



CHAVE: Consolidation with High-Availability on Virtualized Environments

Daniel Scheidemantel Camargo

Orientador: Maurício Aronne Pillon, Dr.
Coorientador: Charles Christian Miers, Dr.

7 de dezembro de 2017



Agenda

- Motivação
- Trabalhos correlatos
- Solução proposta
- Plano de testes
- Resultados preliminares



Objetivo

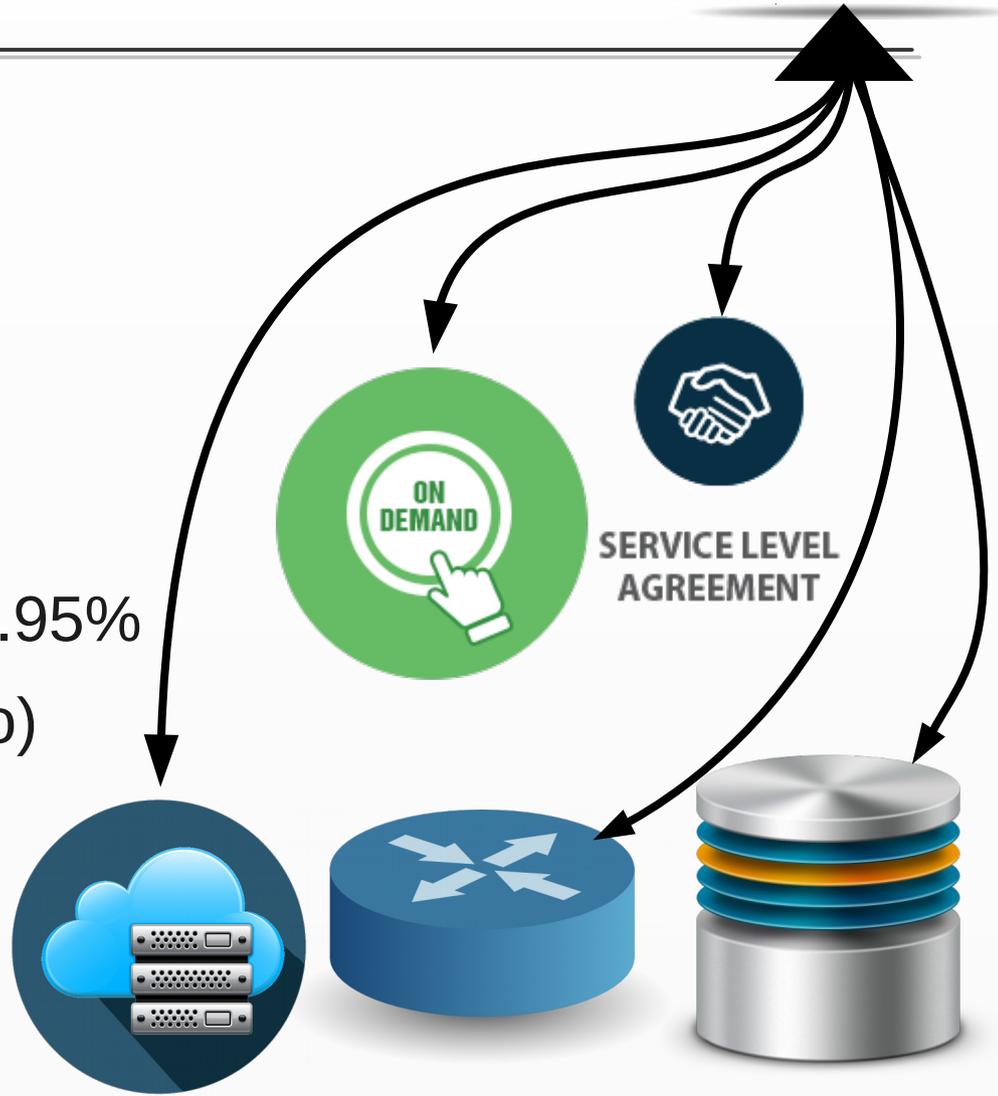


- Mecanismo de alta disponibilidade (HA):
 - Replicação de máquinas virtuais (MVs).
 - Impacto em energia e recursos
- Consolidação de MVs:
 - Reduzir o impacto da HA.
 - Restrição de justaposição das réplicas.

Computação em nuvem



- Computação sob demanda.
- Virtualização
- SLA: **Disponibilidade.**
 - Nuvens públicas IaaS
 - Taxas: de 99.9% a 99.95% (131 a 66 minutos/ano)



Serviços críticos



- Organizações: **continuidade de negócios.**
- Violações no SLA (Interrupções)
 - Disponibilidade abaixo da contratada.
 - Prejuízos financeiro e reputação.
 - Ambos: cliente e provedor
- Se a taxa do SLA não atende aos requisitos da organização:
 - Serviços em alta disponibilidade (HA)
 - Acima de 5 noves (5.2 minutos/ano)



Disponibilidade



Inerente: sistemas computacionais distribuídos.

- Desconsidera-se logística e manutenção

- Razão entre tempo disponível (T_a) e tempo total (T_{to})

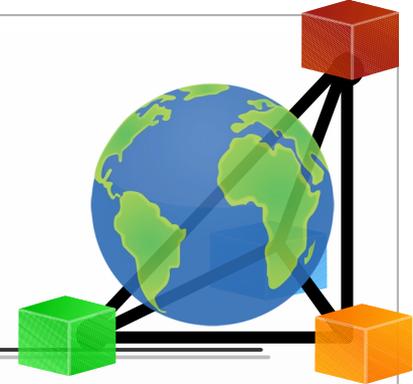
$$A = \frac{T_a}{T_{to}} = \frac{T_a}{T_a + \sum_{i=0}^n T_{mc_i}}$$

Nº de falhas

Tempo de correção

- Variáveis obtidas por **análise histórica**.
- Indicadores **probabilísticos**: MTBF, MTTF e MTTR.

Arquitetura Multi-AZs

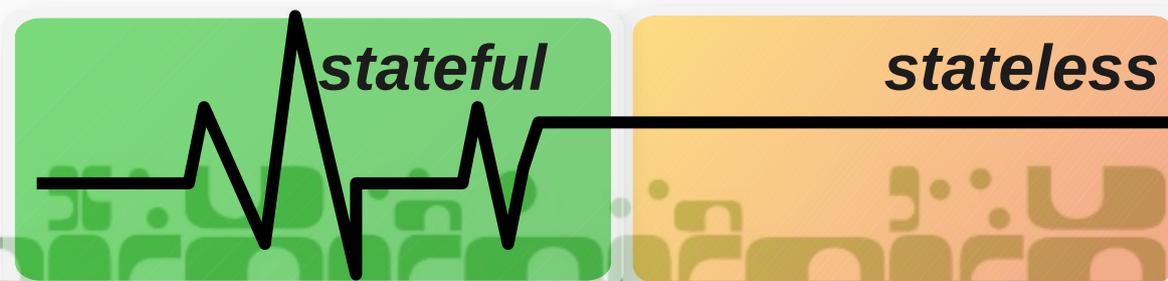


- São infraestruturas de data centers, agrupadas em regiões:
 - Globalmente distribuídas,
 - Independentes entre si (falhas independentes),
 - Links de baixa latência.
- Nuvens públicas e privadas.
- Multi-AZ amplamente usada para alta disponibilidade.

Alta Disponibilidade



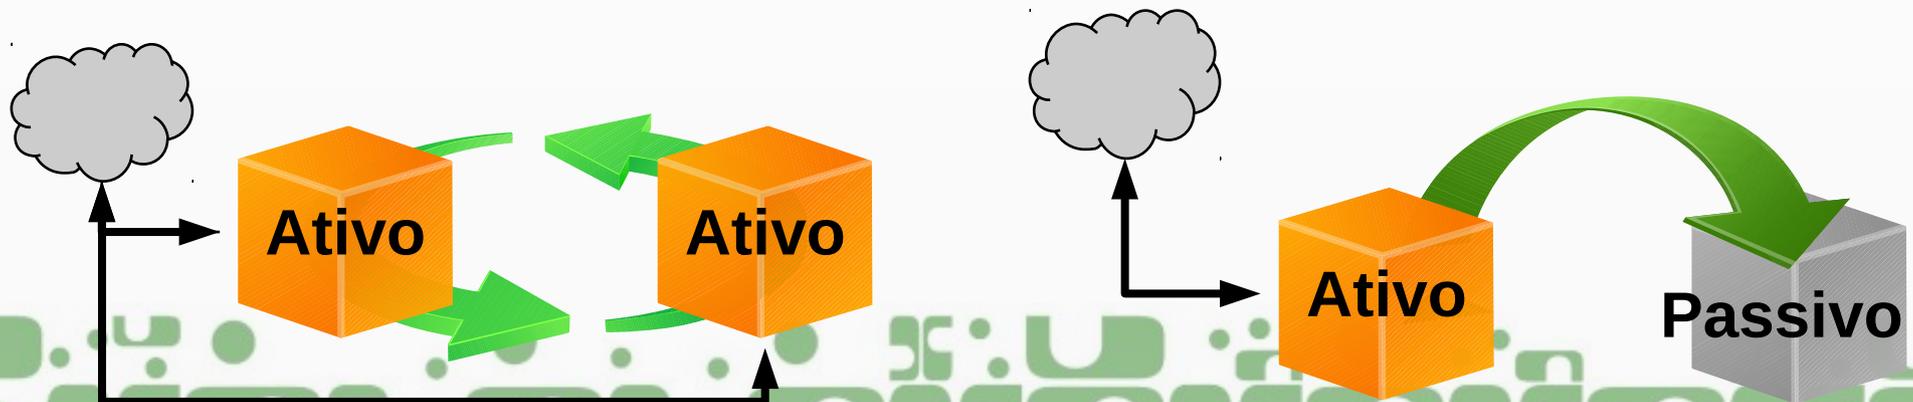
- Serviços nativos para nuvem:
 - Balanceadores de carga autoescaláveis:
 - Sem estados em memória: ***stateless***.
 - Serviços autogerenciados:
 - SGBDs específicos.
- Demais aplicações ***stateful*** sem acesso a HA:
 - Serviços legados, aplicações científicas.



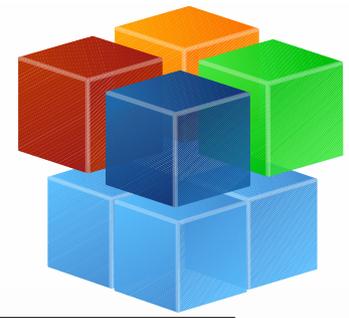
Alta Disponibilidade Replicação



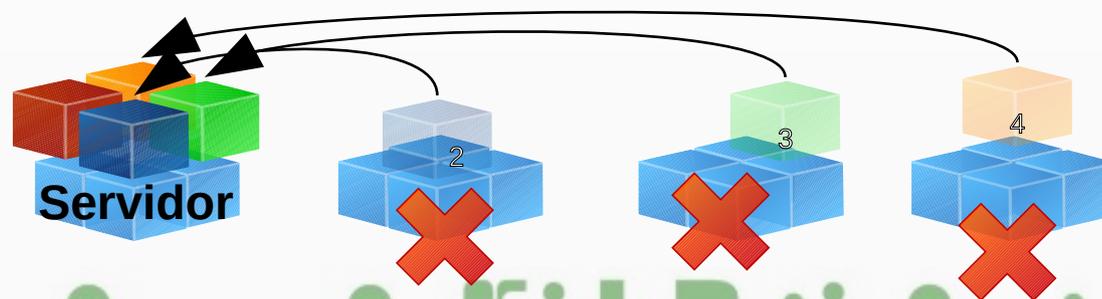
- Análise: *Tempo de correção X Sincronização X Recursos.*
 - Backup por *snapshots* (maior tempo de correção)
 - Replicação de estados de memória:
 - Ativo/ativo e ativo/passivo.
 - Maior **impacto no consumo de energia**



Consolidação de MVs



- Estratégia para reduzir o consumo de energia em DCs.
- Alocar todas as MVs no menor número possível de servidores, desabilitando os servidores subutilizados.
- Dilema: Consolidação vs. Violações do SLA.
- **Restrição de justaposição:** As réplicas de uma MV crítica não devem estar no mesmo ponto de falhas (SPOF)





Trabalhos correlatos

Trabalhos correlatos

- Relacionados doze trabalhos, organizados em três linhas de pesquisa:
 - Apenas consolidação, apenas HA, e ambos.
- Critérios:
 - **Contribuições:** Conceitos e práticas que agregam para a presente proposta.
 - **Problemas:** Conceitos incompatíveis com a presente proposta.

Trabalhos correlatos

- Linha de pesquisa:
 - Consolidação de MVs

Autores	Contribuições	Problemas
Nathuji e Schan 2007	Políticas locais e globais	Viola preceitos de isolamento e segurança
Corradi 2012	Mensura impactos negativos da consolidação	Sem uma estratégia definida
Beloglazov 2013	Utiliza o FFD para consolidar	Não considera diversas restrições
Zhang 2014	Correlaciona recursos físicos com virtuais	Utiliza apenas o posicionamento inicial

Trabalhos correlatos

- Linha de pesquisa:
 - Alta disponibilidade

Autores	Contribuições	Problemas
Ranjan 2015	Replicação Multi-AZ em nuvens públicas	Survey discute diversas abordagens.
Masakari 2017	Evacuação de MVs e reinício forçado	Apenas serviços <i>stateles</i>
Cully 2008	Usa <i>checkpoints</i> de replica de 1:N, tolerância à falhas	Compatível apenas com hipervisores Xen
Dong 2013	Abordagem em lockstep, proporciona melhor uso de recursos	Invasivo, pois requer modificações no TCP

Trabalhos correlatos

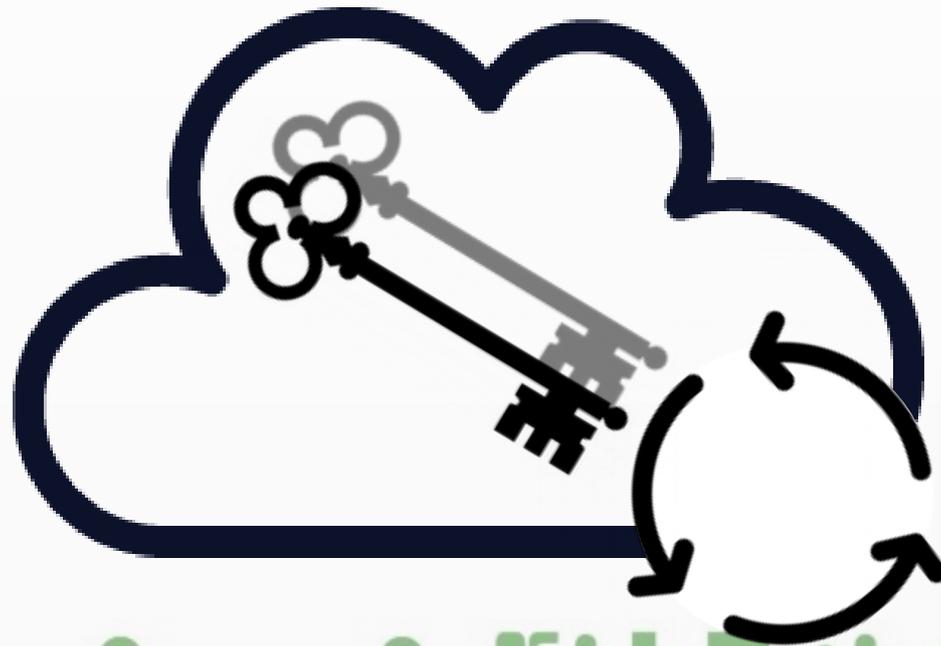
- Linha de pesquisa:
 - Consolidação de MVs com alta disponibilidade

Autores	Contribuições	Problemas
Bin 2011	Adota a restrição de justaposição	<i>Backup por snapshots, (tempo para restauração)</i>
Simonin 2013	Arquitetura Big-Tree, verificação de falhas	Considera apenas +1 replica (sem HA OnDemand)
Li 2016	Replicação de 1:N, conceitos de probabilidade de falhas	<i>Backup por snapshots, viola preceitos de isolamento e segurança</i>

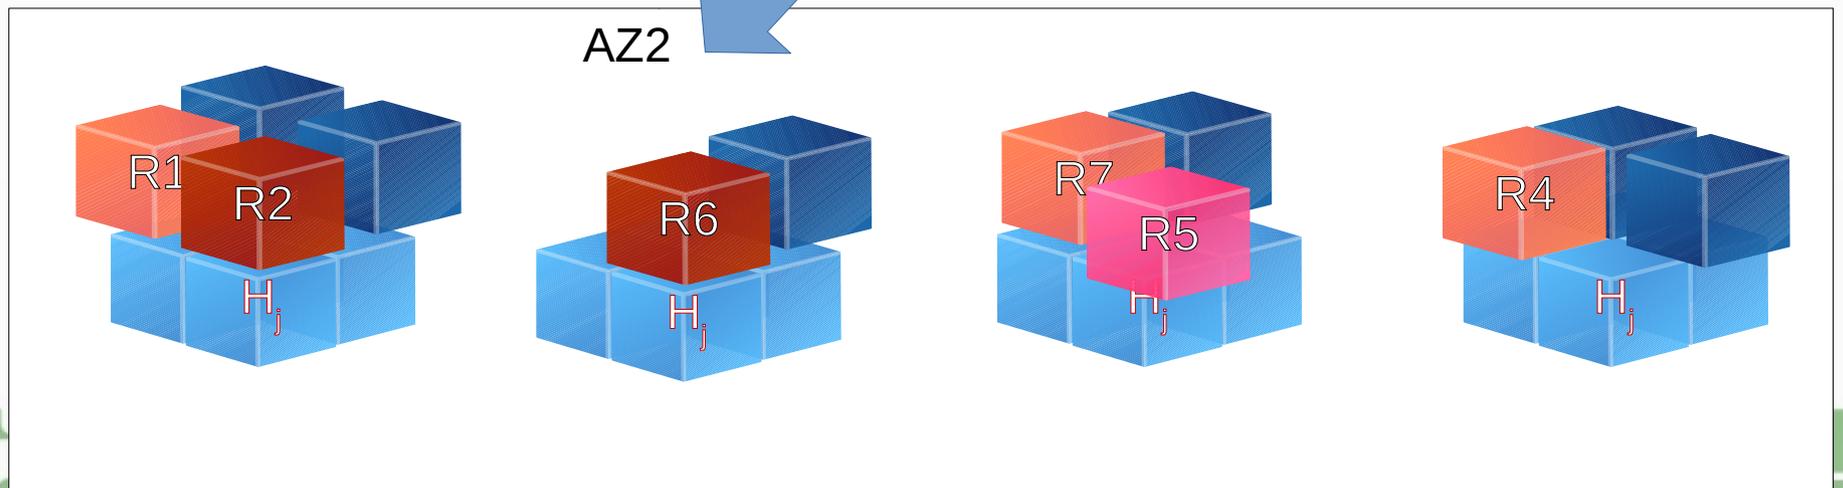
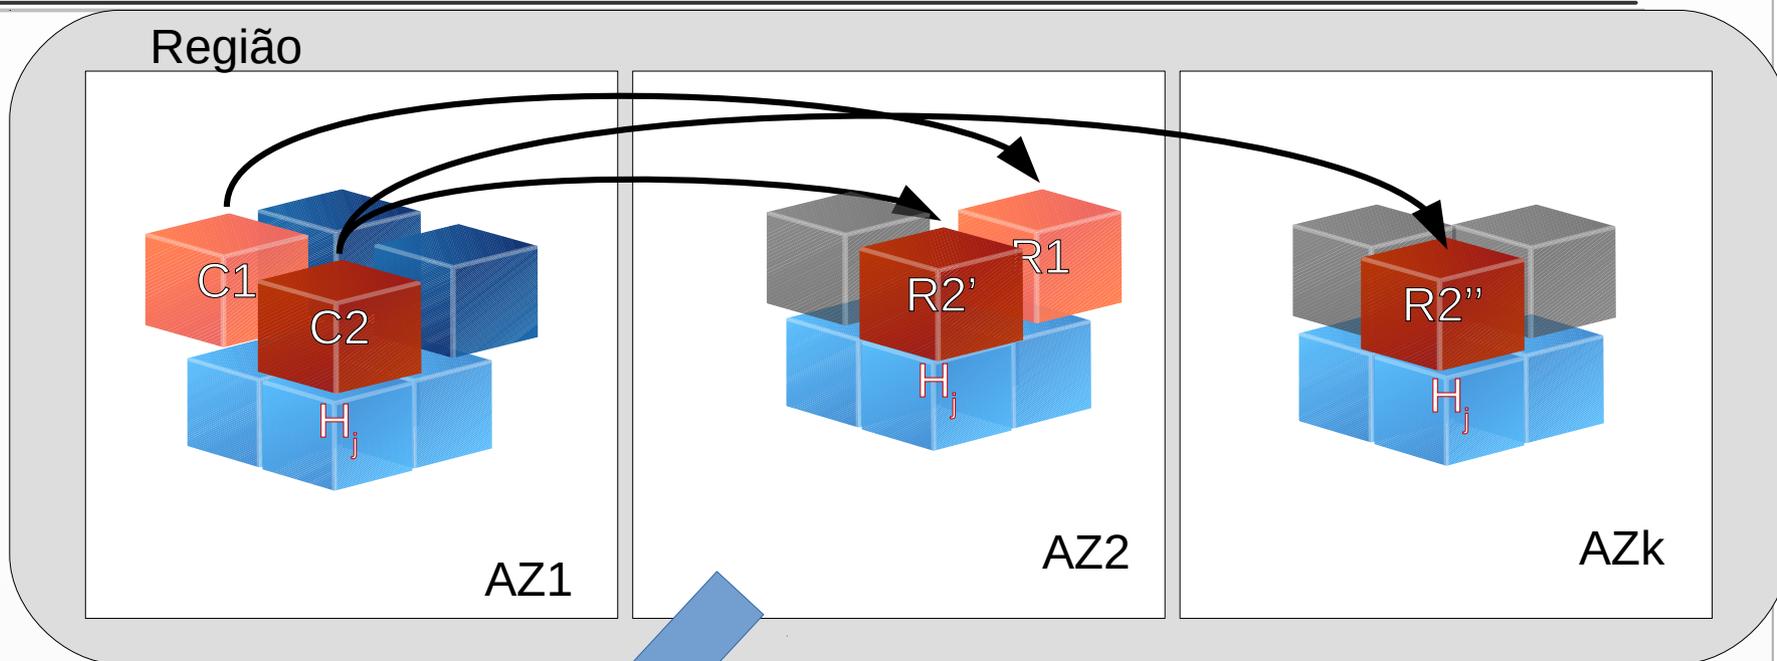
Trabalhos correlatos

- Diversas abordagens em consolidação ou HA:
 - Indicando que estas são potenciais áreas de pesquisa.
- Poucos trabalhos com as duas linhas de pesquisa.
- Levantamento das contribuições e problemas.
- Até o momento, não foram encontrados trabalhos que reúnam todas as características na mesma proposta.

CHAVE: Consolidation with High-Availability on Virtualized Environments



Objetivos gerais



Arquitetura Multi-AZ

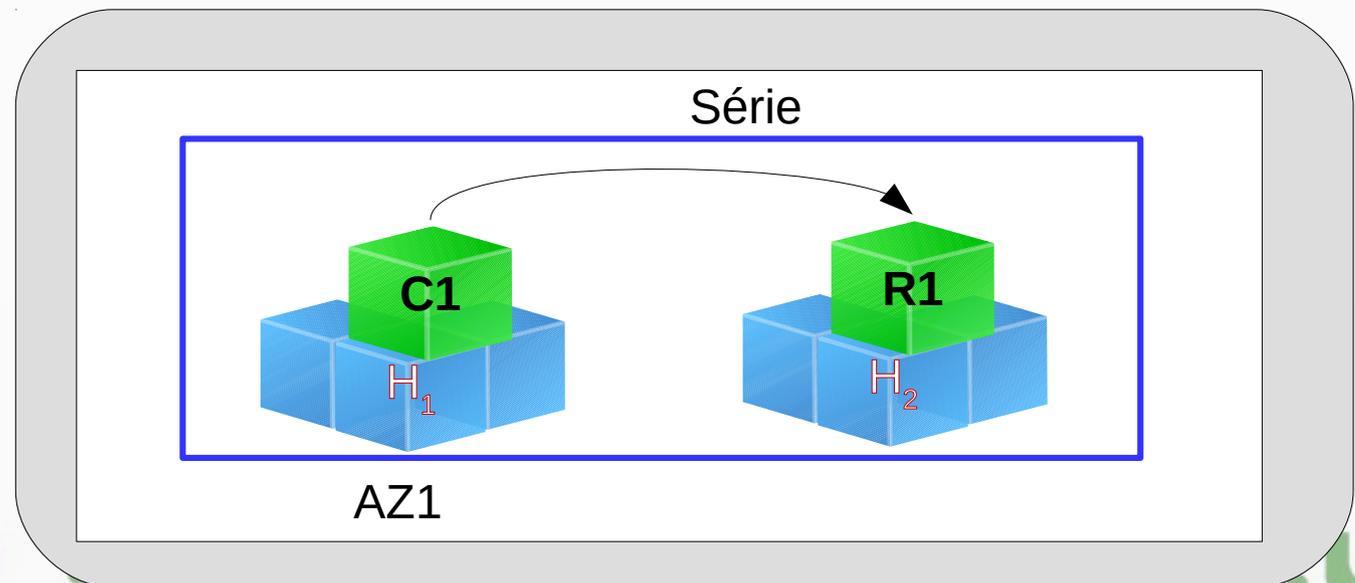
- As réplicas são obrigatoriamente instanciadas em AZs diferentes.
 - Minimiza o SPoF.
 - Habilita uma consolidação de MVs livre de restrições
 - Justaposição
 - Resultados mais próximos do ótimo

Alta Disponibilidade

Diagrama de blocos de confiabilidade



- Posicionamento das réplicas: componentes em série
 - Produto da disponibilidade da AZ_1 , servidor.
 - $A_1 * A_1 = A_{final}$
 - Resultado **menor** que a taxa de ambos.

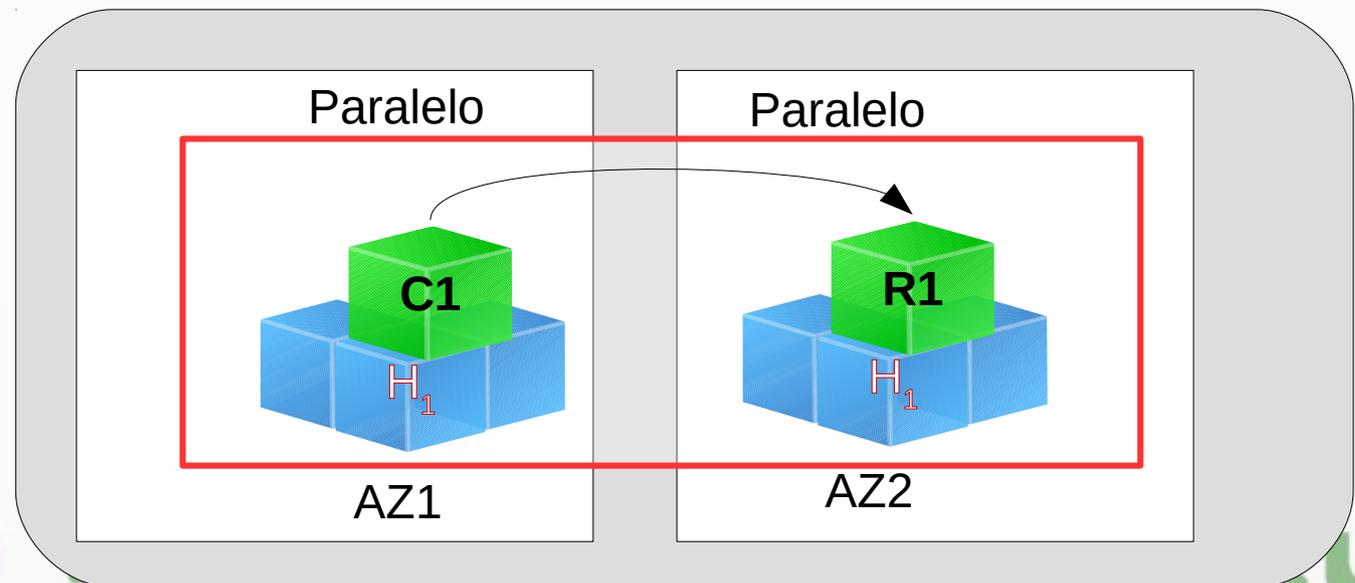


Alta Disponibilidade

Diagrama de blocos de confiabilidade



- Posicionamento das réplicas: componentes em paralelo.
 - **1** - Produto da indisponibilidade $(1-A_1), (1-A_2), \dots (1-A_n)$
 - $1 - (1-A_1) * (1-A_2) = A_{\text{final}}$
 - Resultado **maior** que a taxa dos componentes.



Alta Disponibilidade



- Probabilidade de falhas de eventos independentes.
- Para k componentes, a probabilidade de todas as AZs falharem simultaneamente:

$$HA = 1 - (1 - A)^k$$

- 'k' é o número de paralelos (1 MV crítica + réplicas)
- Entradas: Taxa de disponibilidade A e o valor de 'k'

HA sob demanda

- Transparência para o desenvolvedor:
- Como saber o número de réplicas?
 - “Forneça a taxa de HA requerida”. Ex.: 6 ‘noves’
 - A solução fornece o número de réplicas ‘ r ’ necessárias para alcançar essa taxa.

$$\text{ceil}(r) \approx \log_{1-\mathbb{A}}(1 - \mathbb{HA}) - 1 \equiv \frac{\log_{10}(1 - \mathbb{HA})}{\log_{10}(1 - \mathbb{A})} - 1$$

- Base na disponibilidade \mathbb{A} de cada AZ.

Definições Replicação

Perspectiva do desenvolvedor

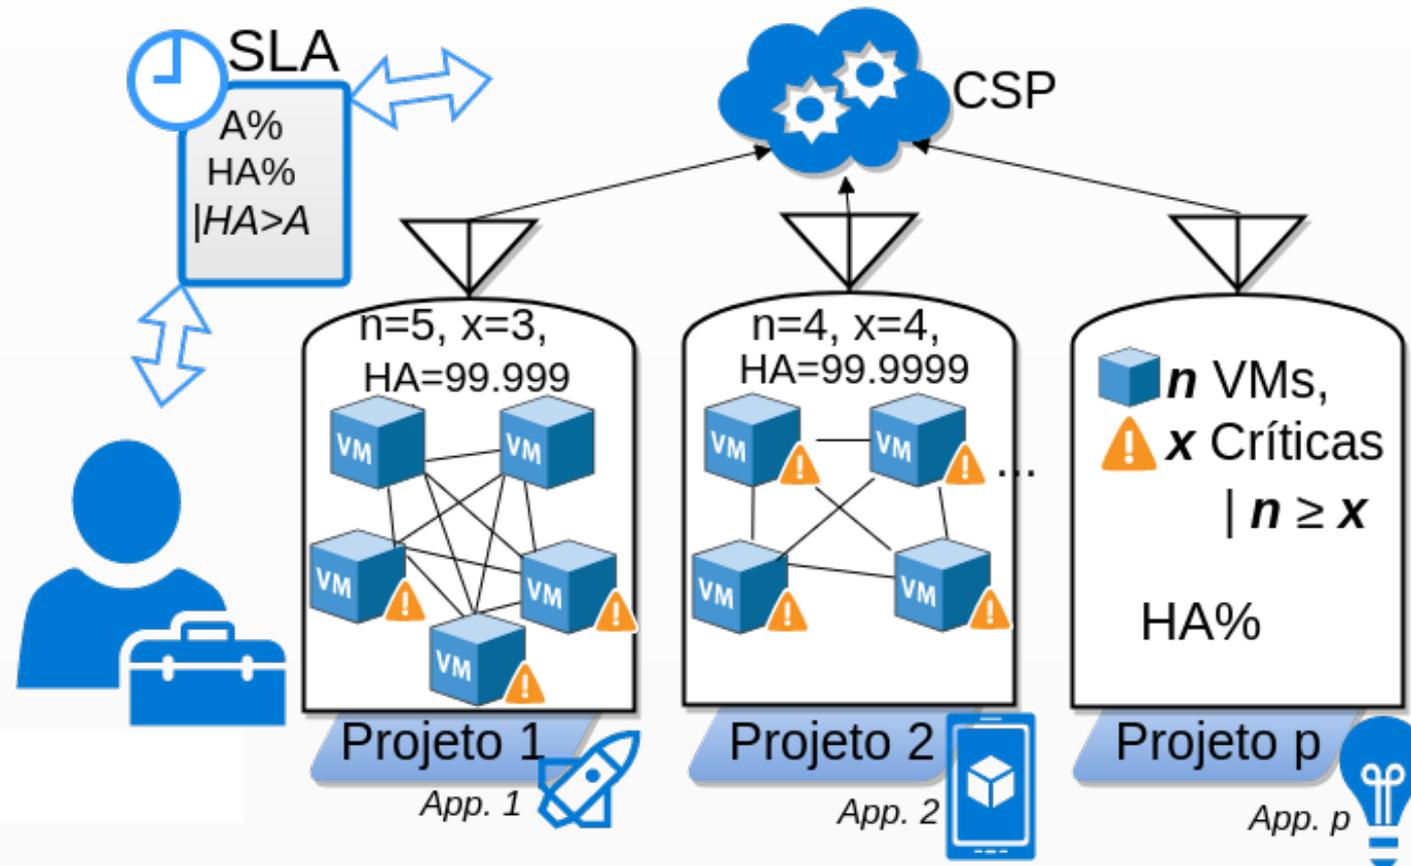


-n MVs

-x Críticas: \mathcal{V}_x^c

-Taxa HA = XX%

-Qual AZ ?

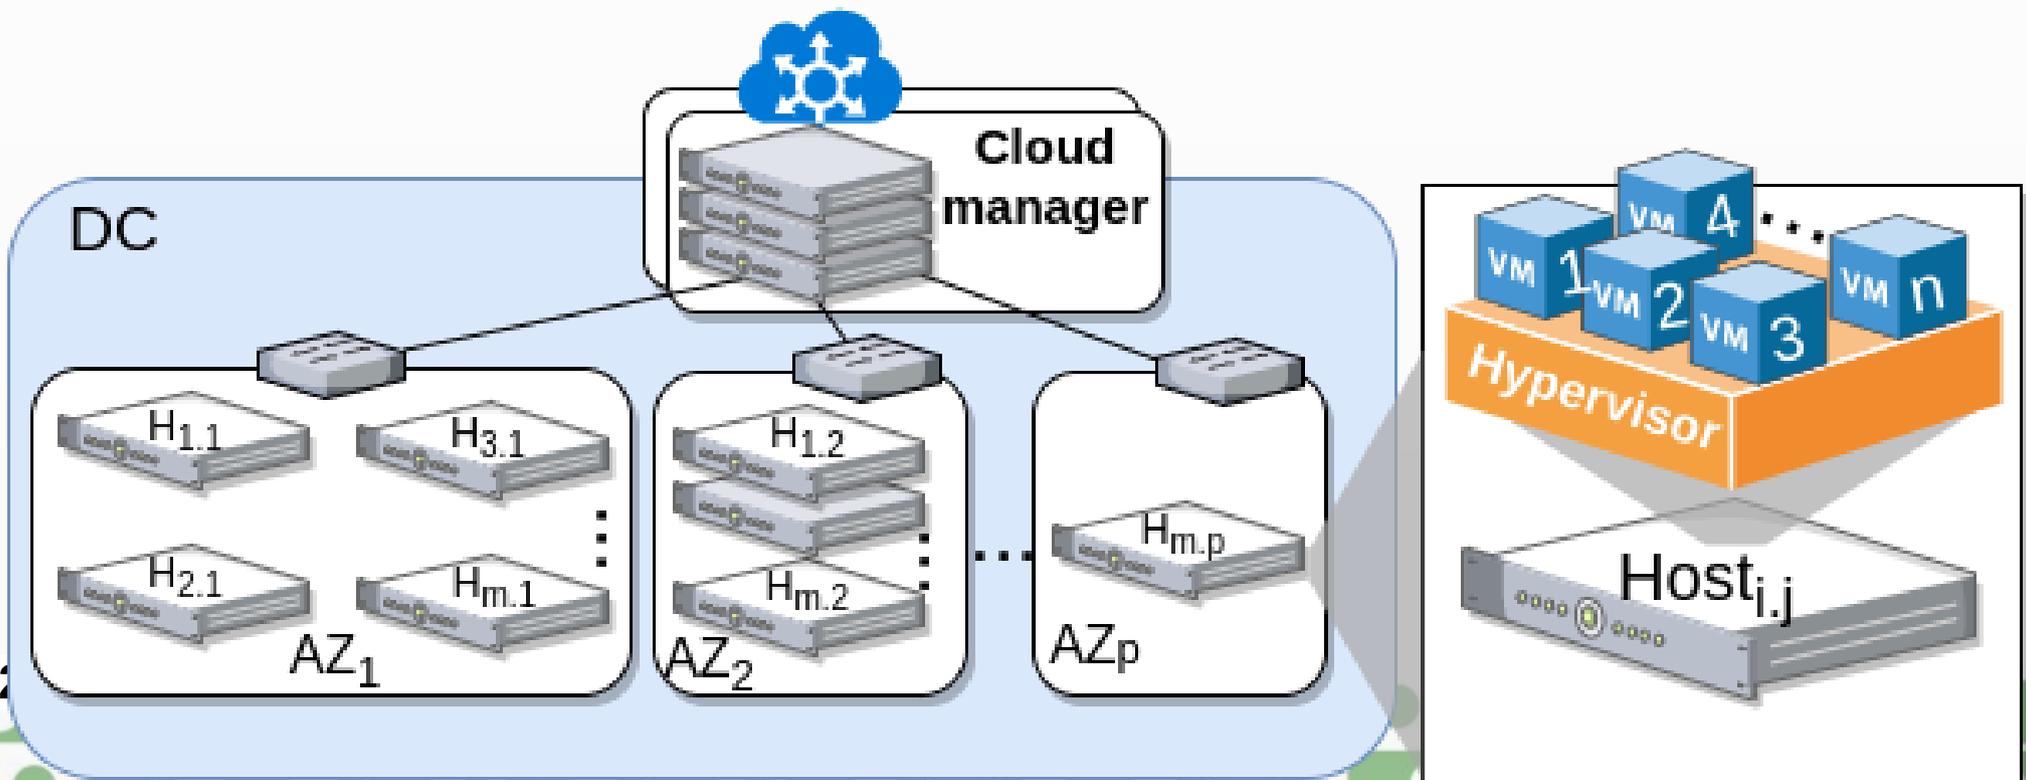


Definições Replicação

Perspectiva do provedor de nuvem



- 'n' MVs instanciadas: críticas e regulares. \mathcal{V}_{nmp}
- 'm' servidores em cada uma das AZs.
- Segurança e isolamento.

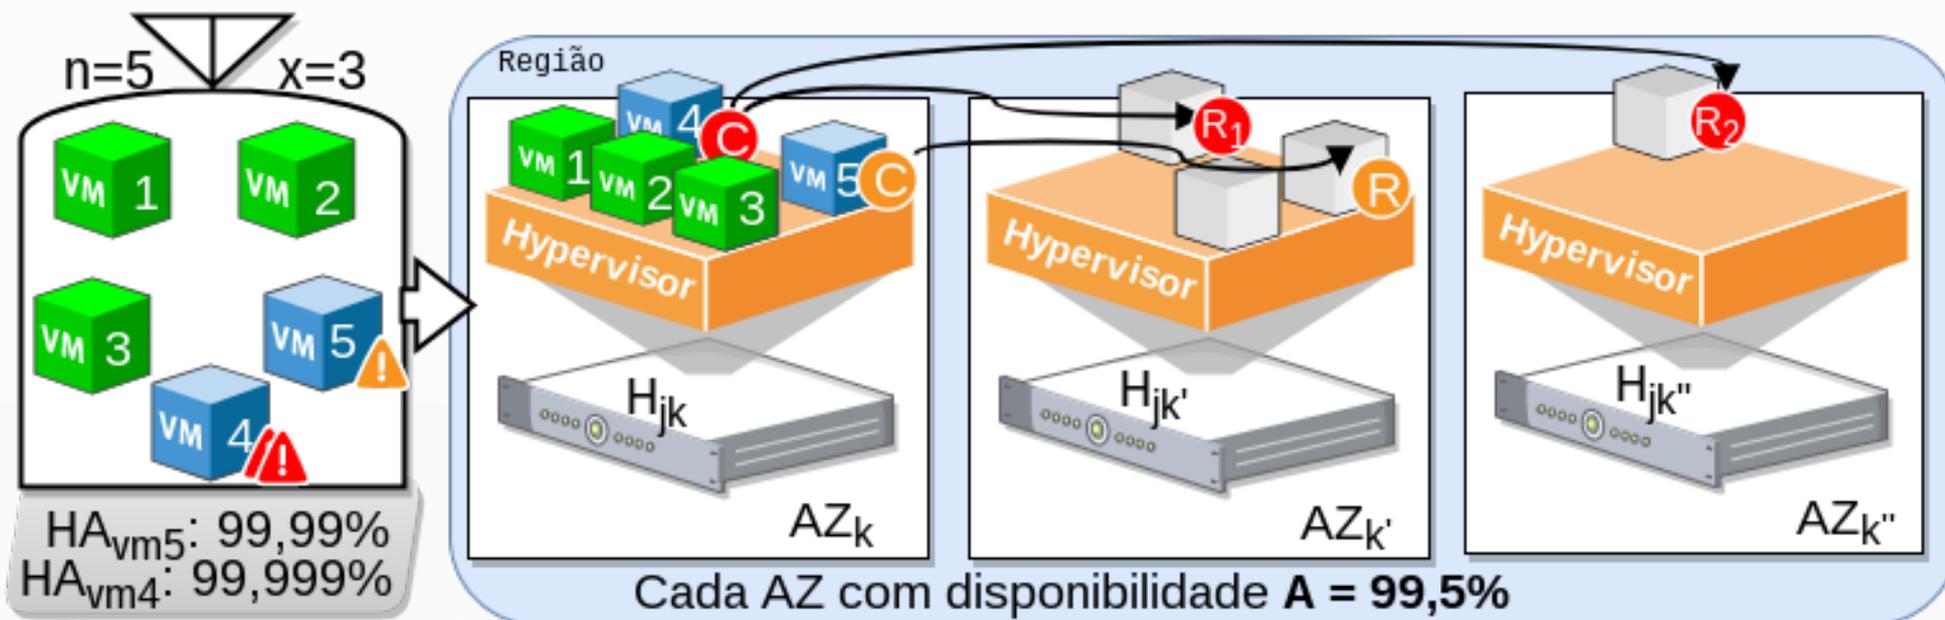


Definições Replicação

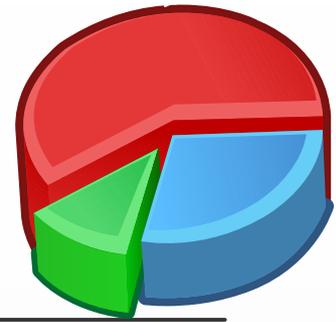


Conjunto de requisições de um mesmo desenvolvedor:

- VM5 demanda HA de **99,99%** = +1 réplica
- VM4 demanda HA de **99,999%** = +2 réplicas
- Disponibilidade regular **A = 99,5%**
- Duas MVs necessitam de três réplicas: Total 5 MVs

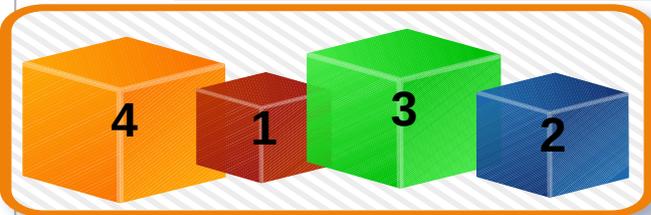
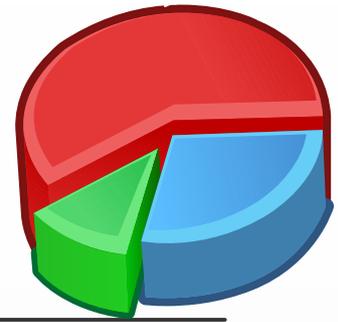


Consolidação de MVs

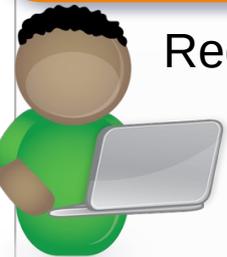


- Todas as MVs no menor número de servidores, desativando-os quando subutilizados.
- Problema do Bin-Packing (NP-Difícil).
 - Grande quantidade de requisições simultâneas inviabilizam a solução ótima por força bruta (tempo).
 - Heurísticas possibilitam obter uma solução aproximada em tempo hábil.
 - Relação entre tempo de resposta e otimalidade.
 - Algoritmo First-Fit Decreasing (FFD).
 - $FFD(L) \leq (11/9) * OPT(L) + n$

Consolidação de MVs

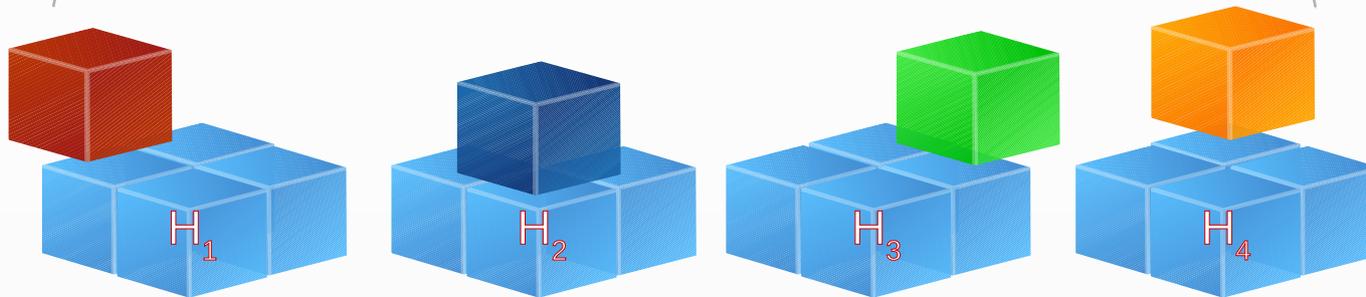


Requisições FIFO



Distribuir

- ▶ Round-Robin
- ▶ Randômico
- ▶ Guloso

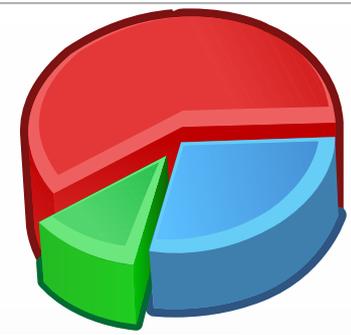


Consolidação ocorre em duas etapas independentes:

- Posicionamento inicial e Migração de MVs

Consolidação de MVs

Posicionamento inicial

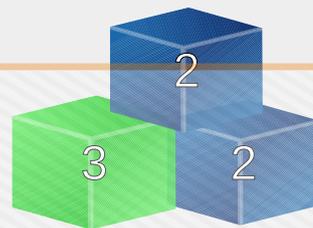
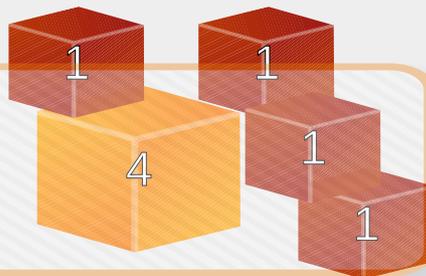


Utilizando o conceito de **janelas** com limitações de **tempo** e **tamanho**:

- Reduz a espera e complexidade.
- Abordagem *offline*

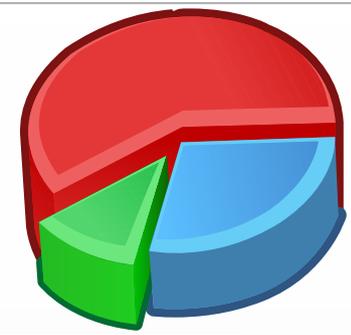
Tempo de chegada

Saída da fila



Consolidação de MVs

Posicionamento inicial

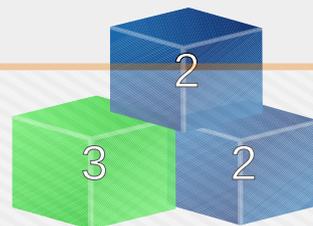
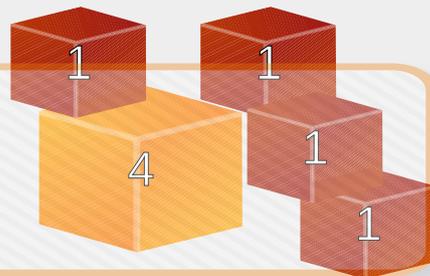


Utilizando o conceito de **janelas** com limitações de **tempo** e **tamanho**:

- Reduz a espera e complexidade.
- Abordagem *offline*

Tempo de chegada

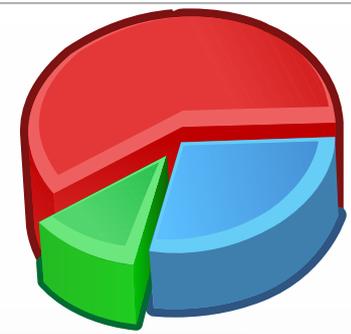
Saída da fila



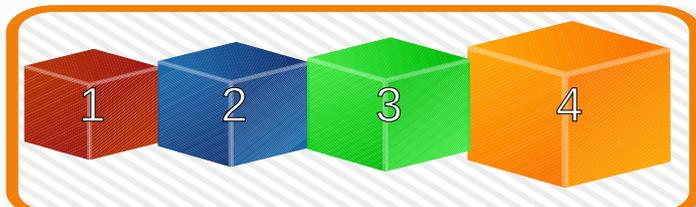
FFD()

Consolidação de MVs

Posicionamento inicial



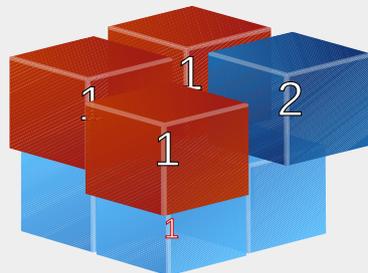
Reduzir complexidade na busca pelo melhor servidor:
- Ordenar servidores por recursos disponíveis (D).



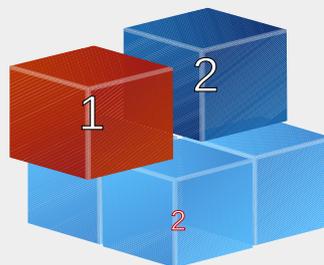
Requisições para instanciar

Ordenação dos servidores por recursos disponíveis D

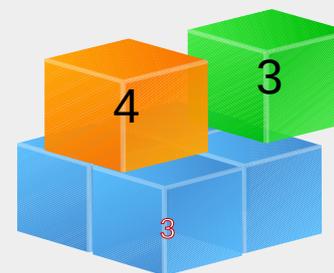

Servidores
Tamanho S=8



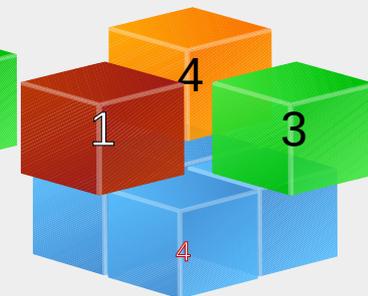
T=5,
D:3



T=3,
D:5



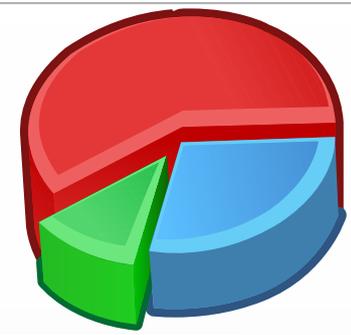
T=7,
D:1



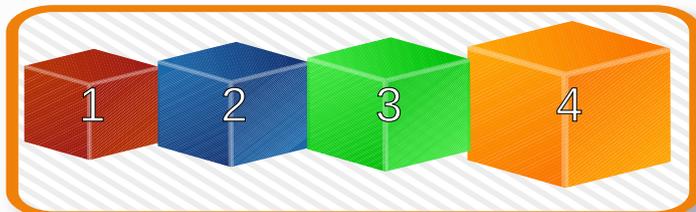
T=8,
D:0

Consolidação de MVs

Posicionamento inicial

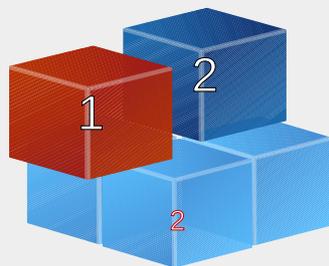


FFD Dynamic Decrasing (FF3D): Ordena **decrecente** os recursos disponíveis dos servidores

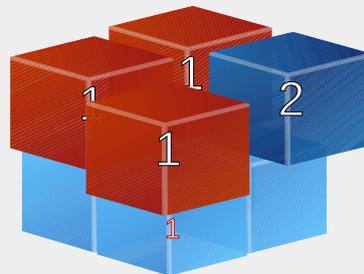


Requisições para instanciar

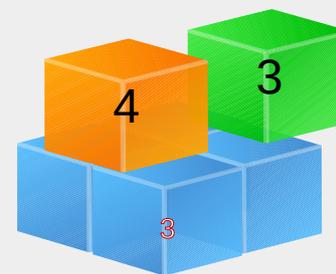
FF3D ()
S=8



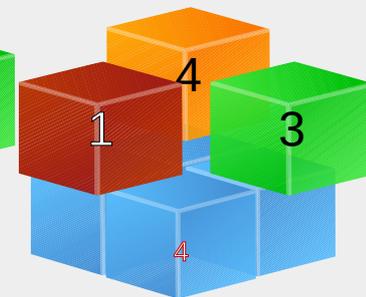
D:5



D:3



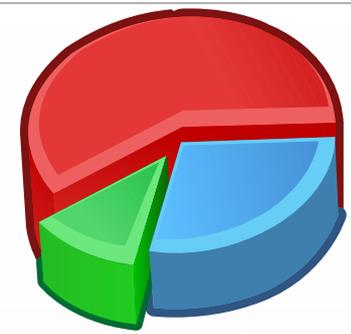
D:1



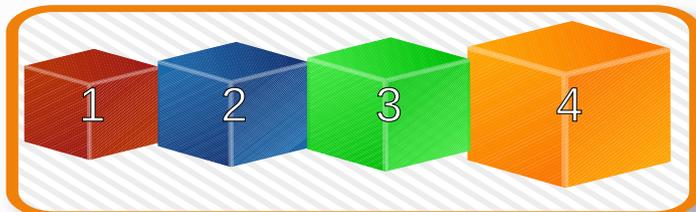
D:0

Consolidação de MVs

Posicionamento inicial

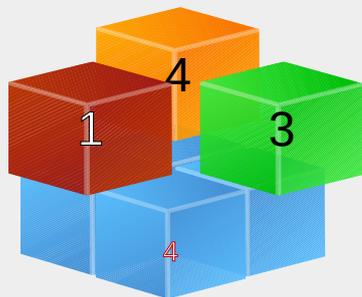


FFD Dynamic Decreasing Increasing (FF2DI): Ordena **crecente** os recursos disponíveis dos servidores

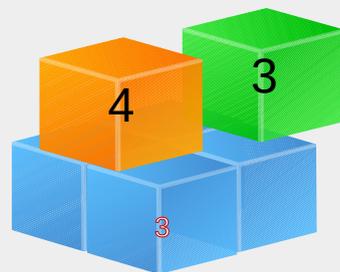


Requisições para instanciar

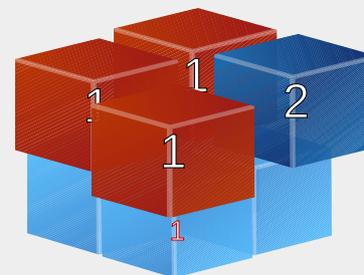
FF2DI(
S=8



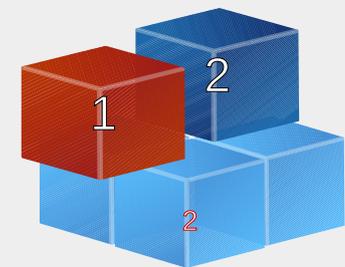
D:0



D:1



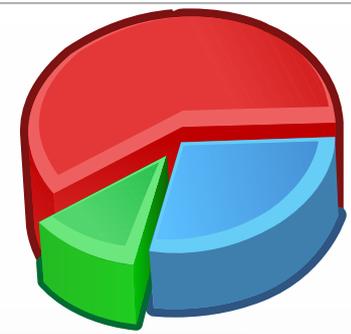
D:3



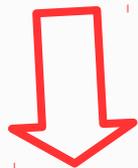
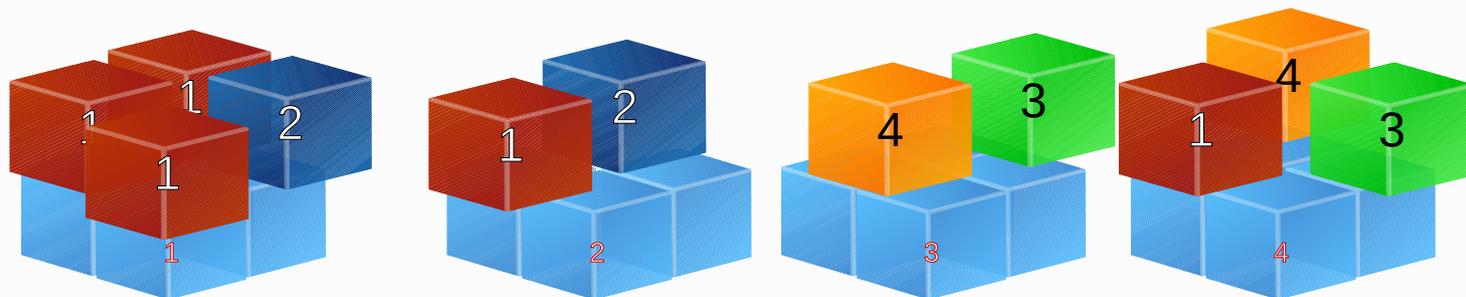
D:5

Consolidação de MVs

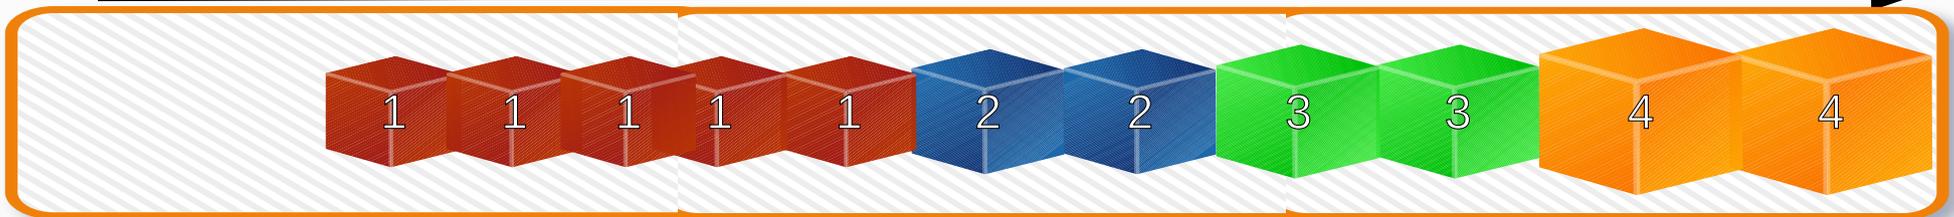
Migração de MVs



Muda as MVs após alocadas em um servidor (desativa-os).
Simula a melhor configuração e migra o necessário.

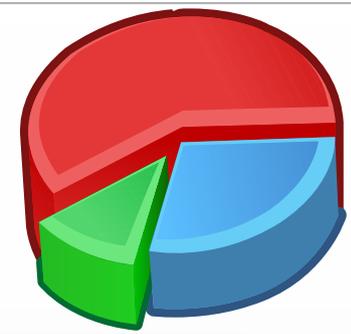


MVs para migrar



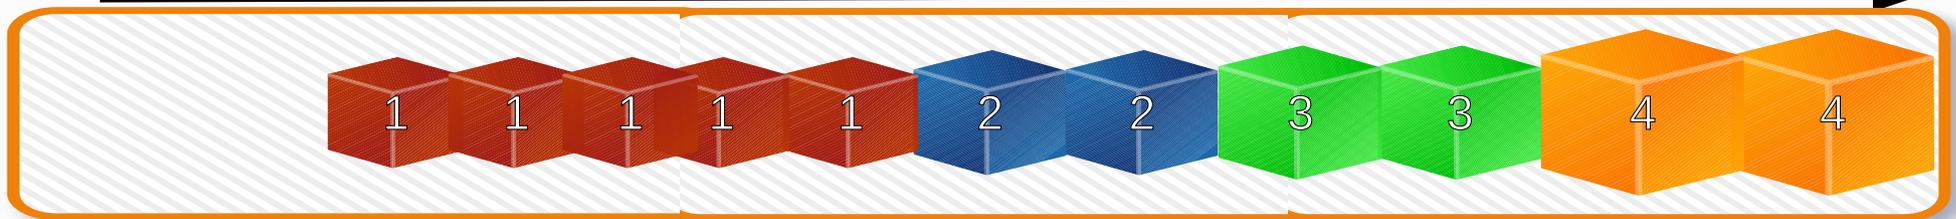
Consolidação de MVs

Migração de MVs

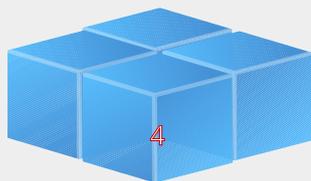


Cria-se uma lista de requisições fictícia

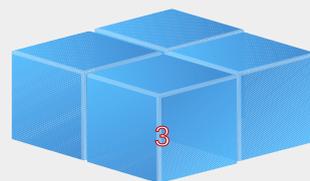
Requisições para instanciar



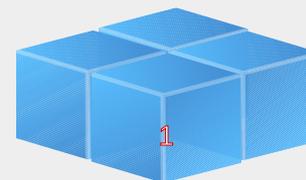
migra()
S=8



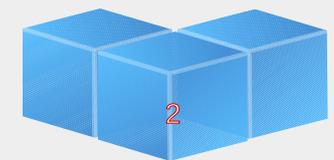
D:8



D:8



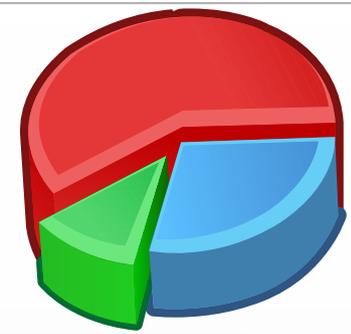
D:8



D:8

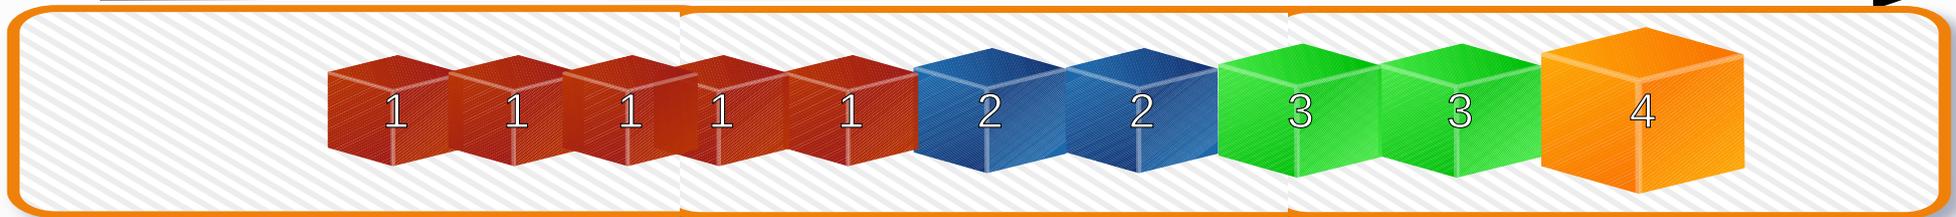
Consolidação de MVs

Migração de MVs

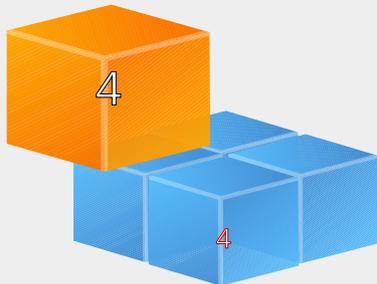


Cria-se uma lista de requisições fictícia

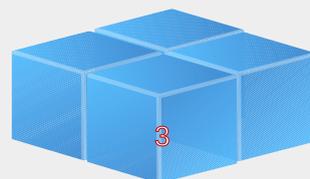
Requisições para instanciar



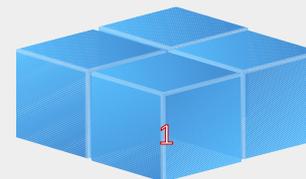
migra()
S=8



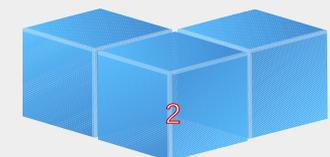
D:4



D:8



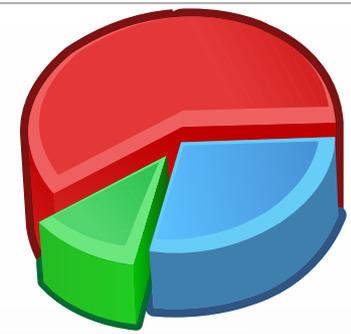
D:8



D:8

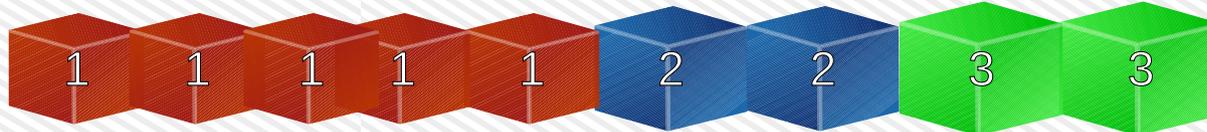
Consolidação de MVs

Migração de MVs

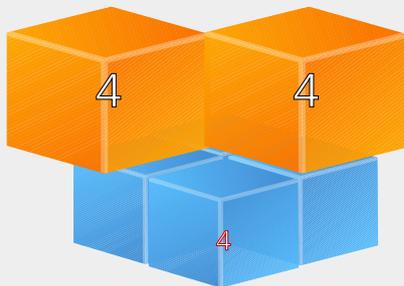


Cria-se uma lista de requisições fictícia

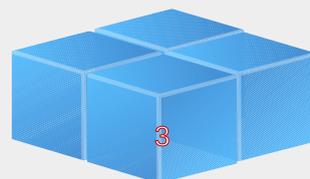
Requisições para instanciar



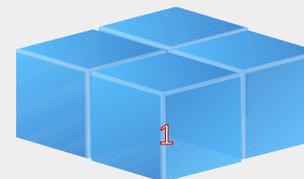
migra()
S=8



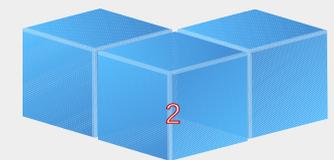
D:0



D:4



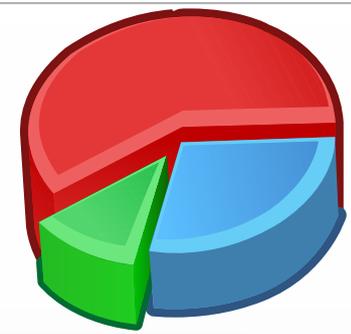
D:8



D:8

Consolidação de MVs

Migração de MVs

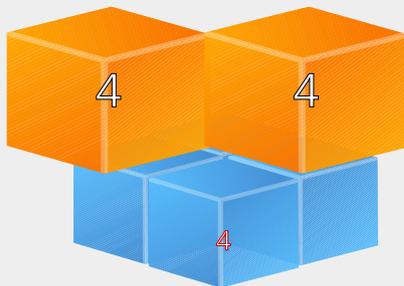


Cria-se uma lista de requisições fictícia

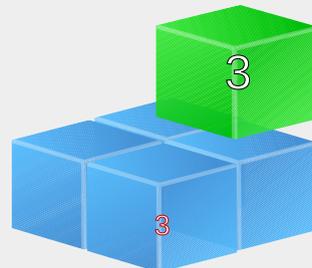
Requisições para instanciar



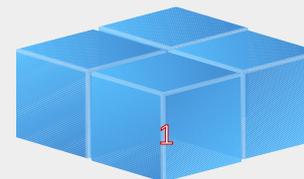
migra()
S=8



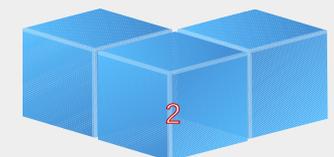
D:0



D:5



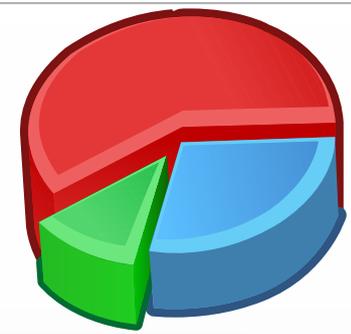
D:8



D:8

Consolidação de MVs

Migração de MVs

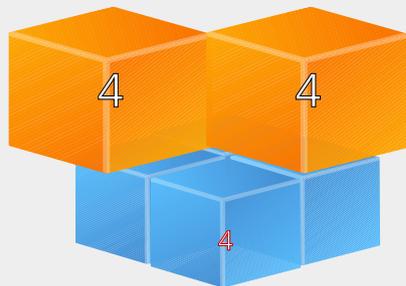


Cria-se uma lista de requisições fictícia

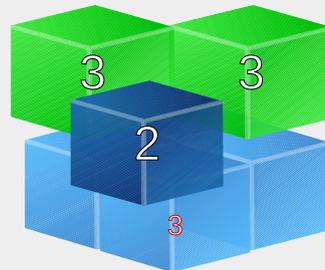
Requisições para instanciar 



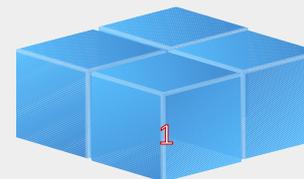
migra()
S=8



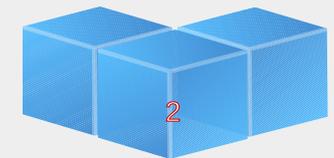
D:0



D:0



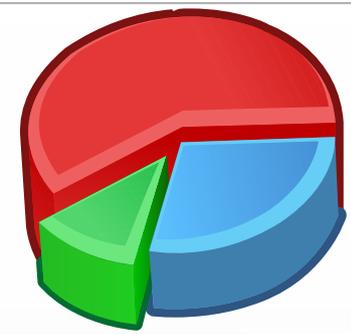
D:8



D:8

Consolidação de MVs

Migração de MVs

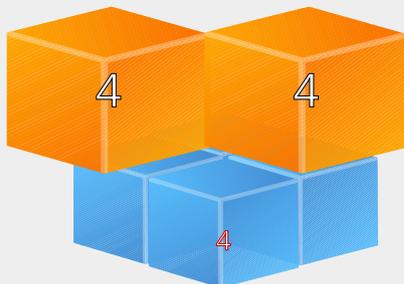


Cria-se uma lista de requisições fictícia

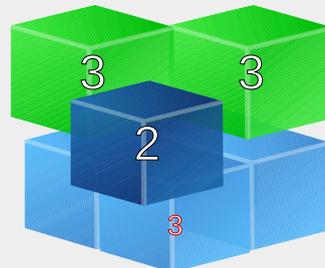
Requisições para instanciar



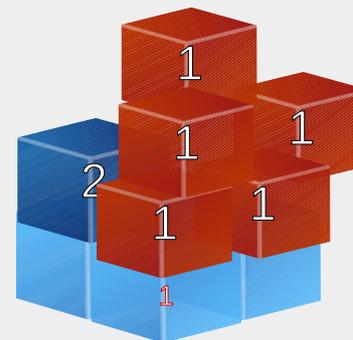
migra()
S=8



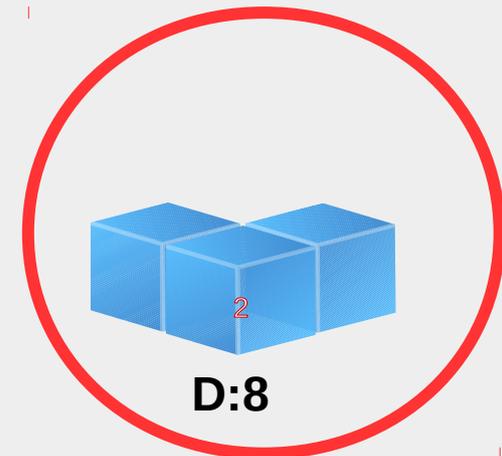
D:0



D:0



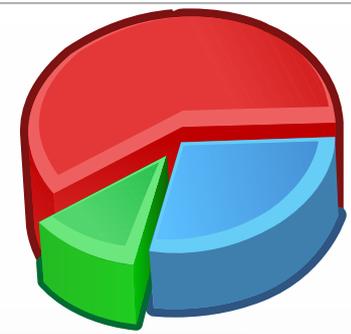
D:1



D:8

Consolidação de MVs

Migração de MVs

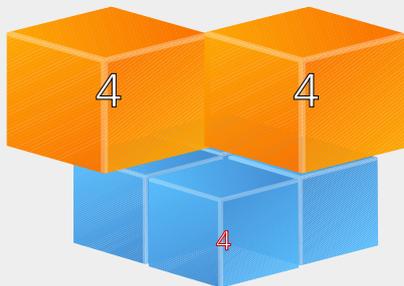


Cria-se uma lista de requisições fictícia

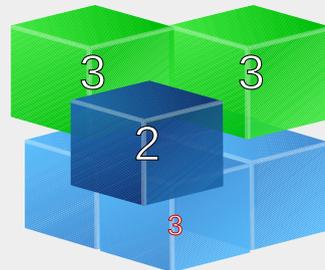
Requisições para instanciar



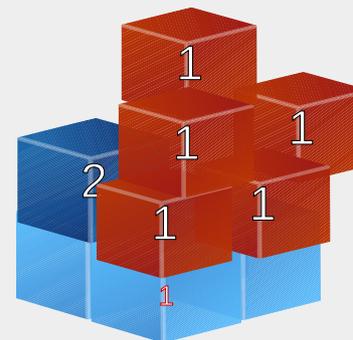
migra()
S=8



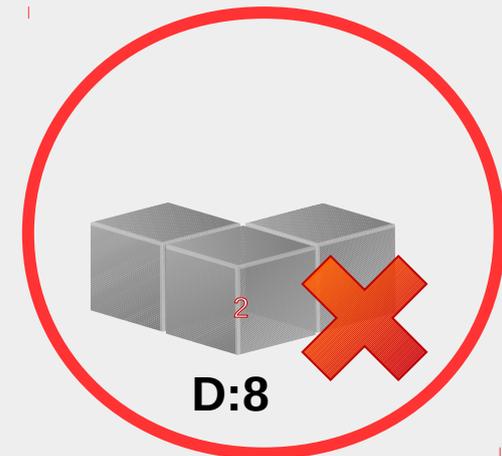
D:0



D:0



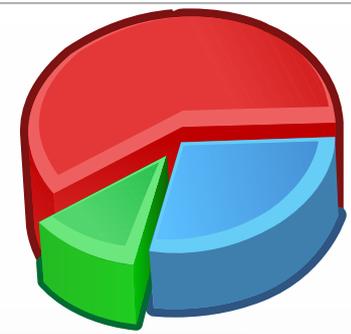
D:1



D:8

Consolidação de MVs

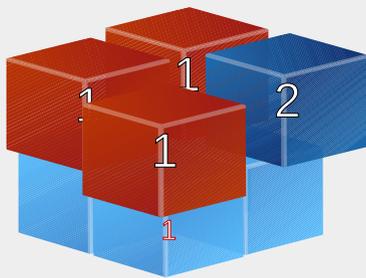
Migração de MVs



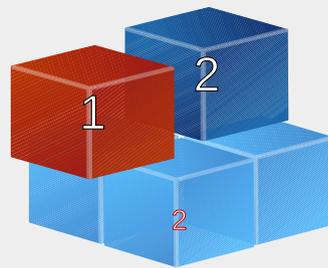
Número alto de migrações:

- Pior caso é o tamanho fila

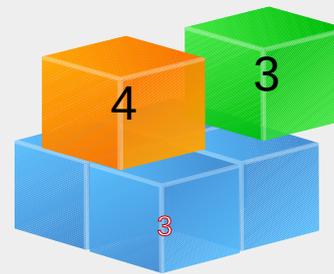
Antes



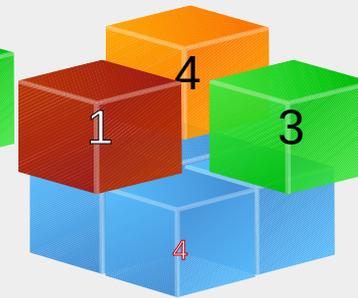
T=5,
D:3



T=3,
D:5

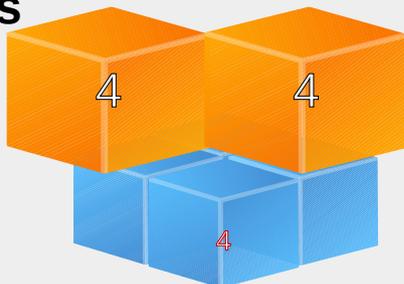


T=7,
D:1

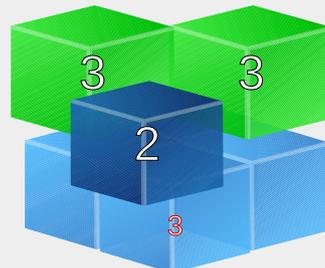


T=8,
D:0

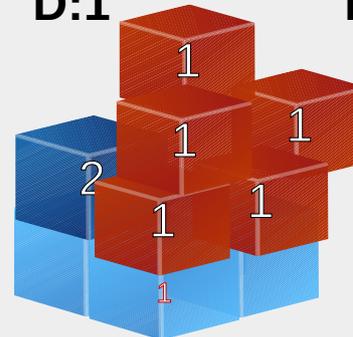
Depois



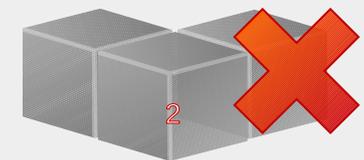
D:0



D:0



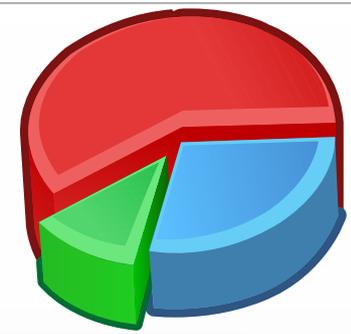
D:1



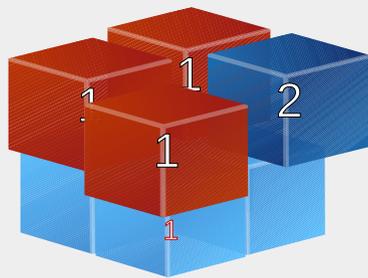
D:8

Consolidação de MVs

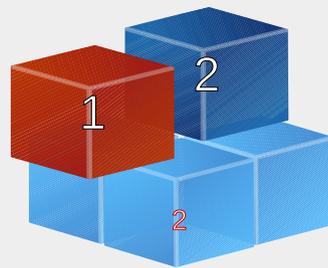
Migração de MVs



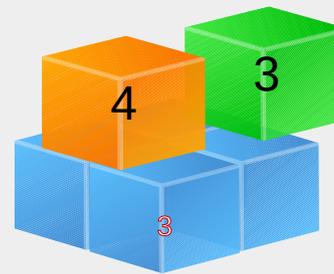
- *Minimum Migration Aware (MMA)*: Visa minimizar o número de migrações



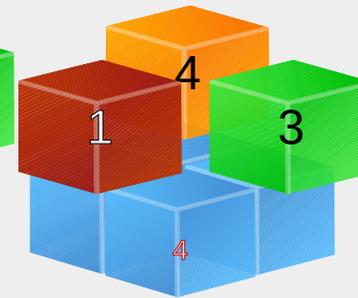
**T=5,
D:3**



**T=3,
D:5**



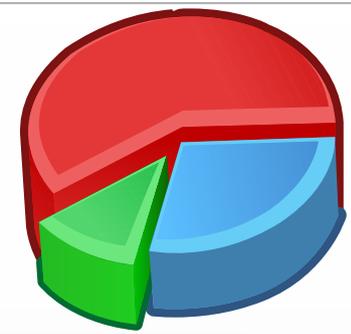
**T=7,
D:1**



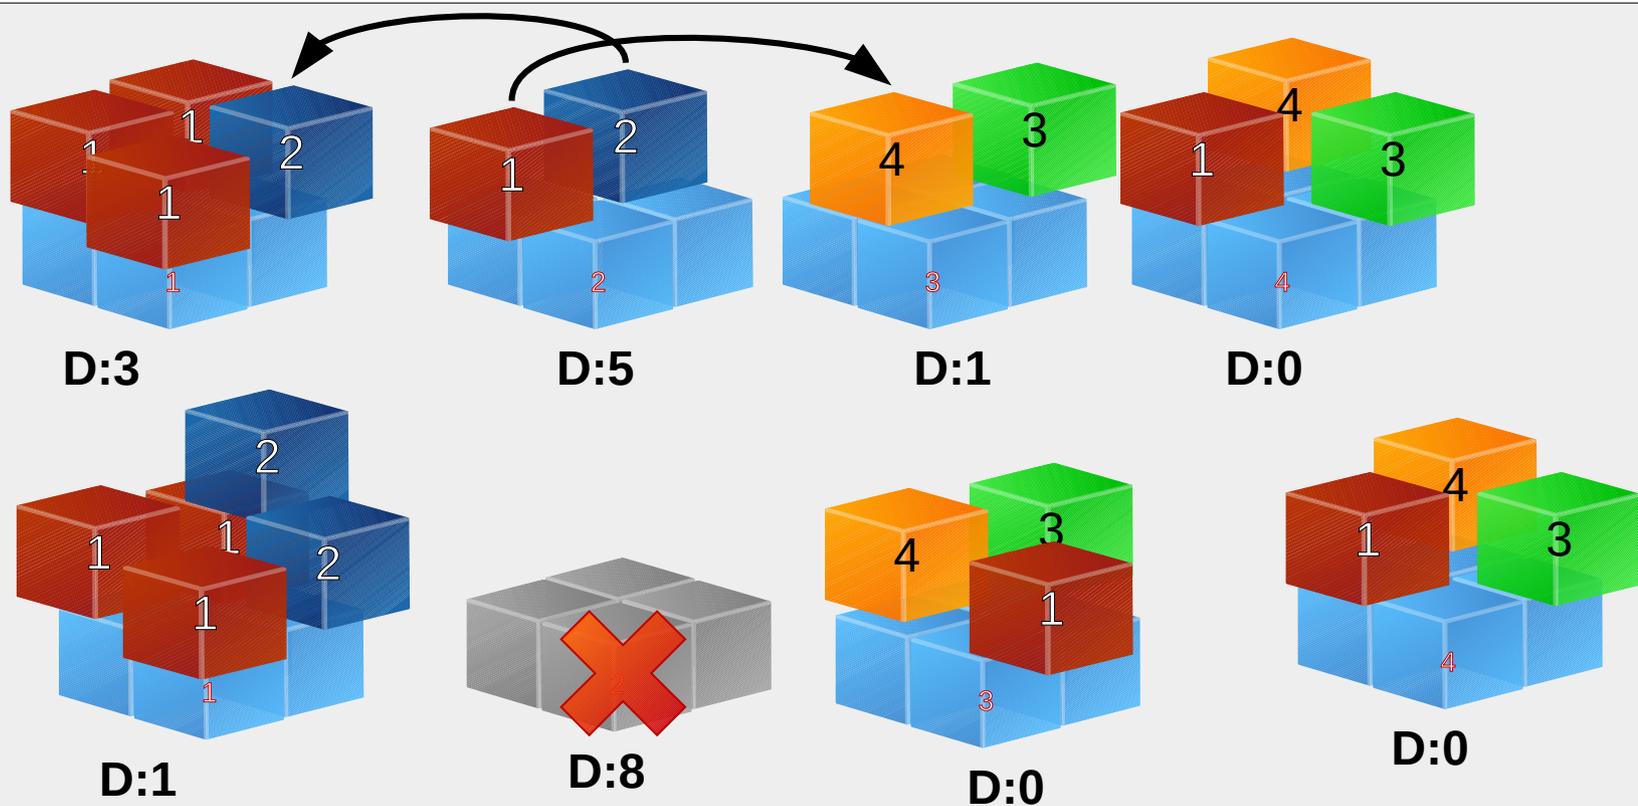
**T=8,
D:0**

Consolidação de MVs

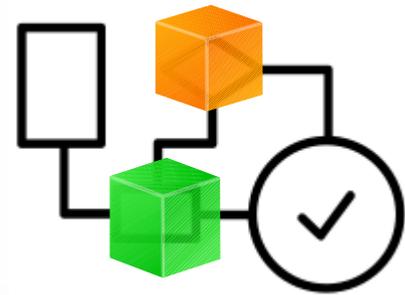
Migração de MVs



- *Minimum Migration Aware (MMA)*: Visa minimizar o número de migrações

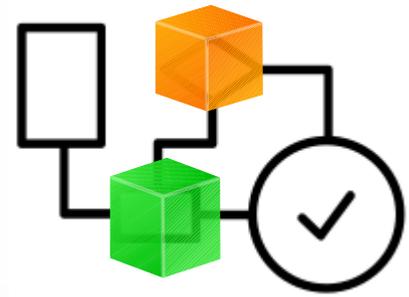


Conjunto de soluções



- Entre tantas possibilidades, qual a melhor abordagem?
 - Geral:
 - Migra antes de posicionar
 - Posiciona antes de migrar
 - Posicionamento:
 - FF3D ou FF2DI
 - Migração:
 - Total ou MMA
- Tamanho e tempo entre janelas, *overbooking*, etc

Conjunto de soluções



- Melhor combinação depende do conjunto de requisições!
 - Realiza numericamente todas as possibilidades:
 - Menor número de servidores ativos (energia).
 - No menor custo de tempo e de migrações.
- Determina-se a sequência de etapas a serem executadas pelo escalonador da nuvem.
- Solução agnóstica à plataforma de computação em nuvem.
 - Ações por meio de API.



Estudo de caso

Estudo de caso



- Realizado no simulador EAVIRA (Ruck, 2017):
 - Linguagem Python
 - Alterações de infraestruturas virtuais para MVs.
- Executadas em uma instância na AWS, Ubuntu 16.04 com 4 vCPU e 30 GB RAM (memória otimizada).
- Resultados apresentados com base em *traces* do Eucalyptus.

Estudo de caso



- *Traces* reais de uma nuvem privada IaaS.
- Plataforma Eucalyptus (Wolski e Brevik, 2014).
 - 6 AZs, de 7 a 31 servidores de 8 a 32 núcleos cada
 - Mínimo de 1,8k até 18k operações:
 - < START / STOP >
 - Entre 33 e 279 dias de *trace*.
 - *Escalonamento: Greedy e Round-Robin*
 - Adicionada funcionalidades de overbooking (200%)

Plano de testes

Seleção das estratégias

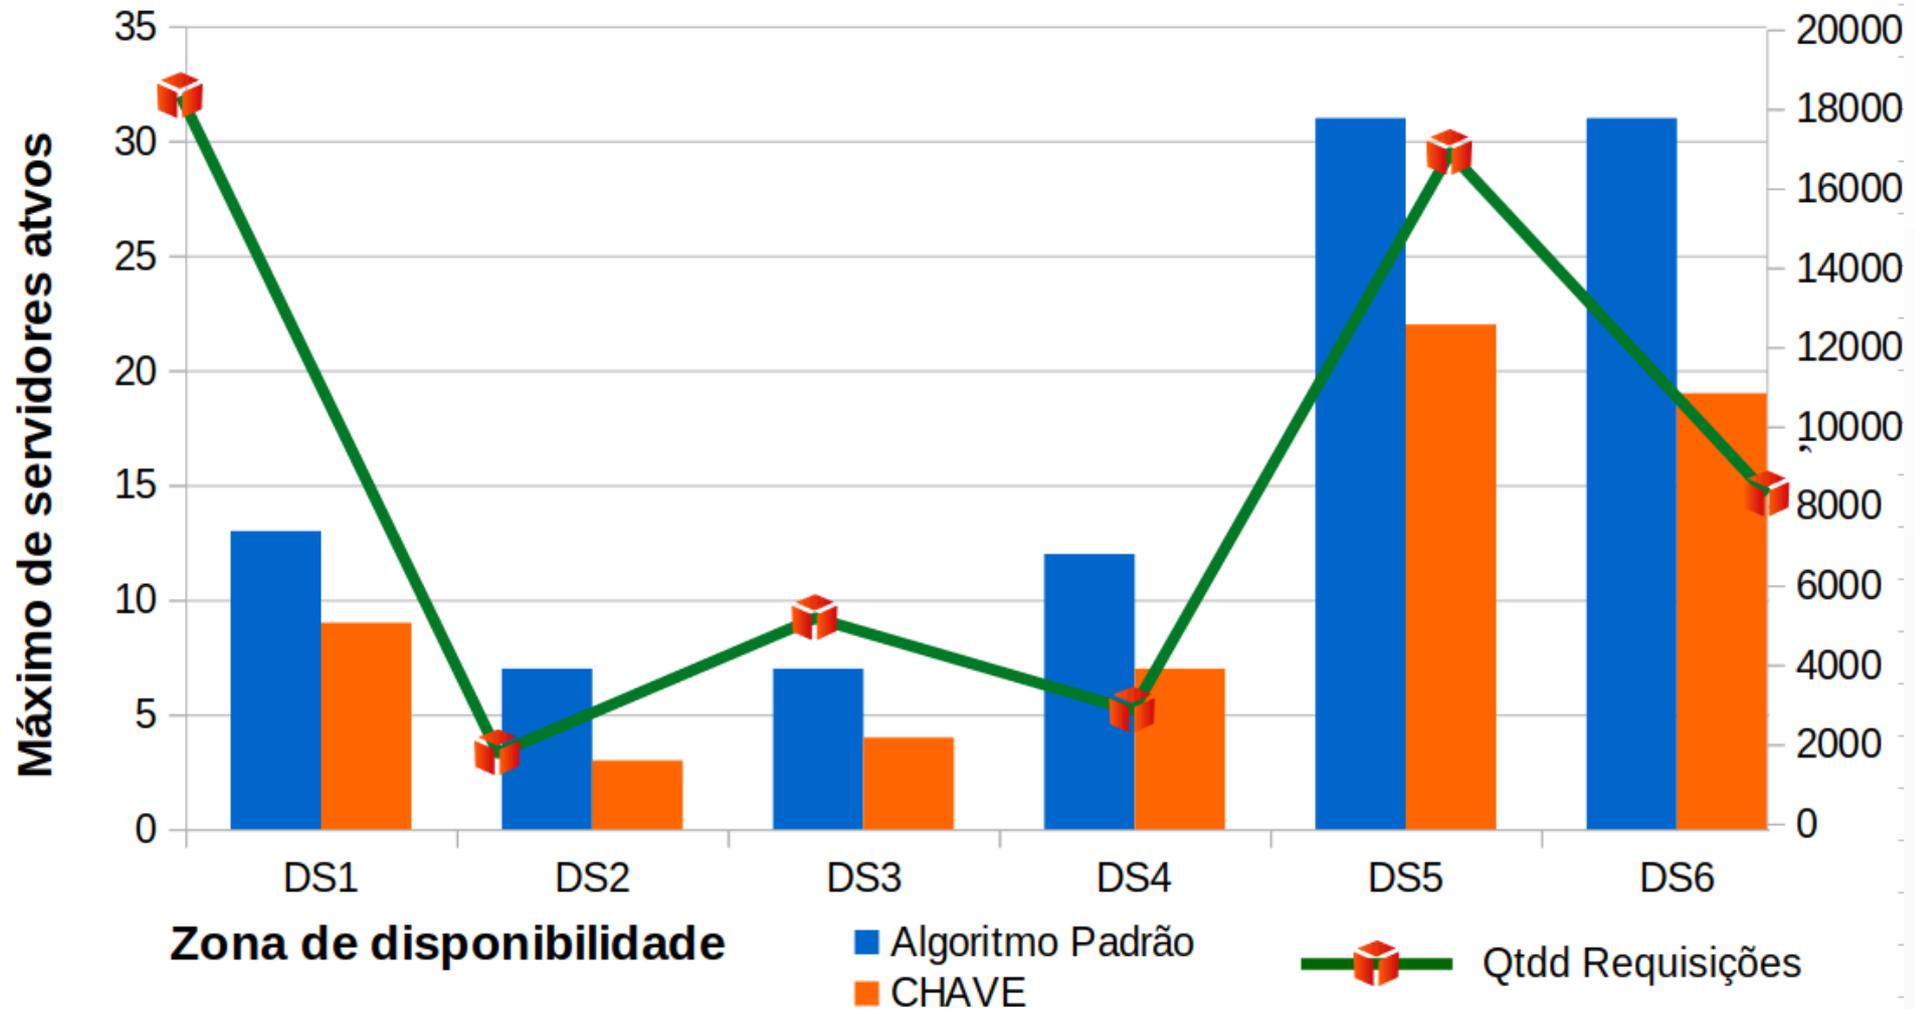


Estratégia	Posiciona-migra	migra-posiciona	FF2DI	FF3D
E_0	<i>Sem consolidação</i>			
E_1	✓		✓	
E_2	✓		✓	
E_3	✓			✓
E_4	✓			✓
E_5		✓	✓	
E_6		✓	✓	
E_7		✓		✓
E_8		✓		✓

Plano de testes

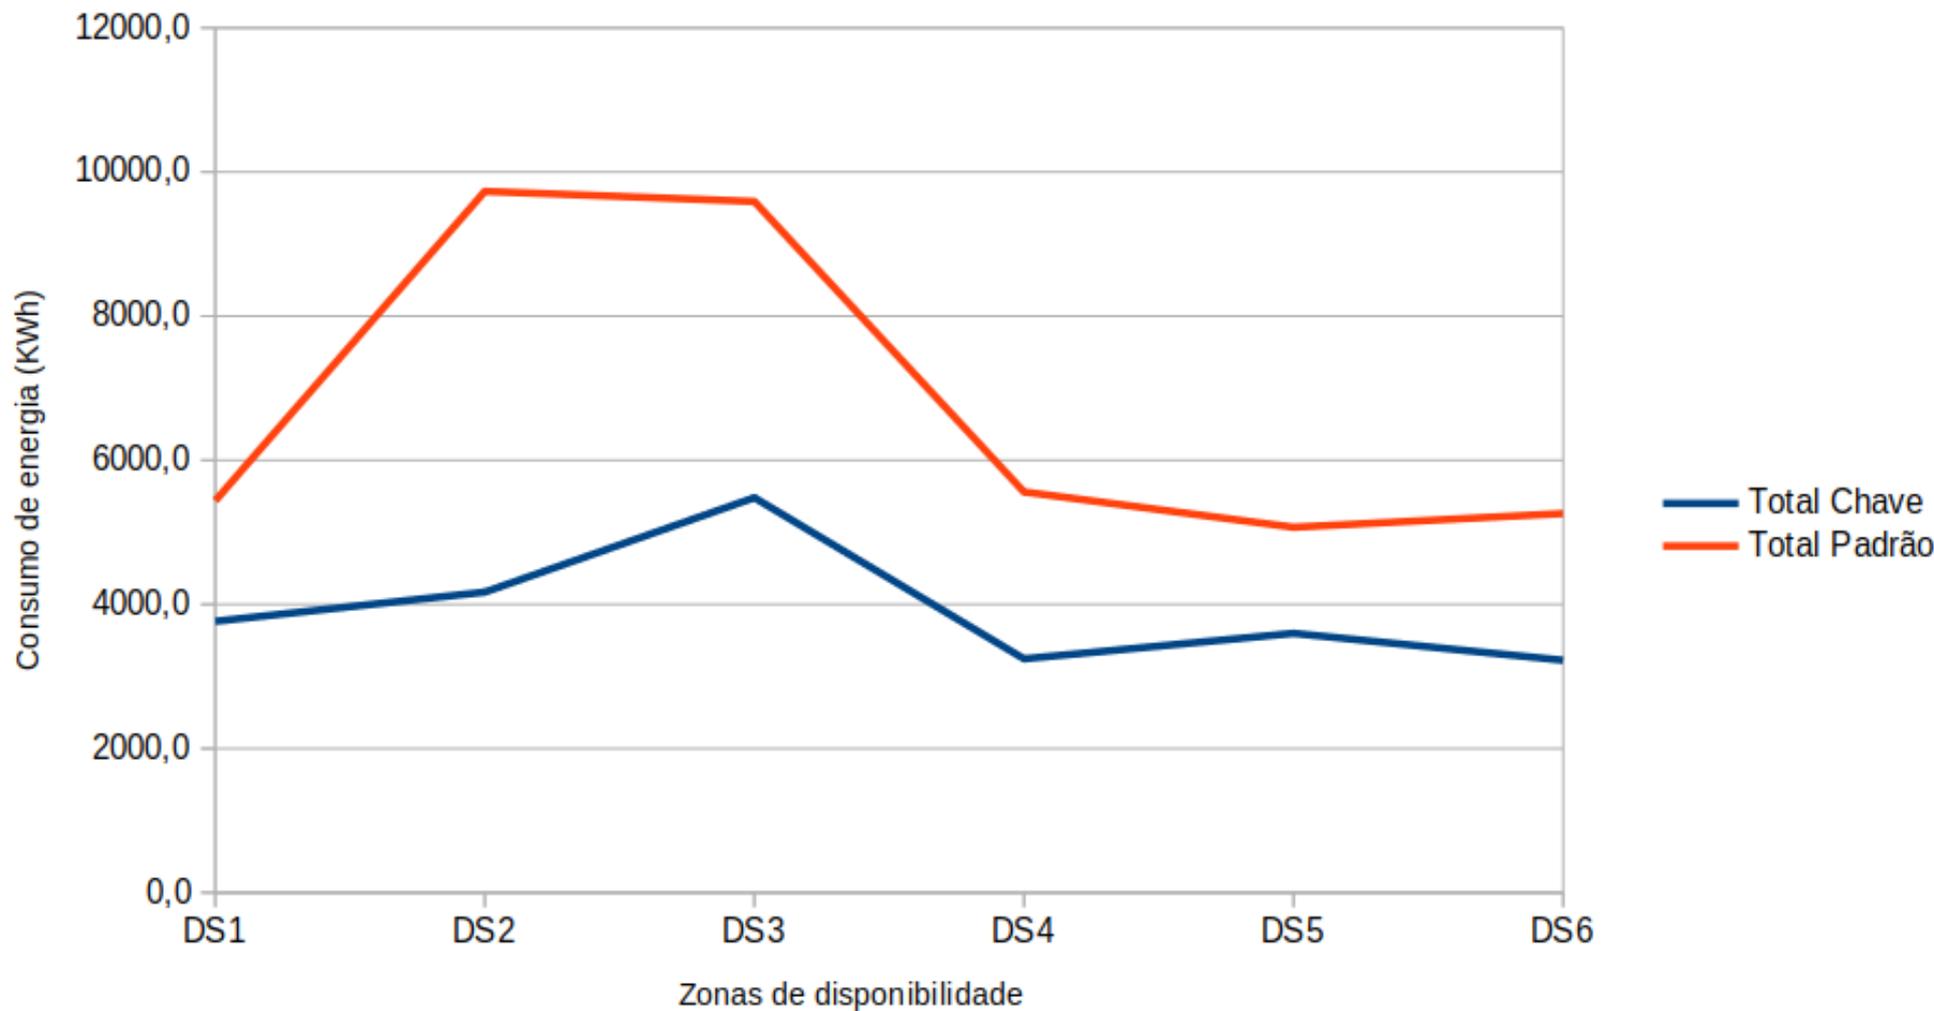
- Tamanho das janelas: 1% do conjunto de requisições.
- Tempo entre janelas: de 20 a 200 segundos.
- Para cada algoritmo: CHAVE e padrão do Eucalyptus:
 - O maior número de servidores ativados ao mesmo tempo? (Pior caso)
 - Consumo de energia total para o período de execução?
 - Relação final de eficiência?
 - Quantas réplicas é possível instanciar com o CHAVE, mantendo o mesmo consumo de energia dos algoritmos padrão do Eucalyptus?

Resultados: Quantidade de servidores



38,7% desativados

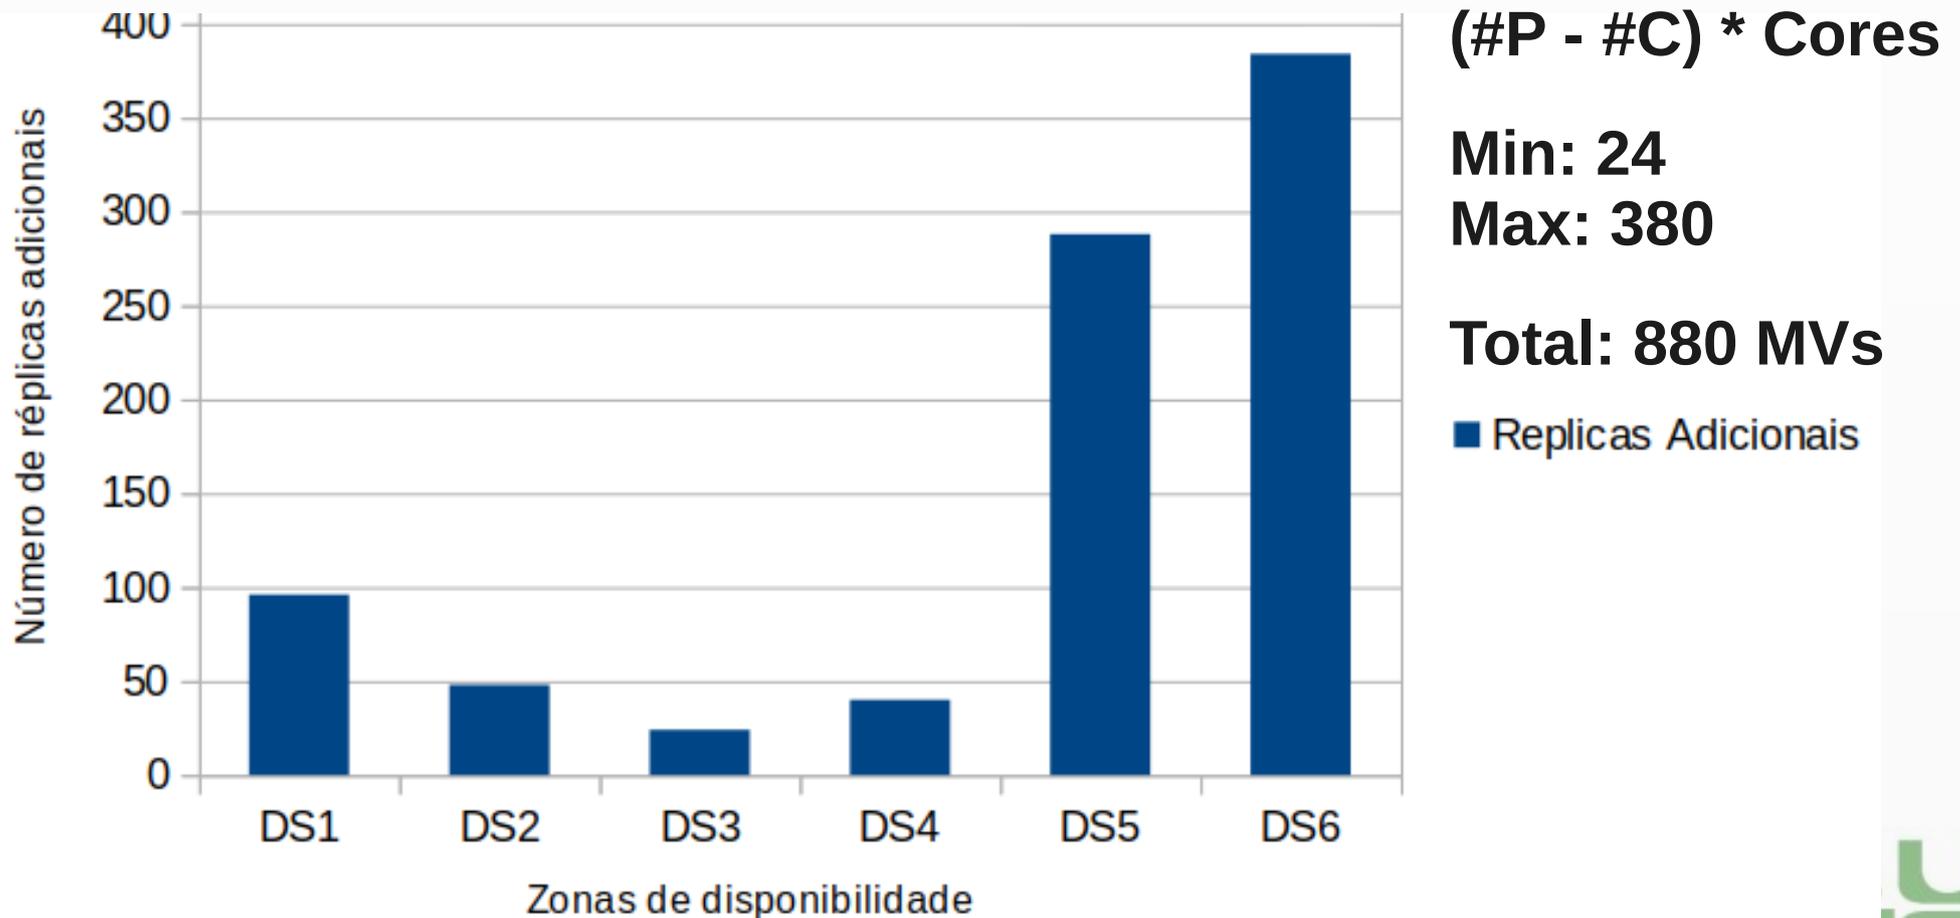
Resultados: Consumo de energia



Eficiência final de 42,2%

Resultados: Réplicas adicionais

- Quantas réplicas adicionais poderíamos adicionar em cada AZ para manter o mesmo consumo de energia?



Discussão dos resultados



- Foi possível reduzir a quantidade de servidores em média de 40% no pior caso de consolidação
- Obtida uma eficiência energética de 42,2% no total, apenas com a consolidação.
- Ao realizar a replicação, para manter o mesmo consumo de energia poderiam ser replicadas até 880 MVs críticas no total, com uma réplica cada.
- As melhores configurações entre seleção de estratégias de algoritmos foram varias, pois depende das requisiões.

Considerações gerais



- A presente solução objetiva a fornecer alta disponibilidade sob demanda utilizando a consolidação de MVs para reduzir o impacto causado pelo consumo de energia.
- Trabalhos relacionados indicam oportunidades na área de pesquisa. Poucas soluções que unem HA e consolidação.
- Devido a complexidade de implementar a solução em um ambiente real, é utilizada a simulação, mas o objetivo final é aplicar o CHAVE em um estudo de caso em ambiente real OpenStack.

Próximos passos



-
- Realização de mais testes considerando todas as possibilidades levantadas.
 - Gerar *traces* aleatórios, distribuições variadas.
 - Outros *traces* reais.
 - Implementar a consolidação em ambiente real OpenStack.
 - Adequar o simulador para ser utilizado em outras pesquisas
 - Documentação, didática, entrada e saída de dados, etc.

Publicação de Artigos



- Publicados:
 - Daniel Camargo, Maurício Pillon, Charles Miers, Guilherme Koslowski “***MeHarCEn: Método de Harmonização do Consumo de Energia em Data Centers***”, RBCA 2017.
 - Durante a graduação: Consumo de energia em DCs.
- Em submissão:
 - Daniel Camargo, Maurício Pillon, Charles Miers, Guilherme Koslowski, _____. “***CHAVE: Consolidation with High-Availability on Virtualized Environments***”, SBRC 2018.



CHAVE: Consolidation with High-Availability on Virtualized Environments

Daniel Scheidemantel Camargo

daniel@colmeia.udesc.br

