

# **Методы автоматизации сбора и обработки статистических данных**

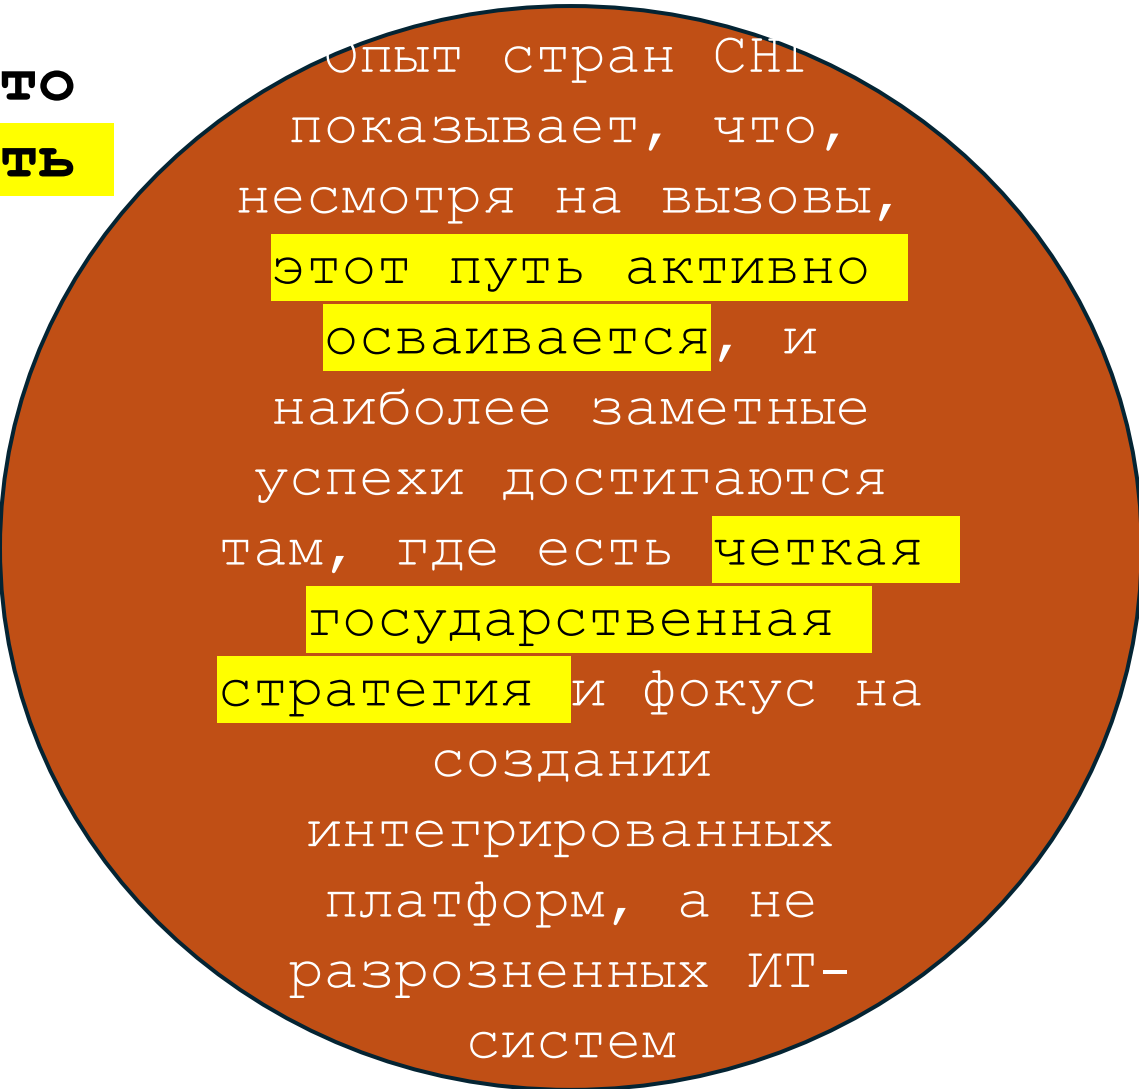
## Лекции 2 и 3

Зарова Елена Викторовна, доктор  
экономических наук. профессор


# План лекции

- **Использование цифровых платформ, облачных решений и ИИ для автоматизации сбора и обработки данных (лекция 3)**
- Практические примеры: автоматизация переписей, обработка административных данных
- Теоретические основы: обработка больших данных, обезличивание и защита информации

Использование цифровых платформ,  
облачных решений и ИИ для  
автоматизации сбора данных – это  
не просто тренд, а необходимость  
для повышения эффективности  
государственного управления и  
конкурентоспособности бизнеса



Опыт стран СНГ  
показывает, что,  
несмотря на вызовы,  
этот путь активно  
осваивается, и  
наиболее заметные  
успехи достигаются  
там, где есть четкая  
государственная  
стратегия и фокус на  
создании  
интегрированных  
платформ, а не  
разрозненных ИТ-  
систем



# Применение МО и ИИ на этапах Типовой модели производства статистической информации

Уровни 1 и 2: принципы, задачи, опыт официальной статистики стран СНГ

# Введение: Значение МО и ИИ в современной официальной статистике

## Рост рынка ИИ

Рынок искусственного интеллекта в России достигнет 300 млрд рублей в 2024 году, становясь мощным драйвером цифровой трансформации экономики

## Повышение качества

МО и ИИ позволяют существенно повысить качество, скорость обработки и точность статистических данных

## Инновации СНГ

Страны СНГ активно внедряют передовые технологии в национальных статистических службах





# Типовая модель производства статистической информации

Уровни 1 и 2



## Первый уровень

Сбор и первичная обработка данных — ключевая база для всей статистической системы, требующая особого внимания к качеству



## Второй уровень

Интеграция, верификация и подготовка агрегированных данных для последующего анализа



## Роль технологий

МО и ИИ автоматизируют рутинные операции, выявляют аномалии и улучшают качество данных на всех этапах




# Управление качеством/управление метаданными

Спецификация потребностей	Проектирование	Построение	Сбор	Обработка	Анализ	Распространение	Оценка
1.1 Определение потребностей	2.1 Проектирование выходных материалов	3.1 Построение механизма сбора данных	4.1 Формирование генеральной совокупности и выборки	5.1 Интеграция данных	6.1 Подготовка предварительных материалов	7.1 Обновление систем производства материалов	8.1 Сбор информации для оценки
1.2 Проведение консультаций и подтверждение потребностей	2.2 Проектирование описаний переменных	3.2 Построение или укрепление компонентов процесса	4.2 Организация сбора	5.2 Классификация и кодирование	6.2 Валидация материалов	7.2 Производство продуктов для распространения	8.2 Проведение оценки
1.3 Установление формирования материалов целей	2.3 Проектирование сбора данных	3.3 Построение или укрепление компонентов распространения	4.3 Проведение сбора	5.3 Проверка и валидация	6.3 Толкование и пояснение материалов	7.3 Управление опубликованием продуктов для распространения	8.3 Согласование плана действий
1.4 Определение концепций	2.4 Проектирование генеральной совокупности и выборки	3.4 Компоновка производственных процессов	4.4 Завершение сбора	5.4 Редактирование и импутация	6.4 Применение мер противодействия идентификации	7.4 Реклама продуктов для распространения	
1.5 Проверка наличия данных	2.5 Проектирование обработки и анализа	3.5 Тестирование системы производства		5.5 Формирование новых производных переменных и статистических единиц	6.5 Завершение формирования материалов	7.5 Управление поддержкой пользователей	
1.6 Подготовка бизнес-модели	2.6 Проектирование производственных систем и процесса	3.6 Тестирование статистического бизнес-процесса		5.6 Расчет весов			
		3.7 Ввод в строй системы производства		5.7 Расчет агрегатов			

**ТМПСИ: первый и второй уровни**

# ИИ и МО в стратегиях развития государственной статистики стран СНГ


Страна	Наличие и ссылка на стратегию	Год утверждения	Упоминание ИИ/МО в стратегии
Азербайджан	Да. <a href="#">Государственная программа по развитию статистики в Азербайджанской Республике на 2018-2025 годы</a>	2018	Косвенное указание. Упоминается развитие IT-инфраструктуры и использование "альтернативных источников данных", но прямого указания на ИИ/МО нет.
Армения	Да. <a href="#">Стратегическая программа развития статистики Армении на 2022-2026 гг.</a>	2022	Прямое указание. Содержит задачу "исследовать и внедрять передовые технологии,  ле как искусственный интеллект и машинное обучение, для

Сообщение для DeepSeek

Требуе**т** проверки

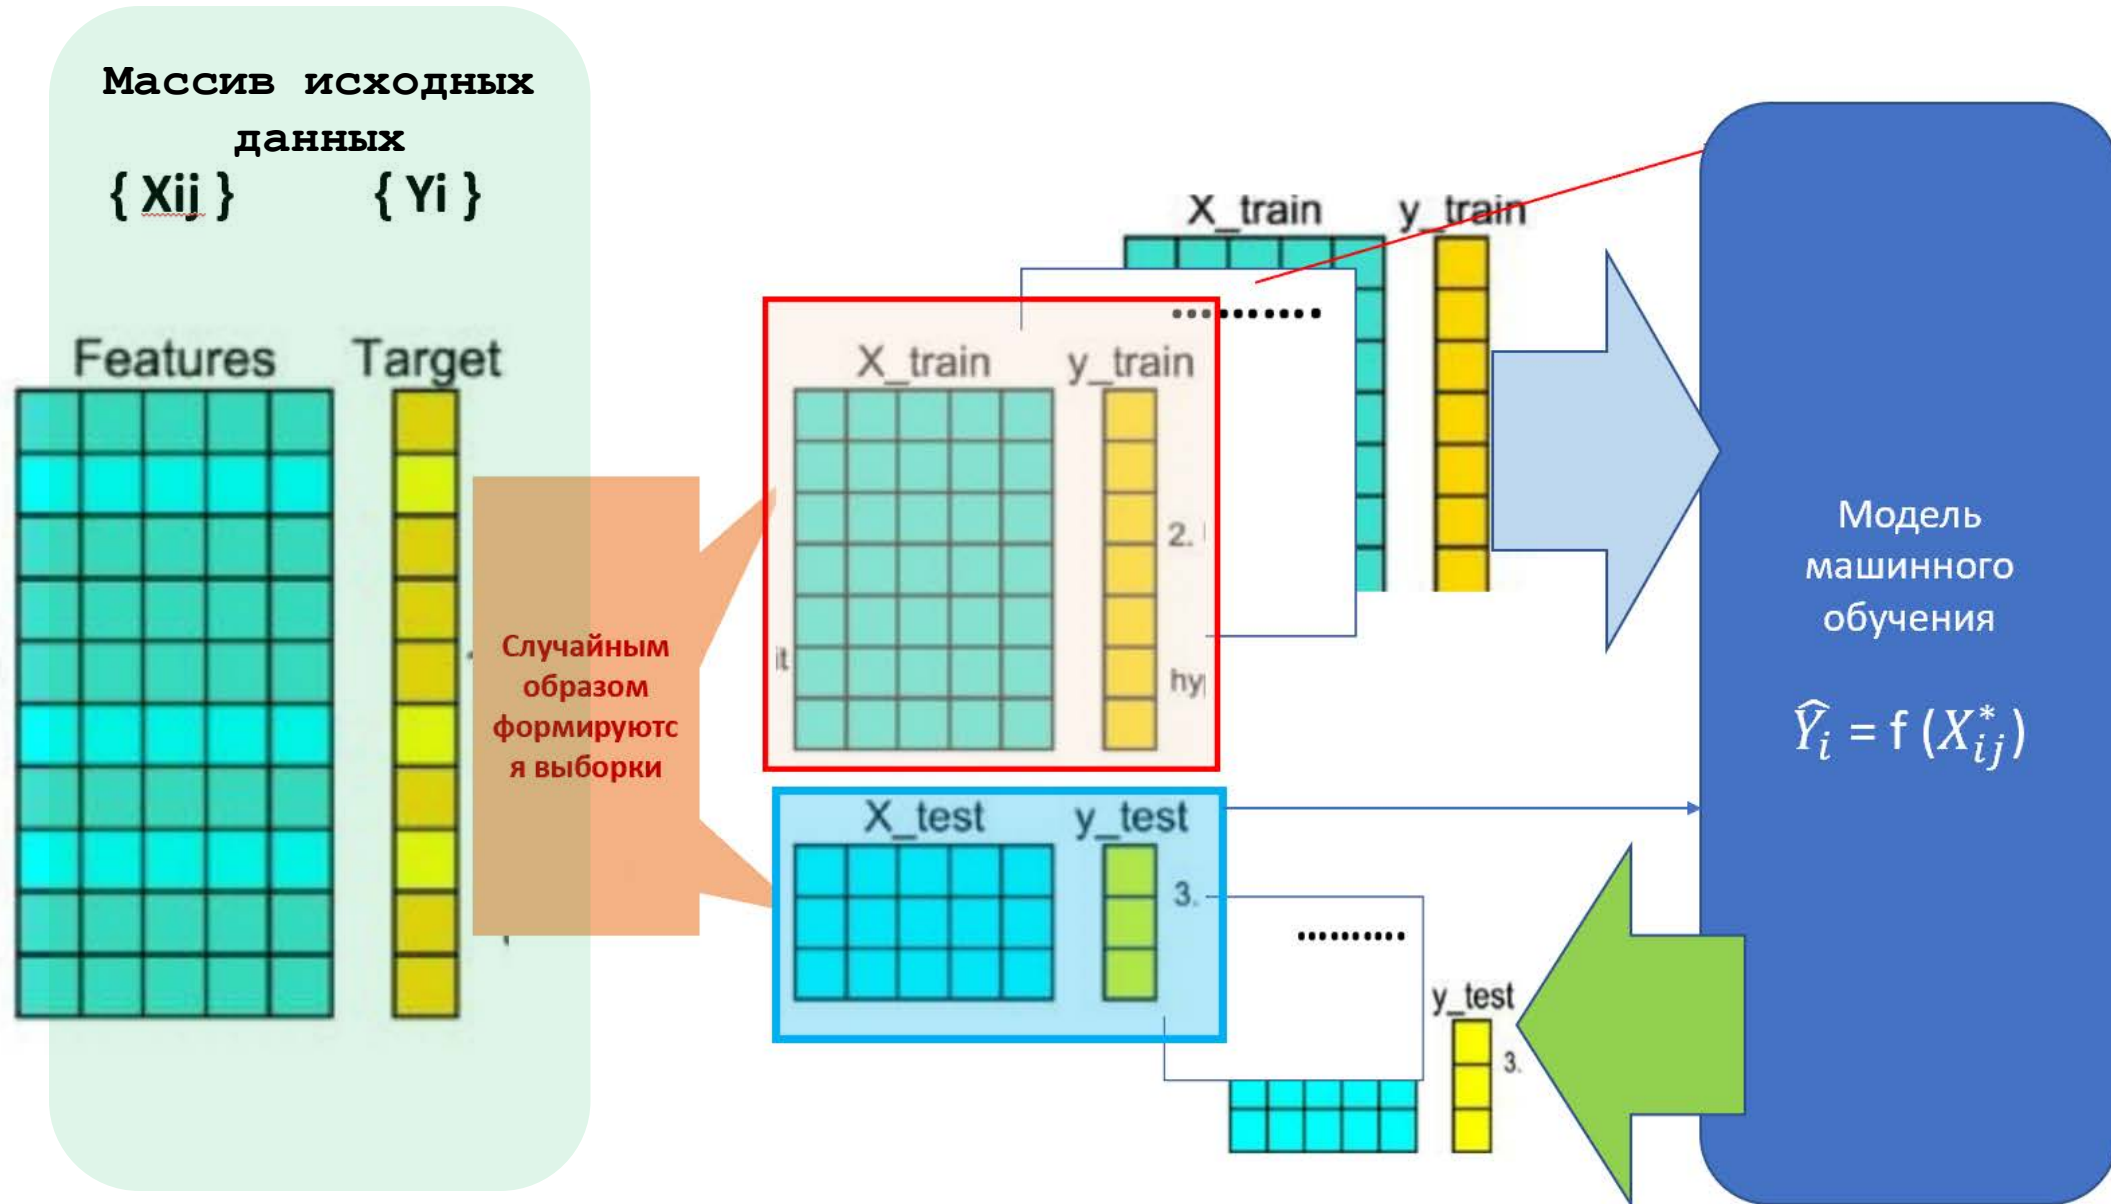
данных и




Беларусь	Да. Концепция развития государственной статистики до 2027 года	2020	Косвенное указание. Упоминается "анализ больших данных" и "совершенствование ИТ-инфраструктуры", но прямого указания на ИИ/МО нет.
Казахстан	Да. Концепция развития государственной статистики до 2026 года	2021	Прямое указание. Планируется "внедрение методов больших данных, машинного обучения и искусственного интеллекта для повышения оперативности, точности и эффективности статистических процессов".
Кыргызстан	Да. Стратегия развития государственной статистики Кыргызской Республики на 2019-2030 годы	2019	Прямое указание. Запланировано "использование методов интеллектуального анализа данных, машинного обучения и искусственного интеллекта для обработки больших ма  ов информации".

Молдова	Да. Стратегия развития национальной статистической системы на 2021-2025 годы	2021	"внедрении новых технологий, таких как искусственный интеллект и машинное обучение, для анализа больших данных и повышения эффективности производства статистики".
Россия	Да. Концепция развития государственной статистики на период до 2024 года и дальнейшую перспективу до 2030 года	2021	Прямое указание. Включено "использование методов машинного обучения и искусственного интеллекта для анализа данных, в том числе больших данных, и автоматизации процессов".
Узбекистан	Да. Стратегия развития государственной статистики на 2020-2025 годы	2020	Прямое указание. Включено "внедрение передовых методов, включая машинное обучение и искусственный интеллект, для анализа больших данных и повышения качества статистической информации".


# Идея метода машинного обучения



## “Data-information-knowledge pyramid”



“a”



“b”

*(proposed by the author)*

\* Conventional statistics (CS)

# Семинар по ИИ в официальной статистике

## AI for official statistics: opportunities and challenges

17 October 2025  
from 11:00 to 11:45 CEST

Join the Eurostat webinar

Slido code #2726 508

#AskEurostat

eurostat 



<https://unstats.un.org/bigdata>



# DM в руководствах EUROSTAT



Методы интеллектуального анализа данных (социальные нейронные сети, кластерный анализ, анализ выбора модели и взвешенный сетевой корреляционный анализ, чтобы установить связь между характеристиками рынка труда ЕС и индикаторами рынка труда.

Figure 1: Country social network using Labour Market Attractiveness set




Figure 2: Cluster analysis using Labour Market Attractiveness set. Average silhouette width for all possible number of clusters (left). Silhouette width of regions considered for 10 clusters (right)




Table 3: Description of clusters

cluster	NUTS <sup>(*)</sup>	n	sep
AT-BE-CY-MT	MT, CY, BE, AT	4	2.66
BG-HU-LV-RO	BG, RO, LV, HU	4	2.49
CZ-SK-SI	CZ, SK, SI	3	2.31
DE-FR-UK	DE, UK, FR	3	3.19
DK-FI-NL-SE	DK, SE, FI, NL	4	2.66
EE-LT-PL-PT	EE, LT, PT, PL	4	2.31
EL-HR	EL, HR	2	3.53
ES-IT	ES, IT	2	3.10
IE	IE	1	3.75
LU	LU	1	4.68

(\*) Order of countries reflects belongingness to cluster (i.e. silhouette width).



## Многофакторные регрессионные модели

**Table 5:** Summary Table for best multivariate model for Skills Mismatch

Variables	Estimate	Std. Error	t-value	Pr(> t-value )
(Intercept)	100.60	8.694	11.570	<0.001
emp_Y15-24	-3.18	0.356	-8.920	<0.001
emp_Y15-24_NaceM-N	6.56	1.000	6.560	0.001

skills\_mismatch ~ emp\_Y15-24 + emp\_Y15-25\_NaceM-N

RSS = 5.51 (5 d.f.)

$R^2 = 0.94$ ,  $R^2$ -adjusted = 0.92

$F(2,5) = 43.76$  (p-value < 0.001)

Note: 20 data entries and 34 variables were removed to keep only complete-cases; 10 variables highly correlated among them ( $\rho > 0.90$ ) and 2 variables least correlated with dependent variable ( $\rho < 0.06$ ) were removed to run analysis at the most with 30 variables.

**Table 6:** Summary Table for best multivariate model for Mobility

Variables	Estimate	Std. Error	t-value	Pr(> t-value )
(Intercept)	1.82	6.196	0.290	0.772
emp_Y25-64_NaceK	4.61	0.711	6.470	<0.001
emp_Y25-64_NaceL	10.04	2.892	3.470	0.002
emp_Y15-24_NaceB-E	-0.38	0.198	-1.930	0.067

mobility ~ emp\_Y25-64\_NaceK + emp\_Y25-64\_NaceL + emp\_Y15-24\_NaceB-E

RSS = 7.10 (21 d.f.)

$R^2 = 0.79$ ,  $R^2$ -adjusted = 0.76

$F(3,21) = 25.85$  (p-value < 0.001)

Note: 3 data entries and 34 variables were removed to keep only complete-cases; 1 variables highly correlated among them ( $\rho > 0.90$ ) and 11 variables least correlated with dependent variable ( $\rho < 0.15$ ) were removed to run analysis at the most with 30 variables.

**Table 7:** Summary Table for best multivariate model for Emigration

Variables	Estimate	Std. Error	t-value	Pr(> t-value )
(Intercept)	0.52	0.276	1.900	0.071
emp_Y25-64_NaceK	0.18	0.031	5.790	<0.001
emp_Y15-24_ED5-8	0.03	0.006	4.420	<0.001
emp_Y15-24_NaceO-Q	-0.03	0.011	-2.880	0.009
pop_Total	0.00	0.000	-2.500	0.020
emp_Y15-24_NaceB-E	-0.01	0.008	-1.870	0.075

## Регрессия на главных компонентах

**Table 8:** Eigenvariables of Labour Market Attractiveness set

Eigenvariables	n	mean MM	Variables (>0.75 MM)
Unemployment	3	0.83	+: emp_Y[15-24]_Nace[G-I]; unemp_Y[15-24, GE25]. -: none.
Poverty	2	0.95	+: ARPR; AROPE. -: none.
Ageing Population	2	0.86	+: pop_Y[GE75]. -: pop_Y[15-24].
Education (Employed Adults)	4	0.71	+: emp_Y[25-64]_ED[3-4]. -: emp_Y[25-64]_ED[0-2]
Employment	4	0.80	+: emp_Y[15-24, 25-64] -: none.
Earnings	51	0.76	+: earn_OC[1-5, 7-9]_Nace[B-F]; earn_OC[1-5, 7-9]_Nace[G-N]; earn_OC[1-5, 9]_Nace[P-S]; emp_T[P]; emp_Y[25-64]_Nace[M_N, O-Q]; GDP; rooms_pp; training; -: mat_depriv.

n, number of variables grouped in Eigenvariable; MM, module membership calculated as the correlation to belonging Eigenvariable.


Note: 8 variables with more than 15% of missing data were removed. 2 variables did not group into any Eigenvariable.

**Table 9:** Correlation between labour market indicators and Eigenvariables

Eigenvariables	Skills Mismatch	Mobility	Emigration
Unemployed	0.36 (0.385)	-	-
Poverty	0.38 (0.352)	-	-
Ageing Population	-	-	-0.36 (0.063)
Education (Employed Adults)	-0.38 (0.352)	-	-0.50 (0.007)
Employed	-0.69 (0.058)	0.35 (0.082)	-
Earnings	-	0.59 (0.002)	-

(-) correlations between -0.30 and 0.30.

Note: Correlations calculated using Spearman correlation (p-values between brackets).



# Statistical matching and hot deck variants applied

Объединение данных двух источников (статистики миграции и статистики благосостояния) STATMATCH

Table 2: Scheme of the experiment

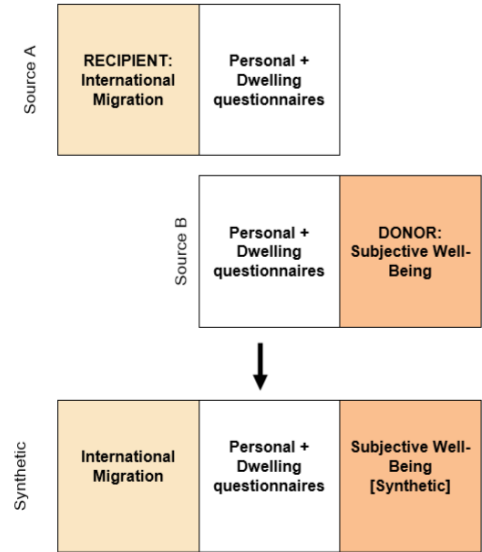
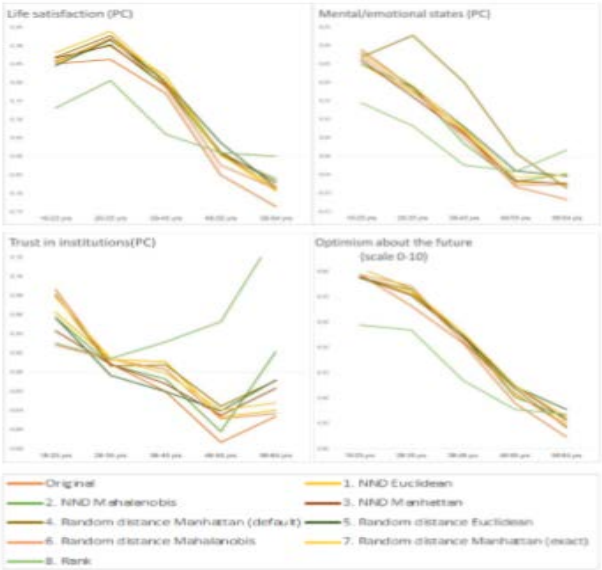


Table 3: Variants of hot deck methods, matching variables and donation classes used in the experiment

	Nearest neighbour distance hot deck			Random distance hot deck				Rank hot deck
	Method 1	Method 2	Method 3	Method 4	Method 5	Method 6	Method 7	Method 8
Distance Method	Euclidean	Mahalanobis	Manhattan	Default	Euclidean *	Mahalanobis*	Manhattan *	**
Constraint	Unconstrained							
Matching variables	Age, partner, underage child, type of settlement							Age
Class variables (donation classes)	Sex, Education							
Donor variables	Satisfaction (PC), Mental / emotional state (PC), Trust in institutions (PC), Optimism about the future							

Figure 1: Mean values of the original and the synthetic donor variables by age groups



## Filtering techniques for big data and big data based uncertainty indexes

GEORGE KAPETANIOS,  
MASSIMILIANO MARCELLINO, FOTIS PAPAILIAS

2017 edition




STATISTICAL  
WORKING PAPERS

eurostat 

## R packages

- "highfrequency" for intraday data,
- "ggmap" to plot the position of user 100 in the Sensor data analysis on Google maps,
- "gtrendsR" to download Google Trends series in R,
- "twitterR" to download Twitter series in R,
- "lubridate" to manipulate dates,
- "apcluster" for APC,
- functions from "clusterv" package,
- "rCUR" for CUR.

Figure 8: Decomposing the daily aggregated time series using STL




Source: Based on author's calculations



Figure 34: Reuters News Uncertainty Indexes for four countries



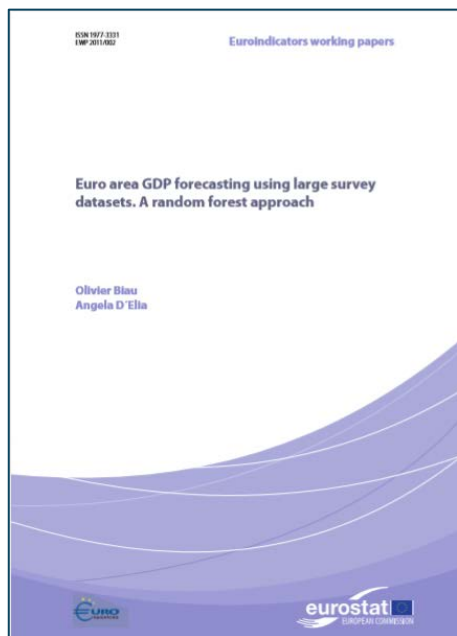
Electronic payments data .  
Mobile phone usage data .  
Sensor data .....  
Satellite images data .....  
Price data .....  
Textual data .....



TEXT MINING







## Выявление структурных «паттернов» и моделирование зависимостей с использованием технологий “random forest”




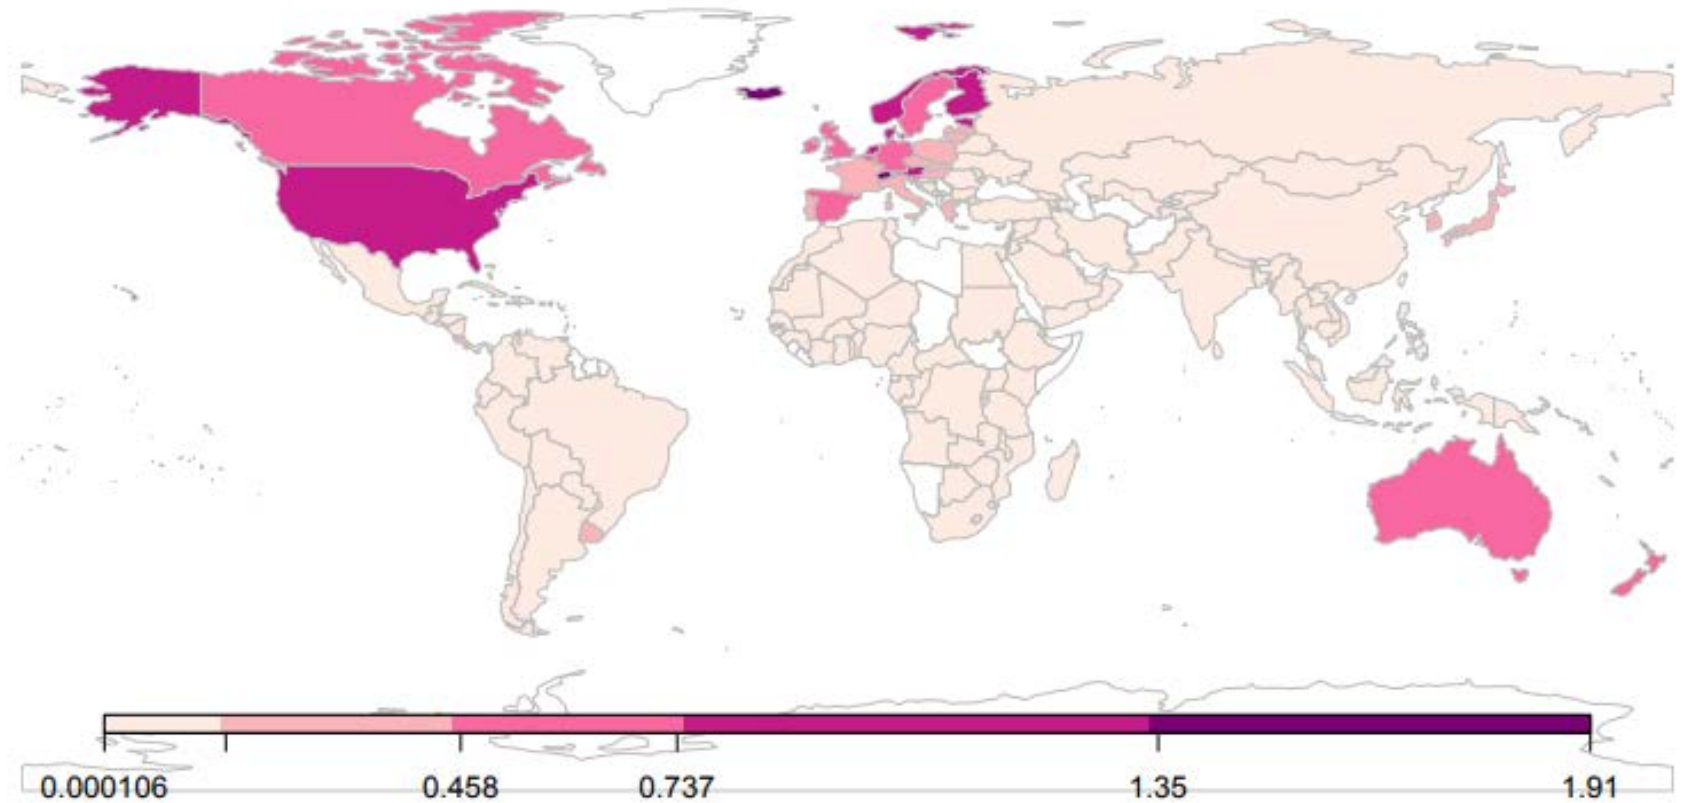



Figure I.12: Overview of relevant export and import transactions of a foreign affiliate for outward FATS



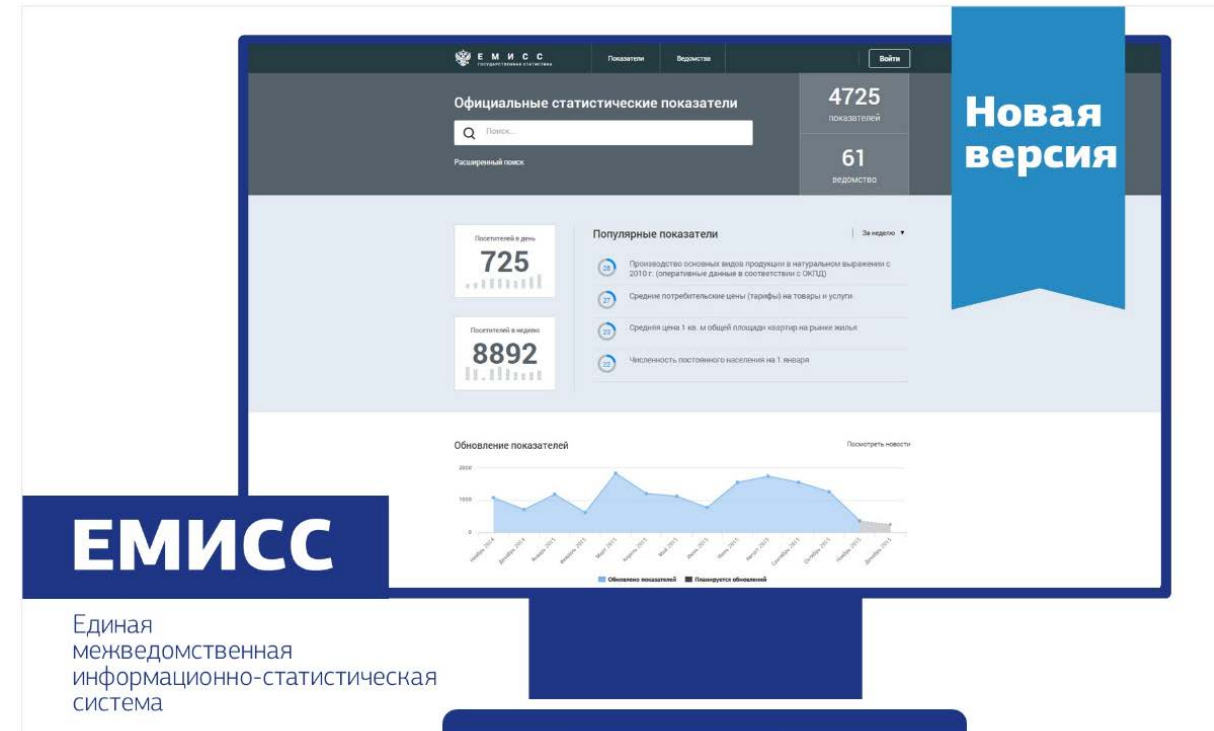

## Использование пакетов R в официальной статистике



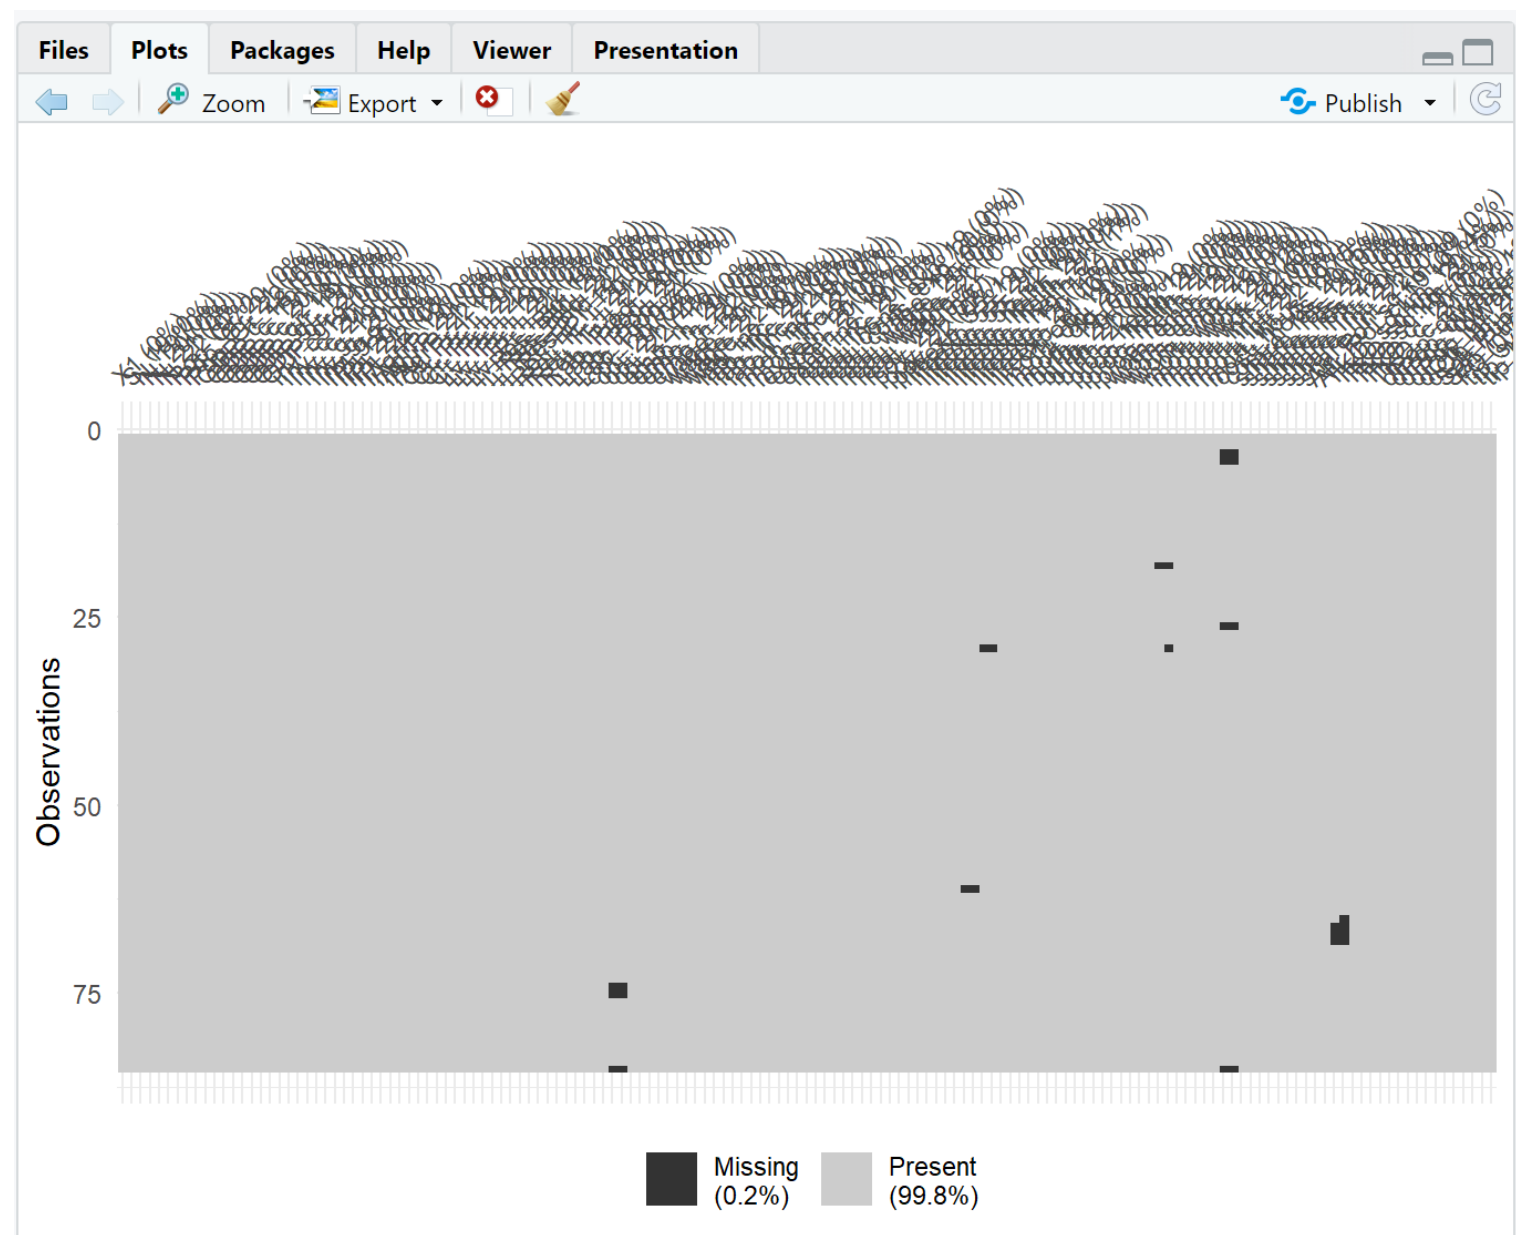
Загрузки пакетов R, включенных в представление задач CRAN **по официальной статистике** и методологии опросов по всему миру. Количество загрузок представлено на душу населения (то есть нормализовано путем деления на количество населения)

<https://www.researchgate.net/publication/297656682> The Software Environment R for Official Statistics and Survey Methodology

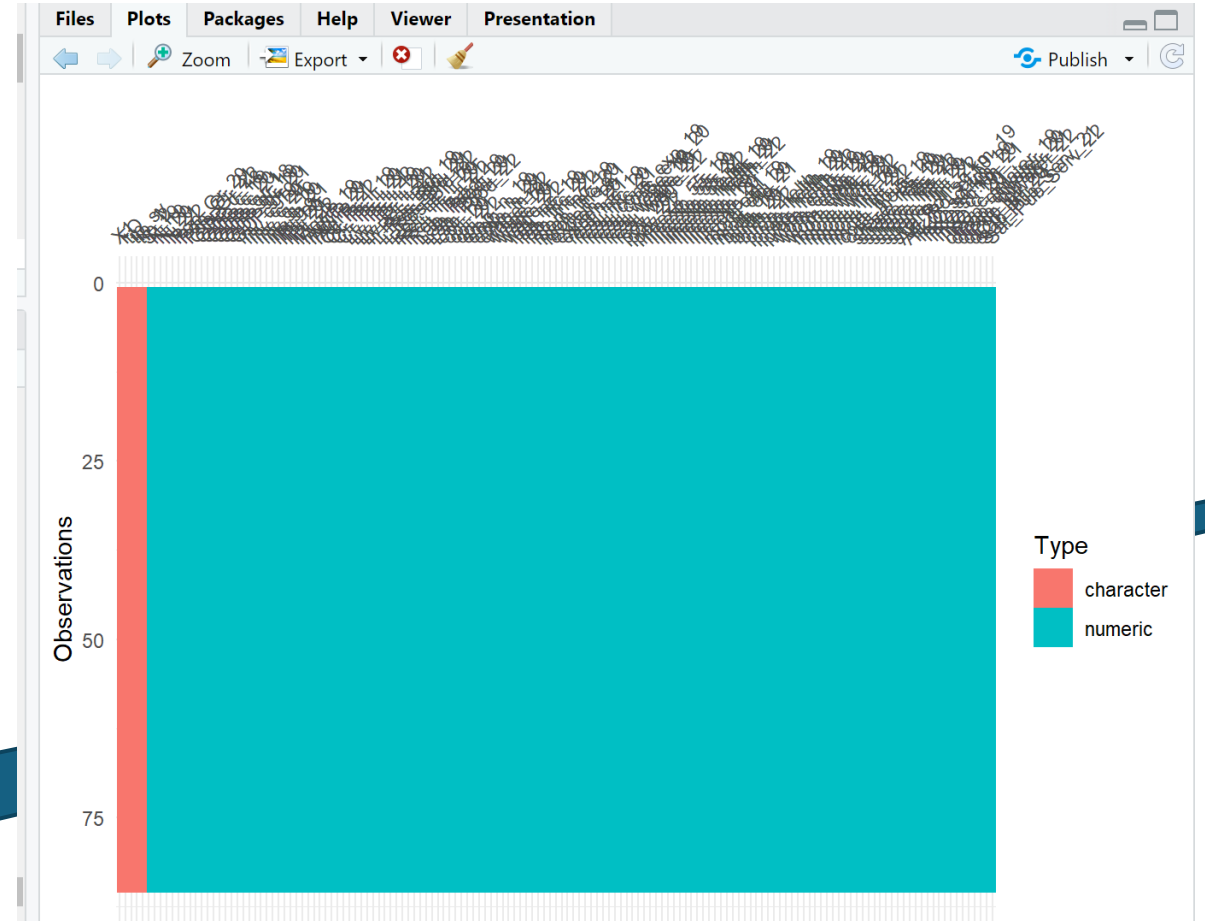
# ПРИМЕР (1) на данных ЕМИСС. Региональные данные ЕМИСС -148 показателей, 2022 г.




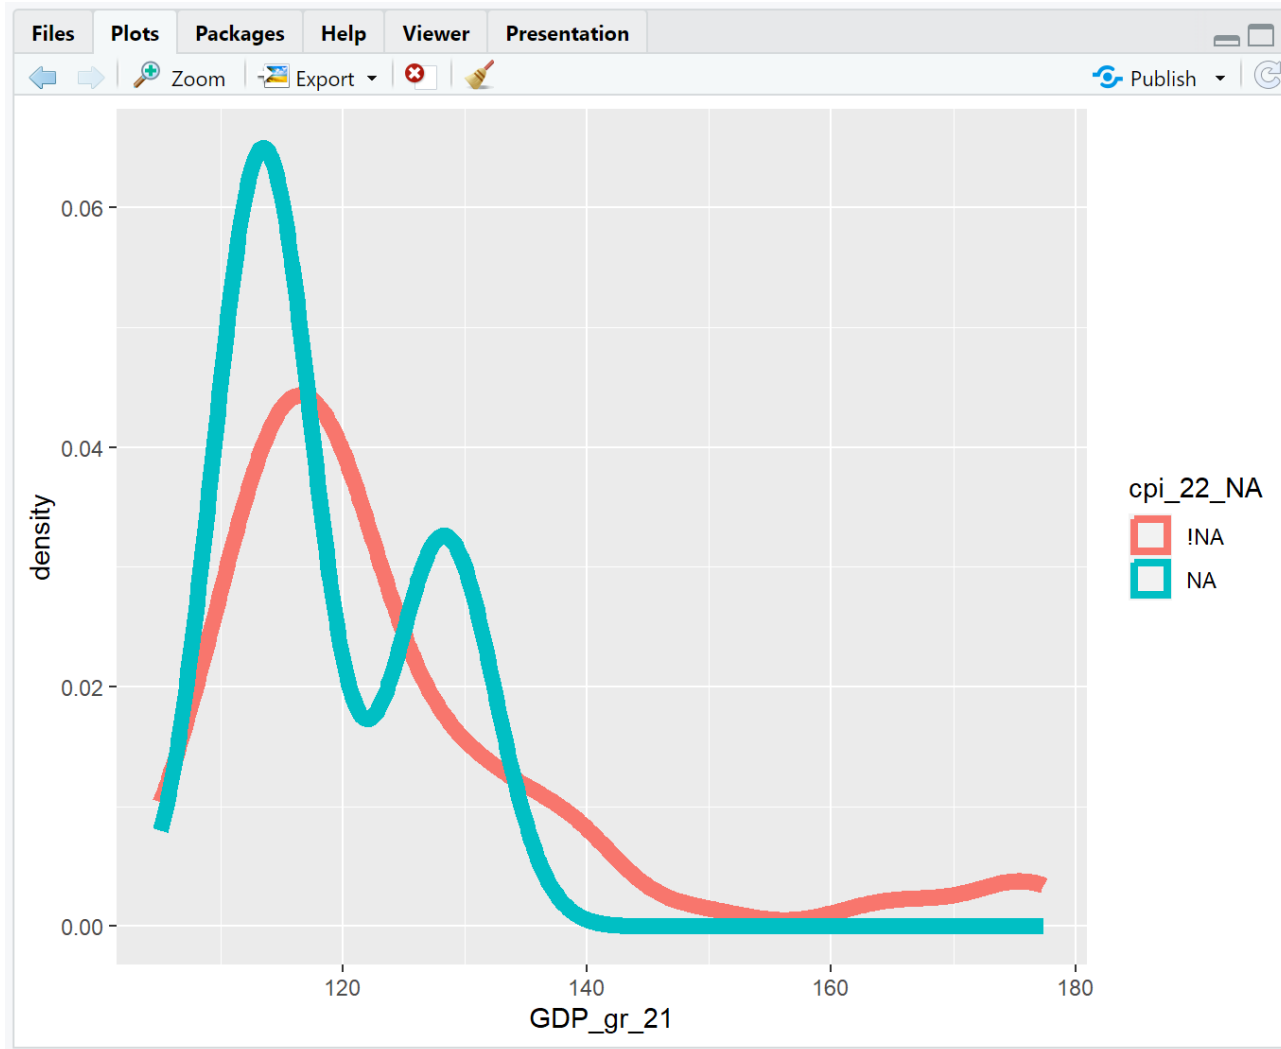




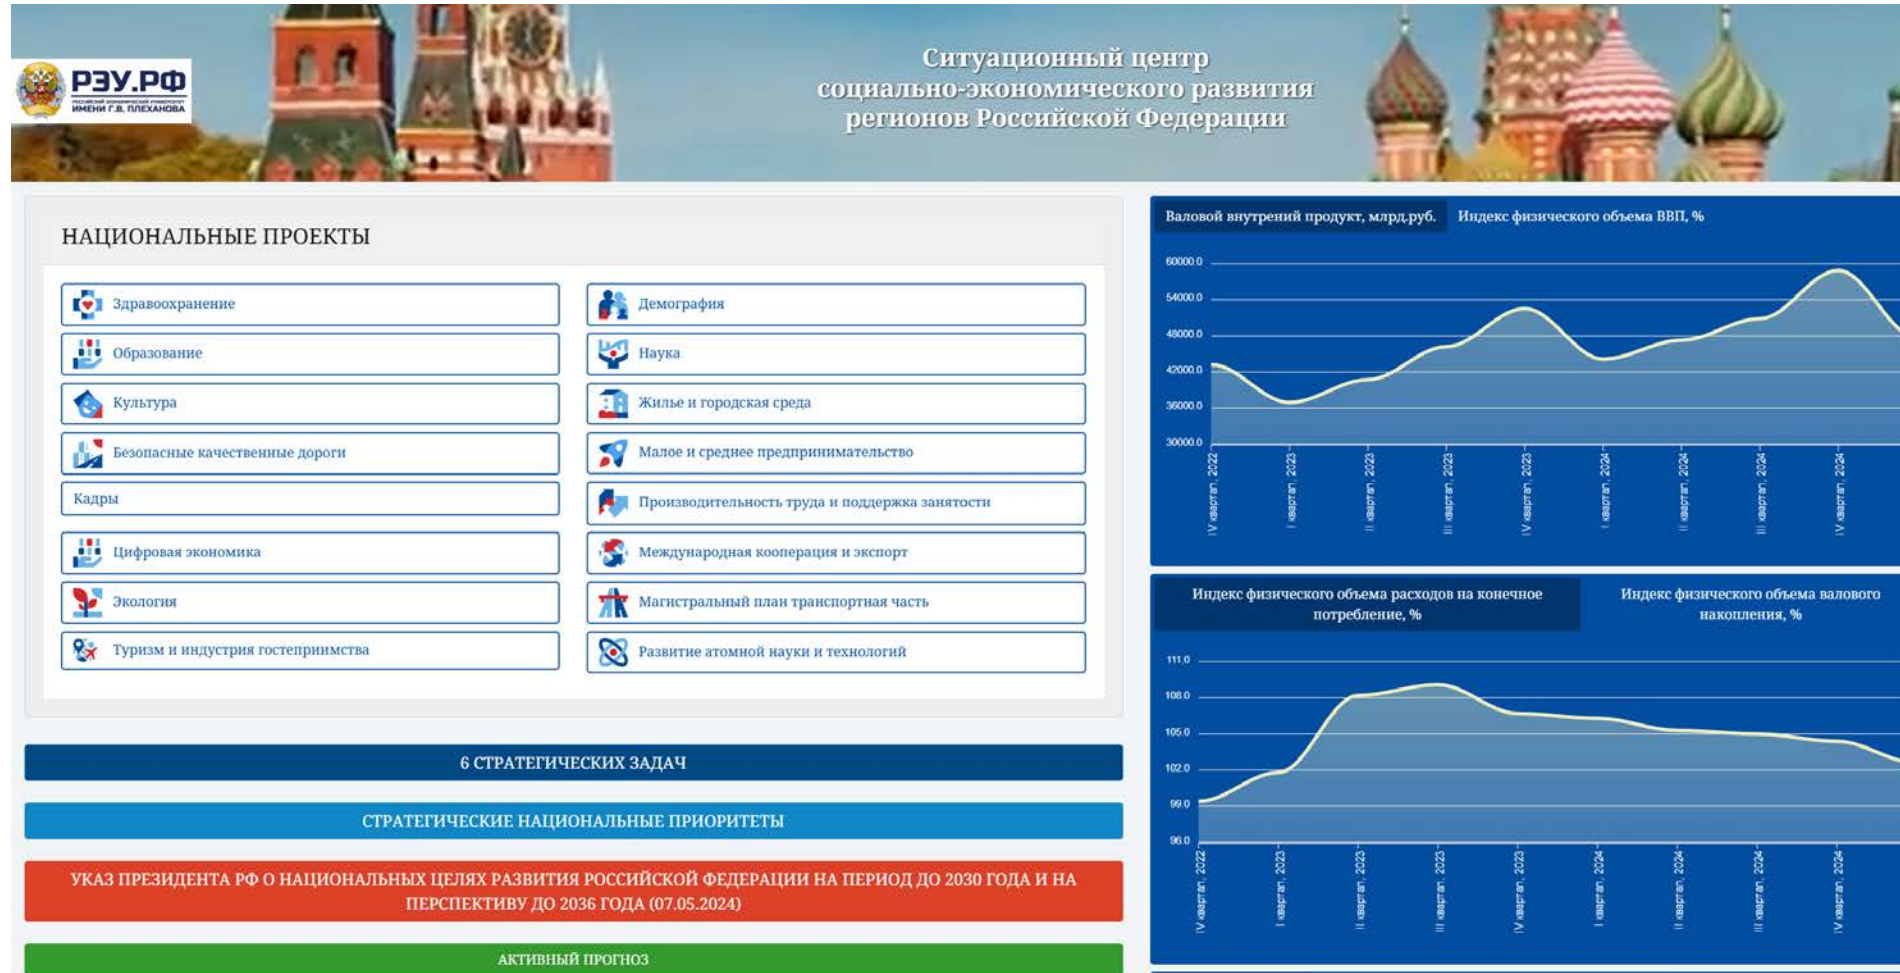
Метод машинного  
обучения



# Технологии ИИ – предсказание пропусков данных




# ПРИМЕР (2) платформа СЦ РЭУ им. Г.В. Плеханова



ЗНАЧИМОСТЬ ФАКТОРНЫХ ПЕРЕМЕННЫХ ДЛЯ ЦЕЛЕВОЙ ПЕРЕМЕННОЙ

Труд / Уровень занятости населения, по данным выборочных обследований рабочей силы; в процентах



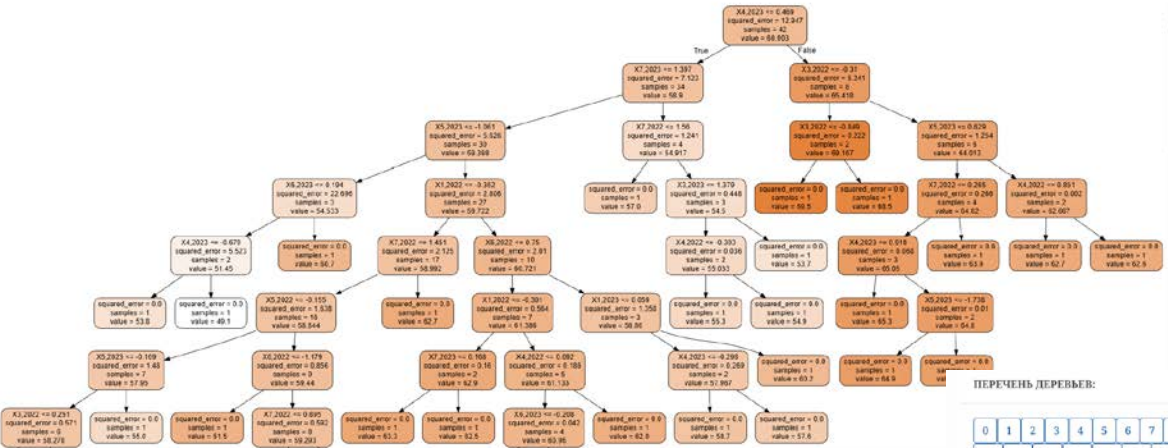
Описание	Переменная
Труд / Уровень занятости населения, по данным выборочных обследований рабочей силы; в процентах	Y1
Уровень жизни населения / Среднедушевые денежные доходы населения, в месяц; рублей	X1
Уровень жизни населения / Среднемесячная номинальная начисленная заработная плата работников организаций, рублей	X2
Реальные денежные доходы / Реальная начисленная заработная плата работников организаций, в процентах к предыдущему году	X3
Инвестиции / Инвестиции в основной капитал на душу населения, в фактически действовавших ценах; рублей	X4
Образование / Валовой коэффициент охвата дошкольным образованием, на конец года; в процентах от численности детей в возрасте 1-6 лет	X5
Численность зрителей театров и число посещений музеев на 1000 человек населения / Численность зрителей театров	X6
Здравоохранение / Заболеваемость на 1000 человек населения, зарегистрировано заболеваний у пациентов с диагнозом, установленным впервые в жиз	X7

КОЭФФИЦИЕНТ ДЕТЕРМИНАЦИИ

$R^2 = 0.9024$

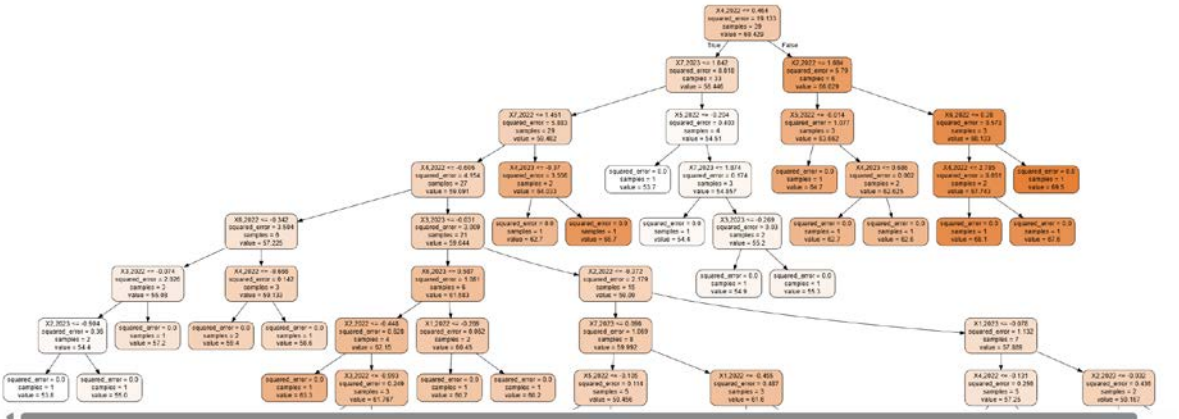
ПЕРЕЧЕНЬ ДЕРЕВЬЕВ:

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41
42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81		
82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99																								



ПЕРЕЧЕНЬ ДЕРЕВЬЕВ:

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41																
42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99



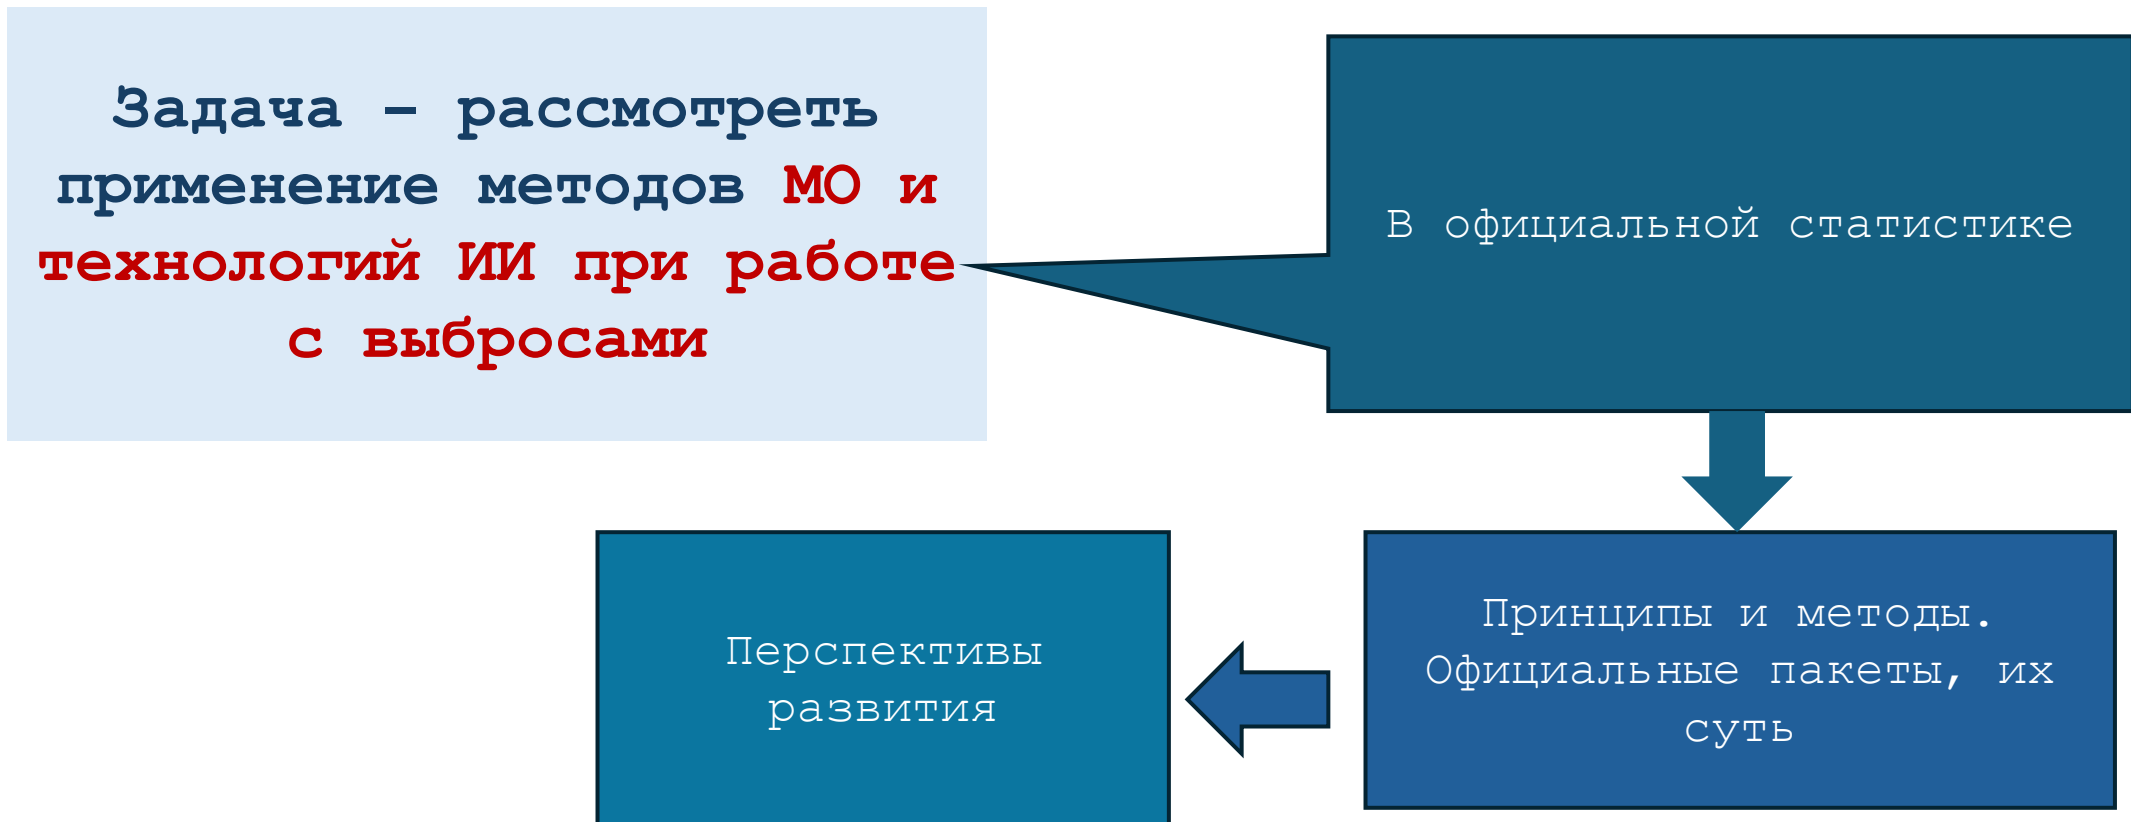


# Выводы по разделу

1. ИИ формирует потенциал аналитической функции официальной статистики, требования к развитию которой будут усиливаться со стороны пользователей
2. Потенциальным риском является «поведенческий дрейф», который возникает, когда модели ИИ корректируют свои выходные данные в соответствии с новой информацией. Это создает проблему, поскольку официальная статистика основана на достоверности, последовательности и сопоставимости.
3. Без сомнения, НСУ должны активно проверять системы искусственного интеллекта и снижать риски посредством тщательного тестирования и прозрачных операций.
4. Необходима нормативная проработка использования ИИ в официальной статистике.
5. Создание экосистемы данных с центральной интегрирующей ролью национального статистического офиса

Методы МО в обработке  
первичных данных (выявление  
статистических выбросов)

Выявление выбросов является важной задачей производства статистической информации



# «Выбросы»

Выбросом ( *outlier* )  
считается  
значение в  
данных, которое  
находится далеко  
за пределами  
других  
наблюдений

**Экстремальные значения** —  
это устранимые или  
неустранимые **ошибки**,  
возможные фиктивные  
значения

**Статистический выброс** — это наблюдение,  
которое существенно отклоняется от  
основной массы данных и расположено  
далеко от кривой плотности  
распределения вероятностей, к которой  
относятся основной объем данных.  
Формально, выброс — это точка данных с  
низкой вероятностью в данном  
распределении

# Типы ошибок

Причины выбросов разнообразны:

- Ошибки измерения
- Ошибки ввода данных
- Ошибки обработки данных

ОШИБКИ РЕГИСТАЦИИ

- Ошибки выборки
- Ошибки эксперимента
- **Естественные выбросы.** Эти отклонения не являются ошибками, хотя и «выбиваются» на фоне остальных данных

ОШИБКИ РЕПРЕЗЕНТАТИВНОСТИ

# Сведения о применении пакетов машинного обучения в официальной статистике стран СНГ (пакеты R)

## BY Белстат (Беларусь)

- `rpart` - для автоматической классификации видов экономической деятельности
- Базовые ML-пакеты в проектах по big data

## KZ Казстат (Казахстан)

- `rpart` - для стратификации в выборочных обследованиях домохозяйств
- `e1071` - контроль качества данных переписи населения

## RU Росстат (Россия)

- `e1071` - для обнаружения выбросов в экономической статистике
- `rpart` - для классификации предприятий по обороту
- `caret` - в исследовательских проектах по прогнозированию

## UZ Узстат (Узбекистан)

- Ограниченное использование ML-пакетов
- `rpart` - в пилотных проектах по прогнозированию урожая



**ROSA:** выявление выбросов (одномерный и многомерный подходы, применение методов MO)  
**ROSA (R FOR OFFICIAL STATISTICS AND DATA ANALYSIS):**

**Создатель и целевая аудитория:**

- **Разработчик:** Евростат (Eurostat), статистическая служба Европейского Союза.
- **Для кого:** Специально создан для национальных статистических офисов и официальных статистиков.

**Основные функции пакета univOutl для одномерного выявления выбросов:**

- `LocScaleB()`: Выявляет выбросы на основе робастного расположения и масштаба (аналог метода "медиана  $\pm 3$  MAD").
- `QCD()`: Использует робастный квартильный коэффициент дисперсии (QCD).
- `adjbox()`: Строит "скорректированные" диаграммы размаха (boxplot), которые лучше учитывают асимметрию данных.
- `HDoutliers()`: Алгоритм для обнаружения выбросов на основе теории больших отклонений (Heavy-Depth), эффективен для многомодальных распределений.

Практический пример

# Асимметричное распределение



## Визуализация асимметричного распределения

### Правосторонняя асимметрия


Длинный правый хвост с концентрацией выбросов в области больших значений

### Левосторонняя асимметрия


Длинный левый хвост с выбросами в области малых значений

Методы детектирования  
IQR-метод, z-оценки и робастные статистические подходы

Понимание природы асимметрии критически важно для корректной интерпретации выбросов и выбора подходящих методов их обработки в статистическом анализе.



# IQR – метод установления выбросов




# Микроданные ОРС (фрагмент)

	territ	posel	BB2	NAS_POL	NAS_VOZR	NASOBRAZ	INVALID	V_OSNZAN	KAT_TRUD1	V_OSNRB	OKZ_OSN1
1	40	1	4	1	51	10	0	1	2	1	
2	76	1	2	1	68	10	0	0	0	0	
3	40	1	4	2	20	5	0	0	0	0	
4	40	1	4	2	46	10	0	1	2	1	
5	45	1	1	2	73	8	0	0	0	0	
6	89	1	1	2	82	3	1	0	0	0	
7	88	2	2	1	68	4	0	0	0	0	
8	63	1	3	1	28	3	0	10	2	1	
9	63	1	2	1	22	5	0	0			
10	45	1	3	2	16	6	0	0			
11	52	2	3	2	48	5	0	1			
12	87	1	1	1	78	4	1	0			
13	87	1	3	1	29	11	0	1			
14	52	2	1	2	73	4	1	0			
15	63	1	2	2	75	5	0	0			

```
> summary(LFS_300[c('RBVR_FOS', 'RBVR_NOS')])
      RBVR_FOS      RBVR_NOS
Min.   : 0.00   Min.   : 0.00
1st Qu.: 0.00   1st Qu.: 0.00
Median : 36.00  Median :36.00
Mean   : 21.61  Mean   :21.37
3rd Qu.: 40.00  3rd Qu.:40.00
Max.   :140.00  Max.   :48.00
```


# Справочно: типы асимметричных распределений






# Описательная статистика

Статистическая характеристика	RBVR_FOS (час.) – фактическая продолжительность рабочей недели	RBVR_NOS (час.) – Нормальная продолжительность рабочей недели
Среднее (mean)	21.61	21.37
Станд. отклонение (sd)	21.34	19.68
Минимум	0	0
Максимум	140	48
Коэффициент вариации, %	98,6	92,0






Фактическая продолжительность рабочей недели, час.

Скрипичны  
е  
диаграммы

Фактическая продолжительность рабочей недели, час.



Группа NAS\_POL

- Группа 1
- Группа 2

# Типы переменных в примере (микроданные ОРС) – для применения МО «без учителя» (кластерный анализ) с целью выявления статистических выбросов

Количественные (числовой тип)


RBVR\_FOS,  
RBVR\_NOS

Категориальные (факторный тип)


NAS\_POL : 2 уровней  
NAS\_VOZR : 71 уровней  
NASOBRAZ : 9 уровней  
V\_OSNZAN : 6 уровней  
V\_OSNRB : 4 уровней

# Метод 1. МО «без учителя» - иерархическая кластеризация

Дендрограмма - метод ward.D2




Метод локтя - ward.D2






# Отсечение ранжированных высот на 90-м перценти.

Дендрограмма - метод average



**Расстояние Говера\*** = это "универсальная метрика" для смешанных данных.  
= "Умный способ измерить похожесть между объектами, когда **данные разного типа**  
**(Приложение 1)**"

Метод локтя - average




6  
кластеров

# Результат выделения статистических выбросов в микроданных ОРС (фрагмент) методом МО «без учителя»

cluster_k	n	mean_RBVR_FOS	mean_RBVR_NOS	sd_RBVR_FOS	sd_RBVR_NOS
1	81	40.9	40.0	13.1	0.444
2	51	0.490	0.490	3.50	3.50
3	64	37.7	38.4	6.69	2.97
4	81	0.0494	0.0494	0.444	0.444
3	17	42.8	40.5	9.24	1.94

Итого  
294

Потенциальные «выбросы» 300-294  
= 6



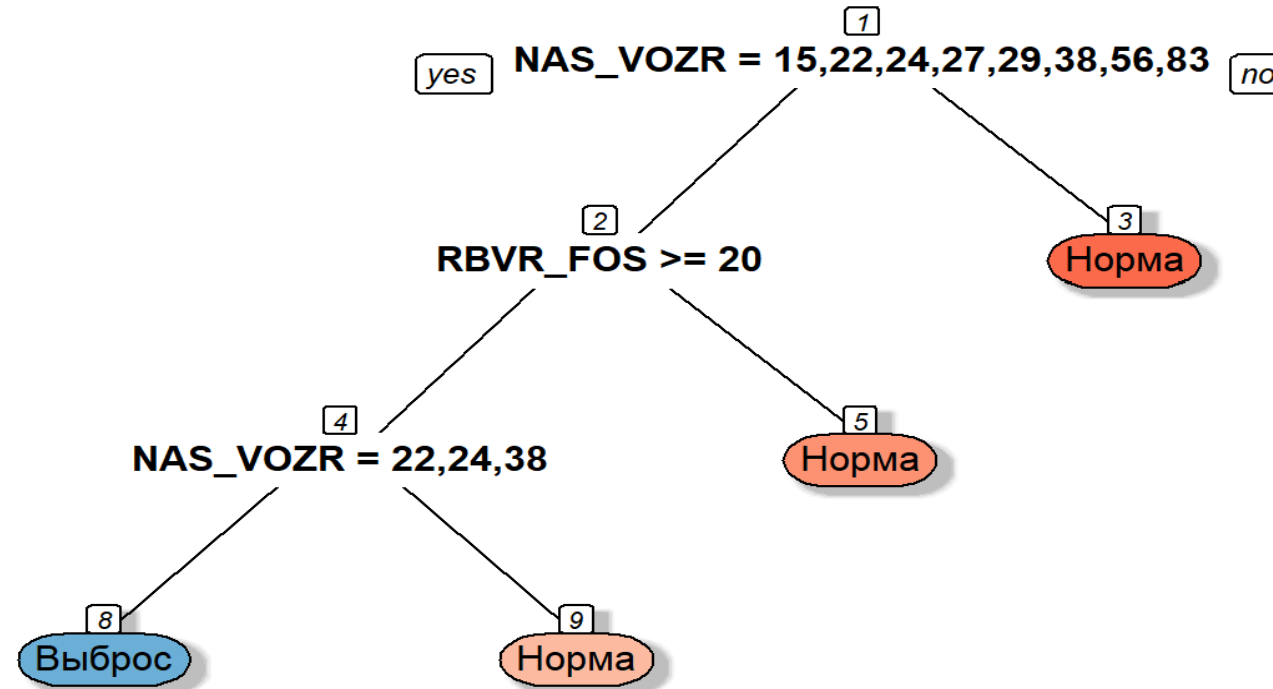
# Итоговая таблица выбросов

ТАБЛИЦА ВЫБРОСОВ - Кластерный анализ - 2025-11-18									
ID_наблюдения	Статус	Кластер	NAS_POL	NAS_VOZR	NASOBRAZ	V_OSNZAN	V_OSNRB	RBVR_FOS	RBVR_NOS
114	Выброс	1	2	47	3	1	1	24	24
18	Выброс	1	2	49	4	1	1	36	36
277	Выброс	1	2	46	4	1	1	48	40
27	Выброс	1	2	65	4	1	1	40	40
198	Выброс	1	2	29	4	1	1	40	40
106	Выброс	1	2	32	4	8	0	40	40
173	Выброс	2	1	44	5	5	0	25	40
98	Выброс	2	2	61	3	8	0	50	40
234	Выброс	1	2	33	4	8	0	40	40
105	Выброс	2	2	23	5	8	0	40	40
96	Выброс	2	2	45	5	8	0	40	40

## Метод 2. Выявление выбросов методом МО «с учителем» – деревья классификации (фрагмент)


Примечание 2.

Дерево решений для классификации выбросов



# Визуализация выбросов.

## Примечание 3.





# ПРИМЕЧАНИЯ

# Примечание 1. Расстояние Говера

**Расстояние Говера** – это "универсальная метрика" для смешанных данных.

Если в данных имеются:

**Числовые переменные** (возраст, зарплата)

**Категориальные** (пол, профессия, цвет)

**Расстояние Говера** умеет корректно сравнивать объекты по всем этим типам переменных одновременно, приводя их к общей шкале.

**Как работает:**

- Для числовых переменных – использует нормализованную разницу
- Для категориальных – считает, совпадают значения или нет

Объединяет всё в одно итоговое расстояние

**Расстояние Говера** – это "универсальная метрика" для смешанных данных.

# Примечание 2. Что значит «норма» и «выброс» в решении методом МО на основе деревьев классификации

## Почему такое разделение?

Дерево решений автоматически выявило **естественные границы** в данных на основе:

**Фактической продолжительности рабочей недели на основной работе (RBVR\_FOS)**

**Возраста сотрудников (NAS\_VOZR)**

**Возможно, других переменных**

**Критерии "выбросов"** определяются статистически – это наблюдения, которые:

Значительно отличаются от большинства

Находятся в "хвостах" распределения

Имеют нестандартные сочетания характеристик

Такой подход позволяет **автоматически идентифицировать** случаи, требующие дополнительной проверки в статистическом обследовании.

Анализируя визуализацию дерева решений, можно определить логику разделения на **"Норма"** и **"Выброс"**:

### **"НОРМА"** (Normal)

Это **типичные/стандартные наблюдения**, которые соответствуют основным паттернам данных

В контексте рабочего времени: сотрудники с **стандартной продолжительностью рабочей недели**

Например: большинство сотрудников с рабочим временем в типичном диапазоне (вероятно 35–50 часов)

### **"ВЫБРОС"** (Abnormal)

Это **аномальные наблюдения**, которые значительно отклоняются от типичных паттернов

В контексте рабочего времени могут включать:

- Слишком короткая** рабочая неделя (< определенного порога)

- Слишком длинная** рабочая неделя (> определенного порога)

- Необычные комбинации** основной и дополнительной работы

# Примечание 3. Обнаружение выбросов: **One-Class SVM** и **Local Outlier Factor (LOF)**

## 1. **One-Class SVM** - обнаружено выбросов:

Модель обучается только на "нормальных" данных

Строит границу вокруг нормальных наблюдений

Все, что выходит за эту границу - считается выбросом

**Аналогия:** "Рисует забор вокруг типичных данных, кто за забором - выброс"

## 2. **Local Outlier Factor (LOF)** - обнаружено выбросов:

Сравнивает плотность точек вокруг каждого объекта

Если у точки соседи редкие/далекие - она выброс

Учитывает локальную структуру данных

**Аналогия:** "Ищет одинокие точки в малолюдных районах"

**Различие:** SVM ищет глобальные выбросы, LOF - локальные аномалии в контексте их окружения.