

Основы работы с данными для ИИ

Лекция 5 Этические аспекты ИИ. Парсинг HTML и скрапинг

Доц
Екатерина Александровна

Преподаватель кафедры информатики и вычислительного эксперимента

Зачем говорить об этике ИИ

ИИ — не просто инструмент, а система, влияющая на людей, бизнес и общество. Ошибки ИИ масштабируются, а последствия часто «трудно объяснить» (black box).

Этика нужна, чтобы:

- минимизировать вред (дискриминация, утечки, небезопасный код);
- повысить доверие (прозрачность, проверяемость);
- соответствовать законам и лицензиям;
- сделать выгоды от ИИ устойчивыми и справедливыми.

- **Прозрачность и объяснимость:** фиксировать источники, версию модели, ограничения; уметь объяснить вывод.
- **Справедливость и недискриминация:** оценивать и снижать смещения в данных и результатах.
- **Приватность и минимизация данных:** собирать ровно столько, сколько нужно; не хранить секреты в промптах.
- **Безопасность и надёжность:** защищаться от атак (prompt injection, supply chain), тестировать на отказоустойчивость.
- **Ответственность человека:** человек принимает финальные решения (human-in-the-loop), фиксирует авторство и рецензирует.
- **Устойчивость и экологичность:** учитывать вычислительные затраты и энергоэффективность.

Что может пойти не так (общие риски ИИ)

- **Смещения и дискриминация:** модель повторяет перекосы исходных данных.
- **Галлюцинации:** уверенные, но неверные ответы; опасно в медицине, праве, безопасности.
- **Приватность и секреты:** случайная утечка PII/секретов в промптах или логах.
- **Интеллектуальная собственность:** нарушение авторских прав и лицензий, «заражение» кода не совместимыми лицензиями.
- **Безопасность:** атакующие подсказки, уязвимые шаблоны кода, вредоносные зависимости.
- **Зависимость и «разучивание»:** снижение квалификации, если слепо полагаться на ИИ.
- **Непрозрачность:** трудно воспроизвести и объяснить результат.

- **Скорость разработки:** генерация чернового кода, шаблонов, документации, тестов.
- **Качество:** напоминание про edge-cases, рефакторинг, статический анализ, автогенерация тестов.
- **Доступность:** помогает новичкам быстрее входить в стек, снижает языковой барьер.
- **Поддержка безопасности:** подсказки по исправлению уязвимостей, чек-листы best practices.
- **Рутины:** миграции, конфиги CI/CD, boilerplate — экономия времени на низкоуровневых задачах.

- **Уязвимый/устаревший код:** ассистент может сгенерировать небезопасные конструкции или старые API.
- **Лицензии и авторские права:** фрагменты могут походить на код с GPL/AGPL и др.; риск несоответствия корпоративной политике.
- **Ложная уверенность:** «код компилируется» ≠ «код корректен, безопасен и эффективен».
- **Зависимости и supply chain:** ассистент предложит библиотеку с низкой репутацией.
- **Секреты:** случайная вставка ключей/токенов, отправка их в промпт или логи.
- **Потеря навыков:** без рецензии и обучения разработчик перестаёт понимать дизайн-решения.
- **Непредсказуемость:** одинаковые запросы → разные ответы; сложно вести диффы и RCA без протоколов.

Перед использованием ассистента:

- Не вставлять в промпт секреты/PII (ключи, пароли, приватный код клиента).
- Ставить чёткую цель: «что именно генерировать/исправлять», какие ограничения (лицензии, стиль, версия языка).

После получения кода:

- Считать это черновиком: проверить логику, граничные случаи, производительность.
- Запустить тесты (если есть).
- Сверить код с официальной документацией API/фреймворка (мог быть устаревший синтаксис).
- Дополнить комментарии и документацию: зачем принято решение, какие альтернативы.

Баланс: как извлечь максимум пользы

- Используйте ИИ там, где много рутины и есть чёткие спецификации.
- Всегда оставляйте человеческое рецензирование для критичных частей.
- Документируйте ограничения ассистента и границы ответственности.
- Включайте автоматические сканеры лицензий, секретов, уязвимостей в CI.
- Развивайте навыки разработчика: ИИ — усилитель, а не замена мышления.

- Сформулировать цель одной фразой. Что именно нужно на выходе? («Сгенерируй функцию валидации e-mail с тестами».)
- Дать контекст. Среда, версии, ограничения (Python 3.11, pandas 2.x, без внешних API).
- Определить формат вывода. «Верни только JSON со схемой ...» / «Код в одном блоке, без комментариев».
- Задать критерии качества. Скорость $O(n)$, совместимость лицензий.
- Пример(ы) ввода/вывода. 1–2 эталона сильно повышают точность
- Границы и запреты. «Не использовать глобальные переменные», «не ставить новые зависимости».
- Попросить самопроверку. «Проверь граничные случаи: пустой ввод, дубликаты, Unicode».
- Попросить краткое резюме решений. 2–3 пункта: что выбрано и почему (без лишней «воды»).
- Ограничить длину. «Не более 150 строк кода/500 слов пояснений».
- Итерировать. Дальше давать точечные правки: «Перепиши только часть X»

Советы по промптингу

Скелет «идеального» промпта (Prompt Canvas)

Роль: «Ты —разработчик Python»

Задача: (1 фраза, глаголом)

Контекст/среда: версии, ОС, политика лицензий

Входные данные: как устроен input

Выход/формат: код/JSON/таблица, чёткие поля

Критерии качества: метрики, стиль, совместимость

Примеры: 1–2 пары input→output

Ограничения/запреты: что нельзя использовать

Самопроверка: чек-лист из 3–5 пунктов

Длина/тон: кратко/подробно; язык ответа

Парсинг – это автоматизированный процесс сбора и преобразования данных из неструктурированных или полуструктурированных источников, таких как веб-страницы, текстовые файлы или таблицы, в удобный для анализа и обработки формат. Этот процесс выполняется с помощью специальных программ – **парсеров**, которые извлекают нужную информацию согласно заданным правилам и сохраняют ее в структурированном виде, например, в таблицах или базах данных.

Для чего используется парсинг:

- **Автоматизация** сбора больших объемов данных без ручного ввода
- **Анализ** информации с конкурирующих или тематических сайтов для принятия решений
- **Подготовка данных** для машинного обучения и бизнес-аналитики
- **Обновление и пополнение** баз данных с актуальными сведениями
- **Оптимизация** маркетинга, SEO и исследований рынка через быстрый сбор релевантной информации.

Парсинг HTML страниц

Основные библиотеки и инструменты для парсинга на Python

requests – библиотека для отправки HTTP-запросов и получения HTML страниц.

BeautifulSoup (bs4) – популярный парсер HTML/XML, удобен для навигации по дереву документа и извлечения информации.

lxml – быстрая библиотека для парсинга HTML и XML, используется как альтернатива или дополнение к BeautifulSoup.

Scrapy – мощный и масштабируемый фреймворк для веб-скрапинга, подходящий для проектов с большим объёмом данных и сложной логикой.

Selenium – инструмент для автоматизации браузера, нужен, если сайт динамически генерирует контент с использованием JavaScript (например, SPA или загрузка данных через AJAX).

pandas – для обработки и сохранения собранных данных в удобном формате (DataFrame, CSV, Excel).

Сайт для скрапинга – Books to Scrape

Books to Scrape We love being scraped!

[Home](#) / [All products](#)


Books

- Travel
- Mystery
- Historical Fiction
- Sequential Art
- Classics
- Philosophy
- Romance
- Womens Fiction
- Fiction
- Childrens
- Religion
- Nonfiction
- Music
- Default
- Science Fiction
- Sports and Games
- Add a comment
- Fantasy
- New Adult


All products

1000 results - showing 1 to 20.

Warning! This is a demo website for web scraping purposes. Prices and ratings here were randomly assigned and have no real meaning.




A Light in the ...



Tipping the Velvet



Soumission



Sharp Objects

Парсинг HTML страниц

```
import requests
from bs4 import BeautifulSoup
import pandas as pd

all_books = []
```

Импорт библиотек

Объявление пустого массива

Сохраняем URL страниц каждой книги

```
for page_num in range(1, 5):
    url = f'https://books.toscrape.com/catalogue/page-{page\_num}.html'
    response = requests.get(url)
    soup = BeautifulSoup(response.content, 'html.parser')

    books = soup.find_all('li', class_='col-xs-6')
```

Проходим по страницам каждой книги и сохраняем в массив `all_books`

```
for book in books:
    book_url = 'https://books.toscrape.com/catalogue/' + book.find('a')['href']
    book_resp = requests.get(book_url)
    book_soup = BeautifulSoup(book_resp.content, 'html.parser')

    all_books.append({
        'Name': book_soup.find('h1').text,
        'Description': book_soup.select('p')[3].text,
        'Price': book_soup.find('p', class_='price_color').text,
        'Category': book_soup.find('ul', class_='breadcrumb').select('li')[2].text.strip(),
        'Availability': book_soup.select_one('p.availability').text.strip(),
        'UPC': book_soup.find('table').find_all('tr')[0].find('td').text
    })
```

```
df = pd.DataFrame(all_books)
```

Создаем датафрейм на основе полученного массива

Парсинг HTML страниц

Больше сайт для скрапинга

- Quotes to Scrape

Quotes to Scrape

"The world as we have created it is a process of our thinking. It cannot be changed without changing our thinking."

by [Albert Einstein](#) (about)

Tags: [change](#) [deep-thoughts](#) [thinking](#) [world](#)

"It is our choices, Harry, that show what we truly are, far more than our abilities."

by [J.K. Rowling](#) (about)

Tags: [abilities](#) [choices](#)

"There are only two ways to live your life. One is as though nothing is a miracle. The other is as though everything is a miracle."

by [Albert Einstein](#) (about)

Tags: [inspirational](#) [life](#) [live](#) [miracle](#) [miracles](#)

- Open Food Facts

Top Ten tags

love

inspirational

life

humor

books


reading

friendship

friends

truth

ends



urllib – это стандартная библиотека Python для работы с URL и веб-запросами. Он состоит из нескольких подтем: **urllib.request** для отправки запросов и получения ответов, **urllib.parse** для разбора и построения URL, **urllib.error** для обработки ошибок и **urllib.robotparser** для анализа файла robots.txt.

```
from urllib.parse import urlparse, urlunparse, urlencode

url = 'https://edu.mmcs.sfedu.ru/course/view.php?id=806'
parsed = urlparse(url)
print(parsed.scheme) # https
print(parsed.netloc) # edu.mmcs.sfedu.ru
print(parsed.path)   # /course/view.php

# Изменение и сборка URL
new_url = urlunparse(parsed._replace(scheme='http'))
print(new_url) # http://edu.mmcs.sfedu.ru/course/view.php?id=806

# Кодирование параметров для URL
params = {'q': 'python urllib', 'page': 2}
query_string = urlencode(params)
print(query_string) # q=python+urllib&page=2
```

API (Application Programming Interface) – это программный интерфейс приложения, набор правил и инструкций, по которым разные программы взаимодействуют между собой и обмениваются данными. Проще говоря, API – это «интерфейс» или «переводчик», благодаря которому одна программа может «общаться» с другой, независимо от их внутренней реализации.

API широко используются для получения данных из внешних источников, интеграции разных систем, автоматизации процессов и расширения возможностей приложений. Например, с помощью API можно подключить погодный сервис к вашему приложению, получить данные о курсах валют, работать с базами данных, управлять удалёнными устройствами и многое другое. API работают через **стандартизованные запросы** (например, **HTTP**), обычно возвращая данные в удобных форматах, таких как **JSON** или **XML**. Это упрощает разработку, делает программы более гибкими и масштабируемыми.

NASA EXOPLANET ARCHIVE

A SERVICE OF NASA EXOPLANET SCIENCE INSTITUTE

EXOPLANET EXPLORATION
Planets Beyond Our Solar System

[Home](#)[About Us](#)[Data](#)[Tools](#)[Support](#)[Login](#)

6,028
Confirmed Planets
10/09/2025

705
TESS Confirmed Planets
10/09/2025

7,703
TESS Project Candidates
10/03/2025

View more Planet and
Candidate statistics

Explore the Archive

Search

Optional Radius (arcsec)

Advanced Search

Transit Surveys

130,041,578 Light Curves

Launched in April 2018, TESS is surveying the sky for two years to find transiting exoplanets around the brightest stars near Earth.

Confirmed Planets

ExoFOP-TESS

Project Candidates

Community Candidates

TESS

Kepler

K2

KELT

UKIRT

Six Planets, Including a Second GPI Planet!

October 9, 2025 • New Data

This week's new planets include HD 143811 AB b, a massive Jupiter in a 300+-year orbit around two young (15 Myr) stars that was directly imaged by the Gemini Planet Imager (GPI). There are also new data for 16 planets and new JWST transmission spectra.

SNR

GPI (2016-04-30)

News

1 2 3 4

Plots

1 2 3 4

19

Отправка GET-запроса к NASA Exoplanet Archive через TAP API. Метод `raise_for_status()` проверяет, что запрос успешен (код 200), иначе вызовет исключение.

```
url = "https://exoplanetarchive.ipac.caltech.edu/TAP/sync?query=select+*+from+pscomppars&format=json"
response = requests.get(url)
response.raise_for_status()
data = response.json()
df = pd.DataFrame(data)
```