ФЕДЕРАЛЬНОЕ АГЕНТСТВО
ПО ТЕХНИЧЕСКОМУ РЕГУЛИРОВАНИЮ И МЕТРОЛОГИИ

Н А Ц И О Н А Л Ь Н Ы Й
С Т А Н Д А Р Т
Р О С С И Й С К О Й
Ф Е Д Е Р А Ц И И

ГОСТ Р /
ИСО/МЭК
20547–3–
(проект)

Информационные технологии

ЭТАЛОННАЯ АРХИТЕКТУРА БОЛЬШИХ ДАННЫХ

Часть 3

Эталонная архитектура

(ISO/IEC 20547–3:2020, IDT)

Издание официальное

Настоящий проект стандарта не подлежит применению до его утверждения

Москва
Российский институт стандартизации
202_

Предисловие

1 ПОДГОТОВЛЕН Научно-образовательным центром компетенций в области цифровой экономики Федерального государственного бюджетного образовательного учреждения высшего образования «Московский государственный университет имени М.В.Ломоносова» (МГУ имени М.В.Ломоносова) и Обществом с ограниченной ответственностью «Институт развития информационного общества» (ИРИО), на основе собственного перевода на русский язык англоязычной версии стандарта, указанного в пункте 4

2 ВНЕСЕН Техническим комитетом по стандартизации ТК 164 «Искусственный интеллект»

3 УТВЕРЖДЕН И ВВЕДЕН В ДЕЙСТВИЕ Приказом Федерального агентства по техническому регулированию и метрологии от 202 г. № -ст

4 Настоящий стандарт идентичен международному стандарту ИСО/МЭК 20547–3:2020 «Информационная технология. Эталонная архитектура больших данных. Часть 3: Эталонная архитектура» (ISO/IEC 20547–3:2020, Information technology — Big data reference architecture — Part 3: Reference architecture, IDT)

5 ВВЕДЕН ВПЕРВЫЕ

Правила применения настоящего стандарта установлены в статье 26 Федерального закона от 29 июня 2015 г. № 162-ФЗ «О стандартизации в Российской Федерации». Информация об

изменениях к настоящему стандарту публикуется в ежегодном (по состоянию на 1 января текущего года) информационном указателе «Национальные стандарты», а официальный текст изменений и поправок — в ежемесячном информационном указателе «Национальные стандарты». В случае пересмотра (замены) или отмены настоящего стандарта соответствующее уведомление будет опубликовано в ближайшем выпуске ежемесячного информационного указателя «Национальные стандарты». Соответствующая информация, уведомление и тексты размещаются также в информационной системе общего пользования — на официальном сайте Федерального агентства по техническому регулированию и метрологии в сети Интернет (www.rst.gov.ru)

© ISO, 2020

© IEC, 2020

© Оформление. ФГБУ «Институт стандартизации», 202_

Настоящий стандарт не может быть полностью или частично воспроизведен, тиражирован и распространен в качестве официального издания без разрешения Федерального агентства по техническому регулированию и метрологии

Содержание

1 Область применения .....

2 Нормативные ссылки .....

4 Обозначения и сокращения .....

5 Условные обозначения .....

6 Концепция эталонной архитектуры больших данных .....

7 Пользовательское представление .....

8 Сквозные аспекты .....

9 Функциональное представление .....

Приложение А (справочное) Сопоставление функциональных представлений при интеграции эталонной архитектуры больших данных с эталонной архитектурой других систем .....

Приложение В (справочное) Примеры взаимосвязей ролей в экосистеме больших данных .....

Приложение С (справочное) .....

Приложение ДА .....

(справочное) .....

Сведения о соответствии ссылочных международных стандартов национальным стандартам .....

Библиография .....

Введение

Серия стандартов ИСО/МЭК 20547 предназначена для предоставления пользователям стандартизованного подхода к разработке и внедрению архитектур больших данных и предоставления необходимых справочных материалов. Стандарт ИСО/МЭК 20547–1 содержит общие представления о структуре эталонной архитектуры, представленной в стандарте, а также описывает процесс ее применения в ходе выполнения разработки архитектуры. Стандарт ИСО/МЭК 20547–2 включает набор вариантов использования больших данных и представляет их в виде совокупности технических условий, которые могут учитываться архитекторами больших данных и разработчиками систем, а также могут использоваться архитектором больших данных для описания конкретной системы. Стандарт ИСО/МЭК 20547–4 описывает аспекты защищенности и конфиденциальности персональных данных, которые являются уникальными для больших данных. Стандарт ИСО/МЭК 20547–5 содержит перечень стандартов и описывает их взаимосвязи с эталонной архитектурой, которую архитекторы и разработчики могут рассматривать как составную часть процесса проектирования и реализации своей системы.

Каждая из этих частей построена на общих подходах: словаре и концепциях, представленных в стандарте ИСО/МЭК 20546.

В общих чертах, эталонная архитектура представляет собой авторитетный источник информации о конкретной предметной области, который направляет и ограничивает реализацию нескольких архитектур и решений (см. п. 3.2).

Эталонные архитектуры обычно служат рекомендованной основой для архитектурных решений, а также могут использоваться в целях сравнения и согласования.

Ключевая цель эталонной архитектуры — обеспечивать общее понимание и представление различных продуктов, организаций и дисциплин применительно к существующим архитектурам и их будущим вариантам развития.

Эталонная архитектура, описанная в настоящем стандарте, представляет собой структуру архитектуры, предназначенную для описания компонентов больших данных, процессов и систем больших данных, чтобы установить общий (универсальный) язык для общения заинтересованных сторон, и носит название эталонной архитектурой больших данных. Настоящий стандарт не представляет системную архитектуру конкретной системы больших данных. Это — инструмент для описания и обсуждения, а также разработки системных архитектур используя структуру эталонной архитектуры. Он обеспечивает общие высокоуровневые архитектурные представления, которые являются эффективным инструментом для обсуждения требований, структур и операций, присущих большим данным. Представленная в стандарте модель не привязана к продуктам, сервисам или эталонным реализациям конкретных поставщиков, а также не содержит нормативные решения, препятствующие инновациям.

НАЦИОНАЛЬНЫЙ СТАНДАРТ РОССИЙСКОЙ ФЕДЕРАЦИИ

Информационные технологии
ЭТАЛОННАЯ АРХИТЕКТУРА БОЛЬШИХ ДАННЫХ
Часть 3
Эталонная архитектура

Information technology. Big data reference architecture. Part 3. Reference architecture

Дата введения – с __-____-____

1 Область применения

Настоящий стандарт определяет эталонную архитектуру больших данных. Эталонная архитектура больших данных включает концепции и архитектурные представления.

Эталонная архитектура больших данных, представленная в стандарте, определяет две архитектурные точки зрения:

- пользовательское представление, определяющее роли/подроли, их отношения и типы действий в экосистеме больших данных;

- функциональное представление, определяющее архитектурные уровни и классы функциональных компонентов на этих уровнях, которые реализуют виды деятельностей ролей/подролей в пользовательском представлении.

Эталонная архитектура больших данных предназначена для:

- обеспечения общего языка для различных заинтересованных сторон;

Издание официальное

- поощрения приверженности соблюдения общих стандартов, спецификаций и шаблонов;

- обеспечения согласованность реализации технологии для решения однотипных наборов задач;

- облегчения понимания операционных особенностей больших данных;

- иллюстрации и понимания различных компонентов, процессов и систем в контексте общей концептуальной модели больших данных;

- подготовки к представлению технической справки для государственных организаций, агентств и других потребителей, обеспечивающей возможности понимания, обсуждения, классификации и сравнения решений для больших данных; а также

- облегчения анализа создаваемых стандартов на интероперабельность, переносимость, возможность повторного использования и расширяемость.

2 Нормативные ссылки

В настоящем стандарте использованы нормативные ссылки на следующие межгосударственные стандарты и рекомендации [для датированных ссылок применяются только указанное издание ссылочного стандарта, для недатированных – последнее издание (включая все изменения)]:

ISO 8000-2, Data quality — Part 2: Vocabulary (Качество данных. Часть 2. Словарь).

ISO/TS 8000-60, Data quality — Part 60: Data quality management: Overview (Качество данных — Часть 60: Управление качеством данных. Обзор).

ISO 8000-61 Data quality — Part 61: Data quality management: Process reference model (Качество данных. —Часть 61. Менеджмент качества данных. Эталонная модель процесса).

ISO/IEC 38500 Information technology — Governance of IT for the organization (Информационные технологии. Управление ИТ в организации).

ISO/IEC 38505-1, Information technology — Governance of IT — Governance of data — Part 1: Application of ISO/IEC 38500 to the governance of data (Информационные технологии. Управление ИТ. Управление данными. Часть 1. Применение ИСО/МЭК 38500 к управлению данными).

ISO/IEC TR 38505-2, Information technology — Governance of IT — Governance of data — Part 2: Implications of ISO/IEC 38505-1 for data management (Управление активами. Системы менеджмента. Руководство по применению ISO 55001).

ISO 55000, Asset management — Overview, principles and terminology (Управление активами. Обзор, принципы и терминология).

ISO 55001, Asset management — Management systems — Requirements (Управление активами. Системы менеджмента. Требования).

ISO 55002, Asset management — Management systems — Guidelines for the application of ISO 55001 (Управление активами. Системы менеджмента. Руководство по применению ISO 55001).

ISO/IEC/IEEE 42010, Systems and software engineering — Architecture description (Разработка систем и программного обеспечения. Описание архитектуры).

ISO/IEC 20546, Information technology — Big data — Overview and vocabulary (Информационные технологии. Большие данные. Обзор и словарь).

ISO/IEC 17789, Information technology — Cloud computing — Reference architecture (Информационные технологии. Облачные вычисления. Эталонная архитектура).

3 Термины и определения

Для целей настоящего стандарта применяются термины и определения, приведенные в [6], [7], [19] – [28].

ИСО и МЭК поддерживают терминологические базы данных для использования в стандартизации, расположенные по следующим адресам:

- платформа ИСО для онлайн-просмотра материалов по стандартам (Online Browsing Platform, OBP) доступна по адресу https://www.iso.org/obp/ui;

- база данных МЭК «Электропедия» (IEC Electropedia) доступна по адресу http://www.electropedia.org/.

ISO и IEC поддерживают терминологические базы данных для использования в стандартизации по следующим адресам:

- Платформа просмотра ISO Online: доступно по адресу https://www.iso.org/home.html;

- IEC Electropedia: доступно по адресу https://www.electropedia.org/.

В настоящем стандарте также применены следующие термины с соответствующими определениями:

3.1 **данные** (data): Реинтерпретируемое представление информации (3.3) формализованным способом, обеспечивающим коммуникацию,интерпретацию или обработку.

[ИСО/МЭК 2382:2015, 2121272]

3.2 **эталонная архитектура** (reference architecture): Авторитетный источник информации о конкретной предметной области, который направляет и ограничивает реализацию множества архитектур и решений.

Примечание 1 — В настоящем стандарте используется определение эталонной архитектуры из документа «Описание эталонной архитектуры» Министерства обороны США (DoD) [7].

Примечание 2 — Эталонные архитектуры обычно служат основой для выбора варианта архитектуры, а также могут использоваться для сравнения и согласования конкретных вариантов архитектур и принятых решений.

3.3 **информация** (information): Данные (3.1), которые обрабатываются, организуются и коррелируются для получения выходного значения.

Примечание — Информация касается фактов, концепций, объектов, событий, идей, процессов и т. д.

3.4 **деятельность** (activity): Заданная последовательность или совокупность задач.

[ИСО/МЭК 17789:2014, 3.2.1]

3.5 **знание** (knowledge): Сохраняемая, обрабатываемая и интерпретируемая информация (3.3).

[ИСО 5127:2017, 3.1.1.17]

3.6 **функциональный компонент** (functional component): Функциональный структурный блок, необходимый для участия в виде деятельности (3.4), поддерживаемой в ходе имплементации.

[ИСО/МЭК 17789:2014, 3.2.3]

3.7 **стратегическое управление данными** (data governance): Свойство или способность, которые необходимо координировать и реализовывать с помощью набора действий (3.4), направленных на разработку, внедрение и мониторинг стратегического плана управления информационными активами.

Примечание 1 — Стратегическое управление данными описано в ИСО/МЭК 38505–1.

Примечание 2 — Под активом данных понимается набор элементов данных или объектов данных, которые имеют реальную или потенциальную выгоду для организации. Актив данных — это подмножество активов, определенных в ИСО 55000. Выгода — это преимущество организации практических знаний, полученных из аналитической системы. Его часто приписывают большим данным из-за понимания того, что данные имеют потенциальную пользу, которая ранее обычно не рассматривалась.

Примечание 3 — Стратегический план управления активами данных — это документ, который определяет, как управлять данными (3.15). Он должен быть согласован со стратегией организации. Этот термин имеет то же значение, что и план стратегического управления активами, определенный в ИСО 55000 с точки зрения данных.

3.8 **качество данных** (data quality): Степень, в которой характеристики данных удовлетворяют заявленным и предполагаемым потребностям при использовании в определенных условиях.

[ИСО/МЭК 25024:2015, 4.11]

3.9 **управление качеством данных** (data quality management): Скоординированные действия по руководству и контролю организации в отношении качества данных.

[ИСО 8000–2:2018, 3.4.9]

3.10 **сторона** (party): Физическое или юридическое лицо, зарегистрированное или не зарегистрированное, или их группа.

[ИСО/МЭК 17789:2014, 7.2.3]

3.11 **политика** (policy): Цель и направление деятельности организации, официально выраженное ее высшим руководством.

[ИСО 55000:2014, 3.1.18, измененный — термин был изменен на форму единственного числа, и конечная часть удалена из определения]

3.12 **роль** (role): Набор действий (3.4), которые служат общей цели.

[ИСО/МЭК 17789:2014, 3.2.7]

3.13 **поток** (stream): Список объектов потока, прикрепленных к порту объекта потока.

[ИСО/МЭК 10179:1996, 4.33, изменено — путем удаления начального артикля и точки в конце]

3.14 **подроль** (sub-role): Подмножество деятельностей (3.4) данной роли (3.14).

[ИСО/МЭК 17789:2014, 3.2.9]

3.15 **управление данными** (data management): Совокупность деятельностей (3.4), направленных на имплементацию архитектуры больших данных, которая наилучшим образом отвечает бизнес-целям в соответствии со стратегическим планом оценки управления данными.

3.16 **жизненный цикл данных** (data lifecycle): Стадии управления данными.

Примечание — Цель жизненного цикла (определенная в ISO 55000) — это данные в настоящем документе.

3.17 **интерфейс прикладного программирования** (application programming interface, API): Граница, через которую прикладное

программное обеспечение использует средства языков программирования для вызова сервиса.

[ИСО/МЭК 18012–2:2012, 3.1.4, изменено — примечание 1 к записи было удалено, а конечная часть была удалена из определения]

4 Обозначения и сокращения

API — Программный интерфейс приложения (application programming interface)

ACID — Атомарность, непротиворечивость, изоляция и долговечность (atomicity, consistency, isolation, and durability)

CPU — Центральное процессорное устройство (central processing unit)

CEP — Обработка сложных событий (complex event processing)

BDA — Аудитор больших данных (big data auditor)

BDAP — Сервис-провайдер приложения больших данных (big data application provider)

BDAcP — Сервис-провайдер доступа к большим данным (big data access provider)

BDAnP — Сервис-провайдер аналитики больших данных (big data analytics provider)

BDC — Потребитель больших данных (big data consumer)

BDCP — Сервис-провайдер комплектования больших данных (big data collection provider)

BDFP — Сервис-провайдер среды обработки больших данных (big data framework provider)

BDIP — Сервис-провайдер инфраструктуры больших данных (big data infrastructure provider)

BDP — Сервис-провайдер больших данных (big data provider)

BDPlaP — Сервис-провайдер платформы больших данных (big data platform provider)

BDPreP — Сервис-провайдер предобработки больших данных (big data preparation provider)

BDProP — Сервис-провайдер обработки больших данных (big data processing provider)

BDRA — Эталонная архитектура больших данных (big data reference architecture)

BDSD — Разработчик сервиса больших данных (big data service developer)

BDSO — Оркестратор системы больших данных (big data system orchestrator)

BDSP — Партнер сервиса больших данных (big data service partner)

BDVP — Сервис-провайдер визуализации больших данных (big data visualization provider)

DG — Стратегическое управление данными (data governance)

DV — Менеджер данных (data manager)

DQM — Менеджер качества данных (data quality manager)

PII — Личная идентифицируемая информация (personally identifiable information)

RA — Эталонная архитектура (reference architecture)

5 Условные обозначения

Схемы, представленные в настоящем стандарте, построены с использованием условных обозначений, представленных в таблице 1. Эти обозначения используются, как описано в ИСО/МЭК 17789.

Таблица 1 — Пояснения к диаграммам, используемым в настоящем стандарте

Объект	Обозначение
	Сторона
	Роль
	Подроль
	Деятельность
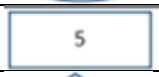	Функциональный компонент
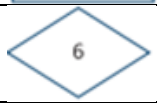	Сквозной аспект

6 Концепция эталонной архитектуры больших данных

6.1 Общие положения

В настоящем стандарте определяется эталонная архитектура больших данных, которая служит фундаментальной точкой отсчета для стандартизации больших данных и представляет общую структуру архитектуры для описания основных концепций и принципов, лежащих в основе системы больших данных.

Настоящий стандарт описывает логические взаимосвязи (соотношения): между ролями/подролями, видами деятельности и функциональными компонентами, а также сквозные аспекты, составляющие архитектуру системы больших данных.

На рассмотренные взаимосвязи (отношения) распространяются и некоторые другие стандарты, которые могут использоваться для:

- уточнения уровня потока информации или других типов интероперабельности и/или

- обеспечения заданных уровней качества (например, уровня защищенности или уровня сервиса).

Логические взаимосвязи, определенные в рамках эталонной архитектуры больших данных, являются важной частью ее спецификации и функционирования затрагивают такие вопросы, как категории информационных потоков между ее функциональными компонентами.

6.2 Представления

Большие данные могут быть описаны с использованием представлений. В эталонной архитектуре больших данных используются четыре вида различных представления (см. рисунок 1 и таблицу 2).

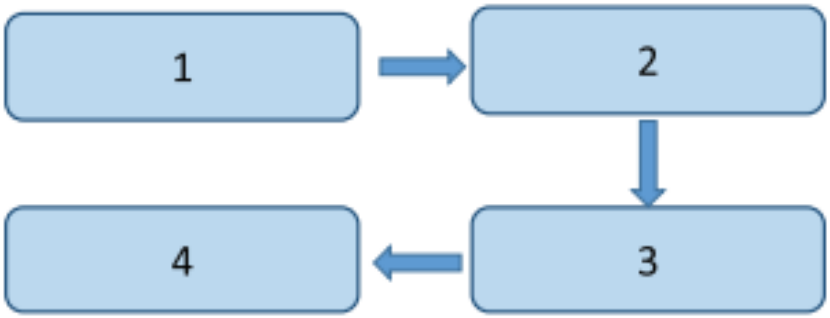

Обозначения:

1 – пользовательское представление

2 – функциональное представление

3 – представление реализации

4 – представление развертывания

Рисунок 1 — Взаимосвязи между архитектурными представлениями

Т а б л и ц а 2 — Представления в рамках эталонной архитектуры больших данных

Представление	Описание представления	Области применения
Пользовательское представление	Экосистема больших данных с заинтересованными сторонами (используется в ISO/IEC/IEEE 42010), роли, подроли и деятельность с большими данными	В рамках эталонной архитектуры больших данных
Функциональное представление	Функции, необходимые для поддержки деятельности с большими данными	В рамках эталонной архитектуры больших данных
Представление реализации	Функции, необходимые для реализации больших данных в сервисных компонентах и/или компонентах инфраструктуры	Вне рамок эталонной архитектуры больших данных
Представление развертывания	Каким образом технически реализованы функции больших данных в существующих компонентах инфраструктуры или в новых компонентах, которые будут встроены в эту инфраструктуру	Вне рамок эталонной архитектуры больших данных

П р и м е ч а н и е — В настоящем стандарте рассматриваются детали пользовательского и функционального представлений, в то же время представления реализации и развертывания связаны с технологиями и реализациями больших данных конкретных поставщиков и фактическими вариантами развертывания и, следовательно, выходят за рамки настоящего стандарта.

5.1. Обзор пользовательского представления

В рамках пользовательского представления в экосистеме больших данных используются следующие понятия:

- **Стороны:** Сторона представляет собой физическое или юридическое лицо, зарегистрированное или не зарегистрированное, или их группа. Стороны в экосистеме больших данных являются ее заинтересованными сторонами;

- **Роли и подроли:** Роль представляет собой набор деятельностей с большими данными, служащих общей цели: подроль – это подмножество деятельностей с большими данными для данной роли, и разные подроли могут совместно использовать деятельности, ассоциированные с данной ролью;

- **Виды деятельности:** Деятельность представляет собой определенный исполнение или набор задач, которые должны иметь цель и обеспечивать получение одного или нескольких результатов. Деятельность реализуется с использованием функциональных компонентов.

- **Сквозные аспекты:** Сквозные аспекты могут быть общими и влиять на несколько ролей и на деятельности с большими данными. Сквозные аспекты сопоставляются с многоуровневыми функциями и связанными с ними функциональными компонентами, которые реализуют деятельности в рамках сквозного аспекта.

Примечание — Сторона может взять на себя более чем одну роль в любой конкретный момент времени и может участвовать в определенном подмножестве деятельностей этой роли. Примеры сторон включают, помимо прочего, крупные корпорации, малые и средние предприятия, государственные ведомства, академические учреждения и частных лиц.

На рисунке 2 показаны взаимосвязи между сущностями пользовательского представления.

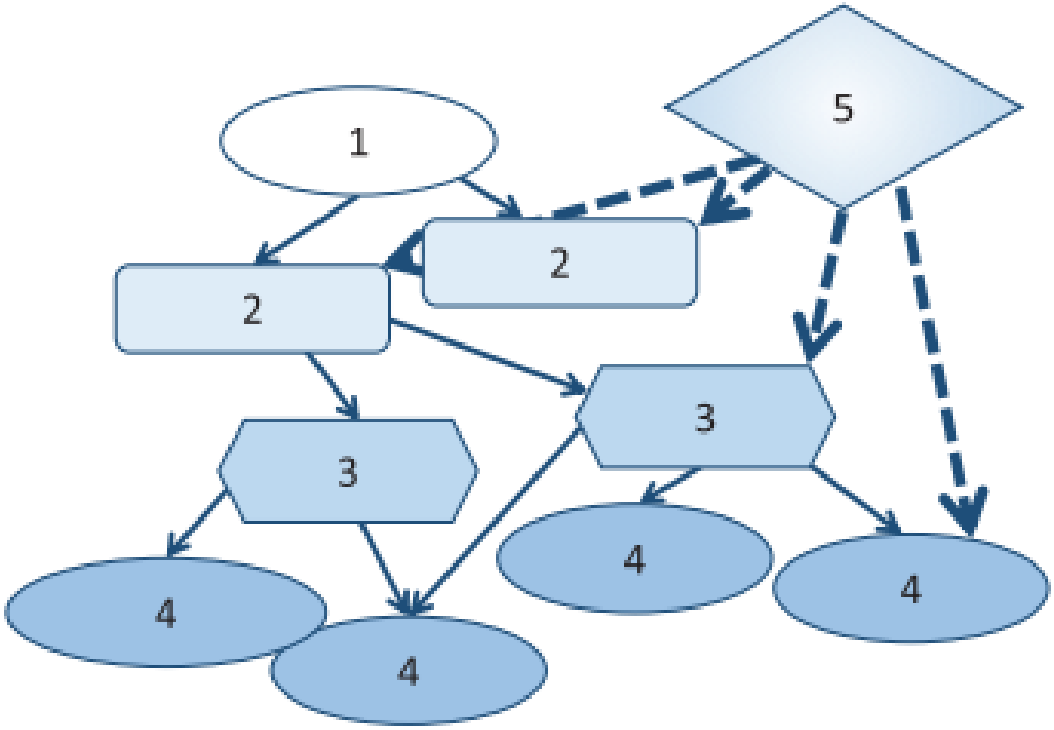

Обозначения:

1 сторона

2 роль

3 подроль

4 деятельность

5 сквозной аспект

Рисунок 2 — Сущности пользовательского представления

6.4 Обзор функционального представления

Функциональное представление является технологически нейтральным представлением о функциях, необходимых для формирования системы больших данных. Оно описывает распределение функций, необходимых для поддержания деятельностей с большими

данными. Функциональная архитектура также определяет взаимозависимости между функциями.

В архитектуре больших данных рассматриваются следующие понятия в рамках функционального представления:

- **Функциональные компоненты:** функциональный компонент представляет собой функциональный строительный блок, который предназначен для участия в деятельности в процессе имплементации.

- **Функциональные уровни:** уровень представляет собой набор функциональных компонентов со схожими возможностями или служащими общей цели.

- **Многоуровневые функции:** многоуровневые функции включают в себя функциональные компоненты с возможностями, используемыми на нескольких функциональных уровнях, и они сгруппированы в подмножества.

Примечание — Создание функциональных компонентов в конкретной системе больших данных на всех уровнях является необязательным.

На рисунке 3 показаны сущности, определенные для пользовательского представления.

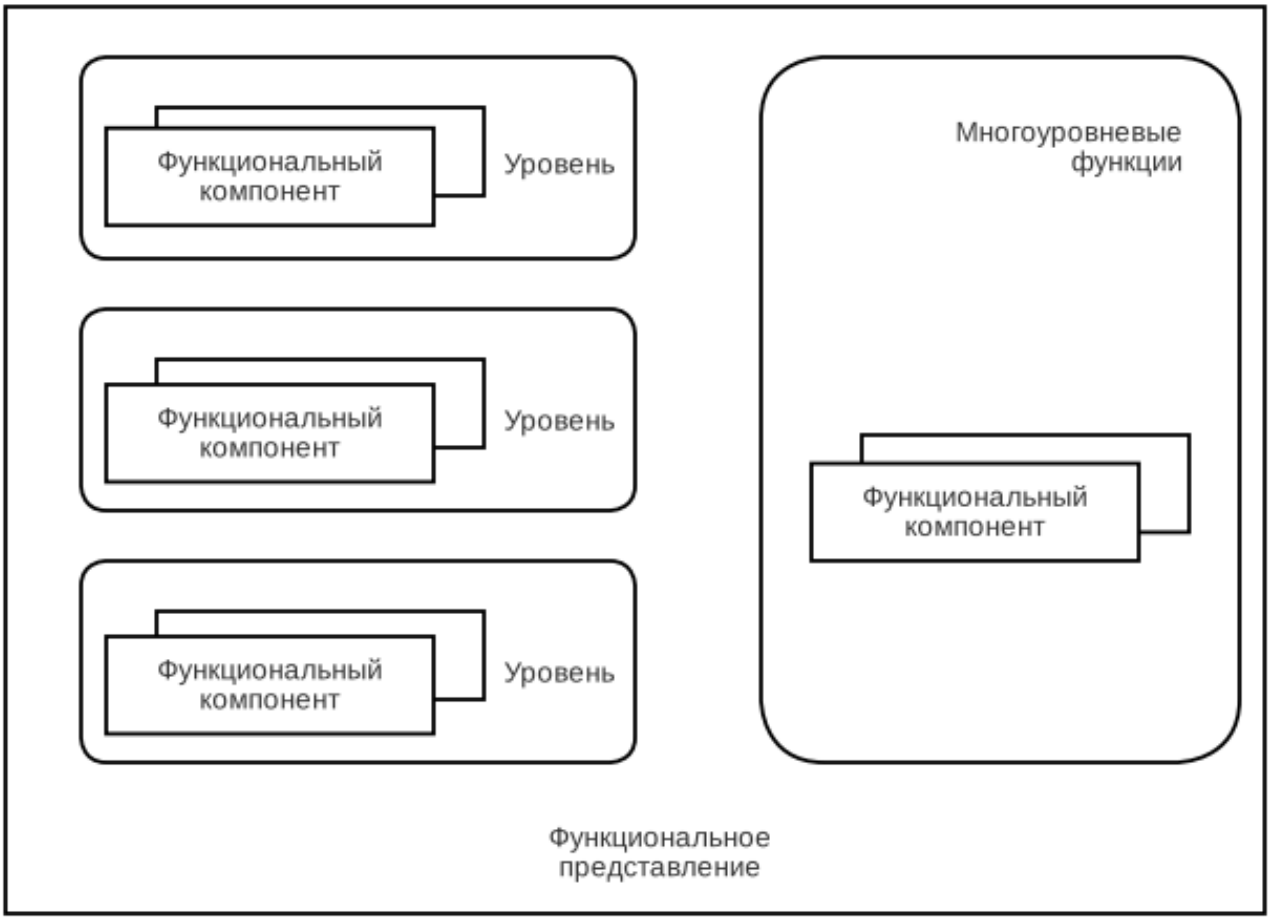

Рисунок 3 — Функциональные уровни

6.5 Взаимосвязи между пользовательским и функциональным представлениями

На рисунке 4 показана взаимосвязь пользовательского представления, отражающего совокупность деятельностей с большими данными, и функционального представления в виде набора функциональных компонентов.

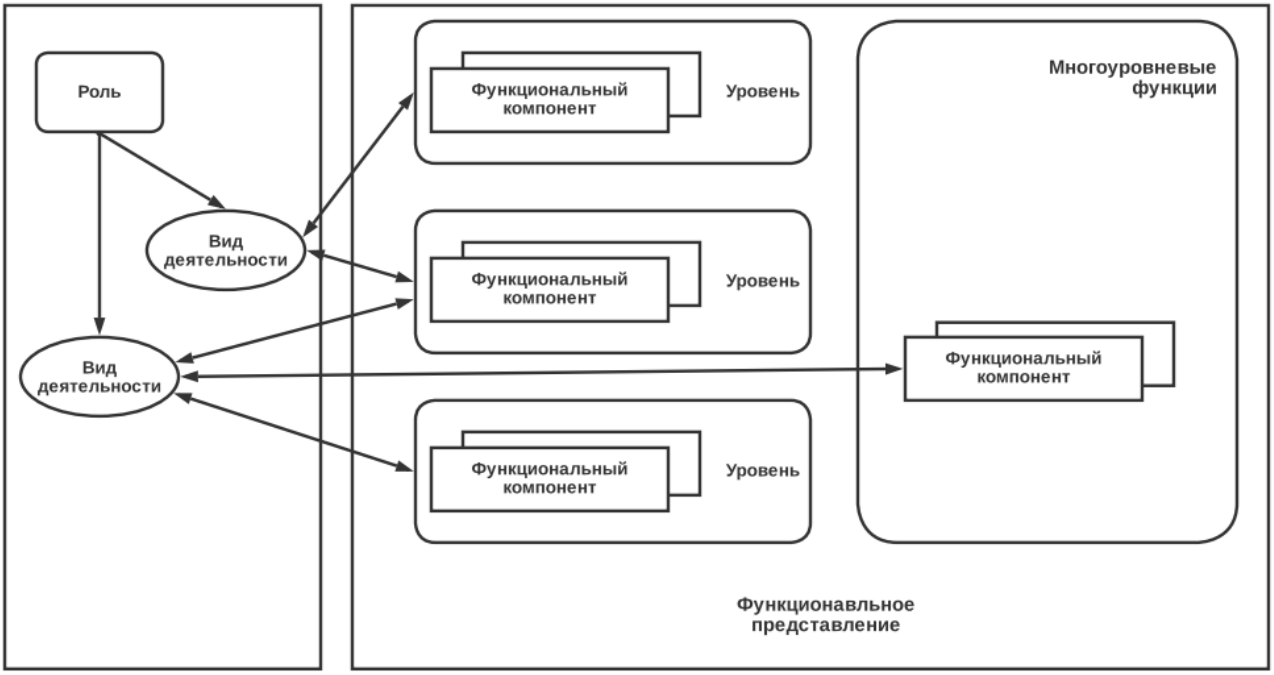

Рисунок 4 — От пользовательского представления к функциональному представлению

6.6 Взаимосвязи пользовательского и функционального представлений применительно к сквозным аспектам

Сквозные аспекты, как следует из их названия, применимы как к пользовательскому представлению, так и к функциональному представлению больших данных.

В пользовательском представлении сквозные аспекты применяются к ролям и подролям и прямо или косвенно влияют на выполняемые этими ролями различные виды деятельности

В функциональном представлении сквозные аспекты также относятся к функциональным компонентам, которые используются при выполнении видов деятельности, описанных в пользовательском представлении (см. рисунок 4).

Сквозные аспекты больших данных описаны в разделе 9 и включают:

- безопасность персональных данных;
- оперативное управление данными;
- стратегическое управление данными.

7 Пользовательское представление

7.1 Роли, подроли и виды деятельности с большими данными

Учитывая, что распределенные услуги и их предоставление лежат в основе применения больших данных, все виды деятельности, связанные с большими данными, можно разделить на три основные группы: виды деятельности, использующие большие данные, виды деятельности, предоставляющие услуги анализа больших данных, и виды деятельности, предоставляющие данные.

В настоящем разделе представлены описания некоторых общих ролей и подролей, связанных с большими данными.

Важно отметить, что сторона может играть более одной роли в любой момент времени. Играя роль, сторона может ограничиться исполнением одной или нескольких подролей. Подроли — это подмножество деятельностей конкретной роли с большими данными.

Как показано на рисунке 5 в архитектуре больших данных выделяются следующие роли:

- сервис-провайдер приложения больших данных (BDAP) (см. 7.2);
- сервис-провайдер прикладной среды обработки больших данных (BDFP) (см. 7.3).
- партнер сервиса больших данных (BDSP) (см. 7.4)

- сервис-провайдер больших данных (BDP) (см. 7.5);
- потребитель больших данных (BDC) (см. 7.6);

Примечание — Сервис-провайдер больших данных представляет собой любого поставщика данных для эталонной архитектуры больших данных.

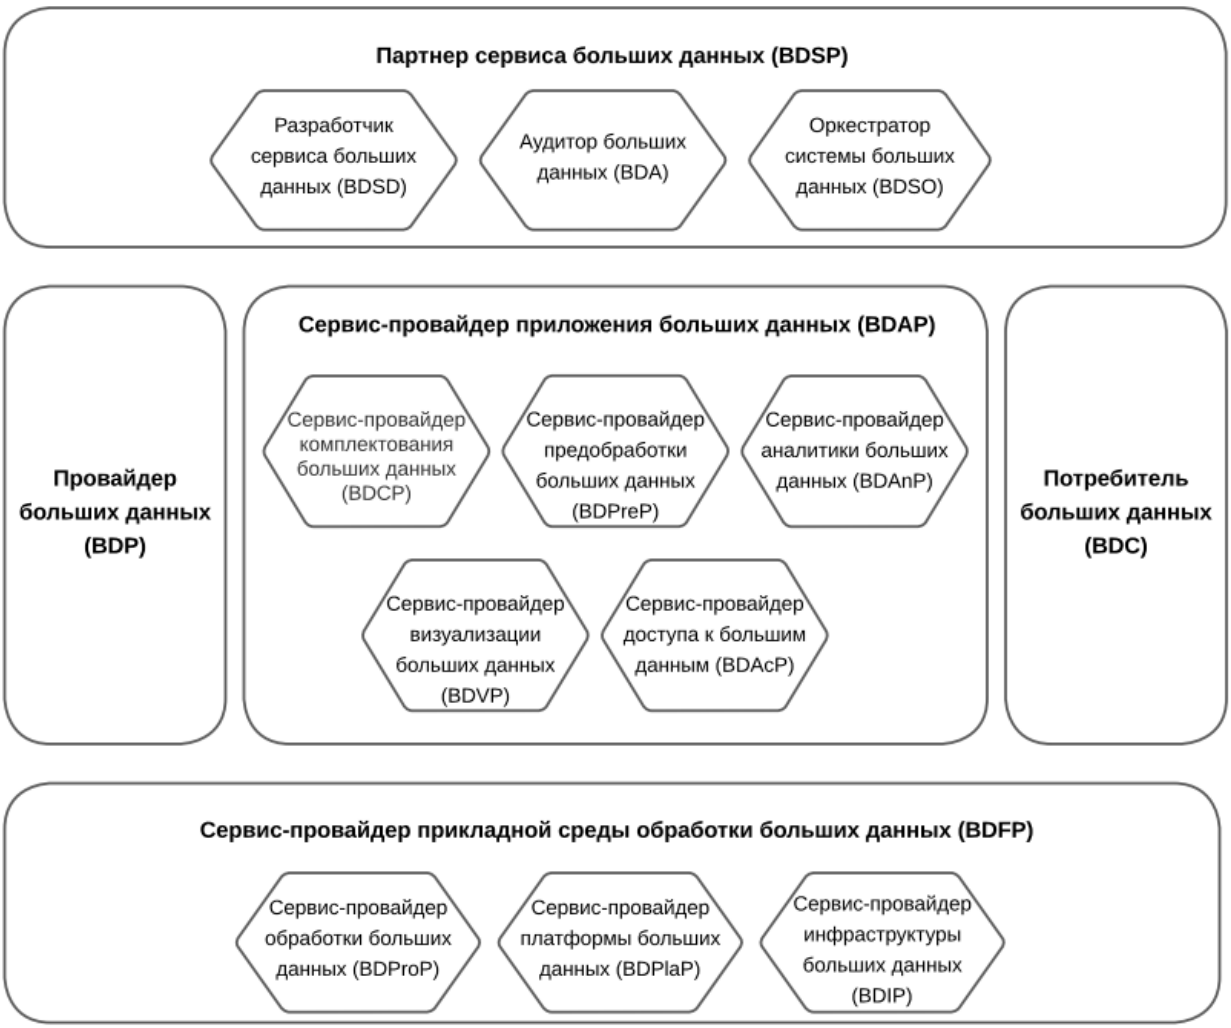

Рисунок 5 — Роли в архитектуре больших данных

В приложении В приведены примеры взаимосвязи ролей в экосистемах больших данных.

Каждая из подролей, показанных на рисунке 5, более подробно описана в разделах с 7.2 по 7.6.

7.2 Роль: сервис-провайдер приложения больших данных

7.2.1 Общие положения

Сервис-провайдер приложения больших данных реализует свои функции на различных этапах жизненного цикла данных. В указанной роли объединены общие возможности пользовательского представления эталонной архитектуры больших данных, отраженные на рисунке 5 и представляющие комбинацию для построения конкретной системы данных.

Примечание 1 — Несмотря на то, что действия провайдера приложений одинаковы независимо от того, касается ли создаваемое решение больших данных или нет, методы и приемы работы с большими данными изменяются в связи с тем, что данные и их обработка распараллеливаются между ресурсами.

Примечание 2 — Поскольку данные распространяются в рамках экосистемы, они обрабатываются и преобразуются для извлечения результатов из исходной информации различными способами. Каждый вид деятельности провайдера приложения больших данных может быть реализован независимыми заинтересованными сторонами и представлен как автономный сервис.

Примечание 3 — Сервис-провайдер приложения больших данных может быть отдельным экземпляром или совокупностью специализированных сервис-провайдеров приложения больших данных, каждый из которых реализует различные этапы жизненного цикла данных. Каждый из видов деятельности сервис-провайдера приложения больших данных может представлять собой общий сервис, вызываемый сервис-провайдером данных или потребителем больших данных (предоставляемых, например: веб-сервером, файловым сервером, набором из нескольких прикладных программ или их комбинации).

Примечание 4 — Сервис-провайдер приложения больших данных обеспечивает реализацию, тестирование и валидацию бизнес-правил, а также требований и метрик качества данных, которые обеспечивают корректное управление

данными в системе больших данных. Любой провайдер приложения может обеспечить выполнение требований к качеству данных на протяжении всего жизненного цикла данных.

Сервис-провайдер приложения больших данных включает следующие пять подролей, как показано на рисунке 6:

- сервис-провайдер комплектования больших данных (см. 7.2.2);
- сервис-провайдер предобработки больших данных (см. 7.2.3);
- сервис-провайдер аналитики больших данных (см. 7.2.4);
- сервис-провайдер визуализации больших данных (см. 7.2.5);
- сервис-провайдер доступа к большим данным (см. 7.2.6).

Рисунок 6 — Виды деятельности подролей сервис-провайдера приложения больших данных

7.2.2 Подроль: сервис-провайдер комплектования больших данных

Сервис-провайдер комплектования больших данных является подролью сервис-провайдера приложения больших данных, которая обеспечивает комплектование больших данных от провайдера данных. Таким сервис-провайдером может быть общий сервис, предоставляемый: файловым сервером или веб-сервером для приема или выполнения конкретных наборов данных, или специализированным сервисом, предназначенным для извлечения данных или получения данных в форме пуш-уведомлений от провайдера данных.

Сервис-провайдер комплектования больших данных включает следующие виды деятельности:

- вид деятельности «**Найти источник данных**», направленной на поиск и хранение метаданных источников данных, которые можно использовать для сбора и/или хранения данных;

- вид деятельности «**Собрать данные**», направленной на преобразование доступных данных (например, веб-документ, данные блога и т.д.) в форму, которая может быть обработана системой;

- вид деятельности «**Регистрировать и буферизировать данные**», направленной на сохранение данных в реестре данных или временное хранение данных перед их передачей другим задачам или процессам.

7.2.3 Подроль: сервис-провайдер предобработки больших данных

Сервис-провайдер предобработки больших данных является подролью сервис-провайдера приложения больших данных, которая обеспечивает подготовку необработанных данных к проведению анализа. Сервис-провайдер предобработки больших данных включает следующие виды деятельности:

- вид деятельности «**Преобразовать данные**», направленной на преобразование данных или информации из одного формата в другой;

- вид деятельности «**Валидировать данные**», направленной на обеспечение корректности данных с использованием допустимых условий, таких как корректность, значимость, безопасность и конфиденциальность и т.д.;

- вид деятельности «**Очистить данные**», направленной на обнаружение некорректной части данных и их исправление путем замены, изменения или удаления;

- вид деятельности «**Агрегировать данные**», направленной на объединение двух или более наборов данных в один сводный набор данных.

Валидация и очистка данных должны проводиться с учетом требований системы менеджмента качества данных.

7.2.4 Подроль: сервис-провайдер аналитики больших данных

Сервис-провайдер аналитики больших данных является подролью сервис-провайдера приложения больших данных, которая обеспечивает анализ больших данных в соответствии с требованиями, предъявляемыми к ним, для получения информации, которая соответствует технической цели.

Вид деятельности сервис-провайдера аналитики больших данных представляет собой взаимосвязанное аналитическое логическое действие, которое включает моделирование процессов обработки данных в соответствии с логикой, предназначенной для извлечения информации из данных, на основе предъявляемых к приложению требований.

7.2.5 Подроль: сервис-провайдер визуализации больших данных

Сервис-провайдер визуализации больших является подролью сервис-провайдера приложения больших данных, которая обеспечивает представление потребителю больших данных информации об источнике данных или результатов анализа. Целью указанных видов деятельностей является форматирование и представление данных таким образом, который обеспечивает оптимальную передачу как смысла, так и знаний.
Сервис-провайдер визуализации больших включает следующие виды деятельности:

- вид деятельности «**Опубликовать статус данных**», направленной на описание состояния данных в хранилище данных и включающая различные виды визуализации, критерии классификации и т.д.;

- вид деятельности «**Форматировать результат анализа**», направленной на форматирование обработанных данных с целью надежной и эффективной коммуникации и включающая визуальное представление, наложение и т.д.

7.2.6 Подроль: сервис-провайдер доступа к большим данным

Сервис-провайдер доступа к большим данным является подролью сервис-провайдера приложения больших данных, которая обеспечивает обмен данными между приложением больших данных и провайдером больших данных или потребителем больших данных.

Сервис-провайдер доступа к большим данным включает вид деятельности «**Передать данные**» (Transfer data), направленной на передачу или перезапись больших данных из одной системы в другую,

обеспечивая их целостность, непрерывность, защищенность и конфиденциальность передачи данных.

7.3 Роль: сервис-провайдер среды обработки больших данных

7.3.1 Общие положения

Сервис-провайдер среды обработки больших данных состоит из одного или нескольких иерархически организованных экземпляров компонентов. При этом, не требуется, чтобы все экземпляры на данном уровне в иерархии реализовывали одну и ту же технологию.

Примечание — На практике большинство реализаций больших данных представляют собой гибридные системы, сочетающие различные технологические подходы для обеспечения гибкости или удовлетворения всего спектра требований сервис-провайдера приложения больших данных.

Сервис-провайдер среды обработки больших данных включает следующие три подроли (см. рисунок 7):

- сервис-провайдер инфраструктуры больших данных (см.п. 7.3.2);
- сервис-провайдер платформы больших данных (см. п. 7.3.3);
- сервис-провайдер обработки больших данных (см. п. 7.3.3).

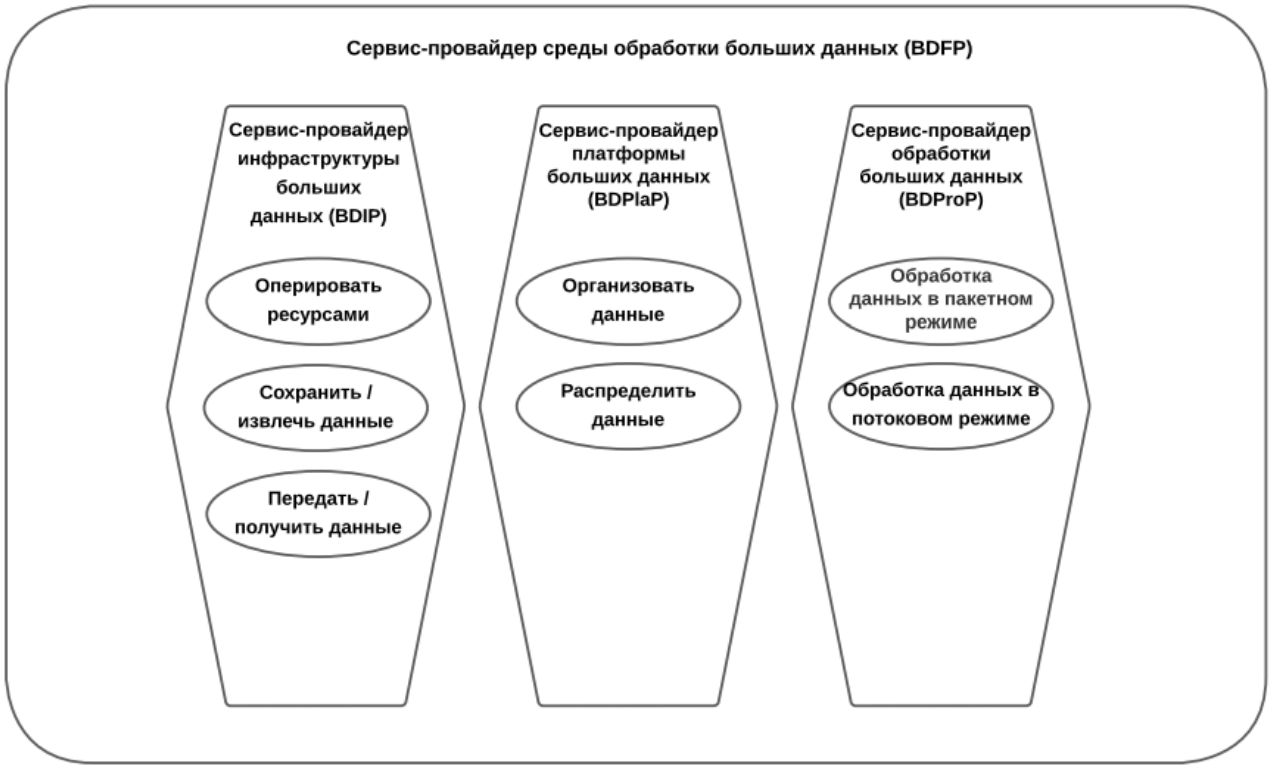

Рисунок 7 — Виды деятельности подролей сервис-провайдера среды обработки больших данных

7.3.2 Подроль: сервис-провайдер инфраструктуры больших данных

Сервис-провайдер инфраструктуры больших данных является подролью сервис-провайдера среды обработки больших данных, которая обеспечивает предоставление системных ресурсов, включая системные средства (например, сети, компьютеры, хранилища и т. д.) и физическую среду (например, компьютерные залы, электропитание, кондиционеры и т.д.).

Сервис-провайдер инфраструктуры больших данных включает следующие виды деятельности:

- вид деятельности «**Оперировать ресурсами**», направленной на обработку или контроль физических или виртуальных ресурсов;

- вид деятельности «**Сохранить/извлечь данные**», направленной на сохранение и извлечение данных из хранилища;

- вид деятельности «**Передать/получить данные**», направленной на передачу данных по сети и доставку получателю.

7.3.3 Подроль: сервис-провайдер платформы больших данных

Сервис-провайдер платформы больших данных является подролью сервис-провайдера среды обработки больших данных, которая обеспечивает предоставление платформ для организации и распределения больших данных в рамках инфраструктуры больших данных и включает следующие виды деятельности:

- вид деятельности «Организовать данные», направленной на ранжирование, индексацию и связывание данных способами, предназначенными для конкретных приложений и аналитики.

- вид деятельности «Распределить данные», направленной на распределение данных между ресурсами инфраструктуры, чтобы максимально локализовать данные для обеспечения необходимого уровня производительности распределенных вычислений.

7.3.4 Подроль: сервис-провайдер обработки больших данных

Сервис-провайдер обработки больших данных является подролью сервис-провайдера среды обработки больших данных, которая обеспечивает поддержку вычислительных и аналитических процессов для деятельностей сервис-провайдера приложения больших данных. Сервис-провайдер обработки больших данных (включает следующие виды деятельности:

- вид деятельности «**Обработка данных в пакетном режиме**»: обработка данных с большим шагом и на непрерывной основе. Пакетная обработка используется, когда время отклика не является критичным. Пакетная обработка чаще всего связана с объемом данных или сложностью анализа.

- вид деятельности «**Обработка данных в потоковом режиме**»: непрерывная обработка данных с небольшим шагом (как правило, отдельные записи или элементы данных). Потоковая обработка используется, когда время отклика является критичным, и чаще всего связана со скоростью данных.

7.4 Роль: партнер сервиса больших данных

7.4.1 Общие положения

Партнер сервиса больших данных является ролью, которая обеспечивает поддерживающий или вспомогательный вид деятельности между провайдером приложения больших данных, провайдером среды обработки больших данных, провайдером больших данных, потребителем больших данных или всеми перечисленными ролями.

В экосистеме больших данных виды деятельности партнера сервиса больших данных в области больших данных варьируются в зависимости от типа партнера и его отношений с другими ролями.

Партнер сервиса больших данных включает следующие три подроли, как показано на рисунке 8:

- разработчик сервиса больших данных (см. 7.4.2);
- аудитор больших данных (см. 7.4.3);
- оркестратор системы больших данных (см. 7.4.4).

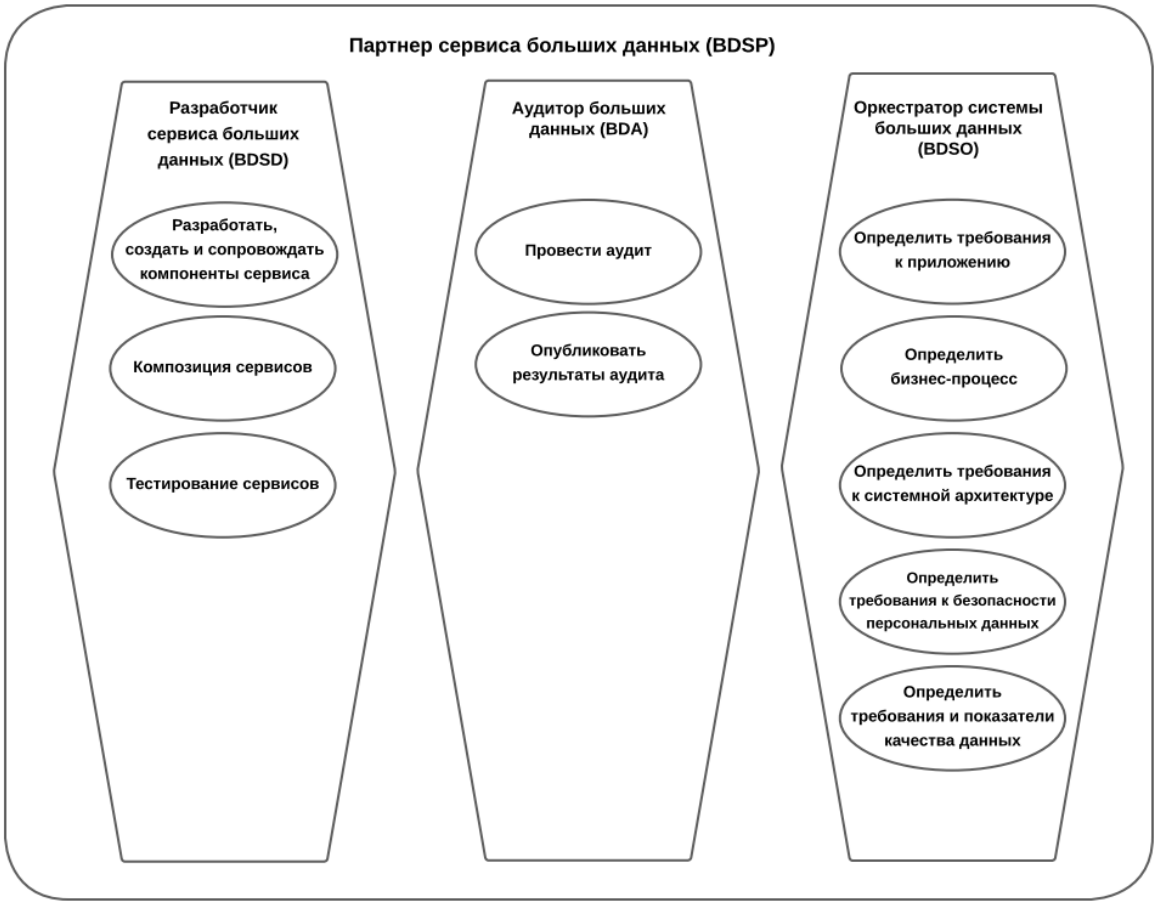

Рисунок 8 — Виды деятельности с большими данными, относящиеся к подролям партнера сервиса больших данных

7.4.2 Подроль: разработчик сервиса больших данных

Разработчик сервиса больших данных является подролью партнера сервиса больших данных, которая обеспечивает: проектирование, разработку, тестирование и поддержку реализации сервиса больших данных, и сопровождение процесса реализации сервиса больших данных.

Разработчик сервиса больших данных включает следующие виды деятельности:

- вид деятельности «**Разработать, создать и сопровождать компоненты сервиса**», направленной на разработку и создание программных компонентов, которые являются частью процесса реализации сервиса больших данных, а также предоставление рекомендаций по совершенствованию этого процесса;

- вид деятельности «**Композиция сервисов**», направленной на композицию сервисов с использованием существующих сервисов путем реализации функций посредничества и их агрегации;

- вид деятельности «**Тестирование сервисов**», направленной на тестирование компонентов и сервисов, созданных разработчиком сервиса больших данных.

7.4.3 Подроль: аудитор больших данных

Аудитор больших данных (BDA) является подролью партнера сервиса больших данных, которая обеспечивает проведение аудита вопросов предоставления и использования сервисов больших данных.

Аудит больших данных охватывает такие вопросы, как: достоверность источников данных, выполняемые операции, производительность, защищенность и конфиденциальность персональных данных, а также проверяет соответствие заданному набору критериев аудита.

Примечание — Существуют различные спецификации для критериев аудита, например, в [8] рассматриваются вопросы безопасности.

Подроль аудитор больших данных включает следующие виды деятельности:

- вид деятельности «**Провести аудит**», направленной на запрос или получение результатов аудита, проведение необходимых тестирований

системы, или данных, подлежащих аудиту, а также получение результатов аудита программным путем.

- вид деятельности «**Опубликовать результаты аудита**», направленной на предоставление документированного отчета о результатах проведения аудита.

Примечание — Аудитор больших данных обеспечивает оценку качества данных, определение и оценку уровней сервиса качества данных, непрерывное измерение и контроль качества данных.

7.4.4 Подроль: оркестратор системы больших данных

Оркестратор системы больших данных является подролью партнера сервиса больших данных (BDSP), которая обеспечивает описание основных требований к системе, включая требования к политике, стратегическому управлению, архитектуре, ресурсам и требований бизнеса, а также мониторинг видов деятельностей для обеспечения соответствия системы этим требованиям.

Подроль оркестратор системы больших данных включает следующие виды деятельности:

- вид деятельности «**Определить требования к приложению**», направленной на определение общих требований, которым должно удовлетворять приложение больших данных;

- вид деятельности «**Определить деловой процесс**», направленной на определение частично упорядоченного набора деятельностей проекта, которые могут быть выполнены для реализации определенной цели проекта или части проекта и достижения некоторого ожидаемого конечного результата;

- вид деятельности «**Определить требования к системной архитектуре**», направленной на определение концептуальных требований для определения структуры, поведения и представления системы больших данных;

- вид деятельности «**Определить требования к безопасности персональных данных**», направленной на определение требований к защищенности и конфиденциальности персональных данных с точки зрения стратегического управления;

- вид деятельности «**Определить требования и показатели качества данных**», направленной на повышение осведомленности о качестве данных, а также на определение бизнес-правил, требований и метрик качества данных;

7.5 Роль: сервис-провайдер больших данных

Сервис-провайдер больших данных позволяет сделать данные доступными как для себя, так и для других. Выполняя свою роль, сервис-провайдер больших данных позволяет формировать абстрактное представление различных типов источников данных, таких как необработанные данные или данные, ранее преобразованные другой системой, и позволяет сделать их доступными через различные функциональные интерфейсы.

Рисунок 9 — Виды деятельности с большими данными, связанные с сервис-провайдером больших данных

Примечание — Концепция провайдера данных не является новой, поскольку более широкие возможности сбора и анализа данных открывают новые возможности для предоставления значимых данных.

Сервис-провайдер больших данных включает следующие виды деятельности (см. рисунок 9):

- вид деятельности «**Сделать данные доступными**», направленной на открытие или распространение источника данных за пределы первоначально предназначенной системы;

- вид деятельности «**Абстрагировать тип источника данных**» направленной на публикацию метаданных или каталога данных с целью распространения данных через реестр.

Примечание — При предоставлении данных другим лицам сервис-провайдер больших данных может отслеживать данные и

управлять выявленными проблемами качества данных в соответствии с требованиями по управлению качеством данных.

7.6 Роль: потребитель больших данных

Потребитель больших данных получает результаты работы системы больших данных.

Во многих отношениях он является получателем тех же функциональных интерфейсов, которые сервис-провайдер больших данных предоставляет сервис-провайдеру приложений для больших данных. После того как системой больших данных будет добавлен смысл источникам исходных данных, сервис-провайдер приложения больших данных в последующем обеспечивает предоставление потребителю больших данных функциональных интерфейсов соответствующего типа.

Рисунок 10 — Виды деятельности с большими данными, связанные с потребителем больших данных

Потребитель больших данных включает следующие виды деятельности (см. рис.10):

- вид деятельности «**Использовать большие данные**», направленной на использование результатов анализа больших данных или использование интерфейсов приложения, предоставляемых провайдером приложения больших данных для бизнес-целей потребителя больших данных;

- вид деятельности «**Оценить большие данные**», направленной на оценку качества больших данных или приложений больших данных в качестве обратной связи.

8 Сквозные аспекты

8.1 Общие положения

К сквозным аспектам относятся:

- **безопасность персональных данных**. Указанный аспект касается того, как системы и данные защищены от риска путем сохранения их конфиденциальности, целостности и доступности, а также того, как персональные данные (ПДн) защищены от несанкционированного использования;

- **оперативное управление**. Указанный аспект относится к тому, как системные компоненты и ресурсы выделяются, настраиваются, используются и контролируются;

- **стратегическое управление данными**. Указанный аспект относится к тому, как данные контролируются и управляются в системе на протяжении этапов их жизненного цикла.

8.2 Безопасность персональных данных

Вопросы безопасности персональных данных затрагивают все остальные роли и подроли в экосистеме больших данных и функциональных компонентах эталонной архитектуры больших данных. Безопасность персональных данных тесно связаны с оркестратором системы больших данных в части политики, требований и проведения аудита, а также сервис-провайдером среды обработки больших данных и сервис-провайдером инфраструктуры больших данных в части разработки, развертывания и эксплуатации системы.

Соображения, связанные с безопасностью больших данных, включают:

- **конфиденциальность**, которая обеспечивает гарантию того, что системы и данные не будут доступны или раскрыты неавторизованным лицам, объектам или процессам;

- **целостность**, которая обеспечивает точность и полноту систем и данных;

- **доступность**, которая обеспечивает гарантию того, что системы и данные доступны и могут использоваться авторизованным органом по требованию.

Соображения, связанные с конфиденциальностью персональных данных в системах больших данных, включают:

- **несвязываемость**, которая обеспечивает гарантию того, что субъект персональных данных может многократно использовать ресурсы или услуги, при этом другие субъекты не смогут связать эти виды использования вместе;

- **прозрачность**, которая обеспечивает достижение надлежащего уровня ясности процессов обработки данных, имеющих отношение к персональным данным с тем, чтобы сбор, обработка и использование информации могли быть понятны и восстановлены в любое время;

- **возможность легитимного вмешательства**, которая обеспечивает гарантию, что субъекты ПДн операторы ПДн, обработчики ПДн, а также надзорные органы могут вмешиваться во все процессы обработки данных, связанные с персональными данными (см. [28], [29]).

8.3 Оперативное управление данными

Такие характеристики больших данных, как объем, скорость, разнообразие и изменчивость, требуют универсальной платформы управления системой и программным обеспечением для: обеспечения, настройки и управления программным обеспечением и пакетной обработкой, мониторинга производительности, а также и управления ресурсами и производительностью. Оперативное управление большими данными включает решение задач, связанных с: системой больших данных, непосредственно данными, безопасностью персональных данных с учетом их масштабирования при сохранении высокого уровня качества данных и безопасного доступа.

К соображениям, связанным с оперативным управлением большими данными, относятся следующие:

- **Выделение ресурсов**: выделение ресурсов представляет собой деятельность по конфигурированию системных ресурсов для поддержки решения конкретной задачи. Выделение ресурсов может выполняться на нескольких уровнях архитектуры системы: от выделения ресурсов для виртуальных машин до выделения ресурсов для конкретного задания на одном или нескольких узлах. Эти соображения включают эффективное использование и конфигурирование ресурсов для поддержки одной или нескольких задач.

- **Конфигурация**: указанные соображения включают надлежащую настройку параметров внутри системных компонентов для обеспечения оптимального функционирования и использования системных ресурсов.

- **Управление пакетами**: указанные соображения включают управление базовыми наборами пакетов для системных компонентов с целью обеспечения безопасности и эксплуатационной надежности системы.

- **Управление ресурсами**: указанные соображения касаются того, как ресурсы системы используются для поддержки различных рабочих нагрузок, поддерживаемых системой, в зависимости от их приоритета.

8.4 Стратегическое управление данными

Стратегическое управление данными представляет собой высокоуровневый процесс планирования и реализации деятельности исполнителей различных ролей и подролей, направленный на создание новых ценностей и эффективное реагирование на потребности бизнеса. Стратегическое управление данными определяется и обеспечивается путем планирования:

- **стратегии организации**, связанной с управлением данными, которая обеспечивает гарантию того, что данные соответствуют бизнесу;

- **стратегии управления качеством данных**, представляющей собой набор ограничений, действий и требований, направленных на соответствие данных показателям качества, определяемых потребностями бизнеса (более подробная информация представлена в Приложении С).

9 Функциональное представление

9.1 Функциональная архитектура

9.1.1 Общие положения

Функциональная архитектура для больших данных позволяет описать большие данные в терминах высокоуровневого набора уровней функциональных компонентов. Функциональные уровни представляют собой наборы функциональных компонентов с аналогичными возможностями, которые требуются для выполнения различных видов деятельности с большими данными, представленных в разделе 8, для различных ролей и подролей применительно к большим данным, с учетом спецификации и реализации архитектуры больших данных.

Функциональная архитектура описывает функциональные компоненты с точки зрения многоуровневой архитектуры, в которой определенные типы функций сгруппированы на каждом уровне, как показано на рисунке 11.

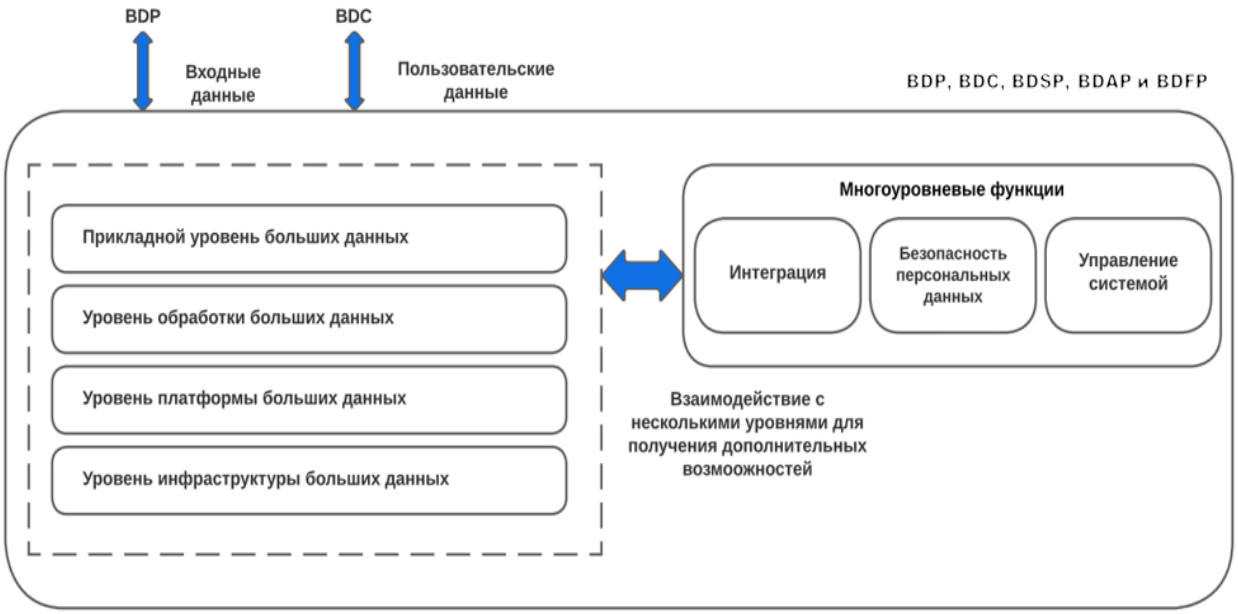

Рисунок 11 — Функциональные уровни эталонной архитектуры больших данных

Как показано выше сервис-провайдер больших данных и потребитель больших данных могут быть внешними компонентами по отношению к системе больших данных в процессе разработки архитектуры или внутренними компонентами (поскольку один поставщик приложений в архитектуре больших данных может предоставлять входные данные или получать входные данные от другого поставщика приложений в рамках архитектуры). Дополнительная информация о сопоставлении функционального представления эталонной архитектуры больших данных с другой эталонной архитектурой системной интеграции представлена в Приложении А.

Как показано на рисунке 11 роли и виды деятельности пользовательского представления больших данных, включая сервис-провайдера больших данных, потребителя больших данных, партнера сервиса больших данных, сервис-провайдера приложения больших данных и сервис-провайдера среды обработки больших данных, реализуются с помощью четырехуровневых функций и/или многоуровневых функций. В целях определения конкретной архитектуры рекомендуется использовать лучшие практики, чтобы архитектор задокументировал конкретные функциональные компоненты, обеспечивающие интерфейсы между этими уровнями и архитектурой больших данных.

9.1.2 Многоуровневая архитектура

9.1.2.1 Общие положения

Многоуровневая эталонная архитектура больших данных включает четыре уровня и набор функций, охватывающих все уровни.
Указанные четыре функциональных уровня включают:

- прикладной уровень больших данных (см. 9.1.2.2);
- уровень обработки больших данных (см. 9.1.2.3);
- уровень платформы больших данных (см. 9.1.2.4);
- уровень инфраструктуры больших данных (см. 9.1.2.5).

Функции, охватывающие различные уровни, называются многоуровневыми функциями.

На рисунке 11 представлена многоуровневая архитектура, при этом каждый из внутренних уровней многоуровневой архитектуры более подробно описан в 9.1.2.2–9.1.2.5

9.1.2.2 Прикладной уровень больших данных

Прикладной уровень больших данных предоставляет функции поддержки приложения, включая сбор данных, подготовку, аналитику, визуализацию и функции доступа. Эти функции реализуются через интерфейсы сервис-провайдером больших данных на уровне обработки больших данных, уровне платформы больших данных и потребителем больших данных.

9.1.2.3 Уровень обработки больших данных

Уровень обработки больших данных предоставляет компоненты платформы и библиотеки для реализации аналитики, заданной уровнем провайдера приложений. На этом уровне его компоненты управляют выполнением аналитических задач в системе. Компоненты взаимодействуют с уровнем платформы с целью определения места, в котором хранятся данные в системе, и направляют результаты аналитики этих данных на соответствующий узел для того, чтобы обеспечить локализацию данных для выполнения вычислений. В рамках многоуровневых функций для обеспечения балансировки вычислений в

системе они также взаимодействуют с компонентами управления ресурсами.

9.1.2.4 Уровень платформы больших данных

Уровень платформы больших данных предоставляет компоненты для хранения и организации данных, обрабатываемых системой. Указанные компоненты используют ресурсы одноименного уровня и, в случае применения оперативной памяти, координируют необходимые ресурсы с компонентами управления ресурсами в многоуровневых функциях с учетом требований к ним. Компоненты уровня платформы предназначены в первую очередь для обеспечения эффективной организации данных для доступа от провайдера приложений и уровней обработки в системе.

9.1.2.5 Уровень инфраструктуры больших данных

Уровень инфраструктуры больших данных представляет собой место, где размещаются ресурсы. Данный уровень включает в себя оборудование, обычно используемое в центре обработки данных, такое как серверы, сетевые коммутаторы и маршрутизаторы, устройства хранения, а также соответствующее программное обеспечение, не связанное с большими данными, которое работает на серверах и другом оборудовании, таком как хост-операционные системы, гипервизоры, драйверы устройств. и универсальное программное обеспечение для управления системами.

Уровень инфраструктуры больших данных также представляет и включает функциональные возможности сети передачи больших данных, которые необходимы для обеспечения базовой взаимосвязи между сервис-провайдером приложений для больших данных и сервис-

провайдером больших данных/потребителем больших данных, а также в рамках провайдера приложений для больших данных — между одноранговыми провайдерами приложений больших данных.

9.1.3 Многоуровневые функции

Многоуровневые функции включают ряд функциональных компонентов, которые взаимодействуют с функциональными компонентами вышеупомянутых четырех других уровней и обеспечивают помимо всего прочего следующие вспомогательные возможности:

- возможности функционирования систем безопасности (аутентификации, авторизации, аудита, валидации, шифрования);

- возможности интеграции (взаимодействия различных компонентов для достижения требуемой функциональности);

- возможности управления (развертыванием, конфигурацией, мониторингом, множественной арендой (мультитенантностью) ресурсов, высокой доступностью и жизненным циклом больших данных).

Многоуровневые функции, описанные выше, могут поддерживать сквозные аспекты или виды деятельности ролей, которые имеют широкое применение в системной архитектуре.

9.2 Функциональные компоненты

9.2.1 Общие положения

В данном подразделе архитектура больших данных описывается с точки зрения общего набора функциональных компонентов больших данных. Функциональный компонент является функциональным элементом эталонной архитектуры больших данных, который используется для выполнения видов деятельности или некоторой части

вида деятельности и имеет артефакт выполнения в конкретном варианте архитектуры, например, программный компонент, подсистема или приложение.

На рисунке 12 представлен общий вид функциональных компонентов эталонной архитектуры больших данных, организованных посредством многоуровневой архитектуры.

Термин «структура», используемый для имен функциональных компонентов на рисунке 12 и связанных с ним текстовых разделов, определен в стандарте ИСО/ИИЭР 11073–10201 как «структура процессов и спецификаций, предназначенных для поддержки выполнения конкретной задачи».

Примечание — Учитывая диапазон приложений/областей, связанных с большими данными, и быстрое развитие технологий больших данных, описание исчерпывающего списка возможных функциональных компонентов на этих уровнях является объемным и не может быть полным. Поэтому в настоящем стандарте представлено только общее описание функциональных компонентов.

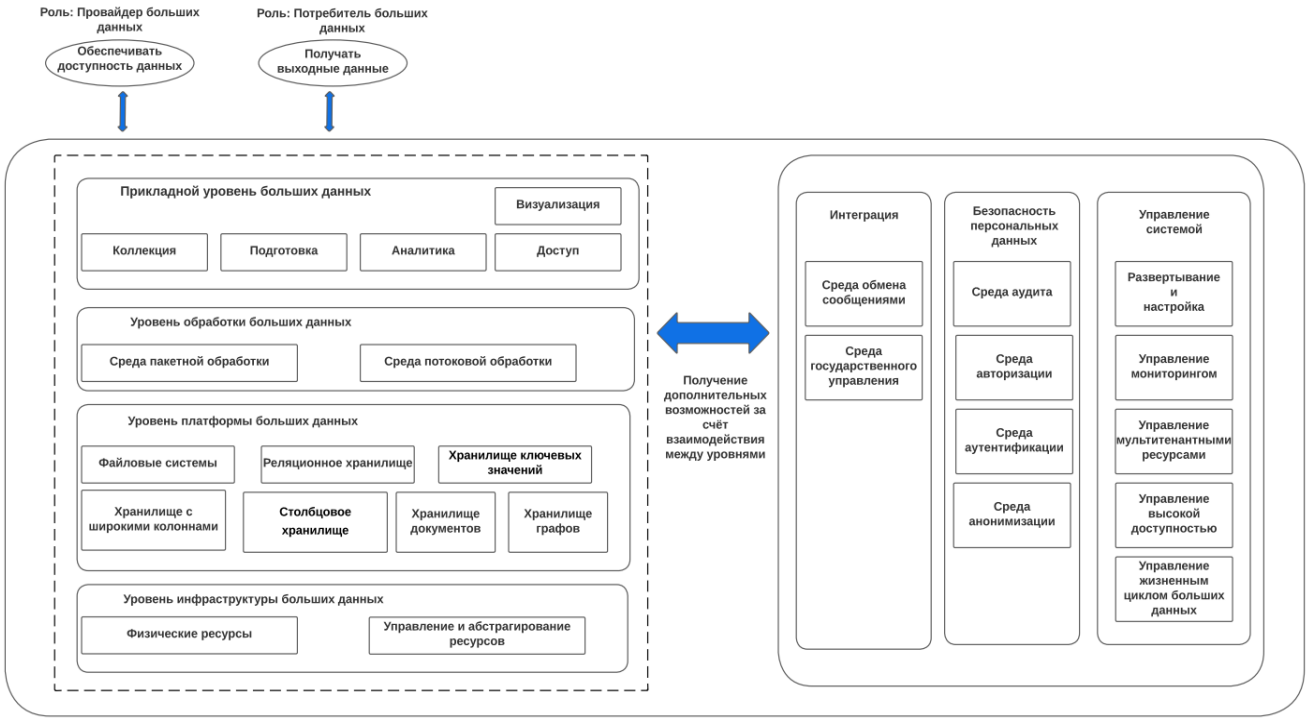

Рисунок 12 — Функциональные компоненты эталонной архитектуры больших данных

9.2.2 Функциональные компоненты прикладного уровня больших данных

9.2.2.1 Общие положения

Уровень приложений больших данных с функциональными компонентами поддерживает деятельность сервис-провайдера приложений больших данных. Он обеспечивает основной интерфейс для внешних компонентов, включая провайдеров и потребителей больших данных. В качестве компонентов в данном случае выступают компоненты на уровне обработки больших данных и на уровне платформы больших данных для реализации деятельностей на уровне приложений для больших данных. Ниже приведены основные функциональные компоненты этого уровня.

9.2.2.2 Функциональные компоненты комплектования больших данных

Функциональные компоненты комплектования больших данных используются для создания механизмов импорта данных от провайдера данных, а также системы хранения данных для выполнения последующих процессов:

- установления связи,
- импорта данных,
- хранения данных.

Данная категория компонентов связана с получением данных в системе. Указанные компоненты могут эффективно реализовывать свои функции с учетом объема и скорости поступающих данных.

9.2.2.3 Функциональные компоненты предобработки

Функциональный компонент предобработки используется для подготовки данных, предназначенных для конкретного процесса анализа. Детализированные функции включают: агрегацию данных, очистку данных, конверсию/трансформацию данных, создание вычислительного поля данных, оптимизацию данных, разделение данных, суммирование данных, выравнивание данных, проверку данных, виртуализацию и хранение подготовленных данных. Виртуализация данных представляет собой подход к управлению данными, при котором приложение может получать доступ к данным и изменять их, не выполняя физического форматирования и хранения данных. Трансформация данных преобразует данные из одного формата в другой, включая шифрование/дешифрование, компрессию/декомпрессию, прореживание, получение сводных данных и нормализацию данных.

9.2.2.4 Функциональный компонент аналитики

Функциональный компонент аналитики используется для инкапсуляции специализированных вычислений, которые необходимо выполнять с данными с целью поиска информации и/или извлечения знаний для удовлетворения прикладных требований с использованием заданных алгоритмов.

Примечание 1 — Классы алгоритмов для машинного обучения помимо всего прочего реализуют функции: корреляции, классификации, слияния данных, интеграции данных, интеллектуального анализа данных, искусственного интеллекта, распознавания образов, прогнозного моделирования, регрессии, кластерного анализа, пространственного анализа, аудио анализа, визуального анализа, текстового анализа и др. Алгоритмы текстового анализа включают: анализ тональности, распознавание именованных объектов и определение темы. Алгоритмы машинного обучения включают методы: корреляции, классификации, распознавания образов, прогнозного моделирования, регрессии, кластерного анализа и пространственного анализа. Во многих случаях системы больших данных объединяют несколько таких типов алгоритмов в потоковый процесс обработки данных. Например, система может использовать распознавание именованных сущностей для извлечения определенных сущностей (людей, мест, организаций и т. д.) из неструктурированных фрагментов текста, а затем передавать эту информацию в виде признаков для кластеризации фрагментов текста с использованием алгоритмов кластеризации на основе K-ближайших соседей или K-средних.

Примечание 2 — Классом аналитических функций является оперативный анализ данных, т. е. анализ лог-файлов, данных о системном статусе, предупредительной информации и др., предназначенных для эксплуатации и обслуживания системы. Типовой запрос и анализ включают: поиск текстового лог-файла, многомерный комплексный анализ и т. д. Алгоритмы численного анализа включают: использование быстрого преобразования Фурье, линейной алгебры и методы N-тел. Графовые алгоритмы включают: выявление массивов данных, поиск подграфа / смысла , оценка размерности поиска, коэффициента кластеризации,

рейтинга страницы, максимальные клики, компонентов связности, промежуточной центральности, кратчайшего пути.

Примечание 3 — Критические характеристики рассмотренных алгоритмов для больших данных определяются тем, что они должны иметь возможность работать параллельно на уровне обработки данных и учитывать распределенный характер данных на уровне платформы.

9.2.2.5 Функциональный компонент визуализации

Функциональный компонент визуализации используется для осмысленного представления проанализированных данных потребителю больших данных. Детализация задач функционального компонента включает:

- визуализацию результатов разведочного анализа данных (многомерность, переменная разрешающая способность, взаимодействие, анимация, симуляция, статистическая графика, рендеринг поверхности, рендеринг объема);
- визуализацию знаниевого компонента/объяснительного компонента (отчеты, бизнес-аналитика и обобщающая презентация для клиентов).

Примечание — Важнейшим аспектом визуализации больших данных является представление больших наборов данных таким образом, чтобы по ним можно было легко ориентироваться, и они были доступными для понимания. Кроме того, может потребоваться работа с данными в распределенном параллельном режиме.

9.2.2.6 Функциональный компонент доступа

Функциональный компонент доступа используется для предоставления потребителям больших данных доступа к результатам прикладного уровня больших данных. Детализированные функции включают:

- управление правами доступа;
- экспорт данных (например, через программный интерфейс приложения, протокол или язык запросов);
- безопасный доступ к данным.

Примечание — Потребители больших данных подключаются через указанный функциональный компонент с использованием веб-сервисов, пользовательских интерфейсов и/или API -интерфейса, протоколов и т. д., которые используются для доступа/извлечения данных. В данном случае важной проблемой для больших данных является то, как представить данные потребителю больших данных с учетом проблем, связанных с объемом и скоростью.

9.2.3 Функциональные компоненты уровня обработки

9.2.3.1 Общие положения

Компоненты уровня обработки больших данных в первую очередь ориентированы на показатели производительности (например, получение результатов вычислений з требуемый период времени). Уровень обработки больших данных предоставляет функциональные компоненты для поддержки таких характеристик больших данных, как объем, скорость и разнообразие. Указанный уровень использует различные механизмы обработки для различных хранилищ данных и планирования вычислений в ближнем или локальном хранилище. Он обеспечивает абстрактную функциональность для выполнения операций

прикладного уровня больших данных. Пользовательские операции абстрагируются в качестве: источника данных, фильтра, карты, окна, агрегации и др. Уровень обработки больших данных завершает процесс обработки потока данных между операторами, а также входом и выходом. На этом уровне реализуется процесс параллельной обработки данных.

Примечание 1 — В существующих системах баз данных компоненты уровня обработки больших данных носят название исполнительного механизма. Уровень обработки больших данных в большей степени относится к среде выполнения. Ключевое слово «большой» означает не только наличие больших данных из источника; при этом объем промежуточных данных могут быть больше объема необработанных данных.

Примечание 2 — При распараллеливании операций компоненты уровня обработки обычно распределяют работу между узлами в кластере сначала на основе местоположения данных (например, данные на уровне платформы, необходимые для вычислений, находятся на узле), а затем на основе ресурсов памяти и ресурсов центрального процессора.

Примечание 3 — Примером этого является шаблон программирования map/reduce (отображение/свертка), в котором вычисления для отдельных записей распределяются по узлам в зависимости от местоположения данных на этапе сопоставления, а затем результаты каждого узла объединяются и сортируются на этапе сокращения.

Уровень обработки больших данных использует разные механизмы обработки для разных хранилищ данных и планирования вычислений в ближнем или локальном хранилище.

Как правило, платформы на уровне обработки больших данных классифицируются в зависимости от количества элементов и скорости их обработки. Распространенными формами оценки являются один блок (пакет) или один элемент (поток).

9.2.3.2 Функциональный компонент среды пакетной обработки

Функциональный компонент пакетной обработки в основном направлен на решение проблемы объема данных. В качестве базовой единицы для обработки используется партия элементов. Полученные элементы блокируются для формирования пакета на основе их распределения на уровне платформы для обработки, чтобы максимизировать локальность данных. После того, как каждый узел обработал очередной пакет, результаты синхронно или асинхронно пересылаются на следующий шаг, который может представлять другой цикл обработки (как это делается в массовом синхронном параллельном шаблоне) или суммированием результатов (как это делается в методе отображение/ шаблон свертки). Время, необходимое для выполнения пакетной аналитики, может варьироваться от часов до долей секунды в зависимости от аналитики и данных. Приложениям специальных запросов и отчетов ежедневного оперативного анализа может потребоваться разное время отклика. Когда время отклика составляет минуты, часы или более длительный уровень, его часто называют автономной обработкой. Когда он находится в диапазоне секунд или долей секунды, это носит название интерактивной обработки. Однако тот факт, что система спроектирована как интерактивная, не означает, что все времена отклика находятся в диапазоне секунд или долей секунды. Плохо написанная аналитика/запрос, которая может иметь простые или сложные взаимосвязи между данными, должна обрабатывать большой объем записей, что может занять минуты или часы.

9.2.3.3 Функциональный компонент среды потоковой обработки

9.2.3.3.1 Общие положения

Функциональный компонент среды потоковой обработки в основном направлен на решение проблемы скорости. Модель процесса является конвейерной, и каждый элемент пересылается следующему оператору с минимальной задержкой. Главной задачей является мгновенный ответ, при этом каждый элемент является значимым в данный момент времени, в то же время некоторые операции требуют, чтобы элементы были заблокированы или буферизованы, например, в случае выполнения процесса агрегирования скользящего окна. Однако в идеальном случае данные непрерывно подвергаются конвейерной обработке. Функциональный компонент среды обмена сообщениями (см. 9.2.6.2.2) используется для взаимосвязи между операторами через узлы. Когда данные имеют слишком большой объем и/или слишком высокую скорость, система больших данных может использовать временное хранилище, удалить избыточных данные или вынуждена использовать механизм ограничения скорости совместно с производителем, чтобы избежать сбоев в системе.

Основной характеристикой среды потоковой является поток данных. Поток данных внутренне представляет собой ориентированный ациклический граф, который содержит оператор в качестве вершины и поток событий в качестве ребер. Оператор может быть распараллелен, а поток событий может быть разделен. Сложная обработка событий является более продвинутой, чем обычная потоковая обработка, и к ней можно обращаться с запросами, что обеспечивает добавление дополнительных рабочих характеристик: упорядочение событий, гарантия обработки событий, хранилище и разделения потоков/параллелизм операций.

Указанные четыре характеристики описаны в подразделах 9.2.3.3.2–9.2.3.3.5.

9.2.3.3.2 Упорядочение событий

Упорядочение событий гарантируется пользовательской глобальной меткой времени или идентификатором последовательности, оба из которых маркированы фидером. Порядок событий может обрабатываться по времени или количеству и относится к оконному потоку. Когда используется параметр времени события, порядок событий означает, что событие должно оцениваться в оконном операторе в порядке отметок времени. Неупорядоченные и задержанные события следует переупорядочивать, отбрасывать или немедленно оценивать (анализировать). Когда используется счетчик событий, порядок событий означает, что событие должно оцениваться в операторе окна с использованием идентификатора последовательности. Время события или идентификатор последовательности должны монотонно увеличиваться.

9.2.3.3.3 Гарантированная обработки событий

При наличии сбоев события должны обрабатываться с использованием отказоустойчивого механизма. Это особенно важно, при разделении потоковой передачи, параллельной работе оператора и наличии распределенности данных. Данные, хранящиеся в памяти, и данные, хранящиеся в файловой системе постоянного хранилища, должны быть гарантировано обработаны в оконном интервале. Особое внимание следует уделить двум важным фазам: получение данных о событиях перед обработкой (получатель) и фиксация после обработки (процессор).

Гарантированная обработка событий обычно включает следующие три класса:

- **не более одного раза:** такой класс означает, что на фазе приема событие должно быть получено один раз от источника данных, при этом не должно поддерживаться полученное смещение, а также фаза работы процессора не гарантируется. Полученное событие может быть обработано, при этом результаты обработки не возвращаются. Данный класс является простым и имеет низкую задержку, но при этом не гарантируется корректность.

- **хотя бы один раз:** такой класс означает, что на фазе получения событие может быть воспроизведено и получено несколько раз, а на фазе работы процессора события могут многократно обрабатываться. Все события могут быть получены и обработаны, но результат может быть неточным. При этом должен поддерживаться дополнительный механизм ручной корректировки систематического отклонения, позволяющий скорректировать последствия повторного воспроизведения событий, и может поддерживаться механизм обработки дубликатов для сокращения повторной обработки одних и тех же событий. В этом случае возникают дополнительные накладные расходы, однако он может обеспечить низкое значение задержки и определенную степень гарантированности обработки.

- ровно один раз: событие принимается один раз и обрабатывается один раз без потерь и повторов. При этом фазы приемника и процессора гарантированы. Обе фазы требуют реализации механизмов независимой отказоустойчивости и восстановления после сбоев для обеспечения работы неделимого и надежного хранилища. В этом случае возрастают накладные расходы из-за частых операций ввода-вывода, но при этом обеспечивается гарантия корректности.

9.2.3.3.4 Хранилище состояний

Типовые потоковые среды обработки имеют модель конвейерного процесса, в то время как средам со сложной обработкой событий по сравнению с потоковыми средами требуется дополнительное состояние для поддержки операции окна, которая предназначена для непрерывного запроса, когда событие сохраняется в течение определенного периода времени для создания окна. В традиционном варианте среды со сложной обработкой событий окно является маленьким, а событие сохраняется в буфере. В то время как события в окне в современной среде со сложной обработкой событий для больших данных могут быть множественными, хранилище состояний может обеспечить под держку потоков с большим объемом событий. Дополнительное хранилище необходимо для обеспечения отказоустойчивости и восстановления после сбоев, репликации, записи логов в журнал упреждающей записи и реализации контрольной точки, которые являются классическими методами решения проблем, поэтому хранилище состояний может поддерживать распределенную семантику и семантику ACID (атомарность, непротиворечивость, изолированность и долговечность) ограниченными способами, а компромисс заключается в обеспечении функций производительности и коррекции.

9.2.3.3.5 Разделение потока / параллелизм операторов

Данная характеристика относится к вопросам масштабируемости. Функции потока и оператора выполняются в ориентированном ациклическом графе. Цель потоковых сред обработки данных — максимально распараллелить выполнение. Потоковое разделение служит для обеспечения распределения событий, а оператор parallel — для параллельных вычислений. Планировщик реализует параллельные вычисления с локальными событиями. Разделение потока по ключу

(например, идентификатор датчика, идентификатор пользователя, идентификатор учетной записи) и функция агрегирования оцениваются отдельно для разделенного потока. Потоковые метаданные, координация связи, динамическое распределение ресурсов и стратегия извлечения по принципу push/pull (активный и пассивный способы извлечения данных) необходимы для разделения потока в распределенной среде. Параллелизм операторов необходим для обеспечения быстрых вычислений, но для координации глобального состояния (барьер, порядок событий) требуется больше механизмов. Операторы достаточно часто выполняют свои функции последовательно друг за другом, некоторые операторы могут быть объединены в цепочку с целью уменьшения накладных расходы на сетевые коммуникации.

9.2.4 Функциональные компоненты уровня платформы больших данных

9.2.4.1 Общие положения

Компоненты уровня платформы больших данных предоставляют услуги по хранению, организации и извлечению данных для поддержки более высоких уровней. Соответственно, этот уровень обеспечивает логическую организацию и распределение данных в сочетании с соответствующими интерфейсами прикладного программирования или методами доступа. Сюда также могут входить службы регистрации данных и метаданных, а также семантические описания данных, такие как формальные онтологии или таксономии.

Примечание — Одним из аспектов архитектуры этого уровня является выбор или совершенствование организации данных и методов хранения для более эффективного использования данных и повышения производительности запросов

или процедур извлечения. Особенно в связи с быстрым увеличением объемов больших данных (например, в финансовой сфере, банковском деле, средствах массовой информации, обрабатывающей промышленности) и сценариях сервиса пользователям требуется повышенная производительность для реализации различных запросов и процедур анализа с меньшей степенью дублирования и избыточности в хранилище данных.

В подразделах с 9.2.4.2 по 9.2.4.8 описаны общие категории этих компонентов.

9.2.4.2 Функциональный компонент файловой системы

Файловые системы организуют фрагменты данных (обычно определяемые как записи), доступ к которым осуществляется как к именованному объекту в определенном пространстве имен. В то время как локальные файловые системы часто используются в системах больших данных для хранения промежуточных данных локально по отношению к узлу обработки, распределенные файловые системы гораздо более распространены для постоянного хранения данных. Разница заключается в том, что распределенные файловые системы управляют распределением и репликацией блоков данных между узлами, а пространство имен не хранится вместе с данными, а управляется через центральную службу имен, часто работающую в режиме «ведущий/ведомый» или с несколькими ведущими для обеспечения отказоустойчивости.

Распределенные файловые системы (также известные как кластерные файловые системы) стремятся преодолеть проблемы с пропускной способностью, связанные с объемными и скоростными характеристиками больших данных, объединяя пропускную способность ввода-вывода для нескольких устройств (дисковых приводов) на каждом

узле с избыточностью и отказоустойчивым зеркалированием или репликацией данных на уровне блоков между несколькими узлами. Процедура репликации данных распределенной файловой системы специально разработана для использования разнородного стандартного оборудования в кластере больших данных. Таким образом, в случае сбоя одного диска или всего узла данные не теряются, так как они реплицируются на другие узлы, а пропускная способность снижается лишь минимально, так как эта обработка может быть перенесена на другие узлы. Кроме того, репликация обеспечивает высокий уровень параллелизма при чтении данных и начальной записи.

Хранилища распределенных объектов (также известные как глобальные хранилища объектов) являются уникальным примером организации распределенной файловой системы. В отличие от подходов, описанных выше, которые реализуют традиционные подходы к пространству имен иерархии файловой системы, хранилища распределенных объектов представляют плоское пространство имен с глобальным уникальным идентификатором для любого фрагмента данных. Как правило, данные в хранилище находятся с помощью запроса к каталогу метаданных, который возвращает соответствующие идентификаторы. В общем случае с глобальными уникальными идентификаторами предоставляется базовая программная реализация с местом хранения данных. Такие хранилища разрабатываются и продаются для хранения очень больших объектов данных, от полных наборов данных до крупных отдельных объектов (например, изображений с высоким разрешением размером в десятки гигабайт).

9.2.4.3 Функциональный компонент реляционного хранилища

В случае реляционной модели хранения данные хранятся в виде строк, где каждое поле представляет собой столбец, организованный в виде таблицы на основе логической организации данных.

Примечание — Реализации больших данных реляционных моделей хранения данных являются относительно зрелыми и были приняты рядом организаций. Они также очень быстро совершенствуются благодаря новым реализациям, ориентированным на улучшение времени отклика. Многие реализации больших данных к масштабированию реляционных запросов используют подход «грубая сила». По существу, запросы разбиваются на этапы, но, что более важно, обработка входных таблиц распределяется между несколькими узлами (часто в виде задания сопоставления/уменьшения).

Фактическим хранилищем данных могут быть плоские файлы (с разделителями или фиксированной длины), где каждая запись/строка в файле представляет собой строку в таблице. Однако эти реализации все чаще используют двоичные форматы хранения, оптимизированные для распределенных файловых систем. В этих форматах часто используются индексы на уровне блоков и организация данных по столбцам, чтобы обеспечить доступ к отдельным полям в записях без необходимости чтения всей записи. Несмотря на это, большинство моделей реляционного хранения больших данных по-прежнему представляют собой пакетно-ориентированные системы, предназначенные для очень сложных запросов, которые генерируют очень большие промежуточные матрицы перекрестных продуктов из объединений, поэтому даже самый простой запрос может потребовать десятки секунд для выполнения.

9.2.4.4 Функциональный компонент хранилища «ключ-значение»

Принципы построения хранилищ «ключ-значение» лежат в основе всех других моделей хранения и индексации. С точки зрения больших данных эти хранилища эффективно представляют модели памяти с произвольным доступом. Хотя данные, хранящиеся в значениях, могут иметь сколь угодно сложную структуру, вся обработка этой структуры должна обеспечиваться приложением, а реализация хранилища часто возвращает только указатель на блок данных. Хранилища типа «ключ-значение» также, как правило, лучше всего работают для отношений 1–1, один к одному, (например, каждый ключ относится к одному значению), но также могут быть эффективны для сопоставления ключей со списками однородных значений. Когда ключи сопоставляют несколько значений разнородных типов/структур или когда значения из одного ключа необходимо объединить со значениями для другого или того же ключа, требуется пользовательская прикладная логика. Указанное требование для этой пользовательской логики часто препятствует решению задачи эффективного масштабирования.

В хранилищах типа «ключ-значение» обычно хорошо реализуются обновления в случаях, когда имеет место отношение один к одному, а значение (размер/длина) данных не изменяется. Способность хранилищ «ключ- значение» обрабатывать вставки обычно зависит от базовой реализации. Обычно хранилища типа «ключ-значение» требуют значительных ресурсов (как ручных, так и вычислительных) для обработки изменений в базовой структуре данных значений. Наиболее часто используемой реализацией в приложениях для работы с большими данными являются распределенные хранилища типа «ключ – значение». При этом всегда должна решаться одна проблема, которая не является уникальной для реализаций типа «ключ-значение»— это распределение ключей по всему пространству возможных вариантов «ключ-значения».

В частности, ключи необходимо выбирать достаточно тщательно, чтобы избежать искажений в распределении данных по кластеру. Когда данные сильно искажены в рамках небольшого диапазона, это может привести к возникновению горячих точек (hot spot) вычислений в кластере в случае, если в процессе реализации делается попытка оптимизировать локализацию данных. Если данные являются динамическими (добавляются новые ключи) для такой реализации, то вполне вероятно, что в какой-то момент данные могут потребовать повторной балансировки в кластере. В случае реализации, когда локализация не оптимизируется, используют различные виды хеширования, а также случайного или циклического подхода к распределению данных, как правило не возникают искажения и горячие точки. Однако, в этом случае особенно сложно решаются задачи, требующие агрегирование наборов данных.

9.2.4.5 Функциональный компонент столбцового хранилища с широкими столбцами

В отличие от простых реляционных данных, которые хранят данные по строкам связанных отношениями значений, в столбцовых хранилищах данные организуются в группы подобных значений. В этом случае разница является небольшой, но в реляционных базах данных отдельная группа столбцов (часто один или несколько столбцов) для создания записи связана с определенным первичным ключом.

В столбцовых хранилищах значение каждого столбца является ключом, и подобные значения столбцов указывают на связанные строки.

Простейший пример столбцового хранилища – это не более чем хранилище ключей и значений, в котором роли ключа и значения поменялись местами. Во многих отношениях столбчатые хранилища

данных очень похожи на индексы в реляционных базах данных. Кроме того, реализация широких столбцовых хранилищ, которые соответствуют модели разреженной, распределенной многомерной модели отсортированной карты (где произвольные байтовые массивы индексируются/доступны на основе строковых и столбцовых ключей), вводят дополнительный уровень сегментации за пределами таблицы, строки и столбца реляционной модели, которая получила название семейства столбцов. Таким образом, в широком столбчатом хранилище добавляется дополнительное измерение, известное как семейство столбцов.

9.2.4.6 Функциональный компонент столбцового хранилища

Путем организации и хранения данных по столбцам (а не по строкам – в хранилищах на основе строк) столбцовые базы данных хорошо подходят для приложений с большими данными, которые требуют широкого спектра вариантов анализа, таких как: многомерный OLAP (оперативная аналитическая обработка) – запрос, запрос сканирования (большого и малого). Для повышения производительности запросов могут применяться различные методы сортировки, индексации и сжатия на основе столбцов, например: многомерное индексирование, словарное кодирование и т. д., которые могут применяться для повышения производительности запросов.

9.2.4.7 Функциональный компонент хранилища документов

В последнее время активно развивались и нашли широкое применение современные хранилища документов, которые сегодня включают расширенные возможности поиска и индексирования структурированных данных и метаданных, поэтому их часто называют

хранилищами слабоструктурированных данных. В хранилище данных, ориентированном на документы, каждый документ инкапсулирует и кодирует метаданные, поля и любые другие варианты представления этой записи. Хотя хранилища документов в какой-то степени аналогичны строке в реляционной таблице, одной из причин развития и популярности хранилищ документов является то, что большинство реализаций не применяют фиксированную (постоянную) схему. Хотя передовой опыт утверждает, что группы документов должны быть логически связаны и содержать схожие данные, не требуется, чтобы они были одинаковыми или чтобы любые два документа содержали одни и те же поля. В этом заключается одна из причин, по которой хранилища документов достаточно популярны для хранения наборов данных с редко заполненными полями, поскольку обычно возникает гораздо меньше накладных расходов, чем в традиционных системах СУБД, где в качестве записей фактически хранятся столбцы с нулевыми значениями. Группы документов в этих типах хранилищ обычно называются коллекциями, и, подобно хранилищам типа «ключ-значение», некоторые уникальные ключи имеют ссылки на каждый документ.

9.2.4.8 Функциональный компонент графовой базы данных

В то время как сайты социальных сетей, безусловно, стимулировали эволюцию графовых баз данных и способствовали повышению их наглядности (а также повышению эффективности обработки, о чем сказано далее), хранилища графов в течение нескольких лет были важной составной частью многих предметных областей, начиная с военной разведки и борьбы с терроризмом и заканчивая планированием/навигацией маршрутов, а также семантическими сетями. В графовых базах данных данные представляются в виде совокупности

узлов, ребер и их свойств (характеристик). Для устранения неоднозначности сущностей и сравнения графов аналитика по графовым базам данных содержит результаты расчета основного (базового) кратчайшего пути и ранжирования страниц.

Подходы к решению задачи построения графовых баз данных фактически можно рассматривать как специализированную реализацию схемы хранения данных с двумя типами данных (узлы и отношения (их взаимосвязи). Кроме того, одним из наиболее важных элементов анализа данных графа является определение местоположения узла или ребра графа, с которого должен начаться анализ. Для этого в большинстве графовых баз данных реализованы индексы свойств узлов или ребер. В отличие от реляционных и других подходов к хранению данных, большинство графовых баз данных, как правило, используют искусственные идентификаторы /псевдоключи или руководство для уникальной идентификации узлов и ребер. Это позволяет легко изменять атрибуты/свойства как вследствие фактических изменений в данных (кто-то изменил свое имя), так и вследствие обнаружения дополнительной информации (например, лучшего местоположения для некоторого элемента или события) без необходимости вносить изменения в указатели отношений в прямом направлении/обратном направлении.

Как правило, в распределенных архитектурах для обработки графов фрагменты графа сопоставляют системным узлам, после чего в системных узлах для передачи данных об изменениях в графе или полученных значениях используется подход на основе расчета путей в графе. Даже небольшие графы быстро превращаются в область больших данных, когда кто-то ищет шаблоны или расстояния на более чем одной или двух степенях разделения между узлами графа.

В зависимости от плотности графа такой подход может быстро вызвать комбинаторный взрыв применительно к количеству условий/шаблонов, которые будет необходимо проверить. Существует специализированный вариант реализации хранилища графов, известный как структура описания ресурсов (RDF), который является частью семейства спецификаций консорциума World Wide Web(W3C), которые часто напрямую ассоциированы с семантическим вебом и связанными с ней концептами. Тройки RDF, как известно, состоят из подлежащего (мистер X), предиката (живет в) и объекта (переулок пересмешника). Таким образом, набор троек RDF представляет собой ориентированный помеченный граф. Содержимое RDF-хранилищ часто описывается с использованием формальных языков онтологии, таких как OWL или язык RDF- схем (RDFS), которые устанавливают семантические значения и модели базовых данных. Для поддержки лучшей горизонтальной интеграции (Smith, et al., 2012) [16] гетерогенных наборов данных были предложены расширения концепции RDF, такие как структура описания данных (DDF) (Yoakum-Stover & Malyuta, 2008) [17], которые добавили дополнительные типы данных для более эффективной поддержки семантической совместимости и анализа. В хранилищах графических данных в настоящее время отсутствуют какие-либо стандартизированные API-интерфейсы или языки запросов. Тем не менее, консорциум W3C разработал язык запросов к данным, представленным по модели RDF SPARQL (SPARQL Protocol and RDF Query Language для RDF), который в настоящее время находится в статусе рекомендации, и есть несколько систем, таких как Sesame, которые набирают популярность для работы с RDF и другими хранилищами данных, ориентированными на графы.

9.2.5 Функциональные компоненты ресурсного уровня

9.2.5.1 Общие положения

Функциональные компоненты ресурсного уровня включают в себя:

- компонент абстракции ресурсов и управления ими;
- компонент физических ресурсов.

9.2.5.2 Функциональный компонент абстракции и управления ресурсами

Функциональный компонент абстракции ресурсов и управления используется сервис-провайдером приложения больших данных для предоставления доступа к физическим вычислительным ресурсам посредством программной абстракции. Ресурсная абстракция необходима для обеспечения эффективного, безопасного и надежного использования базовой инфраструктуры. Функции ресурсной абстракции поддерживаются возможностями данного функционального компонента.

Примечание 1 — Когда система больших данных развернута в среде облачных вычислений, функции виртуализации ресурсов предоставляются средой облачных вычислений, как определено в [6].

Функциональный компонент абстракции ресурсов и управления позволяет сервис-провайдерам приложений больших данных обеспечивать такие характеристики, как быстрая эластичность, объединение ресурсов и самообслуживание по требованию. Функциональный компонент виртуализации ресурсов и управления может включать программные элементы, такие как гипервизоры, виртуальные машины, виртуальное хранилище данных и обработку в режиме разделения времени.

Применительно к сети абстракция и управление ресурсами представляют собой средства, обеспечивающие передачу данных от одного компонента к другому на уровне инфраструктуры. Кроме того, сетевая инфраструктура может также включать автоматизированное развертывание, а также возможности предоставления

или агенты, в том числе агенты мониторинга всей инфраструктуры, которые используются элементами управления/коммуникации, которые обеспечивают реализацию конкретной модели.

Логическое распределение кластера/вычислительной инфраструктуры для выполнения вычислений может изменяться от грид-сети физических компьютеров в стойке до набора виртуальных машин, работающих у поставщика облачных услуг, или до сети слабосвязанных компьютеров, распределенных по всему миру и обеспечивающих доступ к неиспользуемым вычислительным ресурсам.

Примечание 2 — Гипервизор представляет собой часть компьютерного программного обеспечения, прошивки или оборудования, которое создает и запускает виртуальные машины. В таком виде гипервизор изначально работает на «голом железе» и управляет несколькими виртуальными машинами, состоящими из операционных систем (ОС) и приложений.

9.2.5.3 Функциональный компонент физических ресурсов

Функциональный компонент физических ресурсов представляет собой элементы, необходимые поставщикам приложений больших данных для запуска и управления предлагаемыми ими системами больших данных.

Физические ресурсы включают аппаратные ресурсы, такие как компьютеры (CPU и память), сети (маршрутизаторы, межсетевые экраны, коммутаторы, сетевые соединения и сетевые разъемы), компоненты хранения (жесткие диски) и другие элементы физической вычислительной инфраструктуры. Данные ресурсы могут включать те, которые находятся внутри облачных центров обработки данных (например, вычислительных серверах, серверах хранения и сетях внутри дата-центров) и те, которые находятся за пределами центров обработки данных, как правило, сетевые ресурсы, такие как сети центров обработки данных и опорные транспортные сети.

Для сети характеристики объема и скорости больших данных часто являются основными факторами в реализации внутренней и внешней связности сетевой инфраструктуры.

Физические ресурсы для вычислений – это физические серверы, которые выполняют и поддерживают программное обеспечение других компонентов системы больших данных. Вычислительная инфраструктура также часто включает базовые операционные системы и взаимодействующие сервисы, используемые для соединения кластерных ресурсов через сетевые элементы. Физические ресурсы для хранилища– это ресурсы, которые обеспечивают постоянство данных в системе больших данных. Инфраструктура хранения может включать любой ресурс от изолированных локальных дисков до сетей хранения данных (SAN) или сетевого хранилища.

Физические ресурсы – это физические ресурсы предприятия (электропитание, охлаждение), которые следует учитывать при создании экземпляра конкретного варианта системы больших данных.

Хотя компоненты ресурсов могут быть развернуты непосредственно на физических ресурсах или на виртуальных ресурсах, на определенном уровне все ресурсы имеют физическое представление. Физические ресурсы часто используются для развертывания нескольких компонентов, которые дублируются на большом количестве физических узлов, чтобы обеспечить так называемую горизонтальную масштабируемость. Виртуализация часто используется для достижения эластичности и гибкости при распределении физических ресурсов и часто упоминается как «инфраструктура как услуга» (Infrastructure as a Service, IaaS) в рамках модели облачных вычислений.

Ресурсы, повышающие эффективность вычислений, хранения или скорости передачи систем больших данных получили название

ускорителей. Объем, разнообразие и скорость больших данных требуют более высокой и гибкой скорости обработки, чем при традиционном подходе.

Примечание — Например, ускорители для вычислений включают в себя, но не ограничиваются только этим: графический процессор, настраиваемую вентильную матрицу для ускорения вычислений путем ее программирования пользователем.

9.2.6 Многоуровневые функциональные компоненты

9.2.6.1 Общие положения

Многоуровневые функции включают ряд функциональных компонентов, которые предоставляют сервисы функциональным компонентам других уровней.

9.2.6.2 Функциональные компоненты уровня интеграции

9.2.6.2.1 Общие положения

Функциональные компоненты уровня интеграции предоставляют услуги для подключения функциональных возможностей компонентов.
на одном уровне или на разных уровнях.
Функциональные компоненты интеграции могут включать, но не ограничиваться:

- среды обмена сообщениями (см. 9.2.6.2.2);
- среды управления состоянием (см. 9.2.6.2.3).

9.2.6.2.2 Функциональный компонент среды обмена сообщениями

Функциональный компонент среды обмена сообщениями предоставляет сервисы, например, в виде API-интерфейсы, для маршрутизации и обмена сообщениями, включая, помимо прочего, надежную организацию очередей, передачу и получение данных между узлами в горизонтально масштабируемом кластере или компонентами в различные вертикальные уровни или между ними, показанные на рисунке 12. Например, сетевой ресурс на уровне ресурсов может отправлять информацию о своем состоянии на компоненты управления системой через предлагаемые API-интерфейсы с помощью среды обмена сообщениями.

9.2.6.2.3 Функциональный компонент среды управления состояниями

Функциональный компонент среды управления состоянием используется другими функциональными компонентами для сохранения или поддержания состояния на узлах в распределенной среде, чтобы обеспечить согласованность состояний и постоянство во избежание сбоев ресурсов или системы. Информация о постоянном состоянии может быть введена в компоненты управления системой для мониторинга или управления ресурсами.

9.2.6.3 Функциональные компоненты уровня безопасности персональных данных

9.2.6.3.1 Общие положения

Компоненты безопасности персональных данных используются для облегчения взаимодействия в рамках эталонной модели больших данных без ущерба для безопасности персональных данных,

конфиденциальности или целостности. Компоненты защищенности и конфиденциальности персональных данных тесно связаны со всеми функциональными компонентами через API-интерфейсы.

Примечание — Компоненты безопасности персональных данных составляют фундаментальный аспект эталонной архитектуры. Они представляют собой геометрически охватывающие или сквозные основные компоненты, указывающие на то, что на все компоненты влияют соображения безопасности персональных данных. Таким образом, роль безопасности персональных данных корректно отображается по отношению к другим компонентам, но не расширяется до более мелких деталей, которые дают более точное представление, но скорее относятся к более детализированной эталонной архитектуре и безопасности персональных данных. Общие категории компонентов, реализованных для поддержки аспектов безопасности персональных данных приведены ниже.

Компоненты безопасности персональных данных используют ряд компонентов управления системой для сбора и отслеживания данных взаимодействуют с ними.

9.2.6.3.2 Функциональный компонент среды аудита

Функциональный компонент среды обработки для аудита используется другими компонентами для записи событий в системе. События могут включать пользователей, компоненты, задания и их действия, такие как: запуск, остановка, доступ к данным, обновление данных и т. д. Эти компоненты часто используют компоненты уровня платформы для записи и сохранения данных, но могут в целях безопасности сохранять данные за пределами архитектуры больших данных. Журналы аудита, поддерживаемые этими компонентами, могут использоваться для отслеживания происхождения данных, для

восстановления данных/состояния в случае сбоя системного компонента или для криминалистического анализа системного сбоя или вторжения.

9.2.6.3.3 Функциональный компонент среды аутентификации

Функциональный компонент среды аутентификации обеспечивает управление доступом к базовым данным и службам в других компонентах, а также доступ к системе в целом из внешних элементов. Аутентификация включает представление идентификатора (например, имени пользователя) и ключа или ключей доступа (например, пароля или сертификата), которые сверяются с хранилищем эталонных данных. Как правило, аутентифицируемый компонент, предоставляя идентификатор и ключ, связывается с компонентом, к которому он хочет получить доступ. Затем компонент, к которому осуществляется доступ, вызывает службы аутентификации и получает ответ о том, разрешить или отклонить доступ. Хотя в идеале сервисы аутентификации должны быть централизованы в одном компоненте, наличие нескольких компонентов на всех уровнях может включать разные уровни или компоненты, требующие разных компонентов аутентификации.

9.2.6.3.4 Функциональный компонент среды авторизации

Функциональный компонент среды авторизации обеспечивает поддержку функции сопоставления идентификатора пользователя или компонента с привилегиями, которые они имеют при доступе к ресурсам (как к данным, так и к обработке) в кластере.

Примечание — Примерами привилегий, которые могут применяться к любому заданному ресурсу или элементу в кластере, являются: чтение или доступ, запись, удаление, выполнение, обход и завершение.

Привилегии могут применяться к ресурсу с разной степенью детализации. Например, многие платформы больших данных в настоящее время реализуют управление доступом на уровне полей/элементов, а не на уровне записей или файлов/наборов данных.

9.2.6.3.5 Функциональный компонент среды анонимизации

Функциональный компонент среды анонимизации поддерживает сохранение конфиденциальности или безопасности персональных данных путем запутывания одного или нескольких элементов данных, чтобы их нельзя было легко связать с другими элементами данных.

Примечание — Основным примером этого является анонимизация личной информации (PII) о людях для защиты их персональных данных. Эти компоненты часто реализуют односторонние хеш-функции для создания уникальных значений, которые нельзя легко преобразовать к исходным значениям.

Службы авторизации используются для определения того, может ли данный пользователь или сервис получить доступ к исходным или собственным данным или получает доступ только к закрытым данным.

9.2.6.4 Функциональные компоненты уровня управления системой

9.2.6.4.1 Общие положения

Функциональные компоненты уровня управления системой обеспечивают предоставление широкого спектра сервисов по установке, развертыванию, конфигурированию, мониторингу и настройке для функциональных компонентов на вертикальных уровнях, включая, помимо прочего:

- развертывание и конфигурацию (см. 9.2.6.4.2);

- мониторинг и оповещение (см. 9.2.6.4.3);
- многопользовательское управление ресурсами (см. 9.2.6.4.4);
- управление высокой доступностью (см. 9.2.6.4.5);
- функциональный компонент управления жизненным циклом больших данных (см. 9.2.6.4.6).

9.2.6.4.2 Функциональный компонент развертывания и конфигурации

Компоненты развертывания и конфигурации предоставляют функции для установки, развертывания и (повторной) конфигурации пакетов и сервисов на разных уровнях.

9.2.6.4.3 Функциональный компонент мониторинга и оповещения

Компоненты мониторинга и оповещения предоставляют функции для мониторинга состояния и производительности ресурсов и сервисов, развернутых на разных уровнях, а также отправки оповещений соответствующим компонентам управления при возникновении критических или опасных событий. Управление ресурсами по запросу, которое может использовать различные количества и различные типы ресурсов и услуг на любом уровне, необходимо для обеспечения масштабируемых вычислений и эластичности. Оповещения могут быть отправлены, например, компоненту управления ресурсами с несколькими арендаторами или компоненту управления высокой доступностью для запуска реконфигурации ресурса или сервиса.

9.2.6.4.4 Функциональный компонент управления мультитенантными ресурсами

Компонент управления ресурсами с несколькими арендаторами предоставляет функции для выделения изолированных ресурсов для разных арендаторов, запрашивающих услуги больших данных. Мультитенантность (многоарендность) представляет собой распространенный метод, популяризированный облачными вычислениями, позволяющий совместно использовать ресурсы и обеспечивать качество сервиса QoS среди разных арендаторов. Ресурсы, изолированные и предоставляемые арендаторам, могут охватывать уровень ресурсов (например, центральный процессор и хранилища), уровень платформы (файловые системы или базы данных), уровень обработки (например, единая или гибридная платформа обработки) и уровень приложений для работы с большими данными. (конкретные сервисы, предлагаемые арендаторам). В целях масштабируемости вычислений и обеспечения эластичности необходимы стандартные интерфейсы для управления ресурсами по запросу, которые могут использовать различные объемы и различные типы ресурсов и услуг на любом уровне.

9.2.6.4.5 Функциональный компонент управления обеспечением высокой доступности

Компоненты управления обеспечением высокой доступности реализуют функции для разработки политик, конфигурации и настройки статических или динамических сервисов, связанных с обеспечением избыточности, резервным копированием данных или ресурсов, запасным замещением и миграцией данных для восстановления после возникновения ошибок. В системе больших данных начиная от уровня ресурсов и до уровня промежуточного программного обеспечения могут возникать различные типы ошибок, например: сбои центрального

процессора или хранилища, сбои отдельных узлов или кластера, программные ошибки, сбои питания или неожиданное отключение устройств. Компоненты управления высокой доступностью могут получать входные данные от компонента мониторинга и оповещения и конфигурировать ресурсы или сервисы напрямую, или через компонент управления ресурсами в режиме коллективной аренды.

9.2.6.4.6 Функциональный компонент управления жизненным циклом больших данных

9.2.6.4.6.1 Общие положения

Функциональные компоненты управления жизненным циклом больших данных предоставляют функции для управления жизненным циклом больших данных с момента поступления данных в систему через компонент импорта данных до их обработки или удаления из системы. Он может включать, помимо прочего, управление метаданными и управление качеством данных.

9.2.6.4.6.2 Функциональный компонент управления метаданными

Под управлением метаданными понимаются возможности оперирования метаданными, созданными на каждом этапе жизненного цикла больших данных — от приема, предварительной обработки, обработки, анализа, хранения до уничтожения или удаления.

Примечание — Управление метаданными необходимо для систем больших данных по следующим причинам:

- объем метаданных в эпоху больших данных значительно больше, чем раньше, и постоянно растет;

- надлежащее управление метаданными играет важную роль в процессе добычи и анализа данных, поскольку метаданные предоставляют информацию о том, как данные можно обрабатывать или использовать.

9.2.6.4.6.3 Функциональный компонент управления качеством данных

Управление качеством данных относится к установлению и развертыванию ролей, политик, действий и процедур, касающихся точности, целостности и полноты данных в течение жизненного цикла больших данных.

Примечание — Управление качеством данных имеет важное значение для систем больших данных, поскольку низкое качество данных, например неполные, ложные или устаревшие данные, может повлиять на эффективность процессов интеллектуального анализа данных, помешать получению полезных результатов или привести к неправильным выводам.

Функции управления качеством данных взаимодействуют с каждым вертикальным функциональным уровнем, поскольку на качество данных влияют все процессы импорта, интеграции, анализа, хранения, визуализации и потребления данных.

Приложение А
(справочное)
Сопоставление функциональных представлений при интеграции эталонной архитектуры больших данных с эталонной архитектурой других систем

Пользовательское представление является единственным для конкретной системы больших данных. Функциональное представление можно применено к целевой системе или сервису. Например, на основе эталонной архитектуры облачных вычислений (ИСО/МЭК 17789) определяется собственное функциональное представление для облачных вычислений. Если решение для больших данных реализовано в среде облачных вычислений, функциональное представление больших данных можно сопоставить с функциональным представлением облачных вычислений (см. рисунок А.1).

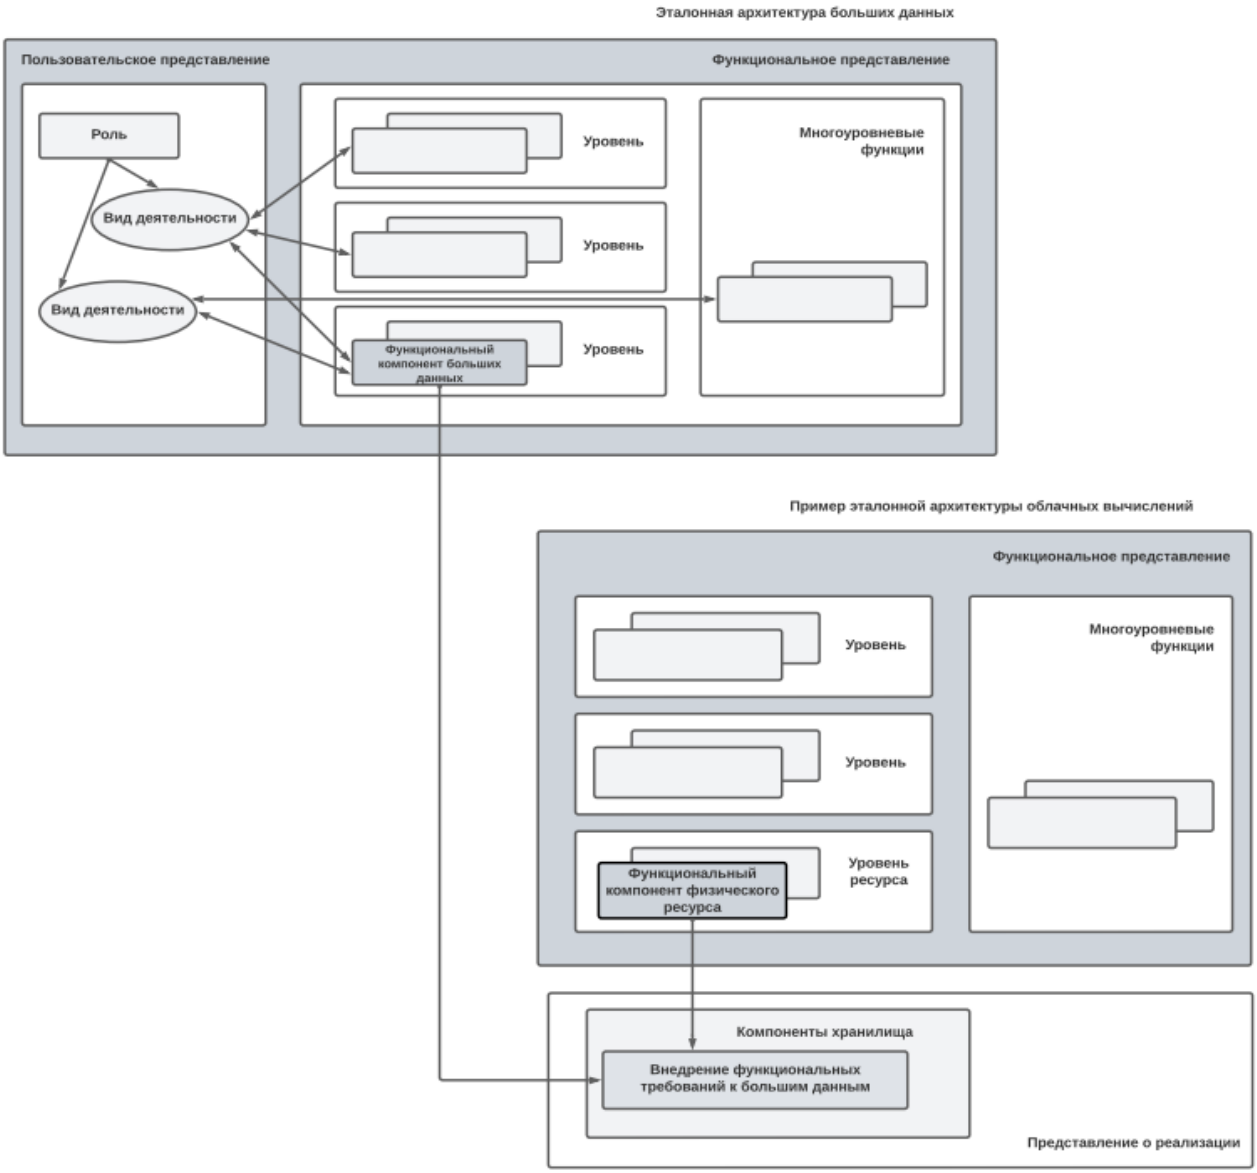

Рисунок А.1 — Сопоставление функциональных представлений при интеграции эталонной архитектуры больших данных с эталонной архитектурой облачных вычислений

Приложение В
(справочное)
Примеры взаимосвязей ролей в экосистеме больших данных

На рисунке В.1 представлена формализация эталонной архитектуры в терминах диаграммы классов UML. Необходимо отметить, что класс сервис-провайдера приложения больших данных имеет обратную ссылку «предоставления данных», чтобы учесть возможность того, что сервис-провайдер приложения больших данных предоставляет данные другому сервис-провайдеру приложения больших данных, что позволяет предоставлять данные по цепочке данных через множество сервис-провайдеров приложения больших данных.

Обозначения:

BDAP — Сервис провайдер приложения больших данных

BDC – Потребитель больших данных

BDP – Сервис-провайдер больших данных

BDFP – Сервис-провайдер среды обработки больших данных

Рисунок В.1 — Диаграмма классов UML эталонной архитектуры

На рисунке В.2 представлена сеть взаимосвязей между экземплярами ролей на основе вышеприведенной схемы UML. Данные каскадно проходят через несколько сервис-провайдеров приложения больших данных.

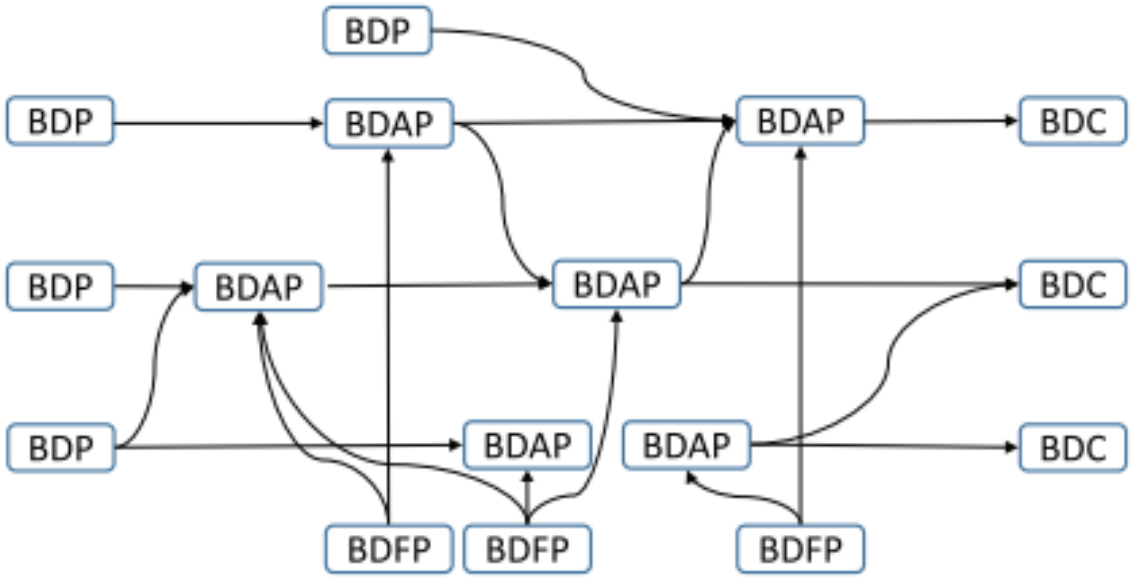

Обозначения:

BDAP — Сервис провайдер приложения больших данных

BDC – Потребитель больших данных

BDP – Сервис-провайдер больших данных

BDFP – Сервис-провайдер среды обработки больших данных

Рисунок В.2 – Пример сети взаимосвязей между экземплярами ролей больших данных

Приложение С
(справочное)

Основная цель данного приложения – дать характеристику основным понятиям: стратегического управления данными, управления качеством данных и оперативного управления данными в контексте больших данных. Указанные понятия, представленные в приложении, были в основном перенесены из соответствующих документов международной организации по стандартизации, упомянутых в приложении, а также из наиболее широко используемой и признанной литературы, полученной от конкретных профессиональных ассоциаций, таких как ассоциация управления данными (DAMA, Data Management Association,), Институт управления данными, Институт мастер-данных, Испанская ассоциация качества данных и информации (AECDI, Asociación Española para la Calidad de Datos y Información), международная ассоциация, объединяющая профессионалов в области ИТ-аудита, ИТ-консалтинга, управления ИТ-рисками и информационной безопасности ISACA (Information Systems Audit and Control Association) и Международная ассоциация качества информации и данных (IAIDQ, International Association for Information and Data Quality).

Представленный подход основан на идее одновременного рассмотрения «данных как актива организации» и «данных как продукта», поэтому данными следует управлять как активом и так и продуктом. На рисунке С.1 представлена взаимосвязь между тремя рассматриваемыми понятиями в рамках данного подраздела.

Стратегическое управление данными — понятие организационного характера (т. е. набор организационных действий), отвечающий за обеспечение того, чтобы данные, используемые в бизнес-процессах, создавали ценность и эффективно реагировали на потребности бизнеса.

Оперативное управление данными — понятие, включающее набор видов деятельности, направленных на поддержку жизненного цикла данных (сбор, описание, хранение, обработка и уничтожение) с технической точки зрения (DAMA, 2009).

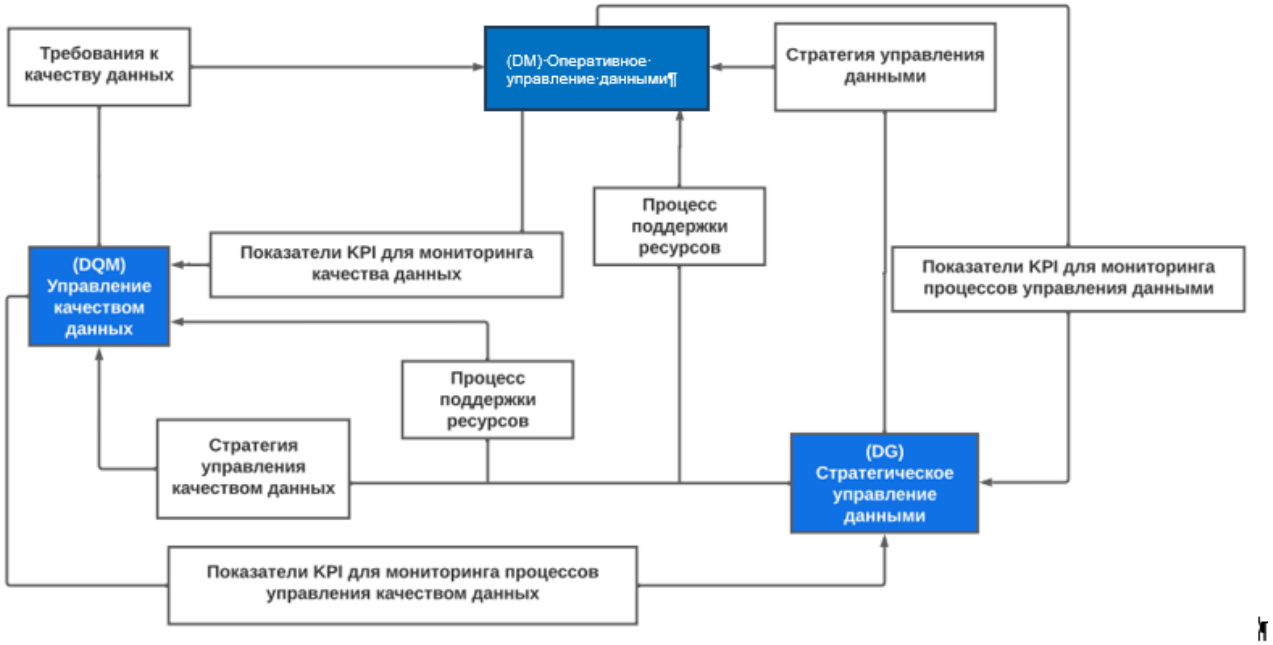

Рисунок С.1 — Взаимосвязи между основными понятиями: оперативного управления данными (DM), управления качеством данных (DQM) и стратегического управления данными (DG)

Понятие стратегического управления данными обеспечивает планирование и определение организационной стратегии, связанной с управлением данными, с целью обеспечения соответствия данных требованиям бизнеса. Понятие оперативного управления данными обеспечивает реализацию этой стратегии и получает набор ресурсов для поддержки ее реализации. Понятие оперативного управления данными обеспечивает реализацию и развертывание стратегии управления данными, а также обеспечивает понятие стратегического управления данными набором индикаторов для мониторинга состояния проводимых видов деятельности, определенных в стратегии. Взаимосвязи между рассмотренными понятиями можно увидеть на рисунке С.1.

Управление качеством данных представляет собой организационную функцию, направленную на подтверждение того, что данные имеют адекватный уровень качества в соответствии с потребностями бизнеса. Адекватный уровень качества данных указывает на достоверность результатов бизнес-процессов, использующих данные.

Стратегическое управление данными определяет стратегию управления качеством данных, которая представляет собой набор ограничений и действий, направленных на обеспечение того, чтобы данные соответствовали требованиям к качеству, определенным бизнесом. Стратегическое управление данными реализует стратегию управления качеством данных и предоставляет вспомогательные ресурсы для реализации управления качеством данных. Управление качеством данных определяет набор требований к качеству данных, показателям и критериям принятия решений, основанных на ограничениях и видах деятельности для того, чтобы эффективно контролировать и, при необходимости, улучшать уровни качества данных.

Требования, а также способы измерения уровней качества данных предоставляются в ходе оперативного управления данными, позволяющего использовать метрики качества данных, определенные функционалом управления качеством данных. Результирующие индикаторы качества данных передаются процессу управления качеством данных, который позволяет оценить, удовлетворяются ли потребности бизнеса в отношении качества данных.

Управление качеством данных обеспечивает предоставление процессу стратегического управления данными набора показателей выполнения мероприятий по обеспечению качества данных.

Стратегическое управление данными обеспечивает запрос у ИТ-подразделений, подразделений управления человеческими ресурсами, а также подразделений управления корпоративными финансами необходимых ресурсов с целью гарантии выполнимости процессов управления качеством данных и оперативного управления данными.

Введенные понятия по возможности приведены в соответствие с опубликованными или разрабатываемыми стандартами ISO в случае, если такие документы существуют. С учетом сказанного рассмотрим следующие допущения:

- В связи с тем, что данные очень ценны для организаций, их можно рассматривать как актив и, следовательно, управлять ими соответствующим образом для достижения целей организации. В рамках таких допущений можно считать, что:

- данные о сделках как актив могут быть контекстуализированы в соответствии с принципами, представленными в [*24*];

- управляющие данные могут быть контекстуализированы в соответствии с принципами, представленными в [*21*].

- В связи с тем, что данные можно представить как исходный материал в виде сырых необработанных данных и как результаты «обработки данных», их можно рассматривать как продукт. Также имеет смысл обратить внимание на качество продукта. В рамках этой гипотезы можно считать, что:

- управление качеством данных является восприимчивым к контекстуализации в соответствии с принципами, представленными в серии стандартов ИСО 8000;

- определение характеристик качества данных как продукта, а также соответствующих показателей можно найти в стандартах [*9*], [*10*] и [*30*]

Понятия, извлеченные и адаптированные из перечисленного набора стандартов, могут быть дополнены другими существующими стандартами, касающимися конкретных вопросов управления данными (например, [*11*]), или стандартами, соответствующими проблематике управления данными или управления качеством данных в конкретных областях (например, [*12*], [*13*], [*14*], [*15*]).

Даже если мы признаем, что это вопрос языка, т.е. использование терминов «стратегическое управление большими данными», «оперативное управление большими данными» и «управление качеством больших данных» не эквивалентно терминам «стратегическое управление данными в рамках проектов или экосистем больших данных, «Оперативное управление данными» в рамках проектов или экосистем больших данных и «Управление качеством данных» в рамках проектов или экосистем больших данных, поскольку понятия стратегического управления данными, управления качеством данных и оперативного управления данными выходят за рамки обычного использования данных.

Приложение ДА
(справочное)
Сведения о соответствии ссылочных международных стандартов национальным стандартам

Обозначение ссылочного международного стандарта	Степень соответствия	Обозначение и наименование соответствующего национального стандарта
ISO 8000-2, Data quality — Part 2: Vocabulary	IDT*	ГОСТ Р ИСО 8000–2–2014 Качество данных. Часть 2. Словарь. (ISO 8000-2:2012, IDT).
ISO/TS 8000-60, Data quality — Part 60: Data quality management: Overview		нет
ISO 8000-61, Data quality — Part 61: Data quality management: Process reference model		нет
ISO/IEC 38500 Information technology — Governance of IT for the organization	IDT	ГОСТ Р ИСО/МЭК 38500—2017 Информационные технологии Стратегическое управление ИТ в организации (ISO/IEC 38500:2015, IDT).
ISO/IEC 38505-1, Information technology — Governance of IT — Governance of data — Part 1: Application of ISO/IEC 38500 to the governance of data		нет

Продолжение таблицы ДА.1

ISO/IEC TR 38505-2, Information technology — Governance of IT — Governance of data — Part 2: Implications of ISO/IEC 38505-1 for data management		нет
ISO 55000, Asset management — Overview, principles and terminology	IDT	ГОСТР 55.0.01–2014/ИСО 55000:2014 Управление активами Национальная система стандартов. Общее представление, принципы и терминология (ISO 55000:2014, IDT)
ISO 55001, Asset management — Management systems — Requirements	IDT	ГОСТ Р 55.0.02–2014/ИСО 55001:2014 Управление активами. Национальная система стандартов. Системы менеджмента. Требования (ISO 55001:2014, IDT)
ISO 55002, Asset management — Management systems — Guidelines for the application of ISO 55001	IDT	ГОСТ Р 55.0.03–2014/ИСО 55002:2014 Управление активами. Национальная система стандартов. Системы менеджмента. Руководство по применению ISO 55001 (ISO 55002:2014, IDT)

Окончание таблицы ДА.1

ISO/IEC/IEEE 42010, Systems and software engineering — Architecture description	IDT	ГОСТ Р 57100–2016/ISO/IEC/IEEE 42010:2011 Национальный стандарт Российской Федерации. Системная и программная инженерия. Описание архитектуры. (ISO/IEC/IEEE 42010, IDT)
ISO/IEC 20546, Information technology — Big data — Overview and vocabulary	IDT	ГОСТ Р ИСО/МЭК 20546–2021 Национальный стандарт Российской Федерации. Информационные технологии. Большие данные Обзор и словарь (ISO/IEC 20546, IDT).
IDT* – идентичный стандарт		

Библиография

[1] Phillip C., Defining software requirements for scientific computing. Slide of 2004 presentation included in David Patterson’s 2005 talk

[2] http://www.lanl.gov/orgs/hpc/salishan/salishan2005/davidpatterson.pdf

[3] David P., Katherine Y., Dwarf Mind. A View From Berkeley. http://view.eecs.berkeley.edu/wiki/Dwarf_Mine

[4] United States Census Bureau, The “72-Year Rule.” https://www.census.gov/history/www/ genealogy/decennial_census_records/the_72_year_rule_1.html. Accessed March 3, 2015

[5] Hadoop A., Web HDFS REST API. https://hadoop.apache.org/docs/r1.0.4/webhdfs.html #FsURIvsHTTP_URL. Accessed Feb 24, 2017

[6] ISO/IEC 20546, Информационные технологии — Большие данные — Обзор и словарь

[7] ISO/IEC 17789, Информационные технологии — Облачные вычисления — Эталонная архитектура

[8] DoD Reference Architecture Description https://dodcio.defense.gov/Portals/0/Documents/DIEA/Ref_Archi_ Description_Final_v1_18Jun10.pdf

[9] ISO/IEC 27002, Информационные технологии — Методы обеспечения безопасности — Свод практических правил для средств управления информационной безопасностью

[10] ISO/IEC 25012, Разработка программного обеспечения — Требования к качеству программного продукта и его оценка (SQuaRE — Модель качества данных

[11] ISO/IEC 25024, Системная и программная инженерия — Требования к качеству систем и программного обеспечения и оценка (SQuaRE) — Измерение качества данных

[12] ISO 22745 Системы промышленной автоматизации и интеграция — Открытые технические словари и их применение к основным данным

[13] ISO 19157, Географическая информация — Качество данных

[14] ISO 13119, Информатика здравоохранения — Ресурсы клинических знаний. Метаданные

[15] ISO/TR 21707, Интеллектуальные транспортные системы — Интегрированная транспортная информация, управление и контроль — Качество данных в системах ИТС

[16] ISO/HL7 10781, Информатика здравоохранения — Функциональная модель системы электронных медицинских карт HL7, выпуск 2 (EHR FM)

[17] Barry S., Tatiana M., Mandrick W.S., Chia F., Kesny P., Milan P., (2012). Horizontal Integration of Warfighter Intelligence Data: A Shared Semantic Resource for the Intelligence Community. In Proceedings of the Conference on Semantic Technology in Intelligence, Defense and Security (STIDS), CEUR_. pp. 1–8 [17]

[18] Suzanne Y.-S., Malyuta T., Unified Integration Architecture for Intelligence Data." Proceedings of DAMA International Europe Conference, London, UK. 2008

[19] ISO 8000–2, Качество данных — Часть 2 — Словарь

[20] ISO/TS 8000–60, Качество данных — Часть 60. Управление качеством данных — Обзор

[21] ISO 8000–61, Качество данных — Часть 61— Управление качеством данных — Эталонная модель процесса

[22] ISO/IEC 38500, Информационные технологии — Управление ИТ в организации

[23] ISO/IEC 38505–1, Информационные технологии — Управление ИТ. Управление данными — Часть 1 — Применение ИСО/МЭК 38500 к управлению данными

[24] ISO/IEC TR 38505–2, Информационные технологии. Управление ИТ — Управление данными —. Часть 2: Значение ISO/IEC 38505–1 для управления данными

[25] ISO 55000, Управление активами — Обзор, принципы и терминология

[26] ISO 55001, Управление активами— Системы менеджмента. Требования

[27] ISO 55002, Управление активами —Системы менеджмента — Руководство по применению ISO 55001

[28] ISO/IEC/IEEE 42010, Системная и программная инженерия — Описание архитектуры

[29] ISO/IEC 20547–4, Информационные технологии — Эталонная архитектура больших данных — Часть 4. Безопасность и конфиденциальность

[30] ISO/IEC 27000, Информационные технологии. Методы обеспечения безопасности. Системы управления информационной безопасностью — Обзор и словарь

УДК 004.71 ОКС 35.020

Ключевые слова: эталонная архитектура, большие данные, пользовательское представление, функциональное представление, роль, подроль, сервис-провайдер, безопасность персональных данных, сквозные аспекты, управление данными, функциональная архитектура, функциональные компоненты, многоуровневая архитектура

Руководитель разработки
Председатель совета директоров
Института развития информационного
общества Ю. Е. Хохлов

Исполнитель А. А. Микрюков