


DataLad Insights

DataLad Insights — это модуль интерактивной визуализации данных, который превращает любой Parquet-датасет в набор профессиональных дашбордов. Аналитик указывает источник данных, выбирает колонки и агрегации — система возвращает готовый график без написания кода, SQL запросов в интерфейсе или создания собственных визуализаций.

Insights встроен в платформу DataLad и работает в паре с остальными сервисами (сбор событий, хранилище ключ-значение, MemTables). Визуализации доступны в отдельной вкладке «Аналитика» в левом меню.



Два уровня аналитики

Insights разделяет сценарии «построить график по любым данным» и «построить график по временным рядам». Первый сценарий работает с произвольным Parquet-датасетом; второй требует, чтобы данные соответствовали **канонической схеме временных рядов** (описана ниже).

УРОВЕНЬ	ТРЕБОВАНИЯ К ДАННЫМ	ДОСТУПНЫЕ ГРАФИКИ
Произвольные данные	Любой Parquet — колонки выбираются в интерфейсе	Treemap, Sunburst, Radial bar, Sankey
Временные ряды	Каноническая схема	Мультисерийный линейный график со слайдером и аннотациями

UI автоматически определяет, соответствует ли текущий датасет канонической схеме, и включает вкладку «**Время**» в списке семейств графиков без дополнительных настроек.

Каноническая схема временных рядов

Это восемь колонок в формате long-table, которые делают датасет пригодным для построения временных рядов. Шесть из них обязательные; `description` и `annotation` — необязательные и отвечают за разные задачи (см. ниже).

КОЛОНКА	ТИП	ОБЯЗАТЕЛЬНА?	НАЗНАЧЕНИЕ	ПРИМЕР
stat_date	Строка (YYYY-MM-DD) или Date32 / Date64	да	Партиция по дате. Дублирует ts , но удобна для фильтров WHERE stat_date = '...' .	"2026-02-25"
ts	Timestamp(*, *) или ISO 8601-строка	да	Точный момент события. Строка и таймстамп обрабатываются единообразно — при запросе выполняется CAST(ts AS TIMESTAMP) .	"2026-02-25T09:00:00"
granularity	Строка (minute hour day week month)	да	Разрешение хранения. Интерфейс умеет укрупнять гранулярность «на лету» (date_trunc).	"hour"
count_name	Строка	да	Название метрики. В одной точке времени может быть несколько строк — по одной на каждую метрику.	"total_events" , "resolved_events" , "distinct_item_count"
entity_name	Строка	да	Объект, к которому относится метрика. Если фильтр по сущностям пуст — значения суммируются по всем объектам.	"acme" , "globex"
value	Численный (Int* , UInt* , Float* , Decimal)	да	Само измерение. При агрегациях приводится к Float64 .	2618
description	Строка (необязательная)	нет	Документация строки. Поясняет, что измеряет метрика, историю данных, пользовательские заметки — тот текст, который аналитик видит в инспекторе	"Поток входящих событий до дедупликации"

КОЛОНКА	ТИП	ОБЯЗАТЕЛЬНА?	НАЗНАЧЕНИЕ	ПРИМЕР
			данных, но не на графике.	
annotation	Строка (необязательная; как правило пуста)	нет	Текст маркера на графике. Непустые значения превращаются в вертикальные янтарные линии на временном ряду. Используется точно — обычно одна аннотация на событие.	"релиз v2.4"

Чем различаются description и annotation

Эти две строковые колонки похожи на первый взгляд, но играют противоположные роли и используются разными частями интерфейса:

- **description — история данных и контекст.** Как правило один и тот же текст повторяется для всех строк одной count_name, потому что он описывает саму метрику, а не конкретное событие. Это подпись, которую аналитик видит при просмотре строки; в качестве маркера на графике она не отображается.
- **annotation — маркер в точке времени.** Почти всегда пуста. Непустые значения появляются на считанных строках (релизы, начало/конец инцидента, запуск кампании), и именно эти строки превращаются в вертикальные линии на графике. На маркеры влияет только колонка annotation; к description система для этих целей не обращается.

Гибкость типов

Валидатор принимает любые строковые представления Arrow (Utf8, LargeUtf8, Utf8View), все разрешения таймстампов (секунды, миллисекунды, микросекунды, наносекунды) — с временной зоной или без — и любой числовой тип для value. Это значит, что датасеты, собранные разными инструментами (Arrow CSV, csv-to-parquet из состава DataLad, сервис сбора событий Ledger, pandas, Spark), попадают в один и тот же контракт без предварительного преобразования.

Проверка выполняется каждый раз при загрузке схемы: если датасет подходит — вкладка «Время» включается; если нет — доступны только «Иерархия» и «Поток».

Пример канонических строк

Каждая строка — одно измерение в тройке (время, метрика, сущность). description несёт документацию метрики для инспекции, а annotation пуста везде, кроме нескольких строк, которые должны стать маркерами на графике:


stat_date	ts	granularity	count_name	entity_name	value	description
2026-01-01	2026-01-01T00:00:00	hour	total_events	acme	126.35	"Поток вхо"
2026-01-01	2026-01-01T00:00:00	hour	resolved_events	acme	103.46	"События,
2026-01-01	2026-01-01T00:00:00	hour	distinct_item_count	acme	42.00	"Уникальн
...						
2026-02-25	2026-02-25T09:00:00	hour	total_events	initech	153.91	"Поток вхо"

Для одной сущности на горизонте 90 дней в почасовой гранулярности объём составляет примерно `90 × 24 × N_метрик` строк. Входящий в поставку демонстрационный датасет — 25 920 строк в Parquet-файле размером 96 КБ.

Семейства визуализаций

UI группирует типы графиков в три семейства. При переключении семейства меняется панель управления; при переключении типа внутри одного семейства (Treemap → Sunburst → Radial) перерисовка выполняется мгновенно без повторной выборки данных.

Иерархия




Пользователь выбирает колонку-метку (`label_col`), при необходимости — колонку-родителя (`parent_col`), а также агрегацию (`sum` , `avg` , `min` , `max` , `count` , `count_distinct`) и опциональный SQL-фильтр `WHERE` . Система возвращает подготовленные данные для Plotly:

```
SELECT
  CAST(<label> AS VARCHAR) AS label,
  CAST(<parent> AS VARCHAR) AS parent,  -- NULL для плоского дерева
  <agg>(<value>) AS value
FROM t [WHERE (<where>)]
GROUP BY label, parent
ORDER BY value DESC NULLS LAST
LIMIT <limit>
```

При указании родителя сервис автоматически синтезирует промежуточные узлы с агрегированными значениями, так что Plotly получает корректное дерево.

Три варианта отображения на одном и том же наборе данных:

- **Treemap** — прямоугольная упаковка плиток (используется по умолчанию).
- **Sunburst** — концентрические кольца; та же иерархия в радиальной форме.
- **Radial bar** — круговая столбчатая диаграмма. Если в данных есть иерархия, оставляются только листья, промежуточные узлы удаляются.




Поток (Sankey)

Пользователь выбирает колонку-источник (`source_col`), колонку-цель (`target_col`), колонку значений и агрегацию. Сервис формирует по одной связи на каждую пару (`source`, `target`) и приводит результат к формату Sankey-диаграммы Plotly: { `nodes`, `links` }. Узлы дедуплицируются по значению — если «Europe» встречается и как источник, и как цель, он пройдет через единственный узел.

```
SELECT CAST(<source> AS VARCHAR) AS source,
       CAST(<target> AS VARCHAR) AS target,
       <agg>(<value>) AS value
FROM t [WHERE (<where>)]
GROUP BY source, target
ORDER BY value DESC
LIMIT <limit>
```

Время (временные ряды)



Доступно только для датасетов с канонической схемой. Интерфейс подгружает уникальные значения `count_name` и `entity_name` и предлагает их в мультिवыборе. Диапазон времени задаётся вручную или одной из пресет-кнопок (1 день, 7 дней, 30 дней, 90 дней). Гранулярность переключается независимо от того, как хранится датасет — система выполняет `date_trunc` на лету.

Шаблон запроса:


```
SELECT date_trunc('<gran>', CAST(ts AS TIMESTAMP)) AS bucket,
       CAST(count_name AS VARCHAR) AS count_name,
       CAST(entity_name AS VARCHAR) AS entity_name, -- NULL при агрегации
       CAST(SUM(value) AS DOUBLE) AS value
FROM t
WHERE count_name IN (...)
      [AND entity_name IN (...)]
      [AND CAST(ts AS TIMESTAMP) BETWEEN ... AND ...]
      [AND (<where>)]
GROUP BY bucket, count_name [, entity_name]
ORDER BY bucket, count_name
```

Формат ответа:

```
{
  "series": [
    {
      "name": "total_events · globex",
      "count_name": "total_events",
      "entity_name": "globex",
      "x": ["2026-02-25T09:00:00", ...],
      "y": [912.4, ...]
    }
  ],
  "annotations": [
    { "ts": "2026-02-25T09:00:00", "text": "schema migration",
      "count_name": "total_events", "entity_name": "initech" }
  ],
  "granularity": "hour",
  "truncated": false
}
```

Количество серий ограничено 24 (достаточно для любого осмысленного дашборда); они сортируются по пиковому значению, чтобы самая заметная серия отображалась первой в легенде.

Аннотации (колонок `annotation`)



Любая строка с непустым значением в колонке `annotation` превращается в маркер на графике. Система выполняет отдельный SQL-запрос параллельно с основным, применяет те же фильтры (по метрикам, сущностям, временному окну) и возвращает до 200 маркеров. UI рисует каждый как:

- Вертикальную пунктирную янтарную линию, проходящую через всю область графика.
- Небольшую текстовую метку над графиком, привязанную к соответствующему времени.

К колонке `description` система намеренно не обращается — это не визуальный маркер, а документация строки. Если датасет был создан ещё до разделения и в нём нет колонки `annotation`, сервис возвращает пустой список маркеров без ошибки.

Чтобы разметить собственные релизы, инциденты или маркетинговые кампании, достаточно записать значение в колонку `annotation` на строке соответствующей временной точки. Чтобы маркер не дублировался по числу метрик в точке, рекомендуется прикреплять его только к одной канонической `count_name` — например, `total_events`.

Цветовое оформление

Insights отходит от стандартной радужной палитры Plotly ради более сдержанного корпоративного стиля. Используются две стратегии в зависимости от того, содержит ли визуализация иерархию:

1. **Иерархическое отображение.** Каждый корневой узел (например, регион) получает отдельный цвет из кураторской палитры на 12 цветов. Все его потомки окрашены тем же цветом с прозрачностью от 0.55 до 0.85, пропорционально величине значения. Благодаря этому «регион» на treemap воспринимается как цельный блок, а отдельные плитки внутри остаются различимыми.
2. **Плоское отображение.** Применяется пятиступенчатый градиент `indigo-950` → `indigo-700` → `purple-500` → `pink-500` → `amber-400`, подобранный под тёмный фон панели. Значения предварительно пропускаются через `log(v + 1)`, чтобы длинный хвост мелких значений тоже использовал всю палитру, а не сжимался в одну тёмную зону.

Radial bar всегда использует плоскую стратегию (это по определению плоский график). Sankey использует прозрачный фиолетовый для связей и фирменный `#8a7cff` для узлов. Временные ряды циклически перебирают палитру из 15 цветов; порядок серий стабилен между перерисовками.

Запуск сервиса Insights

Каждый экземпляр Insights — отдельный сервис с собственным портом, собственной Swagger-документацией и собственной конфигурацией. Создание выполняется через интерфейс: на странице «Сервисы» нажмите **Add service**, выберите тип `insights`, заполните TOML-конфигурацию.

Минимальная конфигурация

```
[insights]
# scan_row_budget      = 2_000_000
# max_files_per_scan   = 5_000
# exec_timeout_secs    = 30
# max_treemap_slices   = 500

# Закреплённые датасеты – именованные ярлыки, которые появятся в списке
# «Pinned» в интерфейсе. Пользователи могут работать и с произвольными путями
# через поле «Custom path» – закрепление лишь добавляет удобные имена.
[[insights.datasets]]
id          = "sales_demo"
name        = "Sales (demo)"
path        = "./test-data/datasets/for_treemap"
description = "Демонстрация семейств Hierarchy и Flow (384 строки)"

[[insights.datasets]]
id          = "events_demo"
name        = "Events (demo)"
path        = "./test-data/datasets/for_timeseries"
description = "Демонстрация канонических временных рядов (25 920 строк, 90 дней)"
```

Ключевые параметры

ПАРАМЕТР	НАЗНАЧЕНИЕ	ЗНАЧЕНИЕ ПО УМОЛЧАНИЮ
bind	Адрес и порт привязки сервиса	0.0.0.0:8084
scan_row_budget	Максимум строк, просматриваемых в одном запросе-графике	2 000 000
max_files_per_scan	Максимум parquet-файлов, включаемых в один запрос	5 000
exec_timeout_secs	Таймаут выполнения одного запроса (секунды)	30
max_treemap_slices	Максимальное число плиток в одном treemap/sankey	500

Эти пороги защищают сервис от случайного запуска гигантских выборок (например, от случайной подстановки корня продакшн-озера данных в поле пути).

Справочник HTTP API

Базовый URL внутри сервиса: `http://<bind>/api/v1/insights/`. Через UI-прокси доступ выполняется по `/api/svc/<port>/api/v1/insights/`. Все ответы в формате JSON; ошибки — в общем формате `{ error, code, details }`.

МЕТОД	ПУТЬ	НАЗНАЧЕНИЕ
GET	/health	Проверка готовности.
GET	/status	Текущая конфигурация и количество закреплённых датасетов.
GET	/datasets	Список закреплённых датасетов из TOML.
POST	/schema	{ path } → колонки, число файлов, флаг timeseries_capable.
POST	/query/treemap	{ path, label_col, parent_col?, value_col?, agg, where?, limit? } → { ids, labels, parents, values, total, truncated }.
POST	/query/sankey	{ path, source_col, target_col, value_col?, agg, where?, limit? } → { nodes, links, total, truncated }.
POST	/query/distinct	{ path, column, limit? } → { values, truncated }. Используется UI для наполнения мультивыборов.
POST	/query/timeseries	{ path, count_names[], entity_names[]?, granularity?, from?, to?, where? } → { series, annotations, granularity, truncated }.

Полная OpenAPI-спецификация доступна по адресу `/docs` на порту сервиса.

Демонстрационные данные

В поставку DataLad входят два демонстрационных датасета в каталоге `test-data/datasets/`.

`for_treemap/sales.parquet`

Глобальные продажи e-commerce, 384 строки, 11 колонок. Два независимых измерения иерархии и несколько числовых метрик:

- Географическое: `region` → `country` → `city` ($4 \times 3 \times 3 = 36$ городов)
- Товарное: `category` → `subcategory` → `product` ($4 \times 2 \times 2 = 16$ товаров)
- Метрики: `units`, `revenue`, `orders`, `customers`, `quarter`

Сценарии визуализации:

LABEL	PARENT	VALUE	AGG	ЧТО УВИДИТЕ
country	region	revenue	sum	«Карта выручки мира» в виде treemap
city	country	revenue	sum	Детализация городов в разрезе стран
product	category	units	sum	Проданные единицы по товарам
subcategory	category	revenue	avg	Средняя выручка по подкатегориям
(source=region, target=category)		revenue	sum	Sankey: потоки выручки из регионов в категории

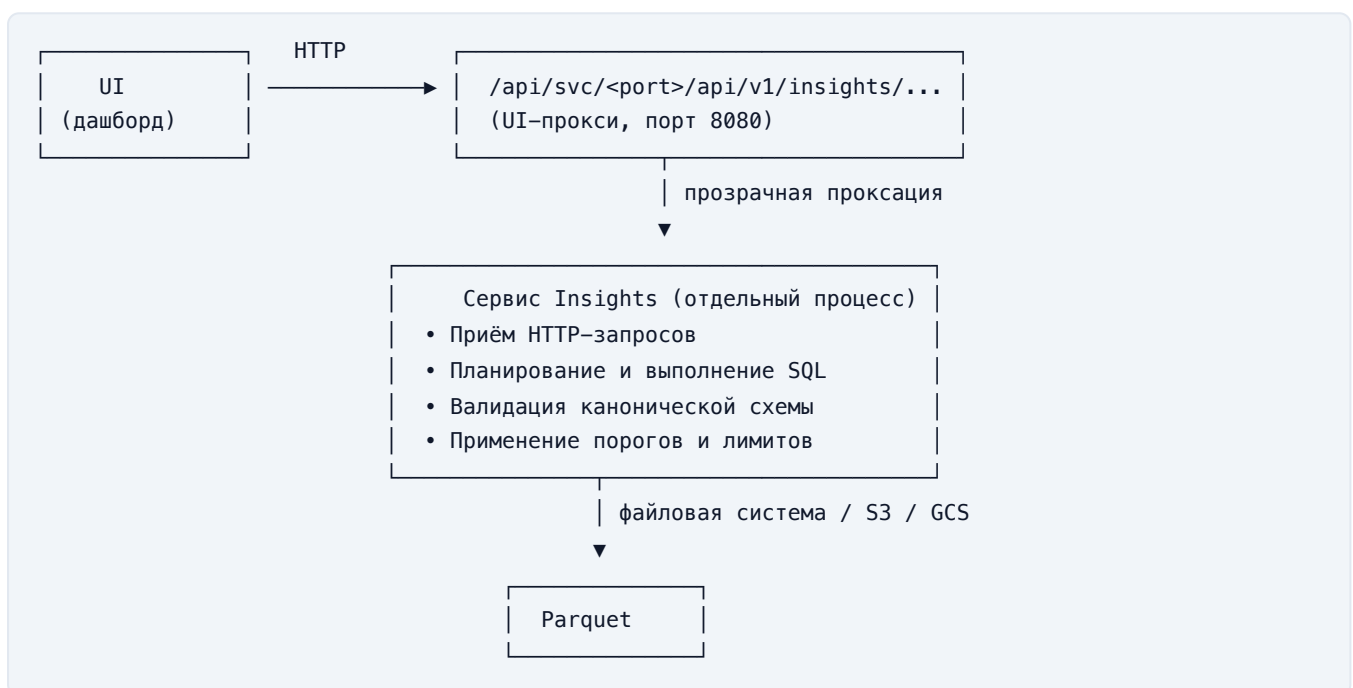
for_timeseries/events.parquet

Канонические временные ряды, 25 920 строк, 90 дней × 24 часа × 3 метрики × 4 сущности.

- Метрики: `total_events`, `resolved_events`, `distinct_item_count`
- Сущности: `acme`, `globex`, `initech`, `umbrella`
- Характер сигнала: суточный цикл + недельный цикл + постепенный рост на 15% + гауссовский шум + 5 заранее размеченных всплесков (два инцидента, маркетинговая кампания, перебой) + 7 маркеров в колонке `annotation` (при этом `description` несёт стабильную документацию по каждой `count_name`).

Генератор использует фиксированное зерно случайных чисел (`random.seed(42)`), поэтому все графики воспроизводятся один-в-один.

Архитектура (с точки зрения потока данных)



Сервис Insights работает только на чтение: у него нет собственного состояния и он не принимает данные. Все запросы выполняются SQL-движком в реальном времени по исходному Parquet. Пороги на количество строк, файлов и секунд защищают сервис от случайных больших выборок.

Для локальных путей выполняется рекурсивный обход каталогов — это гарантирует, что многоуровневые Hive-разметки (`schema=.../date=.../bucket=.../part.parquet`) полностью попадают в выборку.

Решение проблем

СИМПТОМ	ПРИЧИНА	ДЕЙСТВИЕ
Кнопка «Время» заблокирована	Датасет не соответствует канонической схеме	Загрузите датасет с колонками <code>stat_date</code> , <code>ts</code> , <code>granularity</code> , <code>count_name</code> , <code>entity_name</code> , <code>value</code> — при успехе в заголовке схемы появится зелёный маркер «time-series ready».
<code>unexpected label column type</code>	Сервис работает с устаревшей версией	Остановите и запустите сервис заново на странице «Сервисы».
<code>Parser error: Error parsing timestamp from 'YYYY-MM-DDTHH:MM'</code>	Поле <code>datetime-local</code> не включает секунды	Обрабатывается автоматически в UI; при вызове API напрямую дописывайте <code>:00</code> .
<code>no parquet files found under <path></code>	Путь некорректен или файлы не имеют расширения <code>.parquet</code>	Проверьте, что путь существует и содержит файлы с расширением <code>.parquet</code> (регистр не важен). Можно указать и отдельный файл.
<code>too many parquet files (>N)</code>	Поддерево превышает <code>max_files_per_scan</code>	Увеличьте лимит в конфигурации или укажите более узкий путь.
404 на <code>/query/sankey</code> или <code>/query/timeseries</code>	Сервис обновлён, но процесс не перезапущен	Остановите и запустите сервис заново.

Интеграция с платформой

- **Сервисы** — Insights регистрируется наравне с другими сервисами DataLad, имеет собственный порт и собственную OpenAPI-документацию.
- **Закреплённые датасеты** — удобные именованные ссылки на источники данных, не ограничивают пользователя: любой аналитик может работать с произвольным путём через поле «Custom path».
- **Произвольные объектные хранилища** — поддерживаются протоколы `file://`, `s3://`, `gs://`; учётные данные настраиваются в TOML-конфигурации сервиса.
- **Экспорт** — любая визуализация экспортируется в PNG с двумя вариантами фона: тёмный (по умолчанию, подходит для слайдов) и прозрачный (для наложения на произвольный фон).