

# Utilizando a computação paralela para alavancar a pesquisa científica no IFPB

Paulo Ditarso Maciel Jr. <sup>[1]</sup>, Thiago Gouveia da Silva <sup>[2]</sup>, Thomas Ribeiro Rodrigues <sup>[3]</sup>

[1] paulo.maciel@ifpb.edu.br. Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, Unidade Acadêmica de Informática – Grupo de Pesquisa em Computação Distribuída. Av. 1o de Maio, 720 – Jaguaribe – João Pessoa/PB – CEP: 58015-430 ; [2] thiago.gouveia@ifpb.edu.br ; [3] thomas.ribeiro2392@gmail.com

## RESUMO

A computação paralela vem sendo amplamente utilizada como ferramenta para acelerar o processo de obtenção de resultados em pesquisas experimentais. Neste artigo apresentamos o sistema *OurGrid*, que é uma grade computacional peer-to-peer (P2P) e oferece um ambiente de computação paralela apropriado para a realização de experimentos científicos. O sistema serve como ferramenta útil para realização de simulações científicas, possibilitando acelerar o processo de obtenção dos resultados. Descrevemos um caso de uso onde o sistema foi utilizado para resolver um problema de otimização na alocação de antenas de comunicação sem fio no estado da Paraíba. Pelos resultados obtidos podemos concluir que a ferramenta é realmente eficaz, acelerando a obtenção dos resultados em um fator de aproximadamente 30 vezes. O nosso principal objetivo é difundir esta ferramenta para que a mesma possa ser utilizada em diferentes áreas do conhecimento (Engenharia Elétrica, Química, Mineração etc.) e que isso possa alavancar a pesquisa científica nos Institutos Federais em todo o país.

**Palavras-chave:** computação paralela, grades computacionais, pesquisa experimental.

## ABSTRACT

*Parallel computing has been widely used as useful tool in order to speedup the process of obtaining results in experimental research. In this article, we present the OurGrid system which is peer-to-peer grid computing and offers a parallel computing environment suitable for executing scientific experiments. The system works a powerful tool to run scientific simulations, allowing speedup the process of getting the results. We describe a use case example in which the system was used to solve an optimization problem of allocating wireless network antennas across the state of Paraíba. From the obtained results we can conclude that the system is really effective, speeding up the process in approximately 30-times. Our main purpose is to disseminate the OurGrid in a way it can be used in different areas (Electrical Engineering, Chemistry, Mining, etc.), and that it might increase the scientific research at the Federal Institutes across the country.*

**Keywords:** *parallel computing, grid computing, experimental research.*

## 1 Introdução

Computação paralela é uma forma de processamento onde diversas tarefas computacionais são realizadas simultaneamente. A principal ideia por trás da computação paralela é que grandes problemas computacionais podem ser divididos em problemas menores, e estes problemas menores podem ser resolvidos (ou processados) de forma concorrente. Desta forma, experimentos científicos que demandam um alto poder computacional podem utilizar alguma solução de computação paralela, com o objetivo de agilizar o processamento e obter os resultados de uma forma mais rápida e eficiente (HENNESSY e PATTERSON, 2002). Existem hoje diversas soluções de computação paralela que podem ser aplicadas em diferentes contextos do meio acadêmico de pesquisa. Uma solução de particular interesse é a utilização de grades computacionais do tipo *peer-to-peer* (P2P) (CIRNE, BRASILEIRO, et al. 2006), uma vez que o custo desta utilização é muito pequeno em relação a outras soluções como, por exemplo, a aquisição de equipamentos especializados tais como clusters ou supercomputadores.

A computação através de grades computacionais surgiu como uma forma de agregar grandes volumes de recursos pertencentes a diferentes domínios administrativos, para a realização de tarefas comuns (FOSTER e KESSELMAN, 1999). Contudo, boa parte das grades computacionais existentes necessita de intervenção humana para a negociação dos recursos disponíveis, o que limita a escalabilidade destes sistemas. Por outro lado, grades computacionais P2P apresentam uma alternativa para construção de sistemas de grade em larga escala, onde os participantes devem receber algum tipo de incentivo para disponibilizar seus recursos.

Por exemplo, o sistema *OurGrid* ([www.OurGrid.org](http://www.OurGrid.org)), desenvolvido na Universidade Federal de Campina Grande em colaboração com a HP R&D Brazil, é uma grade computacional P2P focada em aplicações *Bag-of-Tasks* (aplicações paralelas cujas tarefas são independentes uma das outras) e que está em produção desde 2004, onde o comportamento colaborativo entre os pares no sistema define quem (ou qual par) será priorizado na alocação das tarefas.

Dentro desse contexto, vislumbramos que, num futuro próximo, diversas infraestruturas de TI voltadas à comunidade científica serão formadas por uma mistura de poder computacional provido por recursos

locais dedicados e provedores externos de computação utilitária, tais como computação na nuvem e grades computacionais. Além disso, cada uma destas abordagens proverá diferentes garantias, desde aquelas com requisitos bem definidos de qualidade de serviço, às baseadas no modelo “melhor esforço”. Conjectura esta suportada por nossa própria experiência com o *middleware OurGrid*, que tem sido utilizado como ferramenta de suporte em diversas áreas de pesquisa, da Engenharia à Bioinformática, da Ciência da Computação às aplicações financeiras (ARAUJO, CIRNE *et al.*, 2005; WILTER, OSTHOFF *et al.*, 2005; DUARTE, CIRNE, BRASILEIRO, MACHADO, 2006; OSTHOFF, OLIVEIRA, *et al.*, 2003).

O principal objetivo deste artigo é demonstrar como uma grade computacional P2P pode alavancar a pesquisa científica em Institutos Federais de Educação, Ciência e Tecnologia, através de uma plataforma computacional de alto desempenho e baixo custo. Para isto, apresentamos um caso de uso do sistema *OurGrid* em uma pesquisa realizada no Instituto Federal da Paraíba (IFPB), envolvendo um problema de otimização na alocação de antenas para redes de comunicação sem fio. Mais especificamente, apresentamos indícios de como o *OurGrid* pode “acelerar” o processo de pesquisa e a obtenção de resultados, possibilitando um aumento na produção científica em diversas áreas do conhecimento.

O restante deste documento está dividido como segue: a Seção 2 apresenta uma descrição do sistema *OurGrid* através dos seus principais componentes; a Seção 3 descreve um caso de uso da utilização da ferramenta, através de um problema de otimização na alocação de antenas para redes sem fio no estado da Paraíba, além disso, apresenta uma análise quantitativa com o intuito de demonstrar como o sistema *OurGrid* pode acelerar a obtenção de resultados em uma pesquisa científica; por fim, a Seção 5 apresenta conclusões e outras perspectivas de utilização do sistema.

## 2 Descrição do Sistema

O *OurGrid* é uma ferramenta de código aberto e seu desenvolvimento é realizado em linguagem de programação Java e scripts Shell. Como mencionado anteriormente, é uma ferramenta adequada para execução de aplicações do tipo *Bag-of-Tasks* (onde não existe comunicação entre as tarefas e a execução pode ocorrer em paralelo).


O *OurGrid* busca não interferir no desempenho da máquina, uma vez que utiliza apenas recursos ociosos dos computadores que formam o sistema, e, além disso, implementa um sistema de incentivo para estimular a cooperação entre os “pares” no sistema, priorizando os que mais contribuem na hora de alocar os recursos. De uma forma bem resumida, o sistema funciona a partir da “doação” de recursos ociosos ao sistema, ou seja, computadores que não estão sendo utilizados por seus usuários. Por exemplo, quanto mais recursos um laboratório de pesquisa disponibiliza para os outros pares no sistema, maior será a probabilidade deste laboratório receber recursos de seus pares quando o mesmo necessitar de um alto poder computacional. Quando os recursos de um laboratório estão ociosos, estes podem executar tarefas submetidas por usuários de outros laboratórios. A partir do momento que o usuário de um recurso ocioso passa a utilizar a máquina, esta se torna indisponível, podendo interromper a execução de uma tarefa sem que a mesma seja finalizada. Por este motivo, o sistema *OurGrid* não apresenta fortes requisitos de qualidade de serviço, uma vez que não há garantias na execução das tarefas. Grades computacionais dedicadas, diferente das grades P2P, apresentam um forte requisito de qualidade de serviço. Contudo, o sistema *OurGrid* apresenta uma alta escalabilidade de recursos, pois depende apenas da colaboração entre os pares, e, além disso, não demanda custos adicionais de hardware ou serviço, como acontece nas grade computacionais dedicadas.

Assim como em outros sistemas P2P, uma das principais preocupações no projeto *OurGrid* são os usuários que não colaboram com seus recursos, apenas consumindo os recursos disponibilizados por outros usuários. Para evitar este problema, foi incorporado ao *OurGrid* um esquema de reputação autônomo, cujo principal objetivo é incentivar a colaboração entre os participantes da grade, chamado Rede de Favores (ANDRADE, BRASILEIRO, CIRNE, MOWBRAY, 2007). Basicamente, através do comportamento autônomo dos participantes no sistema, aqueles que colaboram mais são priorizados quando requisitam recursos da comunidade.

O *OurGrid* é composto de quatro componentes básicos: *DiscoveryService*, *Broker*, *Peer* e *Worker*. Destes componentes, o *Worker* é o responsável por executar as tarefas repassadas pelo usuário, através de uma máquina virtual que abstrai e encapsula o funcionamento de uma máquina real. Assim se torna

um recurso seguro que irá executar tarefas em uma máquina virtual, protegendo a máquina real (hospedeira) contra uma possível aplicação maliciosa. O *Peer* funciona tanto como um provedor quanto um administrador de *Workers*. É o componente responsável por alocar as tarefas para os *Workers* que estiverem ociosos. O *Broker* é a interface por onde são submetidos e monitorados os *Jobs* (coleções de tarefas submetidas ao sistema). O *Broker* é o componente que requisita, ao *Peer*, os *Workers* disponíveis para execução dos *Jobs*. Por fim, o *DiscoveryService* é o componente responsável pela comunicação entre os demais e pela descoberta de recursos em outros *Peers*. A Figura 1 ilustra a arquitetura de funcionamento do sistema *OurGrid*.

Figura 1 – Arquitetura de funcionamento do sistema *OurGrid*.



Como um bom exemplo da utilização do sistema, podemos destacar que o *OurGrid* suporta o trabalho cooperativo de um grupo de pesquisa composto por meteorologistas e hidrologistas, tanto na academia quanto em agências governamentais (VOORSLUYS, ARAUJO, et al. 2005), onde previsões diárias do tempo são oferecidas como um serviço público para a comunidade ([www.cptec.inpe.br/](http://www.cptec.inpe.br/)). Para isto, simulações são submetidas e avaliadas diariamente pelo grupo de pesquisa. Contudo, a capacidade requerida nos horários críticos (quando aplicações com requisitos de tempo estão sendo executadas) é muito maior do que aquela requerida em horas normais de trabalho. Dessa forma, uma infraestrutura híbrida onde o poder computacional pode ser adquirido de diversas fontes é altamente desejável, uma vez que nem sempre é possível adquirir recursos em tempo hábil para resolução de problemas imediatos. Contudo, se por um lado o super provisionamento desta infraestrutura híbrida para essas agências públicas suportarem a alta demanda em tempos críticos não é eficaz, por

outro, confiar na natureza “melhor-esforço” do *OurGrid* não é aceitável. Neste sentido, é provável que a capacidade extra requerida nos horários críticos seja adquirida sob demanda (em provedores externos de computação na nuvem, por exemplo) e com requisitos firmes de qualidade de serviço, a um custo mais barato do que super provisionar a infraestrutura local dedicada. O importante observar é que a quantidade extra de poder computacional requerido pode ser reduzida, se os ciclos computacionais ociosos dos recursos locais dedicados puderem ser “negociados” em uma grade computacional P2P como o *OurGrid*. Nesta situação, a infraestrutura híbrida toma proveito da grade computacional P2P, através da redução dos custos operacionais para realização das simulações meteorológicas.

### 3 Caso de uso

Com o objetivo de tornar evidente algumas das vantagens da utilização do ambiente *OurGrid* implementado, foi elaborado um caso de uso que requeira o desenvolvimento de um algoritmo específico e demandasse uma quantidade de processamento suficiente para os estudos realizados.

#### 3.1 O problema

Uma empresa do ramo de Redes de Computadores pretende investir certa quantidade de recursos para cobrir o estado da Paraíba com antenas de redes sem fio WiMAX. O gerente de projetos estratégicos desta empresa deseja saber como deve ser utilizado o recurso, de forma tal que o maior número de habitantes do estado tenha acesso à rede.

Para este projeto, a empresa dispõe de três tipos diferentes de antena ( $A$ ) incompatíveis entre si, o que implica que apenas um tipo de antena pode ser usado para cobrir o estado.

Cada antena possui um raio de cobertura  $rA$  e um custo para sua compra e implantação  $cA$ , conforme disposto na Tabela 1. Uma vez que uma cidade  $v$  é escolhida para possuir uma antena, toda a sua população automaticamente ganha acesso à rede, assim como a população de todas as cidades cuja distância para  $v$  seja menor que  $rA$ .

Uma vez escolhidas as cidades onde serão instaladas as antenas, para que haja a interconexão estadual, estas devem ser conectadas utilizando uma linha de transmissão cabeada, ao custo de R\$ 20,00/Km. O custo desta interligação cabeada pode ser facilmente

calculada por um algoritmo de Árvore de Cobertura Mínima (CORMEN *et al.*, 2009). Dado um tipo específico de antena  $A$  e um montante de capital para investir  $C$ , o objetivo é selecionar as cidades que irão receber antenas, de modo que o maior número de habitantes seja atendido pelo serviço e que o custo de instalação das antenas, mais o custo da interconexão cabeada destas, não ultrapasse  $C$ .

#### 3.2 Os cenários possíveis

De acordo com o gerente de projetos da empresa, esta pretende decidir se investirá R\$ 50.000,00, R\$ 100.000,00 ou R\$ 150.000,00. Para tomar esta decisão, dada a incompatibilidade entre as antenas, é necessário calcular o número máximo de habitantes atendidos em cada um dos nove cenários possíveis, apresentados na Tabela 2.

É importante ressaltar que os custos utilizados neste trabalho são valores hipotéticos, definidos apenas para avaliarmos diferentes cenários de implantação.

Tabela 1 – Tipos de Antenas

Antena (A)	Raio de cobertura (rA)	Custo de compra e implantação (cA)
$A_1$	15 km	R\$ 5.000,00
$A_2$	25 km	R\$ 7.000,00
$A_3$	40 km	R\$ 10.000,00

Tabela 2 – Cenários de Implementação

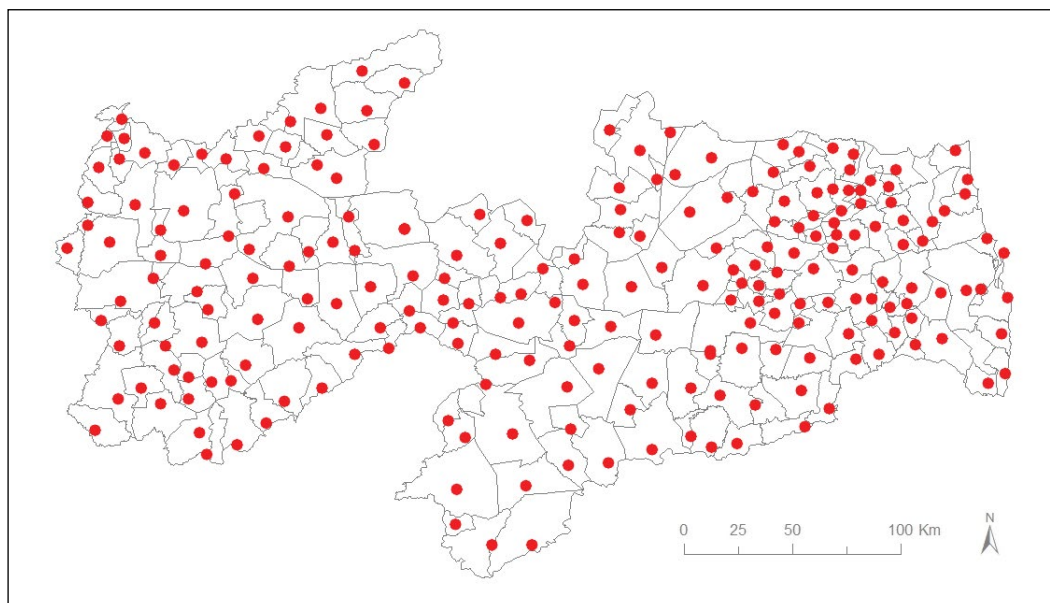
Cenário	Investimento (C)	A	rA	cA
1	R\$ 50.000,00	$A_1$	15 Km	R\$ 5.000,00
2	R\$ 100.000,00			
3	R\$ 150.000,00			
4	R\$ 50.000,00	$A_2$	25 Km	R\$ 7.000,00
5	R\$ 100.000,00			
6	R\$ 150.000,00			
7	R\$ 50.000,00	$A_3$	40 Km	R\$ 10.000,00
8	R\$ 100.000,00			
9	R\$ 150.000,00			

### 3.3 Detalhes da implementação

O primeiro passo necessário para resolução de cada cenário foi a construção de um grafo  $G(V,E,P)$  representando o estado da Paraíba, no qual  $V$  representa o conjunto de todos os 223 municípios do esta-

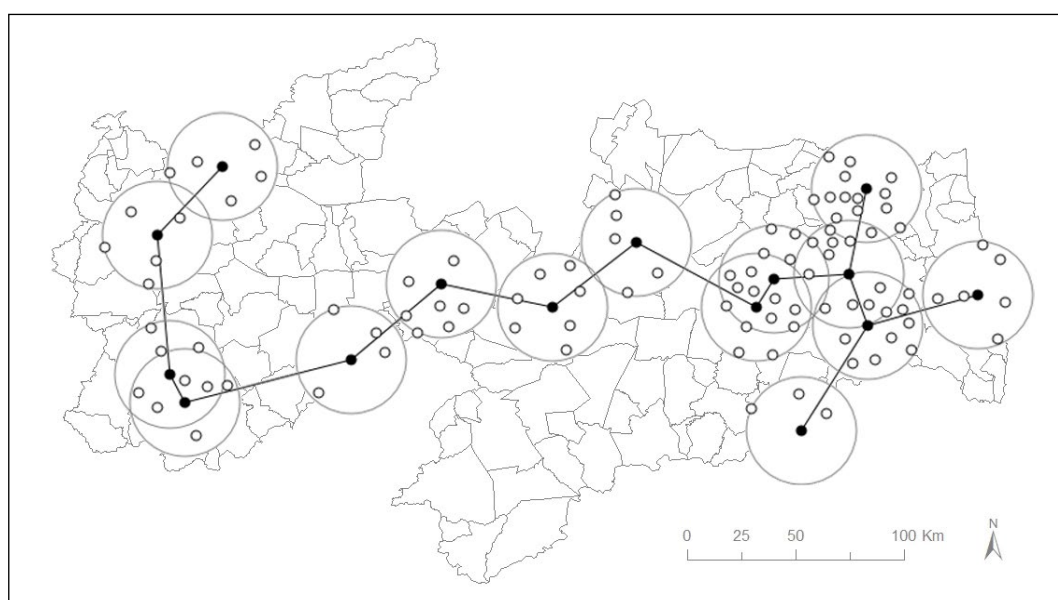
do,  $E$  representa as distâncias em quilômetros entre cada par de município e  $P$  representa a população de cada município (IBGE, 2010). A Figura 2 exibe o mapa da Paraíba e os vértices representando cada município; enquanto a Figura 3 exibe uma possível solução para o problema.

**Figura 2** – Mapa da Paraíba e os vértices representando seus 223 municípios



Fonte: adaptado do site <http://www.mapasparacolorir.via12.com>.

**Figura 3** – Solução de cobertura WiMAX com antenas de 40 km



Fonte: adaptado do site <http://www.mapasparacolorir.via12.com>.

Uma vez construído o grafo, optou-se por uma abordagem aleatória de simples implementação. Desta forma, em vez de gastar o tempo elaborando um algoritmo sofisticado, utiliza-se o poder computacional do *OurGrid* para que um algoritmo simples obtenha os mesmos (ou até melhores) resultados.

O algoritmo consiste em: dado o grafo  $G$ , um tipo de antenas  $A$ , e um custo máximo  $C$ , selecionar um número de antenas aleatoriamente entre 2 e o número máximo de antenas  $mA$  permitido por  $C$  ( $C/cA$ ); o próximo passo é selecionar aleatoriamente as  $mA$  cidades onde serão posicionadas as antenas e calcular o custo e o número de habitantes atendidos. Este procedimento, então, é repetido até que o tempo limite seja atingido e a melhor solução (maior número de habitantes atendidos sem violar a restrição de custo máximo) é retornada.

De posse dos melhores resultados obtidos, a empresa pode tomar sua decisão sobre o capital que deve ser investido e o tipo de antena que deve ser utilizado baseando-se na métrica custo/habitante atendido e no número total de habitantes atendidos em cada cenário.

### 3.4 Análise da utilização da ferramenta

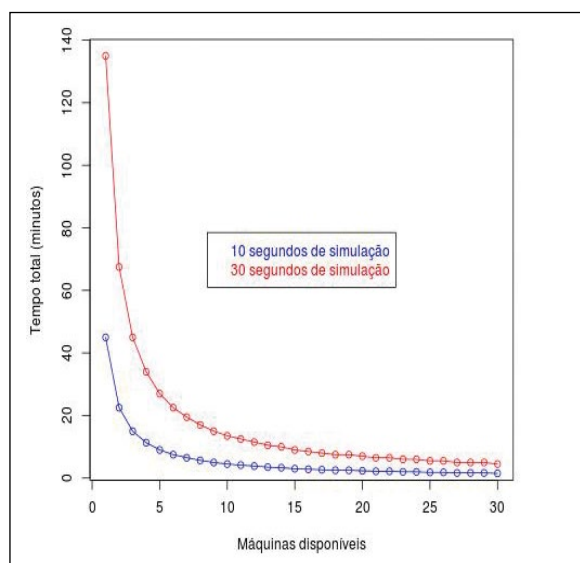
O intuito desta subseção é apresentar indícios de que a utilização do *OurGrid* pode acelerar a obtenção de resultados em uma pesquisa científica. Para isto, vamos utilizar uma métrica de *speedup*, que representa o quão mais rápido é o processamento de uma simulação em paralelo, em comparação com o mesmo processamento realizado de forma sequencial. A partir do problema de otimização definido e dos nove cenários de simulação descritos anteriormente, pretendemos demonstrar quantitativamente o quanto a utilização da grade computacional pode ajudar na obtenção mais rápida de resultados.

Consideramos simulações com o tempo de 10 ou 30 segundos para cada cenário. Ou seja, o algoritmo de simulação busca a melhor solução por 10 (ou 30) segundos, testando várias possibilidades de configuração para o custo total, raio e custo da antena ( $C$ ,  $cA$  e  $rA$ ). Após 10 (30) segundos de simulação, o algoritmo apresenta a configuração de posicionamento das antenas com o maior número de habitantes atendidos, sem ultrapassar o custo pretendido. O tempo de processamento total será definido a partir dos cenários individuais de simulação.

Para uma análise estatística mais confiável dos resultados, cada um dos 9 cenários simples definidos

na Tabela 2 foi executado pelo menos 30 vezes (JAIN, 1991). Desta forma, para este pequeno número de parâmetros (3 valores para custo máximo e 3 tipos de antenas com raios de alcance e preços diferentes), foram necessárias 270 simulações. Fazendo um cálculo bem simples para um pior caso, se todos os 270 cenários fossem executados em uma única máquina e de forma sequencial, o tempo total seria de, aproximadamente, 45 minutos para simulações de 10 segundos e 2 horas e 15 minutos para simulações de 30 segundos. Já para o melhor caso, onde a grade computacional disponibilizou 30 *Workers* para execução das simulações, o tempo total foi um pouco mais do que 1 minuto e meio, levando em consideração cenários de 10 segundos e pouco mais do que 5 minutos e meio para cenários de 30 segundos (consideramos valores aproximados para estes cálculos e desprezamos o tempo necessário para configuração e envio dos *Jobs*, uma vez que os testes foram realizados em uma rede local cuja latência é muito baixa). A Figura 4 mostra o *speedup* dos experimentos realizados levando em consideração o problema de otimização descrito e a utilização do *OurGrid* para execução em paralelo das simulações.

Figura 4 – *Speedup* dos experimentos realizados



Pela Figura 4 podemos perceber que é vantajoso utilizar uma ferramenta/solução de computação paralela para realização de experimentos científicos. Tivemos um *speedup* de aproximadamente 30 vezes menor quando consideramos a pior (1 máquina) e a melhor (30 máquinas) configuração. Em outras palavras, o tempo total de simulação diminuiu de 45 minutos para 1 minuto e meio, no caso das simulações

de 10 segundos cada; e, para as simulações de 30 segundos cada, aproximadamente 2 horas e 10 minutos a menos no tempo total de simulação, passando de 2 horas e 15 minutos para 4 minutos e meio.

É importante salientar que estes resultados foram obtidos para os cenários simples de simulação descritos anteriormente. A quantidade de parâmetros envolvidos, bem como os possíveis valores destes parâmetros, pode aumentar significativamente, tornando a combinação entre eles um número extremamente alto de simulações a serem executadas. Além disso, as 30 máquinas do *OurGrid* foram obtidas em uma configuração simples de laboratório. O potencial de obtenção de recursos é muito maior quando, por exemplo, consideramos diversos laboratórios (*peers*) interagindo uns com os outros em um mesmo campus, ou mesmo entre diferentes Institutos Federais espalhados pelo país. Conjecturamos que, com uma grande adesão da comunidade científica dos Institutos Federais, a quantidade de recursos disponibilizados ao sistema pode chegar a algumas várias centenas.

## 4 Conclusões

Neste artigo apresentamos o sistema *OurGrid*, que é uma grade computacional P2P e oferece um ambiente de computação paralela apropriado para aplicações *Bag-of-Tasks*. O sistema serve como ferramenta útil para realização de experimentos científicos, possibilitando acelerar o processo de obtenção de resultados. Para demonstrar indícios de como o *OurGrid* pode alavancar a pesquisa científica em Institutos Federais, descrevemos um caso de uso onde o sistema foi utilizado para resolver um problema de otimização na alocação de antenas de comunicação sem fio no estado da Paraíba. Pelos resultados obtidos podemos concluir que a ferramenta é realmente eficaz, chegando a um *speedup* proporcional à quantidade de máquinas disponibilizadas no sistema. Como perspectiva de trabalho futuro, pretendemos elaborar diferentes casos de uso para o *OurGrid* dentro do IFPB e envolvendo diferentes áreas do conhecimento (Engenharia Elétrica, Química, Mineração etc.). O objetivo é difundir a ferramenta para que a mesma possa ser utilizada em diferentes contextos e que isso possa alavancar a pesquisa científica do instituto como um todo.

## REFERÊNCIAS

ANDRADE, N., BRASILEIRO, F., CIRNE, W., MOWBRAY, M., **Automatic grid assembly by promoting**

**collaboration in peer-to-peer grids**, Journal of Parallel and Distributed Computing, vol 67, num 8, pages 957-966, Academic Press, Inc., Orlando, FL, USA (2007).

ARAUJO, E., CIRNE, W., et al., **The seghidro experience: Using the grid to empower a hydro-meteorological scientific network**, in Proc. of the 1st IEEE International Conference on e-Science and Grid Computing e-Science, Melbourne, Australia, Melbourne, Australia (2005).

CIRNE, W., BRASILEIRO, F., et al., **Labs of the World, Unite!!!**. Journal of Grid Computing, vol 4, num 3, pages 225-246, Springer, New York, USA (2006).

CORMEN, T.H., LEISERSON, C.E., RIVEST, R.L., STEIN, C. **Introduction to algorithms**, 3rd ed., MIT Press & McGraw-Hill (2009).

DUARTE, A., CIRNE, W., BRASILEIRO, F., MACHADO, P., **GridUnit: Software testing on the grid**, in Proc. 28th ACM/IEEE International Conference on Software Engineering, Shanghai, China, Shanghai, China (2006).

FOSTER, I., KESSELMAN, C., **The Grid: Blueprint for a New Computing Infrastructure**. Morgan Kaufmann Publishers. (1999).

HENNESSY, J.L.; PATTERSON, D.A., **Computer architecture: a quantitative approach**. (3rd ed.). San Francisco, Calif.: International Thomson, p. 43, (2002).

IBGE, Instituto Brasileiro de Geografia e Estatística. Censo Populacional (2010).

JAIN, R, **The Art of Computer Systems Performance Analysis: Techniques for Experimental Design, Measurement, Simulation and Modeling**, Wiley, 1st edition, (1991)

OSTHOFF, C., OLIVEIRA, F., et al., **A grid computing testbed for EM algorithm financial market applications**, in Third IFIP Conference on E-Commerce, E-Business and E-Government, Guarujá, SP, pp. 583-590 (2003).

VOORSLUYS, W., ARAUJO, E., et al., **Fostering collaboration to better manage water resources**, Proceedings of GCE 2005: Workshop on Grid Computing Portals, November (2005).

WILTER, A., OSTHOFF, C., et al., **The biopauã project: A portal for molecular dynamics using grid environment**, Brazilian Symposium on Bioinformatics (2005).