



Fundação para a Computação Científica Nacional
Foundation for National Scientific Computing

Preservação da Web através de replicação distribuída em larga escala

André Nogueira

AWP – Arquivo da Web Portuguesa - <http://arquivo-web.fccn.pt/>

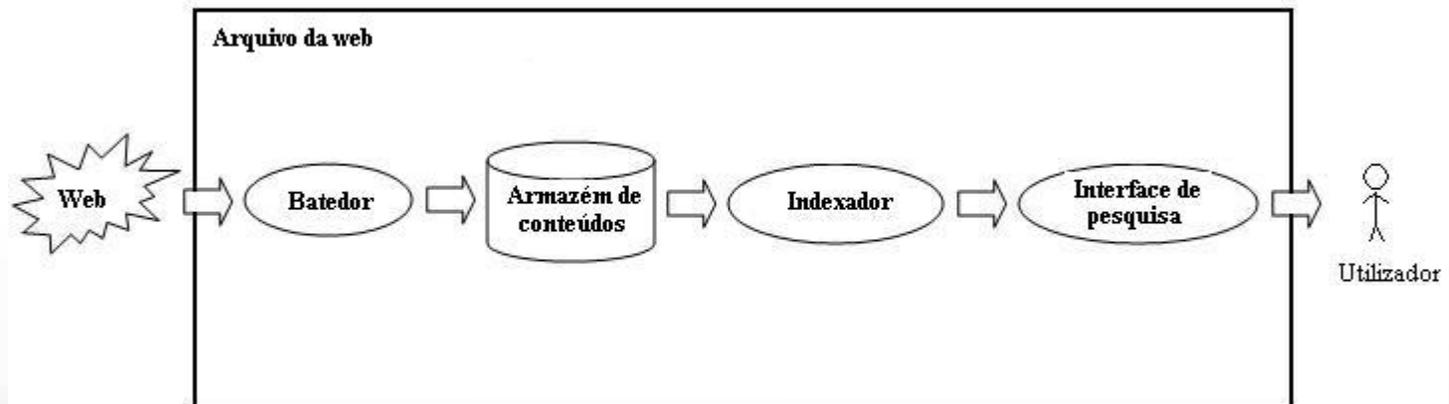
andre [ponto] nogueira [arroba] fccn [ponto] pt



ARQUIVO DA WEB
PORTUGUESA

- A Web é a maior fonte de informação construída
 - Jornais, livros, documentação técnica, blogs
 - Informação publicada exclusivaente na Web
- A informação na Web é efémera
- Preservação iniciada pelos arquivos da Web
- Primeira iniciativa: Internet Archive

Arquitectura geral



- Armazenamento centralizado
 - Incêndio ou inundação das instalações
- Cópias de segurança → Duplicação de custos
- Recolha contínua → Aumento do espaço de armazenamento
- Resultados de uma recolha do AWP
 - Sítios Web visitados: 455 mil
 - Tamanho máximo ficheiro: 10 MBytes
 - Total recolhido: 2,5 TBytes

- Em 2015 haverá mais de 1000 milhões de computadores ligados à rede mundial

BOINC: A System for Public-Resource Computing and Storage. David P. Anderson. 5th IEEE/ACM International Workshop on Grid Computing. November 8, 2004, Pittsburgh, USA.

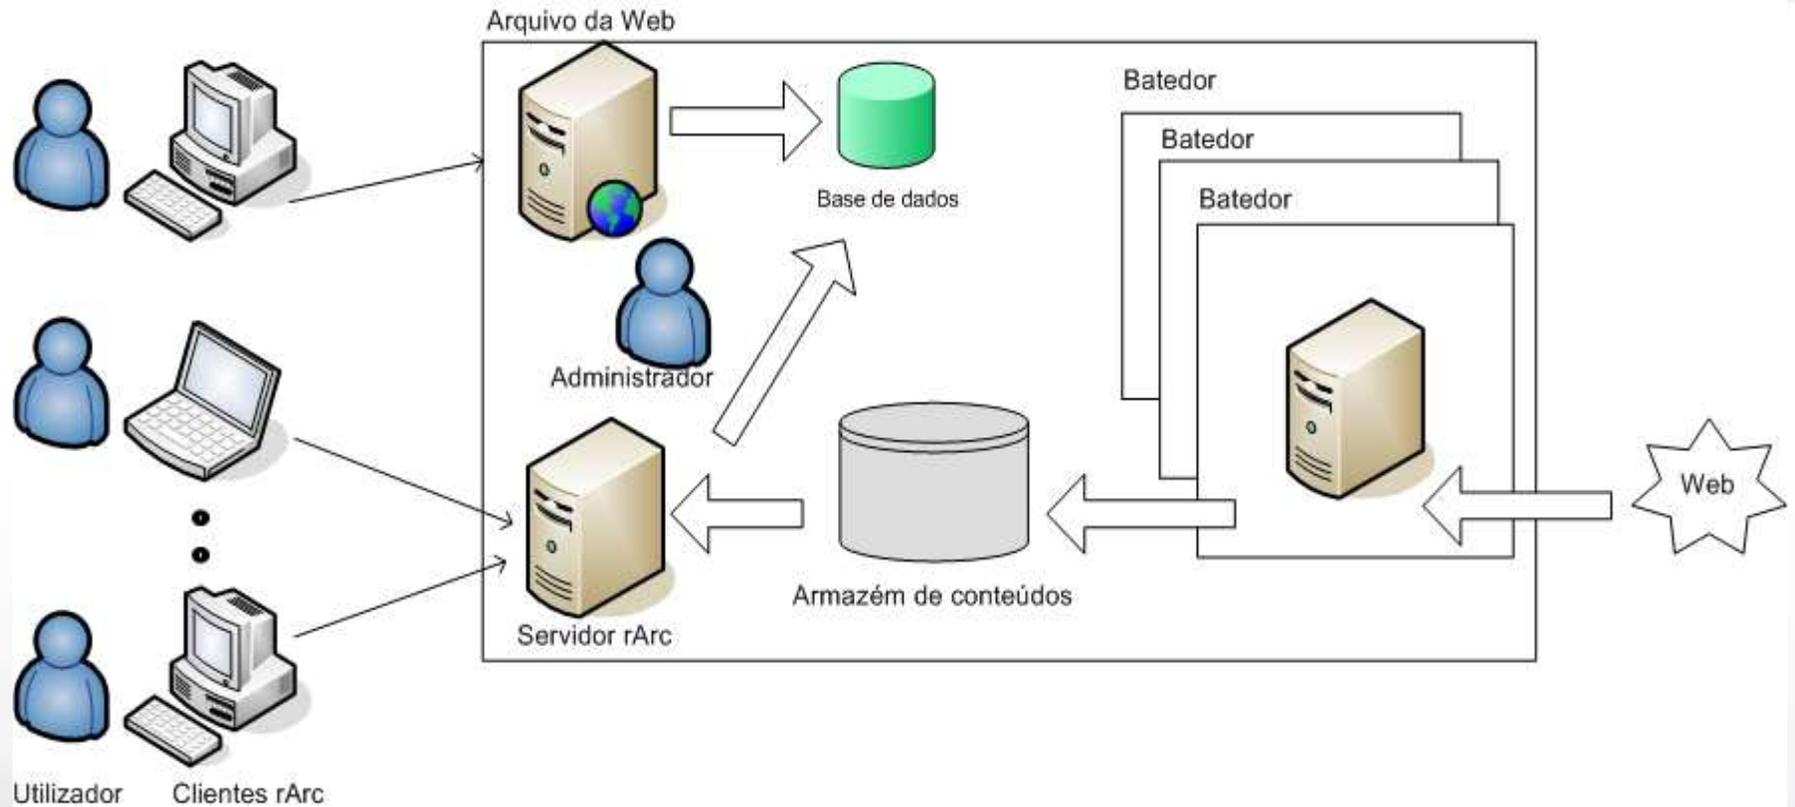
- Actualmente, um PC tem 100 GBytes de capacidade de disco
- Se 100 milhões de utilizadores disponibilizarem 10% (10 GBytes) de espaço de disco → Total disponível seria 1 ExaByte (10^{18} bytes)

Replicador de ficheiros Arc (rArc)

- Requisitos
- Trabalho Relacionado
- Arquitectura
- Funcionamento
- Avaliação
- Trabalho Futuro
- Conclusões

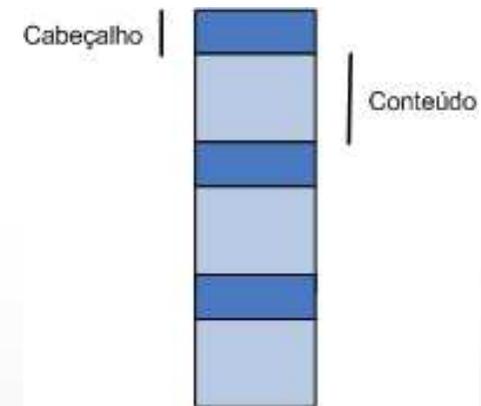
- Disponibilidade
 - Diferentes fusos horários
- Confidencialidade
 - Informação confidencial; *Spam*
- Autenticidade
 - Virus informáticos
- Integridade
 - Problemas físicos dos discos dos computadores dos utilizadores
- Portabilidade
 - Rede mundial de computadores heterogéneos
- Usabilidade
 - Motivação dos utilizadores

- Partilha de ficheiros ponto-a-ponto (Napster)
 - Partilha de informação
- Bibliotecas digitais (LOCKSS)
 - Problemas de confidencialidade
- Data grids (SRB)
 - Acesso uniforme à informação
- Computação distribuída voluntária (BOINC)
 - Processamento de informação
- Armazenamento distribuído (OceanStore)
 - Disponível apenas um protótipo

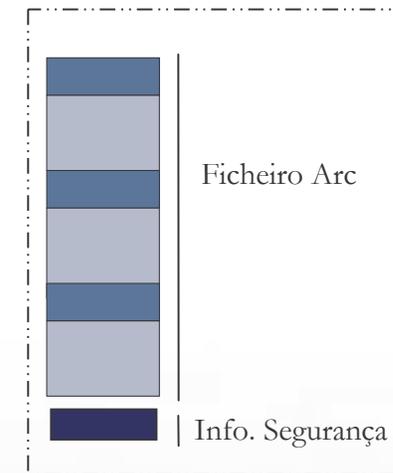


- Base de dados sobrevive à perda de informação no armazém de conteúdos

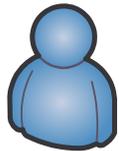
- Especificação de ficheiro desenvolvido pelo Internet Archive.
- Formato utilizado pelo batedor Heritrix.
- O tamanho definido por omissão no Heritrix é 100 MBytes.
- Warc o formato sucessor do Arc.



- Permite garantir a confidencialidade e autenticidade
- Uma cápsula é constituída por:
 - Ficheiro Arc
 - Info. Segurança (assinatura simétrica)



Cifrado



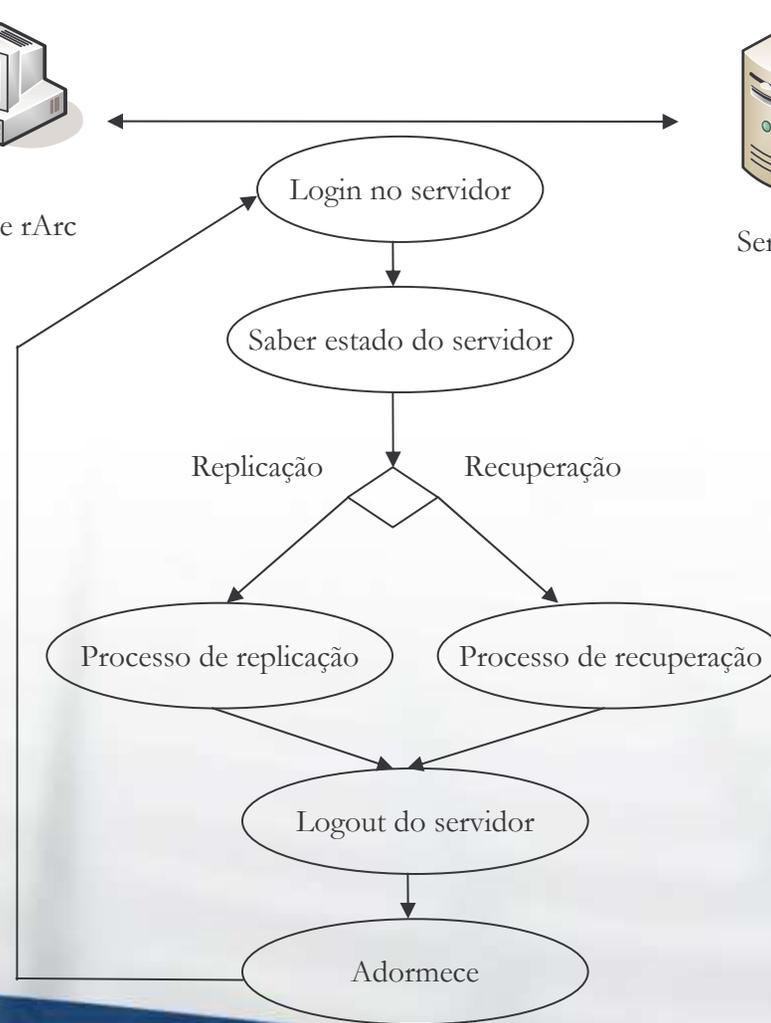
Utilizador




Cliente rArc

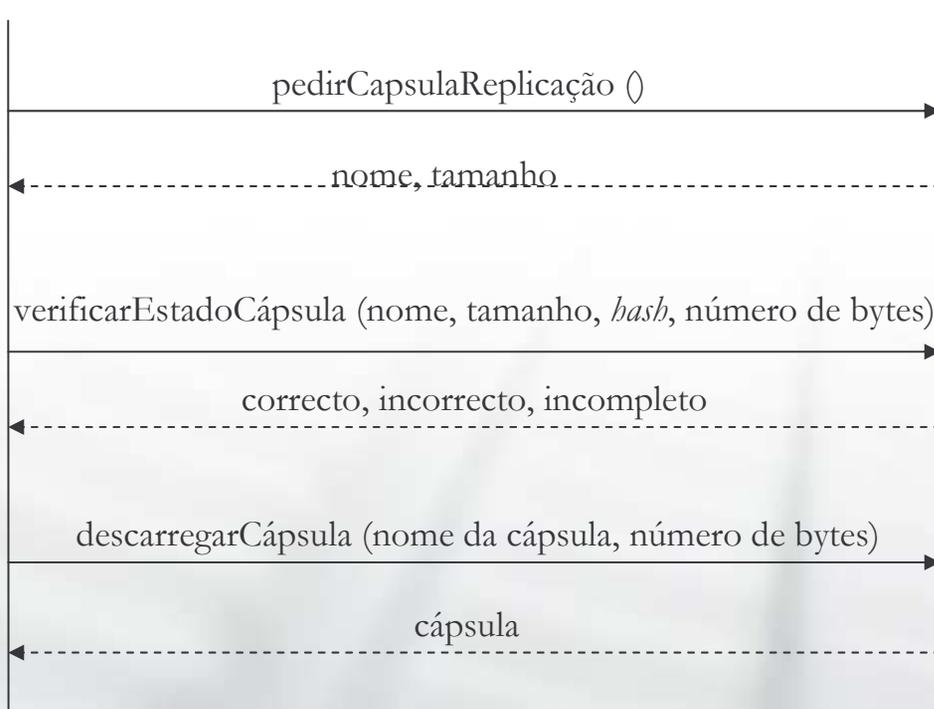


Servidor rArc



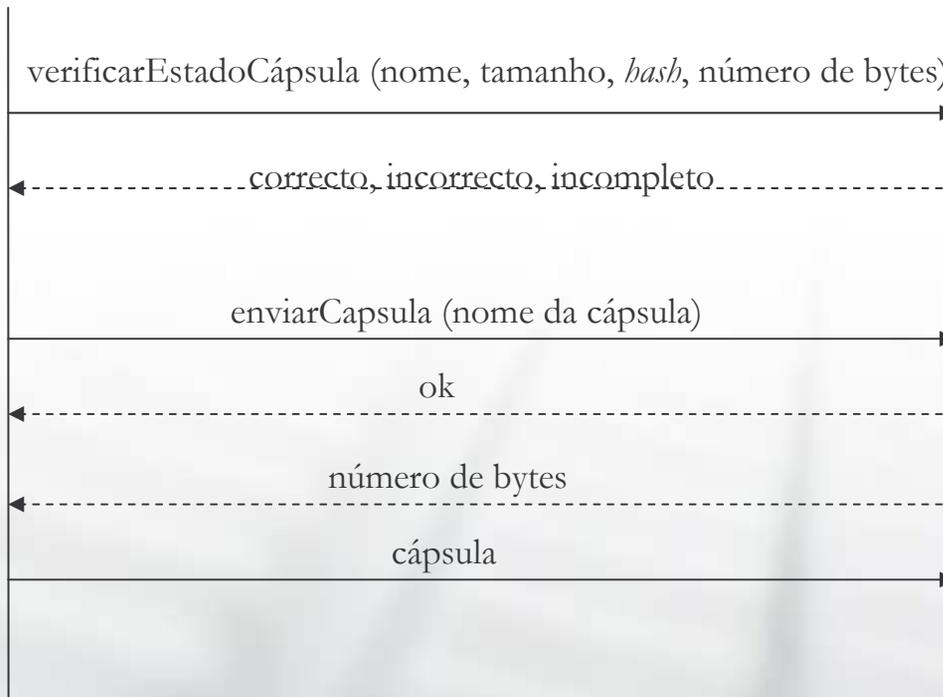


- O servidor escolhe a cápsula com menos tentativas de replicação



Nome de cápsula	Número de vezes eleita para replicação
Cápsula 1	2
Cápsula 2	2
Cápsula 3	2
Cápsula 4	1

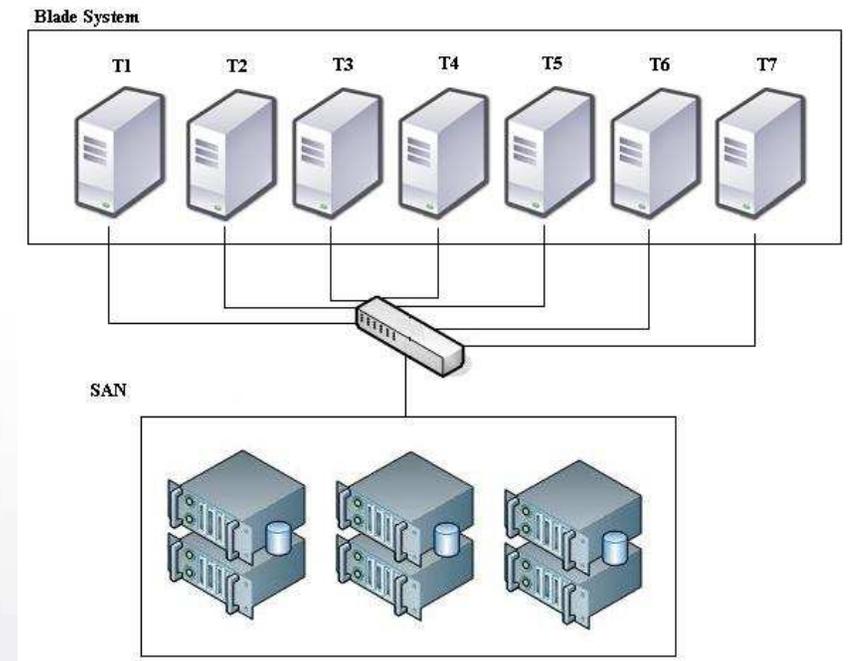
- Quando são adicionadas novas cápsulas ao sistema, o servidor vai eleger estas para replicação.



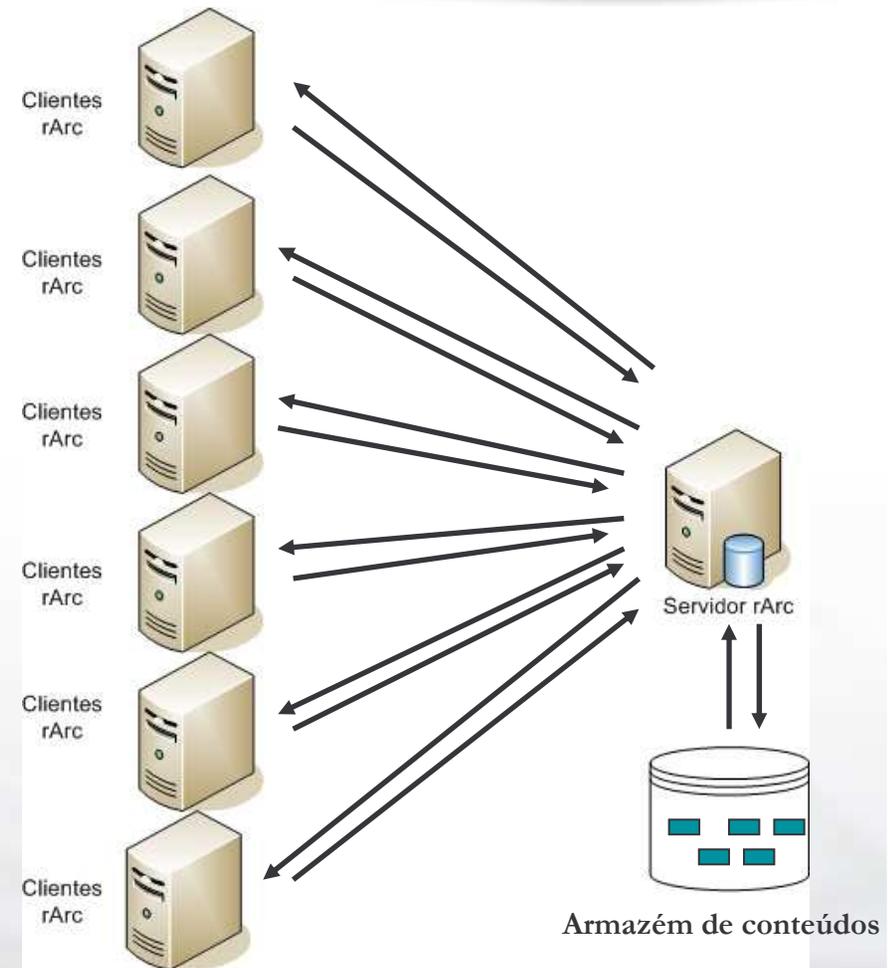
- Quando termina o envio de uma cápsula, o servidor verifica a autenticidade do ficheiro Arc
- Quando uma cápsula é recuperada, as restantes transferências da mesma cápsula são terminadas

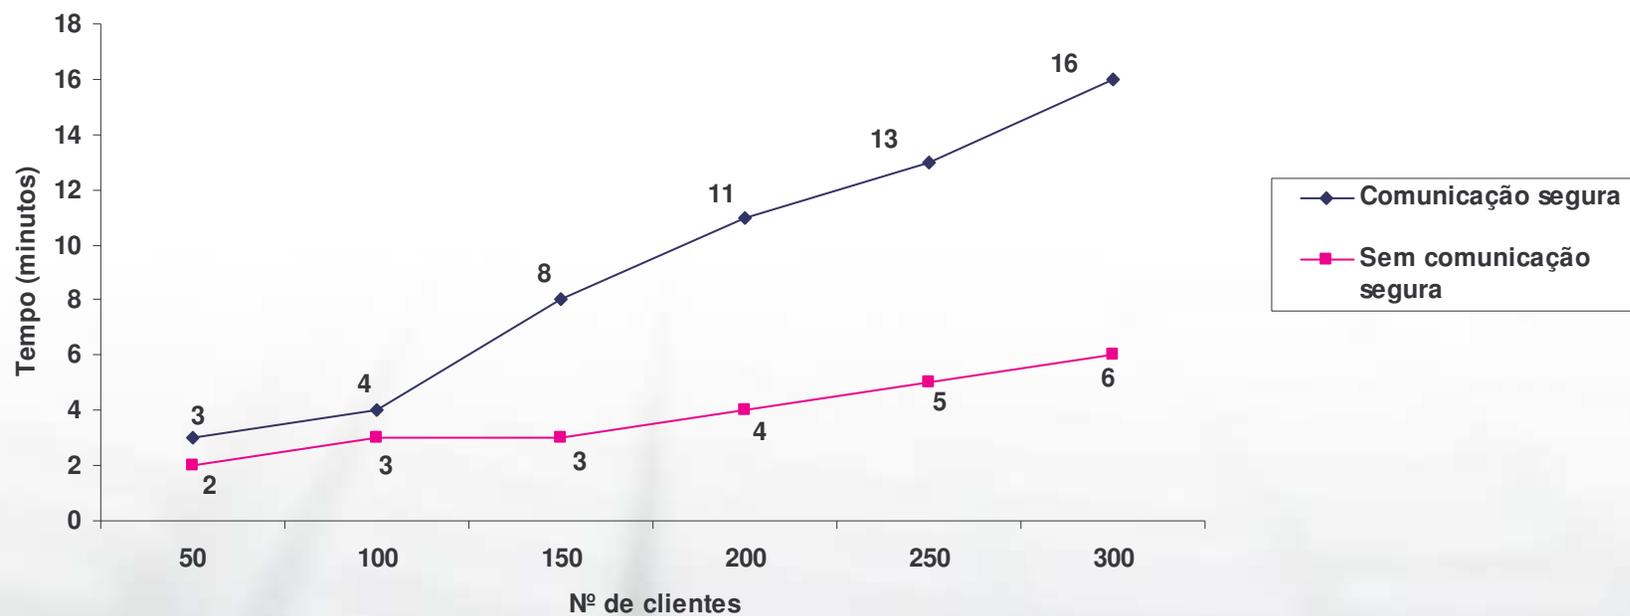
- Ferramentas
 - ArgoUml (análise e desenho)
 - Java (desenvolvimento)
 - Eclipse
 - MySQL (desenvolvimento)
- Ferramentas e tecnologias utilizadas de código aberto
 - Não existe custo de aquisição

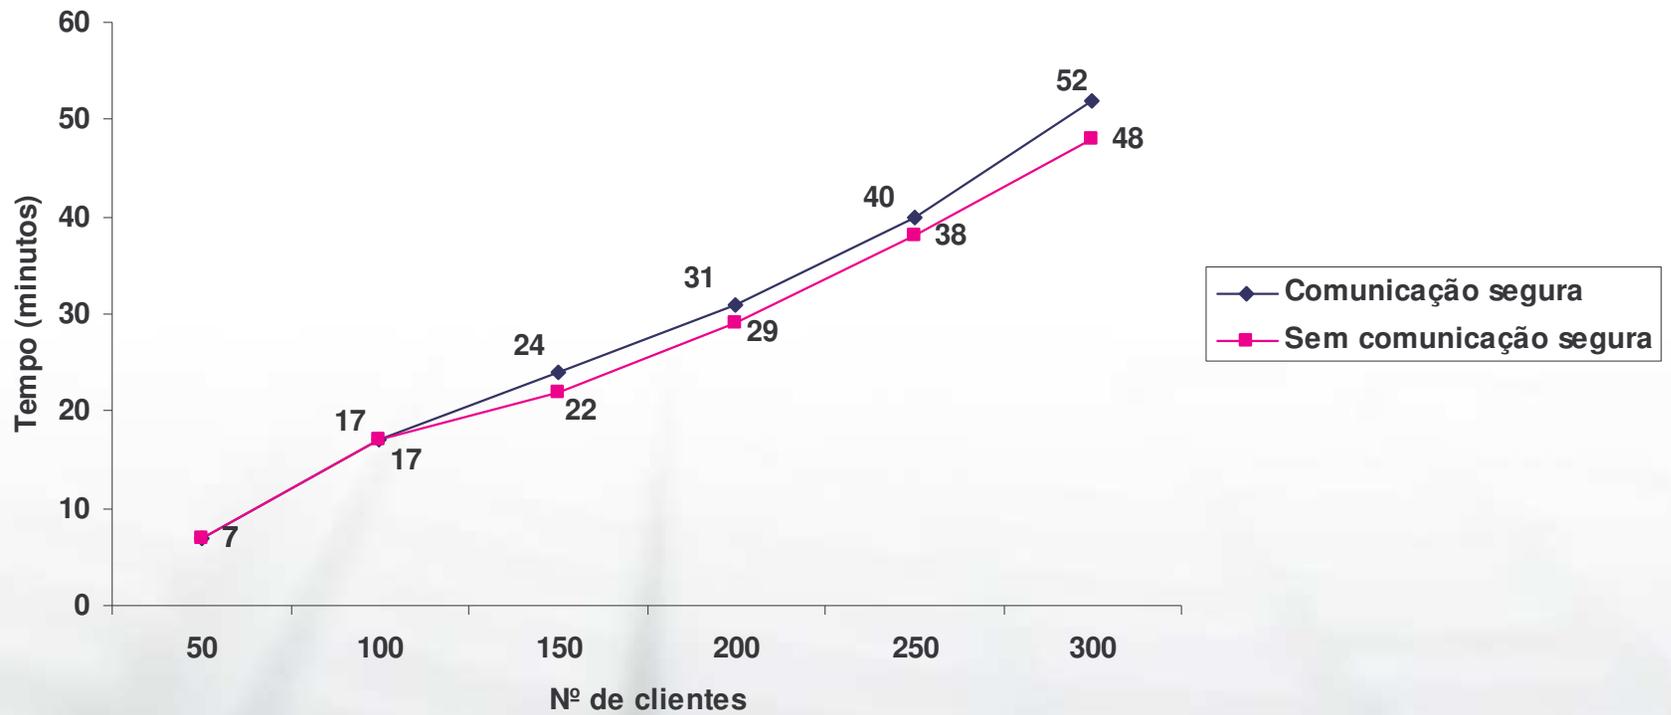
- Objectivo
 - Avaliar a correcção de funcionamento
 - Avaliar o desempenho
- Infra-estrutura do AWP
 - Blade system
 - Intel Xenon Quad-Core (2.33 GHz)
 - 8 GBytes RAM
 - Red Hat Enterprise Linux 5
 - SAN
 - Espaço total: 24,5 TBytes

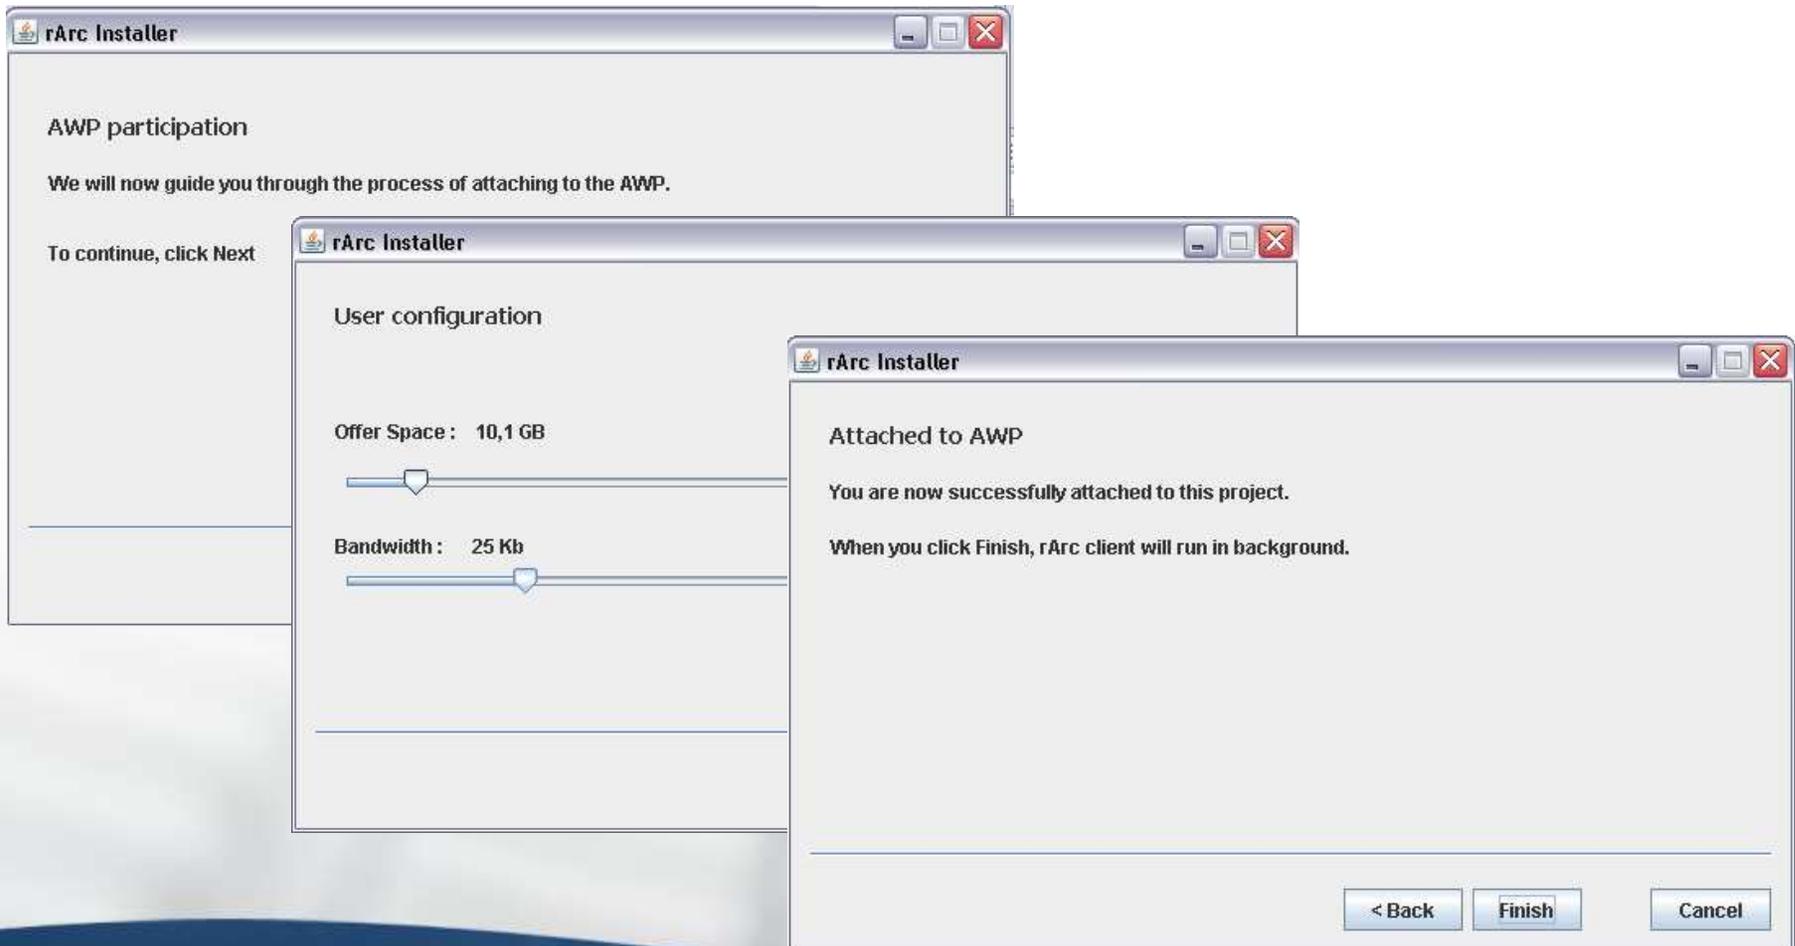


- Dois cenários:
 - Replicação - replicar cápsulas por vários clientes
 - Recuperação - recuperar as cápsulas replicadas pelos clientes
- Medir o tempo total para replicar e recuperar as cápsulas









- Motivação do utilizadores
 - Sítio de apoio
 - Sistema de ranking
- Melhorar o desempenho
- Recuperação parcial
- Comunicação segura apenas na autenticação do cliente rArc

- Análise de requisitos para sistemas relacionados com o arquivo da Web não é trivial
- Não existia um sistema que respondesse aos requisitos dos arquivos da Web.
- Rarc disponível para a comunidade em código aberto
- A comunidade pode contribuir para a preservação dos conteúdos dos arquivos da Web
- Disponível em breve em <http://arquivo-web.fccn.pt>

Obrigado pela atenção