

БЕЗОПАСНЫЕ ОБЛАЧНЫЕ ХРАНИЛИЩА БИМЕДИЦИНСКИХ ДАННЫХ

Хлебанова К. О.

Факультет компьютерного проектирования,
Белорусский государственный университет информатики и радиоэлектроники
Минск, Республика Беларусь
E-mail: ksenia.hlebanova@gmail.com

В последние годы объем биомедицинских данных, генерируемых клиническими системами, геномными исследованиями и носимыми устройствами, стремительно возрастает. Это требует разработки архитектур облачных хранилищ, обеспечивающих высокую производительность, масштабируемость и защиту персональных медицинских данных. В работе рассматриваются современные подходы к организации хранения биомедицинских данных в облаке, включая распределённые системы, микросервисные архитектуры и механизмы обеспечения конфиденциальности и целостности информации.

ВВЕДЕНИЕ

Биомедицинские данные характеризуются высокой гетерогенностью (большие бинарные объекты – медицинские изображения, большие файлы геномики; структурированные EHR/метаданные; потоковые сенсорные данные), строгими требованиями к конфиденциальности (PHI, GDPR/HIPAA), потребностью в аналитике в реальном времени и архивном хранении [1-2]. Проектируемая архитектура должна обеспечивать:

- масштабируемость по объёму и запросам;
- различную производительность для горячих и холодных данных;
- контроль доступа, шифрование и доказуемый аудит;
- поддержку стандартов обмена (FHIR, DICOM, HL7) и возможность приватных вычислений (secure enclave, TEEs, SMC/HE).

Далее рассматриваются два подхода, реалистичных для облачной среды.

I. ЦЕНТРАЛИЗОВАННЫЙ ОБЛАЧНЫЙ DATA LAKE

Централизованный облачный *Data Lake* представляет собой архитектуру, где объектное хранилище (S3-подобного типа) служит единым источником данных – DICOM, геномных (FASTQ/BAM) и электронных медицинских записей (EHR). Метаданные и индексы хранятся в NoSQL или реляционной базе, связанной с FHIR-ресурсами. Поток данных проходит через слой преобразования (ETL/ELT), нормализующий их в аналитические форматы Parquet/ORC.

Аналитический слой (BigQuery, Athena, Spark) обеспечивает масштабируемую пакетную аналитику. Безопасность реализуется с помощью шифрования (at-rest, in-transit), IAM, KMS и аудита. Для оптимизации затрат используется многоуровневое хранение (hot-cold) с автоматическим tiering. DICOM-объекты индексируются через метаданные и миниатюры, геномные данные преобразуются в табличный формат, EHR – в FHIR-структуры [2]. Время отклика системы

можно аппроксимировать выражением:

$$L = L_{\text{net}} + L_{\text{meta}} + L_{\text{io}}, \quad L_{\text{io}} \approx \frac{S}{B},$$

где L_{net} – сетевые задержки при передаче данных, L_{meta} – время поиска и обработки метаданных, L_{io} – задержка при чтении объектов из хранилища, зависящая от их размера S и пропускной способности канала B .

Надёжность системы определяется вероятностью доступности данных при k -кратной репликации:

$$A = 1 - (1 - a)^k,$$

где a – индивидуальная надёжность отдельного узла хранения, а A – совокупная доступность объекта. Увеличение числа копий данных повышает отказоустойчивость, но увеличивает издержки хранения.

Стоимость хранения оценивается как:

$$Cost = V_{\text{hot}} c_{\text{hot}} + V_{\text{cold}} c_{\text{cold}} + T_{\text{egress}} c_{\text{egress}},$$

где V_{hot} и V_{cold} – объёмы данных в горячем и холодном уровнях хранения, c_{hot} и c_{cold} – их удельные стоимости, T_{egress} – объём исходящего трафика, а c_{egress} – стоимость передачи. Данная модель позволяет балансировать между производительностью и затратами при больших объёмах медицинских данных.

Преимущества: централизованное управление, готовность к аналитике, эффективное хранение крупных файлов. Недостатки: единая точка отказа, риск утечки PHI, возможные сетевые задержки при высокой нагрузке. Подход эффективен для крупных исследовательских и национальных платформ с централизованным контролем доступа.

II. ФЕДЕРАТИВНАЯ АРХИТЕКТУРА С БЕЗОПАСНЫМИ ВЫЧИСЛЕНИЯМИ

Федеративная (*Data Mesh / Federated*) архитектура строится на распределённой модели, где каждое доменное хранилище (клиника или

лаборатория) сохраняет собственные данные локально или в изолированном облачном пространстве. Глобальный каталог метаданных содержит только описания и минимальные индексы, а взаимодействие между доменами осуществляется через контракты данных и единые API-интерфейсы (FHIR). Центральная оркестрационная платформа маршрутизирует запросы, выполняет авторизацию и обеспечивает виртуализацию данных, не требуя их физического перемещения.

Вычисления над конфиденциальными данными выполняются в доверенных средах (*secure enclaves*) или с применением методов защищённых вычислений – многопартийных протоколов (MPC) и гомоморфного шифрования (HE). Для кросс-доменных исследований применяются федеративное обучение и приватизация данных по модели дифференциальной приватности.

Время выполнения распределённого запроса описывается выражением:

$$T = \max_{i \in [1..n]} (T_{local,i}) + T_{agg} + T_{net},$$

где $T_{local,i}$ – время обработки на домене i , T_{agg} – агрегация результатов, T_{net} – сетевые накладные расходы. Стоимость распределённого запроса определяется как:

$$Cost_{query} = \sum_i cost_{compute,i} + cost_{orchestration},$$

где $cost_{compute,i}$ – вычислительная стоимость обработки на каждом домене, а $cost_{orchestration}$ – накладные расходы на координацию, маршрутизацию и объединение результатов между участниками федерации. Применение ϵ -дифференциальной приватности позволяет ограничить вероятность раскрытия персональных данных при агрегации.

Основными преимуществами подхода являются высокая степень защиты данных, соответствие юридическим требованиям (данные не покидают юрисдикцию) и распределённый контроль. Недостатками выступают сложность согласования форматов и политик доступа, повышенные задержки при агрегации и более высокие операционные затраты. Такой подход предпочтителен при организации межведомственных или международных биомедицинских систем, где конфиденциальность превалирует над скоростью обработки.

III. СРАВНИТЕЛЬНЫЙ АНАЛИЗ И ВЫВОД

Централизованный *Data Lake* обеспечивает высокую производительность и удобство аналитической обработки за счёт унифицированного хранилища и зрелых облачных инструментов. Однако он создаёт единую точку отказа и повышенные риски компрометации конфиденциаль-

ных медицинских данных. Федеративная архитектура, напротив, распределяет ответственность между доменами, снижает вероятность утечек и лучше соответствует нормативным требованиям (HIPAA, GDPR), но требует сложной оркестрации и имеет большие сетевые задержки.

Сравнение по ключевым параметрам представлено в табл. III.

Таблица 1 – Сравнение архитектурных подходов

Критерий	Централизованный <i>Data Lake</i>	Федеративная архитектура
Производительность	Высокая, оптимизированные OLAP-запросы	Зависит от числа доменов и сети
Безопасность и приватность	Централизованное управление, высокий риск утечек	Распределённый контроль, минимизация РНП-передачи
Масштабируемость	Простое горизонтальное масштабирование	Ограничено политиками и совместимостью
Соответствие регуляторным требованиям	Ограничено при кросс-юрисдикционном обмене	Полное соответствие локальному законодательству
Операционные затраты	Ниже при большом объёме данных	Выше из-за оркестрации и синхронизации

Оптимальным направлением развития является гибридный подход, объединяющий сильные стороны обоих решений: использование централизованного *Data Lake* для обезличенных или агрегированных данных и федеративных механизмов для чувствительных данных. Такая гибридная архитектура обеспечивает баланс между безопасностью, масштабируемостью и аналитической эффективностью, что делает её наиболее перспективной для будущих облачных платформ хранения и анализа биомедицинской информации.

IV. СПИСОК ЛИТЕРАТУРЫ

1. Tahir, A.; Rehman, A.; Iqbal, S. et al. A Systematic Review on Cloud Storage Mechanisms in Healthcare / A. Tahir, A. Rehman, S. Iqbal // *Sensors*. – 2020. – Vol. 20, № 18. – P. 5392.
2. Hashem, I. A. T.; Yaqoob, I.; Anuar, N. B. et al. The rise of “big data” on cloud computing: Review and open research issues / I. A. T. Hashem, I. Yaqoob, N. B. Anuar // *Information Systems*. – 2015. – Vol. 47. – P. 98–115.
3. Manco, C.; et al. HEALER: A Data Lake Architecture for Healthcare / C. Manco, et al. // *CEUR Workshop Proceedings*, Vol. 3379. – 2023. – P. 602
4. Simhadri, S. Y.; Deshpande, L. K. Evaluating Data Mesh and Traditional Data Architectures: Implications for Governance, Scalability, Cost, and Enterprise Adoption / S. Y. Simhadri, L. K. Deshpande // *Frontiers in Health Informatics*. – 2024. – Vol. 13, № 8. – P. 5095–5106.