

APLICAÇÃO E COMPARAÇÃO DAS META-HEURÍSTICAS ARREFECIMENTO SIMULADO E ALGORITMOS GENÉTICOS PARA ALOCAÇÃO DE HORÁRIOS UNIVERSITÁRIOS

Marcelo Bezerra Gonçalves¹, Francisco Jozivan Tiadoza Freire¹, Diego Rocha Lima², Talles Brito Viana¹

¹ Instituto Federal de Educação, Ciência e Tecnologia do Ceará – *campus* Crato

² Instituto Federal de Educação, Ciência e Tecnologia do Ceará – *campus* Aracati

{tallesbrito, diegorocha}@ifce.edu.br, {marcelobez.g, josivamfreire.fj}@gmail.com

RESUMO: Este trabalho tem como objetivo descrever a aplicação das meta-heurísticas Arrefecimento Simulado e Algoritmos Genéticos para alocação de horários do IFCE campus Crato bem como realizar um estudo comparativo sobre o desempenho, resultados e limitações das mesmas. Para realizar o experimento, os algoritmos foram submetidos a condições análogas e utilizou-se um grupo de restrições adaptadas às características da instituição. As meta-heurísticas foram comparadas quanto à: rapidez, assegurabilidade, qualidade e quantidade das soluções geradas. Após o estudo pode-se concluir que a aplicação criada com uso do Arrefecimento Simulado está mais apta a gerar horários para o curso por suprir de melhor forma as necessidades da organização e por ter baixo desempenho somente nos quesitos que são menos relevantes.

Palavras-chave: Arrefecimento Simulado. Algoritmos Genéticos. Alocação de Horários.

ABSTRACT: The aim of this paper is to describe the application of Simulated Annealing and Genetic Algorithms metaheuristics for generating a university timetabling to IFCE Campus Crato, as well as to present a comparative study about their performance, results and limitations. In order to carry out the experiment, such algorithms were submitted to similar conditions and a group of adapted constraints was used according to the institution characteristics. The metaheuristics were compared regarding to: speed, assurance, quality and generated solutions quantity. It is concluded that Simulated Annealing is fitter than Genetic Algorithms as it better suits the organization needs and it has low performance regarding only to the requirements which are less relevant.

Keywords: Genetic Algorithms. Simulated Annealing. Timetabling.

1. INTRODUÇÃO

A alocação de horários universitários (ou escolares) é uma tarefa ainda desempenhada manualmente por diversas instituições, o que consome tempo e requer trabalho exaustivo dos profissionais aos quais a função é designada. Este problema consiste em alocar horários baseados em uma série de restrições organizacionais, pedagógicas e pessoais (CARVALHO et al., 2016). Este problema é também conhecido como *University Timetabling Problem* (UTP) na literatura e é considerado um problema *NP-HARD*, o que consequentemente demonstra a dificuldade em resolver o mesmo através de métodos manuais (SAPRU; REDDY; SIVASELVAN, 2010).

Muitos trabalhos apresentam ferramentas para solucionar esse problema. Essas obras tratam, principalmente, de táticas como programação linear, fluxos em rede, coloração de grafos, entre outras (LARA,

2006). Porém, todas apresentam limitações em alguns aspectos, sejam elas relacionadas a execução ou a qualidade.

Segundo Luke (2013), uma meta-heurística é um método de otimização estocástica que aplica determinado grau de aleatoriedade para encontrar soluções ótimas, geralmente utilizado em situações em que o espaço de busca é muito extenso e existe a possibilidade de avaliar o quão boa é uma solução gerada. Desta forma, ao decorrer dos anos, algumas meta-heurísticas passaram a ser usadas para resolver o UTP, dentre estas, os Algoritmos Genéticos (AG) e o Arrefecimento Simulado (AS) (SHEUNG; FAN; TANG, 1993).

O objetivo desse artigo é contrastar duas resoluções para o UTP usando Algoritmos genéticos e Arrefecimento Simulado aplicadas à alocação de horário do IFCE campus Crato para o curso de Sistemas de informação, analisando-os quanto à rapidez, qualidade, assegurabilidade e quantidade de soluções geradas. Estes

itens são descritos detalhadamente na Seção 3.

Esse trabalho está organizado da seguinte forma: a Seção 2 ressalta a importância desse trabalho discutindo outros trabalhos relacionados que abordam o problema de alocação de horários; a Seção 3 apresenta o detalhamento do processo de investigação e desenvolvimento das meta-heurísticas, além de um relato acurado do experimento; a Seção 4 retrata os resultados obtidos quanto a comparação dos fatores anteriormente mencionados; e a Seção 5 expõe as principais conclusões obtidas neste trabalho.

2. REVISÃO TEÓRICA

Os AGs são usados na resolução de uma variedade de problemas de otimização atualmente. Nastasi et al. (2016), por exemplo, fez uso dos AGs para criação de armazéns inteligentes de maneira a aperfeiçoar o uso de espaço e diminuir os custos. Da mesma forma os ASs são ferramentas regularmente utilizadas com esse propósito, como em trabalhos como o de Fang et al. (2018) que propôs o uso dos ASs para aprimorar um método de reconstrução de imagens e o de Lehmann et al. (2016) que apresentou um projeto sobre a otimização de escolhas na projeção de parques de produção de energia eólica.

Outro tema que expõe a característica da necessidade de otimização para solução é o UTP, o qual apresenta uma grande dificuldade de resolução devido ao fato de ser um problema de difícil generalização (CARVALHO et al., 2016). Em outras palavras, é necessário definir um conjunto de restrições que deverão ser atendidas, o que define uma solução ótima para o UTP. Esse problema também possui natureza combinatória, gerando a necessidade da análise de um grande número de combinações para encontrar uma solução factível (BUCCO, 2014). Segundo Barata et al. (2016), isso diminui a possibilidade de existir algoritmos exatos que resolvam o UTP em tempo polinomial, gerando assim necessidade do uso de métodos mais elaborados como as meta-heurísticas apresentadas nos trabalhos de Soyemi (2017), Mahmudy (2017) e neste trabalho.

Diversos trabalhos também demonstram interesse na comparação de meta-heurísticas como Jarecki et al. (2017), que faz uso de três, AG, AS e Cross-Entropy, para resolução do problema não polinomial *green supply chain management (GSCM)*, o qual refere-se ao planejamento da cadeia de recursos de forma a garantir eficiência, sustentabilidade e resiliência. De forma semelhante, Fahimnia, Davarzani e Eshragh (2018) fazem uso de AS, AG e *Ant Colony Optimization* – meta-heurística baseada no comportamento de algumas espécies de formigas –, para realizar uma análise da eficiência desse métodos na busca por melhor rota em áreas com obstáculos. Este

trabalho, então, apresenta também um estudo comparativo sobre o uso de meta-heurísticas para resolução de um problema de complexidade semelhantes aos mencionados anteriormente.

3. METODOLOGIA

O primeiro passo da pesquisa consistiu na compreensão do método atualmente usado pelo IFCE campus Crato para gerar os horários, o qual é manual e demanda cerca de dois dias para ser realizada por dois profissionais. Acompanhado a isso, também obteve-se a lista de docentes e restrições fortes e fracas que a instituição adota.

Realizou-se, então, um estudo teórico e prático das meta-heurísticas em questão a fim de melhor compreendê-las e implementá-las. Para tal feito, adotou-se a linguagem de programação C++. Ambos os algoritmos foram aplicados com as seguintes características: as soluções iniciais são geradas aleatoriamente, as mesmas são representadas como matrizes cúbicas que possuem os horários alocados na forma de $SEMESTRES \times DIAS \times HORÁRIOS$ e os indivíduos são avaliados segundo as restrições descritas na Tabela 1.

Tais restrições definem que “*Colisão de professores*” é referente ao fato de uma solução possuir um mesmo professor ministrando duas ou mais aulas em mesmo horário e “*Laboratórios*” verifica a disponibilidade de laboratórios caso a disciplina requisite. Além disso, a restrição de “*Professor sem folga*” garante que todo professor deve, pelo menos, folgar um dia por semana; a restrição de “*Aulas consecutivas*” garante que disciplinas não terão aulas ministradas seguidamente em um mesmo dia; A restrição de “*Primeiro horário vago*” garante que em semestres onde não há disciplinas suficientes para um horário semanal completo, os espaços vagos na grade serão preferencialmente nos turnos finais ou em dias sem aula; e a “*Preferência por folga*” assegura que qualquer docente que esteja indisponível em determinado dia não tenha aulas alocadas para o mesmo.

Uma solução ótima é, então, definida como uma tal qual respeita todas as restrições descritas na Tabela 1. Desta forma, para saber o quão próxima ou distante de uma solução ótima está da solução atual, se faz uso de funções de custo: no AG utiliza-se uma função normalizada onde 1 representaria a melhor solução possível (BARCELLOS, 2000). Em AS, porém, define-se uma solução ótima como uma associada ao menor custo possível, nesse caso 0 (SOUZA, 2012). Nas próximas subseções mais sobre a implementação do AG e do AS para a aplicação é detalhado.

Tabela 1. Restrições fortes e fracas e valores de penalidades.

Restrição Forte	Peso (AG)	Peso (AS)	Restrição fraca	Peso (AG)	Peso (AS)
Colisão de professores	10	400	Primeiro horário vago	3	50
Professor sem folga	5	200	Laboratórios	2	30
Aulas consecutivas	1	100	Preferência de folga	1	10

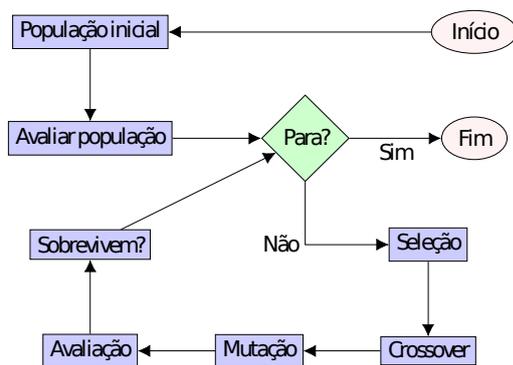
3.1. Algoritmos Genéticos

Segundo Timoteo (2002), os Algoritmos genéticos foram criados fundamentados nas leis da evolução natural, propostas por Charles Darwin, aliadas as ideias sobre genética estabelecidas por Mendel. Assim sendo, a ideia principal é gerar e testar soluções baseado nos parâmetros da evolução até que uma condição de parada seja satisfeita. Para isso, segundo Moreira (2010), inicialmente é definido uma população de indivíduos e a partir dela serão feitas seleções para identificar os indivíduos mais aptos a cruzar, ou seja, gerar novas soluções. Isso é realizado baseando-se em um índice *fitness* (ou grau de aptidão) calculado (através do uso da Equação 1) a partir das restrições descritas na Tabela 1.

$$f(x) = \frac{1}{1 + \text{penalidades}} \quad (01)$$

Após o cruzamento (*crossover*), ou recombinação, uma nova população é gerada e avaliada e uma condição de sobrevivência testa quais indivíduos farão parte da nova população. Um processo de mutação (troca de dois valores de slots/genes) é eventualmente realizado para garantir variabilidade genética sobre a população. Esse esquema é demonstrado pelo fluxograma na Figura 1.

Figura 1. Fluxograma ilustrando funcionamento básico do AG.



Durante o desenvolvimento foram testados três métodos de seleção: *seleção uniforme (SU)*, *seleção por*

torneio (ST) e *seleção por roleta giratória (SRG)* proposto no trabalho de Timóteo (2002). Segundo Simão (2013), na estratégia de seleção uniforme os indivíduos que participarão da etapa de cruzamento são selecionados de forma arbitrária, sem levar em consideração o grau de aptidão. Já no método de torneio ocorre uma seleção aleatória de dois indivíduos e aquele que possuir maior grau de aptidão é selecionado. Por fim, segundo Barcellos (2010), na estratégia de seleção por roleta giratória todo indivíduo possui uma chance de ser selecionado equivalente ao seu índice *fitness*. Este último foi o método que apresentou melhor desempenho, conforme demonstrado no gráfico A da Figura 2 e foi escolhido para compor o experimento comparativo.

Os métodos de *crossover* investigados foram: *crossover em um ponto* e *crossover em dois pontos*. Pela representação dos indivíduos como anteriormente mencionado, foi necessária precaução a fim de não gerar indivíduos inválidos, uma vez que esses métodos tratam de recombinação genética, inferindo na troca de valores dos slots entre os indivíduos pais para gerar um indivíduo filho (LUKE, 2013). Por não apresentar valores significativos de melhora entre o uso dos métodos, a técnica de corte em um ponto foi escolhida pela simplicidade.

As condições de sobrevivência testadas consistem dois métodos: *Elitista* e *Os filhos substituem os pais (FSP)*. A estratégia elitista consiste em “substituir o(s) pior(es) cromossomo(s) da nova geração pelo(s) melhor(es) da antiga” (BARCELLOS, 2000). No segundo, como evidenciado pelo nome, a população filha substituirá a população pai. Por fim, foi escolhido o primeiro método para compor a aplicação já que o mesmo demonstrou um desempenho estritamente melhor (cerca de 56%) como representado no gráfico B da Figura 2.

Por fim, definimos a mutação como a troca os valores de dois genes (slot) e a condição de parada é o número de gerações sem que nenhuma melhor solução seja encontrada (TIMOTEO, 2002). Um valor de idade foi definido como estratégia para evitar que indivíduos não se tornem proeminentes pela estratégia elitista a ponto de reduzir a variabilidade genética da população, eliminando, dessa forma, cromossomos que ultrapassem esse valor em quantidade de gerações. Os valores definidos estão especificados na Tabela 2.

Figura 2. Gráficos ilustrando a diferença entre a média do índice fitness das melhores soluções encontradas até certa geração por: tipos de seleção (A) e condições de sobrevivência (B).

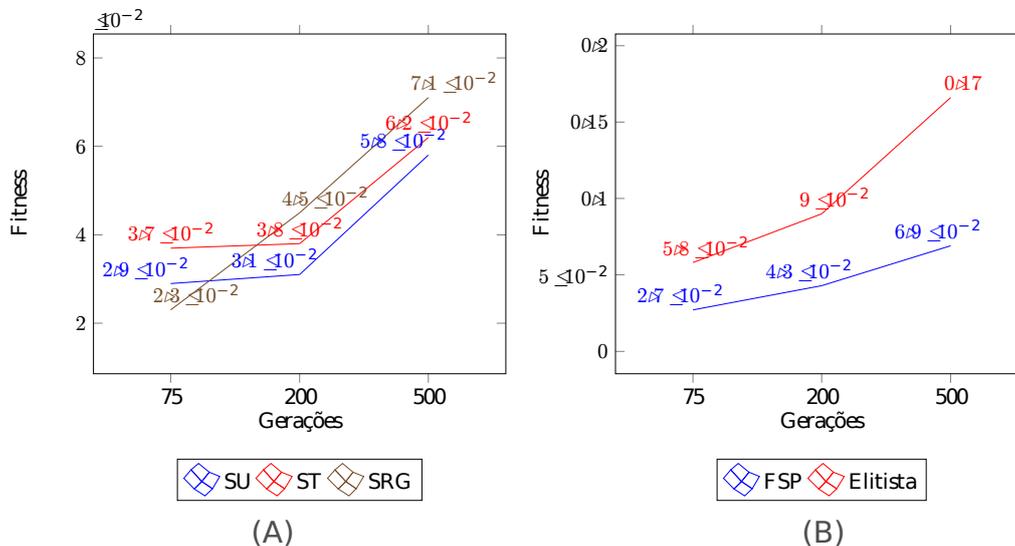


Tabela 2. Valores referentes aos parâmetros dos AGs

Parâmetro	Valor	Parâmetro	Valor
Tamanho da população	100	Idade máxima do indivíduo	20
Probabilidade de mutação	0,02	Gerações sem encontrar melhor solução (condição de parada)	500
Probabilidade de recombinação	0,8		

3.2. Arrefecimento Simulado

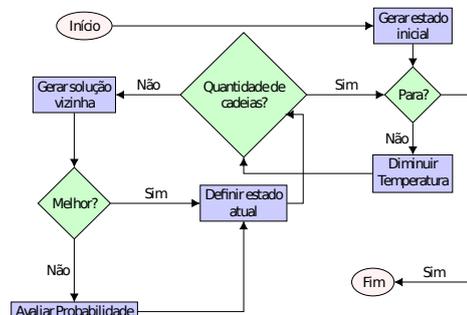
Segundo Araujo (2001), o AS foi desenvolvido através do resultado de diversas pesquisas realizadas em meados dos anos 80 e o mesmo consiste em uma busca pela vizinhança com a adição do Algoritmo de Metr polis que consiste em uma simula o do comportamento dos  tomos   lenta varia o de uma temperatura alta a uma extremamente baixa, criado por Nicholas Metropolis em 1953. Esse algoritmo supre as limita es claras de uma busca por vizinhança padr o por n o conseguir escapar de  timos locais. Nesse algoritmo, reconhecemos, analogicamente, um estado como uma poss vel solu o, a energia como o custo de um estado, uma perturba o de um estado f sico como a sele o de uma solu o vizinha, o estado fundamental como um  timo global, e um resfriamento r pido como um  timo local (ARAUJO, 2001).

$$g(-\Delta E, T) = \frac{e^{-\Delta E}}{T} \quad (02)$$

O procedimento desse algoritmo consiste em: define-se uma temperatura inicial e uma solu o inicial

para o problema. Enquanto a temperatura n o estiver muito pr xima a zero, ocorrem-se perturba es a partir do estado atual e analisa-se a varia o de energia entre o estado novo e o atual. A solu o gerada pela perturba o torna-se o estado f sico atual apenas se possuir menor energia ou se o resultado da Equa o 2 for um valor inferior a um n mero entre 0 e 1 gerado aleatoriamente (SOUZA, 2012) (ilustrado no fluxograma da Figura 3).

Figura 3. Representa o b sica em fluxograma do algoritmo de AS.



O conjunto desses parâmetros, ou *programa de resfriamento*, foi adequado ao tipo geométrico (KIRKPATRICK; GELATT; VECCHI, 1983) e salienta as medidas da seguinte maneira: a temperatura inicial T_0 , que segundo Herrera (2007) “deve ser um valor suficientemente elevado para que todas as soluções da vizinhança”, independente de qualidade, “tenham a probabilidade próxima de 1 de ser escolhidas”, recebeu valor 10 para garantir essa premissa. A quantidade de perturbações a partir de um estado, ou tamanho da cadeia, é definida como fixo e igual a 40. A redução de temperatura ocorre através do produto da atual por um fator fixo $\alpha < 1$, o qual foi definido como $\alpha = 0,995$. A condição de parada do algoritmo é definida por uma temperatura em um momento k , tal que $T_k < 0,001$ e o estado físico atual não muda por pelo menos 100 perturbações. Durante o processo de definição desses parâmetros uma variedade maior de valores foram testados. Estes, porém, reduziram em qualidade o resultado esperado.

3.3. O Experimento

Após os passos de compreensão e implementação das meta-heurísticas, o experimento comparativo foi iniciado da seguinte forma: foram submetidos às meta-heurísticas as entradas com os seguintes dados obtidos com o IFCE campus Crato: docentes disponíveis e lista de disciplinas aptas a ministrar; as matérias por semestre; dia da semana preferencial para folga de cada professor e se a disciplina requisita ou não laboratório. As implementações das meta-heurísticas de Arrefecimento Simulado e Algoritmos Genéticos foram submetidas ao teste em um computador com a seguinte configuração: Processador Intel Core i3-2328M CPU 2.20GHz.

O teste consistiu em executar as implementações das meta-heurísticas sob as mesmas condições, com as mesmas entradas e um mesmo número de vezes. Os resultados foram expostos detalhadamente em arquivos de saída para cada aplicação e depois analisados de forma minuciosa.

4. RESULTADOS

Os resultados estão ilustrados nos gráficos da Figura 4 e foram comparados quanto aos seguintes quesitos: rapidez para encontrar a primeira solução ótima (Gráfico A); qualidade da solução ótima expressa pela avaliação quanto às restrições (Gráfico B); segurança quanto à garantia de, pelo menos, uma solução ótima gerada no tempo (Gráfico C); e a quantidade de soluções geradas (Gráfico D).

Para calcular o tempo, foi utilizado uma mesma função que iniciava a contagem quando os algoritmos

geravam a primeira solução. A cronometragem era, então, parada quando os mesmos encontravam uma solução ótima e os dados armazenados no arquivo de saída. Por fim, gerou-se uma média ponderada do tempo a partir dos dados. É importante salientar que apenas foram levados em consideração, nesse quesito, os dados sobre eventos em que a aplicação encontrava uma solução ótima, deixando para o quesito de assegurabilidade a tarefa de analisar os algoritmos quanto a esse fator. Os resultados obtidos mostram que o AG é em média 6,6 vezes mais rápido em encontrar uma solução ótima do que o AS.

O percentual de qualidade foi calculado baseado na média ponderada da qualidade de todas as soluções geradas e fornece noção sobre o quão próximas ou distantes estão estas soluções de soluções ótimas. De forma semelhante, o percentual de assegurabilidade demonstra o comportamento das meta-heurísticas quanto ao ato de gerar ou não uma solução ótima. Para analisar esse quesito, definiu-se um tempo limite de quatro segundos para de execução total.

Por fim, cada algoritmo foi ajustado para, mesmo após encontrar uma solução ótima, procurar alternativas e adicioná-las a saída. O AG apresentou maior facilidade em encontrar outras soluções pelo comportamento mais característico de busca global, enquanto o AS, possuindo um decréscimo evidente na temperatura no final do algoritmo demonstrou maior dificuldade.

5. CONCLUSÕES

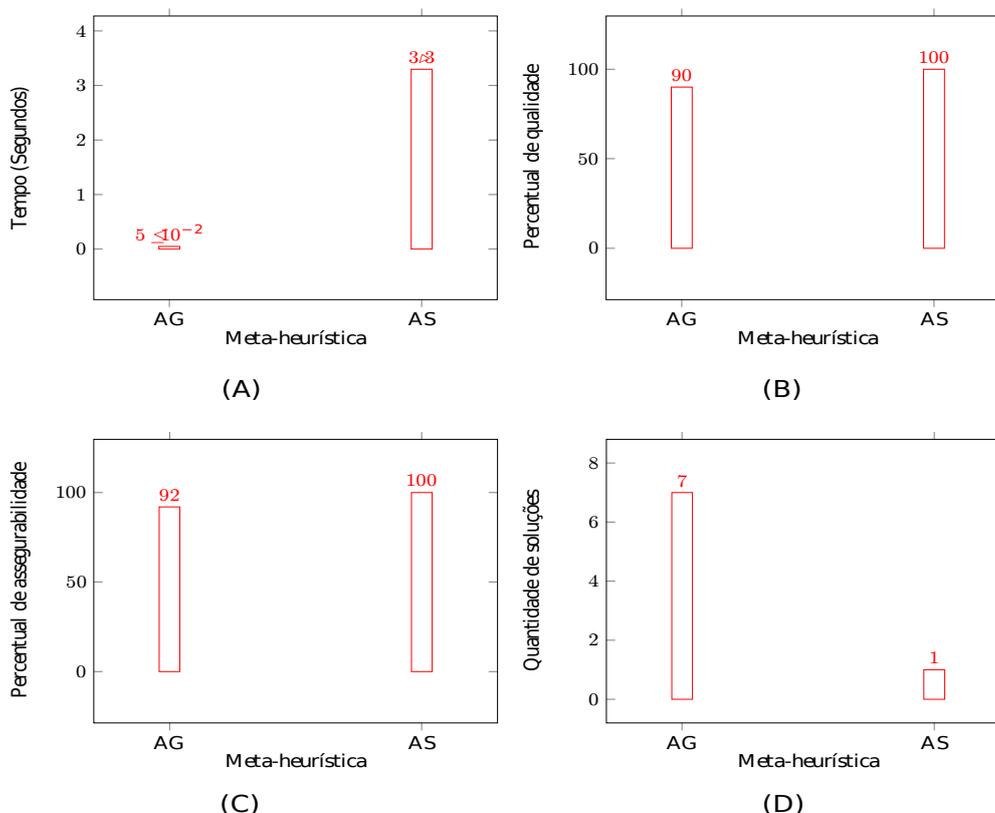
De acordo com o primeiro quesito expresso pelo gráfico A (da Figura 4), que representa a rapidez em encontrar a primeira solução ótima, podemos concluir que os AGs estão mais aptos nessas condições a serem utilizados quando há a necessidade de possuir rápida resposta da aplicação. Estes também são recomendados, segundo o gráfico D (da Figura 4), caso haja a necessidade de obter uma variedade maior de grades geradas, já que os mesmos geram em média sete vezes mais soluções que o AS.

Baseado nisso, entende-se que a aplicação desenvolvida com AG é mais recomendada em ambientes com UTP de maior complexidade e escala, de maneira que a rapidez seria de maior interesse. Também em casos em que a instituição precise lidar com maior flexibilidade e disponibilizar um número maior de horários para expandir as opções a fim de lidar de melhor forma com imprevistos.

A partir dos resultados expressos nos gráficos B e C (da Figura 4), o AS apresenta maior utilidade em casos em que uma resposta ótima ou a qualidade da mesma deve ser assegurada pela aplicação, tornando o AS o algoritmo ideal para uso no caso do IFCE campus Crato, já que os quesitos descritos em A e D são mais relevantes em casos onde existe maior complexidade e espaço de busca.

APLICAÇÃO E COMPARAÇÃO DAS META-HEURÍSTICAS ARREFECIMENTO SIMULADO E ALGORITMOS GENÉTICOS PARA ALOCAÇÃO DE HORÁRIOS UNIVERSITÁRIOS

Figura 4. Gráficos apresentando o resultado dos testes quanto a rapidez (A), qualidade (B), assegurabilidade (C) e quantidade de soluções geradas (D).



Como trabalhos futuros pretende-se disponibilizar as aplicações em uma ferramenta web que se baseia nas necessidades do usuário e na complexidade do caso para escolher qual algoritmo será utilizado para gerar os horários. Uma variedade maior de restrições serão adicionadas a fim de abranger de melhor forma as necessidades de instituições que venham utilizar a ferramenta, como por exemplo, permitir a distribuição das lotações dos professores em mais de um curso.

REFERÊNCIAS BIBLIOGRÁFICAS

ARAUJO, Haroldo Alexandre de. **Algoritmo Simulated Annealing**: Uma Nova Abordagem. 2001. 117 f. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Santa Catarina, Florianópolis, 2001.

BARATA, B. M. P. et al. Problema de alocação de horários: um estudo de caso utilizando o software livre fet. **Revista Eletronica TECCEN**, v. 3, n. 2, p. 13–22, 2016.

BARCELLOS, João Carlos Holland de. **Algoritmos**

Genéticos Adaptativos: Um estudo Comparativo. 2000. 143 f. Dissertação (Mestrado em Engenharia) – Universidade Federal de Lavras, Belo Horizonte, 2002.

BUCCO, Guilherme Brandelli. **Construção de um modelo de programação linear para o University Timetabling Problem**. 2014. 156 f. Dissertação (Mestrado em Administração) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2014.

CARVALHO, A. S. et al. Simulated annealing aplicado ao problema de programação de horários do cca-ufes. **Blucher**, Universidade Federal do Espírito Santo, p. 2–11, 2016.

FAHIMNIA, B.; DAVARZANI, H.; ESHRAGH, A. Planning of complex supply chains: A performance comparison of three meta-heuristic algorithms. **Computers Operations Research**, v. 89, p. 241 – 252, 2018. ISSN 0305-0548. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0305054815002397>>.

APLICAÇÃO E COMPARAÇÃO DAS META-HEURÍSTICAS ARREFECIMENTO SIMULADO E ALGORITMOS GENÉTICOS PARA ALOCAÇÃO DE HORÁRIOS UNIVERSITÁRIOS

- FANG, L. et al. Image reconstruction through thin scattering media by simulated annealing algorithm. **Optics and Lasers in Engineering**, v. 106, p. 105 – 110, 2018. ISSN 0143-8166. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0143816617313714>>.
- FEBRITA, R. E.; MAHMUDY, W. F. Modified genetic algorithm for high school time-table scheduling with fuzzy time window. In: **2017 International Conference on Sustainable Information Engineering and Technology (SIET)** . [S.l.: s.n.], 2017. p. 88–92.
- HERRERA, Claudia Natalia Lara. **Algoritmo de Tomografia por Impedância Elétrica baseado em Simulated Annealing**. 2007. 71 f. Tese (Mestrado em Engenharia) – Universidade de São Paulo, São Paulo, 2007.
- JARECKI, P. et al. Comparison of algorithms for finding best route in an area with obstacles. In: **2017 25th International Conference on Systems Engineering (ICSEng)**. [S.l.: s.n.], 2017. p. 163–168.
- KIRKPATRICK, S., GELATT, Jr., C. D. e VECCHI, M. P. Optimization by Simulated Annealing. **Science**, n. 220, p. 671-680, 1983.
- LARA, Braulio Alves Silva. **Quadro de Horários Acadêmico: Uma Abordagem com Foco na Avaliação Institucional e na Gestão de Custos de Instituições de Ensino Superior Privadas Brasileiras**. 2006. 144 f. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Minas Gerais, Belo Horizonte, 2006.
- LEHMANN, S. et al. A simulated-annealing-based approach for wind farm cabling. In: **Proceedings of the Eighth International Conference on Future Energy Systems**. New York, NY, USA: ACM, 2017. (e-Energy '17), p. 203–215. ISBN 978-1-4503-5036-5. Disponível em: <<http://doi.acm.org/10.1145/3077839.3077843>>.
- LUKE, S. **Essentials of Metaheuristics**. second. [S.l.]: Lulu, 2013. 261 p. Available for free at <http://cs.gmu.edu/~sean/book/metaheuristics/>.
- MOREIRA, Renato Simões. **Algoritmo Genético Retroviral Iterativo**. 2010. 78 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Pará, Belém, 2010.
- NASTASI, G. et al. Implementation and comparison of algorithms for multi-objective optimization based on genetic algorithms applied to the management of an automated warehouse. **Journal of Intelligent Manufacturing**, Jan 2016. ISSN 1572-8145. Disponível em: <<https://doi.org/10.1007/s10845-016-1198-x>>.
- SIMÃO, Thiago Dias. **Utilização de Algoritmos Genéticos para Otimização de Soluções para o Timetabling escolar**. 2013. 73 f. Monografia (Graduação em Ciência da Computação) – Universidade de São Paulo, São Paulo, 2000.
- TIMÓTEO, Guilherme Tadeu Silva. **Desenvolvimento de um Algoritmo Genético para a resolução do Timetabling**. 2002. 144 f. Monografia (Graduação em Ciência da Computação) – Universidade Federal de Lavras, Belo Horizonte, 2002.
- SAPRU, V.; REDDY, K.; SIVASELVAN, B. Time table scheduling using genetic algorithms employing guided mutation. In: **2010 IEEE International Conference on Computational Intelligence and Computing Research**. [S.l.: s.n.], 2010. p. 1–4.
- SHEUNG, J.; FAN, A.; TANG, A. Time tabling using genetic algorithm and simulated annealing. In: **TENCON '93. Proceedings. Computer, Communication, Control and Power Engineering.1993 IEEE Region 10 Conference on**. [S.l.: s.n.], 1993. v. 1, p. 448–451 vol.1.
- SOUZA, Juliano da Silva de. **Uma aplicação do Simulated Annealing em Problemas de Corte de Estoque**. 2012. 72 f. Dissertação (Mestrado em Matemática Aplicada) – Universidade Estadual de Campinas, Campinas, 2012.
- SOYEMI, J.; AKINODE, J.; OLORUNTOBA, S. Electronic lecture time-table scheduler using genetic algorithm. In: **2017 IEEE 15th Intl Conf on Dependable, Autonomic and Secure Computing, 15th Intl Conf on Pervasive Intelligence and Computing, 3rd Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress(DASC/PiCom/DataCom/CyberSciTech)**. [S.l.: s.n.], 2017. p. 710–715.