友乾营

专注数据技术的社群

分库后的查询统计

14 期

www.raqsoft.com.cn/yqy

目录 CONTENTS

友乾营

专注数据技术的社群

分库的概念

友乾营

分库通常会遵循一定规则，目的是将数据尽可能地均匀分布在不同库中

举例：n个MySQL数据库， 1号库存放2013年销售数据，2号库存放2014年销售数据，...,n号库存放2012+n年的销售数据，如下所示：

CLIENT	SELLERID	AMOUNT	ORDERDATE
FHYBR	17	12000.0	2013-12-28 15:28:05
HANAR	16	4312.0	2013-12-28 15:28:05
YZ	14	19100.0	2013-12-28 15:28:05
MIP	10	5390.0	2013-12-29 15:28:05
AVU	2	27000.0	2013-12-30 15:28:05
VILJX	9	19700.0	2013-12-31 15:28:05
PJIPE	12	7840.0	2013-12-31 15:28:05

1号库（2013年）
销售数据

CLIENT	SELLERID	AMOUNT	ORDERDATE
JOPO	9	392.0	2014-01-01 15:28:05
AYWYN	13	25800.0	2014-01-04 15:28:05
PJIPE	14	29400.0	2014-01-05 15:28:05
DNEDL	10	24200.0	2014-01-07 15:28:05
HANAR	18	7252.0	2014-01-08 15:28:05
SAVEA	8	11600.0	2014-01-09 15:28:05
PJIPE	10	7742.0	2014-01-12 15:28:05
SAVEA	15	19900.0	2014-01-12 15:28:05

2号库（2014年）
销售数据

.....

n号库（2012+n年）
销售数据

友乾营

各分库表过滤后的结果纵向连接

举例：n个库的销售数据表，查询单笔销售额大于500的所有订单记录

1号库（2013年）
销售额大于500

CLIENT	SELLERID	AMOUNT	ORDERDATE
FHYBR	5	29700.0	2013-04-05 15:28:05
QUICK	6	29700.0	2013-11-04 15:28:05
YZ	8	29600.0	2013-01-06 15:28:05
FHYBR	2	29400.0	2013-08-19 15:28:05
SJCH	18	29100.0	2013-05-29 15:28:05
BTMMU	16	29100.0	2013-11-13 15:28:05
SAVEA	7	28900.0	2013-03-23 15:28:05

2号库（2014年）
销售额大于500

CLIENT	SELLERID	AMOUNT	ORDERDATE
AYWYN	13	25800.0	2014-01-04 15:28:05
PJIPE	14	29400.0	2014-01-05 15:28:05
DNEDL	10	24200.0	2014-01-07 15:28:05
HANAR	18	7252.0	2014-01-08 15:28:05
SAVEA	8	11600.0	2014-01-09 15:28:05
PJIPE	10	7742.0	2014-01-12 15:28:05
SAVEA	15	19900.0	2014-01-12 15:28:05

……

CLIENT	SELLERID	AMOUNT	ORDERDATE
SJCH	5	25500.0	2013-12-27 15:28:05
FHYBR	17	12000.0	2013-12-28 15:28:05
HANAR	16	4312.0	2013-12-28 15:28:05
YZ	14	19100.0	2013-12-28 15:28:05
MIP	10	5390.0	2013-12-29 15:28:05
AVU	2	27000.0	2013-12-30 15:28:05
PJIPE	12	7840.0	2013-12-31 15:28:05
VILJX	9	19700.0	2013-12-31 15:28:05
AYWYN	13	25800.0	2014-01-04 15:28:05
PJIPE	14	29400.0	2014-01-05 15:28:05
DNEDL	10	24200.0	2014-01-07 15:28:05
HANAR	18	7252.0	2014-01-08 15:28:05
SAVEA	8	11600.0	2014-01-09 15:28:05
PJIPE	10	7742.0	2014-01-12 15:28:05
SAVEA	15	19900.0	2014-01-12 15:28:05
BTMMU	8	18700.0	2014-01-13 15:28:05

由程序将分库过滤结果纵向连接

where

友乾营

各分库表过滤后的结果纵向连接

举例：n个库的销售数据表，查询单笔销售额大于500的所有订单记录

序表

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select * from** sales **where** amount >500"	
3	fork A1	=A3.query@x(SQL)
4	=A3.conj()	

数据量较大时，使用游标**cursor+conjx**

注意：对数据库游标不再使用fork并行，而使用循环函数，用了fork反而会慢一些

游标

	A
1	=n.(connect("mysql"+string(~)))
2	=SQL="**select * from** sales **where** amount >500"
3	=A1.(~.**cursor**(SQL))
4	=A3.**conjx**()

order by

各分库表按某字段排序后的结果再排序

举例：n个库的销售数据表，按订单金额逆序排序

1号库（2013年）
按销售额逆序排序

CLIENT	SELLERID	AMOUNT	ORDERDATE
FHYBR	5	29700.0	2013-04-05 15:28:05
QUICK	6	29700.0	2013-11-04 15:28:05
YZ	8	29600.0	2013-01-06 15:28:05
FHYBR	2	29400.0	2013-08-19 15:28:05
SJCH	18	29100.0	2013-05-29 15:28:05
BTMMU	16	29100.0	2013-11-13 15:28:05
SAVEA	7	28900.0	2013-03-23 15:28:05

2号库（2014年）
按销售额逆序排序

CLIENT	SELLERID	AMOUNT	ORDERDATE
HP	6	29800.0	2014-10-08 15:28:05
JOPO	3	29700.0	2014-12-15 15:28:05
DILRT	14	29700.0	2014-05-24 15:28:05
BTMMU	7	29700.0	2014-04-30 15:28:05
HANAR	15	29600.0	2014-07-12 15:28:05
ERNSH	4	29600.0	2014-10-07 15:28:05
PJIPE	14	29400.0	2014-01-05 15:28:05

……

CLIENT	SELLERID	AMOUNT	ORDERDATE
HP	6	29800.0	2014-10-08 15:28:05
DILRT	14	29700.0	2014-05-24 15:28:05
QUICK	6	29700.0	2013-11-04 15:28:05
JOPO	3	29700.0	2014-12-15 15:28:05
BTMMU	7	29700.0	2014-04-30 15:28:05
FHYBR	5	29700.0	2013-04-05 15:28:05
ERNSH	4	29600.0	2014-10-07 15:28:05
YZ	8	29600.0	2013-01-06 15:28:05
HANAR	15	29600.0	2014-07-12 15:28:05
FHYBR	2	29400.0	2013-08-19 15:28:05
PJIPE	14	29400.0	2014-01-05 15:28:05
BTMMU	16	29100.0	2013-11-13 15:28:05
SJCH	18	29100.0	2013-05-29 15:28:05
AYWYN	5	28900.0	2014-09-01 15:28:05
QHHW	16	28900.0	2014-10-30 15:28:05
SAVEA	7	28900.0	2013-03-23 15:28:05

将分库排序结果再次按订购日期排序
（分库结果集有序，可使用归并算法
进行有序归并，提升效率）

order by

各分库表按某字段排序后的结果再排序

举例：n个库的销售数据表，按订单金额降序或升序排序

升序

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select * from** sales **order by** amount"	
3	fork A1	=A3.query@x(SQL)
4	=A3.merge(amount)	

降序

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select * from** sales **order by** amount **desc**"	
3	fork A1	=A3.query@x(SQL)
4	=A3.merge(-amount)	

order by

友乾营

各分库表按某字段排序后的结果再排序

举例：n个库的销售数据表，按订单金额升序排序

序表

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select * from** sales **order by** amount"	
3	fork A1	=A3.query@x(SQL)
4	=A3.merge(amount)	

数据量较大时：

游标

	A
1	=n.(connect("mysql"+string(~)))
2	=SQL="**select * from** sales **order by** amount"
3	=A1.(~.**cursor**(SQL))
4	=A3.**mergex**(amount)

limit Y offset X

友乾营

基于排序结果，取第几条后的多少条记录

举例：n个库的销售数据表，按订单金额逆序排序，随后跳过第1条的记录，取10条记录

1号库（2013年）
按销售额逆序排序

CLIENT	SELLERID	AMOUNT	ORDERDATE
FHYBR	5	29700.0	2013-04-05 15:28:05
QUICK	6	29700.0	2013-11-04 15:28:05
YZ	8	29600.0	2013-01-06 15:28:05
FHYBR	2	29400.0	2013-08-19 15:28:05
SJCH	18	29100.0	2013-05-29 15:28:05
BTMMU	16	29100.0	2013-11-13 15:28:05
SAVEA	7	28900.0	2013-03-23 15:28:05

2号库（2014年）
按销售额逆序排序

CLIENT	SELLERID	AMOUNT	ORDERDATE
HP	6	29800.0	2014-10-08 15:28:05
JOPO	3	29700.0	2014-12-15 15:28:05
DILRT	14	29700.0	2014-05-24 15:28:05
BTMMU	7	29700.0	2014-04-30 15:28:05
HANAR	15	29600.0	2014-07-12 15:28:05
ERNSH	4	29600.0	2014-10-07 15:28:05
PJIPE	14	29400.0	2014-01-05 15:28:05

……

CLIENT	SELLERID	AMOUNT	ORDERDATE
HP	6	29800.0	2014-10-08 15:28:05
DILRT	14	29700.0	2014-05-24 15:28:05
QUICK	6	29700.0	2013-11-04 15:28:05
JOPO	3	29700.0	2014-12-15 15:28:05
BTMMU	7	29700.0	2014-04-30 15:28:05
FHYBR	5	29700.0	2013-04-05 15:28:05
ERNSH	4	29600.0	2014-10-07 15:28:05
YZ	8	29600.0	2013-01-06 15:28:05
HANAR	15	29600.0	2014-07-12 15:28:05
FHYBR	2	29400.0	2013-08-19 15:28:05
PJIPE	14	29400.0	2014-01-05 15:28:05
BTMMU	16	29100.0	2013-11-13 15:28:05
SJCH	18	29100.0	2013-05-29 15:28:05
AYWYN	5	28900.0	2014-09-01 15:28:05
QHHW	16	28900.0	2014-10-30 15:28:05
SAVEA	7	28900.0	2013-03-23 15:28:05

跳过第1条取10条

基于分库排序+有序归并后的结果，跳过X条记录，取Y条记录
（分库可以取X+Y条，但不能跳）

limit Y offset X

友乾营

基于排序结果，取第几条后的多少条记录

举例：从n个库的销售数据表中，按订单金额逆序排序，随后跳过第1条的记录，取10条记录

序表

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select** * **from** sales **order by** amount **desc limit** 11"	
3	fork A1	=A3.query@x(SQL)
4	=A3.merge(-amount).to(2,11)	

数据量较大时（由于单库SQL有limit，数据量不会较大，此处仅作为游标使用示例）：

游标

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select** * **from** sales **order by** amount **desc limit** 11"	
3	=A1.(~.**cursor**(SQL))	
4	=A3.**mergex**(-amount)	=A4.skip(1)
5	=A4.fetch(10)	

sum/count/avg/max/min

各分库表聚合后的结果需要再聚合，但有些注意事项

sum：分库sum，汇总还是sum

count：分库count，汇总是要用sum

avg：要变成sum和count分别计算后再计算avg

max\min：和sum一样

sum/count/avg/max/min

各分库表聚合后的结果需要再聚合，但有些注意事项

举例：n个库的销售数据表，求销售总额、订单数、销售额最值和销售额均值

	A
1	=n.(connect("mysql"+string(~)))
2	=SQL="**select sum**(amount) totalamount,**count**(amount) countamount,**max**(amount) maxamount,**min**(amount) minamount **from** sales
3	=A1.(~.**cursor**(SQL))
4	=A3.conjx().total(sum(totalamount), sum(countamount), max(maxamount), min(minamount))
5	=create(totalamount,countamount,avgamount,maxamount,minamount).insert(0,A4(1),A4(2),if(A4(2)!=0,round(A4(1)/A4(2)),null),A4(3),A4(4))

group by

各分库表的分组聚合结果再分组聚合，不能简单合并

举例：n个库的销售数据表，按销售人员ID分组，对销售金额求和、最大最小值与订单数

sellerid	totalamount	countamount	maxamount	minamount
1	313228.0	20	26400.0	4998.0
2	298006.0	23	29400.0	1666.0
3	142054.0	14	23100.0	1568.0
4	237614.0	14	28400.0	1764.0
5	252294.0	20	29700.0	490.0
6	246922.0	18	29700.0	1372.0

SELLERID	TOTALAMOUNT	COUNTAMOUNT	MAXAMOUNT	MINAMOUNT
1	265934	20	27400	98
2	301502	26	27800	392
3	279986	20	29700	686
4	228070	20	29600	1862
5	175478	16	28900	392
6	198150	17	29800	294

.....

SELLERID	TOTALAMOUNT	COUNTAMOUNT	MAXAMOUNT	MINAMOUNT
1	687850.0	51	29000.0	98.0
2	734276.0	64	29400.0	392.0
3	554724.0	44	29700.0	686.0
4	565594.0	48	29600.0	98.0
5	564516.0	50	29700.0	196.0
6	672064.0	50	29800.0	294.0

group by

友乾营

各分库表的分组聚合结果再分组聚合，不能简单合并

举例：n个库的销售数据表，按销售人员ID分组，对销售金额求和、最大最小值与订单数

对于各库结果较小，再聚合运算的结果集只会更小，使用**query+groups**

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select** sellerid, **sum**(amount) totalamount, **count**(amount) countamount,**max**(amount) maxamount,**min**(amount) minamount **from** sales **group by** sellerid"	
3	fork A1	=A3.**query@x**(SQL)
4	=A3.conj().**groups**(sellerid;sum(totalamount):totalamount,sum(countamount):countamount,max(maxamount):maxamount,min(minamount):minamount)	
5	=A4.new(sellerid,totalamount,countamount,if(countamount==0,null,round(totalamount/countamount)):avgamount,maxamount,minamount)	

group by

友乾营

各分库表的分组聚合结果再分组聚合，不能简单合并

举例：n个库的销售数据表，按销售人员ID分组，对销售金额求和、最大最小值与订单数

对于各库结果较大，再分组聚合的结果不大，使用**cursor+conjx+groups**

	A
1	=n.(connect("mysql"+string(~)))
2	=SQL="**select** sellerid, **sum**(amount) totalamount, **count**(amount) countamount,**max**(amount) maxamount,**min**(amount) minamount **from** sales **group by** sellerid"
3	=A1.(~.**cursor**(SQL))
4	=A3.**conjx()**.**groups**(sellerid;sum(totalamount):totalamount,sum(countamount):countamount,max(maxamount):maxamount,min(minamount):minamount)
5	=A4.new(sellerid,totalamount,countamount,if(countamount==0,null,round(totalamount/countamount)):avgamount,maxamount,minamount)

group by

友乾营

各分库表的分组聚合结果再分组聚合，不能简单合并

举例：n个库的销售数据表，按销售人员ID分组，对销售金额求和、最大最小值与订单数

对于各库结果较大，再分组聚合的结果也很大，使用**cursor+mergex+groupx**

	A
1	=n.(connect("mysql"+string(~)))
2	=SQL="**select** sellerid, **sum**(amount) totalamount, **count**(amount) countamount,**max**(amount) maxamount,**min**(amount) minamount **from** sales **group by** sellerid **order by** sellerid"
3	=A1.(~.**cursor**(SQL))
4	=A3.**mergex()**.**groupx@o**(sellerid;sum(totalamount):totalamount,sum(countamount):countamount,max(maxamount):maxamount,min(minamount):minamount)
5	=A4.new(sellerid,totalamount,countamount,if(countamount==0,null,round(totalamount/countamount)):avgamount,maxamount,minamount)

group by having

友乾营

各分库表仅分组聚合，所有结果彻底完成分组聚合后再过滤

举例：n个库的销售数据表，按月份和销售员ID分组，统计平均销售额小于10000的数据

1号库（2013年）
按月、销售员id分组，统计销售总额和订单总数

ORDERMONTH	SELLERID	TOTALAMOUNT	TOTALCOUNT
1	1	24800.0	2
1	2	10300.0	1
1	3	37766.0	3
1	4	26700.0	1
1	5	36800.0	2
1	6	67858.0	4
1	8	34206.0	3
1	9	26200.0	1

2号库（2014年）
按月、销售员id分组，统计销售总额和订单总数

ORDERMONTH	SELLERID	TOTALAMOUNT	TOTALCOUNT
1	3	9408.0	2
1	4	5782.0	1
1	6	5292.0	1
1	7	20000.0	1
1	8	68220.0	6
1	9	2646.0	2
1	10	38704.0	3
1	11	3528.0	1

……

ORDERMONTH	SELLERID	AVGAMOUNT
1	2	8932.0
1	16	6444.0
1	17	8859.0
1	18	5945.0
1	19	9993.0
2	3	8918.0
2	4	8368.0
2	6	9428.0

数据量较大时，分库中分别按分组维度有序地返回结果。程序在处理时可采用归并算法，有序归并各库结果。归并后的结果仍是有序的，可继续采用有序分组聚合后再过滤。（要注意的是：分库中不应having）

group by having

各分库表仅分组聚合，所有结果彻底完成分组聚合后再过滤

举例：n个库的销售数据表，按月份和销售员ID分组，统计平均销售额小于10000的数据

聚合计算是在汇总之后才能最终完成，随后再使用函数select实现过滤

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select month**(orderdate) ordermonth,sellerid,**sum**(amount) totalamount,**count**(amount) totalcount **from** sales **group by** ordermonth,sellerid"	
3	fork A1	=A3.**query@x**(SQL)
4	=A3.**conj**().**groups**(ordermonth,sellerid;sum(totalamount):totalamount,sum(totalcount):totalcount).new(ordermonth,sellerid,(totalamount/totalcount):avgamount).**select**(avgamount<10000)	

对于大数据量，需要使用游标 (select函数同样适用于游标)

	A
1	=n.(connect("mysql"+string(~)))
2	=SQL="**select month**(orderdate) ordermonth,sellerid,**sum**(amount) totalamount,**count**(amount) totalcount **from** sales **group by** ordermonth,sellerid **order by** ordermonth,sellerid"
3	=A1.(~.**cursor**(SQL))
4	=A3.**mergex(ordermonth,sellerid)**.**groupx@o**(ordermonth,sellerid;sum(totalamount):totalamount,sum(totalcount):totalcount).new(ordermonth,sellerid,(totalamount/totalcount):avgamount).**select**(avgamount<10000)

distinct

distinct x 相当于 select x group by x，实现方法和group相同

各分库表仅做去重运算，所有结果做并集（去重），不能简单合并

举例：n个库的销售数据表，统计所有对客户编号为 ‘YZ’ 有过成交记录的销售人员ID

1号库（2013年）
统计当年对客户编号为 ‘YZ’
有成交记录的销售人员ID

sellerid
1
2
3
4
5
6
7

2号库（2014年）
统计当年对客户编号为 ‘YZ’
有成交记录的销售人员ID

SELLERID
2
4
7
13
16
17
18

……

SELLERID
1
8
9
11
12
13
14
15
16
17
18
19

显然需要将各分库的结果做并集（去重），而非简单的合并。

distinct

distinct x 相当于 select x group by x，实现方法和group相同

各分库表仅做去重运算，所有结果做并集（去重），不能简单合并

举例：n个库的销售数据表，统计所有对客户编号为 ‘YZ’ 有过成交记录的销售人员ID

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select distinct** sellerid **from** sales **where** client='YZ' **order by** sellerid"	
3	fork A1	=A3.**query@x**(SQL)
4	=A3.**merge@u**(sellerid)	

对于大数据量，可以使用**cursor+mergex@u**

	A
1	=n.(connect("mysql"+string(~)))
2	=SQL="**select distinct** sellerid **from** sales **where** client='YZ' **order by** sellerid"
3	=A1.(~.**cursor**(SQL))
4	=A3.**mergex@u**(sellerid)

count(distinct)

友乾营

各分库表仅做去重运算，所有结果做并集去重后再计数

举例：n个库的销售数据表，统计单笔销售额大于29000的销售员个数

1号库（2013年）
统计单笔销售额大于
29000的销售员

sellerid
2
5
6
8
16
18

2号库（2014年）
统计单笔销售额大于
29000的销售员

SELLERID
3
4
6
7
14
15

……

COUNTRESULT
11

对于分库中去重结果集较大时，
可以在各库分别排序，后续代码
可利用有序的特点用归并算法求
并集后再计数

count(distinct)

友乾营

各分库表仅做去重运算，所有结果做并集（去重）后再计数

举例：n个库的销售数据表，统计单笔销售额大于29000的销售员个数

对于小数据量，可以使用**query、merge@u和len**

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select distinct** sellerid **from** sales **where** amount>29000 **order by** sellerid"	
3	fork A1	=A3.**query@x**(SQL)
4	=A3.**merge@u**(sellerid).len()	

对于大数据量小结果集，可以使用**cursor、mergex@u和total**

	A
1	=n.(connect("mysql"+string(~)))
2	=SQL="**select distinct** sellerid **from** sales **where** amount>29000 **order by** sellerid"
3	=A1.(~.**cursor**(SQL))
4	=A3.**mergex@u**(sellerid).total(count(~))

count(distinct) group by

count(distinct) group by要把distinct的内容和group by内容一起group(distinct)

各分库表仅做去重运算，所有结果做并集（去重）后再计数，当多列时需要多次计算

举例：n个库的销售数据表，按月份分组，统计单笔销售额大于10000的销售员个数

1号库（2013年）
统计单笔销售额大于10000，且按月、销售员id去重并排序

ORDERMONTH	SELLERID
1	1
1	2
1	3
1	4
1	5
1	6
1	8
1	9
1	10

2号库（2014年）
统计单笔销售额大于10000，且按月、销售员id去重并排序的结果

ORDERMONTH	SELLERID
1	7
1	8
1	10
1	13
1	14
1	15
1	20
2	1
2	4

……

ORDERMONTH	COUNTID
1	18
2	17
3	19
4	20
5	19
6	18
7	17
8	15
9	16
10	14
11	20
12	19

对于分库中去重结果集较大时，可以在各库分别排序，后续代码可利用有序的特点用归并算法求并集后再计数

count(distinct) group by

count(distinct) group by要把distinct的内容和group by内容一起group(distinct)

各分库表仅做去重运算，所有结果做并集（去重）后再计数，当多列时需要多次计算

举例：n个库的销售数据表，按月份分组，统计单笔销售额大于10000的销售员个数

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select distinct month**(orderdate) ordermonth,sellerid **from** sales **where** amount > 10000 **order by** ordermonth,sellerid"	
3	fork A1	=A3.**query@x**(SQL)
4	=A3.**merge@u**(ordermonth,sellerid).**groups@o**(ordermonth;count(sellerid):countseller)	

对于大数据量小结果集，可以使用**cursor、mergex@u和groups@o**

	A
3	=A1.(~.**cursor**(SQL))
4	=A3.**mergex@u**(ordermonth,sellerid).**groups@o**(ordermonth;count(sellerid):countseller)

对于大数据量大结果集，可以使用**cursor、mergex@u和groupx@o**

	A
3	=A1.(~.**cursor**(SQL))
4	=A3.**mergex@u**(ordermonth,sellerid).**groupx@o**(ordermonth;count(sellerid):countseller)

带join on的查询

友乾营

合理的数据分布方案，可以使JOIN只在分库进行，汇总阶段不再处理JOIN

在同步分库的方案下，FULL JOIN，LFET JOIN都可以支持，但不同类型的JOIN关系需要不同的分布方式

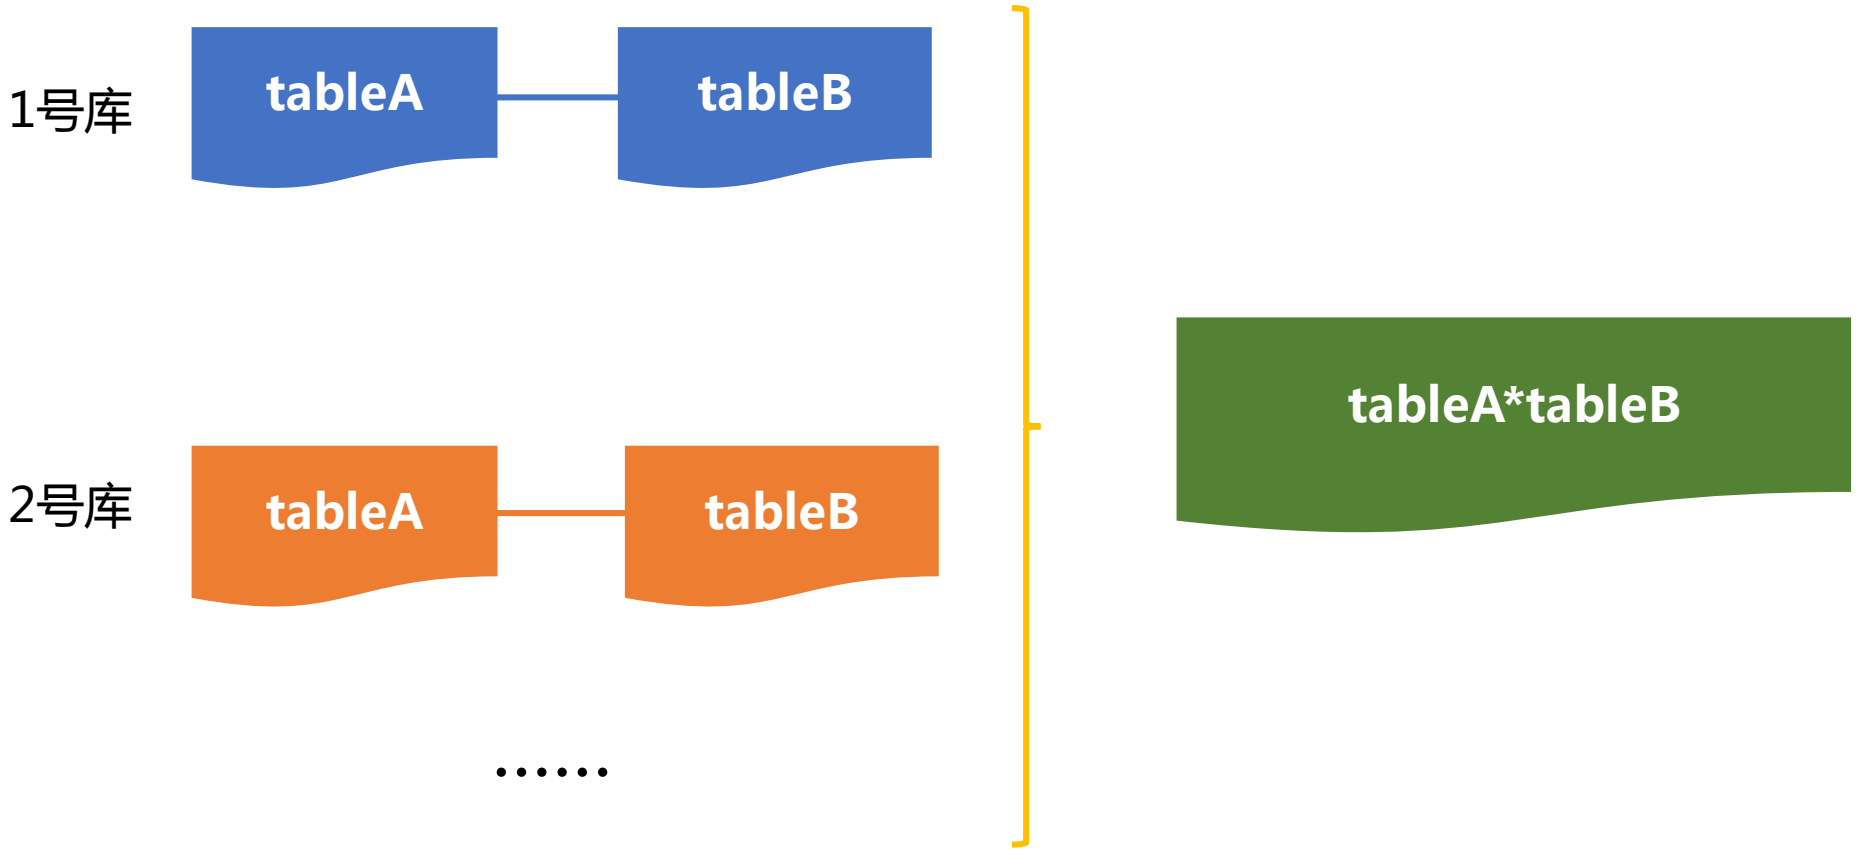

同维与主子表

友乾营

product 产品表	
sid ★ 主键	产品号
producttime	生产时间
workshopnum	车间号
…	…

1 : 1

quality 产品质量表	
sid ★ 主键	产品号
qlevel	产品质量等级
…	…

同维表：表 A 的主键与表 B 的主键关联，A 和 B 互称为同维表。同维表是一对一的关系，同维表之间的关系是对等的。

orderinfo 订单表 (主表)	
orderid ★ 主键	订单编号
customer	客户
date	日期
country	国家
…	…

1 : N

orderdetail 订单明细（子表）	
orderid ★ 主键	订单编号
sid ★ 主键	序号
productid	产品编号
price	价格
num	数量
…	…

主子表：表 A 的主键与表 B 的部分主键关联，A 称为主表，B 称为子表。主子表是一对多的关系。

外键表（维表）

orderdetail 订单明细	
orderid ★主键	订单编号
sid ★主键	序号
productid	产品编号
price	价格
num	数量

product 产品表	
pid ★主键	产品编号
name	产品名称
area	产地
…	…

表 A 的某些字段与表 B 的主键关联。A 表中与 B 表主键关联的字段称为 A 指向 B 的外键，B 也称为 A 的外键表。外键表是多对一的关系。

同维主子表同步分库

分库后，在各分库中把join处理完即可，汇总阶段不用再考虑join

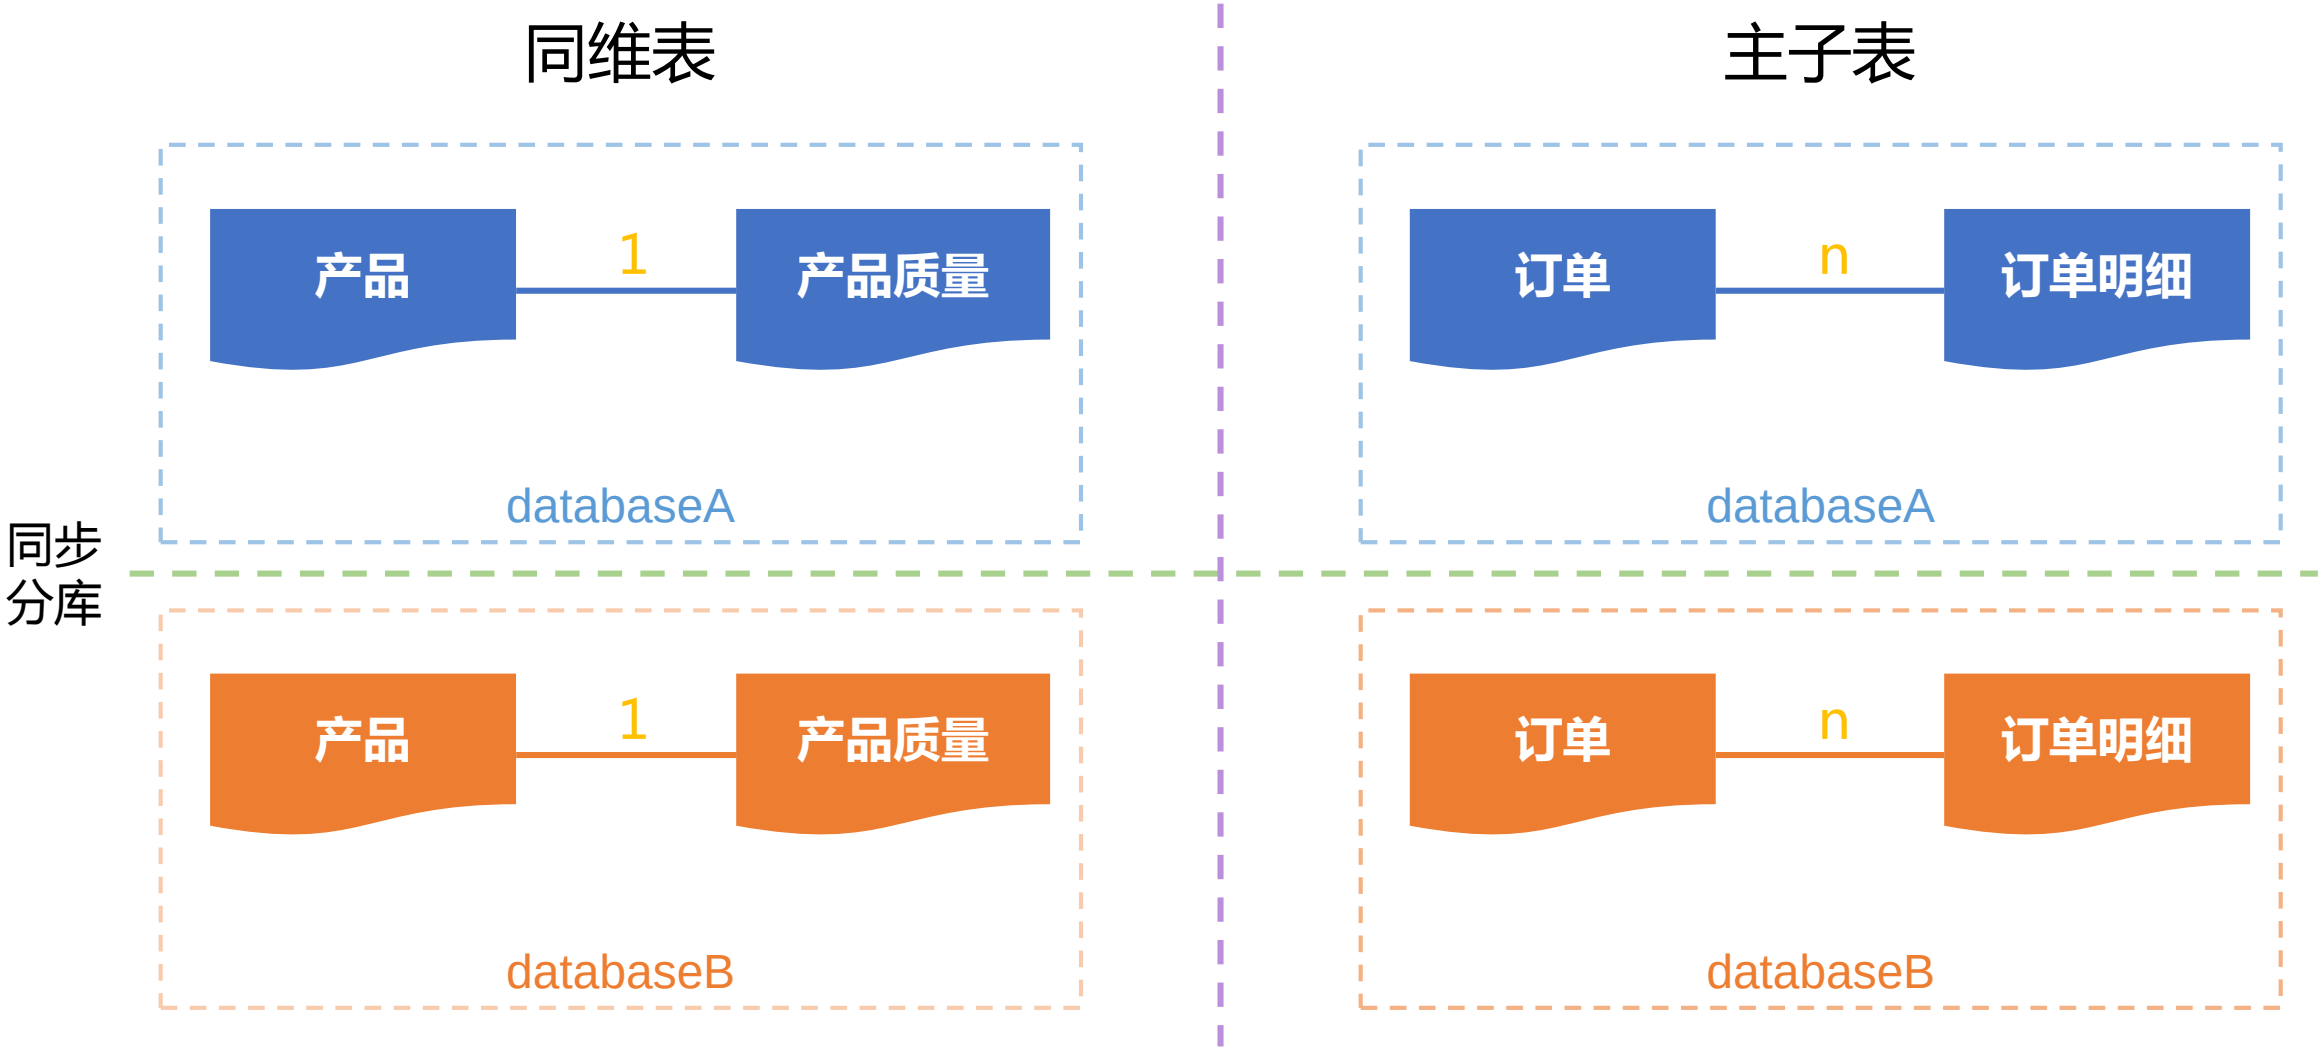

同维表

同步分库的同维表，可在各分库中分别关联后合并

举例：n个库中，产品表与产品质量表属同步分库，按车间号分组，统计产品质量等级小于3的产品个数

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select** t1.workshopnum workshopnum,**count**(t2.qlevel) lt3count **from** product t1 **join** quality t2 **on** t1.sid**=**t2.sid **where** t2.qlevel**<**3 **group by** t1.workshopnum **order by** t1.workshopnum"	
3	fork A1	=A3.**query@x**(SQL)
4	=A3.**merge**(workshopnum).**groups@o**(workshopnum;sum(lt3count):lt3count)	

对于大数据量，使用游标

	A
1	=n.(connect("mysql"+string(~)))
2	=SQL="**select** t1.workshopnum workshopnum,**count**(t2.qlevel) lt3count **from** product t1 **join** quality t2 **on** t1.sid**=**t2.sid **where** t2.qlevel**<**3 **group by** t1.workshopnum **order by** t1.workshopnum"
3	=A1.(~.**cursor**(SQL))
4	=A3.**mergex**(workshopnum).**groupx@o**(workshopnum;sum(lt3count):lt3count)

主子表

同步分库的主子表，可在各分库中分别关联后合并

举例：n个库中，订单与订单明细属同步分库，按国家、产品编号分组，统计产品总数

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select** t1.country country,t2.productid productid,**sum**(t2.num) totalnum **from** orderinfo t1 **join** orderdetail t2 **on** t1.orderid**=**t2.orderid **group by** t1.country,t2.productid **order by** t1.country,t2.productid"	
3	fork A1	=A3.**query@x**(SQL)
4	=A3.**merge**(country,productid).**groups@o**(country,productid;sum(totalnum):totalnum)	

对于大数据量，使用游标

	A
1	=n.(connect("mysql"+string(~)))
2	=SQL="**select** t1.country country,t2.productid productid,**sum**(t2.num) totalnum **from** orderinfo t1 **join** orderdetail t2 **on** t1.orderid**=**t2.orderid **group by** t1.country,t2.productid **order by** t1.country,t2.productid"
3	=A1.(~.**cursor**(SQL))
4	=A3.**mergex**(country,productid).**groupx@o**(country,productid;sum(totalnum):totalnum)

外键表（维表）复制冗余

维表（右表）在每个库中都有同一份，则事实表（左表）（每个数据库中各有其一部分）在汇总后再连接，等同于各库中的事实表与维表先连接后，再汇总到一起的结果。如图：

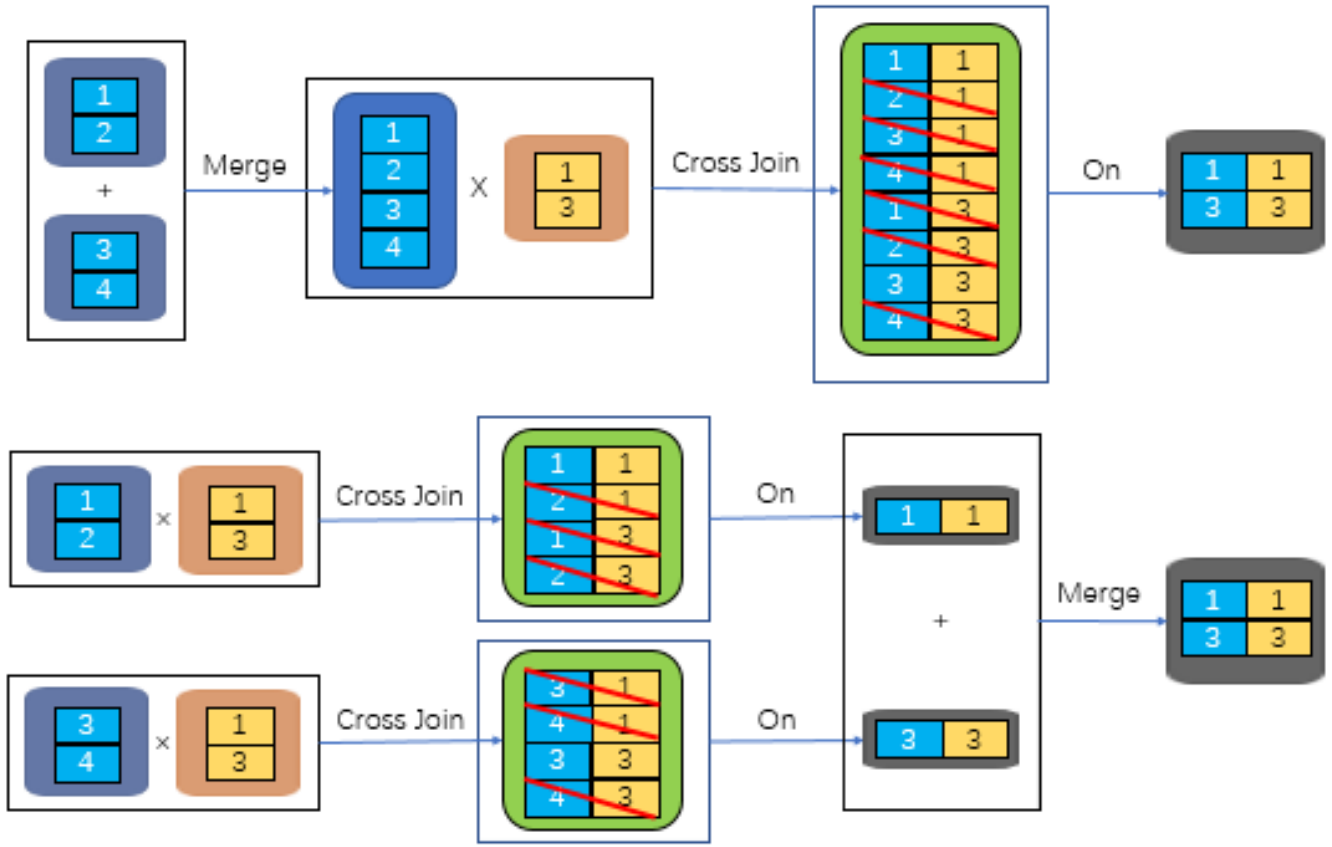

维表冗余

各分库均有一份相同的完整外键表，可在各分库中分别关联后合并

举例：n个库中，订单明细在各分库均匀分布，产品表在各分库冗余，过滤出所有产地为东部的订单

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL="**select * from** orderdetail t1 **join** product t2 **on** t1.productid**=**t2.pid **where** t2.area**=**'east'"	
3	fork A1	=A3.**query@x**(SQL)
4	=A3.**conj()**	

对于大数据量，使用游标

	A
1	=n.(connect("mysql"+string(~)))
2	=SQL="**select * from** orderdetail t1 **join** product t2 **on** t1.productid**=**t2.pid **where** t2.area**=**'east'"
3	=A1.(~.**cursor**(SQL))
4	=A3.**conjx()**

维表内存化

当维表（外键表）被分散存储在各分库中，若完整的维表可以装入内存，可以将外键表提取后由程序实现join

举例：n个库中，订单明细在各分库均匀分布，产品表分散在各分库，过滤出所有产地为东部的订单

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL1="**select * from** product **where** t2.area**=**'east'"	
3	fork A1	=A3.**query**(SQL1)
4	=A3.**conj()**	
5	=SQL2="**select * from** orderdetail"	
6	fork A1	=A6.**query@x**(SQL2)
7	=A6.**conj()**	
8	=join(A4:product,pid;A7:orderdetail,productid)	

不可内存化的情况需要专门针对性的的存储和计算方案，这里暂不讨论

维表内存化

当维表（外键表）被分散存储在各分库中，若完整的维表可以装入内存，可以将外键表提取后由程序实现join

举例：n个库中，订单明细在各分库均匀分布，产品表分散在各分库，过滤出所有产地为东部的订单

当数据量较大时，可使用**cursor+conjx**

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=SQL1="**select * from** product **where** t2.area**=**'east'"	
3	fork A1	=A3.**query**(SQL1)
4	=A3.**conj()**	
5	=SQL2="**select * from** orderdetail"	
6	=A1.(~.**cursor**(SQL2))	
7	=A6.**conjx()**	
8	=A7.join(productid,A4:pid)	

集合运算

集合运算，常见的有以下四种，分库下各场景方案类似

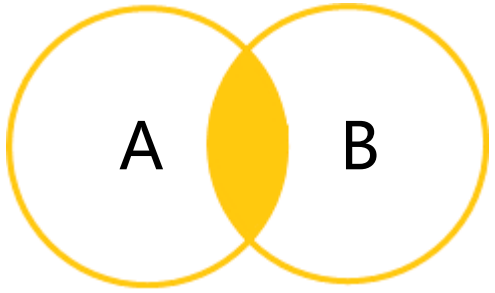

交集

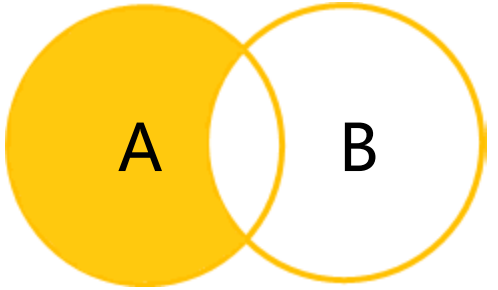

差集

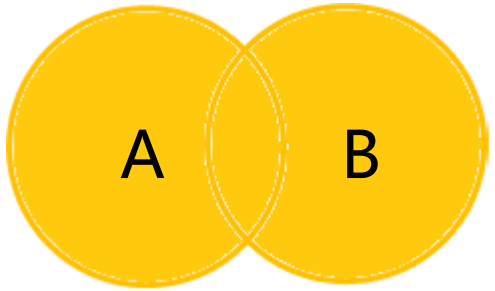

并集

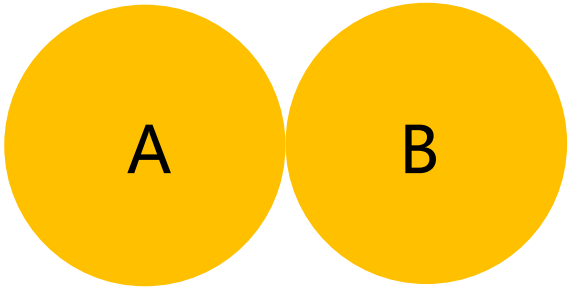

合集

集合运算

交集：由所有属于集合A且属于集合B的元素所组成的集合（差集、并集类似）

举例：n个库中存有订单表（orders）与回款表（returns），求出订单金额超过10000，但总回款小于5000的订单

单库的情况下：

```
SELECT O_ORDERKEY
FROM ORDERS
WHERE O_TOTALPRICE > 10000
INTERSECT
SELECT R_ORDERKEY
FROM RETURNS
GROUP BY R_ORDERKEY
HAVING SUM(R_MONEY) < 5000
```

单库SQL示例

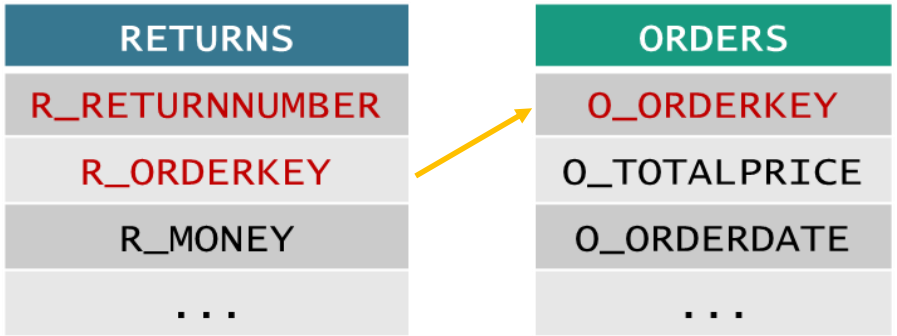

集合运算

交集：由所有属于集合A且属于集合B的元素所组成的集合（差集、并集类似）

举例：n个库中存有订单表（orders）与回款表（returns），求出订单金额超过10000，但总回款小于5000的订单

分库的情况下：

分库where统计出订单金额超过10000的订单表数据

ORDERKEY	O_TOTALPRICE
3	13500.0
4	26100.0
7	17800.0
9	17400.0
10	19200.0

分库group by having统计出总回款小于5000的回款表数据

ORDERKEY	R_TOTALMONEY
3	2285
7	1005
8	3657
9	3784
10	4697

订单表数据（集合A）与回款表数据（集合B）进行交集运算

ORDERKEY	O_TOTALPRICE
3	13500.0
7	17800.0
9	17400.0
10	19200.0
11	13700.0

※注意：两表的分库运算与最终的集合运算可以利用订单ID的有序特性，利用有序归并提升效率

集合运算

友乾营

交集：由所有属于集合A且属于集合B的元素所组成的集合（差集、并集类似）

举例：n个库中存有订单表（orders）与回款表（returns），求出订单金额超过10000，但总回款小于5000的订单

	A	B
1	=n.(connect("mysql"+string(~)))	
2	=orders="select O_ORDERKEY as ORDERKEY,O_TOTALPRICE from ORDERS where O_TOTALPRICE>10000"	
3	fork A1	=A3.**query**(orders)
4	=A3.**merge**(ORDERKEY)	
5	=returns="select R_ORDERKEY as ORDERKEY,sum(R_MONEY) as R_TOTALMONEY from RETURNS group by ORDERKEY"	
6	fork A1	=A6.**query**(returns)
7	=A6.**conj**().**groups**(ORDERKEY;sum(R_TOTALMONEY):R_TOTALMONEY).select(R_TOTALMONEY<5000)	
8	=[A4,A7].**merge@i**()	/选项@d为A4与A7的差集、选项@u为并集

※注意：这里需要两层归并（merge），第一层是处理分库数据表的运算，第二层是处理集合运算

集合运算

友乾营

交集：由所有属于集合A且属于集合B的元素所组成的集合（差集、并集类似）

举例：n个库中存有订单表（orders）与回款表（returns），求出订单金额超过10000，但总回款小于5000的订单

当数据量较大时，改为使用游标

	A
1	=n.(connect("mysql"+string(~)))
2	=orders="select O_ORDERKEY as ORDERKEY,O_TOTALPRICE from ORDERS where O_TOTALPRICE>10000 order by ORDERKEY"
3	=A1.(~.**cursor**(orders))
4	=A3.**mergex**(ORDERKEY)
5	=returns="select R_ORDERKEY as ORDERKEY,sum(R_MONEY) as R_TOTALMONEY from RETURNS group by ORDERKEY order by ORDERKEY"
6	=A1.(~.**cursor**(returns))
7	=A6.**mergex**(ORDERKEY).**groupx@o**(ORDERKEY;sum(R_TOTALMONEY):R_TOTALMONEY).select(R_TOTALMONEY<5000)
8	=[A4,A7].**merge@i**()

集合运算的简单情况

友乾营

当恰好A和B从属于不同分库时，不必考虑同表分库数据运算，只要求交集

举例：某书店，店面交易表和网络交易表（表名都为sales）分别在两个不同的数据库中，需要统计出两处都销售过的书籍

ID	PID	PNAME	TYPE
…	…	…	…
S020008116	B2096	The Silent Girl	Book
S020008135	B1780	Insurgent	Book
…	…	…	…

店面交易表

ID	PID	PNAME	TYPE
…	…	…	…
L020003746	B2096	The Silent Girl	Book
L020003864	B1445	Wonder	Book
…	…	…	…

网络交易表

集合运算的简单情况

友乾营

当恰好A和B从属于不同分库时，不必考虑同表分库数据运算，只要求交集

举例：某书店，店面交易表和网络交易表（表名都为sales）分别在两个不同的数据库中，需要统计出两处都销售过的书籍

	A	B
1	=n.(connect("mysql"+string(~)))	
2	fork A1	=A2.query@x("select distinct pid,pname from sales order by pid")
3	=A2.merge@i(pid)	

当数据量较大时，使用cursor+mergex@i

	A
1	=n.(connect("mysql"+string(~)))
2	=A1.(~.cursor("select distinct pid,pname from sales order by pid"))
3	=A2.mergex@i(pid)

※注意：简单情况下由于A、B集合恰好分库，只需要一层归并（merge）求集合运算即可

join on转为集合运算

select distinct A.key from A join B on A.key=B.A_key

可当做交集运算来处理

select A.key from A intersect select distinct B.A_key from B

举例：n个库中存有订单表（orders）与回款表（returns），求出订单金额超过10000，且一次性回款大于5000的订单

分库where统计出订单金额超过10000的订单表数据

ORDERKEY	O_TOTALPRICE
1	10392.0
2	14802.0
3	13500.0
4	26100.0
5	14410.0

分库distinct统计出一次性回款大于5000的回款表数据

ORDERKEY	R_MONEY
3	5040
5	5930
12	6710
14	5385
20	5671

ORDERKEY	O_TOTALPRICE
1	10392.0
2	14802.0
4	26100.0
6	16174.0
7	17800.0

此处的join on可以转为集合交集运算

join on转为集合运算

select distinct A.key from A join B on A.key=B.A_key

可当做交集运算来处理

select A.key from A intersect select distinct B.A_key from B

举例：n个库中存有订单表（orders）与回款表（returns），求出订单金额超过10000，且一次性回款大于5000的订单

当数据量较大时（这里需要注意回款表SQL中的distinct和分库归并去重）：

	A
1	=n.(connect("mysql"+string(~)))
2	=orders="select O_ORDERKEY as ORDERKEY,O_TOTALPRICE from ORDERS where O_TOTALPRICE>10000 order by ORDERKEY"
3	=A1.(~.**cursor**(orders))
4	=A3.**mergex**(ORDERKEY)
5	=returns="select **distinct** R_ORDERKEY as ORDERKEY from RETURNS where R_MONEY > 5000 order by ORDERKEY"
6	=A1.(~.**cursor**(returns))
7	=A6.**mergex@u**(ORDERKEY)
8	=[A4,A7].**merge@i**()

异构数据库分库

友乾营

各数据库函数不尽相同，异构库分库需要执行相应的SQL

举例：依旧是分组聚合过滤的例子，由于MySQL和Oracle的“取月”函数不同，需要分别执行不同SQL

标准函数	含义	Oracle	MySQL
YEAR(d)	取年	EXTRACT(YEAR FROM d)	YEAR(d)
MONTH(d)	取月	EXTRACT(MONTH FROM d)	MONTH(d)

MySQL: **select month**(orderdate) ordermonth,sellerid,**sum**(amount) totalamount,**count**(amount) totalcount **from** sales **group by month**(orderdate) sellerid **order by** ordermonth,sellerid

Oracle: **select extract** (**month from** orderdate) ordermonth,sellerid,**sum**(amount) totalamount,**count**(amount) totalcount **from** sales **group by extract** (**month from** orderdate) sellerid **order by** ordermonth,sellerid

异构数据库分库

各数据库函数不尽相同，异构库分库需要执行相应的SQL

举例：依旧是分组聚合过滤的例子，由于MySQL和Oracle的“取月”函数不同，需要分别执行不同SQL

	A	B
1	=[[connect@l("mysql"),"MYSQL"],[connect@l("oracle"),"ORACLE"]]	
2	=SQL="**select month**(orderdate) ordermonth,sellerid,**sum**(amount) totalamount,**count**(amount) totalcount **from** sales **group by month**(orderdate),sellerid"	
3	fork A1	=SQL.**sqltranslate**(A3(2))
4		=A3(1).query(B3)
5	=A3.conj()	

润乾线上直销系统

玩转好多乾

http://www.raqsoft.com.cn/wx/hdq-strategy.html