

# R/Bioconductor在生物多维组学数据 整合中的应用





第五届中国R语言会议（上海）

2012年11月03日

# 概要



- 涉及的基本生物学概念
  - 中心法则和组学(Omics)
- 组学数据整合的哲学基础和应用意义
- R/Bioconductor在组学数据整合中的案例
- 挑战和展望

# 细胞中分子信息链



# 分子生物学“第一定律”

- 1953年James Watson & Francis Crick发现DNA双螺旋结构；
- 1958年Francis Crick提出中心法则“Central dogma”，并于1970年在Nature杂志上发表；
- 中心法则的多层次扩展产生了多种组学(Omics)数据；




Watson J.D. and Crick F.H.C. A Structure for Deoxyribose Nucleic Acid. *Nature* 171, **1953**. 737-738.

Crick F., Central Dogma of Molecular Biology. *Nature* 227, **1970**. 561-563.

# 中心法则与多层次组学

- 什么是组学(Omics)?
- 随着中心法则展开, 生物的信息复杂度逐步增大;
- 基因型和表型密切相关, 从而为疾病研究提供思路。




# 数据整合的哲学基础



# 组学数据整合的医学意义

- 疾病是**复杂系统**，如何解决“**Puzzle of Complex Disease**”？
- 多维组学数据整合可更全面真实地模拟疾病**自然机制**；
- 多维组学数据整合可以有效提高生物信号的“**信噪比**”；
- **系统生物学**理论指引的数据整合是**转化医学**和**个体化医疗**发展的基石。




# 多维组学数据整合的方式

## 整合类型定义和平台建设:

- 第一类，组学数据与**先验知识**的横向整合
  - 文献、本体、生物医学数据库等。
  - 自有数据 + 同类的公共数据/已测基因组。
- 第二类，**不同层次**组学数据之间的纵向整合
  - **SNPs / CNVs / DNA methylation / Gene Expression / microRNAs/Proteins**
    - DNA methylation/microRNAs/lncRNA profiling/CNVs + gene expression,
    - SNPs + CNVs, SNPs + gene expression,
    - Gene expression +Proteins, microRNA + Proteins.
- 第三类，组学数据与**表型数据**的关联性整合
  - 组学数据 + 临床资料(门诊、影像、生化和病理等);
  - 组学数据 + 治疗数据(药理、药效和预后等)。
- 第四类，基于公共大数据的**专题**挖掘性整合

# 案例分析：神经胶质瘤干细胞 vs 正常神经干细胞的Gene和microRNA表达数据整合分析

- **神经胶质瘤(Glioma)**是起源于神经胶质细胞的最常见的颅内肿瘤，约占所有颅内肿瘤的45%左右；
- 肿瘤干细胞学说：
  - 肿瘤干细胞和非肿瘤干细胞：**神经胶质瘤干细胞(GSC)**和**正常神经干细胞(NSC)**；
  - 基因调控(表达异常和突变等)可使**NSC**获得过度增殖能力，就具备了肿瘤细胞的特征；
  - 肿瘤发生、复发和转移的根源。




# microRNA的基因调控

- microRNA是一类由内源基因编码的长度约为22个核苷酸的非编码单链RNA分子；
- microRNA可在转录后抑制基因的表达；
- microRNA倾向于和靶标基因表达负相关；
- 靶标预测是microRNA调控研究的难点；
- microRNA调控广泛存在于神经胶质瘤(Glioma)。

# miRNA-mRNA整合分析流程

- miRNA和mRNA表达谱数据矩阵化
- 利用miRNA-mRNA的负相关关系筛选相关性
- miRNA的靶标预测及其功能通路分析
- 整合miRNA-mRNA相关性矩阵和靶标矩阵
- 利用整合相关性构建miRNA-mRNA调控关系




# 流程中的R和Bioconductor(芯片数据为例)


simpleaffy    affy  
affycoretools    limma

heatmap.2()  
plotPCA()  
hclust()


Hmisc.rcorr(), cor()




质控/预处理




样本分析




相关性计算



差异基因筛选



调控网络



功能分析

t.test()    genefilter  
samr    TANOVA  
limma    siggenes


igraph  
mirDIP

GO.db    AnnotationDbi    barplot()  
org.Hs.eg.db    Bsgenome    ggplot2  
org.Mm.eg.db    phyper()

# 原始数据质量控制

## RNA degradation plot

```
> library(simpleaffy)
> Dilution.deg <- AffyRNAdeg(Dilution)
> plotAffyRNAdeg(Dilution.deg,col=colors)
> legend("topright",rownames(pData(Dilution)),
col=colors,lwd=1,inset=.05)
```



# 原始数据质量控制

RNA degradation of beta-actin

Boxplot of beta-actin ratios

```
> require("affy", quietly = TRUE)
> require("affycomp", quietly = TRUE)
> require("affyPLM", quietly = TRUE)
> require("affypdnn", quietly = TRUE)
> require("bioDist", quietly = TRUE)
> require("simpleaffy", quietly = TRUE)
> require("affyQCReport", quietly = TRUE)
> require("plier", quietly = TRUE)
> rawData <- ReadAffy()
> ###ratioPlot()自定义函数
> ratioPlot(rawData,quality=quality,experimentFactor,
plotColors,legendColors, WIDTH=WIDTH,
HEIGHT=HEIGHT, POINTSIZE=POINTSIZE,
MAXARRAY=maxArray)
```


c\_12h\_rep2  
c\_12h\_rep1  
c\_24h\_rep2  
c\_24h\_rep1  
t\_12h\_rep1  
t\_12h\_rep2  
t\_24h\_rep1  
t\_24h\_rep2

3'/5' ratio


3'/M ratio

beta-actin QC: OK (all 3'/5' ratios < 3)


# 数据标准化



# 基于PCA分析的样本筛选



# 样本无监督聚类



```
> library(gplots)
> data <- read.table(file = "", header = T, quote = "")
> X <- data[,1:6]
> X <- as.matrix(X)
> for(i in 1:dim(X)[1])
  {
  len = max(X[i,]) - min(X[i,])
  X[i,] = X[i,] - min(X[i,])
  X[i,] = X[i,] / len
  }
> heatmap.2(X, dendrogram = "both", col = greenred,
trace = "none", ylab = NULL, margins = c(6, 8))
```

NSC\_2

NSC\_1

NSC\_3



BTSC\_2

BTSC\_3

BTSC\_1

# 网络构建和模块分析

```
> library(igraph)
> g <- graph.empty()
> g <- add.vertices(g, nrow(nodeattr), name=as.character(nodeattr[,1]),
> fc=as.character(nodeattr[,3]), class=as.character(nodeattr[,4]),
symbol=as.character(nodeattr[,2]))
> V(g)[class=="miRNA"]$shape <- "rectangle"
> V(g)[class=="mRNA"]$shape <- "circle"
> names <- V(g)$name
> V(g)$fc <- log(as.numeric(V(g)$fc),2)
> ids <- 1:length(names)
> names(ids) <- names
> # for edges
> from <- as.character(rel[,1])
> to <- as.character(rel[,2])
> edges <- matrix(c(ids[as.character(from)],ids[to]),nc=2)
> edges <- as.numeric(t(edges))
> g <- add.edges(g, edges)
> plot(g,vertex.label=V(g)$symbol,vertex.label.color="black",
edge.arrow.size=0)
```




# GO功能富集分析

regulat


re

```
> data<-read.table("", sep = "\t")
> X<-data[,4:7]
> P<-matrix(0,nrow=dim(X)[1],ncol=2)
> p <- phyper(q, m, n, k, lower.tail = TRUE, log.p = FALSE)
> P[i,1]=1-p
> p.adjust(P[,1],method="fdr")->P[,2]
> gears =cbind(data[,2:3],data[,11])
> gears_bp=gears[gears[,2]=="biological_process",]
> gears_bp<-gears_bp[order(gears_bp[,3],decreasing=TRUE),]
> barplot(gears_mf[,3], horiz=TRUE,xlab="-log(p-
value)",col=3,axes = TRUE, axisnames=TRUE,
names.arg=labels,las=1)
```

# Pathway功能富集分析



## Axon guidance



# 挑战和展望



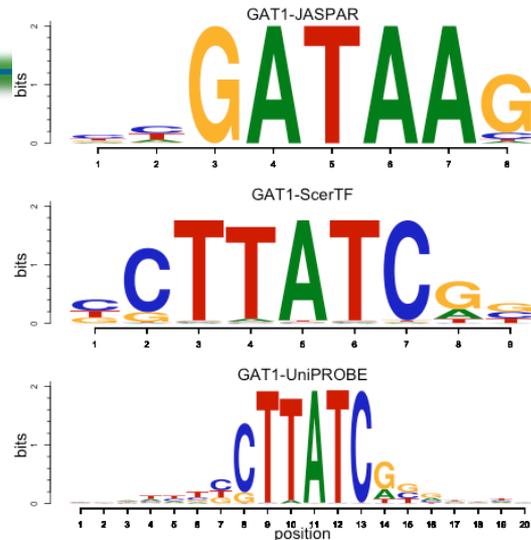


- **疾病的复杂性要求**
  - 更可靠的临床样本积累；
  - 更真实的科学假设；
  - 更海量的信息和数据；
- **应对生物大数据要求**
  - 更高效的算法和程序；
  - 更先进的软件体系（如云或并行构架R）；
  - 更强大的硬件支撑；
  - 学科间的交流和交叉学科人才培养。


# 《R语言在生物信息学中的应用》

——一本即将面世的R红宝书

康奈尔大学 高山博士

基本统计分析，高通量与多维数据可视化，统计绘图，下一代测序技术数据分析





1. 本书是多名**R领域专家**通过互联网联手写作。
2. 从实例出发，直接和应用挂钩，不是罗列流水账，不是背课文。
3. 很多例子来自于实际工作，有些工作发表在**nature**等高水平期刊上。
4. 作者之一参与了**R bioconductor**的开发，所开发包的内容也包括进本书。
5. 从研究课题出发，讲思路，有具体代码和详细注释，不空洞，学生可以系统掌握如何设计课题，编程实现。





## 编者阵容

- 高山（Cornell University，目前主要研究生物信息学算法，专长R与新算法开发。）
- 欧剑虹（Umass Medical School，主要从事R package的开发，曾参与并成功开发了多个Bioconductor包）
- 肖凯（职业数据分析师，专长于R平台的数据分析）
- 李勃（重庆大学，曾主编基因工程等教材，现从事生物芯片数据挖掘）
- 施劲松（南京军区总医院）
- 管栋印（Case Western Reserve University）
- 张洋（University of Illinois）
- 其他。。。



## 致谢

- 感谢国内首本“R/Bioconductor”的作者谢建明老师的大力支持！
- 欣蒙多家出版商的邀稿，虽未最终确定出版方，但仍表示感谢！

# 谢谢!



## 思博奥科

SysBiomics Bioinformatics (Beijing) Ltd.

思行创新

Consideration, Action and Creation

联系人: 杭兴宜 博士

地址: 北京市中关村科技园(丰台园)航丰路8号1808室 100070

电话(传真): +86 10 5805 1799, 传真: +86 10 8826 9778

手机: 15611223895

电子邮件: [xingyi.hang@sysbiomics.com](mailto:xingyi.hang@sysbiomics.com)