

# Ricerca di motivi nei grafi

## Applicazione a reti metaboliche

Giuseppe Luca Tomaino e Ilaria Clara Urciuoli

Università di Pisa  
<http://www.unipi.it>

4 giugno 2009



# Summary

- 1 Nozioni preliminari
  - Il metabolismo
  - Gli enzimi
- 2 Ricerca di motivi nei grafi
  - Definizione del problema
  - Complessita'
- 3 Algoritmo
  - Senza gap
  - Con gap
  - Risultati in tempo
- 4 Applicazioni
  - Ipotesi evolutive
  - Caratteristiche della rete

# Il metabolismo

## Il metabolismo

Insieme delle reazioni chimiche impiegate nella sintesi e degradazione di piccole molecole (le sostanze di cui un organismo è composto) dalle quali ottiene l'energia necessaria per la crescita

**Primario:** rappresenta il motore energetico principale; reazioni riscontrabili in tutti gli organismi

**Secondario:** non essenziale per la semplice crescita, sviluppo o riproduzione dell'organismo: di natura ecologica

# Il metabolismo

Elementi essenziali del metabolismo:

- Metaboliti
- Reazioni biochimiche
- Enzimi

## Metabolita

Composto coinvolto in una reazione biochimica del metabolismo: puo' costituire il substrato della reazione o un prodotto (intermedio o finale)

# Il metabolismo

Reazioni biochimiche:

**Anabolismo:** composti semplici + energia  $\rightarrow$  macromolecole complesse

**Catabolismo:** macromolecole complesse  $\rightarrow$  composti semplici + energia

## Vie metaboliche o Pathway


Insieme di reazioni chimiche che avvengono in modo sequenziale, e portano alla produzione di un prodotto finale e di prodotti intermedi (esempio: biosintesi della valina).

L'insieme dei pathway costituisce una rete metabolica

# Enzimi

## Gli enzimi

Struttura molecolare di natura proteica che catalizza una reazione chimica grazie all'interazione tra il suo *sito attivo* e il substrato che da origine al *complesso enzima-substrato*



L'enzima non si consuma durante la reazione

Il prodotto viene allontanato dall'enzima che è disponibile per una nuova reazione

# Enzimi

**Enzimi allosterici:** sono provvisti anche di un *sito allosterico* cui si lega una molecola che modifica la forma dell'enzima inibendo o facilitando la creazione di un complesso enzima-substrato



## Inibizione non competitiva



Il prodotto finale della via metabolica opera un meccanismo di regolazione a retroazione o feedback

Omeostasi: capacità di mantenere costanti le condizioni chimico-fisiche interne anche al variare delle condizioni ambientali esterne

# Gli enzimi

L' International Union of Biochemistry and Molecular Biology ha creato una commissione (**Enzyme Commission, EC**) per rinominare e numerare gli enzimi

## Principi

- 1 ogni nome deve identificare singoli enzimi e non possono essere applicati a sistemi contenenti più di un enzima
- 2 numero e nome sono assegnati in base alla reazione catalizzata dall'enzima;
- 3 gli enzimi sono divisi in gruppi sulla base dei tipi di reazione catalizzata e insieme ai nomi dei substrati sono le basi della nomenclatura e della numerazione

# La numerazione EC

Il numero EC indica uno specifico enzima in relazione alla **reazione** che è in grado di catalizzare.


Numerazione gerarchica:

EC  $x.y.z.t$

- $x$  tipo di reazione catalizzata (es. ossidoriduttasi, trasferasi, idrolasi)
- $y$  sottoclasse di reazione
- $z$  sotto-sottoclasse di reazione
- $t$  numero seriale per l'enzima nella sotto-sottoclasse

Un enzima puo' catalizzare piu' di una reazione e una reazione puo' essere catalizzata da piu' di un enzima

# Esempio di via metabolica



Fonte: KEGG Pathway

# KEGG Pathway

**KEGG PATHWAY** e' una collazione di vie metaboliche disegnate a mano che rappresentano la conoscenza attuale.

Contiene informazioni sul metabolismo di 209 organismi

Sono rappresentate solo le reazioni tra metaboliti primari

# Reti metaboliche come grafi

## Grafo

Definito come coppie  $(V, E)$  dove  $V$  è l'insieme di *vertici* e  $E \subseteq V \times V$  è l'insieme degli *archi*

Tipi di grafo:

- grafo bipartito:  $V = \text{composti} \cup \text{reazioni}$
- grafo dei composti  $V = \text{composti}$  (reazioni: etichette di  $E$ )
- grafo delle reazioni  $V = \text{reazioni}$  (composti: etichette di  $E$ )

# Grafo $G$

Grafo delle reazioni *non direzionato* e con etichette per i vertici

Ogni vertice di  $G$  sara' etichetto con 1 o piu' elementi dell'insieme  $C$  (chiamati colori)

$C$  è l'insieme degli EC number

## Direzionalita'

Il verso di una reazione dipende dalla sua reversibilità  
Informazione non sempre conosciuta e spesso incongruente all'interno dello stesso database

## Funzione di similarità tra reazioni: $S$

Per calcolare la similarità tra le reazioni si considera la similarità tra gli enzimi che le catalizzano:

- allineamento delle sequenze proteiche che compongono l'enzima
- confronto degli EC number degli enzimi

### Funzione di similarità

Assegna come score il valore corrispondente al livello più profondo al quale due EC number sono uguali.

Es.  $S(1.1.1.2, 1.1.1.3) = 3$

Valore di cut-off  $s$  in  $[0 \dots 4]$

# Definizione di Motivo

## Motivo


Un motivo  $M$  e' un insieme di elementi da un insieme  $C$  di colori

Nessun limite topologico: non viene specificato l'ordine in cui devono comparire i colori

Vantaggio: possiamo aggiungere successivamente restrizioni di tipo topologico e misurarne l'impatto

## Definizione di Motivo: esempio

$$M = \{blu, rosso, giallo, bianco\}$$



Limite di colore: 3 match

Limite topologico: 1 match

# Definizione di Occorrenza

Insieme connesso di vertici etichettati con i colori del motivo

Formalmente

$R$  sottinsieme dei nodi di  $G$

$M$  motivo con  $|M| = |R|$

$H(R, M)$  denota grafo bipartito in cui

- $R \cup M$  insieme dei vertici di  $H$
- c'è un arco tra un vertice  $v$  di  $R$  e un vertice  $c$  di  $M$  sse  $v$  ha  $c$  tra i suoi colori


# Definizione di Occorrenza esatta

## Occorrenza esatta

Un'occorrenza esatta del motivo  $M$  e' un insieme  $R$  di vertici di  $G$  tale che  $H(R, M)$  è un match perfetto e  $R$  induce un sottografo connesso in  $G$

## Definizione di Occorrenza esatta: esempio

$$M = \{blu, blu, giallo, rosso\}$$



1 match

# Definizione di Occorrenza approssimata

$lb$  numero massimo di gap locali

$gb$  numero massimo di gap globali

$s_c$  valore di cut-off,  $\forall c \in M$


## Occorrenza approssimata

Un'occorrenza approssimata di  $M$  (che rispetti  $lb$ ,  $gb$ , e la soglia  $s_c$ ) e' un insieme  $R$  di vertici contenuto in un insieme  $R'$  di vertici di  $G$  tale che:

- 1 per il grafo bipartito  $H(M \cup R, E_H)$  con  $E_H = \{\{c, v\} \in M \times R \mid \text{esiste un colore } c' \text{ per il quale } S(c', c) \geq s_c\}$ ,  $R$  e' un perfetto match;
- 2 per ogni sottoinsieme  $B$  di  $R$  tale che  $B \neq \emptyset$  e  $R \setminus B \neq \emptyset$  la lunghezza del percorso più breve in  $G_{R'}$  tra  $B$  e  $R \setminus B$  e' al più  $lb$ ;
- 3  $|R'| - |R| \leq gb$ .

## Definizione di Occorrenza approssimata: esempio

$$M = \{blu, blu, giallo, rosso\}$$



$$lb = 1$$


$$gb = 2$$

$$s = 4$$

1 match

## Definizione di Occorrenza approssimata: esempio

$$M = \{blu, blu, giallo, rosso\}$$



$$lb = 1$$

$$gb = 2$$

$$s = 4$$

non match

$$gb = 3 \rightarrow \text{match}$$

# Introduzione al problema

## Problema di ricerca

Dato un motivo  $M$  e un grafo  $G$  etichettato e non direzionato, trovare tutte le occorrenze di  $M$  in  $G$ .

- Nessuna restrizione topologica in  $M \implies$  problema  $\neq$  isomorfismo tra sottografi

## Problema di esistenza

Dato un motivo  $M$  e un grafo  $G$  etichettato e non direzionato, stabilire se  $M$  occorre in  $G$ .

- Complessità NP-C

# Introduzione al problema

## Problema di ricerca

Dato un motivo  $M$  e un grafo  $G$  etichettato e non direzionato, trovare tutte le occorrenze di  $M$  in  $G$ .

- Nessuna restrizione topologica in  $M \implies$  problema  $\neq$  isomorfismo tra sottografi

## Problema di esistenza

Dato un motivo  $M$  e un grafo  $G$  etichettato e non direzionato, stabilire se  $M$  occorre in  $G$ .

- Complessità NP-C

# Introduzione al problema

## Problema di ricerca

Dato un motivo  $M$  e un grafo  $G$  etichettato e non direzionato, trovare tutte le occorrenze di  $M$  in  $G$ .

- Nessuna restrizione topologica in  $M \implies$  problema  $\neq$  isomorfismo tra sottografi

## Problema di esistenza

Dato un motivo  $M$  e un grafo  $G$  etichettato e non direzionato, stabilire se  $M$  occorre in  $G$ .

- Complessità NP-C

# Introduzione al problema

## Problema di ricerca

Dato un motivo  $M$  e un grafo  $G$  etichettato e non direzionato, trovare tutte le occorrenze di  $M$  in  $G$ .

- Nessuna restrizione topologica in  $M \implies$  problema  $\neq$  isomorfismo tra sottografi

## Problema di esistenza

Dato un motivo  $M$  e un grafo  $G$  etichettato e non direzionato, stabilire se  $M$  occorre in  $G$ .

- Complessità NP-C

# Dimostrazione

## Proposizione

Il “Problema di esistenza” è NP-C anche se  $G$  è un albero

### Dimostrazione

Utilizzata una semplificazione dell'EXACT COVER BY 3-SETS (X3C)  $\implies$  Complessità NP-C

Istanza:

- un insieme  $X = \{1, 2, \dots, 3q\}$  con  $|X| = 3q$
- una collezione di sottoinsiemi  $C = \{C_1, C_2, \dots, C_n\}$  dove tutti gli elementi di  $C_i$  appartengono ad  $X$  e  $|C_i|=3$ ,  $\forall i = 1, \dots, n$
- un motivo  $M = \{Y, B, \dots, B, 1, \dots, 3q\}$
- un albero  $T$

# Dimostrazione

## Proposizione

Il “Problema di esistenza” è NP-C anche se  $G$  è un albero


### Dimostrazione

Utilizzata una semplificazione dell'EXACT COVER BY 3-SETS (X3C)  $\implies$  Complessità NP-C

Istanza:

- un insieme  $X = \{1, 2, \dots, 3q\}$  con  $|X| = 3q$
- una collezione di sottoinsiemi  $C = \{C_1, C_2, \dots, C_n\}$  dove tutti gli elementi di  $C_i$  appartengono ad  $X$  e  $|C_i|=3$ ,  $\forall i = 1, \dots, n$
- un motivo  $M = \{Y, B, \dots, B, 1, \dots, 3q\}$
- un albero  $T$

# Dimostrazione



## Dimostrazione

Definiamo una sotto-collezione  $C' \subseteq C$  avente la proprietà che ogni elemento di  $X$  occorre esattamente in un solo elemento di  $C'$

$$\exists C' \iff M \text{ occorre in } T$$

$\exists C' \implies M$  occorre in  $T$

$$|C'| = q.$$

Sia  $R$  l'insieme dei nodi di  $T$  che consiste in un nodo marcato  $Y$  e 4 nodi per ogni elemento di  $C'$ .

In  $R$  saranno presenti anche  $q$  nodi marcati  $B$  ed uno marcato da ogni elemento in  $X$ .

$\implies R$  è un'occorrenza di  $M$  in  $T$

$\exists C' \iff M \text{ occorre in } T$

Esiste un insieme  $R$  (con  $|R| = 1 + 4q$ ) che induce un sottografo di  $T$  connesso ed ha un nodo marcato da ognuno dei colori in  $M$ .

In  $R$  è inoltre presente il nodo marcato  $Y$

Una foglia da un elemento di  $C'$  è in  $R$  se e solo se il corrispondente  $r_i$  e' anche in  $R$ .


$|C'| = q$  ( $R$  deve contenere esattamente  $q$  nodi marcati  $B$ ).

Le tre foglie di ogni elemento di  $C'$  devono essere in  $R$  ( $|R| = 1 + 4q$ ).

$R$  deve contenere un nodo marcato per ogni elemento di  $X$ .

$\implies$  esiste l'insieme  $C'$  contenente ogni elemento di  $X$ .

# Esempio



Albero  $T$  e le sue etichette per  $X = \{1, \dots, 9\}$

$C = \{\{7, 6, 5\}, \{6, 5, 1\}, \{9, 8, 7\}, \{9, 8, 2\}, \{6, 4, 2\}, \{1, 3, 4\}\}$

In questo esempio  $M = \{Y, B, B, B, 1, \dots, 9\}$

# Trattabilita'

Dato che "Problema di esistenza" e' NP-C anche se  $G$  e' un albero, il "Problema di ricerca" e' NP-Hard

Trattabilita' a parametro fisso

- Il "Problema di ricerca" pur essendo NP-Hard e' trattabile a parametro fisso se  $G$  e' un albero con parametro  $k$  la lunghezza del motivo.
- Per un generico grafo  $G$  invece la complessita' e' sempre NP-C.

# Trattabilita'

Dato che “Problema di esistenza” e' NP-C anche se  $G$  e' un albero, il “Problema di ricerca” e' NP-Hard

Trattabilita' a parametro fisso

- Il “Problema di ricerca” pur essendo NP-Hard e' trattabile a parametro fisso se  $G$  e' un albero con parametro  $k$  la lunghezza del motivo.
- Per un generico grafo  $G$  invece la complessita' e' sempre NP-C.

# Trattabilita'

Dato che “Problema di esistenza” e' NP-C anche se  $G$  e' un albero, il “Problema di ricerca” e' NP-Hard

Trattabilita' a parametro fisso

- Il “Problema di ricerca” pur essendo NP-Hard e' trattabile a parametro fisso se  $G$  e' un albero con parametro  $k$  la lunghezza del motivo.
- Per un generico grafo  $G$  invece la complessita' e' sempre NP-C.


# Risultati di complessita'

TABLE 1  
 Complexity Results for the Motif Search Problem

MOTIF \ INPUT GRAPH		TREE	ARBITRARY
		TOPOLOGICAL MOTIFS	
COLORED TOPOLOGICAL MOTIFS	GENERAL CASE	polynomial	NP-complete
	FIXED COLORS AND NO REPETITION	polynomial	polynomial (conjecture)
COLORED MOTIFS (this paper)		NP-complete, FPT in $k$	NP-complete

Nella pratica le reti metaboliche sono grafi e non alberi, ma essendo relativamente piccole (3184 nodi e 17642 archi per una rete costruita a partire dal database di KEGG) è concepibile tentare di risolverlo applicando opportune potature nonostante il problema sia NP-C.

## Senza gap:




INPUT :  $|M| = 3$

Inizializzazione:

$Q = \{a\}$

$p = a$

## Senza gap:




Iterazione 1:

$$R = \{a\}$$

$$V[a] = \{b, c\}$$

$$Q = \{a, b, c\}$$

## Senza gap:



Iterazione 1:


$$R = \{a\}$$

$$V[a] = \{b, c\}$$

$$Q = \{a, b, c\}$$

$$p = b$$

## Senza gap:




Iterazione 2:

$$R = \{a, b\}$$

$$V[b] = \{d\}$$

$$Q = \{a, b, c, d\}$$

## Senza gap:



Iterazione 2:


$$R = \{a, b\}$$

$$V[b] = \{d\}$$

$$Q = \{a, b, c, d\}$$

$$p = c$$

## Senza gap:




Iterazione 3:

$$R = \{a, b, c\}$$

$$OCC = \{\{a, b, c\}\}$$

$$R = \{a, b\}$$

## Senza gap:



Iterazione 3:


$$R = \{a, b, c\}$$

$$OCC = \{\{a, b, c\}\}$$

$$R = \{a, b\}$$

$$p = d$$

## Senza gap:




Iterazione 4:

$$R = \{a, b, d\}$$

$$OCC = \{\{a, b, c\}\}$$

$$R = \{a, b\}$$

## Senza gap:



Iterazione 4:

$$R = \{a, b, d\}$$

$$OCC = \{\{a, b, c\}\}$$

$$R = \{a, b\}$$


Backtracking

$$p = b$$

$$R = \{a\}$$

$$Q = \{a, b, c\}$$

## Senza gap:



Iterazione 4:

$$R = \{a, b, d\}$$

$$OCC = \{\{a, b, c\}\}$$

$$R = \{a, b\}$$

Backtracking


$$p = b$$

$$R = \{a\}$$

$$Q = \{a, b, c\}$$

$$p = c$$

## Senza gap:




Iterazione 5:

$$R = \{a, c\}$$

$$V[c] = \{e\}$$

$$Q = \{a, b, c, e\}$$

## Senza gap:



Iterazione 5:


$$R = \{a, c\}$$

$$V[c] = \{e\}$$

$$Q = \{a, b, c, e\}$$

$$p = e$$

## Senza gap:




Iterazione 6:

$$R = \{a, c, e\}$$

$$OCC = \{\{a, b, c\}\}$$

$$R = \{a, c\}$$

## Senza gap:



Iterazione 6:

$$R = \{a, c, e\}$$

$$OCC = \{\{a, b, c\}\}$$

$$R = \{a, c\}$$


Backtracking

$$p = c$$

$$R = \{a\}$$

$$Q = \{a, b, c\}$$

## Senza gap:



Iterazione 6:

$$R = \{a, c, e\}$$

$$OCC = \{\{a, b, c\}\}$$

$$R = \{a, c\}$$

Backtracking

$$p = c$$


$$R = \{a\}$$

$$Q = \{a, b, c\}$$

$$p = a$$

$$R = \{\}$$

## Senza gap:



Iterazione 6:

$R = \{a, c, e\}$

$OCC = \{\{a, b, c\}\}$

$R = \{a, c\}$

Backtracking

$p = c$

$R = \{a\}$

$Q = \{a, b, c\}$

$p = a$

$R = \{\}$

$Q = \{a\}$  STOP


## Senza gap: pseudocodice

```

procedure noGaps ( INPUT: grafo  $G = \langle N, A \rangle$  , motivo  $M$ 
                   OUTPUT: tutte le occorrenze di  $M$  in  $G$  )

begin {
    OCC = {} //Occorrenze di  $M$  in  $G$ 
    Q = {} //coda
    V[] = {} //insieme dei vicini di un nodo
    R = {} //insieme candidato come occorrenza
    p = null //puntatore a nodo in  $N$ 
    foreach nodo n appartenente  $N$  {
        Q = {}
        Q = Q unito {n}
        p = n
        do {
            R = R unito {p}
            if (|R| == |M|) {
                if (R è un match con M)
                    OCC unito R
                R = R tolto {p}
            }
            else {
                V[p] = {nodi vicini a P non presenti in Q}
                Q = Q unito V[p]
            }
            while (p == ultimo elemento di Q && p !=n) {
                p = ultimo elemento in R
                R = R tolto {p}
                Q = Q tolto V[p]
            }
            p = successivo elemento in Q;
        } while (Q non contiene solo n)
    }
    return OCC
}
    
```

## Con gap:




INPUT :  $|M| = 3$   
 $lb = 1$   
 $gb = 2$

Inizializzazione:

$Q = \{a\}$   
 $p = a$

## Con gap:



Iterazione 1:

$$R = \{a\}$$

$$S = \{\}$$

$$d = 0$$


$$dtot = 0$$

$$DIST[a] = 0$$

$$V[a] = \{b,c,e,d\}$$

$$Q = \{a,b,c,e,d\}$$

## Con gap:



Iterazione 1:

$$R = \{a\}$$

$$S = \{\}$$

$$d = 0$$

$$dtot = 0$$


$$DIST[a] = 0$$

$$V[a] = \{b,c,e,d\}$$

$$Q = \{a,b,c,e,d\}$$

$$p = b$$

## Con gap:



Iterazione 2:

$$R = \{a, b\}$$

$$S = \{a\}$$

$$d = 0$$


$$dtot = 0$$

$$DIST[b] = 0$$

$$V[b] = \{\}$$

$$Q = \{a, b, c, e, d\}$$

## Con gap:



Iterazione 2:

$$R = \{a, b\}$$

$$S = \{a\}$$

$$d = 0$$

$$dtot = 0$$


$$DIST[b] = 0$$

$$V[b] = \{\}$$

$$Q = \{a, b, c, e, d\}$$

$$p = c$$

## Con gap:




Iterazione 3:

$$R = \{a, b, c\}$$

$$OCC = \{\}$$

$$R = \{a, b\}$$

## Con gap:



Iterazione 3:


$$R = \{a, b, c\}$$

$$OCC = \{\}$$

$$R = \{a, b\}$$

$$p = e$$

## Con gap:




Iterazione 4:

$$R = \{a, b, e\}$$

$$OCC = \{\}$$

$$R = \{a, b\}$$

## Con gap:



Iterazione 4:


$$R = \{a, b, e\}$$

$$OCC = \{\}$$

$$R = \{a, b\}$$

$$p = d$$

## Con gap:




Iterazione 5:

$$R = \{a, b, d\}$$

$$OCC = \{\}$$

$$R = \{a, b\}$$

## Con gap:



Iterazione 5:

$R = \{a, b, d\}$

$OCC = \{\}$

$R = \{a, b\}$

Backtracking


$p = b$

$R = \{a\}$

$dtot = 0$

$Q = \{a, b, c, e, d\}$

## Con gap:



Iterazione 5:

$R = \{a, b, d\}$

$OCC = \{\}$

$R = \{a, b\}$

Backtracking

$p = b$


$R = \{a\}$

$dtot = 0$

$Q = \{a, b, c, e, d\}$

$p = c$

## Con gap:



Iterazione 6:

$$R = \{a, c\}$$


$$S = \{a\}$$

$$d = 0$$

$$\text{DIST}[c] = 0$$

$$V[c] = \{f\}$$

## Con gap:



Iterazione 6:

$$R = \{a, c\}$$

$$S = \{a\}$$

$$d = 0$$


$$\text{DIST}[c]=0$$

$$V[c] = \{f\}$$

$$Q = \{a,b,c,e,d,f\}$$

$$p = e$$

## Con gap:




Iterazione 7:

$$R = \{a, c, e\}$$

$$OCC = \{\}$$

$$R = \{a, c\}$$

## Con gap:



Iterazione 7:


$$R = \{a, c, e\}$$

$$OCC = \{\}$$

$$R = \{a, c\}$$

$$p = d$$

## Con gap:




Iterazione 8:

$$R = \{a, c, d\}$$

$$OCC = \{\}$$

$$R = \{a, c\}$$

## Con gap:



Iterazione 8:


$$R = \{a, c, d\}$$

$$OCC = \{\}$$

$$R = \{a, c\}$$

$$p = f$$

## Con gap:




Iterazione 9:

$$R = \{a, c, f\}$$

$$OCC = \{\}$$

$$R = \{a, c\}$$

## Con gap:



Iterazione 9:

$R = \{a, c, f\}$

$OCC = \{\}$

$R = \{a, c\}$


Backtracking

$p = c$

$R = \{a\}$

$dtot = 0$

## Con gap:



Iterazione 9:

$$R = \{a, c, f\}$$

$$OCC = \{\}$$

$$R = \{a, c\}$$

Backtracking

$$p = c$$


$$R = \{a\}$$

$$dtot = 0$$

$$Q = \{a, b, c, e, d\}$$

$$p = e$$

## Con gap:



Iterazione 10:

$$R = \{a, e\}$$

$$S = \{a\}$$


$$d = 1$$

$$dtot = 1$$

$$DIST[e] = 1$$

$$V[e] = \{f, g, h\}$$

## Con gap:



Iterazione 10:

$$R = \{a, e\}$$

$$S = \{a\}$$

$$d = 1$$

$$dtot = 1$$


$$DIST[e] = 1$$

$$V[e] = \{f, g, h\}$$

$$Q = \{a, b, c, e, d, f, g, h\}$$

$$p = d$$

## Con gap:




Iterazione 11:

$$R = \{a, e, d\}$$

$$OCC = \{\}$$

$$R = \{a, e\}$$

## Con gap:



Iterazione 11:


$$R = \{a, e, d\}$$

$$OCC = \{\}$$

$$R = \{a, e\}$$

$$p = f$$

## Con gap:




Iterazione 12:

$$R = \{a, e, f\}$$

$$OCC = \{\{a, e, f\}\}$$

$$R = \{a, e\}$$


## Con gap:



Iterazione 12:

$R = \{a, e, f\}$   
 $OCC = \{\{a, e, f\}\}$   
 $R = \{a, e\}$   
 $p = g$

## Con gap:




Iterazione 13:

$$R = \{a, e, g\}$$

$$OCC = \{\{a, e, f\}\}$$

$$R = \{a, e\}$$

## Con gap:



Iterazione 13:


$$R = \{a, e, g\}$$

$$OCC = \{\{a, e, f\}\}$$

$$R = \{a, e\}$$

$$p = h$$

## Con gap:




Iterazione 14:

$$R = \{a, e, h\}$$

$$OCC = \{\{a, e, f\}, \\ \{a, e, h\}\}$$

$$R = \{a, e\}$$

## Con gap:



Iterazione 14:

$R = \{a, e, h\}$

$OCC = \{\{a, e, f\},$   
 $\{a, e, h\}\}$

$R = \{a, e\}$


Backtracking

$p = e$

$R = \{a\}$

$dtot = 0$

## Con gap:



Iterazione 14:

$R = \{a, e, h\}$

$OCC = \{\{a, e, f\},$   
 $\{a, e, h\}\}$

$R = \{a, e\}$

Backtracking

$p = e$


$R = \{a\}$

$dtot = 0$

$Q = \{a, b, c, e, d\}$

$p = d$

## Con gap:



Iterazione 15:

$$R = \{a,d\}$$

$$S = \{a\}$$


$$d = 1$$

$$dtot = 1$$

$$V[d] = \{\}$$

$$Q = \{a,b,c,e,d\}$$

## Con gap:



Iterazione 15:

$$R = \{a,d\}$$

$$S = \{a\}$$

$$d = 1$$

$$dtot = 1$$

$$V[d] = \{\}$$

$$Q = \{a,b,c,e,d\}$$

Backtracking


$$p = d$$

$$R = \{a\}$$

$$dtot = 0$$

$$Q = \{a,b,c,e,d\}$$

## Con gap:



Iterazione 15:

$R = \{a,d\}$

$S = \{a\}$

$d = 1$

$dtot = 1$

$V[p] = \{\}$

$Q = \{a,b,c,e,d\}$

Backtracking

$p = d$

$R = \{a\}$

$dtot = 0$


$Q = \{a,b,c,e,d\}$

$p = a$

$R = \{\}$

$dtot = \text{null}$

## Con gap:



Iterazione 15:

$R = \{a,d\}$

$S = \{a\}$

$d = 1$

$dtot = 1$

$V[p] = \{\}$

$Q = \{a,b,c,e,d\}$

Backtracking

$p = d$

$R = \{a\}$

$dtot = 0$

$Q = \{a,b,c,e,d\}$

$p = a$

$R = \{\}$

$dtot = \text{null}$

$Q = \{a\}$  STOP

# Con gap: pseudocodice 1

```
procedura withGaps ( INPUT: grafo  $G = \langle N, A \rangle$  , motivo  $M$ , numero massimo di salti locali  $lb$ , numero  
                    massimo di salti globali  $gb$   
                    OUTPUT: tutte le occorrenze di  $M$  in  $G$  )  
  
begin {  
  OCC = {} //Occorrenze di  $M$  in  $G$   
  Q = {} //coda  
  V[] = {} //insieme dei vicini di un nodo  
  R = {} //insieme candidato come occorrenza  
  p = null //puntatore a nodo in  $N$   
  S //sottografo formato dai nodi candidati a distanza da  $p$  al massimo pari a  $gb$   
  d //distanza minima tra  $p$  e ed il sottografo  $S$   
  dtot //il numero di salti totali compiuti per un determinato percorso  
  DIST[ ] //numero di salti da un nodo totali tra un nodo ed il nodo origine
```

## Con gap: pseudocodice 2

```

foreach nodo n appartenente N {
    Q = {}
    Q = Q unito {n}
    p = n
    do {
        R = R unito {p}
        if (|R| == |M|) {
            if (R è un match con M)
                OCC unito R
            R = R tolto {p}
        }
        else {
            S = nodi presenti in R, escluso p, a distanza da p al massimo pari a gb
            d=distanza minima per arrivare da p a uno qualsiasi dei nodi di S oppure zero se p=n
            dtot=dtot+d
            DIST[p]=dtot
            V[p] = {nodi a distanza massima da p pari a min{lb,gb-dtot} non presenti in Q}
            Q = Q unito V[p]
        }
        while (p == ultimo elemento di Q && p!=n) {
            p = ultimo elemento in R
            R = R tolto {p}
            dtot=DIST[ultimo elemento in R]
            Q = Q tolto V[p]
        }
        p = successivo elemento in Q;
    } while (Q non contiene solo n)
}
return OCC
    
```

## Risultati in tempo

Grafo utilizzato: 3184 nodi e 17642 archi (rete costruita a partire dal database di KEGG)

Per  $s=3$ :


- numero di colori: 171
- frequenza minima di un colore: 0,006
- frequenza più alta di un colore: 0,089

Per un motivo  $M$  con  $|M| = 4$  ed  $lb = gb = 0$ , ricercare tutte le occorrenze ha impiegato 8ms (in media) su un Pentium IV (CPU da 1,70GHz) con 512Mb di memoria ram


# Ipotesi evolutive

Tentativo di spiegare la storia evolutiva a partire dalla somiglianza dei pathway


Leucine Biosynthesis



Valine Biosynthesis




Isoleucine Biosynthesis



$$M = \{1.1.1.86, 1.1.1.86, 4.2.1.9, 2.6.1.42, 6.1.1.9\}, s = 3, lb = gb = 1$$

# Caratteristiche della rete: power law

- Distribuzione dei gradi dei vertici del grafo (pochi hub, molti nodi poco connessi)
- Distribuzione del numero di occorrenze dei motivi (con  $|M| = 4$  e  $s = 3$ ,  $|M| = 4$  e  $s = 2$ ,  $|M| = 3$  e  $s = 3$  e  $|M| = 3$  e  $s = 2$ )



Inoltre il 95% dei motivi di lunghezza 3 (il 98% nel caso di motivi lunghi 4) non occorrono mai

# Caratteristiche della rete: occorrenze interpathway

## Occorrenze interpathway

Occorrenze di un motivo che superano i confini dei pathway così come sono stabiliti ora

$$|M| = 3$$

$$s = 3$$

74% delle occorrenze sono interpathway

$$|M| = 4$$

$$s = 3$$

92% delle occorrenze sono interpathway

# Bibliografia

-  Vincent Lacroix, Cristina G. Fernandes, Marie-France Sagot - *Motif search in graph: application to metabolic network*
-  Vincent Lacroix, Ludovic Cottret, Patricia Thébault, Marie-France Sagot - *An introduction to metabolic networks and their structural analysis*
-  Giuseppe, Domenico Arrabito - *Le reti metaboliche*
-  <http://www.genome.jp/kegg/>
-  <http://www.wikipedia.org/>