

# Mineração do DHBB

Alexandre Rademaker (FGV/EMAp e IBM Research)

<http://arademaker.github.io>

<http://emap.fgv.br/corpo-docente/alexandre-rademaker>

<http://researcher.ibm.com/person/br-alexrad>

# Colaboradores

- Fabricio Chalub (IBM)
- Bruno Cuconato (FGV/EMAp)
- Henrique Muniz (FGV/EMAp e IBM)
- Guilherme Passos (IBM)
- Claudia Freitas (PUC-Rio)
- Suemi Higuchi (CPDOC)
- Flávia M. da R. Pereira da Silva (IBM)
- Valéria de Paiva, Adam Pease, Gerard de Melo etc.

# O que é Processamento de Linguagem Natural?

- Resposta à perguntas (IBM Watson ganhou o Jeopardy 2011)
- Extração de Informações (entidades nomeadas, eventos, relações etc)
- Expanção de consultas (via sinônimos)
- Análise de sentimentos (críticas em blogs e em sites online)
- Tradução
- Classificação de textos
- Sumarização
- Linguagens controladas . . .

# O que é PLN?

Dan Jurafsky



## Why else is natural language understanding difficult?

### non-standard English

Great job @justinbieber! Were SOO PROUD of what youve accomplished! U taught us 2 #neversaynever & you yourself should never give up either♥

### segmentation issues

the New York-New Haven Railroad  
the New York-New Haven Railroad

### idioms

dark horse  
get cold feet  
lose face  
throw in the towel

### neologisms

unfriend  
Retweet  
bromance

### world knowledge

Mary and Sue are sisters.  
Mary and Sue are mothers.

### tricky entity names

Where is *A Bug's Life* playing ...  
*Let It Be* was recorded ...  
... a mutation on the *for* gene ...

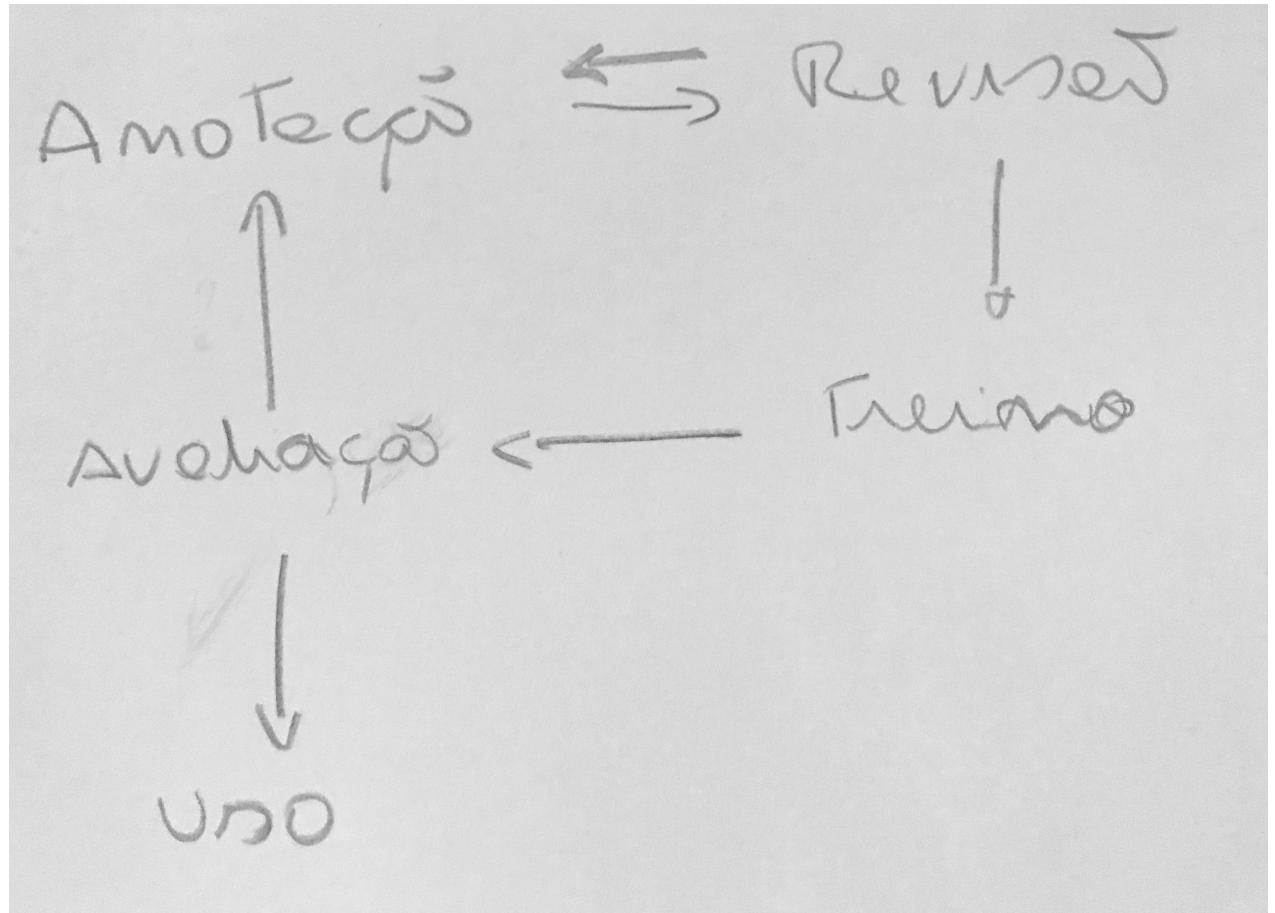
But that's what makes it fun!

# Mineração do DHBB

- Extração de Informações ou “reconhecimento de entidades mencionadas” ([https://en.wikipedia.org/wiki/Information\\_extraction](https://en.wikipedia.org/wiki/Information_extraction))
- Avaliação conjunta [\*\*HAREM\*\*](#) da Linguateca (2008)
- Identificação no texto de menções à:
  - Entidades
  - Relações
  - Co-Referências
- Demo <http://184.172.236.221:30000/home>

# Como?

- Modelagem do domínio: o que extrair? O que é relevante?
- Abordagens: **estatísticas** versus “linguisticamente motivadas”
- Combinação das abordagens.



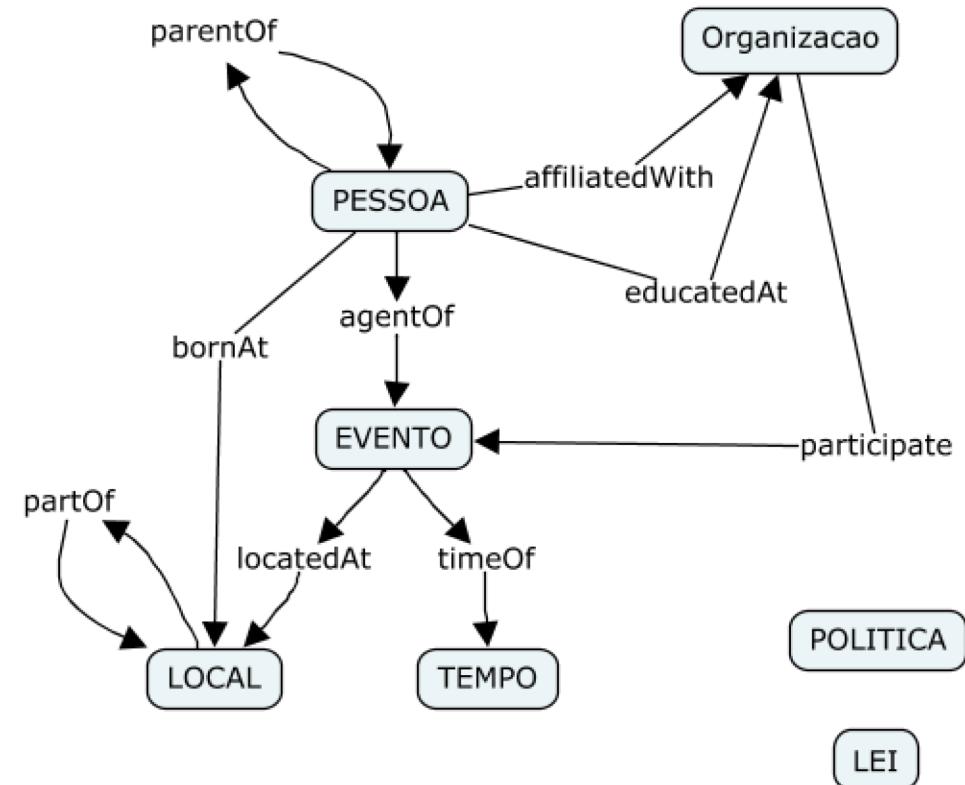
# Ferramentas IBM (Watson)

- Watson Knowledge Studio
- Serviços
  - Natural Language Understanding
  - Watson Discovery Service
  - IBM Cloud

The screenshot displays the IBM Watson Knowledge Studio interface. On the left, there's a navigation sidebar with sections like Model Management, Assets & Tools, Document Annotation (with 'Mentions' selected), Relations, Coreferences, Rules, and Help. The main workspace shows a document titled '49.txt' with several entities highlighted in yellow and red boxes. A semantic graph below the document shows entities like 'Emiliano Estanislau Afons' and 'Gerônico Estanislau' connected by relations such as 'agentOf', 'locatedAt', and 'partOf'. To the right, there's a 'Performance' section for a model named 'dhbb' (Language of documents: Portuguese (BR)). It shows a pie chart with 34 Training Set, 11 Test Set, and 4 Blind Set. Below it is a 'Document set evaluation' section with a line graph titled 'Model over time' showing scores from version 1.0 to 1.4. The graph has two series: one in green and one in blue. The green series starts at ~0.80, dips to ~0.75 at version 1.1, then rises to ~0.78 at version 1.4. The blue series starts at ~0.60, dips to ~0.55 at version 1.1, then rises to ~0.70 at version 1.4. A legend on the right indicates that green dots represent 'Mention' and blue dots represent 'Relation'. Other metrics shown include 'Precision' and 'Recall' for both. A legend also lists various relation types with corresponding colored squares.

# Modelagem

- O que existe e como aparecem nos textos?
- Que informações gostaríamos de ter e com qual estrutura?
- Que consultas queremos poder fazer?
- Qual a capacidade da ferramenta de aprender? Como saber o que não foi aprendido e o motivo?
- Caso DHBB: muita regularidade nos textos!



# Resultados atuais

- 50 documentos anotados
- Foco inicial parágrafos sobre: filiação, nascimento, educação, conjugue e falecimento.
- Performance de .68 (entidades) e .73 (relações)
- Demo online
- Melhoria Incremental



Current version insights

Mention breakdown [i](#) [Detailed Statistics](#)



## Ways to Improve

- Entities get confused with other entities when there are mixed examples. Ensure examples are consistent.
- Label more examples of low performing types.
- Add more documents with new examples.

.73 Precision: .79  
Recall: .67

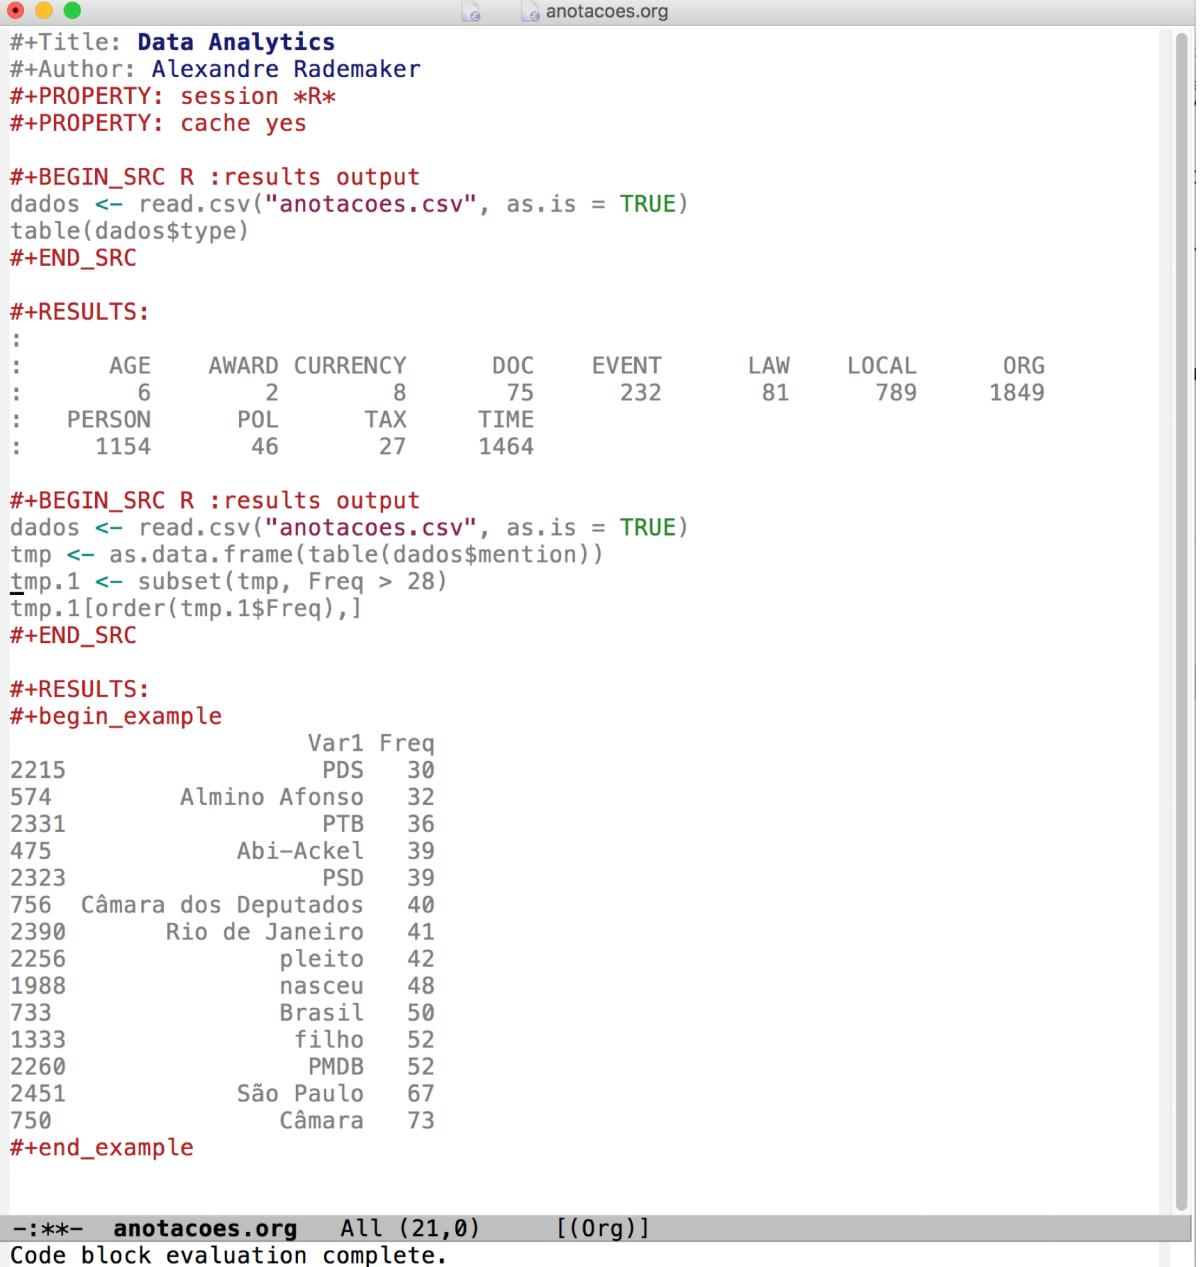
Coreference

-- Precision: --  
Recall: --

Low performing range

# Próximos passos

- Melhorar o dataset (promover avaliação e competição)
- Melhorar interface de busca
  - Maior flexibilidade
  - Flexibilidade vs facilidade
- Corpus como testes para métodos ‘linguisticamente motivados’ → adaptáveis!



The screenshot shows a RStudio-like environment with the following details:

- Title Bar:** anotacoes.org
- Code Block:**

```
#+Title: Data Analytics
#+Author: Alexandre Rademaker
#+PROPERTY: session *R*
#+PROPERTY: cache yes

#+BEGIN_SRC R :results output
dados <- read.csv("anotacoes.csv", as.is = TRUE)
table(dados$type)
#+END_SRC

#+RESULTS:
:
:
AGE      AWARD    CURRENCY      DOC     EVENT     LAW   LOCAL   ORG
:       6          2            8      75      232      81      789   1849
: PERSON      POL        TAX      TIME
:      1154      46         27      1464
```
- Code Block:**

```
#+BEGIN_SRC R :results output
dados <- read.csv("anotacoes.csv", as.is = TRUE)
tmp <- as.data.frame(table(dados$mention))
tmp.1 <- subset(tmp, Freq > 28)
tmp.1[order(tmp.1$Freq),]
#+END_SRC
```
- Code Block:**

```
#+RESULTS:
#+begin_example
:
:
Var1 Freq
2215      PDS  30
574       Almino Afonso 32
2331      PTB  36
475       Abi-Ackel 39
2323      PSD  39
756 Câmara dos Deputados 40
2390      Rio de Janeiro 41
2256      pleito 42
1988      nasceu 48
733       Brasil 50
1333      filho 52
2260      PMDB 52
2451      São Paulo 67
750       Câmara 73
#+end_example
```
- Status Bar:** -:\*\*\*- anotacoes.org All (21,0) [(Org)]  
Code block evaluation complete.

# Desafio OAB

Alexandre Rademaker (FGV/EMAp e IBM Research)

<http://arademaker.github.io>

<http://emap.fgv.br/corpo-docente/alexandre-rademaker>

<http://researcher.ibm.com/person/br-alexrad>

# Colaboradores

- Fabricio Chalub (IBM)
- Pedro Delfino (FGV/EMAp e FGV/Direito)
- Bruno Cuconato (FGV/EMAp)
- Henrique Muniz (FGV/EMAp e IBM)
- Guilherme Passos (IBM)
- Valéria de Paiva, Adam Pease, Gerard de Melo etc.

# O desafio da OAB

- Exame nacional da OAB
- Os exames fornecem uma excelente referência para o desempenho de sistemas de informações jurídicas.
- Interessante problema que requer >> entendimento
- Processamento superficial seguido de processamento profundo.
- No ML approach! GOFAI ("Good Old-Fashioned Artificial Intelligence")

# O Exame

- Apenas em 2010 os exames foram unificados nacionalmente.
- Dois estágios, estamos trabalhando apenas no primeiro, questões multiplas escolhas.
- 80 questões com 4 opções. Performance minima de 50%.
- A cada ano, 3 aplicações do exame.
- O exame tem uma taxa de 80% de reprovado. Em julho de 2017, a reprovado foi de 86%

# Questões por assunto

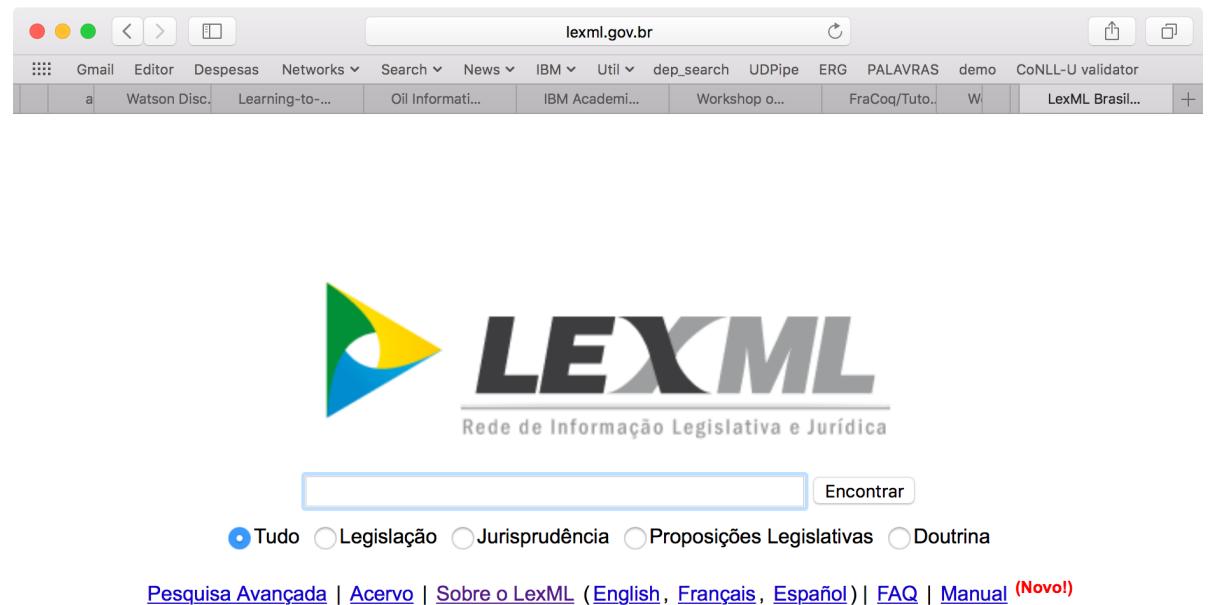
area	#	(%)	area	#	(%)
Ethics	10	65	Constitutional Law	7	42
Consumer's Law	2	56	Civil Procedures	6	40
Children's Law	2	54	Philosophy	2	40
Criminal Procedures	5	47	Labor's Law Proc.	6	40
Regulatory Law	6	47	Criminal Law	6	38
Human Rights	3	47	International Law	2	37
Civil Law	7	44	Business Law	5	33
Environmental	2	43	Taxes	4	42
Labor's Law	5	42			



# Leis

- Como tartar as leis?
- Estrutura das leis é relevante.
- Portal e padrão de codificação de leis (LexML)

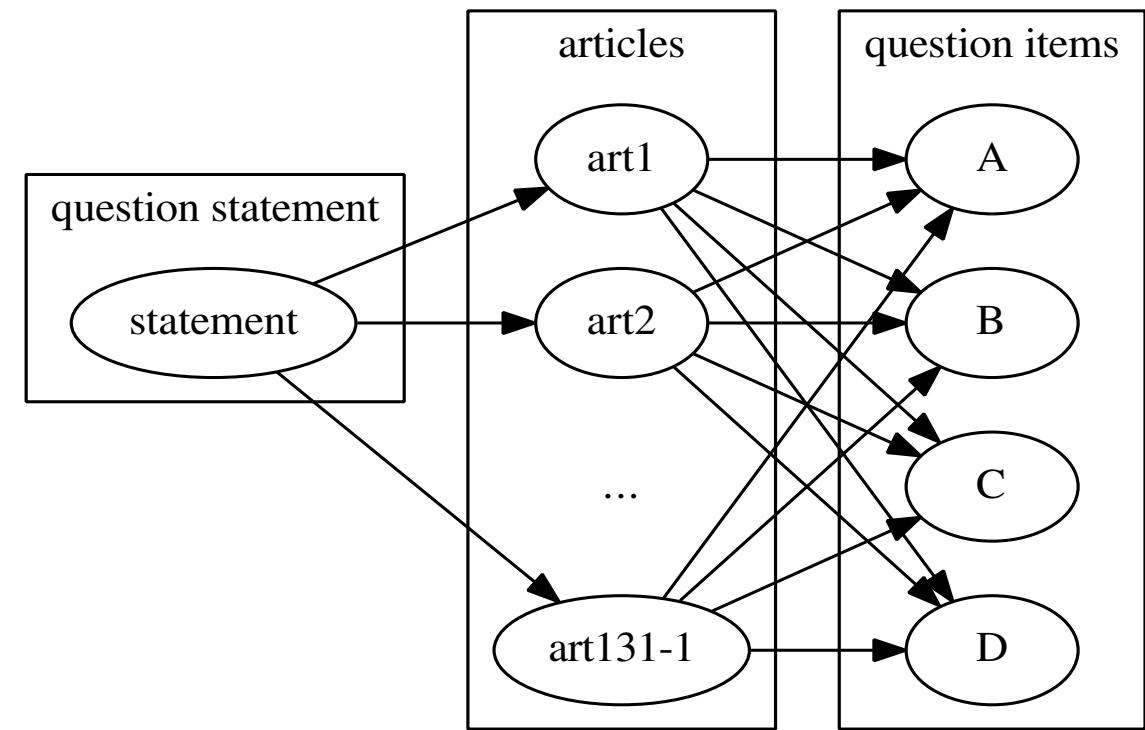
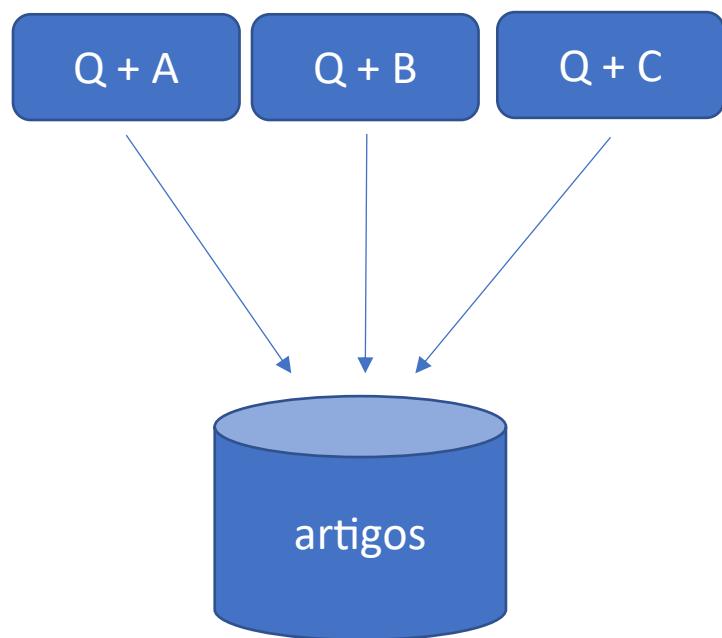
<http://www.lexml.gov.br>



# Conjunto manual de verificação

- Escolhemos 60 questões de ética e constitucional
- Um dos pesquisadores identificou para cada questão qual artigo de qual lei justifica a resposta.
- Em geral um artigo por questão.
- Em Ética, 3 normas (leis).
- Em constitucional, decisões do STJ e outros.
- Como lidar com revisões de leis?

# Experimentos: IR e graph



# Resultados parciais (baselines)

Os jovens Rodrigo, 30 anos, e Bibiana, 35 anos, devidamente inscritos em certa seccional da OAB, desejam candidatar-se, pela primeira vez, a cargos de diretoria do Conselho Seccional respectivo. Rodrigo está regularmente inscrito na referida seccional da OAB há seis anos, sendo dois anos como estagiário. Bibiana, por sua vez, exerceu regularmente a profissão por três anos, após a conclusão do curso de Direito. Contudo, afastou-se por dois anos e retornou à advocacia há um ano. Ambos não exercem funções incompatíveis com a advocacia, ou cargos exoneráveis ad nutum. Tampouco integram listas para provimento de cargos em tribunais ou ostentam condenação por infração disciplinar. Bibiana e Rodrigo estão em dia com suas anuidades.

Considerando a situação narrada, assinale a afirmativa correta.

## OPTIONS

- A) Apenas Bibiana preenche as condições de elegibilidade para os cargos.
- B) Apenas Rodrigo preenche as condições de elegibilidade para os cargos.
- C) Bibiana e Rodrigo preenchem as condições de elegibilidade para os cargos.
- D:CORRECT) Nenhum dos dois advogados preenche as condições de elegibilidade para os cargos.

Paulo é contratado por Pedro para promover ação com pedido condenatório em face de Alexandre, por danos causados ao animal de sua propriedade. Em decorrência do processo, houve condenação do réu ao pagamento de indenização ao autor, fixados honorários de sucumbência correspondentes a dez por cento do apurado em cumprimento de sentença. O réu ofertou apelação contra a sentença proferida na fase cognitiva. Ainda pendente o julgamento do recurso, Pedro decide revogar o mandato judicial conferido a Paulo, desobrigando-se de pagar os honorários contratualmente ajustados.

Nos termos do Código de Ética da OAB, a revogação do mandato judicial, por vontade de Pedro,

## OPTIONS

- A:CORRECT) não o desobriga do pagamento das verbas honorárias contratadas.
- B) desobriga-o do pagamento das verbas honorárias contratadas.
- C) desobriga-o do pagamento das verbas honorárias contratadas e da verba sucumbencial.
- D) não o desobriga do pagamento das verbas honorárias sucumbenciais, mas o desobriga das verbas contratadas.

# Tipos de questões

1. Narrativas e respostas longas
2. Factuais
3. Nomes de normas ou entidades
4. Negativa

# Mais que extração de informações!

Leonardo, and Bruno. Luana, 35 years old, was already a manager in a bank when she graduated. Leonardo, 30 years, is mayor of the municipality of Pontal. Bruno, 28 years old, is a military policeman in the same municipality. The three want to practice law in the private sector. Considering the incompatibilities and impediments to practice, please select the correct answer.

- A) Luana is not prohibited from practicing law because she is an employee of a private institution, so there are no impediments or incompatibilities.
- B) Bruno, like all other civil servants, is only prohibited from practicing the law against the government agency that remunerates him.
- C) The three graduates, Luana, Leonardo, and Bruno, have functions incompatible with legal practice. They are therefore prohibited from exercising private practice. (CORRECT)
- D) Leonardo is banned from practicing law only against or in favor of legal entities from the public sector, public companies, mixed-capital companies, public foundations, parastatal entities or concessionaire corporations or public service licensees.

(2016 OAB exam, 19th edition, question 4)

Art. 28. A advocacia é incompatível, mesmo em causa própria, com as seguintes atividades:

- I – chefe do Poder Executivo e membros da Mesa do Poder Legislativo e seus substitutos legais;
  - II – membros de órgãos do Poder Judiciário, do Ministério Público, dos tribunais e conselhos de contas, dos juizados especiais, da justiça de paz, juízes classistas, bem como de todos os que exerçam função de julgamento em órgãos de deliberação coletiva da administração pública direta e indireta;
  - III – ocupantes de cargos ou funções de direção em Órgãos da Administração Pública direta ou indireta, em suas fundações e em suas empresas controladas ou concessionárias de serviço público;
  - IV – ocupantes de cargos ou funções vinculados direta ou indiretamente a qualquer órgão do Poder Judiciário e os que exercem serviços notariais e de registro;
  - V – ocupantes de cargos ou funções vinculados direta ou indiretamente a atividade policial de qualquer natureza;
  - VI – militares de qualquer natureza, na ativa;
  - VII – ocupantes de cargos ou funções que tenham competência de lançamento, arrecadação ou fiscalização de tributos e contribuições parafiscais;
  - VIII – ocupantes de funções de direção e gerência em instituições financeiras, inclusive privadas.
- § 1º A incompatibilidade permanece mesmo que o ocupante do cargo ou função deixe de exercê-lo temporariamente.  
§ 2º Não se incluem nas hipóteses do inciso III os que não detenham poder de decisão relevante sobre interesses de terceiro, a juízo do conselho competente da OAB, bem como a administração acadêmica diretamente relacionada ao magistério jurídico.

# Next

XQuartz Applications Edit Window Help

valid tree for S:235

"A criança acredita que ela ligou o trator."

CS 1: S  
IP PUNCT  
DP VP  
Dbar Vbar  
NP V  
a N acrelita C  
criança que DP VP  
Dbar Vbar

kill prev next Commands Views n p

F-structure chart

"A criança acredita que ela ligou o trator."

PRED 'acreditar<[1:criança], [12:ligar]>'  
SUBJ 'criança'  
GLOSS [TRANS child]  
NTYPE [NSEM [COMMON count]]  
NSYN common  
SPEC [DET [PRED 'o']]  
1 [CASE nom, GEND fem, HUMAN +, NUM sg, PERS 3]  
PRED 'ligar<[17:pro], [23:trator]>'  
SUBJ 'pro'  
GLOSS [TRANS she]  
NTYPE [NSYN pronoun]  
17 [CASE nom, GEND fem, NUM sg, PERS 3, PRON-FOR]  
PRED 'trator'  
GLOSS [TRANS tractor]  
COMP OBJ  
OBJ [NSEM [COMMON count]]  
NSYN common  
SPEC [DET [PRED 'o']]  
23 [CASE acc, GEND masc, HUMAN -, NUM sg, PERS 3]  
GLOSS [TRANS start]  
TNS-ASP [MOOD indicative, TENSE perf]  
12 [CLAUSE-TYPE decl, COMP-FORM que, MOOD indicative, PA]  
GLOSS [TRANS believe]  
TNS-ASP [MOOD indicative, TENSE pres]  
9 [CLAUSE-TYPE decl, PASSIVE -, VTYPE main]

lock F-structure #1

"A criança acredita que ela ligou o trator."

PRED 'acreditar<[1:criança], [12:ligar]>'  
SUBJ 62 'criança'  
GLOSS [TRANS child]  
NTYPE [NSEM [COMMON count]]  
NSYN common  
SPEC [DET [PRED 'o']]  
82 [CASE nom, GEND fem, HUMAN +, NUM sg, PERS 3]  
PRED 'ligar<[17:pro], [23:trator]>'  
SUBJ 19 'pro'  
GLOSS [TRANS she]  
215 [NTYPE [NSYN pronoun]]  
216 [CASE nom, GEND fem, NUM sg, PERS 3, PRON-FOR]  
PRED 'trator'  
GLOSS [TRANS tractor]  
COMP OBJ  
OBJ 156 [NSEM [COMMON count]]  
NSYN common  
20 [SPEC [DET [PRED 'o']]  
22 [SPEC [DET [PRED 'o']]  
199 [193 [SPEC [DET [PRED 'o']]  
202 [194 [CASE acc, GEND masc, HUMAN -, NUM sg, PERS 3]  
219 [GLOSS [TRANS start]]  
16 [TNS-ASP [MOOD indicative, TENSE perf]]  
9 [CLAUSE-TYPE decl, COMP-FORM que, MOOD indicative, PA]  
230 [GLOSS [TRANS believe]]  
357 [TNS-ASP [MOOD indicative, TENSE pres]]

fschart for sentence 10

"A criança acredita que ela ligou o trator."

kill prev sentence next sentence most probable Commands Views

A F-structure chart

"A criança acredita que ela ligou o trator."

1. xle

software is made available AS IS,  
poration make no warranty about  
ance or its conformity to any specification.  
17 21:02.  
rmation.

gram/config.lfg...  
81 states, 129 arcs, and 137 disjuncts (139 DNF).  
ative to /Users/ar/work/brgram/

fig.lfg loaded  
Apr 05, 2018 15:21.

lfg 5  
inha.}  
)

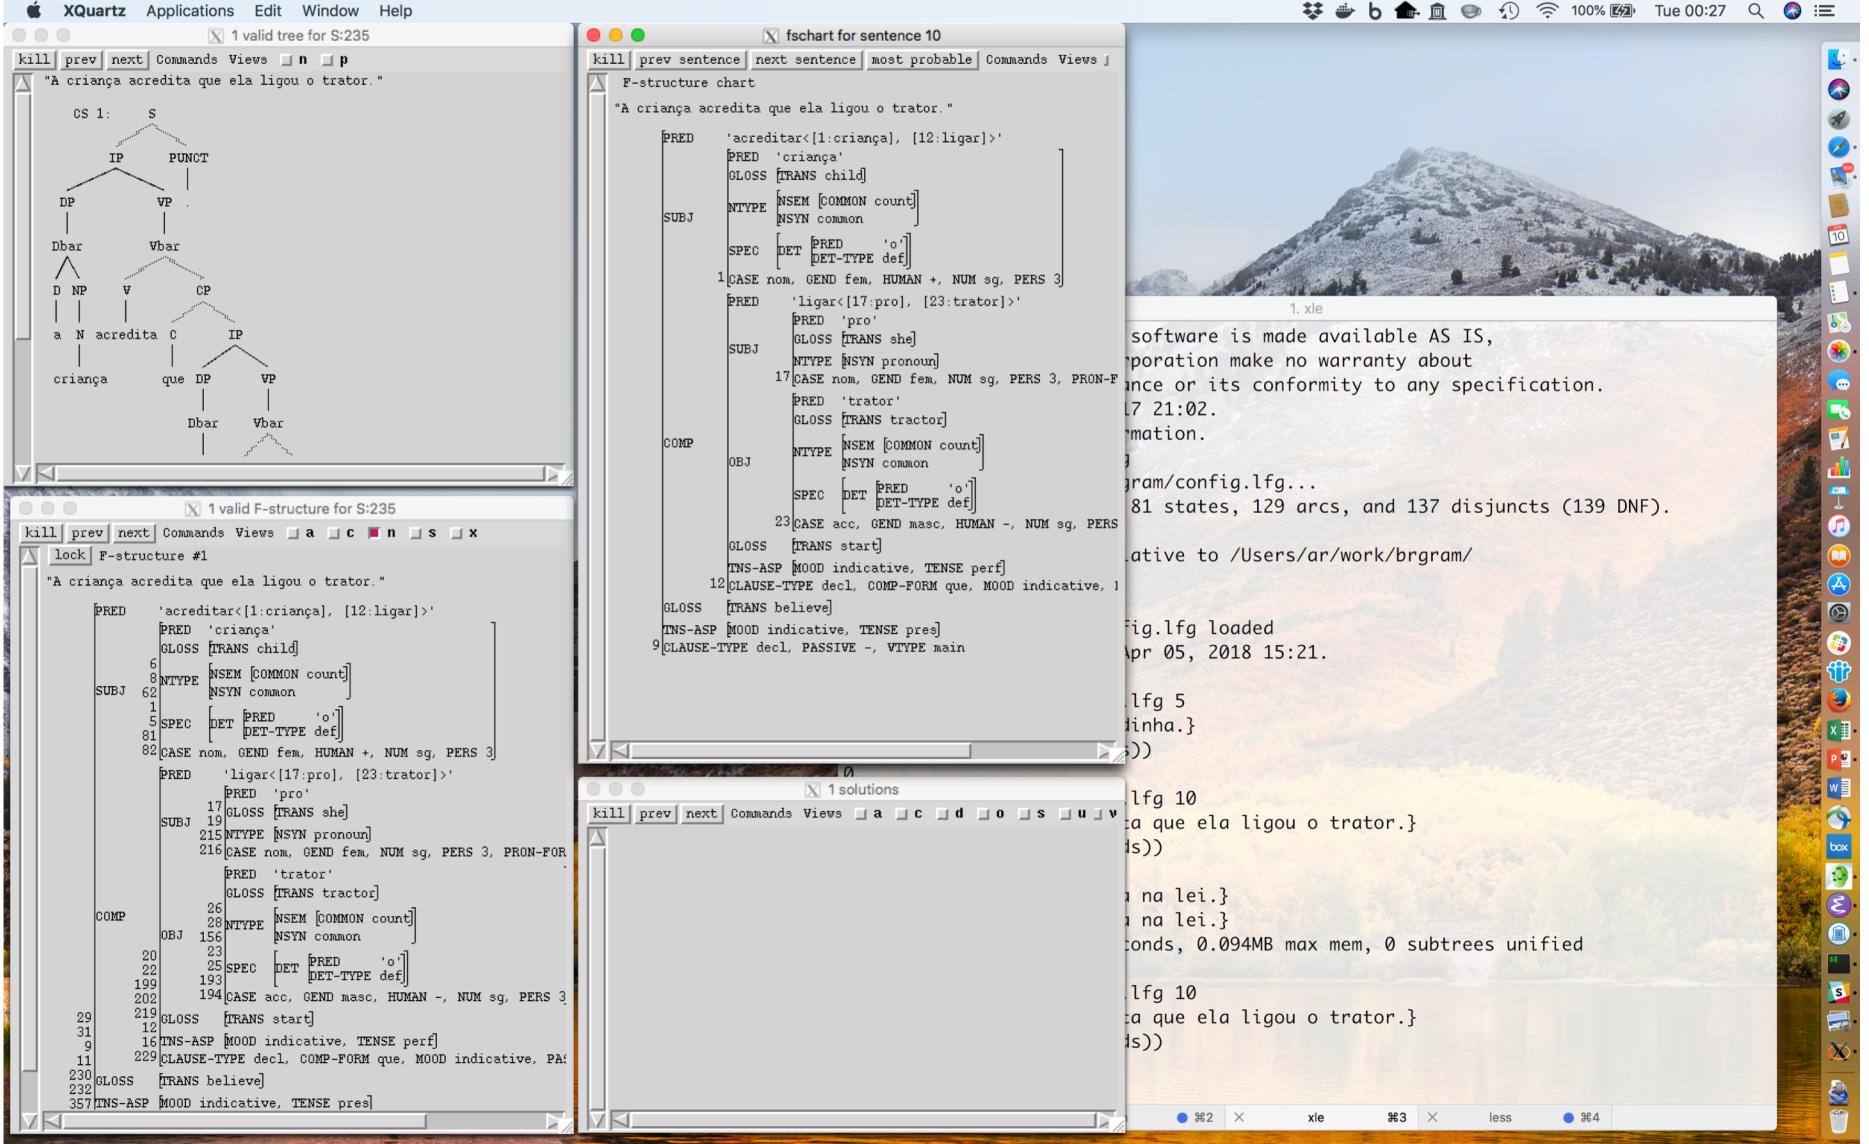
lfg 10  
ta que ela ligou o trator.}  
(s))

na lei.}  
na lei.}

onds, 0.094MB max mem, 0 subtrees unified

lfg 10  
ta que ela ligou o trator.}  
(s))

1. xle 2. xle 3. less



# Obrigado! Thanks!

[arademaker@gmail.com](mailto:arademaker@gmail.com)

[alexrad@br.ibm.com](mailto:alexrad@br.ibm.com)