



Harry Potter and Why Functional Programming Matters

Развлекательная
социальная сеть
Одноклассники

2016

Виталий Худобахшов




Содержание

- Не все то золото, что функционально
- Больше свободы = больше ответственности
- Анализ данных и MapReduce как функциональное программирование на каждый день
- Стримоз, ФП головного мозга и прочие болезни
- Кейсы

4 Функциональное программирование (Haskell)



4 ООП (Java)



4 Смешанная парадигма (Scala)





Все что вы хотели знать о ФП, но боялись спросить

7 Основные принципы



ООП

- Инкапсуляция
- Полиморфизм
- Наследование



8 Основные принципы

ООП

- ~~Инкапсуляция~~ (есть в любых языках кроме ассемблера)
- ~~Полиморфизм~~ (зависит от системы типов)
- Наследование



9 Основные принципы

Функциональное программирование

- Функции как объекты 1-ого класса
- Рекурсия
- Сопоставление с образцом
- ~~Алгебраические типы~~
- Каррирование
- неизменяемость



10 Функции как объекты 1-ого класса

Что это значит

- Функции можно передавать в качестве параметра
- Возвращать в качестве значения

Где это реализовано

- Lisp (1958), ML (1973), Erlang (1987), Haskell (1990), Python (1991), R (1993), Scala (2003), Clojure (2007), C++ (2011), Kotlin (2011), Java (2014)

11 Рекурсия



Что это значит (в теории)

- Циклов нет (хвостовая рекурсия)

Что это значит (на практике)

- Частичный отказ от циклов в пользу функций `map`, `fold` и `filter` позволяет лучше структурировать код

12 Сопоставление с образцом



Теория

- Код красивый и понятный
- Умный компилятор точно скажет, где и что ты забыл
- Особенно хорошо, если ты пишешь компилятор/интерпретатор

Практика

- Кое где работает медленно
- Плохо сочетается с циклами
- Используется только для деконструкции



13 Левая свертка (в теории)

Как должно бы быть

```
@tailrec
def foldLeft[A, B](f: (B, A) => B)(z: B)
  (list: List[A]): B = list match {
    case Nil => z
    case x :: xs => foldLeft(f)(f(z, x))(xs)
  }
```



14 Левая свертка (на практике)

List.foldLeft в Scala

```
def foldLeft[B](z: B)(f: (B, A) => B): B = {  
    var acc = z  
    var these = this  
    while (!these.isEmpty) {  
        acc = f(acc, these.head)  
        these = these.tail  
    }  
    acc  
}
```



15 Левая свертка (альтернативный вариант)

Что на счет этого варианта?

```
@tailrec
def foldLeft2[A, B](f: (B, A) => B)(z: B)
    (list: List[A]): B =
if (list.isEmpty) z else foldLeft2(f)(f(z, list.head))
    (list.tail)
```

16 Каррирование



Теория

```
def add(x: Int, y: Int) = x + y
def add(x: Int)(y: Int) = x + y
def add(x: Int) = (y: Int) => x + y
```

```
def sum = foldLeft((x: Int, y: Int) => x + y)(0) _
```

Практика

1. foldLeft(f)(z)
2. foldLeft(z)(f)

17 Каррирование



Теория

```
def add(x: Int, y: Int) = x + y
def add(x: Int)(y: Int) = x + y
def add(x: Int) = (y: Int) => x + y
```

```
def sum = foldLeft((x: Int, y: Int) => x + y)(0) _
```

Практика

1. `foldLeft(f)(z)` $\Rightarrow$ `sumWithAcc = foldLeft(+) _`
2. `foldLeft(z)(f)` $\Rightarrow$ `?????`

18 Каррирование



Вывод №1

- Если каррирование не является «синтаксически прозрачным», это сводит на нет все его плюсы

Вывод №2

- 7 раз отмерь – 1 раз отрежь

19 Неизменяемость



Теория

- Отсутствие присваивания
- Любая обработка структуры данных приводит к появлению новой структуры
- Высокий уровень параллелизма

Практика

- Дозированное использование состояния
- Основной паттерн обработки (больших) данных

20 Очень тяжелый случай



Почему это плохо?

```
val m: Map[String, Int] = ...  
m.map(x => (x._1, x._2 * x._2))
```



21 Очень тяжелый случай

Почему это плохо?

```
val m: Map[String, Int] = ...  
m.map(x => (x._1, x._2 * x._2))
```

А если так?

```
m.map(x => ("foo", x._2))
```



22 Почему это плохо на самом деле?


`map(id) = id`

`map(g ∘ f) = map(g) ∘ map(f)`

4 Вывод



Компилятор языка Scala
должен останавливать
каждого, кто не читал эту
книгу!





Анализ данных и ФП

25 Кто такие датамайнеры?



Это те люди, которые используют функциональное программирование чаще других



27 Из чего состоит анализ данных



Обработка данных

- Выборка
- Очистка
- Агрегация

MapReduce/SQL

Построение модели

- Машинное обучение
- Тестирование модели

MapReduce

28 Больше данных – больше ответственность



Особенности MapReduce парадигмы

- Неизменяемость
- Ассоциативность редукции
- Данные представляют собой пары (key, value)
- Эти данные являются распределенными



29 Что такое shuffle?

Shuffle для обычного программиста за 2 минуты

```
val rdd = sc.textFile(...)
rdd.flatMap {
    line => line.split(' ')
}.map((_, 1))
.reduceByKey((a, b) => a + b).collect()
```

- Чтобы просуммировать значение для двух одинаковых ключей, соответствующие пары *должны быть на одном вычислительном узле*



Кейсы

31 Кейс №1: The Good, the Bad and the Ugly



Постановка задачи

- Около 200 млн пользователей
- Не все пользователи указали свой истинный возраст
- Как оценить истинный возраст пользователей?

Исходные данные

- Социальный граф как список смежности с некоторыми размеченными связями
- Таблица известных возрастов пользователей

32 Вариант 1



JOIN, JOIN - и в продакшн

```
(userId, [friendId1, friendId2, ...]) => // flatMap  
  
(friendId, userId) => // join  
  
(friendId, (userId, birthYear)) => // map  
  
(userId, [(friendId, birthYear)]) => // reduceByKey  
  
(userId, [(friendId1, birthYear), ...])
```


33 Вариант 2



Есть же DataFrames и SQL

```
graph.flatMap {  
  r =>  
    val userId = r._1  
    val friends = r._2  
    friends.map(x => (userId, x._1))  
}.toDF("USER_ID", "OTHER_USER_ID").  
  write.parquet("users/graph_pairs")
```

34 Вариант 3: свободный стиль



А вдруг shuffle будет очень большим?

- 200 млн пользователей * среднее количество друзей = очень много пар
- А можно совсем без JOIN?

35 Если очень хочется, то можно!



1. Разделить информацию о возрасте на части
2. Для всех полученных частей
 - Сделать так, чтобы эта часть была на всех узлах
 - Для каждого пользователя в графе проставить нужную информацию о возрасте его друзей
 - Для тех друзей, которые не попали в эту часть, оставить значение по умолчанию
3. Рассчитать возраст исходя из возраста друзей

36 Шаг 1 - Split



```
val customers = sqlc.sql("SELECT USER_ID, BIRTH_YEAR  
FROM customers")
```

```
customers.map(r => (r.getLong(0), r.getInt(1)))  
  .randomSplit(splitWeights, 3)  
  .zipWithIndex  
  .foreach {  
    x =>  
      x._1.saveAsObjectFile(s"split-${x._2}")  
  }
```

37 War 2 - Broadcast



```
(0 until splitFactor).foreach { s =>
  val splitGraph = sc.objectFile(s"users-graph-$s")
  val split = sc.objectFile(s"split-$s")
  split.collect()
    .foreach(x => hashMap.put(x._1, x._2))
  val bc = sc.broadcast(hashMap)
  val next = s + 1
  ...
}
```



38 Шаг 2 – вместо JOIN

```
...
splitGraph.map { x =>
    val hm = bc.value
    val friendsWithBD = x._2.map { u =>
        if (u._3 == 0) {
            val v = hm.get(u._1) // 0 если нет
            (u._1, u._2, v)      // (Long, Long, Int)
        } else u
    }
    (x._1, friendsWithBD)
}.saveAsObjectFile(s"users-graph-$next")
...
```

39 Шаг 3 – все просто



Расчет вариантов возраста

- Можно взять одноклассников и посмотреть их возраст
- То же самое с сокурсниками
- Можно найти самую большую группу пользователей среди друзей с одинаковым возрастом
- Выбрать наиболее подходящий вариант

40 Who is who?



Результаты для разных вариантов

- | | | |
|------------------------|----------|----------|
| • Вариант 1 (ФП) | 15 минут | The Good |
| • Вариант 2 (ФП + SQL) | 15 минут | The Ugly |
| • Вариант 3 (Mix) | ~5 часов | The Bad |

41 Кейс №2: Как сделать рекомендации



Постановка задачи

- 200 млн пользователей
- 10 млн групп
- Как рекомендовать группу конкретному пользователю

Исходные данные

- Набор пар (userID, groupID)



4 Как сделать рекомендации

```
(userId, groupId) => // map
(userId, [groupId]) => // reduceByKey

(userId, [group_1, group_2, group_3 ...]) => // flatMap

((group_1, group_2), 1)
((group_1, group_3), 1)
((group_2, group_3), 1)
... => // reduceByKey

((gid1, gid2), #number_of_shared_users)
```



43 Немного императивного кода

Функция `genPairs()`

```
def genPairs(seq: Seq[Long]): Seq[((Long, Long), Int)] = {  
    val buf = new ArrayBuffer[((Long, Long), Int)](seq.size * seq.size >> 1)  
    var i = 0  
    var j = 0  
    while (i < seq.size) {  
        while (j < seq.size) {  
            val x = seq(i)  
            val y = seq(j)  
            if (x > y) buf.append(((x, y), 1))  
            j += 1  
        }  
        i += 1  
    }  
    buf  
}
```

44 Как сделать рекомендации



Реализация

```
pairs.map{
  case (userId, groupId) => (userId, Seq(groupId))
}.reduceByKey((a, b) => a ++ b)
.flatMap(m => genPairs(m._2))
.reduceByKey((a, b) => a + b)
.filter(x => x._2 > minimumSharedUsers)
.map {
  case ((groupId1, groupId2), sharedUsers) =>
    ...
}
```

45 Выводы



- Нужно перестать бояться и начать использовать Spark
- Оптимизируйте правильно
- Держитесь в рамках выбранной парадигмы, если это не вредит
- Используйте сильные стороны разных парадигм

4 Кое что о названии и что почитать



Why Functional Programming Matters by John Hughes

- Why Functional Programming Matters by John Hughes from “Research Topics in Functional Programming” ed. D. Turner, Addison-Wesley, 1990, pp 17–42.

Structure and Interpretation of Computer Programs

- <https://ocw.mit.edu/courses/electrical-engineering-and-computer-science/6-001-structure-and-interpretation-of-computer-programs-spring-2005>



ОДНОКЛАССНИКИ