



БЮРО НАЦИОНАЛЬНОЙ СТАТИСТИКИ  
АГЕНТСТВА ПО СТРАТЕГИЧЕСКОМУ  
ПЛАННИРОВАНИЮ И РЕФОРМАМ РЕСПУБЛИКИ  
КАЗАХСТАН

# Использование больших данных при формировании ИПЦ в Казахстане

ноябрь 2025 г.

# Активная стадия реформирования Бюро национальной статистики



- На активной стадии реализация Концепции развития государственной статистики и национальной экосистемы данных




В реализацию Концепции утверждена  
Дорожная карта реформирования БНС:

- 1 Институционально-организационные меры
- 2 Активное использование **административных и альтернативных** источников
- 3 Укрепление аналитического потенциала и расширение доступа к данным

Реформы реализуются поэтапно **с учетом мнения экспертного сообщества, пользователей и респондентов** для соблюдения интересов всех заинтересованных сторон

# Переход на альтернативные источники данных



# Касательно административных данных ОФД



**Операторы фискальных данных (ОФД)** — связующее звено для передачи сведений в комитет государственных доходов от контрольно кассовых машин

- В стране операторы фискальных данных (ОФД) появились в 2015 году, когда АО «Казахтелеком» было назначено постановлением правительства оператором, отвечающим за передачу сведений о денежных расчетах налогоплательщиков в органы налоговой службы в режиме онлайн.

## Обязательные пользователи онлайн-касс:

- Субъекты осуществляющие розничную торговлю и услуги населению
- Субъекты обязаные фиксировать наличные и безналичные расчеты через кассы
- Торговые автоматы и терминалы оплаты услуг, если они принимают наличные средства

## Освобожденные от обязательного использования онлайн-касс:

- Частные судебные исполнители, адвокаты и медиаторы
- Организации и граждане, осуществляющие перевозки общественным транспортом
- Национальный Банк РК, банки второго уровня, религиозные объединения
- Налогоплательщики в местах без связи, допускается использование только «старых» касс, без передачи данных



## Ограничения данных ОФД

- Не охватывают неформальный сектор экономики
- В случае технических сбоев (кассовое ПО, серверы ОФД, перебои связи) возможна задержка поступления чеков
- Не всегда в чеке указывается подробное наименование товара (например, только «товар», «продукт»)
- В случае задержки передачи данных от КГД возможны сбои в полноте и своевременности анализа, что может повлиять на оперативность расчетов ИПЦ

**Отличительная особенность данных ОФД это возможность оперативного мониторинга цен на товары**

# Внедрение инструментов ИИ для автоматизации обработки и анализа данных



**Цель проекта** – разработка и внедрение автоматизированной системы классификации наименований товаров с использованием современных языковых моделей и методов машинного обучения для ускорения обработки фискальных данных и упрощения анализа товарного ассортимента



## Задачи

- Категоризация 362 млн. товарных наименований для дальнейшего использования при расчете инфляции на основе данных ОФД



## Ожидаемые результаты

- Полностью автоматизированная система классификации наименований товаров (перед началом реализации проекта было 20 товаров)
- Расширение перечня товаров для формирования статистической информации



## Ключевые эффекты

- Точный мониторинг инфляции по большему количеству товаров
- Детальный расчет показателей розничной торговли



## Источники данных

- Данные Операторов фискальных данных (ОФД)
- Данные Статистического бизнес регистра
- Справочник по адресам контрольно-кассовых машин

# Этапы построения выборки и очистки для категоризации данных



## Этапы построения выборки

1

### Фильтрация по видам деятельности

исключительно розничной торговли, исключение онлайн торговли, аптек и прочего

2

### Фильтрация по обороту, компании с объемом продаж **свыше 10 млн тенге**

3

### Фильтрация по длине символов

, длина от 2 до 150 символов, исключаются технические записи (*TO\_EMPTY, BAD\_BIN*)

4

### GTIN-склейка

 – в случае, если в чеке имеется GTIN, он используется для унификации в рамках одного субъекта

## Этапы очистки

1

### Приведение наименований товаров **к нижнему регистру**

2

### Очистка от неинформативных данных

 (спецсимволы, служебные наименования – «чек», «касса», «скидка», прочее)

3

### Нормализация символов

, латинские буквы, похожие на кириллицу (а→а, о→о, р→р и т.д.), заменяются.

4

### Специфическая обработка топлива

 для строк с наименованием «АИ-92», «АИ-95», «ДТ», «газ» отдельные правила.

**Обучена модель *bge\_m3* (600 млн параметров), которая  
по качеству сопоставима с GPT-5 на задачах категоризации товаров  
по данным ОФД**



Картофель

Выбросы



## Модель машинного обучения на базе обработки естественного языка


- ***bge\_m3 (~600 млн параметров)*** компактная модель, дообученная на данных ОФД. Работает быстро и дешевле в эксплуатации.
- **GPT-5 (сотни миллиардов параметров)** универсальная модель для множества задач, при этом гораздо тяжелее и дороже.
- **LLaMA-7B (7 млрд параметров)** пример «среднего размера» модели, которая тоже требует серьезных ресурсов.

# От выборочного мониторинга к масштабному применению данных фискальных чеков

## Традиционный метод

- 120 тыс. котировок

12 тыс.  
базовых объектов  
(магазины, рынки)




Цены  
фиксируется  
регистраторами  
цен (свыше 300  
сотрудников)

## Использование данных фискальных чеков

36,9 млн. котировок

124 тыс.  
объектов розничной торговли охваченных  
категоризацией



Используются  
данные  
фискальных  
чеков с  
применением ИИ

# Внедрение инструментов ИИ для автоматизации обработки и анализа данных



## Текущие результаты



КГД



БНС



Индекс потребительских цен на основе анализа диапазона цен

КОЛИЧЕСТВО ПОСТУПИВШИХ ЗАПИСЕЙ

20,6 млрд

После фильтрации, очистки и разметки

КОЛИЧЕСТВО УНИКАЛЬНЫХ НАИМЕНОВАНИЙ ТОВАРОВ

362 млн

КОЛИЧЕСТВО УНИКАЛЬНЫХ ТОВАРОВ ПОСЛЕ ФИЛЬТРАЦИИ ПО КРИТЕРИЯМ


36,9 млн

КОЛИЧЕСТВО ОХВАЧЕННЫХ КАТЕГОРИЙ ТОВАРОВ

290 или 57% (от всего перечня товаров ИПЦ)

КОЛИЧЕСТВО ОХВАЧЕННЫХ ЗАПИСЕЙ ПО 290 КАТЕГОРИЯМ

8,3 млрд или 40,3% (от всего кол-ва записей)



Данные обновляются на дашборде для внутреннего пользования

Примечание: в расчет взяты данные с января 2023 года по август 2025 года

# Комбинированный метод сбора



Вместо бумажного процесса регистрации цен переход на цифровой сбор посредством сканирования **штрих кодов, фиксирования пути и места нахождения регистратора цен, а также централизованный сбор посредство парсинга**

**Внедрен модуль ввода данных мобильного приложения (МП)**  
С марта 2024г. сбор цен на СЗПТ производится с помощью МП

## Преимущества:

- повышение качества первичных данных за счет минимизации ошибок при вводе (возможность передачи скринов товара, выявление ошибок)
- передача данных в онлайн-режиме и более оперативная обработка данных

**Разработан и используется инструмент парсинга**  
С января 2024г. осуществляется сбор по 43 наименованиям ИПЦ

## Преимущества:

- web scraping позволяет автоматический собирать данные о ценах с множества сайтов, что значительно экономит время по сравнению с традиционным методом
- передача данных в онлайн-режиме и более оперативная обработка данных

Осуществлен экспериментальный расчет индексов цен на основе **данных контрольно-кассовых машин**.  
Результаты расчетов опубликованы на официальном сайте Бюро в рубрике «Экспериментальная статистика и исследования» в виде дашборда и аналитической записи к дашборду.