

**МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ
РОССИЙСКОЙ ФЕДЕРАЦИИ
Федеральное государственное бюджетное
образовательное учреждение высшего образования
«ПЕНЗЕНСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ»**

С. В. Рындина

**АНАЛИЗ ДАННЫХ:
ПОСТРОЕНИЕ ОТЧЕТОВ
С YANDEX DATALENS И GLARUS BI**

Учебно-методическое пособие

ПЕНЗА 2025

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ
РОССИЙСКОЙ ФЕДЕРАЦИИ
Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Пензенский государственный университет» (ПГУ)

С. В. Рындина

Анализ данных: построение отчетов с Yandex DataLens и Glarus BI

Учебно-методическое пособие

Пенза
Издательство ПГУ
2025

УДК 004.738.5(075)+339(075)

P95

Р е ц е н з е н т

кандидат экономических наук, доцент,
руководитель сектора методологии учета и оформления
банковских операций ПАО Банк «Кузнецкий»

О. Б. Волошина

Рындина, Светлана Валентиновна.

P95 Анализ данных: построение отчетов с Yandex DataLens и Glarus BI : учеб.-метод. пособие / С. В. Рындина. – Пенза : Изд-во ПГУ, 2025. – 88 с.

Рассматриваются возможности систем Business Intelligence: Yandex DataLens и Glarus BI для анализа данных. Приведены задания для лабораторных работ по разведочному анализу данных. Материал пособия соответствует программе дисциплины «Анализ данных» и может быть использован при изучении дисциплин «Бизнес-аналитика на основе больших данных», «Интеллектуальные информационные системы», а также при написании выпускной работы бакалавра.

Издание подготовлено на кафедре «Цифровая экономика» и предназначено для обучающихся по направлению подготовки 38.03.05 «Бизнес-информатика».

УДК 004.738.5(075)+339(075)

СОДЕРЖАНИЕ

ВВЕДЕНИЕ	4
1. РАЗВЕДОЧНЫЙ АНАЛИЗ ДАННЫХ В GLARUS BI	5
1.1. Система Business Intelligence (Glarus BI)	5
1.2. Импорт данных. Типы данных	6
1.3. Построение запросов	11
1.4. Построение дашбордов	30
1.5. Объединение данных и визуализаций	40
2. РАЗВЕДОЧНЫЙ АНАЛИЗ ДАННЫХ В YANDEX DATALENS	55
2.1. Yandex DataLens – система Business Intelligence	55
2.2. Создание подключения и датасета	58
2.3. Создание чартов	62
2.4. Создание дашборда	69
2.5. Объединение данных	76
Лабораторная работа № 1. Создание отчета по разведочному анализу данных средствами Glarus BI	85
Лабораторная работа № 2. Создание отчета по разведочному анализу данных средствами Yandex Datalens	86
СПИСОК ЛИТЕРАТУРЫ	87

ВВЕДЕНИЕ

В соответствии с учебным планом студенты второго курса направления подготовки 38.03.05 «Бизнес-информатика» изучают дисциплину «Анализ данных».

Описательный анализ данных, разведочный анализ данных и проверка статистических гипотез – базовые методы работы с данными.

Целью учебно-методического пособия является рассмотрение возможностей BI-систем Yandex DataLens и Glarus BI для разведочного анализа данных.

Рассматривается построение запросов и дашбордов в Glarus BI, а также создание подключений, датасетов, чартов и дашбордов в Yandex DataLens.

Также приведены задания лабораторных работ по анализу данных в Yandex DataLens и Glarus BI.

1. РАЗВЕДОЧНЫЙ АНАЛИЗ ДАННЫХ В GLARUS BI

1.1. Система Business Intelligence (Glarus BI)

Glarus BI – это российская BI-платформа уровня Enterprise для бизнес-аналитики [1]. Сервис позволяет подключаться к различным источникам данных, строить визуализации, собирать дашборды и делиться полученными результатами. За основу разработчики платформы взяли open source BI-систему Metabase. Glarus BI включена в Реестр программного обеспечения Минцифры (Запись в реестре от 30.01.2023 № 16417).

Glarus BI состоит из нескольких сущностей, которые обеспечивают полный цикл работы с данными (рис. 1.1):

- запрос (SQL-запрос);
- дашборд (dashboard, приборная панель) – набор визуализаций по запросам, фильтров, текстовых блоков, ссылок и других элементов;
- коллекция;
- модель.




Рис. 1.1. Сущности Glarus BI

Коллекция – папка, в которой хранятся запросы, дашборды, модели. *Модель* – это набор данных или запрос, который можно снабдить метаданными (т.е. описанием отдельных показателей). В настоящем пособии модели рассматриваться не будут.

Платформу можно установить на хостинге, принадлежащем организации, или сразу развернуть облачную виртуальную машину с Glarus BI у таких облачных провайдеров, как VK cloud, MWS или

T1 cloud, но в пособии будет рассматриваться только вариант работы в облаке <https://demo.glarus-analytics.ru>, доступ к которому можно получить автоматически, заполнив на сайте <https://glarus-bi.online> регистрационную форму, которая открывается щелчком на кнопке (рис. 1.2).




Рис. 1.2. Облачная демоверсия для одного пользователя

Пользовательский доступ для тестирования возможностей платформы по работе с данными предоставляется бесплатно. Роль пользователя не единственная из возможных ролей на платформе. Так, роль администратора позволяет подключать новых пользователей, осуществлять разграничение прав доступа пользователям и распределять ресурсы. Доступ к платформе в роли администратора возможен при коммерческом использовании платформы и по академической программе для учебных организаций.

В коммерческих целях выгоднее произвести установку на собственном хостинге, тем более что компания, разработавшая систему, передает исходный код и в дальнейшем платным будет лишь консультирование, сопровождение и обучение при запросе на эти услуги со стороны заказчика.

Любой проект по анализу данных начинается с данных. У данных есть тип и структура.

1.2. Импорт данных. Типы данных

Выполним разведочный анализ данных для набора данных `insurance.csv` (доступен по ссылке <https://www.kaggle.com/>

mirichoi0218/insurance). На ресурсе kaggle.com для скачивания файла с данными необходимо зарегистрироваться.

Файл с именем insurance.csv представляет собой текстовый файл с данными, разделенными запятой. Такое представление данных называется плоскими таблицами. Можно просмотреть содержимое файла с помощью текстового редактора, не поддерживающего форматирование, например редактора Блокнот (рис. 1.3).




Рис. 1.3. Просмотр данных

В демоверсии Glarus BI требуется определенное расширение файла (.xlsx).

Можно воспользоваться MS Excel, открыв новый файл и выполнив импорт данных из текстового файла (рис. 1.4).




Рис. 1.4. Импорт данных из текстового файла

С помощью Мастера импорта нужно выполнить необходимые настройки и получить данные в таблице (рис. 1.5), сохранить файл в требуемом формате.

	A	B	C	D	E	F	G	H
1	age	sex	bmi	children	smoker	region	charges	
2	19	female	27.9		0 yes	southwest	16884.924	
3	18	male	33.77		1 no	southeast	1725.5523	
4	28	male	33		3 no	southeast	4449.462	
5	33	male	22.705		0 no	northwest	21984.47061	
6	32	male	28.88		0 no	northwest	3866.8552	
7	31	female	25.74		0 no	southeast	3756.6216	
8	46	female	33.44		1 no	southeast	8240.5896	
9	37	female	27.74		3 no	northwest	7281.5056	
10	37	male	29.83		2 no	northeast	6406.4107	
11	60	female	25.84		0 no	northwest	28923.13692	
12	25	male	26.22		0 no	northeast	2721.3208	
13	62	female	26.29		0 yes	southeast	27808.7251	
14	23	male	34.4		0 no	southwest	1826.843	
15	56	female	39.82		0 no	southeast	11090.7178	
16	27	male	42.13		0 yes	southeast	39611.7577	
17	19	male	24.6		1 no	southwest	1837.237	
18	52	female	30.78		1 no	northeast	10797.3362	
19	23	male	23.845		0 no	northeast	2395.17155	
20	56	male	40.3		0 no	southwest	10602.385	
21	30	male	35.3		0 yes	southwest	36837.467	
22	60	female	36.005		0 no	northeast	13228.84695	
23	30	female	32.4		1 no	southwest	4149.736	
24	18	male	34.1		0 no	southeast	1137.011	
25	34	female	31.92		1 yes	northeast	37701.8768	
26	37	male	28.025		2 no	northwest	6203.90175	
27	59	female	27.72		3 no	southeast	14001.1338	
28	63	female	23.085		0 no	northeast	14451.83515	
29	55	female	32.775		2 no	northwest	12268.63225	
30	23	male	17.385		1 no	northwest	2775.19215	
31	21	male	26.2		2 yes	southwest	28711	

Рис. 1.5. Импорт из текстового файла в книгу Excel

Можно воспользоваться онлайн-конвертором и преобразовать файл с расширением .csv в файл с расширением .xlsx (некоторые конверторы требовательны к размеру файла и не будут выполнять конвертацию для очень объемных наборов данных).

Бургерное меню (рис. 1.6) предоставляет доступ к основным сущностям платформы: Ваша личная коллекция – это Запросы, Дашборды и Модели доступные только пользователю соответствующего аккаунта.

Перемещение элементов в Общую коллекцию позволяет открыть к ним доступ и другим пользователям. Если элемент является составным, то в общую коллекцию необходимо вместе с ним переместить и связанные элементы.

Загрузим файл insurance.xlsx на платформу (рис. 1.6).




Рис. 1.6. Загрузка файла на платформу

Загруженный файл будет размещен в СУБД ClickHouse_Test, к которой можно получить доступ, выбрав опцию Просмотреть данные (рис. 1.7).




Рис. 1.7. Просмотр данных

Название таблицы с данными в базе данных составлено из имени файла insurance и имени листа с данными Worksheet. При наведении курсора на имя таблицы становится доступно пиктографическое меню, предоставляющее опции сканирования, просмотра сведений о таблице и удаления (рис. 1.8).




Рис. 1.8. Пиктографическое меню для действий с таблицей

Просмотрим сведения о таблице, проконтролируем корректность распознавания типов данных (рис. 1.9).

БАЗЫ... > CLICKH... > 365_INSURANC... **Поля в insurance / Worksheet**

Детали

Поля в этой таблице

Запросы об этой таблице

Сканировать таблицу

Имя поля	Тип поля	Тип данных
Age age	# Нет типа поля	type/Integer
Sex sex	T Нет типа поля	type/Text
Bmi bmi	# Нет типа поля	type/Float
Children children	# Нет типа поля	type/Integer
Smoker smoker	T Нет типа поля	type/Text
Region region	T Нет типа поля	type/Text
Charges charges	# Нет типа поля	type/Float
Glarus Load Dttm glarus_load_dttm	📅 Нет типа поля	type/DateTime

Рис. 1.9. Просмотр типов полей данных для загруженного набора

Описание переменных набора:

- age: возраст основного бенефициара;
- sex: пол застрахованного;
- bmi: индекс массы тела;
- children: число детей, охваченных медицинским страхованием / число иждивенцев;
- smoker: курит ли застрахованный;
- region: жилой район получателя страховых выплат (северо-восток, юго-восток, юго-запад, северо-запад).
- charges: индивидуальные медицинские расходы, оплачиваемые страховкой.

Типы данных, которые есть в наличии в данном наборе:

- числовые данные, имеют маркер #:
 - integer – целочисленные данные;
 - float – вещественные (десятичные дроби);

- категориальные данные, имеют маркер T:
 - text – строковые данные;
- данные даты и времени, имеют маркер 📅 :
 - DateTime – временные данные.

Поле Qlarus Load Dttm с типом Date time в таблицу добавлено платформой (это момент загрузки данных).

1.3. Построение запросов

Разведочный анализ заключается в построении визуализаций, которые выявляют связи между данными.

Построим визуализацию, с помощью которой можно установить, есть ли связь между индексом массы тела респондента и его медицинскими расходами.

Создадим запрос на основе данных, воспользовавшись кнопкой добавления новой сущности (рис. 1.10).




Рис. 1.10. Создание запроса

Выберем начальные данные (рис. 1.11), которые можно посмотреть с помощью стрелки справа в поле имени набора, она же появится, если добавить условие фильтрации или настройки для агрегации (суммирования). К данным можно присоединить дополнительный набор с помощью кнопки .

Построим визуализацию для данных исходной таблицы, выбрав щелчком по кнопке визуализации под таблицей тип Разброс (рис. 1.12).




Рис. 1.11. Настройки для запроса




Рис. 1.12. Выбор типа визуализации

В настройках визуализации (рис. 1.13) выберем для оси абсцисс показатель bmi (индекс массы тела), а для оси ординат показатель charges (медицинские расходы).




Рис. 1.13. Настройки для визуализации

Построенную визуализацию можно сделать более информативной, добавив разрыв серии (рис. 1.14). Сохраним запрос с названием Диаграмма разброса расходов от веса.




Рис. 1.14. Диаграмма рассеяния с выделением цветом тех, у кого есть вредная привычка

Сохраним запрос с названием Диаграмма разброса расходов от веса (рис. 1.15). Название исходного набора данных оставим в имени.




Рис. 1.15. Сохранение запроса

Как видим, расходы зависят и от лишнего веса, и от наличия вредной привычки. Не все обладатели лишнего веса имеют значительные медицинские расходы, однако с увеличением веса вероятность роста расходов повышается. Если потребуется отредактировать сохраненный запрос (рис. 1.16), то кнопки **Визуализация**  позволяют перейти к выбору типа визуализации и ее настройкам. А редактор запросов  позволяет изменить конфигурацию запроса, удалить / добавить / изменить фильтр и агрегацию.

Проанализируем сбалансированность набора данных по показателю smoker. Новый запрос можно создать, сразу выбрав исходные данные. Откроем набор данных, щелкнув по его имени в папке ClickHouse_Test, и вызовем редактор запросов (рис. 1.17).

В редакторе (рис. 1.18) выберем для агрегации метрику Количество показателя smoker (рис. 1.19).

В качестве визуализации выберем гистограмму (рис. 1.20) и сохраним запрос с тем названием, которое предложит платформа.

Построим на основе этого запроса новый запрос, определив пространственность вредной привычки в зависимости от района. Для этого продублируем запрос (рис. 1.21, 1.22).




Рис. 1.16. Возможности редактирования запроса

<div> <div> <div>ClickHouse DIGITAL</div> </div> <div> <div>☰</div> <div>ClickHouse_Test / insurance / Worksheet</div> </div> </div> <div> <div> <div>Поиск...</div> <div>+ Новый</div> </div> <div> <div>Фильтр</div> <div>Суммировать</div> <div> <div>⌵</div> <div>Сохранить</div> </div> </div> </div>									
Age	Sex	Bmi	Children	Smoker	Region	Charges	Glauus Load Dttm		
19	female	27,9	0	yes	southwest	16884,92	22 января, 2025, 19:11		
18	male	33,77	1	no	southeast	1725,55	22 января, 2025, 19:11		
28	male	33	3	no	southeast	4449,46	22 января, 2025, 19:11		
33	male	22,71	0	no	northwest	21984,47	22 января, 2025, 19:11		
32	male	28,88	0	no	northwest	3866,86	22 января, 2025, 19:11		
31	female	25,74	0	no	southeast	3756,62	22 января, 2025, 19:11		
46	female	33,44	1	no	southeast	8240,59	22 января, 2025, 19:11		
37	female	27,74	3	no	northwest	7281,51	22 января, 2025, 19:11		
37	male	29,83	2	no	northeast	6406,41	22 января, 2025, 19:11		
22	female	27,74	3	no	northwest	7281,51	22 января, 2025, 19:11		

Рис. 1.17. Вызов редактора запросов




Рис. 1.18. Переход к настройкам агрегации




Рис. 1.19. Настройки запроса




Рис. 1.20. Распространенность вредной привычки в наборе данных




Рис. 1.21. Дублирование запроса

Дублировать "insurance / Worksheet, Количество, Grouped by Smoker" ×

Имя

insurance / Worksheet, Количество, Grouped by Smoker+Region

Описание

Это не обязательно, но может быть полезным

В какую коллекцию следует это включить?

Светлана личная коллекция Рындина ▼

Дублировать

Рис. 1.22. Изменение имени запроса

Перейдем в редактор запроса (рис. 1.23) с помощью кнопки пиктографического меню  и добавим в качестве группирующего показателя region (рис. 1.24)

Перейдем к визуализации и в ее настройках изменим показатель для оси абсцисс и выберем опцию Добавление разрыва серии (рис. 1.25). В качестве показателя для разрыва серии выберем smoker, дополнительно скорректируем вид полученной визуализации (рис. 1.26). Сохраним запрос (рис. 1.27).

Проделаем аналогичные манипуляции с ранее построенной диаграммой рассеяния (см. рис. 1.16): перейдем к этому запросу, создадим его копию (рис. 1.28), поменяем показатель для оси абсцисс (вместо bmi выберем age). Сохраним запрос (рис. 1.29).

Создадим визуализацию, анализирующую сбалансированность набора данных по показателю sex (рис. 1.30).

Перейдем к построению дашборда.




Рис. 1.23. Переход в редактор запросов



23




Рис. 1.25. Изменение настроек для визуализации (данные)




Рис. 1.26. Изменение настроек вида визуализации




Рис. 1.27. Итоговый вид визуализации

Дублировать "insurance / Worksheet Диаграмма рассеяния расходов от веса" ✕

Имя

insurance / Worksheet Диаграмма рассеяния расходов от веса

Описание

Это не обязательно, но может быть полезным

В какую коллекцию следует это включить?

Светлана личная коллекция Рындина

Дублировать

Рис. 1.28. Изменение имени запроса для копии




Рис. 1.29. Сохранение визуализации




Рис. 1.30. Количество наблюдений с разными значениями показателя sex

1.4. Построение дашбордов

Создадим дашборд с именем Медицинское страхование (рис. 1.31).




Рис. 1.31. Создание дашборда

Справа вверху в режиме редактирования дашборда имеется пиктографическое меню. Кнопка «+» открывает справа панель с запросами, которые можно добавить на дашборд (рис. 1.32).




Рис. 1.32. Панель с перечнем созданных запросов

Также на дашборд можно добавить текст или заголовок (рис. 1.33), чтобы сделать его более информативным.




Рис. 1.33. Добавление описания и заголовков на дашборд

Разместим построенные визуализации на новом дашборде (рис. 1.34).




Рис. 1.34. Дашборд, включающий построенные визуализации

Добавим фильтр (рис. 1.35). Сначала выберем для настройки фильтра числовой показатель age (рис. 1.36–1.38). Тип фильтра выбирается между, чтобы иметь возможность рассматривать различные варианты диапазонов значений показателя (рис. 1.38).




Рис. 1.35. Добавление фильтра




Рис. 1.36. Выбор типа показателя (поля) для настройки фильтра




Рис. 1.37. Выбор типа фильтра




Рис. 1.38. Выбор показателя для фильтрации

В режиме редактирования всегда можно вернуться к настройкам фильтра (рис. 1.39).




Рис. 1.39. Изменение настроек фильтра (при необходимости)

Также добавим фильтр по показателю region (рис. 1.40–1.42).




Рис. 1.40. Выбор типа показателя (поля) для настройки фильтра




Рис. 1.41. Выбор типа фильтра




Рис. 1.42. Выбор показателя для фильтрации

При сохранении дашборда автоматически перейдем в режим просмотра (рис. 1.43).




Рис. 1.43. Добавление значений в фильтр по показателю age

Обратно в режим редактирования возвращает кнопка пиктографического меню . Внесем значения в фильтр по показателю age (от 18 до 35) и по показателю region, выбрав три района из четырех (рис. 1.44).




Рис. 1.44. Дашборд с двумя активными фильтрами

Создадим новый запрос по всем данным с визуализацией таблицы (рис. 1.45).

На созданный дашборд добавим ссылку (рис. 1.46) на источник данных на ресурсе (<https://www.kaggle.com/mirichoi0218/insurance>) и на запрос с таблицей данных (рис. 1.47).

В качестве заголовков для визуализаций на дашборде используются названия запросов. Однако в каждой активной визуализации на дашборде в режиме редактирования имеется кнопка  для изменения вида визуализации (рис. 1.48), позволяющая менять заголовки, подписи осей и т.п.

insurance / Worksheet

Age	Sex	Bmi	Children	Smoker	Region	Charges	Glarus Load Dttm
19	female	27,9	0	yes	southwest	16 884,92	21 января, 2025, 20:15
18	male	33,77	1	no	southeast	1 725,55	21 января, 2025, 20:15
28	male	33	3	no	southeast	4 449,46	21 января, 2025, 20:15
33	male	22,71	0	no	northwest	21 984,47	21 января, 2025, 20:15
32	male	28,88	0	no	northwest	3 866,86	21 января, 2025, 20:15
31	female	25,74	0	no	southeast	3 756,62	21 января, 2025, 20:15
46	female	33,44	1	no	southeast	8 240,59	21 января, 2025, 20:15
37	female	27,74	3	no	northwest	7 281,51	21 января, 2025, 20:15
37	male	29,83	2	no	northeast	6 406,41	21 января, 2025, 20:15
60	female	25,84	0	no	northwest	28 923,14	21 января, 2025, 20:15

Рис. 1.45. Исходные данные набора



Рис. 1.46. Добавление ссылки




Рис. 1.47. Дашборд со ссылками на данные

Изменим заголовок и цвет фона для одной из визуализаций (рис. 1.49).




Рис. 1.48. Переход к форматированию визуализации





Рис. 1.49. Форматирование визуализации

Аналогично можно отформатировать и остальные визуализации.

1.5. Объединение данных и визуализаций

Создадим новую коллекцию с именем Продажи (рис. 1.50), в которой будем размещать запросы по новым наборам данных.



Новая коллекция ×

Имя

Продажи

Описание (необязательный)

Это не обязательно, но может быть полезным

Коллекция сохранена в

Светлана личная коллекция Рындина

Отмена Создать

Рис. 1.50. Создание коллекции

Наборы данных, которые будут использоваться: данные о транзакциях (https://www.kaggle.com/datasets/regivm/retailtransactiondata?select=Retail_Data_Transactions.csv) и об отклике тех же клиентов на рекламные взаимодействия (https://www.kaggle.com/datasets/regivm/retailtransactiondata?select=Retail_Data_Response.csv).

Переведем эти наборы в нужный формат файла с помощью MS Excel. Сначала импортируем в созданный файл в MS Excel данные из Retail_Data_Transactions.csv (рис. 1.51), изменив представление для даты, если потребуется (рис. 1.52).

Аналогично импортируем в тот же файл данные из Retail_Data_Response.csv и удалим все остальные листы (рис. 1.53).

Сохраним файл с именем retail.xlsx. И загрузим этот файл на платформу. Он будет загружен в виде двух таблиц (рис. 1.54).

Книга1 - Excel

Файл Главная Вставка Разметка страницы Формулы **Данные**

Получить данные ▾

- Из текстового/CSV-файла
- Из Интернета
- Из таблицы/диапазона

Последние источники

Существующие подключения

Обновить все ▾

Получить и преобразовать данные

A1

	A	B	C	D	E	F
1	customer_id ▾	trans_date ▾	tran_amount ▾			
2	CS5295	11.02.2013	35			
3	CS4768	15.03.2015	39			
4	CS2122	26.02.2013	52			
5	CS1217	16.11.2011	99			
6	CS1850	20.11.2013	78			
7	CS5539	26.03.2014	81			
8	CS2724	06.02.2012	93			
9	CS5902	30.01.2015	89			
10	CS6040	08.01.2013	76			
11	CS3802	20.08.2013	75			
12	CS3494	02.07.2013	94			
13	CS3780	25.03.2013	80			
14	CS1171	03.11.2012	59			
15	CS2892	12.05.2013	43			
16	CS5552	29.12.2014	78			
17	CS6043	15.01.2014	98			
18	CS4147	08.07.2013	81			
19	CS4655	30.12.2013	93			
20	CS3904	20.07.2014	103			
21	CS4102	09.07.2011	96			
22	CS2086	05.03.2013	75			
23	CS6085	09.01.2013	49			
24	CS1328	06.02.2013	54			
25	CS4564	27.03.2012	48			
26	CS5910	01.01.2012	98			
27	CS2748	23.03.2013	37			
28	CS5147	29.04.2013	72			
29	CS1770	02.11.2012	83			
30	CS3510	24.10.2011	81			
31	CS3500	05.12.2014	105			

Рetail_Data_Transactions Лист1 +

Рис. 1.51. Импорт данных из текстового файла




Рис. 1.52. Форматирование даты




Рис. 1.53. Импорт данных из второго файла




Рис. 1.54. Результат загрузки файла retail.xlsx на платформу

Откроем сведения о первой таблице Retail_Data_Transactions (рис. 1.55).




Рис. 1.55. Сведения о наборе данных Retail_Data_Transactions

Ранее в данных о медицинском страховании показатель children определялся как категориальный с типом integer, в этих данных tran_amount определяется как числовой с типом integer. Тип поля в этом случае зависит от числа уникальных значений по сравнению с числом наблюдений, если уникальных значений мало, то показатель считается категориальным, иначе – числовым.

Таблица Retail_Data_Transactions содержит следующие данные:

- customer_id – идентификатор клиента (текстовая/символьная переменная);

- trans_date – дата транзакции;

- tran_amount – сумма покупки.

Таблица Retail_Data_Response содержит следующие данные:

- customer_id – идентификатор клиента (текстовая/символьная переменная);

- response – наличие/отсутствие отклика на рекламную компанию (бинарная переменная отклика).

Создадим запрос, который сравнивает общую сумму продаж клиентам, откликнувшимся на рекламу, с общей суммой продаж тем, кто рекламу проигнорировал.

Для этого к данным первой таблицы Retail_Data_Transactions присоединим данные второй таблицы Retail_Data_Response для изменения типа соединения, кликнув по значку соединения и выбрав внутреннее (рис. 1.56). Также выберем поля этих таблиц, по которым объединение произойдет (Customer_ID). Важно, чтобы поля, по которым происходит соединение таблиц, имели один и тот же тип данных и содержали одинаковые значения. Если рядом с таблицей запроса появляется стрелка, раскрывающая список полей, то в ней можно настроить поля для отображения (рис. 1.57).




Рис. 1.56. Изменение типа соединения




Рис. 1.57. Выбор полей

Агрегацию проведем по полю tran_amount первой таблицы Retail_Data_Transactions, а группировать будем по переменной response второй таблицы Retail_Data_Response (рис. 1.58).




Рис. 1.58. Настройки для запроса по данным двух объединенных таблиц

Построим визуализацию (гистограмму) и сохраним запрос в созданную коллекцию Продажи, сократив его название (рис. 1.59).

Сохранить новый запрос

×

Имя

Retail Data Transactions + retail / Retail Data Response -продажи и отклик

Описание

Это не обязательно, но может быть полезным

В какую коллекцию следует это включить?

Продажи

Отмена

Сохранить

Рис. 1.59. Сохранение запроса

Построим гистограмму по числу клиентов, сгруппированному в зависимости от отклика на рекламу (рис. 1.60, 1.61).

Количество по Response: Авт. скомпоновано
ClickHouse_Test / retail / Retail_Data_Response

Данные

retail / Retail_Data_Response

Фильтр

Добавьте фильтры, чтобы сократить результаты запроса

Суммировать

Количество × + по Response: Авт. скомпоновано × +

Фильтр Суммировать Присоединить данные Сортировка Количество строк Произвольная колонка

Визуализация

Рис. 1.60. Настройки запроса





Рис. 1.61. Построенная визуализация

Создадим новый дашборд с именем Продажи (рис. 1.62).



Новый дашборд

Имя

Продажи

Описание

Это не обязательно, но может быть полезным

В какую коллекцию следует это включить?

Продажи

Отмена Создать

Рис. 1.62. Создание дашборда Продажи

Разместим на дашборде гистограмму, построенную по количеству наблюдений, соответствующих каждому из значений переменной response (рис. 1.63). И в пиктографическом меню этой визуализации выберем значок  (Добавить серии), который позволяет дополнить диаграмму другой визуализацией, если в объединяемых визуализациях измерения оси абсцисс совпадают.




Рис. 1.63. Добавление визуализации на новый дашборд

В диалоговом окне для опции Добавить серии будут отображаться те диаграммы, которые можно объединить с текущей (рис. 1.64).




Рис. 1.64. Добавление серии на диаграмму

Скорректируем настройки для объединенных диаграмм (рис. 1.65). Как видим, откликнувшиеся на рекламу покупают больше, просто в общем числе клиентов их доля невелика.




Рис. 1.65. Форматирование объединенной диаграммы (изменение шкалы)

Сохраним дашборд и создадим еще две визуализации: линейную диаграмму по продажам, сгруппированным по месяцам, и таблицу с данными о продажах самым активным клиентам.

Первый из двух новых запросов будет иметь настройки как на рис. 1.66. Важно, что поле с типом данных DateTime, выбранное для группировки, позволяет настроить различные диапазоны для агрегации.




Рис. 1.66. Настройки запроса

Полученная визуализация будет иметь вид, показанный на рис. 1.67.




Рис. 1.67. Визуализация по запросу

Для построения второй визуализации просуммируем все покупки по каждому из клиентов и отсортируем полученную таблицу по сумме покупок по убыванию, а также выведем результат запроса на просмотр (рис. 1.68). Это необходимо для настройки фильтра, чтобы установить границу отсечения для суммы покупки. Как видим, сумма больше значения 2400 позволит оставить в рассмотрении только активных клиентов.




Рис. 1.68. Настройки запроса

Добавим фильтр, выбрав условие Больше чем и значение 2400 (рис. 1.69).




Рис. 1.69. Настройки для фильтра

Добавим две построенные визуализации на дашборд Продажи и скорректируем их заголовки, а также фон одной из визуализаций (рис. 1.70).




Рис. 1.70. Добавление новых визуализаций на дашборд

Добавим фильтр по показателю trans_date (рис. 1.71–1.73).

Как видим, фильтр по времени не будет работать для объединенной диаграммы и для диаграммы по данным таблицы Retail_Data_Response.

Сохраним дашборд Продажи и внесем значения в фильтр, только одна из визуализаций изменится (рис. 1.75).

Для дальнейшего совершенствования навыков работы на платформе Glarus BI можно воспользоваться справочной документацией [2].




Рис. 1.71. Выбор типа показателя (поля) для настройки фильтра




Рис. 1.72. Выбор типа фильтра





Рис. 1.73. Выбор показателя для фильтрации

Диапазон дат
январь 10, 2014 - март 26, 2014 ×



Популатели с самыми большими счетами за покупки	
Customer ID	Сумма Tran Amount
CS4424	2 933
CS4320	2 647
CS5752	2 612
CS4660	2 527
CS3799	2 513
CS5109	2 506
CS4074	2 462
CS3805	2 453
CS4608	2 449
CS5555	2 439
CS3163	2 413




Рис. 1.74. Вид дашборда с примененным фильтром

2. РАЗВЕДОЧНЫЙ АНАЛИЗ ДАННЫХ В YANDEX DATALENS

2.1. Yandex DataLens – система Business Intelligence

Yandex DataLens – это облачный сервис для бизнес-аналитики [3]. Сервис позволяет подключаться к различным источникам данных, строить визуализации, собирать дашборды и делиться полученными результатами.

С помощью Yandex DataLens можно отслеживать продуктовые и бизнес-метрики напрямую из источников, чтобы принимать решения, основанные на данных.

DataLens состоит из нескольких сущностей, которые обеспечивают полный цикл работы с данными (рис. 2.1):

- подключение – набор параметров для доступа к источнику данных;
- датасет (dataset, набор данных) – описание набора данных из источника;
- чарт (chart, диаграмма) – визуализация данных из датасета в виде таблиц, диаграмм и карт;
- дашборд (dashboard, приборная панель) – набор чартов, селекторов для фильтрации данных и текстовых блоков.




Рис. 2.1. Сущности DataLens

В сервис можно зайти по адресу: <https://datalens.yandex.ru> (рис. 2.2) с учетной записью Yandex (аккаунт на @yandex.ru).




Рис. 2.2. Страница для входа в сервис

На стартовой странице (перейти на которую можно по виджету  в левом верхнем углу) доступны для создания все сущности (Подключения, Датасеты, Чарты и Дашборды). Слева располагается вертикальная панель навигации (рис. 2.3).




Рис. 2.3. Стартовая страница DataLens

Сущность Подключение содержит информацию о параметрах доступа к источнику данных, на базе подключения можно на следующем шаге создавать Датасеты.

В DataLens доступно множество типов подключений (рис. 2.4–2.6).

Базы данных




Рис. 2.4. Источники данных (базы данных)

Файлы и сервисы




Рис. 2.5. Источники данных (файлы и сервисы)

Партнерские подключения




Рис. 2.6. Источники данных (партнерские подключения)

Файлы с данными могут иметь расширение `.xlsx` и `.csv`. Большое количество наборов данных доступно для создания отчетов и проведения анализа именно в формате `.csv`. Это текстовый формат для представления табличных данных (Comma-Separated Values, т.е. значения, разделенные запятыми). Многие программы для работы с табличными данными, в том числе и реляционные системы управления данными (PostgreSQL, MySQL и др.), позволяют импортировать данные в этом формате.

2.2. Создание подключения и датасета

Выберем на главной странице опцию Создать подключение и перейдем к варианту Файлы. В диалоговом окне появится возможность загрузить файл в облако, а при его изменении придется создавать новое подключение. Также нельзя превышать предельный размер файла – 200 Мб (с учетом бесплатного использования сервиса).

Загрузим файл `insurance.csv`, с которым мы работали в предыдущем разделе (рис. 2.7). Переводить его в формат `.xlsx` не требуется. При считывании содержимого файла нужно контролировать кодировку и разделитель (они распознаются автоматически), а также правильность определения типов данных: числовых с маркером `#` и текстовых с маркером `T`.

Новое подключение

←

Файлы

+ Загрузить файлы ?

insurance.csv

...

Кодировка

utf-8

Разделитель

Запятая

Заголовок столбцов

Да

Нет

Создать подключение

Поиск по столбцу

#	age	sex	bmi	children	smoker	region	charges
19	female	27.9	0	yes	southwest	16884.924	
18	male	33.77	1	no	southeast	1725.5523	
28	male	33.0	3	no	southeast	4449.462	
33	male	22.705	0	no	northwest	21984.47061	
32	male	28.88	0	no	northwest	3866.8552	
31	female	25.74	0	no	southeast	3756.6216	
46	female	33.44	1	no	southeast	8240.5896	
37	female	27.74	3	no	northwest	7281.5056	

Рис. 2.7. Загрузка файла

Для сохранения подключения необходимо создать воркбук (рис. 2.8).




Рис. 2.8. Создание воркбука

Присвоим ему имя Медицинское страхование и сможем сохранить в этот воркбук подключение с именем insurance (рис. 2.9).




Рис. 2.9. Сохранение подключения

После сохранения подключения становится доступным создание датасета (рис. 2.10).

#	age	sex	bmi	children	smoker	region	charges
19		female	27.9	0	yes	southwest	16884.924
18		male	33.77	1	no	southeast	1725.5523
28		male	33.0	3	no	southeast	4449.462
33		male	22.705	0	no	northwest	21984.47061

Рис. 2.10. Создание датасета

При создании датасета можно произвести необходимые настройки (создание датасета в чем-то похоже на запрос в Glarus BI): скрыть поле, настроить агрегацию, добавить описание и т.п. (рис. 2.11).

Имя	Источник поля	Тип	Агрегация	Описание
age	csv.age	# Целое число	Нет	
sex	csv.sex	Строка	Нет	
bmi	csv.bmi	# Дробное число	Нет	
children	csv.children	# Целое число	Нет	
smoker	csv.smoker	Строка	Нет	
region	csv.region	Строка	Нет	
charges	csv.charges	# Дробное число	Нет	

Рис. 2.11. Настройки для датасета

Поля определяют структуру и формат датасета. Существуют следующие типы полей:

- **Измерение.** Такие поля используются для разделения наборов данных на группы. Например: город, дата покупки, категория продукта. Для такого поля определены следующие агрегации (aggregatio, присоединение – это процесс объединения элементов): количество значений в поле и количество уникальных значений (рис. 2.12).

- **Показатель.** Содержит числовые значения, к которым применяются функции агрегации (сведения). Например: сумма кликов, количество переходов (рис. 2.13).

Источники Поля Параметры Фильтрация							Обновить поля	Предпросмотр	+ Добавить поле	Имя или опи
☐ Имя ↓	Источник поля ↓	🔗 ↓	🔑 ↓	Тип ↓	Агрегация ↓	Опис				
1 age	csv.age			# Целое число	Нет					
2 sex	csv.sex			📄 Строка	Нет					
3 bmi	csv.bmi			# Дробное число	Нет					
4 children	csv.children			# Целое число	Количество					
5 smoker	csv.smoker			📄 Строка	Количество уникальных					
6 region	csv.region			📄 Строка	Нет					
7 charges	csv.charges			# Дробное число	Нет					

Рис. 2.12. Варианты агрегации для измерений

Источники Поля Параметры Фильтрация							Обновить поля	Предпросмотр	+ Добавить поле	Имя или описание поля
☐ Имя ↓	Источник поля ↓	🔗 ↓	🔑 ↓	Тип ↓	Агрегация ↓	Описание ↓				
☐ age	csv.age			# Целое число	Нет					
2 sex	csv.sex			📄 Строка	Нет					
3 bmi	csv.bmi			# Дробное число	Количество					
4 children	csv.children			# Целое число	Количество уникальных					
5 smoker	csv.smoker			📄 Строка	Максимум					
6 region	csv.region			📄 Строка	Минимум					
7 charges	csv.charges			# Дробное число	Среднее					
					Сумма					

Рис. 2.13. Варианты агрегации для показателей

Для одного подключения можно создать несколько датасетов. Однако в этом примере будем работать с исходной таблицей. Сохраним датасет с тем же именем insurance.

2.3. Создание чартов

В сохраненном датасете появляется опция Создать чарт (рис. 2.14).




Рис. 2.14. Создание чарта

Создадим диаграмму разброса расходов от веса. Изменим тип чарта на точечную диаграмму (рис. 2.15).




Рис. 2.15. Выбор типа диаграммы

Добавим в качестве оси X показатель bmi, в качестве оси Y показатель charges, цвет точек определим с помощью показателя smoker, а форму точек с помощью показателя sex (рис. 2.16). При наведении на точку графика курсора появляются значения показателей для нее.




Рис. 2.16. Настройки для диаграммы

При наведении курсора на элемент в панели настройки чарта появляется знак настроек ⚙ для конкретной опции (всего чарта, его осей, цвета и т.п.). Так, например, можно добавить на диаграмму заголовок (рис. 2.17).




Рис. 2.17. Добавление заголовка

Можно изменить настройки для формы точек на графике (рис. 2.18).






Рис. 2.18. Настройки формы точек на графике

Размер точек поменяем на 12, чтобы сделать визуализацию более информативной.

Создадим новый чарт. Это можно сделать различными способами: перейти на главную страницу сайта и выбрать виджет – Создать (рис. 2.19,*а*), можно в пиктографическом меню, расположенном слева, кликнуть на кнопке чарты и в открывшейся вкладке нажать кнопку Создать чарт (рис. 2.19,*б*).



а)



б)

Рис. 2.19. Создание чарта с помощью виджета (*а*)
и с помощью пиктографического меню (*б*)

В этом случае необходимо будет выбрать данные для построения чарта (рис. 2.20).




Рис. 2.20. Выбор датасета

Можно открыть датасет, используя пиктографическое меню (рис. 2.21) и создать чарт из датасета (см. рис. 2.15).




Рис. 2.21. Обращение к датасету

В чарте, открытом для настройки, построим столбчатую диаграмму по переменной *region*, чтобы визуализировать число наблюдений, соответствующих каждому ее значению.

По оси X – значения категориальной переменной *region*, а по оси Y – агрегация для этого показателя, чтобы сменить агрегацию, нужно кликнуть по маркеру # слева от имени показателя (рис. 2.22).




Рис. 2.22. Настройки для чарта

Настроим заголовок Число наблюдений для каждого значения переменной region (рис. 2.23). С тем же именем сохранится чарт.




Рис. 2.23. Добавление заголовка

Построим на основе этого чарта новый, в который добавим разбиение наблюдений в каждом из районов по показателю smoker, отвечающему за наличие вредной привычки, изменим заголовок и сохраним как копию (рис. 2.24). Однако лучше все же сначала сохранить первоначальный чарт как копию, а только потом вносить изменения.




Рис. 2.24. Новый чарт на основе ранее созданного

Для чарта доступны дополнительные опции, которые позволяют просмотреть таблицу с данными, сохранить чарт в файл и т.д. (рис. 2.25).




Рис. 2.25. Дополнительные возможности для работы с чартом

Приступим к созданию дашборда.

2.4. Создание дашборда

Перейдем на главную страницу сервиса и выберем опцию Создать дашборд (см. рис. 2.3). При создании необходимо выбрать воркбук, в котором он будет размещен в момент сохранения.

Дашборд состоит из элементов, называемых виджетами (widget приспособление), которые показывают некоторую информацию или выполняют несложное действие.

Yandex DataLens содержит следующие типы виджетов (рис. 2.26):

- чарт;
- селектор;
- текст;
- заголовок.




Рис. 2.26. Рабочая область дашборда

Виджет в виде текста позволяет разместить на дашборде пояснение, ссылки и другие элементы. Заголовки помогают структурировать виджеты внутри дашборда, отделяя группы связанных виджетов визуально.

Ранее созданные чарты можно размещать в любом месте страницы дашборда и изменять размеры. Селектор – это фильтр, который влияет на результаты запросов на связанных с ним виджетах (чарты или другие селекторы).

Добавим на дашборд ранее созданные чарты (рис. 2.27, 2.28).




Рис. 2.27. Выбор чарта из ранее созданных




Рис. 2.28. Добавление чарта

Уберем заголовок добавленного чарта, перейдя в настройки виджета (рис. 2.29).




Рис. 2.29. Скрытие заголовка чарта с экрана

Добавим также остальные чарты на дашборд. Создадим фильтр по показателю sex (рис. 2.30, 2.31).




Рис. 2.30. Добавление селектора и выбор набора данных

Селекторы

Пол

+ Добавить селектор

Расширенные настройки

Настройки селектора

Данные

Источник

На основе датасета

Датасет

insurance

Открыть

Указать ссылку

Поле

sex

Фильтрация

Тип селектора

Список

Операция

—

Множественный выбор

☒

Значение по умолчанию

Не определено

Обязательное поле

☐

Отображение

Заголовок

Пол

Скрыт

Слева

Сверху

Отменить

Сохранить

Рис. 2.31. Настройки для селектора по полу

Также добавим селектор по числовому показателю age (рис. 2.32).

Селекторы

Возраст

+ Добавить селектор

Расширенные настройки

Настройки селектора

Данные

Источник

На основе датасета

Датасет

insurance

Открыть

Указать ссылку

Поле

age

Фильтрация

Тип селектора

Поле ввода

Операция

Больше

Значение по умолчанию

Обязательное поле

☐

Отображение

Заголовок

Возраст

Скрыт

Слева

Сверху

Отменить

Сохранить

Рис. 2.32. Настройки для селектора по возрасту

Сохраним дашборд (рис. 2.33).




Рис. 2.33. Сохранение дашборда

После сохранения дашборд откроется в режиме просмотра. Применим фильтры и обнаружим, что внесение числового значения в фильтр Возраст — неинформативно, нужно добавить в заголовок и саму операцию сравнения (рис. 2.34).




Рис. 2.34. Изменение настроек селектора

На созданный дашборд добавим ссылку (рис. 2.35) на источник данных на ресурсе (<https://www.kaggle.com/mirichoi0218/insurance>).




Рис. 2.35. Добавление ссылки на данные

Сохраним дашборд. В режиме просмотра его вид представлен на рис. 2.36.




Рис. 2.36. Дашборд в режиме просмотра

Теперь попробуем опубликовать дашборд.

Перед публикацией необходимо убедиться, что:

- чарты и дашборды не содержат персональных данных или коммерческой тайны, так как доступ к опубликованным данным неограничен;

- у вас есть права администратора на публикуемые чарты и дашборды и связанные с ними объекты.

В сохраненном дашборде нажимаем кнопку дополнительных опций рядом с местоположением отчета в иерархии папок (рис. 2.37) и выбираем опцию Публичный доступ.




Рис. 2.37. Опция Публичный доступ

Настраиваем публичный доступ (рис. 2.38).




Рис. 2.38. Настройка публичного доступа

Скопировав ссылку и опубликовав ее на каком-либо ресурсе или разослав ее определенному кругу лиц, вы облегчаете доступ к созданному дашборду.

2.5. Объединение данных

Создадим новый воркбук с именем Продажи (рис. 2.39), в котором будем размещать результаты работы с новыми наборами данных.




Рис. 2.39. Создание воркбука

Создадим новое подключение, загрузим файл retail.xlsx (рис. 2.40), описание появления которого приведено ранее (см. разд. 1.5).




Рис. 2.40. Новое подключение

Сохраним это подключение с именем retail и создадим на его основе датасет (рис. 2.41).




Рис. 2.41. Создание датасета

Так как в этих таблицах есть столбцы с данными об одних и тех же покупателях (Customer_ID), то произошло внутреннее соединение двух таблиц по этому полю (рис. 2.42). К настройкам получаем доступ по щелчку на значке типа соединения.




Рис. 2.42. Настройки для связи между таблицами

Перейдем на вкладку датасета Поля и скроем дублирующее поле из второй таблицы (рис. 2.43).

Коллекции и воркбуки / Продажи / Новый датасет

Источники Поля Параметры Фильтрация Обновить поля Предпросмотр + Добавить поле Имя или описание поля

Имя	Источник поля	Тип	Агрегация	Описание
1 customer_id	xlsx - Retail_Data_Transactions....	Строка	Нет	
2 trans_date	xlsx - Retail_Data_Transactions....	Дата и время	Нет	
3 tran_amount	xlsx - Retail_Data_Transactions....	Целое число	Нет	
4 customer_id (1)	xlsx - Retail_Data_Response.cu...	Строка	Нет	
5 response	xlsx - Retail_Data_Response.res...	Целое число	Нет	

Предпросмотр Количество строк: 10 не больше 1 000

#	customer_id	trans_date	tran_amount	response
1	CS5295	2013-02-11T00:00:00	35	1
2	CS4768	2015-03-15T00:00:00	39	1
3	CS2122	2013-02-26T00:00:00	52	0
4	CS1217	2011-11-16T00:00:00	99	0
5	CS1850	2013-11-20T00:00:00	78	0
6	CS5539	2014-03-26T00:00:00	81	0

Рис. 2.43. Настройки для полей

Сохраним датасет с именем retail и приступим к созданию чарта (рис. 2.44).

Датасет: retail

Поиск по имени и описанию +

Измерения

- customer_id
- response
- tran_amount
- trans_date
- Measure Names

Показатели

- Measure Values

Сводная таблица

Столбцы

Строки

- customer_id

Показатели

- tran_amount
- response

Цвета

Сортировка

Фильтры

customer_id	tran_amount	response
CS1112		0
CS1113		0
CS1114		19
CS1115		22
CS1116		13
CS1117		0
CS1118		15
CS1119		0
CS1120		0
CS1121		0
CS1122		0
CS1123		0
CS1124		0
CS1125		0
CS1126		0
CS1127		0
CS1128		0
CS1129		0
CS1130		0
CS1131		0
CS1132		0
CS1133		0

Рис. 2.44. Чарт Сводная таблица

Показатель tran-amount суммирует все покупки данного клиента, но и показатель response также суммирует все 1 или 0, которые относятся к конкретному клиенту. В случае суммирования 0 – все корректно, но значение 19 означает, что клиент откликнулся на рекламу и совершил 19 транзакций. В этом столбце значения по-прежнему должны быть 0 и 1, поэтому кликнем на значке # рядом с именем показателя и в качестве агрегации выберем минимум (можно выбрать и максимум, и среднее, нужный результат будет достигнут), применим настройки (рис. 2.45) и проконтролируем полученный результат (рис. 2.46).

The image shows a configuration window for a metric named 'response'. The settings are as follows:

- Название:** response
- Тип (до агрегации):** Целое число
- Агрегация:** Минимум (selected from a dropdown menu)
- Формат:** Нет
- Отображать группы разрядов:** (checkbox, not checked)
- Префикс:** (empty field)
- Постфикс:** (empty field)
- Размерность:** Нет
- Линейный индикатор:** (toggle, turned off)

At the bottom, there are two buttons: 'Отменить' (Cancel) and 'Применить' (Apply).

Рис. 2.45. Настройки для показателя response

Ни фильтрация, ни сортировка по агрегированному показателю tran_amount в сводной таблице невозможна. Для выявления наиболее активных клиентов в дальнейшем построим новый датасет, использующий тоже самое подключение retail.

Сохраним чарт и приступим к созданию нового. В новом чарте ось X – trans_date, ось Y – tran_amount. Для показателя trans_date настроим агрегацию по месяцам (рис. 2.47)

Сводная таблица		
Столбцы		
Measure Names		
Строки		
customer_id		
Показатели		
tran_amount		
response		
Цвета		
Сортировка		
Фильтры		

customer_id	tran_amount	response
CS1112	1012	0
CS1113	1490	0
CS1114	1432	1
CS1115	1659	1
CS1116	857	1
CS1117	1185	0
CS1118	1011	1
CS1119	1158	0
CS1120	1677	0
CS1121	1524	0
CS1122	1156	0
CS1123	1331	0
CS1124	1127	0
CS1125	885	0
CS1126	1165	0
CS1127	1676	0
CS1128	1921	0
CS1129	853	0
CS1130	1185	0
CS1131	998	0
CS1132	1074	0
CS1133	1413	0

Рис. 2.46. Результат применения настроек




Рис. 2.47. Изменение агрегации для показателя trans_date

Изменим тип диаграммы на линейную и сохраним построенный чарт (рис. 2.48).




Рис. 2.48. Чарт Линейная диаграмма

Создадим новый дашборд, разместим его в воркбуке Продажи. На дашборд добавим два созданных чарта и настроим селектор по показателю trans_date (рис. 2.49).

The screenshot shows a 'Настройки селектора' (Selector settings) dialog box. On the left, there's a 'Селекторы' (Selectors) list with 'trans_date' selected. Below it is a '+ Добавить селектор' (Add selector) button. The main part of the dialog is titled 'Настройки селектора' (Selector settings). It has a close button 'X' in the top right. The 'Данные' (Data) section includes 'Источник' (Source) set to 'На основе датасета' (Based on dataset), 'Датасет' (Dataset) set to 'retail', and 'Поле' (Field) set to 'trans_date'. There's an 'Открыть' (Open) button next to the dataset name. The 'Фильтрация' (Filtering) section includes 'Тип селектора' (Selector type) set to 'Календарь' (Calendar), 'Операция' (Operation) set to 'Принадлежит диапазону' (Belongs to range), and 'Диапазон' (Range) checked. The 'Отображение' (Display) section includes 'Заголовок' (Header) set to 'trans_date'. At the bottom, there are 'Отменить' (Cancel) and 'Сохранить' (Save) buttons. There's also a 'Расширенные настройки' (Advanced settings) button at the bottom left.

Рис. 2.49. Настройки для селектора

Сохраним дашборд с именем Продажи и настроим диапазон дат для селектора (рис. 2.50).




Рис. 2.50. Дашборд Продажи

Создадим новый датасет, открыв подключение retail. В этом датасете также объединим данные и перейдем на вкладку Поля. Скроем два поля trans_date и дублирующее поле customer_id(1), а также настроим агрегацию для полей tran_amount и response (рис. 2.51). Переименуем поле tran_amount (рис. 2.52).

Источники Поля Параметры Фильтрация					
Обновить поля Предпросмотр + Добавить поле Имя или					
☐	Имя ↓	Источник поля ↓	↓	Тип ↓	Агрегация ↓
1	customer_id	xlsx – Retail_Data_Transactions.cust...	☐	Строка	Нет
2	trans_date	xlsx – Retail_Data_Transactions.tran...	☒	Дата и время	Нет
3	tran_amount	xlsx – Retail_Data_Transactions.tran...	☒	Целое число	Сумма
4	customer_id (1)	xlsx – Retail_Data_Response.custo...	☒	Строка	Нет
5	response	xlsx – Retail_Data_Response.respon...	☐	Целое число	Минимум

Рис. 2.51. Настройки для полей датасета

Источники Поля Параметры Фильтрация					Обновить поля	Предпросмотр	+ Добавить поле	Имя
☐	Имя ↓	Источник поля ↓	☐	Тип ↓	Агрегация ↓			
1	customer_id	xlsx – Retail_Data_Transactions.cust...	☐	Строка	Нет			
2	trans_date	xlsx – Retail_Data_Transactions.tran...	☐	Дата и время	Нет			
☐	sum_tran_amount	xlsx – Retail_Data_Transactions.tran...	☐	# Целое число	Сумма			
4	customer_id (1)	xlsx – Retail_Data_Response.custo...	☐	Строка	Нет			
5	response	xlsx – Retail_Data_Response.respon...	☐	# Целое число	Минимум			

Рис. 2.52. Изменение имени поля

Сохраним датасет с именем retail_ag и создадим на его основе чарт. Тип диаграммы – столбчатая, ось X – customer_id, ось Y – sum_tran_amount, также добавим фильтр для trans_date, оставив в рассмотрении только клиентов с суммарными покупками больше чем 2400 (рис. 2.53).




Рис. 2.53. Настройки фильтра

Также добавим настройки для цвета и сортировки (рис. 2.54). Сохраним построенный чарт.




Рис. 2.54. Настройки для чарта

Для дальнейшего совершенствования навыков работы на платформе Yandex DataLens можно воспользоваться справочной документацией [3].

Лабораторная работа № 1

СОЗДАНИЕ ОТЧЕТА ПО РАЗВЕДОЧНОМУ АНАЛИЗУ ДАННЫХ СРЕДСТВАМИ GLARUS BI

Цель работы: для набора данных создать отчет, используя возможности Glarus BI.

Формируемые знания, умения и навыки: научиться загружать данные, работать с вычислимыми полями. Получить навыки формирования отчета по данным, включающего несколько визуализаций, с пользовательскими настройками форматирования.

Необходимо:

1. Загрузить набор данных.
2. Создать запросы: различные виды диаграмм, сводную таблицу. Для сводной таблицы использовать условное форматирование. В одной из диаграмм использовать сортировку.
3. Создать дашборд, на который добавить заголовки и поясняющий текст. Разместить на дашборде построенные запросы, при необходимости скорректировать визуализации (цвет фона, заголовки для визуализаций), добавить на дашборд фильтры.

Контрольные вопросы и задания

1. Как загрузить данные в Glarus BI? Как просмотреть корректность определения типов данных для полей?
2. Что позволяет сделать опция сканирования для загруженного набора данных?
3. Какие визуализации включены в дашборд? Какую бизнес-проблему описывает дашборд? Какие элементы форматирования использовались для повышения наглядности представления данных дашборда?
4. Как создать сводную таблицу?
5. Как создать фильтр?
6. Как скачать дашборд в виде файла с расширением .pdf?

Лабораторная работа № 2

СОЗДАНИЕ ОТЧЕТА ПО РАЗВЕДОЧНОМУ АНАЛИЗУ ДАННЫХ СРЕДСТВАМИ YANDEX DATALENS

Цель работы: для набора данных создать отчет, используя возможности BI-системы от компании Yandex.

Формируемые знания, умения и навыки: научиться подключать источники данных, работать с вычислимыми полями. Получить навыки формирования отчета по данным, включающего несколько визуализаций, с пользовательскими настройками форматирования.

Необходимо:

1. Подключить источники данных.
2. Создать дашборд, использовать следующие чарты: сводная таблица, индикатор и диаграммы. Добавить селекторы. Использовать несколько вкладок в дашборде, также добавить заголовки и поясняющий текст.
3. Опубликовать дашборд.

Контрольные вопросы и задания

1. Как выполнить подключение?
2. Как настроить различные агрегации для показателей и дат?
3. Какие чарты включены в дашборд? Какую бизнес-проблему описывает дашборд? Какие элементы форматирования использовались для повышения наглядности представления данных дашборда?
4. Как создать сводную таблицу?
5. Как создать селектор?
6. Как опубликовать созданный дашборд?

СПИСОК ЛИТЕРАТУРЫ

1. Glarus BI : офиц. сайт. URL: <https://glarus-bi.ru/> (дата обращения: 10.01.2025).
2. Документация Glarus BI : офиц. сайт. URL: <https://glarus-bi.ru/documentation/index.html> (дата обращения: 10.01.2025).
3. Yandex DataLens : офиц. сайт. URL: <https://datalens.yandex.ru/> (дата обращения: 10.01.2025).

Учебное издание

Рындина Светлана Валентиновна

**Анализ данных: построение отчетов
с Yandex DataLens и Glarus BI**

Редактор *А. Г. Темникова*
Технический редактор *Н. В. Иванова*
Компьютерная верстка *Н. В. Ивановой*

Подписано в печать 05.05.2025.
Формат 60×84¹/₁₆. Усл. печ. л. 5,12.
Тираж 6. Заказ № 146.

Издательство ПГУ
440026, г. Пенза, ул. Красная, 40.
Тел.: (8412) 66-60-49, 66-67-77; e-mail: iic@pnzgu.ru

