



Платформа Data Science-as-a-Service на технологиях Oracle

Олег Сиротюк

Ведущий консультант Oracle

Oleg.Sirotyuk@oracle.com

Safe Harbor Statement

The following is intended to outline our general product direction. It is intended for information purposes only, and may not be incorporated into any contract. It is not a commitment to deliver any material, code, or functionality, and should not be relied upon in making purchasing decisions. The development, release, timing and pricing of any features or functionality described for Oracle's products may change and remains at the sole discretion of Oracle Corporation.



**“Почему Oracle?
Потому что там хранятся
ваши данные!”**

Larry Ellison


Executive Chairman and CTO of Oracle Corporation



Платформа Data Science-как-Сервис

На стандартных технологиях Oracle

Производительность
Масштабируемость
Защита инвестиций
Безопасность



Только **1 из 10** проектов Data Science внедряется в промышленную эксплуатацию

Неэффективная коллаборация –
ключевое препятствие для DS проектов (**>60%**)

**Кибербезопасность и защита
данных** – наиболее актуальные разделы DS
проектов

Определение

Облачный сервис (частное или гибридное облако), предоставляющий экспертам необходимые инструменты, вычислительные ресурсы и данные для реализации проектов по машинному обучению и искусственному интеллекту



Рецепт платформы DataScience – as a –Service от Oracle

Целевые показатели

1. Создание сервиса **< 15** минут
2. Сбор и подготовка данных **МИНИМУМ** времени
3. Утилизация CPU **> 70%**
4. Сжатие данных **5-ТИ** кратное и более
5. Безопасность Все технологии СУБД Oracle


Рецепт DataScience – as a –Service от Oracle

Жизненный цикл сервиса

Владельцы данных публикуют информацию о доступных наборах данных в Каталоге

Платформа выделяет вычислительные мощности и место для данных

Эксперт использует созданный сервис из SQL инструментов, BI или ноутбуков



Эксперт использует Портал для запроса сервиса: требуемые вычислительные мощности, данные и способ их доставки

Платформа создает объекты БД (tables, views, external tables) и настраивает механизмы интеграции (Oracle Big Data SQL, ODI)

Сервис может быть удален через Портал или автоматически по истечению заданного срока годности



**Собираем решение из имеющихся компонентов
и добираем необходимые технологии**

Все! Сервисами можно пользоваться!



Уровень сервисов
ORACLE MULTitenant + OEM

In-Database ML / Python / R
ORACLE ADVANCED ANALYTICS

Хранилище данных
ORACLE DB EE

Аппаратная инфраструктура



Собираем решение из имеющихся компонентов и добираем необходимые технологии



Уровень сервисов
ORACLE MULTitenant + OEM

In-Database ML / Python / R
ORACLE ADVANCED ANALYTICS

Хранилище данных
ORACLE DB EE

Аппаратная инфраструктура



Собираем решение из имеющихся компонентов и добираем необходимые технологии



Уровень сервисов
ORACLE MULTitenant + OEM


In-Database ML / Python / R
ORACLE ADVANCED ANALYTICS

Акселератор аналитики
ORACLE DB IN-MEMORY

Безопасность
ORACLE ADVANCED SECURITY

Хранилище данных
ORACLE DB EE

Аппаратная инфраструктура




DATA LAKE



Платформа Data Science-как-Сервис

Технологии Oracle


- Производительность
- Масштабируемость
- Защита инвестиций
- Безопасность



Традиционный vs. Oracle In-Database ML подходы

Традиционный— “Переносите данные”

ORACLE® — “Переносите алгоритмы”



Проще, умнее управление данными
+ Аналитика / Machine Learning

СУБД Oracle: In-Database Machine Learning

Опция Oracle Advanced Analytics

- In-Database реализация >30 наиболее популярных алгоритмов ML
- Встроенные механизмы подготовки данных
- Создание сложных моделей
 - SQL, R или Python
 - Oracle Data Miner
 - Oracle AutoML²
- Не требуется отдельная инфраструктура (ML выполняется на сервере БД Oracle)
- Масштабируемые, параллельные алгоритмы Data Mining в ядре SQL

МИНИМИЗАЦИЯ ТСО

Не требуется дупликация данных

Не требуются выделенные сервера


Защита сделанных инвестиций

Быстрый time-to-market

Алгоритмы Oracle In-Database Machine Learning

CLASSIFICATION

- Naïve Bayes
- Logistic Regression (GLM)
- Decision Tree
- Random Forest
- Neural Network
- Support Vector Machine
- Explicit Semantic Analysis



CLUSTERING

- Hierarchical K-Means
- Hierarchical O-Cluster
- Expectation Maximization (EM)



ANOMALY DETECTION

- One-Class SVM




TIME SERIES

- State of the art forecasting using Exponential Smoothing
- Includes all popular models e.g. Holt-Winters with trends, seasons, irregularity, missing data



REGRESSION

- Linear Model
- Generalized Linear Model
- Support Vector Machine (SVM)
- Stepwise Linear regression
- Neural Network
- LASSO *




ATTRIBUTE IMPORTANCE

- Minimum Description Length
- Principal Comp Analysis (PCA)
- Unsupervised Pair-wise KL Div
- CUR decomposition for row & AI

ASSOCIATION RULES

- A priori/ market basket



PREDICTIVE QUERIES

- Predict, cluster, detect, features

SQL ANALYTICS

- SQL Windows, SQL Patterns, SQL Aggregates



FEATURE EXTRACTION

- Principal Comp Analysis (PCA)
- Non-negative Matrix Factorization
- Singular Value Decomposition (SVD)
- Explicit Semantic Analysis (ESA)



TEXT MINING SUPPORT

- Algorithms support text
- Tokenization and theme extraction
- Explicit Semantic Analysis (ESA) for document similarity



STATISTICAL FUNCTIONS

- Basic statistics: min, max, median, stdev, t-test, F-test, Pearson's, Chi-Sq, ANOVA, etc.



R PACKAGES

- CRAN R Packages through Embedded R Execution
- Spark MLlib algorithm integration



EXPORTABLE ML MODELS

- REST APIs for deployment




Пример: Создание классификатора

Создание ML модели (PL/SQL)

```
BEGIN
  DBMS_DATA_MINING.CREATE_MODEL(
    model_name          => 'BUY_INSUR1',
    mining_function     => dbms_data_mining.classification,
    data_table_name     => 'CUST_INSUR_LTV',
    case_id_column_name => 'CUST_ID',
    target_column_name  => 'BUY_INSURANCE',
    settings_table_name => 'CUST_INSUR_LTV_SET');
END;
```

Применение модели (SQL запрос)

```
Select prediction_probability(BUY_INSUR1, 'Yes'
  USING 3500 as bank_funds, 825 as checking_amount, 400 as credit_balance, 22 as age, 'Married' as
  marital_status, 93 as MONEY_MONTLY_OVERDRAWN, 1 as house_ownership)
from dual;
```



The screenshot shows the Oracle SQL developer interface. At the top, there are several icons: a red pin, a green document, a blue person, a red X, and the text 'SQL'. Below the icons, the status bar displays 'All Rows Fetched: 1 in 0.043 seconds'. The main area shows the SQL query and its execution results. The query is:

```
PREDICTION_PROBABILITY(BUY_INSUR1,'YES'USING3500ASBANK_FUNDS,825ASCHECKING_AMOUNT,400ASCREDIT_BALANCE
```

The result table has two columns: a header row and a data row. The data row shows the prediction probability for the given input values.

	PREDICTION_PROBABILITY(BUY_INSUR1,'YES'USING3500ASBANK_FUNDS,825ASCHECKING_AMOUNT,400ASCREDIT_BALANCE)
1	0.9276956709910801

Пример: Определение значимых атрибутов

Создание ML модели (PL/SQL)

```
BEGIN
    DBMS_DATA_MINING.CREATE_MODEL(
        model_name    => 'BUY_INSURANCE_AI',
        mining_function      => DBMS_DATA_MINING.ATTRIBUTE_IMPORTANCE,
        data_table_name    => 'CUST_INSUR_LTV',
        case_id_column_name => 'cust_id',
        target_column_name  => 'BUY_INSURANCE',
        settings_table_name => 'Att_Import_Mode_Settings');
END;
```

Применение модели (запрос SQL)


```
SELECT attribute_name, explanatory_value, rank
FROM BUY_INSURANCE_AI
ORDER BY rank, attribute_name;
```

ATTRIBUTE_NAME	RANK	ATTRIBUTE_VALUE
BANK_FUNDS	1	0.2161
MONEY_MONTLY_OVERDRAWN	2	0.1489
N_TRANS_ATM	3	0.1463
N_TRANS_TELLER	4	0.1156
T_AMOUNT_AUTOM_PAYMENTS	5	0.1095

Графический конструктор для проектов по ML

Oracle Data Miner

- Построение модели drag / drop
- Не требуется глубоких познаний в ML
- Легко в использовании, не надо кодировать
- Определение разделяемых аналитических процессов
- Генерация SQL кода



Автономный ML

Oracle AutoML²*



- Использует ML для создания новых моделей ML
- Существенное сокращение времени создания моделей
- Существенное увеличение точности
- Не требуется специальных знаний в ML для создания продуктивных и точных моделей





*Planned for Q1 2020 with Oracle Machine Learning for Python component of Oracle Advanced Analytics Option

Oracle AutoML в действии

Автоматический выбор алгоритма



Автоматический выбор атрибутов



Варианты использования Oracle AutoML

Python

Классификация

```
from automl import Pipeline


est = Pipeline(task='classification',
               scoring='accuracy')
est.fit(X_train, y_train)
y_pred = est.predict(X_test)
```

Регрессия

```
from automl import Pipeline


est = Pipeline(task='regression',
               scoring='neg_mean_squared_error')
est.fit(X_train, y_train)
y_pred = pipe.predict(X_test)
```

GUI




Работаем с данными из источников BigData технология Oracle BigData SQL


ORACLE SQL ДЛЯ BIGDATA



ORACLE DB SECURITY В HADOOP




ПРОИЗВОДИТЕЛЬНОСТЬ



- Анализ и сопоставление данных из гетерогенных источников
- Не требуется менять запросы приложений
- Унифицированные политики безопасности для BigData и БД
- Можно применять функции, такие как data redaction для связки (join) данных из различных источников
- SmartScan на уровне Hadoop
- Фильтрация, агрегация, исполнение функций на узлах данных



Изменяющая роль DBA: От разработчика БД к Data Scientist за 6 недель!



**Мы находимся на заре интеллектуальной, автономной эпохи, и наличие базы данных с самостоятельным управлением – естественный прогресс ...
Я чувствую, что автономные базы данных станут повсеместными в будущем.”**

– Clark A. Kho

Senior Technology Architect, Accenture

Автономная база данных избавляет от рутины

Больше времени для инноваций и улучшения бизнеса

- **Задачи, специфичные для бизнеса и инноваций**

- Архитектура, планирование, моделирование данных
- Безопасность данных и управление жизненным циклом
- Тюнинг приложений
- Комплексное управление уровнем обслуживания



Шкала ценности

Инновации

Обслуживание

- **Техническое обслуживание**

- ~~Конфигурирование и настройка систем, сети, хранилища~~
- ~~Подготовка базы данных, патчинг~~
- ~~Резервное копирование базы данных, Н / А, аварийное восстановление~~
- ~~Оптимизация базы данных~~



Эволюция разработчика БД в Эксперта по данным

Они уже выполняют большую часть работ

Выгрузка данных

Подготовка данных

Выявление новых атрибутов
("feature engineering")

...
... тут происходит «магия» Machine Learning

Импорт результатов

Внедрение ML

Автоматизация

До 80% проекта

Большинство экспертов тратят только 20% времени на анализ данных и до 80% времени - на поиск, очистку и реорганизацию данных¹




Исключено или минимизировано Oracle


Платформа управления данными становится платформой для проектов машинного обучения

От разработчика БД к Data Scientist за 6 недель!

- Исследование бизнеса — Неделя 1
- Понимание данных — Неделя 2
- Подготовка данных — Неделя 3
- Моделирование (ML) — Неделя 4
- Оценка — Неделя 5
- Развертывание — Неделя 6



От разработчика БД к Data Scientist за 6 недель!






Облако Oracle


Используйте облако Oracle для расчета трудоемких моделей

- Автономность
- Масштабируемость
- Производительность
- Экономика



Oracle ML аналогичный в Вашем ЦОДе и в облаке Oracle

Используем НРС облако Oracle для расчета ресурсоемких моделей



Oracle In-Database ML в ноутбуке


Oracle Autonomous DataWarehouse Cloud

```
%script
BEGIN
/* Populate settings table */
INSERT INTO glmr_sh_sample_settings (setting_name, setting_value) VALUES
  (dbms_data_mining.algo_name, dbms_data_mining.algo_generalized_linear_model);
-- output row diagnostic statistics into a table named GLMC_SH_SAMPLE_DIAG
INSERT INTO glmr_sh_sample_settings (setting_name, setting_value) VALUES
  (dbms_data_mining.glms_diagnostics_table_name, 'GLMR_SH_SAMPLE_DIAG');
INSERT INTO glmr_sh_sample_settings (setting_name, setting_value) VALUES
  (dbms_data_mining.prep_auto, dbms_data_mining.prep_auto_on);

-- turn on feature selection
INSERT INTO glmr_sh_sample_settings (setting_name, setting_value) VALUES
  (dbms_data_mining.glms_ftr_selection,
  dbms_data_mining.glms_ftr_selection_enable);

-- turn on feature generation
INSERT INTO glmr_sh_sample_settings (setting_name, setting_value) VALUES
  (dbms_data_mining.%sql
  dbms_data_minir SELECT caseID, elect, year,
  PREDICTION(GLMR_SH_Regr_sample USING *) pr
  FROM usa_elect_cons ORDER BY year);
END;
```

grid chart line settings ▾



```
%script
/* Clean up any previous GLM Models for notebook repeatability */
BEGIN
  DBMS_DATA_MINING.DROP_MODEL('usa_elec_cons_model');
EXCEPTION WHEN OTHERS THEN NULL;
END;
/

declare
  v_xlst dbms_data_mining_transform.TRANSFORM_LIST;
BEGIN
  DBMS_DATA_MINING.CREATE_MODEL(
    model_name      => 'usa_elec_cons_model',
    mining_function => dbms_data_mining.regression,
    data_table_name => 'usa_elect_cons',
    case_id_column_name => 'caseId',
    target_column_name => 'elect',
    settings_table_name => 'glmr_sh_sample_settings',
    xform_list        => v_xlst);
END;
```



SAVE THE DATE
**ANALYTICS AND DATA
SUMMIT 2020**

All Analytics. All Data.
No Nonsense.
February 25-27, 2020

Call for Speakers Now Open!

JOIN OUR USER COMMUNITY (FREE)

Formerly the BIWA Summit with the Spatial and Graph Summit.

@AnalyticAndData

