



# Разработка инструмента для сбора обогащенных AST

Автор: Е.С. Спирин, ММО201С

Научный руководитель: к.т.н., доцент Т.А. Брыксин

# Машинное обучение для кода

Появляется все больше работ по применению ML к программному коду – [1], [2], [3]

Способы представления кода в моделях

→ Текстовое представление

Токены кода представляют собой слова естественного языка

→ Абстрактные синтаксические деревья (ASTs)

Используют структурные особенности кода

◆ ASTs и его производные превосходят простые подходы – [4], [5], [6], [7]

[1] – Ferreira et al., “Software engineering meets deep learning: A mapping study”, 2020

[2] – Li et al., “Deep Learning & Software Engineering: State of Research and Future Directions”, 2019

[3] – Yang et al., “A Survey on Deep Learning for Software Engineering”, 2020

[4] – Mou et al., “Convolutional Neural Networks over Tree Structures for Programming Language Processing”, 2016

[5] – Zhang et al., “Retrieval-based neural source code summarization”, 2020

[6] – Alon et al., “A General Path-Based Representation for Predicting Program Properties”, 2019

[7] – Allamanis et al., “Learning to Represent Programs with Graphs”, 2018



# IntelliJ Platform и PSI деревья

[jetbrains.com/opensource/idea/](https://jetbrains.com/opensource/idea/)

Открытая платформа для разработки IDEs (IntelliJ IDEA, Android Studio, ...)

- Предоставляет функциональность по **работе с кодом**
  - ◆ Переименование сущностей
  - ◆ Перемещение фрагментов кода
  - ◆ Переход к местам объявлений или разрешение ссылок
  - ◆ Автодополнение кода
  - ◆ ...
- Использует Program Structure Interface (PSI) для **представление кода**
  - ◆ Хранит в себе конкретное синтаксическое дерево (CST) программы
  - ◆ Предоставляет функции для работы с деревом

# Цель и задачи

**Цель:** разработка инструмента по извлечению и обработке PSI деревьев из IntelliJ Platform.

## **Задачи:**

1. провести обзор предметной области;
  - a. изучить способы представления кода в моделях машинного обучения;
  - b. изучить способы работы с кодом в IntelliJ Platform;
2. спроектировать и разработать инструмент по извлечению и обработке PSI деревьев из IntelliJ Platform;
3. провести апробацию разработанного инструмента.


# PSIMiner – главное

- Использует алгоритмы статического анализа платформы IntelliJ Platform для извлечения обогащенных представлений кода
- Строит готовый к обучению набор данных по исходному коду
  - ◆ Уже содержит популярные сценарии подготовки данных
  - ◆ Расширяется для большего количества сценариев использования с помощью готовых интерфейсов
- Поддерживает Java и Kotlin
  - ◆ PSI доступен для множества популярных языков
  - ◆ Гибкая архитектура позволяет добавлять новые языки



# PSIMiner – технические детали

- PSIMiner – плагин к IntelliJ IDEA, работающей в headless режиме
- Две логические части:
  - ◆ Извлечение и обработка PSI деревьев
  - ◆ Создание набора данных под нужную задачу и модель
- В любой момент можно добавить логику по извлечению новой информации




# PSIMiner – пример обогащения

## Возможное применение

### → Добавление информации о типах в листья AST

- ◆ Если лист соответствует переменной – добавляем ее тип
- ◆ Если лист соответствует вызову функции – добавляем тип возвращаемого значения
- ◆ Специальные токены для листьев с операторами, ключевыми словами.
- ◆ ...




# Модификация моделей

## Code2seq

[Alon et al. “Code2seq: Generating Sequences from Structured Representations of Code”](#)

- AST представляется в виде набора путей – последовательность вершин между двумя листьями
- Кодер строит векторное представление каждого пути




[JetBrains-Research/code2seq](https://jetbrains-research.github.io/code2seq/)

# Модификация моделей

## TreeLSTM

[Tai et al. "Improved Semantic Representations From Tree-Structured Long Short-Term Memory Networks"](#)

- Адаптация ячейки LSTM для работы с деревьями
- Ячейка строит векторное представление поддерева по состояниям дочерних вершин и информации в текущей вершине



[JetBrains-Research/  
embeddings-for-trees](#)

# Результаты модификаций

Сравнение оригинальной и расширенной типами code2seq моделей на задаче предсказания имени метода

| Dataset    | Model         | Precision    | Recall       | F1 score     |
|------------|---------------|--------------|--------------|--------------|
| Java-small | Original      | 38.76        | 28.63        | 32.93        |
|            | Type-enhanced | <b>41.68</b> | <b>29.76</b> | <b>34.73</b> |
| Java-med   | Original      | <b>51.38</b> | 39.08        | 44.39        |
|            | Type-enhanced | 49.15        | <b>42.35</b> | <b>45.5</b>  |

Сравнение оригинальной и расширенной типами TreeLSTM моделей на задаче предсказания имени метода

| Dataset    | Model         | Precision    | Recall       | F1 score     |
|------------|---------------|--------------|--------------|--------------|
| Java-small | Original      | 35.39        | 23.59        | 28.31        |
|            | Type-enhanced | <b>36.06</b> | <b>25.13</b> | <b>29.62</b> |

# Результаты

1. Проведен обзор предметной области. Изучены способы представления кода в ML-моделях и способы работы с кодом в IntelliJ Platform.
2. Спроектирован и разработан PSIMiner, инструмент для извлечения и обработки PSI деревьев из IntelliJ Platform.
3. Проведена апробация инструмента. С помощью PSIMiner в AST была добавлена информация о типах листовых вершин, что повысило качество ML-моделей.

Результаты работы частично представлены на конференции MSR'21 ([Paper](#), [Demo](#))



[JetBrains-Research/psiminer](https://github.com/JetBrains-Research/psiminer)



[JetBrains-Research/code2seq](https://github.com/JetBrains-Research/code2seq)



[JetBrains-Research/  
embeddings-for-trees](https://github.com/JetBrains-Research/embeddings-for-trees)

# Неопубликованные результаты

## → Поддержка нескольких языков

- ◆ PSI деревья поддерживают множество языков
- ◆ PSIMiner предоставляет ряд интерфейсов по добавлению новых языков
- ◆ Добавлена поддержка Kotlin

## → Разделение инструмента на Core и CLI

- ◆ Часть логики PSIMiner направлена на запуск headless IntelliJ IDEA и обработку входных параметров
- ◆ Теперь основную логику легче переиспользовать в сторонних проектах

## → Дополнительный эксперимент с добавлением типов


- ◆ Модифицирована модель TreeLSTM для работы с типами

# Абстрактное синтаксическое дерево

- Представление результата синтаксического анализа программы в виде дерева
  - ◆ Внутренняя вершина – применение продукции грамматики
    - Какая операция выполняется над детьми
  - ◆ Листовая вершина – терминал
    - Операнд (токен) – переменная, литерал, другая функция и т.п.
- Результат работы синтаксического анализа компилятора
- Исследуются на протяжении очень долгого времени


# Абстрактное синтаксическое дерево

```
char getChar(int a) {  
    return (char)a;  
}
```



# PSI дерево

```
char getChar(int a) {  
    return (char)a;  
}
```



# Пример конфигурации

```
{
  "filters": [
    {
      "name": "constructor"
    },
    {
      "name": "empty method"
    },
    {
      "name": "by modifiers",
      "excludeModifiers": ["abstract"]
    }
  ],
  "label": {
    "name": "method name prediction"
  },
  "storage": {
    "name": "json typed tree"
  },
  "languages": ["Java", "Kotlin"],
  "node ignore rules": [
    {
      "name": "whitespace"
    },
    {
      "name": "empty grammar lists"
    },
    {
      "name": "keywords"
    },
    {
      "name": "java symbols"
    }
  ],
  "tree transformations": [
    {
      "name": "compress operators"
    },
    {
      "name": "hide literals",
      "hideNumbers": true
    },
    {
      "name": "remove comments",
      "removeJavaDoc": false
    }
  ],
  "printTrees": false
}
```

# Выделение нужной гранулярности

- Единицей набора данных в коде могут выступать
  - ◆ Метод  
Method name prediction, move method refactoring, ...
  - ◆ Класс  
Class name prediction, ...
  - ◆ Файлы  
Классификация алгоритмов (POJ-104), поиск дубликатов, ...
- Пользователь сам задаёт необходимый уровень гранулярности
- PSIMiner разбивает исходные PSI на нужный уровень
  - ◆ Поддерживается функция, класс и файл.

# Фильтрация AST

Garbage in – garbage out

```
protected abstract fun isGoodTree(  
    root: PsiElement,  
    language: Language  
): Boolean
```

- Удаление конструкторов даёт улучшение на задачи предсказания имён функций
- Поддерживаются
  - ◆ Фильтр функций по модификаторам, аннотациям, наличию тела
  - ◆ Фильтр на основе числа строк кода
  - ◆ Фильтр на основе размера дерева

# Выделение меток

Часто используется self-supervised подход при обучении моделей

```
protected abstract fun handleTree(  
    root: PsiElement,  
    language: Language  
): String?
```

- Метка для каждого примера извлекается из самого примера
  - ◆ Имя функции
  - ◆ JavaDoc или docstring
- Извлечение метки требует и обработки примера чтобы избежать утечку в данных
  - ◆ Если используем имя функции, то надо убедиться, что в коде/AST не осталось этого имени – маскирование

# Сохранение на диск

Разные модели  $\Rightarrow$  разный формат входных данных (пути, деревья, графы...)

```
protected abstract fun convert(  
    labeledTree: LabeledTree,  
    outputDirection: OutputDirection  
): String
```

Поддерживается

→ Code2seq storage


get|type|signature json|value,3|2,<MN> type|signature,4|2,<MN> json|value,3|4,type|signature

→ JSON AST storage (Python150K)

```
{"label": "get|type|signature",  
  "AST":  
    [{"node": "METHOD", "children": [1, 2, 3], "token": "<EMPTY>"},  
     {"node": "MODIFIER_LIST|ANNOTATION|JAVA_CODE_REFERENCE|IDENTIFIER", "token": "json|value"},  
     {"node": "TYPE|JAVA_CODE_REFERENCE|IDENTIFIER", "token": "type|signature"},  
     {"node": "IDENTIFIER", "token": "<MN>"}]}
```

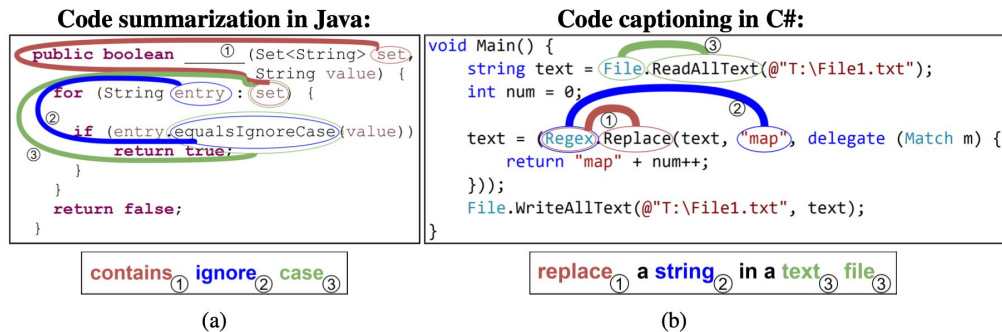
# Утечка в данных

- Результаты ванильного code2seq значительно ниже, чем в оригинальной работе на тех же данных
- Нашли утечку в данных – в оригинальной работе не маскировались рекурсивные вызовы функций
- Повторение утечки поднимает “качество” до заявленных чисел



# Code2seq

[Alon et al. "Code2seq: Generating Sequences from Structured Representations of Code"](#)



## 1. Token embedding

- Токен разбивается на подтокены  
mySuperVariable → [my, super, variable]
- Вектор токена – сумма векторов подтокенов


## 2. Path embedding

- Вектор пути – результат применения bi-LSTM

$$z = \tanh(W_{in} [encode\_path(v_1 \dots v_l); encode\_token(value(v_1)); encode\_token(value(v_l))])$$

# Tree-LSTM

[Tai et al. "Improved Semantic Representations From Tree-Structured Long Short-Term Memory Networks"](#)



$$\tilde{h} = \sum_{k \in C(t)} h_k,$$

$$i = \sigma(W_i x_t + U_i \tilde{h} + b_i),$$

$$u = \tanh(W_u x_t + U_u \tilde{h} + b_u),$$

$$o = \sigma(W_o x_t + U_o \tilde{h} + b_o),$$

$$f_k = \sigma(W_f x_t + U_f h_k + b_f) \forall k \in C(t),$$

$$c_t = (i \odot u) \oplus \sum_{k \in C(t)} f_k \odot c_k,$$

$$h_t = o \odot \tanh c_t,$$

# PSIMiner – пример обогащения

```
fun resolveType(node: PsiElement): String {
    return when {
        ElementType.OPERATION_BIT_SET.contains(node.elementType) → OPERATOR
        node.parent is PsiLiteralExpression → extractFromLiteral(node)
        node is PsiKeyword → KEYWORD
        node is PsiIdentifier → {
            val resolvedType = extractFromIdentifier(node)
            if (resolvedType == NO_TYPE || !splitTypes) return resolvedType
            else splitTypeToSubtypes(resolvedType).joinToString("|")
        }
        else → NO_TYPE
    }
}

private fun extractFromLiteral(node: PsiElement): String =
    node.parentOfType<PsiLiteralExpression>()?.type?.presentableText ?: NO_TYPE
```