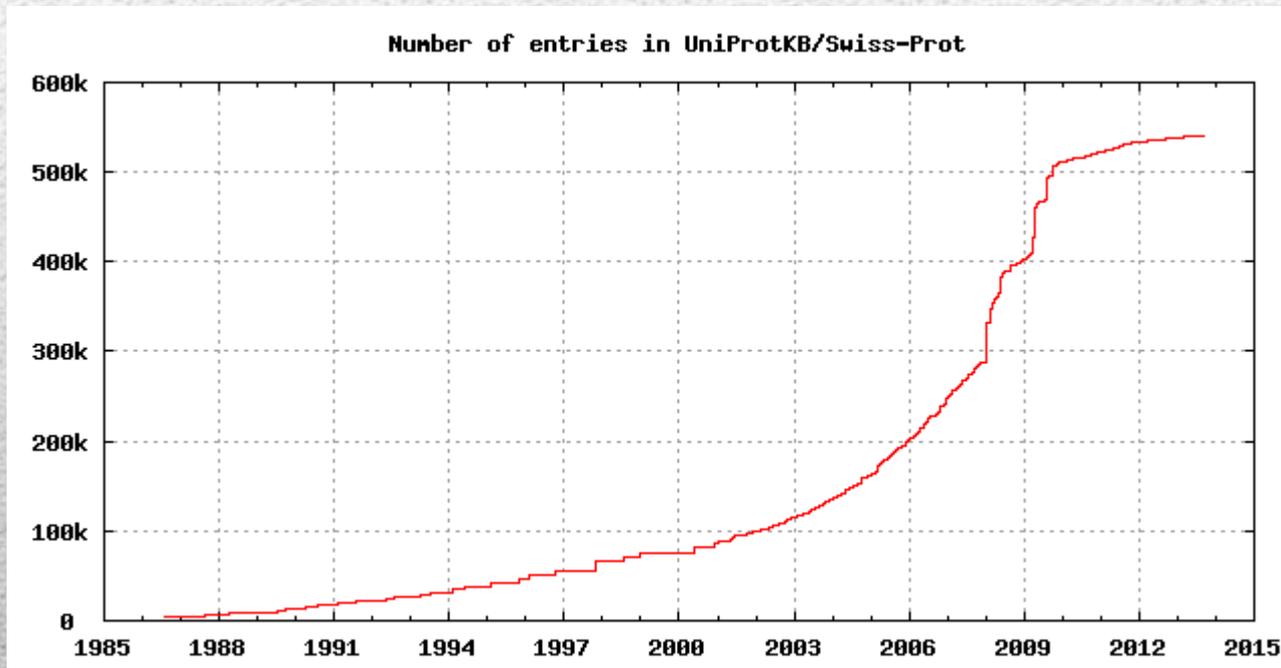


Manipolazione informazione: es. sintesi proteina

- **Copia informazione:** un tratto di DNA (**gene**) viene copiato in una molecola (**RNA**) in grado di trasportare l'informazione altrove.
- **Traduzione:** l'RNA che ha portato l'informazione altrove (**messenger**) viene **tradotto**: viene letto a gruppi di tre lettere, ad ogni tripletta corrisponde uno di 20 aminoacidi. mRNA viene letto e viene sintetizzata una catena di aminoacidi (la **proteina** codificata dal messenger)

Cosa c'entra tutto questo con la lezione di oggi?

Tutte le biosequenze (DNA, geni, mRNA, proteine,...) vengono immagazzinate in apposite banche dati. La banca dati di riferimento per le sequenze di proteine (**Uniprot** : <http://www.uniprot.org/>) contiene, al momento, quasi 600.000 proteine.



Dato il numero estremamente elevato di sequenze non è possibile accedere a queste informazioni senza utilizzare strumenti dedicati. Oggi ci occupiamo di questi strumenti.

BANCHE DATI BIOLOGICHE

Le prime banche dati biologiche sono state create nel 1982. In quel periodo i calcolatori erano poco potenti. La possibilità di scambiarsi informazioni utilizzando internet non era diffusa come al giorno d'oggi.

Tuttavia questa possibilità esisteva già nelle università. In quel periodo serviva molto tempo e molto denaro per ottenere informazioni su una biomolecola.

Ogni volta che il progetto dedicato alla caratterizzazione di una biomolecola terminava, tutti i risultati venivano inseriti in **semplici file di testo** e inviati ad una banca dati che rendeva queste «schede informative» pubblicamente disponibili.

BANCHE DATI BIOLOGICHE

Quindi le prime banche dati biologiche erano semplici pagine web che fornivano l'accesso a collezioni di file di testo.

Ogni file di testo aveva un nome che corrispondeva ad un codice identificativo della molecola descritta al suo interno. Ad esempio se il file conteneva informazioni su una proteina avente codice **PR001** allora il file di testo contenente la sua scheda aveva nome **PR001.txt**.

La pratica di assegnare un identificativo ad ogni molecola inserita in una banca dati biologica è utilizzata ancora adesso. L'identificativo viene detto **accession number** ed è una parola contenente **lettere, numeri e simboli** (spazi vuoti non ammessi)

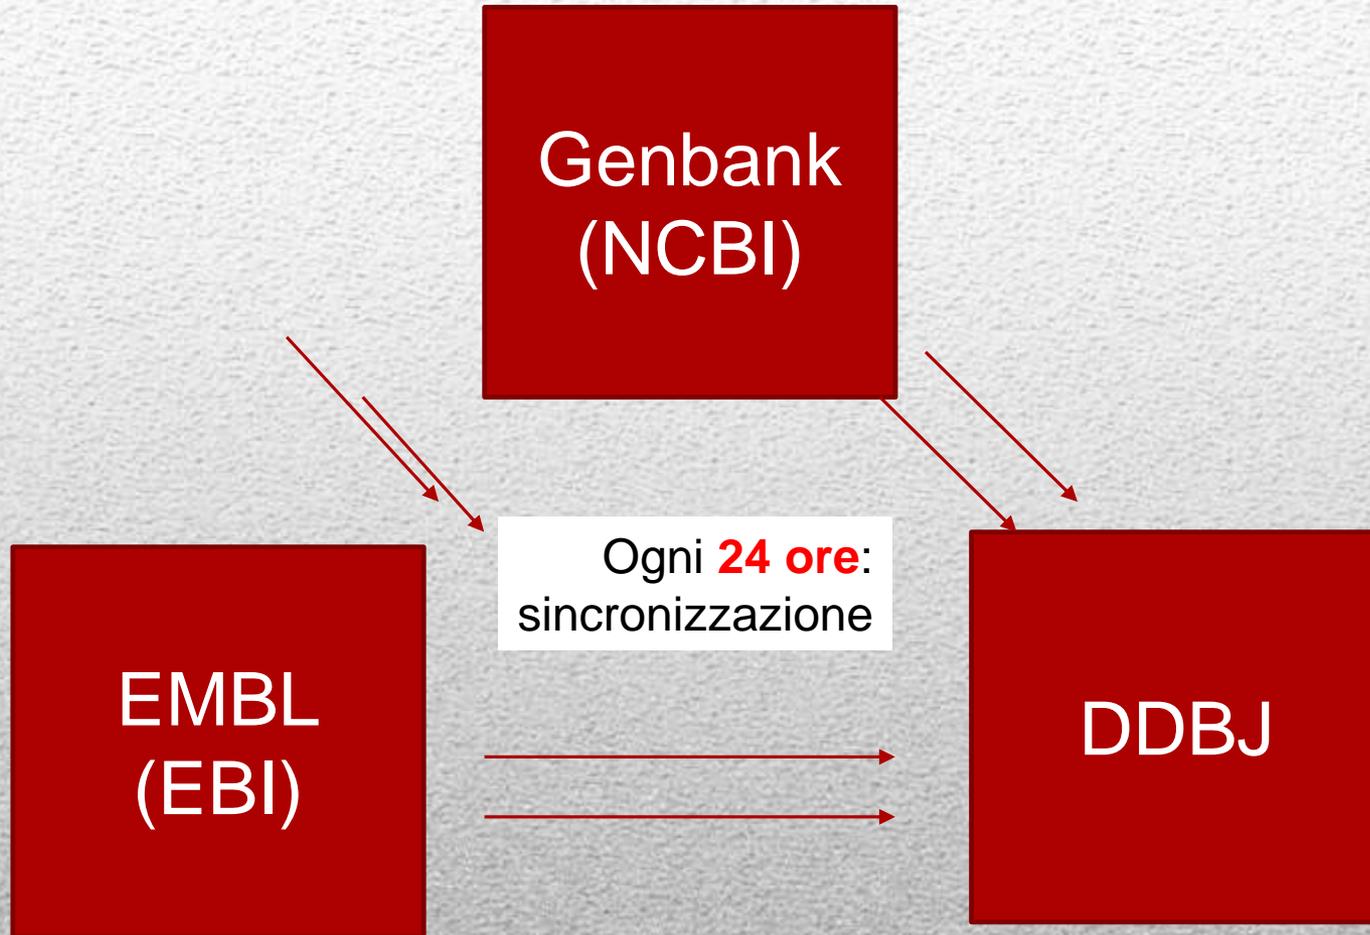
BANCHE DATI BIOLOGICHE

Esistono diversi tipi di banche dati biologiche. Esse si possono classificare in base a vari criteri. Uno di questi riguarda la **qualità delle informazioni** in esse contenute.

Da questo punto di vista possiamo suddividere la banche dati bio in 2 classi principali:

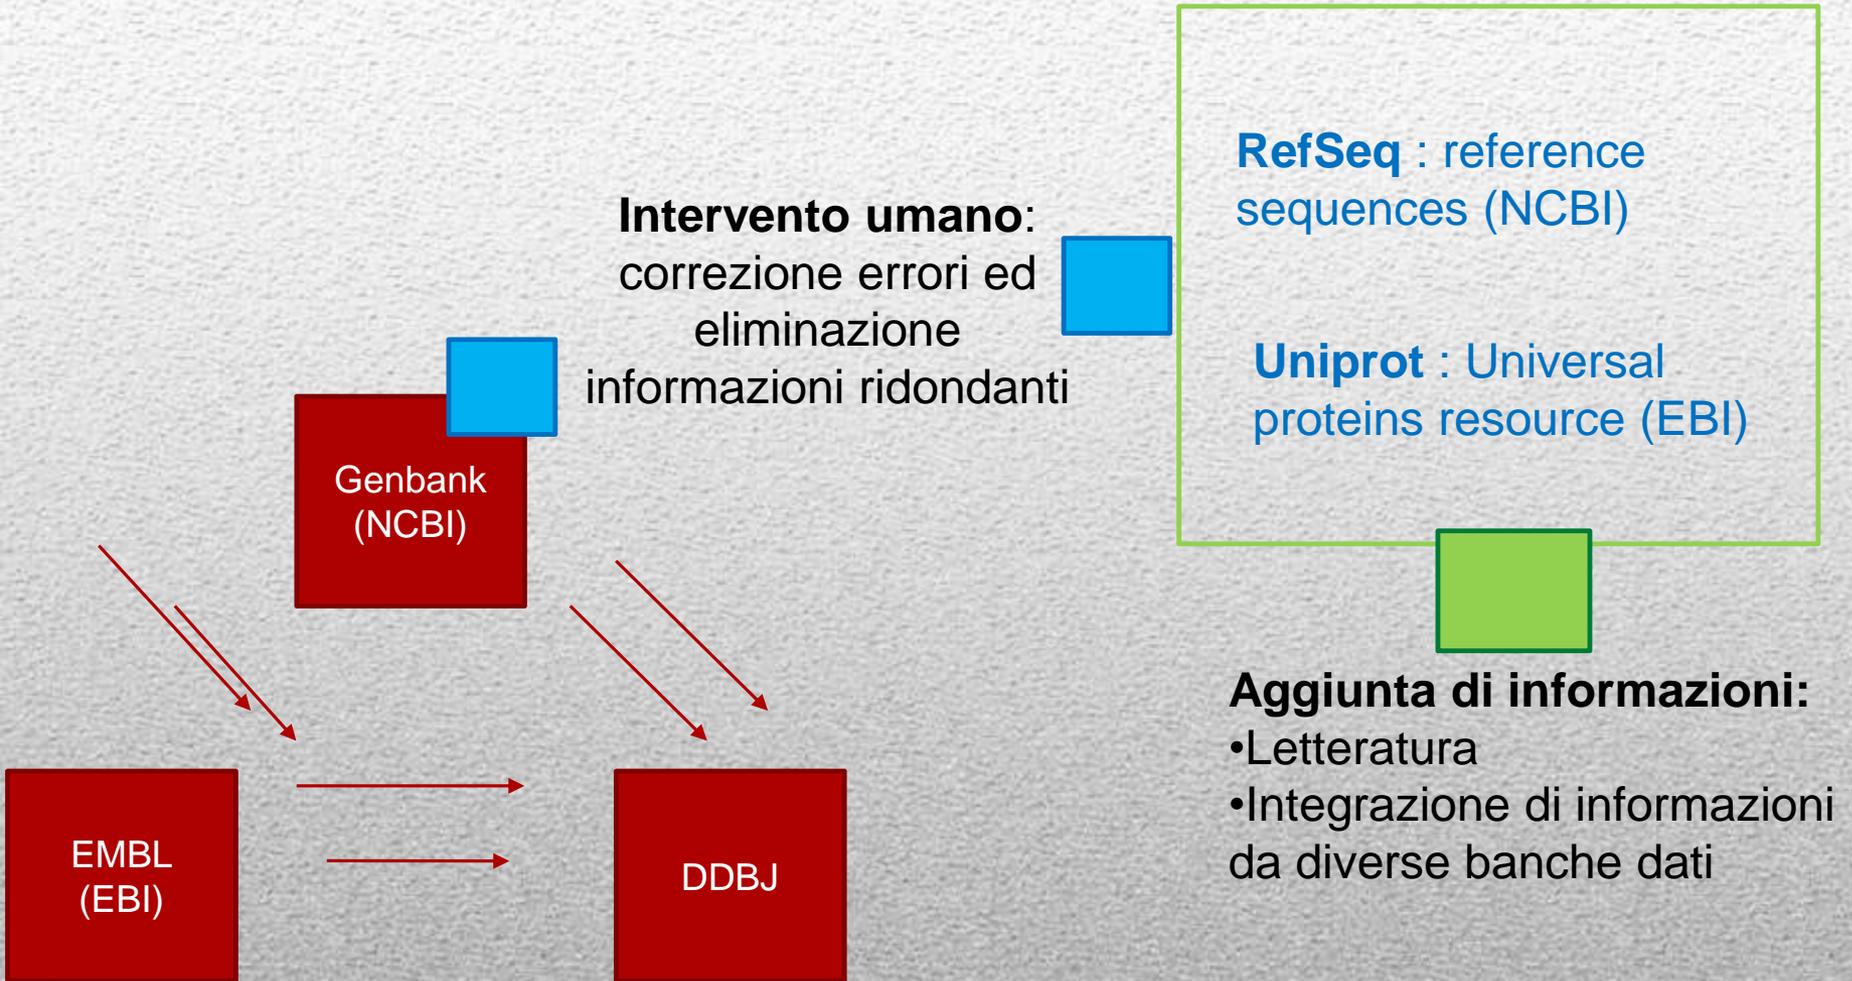
- **Banche dati PRIMARIE** : dette anche collettori primari. Il loro ruolo è quello di raccogliere, giornalmente, tutte le informazioni che riguardano biomolecole prodotte in tutti i laboratori del mondo e renderle disponibili.
 - **Banche dati SECONDARIE**: dato che l'informazione contenuta nei collettori primari è sporca e ridondante esse esaminano i dati dei collettori, correggono eventuali errori, includono informazioni aggiuntive e rendono disponibili i risultati di questo processo di raffinamento.
-

BANCHE DATI PRIMARIE



... va avanti così dagli anni '80 ... secondo voi quanti dati contengono ?

BANCHE DATI SECONDARIE



... va avanti così dagli anni '80 ... secondo voi quanti dati contengono ?

BANCHE DATI PRIMARIE

Queste banche dati contengono, letteralmente, **miliardi di schede**. Sarebbe impossibile trovare quello di cui abbiamo bisogno in assenza di strumenti che permettano di cercare le informazioni a cui siamo interessati.

Questo ci aiuta a capire il motivo per cui le banche dati biologiche non sono **mai** costituite **solamente dalla collezione di dati** che contengono ma anche da un insieme di strumenti progettati per rendere possibile estrazione e manipolazione delle informazioni in esse contenute.

... va avanti così dagli anni '80 ... secondo voi quanti dati contengono ?

Banca dati biologica: definizione

Obiettivi:

1. Disseminare dati ed informazioni biologiche
1. Strutturare l'informazione in modo che essa sia leggibile/modificabile da parte di un calcolatore

Una banca dati biologica **DEVE** avere **almeno uno strumento specifico** per la ricerca ed estrazione dei dati.

- Pagine web, libri, articoli scientifici, tabelle, file di testo, e fogli di calcolo **non possono** essere considerati banche dati biologiche.

Liste pubbliche di banche dati biologiche

- Wikipedia (lista di banche dati biologiche)

https://en.wikipedia.org/wiki/List_of_biological_databases

- Nucleic Acids Research Database Listing

<http://nar.oupjournals.org/cgi/content/full/30/1/1/DC1> (esempio di pubblicazione in cui è presente una lista di database biologici “storica” ... articolo del 2002)

- Sono un buon punto di partenza per farsi un’idea sul numero e varietà delle banche dati biologiche.

- Più di 500** banche dati esistenti sono state catalogate fino ad oggi. E sono costantemente in crescita...



Esempio di accesso a banca dati biologica:

Supponiamo di conoscere il “nome” di un gene: **INDY** (ebbene sì ... ogni gene ha un suo nome). E di voler cercare informazioni su di esso in una banca dati.

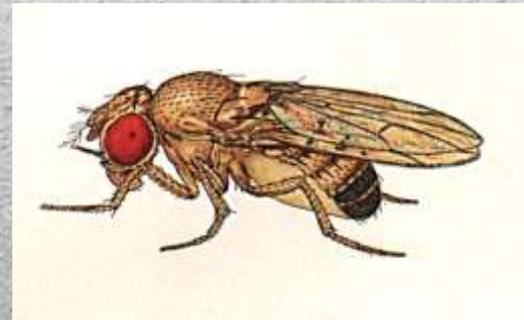
Da dove iniziamo?

Prima di iniziare ...

L'effetto delle mutazioni nei geni viene studiato utilizzando organismi facili da manipolare in laboratorio.

In uno di questi organismi, il moscerino della frutta (nome scientifico: *Drosophila melanogaster*) è stato identificato un gene che, se mutato, raddoppia la **durata della vita media dei moscerini**. A questo gene è stato dato il nome di **INDY**:

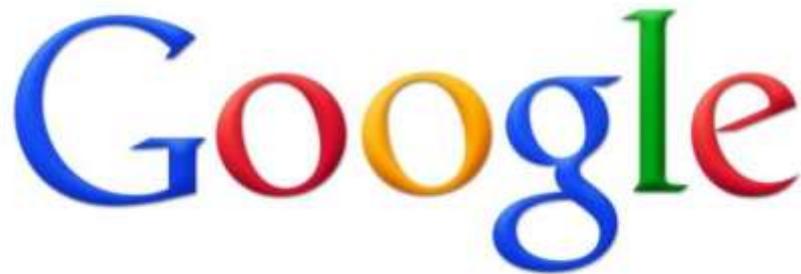
“I’m Not Dead Yet”



Esempio di accesso a banca dati biologica:

Ricerca di informazioni sul gene: **INDY**

Prima prova: usiamo strumenti “classici” per cercare informazioni ...

The image shows the Google logo in its characteristic multi-colored font (blue, red, yellow, blue, green, red) on a white background. The logo is centered within a white rectangular box.

Ricerca di informazioni sul gene: INDY

← → 📶 🔒 https://www.google.it/search?q=INDY&btnG=Cerca&hl=it&gbv=1&site=imghp

+Tu **Ricerca** Immagini Maps Play YouTube News Gmail Altro ▾

Google 🔍

Ricerca Circa 43.200.000 risultati

Web [The Official Site of IndyCar News, Drivers, Schedule & Shop ...](#) 📶
[www.indycar.com/](#) - Copia cache - Simili

Immagini Other Schedules. IZOD IndyCar Series Schedule · Firestone **Indy** Lights Schedule · Pro Mazda Championship Schedule · Cooper Tires USF2000 Schedule.

Maps [Live Timing & Scoring - Schedule - Drivers - Stats](#)

Shopping

Notizie [Indy](#) 📶
[www.indyproject.org/](#) - Copia cache - Simili

Altro An open source internet component suite comprised of popular internet protocols that is included in both Delphi 6 and Kylix. Both client and server ...
[Indy Sockets - Support - CLR - About](#)

Qualsiasi Paese
Pagine da: Italia

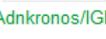
Qualsiasi lingua
Pagine in italiano

Qualsiasi data
Ultima ora
Ultime 24 ore
Ultima settimana
Ultimo mese
Ultimo anno

Tutti i risultati
Verbatim

Notizie relative a INDY

 [Houston: formula **Indy**, lo schianto di Franchitti](#)
[La Repubblica](#) - 1 giorno fa
Brutto incidente per il tre volte campione di Indianapolis Dario Franchitti sulla pista di Houston: all'ultimo giro il contatto con Takuma Sato e...

 [Indy car, terribile schianto per Franchitti - VIDEO](#)
[Adnkronos/IGN](#) [AGI - Agenzia Giornalistica Italia](#) - 18 ore fa

[Maserati **Indy** - Wikipedia](#) 📶
[it.wikipedia.org/wiki/Maserati_Indy](#) - Copia cache - Simili
La **Indy** è un modello di autovettura Maserati costruita dal 1969 al 1975. Disegnata da Virginio Vairo, fu presentata dalla Vignale al Salone dell'automobile di ...

[Formula **Indy**, auto fuori pista: feriti 13 spettatori - Video - Corriere TV](#) 📶
[video.corriere.it/...indy-auto.../8d8dfbf6-2f33-11e3-bfe9-e2443a6320c1](#)
22 ore fa ... Formula **Indy**, auto fuori pista: feriti 13 spettatori: Brutto incidente sul circuito di Houston di Indycar. All'ultimo giro della gara di domenica 6 ...

[Indy Week](#) 📶
[www.indyweek.com/](#) - Copia cache - Simili
Progressive news, culture and commentary for Raleigh, Cary, Durham and Chapel Hill, North Carolina.

Non ci siamo ... ci sono troppe cose in internet che si chiamano INDY ... e il gene non è uno dei primi risultati riportati.

Inoltre anche se trovassimo informazioni relative al gene troveremmo molti collegamenti (uno per ogni banca dati che contiene informazioni sul gene ...)

Ricerca di informazioni sul gene: INDY

RICERCA PER PAROLA CHIAVE

→ Apriamo il web browser e colleghiamoci alla divisione **NUCLEOTIDE** delle banche dati gestite da NCBI:
<http://www.ncbi.nlm.nih.gov/nucleotide>

Scegliendo la “sezione” Nucleotide di Genbank otterremo solo risultati riguardanti molecole composte da nucleotidi (DNA o RNA). Non otterremo risultati riguardanti le schede delle proteine.

Tipo di sequenze contenute: DNA e RNA ... *NON* Proteine

Ricerca di informazioni sul gene: INDY

The image shows a screenshot of the NCBI Nucleotide search interface. A blue callout box on the left contains the text: **MODALITA' DI RICERCA :
RICERCA PER PAROLA
CHIAVE**. Two red arrows originate from this box: one points to the search input field, and the other points to the 'Search' button. The search interface includes a dropdown menu set to 'Nucleotide', a search input field, and a 'Search' button. Below the search bar, there is a red banner with a notice about government funding. The main content area features a 'Nucleotide' heading and a description of the database. At the bottom, there are three columns of links: 'Using Nucleotide', 'Nucleotide Tools', and 'Other Resources'.

www.ncbi.nlm.nih.gov/nucleotide

NCBI Resources How to Sign in to NCBI

Nucleotide Nucleotide Search

Limits Advanced Help

The information on this web site remains accessible; but, due to the lapse in government funding, the information may not be up to date and we may not be able to respond to inquiries until appropriations are enacted. For updates regarding funding, please see USA.gov.

Nucleotide

The Nucleotide database is a collection of sequences from several sources, including GenBank, RefSeq, TPA and PDB. Genome, gene and transcript sequence data provide the foundation for biomedical research and discovery.

Using Nucleotide	Nucleotide Tools	Other Resources
Quick Start Guide	Submit to GenBank	GenBank Home
FAQ	LinkOut	RefSeq Home
Help	E-Utilities	Gene Home
GenBank FTP	BLAST	SRA Home
RefSeq FTP	Batch Entrez	INSDC

Scrivete **qui** il nome del gene e, poi, premete **search**

gene: INDY, ricerca per **parola chiave** NCBI Nucleotide

NCBI Resources How To Sign in to NCBI

Nucleotide Nucleotide INDY Search Save search Limits Advanced Help

Display Settings: Summary, 20 per page, Sorted by Default order **Send to:** **Filter your results:**

Found 81 nucleotide sequences. Nucleotide (53) EST (28)

Results: 1 to 20 of 53 << First < Prev Page 1 of 3 Next > Last >>

- [Drosophila melanogaster INDY transporter protein \(Indy\) mRNA, complete cds](#)
1. 2,602 bp linear mRNA
Accession: AF509505.1 GI: 27127245
[GenBank](#) [FASTA](#) [Graphics](#) [Related](#)
- [Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant A, mRNA](#)
2. 2,581 bp linear mRNA
Accession: NM_001169994.2 GI: 442633232
[GenBank](#) [FASTA](#) [Graphics](#) [Related](#)
- [Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant A, mRNA](#)
3. 2,484 bp linear mRNA
Accession: NM_079426.4 GI: 442633232
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)
- [Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant C, mRNA](#)
4. 2,600 bp linear mRNA

Otteniamo lista di «schede» informative che contengono la parola INDY. Ogni elemento è un link che porta ad una singola scheda (entry)

Filter your results:
All (53)
Bacteria (0)
[INSDC \(GenBank\) \(33\)](#)
[mRNA \(15\)](#)
[RefSeq \(20\)](#)
[Manage Filters](#)

Top Organisms [Tree]
Drosophila melanogaster (27)
Mus musculus (6)
Homo sapiens (4)
synthetic construct (4)
Oryctolagus cuniculus (3)
All other taxa (9)
More...

Find related data
Database:

gene: INDY, ricerca per **parola chiave** NCBI Nucleotide

NCBI Resources How To Sign in to NCBI

Nucleotide Nucleotide INDY Search Save search Limits Advanced Help

Display Settings: Summary, 20 per page, Sorted by Default order **Send to:** **Filter your results:**

Found 81 nucleotide sequences. Nucleotide (53) EST (28)

Results: 1 to 20 of 53 << First < Prev Page 1 of 3 Next > Last >>

[Drosophila melanogaster INDY transporter protein \(Indy\) mRNA, complete cds](#)
1. 2,602 bp linear mRNA
Accession: AF509505.1 GI: 27127245
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

[Drosophila melanogaster l'm not dead yet \(Indy\), transcript variant A, mRNA](#)
2. 2,581 bp linear mRNA
Accession: NM_079426.4 GI: 27127245
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

[Drosophila melanogaster l'm not dead yet \(Indy\), transcript variant A, mRNA](#)
3. 2,484 bp linear mRNA
Accession: NM_079426.4 GI: 27127245
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

[Drosophila melanogaster l'm not dead yet \(Indy\), transcript variant A, mRNA](#)
4. 2,600 bp linear mRNA

All (53)
Bacteria (0)
[INSDC \(GenBank\) \(33\)](#)
[mRNA \(15\)](#)
[RefSeq \(20\)](#)
[Manage Filters](#)

▼ Top Organisms [Tree](#)
Drosophila melanogaster (27)
Mus musculus (6)
Homo sapiens (4)
synthetic construct (4)
Oryctolagus cuniculus (3)
All other taxa (9)
[More...](#)

Find related data Database:

ATTENZIONE: questa banca dati è aggiornata **ogni 24 ore** ... I numeri possono essere diversi!

Abbiamo ottenuto **53** entries da Nucleotide e **28** entries da EST (espressed sequence tags) collezione di sequenze **PARZIALI** (dati meno affidabili di quelli provenienti da Nucleotide)

gene: INDY, ricerca per **parola chiave** NCBI Nucleotide

NCBI Resources How To Sign in to NCBI

Nucleotide Nucleotide INDY Search Save search Limits Advanced Help

Display Settings: Summary, 20 per page, Sorted by Default order **Send to:** Filter your results:

Found 81 nucleotide sequences. Nucleotide (53) EST (28)

Results: 1 to 20 of 53 << First < Prev Page 1 of 3 Next > Last >>

[Drosophila melanogaster INDY transporter protein \(Indy\) mRNA, complete cds](#)
1. 2,602 bp linear mRNA
Accession: AF509505.1 GI: 27127245
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

[Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant A, mRNA](#)
3. 2,484 bp linear mRNA
Accession: NM_079426.4 GI: 442633232
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

[Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant C, mRNA](#)
4. 2,600 bp linear mRNA

All (53)
Bacteria (0)
[INSDC \(GenBank\) \(33\)](#)
[mRNA \(15\)](#)
[RefSeq \(20\)](#)
[Manage Filters](#)

Top Organisms [Tree]
Drosophila melanogaster (27)
Mus musculus (6)
Homo sapiens (4)
synthetic construct (4)
Oryctolagus cuniculus (3)
All other taxa (9)
[More...](#)

Find related data
Database:

E' disponibile il conteggio delle sequenze estratte in base all'organismo da cui derivano. La lista può essere molto lunga. Per visualizzare la lista completa fate click su **More...**

[mRNA](#)

gene: INDY, ricerca per parola chiave

- [Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant D, mRNA](#)
2. 2,581 bp linear mRNA
Accession: NM_001169994.2 GI: 442633233
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

- [Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant A, mRNA](#)
3. 2,484 bp linear mRNA
Accession: NM_079426.4 GI: 442633232
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

- [Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant C, mRNA](#)
4. 2,600 bp linear mRNA
Accession: NM_168779.2 GI: 442633231
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

- [Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant B, mRNA](#)
5. 2,572 bp linear mRNA
Accession: NM_168778.2 GI: 442633230
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

- [Biston betularia I'm not dead yet \(indy\) mRNA, partial cds](#)

- ▼ Top Organisms [Tree]
- Drosophila melanogaster (27)
 - Mus musculus (6)
 - Homo sapiens (4)
 - synthetic construct (4)
 - Oryctolagus cuniculus (3)
 - All other taxa (9)
 - More...

Find related data

Database:

- Select ▼
 - Select ▲
 - Nucleotide
 - Assembly
 - BioProject
 - BioSample
 - BioSystems
 - Clone
 - dbVar
 - Gene
 - Genome
 - GEO Profiles
 - HomoloGene
 - EST
 - GSS
 - OMIM
 - PubChem BioAssay
 - PubChem Compound
 - PubChem Substance
 - PMC
 - PopSet
- more... Clear

Al di sotto della lista dedicata agli organismi di provenienza delle sequenze c'è uno strumento che permette di identificare dati correlati alle sequenze ma **PRESENTI IN ALTRE BANCHE DATI**. Per ora non usiamo questo strumento...

- [Drosophila mauritiana strain G105 I am not dead yet \(Indy\) gene, partial sequence](#)
8. 782 bp linear DNA
Accession: EF388947.1 GI: 126429573
[GenBank](#) [FASTA](#) [Graphics](#) [PopSet](#) [Related Sequences](#)

- [Drosophila sechellia strain S9 I am not dead yet \(Indy\) gene, partial sequence](#)
9. 780 bp linear DNA
Accession: EF388946.1 GI: 126429572

INDY (53)

Nucleotide

See more...

Nucleotide

Nucleotide

INDY

Search

[Save search](#)[Limits](#)[Advanced](#)[Help](#)

The information on this web site remains accessible; but, due to the lapse in government funding, the information may not be up to date, and the agency may not be able to respond to inquiries until appropriations are enacted. For updates regarding government operating status see USA.gov.

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

Send to: Filter your results:

Found 81 nucleotide sequences. Nucleotide (53) EST (28)

Results: 1 to 20 of 53

<< First Prev Page 1 of 3 Next > Last >>

[Drosophila melanogaster INDY transporter protein \(Indy\) mRNA, complete cds](#)

1. 2,602 bp linear mRNA

Accession: AF509505.1 GI: 27127245

[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

All (53)

Bacteria (0)

[INSDC \(GenBank\) \(33\)](#)

[mRNA \(15\)](#)

[RefSeq \(20\)](#)

[Manage Filters](#)

Ora cerchiamo di filtrare i risultati. Vogliamo ottenere solo le sequenze di un certo tipo di molecola: **RNA messaggero (mRNA)**. Fate click su **Limits**

3. 2,484 bp linear mRNA

Accession: NM_079426.4 GI: 442633232

[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

[Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant C, mRNA](#)

4. 2,600 bp linear mRNA

Accession: NM_168779.2 GI: 442633231

[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

▼ [Top Organisms \[Tree\]](#)

Drosophila melanogaster (27)

Mus musculus (6)

Homo sapiens (4)

synthetic construct (4)

Oryctolagus cuniculus (3)

Drosophila pseudoobscura (3)

Macaca fascicularis (2)

Drosophila pseudoobscura

pseudoobscura (2)

Gallus gallus (1)

Drosophila mauritiana (1)

Drosophila sechellia (1)

Biston betularia (1)

[Less...](#)

NCBI Resources How To Sign in to NCBI

Nucleotide Nucleotide INDY Search Help

Advanced

The information on this web site remains accessible, but, due to the lapse in government funding, the information may not be up to date, and the agency may not be able to respond to inquiries until appropriations are enacted. For updates regarding government operating status see USA.gov.

Limits

Published in the last
Any Date

Modified in the last
Any Date

Segmented Sequences
Any

Source database
Any

Molecule
mRNA

Exclude

- STSs
- working draft
- TPA
- patents

Reset Search

1: Selezionate mRNA dalla lista disponibile nella sezione **Molecule**

2: Premete il pulsante Search

Nucleotide

Nucleotide

indy



Search

[Save search](#) [Advanced](#)[Help](#)[Show additional filters](#)**Display Settings:** Summary, 20 per page, Sorted by Default order**Send to:** **Filters:** [Manage Filters](#)**Species**Animals
More ...**Molecule types**genomic DNA/RNA
mRNA
More ...**Source databases**GenBank
RefSeq
More ...**Sequence length**

Custom range...

Release date

Custom range...

Revision date

Custom range...

[Clear all](#)[Show additional filters](#)

Found 89 nucleotide sequences. Nucleotide (61) EST (28)

See [Indy I'm not dead yet](#) in the Gene database
indy reference sequences [Transcript \(4\)](#) [Protein \(4\)](#)**Results: 1 to 20 of 61**

<< First < Prev Page 1 of 4 Next > Last >>

 [Drosophila melanogaster INDY transporter protein \(Indy\) mRNA, complete cds](#)

1. 2,602 bp linear mRNA

Accession: AF509505.1 GI: 27127245

[GenBank](#) [FASTA](#) [Graphics](#) [Related S](#) [Drosophila melanogaster I'm not dead yet](#)

2. 2,581 bp linear mRNA

Accession: NM_001169994.2 GI: 442633233

[GenBank](#) [FASTA](#) [Graphics](#) [Related S](#) [Drosophila melanogaster I'm not dead yet](#)

3. 2,484 bp linear mRNA

Accession: NM_079426.4 GI: 442633232

[GenBank](#) [FASTA](#) [Graphics](#) [Related S](#) [Drosophila melanogaster I'm not dead yet](#)

L'applicazione di filtri avviene talmente di frequente che nelle versioni piu' recenti della banca dati I filtri più utilizzati sono automaticamente disponibili nella parte sinistra dell'interfaccia web.

Results by taxonTop Organisms [\[Tree\]](#)Drosophila melanogaster (27)
Mus musculus (11)
Homo sapiens (4)
synthetic construct (4)
Rattus norvegicus (3)
All other taxa (12)

More...

Find related dataDatabase: **Search details**

indy[All Fields]

[See more...](#)

The information on this web site remains accessible; but, due to the lapse in government funding, the information may not be up to date, and the agency may not be able to respond to inquiries until appropriations are enacted. For updates regarding government operating status see [USA.gov](#).

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

Limits Activated: Molecule: mRNA Change | Remove

Questa scritta ci ricorda che in **Limits** ci sono elementi attivi

Results: 15

Drosophila melanogaster INDY transporter protein (Indy) mRNA, complete cds

1. 2,602 bp linear mRNA

Accession: AF509505

GenBank FASTA

Nelle versioni + recenti dell'interfaccia web I filtri attivi sono evidenziati in grassetto

Drosophila melanogaster

2. 2,581 bp linear mRNA

Accession: NM_001166

GenBank FASTA Graphics Related Sequences

Drosophila melanogaster I'm not dead yet (Indy), transcript variant A, mRNA

3. 2,484 bp linear mRNA

Accession: NM_079426.4 GI: 442633232

GenBank FASTA Graphics Related Sequences

Drosophila melanogaster I'm not dead yet (Indy), transcript variant C, mRNA

4. 2,600 bp linear mRNA

Accession: NM_168779.2 GI: 442633231

GenBank FASTA Graphics Related Sequences

Drosophila melanogaster I'm not dead yet (Indy), transcript variant B, mRNA

5. 2,572 bp linear mRNA

Accession: NM_168778.2 GI: 442633230

Il numero di risultati è diminuito. Tutte le sequenze ottenute sono di tipo: mRNA

INSDB (GenBank) (5)
mRNA (15)
RefSeq (10)

Manage Filters

Top Organisms [Tree]

- Drosophila melanogaster (6)
- Homo sapiens (4)
- Macaca fascicularis (2)
- Mus musculus (1)
- Oryctolagus cuniculus (1)
- All other taxa (1)

More...

Find related data

Database:

Select

The information on this web site remains accessible; but, due to the lapse in government funding, the information may not be up to date, and the agency may not be able to respond to inquiries until appropriations are enacted. For updates regarding government operating status see [USA.gov](#).

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

Send to: ☑ **Filter your results:**

⚠ **Limits Activated:** Molecule: mRNA [Change](#) | [Remove](#)

Results: 15

[Drosophila melanogaster INDY transporter protein \(Indy\) mRNA, complete cds](#)

All (15)

Bacteria (0)

[INSDC \(GenBank\) \(5\)](#)

[mRNA \(15\)](#)

[RefSeq \(10\)](#)

[Manage Filters](#)

▼ **Top Organisms [Tree]**

Drosophila melanogaster (6)

Homo sapiens (4)

Macaca fascicularis (2)

Mus musculus (1)

Oryctolagus cuniculus (1)

All other taxa (1)

[More...](#)

Nonostante il filtro i risultati ottenuti corrispondono a sequenze appartenenti a più organismi. Siamo interessati solo alle sequenze di **Drosophila melanogaster** (il moscerino della frutta ... un noto organismo utilizzato in laboratorio).

Selezioniamo l'organismo da questa lista

Accession: NM_079426.4 GI: 442633232

[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

[Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant C, mRNA](#)

4. 2,600 bp linear mRNA

Accession: NM_168779.2 GI: 442633231

[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

[Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant B, mRNA](#)

5. 2,572 bp linear mRNA

Accession: NM_168778.2 GI: 442633230

Analyze these sequences

[Run BLAST](#)

Find related data

Database:

Select

The information on this web site remains accessible; but, due to the lapse in government funding, the information may not be up to date, and the agency may not be able to respond to inquiries until appropriations are enacted. For updates regarding government operating status see [USA.gov](https://www.usa.gov).

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

Send to: **Filter your results:**

Limits Activated: Molecule: mRNA [Change](#) | [Remove](#)

Results: 6

[Drosophila melanogaster INDY transporter protein \(Indy\) mRNA, complete cds](#)

All (6)

Bacteria (0)

[INSDC \(GenBank\) \(2\)](#)

[mRNA \(6\)](#)

[RefSeq \(4\)](#)

[Manage Filters](#)

Analyze these sequences

[Run BLAST](#)

Find related data

Database:

Select

[Find items](#)

I risultati ottenuti derivano da più banche dati. Vogliamo che i risultati provengano da **una sola** banca dati.

Selezioniamo RefSeq nella left bar dedicata ai filtri (nella sezione **source databases**)

Ora, tutti i risultati ottenuti corrispondono a sequenze che appartengono ad un solo organismo.

4245
[Related Sequences](#)

[I'm not dead yet \(Indy\), transcript variant D, mRNA](#)

42633233
[Related Sequences](#)

[I'm not dead yet \(Indy\), transcript variant A, mRNA](#)

[transcript variant C, mRNA](#)

Accession: NM_168779.2 GI: 442633231
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

[Drosophila melanogaster I'm not dead yet \(Indy\), tra](#)

5. 2,572 bp linear mRNA

Accession: NM_168778.2 GI: 442633230
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

[Drosophila melanogaster LD24274 full insert cDNA](#)

6. 2,488 bp linear mRNA

Accession: AY102686.1 GI: 20976879
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)

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

Send to:

[Turn Off](#) [Clear](#)

Recent activity

[Search](#)

[See more...](#)

gene: INDY, ricerca per **parola chiave**

ESERCIZIO 1 :

Al momento abbiamo ottenuto la lista di sequenze presenti in NCBI Nucleotide che :

- Contengono **INDY** nella loro scheda descrittiva
- Corrispondono a molecole di mRNA
- Corrispondono a sequenze del moscerino della frutta

Rispondete a queste domande:

- Quante sono** le sequenze ottenute?
 - Quante di esse sono presenti nella banca dati secondaria **RefSeq**?
-

gene: INDY, ricerca per **parola chiave**

ESERCIZIO 2 :

Limitare i risultati ottenuti alle sole sequenze che appartengono alla banca dati secondaria **RefSeq**.

Suggerimento: cercate qualcosa che vi permetta di restringere il numero di banche dati sulle quali viene effettuata l'estrazione.

Domanda (a cui rispondere dopo aver risolto l'esercizio) :

- Quante sequenze avete ottenuto?
-

gene: INDY, ricerca per **parola chiave**

ESERCIZIO 3 :

Dopo aver risolto l'esercizio 2 cercate informazioni collegate alle sequenze ottenute **in un'altra banca dati NCBI**. Per questo esercizio cercate informazioni provenienti dalla banca dati **Gene**.

Suggerimento: cercate in una delle slide precedenti il modo di raggiungere la lista dei risultati collegati alla lista di sequenze corrente ma presenti nella banca dati **Gene**. Prima di procedere selezionate alcune delle sequenze RefSeq di partenza. **EVITATE** di selezionare sequenze RefSeq la cui descrizione contiene la parola "chromosome" o la parola PREDICTED.

Domande (a cui rispondere dopo aver risolto l'esercizio) :

- Quanti geni ottenete?
 - A che organismo appartengono?
 - Che nome ha il/i geni ottenuti?
-

Modalità di visualizzazione dei risultati

Chi è stato attento ha notato che, nelle slide precedenti, a volte descrivevamo i risultati riferendoci ad essi come «sequenze». Questo sembra suggerire che per ogni risultato ottenuto il link che punta ad esso restituisca la sequenza della molecola.

Sarà davvero così?

Selezionate il link che punta a :

[Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant A, mRNA](#)

Modalità di visualizzazione dei risultati : **ENTRY**

Drosophila melanogaster I'm not dead yet (Indy), transcript variant A, mRNA

NCBI Reference Sequence: NM_079426.4

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

[Go to:](#)

LOCUS NM_079426 2484 bp mRNA linear INV 16-JAN-2013

DEFINITION Drosophila melanogaster I'm not dead yet (Indy), transcript variant A, mRNA.

ACCESSION NM_079426

VERSION NM_079426.4 GI:442633232

KEYWORDS RefSeq.

SOURCE Drosophila melanogaster (fruit fly)

ORGANISM [Drosophila melanogaster](#)

Eukaryota; Metazoa; Ecdysozoa; Arthropoda; Hexapoda; Insecta; Pterygota; Neoptera; Endopterygota; Diptera; Brachycera; Muscomorpha; Ephydroidea; Drosophilidae; Drosophila; Sophophora.

REFERENCE 1 (bases 1 to 2484)

AUTHORS Hoskins,R.A., Carlson,J.W., Kennedy,C., Acevedo,D., Evans-Holm,M., Frise,E., Wan,K.H., Park,S., Mendez-Lago,M., Rossi,F., Villasante,A., Dimitri,P., Karpen,G.H. and Celniker,S.E.

TITLE Sequence finishing and mapping of Drosophila melanogaster heterochromatin

JOURNAL Science 316 (5831), 1625-1628 (2007)

PUBMED 17569867

Titolo , banca dati (RefSeq) e identificativo nella banca dati

Lunghezza molecola, tipo molecola, data ultimo aggiornamento

Identificativo sequenza (ACCESSION), organismo di provenienza

Lista pubblicazioni che parlano di questa sequenza (elenco può essere lungo ...)

Modalità di visualizzazione ENTRY :

La entries sono simili a schede informative.

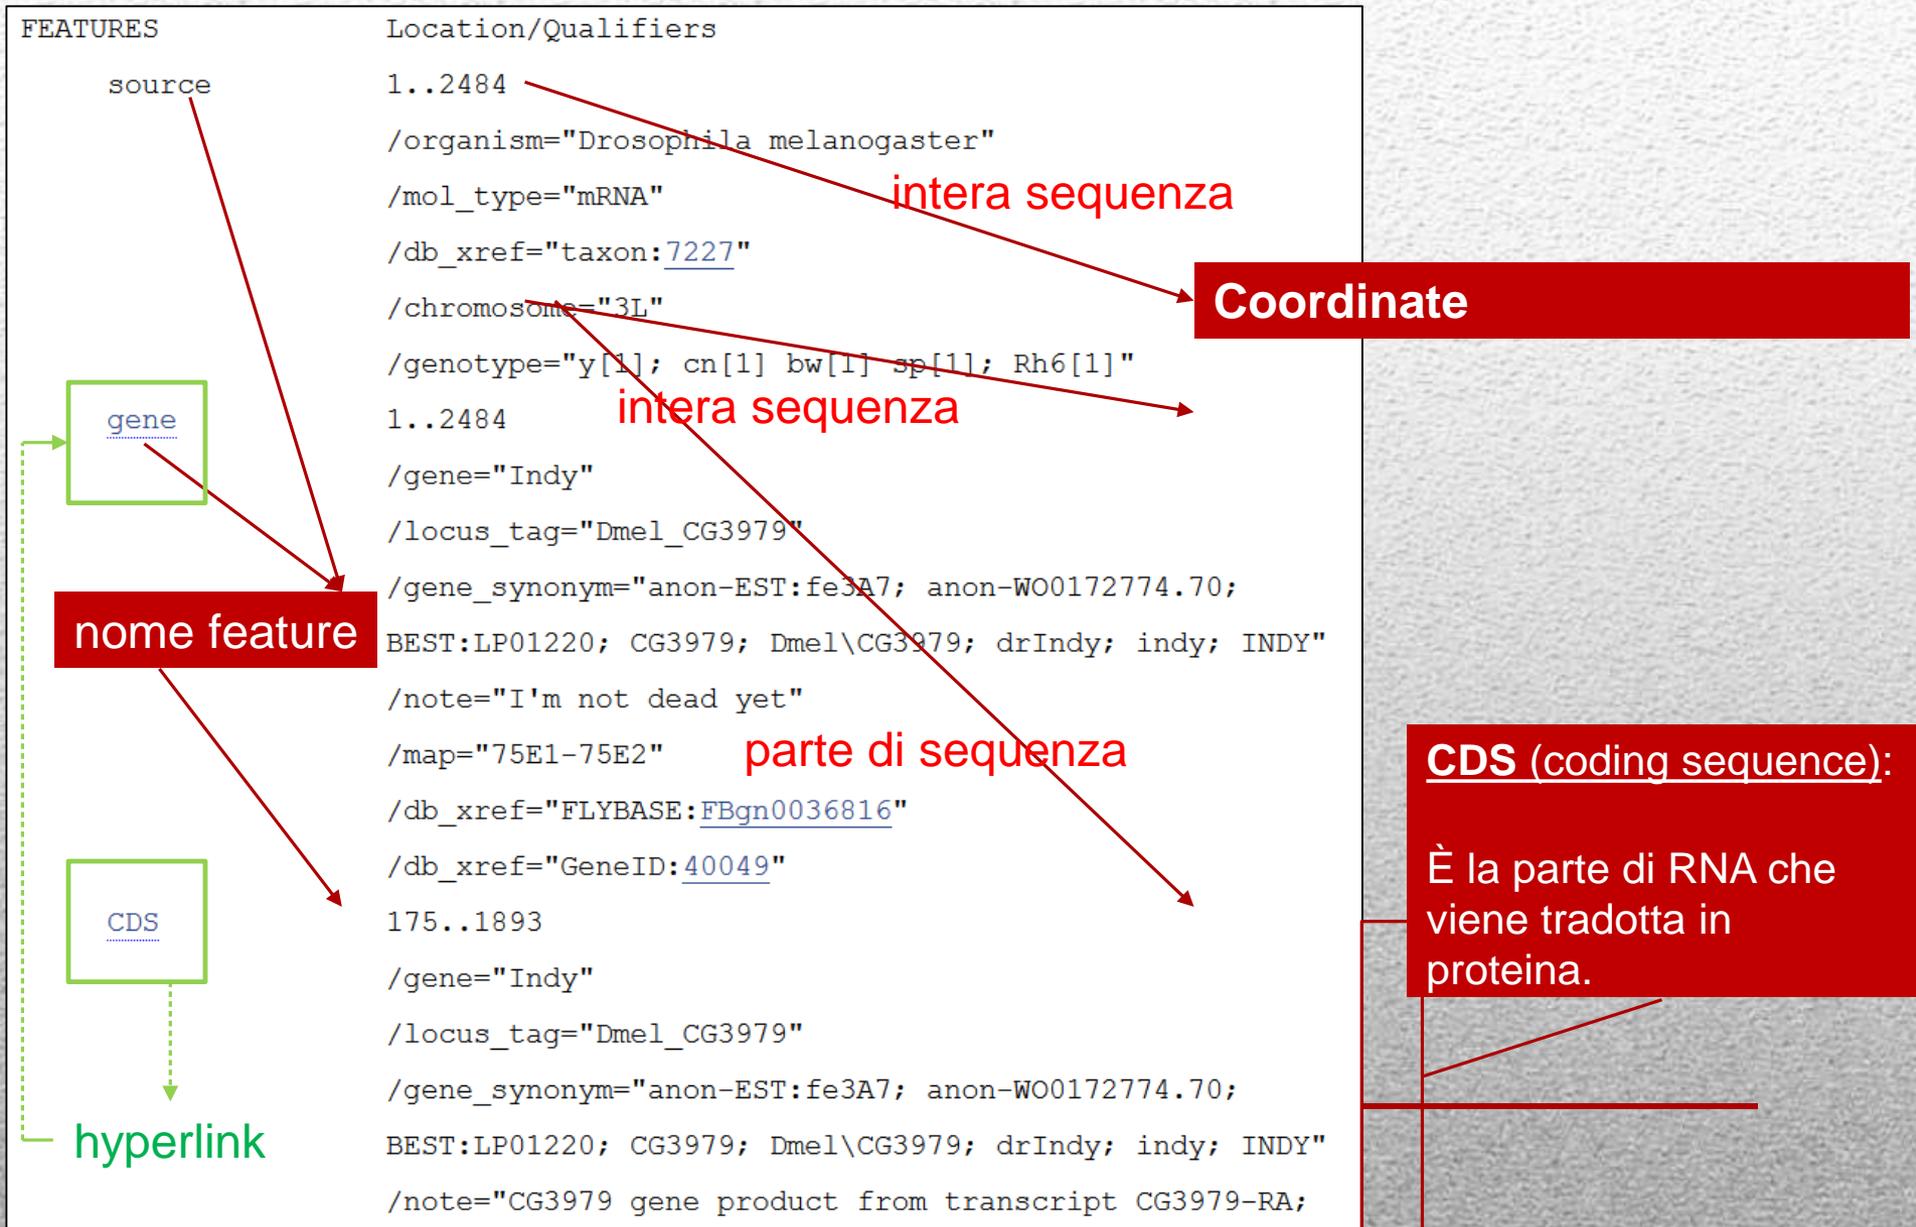
Le entries sono composte da **1 sezione** principale (descritta nella slide precedente) e **3 sezioni aggiuntive**:

- **Comment** : contiene commenti inseriti dai curatori della banca dati
- **Features** : Caratteristiche della sequenza, informazioni generali (che valgono per l'intera sequenza, e informazioni su **tratti specifici della sequenza** (ad es. note riguardanti il tratto di sequenza che va dal nucleotide 10 al nucleotide 20).
- **Sequence** : La sequenza vera e propria

Potete scegliere di andare in una sezione specifica della entry utilizzando il menù **Go to** posto immediatamente all'inizio della entry stessa.



Sezione ENTRY : Feature table



```

1 attcagtcgc gcatttcacc gtttccgaat cggacgaacc gggcgtgctt gctctcctgc
61 tgcttttcgag atcggagtc cgaataaggat ataactacaa cctaagagag aatccaagcc
121 tctctcctgcc gctagtttcg aaaaatctac acgccaccgc cactggacat caaaatggaa
181 attgaaattg gcgaacaacc ccagcctccg gtgaagtgtc ccaacttctt cgctaaccac
241 tgggaaggat tgggtgtgtt cctgggtgcc ctgctatgtc tgcctgttat gctgctaaac
301 gaaggcgccc aatttcggtg catgtacctc cttttggtaa tggccatatt ttgggttacg
361 gaagccttgc ctctctatgt gacgtccatg ataccgatg tggccttccc aataatgggt
421 ataatgagct cggatcagac ttgccgcttg tacttcaagg atacgctggg gatgttcatg
481 ggcggcatta tggtcgcctt ggctgtggag tactgtaatc tacacaaacg tcttgccctg
541 agggtaatcc agatcgtggg ctgcagtccc cgcagattac actttggcct catcatgggt
601 acaatgtttt tgagcatgtg gatttcgaac gccgcctgta ctgccatgat gtgtccgatt
661 atccaagccc tgctggagga gctgcaggct caggggtgtc gcaaaatcaa ccatgagcct
721 caataccaaa tcgttggagg caacaagaaa aacaacgagg atgagccacc ataccccacc
781 aagatcacctc tgtgctacta tctgggcatt gcctacgcct cctcgtggg tggctgtgga
841 accatcatcg gaactgccac caatcttacc ttcaagggca tctacgaggc tctgttcaag
901 aactcccacc aacagatgga ctccccacc ttcatgttct actcgtgccc atccatgttg
961 gtctacacct tgcctgacatt cgtgttccct caatggcact tcatgggtct gtggcgtccc
1021 aagagcaagg aggcacagga agtccagagg ggacgagagg gcgccgatgt cgcacaaaaa
1081 gttatcgatc agcgtacaaa ggatctgggt cccatgtcca ttacgagat ccaagtgatg
1141 attctgttca tttttatggt tgtgatgtac ttaccocgca agcccggcat ctttttggga
1201 tgggcccatt tgcctgaatt caaggacatt cgtaactcta tgcccactat ttttgcctc
1261 gtcatgtgct tcatgctgcc cgcacaattat gctttcctac gctactgcac cagacgcggt
1321 ggtccagtcg ccacgggtcc cactccatcg ctgatcacct ggaagttcat ccagaccaag
1381 gtgccatggg gtctgggtgt cctgcttggc ggtggcttcg ctttggccga aggcagcaag
1441 cagagcggca tggccaaggt gattggcaat gctctgattg gattgaaggt tctgcccaac
1501 tctgtctctc tactggtggt cactcctggg gctgtgttcc tgaccgcctt cagctccaat
1561 gtggcgattg ccaacattat tattcccgtt ctggccgaga tgtcccgtgc cattgagatc
1621 catcctctgt acctgacctc gcccgctggc ttggcctgca gtatggcctt ccacctgccg
1681 gttagtactc cgcacaacgc tttggttct ggctatgcca acattaggac gaaggacatg
1741 gccattgctg gaatcgttcc gaccatcatt accatcatca cctgtttgt tttctgccaa
1801 acctggggcc tggctgteta tccgaacctt aactcgttcc ccgaatgggc tcagatttat
1861 gccgcggcag cactgggaaa caagacgcac tagatagtta gtaattagtg taaataacta
1921 acataccctg cacagcgata aagttgagga aaatttaggg aattttaaac gaaaagtgcc
1981 tttgctgaca gcgaaaaatg tgaaaaatat ttaactatgt atacttgcac ttcagagttg
2041 cgaaaaagtt tgatacaaaa gcattaccta ctgtttagaa aaatgtgtta aaaaaaaac
2101 gtatcgcaat atactgttaa tcaggaattg aacacctggt ctacgcactc agctaaaat
2161 ttaaatacaa attaatgtta cttaatgtt gcatttagca taaaaatgga aaagattgg
2221 aaaagttaga acagtttgtt caatggcagc cctggcctgc taatatttta aataactaga
2281 ctgagagaac ttacatattc atacatgtt ttcaactgtt aaaaattttt aaatgaacaa
2341 ctactcaat acttcattgc gaacccaaat gaacacacaa atagcggtag gctaagctta
2401 aatgatactg tgtacatttt cagatgattt atgttttata tagtttgtaa aaaaatttaa
2461 ataataaaaa gctcaaacga caat

```

Sezione ENTRY : Sequence

Ogni riga contiene 60 caratteri (in questo caso nucleotidi)...

Divisi in gruppi di 10 caratteri (per facilitare conteggi)

Ogni riga inizia con il numero del primo carattere (nucleotide) della riga stessa

Modalità di visualizzazione alternative :

Oltre a visualizzare le informazioni sulla sequenza in modalità ENTRY (a volte detta modalità GenBank) è possibile visualizzare le informazioni in modo diverso.

E' possibile selezionare la modalità di visualizzazione grazie al menù **Display Settings** posto immediatamente all'inizio della entry.

- Summary: solo informazioni principali
- FASTA / FASTA(text): solo sequenza
- GenBank (full) informazioni estese

Dopo aver selezionato la modalità di display premete il pulsante **Apply**. Provate Fasta(text).

Display Settings: GenBank

Format

- Summary
- GenBank
- GenBank (full)
- FASTA
- FASTA (text)
- Graphics
- ASN.1
- Revision History
- Accession List
- GI List

Apply

VERSION NM_079426.4 GI:442633232
KEYWORDS RefSeq.

```
>gi|442633232|ref|NM_079426.4| Drosophila melanogaster I'm not dead yet transcript variant A, mRNA
```

```
ATTAGTTCGCGCATTTCACCGTTTCCGAATCGGACGAACCGGGCGTGCTTGCTCTCCTGCTGCTTTTCGAG
ATCGAGTCCCGATAAAGGATATAACTACAACCTAAAGAGGAATCCAAGCCTCCTCCTGCCGCTAGTTTCG
AAAATCTACACGCCACCGCCACTGGACATCAAATGGAAATTGAAATTGGCGAACAACCCAGCCTCCG
BTGAGTGCTCCTCAACTTCTTCGCTAACCACTGGAAGGGATTGGTTGTGTTTCTGGTGCCGCTGCTATGTC
TGCCTGTTATGCTGCTAAACGAAGGCGCCGAATTTCCGTTGCATGTACCTCCTTTTGGTAATGGCCATATT
TTGGTTACGGAAGCCTTGCCTCTCTATGTGACGTCCATGATACCGATTGTGGCCCTTCCAATAATGGGT
ATAATGAGCTCGGATCAGACTTGCCTGTTACTTCAAGGATACGCTGGTGATGTTTCATGGGCGGCATTA
TGGCGCCCTGGCTGTGGAGTACTGTAATCTACACAAACGCTTGCCTTGAGGGTAATCCAGATCGTGGG
CTGAGTCCCCGAGATTACACTTTGGCCTCATCATGGTTACAATGTTTTTGGAGCATGTGGATTTGAAAC
ECCGCTGTACTGCCATGATGTGTCCGATTTATCCAAGCCGTGCTGGAGGAGCTGCAGGCTCAGGGTGTCT
GCAAAATGAGTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCT
ATAACCGTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCT
ACCATGTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCT
AACAGTATTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCT
CGTGTATTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCT
GGACGTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCT
TTCACCGTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCT
CTTTTTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCT
ETCATGTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCT
CCACGGTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCT
CCTGCTTGGCGGTGGCTTCGCTTTGGCCGAAGTCAGCAAGCAGAGCGGCATGGCCAAGCTGATTGGCAAT
GCTCTGATTGGATTGAAGGTTCTGCCAACTCTGCTCCTTACTGGTGGTCATCCTGGTGGCTGTGTTCC
TGACCCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCTTCCGCT
CATTGAGATCCATCCTCTGTACCTGATCCTGCTCCGCTGGCTTGGCCTGCAGTATGGCCTTCCACCTGCCG
GTTAGTACTCCGCCAACGCTTTGGTTGCTGGCTATGCCAACATTAGGACGAAGGACATGGCCATTGCTG
GAATCGGTCCGACCATCATTACCATCATCACCCTGTTTTGTTTTCTGCCAAACCTGGGGCCTGGTCTCTA
TCCGAACCTTAACTCGTTCCCGGAATGGGCTCAGATTTATGCCGCGGCAGCACTGGGAAACAAGACGCAC
TAGATAGTTAGTAATTAGTGTAATAAATAACTAACATACCCGTCACAGCGATAAAGTTGAGGAAAAATTTAGGG
AATTTTAAACGAAAAGTGCCTTTGCTGACAGCGAAAAATGTGAAAAATATTTAACTATGTATACTTGCAT
TTCAGAGTTGCGAAAAGTTTTGATACAAAAGCATTACCTACTGTTTAGAAAAATGTGTTAAAAAAAAC
STATCGCAATATACTGTTAATCAGGAATTGAACACCTGGTCTACGCACTCAGCTAAATATTTAAATACAA
ATTAATGTTACTTAAATGTTGCATTTAGCATAAAAAATGGAAAAGATTGGAAAAGTTAGAACAGTTTGT
CAATGGCAGCCCTGGCCTGCTAATATTTTAAATAACTAGACTGAGAGAACTTACATATTCATACATGTTT
TTCAACTTGTAATAAATTTTTAAATGAACAACCTCAATACTTCATTGCGAACCAAAATGAACACACAA
ATAGCGGTAGGCTAAGCTTAAATGATACTGTGTACATTTTCAGATGATTTATGTTTTATATAGTTTGTA
AAAATATTAATAATAAAAAAGCTCAAACGACAAT
```

FORMATO FASTA:

- Prima riga: simbolo > seguito da informazioni sulla sequenza
- Dalla seconda riga in poi: Sequenza

Display mode: FASTA (text)

Il formato di visualizzazione FASTA (text) mostra solo la sequenza (senza spazi vuoti e senza numeri). Inoltre **non contiene caratteri invisibili** (a differenza delle altre modalità di visualizzazione della sequenza).

In questo formato la sequenza può essere usata come input per programmi che effettuano analisi su di essa (ad esempio composizione: frequenza caratteri A,C,G e T in questo caso)

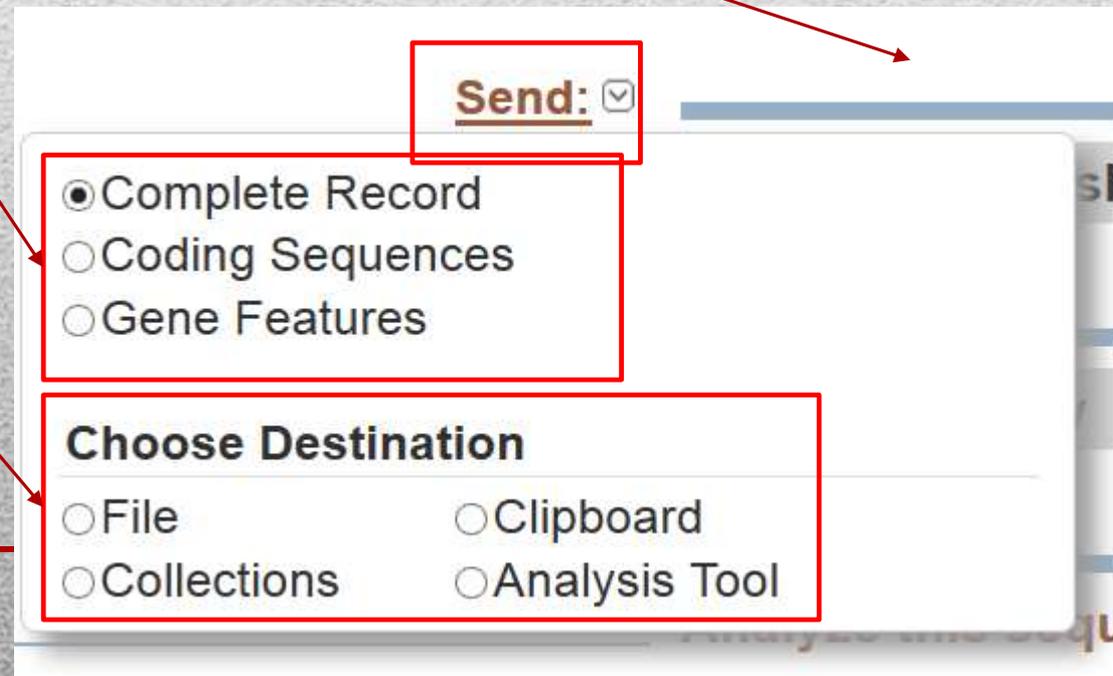
Una volta che abbiamo reperito le informazioni che cerchiamo come le utilizziamo?

Abbiamo varie opzioni ... la più banale è fare una stampa ma questa via presenta diverse limitazioni e serve solo quando abbiamo necessità, ad esempio, di aggiungere delle note manuali. Esiste un modo migliore per **esportare e/o salvare in un file** solo le informazioni di cui abbiamo bisogno.

E' possibile esportare dati (operazione in **2 passaggi**) tramite menù **Send** :

1. **Selezionate** le informazioni a cui siete interessati (ad es. **Complete Record**)

2. **Selezionate** la destinazione di queste informazioni (appunti, file, strumenti di analisi, ...)

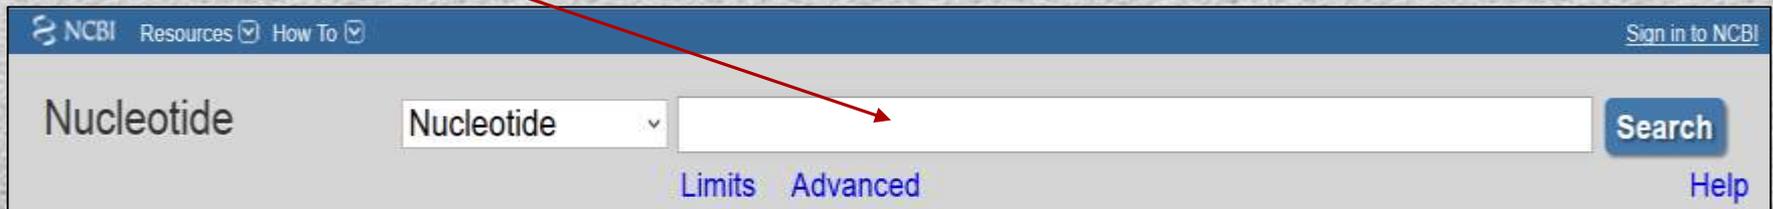


Riepilogo : ricerca per parola chiave

Quella che abbiamo visto è la modalità classica di ricerca di informazione nelle banche dati biologiche. Essa si definisce «ricerca per parola chiave».

Nel nostro esempio la parola chiave era il **nome del gene** (INDY).

In origine non esistevano tutti gli strumenti che abbiamo visto (i menù nell'interfaccia web). L'unica modalità con cui era possibile raffinare la ricerca era quella di costruire complesse stringhe di testo da inserire nella casella di ricerca dove avevamo inserito la parola **INDY**.



The screenshot shows the top navigation bar of the NCBI website with links for 'Resources' and 'How To', and a 'Sign in to NCBI' button. Below this is a search interface with the label 'Nucleotide' on the left. A dropdown menu is set to 'Nucleotide'. To the right is a large white search input field. A red arrow points from the text 'casella di ricerca' in the previous paragraph to this input field. Below the search field are links for 'Limits' and 'Advanced'. On the far right, there is a blue 'Search' button and a 'Help' link.

Anche se in maniera non evidente ... il sistema funziona ancora così ... solo che la stringa di ricerca viene costruita dinamicamente in base alle scelte che operiamo sugli strumenti dell'interfaccia web

Costruzione **dinamica** stringa di ricerca (I)

Nucleotide [Save search](#) [Limits](#) [Advanced](#) [Help](#)

The information on this web site remains accessible; but, due to the lapse in government funding, the information may not be up to date, and the agency may not be able to respond to inquiries until appropriations are enacted. For updates regarding government operating status see [USA.gov](#).

Display Settings: Summary, 20 per page, Sorted by Default order **Send to:** **Filter your results:**

Limits Activated: Molecule: mRNA, Source database: RefSeq [Change](#) | [Remove](#)

Results: 10

- [Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant D, mRNA](#)
1. 2,581 bp linear mRNA
Accession: NM_001169994.2 GI: 442633233
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)
- [Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant A, mRNA](#)
2. 2,484 bp linear mRNA
Accession: NM_079426.4 GI: 442633232
[GenBank](#) [FASTA](#) [Graphics](#) [Related Sequences](#)
- [Drosophila melanogaster I'm not dead yet \(Indy\), transcript variant C, mRNA](#)
3. 2,600 bp linear mRNA
Accession: NM_168779.2 GI: 442633231

Filter your results:

- All (10)
- Bacteria (0)
- INSDC (GenBank) (0)
- [mRNA \(10\)](#)
- [RefSeq \(10\)](#)

[Manage Filters](#)

Top Organisms [Tree]

- Homo sapiens (4)
- Drosophila melanogaster (4)
- Mus musculus (1)
- Oryctolagus cuniculus (1)

Analyze these

Quando cerchiamo la parola chiave INDY ed impostiamo nei limiti (Limits) tipo di molecola: mRNA e source database: RefSeq

Costruzione **dinamica** stringa di ricerca (II)

Mano a mano che aggiungiamo dei filtri il sistema aggiorna una stringa di testo che specifica tutti i passaggi della nostra ricerca ...

E li utilizza per aggiornare una stringa di testo che, se salvata ci permetterà di ritornare al sito e riefettuare la ricerca incollando la stringa nella casella posta di lato al pulsante **Search** (e premendo **Search**)

Search details

```
INDY[All Fields]
AND
(biomol_mRNA[PROP]
AND
srcdb_refseq[PROP])
```

Search

See more...

INDY[All Fields] AND (biomol_mRNA[PROP] AND srcdb_refseq[PROP])

Quando cerchiamo la parola chiave INDY ed impostiamo nei limiti (Limits) tipo di molecola: mRNA e source database: RefSeq

Ricerca mediante similarità di sequenza

Abbiamo potuto trovare informazioni sul gene INDY secondo le modalità descritte nelle slide precedenti solo perchè avevamo a disposizione una parola chiave da utilizzare (**INDY**) ... ma come possiamo cercare informazioni per una molecola **di cui non sappiamo nulla?**

Questa situazione si verifica quando otteniamo la sequenza in laboratorio. L'unica cosa che otteniamo è, appunto, la sequenza. Nient'altro. **In questo caso una ricerca per parola chiave è impossibile da realizzare!**

Ricerca mediante similarità di sequenza

Supponiamo di aver ottenuto, in laboratorio, questa sequenza di cui non sappiamo nulla:

>Sequenza_sconosciuta

```
CTCGCAGGCTCCAGGGGCGGGGCGTGGCCGGGGCGCAGCGACGGGCGCGGAGGTCCGGCCGGGCGCGCGC  
GCCCCGCCACACGCACGCCGGGCGTGCCAGTTTATAAAGGGAGAGCAAGCAGCGAGTCTTGAAGCTC  
TGTTTGGTGCTTTGGATCCATTTCCATCGGTCTTACAGCCGCTCGTCAGACTCCAGCAGCCAAGATGGT  
GAAGCAGATCGAGAGCAAGACTGCTTTTCAGGAAGCCTTGGACGCTGCAGGTGATAAACTTGTAGTAGTT  
GACTTCTCAGCCACGTGGTGTGGGCCTTGCAAAATGATCAAGCCTTTCTTTCATGATGTTGCTTCAGAGT  
GTGAAGTCAAATGCATGCCAACATTCCAGTTTTTTAAGAAGGGACAAAAGGTGGGTGAATTTTCTGGAGC  
CAATAAGGAAAAGCTTGAAGCCACCATTAATGAATTAGTCTAATCATGTTTTCTGAAAATATAACCAGCC  
ATTGGCTATTTAAAACCTTGTAATTTTTTTAATTTACAAAAATATAAAATATGAAGACATAAACCCAGTTG  
CCATCTGCGTGACAATAAAACATTAATGCTAACACTTTTTAAAACCGTCTCATGTCTGAATAGCTTTCAA  
AATAAATGTGAAATGGTCATTTAATGTATTTTCTATATTCTCAATCACTTTTTAGTAACCTTGTAGGCC  
ACTGATTATTTAAGATTTTAAAAATTATTATTGCTACCTAATGTATTGCTACAAAAATCTCTTGTTGG  
GGGCAATGCAGGTAATAAAGTAGTATGTTGTTATTTGTAAAAA
```

E' una semplice sequenza **FASTA (text)** ... potete scaricarla (sottoforma di file di testo) dalla sezione dedicata al materiale didattico presente sul sito del laboratorio.

Aprire il file, selezionare tutto e copiare negli appunti di Windows

Ricerca mediante similarità di sequenza

```
>seq_sconosciuta  
ATTCGATCTAGCGATCTA  
CTAATTCGAGGCGATCTA  
TCAGCGACTAGCTAGCAT  
CGACTACGATCACC...
```



Ricerca in una collezione
di sequenze di sequenze
simili a quella che si usa
per effettuare
l'interrogazione (**QUERY**)

Punti da ricordare:

- Il risultato è una **lista di sequenze** ordinate dalla più simile alla nostra sequenza QUERY alla meno simile.
- Al posto di una parola chiave utilizziamo una **sequenza**.

```
>seq_1  
ATTCGGATCTAGGCTATC  
TAGCGATCGACTGACTAG  
CTAGCTAGCATCGATCAC  
  
>seq_2  
ATTCGAGCGATCTTTTTA  
TTATATCGGATTTCGATCG  
ATCGATCGACTAAAAAA  
  
>seq_3  
ATTCGGATCTAGGCTATC  
TAGCGATCGACTGACTAG  
CTAGCTAGCATCGATCAC
```

Ricerca tramite similarità di sequenza

Apriamo il web browser e colleghiamoci al sito dello strumento di ricerca per similarità di sequenza **BLAST**, **B**asic **L**ocal **A**lignment **S**earch **T**ool (NCBI):

<http://blast.ncbi.nlm.nih.gov/Blast.cgi>

.. nella sezione **Basic Blast**, seguite il link **nucleotide blast**

Enter Query Sequence

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

```
>Sequenza_sconosciuta
CTCGCAGGCTCCAGGGGCGGGGCGTGGCCGGGGCGCAGCGACGGGCGGGAGGTCCGGCCGGGCGCGCGC
GCCCCCGCCACACGCACGCCGGGGCGTGCCAGTTTATAAAGGGAGAGAGCAAGCAGCGAGTCTTGAAGCTC
TGTTTGGTGCCTTGGATCCATTTCCATCGGTCTTACAGCCGCTCGTCAGACTCCAGCAGCCAAGATGGT
GAAGCAGATCGAGAGCAAGACTGCTTTTCAGGAAGCCTTGGACGCTGCAGGTGATAAACTTGTAGTAGTT
GACTTCTCAGCCACGTGGTGTGGGCCTTGCAAAATGATCAAGCCTTCTTTCATGATGTTGCTTCAGAGT
GTGAAGTCAAATGCATGCCAACATTCCAGTTTTTTAAGAAGGGACAAAAGGTGGGTGAAATTTTCTGGAGC
```

Query subrange [Clear](#)

From

To

Or, upload file

Nessun file selezionato. [Clear](#)

Job Title

Sequenza_sconosciuta

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

Align two or more sequences [Clear](#)

Incollate qui la sequenza sconosciuta

Choose Search Set

Database

Human genomic + transcript Mouse genomic + transcript Others (nr etc.):

Reference RNA sequences (refseq_rna) [Clear](#)

Organism

Optional

Enter organism name or id--completions will be suggested

Enter organism common name, binomial, or tax id. Only 20 top taxa will be shown

Exclude

Optional

Models (XM/XP) Uncultured/environmental sample sequences

Entrez Query

Optional

Enter an Entrez query to limit search [Clear](#)

Come collezione di sequenze all'interno della quale effettuare la ricerca scegliete RefSeq

Program Selection

Optimize for

Highly similar sequences (megablast)

More dissimilar sequences (discontiguous megablast)

Somewhat similar sequences (blastn)

Choose a BLAST algorithm [Clear](#)

Scegliamo il tipo di ricerca che ritorna solo sequenza altamente simili (per velocizzare l'analisi)

Search database Reference RNA sequences

Show results in a new window

Scegliamo di visualizzare i risultati in una nuova finestra e premiamo BLAST

Sequenza_sconosciuta

RID [5DTJ5PTT016](#) (Expires on 10-12 01:39 am)

Query ID |d|10343
Description Sequenza_sconosciuta
Molecule type nucleic acid
Query Length 826

Database Name refseq_ma
Description NCBI Transcript Reference Sequences
Program BLASTN 2.2.28+ [►Citation](#)

Other reports: [►Search Summary](#) [[Taxonomy reports](#)] [[Distance tree of results](#)]

Otteniamo un output
composto da varie parti

Graphic Summary

Distribution of 154 Blast Hits on the Query Sequence

Mouse over to see the define, click to show alignments



Sommario (in
forma grafica)

Abbiamo ottenuto
154 corrispondenze

Questa è la **sequenza
QUERY** (in italiano
sequenza sonda)

Queste sono le
sequenze restituite
dalla ricerca...
La PRIMA (sequenza
più simile alla query) ha
la **stessa lunghezza**
della query

Descrizione sequenze estratte (lista risultati)

Sequences producing significant alignments:

Select: [All](#) [None](#) Selected:0

[Alignments](#) [Download](#) [GenBank](#) [Graphics](#) [Distance tree of results](#)

	Description	Max score	Total score	Query cover	E value	Ident	Accession
<input type="checkbox"/>	Homo sapiens thioredoxin (TXN), transcript variant 2, mRNA	1526	1526	100%	0.0	100%	NM_001244938.1
<input type="checkbox"/>	PREDICTED: Gorilla gorilla gorilla thioredoxin, transcript variant 3 (TXN), mRNA	1443	1443	97%	0.0	99%	XM_004048428.1
<input type="checkbox"/>	PREDICTED: Pan troglodytes thioredoxin (TXN), mRNA	1437	1437	97%	0.0	99%	XM_003951491.1
<input type="checkbox"/>	PREDICTED: Macaca fascicularis thioredoxin (TXN), transcript variant X2, mRNA	950	950	73%	0.0	95%	XM_005581101.1
<input type="checkbox"/>	Homo sapiens thioredoxin (TXN), transcript variant 1, mRNA	911	1529	100%	0.0	99%	NM_003329.3
<input type="checkbox"/>	PREDICTED: Gorilla gorilla gorilla thioredoxin, transcript variant 1 (TXN), mRNA	856	1446	97%	0.0	99%	XM_004048426.1
<input type="checkbox"/>	PREDICTED: Pan troglodytes thioredoxin, transcript variant 1 (TXN), mRNA	850	1440	97%	0.0	99%	XM_001142154.2
<input type="checkbox"/>	PREDICTED: Nomascus leucogenys thioredoxin, transcript variant 2 (TXN), mRNA	828	1028	70%	0.0	98%	XM_004087002.1
<input type="checkbox"/>	PREDICTED: Nomascus leucogenys thioredoxin, transcript variant 1 (TXN), mRNA	828	1027	70%	0.0	98%	XM_003260469.2

La prima sequenza della lista copre l'intera lunghezza della sequenza Query ed è anche identica alla sequenza Query.

Abbiamo identificato la sequenza sconosciuta!

Descrizione sequenze estratte (lista risultati)

Sequences producing significant alignments:

Select: [All](#) [None](#) Selected:0

[Alignments](#) [Download](#) [GenBank](#) [Graphics](#) [Distance tree of results](#)

Description	Max score	Total score	Query cover	E value	Ident	Accession
<input type="checkbox"/> Homo sapiens thioredoxin (TXN), transcript variant 2, mRNA	1526	1526	100%	0.0	100%	NM_001244938.1
<input type="checkbox"/> PREDICTED: Gorilla gorilla gorilla thioredoxin, transcript variant 3 (TXN), mRNA	1443	1443	97%	0.0	99%	XM_004048428.1
<input type="checkbox"/> PREDICTED: Gorilla gorilla gorilla thioredoxin, transcript variant 2, mRNA	1437	1437	97%	0.0	99%	XM_003951491.1
<input type="checkbox"/> PREDICTED: Gorilla gorilla gorilla thioredoxin, transcript variant 1 (TXN), mRNA	856	1446	97%	0.0	99%	XM_004048426.1
<input type="checkbox"/> PREDICTED: Pan troglodytes thioredoxin, transcript variant 1 (TXN), mRNA	850	1440	97%	0.0	99%	XM_001142154.2
<input type="checkbox"/> PREDICTED: Nomascus leucogenys thioredoxin, transcript variant 2 (TXN), mRNA	828	1028	70%	0.0	98%	XM_004087002.1
<input type="checkbox"/> PREDICTED: Nomascus leucogenys thioredoxin, transcript variant 1 (TXN), mRNA	828	1027	70%	0.0	98%	XM_003260469.2

Link ai risultati del confronto tra la query e la prima sequenza ottenuta

Link alla **ENTRY** della prima sequenza ottenuta

Ora abbiamo a disposizione due collegamenti che ci permettono di ottenere ulteriori informazioni. **Seguiamo il link che riporta l'accession (codice identificativo) della sequenza.** In questo esempio è : **NM_001244938.1**

Nucleotide

Nucleotide

Search

[Limits](#) [Advanced](#)[Help](#)

The information on this web site remains accessible; but, due to the lapse in government funding, the information may not be up to date, and the agency may not be able to respond to inquiries until appropriations are enacted. For updates regarding government operating status see USA.gov.

[Display Settings:](#) GenBank[Send:](#)

Homo sapiens thioredoxin (TXN), transcript variant 2, mRNA

NCBI Reference Sequence: NM_001244938.1

[FASTA](#) [Graphics](#)[Go to:](#)

LOCUS	NM_001244938	826 bp	mRNA	linear	PRI 05-OCT-2013
DEFINITION	Homo sapiens thioredoxin (TXN), transcript variant 2, mRNA.				
ACCESSION	NM_001244938				
VERSION	NM_001244938.1 GI:349732255				
KEYWORDS	RefSeq.				
SOURCE	Homo sapiens (human)				

Change region shown

Customize view

Analyze this sequence[Run BLAST](#)[Pick Primers](#)[Highlight Sequence Features](#)[Find in this Sequence](#)

In questo modo abbiamo raggiunto la **ENTRY** del gene TXN (tioredossina) umano. De qui in poi vale tutto quello che abbiamo già visto nella sezione dedicata alla ricerca per parola chiave.

Ricerca per **similarità di sequenza**

Domanda 1 :

- a) A che banca dati appartiene la entry che abbiamo appena estratto (TXN human) ?
- b) Pensate che ci sia una relazione tra la risposta della domanda 1.a e le scelte che avete fatto **PRIMA** di effettuare la ricerca BLAST (suggerimento: riguardate la slide n. 53)? Se si quale?

Esercizio 1 :

Scoprite tutto quello che potete sulla sequenza **Sequenza_sconosciuta_2** presente nello stesso file da cui avete copiato la sequenza, in formato FASTA (text), di Sequenza_Sconosciuta.

- Che tipo di molecola è (DNA o mRNA)?
 - Come si chiama il gene da cui deriva?
 - A quale organismo appartiene questa sequenza?
-

Riepilogo

Le banche dati biologiche sono collezioni di informazioni riguardanti molecole presenti nei viventi. Esse hanno dimensioni considerevoli e quindi vengono rese disponibili al pubblico **unitamente a strumenti specializzati** per svolgere ricerche al loro interno.

Esistono principalmente due tipi di ricerca all'interno di una banca dati biologica:

- Ricerca per **parola chiave** : permette di estrarre una o più sequenze fornendo una serie di parole chiave opportunamente combinate. La stringa di interrogazione può essere costruita dinamicamente grazie ad una serie di filtri progressivi. Non può essere utilizzata in assenza di informazioni sull'obiettivo della nostra ricerca.
- Ricerca per **similarità di sequenza** : al posto delle parole chiave si utilizza una sequenza sonda che serve per trovare le sequenze più simili ad essa in banca dati.

Indipendentemente dalla modalità di ricerca adottata è possibile raggiungere delle schede (entries) che contengono molti collegamenti ad altre informazioni sulla sequenza presenti in altre banche dati

Docente: **Matteo Re**
re@di.unimi.it
matteo.re@unimi.it

Università degli
studi di milano



Banche dati biologiche

A.A. 2014-2015 semestre I

5

Accesso diretto

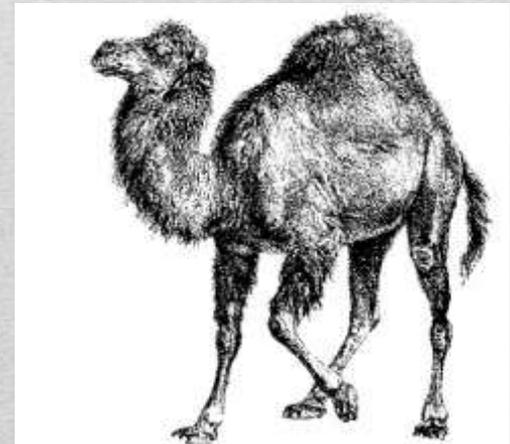
- **Interrogazione diretta di banche dati biologiche**

- Accesso mediante Perl
- Linguaggio SQL

- **Biologia computazionale**

- Struttura (db schema) Ensembl database
- API Ensembl
- Estrazione di annotazioni
- Estrazione di sequenze

- **Obiettivi**



•Linee guida

- **Il livello di complessità di questa esercitazione è medio-alto**
 - Cercate di risolvere il problema dopo aver compreso gli schemi dai database presentati
 - I template script di questa esercitazione sono estremamente semplici ... non fatevi ingannare da questa apparente semplicità **la difficoltà dell'esercizio risiede nella necessità di costruire le interrogazioni in linguaggio SQL** e di integrarle in maniera opportuna negli script. Come sempre il codice che mi invierete DEVE essere commentato (in questo caso il commento riguarderà principalmente le query SQL).
- **Modalità di svolgimento dell'esercitazione:**
 - Nessun file da scaricare questa volta ... lo script di base per effettuare le query SQL è molto contenuto ed è riportato in queste slide.
 - Lo stesso vale per gli esercizi sulle API Ensembl core (trovate molti più esempi risolti mediante le API che mediante SQL... Questo dipende dal fatto che la difficoltà intrinseca degli esercizi SQL sta nella necessità **di dover esplorare lo schema della banca dati Ensembl**).

•Tipi di banche dati biologiche:

•Collettori primari:

- Sequenze sottomesse direttamente dai laboratori di ricerca alle banche dati Genbank, DDBJ ed EMBL. Qualità bassa, a volte contengono errori di annotazione.

•Banche dati secondarie:

- Le informazioni contenute in queste banche dati sono curate manualmente: qualità superiore. Spesso sono banche dati specializzate nel senso che contengono un solo tipo di informazione (seq. proteiche, seq. di trascritti, ...).

•Banche dati associate a progetti genomici:

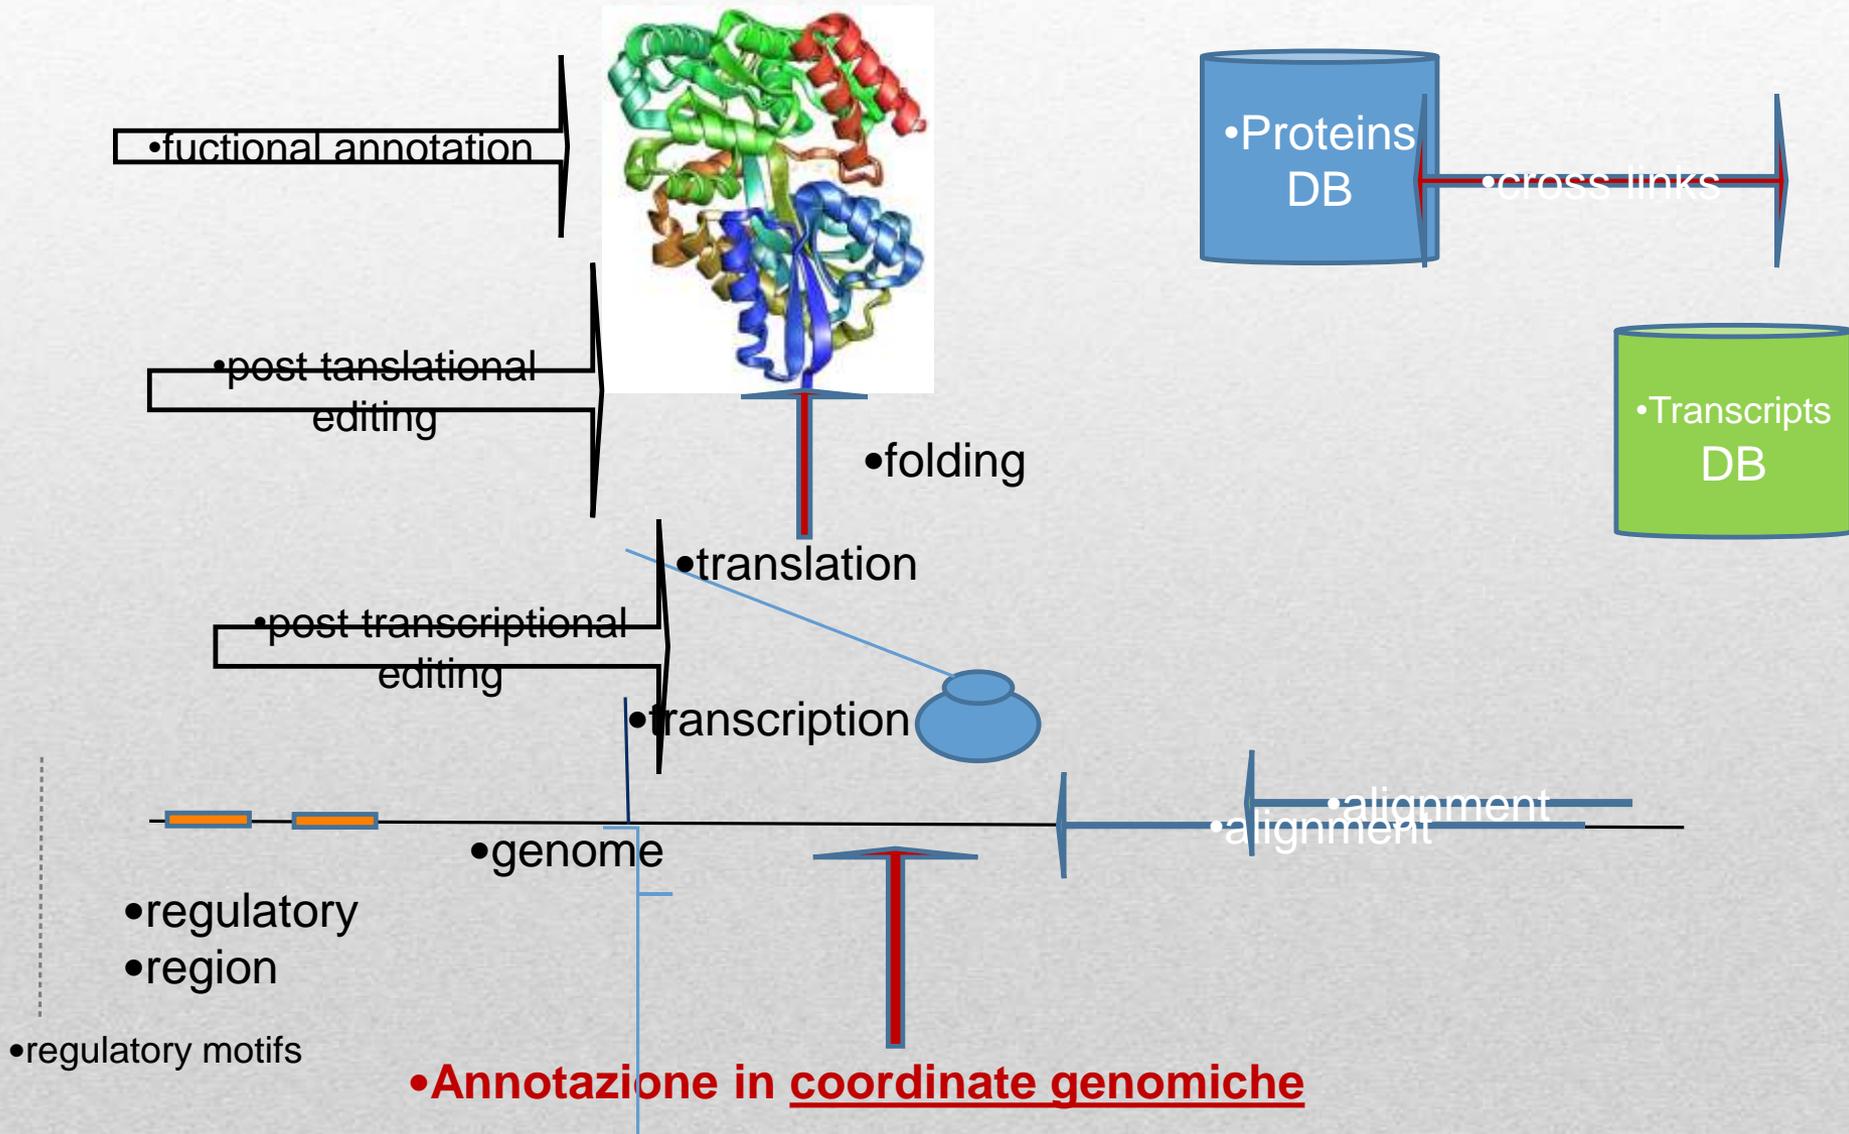
- Le sequenze genomiche sono un tipo di dato molto particolare. Esse si prestano ad essere annotate a diversi livelli. A causa di questa caratteristica la loro annotazione richiede l'utilizzo di informazioni derivanti da un numero consistente di banche dati esterne. Come conseguenza le banche dati associate a progetti di annotazione genomica sono gli strumenti di elezione per **INTEGRARE** il contenuto di altre banche dati in modo da ottenerne una **rappresentazione unitaria**.

•Tipi di dati biologici (solo alcuni)

- Livello dei trascritti** misurati in particolari condizioni: esistono siti dedicati a collezioni di esperimenti microarray (es. NCBI Gene Expression Omnibus (NCBI GEO), <http://www.ncbi.nlm.nih.gov/geo/>)
- Annotazione funzionale di proteine**: «funzionale» viene utilizzato come termine a «basso» livello, annotazione di una sequenza proteica **residuo per residuo**. Molti tipi di annotazione: siti di fosforilazione, presenza di ponti disolfuro, struttura secondaria della proteina, struttura 3D della proteina. Sito di riferimento è una banca dati che integra le informazioni di diverse banche dati: Uniprot (Universal Protein Resource, <http://www.uniprot.org/>) .
- Annotazione funzionale di geni**: «funzionale» viene utilizzato come termine ad «alto» livello. Creazione di vocabolari controllati a partire da materiale reperibile in **LETTERATURA**. Team di curatori assegnano ogni gene ai termini dei vocabolari (**ontologie**). Sito di riferimento: Gene Ontology (<http://www.geneontology.org/>) .
- Variabilità genetica**: Database dedicati a SNP (es. NCBI dbSNP) e a progetti su vasta scala (HapMap). Esistono inoltre databases dedicati a studi di associazione genome-wide (es GWAS central) <http://www.gwascentral.org/index>.

•E MOLTI ALTRI ...

•Esistono molti tipi di banche dati ... perché quelle associate a progetti di annotazione genomica dovrebbero essere considerate più «importanti» di altre?

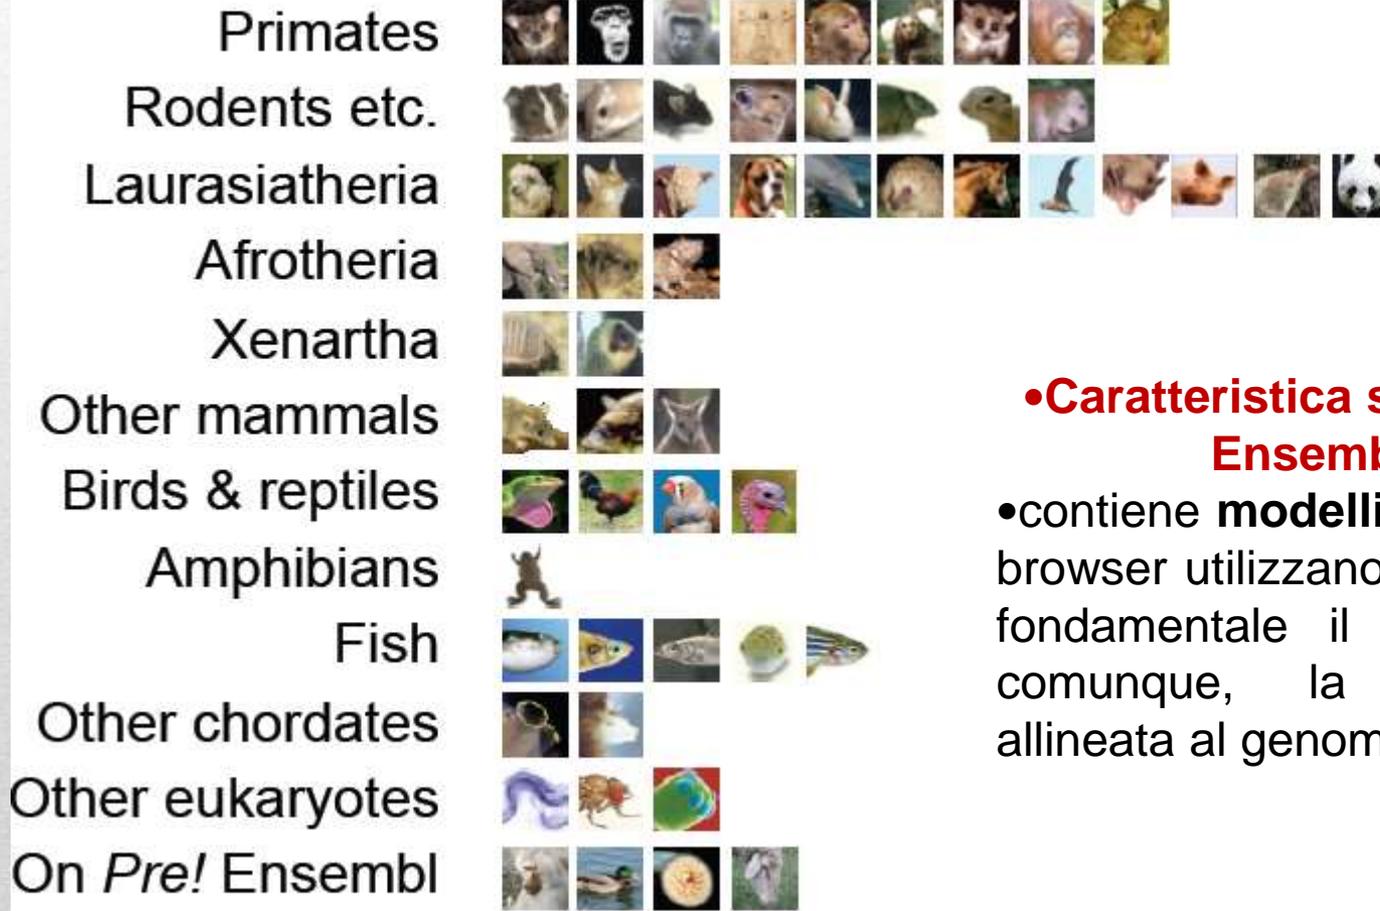


•BROWSERS GENOMICI

- Ne esistono diversi:** Principalmente 3:
 - NCBI map viewer (<http://www.ncbi.nlm.nih.gov/projects/mapview/>)
 - Ensembl (<http://www.ensembl.org/index.html>)
 - UCSC genome browser (<http://genome.ucsc.edu/>)
- Presentano le stesse informazioni, ma in modo diverso:** tutti e tre permettono di trovare la posizione genomica di una sequenza (mediante allineamento o ricerca per parola chiave) e di visualizzare la regione genomica associata.
- I dati contenuti nei browser genomici dipendono dal contenuto di altre banche dati:** necessità di aggiornare i dati molto spesso. Ensembl viene aggiornato mensilmente .
- Produzione dei dati di annotazione genomica:** E' un processo costoso dal punto di vista delle risorse di calcolo (allineamento di intere banche dati di sequenze al genoma). I principali browser genomici contengono più di un genoma (in realtà contengono molti genomi). E' un processo basato su pipeline di annotazione automatizzate.



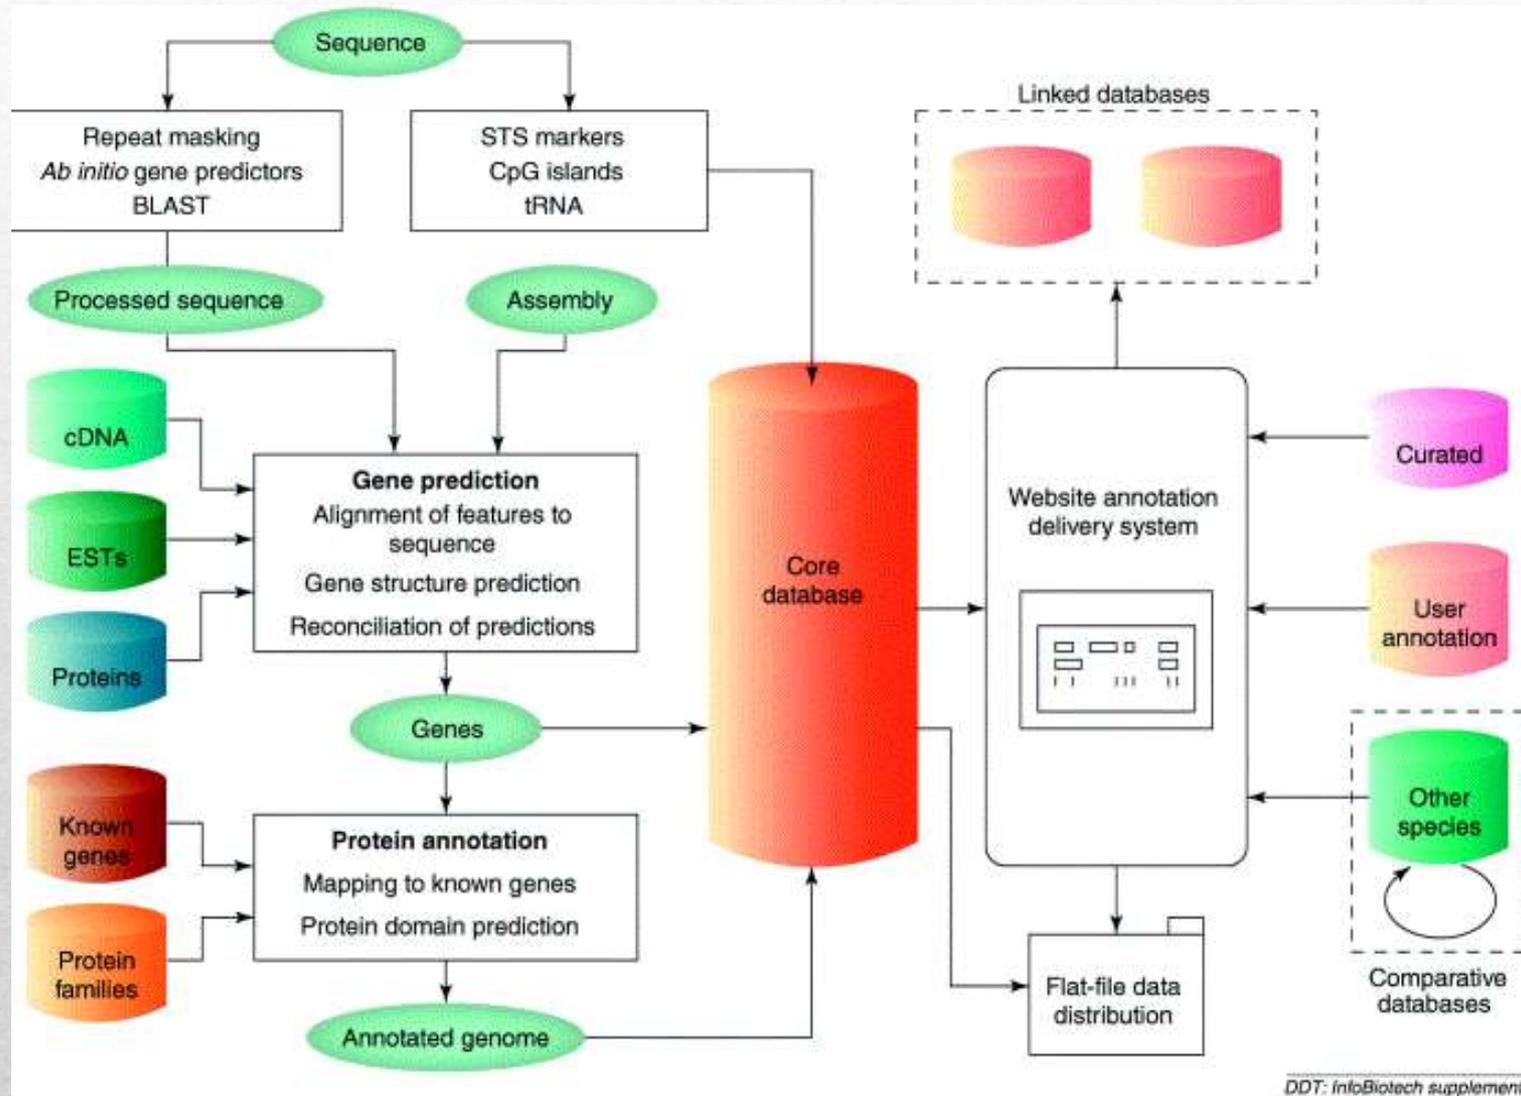
Species



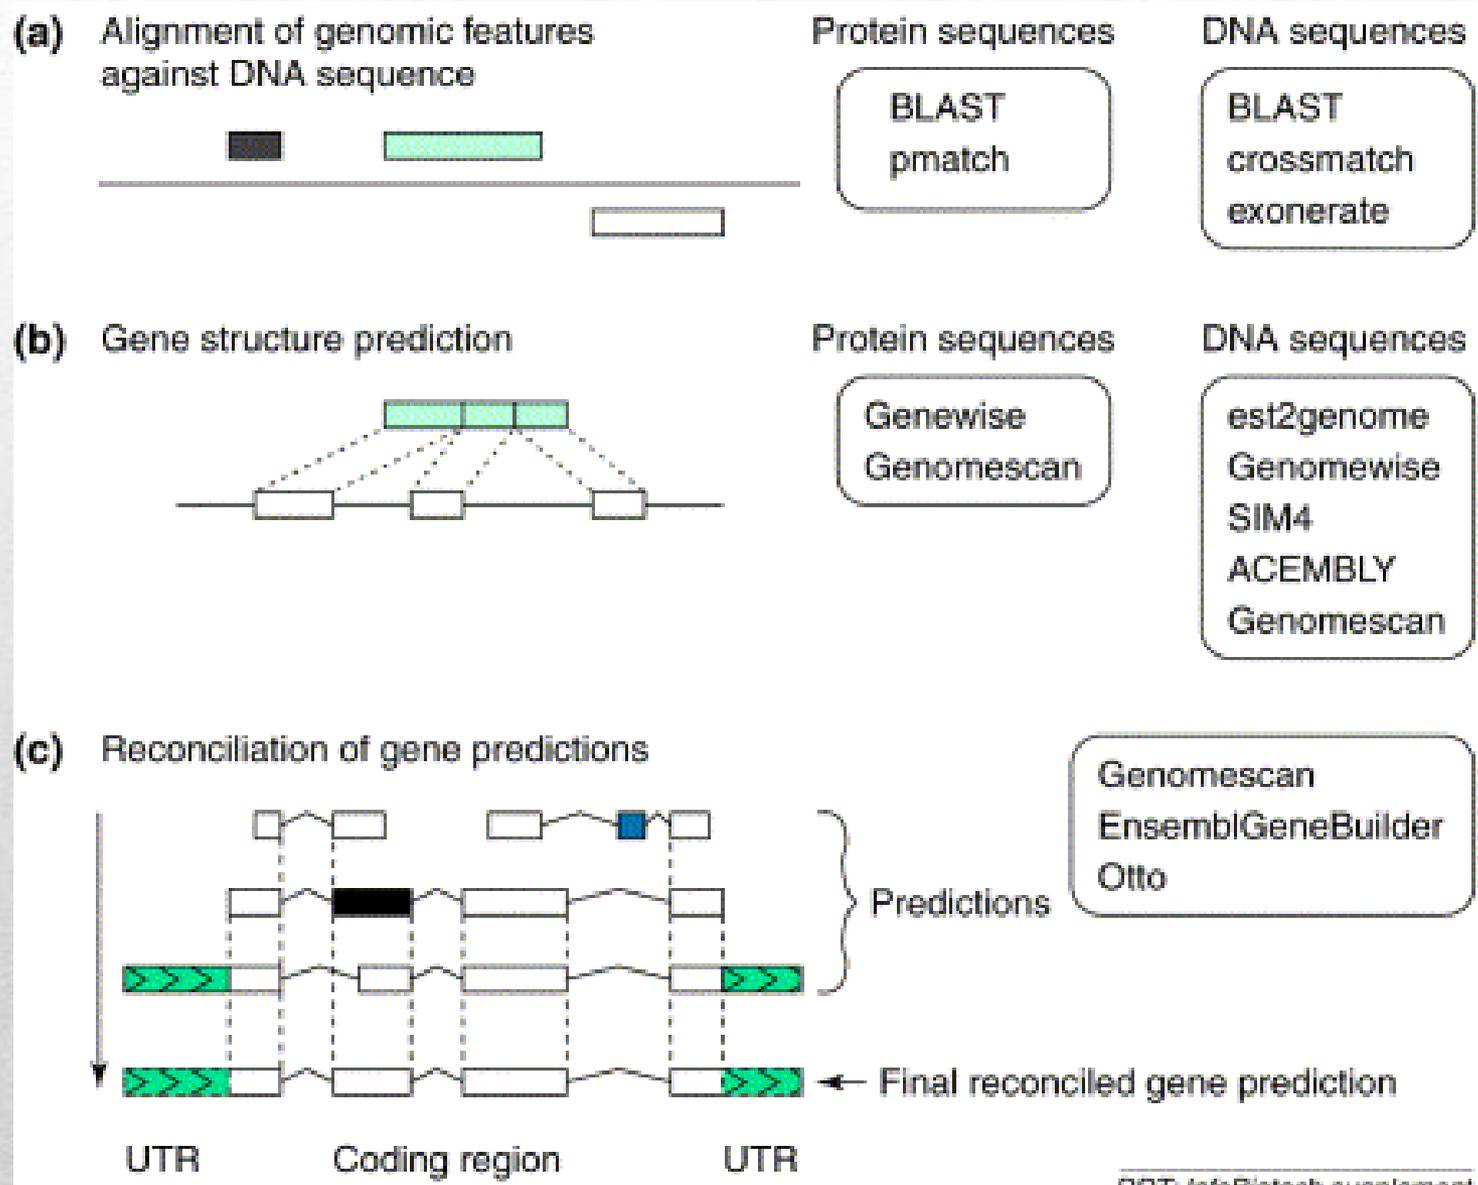
•**Caratteristica specifica di Ensembl :**

- contiene **modelli** di geni (altri browser utilizzano come entità fondamentale il trascritto o, comunque, la «sequenza allineata al genoma»)

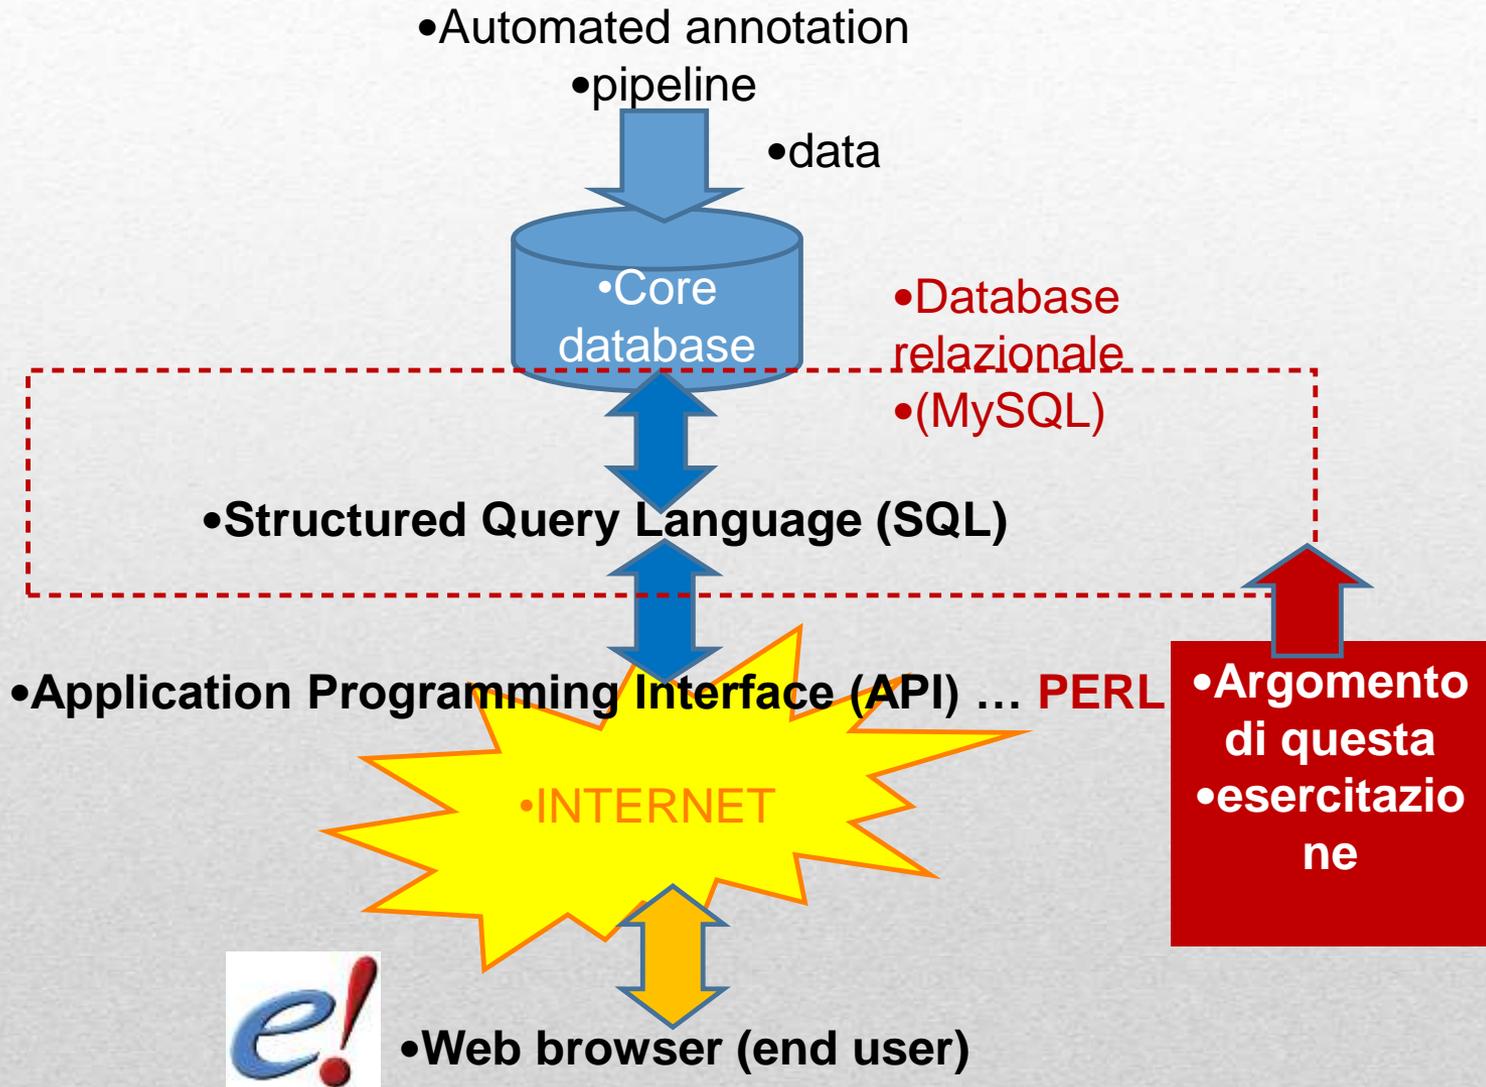
•Automatizzazione del processo di annotazione di una sequenza genomica



•Creazione di «modelli» di geni



•Architettura del browser genomico Ensembl



•Structured Query Language (SQL) e (R)DBMS

•I database sono estremamente eterogenei per quanto riguarda la loro struttura e la quantità di dati contenuta. Essi possono essere costituiti da file di testo ASCII o file che rappresentano complesse strutture composte da alberi binari (ad es. Oracle o Sybase). In ogni caso un database è un contenitore di dati.

•PROBLEMA:

•*Se un database è una semplice collezione di dati ... chi tiene traccia del cambiamento dei dati stessi?*

•Questo è il ruolo dei sistemi di gestione delle basi di dati (database management systems o **DBMS**). Alcuni DBMS sono **relazionali**. In tal caso ci si riferisce ad essi come relational DBMS o **RDBMS**. Le relazioni su cui si basano i sistemi RDBMS assicurano che diverse collezioni di dati (ad es. tabelle) possano essere interrogate “all’unisono”. Le relazioni, di fatto, rappresentano delle **regole di integrità referenziale** tra collezioni di dati. Supponiamo di avere un RDBMS che contiene i dati di tutti gli impiegati di un’azienda e di avere 2 tabelle: reparto e impiegato. Tra di esse potrebbe esistere una relazione che permette l’inserimento di un nuovo **impiegato SOLO se esso è assegnato ad un reparto esistente**.

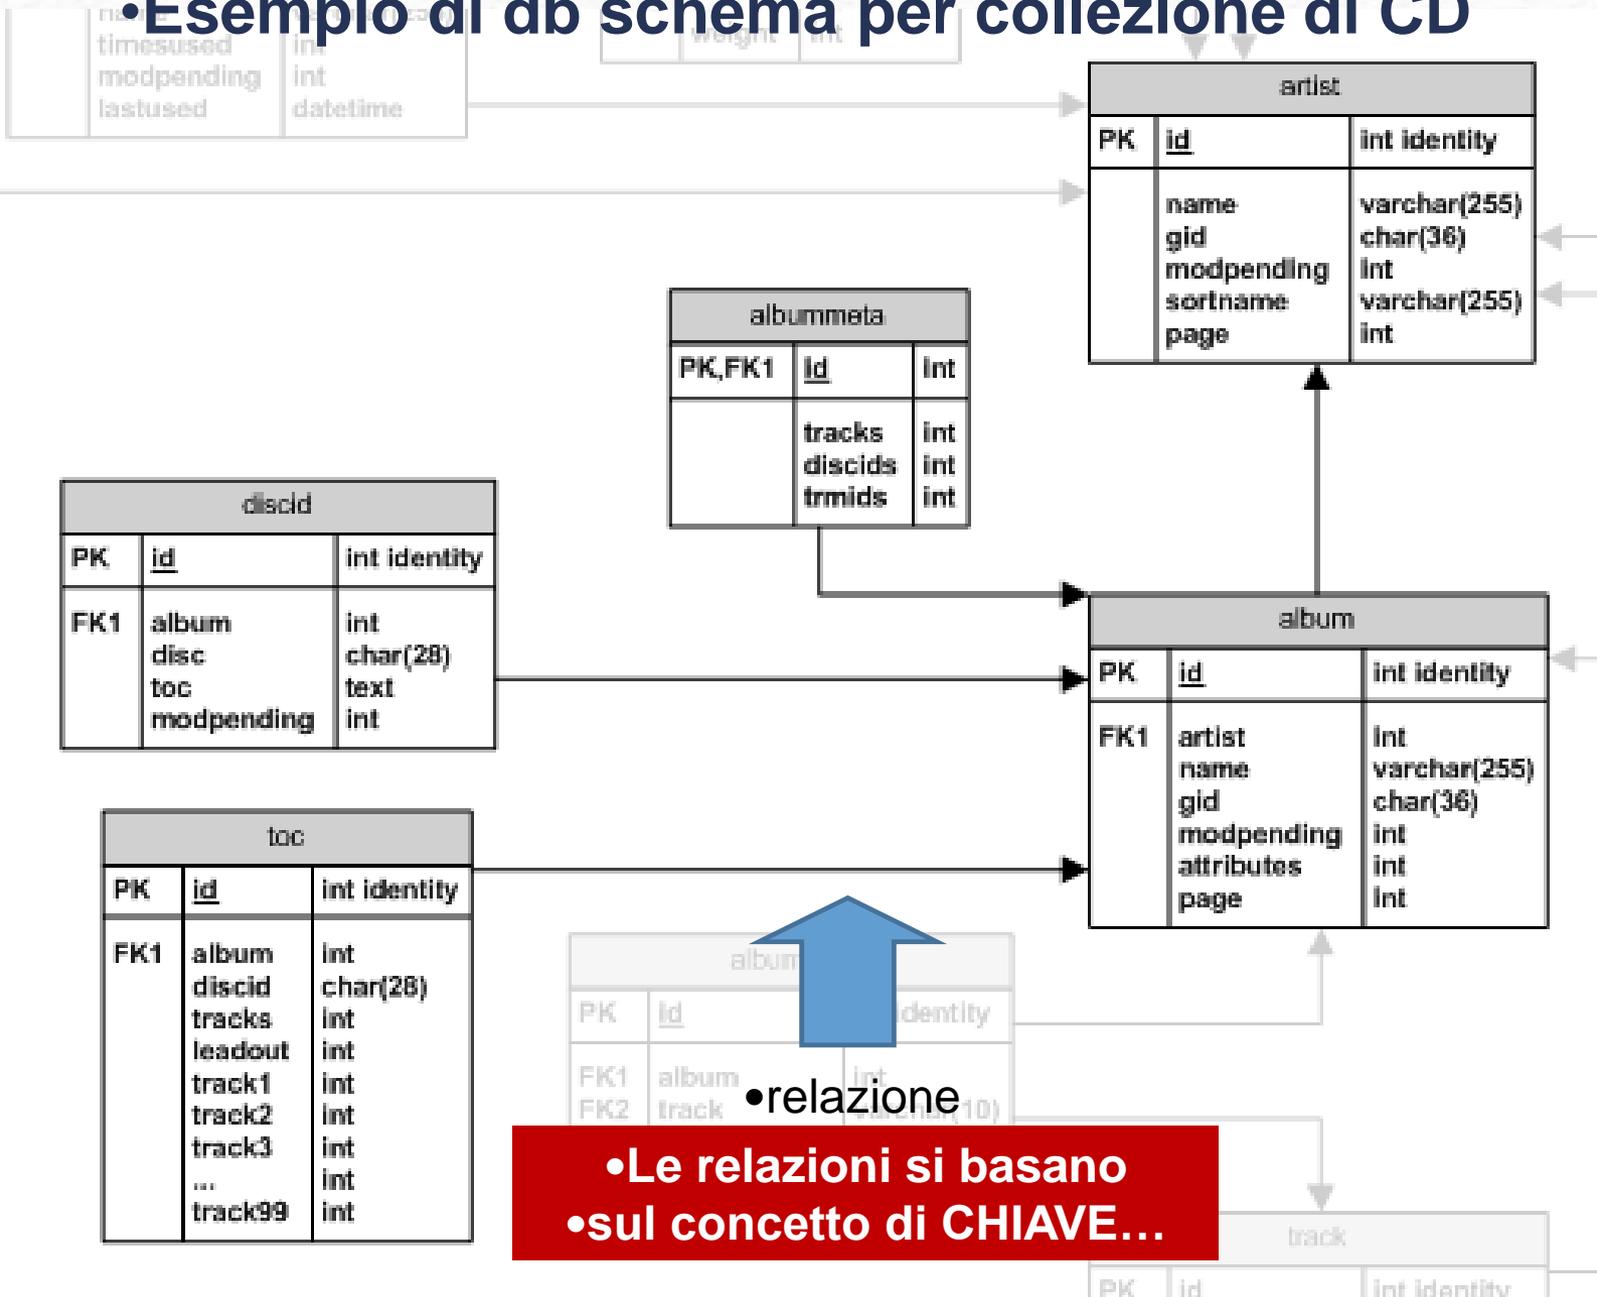
•Structured Query Language (SQL) e (R)DBMS

•Un database relazionale (come quello associato alla maggioranza delle banche dati genomiche) è costituito da :

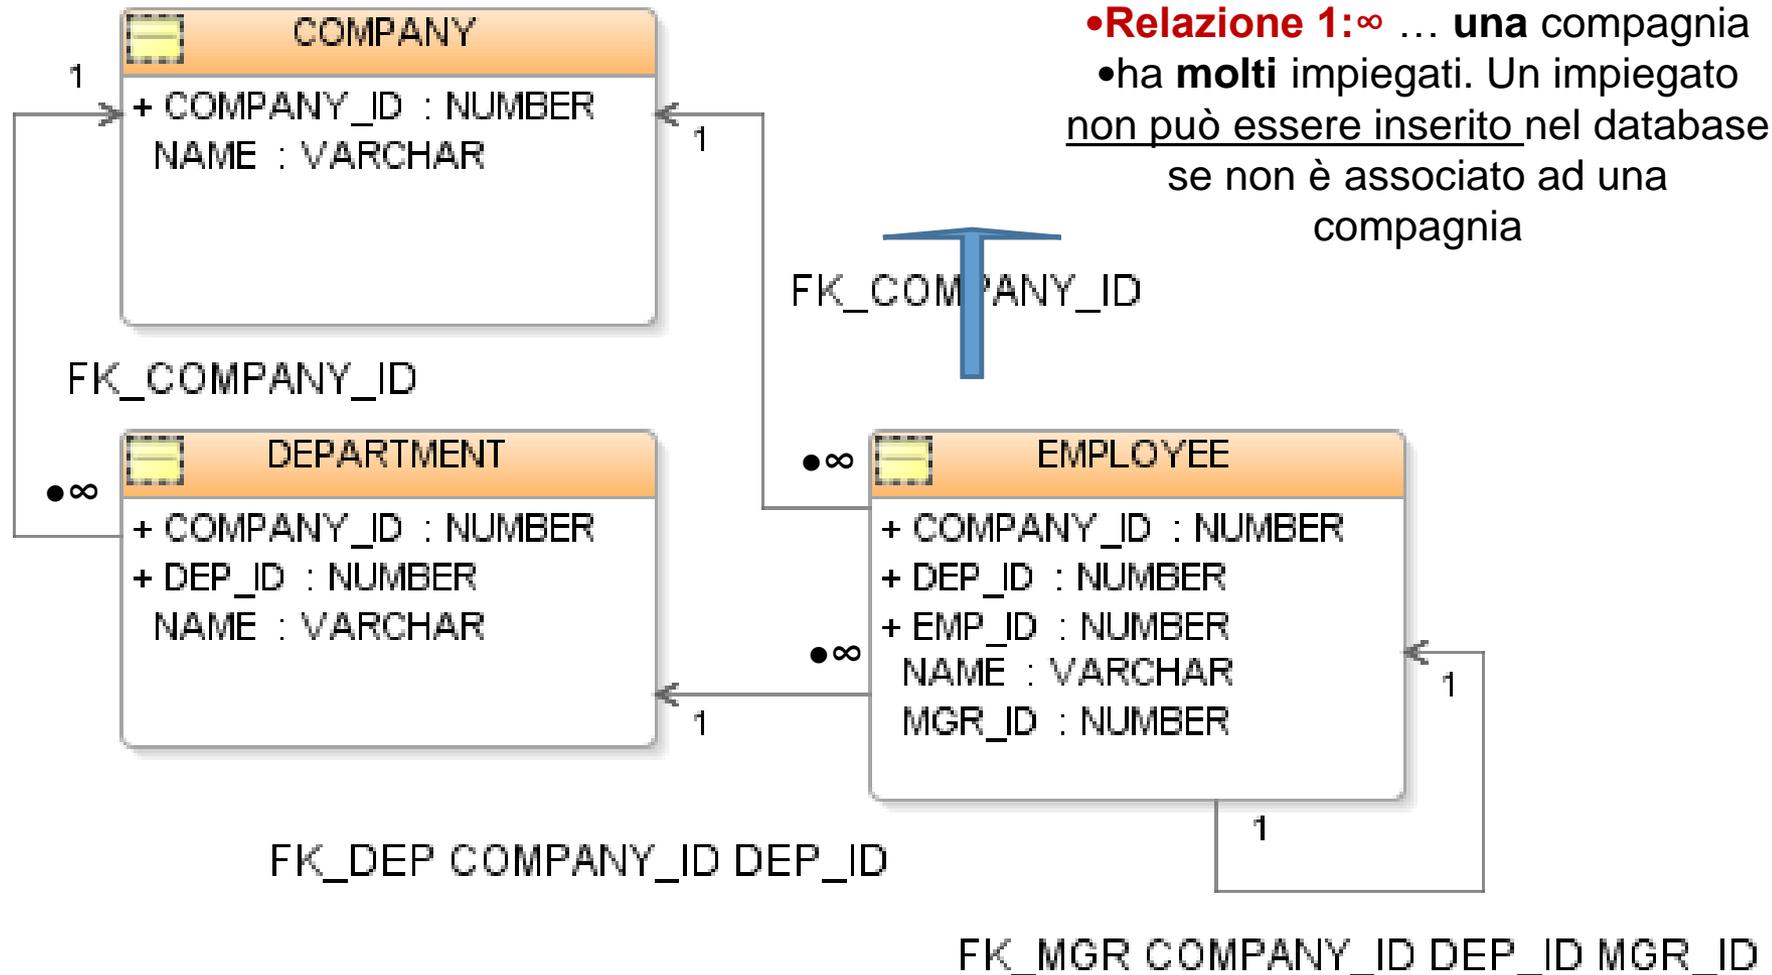
1.Una parte **INVARIANTE** nel tempo detta database schema. Essa definisce la struttura logica delle unità di memorizzazione delle informazioni. Tale struttura, di solito, viene rappresentata sottoforma di **tabella**. La rappresentazione tabulare permette di nascondere i dettagli del formato reale di memorizzazione su disco.

1.I dati veri e propri: ad essi ci si riferisce con il termine generico di **istanze**. Per ogni tabella presente nella banca dati è disponibile una DEFINIZIONE composta da numero e nomi dei campi (colonne) della tabella, tipo di dato ammesso in ogni campo e altre caratteristiche (che descrivono ad esempio, il coinvolgimento di una relazione di integrità associata ad un dato campo). Prima di inserire una nuova riga in una tabella **il sistema RDBMS verifica che la collezione di dati (la riga della tabella) rispetti tutte le specifiche della tabella stessa**. Un altro modo comune di riferirsi alle righe delle tabelle è il termine **RECORD**.

• Esempio di db schema per collezione di CD



•Esempio di db schema per collezione di CD



- Le relazioni si basano
- sul concetto di **CHIAVE...**

•Interazione con RDBMS e ruolo di SQL

•E' necessario uno strumento che permetta di interagire con la banca dati. Questo ruolo è svolto da un linguaggio standardizzato detto Structured Query Language (**SQL**). SQL permette non solo l'estrazione dei dati ma anche la creazione/modifica di database e tabelle nonché la definizione di vincoli relazionali. SQL si divide in:

•**DATA DEFINITION LANGUAGE (DDL)**: linguaggio di definizione dei dati, serve per creare databases, definizioni di tabelle e vincoli di integrità referenziale. Permette inoltre di modificare la struttura di tabelle esistenti.

•**DATA MANIPULATION LANGUAGE (DML)**: insieme di enunciati che permettono, principalmente, di estrarre informazioni da una banca dati.



•A noi interessa DML (DDL non verrà trattato)

•Operazioni realizzabili mediante SQL DML

•SQL DML permette di realizzare diverse operazioni che possono essere attribuite a tre grandi macrocategorie:

•

•**PROIEZIONE:** Estrazione di attributi (valori contenuti in un sottoinsieme di colonne di una tabella specificate dall'utente)

•**ESTRAZIONE:** Selezione di alcune righe (record) da una tabella nel caso in cui queste corrispondano ad alcuni criteri specificati dall'utente

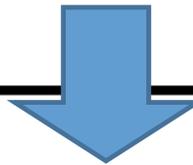
•**JOIN:** Interrogazione simultanea di più tabelle basata su relazioni. Concettualmente equivale a creare in memoria una macrotabella costituita dai dati contenuti in più tabelle. Solitamente dopo il join viene effettuata un'estrazione.

•Esempio di **PROIEZIONE**

T1

Nome	Cognome	Nato il	Nato a
Anna	Rossi	2/2/71	TO
Gigi	Bianchi	23/4/80	Ivrea
Iris	Bianchi	15/9/45	CN

La **proiezione** di T1 sugli attributi Nome e Cognome restituisce



T2

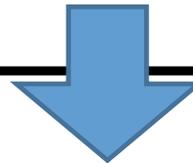
Nome	Cognome
Anna	Rossi
Gigi	Bianchi
Iris	Bianchi

•Esempio di **ESTRAZIONE (o selezione)**

T1

Nome	Cognome	Nato il	Nato a
Anna	Rossi	2/2/71	TO
Gigi	Bianchi	23/4/80	Ivrea
Iris	Bianchi	15/9/45	CN

La **selezione** dei record di T1 tali che “**Nato il** \geq 1/1/1960” restituisce



T2

Nome	Cognome	Nato il	Nato a
Anna	Rossi	2/2/71	TO
Gigi	Bianchi	23/4/80	Ivrea

•Esempio di utilizzo di enunciato **SELECT**

•Il database **Ensembl core** contiene una tabella **gene**:

Field	Type	Null	Key	Default	Extra
<input type="checkbox"/> gene_id	int(10) unsigned	16B NO	PRI	(NULL)	OK auto_increment
<input type="checkbox"/> biotype	varchar(40)	11B NO		(NULL)	OK
<input type="checkbox"/> analysis_id	smallint(5) unsigned	20B NO	MUL	(NULL)	OK
<input type="checkbox"/> seq_region_id	int(10) unsigned	16B NO	MUL	(NULL)	OK
<input type="checkbox"/> seq_region_start	int(10) unsigned	16B NO		(NULL)	OK
<input type="checkbox"/> seq_region_end	int(10) unsigned	16B NO		(NULL)	OK
<input type="checkbox"/> seq_region_strand	tinyint(2)	10B NO		(NULL)	OK
<input type="checkbox"/> display_xref_id	int(10) unsigned	16B YES	MUL	(NULL)	OK
<input type="checkbox"/> source	varchar(20)	11B NO		(NULL)	OK
<input type="checkbox"/> status	enum('KNOWN', 'NOVEL', 'PUTATIVE', 'PREDICTED', 'KNOWN_BY_PRO...)	76B YES		(NULL)	OK
<input type="checkbox"/> description	text	4B YES		(NULL)	OK
<input type="checkbox"/> is_current	tinyint(1)	10B NO		1	1B
<input type="checkbox"/> canonical_transcript_id	int(10) unsigned	16B NO		(NULL)	OK
<input type="checkbox"/> canonical_annotation	varchar(255)	12B YES		(NULL)	OK

•chiave primaria

•chiavi esterne

•descrizione dettagliata (nomi campi, tipi di dato ...)

•SQL: **DESCRIBE gene;**

•Rappresentazione **semplificata** (nomi campo + simboli ma non tipo di dato). Comune in molti strumenti ad interfaccia grafica ed **estremamente comune** nei diagrammi che descrivono gli schemi delle banche dati

gene

- gene_id
- biotype
- analysis_id
- seq_region_id
- seq_region_start
- seq_region_end
- seq_region_strand
- display_xref_id
- source
- status
- description
- is_current
- canonical_transcript_id
- canonical_annotation

Indexes

•Strumenti free per l'accesso a banche dati relazionali

•Proveremo ad effettuare alcuni esperimenti pratici utilizzando uno strumento free: **SQLyog**

•Scaricatelo da questo sito:

•<http://code.google.com/p/sqlyog/downloads/list>

•(scaricate l'ultima versione : [SQLyog-9.0.1-1Community.exe](#))

•Provate ad installarlo in una directory in cui **avete i permessi di scrittura** (es. Documenti).

•Una volta installato definite i parametri per una nuova connessione:

•File -> New **connection**

•**Valori:**

•Nome connessione **EnsEMBL**

•MySQL Host Address **ensemldb.ensembl.org**

•Username **anonymous**

•Port **5306**

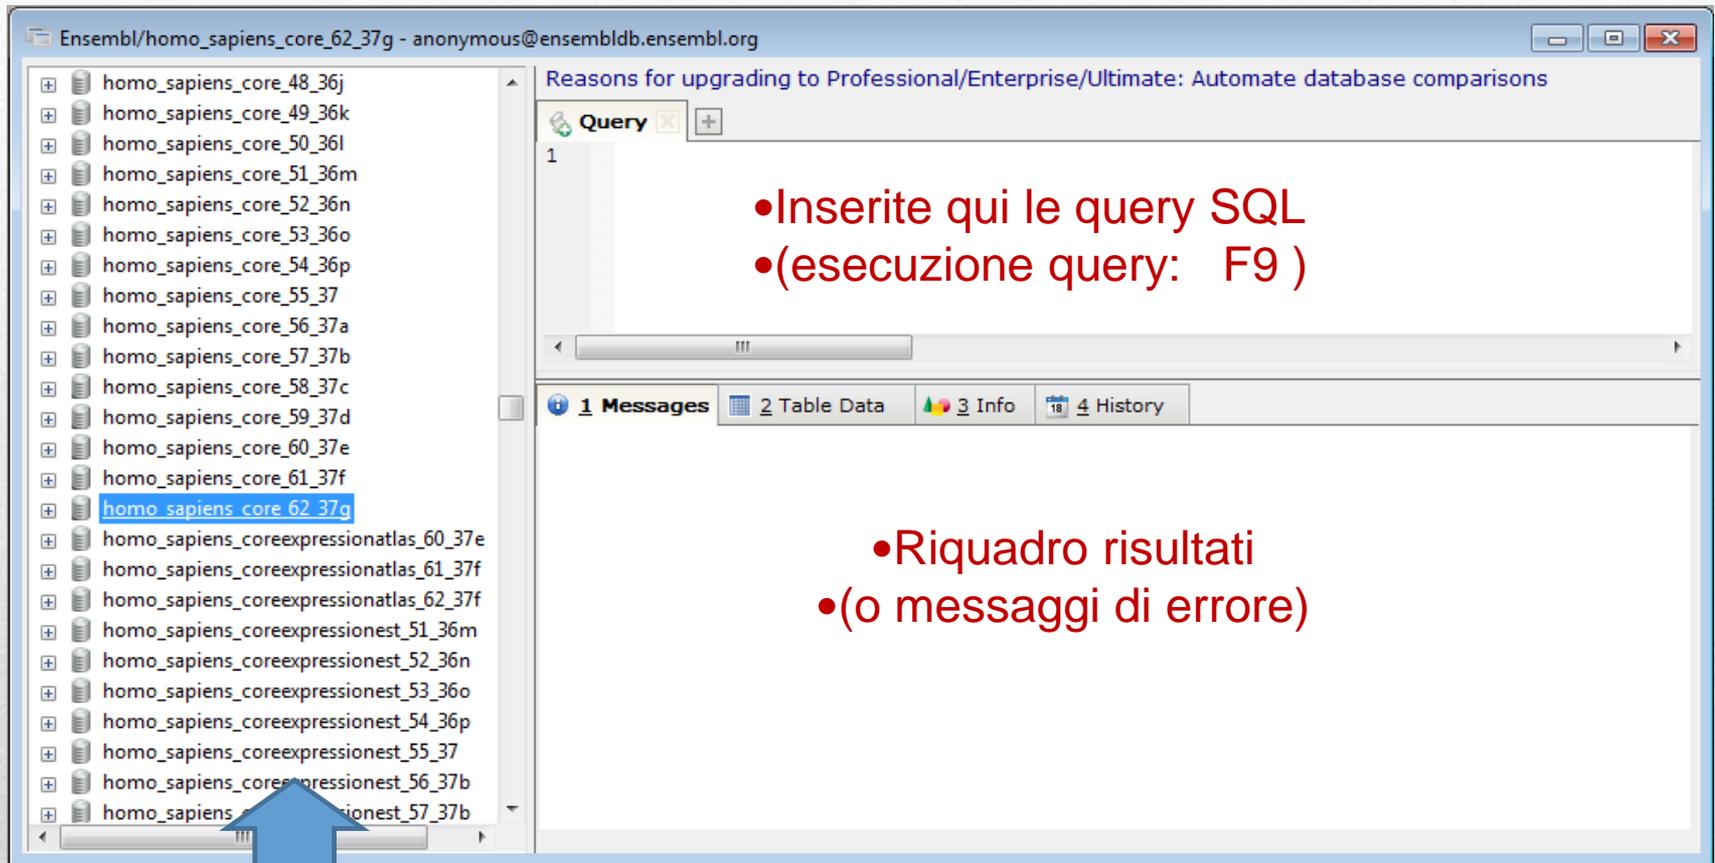
•(lasciate vuota la password che non serve)

(alternativa) **mysql client** command line :

`mysql -u anonymous -h ensemldb.ensembl.org -P 5306`



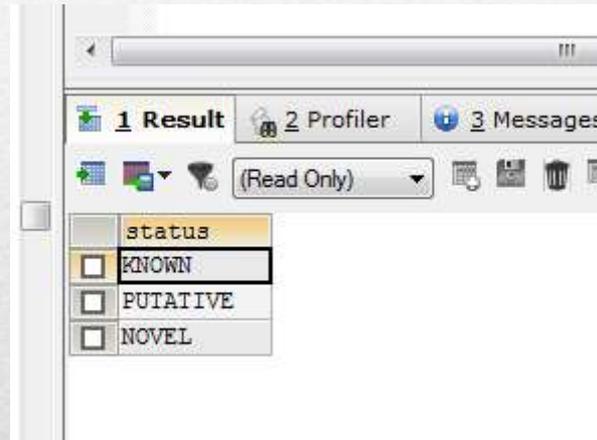
•SQLyog: finestra principale



- Database disponibili: a noi interessa **homo_sapiens_core_62_37g**
• (click sx per selezionarlo)

•Interrogazione diretta di Ensembl

- Quali sono i possibili valori presenti un una data colonna?
- SELECT **DISTINCT(status)** FROM gene;
- Quanti record ottenete?



•**NON** utilizzeremo SQLyog per realizzare i nostri accessi diretti ad Ensembl (utilizzeremo Perl), ma esso è uno strumento molto comodo per testare le query SQL prima di inserirle in uno script, in modo da essere sicuri che si comportino secondo le attese.

•Esecuzione di query SQL da remoto in Perl

```
•# PERL MODULES
•use DBI;
•use DBD::mysql;

•# CONFIG VARIABLES
•$platform = "mysql";
•$host = "ensemldb.ensembl.org";
•$port = "5306";
•$user = "anonymous";
•$pw = "";
•$database="homo_sapiens_core_62_37g";

•#DATA SOURCE NAME #####
•$dsn = "dbi:mysql:$database:$host:5306";

•#CONNECTION #####
•$DBIconnect = DBI->connect($dsn, $user, $pw);

•#Query #####

•$sqlquery = "select * from gene limit 10";

•$sth = $DBIconnect->prepare($sqlquery);

•$sth->execute;

•#PRINT RESULTS #####
•while (@row = $sth->fetchrow_array) {
•print "@row\n";
•}
```

•Librerie SQL

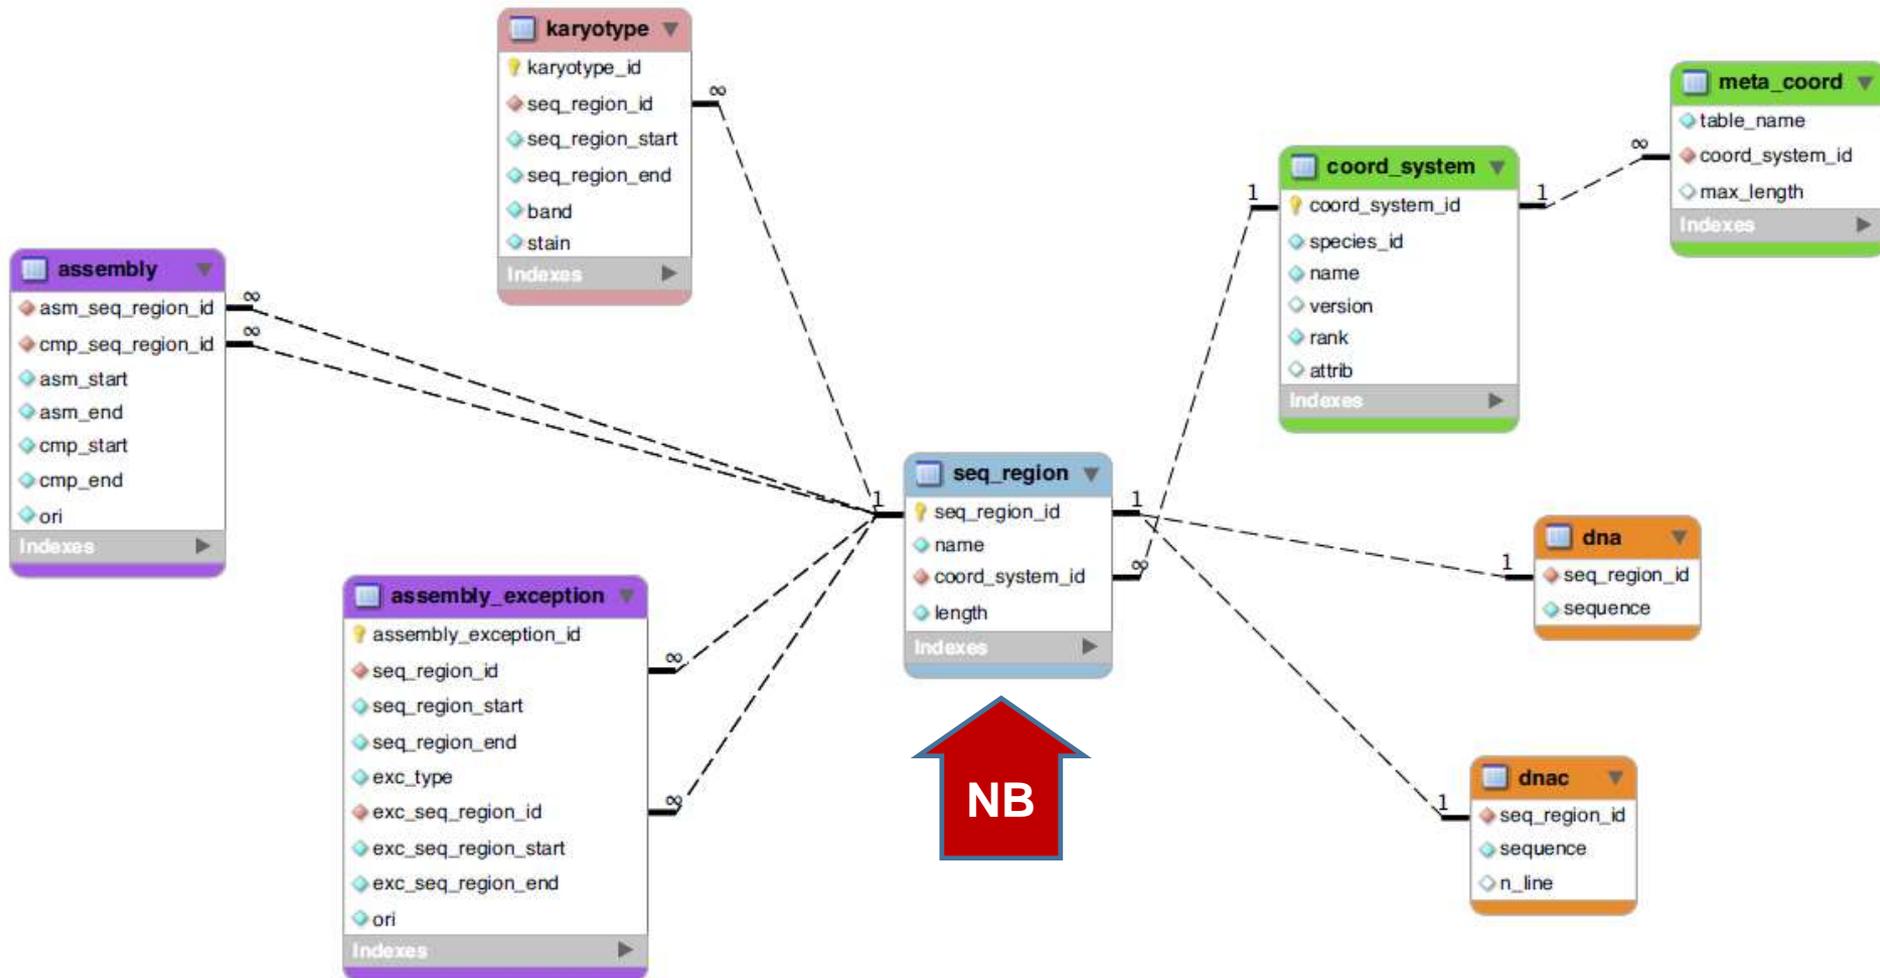
•Parametri di connessione

•Connessione

•Interrogazione

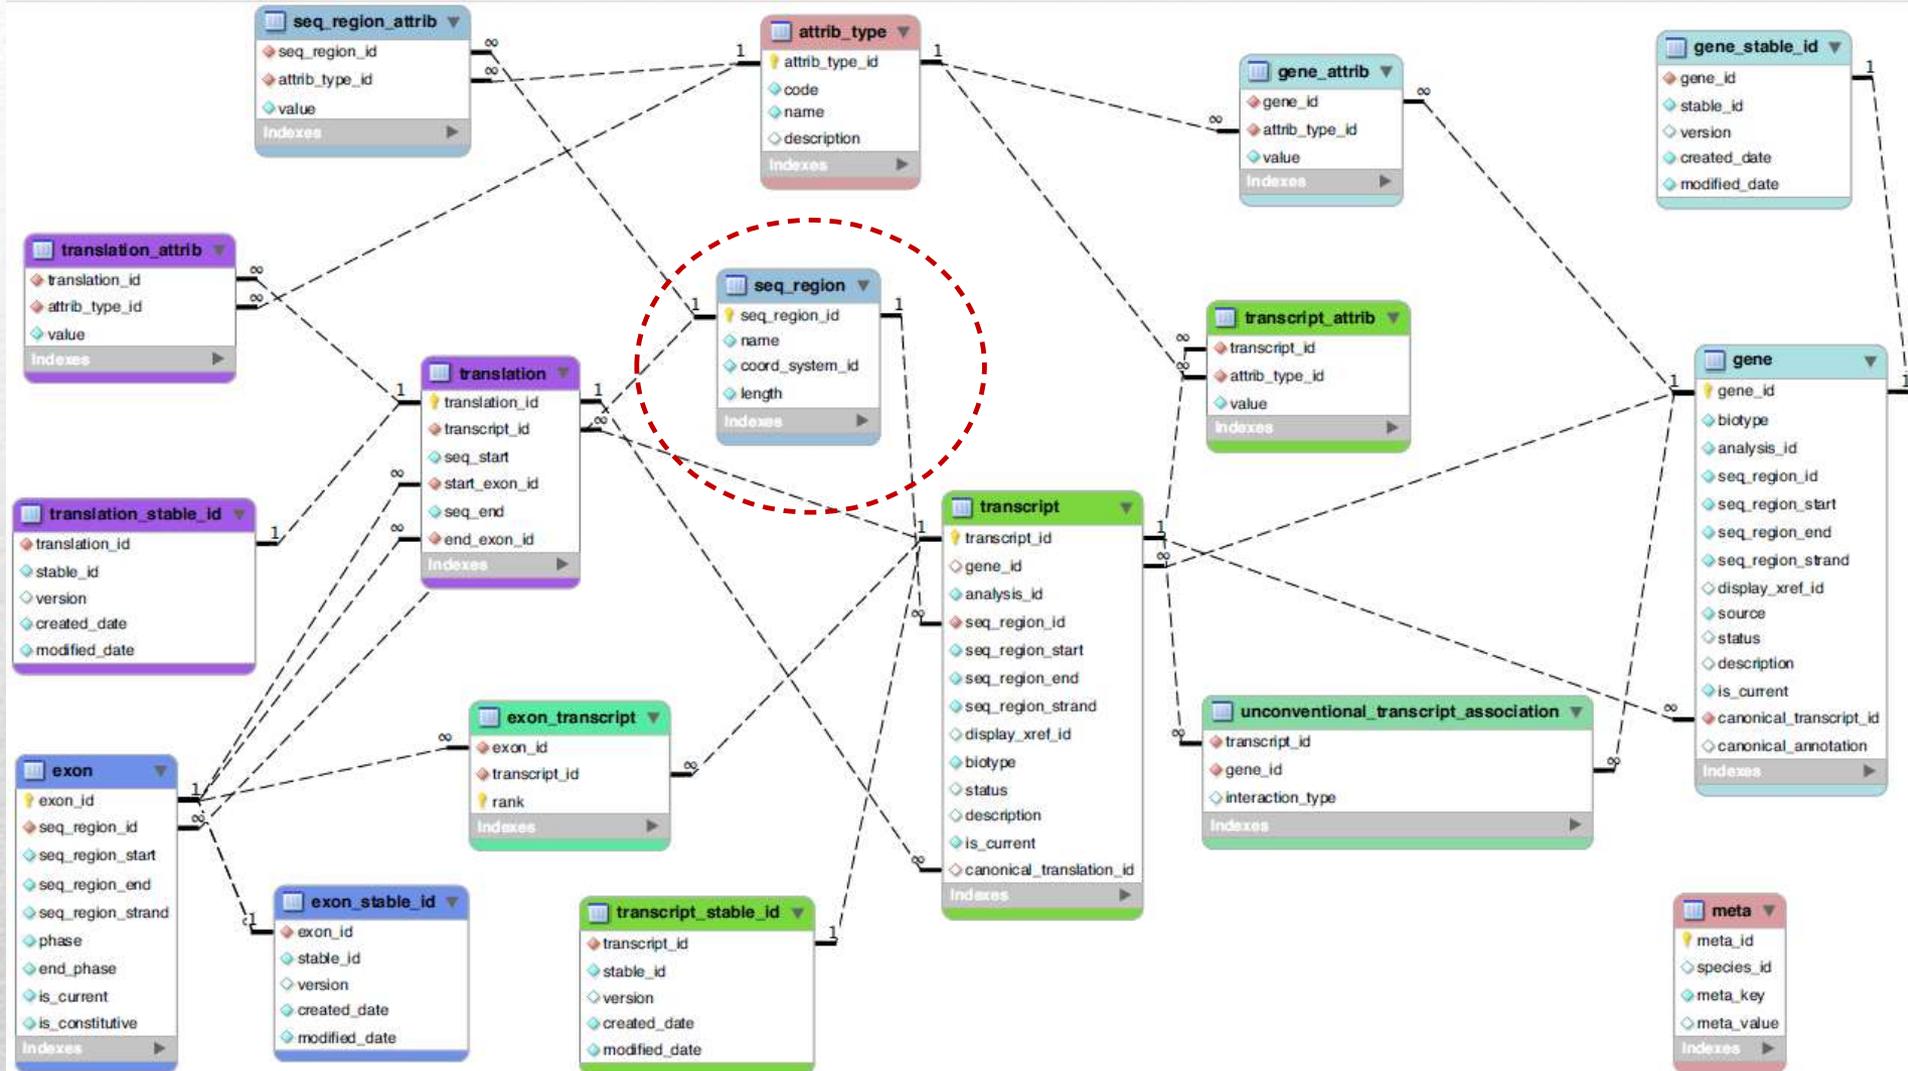
•Stampa risultati

•Ensembl core db schema (I)



•**NB**: il processo di annotazione genomica non viene effettuato unicamente sulle sequenze genomiche assemblate. Parte di esso viene effettuato su cloni, contigui, supercontigui ecc.. **OGNI ANNOTAZIONE** esiste in uno specifico sistema di coordinate

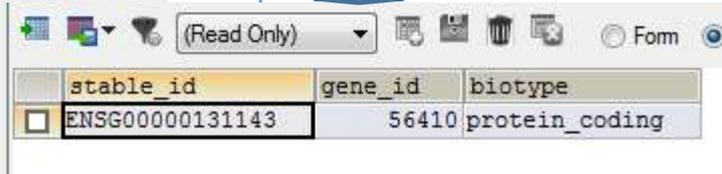
•Ensembl core db schema (II)



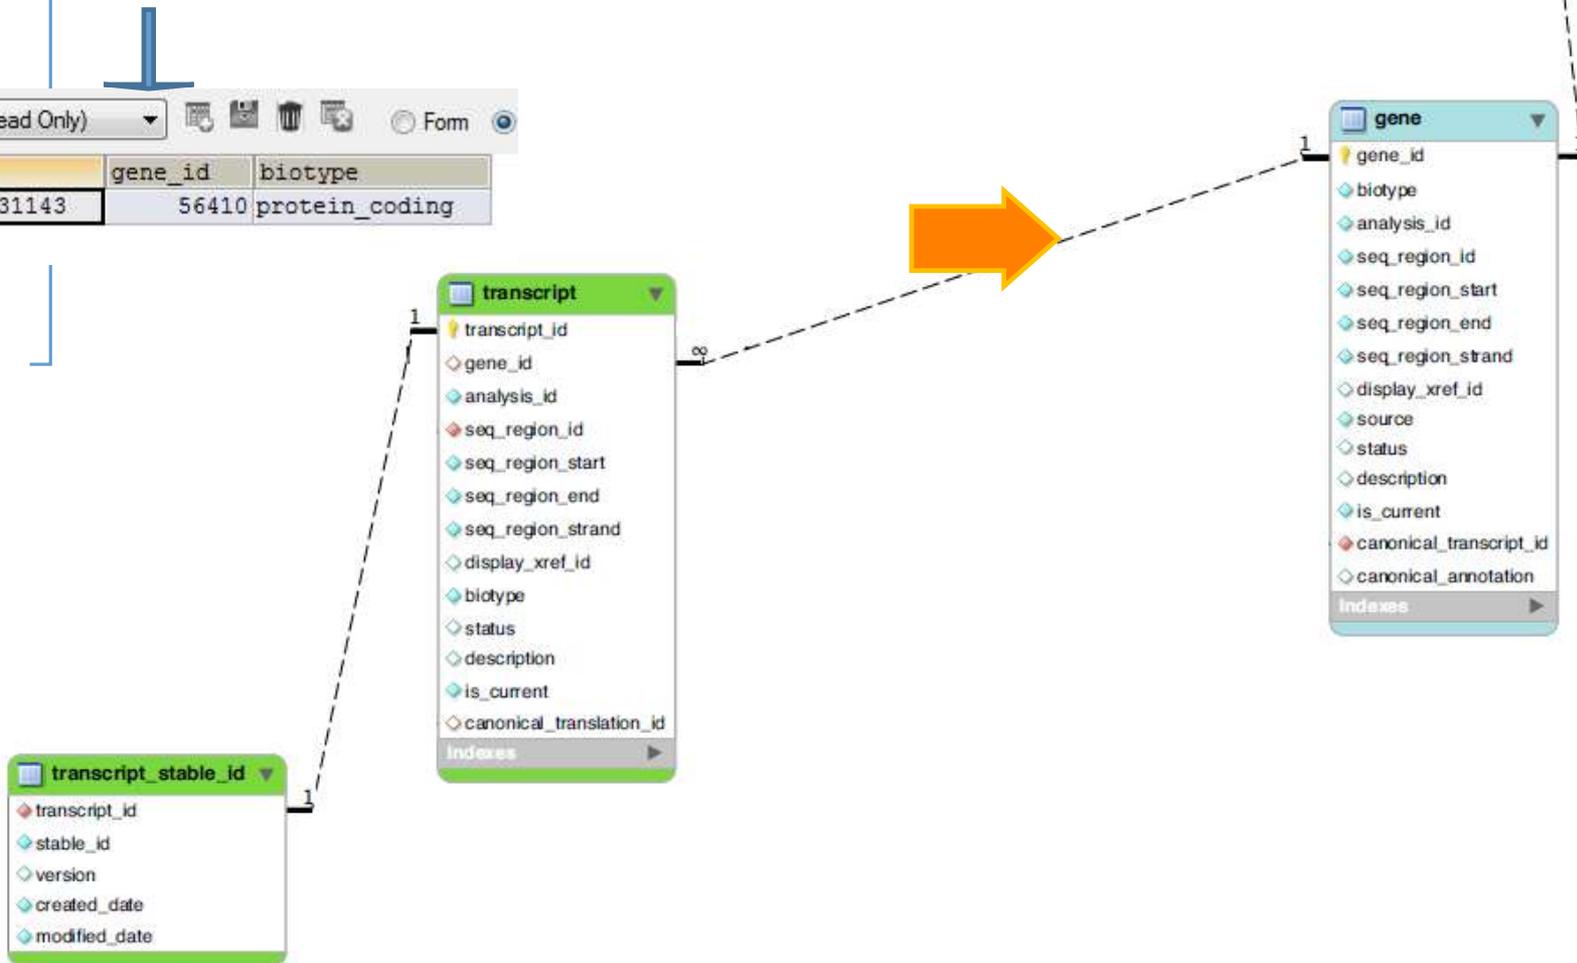
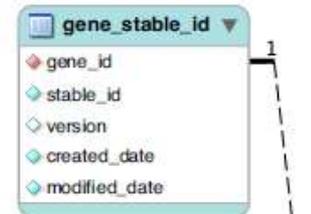
•Ensembl core db schema (II) : JOIN

•nometabella.nomecampo

- SELECT gene_stable_id.stable_id, gene.gene_id, gene.biotype
- FROM gene_stable_id INNER JOIN gene USING (gene_id)
- WHERE gene_stable_id.stable_id = 'ENSG00000131143';



stable_id	gene_id	biotype
ENSG00000131143	56410	protein_coding

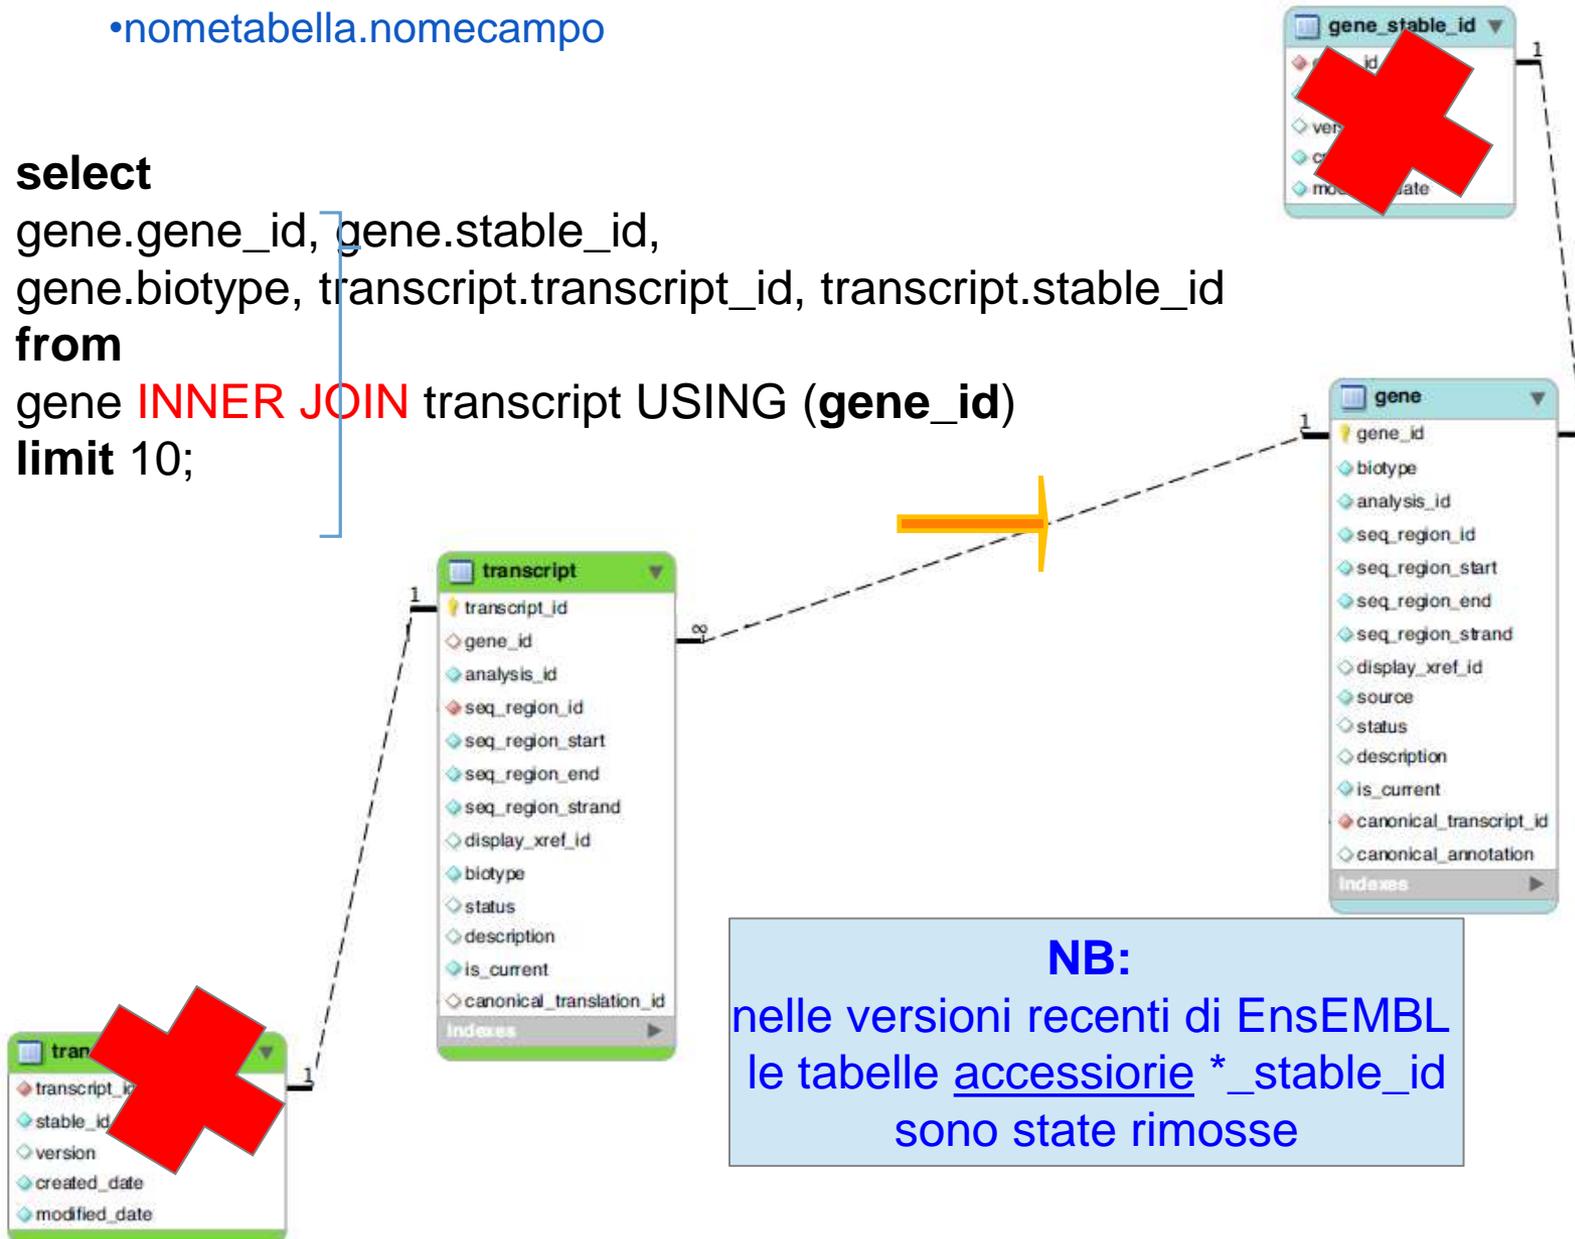


•Ensembl core db schema (II) : JOIN

•nometabella.nomecampo

select

```
gene.gene_id, gene.stable_id,  
gene.biotype, transcript.transcript_id, transcript.stable_id  
from  
gene INNER JOIN transcript USING (gene_id)  
limit 10;
```



•Ensembl core db schema (II) : JOIN

- SELECT** gene.stable_id, transcript.stable_id,
- gene.biotype
- FROM** gene **INNER JOIN** transcript **USING** (gene_id) **INNER JOIN**
- transcript **USING** (transcript_id)
- WHERE** gene.stable_id='ENSG00000005955';

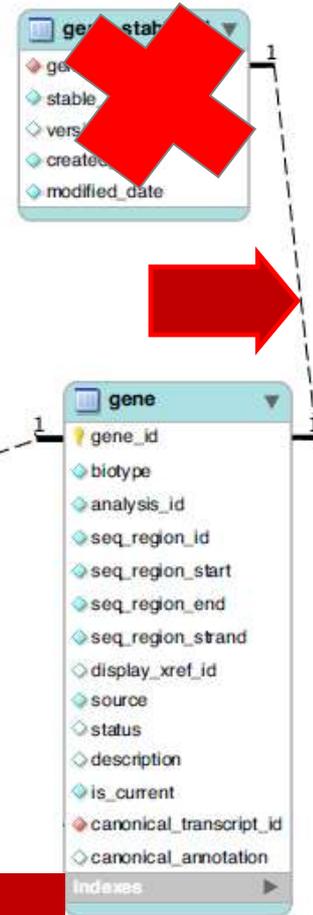
NB:

Se non trovate il gene è possibile che sia stato sostituito da una versione più recente ... (con stable Id aggiornato!!!)



- Estrazione di tutti i
- trascritti di un gene

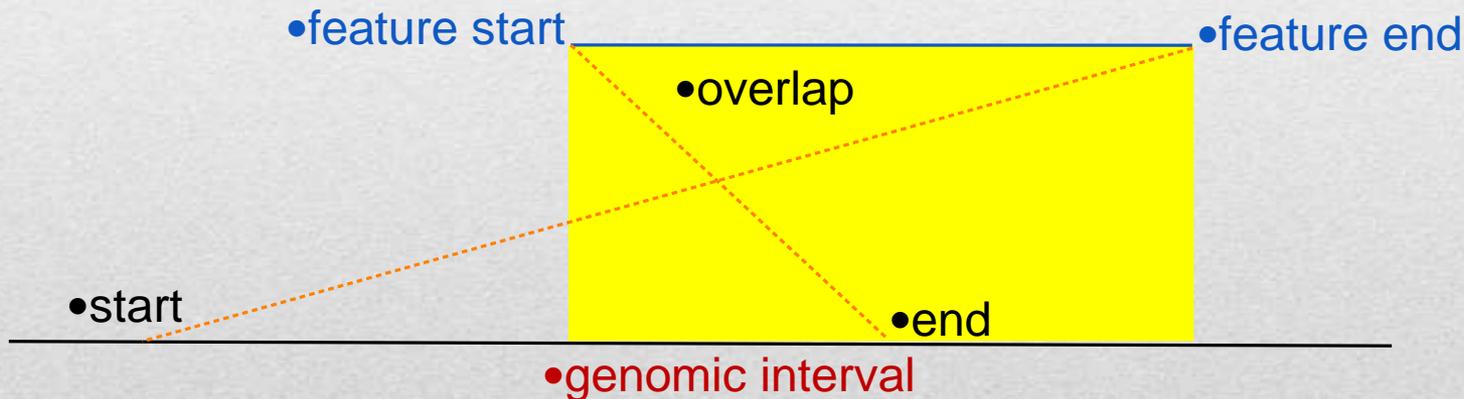
	stable_id	stable_id	biotype
<input type="checkbox"/>	ENSG00000005955	ENST00000485685	protein_coding
<input type="checkbox"/>	ENSG00000005955	ENST00000304718	protein_coding
<input type="checkbox"/>	ENSG00000005955	ENST00000495023	protein_coding
<input type="checkbox"/>	ENSG00000005955	ENST00000486208	protein_coding
<input type="checkbox"/>	ENSG00000005955	ENST00000483256	protein_coding



Form Grid

- **Ensembl core db schema (II) :**
- **estrazione su base *posizionale***

- **SELECT** gene_stable_id.stable_id, gene.biotype
- **FROM** seq_region INNER JOIN gene USING (seq_region_id) INNER JOIN gene_stable_id USING (gene_id)
- **WHERE NOT**(gene.seq_region_start > **84966302** OR gene.seq_region_end < **84826528**) AND seq_region.name = '16';



• Con queste coordinate trova solo il gene **ENSG00000103196** ... sarà vero?

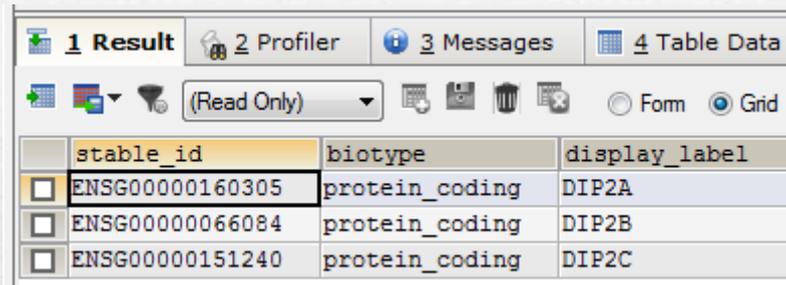
stable_id	biotype
ENSG00000103196	protein_coding



•Ensembl SQL :

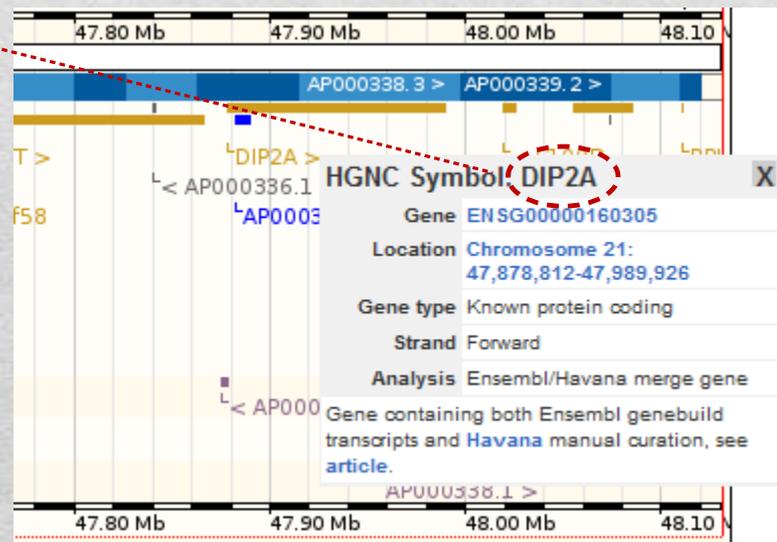
•estrazione basata su pattern di testo

•**SELECT** gene_stable_id.stable_id, gene.biotype, xref.display_label **FROM** gene_stable_id
INNER JOIN gene USING (gene_id) INNER JOIN xref ON (gene.display_xref_id =
xref.xref_id) **WHERE** xref.display_label **LIKE 'DIP2%'**;



stable_id	biotype	display_label
ENSG00000160305	protein_coding	DIP2A
ENSG00000066084	protein_coding	DIP2B
ENSG00000151240	protein_coding	DIP2C

•**NBB**: Tabella **xref** (**external reference**) fa riferimento ad un dato mappato sul genoma ma **ORIGINARIO** di un'altra banca dati. Nel caso (ad es.) di **DIP2A** si tratta di un gene symbol definito da **HGNC** (HUGO Gene nomenclature committee)



•Esercizi (SQL)

- Scrivete una query SQL che restituisca tutti i trascritti di un gene a vostra scelta (**3 pt**)
- Scrivete una query che restituisca **IL NUMERO** degli pseudogeni umani annotati in Ensembl (**3 pt**)
- Scrivete una query che restituisca tutti i geni del cromosoma 1 di tipo **diverso** da protein_coding (**3 pt**)
- Scrivete **uno script** a cui passare come parametro il nome di un gene e che restituisca il numero dei suoi trascritti e, per ciascun trascritto, I nomi e le posizioni dei suoi esoni . Potete realizzare l'esercizio mediante **più query** successive (gene → trascritti, per ogni trascritto → esoni) (**6 pt**).
- Scrivete **uno script** a cui passare come parametro delle coordinate genomiche e che restituisca le simple_feature annotate nella regione genomica, la loro posizione ed il loro tipo . NB: questo esercizio **richiede l'utilizzo di INNER JOIN da una tabella che dovete identificare ad altre due tabelle: seq_region e analysis** (**6 pt**).

•RIEPILOGO (I):

- Alcune banche dati (non tutte) sono disponibili sottoforma di database relazionali pubblici
- Possiamo interrogarle in vari modi (SQL/API dedicate)
- Il **linguaggio di programmazione** delle eventuali API disponibili varia da banca dati a banca dati
- Abbiamo visto una modalità d'accesso (SQL) alla componente core di un browser genomico (Ensembl) tra i più utilizzati (ma ne esistono altri!!!)
- Nel caso in cui una banca dati non permetta l'accesso diretto (SQL o API) solitamente permette scaricare i suoi dati sottoforma di file di testo... I dati sono sempre dati, ma così la loro gestione è **molto più complicata** (inoltre i files possono essere molto grandi (Gb)).

•RIEPILOGO (II):



- Anche se abbiamo visto «da vicino» una banca dati (Ensembl), abbiamo visto solo la «**punta dell'iceberg**» ...

- Per quanto riguarda **Ensembl**:

•Altre API:

- API **Variation** (variabilità genetica)
- API **Compara** (Genomica comparata)
- API **FunctionalGenomics** (il nome dice tutto)

•SQL:

- Databases per genomica comparata, genomica funzionale, variabilità genetica ecc ... per **OGNI SPECIE !**



- UCSC**
- BioMART**
- ...



•RIEPILOGO (II):

•«INDIRIZZI UTILI» (warning: possono cambiare da release a release ... controllate sempre il sito della banca dati.):

•UCSC genome browser:

- host: genome-mysql.cse.ucsc.edu
- user: genome
- access type: SQL

•Vedere anche:

- UCSC Table browser (interfaccia web per «costruire» query):
- <http://genome.ucsc.edu/cgi-bin/hgTables>

•BIOMART:

- host: martdb.ensembl.org
- user: anonymous
- port: 5316
- access type: SQL (API disponibile)