

conta-me
histórias



conta-me histórias

temporal summarization and the Portuguese
web archive

Ricardo Campos, Arian Pasquali, Vítor Mangaravite,
Alípio Jorge, Adam Jatowt

TPDL 2018



about me

arian pasquali

Researcher

University of Porto and LIAAD - INESC TEC



challenges

- . information overload
- . credibility crisis
- . fake news and post-truth era
- . filter bubbles
- . content based machine learning models (e.g. fact-checkers)
- . more than ever web archives are crucial resources



importance of web archives

the importance of preserving the history of the web

~ 2%
of the websites
disappear
every week *

~ 8%
of urls disappear
every year **

* Frank McCown, Catherine C. Marshall, and Michael L. Nelson. 2009. Why web sites are lost. *Commun. ACM* 52, 11 (November 2009), 141-145.

** Legal Information Archive, The chesapeake project report. 2008

2018 Arquivo.pt announces a free text search API

Challenge Arquivo.pt Prizes

- Use public API to create innovative ways to explore the web archive

<https://sobre.arquivo.pt/en/collaborate/submissions-for-the-arquivo-pt-prizes-2018/>



troika em Portugal [Pesquisa avançada](#)

entre: e:

Resultados 1 a 10 de 23.776.571

[Livro Os 10 erros da Troika em Portugal - Figueiras \(Porto\) ...](#)
15 Abril, 2015 - Listar versões
Livro Os 10 erros da **Troika em Portugal** - Figueiras (Porto) - Livros - Revistas Livro Os 10 erros da **Troika em Portugal** olx.pt Anunciar e Vender Anunciar Homepage Pesquisar My OLX Favoritos Início Lazer Livros - Revistas Livro Os 10 erros da **Troika em Portugal** Livro Os 10 erros da **Troika em ...**
<http://figueiras.olx.pt/livro-os-10-erros-da-troika-em-portugal-iid-463457489>

[Louça quer saber para onde vai 1.ª tranche da 'troika' -](#)
31 Maio, 2011 - Listar versões
Louça quer saber para onde vai 1.ª tranche da 'troika' - **Portugal** - DN Última hora Cronologia dos ...
ALUGUER/CRIME Mulheres que alugam o útero **em Portugal** ELEIÇÕES/PSD Passos Coelho diz que Santana ... o DN | Classificados | Loja do Jornal **Portugal** Globo Economia Ciência Artes TV & Media Opinião ...
http://www.dn.pt/inicio/portugal/interior.aspx?content_id=1866281

["Este programa está muito além do memorando" da 'troika' -](#)
8 Maio, 2011 - Listar versões
"Este programa está muito além do memorando" da 'troika' - **Portugal** - DN Última hora PCP deixa **em ...**
Espanha e no YouTube AJUDA EXTERNA Reino Unido põe **em** causa ajuda financeira a **Portugal** COCA COLA ... 'AJUDA EXTERNA Reino Unido põe **em** causa ajuda financeira a **Portugal** EUROVISÃO/EX-CONCORRENTES "A ...
http://www.dn.pt/inicio/portugal/interior.aspx?content_id=1847261

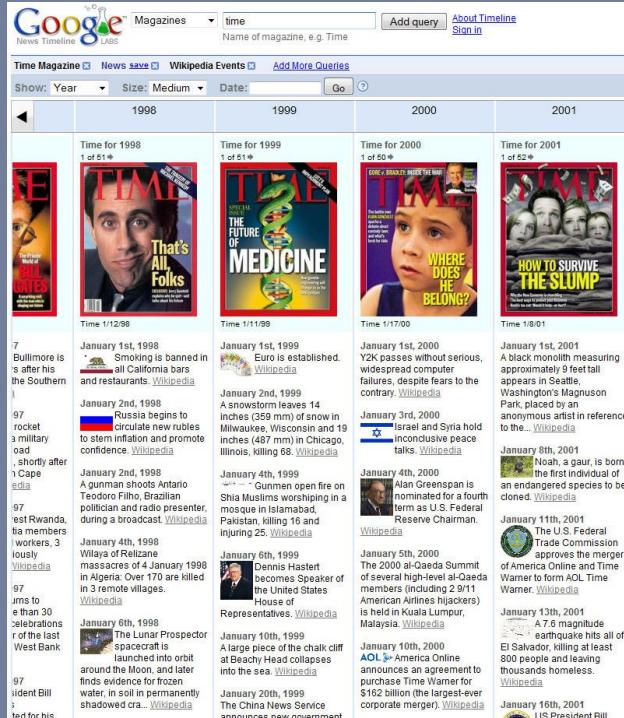
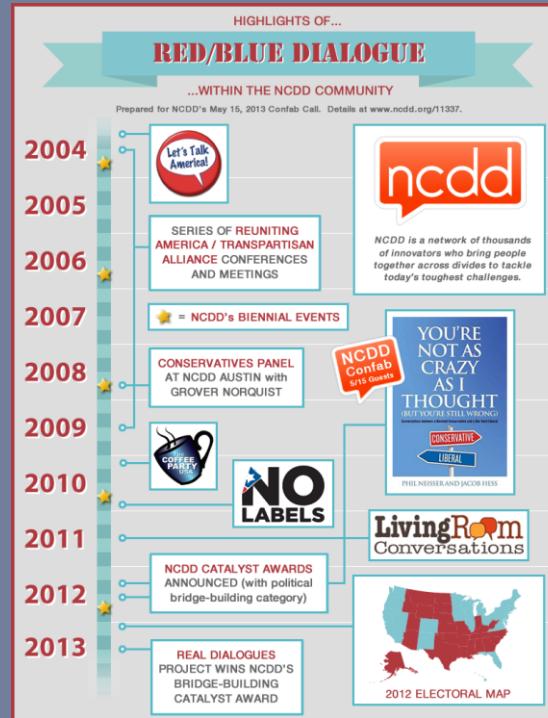
idea

what if we could generate a timeline about
any given topic automatically?

can we build a left-wing versus right-wing
narrative timeline?



timelines are a natural choice to explore long term stories



problem definition

given a search **query**
and a **timeframe**



generate a timeline
summarization with relevant
dates and headlines



steps

1. query news articles using arquivo.pt API

1. identify relevant time frames

1. identify relevant headlines



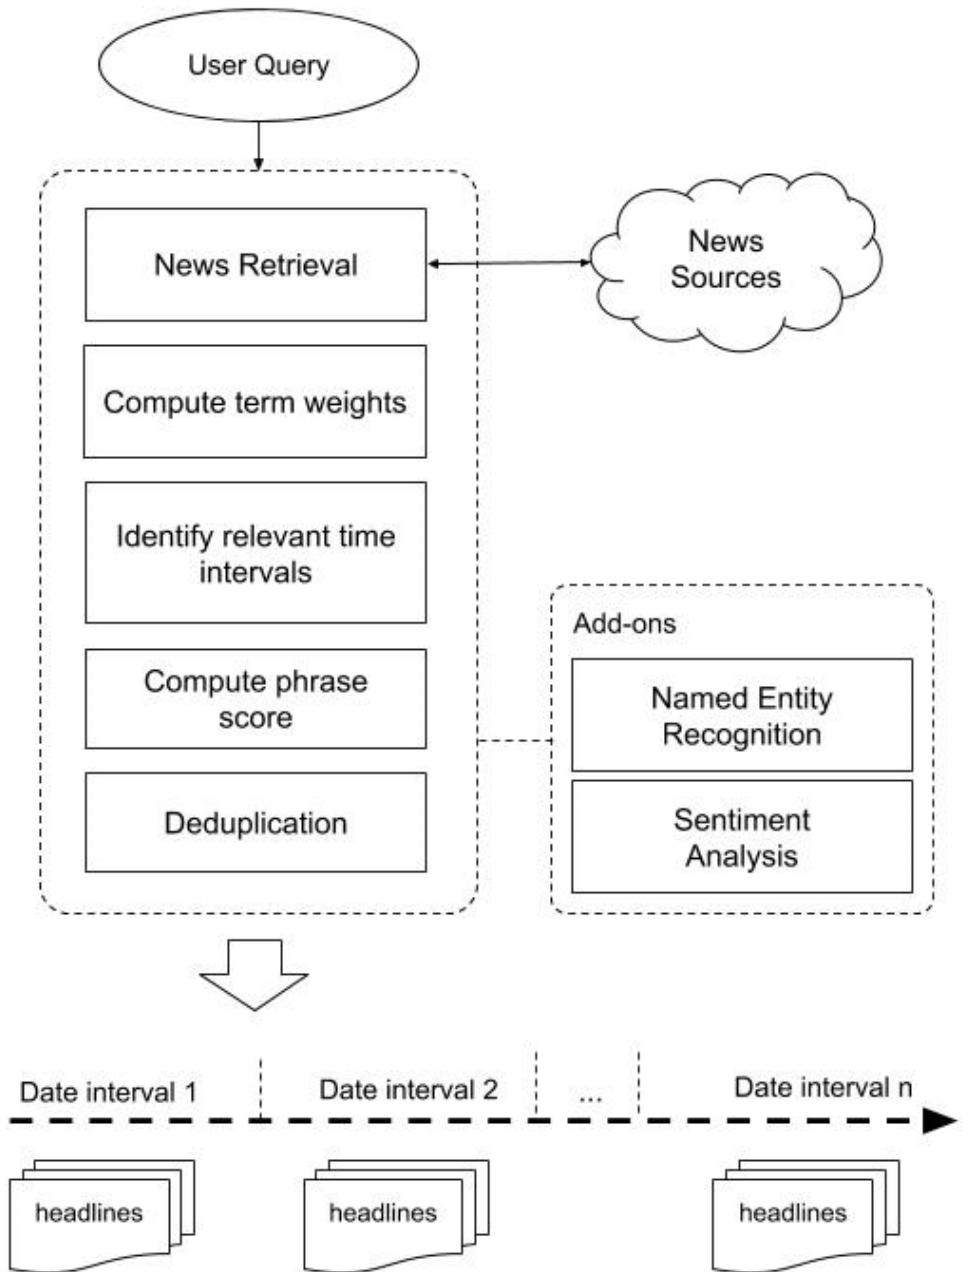
how to calculate headline relevance?

we apply principles of keyword extraction algorithms to calculate headlines relevance from a particular time frame



architecture

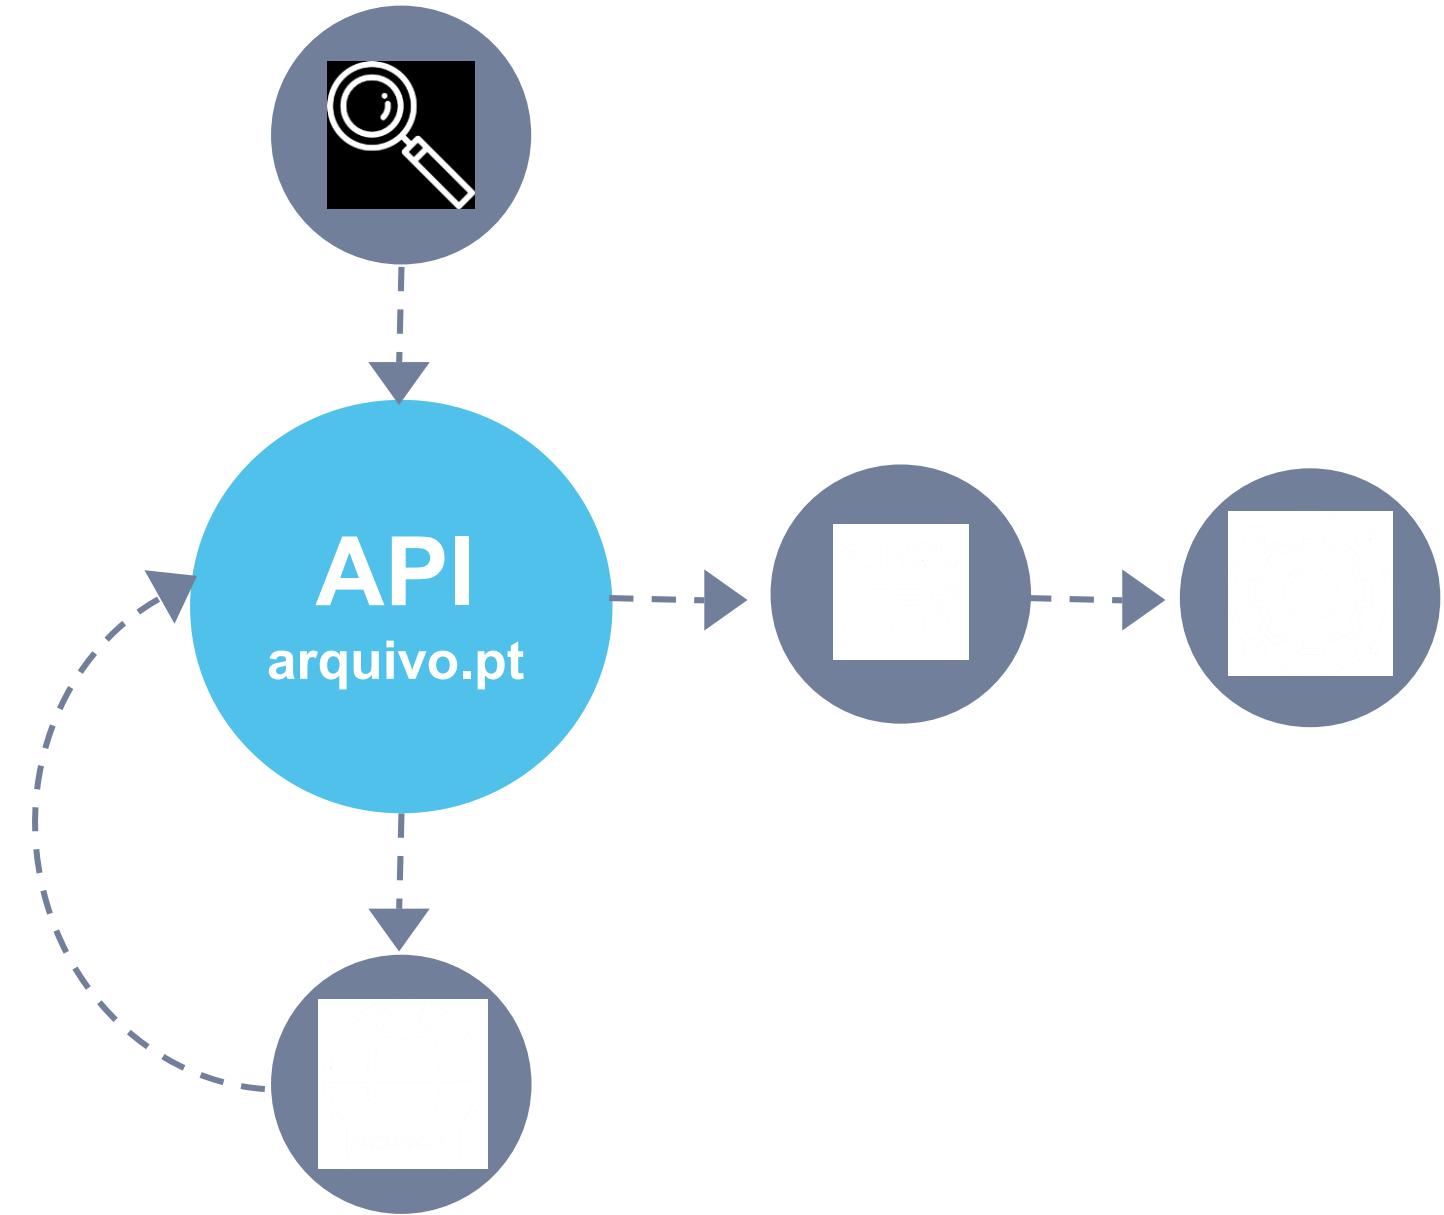
- given a search **query** and a **timeframe**
- apply principles of keyword extraction to compute relevant headlines from a particular time frame



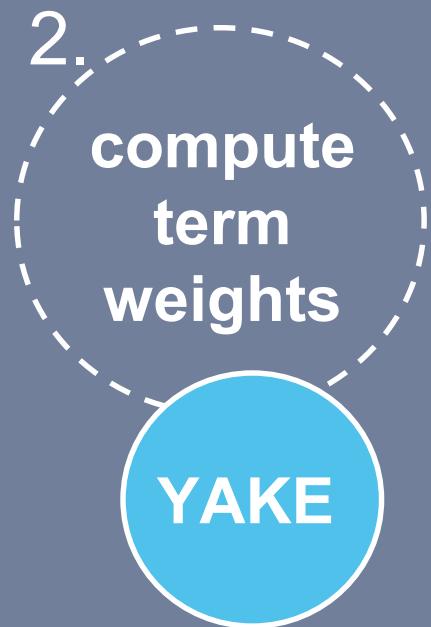
architecture



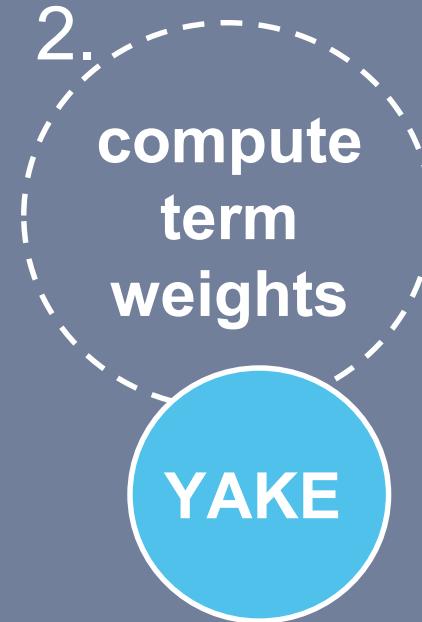
architecture



architecture



architecture



More information

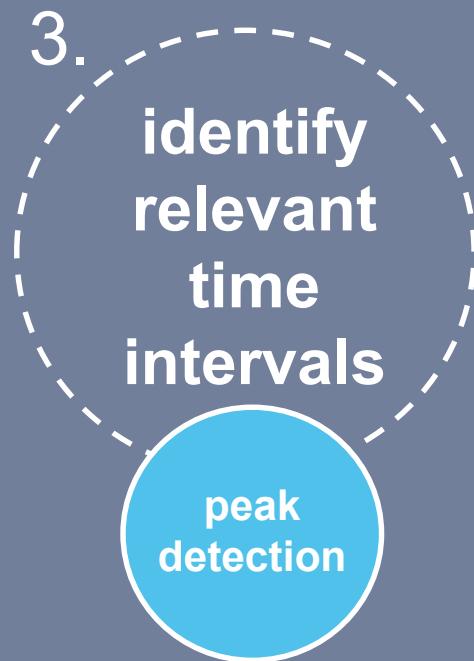
Campos, R., & Mangaravite, V., & Pasquali, A., & Jorge, A., & Nunes, C., & Jatowt, A. (2018). A Text Feature Based Automatic Keyword Extraction Method for Single Documents. Best Short Paper of ECIR'18
(<http://bit.ly/YakeDemoECIR2018>)

$$S(t) = \frac{TContext * TPos}{TCase + \frac{TFreq}{TContext} + \frac{TSent}{TContext}}$$

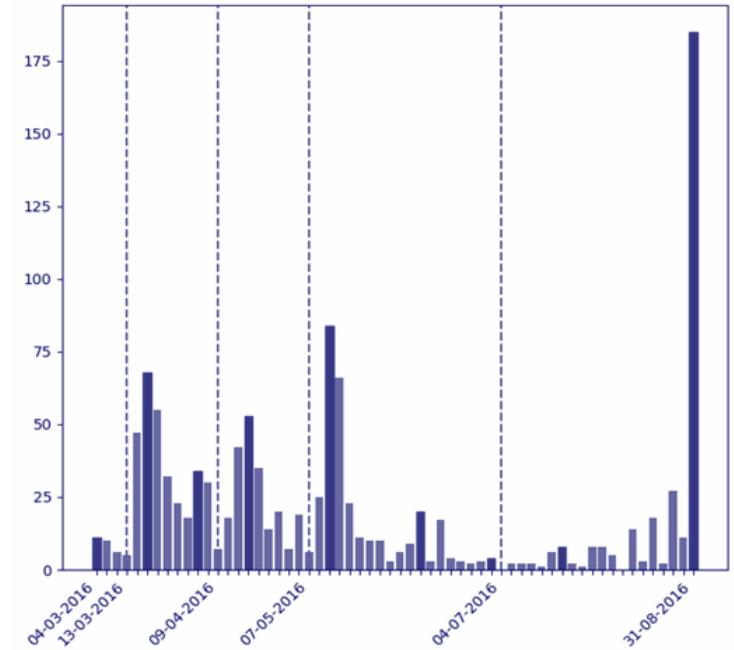
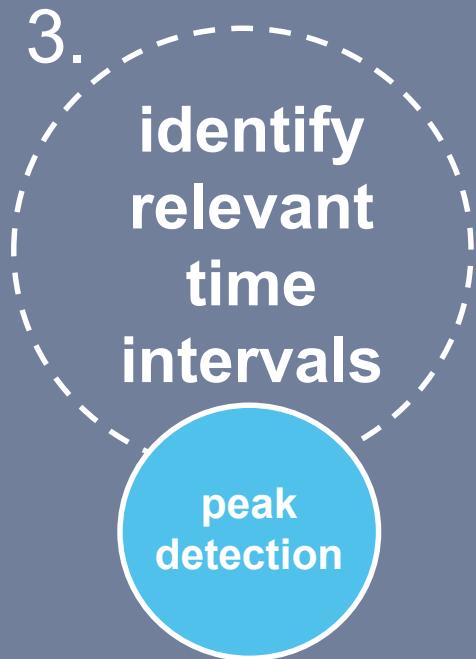
where:

- **TCase** - Casing
 - Reflects case aspect of a particular word
- **TPos** - Term position
 - Relevant terms tend to occur at the beginning of the document
- **TFreq** - Term frequency
 - Assumption that relevant words occur less
- **TSent** - term frequency on different headlines
 - How often a word appears within different headlines
- **TContent** - Term relatedness to context
 - Number of different terms that occur to the left (or right)
 - the more the number of different words around the candidate word, more meaningless the word is likely to be

architecture



architecture



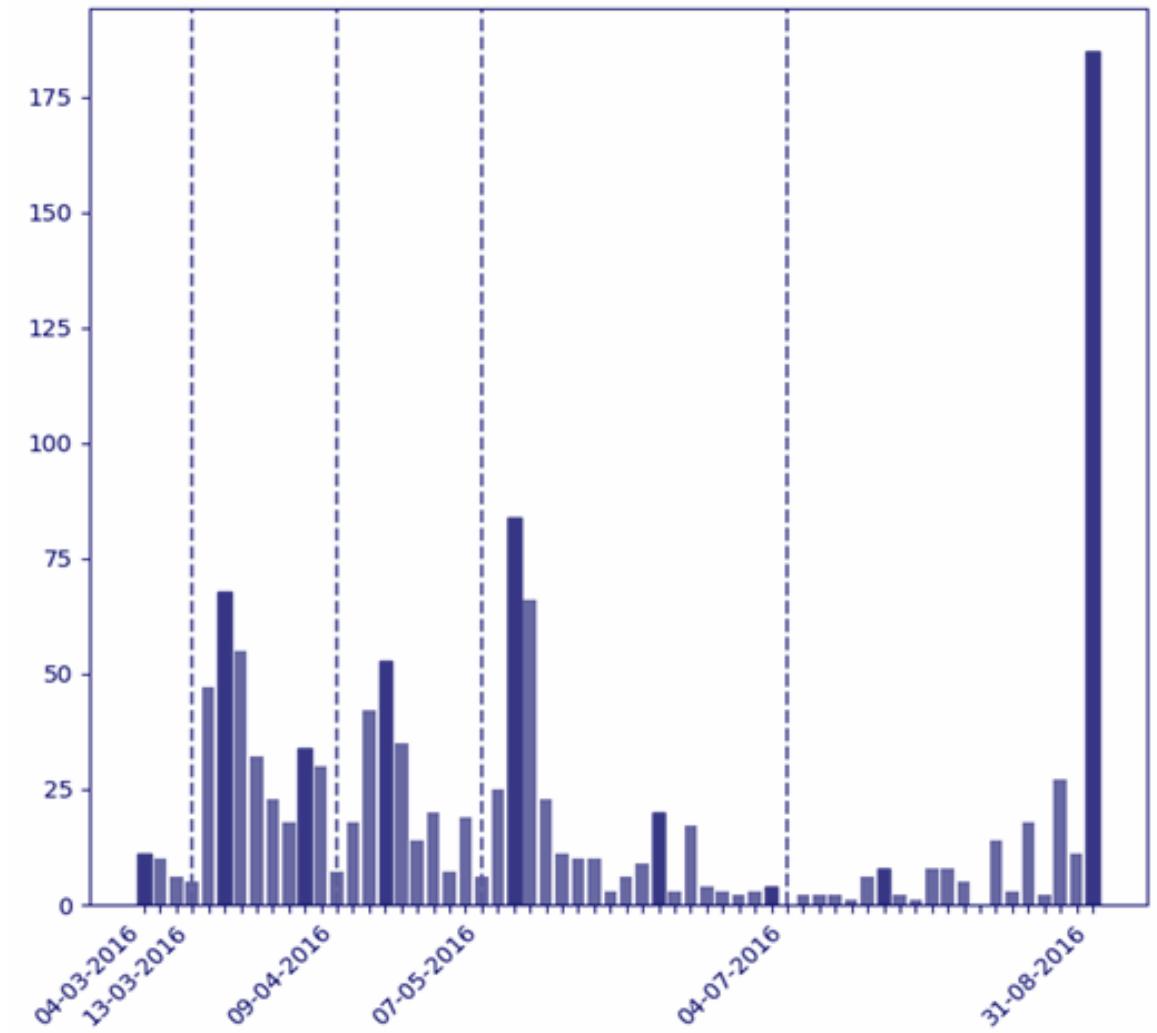
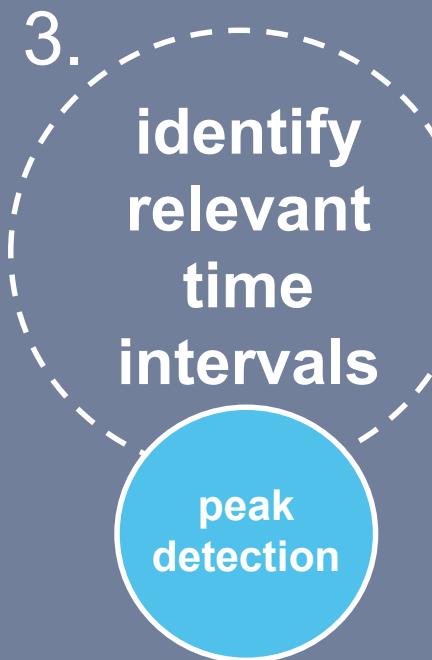
1. We aggregate count of news by date
2. We then detect peaks using scipy's relative extrema function

```
from scipy.signal import argrelextrema
```

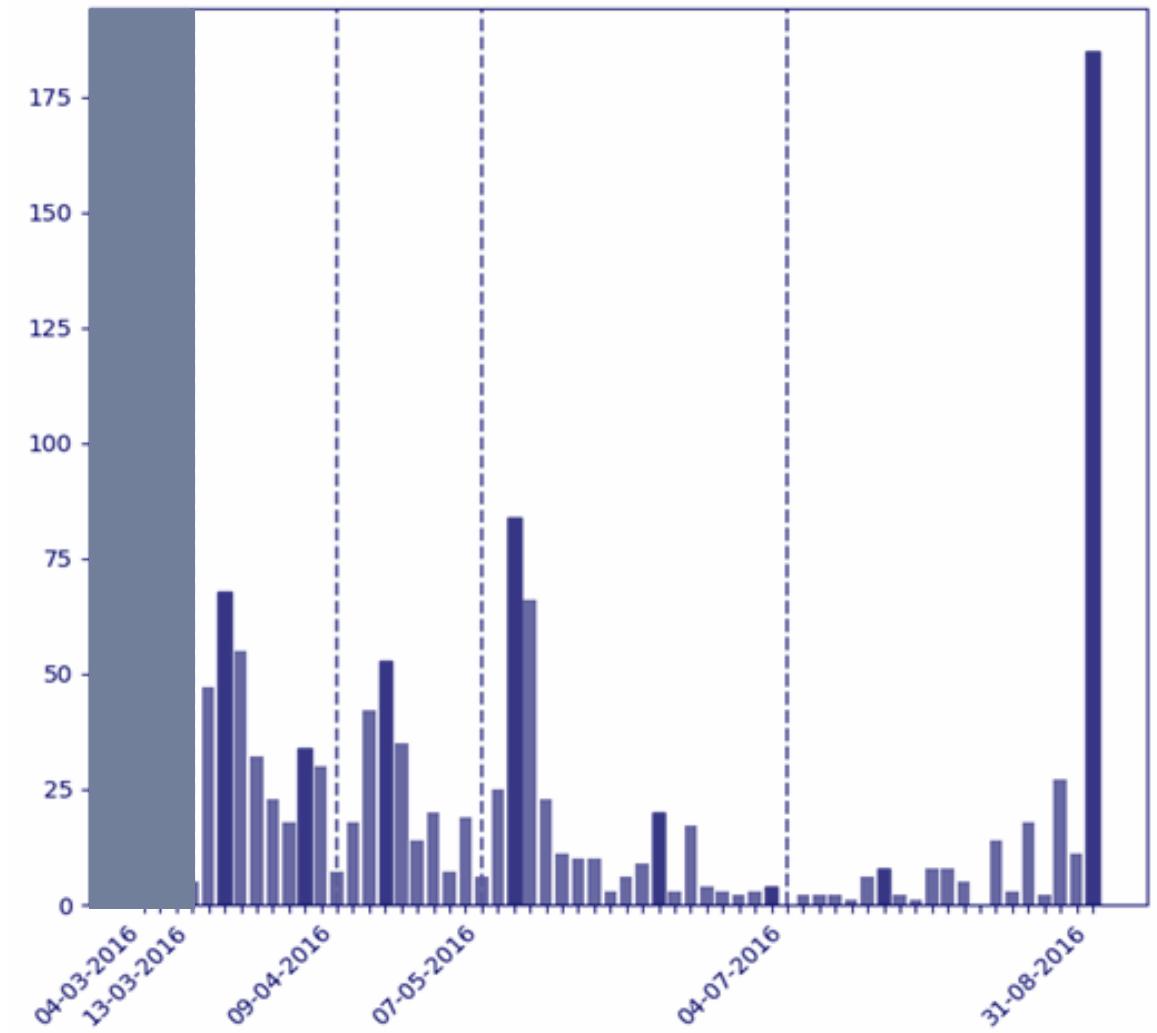
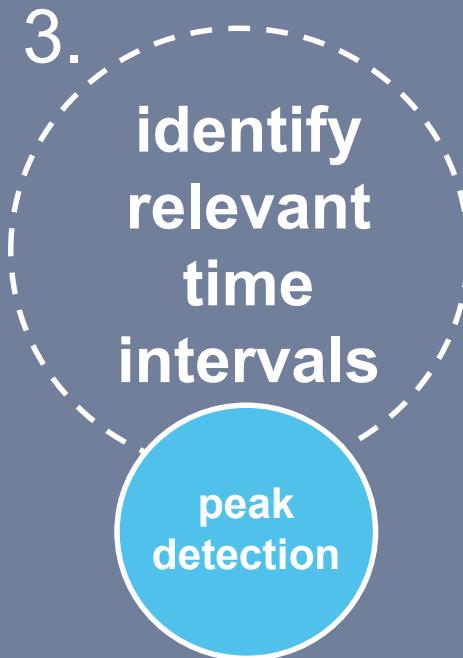
```
x = np.array([2, 1, 2, 3, 2, 0, 1, 0])
argrelextrema(x, np.greater, order=1)
```

```
>> (array([3, 6]), )
```

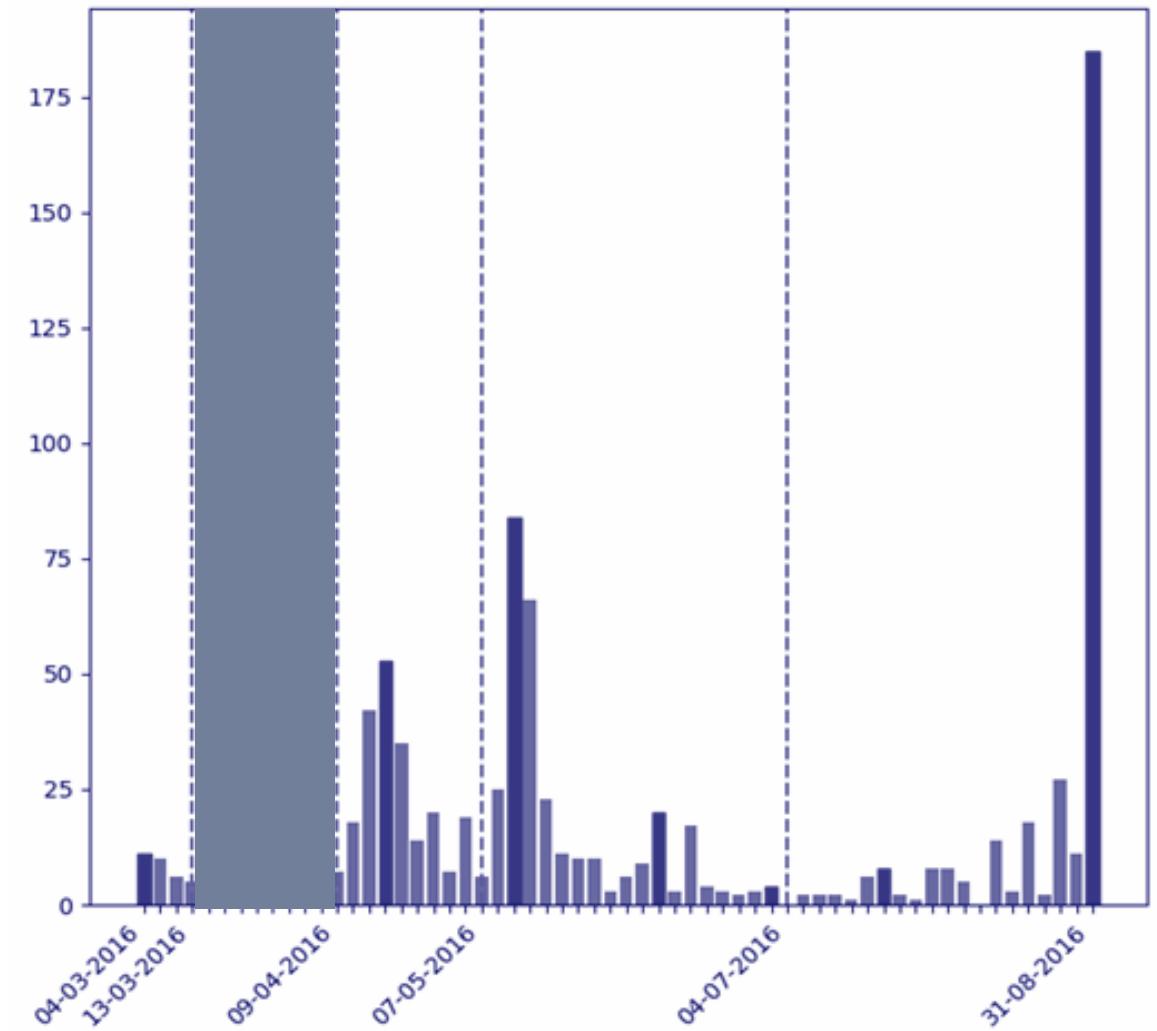
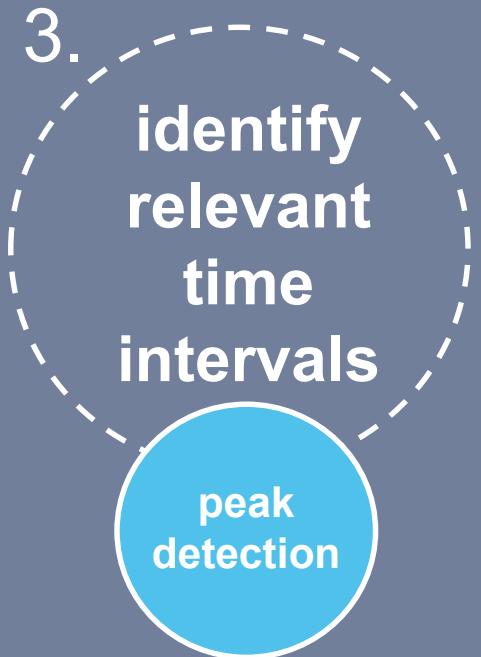
architecture



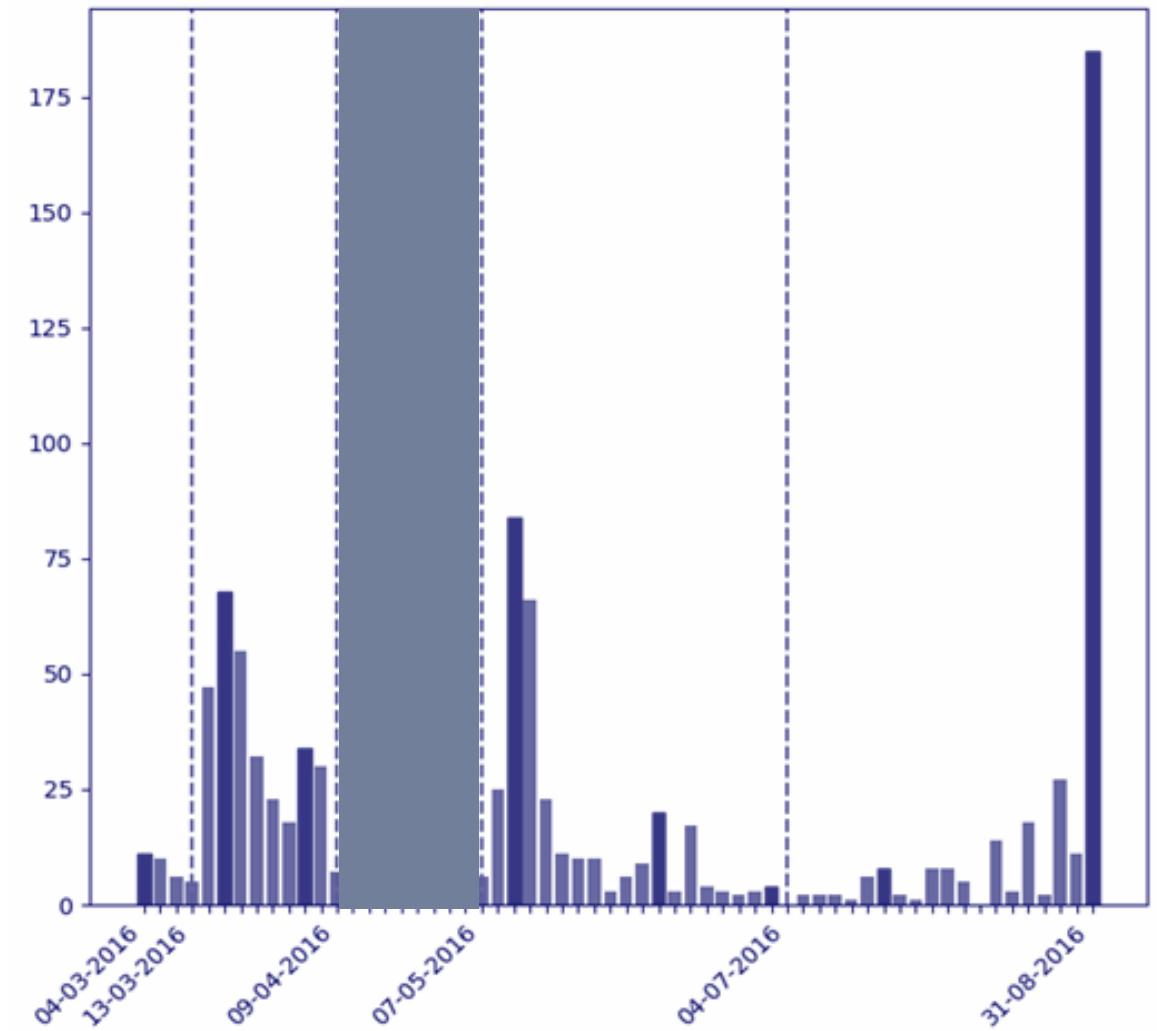
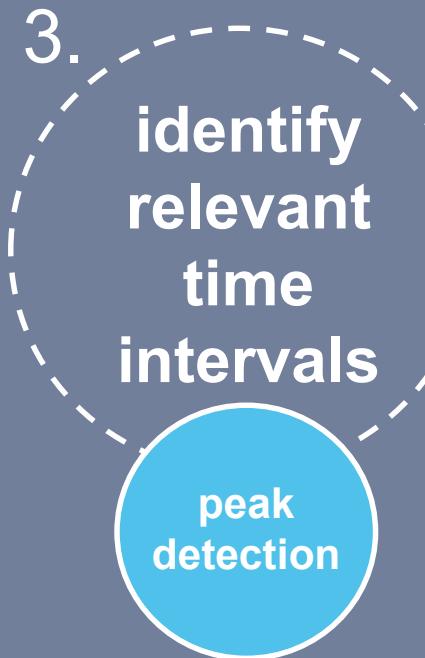
architecture



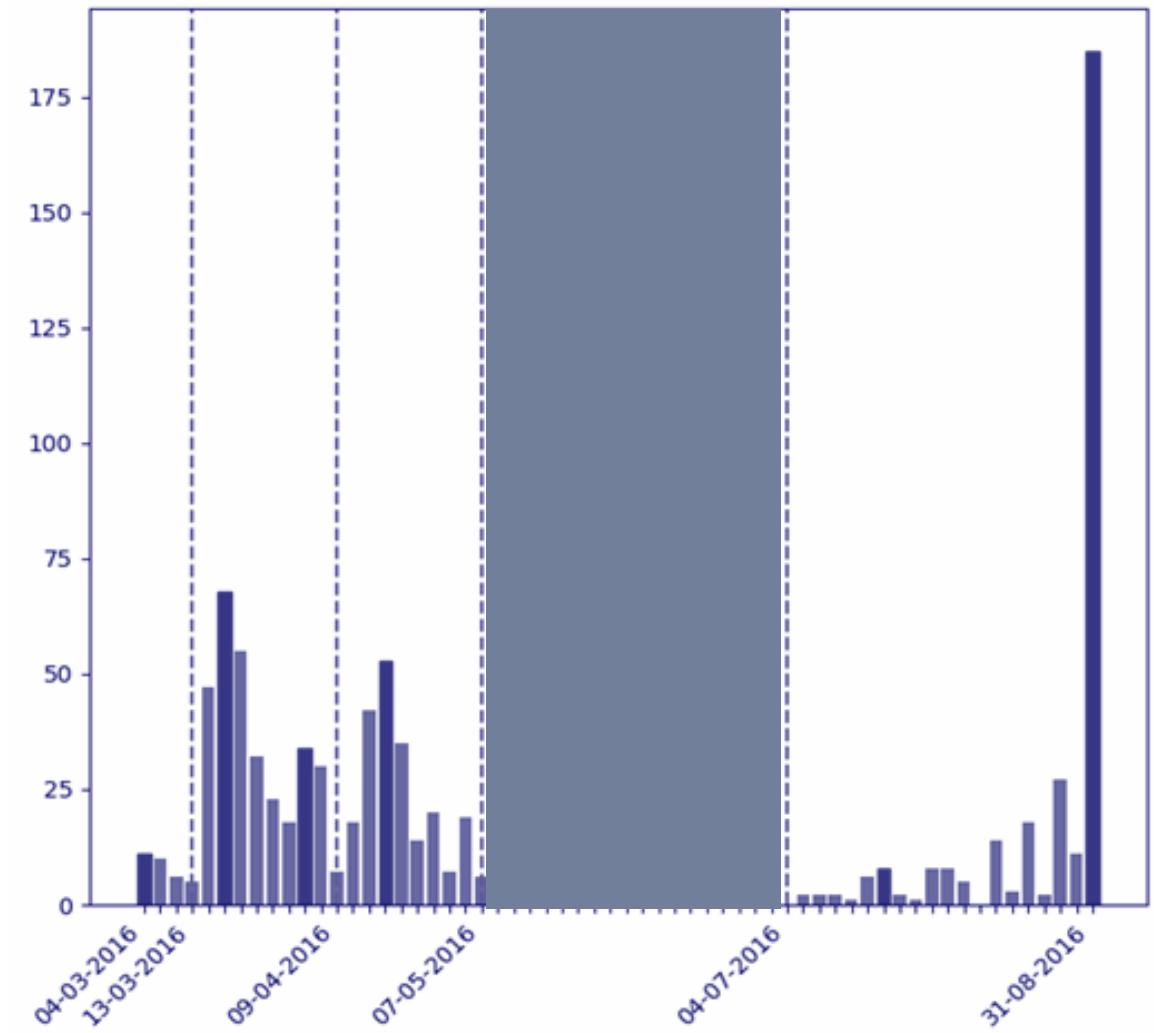
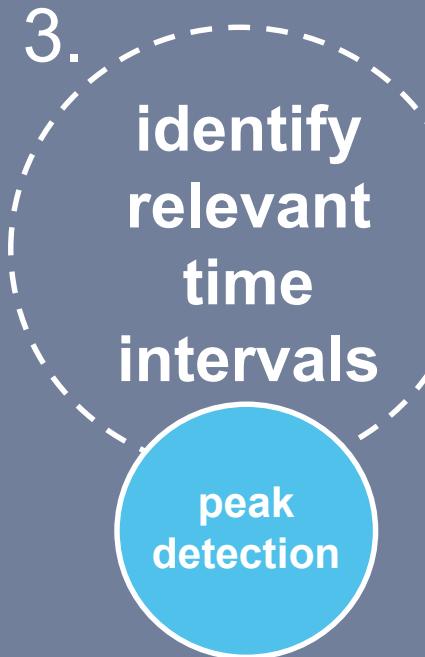
architecture



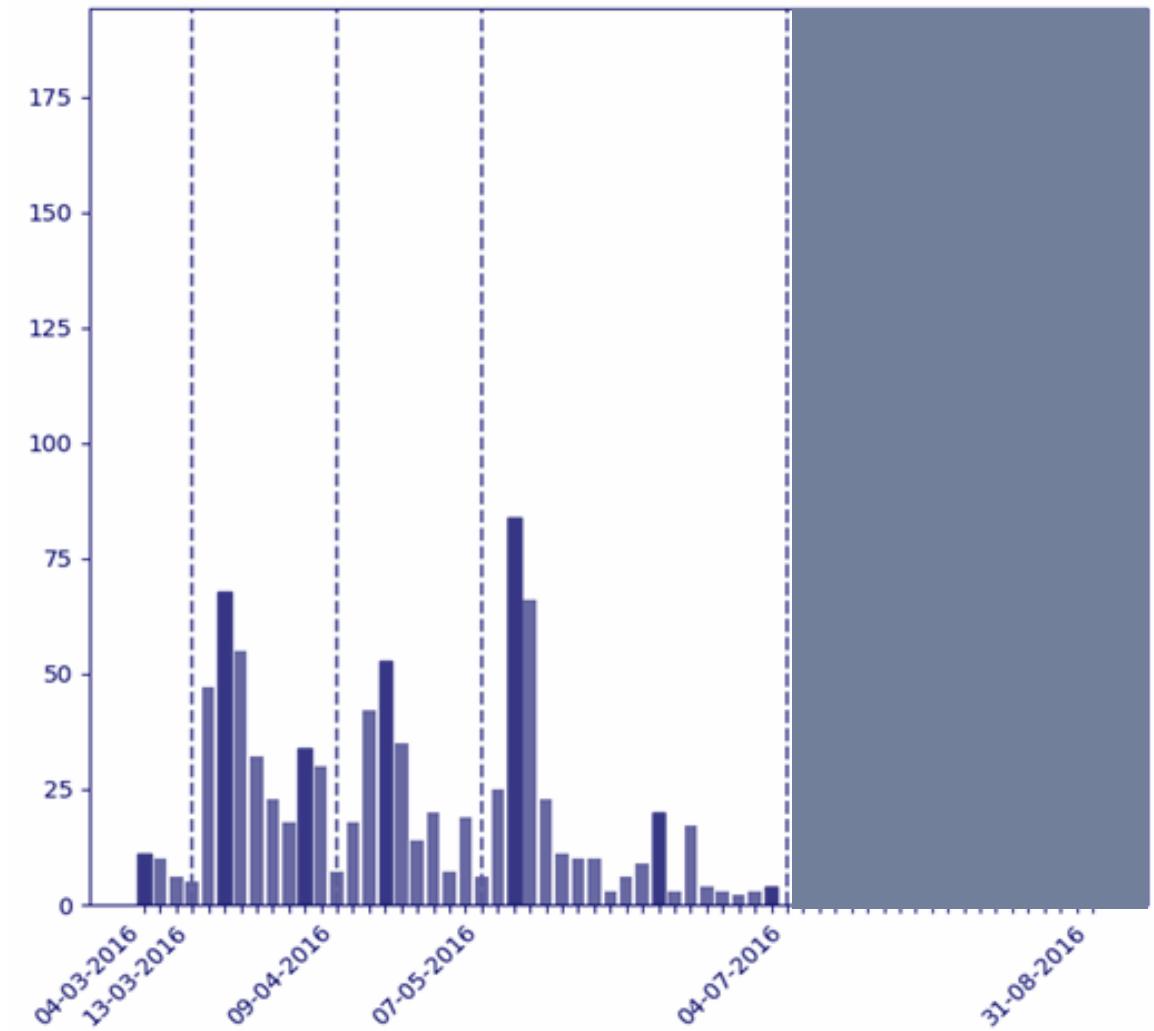
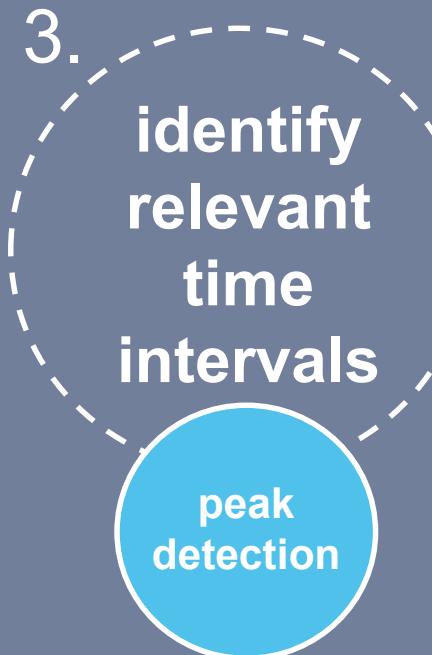
architecture



architecture



architecture



architecture



architecture



More information

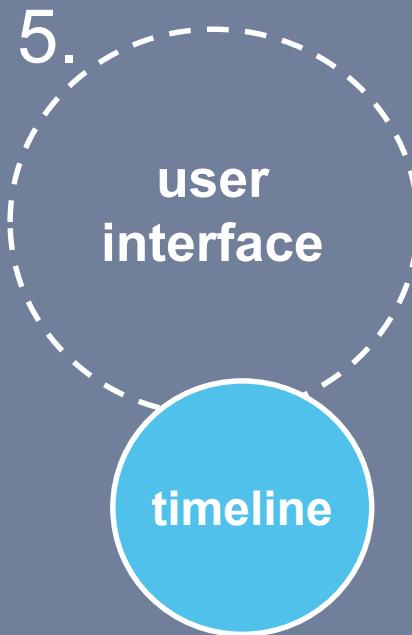
Campos, R., & Mangaravite, V., & Pasquali, A., & Jorge, A., & Nunes, C., & Jatowt, A. (2018). A Text Feature Based Automatic Keyword Extraction Method for Single Documents. Best Short Paper of ECIR'18
[\(<http://bit.ly/YakeDemoECIR2018>\)](http://bit.ly/YakeDemoECIR2018)

$$S(kw) = \frac{\prod_{w \in kw} S(w)}{\text{TF}(kw) + (1 + \sum_{w \in ks} S(w))}$$

Considering headlines from each time interval where:

- **S(w)** - term weight
 - Considers weights from every term in the headline
- **TF(kw)** - Headline frequency
 - How many times this headline occurs
- **S(kw)** - Final headline score

architecture



- Relevant headlines from **27, April 2014 until 20, February 2015**

- Jornalista e fotógrafo do The Times feridos na Síria. negative
- China e Rússia vetam proposta para julgar no TPI crimes de guerra na Síria. negative
- Guerra síria contamina ainda mais o Líbano. negative
- Irão liga ajuda contra Estado Islâmico a negociações nucleares.
- ONU acusa Síria e Estado Islâmico de crimes de guerra contra a humanidade. negative
- Casa Branca confirmou morte de norte-americano jihadista na Síria. negative
- Obama prepara mapa para atacar jihadistas na Síria.
- ONU quer governo e Estado Islâmico julgados por crimes de guerra. negative
- Obama afasta para já intervenção militar na Síria. negative
- Guerra civil na Síria fez mais de três milhões de refugiados. negative
- Primeiro-ministro britânico não afasta ação contra Estado Islâmico na Síria. negative
- Vídeo com refém britânico compara intervenção na Síria à do Vietname.
- Síria diz ter sido informada por Washington dos ataques contra o Estado Islâmico.
- Presidente da Síria fez rara aparição pública em mesquita de Damasco.
- Oposição Síria condena decapitação de cidadão britânico. negative
- Turquia quer mísseis da NATO apontados para a Síria.
- Turcos dão luz verde ao Exército Livre da Síria e travam curdos. positive
- Criminoso de guerra nazi Brunner morreu provavelmente na Síria. negative
- Terminou o ano com mais mortos na guerra civil síria. negative

more detailed information at

A Text Feature Based Automatic Keyword Extraction Method for Single Documents *

Campos, R., & Mangaravite, V., & Pasquali, A., & Jorge, A., & Nunes, C., & Jatowt, A. (2018).
40th European Conference on Information Retrieval (ECIR'18).
Grenoble, France. March 26 – 29. (Vol. 10772(2018), pp. 684 - 691).

YAKE! Collection-independent Automatic Keyword Extractor **

Campos, R., & Mangaravite, V., & Pasquali, A., & Jorge, A., & Nunes, C., & Jatowt, A. (2018).
40th European Conference on Information Retrieval (ECIR'18).
Grenoble, France. March 26 – 29. (Vol. 10772(2018), pp. 806 - 810).

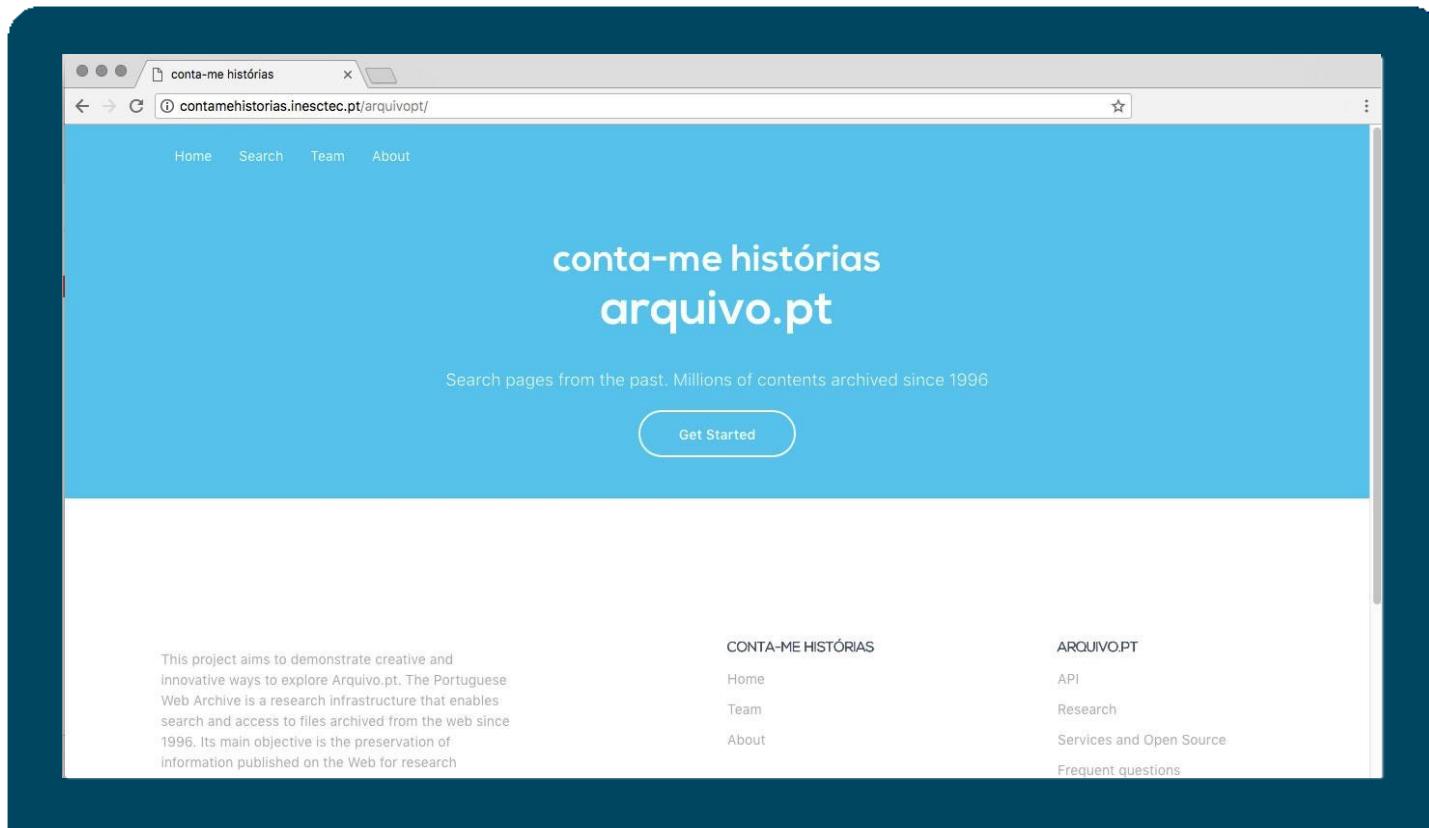


* ECIR 2018 Best Short Paper Award

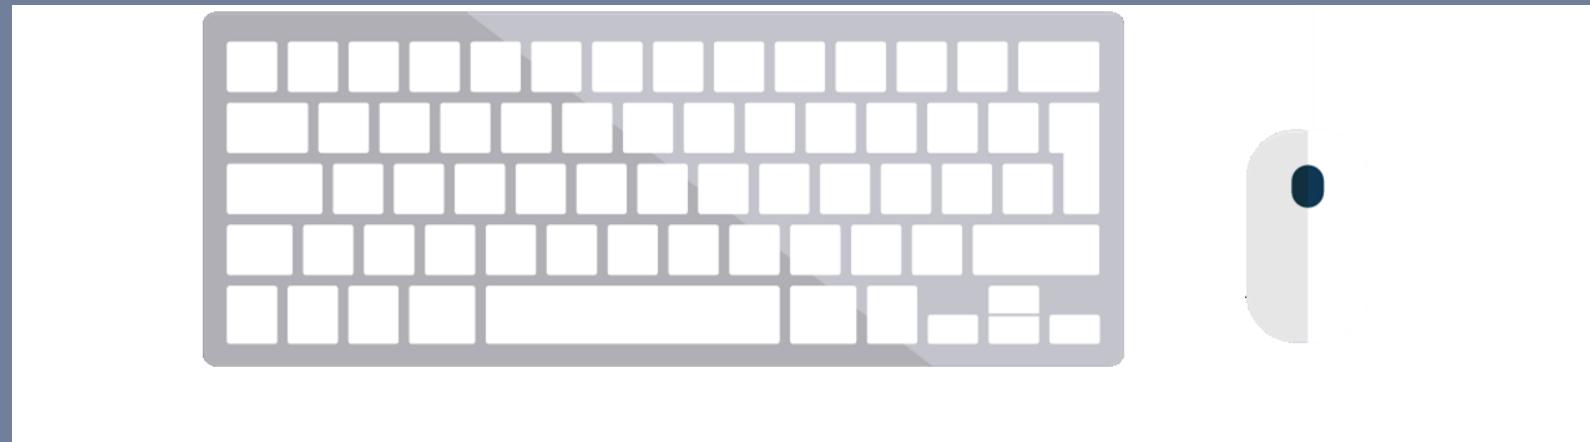
** Demo

<http://bit.ly/YakeDemoECIR2018>

contamehistorias.pt



<http://contamehistorias.pt>



The screenshot shows a laptop displaying the homepage of the website contamehistorias.inesctec.pt/arquivopt/. The page has a blue header bar with navigation links for Home, Search, Team, and About. Below this is a large white main area featuring the project's logo, "conta-me histórias arquivo.pt", in bold white text on a blue background. A sub-headline reads "Search pages from the past. Millions of contents archived since 1996". A prominent "Get Started" button is centered below the headline. The bottom section of the page is white, containing a paragraph about the project's purpose, a "Designed and coded with ❤️ by LIAAD" footer, and links to the "conta-me histórias" and "ARQUIVO.PT" sections.

conta-me histórias
arquivo.pt

Search pages from the past. Millions of contents archived since 1996

Get Started

This project aims to demonstrate creative and innovative ways to explore Arquivo.pt. The Portuguese Web Archive is a research infrastructure that enables search and access to files archived from the web since 1996. Its main objective is the preservation of information published on the Web for research purposes.

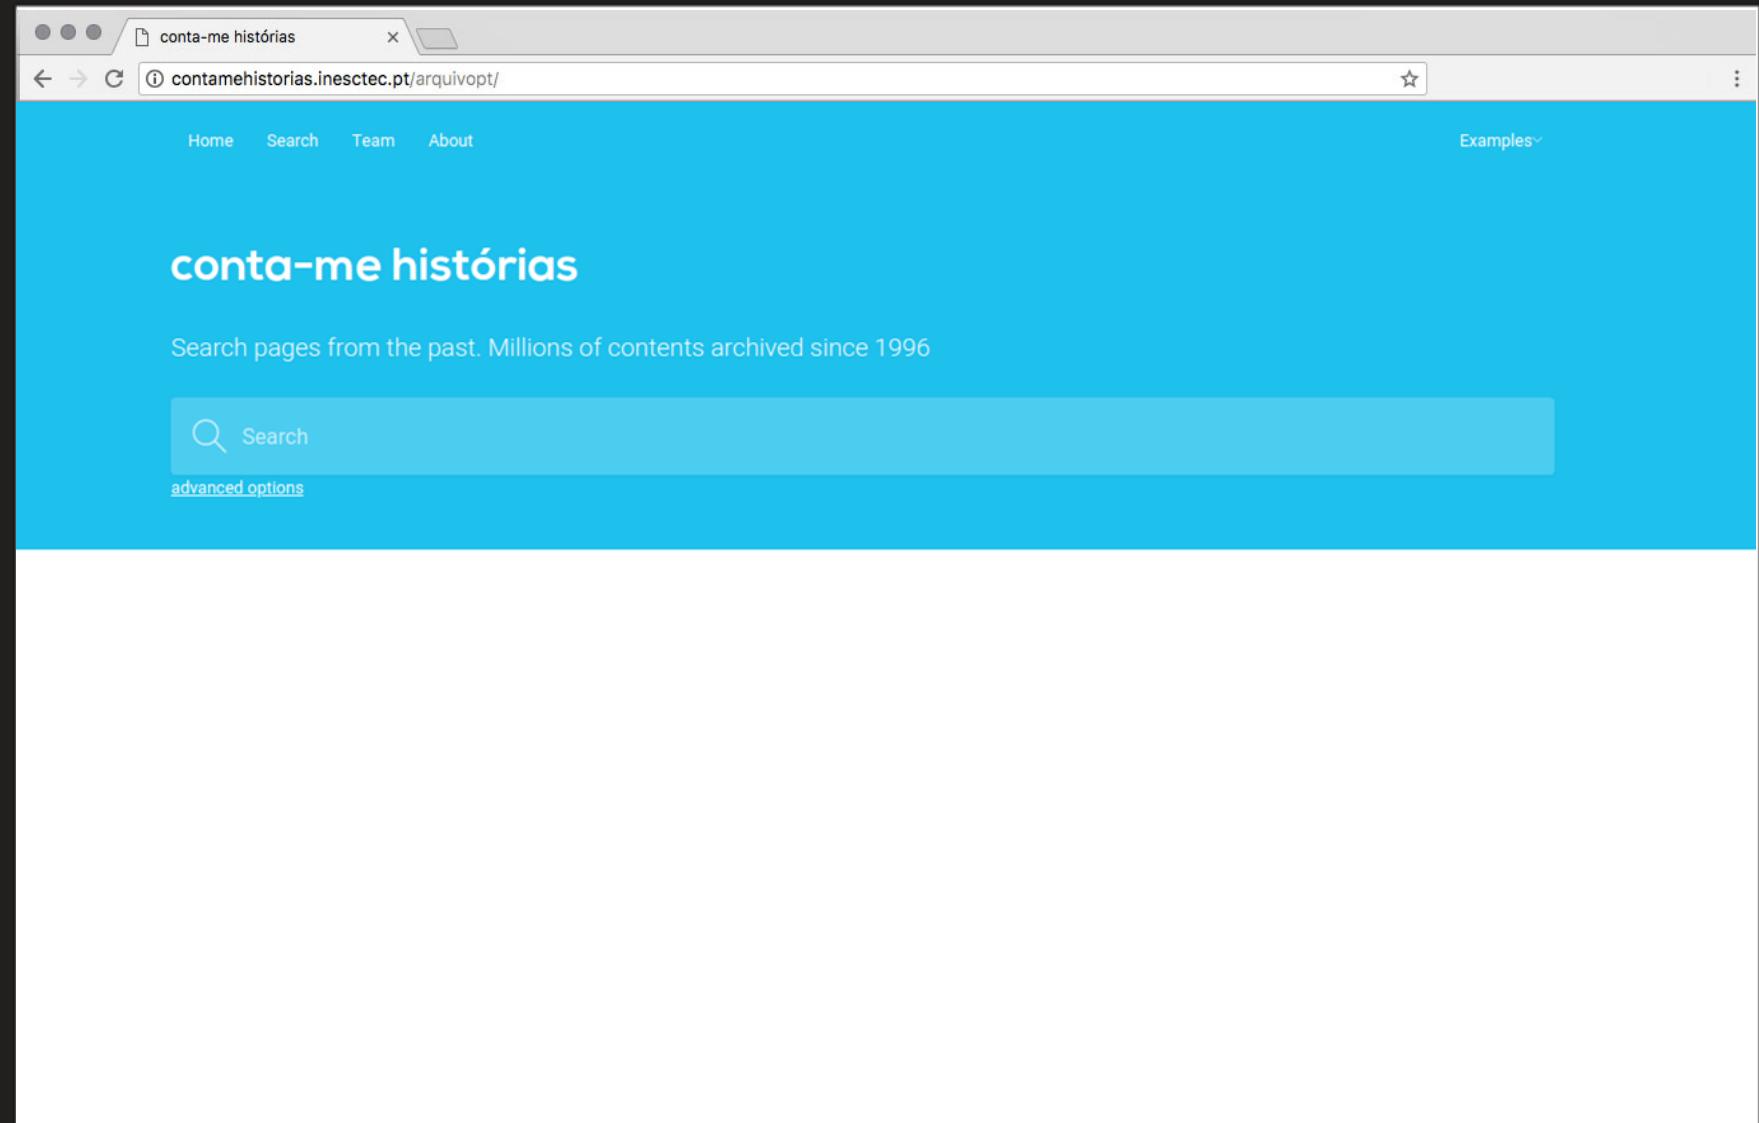
Designed and coded with ❤️ by LIAAD. Thanks to Instituto Politécnico de Tomar ; INESC TEC; University of Porto; Kyoto University

conta-me histórias

- Home
- Team
- About

ARQUIVO.PT

- API
- Research
- Services and Open Source
- Frequent questions



conta-me histórias

contamehistorias.inesctec.pt/arquivopt/

Home Search Team About Examples

conta-me histórias

Search pages from the past. Millions of contents archived since 1996

troika em portugal [advanced options](#)

7855 processed pages in 16.03 seconds (7.29 seconds of query time and 8.75 seconds spent analyzing content)

7855
PAGES FOUND

2290
PAGES ANALYZED

17
UNIQUE DOMAINS

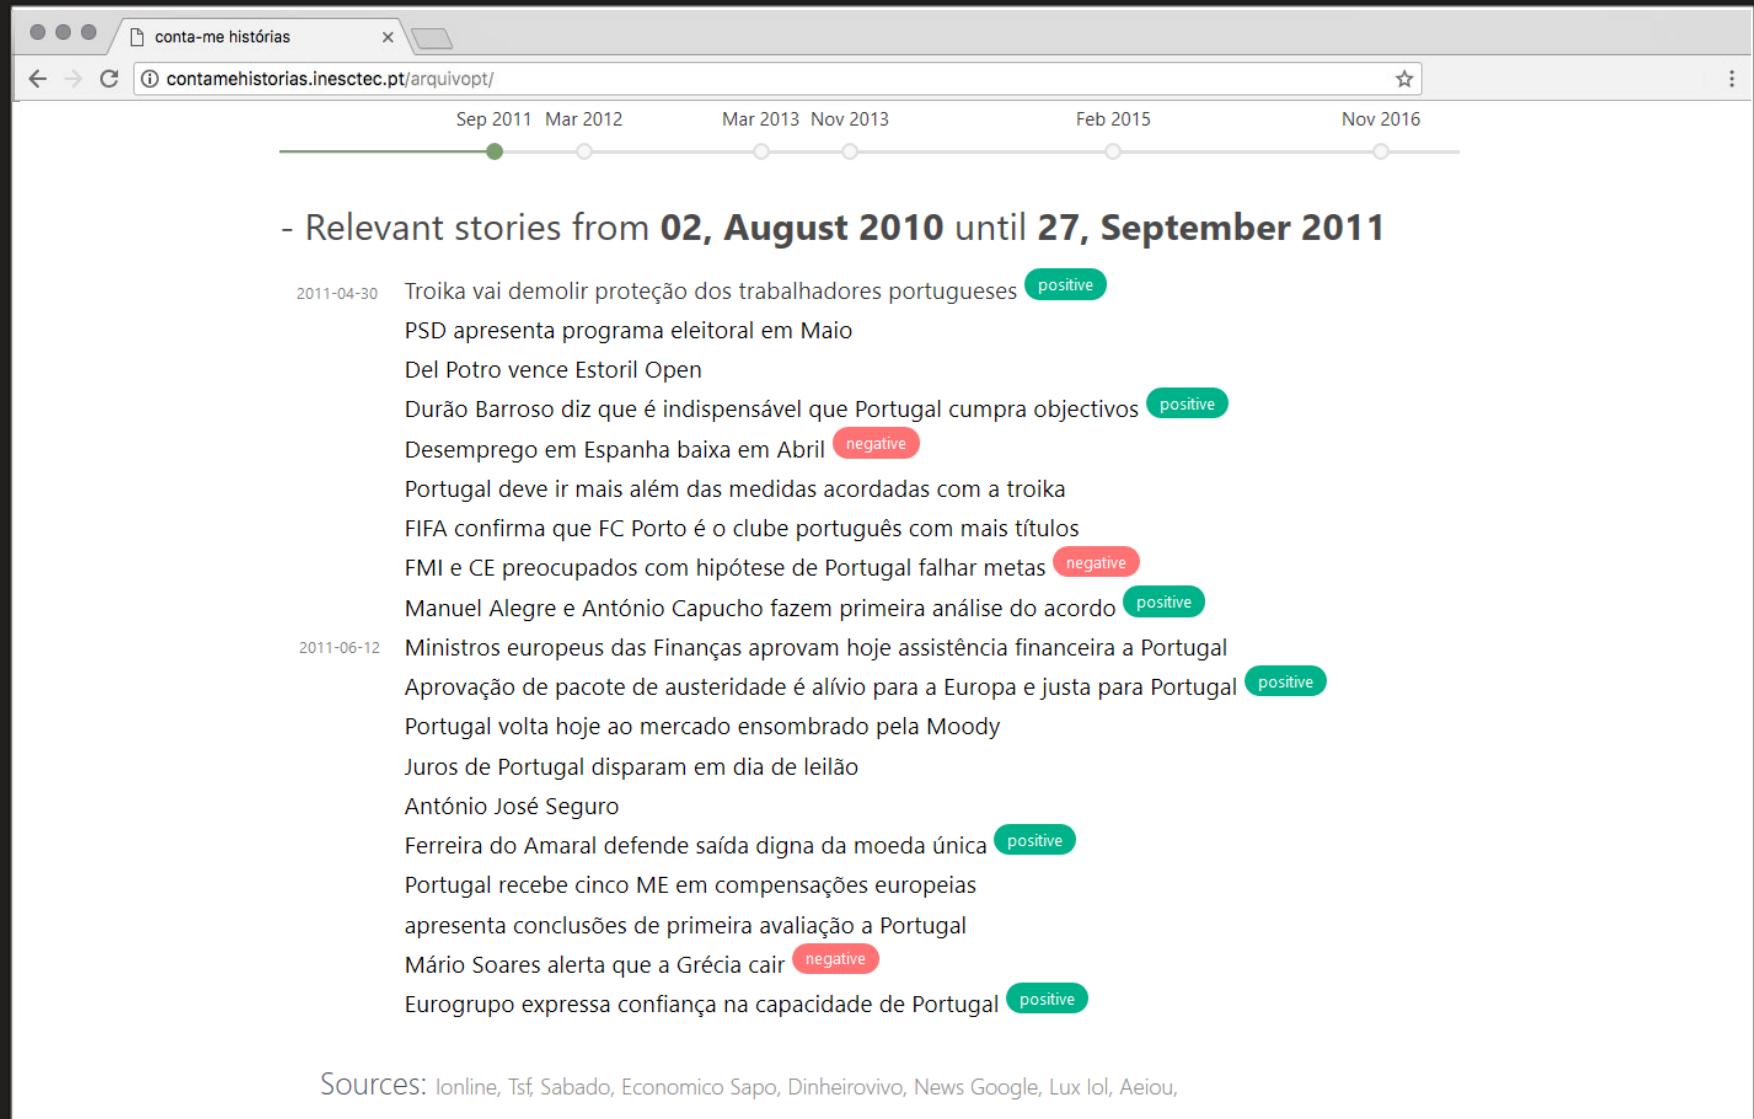
Narrative Related terms

Narrative Timeline of Troika em Portugal during the last 10 years

Horizontal Vertical

Previous Next

This screenshot shows the homepage of the 'conta-me histórias' web application. The main search bar contains the query 'troika em portugal'. Below the search bar, the system displays 7855 processed pages in 16.03 seconds, with 7.29 seconds for query time and 8.75 seconds for content analysis. Three key metrics are highlighted: 7855 pages found, 2290 pages analyzed, and 17 unique domains. A navigation bar at the top includes links for Home, Search, Team, About, and Examples. Below the search bar, there are tabs for 'Narrative' (which is active) and 'Related terms'. A large section titled 'Narrative Timeline of Troika em Portugal during the last 10 years' is visible, though its content is mostly obscured by a white overlay. At the bottom, there are 'Previous' and 'Next' buttons for navigating through the timeline.



conta-me histórias Arquivo.pt: pesquise páginas

arquivo.pt

ARQUIVOPT

www.tsf.pt/Paginal inicial/E..._id=1853012

Listar versões

2011

Maio

Junho

2

5

7

9

10

12

00:06

16

19

20

21

22

23

24

TSF RÁDIO NOTÍCIAS

Actualidade Programas Multimédia Blogues Futebol Bolsa Trânsito Totojogos Meteorologia Marés Farmácias Agenda Jogos

PSI20 | PSI Geral | IBEX35 | CAC 40 | Euronext | FTSE | NASDAQ 100 | Outros Mercados

E.coli Christine Lagarde dívida Eurogrupo Calçado FMI Grécia sindicatos

Noticiário das 00h00 Fórum TSF Podcast RSS FM MOBILE SMS Fale connosco

login | registo

Siga-nos em Facebook | Twitter

Pub

Economia

Administração Pública Orçamento Bolsa Empresas

Patrocínio

Ferramentas

Enviar Aumentar Partilhar Diminuir Imprimir Comentar este Artigo

Estatísticas

515 Visualizações 0 Comentários 0 Envios

Ministros europeus das Finanças aprovam hoje assistência financeira a Portugal

16 MAI 11 às 06:29

Os ministros das Finanças da Zona Euro e da União Europeia deverão aprovar sem dificuldade, esta segunda-feira em Bruxelas, o programa de assistência financeira a Portugal, depois de ter sido afastada a ameaça da Finlândia se opor à decisão.

O acordo político deverá ser alcançado numa reunião, esta tarde às 17h00 (16h00 de Lisboa), dos responsáveis da Zona Euro alargada aos ministros da UE (os 17 anteriores mais dez que não pertencem à Zona Euro).

A assistência financeira a Portugal será repartida em partes iguais de 26 mil milhões de euros pelo Fundo Europeu de Estabilização Financeira (FEEF),

Últimas + Vistas + Comentadas + Pesquisadas

Projecto Novos Povoadores é alternativa à vida na cidade Ontem às 23:44

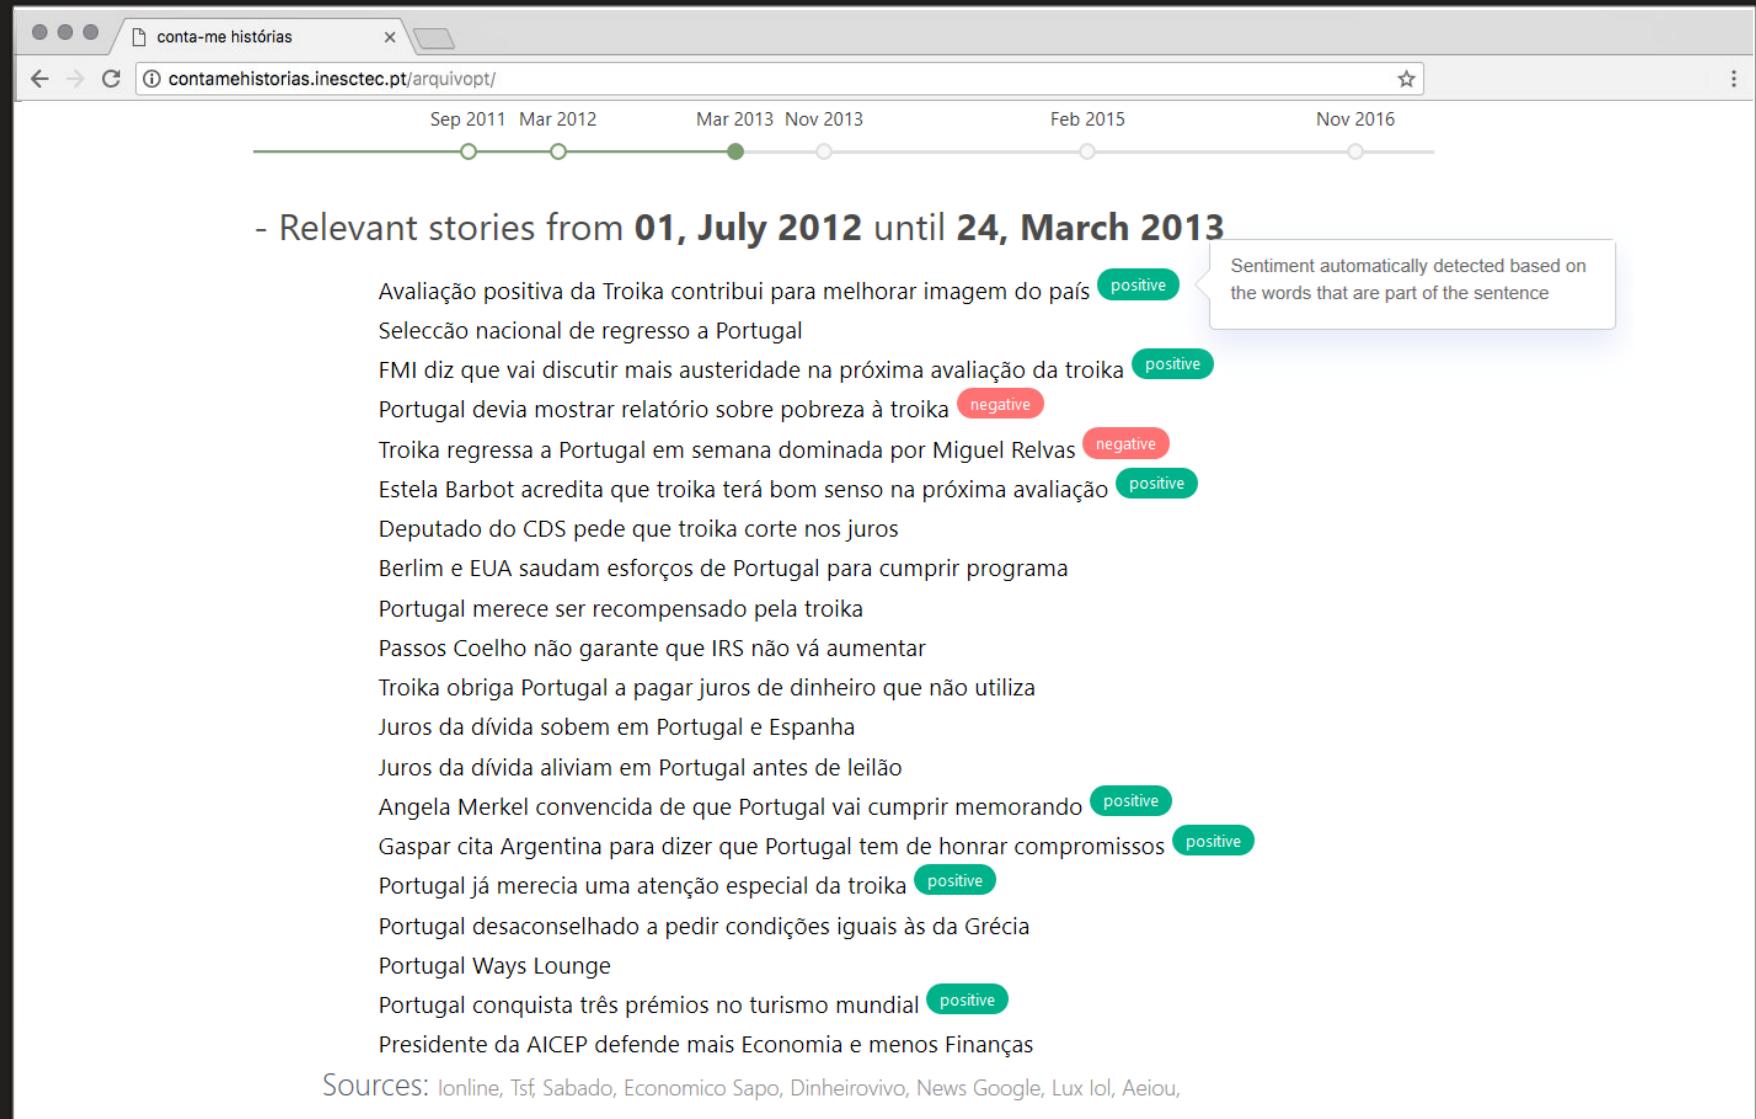
Governador do Banco de Israel é o novo candidato ao FMI Ontem às 23:16

Explosões no Paquistão causam 25 mortos e 100 feridos Ontem às 22:50

Cáritas pede criação de rede de protecção social Ontem às 22:39

Blue Note é a Melhor Editora de Jazz do Mundo Ontem às 22:24

ver +



The screenshot shows a web browser window with a title bar "conta-me histórias" and a URL "contamehistorias.inesctec.pt/arquivopt/". Below the URL is a horizontal timeline with markers for Sep 2011, Mar 2012, Mar 2013, Nov 2013, Feb 2015, and Nov 2016. A green dot is placed under the Nov 2016 marker. The main content area lists news stories from February 2015 to November 2016, each with a date, a brief description, and a sentiment label in a colored circle (green for positive, red for negative). The stories are:

- 2015-02-28 Portugal reembolsará seis mil milhões de euros ao FMI em Março
- Paulo Portas diz ter havido uma troika de restrições e uma troika de bem-fazer
- Portugal não vai recuperar nem metade dos empregos destruídos pela troika positive
- Troika culpa Governo português por falhanço do programa negative
- Passos e Cavaco são a troika em Portugal
- Parlamento Europeu vai investigar erros da troika em Portugal positive
- Troika regressa a Portugal na próxima semana
- Troika regressa a Lisboa para segunda avaliação pós-resgate
- Paulo Portas numa feira em Bruxelas lembra que Portugal não é a Grécia
- chega hoje a Lisboa para debater TSU e Orçamento do Estado
- Troika volta a Portugal e não é para matar saudades
- Costa diz que visita da troika a Portugal
- Banda desenhada do vinho do Porto na Garrafeira Nacional
- The Guardian e Lonely Planet escolhem as melhores dicas sobre Lisboa
- Germano Silva vai ser Doutor Honoris Causa pela Universidade do Porto positive
- Atletas gregos sem dinheiro lutam para competir nos Jogos do Rio de Janeiro positive
- Banco de Portugal e CMVM
- Troika em Portugal para analisar contas próximas
- Presidente da Águas de Portugal demite-se em ruptura com o Governo
- Carlos Costa diz que CMVM devia ser informada pelo BES

Sources: Ionline, Tsf, Sabado, Economico Sapo, Dinheirovivo, News Google, Lux Iol, Aeiou,

conta-me histórias

Arquivo.pt: pesquise páginas

arquivo.pt

Sobre English

ARQUIVO.PT

publico.pt

entre: 01/01/1996 e: 31/12/2017

Pesquisar

Pesquisa avançada

Ver resultados que contêm o texto: 'publico.pt'

Lista de versões

5 368 versões de publico.pt

1996	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
13 Out		12 Dez	25 Jan	11 Mai	18 Abr	30 Mar	8 Fev	2 Jan	4 Jan	1 Jan	2 Fev	1 Jan	20 Mai	23 Mar	1 Jan	1 Jan	10 Jan	27 Abr	1 Jan	1 Jan	Disponíveis após 1 ano.
13 Out		12 Dez	25 Jan	11 Mai	3 Mai	25 Mai	18 Fev	6 Fev	15 Jan	4 Jan	16 Mar	1 Jan	24 Mai	1 Abr	1 Jan	1 Jan	10 Jan	27 Abr	1 Jan	1 Jan	
			8 Fev	11 Mai	6 Mai	28 Mai	22 Mar	11 Abr	17 Jan	4 Jan	16 Mar	5 Jan	24 Jun	5 Abr	2 Jan	2 Jan	11 Jan	27 Abr	1 Jan	1 Jan	
			8 Fev	11 Mai	6 Mai	1 Jun	26 Mar	8 Mai	18 Jan	4 Jan	6 Jun	11 Jan	24 Jun	8 Abr	2 Jan	2 Jan	11 Jan	27 Abr	2 Jan	1 Jan	
			21 Fev	11 Mai	16 Mai	4 Jun	4 Abr	20 Mai	20 Jan	6 Jan	7 Jun	15 Jan	25 Set	9 Abr	3 Jan	3 Jan	12 Jan	28 Abr	2 Jan	2 Jan	
			21 Fev	11 Mai	22 Mai	6 Jun	11 Abr	23 Mai	22 Jan	7 Jan	7 Jun	18 Jan	26 Set	12 Abr	3 Jan	3 Jan	12 Jan	28 Abr	2 Jan	2 Jan	
			21 Abr	11 Mai	8 Jun	2 Ago	24 Abr	26 Mai	24 Jan	8 Jan	7 Jun	20 Jan	17 Dez	13 Abr	4 Jan	4 Jan	15 Jan	28 Abr	3 Jan	2 Jan	
			21 Abr	11 Mai	27 Jun	7 Ago	25 Mai	6 Jun	27 Jan	11 Jan	7 Jun	23 Jan	18 Dez	16 Abr	4 Jan	4 Jan	15 Jan	28 Abr	3 Jan	2 Jan	
			27 Abr	11 Mai	27 Jun	12 Ago	17 Jul	7 Jun	28 Jan	13 Jan	9 Jun	26 Jan		19 Abr	5 Jan	5 Jan	17 Jan	29 Abr	3 Jan	3 Jan	
			27 Abr	11 Mai	28 Jun	12 Ago	30 Set	10 Jun	28 Jan	14 Jan	14 Jun	1 Feb		22 Abr	5 Jan	5 Jan	17 Jan	29 Abr	4 Jan	3 Jan	
			12 Out	11 Mai	28 Jun	23 Set	10 Out	10 Jun	29 Jan	14 Jan	14 Jun	3 Fev		30 Abr	6 Jan	6 Jan	18 Jan	29 Abr	4 Jan	3 Jan	
			12 Out	20 Mai	1 Jul	28 Set	21 Out	11 Jun	30 Jan	14 Jan	6 Ago	9 Fev		2 Mai	6 Jan	6 Jan	18 Jan	30 Abr	4 Jan	3 Jan	
			11 Nov	20 Mai	9 Jul	24 Out	24 Nov	12 Jun	31 Jan	15 Jan	27 Set	13 Fev		3 Mai	7 Jan	7 Jan	19 Jan	30 Abr	5 Jan	4 Jan	

conta-me histórias

contamehistorias.inesctec.pt/arquivopt/

Narrative Related terms

Narrative Timeline of Troika Em Portugal during the last 10 years

Horizontal Vertical

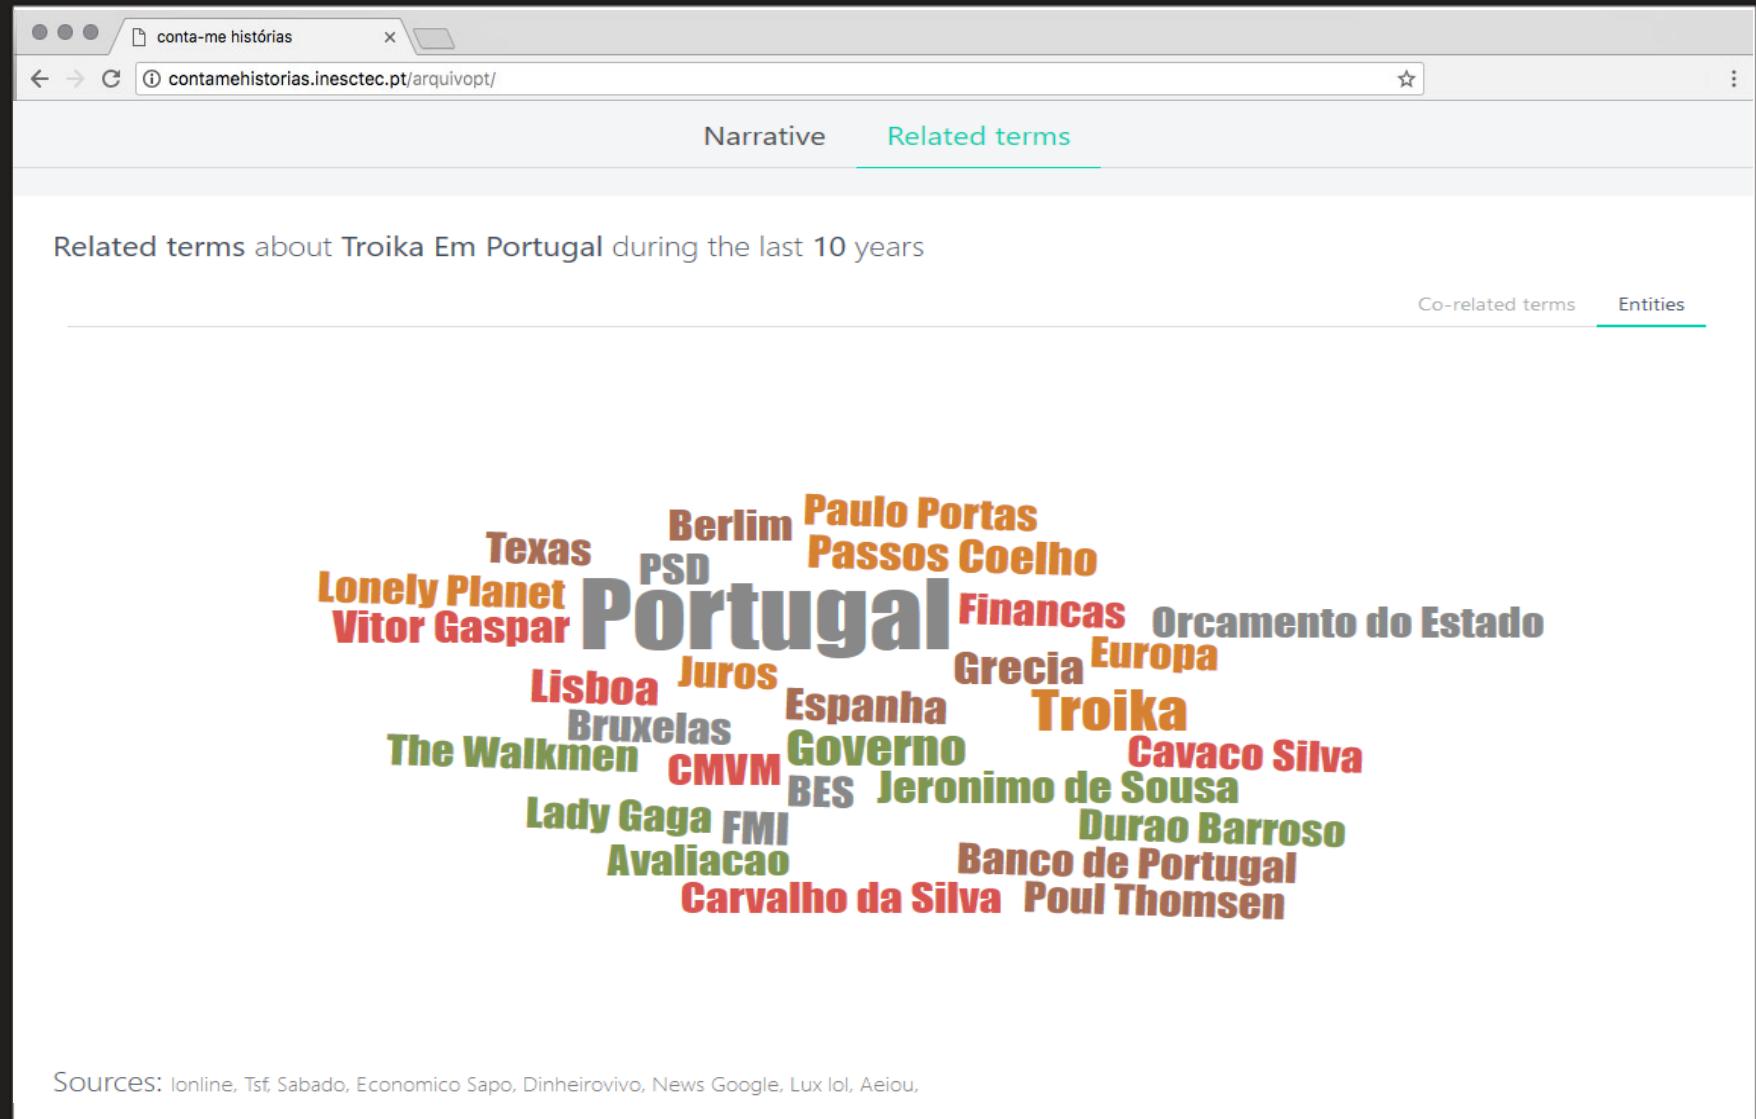
16, November 2016

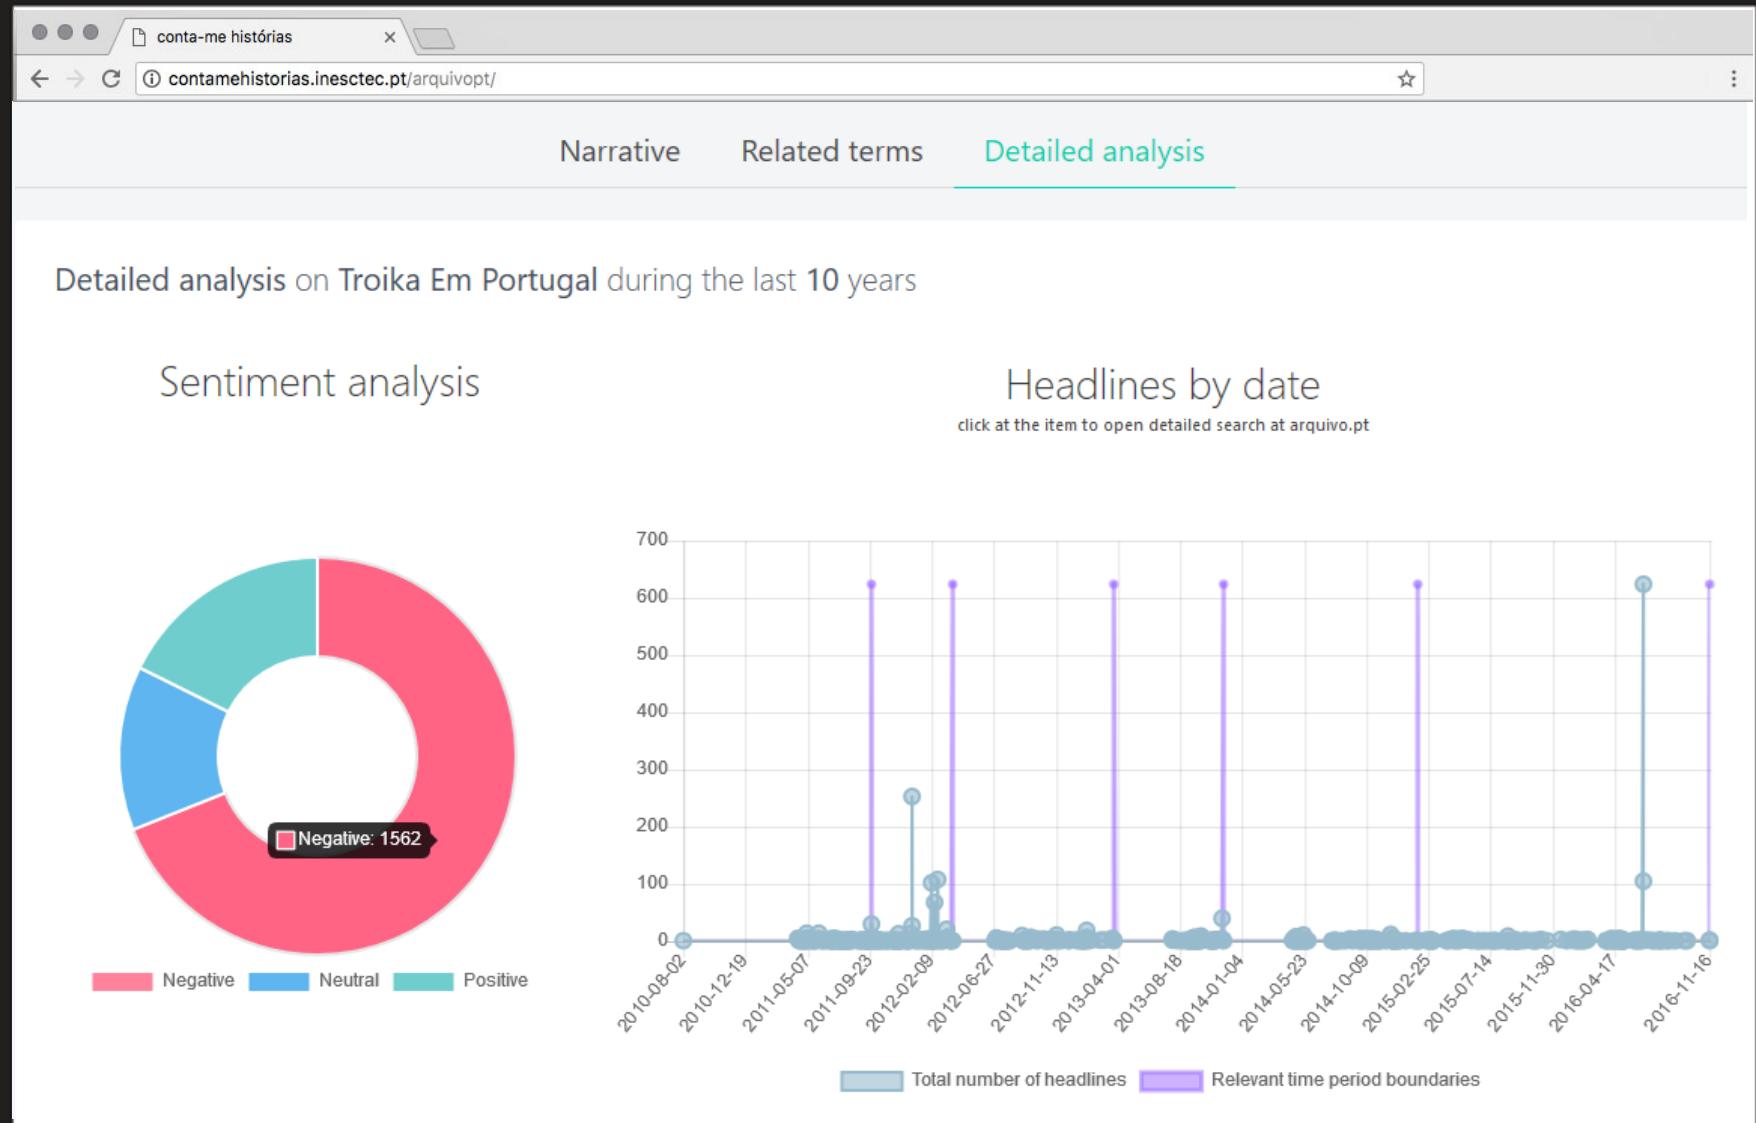
- Portugal reembolsará seis mil milhões de euros ao FMI em Março
- Paulo Portas diz ter havido uma troika de restrições e uma troika de bem-fazer
- Portugal não vai recuperar nem metade dos empregos destruídos pela troika
- Troika culpa Governo português por falhanço do programa
- Passos e Cavaco são a troika em Portugal
- Parlamento Europeu vai investigar erros da troika em Portugal

2 years ago

01, February 2015

- Troika diz que Portugal precisa
- Última avaliação da troika arranca hoje em Lisboa
- Jerónimo de Sousa diz que saída da troika de





conta-me histórias Arquivo.pt: pesquise páginas d

arquivo.pt

Troika em Portugal

entre: 27/12/2011 e: 27/12/2011

Pesquisar Pesquisa avançada

Resultados 1 a 10 de 14.911

Troika: Portugal «tem feito bons progressos em várias frentes»
27 Dezembro, 2011 - Listar versões

Troika: Portugal «tem feito bons progressos em várias frentes» - Comissão Europeia | União Europeia ... : **Portugal** «tem feito bons progressos em várias frentes» - Comissão Europeia A Comissão Europeia considerou hoje que **Portugal** «tem feito bons progressos em várias frentes» no que refere à implementação do ...
http://diariodigital.sapo.pt/news.asp?section_id=57&id_news=549293

Troika: Portugal não deve precisar de mais dinheiro que o in...
27 Dezembro, 2011 - Listar versões

Troika: Portugal não deve precisar de mais dinheiro que o inicialmente acordado - Bruxelas | União Europeia | Diário Digital | Director: Pedro Curvelo Pesquise no DD em Todas as secções.. Sociedade ... **Troika: Portugal** não deve precisar de mais dinheiro que o inicialmente acordado - Bruxelas A Comissão ...
http://diariodigital.sapo.pt/news.asp?section_id=57&id_news=549315

Portugal na "lupa" da troika
27 Dezembro, 2011 - Listar versões

Portugal na "lupa" da troika Skip to content Skip to main navigation Skip to 1st column Skip to 2nd ... Economia | Economia **Portugal** na "lupa" da troika **Portugal** na "lupa" da troika Terça, 08 Novembro 2011 00:00 Redacção ... TRANSLATE english french spanish swahili **Portugal** na "lupa" da troika **Portugal** na "lupa" da troika ...
<http://opais.sapo.mz/index.php/economia/...17575-portugal-na-lupa-da-troika.html>

Sol - Dossier - troika
27 Dezembro, 2011 - Listar versões

Economia **Portugal** deverá poupar 5,2 mil milhões em juros durante ajuda externa A Comissão Europeia ♦♦♦ comentar Economia **Troika: Portugal** não deve precisar de mais dinheiro A Comissão Europeia ... 'troika' no programa de ajustamento... ♦♦♦ comentar Economia Rendimento disponível cai 6% em 2012 O ...

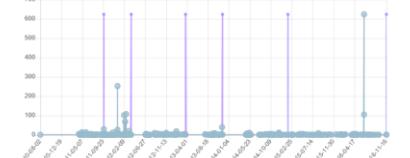
Detailed analysis on Troika Em Portugal during the last 10 years

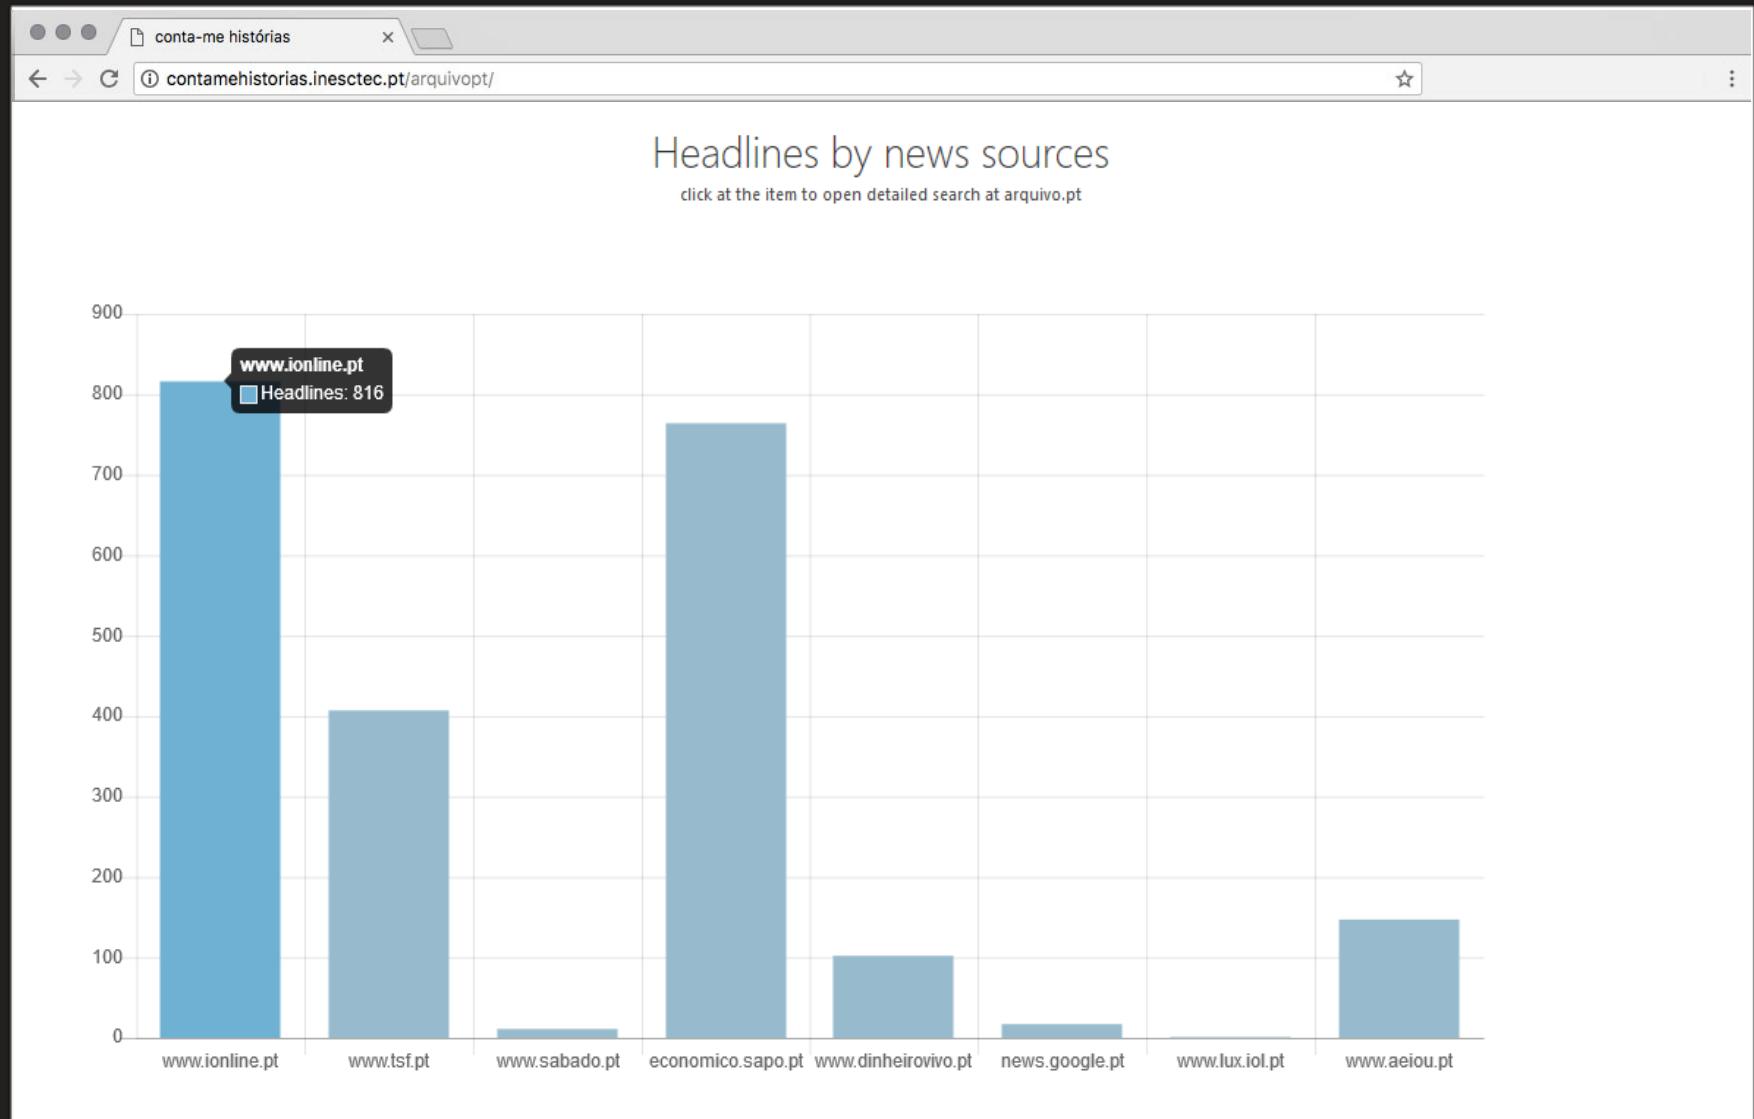
Narrative Related terms Detailed analysis

Sentiment analysis

Headlines by date

Total number of headlines Related time period boundaries





conta-me histórias Arquivo.pt: pesquise páginas d

arquivo.pt

Troika em Portugal site:www.ionline.pt type:html

Pesquisar

entre: 02/08/2010 e: 16/11/2016

Pesquisa avançada

Resultados 1 a 10 de 346.782

Desejava ver apenas o histórico de www.ionline.pt?

Troika: Portugal à espera dos próximos episódios
24 Abril, 2011 - Listar versões

Troika: Portugal à espera dos próximos episódios Fechar Imprimir Troika: Portugal à espera dos próximos episódios Publicado em 22 de Abril de 2011 A troika começou as reuniões com os partidos e ... impostas pela troika aos portugueses deverão ser conhecidas na próxima semana. Ainda uma viagem à ...
<http://www.ionline.pt/interior/index.php?p=news-print&idNota=118903>

Costa. A troika em Portugal agora chama-se Portas, Passos e ...
24 Novembro, 2015 - Listar versões

Costa. A troika em Portugal agora chama-se Portas, Passos e Cavaco 24/11/15 subscrever newsletter ... Registrar Pesquisar Costa. A troika em Portugal agora chama-se Portas, Passos e Cavaco Costa. A troika em Portugal agora chama-se Portas, Passos e Cavaco ANDRÉ KOSTERS, Lusa António Costa 23/04 ...
<http://www.ionline.pt/388076>

Troika. Portugal vai ao terceiro exame da cadeira Maior Ajus...
12 Fevereiro, 2012 - Listar versões

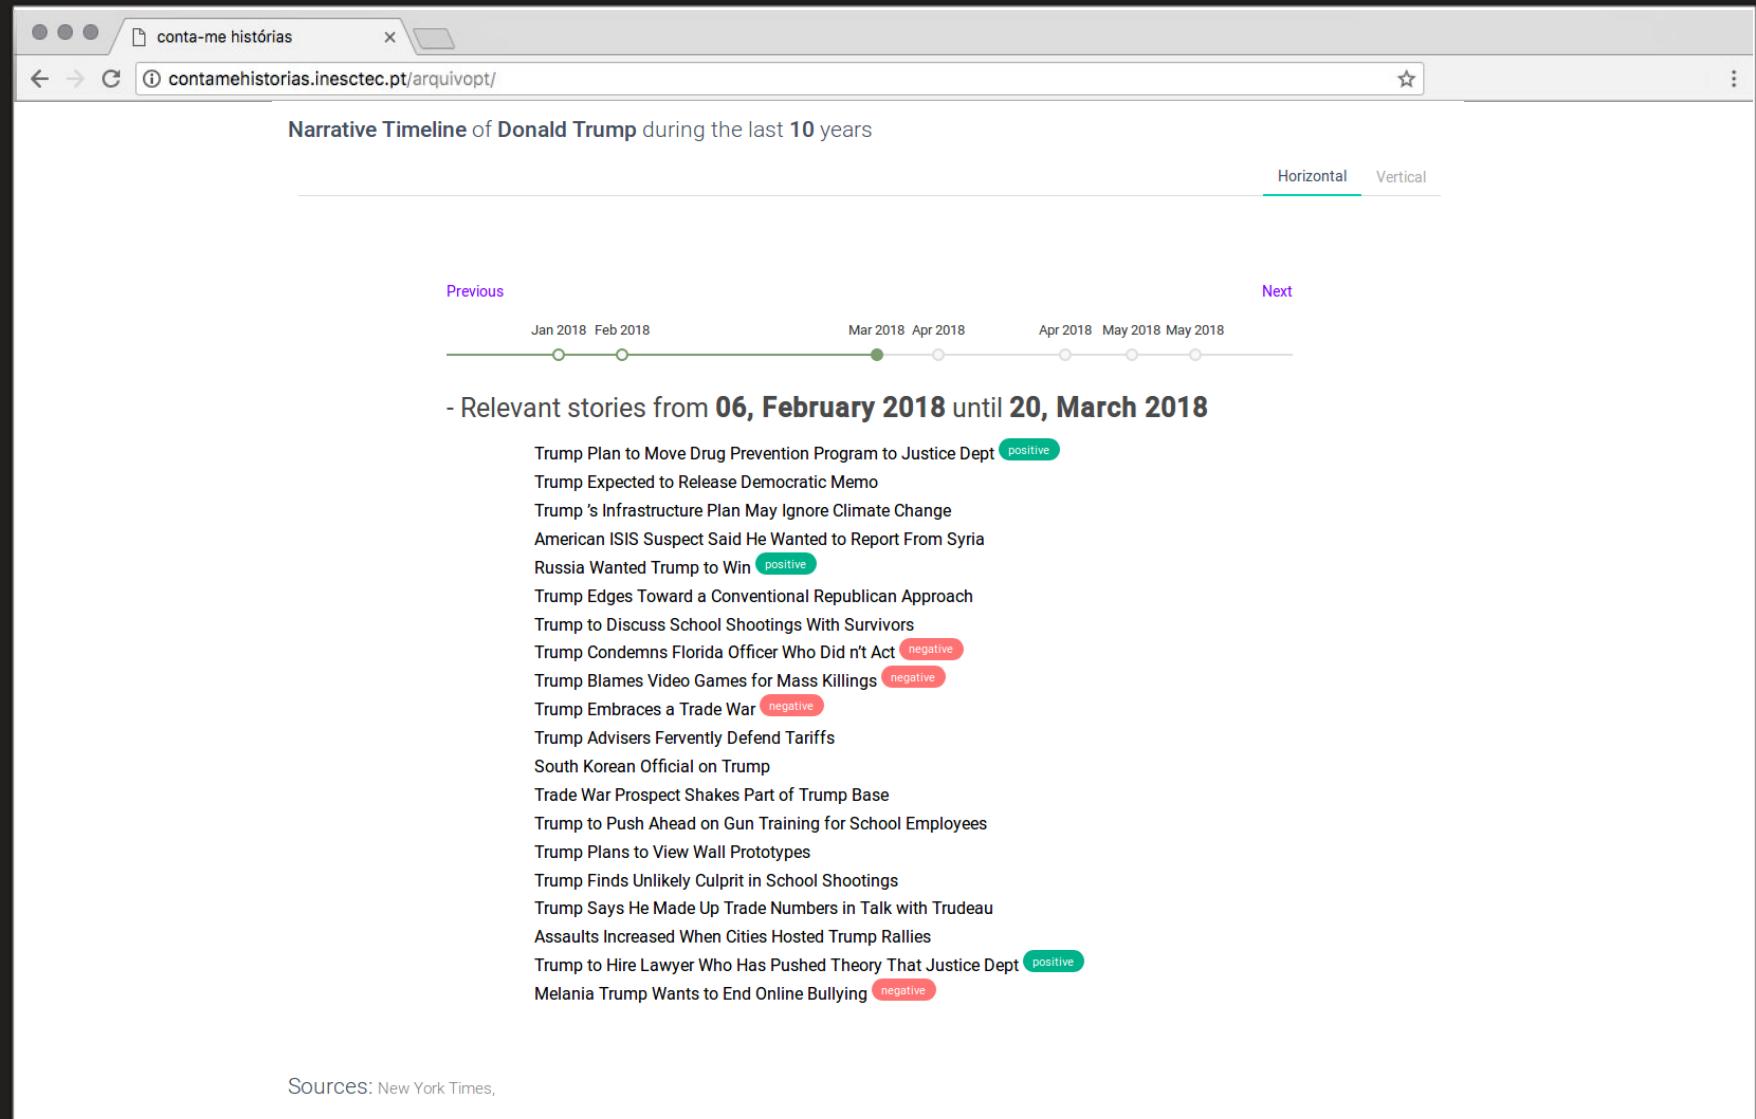
Troika. Portugal vai ao terceiro exame da cadeira Maior Ajustamento Económico de sempre | iOnline ... Mercados Boa Vida iModa iTestdrive iGastronomia Desporto ITV iFotogaleria Opinião iSabe Troika. Portugal ... Portugal, os bancos podem cumprir a meta já em 2013. Mas há um preço: o esmagamento do crédito empresarial ...
<http://www.ionline.pt/dinheiro/troika-po...ra-maior-ajustamento-economico-sempre>

Troika: Portugal não deve precisar de mais dinheiro que o in...
22 Dezembro, 2011 - Listar versões

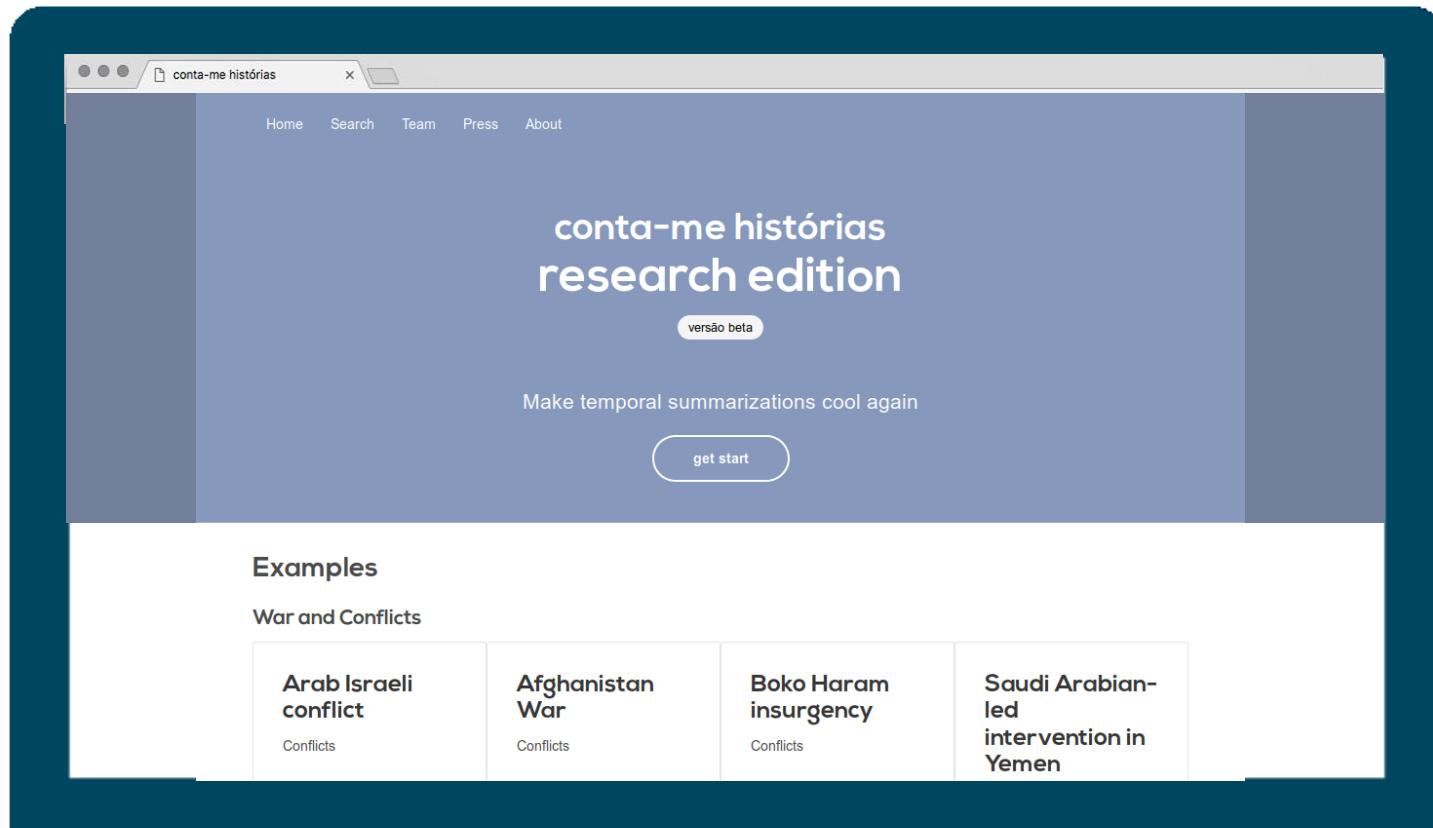
Troika: Portugal não deve precisar de mais dinheiro que o inicialmente acordado - Bruxelas ... iTestdrive

Headlines by news sources
data at the time to open detailed search at arquivo.pt

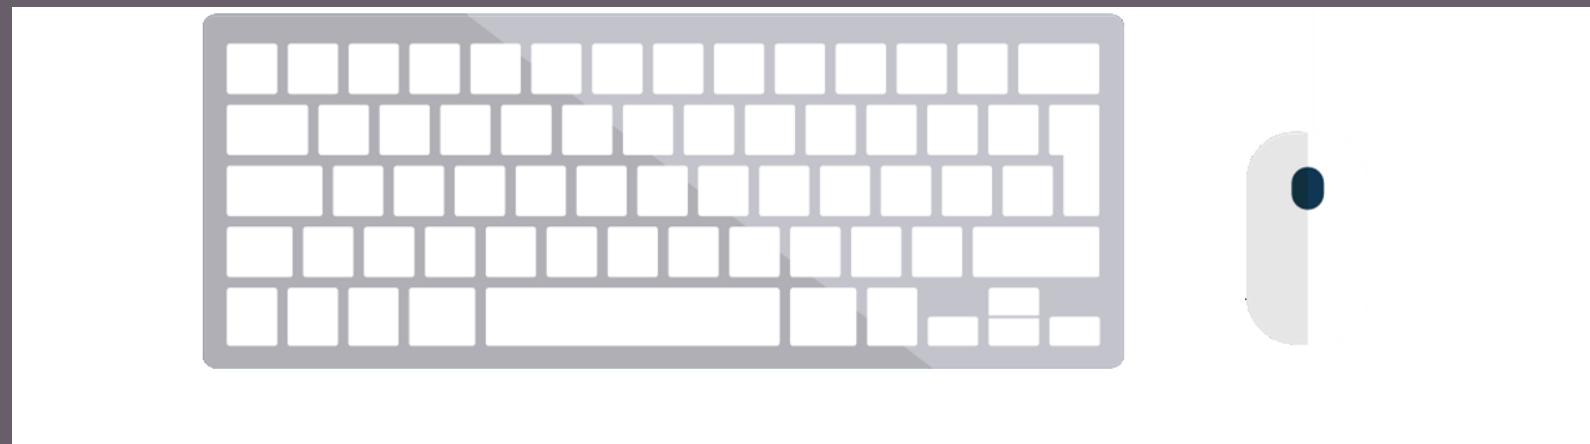
News Source	Number of Headlines
www.ionline.pt	850
www.tbt.pt	400
www.sabado.pt	20
economico.sapo.pt	750
www.dinheiropt.pt	80
news.google.pt	20
www.habizt.pt	10
www.economist.pt	120



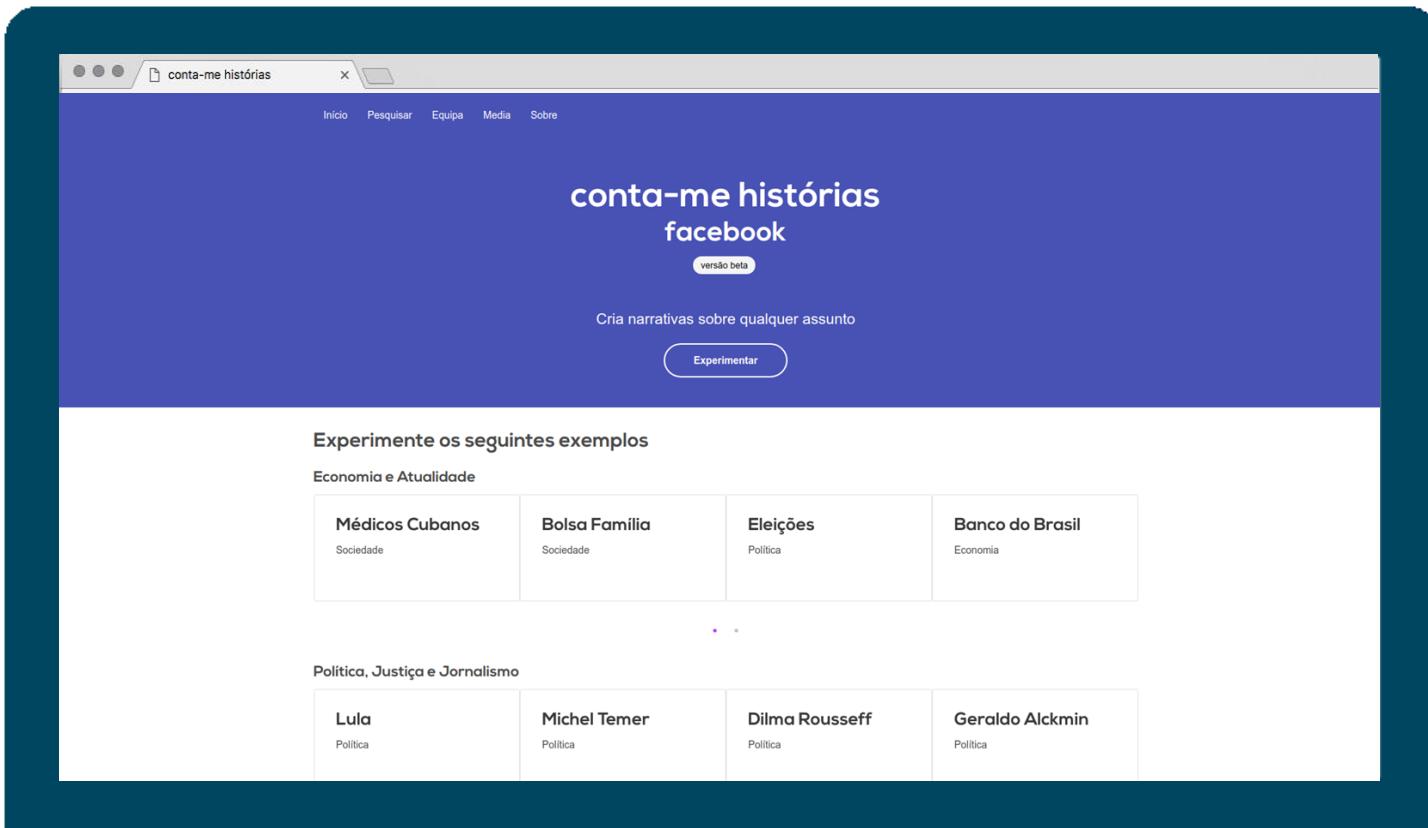
research edition with different



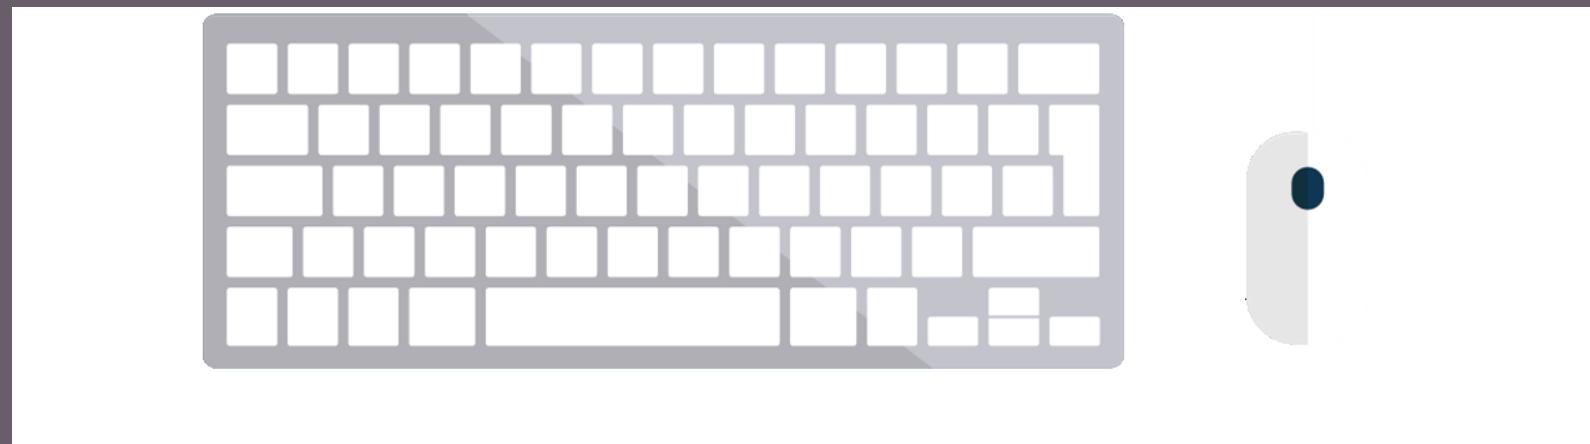
<http://nlplab.inesctec.pt/contamehistorias-labs>



facebook posts edition



<http://nlplab.inesctec.pt/contamehistorias-facebook>



Conta-me Histórias open source

open source python package

The screenshot shows a GitHub repository page for the project "LIAAD / TemporalSummarizationFramework". At the top, there is a success message: "Your repository details have been saved." Below the header, the repository name is displayed in blue text. To the right of the name are buttons for "Unwatch" (with a count of 4), "Star" (with a count of 1), and "Fork" (with a count of 0). The main navigation tabs include "Code" (selected), "Issues" (1), "Pull requests" (0), "Projects" (0), "Wiki", "Insights", and "Settings". A summary bar below the tabs shows "45 commits", "1 branch", "0 releases", and "1 contributor". The "Branch: master" dropdown is set to "master". There are buttons for "New pull request", "Create new file", "Upload files", "Find file", and "Clone or download". The commit history table lists the following commits:

Author	Commit Message	Time Ago
arianpasquali	Update LICENSE.txt	Latest commit aea8fc6a 3 hours ago
contamehistorias	refactoring e levenshtein	a day ago
LICENSE.txt	Update LICENSE.txt	3 hours ago
MANIFEST.in	refactoring e levenshtein	a day ago
README.md	Update README.md	7 days ago
requirements.txt	refactoring e levenshtein	a day ago
setup.cfg	terminal script and pip install	17 days ago
setup.py	refactoring and new examples	15 days ago
test_conteme.py	terminal script and pip install	17 days ago

<http://github.com/LIAAD/TemporalSummarizationFramework>

Installing

requires Python 3



```
> pip install git+https://github.com/LIAAD/TemporalSummarizationFramework.git
```

Using terminal interface

Accessing client help

```
● ● ●

> contamehistorias --help

Usage: contamehistorias [OPTIONS]

  Console script for contamehistorias.

Options:
  --query TEXT      Perform news retrieval with informed query
  --language TEXT   Expected language in headlines
  --start_date DATE Perform news retrieval since this date
  --end_date DATE   Perform news retrieval until this date
  --domains TEXT    Comma separated list of domains (www.publico.pt,www.dn.pt)
  --verbose
  --help             Show this message and exit.
```

Code with Arquivo.pt as data source



```
from contamehistorias.datasources.webarchive import ArquivoPT
from contamehistorias.engine import TemporalSummarizationEngine
from datetime import datetime

domains = [ 'http://publico.pt/' , 'http://www.dn.pt/' , 'http://www.rtp.pt/' , 'http://www.iol.pt/' ]

params = { 'domains':domains, 'from':datetime(year=2016, month=3, day=1),
           'to':datetime(year=2018, month=1, day=10) }
query = 'Dilma Rousseff'
language = "pt"

#instantiate ArquivoPT search engine
apt = ArquivoPT()
search_result = apt.getResult(query=query, **params)
#instantiate temporal summarization class
engine = TemporalSummarizationEngine()
intervals = cont.build_intervals(search_result, language)
#print results
engine pprint(intervals)
```

How to extend it

You can extend it to use your own collection as data source.

Extend BaseDataSource class and implement method **getResult** to return a list of object **ResultHeadLine**.

For each document you need **a title, a timestamp, source and url**.

```
● ● ●

class BaseDataSource(object):

    def __init__(self, name):
        self.name = name

    def getResult(self, query, **kwargs):
        raise NotImplementedError('getResult on ' + self.name + ' not implemented yet!')
```

Extension example with custom dataset *

```
● ● ●

from contamehistorias.engine import TemporalSummarizationEngine
from contamehistorias.datasources.signal import SignalNewsIRDataset

#collect dataset
query = "Barack Obama"
search_result = SignalNewsIRDataset().getResult(query=query)

#generate timeline
engine = TemporalSummarizationEngine()
summary_result = engine.build_intervals(search_result, "en")

#print results
engine pprint(summary_result, verbose=True)
```

* Signal's NewsIR'16 dataset : <http://research.signalmedia.co/newsir16/signal-dataset.html>

Output



```
> contamehistorias_signal --query "Barack Obama"
```

```
Conta-me Historias Temporal Summarization. Signal NewsIR 16 dataset example (more info  
http://research.signalmedia.co/newsir16/signal-dataset.html  
--query "Barack Obama"
```

```
Performing search. This may take a while.  
Computing temporal summarization ...
```

Timeline

2015-07-25 08:44:54 until 2015-09-07 06:53:14

```
obama says world must reach climate deal in paris  
obama enthusiastic for los angeles summer olympics bid  
democrats give obama votes to uphold iran nuke deal  
obama scores policy win in securing votes for iran nuclear deal
```

2015-09-14 04:11:35 until 2015-09-21 22:27:54

```
president obama honors stephen kin with the national medal of the arts  
struggling gop presidential candidate scott walker blames obama for police deaths  
obama unveils new college financial aid application process  
obama will greet chinese president with handshake  
barack obama supports ahmed mohamed
```

next steps

- In terms of data sources support different web archives
- Different timelines for different kinds of sources (left-wing, right-wing, tabloids, etc)
- Extended formal evaluation





thank you

Arian Pasquali
arianpasquali@gmail.com
INESCTEC - LIAAD
Universidade do Porto

<http://contamehistorias.pt>
admin@contamehistorias.pt