

在UNIX服务器上设置Oracle8i全文检索 PDF转换可能丢失图片或格式，建议阅读原文

[https://www.100test.com/kao\\_ti2020/490/2021\\_2022\\_\\_E5\\_9C\\_A8UNIX\\_E6\\_9C\\_8D\\_c67\\_490669.htm](https://www.100test.com/kao_ti2020/490/2021_2022__E5_9C_A8UNIX_E6_9C_8D_c67_490669.htm) 由于工作需要，笔者在HP UX, Solaris 上面设置了Oracle Intermedia来实现全文检索。目前已经投入实际使用。设置过程中有许多问题和经验，拿来和大家交流。本文依据的是Oracle 8.1.6 和8.1.7两个版本,不能保证适用于其他版本。目前全文检索功能几乎所有主流数据库都支持。此前笔者曾在sql server 2000上实现，感觉非常简单，方便，但创建全文检索索引的时间比较长，通常要十几个小时。Oracle 的全文检索建立和维护索引都要快得多，笔者的65万记录的一个表建立索引只需要20分钟，同步一次只需要1分钟。但设置就要复杂得多。

一．设置过程

1．首先，检查你的数据库是否安装了intermedia 这可以通过检查是否有ctxsys用户和ctxapp角色(role). 如果没有这个用户和角色，意味着你的数据库创建时未安装intermedia功能。你必须修改数据库以安装这项功能。修改过程：运行

```
$ORACLE_HOME/bin/dbassist, 选择modify database, 然后在选择数据库功能时将j server 和 intermedia 都选上（安装intermedia必须同时安装jserver). 强烈建议你在做这个改动前先备份整个数据库。
```

2．设置extproc Oracle 是通过所谓的‘外部调用功能’ (external procedure)来实现intermedia的，因此正确地设置extproc是关键一步。首先要配置listener 使它能监听intermedia 调用的请求。你可以通过运行

```
$ORACLE_HOME/bin/netassit 来进行配置，也可以手工修改配置文件：$ORACLE_HOME/network/admin/listener.ora ,然
```

后重新启动listener。下面以一个例子来讲述如何手工修改配置文件。打开listener.ora文件，在修改前，通常有如下内容（假定使用缺省listener）：LISTENER = (DESCRIPTION = (ADDRESS = (PROTOCOL = TCP)(HOST = MYDATABASE)(PORT = 1521))) SID\_LIST\_LISTENER = (SID\_DESC = (GLOBAL\_DBNAME = mydatabase.world) (ORACLE\_HOME = /u01/app/oracle/product/8.1.6) (SID\_NAME = mydatabase)) 这个listener还没有配置extproc, 因此，需要为它增加对extproc的监听，办法就是分别增加description 和 sid\_desc. 修改后的listner.ora 如下：LISTENER = (DESCRIPTION\_LIST = (DESCRIPTION = (ADDRESS = (PROTOCOL = TCP)(HOST = MYDATABASE)(PORT = 1521))) (DESCRIPTION = (ADDRESS = (PROTOCOL = IPC)(KEY = EXTPROC)))) SID\_LIST\_LISTENER = (SID\_LIST = (SID\_DESC = (GLOBAL\_DBNAME = mydatabase.world) (ORACLE\_HOME = /u01/app/oracle/product/8.1.6) (SID\_NAME = mydatabase)) (SID\_DESC = (PROGRAM = extproc) (SID\_NAME = PLSExtProc) (ORACLE\_HOME = /u01/app/oracle/product/8.1.6))) 注意上面的host, global\_dbname,sid\_name,oracle\_home应填写你的数据库的实际值，但program一项必须填写extproc. 其次，要配置服务器端的tnsnames.ora文件。该文件的位置在\$ORACLE\_HOME/network/admin下面。同样可以通过运行netasst来进行配置。在tnsnames.ora文件中需要增加如下一项：

EXTPROC\_CONNECTION\_DATA,EXTPROC\_CONNECTIO

N\_DATA.WORLD = (DESCRIPTION = (ADDRESS\_LIST =  
(ADDRESS = (PROTOCOL = IPC)(KEY = EXTPROC)) )  
(CONNECT\_DATA = (SID = PLSExtProc) ) ) 注意其中，KEY  
和SID必须与listener.ora中的key和sid\_name对应相同。修改完  
成后，重新启动listener (先用lsnrctl stop, 然后 lsnrctl start), 然后  
，使用tnsping 来测试一下是否配置正确：tnsping  
extproc\_connection\_data 或者 tnsping  
extproc\_connection\_data.world,如果配置正确，会显示：  
Attempting to contact  
(ADDRESS=(PROTOCOL=IPC)(KEY=EXTPROC)) OK ( 140毫  
秒 ) 否则请检查你的上述两个文件，并注意，在修改后一定  
要重新启动listener，但并不需要重新启动数据库。3. 设置词  
法分析器(lexer) Oracle实现全文检索，其机制其实很简单。即  
通过Oracle专利的词法分析器(lexer),将文章中所有的表意单元  
( Oracle 称为 term ) 找出来，记录在一组以 dr\$开头的表中  
，同时记下该term出现的位置、次数、hash 值等信息。检索  
时，Oracle 从这组表中查找相应的 term，并计算其出现频率  
，根据某个算法来计算每个文档的得分 ( score ) ,即所谓的 ‘  
匹配率’。而lexer则是该机制的核心，它决定了全文检索的  
效率。Oracle 针对不同的语言提供了不同的 lexer, 而我们通常  
能用到其中的三个：basic\_lexer: 针对英语。它能根据空格和  
标点来将英语单词从句子中分离，还能自动将一些出现频率  
过高已经失去检索意义的单词作为 ‘垃圾’ 处理，如if, is 等  
，具有较高的处理效率。但该lexer应用于汉语则有很多问题  
，由于它只认空格和标点，而汉语的一句话中通常不会有空  
格，因此，它会把整句话作为一个term,事实上失去检索能力

。以‘中国人民站起来了’这句话为例，basic\_lexer分析的结果只有一个term,就是‘中国人民站起来了’。此时若检索‘中国’，将检索不到内容。chinese\_vgram\_lexer: 专门的汉语分析器，支持所有汉字字符集。该分析器按字为单元来分析汉语句。‘中国人民站起来了’这句话，会被它分析成如下几个term: ‘中’，‘中国’，‘国人’，‘人民’，‘民站’，‘站起’，‘起来’，‘来了’，‘了’。可以看出，这种分析方法，实现算法很简单，并且能实现‘一网打尽’，但效率则是差强人意。chinese\_lexer: 这是一个新的汉语分析器，只支持utf8字符集。上面已经看到，chinese vgram lexer这个分析器由于不认识常用的汉语词汇，因此分析的单元非常机械，像上面的‘民站’，‘站起’在汉语中根本不会单独出现，因此这种term是没有意义的，反而影响效率

。chinese\_lexer的最大改进就是该分析器能认识大部分常用汉语词汇，因此能更有效率地分析句子，像以上两个愚蠢的单元将不会再出现，极大提高了效率。但是它只支持 utf8, 如果你的数据库是zhs16gbk字符集，则只能使用笨笨的那个Chinese vgram lexer. 如果不做任何设置，Oracle 缺省使用basic\_lexer这个分析器。要指定使用哪一个lexer, 可以这样操作：第一．在ctxsys用户下建立一个preference: begin ctx\_ddl.create\_preference(my\_lexer,chinese\_vgram\_lexer). end. 第二．在建立intermedia索引时，指明所用的lexer: create index myindex on mytable(mycolumn) indextype is ctxsys.context parameters(lexer my\_lexer). 这样建立的全文检索索引，就会使用chinese\_vgram\_lexer作为分析器。4．使用job定时同步和优化 在intermedia索引建好后，如果表中的数据发生变化，比如

增加或修改了记录，怎么办？由于对表所发生的任何dml语句，都不会自动修改索引，因此，必须定时同步(sync)和优化(optimize)索引，以正确反映数据的变化。在索引建好后，我们可以在该用户下查到Oracle自动产生了以下几个表：（假设索引名为myindex）：DR\$myindex\$I，DR\$myindex\$K，DR\$myindex\$R，DR\$myindex\$N 其中以I表最重要，可以查询一下该表，看看有什么内容：0select token\_text, token\_count from DR\$I\_RSK1\$I where rownum这里就不列出查询接过了。可以看到，该表中保存的其实就是Oracle分析你的文档后，生成的term记录在这里，包括term出现的位置、次数、hash值等。当文档的内容改变后，可以想见这个I表的内容也应该相应改变，才能保证Oracle在做全文检索时正确检索到内容（因为所谓全文检索，其实核心就是查询这个表）。那么如何维护该表的内容呢？总不能每次数据改变都重新建立索引吧！这就用到sync和optimize了。同步(sync):将新的term保存到I表；优化(optimize):清除I表的垃圾，主要是将已经被删除的term从I表删除。Oracle提供了一个所谓的ctx server来做这个同步和优化的工作，只需要在后台运行这个进程，它会监视数据的变化，及时进行同步。但笔者使用ctxserver碰到了许多问题，Oracle北京的support也建议不使用，而是用以下的两个job来完成（该job要建在和表同一个用户下）：-- sync: VARIABLE jobno number. BEGIN DBMS\_JOB.SUBMIT(:jobno,ctx\_ddl.sync\_index(myindex)., SYSDATE, SYSDATE (1/24/4)). commit. END. -- optimizer VARIABLE jobno number. BEGIN DBMS\_JOB.SUBMIT(:jobno,ctx\_ddl.optimize\_index(myindex,FU

LL)., SYSDATE, SYSDATE 1). commit. END. 其中，第一个job的SYSDATE (1/24/4)是指每隔15分钟同步一次，第二个job的SYSDATE 1是每隔1天做一次全优化。具体的时间间隔，你可以根据自己应用的需要而定。至此，你的全文检索功能已设置完成。 100Test 下载频道开通，各类考试题目直接下载。详细请访问 [www.100test.com](http://www.100test.com)