

# 主讲简介

- 郭宁
- 数据处理, 4 年左右 (2012年初起)
- 涉及领域:
  - 数据挖掘算法
  - 数据平台架构
- 论文:
  - *Soft-CsGDT: soft cost-sensitive Gaussian decision tree for cost-sensitive classification of data streams*, In Proc. of BigMine Workshop of ACM SIGKDD, 11-14 August 2013, Chicago, IL, USA.



# 海量数据处理

## ——关键思想

郭宁@美团

2016/10/14

[guoning.gn@gmail.com](mailto:guoning.gn@gmail.com)

# 目录

- 数据特征：海量数据处理 vs. 普通数据处理
- 基本原理：海量数据处理，典型场景和关键过程
- 关键思想：
  - 分发计算
  - 机架感知
- 本质分析

# 海量数据特征

- 背景：
  - 海量数据处理之前，就有数据处理
  - 海量数据处理，有什么独特之处？
- 海量数据，特点：
  - 数据量大：远超单节点存储能力
  - 高速到达：存量数据是海量，增量数据也是海量的
  - 数据多样化：
    - 结构化特征不明显
    - 冗余信息多
    - 容错数据多：举例：系统升级，交易日志格式变更；服务降级，产生容错数据；

# 海量数据特征

201.158.69.116 - - [03/Jan/2013:21:17:20 -0600] fwf[-] tip[-] 127.0.0.1:9000 0.007 0.007 MX pythontab.com GET /html/test.html HTTP/1.1 "200" 2426 "http://a.com" "es-ES,es;q=0.8" "Mozilla/5.0 (Windows NT 6.1) AppleWebKit/537.11 (KHTML, like Gecko) Chrome/23.0.1271.97 Safari/537.11"

187.171.69.177 - - [03/Jan/2013:21:17:20 -0600] fwf[-] tip[-] 127.0.0.1:9000 0.006 0.006 MX pythontab.com GET /html/test2.html HTTP/1.1 "aaa" 2426 "http://a.com" "es-ES,es;q=0.8" "Mozilla/5.0 (Windows NT 6.1) AppleWebKit/537.11 (KHTML, like Gecko) Chrome/23.0.1271.97 Safari/537.11"

容错数据：本来应该为 http status code，但出现非法数据。

# 目录

- 数据特征：海量数据处理 vs. 普通数据处理
- 基本原理：海量数据处理，典型场景和关键过程
- 关键思想：
  - 分发计算
  - 机架感知
- 本质分析

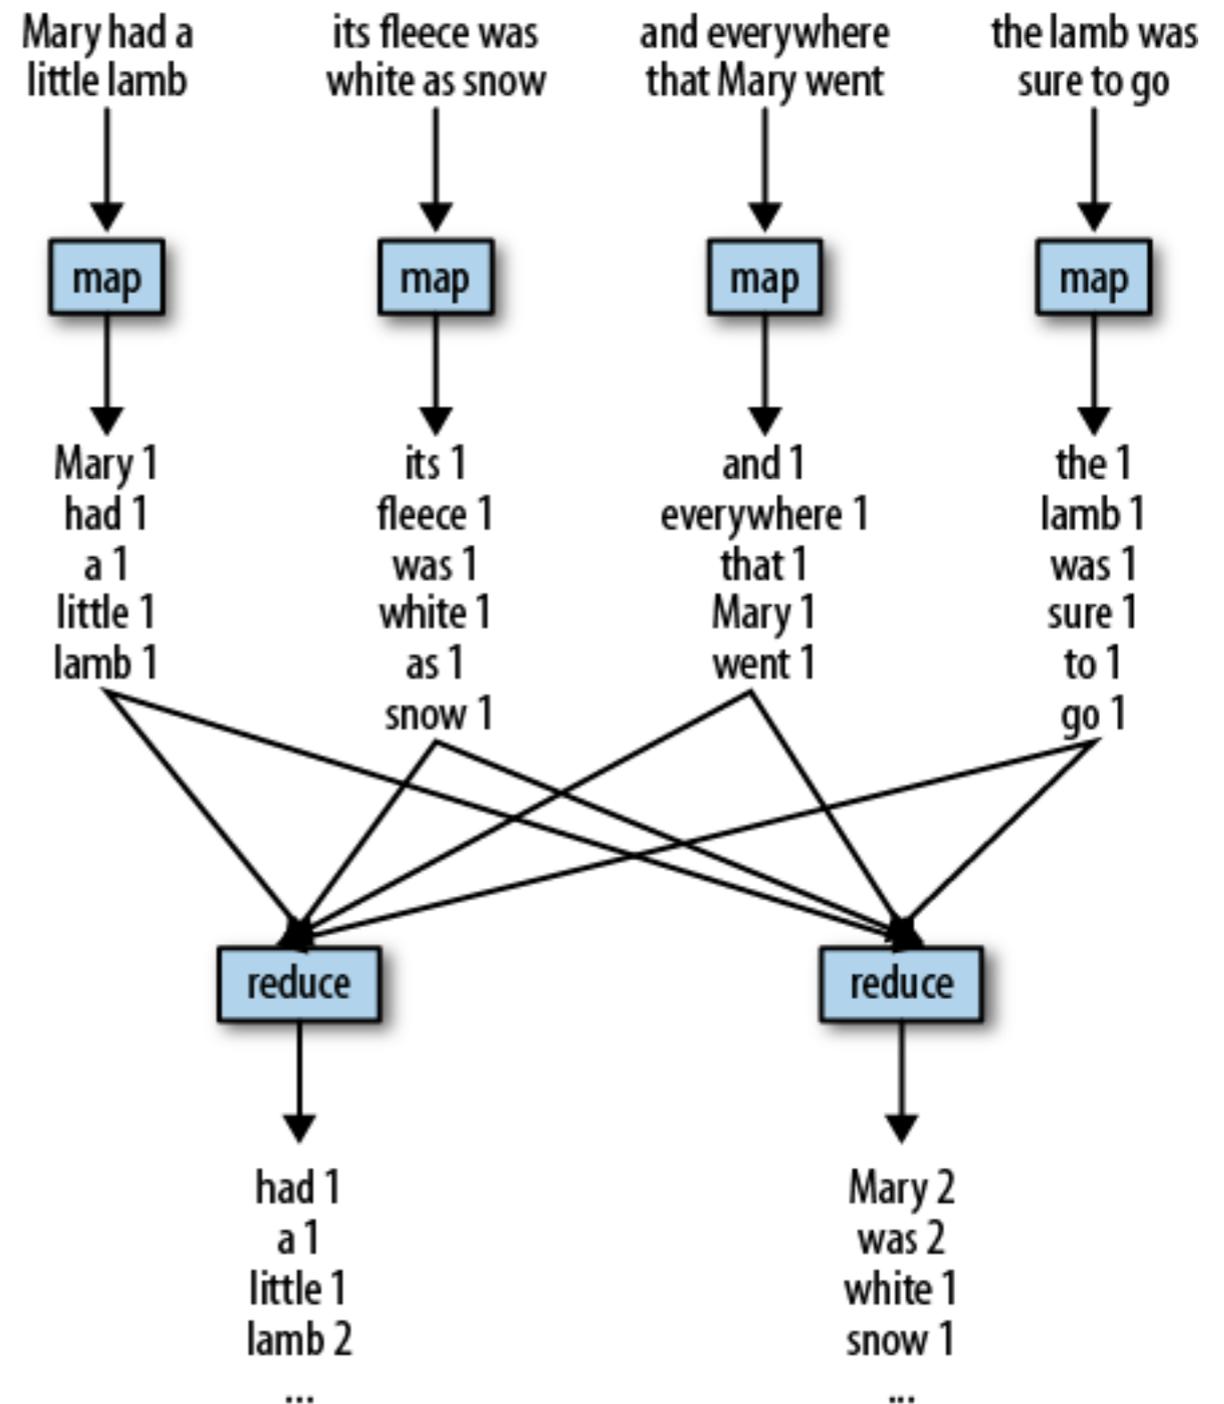
# 基本原理：典型场景

- 场景：
  - 词频统计
  - 统计右侧文本中，所有单词出现的频率。

Mary had a little lamb  
its fleece was white as snow  
and everywhere that Mary went  
the lamb was sure to go.

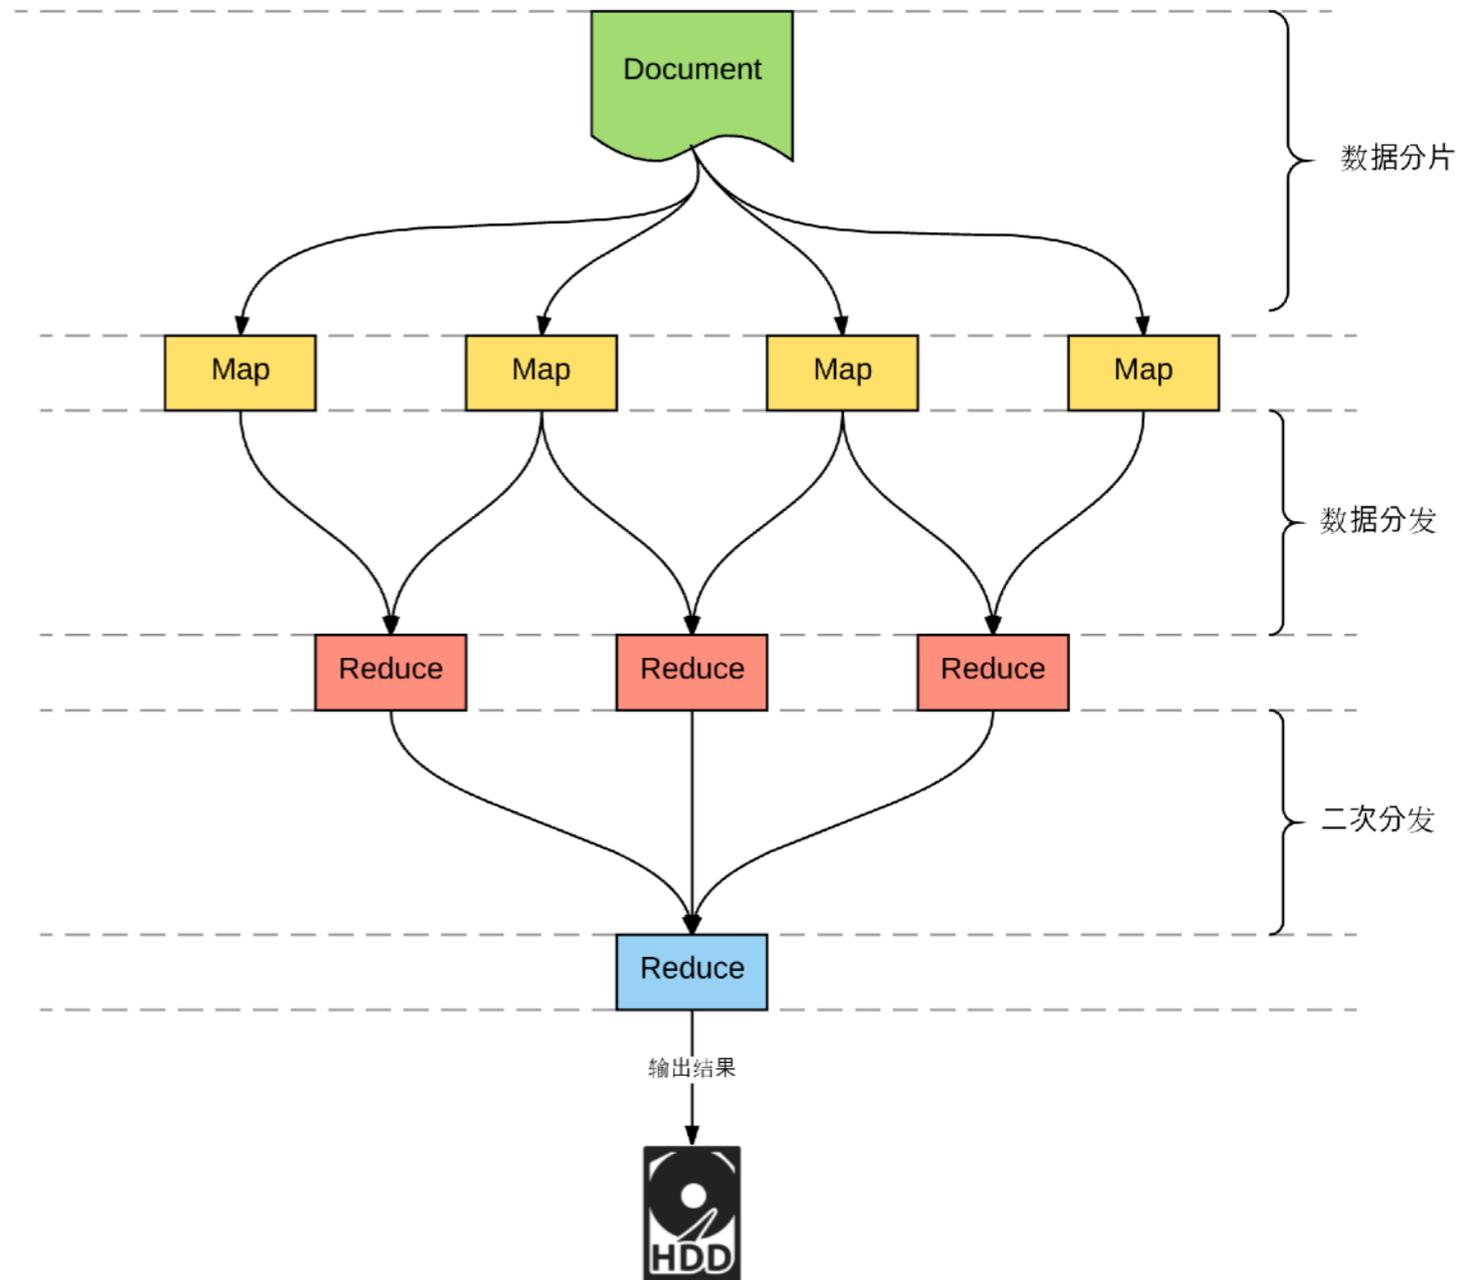
# 基本原理：典型场景

- 解决方式：常说的 MR
  - Map:
    - 输入？
    - 输出？
    - 作用？ 数据处理，快速的数据处理，通常处理逻辑简单
  - Reduce:
    - 输入？
    - 输出？ 输出的数据单元  $\leq$  输入数据单元数量
    - 作用？ 对 map 结果进行聚合、收敛



# 基本原理：关键过程

- 实际上，上述场景包含更丰富的内容：
  - **分片** (Partition) :
    - Map 之前的数据切割、分片
  - **分发** (Shuffle) :
    - Map 之后，将 Map 结果 shuffle 到特定的 Reduce 进行聚合
  - **Multi-MapReduce** :
    - 一次 MR 之后，通常还没有结束，会再次进行 Map 或 Reduce



# 基本原理：关键过程

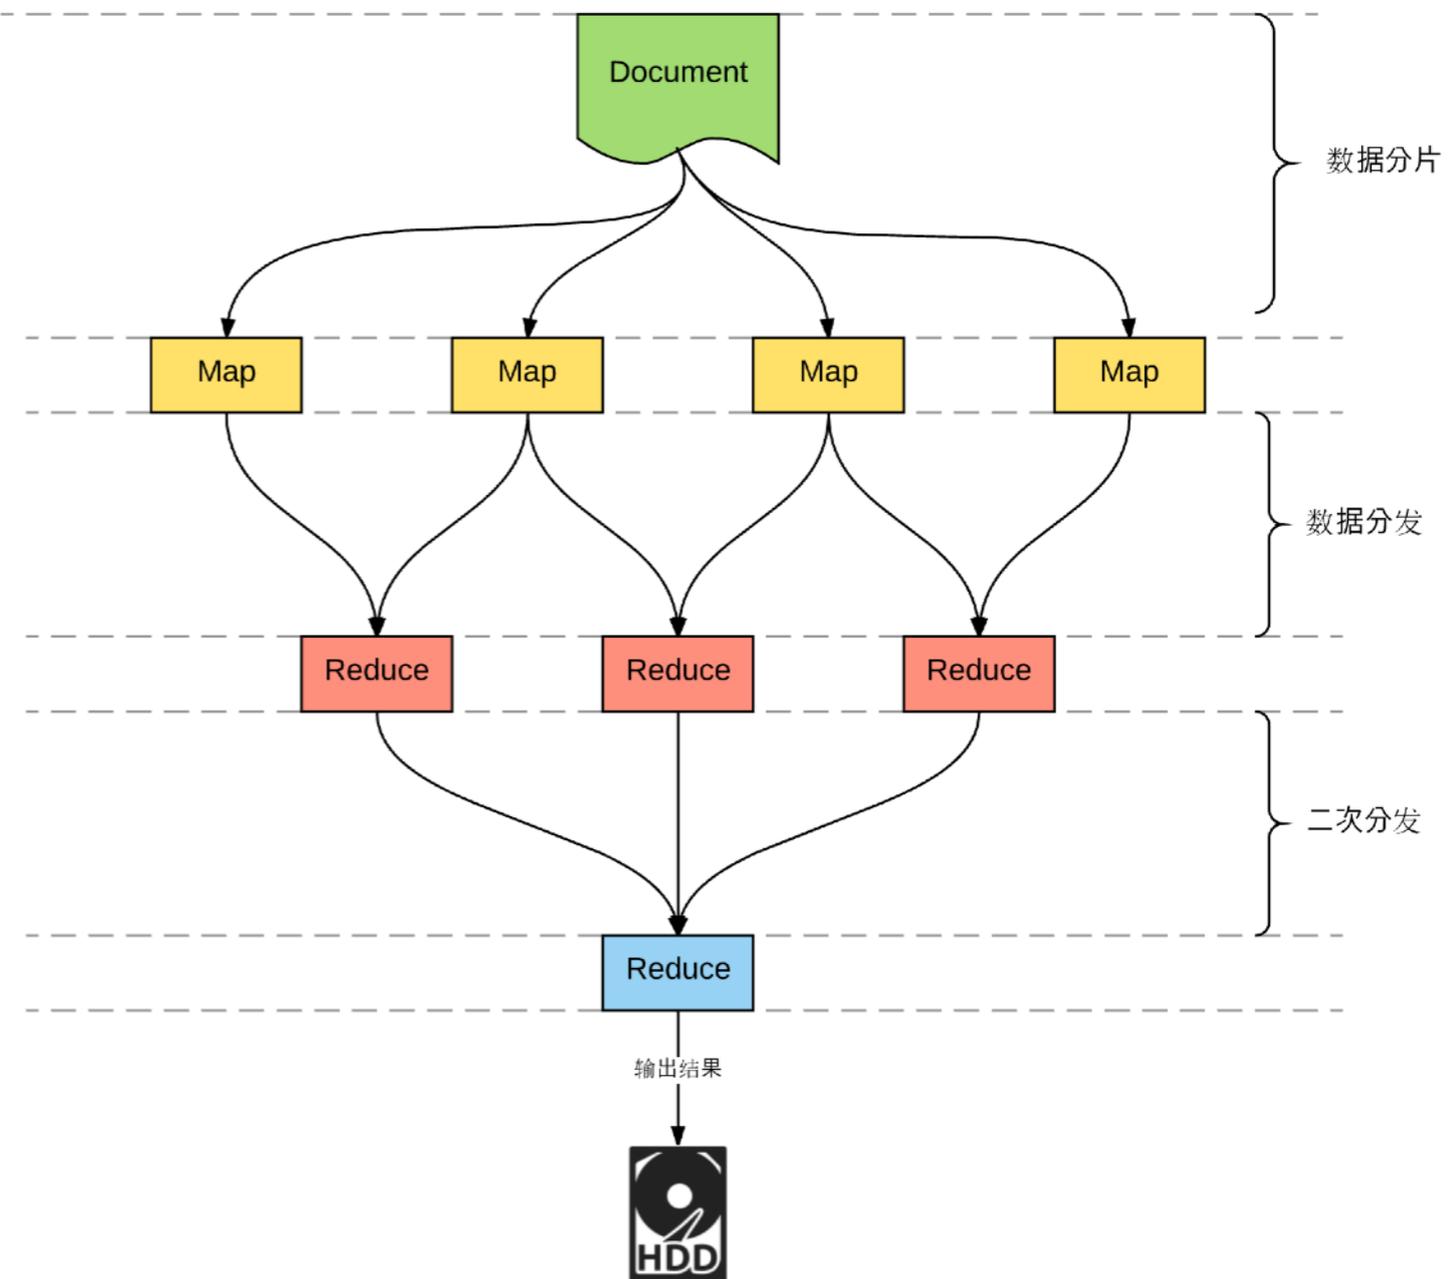
- 数据分片、数据分发之间的区别：

- **数据分片** (partition) :

- 第一次进行数据处理之前，并不知道数据的具体内容，因此，是简单的数据切割

- **数据分发** (shuffle) :

- 已经知道数据的具体内容，按照既定的业务逻辑，将特定的数据，送入特定的节点，数据分发中，要处理的典型问题：**数据倾斜**



# 基本原理：关键过程

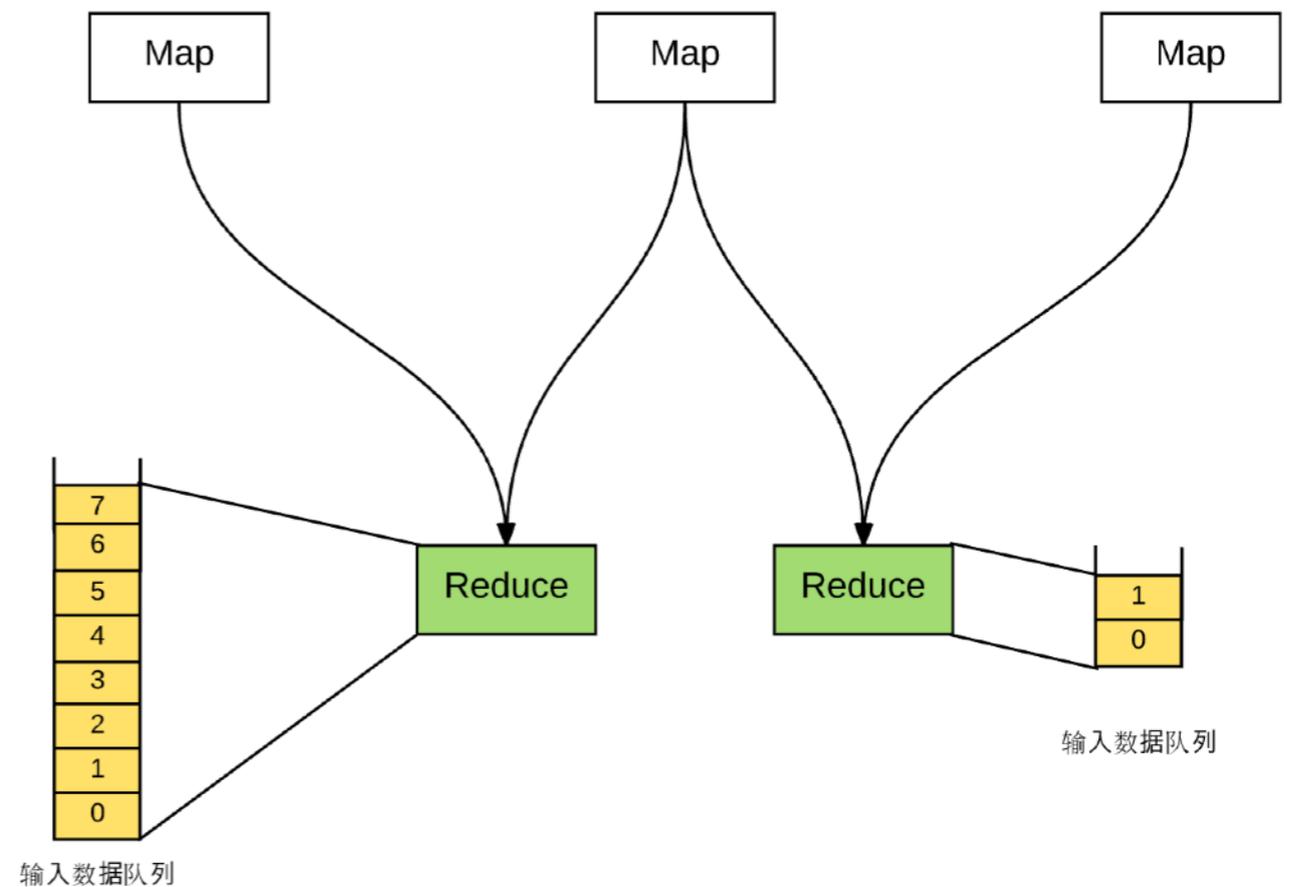
- 数据分片、数据分发之间的区别：

- **数据分片** (partition) :

- 第一次进行数据处理之前，并不知道数据的具体内容，因此，是简单的数据切割

- **数据分发** (shuffle) :

- 已经知道数据的具体内容，按照既定的业务逻辑，将特定的数据，送入特定的节点，数据分发中，要处理的典型问题：**数据倾斜**



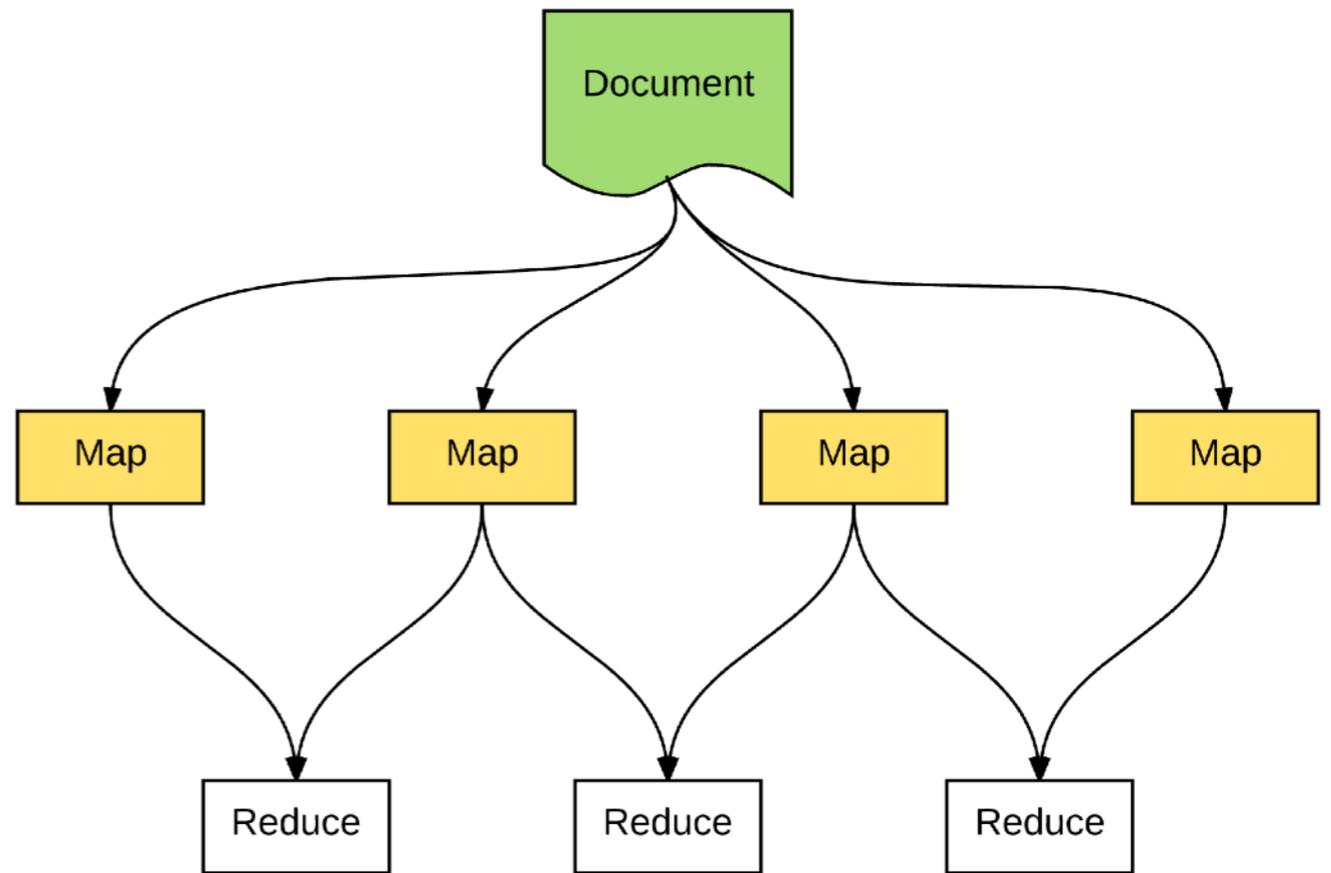
# 小结：基本原理

- 海量数据处理，基本原理：
  - 海量数据处理，涉及 4 个典型过程：
    - 数据分片
    - Map
    - Shuffle
    - Reduce
  - 海量数据处理，调优时，根据具体的业务场景、数据特征，减弱「数据倾斜」现象
  - Map-Reduce 是一种编程模型，实现方式可以有多种，代表性的实现，就是 Hadoop
- 疑问：
  - 上面的场景，潜在瓶颈在哪？海量数据，各种瓶颈

# 目录

- 数据特征：海量数据处理 vs. 普通数据处理
- 基本原理：海量数据处理，典型场景和关键过程
- 关键思想：
  - 分发计算
  - 机架感知
- 本质分析

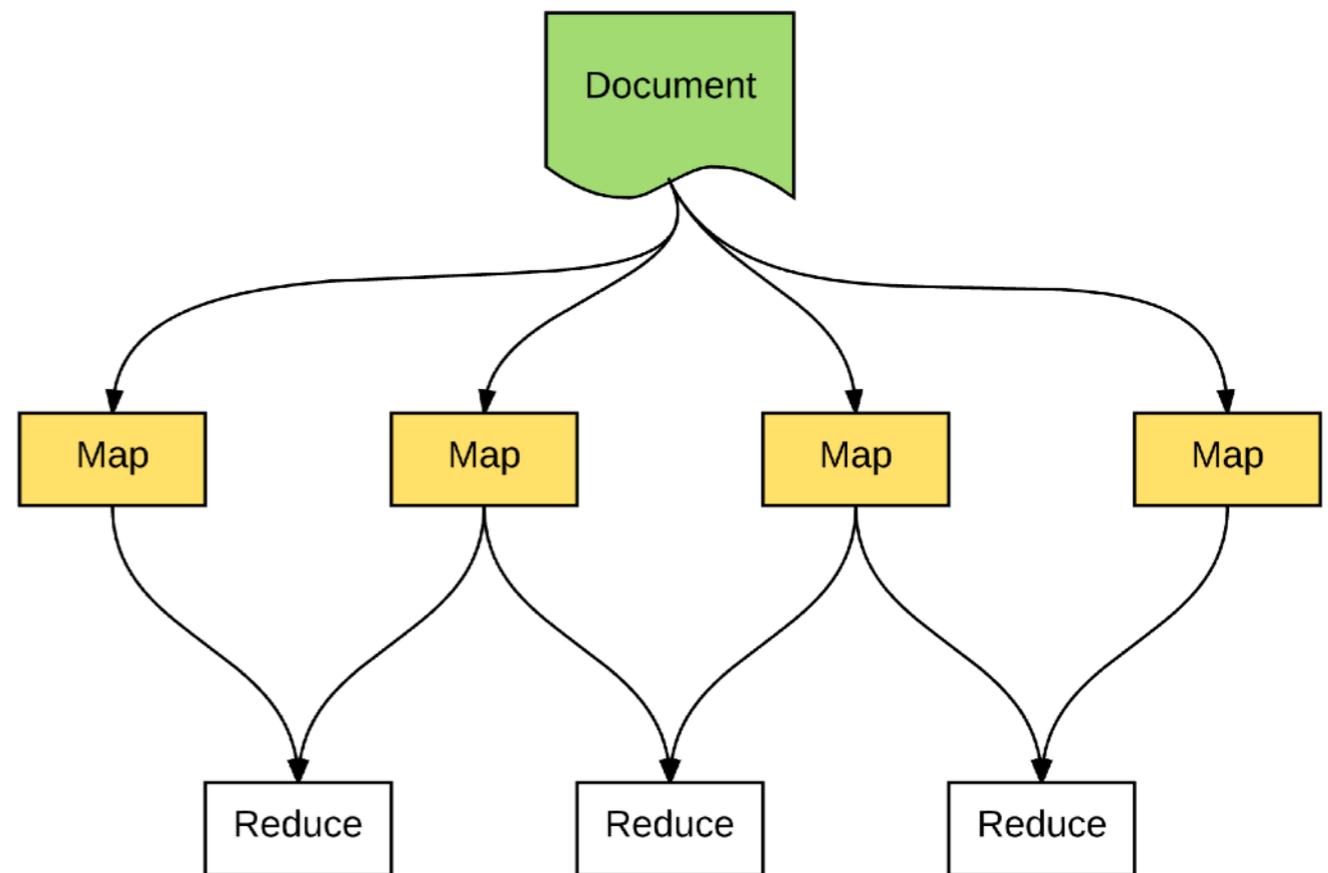
# 关键思想：分发计算



# 关键思想：分发计算

- 分布式存储：

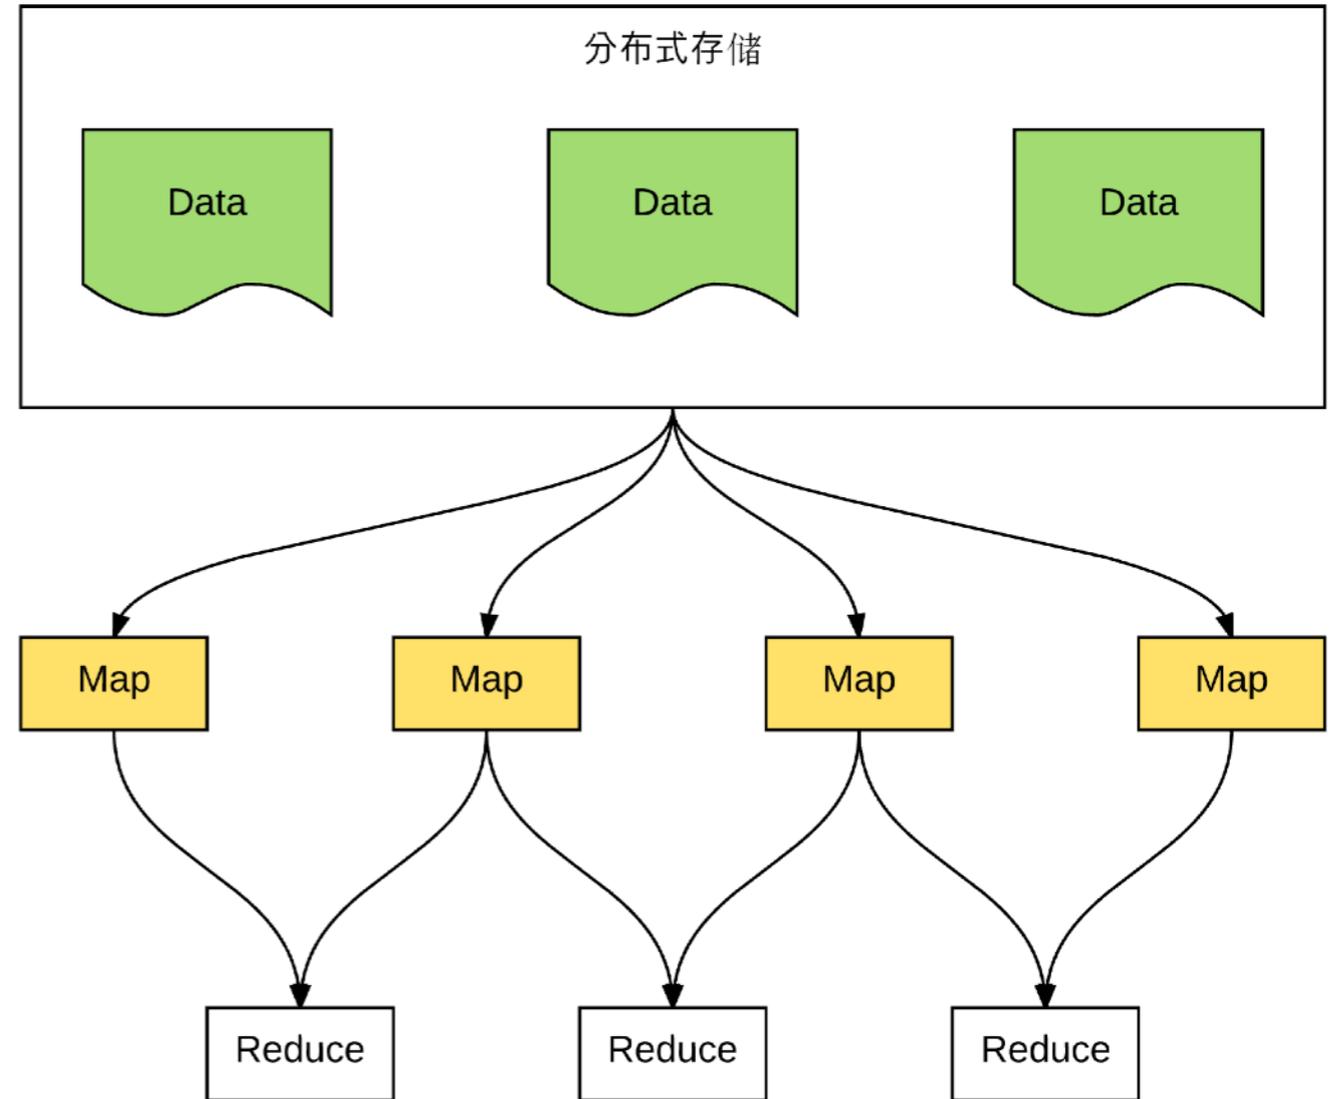
- 面对海量数据，单个存储节点，无法完成所有数据的存储，因此，采用分布式存储。



# 关键思想：分发计算

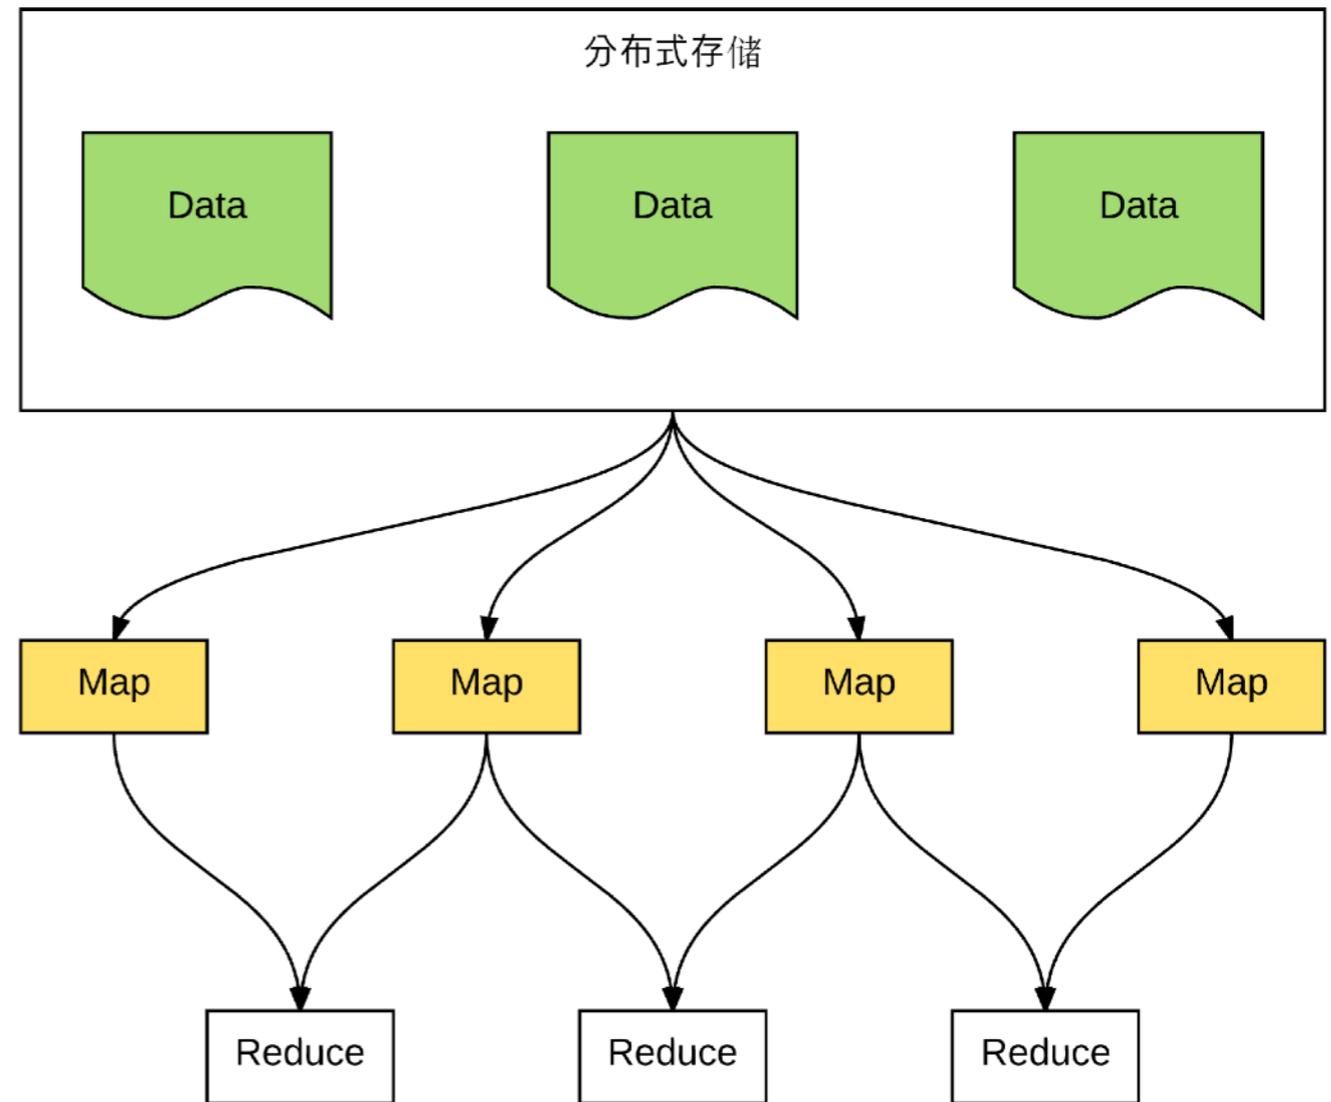
- 分布式存储：

- 面对海量数据，单个存储节点，无法完成所有数据的存储，因此，采用分布式存储。



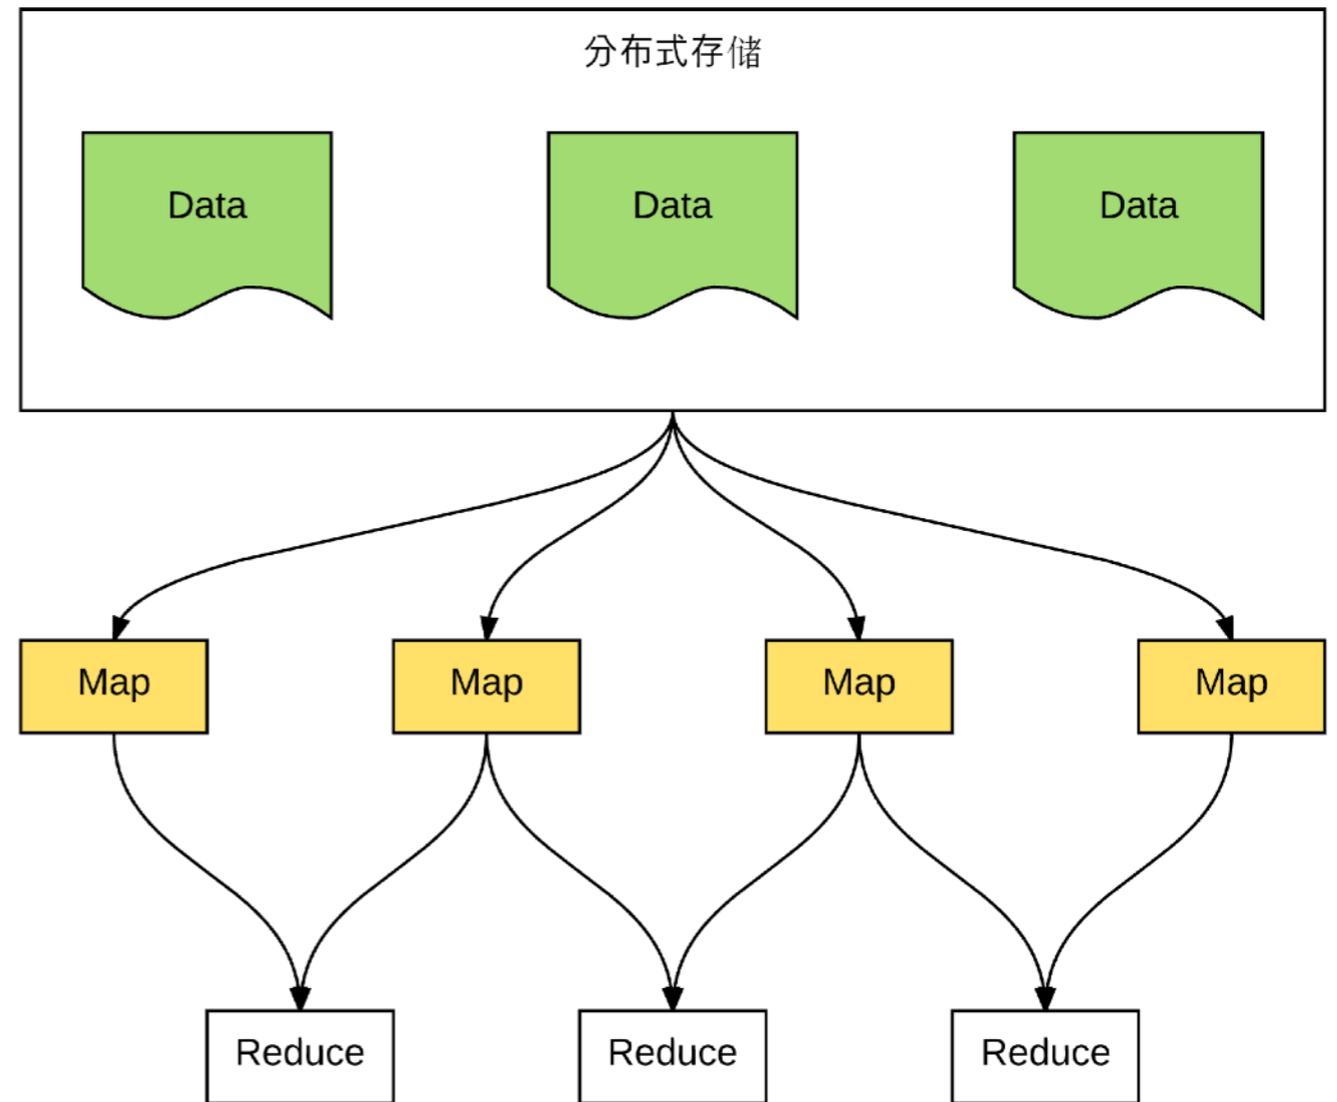
# 关键思想：分发计算

- 分布式存储：
  - 面对海量数据，单个存储节点，无法完成所有数据的存储，因此，采用分布式存储。
- 存在的问题：
  - 小数据量时，都没有问题，一旦是真的海量数据，就会导致：数据分片过程中，Map节点读取Data时，**耗费大量的网络带宽**，网络被打满，成为新的**瓶颈**，随着数据量的剧增，达到网络带宽的瓶颈。

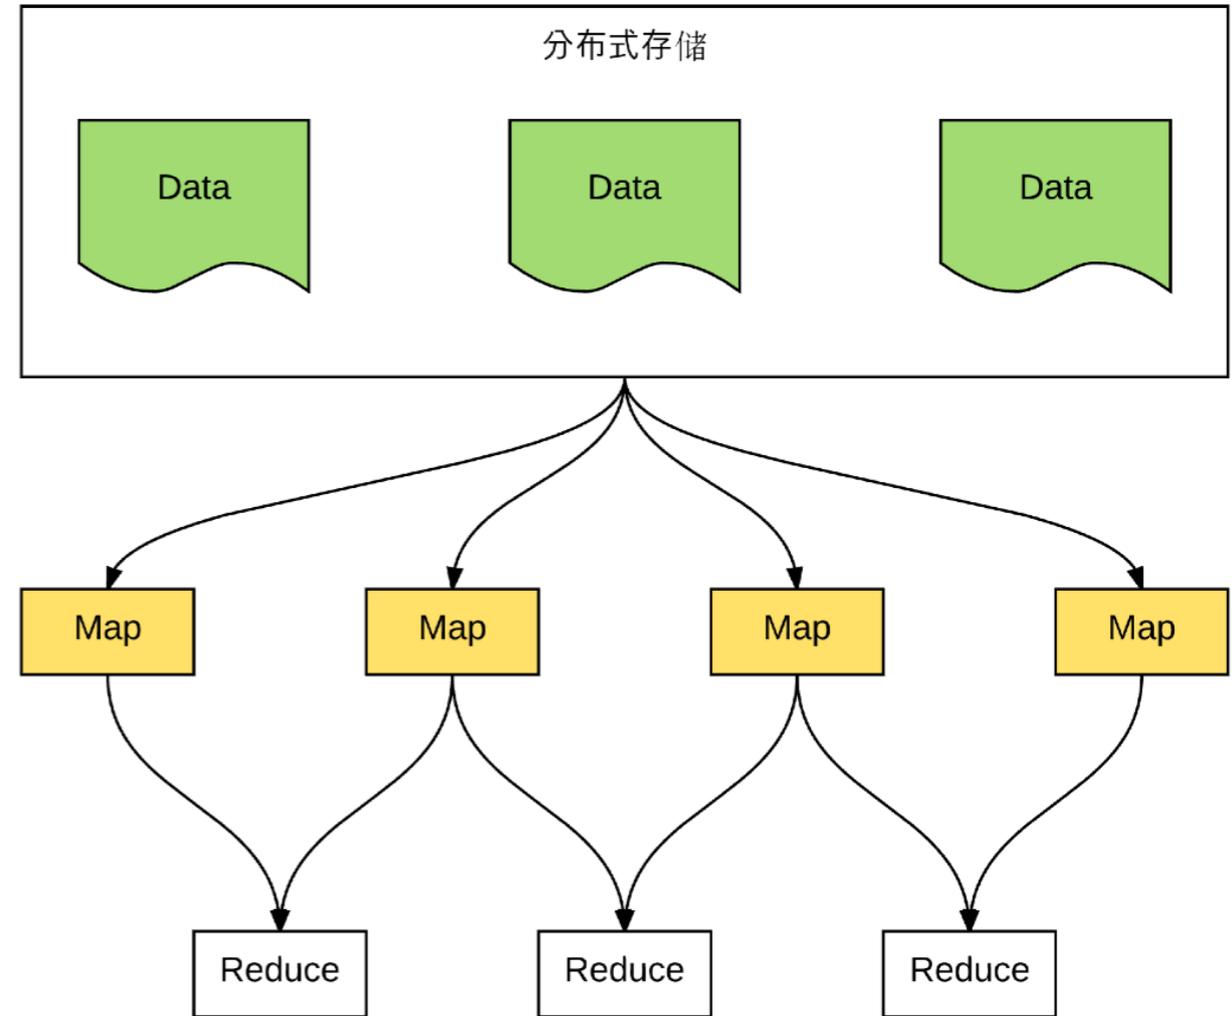


# 关键思想：分发计算

- 分布式存储：
  - 面对海量数据，单个存储节点，无法完成所有数据的存储，因此，采用分布式存储。
- 存在的问题：
  - 小数据量时，都没有问题，一旦是真的海量数据，就会导致：数据分片过程中，Map节点读取Data时，**耗费大量的网络带宽**，网络被打满，成为新的**瓶颈**，随着数据量的剧增，达到网络带宽的瓶颈。
- 几个瓶颈及解决思路：
  - **磁盘容量的瓶颈**：采用**分布式存储**解决
  - **单机计算能力的瓶颈**：采用**分布式计算**解决
  - **网络带宽的瓶颈**：海量数据，Map节点，读取海量数据，达到网络，怎么办？

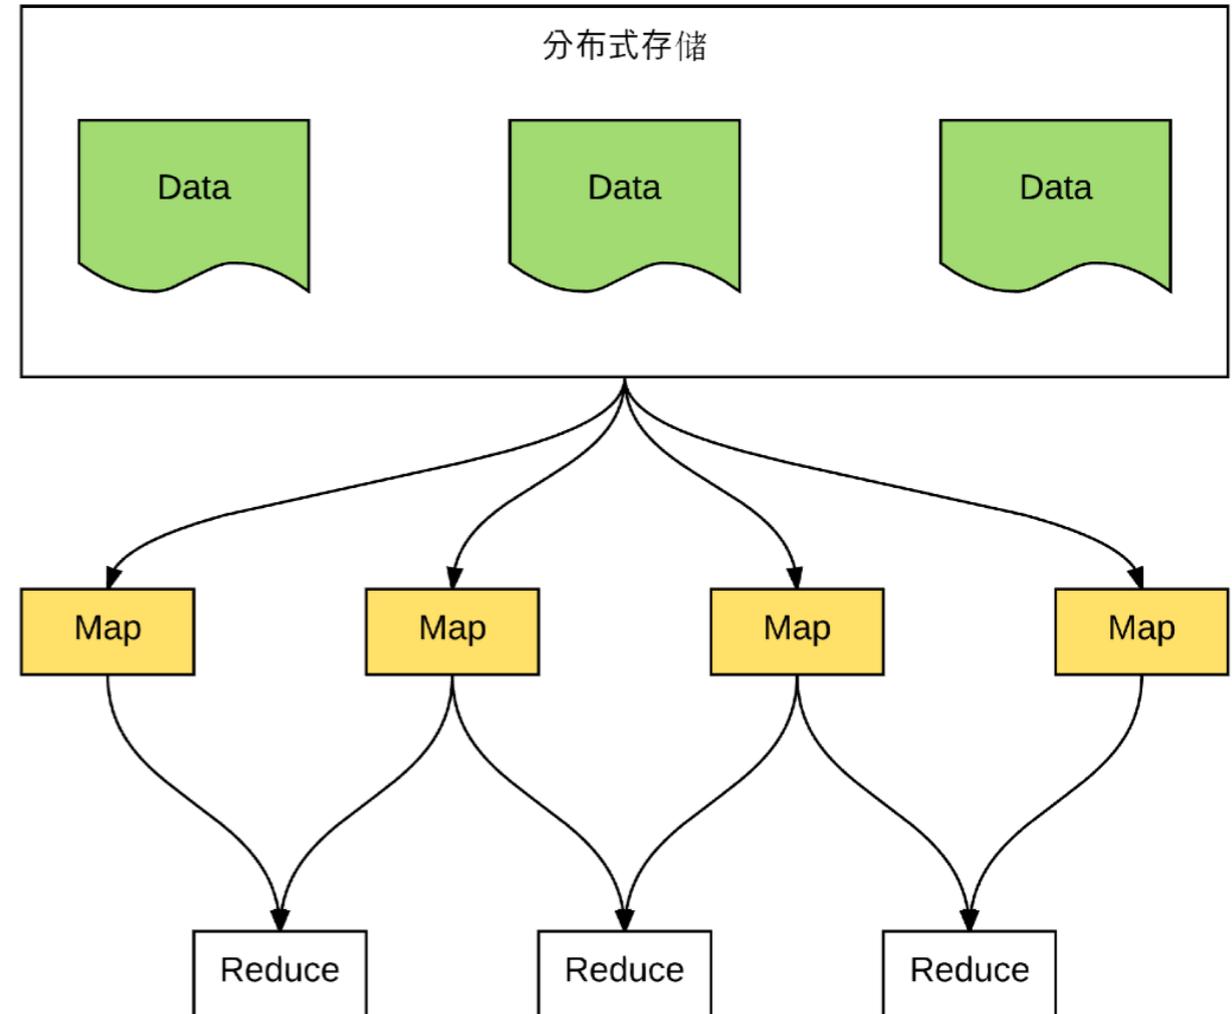


# 关键思想：分发计算



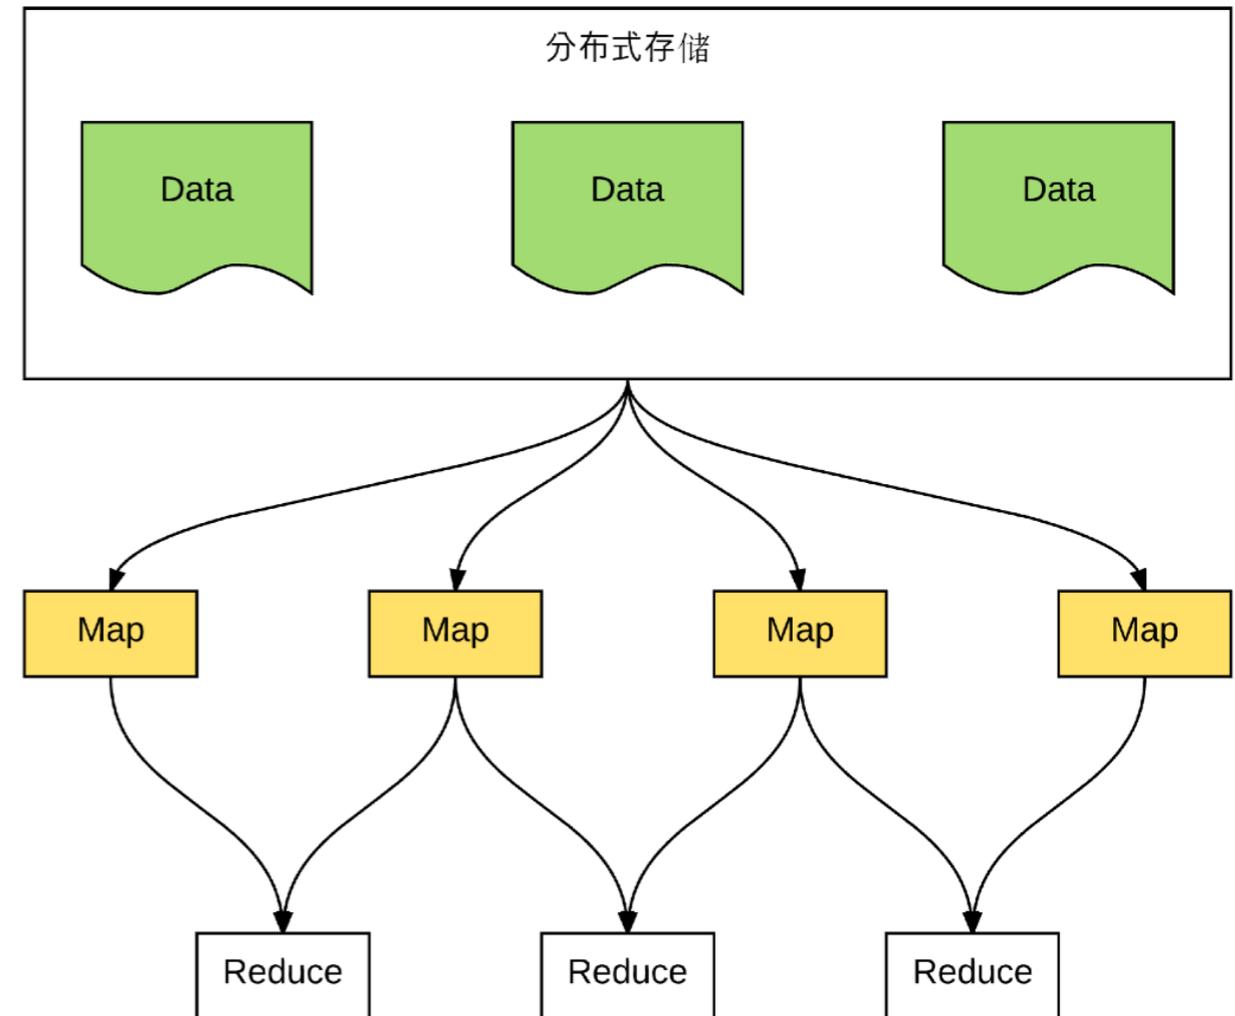
# 关键思想：分发计算

- 为什么会出现：网络带宽瓶颈？



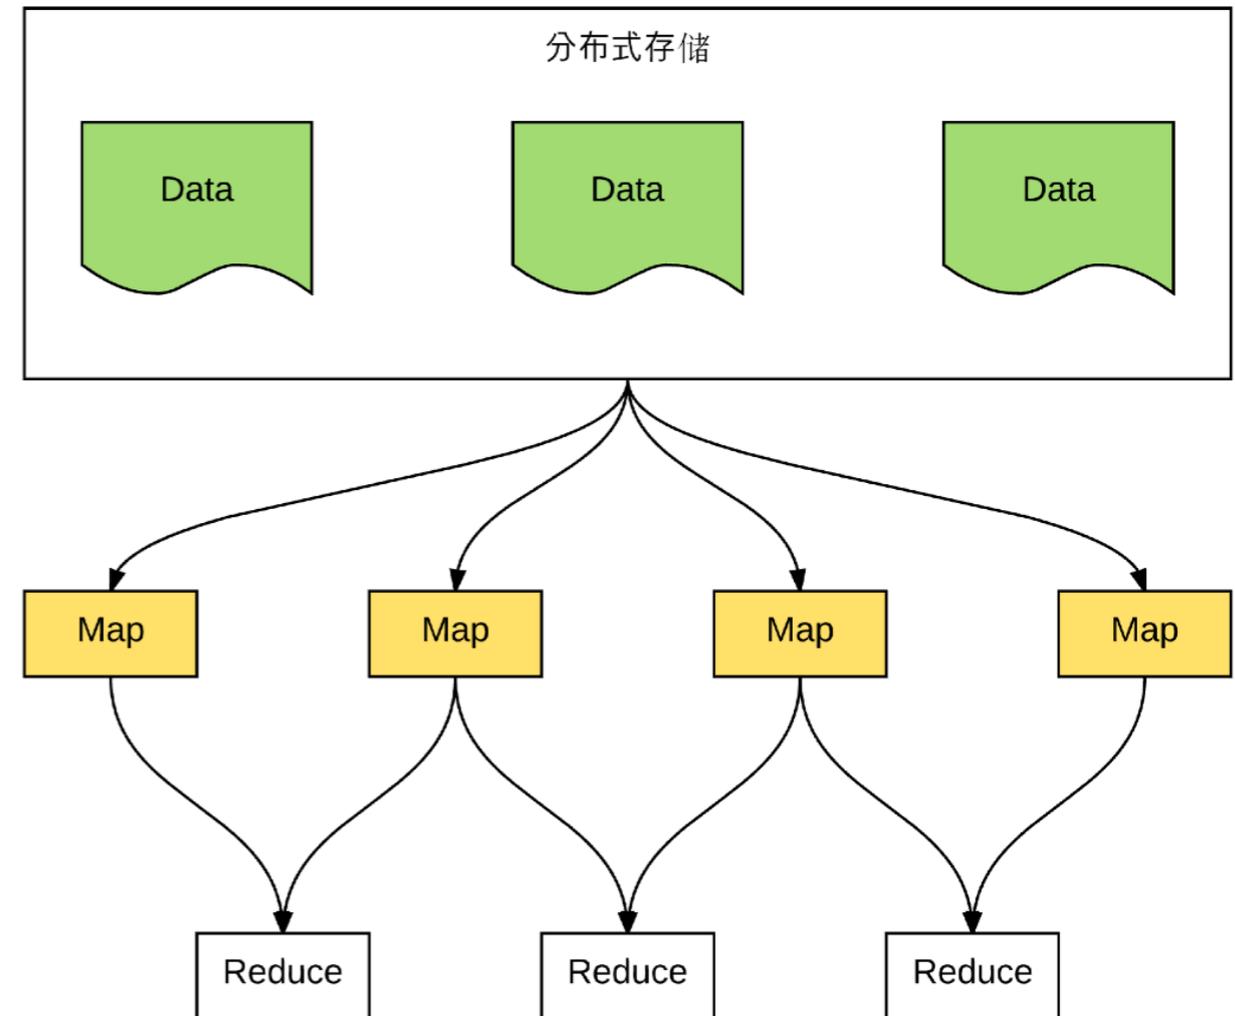
# 关键思想：分发计算

- 为什么会出现：网络带宽瓶颈？
- 本质原因：
  - Map 节点，计算过程中，需要输入，需要数据，就从其他地方读取数据，耗费网络带宽。



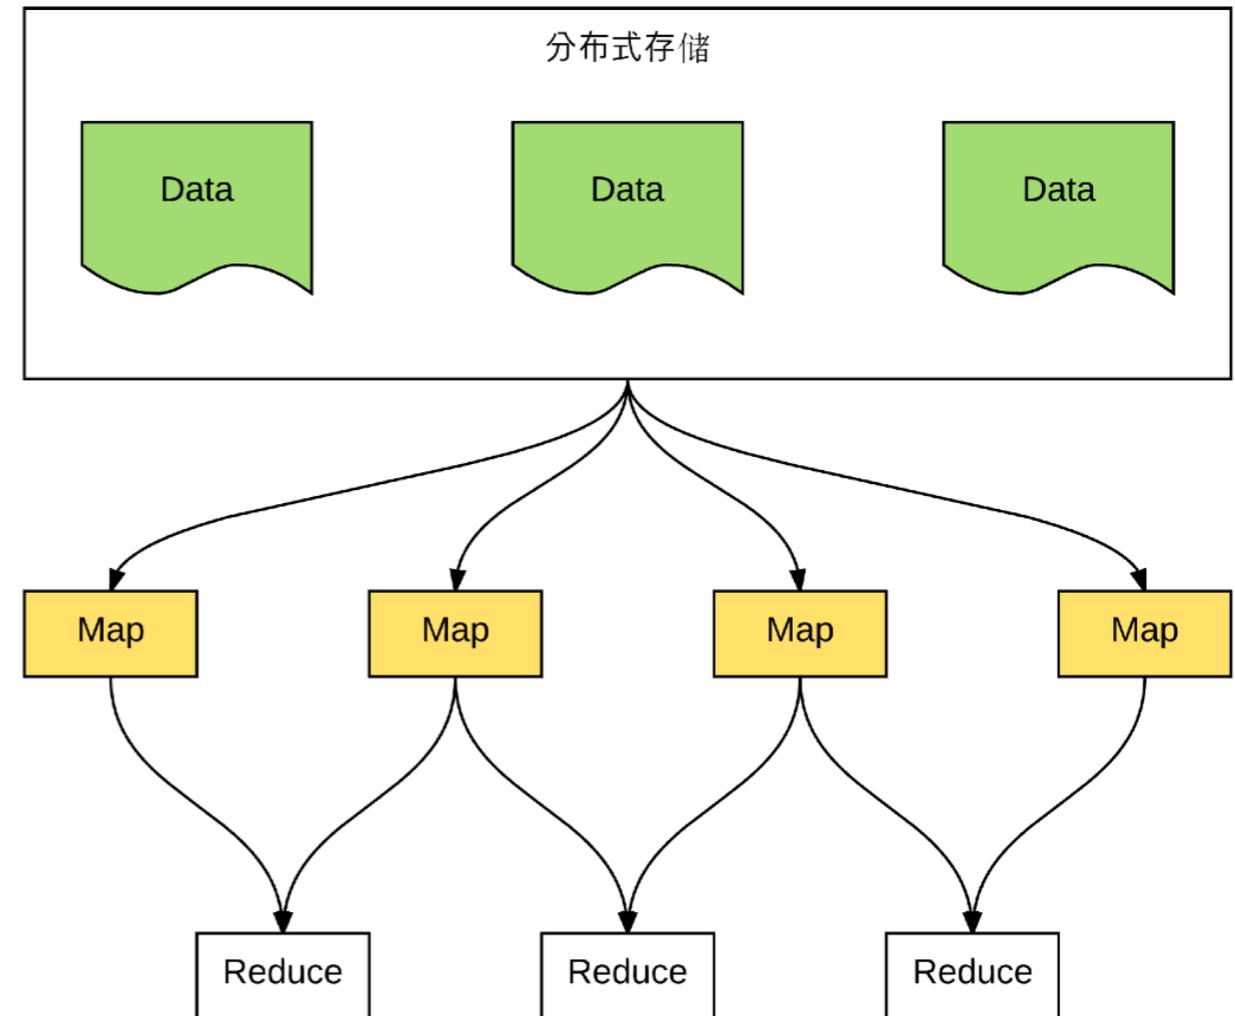
# 关键思想：分发计算

- 为什么会出现：网络带宽瓶颈？
- 本质原因：
  - Map 节点，计算过程中，需要输入，需要数据，就从其他地方读取数据，耗费网络带宽。
- 换个思路，就能解决上述问题，上述本质原因是：
  - 分发数据，即，计算节点把数据，读取到本地，耗费计算。



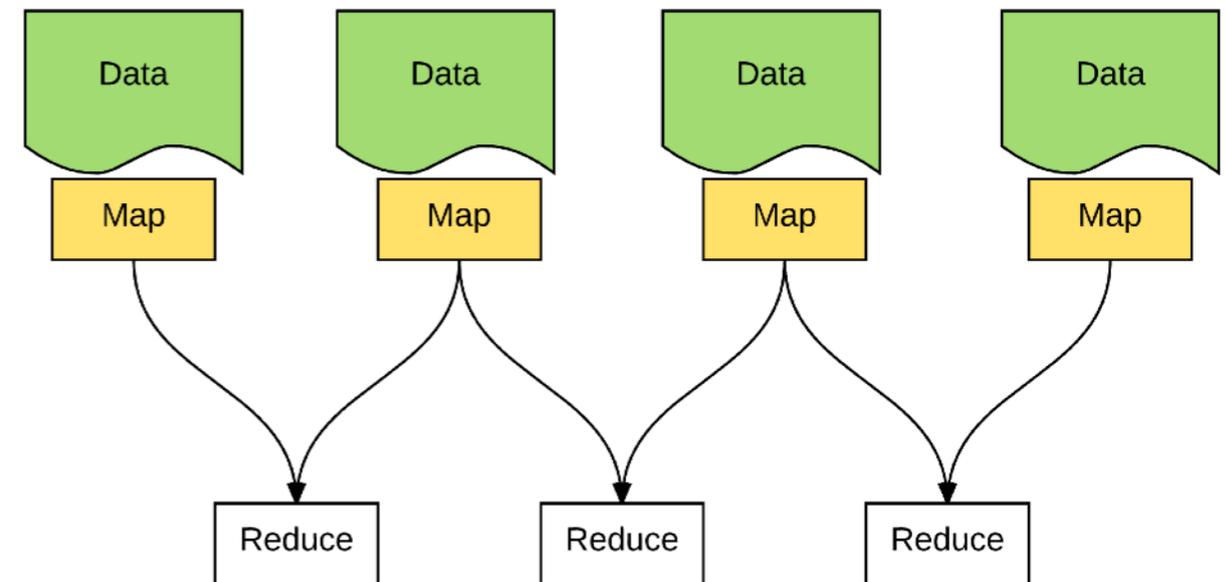
# 关键思想：分发计算

- 为什么会出现：网络带宽瓶颈？
- 本质原因：
  - Map 节点，计算过程中，需要输入，需要数据，就从其他地方读取数据，耗费网络带宽。
- 换个思路，就能解决上述问题，上述本质原因是：
  - 分发数据，即，计算节点把数据，读取到本地，耗费计算。
- 解决思路：
  - 分发计算（Deliver Computation），把**计算逻辑（计算代码）**分发到 **Data 所在的节点**上，就能极大降低网络消耗，简直是天才。



# 关键思想：分发计算

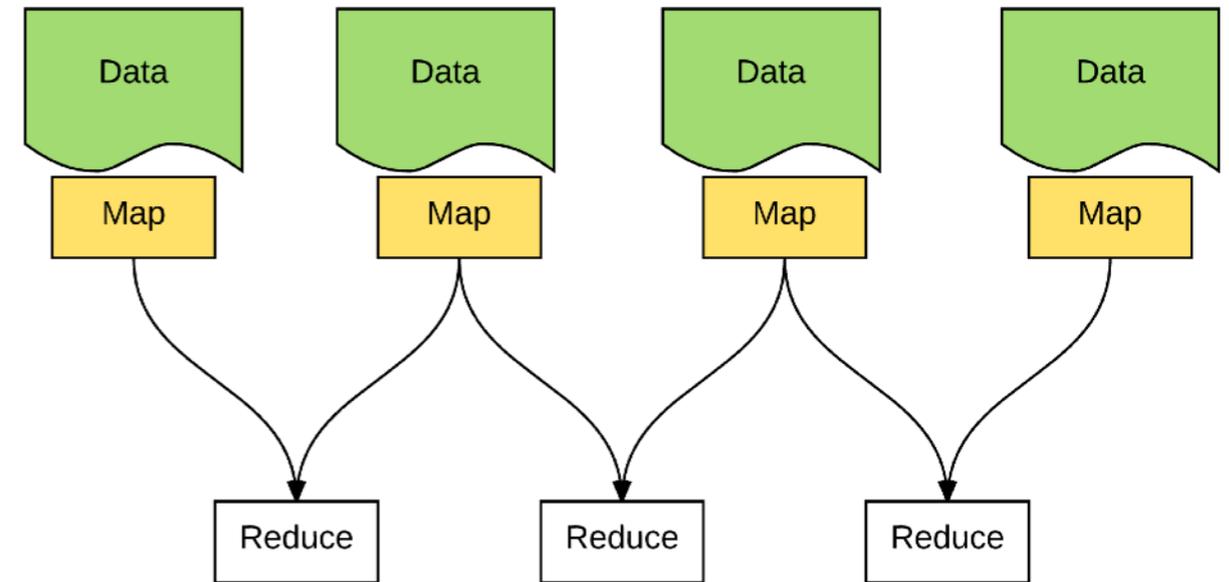
- 为什么会出现：网络带宽瓶颈？
- 本质原因：
  - Map 节点，计算过程中，需要输入，需要数据，就从其他地方读取数据，耗费网络带宽。
- 换个思路，就能解决上述问题，上述本质原因是：
  - 分发数据，即，计算节点把数据，读取到本地，耗费计算。
- 解决思路：
  - 分发计算（Deliver Computation），把**计算逻辑（计算代码）**分发到 **Data 所在的节点**上，就能极大降低网络消耗，简直是天才。



# 目录

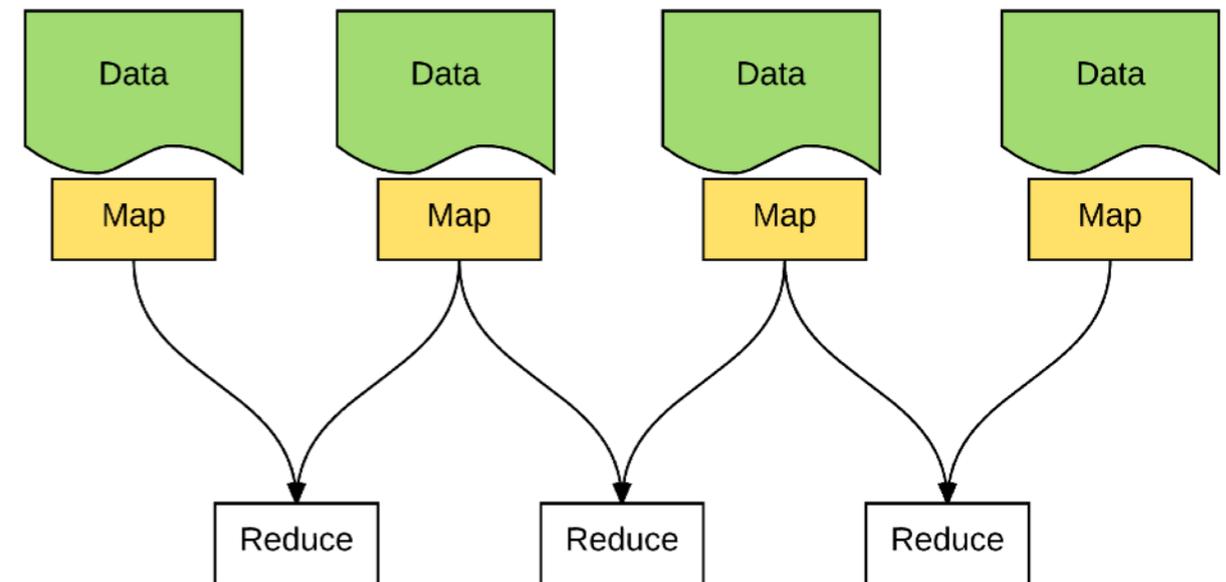
- 数据特征：海量数据处理 vs. 普通数据处理
- 基本原理：海量数据处理，典型场景和关键过程
- 关键思想：
  - 分发计算
  - 机架感知
- 本质分析

# 关键思想：机架感知



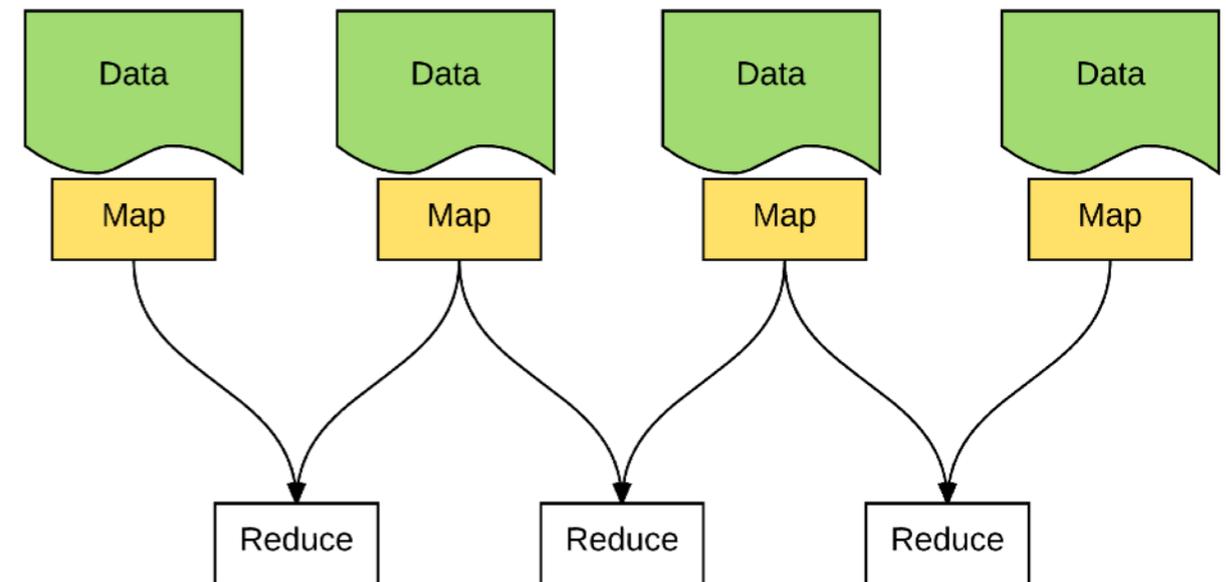
# 关键思想：机架感知

- 背景：分发计算存在的问题
  - 上面分发计算的基本思路是：把计算逻辑分发到数据节点上，就能避免大量的网络传输，解决海量数据处理场景下的带宽瓶颈。
  - 但实际上，分布式存储跟分布式计算，是要保持一定的隔离的：
    - 过度的耦合：会限制两个系统性能的发展和演进，无法实现计算引擎的可插拔
    - 计算能力受限：数据节点的数目，不应跟处理节点的数目绑定，即，不能因为节点数量，限制计算能力上限

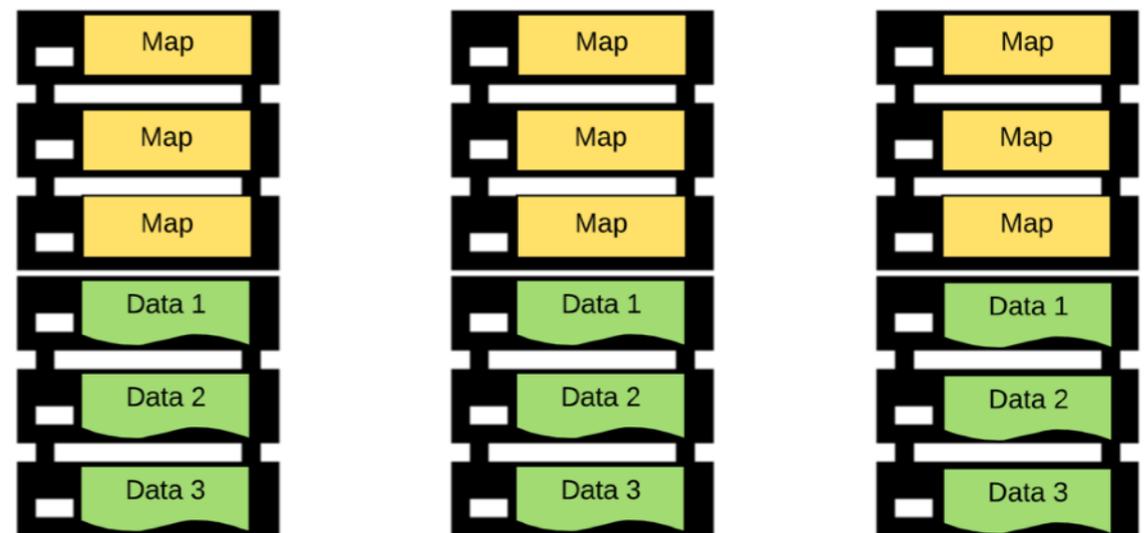
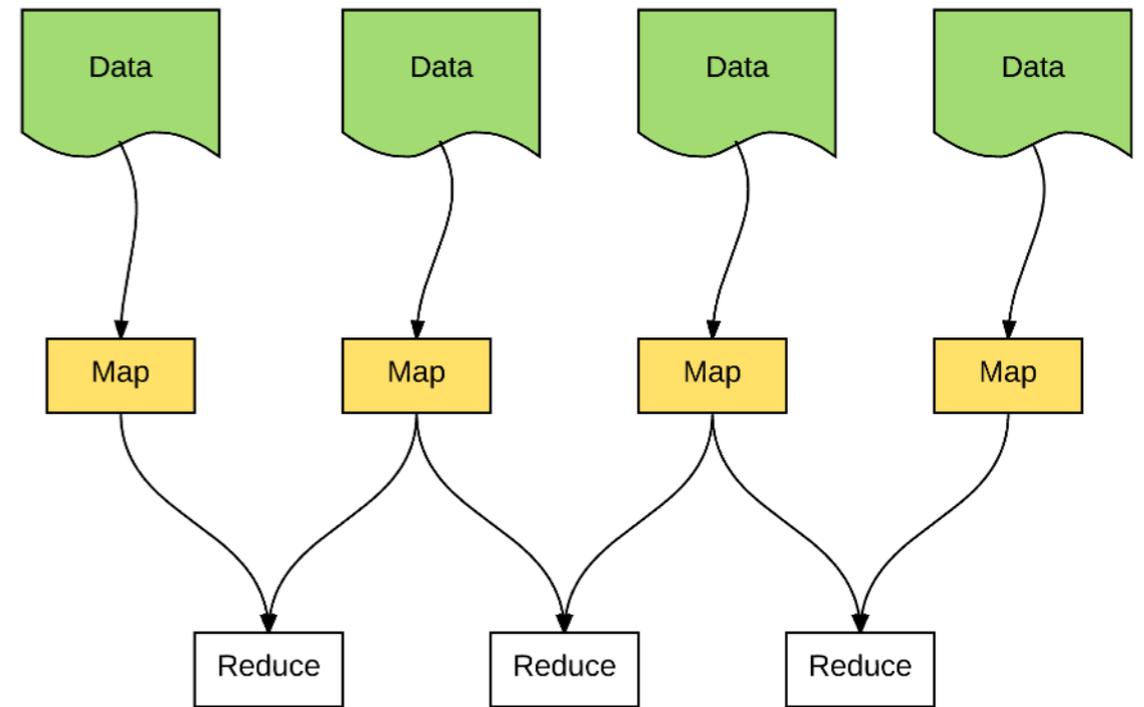


# 关键思想：机架感知

- 背景：分发计算存在的问题
  - 上面分发计算的基本思路是：把计算逻辑分发到数据节点上，就能避免大量的网络传输，解决海量数据处理场景下的带宽瓶颈。
  - 但实际上，分布式存储跟分布式计算，是要保持一定的隔离的：
    - 过度的耦合：会限制两个系统性能的发展和演进，无法实现计算引擎的可插拔
    - 计算能力受限：数据节点的数目，不应跟处理节点的数目绑定，即，不能因为节点数量，限制计算能力上限
- 因此，不能让 Map 紧贴 Data。

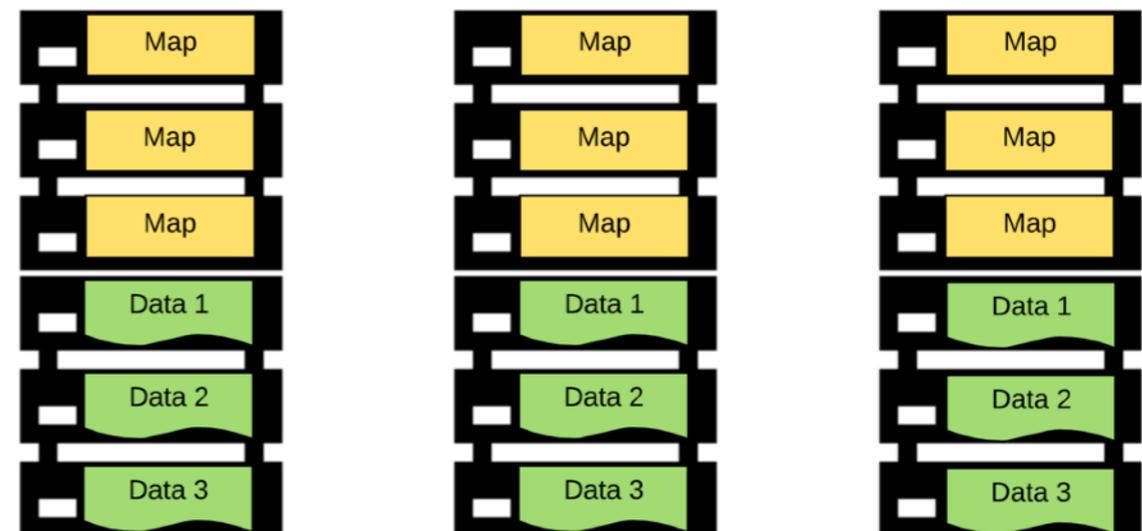
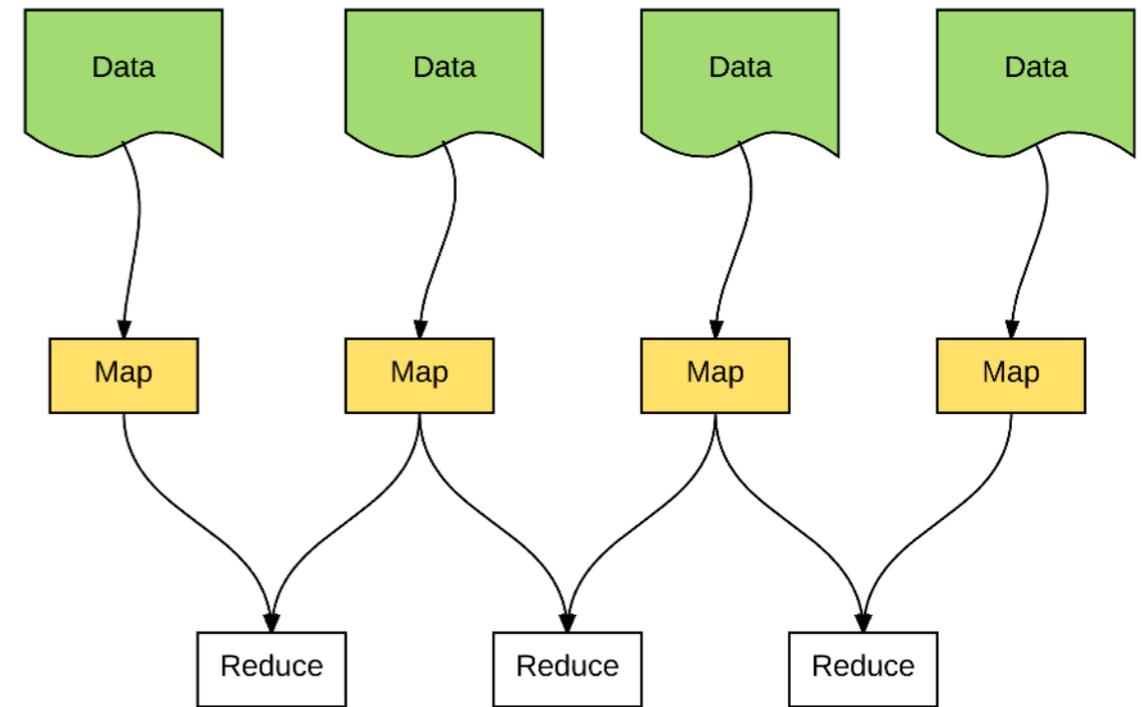


# 关键思想：机架感知



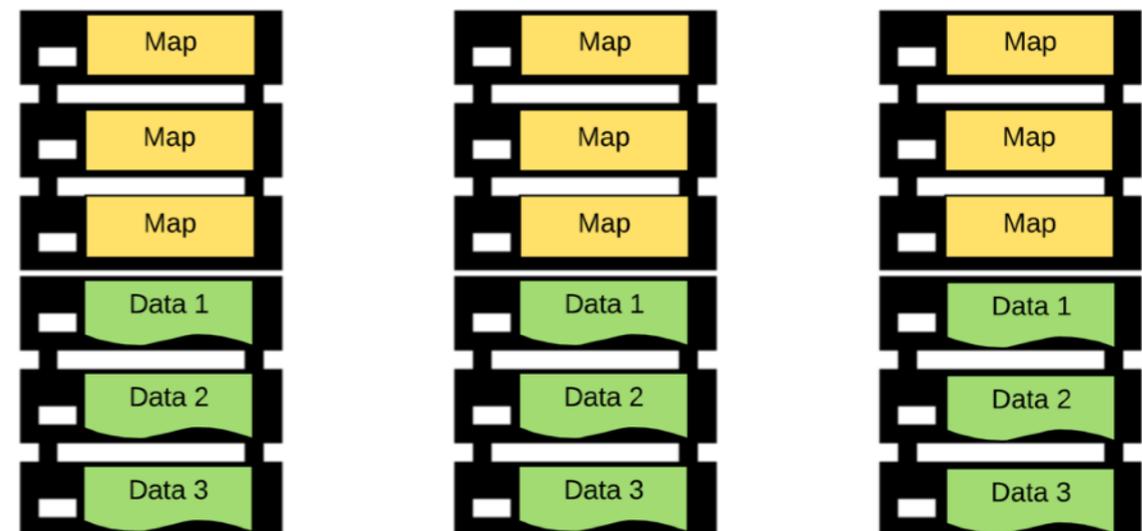
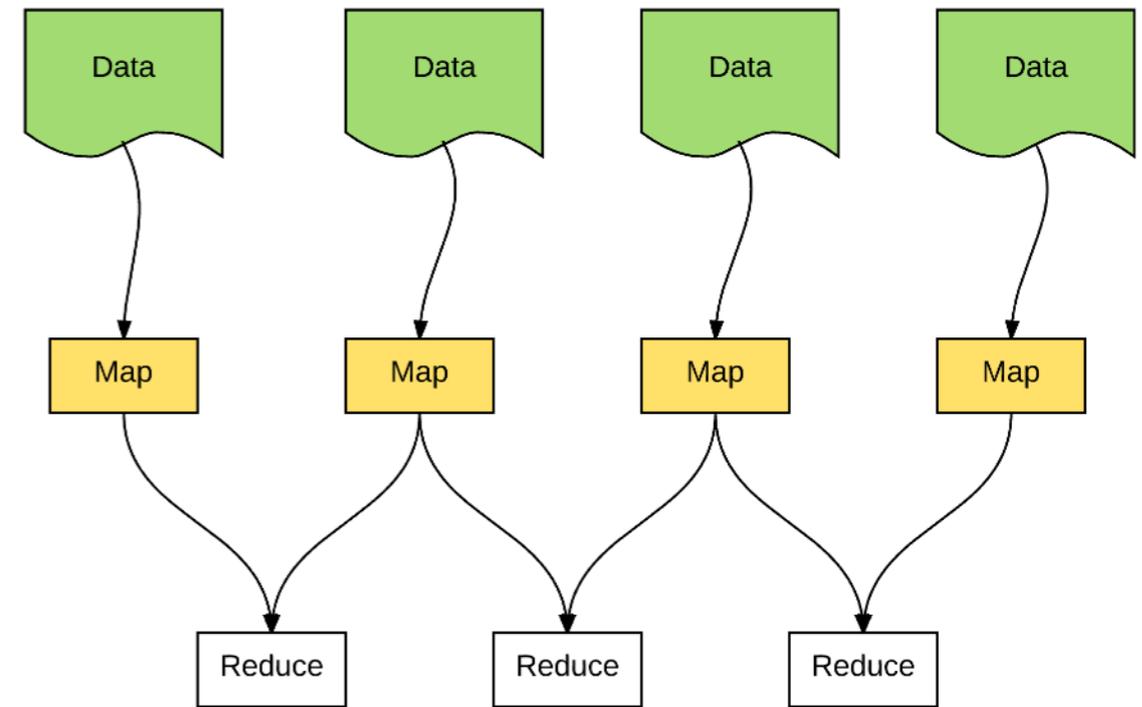
# 关键思想：机架感知

- 解决思路：
  - 既然不能让 Map 绑定 Data，那就让他们尽可能贴近就好了。



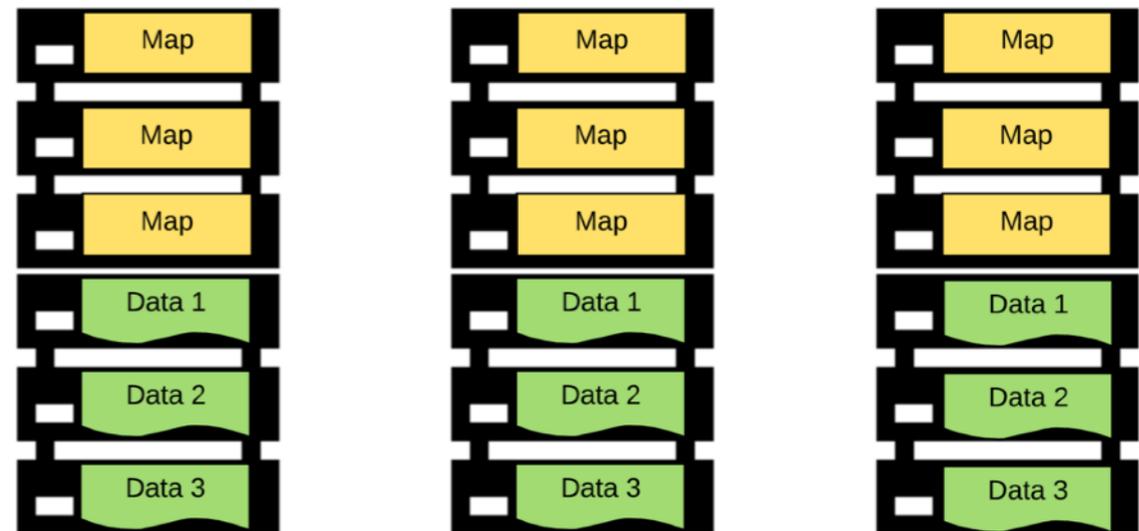
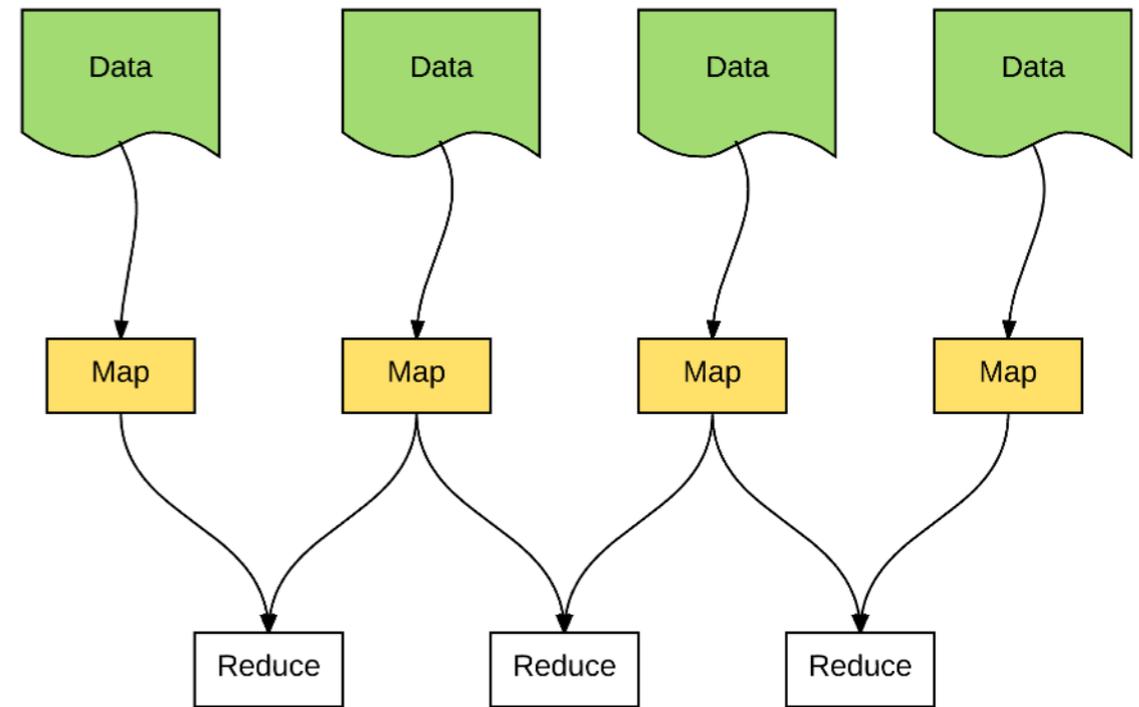
# 关键思想：机架感知

- 解决思路：
  - 既然不能让 Map 绑定 Data，那就让他们尽可能贴近就好了。
- 具体实现：
  - 尽可能让离 Data 物理距离近的 Map 来处理相应的 Data。
  - 物理距离，一般以：机架、机房来划分，即，同机架、同机房。



# 关键思想：机架感知

- 解决思路：
  - 既然不能让 Map 绑定 Data，那就让他们尽可能贴近就好了。
- 具体实现：
  - 尽可能让离 Data 物理距离近的 Map 来处理相应的 Data。
  - 物理距离，一般以：机架、机房来划分，即，同机架、同机房。
- Note：
  - 补充说明，分布式存储，为了提高系统的可靠性，一般会设置数据的副本个数，例如，设置数据副本数为 3，则，采取适当策略，会在至少 3 个机架中，都存在同样的一份数据。



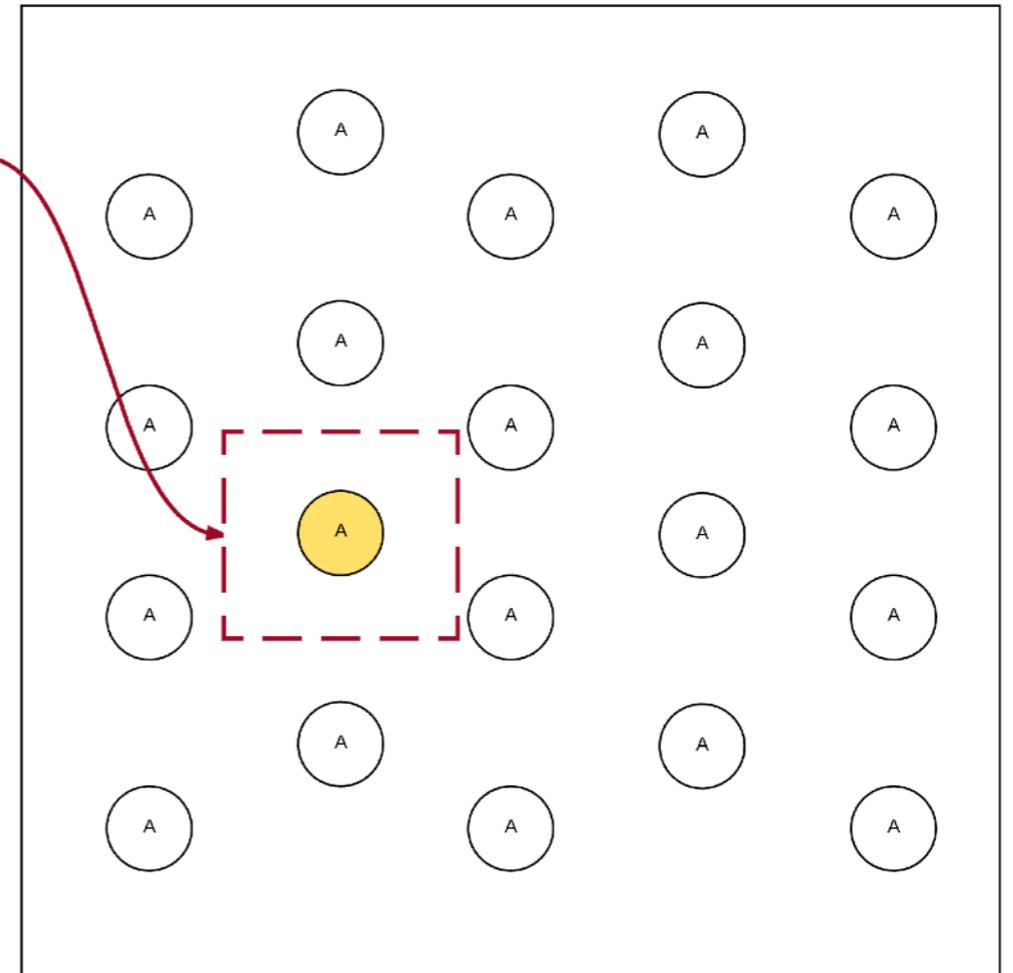
# 目录

- 数据特征：海量数据处理 vs. 普通数据处理
- 基本原理：海量数据处理，典型场景和关键过程
- 关键思想：
  - 分发计算
  - 机架感知
- 本质分析

# 本质分析：Principle of Locality

- 本质：
  - 局部性原理 (Principle Of Locality) ，就近原则
- 具体：
  1. 网络局部性原理
  2. 磁盘局部性原理

在局部：  
把问题解决



# 本质分析： Principle of Locality

- 扁鹊早就知道局部性原理的厉害之处：
  - 魏文王问扁鹊曰：「子昆弟三人其孰最善为医？」
  - 扁鹊曰：「长兄最善，中兄次之，扁鹊最为下。」
  - 魏文侯曰：「可得闻邪？」
  - 扁鹊曰：
    - 长兄於病视神，未有形而除之，故名不出於家。
    - 中兄治病，其在毫毛，故名不出於闾。
    - 若扁鹊者，鑿血脉，投毒药，副肌肤，闲而名出闻於诸侯。

# 总结 & 回顾

- 海量数据处理，基本原理：
  - 海量数据处理，涉及 4 个典型过程：
    - 数据分片
    - Map
    - Shuffle
    - Reduce
  - 海量数据处理，调优时，根据具体的业务场景、数据特征，减弱「数据倾斜」现象
  - Map-Reduce 是一种编程模型，实现方式可以有多种，代表性的实现，就是 Hadoop
- 海量数据处理，关键思想：
  - 分发计算：把计算逻辑（计算代码）分发到 Data 所在的节点上，就能极大降低网络消耗
  - 机架感知：尽可能让离 Data 近的 Map 节点来处理数据，感知 Data 跟 Map 的物理距离
  - 本质：网络局部性原理

# 参考资料

- <http://dl.acm.org/citation.cfm?id=1327492> Dean J, Ghemawat S. MapReduce: simplified data processing on large clusters[J]. Communications of the ACM, 2008, 51(1): 107-113.
- <http://www.cloudera.com/content/dam/www/static/documents/whitepapers/hadoop-and-hdfs.pdf>  
Hadoop and HDFS: Storage for Next Generation Data Management (White Paper of Cloudera)
- [https://en.wikipedia.org/wiki/Principle\\_of\\_locality](https://en.wikipedia.org/wiki/Principle_of_locality) Principle Of Locality wiki
- <http://hadoop.apache.org/>

# Q & A

