



Fundação para a Computação Científica Nacional  
*Foundation for National Scientific Computing*

# Arquivo e medição da Web portuguesa

Daniel Gomes e João Miranda

{daniel.gomes, joao.miranda} @ fccn.pt

# A era digital começou

- A Web é a maior fonte de informação construída
  - Jornais, livros, documentação técnica
  - Informação publicada exclusivamente na Web
- A informação na Web é efémera
  - Análise de 150 sítios populares após 1 ano (Ntoulas, 2004)
    - Apenas 20% dos URLs permanecem válidos
    - Só 10% dos conteúdos mantêm-se inalterados
  - Web portuguesa é semelhante (Gomes, 2006)
- Temos que começar a arquivar
  - Para que a História não se perca

# Arquivos de Web nacionais

- Internet Archive arquiva a Web “toda” desde 1996
- Dividir para conquistar: cada país arquiva a sua Web
  - **11 da U. E.:** Alemanha, Áustria, Dinamarca, Finlândia, França, Grécia, Lituânia, Holanda, Suécia, Reino Unido e República Checa.
  - **6 externos:** Austrália, Canadá, Estados Unidos da América, Japão, Nova Zelândia e Noruega.
- Necessários sistemas para suportar o arquivo da Web

# Alguns casos de uso para um Arquivo da Web

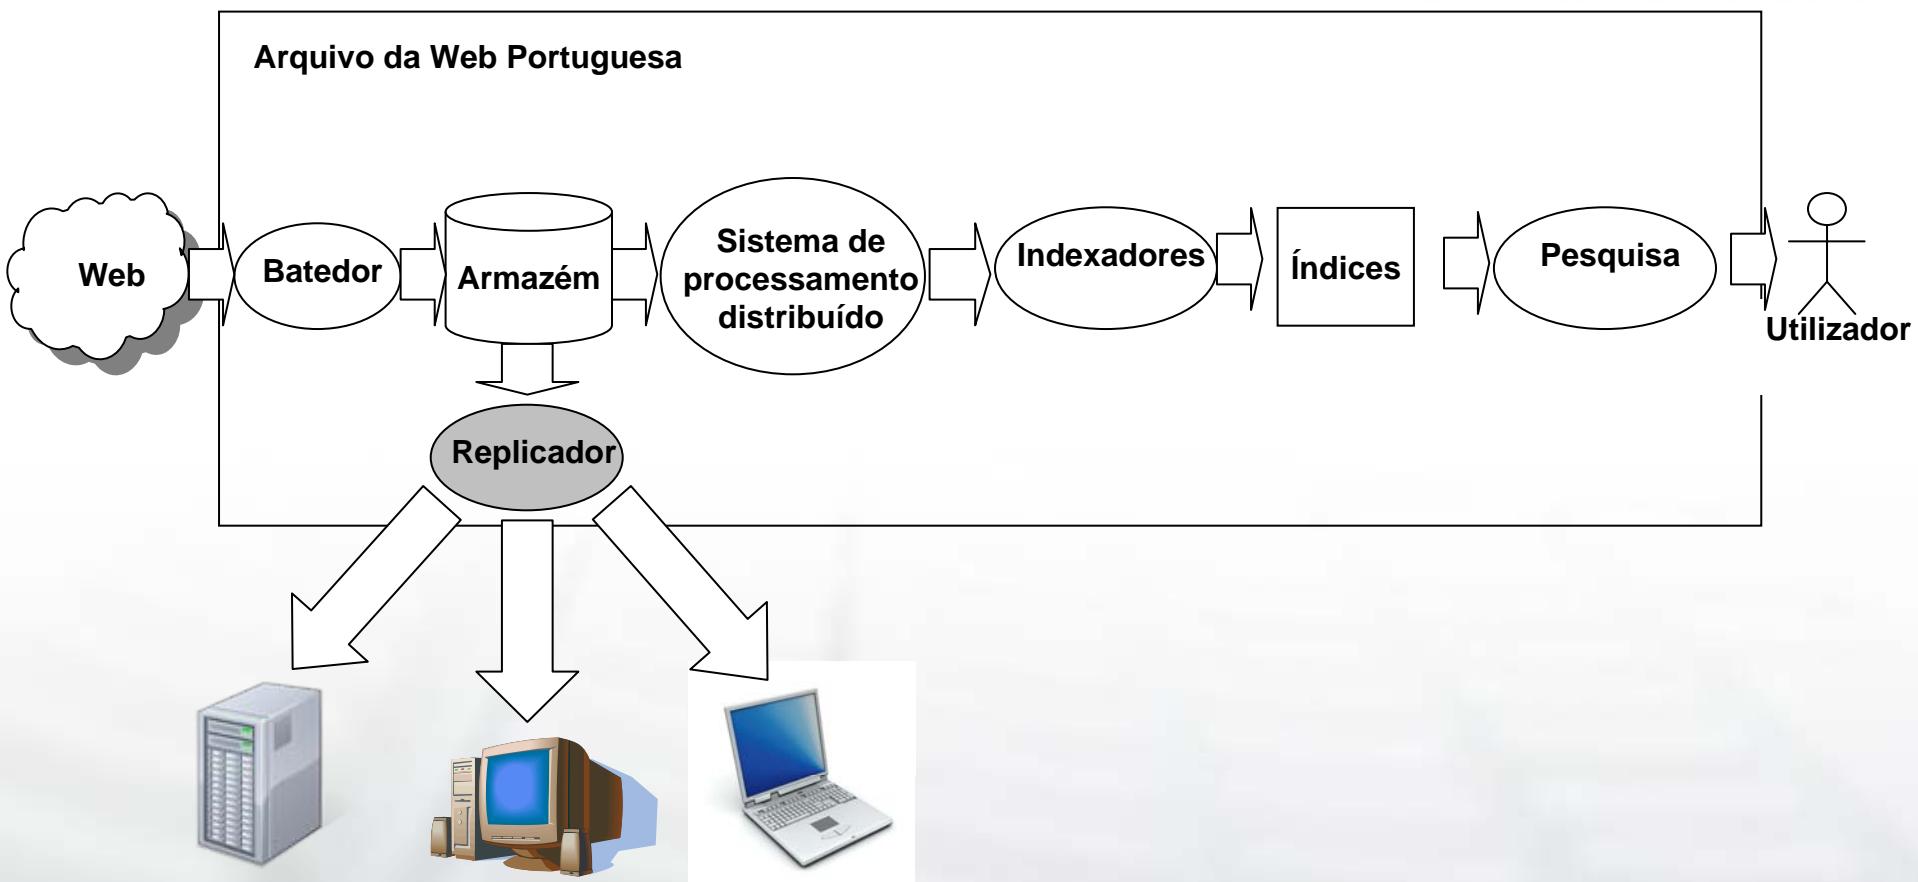
- Jornalista documenta artigo
- Webmaster recupera versão perdida de página
- Historiador analisa documentos digitais
- Utilizador da Web visita *Favorito* quebrado
- Sociólogo estuda proliferação das redes sociais
- Jurista obtém provas para caso (?)

...

- Motivação
- Sistema de Arquivo da Web Portuguesa
- Resultados de uma medição da Web portuguesa
- Conclusões

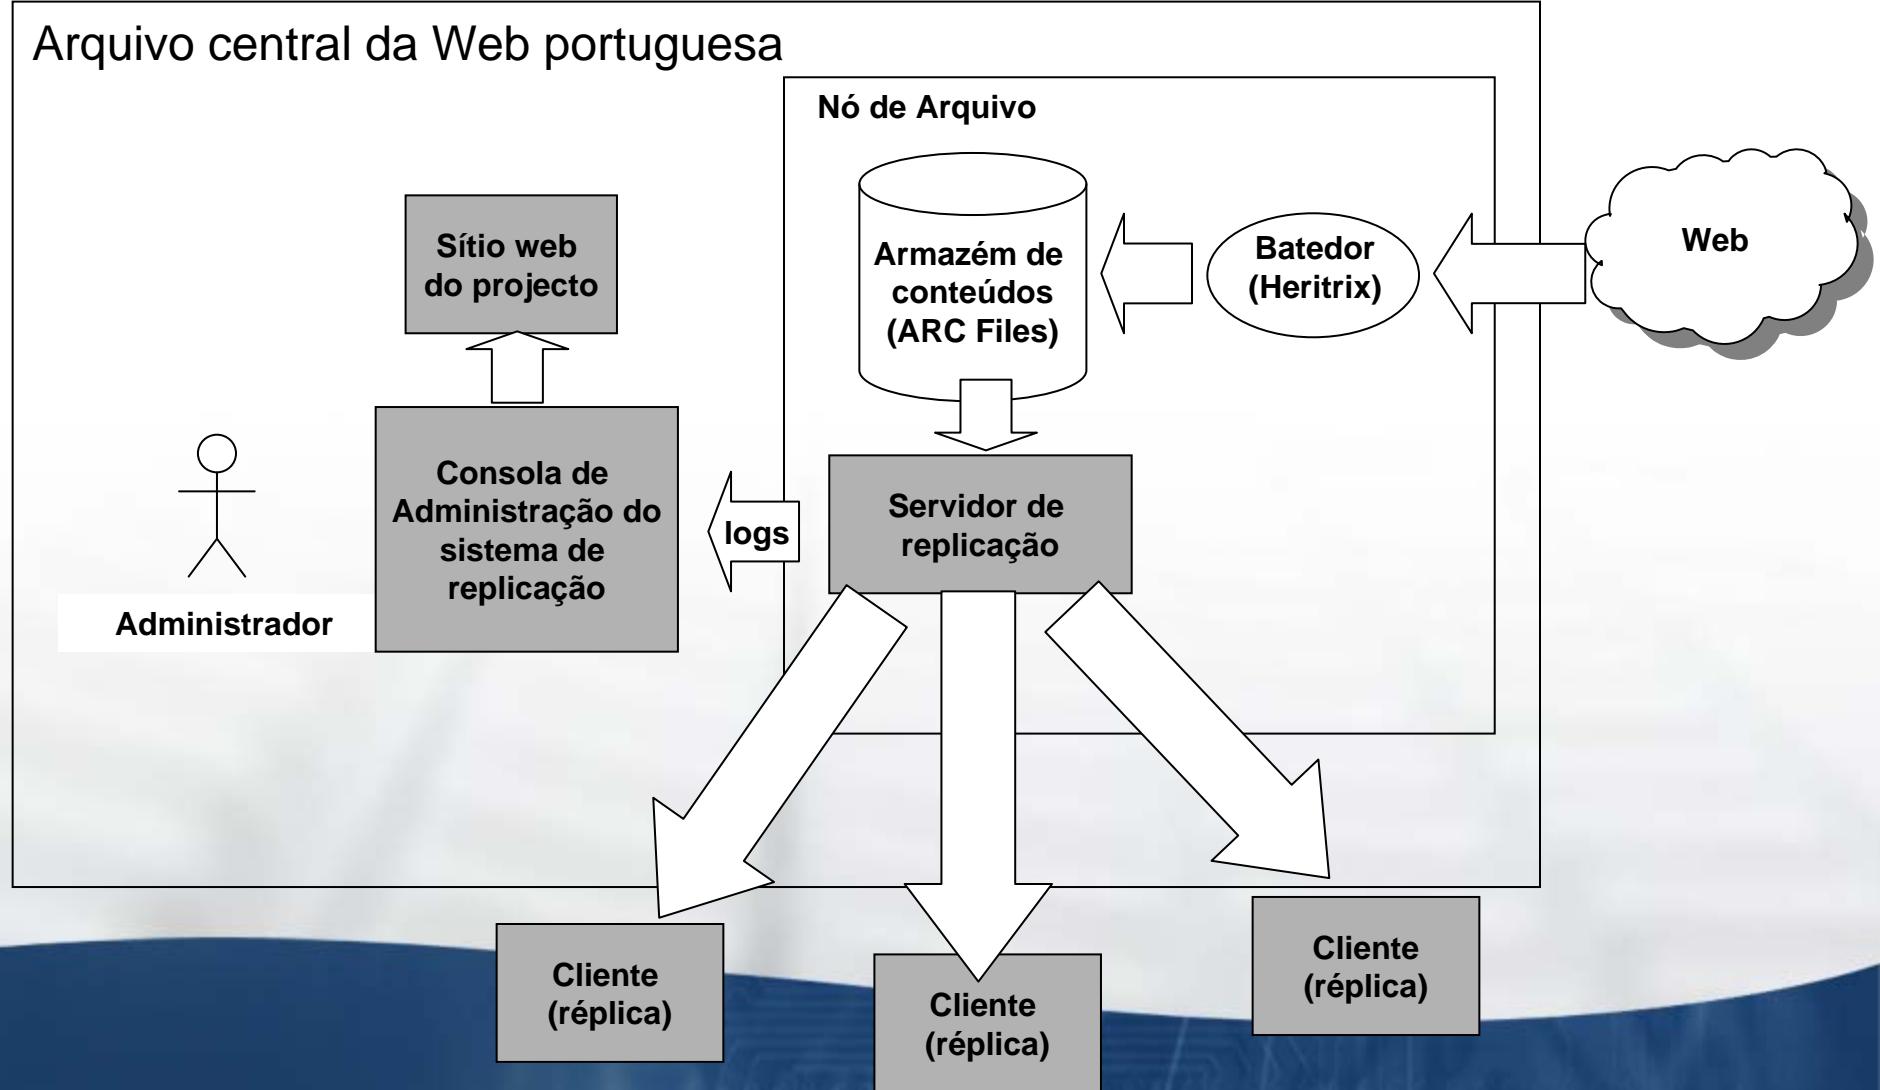
# Principais objectivos

- Iniciar o “depósito legal” da Web portuguesa
- Serviços públicos de acesso à informação arquivada
  - Pesquisa por termo e endereço
- Prestação de serviços à comunidade científica
  - Disponibilização de colecções de dados
  - Partilha de plataforma de computação
- Formação de recursos humanos
- Publicação de artigos científicos e técnicos
  - Estudo da Web portuguesa



# Todos podem contribuir para a preservação da Web

## Arquivo central da Web portuguesa



# Características do rARC

- Não é intrusivo, não carrega o computador do cliente
- Fácil de instalar
- Permite controlar espaço e largura de banda
- Confidencialidade
  - Cópias de segurança cifradas
- Integridade
  - Protecção contra clientes maliciosos que tentem adulterar as cópias para inserir conteúdos maliciosos no arquivo.
- Disponível em breve...



Fundação para a Computação Científica Nacional  
*Foundation for National Scientific Computing*

# Processamento e pesquisa no AWP

# Processamento dos conteúdos arquivados

- Permite executar rotinas em larga escala
- Hadoop: plataforma de processamento paralelo
  - Implementa map-reduce do Google File System
  - Apenas é necessário escrever 2 rotinas. Exemplo:
    - Map: separa palavras num texto
      - “O tempo perguntou ao tempo”
      - <O,1>< tempo,1>< perguntou,1><ao,1><tempo,1>
    - Reduce: conta quantas vezes ocorre cada termo
      - <O,1>< tempo,2>< perguntou,1><ao,1>
  - Adoptado pela Yahoo em 10 000 servidores

# Pesquisa por termo

A screenshot of a web browser window. The title bar shows "Dia da Europa - FCCN - Fundação para ...". The address bar contains "fccn grifos". The page itself is from the Internet Archive and displays search results for "fccn grifos". The results include several links to FCCN's website, such as "FCCN - Fundação para a Computação Científica Nacional" and "Notícias FCCN". Each result includes a brief description, a timestamp (e.g., "2008-03-12 05:59:01"), and links to "other versions" and "explain".

**ARQUIVO DA WEB PORTUGUESA**

**Web Search**

fccn grifos Localizar Help

Search took 0.145 seconds. Resultados 1-10 (de um total de 39 documentos):

**FCCN - Fundação para a Computação Científica Nacional**

-europeia - 15 Fevereiro, 2008 A FCCN, responsável pela vídeo-difusão do ninho de **grifos** localizado em ... FCCN - Fundação para a Computação Científica Nacional Login... Localização Contacte-nos FCCN ... do Concurso Público n.º 2/2008 FCCN lança concurso público internacional n.º 2/2008, para ...  
<http://www.fccn.pt/> [html] (25046 bytes) - 2008-03-12 05:59:01 - [other versions](#) - [explain](#)

**FCCN - Fundação para a Computação Científica Nacional**

-europeia - 15 Fevereiro, 2008 A FCCN, responsável pela vídeo-difusão do ninho de **grifos** localizado em ... FCCN - Fundação para a Computação Científica Nacional Login... Localização Contacte-nos FCCN ... do Concurso Público n.º 2/2008 FCCN lança concurso público internacional n.º 2/2008, para ...  
<http://www.fccn.pt/index.php> [html] (24874 bytes) - 2008-03-12 06:12:24 - [other versions](#) - [explain](#)

**Notícias FCCN**

web <http://www.fccn.pt/> <p align="justify">A FCCN, responsável pela vídeo-difusão do ninho de **grifos** ... Notícias FCCN <http://www.fccn.pt/> Notícias FCCN Rede TEIN continua a crescer <http://www.fccn.pt/> <p ... Concurso Público n.º 2/2008 <http://www.fccn.pt/> <p align="justify">FCCN lança concurso público ...  
[http://www.fccn.pt/index.php?module=phpwsrssfeeds&RSS\\_MAN\\_op=Backend&lay\\_quiet=1&RSS\\_id=1](http://www.fccn.pt/index.php?module=phpwsrssfeeds&RSS_MAN_op=Backend&lay_quiet=1&RSS_id=1) [xml] (6276 bytes) - 2008-03-12 06:04:34 - [other versions](#) - [explain](#)

**FCCN - Fundação para a Computação Científica Nacional**

FCCN - Fundação para a Computação Científica Nacional Login... Localização Contacte-nos FCCN ... Solidária Legislação Recrutamento Newsletter Consulta para aquisição de equipamento A FCCN pretende ... suporte à consulta devem ser solicitados para o email: compras@[fccn.pt](mailto:fccn.pt). As propostas deverão ser ...

# Pesquisa por endereço

The screenshot shows a web browser window with the following elements:

- Toolbar:** FCCN - Fundação para a Comput... | Internet Archive: resultados da p... | Internet Archive Wayback M... | [refresh]
- Logo:** ARQUIVO DA WEB PORTUGUESA (with a blue and green stacked logo)
- Search Bar:** Enter Web Address:  All ▾ Take Me Back Adv.Search
- Text:** 1,000 results for http://www.fccn.pt/  
between 101, 1996 and 1021, 2008
- Result Line:** [20080312055901](#) www.fccn.pt 200 text/html (new version)
- Footer:** Home | Help

# Conteúdo arquivado

F FCCN - Fundação para a Computação... Internet Archive: resultados da pesquisa Internet Archive Wayback Machine

Viewing version 1 of 1,000 12 ?? 12 ?? Help

Wayback - External links, forms, and search boxes may not function within this collection. Url: http://www.fccn.pt/time: 5:59:01 3 12, 2008 [Info]

**FCCN**  
Fundação para a Computação Científica Nacional  
FCCN | Participação Internacional | Documentação | Domínios PT  
Home English RCTS Edu.PT IPv6 VoIP e-U Campus Virtual Biblioteca do conhecimento on-line Segurança GigaPIX Serviços Projectos Eventos Rede Solidária Legislação Recrutamento Newsletter

**Grifos na Web**  
Vulture Cam

**FCCN**  
responsável pela difusão do sinal de vídeo que permite acompanhar de perto, 24Horas por dia, o processo de nidificação de um casal de grifos.

Um projecto conjunto de:  
FCCN P REFER EP

[www.publico.pt/grifosnaweb](http://www.publico.pt/grifosnaweb)

Rede TEIN continua a crescer  
A rede Trans-Europa Information Network (TEIN) - rede regional asiática que interliga as instituições de ensino e investigação deste continente, possuindo uma ligação à rede europeia GÉANT2 - está a crescer, prevendo alargar-se durante o decurso deste ano a novos países do sul da Ásia, como Laos e Cambodia.

Lançamento do Concurso Público n.º 2/2008  
FCCN lança concurso público internacional n.º 2/2008, para "Fornecimento, instalação e configuração das redes eléctricas, AVAC, segurança e telecomunicações para sala GRID". Anúncio (não dispensa a consulta das peças concursais).

Mais...

Megamail celebra aniversário com novo site  
O Megamail está a celebrar o seu 8.º aniversário de funcionamento, com uma nova imagem, um novo interface de serviço mais apelativo, cumprindo as regras de acessibilidade e, sobretudo, disponibilizando novos serviços aos seus utilizadores.

ServerSign EDU  
FCCN celebra contrato com a TERENA tendo em vista a implementação nacional do projeto europeu ServerSign EDU. Este projeto tem como principais objetivos o fornecimento, em condições especiais, de certificados de servidor do tipo GlobalSign SureServer EDU Secure Server Certificates a instituições do meio académico e científico, parte da RCTS.

Pesquisar OK Pesquisa Avançada Horas Legais em Portugal 05:00:54

Calendário □ Março 2008 □

S	D	S	T	Q	Q	S
24	25	26	27	28	29	01
02	03	04	05	06	07	08
09	10	11	12	13	14	15
16	17	18	19	20	21	22
23	24	25	26	27	28	29
30	31	01	02	03	04	05

Eventos Sessões de vídeo-difusão Outros

Receba comodamente a nossa Newsletter

20 anos em rede consigo

megamail

Speedmeter



Fundação para a Computação Científica Nacional  
*Foundation for National Scientific Computing*

# Software e maquinaria

- Não existe software comercial de arquivo da Web
- Adoptar soluções de código aberto
  - Alteração para o contexto da Web
  - Maior garantia de preservação
  - Gratuitas
  - Existem para o arquivo da Web!
- Archive-access project liderado pelo Internet Archive
  - Poupança de recursos entre iniciativas
  - Heritrix crawler
  - Formatos ARC e WARC
  - NutchWAX (Nutch + Web Archive eXtensions)

# Problemas com as tecnologias de arquivo

- Boa base para o Arquivo da Web Portuguesa mas...
- São tecnologia de ponta
  - Estão em desenvolvimento
  - Pouco maduras e instáveis
  - Documentação com erros ou inexistente
- É necessário contribuir para melhorá-las



- Blade system
  - 7 blades: 2 x Quad-core, 8 GB
  - Espaço para 16 blades
- Armazenamento
  - SAN: 25.6 TB em RAID 5
  - 56 discos (500 GB e 1 TB)
  - Discos SATA (7.2K) e Fibre Channel (15K)
  - Autómato de tapes: 12 TB



Fundação para a Computação Científica Nacional  
*Foundation for National Scientific Computing*

# Medição da Web portuguesa

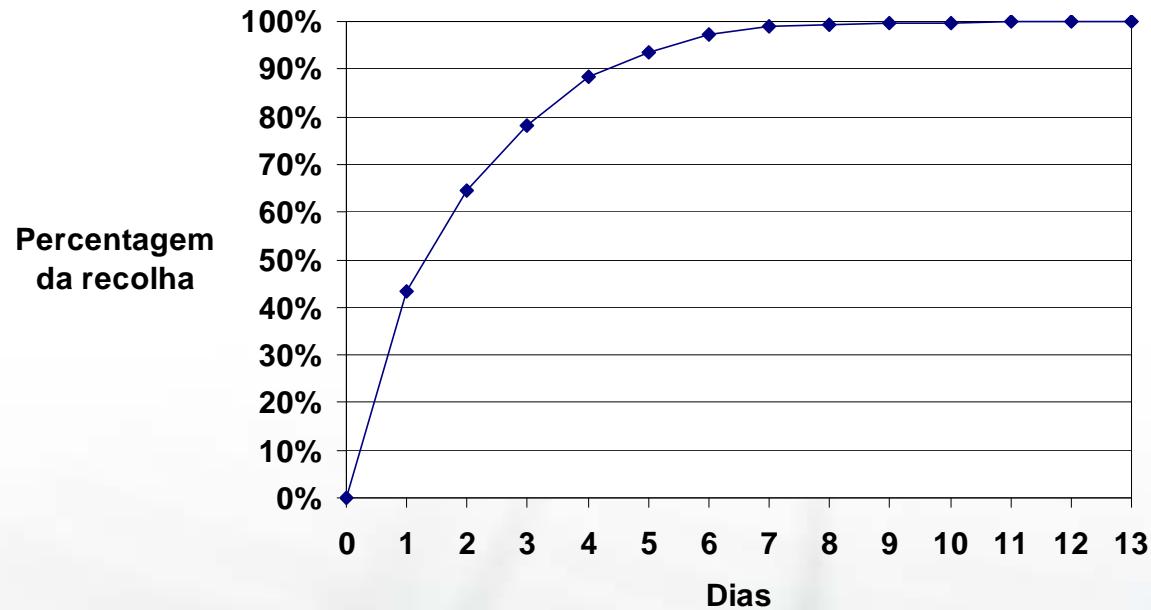
# Critério de selecção para um arquivo Web nacional

- Objectivo: seleccionar conteúdos para arquivar
- Critério de relevância histórica?
  - Requer intervenção humana
  - 50 milhões de conteúdos por trimestre
- Que critério de selecção automática adoptar para recolher conteúdos de uma Web nacional?

# Definição de Web portuguesa

- Recolha automática
- Sites sob .PT (1<sup>a</sup> fase)
  - Noutros domínios: embebidos + redirecções
- Todos os tipos são aceites (máximo de 10 MB)
- 10 000 URLs por sítio Web
- Profundidade máxima de 5 ligações
- Respeito por regras de exclusão de robots (REP e meta-tag ROBOTS) e 2 segundos de pausa
- No futuro todos os conteúdos em português?

# Evolução da recolha



- Fevereiro de 2008
- 1 computador
- 99% em 7 dias
- Conteúdos alojados na RCTS
  - 1 Gbps ou 100 Mbps
  - 11% dos URLs
  - 18% volume dados

# Caracterização de uma recolha

Métrica	Volume
Endereços visitados	<b>72 milhões</b>
Sítios Web visitados	<b>455 mil</b>
Conteúdos recolhidos	<b>56 milhões</b>
Volume de dados recolhidos	<b>2,8 TB</b>
Dados comprimidos	<b>2 TB</b>

Código	# URLs	%
<b>200</b>	<b>56 046 288</b>	<b>85,2%</b>
<b>302</b>	<b>4 305 265</b>	<b>6,5%</b>
<b>404</b>	<b>3 669 855</b>	<b>5,6%</b>
<b>301</b>	<b>789 133</b>	<b>1,2%</b>
<b>500</b>	<b>325 225</b>	<b>0,5%</b>
<b>400</b>	<b>266 318</b>	<b>0,4%</b>
<b>403</b>	<b>164 241</b>	<b>0,2%</b>
<b>303</b>	<b>124 385</b>	<b>0,2%</b>
<b>401</b>	<b>48 334</b>	<b>0,1%</b>
<b>outros</b>	<b>36 136</b>	<b>0,1%</b>
<b>Total</b>	<b>65 775 180</b>	<b>100%</b>

- Estudo detalhado de caracterização está em progresso
- Analisar evolução da Web portuguesa
  - Comparação com estudos anteriores

# Distribuição de formatos: número de endereços

MIME	% conteúdos
text/html	65%
image/jpeg	17,7%
image/gif	7,6%
application/pdf	2,1%
text/plain	1,5%
Outros	6,1%

- Preservar formatos HTML, JPEG e GIF: cobririam 90% da Web portuguesa (03/2008)

# Distribuição de formatos: volume de dados

MIME	% Dados	Posição #URLs
text/html	39,6%	1
application/pdf	14,4%	6
image/jpeg	12,4%	2
text/plain	4,7%	5
application/x-gzip	4,3%	10
Outros	24,6%	

- Posições alteram-se
- Dominância de formatos não é tão evidente

# Trabalho “futuro”

- Integração de colecções externas
  - Internet Archive (2000-2007): 800 GB
  - Recolhas do tumba! (2002-2006): 1,5 TB!
- Investigação acerca de pesquisa temporal sobre a Web
- Novas ferramentas em desenvolvimento
  - rARC: replicador de ARCs
  - GAppA: Grid Appliance para o Arquivo
  - WebClass: classificador de conteúdos
- Medição da acessibilidade da Web portuguesa

- Arquivar a Web tem interesse nacional
- Um arquivo necessita de ser pesquisável ou a informação arquivada “morre” por estar inacessível
- Arquivar a Web portuguesa é possível
- Contamos com a ajuda de todos



ARQUIVO DA WEB  
PORTUGUESA

**Obrigado pela atenção.  
Questões e sugestões são bem-vindas!**

<http://arquivo-web.fccn.pt>