

ТРАНСПОНИРОВАНИЕ ДАННЫХ

- ПРЕДСТАВЛЕНИЕ ДАННЫХ
- НЕКОРРЕКТНАЯ СТРУКТУРА: ПРИМЕР
- ПОНЯТИЕ ТРАНСПОНИРОВАНИЯ
- ТРАНСПОНИРОВАНИЕ НА ЭТАПЕ ETL
- ОБРАТНОЕ ТРАНСПОНИРОВАНИЕ

ПРЕДСТАВЛЕНИЕ ДАННЫХ

Большинство алгоритмов аналитики данных могут применяться только к структурированным данным, то есть данным, представленным в виде таблиц, в которых каждый столбец представляет собой некоторый атрибут или признак, а каждая запись – наблюдение, описывающее состояние анализируемого объекта или процесса.

Однако даже если данные являются структурированными, это еще не гарантирует, что структура таблицы соответствует требованиям той или иной задачи анализа.

| | Атрибут 1 | Атрибут 2 | Атрибут 3 |
|--------------|-----------|-----------|-----------|
| Наблюдение 1 | | | |
| Наблюдение 2 | | | |
| Наблюдение 3 | | | |


ПРЕДСТАВЛЕНИЕ ДАННЫХ

Действительно, для одного и того же набора данных можно построить множество табличных представлений. При этом некоторые представления способны привести к частичной и даже полной утрате смысла данных.

В лучшем случае это может привести к невозможности построить на основе данных модель или применить к ним готовую модель. В худшем можно получить некорректные результаты анализа, сделать по ним неправильные выводы и заключения.

| | Атрибут 1 | Атрибут 2 | Атрибут 3 |
|--------------|-----------|-----------|-----------|
| Наблюдение 1 | → | | |
| Наблюдение 2 | → | | |
| Наблюдение 3 | → | | |

ПРЕДСТАВЛЕНИЕ ДАННЫХ



Иллюстрацией к такой ситуации может служить построение графика. Для получения корректного графического представления данных значения независимой переменной (например, **Дата продажи**) откладываются по горизонтальной оси, а зависимой (например, **Сумма продажи**) – по вертикальной. Если сделать наоборот, то разобраться в таком графике будет очень непросто.

ПРЕДСТАВЛЕНИЕ ДАННЫХ

Ситуации, когда структура таблицы, в которой содержатся анализируемые данные, не соответствует решаемой задаче, чаще всего возникают тогда, когда данные поступают с рабочих мест отдельных пользователей, которые строят таблицу, как умеют, или как им удобно.

ПРЕДСТАВЛЕНИЕ ДАННЫХ

| Дата | 01.03.17 | 02.03.17 | 03.03.17 | 04.03.17 | 05.03.17 | 06.03.17 |
|------------|----------|----------|----------|----------|----------|----------|
| Товар | | | | | | |
| Количество | | | | | | |
| Сумма | | | | | | |
| Остаток | | | | | | |

① ② ③

Приведем пример. Пусть имеется плоская таблица, по которой требуется построить модель для прогнозирования временного ряда, которую пользователь заполнил в виде, представленном на слайде.

Использование такой таблицы в качестве источника данных для алгоритма прогнозирования крайне неудобно, поскольку даты, товары и количественные показатели продаж должны образовывать столбцы (поля), а наблюдения – строки (записи).

ПРЕДСТАВЛЕНИЕ ДАННЫХ

| Дата | 01.03.17 | 02.03.17 | 03.03.17 | 04.03.17 | 05.03.17 | 06.03.17 |
|------------|----------|----------|----------|----------|----------|----------|
| Товар | | | | | | |
| Количество | | | | | | |
| Сумма | | | | | | |
| Остаток | | | | | | |

1 2 3

В данном же случае наблюдение – это информация о товаре, его количестве, сумме и остатке на определенную дату. При этом наблюдения образуют столбцы, что противоречит самой идее структуризации.

ПРЕДСТАВЛЕНИЕ ДАННЫХ

| Дата | 01.03.17 | 02.03.17 | 03.03.17 | 04.03.17 | 05.03.17 | 06.03.17 |
|------------|----------|----------|----------|----------|----------|----------|
| Товар | | | | | | |
| Количество | | | | | | |
| Сумма | | | | | | |
| Остаток | | | | | | |

① ② ③

Кроме того, поля источника данных должны быть типизированы, то есть содержать данные только одного типа. В представленной таблице поля содержат значения различных типов: строковые – для наименований товаров, и числовые – для суммы, количества и остатков, то есть тип данных каждого столбца – переменный.


Такая ситуация в большинстве случаев приведет к ошибке несоответствия типов данных при попытке применить к данным из таблицы какую-либо обработку.

НЕКОРРЕКТНАЯ СТРУКТУРА: ПРИМЕР

| Дата | Товар | Количество | Сумма | Остаток |
|------------|-------|------------|-------|---------|
| 01.03.2017 | | | | |
| 02.03.2017 | | | | |
| 03.03.2017 | | | | |
| 04.03.2017 | | | | |
| 05.03.2017 | | | | |
| 06.03.2017 | | | | |

Ситуацию можно легко исправить, если применить к таблице операцию, которая преобразует строки таблицы в столбцы, а столбцы – в строки. В результате мы получим те же данные, но другой структуры.

ПОНЯТИЕ ТРАНСПОНИРОВАНИЯ



Транспонирование – это термин из теории матриц, который обозначает операцию, преобразующую столбцы матрицы в строки, а строки – в столбцы.

При работе с таблицами, содержащими анализируемые данные, этот термин имеет более широкий смысл. Такие таблицы могут иметь сложную структуру, десятки полей измерений и фактов. В результате возникает противоречие между «плоской» структурой таблицы и «многомерным» характером содержащихся в ней данных.

ПОНЯТИЕ ТРАНСПОНИРОВАНИЯ

Традиционно в бизнес-аналитике для выбора наиболее удобного представления многомерных данных используются OLAP-кубы, но OLAP-куб – это всего лишь средство визуализации многомерных данных.

Манипулируя OLAP-кубом для выбора оптимального представления, мы не изменяем саму структуру источника данных. Можно сказать, что с помощью OLAP -куба пользователь управляет представлением данных, а с помощью транспонирования – структурой источника данных.



ТРАНСПОНИРОВАНИЕ НА ЭТАПЕ ETL

Транспонирование на этапе ETL используется для оптимизации структуры источника данных с точки зрения определенной задачи. С помощью транспонирования можно не только менять местами строки и столбцы таблицы, но и проводить более сложные манипуляции с ее структурой.

В качестве источников данных часто выступают файлы баз данных самых различных форматов, поэтому, получая источник данных, аналитик заранее не знает, в каком виде эти данные будут загружены в информационную систему компании.



ТРАНСПОНИРОВАНИЕ НА ЭТАПЕ ETL

| Таблица 1 | | | Таблица 2 | | | |
|--------------|-------------|-------------------|--------------|---------|--------|-------------|
| ФИО клиента | Атрибут | Значение атрибута | ФИО клиента | Возраст | Доход | Стаж работы |
| Иванов И.И. | Возраст | 36 | Иванов И.И. | 36 | 18 000 | 15 |
| Иванов И.И. | Доход | 18 000 | Сидоров П.В. | 45 | 24 000 | 21 |
| Иванов И.И. | Стаж работы | 15 | | | | |
| Сидоров П.В. | Возраст | 45 | | | | |
| Сидоров П.В. | Доход | 24 000 | | | | |
| Сидоров П.В. | Стаж работы | 21 | | | | |

Например, возможна ситуация, когда данные из первичного источника представлены структурой, как это демонстрирует таблица 1. Каждое наблюдение (клиент) оказывается размещенным в нескольких строках, а атрибуты не образуют поля.

С помощью транспонирования можно «развернуть» таблицу 2, как показано на слайде.

ОБРАТНОЕ ТРАНСПОНИРОВАНИЕ

Еще одной проблемой, с которой часто приходится сталкиваться аналитикам при работе с источниками данных, являются нарушения в их структуре.

Если в витринах, хранилищах и базах данных регулярность структуры данных поддерживается автоматически, то в файлах отдельных пользователей структура таблиц не является жестко заданной.

Особенно характерна данная ситуация для файлов электронных таблиц, где в случае сложной, иерархической структуры данных появляются заголовки, общие для нескольких полей.



ОБРАТНОЕ ТРАНСПОНИРОВАНИЕ

| Дата | Группа 1 | | | | | | Группа 2 | | | |
|----------|----------|-------|---------|-------|---------|-------|----------|-------|---------|-------|
| | Товар А | | Товар В | | Товар С | | Товар D | | Товар Е | |
| | Кол-во | Сумма | Кол-во | Сумма | Кол-во | Сумма | Кол-во | Сумма | Кол-во | Сумма |
| 01.03.17 | | | | | | | | | | |
| 02.03.17 | | | | | | | | | | |
| 03.03.17 | | | | | | | | | | |

Типичный пример представлен на слайде, где в таблице присутствуют три измерения: **Дата**, **Товар** и **Группа товара**. При этом измерение **Товар** является иерархически подчиненным измерению **Группа товара**. Часто встречаются еще более сложные структуры, например, товары могут группироваться по городам, где они продавались, фирмам-поставщикам и клиентам и так далее.

Операция **обратного транспонирования** позволяет избавиться от структурных нарушений в таблице.

ОБРАТНОЕ ТРАНСПОНИРОВАНИЕ

В результате обратного транспонирования таблицы может быть получена структура, показанная на слайде.

В каждой записи новой таблицы содержится наблюдение по каждой дате, группе товара и отдельному товару, структура данных является полностью регулярной, а столбцы – типизированы. Такая таблица вполне отвечает требованиям, предъявляемым источникам данных, хотя и выглядит более громоздкой и избыточной.

Для выполнения операции транспонирования пользователь должен определить, какие именно измерения и факты исходной таблицы должны войти в транспонированную таблицу, а также, какие измерения должны отображаться в столбцах, а какие – в строках.

При этом для выполнения операции транспонирования должно быть выбрано хотя бы одно поле фактов, поскольку именно факты являются «связующим звеном» измерений.

Иными словами, какие бы изменения в таблице не происходили в результате ее транспонирования, факты должны быть жестко связаны со своими измерениями.

| Дата | Группа товара | Товар | Кол-во | Сумма |
|----------|---------------|---------|--------|-------|
| 01.03.17 | Группа 1 | Товар А | | |
| 01.03.17 | Группа 1 | Товар В | | |
| 01.03.17 | Группа 1 | Товар С | | |
| 01.03.17 | Группа 2 | Товар D | | |
| 01.03.17 | Группа 2 | Товар E | | |
| 02.03.17 | Группа 1 | Товар А | | |
| 02.03.17 | Группа 1 | Товар В | | |
| 02.03.17 | Группа 1 | Товар С | | |
| 02.03.17 | Группа 2 | Товар D | | |
| 02.03.17 | Группа 2 | Товар E | | |
| 03.03.17 | Группа 1 | Товар А | | |
| 03.03.17 | Группа 1 | Товар В | | |
| 03.03.17 | Группа 1 | Товар С | | |