

Monadische Parser

8 out of 10 cats do ... *parsing*

Christian Höner zu Siederdissen

christian.hoener.zu.siederdissen@uni-jena.de

Theoretische Bioinformatik, Bioinformatik Uni Jena

Dec 1st, 2022

Parsing mit coolen Typen¹

Parser bisher:

```
1 pSumPNP :: [Token] -> Maybe (Expr,[Token])
```

generalisieren:

```
1 type Parser = [Token] -> Maybe (Expr,[Token])
```

0...n Parses:

```
1 type Parser = [Token] -> [(Expr,[Token])]
```

Expr generalisieren:

```
1 type Parser a = [Token] -> [(a,[Token]))
```

Token generalisieren:

```
1 type Parser t a = [t] -> [(a,[t]))
```

¹und schlechten Wortwitzen

Parsing mit coolen Typen²

Namen erfinden:

```
1 newtype Parser t a = Parser {parse :: [t] -> [(a,[t])]}
```

und vergleichen:

```
1 type Parser t a = [t] -> [(a,[t])]
```

```
2
```

```
3 pSumPNP :: Parser Token Expr
```

```
4 pSumPNP :: Parser Char Expr
```

```
5     == [Char] -> [(Expr,[Char])]
```

```
6     == String -> [(Expr,String)]
```

Ein Parser ist eine Funktion die eine Eingabeliste $[t]$ von Token nimmt und eine Liste $[(a, [t])]$ von Parses a zusammen mit der restlichen Eingabe $[t]$ liefert.

²und schlechten Wortwitzten

Parsen eines Tokens

```
1 newtype Parser t a = Parser { parse :: [t] -> [(a,[t])] }
2
3 itemP :: Parser t t
4 itemP = Parser go
5   where go [] = []
6       go (x:xs) = [(x,xs)]
7
8
9
10 atomP :: Eq t => t -> Parser t t
11 atomP c = Parser go
12   where go [] = []
13       go (x:xs) | x/=c = []
14       go (x:xs) = [(x,xs)]
15
16 -- | This is Maybe
17 data Option a = Nul | Has a
18   deriving (Show)
```

Funktoren ?!

```
1 instance Functor (Parser t) where
2   fmap :: (a -> b) -> Parser t a -> Parser t b
3   fmap f (Parser p) = Parser (\cs ->
4     [(f a,ds) | (a,ds) <- p cs])
```

```
1 -- Funktion f auf Elemente in Has anwenden
2 instance Functor Option where
3   fmap :: (a->b) -> Option a -> Option b
4   fmap f Nul      = Nul
5   fmap f (Has a) = Has (f a)
```

Applicatives ???!

```

1 instance Applicative (Parser t) where
2   pure :: a -> Parser t a
3   pure x = Parser (\cs -> [(x,cs)])
4   (*)> :: Parser t (a -> b) -> Parser t a -> Parser t b
5   Parser p *> Parser q = Parser (\cs ->
6     [ (f a,es) | (f,ds) <- p cs
7       , (a,es) <- q ds])
8

1 -- Sowohl Funktion als auch Argument sind "eingepackt"
2 instance Applicative Option where
3   pure :: a -> Option a
4   pure = Has
5   (*) :: Option (a->b) -> Option a -> Option b
6   Nul *> _ = Nul
7   _ *> Nul = Nul
8   Has f *> Has a = Has (f a)

```

Alternatives ?!

```
1 instance Applicative (Parser t) => Alternative (Parser t)
2 where
3     empty = noP
4     Parser p <|> Parser q = Parser $ \cs -> p cs ++ q cs
5
6
7 instance (Monad (Parser t), Alternative (Parser t))
8 => MonadPlus (Parser t) where
9     mzero = empty
10    mplus = (<|>)

1 -- | Entweder lhs (bevorzugt) oder rhs nutzen
2 instance Applicative Option => Alternative Option where
3     empty :: Option a
4     empty = Nul
5     (<|>) :: Option a -> Option a -> Option a
6     Nul <|> option = option
7     Has a <|> _      = Has a
```

Monads: Are you joking?

```
1 instance Monad (Parser t) where
2   return :: a -> Parser t a
3   return = pure
4   (>>=) :: Parser t a -> (a -> Parser t b) -> Parser t b
5   Parser p >>= pq = Parser (\cs ->
6     [ (b,es) | (a,ds) <- p cs
7       , let Parser q = pq a
8       , (b,es) <- q ds])
```

```
1 -- | a innerhalb eines "Option" Kontext bearbeiten
2 instance Monad Option where
3   (>>=) :: Option a -> (a->Option b) -> Option b
4   Nul >>= f = Nul
5   Has a >>= f = f a
```

```
1 noP :: Parser t a
2 noP = Parser $ \cs -> []
3
4 satP :: (t -> Bool) -> Parser t t
5
6 satP c = Parser go
7   where go [] = []
8       go (x:xs) | c x = [(x,xs)]
9       go _ = []
10
11 satP c = itemP >>= \x -> if c x then pure x else mzero
12
13 satP c = Parser goL >>= \x ->
14   if c x then Parser (\cs -> [(x,cs)])
15       else Parser (\cs -> [])
16   where goL [] = []
17       goL (x:xs) = [(x,xs)]
```

fuz rho doh

```
1  satP c = do
2      x <- itemP
3      if c x then pure x else mzero
4
5  testPP =
6      itemP >>= \x1 ->
7      itemP >>= \x2 ->
8      itemP >>
9      itemP >>= \x4 ->
10     return (x1,x2,x4)
11
12 testD0 = do
13     x1 <- itemP
14     x2 <- itemP
15     itemP
16     x4 <- itemP
17     return (x1,x2,x4)
```

Combinator-Time

```
1 theseP :: Eq t => [t] -> Parser t [t]
2 theseP [] = pure []
3 theseP (t:ts) = satP (t==) >> theseP ts
4
5 manyP p = someP p <|> return []
6
7 someP p = do {x <- p; xs <- manyP p; return (x:xs)}
8
9 -- btw. "many" und "some" gibt es fuer *alle* Alternative's
```

In Haskell liegt die Kunst nicht darin möglichst viele verschiedene Kombinatoren zu haben, sondern wenige, *generische* Kombinatoren die breite Anwendung finden.

Deshalb machen auch "Monaden" Sinn: sie beschreiben generische strukturelle Features

Listen, und Klammern

```
1 sepBy :: Parser t a -> Parser t b -> Parser t [a]
2 p `sepBy` s = (p `sepBy1` s) <|> return []
3
4 -- HEY! Das sind ja programmierbare Semikolons!
5
6 sepBy1 :: Parser t a -> Parser t b -> Parser t [a]
7 p `sepBy1` s = do {a <- p; as <- many (s >> p)
8                     ;return (a:as)}
9
10 bracketedP :: Parser t l -> Parser t x -> Parser t r
11      -> Parser t x
12 bracketedP lP xP rP = do
13     _l <- lP
14     x  <- xP
15     _r <- rP
16     return x
```

Operatoren und Operanden

```
1 chainl :: Parser t a -> Parser t (a -> a -> a) -> a
2     -> Parser t a
3 chainl p op a = (p `chainl1` op) <|> return a
4
5 chainl1 :: Parser t a -> Parser t (a -> a -> a)
6     -> Parser t a
7 chainl1 p op = p >>= go
8     where go a = do
9         f <- op
10        b <- p
11        go (f a b)
12        <|> return a
```

Noch schnell ein lexikalischer Parser

```
1 spaceP :: Parser Char String
2 spaceP = many (satP isSpace)
3
4 tokenP :: Parser Char a -> Parser Char a
5 tokenP p = p <* spaceP
6
7 stringP :: String -> Parser Char String
8 stringP = tokenP . theseP
```

Und ein neuer Expr Parser

```
1  digitP :: Parser Char Int
2  digitP = satP isDigit >= \x -> pure (ord x - ord '0')
3
4  numberP :: Parser Char Expr
5  numberP = do
6      ds <- some digitP
7      spaceP
8      return . Num $ foldl (\acc x -> 10*acc + x) 0 ds
9
10 bracketP :: Parser Char Expr
11 bracketP = bracketedP l exprP r
12   where l = tokenP $ atomP '('
13       r = tokenP $ atomP ')'
```

Dieser Parser braucht jetzt auch kein Tokenizing mehr! Und vesteht Leerzeichen!

Das ist ja einfach ...

```
1 addopP, mulopP
2   :: Parser Char (Expr -> Expr -> Expr)
3
4 addopP = (stringP "+" >> pure (App Add))
5       <|> (stringP "-" >> pure (App Sub))
6
7 mulopP = (stringP "*" >> pure (App Mul))
8       <|> (stringP "/" >> pure (App Div))
```

Der komplette Expr Parser

```
1 -- Expr's sind Terme mit addop's verbunden
2
3 exprP :: Parser Char Expr
4 exprP = termP `chainl1` addopP
5
6 -- Terme sind factors mit Multiplikationen verbunden
7
8 termP = factorP `chainl1` mulopP
9
10 -- factors sind Zahlen oder wohlgeformte Klammern
11
12 factorP = numberP <|> bracketP
```

Zusammenfassung

- Wir haben Functor, Alternative, Applicative, Monad als Abstraktionsmittel kennengelernt
- Jede dieser Abstraktionen erlaubt es eine Zahl vorgefertigter Kombinatoren zu nutzen
- Unser neuer Parser ist ein Beispiel fuer Monaden in Aktion
- Und auch fuer do-Notation, die aber nur syntaktischer Zucker ist
- Unser neuer Parser kann prinzipiell alle legalen Parses, nicht nur einen, erzeugen

Es folgt dann die Frage ob sich der "Monad" Aufwand lohnt? (Ja)
Und die Konstruktion eines effizienteren Countdown!

Memoisation

Wikipedia: Memoisation oder Memoisierung ist eine Technik, um Computerprogramme zu beschleunigen, indem Rückgabewerte von Funktionen zwischengespeichert anstatt neu berechnet werden.

Warum ist das von Interesse? Was macht mkExpr? Wie häufig sehen wir Teilsequenzen in mkExpr?

1,2,3,4,5,6

fix und Open Recursion

Betrachten wir noch einmal *Fibonacci*

```
1 fib :: Int -> Int
2 fib 0 = 1
3 fib 1 = 1
4 fib n = fib (n-1) + fib (n-2)
5           ^^^           ^^^
```

- fib nutzt (offensichtlich Rekursion)
- wir wollen jetzt die Rekursion "heraus ziehen" in eine eigene Funktion

```
1 fob :: (Int -> Int) -> Int -> Int
2 fob f 0 = 1
3 fob f 1 = 1
4 fob f n = f (n-1) + f (n-2)
5           ^^^           ^^^
6
7 runfob :: Int -> Int
8 runfob = fib runfob
```

fix und Open Recursion

```
1  fob :: (Int -> Int) -> Int -> Int
2  fob f 0 = 1
3  fob f 1 = 1
4  fob f n = f (n-1) + f (n-2)
5          ^^^      ^^^
6
7  runfob :: Int -> Int
8  runfob = fib runfob
9
10 -- fib (fib (fib (fib (...))))
```

Generalisieren von runfob

```
1  -- 'f' ist der Typ von Funktionen, zB
2  -- fix :: ((Int -> Int) -> (Int -> Int)) -> (Int -> Int)
3  fix :: (f -> f) -> f
4  fix f = let x = f x in x
```

fix und Open Recursion

```
1  fob :: (Int -> Int) -> Int -> Int
2  fob f 0 = 1
3  fob f 1 = 1
4  fob f n = f (n-1) + f (n-2)
5          ^^^        ^^^
6
7  fix :: (f -> f) -> f
8  fix f = let x = f x in x
9
10 runfob :: Int -> Int
11 runfob = fix fob
```

fix erlaubt es uns in jedem Rekursionsschritt interessante Dinge mit fob zu machen, wobei die "interessanten Dinge" auf jeder Ebene passieren!

fix und Open Recursion

```
1  fob :: (Int -> Int) -> Int -> Int
2  fob f 0 = 1
3  fob f 1 = 1
4  fob f n = f (n-1) + f (n-2)
5          ^^^        ^^^
6
7  fix :: (f -> f) -> f
8  fix f = let x = f x in x
9
10 -- fix fib 10
11 -- fix (\f -> fib ((1+) . f)) 10
```

Mematables

```
1  fob :: (Int -> Int) -> Int -> Int
2  fob f 0 = 1
3  fob f 1 = 1
4  fob f n = f (n-1) + f (n-2)
5
6  fix :: (f -> f) -> f
7  fix f = let x = f x in x
8
9  -- gib eine Liste von Indices fuer die Funktion f
10 -- und ihre Werte gespeichert werden
11 memoList :: [Int] -> (Int -> a) -> (Int -> a)
12 memoList ks f = (map f ks !!)
13
14 memofib :: Int -> Int
15 memofib = fix (memoList [0..1000] . fib)
16 -- === fix (fib . memoList [0..1000])
```

memo Expr

```
1 fix :: (f -> f) -> f
2 fix f = let x = f x in x
3
4 -- mkExprs, aber die Rekursion ist jetzt via "mk"
5 orExprs :: ([Int] -> [(Expr,Value)]) -> [Int] -> [(Expr, Va
6 orExprs mk [x] = [(Num x, Value x)]
7 orExprs mk xs =
8   [ ev | (ys,zs) <- unmerges xs
9     , l <- mk ys, r <- mk zs
10    , ev <- combine l r ]
11
12 -- wie bei fib, wir machen die Rekursion explizit
13 recExprs :: [Int] -> [(Expr,Value)]
14 recExprs = orExprs recExprs
15
16 fixExprs :: [Int] -> [(Expr,Value)]
17 fixExprs = fix orExprs
```

memo Expr

```
1 fix :: (f -> f) -> f
2 fix f = let x = f x in x
3
4 -- mkExprs, aber die Rekursion ist jetzt via "mk"
5 orExprs :: ([Int] -> [(Expr,Value)]) -> [Int] -> [(Expr, Va
6 orExprs mk [x] = [(Num x, Value x)]
7 orExprs mk xs =
8   [ ev | (ys,zs) <- unmerges xs
9     , l <- mk ys, r <- mk zs
10    , ev <- combine l r ]
11
12 -- Speichern fuer alle sequences, die man angibt
13 memoSeqs :: forall a . [[Int]] -> ([Int] -> a) -> ([Int] ->
14 memoSeqs sqs f = (tbl Map.!)
15   where
16     tbl :: Map.Map [Int] a
17     tbl = Map.fromList [ (s,f s) | s <- sqs ]
```

Laufzeit?

```
1 length . concatMap mkExprs $ subseqs [1..6]
2 -- 5341067
3 -- (6.55 secs, 6,155,652,240 bytes)
4
5 length . concatMap recExprs $ subseqs [1..6]
6 -- 5341067
7 -- (6.68 secs, 6,182,532,000 bytes)
8
9 length . concatMap (fix orExprs) $ subseqs [1..6]
10 -- 5341067
11 -- (6.60 secs, 6,182,532,112 bytes)
12
13 length . concatMap (fix (orExprs . memoSeqs (subseqs [1..6])
14 -- 5341067
15 -- (4.45 secs, 4,110,812,488 bytes)
```

Zusammenfassung

- Rekursion kann durch `fix` den "least fixpoint operator" expliziter gemacht werden
- Dadurch koennen wir in jeder Ebene einer Rekursion Funktionalitaet "injizieren"
- Hier "ziehen" wir eine Datenstruktur durch, mit der wir fuer jede Eingabe die Ausgabe speichern (*memoisieren*)
- `fib` wird dadurch polynomiell
- `orExprs` und `memoSeqs` bringen weniger, da die Datenstrukturen viel groesser sind