



基因排序器的设计

代码之美第13章

基因排序器

- 网址 <http://genome.ucsc.edu/cgi-bin/hgNear>
- 用于处理人类基因组项目(Human Genome Project)中产生的数据

处理流程

- 1 通过CGI收集收集来自用户的输入
- 2 查询MySQL数据库
- 3 用HTML呈现结果

用户界面

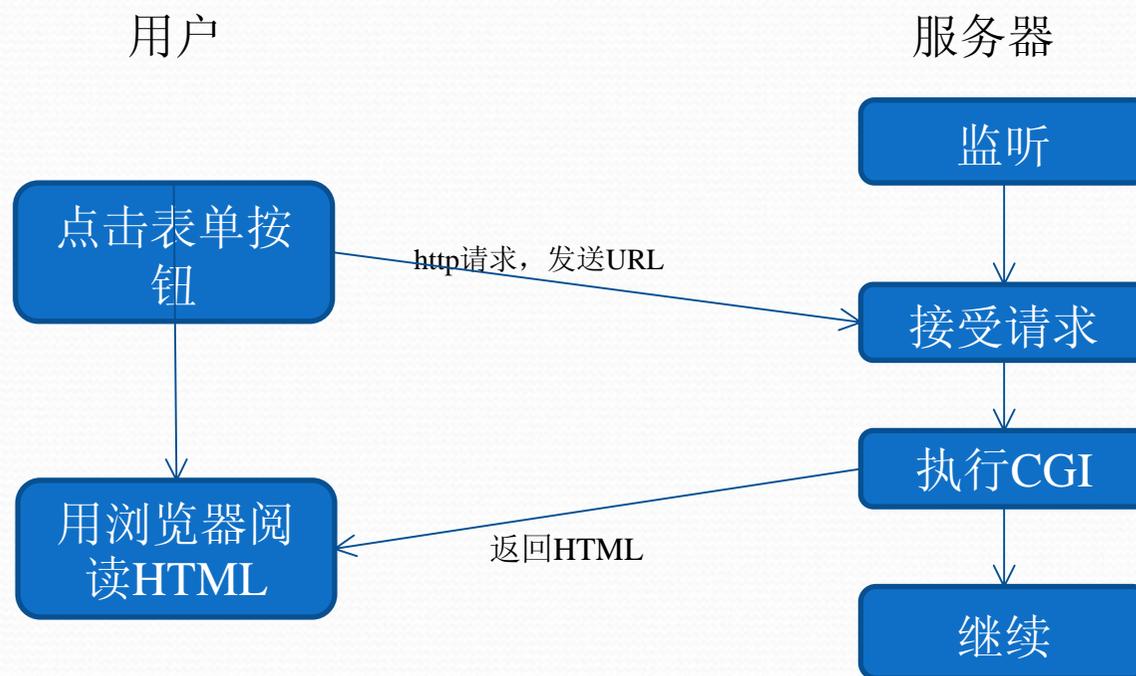
Home UCSC Human Gene Sorter [Help](#)

genome: Human assembly: Mar. 2006 (NCBI36/hg18) search: uc004dmz.1

sort by: Gene Distance filter (now off) display: 50 output:

#	Name	VisiGene	testis	ovary	liver	kidney	lung	heart	pancreatic islets	adipocyte	skin	PB-CD4+ T cells	bone marrow	thymus	amygdala	whole brain	fetal brain	BLASTP E-Value	Genome Position	Description
1	SYP	76987	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	5e-130	chrX 48,937,407	synaptophysin
2	PRICKLE3	186068	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,924,285	LIM domain only 6
3	PLP2	76455	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,916,799	proteolipid protein 2 (colonic)
4	CACNA1F	174590	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,962,622	calcium channel, voltage-dependent, L type,
5	MAGIX	179636	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,908,452	MAGI family member, X-linked isoform a
6	CCDC22	185157	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,986,613	coiled-coil domain containing 22
7	FOXP3	1768	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 49,001,036	forkhead box P3 isoform a
8	GPKOW	n/a	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,862,156	G patch domain and KOW motifs
9	PPP1R3F	179945	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	chrX 49,022,141	protein phosphatase 1, regulatory (inhibitor)
10	WDR45	35149	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,821,772	WD repeat domain 45 isoform 2
11	PRAF2	175866	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,817,184	PRA1 domain family, member 2
12	GAGE10	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	chrX 49,055,162	G antigen 10
13	AK001937	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	chrX 48,807,010	Homo sapiens cDNA FLJ11075 fis, clone PLACE1005046.
14	CCDC120	185158	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,808,957	coiled-coil domain containing 120
15	TFEB3	39053	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,779,560	transcription factor E3
16	GRIPAP1	30802	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,729,348	GRIP1 associated protein 1 isoform 1
17	KCND1	62197	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	n/a	chrX 48,708,389	potassium voltage-gated channel, Shal-related

通过Web与用户保持对话



CGI

- 优点：
 - 可移植性高
- 缺点：
 - 交互性一般

生命周期短暂的CGI脚本

- 复杂的CGI脚本需要能长期保存数据
- 方法一：隐藏的CGI变量（数据通过隐藏的<INPUT>标签保存在HTML中），生命周期为单次会话。
- 方法二：cookie，生命周期很长。

行李车

- 维护两张数据库表，一张关联用户，另一张关联会话。
- 表的格式：
 - 一个主键列，一个blob字段，一个跟踪使用时间和访问计数的字段。（Blob：包含通过URL传送的所有变量/值对。）
- Cookie指向用户表
- 隐藏的CGI变量指向会话表

行李车

- 网站上所有的CGI脚本共享同一个行李车。
- 避免变量名冲突
CGI变量名使用CGI脚本的名字开头。

多态

- 在C语言中构造多态对象：
- 1 用结构体代替对象
- 2 用函数指针代替多态方法

column结构体

```
struct column
/*大表格中的一列，hgNear中的核心数据结构*/
{
    /*所有的列都存在的数据；*/
    struct column *next; /*链表中的下一列*/
    char *name;          /*列名，用户看不到*/
    char *shortLabel;   /*列标签*/
    char *shortLabel;   /*列描述*/

    /*方法*/
    void (*cellPrint)(struct column *col, struct genePos *gp, struct sqlConnection *conn);
    /*在HTML中打印该列的一个单元格*/

    void (*labelPrint)(struct column *col);
    /*在标签行中打印标签*/
    void (*filterControls)(struct column *col, struct sqlConnection *conn);
    /*打印高级过滤器中的控件标签*/
    struct genePos *(*advFilter)(struct column *col, struct sqlConnection *conn)
    /*返回高级过滤器的位置列表*/

    /*下面的几个字段是查找表(Lookup table)使用的*/
    char *table; /*关联表(associated table)的名字*/
    char *keyField; /*关键表中的GeneID字段*/
    char *valField; /*关键表中的Value字段*/

    /*除了跟查找相关的字段，关联表还使用如下字段*/
    char *queryFull; /*返回两列键/值的查询*/
    char *queryOne; /*给定键，返回值相关值的查询*/
    char *invQueryOne; /*给定值，返回值相关键的查询*/
};
```

创建列对象的方法

- 基于columnDb.ra文件创建
- columnDb记录包含一些字段用于描述列名，用户可见的短标签和长标签，列在表格中的默认位置，默认是否可见，以及一些类型字段。
- 类型字段决定列拥有哪些方法。
- 除此之外，可能存在类型特定的附加字段。
- 在很多情形中，columnDb包含了查询数据库表的sql语句以及链接到列中每个数据项的URL。

columnDb.ra

name proteinName
shortLable UniProt
longLable UniProt (SwissProt/TrEMBL) Protein Display ID
priority 2.1
visibility off
type association kgXref
queryFull select kgID, spDisplayID from kgXref
queryOne select spDisplayID, spID from kgXref where kgID = '%s'
invQueryOne select kgID from kgXref where spDisplayID = '%s'
search fuzzy
itemUrl <http://us.expasy.org/cgi-bin/niceprot.pl?%s>

name proteinAcc
shortLable UniProt Acc
longLable UniProt (SwissProt/TrEMBL) Protein Accession
priority 2.15
visibility off
type lookup kgXref kgID spID
search exact
itemUrl <http://us.expasy.org/cgi-bin/niceprot.pl?%s>

name refSeq
shortLable RefSeq
longLable NCBI RefSeq Gene Accession
priority 2.2
visibility off
Type lookup knowToRefSeq name value
search exact
itemUrl <http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?cmd=Search&db=Nucleotide&term=%s&doptcmdl=GenBank&tool=genome.ucsc.edu>

- columnDb被编排成三层目录结构。
- 根目录：所有物种都会出现的列信息。
- 中间层：特定物种的信息。
- 底层：特定集合的信息（将特定物中的DNA分成若干集合）

列的类型

- 1 查找类型
 - 引用一张表，对GeneID进行索引
 - 包含表、geneID字段和列中显示的字段
- 2 关联类型
 - 一个基因关联多个值
- 3 其他
 - 如基因表达的列
 - 相对复杂

滤除无关的基因

- 每一列有两个过滤方法：用来向过滤器用户界面输出HTML的filterControls和完成实际的过滤的advFilter。
- 这两个方法通过行李车变量进行交互。
- 过滤器被排成一个链。把每个过滤器依次调用一遍。

过滤器的性能

- 在每个基因上用的时间不超过万分之一秒。
- 避免磁盘寻道。
先到行李车检查是否设置过相关变量。
每次读取整张表。

大规模美丽代码理论

- 提高代码的可理解性
- 合适的名字

```

static struct genePos *wildAssociationFilter(
    struct slName *wildList, boolean orLogic, struct column *col,
    struct sqlConnection *conn, struct genePos *list)
/*过滤匹配通配符列表中的任何一项的关联.*/
{
/*将关联按gene ID分组*/
struct assocGroup *ag = assocGroupNew(16);
struct sqlResult *sr = sqlGetResult(conn, col->queryFull);
char **row;
while ((row = sqlNextRow(sr)) != NULL)
    assocGroupAdd(ag, row[0], row[1]);
sqlFreeResult(&sr);

/*寻找匹配的关联并把它们放进passHash表中.*/
struct hash *passHash = newHash(16); /*哈希表, 用于保存通过过滤的项目*/
struct genePos *gp;
for (gp = list; gp != NULL; gp = gp->next)
    {
    char *key = (col->protKey ? gp->protein : gp->name);
    struct assocList *al = hashFindVal(ag->listHash, key);
    if (al != NULL)
        {
        if (wildMatchRefs(wildList, al->list, orLogic))
            hashAdd(passHash, gp->name, gp);
        }
    }
/*创建经过过滤的列表, 善后清理, 返回.*/
list = weedUnlessInhash(list, passHash);
hashFree(&passHash);
assocGroupFree(&ag);
return list;
}

```

其他提高代码可理解性的方法

- 尽可能让作用域局部化。
- 减小副作用