



罗炳森 黄超 钟饶 著

SQL

优化核心思想

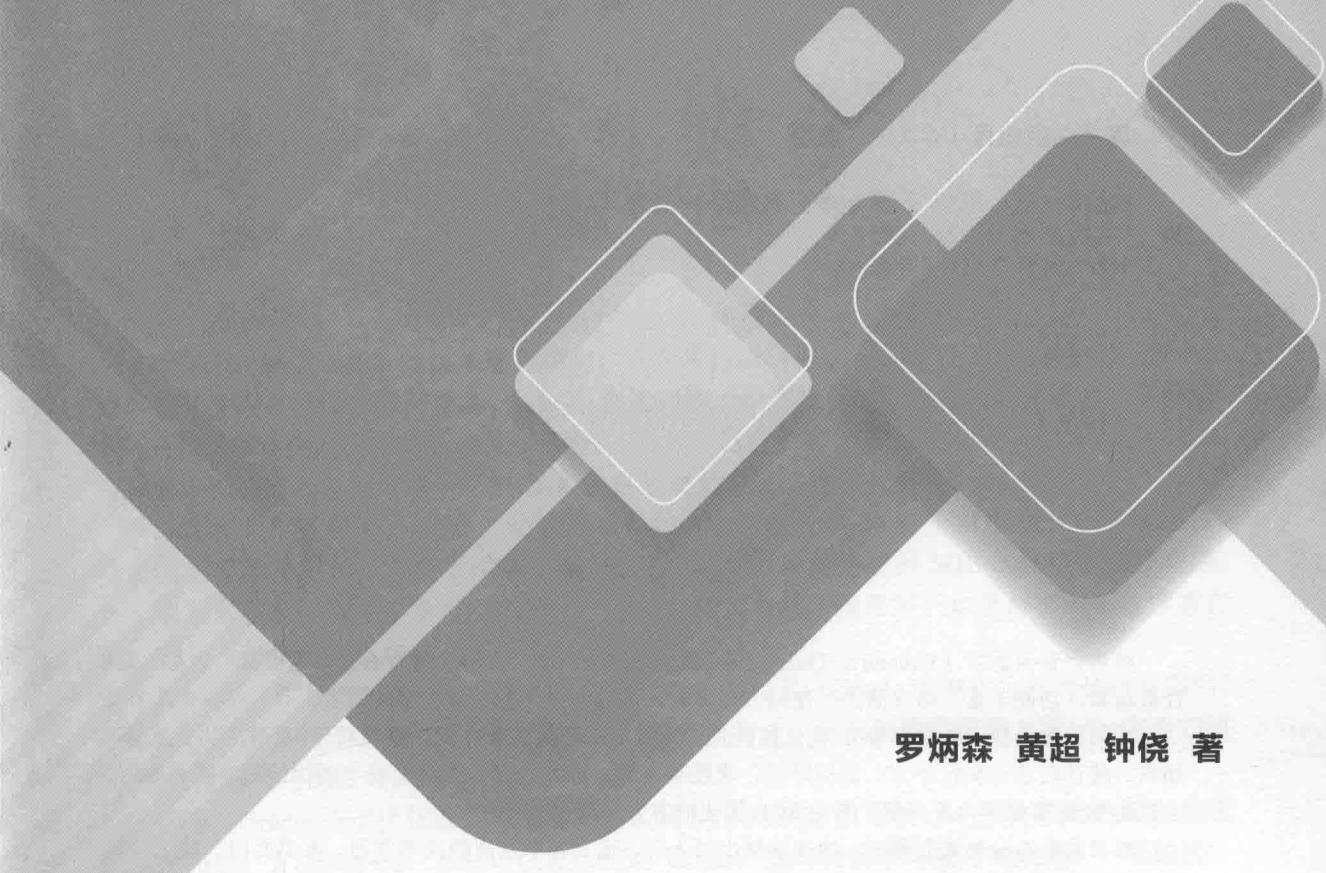
本书内容源自“道森起点”高级SQL优化实战班
专业团队倾力打造，集多年SQL **优化实战经验和专职教学经验**于一体



中国工信出版集团



人民邮电出版社
POSTS & TELECOM PRESS



罗炳森 黄超 钟饶 著

SQL

优化核心思想

人民邮电出版社
北京

图书在版编目 (C I P) 数据

SQL优化核心思想 / 罗炳森, 黄超, 钟饶著. — 北京 : 人民邮电出版社, 2018. 4
ISBN 978-7-115-47849-8

I. ①S… II. ①罗… ②黄… ③钟… III. ①SQL语言
IV. ①TP311. 138

中国版本图书馆CIP数据核字(2018)第019196号

内 容 提 要

结构化查询语言 (Structured Query Language, SQL) 是一种功能强大的数据库语言。它基于关系代数运算, 功能丰富、语言简洁、使用方便灵活, 已成为关系数据库的标准语言。

本书旨在引导读者掌握 SQL 优化技能, 以更好地提升数据库性能。本书共分 10 章, 从 SQL 基础知识、统计信息、执行计划、访问路径、表连接方式、成本计算、查询变换、调优技巧、经典案例、全自动 SQL 审核等角度介绍了有关 SQL 优化的方方面面。

本书基于 Oracle 进行编写, 内容讲解由浅入深, 适合各个层次的读者学习。本书面向一线工程师、运维工程师、数据库管理员以及系统设计与开发人员, 无论是初学者还是有一定基础的读者, 都将从中获益。

◆ 著	罗炳森 黄超 钟饶
责任编辑	胡俊英
责任印制	焦志炜
◆ 人民邮电出版社出版发行	北京市丰台区成寿寺路 11 号
邮编 100164	电子邮件 315@ptpress.com.cn
网址 http://www.ptpress.com.cn	
三河市君旺印务有限公司印刷	
◆ 开本:	800×1000 1/16
印张:	20
字数:	445 千字
印数:	1—2 400 册
	2018 年 4 月第 1 版
	2018 年 4 月河北第 1 次印刷

定价: 79.00 元

读者服务热线: (010) 81055410 印装质量热线: (010) 81055316

反盗版热线: (010) 81055315

广告经营许可证: 京东工商广登字 20170147 号

前　　言

近年来，随着系统的数据量逐年增加，并发量也成倍增长，SQL 性能越来越成为 IT 系统设计和开发时首要考虑的问题之一。SQL 性能问题已经逐步发展成为数据库性能的首要问题，80% 的数据库性能问题都是因 SQL 而导致。面对日益增多的 SQL 性能问题，如何下手以及如何提前审核已经成为越来越多的 IT 从业者必须要考虑的问题。

现在将 8 年专职 SQL 优化的经验和心得与大家一起分享，以揭开 SQL 优化的神秘面纱，让一线工程师在实际开发中不再寝食难安、谈虎色变，最终能够对 SQL 优化技能驾轻就熟。

编写本书也是对多年学习积累的一个总结，鞭策自己再接再厉。如果能够给各位读者在 SQL 优化上提供一点帮助，也不枉个中辛苦。

2014 年，作者罗炳森与有教无类（网名）联合编写了《Oracle 查询优化改写技巧与案例》一书，该书主要侧重于 SQL 优化改写技巧。到目前为止，该书仍然是市面上唯一一本专门讲解 SQL 改写技巧的图书。

因为《Oracle 查询优化改写技巧与案例》只专注于 SQL 改写技巧，并没有涉及 SQL 优化的具体思想、方法和步骤，本书可以看作是对《Oracle 查询优化改写技巧与案例》一书的进一步补充。

本书共 10 章，各章的主要内容如下。

第 1 章详细介绍了 SQL 优化的基础知识以及初学者切实需要掌握的基本内容，本章可以帮助初学者快速入门。

第 2 章详细讲解统计信息定义、统计信息的重要性、统计信息相关参数设置方案以及统计信息收集策略。

第 3 章详细讲解执行计划、各种执行计划的使用场景以及执行计划的阅读方法，通过定制执行计划，读者可以快速找出 SQL 性能瓶颈。

第 4 章详细讲解常见的访问路径，这是阅读执行计划中比较重要的环节，需要掌握各种常见的访问路径。

第 5 章详细讲解表的各种连接方式、各种表连接方式的等价改写以及相互转换，这也是本书的核心章节。

第 6 章介绍单表访问以及索引扫描的成本计算方法，并由此引出 SQL 优化的核心思想。

第 7 章讲解常见的查询变换，分别是子查询非嵌套、视图合并和谓词推入。如果要对复杂的 SQL（包含各种子查询的 SQL）进行优化，读者就必须掌握查询变换技巧。

第 8 章讲解各种优化技巧，其中涵盖分页语句优化思想、分析函数减少表扫描次数、超大表与超大表关联优化方法、dblink 优化思路，以及大表的 rowid 切片优化技巧。掌握这些调优技巧往往能够事半功倍。

第 9 章分享在 SQL 优化实战中遇到的经典案例，读者可以在欣赏 SQL 优化案例的同时学习罗老师多年专职 SQL 优化的经验，同时学到很多具有实战意义的优化思想以及优化方法与技巧。

第 10 章讲解全自动 SQL 审核，将有性能问题的 SQL 扼杀在“摇篮”里，确保系统上线之后，不会因为 SQL 写法导致性能问题，同时还能抓出不符合 SQL 编码规范但是已经上线的 SQL。

本书对系统面临性能压力挑战的一线工程师、运维工程师、数据库管理员（DBA）、系统设计与开发人员，具有极大的参考价值。

为了满足不同层次的读者需求，本书在写作的内容上尽量由浅入深，前 5 章比较浅显易懂，适合 SQL 优化初学者阅读。通读完前 5 章之后，初学者能够对 SQL 优化有一定认识。后 5 章属于进阶和高级内容，适合有一定基础的人阅读。通读完后 5 章的内容之后，无论是初学者或是有一定基础的读者都能从中获益良多。

本书专注于 SQL 优化技巧，因此书中不会涉及太多数据库系统优化的内容。

虽然本书是基于 Oracle 编写的，但是关系型数据库的优化方法都殊途同归，因此无论是 DB2 从业者、SQL SERVER 从业者、MYSQL 从业者，亦或是 PostGre SQL 从业者等，都能从本书中学到所需要的 SQL 优化知识。

因水平有限，本书在编写过程中难免有错漏之处，恳请读者批评、指正。联系我们的方法如下：692162374@qq.com（QQ 好友数已达上限）或者 327165427@qq.com（新开 QQ 账号）。

如果有读者想进一步学习 SQL 优化技能或者一些公司或机构需要开展 SQL 优化方面的培训，都可以联系作者。另外，作者还开设了实体培训班，可以实现零基础学习，结业后可以顺利就业，欢迎联系罗老师。

本书约定

在阅读本书之前请读者安装好 Oracle 数据库并且配置好示例账户 Scott，因为本书均以 Scott 账户进行讲解。推荐读者安装与本书相同版本的数据库进行测试，具有专研精神的读者请安装好 Oracle12c 进行对比实验，这样一来，你将发现 Oracle12c CBO 的一些新特征。本书使用的版本是 Oracle11gR2。

```
SQL> select * from v$version where rownum=1;
BANNER
-----
Oracle Database 11g Enterprise Edition Release 11.2.0.1.0 - Production
SQL> show user
USER is "SYS"
SQL> grant dba to scott;
Grant succeeded.
SQL> alter user scott account unlock;
User altered.
SQL> alter user scott identified by tiger;
User altered.
SQL> conn scott/tiger
Connected.
SQL> create table test as select * from dba_objects;
Table created.
```

目 录

第 1 章 SQL 优化必懂概念	1
1.1 基数 (CARDINALITY)	1
1.2 选择性 (SELECTIVITY)	3
1.3 直方图 (HISTOGRAM)	7
1.4 回表 (TABLE ACCESS BY INDEX ROWID)	13
1.5 集群因子 (CLUSTERING FACTOR)	15
1.6 表与表之间关系	19
第 2 章 统计信息	21
2.1 什么是统计信息	21
2.2 统计信息重要参数设置	24
2.3 检查统计信息是否过期	32
2.4 扩展统计信息	37
2.5 动态采样	42
2.6 定制统计信息收集策略	47
第 3 章 执行计划	49
3.1 获取执行计划常用方法	49
3.1.1 使用 AUTOTRACE 查看执行计划	49
3.1.2 使用 EXPLAIN PLAN FOR 查看执行计划	52
3.1.3 查看带有 A-TIME 的执行计划	54
3.1.4 查看正在执行的 SQL 的执行计划	56
3.2 定制执行计划	57
3.3 怎么通过查看执行计划建立索引	59
3.4 运用光标移动大法阅读执行计划	63
第 4 章 访问路径 (ACCESS PATH)	67
4.1 常见访问路径	67
4.1.1 TABLE ACCESS FULL	67
4.1.2 TABLE ACCESS BY USER ROWID	71
4.1.3 TABLE ACCESS BY ROWID RANGE	71
4.1.4 TABLE ACCESS BY INDEX ROWID	72
4.1.5 INDEX UNIQUE SCAN	72
4.1.6 INDEX RANGE SCAN	73
4.1.7 INDEX SKIP SCAN	74
4.1.8 INDEX FULL SCAN	75
4.1.9 INDEX FAST FULL SCAN	77
4.1.10 INDEX FULL SCAN (MIN/MAX)	80
4.1.11 MAT_VIEW REWRITE ACCESS FULL	83
4.2 单块读与多块读	83
4.3 为什么有时候索引扫描比全表扫描更慢	84
4.4 DML 对于索引维护的影响	84
第 5 章 表连接方式	86
5.1 嵌套循环 (NESTED LOOPS)	86
5.2 HASH 连接 (HASH JOIN)	90
5.3 排序合并连接 (SORT MERGE JOIN)	93
5.4 笛卡儿连接 (CARTESIAN JOIN)	95
5.5 标量子查询 (SCALAR SUBQUERY)	98
5.6 半连接 (SEMI JOIN)	100
5.6.1 半连接等价改写	100
5.6.2 控制半连接执行计划	101
5.6.3 读者思考	103
5.7 反连接 (ANTI JOIN)	104
5.7.1 反连接等价改写	104

5.7.2 控制反连接执行计划	105	9.7 ORDER BY 取别名列优化案例	183
5.7.3 读者思考	108	9.8 半连接反向驱动主表案例一	185
5.8 FILTER	108	9.9 半连接反向驱动主表案例二	187
5.9 IN 与 EXISTS 谁快谁慢	111	9.10 连接列数据分布不均衡导致性能问题	192
5.10 SQL 语句的本质	111	9.11 Filter 优化经典案例	198
第 6 章 成本计算	112	9.12 树形查询优化案例	202
6.1 优化 SQL 需要看 COST 吗	112	9.13 本地索引优化案例	204
6.2 全表扫描成本计算	112	9.14 标量子查询优化案例	206
6.3 索引范围扫描成本计算	116	9.14.1 案例一	206
6.4 SQL 优化核心思想	119	9.14.2 案例二	207
第 7 章 必须掌握的查询变换	120	9.15 关联更新优化案例	211
7.1 子查询非嵌套	120	9.16 外连接有 OR 关联条件只能走 NL	213
7.2 视图合并	125	9.17 把你脑袋当 CBO	217
7.3 谓词推入	129	9.18 扩展统计信息优化案例	221
第 8 章 调优技巧	133	9.19 使用 LISGAGG 分析函数优化 WMSYS.WM_CONCAT	227
8.1 查看真实的基数 (Rows)	133	9.20 INSTR 非等值关联优化案例	230
8.2 使用 UNION 代替 OR	134	9.21 REGEXP_LIKE 非等值关联优化案例	233
8.3 分页语句优化思路	135	9.22 ROW LEVEL SECURITY 优化案例	237
8.3.1 单表分页优化思路	135	9.23 子查询非嵌套优化案例一	240
8.3.2 多表关联分页优化思路	150	9.24 子查询非嵌套优化案例二	247
8.4 使用分析函数优化自连接	153	9.25 烂用外连接导致无法谓词推入	252
8.5 超大表与超小表关联优化方法	154	9.26 谓词推入优化案例	262
8.6 超大表与超大表关联优化方法	155	9.27 使用 CARDINALITY 优化 SQL	268
8.7 LIKE 语句优化方法	159	9.28 利用等待事件优化 SQL	272
8.8 DBLINK 优化	161		
8.9 对表进行 ROWID 切片	167		
8.10 SQL 三段分拆法	169		
第 9 章 SQL 优化案例赏析	170	第 10 章 全自动 SQL 审核	281
9.1 组合索引优化案例	170	10.1 抓出外键没创建索引的表	281
9.2 直方图优化案例	173	10.2 抓出需要收集直方图的列	282
9.3 NL 被驱动表不能走 INDEX SKIP SCAN	177	10.3 抓出必须创建索引的列	283
9.4 优化 SQL 需要注意表与表之间关系	178	10.4 抓出 SELECT * 的 SQL	284
9.5 INDEX FAST FULL SCAN 优化案例	179	10.5 抓出有标量子查询的 SQL	285
9.6 分页语句优化案例	181	10.6 抓出带有自定义函数的 SQL	286

10.10 抓出 NL 被驱动表走了全表 扫描的 SQL.....	292
10.11 抓出走了 TABLE ACCESS FULL 的 SQL.....	293
10.12 抓出走了 INDEX FULL SCAN 的 SQL.....	294
10.13 抓出走了 INDEX SKIP SCAN 的 SQL.....	295
10.14 抓出索引被哪些 SQL 引用	297
10.15 抓出走了笛卡儿积的 SQL	298
10.16 抓出走了错误的排序合并连接 的 SQL	299
10.17 抓出 LOOP 套 LOOP 的 PSQL.....	301
10.18 抓出走了低选择性索引的 SQL.....	302
10.19 抓出可以创建组合索引的 SQL (回表再过滤选择性高的列)	304
10.20 抓出可以创建组合索引的 SQL (回表只访问少数字段)	306

第1章 SQL 优化必懂概念

1.1

基数 (CARDINALITY)

某个列唯一键 (Distinct_Keys) 的数量叫作基数。比如性别列, 该列只有男女之分, 所以这一列基数是 2。主键列的基数等于表的总行数。基数的高低影响列的数据分布。

以测试表 test 为例, owner 列和 object_id 列的基数分别如下所示。

```
SQL> select count(distinct owner),count(distinct object_id),count(*) from test;
COUNT(DISTINCTOWNER) COUNT(DISTINCTOBJECT_ID) COUNT(*)
----- ----- -----
      29          72462        72462
```

TEST 表的总行数为 72 462, owner 列的基数为 29, 说明 owner 列里面有大量重复值, object_id 列的基数等于总行数, 说明 object_id 列没有重复值, 相当于主键。owner 列的数据分布如下。

```
SQL> select owner,count(*) from test group by owner order by 2 desc;
```

OWNER	COUNT (*)
SYS	30808
PUBLIC	27699
SYSMAN	3491
ORDSYS	2532
APEX_030200	2406
MDSYS	1509
XDB	844
OLAPSYS	719
SYSTEM	529
CTXSYS	366
WMSYS	316
EXFSYS	310
SH	306
ORDDATA	248
OE	127
DBSNMP	57
IX	55
HR	34
PM	27
FLWS_FILES	12
OWBSYS_AUDIT	12
ORDPLUGINS	10
OUTLN	9
BI	8
SI_INFORMTN_SCHEMA	8
ORACLE_OCM	8
SCOTT	7

APPQOSSYS	3
OWBSYS	2

owner列的数据分布极不均衡，我们运行如下SQL。

```
| select * from test where owner='SYS';
```

SYS有30 808条数据，从72 462条数据里面查询30 808条数据，也就是说要返回表中42.5%的数据。

```
| SQL> select 30808/72462*100 "Percent" from dual;
```

Percent
42.5160774

那么请思考，你认为以上查询应该使用索引吗？现在我们换一种查询语句。

```
| select * from test where owner='SCOTT';
```

SCOTT有7条数据，从72 462条数据里面查询7条数据，也就是说要返回表中0.009%的数据。

```
| SQL> select 7/72462*100 "Percent" from dual;
```

Percent
.009660236

请思考，返回表中0.009%的数据应不应该走索引？

如果你还不懂索引，没关系，后面的章节我们会详细介绍。如果你回答不了上面的问题，我们先提醒一下。当查询结果是返回表中5%以内的数据时，应该走索引；当查询结果返回的是超过表中5%的数据时，应该走全表扫描。

当然了，返回表中5%以内的数据走索引，返回超过5%的数据就使用全表扫描，这个结论太绝对了，因为你还没掌握后面章节的知识，这里暂且记住5%这个界限就行。我们之所以在这里讲5%，是怕一些初学者不知道上面问题的答案而纠结。

现在有如下查询语句。

```
| select * from test where owner=:B1;
```

语句中，“:B1”是绑定变量，可以传入任意值，该查询可能走索引也可能走全表扫描。

现在得到一个结论：如果某个列基数很低，该列数据分布就会非常不均衡，由于该列数据分布不均衡，会导致SQL查询可能走索引，也可能走全表扫描。在做SQL优化的时候，如果怀疑列数据分布不均衡，我们可以使用select列，count(*) from 表 group by 列 order by 2 desc来查看列的数据分布。

如果SQL语句是单表访问，那么可能走索引，可能走全表扫描，也可能走物化视图扫描。在不考虑有物化视图的情况下，单表访问要么走索引，要么走全表扫描。现在，回忆一下走索引的条件：返回表中5%以内的数据走索引，超过5%的时候走全表扫描。相信大家读到这里，已经搞懂了单表访问的优化方法。

我们来看如下查询。

```
select * from test where object_id=:B1;
```

不管 object_id 传入任何值，都应该走索引。

我们再思考如下查询语句。

```
select * from test where object_name=:B1;
```

不管给 object_name 传入任何值，请问该查询应该走索引吗？

请你去查看 object_name 的数据分布。写到这里，其实有点想把本节名称改为“数据分布”。大家在以后的工作中一定要注意列的数据分布！

1.2 选择性 (SELECTIVITY)

基数与总行数的比值再乘以 100% 就是某个列的选择性。

在进行 SQL 优化的时候，单独看列的基数是没有意义的，基数必须对比总行数才有实际意义，正是因为这个原因，我们才引出了选择性这个概念。

下面我们查看 test 表各个列的基数与选择性，为了查看选择性，必须先收集统计信息。关于统计信息，我们在第 2 章会详细介绍。下面的脚本用于收集 test 表的统计信息。

```
SQL> BEGIN
 2   DBMS_STATS.GATHER_TABLE_STATS(ownname          => 'SCOTT',
 3                                   tabname           => 'TEST',
 4                                   estimate_percent => 100,
 5                                   method_opt       => 'for all columns size 1',
 6                                   no_invalidate    => FALSE,
 7                                   degree           => 1,
 8                                   cascade          => TRUE);
 9 END;
10 /
PL/SQL procedure successfully completed.
```

下面的脚本用于查看 test 表中每个列的基数与选择性。

```
SQL> select a.column_name,
 2        b.num_rows,
 3        a.num_distinct Cardinality,
 4        round(a.num_distinct / b.num_rows * 100, 2) selectivity,
 5        a.histogram,
 6        a.num_buckets
 7     from dba_tab_col_statistics a, dba_tables b
 8    where a.owner = b.owner
 9      and a.table_name = b.table_name
10     and a.owner = 'SCOTT'
11     and a.table_name = 'TEST';
```

COLUMN_NAME	NUM_ROWS	CARDINALITY	SELECTIVITY	HISTOGRAM	NUM_BUCKETS
OWNER	72462	29	.04	NONE	1
OBJECT_NAME	72462	44236	61.05	NONE	1
SUBOBJECT_NAME	72462	106	.15	NONE	1
OBJECT_ID	72462	72462	100	NONE	1

DATA_OBJECT_ID	72462	7608	10.5	NONE	1
OBJECT_TYPE	72462	44	.06	NONE	1
CREATED	72462	1366	1.89	NONE	1
LAST_DDL_TIME	72462	1412	1.95	NONE	1
TIMESTAMP	72462	1480	2.04	NONE	1
STATUS	72462	1	0	NONE	1
TEMPORARY	72462	2	0	NONE	1
GENERATED	72462	2	0	NONE	1
SECONDARY	72462	2	0	NONE	1
NAMESPACE	72462	21	.03	NONE	1
EDITION_NAME	72462	0	0	NONE	0

15 rows selected.

请思考：什么样的列必须建立索引呢？

有人说基数高的列，有人说在 where 条件中的列。这些答案并不完美。基数高究竟是多高？没有和总行数对比，始终不知道有多高。比如某个列的基数有几万行，但是总行数有几十亿行，那么这个列的基数还高吗？这就是要引出选择性的根本原因。

当一个列选择性大于 20%，说明该列的数据分布就比较均衡了。测试表 test 中 object_name、object_id 的选择性均大于 20%，其中 object_name 列的选择性为 61.05%。现在我们查看该列数据分布（为了方便展示，只输出前 10 行数据的分布情况）。

```
SQL> select *
  2    from (select object_name, count(*)
  3           from test
  4          group by object_name
  5          order by 2 desc)
  6   where rownum <= 10;
```

OBJECT_NAME	COUNT(*)
COSTS	30
SALES	30
SALES_CHANNEL_BIX	29
COSTS_TIME_BIX	29
COSTS_PROD_BIX	29
SALES_TIME_BIX	29
SALES_PROMO_BIX	29
SALES_PROD_BIX	29
SALES_CUST_BIX	29
DBMS_REPCAT_AUTH	5

10 rows selected.

由上面的查询结果我们可知，object_name 列的数据分布非常均衡。我们查询以下 SQL。

```
select * from test where object_name=:B1;
```

不管 object_name 传入任何值，最多返回 30 行数据。

什么样的列必须要创建索引呢？当一个列出现在 where 条件中，该列没有创建索引并且选择性大于 20%，那么该列就必须创建索引，从而提升 SQL 查询性能。当然了，如果表只有几百条数据，那我们就不用创建索引了。

下面抛出 SQL 优化核心思想第一个观点：只有大表才会产生性能问题。

也许有人会说：“我有个表很小，只有几百条，但是该表经常进行 DML，会产生热点块，

也会出性能问题。”对此我们并不想过多地讨论此问题，这属于应用程序设计问题，不属于 SQL 优化的范畴。

下面我们将通过实验为大家分享本书第一个全自动优化脚本。

抓出必须创建索引的列 (请读者对该脚本适当修改,以便用于生产环境)。

首先,该列必须出现在 where 条件中,怎么抓出表的哪个列出现在 where 条件中呢?有两种方法,一种是可以通过 V\$SQL_PLAN 抓取,另一种是通过下面的脚本抓取。

先执行下面的存储过程,刷新数据库监控信息。

```
begin
  dbms_stats.flush_database_monitoring_info;
end;
```

运行完上面的命令之后,再运行下面的查询语句就可以查询出哪个表的哪个列出现在 where 条件中。

```
select r.name owner,
       o.name table_name,
       c.name column_name,
       equality_preds, ---等值过滤
       equijoin_preds, ---等值 JOIN 比如 where a.id=b.id
       nonequijoin_preds, ----不等 JOIN
       range_preds, ----范围过滤次数 > = < <= between and
       like_preds, ----LIKE 过滤
       null_preds, ----NULL 过滤
       timestamp
  from sys.col_usage$ u, sys.obj$ o, sys.col$ c, sys.user$ r
 where o.obj# = u.obj#
   and c.obj# = u.obj#
   and c.col# = u.intcol#
   and r.name = 'SCOTT'
   and o.name = 'TEST';
```

下面是实验步骤。

我们首先运行一个查询语句,让 owner 与 object_id 列出现在 where 条件中。

```
SQL> select object_id, owner, object_type
  2    from test
  3   where owner = 'SYS'
  4     and object_id < 100
  5     and rownum <= 10;
```

OBJECT_ID	OWNER	OBJECT_TYPE
20	SYS	TABLE
46	SYS	INDEX
28	SYS	TABLE
15	SYS	TABLE
29	SYS	CLUSTER
3	SYS	INDEX
25	SYS	TABLE
41	SYS	INDEX
54	SYS	INDEX
40	SYS	INDEX

10 rows selected.

其次刷新数据库监控信息。

```
SQL> begin
 2   dbms_stats.flush_database_monitoring_info;
 3 end;
4 /
```

PL/SQL procedure successfully completed.

然后我们查看 test 表有哪些列出现在 where 条件中。

```
SQL> select r.name owner, o.name table_name, c.name column_name
 2   from sys.col_usage$ u, sys.obj$ o, sys.col$ c, sys.user$ r
 3   where o.obj# = u.obj#
 4     and c.obj# = u.obj#
 5     and c.col# = u.intcol#
 6     and r.name = 'SCOTT'
 7     and o.name = 'TEST';
```

OWNER	TABLE_NAME	COLUMN_NAME
SCOTT	TEST	OWNER
SCOTT	TEST	OBJECT_ID

接下来我们查询出选择性大于等于 20% 的列。

```
SQL> select a.owner,
 2       a.table_name,
 3       a.column_name,
 4       round(a.num_distinct / b.num_rows * 100, 2) selectivity
 5   from dba_tab_col_statistics a, dba_tables b
 6  where a.owner = b.owner
 7    and a.table_name = b.table_name
 8    and a.owner = 'SCOTT'
 9    and a.table_name = 'TEST'
10    and a.num_distinct / b.num_rows >= 0.2;
```

OWNER	TABLE_NAME	COLUMN_NAME	SELECTIVITY
SCOTT	TEST	OBJECT_NAME	61.05
SCOTT	TEST	OBJECT_ID	100

最后，确保这些列没有创建索引。

```
SQL> select table_owner, table_name, column_name, index_name
 2   from dba_ind_columns
 3  where table_owner = 'SCOTT'
 4    and table_name = 'TEST';
未选定行
```

把上面的脚本组合起来，我们就可以得到全自动的优化脚本了。

```
SQL> select owner,
 2       column_name,
 3       num_rows,
 4       Cardinality,
 5       selectivity,
 6       'Need index' as notice
 7   from (select b.owner,
 8             a.column_name,
 9             b.num_rows,
```

```

10          a.num_distinct Cardinality,
11          round(a.num_distinct / b.num_rows * 100, 2) selectivity
12      from dba_tab_col_statistics a, dba_tables b .
13      where a.owner = b.owner
14      and a.table_name = b.table_name
15      and a.owner = 'SCOTT'
16      and a.table_name = 'TEST')
17  where selectivity >= 20
18  and column_name not in (select column_name
19                      from dba_ind_columns
20                      where table_owner = 'SCOTT'
21                      and table_name = 'TEST')
22  and column_name in
23  (select c.name
24    from sys.col_usage$ u, sys.obj$ o, sys.col$ c, sys.user$ r
25   where o.obj# = u.obj#
26   and c.obj# = u.obj#
27   and c.col# = u.intcol#
28   and r.name = 'SCOTT'
29   and o.name = 'TEST');

OWNER      COLUMN_NAME      NUM_ROWS CARDINALITY SELECTIVITY NOTICE
-----      -----      -----
SCOTT      OBJECT_ID        72462      72462      100 Need index

```

1.3 直方图 (HISTOGRAM)

前面提到，当某个列基数很低，该列数据分布就会不均衡。数据分布不均衡会导致在查询该列的时候，要么走全表扫描，要么走索引扫描，这个时候很容易走错执行计划。

如果没有对基数低的列收集直方图统计信息，基于成本的优化器 (CBO) 会认为该列数据分布是均衡的。

下面我们还是以测试表 test 为例，用实验讲解直方图。

首先我们对测试表 test 收集统计信息，在收集统计信息的时候，不收集列的直方图，语句 for all columns size 1 表示对所有列都不收集直方图。

```

SQL> BEGIN
 2      DBMS_STATS.GATHER_TABLE_STATS(ownname      => 'SCOTT',
 3                                      tabname       => 'TEST',
 4                                      estimate_percent => 100,
 5                                      method_opt     => 'for all columns size 1',
 6                                      no_invalidate => FALSE,
 7                                      degree        => 1,
 8                                      cascade        => TRUE);
 9  END;
10 /

```

PL/SQL procedure successfully completed.

Histogram 为 none 表示没有收集直方图。

```

SQL> select a.column_name,
 2      b.num_rows,
 3      a.num_distinct Cardinality,
 4      round(a.num_distinct / b.num_rows * 100, 2) selectivity,
 5      a.histogram,

```

```

6      a.num_buckets
7  from dba_tab_col_statistics a, dba_tables b
8  where a.owner = b.owner
9  and a.table_name = b.table_name
10 and a.owner = 'SCOTT'
11 and a.table_name = 'TEST';

```

COLUMN_NAME	NUM_ROWS	CARDINALITY	SELECTIVITY	HISTOGRAM	NUM_BUCKETS
OWNER	72462	29	.04	NONE	1
OBJECT_NAME	72462	44236	61.05	NONE	1
SUBOBJECT_NAME	72462	106	.15	NONE	1
OBJECT_ID	72462	72462	100	NONE	1
DATA_OBJECT_ID	72462	7608	10.5	NONE	1
OBJECT_TYPE	72462	44	.06	NONE	1
CREATED	72462	1366	1.89	NONE	1
LAST_DDL_TIME	72462	1412	1.95	NONE	1
TIMESTAMP	72462	1480	2.04	NONE	1
STATUS	72462	1	0	NONE	1
TEMPORARY	72462	2	0	NONE	1
GENERATED	72462	2	0	NONE	1
SECONDARY	72462	2	0	NONE	1
NAMESPACE	72462	21	.03	NONE	1
EDITION_NAME	72462	0	0	NONE	0

15 rows selected.

owner 列基数很低，现在我们对 owner 列进行查询。

```

SQL> set autot trace
SQL> select * from test where owner='SCOTT';
7 rows selected.

```

Execution Plan

Plan hash value: 1357081020

Id	Operation	Name	Rows	Bytes	Cost (%CPU)	Time
0	SELECT STATEMENT		2499	236K	289 (1)	00:00:04
* 1	TABLE ACCESS FULL	TEST	2499	236K	289 (1)	00:00:04

Predicate Information (identified by operation id):

```
1 - filter("OWNER"='SCOTT')
```

请注意看粗体字部分，查询 owner='SCOTT' 返回了 7 条数据，但是 CBO 在计算 **Rows** 的时候认为 owner='SCOTT' 返回 **2 499** 条数据，Rows 估算得不是特别准确。从 72 462 条数据里面查询出 7 条数据，应该走索引，所以现在我们对 owner 列创建索引。

```
SQL> create index idx_owner on test(owner);
```

Index created.

我们再来查询一下。