

肝细胞癌关键生物标志物的筛选和鉴定

——来自生物信息分析的证据

王乾坤

安徽医科大学第一临床医学院, 中国·安徽 合肥 230032

【摘要】为探究HCC发生的分子机制,从GEO芯片数据集GSE84402获取肝癌组织和肝癌旁正常组织的数据信息,通过GEO2R鉴定出差异常表达基因(DEGs),对DEGs进行功能GO富集分析和KEGG通路分析比较,并构建蛋白-蛋白相互作用网络(PPI)图导入Cytoscape进行模块分析得到Hub基因,分别对Hub基因在cBioPortal用Kaplan-Meier曲线进行总生存期和无病生存期分析,确定关键基因,最后用UCLAN进行验证。结果鉴定出93个基因,其中下调基因68个,上调基因25个。TTK、CYP3A4和MT1G是Hub基因,生存分析显示,TTK是肝癌的关键基因,可能是HCC的候选生物标志物,或成为肝细胞癌基因治疗的靶点,验证后支持上述结果。

【关键词】肝细胞癌; 差异表达基因; 蛋白-蛋白相互作用; 富集分析; GSE84402

1 引言

原发性肝细胞癌(hepatocellular carcinoma, HCC)(以下简称肝癌)是我国发病率较高的的癌症之一,近几年发病率呈上升趋势,具有恶性程度高,进展快,转移早,发现晚,预后差的特点。因此,了解HCC早期诊断、治疗和生存预后相关基因,为制定有效诊断和治疗HCC的策略提供依据具有重大意义^[1]。

从基因层面看,肝细胞癌的发生发展是一个多基因参与的多因素多阶段的复杂过程,涉及多个信号转导通路中大量基因表达的异常^[2]。随着大数据时代的到来,人们广泛使用基因芯片技术和生物信息学的方法筛选参与HCC发生发展的关键基因,为肝癌的早期诊断和治疗带来福音。

目前虽然对HCC形成和发展的分子机制已有广泛的研究,但是肝细胞癌的关键基因尚未完全阐明,本实验选取了GSE84402数据集,对16例肝癌组织及16例相应的癌旁正常组织进行对比分析,经验证后选取具显著临床意义的基因,这可能是HCC的候选生物标志物,或成为肝细胞癌基因治疗的靶点。

2 数据的收集和预处理

2.1 HCC组织基因表达谱数据获取及差异基因筛选

本实验从GEO数据库(<http://www.ncbi.nlm.nih.gov/geo>)选取了GSE84402数据集,其中包含了16例肝癌组织及16例相应的癌旁正常组织的基因表达谱,将其分别分组为cancer组和normal组使用GEO2R在线分析工具(<http://www.ncbi.nlm.nih.gov/geo/geo2r>),以矫正后 $P < 0.01$ 和作为截取标准,进行cancer组和normal组的DEGs分析。

2.2 DEGs的GO和KEGG富集分析

在线数据库DAVID(<http://david.ncifcrf.gov>)(6.8版)是一个集生物数据和分析工具于一体的在线综合生物信息数据库,可为用户提供一套完整的基因与蛋白质功能注释信息^[3]。本研究将DEGs导入DAVID数据库(<http://david.ncifcrf.gov>)(6.8版),以人源基因为背景,进行GO功能富集分析KEGG通路分析,分析内容包括生物过程(biological process, BP)、分子功能(molecular function, MF)、细胞成分(cellular component, CC)及细胞信号转导通路。

2.3 PPI网络建设与模块分析

本研究首先将cancer组特有的DEGs上传至STRING数据库(<https://string-db.org/cgi/input.pl>)主界面获得DEGs编码的蛋白质相互作用(protein-protein interaction, PPI)网络图。然后将得到的PPI以TSV文件下载后导入Cytoscape(版本3.6.1),用MCODE插件对PPI网络进行模块分析,基于重要性程度筛选关键Hub基因。选择标准: MCODE scores > 5, degree cut-off = 2, node score cut-

off = 0.2, k-score = 2, Max depth = 100。

2.4 中枢基因的选择和分析与关键基因的验证

使用Cytoscape(版本3.6.1)的生物网络基因肿瘤学工具(BiNGO)(version 3.0.4)插件对Hub基因进行生物学过程分析并进行可视化。在cBioPortal(<https://www.cbioportal.org/>)中使用Kaplan-Meier曲线进行Hub基因的总生存期和无病生存期分析。最后利用UCLAN数据库(<http://ualcan.path.uab.edu/>)对最终确定的关键基因进行验证分析。

3 结果

3.1 肝癌中DEGs的鉴定

应用GEO2R对基因芯片GSE84402结果的标准化,鉴定出93个基因,其中下调基因68个,上调基因25个。

3.2 DEGs的KEGG和GO富集分析

对93个差异基因使用DAVID工具进行GO功能富集分析和KEGG通路富集分析。GO功能分析结果显示,DEGs的生物过程(BP)变化显著富集于有丝分裂核分裂、有丝分裂细胞周期和细胞周期过程;分子功能(MF)变化主要富集于蛋白质结合和ATP结合。KEGG路径分析显示,DEGs主要富集于药物代谢和细胞周期(如表1所示)。

表1 KEGG和GO富集分析

类别	项目	描述	数量	P值
BP	G0:0051301	cell division	9	3.7×10^{-10}
	G0:0007067	Mitotic nuclear division	7	6.9×10^{-8}
	G0:0007062	sister chromatid cohesio	6	3.3×10^{-8}
MF	G0:0042803	protein homodimerization activity	11	1.1×10^{-3}
	G0:0019899	enzyme binding	6	1.5×10^{-2}
	G0:0020037	heme binding	5	2.9×10^{-3}
	G0:0005506	iron ion binding	5	4.3×10^{-3}
KEGG	hsa05204	Chemical carcinogenesis	5	1.1×10^{-3}

3.3 PPI网络建设与模块分析和Hub基因的筛选

利用String在线网络分析工具构建DEGs的PPI网络图并用Cytoscape标注上下调基因,其中下调基因用红色标注,上调基因用蓝色标注(如图1所示),使用Cytoscape的MCODE插件得到连接度最高的三个Hub基因:TTK、CYP3A4和MT1G。

