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

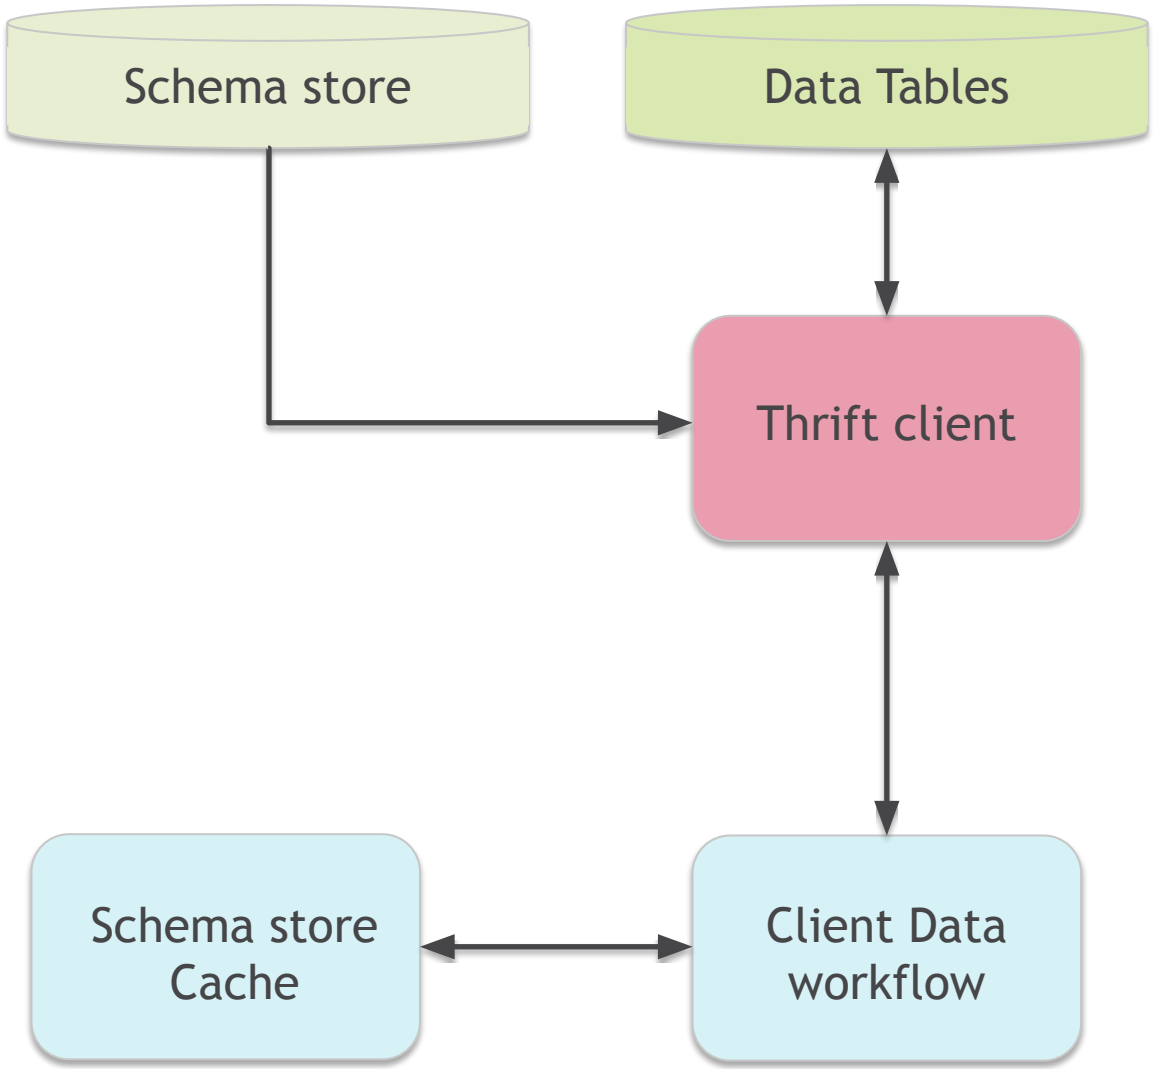
Schema store
Data Tables
Thrift client
Schema store
Cache
Client Data
workflow

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

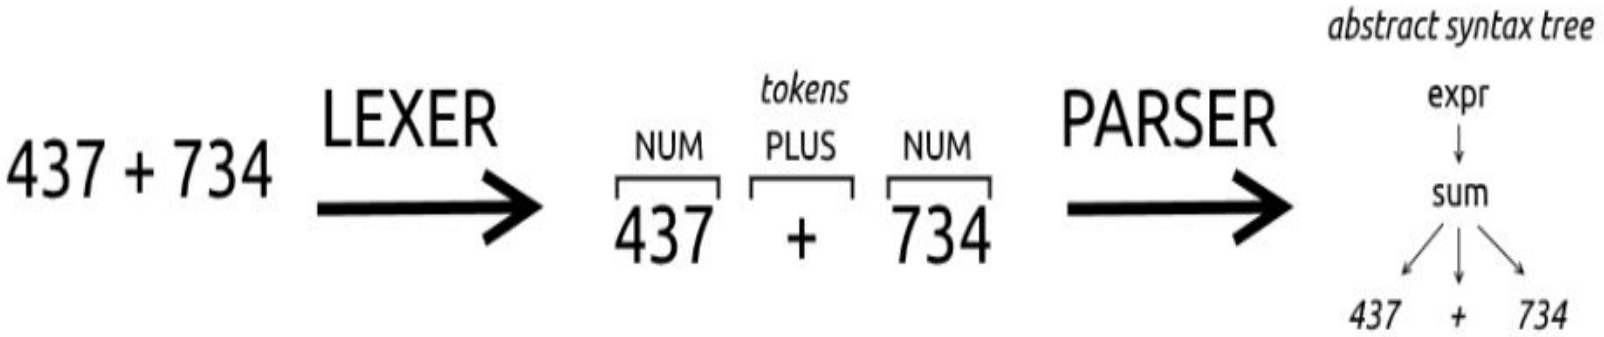

Выбор

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

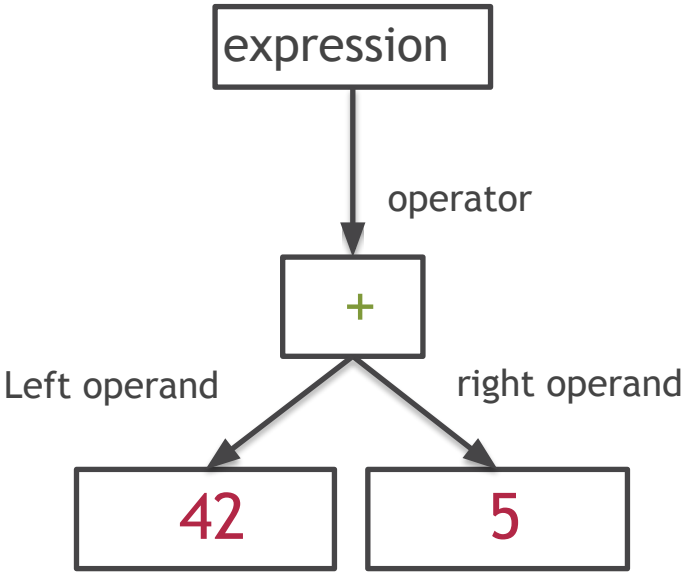

Парсим простое выражение : “42 + 5”

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

Грамматика в БНФ

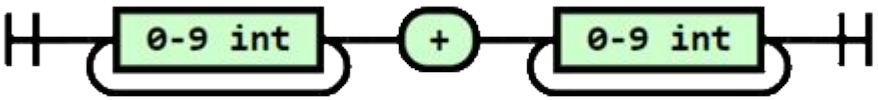

Railroad - диаграмма

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);
    }
}
```

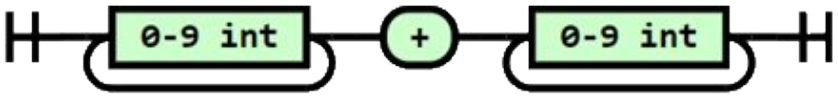

Ну, а как же без TDD?

```
[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

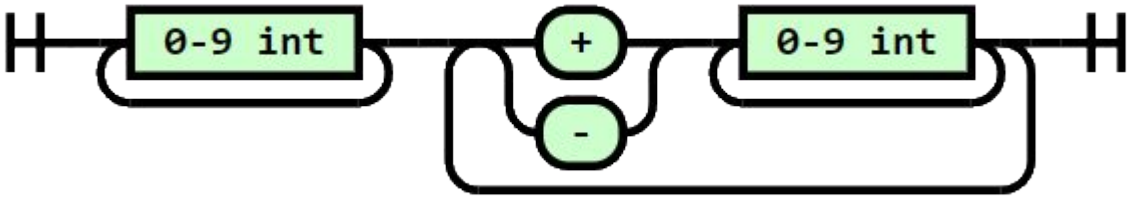

Railroad - диаграмма

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);
    }
}
```

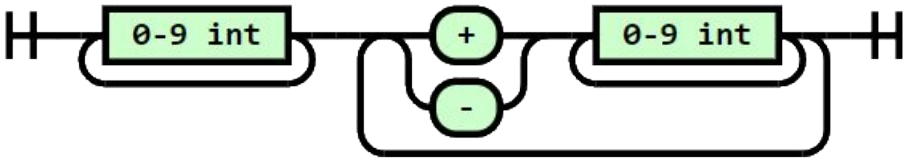

Когда и зачем писать свои парсеры?

- 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);
}
```

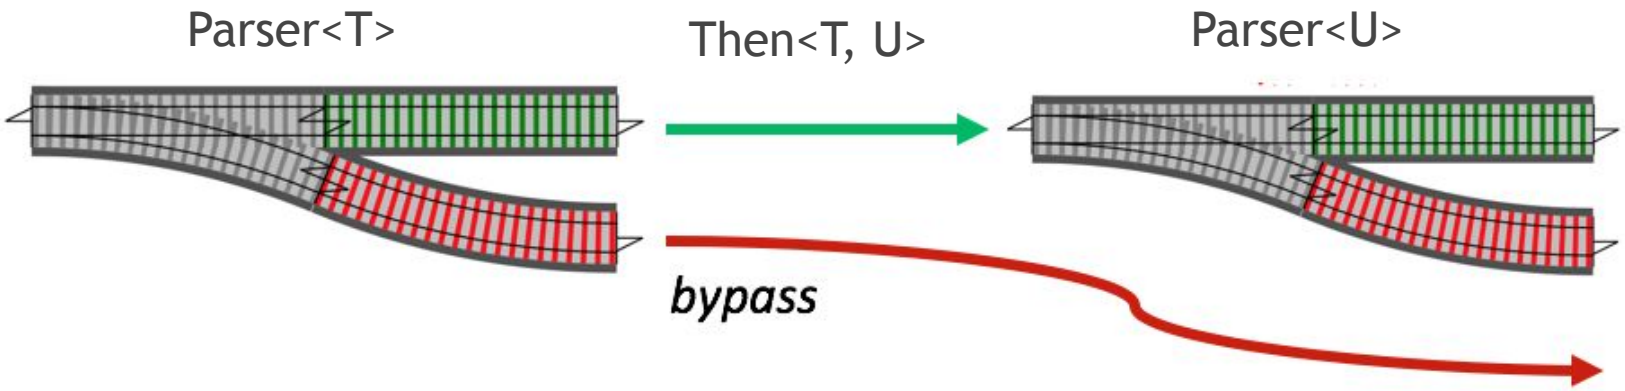


```
// parse('-') then parse('Number')
// input: "-1 + 5" -> result (success, value: "-1", remainder: "+ 12")
public static Parser<U> Then<T, U>(this Parser<T> first, Func<T, Parser<U>> second)
{
    return i => first(i).IfSuccess(s => second(s.Value)(s.Remainder));
}
```

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’а.
4. 102 селектора.
5. 25 с фильтрами.
6. Полностью отформатирован.

Перформанс **HASL -** Результаты

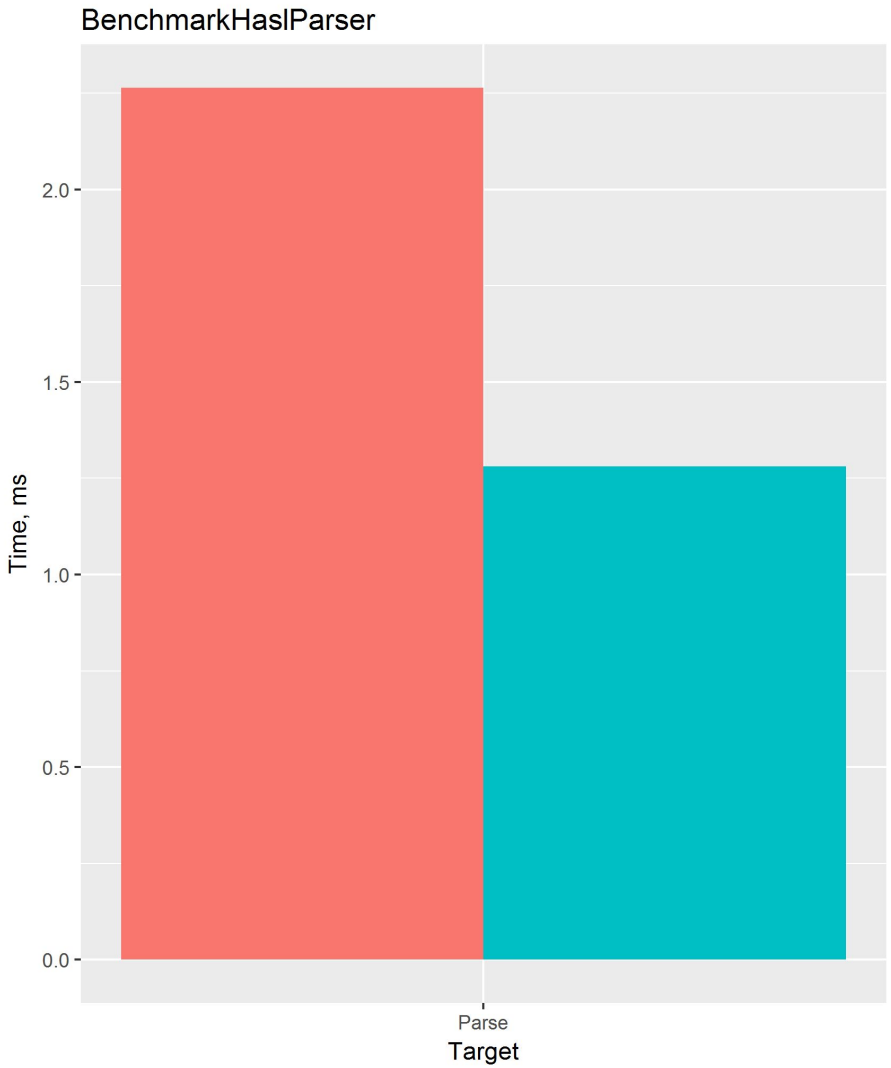

Method	Job	Jit	Mean
Parse	LegacyJitX64	LegacyJit	2.2644 ms
Parse	RyuJitX64	RyuJit	1.2813 ms

BenchmarkDotNet v0.10.3.0

Схема


{
"Apple":{
"Id":"long",
"Name":"String"
},
"AppleTraders":{
"AppleTrader":[
{
"Id":"long",
"Name":"String",
"TraderCompany":{
"Id":"long",
"Name":"String"
}
}
]
}
}

Пример запроса

```
query {
  //bad part
  Apple.Id
  AppleTraders.AppleTrader.Name
  AppleTraders.AppleTrader.TraderCompany.Id
  AppleTraders.AppleTrader.TraderCompany.Name

  //cool part
  Apple.Id
  AppleTraders.AppleTrader(Name="Antonovka" AND TraderConpany.Id = 405000) [
    Name
    TraderCompany {
      Id
      Name
    }
  ]
}
```

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)