Функциональное программирование

КОМБИНАТОРНЫЕ ПАРСЕРЫ ДЛЯ ПРОСТЫХ СМЕРТНЫХ

Немного о проекте

1. Распределенный API: по 22 сервера в 2-х датацентрах (Америка, Европа).
2. Разнообразные клиентские приложения: 40 desktop и web приложений.
3. Датацентр обрабатывает 12 000 запросов в минуту.
4. Ресурсоёмкие запросы и пакетные запросы.

С чего все началось?

Возникла необходимость добавить новый источник данных HBase.

Что такое HBase?

- NoSql – <ключ значение>;
- написана на Java;
- аналог Google Big table;
- не является заменой SQL;
- интерфейсы взаимодействия: REST, Java API, Apache THRIFT.

AVRO

1. Apache Avro — система сериализации данных.
2. Система использует JSON для определения структуры данных (схемы), которые сериализуются в компактный бинарный формат.

AVRO – схема

```
{
  "namespace": "com.acme",
  "protocol": "HelloWorld",
  "doc": "Protocol Greetings",

  "types": [
    {"name": "Greeting", "type": "record", "fields": [
      {"name": "message", "type": "string"}]},
    {"name": "Curse", "type": "error", "fields": [
      {"name": "message", "type": "string"}]}
  ],

  "messages": {
    "hello": {
      "doc": "Say hello.",
      "request": [{"name": "greeting", "type": "Greeting" }],
      "response": "Greeting",
      "errors": ["Curse"]
    }
  }
}
```

HBase + Thrift-AVRO + .NET = ?

Workflow

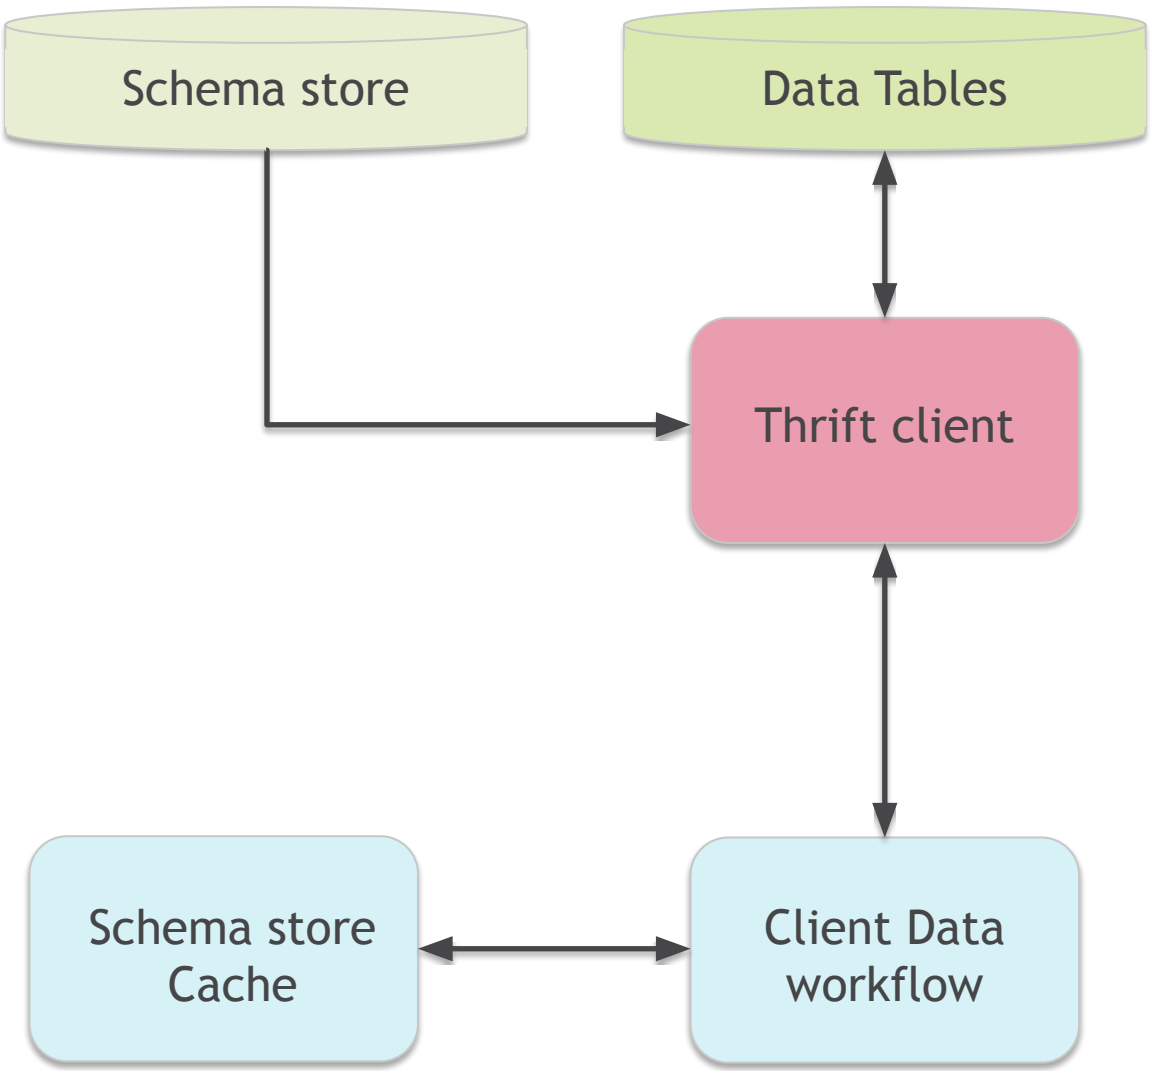
Schema store
Data Tables
Thrift client
Schema store
Cache
Client Data
workflow

Требования

1. META-DRIVEN;
2. результат – простая таблица;
3. возможность выполнять Map/Reduce;
4. сохранить отношения данных;

Проблемы

- большие вложенные AVRO схемы до 1 000 000 строк;
- AVRO не дружит с .NET;
- после десериализации AVRO Dictionary<string, object>.

Что делать?

А давайте напишем свой DSL!

Разработка синтаксиса

```
query(view: "TABLENAME") {

  //simple selector
  Selector

  //nested-field selector
  Selector.Next

  Selector.Next.Value.ID
  Selector.Next.Value.InnerValue

  //nested-object selector
  Selector.Next.Value {
    ID
    InnerValue
  }

  //nested-array selector
  Selector.Next.Values((ID >= 1 AND ID <= 100) AND (InnerValue = "Hello" OR InnerValue="World")) [
    ID
    InnerValue
  ]
}
```

А давай еще **Join's**

```
query(view: "first_table") {
  //ID Selector
  Selector.ID

  //other selectors
  Value
} with(view: "second_table" fetchkeys: first_table:Selector.ID) {
  //ID Selector
  Target.ID

  //other selectors
  Values.Next
} leftjoin (

  first_table:Selector.ID = second_table:Target.ID

) with(view: "third_table" fetchkeys: first_table:Selector.ID second_table:Target.ID) {
  //ID Selector
  Company.ID
  Apple.Value

  //other selectors
  Values.Next
} leftjoin (
  first_table:Selector.ID = third_table:Company.ID
  AND
  second_table:Target.ID = third_table:Apple.Value
)
```

А как быстро написать парсер?

Парсинг(синтаксический анализ текста)

ОБЩИЙ ПОДХОД

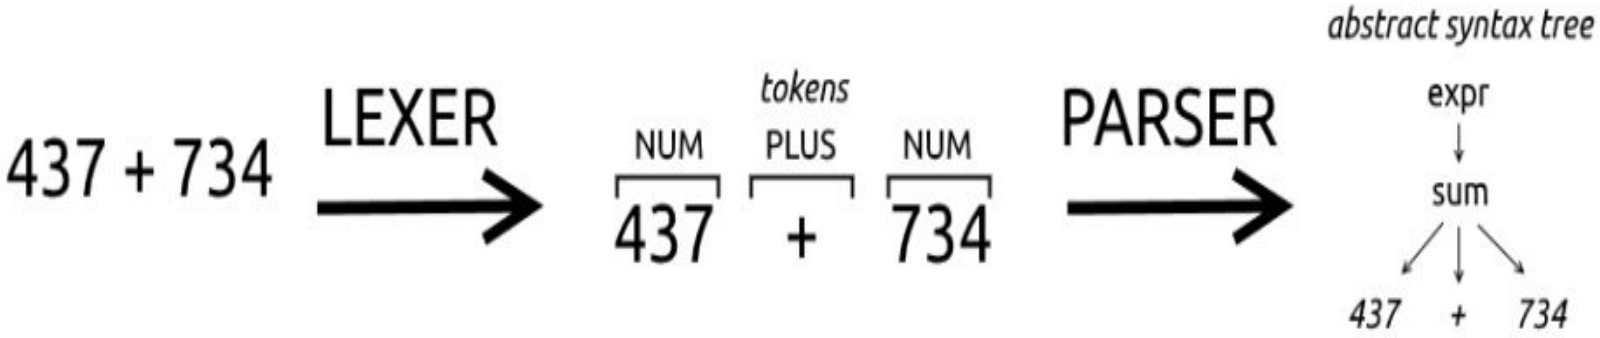

Выбор

1. Парсер генератор на основе формальных языков (ANTLR).
2. Подключаемая библиотека комбинаторных парсеров (Sprache, SuperPower).
3. …

Написать руками

Генератор на основе формальных языков

ANTLR (Another Tool for Language Recognition)

```
grammar Expr;
prog:   (expr NEWLINE)* ;
expr:   expr ('*'|'/')
expr
    |   expr ('+'|'-')
expr
    |   INT
    |   '(' expr ')'
    ;
NEWLINE : [\r\n]+ ;
INT     : [0-9]+ ;
```

Расширенная форма Бэкуса — Наура

Генератор на основе формальных языков

Плюсы

- декларативный синтаксис;
- строгое соблюдение грамматики;
- не нужно думать о performance;
- не нужно писать документацию.

Недостатки

- строгие грамматики;
- интеграция с системой сборки;
- тяжело отлаживать;
- кастомные ошибки;
- медленные парсеры;
- проблемы с кодировками;
- проблемы переносимости.

Комбинаторные парсеры **(Sprache** и т.д.**)**

Плюсы

- реализован как библиотека языка;
- модульный и поддерживаемый;
- полуавтоматическая генерация сообщений об ошибках;
- backtracking и look ahead;
- возможности в runtime;
- не требует предварительной токенизации(лексера).

Недостатки

- компромисс между декларативностью производительностью;
- проблемы с левой рекурсией;
- придется учить API;
- только для вашего языка.
- может не иметь предварительной токенизации.

Рукописные парсеры

Плюсы

- никакого внешнего кода;
- поддается к индивидуальным требованиям;
- потенциально быстр, как только это возможно.

Недостатки

- все писать с 0;
- создание быстрых парсеров требует опыта;
- выражения с инфиксными операторами(приоритеты).

Основные концепции:

- неизменяемые структуры данных;
- чистые функции;
- функции высших порядков;
- рекурсия.

Императивное vs Функциональное

```
List<int> values = new List<int>();

for (int i = 0; i < 42; i++)
    values.Add(i);

List<int> evenNums = new List<int>();
foreach (var value in values)
{
    if (value % 2 == 0)
        evenNums.Add(value);
}

return evenNums;
```

```
var evenNums = Enumerable.Range(0, 42)
                         .Where(num => num % 2 == 0)
                         .ToList();
```

```
let evenNums = [0..42]
               |> List.where(fun num -> num % 2 = 0)
```

1. Написать примитивные парсеры(функции).
2. Написать функции для комбинирования.
3. Скомбинировать простые парсеры в более сложные.
4. PROFIT!

Сигнатура нашего парсера

```
type Parser = String -> Tree
```

```
type Parser = String -> (String, Tree)
```

```
type Parser<T> = String -> (String, T)
```

```
type Parser<TInput, T> = TInput -> (TInput, T)
```

Пишем простой комбинаторный парсер

Выражение : **“42 + 5”**

42 + 5

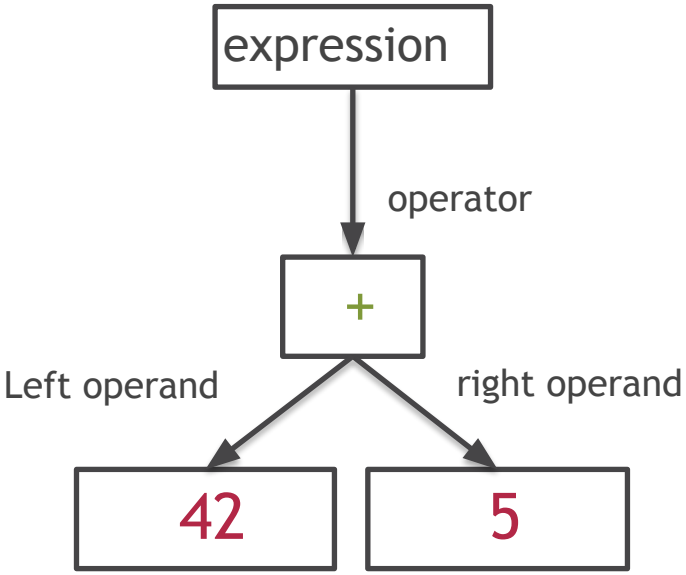

Парсим простое выражение : “42 + 5”

```
Int ::= [0-9]+
AddExpr ::= Int '+' Int
```

Грамматика в БНФ

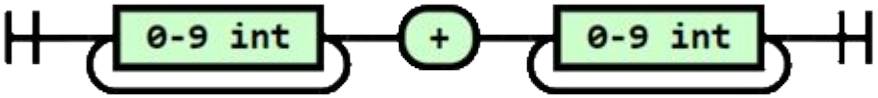

Railroad - диаграмма

Библиотеки с готовым набором комбинаторных парсеров для C#

Sprache https://github.com/sprache/Sprache

- небольшая библиотека, совместима .NET Core;
- простой, но богатый API;
- много используется в “боевых проектах”: R#, Octostache, EasyNetQ, Seq.

Superpower https://github.com/datalust/superpower

- форк Sprache с блэк джеком и …;
- использует токинезатор;
- парсит потоки токенов, а не поток символов;
- хорошие сообщения об ошибках, легко кастомизируются;
- работает быстрее.

Готовый код парсера для “42 + 5”

```
public static class CalcParserExample
{
    private static readonly Parser<ConstantExpression> Constant =
        from number in Parse.Number.Token()
        select Expression.Constant(int.Parse(number));

    private static readonly Parser<char> AddOperator =
        from addOperator in Parse.Char('+').Token()
        select addOperator;

    private static readonly Parser<BinaryExpression> SumExpression =
        from lop in Constant
        from  addOperator  in AddOperator
        from rop in Constant
        select Expression.Add(lop, rop);

    public static Expression<Func<int>> ParseExpression(string input)
    {
        var body = SumExpression.Parse(input);
        return Expression.Lambda<Func<int>>(body);
    }
}
```

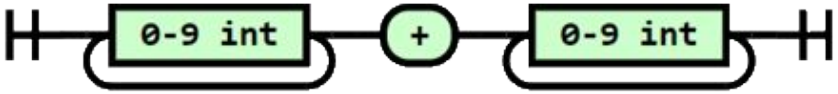

Ну, а как же без TDD?

```
[TestFixture]
internal class ParserTests
{
    [Test]
    public void CalculatorTest()
    {
        string input = "42 + 5";

        Expression<Func<int>> expression = CalcParserExample.ParseExpression(input);
        int result = expression.Compile()();

        Assert.AreEqual(47, result);
    }

    [Test]
    public void CalculatorFailTest()
    {
        Assert.Catch<Exception>(() =>
        {
            string input = "f + 14";

            Expression<Func<int>> expression = CalcParserExample.ParseExpression(input);
            int result = expression.Compile()();
        }, "unexpected f, expected: Numeric character");
    }
}
```

Давайте усложним : “42 + 5 - 7”

```
Int ::= [0-9]+
Opertator ::= '+' | '-'

Expr ::= Expr Operator Expr | Int
```

Грамматика в БНФ

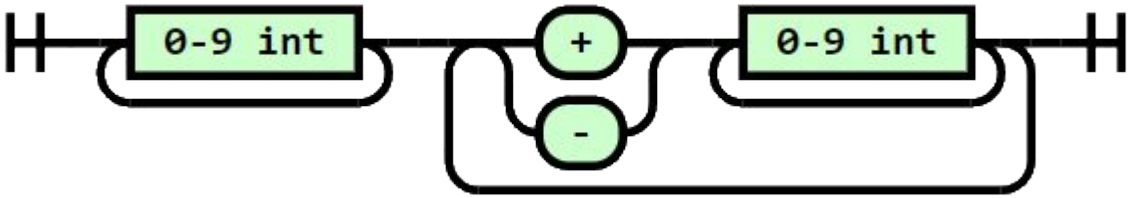

Railroad - диаграмма

Парсер на Sprache “42 + 5 - 7”

```
public static class SpracheCalcParser
{
    private static Parser<ExpressionType> CreateOperator(string op, ExpressionType type)
    {
        return Parse.String(op).Token().Return(type);
    }

    private static readonly Parser<ExpressionType> Add = CreateOperator("+", ExpressionType.Add);
    private static readonly Parser<ExpressionType> Subtract = CreateOperator("-", ExpressionType.Subtract);

    private static readonly Parser<Expression> Operand =
        from number in Parse.Number.Token()
        select Expression.Constant(int.Parse(number));

    private static readonly Parser<Expression> MainExpression =
        Parse.ChainOperator(
            Add.Or(Subtract),
            Operand,
            Expression.MakeBinary);

    public static Expression<Func<int>> ParseExpression(string input)
    {
        var body = MainExpression.Parse(input);
        return Expression.Lambda<Func<int>>(body);
    }
}
```

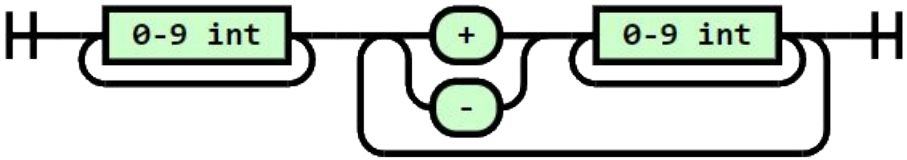

Когда и зачем писать свои парсеры?

- DSL (Domain-specific language) Пример: XPath, SQL;
- использование NoSQL;
- не хватает всей “Мощи” XML;
- разработка IDE или плагинов к ним;
- клиентские приложения, например, поиск;
- анализ документов.

Что внутри?

```
public delegate Result<TValue> Parser<TValue>(Input input);


public static class ParserExtensions
{
    public static T Parse<T>(this Parser<T> parser, string input)
    {
        var result = parser(new Input(input));

        if (result.WasSuccessful)
            return result.Value;

        throw new Exception(result.Message);
    }
}
```

Тип Result<T>

```
public struct Result<T>
{
    public T Value { get; }
    public bool WasSuccessful { get; }
    public string Message { get; }
    public Input Remainder { get; }

    public Result(string errorMessage)
    {
        Value = default(T);
        Remainder = default(Input);

        Message = errorMessage;
        WasSuccessful = false;
    }

    public Result(T value, Input remainder, bool wasSuccessful, string errorMessage)
    {
        Value = value;
        WasSuccessful = wasSuccessful;
        Message = errorMessage;
        Remainder = remainder;
    }

    public static Result<T> Success(T inputCurrent, Input remainder)
        => new Result<T>(inputCurrent, remainder, true, string.Empty);

    public static Result<T> Failure(string errrorMessage) => new Result<T>(errrorMessage);
}
```

Тип Input (обертка над string)

```
public struct Input
{
    public string Source { get; }
    public int Position { get; }

    public char Current => Source[Position];
    public bool AtEnd => Position == Source.Length;

    public Input(string source)
    {
        Source = source;
        Position = 0;
    }

    public Input(string source, int position)
    {
        Source = source;
        Position = position;
    }

    public Input GetRemainder() => new Input(Source, Position + 1);
}
```

Начнем с простых парсеров

```
public static class Parse
{
    // predicate: (current == "a")
    // input: "abc" -> result (success, value: "a", remainder: "bc")
    public static Parser<char> Char(Func<char, bool> predicate, string description)
    {
        return i =>
        {
            if (!i.AtEnd)
            {
                return predicate(i.Current)
                    ? Result<char>.Success(i.Current, i.GetRemainder())
                    : Result<char>.Failure($"unexpected {i.Current}, expected: {description}");
            }

            return Result<char>.Failure("Unexpected end of string");
        };
    }
    // target: 'a'
    // input: "abc" -> result (success, value: "a", remainder: "bc")
    public static Parser<char> Char(char target)
    {
        return Char(current => current == target, target.ToString());
    }

    // input: " abc" -> result (success, value: " ", remainder: "abc")
    public static readonly Parser<char> WhiteSpace = Char(char.IsWhiteSpace, "WhiteSpace");
    // input: "11 + 2" -> result (success, value: "1", remainder: "1 + 2")
    public static readonly Parser<char> Numeric = Char(char.IsNumber, "Numeric character");
```

Пишем первый комбинирующий парсер

```
public static Result<U> IfSuccess<T, U>(this Result<T> result, Func<Result<T>, Result<U>> next)
{
    return result.WasSuccessful
        ? next(result)
        : Result<U>.Failure(result.Message);
}
```

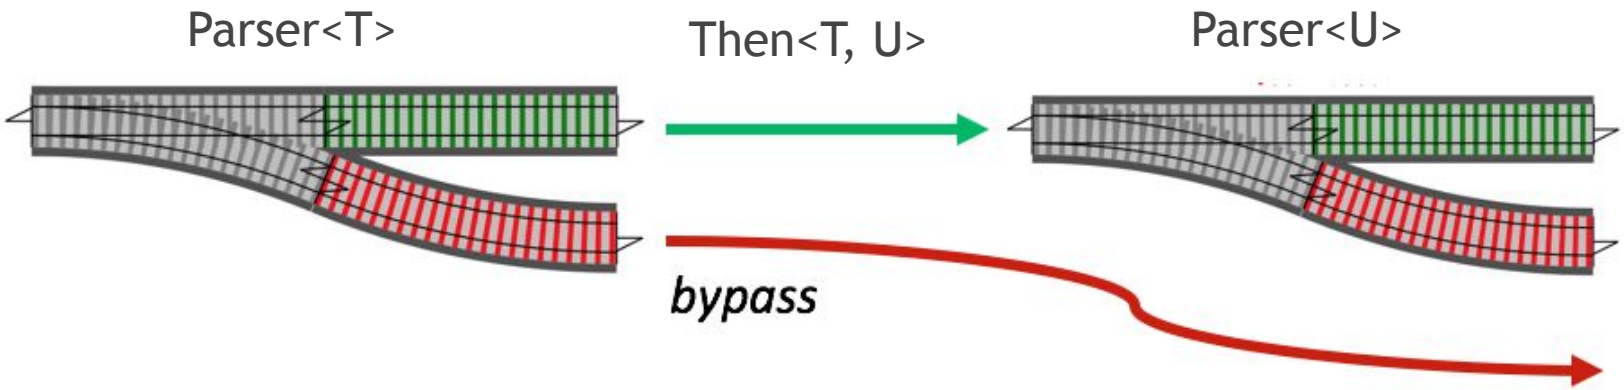


```
// parse('-') then parse('Number')
// input: "-1 + 5" -> result (success, value: "-1", remainder: "+ 12")
public static Parser<U> Then<T, U>(this Parser<T> first, Func<T, Parser<U>> second)
{
    return i => first(i).IfSuccess(s => second(s.Value)(s.Remainder));
}
```

Строим путь к LINQ’s query синтаксису

```
//maps T to Parser<T>
public static Parser<T> Return<T>(T value)
{
    return i => Result<T>.Success(value, i);
}

//maps/selects result from T to U.
public static Parser<U> Select<T, U>(this Parser<T> parser, Func<T, U> convert)
{
    return parser.Then(t => Return(convert(t)));
}

// maps Parse<IEnumerable<char>> to Parse<string>
public static Parser<string> Text(this Parser<IEnumerable<char>> characters)
{
    return characters.Select(chs => new string(chs.ToArray()));
}
```

Комбинируем

```
// like LINQ's SelectMany
public static Parser<V> SelectMany<T, U, V>(
    this Parser<T> parser,
    Func<T, Parser<U>> selector,
    Func<T, U, V> projector)
{
    return parser.Then(t => selector(t).Select(u => projector(t, u)));
}

// input parser: Parser<int>
// input: " 123 + 12" -> result (success, value: "123", remainder: "+ 12")
public static Parser<T> Token<T>(this Parser<T> parser)
{
    return from leading in WhiteSpace.Many()
           from item in parser
           from trailing in WhiteSpace.Many()
           select item;
}
```

Полный код на **GitHub**

HASL – HBase Avro Snapshot Language

Фрагмент из клипа Thrift shop ☺️

Разработка

- прототип был написан за 1 вечер на Sprache;
- был переписан на Superpower;
- в дальнейшем все изменения занимали 1-2 часа.

Что получилось достичь за **1** день**?**

```
query(view: "TABLENAME") {

  //simple selector
  Selector

  //nested-field selector
  Selector.Next

  Selector.Next.Value.ID
  Selector.Next.Value.InnerValue

  //nested-object selector
  Selector.Next.Value {
    ID
    InnerValue
  }

  //nested-array selector
  Selector.Next.Values((ID >= 1 AND ID <= 100) AND (InnerValue = "Hello" OR InnerValue="World")) [
    ID
    InnerValue
  ]
}
```

Особенности HASL

1. Транформирует объекты в таблицу.
2. Ориентирован на AVRO-схему.
3. Селекторы для всех типов: object, type[], примитивы.
4. Фильтры для [].
5. API функций для сложных вычислений и фильтраций.
6. Поддержка Join’ов.

Перформанс **HASL -** Основа

1. Core-I7 6700 3.40 GHz.
2. Windows server 2010.
3. x64.

Перформанс **HASL** – Тестовые данные

1. 3 424 знаков.
2. 120 строк.
3. 3 Join’a.
4. 102 селектора.
5. 25 с фильтрами.
6. Полностью отформатирован.

Перформанс **HASL -** Результаты

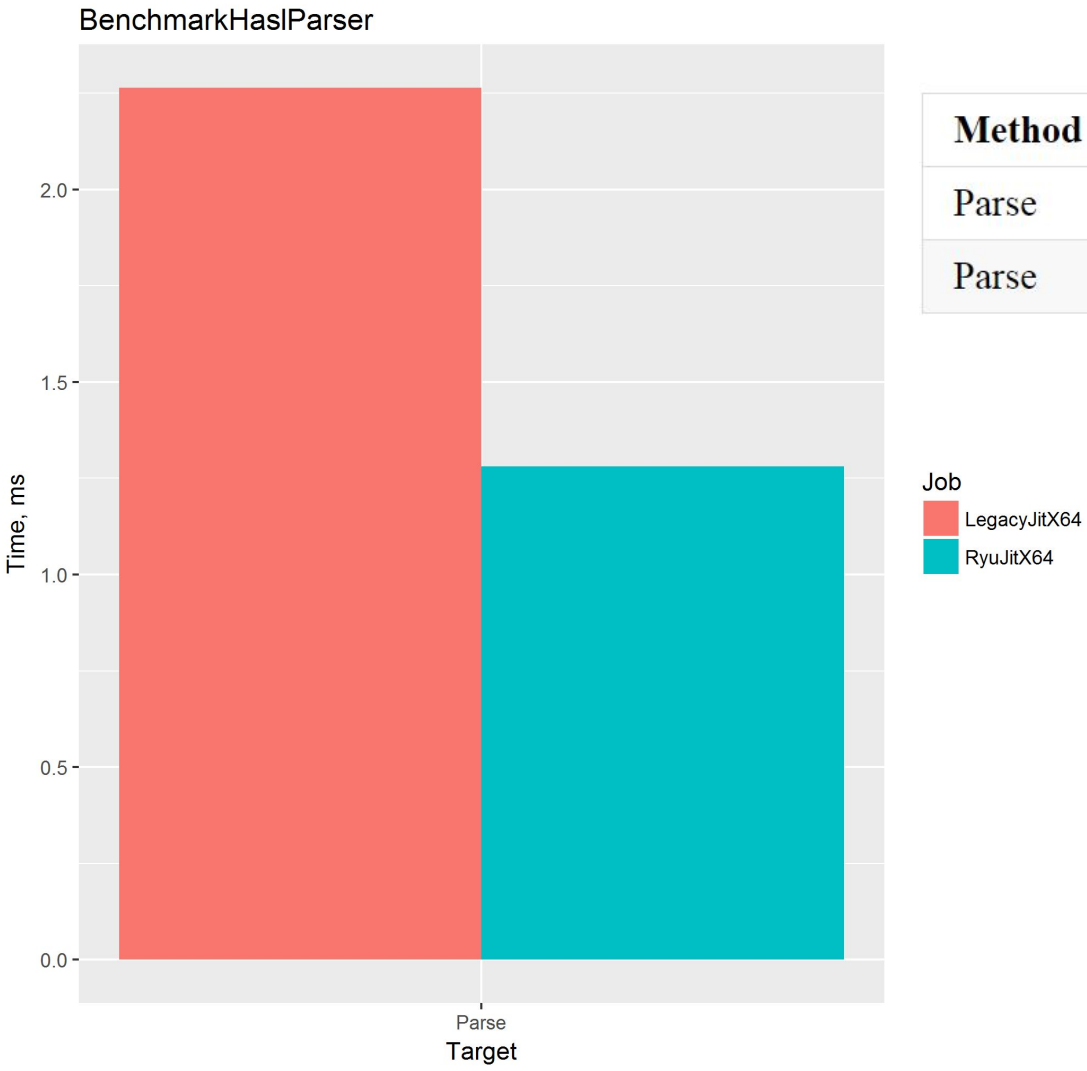

Method	Job	Jit	Mean
Parse	LegacyJitX64	LegacyJit	2.2644 ms
Parse	RyuJitX64	RyuJit	1.2813 ms

BenchmarkDotNet v0.10.3.0

Схема

```
1  {
2      "Apple":{
3          "Id":"long",
4          "Name":"String"
5      },
6      "AppleTraders":{
7          "AppleTrader":[
8              {
9                  "Id":"long",
10                 "Name":"String",
11                 "TraderCompany":{
12                     "Id":"long",
13                     "Name":"String"
14                 }
15             }
16         ]
17     }
18 }
```

Пример запроса

```
1  query {
2    //bad part
3    Apple.Id
4    AppleTraders.AppleTrader.Name
5    AppleTraders.AppleTrader.TraderCompany.Id
6    AppleTraders.AppleTrader.TraderCompany.Name
7
8    //cool part
9    Apple.Id
10   AppleTraders.AppleTrader(Name="Antonovka" AND TraderConpany.Id = 405000) [
11     Name
12     TraderCompany {
13       Id
14       Name
15     }
16   ]
17 }
```

Результат

Apple.Id	AppleTraders.AppleTrader.Name	TraderCompany.Id	TraderCompany.Name
1	Company1	405000	“Antonovka”
1	Company2	405000	“Antonovka”
1	Company3	405000	“Antonovka”
2	Company1	405000	“Antonovka”

Спасибо за внимание!

Sprache

Superpower

Вопросы?

scala.util.parsing.combinator.Parsers.Parser
def *: Parsers.this.Parser[scala.List[T]]
Returns a parser that repeatedly parses what this parser parses.
Returns:
rep(this)