Для доступа к «большим и быстрым» данным была разработана **лямбда-архитектура**, которая представляет собой общий подход, направленный на применение произвольной функции к произвольному набору данных, при этом обеспечивая минимальный период ожидания возвращения функцией искомого значения. Она состоит из трех уровней: пакетного (batch layer), сервисного (serving layer), уровня ускорения (speed layer).

Пакетный уровень – архив сырых исторических данных. Чаще всего, это «озеро данных» на базе Hadoop, хотя встречается и в форме OLAP-хранилища данных, старые данные остаются *неизменными* – происходит добавление новых.

Сервисный уровень индексирует пакеты и обрабатывает результаты вычислений, происходящих на пакетном уровне.

Уровень **ускорения** отвечает за обработку данных, поступающих в систему в реальном времени. Представляет собой совокупность складов данных, в которых те находятся в режиме очереди, в потоковом или в рабочем режиме.

На этом уровне компенсируется разница в актуальности данных, а в отдельные представления реального времени добавляется информация с коротким жизненным циклом (чтобы исключить дублирование данных). Эти представления параллельно с сервисным уровнем обрабатывают свои запросы.

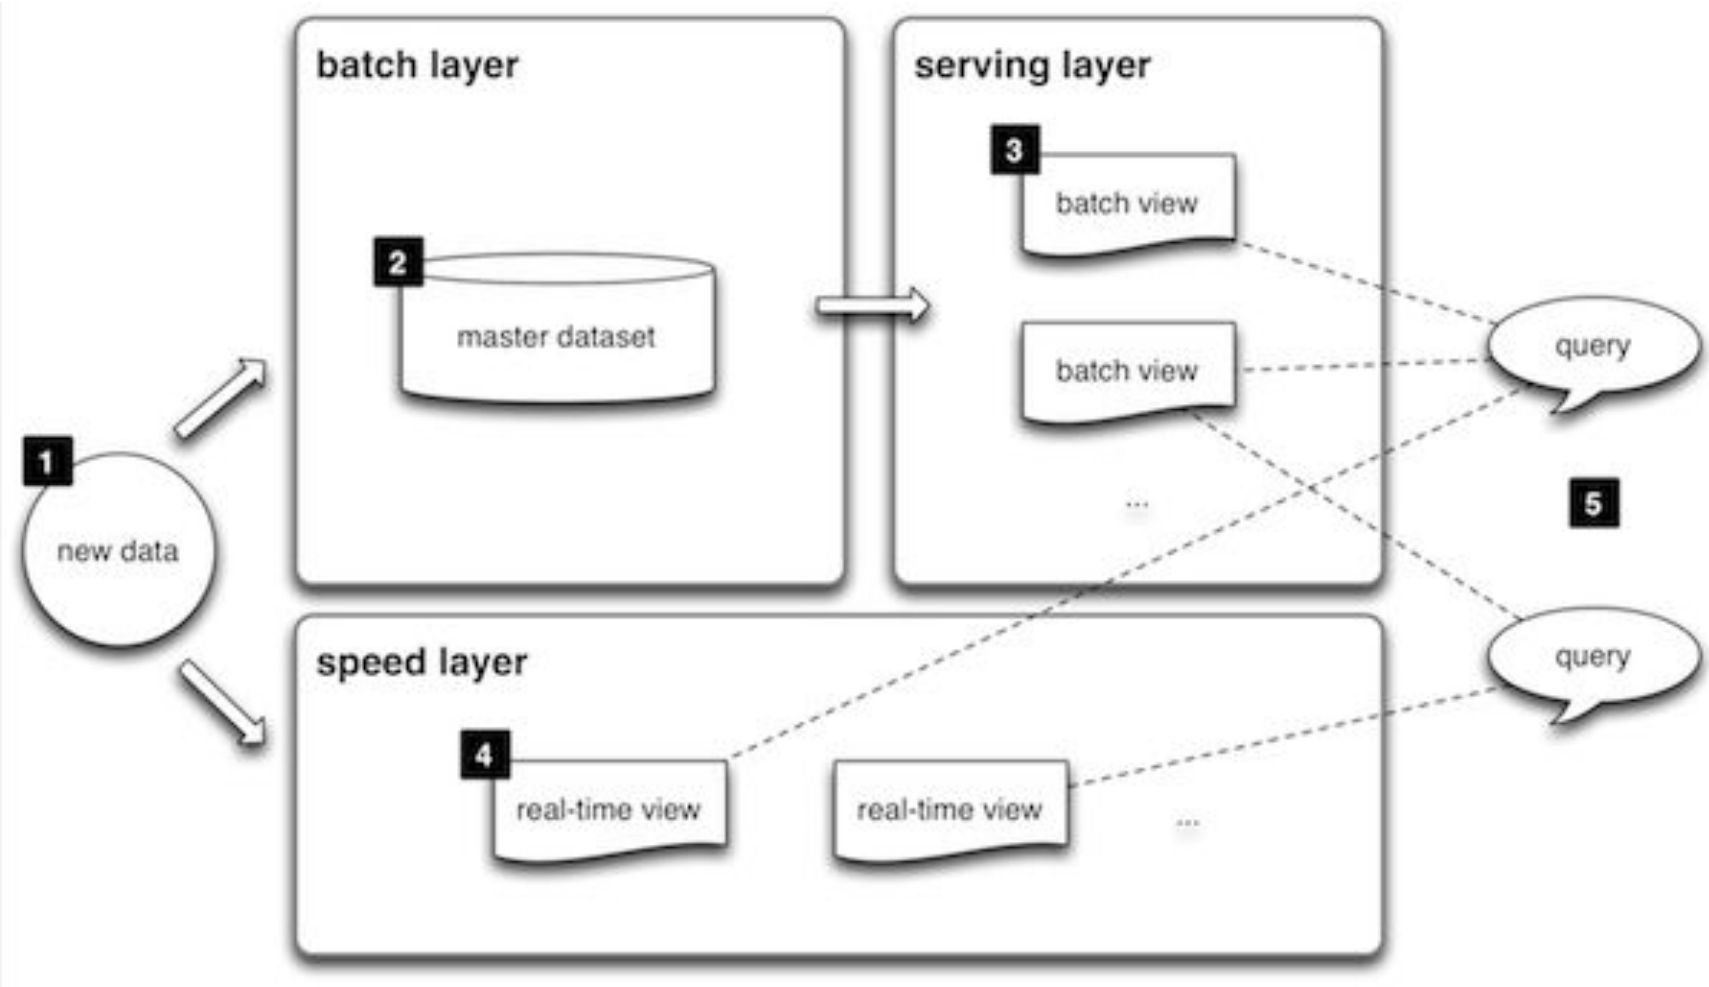

В основе Лямбда-архитектуры лежит несколько принципов:
система не восприимчива к единичной потере данных и/или повреждению данных (fault-tolerance);
неизменность данных – хранение данных в исходном неизменяемом виде;
перевычисление – есть возможность всегда провести вычисления на исходных данных.

Вся информация поступает в единое хранилище данных (*мастер*), в котором может быть и другая статичная информация, и одновременно дублируется на уровне агрегации краткосрочного периода. любой запрос имеет доступ к мастеру для получения полного ответа на основе полных данных, и коррекции с учетом самой последней информации, агрегированной за краткосрочный период, поскольку мастер, очевидно, имеет определенную инерцию из-за скорости обработки большого объема информации.

Уровень **пакет** использует Apache Hadoop

Уровень **скорость** использует Stream-processing technologies typically Apache Storm использует Stream-processing technologies typically Apache Storm, SQLstream использует Stream-processing technologies typically Apache Storm, SQLstream and Apache Spark. Результат обычно сохраняется на быстрых NoSQL БД.

Уровень **сервис** использует **Apache CassandraApache Cassandra or Apache HBaseApache Cassandra or Apache HBase for speed-layer output, and Elephant DBApache Cassandra or Apache HBase for speed-layer output, and Elephant DB or Cloudera Impala for batch-layer output.**

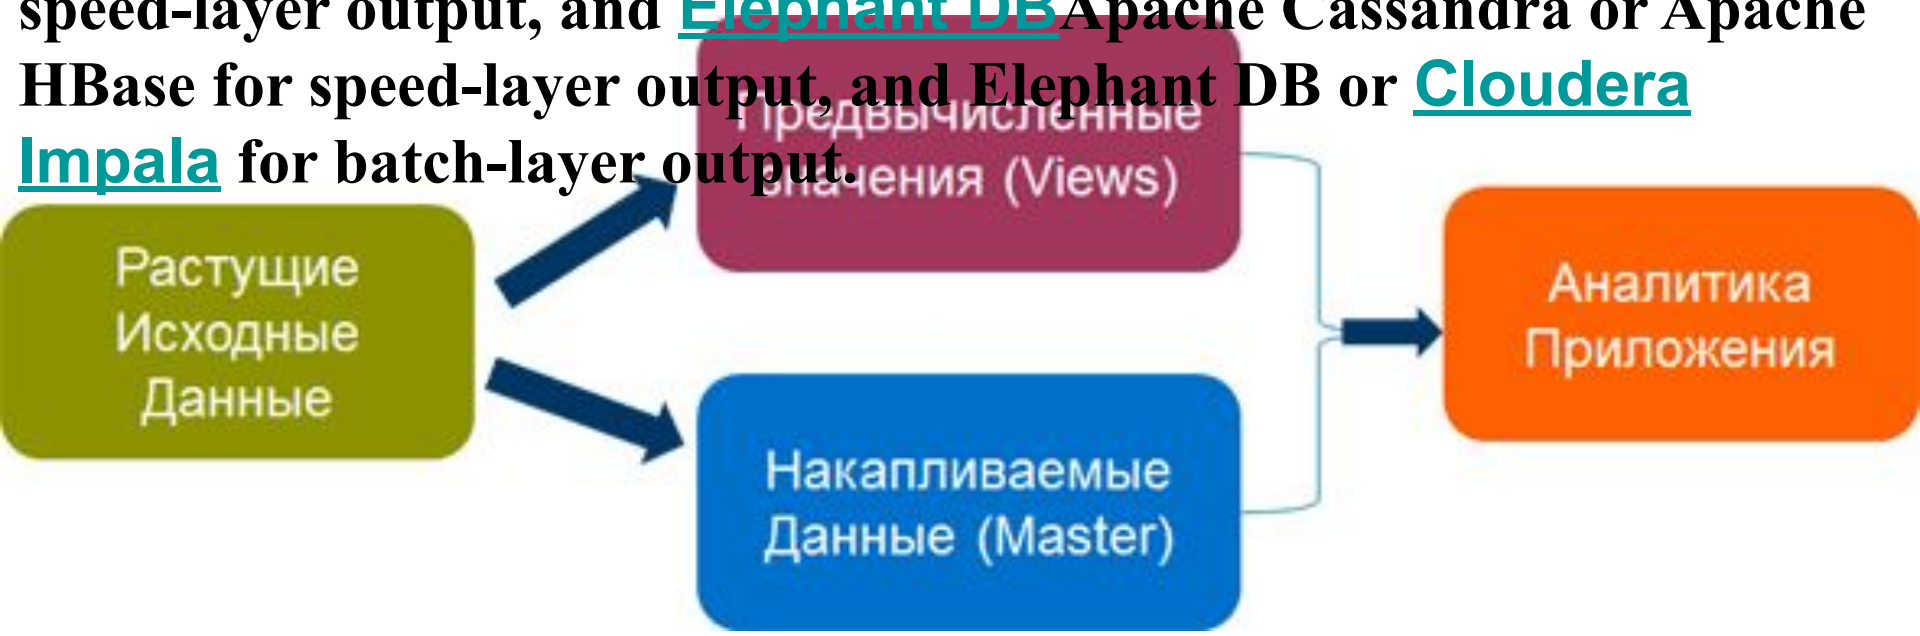

Новые данные поступают на оба уровня: Пакетный и Ускорения (A). Мастер (B) представляет собой хранилище неизменяемой сырой информация, где исходные данные только добавляются. Пакетный уровень (C) постоянно перевычисляет функции заново в Пакеты. Сервисный Уровень (D) индексирует Пакеты, и здесь результаты обычно отстают по времени из-за скорости прохождения мастера и индексирования. Уровень Ускорения (E) компенсирует разницу в актуальности данных, и постоянно добавляет данные в представления реального-времени с коротким жизненным циклом (ведь нам не нужно дублирование в хранении данных, т.к. они накапливаются на Мастере). И, наконец, запросы обрабатывают пакеты и представления реального времени (F).

На данный момент существуют различные вариации технологических компонент для Лямбда-архитектуры.

Например, проект Lambdoop, который объединяет компоненты эко-системы Hadoop для всех трех слоев Лямбда-архитектуры: кластер Hadoop используется для пакетного уровня – HDFS для мастера и MapReduce для быстрого перевычисления запроса на исходных данных; для сервисного уровня используются Cloudera Impala для пакетов и Apache HBase для создания представлений реального времени; и технология Storm для уровня ускорения. Также Cloudera Impala решает вопрос агрегации результатов из уровней для ответа на запрос.

Проект развивается с 2013 г.

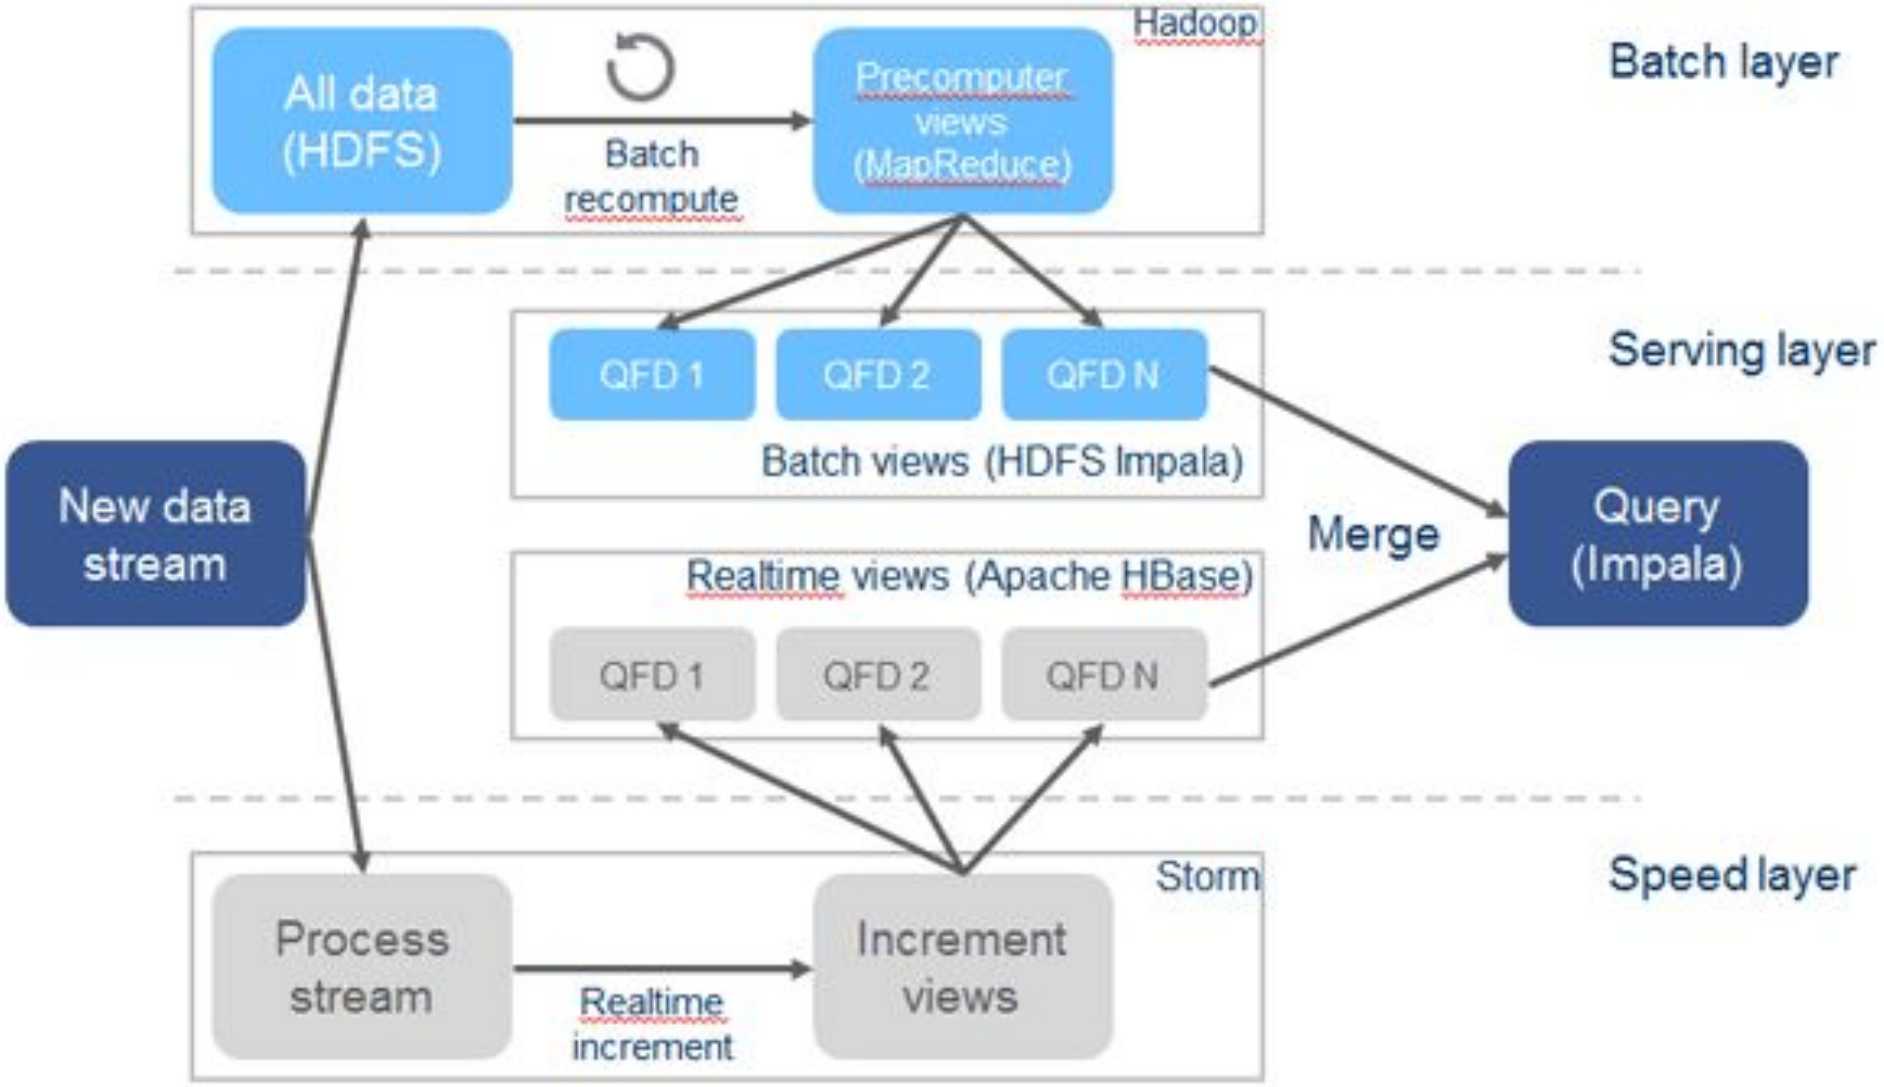
Hadoop
All data (HDFS)
Batch recompute
Precomputer views (MapReduce)
Batch layer
QFD 1
QFD 2
QFD N
Batch views (HDFS Impala)
Serving layer
New data stream
Merge
Query (Impala)
Realtime views (Apache HBase)
QFD 1
QFD 2
QFD N
Storm
Process stream
Realtime increment
Increment views
Speed layer

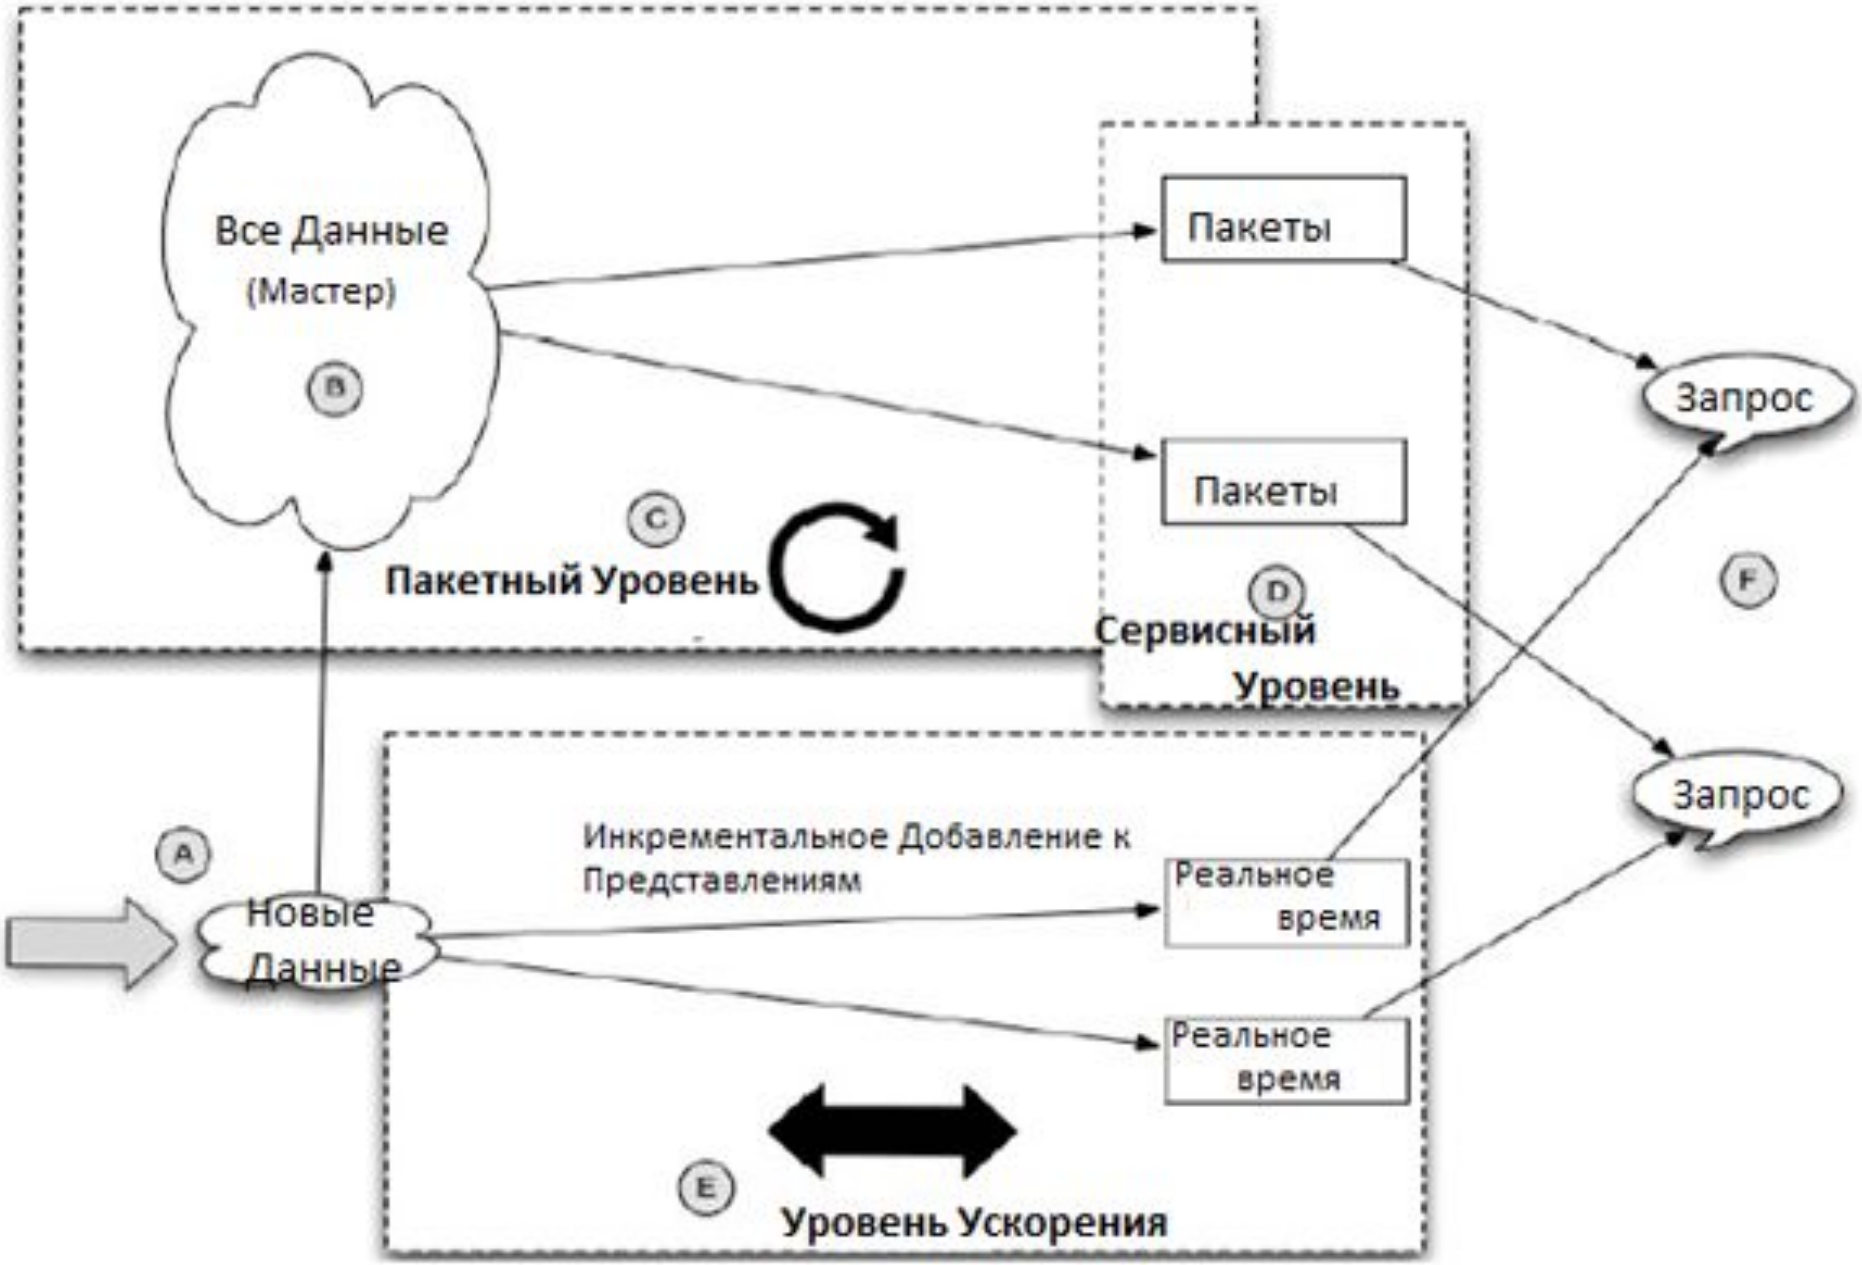
Все Данные
(Мастер)
B
Пакеты
Пакеты
Запрос
Запрос
C
Пакетный Уровень
D
Сервисный
Уровень
F
A
Новые
Данные
Инкрементальное Добавление к
Представлениям
Реальное
время
Реальное
время
E
Уровень Ускорения