

# SPL

Structure Process Language

润乾软件@2018



# 目录页

## CONTENTS



01 背景介绍



02 SPL



03 运算模型



04 工程实现



05 应用场景



06 计算实例

# 结构化数据计算



## 结构化数据仍是现代数据分析中最重要的内容

数据分析（计算）的目的是寻找事物之间的关联，而事物是由其属性决定的，技术上表现为结构化数据



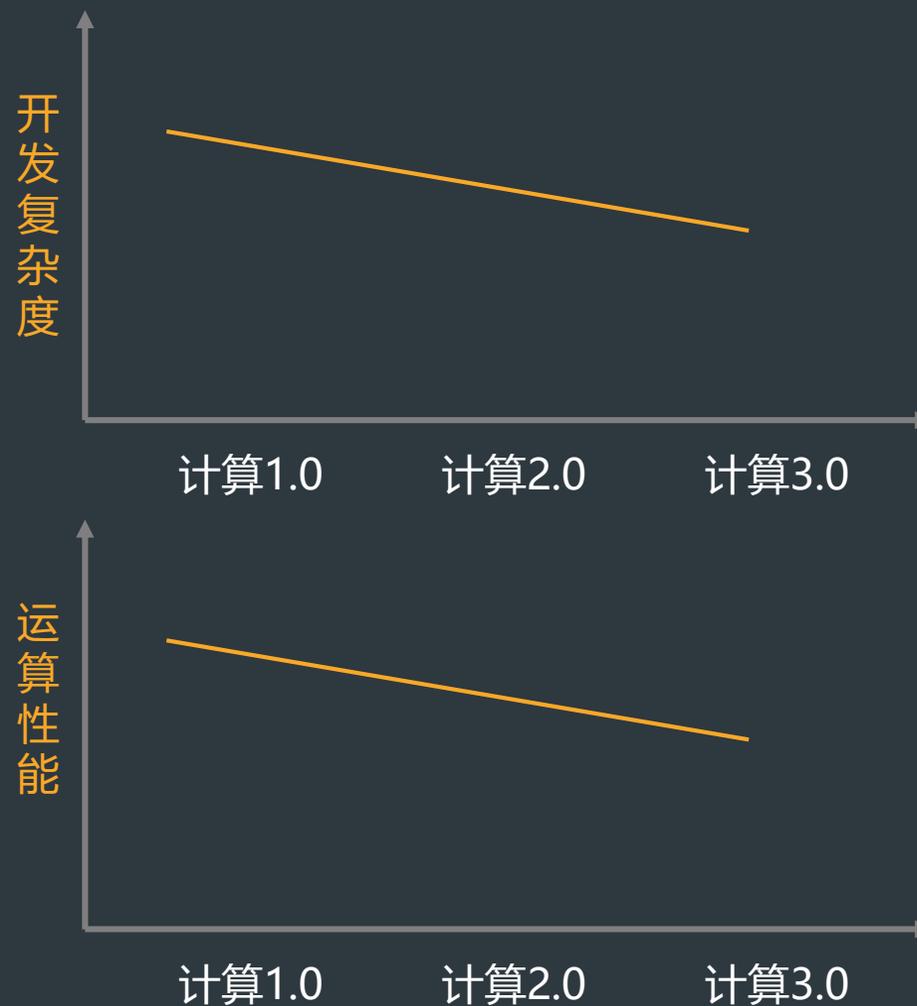
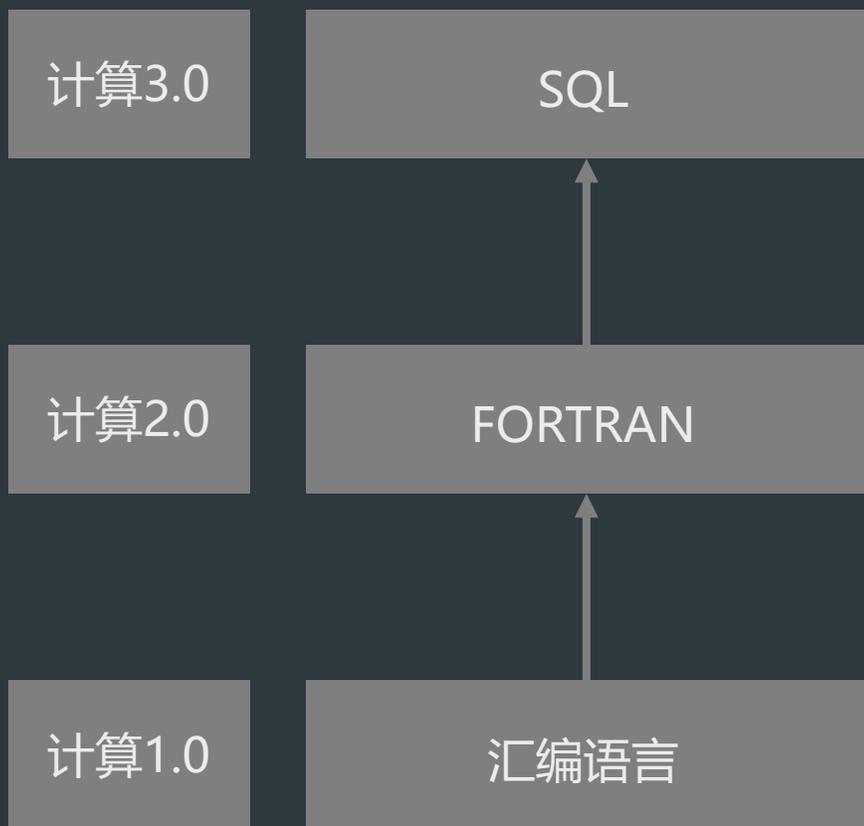
计算3.0-SQL

计算2.0-Fortran

计算1.0-汇编语言

# || 数据计算进化史

# 数据计算进化史



## 3.0时代数据计算难题



### 开发难

- 复杂SQL实现难
- 前人代码维护难
- 库外计算实施难
- 多系统数据整合难
- 应用耦合性过高
- MySQL无窗口函数

### 运算慢

- 查询分析响应慢
- ETL时间长
- 存储过程执行慢
- Hadoop性能低
- 库外数据处理慢
- 数据库资源不够用



# 原因分析

## 理论模型限制

SQL的理论模型是诞生于上世纪60年代的关系代数体系，该体系下实施计算难度非常大

## 不提倡分步运算

SQL语法很像英语，不提供分步机制，无过程性导致算法实现、维护困难

## 不支持有序集合

SQL不支持有序集合，涉及有序计算实现困难甚至实现不了，而有序计算在结构化数据计算中很常见

## 缺乏离散性

离散性允许记录游离于集合之外参与计算，SQL离散性差导致资源浪费，无法修改原记录

## 集合化不彻底

SQL不具备离散性，导致集合化不彻底，从而难以直接利用分组子集的内容

## 关联定义简单

SQL对关联的定义过于简单，相当于加法，但在特定的情况下使用乘法更加高效，而非都用加法描述



计算4.0-SPL

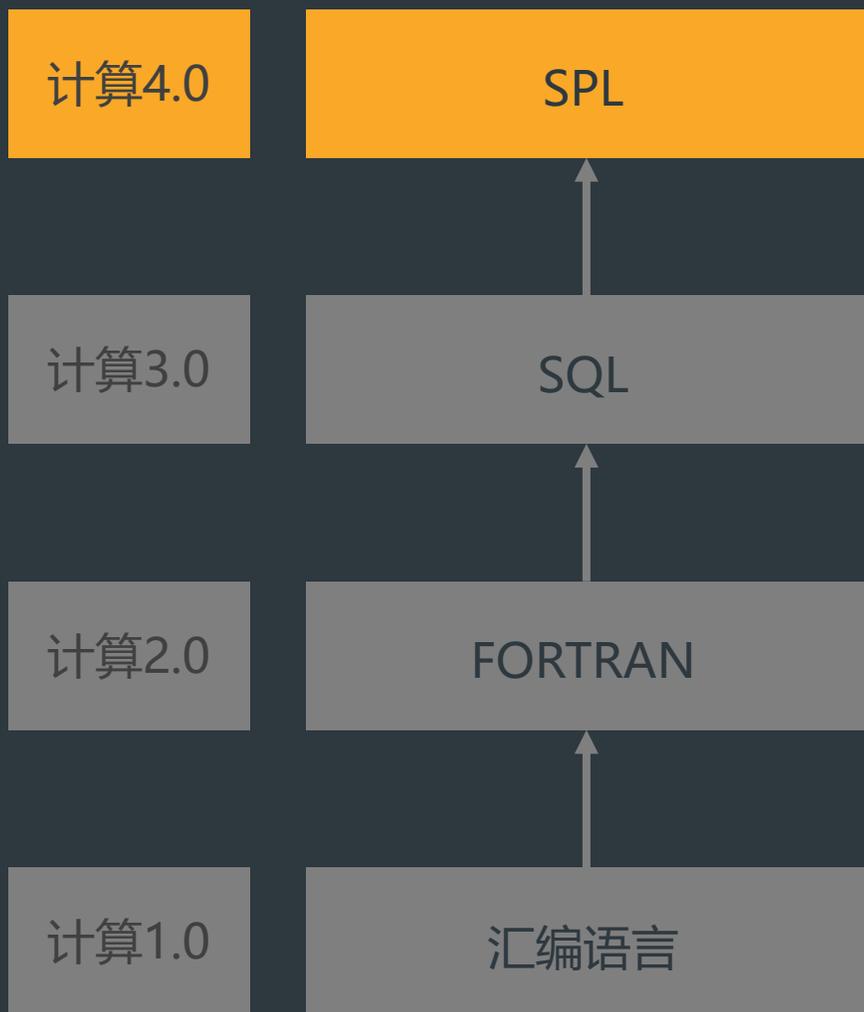
计算3.0-SQL

计算2.0-Fortran

计算1.0-汇编语言

|| 数据计算新时代

# 数据计算4.0



# 目录页

## CONTENTS

- ★ 01 背景介绍
- ★ 02 SPL
- ★ 03 运算模型
- ★ 04 工程实现
- ★ 05 应用场景
- ★ 06 计算实例



# SPL

---

Structured Process Language

面向过程的结构化数据计算语言

# ▶ SPL理论模型



**离散数据集模型**作为SPL的全新数学模型，全面改善了SQL在计算3.0时代的各种弊端，是计算4.0时代的重要理论基础

# 目录页

## CONTENTS

- ★ 01 背景介绍
- ★ 02 SPL
- ★ 03 运算模型
- ★ 04 工程实现
- ★ 05 应用场景
- ★ 06 计算实例

**集合化**

**离散性**

**深度集合化**

**有序性**

**SPL特性**

# 集合化



集合化

结构化数据总是批量形式

**集合运算库 · lambda语法 · 动态数据结构**

**SQL是集合化的语言**

WHERE, ORDER BY, GROUP

INTERSECT, UNION, MINUS

## 离散性



集合成员可以游离在集合外存在

独立运算或及其它游离成员再组合新集合运算

### SQL缺乏离散性

只有单行记录的表，没有游离记录

计算结果总是新产生，和原记录无关



### ⚙️ 人员表计算张三和李四的年龄差和收入差-SPL

|   | A                              |  |
|---|--------------------------------|--|
| 1 | =employee.select@1(name=="张三") |  |
| 2 | =employee.select@1(name=="李四") |  |
| 3 | =A1.age-A2.age                 |  |
| 4 | =A1.salary-A2.salary           |  |



## 人员表计算张三和李四的年龄差和收入差-SQL

|   |   |
|---|---|
| 1 | SELECT (SELECT age FROM employee WHERE name='张三')         |
| 2 | - (SELECT age FROM employee WHERE name='李四') FROM dual    |
| 3 | SELECT (SELECT salary FROM employee WHERE name='张三')      |
| 4 | - (SELECT salary FROM employee WHERE name='李四') FROM dual |

## 离散性应用



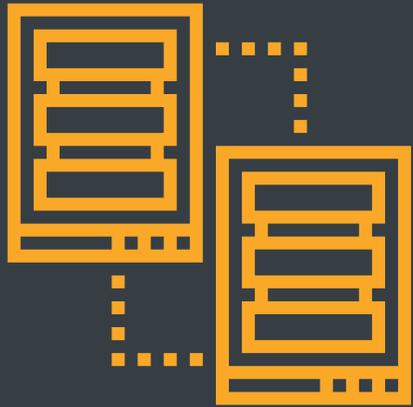
### 指定条件更新数据：业绩在前10%的代理商再奖励5%业绩

|   | A   |       |
|---|---|-------|
| 1 | =agent.sort@z(amount).to(agent.len()*0.1) | 取前10% |
| 2 | =A1.run(amount=amount*1.05)               | 奖励销售额 |

### 引用式外键：选出北京地区的交易记录

|   | A                         |              |
|---|---------------------------|--------------|
| 1 | >交易记录.switch(地区,地区表:编号)   | 建立外键引用       |
| 2 | =交易记录.select(地区.名称=="北京") | 用外键引用记录的字段过滤 |

## 深度集合化



彻底的集合化需要离散性的支持

允许游离成员组成新集合

**分组子集 · 非常规聚合 · 主子表**

## 分组子集 (一)



### 找出总分500分以上的学生的各科成绩记录

|   | A  |  |
|---|--|--|
| 1 | =成绩表.group(学生).select(~.sum(成绩)>=500).conj() |  |

有离散性后才能还原分组运算的本来面目

SQL没有游离记录构成的显式集合，无法保持分组结果，强迫聚合后要两次扫描并连接

|   |   |
|---|---|
| 1 | WITH T AS   |
| 2 | (SELECT 学生 FROM 成绩表 GROUP BY 学生 HAVING SUM(成绩)>500) |
| 3 | SELECT TT.* FROM T LEFT JOIN 成绩表 TT on T.学生=TT.学生   |

## 分组子集 (二)



### 用户在最后一次登录前三天内的登录次数

|   | A  |
|---|--|
| 1 | =登录表.group(uid;~.max(logtime):last,~.count(interval(logtime,last)<=3):num) |

针对分组子集的聚合运算较复杂时难以用简单聚合式写出，保留分组子集再结合分步计算则很容易  
SQL不能保持子集，要用子查询在原集上附加信息，导致多次计算

|   |  |
|---|--|
| 1 | WITH T AS  |
| 2 | (SELECT uid,max(logtime) last FROM 登录表 GROUP BY uid) |
| 3 | SELECT T. uid,T.last,count(TT.logtime)               |
| 4 | FROM T LEFT JOIN 登录表 TT ON T.uid=TT.uid              |
| 5 | WHERE T.last-TT.logtime<=3 GROUP BY T.uid,T.last     |

## 非常规聚合 (一)



### 列出用户首次登录的记录

|   | A                                 |  |
|---|-----------------------------------|--|
| 1 | =登录表.group(uid).(~.minp(logtime)) |  |

聚合运算不一定总是SUM/COUNT这些，还可以理解为取出某个成员  
有离散性时可以简单针对分组子集实施这种聚合

|   |   |
|---|---|
| 1 | SELECT * FROM   |
| 2 | (SELECT RANK() OVER(PARTITION BY uid ORDER BY logtime) rk, T.* FROM 登录表 T) TT |
| 3 | WHERE TT.rk=1   |

## 非常规聚合 (二)



### 列出每个用户最近一次登录间隔

|   | A   |          |
|---|---|----------|
| 1 | =登录表.groups(uid;top(2,-logtime))            | 最后2个登录记录 |
| 2 | =A1.new(uid,#2(1).logtime-#2(2).logtime:间隔) | 计算间隔     |

聚合函数返回值不一定是单值，也可以返回一个集合

彻底的集合化后很容易针对分组子集实施返回集合的聚合运算

|   |   |
|---|---|
| 1 | WITH T AS   |
| 2 | (SELECT RANK() OVER(PARTITION BY uid ORDER BY logtime DESC) rk, T.* FROM 登录表 T) |
| 3 | SELECT uid,(SELECT TT.logtime FROM TT where TT.uid=TTT.uid and TT.rk=1)         |
| 4 | -(SELET TT.logtim FROM TT WHERE TT.uid=TTT.uid and TT.rk=2) 间隔                  |
| 5 | FROM 登录表 TTT GROUP BY uid   |

# 主子表



## 由订单明细计算金额

|   | A                                       |          |
|---|---|----------|
| 1 | =订单表.derive(订单明细.select(编号==订单表.编号):明细) | 建立子表集合字段 |
| 2 | =A1.new(编号,客户,明细.sum(单价*数量):金额)         | 计算订单金额   |

字段取值也可以是个集合，从而轻松描述主子表，适应于多层结构数据

SQL没有显式集合数据，没有离散性也不能引用记录，要JOIN后再GROUP

|   |                                     |
|---|-------------------------------------|
| 1 | SELECT 订单表.编号, 订单表.客户, SUM(订单明细.价格) |
| 2 | FROM 订单表                            |
| 3 | LEFT JOIN 订单明细 ON 订单表.编号=订单明细.编号    |
| 4 | GROUP BY 订单表.编号, 订单表.客户             |

## 有序性



有序计算是集合化与离散性的结合物



运算不仅与数据本身有关，还和数据所在位置有关



**跨行引用 · 有序分组 · 位置利用**

## 有序计算



关系代数延用了数学上的无序集合概念

早期SQL要生成序号后JOIN才能实现有限的有序计算

### 计算股票的涨幅

|   |   |
|---|---|
| 1 | WITH T AS                               |
| 2 | (SELECT rownum 序号,交易日,收盘价               |
| 3 | FROM ( SELECT * FROM 股票 ORDER BY 交易日) ) |
| 4 | SELECT T1.交易日,T1.收盘价-T2.收盘价             |
| 5 | FROM T T1 JOIN T T2 ON T1.序号=T2.序号+1    |

SQL2003标准增加了窗口函数方便生成序号并引用相邻成员

|   |   |
|---|---|
| 1 | SELECT 交易日,收盘价-LAG(收盘价) OVER (ORDER BY 交易日) FROM 股票 |
|---|---|

## 跨行引用 (一)



### 由订单明细计算金额

|   | A   |
|---|---|
| 1 | =销售表.sort(产品,月份)  |
| 2 | =A1.select(if(产品==产品[-1],销售量/销售量[-1])>1.1 && 销售额/销售额[-1])>1.1)) |

集合有序后可直接提供跨行引用的方案

SQL窗口函数必须使用子查询才能实现跨行计算，多个跨行项要分别使用窗口函数

|   |   |
|---|---|
| 1 | WITH T AS   |
| 2 | (SELECT 销售量/LAG(销售量) OVER(PARTITION BY 产品 ORDER BY 月份) r1                   |
| 3 | (SELECT 销售额/LAG(销售额) OVER(PARTITION BY 产品 ORDER BY 月份) r2, A.*, FROM 销售表 A) |
| 4 | SELECT * FROM T WHERE r1>1.1 AND r2>1.1                                     |

## 跨行引用 (二)



### ⚙️ 计算每月前后各一个月的销售额移动平均值

|   | A   |
|---|---|
| 1 | =销售表.sort(月份).derive(销售额{-1,1}.avg()):移动平均) |

有序集合上容易提供跨行集合引用方案

SQL窗口函数只有简单的跨行引用，涉及集合要用成员去拼

|   |  |
|---|--|
| 1 | WITH B AS  |
| 2 | (SELECT LAG(销售额) OVER (ORDER BY 月份) f1, LEAD(销售额) OVER (ORDER BY 月份) f2, A.* FROM 销售表 A) |
| 3 | SELECT 月份,销售额,   |
| 4 | (NVL(f1,0)+NVL(f2,0)+销售额)/(DECODE(f1,NULL,0,1)+DECODE(f2,NULL,0,1)+1) 移动平均               |
| 5 | FROM B   |

## 有序分组 (一)



### ⚙️ 一批婴儿中连续出生的同性别人数超过5人的有多少组

|   | A  |
|---|--|
| 1 | =婴儿表.sort(生日).group@o(性别).count(~.len())>=5) |

分组可能和次序相关，不只是等值分组

有序集合上可以定义与次序有关的分组，考察值变化时即产生新组

|   |   |
|---|---|
| 1 | SELECT COUNT(*) FROM  |
| 2 | (SELECT 改变次数 FROM   |
| 3 | (SELECT SUM(改变标志) OVER ( ORDER BY 生日) 改变次数 FROM                                   |
| 4 | (SELECT CASE WHEN 性别=LAG(性别) OVER (ORDER BY 生日) THEN 0 ELSE 1 END 改变标志 FROM 婴儿表)) |
| 5 | GROUP BY 改变次数 HAVING COUNT(*)>=5)   |

## 有序分组 (二)



### ⚙️ 一支股票最长连续上涨了多少天

A

```
1 =股票.sort(交易日).group@i(收盘价<收盘价[-1]).max(~.len())
```

另一种和次序有关的分组，条件成立时产生新组

|   |  |
|---|--|
| 1 | SELECT max(连续日数)-1 FROM  |
| 2 | (SELECT count(*) 连续日数 FROM                                       |
| 3 | (SELECT SUM(涨跌标志) OVER ( ORDER BY 交易日) 不涨日数 FROM                 |
| 4 | ( SELECT 交易日,  |
| 5 | CASE WHEN 收盘价>LAG(收盘价) OVER( ORDER BY 交易日 THEN 0 ELSE 1 END 涨跌标志 |
| 6 | FROM 股票 ))   |
| 7 | GROUP BY 不涨日数)   |

## 混合情况



### 找出连续上涨三天的股票

|   | A   |
|---|---|
| 1 | =股票.sort(交易日).group(代码)                                       |
| 2 | =A1.select((a=0,~.pselect(a=if(收盘价>收盘价[-1],a+1,0):3))>0).(代码) |

### 分组子集与有序计算的组合

|   |  |
|---|--|
| 1 | WITH A AS  |
| 2 | (SELECT 代码,交易日, 收盘价-LAG(收盘价) OVER (PARTITION BY 代码 ORDER BY 涨幅) FROM 股票) |
| 3 | B AS   |
| 4 | (SELECT 代码,  |
| 5 | CASE WHEN 涨幅>0 AND   |
| 6 | LAG(涨幅) OVER (PARTITION BY 代码 ORDER BY 交易日) >0 AND                       |
| 7 | LAG(涨幅,2) OVER PARTITION BY 代码 ORDER BY 交易日) >0                          |
| 8 | THEN 1 ELSE 0 END 三天连涨标志 FROM A)   |
| 9 | SELECT distinct 代码 FROM B WHERE 三天连涨标志=1                                 |

## 位置利用 (一)



### ⚙️ 计算一组商品价格的中位数

|   | A   |
|---|---|
| 1 | =价格表.sort(价格).([(价格表.len()+1)\2,价格表.len()\2+1]).avg() |

有序集合可以直接用序号访问成员

SQL的无序集合需要人为制造出序号，不分步运算加剧了困难

|   |  |
|---|--|
| 1 | WITH N AS (SELECT COUNT(1) FROM 价格表)                     |
| 2 | SELECT AVERAGE(价格) FROM                                  |
| 3 | (SELECT 价格,ROW_NUMBER() OVER (ORDER BY 价格) r FROM 价格表) T |
| 4 | WHERE r=TRUNC((N+1)/2) OR r=TRUNC(N/2)+1                 |

## 位置利用 (二)



### 某股票股价最高的那三天的平均涨幅

|   | A   |
|---|---|
| 1 | =股票.sort(交易日)                               |
| 2 | =A1.calc(A1.ptop(3,-收盘价),收盘价-收盘价[-1]).avg() |

有序集合可以提供丰富的按位置访问机制

无序集合不能利用位置访问相邻成员，计算量增大，描述复杂度提高

|   |   |
|---|---|
| 1 | SELECT AVG(涨幅) FROM   |
| 2 | ( SELECT 交易日, 收盘价-LAG(收盘价) OVER ( ORDER BY 交易日) 涨幅 FROM 股价表   |
| 3 | WHERE 交易日 IN  |
| 4 | (SELECT 交易日 FROM  |
| 5 | (SELECT 交易日, ROW_NUMBER() OVER(ORDER BY 收盘价 DESC) 排名 FROM 股票) |
| 6 | WHERE 排名<=3 )   |

# 结构化数据计算总结



## 离散性与集合化的有效结合

集合化是批量计算的基本能力

离散计算也不可或缺

离散性支持更彻底的集合化

离散性产生有序集合运算

离散集合模型

=

集合运算

+

游离成员

=>

彻底集合化/有序集合

# 目录页

## CONTENTS

- ★ 01 背景介绍
- ★ 02 SPL
- ★ 03 运算模型
- ★ 04 工程实现
- ★ 05 应用场景
- ★ 06 计算实例

# 集算器



**集算器**是离散数  
据集的工程实现产品  
SPL作为集算器的形  
式化语言

# 开发环境



执行、调试执行、单步执行

设置断点

The screenshot shows the development environment interface. At the top, there is a menu bar with options like '文件(E)', '编辑(E)', '程序(P)', '工具(T)', '窗口(W)', and '帮助(H)'. Below the menu is a toolbar with icons for running, debugging, and stepping through code. The main area displays a code editor with the following code:

```
A2 = 1 =file("../demo\zh\tx\Sale.txt").import@t().select(month(Datetime)==6)
.....
1 =file("../demo\zh\tx\Stock.txt").import@t().select(month(Datetime)==6)
2 =file("../demo\zh\tx\Sale.txt").import@t().select(month(Datetime)==6)
3 =file("../demo\zh\tx\Storage.txt").import@t().select(month(Date)==5)
4 =file("../demo\zh\tx\Commodity.txt").import@t()
5 '08:00:00 '21:30:00
6 =periods@d(date("2009-6-1"), date("2009-6-30"), 1)
7 =A1.align@a(A6:~,date(Datetime))
8 =A2.align@a(A6:~,date(Datetime))
9 =A4.new(ID:Commodity,B:Stock,CosTime,B.TotalCosTime)
10 >A9 keys(Commodity)
```

Below the code editor is a data grid with columns A, B, C, and D. The grid contains several rows of data, including dates and times. To the right of the code editor is a separate window showing a data grid with columns 'Datetime', 'Commodity', and 'Volume'. The data in this grid is as follows:

| Datetime        | Commodity | Volume |
|-----------------|-----------|--------|
| 2009-06-01 08:0 | 20077     | 28     |
| 2009-06-01 08:1 | 20056     | 47     |
| 2009-06-01 08:1 | 20094     | 34     |
| 2009-06-01 08:2 | 20020     | 19     |
| 2009-06-01 08:4 | 20013     | 42     |
| 2009-06-01 08:4 | 20077     | 1      |
| 2009-06-01 08:5 | 20069     | 19     |
| 2009-06-01 09:0 | 20011     | 22     |
| 2009-06-01 09:0 | 20007     | 22     |

At the bottom of the interface, there is a '系统信息输出' (System Information Output) window showing the following text:

```
[2017-09-28 10:38:11]
DEBUG: Esproc Function Points = 1000 0001 1111 1101
```

网格结果所见即所得，易于调试；方便引用中间结果

语法简单，符合自然思维，比其他高级开发语言更简单

系统信息输出，异常随时查看

# 专门设计的语法体系



## 特别适合复杂过程运算

|    | A   | B                                     | C       | D      | E | F |
|----|---|---------------------------------------|---------|--------|---|---|
| 1  | =esProc.query("SELECT 订单ID AS 合同,订购日期 AS 日期,客户 ,订单金额 AS 金额,员工ID AS 销售 FROM 销售记录表 WHERE year(订购日期)=? OR year(订购日 |                                       |         |        |   |   |
| 2  | =esProc.query("select * from 员工表")  |                                       |         |        |   |   |
| 3  | >A1.run(销售=A2.select@1(编号:A1.销售))   |                                       | 字段值 是记录 |        |   |   |
| 4  | =A1.group(销售)   |                                       |         |        |   |   |
| 5  | =create(销售,今年销售额,去年销售额,增长率,客户数,大客户数,大客户占比)  |                                       |         |        |   |   |
| 6  | for A4  | =A6(1).销售.姓名                          |         |        |   |   |
| 7  |   | =A6.select(year(日期)==年份).sum(金额)      |         | /今年销售额 |   |   |
| 8  |   | =A6.select(year(日期)==年份-1).sum(金额)    |         | /去年销售额 |   |   |
| 9  |   | =B8/B7-1                              | /增长率    |        |   |   |
| 10 |   | =A6.group(客户)(~.sum(金额))              |         |        |   |   |
| 11 |   | =B10.count()                          |         |        |   |   |
| 12 |   | =B10.count(=10000)                    |         |        |   |   |
| 13 |   | =B12/B11                              |         |        |   |   |
| 14 |   | >A5.insert(0,B6,B7,B8,B9,B11,B12,B13) |         |        |   |   |
| 15 | result A5   |                                       |         |        |   |   |

天然分步、层次清晰、直接引用单元格名无需定义变量



# 丰富的运算类库



## 专门针对结构化数据表设计

|    | A  | B                                 | C        |
|----|--|-----------------------------------|----------|
| 1  | =esProc.query("SELECT 订单ID AS 合同,订购日期 AS |                                   | /读取销售记录表 |
| 2  | =A1.group(销售)                            |                                   |          |
| 3  | =create(销售,今年销售额,去年销售额,客户数,大客户数)         |                                   |          |
| 4  | for A2                                   | =A4(1).销售                         |          |
| 5  |  | =A4.select(year(日期)==年份).sum(金额)  |          |
| 6  |  | =A4.select(year(日期)-年份-1).sum(金额) |          |
| 7  |  | =A4.group(年份).sum(金额)             |          |
| 8  |  | =B7.count()                       |          |
| 9  |  | =B7.count(<=>=10000)              |          |
|    | A  | B                                 | C        |
| 1  | =esProc.query("select * from 员工表")       |                                   |          |
| 2  | =A1.select(性别=="男")                      |                                   |          |
| 3  | =A1.select(出生日期>=date("1970-01-01"))     |                                   |          |
| 4  | =A2^A3                                   | /交运算,统计晚于1970年出生的男员工              |          |
| 5  | =A2&A3                                   | /并运算,统计男员工或者晚于1970年出生的员工          |          |
| 6  | =A2\A3                                   | /运算,统计早于1970年出生的男员工               |          |
| 7  | =A4.sum(工资)                              |                                   |          |
| 8  | =A5.avg(年龄)                              |                                   |          |
| 9  | =A6.sort(出生日期)                           |                                   |          |
| 10 | /集合作为基本数据类型                              |                                   |          |
| 11 |  |                                   |          |

### 分组、循环

### 集合运算

|    | A  | B              | C |
|----|--|----------------|---|
| 1  | =file("交易记录.txt").import@t0                                |                |   |
| 2  | =A1.sort(客户编码,交易日期)  |                |   |
| 3  | =A2.select(车辆型号=="捷达"    车辆型号=="迈腾").dup@t0                |                |   |
| 4  | =A3.derive(interval(交易日期[-1],交易日期):间隔)                     |                |   |
| 5  | =A4.select(车辆型号[-1]=="捷达" && 车辆型号=="迈腾" && 客户编码==客户编码[-1]) |                |   |
| 6  | =A5.avg(间隔)  |                |   |
| 7  |  |                |   |
| 8  |  |                |   |
| 9  |  |                |   |
|    | A  | B              | C |
| 1  | =esProc.query("select * from 员工表")                         |                |   |
| 2  | =A1.sort(入职日期)   |                |   |
| 3  | =A2.pmin(出生日期)   | /出生最早的员工的记录序号  |   |
| 4  | =A2(to(A3-1))  | /直接用序号访问成员     |   |
| 5  | =esProc.query("select * from 股价表 where 股票代码='000062'")     |                |   |
| 6  | =A5.sort(交易日期)   |                |   |
| 7  | =A6.pmax(收盘价)  | /收盘价最高的那条记录的序号 |   |
| 8  | =A6.calc(A7.收盘价/收盘价[-1]-1)                                 |                |   |
| 9  |  |                |   |
| 10 | /直接用序号访问成员   |                |   |
| 11 |  |                |   |

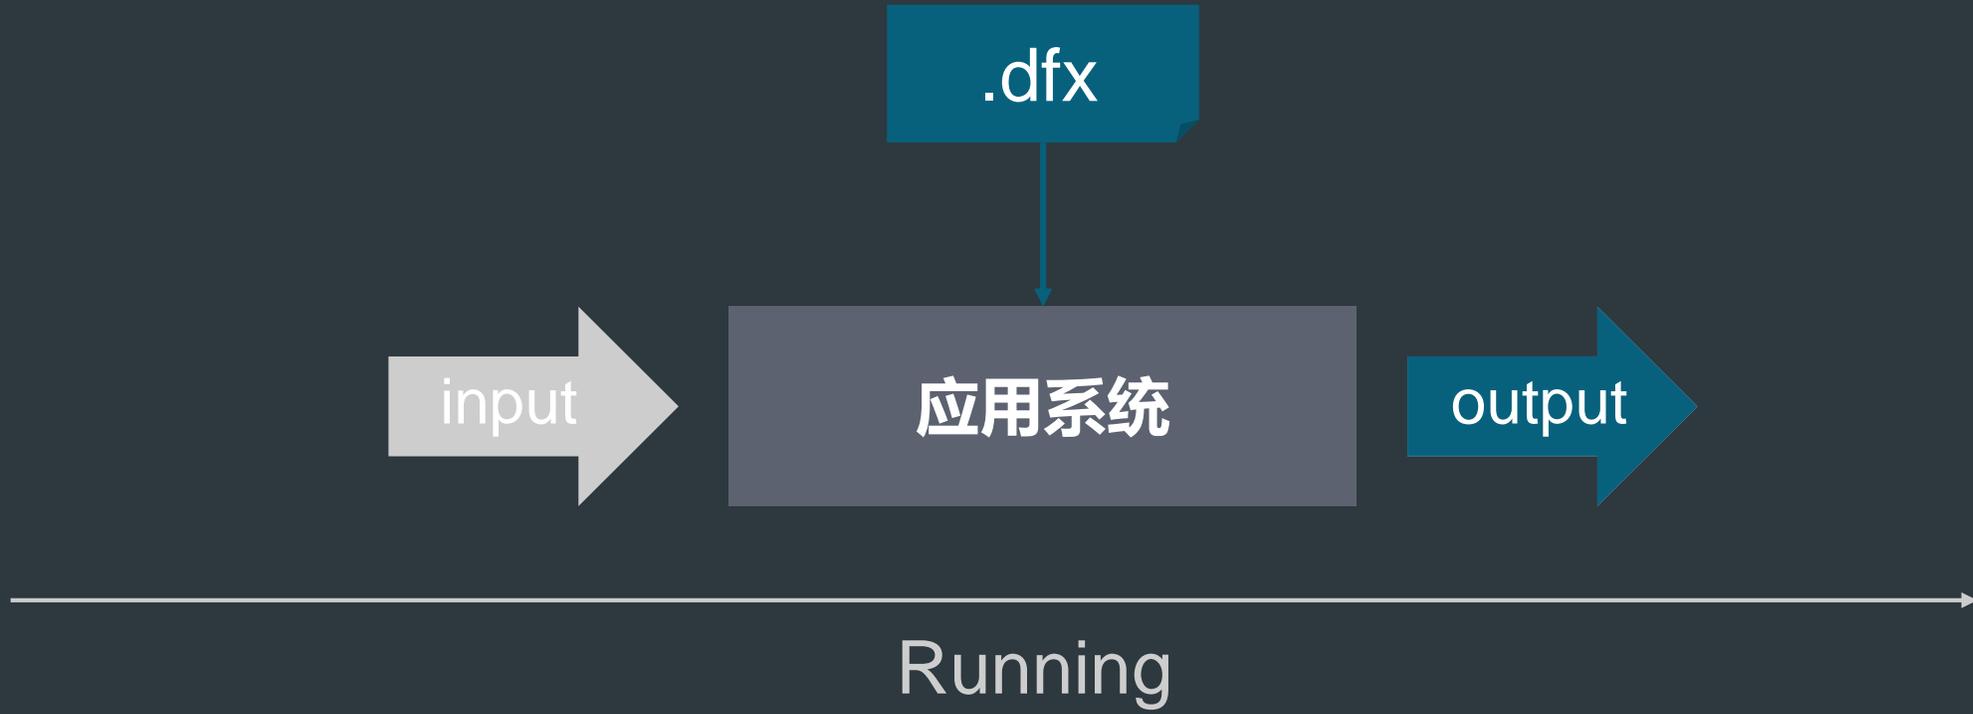
### 排序、过滤

### 有序集合

## 热切换



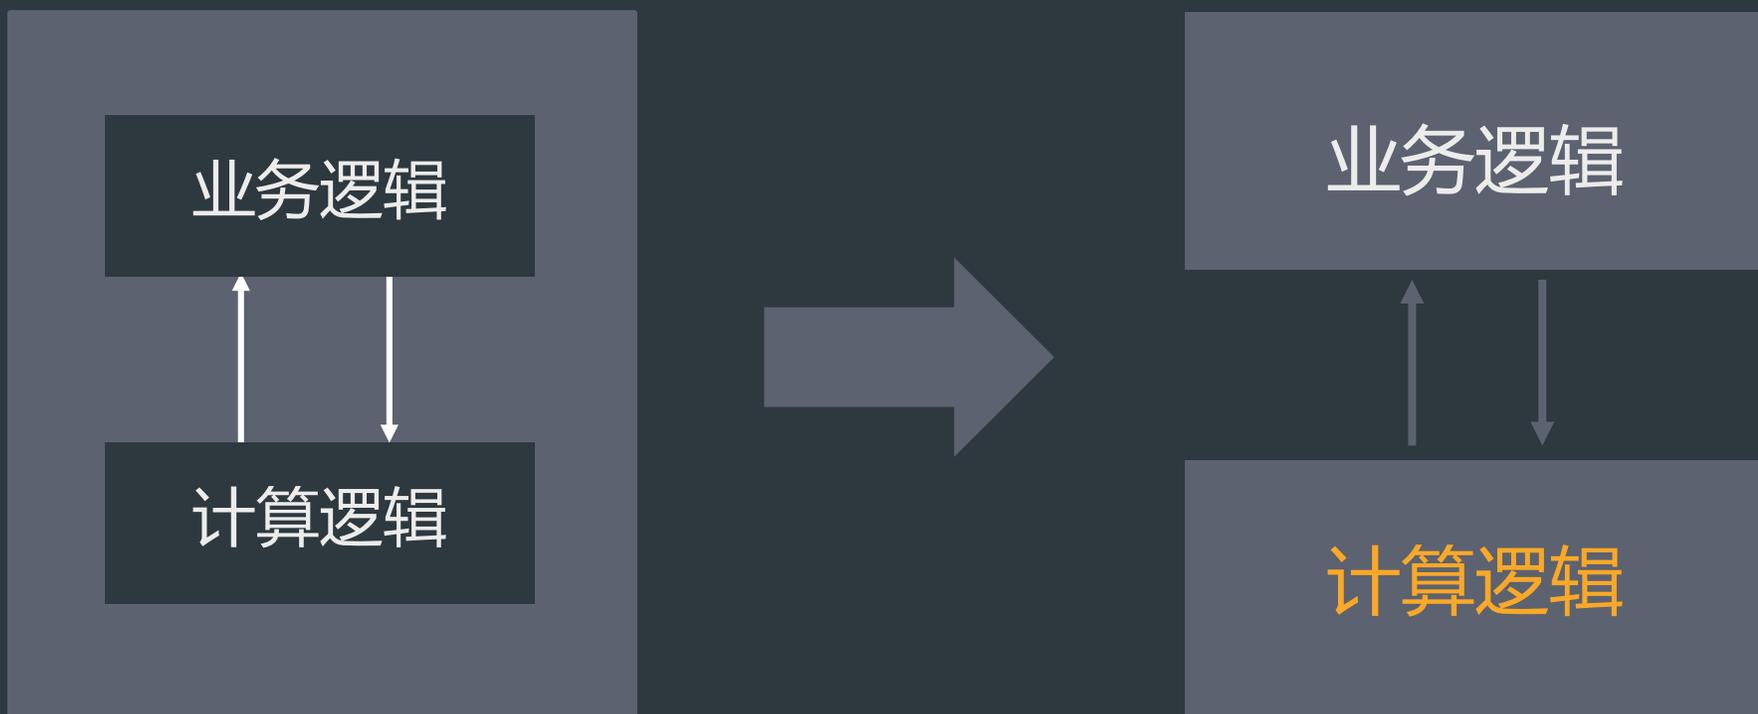
集算器脚本解释执行，支持不停机热切换



## 低耦合



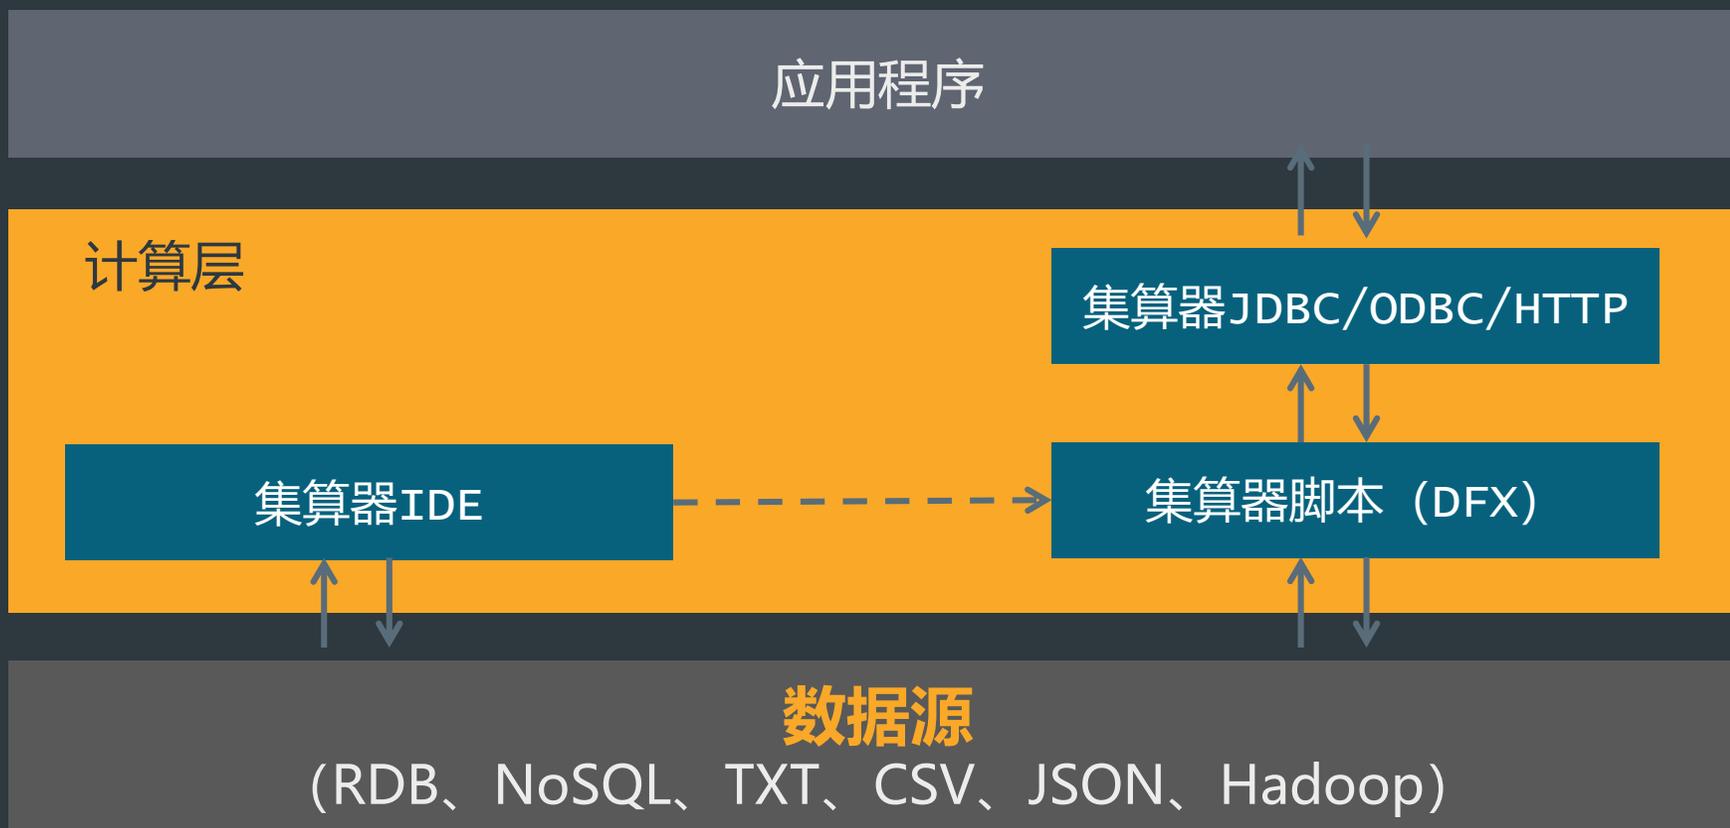
计算逻辑脚本单独维护，方便模块化



# 集成性



集算器使用JAVA开发，提供标准应用接口可无缝集成到应用中



## 多样性数据源



直接使用多个数据源混合计算，无需后台先将数据统一（ETL）后再计算

多源混算



SQLDB



NoSQLDB



File/HDFS



## 外部数据接口

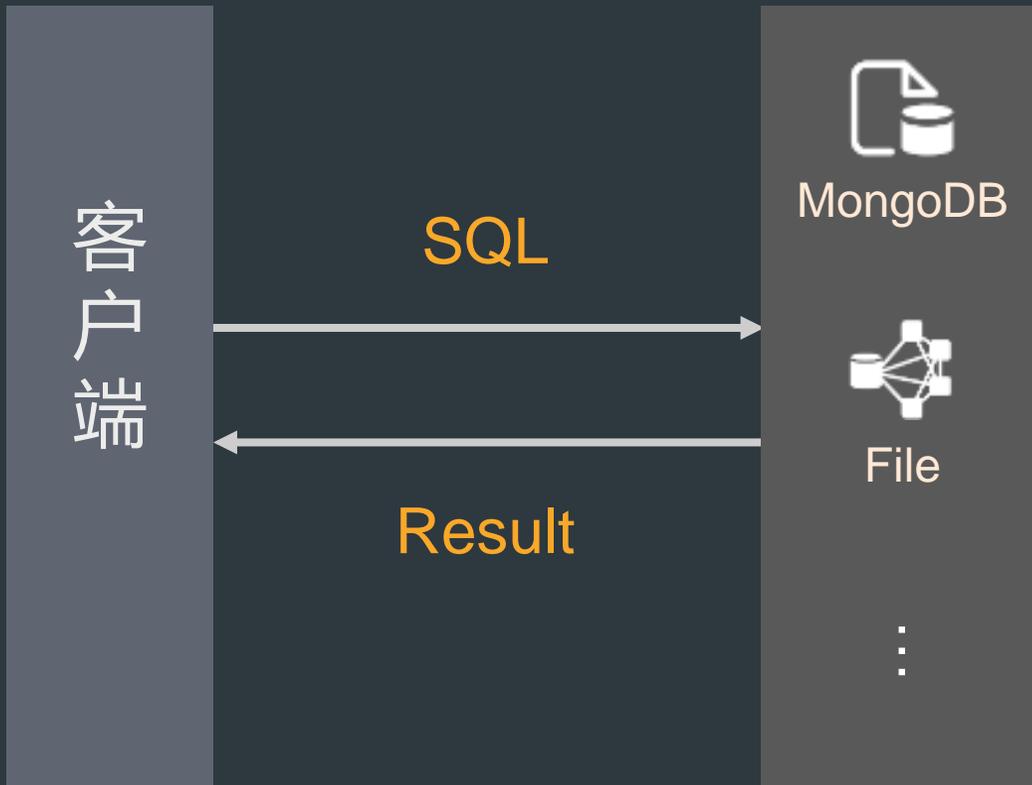
- RDB: Oracle, DB2, MS SQL, MySQL, PG, ....
- TXT/CSV, JSON/XML, EXCEL
- Hadoop: HDFS, HIVE, HBASE
- MongoDB, REDIS, ...
- HTTP、ALI-OTS
- ...

内置接口，即装即用

# 文件SQL查询



针对MongoDB和文件等使用SQL进行查询

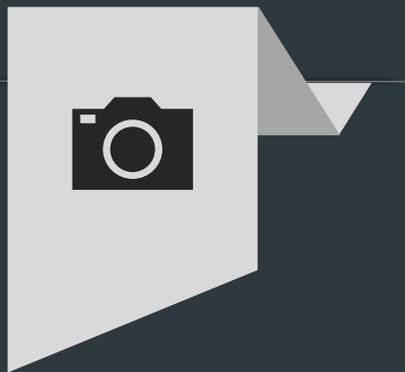


集算器赋予  
NoSQL和文件  
SQL查询能力

# 目录页

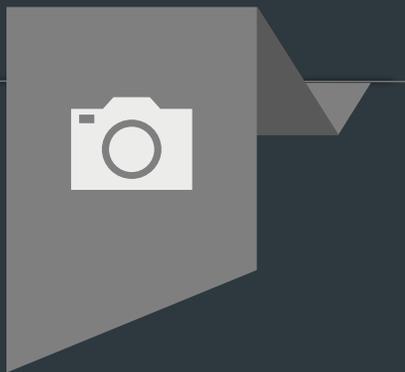
## CONTENTS

- ★ 01 背景介绍
- ★ 02 SPL
- ★ 03 运算模型
- ★ 04 工程实现
- ★ 05 应用场景
- ★ 06 计算实例



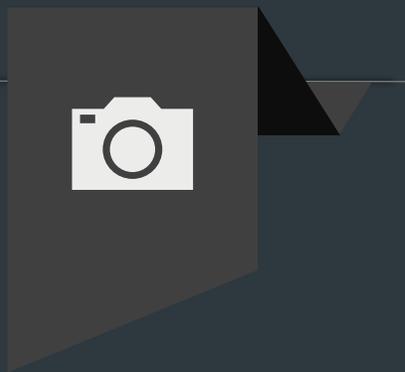
## 数据计算中间件

可集成到应用中作为数据计算层，为应用提供数据支持



## 挖掘前数据整理

整理数据挖掘前数据，以满足数据挖掘需要



## 临时计算

应对临时性查询和提数需求



## 桌面分析

单机桌面数据分析，使用更灵活

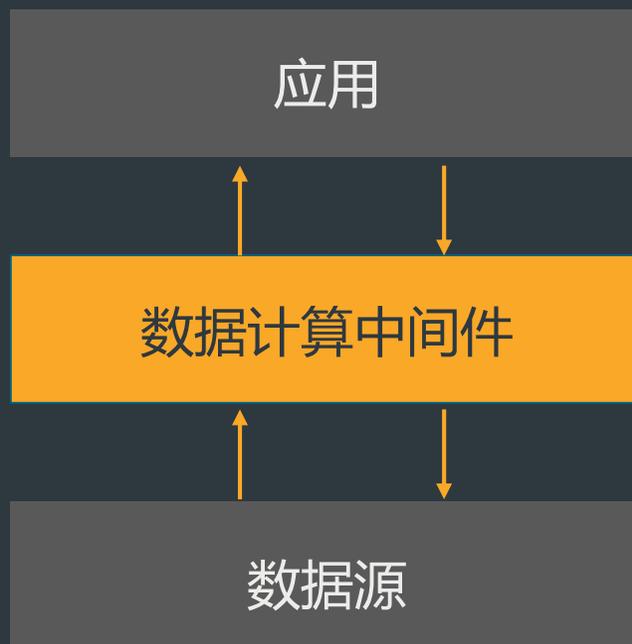


## 应用场景

## 数据计算中间件



位于数据源和应用之间提供通用计算服务，DCM (Data Computing Middleware)  
有效分担数据源压力、降低耦合性、提供开放计算能力



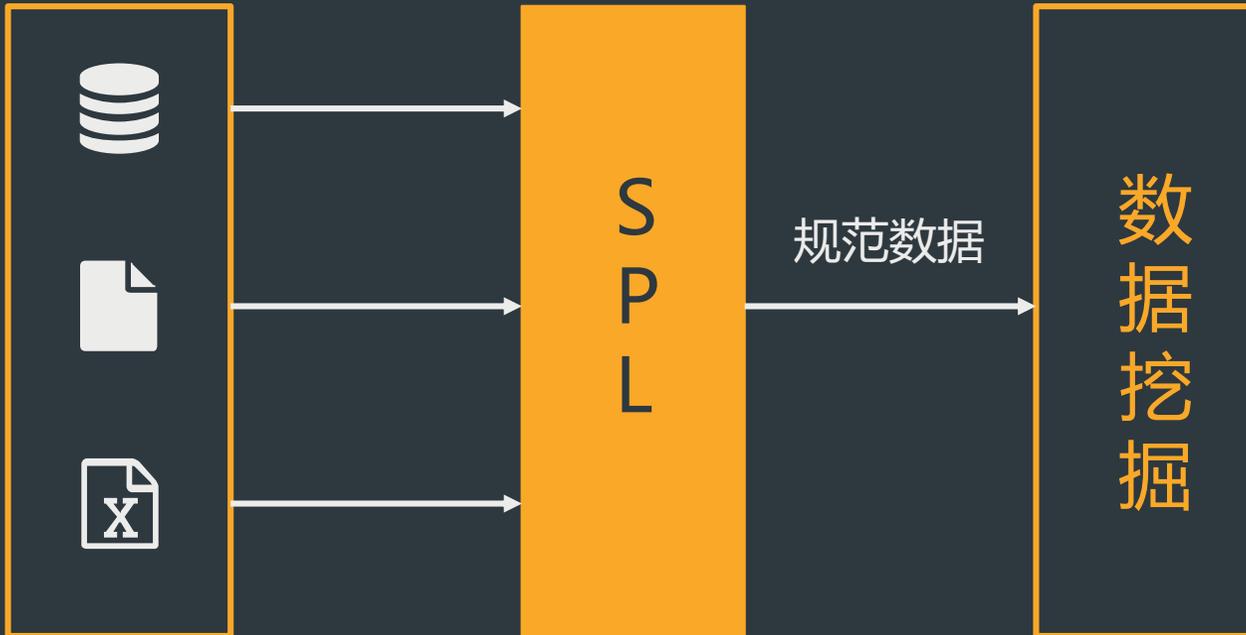
\*更多内容请参考<数据计算中间件.pptx>

## 挖掘前数据整理



数据整理通常占数据挖掘工作量一半以上

SPL提供开放、灵活简单的整理方式





### SPL开放计算能力可以很好满足临时性计算需求

应对业务部门的临时取数需求

即时进行的（外部）数据分析与考察

有业务规则的测试数据生成

大数据计算的优化方案实验

非日常（外部）数据清洗与入库

# 桌面分析



执行、调试执行、单步执行

设置断点

The screenshot shows the EsProc 3.1 IDE interface. At the top, there's a menu bar with options like '文件(E)', '编辑(E)', '程序(P)', '工具(T)', '窗口(W)', and '帮助(H)'. Below the menu is a toolbar with various icons for file operations and execution. The main editor area contains a script with the following lines:

```
A2 = 1 =file("../demo\zh\lxt\Sale.txt").import@t().select month(Datetime)==6
.....
1 =file("../demo\zh\lxt\Stock.txt").import@t().select(month(Datetime)==6)
2 =file("../demo\zh\lxt\Sale.txt").import@t().select(month(Datetime)==6)
3 =file("../demo\zh\lxt\Storage.txt").import@t().select(month(Date)==5)
4 =file("../demo\zh\lxt\Commodity.txt").import@t()
5 '08:00:00 '21:30:00
6 =periods@d(date("2009-6-1"), date("2009-6-30"), 1)
7 =A1.align@a(A6:~,date(Datetime))
8 =A2.align@a(A6:~,date(Datetime))
9 =A4.new(ID:Commodity,8:Stock,8:CosTime,8:TotalCosTime)
10 >A9 keys(Commodity)
```

Below the script editor is a data grid with columns A, B, C, and D. The grid contains data for rows 1 through 10. Row 2 is highlighted in green. To the right of the grid is a detailed view of the data for row A2, showing columns Datetime, Commodity, and Volume. The data in this view is as follows:

| Datetime        | Commodity | Volume |
|-----------------|-----------|--------|
| 2009-06-01 08:0 | 20077     | 28     |
| 2009-06-01 08:1 | 20056     | 47     |
| 2009-06-01 08:1 | 20094     | 34     |
| 2009-06-01 08:2 | 20020     | 19     |
| 2009-06-01 08:4 | 20013     | 42     |
| 2009-06-01 08:4 | 20077     | 1      |
| 2009-06-01 08:5 | 20069     | 19     |
| 2009-06-01 09:0 | 20011     | 22     |
| 2009-06-01 09:0 | 20007     | 22     |

At the bottom of the IDE, there is a '系统信息输出' (System Information Output) window. It contains the following text:

```
[2017-09-28 10:38:11]
DEBUG: Esproc Function Points = 1000 0001 1111 1101
```

网格结果所见即所得，易于调试；方便引用中间结果

语法简单，符合自然思维，比其他高级开发语言更简单

系统信息输出，异常随时查看

# 目录页

## CONTENTS

- ★ 01 背景介绍
- ★ 02 SPL
- ★ 03 运算模型
- ★ 04 工程实现
- ★ 05 应用场景
- ★ 06 计算实例

# 计算代码举例



## 文本计算

无结构计算  
结构化计算  
类文本数据



## 数据库计算

分组  
序运算  
字串与日期

# 无结构运算-文本解析 (一)



实际需求

文本T.txt的行内数据项由不确定数量的空格分隔开:

2010-8-13 991003 3166.63 3332.57 3166.63 3295.11

2010-8-10 991003 3116.31 3182.66 3084.2 3140.2

.....

现在要计算每行最后四项数据的平均值列表。

|   | A   |
|---|---|
| 1 | <code>=file("T.txt").read@n().(~.split@tp(" ").to(-4).avg())</code> |

`read@n()`将文本读入成字符串集合, `split@t(" ")`将字符串按不定数量的空白符拆成子串集合, `@p`将自动解析成合适的数据类型以便进一步计算 (这里计算平均)。

# 无结构运算-结构化 (一)



实际需求

日志S.log中每3行构成一段完整信息  
需要将其解析成结构化数据后再保存到T.txt

|     | A                         | B               |                   |
|-----|---------------------------|-----------------|-------------------|
| 1   | =file("S.log").read@n()   |                 |                   |
| 2   | =create(...)              |                 | 建立目标结果集           |
| 3   | for A1.group((#-1)\3)     | ...             | 按行号分组, 每3行一个单位    |
| ... |                           | ...             | 从A3 (这3行) 中解析出字段值 |
| ... |                           | >A2.insert(...) | 插入到目标结果集          |
| ... | >file("T.txt").export(A2) |                 | 写出结果              |

有了按行号分组的机制, 就可以用循环每次处理一组数据, 简化难度。显然, 更简单的单行情况是其特例

# 无结构运算-查找统计 (一)



实际需求

grep是常用命令，但有些OS没有，用程序中实现也不简单。

当前目录下有很多文本文件

找出含有指定单词的文件，并列出行内容及行号

|   | A  |
|---|--|
| 1 | =directory@p("* .txt")   |
| 2 | =A1.conj(file(~).read@n().(if(pos(~,"xxx"),[A1.~,#,~].string()))).select(~)) |

集算器提供了**文件系统的遍历功能**，结合文本计算能力，只要两句代码就能完成。

# 结构化运算-读入控制 (一)



实际需求

D.csv(逗号分隔)文件中有多列,每列都有标题

需要读入4列:name,sex,age,phone; 其中phone是全数字但必须读成字符串类型

|   | A  |  |
|---|--|--|
| 1 | <code>=file("D.csv").import@tc(name,sex,age,phone:string)</code> |  |

import函数有丰富的参数和选项控制是否有标题、分隔符、读入的列及其数据类型,大部分结构化文本的读入可以一句完成。

相当于把文本当作数据库表读入

## 结构化运算-常规运算 (一)



实际需求

从文本D.csv中找出男25岁以上、女23岁以上的人：

1) 按姓名排序列出； 2) 按性别分组计算平均年龄； 3) 列出所有出现过的姓氏（不考虑复姓）。

|   | A  |      |
|---|--|------|
| 1 | =file("D.csv").import@tc(name,sex,age)             |      |
| 2 | =A1.select(sex=="男"&& age>=25  sex=="女"&& age>=23) | 过滤   |
| 3 | =A2.sort(name)                                     | 排序   |
| 4 | =A2.groups(sex;avg(age):age)                       | 分组汇总 |
| 5 | =A2.id(left(name,1))                               | 唯一值  |

集算器提供了丰富的结构化计算功能。

一定程度上可以**将文本作为数据库表进行运算**，无数据库也能获得类似SQL的计算能力。

# 结构化运算-文件对比 (一)



实际需求

文本文件T1.txt和T2.txt都有id列

找出T1.txt和T2.txt中共有的id值

找出T1.txt中有, T2.txt中没有的id值

|   | A                             |                   |
|---|-------------------------------|-------------------|
| 1 | =file("T1.txt").import@ti(id) | @i结果只有一列时返回成序列    |
| 2 | =file("T2.txt").import@ti(id) |                   |
| 3 | =A1^A2                        | 交集, 即T1和T2共有的值    |
| 4 | =A1\A2                        | 差集, 即T1中有而T2中没有的值 |

比对列值直接用**集合交**、**差运算**即可。

# 类文本数据-json



实际需求

Java有足够多的类库用于解析和生成json，但缺乏后续计算能力。集算器支持多层结构数据，可以不丧失信息地将json解析成可计算的内存数据表进一步处理。

```
{
  "order": [
    {
      "client": "北京润乾软件",
      "date": "2015-6-23",
      "item": [
        {"product": "HP笔记本", "number": 4, "price": 3200},
        {"product": "DELL服务器", "number": 1, "price": 22100}
      ], ...
    }
  ]
}
```

Json数据要写入数据库中：

order表，结构为：orderid,client,date；

orderdetail表，结构为：orderid,seq,product,number,price

其中：orderid和seq按顺序生成即可。

# 类文本数据-json



```
{
  "order": [
    {
      "client": "北京润乾软件",
      "date": "2015-6-23",
      "item": [
        {"product": "HP笔记本", "number": 4, "price": 3200},
        {"product": "DELL服务器", "number": 1, "price": 22100}
      ], ...
    }
  ]
}
```

|   | A  |  |
|---|--|--|
| 1 | =file("data.json").read().import@j().order             |  |
| 2 | =A1.new(#:orderid,client,date)                         |  |
| 3 | =A1.news(item;A1.#:orderid,#:seq,product,number,price) |  |
| 4 | >db.update@i(A2,order)                                 |  |
| 5 | >db.update@i(A3,ordededetail)                          |  |

# 类文本数据-Excel



## 实际需求

Excel相当于已经结构化的文本。Java有能解析xls的开源类库（如poi），功能强大但过于底层，开发复杂度高。

集算器封装了poi，可读入xls转成二维数据表再进一步运算。

- position.xls保存“点”的位置，range.xls保存“范围”的起止位置
- 对position中的每个“点”在range中找到包含这个“点”的第一个“范围”
- 将“点”和对应的“范围”写到result.xls中。后。

| range.xls |       |       | position.xls |          |
|-----------|-------|-------|--------------|----------|
| range     | start | stop  | Point        | position |
| Range1    | 4561  | 6321  | point1       | 5213     |
| Range2    | 9842  | 11253 | point2       | 10254    |
| ...       |       |       | ...          |          |

## 类文本数据-Excel



| range.xls |       |       | position.xls |          |
|-----------|-------|-------|--------------|----------|
| range     | start | stop  | Point        | position |
| Range1    | 4561  | 6321  | point1       | 5213     |
| Range2    | 9842  | 11253 | point2       | 10254    |
| ...       |       |       | ...          |          |

|   | A  |
|---|--|
| 1 | =file("range.xls").importxls@t()   |
| 2 | =file("position.xls").importxls@t()  |
| 3 | =A2.derive((t=A1.select@1(position >= start && position <= stop)).range:range,<br>t.start:start,t.stop:stop) |
| 4 | =file("result.xls").exportxls(A3)  |

**集算器读入xls后可以充分利用已有的计算能力。**

用Excel自带的VBA只能硬编码实现JOIN，非常繁琐，有时不得不导入数据库来做。

# 动态列-列间统计



实际需求

体育测验表结构为：姓名、短跑、长跑、跳远、铅球、...；成绩分为优秀、良好、及格、不及格四档，现在要统计各档次在所有项目上的人数合计。

|   | A                              |                 |
|---|--------------------------------|-----------------|
| 1 | =db.query("select * from 测验表") |                 |
| 2 | =A1.conj(~.array().to(2,))     | 从第2字段的各项目成绩合并起来 |
| 3 | =A2.groups(~:成绩;count(1):数量)   | 分组汇总            |

集算器可以将多列作为一个集合，方便处理列数不确定的情况。



# 动态列-转置计算



| 序号  | 帐户 | 状态 | 发生日期      |
|-----|----|----|-----------|
| 1   | A  | 透支 | 2014-1-4  |
| 2   | A  | 正常 | 2014-1-8  |
| 3   | A  | 挂失 | 2014-3-21 |
| ... |    |    |           |



| 帐户  | 1 | 2 | 3 | 4  | 5  | 6  | 7  | 8  | 9  | ... | 31 |
|-----|---|---|---|----|----|----|----|----|----|-----|----|
| A   |   |   |   | 透支 | 透支 | 透支 | 透支 | 正常 | 正常 | ... | 正常 |
| ... |   |   |   |    |    |    |    |    |    |     |    |

|   | A  | B                       |
|---|--|-------------------------|
| 1 | =db.query("select * from T where year(日期)=? and month(日期)=?",2014,1) |                         |
| 2 | =create(帐户,\${to(31).concat@c()})                                    |                         |
| 3 | for A1.group(帐户)   | =31.(null)              |
| 4 |  | >A3.run(B3(day(日期))=状态) |
| 5 |  | >B3.run(~=ifn(~,~[-1])  |
| 6 |  | >A2.record(A3.帐户 B3)    |
| 7 | return A2  |                         |

转置标准流程：A2中先用宏生成目标结果集，再在A3-B6的循环中将数据变换后插入到结果集

# 分组-非等值分组 (一) 按段分组



实际需求

按段分组：如成绩段（优秀、良好...），年龄段（青年、中年...）等。

集算器penum函数可返回枚举条件的序号：

```
["?<60", "?>=60&&?<75", "?>=75&&?<90", "?>=90"].penum(成绩)
```

连续分段可以用pseg函数更简单地获得分段序号：`[60,75,90].pseg(成绩)`

上述条件和分段都是普通数组，可作为参数传递进来，长度不限制

基于分段号即可将枚举分组和按段分组转变成普通的等值分组



## 分组-非等值分组 (二) 对齐

实际需求

分组时要按指定的次序而不是数据本身排序，比如中国省份排列时一般要将北京放在第一个。

- 集算器提供了align@s函数专门用于对齐排序：  
`T.align@s(["北京","河北","山东",...],地区)`
- 将表T以字段地区按指定的次序排序
- 排序依据是个普通数据，可以作为参数传递

## 分组-逆分组



实际需求

分期付款表结构为：编号、总金额、起始日、总期数；  
要将每笔贷款拆分成多期记录，结构为：编号、期数、还款日、金额。总金额  
将简单地平均分配到每一期，一期为一个月。

|   | A   |
|---|---|
| 1 | =db.query("select * from 分期付款表")                      |
| 2 | =A1.news(总期数;编号,~:期数,after@m(起始日,~-1):还款日,总金额/总期数:金额) |

news：计算序列字段值合并生成新序表，一行变多行。

## 字串与日期-字串 (一)



### 实际需求

拼串任务：设有**学生表**结构为：班级、姓名、性别；  
要按**班级分组**后将男生和女生分别列成**逗号分隔的串**，串成员按姓名排序

|   | A  |
|---|--|
| 1 | =db.query("select * from 学生表")   |
| 2 | =A1.group(班级; ~.select(性别=="男").(姓名).sort().concat@c():男生,<br>~.select(性别=="女").(姓名).sort().concat@c():女生) |

集算器有集合数据，**无需专门针对分组的拼串函数**，可以随意组合出各种运算。

## 字串与日期-日期 (一)



实际需求

设有旅行记录表结构为：人员、开始日、结束日、...；  
现在要统计这批记录中哪5天正在旅行的人数最多。

|   | A   |
|---|---|
| 1 | =db.query("select 开始日,结束日 from 旅行表")                |
| 2 | =A1.conj(periods(开始日,结束日)).groups(~:日期,count(1):人次) |
| 3 | =A2.sort(人次:-1).to(5)                               |

集算器提供日期拆分函数periods，完成这个问题就很轻松。



---

# THANKS

创新技术 推动应用进步

