НАФИ

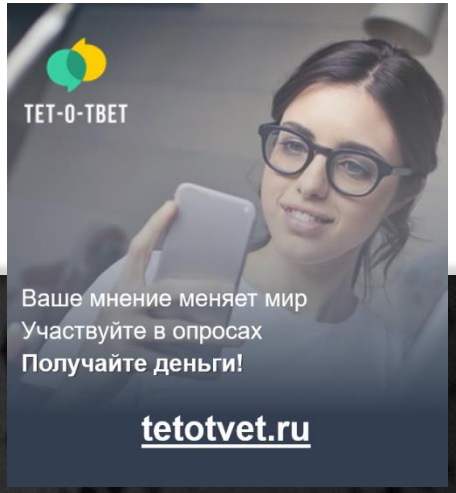

ТЕМА 1

ОБЗОР ПРОГРАММНОГО ПАКЕТА SPSS. НАЧАЛО РАБОТЫ

Для свободного использования в образовательных целях
Copyright © Академия НАФИ. Москва
Все права защищены
nafi.ru

ОГЛАВЛЕНИЕ

1. ВВЕДЕНИЕ В КОЛИЧЕСТВЕННЫЕ ИССЛЕДОВАНИЯ

1. Введение в количественные исследования

ЧТО ИЗУЧАЮТ СОЦИАЛЬНЫЕ НАУКИ?

Общество
(Population)

Выборка
(Sample)

Человек
(Case)

СОЗНАНИЕ

ПОВЕДЕНИЕ

Совет

По ссылке вы можете ознакомиться с различными примерами количественных исследований НАФИ

1. Введение в количественные исследования

ОТ ТЕОРЕТИЧЕСКОЙ СОЦИОЛОГИИ К ЭМПИРИЧЕСКОЙ

Свойства людей – это их физические, психические и социальные характеристики (**признаки**).

Социологов и маркетологов преимущественно интересуют **социальные характеристики: сознание (мнение) и бытие (поведение) людей, в случае маркетинга – потребителей.**

1. Введение в количественные исследования

ЧТО ТАКОЕ АНАЛИЗ ДАННЫХ?

Анализ данных является одним из этапов исследования и включает проверку соответствия между эмпирическими данными и теоретической моделью изучаемого явления.

Переменная (признак) – некоторое общее для всех изучаемых объектов, например людей, свойство, конкретные проявления которого могут меняться от объекта к объекту.

Различные проявления признака для разных объектов называют **значениями.** Значения переменной, которые она принимает для различных изучаемых объектов, приводят нас к необходимости рассматривать **распределение переменной.**

Переменная (variable)

Значение

Наблюдение (case)

Респондент (num_ank)	Возраст (AGE)	Пол (GENDER)	Образование (EDU)	Семейное положение (FAMILY)
1	21	1	3	1
2	34	2	2	2
3	19	1	3	3
4	52	1	4	2
5	46	2	5	3

1 = мужской
2 = женский

1. Введение в количественные исследования

ПРИМЕР АНАЛИЗА ДАННЫХ О РАСПРЕДЕЛЕНИ ПЕРЕМЕННОЙ

Задача: проанализировать возраст работающего населения

Объект исследования: работающее (полная занятость) население страны

Признак (переменная): возраст (age)

Значения переменной: 18…70 лет

Распределение значений переменной (distribution)

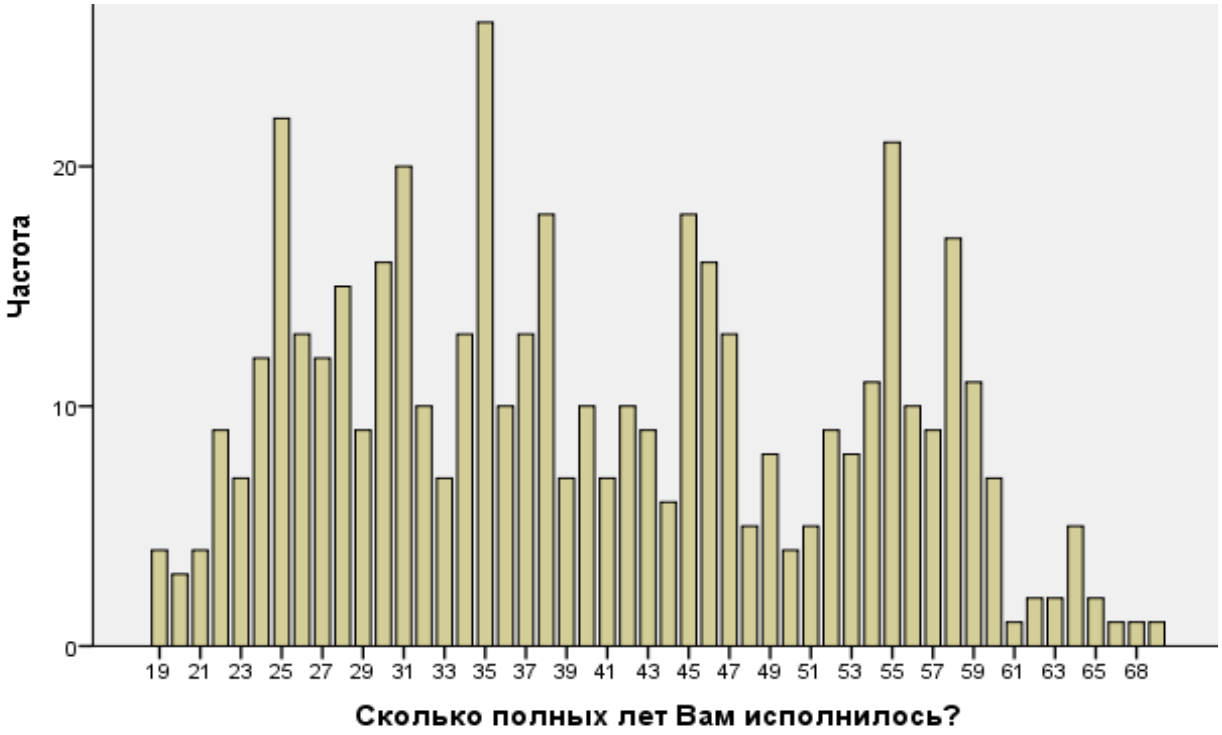

1. Введение в количественные исследования

КАКИЕ ДАННЫЕ АНАЛИЗИРУЕТ СОЦИОЛОГ ИЛИ МАРКЕТОЛОГ?

Данные – это результаты наблюдений, испытаний, накапливаемые с целью последующего изучения и анализа.

ДИСКРЕТНЫЕ ДАННЫЕ

представляют собой отдельные значения признака, общее число которых конечно или счетно (может быть подсчитано)

Пример:
Пол респондента (GENDER):
1 = Мужской **2** = Женский

НЕПРЕРЫВНЫЕ ДАННЫЕ

в отличие от дискретных данных, могут принимать любое значение в некотором интервале

Пример:
Доход работника (INCOME):
100$.....100 000$+

1. Введение в количественные исследования

ГЕНЕРАЛЬНАЯ СОВОКУПНОСТЬ И ВЫБОРКА

«Чтобы понять вкус супа, не обязательно съедать всю кастрюлю – достаточно одной ложки»

Генеральная совокупность (population) – полная совокупность изучаемых объектов.

Выборка (sample) – часть генеральной совокупности, отбираемая специальным образом и исследуемая с целью получения репрезентативных выводов о свойствах генеральной совокупности.

Репрезентативность выборки – это свойство выборки отражать генеральную совокупность с определенной погрешностью (ошибкой выборки).

Ошибка выборки — отклонение характеристик выборочной совокупности от характеристик генеральной совокупности.

Генеральная совокупность	Выборочная совокупность (выборка)
Все занятое население России **72,3 млн человек**	**500 чел.**

1.1 ОБЗОР ОСНОВНЫХ ПОНЯТИЙ СТАТИСТИКИ

1.1. Обзор основных понятий статистики

В количественных исследованиях признаки изучаются на основе статистики их распределения, распространенности в обществе или среди отдельных групп.

- **Частотное распределение признака (frequency distribution)** – закономерность встречаемости разных его значений.
- **Частота (frequency)** – количество наблюдений, в которых признак принимает определенное значение или находится в определенном интервале.

Частотное **распределение** переменной (frequency distribution)

1. МЕРЫ СРЕДНЕГО УРОВНЯ

- Среднее
- Мода
- Медиана

2. МЕРЫ РАССЕЯНИЯ (ДИСПЕРСИИ)

- Дисперсия
- Средне-квадратическое (стандартное) отклонение
- Стандартная ошибка
- Размах

3. МЕРЫ РАСПРЕДЕЛЕНИЯ

- Асимметрия
- Эксцесс

НОРМАЛЬНОЕ РАСПРЕДЕЛЕНИЕ

Кривая Гаусса:

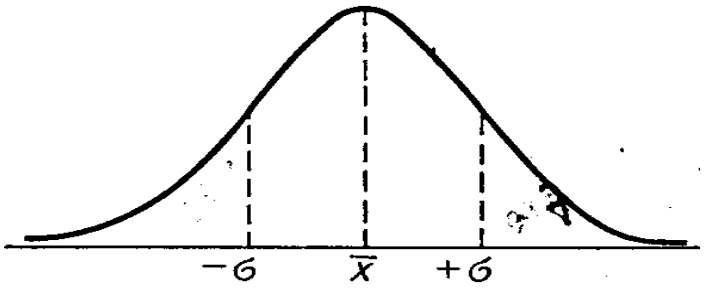

Формула:

$$f_{отн} = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x_i - M)^2}{2\sigma^2}}$$

- Характеризуется тем, что крайние значения признака в нем встречаются редко, а значения, близкие к средней величине – достаточно часто.
- Некоторая величина отклоняется от среднего под воздействием слабых, независимых друг от друга случайных факторов.
- Имеет место, когда интересующее нас явление подвержено влиянию бесконечного числа случайных факторов, уравновешивающих друг друга.
- Если действует какой-либо однонаправленный фактор, распределение может отличаться от нормального.

СРЕДНЕЕ (Mean)

- Сумма всех значений, отнесенная к общему числу наблюдений (очень чувствительна к выбросам).
- Предполагает, что результат измерения задан в метрической (интервальной) шкале.
- Важнейшее свойство средней величины заключается в том, что она выражает то общее, что присуще всем единицам исследуемой совокупности.
- Типичность средней зависит от степени однородности совокупности. Сумма отклонений от среднего равна 0.

Среднее для **выборки**

$$\overline{X} = \frac{\sum_i X_i}{n}$$

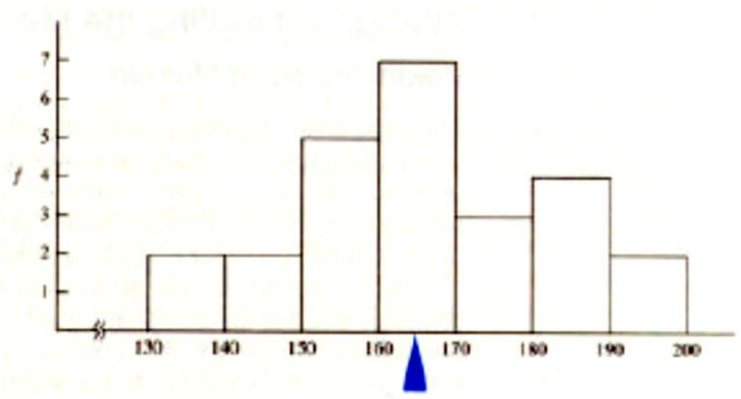

МОДА (Mode)

- Наиболее часто встречающееся значение переменной.
- Обычно используется, когда набор значений ограничен и имеется их частое повторение.
- Если в выборке встречаются одинаково часто два значения, распределение называют бимодальным, если присутствуют несколько часто встречающихся значений – мультимодальным.
- Если все значения в распределении встречаются одинаково часто, то такая выборка не имеет моды.

Унимодальное

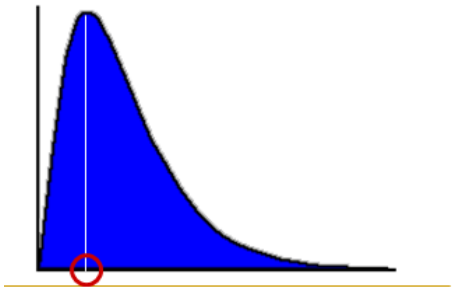

Бимодальное

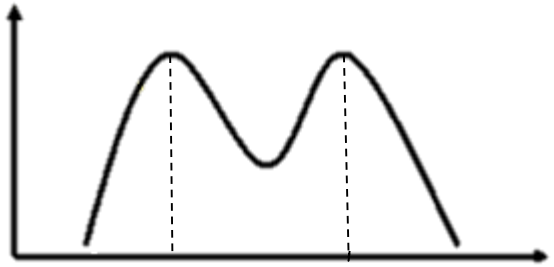

Мультимодальное

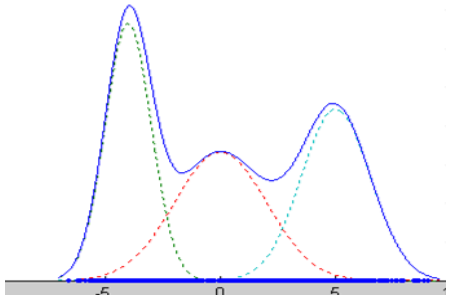

обычно возникают,
если выборка имеет естественные обособленные подгруппы

МЕДИАНА (Median)

- Значение, которое делит распределение пополам: половина значений больше медианы, половина – меньше. «Середина» распределения.
- Когда есть сильные выбросы, лучше использовать медиану, а не среднее.
- Имеет смысл для ранговых и количественных переменных, но не для качественных.

Количество чисел (значений) в ряду

Нечетное

Пример:
Возраст **5** опрошенных (AGE):

18 22 (27) 31 44

Четное

Пример:
Возраст **6** опрошенных (AGE):

18 22 27 31 44 55

(27+31):2 = (29)

1.1. Обзор основных понятий статистики

Мода, медиана и среднее СОВПАДАЮТ для симметричного унимодального распределения. К появлению перекоса чувствительнее всего среднее значение.

	ЗАРПЛАТА, руб.	ЧАСТОТА, чел.
Генеральный директор	1 000 000	1
Заместители директора	80 000	3
Менеджеры	40 000	10
Ассистенты	25 000	14

Средняя з/п = 71 071 руб.

Медиана = 32 500 руб.

Мода = 25 000 руб.

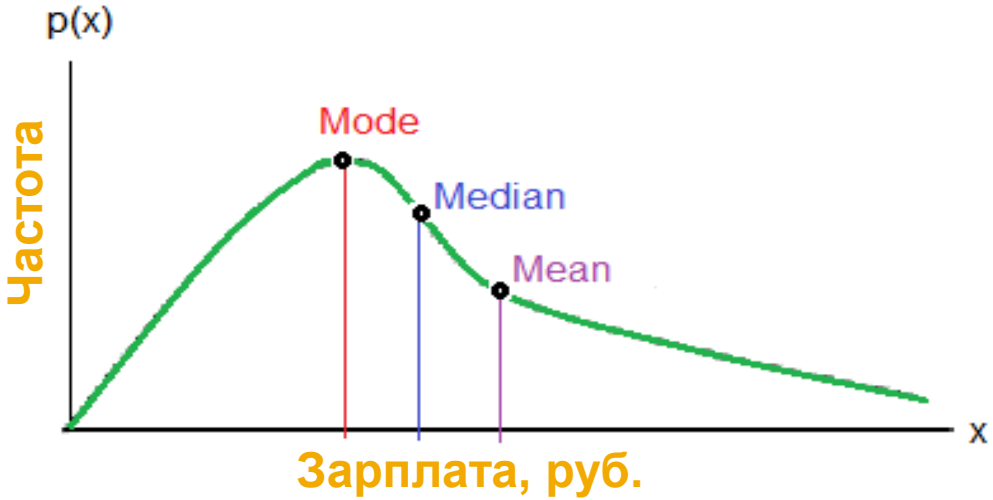

ДИСПЕРСИЯ (VARIANCE)

- Дисперсия – это среднее арифметическое квадратов разностей полученных значений переменной и ее средним значением.
- Измеряется в единицах переменной, возведённых в квадрат (не всегда удобно).
- Показывает разброс значений признака относительно своего среднего арифметического значения, то есть насколько плотно значения признака группируются вокруг.
- Чем больше разброс, тем сильнее варьируются ответы респондентов в данной группе, тем больше индивидуальные различия между респондентами.
- Используется скорее в различных статистических тестах, а не в описательной статистике.

$$D = \frac{(a_1 - S)^2 + (a_2 - S)^2 + \ldots + (a_n - S)^2}{n}$$

a_1, a_2, a_3 … a_n – данные,
S – среднее арифметическое
n – количество чисел в ряду

СТАНДАРТНОЕ ОТКЛОНЕНИЕ (Standard Deviation)

- Среднеквадратическое или стандартное отклонение – мера разброса значений признака около среднего арифметического значения.
- На практике вместо оценки дисперсии чаще используют производную от нее – стандартное отклонение (корень из дисперсии).
- Более наглядно, т.к. его размерность соответствует размерности измеряемой величины (*измеряется в тех же единицах, что и переменная!*)

$$\sigma = \sqrt{D}$$

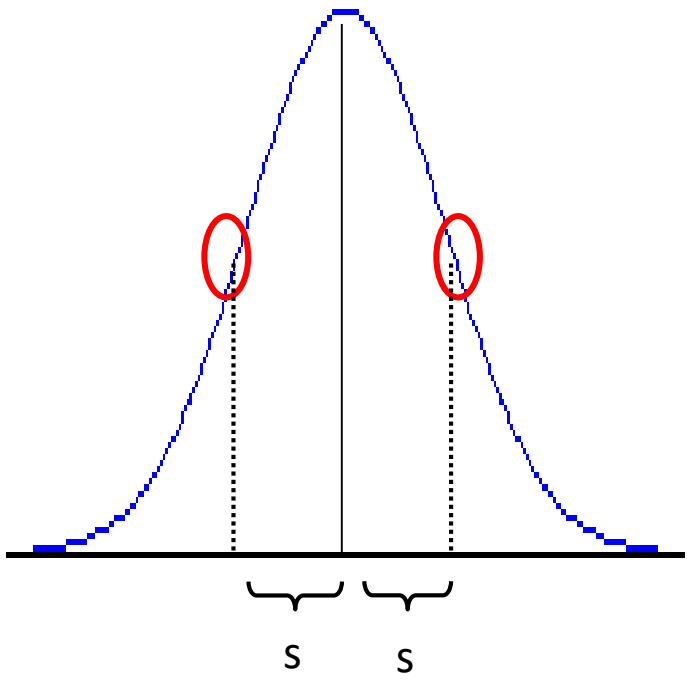

1.1. Обзор основных понятий статистики

Variation ratio – самая простая мера рассеяния (для номинальных переменных). Это “доля” объектов, не попадающих в модальную категорию.

1	**Женат/ замужем**	**58%**
2	**Холост/ не замужем**	18%
3	**Разведен/ разведена**	9%
4	**Незарегистр. / гражданский брак**	3%
5	**Вдовец/вдова**	11%
Total=1586		

Мода – 1 (женат/замужем)
Variation ratio = 1 – 0.58 = 0.42
Диапазон значений – от 0 до 1. Чем больше variation ratio, тем больше дисперсия признака.

Коэффициент вариации (CV) – отношение стандартного отклонения к среднему арифметическому, выраженное в %. Это относительная мера разброса значений признака.

$$CV = \frac{s \cdot 100}{\overline{X}}$$

Стандартная ошибка (S.E. Mean) – определяется как стандартное отклонение, деленное на квадратный корень из объема выборки. Используется для оценки того, насколько выборка отражает тенденции, наблюдаемые в генеральной совокупности.

Размах (Range) – разница между наибольшим и наименьшим значениями в распределении (между мин и макс). Используется для порядковых переменных. Пример: рейтинги успеваемости студентов.

ПРОЦЕНТИЛИ И КВАРТИЛИ

Квартили (quartiles) делят распределение на четыре части так, что в каждой из них оказывается поровну значений (2-й квартиль = медиана)

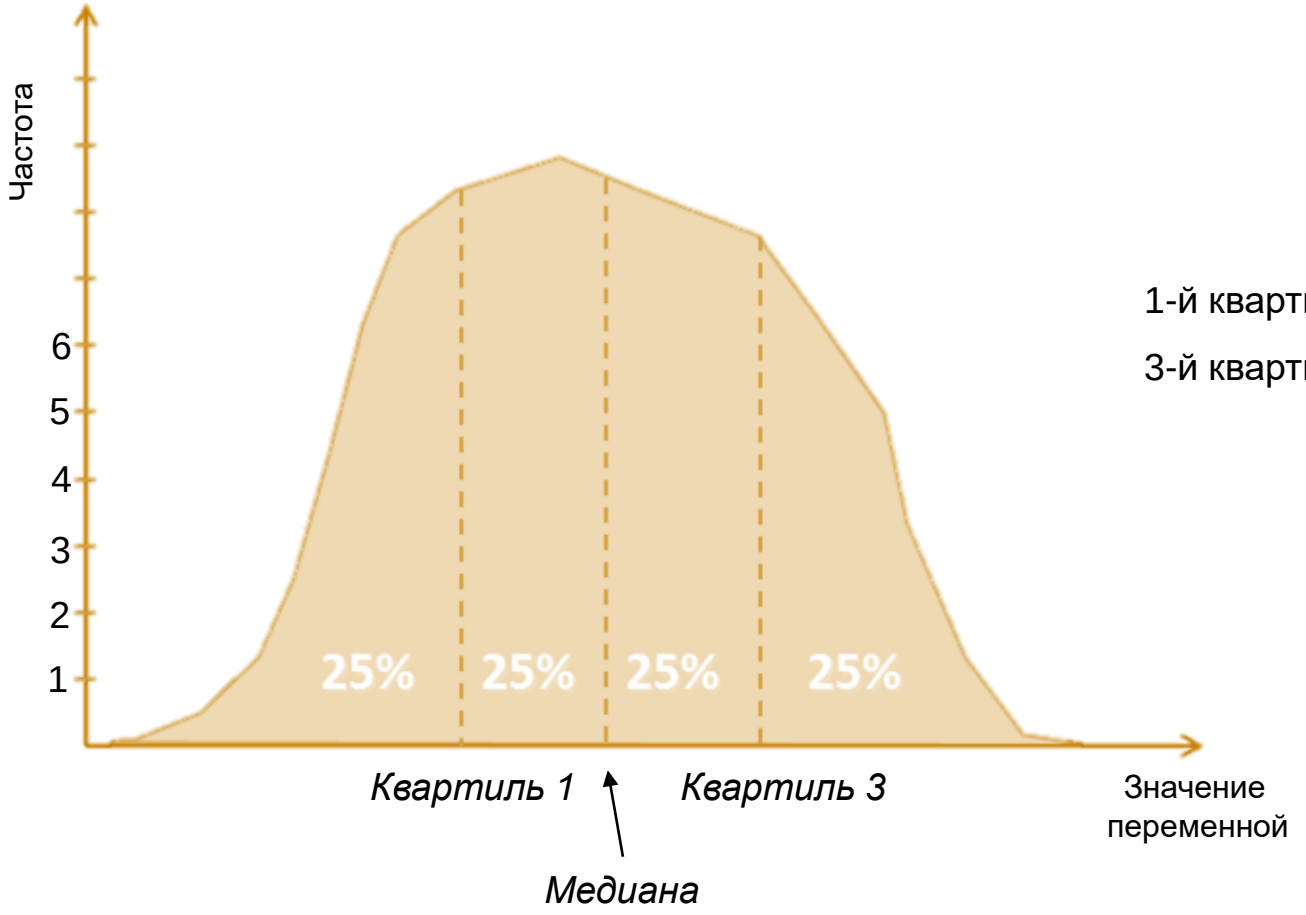

1-й квартиль = 25% процентиль

3-й квартиль = 75% процентиль

АСИММЕТРИЯ

Коэффициент асимметрии A (skewness) – характеризует скошенность распределения в сторону больших или меньших значений признака. Это мера отклонения распределения частоты от симметричного (нормального) распределения, то есть такого, у которого на одинаковом удалении от среднего значения по обе стороны выборки данных располагается одинаковое количество значений.

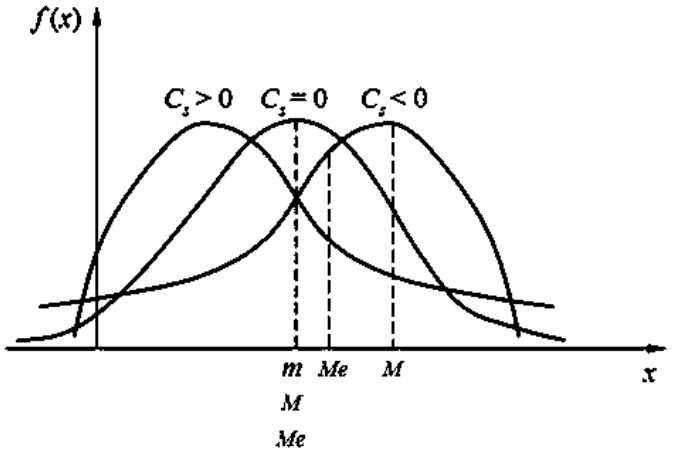

Коэффициент асимметрии изменяется от минус до плюс бесконечности, для нормальных распределений A=0.

Если вершина асимметричного распределения сдвинута к меньшим значениям, то говорят **о положительной асимметрии** (A>0), в противоположном случае — **об отрицательной** (A<0).

$$As = \frac{\sum (x_i - M)^3}{n\sigma^3}$$

ЭКСЦЕСС

Коэффициент эксцесса E (kurtosis) - характеризует степень островершинности распределения. Коэффициент указывает, является ли распределение пологим (при большом значении коэффициента) или крутым.

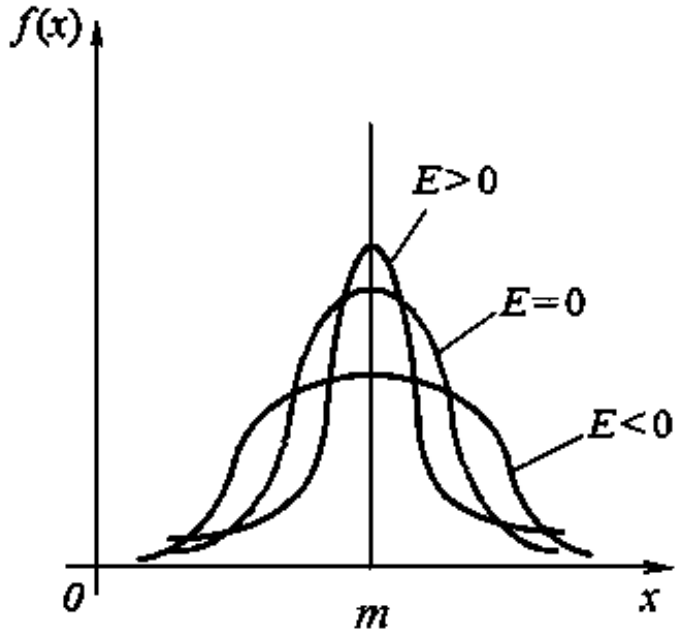

Для нормального распределения E=0
Для островершинного E>0
Для плосковершинного E<0

$$Ex = \frac{\sum_i (x_i - M)^4}{n\sigma^4} - 3$$

1.2 ТИПЫ ШКАЛ

1.2. Типы шкал

ОСНОВНЫЕ ПОНЯТИЯ

Шкала (Scale) – правило, определяющее, каким образом в процессе измерения каждому изучаемому объекту ставится в соответствие некоторое число или символы.

Шкалирование (**Scaling**) – процесс создания континуума (последовательного ряда), на котором размещаются измеряемые объекты.

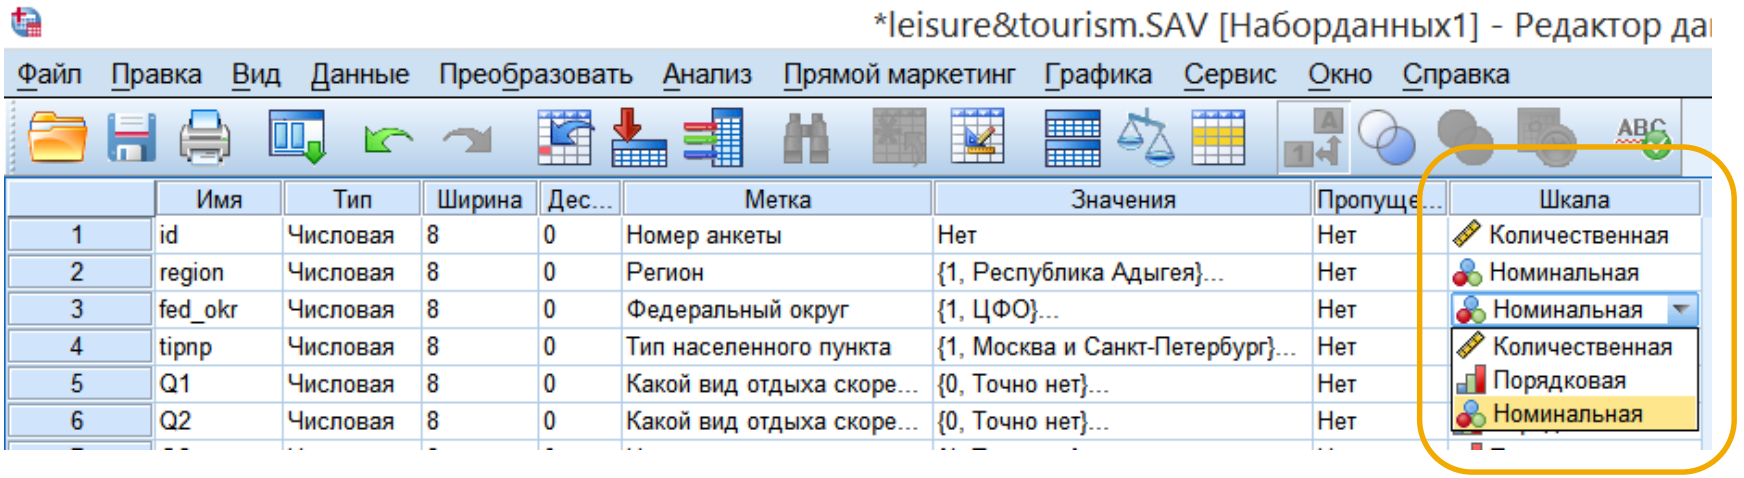

1.2. Типы шкал

Назовите, пожалуйста, форму вашей работы?

1. Работаю по найму
2. Являюсь владельцем предприятия
3. Самостоятельная занятость
4. Не работаю

Как бы вы оценили материальное положение своей семьи?

1. Высокое
2. Выше среднего
3. Среднее
4. Ниже среднего
5. Низкое
6. Затрудняюсь ответить

Оцените, насколько вы согласны с каждым из следующих суждений относительно работы органов власти страны?
(от 1 до 5, где 5 – максимально хорошо)
Суждение 1
Суждение 2
Суждение 3
И т.п.
Итог: сумма ответов

Сколько вам лет?
_____ *(запишите число)*

Сколько человек в вашей семье, включая вас?
_____ *(запишите число)*

1.2. Типы шкал

Номинальная шкала (Nominal) — шкала наименований, которая состоит из значений признаков, не упорядоченных по степени возрастания или убывания.

> **Пример:** национальность, профессия, семейное положение, пол и т.д.

Порядковая шкала (Ordinal) — градации располагаются в определенном порядке относительно возрастания либо убывания интенсивности свойства.

> **Пример:** переменная «Курение» со значениями (1 = некурящий; 2 = изредка курящий; 3 = интенсивно курящий; 4 = очень интенсивно курящий). Переменная сортирована в порядке значимости снизу вверх: умеренный курильщик курит больше, нежели некурящий, а сильно курящий — больше, чем умеренный курильщик и т.д., поэтому порядковая шкала.

Интервальные шкалы (Interval) — основаны на процедурах, обеспечивающих равные или примерно равные расстояния между градациями переменной. В данном случае сравниваются не значения переменных, а расстояния между значениями.

> **Пример:** температура, измеренная в градусах Цельсия. Можно не только сказать, что температура 30 градусов выше, чем 20 градусов, но и то, что увеличение температуры с 10 до 30 градусов вдвое больше увеличения температуры от 20 до 30 градусов.

Шкалы отношений (Метрические) — соответствуют всем требованиям, предъявляемым к шкалам более низких классов.

> **Пример:** возраст. Если Максу 30 лет, а Сергею 60, можно сказать, что Сергей вдвое старше Макса.

1.2. Типы шкал

ЗНАНИЕ ТИПОВ ШКАЛ ПОЗВОЛИТ ВЫБРАТЬ ОПТИМАЛЬНЫЕ МЕТОДЫ АНАЛИЗА ДЛЯ РАЗНЫХ ТИПОВ ДАННЫХ

Статистическая шкала	Математическая значимость
Номинальная	Нет
Порядковая	Порядок чисел
Интервальная	Разность между числами
Шкала отношений	Отношение чисел

В SPSS объединены в одну метрическую шкалу

Шкала, по которой измеряется переменная, накладывает ограничения на выбор меры центральной тенденции

Типическое значение	Номинальные данные	Порядковые данные	Интервальные данные
Мода	●	●	●
Медиана		●	●
Среднее			●

2. ПРОГРАММНЫЙ ПАКЕТ SPSS И ЕГО ВОЗМОЖНОСТИ

Программный пакет SPSS и его возможности

- **SPSS** — Statistical Package for the Social Science (статистический пакет для социальных наук)

- Наряду с другими статистическими пакетами (Statistica, STATA, SAS) широко используется специалистами в сфере исследований (социология, психология, маркетинг, медицина и пр.) для обработки и анализа количественных данных.

Полезный совет

Ознакомьтесь с исследованием НАФИ о студентах, выполненном с помощью пакета SPSS

Загрузите отчет бесплатно (PDF) по ссылке

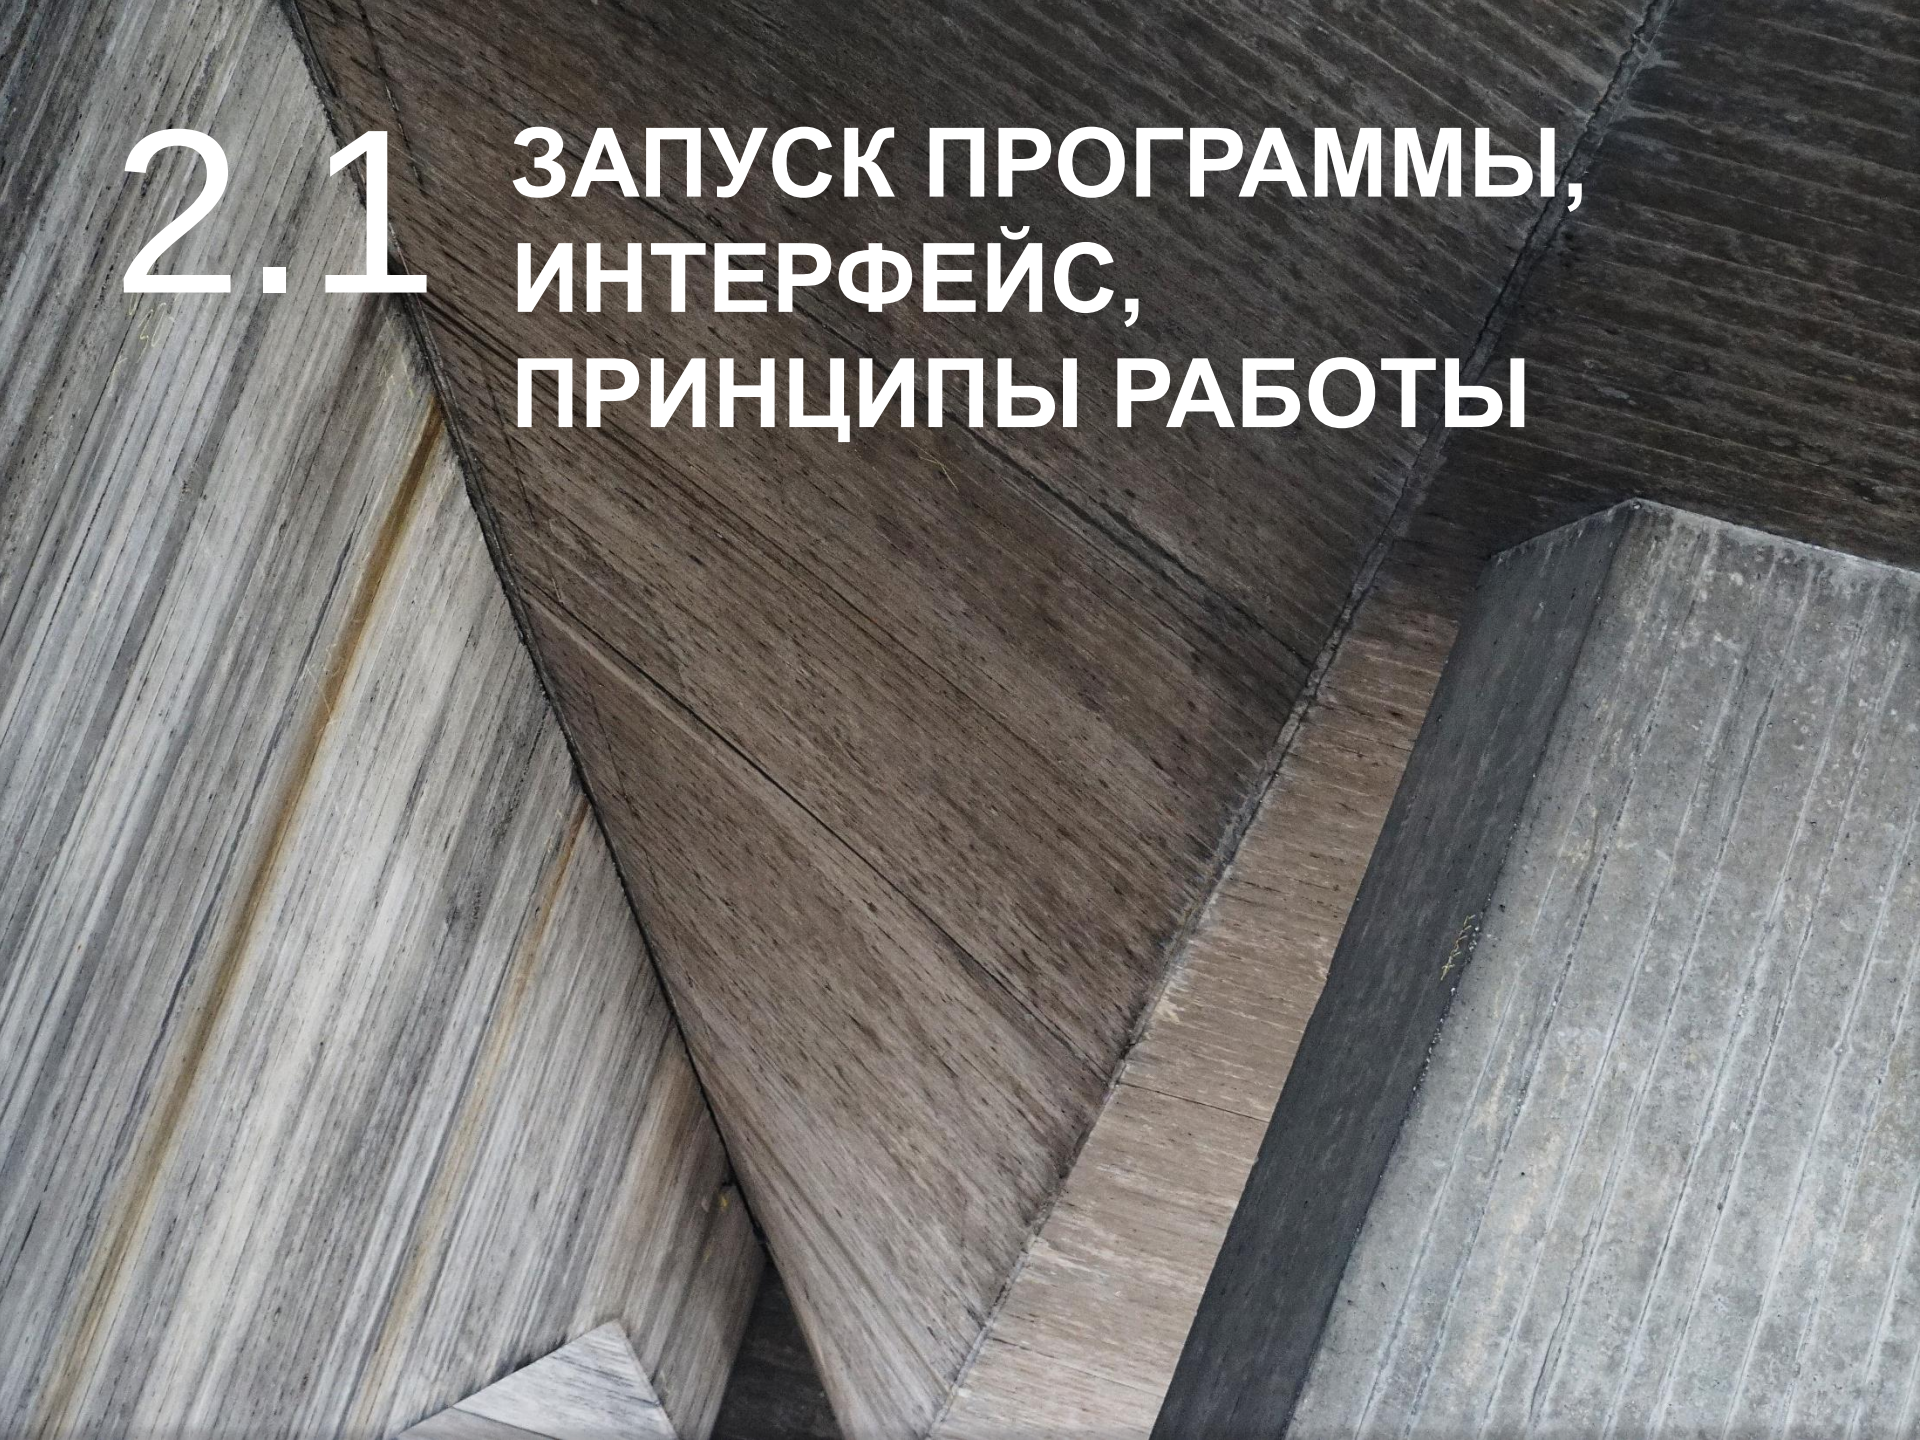

2.1 ЗАПУСК ПРОГРАММЫ, ИНТЕРФЕЙС, ПРИНЦИПЫ РАБОТЫ

2.1. Запуск программы, интерфейс, принципы работы

ПО УМОЛЧАНИЮ ПРИ ЗАПУСКЕ SPSS ЗАПУСКАЕТСЯ ОКНО «РЕДАКТОР ДАННЫХ»

Запуск SPSS

Start → All Programs → SPSS Inc → IBM SPSS Statistics

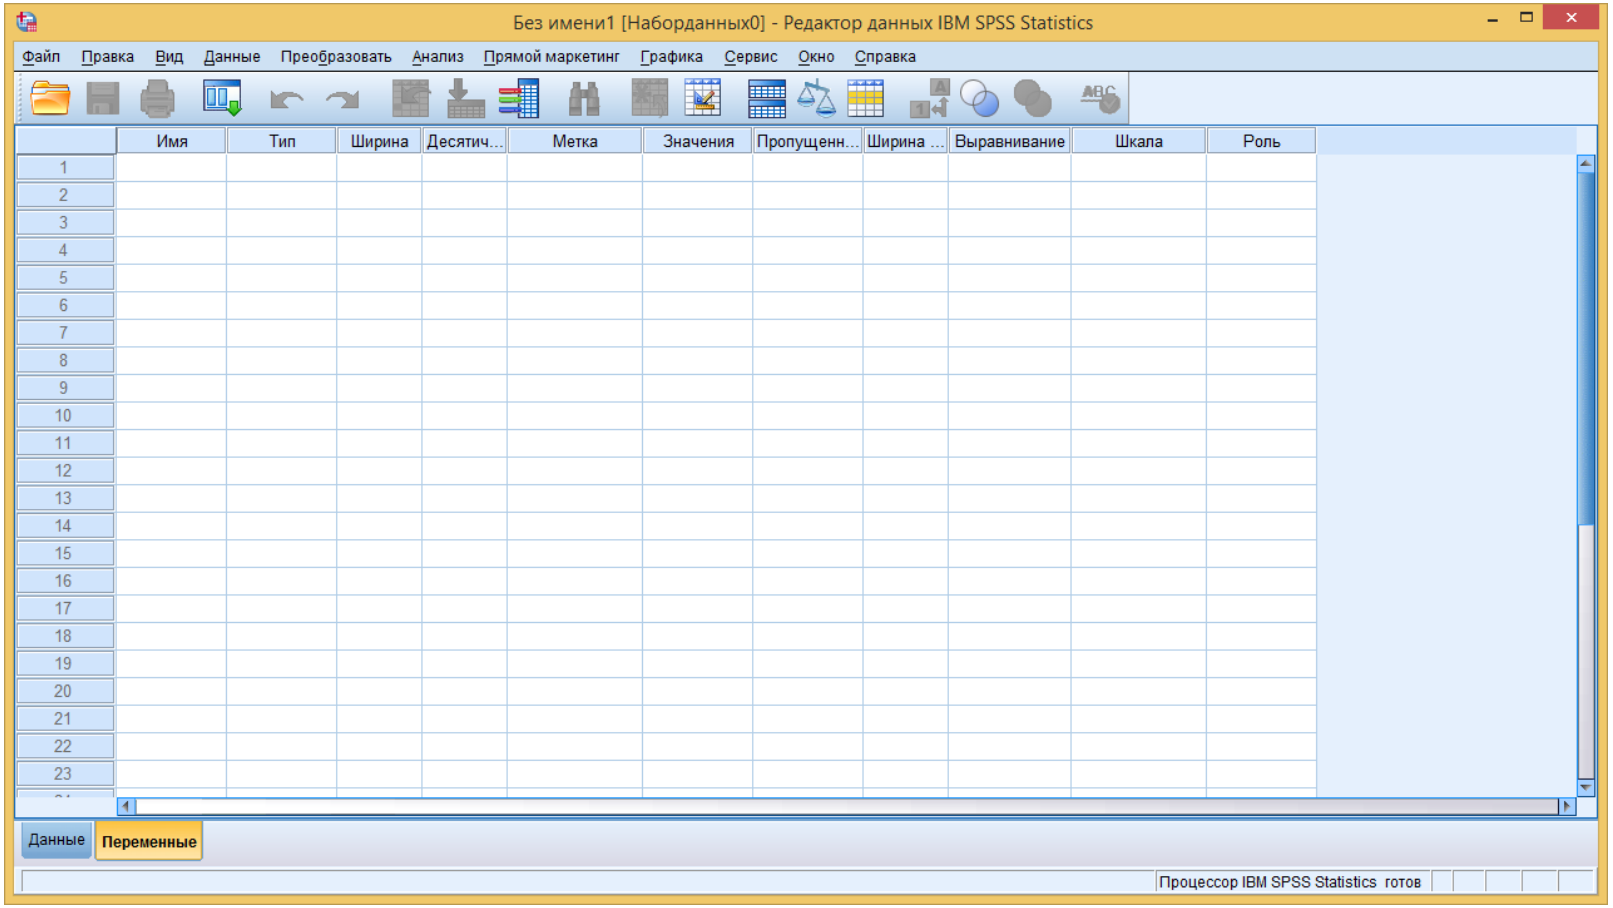

2.1. Запуск программы, интерфейс, принципы работы

ДВА ИНТЕРФЕЙСА SPSS

В SPSS реализовано два основных интерфейса работы с данными. Кнопочный – интуитивно более понятный. Синтаксис – язык команд, больше подходит для выполнения более сложных или повторяющихся вычислений.

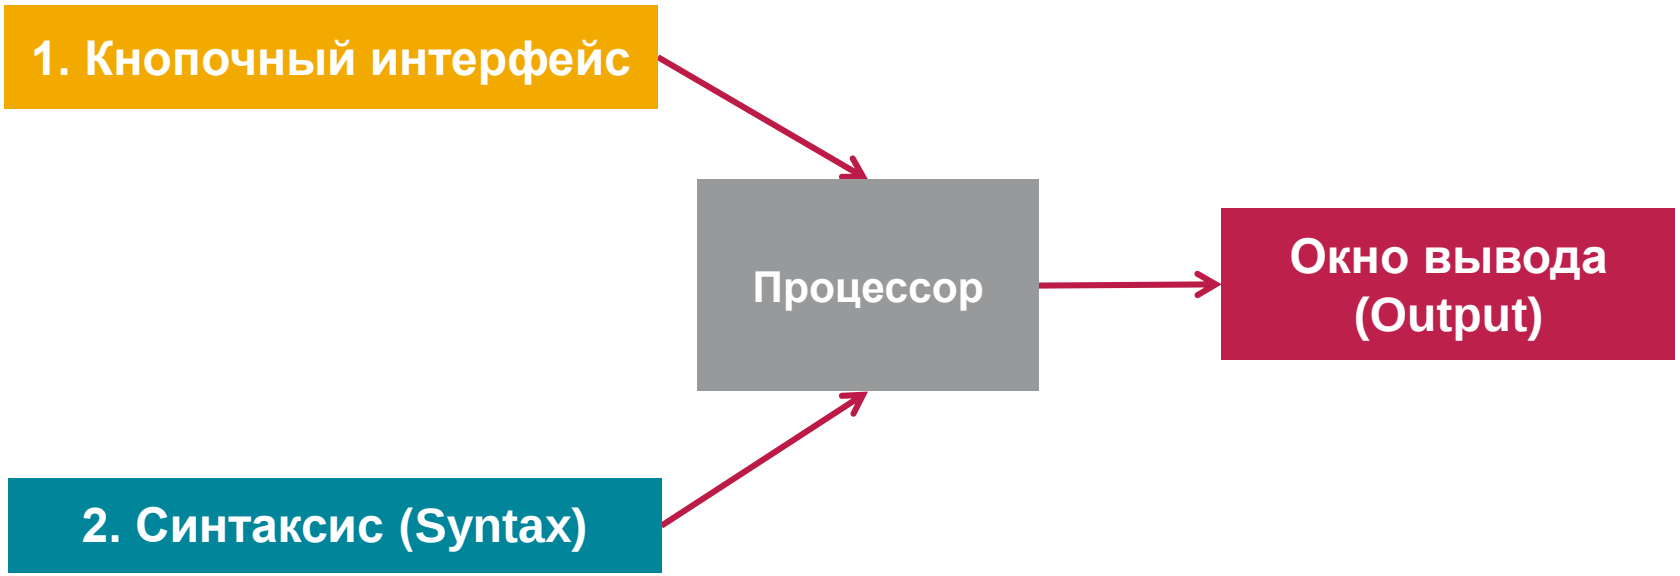

2.1. Запуск программы, интерфейс, принципы работы

1. КНОПОЧНЫЙ ИНТЕРФЕЙС

При запуске SPSS пользователю открывается окно для ввода, редактирования и просмотра данных исследования. Данные сохраняются в файле с расширением *.sav

Кнопочный интерфейс состоит из двух вкладок:

- **Вкладка «Data view» (Окно данных)**
  - Окно ввода данных
  - Columns: variables (переменные)
  - Rows: cases (наблюдения)
- **Вкладка «Variable view» (Окно переменных)**
  - Окно создания и настройки переменных
  - Variables (список переменных)
  - Параметры каждой из переменных

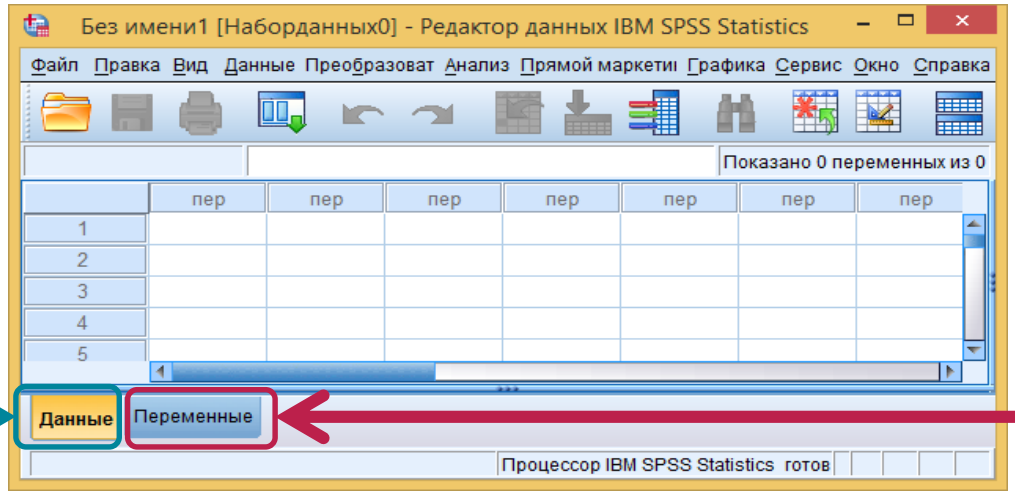

2.1. Запуск программы, интерфейс, принципы работы

2. ОКНО РЕДАКТОРА КОМАНДНОГО ЯЗЫКА SYNTAX

Текстовый редактор для ввода синтаксиса – команд обработки данных. **Используется для оптимизации и детальной настройки вычислений, недоступной в кнопочном интерфейсе.**

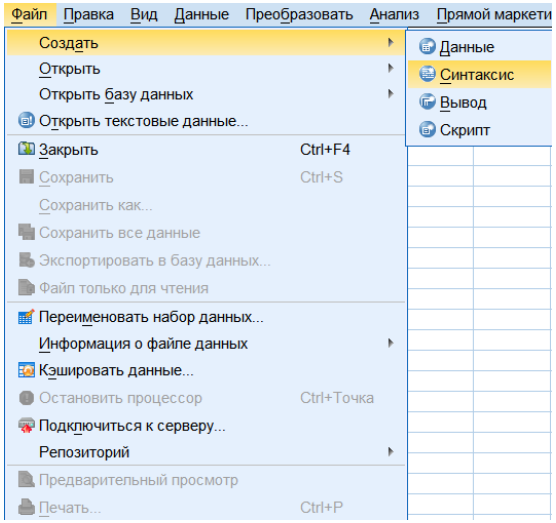

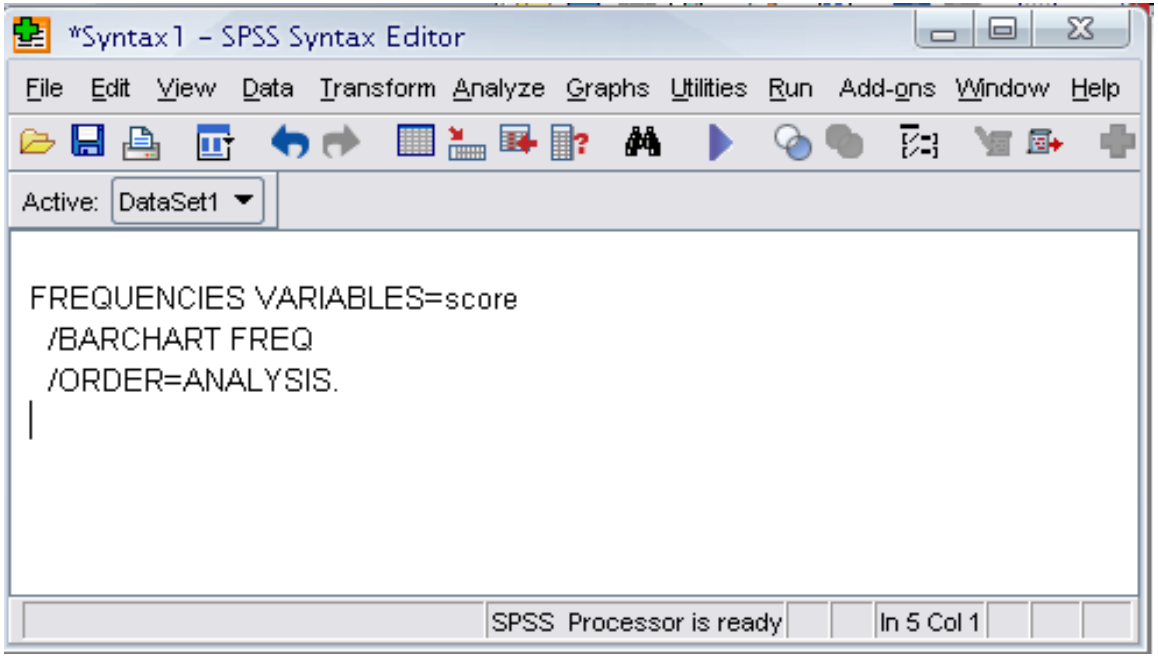

Расширение файла: *.sps

2.1. Запуск программы, интерфейс, принципы работы

3. ОКНО ВЫВОДА

В отличие, например, от Excel, результаты вычислений, анализа данных и их представление в визуальном виде производится **в отдельном окне**.

Окно отображает историю команд (слева), вывод результатов расчетов и возникающие ошибки расчетов (справа). Сохранение осуществляется в файл *.spv или *.spo

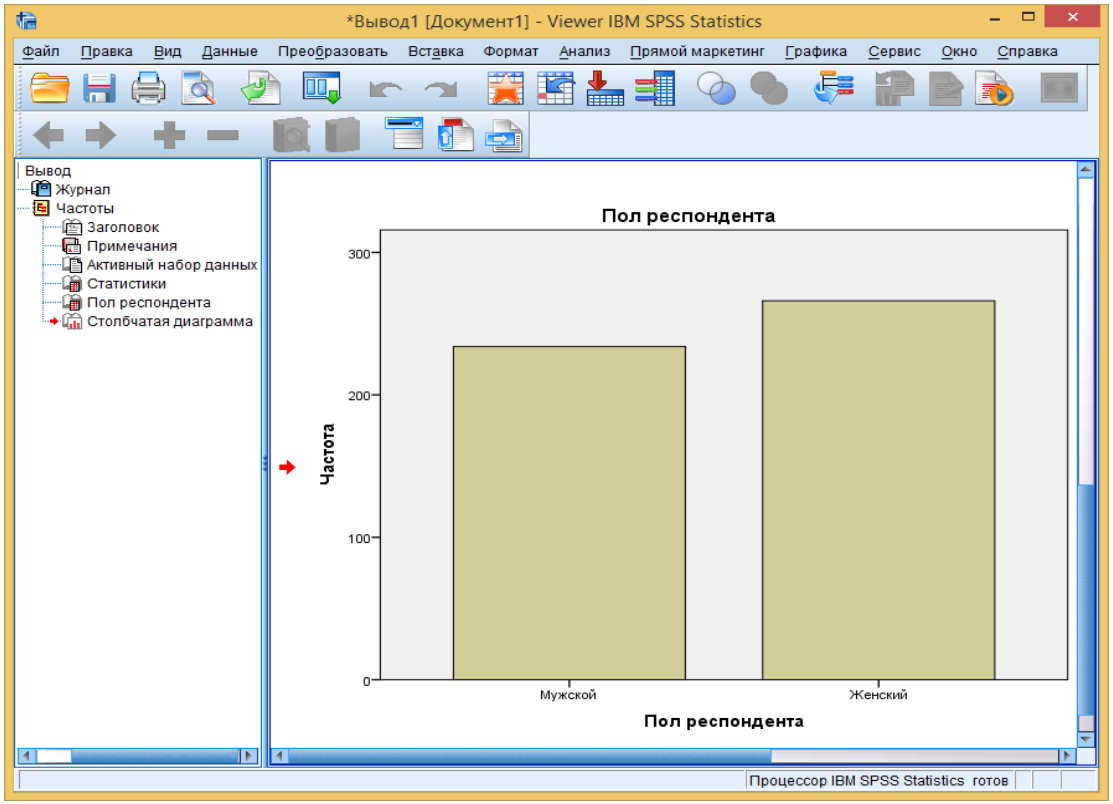

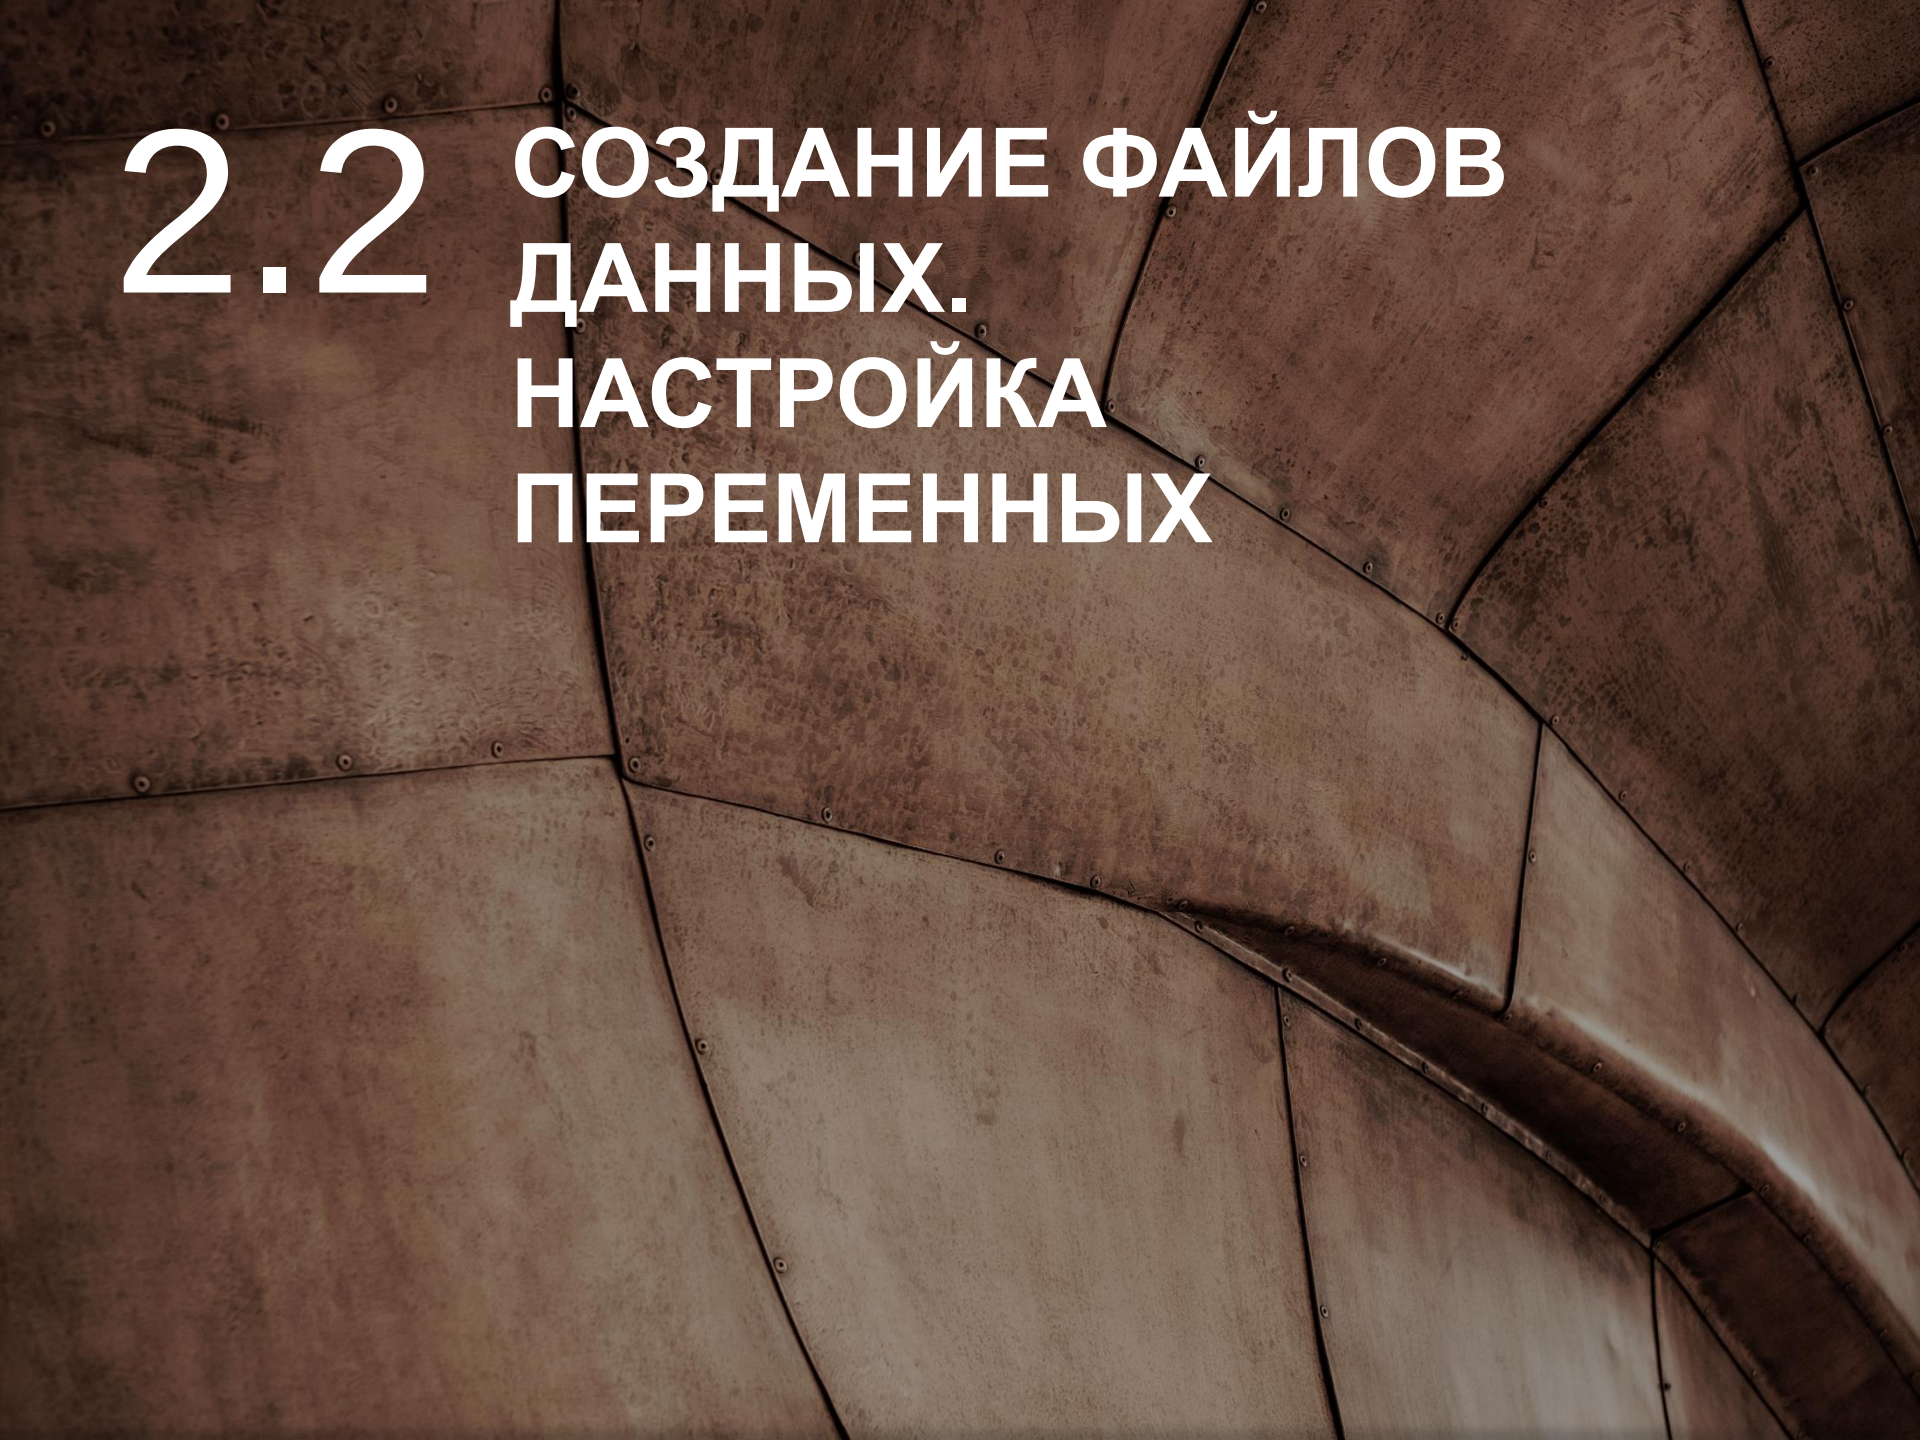

2.2 СОЗДАНИЕ ФАЙЛОВ ДАННЫХ. НАСТРОЙКА ПЕРЕМЕННЫХ

2.2. Создание файлов данных. Настройка переменных

3 ЭТАПА СОЗДАНИЯ БАЗЫ ДАННЫХ ДЛЯ АНАЛИЗА

До начала ввода данных в SPSS необходимо создать макет (структуру) переменных (на основе, например, анкеты).

В этом случае вопросы ложатся в основу переменных. У каждой переменной – свои настройки (имя, допустимые значения, тип шкалы и др.)

Структуру базы данных правильнее определить на этапе планирования исследования и разработки инструментария (например, анкеты) в соответствии с гипотезой и задачами исследования.

Шаг 1. Задание имён переменных

Шаг 2. Определение их параметров

Шаг 3. Ввод данных

2.2. Создание файлов данных. Настройка переменных

ПАРАМЕТРЫ ПЕРЕМЕННЫХ

Вкладка **Переменные** (**Variable view**) содержит информацию о параметрах переменных, в которые затем вводятся собранные данные.

1. Имя переменной (Name)

- Первый символ должен быть буквой
- Должно быть уникальным и не превышать 64 символов
- Пробелы недопустимы

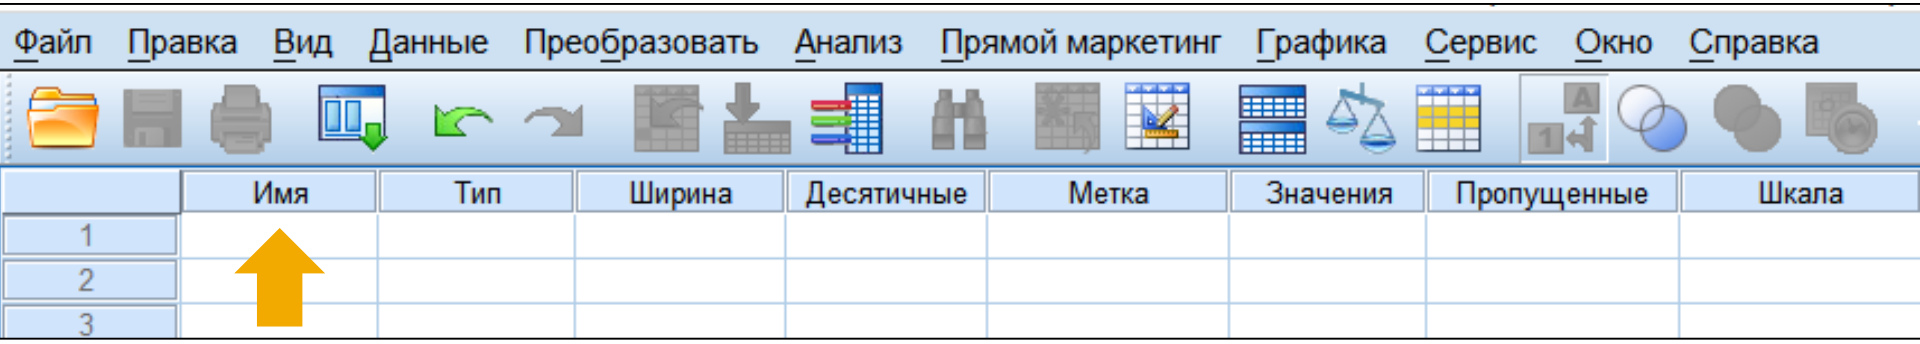

ПАРАМЕТРЫ ПЕРЕМЕННЫХ

2. Тип переменной (Type)

Наиболее часто используются два типа переменной:

1) **Числовая** – для всех вопросов, ответам которых присваиваются числовые значения (коды или числа)

2) **Текстовая** – для открытых вопросов без кодов ответов (для ввода текста)

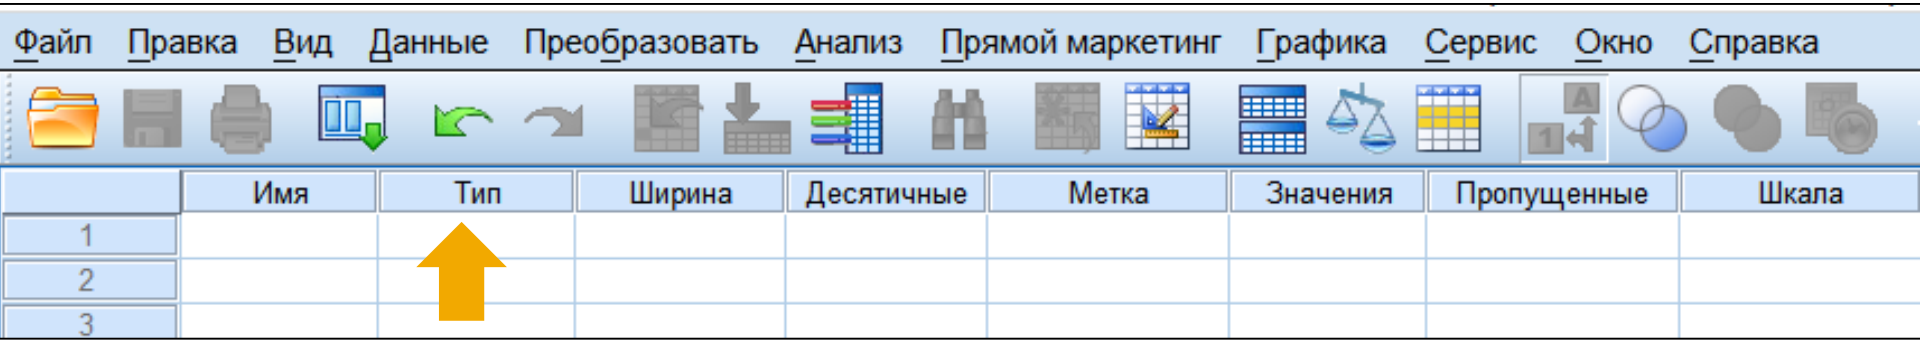

2.2. Создание файлов данных. Настройка переменных

ПАРАМЕТРЫ ПЕРЕМЕННЫХ

3. Ширина (Width)

Позволяет установить число знаков, которые можно ввести в значение настраиваемой переменной.

4. Десятичные (Decimals)

Позволяет установить число знаков, после запятой (не более 16) в вводимом значении переменной.

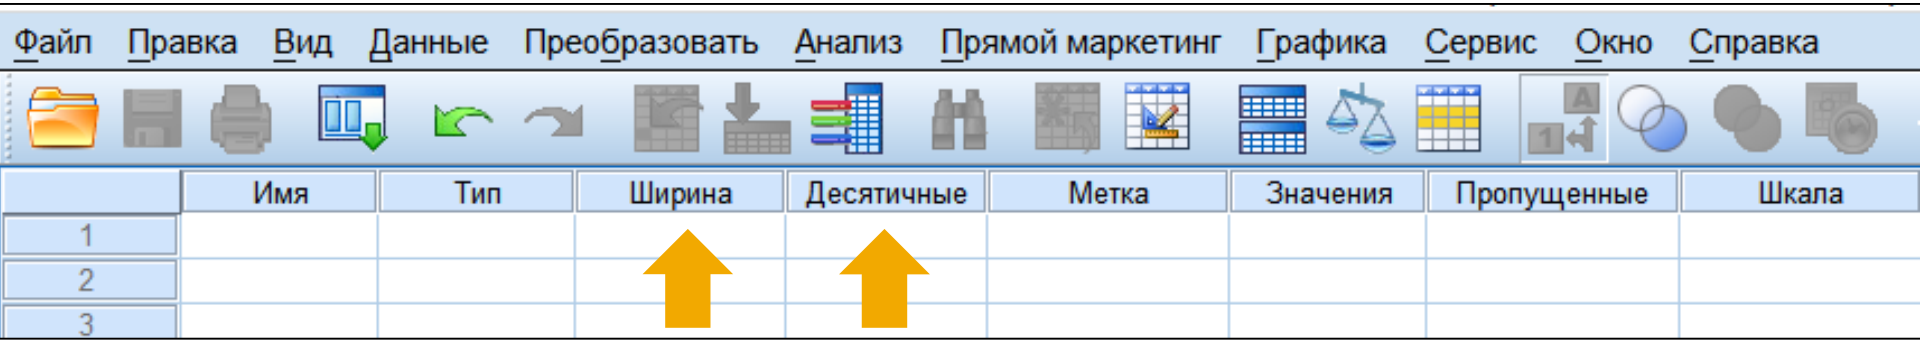

2.2. Создание файлов данных. Настройка переменных

ПАРАМЕТРЫ ПЕРЕМЕННЫХ

5. Метка (Labels)

Используется, когда смысл переменной недостаточно точно отражен в имени переменной. Это поле для ввода полного названия переменной (*обычно – номер и формулировка вопроса*). Максимальная длина - 256 знаков.

6. Значения (Values)

Вводятся коды и их значения
обычно – коды ответов на вопрос:
1 = «Да»
2 = «Нет»
99 = «Затрудняюсь ответить»

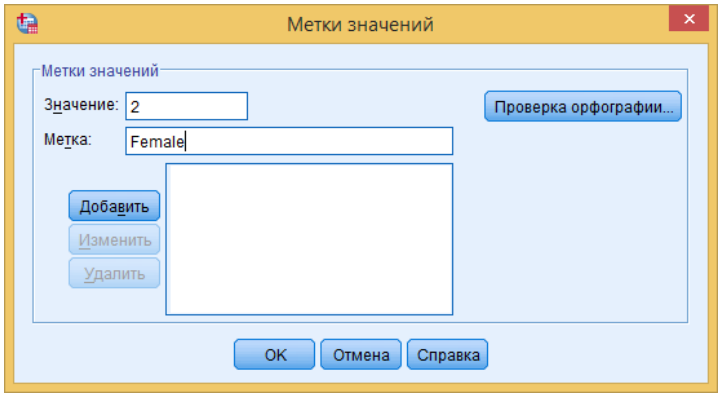

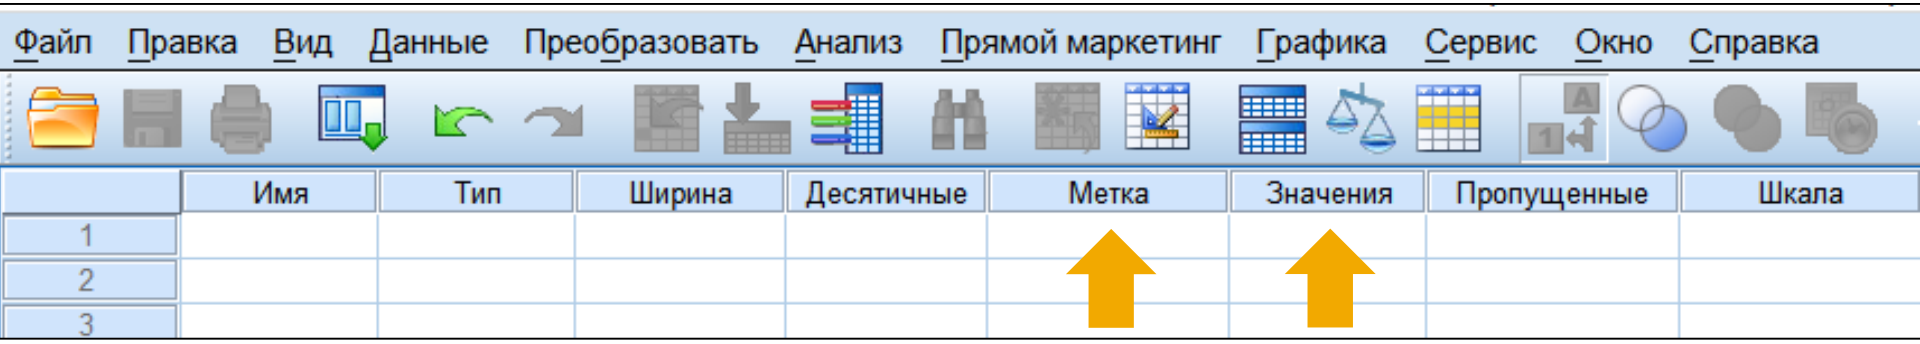

ПАРАМЕТРЫ ПЕРЕМЕННЫХ

7. Пропущенные (Missing)

Поле для ввода пропущенных значений; используется, если нужно исключить из расчета какие-либо значения (например, посчитать без «затруднившихся ответить», т.е. без кода 99).

8. Шкала (Scale)

Устанавливается тип шкалы измерения, в зависимости от данных, которые содержит переменная (номинальные, порядковые, метрические).

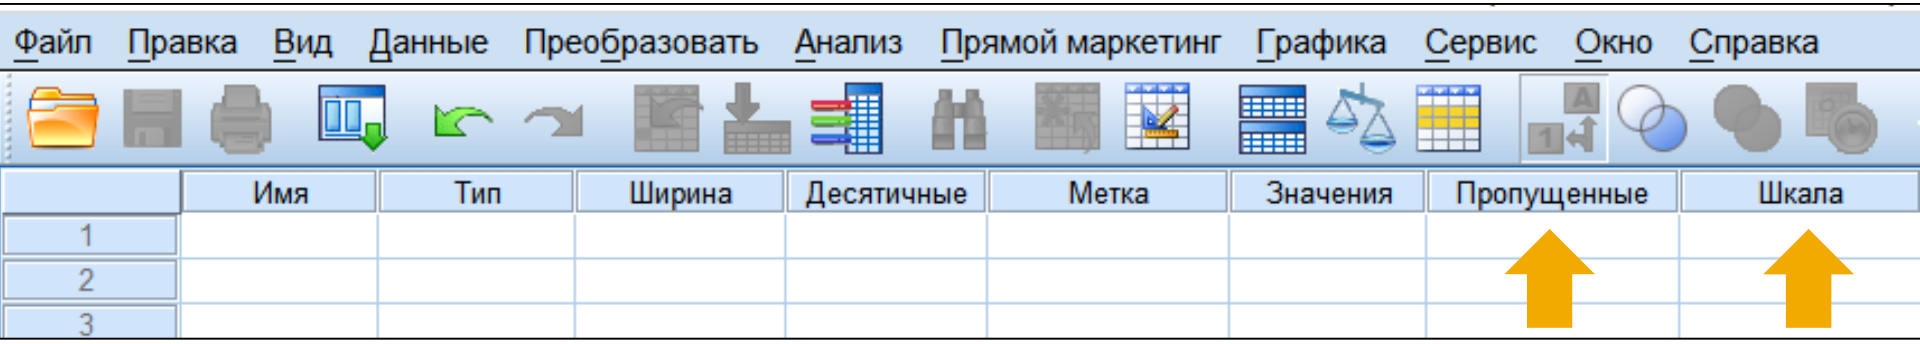

2.2. Создание файлов данных. Настройка переменных

ПАРАМЕТРЫ ПЕРЕМЕННЫХ

Перейдя на вкладку Данные после установки параметров переменных, их имена отобразятся в столбцах.

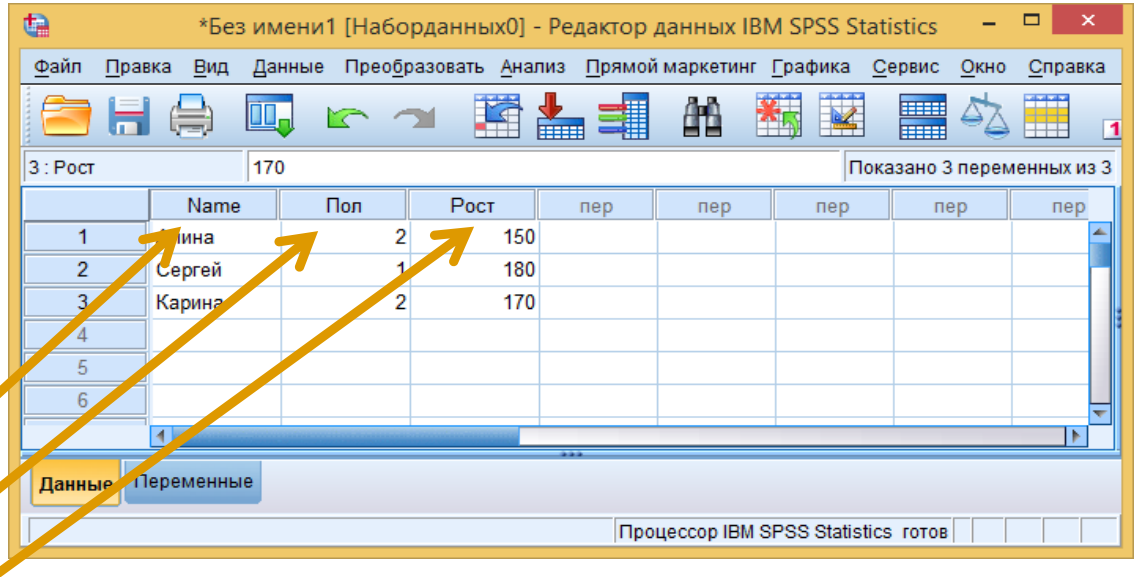

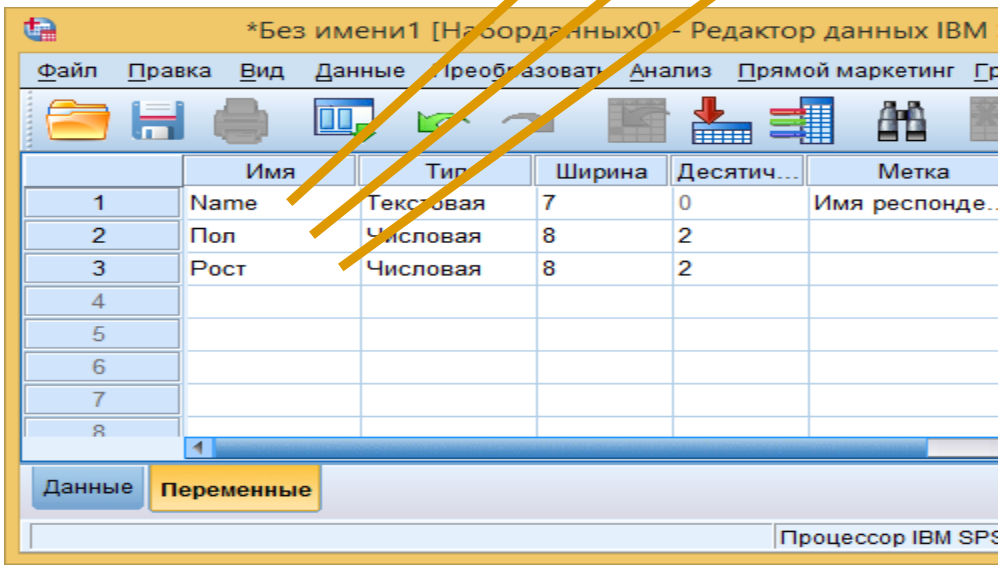

Ввод данных осуществляется **вручную** или **автоматически** (например, через сканер с распознаванием, через онлайн ввод).

2.2. Создание файлов данных. Настройка переменных

СОХРАНЕНИЕ ФАЙЛА ДАННЫХ

После завершения ввода данных и работы с массивом, рабочий файл с данными нужно сохранить.

Массив (базу данных) можно сохранить как в стандартном формате **SPSS (*.sav)**, так и в других форматах, в том числе Excel.

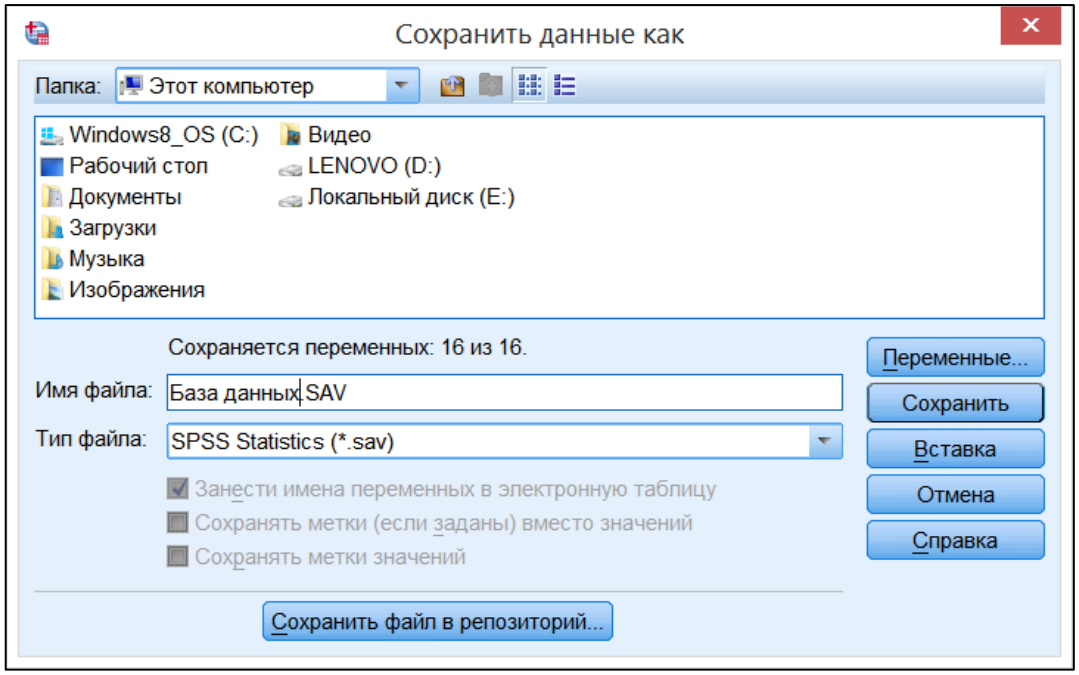

Литература по Теме 1

1) **Бююль А., Цеффель П. SPSS: искусство обработки информации. – М., 2005**
   - Глава 3. Подготовка данных
   - Глава 5. Основы статистики
   - Глава 6. Частотный анализ
2) **Наследов А. IBM SPSS Statistics 20 и AMOS: профессиональный статистический анализ данных. – СПб., 2013**
   - Глава 3. Создание и редактирование файлов данных
3) **Измерение в социологии: учеб. пособие / А.П. Кулаков; Новосиб. гос. архитектур.-строит. ун-т. – Новосибирск : НГАСУ (Сибстрин), 2005**
   - Параграфы 1 - 7

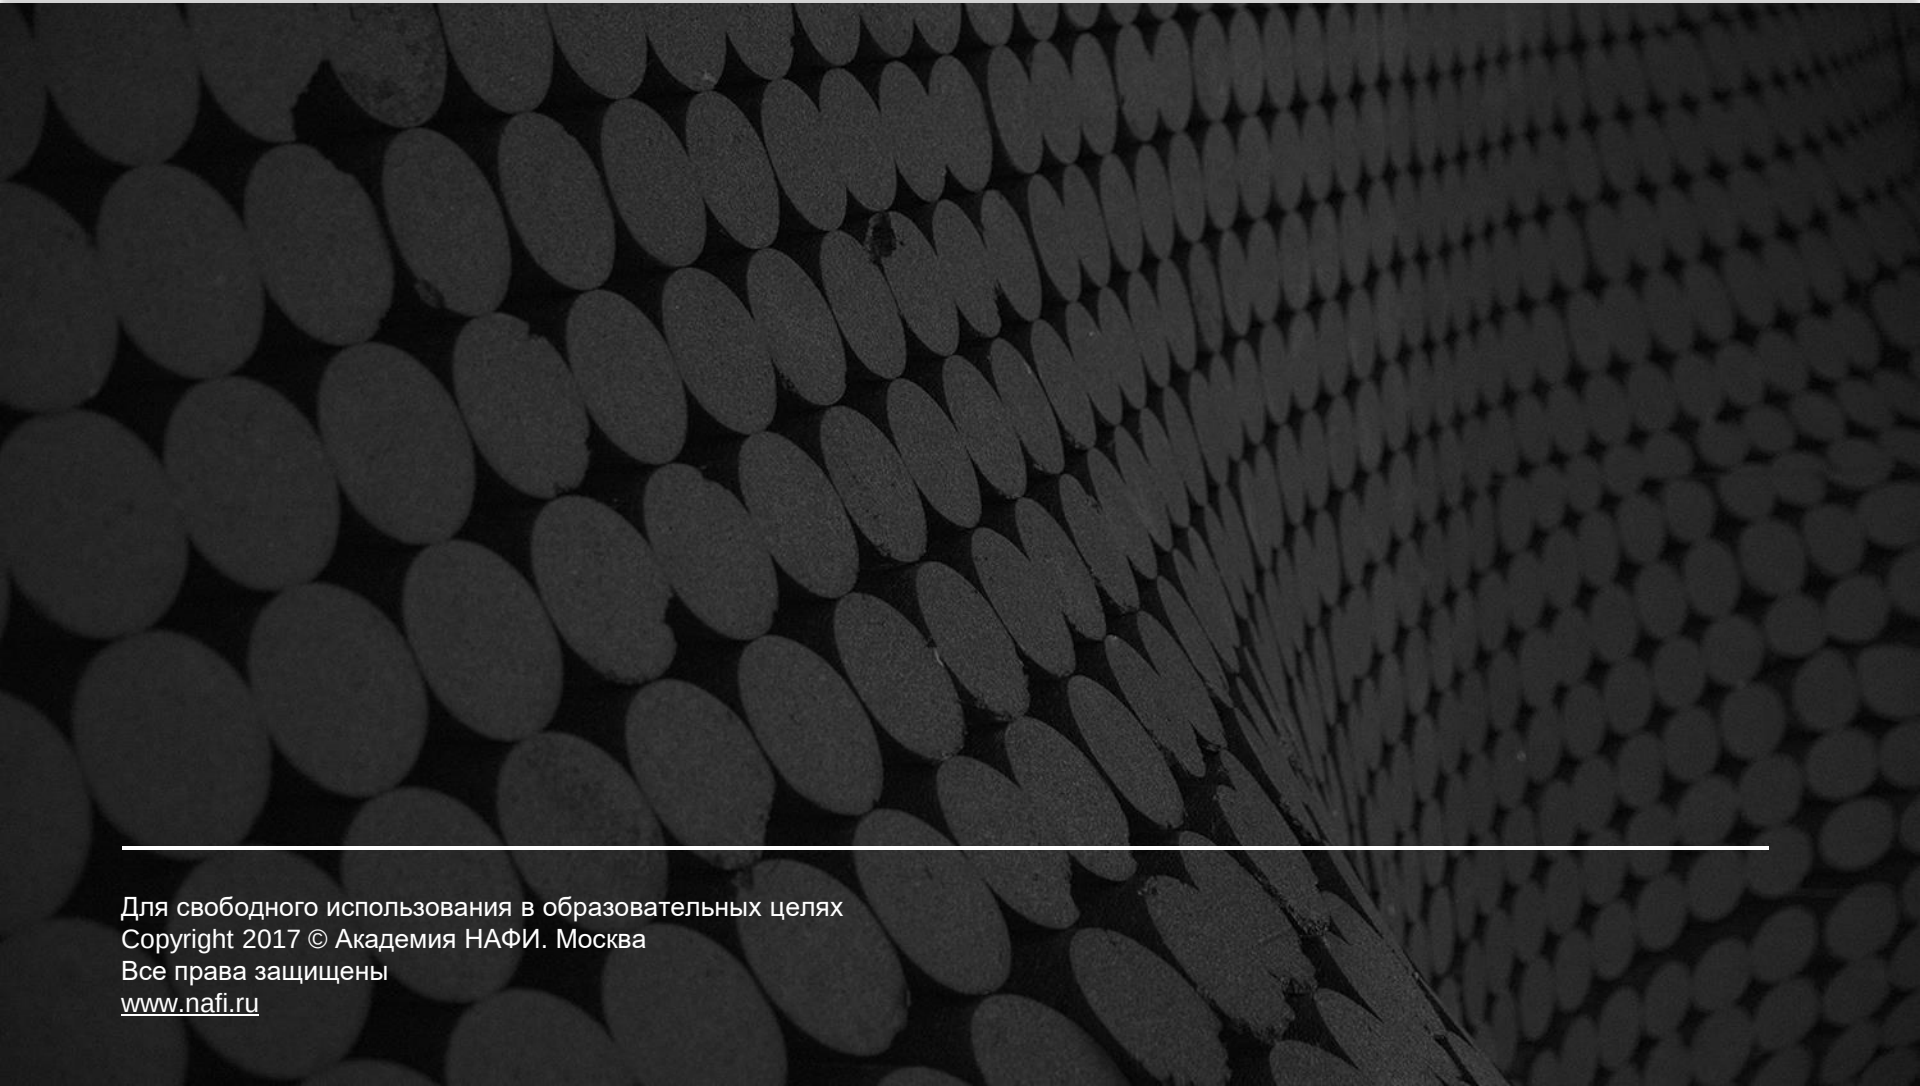

Для свободного использования в образовательных целях
Copyright 2017 © Академия НАФИ. Москва
Все права защищены
www.nafi.ru