

Изучение знаний и опыта, полученных в результате проекта ЕФО «Большие данные для аналитики рынка труда»

Обзор технического построения системы сбора и анализа данных онлайн-вакансий: от изучения ландшафта источников данных до их визуализации

Мауро Пелуччи

Ноябрь 2021

Темы

1. Обзор и краткое повторение
2. Что такое конвейер?
3. Уровень хранения
4. Фреймворк Spark
5. Лабораторная работа
 1. Поиск новых наименований должностей
 2. Поиск новых профессий

Темы

- 1. Обзор и краткое повторение**
2. Что такое конвейер?
3. Уровень хранения
4. Фреймворк Spark
5. Лабораторная работа
 1. Поиск новых наименований должностей
 2. Поиск новых профессий

Общий поток данных



Извлечение информации

- **Цель:**
 - Извлечь и структурировать информацию из данных для передачи на уровень представления
- **Задачи:**
 - Обработка огромного массива неоднородных данных на разных языках
- **Подход:**
 - Разработать адаптируемую схему, подстроенную к различным особенностям информации. Некоторые актуальные задачи:
 - Классификация по **профессии**: комбинированные методы, такие как машинное обучение, тематическое моделирование, обучение без учителя
 - Классификация по **профессиональным умениям**: другие различные комбинированные методы, такие как анализ текста с учетом сходства на основе корпуса или знаний
- **Особенности:**
 - Гарантировать извлечение объяснимой информации, регистрацию методов классификации и соответствующие особенности.

Извлечение и классификация информации

Аналитика рынка труда в реальном времени


Извлечение информации — это сфера обработки естественного языка, которая связана с поиском фактической информации в произвольном тексте.

Для выполнения этой задачи используются методы машинного обучения (обучение на основе онтологии, обучение с учителем и без учителя), чтобы сопоставлять объявления о работе со стандартными классификациями.



Извлечение информации

Извлечение информации: анализ неструктурированного документа с целью извлечения определенной информации.



Вакансия



Профессия	Профессиональные умения
Время	Регион
Отрасль	...

Младший разработчик ПО

В качестве младшего разработчика ПО, вы будете разрабатывать прекрасное программное обеспечение для использования в сфере сопоставления полей, сбора данных, сенсорных сетей, уличной навигации, и многих других. Вы будете сотрудничать с другими программистами и разработчиками в целях самостоятельного проектирования и внедрения высококачественных веб-приложений, API, соответствующих ограничениям REST, и обеспечения интеграции сторонних решений.

Мы ищем увлеченного, преданного делу разработчика, умеющего решать и формулировать сложные задачи в сфере проектирования приложений, разработки и взаимодействия с пользователем. Работа в нашем офисе в Харвелле, Великобритания.




2512 — Разработчик ПО

Проф. умения: разработка ПО, внедрение веб-приложений, решение проблем, разработка пользовательских взаимодействий

Харвелл, Великобритания


...




Темы

1. Обзор и краткое повторение
- 2. Что такое конвейер?**
3. Уровень хранения
4. Фреймворк Spark
5. Лабораторная работа
 1. Поиск новых наименований должностей
 2. Поиск новых профессий

Анатомия информационного продукта




Анатомия информационного продукта



Конвейер обработки данных

Еще одна компьютерная программа




Пакетное задание


Работа == функция ([входящий набор данных]):
[выходящий набор данных]


- Поддается проверке
- Элементарное
- Детерминированное
- Идемпотентное
- Отсутствие других вводных параметров

Схема конвейера




Конвейер и определение языка





Компоненты на основе онтологий




Регулярные выражения


Регулярное выражение
— это запись для
определения набора строк.




Онтологии



Регулярные
выражения



Модели
на основе онтологий



Классифицированные
элементы

Регулярное выражение для определения зарплаты



Тестирование (одна работа)

Как тестировать конвейер обработки данных?

- Тестировать одну работу / один компонент
- Стандартный набор данных («золотой» набор данных или имитация набора данных)
 - Сгенерировать входные данные
 - Запустить в рамках локального / маленького кластера
 - Проверить выходные данные

Что нам нужно?

Набор средств



Что нам нужно?

Набор средств

Статистические методы

Инструменты

Исследование механизма взаимодействия с пользователем

Языки

Python

R

Scala

SQL

Библиотеки

Pandas

Sklearn

OpenNLP

Spacy

Fasttext

Word2Vec

H2O.ai

...

Инженерия данных

Hadoop

Spark

Профилирование

ETL (извлечение, преобразование, загрузка)

Объявления о работе

API

Конвейер обработки

оптимизированных данных

Хранение оптимизированных данных/ доступ к ним

Облако (AWS)

CI/CD

Визуализация

D3.js

Gephi

R

Matplot

Shiny

Tableau

Что нам нужно?

Набор средств

Статистические методы

Инструменты

Исследование механизма взаимодействия с пользователем

Интерактивное прототипирование

Создание карты сервисного сценария

Наблюдение за пользователем

Создание карты пути пользователя

Темы

1. Обзор и краткое повторение
2. Что такое конвейер?
- 3. Уровень хранения**
4. Фреймворк Spark
5. Лабораторная работа
 1. Поиск новых наименований должностей
 2. Поиск новых профессий

Ключевые понятия

- Столбчатые форматы данных
- Delta lake

Понятия

Столбчатые форматы данных


- Фильтры — это не единственные «предикаты», которые могут быть спущены
- Для этой цели также может быть использован выбор столбцов
 - В такой базе данных, как PostgreSQL, это можно сделать с помощью оператора SELECT
 - Для файлов нам требуется столбчатый формат файлов
- Данные хранятся по столбцам, а не по строкам
 - Parquet и ORC
 - Формат Delta lake: [Delta.io](#), [Hudi](#), [Iceberg](#)
- В сравнении с построчными форматами файлов, в которых данные хранятся по строкам
 - CSV, TSV, JSON, и AVRO

Понятия

Пример: Столбчатый формат в сравнении с построчным

Построчный

	имя	цвет	город	возраст
Строка 1	Том	красный	Чикаго	32
Строка 2	Салли	синий	Париж	87
Строка 3	Майк	зеленый	Лондон	20
Строка 4	Мэри	желтый	Фресно	55



Столбчатый

	Строка 1	Строка 2	Строка 3	Строка 4
имя	Том	Салли	Майк	Мэри
цвет	красный	синий	зеленый	желтый
город	Чикаго	Париж	Лондон	Фресно
возраст	32	87	20	55



Что такое **Delta Lake**?



Технология, разработанная для
использования с Apache Spark с целью
создания озер надежных данных

Проект с открытым исходным кодом

delta.io

Databricks [документация Delta Lake](#)


Особенности Delta lake

- Транзакции, соответствующие требованиям ACID, на базе Spark
- Масштабируемая обработка метаданных
- Поточковая передача и унификация пакетов
- Принудительное применение схемы
- Механизм путешествия во времени
- Обновление или вставка и удаление
- Полностью конфигурируемый/ оптимизируемый
- Поддержка структурированной потоковой передачи


Промежуточная область

ПРОМЕЖУТОЧНАЯ ОБЛАСТЬ = конвейеры обработки данных, данные и процессы ETL, это как кухня ресторана

- У конечного пользователя не должно быть доступа к данным в промежуточной области: они не готовы к потреблению.
- В промежуточной области проводятся «опасные» операции: очистка данных, поиск и соединение данных, создание витрин данных, ...
- Корпоративные пользователи не думают (и не должны думать) о том, что происходит в рамках конвейера обработки данных и процессов ETL.



Озеро данных



Источник иллюстрации: EMC

<https://40uu5c99f3a2ja7s7miveqqqu-wpengine.netdna-ssl.com/wp-content/uploads/2017/02/Understanding-data-lakes-EMC.pdf>

Парадигма озера данных

Хранилище данных

- Агрегированные подмножества
- Представление данных по запросу
- Проверено экспертами
- Структурированное — таблицы, представление данных, отчеты. Узкий контекст
- Качество данных известно и постоянно отслеживается

Озеро данных

- Хранение данных в исходном виде
- Пусть бизнес сам решает, что ему нужно
- Поддержка быстрых изменений
- Возможность отслеживания и визуализации линии данных и истории использования данных
- Неструктурированное — поиск по ключевым словам
- Данные доступны в различных видах: от «сырых» данных до полностью соответствующих требованиям
- Параметры качества зачастую отсутствуют

Современная архитектура озера данных

- Структурирование данных при чтении
- Декриптивное моделирование данных
- Новые данные могут начать поступать в любое время и будут появляться задним числом
- Гибкость
- Масштабируемость
- Быстрый прием данных
- Подходит для исследований и подхода «снизу вверх»



**amazon
EMR**



Parquet



AWS Athena



S3 Bucket
Datalake

Резюме и ключевые слова



- Конвейеры обработки данных и вакансии
 - Еще одна компьютерная программа
 - Пакетное задание
- Разные типы компонентов
 - На основе машинного обучения, на основе онтологий, регулярных выражений, ...
- Тестирование конвейера
- Хранилище
 - Разные форматы: json, parquet и delta.io
 - Разные области: метаданные, озеро данных, область представления

Вопросы?



Темы

1. Обзор и краткое повторение
2. Что такое конвейер?
3. Уровень хранения
4. **Фреймворк Spark**
5. Лабораторная работа
 1. Поиск новых наименований должностей
 2. Поиск новых профессий



Де-факто стандартная унифицированная аналитическая платформа для **обработки больших данных**

Самый крупный проект с открытым исходным кодом в сфере обработки данных

Ключевые понятия и термины

- Общие ресурсы
- Распараллеливание
- Разделы
- Работы, этапы и задачи
- Драйверы
- Исполнители
- Кластер и узлы
- Ядра/потоки выполнения

Сможешь открыть
пачку...




...и съесть все
коричневые конфет










...за 60 секунд?

А как насчет 100 пачек M&Ms
за 60 секунд?













Инструкции: Съесть все
коричневые и сложить
остальные конфеты в кучку в
углу.










Некоторые люди
быстрее других...

И в то же время другие
медленнее, чем
некоторые...










4 наших работника
снова сидят без
дела...


Им нужно дать
новые задания!





Готово!

...и работают...

















Набор
данных






Работа Spark


Инструкции: отсеять все
коричневые конфеты и
сложить остальные в кучку в
углу.




Выполнение Spark



Кластер Spark



Spark API



Резюме и ключевые слова



- Spark
 - По факту стандартная обработка больших данных
- Ленивые вычисления
- Разделы набора данных
- Горизонтальное масштабирование
- Трансформации и компоненты

Вопросы?



Темы

1. Обзор и краткое повторение
2. Что такое конвейер?
3. Уровень хранения
4. Фреймворк Spark
- 5. Лабораторная работа**
 1. Поиск новых наименований должностей
 2. Поиск новых профессий

Цель

Обучить модель векторного представления слов, чтобы улучшить наши онтологии:

- начать с одной профессии
- создать корпус
- предварительная обработка
- обучить модель
- использовать модель для извлечения **НОВЫХ** наименований вакансий

Внедрение зависит от понятия **схожести слов**.

Очень полезное определение — парадигматическая схожесть:
Похожие слова употребляются в **схожих контекстах**. Они
взаимозаменяемые.

Вчера { POTUS
Президент
Обама } созвал пресс-конференцию

Интуиция: контекст также определяет СМЫСЛ



I eat an **apple** every day.

The diagram shows two curved arrows above the word 'apple'. The first arrow starts above 'eat' and points to 'apple'. The second arrow starts above 'apple' and points to 'every day', indicating the relationship between the verb and the object, and the object and the frequency.



I eat an **orange** every day.

The diagram shows two curved arrows above the word 'orange'. The first arrow starts above 'eat' and points to 'orange'. The second arrow starts above 'orange' and points to 'every day', indicating the relationship between the verb and the object, and the object and the frequency.



I like **driving** my **car** to work.

The diagram shows three curved arrows above the words 'driving' and 'car'. The first arrow starts above 'like' and points to 'driving'. The second arrow starts above 'driving' and points to 'car'. The third arrow starts above 'car' and points to 'to work', indicating the relationship between the verb and the activity, the activity and the object, and the object and the purpose.



+ Codice + Testo

Taxonomy improvement with Word-embeddings

Welcome!

In this notebook we first see an introduction about the concept of Word-Embedding and as we go on we'll learn how Word2Vec algorithms and see how can we implement them with the scope to improve our taxonomies (mainly ESCO occupations).

Please note that the main purpose of this notebook is to make familiar a beginner ML user with the mentioned concepts instead of focusing on the most efficient - or pythonic - way to write the code.

First we start by uploading the files we will use. This is a file with 25 observations: 5k for each occupation. We will start by processing one occupation.

```
[1] from google.colab import files
    _source = files.upload()
```

Choose Files esco_4occupations.csv

- **esco_4occupations.csv**(text/csv) - 1811573 bytes, last modified: 9/10/2020 - 100% done
Saving esco_4occupations.csv to esco_4occupations.csv

```
[2] import io
    import pandas as pd
    df = pd.read_csv(io.BytesIO(_source['esco_4occupations.csv']), sep = ',', delimiter=None, header='infer', encoding = 'utf-8')
    display(df)
```

Лабораторная работа


Поиск новых профессий

Цель

Использовать модель LDA для улучшения наших онтологий и извлечения новых сведений:

- начать с корпуса вакансий
- предварительная обработка
- применить некоторые методы тематического моделирования
- извлечь новые профессии

M Documents



Что означает «тема»?

Наблюдение

Одна группа слов, вероятно, будет встречаться в одном и том же **контексте**


Скрытая (т.е. неизвестная) структура, которая помогает определить, какие слова, вероятно, будут встречаться в корпусе

Тема — это распределение слов по фиксированному словарному составу

+ Codice + Testo

RAM Disco Modifica

Intertopic Distance Map (via multidimensional scaling)



Top-30 Most Relevant Terms for Topic 4 (11.9% of tokens)

