



O USO DE MÉTODOS HEURÍSTICOS NA ALOCAÇÃO DE RECURSOS
DEFENSIVOS EM CENÁRIOS TÁTICOS

Mônica de Rezende

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Civil, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Civil.

Orientadora: Beatriz de Souza Leite Pires de Lima

Rio de Janeiro
Dezembro de 2014

O USO DE MÉTODOS HEURÍSTICOS NA ALOCAÇÃO DE RECURSOS
DEFENSIVOS EM CENÁRIOS TÁTICOS

Mônica de Rezende

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS EM
ENGENHARIA CIVIL.

Examinada por:

Prof.^a Beatriz de Souza Leite Pires de Lima, D.Sc.

Prof. Nelson Francisco Favilla Ebecken, D.Sc.

Prof.^a Solange Guimarães, D.Sc.

Prof. Elton Fernandes, Ph.D.

Prof. Hélio José Corrêa Barbosa, D.Sc.

RIO DE JANEIRO, RJ - BRASIL
DEZEMBRO DE 2014

Rezende, Mônica de

O uso de métodos heurísticos na alocação de recursos defensivos em cenários táticos/ Mônica de Rezende. - Rio de Janeiro: UFRJ/COPPE, 2014.

XV, 87 p.: il.; 29,7 cm.

Orientador: Beatriz de Souza Leite Pires de Lima

Tese (doutorado) – UFRJ/ COPPE/ Programa de Engenharia Civil, 2014.

Referências Bibliográficas: p. 81-87.

1. Otimização da Alocação de Recursos Defensivos.
2. Simulação de Cenários Táticos Navais. 3. Algoritmo ACS. I. Lima, Beatriz de Souza Leite Pires de. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Civil. III. Título.

“É fazendo que se aprende a fazer aquilo que se deve aprender a fazer”

Aristóteles

Aos meus pais José e Ana, ao meu esposo Luiz
César, às minhas filhas Patrícia e Juliana.

AGRADECIMENTOS

À Deus, pelo suporte espiritual necessário para cumprir mais esta etapa da minha vida.

À minha família pelo apoio incondicional demonstrado em todos os momentos e a compreensão pelo tempo que tive que dedicar a este trabalho.

À Prof.^a Beatriz S. L. P. de Lima pela confiança, orientação e incentivo, fundamentais para a conclusão deste trabalho.

À Prof.^a Solange Guimarães pela valiosa contribuição, pela análise e pelo tempo dispensado na elaboração do artigo.

Aos demais professores do PEC com quem tive contato, Prof. Nelson Francisco Favilla Ebecken, Prof. Luiz Bevilacqua e Prof. Alexandre Gonçalves Evsukoff, pelos seus ensinamentos.

Aos meus colegas de trabalho Rubens e José Gomes por terem me incentivado a iniciar esta jornada.

À equipe técnica do SSTT2, Mariângela, Márcio e Yuan, por tudo que aprendi com este projeto.

Aos meus chefes deste período, Cmte. Marins, Cmte. Andrada, Cmte. Sineiro e Cmte. André Chaves e à minha coordenadora Maria Odete, que ao longo destes anos me ofereceram apoio e suporte logístico.

Ao Cmte. César pelas ideias e seu conhecimento operativo.

Ao Instituto de Pesquisas da Marinha e à Marinha do Brasil por permitir a realização deste trabalho.

Agradeço também aos funcionários da secretaria do Programa de Engenharia Civil por sua atenção e presteza.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

O USO DE MÉTODOS HEURÍSTICOS NA ALOCAÇÃO DE RECURSOS DEFENSIVOS EM CENÁRIOS TÁTICOS

Mônica de Rezende

Dezembro/2014

Orientadora: Beatriz de Souza Leite Pires de Lima

Programa: Engenharia Civil

O problema da alocação de recursos defensivos é uma questão crucial para o planejamento das operações de defesa militares. O objetivo neste problema é definir a melhor forma de se alocar os recursos existentes contra um conjunto de múltiplas ameaças, de modo a reduzir ao máximo o nível de risco presente no cenário tático. Este problema é NP-Completo, ou seja, não se conhece uma solução exata temporalmente viável, capaz de lidar com todos os cenários possíveis. Apesar de muitos estudos baseados em abordagens analíticas e heurísticas já terem sido propostos, a maioria não se atém ao desempenho em tempo real das suas soluções, uma questão crítica nesta área.

Esta tese apresenta uma abordagem híbrida paralela para a resolução do problema de alocação de recursos, que atende as limitações temporais dos cenários de defesa aérea de grande porte. Esta abordagem combina um sistema de colônia de formigas com uma heurística determinística clássica. Os resultados obtidos demonstram a qualidade do seu desempenho, que possibilita uma expressiva redução dos níveis de risco iniciais, obedecendo às limitações temporais impostas pelas estratégias ofensivas deste tipo de cenário.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

THE USE OF HEURISTIC METHODS IN DEFENSIVE RESOURCE ALLOCATION OF TACTICAL SCENARIOS

Mônica de Rezende

December/2014

Advisor: Beatriz de Souza Leite Pires de Lima

Department: Civil Engineering

The weapon-target assignment problem is crucial for the planning of military defense operations. Its goal is defining the best way to assign defensive resources against a set of multiple threats, minimizing the risk present in tactical scenarios. This is a NP-complete problem where no exact solution is available to deal with all possible scenarios in reasonable computational time. Although many studies on different analytical and heuristic approaches to deal with this problem have been proposed, most of them do not show the real time performance of their solutions, a critical issue in this area.

This thesis presents a parallel hybrid approach for solving this resource assignment problem, which addresses temporal limitations of large air combat scenarios. This approach combines an ant colony system with a classical deterministic heuristic. Results obtained show the quality of its performance, which allowed an expressive reduction of initial threat levels, obeying time limitations of offensive strategies of this type of scenarios.

SUMÁRIO

| | |
|---|------|
| LISTA DE TERMOS..... | xiii |
| LISTA DE ABREVIATURAS E SIGLAS..... | xiv |
| 1 INTRODUÇÃO..... | 1 |
| 1.1 Contexto | 2 |
| 1.2 Motivação..... | 4 |
| 1.3 Objetivos e Contribuições | 6 |
| 1.4 Organização do Documento..... | 8 |
| 2 SISTEMAS TÁTICOS NAVAIS | 10 |
| 2.1 Introdução..... | 10 |
| 2.2 Comando e Controle (C2) | 10 |
| 2.2.1 Detecção e Acompanhamento dos Alvos | 12 |
| 2.2.2 Identificação dos Alvos | 14 |
| 2.2.3 Avaliação dos Alvos..... | 15 |
| 2.2.4 Alocação de Recursos..... | 18 |
| 2.3 Fusão de Dados..... | 20 |
| 2.3.1 Nível 0 | 23 |
| 2.3.2 Nível 1 | 23 |
| 2.3.3 Nível 2 | 24 |
| 2.3.4 Nível 3..... | 24 |
| 2.3.5 Nível 4 | 25 |
| 2.3.6 Nível 5 | 25 |
| 3 O PROBLEMA DE ALOCAÇÃO..... | 26 |
| 3.1 Introdução..... | 26 |
| 3.2 A Alocação de Recursos Defensivos..... | 27 |
| 3.2.1 Modelo Baseado em Alvo | 29 |
| 3.3 Métodos de Resolução do Problema SWTA | 31 |
| 3.3.1 Métodos Exatos..... | 32 |
| 3.3.2 Métodos Analíticos | 33 |
| 3.3.3 Métodos Heurísticos | 34 |
| 3.3.4 Metaheurísticas | 35 |
| 4 OS MÉTODOS DE BUSCA..... | 40 |

| | | |
|-------|--|----|
| 4.1 | Introdução..... | 40 |
| 4.2 | Método de Busca Exaustiva..... | 40 |
| 4.3 | Heurísticas Determinísticas..... | 42 |
| 4.3.1 | MMR1..... | 42 |
| 4.3.2 | MMR2..... | 44 |
| 4.4 | Heurísticas não Determinísticas..... | 45 |
| 4.4.1 | Ant Colony Optimization (ACO)..... | 46 |
| 4.4.2 | Ant Colony System (ACS)..... | 50 |
| 4.4.3 | Modelo ACS Sequencial..... | 52 |
| 4.4.4 | Modelo Greedy Ant Colony System (GACS)..... | 55 |
| 5 | ESTUDO DE CASO..... | 62 |
| 5.1 | Introdução..... | 62 |
| 5.2 | Simulação dos Cenários..... | 63 |
| 5.2.1 | Avaliação Temporal do Método de Busca Exaustiva..... | 64 |
| 5.3 | Avaliação de Cenários de Pequeno Porte..... | 67 |
| 5.4 | Avaliação de Cenários de Grande Porte..... | 71 |
| 5.4.1 | Parâmetro de Ajuste do ACS e do GACS..... | 71 |
| 5.4.2 | Resultados Obtidos..... | 72 |
| 6 | CONCLUSÕES..... | 77 |
| 6.1 | Trabalhos Futuros..... | 78 |
| | REFERÊNCIAS BIBLIOGRÁFICAS..... | 81 |

ÍNDICE DE FIGURAS

| | |
|--|----|
| FIGURA 2.1 - VISÃO FUNCIONAL DE UM SISTEMA DE DEFESA..... | 11 |
| FIGURA 2.2 – REPRESENTAÇÃO GRÁFICA DE UM CONTATO | 13 |
| FIGURA 2.3 – PMA ENTRE O PPN E O ALVO | 17 |
| FIGURA 2.4 – EXEMPLO DE ATAQUE AÉREO | 20 |
| FIGURA 2.5 – MÉTODOS DE FUSÃO | 21 |
| FIGURA 2.6 – MODELO JDL DE FUSÃO DE DADOS..... | 22 |
| FIGURA 4.1 - ALGORITMO DE BUSCA EXAUSTIVA DO PROBLEMA SWTA..... | 41 |
| FIGURA 4.2 – ALGORITMO MMR1 | 43 |
| FIGURA 4.3 – ALGORITMO MMR2 | 44 |
| FIGURA 4.4 – ALGORITMO ACO | 48 |
| FIGURA 4.5 - GRAFO DO PROBLEMA ESTÁTICO DE ALOCAÇÃO (SWTA) | 53 |
| FIGURA 4.6 - ALGORITMO ACS (JOHANSSON E FALKMAN, 2010B)..... | 54 |
| FIGURA 5.1 – NÍVEIS INICIAIS DE AMEAÇA DO CENÁRIO 9X9 | 69 |
| FIGURA 5.2 – VALORES DE REDUÇÃO DE AMEAÇA OBTIDOS PELOS ALGORITMOS BE, MMR1 E MMR2 PARA CADA UMA DAS 10 INSTÂNCIAS SIMULADAS PARA UM CENÁRIO 9X9 | 70 |
| FIGURA 5.3 – GRÁFICO DE BARRAS DOS NÍVEIS DE AMEAÇA INICIAIS E FINAIS DO CENÁRIO | 70 |
| FIGURA 5.4 - NÍVEIS DE AMEAÇA DO CENÁRIO 80X80 | 73 |
| FIGURA 5.5 – COMPARAÇÃO DOS RESULTADOS DO GACS E DO ACS | 74 |
| FIGURA 5.6 – COMPARAÇÃO DOS RESULTADOS DO GACS E DO MMR2 | 74 |

ÍNDICE DE TABELAS

| | |
|--|----|
| TABELA 4.1 - MODELOS DE TAXONOMIA PARA ACO PARALELO | 60 |
| TABELA 5.1- TEMPOS DE CPU DO ALGORITMO DE BUSCA EXAUSTIVA..... | 65 |
| TABELA 5.2– CARACTERÍSTICAS DE RECURSOS DEFENSIVOS TÍPICOS | 65 |
| TABELA 5.3 – DESEMPENHO DE RADARES DE VIGILÂNCIA TÍPICOS..... | 66 |
| TABELA 5.4 –TEMPOS DE REAÇÃO PARA AMEAÇAS NA REGIÃO ENTRE A EXTREMIDADE EXTERNA DO SETOR DE COBERTURA DO RADAR DE VIGILÂNCIA E A EXTREMIDADE EXTERNA DO SETOR DE COBERTURA DO SISTEMA DE DEFESA ANTIAÉREO | 66 |
| TABELA 5.5 –TEMPOS DE REAÇÃO PARA AMEAÇAS NO INTERIOR DO SETOR DE DEFESA | 67 |
| TABELA 5.6 - ÍNDICE DE SUCESSO DO MMR1 E DO MMR2 | 68 |
| TABELA 5.7 – RESULTADOS DOS ALGORITMOS: MMR1, MMR2, BE | 68 |
| TABELA 5.8 – RESULTADOS DOS ALGORITMOS: MMR1, MMR2, ACS E GACS..... | 72 |
| TABELA 5.9 – RESULTADOS DO MMR2 E DA VERSÃO SEMEADA E NÃO SEMEADA DO AG1. | 75 |
| TABELA 5.10 - RESULTADOS DO MMR2 E DA VERSÃO SEMEADA E NÃO SEMEADA DO AG2. | 75 |

LISTA DE TERMOS

- **Acompanhamentos:** objetos sintéticos do cenário tático, criados pelo computador a partir do processamento da medida de posição dos contatos capturados pelos sensores. Eles têm por objetivo fornecer ao operador uma apresentação gráfica de mais alto nível das informações obtidas pelos sensores.
- **Alvos:** contatos em que foi identificada a capacidade de executar algum tipo de ação que represente uma ameaça para a plataforma do navio militar ou para algum outro elemento de interesse no entorno da área de observação da plataforma.
- **Contatos:** objetos móveis capturados por sensores do navio, como o radar e o sonar, por exemplo.
- **Contramidas:** nome dados aos meios usados para enganar os sistemas de orientação de mísseis ou de torpedos das plataformas oponentes.
- **Despistadores:** alvos falsos e descartáveis lançados pelo navio militar. Seu objetivo é simular uma plataforma, confundindo assim os sistemas de defesa oponentes. Um exemplo de despistador é o *chaff*, um foguete usado para despistar mísseis guiados por radar, que após lançado libera uma nuvem de cargas metálicas próxima ao navio, de modo a confundir os sistemas de detecção.
- **Interferidores:** elementos que degradam a capacidade dos sensores oponentes pelo uso de interferências eletromagnéticas e geradores de ruídos.
- **Marcação:** ângulo existente entre o alvo e a plataforma de observação do cenário.
- **Próprio Navio:** plataforma em que se encontra o observador do cenário tático, responsável pelo processo de monitoração dos contatos através de sensores ativos e passivos.
- **Rumo:** ângulo horizontal entre uma direção de referência, normalmente o norte verdadeiro, e a direção para a qual aponta a proa do navio. Os rumos assumem valores entre 0° e 360° , no sentido do movimento dos ponteiros de um relógio.

LISTA DE ABREVIATURAS E SIGLAS

- ACO – Ant Colony Optimization
- ACS – Ant Colony System
- AG – Algoritmos Genéticos
- AIS – Automatic Identification System
- AS – Ant System
- BE – Busca Exaustiva
- C2 – Comando e Controle
- CPU – Central Processing Unit
- DPSO – Discrete Particle Swarm Optimization
- DWTA – Dynamic Weapon-Target Assignment
- GACS - Greedy Ant Colony System
- IFF - Identification Friend or Foe
- IHM – Interface Homem-Máquina
- JDL – Joint Directors Laboratory
- MB – Marinha do Brasil
- MMR – Maximal Marginal Return
- MN – Milha Náutica
- NCW - Network Centric Warfare
- NP – Nondeterministic Polynomial Time
- PAG – Problema de Alocação Generalizado
- PC - Portable Computer
- PMA – Ponto de Maior Aproximação
- PO – Pesquisa Operacional

- PPN – Próprio Navio
- PSO – Particle Swarm Optimization
- RAM – Random Access Memory
- ROE - Rules Of Engagement
- SWTA - Static Weapon-Target Assignment
- TE - Threat Evaluation
- TEWA - Threat Evaluation + Weapon Allocation (TE + WA)
- TO – Teatro de Operações
- TPMA – Tempo para PMA
- UDT_PMA – Unidades de Tempo para o PMA
- US DoD – United States Department of Defense
- WA – Weapon Allocation or Weapon Assignment
- WTA – Weapon-Target Assignment

1 INTRODUÇÃO

Desde o início dos tempos o ser humano procura ainda que de forma intuitiva extrair o melhor do ambiente e das circunstâncias que o cercam. O nível acirrado de competitividade existente em basicamente todas as atividades produtivas do mundo de hoje, fazem desta busca pela melhoria do desempenho e pela redução de custos, requisitos fundamentais para qualquer setor.

A abordagem matemática desta questão deu origem aos chamados problemas de otimização, onde o objetivo é a maximização ou a minimização da função objetivo usada para modelá-lo. Dada a abrangência do tema, exemplos práticos podem ser encontrados em diversas áreas da pesquisa, como a inteligência artificial, a pesquisa operacional (PO), as comunicações, a computação de alto desempenho.

A otimização combinatória difere dos casos de otimização clássicos por possuir um conjunto de soluções possíveis discretas, o que em tese possibilita a enumeração explícita de todo o espaço de busca (NEMHAUSER e WOLSEY, 1999). Esta característica não garante, no entanto, que a solução mais eficiente possa ser encontrada em um tempo computacional adequado à natureza do problema, pois o número de possibilidades a serem testadas pode ser muito grande. Por conta disto, muitos casos de otimização combinatória não possuem algoritmos que garantam a obtenção do ótimo absoluto para a forma generalizada do problema, em um tempo viável (polinomial), isto é, quando se considera tamanhos arbitrários do mesmo. A roteirização de veículos, o problema do caixeiro viajante, o problema da mochila, o problema da alocação generalizada, entre outros, são exemplos de problemas deste tipo.

A proposta deste trabalho é o desenvolvimento de um método heurístico eficiente para o tratamento de um problema de otimização combinatória do setor de sistemas de comando e controle navais, o problema da alocação de recursos defensivos em cenários táticos militares. O algoritmo proposto, dada à natureza crítica da aplicação, deve ser capaz de atender os objetivos formulados para o problema, chegando a níveis de redução de risco substanciais em tempo real, mesmo em cenários com alto nível de complexidade, o que dificulta a sua especificação.

1.1 Contexto

Nosso mar territorial tem grande influência na economia do país e também um papel estratégico significativo, é pelo mar que circulam cerca de noventa e cinco por cento das nossas importações e exportações, dele e de seu subsolo se extraem ainda diversos outros recursos, pertencentes a setores produtivos importantes, como o petróleo e o gás natural; a pesca e a aquicultura; os minerais metálicos e não metálicos.

O elevado montante de recursos extraídos e explorados ao longo do litoral demonstram a necessidade de se proteger a região de forma adequada, como parte integrante e inalienável do nosso território. Mas, o tamanho da área a ser monitorada é muito grande, o que é crítico para a manutenção da sua segurança e representa uma das nossas maiores vulnerabilidades.

Nos últimos anos, vem sendo verificado o incremento das notificações relacionadas a exploração ilegal da fauna marinha, ao contrabando de armas e drogas, a pirataria, ao despejo de materiais poluentes. Mas, estes crimes aparentemente comuns muitas vezes são usados de forma conjugada para atingir fins materiais e ideológicos de redes criminosas. Somado a estes fatores, observa-se ao redor do mundo, muitas disputas relacionadas a supremacia marítima comercial e militar, geradas respectivamente, pela progressiva escassez de recursos naturais e pelo crescimento das ameaças terroristas. O reconhecimento desta nova realidade tem obrigado os setores responsáveis a rever seus conceitos de proteção das fronteiras.

No mar não existem barreiras físicas, as fronteiras são definidas pela existência de navios ou aviões em patrulha realizando ações de busca, tornando estas atividades bem mais complexas que as similares realizadas em terra firme. Cada país tem a responsabilidade de fazer cumprir a lei nas suas próprias águas territoriais, não existindo muita cooperação entre as nações vizinhas, o que dificulta o combate, a captura e a penalização dos criminosos. A vigilância e a defesa da nossa costa ficam a cargo da Marinha do Brasil (MB). Os sistemas de monitoração dos veículos de patrulha devem ser capazes de realizar este policiamento, o qual pode evoluir para diversos tipos de ações táticas, como o apresamento, a interceptação, e em último caso, o uso de recursos defensivos.

Os navios da MB participam também de missões de apoio internacionais atuando em conjunto com forças navais amigas em diversas partes do globo. Os conflitos em alto mar não são mais comuns, o foco da área de defesa marítima agora é a atuação em regiões costeiras, que apresentam uma série de dificuldades para a realização de operações militares. Próximo ao litoral, geralmente existem pontos de concentração urbana, o que gera um tráfego mais intenso de barcos e aeronaves civis, além disto, as condições ambientais e meteorológicas costumam ser mais adversas. O litoral possui também a desvantagem de expor mais as tripulações aos ataques surpresa, pois facilita a execução de ofensivas realizadas por recursos de curto alcance, mais baratos e mais fáceis de se obter, disparados pelas chamadas ameaças assimétricas.

O termo ameaça assimétrica, significa que um dos lados não possui capacidade para enfrentar diretamente o seu oponente, necessitando fazer uso de logísticas e estratégias arrojadas para compensar sua carência de recursos. A história recente mostra que o caráter inopinado dos ataques provocados por este tipo de ameaça é capaz de alcançar resultados surpreendentes contra forças com muito maior potencial de reação. As ações assimétricas são desencadeadas normalmente por elementos ligados a grupos extremistas.

Melhorar a capacidade de reação em todas estas situações é uma questão de extrema importância, pois acidentes envolvendo perdas de pessoas ou recursos estratégicos geram impactos negativos à qualquer país, impondo uma pressão psicológica muito grande às tripulações das plataformas envolvidas nestas missões.

A busca por falhas de segurança deve sempre procurar identificar precocemente os pontos mais propícios à ocorrência de problemas, existindo consenso sobre a necessidade de se investir em sistemas de apoio totalmente ou parcialmente automatizados. O planejamento e a coordenação táticos não são tarefas triviais, mesmo quando se usa sistemas computadorizados. A globalização acabou com várias barreiras que existiam no passado, facilitando o acesso a uma grande gama de artefatos de uso militar, como armas, equipamentos, veículos, ou mesmo informações, que estão hoje disponíveis ao conhecimento público, a qualquer hora, em qualquer lugar, não sendo possível controlar o acesso ou evitar o uso inadequado.

A redução dos níveis de risco não é fácil, os agentes são muito variados, existindo uma enorme quantidade de possíveis cenários, lidar com toda esta complexidade é um dos grandes desafios do setor. Este conjunto de incertezas

impede que se garanta a eliminação completa de todos os fatores de risco, então, qualquer tipo de esforço usado para prevenir o surgimento de ameaças tem sempre que considerar a possibilidade da ocorrência de falhas.

Os sistemas mais modernos procuram não só identificar e classificar os alvos detectados pelos sensores, mas também prever seu comportamento de risco, capturando as relações existentes, fazendo análises comparativas que ajudem na aplicação criteriosa dos recursos de defesa. A dificuldade para identificar e classificar corretamente as ameaças nos sistemas tradicionais prejudica ou até inviabiliza, a adoção de medidas de reação adequadas, pois reduz o tempo disponível para o planejamento e a execução das mesmas (CASTRO, 2009).

O problema da alocação de recursos de defesa é crucial para a boa finalização do processo de tomada de decisão em operações táticas. Ele define a melhor forma de conter as ameaças presentes nos cenários. Este problema aparece em muitos estudos acadêmicos, sendo os primeiros datados de meados do século passado, mas, a constante evolução da tecnologia, das doutrinas e dos modelos usados nas operações mantêm as pesquisas nesta área bastante ativas até hoje.

A alocação de recursos defensivos pode ser voltada à proteção de uma única plataforma ou ser usada para a proteção de um grupo de plataformas. O estudo do comportamento dos algoritmos em cenários de maior complexidade advém da necessidade de se modelar missões em que se considera uma ampla distribuição de forças, uma rede de plataformas, todas atuando de forma colaborativa para anular múltiplas ameaças. A possibilidade de compartilhar dados coletados por unidades diferentes contribui para uma consciência situacional mais robusta e confiável, além de permitir o aumento da quantidade e da diversidade de recursos disponíveis. Este modelo de composição dos recursos, formando uma rede de plataformas de defesa integradas, está também no foco dos estudos mais recentes, sendo conhecido como Combate Centrado em Rede (*Network Centric Warfare - NCW*).

1.2 Motivação

Os países para atender as necessidades geradas por estes novos contextos, precisam submeter suas frotas e ambientes de treinamento a constantes procedimentos de modernização. O domínio da tecnologia nesta área se concentra nas nações do primeiro mundo, mas, a natureza da aplicação, impede que os sistemas de ponta destes países sejam comercializados. Os custos dos sistemas que

são disponibilizados para venda são muito elevados, além disso, estas unidades sempre sofrem de várias restrições tecnológicas. A manutenção evolutiva dos sistemas adquiridos é outro ponto também bastante delicado. Os países sem tradição neste tipo de desenvolvimento, necessitam então incentivar a formação de conhecimento científico próprio.

O Livro Verde, uma publicação do Ministério da Ciência e Tecnologia, resume bem esta questão no trecho a seguir:

“O conhecimento tornou-se hoje, mais do que no passado, um dos principais fatores de superação de desigualdades, de agregação de valor, de criação de emprego qualificado e de propagação do bem-estar. A nova situação tem reflexos no sistema econômico e político. A soberania e a autonomia dos países passam mundialmente por uma nova leitura, e sua manutenção, que é essencial, depende nitidamente do conhecimento, da educação e do desenvolvimento científico e tecnológico” (TAKAHASHI, 2000).

A MB possui um bom número de sistemas legados, trabalhos recentes publicados por seus pesquisadores estudaram alguns aspectos presentes nos sistemas táticos mais modernos, como a interceptação de alvos móveis em ambientes com obstáculos poligonais (GOUVÊA, 2012), e a fusão de dados táticos em ambientes de monitoração contínua (CARVALHO JUNIOR, 2010). A monitoração realizada pelos meios de patrulha envolve em última análise a defesa de instalações civis e militares espalhadas ao longo das regiões litorâneas, questão esta que ainda não tinha sido diretamente abordada.

Modelar de forma eficiente problemas desta natureza é importante não só para executar bem operações reais, mas, no caso do nosso país, principalmente para atender às diversas etapas que a precedem, como por exemplo: análise de processos (CRAMER, BEACH e MAZZUCHI, 2006), a análise de desempenho isolada ou conjunta dos recursos existentes, a avaliação de sistemas de suporte ou de defesa para fins de desenvolvimento e aquisição (PARK, KWON, et al., 2010), (BALCI, ARTHUR e ORMSBY, 2011), o treinamento tático especializado individual ou coletivo de operadores em cenários simulados (ZAVARELLI, DECHIARO, et al., 2006).

O desenvolvimento da terceira geração de um sistema de simulação tática e treinamento de grande porte, voltado ao adestramento no setor de comando e controle de equipes navais e aeronavais, motivou o desenvolvimento desta tese. O uso deste

tipo de simulação é muito importante, pois dá oportunidade às equipes de comando analisarem de forma controlada a eficiência e a eficácia das decisões tomadas em diferentes tipos de cenários de defesa. Vale ressaltar que este trabalho faz uma abordagem científica do assunto, não sendo apresentados dados ou estratégias associadas a operações reais.

1.3 Objetivos e Contribuições

Esta tese propõe um algoritmo competitivo voltado ao tratamento do problema de alocação de recursos defensivos (*Weapon-Target Assignment – WTA*), um problema crucial do planejamento de operações militares, que envolve a definição em tempo real dos meios mais adequados para conter alvos móveis classificados como ameaças.

Para cumprir esta meta, foram estudados os modelos de cenários táticos normalmente usados, sua formulação matemática, e os parâmetros de entrada necessários. As ameaças precisam ser contextualizadas dentro dos cenários, e esta contextualização é um dado de entrada do algoritmo que é realizado a priori. Ela envolve a determinação do grau de ameaça de cada alvo, o que permite a ordenação dos mesmos dentro do chamado Teatro de Operações (TO) da missão. A probabilidade de dano dos recursos usados para conter as ameaças é outro dado de entrada importante, pois define o efeito que cada recurso exerce sobre cada um destes alvos. Este valor depende do tipo de ameaça para a qual é designado.

Nas publicações existentes encontram-se propostas baseadas nos mais diferentes tipos de métodos de resolução. Neste trabalho é feita uma revisão sobre o assunto, focando heurísticas determinísticas clássicas e bio-inspiradas aplicadas ao problema de alocação de recursos defensivos. Após esta apresentação inicial, são selecionados alguns métodos, com o objetivo de se demonstrar a eficiência e a eficácia dos mesmos, com relação a um método exato de enumeração explícita. Uma vez qualificados, os métodos selecionados são usados como base de comparação para a análise de desempenho do algoritmo proposto.

O algoritmo desenvolvido nesta tese para tratar o problema de alocação de recursos militares, denominado GACS (*Greedy Ant Colony System*), faz a hibridização de uma nova variante do ACS (*Ant Colony System*) (DORIGO e GAMBARELLA, 1997), com uma heurística determinística gananciosa, o MMR (KOLITZ, 1988), buscando assim acelerar a convergência do algoritmo. Além disto, foi desenvolvida

ainda uma estratégia de ACO paralelo, que faz uso de múltiplas colônias de formigas que executam de forma independente e simultânea, a paralelização permite aumentar a diversidade da busca sem afetar os tempos absolutos, pois a busca dentro das populações de cada colônia evolui de forma distribuída e não cooperativa, com cada colônia procurando pela melhor solução concorrentemente.

As simulações estratégicas permitem explorar, repetir, refletir sobre decisões em diferentes contextos (PERLA e MCGRADY, 2011). As contribuições desta tese são voltadas principalmente às simulações táticas militares, habilitando o exercício de operações dentro das características presentes no panorama dos conflitos atuais. Mas, esta tese também contribui para o desenvolvimento de novos algoritmos para tratamento do problema de alocação de recursos. As contribuições estão resumidas na lista dada a seguir:

- Redução acentuada dos níveis de risco iniciais associados às ameaças presentes nos cenários táticos de conflito. O modelo desenvolvido atende aos requisitos tanto dos cenários aonde as condições de defesa são mais favoráveis, ou seja, o número de recursos é maior ou igual ao número de ameaças, mas, mais importante do que isto, também aos cenários em que ocorre o contrário.
- Capacidade de atender de forma adequada às limitações temporais impostas pelo planejamento de operações de defesa em cenários contendo ameaças aéreas com alto poder de manobra. As ameaças aéreas, devido as suas características são consideradas bastante críticas, sendo este tipo de operação um elemento importante dentro do contexto de aprendizado do simulador.
- Capacidade de atender de forma adequada ao planejamento de operações de defesa em cenários envolvendo ameaças assimétricas litorâneas caracterizadas por ofensivas com recursos aéreos de curto alcance, as quais também impõem limitações ao tempo de resposta.
- Capacidade de realizar o planejamento da alocação de recursos em cenários com alto nível de complexidade, atendendo às prerrogativas do simulador para o planejamento de operações aeronavais em rede (NCW). O modelo implementado obteve um bom desempenho em cenários envolvendo até 80 recursos e ameaças simultâneas, o que representa um resultado competitivo de redução dos níveis iniciais de ameaça, e coloca o GACS alinhado com o estado

da arte do desenvolvimento atual apresentado em publicações científicas sobre este tema.

- O modelo implementado também tem contribuição para a área de alocação de recursos em geral, pois possui fácil capacidade de adequação para outros tipos de problemas de alocação, fato que também é abordado ao longo do texto.

1.4 Organização do Documento

Este trabalho contém um total de seis capítulos. O primeiro capítulo faz a introdução do assunto, ele contém a descrição do contexto gerador da pesquisa, sua complexidade, motivação e as contribuições alcançadas.

O capítulo 2 é dedicado aos sistemas táticos navais, mais especificamente, os sistemas de defesa. O texto apresenta ao leitor um diagrama das principais funcionalidades deste tipo de sistema e a forma como elas se relacionam tanto internamente, como externamente com os sensores e sistemas de combate. As funcionalidades apresentadas seguem uma sequência de execução, esta ordem é mantida no texto, onde é feita uma breve descrição de cada uma. A alocação de recursos de defesa é a última funcionalidade do bloco, ela depende de informações obtidas e processadas nas etapas anteriores. O sistema tático de defesa é apresentado também sob a ótica de um modelo conceitual de Fusão de Dados, uma opção comum a muitos trabalhos da área militar, sendo feita uma correspondência com o diagrama apresentado inicialmente.

O capítulo 3 mostra os modelos matemáticos usados para representar os cenários táticos de combate. Este trabalho trata do caso estático de alocação de recursos baseado em alvo, existindo uma formulação específica associada a este caso. No mesmo capítulo é feita também uma revisão bibliográfica de métodos de resolução exatos, analíticos, heurísticos e das metaheurísticas voltadas ao tratamento do caso estático.

No capítulo 4 são descritos métodos heurísticos determinísticos e não determinísticos deste universo de problemas. Os métodos apresentados são usados posteriormente, como modelo de comparação na avaliação de desempenho do algoritmo GACS proposto nesta tese.

O capítulo 5 apresenta e analisa os resultados computacionais obtidos nas simulações realizadas com o intuito de avaliar o desempenho do algoritmo proposto, o GACS.

Por fim, no último capítulo, o capítulo 6, são feitas as considerações finais sobre o assunto, sendo enumeradas ainda uma série de propostas sobre os possíveis trabalhos que podem ser desenvolvidos futuramente nesta área de pesquisa.

2 SISTEMAS TÁTICOS NAVAIS

2.1 Introdução

Este capítulo situa o leitor com relação as características e conceitos presentes neste domínio de sistemas, apresentando as funcionalidades típicas associadas ao planejamento das operações de defesa navais, e a relação das mesmas com o problema de alocação de recursos tratado nesta tese. Os sistemas táticos navais reais ou simulados são usados na gestão das plataformas, sensores e equipamentos embarcados, ou seja, eles são responsáveis pelo ordenamento das forças em posições que as favoreçam, fornecendo apoio à tomada de decisões em diversos níveis da escala de comandos. O termo Comando e Controle, que intitula a primeira subseção, é muito usado para designar estes sistemas.

Os sistemas sofreram profundas mudanças ao longo das últimas décadas, o uso intensivo da computação permitiu automatizar total ou parcialmente diversas tarefas antes realizadas manualmente pelos operadores. Possuir a informação certa na hora certa é importante para qualquer ambiente, seja ele civil ou militar, e a automação proporciona uma melhora significativa neste quesito, mas com as novas tecnologias, surgiram também novos desafios.

Um problema derivado do desenvolvimento computacional é a sobrecarga de informações manipuladas e apresentadas em tempo real. A tecnologia de fusão de dados, surgiu primeiramente no meio militar, como um modelo capaz de conjugar as informações veiculadas e permitir a realização de inferências úteis sobre o conteúdo dos seus dados. Os modelos de Fusão de Dados propõem formas de se dividir o problema em diferentes níveis de abstração. A segunda subseção discorre sobre este assunto como um todo, mostrando o nível de abstração e processamento associado ao problema de alocação de recursos.

2.2 Comando e Controle (C2)

Os sistemas C2 envolvem todos os equipamentos, procedimentos e pessoal necessários para que um comandante possa fazer o planejamento, o direcionamento e o controle das missões. Estes sistemas dependem, portanto, do funcionamento integrado de diversas funcionalidades, sendo as principais: a detecção através de

sensores dos alvos presentes na área ao redor da unidade, o acompanhamento automático destes alvos através da estimação da sua rota de deslocamento, a identificação das plataformas dos alvos, a avaliação do grau de hostilidade de cada um, e por fim, a alocação dos recursos de defesa cabíveis para conter as ameaças identificadas (BENASKEUR, BOSSÉ e BLODGETT, 2007).

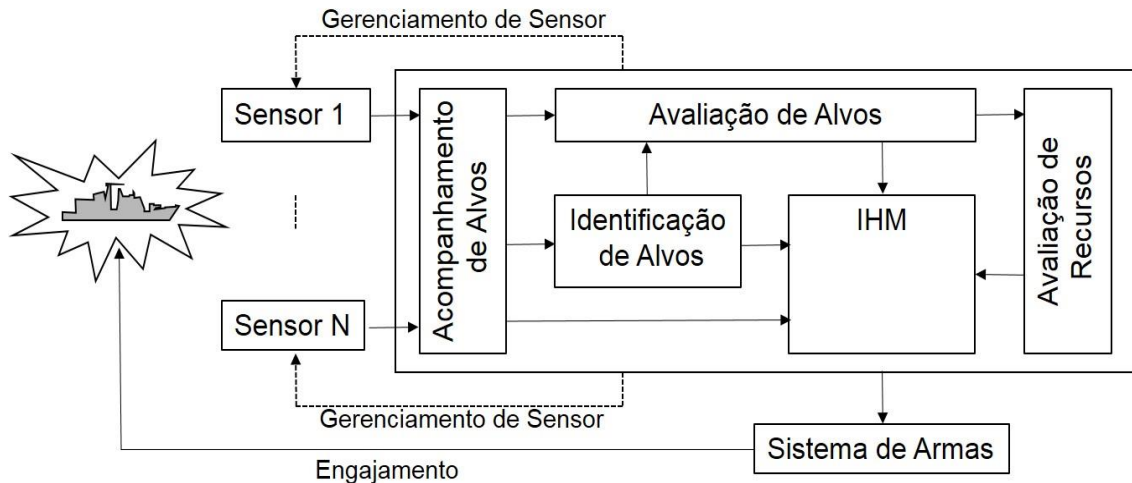


Figura 2.1 - Visão Funcional de um Sistema de Defesa
(JOHANSSON e FALKMAN, 2010b)

A Figura 2.1 (JOHANSSON e FALKMAN, 2010b), mostra como as funcionalidades citadas se relacionam dentro do sistema de defesa. Estas funcionalidades são as responsáveis pela compilação do panorama tático, sendo seu objetivo final construir uma imagem sintética consolidada do cenário em que a unidade está inserida (LLINAS e HALL, 2001). Esta imagem sintética é visualizada pelos operadores através da Interface Homem-Máquina (IHM) do sistema, e busca melhorar a consciência situacional dos operadores, facilitando a compreensão da evolução da missão.

Existem diferentes níveis de operadores participando das operações e interagindo com o sistema, se não houver uma integração adequada, toda a operação pode ser prejudicada. O relacionamento direto com a parte cognitiva do processo de tomada de decisão é de extrema importância em ambientes aonde existe um fluxo de informações e um potencial de risco muito elevados. Nestes ambientes é necessário haver um grau de sinergia bastante forte entre os vários tipos de operadores do sistema, as doutrinas táticas estabelecidas e a tecnologia do sistema de informação, propriamente dito.

A alocação de recursos defensivos está na extremidade final do processo de comando e controle, ela depende dos resultados fornecidos pelas etapas anteriores. As ações desempenhadas por cada funcionalidade do sistema, possuem uma relação de compromisso entre si, quanto mais tempo se gasta com a avaliação dos alvos, por exemplo, menos tempo sobra para a escolha dos recursos de defesa mais adequados.

Outra limitação, é que para se realizar uma boa avaliação, é necessário gastar um certo tempo com a coleta de dados relevantes, o problema é que o montante de tempo consumido nesta tarefa, não diminui de forma proporcional com a evolução do cenário, pois parte dos dados está ligada ao comportamento dinâmico dos alvos, como por exemplo, a sua velocidade e posição. Um caso típico, usado para exemplificar uma situação operativa crítica, é o controle aéreo civil ou militar, pois as plataformas aéreas possuem um alto grau de mobilidade, podendo sofrer mudanças muito bruscas em intervalos de tempo bastante reduzidos, o que exige agilidade do ambiente computacional usado na sua monitoração (BENASKEUR, BOSSÉ e BLODGETT, 2007).

Roux e Van Vuuren (2008) resumem assim as dificuldades associadas à tomada de decisão nestes ambientes:

- Disponibilidade de intervalos de tempo muito pequenos para a realização de inferências por vezes bastante críticas sobre a evolução dos cenários nestes tempos (Ex.: Ataque aéreo).
- Inexistência de uma ontologia que forneça a especificação dos objetos e classes pertencentes a este domínio.
- Dificuldade para modelar as relações de causalidade existentes entre as atividades executadas pelos alvos ao longo do tempo, prejudicando a construção de um histórico comportamental dos mesmos e a consequente identificação das situações de risco associadas a cada um.

2.2.1 Detecção e Acompanhamento dos Alvos

Os navios como qualquer veículo móvel, dependem de vários sensores e equipamentos para realizar as suas atividades de forma segura. Os sensores típicos usados nesta fase são: os radares de vigilância, os sonares, os sensores óticos, os sensores infravermelhos (ROUX e VUUREN, 2008). A qualidade da detecção dos alvos depende diretamente da qualidade dos sensores usados pelo navio.

Os elementos capturados por cada sensor são mostrados de forma simbólica no ambiente computacional do sistema. Estes cenários sintéticos são uma representação gráfica de mais alto nível das condições ambientais, formações geográficas e contatos móveis reais detectados pelos sensores. Os objetos associados aos contatos detectados são denominados acompanhamentos do sistema. Os acompanhamentos são objetos criados pelo computador a partir do processamento da medida de posição obtida pelos sensores. Após a detecção é necessário acompanhar a movimentação destes elementos. A correlação de sucessivas medidas de um mesmo contato móvel permite que o sistema extrapole seus dados de cinemática (velocidade e rumo), e faça o cálculo automático da sua posição futura.

A monitoração dos acompanhamentos é uma tarefa que deve ser feita de forma contínua, em tempo real, as regiões a serem monitoradas podem ser bastante amplas, podendo portanto, existir um grande número de elementos para ser acompanhado. Para facilitar a diferenciação, na representação dos acompanhamentos são empregados símbolos, cores e caracteres alfanuméricos de identificação, que evidenciam o ambiente tático (submarino, superfície, aéreo), o tamanho, os dados de cinemática de cada um. Dependendo do nível de sofisticação dos algoritmos internos do sistema, diversos tipos de informação podem ser agregados à representação dos mesmos, reduzindo a carga de trabalho dos operadores e possibilitando a evolução mais coordenada e automatizada das missões.




Figura 2.2 – Representação gráfica de um contato

A Figura 2.2 dá um exemplo de uma possível simbologia para a representação de um acompanhamento radar de superfície (elemento retangular), identificado de forma única pelo Número de Acompanhamento (NA=3304), a marcação em graus (306°) e a distância (44.41 MN) em Milhas Náuticas com relação ao Próprio Navio (PPN), a velocidade (17 Nós) e o rumo (160°) de deslocamento.

O termo alvo, que aparece nos blocos da Figura 2.1, caracteriza o acompanhamento em que foi identificada a capacidade, a possível intenção ou a oportunidade para efetuar atos que possam ameaçar a integridade da própria unidade

ou de algum outro acompanhamento ou instalação de interesse dentro do panorama tático da unidade.

2.2.2 Identificação dos Alvos

A identificação automatizada é uma tarefa complexa, pois é necessário transformar o conjunto de atributos reunidos sobre cada alvo em um identificador único do seu tipo de plataforma. Os alvos são elementos dinâmicos, não sendo possível prever a evolução dos valores dos atributos que influenciam neste processo. Para se concluir de modo seguro que a plataforma de um acompanhamento possui um determinado perfil de risco é necessário coletar dados provindos de vários canais independentes, obtidos tanto de sistemas e equipamentos embarcados, como de fontes externas.

Os sensores radar e sonar ativo, usados no processo de detecção, são exemplos de sistemas embarcados não cooperativos que contribuem no processo de identificação. Seu princípio básico de funcionamento consiste na emissão de ondas. Estas ondas se propagam pelos ambientes em que estes sensores operam e ao encontrar um obstáculo, retornam, evidenciando a presença de um possível alvo. A medida de determinadas características do sinal de retorno é usada para inferir atributos dos objetos detectados. A medida da seção reta radar, por exemplo, é usada na avaliação do tamanho da plataforma do contato detectado pelo radar.

O sonar passivo é um sensor que não emite sinais, ele apenas captura os sinais acústicos emitidos pelos alvos presentes no cenário. Neste sensor, a identificação das plataformas é feita pela análise do grau de similaridade existente entre os sons provenientes de um determinado contato do cenário e, os sons característicos associados a navios de diferentes classes.

Todas estas informações são submetidas a algoritmos internos para reconhecimento de padrões, dentre as principais técnicas usadas por estes algoritmos, temos: a abordagem baseada em modelos probabilísticos, a abordagem neuronal baseada em redes neurais artificiais, a abordagem difusa que considera o grau de incerteza inerente aos atributos coletados, a abordagem sintática, baseada na definição de uma estrutura de padrões e inter-relações entre as características coletadas.

Na identificação das plataformas é necessário extrair dos sinais capturados as informações que estão associadas a ruídos e outros elementos presentes no ambiente. Em (OLIVEIRA, LIMA e EBECKEN, 2014), (OLIVEIRA, 2010), a classificação de contatos do sonar passivo é baseada na análise multimodos. Esta ferramenta é usada para gerar um modelo de assinatura acústica compacto e robusto ao ruído de fundo, dispensando a necessidade de um especialista no processo de classificação.

A adoção de códigos de resposta padronizados entre as unidades também ajuda os sistemas táticos a identificar os alvos de forma cooperativa. O IFF (*Identification Friend or Foe*) e o AIS (*Automatic Identification System*), são exemplos de sistemas embarcados cooperativos usados na identificação de aeronaves e embarcações civis e militares, respectivamente. Estes sistemas podem ser usados também para auxiliar o processo posterior de avaliação.

O uso de todas estas fontes de dados busca evitar erros provenientes tanto de falsos alarmes, como de subavaliações, já que muitas vezes as ameaças se ocultam atrás de perfis similares aos padrões considerados normais, visando com isso dificultar a sua identificação.

2.2.3 Avaliação dos Alvos

A avaliação dos alvos visa determinar o grau de risco que cada um representa para uma Força Naval ou para o PPN. Esta funcionalidade depende obviamente da identificação prévia do mesmo. A funcionalidade pode ser sumarizada como (PARADIS, BENASKEUR, *et al.*, 2005), (BENASKEUR, BOSSÉ e BLODGETT, 2007):

“O contínuo processo de se determinar se uma entidade tem a intenção de infligir baixas ou danos às forças de defesa e a seus elementos de interesse, junto com a ordenação dessas entidades de acordo com o nível de ameaça que cada uma representa.”

Os sistemas C2 normalmente só calculam o grau de ameaça dos acompanhamentos identificados como inimigos ou como desconhecidos suspeitos. A definição dos graus de ameaça depende da análise combinada de diversos atributos, sendo estes atributos em princípio, os mesmos usados nos processos anteriores de identificação e acompanhamento. A combinação dos atributos geralmente é feita de forma ponderada segundo alguma estratégia específica, de modo que quanto maior o

valor resultante desta composição, maior o grau de ameaça do alvo. Os valores destes atributos normalmente não são fixos, precisando ser constantemente reavaliados. Em cenários com uma densidade muito grande de alvos é mais difícil diferenciar e ordenar os mesmos.

O contexto tático em que uma ação se desenvolve também influi na avaliação de risco. As regras de engajamento, mais conhecidas pelo nome inglês *Rules of Engagement* (ROE), ditam a doutrina a ser seguida durante as missões. Em operações de aparente rotina pode haver um relaxamento maior quanto ao nível de influência de determinados parâmetros, condição oposta à que deve ser aplicada em situações de conflito explícito.

Alguns autores sugerem que a seleção dos atributos seja feita segundo dois critérios principais: a capacidade de imposição de dano e a intenção (NAEM e MASOOD, 2010). O primeiro critério está associado à identificação do tipo da plataforma do alvo, este dado pode ser obtido de diversos modos: através de informações provindas de outras unidades ou de um centro de monitoração; através de deduções feitas a partir de informações coletadas pelos sensores, como o seu tamanho, ou através do reconhecimento de padrões de emissão dos seus sensores de bordo.

O segundo critério, a intenção, depende também da análise do comportamento dinâmico do alvo. Dentre os fatores normalmente considerados estão: a realização de manobras bruscas, modificando os parâmetros de deslocamento de forma significativa (velocidade, direção e altitude); a resposta (ou ausência de resposta) aos equipamentos de interrogação automática cooperativos (IFF / AIS); a detecção de emissões características de sistemas de direção de tiro; a detecção de sistemas de guerra eletrônica; o nível de conformidade com as rotas comerciais de navios e aeronaves civis, etc.

Algumas propostas usam um terceiro critério, a oportunidade (LITTLE e ROGOVA, 2006), associado à relação espaço-temporal das unidades para com os alvos. Neste critério se avalia a relação entre o provável alcance do sistema de armas do lado oponente e a distância deste até o PPN ou as instalações sob proteção. Alvos posicionados fora das margens de segurança possuem um maior grau de periculosidade.

Um outro critério de oportunidade mais genérico e bastante usado, é a proximidade (JOHANSSON e FALKMAN, 2008), obtido diretamente pelo cálculo da

distância entre o alvo e o PPN ou, entre o alvo e as instalações sob proteção. A extrapolação do Ponto de Maior Aproximação (PMA) existente entre eles também é considerado como um indicador de proximidade.

O uso do PMA em avaliações táticas é uma prática comum. Os cálculos são baseados nos dados de cinemática correntes dos elementos envolvidos. A Figura 2.3 demonstra graficamente este cálculo tático.




Figura 2.3 – PMA entre o PPN e o Alvo
(JOHANSSON e FALKMAN, 2008)

O Tempo gasto para alcançar o PMA (TPMA), calculado conforme a Eq. (2.1), serve para ponderar os casos em que os alvos são do mesmo tipo e possuem o mesmo PMA. O TPMA determina o alvo que alcança o PMA mais rapidamente, indicando assim aquele que representa uma ameaça maior naquele instante. Em todos estes cálculos se considera que os elementos se deslocam em movimento retilíneo uniforme, mantendo seu rumo e velocidade constantes.

$$TPMA = \frac{\text{distância entre o alvo e o PMA}}{\text{velocidade do alvo}} \quad (2.1)$$

Outro possível parâmetro indicador de oportunidade, é o tempo gasto pelo alvo, caso este após alcançar o PMA, realize uma manobra de 90 graus em direção ao PPN ou em direção às instalações sob proteção. Este tempo, calculado conforme a Eq. (2.2), é denominado de Unidades De Tempo do PMA (UDT_PMA).

$$UDT_{PMA} = \frac{\text{distância do PMA até a força ou o PPN}}{\text{velocidade atual do alvo}} \quad (2.2)$$

O somatório dos tempos TPMA e UDT_PMA, representa em última análise o tempo para os dois elementos colidirem.

Os critérios descritos podem ser usados tanto de forma isolada como conjunta, eles geram valores individuais que indicam o grau de hostilidade de cada alvo. Os valores resultantes desta análise são colocados em uma lista ordenada de graus de ameaça, para que o sistema possa comandar as medidas cabíveis.

Não existe uma definição amplamente aceita sobre o que deve ser usado, existe apenas um certo consenso quanto à necessidade de se analisar pelo menos alguns destes atributos. Vários tipos de propostas já foram publicados, baseados por exemplo, na ponderação direta de parâmetros (LIEBHABER e SMITH, 2000), na lógica difusa (LIANG, 2007) e em redes bayesianas (JOHANSSON e FALKMAN, 2008).

Cada proposta estabelece um modelo para a representação dos cenários a que as unidades ficam expostas. Os valores calculados podem ser usados para outros fins, além da alocação de recursos de defesa, servindo por exemplo, para o gerenciamento dos sensores mais adequados para acompanhar os alvos com maior grau de ameaça, ou para o gerenciamento de risco, pela identificação dos pontos em que as unidades podem ficar mais sujeitas a ataques, devido a concentração de ameaças em uma determinada região.

2.2.4 Alocação de Recursos

A forma como os recursos defensivos são alocados e o tipo de ameaças a ser enfrentado mudou, existindo hoje uma tendência para a realização de operações táticas centradas em rede (NCW). Este tipo de operação se apoia no uso combinado de informações e recursos de diferentes plataformas, permitindo o melhor aproveitamento de todos estes elementos, que são gerenciados por unidades de comando e controle centrais. O compartilhamento dos recursos e dados entre as unidades possibilita a realização de operações de maior porte, havendo um aumento significativo da quantidade de recursos manipulados. As operações junto ao litoral, propiciam também a existência de um grande número de ameaças, devido as possibilidades logísticas proporcionadas por este tipo de região, que habilita o uso de recursos de curto alcance.

A tecnologia atual disponibiliza recursos com capacidade para a realização de operações de longa distância, mas, esta vantagem tática é subutilizada, pois os sistemas não possuem ainda boas condições para identificar e classificar automaticamente ameaças situadas a longas distâncias. Algumas ameaças só são detectadas e classificadas segundos antes da sua entrada nas fronteiras da área de proteção limitando o alcance das operações a praticamente à linha de visada da unidade. A pressão imposta ao processo decisório e a reduzida quantidade de ciclos ofensivos, derivados destas situações, pode levar a alocação ineficiente dos recursos existentes nos poucos ciclos ainda viáveis.

Os algoritmos de alocação de recursos para a resolução de problemas defensivos em cenários táticos, devem ser capazes de planejar e produzir respostas de qualidade dentro dos limites temporais reduzidos impostos pelas formas de operação descritas, associadas ao aumento significativo das dimensões dos novos cenários de operação em rede, às limitações dos processos de identificação automática e ao aumento dos conflitos assimétricos.

O setor de defesa aérea é o que mais se ressentir destas limitações. A velocidade das ameaças aéreas atuais é muito elevada, deixando o tempo de reação disponível para os operadores definirem sua forma de atuação muito curto, da ordem de segundos. Esta situação é crítica, mesmo para sistemas de defesa aérea automáticos ou semiautomáticos, considerados essenciais nos cenários de maior complexidade. Os sistemas de defesa aérea são mais conhecidos pela sigla inglesa TEWA (*Threat Evaluation & Weapon Allocation*), nome que ressalta duas funcionalidades dos sistemas C2, a avaliação dos alvos e a alocação de recursos defensivos.

A Figura 2.4 ilustra um caso de ataque aéreo isolado, onde a ameaça é um míssil antinavio com capacidade de voo rasteiro, ou seja, voo próximo à superfície do mar, e que se desloca em direção ao PPN. Este perfil de voo dificulta a detecção do alvo pelo radar de vigilância, fazendo com que só seja percebido quando já está dentro da linha do horizonte do navio. A ilustração indica o míssil sendo detectado a cerca de 12 Km do PPN. Na situação mostrada neste exemplo, o sistema tem cerca de 20 segundos para adquirir o contato pelo radar de tiro, computar a previsão de tiro, posicionar o armamento e abrir fogo.

Este tipo de ataque pode ser disparado a partir de pontos de terra, de outros navios ou de aeronaves. Os mísseis antinavio são considerados uma das principais ameaças para as unidades navais atuais.

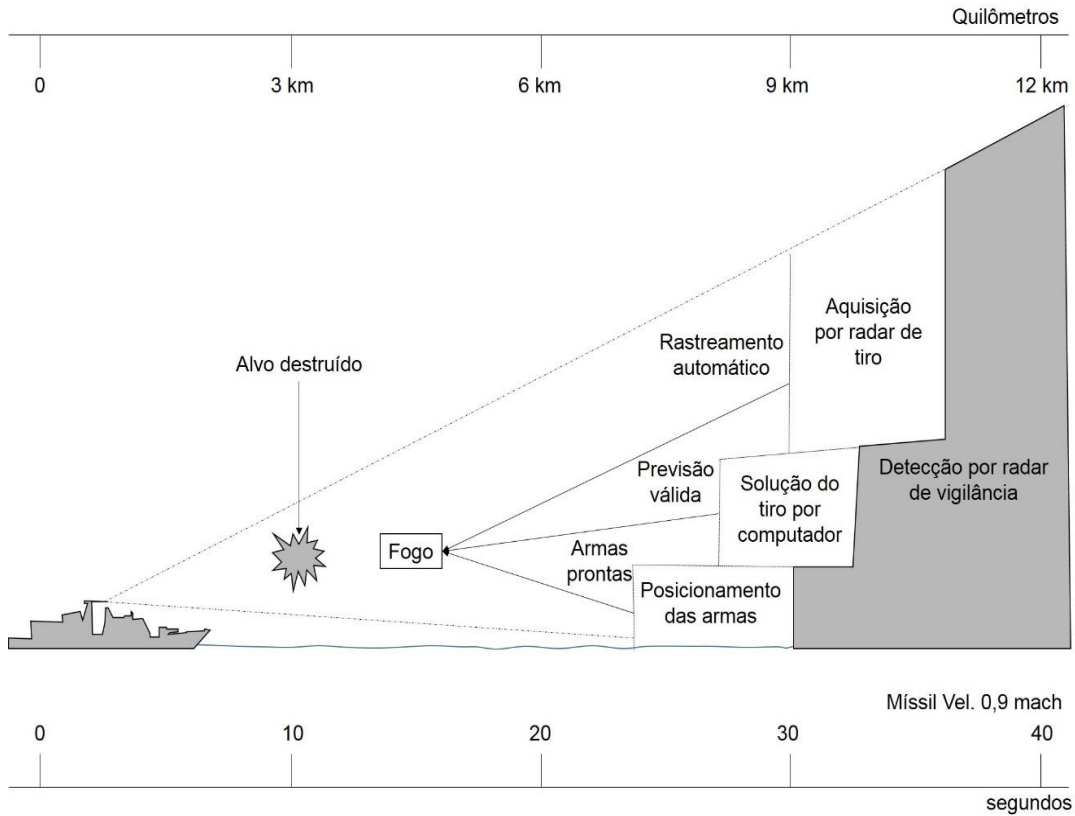


Figura 2.4 – Exemplo de ataque aéreo
(GUERRA DE COMANDO & CONTROLE, 2014)

2.3 Fusão de Dados

A realização de inferências a partir da conjugação de vários itens de dados permeia toda atividade cognitiva e também praticamente todos os enfoques automatizados para a utilização da informação. Os sensores e os demais equipamentos usados como fonte de dados nos sistemas C2 capturam e sinalizam, em tempo real, mudanças nos parâmetros por eles observados. Todos estes elementos apresentam limitações e os dados obtidos por eles normalmente são incompletos, imprecisos, inconsistentes, ambíguos, ou então, alguma combinação destas opções.

A Fusão de Dados é a tecnologia usada na manipulação dos dados que transitam nos sistemas táticos militares. O uso da fusão de dados é a opção natural

para reunir as informações coletadas pelos sensores e se chegar a conclusões úteis com relação às mesmas. A fusão além de ajudar a compor uma visão mais precisa do cenário pode reduzir também os custos associados à obtenção dos dados. O uso de técnicas de fusão de dados apropriadas pode compensar até certo nível, a existência de equipamentos mais baratos e conseqüentemente mais imprecisos (FACELI, CARVALHO e REZENDE, 2005). Devido as características físicas e as deficiências de cada sensor, os sistemas embarcados precisam adotar diferentes estratégias de fusão simultaneamente.

Para facilitar a compreensão e o gerenciamento das estratégias de fusão foram propostos vários modos de se classificar as mesmas. JOSHI e SANDERSON (1999) propuseram o modelo simplificado mostrado na Figura 2.5. Nesta proposta, os dados coletados são agrupados segundo um dos seguintes métodos: complementar, competitivo, cooperativo.




Figura 2.5 – Métodos de Fusão
(JOSHI e SANDERSON, 1999)

No método complementar são usadas fontes de dados que capturam características diferentes do ambiente, ou seja, cada fonte contribui com um percentual das informações necessárias para a compreensão unificada do cenário. No método competitivo as fontes possuem alcances e funcionalidades sobrepostas, ou seja, elas detectam o mesmo dado. Neste caso o processo de fusão se desenvolve como uma espécie de competição, sua principal vantagem é aumentar a confiabilidade pela redundância dos dados e a redução das incertezas inerentes à detecção individual feita por cada fonte. O terceiro método considera o trabalho cooperativo,

neste modelo o processo de fusão é feito através da triangulação das informações fornecidas por cada fonte.

No meio militar surgiram os primeiros esforços para se implementar Sistemas de Fusão de Dados, vindo daí um modelo bastante difundido no meio, conhecido como Modelo JDL (*Joint Directors of Laboratories*) de Fusão de Dados. Este modelo foi apresentado por membros de laboratórios do Departamento de Defesa dos Estados Unidos (*United States Department of Defense – US DoD*), nele o processo de fusão foi separado inicialmente em cinco níveis de abstração, seu modelo de dados foi apresentado inicialmente em 1987. O modelo JDL foi revisado algumas vezes, em 1998 foi acrescentado mais um nível de abstração ao mesmo, formando então um total de seis níveis de fusão (STEINBERG, BOWMAN e WHITE, 1999).

A forma de distribuição das funções pelos níveis do modelo JDL considera que a fusão de dados é alcançada através de um contínuo processo de refinamento. A Figura 2.6 apresenta os seis níveis do modelo e identifica o objetivo principal de cada um.

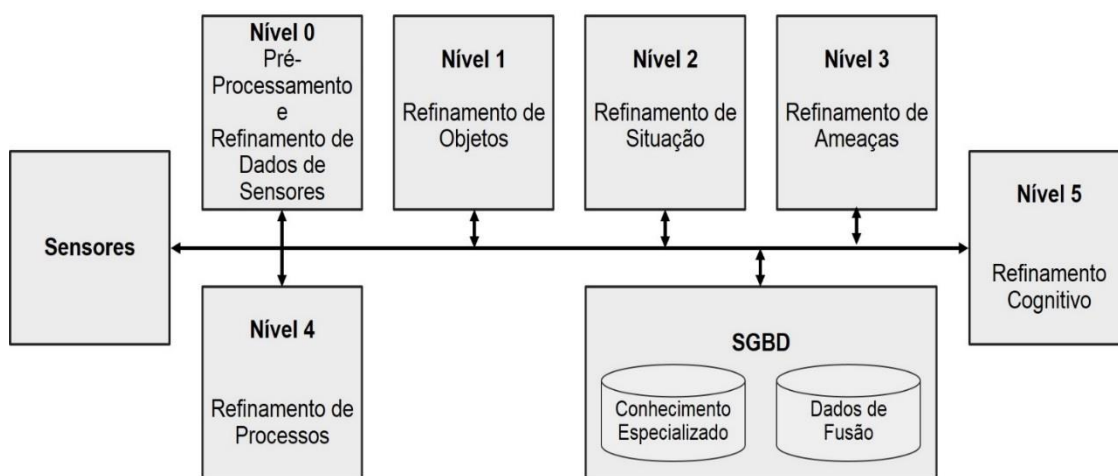


Figura 2.6 – Modelo JDL de Fusão de Dados (STEINBERG, BOWMAN e WHITE, 1999)

O modelo JDL, devido as suas próprias origens, possui maior afinidade com o tema desta tese. No texto seguinte à ilustração é feita uma descrição sucinta das funcionalidades desempenhadas por cada um destes seis níveis, e sempre que possível, é feito um paralelo entre estes níveis e as funcionalidades dos sistemas C2 descritas anteriormente.

2.3.1 Nível 0

Este nível é responsável pelo pré-processamento e pelo refinamento individualizado das informações analógicas ou digitais coletadas por cada sensor ou obtidas de base de dados, preparando os dados para os processos de fusão realizados nos próximos níveis.

A natureza dos procedimentos aplicados pode ser bastante variada, e depende das características individuais destes elementos. O processamento realizado refere-se a ações como: a conversão dos dados (analógica / digital), as translações de espaço (fase / frequência / amplitude), a conversão de unidades, a filtragem de ruídos e todos os demais tratamentos necessários à identificação de informações válidas associadas à leitura e ao processamento dos dados fornecidos na interface física dos elementos com o sistema.

2.3.2 Nível 1

Neste nível ocorre o refinamento das informações associadas aos objetos capturados, havendo a fusão dos dados obtidos por vários sensores. O processamento conjunto dos dados permite a realização de estimativas mais confiáveis e precisas, confirmando a existência do alvo. A estimação da localização, da velocidade e do rumo de deslocamento (dados de cinemática) do alvo, bem como da sua identidade são exemplos de funções realizadas neste nível.

Antes de se fundir os dados é verificada a necessidade de se alinhar as informações, pois cada fonte pode usar um sistema de referência espacial e temporal diferente. Após o alinhamento é verificada a existência de objetos superpostos, de modo a caracterizar os elementos reais presentes no cenário tático. Os objetos resultantes deste processo de associação e correlação de diferentes medidas são chamados de acompanhamentos.

A mudança de posição de cada acompanhamento é controlada pelo sistema, isto permite a estimação dos dados de cinemática e a extrapolação automática de sua trajetória. Algoritmos de reconhecimento de padrões podem ser usados para inferir outros atributos dos alvos, facilitando assim a estimação da sua identidade (HALL e MCMULLEN, 2004). O nível 1 realiza então o acompanhamento e a identificação dos alvos detectados pelos diversos sensores.

2.3.3 Nível 2

Este nível faz o refinamento da situação tática, ele procura interpretar e descrever o contexto das atividades realizadas por cada objeto do cenário, aumentando a consciência situacional dos operadores. Para cumprir esta tarefa são usados dados individuais dos alvos, informações sobre os relacionamentos existentes entre os alvos e informações sobre os relacionamentos destes com o ambiente.

Uma funcionalidade importante é a detecção e a associação de eventos e atividades em curso no cenário. Muitas informações podem ser deduzidas a partir da observação do comportamento individual ou coletivo dos acompanhamentos, como por exemplo, a identificação de padrões de formatura, a identificação de manobras táticas de ataque, a detecção de padrões de comunicação que possam indicar o estabelecimento de uma cadeia de comandos entre os alvos, etc.

Outra funcionalidade importante é a agregação dos atributos obtidos no nível anterior e no atual, visando a dedução da intenção ou da capacidade de um acompanhamento ou de um grupo de acompanhamentos impor danos, ou seja, identificar e avaliar parcialmente as ameaças ou possíveis ameaças presentes no cenário, transformando as estimativas independentes acerca de um objeto em um ente de mais alto nível, inserido no contexto do cenário atual observado.

2.3.4 Nível 3

O nível 3 faz o refinamento das informações acerca das ameaças identificadas estabelecendo hipóteses sobre a evolução do contexto inferido no nível anterior. Ele procura assim prever as consequências, o risco ou o custo associado a evolução dos eventos em curso, ou seja, faz a análise de impacto associada às condições atuais.

A avaliação de ameaças pertence essencialmente a este nível, nele são aplicados os critérios de avaliação de ameaça mencionados na descrição dos sistemas C2: estimativa/agregação da capacidade dos alvos, análise das intenções deduzidas a partir da sequência de manobras e ações realizadas pelos alvos, compreensão das possibilidades táticas e logísticas dos alvos.

Neste nível se encontra também a alocação de recursos defensivos. A partir do cenário corrente, após a avaliação dos alvos segundo seu grau de periculosidade, são verificadas as implicações associadas ao confronto direto contra os mesmos, estabelecendo-se os danos que podem ser impostos às ameaças, ou as perdas que

podem ser sofridas pelo PPN ou pelas unidades e instalações amigas (ROUX e VUUREN, 2007).

2.3.5 Nível 4

No nível 4 ocorre o refinamento dos processos ligados ao monitoramento da evolução dos objetos do cenário como um todo. O intuito deste nível é melhorar a utilização das fontes de informação e dos sensores, sugerindo a redefinição ou redirecionamento dos elementos usados na obtenção de informações dos níveis anteriores. O nível pode também detectar falhas em equipamentos.

O ajuste dos parâmetros internos de controle dos algoritmos usados pelos níveis de 1 a 3 é outro exemplo de funcionalidade passível de ser implementada, e que representa um tipo de correção de mais alto nível.

Para a definição dos processos mais adequados são usados tanto dados locais obtidos dos níveis anteriores, como informações baseadas em estratégias e doutrinas mais gerais. A medição da efetividade das ações de defesa executadas pertence a este nível.

2.3.6 Nível 5

Este nível trata do refinamento da parte cognitiva associada a avaliação humana do cenário e dos dados fundidos pelo sistema em tempo real. Os sistemas C2 trabalham em conjunto com diversos sensores e equipamentos operados ou de forma autônoma, ou por um ou mais operadores. Os dados provenientes dos sensores e equipamentos são fundidos formando um cenário sintético global, que deve representar a situação tática corrente de forma compreensiva. Existe uma classe de operadores dedicada ao gerenciamento deste cenário, e que é a responsável pela aplicação das doutrinas estabelecidas para a missão.

O objetivo deste nível de fusão é direcionar a interpretação do contexto, explorando os mecanismos que podem ser usados para melhorar a interface com os especialistas e/ou usuários do sistema. A ideia é evitar que interpretações e tendências individuais dos operadores dominem determinados processos de tomada de decisão. A IHM deve reforçar os recursos associados a elementos críticos deste processo em tempo de execução.

3 O PROBLEMA DE ALOCAÇÃO

3.1 Introdução

O Problema de Alocação Generalizada (PAG) é um problema clássico da área de otimização combinatória. Ele é uma generalização do problema de alocação simples estudado na área de programação linear. O problema considera a existência de dois conjuntos, um conjunto de tarefas $i \in I$, que deve ser alocado a um conjunto de agentes $j \in J$. A quantidade de tarefas que pode ser alocada a cada agente pode variar de um elemento para outro (ROSS e SOLAND, 1975).

Entende-se o PAG então, como o problema de se alocar, a um custo mínimo, um conjunto de tarefas a um conjunto de agentes, sem ultrapassar as limitações de capacidade individuais de cada agente. A equação 3.1 descreve o problema.

$$\text{Minimizar } f(\mathbf{S}) = \sum_{i=1}^A \sum_{j=1}^T C_{ij} X_{ij}(\mathbf{S}) \quad (3.1)$$

$$\text{Sujeito a } \sum_{j=1}^T R_{ij} X_{ij}(\mathbf{S}) \leq B_i \quad (3.2)$$

$$X_{ij}(\mathbf{S}) = \begin{cases} 1 & \text{se } S_j = i \\ 0 & \text{caso contrário} \end{cases} \quad (3.3)$$

Na Eq. (3.1), a função $f(\mathbf{S})$, corresponde ao custo total de alocação de todas as tarefas. O vetor \mathbf{S} é uma solução viável do problema, onde cada elemento S_j , deste vetor indica o agente i que foi alocado à j^{th} tarefa. A matriz \mathbf{C} contém os diferentes custos de alocação, sendo C_{ij} , o custo corrente associado ao par formado pelo agente i e pela tarefa j . A representa a quantidade total de agentes. T representa a quantidade total de tarefas. A Eq. (3.1) mostra ainda a matriz \mathbf{X} , onde as variáveis de decisão binárias $X_{ij}(\mathbf{S})$, indicam quais tarefas estão alocadas a quais agentes, conforme mostrado na Eq. (3.3). Na Eq. (3.2), R_{ij} indica a quantidade de recursos do agente i consumida pela tarefa j . A tarefa j alocada ao agente i , atende a condição de capacidade, se limitando ao montante de recursos B_i do agente ($B_i > 0$). O vetor \mathbf{S} tem a vantagem de sempre produzir uma solução viável, atendendo automaticamente à restrição, $\sum_{i=1}^A X_{ij} = 1$. Várias tarefas podem ser alocadas a um agente, mas cada tarefa é alocada a somente um agente.

A solução final do problema deve alocar todas as tarefas existentes, respeitando a capacidade de cada agente.

Este problema de otimização é usado para modelar uma grande variedade de problemas práticos de setores da indústria, das telecomunicações, do transporte de cargas, do planejamento militar, como é o caso da alocação de recursos defensivos, tema tratado nesta tese.

3.2 A Alocação de Recursos Defensivos

O problema da alocação de recursos defensivos (WTA) é um caso de otimização combinatória, que tem como dados de entrada, também dois conjuntos, um de recursos e outro de alvos. O problema consiste em se encontrar a forma mais adequada de se designar os recursos disponíveis aos alvos contidos nos cenários. Seu objetivo é minimizar o nível de ameaça dos alvos que sobreviverem a um ciclo de defesa, ou minimizar os danos impostos por estes às instalações ou unidades sob proteção.

Encontrar a melhor forma de se alocar os poucos recursos existentes contra os alvos presentes nos cenários táticos das operações de defesa é o objetivo formulado neste problema, existindo diversos tipos de modelos e técnicas que podem ser empregados na sua solução. Baseado nestas considerações, Hosein (1990) descreveu dois modelos de cenários táticos diferentes, o modelo baseado em alvo (*target-based model*) e o modelo baseado em instalação (*asset-based model*).

No modelo baseado em alvo, cada alvo do cenário recebe um valor que indica o seu nível de ameaça. Quando um recurso defensivo é designado para conter um alvo, eles formam um par, este par (recurso-alvo) possui uma probabilidade de dano associada, valor este que fornece uma medida estatística da probabilidade do recurso defensivo conseguir anular o alvo para o qual foi designado.

O objetivo do problema neste modelo é minimizar o nível global de ameaça associado aos alvos que restarem após a realização simultânea de todos os confrontos do ciclo de defesa. Este modelo se aplica a estratégias ofensivas, em que não se assume o conhecimento prévio do direcionamento dos alvos (MURPHEY, 2000).

No modelo baseado em instalação é necessário decidir em quais instalações civis ou militares, da área sob proteção, deve a defesa concentrar seus recursos. Neste modelo é necessário se atribuir um valor a cada instalação, de modo a indicar seu nível de importância dentro da área sob proteção. Cada par alvo-instalação tem

uma probabilidade de letalidade associada, este valor dá uma medida estatística da probabilidade do alvo destruir a instalação para a qual se dirige, caso ele não seja interceptado antes por um recurso defensivo. Cada par recurso-alvo, possui ainda uma probabilidade de dano, definida da mesma forma que no modelo anterior.

Neste modelo, o objetivo é maximizar o valor das instalações sobreviventes, garantindo assim a sobrevivência das mais importantes. O modelo baseado em instalação envolve estratégias de defesa balísticas, demandando um conhecimento mais preciso sobre o direcionamento dos alvos com relação as instalações existentes (MURPHEY, 2000).

Em (LLOYD e WITSENHOUSEN, 1986), foi comprovado que o modelo estático de defesa baseado em alvo é NP-Completo. Em (HOSEIN, 1990) foi estabelecido um paralelo entre estes dois modelos de cenários de defesa, visando comprovar que o modelo baseado em instalação, da mesma forma que o modelo baseado em alvo, também é um problema NP-Completo. No raciocínio empregado pelo autor, o problema de alocação de recursos baseado em instalações é visto como uma generalização do problema de alocação baseado em alvo.

No cenário adotado para a demonstração de Hosein (1990), os alvos que se deslocam na direção de cada instalação, recebem como grau de ameaça, o mesmo valor atribuído à instalação, com esta estratégia, a minimização da possibilidade de sobrevida dos alvos direcionados à uma das instalações, implica conseqüentemente na maximização da sobrevivência das instalações. Em (METLER e PRESTON, 1990), se usa um raciocínio próximo, a diferença é que o valor da instalação é dividido de maneira uniforme entre os alvos a ela direcionados.

Um outro aspecto considerado na modelagem dos cenários refere-se à evolução das operações ao longo do tempo. O modelo estático, chamado de atribuição estática de recursos-alvos (*Static Weapon-Target Assignment* - SWTA) considera que as operações de defesa evoluem em um único ciclo. Todos os valores usados como parâmetros de entrada são fixos e conhecidos, este modelo é adequado aos casos em que a operação de defesa se dá em uma única etapa, com todos os engajamentos sendo feitos de forma simultânea. Ao final dos engajamentos um processo de avaliação verifica os alvos ou as instalações sobreviventes.

No problema de atribuição dinâmica de recursos-alvos (*Dynamic Weapon-Target Assignment* - DWTA) se consideram vários ciclos de defesa. Em cada ciclo, é necessário decidir quando e para quais alvos deve se alocar os recursos existentes. O

número de elementos envolvidos muda de um ciclo para outro, sendo necessário considerar explicitamente os sucessos e os fracassos do ciclo anterior. O modelo é caracterizado pelo seu aspecto não-determinístico, onde o resultado de cada ciclo deve ser levado em consideração para a definição dos valores dos parâmetros usados no ciclo seguinte.

A formulação matemática do problema muda em função das questões citadas. Com relação a evolução das missões ao longo do tempo, muitos autores consideram que os modelos de alocação dinâmica podem se valer dos mesmos algoritmos usados no tratamento do problema estático, usando-os como importantes sub-rotinas de suas propostas (AHUJA, KUMAR, *et al.*, 2007). Nesta hipótese se considera o problema dinâmico basicamente como um somatório de instâncias estáticas, onde os resultados dos ciclos anteriores vão impondo restrições aos dados de entrada dos ciclos subsequentes.

Esta tese aborda o modelo estático baseado em alvo, onde se considera que todas as ameaças e recursos defensivos são conhecidos, e que todos os engajamentos são realizados em um único ciclo. Apesar do modelo não contemplar o tempo de forma explícita, ele está obviamente presente, sendo importante obter resultados que atendam as limitações temporais impostas pelos cenários de defesa.

3.2.1 Modelo Baseado em Alvo

A Eq. (3.4) descreve o modelo estático baseado em alvo, cujo objetivo é minimizar os valores das ameaças sobreviventes $f(\mathbf{S})$. Na descrição do problema SWTA não se considera a restrição de capacidade apresentada anteriormente na formulação do PAG. O SWTA é um problema de programação não linear inteira.

$$\text{Minimizar } f(\mathbf{S}) = \sum_{i=1}^T V_i (\prod_{j=1}^W (1 - P_{ij})^{X_{ij}(\mathbf{S})}) \quad (3.4)$$

$$X_{ij}(\mathbf{S}) = \begin{cases} 1 & \text{se } S_j = i \\ 0 & \text{caso contrário} \end{cases} \quad (3.5)$$

Na Eq. (3.4), o vetor \mathbf{S} representa uma solução viável do problema, onde cada elemento S_j , indica o alvo i que foi alocado ao j^{th} recurso. T representa a quantidade total de alvos do cenário e W a quantidade total de recursos disponíveis. É interessante ressaltar que o vetor \mathbf{S} tem a vantagem de sempre produzir uma solução

viável, atendendo automaticamente à restrição, $\sum_{i=1}^T X_{ij} = 1$. Portanto, qualquer recurso pode ser alocado a qualquer alvo e mais de um recurso pode ser alocado a um mesmo alvo, mas cada recurso só é alocado a exatamente um alvo, sendo a quantidade de recursos alocados a cada alvo sempre um valor inteiro.

Ainda na mesma Eq. (3.4), o vetor \mathbf{V} representa os valores iniciais dos alvos, ou seja, os graus de ameaça iniciais atribuídos a cada alvo do cenário. A matriz \mathbf{P} é a matriz de probabilidade de danos dada, onde cada elemento P_{ij} , que indica a probabilidade do recurso j anular o alvo i em um confronto, é um evento independente, ou seja, o uso de um determinado recurso j não modifica a probabilidade de dano associada a outro recurso qualquer também usado para conter este mesmo alvo i . Portanto, o termo $(1 - P_{ij})$ indica a probabilidade do alvo i sobreviver se for confrontado pelo recurso j .

O número total de soluções viáveis para um problema envolvendo T alvos e W recursos é T^W . Então, por exemplo, quando um navio equipado com 4 recursos, cada um de um tipo diferente, precisar definir uma estratégia ofensiva simultânea contra 4 ameaças, o total de soluções possíveis para este caso aparentemente pequeno é 256, demonstrando a necessidade de sistemas de apoio computadorizados automáticos ou semiautomáticos no processo de tomada de decisão.

O nível de ameaça inicial do alvo é diminuído à medida que recursos vão sendo designados a ele, então, quando um recurso j é designado para conter um alvo i , o grau de ameaça deste alvo é alterado para $V_i(1 - P_{ij})$, reduzindo o nível de ameaça corrente do mesmo. Considerando um determinado par recurso-alvo, se k recursos são designados a um determinado alvo i , o valor do alvo diminui do montante associado ao somatório $\sum_{j=1}^W V_i P_{ij} \delta_{isj}$, onde δ_{isj} é o delta de Kronecker e $\sum_{j=1}^W \delta_{isj} = k$. Obviamente, se nenhum recurso for atribuído a um determinado alvo i , este mantém seu nível de ameaça inicial V_i .

A Eq. (3.6) mostra que a solução para o problema pode ser representada também pela matriz \mathbf{X} , de dimensão $W \times T$, onde as variáveis de decisão binárias $X_{ij}(\mathcal{S})$, indicam quais ameaças estão alocadas a quais recursos. A solução deve obedecer ao estabelecido anteriormente na Eq. (3.5). A soma dos elementos de uma dada coluna é sempre 1, indicando que cada recurso só pode ser alocado a um alvo.

$$X = \begin{pmatrix} X_{11} & \cdots & X_{1W} \\ \vdots & \ddots & \vdots \\ X_{T1} & \cdots & X_{TW} \end{pmatrix} \quad (3.6)$$

Para facilitar a resolução dos problemas, os modelos são sempre uma visão mais simplificada da situação real. Na Eq. (3.4) se assume que todos os recursos ofensivos devem ser usados simultaneamente na solução do problema e que cada recurso só pode ser designado a um alvo, mas restrições adicionais podem ser adotadas, afetando conseqüentemente, a formulação do mesmo. Exemplos de outras restrições normalmente usadas são: o alcance máximo de cada recurso, a especificação do número máximo de recursos que podem ser designados a cada alvo, o custo associado a cada par designado.

O caso mais comum tratado na literatura é a inclusão do parâmetro custo na formulação do problema. Na defesa baseada em alvo, mantendo-se as mesmas considerações das equações anteriores, o problema de minimização pode ser formulado com uma parcela de custo aditiva C_{ij} , conforme apresentado na Eq. (3.7) (JOHANSSON, 2010). Para tornar a representação mais compacta, o termo $(1 - P_{ij})$, associado a probabilidade do alvo i não ser anulado pelo recurso j , foi substituído por $q_{ij} = (1 - P_{ij})$.

$$\text{Minimizar } f(S) = \sum_{i=1}^T V_i \prod_{j=1}^W q_{ij}^{X_{ij}(S)} + \sum_{i=1}^T \sum_{j=1}^W X_{ij}(S) C_{ij} \quad (3.7)$$

A inclusão da parcela de custo na fórmula altera o espaço de busca do problema, mas não afeta o nível de complexidade computacional.

3.3 Métodos de Resolução do Problema SWTA

A alocação de recursos defensivos é um assunto bastante conhecido da área de PO, os primeiros trabalhos foram publicados no século passado durante as décadas de 50 e 60, em publicações especializadas nesta linha de pesquisas. Apesar da quantidade de trabalhos existentes ainda hoje, pelo menos para o meio acadêmico, não existe uma solução para o caso generalizado, ou seja, não se conhecem algoritmos capazes de resolver esta questão em tempos polinomiais. Vale ressaltar que as principais pesquisas são financiadas por grandes companhias e organismos do setor de defesa de países como os Estados Unidos, o que pressupõe a existência de bons resultados ainda não divulgados.

Nas publicações, diversas propostas procuram contornar esta característica não polinomial do problema, permitindo a obtenção de soluções ótimas ou quase ótimas em tempos viáveis. Estas propostas se baseiam em diferentes tipos de enfoque, muitas sugerem métodos exatos para tratar de cenários táticos especiais, outras usam métodos analíticos aproximativos, existem ainda os métodos heurísticos, ocorrendo dentro desta linha um grande número de trabalhos voltados às metaheurísticas inspiradas em fenômenos biológicos da natureza.

Exemplos de todos estes casos são comentados a seguir, o foco desta tese está no uso de técnicas heurísticas para a solução do problema. Os algoritmos descritos são voltados aos casos estáticos de alocação baseada em alvo, entretanto, eles também podem ser aplicados aos cenários baseados em instalação, desde que se adote a estratégia de se atribuir de forma integral ou uniformemente distribuída, o valor da instalação entre os alvos a ela direcionados, conforme respectivamente sugerido em (HOSEIN, 1990) e (METLER e PRESTON, 1990).

3.3.1 Métodos Exatos

Os métodos de busca exatos são aqueles que garantem a obtenção do ótimo global de um problema, satisfazendo sua função objetivo e as restrições formuladas para o mesmo. O problema de alocação de recursos é um problema de natureza combinatória, por conseguinte, um método de enumeração explícita garante a obtenção do ótimo global.

A questão é que apesar de poder se resolver o problema através de um método exato, o tempo gasto com o seu processamento cresce de forma exponencial com o aumento do número de variáveis, o que conseqüentemente implica no aumento do tamanho do espaço de busca, inviabilizando a sua aplicação prática. Os cenários reais que podem ser encontrados são muito variados não sendo possível prever o nível de complexidade que as plataformas podem ter que lidar durante suas missões. Esta limitação é bastante crítica, especialmente quando se considera o contexto da aplicação.

Os métodos exatos são diretamente aplicáveis a problemas polinomiais, ou seja, problemas pertencentes à classe P de problemas de otimização, o que não é o caso do problema de alocação de recursos defensivos. A opção pelo uso de um método exato para este tipo de problema tem sempre que considerar a viabilidade de sua aplicação se restringindo aos cenários de pequeno porte ou cenários especiais.

O problema de alocação estática de recursos baseada em alvo, objeto deste estudo, foi formulado inicialmente em (MANNE, 1958). Em (DEN BROEDER, ELLISON e EMERLING, 1959) foi proposto um método exato para resolver em tempo polinomial um caso especial do SWTA, o qual recebeu o nome de MMR (*Maximal Marginal Return*). Nele o ótimo absoluto é alcançado para os casos em que se considera que a probabilidade de dano é independente dos recursos, pois os recursos são todos do mesmo tipo, além disto a geometria do problema não é considerada, ou seja, a disposição dos recursos dentro das plataformas militares não é levada em conta nos cálculos, temos então que $P_{ij} = P_i$.

Em (HOSEIN, 1990) foi apresentado um algoritmo de busca local para a solução exata do caso descrito. Neste mesmo trabalho o autor considera também a possibilidade de que nem todos os recursos são aplicáveis a todas as ameaças e, nos casos em que é válido, a probabilidade de dano depende também exclusivamente do tipo do alvo. Para este caso, as probabilidades associadas a cada par são consideradas como: $P_{ij} \in \{0, P_i\}$. Neste último caso, segundo o autor, o problema pode ser transformado em um problema de rede de fluxos de custo mínimo cujos arcos possuem custo linear, existindo vários algoritmos considerados eficientes para este problema.

3.3.2 Métodos Analíticos

As propostas analíticas estiveram entre as primeiras opções a serem apresentadas, elas incluem métodos de otimização como a enumeração implícita, os algoritmos *Branch and Bound*, os multiplicadores de Lagrange e a programação dinâmica. O primeiro grande estudo sobre esta classe de métodos pode ser encontrado em (MATLIN, 1970). Posteriormente foram apresentados outros modelos matemáticos desenvolvidos para abordar o problema SWTA sob uma ótica diferente da usada por Matlin (ECKLER e BURR, 1972), (CHEONG, 1985).

Algumas técnicas sugerem o relaxamento da restrição que obriga a variável de decisão a ser inteira, ou seja, onde a solução final pode indicar valores fracionários de alocação de um recurso (Ex.: 0,654). Esta condição torna necessário o uso de técnicas da programação linear para resolver o problema contínuo resultante deste relaxamento, como por exemplo, o algoritmo *Branch and Bound* (LAWLER e WOOD, 1966).

Em (AHUJA, KUMAR, *et al.*, 2007) são propostos três esquemas diferentes com base nos algoritmos *Branch and Bound*. Este tipo de algoritmo adota um método de busca em árvore, sendo muito usado na solução de problemas NP-completos, ele é considerado um método de enumeração implícita, pois consegue eliminar um grande número de soluções candidatas através do estabelecimento de limites inferiores e superiores para a solução. Os resultados descritos por este autor são bem expressivos, principalmente com relação ao tratamento de cenários de maior porte, só que esta abordagem não apresenta garantias de ser sempre possível eliminar ramos significativos da estrutura em árvore, ou seja, no pior caso pode ser necessário varrer toda a estrutura, o que o igualaria aos algoritmos de enumeração explícita (método de busca exaustiva). Outra questão é que não há como se estabelecer previamente limites máximos para o processamento dos cenários, podendo ocorrer casos em que um cenário de grande porte seja processado mais rapidamente que um consideravelmente menor.

Em (EVERETT, 1963), métodos baseados em multiplicadores de Lagrange são aplicados ao problema. Esta técnica faz uso de derivadas, o que inviabiliza a obtenção da solução para alguns problemas.

3.3.3 Métodos Heurísticos

Os métodos heurísticos são uma boa forma de abordagem para os problemas de otimização combinatória. Eles buscam a simplificação do problema original, visando com isto encontrar respostas viáveis em tempos aceitáveis, ainda que estas respostas não representem a solução ótima para grande parte das instâncias do problema em questão. Normalmente, não existem parâmetros formais para a determinação da qualidade das soluções fornecidas por um método heurístico. Sua avaliação é realizada de forma indireta, através da quantificação do grau de proximidade existente entre a sua solução e a solução ótima, ou a comparação com algum outro objetivo considerado adequado à natureza do problema.

O método MMR proposto em (DEN BROEDER, ELLISON e EMERLING, 1959), quando aplicado a modelos de cenários mais gerais, normalmente não chega ao ótimo global, mas ainda assim, é considerado um exemplo clássico de heurística construtiva determinística para a solução do problema de alocação, permitindo a obtenção de resultados aproximados. Anos mais tarde, Kolitz (1988) propôs um novo algoritmo MMR que alcança resultados melhores que a proposta anterior para muitas instâncias do problema de alocação.

Estes métodos são classificados como métodos heurísticos construtivos gulosos, sendo as soluções obtidas passo a passo, segundo uma estratégia de otimização.

3.3.4 Metaheurísticas

Os métodos estocásticos, também chamados metaheurísticas, deram origem a uma nova onda de propostas, permitindo aumentar a complexidade dos problemas tratados. Eles trabalham bem em muitos casos, obtendo respostas viáveis de boa qualidade em tempos reduzidos, mas não há prova de que sejam sempre rápidos ou de que produzam sempre bons resultados, sendo necessário se estabelecer limites para o tempo de busca ou para a quantidade de ciclos a serem realizados. Apesar disto, na prática, estes métodos costumam convergir para uma boa resposta de forma extremamente rápida. As metaheurísticas são heurísticas mais genéricas e sofisticadas, que coordenam procedimentos para a exploração do espaço de busca de forma mais inteligente, empregando técnicas que incluem um certo grau de aleatoriedade e de conhecimento histórico dos resultados anteriores. Os algoritmos de otimização inspirados na natureza pertencem a esta classe de métodos.

Os algoritmos genéticos (AG) (HOLLAND, 1975) foram usados em muitos trabalhos. O AG procura imitar o processo de evolução biológica, onde as soluções candidatas são representadas por uma população de cromossomos artificiais (cadeias de bits, por exemplo). A população evolui, se transformando em uma nova população, à medida que operadores de cruzamento, mutação e inversão, além de procedimentos especiais de seleção vão sendo aplicados.

Lee, Lee e Su (2002a), incluíram no operador de cruzamento do AG elementos específicos ligados ao conhecimento do domínio do problema, além de um mecanismo para busca local. Em (LEE e LEE, 2003), se propôs a inclusão no AG de mecanismos para melhoria do processo de evolução baseados em um algoritmo guloso, o MMR (DEN BROEDER, ELLISON e EMERLING, 1959).

Muitos trabalhos focaram na hibridização de estratégias bio-inspiradas diferentes, combinando métodos baseados na inteligência de enxames com o AG, tentando com isto melhorar os resultados obtidos pela unificação das vantagens oferecidas individualmente por cada abordagem. Em (LEE, LEE e SU, 2002b), se propõe a hibridização da otimização por colônia de formigas (ACO) (DORIGO e DI CARO, 1999) com um sistema imune artificial. Em outra proposta (LEE e LEE, 2005), foi feita a combinação dos métodos ACO e AG. Em (WANG e CHEN, 2012) um

algoritmo de otimização por enxame de partículas (PSO) (EBERHART e KENNEDY, 1995) e um algoritmo cultural são reunidos. Nesta proposta o método de busca global e local do PSO é agregado ao esquema de representação do conhecimento usado na coleta e no aprendizado de experiências individuais do algoritmo cultural. Em (ZENG, 2006), se considera a combinação de um PSO discreto (DPSO) e do AG. Neste trabalho, uma estratégia de busca gulosa é introduzida no DPSO, visando a construção de um esquema de prioridade para controlar a busca local e ajudar na eficiência da convergência para um ótimo global.

A maior parte dos artigos lida com a questão do engajamento, ou seja, a alocação de recursos letais. Porém, uma plataforma militar nem sempre pode se arriscar a fazer uma ofensiva quando o ambiente lhe é muito desfavorável, existindo ainda uma série de recursos não letais, que podem ser alocados com o intuito de cumprir estratégias para despistar ou confundir os alvos a ela direcionados; a alocação de recursos militares engloba ambas questões.

Um exemplo de alocação de recursos não letais pode ser visto em (LIANG e WANG, 2006). O artigo mostra como solucionar a coordenação das manobras de evasão com o lançamento de despistadores e interferidores para 'distrair' torpedos lançados na direção de um submarino. A proposta usa o AG para calcular a melhor forma para a plataforma despistar o torpedo e ao mesmo tempo fugir com segurança da área sob ameaça.

Apesar de todos estes algoritmos reduzirem consideravelmente o nível de ameaça inicial dos cenários, o tempo computacional gasto por cada um pode subir rapidamente com o aumento do tamanho do problema. Dependendo do montante de alvos e recursos presentes nos cenários, a obtenção de uma boa solução pode consumir muito tempo, tornando a sua busca inviável. A tomada de decisão em cenários de defesa aérea, por exemplo, necessita de tempos de reação na faixa de 1 a 2 segundos (JOHANSSON e FALKMAN, 2011).

Muitos trabalhos não consideram as limitações temporais associadas a necessidade de se fazer o processamento dos cenários em tempo real, apresentando resultados obtidos após a execução de seus algoritmos por horas a fio, o que compromete a sua aplicabilidade, mesmo quando se considera a análise de cenários simulados (LEE, LEE e SU, 2002a), (LEE, LEE e SU, 2002b), (LEE e LEE, 2003), (LEE e LEE, 2005). Em (JOHANSSON e FALKMAN, 2011) os autores consideram

explicitamente este tipo de limitação adotando-o como um critério de parada da busca em seu trabalho.

Julstrom (2009), apresentou resultados temporalmente viáveis, obtidos com dois tipos de AG, no primeiro é usada a codificação em cadeia (*string-coded*) e, no outro é usada a codificação por permutação (*permutation-coded*). Na versão de AG denominada *string-coded*, a solução candidata, representada pelo cromossomo **C**, é um vetor de tamanho fixo. Este vetor representa uma solução viável para o problema WTA. Cada elemento $C_j, \forall j = 1, \dots, W$, indica o alvo i que foi alocado ao j^{th} recurso. Portanto, a minimização do valor da função de avaliação da aptidão (*fitness*) do cromossomo é a minimização do valor de ameaça inicial dos alvos. A população de soluções candidatas (cromossomos) é gerada inicialmente de forma aleatória. Durante o processo evolutivo estas soluções são alteradas em busca do ótimo. Esta busca é feita através da aplicação do operador genético de cruzamento (*crossover*) multiponto (*k-point*), e do operador de mutação por troca de posição (*position-by-position*).

No segundo tipo de AG empregado por Julstrom, o cromossomo **C** representa somente a ordem dos recursos a serem avaliados pela função de aptidão. Esta ordem é a obtida pelo algoritmo MMR de Kolitz (1988). O valor da função de avaliação de aptidão é dado por um decodificador baseado na heurística gulosa proposta em (DEN BROEDER, ELLISON e EMERLING, 1959), um algoritmo MMR, mas a ordem da busca deste decodificador é dada pela ordem dos recursos em **C**. O decodificador verifica, para cada recurso C_j , o alvo i que minimiza o valor de ameaça inicial, se engajado pelo recurso corrente C_j . Como usual, os cromossomos são inicialmente gerados de forma aleatória. O operador de cruzamento usado é o Cruzamento Parcialmente Mapeado, mais conhecido como PMX (*Partially Mapped Crossover*) (GOLDBERG e LINGLE, 1985). A mutação é feita pela troca de recursos localizados em duas posições do cromossomo escolhidas de forma aleatória.

O autor mostra as melhorias alcançadas quando a solução obtida pelo algoritmo MMR apresentado em (KOLITZ, 1988) é usada para introduzir uma solução candidata na população inicial dos dois AG mencionados. Esta técnica é conhecida como *seeding*. Na versão semeada (*seeding*) do AG denominado *string-coded*, a solução do MMR de Kolitz é replicada em um cromossomo **C**. Para a versão semeada do AG denominado *permutation-coded*, um cromossomo **C** lista os recursos na mesma ordem designada pelo MMR de Kolitz (1988).

As versões semeadas e não semeadas foram executadas 30 vezes usando quinze cenários de tamanhos diferentes; todos gerados de forma aleatória, ou seja, para cada cenário, os níveis de ameaça dos alvos e a probabilidade de danos de cada par alvo-recurso foram gerados de forma aleatória. Cada cenário contém uma quantidade de alvos e recursos diferente, possibilitando o estudo do desempenho dos algoritmos em diversos níveis de complexidade. As versões de AG semeadas obtiveram um desempenho melhor do que as versões não semeadas e do MMR de Kolitz. Nos testes envolvendo cenários maiores, a versão de AG denominada *string-coded* apresentou melhor desempenho temporal que a versão denominada *permutation-coded*, mostrando-se adequada para aplicações práticas envolvendo até 40 recursos e 80 alvos, mas os testes foram limitados a somente uma instância de cada tamanho de cenário.

Johansson e Falkman [(2009), (2010a), (2011)] em seus trabalhos, revisaram várias heurísticas determinísticas e não determinísticas usadas para a solução dos problemas de alocação de recursos defensivos. Estas heurísticas foram aplicadas ao problema de forma isolada ou combinada: Busca Exaustiva; Busca Aleatória, dois tipos de MMR (DEN BROEDER, ELLISON e EMERLING, 1959) e (KOLITZ, 1988), MMR + Busca Local, AG, ACO, PSO.

Nestes trabalhos é relatado que as versões dos algoritmos baseadas no AG e no PSO foram as que obtiveram melhor desempenho. Estas versões foram mais bem sucedidas quando semeadas com a solução obtida pelo algoritmo MMR de Kolitz (1988). A seguir são feitos alguns comentários sobre as versões citadas aqui.

O AG implementado por Johansson e Falkman (2010a) foi inspirado em (LEE e LEE, 2005), tendo sido introduzidas algumas modificações para a redução dos tempos de resposta. Visando tornar o algoritmo mais rápido, os autores excluíram o procedimento de busca local usado no refinamento das soluções obtidas em cada geração do AG de Lee e Lee (2005). Eles também simplificaram os operadores, usando o operador de cruzamento de um ponto, e a mutação de um ponto, onde a posição para aplicação deste operador é escolhida de forma aleatória.

O PSO implementado segue a proposta clássica (EBERHART e KENNEDY, 1995). Todos os algoritmos bio-inspirados têm como critério de parada o tempo de 1 segundo. Os testes realizados se limitaram a cenários menores (30x30). Nos cenários contendo até 10 alvos e 10 recursos, os testes indicaram como melhor opção o uso do PSO. Nos cenários acima disto, envolvendo até 30 recursos e 30 alvos, é sugerido o

uso do AG. Os resultados finais, no entanto, mostram níveis de redução de ameaça muitas vezes idênticos, aos obtidos de forma isolada pelo algoritmo MMR de Kolitz (1988), possuindo ainda a desvantagem de levar muito mais tempo de busca que o MMR para chegar aos mesmos valores.

A ausência de padrões de qualidade pré-estabelecidos dificulta a comparação entre os resultados alcançados por diferentes autores em seus respectivos trabalhos. A não divulgação das fontes de dados efetivamente usadas por cada um, também é outro entrave, pois impede a realização de novos testes usando outros critérios de avaliação.

Esta tese propõe a hibridização de duas abordagens: o método heurístico determinístico de Kolitz (1988), e o método estocástico do ACO. O estudo adapta para o problema de alocação de recursos defensivos, uma variante do Sistema de Colônia de Formigas (*Ant Colony System - ACS*), originalmente proposto em (DORIGO e GAMBARELLA, 1997), além de uma estratégia de múltiplas colônias paralelas, para melhoria do seu desempenho. O algoritmo desenvolvido alcançou bons resultados atendendo às limitações de tempo estipuladas para os cenários contendo ameaças aéreas. Foram simulados cenários de defesa aérea de grande porte, contendo até 100 recursos e 100 alvos.

4 OS MÉTODOS DE BUSCA

4.1 Introdução

Na condução de qualquer pesquisa sempre é necessário se fazer análises sobre as semelhanças e as diferenças encontradas entre o que se propõe e o que foi apresentado anteriormente por outros pesquisadores. Esta abordagem visa evidenciar o contexto de aplicação da nova proposta e as possíveis contribuições neste contexto.

O foco deste trabalho é o desenvolvimento de uma heurística para o tratamento dos casos de alocação estática de recursos defensivos capaz de atender as limitações temporais dos cenários de defesa aérea. Para avaliar o desempenho da heurística implementada é necessário selecionar os métodos que vão ser usados como base comparativa da mesma. Idealmente, a medida do sucesso da proposta depende da verificação da rapidez com que as respostas são geradas e o quanto elas se aproximam da solução ótima, o problema é que neste caso, a solução ótima nem sempre pode ser obtida. Por conta disto, a aplicabilidade da heurística para os cenários simulados no próximo capítulo teve que ser feita com base na comparação com os resultados obtidos por outras heurísticas consideradas clássicas dentro do universo deste problema.

Neste capítulo, são apresentados, além do algoritmo proposto, denominado GACS, todos os outros algoritmos usados para avaliar o desempenho da proposta desta tese. No total, vão ser descritos cinco métodos: um algoritmo exato, dois métodos heurísticos determinísticos e dois não determinísticos.

4.2 Método de Busca Exaustiva

Os métodos de busca exaustiva enumeram e testam de forma explícita todas as soluções possíveis, por causa disto, seus tempos de resposta crescem exponencialmente com o tamanho do problema estático de alocação (SWTA). Foi demonstrado que o problema SWTA pertence à classe NP-Completo em (LLOYD e WITSENHOUSEN, 1986). O método de enumeração explícita garante a obtenção do ótimo global, mas esta busca só é possível em cenários contendo uma quantidade pequena de alvos e recursos. Nos cenários de menor dimensão ele é sem dúvida a melhor escolha. A Figura 4.1 mostra o pseudocódigo do algoritmo implementado para os testes de análise de desempenho.

O algoritmo da figura é baseado em (JOHANSSON e FALKMAN, 2009). Este algoritmo é usado como base comparativa para a avaliação qualitativa das soluções encontradas pelos métodos heurísticos determinísticos usados nos testes.

Segundo seus próprios autores, o algoritmo segue uma opção ingênua, o que não o invalida para fins de comparação, já que obtém sempre o maior nível de redução possível dos valores de ameaça. Cenários pequenos, mas de tamanhos diferentes são processados neste trabalho por este método, visando exemplificar o crescimento exponencial dos tempos de busca consumidos pelo mesmo. A função CriaSolução() que aparece no pseudocódigo gera um vetor **K** de tamanho fixo *W* a cada passo da iteração controlada pela variável *contador*. O vetor **K** representa uma das T^W soluções viáveis do problema. A solução final **S** só é obtida após a varredura de todas as soluções.

```

Início
 $f_{min} = \infty;$ 
 $contador = 0;$ 
Enquanto ( $contador < T^W$ ) faça
    K = criaSolucao(count);
     $f(\mathbf{K}) = 0;$ 
    Para  $i = 1$  a  $T$  faça
         $P_{sobrevida} = 1;$ 
        Para  $j = 1$  a  $W$  faça
            Se ( $K_j = i$ ) então
                 $P_{sobrevida} = P_{sobrevida} (1 - P_{ij})$ 
            Fim Se
        Fim Para
         $f(\mathbf{K}) = f(\mathbf{K}) + V_i P_{sobrevida};$ 
    Fim Para
    Se ( $f(\mathbf{K}) < f_{min}$ ) então
         $f_{min} = f(\mathbf{K});$ 
         $\mathbf{S} = \mathbf{K};$ 
    Fim Se
     $contador = contador + 1$ 
Fim Enquanto
Retorna S
Fim

```

Figura 4.1 - Algoritmo de Busca Exaustiva do problema SWTA
(JOHANSSON e FALKMAN, 2009)

4.3 Heurísticas Determinísticas

Os métodos heurísticos gulosos (*greedy*) construtivos, também chamados de métodos gananciosos, resolvem os problemas de otimização selecionando a cada iteração a escolha que melhor atende a função objetivo do problema naquele instante, isto é, escolhem deterministicamente uma solução que representa um ótimo local, considerando que através desta estratégia de busca acabem encontrando a solução ótima global para o problema. Esta foi uma das primeiras heurísticas usadas na solução de problemas de alocação de recursos defensivos.

O trabalho usa duas heurísticas gulosas diferentes, ambas seguem um processo de seleção baseado no ganho imediato (*gain-based*). A primeira é o algoritmo MMR proposto por (DEN BROEDER, ELLISON e EMERLING, 1959), aqui denominado MMR1. A segunda proposta é também um algoritmo MMR, que aqui, para fins de diferenciação do algoritmo MMR1, será chamado de MMR2, este algoritmo foi proposto por (KOLITZ, 1988).

Estes algoritmos são opções tradicionais nesta área, sendo normalmente adotados em estudos comparativos para a avaliação de desempenho de outras propostas (LEE e LEE, 2005), (AHUJA, KUMAR, *et al.*, 2007), (JULSTROM, 2009), (JOHANSSON e FALKMAN, 2011).

4.3.1 MMR1

O MMR1 segue uma estratégia gulosa, onde o método parte de uma solução vazia, adicionando a cada passo de iteração, um elemento viável à solução do problema, o par recurso-alvo selecionado representa sempre a melhor escolha imediata para o problema.

O pseudocódigo do MMR1 para este problema está na Figura 4.2. Os parâmetros de entrada são o vetor \mathbf{V} , que contém os valores de ameaça dos alvos; a matriz \mathbf{P} de probabilidade de danos; o total de alvos T presentes no cenário; o total de recursos W disponíveis. O parâmetro de saída é o vetor \mathbf{S} contendo a melhor combinação de pares recurso-alvo obtida pelo algoritmo de minimização. O objetivo de cada passo do laço de iteração é escolher o alvo que quando designado ao recurso corrente garante a maior redução do grau de ameaça do mesmo. A cada designação o valor da ameaça do alvo i selecionado (V_i), é diminuído do montante correspondente à esta alocação ($V_i P_{ij}$), computando assim os impactos associados a operação de

designação do recurso. Conforme o valor inicial das ameaças e o grau de redução de risco proporcionado pela designação de cada par recurso-alvo, existe a possibilidade de se alocar mais de um recurso a um mesmo alvo.

Início

Para $j = 1$ a W **faça**

$maiorDano = 0.0;$

$alvo = 0;$

Para $i = 1$ a T **faça**

$danoAtual = V_i P_{ij};$

Se ($danoAtual > maiorDano$) **então**

$maiorDano = danoAtual;$

$alvo = i;$

Fim Se

Fim Para

$S_j = alvo;$

$V_{alvo} = V_{alvo} - maiorDano;$

Fim Para

Retorna S;

Fim

Figura 4.2 – Algoritmo MMR1
(DEN BROEDER, ELLISON e EMERLING, 1959)

A busca segue a sequência da lista de recursos disponíveis. Portanto, ao fim do laço de varredura desta lista de recursos, todas as designações possíveis terão sido determinadas. O MMR1 assegura a obtenção do ótimo absoluto para o modelo de alocação simplificado de cenário originalmente estudado pelos seus autores, conforme demonstrado em (HOSEIN, 1990). A complexidade do algoritmo MMR1 é baixa. Para cada recurso j , são testados os valores de ameaça de um total de T alvos, ou seja, o algoritmo possui dois laços iterativos, W e T . A complexidade computacional do método MMR1 é de $O(W \times T)$.

A lógica implementada pelo algoritmo é simples, e seu tempo de processamento é bastante baixo, mas ele não garante a melhor solução para os casos gerais de alocação de recursos defensivos. O MMR1 é um algoritmo determinístico, ou seja, usando-se os mesmos dados entrada, a solução obtida é sempre a mesma.

4.3.2 MMR2

A segunda proposta de algoritmo determinístico é mais recente, e expande o escopo da busca pelos melhores pares (KOLITZ, 1988). Este algoritmo guloso tem seu pseudocódigo mostrado na Figura 4.3. Diferentemente da lógica seguida no algoritmo MMR1, o recurso a ser designado não é um dado predefinido de cada iteração.

Início
Para $k = 1$ a W **faça**
 $maiorDano = 0.0;$
 $alvo = 0;$
 $recurso = 0;$
 Para $j=1$ a W **faça**
 Se j não está em *lista-tabu-recursos-designados* **então**
 Para $i = 1$ a T **faça**
 $danoAtual = V_i P_{ij};$
 Se ($danoAtual > maiorDano$) **então**
 $maiorDano = danoAtual;$
 $alvo = i;$
 $recurso = j$
 Fim Se
 Fim Para
 Fim Se
 Fim Para
 $lista-tabu-recursos-designados \leftarrow j$
 $S_{recurso} = alvo;$
 $V_{alvo} = V_{alvo} - maiorDano;$
Fim Para
Retorna $S;$
Fim

Figura 4.3 – Algoritmo MMR2
(KOLITZ, 1988)

O algoritmo faz a varredura de todos os valores do vetor \mathbf{V} e, de todas as probabilidades de danos da matriz \mathbf{P} , associadas aos recursos ainda não designados, para então definir o par que correntemente assegura a máxima redução do valor de ameaça. Da mesma forma que no algoritmo MMR1, o valor do alvo selecionado (V_i) é reduzido após a sua designação a um determinado recurso. Os parâmetros de entrada do algoritmo MMR2 são os mesmos usados pelo algoritmo MMR1, ou seja: \mathbf{P} , \mathbf{V} , T e W .

A complexidade do MMR2 é maior do que a verificada para o algoritmo MMR1, sendo dada por $O(W^2 \times T)$, mas este nível de complexidade continua sendo muito baixo quando comparado com a complexidade de um algoritmo exato de enumeração explícita, como o apresentado no item 4.2, que é $O(T^W)$.

Os algoritmos MMR1 e MMR2, apesar de seguirem uma mesma linha de ação a cada passo do seu processo de busca, não são iguais, fazendo com que as respostas fornecidas por cada um, para um mesmo problema, sejam em geral diferentes entre si. Eles têm baixo nível de complexidade, fornecendo rapidamente uma solução para o problema, mesmo quando aplicados aos cenários de maior porte, além disto, suas respostas são determinísticas. O problema das heurísticas, é que não existem garantias de que o ótimo absoluto seja alcançado, embora isto ocorra em determinados casos.

Em (JOHANSSON e FALKMAN, 2011), foi observado que em cenários de menor complexidade, comparando-se os dois métodos, o MMR2 alcança o ótimo global para os problemas mais frequentemente, sendo portanto, mais efetivo. Entretanto, em cenários complexos, devido à falta de um método exato temporalmente viável, a qualidade das soluções obtidas pelo MMR1 e pelo MMR2, não podem ser mensuradas, uma vez que não há como verificar se os resultados estão associados a um ótimo local de baixa qualidade. No capítulo de testes, estas características vão ser discutidas com mais detalhes.

Os pseudocódigos dos algoritmos apresentados são para modelos de cenários baseados em alvo, mas seguindo o raciocínio apresentado em (HOSEIN, 1990), também é possível usá-los para o modelo baseado em instalação, desde que sejam feitas as conversões sugeridas.

4.4 Heurísticas não Determinísticas

Primeiramente vai ser descrita a metaheurística de Otimização por Colônia de Formigas (*Ant Colony Optimization* - ACO) (DORIGO e STÜZLE, 2004). As metaheurísticas são estruturas algorítmicas gerais voltadas à resolução de problemas de otimização, são portanto independentes, podendo atender a uma ampla gama de problemas. A seguir vai ser detalhado o Sistema de Colônia de Formigas (*Ant Colony System* - ACS) (DORIGO e GAMBARDELLA, 1997), um dos diversos tipos de implementação baseados nesta metaheurística.

Este trabalho usa duas versões diferentes do algoritmo ACS, adaptadas para atender ao problema de alocação estática de recursos defensivos: o ACS proposto em (JOHANSSON, 2010), e o GACS, que é a proposta do presente trabalho. O GACS é uma versão híbrida paralela do ACS sequencial de Johansson (2010).

As metaheurísticas buscam melhorar a capacidade de exploração e exploração do espaço de busca dos problemas de otimização combinatória. Sua ideia é introduzir de forma controlada, alguns elementos aleatórios aos processos de busca realizados pelas heurísticas determinísticas simplesmente gulosas. O desempenho apresentado por cada um destes algoritmos será analisado nos experimentos realizados no capítulo 5, onde ficarão mais evidentes as vantagens das inovações do GACS. Os detalhes construtivos das adaptações feitas nas regras que governam o processo de busca destes dois algoritmos, são dados nas próximas seções.

4.4.1 Ant Colony Optimization (ACO)

O ACO é uma metaheurística não determinística, baseada em população e na inteligência de enxames, conceitos mais recentes, usados na solução de problemas de otimização. A inteligência de enxames é baseada no comportamento social coletivo de algumas colônias de insetos, nela, elementos que aparentemente não possuem um nível de inteligência individual significativo, conseguem realizar tarefas bastante complexas, quando realizam estas tarefas em grupo. O ACO é inspirado no comportamento cooperativo realizado pelas formigas reais quando elas partem de seu ninho em busca de uma fonte de comida (DORIGO e STÜZLE, 2004). Vários problemas de otimização combinatória têm empregado esta técnica de forma bem sucedida, sendo o exemplo de aplicação mais famoso, o conhecido problema do caixeiro viajante (*Traveling Salesman Problem* - TSP).

Inicialmente, as formigas começam a sua busca por uma fonte de comida de forma aleatória. Muitas espécies de formigas são completamente cegas ou possuem baixa capacidade visual. Para compensar esta limitação, as formigas deixam uma substância química ao longo dos caminhos por elas percorridos, esta substância é chamada de feromônio, e é a forma encontrada por estas espécies para demarcar os caminhos visitados, ajudando-as a retornar para o seu ninho. Este também é o mecanismo encontrado para as formigas compartilharem informações entre si, uma vez que as formigas conseguem detectar as trilhas de feromônio. As direções que possuem níveis mais intensos de feromônio são mais atrativas para elas, portanto, a probabilidade de uma formiga selecionar um determinado caminho, aumenta à medida

que o montante de formigas atravessando este caminho é elevado, ou seja, este evento de probabilidade é diretamente proporcional à quantidade de feromônio depositado pelas formigas.

As formigas gastam menos tempo para ir e voltar nos caminhos que são mais curtos, isto faz com que o acúmulo de feromônio nos caminhos menores seja maior do que nos caminhos maiores, existindo portanto, uma tendência natural das formigas privilegiarem em sua escolha os caminhos menores. Esta forma peculiar de compartilhamento de informações, faz com que as formigas possuam uma capacidade nata de encontrar o caminho mínimo entre o seu ninho e uma fonte de comida.

Com o passar do tempo, as trilhas de feromônio evaporam, evitando assim a convergência prematura das formigas para os pontos mais distantes ou menos percorridos. A taxa de evaporação de feromônio é inferior à taxa dos depósitos deste elemento, considerando que as formigas continuem usando a trilha e mantenham assim seu poder de atração.

A metaheurística ACO usa grafos direcionados para modelar os problemas de otimização. No ACO, uma população de m formigas artificiais é colocada para atravessar o grafo de modo a achar o caminho mais curto. Os caminhos são escolhidos através de regras probabilísticas. O caminho completo atravessado por uma formiga artificial representa uma solução viável do problema de otimização tratado. Nos problemas de otimização, o processo de evaporação é o modo para evitar a convergência prematura para um ótimo local, permitindo assim que os resultados de baixa qualidade sejam gradativamente esquecidos.

Nos caminhos percorridos, os valores associados ao nível de feromônio são depositados nas arestas do grafo, fazendo-se assim a correspondência com a forma de comunicação usada pelas formigas reais.

As regras probabilísticas que guiam a escolha dos percursos devem evitar a convergência prematura em uma dada direção, deixando espaço para a exploração de outros caminhos do grafo. Para que isto seja possível, deve haver um equilíbrio entre o esquema de atualização dos níveis de feromônio, usados para modelar os procedimentos de depósito e evaporação do mesmo, e a função heurística usada para definir o nível de atratividade dos caminhos.

No início do processo de busca os níveis de feromônio depositados em cada trilha (τ_{ij}) e a informação heurística correspondente (η_{ij}) a cada um, indicam a

do mesmo. No tempo t as formigas caminham do nó inicial para o nó final do grafo. O depósito de feromônio dos caminhos é atualizado depois, quando as formigas retornam para o ponto de origem do grafo para começar uma nova busca (iteração), no próximo instante de tempo $(t + 1)$. As alterações nos níveis de feromônio são reguladas pela expressão mostrada na Eq. (4.2):

$$\tau_{ij}(t + 1) = (1 - \rho)\tau_{ij}(t) + \Delta\tau_{ij}(t) \quad (4.2)$$

Primeiramente, o valor do feromônio é reduzido, representando assim o processo de evaporação, como mostrado no termo $(1 - \rho)\tau_{ij}(t)$, onde, $0 < \rho \leq 1$, é uma taxa constante escolhida *a priori*, ρ indica o nível de evaporação de feromônio entre o instante t e o instante $t + 1$. O termo $\Delta\tau_{ij}(t) = \sum_{k=1}^m \Delta\tau_{ij}^k(t)$ indica os depósitos efetuados por todas as m formigas que passaram pelo caminho ij .

Ações adicionais podem ser aplicadas visando a melhoria das soluções construídas. Este é o objetivo do passo “Atividades Extras”, mostrado na Figura 4.4. Este passo refere-se as ações que necessitam de um agente com conhecimento global do problema, não podendo por isto ser executadas individualmente por uma formiga. Um exemplo de um procedimento muito comum, executado nesta fase, é a realização de uma busca local na vizinhança das melhores soluções obtidas, visando identificar possíveis melhorias.

A fase “Atividade de Escalonamento” refere-se a possibilidade de escalonamento e sincronização das atividades mostradas na Figura 4.4, esta opção fica a cargo do desenvolvedor. A atividade de escalonamento escolhida no algoritmo vai ser detalhada na seção de implementação. A condição de término do processo de busca também não é um elemento pré-estabelecido no algoritmo original, deixando espaço ao desenvolvedor para a adoção dos critérios que considerar mais adequados para a natureza do problema a ser tratado.

O ACO é uma metaheurística probabilística que gera soluções não determinísticas, é sensível ao tamanho do problema, e pode apresentar resultados pobres quando submetido a requisitos de tempo mais rigorosos. Sua grande vantagem está na forma como realiza a exploração e a exploração do espaço de busca, ampliando o escopo da busca realizada pelos métodos heurísticos gulosos, muito dependentes do problema. O ACO é uma metaheurística construtiva, que possui a capacidade de manter uma memória indireta dos caminhos já percorridos pelo uso dos

depósitos de feromônio e da informação heurística associada a cada trecho percorrido. Seu desempenho também depende do ajuste correto dos elementos usados como parâmetros de controle do algoritmo.

Com base nesta proposta original, surgiram diversas sugestões de implementação. Geralmente a diferença entre elas está no momento em que realizam o depósito de feromônio, e na forma como se atualiza os valores de feromônio. O ACS (DORIGO e GAMBARELLA, 1997) é uma destas variantes, sendo detalhado a seguir.

4.4.2 Ant Colony System (ACS)

O ACS é uma proposta que visa a melhoria do primeiro exemplo de algoritmo ACO implementado, este algoritmo conhecido pelo nome de Sistema de Formigas (*Ant System* - AS) foi publicado primeiramente em (DORIGO, 1992). No AS, a atualização do feromônio é feita somente após todas as formigas terem terminado de percorrer seus caminhos e, o montante de feromônio depositado por cada formiga é dado por uma função que avalia a qualidade do caminho percorrido, ou seja, as formigas que percorreram o caminho mais curto depositam mais feromônio nas arestas associadas a este caminho. O AS não realiza nenhuma ação extra de busca.

O ACS melhora o algoritmo AS original, pela inclusão de três novas características. Primeiramente, há uma modificação na heurística do algoritmo, os procedimentos de atualização global de depósito e de evaporação de feromônio só ocorrem nos arcos atravessados pela formiga que percorreu o melhor caminho obtido até então (*best-so-far path*), isto permite um incremento da exploração pela redução dos depósitos de feromônio realizados. Outra diferença é que durante a fase de construção das soluções, é incluído a cada passo de iteração, um procedimento de atualização local de feromônio, realizado cada vez que uma formiga atravessa um dado arco, este procedimento visa equilibrar a estratégia de certa forma gulosa realizada pelo processo de atualização global mencionado anteriormente. A última alteração, refere-se ao esquema de elitismo, que é indiretamente contemplado pela inclusão de uma cláusula extra na expressão usada pela formiga para se deslocar, demonstrada na Eq. (4.3). Esta nova regra do ACS, denominada pseudoaleatória proporcional, governa então os deslocamentos realizados por uma formiga k , posicionada no nó i , e indo em direção ao nó j .

$$j = \begin{cases} \operatorname{argmax}_i \{\tau_{il} [\eta_{il}]^\beta\}, & \text{se } q \leq q_0, \forall l \in \text{allowed } l(t) \\ \text{Escolha Probabilística, Eq. (4.1),} & \text{caso contrário} \end{cases} \quad (4.3)$$

A variável q é um valor real aleatório uniformemente distribuído, variando no intervalo entre 0 e 1, e o elemento q_0 é um valor constante pré-estabelecido, $0 \leq q_0 \leq 1$. A variável q_0 faz o balanceamento entre os processos de exploração e de exploração do espaço de busca. A regra adicional apresentada na Eq. (4.3) especifica que quando $q \leq q_0$, a formiga k faz uma escolha gulosa, movendo-se para o melhor caminho possível no instante t , ou seja, no caso do problema de alocação, isto significa que seleciona a ameaça i que quando alocada ao recurso j proporciona a maior redução de risco para o cenário, com probabilidade q_0 . Quando $q > q_0$, o alvo a ser alocado ao recurso corrente é escolhido pelo método proposto no algoritmo AS. No ACS, o peso α é sempre dado por $\alpha = 1$.

A atualização do feromônio, conforme já comentado, é realizada duas vezes, primeiro localmente e depois de forma global. As formigas realizam a atualização local imediatamente depois atravessarem um arco, a ideia é reduzir o poder de atração exercido pelos arcos mais visitados. A atualização local do feromônio permite a diversificação dos caminhos percorridos pelas formigas que vão vir posteriormente realizar uma nova busca na mesma iteração, a regra para esta operação local é dada na Eq. (4.4):

$$\tau_{ij}(t) = (1 - \xi)\tau_{ij}(t) + \xi\tau_0 \quad (4.4)$$

Onde, $0 < \xi \leq 1$, é uma constante, e τ_0 é o valor inicial do feromônio. De acordo com Dorigo e Stützle (2004), são considerados bons valores para estes parâmetros $\xi = 0.1$ e $\tau_0 = 1 / (m f_{nn})$, onde m indica o número total de formigas da população e f_{nn} é um valor produzido por uma heurística conhecida como heurística do vizinho mais próximo (*nearest-neighbor heuristic*), a qual é específica para a natureza do problema.

Após todas as formigas alcançarem o nó final do grafo, a atualização global do valor do feromônio é efetuada. Somente uma formiga, a que percorreu o melhor caminho, adiciona feromônio. A regra do ACS para controlar esta atualização global é dada na Eq. (4.5):

$$\tau_{ij}(t+1) = \begin{cases} (1 - \rho)\tau_{ij}(t) + \rho\Delta\tau_{ij}^{best}(t), & \text{if } (i,j) \in R^{best} \\ \tau_{ij}(t), & \text{ou seja, não evapora} \end{cases} \quad (4.5)$$

Onde, $\Delta\tau_{ij}^{best} = 1/L^{Best}$, e L^{Best} é o tamanho do melhor caminho percorrido até então (*best-so-far*), que é R^{best} . Deste modo, o nível de feromônio vai sendo aumentado nos caminhos associados às melhores escolhas, aumentando a probabilidade de serem escolhidos pelas próximas formigas nas próximas iterações. A melhor solução global é sempre mantida armazenada, de modo que ao fim do ciclo de busca a melhor solução encontrada possa ser retornada pelo algoritmo.

Este modelo de implementação tradicional do algoritmo ACS apresentado aqui precisou sofrer adaptações para adequá-lo as características específicas do problema de alocação de recursos defensivos SWTA. Nos próximos itens são apresentados os dois modelos de adaptação comentados anteriormente, o modelo GACS e o ACS de Johansson e Falkman [(2010a), (2010)].

4.4.3 Modelo ACS Sequencial

O grafo direcionado do ACS, usado para fazer a representação do problema de alocação estática de recursos defensivos (SWTA) do modelo baseado em alvo, pode ser visto na Figura 4.5. A partir do primeiro recurso W_1 , o nó inicial do grafo, uma das m formigas, a formiga k , escolhe probabilisticamente um dos T arcos que partem de W_1 , em direção ao nó W_2 , de modo a compor um par recurso-alvo W_1T_l . A formiga k se move de um nó i para outro nó j , escolhendo probabilisticamente o arco l , um dos arcos disponíveis, de acordo com a regra definida na Eq. (4.3), até que ela alcance o nó Fim. Cada arco do grafo está associado a um valor atualizado do alvo V_i , e a um valor de informação heurística η_{ij} , atualizado a cada escolha da formiga k , sendo η_{ij} definido pelo produto da probabilidade de dano pelo valor do alvo, V_iP_{ij} . Cada arco tem um valor de feromônio τ_{ij} , que é atualizado cada vez que é atravessado, sendo seu valor inicial dado por $\tau_{ij} = 1/(m f(\mathbf{S})_{MMR1})$, $\forall i = 1, \dots, T$, onde $f(\mathbf{S})_{MMR1}$ é o valor de ameaça final fornecido pela solução encontrada pelo algoritmo MMR1, conforme Eq. (3.4).




Figura 4.5 - Grafo do Problema Estático de Alocação (SWTA)

A implementação do ACS, usada na proposta de (JOHANSSON e FALKMAN, 2010a), segue o pseudocódigo mostrado na Figura 4.6, uma lista de 11 passos auto explicativos. O passo 1 mostra todos os detalhes de iniciação usados para esta adaptação para o problema SWTA.

A informação heurística é atualizada a cada passo da iteração corrente, como pode ser visto no passo 7, e é reiniciada para o seu valor original, somente para o próximo ciclo, no passo 10. A atualização segue a regra $\eta_{ij}(t) = V_i(1 - P_{ij}) P_{ij}$, onde $V_i(1 - P_{ij})$ é o grau de ameaça atualizado associado ao alvo i , dado que este foi designado ao recurso j . Este valor influencia a próxima escolha de caminho de uma formiga k , que vem a ser, o próximo alvo a ser alocado ao recurso $(j+1)$.

O algoritmo apresentado por Johansson e Falkman (2010a), (2010), é baseado em uma proposta anterior de outros autores (LEE, LEE e SU, 2002a), (LEE e LEE, 2005). A modificação do algoritmo originalmente proposto teve como intuito melhorar o desempenho computacional do mesmo.

A proposta original apresenta níveis de redução de ameaça consideráveis, mas o tempo usado nas simulações é extremamente alto, o que inviabiliza a sua aplicação prática em cenários reais ou mesmo simulados. O problema dos testes realizados com o ACS descrito na Figura 4.6 é que foram considerados cenários de porte relativamente pequeno.

-
- Passo 1:** Dados W , T , V e P , inicie o número total de formigas como $m = \text{Max}(T, W)$, maior valor dentre o número total de alvos e o número total de recursos disponíveis. Inicie a matriz de feromônio, $\tau_{ij} = \tau_0 = 1/(m f(\mathbf{S})_{MMR1})$, onde $f(\mathbf{S})_{MMR1}$, é a solução encontrada pelo algoritmo MMR1, Eq. (3.4). Inicie a matriz de informação heurística com os elementos $\eta_{ij} = V_i P_{ij}$, o nível máximo de redução de hostilidade associado ao percurso ij . A análise de sensibilidade define os valores de β , ρ , ξ , q_0 . No ACS, $\alpha = 1$. Inicie a variável inteira para controle do tempo decorrido LTS (*Last Time Stamp*), definida a priori, como $LTS = 1s$, esta é condição de parada, sendo seu valor dado em segundos; ela controla indiretamente o número de iterações.
- Passo 2:** Controle o tempo decorrido. Se a diferença entre a hora atual e a hora do início da busca é menor do que LTS , siga para o próximo passo, caso contrário vá para o **Passo 11**.
- Passo 3:** Controle o laço de busca da população de formigas. Coloque uma formiga k para iniciar a busca. Comece com $k = 1$ e vá até $k = m$.
- Passo 4:** Controle o laço dos recursos defensivos. A formiga k inicia sua busca a partir do recurso $j = 1$, e vai na sequência da lista de recursos até o nó Fim, passando através do recurso $j = W$.
- Passo 5:** A formiga k , posicionada no nó j , seleciona probabilisticamente um arco, o alvo i , de acordo com a Eq.(4.3). Existem T possíveis alvos (arcos) disponíveis partindo de cada recurso (nó) j .
- Passo 6:** Aplique o processo de atualização local do feromônio τ_{ij} , de acordo com a Eq.(4.4), onde τ_0 é dado no **Passo 1**.
- Passo 7:** Atualize o valor do alvo $V_i = V_1(1 - P_{ij})$. Atualize a informação heurística $\eta_{ij} = V_i P_{ij}$ do arco selecionado, de acordo com o valor já atualizado do alvo. Vá para o **Passo 4**.
- Passo 8:** Reinicie os valores dos alvos aos seus níveis originais. Se o valor da solução obtida pela formiga k é igual ou maior do que o valor a melhor solução da iteração corrente, $f(\mathbf{S})_{tBest}$, encontrada até o momento, vá para o **Passo 3**. Caso contrário, atualize $f(\mathbf{S})_{tBest}$, e vá para o **Passo 9**.
- Passo 9:** Se $f(\mathbf{S})_{tBest}$ é menor do que o melhor valor global de redução do nível de ameaça $f(\mathbf{S})_{Best}$, achado até o momento, atualize $f(\mathbf{S})_{Best}$. Vá para o **Passo 3**.
- Passo 10:** Faça a atualização global de feromônio, de acordo com a Eq. (4.5), onde $L^{Best} = 1/f(\mathbf{S})_{tBest}$, atualize os valores dos alvos, retornando-os aos seus valores originais, reinicie a informação heurística $\eta_{ij} = V_i P_{ij}$, para o próximo ciclo de busca. Vá para o **Passo 2**.
- Passo 11:** Retorne $f(\mathbf{S})$.
-

Figura 4.6 - Algoritmo ACS modificado (JOHANSSON e FALKMAN, 2010b)

4.4.4 Modelo Greedy Ant Colony System (GACS)

O método proposto nesta tese, o GACS, é uma variante do ACS em que foi aplicada uma estratégia híbrida gulosa baseada no MMR2 (KOLITZ, 1988) e, um sistema de múltiplas colônias paralelas independentes. A proposta visa melhorar os níveis de redução de ameaça iniciais presentes nos cenários, sem comprometer o desempenho computacional do algoritmo, permitindo a sua aplicação inclusive aos cenários de defesa aérea, onde as limitações temporais são bem mais rigorosas.

Nos experimentos realizados por Johansson e Falkman [(2010a), (2010)], foram implementadas várias heurísticas determinísticas e bio-inspiradas, usadas de forma isolada ou combinada, para tratar o problema. As soluções obtidas por todas estas abordagens, incluindo aí o ACS mostrado no item 4.4.3, se mostraram adequadas somente a cenários de pequeno porte. A observação destes resultados e a confiança na capacidade de adaptação da metaheurística ACO foram os motivadores para a pesquisa de combinações mais promissoras, capazes de melhorar o desempenho tanto em cenários de pequeno porte, como em cenários de grande porte, uma necessidade atual do setor para fazer frente as novas doutrinas e cenários de combate reais e simulados estudados nos dias de hoje.

PARÂMETROS DE INICIAÇÃO

O desempenho do GACS, como em todo algoritmo que implementa a metaheurística ACO, depende muito do ajuste realizado em seus parâmetros de controle, por este motivo foram realizadas várias análises, visando a verificação do nível de sensibilidade das variáveis de controle e das fórmulas usadas no processo de busca.

No ACS adaptado por Johansson e Falkman [(2010a), (2010b)] para o problema SWTA do modelo baseado em alvo, o total de formigas usado é dado pela verificação do número máximo obtido entre o total de recursos defensivos e o total de alvos avaliados. No ACS clássico de Dorigo e Gambardella (1997) é sugerido o uso de 10 formigas. No GACS o número total de formigas foi limitado a 15. A opção de Dorigo e Gambardella limita mais a quantidade de buscas realizadas em um mesmo ciclo, são usadas 10 formigas, prejudicando a melhoria das soluções. Já a opção de Johansson e Falkman, não se mostrou adequada para o tratamento dos cenários de grande porte, aumenta a quantidade de buscas dentro de um mesmo ciclo mas reduz a quantidade

total de ciclos de busca realizados no tempo estabelecido, prejudicando o resultado final em cenários deste tipo.

O uso de um valor muito baixo para o parâmetro β provoca uma estagnação precoce da busca realizada pelo algoritmo. No algoritmo ACS de Johansson e Falkman foi adotado $\beta = 1$. No algoritmo ACS clássico sugere-se $2 \leq \beta \leq 5$. No GACS foi empregada uma estratégia mais arrojada para a definição deste parâmetro, adotando valores bastante elevados e diferenciados para β . Em cenários menores, contendo até 40 ameaças e 80 recursos, foi usado $\beta = 12$, nos cenários maiores, envolvendo até 100 ameaças e 100 recursos, $\beta = 17$. Valores elevados de β priorizam a informação heurística.

Quando o valor do parâmetro q_0 , é mais próximo de 1, o objetivo é priorizar o processo de intensificação, ou seja, a exploração da solução dada pela regra baseada na heurística gulosa, na escolha de um novo elemento do par. Quando o valor de q_0 está mais próximo de 0, prioriza-se a diversificação, ou seja, a exploração de outros elementos aleatórios, conforme indicado na regra do AS. O GACS obteve melhores resultados com a priorização do processo de exploração, ficando o valor final de $q_0 = 0.75$. O ACS modificado (JOHANSSON e FALKMAN, 2010a), (JOHANSSON e FALKMAN, 2010b) adota uma posição neutra com relação a este parâmetro, $q_0 = 0.5$. No ACS clássico é sugerido o uso de $q_0 = 0.9$.

Os demais parâmetros usados nas fórmulas não sofreram modificações com relação aos valores sugeridos na abordagem clássica de Dorigo e Gambardella (1997), comportamento também seguido por Johansson e Falkman [(2010), (2010a)]. No capítulo dedicado aos testes, são apresentados os valores finais da análise de sensibilidade realizada para os cenários testados.

Outro detalhe do GACS em relação ao ACS modificado apresentado na figura Figura 4.6, é o uso da solução obtida pelo algoritmo MMR2 como semente do processo de iniciação da matriz de feromônios. No ACS de Johansson e Falkman é usada a solução obtida pelo algoritmo MMR1.

O critério de parada estabelecido é o mesmo usado no ACS mostrado anteriormente, ou seja, o tempo máximo de busca é limitado a 1 segundo, e os motivos são os mesmos também, a avaliação da adequação do algoritmo para cenários de defesa aérea.

ESTRATÉGIA DE HIBRIDIZAÇÃO

No GACS, a hibridização do ACS com a heurística determinística do MMR2 impõe algumas diferenças no processo de busca usado por Johansson e Falkman em seu trabalho. No algoritmo MMR2, diferentemente do MMR1, a busca pelos melhores pares ij de cada iteração, obtém uma solução que não está ordenada por nenhum dos dois elementos do par, no caso, os alvos e os recursos defensivos. Então, para se obter a solução \mathbf{S} , conforme especificado no capítulo 3, ou seja como um vetor ordenado de $j = 1, \dots, W$, é necessário se reorganizar os pares obtidos pelo algoritmo MMR2.

No GACS, a mudança observada na ordem das designações foi usada como uma forma para se melhorar os resultados alcançados. Esta alteração modifica a ordem da busca realizada no Passo 4 do pseudocódigo do ACS apresentado na Figura 4.6. Foi observado que a inclusão deste novo arranjo, proporcionou uma redução maior dos níveis de ameaça iniciais, embora os percentuais alcançados tenham sido de um modo geral discretos.

Para evitar a estagnação da busca, é proposta uma estratégia extra para controlar a repetição continuada dos melhores caminhos dentro do algoritmo. O objetivo desta proposta é evitar a convergência prematura provocada pelo aumento constante dos níveis de feromônio depositados em caminhos associados a ótimos locais, que aumentariam continuamente seu nível de atratividade. Por este motivo, os caminhos mais visitados, são alvo de um fator de penalidade, que reduz a atratividade dos mesmos pela interrupção do processo de acúmulo de feromônio.

A atualização global de feromônio, mostrada no passo 10 da Figura 4.6, foi modificada, com a introdução de um multiplicador φ no termo responsável pelo controle do processo de depósito de feromônio, conforme indicado na Eq. (4.6):

$$\tau_{ij}(t+1) = (1 - \rho)\tau_{ij}(t) + \rho\varphi\Delta\tau_{ij}^{best}(t), \forall (i, j) \in T^{best} \quad (4.6)$$

O fator multiplicador φ é um valor inteiro que varia dentro da faixa de 1 a 3, $\varphi = [1, 2, 3]$. O valor de φ é automaticamente aumentado quando as formigas revisitam uma determinada solução continuamente. O número de períodos de 200 ms contidos no tempo de computação decorrido controla este aumento do valor φ . Quando o tempo máximo de cálculo é superior a 600 ms, a estratégia de penalização é implementada e os níveis de feromônios são reiniciados para o seu valor inicial,

$\tau_{ij} = 1/(m f(\mathbf{S})_{\text{MMR}_2})$, assim como o factor multiplicador, fazendo $\varphi = 1$. As melhores soluções obtidas anteriormente, são mantidas em uma lista na memória do algoritmo, para não serem perdidas durante este novo processo de busca.

ACO PARALELO

A programação paralela parte do princípio de que determinados problemas de maior complexidade podem ser divididos em partes menores, que são processadas de forma independente e simultânea, tendo depois seus resultados reunidos de modo a prover mais rapidez ao processo de obtenção de solução original usada para o problema. No desenvolvimento de estratégias paralelas é muito importante saber estabelecer o nível de granularidade usado na divisão do problema, o tipo de elemento a ser distribuído, os mecanismos de comunicação adotados.

O uso da computação paralela no ACO, na realidade é uma ideia que já está de certo modo implícita no pseudocódigo que faz a descrição da metaheurística, como apresentado na Figura 4.4. Existem várias formas para se construir uma solução viável concorrentemente, de forma independente, usando mecanismos de comunicação síncronos ou assíncronos (DORIGO e SOCHA, 2006), ficando a cargo do implementador selecionar a opção que melhor se adequa ao seu problema.

Uma das primeiras ideias para melhorar o desempenho foi o uso de técnicas de programação paralela. As implementações paralelas da metaheurística ACO são obviamente voltadas ao tratamento de instâncias mais complexas e de maior porte dos problemas de otimização combinatória, as quais, como já enfatizado sejam consideradas difíceis de serem resolvidas dentro de tempos computacionais polinomiais. O ritmo de evolução acelerado da tecnologia dos computadores tem levado a um número crescente de publicações dedicadas a esta matéria, mas, apesar da imediata identidade com tudo apresentado até aqui, não é fácil se achar artigos que discutam estratégias paralelas para os problemas de alocação de recursos de defesa, sendo poucas as publicações conhecidas (LEE, LEE e SU, 2002a), (GAO, GONG, *et al.*, 2010).

As implementações paralelas do ACO presentes nos trabalhos em geral, propõem diferentes formas de se dividir a população e os procedimentos internos executados pelos elementos da população, de modo a gerar várias unidades de processamento paralelo e, assim, possibilitar a obtenção de respostas mais rapidamente. Dentre os muitos trabalhos já publicados, observa-se um problema

recorrente a muitas outras áreas da pesquisa, que é a falta de uma taxonomia própria e padronizada, que possibilite a classificação coerente das diferentes estratégias usadas nas implementações, facilitando assim o entendimento e a diferenciação dos modelos propostos.

Recentemente, foi publicado um estudo bastante abrangente sobre este tema, que apresenta o estado da arte das implementações; discorrendo sobre os rumos e as perspectivas neste campo, baseado em levantamentos realizados no que foi publicado em livros, jornais e artigos de conferências, todos revisados, no período de 2005 a 2010. Os autores propõem ainda uma nova taxonomia, para auxiliar a classificação dos trabalhos futuros desenvolvidos nesta área (PEDEMONTE, NESMACHNOW e CANCELA, 2011).

Apesar do trabalho publicado, os mesmos autores concordam que esta é uma questão que ainda carece de mais pesquisas, considerando importante se incentivar o uso sistemático de classificações nas publicações em geral. O GACS, emprega uma técnica paralela no intuito de melhorar tanto a questão da redução dos níveis de periculosidade, como os tempos de CPU gastos com a busca de melhores resultados, estando a sua estratégia de acordo com um dos modelos desta taxonomia, como será mostrado mais adiante.

Existem vários aspectos que devem ser considerados quando se cria modelos, as primeiras propostas de categorização surgiram nos anos 90, com um escopo bem mais limitado, mas algumas formas de classificação mais antigas, foram consideradas válidas e incorporadas ao novo conjunto. Os modelos e suas respectivas características, podem ser vistos na Tabela 4.1. Com relação ao preenchimento dos campos, o termo assinalado como D/P, significa que o item Depende da Proposta, podendo assumir diferentes valores.

O GACS pode ser classificado como um algoritmo paralelo explícito. Na Tabela 4.1, o modelo mais adequado para descrever a estratégia implementada é o modelo denominado “Execuções Independentes e Paralelas”. Neste modelo se assume a existência de vários algoritmos ACO sequenciais executando concorrentemente, de forma distribuída e não cooperativa, ou seja, cada algoritmo executa de forma totalmente independente, não havendo nenhuma forma de comunicação entre as colônias de formigas, cada colônia é atribuída a um processador ou a uma linha de execução (*thread*) diferente.

Tabela 4.1 - Modelos de Taxonomia para ACO Paralelo
(Adaptada de (PEDEMONTE, NESMACHNOW e CANCELA, 2011))

| Modelo | Organização da População | Nro. de Colônias | Matriz de Feromônios | Freq. de Comunicação |
|--|--------------------------------|------------------|----------------------|----------------------|
| Mestre-escravo Granularidade grossa | Hierárquica Não cooperativa | 1 | 1 | Média |
| Mestre-escravo Granularidade média | Hierárquica Não cooperativa | 1 | 1 | Média-alta |
| Mestre-escravo Granularidade fina | Hierárquica Não cooperativa | 1 | 1 | Alta |
| Celular | Estruturada Cooperativa | 1 | Muitas | Média |
| Execuções independentes e paralelas | Distribuída Não cooperativa | Várias | Várias | 0 |
| Multicolônias | Distribuída Cooperativa | Várias | Várias | Baixa |
| Híbridos | Hierárquica | D/P | D/P | D/P |

O GACS explora os mecanismos da programação *multithread*. As *threads* executam de forma independente, mas compartilham memória e outros recursos, seus mecanismos de comunicação são também considerados mais rápidos do que os associados aos processos. Cada algoritmo GACS é processado em uma linha de execução independente, existindo um total de 10 *threads* dedicadas ao procedimento de busca, uma para cada colônia do GACS sequencial. Esta forma de abordar o problema, possui um nível de granularidade mais elevado, o que foi considerado mais adequado para a redução do tempo total de processamento.

Dentro de cada *thread* cada colônia segue em seu processo de busca pela melhor solução sequencialmente. Um procedimento principal controla a iniciação dos parâmetros e a obtenção da solução final. Todas as colônias possuem o mesmo tipo de comportamento e a comunicação com o processo principal é assíncrona durante a sua execução. Cada colônia tem sua própria matriz de feromônios, e mantém o

procedimento principal informado acerca dos seus respectivos melhores resultados, através de uma área de memória compartilhada.

Nos testes realizados a seguir observa-se que o somatório de todas estas estratégias, além de aumentar as chances de se obter melhores resultados, ajudou também a evitar a ocorrência de problemas de estagnação.

5 ESTUDO DE CASO

5.1 Introdução

A comparação do algoritmo desenvolvido com outros trabalhos não é uma tarefa trivial, tendo dificuldades inerentes que vão além das associadas a formulação do problema em si. Os autores de publicações nesta área omitem os conjuntos de dados usados em seus testes, a única informação dada sobre os valores usados, são as faixas de variação de cada dado de entrada, sendo os valores em geral obtidos através de geradores de números aleatórios. Não existem também bases de dados padronizadas públicas que possam ser usadas pelos pesquisadores. Obviamente todas estas características estão ligadas a natureza confidencial do assunto tratado, que inibe o surgimento de bases de dados públicas. Portanto, nos testes foi seguido o mesmo padrão presente em outras publicações da área (AHUJA, KUMAR, *et al.*, 2007), (JOHANSSON, 2010).

Para demonstrar o potencial do método GACS proposto é necessário avaliar seu desempenho em cenários com diferentes níveis de complexidade, comparando seus resultados com os resultados alcançados por outros métodos heurísticos clássicos usados no tratamento do problema de alocação SWTA. Os algoritmos usados nestes testes foram todos apresentados no capítulo anterior, e são: o MMR1 (DEN BROEDER, ELLISON e EMERLING, 1959), o MMR2 (KOLITZ, 1988) e o ACS (JOHANSSON e FALKMAN, 2010a).

Para analisar o nível de competitividade do GACS são realizados dois grupos de testes principais. O primeiro grupo contém cenários pequenos e conseqüentemente menos complexos, os tamanhos dos cenários testados vão de 5x5 até 9x9 ($T \times W$). Nestes testes o objetivo é comparar o desempenho das heurísticas determinísticas MMR1 e MMR2, com relação a solução ótima obtida por um método exato. Este tipo de avaliação só é temporalmente viável em experimentos envolvendo cenários pequenos, fáceis de serem processados por um método de enumeração explícita, sendo este o motivo de escolha dos tamanhos de cenário reduzidos encontrados neste teste.

No segundo grupo são avaliados cenários com tamanhos variando de 10x5 até 100x100, que incluem portanto, cenários com níveis de complexidade bem maiores. Nesta etapa, foi verificado o desempenho do GACS com relação aos outros métodos

selecionados: MMR1, MMR2, ACS. Devido ao tamanho dos cenários testados, nesta etapa não é possível comparar a qualidade dos resultados obtidos por cada método com o ótimo absoluto.

Antes de analisar estes dois grupos de testes, são primeiramente apresentados detalhes dos cenários simulados, estudos sobre o desempenho temporal do método exato usado na primeira bateria de testes, estudos sobre as limitações temporais dos cenários de defesa aérea, apresentação dos parâmetros de iniciação do GACS nos cenários usados nos testes, etc. Estes outros testes fornecem uma visão quantitativa e qualitativa de algumas características comentadas ao longo do texto.

5.2 Simulação dos Cenários

A avaliação de desempenho dos algoritmos estáticos de alocação de recursos (SWTA) demanda a representação do cenário em um instante específico do tempo, isto é, a definição do número T de alvos presentes no cenário, a definição do número W de recursos disponíveis, a definição dos valores de ameaça iniciais de cada alvo, apresentados no vetor \mathbf{V} , a definição da probabilidade de dano de cada par recurso-alvo, apresentada na matriz \mathbf{P} .

Os valores T e W definem o tamanho do cenário, e conseqüentemente o tamanho do espaço de busca do problema corrente. Nos testes apresentados nas próximas subseções são usados cenários de diferentes tamanhos, com o objetivo de testar o desempenho do algoritmo em cenários com diferentes níveis de complexidade. Esta espécie de instantâneo da situação tática compõe uma instância do problema. Para cada tamanho de cenário foram simuladas dez instâncias diferentes do problema, ou seja, foram usados dez vetores \mathbf{V} e dez matrizes \mathbf{P} , diferentes na simulação de cada tamanho de cenário.

Os valores de \mathbf{P} e \mathbf{V} modelam recursos de defesa e ameaças contextualizadas, passíveis de compor os cenários reais das operações militares. Na avaliação dos algoritmos, para não se expor dados sigilosos, os valores de \mathbf{V} e \mathbf{P} são gerados aleatoriamente, dentro de faixas de variação pré-estabelecidas. Segundo a proposta de (AHUJA, KUMAR, *et al.*, 2007), uma referência bastante usada na área, os valores de ameaça (\mathbf{V}) são obtidos a partir de uma distribuição uniforme de valores inteiros, variando na faixa de 25 até 100, e os valores das probabilidades de danos (\mathbf{P}), a partir de uma distribuição uniforme de valores reais, variando de 0.6 até 0.9.

Estes intervalos aparecem em muitas publicações, indicando cenários com uma composição mista de ameaças e um conjunto de recursos defensivos com valores de probabilidade de dano, acima da média. Simulações voltadas à verificação de cenários contendo ameaças e recursos específicos também são possíveis, bastando apenas se alterar as faixas de distribuição dos valores.

O ambiente de teste usado para avaliar todos estes algoritmos foi implementado na linguagem de programação C++. Nos experimentos foi usado um computador PC com um processador Intel® Core™ i7, 2.2GHz e 6GB de memória RAM. Os próximos subitens são dedicados a apresentação dos testes voltados a contextualização de diversos elementos ligados ao problema.

5.2.1 Avaliação Temporal do Método de Busca Exaustiva

O tempo de processamento gasto por um método de enumeração explícita, cresce exponencialmente com o tamanho dos cenários. Para evidenciar este comportamento do método de busca exaustiva usado na avaliação de cenários de pequeno porte, foram usados vários tipos de cenários, os tamanhos escolhidos levaram em consideração os valores usados no estudo realizado em (JOHANSSON e FALKMAN, 2009), indo do tamanho 3x3 até o tamanho 9x9. Os tempos de processamento obtidos nos testes são menores, devido certamente as diferenças nas características do ambiente computacional utilizado, mais recente, mas, mesmo assim, os resultados obtidos demonstram claramente as restrições temporais peculiares ao problema de otimização combinatória tratado.

A Tabela 5.1 apresenta os tempos médios de processamento gastos pelo algoritmo para a obtenção dos melhores pares alvo-recurso, sendo os tempos apresentados em milissegundos. Nos casos em que o tempo de CPU consumido foi inferior a 1 milissegundo, o campo correspondente da tabela foi preenchido apenas com um traço.

Os resultados confirmam as observações já realizadas até aqui. Os tempos médios de processamento dos cenários mostrados na última linha da Tabela 5.1, onde o número de alvos é 9, crescem segundo uma escala multiplicativa ascendente de ordem 10. O maior cenário usado nos testes, contém 9 ameaças e 9 recursos defensivos e o tempo consumido no seu processamento é de 395946 milissegundos, ou seja, o algoritmo gasta aproximadamente 400 segundos para chegar a melhor solução, valor que para este tipo de aplicação é considerado muito elevado.

Tabela 5.1- Tempos de CPU do Algoritmo de Busca Exaustiva
(JOHANSSON e FALKMAN, 2009)

| T | W=3 T (ms) | W=4 T (ms) | W=5 T (ms) | W=6 T (ms) | W=7 T (ms) | W=8 T (ms) | W=9 T (ms) |
|---|---------------|---------------|---------------|---------------|---------------|---------------|---------------|
| 3 | - | - | - | - | - | - | 15 |
| 4 | - | - | - | - | 1 | 51 | 246 |
| 5 | - | - | - | 7 | 67 | 363 | 1868 |
| 6 | - | - | - | 32 | 249 | 1585 | 9881 |
| 7 | - | - | 3 | 98 | 765 | 5614 | 42014 |
| 8 | - | 1 | 17 | 223 | 1956 | 16584 | 136468 |
| 9 | - | 1 | 46 | 494 | 4982 | 46279 | 395946 |

A tomada de decisão em cenários de defesa aérea, pode precisar atender a tempos de reação na faixa entre 1 e 2 segundos (JOHANSSON e FALKMAN, 2011). As ameaças aéreas mais críticas estão associadas a aviões ou recursos defensivos com alto poder de manobra. Dados obtidos em sítios da Internet dedicados a assuntos militares, mostram que os aviões militares atualmente em uso ao redor do mundo, possuem velocidades de deslocamento oscilando entre 1000 km/h e 3000 km/h (50 km/min) (ABBUD, 2014). As ameaças aéreas assimétricas, envolvem em geral peças de artilharia, cujas plataformas possuem velocidades de deslocamento menores, sem poder de manobra. Segundo (SHARP, 2008) os tempos de reação necessários para estes casos são em geral da ordem de 15 a 45 segundos.

A seguir são dadas medidas de desempenho típicas de alguns radares e sistemas de defesa. A Tabela 5.2 fornece as especificações dos alcances mínimo e máximo associados a alguns sistemas de defesa de curto, médio e longo alcances.

Tabela 5.2– Características de Recursos Defensivos Típicos
(BENASKEUR, BOSSÉ e BLODGETT, 2007)

| Tipo de Recurso | Alcance Mínimo (Km) | Alcance Máximo (Km) |
|------------------------------|---------------------|---------------------|
| Sistema Antiaéreo | ~ 1.5 | ~ 16 |
| Peças de Artilharia | ~ 1 | ~ 5 |
| Sistema de Defesa Aproximado | 0 | ~ 2.5 |

A Tabela 5.3 mostra o tempo de varredura e a faixa de detecção de radares de vigilância de curto, médio e longo alcances. Os dados da Tabela 5.2 e da Tabela 5.3 são usados como base para a construção de duas novas tabelas, a Tabela 5.4 e a Tabela 5.5. Estas tabelas exemplificam os intervalos de tempo disponíveis para a elaboração de uma reação contra dois tipos de avião, um com velocidade de deslocamento de 1000 km/h e outro com velocidade de 3000 km/h.

Tabela 5.3 – Desempenho de Radares de Vigilância Típicos
(ROUX e VUUREN, 2008)

| Tipo do Radar | Varredura | Alcance (Km) |
|---------------|-----------|--------------|
| Curto Alcance | < 1 s | 0 - 50 |
| Médio Alcance | 2 – 4 s | 50 - 200 |
| Longo Alcance | 10 s | >= 200 |

A Tabela 5.4 mostra os intervalos mínimo e máximo disponíveis para aeronaves situadas em uma das extremidades da região situada entre o alcance máximo do setor de cobertura de um determinado tipo de radar e o alcance máximo do setor de cobertura do sistema de defesa antiaéreo. As colunas da tabela estão associadas a cada uma destas regiões. Cada célula da tabela apresenta dois valores, um para cada tipo de aeronave. Os valores entre parênteses estão associados à aeronave menos veloz (1000 Km/h). Os tempos são todos dados em segundos.

Tabela 5.4 – Tempos de Reação para Ameaças na Região entre a Extremidade Externa do Setor de Cobertura do Radar de Vigilância e a Extremidade Externa do Setor de Cobertura do Sistema de Defesa Antiaéreo

| Tipo do Radar | Intervalo Mínimo | Intervalo Máximo |
|------------------------|-------------------|------------------------|
| Curto Alcance (0~50Km) | ~ 19.2 s (57.6 s) | ~ 60.0 s (180.0 s) |
| Médio Alcance (50~200) | ~ 19.2 s (57.6 s) | ~ 240.1 s (720.3 s) |
| Longo Alcance (>= 200) | ~ 19.2 s (57.6 s) | ~ > 240.1 s (>720.3 s) |

A Tabela 5.5, mostra uma situação mais crítica para a defesa, em que o alvo já está dentro do setor do sistema de defesa, os intervalos de tempo disponíveis são bem menores, estando de acordo com os valores citados por Johansson e Falkman (2011). O intervalo mínimo da Tabela 5.4 corresponde ao intervalo máximo do sistema

de defesa antiaérea, mostrado na Tabela 5.5. Da mesma forma que para a tabela anterior, os valores entre parênteses são da aeronave mais lenta (1000 Km/h).

Tabela 5.5 – Tempos de Reação para Ameaças no Interior do Setor de Defesa

| Tipo de Recurso | Intervalo Mínimo | Intervalo Máximo |
|--------------------|------------------|-------------------|
| Sistema Antiaéreo | ~ 1.8 s (5.4 s) | ~ 19.2 s (57.6 s) |
| Artilharia | ~ 1.2 s (3.6 s) | ~ 6 s (18 s) |
| Sistema Aproximado | 0 s (0 s) | ~ 3 s (9 s) |

As plataformas aéreas possuem um tamanho bem menor do que as plataformas de superfície, isto dificulta a sua detecção pelos sensores de bordo. Em cenários de conflito, o ideal é que as unidades operem de forma colaborativa com outras unidades, possibilitando assim o início do processo de avaliação antes que as ameaças estejam muito próximas ou já no interior do setor de defesa.

Nos sistemas de apoio à decisão semiautomáticos, reais ou simulados, o resultado final obtido pelo algoritmo de alocação é submetido ao operador do sistema, que então decide pelo lançamento ou não dos recursos defensivos da forma indicada. Então, o tempo total disponível para a reação, envolve além do tempo gasto pelo sistema C2, o tempo associado à resposta cognitiva do operador do sistema e o tempo para lançamento do recurso.

5.3 Avaliação de Cenários de Pequeno Porte

Serão realizadas inicialmente simulações visando a avaliação do desempenho das heurísticas MMR1 e MMR2. Para avaliar a qualidade das respostas fornecidas por estes métodos foram geradas 10 instâncias diferentes de cada um dos cinco tamanhos de cenários de pequeno porte testados. O número T de alvos e W de recursos usados na simulação é sempre igual, ou seja, $T = W$, e a diferença de tamanho entre cada cenário é de uma unidade, o que resulta num total de 5 cenários simétricos: 5x5, 6x6, 7x7, 8x8, 9x9.

A Tabela 5.6 apresenta o índice de sucesso do algoritmo MMR1 e do algoritmo MMR2. O índice mostra o número de vezes em que cada algoritmo alcançou o mínimo global do problema STWA, se equiparando ao algoritmo de busca exaustiva. Entre parênteses, está o percentual que este valor representa com relação ao total de amostras simuladas.

O índice de sucesso do MMR1 foi pior que o obtido pelo MMR2, mas na análise individual dos resultados do MMR1, para alguns tamanhos de cenário, o algoritmo MMR1 conseguiu chegar ao ótimo absoluto em 10% das instâncias dadas. O MMR2 apresentou uma probabilidade bem maior de alcançar o ótimo global, tendo alcançado o feito para quase todos os tamanhos de cenários de pequeno porte testados. Ambas heurísticas são muito simples e rápidas, sendo muito usadas em processos de hibridização.

Tabela 5.6 - Índice de Sucesso do MMR1 e do MMR2

| Tamanho do Cenário | Índice de Sucesso MMR1 | Índice de Sucesso MMR2 |
|--------------------|------------------------|------------------------|
| 5x5 | 1 (10%) | 5 (50%) |
| 6x6 | 0 | 6 (60%) |
| 7x7 | 1 (10%) | 3(30%) |
| 8x8 | 1 (10%) | 4 (40%) |
| 9x9 | 0 | 0 |

A Tabela 5.7 mostra a redução dos níveis iniciais de ameaça obtidos pelos algoritmos MMR1, MMR2 e busca exaustiva (BE) (JOHANSSON e FALKMAN, 2009).

Tabela 5.7 – Resultados dos algoritmos: MMR1, MMR2, BE (JOHANSSON e FALKMAN, 2009).

| Cenário | | BE $f(\mathbf{S})$ | | MMR1 $f(\mathbf{S})$ | | MMR2 $f(\mathbf{S})$ | |
|---------|-----------------------|-----------------------|----------|-------------------------|----------|-------------------------|----------|
| W x T | $\langle V_T \rangle$ | Média | σ | Média | σ | Média | σ |
| 5x5 | 318.2 | 50.89 | 8.65 | 60.85 | 16.93 | 54.23 | 11.97 |
| 6x6 | 359.6 | 57.93 | 6.75 | 67.33 | 11.23 | 61.44 | 8.18 |
| 7x7 | 421.4 | 61.63 | 10.08 | 70.74 | 12.88 | 66.62 | 15.00 |
| 8x8 | 508.4 | 75.11 | 7.87 | 89.37 | 10.99 | 81.84 | 13.43 |
| 9x9 | 536.4 | 76.69 | 6.88 | 105.63 | 9.80 | 81.88 | 8.51 |

$\langle V_T \rangle$: média da soma dos valores iniciais de ameaça de cada instância; Média: média da minimização de $f(\mathbf{S})$ das 10 instâncias de cada tamanho de cenário; σ : desvio padrão.

Os resultados representam a média obtida sobre as 10 instâncias simuladas de cada tipo de cenário. Os tempos de CPU foram omitidos por não terem sido considerados necessários para os objetivos do teste atual, o MMR1 e o MMR2 consomem menos de 1 milissegundo no processamento destes cenários de pequeno porte. O tempo gasto pelo algoritmo de busca exaustiva é consideravelmente maior, mas a ordem de grandeza dos tempos associados a cada tamanho de cenário já foi avaliada anteriormente, podendo ser revista na Tabela 5.1.

A Figura 5.1 mostra os valores iniciais de ameaça de cada instância do cenário 9x9. Pela figura é possível observar a taxa de variação existente entre estes valores. Comparando-se estes níveis de ameaça com o valor médio mostrado na Tabela 5.7, observa-se que para alguns casos, a margem de variação atinge valores percentuais da ordem de +/- 10%.

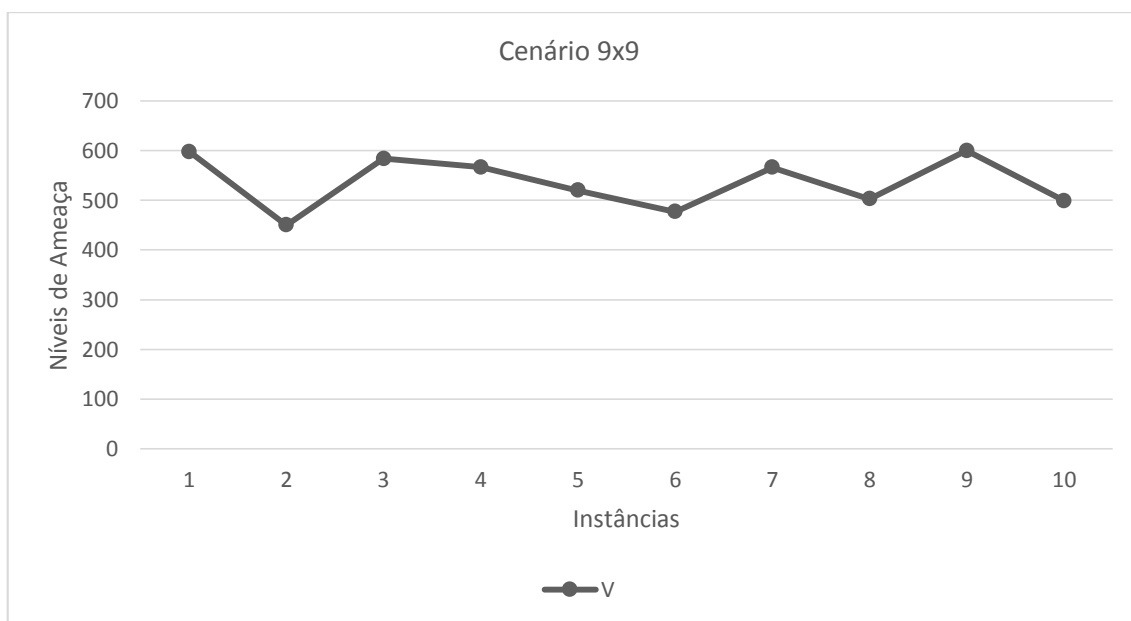


Figura 5.1 – Níveis Iniciais de Ameaça do Cenário 9x9

A Figura 5.2 mostra a redução do nível de ameaça de cada instância do cenário de tamanho 9x9. Os valores, obtidos com a aplicação dos algoritmos de alocação BE, MMR1 e MMR2, possuem uma taxa de variação ao longo das 10 instâncias simuladas. Estas variações são mais suaves que as observadas na Figura 5.1, mas de certa forma, seguem o comportamento visto nesta figura.

Os desvios padrão elevados observados na Tabela 5.7 são o resultado destas variações. Pela Tabela 5.7 e pela Figura 5.2, fica claro também que o desempenho do algoritmo MMR2 é bem próximo do mínimo global calculado pelo algoritmo BE.

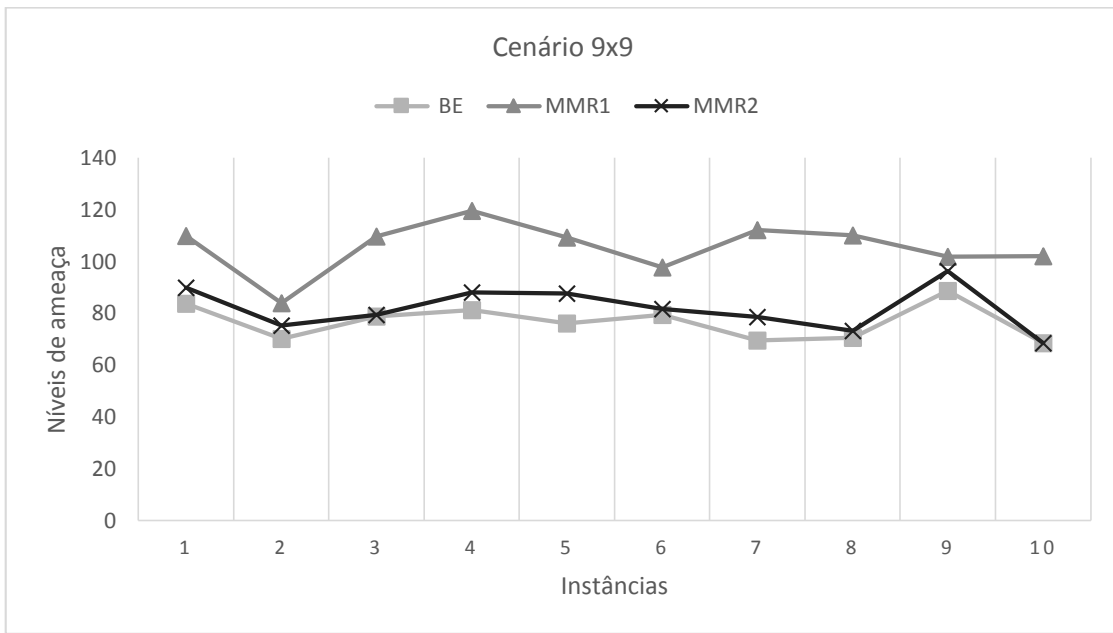


Figura 5.2 – Valores finais de ameaça obtidos pelos algoritmos BE, MMR1 e MMR2 para cada uma das 10 instâncias simuladas para um cenário 9x9

O diagrama em barras da Figura 5.3 mostra de forma mais clara os acentuados níveis de redução de ameaça obtidos pelo algoritmo BE e pelas heurísticas MMR1 e MMR2.

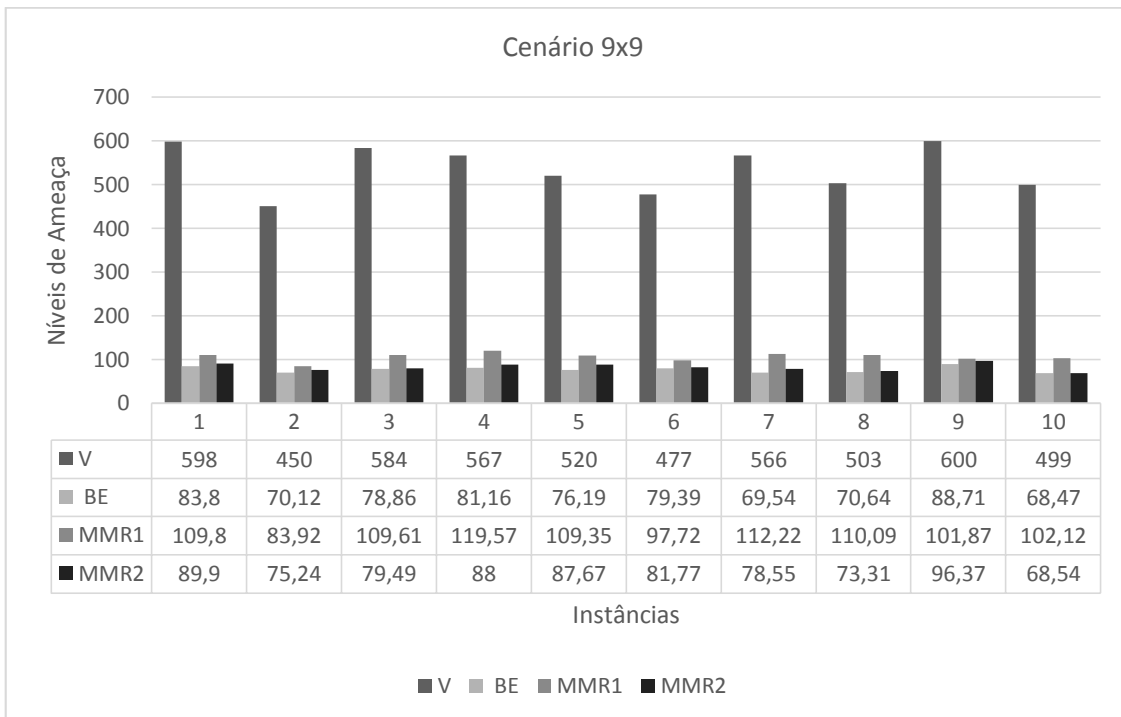


Figura 5.3 – Gráfico de barras dos Níveis de Ameaça Iniciais e Finais do Cenário

O algoritmo MMR2 apresenta um desempenho bem melhor que o algoritmo MMR1, fato visível na Figura 5.2. Olhando individualmente para cada uma das células da Tabela 5.6, correspondentes a cada uma das heurísticas e tamanhos de cenário testados, o MMR2 obteve o ótimo global para 18 das 50 instâncias simuladas. O MMR1 só foi bem sucedido em 3 das 50 instâncias, mas para estes poucos casos, ele alcançou melhores resultados do que o MMR2.

Os resultados obtidos com o processamento destes cenários menores não podem ser usados para se chegar a conclusões sobre o desempenho generalizado dos algoritmos para todos os tipos de cenário, mas, o processamento dos cenários de pequeno porte é mais rápido, e por conseguinte, mais fácil ser obtido, quando comparado aos cenários de grande porte. A simulação realizada com base nestes cenários tem o intuito de demonstrar o desempenho relativo das abordagens heurísticas construtivas selecionadas.

5.4 Avaliação de Cenários de Grande Porte

O método GACS vai ter seu desempenho comparado com outros três métodos, implementados no sistema para este fim. Os métodos heurísticos usados no teste dos cenários de grande porte, são os algoritmos MMR1, MMR2, ACS e GACS. Estas novas simulações envolvem cenários contendo até 100 ameaças e 100 recursos. Para aumentar a complexidade destes novos testes, foram incluídos cenários em que a relação entre as quantidades de recursos e alvos além de não ser unitária ($T \neq W$), também não é favorável, considerando casos em que $T > W$.

Os resultados dos experimentos realizados são apresentados da mesma forma usada para o caso de testes anterior, sendo apresentada a média dos melhores valores obtidos por cada uma das 10 instâncias de cada um dos diferentes tamanhos de cenário simulados. A resposta obtida pelos algoritmos MMR1 e MMR2, para cada instância do problema, resulta de uma única execução. Cada resultado obtido pelo algoritmo ACS é o melhor obtido em 10 execuções sequenciais. Enquanto isto, para o algoritmo GACS, o valor final obtido representa o melhor resultado obtido entre as 10 linhas de execução (threads) do algoritmo GACS, executadas em paralelo.

5.4.1 Parâmetro de Ajuste do ACS e do GACS

Os parâmetros de ajuste usados para o algoritmo ACS foram definidos em (JOHANSSON, 2010):

$$\alpha=1, \beta = 1, \rho = 0.1, \xi = 0.1, q_0 = 0.5.$$

Os parâmetros de ajuste do algoritmo GACS foram obtidos pela análise paramétrica dos vários tipos de cenário simulados:

$$\alpha=1, \beta = 12, \rho = 0.1, \xi = 0.1, q_0 = 0.75, \varphi=1, m=15.$$

$\beta = 17$ para os últimos três tamanhos de cenários (80x40 / 80x80 / 100x100).

5.4.2 Resultados Obtidos

A média dos melhores valores e os tempos de CPU correspondentes, dados em segundos, são listados na Tabela 5.8. Os tamanhos da maioria das instâncias deste segundo caso de teste são maiores do que os mostrados na Tabela 5.7. O objetivo deste teste é analisar o comportamento dos algoritmos em cenários com maior nível de complexidade, onde a relação recurso/alvo não seja favorável em termos defensivos. A Tabela 5.8 apresenta os resultados dos testes envolvendo os quatro algoritmos: o MMR1, o MMR2, o ACS, o GACS.

Tabela 5.8 – Resultados dos algoritmos: MMR1, MMR2, ACS e GACS

| Cenário | | MMR1 | | MMR2 | | ACS | | GACS | |
|---------|-----------------------|--------|--------|--------------|--------|--------|-------|---------------|--------|
| T x W | $\langle V_T \rangle$ | Média | T(s) | Média | T(s) | Média | T(s) | Média | T(s) |
| 10x5 | 536.0 | 243.1 | <0.001 | 260.2 | <0.001 | 237.0 | <.001 | 235.8 | <0.001 |
| 10x10 | 660.0 | 92.7 | <0.001 | 147.4 | <0.001 | 114.4 | <.001 | 92.7 | <0.001 |
| 10x20 | 636.0 | 23.6 | <0.001 | 12.2 | <0.001 | 17.3 | 0.151 | 11.9 | <0.001 |
| 20x10 | 1213 | 529.5 | <0.001 | 569.7 | <0.001 | 526.8 | 0.204 | 526.6 | <0.001 |
| 20x20 | 1225 | 226.7 | <0.001 | 158.9 | <0.001 | 202.6 | 0.271 | 157.6 | <0.001 |
| 20x40 | 1238 | 40.9 | <0.001 | 19.0 | <0.001 | 31.2 | 0.293 | 18.7 | <0.001 |
| 40x20 | 2244 | 1111.9 | <0.001 | 1057.8 | <0.001 | 1100.7 | 0.209 | 1057.3 | <0.001 |
| 40x40 | 2497 | 405.6 | <0.001 | 290.7 | <0.001 | 395.2 | 0.507 | 290.3 | 0.020 |
| 40x80 | 2420 | 68.4 | <0.001 | 31.1 | <0.001 | 63.4 | 0.555 | 30.9 | 0.154 |
| 80x40 | 5018 | 2215.8 | <0.001 | 2140.6 | <0.001 | 2247.1 | 0.518 | 2140.4 | 0.174 |
| 80x80 | 4983 | 732.8 | <0.001 | 548.6 | <0.001 | 688.6 | 0.621 | 547.8 | 0.265 |
| 100x100 | 6246 | 884.5 | <0.001 | 667.5 | <0.001 | 849.5 | 0.540 | 676.6 | 0.181 |

$\langle V_T \rangle$: média da soma dos valores iniciais de ameaça; Média dos melhores $f(\mathbf{S})$ obtidos pelas 10 instâncias de cada tamanho de cenário; T(s): tempo em segundos.

Na tabela pode-se verificar que o algoritmo que apresenta o melhor desempenho em termos de redução do nível de ameaça, dentre os 11 cenários simulados, é o GACS, que só perde para o MMR2 no último cenário, o maior tamanho de cenário testado (100x100). O algoritmo MMR2 é o segundo melhor algoritmo, e seus tempos são tão reduzidos quanto os obtidos pelo algoritmo MMR1. O algoritmo ACS apresenta o terceiro lugar em termos de desempenho, ganhando apenas da heurística MMR1, mas seus tempos de processamento são os piores dentre os quatro algoritmos avaliados. Os resultados obtidos pelo método MMR1 são os piores, quando comparados com todos os demais, mas como já foi mencionado, este tipo de algoritmo é muito rápido, portanto é fácil avaliar a eficácia de sua solução para um problema específico, em paralelo com outras estratégias.

Os resultados obtidos pelo GACS asseguram a qualidade superior fornecida pelo modelo híbrido paralelo implementado, quando comparados com os resultados obtidos pelo ACS e pelo MMR1, para todos os problemas de otimização testados.

As figuras a seguir são para efeito de uma avaliação e comparação mais detalhadas dos valores obtidos no processamento do cenário 80x80. A Figura 5.4 mostra a variação existente entre os níveis de ameaça de cada instância deste cenário. Todos os métodos conseguiram consideráveis índices de redução dos níveis de ameaça, sendo os resultados obtidos pelas duplas ACS&MMR1 e GACS&MMR2, relativamente próximos, havendo no entanto, uma ligeira vantagem para as propostas baseadas no ACO.

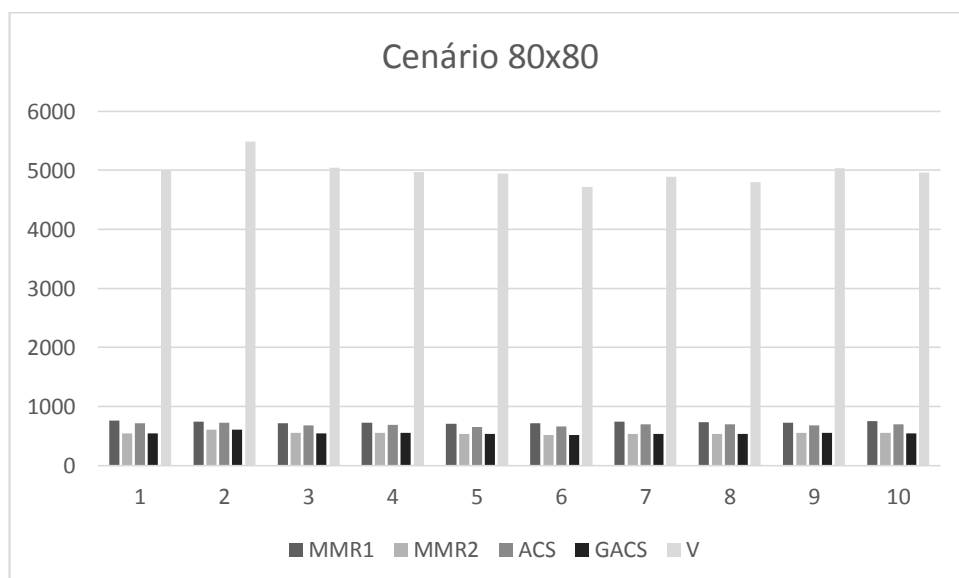


Figura 5.4 - Níveis de Ameaça de cada instância do Cenário 80x80

A Figura 5.5 mostra em uma escala mais favorável que a mostrada na Figura 5.4, como o desempenho do GACS é bem superior ao alcançado pelo ACS proposto em (JOHANSSON e FALKMAN, 2010a) para todas as 10 instâncias deste cenário. Estes autores realizaram testes com outros métodos, mas o maior tamanho de cenário testado foi 30x30 (JOHANSSON e FALKMAN, 2011).

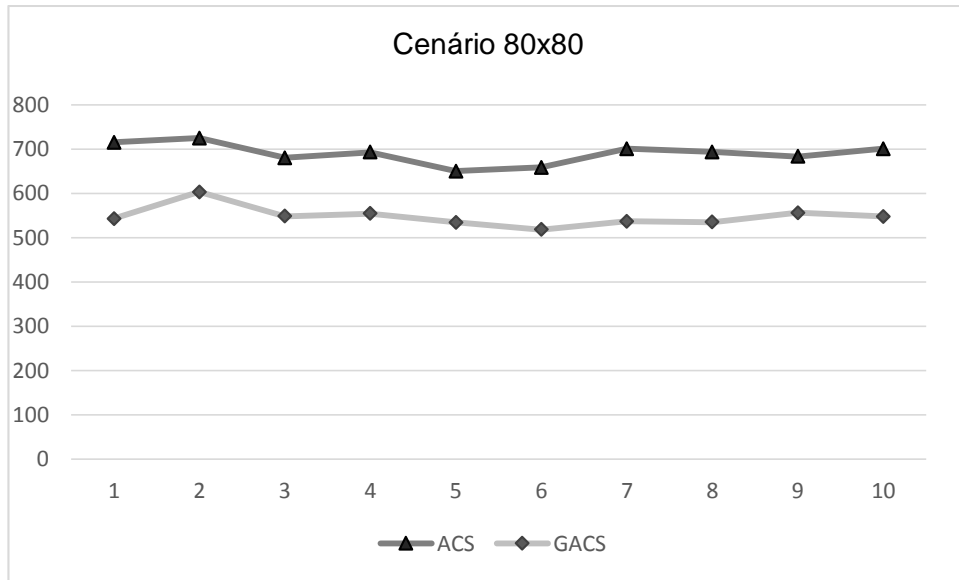


Figura 5.5 – Comparação dos Resultados do GACS e do ACS

A Figura 5.6 evidencia a proximidade entre os resultados do GACS e do MMR2 no cenário 80x80.

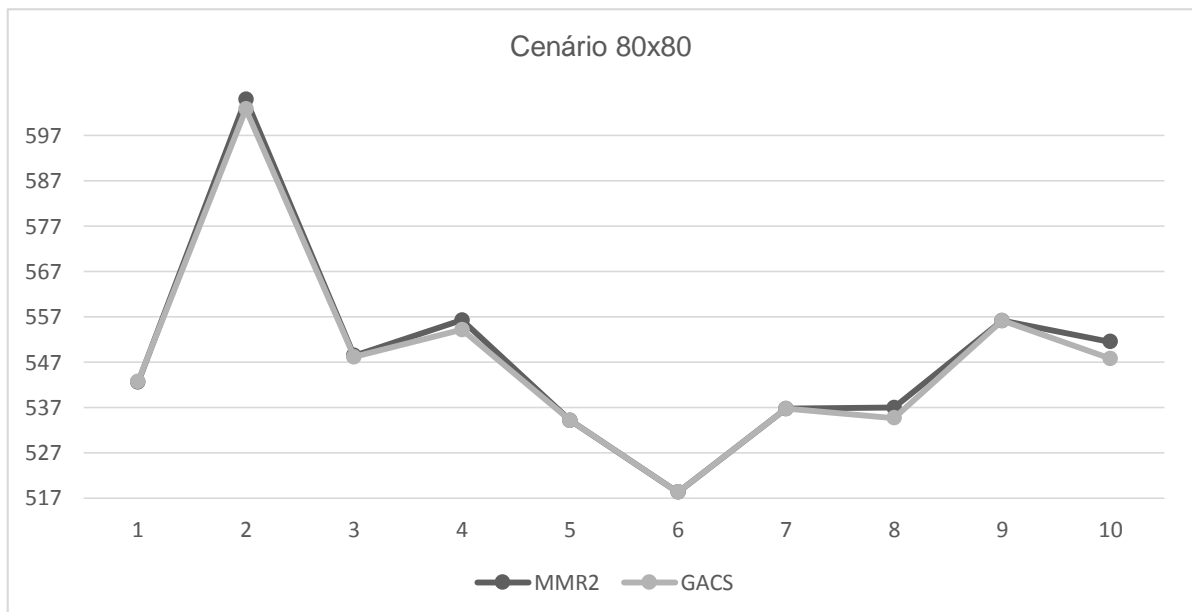


Figura 5.6 – Comparação dos Resultados do GACS e do MMR2

Dentre as diversas propostas baseadas em metaheurísticas mostradas na subseção 3.3.4, o trabalho apresentado em (JULSTROM, 2009) foi destacado por envolver cenários de complexidade bem elevada, contendo até 400 ameaças e 200 recursos, e tempos computacionais relativamente baixos. A Tabela 5.9 apresenta um extrato dos resultados obtidos no trabalho de Julstrom com a versão de AG denominada *string-coded*, identificada na tabela como AG1. O método AG1, na versão semeada com a solução do MMR2, apresenta os maiores níveis de redução de ameaça ou, no pior caso, pelo menos se iguala ao valor obtido pelo método MMR2. Os tempos da versão semeada do AG1 que são superiores a 1 segundo, limite de tempo de busca adotado nesta tese, estão destacados em negrito. Neste extrato dos testes é possível observar que os tempos computacionais são todos superiores aos obtidos pelo GAGS.

Tabela 5.9 – Resultados do MMR2 e da versão semeada e não semeada do AG1.

| Cenário | | MMR2 | | AG1 | | AG1 Semeado | |
|---------|------|-----------------|--------|--------|------|-------------|-------------|
| T x W | <V> | $f(\mathbf{S})$ | T(s) | Média | T(s) | Média | T(s) |
| 40x40 | 2544 | 304.0 | <0.001 | 387.7 | 2.8 | 303.2 | 0.8 |
| 40X80 | 2431 | 31.1 | <0.001 | 46.1 | 20.0 | 31.1 | 5.0 |
| 80X40 | 4904 | 2128.1 | <0.001 | 2240.5 | 3.2 | 2127.9 | 0.8 |
| 80X80 | 4809 | 517.6 | <0.001 | 718.1 | 21.4 | 516.9 | 5.3 |
| 100x100 | 6115 | 663.5 | <0.01 | 954.3 | 41.5 | 663.1 | 10.3 |

<V> soma dos graus de ameaça iniciais. $f(\mathbf{S})$: resultado do MMR2. Média: média dos resultados do AG1. T(s): tempo de processamento em segundos.

Tabela 5.10 - Resultados do MMR2 e da versão semeada e não semeada do AG2.

| Cenário | | MMR2 | | AG2 | | AG2 Semeado | |
|---------|------|-----------------|--------|--------|-------|-------------|-------------|
| T x W | <V> | $f(\mathbf{S})$ | T(s) | Média | T(s) | Média | T(s) |
| 40x40 | 2544 | 304.0 | <0.001 | 291.1 | 4.4 | 289.2 | 1.8 |
| 40X80 | 2431 | 31.1 | <0.001 | 33.6 | 34.6 | 29.6 | 14.2 |
| 80X40 | 4904 | 2128.1 | <0.001 | 2105.6 | 7.2 | 2106.7 | 2.9 |
| 80X80 | 4809 | 517.6 | <0.001 | 511.8 | 57.7 | 506.8 | 23.5 |
| 100x100 | 6115 | 663.5 | <0.01 | 650.6 | 155.7 | 643.5 | 63.1 |

<V> soma dos graus de ameaça iniciais. $f(\mathbf{S})$: resultado obtido pelo MMR2. Média: média dos resultados obtidos pelo AG2. T(s): tempo de processamento em segundos.

A Tabela 5.10 apresenta um extrato dos resultados obtidos por Julstrom com a versão de AG denominada *permutation-coded*, identificada nesta tabela como AG2. O método AG2, na versão semeada com a solução do MMR2, apresenta níveis de redução de ameaça maiores que o AG1, superando o MMR2 em todos os cenários exibidos na tabela. No entanto, na versão semeada do AG2, os tempos computacionais são todos superiores a 1 segundo, conforme destacado em negrito na tabela. O desempenho temporal do AG2 é bem inferior ao alcançado pelo AG1 e pelo GACS.

Todos os métodos testados aqui alcançaram elevados níveis de redução quando comparados com os valores iniciais de ameaça dos alvos, especialmente nos casos de teste em que $W > T$, o que está de acordo com as condições de defesa mais favoráveis representadas por este tipo de cenário. Nos casos de teste em que $W < T$, ficam tipificadas condições de defesa mais desfavoráveis, e neste caso, todos os métodos alcançaram níveis de redução dos valores iniciais de ameaça muito menores que os obtidos para o caso anterior, mas, mesmo assim, os resultados obtidos podem ser considerados bons.

Os resultados fornecidos pelo método proposto nesta tese, o GACS, se mostraram competitivos quando comparados a outras propostas similares (JULSTROM, 2009), (JOHANSSON e FALKMAN, 2010a). Infelizmente, para estas dimensões do problema, não é possível se verificar a qualidade das soluções obtidas em um período de tempo que seja viável para a natureza do problema. O modelo adotado não possibilita quantificar os danos impostos aos alvos como resultado dos engajamentos realizados pelos recursos designados por cada algoritmo, permitindo assim a correlação dos resultados obtidos com uma simulação de enfrentamento real. Entretanto, a incorporação destes requisitos ao algoritmo, visando atender este tipo de aplicação, pode ser considerada como uma tarefa de complexidade relativamente baixa.

6 CONCLUSÕES

Este trabalho propõe uma nova variante para o ACS, um algoritmo de otimização de formigas tradicional e bastante conhecido. Esta variante, denominada GACS, é voltada à solução de um problema crucial do planejamento de operações táticas militares, o problema estático de alocação de recursos defensivos (STWA). O algoritmo proposto faz a hibridização do ACS com o MMR2, uma heurística determinística clássica. Em sua implementação são usadas formas de iniciação do feromônio e da informação heurística específicas para o problema de alocação, a estratégia de seleção também foi adaptada para o problema.

Atualmente, o foco das simulações de operações de defesa militares é a implementação do conceito de defesa em rede, onde um conjunto elevado de ameaças e recursos, pertencentes a diferentes unidades, deve ser gerenciado de forma conjunta, visando obter a melhor alocação global possível, em um espaço de tempo bastante reduzido. Este novo conceito obriga a realização de simulações envolvendo cenários de maior complexidade, contendo um grande número de ameaças e recursos. Não existe um padrão definido para a classificação dos cenários em função do seu tamanho, mas os níveis de complexidade adotados neste trabalho, estão fundamentados em propostas apresentadas em outras publicações da área (AHUJA, KUMAR, *et al.*, 2007), (JULSTROM, 2009), (JOHANSSON e FALKMAN, 2010a). Este trabalho testou cenários com diversos níveis de complexidade, envolvendo até 100 ameaças e 100 recursos

O uso da técnica de múltiplas colônias em paralelo, permitiu a melhoria da qualidade da solução quando comparado com a versão de ACS sequencial vistas em outros algoritmos evolucionários, incluindo o ACS aqui implementado. A técnica permitiu o aumento do número das buscas executadas dentro do período reduzido estabelecido para a mesma. O tempo máximo de busca estabelecido possui um valor reduzido, porque faz parte da proposta do trabalho avaliar a adequação dos algoritmos em cenários de defesa aérea.

Propostas baseadas no ACO não garantem um resultado exato, ou seja, não garantem a obtenção do ótimo global. Porém, a natureza combinatória do problema de alocação de recursos defensivos, um problema da classe NP-Completo, obriga a adoção de heurísticas para a obtenção de uma solução aproximada, de boa qualidade (solução ótima local). Os métodos exatos, precisam enumerar todas as soluções

possíveis, sendo por conta disto temporalmente inviáveis. O GACS foi testado em cenários de grande porte, tendo seu desempenho comparado com duas heurísticas gulosas, o MMR1 e o MMR2, e um outro algoritmo ACS sugerido na literatura.

Na simulação de cenários defensivos complexos de grande porte, mesmo pequenas melhorias podem fazer a diferença, justificando o uso de algoritmos com tempo computacional mais alto. Para não deixar o algoritmo executando por um período demasiadamente grande, é estabelecido um limite máximo como critério para o encerramento da busca, devendo esta limitação temporal ser adequada aos objetivos do problema.

Obviamente, em cenários menores, o melhor procedimento é fazer uma busca exaustiva usando um método de enumeração explícita. O GACS foi testado em cenários de alta complexidade, alcançando resultados bastante competitivos quando comparado aos resultados dos algoritmos citados como base de referência. Os níveis de redução de ameaça alcançados foram bem elevados nos cenários em que $W > T$, um tipo de cenário que configura uma situação mais favorável para a defesa, mas mais importante do que isto, foi o fato do GACS ter conseguido níveis de redução competitivos também para os casos em que isto não ocorre, ou seja, $W < T$.

O SWTA é um modelo de alocação de recursos militares clássico da área de PO. Este modelo pode ser adaptado para o tratamento de diversos outros problemas de alocação, tanto na área militar, na otimização da alocação de sensores em sistemas C2, como também, na alocação humanitária de remédios para o combate de doenças, por exemplo. O bom desempenho alcançado pela heurística desenvolvida nesta tese, e a facilidade da adequação das abordagens baseadas no ACO, motivam a pesquisa do emprego do GACS para problemas tanto no escopo de atuação da MB como na sociedade em geral. Na próxima subseção esta questão é abordada em mais detalhes.

6.1 Trabalhos Futuros

O tema abordado nesta tese é bastante amplo, existindo várias alternativas para o desenvolvimento de novos trabalhos. A alocação de recursos defensivos, segundo (BENASKEUR, BOSSÉ e BLODGETT, 2007), envolve o planejamento da alocação dos recursos propriamente ditos, e a programação da aplicação destes recursos aos seus respectivos alvos de acordo com a evolução do cenário ao longo do tempo.

O modelo usado no trabalho, trata do planejamento da alocação estática de recursos, a programação não é levada em conta, mas existem modelos voltados ao tratamento de problemas de alocação de recursos dinâmicos. No modelo estático, todos os valores dos parâmetros de entrada estão definidos e os recursos são todos aplicados em um único ciclo. No modelo dinâmico se considera que os recursos vão sendo distribuídos de forma gradativa, de acordo com a evolução do cenário, isto significa que o espaço de busca muda ao longo do tempo. Estudar formas de se alterar a direção da busca em algoritmos baseados no ACO, como é o caso do GACS, é uma opção interessante e ainda não muito explorada nesta área de aplicação. A aplicação de metaheurísticas como o ACO a problemas de otimização dinâmica pode ser vista em trabalhos recentes na área de telecomunicações, como no roteamento em redes de telecomunicações, por exemplo (LIO e VERMA, 2010). No setor militar, um exemplo da alocação de recursos para a defesa de fortificações em cenários dinâmicos (DWTA), pode ser visto na proposta de (CHEN, XIN, *et al.*, 2009). Este trabalho apresenta um modelo dinâmico baseado em AG.

Os dados usados como parâmetros de entrada do algoritmo, o vetor **V** e a matriz **P**, tiveram seus valores gerados de forma aleatória. Vários elementos influenciam na obtenção destes valores nos sistemas C2 reais e simulados, o aprofundamento no estudo dos critérios e das técnicas que podem ser usadas para a obtenção dos mesmos, pode resultar em um trabalho interessante. Os trabalhos publicados que tratam da definição do grau de ameaça de cada alvo, não são numerosos e em geral não descrevem de forma clara detalhes de suas propostas, especialmente quando relacionados a sistemas militares.

O problema de alocação estática estudado aplica-se ao modelo de defesa baseado em alvo, descrito em (HOSEIN, 1990), mas, este autor também aborda o modelo de defesa baseado em instalações. No modelo baseado em instalação, além da probabilidade de dano, são usados outros parâmetros de entrada, como o valor de cada instalação e a letalidade que cada alvo representa para a instalação para a qual está direcionado, quando não for interceptado por nenhum recurso. A aplicação dos algoritmos a este modelo de defesa, além da especificação dos critérios para a definição dos valores destes outros parâmetros são temas que complementariam o tratamento da questão da alocação em cenários estáticos.

A integração da alocação de recursos, com um sistema de informações geográficas, pode ser explorada de diferentes formas, expandindo o escopo do modelo, agregando informações que garantam mais confiabilidade à análise de risco

do cenário. A identificação de obstáculos geográficos tridimensionais na região em que a ação transcorre, facilita tanto na identificação prévia das possíveis estratégias do lado oponente, como na elaboração das mesmas no lado da defesa. Esta noção espacial melhora também o processo de avaliação das ameaças, permitindo a inclusão de pesos associados ao setor ou país de origem dos alvos e, ao nível de conformidade do deslocamento dos alvos com as rotas comerciais praticadas na região. A criação de cenários cenográficos virtuais com as características da região, é outra opção para o estudo de casos de alocação, explorada em (OXENHAM e CUTTLER, 2006).

O modelo de cenário usado não contempla o mapeamento dos danos resultantes de uma operação de alocação. Reduzir o risco global de um cenário a um valor mínimo absoluto pode ser além de desnecessário, sob o ponto de vista tático, indesejado, com o emprego massivo de elementos para conter ameaças cujo porte não demande este tipo de ação. Operações deste tipo, além de onerar os custos da missão, provocam a perda precoce de recursos importantes, que poderiam ser mais bem empregados em ciclos de defesa posteriores. O uso massivo de recursos defensivos, pode também imputar danos a outras plataformas ou povoados situados em regiões próximas ao local da operação, o que obviamente é um efeito colateral indesejado, e que deve ser evitado a todo custo.

Esta situação, tratada mais recentemente em alguns trabalhos (BOGDANOWICZ, 2009), (BOGDANOWICZ, 2012), (BOGDANOWICZ, TOLANO, *et al.*, 2013), recebe o nome de *Over Kill*. Para a sua modelagem é necessário se estabelecer um limite de redução de risco que atenda ao mesmo tempo as condições de dissuasão ou avaria de cada ameaça, bem como, as condições de custo e impacto na região do entorno.

REFERÊNCIAS BIBLIOGRÁFICAS

ABBUD, G. Aviation Top 100. **Military Power Review**, 2014. Disponível em: <<http://www.militarypower.com.br/frame4-aviao.htm>>. Acesso em: 12 Outubro 2014.

AHUJA, R. K. et al. "Exact and Heuristic Methods for the Weapon Target Assignment Problem". **Operations Research**, v. 55, n. 6, Nov. 2007. pp. 1136 - 1146.

BENASKEUR, A. R.; BOSSÉ, É.; BLODGETT, D. **Combat resource allocation planning in naval engagements**. Defence R&D. Valcartier. 2007.

BOGDANOWICZ, Z. R. "A new efficient algorithm for optimal assignment of smart weapons to targets". **Computers and Mathematics with Applications**, v. 58, n. 10, 2009. pp. 1965 - 1969.

BOGDANOWICZ, Z. R. "Advanced Input Generating Algorithm for Effect-Based Weapon-Target Pairing Optimization". **IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans**, v. 42, n. 1, 2012. pp. 276 - 280.

BOGDANOWICZ, Z. R. et al. "Optimization of Weapon-Target Pairings Based on Kill Probabilities". **IEEE Transactions on Cybernetics**, v. 43, n. 6, Dec. 2013. pp. 1835 - 1844.

CARVALHO JUNIOR, J. G. **Fusão de Dados Multi-Nível em Ambientes de Monitoração Contínua de Sistemas táticos Navais Utilizando Múltiplas Lógicas**. Tese de D.Sc., COPPE/UFRJ. Rio de Janeiro, RJ, Brasil. 2010.

CASTRO, F. Armas Navais Primárias. **Sistemas de Armas**, 2009. Disponível em: <<http://sistemasdearmas.com.br/nav/modmbngfs.html>>. Acesso em: 27 Setembro 2014.

CHEN, J. et al. "Evolutionary decision-makings for the dynamic weapon-target assignment problem". **Science in China Series F.-Information Science**, v. 52, n. 11, Nov. 2009. pp. 2006 – 2018.

CHEONG, C. K. **Survey of investigations into the missile allocation problem**. M. Sc. Thesis, Naval Postgraduate School. Monterey, CA, USA, p. 113. 1985.

DEN BROEDER, G. G.; ELLISON, E. L.; EMERLING, L. "On optimum target assignments". **Operations Research**, v. 7, n. 3, 1959. pp. 322 - 326.

DORIGO, M. **Optimization, Learning and Natural Algorithm [in Italian]**. PhD Thesis, Dipartimento di Elettronica, Politecnico di Milano. Milan, Italy. 1992.

DORIGO, M.; DI CARO, G. "**Ant colony optimization - A new meta-heuristic**". In: Proceedings of the 1999 Congress on Evolutionary Computation. Washington, DC, USA: IEEE Press. 1999. p. 1470 - 1477.

DORIGO, M.; GAMBARDELLA, L. M. "Ant colony system: A cooperative learning of traveling salesman problem". **IEEE Transactions on Evolutionary Computation**, v. 1, n. 1, Apr. 1997. pp. 53 - 66.

DORIGO, M.; SOCHA, K. **An Introduction to Ant colony Optimization**. Université Libre de Bruxelles. Bruxelles, Belgium, p. 22. 2006. (TR/IRIDIA/2006-010).

DORIGO, M.; STÜZLE, T. **Ant Colony Optimization**. Cambridge, MA: MIT Press, 2004.

EBERHART, R. C.; KENNEDY, J. "**A New Optimizer using Particle Swarm Theory**". In: Proceedings of the Sixth International Symposium on Micro Machine and Human Science. Nagoya, Japan: IEEE Service Center. 1995. p. 39 - 43.

ECKLER, A.; BURR, S. **Mathematical models of target coverage and missile allocation**. Military Operations Research Society. Alexandria, VA. 1972. (Technical Report DTIC:AD-A953517).

EVERETT, H. "Generalized Lagrange multiplier method for solving problems of optimum allocation of resources". **Operations Research**, v. 11, n. 3, Jun. 1963. pp. 399 - 417.

FACELI, K.; CARVALHO, A. C. P. L. F.; REZENDE, S. O. Fusão de Sensores. In: REZENDE, S. O. **Sistemas Inteligentes: Fundamentos e Aplicações**. Barueri: Editora Manole Ltda., v. 1, 2005. p. 525.

GAO, D. et al. "**Application of multi-core parallel ant colony optimization in target assignment**". In: Proceedings of the International Conference on Computer Application and System Modeling (ICCSM). Taiyuan, China: IEEE. 2010. p. 514 - 518.

GOLDBERG, D. E.; LINGLE, R. "**Alleles, loci, and the traveling salesman problem**". In: Proceedings of the First International Conference on genetic Algorithms

and their Applications. Pittsburgh, PA: Lawrence Erlbaum Associates, Publishers. 1985. p. 154 - 159.

GOUVÊA, L. F. Y. **Interceptação de Alvos Móveis em Ambiente com Obstáculos Poligonais Bidimensionais**. Tese de D. Sc., COPPE/UFRJ. Rio de Janeiro, RJ, Brasil. 2012.

GUERRA DE COMANDO & CONTROLE. **Sistema de Armas**, 2014. Disponível em: <<http://sistemasdearmas.com.br/ggn/ggn02c4i.html>>. Acesso em: 20 Outubro 2014.

HALL, D. L.; MCMULLEN, S. A. H. **Mathematical Techniques in Multisensor Data Fusion**. 2. ed. Norwood, MA: Artech House Publications, v. 1, 2004. 449 p.

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. 1. ed. Ann Harbor, MI: The University of Michigan Press, v. 1, 1975.

HOSEIN, P. A. **A class of dynamic nonlinear resource allocation problems**. Phd. Thesis, Massachusetts Institute of Technology. Massachusetts, USA, p. 218. 1990.

JOHANSSON, F. **Evaluating the Performance of TEWA Systems**. Phd.Thesis, University of Skövde. Skövde, Sweden, p. 200. 2010.

JOHANSSON, F.; FALKMAN, G. "A Bayesian Network Approach to Threat Evaluation with Application to an Air Defense Scenario". In: Proceedings of the 11th International Conference on Information Fusion. Cologne, Germany: IEEE. 2008. p. 1352 - 1358.

JOHANSSON, F.; FALKMAN, G. "An empirical investigation of the static-weapon allocation problem". In: Proceedings of the 3rd Skövde Workshop on Information Fusion Topics (SWIFT 2009). Skövde, Sweden: University of Skövde. 2009. p. 63 - 67.

JOHANSSON, F.; FALKMAN, G. "A suite of metaheuristic algorithms for static weapon-target allocation". In: Proceedings of the 2010 International Conference on Genetic and Evolutionary Methods. Skövde: CSREA Press. 2010a. p. 132 - 138.

JOHANSSON, F.; FALKMAN, G. "SWARD - System for Weapon Allocation Research & Development". In: Proceedings of the 13th International Conference on Information Fusion. Edimburg, UK: IEEE. 2010b. p. 1 - 7.

JOHANSSON, F.; FALKMAN, G. "Real Time Allocation of Firing Units to Hostile Targets". **Journal of Advances in Information Fusion**, v. 6, n. 2, Dec. 2011. pp. 187 - 199.

JOSHI, R.; SANDERSON, A. C. **Multisensor Fusion: A minimal representation framework**. 1. ed. Singapore: In Series: Intelligent Control and Intelligent Automation, v. 11, 1999.

JULSTROM, B. A. "**String and permutation coded genetic algorithms for the static weapon-target assignment problem**". In: Proceedings of the 11th Annual Conference Companion on Genetic and Evolutionary Computation Conference. New York, NY, USA: ACM. 2009. p. 2553 - 2558.

KOLITZ, S. E. "**Analysis of a maximal marginal return assignment algorithm**". In: Proceedings of the 27th Conference on Decision and Control. Austin, Texas, USA: IEEE. 1988. p. 2431 - 2436.

LAWLER, E. L.; WOOD, D. E. "Branch and Bound Methods: A Survey". **Operations Research**, v. 14, n. 4, Jul. - Ago. 1966. pp. 699 - 719.

LEE, Z. J.; LEE, C. Y.; SU, S. F. "**Parallel ant colonies with heuristics applied to weapon-target assignment problems**". In: Proceedings of the 7th Conference on Artificial Intelligence and Applications. Taichung, Taiwan: TAAI2002. 2002a. p. 201 - 206.

LEE, Z. J.; LEE, C. Y.; SU, S. F. "An immunity-based ant colony optimization algorithm for solving weapon-target assignment problem". **Applied Soft Computing**, v. 2, n. 1, Aug. 2002b. pp. 39-47.

LEE, Z. J.; LEE, C.-Y. "A hybrid search algorithm with heuristics for resource allocation problem". **Information Sciences**, v. 173, n. 1-3, Jun. 2005. pp. 157 - 167.

LEE, Z. J.; LEE, W. L. A hybrid search algorithm of ant colony optimization and genetic algorithm applied to weapon-target assignment problems. In: LIU, L.; CHEUNG, Y. M.; YIN, H. **Intelligent Data Engineering and Automated Learning**. 1. ed. Hong Kong: Springer Berlin Heidelberg, v. 2690, 2003. p. 278 - 285.

LIANG, K.; WANG, K. "**Using Simulation and Evolutionary Algorithms to Evaluate the Design of Mix Strategies of Decoy and Jammers in Anti-Torpedo Tactics**". In: Proceedings of the Winter Simulation Conference Issues. Monterey, CA, USA: IEEE. 2006. p. 3 - 6.

LIANG, Y. "**An Approximate Reasoning Model for Situation and Threat Assessment**". In: Proceedings of the Fourth International Conference on Fuzzy Systems and Knowledge Discovery. Haikou, Hainan, China: IEEE. 2007. p. 246 - 250.

LIEBHABER, M. J.; SMITH, C. A. P. "**Naval Air Defense Threat Assessment: Cognitive Factors and Model**". Space and Naval Warfare Systems Center. San Diego. 2000.

LIO, P.; VERMA, D. "Biologically inspired networking" [guest editorial]. **IEEE Network**, 24, n. 3, May-Jun 2010. pp. 4.

LITTLE, E.; ROGOVA, G. "**An ontological analysis of threat and vulnerability**". In: Proceedings of the 9th International Conference on Information Fusion. Florence, Italy: IEEE. 2006. p. 1 - 8.

LLINAS, J.; HALL, D. L. **Handbook of Multisensor Data Fusion**. 1^a. ed. Boca Raton: CRC Press, 2001.

LLOYD, S. P.; WITSENHOUSEN, H. S. "**Weapon allocation is NP-complete**". In: Proceedings of the 1986 Summer Conference on Simulation. Reno, NV: Soc. For Computer Simulation. 1986. p. 1054 - 1058.

MANNE, A. S. "A target-assignment problem". **Operations Research**, v. 6, n. 3, May-Jun. 1958. pp. 346 - 351.

MATLIN, S. M. "A review of the literature on the missile-allocation problem". **Operations Research**, v. 18, n. 2, 1970. pp. 334 - 373.

METLER, W. A.; PRESTON, F. L. **A suite of weapon assignment algorithms for a SDI mid-course battle manager**. Naval Research Laboratory. Washington, DC, p. 27. 1990. (ADA229189).

MURPHEY, R. . A. "Target-based weapon target assignment problems. In: Nonlinear Assignment Problems". **Combinatorial Optimization**, New York, 2000. pp. 39 - 53.

NAEM, H.; MASOOD, A. "An optimal dynamic threat evaluation and weapon scheduling technique". **Knowledge-Based Systems**, v. 23, 2010. pp. 337 - 342.

NEMHAUSER, G. L.; WOLSEY, L. A. **Integer and Combinatorial Optimization**. 1. ed. New York, NY: Wiley-Interscience, 1999.

OLIVEIRA, R. L. **O emprego da análise multi-modos na classificação de contatos sonar passivo**. Tese de D.Sc., COPPE/UFRJ. Rio de Janeiro, R.J., Brasil. 2010.

OLIVEIRA, R. L.; LIMA, B. S. L. P.; EBECKEN, N. F. F. "Multiway analysis in data SONAR classification". **Mechanical Systems and Signal Processing**, v. 45, n. 2, Apr. 2014. pp. 531 - 541.

OXENHAM, M. G.; CUTTLER, P. "**Accommodating Obstacle Avoidance in Weapon Allocation Problems for Tactical Air Defence**". In: 9th International Conference on Information Fusion. Florence, Italy: IEEE. 2006. p. 1 - 8.

PARADIS, S. et al. "**Threat evaluation and weapon allocation in network-centric warfare**". In: Proceedings of the 8th International Conference in Information Fusion. Stockholm, Sweden: IEEE. 2005. p. 1078 - 1085.

PEDEMONTE, M.; NESMACHNOW, S.; CANCELA, H. "A Survey on Parallel Ant Colony Optimization". **Applied Soft Computing**, v. 11, n. 8, Dec. 2011. pp. 5181 - 5197.

PERLA, P. P.; MCGRADY, E. D. Why Wargaming Works. **Naval War College Review**, Newport, v. v. 64, n. 3, p. pp. 111 - 130, Summer 2011.

ROSS, G. T.; SOLAND, R. M. "A Branch and Bound algorithm for the generalized assignment problem". **Mathematical Programming**, v. 8, 1975. pp. 91 - 103.

ROUX, J. N.; VUUREN, J. H. Threat evaluation and weapon assignment decision support: A review of the state of the art. **Journal of Operations Research Society of South Africa**, v. 23, n. 2, Dec. 2007. pp. 151 - 186.

ROUX, J. N.; VUUREN, J. H. V. "Real-time threat evaluation in a ground base-based air defence environment". **The Operations Research Society in South Africa**, v. 24, n. 1, Apr. 2008. pp. 75 - 101.

SHARP, H. News Middle East. **BBC News**, 2008. Disponível em: <http://news.bbc.co.uk/2/hi/middle_east/7802276.stm>. Acesso em: 28 out. 2014.

STEINBERG, A. N.; BOWMAN, C. L.; WHITE, F. E. "**Revisions to the JDL Data Fusion Model**". In: Proceedings of the SPIE3719 Sensor Fusion: Architectures, Algorithms, and Applications III. Orlando, FL, USA: SPIE. Digital Library. 1999. p. 430 - 441.

TAKAHASHI, T. Sociedade da Informação no Brasil - Livro Verde. **Ministerio da Ciência e Tecnologia**, Brasília, Setembro 2000. Disponível em:

<www.governoeletronico.gov.br/biblioteca/arquivos/livro-verde/>. Acesso em: 27 Setembro 2014.

WANG, S.; CHEN, W. **"Solving weapon-target assignment problems by cultural particle swarm optimization"**. In: 4th International conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC). Nanchang, Jiangxi, China: IEEE Press. 2012. p. 141 - 144.

ZENG, X. **"Solving Weapon-Target Assignment Problem Using Discrete Particle Swarm Optimization"**. In: The Sixth World Congress on Intelligent Control and Automation. Dalian, China: IEEE Press. 2006. p. 3562 - 3565.