

# Βιοπληροφορική

## Ενότητα 3: Ηλεκτρονική διαχείριση βιολογικών δεδομένων

Αν. καθηγητής Αγγελίδης Παντελής

e-mail: [paggelidis@uowm.gr](mailto:paggelidis@uowm.gr)

ΕΕΔΙΠ Μπέλλου Σοφία

e-mail: [sbellou@uowm.gr](mailto:sbellou@uowm.gr)

Τμήμα Μηχανικών Πληροφορικής και Τηλεπικοινωνιών

---



# Άδειες Χρήσης

---

- Το παρόν εκπαιδευτικό υλικό υπόκειται σε άδειες χρήσης Creative Commons.
- Για εκπαιδευτικό υλικό, όπως εικόνες, που υπόκειται σε άλλου τύπου άδειας χρήσης, η άδεια χρήσης αναφέρεται ρητώς.



# Χρηματοδότηση

- Το παρόν εκπαιδευτικό υλικό έχει αναπτυχθεί στα πλαίσια του εκπαιδευτικού έργου του διδάσκοντα.
- Το έργο «**Ανοικτά Ψηφιακά Μαθήματα στο Πανεπιστήμιο Δυτικής Μακεδονίας**» έχει χρηματοδοτήσει μόνο τη αναδιαμόρφωση του εκπαιδευτικού υλικού.
- Το έργο υλοποιείται στο πλαίσιο του Επιχειρησιακού Προγράμματος «Εκπαίδευση και Δια Βίου Μάθηση» και συγχρηματοδοτείται από την Ευρωπαϊκή Ένωση (Ευρωπαϊκό Κοινωνικό Ταμείο) και από εθνικούς πόρους.



Ευρωπαϊκή Ένωση  
Ευρωπαϊκό Κοινωνικό Ταμείο



ΕΠΙΧΕΙΡΗΣΙΑΚΟ ΠΡΟΓΡΑΜΜΑ  
ΕΚΠΑΙΔΕΥΣΗ ΚΑΙ ΔΙΑ ΒΙΟΥ ΜΑΘΗΣΗ  
*επένδυση στην κοινωνία της γνώσης*  
ΥΠΟΥΡΓΕΙΟ ΠΑΙΔΕΙΑΣ ΚΑΙ ΘΡΗΣΚΕΥΜΑΤΩΝ  
ΕΙΔΙΚΗ ΥΠΗΡΕΣΙΑ ΔΙΑΧΕΙΡΙΣΗΣ

Με τη συγχρηματοδότηση της Ελλάδας και της Ευρωπαϊκής Ένωσης



ΕΥΡΩΠΑΪΚΟ ΚΟΙΝΩΝΙΚΟ ΤΑΜΕΙΟ



# Σκοπός του μαθήματος

---


- Δημόσιες βάσεις δεδομένων βιοπληροφορικής.
- Βασικοί ορισμοί (Data repository, Data mart, Data warehouse).
- Ηλεκτρονικά ιατρικά αρχεία.
- Κύκλος ζωής ιατρικών δεδομένων.
- Είδη βάσεων δεδομένων στη Βιοπληροφορική.
- Οργάνωση των βιολογικών βάσεων δεδομένων (πεδία-εγγραφές).
- Σχεσιακές βιολογικές βάσεις δεδομένων.
- Βιβλιογραφικές βάσεις δεδομένων.



# Computers and bioinformatics

Computers serve 4 independent functions in bioinformatics:

- I. **Communication:** More journal articles available for the researchers in less time and increasingly large proportion of academic research information appears online.
- II. **Computations:** Computers are used for tasks that range from searching a reference (or a nucleotide sequence) and visualizing protein folding patterns to simulating 3D protein-protein interaction.
- III. **Control:** Computer controlled devices are superior to manual operators, when time matters.
- IV. **Storage:** A true database is the data repository, a database used as an information storage facility, with minimal analysis or querying functionality.



<https://www.cartoonstock.com/>



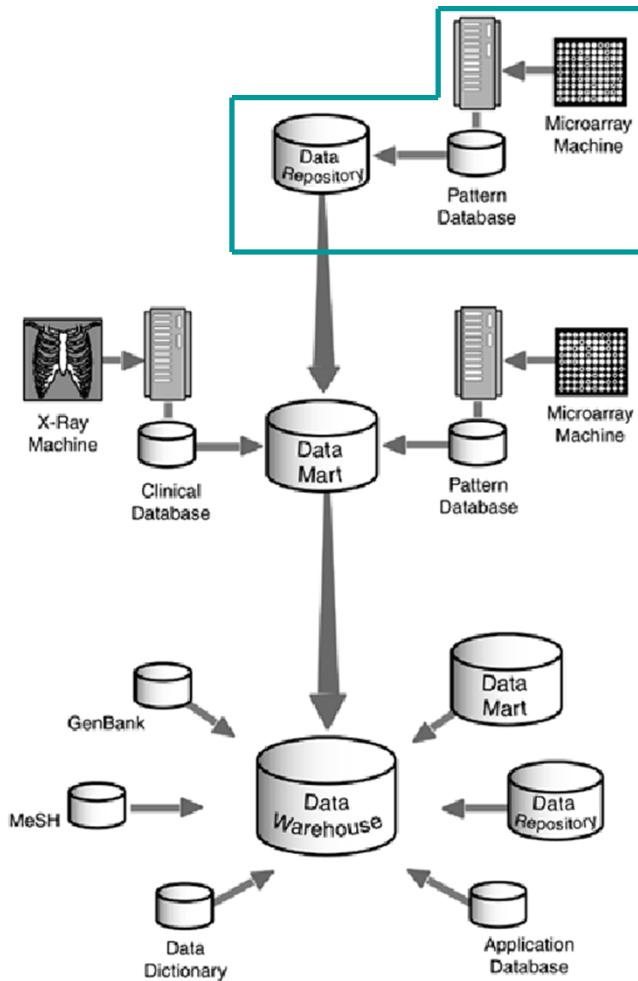
# Public bioinformatics databases accessible via the Internet

Nucleotide Sequence	GenBank	One of the largest public sequence databases	Enzymes and Compounds	LIGAND	Chemical compounds and reactions
	DDBJ	DNA DataBank of Japan	Sequence Motifs (Alignment)	PROSITE	Sequence motifs
	EMBL	European Molecular Biology Laboratory		BLOCKS	Derived from PROSITE
	MGDB	Mouse Genome Database		PRINTS	A superset of BLOCKS
	GSX	Mouse Gene Expression Database		Pfam	Protein families database of alignments and hidden Markov models
	NDB	Nucleic Acid Database		ProDOM	Protein Domains
Protein Sequence	SWISS-PROT	Swiss Institute for Bioinformatics and European Bioinformatics Institute	Pathways and Complexes	Pathway	Metabolic and regulatory pathway maps
	TrEMBL	Annotated supplement to SWISS-PROT	Molecular Disease	OMIM	Online Mendelian Inheritance in Man
	TrEMBLnew	Weekly, pre-processed update to TrEMBL	Biomedical Literature	PubMed	Contains Medline
	PIR	Protein Information Resource		Medline	Medical Literature
3D Structures	PDB	Protein DataBank	Vectors	UniVec	Used to identify vector contamination
	MMDB	Molecular Modeling Database	Protein Mutations	PMD	Protein Mutant Database
	Cambridge Structural Database	For small molecules	Gene Expressions	GEO	Gene Expression Omnibus
			Amino Acid Indices	Aaindex	Amino Acid Index Database
			Protein/Peptide Literature	LITDB	Literature database for proteins and peptides
			Gene Catalog	GENES	KEGG Genes Database

Bergeron, B. *Bioinformatics Computing*



# Ορισμοί – Definitions (1/3)



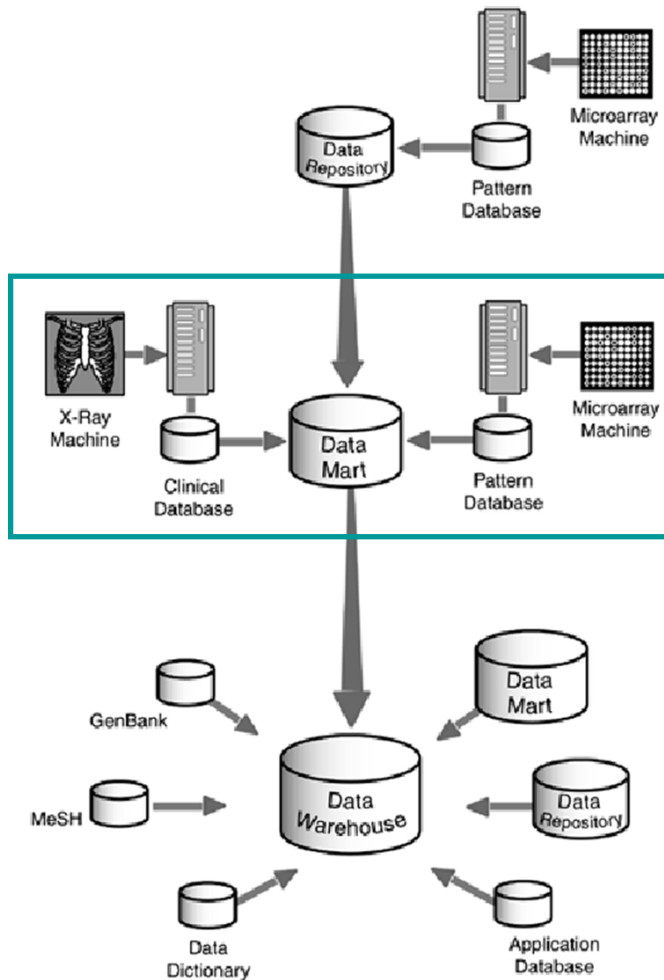
## 1<sup>st</sup> level: Data repository

- Simplest level of a true database is the data repository (database used as an information storage facility) with minimal analysis.
- Advantages using data repository instead of original database.
  - Longitudinal studies are possible because all data in the host application are stored in the repository.
  - Offloads the query functions that are available through native applications to the database management system that enables efficient control and management of the data repository.

**Bergeron, B. *Bioinformatics Computing***



# Ορισμοί – Definitions (2/3)



## 2<sup>nd</sup> level: Data mart

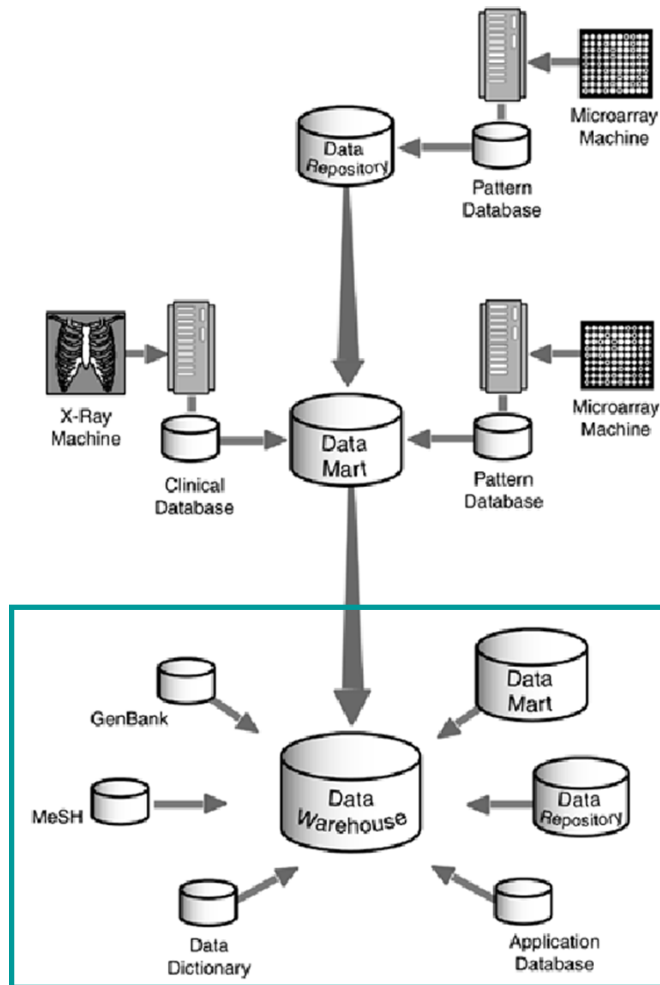
- Εξειδικευμένα θεματικά υποσύνολα.
- Περιορισμένο εύρος δεδομένων για ένα συγκεκριμένο ερευνητικό θέμα.
- Διαφορά με data repository: Περιέχει πειραματικά/κλινικά δεδομένα που προέρχονται από πολλές βάσεις δεδομένων - data repository.

**Bergeron, B. Bioinformatics Computing**





# Ορισμοί – Definitions (3/3)

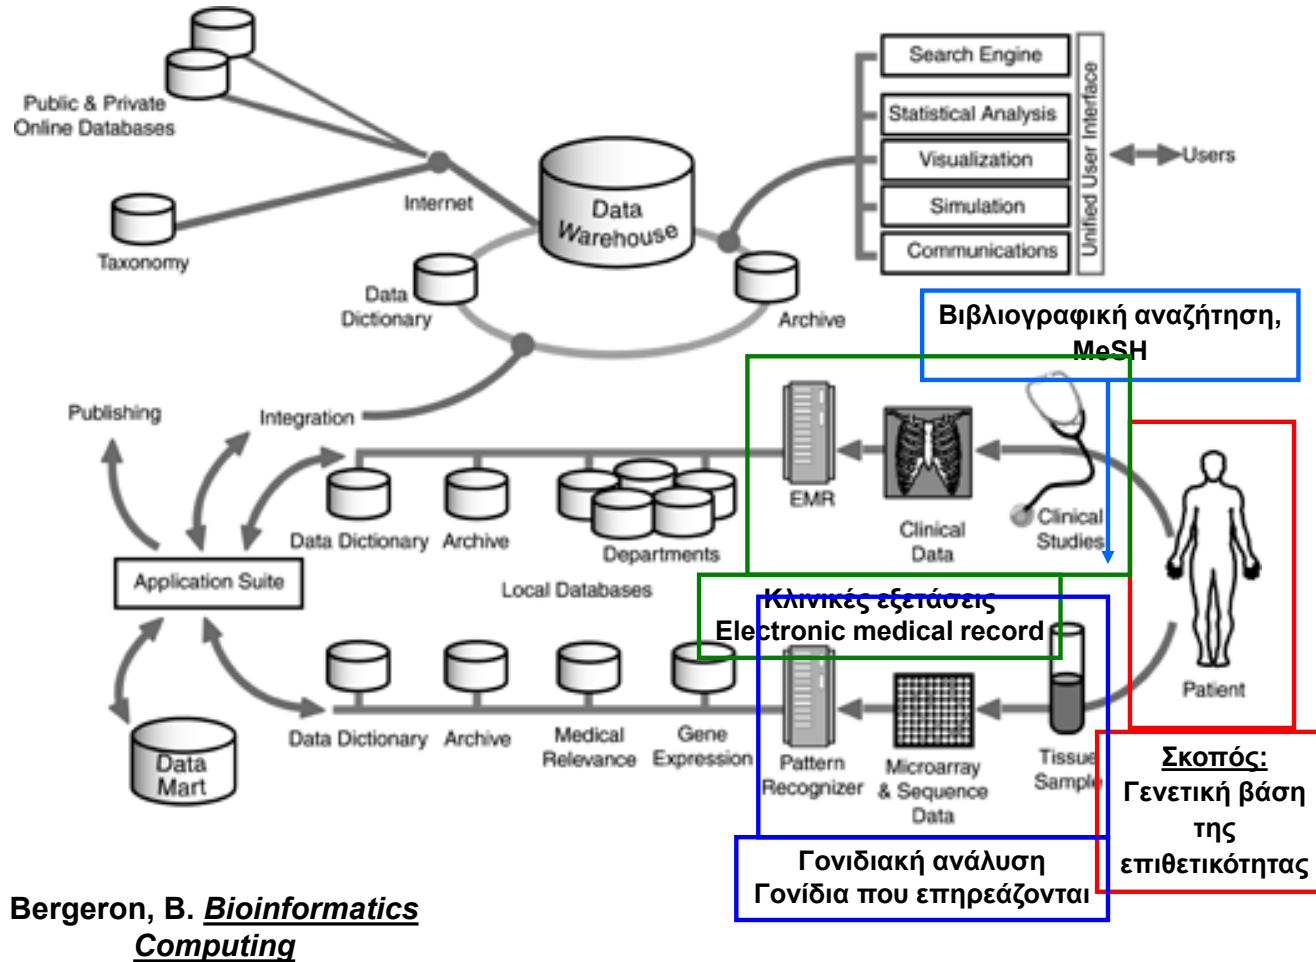


## 3<sup>rd</sup> level: Data warehouse

- Κεντρική βάση δεδομένων.
- Σύνολο όψεων από διαφορετικές πηγές.
- Τα δεδομένα:
  - χαρακτηρίζονται από ανομοιομορφία,
  - δεν αντικαθίστανται από καινούργια δεδομένα,
  - χαρακτηρίζονται από την ημερομηνία καταχώρησης (time-stamped) η οποία δεν αλλάζει.



# Data management scenario for a pharmacogenomic laboratory (1/3)



# Data management scenario for a pharmacogenomic laboratory (2/3)

---

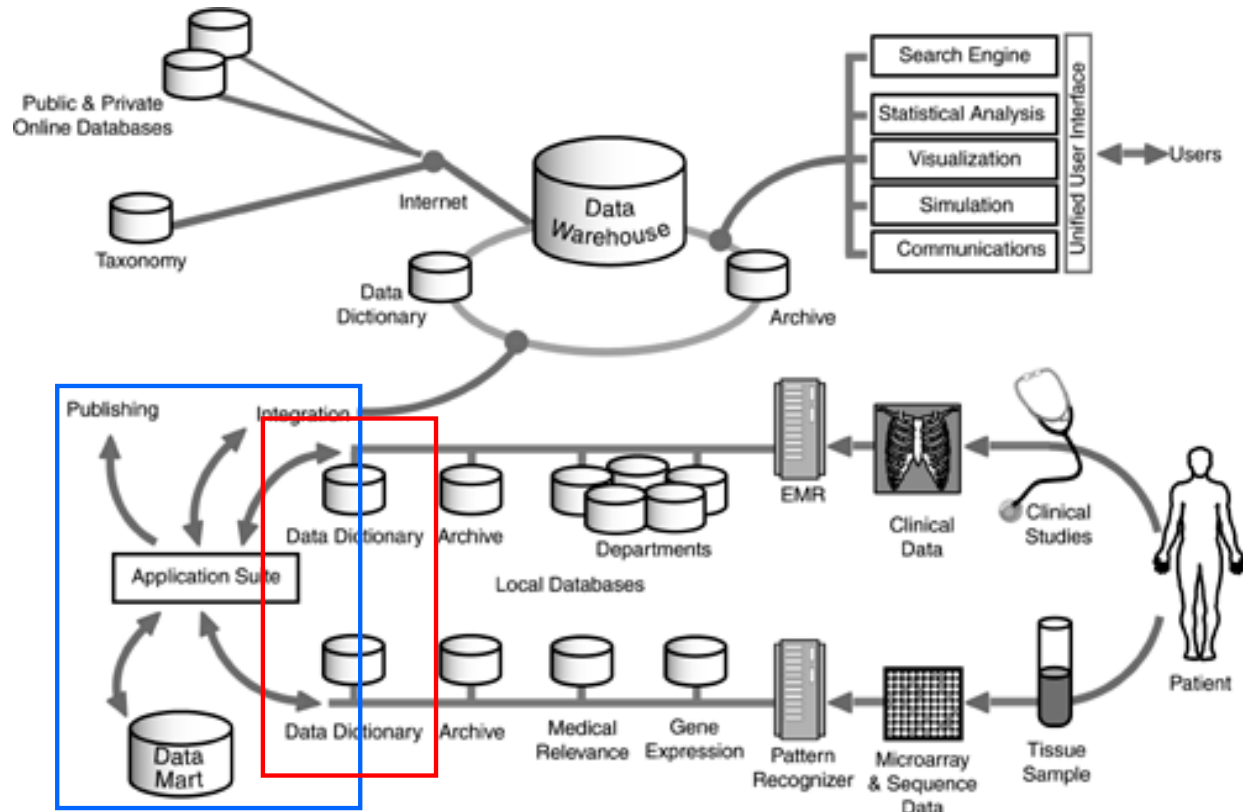
## Typical electronic Medical Record (EMR)

Data Category	Description
Chief Complaint	Patient's primary reason for the medical visit
History of Present Illness	History of onset of clinical signs and symptoms
Medications	Current list of medications the patient is using
Past Medical History	Relevant past medical history, including hospital admissions, surgeries, and diagnoses
Family History	History of family diseases, such as diabetes, cancer, heart disease, and mental illness
Social History	Use of drugs, smoking, job stability, housing, living conditions, incarceration
Review of Systems	Patient's recollection of symptoms and current medical problems, such as trouble sleeping at night or panic episodes, and results of tests
Physical Examination	The clinician's hands-on examination of the patient, including head, eyes, ears, nose, throat, chest, and extremities
Labs	Includes blood glucose, cholesterol, and drug levels
Studies	X-ray, MRI, CT, and EKG
Progress notes	Record of temporal progression of signs and symptoms, labs, and studies for the length of the study or admission

Bergeron, B. *Bioinformatics Computing*



# Data management scenario for a pharmacogenomic laboratory (3/3)

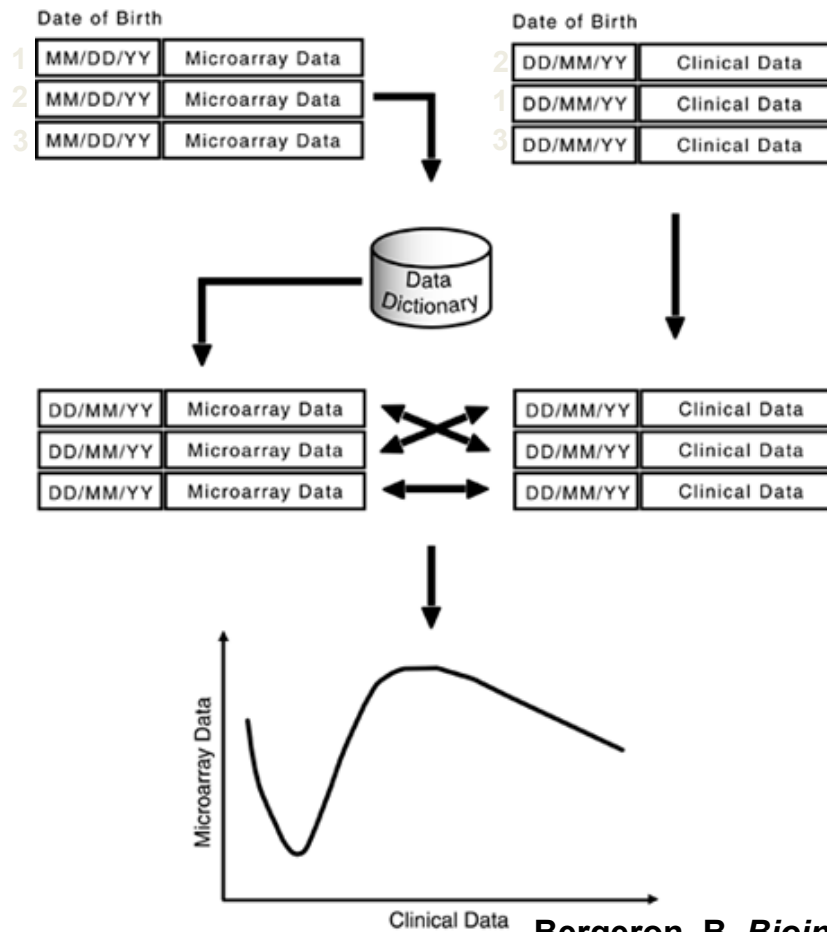


Bergeron, B. *Bioinformatics Computing*



# Data modification

Γονιδιακή  
ανάλυση  
δειγμάτων με  
βιοπληροφορική

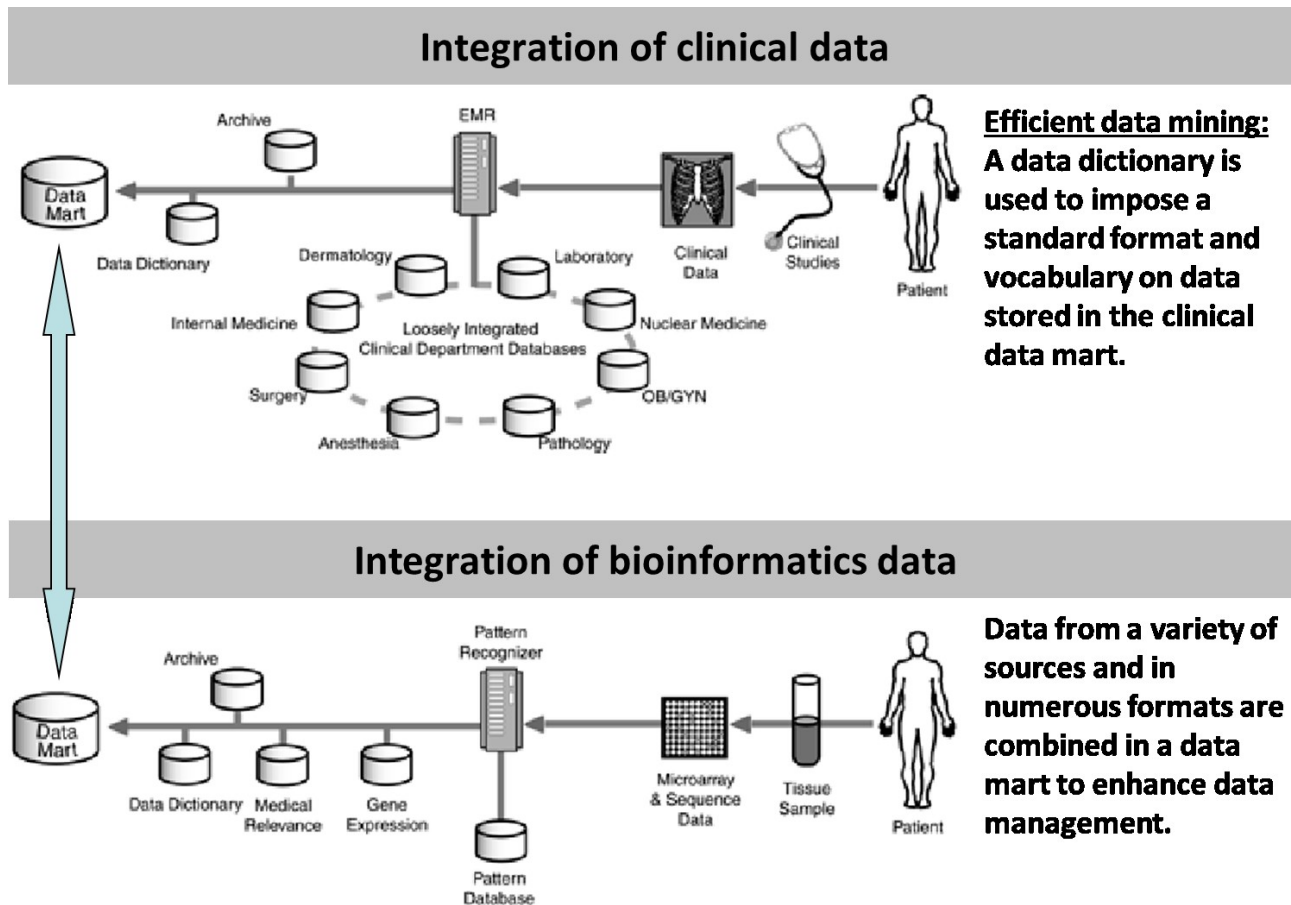


Κλινικές  
δοκιμές σε  
ασθενείς

Bergeron, B. *Bioinformatics Computing*



# Integration of clinical data – Integration of bioinformatics data



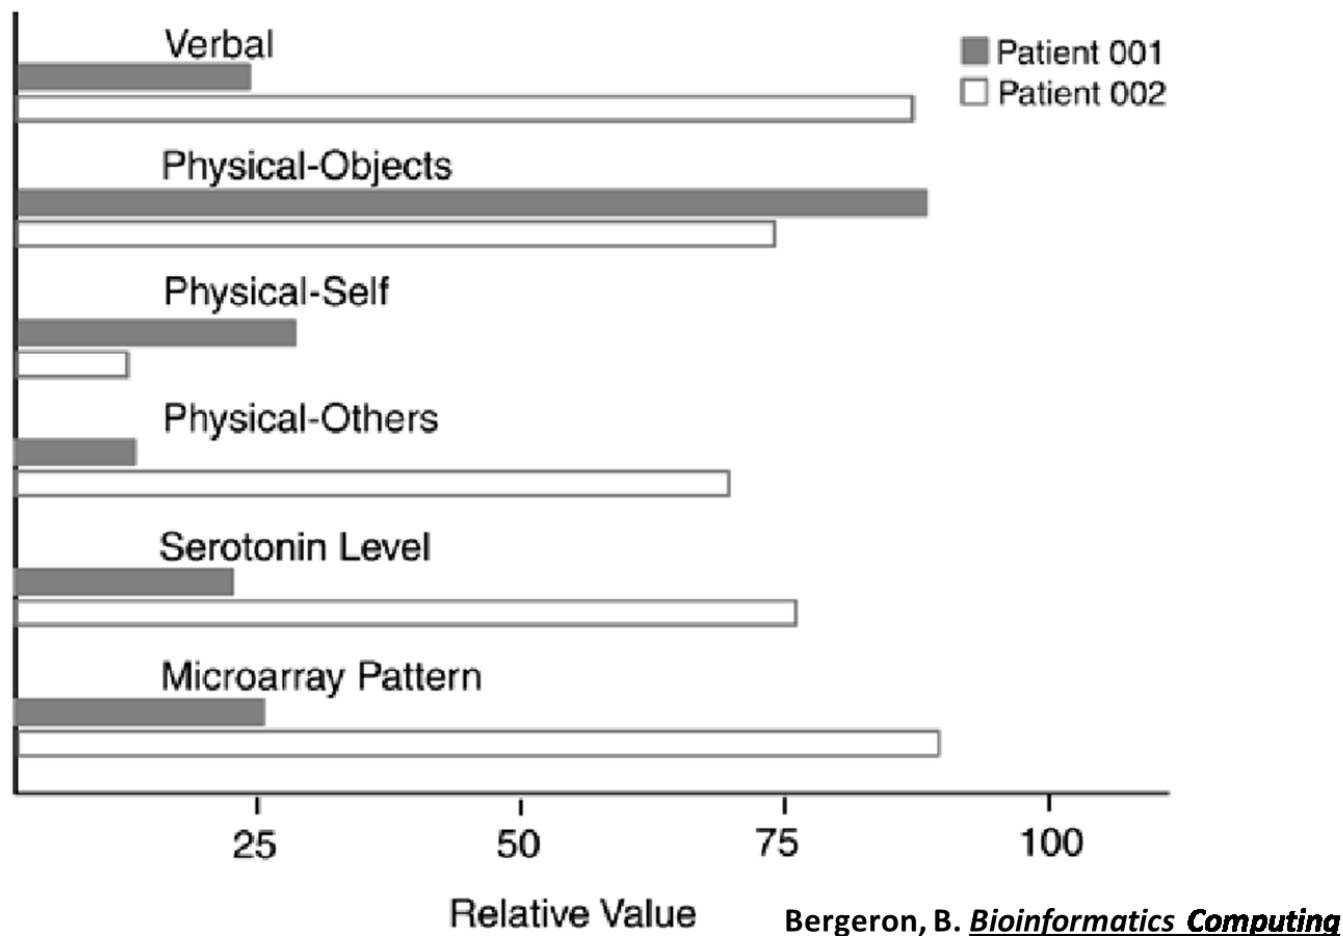
**Efficient data mining:**  
A data dictionary is used to impose a standard format and vocabulary on data stored in the clinical data mart.

**Data from a variety of sources and in numerous formats are combined in a data mart to enhance data management.**

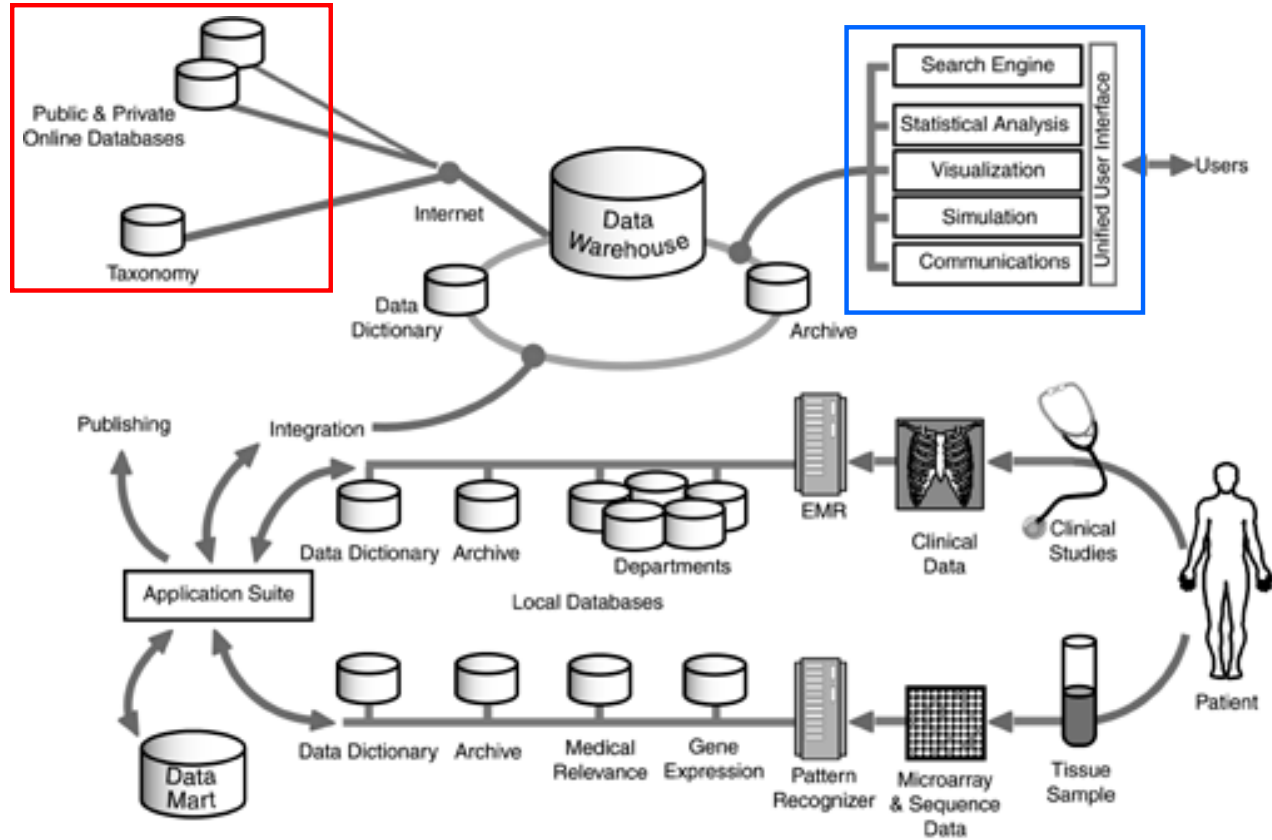
Bergeron, B. *Bioinformatics Computing*



# Aggressive behavior - Results



# Data management scenario for a pharmacogenomic laboratory



Bergeron, B. *Bioinformatics Computing*





# Genomic & public-funded applications

---

## Application

## Examples

Sequence Search

BLAST, BLASTN, CLUSTALW, FASTA, MOTIF, PBLAST, TBLASTIN

Submission

AceDB, Audit, BankIt, Sakura, Sequin, WebIN

Information Retrieval

Entrez, DBGET, IDEAS

Linkage

LocusLink

Portal

KEGG

Structure Match

CD, DALI, SCOP, Searchlite, Structure Explorer, VAST

Visualization

CAD, Cn3D, Mage, RasMol/WebMol, SWISS-PDBViewer, VRML, WebMol

Protein-Protein Interactions

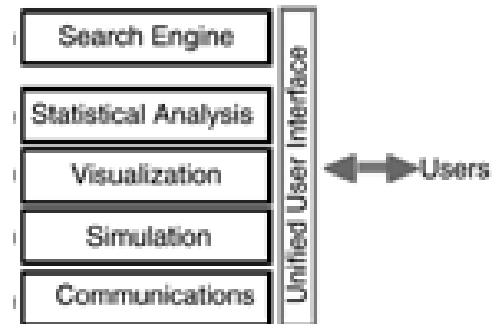
BRITE

Microarray Gene Expression Profiles

Expression

Open-Reading Frame Locator

ORF Finder



Bergeron, B. *Bioinformatics Computing*



# FASTA Format

## for sequencing analysis

- Διάταξη για αλληλουχίες DNA και πρωτεϊνών.
- Περιέχει γραμμή-επικεφαλίδα, η οποία **αρχίζει πάντα με το σύμβολο <**.
- Δίνει το όνομα ακολουθίας και μία σύντομη περιγραφή γι' αυτήν.
- Ακολουθείται από τη νουκλεοτιδική (DNA-RNA) ή αμινοξική (πρωτεΐνη) ακολουθία.

```
1  mvmevgtlda gglrallger aaqcilldcr sffafnaghi agsvnvrfst ivrrakgam
61  glehivpnae lgrllagay havvlders aaldgakrdg tlalaagalc rearaaqvff
>gij184 121 lkggyeafsa scpelcskqs tpmglslpls tsvpdsaesg csscstplyd qggpveilpf
MVME 181 lylgsayhas rkdmldalgi talinvsanc pnhfeghyqy ksipvednhk adisswfnea EHVIPNAE
LRGRL 241 idfidsikna ggrnfvhcqa girsaticl aylmrtnrvk ldeafevkq rrsiispnfs PELCSKQS
TPMGI 301 fmgqllqfes qvlaphcsae agspamavld rgtstttvfn fpvsipvhst nsalsylqsp NVSANC
PNHFE 361 ittspsc RTNRVK
LDEAFEFVKQRRSIISP NFSFMGQLLQFESQVLAPHCSAEAGSPAMAVLDRGTSTTTVFNFVPSIPVHST
NSALSYLQSPITTSPSC
```



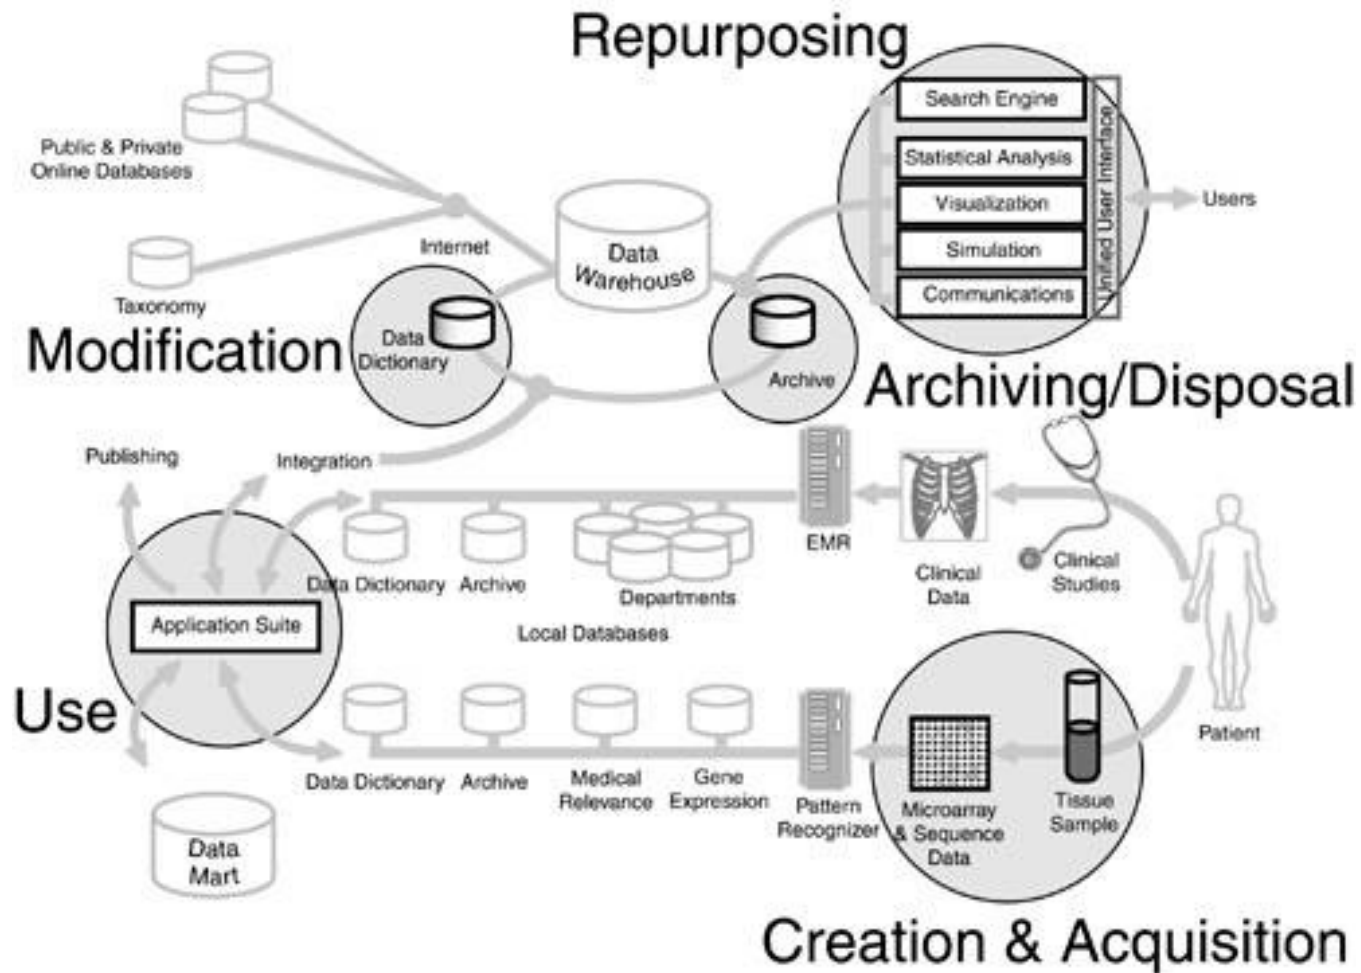
# Καταχωρήσεις (entries) στις βιολογικές βάσεις δεδομένων

---

- Οι καταχωρήσεις έχουν έναν «κύκλο ζωής» στις βάσεις δεδομένων.
- Εξαιτίας της αυξημένης ζήτησης για άμεση πρόσβαση στην νέα πληροφορία, οι καινούργιες καταχωρήσεις είναι διαθέσιμες πριν ολοκληρωθούν και ελεγχθούν από την ερευνητική κοινότητα.
- Οι καταχωρήσεις «ωριμάζουν» μέσω των τάξεων:
  - **Unannotated** → **Preliminary** → **Unreviewed** → **Standard**.
  - **Ασχολίαστη** → **Προκαταρτική** → **Μη επαληθεύσιμη** → **Τελική**.
  - Σπάνια, μία καταχώρηση «πεθαίνει» (an entry '**dies**').
  - Περιορισμένος αριθμός καταχωρήσεων έχει αφαιρεθεί από τις βάσεις δεδομένων όταν διαπιστώθηκε ότι ήταν λανθασμένες.




# Data Life Cycle



# Organic analog of database hierarchy

---



# Αναγκαιότητα...

---

- Αύξηση βιολογικής πληροφορίας εξαιτίας νέων τεχνολογιών.
  - Για παράδειγμα, αύξηση του αριθμού των γονιδιωμάτων των οργανισμών που έχουν αποκρυπτογραφηθεί.
- Διαθεσιμότητα πληροφορίας στους επιστήμονες.
  - Ενοποίηση πληροφοριών από διαφορετικές πηγές.
  - Προσβασιμότητα σε πληροφορία που δεν μπορεί να δημοσιευτεί αναλυτικά.
- Διαθεσιμότητα πληροφορίας σε επεξεργάσιμη μορφή.
  - Αυτόματη ανάλυση.

## Έτσι...

Δημιουργήθηκε η ανάγκη της μεθοδικής οργάνωσής τους σε βάσεις δεδομένων, δηλαδή της ηλεκτρονικής αρχειοθέτησής τους.



# Διαφορετικά είδη βάσεων δεδομένων στη Βιοπληροφορική (1/2)

## 1. Δεδομένα:

- **Καταχώρηση στοιχείων και έλεγχος ποιότητας:**
  - ✓ data deposited directly
  - ✓ curators add and update data
  - ✓ treatment of erroneous data: removed, or marked
  - ✓ error checking
  - ✓ consistency, updates
  - ✓ ....

- **Τύπος δεδομένων:**
  - nucleotide sequences (DNA-RNA)
  - protein sequences
  - 3D structures
  - gene expression data
  - metabolic pathways
  - ....

- **Πρωτογενή ή επεξεργασμένα δεδομένα:**
  - Primary databases: direct experimental results
  - Secondary databases: result of analysis on primary databases
  - Consolidation of many databases
  - ...



# Διαφορετικά είδη βάσεων δεδομένων στη Βιοπληροφορική (2/2)

## 2. Βάση δεδομένων:

### Οργάνωση:

- ✓ flat files.
- ✓ Relational databases.
- ✓ Object-oriented databases.
- ✓ ....

### • Διαθεσιμότητα:

- Publicly available, no restriction.
- Available, but with copyright.
- Accessible, but not downloadable.
- Academic, but not freely available.
- Commercial.

### • Curators:

- Large, public institution (EMBL, NCBI).
- Quasi-academic institute (Swiss institute of Bioinformatics, TIGR,...).
- Academic group or scientist.
- Commercial company.





# Οργάνωση των βιολογικών βάσεων δεδομένων

---

- Ανάλυση των δεδομένων σε:
  - Εγγραφές (records) και πεδία (fields), ή
  - Γραμμές και στήλες, ή
  - Κάρτες και στοιχεία.
- **Εγγραφή (record)**: Συγκεκριμένη ομάδα πληροφοριών που εισάγεται στη βάση δεδομένων. Οι πληροφορίες αυτές αναφέρονται σε **ένα γονίδιο** ή **μία πρωτεΐνη**.
- **Πεδία (fields)**: Τα μέρη στα οποία αναλύεται μία εγγραφή. Ίδια πεδία σε κάθε εγγραφή. Μοναδικό πεδίο σε κάθε εγγραφή.
  - Όνομα πρωτεΐνης / γονιδίου.
  - Αριθμών αμινοξέων / νουκλεοτιδίων.



# Βάσεις δεδομένων - Κατηγορίες

---

- Βάσεις επίπεδης οργάνωσης (flat file):
  - Χειρίζονται μόνο ένα σύνολο από εγγραφές του ίδιου τύπου κάθε φορά.
  - Προορίζονται για τη διαχείριση καταλόγων.
  - Περιορισμένες δυνατότητες / Βοηθητικός ρόλος.



# Παράδειγμα

- Filing cabinet for invoices:
  - **Table:** the filing cabinet.
  - **Rows (records):** individual invoices.
  - **Columns (fields):** data on the individual invoices (*customer, product, price, quantity*).

invoice_	custome	product	price	quantity	total
1	Elmer	buckshot	\$2,00	2	\$4,00
2	Wiley	Acme snow mach	\$5,00	1	\$5,00
3	Elmer	shotgun	\$25,00	1	\$25,00
4	Bugs	carrots	\$0,50	20	\$10,00



# Εγγραφές και πεδία των βιολογικών βάσεων δεδομένων

## ΠΕΔΙΑ - FIELDS

ΕΓΓΡΑΦΕΣ-  
RECORDS

Accession	Protein names	Organism	Length (a.a.)
P32234	GTP-binding protein	Drosophila melanogaster (Fruit fly)	368
P19084	11S globulin seed storage protein G3	Helianthus annuus (Common sunflower)	493
Q4U9M9	104 kDa microneme/rhoptry antigen (p104)	Theileria annulata	893
P15711	104 kDa microneme/rhoptry antigen (p104)	Theileria parva	924

- **Problem:** Storage of data in one way (e.g. alphabetic order).  
Search on any other criteria?



# Παράδειγμα (συνέχεια)

invoice_id	customer	product	price	quantity	total
1	Elmer	buckshot	\$2.00	2	\$4.00
2	Wiley	Acme snow machine	\$5.00	1	\$5.00
3	Elmer	shotgun	\$25.00	1	\$25.00
4	Bugs	carrots	\$0.50	20	\$10.00

- Σ
- Ε
- Γ
- Λ

customer_table		
name	address	notes
Elmer	Looney Tunes Dr.	likes hunting and opera
Wiley	Southwest desert	big mail order customer
Bugs	Rabbit Hole	likes to cross dress

product_table		
product	price	notes
carrots	\$ 0.50	
shotgun	\$ 25.00	oddly flexible
buckshot	\$ 2.00	
Acme snow machine	\$ 5.00	high defect rate



# Σχεσιακές βάσεις δεδομένων (Relational biological database)

**Relationships** can be built between tables and fields:

invoice_id	customer	product	price	quantity	total
1	Elmer	buckshot	\$2.00	2	\$4.00
2	Wiley	Acme snow machine	\$5.00	1	\$5.00
3	Elmer	shotgun	\$25.00	1	\$25.00
4	Bugs	carrots	\$0.50	20	\$10.00

customer_table		
name	address	notes
Elmer	Looney Tunes Dr.	likes hunting and opera
Wiley	Southwest desert	big mail order customer
Bugs	Rabbit Hole	likes to cross dress

product_table		
product	price	notes
carrots	\$ 0.50	
shotgun	\$ 25.00	oddly flexible
buckshot	\$ 2.00	
Acme snow machine	\$ 5.00	high defect rate

database "**schema**"



# Βάσεις δεδομένων – Κατηγορίες (1/3)

---

- Σχεσιακές ή συσχετισμένες βιολογικές βάσεις δεδομένων (Relational biological database):
  - Δυνατότητα ταυτόχρονου χειρισμού και σύνδεσης πολλών συλλογών από εγγραφές διαφορετικών τύπων οργανωμένες σε πίνακες.
  - Οι πίνακες της βάσης μπορούν να συσχετιστούν μεταξύ τους, με αποτέλεσμα την ομοιόμορφη κατανομή της πληροφορίας σε όλη τη βάση.



# Παράδειγμα σχεσιακής βιολογικής βάσης δεδομένων

ΠΡΩΤΕΪΝΕΣ - PROTEINS			
No of protein (primary key)	Protein names	Accession	Length (a.a.)
2	GTP-binding protein	P32234	368
3	11S globulin seed storage protein G3	P19084	493

ΒΙΒΛΙΟΓΡΑΦΙΕΣ - REFERENCES				
No of protein (foreign key)	Reference number (primary key)	Title	Date	Authors
2	45	The genome sequence of...	2000	Adams M.D., Celnikew S.E....

ΣΥΓΓΡΑΦΕΙΣ - AUTHORS			
No of author (primary key)	Reference number (foreign key)	Name	Institute
2	45	Adams M.D.	Case Western Reserve University
6	45	Celnikew S.E	University of California





# Πλεονεκτήματα σχεσιακών βάσεων δεδομένων

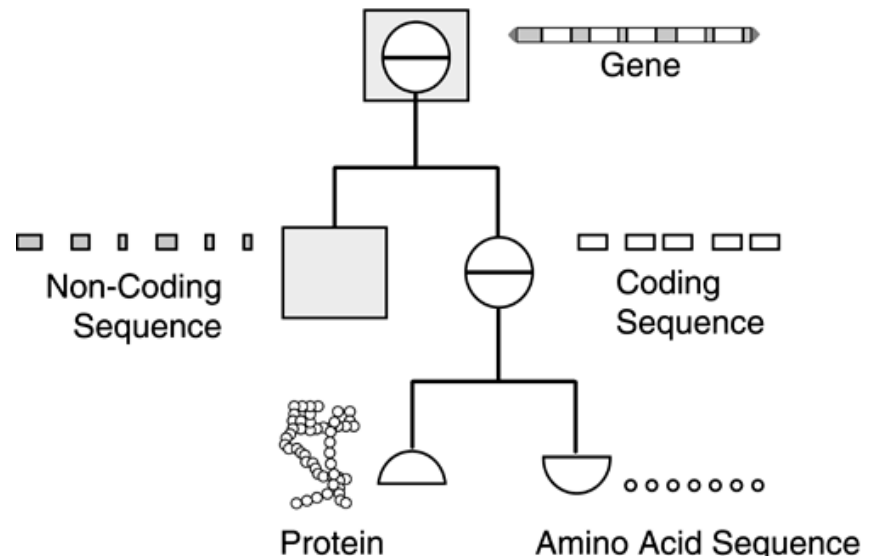
---

- ✓ Αποφυγή επανάληψης και συσσώρευσης δεδομένων.
- ✓ Εξασφάλιση της πληρότητας και της αξιοπιστίας των δεδομένων.
- ✓ Εύκολη άντληση της πληροφορίας.
  - Πακέτα λογισμικού για τη δημιουργία, αποθήκευση και διαχείριση των βάσεων δεδομένων.
  - Συστήματα διαχείρισης βάσεων δεδομένων (Database Management System - DBMS).




# Βάσεις δεδομένων – Κατηγορίες (2/3)

- Αντικειμενοστραφείς Βάσεις Δεδομένων. (Object-oriented biological database):
  - Πολύπλοκες δομές δεδομένων παρουσιάζονται με σύνθετες καταχωρήσεις.
  - Αυτές οι σύνθετες καταχωρήσεις περιέχουν με τη σειρά τους άλλα αντικείμενα.
  - Τελικά οι δομές ομαδοποιούνται σε πολλά επίπεδα.




# Βάσεις δεδομένων – Κατηγορίες (3/3)


---



Flat




Object-Oriented



Relational

# Βιολογικές βάσεις δεδομένων - ΒΒΔ


- **Ορισμός:** Ηλεκτρονικές βιβλιοθήκες βιολογικών πληροφοριών.
- **Οι πληροφορίες συλλέγονται από:**
  - Επιστημονικά πειράματα.
  - Δημοσιευμένη βιβλιογραφία.
  - Πειράματα και αναλύσεις που πραγματοποιούνται στον Η/Υ.



# Βιολογικές βάσεις δεδομένων - Κατηγορίες (1/3)

- Γενικευμένες (Generalised) ή Αρχειακές (Archival): Περιλαμβάνουν πρωτογενή βιολογική πληροφορία.
  - Πρωτογενείς βάσεις δεδομένων ακολουθιών.
  - Βάσεις δεδομένων με τρισδιάστατες δομές.

```
GATCCCTGCC TGGGCTTTGC CTCTGCAGCC CCCC GCCCA CAGGTTACA C2TCGGGTCT  
TCTCCACCGC TGCCACACGC CAGAGCCTGT AGCGGGGCT CAGAGTCTGG GAGGTGGGAC  
TCCTGCACCT CAGCCATCAT CAGACCCATG GGGCCACCCA GGGAACTTGG GCAGGGACCA  
TTACCAGTGA CTTGCCGAGG CCCC GGACTC TGCCAGCCAG CTGTGCCGGC CACCTGCCCC  
CGGACAGTGC CGGTTCAATG GGGAACTAGG GGACGATGTG GTTCTTCGCA TCTGATGATG  
AAGGCCCTGG GCCACTTGGC ACGGGCGGGC GCTCCCGAGA TGGATATGAG GAGCCCCCTC  
TGCCCAACTC CCAGAAAAGC CGAGGCTCTG CAGCGGGAGG AAGTCCTGCG ATGTCCTGGG  
GGCAGCAGC GCAGGGCACA GGGACAGCCC CCTCCACAG CTCTTCCTGG CCAGCCCTCC  
CCACTATCTG CCAGGAGGTT GCTTCTTCCA GGAGGCTTTT CCGCACCAGC CCAGGGGTCC  
AGGGTCTGGG GCTCCAGACT GCTGTGAGTG CTGCACATTC TCTTGAGGAC AGCCCCCTCC  
CTCCCCGACC CACTTCTGGT GCCCACTGTG GCCACAGCAA GCCTGGGGC CTGCACTCAG  
GGACCTCGGG GCCTCCTGGG GAGCTGCTGA CCTAGGCAG AGAGATTGCA CATCCCTAAG  
AGTCTACAGA CACCCAGTG TTTGCCAGTG TTTGCCCGTG TTCACCACTG TTTGCCAGTG  
TTTGCCAGTA TTTGCTCGCC AGTGTTCGCC ACTTGTCCCT CTGGCTGCAA GAGTGACTGG  
GTTTGGGCGG GAAGTTGCAG GTCCTCCAG GACAGTTGGC CGATGACGTG GAGACAGACC  
CACCCCCCAA TCTTGGCTCC CTGCAGGAGC CCGGGCCCCC CGAGATCCTG GCGGTGCTCA  
GCACGACGGG CACCTCCGTG TTCACCACTG CAATGGGCAC GGAGCGTGGC TTTATTTGCA  
TGTCTGGATT CCTAACACT TCAAGCCTCTG CACCTCCTGG GTTTTCCTG CTGCAAAATG  
CCATTTGGCG TCGTCCCAA TTTCCGGCCA AGGCCGCTC GTCGTGCTGC TGTGTAATTT  
GATGTGTGGA GTTCTAGATA CCAAGTGTCT GTCGGTTTGA GACATCGCAA ACCTCCTTCC  
CAGTGTGGCC CGTCCATTCG CTCTGTGCA GCAAATCTT TAATTTATTTG ATGGCATCAA  
AATGTGTGTC CAGTTTACC TTTAGTTTA TACTTTCGAA CATTTGTTG AGAAATCTT  
CTCCCACTG TGGCTGATAG TGACGTCTTC TAACCTCCCA TTTACTATGT TACATTCAGA  
CCCATCATCT TCAGGAAGAC GCTTGTGTGC GAGACGGGTA TGAGGCCCCC ACACCCCGCC  
TCAGGACCAC TGTCCATGGT TCCACCCCTG ACCCCGGACT CCGTCCCCA GACCTCTAA
```



# Βιολογικές βάσεις δεδομένων - Κατηγορίες (2/3)

---

- Δευτερεύουσες (Secondary) βιολογικές βάσεις δεδομένων: Τα δεδομένα τους προκύπτουν από ανάλυση των δεδομένων των αρχειακών βάσεων δεδομένων.
  - ΒΔ στις οποίες έχουν ληφθεί υπόψη οι πρωτεϊνικές αλληλουχίες **στην πρόβλεψη** της τρισδιάστατης δομής των πρωτεϊνών.
  - ΒΔ που, ιεραρχούν/συσχετίζουν οικογένειες πρωτεϊνών, δομικά κοινές πρωτεΐνες, κοινά μοτίβα ακολουθιών DNA και πρωτεϊνών.
  - ΒΔ που καταγράφουν μεταλλαγές ή παραλλαγές στις ακολουθίες DNA ή πρωτεϊνών.



# Βιολογικές βάσεις δεδομένων - Κατηγορίες (3/3)

---

- **Βιολογικές βάσεις δεδομένων ιστοσελίδων που περιλαμβάνουν:**
  - Βάσεις δεδομένων που περιέχουν ως εγγραφές βιολογικές βάσεις δεδομένων.
  - Συνδέσμους μεταξύ των βιολογικών βάσεων δεδομένων.
- **Εξειδικευμένες βάσεις δεδομένων:**
  - ΒΔ μικροσυστοιχιών (microarrays).
  - ΒΔ μεταβολικών μονοπατιών.
- **Βιβλιογραφικές βάσεις δεδομένων.**



# Βιβλιογραφικές βάσεις δεδομένων

---

dblp .uni-trier.de  
Computer Science  
Bibliography

PubMed

Πληροφορική  
Ιατρική - Βιολογία  
Βιομοριακή Τεχνολογία





# Είδη δημοσιεύσεων

---

- Books – Βιβλία (μονογραφίες).
- Journals – Επιστημονικά περιοδικά.
- Conferences – Επιστημονικά συνέδρια.
- Research articles - Ερευνητικά Άρθρα.
- Review articles – Άρθρα ανασκόπησης.
- Meta – analysis – Ανάλυση αποτελεσμάτων προηγούμενων δημοσιεύσεων.



# Η δομή μίας δημοσίευσης – Computer science

---

1. Abstract.
2. Introduction.
3. Method – Algorithm – Tools.
4. Results / Conclusions.
5. References.



# Ερευνητικό άρθρο - Research Article (1/2)

---

**BIOINFORMATICS APPLICATIONS NOTE**

Vol. 27 no. 7 2011, pages 1034–1035  
doi:10.1093/bioinformatics/btr047

---

*Data and text mining*

Advance Access publication February 9, 2011

## **GeneReporter—sequence-based document retrieval and annotation**

Annekathrin Bartsch<sup>1</sup>, Boyke Bunk<sup>1</sup>, Isam Haddad<sup>1</sup>, Johannes Klein<sup>1</sup>, Richard Münch<sup>1</sup>, Thorsten Johl<sup>2</sup>, Uwe Kärst<sup>2</sup>, Lothar Jänsch<sup>2</sup>, Dieter Jahn<sup>1</sup> and Ida Retter<sup>1,\*</sup>

<sup>1</sup>Institute for Microbiology, Technische Universität Braunschweig, Spielmannstr. 7, 38106 Braunschweig and <sup>2</sup>Cellular Proteomics Group, Helmholtz Centre for Infection Research, Inhoffenstr. 7, 38124 Braunschweig, Germany

Associate Editor: Jonathan Wren

---



# Ερευνητικό άρθρο - Research Article (2/2)

---

## ABSTRACT

**Summary:** GeneReporter is a web tool that reports functional information and relevant literature on a protein-coding sequence of interest. Its purpose is to support both manual genome annotation and document retrieval. PubMed references corresponding to a sequence are detected by the extraction of query words from UniProt entries of homologous sequences. Data on protein families, domains, potential cofactors, structure, function, cellular localization, metabolic contribution and corresponding DNA binding sites complement the information on a given gene product of interest. **Availability and implementation:** GeneReporter is available at <http://www.genereporter.tu-bs.de>. The web site integrates databases and analysis tools as SOAP-based web services from the EBI (European Bioinformatics Institute) and NCBI (National Center for Biotechnology Information). **Contact:** i.retter@tu-bs.de; ida.retter@helmholtz-hzi.de **Supplementary information:** Supplementary data are available at *Bioinformatics* online.

Received on October 3, 2010; revised on December 1, 2010; accepted on January 9, 2011

## 1 INTRODUCTION

In face of next-generation sequencing and high-throughput analyses, the link between obtained data and existing knowledge is crucial. Automatic annotation pipelines provide useful evidence of potential functions for genes and proteins, but in a last essential step, the scientist must manually evaluate the available information. Usually, the necessary evidence is derived from scientific publications, databases and *in silico* predictions. Thus, tools that provide a combination of all of these relevant data for a gene or protein of interest are of high practical impact. In this context, GeneReporter offers a customizable workflow for the integrated application of protein sequence analysis and document retrieval.

A large number of diverse text-mining tools exist that provide different strategies and interfaces to satisfy the extensive data-mining demands in biomedical sciences (Krallinger *et al.*, 2010). GeneReporter identifies citations related to a gene or protein sequence of interest. The UniProt annotations of homologous sequences are used to derive keywords such as gene names, synonyms and species. These keywords provide the query terms for a subsequent literature search in PubMed (Sayers *et al.*, 2010). In

## 3 RESULTS

The results are summarized on an overview page. For each query sequence, this page provides a link to a detailed view of the obtained

## ACKNOWLEDGEMENTS

We would like to thank the EBI and NCBI for providing web service access to their tools and databases. We would also like to thank Max Schobert for intensive testing and discussions and Patrick Jökel for the layout of the GeneReporter logo.

**Funding:** Grants of the German Federal Ministry of Education and Research (BMBF) for the European transnational research initiative on 'Systems Biology of Microorganisms', SysMO (Pysmo) (grant number 0313980D); the Volkswagen Foundation (I/81448).

**Conflict of Interest:** none declared.

## REFERENCES

- Altschul,S.F. *et al.* (1997) Gapped BLAST and PSI-BLAST: a new generation of protein database search programs. *Nucleic Acids Res.*, 25, 3389–3402.
- Diederich,G. *et al.* (2005) MineBlast: a literature presentation service supporting protein annotation by data mining of BLAST results. *Bioinformatics*, 21, 3450–3451.
- Gickrist,M.J. *et al.* (2008) Evading the annotation bottleneck: using sequence similarity to search non-sequence gene data. *BMC Bioinformatics*, 9, 442.
- Goujon,M. *et al.* (2010) A new bioinformatics analysis tools framework at EMBL-EBI. *Nucleic Acids Res.*, 38, W695–W699.
- Hiller,K. *et al.* (2004) PrediSi: prediction of signal peptides and their cleavage positions. *Nucleic Acids Res.*, 32, W375–W379.
- Hunter,S. *et al.* (2009) InterPro: the integrative protein signature database. *Nucleic Acids Res.*, 37, D211–D215.
- Lopez,R. *et al.* (2003) WU-Blast2 server at the European Bioinformatics Institute. *Nucleic Acids Res.*, 31, 3795–3798.
- Käll,L. *et al.* (2007) Advantages of combined transmembrane topology and signal peptide prediction—the Phobius web server. *Nucleic Acids Res.*, 35, W429–W432.
- Krallinger,M. *et al.* (2010) Analysis of biological processes and diseases using text mining approaches. *Methods Mol. Biol.*, 593, 341–382.
- Mitchell,A.L. *et al.* (2005) METIS: multiple extraction techniques for informative sentences. *Bioinformatics*, 21, 4196–4197.
- Sayers,E.W. *et al.* (2010) Database resources of the National Center for Biotechnology Information. *Nucleic Acids Res.*, 38, D5–D16.
- UniProt Consortium (2010) The Universal Protein Resource (UniProt) in 2010. *Nucleic Acids Res.*, 38, D142–D148.



# SCOPUS (1/3)



Hub | ScienceDirect | Scopus | SciTopics | Applications

SCOPUS <http://www.scopus.com/home.url>

[Search](#) | [Sources](#) | [Analytics](#) | [My alerts](#) | [My list](#) | [My settings](#)

**Document search** | Author search | Affiliation search | Advanced search

[? Search tips](#)

Search for:  in   
E.g., "heart attack" AND stress

[Add search field](#) |

**Limit to:**

**Date Range (inclusive)**  
 Published  to   
 Added to Scopus in the last  days

**Document Type**

**Subject Areas** ⓘ

Life Sciences (> 4,300 titles)  Physical Sciences (> 7,200 titles)  
 Health Sciences (> 6,800 titles. 100% Medline coverage)  Social Sciences & Humanities (> 5,300 titles)

Download mobile apps



About Scopus:

- [What is Scopus?](#)
- [Content coverage](#)
- [What do users think?](#)
- [Scopus tutorials](#)
- [Join an Upcoming Scopus Live Training](#)
- [SJR & SNIP metrics](#)

Resource Library:

- [Brochures](#)
- [User guides](#)
- [Fact sheets](#)

**Search history** [Hide](#) ⓘ

Search	Results	Actions
You have not performed any searches in this session.		

**Note:** This Search history will contain the latest 50 searches you perform in this session.



# SCOPUS (2/3)

Document search **Author search** Affiliation search Advanced search

[? Search tips](#)

**Author** ⓘ :    Show exact matches only  
E.g., smith E.g., j.l.

**Initials or First Name**

**Affiliation:**   
E.g., university of toronto

**Search**

**Subject Areas** ⓘ

Life Sciences  Physical Sciences  
 Health Sciences  Social Sciences & Humanities

**Search**

Document search Author search **Affiliation search** Advanced search

[? Search tips](#)

**Affiliation** ⓘ :   
E.g., university of toronto

**Search**

[Would you like to search for documents by affiliation?](#) ⓘ



# SCOPUS (3/3)

Search | Sources | Analytics | My alerts | My list | My settings Live Chat | Help

Quick Search

Scopus: 104,502


Your query: TITLE-ABS-KEY-AUTH(dynamic algorithm)

---

Document results: 104,502 | [Show all abstracts](#) Go to page: 1 of 5226  [Next >](#)

All  With selected  Page          Sort by **Date (Newest)**

Document title	Author(s)	Date	Source title	Citations
1 <input type="checkbox"/> A branch and bound algorithm for minimizing total completion time on a single batch machine with incompatible job families and dynamic arrivals	Yao, S., Jiang, Z., Li, N.	2012	<i>Computers and Operations Research</i> 39 (5), pp. 939-951	0
<input type="button" value="Full Text"/>   <input type="button" value="Show abstract"/>   <input type="button" value="Related documents"/>				
2 <input type="checkbox"/> Restricted dynamic programming: A flexible framework for solving realistic VRPs	Gromicho, J., Van Hoom, J.J., Kok, A.L., Schutten, J.M.J.	2012	<i>Computers and Operations Research</i> 39 (5), pp. 902-909	0
<input type="button" value="Full Text"/>   <input type="button" value="Show abstract"/>   <input type="button" value="Related documents"/>				
3 <input type="checkbox"/> An effective genetic algorithm for network coding	Hu, X.-B., Leeson, M.S., Hines, E.L.	2012	<i>Computers and Operations Research</i> 39 (5), pp. 952-963	0
<input type="button" value="Full Text"/>   <input type="button" value="Show abstract"/>   <input type="button" value="Related documents"/>				
4 <input type="checkbox"/> Metaheuristics for the traveling salesman problem with pickups, deliveries and handling costs	Erdoğan, G., Battarra, M., Laporte, G., Vigo, D.	2012	<i>Computers and Operations Research</i> 39 (5), pp. 1074-1086	0
<input type="button" value="Full Text"/>   <input type="button" value="Show abstract"/>   <input type="button" value="Related documents"/>				
5 <input type="checkbox"/> Variable neighbourhood search for the variable sized bin packing problem	Hemmelmayr, V., Schmid, V., Blum, C.	2012	<i>Computers and Operations Research</i> 39 (5), pp. 1097-1108	0
<input type="button" value="Full Text"/>   <input type="button" value="Show abstract"/>   <input type="button" value="Related documents"/>				
6 <input type="checkbox"/> Vehicle routing under time-dependent travel times: The impact of congestion avoidance	Kok, A.L., Hans, E.W., Schutten, J.M.J.	2012	<i>Computers and Operations Research</i> 39 (5), pp. 910-918	1
<input type="button" value="Full Text"/>   <input type="button" value="Show abstract"/>   <input type="button" value="Related documents"/>				
7 <input type="checkbox"/> An operator allocation optimization model for balancing control of the hybrid assembly lines using Pareto utility discrete differential evolution algorithm	Zeng, X., Wong, W.-K., Leung, S.Y.-S.	2012	<i>Computers and Operations Research</i> 39 (5), pp. 1145-1159	0
<input type="button" value="Full Text"/>   <input type="button" value="Show abstract"/>   <input type="button" value="Related documents"/>				
8 <input type="checkbox"/> An improved algorithm for the longest common subsequence problem	Mousavi, S.R., Tabataba, F.	2012	<i>Computers and Operations Research</i> 39 (3), pp. 512-520	0
<input type="button" value="Full Text"/>   <input type="button" value="Show abstract"/>   <input type="button" value="Related documents"/>				
9 <input type="checkbox"/> The dynamic space allocation problem: Applying hybrid GRASP and Tabu search metaheuristics	Da Silva, G.C., Bahiense, L., Satoru Ochi, L., Boaventura-Netto, P.D.	2012	<i>Computers and Operations Research</i> 39 (3), pp. 671-677	0
<input type="button" value="Full Text"/>   <input type="button" value="Show abstract"/>   <input type="button" value="Related documents"/>				





# Scopus, Πηγές (Sources)

---

- Agricultural and Biological Science.
- Arts and Humanities.
- Biochemistry, Genetics and Molecular Biology.
- Business, Management and Accounting.
- Chemical Engineering.
- Chemistry.
- **Computer Science.**
- Dentistry.
- Earth and Planetary Sciences.
- Economics, Econometrics and Finance.
- Energy.
- **Engineering.**
- Environmental Science.
- Health Professions.
- Immunology and Microbiology.
- Materials Science.
- Mathematics
- Medicine
- Neuroscience.
- Nursing.
- Pharmacology, Toxicology and Pharmaceutics.
- Physics and Astronomy.
- Psychology.
- Social Sciences.
- Veterinary.





# Google (1/6)

---



---

Οι παραθέσεις μου Προειδοποιήσεις Μετρήσεις Ρυθμίσεις



bioinformatics algorithm



Στηριχθείτε γερά πάνω σε γίγαντες



# Google (2/6)



The screenshot shows a Google Scholar search page for the query "bioinformatics algorithm". The browser's address bar shows the URL "scholar.google.gr/scholar?hl=en&q=bioinformatics+algorithm&btnG=".

**Μελετητής** Περίπου 866.000 αποτελέσματα (0,06 sec.)

**Οποιαδήποτε στιγμή**  
Από το 2013  
Από το 2012  
Από το 2009  
Προσαρμοσμένο εύρος...

**Ταξινόμηση κατά συνάφεια**  
Ταξινόμηση κατά ημερομηνία

- συμπεριληφθεί ευρεσιτεχνιών
- να περιλαμβάνονται παραθέματα
- Δημιουργία αδοποίησης

**Συμβουλή:** Αναζήτηση αποτελεσμάτων μόνο στα **Ελληνικά**. Μπορείτε να επιλέξετε τη γλώσσα αναζήτησης στη σελίδα Ρυθμίσεις Μελετητή.

**ETS gene fusions in prostate cancer: from discovery to daily clinical practice** [PDF] από cornell.edu  
SA Tomlins, A Bjartell, AM Chinnaiyan, G Jenster... - European urology, 2009 - Elsevier  
... 1). Thus, a novel **bioinformatics algorithm** called the Cancer Outlier Profile Analysis (COPA) was developed to analyze DNA microarray data for outlier genes (those markedly overexpressed in a subset of cases) [3]. Full-size image (45 K) Full-size image (45 K) Fig ...  
Γίνεται αναφορά σε 150 Σχετικά άρθρα Όλες οι 15 εκδόχές Παράθεση

**[βιβλίο] An introduction to bioinformatics algorithms** [PDF] από emory.edu  
NC Jones, P Pevzner - 2004 - books.google.com  
This introductory text offers a clear exposition of the algorithmic principles driving advances in **bioinformatics**. Accessible to students in both biology and computer science, it strikes a unique balance between rigorous mathematics and practical techniques, emphasizing the ...  
Γίνεται αναφορά σε 332 Σχετικά άρθρα Όλες οι 13 εκδόχές Παράθεση

**Applied bioinformatics for the identification of regulatory elements** [PDF] από umontreal.ca  
WW Wasserman, A Sandelin - Nature Reviews Genetics, 2004 - nature.com  
... **Bioinformatics** resources that provide broadly related orthologues between species include COGs/KOGs 30 ... There are two broadly used **algorithms** for such alignments: one that targets short ... For the former, the BLASTZ 33 **algorithm** identifies short segments of exact identity and ...  
Γίνεται αναφορά σε 730 Σχετικά άρθρα Όλες οι 18 εκδόχές Παράθεση

**DAVID Bioinformatics Resources: expanded annotation database and novel algorithms to better extract biology from large gene lists** [HTML] από oxfordjournals.org  
BT Sherman, O Tan, J Kir, D Liu, D Bryant... - Nucleic acids ..., 2007 - Oxford Univ Press  
Abstract All tools in the DAVID **Bioinformatics Resources** aim to provide functional interpretation of large lists of genes derived from genomic studies. The newly updated DAVID **Bioinformatics Resources** consists of the DAVID Knowledgebase and five ...  
Γίνεται αναφορά σε 245 Σχετικά άρθρα Όλες οι 18 εκδόχές Παράθεση

**Data mining in bioinformatics using Weka** [PDF] από oxfordjournals.org  
E Frank, M Hall, L Trigg, G Holmes, JH Witten - Bioinformatics, 2004 - Oxford Univ Press  
... regression, clustering and feature selection—common data mining problems in **bioinformatics** research ... It contains an extensive collection of machine learning **algorithms** and data pre-processing ... from data and (b) enable them to easily identify a suitable **algorithm** for generating ...  
Γίνεται αναφορά σε 384 Σχετικά άρθρα Όλες οι 18 εκδόχές Παράθεση

**A review of feature selection techniques in bioinformatics** [HTML] από oxfordjournals.org  
Y Saeyn, Llinza, P Larralde - bioinformatics, 2007 - Oxford Univ Press  
... In Saeyn et al. (2004), an estimation of distribution **algorithm** (EDA, a generalization of genetic **algorithms**) was used to ... 3.2 Feature selection for microarray analysis. During the last decade, the advent of microarray datasets stimulated a new line of research in **bioinformatics** ...  
Γίνεται αναφορά σε 1061 Σχετικά άρθρα Όλες οι 24 εκδόχές Παράθεση




# Google (3/6)

---

 Οι παραθέσεις μου

 Οι ενημερώσεις μου

 Προειδοποιήσεις

 Μετρήσεις

 Ρυθμίσεις

Google  
scholar



# Google (4/6)



**Sofia Bellou** Επεξεργασία  
 University of Western Macedonia-University of Ioannina Επεξεργασία  
**Signal transduction - Angiogenesis - Cancer therapy** Επεξεργασία  
 Η διεύθυνση ηλεκτρονικού ταχυδρομείου έχει επαληθευτεί στον τομέα uowm.gr Επεξεργασία  
 Το προφίλ μου είναι δημόσιο Επεξεργασία Σύνδεσμος Προσθήκη κριτικής αξιολόγησης

Αλλαγή φωτογραφίας

**Δείκτες παραθέσεων**

Δείκτης	Όλο	Από το 2008
Παραθέσεις	32	32
h-index	3	3
i10-index	1	1

**Παραθέσεις στο έργο μου**



Επιλέξτε: Όλα, Κανένα Ενέργειες 1-8

Τίτλος / Συγγραφέας	Παρατίθεται από	Έτος
VEGF autoregulates its proliferative and migratory ERK1/2 and p38 cascades by enhancing the expression of DUSP1 and DUSP5 phosphatases in endothelial cells S Bellou, MA Hink, E Bagli, E Panopoulou, PIH Bastiaens, C Murphy, T Fotis American Journal of Physiology-Cell Physiology 297 (6), C1477-C1489	14	2009
Immunohistochemical study of the epithelial-mesenchymal transition phenotype in cancer of unknown primary: incidence, correlations and prognostic utility A Stoyianni, A Goussia, G Pantheroudakis, V Sizozopoulou, E Ioachim, D ... Anticancer research 32 (4), 1273-1281	8	2012
Insulin resistance: An adaptive mechanism becomes maladaptive in the current environment—An evolutionary perspective A Tzatsoulis, MD Mantzaris, S Bellou, M Andrikoula Metabolism	7	2012
The isoflavone metabolite 6-methoxyquercetin inhibits angiogenesis and suppresses tumor growth S Bellou, E Karali, E Bagli, N Al-Maharik, L Morbidelli, M Ziche, H ... Molecular cancer 11 (1), 1-11	2	2012
Anti-Angiogenesis in Cancer Therapy: Hercules And Hydra S Bellou, G Pantheroudakis, C Murphy, T Fotis Cancer letters	1	2013
PP23-Implication of "labile iron" in H <sub>2</sub> O <sub>2</sub> -induced cell signaling MD Mantzaris, I Verginadis, V Skiada, S Bellou, S Kitzati, D Galaris Free Radical Biology and Medicine 65, S31		2013
VEGF autoregulates its proliferative and migratory CM Bastiaens, T Fotis, S Bellou, MA Hink, E Bagli, E Panopoulou, PIH Carcinogenesis 32 (3), 286-295		2011
VEGF auto-regulates its proliferative and migratory ERK1/2 and p38 MAPK cascades by enhancing the expression of DUSP1 and DUSP5 phosphatases in endothelial cells S Bellou, M Hink, E Bagli, E Panopoulou, P Bastiaens, C Murphy, T Fotis FEBS JOURNAL 275, 302-302		2008

Επιλέξτε: Όλα, Κανένα Ενέργειες 1-8

**Google scholar**

[Αναζήτηση Συγγραφέων](#)

Οι παραθέσεις μου - Βοήθεια

[Ακολουθήστε αυτόν τον συγγραφέα](#)  
 Ακολουθήστε νέα άρθρα  
 Ακολουθήστε νέες παραθέσεις

**Προσθήκη από κοινού συγγραφέων**

Michalis D. Mantz... Προσθήκη

[Προβολή όλων των συγγραφέων](#)

**Συν-συγγραφείς**

Δεν υπάρχουν συν-συγγραφείς

Ηλεκτρονικό ταχυδρομείο

Πρόσκληση συν-συγγραφέα  
 Αποστολή πρόσκλησης


Οι ημερομηνίες και οι αριθμοί των παραθέσεων υπολογίζονται και καθορίζονται από το υπολογιστικό πρόγραμμα.  
 ©2013 Google - Πληροφορίες για τον Μετρητή Google - Σχετικά με τη Google - Αποστολή σχολίων - Οι παραθέσεις μου

# Google (5/6)

---

 Οι παραθέσεις μου

 Οι ενημερώσεις μου

 Προειδοποιήσεις

 Μετρήσεις

 Ρυθμίσεις

Google  
scholar



# Google (6/6)

The screenshot shows a Google Scholar search results page. At the top, the Google logo is on the left, a search bar in the center, and a search button on the right. Below the search bar, the text 'Μελετητής' (Author) is followed by '46 αποτελέσματα (0,05 δευ.)'. To the right of this are icons for 'Οι παραθέσεις μου' (My citations), a notification bell with '0', and a dropdown arrow. Below this is a section for 'Οι ενημερώσεις μου' (My updates) with a sub-section 'Προτεινόμενα με βάση τις Αναφορές μου' (Recommended based on my references). This section contains a list of search results, each with a title, a brief abstract, and a link to the full text. The results are as follows:

Προτεινόμενα με βάση τις Αναφορές μου	Προβολή	Κορυφή	Όλο
<p><a href="#">VEGFR and Type-V RTK Activation and Signaling</a> M Shibuya - Cold Spring Harbor perspectives in biology, 2013 - cshperspectives.com 14 ημέρες πριν - Abstract Vascular endothelial growth factor receptors (VEGFRs) in vertebrates play essential roles in the regulation of angiogenesis and lymphangiogenesis. VEGFRs belong to the receptor-type tyrosine kinase (RTK) supergene family. They consist ... <a href="#">Παράθεση</a></p>			<a href="#">[HTML] από cshperspectives.com</a>
<p><a href="#">Mitogen-Activated Protein Kinase Phosphatases in Metabolism</a> A Lawan, AM Bennett - Protein Tyrosine Phosphatase Control of ... , 2013 - Springer 45 ημέρες πριν - Although we continue to learn much about how the mitogen-activated protein kinases (MAPKs) are involved in physiological and pathophysiological signaling in metabolism, a comparable level of understanding about the mechanisms of MAPK ... <a href="#">Παράθεση</a></p>			
<p><a href="#">[HTML] Novel VEGF Decoy Receptor Fusion Protein Conbercept Targeting Multiple VEGF Isoforms Provide Remarkable Anti-Angiogenesis Effect In Vivo</a> Q Wang, T Li, Z Wu, Q Wu, X Ke, D Luo, H Wang - PloS one, 2013 - dx.plos.org 63 ημέρες πριν - Abstract VEGF family factors are known to be the principal stimulators of abnormal angiogenesis, which play a fundamental role in tumor and various ocular diseases. Inhibition of VEGF is widely applied in antiangiogenic therapy. Conbercept is a ... <a href="#">Παράθεση</a></p>			<a href="#">[HTML] από plos.org</a>
<p><a href="#">[HTML] In Vivo Monitoring of Angiogenesis Inhibition via Down-Regulation of Mir-21 in a VEGFR2-Luc Murine Breast Cancer Model Using Bioluminescent Imaging</a> D Zhao, Y Tu, L Wan, L Bu, T Huang, X Sun, K Wang... - PloS one, 2013 - dx.plos.org 67 ημέρες πριν - Abstract MicroRNA-21 (miR-21) is overexpressed in a wide range of cancers and involved in tumor proliferation and metastasis. However, the potential function of miR-21 in regulating tumor angiogenesis has been little disclosed. In this study, we ... <a href="#">Παράθεση</a></p>			<a href="#">[HTML] από plos.org</a>
<p><a href="#">Thrombospondin-1 modulates VEGF signaling via CD36 by recruiting SHP-1 to VEGFR2 complex in microvascular endothelial cells</a> LY Chu, DP Ramakrishnan... - Blood, 2013 - bloodjournal.hematologylibrary.org 75 ημέρες πριν - Abstract Thrombospondin-1 (TSP-1) inhibits growth factor signaling at the receptor level in microvascular endothelial cells (MVEC), and CD36 has been suggested to be involved in this inhibition, but the mechanisms are not known. We hypothesized that ... <a href="#">Παράθεση</a></p>			<a href="#">[HTML] από hematologylibrary.org</a>
<p><a href="#">Pseudophosphatase STYX modulates cell-fate decisions and cell migration by spatiotemporal regulation of ERK1/2</a> V Reiterer, D Fey, W Kolch... - Proceedings of the ... , 2013 - National Acad Sciences 95 ημέρες πριν - Abstract Serine/threonine/tyrosine-interacting protein (STYX) is a catalytically inactive member of the dual-specificity phosphatases (DUSPs) family. Whereas the role of DUSPs in cellular signaling is well explored, the function of STYX is still ... <a href="#">Παράθεση</a></p>			<a href="#">[HTML] από pnas.org</a>
<p><a href="#">[PDF] p38 beta MAP kinase</a> S Rousseau - UCSD Molecule Pages, 2013 - escholarship.org</p>			<a href="#">[PDF] από escholarship.org</a>



# Google (7/8)

---

 Οι παραθέσεις μου

 Οι ενημερώσεις μου

 Προειδοποιήσεις

 Μετρήσεις


 Ρυθμίσεις

Google  
scholar



# Google (8/8)

Ιστός Εικόνες Περισσότερα... sofiabellou@gmail.com



**Μελετητής** Δημιουργία ειδοποίησης Εμφάνιση ειδοποιήσεων

Προειδοποιήσεις

Ερώτημα ειδοποίησης:

Ηλεκτρονικό ταχυδρομείο:

Αριθμός αποτελεσμάτων:

[Πληροφορίες για τον Μελετητή Google](#) [Σχετικά με τη Google](#) [Απόρρητο και όροι](#) [Στείλτε μας τα σχόλιά σας](#)





# PubMed – NCBI

(National Center for Biotechnology Information)

NCBI Resources How To My NCBI Sign In

**PubMed.gov**  
U.S. National Library of Medicine  
National Institutes of Health

Search: PubMed Limits Advanced search Help

Search Clear



## PubMed

PubMed comprises more than 20 million citations for biomedical literature from MEDLINE, life science journals, and online books. Citations may include links to full-text content from PubMed Central and publisher web sites.


### Using PubMed

[PubMed Quick Start Guide](#)

[Full Text Articles](#)

[PubMed FAQs](#)

[PubMed Tutorials](#)

[New and Noteworthy](#) 

### PubMed Tools

[Single Citation Matcher](#)

[Batch Citation Matcher](#)

[Clinical Queries](#)

[Topic-Specific Queries](#)

### More Resources

[MeSH Database](#)

[Journals Database](#)

[Clinical Trials](#)

[E-Utilities](#)

[LinkOut](#)

<http://www.ncbi.nlm.nih.gov/sites/entrez?db=pubmed>



# PubMed

NCBI Resources How To My NCBI Sign In

PubMed.gov U.S. National Library of Medicine National Institutes of Health

Search PubMed Advanced search Help

Search Clear

## Limits

Dates

Published in the Last: Any date

Type of Article

- Clinical Trial
- Editorial
- Letter
- Meta-Analysis
- Practice Guideline

Species

- Humans
- Animals

Subsets

Journal Groups

- Core clinical journals
- Dental journals
- Nursing journals

Text Options

- Links to full text
- Links to free full text
- Abstracts

Languages

- English
- French
- German
- Italian
- Japanese

Gender

- Male
- Female

Ages

- All Infant: birth-23 months
- All Child: 0-18 years
- All Adult: 19+ years
- Newborn: birth-1 month
- Infant: 1-23 months

Search Field Tags

Field: All Fields

Reset Search

## PubMed Advanced Search

[Back to PubMed](#)

Search Box

Search Preview Clear

## Search Builder

All Fields AND Add to Search Box

[Show Index](#)

[Search Builder Instructions](#)



# DBLP Database

**DBLP Database**  
DataBase systems  
and Logic  
Programming  
or  
Digital Bibliography  
& Library Project.



home | browse | search | about

## DBLP FAQ: How does the 'author search' work?

Name:

A query is interpreted as a **set of prefixes of name parts**. If you enter a few words, you get the names which include these words as prefixes of some name parts:

**query** = A Meyer — **answers** = Achim Meyer, Andrea Meyer, Anne Meyer, Hans-Albert Meyer, A. Meyers, Anton Smith-Meyer, ...

**query** = Ar b c — **answers** = Clark B. Archer, Arnold B. Calica, Arnab B. Chowdry, Armin B. Cremers, ...

More details:

- The query and the names stored in DBLP are broken in parts. The delimiters of this 'tokenizing' are spaces and punctuation marks. The punctuation marks are not relevant for the matching. "Ar-b-c." produces the same result as "Ar b c".
- The matching is NOT case-sensitive.
- The order of the query words does not matter, i.e. the queries "Petra M A" and "M Petra A" are equivalent.
- If you end a query word with a \$-sign, only exact matches of this word are shown. Try the queries "xi li" vs. "xi\$li" vs. "xi li\$" vs. "xi\$li\$" ("xi\$ li" and "xi\$li" are equivalent).

Diacritic marks:

- Most parts of DBLP are restricted to the Latin-1 character set. This includes characters like ä, é, è, ñ, ã ç etc. but NOT ì, ð, ú, § ... In DBLP, we try to transliterate all person names to Latin-1.
- As long as you restrict your query to ASCII (Basic Latin in Unicode) the search engine matches 'diacritic insensitive', i.e. the query "moller" matches "moller", "möller", "møller", "möller" etc.
- As soon as your query contains any diacritic mark, the matching becomes exact. Now "René" matches "René" but not "Rene" or "Renè".

Encoding, form method, ...:

- The preferred encoding to transmit the query is UTF-8. As soon as the query contains a byte sequence which is illegal in UTF-8, the incoming byte sequence is interpreted as Latin-1.
- Additionally, the search engine understands character entities like &auml; for the Latin-1 characters.
- The author search accepts queries using the GET method.



data released under the ODC-BY 1.0 license. See also our legal information page  
last updated on 2013-10-14T21:48:16 by the dblp team



# DBLP

[home](#) | [browse](#) | [search](#) | [about](#)



## DBLP FAQ: How does the 'author search' work?

Name:

A query is interpreted as a **set of prefixes of name parts**. If you enter a few words, you get the names which include these words as prefixes of some name parts:

**query** = A Meyer — **answers** = Achim Meyer, Andrea Meyer, Anne Meyer, Hans-Albert Meyer, A. Meyers, Anton Smith-Meyer, ...

**query** = Ar b c — **answers** = Clark B. Archer, Arnold B. Calica, Arnab B. Chowdry, Armin B. Cremers, ...

More details:

- The query and the names stored in DBLP are broken in parts. The delimiters of this 'tokenizing' are spaces and punctuation marks. The punctuation marks are not relevant for the matching. "Ar-b-c." produces the same result as "Ar b c".
- The matching is NOT case-sensitive.
- The order of the query words does not matter, i.e. the queries "Petra M A" and "M Petra A" are equivalent.
- If you end a query word with a \$-sign, only exact matches of this word are shown. Try the queries "xi li" vs. "xi\$li" vs. "xi li\$" vs. "xi\$li\$" ("xi\$ li" and "xi\$li" are equivalent).

Diacritic marks:

- Most parts of DBLP are restricted to the Latin-1 character set. This includes characters like ä, é, è ñ, ã ç etc. but NOT Ì, Ć, Ū, Ş ... In DBLP, we try to transliterate all person names to Latin-1.
- As long as you restrict your query to ASCII (Basic Latin in Unicode) the search engine matches 'diacritic insensitive', i.e. the query "moller" matches "moller", "möller", "møller", "móller" etc.
- As soon as your query contains any diacritic mark, the matching becomes exact. Now "René" matches "René" but not "Rene" or "Renè".


Encoding, form method, ...:

- The preferred encoding to transmit the query is UTF-8. As soon as the query contains a byte sequence which is illegal in UTF-8, the incoming byte sequence is interpreted as Latin-1.
- Additionally, the search engine understands character entities like &uml; for the Latin-1 characters.
- The author search accepts queries using the GET method.



# Πρωτογενείς βάσεις δεδομένων DNA & πρωτεϊνών

---



# Πρωτογενείς βάσεις δεδομένων DNA (Primary sequence database)

---

1. NCBI - National Centre of Biotechnology information (U.S.A.).
2. EMBL - European Molecular Biology Laboratory (Europe).
3. DDBJ - DNA Data Banf of Japan (Japan).

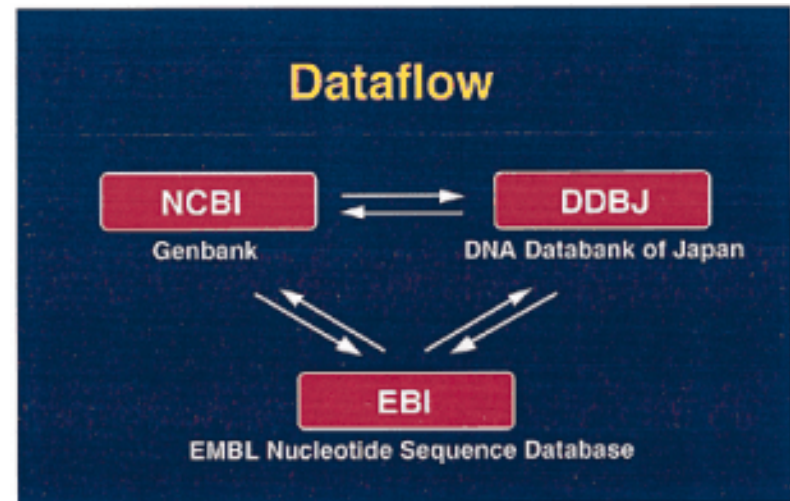
**Σκοπός:** Συλλογή και διάθεση στην επιστημονική κοινότητα ακολουθιών DNA και RNA από πλήρως ή μερικώς αποκρυπτογραφημένα γονιδιώματα οργανισμών, θέτοντας κοινούς κανόνες ταξινόμησης και σχολιασμού των δεδομένων.

Τα δεδομένα υποβάλλονται από διάφορες ανά τον κόσμο επιστημονικές ομάδες σε μία από τις τρεις βάσεις δεδομένων και **μέσω της καθημερινής ανταλλαγής στοιχείων** ενημερώνονται και οι υπόλοιπες.



# INSDC

- International Nucleotide Sequence Database Collaboration.
- Made up of:
  - GenBank,
  - European Nucleotide Archive, and
  - DNA Data Bank of Japan.
- Represents an archival repository of all sequences.



# Identifiers and Accession numbers

---

- **Identifier:** Συμβολοσειρά από γράμματα και ψηφία που συνήθως είναι «δυσνόητα».
  - Example: TPIS\_CHICK (Triose Phosphate Isomerase from chicken (gallus gallus)) in protein database.
  - The identifier can change (based on the curator).
- **Accession code:** Συμβολοσειρά από γράμματα και ψηφία που αναγνωρίζει μοναδικά την καταχώρηση στη βάση δεδομένων.
  - The accession number for TPIS\_CHICK is P00940.
  - Accession number should not be changed!!





# NCBI - GENBANK

---

- Υπό την αιγίδα του Εθνικού Ινστιτούτου Υγείας (National Institutes of Health - NIH).
- Διαθέτει νουκλεοτιδικές αλληλουχίες από περισσότερους από 300,000 οργανισμούς.
- Δεδομένα:
  - Απευθείας υποβολές των αποτελεσμάτων ερευνών διαφόρων μικρών ερευνητικών ομάδων, ή
  - Υποβολές εύρεσης της αλληλουχίας του γονιδιώματος διαφόρων οργανισμών από μεγάλα ερευνητικά κέντρα.
- Η τελευταία έκδοση της GENBANK περιλαμβάνει:
  - 126,551,501,141 βάσεις DNA.
  - 135,440,924 εγγραφές.



# Format αρχείου GenBank

- Αποτελείται από 3 μέρη:
  - i. Σχόλια (Comment).
  - ii. Χαρακτηριστικά (Features).
  - iii. Ακολουθία (Sequence).

[Display Settings:](#)  GenBank

## Homo sapiens dual specificity phosphatase 5 (DUSP5), mRNA

NCBI Reference Sequence: NM\_004419.3

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

[Go to:](#)

Comment	NM_004419	2545 bp	mRNA	linear	PRI 25-SEP-2011
Features	Homo sapiens dual specificity phosphatase 5 (DUSP5), mRNA.				
Sequence	NM_004419				
	NM_004419.3	GI:62865889			



# GENBANK Format – DNA (1/2)

**Locus:** Η γραμμή περιλαμβάνει αριθμό υποβολής εγγραφής (Accession

**Version:** Ο αριθμός υποβολής της εγγραφής της ακολουθίας και η

**Source:** Το κοινό όνομα του

**Organism:** Το επίσημο επιστημονικό όνομα του οργανισμού και η συστηματική αναγνώρισή του.

**Reference:** Παράθεση των άρθρων που περιέχουν δεδομένα για την εγγραφή, με αναφορά στον συγγραφέα, τον τίτλο του άρθρου, τα στοιχεία του περιοδικού στο οποίο δημοσιεύτηκε, το μοναδικό αριθμό καταχώρησης του άρθρου στις βιβλιογραφικές βάσεις δεδομένων MEDLINE & PUBMED.

## Homo sapiens dual specificity phosphatase 5 (DUSP5), mRNA

[Comment](#) [Features](#) [Sequence](#)

```

LOCUS       NM_004419                2545 bp     mRNA     linear     PRI 01-MAR-
2009
DEFINITION Homo sapiens dual specificity phosphatase 5 (DUSP5), mRNA.
ACCESSION  NM_004419
VERSION    NM_004419.3  GI:62865889
KEYWORDS   .
SOURCE     Homo sapiens (human)
ORGANISM   Homo sapiens
            Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi;
            Mammalia; Eutheria; Euarchontoglires; Primates; Haplorrhini;
            Catarrhini; Hominidae; Homo.
REFERENCE  1 (bases 1 to 2545)
AUTHORS   Pramanik,K., Chun,C.Z., Garzaas,M.K., Samant,G.V., Li,K.,
            Horswill,M.A., North,P.E. and Ramchandran,R.
TITLE     Dusp-5 and Sazk-1 coordinately function during vascular
            development
            and disease
JOURNAL   Blood 113 (5), 1184-1191 (2009)
PUBMED   18927432
REMARK    GeneRIF: mutations in dusp-5 and sazr-1 have been identified in
            affected tissues of patients with vascular anomalies, implicating
            the Sazr-1-Dusp-5 signaling pathway in human disease.
REFERENCE  2 (bases 1 to 2545)
AUTHORS   Kovanen,P.E., Bernard,J., Al-Shami,A., Liu,C.,
            Bollenbacher-Reilley,J., Young,L., Fise-Masison,C., Spolski,R.
            and
            Leonard,W.J.
TITLE     T-cell development and function are modulated by dual specificity
            phosphatase DUSP5
    
```



# GeneBank - Comment

## COMMENT

REVIEWED [REFSEQ](#): This record has been curated by NCBI staff. The reference sequence was derived from [BF979291.1](#), [CB991409.1](#), [U15932.2](#), [AL355512.22](#), [BC062545.1](#) and [BI495660.1](#).  
On Apr 22, 2005 this sequence version replaced gi:[12707565](#).

**Summary:** Περίληψη λειτουργίας της πρωτεΐνης που κωδικοποιείται από το γονίδιο

**Summary:** The protein encoded by this gene is a member of the dual specificity protein phosphatase subfamily. These phosphatases inactivate their target kinases by dephosphorylating both the phosphoserine/threonine and phosphotyrosine residues. They negatively regulate members of the mitogen-activated protein (MAP) kinase superfamily (MAPK/ERK, SAPK/JNK, p38), which are associated with cellular proliferation and differentiation. Different members of the family of dual specificity phosphatases show distinct substrate specificities for various MAP kinases, different tissue distribution and subcellular localization, and different modes of inducibility of their expression by extracellular stimuli. This gene product inactivates ERK1, is expressed in a variety of tissues with the highest levels in pancreas and brain, and is localized in the nucleus. [provided by RefSeq, Jul 2008].

Publication Note: This RefSeq record includes a subset of the publications that are available for this gene. Please see the Gene record to access additional publications.

COMPLETENESS: complete on the 3' end.

PRIMARY	REFSEQ_SPAN	PRIMARY_IDENTIFIER	PRIMARY_SPAN	COMP
	1-49	BF979291.1	35-83	
	50-464	CB991409.1	37-451	
	465-465	U15932.2	420-420	
	466-602	CB991409.1	453-589	
	603-861	U15932.2	555-813	
	862-1003	AL355512.22	181442-181583	
	1004-2493	AL355512.22	184449-185938	
	2494-2495	U15932.2	2444-2445	
	2496-2513	BC062545.1	2413-2430	
	2514-2545	BI495660.1	146-177	



# GENBANK - Features

Χαρακτηριστικά

FEATURES

source

```
Location/Qualifiers
1..2545
/organism="Homo sapiens"
/mol_type="mRNA"
/db_xref="taxon:9606"
```

Χρωμόσωμα

gene

```
/map="10q25"
1..2545
/gene="DUSP5"
/gene_synonym="DUSP; HVH3"
/note="dual specificity phosphatase 5"
/db_xref="GeneID:1847"
/db_xref="HGNC:3071"
/db_xref="HPRD:04349"
/db_xref="MIM:603069"
```

**Coding sequence:** Αρχή της μεταγραφής του γονιδίου σε πρωτεΐνη – ATG: start codon

CDS

```
256..1410
/gene="DUSP5"
/gene_synonym="DUSP; HVH3"
/EC_number="3.1.3.16"
/EC_number="3.1.3.48"
/note="serine/threonine specific protein phosphatase;
VH1-like phosphatase 3; dual specificity protein
phosphatase hVH3"
/codon_start=1
/product="dual specificity protein phosphatase 5"
/protein_id="NP_004410.3"
/db_xref="GI:62865890"
/db_xref="CCDS:CCDS7566.1"
/db_xref="GeneID:1847"
/db_xref="HGNC:3071"
/db_xref="HPRD:04349"
/db_xref="MIM:603069"
```

Αλληλουχία πρωτεΐνης

```
/translation="MKVTSLDGRQLRKMLRKEAAARCVVLD CRPYLAF AASNVRGSLN
VNLNSVLRARRGGAVSARYVLPDEAARALLQEGGGVAAVVVLDQGSRRHWQKLREE
SAARVVLTSLLACLPA GPRVYFLKGGYETFYSEYPECCVDV RPISEKIESERALISQ
CGKPVVNVSYRPA YDQGGPVEILPFLYLGSAYHASKCEFLANLHITALLNVSRRTSEA
CATHLHYKWI PVEDSHTADISSHFQEAIDFIDCVREKGGKVLVHCEA GISRSP TICMA
YLMKTKQFRLKEAFDYIKQRRSMVSPNFGFMGQLLQYSEIILPSTPNPQPPSCQGEAA
GSSLLIHLQTLSPDMQ GAYCTFPASV LAPVPTHSTVSELSRSPVATATSC"
```



# GENBANK Format – DNA (2/2)

Αλληλουχία DNA

Start codon (256): ATG

Stop codon (1410): GAT

```
ORIGIN
1  actcattcac  ataaaaacgct  gcgcggccgg  cggaaatcccc  ggetttctagg  gggcgagcgc
61  gccgggcttg  ctatcgcagcg  agcggggcgg  gaacgcggag  ttgcgcgcgc  gctcggggcg
121  cgggctccgt  cgcggccgca  gccccgcggg  tcgccctccc  gtgcctcgcc  cgcggacacc
181  ctggccgtgg  acaccctggc  cgtgggcacc  cgcggggcgc  gcggcgcggg  gccgctggcc
241  ggcggcggcg  gcggcatgaa  ggtcacgctg  ctgcacgggc  gccagctcgc  caagatgctc
301  cgcgaaggag  cgcggcggcg  ctgcgtggtg  ctgcactgcc  ggccctatct  ggccctcgct
361  gccctcgaacg  tgcgcggctc  gctcaaacgtc  aacctcaact  cggtggtgct  gcggcggggc
421  cggggcggcg  cggtgtcggc  gcgctacgtg  ctgcccgcgc  aggcggcgcg  cgcgcggctc
481  ctgcaggagg  gcggcggcgg  cgtcgcggcc  gttggtggtg  tggaccaggg  cagccgcacc
541  tggcagaagc  tgcgagagga  gagcgcgcgc  cgtgtcgtcc  tcacctcgct  actcgtctgc
601  ctaccgcgcg  gccgcggggt  ctacttctc  aaaggggat  atgagacttt  ctactcggaa
661  tatectgagt  gttgcgtgga  tgtaaaacc  atttcacaa  agaagattga  gagtgcagga
721  gccctcatca  gccagtggtg  aaaaccagt  gtaaatgtca  gctacaggcc  agcttatgac
781  cagggtggcc  cagttgaaat  ccttccctc  ctctacctg  gaagtgccta  ccattgatcc
841  aagtgcgagt  tcctcgccaa  cctgcacatc  acagccctgc  tgaatgtctc  ccgacggacc
901  tccgaggcct  gcgcgaccca  cctacactac  aaatggatcc  ctgtggaaga  cagccacacg
961  gctgacatta  gctcccactt  tcaagaagca  atagacttca  ttgactgtgt  cagggaaaag
1021  ggaggcaagg  tcctggtcca  ctgtgaggct  gggatctccc  gttcaccacc  catctgcagt
1081  gcttacetta  tgaagaccaa  gcagttccgc  ctgaaggagg  ccttcgatta  catcaagcag
1141  aggaggagca  tggctcgcgc  caactttggc  ttcattggcc  agctcctgca  gtacgaatct
1201  gagatcctgc  cctccacgcc  caacccccag  cctccctcct  gccaaaggga  ggcagcaggc
1261  tcttcactga  taggccattt  gcagacactg  agccctgaca  tgcagggtgc  ctactgcaca
1321  tccctgctct  cgggtgctgg  accggtgct  accactcaa  cagtcctaga  gctcagcaga
1381  agccctgtgg  caaccggccac  atcctgctaa  aactgggatg  gaggaatcgg  cccagcccca
1441  agagcaactg  tgatttttgt  ttttaagact  catggacatt  tcatacctgt  gcaatactga
1501  agaccctatt  ctgtcatgct  gccccagtga  gatagttagt  ggtcaccagg  cttgcaaatg
1561  aacttcagac  ggacctcagg  gtaggttctc  gggactgaag  gaaggccaag  ccattacggg
1621  agcacagcat  gtgctgacta  ctgtacttcc  agaccctgc  cctcttggga  ctgccagtc
1681  cttgcaccctc  agagtccgcc  ttttcatttc  aagcataaag  caataaatac  ctgcagcaac
1741  gtgggagaaa  gaagttgctg  gaccaggaga  aaaggcagtt  atgaagccaa  ttcattttga
1801  aggaagcaca  atttccacct  tattttttga  actttggcag  tttcaatgct  tgtctctggt
1861  gcttcggggc  ataagctgat  caccgtctag  ttgggaaagt  aacctacag  ggtttgtagg
1921  gacatgatca  gcatectgat  ttgaaccctg  aaatgtttgt  tagacacctc  cttgggtcca
1981  atgaggtagt  tggttgaagt  agcaagatgt  tggcttttct  ggattttttt  tgccatgggt
2041  tcttcactga  ccttggactt  tggcatgatt  cttagtcata  cttgaacttg  tctcatccca
2101  cctcttctca  gagcaactct  tectttggga  aaagagtctc  tcagatcata  gaccaaaaaa
2161  gtcatacctt  cagggtggtg  gcagtagatt  ccaggaggag  aagggtactt  gctaggtatc
2221  ctgggtcagt  ggcggtgcaa  actggtttcc  tcagctgctc  gtcctctctg  gtgcttatgt
2281  ctcttgtgac  aattgttttc  ctccctgccc  ctggagggtg  tcttcaagct  gtggacttct
2341  gggatttgca  gattttgcaa  cgtggtacta  cttttttttt  ctttttcttt  gttagtattt
2401  tctccagggg  aaaaagcaat  aattttctaa  gaccctgtgt  aatgtgaaga  aaagcagtat
2461  gttactggtt  gttgtgtgtt  tctttgtttt  ttatagtgtg  aaataaaaat  agtaaaaagg
2521  gaaaaagcaaa  aaaaaaaaaa  aaaaaa
```

//



# Παράδειγμα GENBANK – Πρωτεΐνη (1/3)

---

## mitogen-activated protein kinase 1 [Homo sapiens]

[Comment](#) [Features](#) [Sequence](#)

LOCUS NP\_620407 360 aa linear PRI 05  
-OCT-2009  
DEFINITION mitogen-activated protein kinase 1 [Homo sapiens].  
ACCESSION NP\_620407  
VERSION NP\_620407.1 GI:20986531  
DBSOURCE REFSEQ: accession [NM\\_138957.2](#)  
KEYWORDS .  
SOURCE Homo sapiens (human)  
ORGANISM [Homo sapiens](#)  
Eukaryota; Metazoa; Chordata; Craniata; Vertebrata;  
Euteleostomi;  
Mammalia; Eutheria; Euarchontoglires; Primates;  
Haplorrhini;  
Catarrhini; Hominidae; Homo.  
REFERENCE 1 (residues 1 to 360)  
AUTHORS Murugan,A.K., Hong,N.T., Cuc,T.T., Hung,N.C.,  
Munirajan,A.K.,  
Ikeda,M.A. and Tsuchida,N.  
TITLE Detection of two novel mutations and relatively high  
incidence of  
H-RAS mutations in Vietnamese oral cancer  
JOURNAL Oral Oncol. 45 (10), E161-E166 (2009)  
PUBMED [19628422](#)  
REMARK GeneRIF: Observational study of gene-disease association.  
(HuGE)



# Παράδειγμα GENBANK – Πρωτεΐνη (2/3)

Summary: The protein encoded by this gene is a member of the MAP kinase family. MAP kinases, also known as extracellular signal-regulated kinases (ERKs), act as an integration point for multiple biochemical signals, and are involved in a wide variety of cellular processes such as proliferation, differentiation, transcription regulation and development. The activation of this kinase requires its phosphorylation by upstream kinases. Upon activation, this kinase translocates to the nucleus of the stimulated cells, where it phosphorylates nuclear targets. Two alternatively spliced transcript variants encoding the same protein, but differing in the UTRs, have been reported for this gene. [provided by RefSeq].

Transcript Variant: This variant (2) contains a different 3' UTR region, compared to variant 1. Both variants 1 and 2 encode the same protein.

Publication Note: This RefSeq record includes a subset of the publications that are available for this gene. Please see the Entrez Gene record to access additional publications.

```
FEATURES             Location/Qualifiers
     source            1..360
                       /organism="Homo sapiens"
                       /db_xref="taxon:9606"
                       /chromosome="22"
                       /map="22q11.21"
     Protein            1..360
                       /product="mitogen-activated protein kinase 1"
                       /EC_number="2.7.11.24"
                       /note="protein tyrosine kinase ERK2; extracellular
signal-regulated kinase 2; mitogen-activated protein
kinase 2; extracellular signal-regulated kinase-2"
                       /calculated_mol_wt=41259
     CDS              1..360
                       /gene="MAPK1"
                       /gene_synonym="ERK; ERK2; ERT1; MAPK2; p38; p40; p41;
p41mapk; P42MAPK; PRKM1; PRKM2"
                       /coded_by="NM_138957.2:241..1323"
                       /db_xref="CCDS:CCDS13795.1"
                       /db_xref="GeneID:5594"
                       /db_xref="HGNC:6871"
                       /db_xref="HPRD:01496"
                       /db_xref="MIM:176948"
```





# Παράδειγμα GENBANK – Πρωτεΐνη (3/3)

---

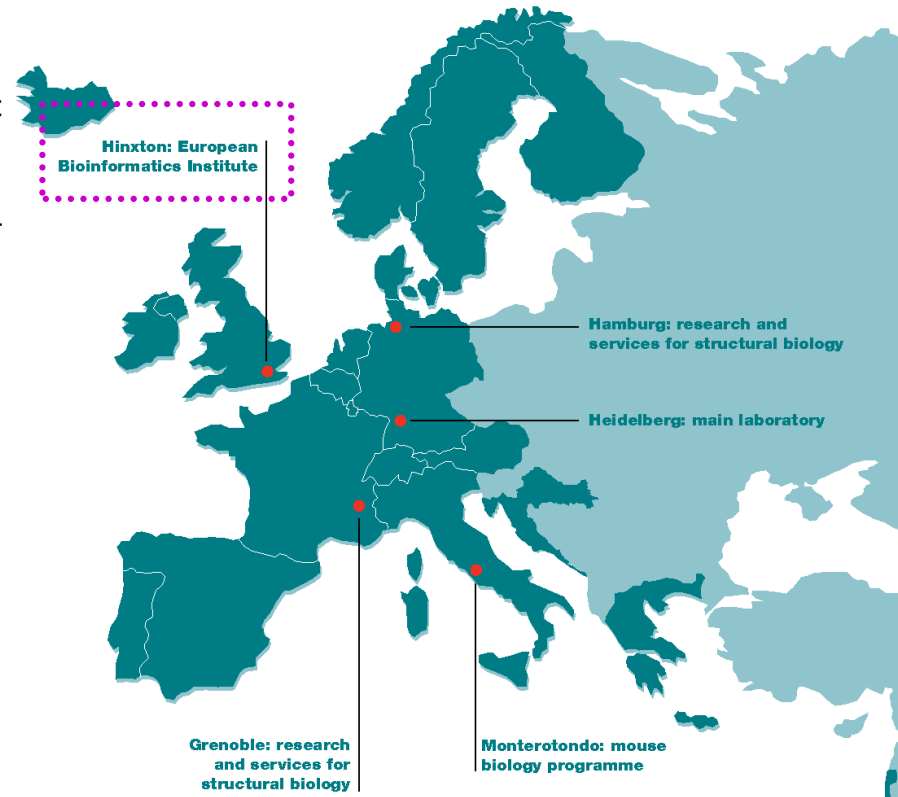

ORIGIN

```
1 maaaaaagag pemvrgqvfd vgptrytnlsy igegaygmvc saydvnkvr vaikkispfe
61 hqtycqrtlr eikillrfrh eniigindii raptieqmkd vyivqdlmet dlykllktqh
121 lsndhicyfl yqilrglkyi hsanvlhrdl kpsnlllntt cdlkicdfgl arvadpdhdh
181 tgflteyvat rwyrapeiml nskgytksid iwsvgcilae mlsnrpifpg khyldqlnhi
241 lgilgspsqe dlnciinlka rnyllslphk nkvpwnrlfp nadskaldll dkmltfnphk
301 rieveqalah pyleqyydps depiaeapfk fdmelledlpk eklkelifee tarfqpgyrs
```



# EMBL (European Molecular Biology Laboratory) Nucleotide Sequence Database (also known as EMBL-Bank)

- **EMBL:** Ευρωπαϊκός οργανισμός έρευνας με το κύριο ερευνητικό του κέντρο στην Χαϊδελβέργη – Γερμανία
- 1 κεντρικό ερευνητικό κέντρο και 4 περιφερειακά
- EMBL-Bank: Εδρεύει στο EBI
- Λειτουργεί κατά αντιστοιχία με την GENBANK.
- Η τελευταία έκδοση της EMBL-Bank περιλαμβάνει:
  - 283,748,816,763 βάσεις DNA
  - 163,656,234 εγγραφές



# EMBL – EBI / Ευρωπαϊκό Ινστιτούτο Βιοπληροφορικής

- **EMBL-Bank:** Νουκλεοτιδική (DNA) βάση δεδομένων.
- **UniProt:** Πρωτεϊνική βάση δεδομένων.
- Η κάθε γραμμή αρχίζει με συγκεκριμένο αναγνωριστικό 2 χαρακτήρων.



# EMBL Format - DNA

---

- Δομή γραμμών που η καθεμία αρχίζει με ένα συγκεκριμένο αναγνωριστικό που αποτελείται από 2 χαρακτήρες.

ID - identification  
AC - accession number  
PR - project identifier  
DT - date  
DE - description  
KW - keyword  
OS - organism species  
OC - organism classification  
OG - organelle  
RN - reference number  
RC - reference comment  
RP - reference positions  
RX - reference cross-reference  
RG - reference group  
RA - reference author(s)  
RT - reference title  
RL - reference location  
DR - database cross-reference  
CC - comments or notes  
AH - assembly header  
AS - assembly information  
FH - feature table header  
FT - feature table data  
XX - spacer line  
SQ - sequence header  
CO - contig/construct line  
bb - (blanks) sequence data  
// - termination line

**Abbreviations**  
**Συντομογραφίες**



# EMBL - Bank format (DNA database) (1/4)

```
DUSP1-EMBL-BANK.txt
ID   DQ301957; SV 1; linear; genomic DNA; STD; HUM; 6585 BP.
XX
```

**ID (Identification):** Περιέχει τον κωδικό κάθε εγγραφής και γενικές πληροφορίες για την ακολουθία.

ID <1>; SV <2>; <3>; <4>; <5>; <6>; <7> BP

1. Αρχικός κωδικός εγγραφής
2. Εκδοχή αλληλουχίας (Sequence version number)
3. Γραμμικό ή κυκλικό DNA
4. Τύπος μορίου που έχει αποθηκευτεί
5. Η μεθοδολογία που χρησιμοποιήθηκε, STD: Standard
6. Ταξινόμηση
7. Μήκος αλληλουχίας σε ζεύγη βάσεων

```
SP1) gene, complete cds.
ata; Euteleostomi; Mammalia;
ni; Catarrhini; Hominidae;
icci C., Baier C.N.,
K., Stanaway I.B.,
RA   Nguyen C.P., Gildersleeve H., Cassidy C.M., Johnson E.J., Swanson J.E.,
RA   McFarland I., Yool B., Park C., Nickerson D.A.;
RT   ;
RL   Submitted (22-NOV-2005) to the EMBL/GenBank/DBJ databases.
RL   Genome Sciences, University of Washington, 1705 NE Pacific, Seattle, WA
RL   98195, USA
XX
CC   To cite this work please use: NIEHS-SNPs, Environmental Genome
CC   Project, NIEHS ES15478, Department of Genome Sciences, Seattle, WA
CC   (URL: http://egp.gs.washington.edu).
XX
FH   Key          Location/Qualifiers
FH
FT   source       1..6585
```



# EMBL - Bank format (DNA database) (2/4)

```
ID DQ301957; S... 85 BP.  
XX  
AC DQ301957;  
XX  
DT 07-DEC-2005  
DT 14-NOV-2006  
XX
```

AC: Accession number. Αριθμός υποβολής της εγγραφής, ίδιος για τις 3 κύριες βάσεις δεδομένων DNA ακολουθιών

**DT (DaTe):** Ημερομηνία που πρωτοεμφανίστηκε και ημερομηνία κατά την οποία ενημερώθηκε τελευταία φορά.

**Μορφή καταχώρησης:**

DT DD-MON-YYYY (Release #, Created)

DT DD-MON-YYYY (Release #, Last updated, Version #)

specificity phosphatase 1 (DUSP1) gene, complete cds.

Chordata; Craniata; Vertebrata; Euteleostomi; Mammalia; Glires; Primates; Haplorrhini; Catarrhini; Hominidae;

```
XX  
RN [1]  
RP 1-6585  
RA Livingston R.J., Rieder M.J., Shaffer T., Bertucci C., Baier C.N.,  
RA Rajkumar N., Willa H.T., Daniels M., Downing T.K., Stanaway I.B.,  
RA Nguyen C.P., Gildersleeve H., Cassidy C.M., Johnson E.J., Swanson J.E.,  
RA McFarland I., Yool B., Park C., Nickerson D.A.;  
RT ;  
RL Submitted (22-NOV-2005) to the EMBL/GenBank/DDBJ databases.  
RL Genome Sciences, University of Washington, 1705 NE Pacific, Seattle, WA  
RL 98195, USA  
XX  
CC To cite this work please use: NIEHS-SNPs, Environmental Genome  
CC Project, NIEHS ES15478, Department of Genome Sciences, Seattle, WA  
CC (URL: http://egp.gs.washington.edu).  
XX  
FH Key Location/Qualifiers  
FH  
FT source 1..6585
```



# EMBL - Bank format (DNA database) (3/4)

```
                                DUSP1-EMBL-BANK.txt
ID   DQ301957; SV 1; linear; genomic DNA; STD; HUM; 6585 BP.
XX
AC   DQ301957;
XX
DT   07-DEC-2005 (Rel. 86, Created)
DT   14-NOV-2006 (Rel. 89, Last updated, Version 3)
XX
DE   Homo sapiens dual specificity phosphatase 1 (DUSP1) gene, complete cds.
XX
KW   ...
XX
OS   Homo sapiens
OC   Eukaryota; Metazoa; Vertebrata; Euteleostomi; Mammalia;
OC   Eukaryota; Metazoa; Vertebrata; Euteleostomi; Mammalia;
OC   Eukaryota; Metazoa; Vertebrata; Euteleostomi; Mammalia;
XX
RN   [1]
RP   1-6585
RA   Livingston D., Shaffer T., Bertucci C., Baier C.N.,
RA   Ralston M., Downing T.K., Stanaway I.B.,
RA   Nguyen T., Cassidy C.M., Johnson E.J., Swanson J.E.,
RA   McPherson J., Nickerson D.A.;
RT   ...
RL   Submitted to the EMBL/GenBank/DBJ databases.
RL   Department of Genome Sciences, University of Washington, 1705 NE Pacific, Seattle, WA
XX
CC   ...
CC   ...
CC   ...
XX
```

**DE (Description):** Περιγραφή.

**KW (Keywords):** Λέξεις κλειδιά

**OS & OC (Organic species & Organism Classification):** Επιστημονικό και κοινό όνομα οργανισμού καθώς και την ταξινομική κατάταξη του οργανισμού.

**RN,RP, RC, RX, RA, RT & RL:** Βιβλιογραφικές αναφορές.





# EMBL - Bank format (DNA database) (4/4)

FT Line: Feature table. Παρέχει μηχανισμό για σχολιασμό (annotation) των δεδομένων της ακολουθίας

```
FT   gene                1496..4598
FT                       /gene="DUSP1"
FT   mRNA                join(1496..2110,2390..2535,2902..3121,3564..4598)
FT                       /gene="DUSP1"
FT                       /product="dual specificity phosphatase 1"
FT   variation           1517
FT                       /gene="DUSP1"
FT                       /replace="t"
FT                       /frequency=".01"
FT   CDS                 join(1744..2110,2390..2535,2902..3121,3564..3934)
FT                       /codon_start=1
FT                       /gene="DUSP1"
FT                       /product="dual specificity phosphatase 1"
FT                       /db_xref="GOA:P28562"
FT                       /db_xref="HGNC:3064"
FT                       /db_xref="HSSP:1M3G"
FT                       /db_xref="InterPro:IPR016130"
FT                       /db_xref="UniProtKB/Swiss-Prot:P28562"
FT                       /protein_id="ABB96250.1"
FT                       /translation="MVMEVGTLDAGGLRALLGERAAQCLLLDCRSFFAFNAGHIAGSVN
FT                       VRFSTIVRRRAKGMGLEHIVPNAELRGRLLAGAYHAVVLLDERSAALDGAKRDGTLAL
FT                       AAGALCREARAAQVFFLKGGYEAFSASCPELCSKQSTPMGLSLPLSTSVPDSAESGCSS
FT                       CSTPLYDQGGPVEILPFLYLGSAYHASRKDMLDALGITALINVSANCPNHFEGHYQYKS
FT                       IPVEDNHKADISSWFNEAIDFIDSIKNAGGRVVFVHCQAGISRSATICLAYLMRTNRVKL
FT                       DEAFEVVKQRRSIIISP NFSFMGQLLQFESQVLAPHCSAEAGSPAMAVLDRGTSTTTVFN
FT                       FPVSI PVHSTNSALS YLQSPITTS PSC"
```





# EMBL-Bank format (DNA database) - Sequence

```

SQ      Sequence 6585 BP; 1466 A; 1770 C; 1733 G; 1616 T; 0 other;
ttctagaaga atccaggcag aacatttgcg caggcgaaaa cacacaagct aagcggaggca      60
aatgcagaag ttgccactgg tgatacagct cgcacagcga cgacgcaggg tggccagcga      120
ccggtttctt tttgctcgcc cctgtttttt gtagaatctc ttcatgcttg acatacctac      4260
cagtattatt cccgacgaca catatacata tgagaatata ccttattttat ttttgtgtag      4320
gtgtctgcct tcacaaatgt cattgtctac tcctagaaga accaaatacc tcaatttttg      4380
tttttgagta ctgtactatc ctgtaaatat atcttaagca ggtttgtttt cagcactgat      4440
ggaaaatacc agtgttgggt ttttttttta gttgccaaca gttgtatggt tgctgattat      4500
ttatgacctg aaataatata tttcttcttc taagaagaca tttgtttaca taaggatgac      4560
ttttttatac aatggaataa attatggcat ttctattgaa atttcaacgc ttttatttct      4620
ttggcaacca cacccaatcc ctctcccact agtgaactag ggaagaattt cgacaagggc      4680
ctgcagaatg tgttgagatc tgatcccatt ccctgtgggt gcccgttggg cccatgaaat      4740
ggctggggtg caagggagga agacaagtga gtatcatgaa acaccggacg ctacagctga      4800
actcttagta ttggatcagt gtgtctgccc atgccattt tagcggctct gtaacctacc      4860
atgtcaccca ggatgccaaag gtgtccccag agccaaagct agggaggaaat agccacttgt      4920
ctgatttgcc ttcttcattt aataccctcc tcaggttaat ataaaaagtc gccttcccat      4980
ctctgagctg tgctggagtt atgaggagac aaaagttttt ccaaacacat gacataaggc      5040
agggtgtgtc tacctgcccc tagagaaact cttgagcaag gccttttgca aatgagatgc      5100
tgagaccag catggctaag tggcagaatg agggtaattg gaatctacat ctgtttcaga      5160
ctttcacttg cccgtctcat ggcttttttt tttttttttt ttttagacgga gtctcactct      5220
gtcacccagg ctggagtgtg ctggtgtgag ctcggtcac tgcaacctcc gcctgccagg      5280
ttcaagccat tctcctgcct cagcttctta agtagctggg attacgggtg cgctcacca      5340
tgcccggcta atttttgtat ttttagtaga gatggggggt tcaccatggt ggccaggctg      5400
gtctcgaact cctgacctat ctttttgctt ttaaaaaggg ttttgttttt gtgaaaattt      5460
aaatacattg gcaaaaaaaaa aaaaaaagaa agaaaaaaaa tccaagcact ataagcaaat      5520
accatgtaaa gaaatcaccc gcaacagccc atccccaacc tgaccattgc taacattgtg      5580
gaggacattc acgctggcat ttctgcatat agacatggca tttttggtag ttgccctctt      5640
catgtcacct gctgctctga tttcatagtt ttgttgagat aagcaattaa acctgacttg      5700
ttctaggata atattctgaa tttgtactcc tttgccaagc aggcacaaaaa cagaagagat      5760
gtaattgcta ccaatccata atccagtcta taatgttgcg ttaagaaaca gcgaagctct      5820
tggattactg gcccttagc gcccccaccc actctttggt tctggacaaa gtgctatggg      5880
aagcagaaaa ggaatatatc cattcgctt atccatgagc accctgtgct atggttctgg      5940
tcctgtcctg ttgttcaagg tctttacgca gaatcagttg ccttgacttt gccctgtgg      6000
ctcactgtct gccacttgac tcccaggggtc tgaaagatcc ctgtgttcta agttctaaga      6060
acttaccctg ggctggcaag ctctatttct cagctggggt tccgattaca agtatgttca      6120
tgccatcaa aacaaatcgt acccagtggt tttatcaaag cctagaaatt tactattgta      6180
aatatctctc tccgtggaat tgtaccagcg acatcgagtc tgtgacagat gccatggctg      6240
acttccccgt gggctagggc cttcgttttc tgcttggcag gcaactggctg aaccaaaatt      6300
aatctccagt gtgatccacg cagtggaaaa atacagcggc tgcctaaggg agccgccagt      6360
gaaaacaagt cactcacttc tcccggctca agccactctg cctcatgcca gccctgagag      6420
ccaggaatga tgaccctga tcccattgta cgggagtcac tgtgttcaga cctccagaa      6480
aaatctcata tttggcctca gactgctttc cttgggaaaa aattaatacc tcgtgatgaa      6540
agatacttaa agtctattaa tgtgtttccc aggaagagat tgaaa      6585

```



# Πρωτεϊνική βάση δεδομένων - UniProt

---

- Το 2002, οι τρεις μεγάλες πρωτεϊνικές βάσεις δεδομένων, Swiss-Prot, TrEMBL και PIR-PSD, ενώθηκαν με αποτέλεσμα τη δημιουργία της μεγάλης παγκοσμιοποιημένης βάσης δεδομένων, **Universal Protein Resource, UniProt**.
- Περιέχει αναφορές από περισσότερες από 50 πρωτεϊνικές βάσεις δεδομένων.



# Protein sequence database – UniProt


---

## Consists of 3 layers:

- i. Knowledgebase (UniProt): A comprehensive catalogue of data on protein sequence and function. Contains only the active entries
- ii. Archive (UniParc): Repository for all protein sequences, providing a mechanism by which the historical association of database records and protein sequences can be tracked. Contains both active and inactive entries.
- iii. Non-redundant database (UniRef): Sequence clusters, used to speed up sequence similarity searches.



# DNA duplex



Copyright © 2006 Pearson Education, Inc., publishing as Benjamin Cummings.



# UniProt Format (1/3)

★ Reviewed, UniProtKB/Swiss-Prot **P28562** (DUS1\_HUMAN)  
Last modified September 1, 2009. Version 95.

Όνομα και προέλευση	Names and origin Protein names	<i>Recommended name:</i> <b>Dual specificity protein phosphatase 1</b> EC=3.1.3.48 EC=3.1.3.16
Εναλλακτικά ονόματα πρωτεΐνης		<i>Alternative name(s):</i> MAP kinase phosphatase 1 Short name=MKP-1 Protein-tyrosine phosphatase CL100 Dual specificity protein phosphatase hVH1
Ονόματα γονιδίου	Gene names	Name: <b>DUSP1</b> Synonyms: CL100, MKP1, PTPN10, VH1
Οργανισμός και ταξινόμηση	Organism	<b>Homo sapiens (Human)</b> [Complete proteome]
	Taxonomic identifier	9606 [NCBI]
	Taxonomic lineage	Eukaryota › Metazoa › Chordata › Craniata › Vertebrata › Euteleostomi › Mammalia › Eutheria › Euarchontoglires › Primates › Haplorrhini › Catarrhini › Hominidae › Homo
Χαρακτηριστικά πρωτεΐνης	Protein attributes	
	Sequence length	367 AA.
	Sequence status	Complete.
	Sequence processing	The displayed sequence is not processed.
	Protein existence	Evidence at protein level.
Γενικές πληροφορίες για την πρωτεΐνη	General annotation (Comments)	
	Function	Dual specificity phosphatase that dephosphorylates MAP kinase ERK2 on both 'Thr-183' and 'Tyr-185'.
	Catalytic activity	Protein tyrosine phosphate + H <sub>2</sub> O = protein tyrosine + phosphate. A phosphoprotein + H <sub>2</sub> O = a protein + phosphate.
	Tissue specificity	Expressed at high levels in the lung, liver placenta and pancreas. Moderate levels seen in the heart and skeletal muscle. Lower levels found in the brain and kidney. <a href="#">Ref.2</a>
	Induction	By oxidative stress and heat shock.
	Sequence similarities	Belongs to the <a href="#">protein-tyrosine phosphatase family</a> . <a href="#">Non-receptor class dual specificity subfamily</a> . Contains 1 <a href="#">rhodanese domain</a> . Contains 1 <a href="#">tyrosine-protein phosphatase domain</a> .



# UniProt Format (2/3)

Πληροφορίες για την αλληλουχία

```
■ P28562-1 [UniParc]. FASTA 367 39,298
Last modified February 1, 1996. Version 3.
Checksum: 11BD1D39A9FCD51F

10 20 30 40 50 60
MVMEVGTIDA GGLRALLGER AAQCLLLDCR SFFAFNAGHI AGSVVVRVRFST IVRRRRKGAM
70 80 90 100 110 120
GLEHIVPNAE LRGRLLAGAY HAVVLLDERS AALDGAKRDK TLALAAGALC REARRAQVFF
130 140 150 160 170 180
LKGGYEAFSA SCPELCSKQS TFMGLSLELS TSVFDSAESG CSSCSTPLYD QGGPVELLFF
190 200 210 220 230 240
LYLGSAYHAS RKDMLDALGI TALINVSANC FNFHEGHYQY KSIPVEDNHK ADISSWFNEA
250 260 270 280 290 300
IDFIDSIKNA GGRVVFHCQA GISRSATICL AYLMTNRVK LDEAFEFVKQ RRSIISPNFS
310 320 330 340 350 360
FMGQLLQFES QVLAPHCSAE AGSPAMAVLD RGTSTTTVFN FVVSIPVHST NSALSYLQSP

ITTSPSC

« Hide
```

Βιβλιογραφικές αναφορές

References

« Hide 'large scale' references

- [1] "Oxidative stress and heat shock induce a human gene encoding a protein-tyrosine phosphatase."  
Keyes S.M., Emslie E.A.  
Nature 359:644-647(1992) [PubMed: 1406996] [Abstract]  
Cited for: NUCLEOTIDE SEQUENCE [MRNA].  
Tissue: Foreskin.
- [2] "Isolation and characterization of a human dual specificity protein-tyrosine phosphatase gene."  
Kwak S.P., Hakes D.J., Martell K.J., Dixon J.E.  
J. Biol. Chem. 269:3596-3604(1994) [PubMed: 8106404] [Abstract]  
Cited for: NUCLEOTIDE SEQUENCE [MRNA], TISSUE SPECIFICITY.
- [3] NIEHS SNPs program  
Submitted (NOV-2005) to the EMBL/GenBank/DBJ databases  
Cited for: NUCLEOTIDE SEQUENCE [GENOMIC DNA], VARIANTS THR-56 AND HIS-187.
- [4] "The status, quality, and expansion of the NIH full-length cDNA project: the Mammalian Gene Collection (MGC)."  
The MGC Project Team  
Genome Res. 14:2121-2127(2004) [PubMed: 15489334] [Abstract]  
Cited for: NUCLEOTIDE SEQUENCE [LARGE SCALE MRNA].  
Tissue: Brain.

+ Additional computationally mapped references.



# UniProt Format (3/3)

## Πληροφορίες για την τριτοταγή δομή της πρωτεΐνης

### 3D structure databases

HSSP	<a href="#">HSSP</a> built from PDB template <a href="#">1M3G</a> based on UniProtKB <a href="#">Q05923</a> .
SMR	<a href="#">P28562</a> . Positions <a href="#">171-313</a> .

### Protein-protein interaction databases

IntAct	<a href="#">P28562</a> . 7 interactions.
STRING	<a href="#">P28562</a> .

## Γενικές πληροφορίες για την καταχώρηση

### Entry information

Entry name	DUS1_HUMAN
Accession	Primary (citable) accession number: <b>P28562</b> Secondary accession number(s): Q2V508
Entry history	Integrated into UniProtKB/Swiss-Prot: December 1, 1992 Last sequence update: February 1, 1996 Last modified: September 1, 2009 This is version 95 of the entry and version 3 of the sequence. [ <a href="#">Complete history</a> ]
Entry status	Reviewed (UniProtKB/Swiss-Prot)
Annotation project	<a href="#">HPI</a> (Human Proteome Initiative)



# DDBJ – DNA Data Bank of Japan (Japan)

---

- Η μοναδική νουκλεοτιδική βάση δεδομένων στην Ασία.
- Λειτουργεί υπό την αιγίδα του Υπουργείου Παιδείας Επιστημών και Αθλητισμού της Ιαπωνίας.
- Πηγή των δεδομένων της είναι, κυρίως, Ιάπωνες ερευνητές.
- Η τελευταία έκδοσή της περιέχει:
  - 87,903,140 εγγραφές.
  - 91,294,770,939 βάσεις.





# Μηχανές αναζήτησης βιολογικών δεδομένων – NCBI, Entrez

NCBI

Entrez, The Life Sciences Search Engine

HOME SEARCH SITE MAP PubMed All Databases Human Genome GenBank Map Viewer BLAST


Search across databases  GO Clear Help

Welcome to the Entrez cross-database search page



<b>PubMed:</b> biomedical literature citations and abstracts	<b>Books:</b> online books
<b>PubMed Central:</b> free, full text journal articles	<b>OMIM:</b> online Mendelian Inheritance in Man
<b>Site Search:</b> NCBI web and FTP sites	
<b>Nucleotide:</b> Core subset of nucleotide sequence records	<b>dbGaP:</b> genotype and phenotype
<b>EST:</b> Expressed Sequence Tag records	<b>UniGene:</b> gene-oriented clusters of transcript sequences
<b>GSS:</b> Genome Survey Sequence records	<b>CDD:</b> conserved protein domain database
<b>Protein:</b> sequence database	<b>UniSTS:</b> markers and mapping data
<b>Genome:</b> whole genome sequences	<b>PopSet:</b> population study data sets
<b>Structure:</b> three-dimensional macromolecular structures	<b>GEO Profiles:</b> expression and molecular abundance profiles
<b>Taxonomy:</b> organisms in GenBank	<b>GEO DataSets:</b> experimental sets of GEO data
<b>SNP:</b> single nucleotide polymorphism	<b>Epigenomics:</b> Epigenetic maps and data sets
<b>dbVar:</b> Genomic structural variation	<b>Cancer Chromosomes:</b> cytogenetic databases
<b>Gene:</b> gene-centered information	<b>PubChem BioAssay:</b> bioactivity screens of chemical substances
<b>SRA:</b> Sequence Read Archive	<b>PubChem Compound:</b> unique small molecule chemical structures
<b>BioSystems:</b> Pathways and systems of interacting molecules	<b>PubChem Substance:</b> deposited chemical substance records
<b>HomoloGene:</b> eukaryotic homology groups	<b>Protein Clusters:</b> a collection of related protein sequences
<b>GENSAT:</b> gene expression atlas of mouse central nervous system	<b>OMIA:</b> online Mendelian Inheritance in Animals
<b>Probe:</b> sequence-specific reagents	<b>BioSample:</b> biological material descriptions
<b>BioProject:</b> aggregated biological research project data	



# Μηχανές αναζήτησης βιολογικών δεδομένων - EBI



EMBL-EBI European Bioinformatics Institute

Databases Tools Research Training Industry About Us Help Site Index  

Explore the EBI:

Examples: [ROA1\\_HUMAN](#), [tpi1](#), [Sulston...](#) [Help](#) | [Feedback](#)

## Data Resources and Tools

- [ENA](#)
- [UniProt](#)
- [ArrayExpress](#)
- [Ensembl](#)
- [InterPro](#)
- [PDBe](#)
- [Genomes](#)
- [Nucleotide Sequences](#)
- [Protein Sequences](#)
- [Macromolecular Structures](#)
- [Small Molecules](#)
- [Gene Expression](#)
- [Protein Expression](#)
- [Molecular Interactions](#)
- [Reactions & Pathways](#)
- [Protein Families](#)
- [Enzymes](#)
- [Literature](#)
- [Taxonomy](#)
- [Ontologies](#)
- [Patent Resources](#)
- [Sequence Similarity & Analysis](#)
- [Pattern & Motif Searches](#)
- [Structure Analysis](#)
- [Text Mining](#)
- [Downloads](#)
- [Web Services](#)



# Μηχανές αναζήτησης βιολογικών δεδομένων - SRS

**SRS**

[Start a Permanent Project](#)

**Tips**

- ★ *Want to know more about using SRS?*  
- go to the [Help Center](#) for online searchable help.  
- look in our [SRS@EBI FAQ](#) for answers to commonly asked questions
- ★ *Linking to SRS?*  
- Please read our [Linking to SRS](#) guide for important information regarding linking to our SRS server.
- ★ [Public SRS servers worldwide](#)

**Quick Text Search** Search Tips

Find :  matching :

Searches Databanks: EMBL Nucleotides

**News and Announcements** Search Tips

**Important announcements:**

- 11.10.11 Please Note:** One of our data centres will be offline from Friday 21 October 2011 at 14.00 (GMT+1) to Monday 24 October, 12 noon (GMT+1). During this period this SRS server will not be available.
- 08.09.11 EMBL-Bank** Release 109 is now on-line ([release notes](#), [data notes](#)). **Note:** since release 108 the Expressed Sequence Tag (EST) entries from the release have been moved out of [EMBLRELEASE](#) into [EMBLESTRELEASE](#).
- 03.06.11 EMBL-Bank** Release 108 is now on-line ([release notes](#), [data notes](#)). **Note:** the Expressed Sequence Tag (EST) entries from the release have been moved out of [EMBLRELEASE](#) in to [EMBLESTRELEASE](#).

**List Search** Search Tips

Paste in a list of sequence ID's. The list must be of the format DATABASE:ID. e.g. EMBL:AB046566 or UNIPROT:104K\_THEAN. For more details see the [wiki](#).

Ensure each entry is on a single line and that the database(s) exists on this server. Multiple databases can be searched simultaneously. There is a maximum limit of 500 ID's.

List file  Δεν έχει ...να αρχείο

- Fields:**
- Nucleotides
  - Proteins
  - Structures
  - Protein families
  - Literature
  - Genome
  - Mutations
  - Metabolic pathways



# Μηχανές αναζήτησης δεδομένων στις βιολογικές βάσεις δεδομένων

---

- Επιλογές για αναζήτηση αλληλουχίας DNA:
  - EBI, <http://www.ebi.ac.uk/>
  - GENBANK, <http://www.ncbi.nlm.nih.gov/Genbank/>
- Επιλογές για αναζήτηση πρωτεϊνικής αλληλουχίας:
  - UniProt, <http://www.uniprot.org/>



# Βάσεις δεδομένων πρωτεϊνικών δομών

---

- Βάσεις δεδομένων για την τρισδιάστατη δομή πρωτεϊνών, των οποίων η δομή έχει λυθεί με τη χρήση διαφόρων τεχνικών όπως κρυσταλλογραφία ακτίνων Χ ή NMR.
- **Protein Databases:**
  - PDB.
  - SCOP.
  - Swiss-Prot.
  - PIR.

## RasMol:

- Molecular Visualization Freeware for proteins, DNA and macromolecules.



# Protein Structure Databases

---

- Η πιο εκτεταμένη βάση δεδομένων τρισδιάστατων πρωτεϊνικών δομών είναι η **Protein Data Bank (PDB)**.
- January 18 , 2010: 54,039 structures.
- October 30, 2012: 85,848 structures.



# Protein Data Bank (PDB) (1/4)

- 90% των πρωτεϊνικών δομών: X-ray crystallography.
- 9% των πρωτεϊνικών δομών: Nuclear Magnetic Resonance techniques (NMR).

Resolution (Å)	
>4.0	Ανεξάρτητες συντεταγμένες χωρίς βιολογική σημασία
3.0 – 4.0	Δομή πιθανώς σωστή, αλλά με λάθη. Οι πλευρικές ομάδες σε λάθος γωνίες
2.5 – 3.0	Δομή πιθανώς σωστή. Μακριές όπως και πολύ μικρές πλευρικές αλυσίδες είναι με λάθος γωνίες
2.0 – 2.5	Δομή πιθανώς σωστή με περιορισμένα λάθη. Τα μόρια νερού καθώς και προσδέτες αρχίζουν να αναγνωρίζονται
1.5 – 2.0	Δομή σωστή με σπάνια την εμφάνιση αστοχιών
0.5 – 1.5	Δομή σχεδόν χωρίς λάθη.



# Protein Data Bank (PDB) (2/4)

RCSB **PDB**  
PROTEIN DATA BANK

A MEMBER OF THE **PDB**

An Information Portal to Biological Macromolecular Structures

As of Tuesday Jan 12, 2010 at 4 PM PST there are 62634 Structures | [PDB Statistics](#)

[WHAT'S NEW](#) | [HELP](#) | [PRINT](#)

PDB ID or keyword  [Search](#) | [Advanced Search](#)

**Home** [Hide](#)

- News & Publications
- Policies
- FAQ
- Contact
- Feedback
- About Us

**Deposition** [Hide](#)

- All Deposit Services
- Electron Microscopy
- NMR
- Validation Server
- BioSync Beamline
- Related Tools

**Search** [Hide](#)

- Advanced Search
- Latest Release
- Latest Publications
- Sequence Search
- Ligand Search
- Unreleased Entries
- Browse Database
- Histograms

**Explorer:**

Last Structure: 2H3L

**Results:**

Query (1 hits):

- Query Results
- Query Details
- Query History
- Save Query to MyPDB

**Tools** [Hide](#)

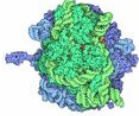
- File Downloads
- FTP Services
- File Formats
- Services: RESTful | SOAP
- Widgets
- Compare Structures

## A Resource for Studying Biological Macromolecules

The PDB archive contains information about experimentally-determined structures of proteins, nucleic acids, and complex assemblies. As a member of the **wwPDB**, the RCSB PDB curates and annotates PDB data according to agreed upon standards.

The RCSB PDB also provides a variety of tools and resources. Users can perform simple and advanced searches based on annotations relating to sequence, structure and function. These molecules are visualized, downloaded, and analyzed by users who range from students to specialized scientists.

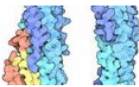
### Molecule of the Month: 70S Ribosomes



Ribosomes are one of the wonders of the cellular world, and one of the many wonders you can explore yourself at the RCSB PDB. In 2000, structural biologists Venkatraman Ramakrishnan, Thomas A. Steitz and Ada E. Yonath made the first structures of **ribosomal subunits** available in the PDB, and in 2009, they each received the **Nobel Prize** for this work. Structures are also available for many of the other players in protein synthesis, including **transfer RNA** and **elongation factors**. Building on these structures, there are now hundreds of structures of entire ribosomes in the PDB, revealing the atomic details of many important steps in protein synthesis.

- [Read more ...](#)
- [Previous Features](#)

### PSI Featured Molecule: Hemolysin BL



Researchers at NYSGXRC have solved the structure of the bacterial toxin hemolysin BL, a widespread cause of food poisoning. The pore-forming hydrophobic loop is seen in a soluble, pre-attack conformation.

- [Read more from the Structural Genomics Knowledgebase](#)
- [Previous Features](#)

New user? Try the browser [compatibility check](#) and information on [Getting Started](#).

### News

- [Complete News](#)
- [Newsletter](#)
- [Discussion Forum](#)
- [Job Listings](#)

#### wwPDB Statement on Retraction of UAB PDB Entries

12-January-2010

#### Time-stamped Copies of PDB Archive Available via FTP

A snapshot of the PDB archive (<ftp://wwpdb.org>) as of January 4, 2010 has been added to <ftp://snapshots.wwpdb.org/>. Snapshots of the PDB have been archived annually since 2004. It is hoped that these snapshots will provide readily identifiable data sets for research on the PDB archive.

[More >>](#)

#### FTP Archive

The up-to-date PDB archive is available at: <ftp://wwpdb.org>

Time-stamped yearly snapshots are available at: <ftp://snapshots.wwpdb.org>







# Protein Data Bank (PDB) (3/4)

1 Structure Hit | 1 Citation | 1 Ligand Hit | 3 Web Page Hits | GO Hits | CATH Hits

Advanced Keyword Query for: DUSP5 Query Options: ▾

Display/Download: ▾  Generate Reports: ▾ Sort by: ▾ Results per Page: ▾

Displaying results 1 - 1 of 1 total | Page 1 of 1


**2G6Z**     


**Crystal structure of human DUSP5**

**Characteristics** Release Date: 16-Jan-2007 Exp. Method: X-RAY DIFFRACTION  
Resolution: 2.70 Å

**Classification** **Hydrolase** 

**Compound** **Molecule:** Dual specificity protein phosphatase 5 **Length:** 211  
**Polymer:** 1 **Type:** polypeptide(L)  
**Chains:** A, B, C  
**EC#:** 3.1.3.48  3.1.3.16 

**Authors** **Fragment:** residues 174-384  
**Kim, S.J.** , **Ryu, S.E.** 



# Protein Data Bank (PDB) (4/4)

## Crystal structure of human DUSP5

DOI:10.2210/pdb2g6z/pdb

### Primary Citation

Crystal structure of the catalytic domain of human DUSP5, a dual specificity MAP kinase protein phosphatase

Jeong, D.G., Cho, Y.H., Yoon, T.S., Kim, J.H., Ryu, S.E., Kim, S.J.  
(2007) Proteins 66: 253-258

PubMed: 17078075

DOI: 10.1002/prot.21224

[Search Related Articles in PubMed](#)

### PubMed Abstract:

No abstract available ... [ [Read More & Search PubMed Abstracts](#) ]

### ↓ Molecular Description

Hide

Classification: Hydrolase  
Structure Weight: 70055.14

Molecule: Dual specificity protein phosphatase 5

Polymer: 1 Type: polypeptide(L)

Length: 211

Chains: A, B, C

EC#: 3.1.3.48 3.1.3.16

Fragment: residues 174-384

### ↓ Source

Hide

Polymer: 1

Scientific Name: Homo sapiens

Common Name:

Human Expression System:

Escherichia coli

### ↓ Ligand Chemical Component

Hide

Identifier	Name	Formula	Interaction View	Links
SO4	SULFATE ION	O4 S	<a href="#">Ligand Explorer</a>	<a href="#">L</a> <a href="#">D</a> <a href="#">H</a>

### ↓ Derived Data

Hide

- CATH Classification v3.2.0 - (3 Domains)
- PFAM Classification - (3 Domains)
- GO Terms - (9 Terms)



# Crystal Structure

## Crystal structure of human DUSP5

Biological Assembly ?

More Images...

View in Jmol SimpleViewer ?  
Other Viewers Protein Workshop

Biological assembly assigned by authors

Deposition Summary Hide

Authors: Kim, S.J., Ryu, S.E.

Deposition: 2006-02-26  
Release: 2007-01-16  
Last Modified (REVDAT): 2009-02-24

Experimental Details Hide

Method: X-RAY DIFFRACTION  
Experimental Data: [ EDS ]


Resolution[Å]: 2.70  
R-Value: 0.248 (obs.)  
R-Free: 0.291  
Space Group: P 4<sub>3</sub> 2 2

Unit Cell:

Length [Å]	Angles [°]
a = 92.71	α = 90.00
b = 92.71	β = 90.00
c = 165.21	γ = 90.00

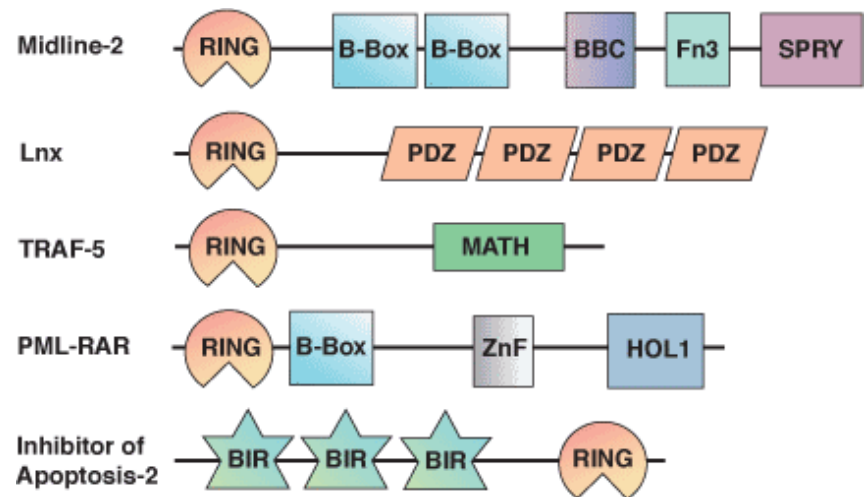


# Protein domain / motif databases (1/2)



# Protein domain / motif databases (2/2)

- **Motif:** A small structural element that is recognizable in several proteins. Length of 6-10 a.a.
- **Domain:** A part of a protein with specific structure which correspond to the family that belongs to the protein. Is related to the function of localization of the protein.



# PROSITE (1/4)

---

- Αρχικά: Περιείχε απλά μοτίβα πρωτεϊνών.
- Σήμερα περιλαμβάνει αρχεία που περιγράφουν:
  - Οικογένειες πρωτεϊνών.
  - Λειτουργικές θέσεις πρωτεϊνών.
  - Προφίλ πρωτεϊνών.
- Τρέχουσα έκδοση:
  - 1650 εγγραφές με βιβλιογραφικά δεδομένα για τα,
  - 1308 πρότυπα και τα,
  - 1039 προφίλ που είναι καταγεγραμμένα σε αυτή.



# PROSITE (2/4)



[Home](#) [ScanProsite](#) [ProRule](#) [Documents](#) [Downloads](#) [Links](#) [Funding](#)

Database of protein domains, families and functional sites

PROSITE consists of [documentation entries](#) describing protein domains, families and functional sites as well as associated [patterns](#) and [profiles](#) to identify them [[More details](#) / [References](#) / [Disclaimer](#) / [Commercial users](#)]. PROSITE is complemented by [ProRule](#), a collection of rules based on profiles and patterns, which increases the discriminatory power of profiles and patterns by providing additional information about functionality and/or structurally critical amino acids [[More details](#)].

Release 20.57, of 24-Nov-2009 (1563 documentation entries, 1308 patterns, 869 profiles and 874 ProRule)

## PROSITE access

**Όνομα domain:** PDOC00022, PS50089, SH3, zinc finger

Search

add wildcard "\*\*"

Browse:

- [by documentation entry](#)
- [by ProRule description](#)
- [by taxonomic scope](#)
- [by number of positive hit](#)

## PROSITE tools

Scan a sequence against PROSITE patterns and profiles - quick scan

(Output includes graphical view and feature detection)



Enter your sequence or a UniProtKB (Swiss-Prot or TrEMBL) ID or AC [ [help](#) ]:

Sequence in FASTA format

Scan

Clear

exclude patterns with a high probability of occurrence

- [ScanProsite](#) - advanced scan
- [PRATT](#) - allows to interactively generate conserved patterns from a series of unaligned proteins.
- [MyDomains - Image Creator](#) <sup>\*\*\*</sup> - allows to generate custom domain figures.



# PROSITE (3/4)



[Home](#) [ScanProsite](#) [ProRule](#) [Documents](#) [Downloads](#) [Links](#) [Funding](#)

Database of protein domains, families and functional sites

PROSITE consists of [documentation entries](#) describing protein domains, families and functional sites as well as associated [patterns](#) and [profiles](#) to identify them [[More details](#) / [References](#) / [Disclaimer](#) / [Commercial users](#)]. PROSITE is complemented by [ProRule](#), a collection of rules based on profiles and patterns, which increases the discriminatory power of profiles and patterns by providing additional information about functionally and/or structurally critical amino acids [[More details](#)].

Release 20.57, of 24-Nov-2009 (1563 documentation entries, 1308 patterns, 869 profiles and 874 ProRule)

## PROSITE access

PDOC00022, PS50089, SH3, zinc finger  
  
 add wildcard "\*\*"

Browse:

- [by documentation entry](#)
- [by ProRule description](#)
- [by taxonomic scope](#)
- [by number of positive hit](#)

## PROSITE tools

Scan a sequence against PROSITE patterns and profiles - quick scan

(Output includes graphical view and feature detection)



Enter your sequence or a UniProtKB (Swiss-Prot or TrEMBL) ID or AC [ [help](#) ]:

Sequence in FASTA format

exclude patterns with a high probability of occurrence

- [ScanProsite](#) - advanced scan
- [PRATT](#) - allows to interactively generate conserved patterns from a series of unaligned proteins.
- [MyDomains - Image Creator](#) <sup>\*\*\*</sup> - allows to generate custom domain figures.





# PROSITE (4/4)

hits by profiles: [5 hits (by 1 profile) on 1 sequence]

Hits by [PS50268](#) CADHERIN\_2 Cadherins domain profile :

USERSEQ1  (882 aa)

180 - 262: score = 20.152

```
-----SNKD--KEGKVFYSITGQGADTppvGVFIIERETGW  
LKVTEPLDRERIATYTLFSAVSSNGNAVEDPMEILITVTDQNDNKPEF
```

263 - 375: score = 29.162

```
TQEVFKGSVMEGALPGTSVMEVTATDADDvnTYNAAIAYTILSQDPELpdkNMFTINRN  
TgVISVVTTLGLDRESFPTYTLVVQAADLQGEGLSTTATAVITVTDNDNPPIF
```

376 - 486: score = 21.402

```
NPTTYKGQVPENEANVVI-TTLKVTDADApnTPAWEAVYTILNDDG--GQFVVTINPvnn  
dGILKTAKGLDFEAKQQYILHVAVTNVVpfeVSLTTSTATVIVDVLVDVNE-APIF
```

487 - 595: score = 23.682

```
VPPEKRVEVSEDFGVGQEITSYTAQEPDTFMEQKITYRIWRDTA--NWLEINPDTGAIST  
RAELDREdfehvKNSTYALIIATDNGSPVATGTGTTTTLILSDVNDNAPIP
```

594 - 702: score = 8.840

```
IPEPRTIFFCERNPKPQV---INIIDADLpPNTSPFTAELTHGASA--NWTIQYNDptqE  
SIILKPKMALE-VGDYKINLKLMDN--QNKDQVTTLEVSVCDEGAagvcrkaQPVE
```



# SMART (Simple Modular Architecture Research Tool)

---

- Αναγνώριση και σχολιασμό domains.
- «Αρχιτεκτονική» των domains.
- Καταγεγραμμένες περισσότερες από 500 οικογένειες domains:
  - Μετάδοση βιολογικού σήματος.
  - Εξωκυττάρια περιοχή πρωτεϊνών.
  - Ενδοκυττάρια περιοχή πρωτεϊνών.
- Καταχώρηση σύμφωνα με:
  - Εξέλιξη, ομοιότητες/διαφορές μεταξύ διαφορετικών ειδών.
  - Λειτουργία – ρόλος.
  - Τριτοταγής δομή (στο χώρο).
  - Κρίσιμα κατάλοιπα (αμινοξέα) για τη λειτουργία της πρωτεΐνης.



# SMART Interface

## Sequence analysis

You may use either a [Uniprot/Ensembl](#) sequence identifier (ID) / accession number (ACC) or the protein sequence itself to request the SMART service.

### Sequence ID or ACC

Examples: [TEC\\_HUMAN](#), [C1S\\_HUMAN](#)

### Sequence

HMMER searches of the SMART database occur by default. You may also find:

- [Outlier homologues](#) and homologues of known structure
- [PFAM](#) domains
- [signal peptides](#)
- [internal repeats](#)
- [intrinsic protein disorder](#)

If you have multiple sequences to analyze, try [batch access](#) to SMART database.

## Domains detected by SMART

### Search domain annotation

Keywords:

Domain name or ACC:

- [Browse](#) the database of all available domains in the SMART database
- [Download](#) domain descriptions in tab delimited plain text
- [See a list](#) of recent domain changes
- [Suggest a domain](#) you think should be added to SMART

## Architecture analysis

You can search for proteins with combinations of [specific domains](#) in different species or taxonomic ranges. You can input the domains directly into "Domain selection" box, or use "GO terms query" to get a list of domains. See [What's New](#) for more info.

### Domain selection

Example: [TyrKc](#) AND [SH3](#) AND NOT [SH2](#)

### GO terms query

Example: [membrane](#) AND [signal transduction](#)

### Taxonomic selection

Select a taxonomic range via the selection box or type it into the text box below:

All

Examples: [Dictyostelium discoideum](#), [Porifera](#)

You can try an [Advanced Query](#) if you're familiar with SQL.



# SMART – Ανάλυση αλληλουχίας

**Sequence analysis**

You may use either a [Uniprot/Ensembl](#) sequence identifier (ID) / accession number (ACC) or the protein sequence itself to request the SMART service.

**Sequence ID or ACC**

  
Examples: [TEC\\_HUMAN](#), [C1S\\_HUMAN](#)

**Sequence**

HMMER searches of the SMART database occur by default. You may also find:

- [Outlier homologues](#) and homologues of known structure
- [PFAM domains](#)
- [signal peptides](#)
- [internal repeats](#)
- [intrinsic protein disorder](#)

If you have multiple sequences to analyze, try [batch access](#) to SMART database.

- Εύρεση πιθανών domains / motifs σε συγκεκριμένη αλληλουχία πρωτεΐνης.
- Εισαγωγή αλληλουχίας σε FASTA format.

**Εισαγωγή αλληλουχίας καντχερίνης-2 σε FASTA format**



# SMART – Παράδειγμα cadherin



Schultz et al. (1998) *Proc. Natl. Acad. Sci. USA* 95, 5857-5864  
 Letunic et al. (2008) *Nucleic Acids Res*, doi:10.1093/nar/gkn808


HOME SETUP FAQ ABOUT GLOSSARY WHAT'S NEW FEEDBACK

SMART MODE:  
 NORMAL  
 GENOMIC

Simple  
 Modular  
 Architecture  
 Research  
 Tool

## Domains within *Homo sapiens* protein CADH2\_HUMAN (P19022)

Cadherin-2 precursor



# SMART –

## Βάση τομέων (domains) πρωτεΐνης

---

- Εύρεση πληροφοριών για συγκεκριμένα domains.
- Λίστα με όλα τα καταχωρημένα domains.

### Domains detected by SMART

**Search domain annotation**   **Display domain annotation**

Keywords:

Search for keywords

Domain name or ACC:

Display annotation

- [Browse](#) the database of all available domains in the SMART database
- [Download](#) domain descriptions in tab delimited plain text
- [See a list](#) of recent domain changes
- [Suggest a domain](#) you think should be added to SMART



# “Ten Important Bioinformatics Databases”

- GenBank <http://www.ncbi.nlm.nih.gov> nucleotide sequences.
- Ensembl <http://www.ensembl.org> human/mouse genome (and others).
- PubMed <http://www.ncbi.nlm.nih.gov> literature references.
- NR <http://www.ncbi.nlm.nih.gov> protein sequences.
- SWISS-PROT <http://www.expasy.ch> protein sequences.
- InterPro <http://www.ebi.ac.uk> protein domains.
- OMIM <http://www.ncbi.nlm.nih.gov> genetic diseases.
- Enzymes <http://www.chem.qmul.ac.uk> enzymes.
- PDB <http://www.rcsb.org/pdb/> protein structures.
- KEGG <http://www.genome.ad.jp> metabolic pathways.



Source: *Bioinformatics for Dummies*



# Χρήσιμες πηγές

---

- **Gene cards (only human):**

<http://www.genecards.org/index.shtml>

- Χαρακτηριστικά και πολλαπλές ονομασίες γονιδίου.
- Γενική λειτουργία πρωτεΐνης που εκφράζεται από γονίδιο.
- Πληροφορίες για την αλληλουχία πρωτεΐνης.
- Δομή πρωτεΐνης.
- Ρόλος πρωτεΐνης στη φυσιολογία του κυττάρου.
- Επίπεδα έκφρασης σε διάφορους ιστούς.
- Βιβλιογραφία.

- <http://searchlauncher.bcm.tmc.edu/multi-align/multi-align.html>

- Επεξεργασία DNA και πρωτεϊνικών αλληλουχιών, π.χ. **FASTA format**.





# Μεταλλάξεις - Mutations

---

Normal DNA sequence

ATC-CCT-AGT-AAA



Mutated DNA sequence

ATC-CTT-AGT-AAG

Normal protein sequence

Isoleucine – Proline – Serine – Lysine

Mutated protein sequence

Isoleucine – Leucine – Serine – Lysine



# Επίσης...

- **a.a.:** Amino acids = Αμινοξέα (Πρωτεΐνη).
- **bp:** Base pairs = Ζεύγη βάσεων, νουκλεοτιδίων (DNA).
- **mRNA:** messenger RNA, αλληλουχία νουκλεοτιδίων, η θυμίνη (T) έχει αντικατασταθεί από ουρακίλη (U).
- **Partial, fragment:** Μέρος της αλληλουχίας (πρωτεΐνη ή DNA).
- **Gene:** Γονίδιο, κομμάτι DNA από το οποίο προκύπτει μία πρωτεΐνη.
- **Start codon:** ATG. Κωδικοποιεί τη μεθειονίνη.
- **Stop codon:** TAA (UAA), TAG (UAG), TGA (UGA). Δεν κωδικοποιεί αμινοξύ.
- **CDS:** Coding sequence, Κωδικοποιούσα αλληλουχία, Γονίδιο. Αρχίζει με ATG και τελειώνει με ένα κωδικόνιο τερματισμού.



---

# Τέλος Ενότητας



Ευρωπαϊκή Ένωση  
Ευρωπαϊκό Κοινωνικό Ταμείο



# Σημείωμα Αναφοράς

---

- Copyright Πανεπιστήμιο Δυτικής Μακεδονίας, Τμήμα Μηχανικών Πληροφορικής και Τηλεπικοινωνιών, Αγγελίδης Παντελής. «**Βιοπληροφορική**». Έκδοση: 1.0. Κοζάνη 2015. Διαθέσιμο από τη δικτυακή διεύθυνση: <https://eclass.uowm.gr/courses/ICTE102/>



# Σημείωμα Αδειοδότησης

Το παρόν υλικό διατίθεται με τους όρους της άδειας χρήσης Creative Commons Αναφορά, Όχι Παράγωγα Έργα Μη Εμπορική Χρήση 4.0 [1] ή μεταγενέστερη, Διεθνής Έκδοση. Εξαιρούνται τα αυτοτελή έργα τρίτων π.χ. φωτογραφίες, διαγράμματα κ.λ.π., τα οποία εμπεριέχονται σε αυτό και τα οποία αναφέρονται μαζί με τους όρους χρήσης τους στο «Σημείωμα Χρήσης Έργων Τρίτων».



[1] <http://creativecommons.org/licenses/by-nc-nd/4.0/>

Ως Μη Εμπορική ορίζεται η χρήση:

- που δεν περιλαμβάνει άμεσο ή έμμεσο οικονομικό όφελος από την χρήση του έργου για το διανομέα του έργου και αδειοδόχο
- που δεν περιλαμβάνει οικονομική συναλλαγή ως προϋπόθεση για τη χρήση ή πρόσβαση στο έργο
- που δεν προσπορίζει στο διανομέα του έργου και αδειοδόχο έμμεσο οικονομικό

# Διατήρηση Σημειωμάτων

---

Οποιαδήποτε αναπαραγωγή ή διασκευή του υλικού θα πρέπει να συμπεριλαμβάνει:

- το Σημείωμα Αναφοράς
- το Σημείωμα Αδειοδότησης
- τη δήλωση Διατήρησης Σημειωμάτων
- το Σημείωμα Χρήσης Έργων Τρίτων (εφόσον υπάρχει)

μαζί με τους συνοδευόμενους  
υπερσυνδέσμους.



# Σημείωμα Χρήσης Έργων Τρίτων

---

Το Έργο αυτό κάνει χρήση των ακόλουθων έργων:

Εικόνες:

- <https://www.cartoonstock.com/>
- Bioinformatics Computing, Book by Bryan Bergeron

