

Impact Factor:

ISRA (India) = 6.317
ISI (Dubai, UAE) = 1.582
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
ПИИЦ (Russia) = 3.939
ESJI (KZ) = 8.771
SJIF (Morocco) = 7.184

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

SOI: [1.1/TAS](#) DOI: [10.15863/TAS](#)

International Scientific Journal Theoretical & Applied Science

p-ISSN: 2308-4944 (print) e-ISSN: 2409-0085 (online)

Year: 2024 Issue: 06 Volume: 134

Published: 02.06.2024 <http://T-Science.org>

Issue

Article



Daria Dmitrievna Danilova

Peter the Great St.Petersburg Polytechnic University
Bachelor

Oleg Yurievich Sabinin

Peter the Great St.Petersburg Polytechnic University
Candidate of Engineering Sciences, Docent

DATA ANALYSIS AND VISUALIZATION OF SIMILAR PRODUCTS

Abstract: This paper presents the continuation of the development of a system for collecting and searching for similar products in various online stores. A visualization system for the analyzed data is also implemented.

Key words: data marts, SQL queries, visualization, Python, Streamlit.

Language: Russian

Citation: Danilova, D.D., & Sabinin, O.Yu. (2024). Data analysis and visualization of similar products. *ISJ Theoretical & Applied Science*, 06 (134), 12-16.

Soi: <http://s-o-i.org/1.1/TAS-06-134-2> **Doi:**  <https://dx.doi.org/10.15863/TAS.2024.06.134.2>

Scopus ASCC: 1701.

АНАЛИЗ И ВИЗУАЛИЗАЦИЯ ДАННЫХ ПОХОЖИХ ТОВАРОВ

Аннотация: В данной статье представлено продолжение разработки системы сбора и поиска похожих товаров в различных онлайн магазинах. Также реализована система визуализации анализируемых данных.

Ключевые слова: витрины данных, SQL запросы, визуализация, Python, Streamlit.

Введение

На сайтах магазинов, маркетплейсов или агрегаторов скидок на товары часто есть раздел с похожими товарами, но они не предоставляют информацию об изменении цен и скидок на них и соответственно не визуализируют эти данные. В данной статье предлагается проанализировать похожие товары и визуализировать результаты.

Система сбора и поиска похожих товаров представлена в докладе на международной научно-практической конференции «Инжиниринг и прикладные науки: новые технологии, инновационные решения» (TEEAS 2024) с последующей публикацией в сборнике материалов конференции.

Описание хранилища

В реализованной системе для каждого товара подбираются наиболее на него похожие товары на

основе текстовых данных: категория, название и описание (состав) товара.

На рис.1 представлен основной слой хранилища, спроектированный по методологии Кимбалла [3; 4, с. 9], в котором хранятся структурированные данные, и слой витрин данных [5]. В таблицах измерений содержатся данные о магазинах, товарах, времени извлечения данных с сайтов онлайн магазинов. В одной таблице фактов содержится информация об изменении цен и скидок на товары, во второй – для каждого продукта массив кортежей из товаров и веса их схожести. Хранилище реализовано в колоночной СУБД ClickHouse [7; 8].

В данной статье витрина данных Mart.SimilarItems дополнена детальной информацией о похожих товарах, и в таблицу Dim.Items добавлено поле status – статус работоспособности ссылки на товар.

Impact Factor:

ISRA (India) = 6.317	SIS (USA) = 0.912	ICV (Poland) = 6.630
ISI (Dubai, UAE) = 1.582	ПИИЦ (Russia) = 3.939	PIF (India) = 1.940
GIF (Australia) = 0.564	ESJI (KZ) = 8.771	IBI (India) = 4.260
JIF = 1.500	SJIF (Morocco) = 7.184	OAJI (USA) = 0.350

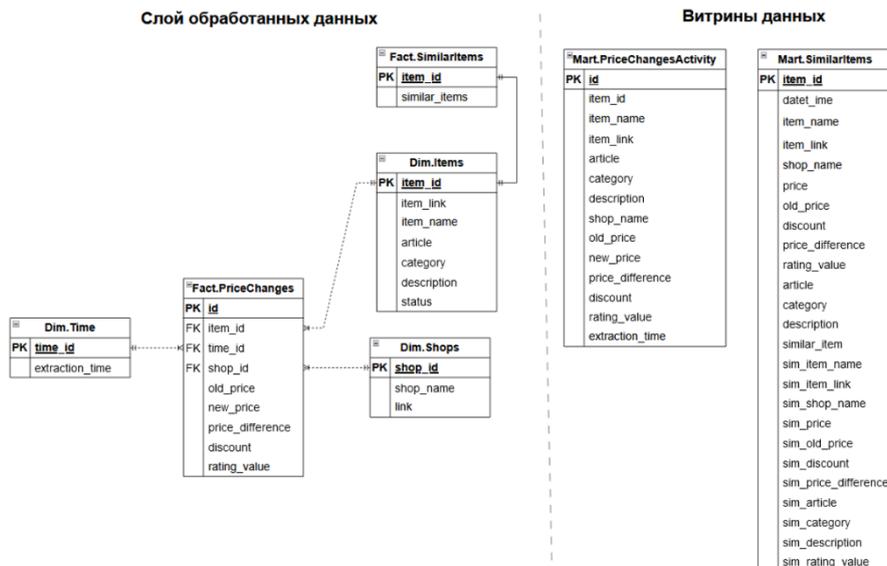


Рисунок 1. Слой хранилища данных.

Анализ цен и скидок похожих товаров

Среди похожих товаров найдем три товара с наибольшим весом похожести, с наибольшей скидкой и с наименьшей ценой. Для этого создадим витрину данных Mart.SimilarItems, которая будет определять такие товары и содержать подробную информацию о каждом из них. Витрина данных будет состоять из денормализованных таблиц фактов, организованных по гораздо более простой схеме

по сравнению с хранилищем данных [2, с. 36; 6, с. 298].

Из таблицы изменяемых данных о товарах Fact.PriceChanges необходимо извлечь данные о товарах за текущий день, а именно идентификатор товара, дату извлечения, идентификатор магазина, предыдущую и текущую цены, разницу между ценами, скидку и рейтинг товара. Код SQL запроса приведен на рис.2.

```
CREATE or replace VIEW Mart.SimilarItems AS
WITH
-- извлекаем основные данные о целевом товаре
discounts AS
(
    SELECT DISTINCT
        item_id,
        toDate(dictGet('Dim.Time', 'extraction_time', time_id)) AS date_time,
        shop_id,
        old_price,
        new_price AS price,
        price_difference,
        discount,
        rating_value
    FROM Fact.PriceChanges
    FINAL
    PREWHERE toDate(dictGet('Dim.Time', 'extraction_time', time_id)) = toDate(now())
),
```

Рисунок 2. Код извлечения данных о целевом товаре.

Далее нужно соединить таблицу Fact.SimilarItems с результатом предыдущего запроса по идентификатору целевого товара. Также необходимо извлечь наименование товара, ссылку на него, название магазина, артикул, категорию, состав и похожие товары.

Воспользовавшись оконной функцией row_number() [9; 10], в рамках каждого целевого товара пронумеруем строки, отсортированные по весу и по скидке в убывающем порядке и по цене в возрастающем порядке, на рис.3 представлен код SQL запроса.

Impact Factor:

ISRA (India) = 6.317	SIS (USA) = 0.912	ICV (Poland) = 6.630
ISI (Dubai, UAE) = 1.582	ПИИЦ (Russia) = 3.939	PIF (India) = 1.940
GIF (Australia) = 0.564	ESJI (KZ) = 8.771	IBI (India) = 4.260
JIF = 1.500	SJIF (Morocco) = 7.184	OAJI (USA) = 0.350

```
-- извлекаем данные о похожих товарах
sim_items AS
(
  SELECT
    item_id,
    similar_items AS similar_item
  FROM Fact.SimilarItems
  FINAL
  LEFT ARRAY JOIN similar_items
),
-- вместо идентификаторов указываем название целевого товара, ссылки, магазина
-- артикула, категории, описания, находим самые похожие (с наибольшим весом похожести, с наибольшей скидкой и с наименьшей ценой), используя row_number
results AS
(
  SELECT
    date_time,
    si.item_id,
    dictGet('Dim.Items', 'item_name', si.item_id) AS item_name,
    dictGet('Dim.Items', 'item_link', si.item_id) AS item_link,
    dictGet('Dim.Shops', 'shop_name', shop_id) AS shop_name,
    price,
    old_price,
    discount,
    price_difference,
    rating_value,
    dictGet('Dim.Items', 'article', si.item_id) AS article,
    dictGet('Dim.Items', 'category', si.item_id) AS category,
    dictGet('Dim.Items', 'description', si.item_id) AS description,
    similar_item,
    row_number() OVER (PARTITION BY si.item_id ORDER BY si.item_id ASC, similar_item.2 DESC, discount DESC, price ASC) AS rn
  FROM sim_items AS si
  LEFT JOIN discounts AS d ON si.item_id = d.item_id
)
```

Рисунок 3. Код извлечения данных о похожих товарах.

Чтобы получить изменяемые данные о похожих товарах, нужно выполнить соединение с первым из запросов по полям этих товаров.

Чтобы вывести товары с наибольшим весом похожести, с наибольшей скидкой и с наименьшей

ценой, при фильтрации необходимо оставить только строки, где значения оконной функции row_number() равны 1, 2 и 3. Код SQL запроса представлен на рис.4.

```
-- отбираем три самых похожих товара, дополняем основной информацией о похожих товарах
SELECT
  date_time,
  item_id,
  item_name,
  item_link,
  shop_name,
  price,
  old_price,
  discount,
  price_difference,
  rating_value,
  article,
  category,
  description,
  similar_item,
  dictGet('Dim.Items', 'item_name', similar_item.1) AS sim_item_name,
  dictGet('Dim.Items', 'item_link', similar_item.1) AS sim_item_link,
  dictGet('Dim.Shops', 'shop_name', d2.shop_id) AS sim_shop_name,
  d2.price AS sim_price,
  d2.old_price AS sim_old_price,
  d2.discount AS sim_discount,
  d2.price_difference AS sim_price_difference,
  dictGet('Dim.Items', 'article', similar_item.1) AS sim_article,
  dictGet('Dim.Items', 'category', similar_item.1) AS sim_category,
  dictGet('Dim.Items', 'description', similar_item.1) AS sim_description,
  d2.rating_value AS sim_rating_value
FROM results
LEFT JOIN discounts AS d2 ON (similar_item.1) = d2.item_id
WHERE rn IN (1, 2, 3)
;
```

Рисунок 4. Код извлечения данных о трех самых похожих товарах.

Задачи и требования к системе визуализации

У магазинов, маркетплейсов и агрегаторов товаров нет визуализации изменений цен и скидок, а также не представлена детальная информация о схожих товарах. Но покупателям эти данные могут оказаться полезными, чтобы представлять, когда следует ожидать скидки на те или иные товары.

Определим следующие задачи для системы визуализации:

А. Отображение минимальной, максимальной и медианной скидки целевого товара.

В. Отображение текущих цены, предыдущей цены и скидки на целевой товар.

С. Построение графиков изменений цены и скидки со временем для целевого товара.

Д. Отображение детальной информации о целевом товаре.

Е. Отображение детальной информации о похожих товарах на целевой товар.

Impact Factor:

ISRA (India) = 6.317
ISI (Dubai, UAE) = 1.582
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
РИИЦ (Russia) = 3.939
ESJI (KZ) = 8.771
SJIF (Morocco) = 7.184

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

Среди требований выделим, что все элементы визуализации должны находиться на одной странице и должны иметь названия, также должна быть возможность выбора целевого товара.

Данные из пунктов А и В достаточно представить в виде скалярных значений. Для данных из пункта С необходимо построить два отдельных графика. Данные из пунктов D и E необходимо представить в виде двух различных таблиц.

Построение визуализация данных

Для визуализации выбрана библиотека Streamlit с открытым исходным кодом, она позволяет писать на языке программирования Python. Кроме того, с помощью Streamlit можно размещать различные элементы – графики, наборы данных, скаляры и т.д. – на одной веб-странице [1].

Для начала необходимо создать раскрывающийся список всех ссылок на товары в онлайн магазинах на основе витрины Mart.SimilarItems.

Затем на основе исторических данных витрины Mart.PriceChangesActivity необходимо определить минимальную, максимальную и медианную скидки на товар.

Текущую и предыдущую цены и текущую скидку на товар необходимо определить из данных витрины Mart.SimilarItems.

Графики изменения скидок и цен на целевой товар строятся на основании исторических

данных витрины Mart.PriceChangesActivity хранилища. Для обоих графиков выбрана диаграмма рассеяния, поскольку, в случае если данные не будут собираться какое-то время, то на графиках это будет видно. В случае линейного графика пропуск отобразится как изменение цены либо скидки, что приведет к ложным представлениям.

Кроме того, визуализируем детальную информацию о товаре: дата извлечения данных о товаре, название товара, ссылка на товара в онлайн магазине, название магазина, текущая цена, предыдущая цена, скидка, разница в цене, рейтинг товара, артикул, категория товара, описание (состав).

Также визуализируем детальную информацию о похожих товарах: дата извлечения данных о товарах, ссылка на целевой товар, названия схожих товаров, ссылки на схожие товары в онлайн магазинах, названия магазинов, текущие цены, предыдущие цены, скидки, разницы в ценах, рейтинги товаров, артикулы, категории товаров, описания (составы).

Результаты визуализации

Ниже на рис.5 представлена часть веб-страницы для одного из продуктов магазина ВкусВилл с найденными похожими товарами в магазине Перекресток. В верхней части присутствует раскрывающийся список, из которого можно выбрать веб-ссылку целевого товара.

Price Changes Activity Dashboard

Select a Product

<https://spb.vkusvill.ru/goods/moloka-pitevoe-mdzh-2-8-4-5-tselnoe-500ml-rp-90442.html>

Min discount

0

Max discount

0

Median discount

0.0

Current price

66

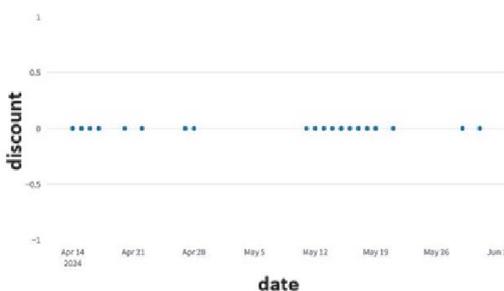
Current discount

0

Old Price

0

History of Discounts Changes



History of Price Changes

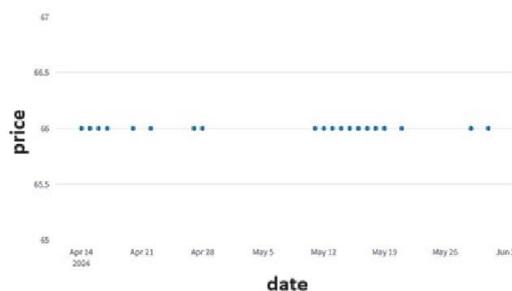


Рисунок 5. Графическое представление информации о цене и скидках на целевой товар.

Impact Factor:

ISRA (India) = 6.317
ISI (Dubai, UAE) = 1.582
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
РИИЦ (Russia) = 3.939
ESJI (KZ) = 8.771
SJIF (Morocco) = 7.184

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

Далее представлена информация о минимальной, максимальной и медианной скидке. Затем приведена информация о текущих цене и скидке, а также о предыдущей цене на товар. За ними располагаются два графика, на которых можно отслеживать изменения цен и скидок на товар с течением времени.

На рис.6 представлено продолжение визуализации.

В верхней таблице представлена детальная информация о целевом товаре: дата извлечения данных с сайта, название товара, ссылка на него на сайте магазина, название магазина, текущая и предыдущая цены, разница между ценами, рейтинг, категория и описание (состав).

Detailed Data For Product Description

	date	item_name	item_link	shop_name	new_price	old_price	discount	price_difference	rating_value	article	category	description
0	2024-05-31	Молоко питьевое мдк 2,8-4,5% цельное 500мл_РП	https://spb.vkusvill.ru/goods	Вкусвилл	66	0	0	0	4.7		Молоко, сливки	молоко цельное коровье

Detailed Data For Similar Products

	date	target_item_link	item_name	item_link	shop_name	price	old_price	discount	price_difference	rating_value	article	category	description
0	2024-05-31	https://spb.vkusvill.ru	Молоко Асеневская Ферма пастеризованное 3.4-6%, 900мл	https://www.perekrestok.ru	Перекрёсток	104	104	0	0	4.9		Молоко	Молоко коровье цельное.
1	2024-05-31	https://spb.vkusvill.ru	Молоко Правильное Молоко пастеризованное 3.2-4%, 2л	https://www.perekrestok.ru	Перекрёсток	219	219	0	0	4.93		Молоко	Цельное молоко.
2	2024-05-31	https://spb.vkusvill.ru	Молоко питьевое топленое 2.5% Зелёная Линия, 900мл	https://www.perekrestok.ru	Перекрёсток	79	79	0	0	4.94		Молоко	Нормализованное молоко

Рисунок 6. Графическое представление данных о товаре и похожих на него товаров-аналогов.

В нижней таблице представлена аналогичная информация, но для товаров-аналогов.

Выводы

В статье представлен инструмент для анализа скидок и цен на похожие товары с помощью

построения витрины данных. Также сформулированы задачи и требования к системе визуализации и приведены результаты поиска похожих товаров из магазинов Перекрёсток и ВкусВилл при помощи разработанной системы.

References:

1. AbdulMajedRaja, R.S. (2024). *How to build a real-time live dashboard with Streamlit. 5 easy steps to make your own data dashboard.* Retrieved 10.05.2024 from <https://blog.streamlit.io/how-to-build-a-real-time-live-dashboard-with-streamlit/>
2. Eagar, G. (2021). *Data Engineering with AWS*, 2021, Packt Publishing, 461 p.
3. (2013). *Kimball Group, Kimball University, Kimball Dimensional Modeling Techniques.* Retrieved 16.04.2024 from <https://www.kimballgroup.com/wp-content/uploads/2013/08/2013.09-Kimball-Dimensional-Modeling-Techniques11.pdf>
4. Kimball, R., & Ross, M. (2013). *The Data Warehouse Toolkit: The Definitive Guide to Dimensional Modeling, Third Edition.* Published by John Wiley & Sons, Inc., Indianapolis, Indiana, 2013. 565 p.
5. Moody, D.L., & Kortink, M.A.R. (2024). *From Enterprise Models to Dimensional Models: A Methodology for Data Warehouse and Data Mart Design.* Retrieved 16.04.2024 from <https://ceur-ws.org/Vol-28/paper5.pdf>
6. Reis, J., & Housley, M. (2022). *Fundamentals of Data Engineering: Plan and Build Robust Data Systems*, First Edition, 2022, 420 p.
7. (2024). *What Is a Columnar Database?* Retrieved 29.05.2024 from <https://clickhouse.com/docs/en/faq/general/columnar-database>
8. (2022). *What is ClickHouse: A revolutionary tool for real-time data processing.* Retrieved 29.05.2024 from <https://double.cloud/blog/posts/2022/09/what-is-clickhouse-why-column-oriented-dbms-are-important/>
9. (2024). *Window Functions.* Retrieved 30.05.2024 from <https://clickhouse.com/docs/ru/sql-reference/window-functions>
10. Zakaznikov, V. (2024). *ClickHouse Window Functions — Current State of the Art.* Retrieved 30.05.2024 from <https://altinity.com/blog/clickhouse-window-functions-current-state-of-the-art>