DotNext 2021 Piter

Простая и быстрая реализация парсеров на C#

Karlen Simonyan
Lead software engineer @ UBS

Обо мне

- Работаю в Security IT / IAM @ UBS
- Занимаюсь созданием приложений, API и фреймворков для внутреннего пользования
- Автор atomics.net

Об ожиданиях

- Данный доклад будет полезен, если Вы:
  - Хотите создать свой DSL для пользователей либо же пытаетесь реализовать существующую грамматику
  - Но нет опыта создания и поддержки такого рода продуктов :)
  - For fun & profit!

Цели

- Познакомить с комбинаторами парсеров
- Показать отличия от генераторов парсеров
- Оценить доступные инструменты для C# / .NET
- Убедить в полезности комбинаторов на прикладном примере с LDAP filters

Предисловие

Welcome to my world :)

- Абсолютно разные источники данных
- Каждая система имеет свой язык запросов для удобства 😬

Как это выглядит?

- Разнообразие обычных СУБД:
  - MS SQL Server, Oracle, Sybase
- SIEM:
  - Splunk SPL
- LDAP
  - MS AD, OUD и т.д.
- JSON для описания всего:
  - Elasticsearch 

  - MongoDB 

- Мимикрия под SQL
  - Cassandra CQL 

- Поддержка лишь части ANSI SQL:
  - Azure Cosmos DB 

ИМХО

- На вершине всего этого - LDAP-сервера со своим первобытным языком запросов aka LDAP filters
  - Не являются чем-то проприетарным (RFC-4515)
  - Имеют диковинный синтаксис
  - Не SQL…

Введение

Инструменты

Что есть из готового?

- System.DirectoryServices + System.DirectoryServices.Protocols
  - ❌ Нет API для парсинга
  - Обёртка вокруг libldap.so либо wldap32.dll

Что есть из готового?

- Novell.Directory.Ldap
  - ❌ API возвращает уже конвертированный в формат ASN.1 объект
    - Бинарный протокол

```
public abstract class Asn1Object
{
    public abstract void Encode(IAsn1Encoder enc, Stream outRenamed);
    public virtual Asn1Identifier GetIdentifier();
    public virtual void SetIdentifier(Asn1Identifier id);
    public byte[] GetEncoding(IAsn1Encoder enc);
}
```

Что есть из готового?

- ASN.1 [1]

```
30 13 02 01 05 16 0e 41 6e 79 62 6f 64 79 20 74 68 65 72 65 3f
```

```
30 – type tag indicating SEQUENCE
13 – length in octets of value that follows
  02 – type tag indicating INTEGER
  01 – length in octets of value that follows
    05 – value (5)
  16 – type tag indicating IA5String
     (IA5 means the full 7-bit ISO 646 set, including variants,
      but is generally US-ASCII)
  0e – length in octets of value that follows
    41 6e 79 62 6f 64 79 20 74 68 65 72 65 3f – value ("Anybody there?")
```

```
<FooQuestion>
    <trackingNumber>5</trackingNumber>
    <question>Anybody there?</question>
</FooQuestion>
```

[1] https://en.wikipedia.org/wiki/ASN.1#Example_encoded_in_DER

Задача

1. Извлечение структурированной информации
   - ❖ Мало работающих под .NET проектов 🤔
   - ❖ ⇒ Нужно делать свой велосипед ¯_(ツ)_/¯
2. Лимит по времени?
   - ❖ не более пары вечеров

Построение парсеров

Построение парсеров

- Генераторы парсеров:
  - bison+flex
  - ANTLR
  - Coco/R
  - GOLD
  - … и т.д.

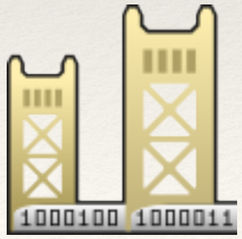

- Комбинаторы парсеров:
  - Parsec
    - FParsec
    - JParsec
    - … и т.д.

А как же Regex?

- Pros:
  - Просто, быстро и неправильно
- Cons:
  - Только регулярная грамматика (КО)
  - ❌ Невозможно использовать для контекстов-свободных грамматик
    - Не пытайтесь!

Генераторы парсеров

Примеры применения

- Apache Cassandra использует ANTLR для своего языка CQL [1] 

- Webkit ранее использовал bison & flex для парсинга CSS [2] 
- PostgreSQL использует набор bison & flex для парсинга PL/pgSQL [3] 

[1] https://github.com/apache/cassandra/blob/trunk/src/antlr/Cql.g
[2] https://github.com/WebKit/webkit/blob/master/Source/WebCore/css/CSSGrammar.y.in
[3] https://www.postgresql.org/docs/current/parser-stage.html

Описание грамматики

- Описывается через форму Бэкуса — Наура BNF [1] (EBNF [2], ABNF [3])
  - ✔ yacc/bison, ANTLR и т.п.
  - ✘ Свои особенности синтаксиса у каждого

[1] https://en.wikipedia.org/wiki/Backus–Naur_form
[2] https://en.wikipedia.org/wiki/Extended_Backus–Naur_form
[3] https://en.wikipedia.org/wiki/Augmented_Backus–Naur_form

Структура парсера

- Процесс делится на 2 этапа:
  - лексический анализ (tokenization)
  - синтаксический анализ (parsing)

Что такое ANTLR?

- ANTLR — (ANother Tool for Language Recognition) is a powerful parser generator for reading, processing, executing, or translating structured text or binary files. It's widely used to build languages, tools, and frameworks. From a grammar, ANTLR generates a parser that can build and walk parse trees. [1]

- [1] https://www.antlr.org/

Какие плюсы есть у ANTLR?

- Огромное количество уже готовых грамматик
- Поддержка множества целевых языков (Java, C#, Python2|3, JavaScript, Go, C++ и т.д.)
- Поддержка обхода AST и много ещё чего
- Большое сообщество

Простой пример ANTLR

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

```
$ antlr4 Expr.g4
$ javac Expr*.java
$ grun Expr prog -gui
100+2*34
^D
```

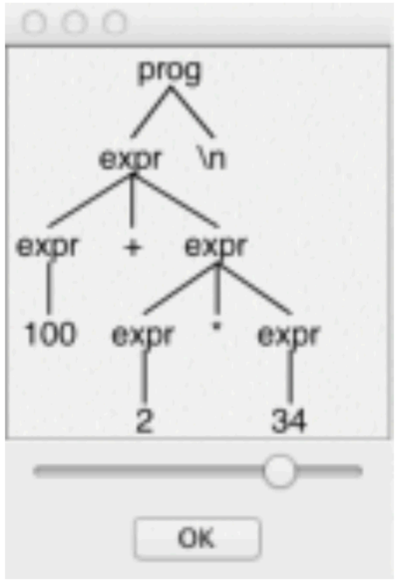

[1] https://www.antlr.org

Почему сразу же не использовать ANTLR?

- Необходимо переводить описания из BNF в формат самого ANTLR
- У проекта есть свой API, требующий углубления, а времени мало
- При необходимости кастомизации требуется много дополнительного кода
- Яркий пример - Apache Cassandra

Почему сразу же не использовать ANTLR?

- Получаемый конечный автомат является тяжеловесным и его компиляция может даже падать [1] [2]

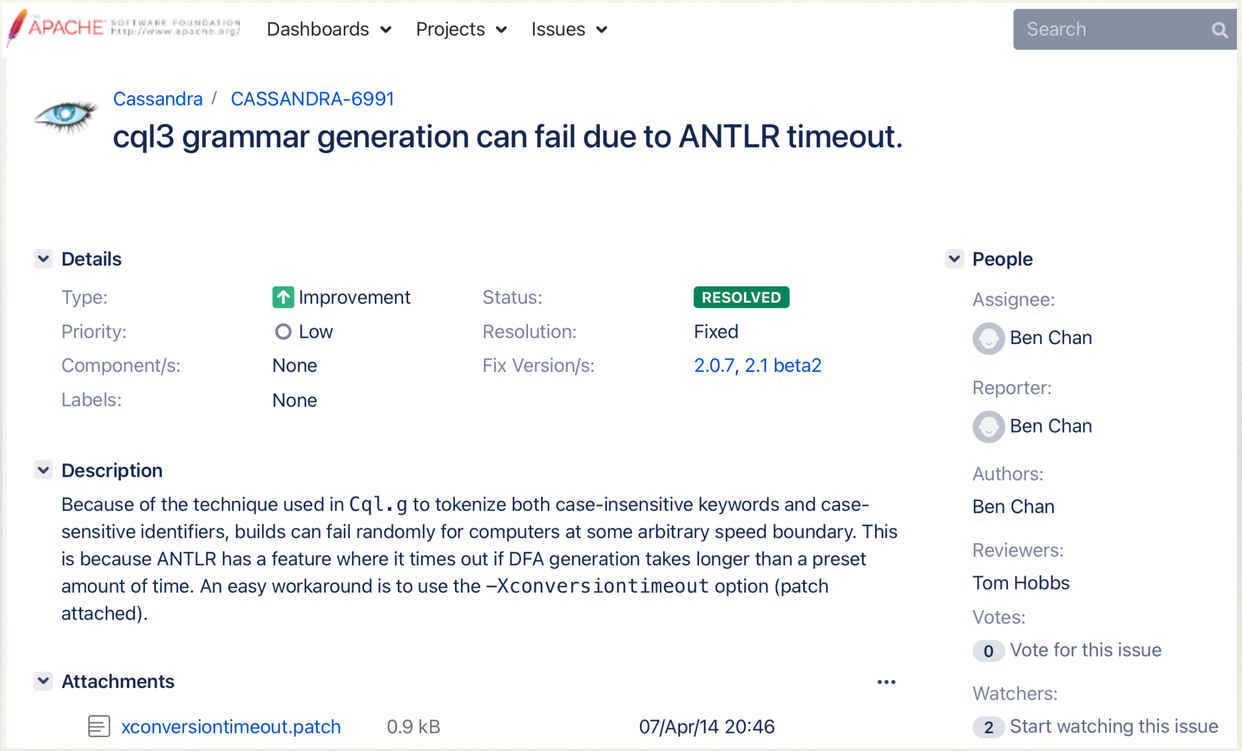

[1] https://www.antlr3.org/pipermail/antlr-interest/2009-September/035957.html
[2] https://issues.apache.org/jira/browse/CASSANDRA-6991

Почему сразу же не использовать ANTLR?

- Может понадобиться ручной фикс останова парсинга [1]

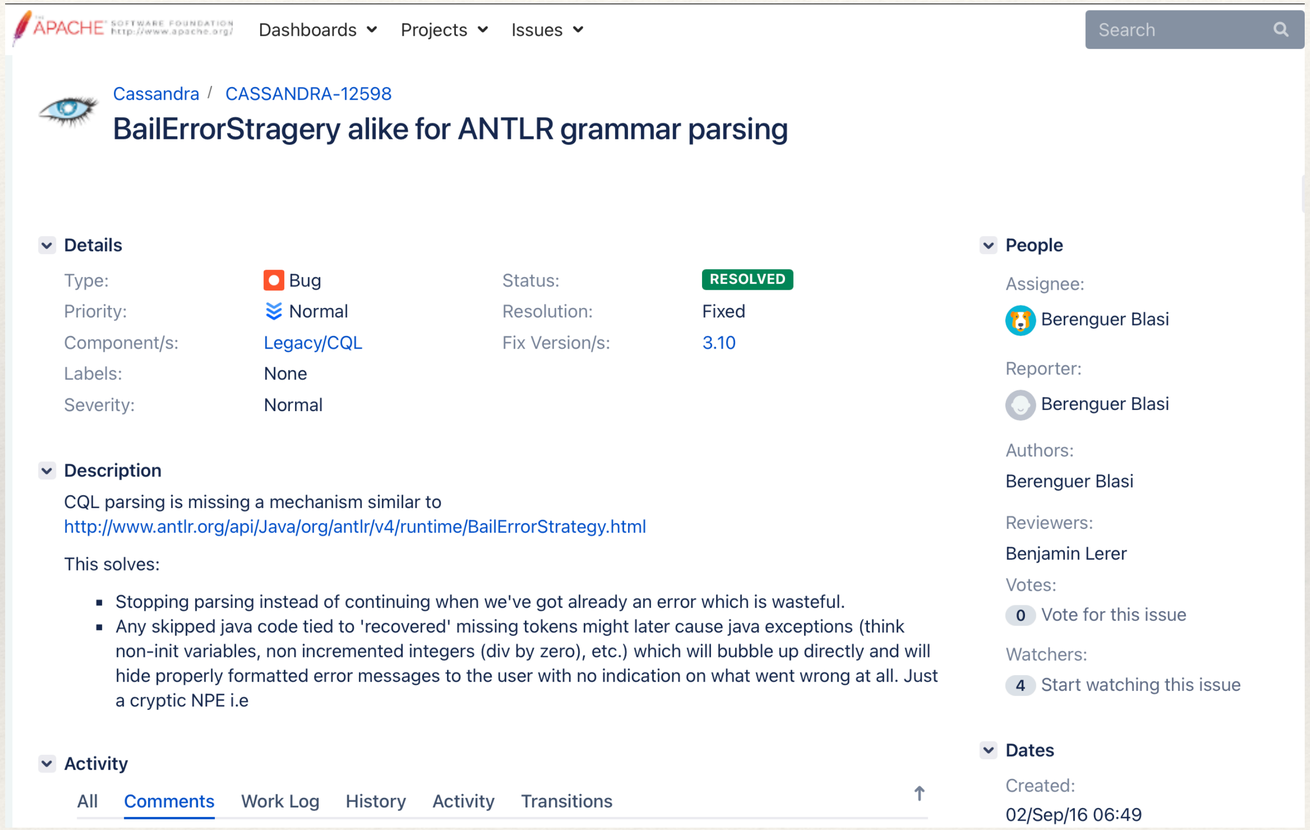

[1] https://issues.apache.org/jira/browse/CASSANDRA-6991

Почему сразу же не использовать ANTLR?

- “Спагетти-код” парсера [3]

```
187     ////////////////////////////////////////////////////////////////////////////////////////////////////////
188     // Recovery methods are overridden to avoid wasting work on recovering from errors when the result will be
189     // ignored anyway.
190     ////////////////////////////////////////////////////////////////////////////////////////////////////////
191
192     @Override
193     protected Object recoverFromMismatchedToken(IntStream input, int ttype, BitSet follow) throws RecognitionException
194     {
195         throw new MismatchedTokenException(ttype, input);
196     }
197
198     @Override
199     public void recover(IntStream input, RecognitionException re)
200     {
201         // Do nothing.
202     }
203 }
204
205 /** STATEMENTS **/
206
207 cqlStatement returns [CQLStatement.Raw stmt]
208     @after{ if (stmt != null) stmt.setBindVariables(bindVariables); }
209     : st1= selectStatement                { $stmt = st1; }
210     | st2= insertStatement                { $stmt = st2; }
211     | st3= updateStatement                { $stmt = st3; }
212     | st4= batchStatement                 { $stmt = st4; }
213     | st5= deleteStatement                { $stmt = st5; }
214     | st6= useStatement                   { $stmt = st6; }
215     | st7= truncateStatement              { $stmt = st7; }
216     | st8= createKeyspaceStatement        { $stmt = st8; }
217     | st9= createTableStatement           { $stmt = st9; }
```

Java-код

BNF-записи

[3] https://github.com/apache/cassandra/blob/trunk/src/antlr/Parser.g

Почему сразу же не использовать ANTLR?

- “Спагетти-код” парсера [4]

```
grammar Cql;

options {
    language = Java;
}

import Parser,Lexer;

@header {
    package org.apache.cassandra.cql3;

    import java.util.Collections;
    import java.util.EnumSet;
    import java.util.HashSet;
    import java.util.LinkedHashMap;
    import java.util.List;
    import java.util.Map;
    import java.util.Set;

    import org.apache.cassandra.auth.*;
    import org.apache.cassandra.cql3.conditions.*;
    import org.apache.cassandra.cql3.functions.*;
    import org.apache.cassandra.cql3.restrictions.CustomIndexExpression;
    import org.apache.cassandra.cql3.selection.*;
    import org.apache.cassandra.cql3.statements.*;
    import org.apache.cassandra.cql3.statements.schema.*;
    import org.apache.cassandra.exceptions.ConfigurationException;
    import org.apache.cassandra.exceptions.InvalidRequestException;
    import org.apache.cassandra.exceptions.SyntaxException;
    import org.apache.cassandra.schema.ColumnMetadata;
    import org.apache.cassandra.utils.Pair;
}

@members {
    public void addErrorListener(ErrorListener listener)
```

[4] https://github.com/apache/cassandra/blob/trunk/src/antlr/Cql.g

Почему сразу же не использовать ANTLR?

- Костыли для case-insensitive keywords [5]

```
58  // Case-insensitive keywords
59  // When adding a new reserved keyword, add entry to o.a.c.cql3.ReservedKeywords as well
60  // When adding a new unreserved keyword, add entry to unreserved keywords in Parser.g
61  K_SELECT:       S E L E C T;
62  K_FROM:         F R O M;
63  K_AS:           A S;
64  K_WHERE:        W H E R E;
65  K_AND:          A N D;
66  K_KEY:          K E Y;
67  K_KEYS:         K E Y S;
68  K_ENTRIES:      E N T R I E S;
69  K_FULL:         F U L L;
70  K_INSERT:       I N S E R T;
71  K_UPDATE:       U P D A T E;
72  K_WITH:         W I T H;
73  K_LIMIT:        L I M I T;
74  K_PER:          P E R;
75  K_PARTITION:    P A R T I T I O N;
76  K_USING:        U S I N G;
77  K_USE:          U S E;
```

```
218 // Case-insensitive alpha characters
219 fragment A: ('a'|'A');
220 fragment B: ('b'|'B');
221 fragment C: ('c'|'C');
222 fragment D: ('d'|'D');
223 fragment E: ('e'|'E');
224 fragment F: ('f'|'F');
225 fragment G: ('g'|'G');
226 fragment H: ('h'|'H');
227 fragment I: ('i'|'I');
228 fragment J: ('j'|'J');
229 fragment K: ('k'|'K');
230 fragment L: ('l'|'L');
231 fragment M: ('m'|'M');
232 fragment N: ('n'|'N');
233 fragment O: ('o'|'O');
234 fragment P: ('p'|'P');
235 fragment Q: ('q'|'Q');
236 fragment R: ('r'|'R');
237 fragment S: ('s'|'S');
238 fragment T: ('t'|'T');
239 fragment U: ('u'|'U');
240 fragment V: ('v'|'V');
241 fragment W: ('w'|'W');
242 fragment X: ('x'|'X');
243 fragment Y: ('y'|'Y');
244 fragment Z: ('z'|'Z');
```

[5] https://github.com/apache/cassandra/blob/trunk/src/antlr/Lexer.g#L58

Почему сразу же не использовать ANTLR?

- Тяжеловесный и трудноподдерживаемый генерируемый код [6]

  - Apache Directory перешёл на вручную написанный парсер вместо ANTLR

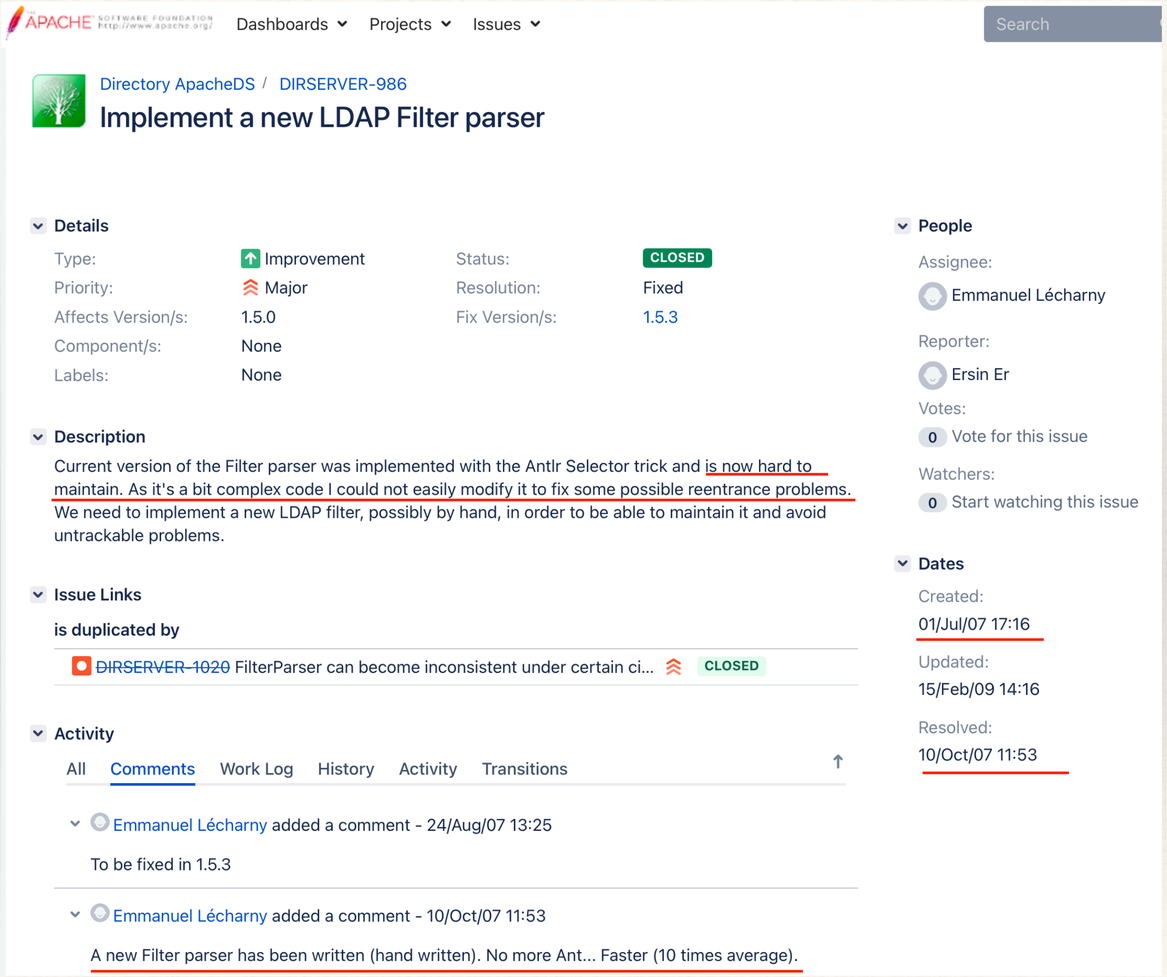

[6] https://issues.apache.org/jira/browse/DIRSERVER-986

Комбинаторы парсеров

Основное правило - декомпозируй задачу!

Комбинаторы парсеров

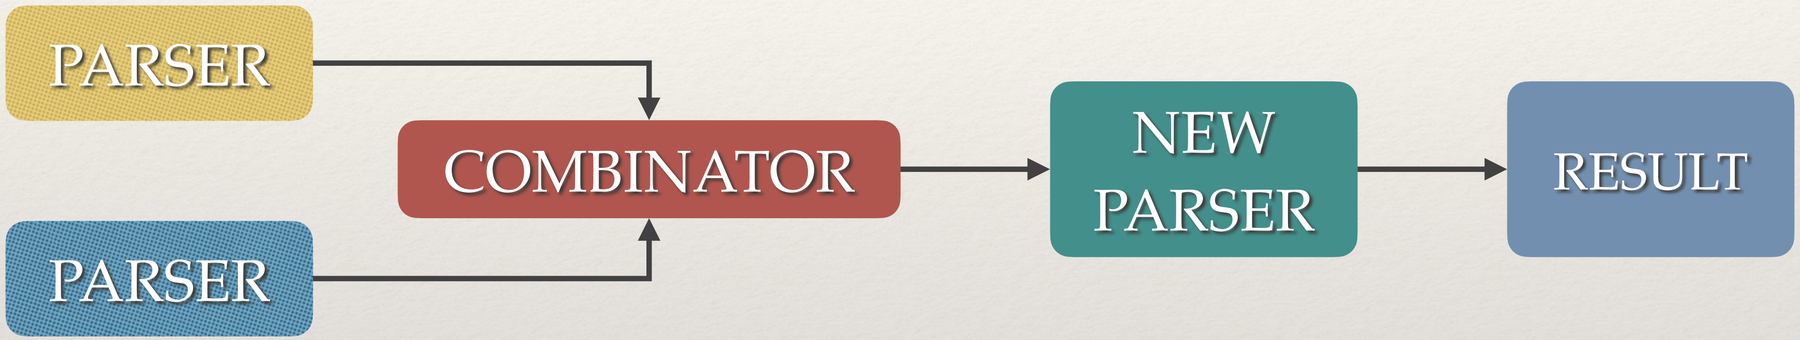

Немного F#

```
let jnull  = stringReturn "null" JNull
let jtrue  = stringReturn "true"  (JBool true)
let jfalse = stringReturn "false" (JBool false)
let jnumber = pfloat |>> JNumber
let stringLiteral = …
let jstring = stringLiteral |>> JString
let listBetweenStrings sOpen sClose pElement f =
    between (str sOpen) (str sClose)
            (ws >>. sepBy (pElement .>> ws) (str "," >>. ws) |>> f)
let jlist   = listBetweenStrings "[" "]" jvalue JList
let keyValue = stringLiteral .>>. (ws >>. str ":" >>. ws >>. jvalue)
let jobject = listBetweenStrings "{" "}" keyValue (Map.ofList >> JObject)
do jvalueRef := choice [jobject
                        jlist
                        jstring
                        jnumber
                        jtrue
                        jfalse
                        jnull]
let json = ws >>. jvalue .>> ws .>> eof
```

[1] https://www.quanttec.com/fparsec/tutorial.html#parsing-json

FParsec: Pros & Cons

- Pros:
  - Процессы лексического и синтаксического анализа объединены
  - Пишем только на целевом языке программирования (если это F#)
  - Можно легко строить AST
- Cons:
  - Полуручной парсинг
  - Чтение только из потока символов [1]

[1] http://www.quanttec.com/fparsec/reference/charstream.html#CharStream

Встречайте Pidgin

Зачем Pidgin?

- Библиотека реализована полностью на C# с LINQ-подобным API
- Весьма производительная
- Чтение из любого источника
- Разрабатывалась в StackExchange (StackOverflow)
- Активно развивается более 3-х лет

Pidgin API: parsers

```
delegate T? Parser<TToken, T>(IEnumerator<TToken> input);
```

```
using Pidgin;
using static Pidgin.Parser;
using static Pidgin.Parser<char>;
```

Pidgin API: generic parsers

```
public static class Parser
{
    public static Parser<char, char> Letter { get; }
    public static Parser<char, char> LetterOrDigit { get; }
    public static Parser<char, char> Lowercase { get; }
    public static Parser<char, char> Uppercase { get; }
    public static Parser<char, char> Punctuation { get; }
    public static Parser<char, char> Symbol { get; }
    public static Parser<char, char> Separator { get; }
    public static Parser<char, string> EndOfLine { get; }
    public static Parser<char, double> Real;
    public static Parser<char, int> DecimalNum { get; }
    public static Parser<char, int> Num { get; }
    public static Parser<char, long> LongNum { get; }
    public static Parser<char, int> OctalNum { get; }
    public static Parser<char, int> HexNum { get; }
    public static Parser<char, char> Whitespace { get; }
    public static Parser<char, IEnumerable<char>> Whitespaces { get; }
    public static Parser<char, char> Digit { get; }
    public static Parser<char, string> WhitespaceString { get; }
    public static Parser<char, Unit> SkipWhitespaces { get; }
}
```

Парсинг знаков

Парсинг чисел

Pidgin API: generic parsers

```
public static class Parser
{
    public static Parser<char, char> Char(char character);
    public static Parser<char, char> CIChar(char character);
    public static Parser<char, string> CIString(string str);
    public static Parser<char, int> Int(int @base);
    public static Parser<char, long> Long(int @base);
    public static Parser<char, string> String(string str);
    public static Parser<char, int> UnsignedInt(int @base);
    public static Parser<char, long> UnsignedLong(int @base);
}
```

Pidgin API: generic parser

```
Parser.HexNum.ParseOrThrow("0x00");
Parser.Digit.ParseOrThrow("3");

Parser.String("foo").ParseOrThrow("foo");
Parser.String("foo")
      .Then(Parser.String("bar"))
      .ParseOrThrow("foobar");
```

Pidgin API: chaining

```
var esc = '\\';

var simpleEscape =
        Char(esc).Then(
            Try(CIChar(esc).ThenReturn('\\'))
                .Or(Try(CIChar('n').ThenReturn('\n')))
                .Or(Try(CIChar('t').ThenReturn('\t')))
                .Or(Try(CIChar('r').ThenReturn('\r')))
                .Or(Try(CIChar('0').ThenReturn('\0')))
        )
        .Or(AnyCharExcept(esc))
        .ManyString()
    ;

var escapedText = simpleEscape.ParseOrThrow(@"first line\nnext line");
```

Pidgin API: main combinators

```
public abstract class Parser<TToken, T>
{
    public Parser<TToken, IEnumerable<T>> AtLeastOnce();
    public Parser<TToken, Unit> SkipMany();
    public Parser<TToken, IEnumerable<T>> Many();
    public Parser<TToken, U> Map<U>(Func<T, U> selector);
    public Parser<TToken, U> OfType<U>();
    public Parser<TToken, T> Or(Parser<TToken, T> parser);
    public Parser<TToken, R> Then<U, R>(Parser<TToken, U> parser,
                                        Func<T, U, R> result);
    public Parser<TToken, U> Select<U>(Func<T, U> selector);
    public Parser<TToken, R> SelectMany<U, R>(Func<T, Parser<TToken, U>> selector,
                                              Func<T, U, R> result);
    public Parser<TToken, T> Where(Func<T, bool> predicate);
    // etc.
}
```

Pidgin API: LINQ

```
// parsing a digit between parenthesis

// LINQ
Parser<char, char> digitTupleParser =
    from lparen in Parser.Char('(')
    from d in Parser.Digit
    from rparen in Parser.Char(')')
    select d;

// Fluent interface
Parser<char, char> digitTupleParser =
    Parser.Char('(')
          .SelectMany(lparen => Parser.Digit,
                      (lparen, d) => new {lparen, d})
          .SelectMany(@t => Parser.Char(')'),
                      (@t, rparen) => @t.d);
// Action
char digit = digitTupleParser.ParseOrThrow("(7)");
```

Парсинг $\mathbb{R}$ чисел

- Натуральные числа $\mathbb{N}_0 = \{0, 1, 2, 3, \ldots\}$
- Целые числа $\mathbb{Z} = \{\ldots, -3, -2, -1, 0, 1, 2, 3, \ldots\}$
- Рациональные числа $\mathbb{Q} = \{\ldots, 3/4, \ldots\}$
  - ❌ Иррациональные $\mathbb{R} \ / \ \mathbb{Q} = \{\ldots, \pi, e, \ldots\}$
- Вещественные числа $\mathbb{R} = \{\ldots -3, 3.1415, 4e15 \}$
- $\mathbb{N} \subset \mathbb{Z} \subset \mathbb{Q} \subset \mathbb{R}$

```
record NaturalNumber(string Num);
record IntegerNumber(char Sign, NaturalNumber Num);
record DecimalNumber(IntegerNumber Num,
                     NaturalNumber Fraction);
record RealNumber(DecimalNumber dec,
                  NaturalNumber? Exponent);
```

```
var naturalNum =
    from digits in Parser.Digit.Many()
    select new
           NaturalNumber(string.Join("", digits));
```

```
var integerNum =
    from sign in Parser.Char('-').
                 Or(Parser.Char('+')).Optional()
    from n in naturalNum
    select new
           IntegerNumber(sign.GetValueOrDefault(), n);
```

```
var decimalNum =
    from i in integerNum
    from _ in Parser.Char('.')
    from f in naturalNum
    select new DecimalNumber(i, f);

var realNum =
    from m in decimalNum
    from e in Parser.Char('e')
                    .Then(naturalNum).Optional()
    select new RealNumber(m, e.GetValueOrDefault());
```

Альтернативы Pidgin

- Sprache: https://github.com/sprache/Sprache 
  - Числится в списке 3rd party ReSharper
- Superpower: https://github.com/datalust/superpower 
  - Форк Sprache
  - Производительнее своего предка :)
  - Используется в Seq/Serilog Seq 
  - Один и тот же автор - Nicholas Blumhardt (@nblumhardt)

RFC-4515

Что такое RFC-4515?

- Lightweight Directory Access Protocol (LDAP): String Representation of Search Filters
- Описывает спецификацию и грамматику LDAP фильтров таких как:

```
(cn=Babs Jensen)
(!(cn=Tim Howes))
(&(objectClass=Person)(|(sn=Jensen)(cn=Babs J*)))
(o=univ*of*mich*)
(seeAlso=)
(:DN:2.4.6.8.10:=Dino)
```

[1] https://tools.ietf.org/search/rfc4515

Грамматика RFC-4515?

```
filter          = LPAREN filtercomp RPAREN
filtercomp      = and / or / not / item
and             = AMPERSAND filterlist
or              = VERTBAR filterlist
not             = EXCLAMATION filter
filterlist      = 1*filter
item            = simple / present / substring / extensible
simple          = attr filtertype assertionvalue
filtertype      = equal / approx / greaterorequal / lessorequal
equal           = EQUALS
approx          = TILDE EQUALS
greaterorequal  = RANGLE EQUALS
lessorequal     = LANGLE EQUALS
extensible      = ( attr [dnattrs]
                            [matchingrule] COLON EQUALS assertionvalue )
                       / ( [dnattrs]
                            matchingrule COLON EQUALS assertionvalue )
present         = attr EQUALS ASTERISK
; and so on
```

[1] https://tools.ietf.org/search/rfc4515

Пример разбора

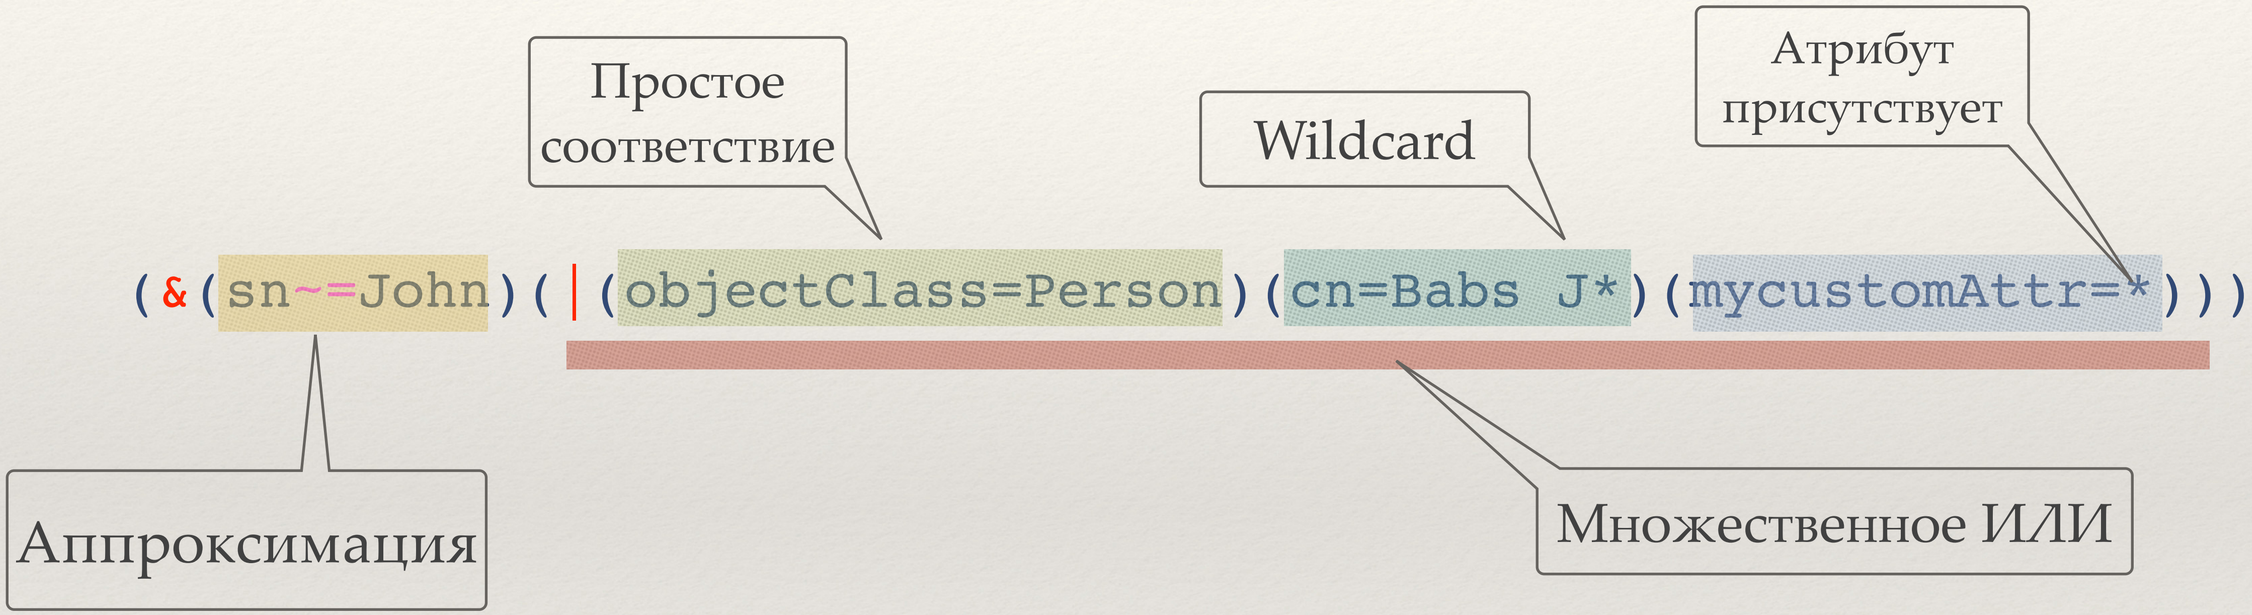

Демо

Демо: реализуем RFC 4515

- Краткий обзор
- Обработка рекурсии
- Обработка неоднозначной грамматики
- Создание AST

Фильтры для бенчмарков

Наличие атрибута

```
(employmentType=*)
```

Вложенные фильтры

```
(&(employmentType=*)(!(employmentType=Hired))
 (!(employmentType=NEW))
 (!(employmentType=POS))(!(employmentType=REH))
)
```

Простое соответствие

```
(sAMAccountName=karlen)
```

Бенчмарки

Тех. спецификация тестовой среды

- CPU: 2,6 GHz 6-Core Intel Core i7 (8870H)
- RAM: 16 GB 2400 MHz DDR4
- OS: macOS Big Sur
- Framework: net5.0
- Lang: C# 9
- Lib: Pidgin 2.5.0

Бенчмарки: результаты

Method	Iterations	Mean	Error	StdDev
Pidgin_ParsePresenceFilter	1000	1.918 ms	0.0537 ms	0.0083 ms
Pidgin_ParseSimpleFilter	1000	2.880 ms	0.1683 ms	0.0260 ms
Pidgin_ParseMultiNestedFilter	1000	13.187 ms	0.4840 ms	0.0749 ms
Sprache_ParsePresenceFilter	1000	58.186 ms	11.6280 ms	1.7994 ms
Sprache_ParseSimpleFilter	1000	74.429 ms	12.1902 ms	1.8864 ms
Sprache_ParseMultiNestedFilter	1000	369.710 ms	52.4777 ms	8.1210 ms
Pidgin_ParsePresenceFilter	10000	19.723 ms	0.2093 ms	0.0324 ms
Pidgin_ParseSimpleFilter	10000	29.543 ms	5.5813 ms	0.8637 ms
Pidgin_ParseMultiNestedFilter	10000	136.791 ms	5.0696 ms	0.7845 ms
Sprache_ParsePresenceFilter	10000	582.619 ms	40.0326 ms	6.1951 ms
Sprache_ParseSimpleFilter	10000	741.687 ms	12.3136 ms	0.6749 ms
Sprache_ParseMultiNestedFilter	10000	3,768.824 ms	433.9293 ms	23.7851 ms
Pidgin_ParsePresenceFilter	100000	209.120 ms	46.4293 ms	7.1850 ms
Pidgin_ParseSimpleFilter	100000	298.788 ms	66.2536 ms	3.6316 ms
Pidgin_ParseMultiNestedFilter	100000	1,406.337 ms	144.5071 ms	22.3626 ms
Sprache_ParsePresenceFilter	100000	6,106.057 ms	1,063.5157 ms	164.5802 ms
Sprache_ParseSimpleFilter	100000	7,709.806 ms	293.1896 ms	45.3714 ms
Sprache_ParseMultiNestedFilter	100000	41,410.988 ms	6,520.3826 ms	1,009.0364 ms

Бенчмарки: сравнение тренда

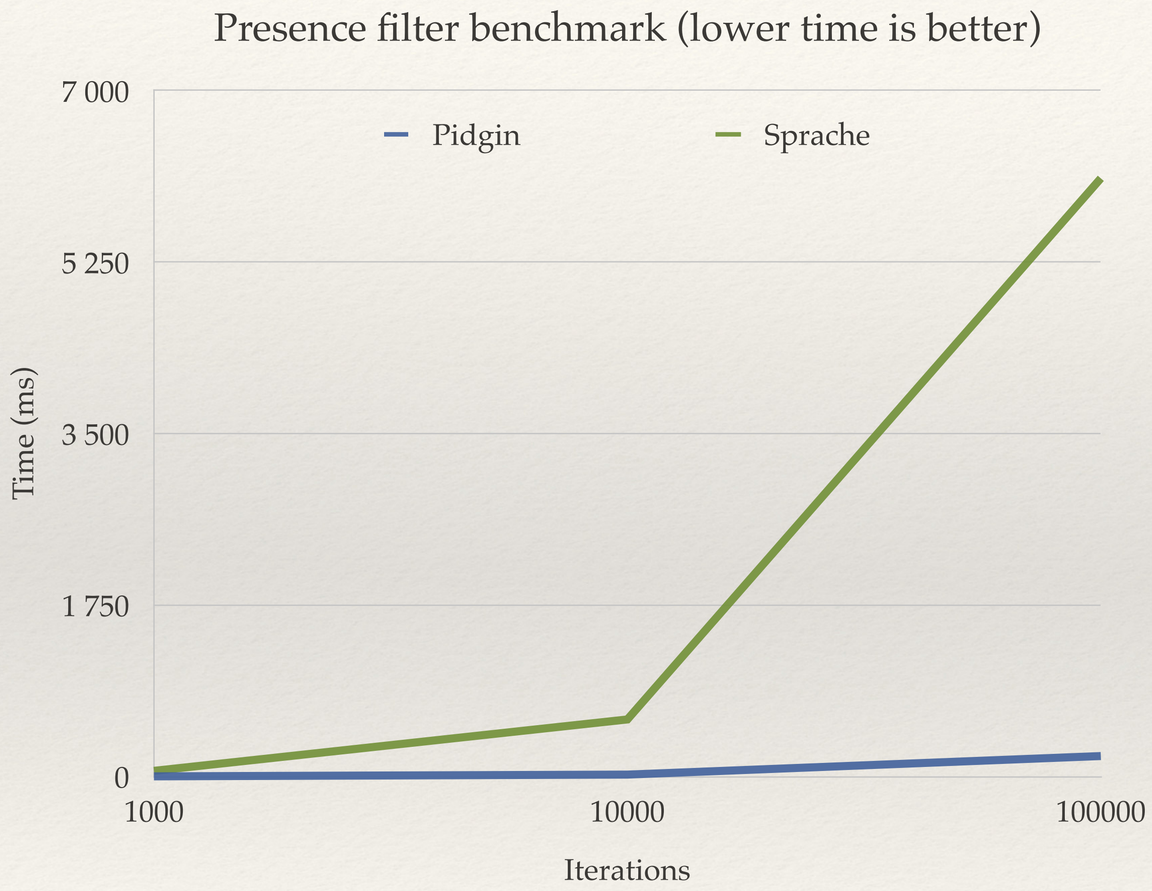

(employmentType=*)

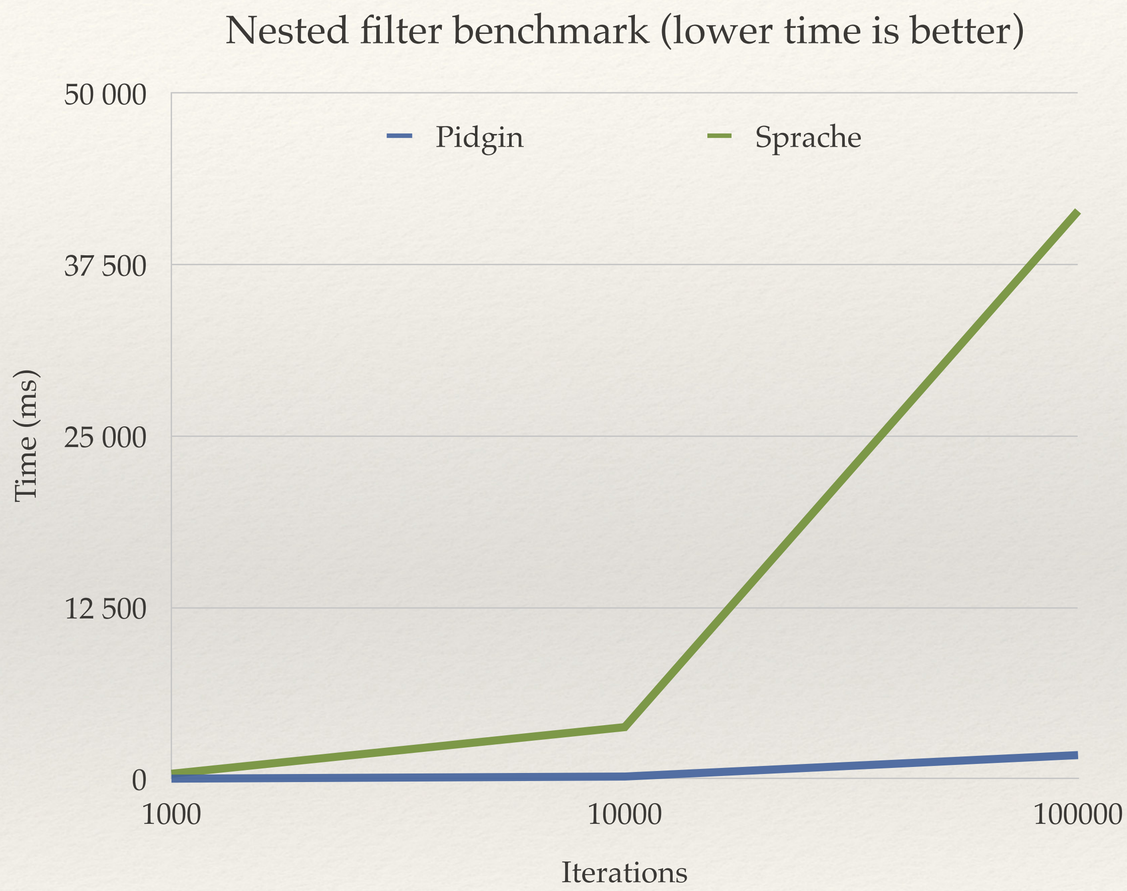

(&(employmentType=*)(!(employmentType=Hired))(!(employmentType=NEW))(!(employmentType=POS))(!(employmentType=REH)))

Бенчмарки: сравнение тренда

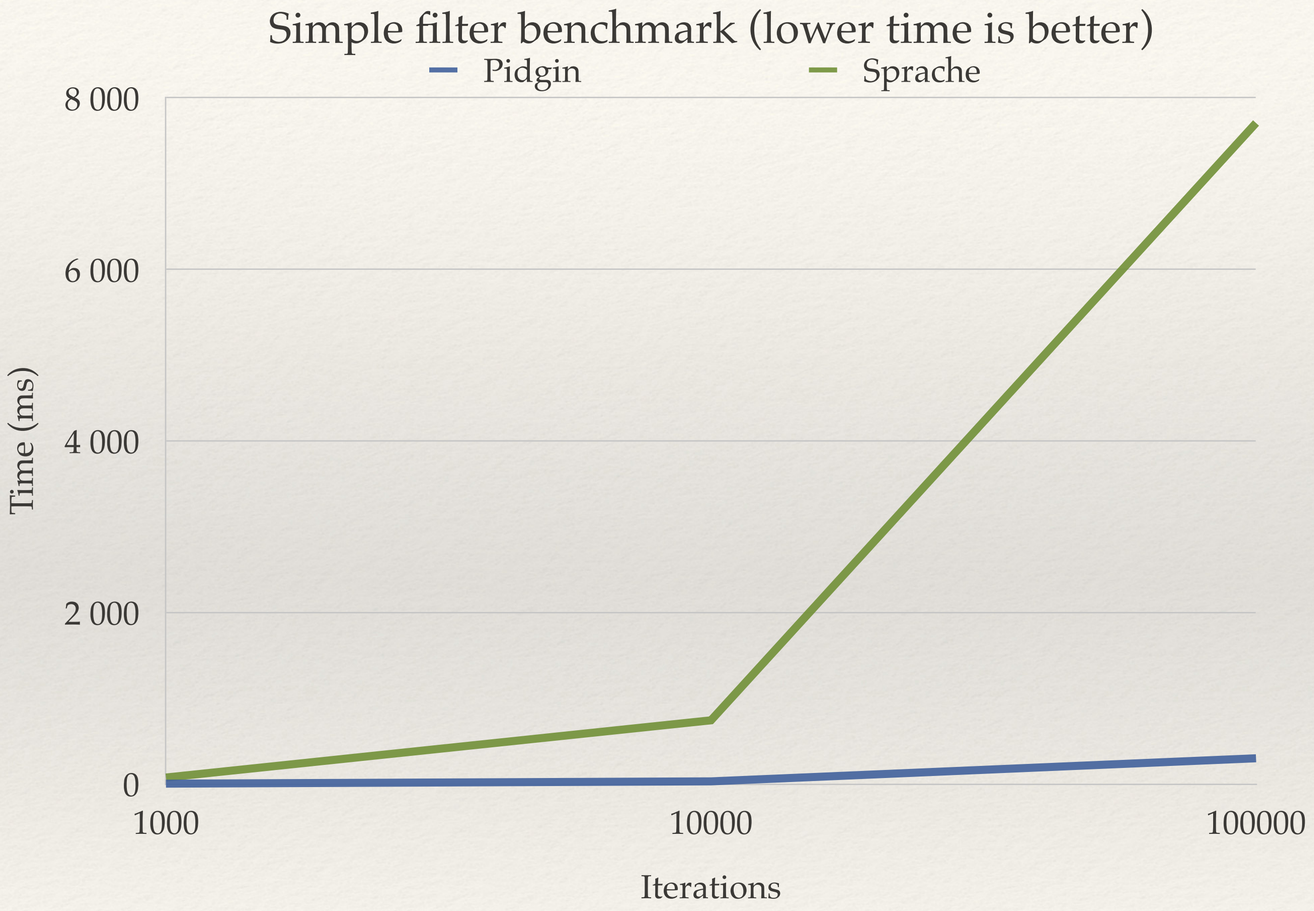

(sAMAccountName=karlen)

Бенчмарки (JSON): сравнение с Superpower & FParsec

`JsonBench`

Method	Mean	Error	StdDev	Ratio	RatioSD	Gen 0	Gen 1	Gen 2
BigJson_Pidgin	684.6 us	2.888 us	2.701 us	1.00	0.00	33.2031	-	-
BigJson_Sprache	3,597.5 us	17.595 us	16.458 us	5.25	0.03	1726.5625	-	-
BigJson_Superpower	2,884.4 us	6.504 us	5.766 us	4.21	0.02	296.8750	-	-
BigJson_FParsec	750.1 us	3.516 us	3.289 us	1.10	0.01	111.3281	-	-

[1] https://github.com/benjamin-hodgson/Pidgin

Почему так?

- Pidgin - новая библиотека и использует все преимущества System.Span<T>
- Имеет более эффективный алгоритм фильтрации токенов

I’m feeling lucky

- Получившийся парсер можно использовать в работе
- Упрощается unit-testing благодаря слабой связности отдельных парсеров
- Имеет приличную производительность 😄

One more thing…

One more thing

- А что если обойтись без генераторов и комбинаторов парсеров вообще?
- Есть ли такие примеры? 🤔
  - Да! Apache Directory 

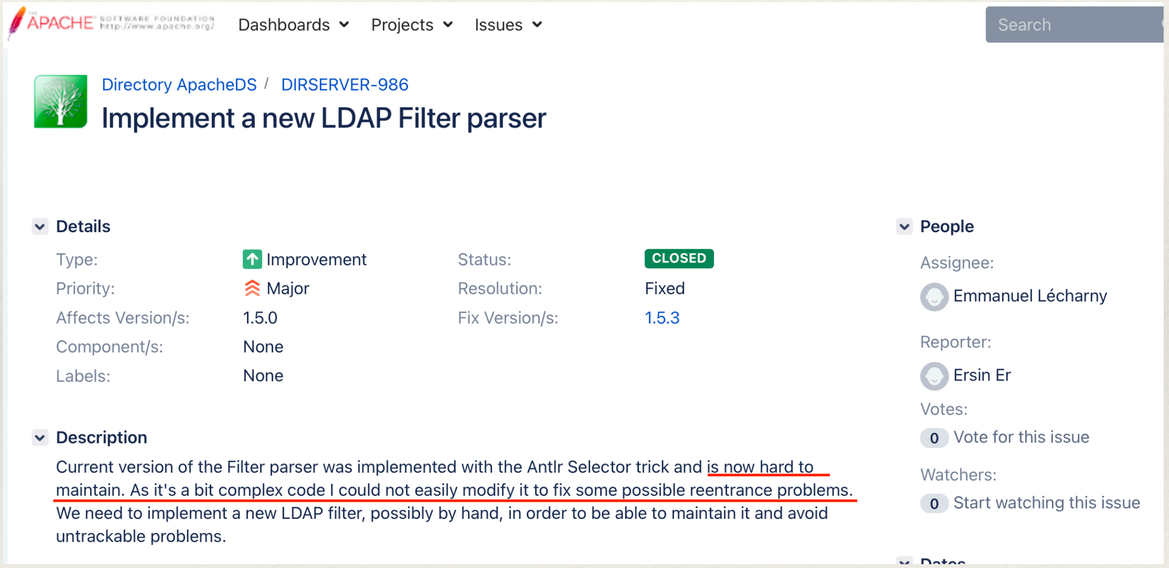

Пример исходного кода Apache DS

```
private static ExprNode parseFilterComp( SchemaManager schemaManager, byte[] filterBytes, Position pos,
    boolean relaxed ) throws ParseException, LdapException
{
    ExprNode node;

    if ( pos.start == pos.length )
    {
        throw new ParseException( I18n.err( I18n.ERR_13313_EMPTY_FILTERCOMP ), pos.start );
    }

    byte b = Strings.byteAt( filterBytes, pos.start );

    switch ( b )
    {
        case '&':
            // This is a AND node
            pos.start++;

            // Skip spaces
            skipWhiteSpaces( filterBytes, pos );

            node = new AndNode();
            node = parseBranchNode( schemaManager, node, filterBytes, pos, relaxed );
            break;
```

Тех. спецификация тестовой среды

- Java 11
- Libs:
  - org.apache.directory.api 2.0.0.AM3-SNAPSHOT
  - JMH 1.29

Бенчмарки: Apache DS FilterParser

Benchmark	(Iterations)	Mode	Score	Units
FiltersBenchmark.nestedFilter	1000	ss	2.253	ms/op
FiltersBenchmark.nestedFilter	100000	ss	72.292	ms/op
FiltersBenchmark.nestedFilter	1000000	ss	702.364	ms/op
FiltersBenchmark.presenceFilter	1000	ss	1.311	ms/op
FiltersBenchmark.presenceFilter	100000	ss	16.719	ms/op
FiltersBenchmark.presenceFilter	1000000	ss	78.134	ms/op
FiltersBenchmark.simpleFilter	1000	ss	0.876	ms/op
FiltersBenchmark.simpleFilter	100000	ss	15.067	ms/op
FiltersBenchmark.simpleFilter	1000000	ss	159.251	ms/op

Бенчмарки: сравнение тренда

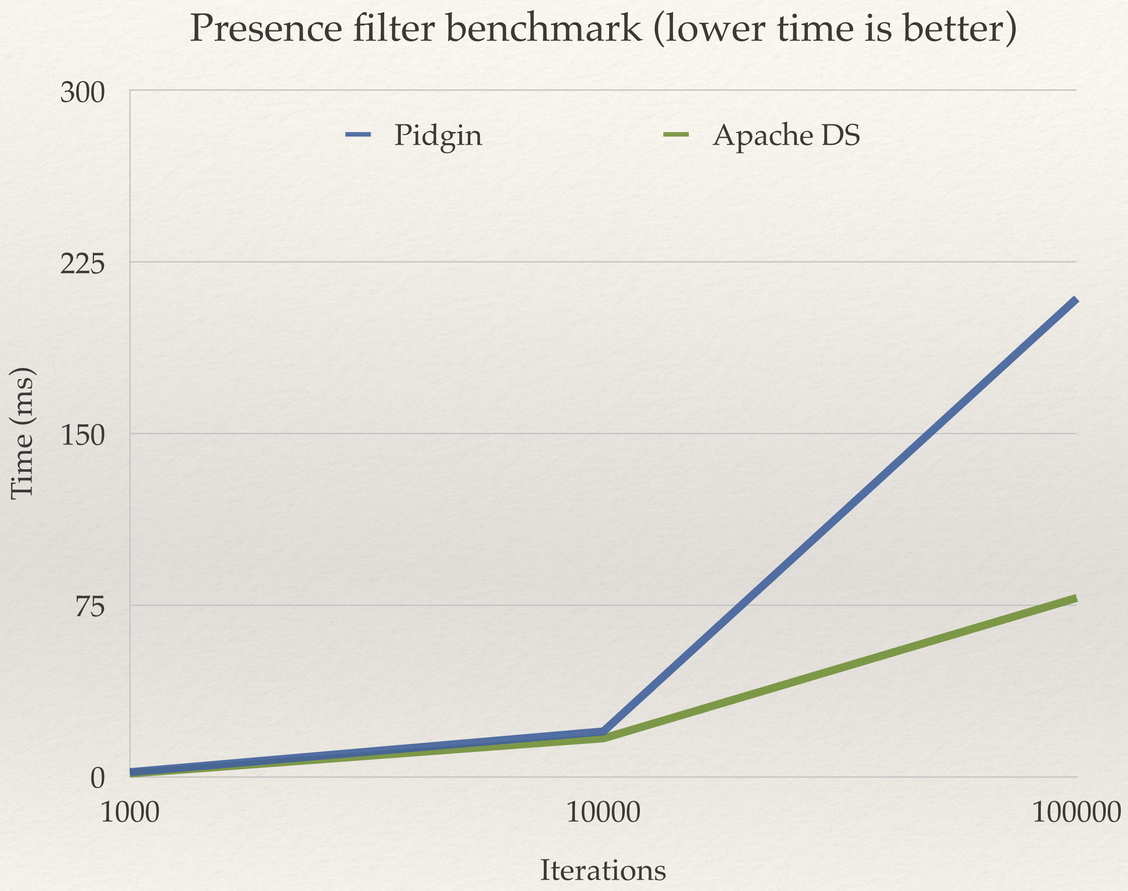

(employmentType=*)

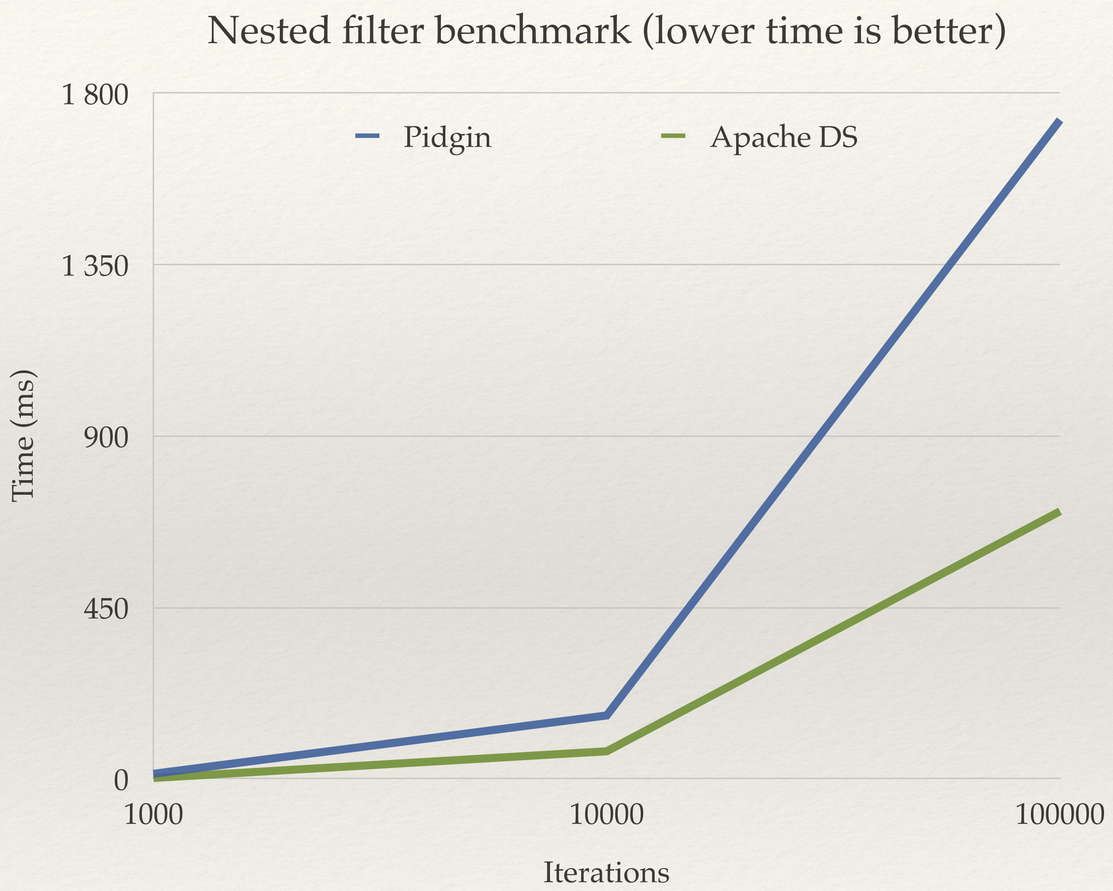

(&(employmentType=*)(!(employmentType=Hired))(!(employmentType=NEW))(!(employmentType=POS))(!(employmentType=REH)))

Бенчмарки: сравнение тренда

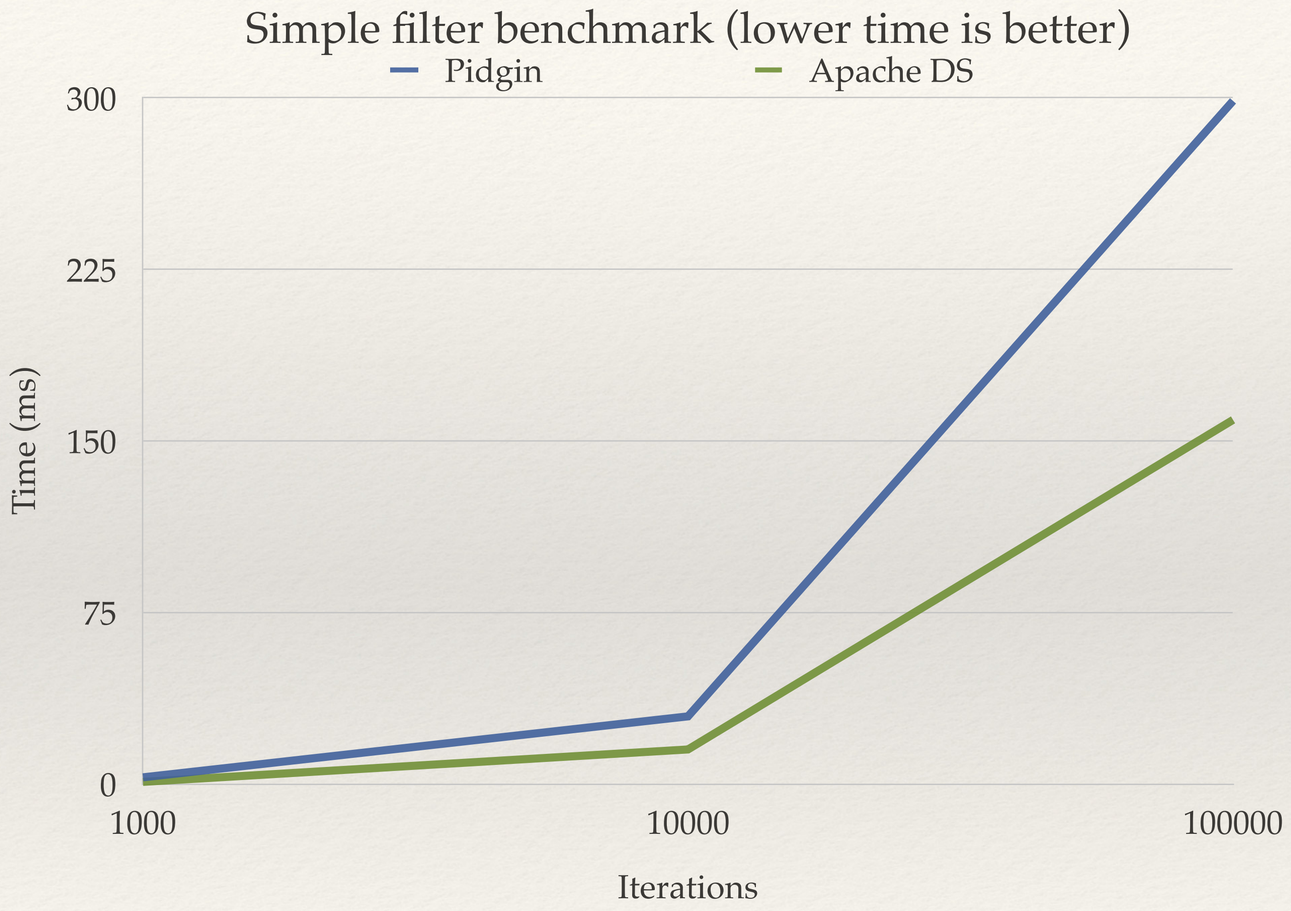

(sAMAccountName=karlen)

Заключение

- Комбинаторы парсеров могут быть отличным подспорьем
- Pidgin - производительная и простая в освоении библиотека
- Можно существенно сократить трудозатраты на разработку DSL и прочих вещей

Полезные ссылки

- Pidgin: https://github.com/benjamin-hodgson/Pidgin
- Sprache: https://github.com/sprache/Sprache
- Superpower: https://github.com/datalust/superpower
- ANTLR: https://www.antlr.org
- FParsec: https://www.quanttec.com/fparsec/
- Apache Directory: http://directory.apache.org

Спасибо!
Q&A

Контакты

- Twitter, GitHub, Habr, LinkedIn: **@szKarlen**
- Blog: szkarlen.com
- Email: szkarlen@gmail.com, karlen.simonyan@ubs.com