

人类基因组中的反转录转座子*

刘新文 童坦君¹⁾ 张宗玉

(北京医科大学生物化学与分子生物学系, 北京 100083)

摘要 人类基因组中有 35% 以上的序列为转座子序列。反转录转座子是引起人类疾病的潜在病因。人类基因组中的主导转座子——L1 反转录转座子内部有二个开放读框，其编码蛋白具有 RNA 结合蛋白、反转录酶和内切酶活性。L1 可能通过靶引物反转录机制整合到染色体中；Alu 等非自主性反转录转座子可能利用 L1 反转录酶的反式互补作用进行转座。

关键词 反转录转座子, 人类基因组, 人类疾病, 反转录转座

学科分类号 Q527

通过大规模的人类基因组序列测定及序列分析，已发现人类基因组中仅有 3% 的序列为外显子序列，其余均为“无用”DNA (junk DNA，包括内含子、简单重复序列和可转移成分等)。其中可转移成分占人类基因组总序列的 35% 以上^[1~3]。

1 人类基因组中的可转移成分

根据序列构成及转座方式不同，人类基因组中的可转移成分可划分为三类：DNA 转座子、自主性反转录转座子和非自主性反转录转座子^[1]。

DNA 转座子 (DNA-based transposable elements) 与细菌转座子结构类似，两端有反向重复序列 (inverted repeats, IR)，内部有转座酶编码序列，通过剪贴 (cut and paste) 或复制 (copy and paste) 方式进行转座。在人类基因组中，DNA 转座子约占 1.6%^[4]，其中以“水手”成分 (mariner element) 最为常见。虽然人体内目前尚未发现活性的“水手”成分，Ivics 等研究结果提示人体内可能存在活性 DNA 转座子。Ivics 等^[5]根据真骨鱼类不同种间转座子转座酶同源序列的系统比较，构建了一种新的人工“水手”转座子——“睡美人” (“sleeping beauty”)。他们利用“睡美人”的转座酶序列作为辅助载体 (helper) 的成分，与重组质粒 pT/neo (含鲑鱼转座子序列 IRs 序列、启动子和报道基因 neo) 共同转化 HeLa 细胞，在 G418 筛选出的转化细胞基因组中检测出 neo 基因序列，说明 neo 基因已“剪贴”到 HeLa 细胞染色体中。

自主性反转录转座子 (autonomous retrotransposons) 内部含逆转录酶编码序列，通过 DNA-RNA-DNA 方式进行转座，即转座子转录产生相应的 RNA，再经逆转录生成新的转座子 DNA 并整合

到基因组中。根据结构中有无长末端重复序列 (long terminal repeats, LTRs)，自主性反转录转座子又可以分为二类：含 LTRs 的转座子和不含 LTRs 的转座子。人体中含量最多的 LTRs 自主性反转录转座子为人类内源性逆转录病毒 (human endogenous retroviruses, HERVs)，约占 1% ~ 2%^[6]。虽然还未发现体内 HERVs 具有反转录转座能力，但已发现 HERVs 中有些元件活性表达，提示人体内可能存在活性 HERVs。不含 LTRs 的自主性反转录转座子主要为长散布元件 (long interspersed elements, LINE)，全长 5~7 kb，称为 L1。人类基因组中有 10 万份以上的 L1，约占总序列的 15% 左右^[4]，主要分布于 A-T 富集区。L1 是进化上保守的一个超基因家族，5'、3' 端为非编码区 (untranslated region, UTR)，中间含二个开放读框 (open reading frame, ORF)。由于 95% 以上的 L1 5' 端存在缺失，其中约有 10% L1 还存在重排，因此具有序列全长及转座活性的 L1 非常少见^[4]。据估计人类基因组中约有 3000~4000 份 L1 具有全长序列，可能只有 30~60 份 L1 具有反转录转座能力。目前已发现 7 份活性 L1^[7]。

非自主性反转录转座子 (non-autonomous retrotransposons) 也通过 DNA-RNA-DNA 方式转座，但本身不能编码蛋白质，因而必须借助胞内酶才能实现转座。这类转座子序列长 100~300 bp，拷贝数达数十万份。人类基因组中的非自主性反转录转座子主要为 Alu 家族 (70 万份左右，占 10%，主要分布于 G-C 富集区) 和加工后的假基因

* 国家自然科学基金资助重点项目 (39930170)。

¹⁾ 通讯联系人。

Tel: (010) 62091454; E-mail: biochem@mail.bjmu.edu.cn

收稿日期: 1999-01-04, 修回日期: 1999-05-15

(processed pseudogenes), 结构中均无 LTR, 无编码蛋白质能力, 但 3' 端有长短不一的 poly A 尾序列^[8,9]. 据推测, Alu 等非自主性反转录转座子转座所需的胞内逆转录酶很可能由活性 L1 编码^[1,9].

鉴于人类基因组中含有丰富的反转录转座子, 1/4 以上的基因组序列来源于活性 L1 直接转座或由 L1 逆转录酶辅助 Alu 等非自主性反转录转座子转座^[4], 目前认为 L1 是人类基因组中的主导转座子 (master human mobile element)^[1].

转座子的移动与果蝇和酵母核型变化相关, 而且转座子通过特殊方式重新组织 DNA 分子, 提高生物的突变率, 因而有可能创建更好的遗传信息表达方式, 促进生物物种进化. 但转座子在进化上到底起多大作用仍然有待进一步研究^[2,3].

2 反转录转座子与人类疾病

1988 年, Kazazian 等^[10]首次证实反转录转座子是人类致病的潜在原因. 他们发现二段缺失突变的 L1 插入到凝血因子 VIII 基因中, 阻断该基因的表达, 引发了血友病 A. 随后, 相继在凝血因子 VIII 基因 (1 种)、Duchenne 型肌营养不良 (Duchenne muscular dystrophy, DMD) 基因 (3 种)、多发性结肠腺癌 (adenomatous polyposis coli, APC) 基因 (1 种) 和 β 珠蛋白基因 (1 种) 中发现了其他 6 种 L1 插入片段, 其中 5 种发生于生殖细胞或早期发育细胞, 1 种 (APC 中的 L1 片段) 发生于克隆的癌细胞, 提示 L1 反转录转座子有可能在体细胞中也起作用^[1].

L1 插入片段有以下结构特点:

- a. 各种插入片段的序列互不相同, 说明分别来源于不同的祖先;
- b. 上述 8 种插入片段中, 7 种片段 5' 端有 538 bp~3.8 kb 缺失, 1 种 (β 珠蛋白基因中的 L1) 具有全长序列 (6.0 kb), 而所有 8 种 L1 片段的开放读框 (ORF) 均完好无损, 说明插入片段可能有反转录转座活性. 目前已经发现小鼠全长序列的 L1 插入片段能够进行转座;
- c. 上述 8 种插入片段中, 7 种属于 L1 超家族中的 Ta 亚类, 表明活性 L1 可能主要来源于 Ta 亚类. Sassaman 等^[7]从人类基因库中分离出 13 个全长序列的 Ta, 其中 3 种即具有转座活性.

除 L1 外, Alu 也是人类疾病的病因之一. 1994 年, Makalowski 等^[11]从人类 DNA 序列数据库中寻找编码区中的 Alu 序列, 结果在 15 种不同

外显子中找到了 17 种插入片段, 其中 3 种为已发现的致病 Alu. 到目前为止, 至少已发现 9 种全长 Alu 插入片段与人类疾病有关. Alu 插入片段发生于生殖细胞或早期发育细胞. Alu 家族中的 Alu-Sb1 和 Alu-Sb2 亚类是活性 Alu 的主要来源^[1,11].

3 活性 L1 和 Alu 的结构

典型的活性 L1 结构如图 1a, 5'、3' 端为非编码序列 (UTR), 内部有二个开放读框 ORF1 和 ORF2. 5' UTR 含有一个内部启动子, 3' UTR 含一个非典型的加尾信号和 polyA 尾序列. 二个开放读框之间为 66 bp 的间隔序列. ORF1 序列和反转录病毒 gag 基因 (group specific antigen gene) 相似, 编码一种 RNA 结合蛋白 P40, 特异地结合于 L1RNA ORF2 的 5' 端附近. ORF2 上游序列与脱嘌呤嘧啶 (apurinic/ apyrimidinic, AP) 内切核酸酶基因相似^[12], 下游序列与反转录病毒及其他反转录转座子的逆转录酶序列同源. ORF2 蛋白是一种双功能蛋白质, 近 N 端有内切酶结构域 (EN), 近 C 端为逆转录酶结构域 (RT). 纯化的 EN 蛋白具内切酶活性, 产生 5'-PO₄、3'-OH 切割. L1 内切酶具有靶位点优先性, 优先切割 (Py)_n/ (Pu)_n 位点 ("/" 为切点), 但该酶无 AP 位点优先且转换数很低. 有趣的是, L1 逆转录酶中的大量序列与端粒酶催化亚基序列相似, 但二者间关系如何有待研究. 此外, ORF2 蛋白 (EN/RT) 也可与 L1RNA 结合^[1,7,9,12].




图 1 反转录转座子的结构
UTR: 非编码序列; TSD: 靶位点重复序列.

典型 Alu 长 282 bp, 由左右二部分同源序列组成 (图 1b), 其间为富含腺苷酸的连接区 (A-rich linker). Alu 5' 端含内部启动子, 3' 端有 polyA 尾序列. 由于左右同源序列均来自内部缺失或点突变, 因而实质上 Alu 是“获得 polyA 尾序列的 7sL RNA 假基因的二聚体”^[9,11].

4 反转录转座机理

L1 是人类基因组中的主导转座子, 其转座机

理受到广泛重视。目前认为, L1 通过 ORF 蛋白顺式结合 (*cis*-binding) 及靶引物反转录 (target-primed reverse transcription, TPRT) 机制转座, 其过程如下^[1, 9]:

a. 如图 2 所示, 活性 L1 由 5' 端内部启动子起始转录, 生成相应的双顺反子转录本 (含 ORF1 和 ORF2 的对应序列)。L1RNA 的长度及其 3' 端的

poly A 尾结构表明 L1RNA 的生成可能由 RNA 聚合酶 II 催化。此外发现转录因子 YY1 结合于内部启动子, 其功能不明。有文献报道, 分化细胞中 CpG 的甲基化可抑制转座子表达, 进而阻抑转座活性^[2, 3, 13]。因此目前认为 L1 转录仅限于低甲基化的未分化细胞, 如: 早期生殖细胞及未分化的肿瘤细胞。




图 2 L1 的转座子机理

b. L1RNA 由核内进入胞质, ORF1、ORF2 转译分别生成 P40 和 EN/RT 蛋白。P40 与 L1RNA ORF2 相应序列的 5' 端附近结合, EN/RT 蛋白可能与 L1RNA 3' 端的 poly A 尾序列结合, 形成核蛋白颗粒 (ribonucleoprotein particles, RNPs)。利用多克隆抗体很容易从未分化培养细胞和肿瘤细胞中检测出 P40, 且已经从人和小鼠细胞中分离出 P40 和 L1RNA 结合形成的 RNP。已证实在 HeLa 细胞 L1 转座中, P40、L1 内切酶活性及逆转录酶活性均起重要作用。Moran 等还发现 L1RNA 的 poly A 尾序列在 L1 转座中非常重要。

已有许多实验证明, L1 蛋白质优先与编码该蛋白质的同一 L1RNA 亲和结合, 称为顺式优先 (*cis* preference)。顺式优先允许 ORF 蛋白一边合成一边与 L1RNA 结合, 从而有利于 RNP 的形成, 提高了转座效率。同时也发现少量蛋白质可与胞内的其他 RNA 结合。在 HeLa 细胞中, 活性 L1.2 可以辅助胞内少量 mRNA 进行反转录。

c. RNP 由胞质到达靶 DNA 序列。目前还不清楚在 RNP 转运过程中是否 P40 和 ORF2 蛋白同时起重要作用; 或是 L1RNA 和 ORF2 蛋白组成

RNP, 在细胞核分裂后被动到达染色质区。由于 ORF2 蛋白难以检测, 目前还未证实核内 ORF2 蛋白的存在。

d. RNP 到达靶序列后, L1RNA 可能通过靶引物反转录生成 L1DNA 并整合到染色体中。即, 首先由 L1 内切酶切割靶位点产生 3'-OH, 然后 L1 逆转录酶以 L1RNA poly A 为模板, 从 3'-OH 开始引发反转录 (靶缺刻引发, target nick-priming), 合成 L1DNA, 新合成的 DNA 链右端与染色体 DNA 相连。已经有文献报道在体外实验中发现昆虫无 LTR 反转录转座子通过 TPRT 机制进行转座。可能由于 L1 逆转录酶的持续合成能力差 (poor processivity), 新合成的转座子 5' 端常出现缺失突变。

如上文所述, ORF 蛋白主要与 L1RNA 顺式结合, 但并不排除 ORF 蛋白与其他含 poly A 尾序列的 RNA 结合, 通过反式互补方式辅助其他 RNA 反转录形成假基因而转座^[9]。

已经发现, Alu 和 L1 在结构上有许多相似之处, 除 3' 端具有 poly A 尾序列之外, 二者末端均具有相似的靶位点重复序列 (target-site

duplications, TSDs), 提示二者由相同的内切酶参与转座。此外, Alu 侧翼序列含有保守的内切酶切点基序 (motif), 该基序与 L1 内切酶优先切割序列相似, 可能形成与 L1RNA 相似的二或三级结构, 从而与 L1 蛋白识别结合。但是低效结合的反式互补模式难以解释 Alu 在人类基因组中的拷贝数达 50~100 万份, 比 L1 的拷贝数 (1~8 万份) 还多。为此, Boeke 提出了另一种作用模式, 认为 Alu RNA 通过拓扑异构上的顺式作用与 L1 ORF2 蛋白结合而实现转座。如前所述, Alu RNA 实质上为获得 poly A 结构的 7sL RNA 二聚体, 而 7sL RNA 是信号识别颗粒 (signal recognition particle, SRP) 的重要组分。有文献报道, Alu RNA 与两种胞内 SRP 蛋白 SRP9 和 SRP14 高亲和结合 (SRP9/14 结合位点可能位于 Alu 的左侧同源区), 形成核蛋白复合物。Alu RNA 很可能借助 SRP9/14 与核蛋白体的相互作用而结合于核蛋白体大亚基的特定位置, 使 Alu RNA 的 poly A 尾得以在核蛋白体出口附近摆动, 从而以近似顺式的方式与 L1 ORF2 蛋白高效结合 (图 3)^[9]。Alu RNA 与 L1 ORF2 蛋白结合后如何转座到染色体中则可能有多种机制。Makalowski 等^[11]从数据库中找出的 17 种插入片段中, 2 种 Alu 片段经反转录直接插入基因组, 而 12 种 (71%) 证明为剪接介导 (splice-mediated events) 的插入事件, 3 种机制未明。




图 3 Alu RNA 与 L1 ORF2 蛋白结合模式

5 展望

L1 与人类疾病的关系值得重视。人类 L1 在小鼠 LTK 细胞中具有高转座活性, 因而有可能利用 L1 筛选出具有理论和实践意义的转基因小鼠。此外, L1 作为载体在基因治疗与基因转移中的作用亟待开拓。

参考文献

- Kazazian H H, Moran J V. The impact of L1 retrotransposons on the human genome. *Nature Genetics*, 1998, **19** (1): 19~24
- Kidwell M G, Lisch D R. Transposons unbound. *Nature*, 1998, **393** (6680): 22~23
- 刘新文, 童坦君. 真核生物中的基因流动现象. 生理科学进展 (Liu X W, Tong T J). *Prog Physiol Sci*, 1998, **29** (4): 324
- Smit A F. The origin of interspersed repeats in the human genome. *Curr Opin Genet Dev*, 1996, **6** (6): 743~748
- Ivics Z, Hackett P B, Plasterk R H, et al. Molecular reconstruction of Sleeping Beauty, a Tel-like transposon from fish, and its transposition in human cells. *Cell*, 1997, **91** (4): 501~510
- Lower R, Lower J, Kurth R. The viruses in all of us: characteristics and biological significance of human endogenous retrovirus sequences. *Proc Natl Acad Sci USA*, 1996, **93** (11): 5177~5184
- Sassaman D M, Dombroki B A, Moran J V, et al. Many human L1 elements are capable of retrotransposition. *Nature Genetics*, 1997, **16** (1): 37~43
- Britten R J. Evidence that most human Alu sequences were inserted in a process that ceased about 30 million years ago. *Proc Natl Acad Sci USA*, 1994, **91** (13): 6148~6150
- Boeke J D. Lines and Alu—the poly A connection. *Nature Genetics*, 1997, **16** (1): 6~7
- Kazazian H H, Wong C, Youssoufian H, et al. Hemophilia A resulting from de novo insertion of L1 sequences represents a novel mechanism for mutation in man. *Nature*, 1988, **332** (6160): 164~166
- Makalowski W, Mitchell G A, Labuda D. Alu sequences in the coding regions of mRNA: a source of protein variability. *Trends in Genetics*, 1994, **10** (6): 188~193
- Feng Q, Moran J V, Kazazian H H, et al. Human L1 retrotransposon encodes a conserved endonuclease required to retrotransposition. *Cell*, 1996, **87** (5): 905~916
- Yoder J A, Walsh C P, Bestor T H. Cytosine methylation and the ecology of intragenomic parasite. *Trends in Genetics*, 1997, **13** (8): 335~340

Human Retrotransposons. LIU Xin-Wen, TONG Tan-Jun, ZHANG Zong-Yu (Department of Biochemistry and Molecular Biology, Beijing Medical University, Beijing 100083, China).

Abstract At least 35% of the human genome is made up of transposon DNA. Retrotransposons are potential causal agents of human disease. The main human mobile element, L1 retrotransposon, has 5', 3'-UTR and two ORFs which encode a sequence-specific RNA-banding protein and a protein containing an endonuclease (EN) domain and a reverse transcriptase (RT) domain. It's likely that L1 undergoes target-primed reverse transcription in order to carry out retrotransposition. The mobilization of the non-autonomous retrotransposons, such as Alu and processed pseudogenes, require a cellular source of reverse transcriptase, which is most likely encoded by L1.

Key words retrotransposon, human genome, human disease, retrotransposition