

Introdução à sintaxe e à anotação no AC/DC

Diana Santos

ILOS

`d.s.m.santos@ilos.uio.no`

Primavera 2019

Algumas linguagens artificiais

- Expressões regulares: Uma linguagem para descrever cadeias de caracteres (sequências de caracteres), com os seguintes caracteres especiais: ., *, +, ?, [], (), {}, | e \ .
- A sintaxe do OCWB: usa [] para as unidades, e elas próprias têm um conjunto de pares atributo valor
- Pode-se usar expressões regulares dentro dos valores das unidades, ou sobre as unidades elas próprias.
- Quando há mais do que uma unidade, tem de se indicar onde começa cada uma. Com aspas, ou com [].

- Formas de descrever um conjunto de unidades pertencentes a uma linguagem.
- Neste caso vamos aplicá-las ao português, que é uma língua (linguagem natural).
- Em primeiro lugar vamos aplicá-las a palavras (ou sinais de pontuação ou números), depois a sequências de palavras e/ou unidades.
- Vamos considerar que existe um conjunto de sinais gráficos (letras, dígitos e outros) que formam o nosso vocabulário.
- Além disso, existem outros sinais que têm um significado especial.

Expressões regulares: principais atores

- * zero ou mais vezes
- + uma ou mais vezes
- ? zero ou uma vez
- . qualquer carater

Exemplos: cas+a, cald?o, .*inho, corr.+, .*lh.*, c.ma, dos*, das?

Expressões regulares: outros atores

E quando queremos não um carater específico, nem um qualquer, mas uma classe de caracteres? Então incluímos dentro destes parênteses retos: []. Outra vez indicamos qualquer carater exceto uma dada classe, indicando a negação por ^.

[ab] ou a ou b

[0-9] qualquer algarismo entre 0 e 9

[óôoõ] um o, acentuado ou ão

[-?.Z] hífen, ponto de interrogação, ponto ou Z.

[^aeiou] tudo menos vogais

Exemplos: pr[éê]mios?, c[aeiou]rt[ao], almoç[áa]mos, A[0-9]+

Expressões regulares: mais complexidade

- Juntar disjunção de sequências, não só de unidades simples:
caixa|saco, (ou|oi)ro,
- em vez de um número qualquer, poder escolher quantas vezes uma dada unidade é repetida: $\{n,m\}$ mínimo n vezes, máximo m vezes

car $\{1,2\}$ o, go $\{3,8\}$ gle, (ca|co) $\{1,3\}$

Expressões regulares no ACDC a outro nível

Os textos do AC/DC estão divididos por unidades. E a cada unidade, além da sua forma, está muita informação associada, em forma de pares atributo-valor.

- Por isso cada unidade é descrita por [], e podem escolher-se os atributos pelos quais se quer identificar uma unidade. A sua forma, o seu lema, a sua categoria gramatical, a variante a que pertence, o seu autor, etc.

[word="comida"], [lema="beber"], [autor="EQ"], [variante="BF"]

- ou conjunções desses critérios, usando & ou

[lema="beber" & autor="EQ"], [word="comida" & variante="BF"]

- E são usadas expressões regulares sobre esses pares

[pos="N.*"] [pos="ADJ.*"]{2,3} [word="que"]

Qual a informação associada a cada unidade?

Isso foi decidido por nós (AC/DC) e parcialmente pelo PALAVRAS. Grande parte do curso vai servir para compreender esse tipo de informação. Dois tipos diferentes:

- informação diferente para cada palavra, às vezes chamada também etiquetagem, do inglês “tagging”
- informação de agrupamento, ou por textos, às vezes chamada também marcação, do inglês “markup”
 - Apenas as fronteiras (os chamados atributos estruturais). (Quem sabe XML, ou HTML, percebe logo)
 - Em todos os elementos (também chamados metadados - simplificam as distribuições)

O que é uma palavra?

Não há definição padrão de uma palavra (forma gráfica), diferentes sistemas ou investigadores têm diferentes opiniões.

- Além disso, as palavras vão mudando, veja-se o Pepetela a escrever por exemplo *masé*.
- E veja-se o corpo ReLi...

Por isso a escolha foi nossa, e refere-se sobretudo a clíticos, contrações, locuções e nomes próprios.

O que é uma palavra?

A nossa solução foi em geral dar as duas possibilidades, tendo a separação ou a junção no lema.

word do -> lema de+o

word Maria -> lema Maria=da=Fonte

word da -> lema Maria=da=Fonte

word Fonte -> lema Maria=da=Fonte

word dei-mo -> lema dar+eu+ele

word dei-lha -> lema dar+lhe&lhes+ela

word esqueceu-se -> lema esquecer+se